

MODEL RANGKAIAN NEURAL BAGI PENENTUAN GAYA PEMBELAJARAN PELAJAR
BERASASKAN MODEL FELDER-SILVERMAN

Mohd Faisal Ibrahim^{1,2*}, Fatimah Az Zahra Azizan¹ & Mohd Saiful Dzulkefly Zan^{1,2}

**¹Jabatan Kejuruteraan Elektrik, Elektronik dan Sistem
Universiti Kebangsaan Malaysia, 43600 UKM Bangi, Selangor, Malaysia**

**²Pusat Penyelidikan Pendidikan Kejuruteraan
Universiti Kebangsaan Malaysia, 43600 UKM Bangi, Selangor, Malaysia**

***(Pengarang Koresponden: faisal.ibrahim@ukm.edu.my)**

Abstract

Student learning style is the tendency of a student's approach to learn. Most of the conventional methods to determine students' learning style are by inquiry and survey methods that require students to answer several questions. This conventional method has several disadvantages such as requiring an amount of time to answer questions, questions are answered casually, low quality of survey questions and a different way each student interprets the questions given. With the development of today's e-learning technology such as the digital learning management system (LMS), records of student activities and interactions with the learning system can be stored online. This study aims to examine the relationship between students' activities in a LMS in determining their learning style. Based on the Felder-Silverman learning style theory, an artificial intelligence model has been developed to automatically determine the learning style dimensions by using student activity records in the LMS. Artificial intelligence models are built based on neural network algorithms and the supervised machine learning technique. These neural network models have been trained using records of how often a student visits learning content such as lecture notes, learning videos, teaching slides and online exercises. As a result, four neural network models have been produced, each of which represents the dimensions of the Felder-Silverman learning style, namely information reception, information delivery, information processing and information organisation. The accuracy of the model obtained is between 77.8% to 100%.

Keywords: Learning style, Felder-Silverman model, neural network, e-learning, student classification.

Abstrak

Gaya pembelajaran merupakan kecenderungan pendekatan seseorang pelajar untuk belajar. Kebanyakan model penentuan gaya pembelajaran yang dibangunkan menggunakan kaedah soal-selidik dan tinjauan yang memerlukan pelajar menjawab soalan yang banyak. Kaedah konvesional ini mempunyai beberapa kelemahan seperti memerlukan masa yang panjang, soal-selidik yang dijawab secara sambil-lewa, kualiti soal-selidik yang rendah serta cara setiap pelajar menginterpretasi soalan yang diberikan. Dengan perkembangan teknologi e-pembelajaran masa kini seperti sistem pengurusan pembelajaran digital (SPP), rekod mentah aktiviti dan interaksi pelajar dengan sistem pembelajaran dapat disimpan secara dalam talian. Kajian ini bertujuan untuk mengkaji hubungkait aktiviti pelajar dalam sesuatu SPP dalam menentukan gaya pembelajaran mereka. Berdasarkan teori gaya pembelajaran Felder-Silverman, satu model kepintaran buatan telah dibangunkan bagi menentukan dimensi-dimensi gaya pembelajaran secara automatik dengan menggunakan rekod aktiviti pelajar dalam SPP. Model kepintaran buatan dibina berdasarkan algoritma Rangkaian Neural dan teknik pembelajaran mesin terselia. Model Rangkaian Neural ini telah dilatih menggunakan rekod kekerapan seseorang pelajar itu melawati kandungan-kandungan pembelajaran seperti nota kuliah, video pembelajaran, slaid pengajaran dan latihan dalam talian. Hasil daripada pembelajaran mesin ini, empat model Rangkaian Neural telah terhasil yang mana setiap satu model mewakili dimensi-dimensi dalam gaya pembelajaran Felder-Silverman iaitu penerimaan maklumat, penyampaian maklumat, pemprosesan maklumat dan organisasi maklumat. Ketepatan model yang diperolehi adalah di antara 77.8% sehingga 100%.

Kata kunci: Gaya pembelajaran, model Felder-Silverman, Rangkaian Neural, e-pembelajaran, klasifikasi pelajar.

1.0 PENGENALAN

Gaya pembelajaran bagi setiap pelajar adalah berbeza dari segi cara pengetahuan itu diperolehi dan diproses. Secara idealnya, gaya pembelajaran pelajar dan gaya pengajaran pensyarah perlu seiring bagi membantu pelajar fokus dan berminat dengan ilmu yang disampaikan dan seterusnya memperoleh pencapaian akademik yang terbaik. Apabila ini berlaku, maka proses pembelajaran akan mendatangkan keseronokan dan keberkesanannya dalam pembelajaran tersebut (Gomedé et al., 2020).

