
การเรียนรู้เพียงครั้งเดียวแบบเพิ่มเติมได้สำหรับปัญหาการแบ่งกลุ่มข้อมูลโดยใช้โครงข่ายประสาทเทียม
และฟังก์ชันไฮเพอร์อัลลิพซอยด์

One-Pass Incremental Learning for Classification Problem Using Neural Network
and Hyper-Ellipsoidal Function

สายชล ใจเย็น ชิดชนก เหลือสินทรัพย์* และศุภกานต์ พิมลธเรศ
ศูนย์วิจัย AVIC ภาควิชาคณิตศาสตร์ คณะวิทยาศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย
Saichon Jaiyen, Chidchanok Lursinsap* and Suphakant Phimoltares

Research Center of AVIC, Department of Mathematics, Faculty of Science, Chulalongkorn University

บทคัดย่อ

บทความนี้นำเสนอโครงข่ายประสาทเทียมชนิดใหม่แบบเรียนรู้ข้อมูลใหม่เพียงครั้งเดียวแล้วทิ้งข้อมูลนั้นโดยไม่ต้องใช้ข้อมูลเก่าที่เรียนรู้ไปแล้วด้วยการใช้ฟังก์ชันไฮเพอร์อัลลิพซอยด์ ฟังก์ชันชนิดนี้มีรูปทรงเป็นทรงรีและสามารถเรียนรู้ข้อมูลในหลายมิติได้โดยการล้อมข้อมูลที่เข้ามา ข้อมูลที่ใช้ในการปรับค่าตัวแปรต่างๆ ของฟังก์ชันชนิดนี้จะใช้เพียงข้อมูลที่เข้ามาใหม่เพียงข้อมูลเดียว โครงข่ายประสาทเทียมชนิดนี้สามารถเรียนรู้ข้อมูลที่ใช้สำหรับเรียนรู้โดยใช้เวลา $O(n)$ เมื่อ n คือจำนวนข้อมูลสำหรับเรียนรู้

คำสำคัญ : การแบ่งกลุ่มข้อมูล การเรียนรู้อย่างรวดเร็ว การวิเคราะห์ส่วนประกอบ ฟังก์ชันไฮเพอร์อัลลิพซอยด์

Abstract

This paper introduces a new neural network which can learn each new data only in one epoch and, then, throw it away without involving the previously learned data by using a hyper-ellipsoidal function. This function has an elliptical shape and can learn any multi-dimensional data by surrounding them. Only one new incoming data is used to adjust the learning parameters. This neural network spends $O(n)$ time complexity to learn a set of n data.

