

Peramalan Kualiti Udara menggunakan Kaedah Pembelajaran Mendalam Rangkaian Perlingkaran Temporal (TCN)

(Air Quality Forecasting using Temporal Convolutional Network (TCN) Deep Learning Method)

MOHD AFTAR ABU BAKAR*, NORATIQAH MOHD ARIFF, SAKHINAH ABU BAKAR, GOH PEI CHI & RAMYAH RAJENDRAN

Jabatan Sains Matematik, Fakulti Sains dan Teknologi, Universiti Kebangsaan Malaysia, 43600 UKM Bangi, Selangor Darul Ehsan, Malaysia

Diserahkan: 13 Mac 2022/Diterima: 4 Julai 2022

ABSTRAK

Kajian ini bertujuan untuk membina model kualiti udara untuk meramalkan kepekatan bahan pencemar udara di Malaysia. Kaedah peramalan yang dipilih dalam kajian ini adalah suatu teknik pembelajaran mendalam iaitu Rangkaian Perlingkaran Temporal (TCN). Set data yang digunakan adalah siri masa zarahan terampai bersaiz diameter lebih kecil atau sama dengan 10 mikrometer (PM_{10}) yang diperoleh daripada Jabatan Alam Sekitar Malaysia dari 5 Julai 2017 hingga 31 Januari 2019. Data daripada lima stesen pemantauan kualiti udara di Semenanjung Malaysia dipilih untuk kajian ini. Bagi tujuan perbandingan, kaedah rangkaian memori jangka pendek panjang (LSTM) juga digunakan dalam kajian ini yang mana ketepatan antara kedua-dua model dibandingkan. Secara amnya, nilai model ramalan daripada kedua-dua model adalah menghampiri data asal. Walau bagaimanapun, model yang dibina dengan kaedah TCN adalah lebih baik berbanding model LSTM dari segi ketepatan nilai ramalan. Kajian ini menunjukkan bahawa TCN merupakan teknik yang sesuai digunakan dalam peramalan data siri masa bagi kualiti udara di Semenanjung Malaysia.

Kata kunci: Kualiti udara; pembelajaran mendalam; PM_{10} ; Rangkaian Perlingkaran Temporal (TCN)

ABSTRACT

This study aims to build an air quality model to predict pollutant concentrations in Malaysia. The method chosen in this study is one of the deep learning techniques which is the temporal convolution network (TCN). The data set used is particulate matter with diameter of 10 micrometers or less (PM_{10}) time series which is obtained from the Department of Environment Malaysia from 5th July 2017 to 31st January 2019. Data from five air quality monitoring stations in Peninsular Malaysia were selected for this study. The long-short term memory network (LSTM) is also used in this study for the purpose of accuracy comparison between the two models. Overall, the forecast values from both models are approximately close to the original data. However, the TCN model is better in terms of the forecast accuracy. This study shows that TCN is a suitable technique that can be used for forecasting air quality time series data in Peninsular Malaysia.

Keywords: Air quality; deep learning; PM_{10} ; Temporal Convolutional Network (TCN)

PENDAHULUAN

Berdasarkan kajian yang dijalankan oleh Jabatan Alam Sekitar dari tahun 1981 hingga 1983, status kualiti udara di Semenanjung Malaysia menunjukkan masalah pencemaran yang serius di kawasan bandar (Awang et al. 2000). Tahap pencemaran atmosfera yang tinggi

dikesan terutamanya di selatan Semenanjung Malaysia disumbangkan oleh pembangunan yang tidak seimbang dan pertumbuhan industri yang pesat sepanjang tempoh pembangunan negara (Azid et al. 2015). Menurut analisis pengelompokan yang dijalankan oleh Suris et al. (2022), terdapat perbezaan pada pola kualiti udara di beberapa

kawasan di Malaysia yang dikaitkan dengan kedudukan dan faktor geografi, selain daripada disebabkan oleh aktiviti utama dan penggunaan tanah di sesuatu kawasan (Halim et al. 2020; Latif et al. 2018).

Kualiti udara yang buruk memberi kesan kepada pelbagai isu kesihatan manusia seperti masalah pernafasan dan kesan karsinogenik (Nadzir et al. 2021). Pencemaran udara didapati telah meningkatkan risiko kanser paru-paru dan penyakit kardiopulmonari (Dockery et al. 1993). Disebabkan kesan kepekatan tinggi pelbagai pencemar terhadap kesihatan manusia, peramalan kualiti udara menjadi salah satu bidang kajian yang penting dalam bidang sains persekitaran (Sethi & Mittal 2020). Ini kerana model peramalan kualiti udara dapat membantu dalam pengurusan dan persediaan menghadapi bencana pencemaran udara.

Sejak kebelakangan ini, pembelajaran mendalam telah menjadi salah satu kaedah yang popular dalam bidang pembelajaran mesin. Hal ini disebabkan, teknik pembelajaran mendalam dapat meningkatkan ketepatan nilai peramalan (Khairi et al. 2021; Li & Sim 2014). Banyak kajian lampau berkaitan peramalan kualiti udara yang menggunakan kaedah peramalan siri masa tradisional dianggap tidak lagi sesuai disebabkan oleh data kualiti udara yang rumit dan merangkumi pelbagai pemboleh ubah. Maka, pembelajaran mendalam telah dicadangkan bagi pembinaan model kualiti udara (Lai et al. 2018).

