

KAJIAN KE ATAS PARAMETER MODEL RANGKAIAN RAMBATAN BALIK UNTUK PERAMALAN: KAJIAN KES HASIL PENGELUARAN GETAH

ROSELINA SALLEHUDDIN¹ & SITI MARIYAM HJ. SHAMSUDDIN²

Abstrak. Kertas kerja ini membincangkan metodologi dan parameter berkaitan yang perlu diambil kira apabila melibatkan proses peramalan menggunakan teknik rambatan balik. Lazimnya, kejituan peramalan banyak dipengaruhi oleh pemilihan parameter iaitu pemalar pembelajaran (pemalar momentum (b) dan kadar pembelajaran (a)), bilangan nod tersembunyi dan jenis fungsi keaktifan. Ketidaksesuaian nilai parameter dan bilangan nod di aras tersembunyi akan menyebabkan rangkaian memberi jawapan yang mencapah daripada sasaran sebenar. Oleh yang demikian, penulis cuba mengkaji nilai parameter yang bersesuaian, perkaitan yang wujud di antara parameter tersebut serta kesannya terhadap prestasi ramalan model rambatan balik. Parameter yang dicadangkan ini diuji ke atas data pengeluaran hasil getah daripada tahun 1989 sehingga 1998.

Kata kunci: Peramalan, Rambatan balik, Parameter Pembelajaran, Momentum, Nod Tersembunyi

Abstract. This paper discusses the methodology and parameters that need to be considered when using backpropagation model for forecasting. Usually, the accuracy of forecasting depends on several parameters such as learning parameters (momentum constant (b) and learning rate (a)), number of hidden nodes and type of activation function used. When the values of learning parameters and the number of hidden nodes are not suitable, the resulted values are diverged from the actual target values. Therefore, in this study, we investigate the compatible values of learning parameters, their relationships and the effectiveness on forecasting performance. The suggested parameters are tested on data of rubber production from the year 1989 to 1998.

Keywords: Forecasting, Backpropagation, Learning Parameter, Momentum, Hidden Nodes

1.0 PENGENALAN

Penggunaan model rambatan balik dalam peramalan bukanlah merupakan satu perkara yang baru. Malah ia telah diakui sebagai salah satu model yang sesuai digunakan dalam kebanyakan aplikasi peramalan, [6]. Contohnya ialah seperti peramalan pasaran saham, kadar tukaran wang asing, ramalan kaji cuaca serta data siri masa kiosk. Model rambatan balik sering menjadi pilihan kerana ia mampu diadaptasi dalam pelbagai masalah peramalan di samping keupayaan pengitlakannya yang lebih baik.

¹ & ²Fakulti Sains Komputer dan Sistem Maklumat, Universiti Teknologi Malaysia. Email: lina@fsksm.utm.my

Namun begitu, terdapat beberapa isu yang perlu dipertimbangkan untuk memperoleh hasil ramalan yang baik daripada model rambatan balik. Lazimnya, operasi pembelajaran di dalam rangkaian rambatan balik banyak dipengaruhi oleh pemilihan parameter momentum (β), kadar pembelajaran (α), bilangan nod tersembunyi dan jenis fungsi keaktifan, iaitu fungsi linear atau tidak linear. Contoh fungsi linear adalah fungsi identiti dan fungsi tidak linear adalah seperti fungsi sigmoid dan fungsi tangen. Pemilihan fungsi keaktifan yang diguna adalah bergantung kepada masalah yang hendak diselesaikan [7].

Ketidaksesuaian nilai parameter dan bilangan nod di aras tersembunyi akan menyebabkan rangkaian memberi jawapan yang mencapah daripada sasaran sebenar. Terlalu sedikit nod tersembunyi yang digunakan mengakibatkan keupayaan rangkaian untuk mempelajari pola pada data menjadi lemah. Manakala terlalu banyak bilangan nod tersembunyi pula akan mengganggu keupayaan rangkaian kebarangkalian untuk mengalami keadaan “lebih latihan” adalah tinggi [7]. Pemalar pembelajaran, α dan β akan mempengaruhi penumpuan rangkaian. Jika nilai α yang kecil digunakan, proses pembelajaran akan mengambil masa yang lama, manakala nilai α yang besar akan mempercepatkan pembelajaran tetapi kebarangkalian penyelesaian untuk terperangkap dalam minimum setempat adalah lebih tinggi. Untuk mengelakkan keadaan ini berlaku, pemalar momentum (β) digunakan [2].

