

MODEL TIMBUNAN DUA LAPIS MENGGUNAKAN
BIDIRECTIONAL UNTUK RAMALAN HARGA
EMAS

CHEW YIERN

UNIVERSITI KEBANGSAAN MALAYSIA

**MODEL TIMBUNAN DUA LAPIS MENGGUNAKAN BIDIRECTIONAL UNTUK
RAMALAN HARGA EMAS**

CHEW YI ERN

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

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

BANGI

2021

PENGAKUAN

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

17 September 2021

CHEW YI ERN
P101445

PENGHARGAAN

Saya ingin mengucapkan jutaan terima kasih kepada penyelia projek ini Profesor Madya Dr. Azizi Abdullah yang sudi meluangkan masa dan tenaga untuk menyelia dan mendorong saya sepanjang perjalanan.

Tidak lupa juga ucapan terima kasih kepada semua pensyarah Program Sarjana Sains Data di Fakulti Teknologi Dan Sains Maklumat, UKM yang membina asas untuk membolehkan saya menyempurnakan projek ini.

Terima kasih kepada ibu dan bapa saya kerana memberi saya rahmat pendidikan sejak saya dilahirkan. Tanpa pendidikan asas, saya tidak akan berada di sini. Saya mendedikasikan projek ini bagi kedua-dua mereka.

Pusat Sumber
FTSM

ABSTRAK

Permintaan emas tidak pernah berakhir sebab setiap pelabur pasaran berminat untuk mengetahui tentang trend emas. Oleh itu, ramalan yang tepat adalah penting dalam analisis data kewangan. Sepanjang tahun, rangkaian teknik ekonometri diterapkan pada harga, pemilihan saham, pengurusan krisis tetapi hanya sedikit dari mereka yang berjaya kerana kurangnya fleksibiliti dengan kata lain, berdasarkan skema tunggal. Sementara itu, kaedah pembelajaran mendalam telah muncul dalam beberapa tahun terakhir dan menunjukkan prestasi yang luar biasa dalam bidang pengenalan penglihatan komputer dan pemrosesan bahasa semula jadi. Namun, tidak banyak kajian dilakukan untuk peramalan data kewangan.

Model rangkaian neural konvensional formal seperti rangkaian neural berulang (RNN), mengalami masalah kehilangan kecerunan. Oleh itu, objektif utama kajian ini adalah untuk mengembangkan kaedah timbunan dari pembelajaran dasar RNN untuk meramalkan harga emas. Untuk menawan maklumat temporal data siri masa, model varian RNN yang optimum akan dipilih dan ditingkatkan. Sementara itu, dengan sifat multi-ciri kaedah timbunan yang dicadangkan dapat menangkap lebih banyak maklumat daripada satu ciri, model pembelajaran cetek.

Dalam kajian ini, skema ramalan harga emas dengan kaedah bertimbunan telah dicadangkan, di mana model dasar varian RNN terutama Memori Jangka Pendek Panjang (*Long Short-Term Memory*) seperti, vanilla LSTM, LSTM timbunan (*stacked LSTM*), LSTM dua arah (*Bidirectional LSTM*), CNN-LSTM dan Unit berulang berpagar (*Gated Recurrent Unit*). Dan model asas berprestasi terbaik akan disesuaikan sebagai seni bina utama meta-pembelajaran. Akhirnya, output dari model asas akan dianggap sebagai input untuk membina model meta dalam algoritma timbunan. Sementara itu, set data diperoleh dari World Gold Council dan terdiri dari 10921 hari harga tutup emas harian.

Prestasi model dinilai dengan metrik regresi seperti *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE) dan pekali korelasi (R kuasa dua). Dalam hasil yang diperoleh menunjukkan bahawa LSTM dua arah adalah model berprestasi terbaik dengan skor 10.89 MAE, 18.67 RMSE dan 0.998 R persegi nilai dalam set latihan, dan 16.9 MAE, 22.62 RMSE dan 0.989 R persegi nilai dalam set ujian. Oleh itu, membuktikan LSTM dua arah adalah kaedah yang baik untuk menangkap corak atau ciri data. Untuk meningkatkan permodalan, kaedah timbunan mengungguli hasil LSTM dua arah dalam kumpulan data latihan dan ujian dengan skor 4.94 MAE, 7.90 RMSE dan nilai persegi 0.998 R; dan 14.74 MAE, 21.89 RMSE dan 0.989 R kuasa dua.

TWO LAYERED STACKING RNN MODEL FOR GOLD FORECASTING

ABSTRACT

The demand of gold never ends, and every investor of market keen to know about the trend of the gold. Thus, an accurate prediction is significant in financial data analysis. Throughout these years, series of econometric techniques were applied on pricing, stock selection, crisis management but only few of those are in great success due to the lack of flexibility in other words, based on single scheme. Meanwhile, the deep learning methods had arisen in recent years and demonstrated outstanding performance in field of image recognition and nature language processing. However not much study done for financial data forecasting.

The formal conventional neural network models such as normal simple recurrent neural network, having the problem of vanishing gradient problem. Thus, the main objective of this study is to develop a stacking algorithm from the RNNs base learner to predict the price of gold. To capture the temporal information of the time series data, the optimal RNNs variant model will be chosen and improved. Meanwhile, with the property of multi-feature of the proposed stacking algorithm able to capture more information than a single feature, shallow learning model.

In this study, we propose a gold price forecasting scheme with a stacking algorithm, where the base learner build by recurrent neural network (RNN) variants especially the Long Short-Term Memory (LSTM) such as, vanilla LSTM, stacked LSTM, bidirectional LSTM, CNN-LSTM and Gated Recurrent Unit (GRU). And the best performing baseline model will be adapting as the main architecture of the meta-learner. Finally, the outputs from the baseline models will be treated as the inputs for the meta-learner in the stacking algorithm. Meanwhile, the dataset is obtained from World Gold Council and composed of 10921 days of daily closed price of gold.

Performance of the models are assessed with the regression metrics such as Mean Absolute Error (MAE), Root Mean Squared Error (RMSE) and the coefficient of correlation (R kuasa dua). In the results obtained had showed that bidirectional LSTM is the best performing models with the score of 10.89 MAE, 18.67 RMSE and 0.998 R square value in training set, and 16.9 MAE, 22.62 RMSE and 0.989 R square value in testing set. Thus, proving the bidirectional LSTM is a good algorithm to capture the patterns or spatial features of the data. And to improve the modelling, the stacking method outperformed the results of bidirectional LSTM in both training and testing data set with a score of 4.94 MAE, 7.90 RMSE and 0.998 R square value; and 14.74 MAE, 21.89 RMSE and 0.989 R square value.

KANDUNGAN

| | Halaman |
|--------------------------|--|
| PENGAKUAN | ii |
| PENGHARGAAN | iii |
| ABSTRAK | iv |
| ABSTRACT | v |
| SENARAI JADUAL | ix |
| SENARAI ILUSTRASI | x |
| | |
| SENARAI SINGKATAN | xii |
| BAB I | |
| 1.1 | PENGENALAN 1 |
| 1.2 | Pendahuluan 1 |
| 1.3 | Pernyataan Masalah 4 |
| 1.4 | Objektif Kajian 5 |
| 1.5 | Persoalan Kajian 6 |
| 1.6 | Skop dan Batasan Kajian 6 |
| | Kepentingan Kajian 7 |
| | |
| BAB II | |
| 2.1 | KAJIAN KEPUTUSAN 8 |
| | Sejarah Ringkas Emas sebagai Wang 8 |
| | 2.1.1 Piawaian Emas Klasik 9 |
| | 2.1.2 Sistem Bretton Woods 10 |
| | 2.1.3 Standard Dolar Global 11 |
| 2.2 | Pasaran Emas 12 |
| | 2.2.1 London dan Zurich Locos 13 |
| | 2.2.2 Bursa Komoditi 14 |
| | 2.2.3 Bursa Emas Shang Hai 15 |
| 2.3 | Asas Pemacu Harga Pasaran Emas 16 |
| | 2.3.1 Harta Emas sebagai Elemen 17 |
| | 2.3.2 Permintaan Emas 18 |
| | 2.3.3 Pembekalan Emas 24 |
| | |
| 2.4 | Rangkaian Neural Berulang 28 |
| 2.5 | Memori Jangka Pendek Panjang 29 |
| 2.6 | Varian LSTM untuk Aplikasi Data Siri 31 |
| | Masa |
| | 2.6.1 LSTM Vanila 32 |
| | 2.6.2 LSTM Timbunan 32 |
| | 2.6.3 LSTM dua arah 33 |
| | 2.6.4 CNN-LSTM 35 |
| | 2.6.5 Unit Berpagar Berulang-alih (GRU) 36 |
| 2.7 | Kaedah Timbunan 38 |

| | | | |
|----------------|---------|---|----|
| | 2.7.1 | Set Data Meta dan Pembelajaran-Meta | 39 |
| 2.8 | | Kajian berkaitan Dengan Ramalan Harga Emas Dengan Kaedah Pembelajaran Mesin, Pembelajaran Dalaman dan lain-lain | 40 |
| | 2.8.1 | Mesin Vektor Sokongan | 40 |
| | 2.8.2 | Linear Regresi | 41 |
| | 2.8.3 | Penyokong Regresi Vektor | 42 |
| | 2.8.4 | Hutan Rawak | 43 |
| | 2.8.5 | Jiran terdekat-K | 44 |
| | 2.8.6 | Pembelajaran Statistik | 44 |
| | 2.8.7 | Kaedah pembelajaran mesin maju dan pembelajaran dalaman | 45 |
| 2.9 | | Kesimpulan | 59 |
| BAB III | | METODOLOGI | 60 |
| 3.1 | | Pengenalan | 60 |
| 3.2 | | Set Data | 61 |
| 3.3 | | Kaedah Timbunan | 62 |
| 3.4 | | Sukatan Statistik Deskriptif | 63 |
| 3.5 | | Metrik Penilaian | 63 |
| | 3.5.1 | Purata Ralat Mutlak | 63 |
| | 3.5.2 | Punca Ralat Purata Kuasa Dua | 64 |
| | 3.5.3 | Hubungan Pekali | 64 |
| | 3.5.4 | R Kuasa Dua | 65 |
| 3.6 | | Kesimpulan | 65 |
| BAB IV | | PELAKSANAAN KAJIAN | 66 |
| 4.1 | | Pengenalan | 66 |
| 4.2 | | Set Data Optimum | 66 |
| | 4.2.1 | Pra-pemprosesan Data | 68 |
| | 4.2.1.1 | Penormalan data dan Pemisahan data | 68 |
| 4.3 | | Penyelesaian Model Skim Penyimpanan | 70 |
| | 4.3.1 | Eksperimen Tetap Persekitaran | 70 |
| | 4.3.2 | Pembinaan Model-Model Variasi RNN Dasar Tunggal | 72 |
| | 4.3.3 | Pembinaan Pembelajaran Meta Kaedah Timbunan | 75 |
| 4.4 | | Pengukuran Statistik | 78 |
| 4.5 | | Kesimpulan | 79 |
| BAB V | | Dapatan Kajian | 80 |
| 5.1 | | Tinjauan Keseluruhan | 80 |
| 5.2 | | Hasil Permodelan | 81 |
| | 5.2.1 | Perbandingan Model | 84 |
| 5.3 | | Pengukuran Statistik | 93 |
| 5.4 | | Kesimpulan | 94 |

| | | |
|-------------------|----------------------------------|-----|
| BAB VI | Rumusan Dan Cadangan | 95 |
| 6.1 | Ringkasan Penemuan | 95 |
| 6.2 | Sumbangan Kajian | 95 |
| 6.3 | Batasan Kajian | 96 |
| 6.4 | Cadangan untuk Kajian Masa Depan | 96 |
| RUJUKAN | | 97 |
| LAMPIRAN A | | 104 |
| LAMPIRAN B | | 106 |
| LAMPIRAN C | | 107 |
| LAMPIRAN D | | 114 |
| LAMPIRAN E | | 115 |

Pusat Sumber
FTSM

SENARAI JADUAL

| No. Jadual | | Halaman |
|------------|---|---------|
| Jadual 1.1 | Persoalan Kajian | 4 |
| Jadual 2.1 | Jumlah Permintaan Barang Kemas di Negara China dan India pada 2019 dan 2020 | 20 |
| Jadual 2.2 | Jumlah permintaan emas dalam industri elektronik, pergajian dan lain-lain pada tahun 2019 dan 2020 | 22 |
| Jadual 2.3 | Pengeluaran lombong emas di dunia | 26 |
| Jadual 2.4 | Ringkasan kajian lalu dalam ramalan harga emas | 52 |
| Jadual 4.1 | Harga dan prestasi Emas | 67 |
| Jadual 4.2 | Konfigurasi Model Dasar | 74 |
| Jadual 4.3 | Konfigurasi Pembelajaran Timbunan | 77 |
| Jadual 5.1 | Prestasi model dalam nisbah pemisahan data 80:10:10 dan 60:20:20 | 81 |
| Jadual 5.2 | Prestasi model dicadang, kaedah timbunan dibandingkan dengan skema konvensional yang lain. Hasil terbaik adalah berwarna. | 82 |
| Jadual 5.3 | Hasil Ramalan Data Latihan (training) Model Asas. | 85 |
| Jadual 5.4 | Hasil Ramalan Data Ujian (testing data) dalam Model Asas. | 87 |
| Jadual 5.5 | Hasil Ramalan Output Data Latihan (training) Kaedah Timbunan | 89 |
| Jadual 5.6 | Hasil Ramalan Output Data Ujian (testing) Kaedah Timbunan | 79 |
| Jadual 5.7 | Kehilangan Latihan dan Pengesahan Model Asas | 90 |
| Jadual 5.8 | Kehilangan Latihan dan Pengesahan bagi Kaedah Timbunan | 92 |
| Jadual 5.9 | RMSE Metrik Pengukuran Statistik | 93 |

SENARAI ILUSTRASI

| No. Rajah | | Halaman |
|------------------|--|----------------|
| Rajah 1.1 | Harga Emas Tertutup Harian Dalam USD per Auns | 3 |
| Rajah 2.1 | Pengagihan permintaan tahunan emas dari 2010 hingga 2020 | 19 |
| Rajah 2.2 | Permintaan tahunan barang kemas emas dari 2010 hingga 2020 | 19 |
| Rajah 2.3 | Permintaan pelaburan bagi emas | 21 |
| Rajah 2.4 | Permintaan Industri dari 2010 sehingga 2020 | 22 |
| Rajah 2.5 | Simpanan emas bank pusat negara | 23 |
| Rajah 2.6 | Pembekalan emas dari sektor perlombongan, lindung nilai pengeluar bersih dan emas kitar semula | 24 |
| Rajah 2.7 | Pengeluaran lombong emas dalam tan sejak 2010 hingga 2020 | 25 |
| Rajah 2.8 | Jumlah emas yang telah dikitari semula | 27 |
| Rajah 2.9 | Pemprosesan berturutan dalam Rangkaian Neural Berulang (RNN) | 28 |
| Rajah 2.10 | Seni Bina Model LSTM, dengan Empat Lapisan yang saling Berinteraksi | 30 |
| Rajah 2.11 | Seni Bina LSTM Vanila | 32 |
| Rajah 2.12 | Seni Bina LSTM Timbunan | 33 |
| Rajah 2.13 | Seni Bina LSTM dua arah | 34 |
| Rajah 2.14 | Seni Bina CNN-LSTM | 36 |
| Rajah 2.15 | Seni Bina GRU | 37 |
| Rajah 2.16 | Aliran Rangkaian Kaedah Timbunan | 38 |
| Rajah 3.1 | Kerangka Kajian Penyelidikan | 61 |
| Rajah 4.1 | Ciri yang Diekstrak Untuk Ramalan Harga Emas | 67 |
| Rajah 4.2 | Skema Pemprosesan Data | 69 |

| | | |
|-----------|--|----|
| Rajah 4.3 | Bentuk data input ke dalam model LSTM | 70 |
| Rajah 4.4 | Kerangka model asas dan penilaian | 72 |
| Rajah 4.5 | Skema Kaedah Timbunan dan Penilaian | 75 |
| Rajah 4.6 | Contoh Set Data meta untuk pembelajaran meta di dalam timbunan | 76 |
| Rajah 4.7 | Fungsi TimeseriesGenerator | 76 |
| Rajah 4.8 | Gambaran keseluruhan pengukuran statistik | 78 |

Pusat Sumber
FTSM

SENARAI SINGKATAN

| | |
|----------|--|
| ANN | Artificial Neural Network |
| ANFIS | Adaptive Neural Fuzzy Inference Systems |
| ARIMA | Autoregressive integrated moving average |
| BPTT | Backpropagating Through Time |
| CNN | Convolutional Neural Network |
| CNN-LSTM | Convolutional Neural Network- Long Short-Term Memory |
| CRB | Commodity Research Bureau future indeks |
| DSN | Deep Stacking Network |
| ETF | Exchange Traded Fund |
| EUROUSD | USD/Euro Foreign Exchange Rate |
| GRU | Gated Recurrent Unit |
| INF | Inflation Rate |
| IR | Interest Rate |
| LR | Logistic Regression |
| LSTM | Long Short-Term Memory |
| MAE | Mean Absolute Error |
| MAPE | Maximum Absolute Percentage Error |
| Max AE | Maximum absolute error |
| MSE | Mean Kuasa dua Error |
| NN | Neural Network |
| NYSE | New York Stock Exchange |
| RMSE | Root Mean Kuasa dua Error |
| RNN | Recurrent Neural Network |

| | |
|------|--------------------------|
| SVM | Support Vector Machine |
| SVR | Support Vector Regressor |
| USD | United States Dollar |
| USDX | US Dollar Indeks |
| WGC | World Gold Council |

Pusat Sumber
FTSM

BAB I

PENGENALAN

1.1 PENDAHULUAN

Pasaran kewangan adalah salah satu penemuan yang paling penting pada masa ini yang memberi kesan kepada banyak bidang seperti perniagaan, pendidikan, pekerjaan, teknologi dan ekonomi (Hiransha et al. 2018). Sebagai aset kewangan, emas diedarkan secara meluas di pasaran; sebagai aset rizab, ia merupakan salah satu aset utama aset rizab antarabangsa. Emas sentiasa menjadi alat pelaburan yang dipercayai. Data penyelidikan World Gold Council menunjukkan bahawa sejak tahun 2001, permintaan pelaburan emas di seluruh dunia telah meningkat sekitar 15% setiap tahun (World Gold Council 2019). Menurut laporan tinjauan pasaran runcit emas terkini pada tahun 2019, antara produk pelaburan yang pernah dibeli oleh pelabur, emas berada di kedudukan ketiga dengan 46%, di sebelah akaun simpanan (78%) dan insurans hayat (54%). Dengan demikian, emas semakin menjadi alat pelaburan arus perdana di pasaran global. Sementara itu, jumlah pembelian emas oleh bank pusat pada tahun 2018 adalah 651 tan, peningkatan sebanyak 74% tahun ke tahun, yang menjadi puncak pembelian emas bank pusat sejak kejatuhan sistem Bretton Woods pada tahun 1970-an. Pada separuh pertama tahun 2019, bank pusat global membeli 374.1 tan emas, pertumbuhan tahun ke tahun sebanyak 57%.

Untuk tahun moden, terdapat peningkatan minat pelabur terhadap emas yang luar biasa. Ini disebabkan oleh ketidakpastian nilai mata wang tetap dan kecenderungan kenaikan kadar emas. Oleh kerana fungsi urus niaga dan lindung nilai eksklusif pasaran logam sebelumnya, terutamanya setelah krisis ekonomi 2008, minat global terhadap logam berharga telah meningkat ke tahap baru. Emas adalah logam berharga yang telah

disempurnakan oleh manusia. Ia menjadi mata wang antarabangsa sebagai hasil daripada dominasi domestik yang tidak dapat ditandingi ketika aktiviti kewangan global berkembang. Emas, kerana sifatnya yang terkenal, memainkan peranan penting dalam pembangunan kewangan dan kestabilan sosial masyarakat individu. Sebagai mata wang yang kuat dan logam berharga, emas telah mendapat perhatian luas untuk fungsinya sebagai unit akaun, alat penyimpanan, peredaran, dan pembayaran, antara lain. Sebilangan besar pemilik emas menyimpan pegangan mereka dalam pelbagai bar atau syiling jongkong sebagai lindungan nilai terhadap kenaikan harga atau pergolakan kewangan tambahan.

Beckmann & Czudaj, (2013) menyatakan bahawa emas adalah alat lindung nilai atau aset perlindungan. Secara amnya, peningkatan ketidakpastian dan turun naik pasaran saham dan keadaan geopolitik yang tegang akan menyebabkan risiko penolakan pelabur menjadi panas. Ciri "*safe haven*" emas menarik pelabur untuk memasuki pasaran emas dan mempelbagaikan pelaburan mereka dengan menambahkan emas ke dalam portfolio mereka, dengan itu mempelbagaikan risiko dan memperoleh pulangan jangka panjang. Di bawah latar belakang dasar dan persekitaran pasaran yang berbeza, faktor pendorong yang dominan di sebalik harga emas juga akan berubah. Pada tahun 2020 yang kacau bilau oleh terkena wabak COVID-19, permintaan dan dagangan pertukaran (*Exchanged Traded Funds, ETF*) masih meningkat 40% ke paras tertinggi tahunan iaitu 1,773.2t apabila banding dengan tahun 2019 (World Gold Council 2021a). Aliran kewangan masuk ke dalam ETF emas menunjukkan kekuatan permintaan pelabur untuk emas di seluruh dunia pada masa peningkatan risiko dan ketidakpastian, kadar faedah yang sangat rendah, pengembangan fiskal dan perlambatan ekonomi. Skala pelaburan dalam produk ini menyumbang kepada momentum di sebalik kenaikan harga emas, yang dengan sendirinya menarik aliran masuk pelaburan yang lebih jauh. Permintaan bank pusat untuk emas semakin meningkat. Emas memainkan peranan yang lebih penting dalam aset rizab.

Ramalan harga emas adalah bidang yang baru ditemui yang menarik pelabur kecil dan besar, serta banyak organisasi global. Pelbagai ekuiti jatuh lebih dari 40% semasa krisis ekonomi 2008, begitu juga dengan harga beberapa produk mineral utama, sementara emas meningkat sebanyak 6%. Penyelidikan awal menunjukkan bahawa perubahan dalam kos emas mempunyai kesan yang besar terhadap pengeluarannya, dan

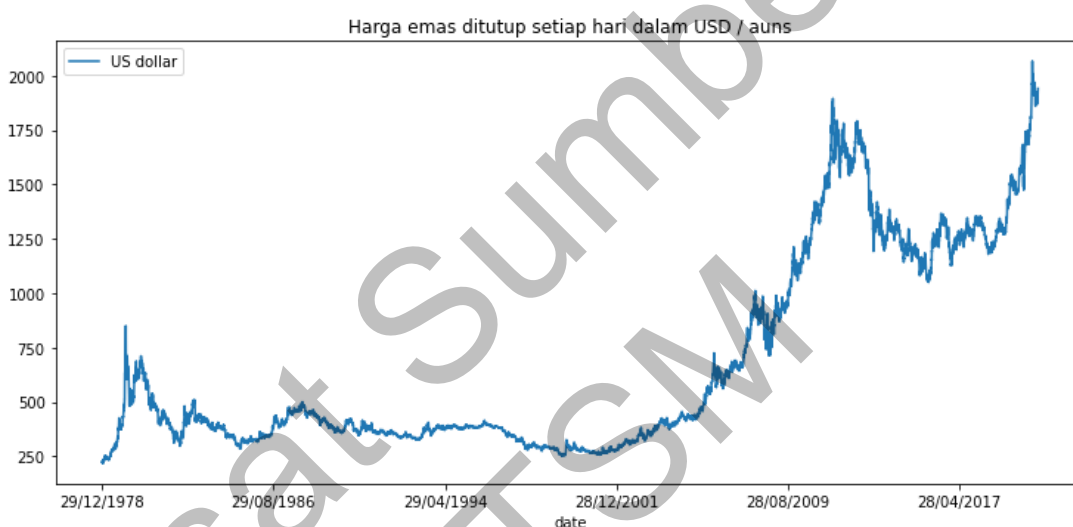
semua kejadian ini, seperti nilai emas dan kesan kadar emas terhadap aktiviti kewangan lain, menekankan kepentingan ramalan kadar. Meramalkan harga adalah komponen penting dalam membuat keputusan kewangan. Ramalan emas menjadi semakin penting pada abad kedua puluh. Di pasaran antarabangsa, emas telah diperdagangkan secara agresif. Banyak derivatif perdagangan emas juga diperdagangkan di pasaran emas global, termasuk pilihan emas, niaga hadapan emas, dan kontrak hadapan. Anehnya, kerana harga emas turun naik dalam julat yang tidak mencukupi, ia mampu mengurangkan kesan inflasi, mengurus kenaikan kos, dan membantu pelaksanaan dasar monetari yang konstruktif (Shafiee & Topal 2010).