Bagi analisis data siri masa dengan menggunakan pembelajaran mendalam, Rangkaian Neural Berulang (RNN) merupakan kaedah yang paling kerap digunakan (Yan et al. 2020). Sebagai contoh, RNN adalah kaedah yang paling kerap digunakan dalam penyelidikan pemrosesan bahasa semula jadi (Elman 1990). Walau bagaimanapun, terdapat kaedah konvolusi lain yang menunjukkan prestasi yang lebih baik berbanding RNN, contohnya kajian sintesis audio yang telah dijalankan oleh Purwins et al. (2019). Pada kajian ini, RNN didapati tidak sesuai digunakan dalam pemodelan siri masa yang mempunyai memori jangka masa panjang disebabkan masalah kecerunan lenyap. Oleh demikian, untuk menyelesaikan masalah ini, RNN telah ditambah baik dengan suatu kaedah yang dinamakan Model Rangkaian Memori Jangka Pendek Panjang (LSTM). LSTM dapat memproseskan urutan yang lebih panjang dan menjana keputusan yang lebih terperinci (Yan et al. 2020). Satu kaedah bernama Unit Berulang Berpagar (GRU) juga dicadangkan dan kerap digunakan untuk menyelesaikan masalah kecerunan lenyap bagi kaedah RNN (Chung et al. 2014).

LSTM memberikan keputusan yang baik dalam peramalan data siri masa kualiti udara (Freeman et al.

2018). Menurut Chen, Chen dan Liu (2020), LSTM kurang cekap dalam memodelkan siri masa yang mempunyai urutan sejarah yang panjang. Oleh sebab itu, model Rangkaian Perlingkaran Temporal (TCN) dicadangkan oleh Chen, Chen dan Liu (2020) untuk memodelkan siri masa yang mempunyai urutan yang panjang. TCN menunjukkan prestasi yang lebih baik berbanding LSTM dengan menggunakan masa latihan yang bersaiz sama (Sun et al. 2020). TCN juga telah menunjukkan prestasi yang lebih baik berbanding RNN dari segi ketepatan dan masa latihan (Carreras et al. 2020). Menurut Kim dan Kim (2020), penangkapan maklumat daripada penjajaran jujukan berbilang oleh TCN adalah lebih cekap dengan menggunakan bilangan urutan yang lebih rendah. Di samping itu, TCN juga dapat mempelajari corak dalam data urutan secara automatik. Oleh itu, TCN sesuai digunakan untuk mempelajari tingkah laku siri masa (He & Zhao 2019).

Matlamat bagi kajian ini adalah untuk membina model kualiti udara menggunakan teknik Rangkaian Perlingkaran Temporal (TCN). Seterusnya, model TCN yang dibina akan digunakan untuk meramal kualiti udara di Malaysia. Perbandingan ramalan antara model TCN dengan model Rangkaian Memori Jangka Pendek Panjang (LSTM) dijalankan bagi tujuan menguji ketepatan model untuk meramalkan data siri masa kualiti udara di Malaysia.

METOD

Model ramalan kualiti udara telah dibina dalam kajian ini dengan menggunakan data siri masa setiap jam kepekatan zarah terampai bersaiz diameter lebih kecil atau sama dengan 10 mikrometer (PM_{10}). Bahan pencemar PM_{10} dipilih kerana ia merupakan antara bahan pencemar utama di Semenanjung Malaysia (Nadzir et al. 2020). Terdapat lima stesen pemantauan kualiti udara telah dipilih, seperti yang ditunjukkan pada Jadual 1 yang meliputi wilayah di Utara, Selatan, Tengah, Timur dan Barat Semenanjung Malaysia. Kaedah rangkaian perlingkaran temporal (TCN) telah digunakan bagi tujuan pembinaan model peramalan kualiti udara. Peramalan daripada kaedah rangkaian memori jangka pendek panjang (LSTM) telah digunakan untuk perbandingan dengan nilai peramalan kaedah TCN dari segi ketepatan.

RANGKAIAN PERLINGKARAN TEMPORAL (TCN)

TCN merupakan gabungan pelingkaran penyebab dan perlingkaran terdilat yang mana ia dapat menguruskan siri masa dengan jujukan yang amat panjang (Chen, Chen & Liu 2020). Terdapat dua ciri utama dalam TCN iaitu yang pertama adalah TCN boleh mengambil jujukan yang

mempunyai panjang yang berbeza sebagai data input dan menghasilkan data output yang mempunyai panjang yang sama dengan data inputnya. Ciri kedua adalah TCN juga menggunakan pelingkaran penyebab dan memastikan

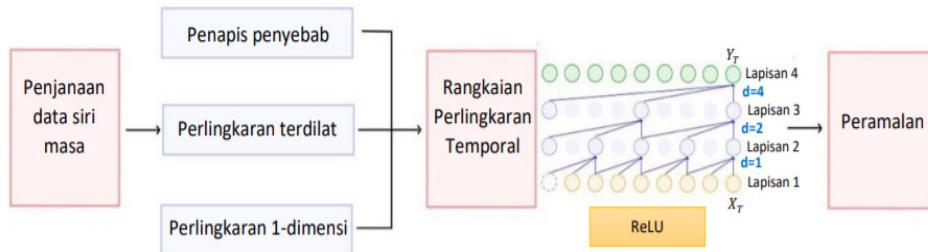
tiada sebarang maklumat yang ditinggalkan dalam seluruh proses (Yan et al. 2020). TCN juga sesuai untuk memodelkan data siri masa disebabkan medan reseptif yang fleksibel dengan menggunakan teknik perlingkaran terdilat (He & Zhao 2019).