Nilai (α , β) ini terletak di antara [0, 1]. Kombinasi yang sesuai bagi pasangan nilai (α , β) sukar untuk ditentukan kerana ianya biasanya ditentukan menerusi eksperimen dan memerlukan masa yang agak lama. Ini adalah kerana beberapa pasangan nilai (α , β) perlulah dicuba bagi memperoleh hasil ramalan yang baik. Namun begitu, beberapa penyelidik telah mencadangkan beberapa peraturan. Di antaranya ialah penggunaan nilai (α , β) yang tinggi bagi masalah siri masa yang kurang kompleks dan penggunaan nilai (α) yang rendah dan nilai (β) yang tinggi bagi masalah yang agak kompleks [4]. Manakala [3] pula mencadangkan penggunaan 3 nilai parameter pembelajaran (α , β) yang berbeza iaitu (0.1, 0.5, 0.9). Pada tahun 1993, [5] telah mengkaji kesan parameter pembelajaran iaitu (α , β) ke atas beberapa set data siri masa yang berbeza. Hasil daripada kajian yang dilakukan, [5] mendapati prestasi ramalan model rangkaian neural amat dipengaruhi oleh (α , β) dan setiap set data siri masa memerlukan nilai (α , β) yang berbeza.

Justeru itu, objektif kertas kerja ini adalah untuk menentukan kombinasi parameter yang paling baik khususnya pemalar pembelajaran iaitu parameter momentum (β), dan kadar pembelajaran (α) bagi model rambatan balik menghasilkan ramalan yang paling optimum menerusi beberapa ujikaji. Di samping itu, kertas kerja ini juga akan mengkaji kesan dan kaitan parameter pembelajaran terhadap prestasi ramalan model rangkaian neural. Seterusnya hubungan yang wujud di antara parameter pembelajaran dengan bilangan nod tersembunyi yang digunakan akan dikaji.

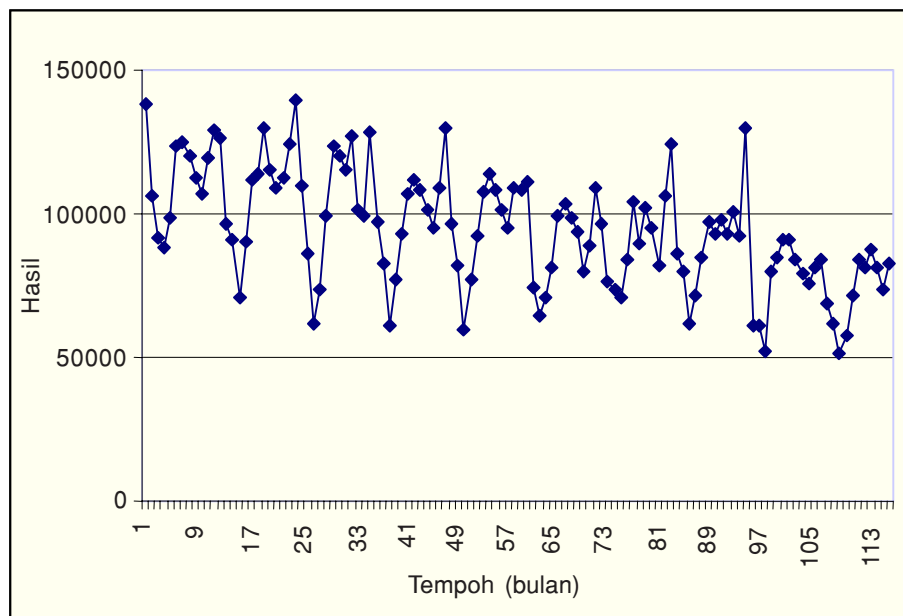
2.0 METODOLOGI KAJIAN

Metodologi kajian dibahagikan kepada dua bahagian. Bahagian pertama akan membincangkan mengenai data kajian seperti sumber perolehan data, pembahagian data serta prapemprosesan terhadap data kajian. Manakala bahagian kedua akan membincangkan mengenai bagaimana model serta ujikaji akan dibangunkan.

Bagi mencapai objektif kajian, satu sampel data telah digunakan. Data tersebut merupakan data bulanan hasil pengeluaran getah negara dari tahun 1989-1998. Data ini diperolehi dari Stesen Penyelidikan Getah, Sungai Buloh dan Institut Penyelidikan Getah Malaysia di Jalan Ampang. Data ini merupakan data siri masa bermusim dan ditunjukkan pada Rajah 1.

Data ini dibahagikan kepada dua bahagian, iaitu, Bahagian 1 terdiri daripada data dari tahun 1989-1997. Data ini digunakan untuk menganalisis dan membangunkan model yang bersesuaian. Manakala Bahagian 2 merupakan data bagi tahun yang terakhir, iaitu 1998 dan digunakan untuk menguji keupayaan model yang telah dibangunkan.