Dengan munculnya dan kemajuan dalam pembelajaran mesin dan pembelajaran mendalam, kaedah baru telah muncul untuk lebih memahami corak dan menjalankan ramalan yang lebih tepat. Kaedah berdasarkan data ini memerlukan akses ke set data yang besar, yang telah tersedia selama beberapa tahun terakhir, dan telah membuka jalan bagi penelitian ke arah ini. Pembelajaran mendalam mendapat perhatian luas baru-baru ini kerana prestasi yang unggul terutama dalam bidang penglihatan komputer dan pemrosesan bahasa semula jadi. Idea asas penghasilan mendalam adalah menggunakan sekumpulan data (data latihan) untuk melatih model dan menjalankan ramalan dengan menggunakan set data lain (data pengujian). Walaupun pembelajaran mendalam telah menunjukkan keberhasilannya dalam bidang yang disebutkan di atas, masih dipertanyakan untuk menerapkan pembelajaran mendalam dalam analisis data kewangan. Sebagai contoh, manusia tidak mempunyai kemampuan untuk menjalankan ramalan mengenai kewangan atau memilih saham. Walaupun begitu, inti pembelajaran mendalam adalah mengira satu set data input, yang mungkin berupa data ekonomi, tarikh perakaunan atau catatan transaksi harian dan lain-lain, pemetaan ke hasil tertentu. Oleh itu, secara teorinya, tidak kira seberapa tidak teratur atau tidak linear data yang dimasukkan, dapat mencari hubungan untuk pulangan yang sesuai.

Pelbagai kajian telah dilakukan sepanjang tahun-tahun ini dengan beberapa teknik pembelajaran mesin dalam menyelesaikan masalah meramal harga emas. Risse (2019) mengembangkan pendekatan baru untuk ramalan harga emas bulanan dengan menggabungkan gelombang dan mesin vektor sokongan (*Support Vector Machine, SVM*). Kadar faedah, kadar pertukaran mata wang, harga komoditi, dan harga saham semuanya termasuk dalam ruang ciri. Setiap ramalan ini diperlakukan dengan

gelombang untuk menghasilkan ciri tambahan untuk SVM. *Wavelet SVM* meramalkan harga emas dengan lebih tepat daripada model lain seperti SVM, hutan rawak (*random forest*), atau peningkatan (*boosting*). Pierdzioch dan Risse (2020) meramalkan pulangan emas, perak, platinum, dan paladium menggunakan hutan rawak. Kajian telah mendapati bahawa ramalan pemboleh ubah berbilang lebih tepat daripada ramalan pemboleh ubah tunggal.

1.2 PENYATAAN MASALAH



Rajah 1.1 Harga emas tertutup harian dalam USD per auns (dihasilkan oleh pengarang)

Secara amnya, harga emas berubah-ubah, seperti rajah 1.1 menunjukkan pergerakan harga emas untuk jangka masa sekitar 41 tahun sehingga dari Disember 1978 hingga November 2020. Walaupun begitu, harga emas dapat diramalkan dan memungkinkan pembuatan keputusan masa depan. Oleh kerana pergerakan harga emas adalah urutan siri masa yang dimaksudkan untuk berubah dari masa ke masa, ramalan dengan data tersebut sukar untuk jangka waktu yang lama sehingga pembelajaran mesin dan pembelajaran mendalam diterapkan pada permainan ekonomi dan statistik.. Sementara itu untuk menangkap ketergantungan data yang panjang memerlukan algoritma yang kuat untuk melakukannya. Oleh itu, di sinilah rangkaian saraf memberi sinar harapan untuk meramalkan harga emas.

Seterusnya, masalah utama lain dalam set data ialah penggunaan pemboleh ubah tunggal untuk ramalan. Oleh itu, untuk mendapatkan hasil prestasi yang tepat untuk sistem yang kompleks ini, model peramal memerlukan lebih banyak pemboleh ubah atau maklumat.- Oleh itu, satu penyelesaian yang mungkin adalah dengan menghasilkan satu siri output menggunakan satu set ramalan pembelajaran mesin. Kemudian, dengan bantuan kaedah timbunan untuk meramalkan output yang dihasilkan untuk mendapatkan ramalan yang lebih sah. Sementara itu, model timbunan juga dapat menunjukkan perbezaan kuasa ramalan bagi implikasi pelbagai model dengan model tunggal.

1.3 OBJEKTIF KAJIAN

Objektif utama penyelidikan ini adalah untuk mengembangkan kaedah timbunan di mana ia dapat menerang maklumat atau ciri di antara data harga emas dan kemudian meramalkan harganya. Objektif penyelidikan yang dinyatakan secara terperinci adalah:

1. Mengkaji model variasi rangkaian neural berulang untuk masalah anggaran harga emas.
2. Mencadangkan kaedah timbunan RNN untuk ramalan anggaran emas.
3. Menilai dan membandingkan prestasi timbunan anggaran emas dengan metrik penilaian model regresi.

1.4 PERSOALAN KAJIAN

Jadual 1.1 Persoalan Kajian

| Objektif | Soalan |
|--|---|
| 4. Mengkaji model variasi rangkaian neural berulang untuk masalah anggaran harga emas. | Variasi RNN mana yang mampu memberikan output yang lebih baik? |
| 5. Mencadang kaedah timbunan RNN untuk ramalan anggaran emas | Bagaimana model kaedah timbunan dapat memberikan pemahaman yang lebih baik dalam menyesuaikan ciri? |
| 6. Menilai dan membandingkan prestasi timbunan anggaran emas model-model dasar tunggal variasi RNN dengan kaedah timbunan. | Bagaimana model timbunan dapat memberi pemahaman yang lebih baik dalam menyesuaikan ciri daripada data? |

1.5 SKOP DAN BATASAN KAJIAN

Kajian ini akan menumpukan pada reka bentuk kaedah timbunan LSTM dan kemudian menunjukkan kekuatan rangkaian dalam analisis ramalan untuk data siri masa melalui analisis deskriptif. Dalam kes ini, harga emas harian ditutup. Set data yang digunakan dalam kajian ini terdiri dari 10921 contoh harga emas harian yang ditutup dalam USD per auns yang diperoleh dari World Gold Council (WGC). Yang hanya terdiri daripada satu ciri iaitu harga, dan satu lajur tarikh.

Untuk menilaikan model, metrik penilaian model regresi seperti *Mean Absolute Error* (MAE), *Root Mean Kuasa duad Error* (RMSE) dan R kuasa dua yang merupakan pekali penentuan digunakan untuk mengukur dan menilaikan model. Sementara itu, *Mean Kuasa duad Error* (MSE) digunakan sebagai latihan dan mengesahkan kerugian daripada latihan model.

1.6 KEPENTINGAN KAJIAN

Ramalan data kewangan seperti komoditi lain atau bahagian pasaran mungkin dilakukan dengan reka bentuk model yang berjaya. Sementara itu, mengembangkan model yang konsisten dan tepat dapat memberi manfaat bukan hanya kepada para penyelidik yang menjelajahi data siri waktu yang kacau tanpa corak yang dapat dilihat, tetapi juga para pelabur dan orang lain yang terlibat dalam pasaran komoditi.

Pusat Sumber
FTSM

BAB II

KAJIAN KEPUSTAKAAN

2.1 Sejarah Ringkas Emas sebagai Wang

Menurut sejarawan, emas pertama kali digunakan sebagai wang pada abad kelapan SM di Asia, di mana bentuk emas yang tidak teratur dicap dan digunakan sebagai media pertukaran. Contoh terawal emas tulen dan halus yang digunakan dalam duit syiling dengan gambar yang dicap bermula pada sekitar 550 SM, semasa pemerintahan raja *Lydia, Croesus*. Menurut beberapa bukti, orang Mesir kuno menggunakan emas sebagai alat pertukaran sejak 2 000 SM. Emas telah digunakan sebagai wang sekurang-kurangnya 3000 tahun, dengan bukti yang menunjukkan bahawa ia digunakan dan diperdagangkan sebagai perhiasan sejak 5000 SM oleh orang Mesir, yang memandang emas sebagai lambang keabadian dan kekuatan kerana ketahanannya terhadap kakisan dan penampilan berkilat (World History Encyclopedia 2014).

Hari ini, sejarawan dan mereka yang terlibat dalam industri emas merujuk mata wang yang disokong oleh emas fizikal sebagai wang bunyi (*Sound money*), iaitu wang yang tidak terdedah kepada kenaikan atau kejatuhan daya beli secara tiba-tiba dalam jangka masa panjang, dibantu oleh mekanisme pembetulan diri yang wujud dalam sistem pasaran bebas. Wang bunyi merupakan sistem yang hanya dibenarkan secara global pada awal tahun 1970-an. Pada awal Amerika Syarikat, terdapat banyak wang, dan petikan langsung dari Artikel 1 bahagian 10 fasal 1 dari perlembagaan AS menyatakan: Tidak ada Negara yang akan terlibat dalam Perjanjian, Perikatan, atau Gabungan; akan menganugerahkan Surat *Marque and Reprisal*; hendaklah mencetak Wang; hendaklah mengeluarkan Bil Kredit; dan mana-mana Negara tidak akan

mengeluarkan apa-apa selain emas dan perak. Syiling Tender dalam Pembayaran Hutang; menggubal apa-apa *Bill of Attainder*, undang-undang Ex Post Facto, atau Undang-Undang yang melanggar Kewajipan Kontrak; atau menganugerahkan apa-apa Gelaran Bangsawan (Constitution Annotated n.d.).

2.1.1 Piawaian Emas Klasik

Piawaian ataupun standard emas didasarkan pada premis bahawa negara akan menetapkan kadar pertukaran tetap antara emas dan mata wang mereka sendiri. Selain itu, tidak ada batasan pada import dan eksport emas, yang memungkinkan untuk menyelesaikan perdagangan antarabangsa dalam emas. Kerana bekalan wang negara dihubungkan dengan jumlah emas yang mereka miliki, aliran yang dihasilkan dari perdagangan antarabangsa menentukan ukuran penawaran wang setiap negara. Peningkatan penawaran wang mengakibatkan inflasi di negara-negara dengan lebih perdagangan dan deflasi di negara-negara dengan defisit perdagangan. (World Gold Council 2018a).

Piawaian emas tradisional sering disebut sebagai sistem pembetulan sendiri, kerana deflasi di negara-negara dengan defisit perdagangan menyebabkan harga domestik turun, sehingga meningkatkan daya saing antarabangsa negara itu. Daya saing yang meningkat menarik pelabur asing, yang mengakibatkan pengembangan penawaran wang, dan keadaannya membalikkan. (World Gold Council 2018a).

Di bawah standard emas klasik, bank pusat mempunyai dua fungsi utama: menjaga kebolehtukaran wang kertas yang diedarkan kepada emas pada harga tetap dan mempercepat proses penyesuaian sekiranya berlaku ketidakseimbangan imbalan pembayaran (World Gold Council 2018a). Kerana fakta bahawa kadar faedah ditentukan oleh penawaran dan permintaan untuk mata wang asli negara itu, bank pusat tidak memiliki pernyataan mengenai suku bunga yang sekarang mereka tetapkan secara langsung. Permulaan Perang Dunia Pertama pada pergantian abad kedua puluh mengubah standard emas klasik. Walaupun negara-negara lain menerapkan amalan dan dasar baru sepanjang dekad pertama abad baru, bermulanya Perang Dunia I pada tahun 1914 sering dianggap sebagai akhir standard emas klasik.

2.1.2 Sistem Bretton Woods

Menjelang tahun 1950, AS telah menjadi pegangan emas terbesar di dunia, dengan rizab nasional berjumlah 20 279 tan, menyumbang lebih dari 68% daripada jumlah simpanan emas nasional dunia selepas perang dunia II. Oleh kerana hakikat bahawa simpanan emas dunia banyak disatukan di Amerika Syarikat selepas , dunia memerlukan sistem baru yang tidak memerlukan negara-negara untuk mempertahankan simpanan emas yang cukup besar untuk melakukan perdagangan internasional. Pada bulan Julai 1944, perwakilan dari 44 negara berkumpul di Bretton Woods, New Hampshire, Amerika Syarikat, untuk mendirikan sistem monetari baru di seluruh dunia, yang kemudian dikenali sebagai sistem Bretton Woods. Hakikatnya, Perjanjian Bretton Woods menyebabkan dolar AS menjadi mata wang rizab dunia (Harvard Business School 2005).

Pada mulanya, sistem Bretton Woods melaksanakan objektifnya dengan baik, menanamkan keyakinan terhadap perdagangan tempatan dan kemudian di seluruh dunia dalam dunia yang hancur akibat perang. Ini dicapai terutamanya dengan membolehkan dolar AS berfungsi sebagai mata wang penukaran dominan di Eropah, dengan mata wang tempatan secara bertahap menggantikannya (Harvard Business School 2005). Sebilangan besar negara maju harus dibanguni kembali dari bawah ke atas, memerlukan permintaan tinggi untuk pekerja binaan dan mesin, serta untuk industri sekutu seperti pengangkutan. Hasilnya, Eropah dan Amerika Syarikat mengalami pengangguran yang rendah dan perkembangan ekonomi yang agak stabil. Zaman ini mula dikenali sebagai ledakan pasca perang, kadang-kadang dikenali sebagai zaman keemasan kapitalisme, di seluruh dunia. Apabila keadaan hidup bertambah baik dalam tempoh peruntukan perang dunia, AS mula membina ketidakseimbangan perdagangan dengan rakan dagang Eropah dan Asia. Ini mengakibatkan penurunan cepat dalam pemegangan emas AS, ketika negara-negara Eropah mulai menuntut emas sebagai pertukaran dolar AS yang terkumpul melalui perdagangan dengan AS.

Penurunan simpanan emas AS yang pesat pada tahun 1960-an, bersama dengan peningkatan defisit pemerintah AS, mengakibatkan tempoh inflasi yang tinggi di Amerika Syarikat. Ketika negara-negara mengembalikan emas dari AS, mereka mengimbangi AS dalam dolar AS, yang mengakibatkan peningkatan jumlah dolar yang beredar di AS. Menurut prinsip kecepatan wang, meningkatkan jumlah mata wang dalam peredaran mengakibatkan peningkatan inflasi apabila halaju wang tetap. Dengan

kata lain, ketika negara-negara Eropah mengembalikan wang tunai AS ke AS, harga pengguna meningkat secara mendadak di AS. Perkembangan ini di Amerika Syarikat menimbulkan kebimbangan di Eropah mengenai kemampuan Amerika Syarikat untuk menukar dolar menjadi emas berdasarkan permintaan.

Akibatnya, era Bretton Woods berakhir pada 15 Ogos 1971, ketika Presiden AS Richard Nixon mengeluarkan perintah eksekutif untuk menghentikan penukaran dolar AS menjadi emas. Kejadian ini merupakan sebahagian daripada urutan dasar ekonomi yang dilaksanakan pada awal 1970-an yang dikenali sebagai Nixon Shock (US department of State, 2018). Kesimpulan dari era Bretton Woods menandakan Standard Dolar Global, yang berterusan hingga ke hari ini.

2.1.3 Standard Dolar Global

Berikutan perintah eksekutif Presiden Nixon untuk menghentikan pengaturan Bretton Woods pada tahun 1971, semua mata wang dunia yang disokong oleh dolar menjadi mata wang fiat, sementara emas menjadi komoditi terapung bebas. Hampir setiap negara di dunia menerima dolar AS sebagai media pertukaran di peringkat pemerintah melalui sistem Swift, kecuali beberapa negara. Dolar AS juga diakui secara universal oleh orang ramai, dan sebagai peraturan umum, sesiapa sahaja yang mempunyai dolar AS boleh melakukan perjalanan ke hampir mana-mana negara di dunia.

Dolar, bersama dengan Euro, Yuan Cina, Yen Jepun, dan Pound Britain, sering disebut sebagai aset rizab. Konsep standard dolar digambarkan dengan baik oleh penggunaan dolar yang meluas dalam transaksi antarabangsa. Pada masa ini, dolar dipandang sebagai mata wang yang kuat yang memberikan keselamatan semasa pergolakan ekonomi antarabangsa. Seperti yang dijelaskan sebelumnya, dolar mencapai kedudukan mata wangnya yang kuat dengan menerapkan dasar kewangan yang agak baik dan berfungsi sebagai pembekal ke Eropah semasa dan selepas Perang Dunia I dan II. Sistem Bretton Woods membolehkan AS memperluas kawalannya terhadap sistem monetari global, yang mencerminkan kedudukan unik semasa dolar. Dolar AS pada masa ini merupakan aset rizab pertukaran asing yang paling banyak dipegang di dunia yang merangkumi 59.23 peratus daripada rizab global yang diperuntukkan sebagai rizab

rasmi, dilaporkan kepada Dana Kewangan Antarabangsa (*Internasional Monetary Fund, IMF*) sehingga Q2 tahun 2021 (International Monetary Fund 2021).

Dengan hampir 80% urusan niaga antara wilayah dilakukan dalam dolar AS, penerimaan global yang meluas dalam dolar, dan dolar menyumbang sebahagian besar rizab pertukaran asing global, angka tersebut menyokong pernyataan bahawa dunia berada pada apa yang disebut 'Standard Global Dolar' di mana hampir semua negara bergantung pada dolar yang berfungsi. Kedudukan dolar yang unik membolehkan AS menjatuhkan sekatan ke atas negara-negara lain. Banyak negara dan organisasi, termasuk Rusia, China, dan Kesatuan Eropah, jelas tidak berpuas hati dengan kemampuan AS untuk menjatuhkan sekatan dan melarang bank dari sistem Swift. Ini telah mengakibatkan peningkatan jumlah pengaturan pembayaran merentas desa yang bertujuan memintas dolar AS dan sistem Swift dengan berdagang dalam mata wang tempatan dan bukannya dolar AS (Financial Time 2018).

2.2 PASARAN EMAS

Seperti kebanyakan komoditi, emas diperdagangkan secara global melalui pasar spot fizikal, bursa niaga hadapan, dan pasar derivatif di luar kaunter (*Over The Counter, OTC*). Pasaran emas terbesar adalah London dan Zurich Locos, yang menawarkan produk OTC seperti spot, forward, dan deposit sewa pinjaman; pertukaran niaga hadapan *Commodity Exchange Inc, COMEX*, yang dikendalikan oleh *New York Mercantile Exchange (NYMEX)*; dan *Shanghai Gold Exchange (SGE)*, yang menawarkan produk niaga hadapan dan OTC seperti spot. Perbezaan utama antara OTC dan emas yang diperdagangkan adalah dari segi fleksibiliti dan privasi. Kontrak niaga hadapan (*Exchanged Traded Future, ETF*) yang diperdagangkan pertukaran diseragamkan dari segi ukuran kontrak, kaedah penghantaran, dan tarikh luput, tetapi transaksi OTC selalu disesuaikan dengan keperluan pihak, walaupun konvensi khusus pasar berlaku. Selain itu, dalam kontrak derivatif yang diperdagangkan di bursa, risiko rakan niaga diperuntukkan untuk pertukaran, tetapi dalam transaksi OTC, risiko rakan niaga diperuntukkan antara pihak yang terlibat (LBMA 2017).

Menurut *London Bullion Market Association* (LBMA), ketelusan pasaran emas global telah meningkat dalam beberapa tahun kebelakangan ini sebagai hasil daripada data baru dalam bentuk data import/eksport yang diterbitkan dari negara-negara perdagangan emas utama, data bank pusat yang dipertingkatkan, maklumat harian mengenai aliran pelabur utama, dan pemegangan peti besi London. LBMA adalah penentu standard yang diakui secara global untuk logam mulia yang diperdagangkan secara fizikal, termasuk emas. Bersama dengan menetapkan kriteria untuk pengiriman dan penyempurnaan emas fizikal, LBMA bertanggungjawab untuk memastikan integriti peserta pasaran dan kualiti emas yang ditukar di London (LBMA n.d.). Selain itu, LBMA telah mula mendedahkan aktiviti perdagangan OTC anggotanya di London dan Zurich Locos, yang dahulunya merupakan pasar swasta.

2.2.1 London dan Zurich Locos

Kedua-dua Locos London dan Zurich adalah pasar logam berharga OTC yang merangkumi pasaran deposit spot, swap, forward, opsiyen, dan pinjaman sewa. London Loco secara meluas dianggap sebagai lokasi penghantaran emas fizikal operasi tertua di dunia dan pada masa ini diunjurkan sebagai pasaran emas fizikal terbesar di dunia dari segi jumlah transaksi (World Gold Council 2021b). Pasaran Loco secara meluas dianggap sebagai pasaran logam berharga utama di dunia, merangkumi kira-kira 70% daripada jumlah dagangan nota global mengikut anggaran WGC, dengan London memberi tumpuan kepada penghantaran emas dan perak dan Zurich pada penghantaran platinum dan paladium, namun kedua-dua pasaran menawarkan penghantaran keempat-empat logam mulia berdasarkan keperluan pelaku pasaran (LBMA 2017). Pasar London unik kerana ia menjual 400 bar bar yang ditetapkan sebagai bar yang berkualiti diadakan di peti besi *London Precious Metals Clearing Limited* (LPMCL) dan *Bank of England* (World Gold Council 2021b). Dan dengan pasaran OTC lain, pasaran Loco emas tidak jelas, kerana urusan niaga antara kedua-dua pihak sering dilakukan secara rahsia. London Loco selalu dianggap sebagai pasar emas utama, jauh lebih besar daripada Zurich Loco dari segi penyelesaian emas.

Titik data yang paling kritikal di London Loco adalah pembetulan AM dan PM, yang menetapkan penanda aras antarabangsa untuk harga emas dua kali sehari pada waktu perniagaan pada jam 10:30 dan 15:00 waktu London. Pemasangan emas pertama kali diadopsi pada tahun 1919 di London Loco dan secara meluas dianggap sebagai harga standard global untuk emas (LBMA 2017).

London Loco tidak ditadbir secara langsung oleh satu pengendali. London Loco dikawal dalam dua cara yang berbeza: satu mengawal pasar itu sendiri, dan yang lain mengawal peserta pasar. Pihak Berkuasa Kelakuan Kewangan Britain (*Financial Conduct Authority, FCA*) mengawal sebahagian besar pelaku pasaran, tetapi bukan pasaran itu sendiri. FCA mengawasi sisi derivatif pasaran emas dan perak London, termasuk pertukaran dan opsiyen (*option*); namun, FCA tidak mengatur simpanan *spot*, *forward*, atau emas, menurut LBMA (2017).