JADUAL 1. Stesen-stesen pemantauan kualiti udara yang dipilih dalam kajian ini

Stesen	Lokasi	Tempat	Kategori
CA06P	Seberang Jaya, Pulau Pinang	Sek. Keb. Seberang Jaya II	Bandar
CA16W	Cheras, KL Wilayah Persekutuan	Sek. Men. Keb. Seri Permaisuri	Bandar
CA28M	Bandaraya Melaka, Melaka	Sekolah Tinggi Melaka	Bandar
CA36J	Kota Tinggi, Johor	Sek. Men. Agama Bandar Penawar	Sub Bandar
CA47D	Kota Bahru, Kelantan	Sek. Men. Keb. Tanjung Chat	Sub Bandar

Kaedah TCN terdiri daripada tiga komponen iaitu penjanaan data siri masa, rangkaian perlingkaran temporal (TCN), dan juga peramalan. Rajah 1 menunjukkan skema TCN bagi peramalan siri masa. Penjanaan data jujukan

dijalankan dengan menggunakan tetingkap gelongsor bagi menghasilkan data jujukan temporal daripada data siri masa asal. TCN menggunakan perlingkaran satu-dimensi, penapis penyebab dan perlingkaran terdilat untuk meningkatkan panjang medan reseptif.



RAJAH 1. Skema TCN bagi peramalan data siri masa

Salah satu ciri TCN adalah menghasilkan output dan input yang sama panjang. Jadi, seni bina rangkaian perlingkaran penuh satu-dimensi digunakan yang mana setiap lapisan tersembunyi mempunyai panjang yang sama dengan lapisan input. Lapisan tersembunyi merupakan lapisan tengah di antara lapisan input dan lapisan output. Pengisian nilai sifar ditambah dalam setiap lapisan untuk mengekalkan panjang setiap lapisan agar sama dengan panjang input. Pelingkaran penyebab dalam TCN pula memastikan tiada sebarang maklumat

ditinggalkan dalam seluruh proses yang mana output pada masa t dilingkarkan hanya kepada unsur pada masa t dan sebelumnya, pada lapisan sebelum itu. Berdasarkan Rajah 1, X_0, X_1, \dots, X_T merupakan jujukan input, Y_0, Y_1, \dots, Y_T merupakan jujukan output, lapisan antara lapisan input dan lapisan output merupakan lapisan tersembunyi dan perlingkaran penyebab mempunyai saiz kernel 3. Panjang medan reseptif L_r ditakrif seperti berikut:

$$L_r = 1 + (N_l - 1) * (S_k - 1) \quad (1)$$

dengan N_l adalah panjang lapisan dan S_k adalah saiz kernel. Berdasarkan persamaan (1), rangkaian N_l yang mendalam atau saiz kernel S_k yang besar diperlukan untuk mendapat panjang medan reseptif yang lebih panjang dan berkesan.

Oleh sebab perlingkaran penyebab memerlukan lapisan yang amat banyak untuk meningkatkan panjang medan reseptif, maka perlingkaran terdilat digunakan untuk mengatasi masalah ini. Perlingkaran terdilat dapat merangkumi kawasan yang lebih luas serta melangkau nilai input dengan langkah yang ditetapkan oleh faktor terdilat, d . Ini dapat meningkatkan panjang medan reseptif TCN dengan lebih berkesan. Berdasarkan Rajah 1, jika nilai d sama dengan 2 seperti dalam Lapisan 2, maka nilai input yang dipilih adalah input yang melangkau dengan dua langkah. Manakala, jika nilai d sama dengan 4 seperti dalam Lapisan 3, maka nilai input yang dipilih adalah input yang melangkau dengan empat langkah. Dengan ini, panjang medan reseptif dapat ditingkatkan dengan lebih berkesan.

Dengan menggunakan faktor terdilat, panjang medan reseptif ditakrifkan seperti berikut:

$$L_r = \sum_D (S_k - 1) * d \quad (2)$$

dengan D merupakan tatasusunan terdilat. Oleh sebab faktor terdilat d meningkat secara eksponen dengan kedalaman rangkaian, maka persamaan (2) dapat ditulis seperti berikut:

$$L_r = 1 + \sum_{i=1}^{N_l-1} (S_k - 1) * 2^{i-1} = 1 + (S_k - 1)(2^{N_l-1} - 1) \quad (3)$$

Seterusnya, lapisan yang padat dengan fungsi pengaktifan Unit Linear Diperbetulkan (ReLU) berfungsi sebagai lapisan regresi untuk meramalkan model (Chen, Chen & Liu 2020).