Rangkaian neural merupakan model “pacuan data” (driven-data) iaitu keupayaan model serta ketepatan ramalan yang diberikan adalah bergantung kepada data yang dipelajari. Sekiranya data yang dipelajari oleh rangkaian tidak bersesuaian dengan fungsi pengaktifan yang digunakan, ia akan memberi kesan ke atas penumpuan rangkaian sama ada dari segi ketepatan ataupun masa yang diambil. Bagi mengelakkan keadaan ini, maka data yang digunakan perlulah dijelmakan supaya ianya berada di



Rajah 1 Plot Hasil Pengeluaran Getah Malaysia (1989-1998)

dalam julat fungsi pengaktifan yang digunakan. Bersesuaian dengan fungsi sigmoid yang digunakan maka jelmaan linear telah dipilih yang menskalakan data dalam julat $[0, 1]$.

Jelmaan linear boleh dinyatakan seperti persamaan (1) berikut,

$$X_n = \frac{(X_o - X_{\min.})}{(X_{\text{maks.}} - X_{\min.})} \quad (1)$$

dengan

- X_n = nilai baru bagi X (nilai yang dinormalkan)
- X_o = nilai asal bagi X (sebelum dinormalkan)
- $X_{\min.}$ = nilai X yang paling minimum dalam sampel data
- $X_{\text{maks.}}$ = nilai X yang paling maksimum dalam sampel data yang digunakan.

Data yang diperolehi daripada penormalan ini akan digunakan untuk pembelajaran dan pengujian rangkaian neural. Data ini akan disimpan di dalam dua fail yang berbeza. Satu fail akan menyimpan data bahagian 1 dan digunakan untuk pembelajaran model. Satu lagi fail akan menyimpan data bahagian 2 dan digunakan untuk menguji keupayaan model yang dilatih menggunakan data bahagian 1.

Setelah rangkaian dilatih dan diuji, hasil yang diperolehi akan dijelmakan semula kepada nilai asal bagi memperoleh nilai yang sebenarnya bagi ramalan. Proses penukaran semula adalah seperti berikut:

$$X_{\text{asal}} = X_{\text{jelma}} (X_{\text{maks.}} - X_{\min.}) + X_{\min.} \quad (2)$$

dengan

- X_{jelma} = nilai baru bagi X (nilai yang dinormalkan)
- X_{asal} = nilai asal bagi X (sebelum dinormalkan)
- $X_{\min.}$ = nilai X yang paling minimum dalam sampel data
- $X_{\text{maks.}}$ = nilai X yang paling maksimum dalam sampel data yang digunakan.

Kemudian nilai ramalan yang diperolehi ini akan dibandingkan dengan nilai sebenar untuk mengukur keupayaan sebenar model rambatan balik melakukan ramalan ke hadapan. Pengukuran prestasi ini dilaksanakan dengan pengiraan ralat punca kuasa dua (RMS).

Jadual 1(a) menunjukkan contoh data asal yang belum dijelmakan. Manakala, Jadual 1(b) menunjukkan data dalam Jadual 1(a) yang dijelmakan menggunakan jelmaan linear.

Jadual 1(a) Data Hasil Pengeluaran Getah (tan)

	1989	1990	1991	1992	1993	1994	1995	1996	1997	1998
Jan	138252	126159	139450	128173	130200	108400	108819	124500	129600	84300
Feb	106315	96461	109844	97338	96800	111000	96747	86000	61100	68500
Mac	91979	90866	85797	82522	82100	74000	76507	80200	61200	62000
Apr	<i>87864</i>	<i>70722</i>	<i>62098</i>	<i>61325</i>	<i>59400</i>	<i>64300</i>	<i>73765</i>	<i>61600</i>	<i>52400</i>	<i>51600</i>
Mei	98281	90486	73605	76963	76900	70500	<i>70645</i>	71700	79800	57600
Jun	123404	111965	99647	93357	92600	81300	83944	84400	84700	71400
Jul	125150	113844	123448	107107	107300	99500	104254	97100	90900	83800
Ogos	120103	129959	120303	112143	113600	103700	89341	93200	90900	81200
Sep	112237	115097	115145	108580	108600	98900	102297	97800	83900	87800
Okt	107161	108806	126784	101612	101700	94000	94991	93000	79400	81400
Nov	119392	112498	101653	94965	94900	80000	81981	100700	75900	73800
Dis	129455	124636	99417	109089	109100	89100	106080	92300	81300	82300