2.2.2 Bursa Komoditi (The Commodity Exchange, COMEX)

COMEX, yang merupakan anak syarikat New York Mercantile Exchange (NYMEX), bursa niaga hadapan (*futures*) komoditi terbesar di dunia dan kini merupakan pertukaran niaga hadapan emas teratas di dunia. WGC melaporkan bahawa pertukaran niaga hadapan emas COMEX rata-rata jumlah harian melebihi 50 bilion AS dolar pada tahun fiskal 2020 (World Gold Council 2021c). Kadar pertukaran niaga hadapan emas COMEX paling tidak relevan, jika tidak lebih, daripada London Loco, kerana COMEX dapat diakses oleh majoriti, jika tidak semua, peserta pasar emas, sedangkan London Loco lebih lazim ketika berurusan dengan sangat sebilangan besar emas fizikal.

Menurut anggaran WGC sebelumnya mengenai kecairan pasaran emas, COMEX dianggarkan hanya menyumbang 15% dari keseluruhan kecairan perdagangan emas tahunan. Anggaran ini dengan cepat berubah setelah pembebasan set data LBMA-i awal, dan World Gold Council kini meletakkan angka tersebut pada 29.7% (World Gold Council 2021c). COMEX memperdagangkan kedua-dua niaga hadapan emas dan opsiyen niaga hadapan, dan tidak seperti pasaran Loco, COMEX secara langsung dikawal selia oleh *Commodity Futures Trading Commission (CFTC)*, pengatur derivatif umum Amerika Syarikat. CFTC memainkan peranan penting dalam krisis kewangan 2008 dan Pembaharuan *Dodd-Frank Wall Street Reform*.

2.2.3 Bursa Emas Shanghai (Shanghai Gold Exchange)

Bursa Emas Shanghai (*Shanghai Gold Exchange, SGE*) dan Bursa Emas Antarabangsa Shanghai (*Shanghai International Gold Exchange, SGEI*) adalah dua perkembangan emas yang paling ketara. Bank Negara China menubuhkan SGE pada tahun 2002 untuk membolehkan perdagangan emas secara dalaman di negara China. Pada tahun yang sama, SGEI ditubuhkan untuk memperluas ruang lingkup dan kesan pasaran emas fizikal China. SGE dipisahkan menjadi dua segmen: niaga hadapan dan spot. Tidak seperti London Loco dan COMEX, emas diperdagangkan dalam gram dan bukannya auns di Shanghai, dan kemurnian bar yang diperdagangkan tidak ditentukan oleh piawaian pengiriman LBMA yang baik tetapi oleh Shanghai sendiri. Sebilangan besar emas yang diperdagangkan di Shanghai disucikan hingga 99,99% ketulenan, walaupun kriteria penghantaran yang sangat baik LBMA memerlukan kemurnian 99.5%.

SGE melancarkan Harga Penanda Aras Emas Shanghai pada 2016, yang merupakan harga rujukan dalam denominasi RMB yang ditentukan dua kali sehari pada pukul 10:15 dan 14:15 waktu Beijing melalui prosedur lelong terpusat yang diadakan di SGE. Menurut kertas putih yang dihasilkan oleh SGE, harga penanda aras dikembangkan "untuk memberikan harga penanda aras emas berdenominasi RMB yang boleh dipasarkan dan stabil -" dan "untuk mempromosikan pertumbuhan pasaran kewangan China" (World Gold Council 2018b). Perdagangan berlaku dalam tiga sesi berbeza dengan selang waktu di antara, berbeza dengan sesi berterusan tunggal yang terdapat di Loco dan COMEX (BullionStar n.d.-a).

Sebagai perbandingan dengan pasaran emas yang lain, SGE mempunyai beberapa ciri yang membezakan, termasuk kriteria kemurnian yang lebih ketat dan jeda antara sesi perdagangan. Pada bulan September 2018, pasar emas Shanghai menjadi yang pertama di dunia yang memperkenalkan syiling emas standard yang dapat diperdagangkan secara terbuka, dengan panda Cina 30g menjadi koin emas yang diperdagangkan di bursa pertama. Perlu diperhatikan bahawa orang Cina mula mengeluarkan duit syiling panda emas rasmi dalam gram dan bukannya auns pada tahun 2015 (Ronan 2018). Selain itu, ini berlaku untuk ukuran penghantaran jongkong emas yang diperdagangkan di SGE. Walaupun sebilangan besar bar yang diperdagangkan di SGE adalah berat 50g, 100g, atau 1kg, bar yang kurang sucinya 3kg dan LBMA 12,5kg juga tersedia (BullionStar n.d.-b).

Walaupun revolusi dengan sendirinya, Majlis Emas Dunia percaya bahawa pasaran emas Shanghai, yang terdiri daripada perdagangan fizikal dan niaga hadapan, menyumbang lebih dari 7% daripada jumlah dagangan emas tahunan pada tahun 2020 (World Gold Council 2021c). SGE adalah pertukaran *spot* fizikal terbesar di dunia sebelum munculnya emas berjangka melalui SHFE. Walaupun tidak signifikan dibandingkan dengan pertukaran emas lain, SGE telah meningkatkan impaknya di peringkat antarabangsa. SGE membuat langkah pertama yang menonjol ke pasaran Eropah pada tahun 2017 ketika mengumumkan tujuannya untuk meningkatkan penggunaan penanda aras emas dalam denominasi yuannya dengan menyenaraikannya di Bursa Saham Budapest. SGE menyenaraikan standard emas berdenominasi yuan di Dubai Gold and Commodities Exchange pada tahun berikutnya (South China Morning Post 2017).

2.3 Asas Pemacu Harga Pasaran Emas

Bab 2.3 ini membincangkan sifat emas sebagai elemen, trend penawaran dan permintaan yang paling ketara di pasaran emas fizikal, serta struktur industri dan cabaran masa depan. Sementara itu, tumpukan usaha anda pada aspek lain dari fungsi penawaran dan permintaan. Walaupun penawaran dan permintaan adalah pusat tindakan harga, alasan untuk penawaran dan permintaan lebih penting, itulah sebabnya bab ini secara ringkas. Bahagian analisis pasaran laporan ini meneliti bahagian permintaan. Oleh kerana peserta pasaran emas berasal dari pelbagai industri, dari perbankan hingga teknologi, dan dari pelaburan hingga aplikasi perubatan, sangat sukar untuk mendapatkan akses ke pasar emas secara keseluruhan. Oleh kerana sifat buram emas yang kabur, kerahsiaan penggunaan sumber syarikat teknologi, dan kerahsiaan sekitar laporan pemerintah, proses penilaian sangat mengambil masa dan sukar. World Gold Council (WGC) berusaha untuk memberikan analisis pasaran, tetapi walaupun dengan sekumpulan pakar, penilaian dibuat berdasarkan usaha terbaik. Ini bermaksud bahawa walaupun sebahagian besar angka yang dikemukakan tidak tepat, mereka adalah anggaran terbaik yang tersedia untuk laporan ini. WGC telah menjalankan banyak penyesuaian terhadap angka permintaan emasnya selama ini. Laporan dan

laman web WGC yang tersedia untuk umum digunakan untuk mengumpulkan data laporan ini mengenai trend penawaran dan permintaan emas.

2.3.1 Harta Emas sebagai Elemen

Emas memiliki dan menggabungkan pelbagai sifat unik yang didapati bermanfaat dalam pelbagai industri, termasuk pelaburan, perhiasan, teknologi, dan, baru-baru ini, penjagaan kesihatan. Aplikasi terawal emas adalah perhiasan, tetapi kerana penampilan emas yang menarik, emas masuk ke dalam sistem kewangan di seluruh dunia. Kemudian dalam sejarah, masyarakat moden menemui banyak aplikasi untuk emas di pelbagai industri. Emas adalah salah satu unsur yang tidak mudah berubah pada jadual berkala, hanya mengiringi platinum sebagai logam reaktif paling tidak aktif. Contohnya, emas tidak bertindak balas dengan oksigen dalam keadaan semula jadi, menjadikannya hampir tidak tahan terhadap kakisan semula jadi. Selain itu, emas adalah logam konduktif elektrik ketiga terbesar di planet ini, di belakang perak dan tembaga (All Metals Fabrication, 2016).

Emas adalah bahan yang sesuai untuk penebat elektronik kerana gabungan rintangan kakisan dan kekonduksian elektronik. Ia digunakan secara meluas sebagai bahan pelapis pada komponen elektronik seperti unit pemprosesan pusat, atau CPU. Oleh kerana emas agak mahal per gram, industri teknologi sering menggunakan lapisan emas yang tipis secara mikroskopik untuk melapisi litar yang mungkin mengandungi pendawaian tembaga atau perak. Selain itu, emas sangat lembut, yang bermaksud boleh dicairkan dan dibentuk dengan mudah. Kelenturan emas disebabkan tahap kekerasan dan takat lebur yang rendah, yang menjadikannya sesuai untuk digunakan dalam pelbagai industri. Emas berada di tengah-tengah spektrum titik lebur, pada suhu 1063 darjah Celsius atau 1945 darjah Fahrenheit, yang lebih rendah daripada titik lebur nikel 1453 darjah Celsius atau 2647 darjah Fahrenheit tetapi jauh lebih tinggi daripada titik lebur timbal 327 darjah Celsius atau 621 darjah Fahrenheit (The Engineering Toolbox 2008).

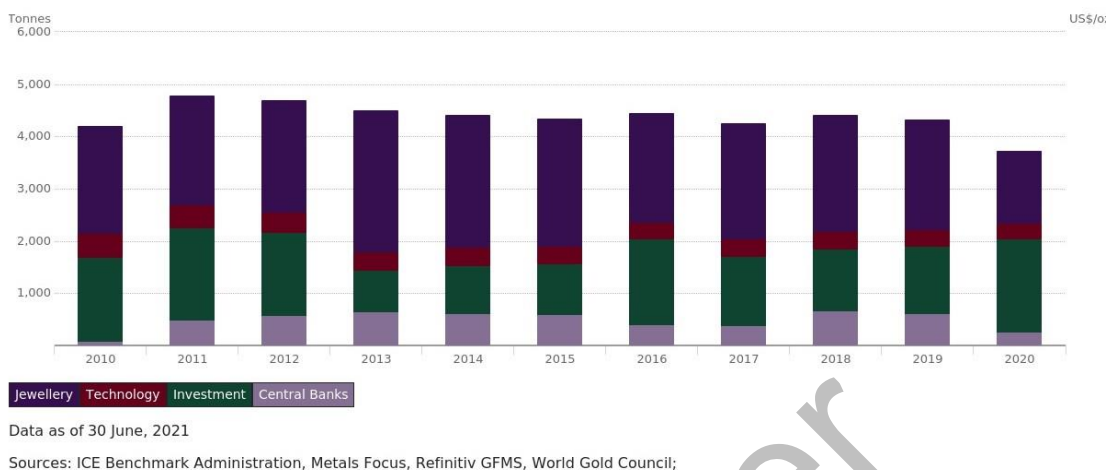
Kekerasan rendah emas jelas kelihatan pada perhiasan emas 24 karat, yang terlalu lembut untuk menggunakan kunci perhiasan mekanikal; sebaliknya, kunci perhiasan emas 24 karat adalah gelung bengkok yang terbuka dan ditutup. Oleh kerana ketumpatan emas yang tinggi, ia dikelaskan sebagai logam berat. Pada suhu bilik, emas mempunyai berat kira-kira 19,3 gram per sentimeter padu, yang setanding dengan berat

plutonium 19,8 gram per sentimeter padu. Sebagai perbandingan, emas lebih daripada tujuh kali berat aluminium dan lebih daripada dua kali berat besi. (The Engineering Toolbox, 2004).

Oleh kerana ketumpatan dan kelenturan emas yang besar, satu auns emas dapat dimampatkan menjadi kepingan lut dengan ketebalan hanya 0,00018 milimeter, yang akan membentang sekitar 80 kilometer sebagai wayar. Oleh kerana kekreatifan emas rendah, aplikasi perubatan dan kemajuan dalam bidang nanoteknologi mula muncul. Sebagai contoh, emas dapat digunakan untuk mengirinkan ubat secara langsung ke tisu barah, dan nanopartikel emas dapat digunakan untuk terapi gen, pengesanan tumor, dan peningkatan dos dalam radioterapi (World Gold Council 2018c). Menurut peribahasa kuno, emas membunuh bakteria ketika bersentuhan. Walau bagaimanapun, kerana kesan oligodinamik emas, bakteria tidak dapat tumbuh di atasnya, menjadikan emas sedikit membersihkan diri. Inilah sebabnya mengapa emas terus digunakan dalam pergigian. Ciri-ciri emas yang pelbagai menjadikannya elemen yang benar-benar unik yang menikmati permintaan dari pelbagai industri, yang secara kolektif menyumbang ke arah permintaan emas. Bab berikut membahas trend permintaan dan spesifik emas.

2.3.2 Permintaan Emas


Permintaan emas global dapat diklasifikasikan menjadi empat segmen yang berbeza berdasarkan ukurannya: perhiasan, pelaburan, bank pusat, dan teknologi. Menurut kepada World Gold Council (2021a), Permintaan pelaburan, yang merangkumi pelabur emas dan perak swasta dan ETF dan produk serupa, melebihi permintaan barang kemas, merangkumi 43% daripada permintaan emas tahunan pada tahun 2020. Sektor kedua terbesar adalah sektor perhiasan, yang menyumbang sekitar 34% permintaan emas tahunan, sementara sektor ketiga dan keempat iaitu bank pusat dan teknologi menyumbang 23% permintaan selebihnya. Rajah 2.1 menunjukkan pengagihan permintaan tahunan emas dari 2010 hingga 2020 dalam 4 sektor yang disebutkan.



Rajah 2.1 Pengagihan permintaan tahunan emas dari 2010 hingga 2020 (World Gold Council 2021d).

(A) Permintaan Barang Kemas

Rajah 2.2 telah menunjukkan bahawa permintaan tahunan barang kemas emas telah kekal stabil antara 2000 dan 2700 tan (World Gold Council 2021d). Permintaan barang kemas pada tahun 2020 turun ke tahap tahunan terendah dalam catatan, dipadamkan oleh gabungan wabak global COVID-19 mengakibatkan penutupan pasaran yang dihasilkan dan mencatatkan harga emas yang tinggi pada masa perlambatan ekonomi. Namun begitu, jumlah permintaan barang kemas emas tahunan turun kepada 1,411.6t, iaitu terendah dalam siri data tahunan dan 34% lebih rendah daripada tahun 2019. Dua pasaran terbesar, India dan China, adalah dua penyumbang utama kepada penurunan permintaan barang kemas tahunan (World Gold Council 2021a).



Rajah 2.2 Permintaan tahunan barang kemas emas dari 2010 hingga 2020 (World Gold Council 2021d).


Jadual 2.1 Jumlah Permintaan Barang Kemas di Negara China dan India pada 2019 dan 2020.

| TAN | 2019 | 2020 | PERBEZAAN TAHUN LEPAS |
|----------------------|--------|--------|--------------------------|
| JUMLAH GLOBAL | 2122.7 | 1411.6 | -34% |
| INDIA | 544.6 | 315.9 | -42% |
| CHINA | 638 | 415.6 | -35% |

Jadual 2.1 telah menunjukkan jumlah permintaan barang kemas di negara China dan India pada 2019 dan 2020. Pasaran barang kemas China telah banyak terjejas di dua bidang sepanjang tahun 2020. Di satu pihak, kerosakan ekonomi dan sekatan aktiviti sosial yang disebabkan oleh COVID-19 pada Q1 mempengaruhi permintaan perhiasan emas tahunan. Sebaliknya, perubahan struktur - seperti peruncit mengurangkan inventori mereka, penyatuan industri mengurangkan jumlah peruncit barang kemas secara umum, dan pilihan berterusan pengguna muda untuk produk yang lebih ringan semuanya menyumbang kepada penurunan permintaan perhiasan emas. Dalam siri data WGC, 2020 menandakan rendah baru bagi permintaan emas India: turun 42 peratus kepada 315.9t. Kerugian berkurang dengan ketara pada suku keempat, dengan permintaan turun hanya 8% dari tahun ke tahun. Manakala Perayaan dan perkahwinan meningkatkan permintaan perhiasan emas pada Q4 oleh kerana keturunan kes COVID-19, tetapi masih tetap lemah berdasarkan sejarah (World Gold Council 2021a).

(B) Permintaan Pelaburan

Menurut WGC, permintaan pelaburan merangkumi kedua-dua syiling jongkong swasta dan permintaan bar dan permintaan dari kenderaan pelaburan yang disokong secara fizikal seperti ETF. Sebagai perbandingan dengan dana yang diperdagangkan di bursa yang disokong emas, permintaan jongkong swasta biasanya menyumbang bahagian yang lebih besar dari jumlah permintaan pelaburan setiap tahun. Secara rasmi, permintaan pelaburan emas fizikal adalah segmen permintaan terbesar kedua.




Rajah 2.3 Permintaan pelaburan bagi emas (World Gold Council 2021d).

Bagi tahun 2020, sektor pelaburan adalah salah satu daripada beberapa titik terang dalam tahun bergelora untuk pasaran emas. Rajah 2.3 menunjukkan permintaan pelaburan bagi emas. Pelaburan emas tahunan berjumlah 1,773.2t, tahap tertinggi dalam siri data dan 40% lebih tinggi daripada pada tahun 2019, dan mencapai tahap tertinggi dalam tempoh sepuluh tahun yang lalu, dengan pelabur Barat di seluruh spektrum mendorong sebahagian besar pertumbuhan. Aliran masuk ke dalam ETF emas mencapai tahap rekod, menunjukkan kekuatan permintaan pelabur untuk emas secara global dalam tempoh peningkatan risiko dan ketidakpastian, kadar faedah yang sangat rendah, pengembangan fiskal, dan perlambatan ekonomi. Besarnya pelaburan dalam produk ini mendorong momentum di sebalik kenaikan harga emas, yang pada gilirannya menarik masuk pelaburan tambahan. Pelaburan runcit di jongkong emas dan syiling kurang konsisten, dengan beberapa pasaran menunjukkan pilihan yang jelas untuk pengambilan untung atau pembubaran, terutamanya pada separuh pertama tahun ini. Sementara yang lain secara konsisten meningkatkan pegangan emas. Jurang ini sebahagian besarnya antara Timur dan Barat, dengan banyak pasaran Asia mengalami peningkatan penjualan emas yang ketara ketika wabak itu terus meningkat. Sementara itu, pelabur Barat menumpukan usaha mereka untuk meningkatkan pegangan emas mereka sebagai aset tempat perlindungan (World Gold Council 2021a).

(c) Permintaan Industri

Melalui sebahagian besar tahun 2020, cabaran meluas yang berkaitan dengan wabak pandemik COVID-19 melambatkan permintaan teknologi. Permintaan emas di sektor teknologi untuk tahun penuh turun 7% kepada 301.9t, turun dari 301.9t pada tahun 2019, telah ditunjukkan dalam rajah 2.4 dan jadual 2.2. Selain itu, permintaan emas dalam industri berkurang secara beransur-ansur dari 460.7t sehingga 302.2t, sejak tahun 2010 hingga 2020.



Rajah 2.4 Permintaan Industri dari 2010 sehingga 2020 (World Gold Council 2021d).

Jadual 2.2 Jumlah permintaan emas dalam industri elektronik, pergigian dan lain-lain pada tahun 2019 dan 2020.


| TAN | 2019 | 2020 | PERBEZAAN TAHUN LEPAS |
|-------------------------------|-------|-------|--------------------------|
| INDUSTRI | 326.0 | 301.9 | -7% |
| ELEKTRONIK | 262.2 | 248.1 | -5% |
| INDUSTRI LAIN-LAIN | 49.8 | 42 | -16% |
| PERGIGIAN | 13.9 | 11.9 | -15% |

Menurut kepada World Gold Council (2021a), penggunaan emas dalam industri elektronik turun 5% dari tahun ke tahun, dan mengingat kekacauan yang melanda pasaran dan ekonomi di seluruh dunia pada tahun 2020, penurunan permintaan emas di sektor elektronik diharapkan. Rantainya bekalan terpengaruh di semua tingkatan, dengan banyak kemudahan pembuatan menanggung operasi untuk mematuhi penutupan tempatan dan nasional.

Menurut kepada jadual 2.2, emas yang digunakan dalam pergigian meneruskan penurunan jangka panjangnya, jatuh 15% dari tahun ke tahun kepada 11.9t. Penggunaan emas industri yang lain mengalami penurunan tahunan sebanyak 15%, kepada 42t, sementara penggunaan turun 4%, kepada 11.8t, berbanding tahun 2019. Nanopartikel emas, sebaliknya, terus menjadi kritikal dalam pengembangan alat diagnostik COVID-19 baru; kedua-dua ujian antigen dan antibodi pesat bergantung pada nanopartikel emas, tetapi sumber permintaan ini tidak signifikan dari segi data WGC.

(D) Permintaan Bank Pusat Negara

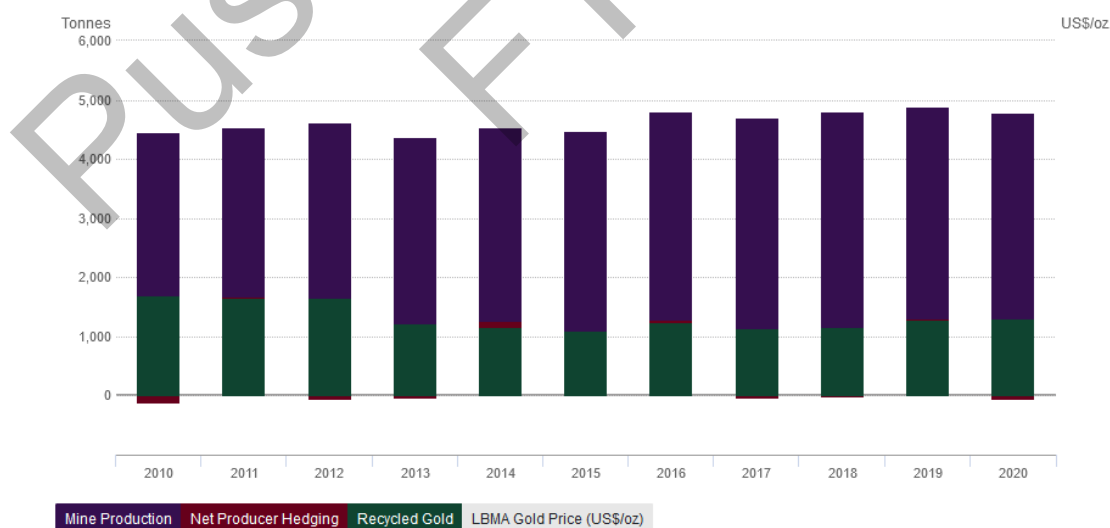
Di rajah 2.4 menunjukkan simpanan emas bank pusat sejak tahun 2010 hingga 2020, Pembelian emas tahunan pada tahun 2020 dianggarkan berjumlah 272.9t, hampir 60% lebih rendah daripada paras terendah dalam tempoh sedekad 668t yang ditambahkan pada tahun 2019. Walaupun bank pusat mencatat pembelian bersih untuk tahun ke-11 berturut-turut pada tahun 2020, ia merupakan jumlah tahunan terendah untuk pembelian bank pusat sejak trend bermula pada tahun 2010.




Rajah 2.5 Simpanan emas bank pusat negara (World Gold Council 2021d).