Namun begitu, penggunaan kaedah soal-selidik dan tinjauan bagi menentukan gaya pembelajaran adalah bersifat konservatif. Kaedah konvensional ini mempunyai beberapa

kelemahan (Ferreira et al., 2018; Lwande et al., 2021). Antara kelemahan yang sering dilontarkan adalah i) soalan soal-selidik yang banyak memerlukan masa yang panjang untuk dijawab, ii) soal-selidik dijawab secara sambil-lewa oleh pelajar, iii) kualiti dan suasana soal-selidik yang berbeza, dan iv) setiap pelajar menginterpretasi soalan soal-selidik yang diberikan secara berbeza.

Seiring dengan perkembangan teknologi dalam era digital ini, pelajar boleh belajar secara dalam talian atau secara hibrid melalui sistem pengurusan pembelajaran (SPP) dengan pensyarah bertindak lebih sebagai fasilitator. Melalui SPP, pensyarah boleh menyediakan pelbagai bahan pengajaran seperti nota kuliah, video pembelajaran, slaid pengajaran dan sebagainya. Para pelajar pula boleh memilih bahan pengajaran yang sesuai dan sepadan dengan gaya pembelajaran mereka. Sebagai contoh, pelajar yang cenderung belajar secara pembelajaran visual akan lebih menyukai dan lebih kerap melihat sumber pembelajaran yang penuh dengan visualisasi seperti rajah, diagram ataupun carta alir (Jamali & Mohamad, 2018). Selain itu, kebanyakan SPP membolehkan rekod aktiviti dan interaksi pelajar disimpan secara dalam talian.

Justeru itu, kajian ini bertujuan untuk menggunakan kaedah analitik data bagi mencari hubungkait aktiviti pelajar dalam sesuatu SPP dalam menentukan gaya pembelajaran mereka. Kaedah analitik data yang berasaskan model kepintaran buatan membolehkan pemodelan gaya pembelajaran dibuat secara automatik tanpa memerlukan pelajar untuk menjawab soal-selidik secara khusus (Da-Costa et al., 2020). Tahap dan gaya pembelajaran pelajar boleh berubah mengikut masa, suasana atau tempat, tetapi dengan penggunaan pemodelan automatik ini, penentuan gaya pembelajaran seseorang pelajar dapat dimodelkan secara pantas melalui data interaksi pelajar dengan sistem pengurusan pembelajaran (Khan et al., 2019).

Dalam kajian ini, teori gaya pembelajaran Felder-Silverman dijadikan sebagai model rujukan asas (Felder & Silverman, 1988). Model Felder-Siverman dipilih berbanding model lain kerana ia mempunyai dimensi-dimensi gaya pembelajaran yang membolehkan cara seseorang pelajar memperolehi dan memproses pengetahuan diketahui. Secara khususnya empat dimensi gaya pembelajaran dapat diterbitkan daripada soal-selidik yang dikenali sebagai *Index of Learning Style Questionnaire* (ILS). Model ini mengklasifikasikan pelajar kepada lapan kategori gaya pembelajaran berdasarkan empat dimensi seperti di dalam

Jadual 1.

Jadual 1: Dimensi dan kategori gaya pembelajaran berdasarkan model pembelajaran Felder-Silverman

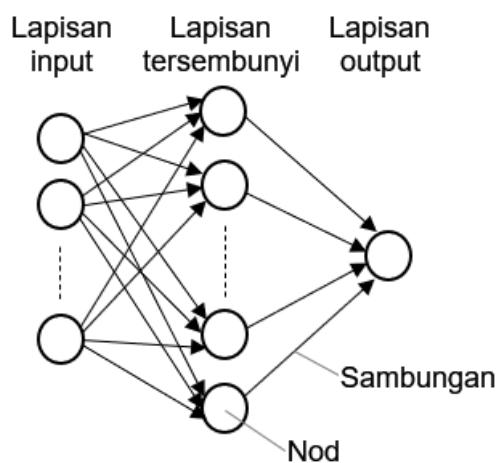
Dimensi	Kategori gaya pembelajaran	Pencirian
Penerimaan maklumat	Penderiaan	Menerima maklumat secara kukuh, praktikal, berasaskan fakta dan tatacara.
	Intuitif	Menerima maklumat secara konsep, inovatif, berasaskan teori dan definisi.
Penyampaian maklumat	Visual	Memilih maklumat bervisual seperti rajah, gambar atau video.
	Lisan	Memilih maklumat berbentuk perbualan, lisan dan penulisan.
Pemprosesan maklumat	Aktif	Memproses maklumat dengan mencuba, melakukan eksperimen dan bekerja dalam kumpulan.
	Reflektif	Memproses maklumat melalui berfikir dan bekerja secara sendiri
Organisasi maklumat	Urutan	Pemikiran linear, memilih maklumat tersusun dan pembelajaran secara langkah demi langkah.
	Global	Pemikiran holistik, memilih maklumat bersistem dan pembelajaran secara luwes.