Keywords : classification, fast learning, principal component

*Corresponding author. E-mail: Ichidcha@gmail.com

โครงข่ายประสาทเทียมชนิด Radial Basis function (RBF) เป็นโครงข่ายประสาทเทียมที่นิยมใช้กันมากในการประมาณฟังก์ชันเนื่องจากสามารถประมาณฟังก์ชันได้โดยตรงจากอินพุต (input) และเอาต์พุต (output) โดยใช้โครงสร้างของโครงข่ายประสาทเทียมแบบง่ายและไม่ซับซ้อน แต่โครงข่ายประสาทเทียมชนิดนี้มีข้อเสียคือ จำนวนของเซลล์ประสาทเทียมจะถูกกำหนดแน่นอนก่อนที่จะเรียนรู้ข้อมูลที่ใช้สำหรับให้โครงข่ายประสาทเทียมเรียนรู้ นอกจากนี้เรายังไม่สามารถรู้ล่วงหน้าได้ว่าต้องใช้จำนวนของเซลล์ประสาทเทียมเท่าไรถึงจะเหมาะสมกับข้อมูลที่โครงข่ายประสาทเทียมจะต้องเรียนรู้ จึงทำให้โครงข่ายประสาทเทียมชนิดนี้ไม่ยืดหยุ่นต่อการใช้งานจริง Platt (1991) เสนออัลกอริทึมที่เรียนรู้แบบลำดับ (sequential learning) สำหรับโครงข่ายประสาทเทียมชนิด Radial Basis function ที่สามารถเรียนรู้ข้อมูลที่ละตัวโดยที่ในตอนเริ่มต้นจะยังไม่มีการเพิ่มเซลล์ประสาทเทียมอยู่ในโครงข่ายเลยแต่จำนวนของเซลล์ประสาทเทียมจะค่อยๆ เพิ่มขึ้นระหว่างการเรียนรู้โครงข่ายประสาทเทียมนี้รู้จักในชื่อ resource allocation network (RAN) แต่เนื่องจากโครงข่ายประสาทเทียมชนิดนี้ใช้อัลกอริทึม least-mean square (LMS) ในการปรับค่าน้ำหนัก (weight) ของโครงข่ายประสาทเทียมทำให้ใช้เวลาในการเรียนรู้มาก ต่อมา Kadirkamanathan และ Niranjan (1993) ได้ปรับปรุงวิธีการของ RAN โดยใช้วิธี extended Kalman filter (EKF) ในการปรับค่าน้ำหนักของโครงข่ายประสาทเทียมแทนวิธี LMS ซึ่งรู้จักในชื่อ RAN extended Kalman filter (RANEKF) อย่างไรก็ตามโครงข่ายประสาทเทียมทั้งสองชนิดนี้ก็มีข้อเสียคือจำนวนของเซลล์ประสาทเทียมจะเพิ่มขึ้นได้อย่างเดียวแต่ไม่มีวิธีการที่จะลดจำนวนของเซลล์ประสาทเทียมที่ไม่จำเป็นออกจากโครงข่ายประสาทเทียมต่อมา Yingwei *et al.* (1997) ได้ปรับปรุงวิธีการของ RANEKF โดยการเพิ่มวิธีการที่จะลบเซลล์ประสาทเทียมที่ไม่จำเป็นออกไปซึ่งรู้จักในชื่อ minimal resource allocating network (MRAN) ต่อมา Li Yan *et al.* (2000) ได้ปรับปรุงวิธีการของ (MRAN) ซึ่งรู้จักกันในชื่อ Extended-MRAN (EMRAN) แต่อย่างไรก็ตามเมื่อสิ้นสุดกระบวนการเรียนรู้และโครงข่ายประสาทเทียมได้ถูกนำไปใช้งานแล้ว แต่ต่อมาในภายหลังเรามีข้อมูลชุดใหม่ที่ต้องการให้โครงข่ายประสาทเทียมเหล่านี้เรียนรู้โครงข่ายประสาทเทียมเหล่านี้จะไม่สามารถที่จะเรียนรู้ข้อมูลชุดใหม่นี้ได้โดยปราศจากข้อมูลชุดเดิม ทำให้โครงข่ายประสาทเทียมเหล่านี้ไม่มีความสามารถเรียนรู้ความรู้ใหม่ได้

โครงข่ายประสาทเทียมชนิดฟังก์ชันไฮเพอร์อัลลิบซอยด์

การเรียนรู้ความรู้ใหม่โดยปราศจากความรู้เก่าเป็นปัญหาที่สำคัญมากในงานวิจัยทางด้านโครงข่ายประสาทเทียมซึ่งจะทำให้การเรียนรู้ของโครงข่ายประสาทเทียมใกล้เคียงกับความสามารถของมนุษย์มากขึ้น ในบทความนี้จึงนำเสนอโครงข่ายประสาทเทียมชนิดใหม่ที่ใช้ฟังก์ชันไฮเพอร์อัลลิบซอยด์ที่สามารถปรับเปลี่ยนตำแหน่ง ขนาด และทิศทางตามการกระจายตัวของข้อมูล โครงสร้างของโครงข่ายชนิดนี้ประกอบด้วยชั้นของเซลล์ประสาทเทียมจำนวนสามเลเยอร์ด้วยกันคือ อินพุตเลเยอร์ (input layer) ฮิดเดนเลเยอร์ (hidden layer) และเอาต์พุตเลเยอร์ (output layer) ในฮิดเดนเลเยอร์จะถูกแบ่งออกเป็นส่วนย่อยๆ ตามจำนวนของกลุ่มข้อมูลซึ่งจะเรียกว่า ฮิดเดนเลเยอร์ย่อย (subhidden layer) ในตอนเริ่มต้นของการเรียนรู้โครงข่ายประสาทเทียมชนิดนี้จะไม่มีการเพิ่มเซลล์ประสาทเทียมอยู่ในโครงข่ายแต่จำนวนของเซลล์ประสาทเทียมจะค่อยๆ เพิ่มขึ้นเรื่อยๆ ในระหว่างการเรียนรู้ ถ้ากำหนดให้เวกเตอร์ $\mathbf{x} = [x_1, x_2, \dots, x_n]^T$ เป็นเวกเตอร์ใน \mathcal{R}^n เอาต์พุตของเซลล์ประสาทเทียมที่ k ในฮิดเดนเลเยอร์ คือ $\varphi_k(\mathbf{x})$ สามารถคำนวณได้ดังสมการต่อไปนี้

$$\varphi_k(\mathbf{x}) = \sum_{i=1}^n \frac{((\mathbf{x}-\mathbf{c}_k)^T \mathbf{u}_i)^2}{a_i^2} - 1,$$