Jadual 1(b) Data Hasil Pengeluaran Getah Yang Telah Dijelmakan

	1989	1990	1991	1992	1993	1994	1995	1996	1997	1998
Jan	0.9864	0.8487	1.0000	0.8716	0.8947	0.6466	0.6513	0.8298	0.8879	0.3722
Feb	0.6228	0.5107	0.6630	0.5206	0.5145	0.6762	0.5139	0.3916	0.1081	0.1924
Mac	0.4596	0.4470	0.3893	0.3520	0.3472	0.2550	0.2835	0.3256	0.1093	0.1184
Apr	0.4128	0.2177	0.1195	0.1107	0.0888	0.1446	0.2523	0.1138	0.0091	0.0000
Mei	0.5314	0.4426	0.2505	0.2887	0.2880	0.2151	0.2168	0.2288	0.3210	0.0683
Jun	0.8173	0.6871	0.5469	0.4753	0.4667	0.3381	0.3682	0.3734	0.3768	0.2254
Jul	0.8372	0.7085	0.8178	0.6318	0.6340	0.5452	0.5994	0.5179	0.4474	0.3665
Ogos	0.7798	0.8920	0.7820	0.6892	0.7057	0.5931	0.4296	0.4735	0.4474	0.3369
Sep	0.6902	0.7228	0.7233	0.6486	0.6488	0.5384	0.5771	0.5259	0.3677	0.4121
Okt	0.6325	0.6512	0.8558	0.5693	0.5703	0.4826	0.4939	0.4713	0.3164	0.3392
Nov	0.7717	0.6932	0.5698	0.4936	0.4929	0.3233	0.3458	0.5589	0.2766	0.2527
Dis	0.8862	0.8314	0.5443	0.6544	0.6545	0.4269	0.6201	0.4633	0.3381	0.3495

3.0 MODEL RANGKAIAN NEURAL

Model rangkaian neural dengan algoritma pembelajaran rambatan balik digunakan untuk meramalkan hasil pengeluaran getah. Bagi membangunkan model ini, satu aturcara yang ditulis dalam C++ telah dibangunkan. Model ini menggunakan satu aras tersembunyi dengan fungsi malar Sigmoid.

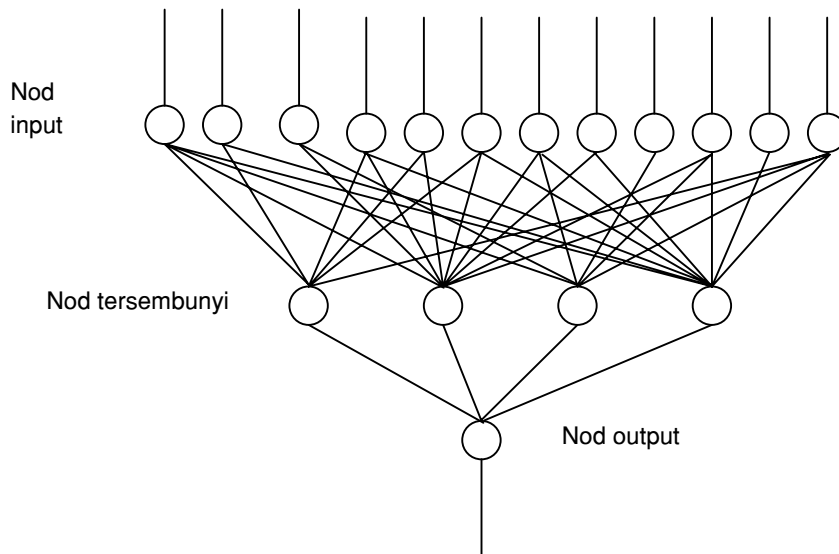
Menentukan struktur rangkaian bermakna menentukan bilangan nod input, nod output, nod tersembunyi serta aras tersembunyi yang akan digunakan. Dalam kajian ini bilangan nod input yang digunakan adalah 12, [1]. Bilangan nod output boleh ditentukan dengan dua cara iaitu kaedah langsung dan kaedah tidak langsung. Dalam kaedah langsung bilangan nod output yang digunakan mewakili tempoh ramalan yang akan dilakukan. Contohnya jika tempoh ramalan yang hendak dilakukan adalah n tempoh ke hadapan, maka bilangan nod output yang digunakan adalah n nod. Manakala, dalam kaedah tidak langsung hanya satu nod output digunakan bagi mewakili tempoh ramalan yang akan dilakukan. Output yang terhasil ini kemudiannya akan disuap balik kepada rangkaian sebagai input untuk mendapatkan output yang seterusnya. Dalam kajian ini, kaedah tidak langsung digunakan. Tempoh ramalan yang dilakukan adalah 12 bulan.