Model kepintaran buatan telah digunakan sebelum ini oleh penyelidik untuk menentukan gaya pembelajaran pelajar. Antara model kepintaran buatan yang digunakan ialah berasaskan algoritma Pohon Keputusan (*Decision Tree*) (Ikawati et al., 2020). Walaubagaimana pun, ia mempunyai julat prestasi ketepatan yang besar, dan memerlukan konfigurasi beberapa parameter secara manual dan heuristik. Dalam kajian ini pula, model kepintaran buatan yang diadaptasi adalah berasaskan kepada model Rangkaian Neural. Rangkaian Neural merupakan satu algoritma komputer yang diinspirasikan dari mekanisma saraf-saraf dalam badan manusia bertindak dan berhubung dengan otak. Model Rangkaian Neural dibentuk melalui gabungan nod-nod yang dipanggil neuron dan disusun secara lapisan demi lapisan (Gambo et al., 2022). Semakin kompleks model yang ingin dibina, semakin

Received: 26 September 2022, Accepted: 26 October 2022, Published: 20 December 2022
<https://doi.org/10.17576/ajtlhe.1402.2022.08>

banyak lapisan neuron ditambah. Rangkaian neural merupakan satu struktur yang fleksibel, yang mana ia membolehkan komputer untuk mempelajari hubungan input dan output sesuatu model berdasarkan kepada data mentah yang diberikan (Ghosh et al., 2020).

Secara khususnya, kajian ini menggunakan struktur Rangkaian Neural yang dinamakan sebagai Perceptron Multi-Lapisan (*Multilayer Perceptron*). Struktur Rangkaian Neural Perceptron Multi-Lapisan (RN-PML) ini bermaksud setiap nod adalah bersambung sepenuhnya antara satu lapisan ke lapisan yang seterusnya seperti dalam Rajah 1.



Rajah 1: Struktur asas Rangkaian Neural Perceptron Multi-Lapisan (RN-PML).

Struktur ini terdiri daripada satu lapisan input, satu lapisan tersembunyi dan satu lapisan output. Secara matematiknya, formula algebra bagi setiap nod, N boleh dikira menggunakan persamaan (1).

$$N = \sum_{i=0}^K x_i w_i + b \quad (1)$$

yang x_i ialah nilai input i dari lapisan sebelumnya dan w_i merupakan nilai pemberat sepadan bagi nod i . Parameter b pula adalah nilai pincang dan K adalah jumlah nod dari lapisan sebelumnya. Fungsi pengaktifan bagi setiap nod ditetapkan menggunakan fungsi tidak lelurus sigmoid pada lapisan tersembunyi dan lapisan output bagi membolehkan Rangkaian Neural ini dimodelkan sebagai fungsi klasifikasi binari. Fungsi sigmoid, f boleh dikira menggunakan persamaan (2).

$$f = \frac{1}{1+e^{-N}} \quad (2)$$

Parameter-parameter yang dipelajari secara automatik oleh komputer ialah semua nilai pemberat w_i dan nilai pincang b yang diumpukan pada setiap sambungan antara satu

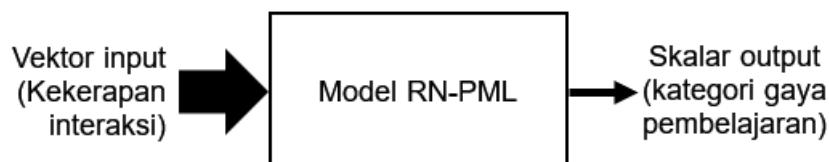
nod dengan nod yang lain. Teknik pembelajaran yang digunakan ialah algoritma rambatan balik kecerunan konjugat berskala (Shrivastava et al., 2021).

2.0 BAHAN DAN METOD

Keseluruhan kajian ini dibahagikan kepada tiga (3) proses utama. Proses-proses tersebut ialah:

- Penentuan struktur model klasifikasi
- Pengumpulan dan pemprosesan data
- Melatih dan menguji model klasifikasi

Kajian dimulakan dengan penentuan struktur model klasifikasi RN-PML yang dipilih. Bagi setiap dimensi di dalam model Felder-Silverman, satu model RN-PML dibina. Oleh itu, struktur asas input dan output kepada setiap satu model RN-PML yang dibina adalah seperti dalam Rajah 2.



Rajah 2: Struktur input dan output model klasifikasi RN-PML.