โดยที่ \mathbf{u}_i เป็นเวกเตอร์หนึ่งหน่วยตามแนวแกนในแต่ละแกนของฟังก์ชันไฮเพอร์อัลลิบซอยด์ a_i เป็นความกว้างในแต่ละแกนของฟังก์ชันไฮเพอร์อัลลิบซอยด์ และ \mathbf{c}_k เป็นจุดศูนย์กลางของฟังก์ชันไฮเพอร์อัลลิบซอยด์ เอาต์พุต (output) ของเซลล์ประสาทเทียมที่ p ในเอาต์พุตเลเยอร์คือ $y_p(\mathbf{x})$ สามารถคำนวณได้โดยใช้สมการดังต่อไปนี้

$$y_p(\mathbf{x}) = \min_j (\varphi_j(\mathbf{x}))$$

โดยที่ $\varphi_j(\mathbf{x})$ เป็นเอาต์พุตของเซลล์ประสาทเทียมที่ j ในฮิดเดนเลเยอร์ เนื่องจากจำนวนของเอาต์พุตในเอาต์พุตเลเยอร์มีจำนวนเท่ากับจำนวนของฮิดเดนเลเยอร์ย่อย เพราะฉะนั้นเราจำเป็นต้องมีฟังก์ชันที่ใช้ในการตัดสินใจว่าจะให้อินพุตที่เข้ามาอยู่ในกลุ่มไหน ซึ่งเราจะนิยามฟังก์ชันการตัดสินใจ $D(\mathbf{x})$ ดังต่อไปนี้

$$D(\mathbf{x}) = \begin{cases} k, & \text{if } k = \arg \min(y_i(\mathbf{x})) \text{ and } y_k(\mathbf{x}) \leq 0 \\ \text{unknown}, & \text{otherwise} \end{cases}$$

ถ้าเรามีข้อมูลชุดใหม่เข้ามาสมมติว่าเป็นเวกเตอร์ x เวกเตอร์นี้จะถูกจัดอยู่ในกลุ่ม k หรือไม่ก็อยู่ในกลุ่ม $unknown$ การคำนวณเวกเตอร์ค่าเฉลี่ย และโคเวเรียนเมทริกซ์ แบบรีเคอร์ซีฟ

ในการหาจุดศูนย์กลางของฟังก์ชันไฮเพอร์อัลลิบซอยด์นั้นเราจะใช้ค่าเฉลี่ยในการคำนวณหาจุดศูนย์กลางของฟังก์ชันไฮเพอร์อัลลิบซอยด์ แต่เนื่องจากการคำนวณค่าเฉลี่ยโดยใช้สูตรคำนวณแบบเดิมเราต้องใช้ข้อมูลทั้งหมดในการคำนวณ ซึ่งไม่เหมาะกับการเรียนรู้แบบเพิ่มเติมได้ ดังนั้นเราจึงนำสูตรคำนวณหาค่าเฉลี่ยแบบเดิมมาเขียนใหม่ในรูปของรีเคอร์ซีฟระหว่างค่าเฉลี่ยใหม่และค่าเฉลี่ย เก่าดังทฤษฎีบทต่อไปนี้

ทฤษฎีบทที่ 1

กำหนดให้ $X = \{x_1, x_2, \dots, x_N\}$ เป็นเซตของข้อมูล โดยที่ x_i เป็นเวกเตอร์ใน \mathbb{R}^n และ กำหนดให้ μ_{old} เป็นเวกเตอร์ค่าเฉลี่ยของเซตนี้ ถ้า x_{N+1} เป็นข้อมูลตัวใหม่ที่ถูกเพิ่มเข้าไปในเซตนี้ จะได้ว่า

$$\mu_{new} = \alpha\mu_{old} + \beta$$

โดยที่ μ_{new} เป็น เวกเตอร์ค่าเฉลี่ยใหม่ $\alpha = \frac{N}{N+1}$ และ

$\beta = \frac{x_{N+1}}{N+1}$ ในการคำนวณหาค่าของเวกเตอร์หนึ่งหน่วยตาม

แกนของฟังก์ชันไฮเพอร์อัลลิบซอยด์เราจะคำนวณจากโคเวเรียนเมทริกซ์ แต่วิธีการหาค่าโคเวเรียนเมทริกซ์แบบเดิมจะต้องใช้ข้อมูลทั้งหมดในการคำนวณซึ่งจะไม่เหมาะสมกับการเรียนรู้แบบเพิ่มเติมได้ ดังนั้นเราจึงควรเขียนเมทริกซ์ใหม่ในรูปแบบของรีเคอร์ซีฟดังแสดงในทฤษฎีบทที่ 2