RANGKAIAN MEMORI JANGKA PENDEK PANJANG (LSTM)

LSTM adalah model yang biasa digunakan dalam pemprosesan data jujukan, seperti pemprosesan data suara atau teks. Model LSTM juga sesuai digunakan untuk peramalan data jenis siri masa (Zhao et al. 2019). Dalam kajian ini, model LSTM digunakan sebagai model perbandingan dengan model ramalan TCN.

Model LSTM terdiri daripada keadaan tersembunyi yang berfungsi sebagai memori jangka pendek rangkaian dan keadaan sel yang merupakan memori

jangka panjang rangkaian. Keadaan sel terdiri daripada tiga bahagian yang dikenali sebagai pagar iaitu pagar lupa (*forget gate*), pagar input (*input gate*) dan pagar hasil (*output gate*). Pagar lupa menentukan sama ada maklumat daripada masa terdahulu perlu disimpan atau tidak manakala pagar input mengawal arus input yang masuk ke dalam sel. Maklumat daripada kedua-dua pagar ini digunakan untuk mengemaskini keadaan sel semasa. Pagar hasil pula menentukan arus hasil yang dikeluarkan ke sel lain dan digunakan untuk mendapatkan keadaan tersembunyi sel semasa. Pengiraan untuk kedua-dua keadaan dan semua pagar ini ditunjukkan dalam Jadual 2 (Bakar et al. 2022).

PETUNJUK KETEPATAN MODEL

Dalam kajian ini, terdapat lima petunjuk digunakan untuk menilai ketepatan model dari segi ukuran ralat peramalan, iaitu min ralat kuasa dua (MSE), punca min ralat kuasa dua (RMSE), min ralat mutlak (MAE), min ralat peratusan mutlak (MAPE), min ralat peratusan mutlak simetri (SMAPE). Formula pengiraan bagi setiap ukuran ketepatan adalah seperti dalam Jadual 3.

KEPUTUSAN DAN PERBINCANGAN

Plot siri masa PM₁₀ (µg/m³) setiap jam dari 5 Julai 2017 hingga 31 Januari 2019 di Stesen Seberang Jaya, Pulau Pinang (CA06P), Stesen Cheras, Kuala Lumpur Wilayah Persekutuan (CA16W), Stesen Bandaraya Melaka, Melaka (CA28M), Stesen Kota Tinggi, Johor (CA36J) dan Stesen Kota Bahru, Kelantan (CA47D) masing-masing ditunjukkan dalam Rajah 2. Berdasarkan plot siri masa daripada lima stesen yang dipilih, kabanyakan kepekatan PM₁₀ (µg/m³) berada dalam indeks 0 hingga 100 iaitu di dalam kategori cemerlang atau baik. Terutamanya, indeks bagi stesen CA36J adalah kurang daripada 100 sepanjang masa kajian iaitu dari 5 Julai 2017 hingga 31 Januari 2019.

Kebanyakan pencemaran udara berlaku dalam jangka masa yang pendek. Stesen CA47D merupakan stesen yang paling kerap berlakunya pencemaran udara berbanding lima stesen yang lain. Walau bagaimanapun, pencemaran yang berlaku hanya berada dalam kategori pencemaran rendah dan pencemaran sederhana. Sebaliknya, stesen CA06P jarang berlaku pencemaran tetapi terdapat satu peristiwa yang mana kepekatan PM₁₀ di stesen ini menghampiri 250 µg/m³ dan dikategorikan sebagai pencemaran serius.

JADUAL 2. Persamaan untuk keadaan dan pagar dalam model LSTM

Pagar/Keadaan	Persamaan
Pagar Lupa	$f_i^{(t)} = \sigma \left(b_i^f + \sum_j U_{i,j}^f x_j^{(t)} + \sum_j W_{i,j}^f h_j^{(t-1)} \right)$ dengan b^f , U^f dan W^f , dan adalah masing-masing bias, pemberat input dan pemberat berulang bagi pagar lupa
Pagar Input	$g_i^{(t)} = \sigma \left(b_i^g + \sum_j U_{i,j}^g x_j^{(t)} + \sum_j W_{i,j}^g h_j^{(t-1)} \right)$ dengan b^g , U^g dan W^g , dan adalah masing-masing bias, pemberat input dan pemberat berulang bagi pagar input
Pagar Hasil	$o_i^{(t)} = \sigma \left(b_i^o + \sum_j U_{i,j}^o x_j^{(t)} + \sum_j W_{i,j}^o h_j^{(t-1)} \right)$ dengan b^o , U^o dan W^o , dan adalah masing-masing bias, pemberat input dan pemberat berulang bagi pagar hasil
Keadaan Sel	$s_i^{(t)} = f_i^{(t)} s_i^{(t-1)} + g_i^{(t)} \sigma \left(b_i + \sum_j U_{i,j} x_j^{(t)} + \sum_j W_{i,j} h_j^{(t-1)} \right)$ dengan b , U dan W , dan adalah masing-masing bias, pemberat input dan pemberat berulang bagi sel
Keadaan Tersembunyi	bunyi $h_i^{(t)} = o_i^{(t)} \tanh(s_i^{(t)})$