Setiap model akan menerima input mewakili kiraan kekerapan seseorang pelajar itu berinteraksi atau melawati satu-satu bahan pembelajaran yang disediakan di dalam SPP. Bagi setiap dimensi di dalam model Felder-Silverman, beberapa bahan pembelajaran telah ditentukan terlebih dahulu bagi digunakan sebagai sumber input. Sebagai contoh, dimensi pemprosesan maklumat yang boleh membezakan pelajar melalui dua gaya pembelajaran iaitu aktif atau reflektif, memerlukan bahan-bahan pembelajaran yang pelbagai antaranya memerlukan aktiviti aktif seperti menulis kod aturcara atau aktiviti pasif seperti mendengar rekod syarahan. Rekod kekerapan interaksi pelajar dengan kesemua bahan pembelajaran berkaitan akan disimpan dan dijadikan sebagai input. Oleh itu, input kepada model disimpan sebagai suatu bentuk vektor. Pada bahagian output pula, setiap model akan menentukan hanya dua (2) kategori gaya pembelajaran. Menggunakan contoh dimensi yang sama, kategori gaya pembelajaran bagi dimensi pemprosesan maklumat ialah sama ada aktif atau reflektif. Justeru, skalar output digunakan dalam konfigurasi ini yang mana nilai 0 dan 1 akan mewakili masing-masing dua kategori yang mungkin.

Setelah itu, proses pengumpulan dan pemprosesan data diteruskan melalui sistem SPP berasaskan platform Moodle yang digunakan di Universiti Kebangsaan Malaysia dinamakan sebagai UKMFolio. Data kekerapan interaksi kepada bahan-bahan pembelajaran telah diekstrak daripada fail log kursus. Dalam kajian ini, rekod yang diambil adalah daripada aktiviti-aktiviti dan bahan-bahan pembelajaran yang berkaitan kursus KKEE1153 Bahasa Pengaturcaraan semester 2 sesi akademik 2021/2022. Kuliah telah diadakan secara bersemuka sepenuhnya di mana pelajar perlu hadir secara fizikal ke kelas. Manakala, semua bahan pembelajaran dan aktiviti tugas diletakkan di dalam portal kursus di dalam sistem UKMFolio.

Rajah 3 menunjukkan aktiviti-aktiviti kuliah yang dijalankan. Kuliah dijalankan di makmal komputer (Rajah 3(a)) dan setiap pelajar menggunakan komputer untuk mengakses bahan pembelajaran di dalam sistem UKMFolio (Rajah 3(b)). Dapat dilihat juga, pelajar-pelajar perlu menyiapkan tugas menulis kod aturcara yang melibatkan perkakasan teknologi mikropengawal dan sensor (Rajah 3(c)).

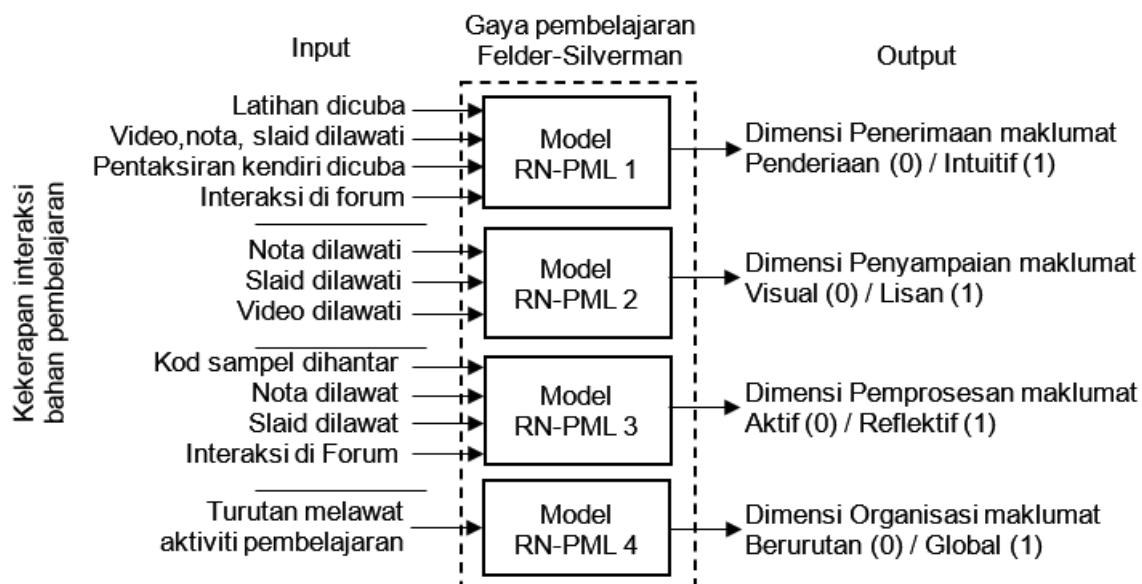


Rajah 3: Aktiviti-aktiviti kuliah dan pembelajaran berasaskan masalah.