ทฤษฎีบทที่ 2

กำหนดให้ $X = \{x_1, x_2, \dots, x_N\}$ เป็นเซตของข้อมูล โดยที่ x_i เป็นเวกเตอร์ใน \mathbb{R}^n และ กำหนดให้ S_{old} เป็นโคเวเรียนเมทริกซ์ ของเซตนี้ ถ้า x_{N+1} เป็นข้อมูลตัวใหม่ที่ถูกเพิ่มเข้าไปในเซตนี้ จะได้ว่า

$$S_{new} = \alpha S_{old} + \kappa$$

โดยที่ $\alpha = \frac{N}{N+1}$,

$$\kappa = \kappa_1 + \kappa_2,$$

$$\kappa_1 = \frac{x_{N+1} x_{N+1}^T}{N+1} - \mu_{new} \mu_{new}^T + \mu_{old} \mu_{old}^T,$$

$$\kappa_2 = -\frac{\mu_{old} \mu_{old}^T}{N+1},$$

μ_{new} เป็นเวกเตอร์ค่าเฉลี่ยใหม่

และ S_{new} เป็นโคเวเรียนเมทริกซ์ ใหม่

อัลกอริทึมการเรียนรู้สำหรับโครงข่ายประสาทเทียมชนิดฟังก์ชันไฮเพอร์อัลลิบซอยด์

การเรียนรู้สำหรับโครงข่ายประสาทเทียมชนิดฟังก์ชันไฮเพอร์อัลลิบซอยด์นี้จะเกี่ยวข้องกับการปรับค่าพารามิเตอร์ต่างๆของฟังก์ชันไฮเพอร์อัลลิบซอยด์ซึ่งได้แก่ จุดศูนย์กลางของฟังก์ชันไฮเพอร์อัลลิบซอยด์ เวกเตอร์หนึ่งหน่วยตามแกนของ ฟังก์ชันไฮเพอร์อัลลิบซอยด์ ความกว้างในแต่ละแกนของฟังก์ชันไฮเพอร์อัลลิบซอยด์ กำหนดให้ $\Omega = \{\Omega_k \mid 1 \leq k \leq K\}$ เป็นเซตของเซลล์ประสาทเทียม K ตัว กำหนดให้ $\Omega_k = (C^k, S^k, N_k, A_k, d_k)$ เป็นเซลล์ประสาทเทียมที่ k โดยที่ C^k เป็นจุดศูนย์กลางของเซลล์ประสาทเทียมที่ k , S^k เป็นโคเวเรียนเมทริกซ์ ของเซลล์ประสาทเทียมที่ k , N_k เป็นจำนวนของข้อมูลของเซลล์ประสาทเทียมที่ k , $A_k = [a_1^k, a_2^k, \dots, a_n^k]^T$ เป็นความกว้างของเซลล์ประสาทเทียมที่ k , และ D_k เป็นชื่อคลาสของเซลล์ประสาทเทียมที่ k เรากำหนดให้ N_0 เป็นค่าคงที่ที่ใช้สำหรับปรับค่าความกว้าง A_k

1 การสร้างเซลล์ประสาทเทียมใหม่

ในตอนเริ่มต้นของการเรียนรู้ จะไม่มีเซลล์ประสาทเทียมอยู่ในโครงข่ายประสาทเทียมเลย แต่จำนวนเซลล์ประสาทเทียมจะเพิ่มขึ้นในระหว่างการเรียนรู้ข้อมูลใหม่ๆ สมมติให้ x_j เป็นอินพุตของโครงข่ายประสาทเทียม และ t_j เป็นชื่อคลาสของ x_j ในขณะที่โครงข่ายประสาทเทียมเรียนรู้อินพุต x_j ก็จะค้นหาเซลล์ประสาทเทียมที่อยู่ใกล้กับอินพุต x_j มากที่สุด ถ้าหาเซลล์ประสาทเทียมดังกล่าวได้ ค่าพารามิเตอร์ของฟังก์ชันไฮเพอร์อัลลิบซอยด์ของเซลล์ที่ได้จะถูกปรับแบบชั่วคราวดังนี้