Penentuan bilangan nod tersembunyi sukar dilakukan. Bilangan nod yang sedikit akan menyebabkan rangkaian tidak mampu mempelajari perkaitan yang terdapat di dalam data. Manakala bilangan nod tersembunyi yang berlebihan akan menyebabkan rangkaian akan mengalami keadaan lebih-latihan. Terdapat banyak kaedah yang dicadangkan bagi mendapatkan bilangan nod tersembunyi yang optimum, namun tiada yang sesuai bagi semua masalah. Justeru itu, dalam kajian ini, bilangan nod tersembunyi yang optimum ditentukan menerusi kaedah “cuba-jaya”.

Kadar pembelajaran (α) dan momentum (β) merupakan parameter yang perlu dipilih bagi membantu rangkaian melatih model dengan baik. Sekiranya nilai yang tidak sesuai digunakan, pembelajaran mungkin mengambil masa yang lama ataupun terperangkap dalam minimum setempat. Maka [3] telah mencadangkan nilai bagi kedua parameter tersebut terletak di antara 0.1 dan 0.9.

Beberapa model rambatan balik dengan bilangan nod tersembunyi yang berbeza akan dilatih menggunakan nilai parameter (α dan β) yang berlainan bagi mendapatkan nilai parameter yang optimum terlebih dahulu. Kemudian itu barulah struktur rangkaian yang paling optimum ditentukan. Ralat punca kuasadua digunakan untuk mengukur prestasi model rambatan balik. Prestasi model yang mempunyai perbezaan nilai atau ralat yang paling minimum akan dianggap mempunyai kombinasi nilai parameter serta struktur rangkaian yang paling baik.

Dalam kajian ini, sembilan kombinasi parameter pembelajaran (α , β) yang terdiri daripada gabungan nilai (0.1, 0.5, 0.9) digunakan. Manakala bilangan nod tersembunyi yang digunakan adalah 4, 6, 12 dan 24. Rangkaian ini kemudiannya akan dilatih sehingga nilai RMS kurang daripada 0.05.



Rajah 2 Contoh Model Rambatan Balik Berstruktur 12-4-1

Rajah 2 menunjukkan contoh model rambatan balik yang mempunyai 12 nod input, 4 nod tersembunyi dan 1 nod output dan ia biasanya dirujuk sebagai 12-4-1.

4.0 HASIL KAJIAN

Bahagian ini akan membincangkan keputusan yang diperolehi daripada kajian yang dilakukan.

4.1 Kesan Pemalar Pembelajaran ke atas Ketepatan

Dalam kajian ini, beberapa model rambatan balik telah dibangunkan dengan menggunakan bilangan nod tersembunyi, 4, 6, 12 dan 24. Setiap model akan dilatih dengan menggunakan kombinasi nilai α dan β yang berbeza. Tiga set nilai α dan β (0.1, 0.5 dan 0.9) digunakan dan menghasilkan 9 set ujikaji bagi setiap model.

Jadual 2 menunjukkan keputusan yang diperolehi bagi model rambatan balik menggunakan 4 nod tersembunyi dan α dan β yang bernilai 0.1, 0.5 dan 0.9.

Notasi *Unit Tersembunyi* mewakili bilangan nod tersembunyi yang digunakan, α dan β mewakili nilai pemalar pembelajaran dan pemalar momentum yang digunakan, ϵ , t dan *RMS* masing-masing mewakili ralat yang dihasilkan semasa pembelajaran, masa pemrosesan dan ralat yang dihasilkan semasa fasa pengujian.

Bagi setiap kombinasi pemalar α dan β yang digunakan, model yang memberi nilai ralat ramalan (RMS) yang paling baik dipilih. Contohnya bagi model yang menggunakan 4 nod tersembunyi dan $\alpha = 0.1$, ralat yang paling minimum diperolehi apabila nilai β yang digunakan adalah 0.9. Maka bagi model rangkaian berstruktur 12-4-

Jadual 2 Kesan Perubahan Nilai α dan β

Unit Tersembunyi			4						
α	0.1		0.5		0.9				
β	0.1	0.5	0.9	0.1	0.5	0.9	0.1	0.5	0.9
ϵ	0.049	0.0497	0.0495	0.049	0.0489	0.0495	0.049	0.0492	0.0437
t	15	5	1	2	1	0	2	1	0
RMS	0.09526	0.09514	0.0949	0.09497	0.09433	0.0875	0.09489	0.09465	0.0899

1, nilai ralat yang paling minima adalah apabila $\alpha = 0.1$ dan $\beta = 0.9$. Kemudian apabila $\alpha = 0.5$, β yang sesuai ialah 0.9 dan bila $\alpha = 0.9$, $\beta = 0.9$. Apabila nilai α semakin meningkat, masa pemprosesan, t, juga semakin berkurang. Ini menunjukkan bahawa apabila nilai α ditingkatkan, keupayaan pembelajaran rangkaian semakin meningkat. Dengan erti kata lain, keupayaan pengitlakan rangkaian semakin baik dan ini ditunjukkan oleh nilai RMS yang semakin menurun.