Seramai 45 orang pelajar tahun 1 dari Jabatan Kejuruteraan Elektrik, Elektronik dan Sistem, Fakulti Kejuruteraan dan Alam Bina, Universiti Kebangsaan Malaysia telah dipilih mengikuti aktiviti-aktiviti ini. Terdapat 5 topik utama yang diajar kepada para pelajar. Setiap topik mempunyai 4 jenis bahan pembelajaran yang disediakan iaitu 1) bahan bacaan yang kandungan utamanya berbentuk penulisan, 2) slaid pembelajaran yang mengandungi kandungan visual dan penulisan secara seimbang, 3) video penerangan yang kandungan

utamanya berbentuk visual dan 4) latihan dan pentaksiran kendiri. Tingkah laku terhadap bahan pembelajaran ini telah direkodkan bagi setiap pelajar. Tingkah laku ini diukur melalui rekod kekerapan pelajar melawat atau menghantar tugas bagi setiap satu bahan pembelajaran. Tingkah laku ini digunakan sebagai pembolehubah bebas untuk membina model RN-PML. Jumlah keseluruhan sampel yang dapat dikumpul ialah sebanyak 90 sampel, iaitu rekod tingkah laku 45 orang pelajar terlibat bagi 2 sesi kuliah berdurasi 3 jam setiap satu. Sesi-sesi kuliah tersebut melibatkan aktiviti pembelajaran berdasarkan masalah bagi memberi kepelbagai dan fleksibiliti dalam kuliah berpusatkan pelajar.

Proses yang ketiga pula adalah melatih setiap satu model klasifikasi RN-PML yang dibina bagi setiap satu dimensi pembelajaran model Felder-Silverman menggunakan data rekod kekerapan interaksi yang telah dikumpul. Untuk nota, rekod kekerapan interaksi ini juga perlu dianotasi dengan gaya pembelajaran sebenar pelajar bagi membolehkan pembelajaran mesin secara terselia dijalankan. Hal ini diterangkan secara lebih mendalam dalam seksyen 3.0. Secara keseluruhannya, terdapat 4 set latihan dan 4 set ujian ketepatan model klasifikasi RN-PML yang perlu dijalankan. Model klasifikasi ini dilatih dan diuji menggunakan perisian MATLAB 2021. Rajah 4 menunjukkan konfigurasi keseluruhan sistem model klasifikasi RN-PML bagi keempat-empat dimensi gaya pembelajaran Felder-Silverman.



Rajah 4: Struktur model Rangkaian Neural bagi keempat-empat dimensi gaya pembelajaran Felder-Silverman.

Bilangan nod pada lapisan input bergantung kepada bilangan aktiviti pembelajaran. Bilangan nod tersembunyi pula diset kepada 10 nod bagi model RN1, RN2 dan RN3, manakala model RN4 disetkan pada 3 nod sahaja. Bilangan nod lapisan output pula hanya satu mewakili satu dimensi gaya pembelajaran yang diukur.

Keempat-empat model Rangkaian Neural dilatih dengan menggunakan kaedah pembelajaran mesin terselia. Konfigurasi latihan model telah diset seperti di dalam Jadual 2. Pertama sekali, data yang dikumpul dibahagikan secara rawak mengikut nisbah 80:20. Ia bermaksud 80% sampel data digunakan bagi tujuan fasa latihan model. Manakala, 20% sampel data lagi digunakan bagi tujuan menguji prestasi sebenar model yang telah dilatih. Pembahagian nisbah ini adalah mengikut prinsip aturan Pareto. Seterusnya, bilangan epoch maksima semasa fasa latihan ditetapkan sebanyak 1000 pusingan. Fungsi latihan berdasarkan perambatan balik kecerunan konjugat berskala digunakan untuk mengemaskini nilai-nilai pemberat dan nilai-nilai pincang yang terdapat di dalam model RN-PML. Ralat entropi silang digunakan sebagai penanda ukur rujukan bagi fungsi latihan menentukan kadar perubahan nilai-nilai tersebut perlu diubah. Akhir sekali, fasa latihan boleh dihentikan lebih awal apabila nilai kecerunan mencapai atau berada di bawah 1×10^{-6} .