(1) คำนวณค่า C_{new}^{cs} จากทฤษฎีบทที่ 1

(2) คำนวณค่า S_{new}^{cs} จากทฤษฎีบทที่ 2

(3) คำนวณค่า eigenvalue ของ S_{new}^{cs}

$$\lambda_1 > \lambda_2 > \dots > \lambda_n$$

(4) คำนวณค่า eigenvector ของ S_{new}^{cs}

$$u_1^{cs}, u_2^{cs}, \dots, u_n^{cs}$$

กำหนดให้ u_i^{cs} เป็นเวกเตอร์หนึ่งหน่วยตามแนวแกน i ของฟังก์ชันไฮเพอร์อัลลิบซอยด์ การที่จะทดสอบว่าเซลล์ประสาทเทียมนี้สามารถคลุ้มข้อมูลใหม่ได้หรือไม่ เราจะทำทดสอบโดยใช้สมการดังต่อไปนี้

$$\varphi_{cs}(x_j) = \sum_{i=1}^n \frac{((x_j - C_{new}^{cs})^T u_i^{cs})^2}{(a_i^{cs})^2} - 1$$

เมื่อ c_s คืออินเด็กซ์ของเซลล์ประสาทเทียมที่อยู่ใกล้กับอินพุตมากที่สุดและ n คือจำนวนมิติของอินพุต ถ้าค่าของ $\varphi_{cs}(x_j) > 0$ แสดงว่าเซลล์ประสาทเทียมนี้ไม่สามารถคลุมอินพุตนี้ได้ ดังนั้นเซลล์ประสาทตัวใหม่จะถูกสร้างขึ้นและถูกเพิ่มเข้าไปในโครงข่ายประสาทเทียมและค่าพารามิเตอร์ของเซลล์ประสาทเทียมใหม่จะถูกกำหนดค่าเริ่มต้นใหม่ดังนี้

$$\begin{aligned} C^{K+1} &= x_i \\ S^{K+1} &= 0 \text{ (zero matrix)} \\ N_{K+1} &= 1 \\ d_{K+1} &= t_j \\ A_{K+1} &= A_0 \end{aligned}$$

เมื่อ A_0 คือพารามิเตอร์ความกว้างเริ่มต้นของเซลล์ประสาทเทียม

2 และการปรับค่าพารามิเตอร์ของเซลล์ประสาทเทียม

ถ้าค่าของ $\varphi_{cs}(x_i) \leq 0$ แสดงว่าเซลล์ประสาทเทียมนี้สามารถคลุมข้อมูลตัวนี้ได้ ดังนั้นค่าพารามิเตอร์ของเซลล์ประสาทเทียมนี้จะถูกปรับตามค่าพารามิเตอร์ชั่วคราวของฟังก์ชันไฮเพอร์อัลลิปซอยด์ดังต่อไปนี้

$$\begin{aligned} C^k &= C_{new}^{cs} \\ S^k &= S_{new}^{cs} \\ N_k &= N_k + 1 \end{aligned}$$

ถ้า $N_k > N_0$ แล้ว $a_i^k = a_i^k + |(C_{new}^k - C_{old}^k)^T u_i|$

3 วิธีการลบเซลล์ประสาทเทียมที่ไม่จำเป็นออกจากโครงข่ายประสาทเทียม

เนื่องจากจำนวนเซลล์ประสาทเทียมจะเพิ่มขึ้นในระหว่างการเรียนรู้ ดังนั้นอาจมีเซลล์ประสาทเทียมบางตัวที่ไม่มีความจำเป็นต้องใช้ เราจึงควรมีวิธีการที่จะกำจัดเซลล์ที่ไม่มีความจำเป็นเหล่านี้ในโครงข่ายประสาทเทียม กำหนดให้

$$\begin{aligned} \Omega_x &= (C^x, S^x, N_x, A_x, d_x) \text{ และ} \\ \Omega_y &= (C^y, S^y, N_y, A_y, d_y) \end{aligned}$$

เป็นเซลล์ประสาทเทียมสองตัวใดๆ ในโครงข่ายประสาทเทียม ถ้าเรารวมสองเซลล์ประสาทเทียมนี้เข้าด้วยกันกลายเป็นเซลล์ประสาทเทียมตัวใหม่คือ

$$\Omega_{new} = (C^{new}, S^{new}, N_{new}, A_{new}, d_{new})$$

ค่าพารามิเตอร์ของเซลล์ประสาทเทียมตัวใหม่สามารถคำนวณได้ดังสมการต่อไปนี้

$$\begin{aligned} C^{new} &= \frac{1}{N_x + N_y} (N_x C^x + N_y C^y) \\ S^{new} &= \frac{N_x}{N_x + N_y} S^x + \frac{N_y}{N_x + N_y} S^y \\ &\quad - \frac{N_x N_y}{(N_x + N_y)^2} (C^x - C^y)(C^x - C^y)^T \\ N_{new} &= N_x + N_y \\ a_j^{new} &= \sqrt{2\pi |\lambda_j|} + \delta, j = 1, 2, \dots, n \\ d_{new} &= d_x \end{aligned}$$