Nota: σ ialah fungsi sigmoid function, $x^{(t)}$ dan $h^{(t)}$ masing-masing ialah input dan vektor lapisan tersembunyi bagi masa t

JADUAL 3. Persamaan untuk petunjuk ketepatan model

Petunjuk Ketepatan Model

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

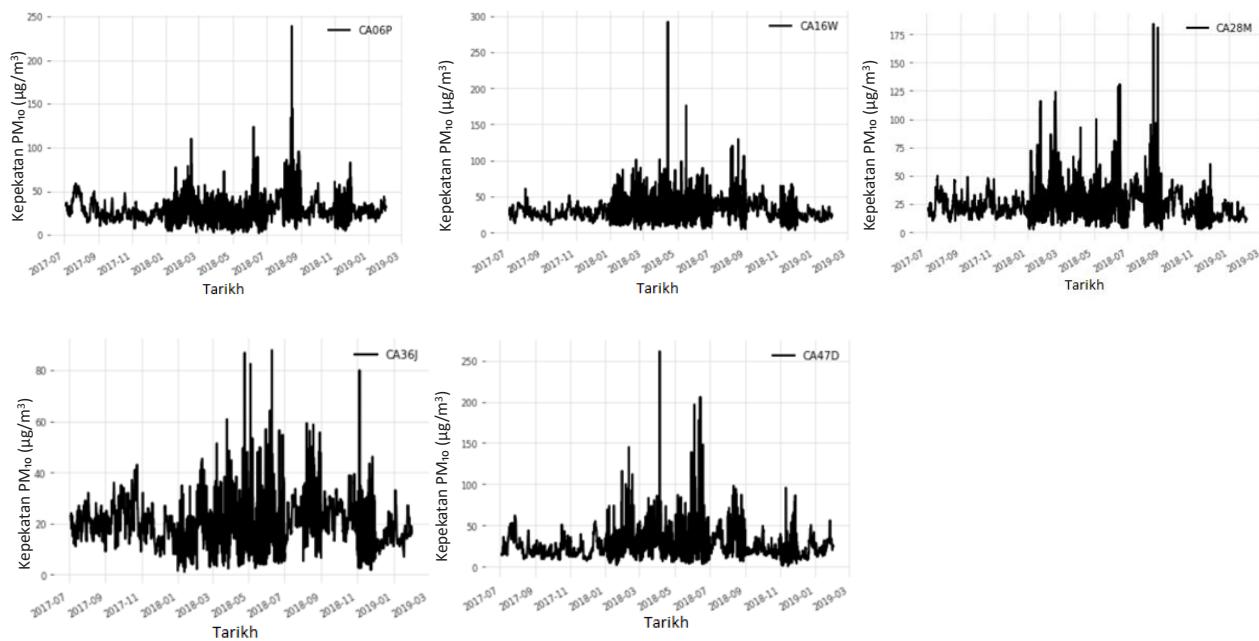
$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right|$$

$$SMAPE = \frac{200\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i + \hat{y}_i} \right|$$

Nota: dan masing-masing ialah nilai pemerhatian daripada data dan nilai ramalan daripada model

RAJAH 2. Plot siri masa PM_{10} di lima stesen yang dipilih

PEMODELAN RANGKAIAN PERLINGKARAN TEMPORAL (TCN)

Set siri masa latihan bagi setiap stesen, iaitu dari 5 Julai 2017 hingga 9 September 2019 telah digunakan bagi pembinaan lima model ramalan model TCN. Bagi setiap stesen, nilai parameter yang bersesuaian telah ditetapkan berdasarkan model TCN yang memberikan

peramalan yang terbaik pada set siri masa ujian. Jadual 4 menunjukkan ukuran ralat peramalan siri masa PM_{10} daripada model TCN bagi kelima-lima stesen pemantauan kualiti udara yang dikaji. Ukuran ralat ini dihitung dengan menggunakan petunjuk ketepatan model berdasarkan set data ujian iaitu dari 10 September 2018 hingga 31 Januari 2019.

JADUAL 4. Ukuran ralat peramalan siri masa PM_{10} bagi model TCN

Stesen	MSE	RMSE	MAE	MAPE	SMAPE
CA06P	66.6085	8.1614	6.1131	24.7797	21.5866
CA16W	63.3135	7.9570	5.8925	24.6690	21.4147
CA28M	48.2497	6.9462	5.4075	36.5763	28.4636
CA36J	29.9447	5.4722	10.2949	25.8513	22.7928
CA47D	74.2559	8.6172	6.1511	39.2279	29.5805

Julat nilai MSE adalah antara 29.9447 hingga 74.2559. Nilai MSE bagi stesen CA36J adalah paling rendah, iaitu 29.9447, manakala nilai MSE bagi stesen CA47D adalah paling tinggi iaitu 74.2559. Bagi nilai RMSE, julat adalah antara 5.4722 bagi stesen CA36J hingga 8.6172 bagi stesen CA47D.

Bagi nilai MAE, stesen CA28M adalah paling rendah iaitu 5.4075 berbanding stesen lain. Nilai MAE bagi semua stesen tidak banyak berbeza iaitu antara 5.4075 hingga 6.1511 kecuali stesen CA36J. Walaupun nilai MSE dan RMSE stesen CA36J adalah yang paling rendah berbanding stesen lain, tetapi nilai MAE stesen ini adalah yang paling tinggi berbanding stesen lain iaitu 10.2949.