2.3.3 Pembekalan emas

Puratanya 75% bekal tahunan emas berasal dari aktivitas perlombongan. Oleh sebab permintaan emas biasanya lebih besar daripada output perlombongan global, permintaan yang tersisa dipenuhi terutamanya melalui kitar semula, yang merangkumi kitar semula barang kemas dan elektronik. Mungkin mengejutkan bagi beberapa orang, tetapi 90% emas kitar semula diambil dari barang kemas kitar semula, sementara hanya 10% yang diekstrak dari komponen elektronik kitar semula. Rajah 2.6 merupakan pembekalan emas dari sektor perlombongan, lindung nilai pengeluaran bersih dan emas kitar semula. Jumlah penawaran jatuh pada tahun 2020 sebanyak 4% tahun demi tahun, menjadi 4,633.1t, penurunan tahunan terbesar sejak 2013. Penurunan ini disebabkan terutamanya oleh gangguan yang disebabkan oleh wabak tersebut. Pengeluaran lombong merosot 4% tahun demi tahun, sementara buku lindung nilai (*net producer hedging*) global turun sebanyak 65.1t pada tahun 2020, lebih daripada membalikkan peningkatan kecil dalam lindung nilai yang dilihat pada tahun 2019. Sekatan penutupan dan penyekatan juga menghalang kemampuan pengguna untuk menjual kembali: penawaran emas kitar semula hanya meningkat 1% walaupun mencatatkan harga emas di setiap pasaran. Yang mengatakan, pada 1,297.4t 2020 menandakan tahap kitar semula tertinggi sejak 2012 (1,645.1t).



Rajah 2.6 Pembekalan emas dari sektor perlombongan, lindung nilai pengeluaran bersih dan emas kitar semula (World Gold Council 2021d).

(A) Perlombongan Emas dalam Angka

Rajah 2.7 Pengeluaran lombong emas dalam tan sejak 2010 hingga 2020 (World Gold Council 2021d).

Rajah 2.7 telah menunjukkan jumlah pengeluaran Emas daripada aktiviti perlombongan. peningkatan pengeluaran emas secara beransur-ansur dari lebih kurang 2754.5t hingga 3486.5t, dapat diperhatikan dalam 10 tahun kebelakangan. Pengeluaran lombong emas berjumlah lebih kurang 3,486.5t pada tahun 2020, 4% lebih rendah daripada pada tahun 2019. Gangguan COVID-19 yang digabungkan dengan faktor lain melanda pengeluaran lombong pada tahun 2020. Gangguan pandemik COVID-19 adalah sebab utama pengeluaran lombong yang lebih rendah pada tahun 2020, dan kesannya berbeza dari segi geografi dan dari masa ke masa. Dari segi geografi, produksi Asia terpukul paling parah pada kuarter pertama tahun ini, seperti yang dikeluarkan dari wilayah Komanwel Negara-negara Merdeka (CIS), walaupun yang terakhir kemungkinan dipengaruhi oleh musim yang berkaitan dengan cuaca biasa. Afrika dan Amerika menyaksikan gangguan koronavirus mencecah pengeluaran paling sukar pada kuarter ke 2 tahun ini sementara Oceania menyaksikan pengeluaran menurun sepanjang tahun, tetapi ini hanya sebahagiannya berkaitan dengan COVID-19.

Jadual 2.3 merujuk kepada pengedaran lombong emas di benua. Benua Afrika menyumbang kepada pengeluaran lombong emas terbesar di dunia, sebanyak 931t, pada tahun 2020 dan mencapai kenaikan output yang jelas sejak 2010. Benua Asia telah menyumbang pengeluaran lombong emas kedua di dunia, sebanyak 610.4t, dan benua Komanwel negara merdeka (*commonwealth of independent state*) telah menyumbang sebanyak 557.4t emas dari lombongan, Komanwel Negara Bebas (CIS) adalah

organisasi yang terdiri daripada negara-negara dari bekas Kesatuan Soviet termasuk Armenia, Belarus, Kazakhstan, Kyrgyzstan, Moldova, Rusia, Tajikistan, Turkmenistan, Ukraine, dan Uzbekistan. Kawasan ini dipisahkan dari kawasan lain kerana banyak perlombongan emas di kawasan ini dilakukan secara kerjasama antara negara-negara CIS. Terutama semua wilayah telah melihat pertumbuhan output perlombongan mulai 2010. Namun, penurunan umum dapat dilihat pada hasil emas jikalau dibandingkan tahun 2020 dengan 2019 kecuali bagi Benua Eropah (World Gold Council, 2021e).

Jadual 2.3 Pengeluaran lombong emas di dunia (World Gold Council, 2021e) .

| Gold Mine Production (tonnes) | | | | | | | | | | | |
|-------------------------------|---------|---------|---------|---------|---------|---------|---------|---------|---------|---------|---------|
| | 2010 | 2011 | 2012 | 2013 | 2014 | 2015 | 2016 | 2017 | 2018 | 2019 | 2020 |
| North America | | | | | | | | | | | |
| Sub-total | 412.1 | 430.3 | 448.5 | 468.6 | 474.6 | 505.5 | 523.0 | 527.1 | 532.2 | 492.3 | 462.5 |
| Central & South America | | | | | | | | | | | |
| Sub-total | 504.6 | 520.4 | 539.4 | 557.1 | 581.8 | 567.9 | 571.0 | 581.4 | 564.5 | 562.0 | 493.7 |
| Europe | | | | | | | | | | | |
| Sub-total | 16.7 | 18.0 | 22.9 | 23.9 | 23.7 | 25.2 | 27.8 | 30.5 | 29.5 | 31.6 | 35.1 |
| Africa | | | | | | | | | | | |
| Sub-total | 621.8 | 671.9 | 678.9 | 718.5 | 742.9 | 773.0 | 864.7 | 902.2 | 934.6 | 939.5 | 931.0 |
| Commonwealth | | | | | | | | | | | |
| Sub-total | 330.5 | 344.0 | 367.2 | 396.1 | 403.2 | 416.9 | 444.9 | 477.8 | 501.3 | 546.0 | 557.4 |
| Asia | | | | | | | | | | | |
| Sub-total | 604.9 | 606.5 | 623.3 | 663.9 | 699.8 | 722.4 | 719.2 | 691.1 | 699.8 | 620.1 | 610.4 |
| Oceania | | | | | | | | | | | |
| Sub-total | 340.4 | 337.2 | 322.7 | 346.6 | 345.2 | 353.3 | 361.7 | 366.1 | 390.9 | 405.7 | 388.0 |
| Global Total | 2,830.9 | 2,928.3 | 3,002.9 | 3,174.8 | 3,271.1 | 3,364.3 | 3,512.3 | 3,576.3 | 3,652.8 | 3,597.2 | 3,478.1 |

Di peringkat negara dan berdasarkan data Majlis Emas Dunia, China adalah pengeluar terbesar di dunia menyumbang 368.3 tan atau kira-kira 10.5 peratus global dan 60.4 peratus di benua Asia tahunan pengeluaran perlombongan emas pada tahun 2020. Pengeluar besar lain termasuk Rusia, Australia, United Negeri, Kanada, Peru dan Afrika Selatan

(B) Emas kitar semula

Seperti yang telah disebutkan, kitar semula adalah bentuk bekalan kedua terbesar di pasaran emas merangkumi kira-kira 25 peratus bekalan emas tahunan. Berbanding dengan perlombongan, kitar semula adalah banyak lebih responsif terhadap perubahan harga emas dan keadaan ekonomi (World Gold Council, 2021d). Orang cenderung mengitar semula lebih banyak emas ketika harga meningkat sementara aktiviti kitar semula jatuh ketika harga menurun.. Juga semasa kesusahan ekonomi orang

memerlukan wang tunai dan dengan itu mereka bertekad untuk menjualnya barang kemas emas. Rajah 2.8 telah menunjukkan jumlah emas yang telah dikitar-semula dan korelasi harga emas.




Rajah 2.8 Jumlah emas yang telah dikitar semula (World Gold Council 2021d).

Peningkatan sederhana dalam penawaran emas kitar semula walaupun harga emas melonjak. Tahap harga dan kadar perubahannya biasanya merupakan pendorong bekalan kitar semula yang luar biasa, jadi memandangkan kenaikan harga yang kukuh sehingga tertinggi sepanjang masa di semua mata wang utama, dapat difahami bahawa bekalan emas kitar semula meningkat pada tahun 2020.

Kesimpulannya, emas sebagai salah satu komoditi terpenting yang banyak dituntut oleh seluruh dunia dalam pelbagai aktiviti sebagai perhiasan, penggunaan industri, pelaburan dan sebagainya. Emas terutama dibekalkan dari aktiviti perlombongan dan bekalan lain diperolehi dari aktiviti kitar semula. Sementara itu, emas memiliki pasaran modal 10 trilion USD, yang menyatakan bahawa sebahagian besar nilai ataupun kewangan di dunia telah terikat padanya, menekankan kepentingan ramalan harga emas dengan ukuran ataupun cara yang lebih tepat dan canggih. Dengan munculnya pembelajaran mesin atau pembelajaran mendalam, yang dapat meramalkan harga emas secara tradisional ataupun moden seperti pembelajaran mendalam, Dalam hal ini, pembelajaran mendalam menunjukkan hasil yang memberangsangkan ketika menangani masalah atau data, dengan ketergantungan terutama untuk permasalahan temporal jangka panjang.

2.4 RANGKAIAN NEURAL BERULANG (RECURRENT NEURAL NETWORK)

Selama dekad yang lalu, teknik pembelajaran mendalam telah dikembangkan dan diguna pakai dengan baik untuk mengekstrak maklumat dari pelbagai jenis data (Rumelhart & Hintont, 1986). Terdapat pelbagai seni bina rangkaian pembelajaran mendalam seperti rangkaian neural berulang (RNN), rangkaian neural konvolusional (*Convolutional Neural Network*) dan rangkaian neural mendalam (*Deep Neural Network*). RNN didapati lebih dominan daripada dua model lain ketika diterapkan pada data penyelidikan yang mengandungi maklumat berurutan. Ciri khas seni bina RNN adalah sambungan siklik, yang membolehkan RNN memiliki kemampuan untuk mengemas kini keadaan semasa berdasarkan keadaan masa lalu dan data input semasa. Strukturnya terdiri dari lapisan input, satu atau lebih lapisan tersembunyi, dan lapisan output. RNN mempunyai struktur seperti modul pengulangan berantai dengan idea di sebalik menggunakan modul ini sebagai ingatan untuk menyimpan maklumat penting dari langkah pemrosesan sebelumnya. Tidak seperti rangkaian saraf feed-forward (*feed-forward neural network*), RNN menyertakan gelung maklum balas yang membolehkan rangkaian saraf menerima urutan input. bermaksud output dari langkah $t-1$ dimasukkan kembali ke dalam jaringan untuk mempengaruhi hasil langkah t , dan untuk setiap langkah berikutnya (Le et al. 2019).



Rajah 2.9 Pemrosesan berturutan dalam Rangkaian Neural Berulang (RNN)


Rajah 2.9 menggambarkan RNN dengan satu unit input, satu unit output, dan satu unit tersembunyi berulang dikembangkan ke rangkaian penuh, di mana X_t adalah input pada waktu langkah t dan h_t adalah output pada langkah waktu t . RNN biasanya menggunakan algoritma penyebaran belakang (*backpropagating*) yang merupakan algoritma yang mengira kecerunan dan menyesuaikan matriks berat dalam rangkaian

saraf tiruan (ANN), yang biasanya diadili sebagai penyebaran belakang melalui masa (*BackPropagating Through Time*), yang merupakan proses menggunakan pendekatan kerja-mundur dari lapisan demi lapisan output akhir rangkaian. Oleh kerana itu, gelung maklumat berulang menyebabkan kemas kini besar pada pemberat (*weight*) model NN dan mengakibatkan rangkaian tidak stabil kerana pengumpulan kecerunan ralat semasa proses pengemaskinian. Oleh itu, penyebaran belakang melalui masa tidak cukup cekap dalam mempelajari urutan temporal dengan ketergantungan jangka panjang kerana masalah kecerunan yang hilang dan meletup (Bengio Y et al., 1994).

Selain itu, ketika jurang data input yang relevan meningkat, RNN tidak akan dapat menangani atau menghubungkan maklumat yang relevan. Seperti yang dinyatakan, ingatan jangka pendek telah berjaya menangani kebergantungan jangka panjang (Hochreiter & Schmidhuber 1997). Keupayaan belajar LSTM mempengaruhi beberapa bidang dari perspektif praktikal dan teori, sehingga menjadi model canggih. Ini seterusnya menyebabkan model digunakan oleh Google untuk pengekaman pertuturan dan meningkatkan terjemahan mesin pada terjemahan Google (Wu et al. 2017). Demi aplikasi yang luas, aplikasi ini dilaksanakan di bidang permainan, seperti AlphaStar buatan Deepmind Google yang dirancang untuk memainkan Starcraft II (AlphaStar Team 2019).

2.5 MEMORI JANGKA PENDEK PANJANG (LONG SHORT-TERM MEMORY)

Memori Jangka Pendek Panjang (*Long Short-Term Memory*), adalah evolusi RNN, diperkenalkan oleh Hochreiter dan Schmidhuber (1997) untuk mengatasi masalah kekurangan RNN dengan menambahkan interaksi tambahan setiap modul (atau sel). LSTM adalah jenis RNN khas, yang mampu mempelajari kebergantungan jangka panjang dan mengingat maklumat untuk jangka masa yang lama sebagai lalai. Menurut Olah (2015) model LSTM disusun dalam bentuk struktur rantai. Walau bagaimanapun, modul berulang mempunyai struktur yang berbeza. Daripada rangkaian neural tunggal seperti RNN standard, ia mempunyai empat lapisan berinteraksi dengan kaedah komunikasi yang unik seperti yang ditunjukkan pada rajah 2.10.



Rajah 2.10 Seni bina model LSTM, dengan empat lapisan yang saling berinteraksi (Olah, 2015)

Rangkaian LSTM khas terdiri daripada blok memori yang disebut sel. Dua keadaan dipindahkan ke sel seterusnya, keadaan sel dan keadaan tersembunyi. Keadaan sel adalah rantai utama aliran data, yang membolehkan data mengalir ke hadapan pada dasarnya tidak berubah. Walau bagaimanapun, beberapa transformasi linear mungkin berlaku. Data dapat ditambahkan ke atau dikeluarkan dari keadaan sel melalui gerbang *sigmoid*. Gerbang seperti lapisan atau rangkaian operasi matriks, yang mengandungi berat individu yang berbeza. LSTM direka untuk mengelakkan masalah kebergantungan jangka panjang kerana menggunakan pintu untuk mengawal proses menghafal.

Langkah pertama dalam membina rangkaian LSTM adalah mengenal pasti maklumat yang tidak diperlukan dan akan dihilangkan dari sel. Proses mengenal pasti dan mengecualikan data ini ditentukan oleh fungsi *sigmoid*, yang mengambil output dari unit LSTM terakhir (h_{t-1}) pada waktu $t-1$ dan input semasa (X_t) pada waktu t . Selain itu, fungsi *sigmoid* menentukan bahagian mana dari output lama yang harus dihapuskan. Gerbang ini dipanggil gerbang lupa (f_t); di mana f_t adalah vektor dengan nilai antara 0 hingga 1, sesuai dengan setiap nombor dalam keadaan sel, C_{t-1} .

$$f_t = \sigma(W_f[h_{t-1}, X_t] + b_f). \quad (1)$$

Di sini, σ adalah fungsi *sigmoid*, dan W_f dan b_f adalah matriks berat dan bias pintu lupa.

Langkah berikut adalah memutuskan dan menyimpan maklumat dari input baru (X_t) dalam keadaan sel dan juga untuk mengemas kini keadaan sel. Langkah ini mengandungi dua bahagian, lapisan *sigmoid* dan kedua lapisan *tanh*. Pertama, lapisan

sigmoid memutuskan sama ada maklumat baru harus dikemas kini atau diabaikan (0 atau 1), dan kedua, fungsi \tanh memberikan pemberat (*weight*) kepada nilai yang dilewati, menentukan tahap kepentingannya (-1 hingga 1). Kedua-dua nilai digandakan untuk mengemas kini keadaan sel baru. Memori baru ini kemudian ditambahkan ke memori lama C_{t-1} sehingga menghasilkan C_t .

$$i_t = \sigma (W_i [h_{t-1}, X_t] + b_i), \quad (2)$$

$$N_t = \tanh (W_n [h_{t-1}, X_t] + b_n), \quad (3)$$

$$C_t = C_{t-1} f_t + N_t i_t \quad (4)$$

Di sini, C_{t-1} dan C_t adalah keadaan sel pada masa $t-1$ dan t , sementara W dan b adalah matriks pemberat dan bias, masing-masing, dari keadaan sel.

$$O_t = \sigma (W_o [h_{t-1}, X_t] + b_o), \quad (5)$$

$$h_t = O_t \tanh(C_t). \quad (6)$$

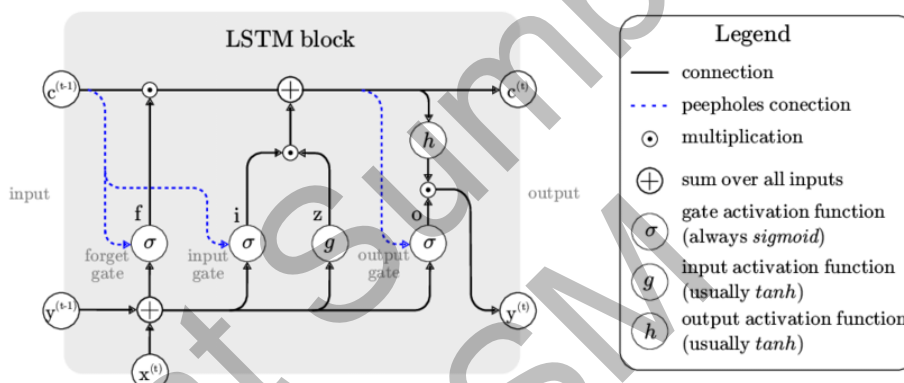
Di sini, W_o dan b_o adalah matriks berat dan bias, masing-masing, dari pintu output.

2.6 VARIAN LSTM UNTUK APLIKASA DATA SIRI MASA

Rangkaian waktu melonjak ke fikiran ketika datang ke urutan temporal dalam data. Oleh kerana ciri-ciri kompleks seperti tak linear, tak pegun dan korelasi urutan, data kewangan menimbulkan cabaran ramalan besar, model LSTM telah diterapkan pada ramalan pasaran kewangan Fischer dan Krauss (2018), bahawa rangkaian LSTM mengungguli lebih tradisional penanda aras: hutan rawak, rangkaian neural dalam standard dan regresi logistik standard apabila membandingkan LSTM dengan model lain. Penyelidikan ini dalam menganggarkan turun naik stok kewangan bukan sahaja menunjukkan bahawa agak mudah mengkalibrasi LSTM, tetapi juga menghasilkan ramalan yang tepat untuk selang waktu yang besar (Y. Liu 2019).

2.6.1 LSTM Vanila


LSTM vanila adalah model yang memiliki lapisan tersembunyi tunggal unit LSTM, dan lapisan keluaran yang digunakan untuk menjalankan ramalan, ia adalah model LSTM yang paling asas. Rajah 2.11 menunjukkan seni bina vanila LSTM, yang merupakan seni bina model yang sama yang disebutkan dalam bahagian 2.6. Ia berfungsi sama seperti yang disebutkan di bahagian 2.6. Dalam kajian yang lalu, usaha untuk meramalkan harga pasaran minyak selama 10 tahun, suatu model telah dicadangkan yang terdiri daripada seni bina LSTM vanila, memperoleh hasil yang baik (Cen & Wang 2019).



Rajah 2.11 Seni bina LSTM vanila (Van Houdt et al. 2020).

2.6.2 LSTM timbunan (Stacked LSTM)

LSTM timbunan adalah lanjutan LSTM vanila yang mempunyai banyak lapisan LSTM tersembunyi di mana setiap lapisan mengandungi beberapa sel memori. Menyusun lapisan tersembunyi LSTM menjadikan model lebih mendalam, lebih tepat memperoleh gambaran sebagai teknik pembelajaran mendalam. Ini adalah kedalaman jaringan saraf yang umumnya dikaitkan dengan keberhasilan pendekatan pada berbagai masalah ramalan yang mencabar. Rajah 2.12 menunjukkan seni bina LSTM timbunan.




Rajah 2.12 menunjukkan seni bina LSTM timbunan (Dihasilkan oleh Pengarang)

LSTM timbunan mengatasi pendekatan standard ketika meramalkan pengeluaran petroleum (Sagheer & Kotb 2019). Dalam penyelidikan mereka, mereka menyusun beberapa lapisan blok LSTM di atas satu sama lain secara hierarki. Ini meningkatkan kemampuan model untuk memproses tugas sementara dan memungkinkannya menangkap struktur urutan data dengan lebih baik.

2.6.3 LSTM Dua Arah

LSTM dua arah adalah lanjutan dari LSTM tradisional yang dapat meningkatkan prestasi model pada urutan masalah klasifikasi. Dalam masalah di mana semua langkah masa urutan input tersedia, LSTM dua arah melatih dua dan bukan satu LSTM pada urutan input. Yang pertama pada urutan input sebagaimana adanya dan yang kedua pada salinan urutan input terbalik. Ini dapat memberikan konteks tambahan ke rangkaian dan menghasilkan pembelajaran yang lebih cepat dan lebih lengkap mengenai masalah tersebut. Seperti yang ditunjukkan pada rajah 2.13, istilah dua arah dalam jaringan saraf berulang berasal dari idea untuk memberikan urutan input dengan dua arah: lapisan depan dan belakang. Dari dua lapisan tersembunyi ini, lapisan output dapat memperoleh maklumat mengenai keadaan masa lalu dan masa depan, masing-masing, secara serentak.



Rajah 2.13 Seni bina LSTM dua arah (Mungalpara, 2021)

Untuk sebarang langkah waktu t , diberi input kumpulan mini (*minibatch*) $\mathbf{X}_t \in \mathbb{R}^{n \times d}$ (bilangan contoh: n , jumlah input dalam setiap contoh: d) dan biarkan fungsi pengaktifan lapisan tersembunyi menjadi ϕ . Dalam seni bina dua arah, menganggap bahawa keadaan tersembunyi maju dan mundur untuk langkah masa ini adalah $\rightarrow \mathbf{H}_t \in \mathbb{R}^{n \times h}$ dan $\leftarrow \mathbf{H}_t \in \mathbb{R}^{n \times h}$, di mana h adalah bilangan unit tersembunyi. Kemas kini keadaan tersembunyi ke depan dan ke belakang adalah seperti berikut:

$$\rightarrow \mathbf{H}_t = \phi(\mathbf{X}_t \mathbf{W}^{(f)}_{xh} + \rightarrow \mathbf{H}_{t-1} \mathbf{W}^{(f)}_{hh} + \mathbf{b}^{(f)}_h), \quad (8)$$

$$\leftarrow \mathbf{H}_t = \phi(\mathbf{X}_t \mathbf{W}^{(b)}_{xh} + \leftarrow \mathbf{H}_{t+1} \mathbf{W}^{(b)}_{hh} + \mathbf{b}^{(b)}_h). \quad (9)$$

di mana pemberatnya $\mathbf{W}^{(f)}_{xh} \in \mathbb{R}^{d \times h}$, $\mathbf{W}^{(f)}_{hh} \in \mathbb{R}^{h \times h}$, $\mathbf{W}^{(b)}_{xh} \in \mathbb{R}^{d \times h}$, and $\mathbf{W}^{(b)}_{hh} \in \mathbb{R}^{h \times h}$, dan biases $\mathbf{b}^{(f)}_h \in \mathbb{R}^{1 \times h}$ and $\mathbf{b}^{(b)}_h \in \mathbb{R}^{1 \times h}$ adalah parameter model.