ผลการทดลอง

เราจะทดสอบประสิทธิภาพของโครงข่ายประสาทเทียมชนิดฟังก์ชันไฮเพอร์อัลลิปซอยด์ (VEBF) เทียบกับโครงข่ายประสาทเทียมที่นิยมใช้กันในปัจจุบันซึ่งได้แก่ โครงข่ายประสาทเทียม Radial Basis function (RBF) และ โครงข่ายประสาทเทียม Multilayer Perceptron (MLP) เราจะใช้ข้อมูลมาตรฐานที่นิยมใช้กันมากในการทดสอบโมเดลของโครงข่ายประสาทเทียม โดยชุดข้อมูลดังกล่าวเราเลือกมาจากฐานข้อมูล UCI [6] เป็นชุดข้อมูลที่ใช้ในการเรียนรู้ของโครงข่ายประสาทเทียมและใช้ทดสอบโครงข่ายประสาทเทียม และเราใช้วิธี 5-fold cross-validation สำหรับทุกโมเดล โดยวิธีการนี้จะแบ่งข้อมูลออกเป็น 5 ส่วนโดยข้อมูลในแต่ละส่วนจะไม่ซ้ำกัน ซึ่งเราจะใช้ 4 ส่วนสำหรับให้โครงข่ายประสาทเทียมเรียนรู้ และอีก 1 ส่วนสำหรับทดสอบโมเดลและทำซ้ำจนครบ 5 ครั้ง แล้วผลลัพธ์จะถูกนำมาเฉลี่ย สำหรับค่าความกว้างเริ่มต้นของ RBF และ VEBF เราจะคำนวณโดยใช้สมการดังนี้

$$a_k = \delta * d_{av}$$

โดยที่ δ เป็นค่าคงที่ และ $d_{av} = \frac{1}{N^2} \sum_{i=1}^N \sum_{j=1}^N d_{ij}$ และ d_{ij} เป็น

Euclidean distance ระหว่างข้อมูลตัวที่ i และตัวที่ j

Iris Data Set

Iris Data Set มีข้อมูลทั้งหมด 150 ตัว โดยที่ข้อมูลแต่ละตัวประกอบด้วยแอตทริบิวต์ทั้งหมด 4 แอตทริบิวต์และมีทั้งหมด 3 คลาสด้วยกัน ในการทดลองนี้เรากำหนดค่า $\delta = 1/3$ สำหรับ VEBF และ $\delta = 10$ สำหรับ RBF สำหรับ MLP เราจะรันโมเดลนี้จำนวน 10 ครั้งโดยเราจะเลือกครั้งที่ดีที่สุดของโมเดลนี้เป็นผลการทดลอง ในการทดลองนี้ VEBF เรียนรู้ข้อมูลเพียงรอบเดียวในขณะที่ RBF และ MLP เรียนรู้ข้อมูลหลายรอบ

ตารางที่ 1 ผลการทดลองจากการทดสอบด้วย Iris Data Set

Testing fold	VEBF			RBF			MLP		
	Time (second)	No. of neurons	Accuracy (%)	Time (second)	No. of neurons	Accuracy (%)	Time (second)	No. of neurons	Accuracy (%)
1	0.08	3	96.67	1.18	3	96.67	1.11	3	96.67
2	0.03	3	100.00	0.43	3	100.00	0.13	3	96.67
3	0.03	3	96.67	0.43	3	100.00	0.10	3	100.00
4	0.03	3	100.00	0.44	3	96.67	0.10	3	96.67
5	0.03	3	96.67	0.43	3	96.67	0.10	3	96.67
Average	0.04	3	98.00	0.58	3	98.00	0.31	3	97.33

ผลการเปรียบเทียบดังแสดงในตารางที่ 1 จากตารางนี้เราจะเห็นว่า ค่าเฉลี่ยของความถูกต้อง (accuracy) ของ VEBF จะเท่ากับ MLP แต่สูงกว่า RBF แต่เวลาที่ใช้ในการเรียนรู้ของ VEBF จะใช้เวลา น้อยกว่า RBF และ MLP

Balance Scale Data Set

Balance Scale Data Set มีข้อมูลทั้งหมด 625 ตัว โดยที่ ข้อมูลแต่ละตัวประกอบด้วยแอดทริบิวต์ทั้งหมด 4 แอดทริบิวต์ และมีทั้งหมด 3 คลาสด้วยกัน ในการทดลองนี้เรากำหนดค่า $\delta = 0.05$ สำหรับ VEBF และ $\delta = 1$ สำหรับ RBF สำหรับ MLP เรา จะรันโมเดลนี้จำนวน 10 ครั้งโดยเราจะเลือกครั้งที่ดีที่สุดของ โมเดลนี้เป็นผลการทดลอง ในการทดลองนี้ VEBF เรียนรู้ข้อมูล เพียงรอบเดียวในขณะที่ RBF และ MLP เรียนรู้ข้อมูลหลายรอบ ผลการเปรียบเทียบดังแสดงในตารางที่ 2 จากตารางนี้เราจะเห็นว่า ค่าเฉลี่ยของความถูกต้อง (accuracy) ของ VEBF สูงกว่า RBF