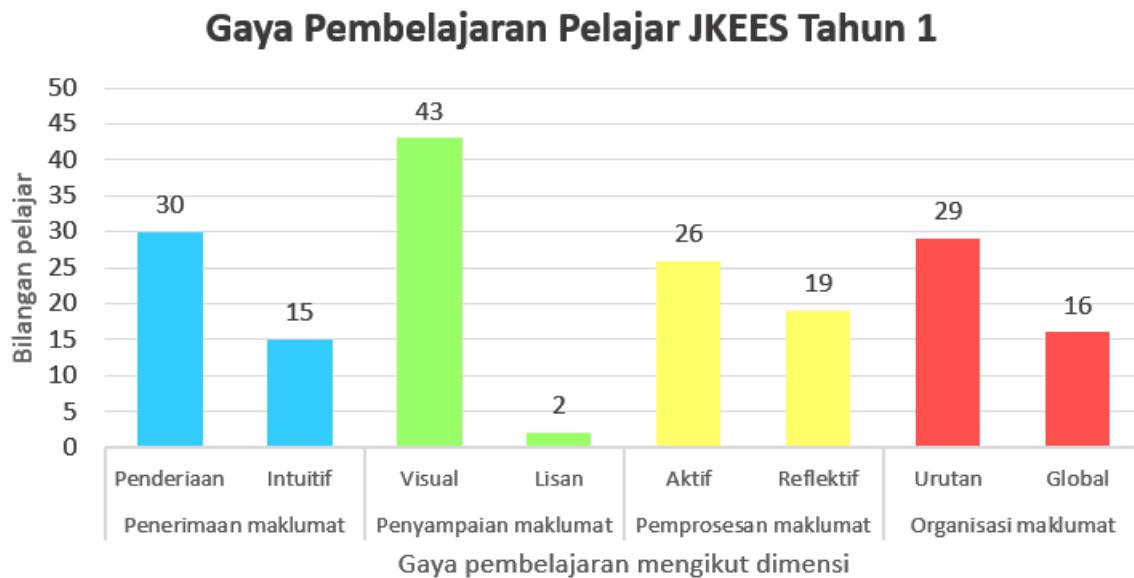
Jadual 2: Konfigurasi parameter latihan model Rangkaian Neural

Parameter	Nilai
Nisbah pemisahan data (latihan/ujian)	80:20
Bilangan epoch maksima	1000
Fungsi latihan	Perambatan balik kecerunan konjugat berskala
Ukuran prestasi	Ralat entropi silang
Kriteria henti epoch	Kecerunan maksima dicapai (1×10^{-6})

3.0 KEPUTUSAN DAN PERBINCANGAN

Seperti diterangkan sebelum ini, data yang direkod perlu dianotasi dengan gaya pembelajaran sebenar pelajar bagi membolehkan pembelajaran mesin secara terselia dijalankan. Oleh itu, satu sesi soal-selidik menggunakan instrumen ILS Felder-Silverman telah dijalankan bagi dijadikan sebagai data rujukan (*ground-truth*) dan untuk mengetahui gaya pembelajaran sebenar setiap pelajar terlibat mengikut dimensi-dimensi gaya pembelajaran Felder-Silverman. Sesi soal-selidik ini melibatkan kesemua 45 orang pelajar yang dinyatakan. Rajah

5 menunjukkan hasil soal-selidik yang dijalankan menggambarkan dimensi-dimensi gaya pembelajaran pelajar.



Rajah 5: Hasil soal-selidik ILS Felder-Silverman terhadap 45 orang pelajar tahun 1 Jabatan Kejuruteraan Elektrik, Elektronik dan Sistem (JKEES), Universiti Kebangsaan Malaysia sesi akademik 2021/22.

Seterusnya, data-data interaksi pelajar dengan bahan-bahan pembelajaran di dalam SPP UKMFolio direkodkan. Setiap sampel yang direkodkan kemudiannya dianotasi dengan gaya pembelajaran sebenar pelajar dari hasil soal-selidik tadi. Sebagai contoh, Rajah 6 menunjukkan anotasi bagi sampel dari 5 orang pelajar. Data kekerapan interaksi seseorang pelajar tersebut terhadap bahan pembelajaran seperti kod aturcara dihantar dan slaid kuliah dilihat, disusun secara lajur, manakala output sasaran sama ada aktif (0) atau reflektif (1) dianotasikan pada lajur yang terakhir dari kanan. Proses anotasi ini dilakukan berulang-ulang sehingga semua sampel dapat dianotasikan.