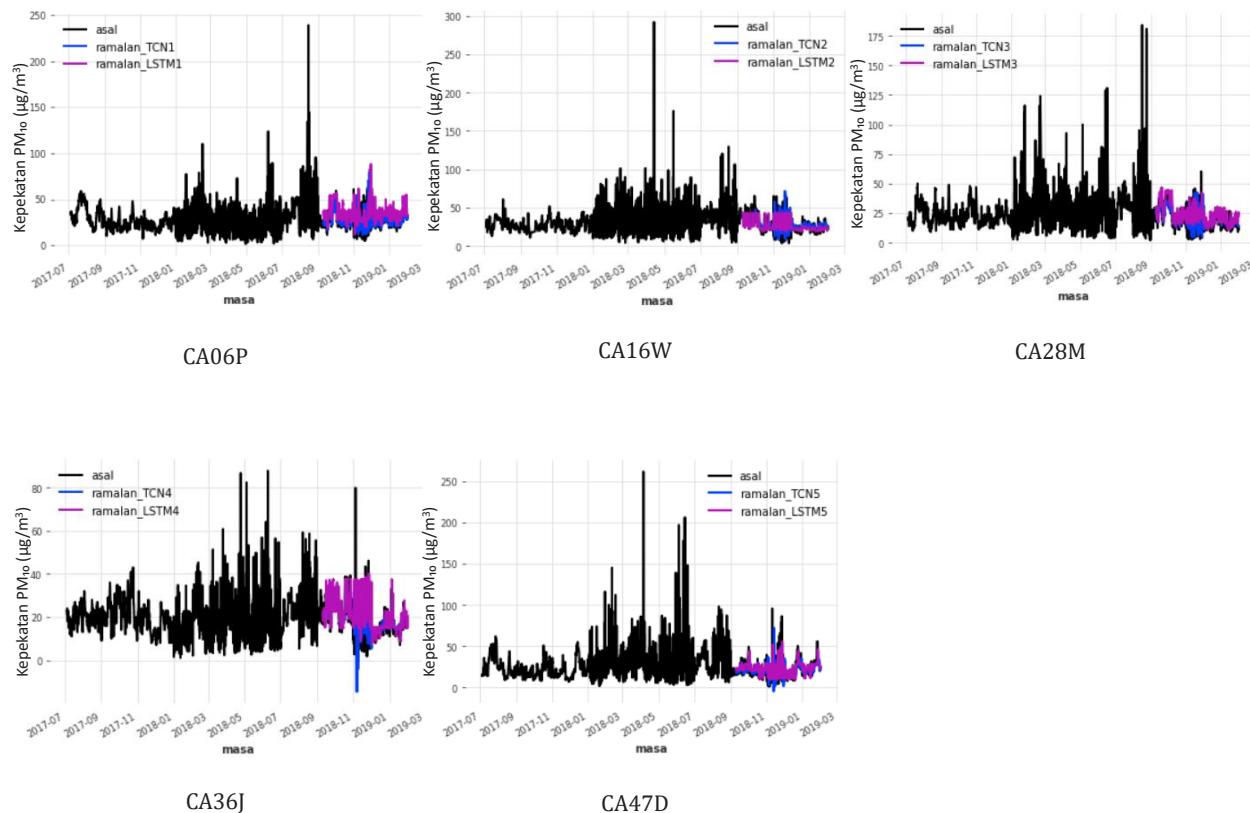
Nilai MAPE bagi stesen CA16W adalah yang paling rendah iaitu 24.6690, manakala nilai MAPE bagi stesen CA47D adalah yang paling tinggi iaitu 39.2279. Seterusnya, nilai SMAPE bagi stesen CA06P dan stesen

CA16W hampir sama iaitu 21.5866 dan 21.4147. Nilai SMAPE bagi stesen CA16W juga adalah yang paling rendah berbanding stesen lain. Manakala nilai SMAPE yang paling tinggi adalah di stesen CA47D, iaitu 29.5805.

PERBANDINGAN ANTARA MODEL TCN DAN LSTM

Sebagai perbandingan, model LSTM telah dipadankan pada kelima-lima siri masa PM_{10} di stesen yang dikaji secara berasingan. Nilai parameter yang bersesuaian juga telah ditetapkan bagi setiap model LSTM agar nilai ralat yang rendah boleh diperoleh.

Rajah 3 menunjukkan plot siri masa dan ramalan PM_{10} daripada model TCN dan model LSTM bagi kelima-lima stesen pemantauan kualiti udara yang dikaji. Jadual 5 pula menunjukkan ukuran ralat ramalan berdasarkan pengiraan petunjuk ketepatan model daripada model TCN dan LSTM bagi kelima-lima stesen yang dikaji.