และ MLP นอกจากนี้เวลาที่ใช้ในการเรียนรู้ของ VEBF จะใช้เวลาน้อยกว่า RBF และ MLP

Parkinson Data Set

Parkinson Data Set มีข้อมูลทั้งหมด 197 ตัว โดยที่ ข้อมูลแต่ละตัวประกอบด้วยแอดทริบิวต์ทั้งหมด 23 แอดทริบิวต์ และมีทั้งหมด 2 คลาสด้วยกัน ในการทดลองนี้เรากำหนดค่า $\delta = 0.05$ สำหรับ VEBF และ $\delta = 1$ สำหรับ RBF สำหรับ MLP เราจะรันโมเดลนี้จำนวน 10 ครั้งโดยเราจะเลือกครั้งที่ดีที่สุดของโมเดลนี้เป็นผลการทดลอง ในการทดลองนี้ VEBF เรียนรู้ ข้อมูลเพียงรอบเดียวในขณะที่ RBF และ MLP เรียนรู้ข้อมูล หลายรอบ ผลการเปรียบเทียบดังแสดงในตารางที่ 3 จากตารางนี้ เราจะเห็นว่า ค่าเฉลี่ยของความถูกต้อง (accuracy) ของ VEBF สูงกว่า RBF และ MLP นอกจากนี้เวลาที่ใช้ในการเรียนรู้ของ VEBF จะใช้เวลา น้อย MLP แต่มากกว่า RBF เพียงเล็กน้อย

ตารางที่ 2 ผลการทดลองจากการทดสอบด้วย Balance Scale Data Set

Testing fold	VEBF			RBF			MLP		
	Time (second)	No. of neurons	Accuracy (%)	Time (second)	No. of neurons	Accuracy (%)	Time (second)	No. of neurons	Accuracy (%)
1	0.24	4	91.27	1.16	4	84.13	1.58	4	84.92
2	0.15	3	91.94	0.38	3	78.23	0.66	3	88.71
3	0.16	5	86.51	0.41	5	82.54	0.65	5	84.92
4	0.15	3	95.12	0.38	3	79.67	0.83	3	91.06
5	0.16	5	89.68	0.41	5	84.92	0.88	5	89.68
Average	0.17	4	90.90	0.55	4	81.90	0.92	4	87.86

ตารางที่ 3 ผลการทดลองจากการทดสอบด้วย Parkinson Data Set

Testing fold	VEBF			RBF			MLP		
	Time (second)	No. of neurons	Accuracy (%)	Time (second)	No. of neurons	Accuracy (%)	Time (second)	No. of neurons	Accuracy (%)
1	2.12	82	92.11	1.60	82	76.32	52.30	82	94.74
2	1.74	82	87.18	0.79	82	66.67	48.24	82	76.92
3	1.76	92	85.00	0.94	92	75.00	65.43	92	82.50
4	1.74	90	92.50	0.90	90	77.50	65.41	90	77.50
5	1.74	87	84.21	0.86	87	68.42	76.54	87	81.58
Average	1.82	86.6	88.20	1.02	86.6	72.78	61.58	86.6	82.65

ตารางที่ 4 ผลการทดลองจากการทดสอบด้วย Zoo Data Set

Testing fold	VEBF			RBF			MLP		
	Time (second)	No. of neurons	Accuracy (%)	Time (second)	No. of neurons	Accuracy (%)	Time (second)	No. of neurons	Accuracy (%)
1	0.10	11	100.00	0.82	11	78.95	1.29	11	94.74
2	0.05	11	100.00	0.13	11	75.00	0.48	11	60.00
3	0.04	11	95.24	0.09	11	80.95	0.51	11	85.71
4	0.04	10	100.00	0.19	10	75.00	0.41	10	80.00
5	0.05	11	95.24	0.21	11	90.48	0.46	11	95.24
Average	0.05	10.8	98.10	0.29	10.8	80.08	0.63	10.8	83.14