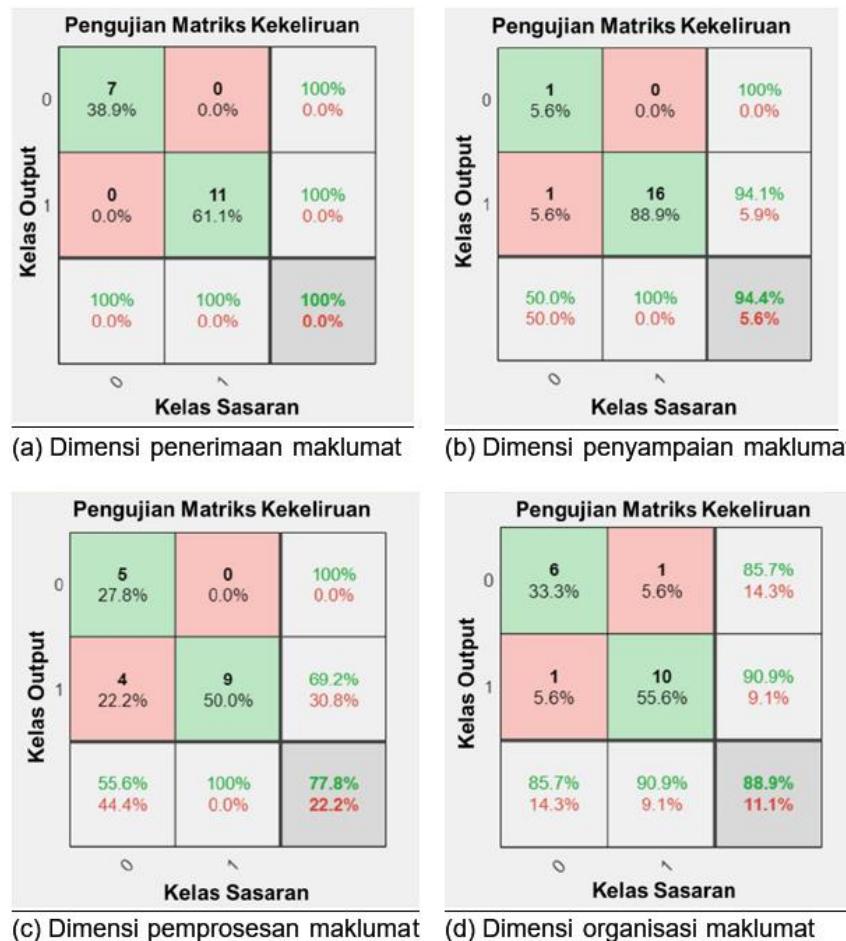
Bil.	No. Matrik	Dimensi Pemprosesan: Aktif/ Reflektif				Aktif (0) / Reflektif (1)
		Kod aturcara dihantar	Nota dilihat	Slaid dilihat	Interaksi forum	
1	A188 [REDACTED]	2	0	2	2	0
2	A190 [REDACTED]	2	0	2	3	0
3	A189 [REDACTED]	3	0	1	4	0
4	A189 [REDACTED]	1	1	2	1	1
5	A186 [REDACTED]	0	3	2	1	1

Rajah 6: Contoh sampel data yang telah dianotasi dengan sasaran output gaya pembelajaran berdasarkan hasil soal-selidik yang dijalankan kepada pelajar.

Sampel data yang telah dianotasi ini kemudiannya digunakan untuk melatih keempat-empat model Rangkaian Neural (RN-PML), masing-masing bagi dimensi penerimaan maklumat, penyampaian maklumat, pemprosesan maklumat dan organisasi maklumat model Felder-Silverman. Setelah keempat-empat model dilatih, prestasi model ini diukur melalui fasa ujian. Model-model ini diuji dengan data ujian yang telah dipisahkan daripada data latihan bagi memastikan ia bebas dari kepincangan pengukuran. Rajah 7 menunjukkan matriks kekeliruan yang menunjukkan ketepatan penentuan gaya pembelajaran bagi setiap dimensi yang ditetapkan.

Melalui keputusan ujian ini, adalah didapati dimensi penerimaan maklumat (penderiaan/intuitif) memberikan nilai prestasi ketepatan yang paling tinggi iaitu 100% tanpa sebarang kesalahan. Dimensi penyampaian maklumat (visual/lisan) pula memberikan nilai ketepatan 94.4%. Ini diikuti oleh dimensi organisasi maklumat (urutan/global) dengan ketepatan 88.9%. Manakala, dimensi yang memberikan nilai ketepatan paling rendah ialah dimensi pemprosesan maklumat (aktif/reflektif) iaitu pada 77.8%.

Prestasi ujian ketepatan yang diukur menunjukkan bahawa terdapat hubungkait di antara corak aktiviti-aktiviti pelajar menggunakan platform SPP dan gaya pembelajaran mereka berdasarkan model Felder-Silverman. Model Rangkaian Neural yang dibina bagi keempat-empat dimensi pembelajaran didapati dapat dilatih dengan baik menggunakan sampel data latihan dari aktiviti-aktiviti SPP. Hal ini dapat disahkan melalui pengujian menggunakan sampel data ujian yang diasangkan bagi memastikan tiada berlaku isu model berat sebelah (*bias*), terlebih-muat (*over-fitting*) atau kurang-muat (*under-fitting*).