Setelah menggabungkan keadaan tersembunyi $\rightarrow \mathbf{H}_t$ and $\leftarrow \mathbf{H}_t$ untuk mendapatkan keadaan tersembunyi $\mathbf{H}_t \in \mathbb{R}^{n \times 2h}$ untuk masuk ke lapisan output, dalam LSTM dua arah yang mendalam (*deep bidirectional LSTM*) dengan beberapa lapisan tersembunyi, maklumat tersebut disampaikan sebagai input ke lapisan dua arah seterusnya. Terakhir, lapisan output mengira output $\mathbf{O}_t \in \mathbb{R}^{n \times q}$ (bilangan output: q):

$$\mathbf{O}_t = \mathbf{H}_t \mathbf{W}_{hq} + \mathbf{b}_q. \quad (10)$$

Metrik pemberat $\mathbf{W}_{hq} \in \mathbb{R}^{2h \times q}$ dan bias $\mathbf{b}_q \in \mathbb{R}^{1 \times q}$ adalah parameter model lapisan output. Sebenarnya, dua arah boleh mempunyai bilangan unit tersembunyi yang berbeza.


Dari kajian lepas, untuk meramalkan baki jangka hayat (RUL) sistem fizikal, misalnya sumber pengeluaran. Ini dilakukan dengan mencadangkan seni bina LSTM dua arah (BLSTM) baru (Elsheikh et al. 2019). Sementara itu, satu kajian menunjukkan hasil yang signifikan dari arah dua arah yang lebih baik daripada LSTM tidak sehal dalam meramalkan kelajuan dan aliran di jalan raya untuk beberapa ufuk ramalan (Abduljabbar et al. 2021).

2.6.4 CNN-LSTM

Rangkaian Neural Konvolusional mempunyai ciri-ciri untuk memperhatikan ciri-ciri yang paling jelas dalam garis penglihatan, sehingga digunakan secara meluas dalam kejuruteraan ciri (Lu et al. 2020). LSTM mempunyai ciri pengembangan mengikut urutan masa, dan ia digunakan secara meluas dalam siri masa. CNN terutama terdiri dari dua bahagian: lapisan konvolusi dan lapisan penyatuan, seperti yang ditunjukkan pada rajah 2.14. Setiap lapisan konvolusi berisi sejumlah kernel konvolusi, dan formula pengiraannya ditunjukkan dalam (11). Selepas operasi lapisan konvolusi, ciri-ciri data diekstrak, tetapi dimensi ciri yang diekstrak sangat tinggi, jadi untuk menyelesaikan masalah ini dan mengurangkan kos latihan jaringan, lapisan MaxPooling, yang merupakan lapisan penyatuan ditambahkan selepas lapisan konvolusi untuk mengurangkan dimensi ciri:

$$l_t = \tanh(x_t * k_t + b_t), \quad (11)$$

Yang mana l_t mewakili nilai output setelah konvolusi, \tanh adalah fungsi pengaktifan, x_t adalah vektor input, k_t adalah berat kernel konvolusi, dan b_t adalah bias kernel konvolusi.



Rajah 2.14 Seni bina CNN-LSTM (He et al. 2019)

Untuk memasukkan selanjutnya dari lapisan CNN akan memerlukan penggunaan lapisan *Flatten* untuk meratakan susulan ke dalam vektor satu dimensi sehingga memungkinkan pengiraan ke dalam lapisan LSTM. Dalam kajian sebelumnya oleh Lu, et al., 2020, CNN-LSTM diusulkan untuk meramalkan harga saham dan mengungguli varian NN lain seperti Perceptron berlapis-lapis (MLP), CNN, RNN, LSTM, dan CNN-RNN.

2.6.5 Unit Berpagar Berulang-Alih (Gated Recurrent Unit, GRU)

Diperkenalkan oleh Cho, et al. pada tahun 2014, GRU bertujuan untuk menyelesaikan masalah kecerunan yang hilang yang disertakan dengan rangkaian saraf berulang standard. GRU sangat mirip dengan LSTM dan dapat dilihat sebagai versi ringkas LSTM klasik, GRU menggunakan dua gerbang untuk mengawal aliran maklumat, berbanding tiga gerbang dalam sel LSTM, iaitu gerbang tetap semula (*reset gate*) dan gerbang kemas kini (*update gate*). Gerbang tetapan semula (nyatakan sebagai r_t), bertanggungjawab untuk memori jangka pendek yang menentukan kuantiti data masa lalu yang akan dilupakan. Sementara itu pintu gerbang kemas kini (ditunjukkan sebagai z_t), akan membebaskan kuantiti data masa lalu dari langkah sebelumnya yang diperlukan untuk diteruskan ke masa depan.

$$r_t = \sigma(W^r x_t + U^r h_{t-1}) \quad (12)$$

$$z_t = \sigma(W^z x_t + U^z h_{t-1}) \quad (13)$$


nilai r_t akan berkisar antara 0 hingga 1 kerana fungsi sigmoid. Di sini U^r dan W^r adalah matriks berat untuk pintu semula. Dan U^z dan W^z adalah matriks berat untuk gerbang kemas kini. Hanya perbezaan bagi kedua-dua pintu adalah metrik berat.

Untuk mencari keadaan Tersembunyi h_t dalam GRU, keadaan tersembunyi calon (ditunjukkan sebagai tidak), perlu dihasilkan, seperti yang ditunjukkan di bawah. Input dan keadaan tersembunyi dari cap waktu sebelumnya h_{t-1} , didarabkan dengan gerbang tetapan semula r_t , diteruskan ke fungsi \tanh yang menghasilkan nilai hasil yang merupakan keadaan tersembunyi calon. Apabila r_t sama dengan 1 menunjukkan maklumat sebelumnya sedang dipertimbangkan. Begitu juga, r_t sama dengan 0 menunjukkan maklumat sebelumnya diabaikan. Akhirnya, \tanh digunakan untuk menghasilkan h'_t .

$$h'_t = \tanh(Wx_t + r_t \odot Uh_{t-1}) \quad (14)$$

Di sebelah untuk mendapatkan h_t , gerbang kemas kini diperlukan, ia menentukan apa yang harus dikumpulkan dari kandungan memori semasa, bukan dan langkah sebelumnya h_t . dengan anggapan nilai z_t mendekati 0 maka keadaan tersembunyi baru tidak membawa banyak maklumat dari keadaan tersembunyi sebelumnya, sementara keadaan tersembunyi pada langkah masa semasa akan terdiri daripada maklumat dari keadaan calon sahaja. Oleh itu, nilai z_t gerbang kemas kini sangat ketara dan boleh berkisar antara 0 hingga 1. Rajah 2.15 menunjukkan seni bina GRU.

$$h_t = (1 - z_t) \odot h'_t + z_t \odot h_{t-1} \quad (15)$$




Rajah 2.15 Seni bina GRU (Olah, 2015).

Dalam kajian sebelumnya mengenai ramalan harga saham berdasarkan pembelajaran mendalam, GRU mengambil lebih sedikit masa untuk menjalankan ramalan daripada LSTM, dan ia menunjukkan lebih banyak toleransi terhadap keturun-naik harga walaupun mempunyai ralat yang lebih tinggi daripada LSTM (Boontham & Meesad 2018).

2.7 KAEDAH TIMBUNAN

Kaedah timbunan, atau generalisasi timbunan adalah algoritma ensemble biasanya dianggap sebagai pembelajaran lemah yang heterogen, dengan menggabungkan ramalan secara linear dari dua atau lebih algoritma pembelajaran mesin asas kemudian membuat ramalan dengan pembelajaran meta (*meta-learner*) (Wolpert 1992). Manfaat timbunan adalah bahawa ia dapat memanfaatkan kemampuan berbagai model bersembah atau berfungsi baik pada tugas klasifikasi atau regresi dan membuat ramalan yang mempunyai prestasi yang lebih baik daripada model tunggal dalam algoritma ensemble. Sementara itu, pendekatan susun dengan model timbunan sangat popular di kalangan peserta komuniti *Kaggle* (Pavlyshenko 2018). Syarikat perniagaan yang berbeza mencadangkan masalah mereka dengan set data membolehkan data saintis untuk mengembangkan model ramalan mereka. Gambar rajah 2.16 menunjukkan aliran pembelajaran ensemble.



Rajah 2.16 Aliran rangkaian algoritma timbunan.

Kaedah timbunan adalah teknik pengurangan bias. Pada tahun 2011, rangkaian cembung mendalam (*Deep Convex Network*) dicadangkan yang merupakan seni bina pembelajaran mendalam yang terdiri daripada sejumlah modul yang berubah-ubah ditumpuk bersama untuk membentuk seni bina yang mendalam. Semasa berurusan dengan kumpulan data berskala besar, rangkaian timbunan dalam dicadangkan (Deng et al. 2012). Model ini berkongsi konsep generalisasi timbunan. Namun, tiada representasi temporal data dalam rangkaian timbunan mendalam (*Deep Stacking Network, DSN*), sehingga menghadapi kesulitan ketika ketergantungan temporal ada dalam data. Oleh itu, Rangkaian Penyisipan Dalam Berulang dicadangkan, dengan menggabungkan kelebihan DSN dan RNN yang memungkinkan penyisipan maklumat temporal ke dalam DSN (Palangi et al. 2014).

Sementara itu, terdapat beberapa aplikasi teknik kaedah timbunan yang diterapkan pada sektor pembelajaran mendalam dalam ramalan siri waktu, model ramalan stok yang diusulkan oleh Xie et al., (2018), mencapai ketepatan rata-rata 58.8% dalam meramalkan indeks dengan kaedah LSTM timbunan. Seterusnya, kajian sebelumnya dalam ramalan hasil dan harga strawberi, kaedah timbunan yang dibina oleh model asas: *Attention-CNN-LSTM* dan *Attention-Conv-LSTM* kemudian regresor sokongan vektor (*Support Vector Regressor*) sebagai pembelajaran meta telah menunjukkan peningkatan yang menjanjikan hasil dengan ralat agregat terendah (Okwuchi et al. 2020). Sementara itu, dalam kajian menganggarkan kepekatan bilangan zarah atmosfera, kaedah timbunan yang dicadangkan yang dibina oleh LSTM, GRU, dan LSTM dua-arah (*Bidirectional LSTM*) telah memperoleh ketepatan 97% (Surakhi et al. 2020).

2.7.1 Set Data Meta dan Pembelajaran-meta (Meta Dataset and Meta Learner)

Set data meta adalah data dengan ukuran yang jauh lebih besar daripada penanda aras sebelumnya dan terdiri daripada pelbagai set data yang ada. Ini mengundang penyelidikan bagaimana sumber data yang pelbagai dapat dimanfaatkan oleh meta-pembelajaran dan membolehkan penilaian masalah generalisasi yang lebih mencabar, ke kumpulan data baru sama sekali (Triantafillou et al. 2019). Dalam kajian ini, set data meta akan dibina oleh output dari setiap model asas. Sering dapat melihat skema

timbunan mempunyai dua lapisan, iaitu lapisan pertama dan lapisan kedua. Di mana lapisan kedua memperoleh data yang dihasilkan dari lapisan pertama pembelajaran individu, kemudian diramalkan dengan penggabungan, atau pembelajaran meta (Zhi Hua 2012). Pembelajaran meta adalah algoritma pembelajaran, yang boleh berbeza, atau sama dengan lapisan sebelumnya untuk mempelajari masalahnya. Kemudian, pembelajaran meta memasukkan penemuan atau ramalan dari lapisan sebelumnya sebagai ciri dan sasaran menjadi nilai sebenar untuk menghasilkan output.

2.8 KAJIAN BERKAITAN DENGAN RAMALAN HARGA EMAS DENGAN KAEDAH PEMBELAJARAN MESIN, PEMBELAJARAN DALAMAN DAN LAIN-LAIN

2.8.1 Mesin vektor sokongan (Support Vector Machine, SVM)

SVM adalah teknik untuk klasifikasi. Item data kemudian dapat diplot sebagai titik dalam ruang n-dimensi, dengan nilai setiap atribut sama dengan nilai koordinat yang tepat. SVM telah berperanan dalam meramalkan harga emas. Onsumran et al., (2015) telah menumpukan perhatian pada teknik penambangan teks untuk memajukan turun naik kos emas. Teknik ini diperbaiki untuk menentukan sejauh mana artikel tersebut memanipulasi ketidakstabilan harga emas. Banyak petunjuk kewangan diperoleh dari artikel berita terpilih, termasuk Bill Auction, indeks Redbook, penjualan runcit, PMI pembuatan pasaran, dan kegiatan keuangan. Penulis meramalkan ketepatan pendekatan pemberat menggunakan SVM, kaedah statistik chi-kuadrat, dan dua teknik klasifikasi lain, tetangga K-terdekat (KNN), dan Bayes naif (*Naives Bayes, NB*). SVM mengungguli semua kaedah lain dengan kadar ketepatan 87.52 peratus dan menonjol sebagai teknik unggul dari segi kemajuan pemberat atribut. Raghuram, (2020) mengembangkan kaedah untuk meramalkan harga emas menggunakan data pasaran saham dengan menggabungkan pembelajaran mesin dan teknik peramalan statistik. Penulis berusaha membandingkan dua teknik ramalan untuk peramalan harga emas: SVM dan regresi. Data yang diperlukan dikumpulkan dari petunjuk pasaran saham dan antarabangsa. Petunjuk pasaran saham didapati menjadi peramal kadar emas yang lebih tepat. Dengan memasukkan pelbagai metrik prestasi, model yang dicadangkan meningkatkan kadar ketepatannya.

Wen et al., (2017) menunjukkan bahawa SVM mengatasi ANN dalam meramalkan harga emas selangkah lebih maju dan lima langkah ke depan. Akibatnya, apabila kedua-dua kaedah dengan komponen harga digabungkan, kesalahan ramalan gabungan lebih rendah daripada ketika menggunakan satu model sahaja. Makala & Li, (2021) mengusulkan kajian menggunakan SVM dan ARIMA untuk meramalkan harga emas harian. Dengan data harian dari WGC, tiga jenis kernel SVM dicadangkan: linear SVM, poli SVM, dan RBF SVM. Ketiga-tiga ARIMA mengungguli, dengan linear dan poli masing-masing memperoleh skor RMSE 0.0276 dan 0.0275. Oleh kerana ketepatan tinggi SVM, hasilnya menunjukkan bahawa ia harus digunakan dalam ramalan harga komoditi.

2.8.2 Linear Regresi (Linear Regression, LR)

LR digunakan untuk menilai nilai sebenar yang ditentukan oleh pemboleh ubah berterusan. Dengan memasang penyelesaian yang sesuai, LR menjalin hubungan antara pemboleh ubah bersandar dan bebas. LR tetap menjadi pilihan popular untuk ramalan harga emas. Sadik et al., (2020) telah mengembangkan kaedah untuk memeriksa hubungan antara harga emas dan beberapa pemboleh ubah deskriptif yang sering digunakan sebagai petunjuk bencana geopolitik dan ekonomi. Kajian itu mengkaji kemungkinan meramalkan kadar emas. Penulis menguji empat algoritma pembelajaran mesin yang berbeza, termasuk LR, SVM, model autorgresi vektor (*Vector autoregression model, VAR*), dan purata bergerak bersepadu autoregresi (ARIMA), dan mendapati bahawa LR mempunyai skor tertinggi, sementara ARIMA mempunyai skor terendah. Sekar et al., (2017) mencadangkan model regresi linear multi-variabel untuk ramalan komoditi emas yang menghilangkan ketidakpastian. Ini sangat bermanfaat dari segi menekankan sifat kritikal dalam memahami pelaburan emas (terutama semasa turun naik). Mereka mensimulasikan model yang dikembangkan dan menunjukkan keberkesanannya sebagai peramal harga emas menggunakan data selama lima tahun. UI & Nazir, (2017) menyatakan bahawa LR memerlukan masa latihan yang lebih sedikit daripada ANN tetapi menunjukkan prestasi yang serupa dengan ANN.

2.8.3 Penyokong Regresi Vektor (Support Vector Regression, SVR)

SVR menerapkan prinsip yang serupa dengan masalah regresi seperti yang dilakukan oleh SVM. SVR, yang merupakan subkelas SVM, dapat digunakan untuk menyelesaikan regresi dan masalah ramalan lain yang berkaitan. Ongsritrakul dan Soonthornphisaj (2003) mencadangkan penggunaan Pokok Keputusan (*Decision Tree, DT*) untuk memilih ciri dan Menyokong Regresi Vektor untuk meramalkan harga emas. mereka menerapkan algoritma SVR pada data indeks penutupan harian yang merangkumi tempoh 5 Mac 1998 hingga 3 April 2002, sebanyak 1000 hari. Pokok keputusan telah memilih faktor penting seperti indeks minyak, indeks S & P500, indeks dolar, indeks bon, hasil bon 30 tahun, indeks mata wang sterling, indeks perlombongan emas, pertukaran Afrika Selatan indeks kadar, indeks kadar pertukaran Kanada, indeks kadar pertukaran Australis, dan indeks kadar sewa sejuk. Mereka menyimpulkan bahawa walaupun SVR mempunyai batasan ukuran set data, ia sangat sesuai untuk jumlah data yang besar. Sebaliknya, regresi linear sesuai untuk sekumpulan kecil data dengan satu arah pergerakan; bagaimanapun, rangkaian saraf tidak hanya buruk dalam masalah regresi, tetapi juga memerlukan jangka masa komputasi yang lebih banyak daripada teknik lain yang dibincangkan dalam makalah ini.

Suranart et al., (2014) melakukan kajian untuk menilai prestasi SVR, rangkaian neural (NN), dan rangkaian fungsi asas radial untuk ramalan harga emas (RNFN). Ketiga-tiga kaedah ini digunakan untuk mengajar teknik berdasarkan harga emas jangka pendek. Kajian ini menganalisis trend kadar emas dan membantu pemilihan emas dan pemetaan rancangan simpanan emas. Ini ditujukan untuk pengusaha, pemodal, dan spekulator yang menjalankan perniagaan berkaitan emas. Perbezaan, nilai keseluruhan keseluruhan, ralat rata-rata (AE), ralat kuasa dua rata-rata (ASE), dan nilai ralat purata mutlak semuanya akan digunakan untuk menentukan ketepatan analisis kadar emas (AAEV). Dubey (2016) mengemukakan kaedah untuk meramalkan harga emas menggunakan teknik SVR dan sistem inferensi kabur neural adaptif (ANFIS). Teknik epsilon SVR digunakan untuk mengembangkan SVM, dan teknik pengelompokan dan partisi grid digunakan untuk meningkatkan ANFIS. Penulis membandingkan prestasi menggunakan pelbagai metrik, termasuk ralat peratusan mutlak purata (MAPE), purata ralat mutlak (MAE), purata ralat kuadrat punca (RMSE), dan pekali kecekapan model

Nash – Sutcliffe. Didapati bahawa kaedah yang diperoleh menggunakan SVR mengungguli model ANFIS.

Plakandaras et al., (2021) mengusulkan kerangka multi-variabel *Ensemble Empirical Mode Decomposition* dengan SVR, (EEMD – SVR), untuk meramalkan harga emas tertutup bulanan sambil menambah data dengan pelbagai pemboleh ubah seperti indeks harga pengguna AS (CPI), wajaran perdagangan luas kadar pertukaran dolar AS terhadap rakan dagangnya (TWI), bil perbendaharaan 10 tahun (10BILL), bil perbendaharaan tiga bulan (3BILL), jangka masa penyebaran antara bil perbendaharaan 10 tahun dan tiga bulan (TS), indeks komposit S & P500 (sp500), Indeks Komoditi Goldman Sachs (GSCI), dan Indeks Komoditi Thomsen (VOL). Fungsi EEMD digunakan untuk melicinkan pemboleh ubah sebelum meramalkan dengan SVR. Kaedah mereka menghasilkan hasil yang signifikan, dengan ralat kuadrat rata-rata 6.06 pada data mentah untuk set data yang merangkumi dua tahun dan ralat kuadrat rata-rata 0,007 pada nilai normal yang merangkumi sepuluh tahun.

2.8.4 Hutan Rawak (Random Forest , RF)

Kaedah RF adalah kaedah ensembel untuk koleksi Pokok Keputusan (DT). Ini terdiri dari koleksi DT, dengan output yang diramalkan menggunakan ramalan rata-rata setiap pokok. Banyak penyelidik telah menggunakan RF untuk meramalkan kadar emas, yang juga memainkan peranan penting. Liu dan Li (2017) menggunakan kaedah RF untuk meramalkan kecenderungan kadar emas berubah-ubah. Penulis melakukan eksperimen yang meluas menggunakan data dunia nyata. Eksperimen yang dicadangkan mencapai kadar ramalan yang tinggi, menunjukkan dominasi perlombongan data dalam meramalkan kenaikan atau penurunan trend harga emas. RF mempunyai tahap kepatuhan tinggi terhadap data yang sukar dan tahap ketepatan yang tinggi. Hasil yang lebih baik menunjukkan bahawa gabungan Indeks Standard & Poor's 500 (S & P500) dan Dow Jones Industrial Average (DJIA) menunjukkan keupayaan positif untuk meramalkan trend harga emas. Pierdzioch dan Risse (2020) mencadangkan model ramalan berasaskan hutan pelbagai rawak untuk kadar emas, perak, dan dua logam berharga yang lain. Dengan membandingkan teknik hutan rawak tunggal dan

multivariate, ditunjukkan bahawa model yang dicadangkan dapat meramalkan harga logam ini dengan tepat dengan kadar ramalan yang lebih tinggi.

2.8.5 Jiran terdekat-k (K-nearest Neighbour, KNN)

KNN adalah algoritma langsung yang boleh digunakan untuk masalah regresi dan klasifikasi. Langkah-langkah algoritma K-purata (K-means) yang lebih mudah memungkinkan penggunaan yang lebih besar dalam menyelesaikan semua jenis masalah kehidupan benar. Al-Dhuraibi dan Ali, (2018) meramalkan harga emas menggunakan kaedah KNN dalam kaedah klasifikasi. Meramalkan harga emas sangat penting dalam pelbagai bidang, termasuk politik, ekonomi, perdagangan, dan pelaburan. Apabila nilai emas diramalkan dengan tepat, penilaian pelaburan yang lebih tepat dapat diselesaikan. Objektif utama kaedah cadangan penulis adalah untuk meramalkan sama ada harga emas akan meningkat atau menurun dalam masa terdekat. Sejumlah algoritma klasifikasi, termasuk DT, SVM, KNN, dan LR, telah digunakan untuk meramalkan harga emas. Penulis menilai prestasi algoritma terpilih menggunakan perisian *Rapid miner*. KNN mengatasi semua algoritma lain.

2.8.6 Pembelajaran statistik

Bagi contoh pembelajaran statistik, satu lagi kajian mengenai penggunaan ARIMA dalam meramalkan harga emas bulanan dilakukan oleh Bandyopadhyay (2016). Di dalam kajian ini, model ARIMA telah digunakan untuk meramal prestasi harga emas sepanjang tempoh 10 tahun di Multi Commodity Exchange of India Ltd. Model ARIMA ini telah memberi prestasi yang baik dalam meramal harga emas semasa. Sementara itu, dalam satu kajian meramalkan harga emas India dengan menggunakan model auto moving regressive integrated average (ARIMA) selama 25 tahun dari Julai 1990 hingga Februari 2015 telah memperoleh output yang signifikan (Tripathy 2017). Kajian menggunakan purata ralat mutlak (MAE), ralat kuadrat punca purata (RMSE), ralat peratusan mutlak maksimum (Max APE), ralat mutlak maksimum (Max AE), dan purata ralat peratusan mutlak (MAPE) untuk menilai ketepatan model. Hasil kajian menunjukkan bahawa ARIMA (0,1,1) adalah tetapan model yang paling sesuai

digunakan untuk meramalkan harga emas India kerana mengandungi paling sedikit MAPE, Max AE dan MAE. Kajian menunjukkan bahawa harga emas selama 1 bulan terakhir mempunyai kesan yang signifikan terhadap harga emas semasa.