Kajian ini diteruskan dengan menambah bilangan nod tersembunyi kepada 6,12 dan 24. Keputusan yang terhasil daripada setiap ujikaji menunjukkan pola yang hampir sama. Apabila nilai α dan β ditingkatkan daripada 0.1 kepada 0.9, masa pemprosesan semakin berkurangan dan ketepatan ramalan semakin meningkat. Bagi setiap kes,

Jadual 3 Ringkasan Keputusan Ujikaji

Unit Tersembunyi 4			
α	0.1	0.5	0.9
β	0.9	0.9	0.9
ϵ	0.0495	0.05	0.0437
t	1	0	0
RMS	0.09487	0.088	0.08988

Unit Tersembunyi 6			
α	0.1	0.5	0.9
β	0.9	0.9	0.9
ϵ	0.04911	0.046	0.0477
t	1	0	0
RMS	0.09449	0.092	0.09316

Unit Tersembunyi 12			
α	0.1	0.5	0.9
β	0.9	0.9	0.9
ϵ	0.04982	0.04658	0.0466
t	5	1	1
RMS	0.09518	0.09203	0.0736

Unit Tersembunyi 24			
α	0.1	0.5	0.9
β	0.9	0.9	0.9
ϵ	0.04987	0.04733	0.036
t	1	1	1
RMS	0.09522	0.09277	0.081

model yang terbaik diperolehi apabila nilai α berubah dari 0.1 kepada 0.9 dengan menggunakan $\beta = 0.9$.

Jadual 3 menunjukkan ringkasan keputusan yang diperolehi bagi setiap model apabila nilai α dan β yang digunakan berubah dari 0.1, 0.5 dan 0.9. Bagi setiap kes, apabila nilai α yang digunakan semakin meningkat nilai ralat juga semakin berkurang. Ini menunjukkan bahawa ramalan yang dihasilkan oleh setiap model juga semakin baik.

4.2 Kesan Nod Tersembunyi ke atas Ketepatan Ramalan

Jadual 4 menunjukkan keputusan yang diperolehi apabila bilangan nod tersembunyi yang berbeza (4, 6, 12 dan 24) digunakan bagi kombinasi nilai pemalar pembelajaran (α) dan pemalar momentum (β) yang paling optimum bagi setiap model, dengan α adalah 0.1, 0.5 dan 0.9, dan nilai b adalah 0.9. Lajur pertama mewakili bilangan nod tersembunyi yang telah digunakan, manakala baris pertama mewakili nilai α yang digunakan. Nilai selainnya mewakili ralat yang paling minimum yang diperolehi bagi setiap model yang digunakan.

Daripada Jadual 4, keputusan ujikaji menunjukkan dua keputusan yang berbeza. Bagi α bernilai 0.1 dan 0.5, ianya menunjukkan pola perubahan yang hampir sama, iaitu apabila bilangan nod tersembunyi yang digunakan meningkat dari 4 hingga 12, ralat yang dihasilkan oleh setiap model juga meningkat. Tetapi pola ini tidak diperolehi, bagi α yang bernilai 0.9.

Pola rawak yang tidak menentu telah dihasilkan dengan nilai ralat meningkat dan berkurangan secara berselang seli. Keadaan ini mungkin disebabkan oleh komponen bermusim yang terdapat pada data hasil getah atau mungkin disebabkan oleh kesan penambahan bilangan nod tersembunyi dan peningkatan nilai α yang digunakan. Penambahan bilangan nod tersembunyi dan nilai α yang tidak sesuai akan menjejaskan keupayaan pengitlakan model kerana kebarangkalian untuk terperangkap dalam penyelesaian minimum setempat adalah tinggi.

Jadual 4 Kesan Perubahan Nod Tersembunyi

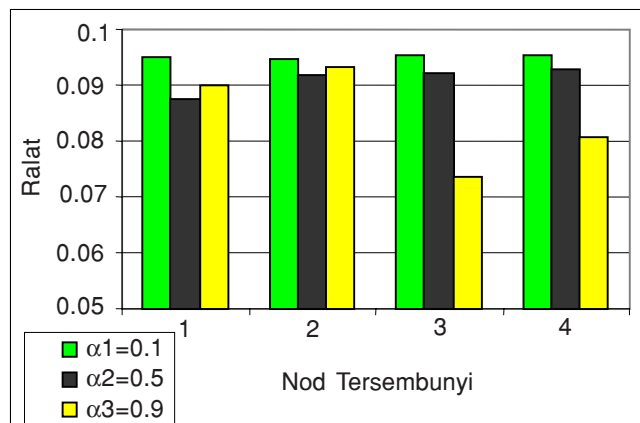
Unit Tersembunyi/ nilai α	0.1	0.5	0.9
4	0.09487	0.08752	0.08988
6	0.09449	0.09193	0.09316
12	0.09518	0.09203	0.07359
24	0.09522	0.09277	0.08083