Rajah 7: Matriks kekeliruan menunjukkan ketepatan penentuan gaya pembelajaran bagi setiap dimensi model Felder-Silverman. Nilai peratusan berwarna hijau mewakili nilai ketepatan, manakala nilai peratusan berwarna merah merupakan jumlah ralat.

4.0 KESIMPULAN

Model Rangkaian Neural bagi menentukan gaya pembelajaran pelajar berdasarkan dimensi pembelajaran Felder-Silverman telah dibangunkan. Hasil ujian model tersebut menunjukkan prestasi ketepatan klasifikasi pada tahap di antara 77.8% dan 100.0% bagi sampel yang diukur. Ini menunjukkan terdapatnya hubungkait di antara corak aktiviti-aktiviti pelajar di dalam sistem pengurusan pembelajaran digital (SPP) dan gaya pembelajaran mereka. Dengan adanya model ini, suatu sistem pintar boleh diadaptasi di dalam SPP bagi membolehkan penyampaian ilmu melalui penggunaan sistem digital menjadi lebih berkesan seiring dengan kehendak kurikulum tersedia masa hadapan.

5.0 PENGHARGAAN

Setinggi-tinggi penghargaan diberikan kepada Pengajaran UKM, Universiti Kebangsaan Malaysia yang menyokong kajian ini menerusi geran PDI-2021-013. Tidak lupa kepada Fakulti Kejuruteraan dan Alam Bina, Universiti Kebangsaan Malaysia khususnya Jabatan Kejuruteraan Elektrik, Elektronik dan Sistem, Pusat Penyelidikan Pendidikan Kejuruteraan (P3K) dan pasukan CRYsTaL@UKM di atas fasiliti dan sumber kerja yang diberikan.

6.0 RUJUKAN

- Alzahrani, N., Meccawy, M. & Siddiqui, M. A. A. A. (2020). Automatic prediction of learning styles in learning management systems: A literature review. *Proceedings of the 2020 IEEE Asia-Pacific Conference on Computer Science and Data Engineering*, 1-7.
- Da-Costa, R.D., de-Souza, G.F., de-Castro, T.B., de- Medeiros-Valentim, R.A. & de-Pinho-Dias, A. (2020). Identification of Learning Styles in Distance Education Through the Interaction of the Student with a Learning Management System. *Proceedings of IEEE Revista Iberoamericana de Tecnologias del Aprendizaje*, 148-160.
- Felder, R.M. & Silverman, L.K. (1988). *Learning and Teaching Styles in Engineering Education. Engr. Education*, 78(7).
- Ferreira, L.D., Spadon, G., Carvalho, A.C. & Rodrigues, J.F. (2018). A comparative analysis of the automatic modeling of Learning Styles through Machine Learning techniques. *Proceedings of the 2018 IEEE Frontiers in Education Conference (FIE)*, 1-8.
- Gambo, F.L., Wajiga, G.M., Shuib, L., Garba, E.J. Abdullahi, A.A. & Bisandu, D.B. (2022). Performance Comparison of Convolutional and Multiclass Neural Network for Learning Style Detection from Facial Images. *EAI Endorsed Transactions on Scalable Information Systems*, 9(35).
- Ghosh, A., Sufian, A., Sultana, F., Chakrabarti, A. & De, D. (2020). Fundamental Concepts of Convolutional Neural Network. *Recent Trends and Advances in Artificial Intelligence and Internet of Things*, 172, 519-567.
- Gomedé, E., Miranda-de-Barros, R., & de-Souza-Mendes, L. (2020). Use of Deep Multi-Target

Prediction to Identify Learning Styles. *Appl. Sci.*, 10(5).

Ikawati, Y., Al Rasyid, M.U.H. & Winarno, I. (2020). Student Behavior Analysis to Detect Learning Styles in Moodle Learning Management System. *Proceedings of International Electronics Symposium: The Role of Autonomous and Intelligent Systems for Human Life and Comfort*, 501–506.

Jamali, A.R. & Mohamad, M.M. 2018. Dimensions of Learning Styles among Engineering Students. *J. Phys.: Conf. Ser.*, 1049.

Khan, F.A., Akbar, A., Altaf, M., Tanoli, S.A.K. & Ahmad, A. (2019). Automatic Student Modelling for Detection of Learning Styles and Affective States in Web Based Learning Management Systems. *IEEE Access*, 7, 128242-128262.

Lwande, C., Muchemi, L. & Oboko, R. (2021). Identifying learning styles and cognitive traits in a learning management system. *Helijon*, 7(8).

Shrivastava, A.K., Das, D., Mahapatra, R. & Varshney, N. (2021). Scaled Conjugate Gradient Algorithm for Neural Network Detector in Mobile Molecular Communication. *Proceedings of the 2021 IEEE Global Communications Conference*.