2.8.7 Kaedah pembelajaran mesin maju dan pembelajaran dalaman

Selain daripada teknik ML umum seperti SVM, DT, RF, dan lain-lain, ada beberapa yang lain kaedah seperti teknik hibrid, model ML maju, dan banyak lagi yang lain menunjukkan kecekapan mereka semasa meramalkan harga emas. Untuk meramalkan harga emas, Weng et al., (2020) mencadangkan algoritma genetik novel mesin pembelajaran ekstrem dalam talian (Genetic Algorithm Regularization Online Extreme Learning Machine, GA-ROSELM). Harga pembukaan emas, perak, dan minyak mentah setiap hari, serta indeks Standard & Poor, digunakan dalam kajian ini. Sementara itu, Kriteria Maklumat Akaike (AIC) digunakan untuk membina lapan kombinasi pemboleh ubah input berdasarkan harga perak hari sebelumnya (Perak D1), Standard & Poor's. Indeks S&P 500 (S&P D1), harga minyak mentah (Crude D1), dan harga emas tiga hari (Emas D1, Emas D2, Emas D3). Model yang dicadangkan (GA-ROSELM) mengatasi batasan model *Online Sequential-Extreme Learning Machine*, OS-ELM dari segi kemudahan dengan matriks tunggal dapat dihasilkan; sebagai tambahan, eksperimen menunjukkan bahawa model ini mengatasi ARIMA, SVM, BP, ELM, dan OS-ELM dalam eksperimen ramalan harga emas. Pada set ujian, ralat punca kuasa dua ramalan model ini menurun masing-masing sebanyak 13.1 peratus, 22.4 peratus, 53.87 persen, 57.84 persen, dan 37.72 peratus, jika dibandingkan dengan lima model lain. Ringkasnya, hasilnya menunjukkan secara jelas keberkesanan model GA-ROSELM.

Teknik gabungan novel berdasarkan kaedah analisis komponen bebas (*Independent component analysis, ICA*) dan rangkaian rangkaian neural unit berulang (*Gate recurrent unit neural network, GRUNN*), dicadangkan ICA-GRUN oleh Jianwei et al., (2019). Teknik ini, ICA-GRUN, meramalkan harga pembukaan dan penutupan data harga emas bulanan dari 1979 hingga 2017. ICA-GRUNN didapati mengungguli semua kaedah konvensional, termasuk ARIMA RBFNN, LSTM, dan GRUNN. Sementara itu, jika dibandingkan dengan ICA-LSTM dan ICA-GRU untuk parameter yang sama, ICA-GRU mencapai nilai MAD, RMSE, dan MAPE yang lebih rendah.

Menurut kepada Yazdani-Chamzini et al., (2012), untuk meramalkan harga emas, menggunakan sistem inferensi neuro-fuzzy adaptif (*Adaptive Neural Fuzzy Inference Systems*, ANFIS) dan model rangkaian neural buatan (*Artificial Neural Networks*, ANN), yang bandingkan dengan model statistik tradisional ARIMA. Kajian ini memodelkan harga emas per auns menggunakan 220 pengamatan bulanan dari April 1990 hingga Julai 2008, sementara juga memilih pemboleh ubah input seperti indeks USD, kadar inflasi, harga minyak (WTI), DJI, harga perak, dan pengeluaran emas dunia. Hasilnya menunjukkan bahawa model ANFIS mengatasi model lain (ANN dan ARIMA) dengan nilai RMSE dan MAE 5.94 dan 0.012 dalam set latihan dan masing-masing 29.84 dan 0.029 dalam set pengesahan. Analisis kepekaan menunjukkan bahawa perubahan harga emas sangat bergantung pada harga perak dan minyak.

Farahani & Mehralian, (2013) membandingkan ANN dan ANFIS untuk meramalkan harga emas dalam sistem dunia nyata. Harga emas diperoleh dari pasaran pertukaran asing. Kumpulan data ini mengandungi harga penutupan emas setiap jam dari 17 September 2010 hingga 21 Januari 2011. Sebagai tambahan, model hibrid baru yang rata-rata berwajaran model ANN dan ANFIS dibandingkan. Untuk meramalkan harga emas, pendekatan ANN dan ANFIS dibandingkan. Sebagai tambahan kepada perbandingan, model hibrid baru dicadangkan di mana output kedua-dua model ramalan ANN dan ANFIS ditimbang berdasarkan prestasi latihan mereka dan output hibrid dihasilkan dengan menggunakan purata wajaran kedua model. Model yang dicadangkan berkinerja serupa dengan ANN dan ANFIS, dengan RMSE 2.54, 2.52 untuk ANFIS, dan 2.62 untuk ANN. Walaupun algoritma *denoising wavelet* digunakan, ia mengakibatkan penurunan data dan mempengaruhi prestasi model.

Menurut Hafezi dan Akhavan (2018), artikel ini mencadangkan model cerdas berdasarkan rangkaian neural buatan (ANN) untuk meramalkan harga emas masa depan menggunakan set data 220 harga emas bulanan per pemerhatian dari 1990-04 hingga 2008-07. Rangkaian pintar yang dicadangkan menggabungkan algoritma meta-heuristik yang disebut algoritma BAT, yang membolehkan ANN mengesan turun naik harga emas. Algoritma kelawar (BAT), yang diilhami oleh tingkah laku ekolokasi (*echo*) kelawar, mempunyai kelebihan menggabungkan algoritma berdasarkan populasi dengan carian tempatan. Model yang dikembangkan dibandingkan dengan makalah ilmiah yang diterbitkan dan model lain yang bersaing seperti *Autoregressive Integrated*

Moving Average (ARIMA), ANN, ANFIS, *Multilayer Perceptron* (MLP), *Radial Basis Function* (RBF) Rangkaian Neural, dan Rangkaian Neural Regresi Umum (*Generalized Regression Neural Networks*, GRNN). RMSE digunakan sebagai indeks ralat untuk menilai prestasi model. Rangkaian Neural BAT (BNN) yang dicadangkan mengungguli model ramalan konvensional dan moden, dengan nilai RMSE 21.26.

Menurut kepada Han Chao dan Dong (2017), mereka mengembangkan algoritma peraturan pergaulan (*association rules*), yang menangani masalah perlombongan faktor dalam model ramalan, yang memungkinkan untuk mengekstraksi faktor pengaruh yang efisien masa yang khusus untuk kumpulan data. Model kelabu (*Grey Model*) dicadangkan untuk meramalkan trend harga emas bersama dengan perlombongan faktor dan dinilai menggunakan MAPE. Kumpulan data tersebut merangkumi sepuluh tahun harga emas harian dari 2007 hingga 1 Julai, harga indeks saham dari pelbagai negara, harga pertukaran, indeks bukan pertanian, indeks pengguna, dan harga pembukaan dan penutupan. Mereka menyimpulkan bahawa kesalahan ramalan untuk setiap bulan kurang dari 6% dan nilai MAPE untuk 12 bulan data ujian adalah 4.31.

Dalam kajian ramalan emas menurut kepada Røine dan Holter (2018), mereka menggunakan konsep gerakan pecahan Brown (*Fractional Brownian Motion*) menerapkan harga emas untuk mencari bukti memori yang panjang. Sementara itu, Gradient Boosting Machine dan XGBoost digunakan untuk menentukan kepentingan relatif pemboleh ubah kewangan dan ekonomi dalam meramalkan harga emas. Set data tersebut merangkumi harga emas harian dari tahun 1978 hingga 2018, inflasi di Amerika Syarikat, Hasil Perbendaharaan 10 tahun, kadar pengangguran, dan barang tahan lama (*Durable goods*). Kadar Dana FED (*FED Fund Rate*), S&P500, *Dow Jones Industrial Average* (DJI), Nikkei225 (N225), Hang Seng Index (HSI), Shanghai Composite Index, Shcomp. Indeks Dolar AS (DXY), USD / CNY, indeks MSCI dunia (MSWI), minyak mentah (West Texas Intermediate, WTI). Prestasi model dinilai dalam tiga jangka masa yang berbeza: sebelum, semasa, dan setelah krisis kewangan 2008. XGBoost dilaporkan memperoleh ramalan terbaik, sementara GBM mempunyai penyebaran yang lebih luas antara MAE dan RMSE, menunjukkan bahawa beberapa ramalan tersebut mengandungi beberapa kesalahan individu yang lebih besar.

Terdapat banyak pembahasan dan penyelidikan mengenai harga emas dan ramalannya serta menentukan faktor-faktor yang mempengaruhi harga emas. Dengan jaringan saraf penyebaran belakang (*backpropagating neural network*) bersama dengan algoritma genetik mendapati bahawa pergerakan harga emas yang diperoleh dari pangkalan data bursa saham New York (*New York Stock Exchange, NYSEX*), bergantung pada jangka masa yang pendek sehingga 36 hari mempengaruhi harga emas pada masa depan, mendakwa sistem mereka memberikan ramalan yang lebih baik jika dibandingkan kepada model ekonometrik tradisional (Mirmirani & Li 2004). Seterusnya, kajian ramalan mengenai harga emas dengan menggunakan kaedah MLR (*Multiple Linear Regression*) Petunjuk yang berbeza seperti; CRB (indeks masa depan Biro Penyelidikan Komoditi), IR (Kadar Inflasi), EUROUSD (Kadar Tukaran Asing USD / Euro), MI (Penawaran Wang), NYSE (Bursa Saham New York), SPX (Standard dan Miskin 500), T-BILL (*Treasury Bill*) dan USDX (*US Dollar index*) mengisyaratkan untuk mempengaruhi emas. Sementara model mereka menganggap CRB ketinggalan satu, EUROUSD ketinggalan satu, INF (*Inflation Rate*) ketinggalan ketinggian dan MI ketinggalan dua merupakan faktor penting bagi harga emas (Z. Ismail et al. 2009).

Dalam kajian yang dilakukan oleh Sujit & Kumar (2011), mereka mempertimbangkan kadar pertukaran, pulangan saham, harga minyak dan harga emas untuk model autoregresif vektor pengkomputeran dan juga kointegrasi. Mencari hubungan antara pemboleh ubah ini dan membuat kesimpulan bahawa kadar pertukaran Dolar Amerika Syarikat secara langsung mempengaruhi harga emas. Sujit & Kumar (2011) menghitung analisis korelasi dan mengungkapkan bahawa perniagaan antarabangsa, politik, keadaan pasaran, induksi dalam pasaran komoditi, tingkah laku membeli pengguna, dan inflasi adalah faktor penting untuk harga emas. Davis et al. (2014) mengembangkan kajian kes mengenai pemodelan dan ramalan harga emas di pasaran kewangan. Harga tutup emas bulanan yang disesuaikan dari Januari 2003 hingga Apr 2012 digunakan untuk membina model ARIMA dan mendedahkan bahawa semua nilai sebenar terletak di antara had yang diramalkan. Mahato dan Attar (2014) mencadangkan kaedah ensembel dengan menggunakan timbunan dan pembungkusan hibrid (*hybrid bagging*), mereka mendapati ketepatan harga emas dan perak masing-masing 85% dan 79%.

Bagi pembelajaran dalaman, Lin (2015) membincangkan tiga model ramalan iaitu rangkaian neural Backpropagating (*Backpropagating Neural Network*), *Principal Component Regression* (PCR) and Regresi pelbagai (Multiple Regression) bagaimana membina model ramalan harga emas untuk mendapatkan pemahaman yang lebih baik mengenai trend harga emas masa depan dan untuk dijadikan rujukan bagi para pakar dan pelabur. Sebagai permulaan, data sejarah mengenai perdagangan emas di Taiwan dikumpulkan dari laman web domestik antara 5 Januari 2010 dan 13 Disember 2012 yang sebanyak 900 hari urus niaga. Formula indeks teknikal untuk harga saham digunakan untuk mengira lima nilai indeks teknikal emas sebagai pemboleh ubah bebas dan harga emas pada hari berikutnya sebagai pemboleh ubah bersandar. Dibina (MR). Hakikat bahawa RMSE BPNN adalah 84.439, MAE adalah 69.041 dan MAPE adalah 0.011, yang semuanya lebih rendah daripada PCR dan MR, menunjukkan bahawa BPN memperoleh prestasi yang lebih baik daripada kedua-dua model PCR dan MR. Dalam kajian Celik dan Basarir (2017), Dengan menggunakan perisian perlombongan data RapidMiner, Rangkaian Neural Buatan (*Artificial Neural Network*, ANN) digunakan untuk meramalkan harga logam berharga seperti emas, perak, platinum, dan paladium. Lima ukuran prestasi digunakan untuk menilai model rangkaian neural tiruan: ralat kuasa dua akar, ralat mutlak, ralat relatif, Spearman's Rho, dan Kendall's Tau. Kajian ini mengkaji data emas, perak, paladium, dan platinum, serta harga gas asli, bon 30 tahun, bon 10 tahun, dan bon 5 tahun, serta S&P 500, Nasdaq, Dow Jones, FTSE100, DAX, CAC40, SMI, NIKKEI, HANH, dan SENG, serta Euro / USD, dari 4 Januari 2010 hingga 14 Disember 2015. Ramalan dan pengesahan berdasarkan harga dari suku akhir 2015. Untuk menonjolkan hasil ramalan emas ANN, model mereka telah memberikan hasil yang menjanjikan, dengan ralat punca kuasa dua (RMSE) 12.594.

Menurut kepada Alameer et al., (2019), artikel ini mencadangkan model baru untuk meramalkan turun naik harga emas bulanan jangka panjang dengan ketepatan yang tinggi. Model ini melatih rangkaian saraf perceptron lapis-lapisan menggunakan teknik meta-heuristik baru-baru ini yang disebut algoritma optimasi paus (*Whale Optimisation Algorithm*). Data yang dianalisis dalam penyelidikan ini merangkumi 360 pemerhatian bulanan mengenai harga emas (\$ / oz) dari September 1987 hingga Ogos 2017. Hasil model yang dicadangkan dibandingkan dengan model lain, termasuk rangkaian neural klasik (NN), pengoptimuman kumpulan zarah untuk rangkaian saraf (*particle swarm optimization for NN*, PSO-NN), algoritma genetik untuk rangkaian

saraf (GA-NN), dan pengoptimuman serigala kelabu untuk rangkaian saraf (grey wolf optimization, GWO – NN). Selain itu, mereka menggunakan model ARIMA sebagai penanda aras untuk menilai kapasiti model yang dicadangkan. Bukti empirikal menunjukkan bahawa model WOA – NN hibrid mengatasi model lain. Selain itu, model WOA – NN yang dicadangkan meningkatkan ketepatan ramalan sebanyak 41.25 peratus, 24.19 peratus, 25.40 peratus, 25.40 peratus, dan 85.84 peratus jika dibandingkan dengan model klasik NN, PSO-NN, GA – NN, GWO – NN, dan ARIMA.

Seterusnya, dalam kajian yang dilakukan oleh Vidya dan Hari (2020) menyatakan bahawa model LSTM mereka sambil meramalkan harga emas dari 1979 hingga 2020 berjumlah 10850 hari perdagangan, dalam INR per auns telah mencapai nilai RMSE 7.385 untuk data ujian, yang melebihi tradisional model seperti ARIMA, perkiraan matriks kovarians, regresi mendalam, SVR, CNN. Kemudian lebih jauh mencadangkan LSTM dua arah mungkin lebih baik dalam kesimpulannya. Satu lagi kajian mengenai penggunaan kaedah pembelajaran mendalam untuk meramalkan harga emas berkenaan dengan pandemik yang dilakukan oleh Khani et al. (2021) telah memperoleh hasil yang baik pada model yang dicadangkan mereka. Kerana pandemi COVID-19 menyebabkan corak perdagangan baru di dunia, model baru rangkaian urutan vektor LSTM mencapai MSE $6.0e-4$, $8.0e-4$, dan $2.0e-3$ pada data validasi yang ditetapkan selama 1 hari, 2 hari, dan ramalan 30 hari lebih awal yang mengungguli kaedah cadangan lain seperti Konvolusional Neural Networks (CNN)-LSTM, LSTM dua-arah (*Bidirectional LSTM*), dan LSTM pengekod-penyahkod (*encoder-decoder LSTM*). Livieris et al., (2020) mencadangkan model CNN LSTM dengan dua parameter yang berbeza. Versi awal CNN-LSTM merangkumi dua lapisan konvolusional dengan masing-masing 32 dan 64 penapis, dan lapisan LSTM 100 unit. Versi kedua CNN-LSTM menggabungkan semua parameter dari versi pertama, termasuk penapis 64 dan 128 untuk lapisan konvolusional, masing-masing, dan lapisan LSTM 200 unit. Selain itu, ia mengandungi lapisan yang terhubung sepenuhnya dengan 32 neuron. Harga emas harian dalam USD dari Januari 2014 hingga April 2018 termasuk dalam set data ini. Prestasi model CNN-LSTM yang dicadangkan dibandingkan dengan model lain, termasuk LSTM, SVR, dan rangkaian neural feed-forward (FFNN). Kedua-dua versi model yang dicadangkan telah mencapai hasil yang luar biasa, dengan versi pertama mengatasi model lain dalam masalah klasifikasi binari untuk meramalkan pergerakan

harga emas pada hari berikutnya, dan versi kedua CNN LSTM meredakan ramalan penurunan harga emas dengan melaporkan nilai RMSE dan MAE terendah.

Seterusnya, Ismail dan Razak (2020) melakukan kajian tentang potensi teknik Pembelajaran Dalam, khususnya jaringan LSTM, untuk meramalkan nilai masa depan Kijang Emas dalam jangka waktu yang panjang. Enam model LSTM yang terdiri daripada seni bina *Simple LSTM*, *Bidirectional LSTM*, dan *Stacked LSTM* telah dibina dan dilatih berdasarkan data harga Kijang Emas selama 15 tahun, sebanyak 3710 data. Prestasi model kemudian dibandingkan dengan ARIMA (5,1,0) dan dinilai menggunakan metrik MAE, MSE, dan RMSE. Hasil kajian menunjukkan bahawa model rangkaian LSTM menunjukkan prestasi yang baik dalam meramalkan harga Kijang Emas menggunakan set data ujian, dengan ralat rata-rata punca rata-rata (RMSE) 49.9 hingga 50.3, sementara model LSTM Bidirectional berprestasi lebih baik daripada model LSTM yang lain. Kajian daripada Krisna Gita Santika et al., (2021) menyatakan dengan hiperparameter yang tetap, kajian mereka menerapkan kaedah hibrid yang menggabungkan CNN dan LSTM. CNN mampu mengekstrak pengetahuan yang berguna dan mempelajari perwakilan dalaman data siri masa, sementara rangkaian LSTM mampu mengenal pasti kebergantungan jangka pendek dan jangka panjang dengan berkesan. Algoritma ini digabungkan untuk meramalkan harga emas setiap hari dan mingguan dengan nisbah ujian 40% dan nisbah ujian 20%. Hasil terbaik diperoleh dalam nisbah ujian waktu 40% setiap hari dengan RMSE 13.67953 dan MAE 9.40998, sementara hasil terbaik diperoleh dalam nisbah ujian waktu 20% setiap hari dengan RMSE 15.53199 dan MAE 10.32953. Pada waktu mingguan, RMSE 37.59087 dan MAE 28.01416 diperoleh untuk nisbah ujian 40%, sementara RMSE 32.68774 dan MAE 22.65841 diperoleh untuk nisbah ujian 20%. Semua kajian akan dicatat dalam jadual 2.4.

Jadual 2.4 Ringkasan kajian lalu dalam ramalan harga emas.

| Metodologi | Penulis / Tahun | Set data | Hasilan/ Prestasi |
|------------------------------|-------------------------|---|--|
| Mesin vektor sokongan | Onsumran et al., (2015) | Petunjuk ekonomi, artikel berita dan data sejarah harga emas. | SVM mengungguli semua kaedah lain dengan kadar ketepatan 87.52 peratus |
| | Raghuram, (2020) | Data pasaran saham | Model yang dicadangkan meningkatkan kadar ketepatannya. |
| | Wen et al., (2017) | Harga emas bulanan | SVM mengatasi ANN, kedua-dua kaedah dengan komponen harga digabungkan, kesalahan ramalan gabungan lebih rendah daripada ketika menggunakan satu model sahaja |
| | Makala & Li, (2021) | Harga emas harian | Linear SVM, poli SVM, dan RBF SVM. Ketiga-tiga ARIMA mengungguli, dengan linear dan poli masing-masing memperoleh skor RMSE 0.0276 dan 0.0275. |
| Linear regresi | Sadik et al., (2020) | Harga emas, pemboleh ubah deskriptif petunjuk | LR, SVM, VAR, ARIMA digunakan, LR mempunyai skor |

...sambungan

| | | | |
|---------------------------------|---|---|---|
| | | bencana geopolitik dan ekonomi. | tertinggi, ARIMA mempunyai skor terendah |
| | Sekar et al., (2017) | Harga emas bulanan selama 5 tahun | Model linear regresi mencapai RMSE 53.583. |
| | UI & Nazir, (2017) | Harga emas harian, harga minyak, S&P500, komoditi lain | LR memerlukan masa latihan yang lebih sedikit daripada ANN tetapi menunjukkan prestasi yang serupa dengan ANN |
| Penyokong Regresi Vektor | Ongsritrakul dan Soonthornphisaj (2003) | Data indeks penutupan harian | SVR mempunyai batasan ukuran set data, ia sangat sesuai untuk jumlah data yang besar. |
| | Suranart et al., (2014) | Data bulanan dan data mingguan harga emas | Menilai prestasi SVR, rangkaian neural (NN), dan rangkaian fungsi asas radial. SVR mempunyai prestasi yang terbaik. |
| | Dubey (2016) | Data harga emas harian selama 8 tahun | SVR dan ANFIS; SVR mengatasi prestasi ANFIS dalam skor RMSE yang terendah. |
| | Plakandaras et al., (2021) | Harga emas tertutup bulanan, indeks harga pengguna, TWI, 10BILL, 3BILL dan sebagainya | EEMD – SVR, Fungsi EEMD digunakan untuk melicinkan pemboleh ubah, ralat kuadrat rata-rata 0,007 pada nilai normal |

bersambung...

...sambungan

| | | | |
|--|-----------------------------|--|---|
| | | | yang merangkumi sepuluh tahun. |
| Hutan Rawak | Liu dan Li (2017) | Kadar emas, perak, dan dua logam berharga yang lain | S&P500 dan DJIA menunjukkan keupayaan positif untuk meramalkan trend harga emas |
| Jiran terdekat | Al-Dhuraibi dan Ali, (2018) | Harga emas mingguan selama 10 tahun | KNN mengatasi semua algoritma lain seperti DT, SVM, KNN, dan LR. |
| Pembelajaran statistik | Bandyopadhyay (2016) | Harga emas bulanan | Konfigurasi model ARIMA (1, 1, 1) mencapai kriteria statistik kesesuaian. |
| | Tripathy (2017) | Harga emas bulanan | ARIMA (0,1,1) adalah tetapan model yang paling sesuai |
| Kaedah pembelajaran mesin maju dan pembelajaran dalaman | Weng et al., (2020) | Harga pembukaan emas, perak, dan minyak mentah setiap hari, S&P500 | GA-ROSELM, mengatasi ARIMA, SVM, BP, ELM, dan OS-ELM dalam eksperimen ramalan harga emas dalam set ujian. |
| ICA-GRUN | Jianwei et al., (2019). | Harga emas bulanan pembukaan dan penutupan dari 1979 hingga 2017 | ICA-GRUN, mengungguli semua kaedah konvensional, termasuk ARIMA RBFNN, LSTM, dan GRUNN |

bersambung...