RAJAH 3. Peramalan model siri masa PM_{10} dengan TCN dan LSTM di lima stesen yang dipilih

JADUAL 5. Ukuran ralat peramalan siri masa PM₁₀ bagi model TCN dan LSTM

Stesen	Model	MSE	RMSE	MAE	MAPE	SMAPE
CA06P	TCN	66.6085	8.1614	6.1131	24.7797	21.5866
	LSTM	117.0938	10.8210	11.1362	36.6571	28.6401
CA16W	TCN	63.3135	7.9570	5.8925	24.6690	21.4147
	LSTM	72.9245	8.5396	6.1851	23.3140	22.3082
CA28M	TCN	48.2497	6.9462	5.4075	36.5763	28.4636
	LSTM	66.5974	8.1607	6.5567	45.0710	32.4407
CA36J	TCN	29.9447	5.4722	10.2949	25.8513	22.7928
	LSTM	51.8628	7.2016	5.3454	35.6747	27.1314
CA47D	TCN	74.2559	8.6172	6.1511	39.2279	29.5805
	LSTM	82.1256	9.0623	6.8006	46.2697	32.1801

Bagi stesen CA06P, CA28M dan CA47D, semua nilai ukuran ralat bagi model TCN adalah lebih rendah berbanding dengan model LSTM. Ini menunjukkan peramalan siri masa PM₁₀ ($\mu\text{g}/\text{m}^3$) menggunakan model TCN adalah lebih baik dari segi ketepatan nilai peramalan berbanding model LSTM pada ketiga-tiga stesen ini. Seterusnya, bagi stesen CA16W, semua ukuran ralat bagi model TCN adalah lebih rendah berbanding dengan model LSTM kecuali nilai MAPE. Manakala stesen CA36J, hanya nilai MAE model LSTM lebih rendah berbanding model TCN. Ini menunjukkan model TCN juga lebih sesuai untuk meramalkan siri masa PM₁₀ bagi kedua-dua stesen ini. Secara keseluruhannya, boleh disimpulkan bahawa peramalan daripada model TCN adalah lebih baik dari segi ketepatan nilai ramalan berbanding model LSTM untuk kelima-lima stesen yang dikaji.

KESIMPULAN

Dalam kajian ini, kaedah pembelajaran mendalam telah digunakan untuk membuat peramalan data siri masa bagi kualiti udara. Rangkaian perlengkaran temporal (TCN) iaitu salah satu kaedah pembelajaran mendalam telah dipilih untuk meramalkan siri masa setiap jam kepekatan zarahan terampai bersaiz diameter lebih kecil daripada 10 mikrometer (PM₁₀). Lima stesen yang meliputi wilayah Utara, Selatan, Tengah, Timur dan Barat Semenanjung Malaysia telah dipilih dalam kajian ini. Selain daripada kaedah TCN, kaedah peramalan rangkaian memori

jangka pendek panjang (LSTM) juga telah digunakan dalam kajian ini untuk tujuan perbandingan. Berdasarkan perbandingan yang dijalankan, model peramalan TCN adalah lebih baik berbanding model peramalan LSTM dalam meramalkan siri masa PM₁₀ pada kelima-lima stesen pemantauan kualiti udara. Kesimpulannya, model pembelajaran mendalam TCN sesuai digunakan untuk meramalkan siri masa PM₁₀ di Malaysia.

PENGHARGAAN

Penulis ingin merakamkan setinggi-tinggi terima kasih kepada Jabatan Alam Sekitar Malaysia kerana menyumbangkan data kualiti udara yang digunakan dalam kajian ini. Selain itu, ucapan penghargaan yang tidak terhingga juga kepada Kementerian Pengajian Tinggi (KPT) untuk geran penyelidikan (FRGS/1/2019/STG06/UKM/02/4) dan kepada Universiti Kebangsaan Malaysia (UKM) untuk geran penyelidikan (GUP-2019-048) serta prasarana yang digunakan untuk kajian ini.

RUJUKAN

- Awang, M.B., Jaafar, A.B., Abdullah, A.M., Ismail, M.B., Hassan, M.N., Abdullah, R., Johan, S. & Noor, H. 2000. Air quality in Malaysia: Impacts, management issues and future challenges. *Respirology* 5(2): 183-196.
- Azid, A., Juahir, H., Ezani, E., Toriman, M.E., Endut, A., Rahman, M.N.A., Yunus, K., Kamarudin, M.K.A., Hasnam, C.N.C., Saudi, A.S.M. & Umar, R. 2015. Identification source of variation on regional impact of air quality pattern using chemometric. *Aerosol and Air Quality Research* 15(4): 1545-1558.