Zoo Data Set

Zoo Data Set มีข้อมูลทั้งหมด 101 ตัว โดยที่ข้อมูลแต่ละตัวประกอบด้วยแอดทริบิวต์ทั้งหมด 17 แอดทริบิวต์และมีทั้งหมด 7 คลาสด้วยกัน ในการทดลองนี้เรากำหนดค่า $\delta = 0.5$ สำหรับ VEBF และ $\delta = 10$ สำหรับ RBF สำหรับ MLP เราจะรันโมเดลนี้จำนวน 10 ครั้งโดยเราจะเลือกครั้งที่ดีที่สุดของโมเดลนี้เป็นผลการทดลอง ในการทดลองนี้ VEBF เรียนรู้ข้อมูลเพียงรอบเดียวในขณะที่ RBF และ MLP เรียนรู้ข้อมูลหลายรอบ ผลการเปรียบเทียบดังแสดงในตารางที่ 4 จากตารางนี้เราจะเห็นว่า ค่าเฉลี่ยของความถูกต้อง (accuracy) ของ VEBF สูงกว่า RBF และ MLP นอกจากนี้เวลาที่ใช้ในการเรียนรู้ของ VEBF จะใช้เวลาน้อยกว่า RBF และ MLP

สรุป

บทความนี้นำเสนอโครงข่ายประสาทเทียมชนิดฟังก์ชันไฮเพอร์อัลลิบชอยด์ (VEBF) ซึ่งใช้ฟังก์ชันไฮเพอร์อัลลิบชอยด์

ในการเรียนรู้ข้อมูลซึ่งฟังก์ชันนี้สามารถเรียนรู้ข้อมูลได้โดยการย้ายจุดศูนย์กลาง หมุน และขยายขนาดของฟังก์ชันเพื่อคลุมข้อมูลที่ต้องการเรียนรู้ โครงข่ายประสาทเทียมนี้สามารถที่จะเรียนรู้ข้อมูลเพียงแค่อรอบเดียวในขณะที่โครงข่ายประสาทเทียมประเภทอื่นๆ จะต้องเรียนรู้ข้อมูลหลายรอบจึงจะสามารถเรียนรู้ข้อมูลได้ดี ซึ่งในขณะที่มีการเรียนรู้ค่าพารามิเตอร์ต่างๆ ของฟังก์ชันไฮเพอร์อัลลิบชอยด์จะถูกปรับจากข้อมูลที่เข้ามาใหม่เพียงข้อมูลเดียวจึงทำให้โครงข่ายประสาทเทียมชนิดฟังก์ชันไฮเพอร์อัลลิบชอยด์นี้สามารถที่จะเรียนรู้ข้อมูลใหม่ๆ ได้หลังจากที่โครงข่ายประสาทเทียมนี้ถูกนำไปใช้งานแล้วโดยไม่จำเป็นต้องเก็บข้อมูลเก่าที่ได้เรียนรู้ไปแล้วซึ่งโครงข่ายประสาทเทียมประเภทอื่นๆ ไม่สามารถทำได้ นอกจากนี้ประสิทธิภาพของโครงข่ายประสาทเทียมชนิดฟังก์ชันไฮเพอร์อัลลิบชอยด์ที่ได้จากการทดลองยังสูงกว่าโครงข่ายประสาทเทียม RBF และ MLP ซึ่ง RBF และ MLP เป็นโครงข่ายประสาทเทียมที่นิยมใช้กันในปัจจุบัน

กิตติกรรมประกาศ

งานวิจัยนี้ได้รับการสนับสนุนเงินทุนจากสำนักงาน
กองทุนสนับสนุนการวิจัย

เอกสารอ้างอิง

- A. Asuncion & D. Newman. (2007) *UCI Machine Learning Repository*. School of Information and Computer Sciences. University. of California, Irvine.
- Kadirkamanathan, V., & Niranjan, M.. (1993). A Function Estimation Approach to Sequential Learning with Neural Networks. *Neural Computation*, 954–975
- Li, Y., Sundararajan, N., & Saratchandran, P. (2000). Analysis of Minimal Radial Basis Function Network Algorithm for Real-time Identification of Nonlinear Dynamic Systems. *IEEE Proceedings-Control Theory and Applications*.
- Platt, J., A. (1991). Resource-allocating Network for Function Interpolation. *Neural Computation*, 213–225.
- Saichon Jaiyen, Chidchanok Lursinsap & Suphakant Phimoltares. (2009). A Versatile Hyper-Ellipsoidal Basis Function for Function Approximation in High Dimensional Space. *6th International Symposium on Neural Networks*.
- Yingwei, L., Sundararajan, N., & Saratchandran, P.. (1997). A Sequential Learning Scheme for Function Approximation Using Minimal Radial Basis Function (RBF) Neural Networks. *Neural Computation*.