...sambungan

| | | | |
|--|----------------------------------|--|---|
| ANFIS | Yazdani-Chamzini et al., (2012), | Harga emas per auns sebanyak 220 pengamatan bulanan, indeks USD, kadar inflasi, harga minyak (WTI), DJI, harga perak, dan pengeluaran emas dunia | Model ANFIS mengatasi model lain (ANN dan ARIMA) dengan nilai RMSE dan MAE 5.94 dan 0.012 dalam set latihan dan masing-masing 29.84 dan 0.029 dalam set pengesahan. |
| ANN dan ANFIS | Farahani & Mehralian, (2013) | Harga penutupan emas setiap jam dari 17 September 2010 hingga 21 Januari 2011. | ANN dan ANFIS, dengan RMSE 2.54, 2.52 untuk ANFIS, dan 2.62 untuk ANN. |
| algoritma BAT | Hafezi dan Akhavan (2018) | Data 220 harga emas bulanan per pemerhatian dari 1990-04 hingga 2008-07 | Menggabungkan algoritma meta-heuristik - algoritma BAT mengungguli model ramalan konvensional dan moden, dengan nilai RMSE 21.26. |
| Model Kelabu dengan peraturan pergaulan | Han Chao dan Dong (2017) | Harga emas harian selama 10 tahun | Mengembangkan algoritma peraturan pergaulan mengekstraksi faktor pengaruh yang efisien, kesalahan ramalan untuk setiap bulan kurang dari 6% dan nilai |

bersambung...

...sambungan

| | | | |
|---|-------------------------|---|---|
| | | | MAPE untuk 12 bulan data ujian adalah 4.31. |
| XGBoost | Røine dan Holter (2018) | Harga emas harian dari tahun 1978 hingga 2018, inflasi di AS, Hasil Perbendaharaan 10 tahun, kadar pengangguran, dan barang tahan lama, Kadar Dana FED, S&P500, DJI dan sebagainya. | XGBoost dilaporkan memperoleh ramalan terbaik; GBM mempunyai penyebaran yang lebih luas antara MAE dan RMSE |
| BPNN dengan GA | (Mirmirani & Li 2004) | Harga emas harian dari 12/31/1974-12/31/1998 | BPNN dengan GA, memberikan ramalan yang lebih baik jika dibandingkan kepada model ekonometrik tradisional |
| | Sujit & Kumar (2011) | Kadar pertukaran, pulangan saham, harga minyak dan harga emas. | Membuat kesimpulan bahawa kadar pertukaran Dolar Amerika Syarikat secara langsung mempengaruhi harga emas |
| Timbunan dan pembungkusan hibrid | Mahato dan Attar (2014) | Harga emas dan perak | Timbunan dan pembungkusan hybrid, mencapai ketepatan harga emas dan perak masing-masing 85% dan 79%. |

bersambung...

...sambungan

| | | | |
|---|--------------------------|--|---|
| BPNN, PCR dan Regresi pelbagai-bagai | Lin (2015) | Perdagangan emas di Taiwan 5 Januari 2010 dan 13 Disember 2012 yang sebanyak 900 hari | tiga model ramalan, BPNN, PCR dan Regresi pelbagaian, BPNN mencapai kehasilan yang terbaik. |
| ANN | Celik dan Basarir (2017) | harga logam berharga seperti emas, perak, platinum, dan palladium dan indeks-indeks. | ANN mencapai skor RMSE 12.594. |
| WOA – NN | Alameer et al., (2019) | 360 bulanan harga emas | Algoritma optimasi paus, WOA; WOA – NN hibrid mengatasi model lain seperti klasik NN, PSO-NN, GA – NN, GWO – NN, dan ARIMA. |
| LSTM | Vidya dan Hari (2020) | Harga emas harian dalam INR per auns | LSTM mencapai nilai RMSE 7.385 untuk data ujian. |
| LSTM | Khani et al. (2021) | Stok di 11 sektor seperti Kewangan, Utiliti, Kebijaksanaan Pengguna, Staples Pengguna, Tenaga, Penjagaan Kesihatan, Industri, Teknologi, | Rangkaian urutan vektor LSTM mencapai MSE $6.0e-4$, $8.0e-4$, dan $2.0e-3$ pada data validasi |

bersambung...

...sambungan

| | | | |
|------------------------------------|---------------------------------------|---|---|
| | | Telekomunikasi, Bahan, dan Harta Tanah. | |
| CNN LSTM | Livieris et al., (2020) | Harga emas harian dalam USD sejak Januari 2014 hingga April 2018. | Dua parameter model CNN LSTM yang berbeza; versi pertama mengatasi model lain dalam masalah klasifikasi binary; versi kedua CNN LSTM meredakan ramalan penurunan harga emas dengan melaporkan nilai RMSE dan MAE terendah |
| LSTM Bidirectional | Ismail dan Razak (2020) | harga Kijang Emas dari 3 January 2005 hingga 5 May 2020, selama 15 tahun, sebanyak 3710 data. | LSTM Bidirectional berprestasi lebih baik daripada model LSTM yang lain, mencapai RMSE 49.9001, yang terendah antara model-model lain. |
| Kaedah hibrid CNN dan LSTM. | Krisna Gita Santika et al., (2021) | 4135 harga emas harian dan 835 harga emas mingguan. | Kaedah hybrid menggabung CNN dan LSTM; meramalkan harga emas setiap hari dan mingguan dengan nisbah ujian 40% dan nisbah ujian 20% dan memperoleh keputusan yang baik |

bersambung...

2.9 KESIMPULAN

Setelah kajian komprehensif mengenai kajian yang berlainan, sampai pada titik bahwa harga emas setiap hari berperan besar dalam pelaburan, teknik yang berbeza digunakan untuk tujuan ini yang disebutkan di atas tetapi masih ada misteri untuk mengetahui bahawa apa yang berlaku di masa depan sama ada naik atau jatuh. Oleh itu, berharap dapat menghasilkan skema model bertimbunan yang membolehkan ramalan harga emas dan membincangkan kesahan model dengan menggunakan MAE, RMSE dan R kuasa dua.

Pusat Sumber
FTSM

BAB III

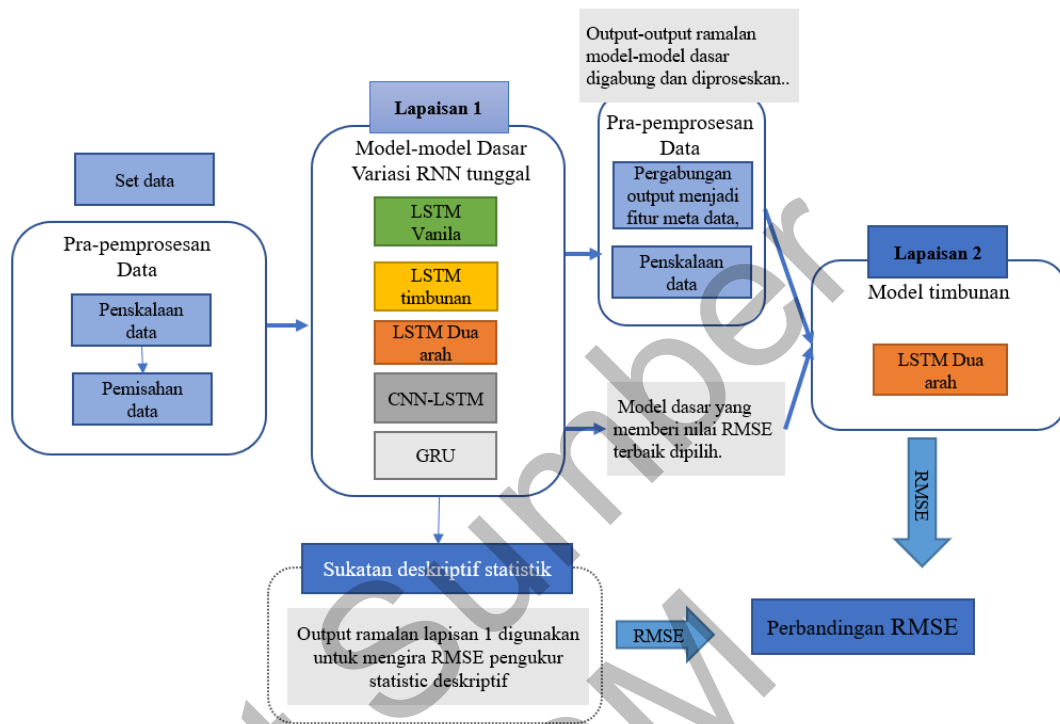
METODOLOGI

3.1 PENGENALAN

Dalam bab ini akan membicarakan secara ringkas mengenai bagaimana kajian dilakukan, pengumpulan data, pra-pemrosesan data, pengaturan permodelan dan akhirnya metrik penilaian yang digunakan untuk menilai prestasi model. Rajah 3.1 menyetengahkan kerangka kajian.

Kajian ini terbahagi kepada dua lapisan. Mulai dari standardisasi model-model dasar ataupun pembelajaran dasar variasi RNN, di mana algoritma pembelajaran dasar akan dilatih dan diuji sama dengan set data latihan, data pengesahan dan data pengujian yang sama, kemudian model terbaik dengan menilai mereka dengan metrik penilaian seperti MAE, RMSE dan R-kuasa dua telah dipilih sebagai pembelajaran meta ataupun kaedah timbunan di lapisan kedua. Seterusnya, sambil memasukkan hasil ramalan yang dihasilkan dari pembelajaran dasar kepada pembelajaran meta, menghasilkan output untuk perbandingan dengan penilaian metrik regresi. Sebaliknya, untuk analisis deskriptif statistik, output yang diperoleh dari setiap pembelajaran RNN dasar akan digunakan untuk mengira metrik deskriptif statistik seperti purata, median, minimum, maksimum.

Akhirnya, untuk mencapai objektif utama, prestasi pembelajaran asas dan pembelajaran meta akan dibandingkan untuk melihat peningkatan apa pun dengan bantuan metrik penilaian regresi, Selain itu, perbandingan metrik statistik dengan output hasil algoritma timbunan akan dilakukan.



Rajah 3.1 Kaedah cadangan timbunan.

3.2 SET DATA

Set data dihasilkan oleh World Gold Council (WGC), yang mengandungi 10991 transaksi harga emas harian yang direkodkan sejak 29 Disember 1978 hingga 6 November 2020, hanya terdiri dari hari perdagangan. Sebelum meneruskan pendekatan, penjelajahan awal data dilakukan, tidak ada nilai hilang yang dilaporkan, dan data tersebut bersih yang hanya terdiri dari lajur tarikh dan harga tutup emas harian.

3.3 KAEDAH TIMBUNAN (STACKING ALGORITHM)

Pada bahagian ini akan dibincangkan kaedah pengembangan algoritma timbunan. Prosesnya akan dibincangkan dengan teliti dalam bab ke-4. Pertamanya, model-model dasar akan diseragamkan di lapisan 1, model dasar yang digunakan dalam kajian ini adalah LSTM vanila, LSTM timbunan dan LSTM dua arah, CNN-LSTM dan GRU.

Sebab 5 model ini dipilih kerana kekurangan kajian terutamanya dalam ramalan komoditi, telah menyiratkan algoritma pembelajaran varian RNN, dalam meramalkan harga emas. Sementara itu, semua 5 model ini adalah variasi RNN yang dapat mengatasi kekurangan ketergantungan *temporal* jangka panjang (*long term temporal dependencies*), dan masalah kecerunan yang hilang dari model RNN biasa.

LSTM vanilla dipilih kerana berfungsi sebagai garis dasar dari semua model, kemudian LSTM timbunan dipilih seperti dengan meningkatkan jumlah sel LSTM untuk mencari peningkatan dibandingkan dengan vanilla LSTM. Dua arah LSTM dipilih kerana algoritma uniknya yang membolehkan mempelajari urutan data secara berulang-ulang, dengan dua cara. Sementara itu, implikasi lapisan CNN di hadapan LSTM, adalah untuk mengenal pasti di mana lapisan konvolusional dan lapisan penyatuan CNN akan meningkatkan ciri menangkap dalam urutan data. Terakhir, GRU sebagai varian LSTM dan dilaporkan mempunyai masa komputasi atau latihan yang lebih pendek daripada LSTM biasa sambil menghasilkan hasil ramalan yang sangat baik. Data yang telah diproses akan dimasukkan ke setiap model dasar di lapisan 1 untuk mendapatkan hasil atau output yang diramalkan masing-masing.

Seterusnya, metrik penilaian model regresi seperti Purata Ralat Mutlak (*Mean Absolute Error, MAE*), Purata Akar Ralat Kuasa Dua (*Root Mean Kuasa dua Error*) dan nilai R-kuasa dua (pekali korelasi) akan dipanggil untuk menilai prestasi setiap model. Model berprestasi terbaik akan dipilih sebagai pembelajaran meta dalam model timbunan lapisan kedua. Kemudian untuk melakukan timbunan, setiap output dari 5 model dasar dikumpulkan kemudian digabungkan menjadi set data meta, set data latihan, set data pengesahan dan set data pengujian. Setiap set data mengandungi 5 output yang diramalkan dari setiap model dasar di lapisan 1, dan nilai sebenarnya harga emas, sebagai fitur ke-6. Kemudian, pembelajaran meta dalam kajian ini akan mempelajari ciri-ciri dan menghasilkan output, iaitu harga emas yang diramalkan. akhirnya, menilai dan membandingkan prestasi model timbunan dengan prestasi model asas dengan metrik-metrik penilaian regresi.

Sementara itu langkah-langkah yang disebutkan di atas semuanya dilakukan dengan *Python* di *Google Colab*, perpustakaan *Keras* akan digunakan untuk merancang dan menggunakan semua model RNN.

3.4 SUKATAN STATISTIK DESKRIPTIF

Pada bahagian ini, metrik deskriptif statistik akan digunakan seperti purata, median, minimum dan maksimum output dari model-model dasar variasi RNN sebagai perbandingan dengan prestasi kaedah timbunan. Setiap nilai RMSE metrik statistik deskriptif akan dihasilkan. Purata dan median adalah ukuran kecenderungan pusat data. Purata adalah jumlah semua nilai dibahagi dengan jumlah nilai. Median adalah titik data tengah apabila set data disusun mengikut urutan dari terkecil hingga terbesar. Minimum dan Maksimum akan mengambil nilai minimum dan maksimum antara output setiap model. Proses akan dibincangkan dengan teliti dalam bab ke-4.

$$\text{Purata} = \frac{\{\text{Sum of Observation}\}}{\{\text{Total numbers of Observations}\}} \quad (16)$$

$$\text{Median} = \left\{ \frac{(n+1)}{2} \right\}^{\text{th}} \text{ term}, \quad (17)$$

3.5 METRIK PENILAIAN

Bagi skema algoritma timbunan, setiap model akan dinilai dengan MAE, RMSE, dan R kuasa dua. Sementara itu memeriksa kehilangan latihan dan data pengesahan setiap model akan membantu pemahaman prestasi model tersebut. Dalam kajian Ismail & Razak (2020) menggunakan metrik MAE dan RMSE, dan dalam kajian He et al. (2019) menggunakan RMSE.

3.5.1 Purata Ralat Mutlak (Mean Absolute Error)

Purata Ralat Mutlak (MAE), mengambil jumlah purata nilai kesilapan ataupun ralat mutlak. Oleh itu, ini bermaksud nilai MAE menunjukkan model meramalan lebih kurang nilai rata-rata daripada nilai sebenarnya. Biasanya, RMSE menghukum ralat ramalan yang dihasilkan daripada model, lebih besar daripada kesalahan yang lebih kecil, melambung atau memperbesar skor ralat purata. Ini disebabkan oleh segi empat sama nilai ralat. MAE tidak memberi berat kepada pelbagai jenis kesalahan dan sebaliknya skor meningkat secara linear dengan peningkatan kesalahan. Oleh itu, MAE paling kuat untuk *outlier*, dan biasanya nilai MAE adalah unit yang sama dengan pemboleh ubah output. Formula MAE ditunjukkan di bawah.

$$\text{MAE} = \frac{1}{N} * \text{sum for } i \text{ to } N \text{ abs}(y_i - \text{yhat}_i) \quad (18)$$

Di mana y_i adalah nilai sebenar dalam set data, yhat_i adalah nilai ramalan dan $\text{abs}()$ adalah fungsi mutlak.

3.5.2 Punca ralat purata kuasa dua (Root Mean Square Error)

Punca ralat purata kuasa dua (RMSE), adalah tambahan ralat purata kuasa dua. Ini adalah sisihan piawai bagi kesalahan atau sisa yang diramalkan. Sisa adalah ukuran sejauh mana titik data garis regresi; RMSE adalah ukuran bagaimana penyebaran sisa ini.

$$\text{RMSE} = \sqrt{\left(\frac{1}{N} * \text{sum for } i \text{ to } N (y_i - \text{yhat}_i)^2\right)} \quad (19)$$

Di mana y_i adalah nilai sebenar dalam set data, yhat_i adalah nilai ramalan dan $\text{sqrt}()$ adalah fungsi punca kuasa dua.

3.5.3 Hubungan Pekali, R kuasa dua (Correlation of Coefficient, R Kuasa dua)

Hubungan Pekali (*Correlation of Coefficient*) adalah R kuasa dua. Ini adalah metrik menunjukkan prestasi model seperti dalam menjelaskan keboleh-ubahan pada pemboleh ubah bersandar. R Kuasa dua adalah ukuran yang baik untuk menentukan sejauh mana model sesuai dengan pemboleh ubah bersandar. R Kuasa dua dikira dengan jumlah kuadrat ralat ramalan dibahagi dengan jumlah keseluruhan petak yang menggantikan ramalan yang dikira dengan purata. Nilai R Kuasa dua adalah antara 0 hingga 1 dan nilai yang lebih besar menunjukkan kesesuaian antara ramalan dan nilai sebenar. Rumus nilai ditunjukkan R kuasa dua.

$$R^2 = 1 - \frac{\text{First Sum of Errors}}{\text{Second Sum of Errors}} \quad (20)$$

3.5.4 Ralat purata kuasa dua (Mean Squared Error)

Semasa menilai kehilangan latihan dan pengesahan model, kerugian lalai diterapkan, kehilangan ralat purata kuasa dua (MSE) untuk masalah regresi. Ini adalah fungsi kerugian yang disukai di bawah kerangka kesimpulan kemungkinan maksimum jika pembahagian pemboleh ubah sasaran adalah *Gaussian*.

$$\text{MSE} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (21)$$

N adalah bilangan sampel yang diuji, y dan y_i adalah nilai sebenar dan ramalan.

3.6 KESIMPULAN

Bab ini menerangkan informasi bagi data yang digunakan dalam kajian ini. Seterusnya, menjelaskan kaedah timbunan dan menerangkan model-model dasar tunggal yang telah digunakan dan sebagai pilihan dalam kajian ini. Selain itu, metrik-metrik penilaian regresi yang dipilih telah dijelaskan dengan teliti.

BAB IV

KAEDAH DUA-LAPIS TIMBUNAN MENGGUNKAN LSTM DUA ARAH

4.1 PENGENALAN

Dalam bab ini, metodologi yang dinyatakan dalam bab 3 akan dihuraikan secara terperinci, dari penyediaan set data, pra-prosesi data, rancangan latihan model-model, penilaian model-model dasar dan kaedah timbunan dengan metrik-metrik regresi.

4.2 SET DATA OPTIMAL

Dalam kajian ini, set data diekstrak dari sektor *data hub* emas di laman web World Gold Council, autoriti global pasaran emas. Harga emas bermula dari 29 Disember 1978 hingga sekarang, yang merangkumi harga emas tahunan, suku tahunan, bulanan dan harian dalam mata wang yang berbeza seperti dolar AS, EUR, RMB, dolar HK dan lain-lain per auns. Dalam kajian ini hanya harga emas harian dalam dolar AS per auns dari 29 Disember 1978 hingga 6 November 2020, keseluruhan 10921 hari perdagangan dipilih untuk analisis. Jadual 4.1 menunjukkan set data mentah dan rajah 4.1 menunjukkan ciri yang diekstrak dalam kajian ini.

4.2.1 Pra-pemrosesan Data

Sebelum meneruskan pendekatan, penjelajahan awal data dilakukan, tidak ada nilai hilang yang dilaporkan, dan data tersebut bersih yang hanya terdiri dari lajur tarikh dan harga emas tertutup harian. Secara amnya, rangkaian saraf sensitif terhadap sifat input data. Oleh itu, pra-pemrosesan data perlu dilakukan terlebih dahulu.

4.2.1.1 Penormalan data dan Pemisahan data

Piawaian ataupun standardisasi set data adalah syarat umum bagi banyak penganggar pembelajaran mesin. Dalam kajian ini, *MinMaxScaler* digunakan untuk penskalaan standard ciri-ciri yang sangat kecil sementara itu dapat mengurangkan jurang data yang hadir dalam set data. Dengan *MinMaxScaler*, purata nilai yang diperhatikan, ruangan, ciri-ciri, pemboleh ubah dalam julat 0 dan 1. Rumus *MinMaxScaler* ditunjukkan seperti berikut:

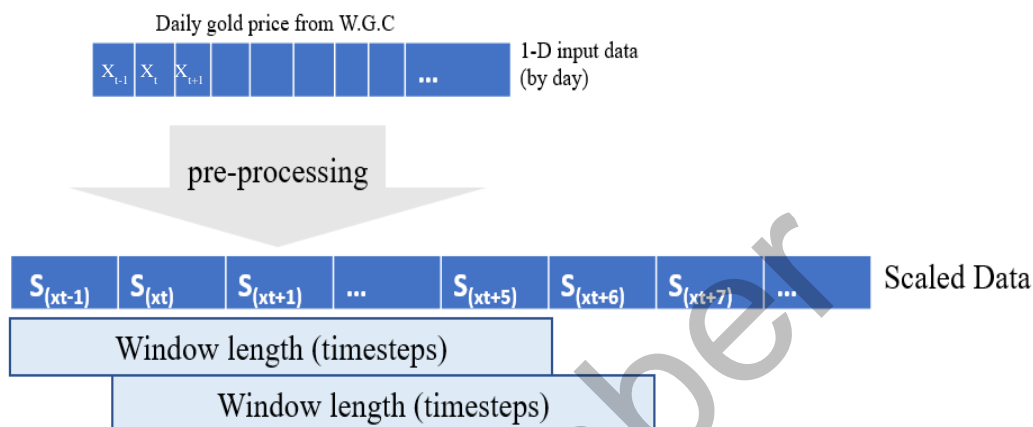
$$X_{scaled} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (21)$$

Di mana x mewakili nilai dalam data harga emas dalam satu jangka masa.

Kaedah lain seperti *RobustScaling* dan *StandardScaling* dari kajian He et al. (2019) telah dicubakan tetapi *MinMaxScaler* memberikan nilai kesalahan terkecil dalam kehilangan latihan dan pengesahan ketika mencuba dengan LSTM vanilla.