- Bakar, M.A.A., Ariff, N.M., Nadzir, M.S.M., Wen, O.L. & Suris, F.N.A. 2022. Prediction of multivariate air quality time series data using long short-term memory network. *Malaysian Journal of Fundamental and Applied Sciences* 18: 52-59.
- Carreras, M., Deriu, G., Raffo, L., Benini, L. & Meloni, P. 2020. Optimizing Temporal Convolutional Network inference on FPGA-based accelerators. *IEEE Journal on Emerging and Selected Topics in Circuits and Systems* 10(3): 348-361.
- Chen, J., Chen, D. & Liu, G. 2020. Using temporal convolution network for remaining useful lifetime prediction. *Engineering Reports* 2020: e12305.
- Chung, J., Gulcehre, C., Cho, K. & Bengio, Y. 2014. Empirical evaluation of gated recurrent neural networks on sequence modeling. *arXiv preprint arXiv:* 1412.3555.
- Dockery, D.W., Pope, C.A., Xu, X., Spengler, J.D., Ware, J.H., Fay, M.E., Ferris Jr., B.G. & Speizer, F.E. 1993. An association between air pollution and mortality in six US cities. *New England Journal of Medicine* 329(24): 1753-1759.
- Elman, J.L. 1990. Finding structure in time. *Cognitive Science* 14(2): 179-211.
- Freeman, B.S., Taylor, G., Gharabaghi, B. & Thé, J. 2018. Forecasting air quality time series using deep learning. *Journal of the Air & Waste Management Association* 68(8): 866-886.
- Halim, N.D.A., Latif, M.T., Mohamed, A.F., Maulud, K.N.A., Idrus, S., Azhari, A., Othman, M. & Sofwan, N.M. 2020. Spatial assessment of land use impact on air quality in mega urban regions, Malaysia. *Sustainable Cities and Society* 63: 102436.
- He, Y. & Zhao, J. 2019. Temporal convolutional networks for anomaly detection in time series. *Journal of Physics: Conference Series* 1213(4): 042050.
- Kim, H.Y. & Kim, D. 2020. Prediction of mutation effects using a deep temporal convolutional network. *Bioinformatics* 36(7): 2047-2052.
- Khairi, S.S.M., Bakar, M.A.A., Alias, M.A., Bakar, S.A., Liong, C.Y., Rosli, N. & Farid, M. 2021. Deep learning on histopathology images for breast cancer classification: A bibliometric analysis. *Healthcare* 10(10): 1-22.
- Lai, G., Chang, W.C., Yang, Y. & Liu, H. 2018. Modeling long-and short-term temporal patterns with deep neural networks. In *The 41st International ACM SIGIR Conference on Research & Development in Information Retrieval*. pp. 95-104.
- Latif, M.T., Othman, M., Idris, N., Juneng, L., Abdullah, A.M., Hamzah, W.P., Khan, M.F., Sulaiman, N.M.N., Jewaratnam, J., Aghamohammadi, N. & Sahani, M. 2018. Impact of regional haze towards air quality in Malaysia: A review. *Atmospheric Environment* 177: 28-44.
- Li, B. & Sim, K.C. 2014. A spectral masking approach to noise-robust speech recognition using deep neural networks. *IEEE/ACM Transactions on Audio, Speech, and Language Processing* 22(8): 1296-1305.
- Nadzir, M.S.M., Nor, M.Z.M., Nor, M.F.F.M., Wahab, M.I.A., Ali, S.H.M., Otuyo, M.K., Bakar, M.A.A., Saw, L.H., Majumdar, S., Ooi, M.C.G., Mohamed, F., Hisham, B.A., Hamid, H.H.A., Khaslan, Z., Ariff, N.M., Anuar, J., Tok, G.R., Ya'akop, N.A. & Meswn, M.M. 2021. Risk assessment and air quality study during different phases of COVID-19 lockdown in an urban area of Klang Valley, Malaysia. *Sustainability* 13: 12217.
- Nadzir, M.S.M., Ooi, M.C.G., Alhasa, K.M., Bakar, M.A.A., Mohtar, A.A.A., Nor, M.F.F.M., Latif, M.T., Hamid, H.H.A., Ali, S.H.M., Ariff, N.M., Anuar, J., Ahmad, F., Azhari, A., Hanif, N.M., Subhi, M.A., Othman, M. & Nor, M.Z.M. 2020. The impact of Movement Control Order (MCO) during pandemic COVID-19 on local air quality in an urban area of Klang Valley, Malaysia. *Aerosol and Air Quality Research* 20: 1237-1248.
- Purwins, H., Li, B., Virtanen, T., Schlüter, J., Chang, S.Y. & Sainath, T. 2019. Deep learning for audio signal processing. *IEEE Journal of Selected Topics in Signal Processing* 13(2): 206-219.
- Sethi, J.K. & Mittal, M. 2020. Analysis of air quality using univariate and multivariate time series models. In *2020 10th International Conference on Cloud Computing, Data Science & Engineering (Confluence)* IEEE. pp. 823-827.
- Sun, J., Luo, X., Gao, H., Wang, W., Gao, Y. & Yang, X. 2020. Categorizing malware via a word2vec-based temporal convolutional network scheme. *Journal of Cloud Computing* 9(1): 1-14.
- Suris, F.N.A., Bakar, M.A.A., Ariff, N.M., Mohd Nadzir, M.S. & Ibrahim, K. 2022. Malaysia PM₁₀ air quality time series clustering based on dynamic time warping. *Atmosphere* 13: 503.
- Yan, J., Mu, L., Wang, L., Ranjan, R. & Zomaya, A.Y. 2020. Temporal convolutional networks for the advance prediction of ENSO. *Scientific Reports* 10(1): 1-15.
- Zhao, J., Deng, F., Cai, Y. & Chen, J. 2019. Long short-term memory - Fully connected (LSTM-FC) neural network for PM2.5 concentration prediction. *Chemosphere* 220: 486-492.

*Pengarang untuk surat-menjurut; email: aftar@ukm.edu.my