4.3 Perkaitan Antara Pemalar Pembelajaran(α) dengan Bilangan Nod Tersembunyi

Daripada keputusan ujikaji yang diperolehi (Jadual 3), dapat dinyatakan di sini bahawa terdapat hubungan yang rapat di antara nilai pemalar pembelajaran dan bilangan nod tersembunyi yang digunakan. Kedua-duanya mempengaruhi antara satu sama lain. Bagi mendapatkan model rambatan balik yang paling baik, kombinasi yang baik di antara keduanya perlu dipertimbangkan.

Rajah 3 menunjukkan plot ralat yang dihasilkan di antara bilangan nod tersembunyi dan pemalar pembelajaran (α) yang digunakan. Paksi-x mewakili bilangan nod tersembunyi yang digunakan, dengan 1, 2, 3 dan 4 masing-masing mewakili 4, 6, 12 dan 24 nod tersembunyi. Manakala α_1 , α_2 dan α_3 masing-masing mewakili nilai α (pemalar pembelajaran) yang digunakan iaitu 0.1, 0.5 dan 0.9. Nilai pada paksi-y mewakili ralat yang dihasilkan bagi setiap model yang dikaji.

Rajah 3 menunjukkan bahawa bilangan nod tersembunyi yang digunakan akan mempengaruhi nilai α . Rajah 3 juga menunjukkan dengan jelas dua keputusan yang berbeza. Apabila bilangan nod tersembunyi yang digunakan adalah 4 dan 6, iaitu kurang daripada bilangan nod input yang digunakan, maka model yang terbaik akan diperolehi dengan kombinasi nilai $\alpha = 0.5$ dan $\beta = 0.9$. Manakala, apabila bilangan nod tersembunyi yang digunakan adalah 12 dan 24 iaitu menyamai atau melebihi bilangan nod input yang digunakan, maka model yang terbaik yang diperolehi adalah kombinasi nilai α dan β yang bernilai 0.9.



Rajah 3 Perkaitan Di Antara Pemalar Pembelajaran(α) dan Bilangan Nod Tersembunyi

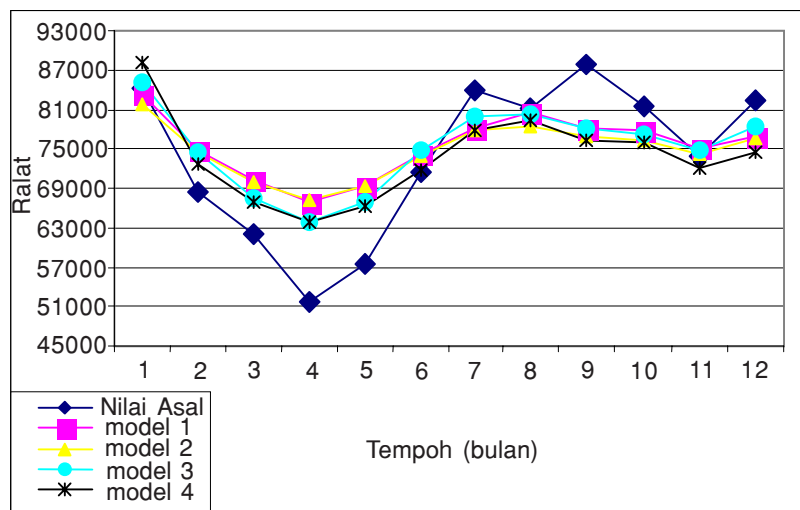
Jadual 5 menunjukkan 4 model yang berbeza. Setiap model mewakili kombinasi parameter yang terbaik bagi model yang menggunakan 4, 6, 12 dan 24 nod tersembunyi. Contohnya, Model 1 mewakili model rambatan balik dengan nilai $\alpha = 0.5$, $\beta = 0.9$ dan 4 nod tersembunyi dan Model 2 model rambatan balik dengan nilai $\alpha = 0.5$, $\beta = 0.9$ dan 6 nod tersembunyi.