Setelah penskalaan data, maka data dibagi menjadi latihan: pengesahan: dan bahagian pengujian, dengan nisbah 80:10:10 dengan rujukan daripada kajian He et al. (2019). Kajian mereka telah menggunakan nisbah 80% dan 60% dalam data latihan dan mendapati 80% data latihan telah memberi keputusan RMSE data latihan yang menakjubkan. Walaubagaimanapun, cuma hasilan data latihan dilaporkan tetapi hasilan data pengesahan dan data ujian. Peraturan 80-20, juga dikenal sebagai Prinsip Pareto, adalah kata pepatah yang menegaskan bahawa 80% hasil (atau output) dihasilkan dari 20% dari semua sebab (atau input) untuk setiap peristiwa tertentu (Investopedia 2020). Dalam projek ini, beberapa nisbah telah digunakan untuk dilatih dan menguji model yang dibangunkan. Walaubagaimanapun, nisbah 80:20 yang baik, jadi nisbah ini akan digunakan dalam kajian ini. Pada akhirnya, mempunyai 8736 baris data latihan, 1092

baris data pengesahan, dan 1093 baris data ujian. Perbandingan nisbah akan dibincangkan di bab pendapatan kajian. Rajah 4.2 merupakan proses pemprosesan data.



Rajah 4.2 Skema Pemprosesan Data.

Untuk membolehkan model LSTM memahami data, dimensi data dibentuk daripada data skala, jangka masa dan jumlah fitur. Rajah 4.3 menggambarkan proses pemprosesan data. Dari rajah 4.3, dapat melihat bahawa data diubah dari X ke S_x . di mana X adalah harga emas, S adalah nilai Skala X , selepas MinMaxScaling. Jangka masa (*window length / timesteps*) dalam penyelidikan ini disesuaikan dari kajian sebelumnya oleh He et al., 2019 iaitu 7 hari perdagangan. Dan bilangan ciri pada tahap ini hanya 1. Oleh itu, dengan fungsi *split_sequence()* untuk menghasilkan data dengan bentuk [sampel, jangka masa, bilangan. ciri] seperti yang ditunjukkan dalam rajah 4.3.

(8729, 7, 1)

Rajah 4.3 Bentuk data input ke dalam model LSTM (Dihasilkan oleh Pengarang). Di mana 8729 bermaksud jumlah sampel atau data skala, 7 menunjukkan langkah waktu ataupun jangkah masa, dan 1 adalah jumlah ciri ataupun bilangan ciri.

4.3 PENYELESAIAN MODEL KAEDAH TIMBUNAN

Dalam sektor ini, proses kaedah RNN timbunan dibincangkan. Dari mana dari lapisan model-model dasar tunggal, memilih pembelajaran dasar yang berprestasi terbaik sebagai seni bina utama pembelajaran meta dalam lapisan kedua, kemudian membina data meta untuk ramalan kaedah timbunan dan meramalkan harga emas. Akhirnya, nilai RMSE model kaedah timbunan akan dicatatkan dan membandingkan dengan lapisan pertama.

4.3.1 Eksperimen Tetapan Persekitaran

Dalam kajian ini, skrip pengaturcaraan ditulis dalam bahasa *Python* di *Google Colab*. *Colaboratory* juga dikenali sebagai *Colab*, adalah produk dari Google Research yang membolehkan sesiapa sahaja melaksanakan kod python sewenang-wenang melalui penyemak imbas. *Colab* percuma untuk digunakan dan memberikan akses percuma ke sumber pengkomputeran seperti *Tensor Processing Unit*, TPU atau *Graphical Processing Unit*, GPU. Buku nota *Colab* boleh disimpan di *Google Drive* dalam format (.ipynb). *Colab* sesuai untuk menjalankan kajian kerana menyokong ekosistem Python di awan (*on cloud*).

Versi Python adalah 3.6, dan perpustakaan yang digunakan dalam kajian dinyatakan seperti di bawah:

- a. **KERAS:** *Keras* adalah perpustakaan Rangkaian Neural Sumber Terbuka yang ditulis dalam Python yang berjalan di atas *TensorFlow*. Ia direka bentuk untuk modular, cepat dan mudah digunakan. Ia dikembangkan oleh François Chollet, jurutera Google. Ia adalah perpustakaan yang berguna untuk membina algoritma pembelajaran mendalam.

Keras bermanfaat kerana memberikan maklum balas yang dapat ditindaklanjuti atas kesalahan pengguna, ia juga menyediakan antara muka yang ringkas dan konsisten yang dioptimumkan untuk kes penggunaan biasa. Sementara itu, sangat bagus untuk membuat lapisan (*layering*), metrik baru dan mengembangkan lagi model canggih. Akhir sekali, ia menawarkan prototaip mudah dan pantas dalam pembelajaran mesin. Pautan ke Keras adalah <https://keras.io/>.

- b. **NumPy:** *NumPy* adalah pakej asas untuk pengkomputeran saintifik di Python. Ia adalah perpustakaan Python yang menyediakan objek array multidimensi, pelbagai objek yang berasal dan pelbagai rutin untuk operasi pantas pada array. Pautan ke Numpy adalah <https://numpy.org/>.

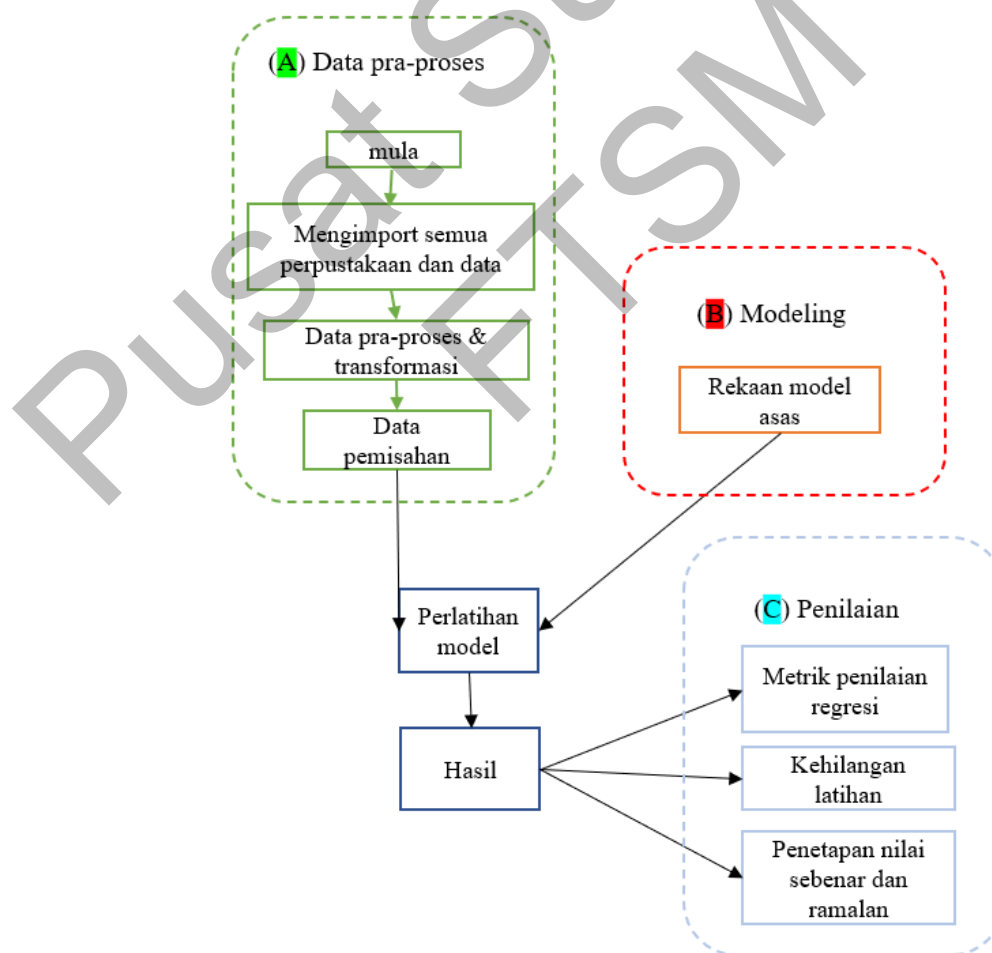
- c. **Matplotlib:** *Matplotlib* adalah perpustakaan komprehensif untuk membuat visualisasi statik, animasi, dan interaktif di *Python*. Laman web rasmi untuk Matplotlib adalah <https://matplotlib.org/>.

- d. **Pandas:** *Pandas* adalah sumber terbuka, perpustakaan berlesen BSD yang menyediakan struktur data berprestasi tinggi, mudah digunakan dan alat analisis data untuk bahasa pengaturcaraan *Python*. Pandas boleh diakses melalui: <https://pandas.pydata.org/>.

- e. **Scikit learn:** *Scikit learn* yang juga dikenali sebagai *sklearn*, adalah perpustakaan pembelajaran mesin sumber terbuka yang menyokong pembelajaran diawasi dan tidak diawasi. Ia juga menyediakan pelbagai alat untuk pemasangan model, pemprosesan data, pemilihan dan penilaian model, dan banyak utiliti lain. *Sklearn* boleh diakses melalui: <https://scikit-learn.org/stable/>.

4.3.2 Pembinaan Model-Model Variasi RNN Dasar Tunggal

Dalam kajian ini, variasi RNN mempunyai tetapan berat yang sama, inisialisasi kernel lalai (*default kernel initializer*) adalah *glorot_uniform* dan pemula bias (*default bias initializer*) lalai adalah *zeros*. Ukuran kumpulan (*batch suze*) untuk semua model adalah 128. Pengoptimum ‘Adam’ dipilih untuk mengoptimumkan hiperparameter semua model. Selain itu, *EarlyStopping of Callback* dari Keras API tersirat hanya untuk menjimatkan kekuatan komputasi dan mempercepat proses latihan semasa proses latihan di Google Colab kerana tidak ada masa latihan yang berlebihan. Sementara itu, kerugian latihan dinilai dengan ralat kuadrat purata (MSE). Model-model dasar dalam kajian ini adalah LSTM vanilla, LSTM timbunan, LSTM dua arah, CNN-LSTM dan GRU. Bahagian latihan ini dapat dibagi menjadi 3 bahagian iaitu: (A) pemprosesan data, (B) pemodelan, dan (C) penilaian model dengan metrik regresi. Cadangan bahagian ini disajikan dalam rajah 4.4.



Rajah 4.4 Cadangan kaedah model-model dasar dan penilaian.

(A) Data Pra-proses

1. Pertama, mengimport semua perpustakaan yang diperlukan dan data mentah (10921 baris harga tertutup emas harian) dan perpustakaan yang diperlukan yang disebutkan dalam 4.3.1.
2. Data kemudian tunduk pada langkah pra-pemrosesan, termasuk mengubah menjadi data skala dengan *minmaxscaler*, kemudian membaginya menjadi 3 bahagian data iaitu 8729 data latihan (*training*), 1085 data pengesahan (*validating*) dan 1086 data pengujian (*testing*). Sementara itu menggunakan fungsi *split_sequence()* untuk membahagikan data kepada bahagian *X* dan *y*, seperti *X_train*, *y_train*, *X_valid*, *y_valid* dan terakhir *X_test* dan *y_test* dan membentuk kembali data ke format yang memerlukan yang dapat difahami oleh model LSTM ialah [*samples/scaled data*, *timestep/window length*, *num of features*].

(B) Pemodelan

1. Model-model dasar dikodkan, dan seni bina dan pengkodan model ditunjukkan dalam lampiran. Bagi konfigurasi dan parameter model dasar ditunjukkan dalam jadual 4.2. Konfigurasi *timestep* ataupun jangka masa, fungsi pengaktifan, kehilangan MSE dan pengoptimum (*optimizer*) telah dirujuk dari kajian He et al. (2019).

Jadual 4.2 Konfigurasi Model Dasar

| Model | Timestep | Batch size | Activation function | Loss | Optimizer |
|----------------------|-----------------|-------------------|----------------------------|-------------|------------------|
| LSTM vanilla | 7 | 128 | relu | mse | adam |
| LSTM timbunan | 7 | 128 | relu | mse | adam |
| LSTM dua arah | 7 | 128 | relu | mse | adam |
| CNN LSTM | 7 | 128 | relu | mse | adam |
| GRU | 7 | 128 | tanh | mse | adam |

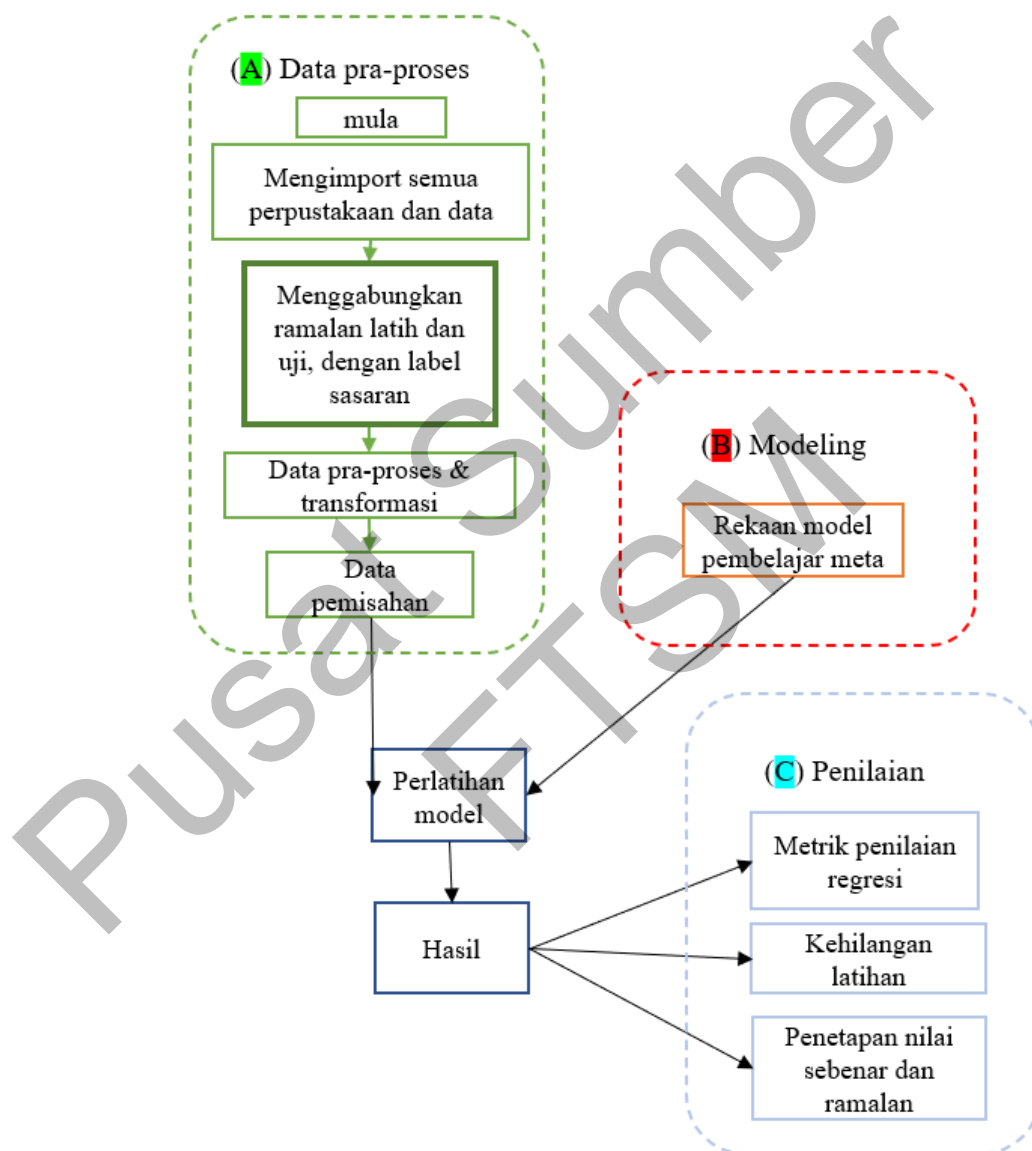
2. Meneruskan pelatihan model, semua model dasar dilatih dengan data latihan dan mengesahkan dengan data pengesahan.

(C) Penilaian

1. Model kemudian akan diuji dengan data ujian, sementara itu, output ramalan akan di-skala terbalik untuk menghasilkan nilai asal, kemudian akan dinilai dengan metrik regresi yang merupakan nilai MAE, RMSE dan R kuasa dua. Selain itu, kehilangan latihan setiap model dicatat dan terakhir, output yang diramalkan dan nilai sebenarnya akan diplot untuk menggambarkan prestasi model.

4.3.3 Pembinaan Pembelajaran Meta Kaedah Timbunan

Model dasar yang berprestasi terbaik dalam lapisan pertama akan dipilih sebagai seni bina utama pembelajaran meta dalam kaedah timbunan. Oleh itu, set data meta perlu disediakan. Kerangka pembinaan pembelajaran meta dalam skema timbunan ditunjukkan pada rajah 4.5.



Rajah 4.5 Skema Algoritma Timbunan dan Penilaian (Dihasilkan oleh Pengarang).

(A) Pra-pemrosesan data

1. Di bagian ini. Setelah memperoleh hasil yang diramalkan dari model dasar, yaitu data latihan yang diramalkan, data pengesahan yang diramalkan dan data ujian yang diramalkan. Ramalan data latihan, data pengesahan dan data ujian kemudian digabungkan dan membentuk kumpulan data meta yang terdiri daripada 6 fitur, yang merupakan 5 fitur ramalan model-model dasar dan fitur keenam, nilai sebenar harga emas sebagai sasaran atau label seperti yang ditunjukkan pada rajah 4.6.

| Fitur output ramalan daripada model-model dasar variasi RNN di lapisan 1 | | | | | | Nilai harga emas sebenar |
|--|--------------|---------------|-------------|----------------|-------------|--------------------------|
| | pred vanilla | pred bidirect | p test cnn | p test stacked | P test gru | US dollar |
| 0 | 1309.500009 | 1328.153422 | 1338.756915 | 1291.741681 | 1311.894880 | 1330.85 |
| 1 | 1324.700022 | 1330.122367 | 1347.057847 | 1291.990928 | 1312.150524 | 1324.60 |
| 2 | 1326.350018 | 1330.159313 | 1349.519000 | 1307.148812 | 1327.695733 | 1323.65 |
| 3 | 1337.249961 | 1328.710148 | 1348.689977 | 1308.794948 | 1329.383888 | 1321.75 |
| 4 | 1348.349964 | 1327.356933 | 1348.436318 | 1319.673054 | 1340.538262 | 1310.80 |
| ... | ... | ... | ... | ... | ... | ... |

Rajah 4.6 Contoh set data meta untuk pembelajaran meta di dalam model timbunan.

2. Data kemudian diproses, ke dalam bentuk data skala, sementara itu menyatakan nilai sebenarnya dari setiap set data sebagai *target_train*, *target_valid* dan *target_test*. Kemudian, data dibahagikan kepada bahagian *X* dan *y*, seperti *X_train*, *y_train*, *X_valid*, *y_valid* dan terakhir *X_test* dan *y_test*.
3. Dengan menggunakan fungsi *TimeseriesGenerator()* akan memungkinkan data dibentuk ke dalam format yang diperlukan ketika berlatih dengan multivariat, seperti yang ditunjukkan pada rajah 4.7.

```
train_generator = TimeseriesGenerator(X_train, y_train, length=n_steps, batch_size=batch_size)
```

Rajah 4.7 Fungsi *TimeseriesGenerator* (Dihasilkan oleh Pengarang).

Di mana *X_train*, *y_train* ialah data, *length* adalah jangka waktu atau panjang tetungkap, *batch_size* merujuk kepada jumlah contoh latihan yang digunakan dalam satu lelaran.

(B) Permodelan pembelajaran meta / pembelajaran timbunan

1. Pembelajaran meta bagi model timbunan akan dipilih. Dalam kajian ini, model berprestasi terbaik dari pembelajaran atau model asas, adalah LSTM dua. Oleh itu, menerapkan seni bina LSTM dua arah yang sama dari model dasar di lapisan 1 sebagai pembelajaran meta. Konfigurasi pembelajaran timbunan ditunjukkan di jadual 4.3.

Jadual 4.3 Konfigurasi pembelajaran meta kaedah timbunan.

| Model | Timestep | Batch size | Activation function | Loss | Optimizer |
|---------------|----------|------------|---------------------|------|-----------|
| LSTM dua arah | 7 | 32 | Relu | MSE | adam |

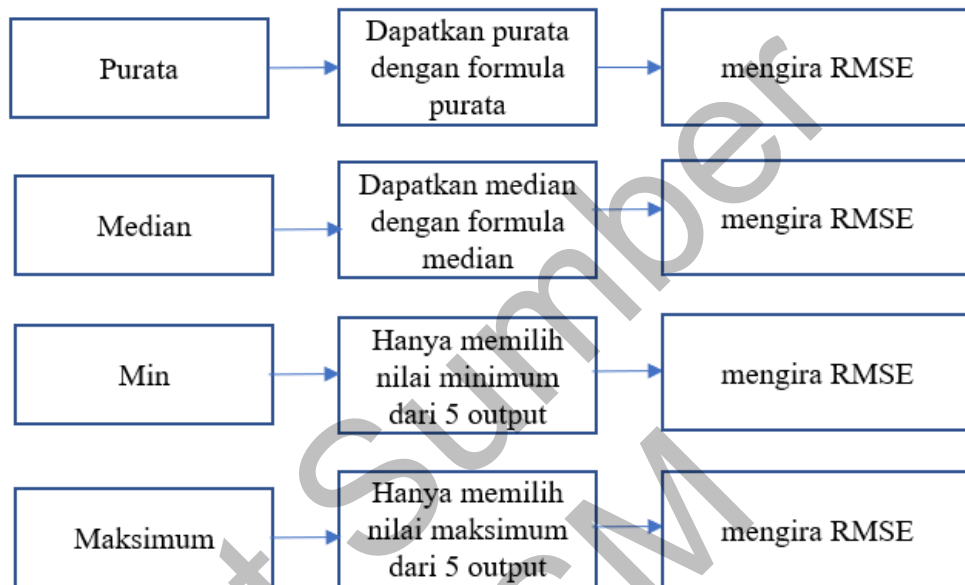
2. Untuk latihan model, dengan fungsi `model.fit_generator()` memasukkan `train_generator` untuk melatih model. Data pengesahan akan dimasukkan menjadi `valid_generator` sebagai pengesahan. `EarlyStopping` dari `Keras` juga tersirat untuk menjimatkan masa komputasi.

(C) Penilaian

1. Ramalan dihasilkan dengan menggunakan model untuk meramalkan `test_generator`. Output yang diramalkan skala terbalik menjadi nilai asal membolehkan grafik plot boleh dihasilkan daripada nilai ramalan dari model dan nilai sebenar untuk visualisasi pemasangan data. Sebaliknya, kehilangan latihan dan pengesahan dirancang dengan kehilangan ralat kuasa dua rata-rata. Tidak lupa metrik penilaian seperti MSE, RMSE dan R kuasa dua ada di sini untuk menilai prestasi algoritma timbunan.

4.4 PENGUKURAN STATISTIK

Dalam bahagian ini, pengukuran statistik dilakukan dengan menggunakan metrik deskriptif statistik seperti purata, median minimum dan maksimum bagi output yang diramalkan dari model garis dasar. Kajian ini dijalankan di *Microsoft Excel*. Proses digambarkan dalam rajah 4.8.



Rajah 4.8 Gambaran keseluruhan pengukuran statistik (Dihasilkan oleh Pengarang).

1. Pada bahagian ini, purata, median, minimum dan maksimum bagi ramalan model-model dasar akan dikira. Setiap metrik akan diukur daripada ramalan data latihan, data pengesahan dan ujian yang diramal oleh model-model dasar variasi RNN .
2. Metrik deskriptif statistik purata dan median mempunyai formula terbina dalam Excel, tidak ada formula yang diperlukan untuk Minimum dan Maksimum.
3. Kemudian, perbezaan nilai ramalan dan nilai sebenar dikira dengan pengurangan sederhana dan menghasilkan nilai positif atau negatif.