Jadual 5 Model Terbaik bagi Kombinasi Parameter yang Digunakan

	Unit Tersembunyi	α	β	RMS
Model 1	4	0.5	0.9	0.08752
Model 2	6	0.5	0.9	0.09193
Model 3	12	0.9	0.9	0.07359
Model 4	24	0.9	0.9	0.08083

Daripada Jadual 5, dapatlah disimpulkan bahawa model terbaik bagi mewakili model pengeluaran hasil getah negara adalah Model 3 yang menggunakan 12 nod tersembunyi dengan α dan β adalah 0.9.

Rajah 4 menunjukkan ramalan yang dihasilkan bagi setiap model dalam Jadual 4. Nilai Asal mewakili nilai sebenar hasil pengeluaran getah dan akan dibandingkan dengan nilai ramalan yang dihasilkan oleh model 1 hingga model 4. Rajah 4 menunjukkan bahawa nilai ramalan yang paling baik diperolehi apabila 12 nod tersembunyi digunakan dengan nilai α dan $\beta = 0.9$ (Model 3), kerana ramalan yang diberikan menghampiri nilai sebenar pengeluaran hasil getah Malaysia.



Rajah 4 Perbandingan Nilai Ralat yang Dihasilkan

5.0 KESIMPULAN

Dari kajian yang dilakukan terhadap data pengeluaran hasil getah negara, dapat disimpulkan bahawa untuk mendapatkan nilai ramalan yang baik menggunakan model rambatan balik, parameter yang berkaitan perlulah diberi perhatian. Pemilihan

struktur rangkaian khususnya bilangan nod tersembunyi dan pemilihan parameter terutamanya pemalar pembelajaran dan momentum yang sesuai perlu dipertimbangkan. Ini adalah kerana ketidaksesuaian nilai yang diguna akan memberi kesan terhadap prestasi rangkaian dalam melakukan peramalan.

Keputusan ujikaji menunjukkan bahawa terdapatnya hubungan yang rapat di antara nod tersembunyi dengan pemalar pembelajaran. Pemilihan nilai pemalar pembelajaran serta momentum dipengaruhi oleh bilangan nod tersembunyi yang digunakan. Jika bilangan nod tersembunyi yang digunakan kurang daripada bilangan nod input, maka pemalar pembelajaran bernilai 0.5 sudah memadai bagi mendapatkan ramalan yang agak baik. Tetapi jika bilangan nod tersembunyi yang digunakan adalah menyamai atau melebihi nilai nod input, maka nilai pemalar pembelajaran yang lebih besar diperlukan. Dalam kajian ini, nilai pemalar pembelajaran yang diperlukan adalah 0.9. Kesimpulannya, dapatlah dinyatakan bahawa model terbaik bagi hasil pengeluaran getah negara adalah model berstruktur 12-12-1 dengan pemalar pembelajaran (α , β) bernilai 0.9.

6.0 CADANGAN KAJIAN AKAN DATANG

Dalam kajian ini, data yang digunakan adalah merupakan data siri masa univariat di mana perubahan pola data hanyalah berdasarkan kepada masa sahaja. Maka, dalam kajian selanjutnya penggunaan data siri masa multivariat dicadangkan. Di samping itu, penggunaan beberapa data siri masa yang berbeza dicadangkan bagi menentusahkan perkaitan yang wujud di antara parameter pembelajaran (α , β) dengan bilangan nod tersembunyi yang diperolehi dalam kajian ini.

RUJUKAN

- [1] Roselina Sallehuddin, Mohd. Salihin Ngadiman, dan Siti Mariyam Shamsuddin. 1999. Penentuan Saiz dan Bilangan Nod Tersembunyi Rangkaian Neural Bagi Peramalan. *Jurnal Teknologi Maklumat*, FSKSM, UTM, Jun. 67–78.
- [2] Rumelhart, D. E., G. E. Hinton, dan R. J. Williams. 1986. Learning Representation by Backpropagating errors. *Nature* 323 (6188). 533–536.
- [3] Sharda dan Patil. 1992. Connectionist Approach to Time Series Prediction: An Empirical Test, *Journal of Intelligent Manufacturing*. 317–323.
- [4] Tang, Z., C. Almeida, P. A. Fishwick. 1991. Time Series Forecasting Using Neural Networks Vs Box-Jenkins Methodology. *Simulation*. 57(5): 303–310.
- [5] Tang, Z., P. A. Fishwick. 1993. Feedforward Neural Nets As Models For Time Series Forecasting. *ORSA Journal on Computing*. 5(4): 374–385.
- [6] Weigend, A. S., B. A. Hubermann, dan D. E. Rumelhart. 1990. Predicting The Future: A Connectionist Approach, *International Journal of Neural Systems*. 1(3): 193–209.
- [7] Zhang *et al.* 1998. Forecasting With Artificial Neural Networks: The State Of The Art. *International Journal of forecasting* 14(1998). 35–62.