การประมาณค่า CBR ของดินโดยโครงข่ายประสาทเทียม

Estimation of California Bearing Ratio by Artificial Neural Network

ณรงค์เดช อินทรัตน์ชัยกิจ

Narongdej Intaratchaiyakit

สาขาวิชาวิศวกรรมโยธา คณะวิศวกรรมศาสตร์และสถาปัตยกรรมศาสตร์
มหาวิทยาลัยเทคโนโลยีราชมงคลตะวันออก วิทยาเขตอุเทนถวาย ถนนพญาไท เขตปทุมวัน กรุงเทพฯ 10330
Department of Civil Engineering, Faculty of Engineering and Architecture
Rajamangala University of Technology Tawan-ok, Uthenthawai Campus, 225 Phayathai Road
Pathumwan, Bangkok 10330, Thailand
E-mail: mydej456@yahoo.co.th โทร. 081-628-8063

บทคัดย่อ

การทดสอบค่าซีบีอาร์ (CBR) ในห้องปฏิบัติเป็นงานยากลำบาก ใช้เวลานาน และมีราคาแพง ส่งผลให้มีการพัฒนาแบบจำลองเชิงทำนายโดยใช้การวิเคราะห์การถดถอยเชิงเส้นพหุคูณ (MLRA) และโครงข่ายประสาทเทียม (ANN) ในการศึกษานี้ ค่าสัมประสิทธิ์การตัดสินใจต่ำในชุดการทดสอบที่ได้รับจาก MLRA ซึ่งใช้กรวด ทราย ดัชนีพลาสติก และปริมาณความชื้นที่เหมาะสมเป็นตัวแปรต้น อย่างไรก็ตาม แบบจำลอง ANN ที่พัฒนาขึ้นอย่างเหมาะสม คือ แบบจำลอง 5 ซึ่งใช้ปริมาณดินมวลละเอียด ดัชนีพลาสติก ปริมาณความชื้นที่เหมาะสม และความหนาแน่นแห้งสูงสุดเป็นตัวแปรต้น แบบจำลอง 5 มีค่าสัมประสิทธิ์การตัดสินใจค่อนข้างสูงในชุดการทดสอบ ค่า CBR ที่ถูกทำนายโดยใช้ ANN จะถูกเปรียบเทียบกับค่า CBR ที่ถูกทำนายโดย MLRA ผลลัพธ์แสดงให้เห็นว่า ANN มีประสิทธิภาพสูงกว่า MLRA และแบบจำลอง 5 สามารถถูกนำมาใช้ได้เพราะค่าความเชื่อถือได้มีค่าสูง ดังนั้นสูตรใหม่ที่ได้จาก ANN ได้ถูกนำเสนอสำหรับการทำนายค่า CBR สูตรใหม่นี้เป็นประโยชน์สำหรับการออกแบบเบื้องต้นในงานดินที่มีข้อจำกัดภายใต้งบประมาณ และเวลาที่จำกัด

คำสำคัญ : ค่าซีบีอาร์ การประมาณค่า โครงข่ายประสาทเทียม ปัญญาประดิษฐ์

Abstract

Laboratory CBR test is laborious, time-consuming, and expensive, resulting in the development of predictive models by employing a multiple linear regression analysis (MLRA) and an artificial neural network (ANN). In this study, a low coefficient of determination in the testing set was deserved from the MLRA in which the gravel, sand, plasticity index, and optimum moisture content were used as independent variables. However, the suitably developed ANN model was Model 5 in which fine content, plastic index, optimum moisture content and maximum dry density were used as independent variables. The Model 5 had a relatively high coefficient of determination in the testing set. The predicted CBR values using the ANN were compared with those predicted by MLRA. The findings demonstrated that ANN outperforms MLRA and that model 5 can be used due to its high reliability. A new formula derived from ANN has been suggested to predict CBR values. This new formula is helpful for a preliminary design in earthwork under time and money constraints.

Keywords : California Bearing Ratio, estimation, artificial neural network, artificial intelligence

1. บทนำ

งานดินในโครงการก่อสร้าง เช่น คันทางถนน และผิวทาง จำเป็นต้องมีชั้นรองพื้นทางที่เหมาะสม ชั้นรองพื้นทางควรพิจารณาเงื่อนไขบางประการ เช่น ความสามารถในการรับน้ำหนัก การทรุดตัว และการพองตัว ดังนั้นวิธีการประเมินจึงมีความสำคัญอย่างมากต่อการสร้างถนน (Taskiran, 2010) ผิวทางแบบยืดหยุ่นประกอบด้วยแอสฟัลต์คอนกรีต ชั้นพื้นทาง ชั้นรองพื้นทาง และชั้นดินเดิม คุณสมบัติของวัสดุและลักษณะความแข็งแรงของผิวทางแต่ละชั้นจะมีความแตกต่างกัน ความแข็งแรงของวัสดุดินเดิมและวัสดุมวลหยาบ สามารถกำหนดได้โดยใช้ค่าซีบีอาร์ (California Bearing Ratio, CBR) และโมดูลัสยืดหยุ่น (Resilient modulus, M_R) (Taha *et al*., 2019)

CBR คือ การทดสอบที่ใช้ประเมินโมดูลัสยืดหยุ่น และความแข็งแรงของดินเดิม นอกจากนี้ CBR แสดงค่าทางอ้อมในลักษณะสัดส่วนของความแข็งแรงของดินเดิมต่อความแข็งแรงของหินคลุกมาตรฐานเป็นเปอร์เซ็นต์ รวมทั้ง CBR ได้ถูกนำมาใช้สำหรับการออกแบบความหนาของผิวทาง อย่างไรก็ตาม การทำงานเพื่อให้ได้ค่า CBR จะต้องใช้ความพยายามอยู่เสมอ ข้อมูลการสำรวจดินอาจไม่เพียงพอเนื่องจากข้อจำกัดด้านงบประมาณ เวลา และแผนงานที่ไม่ดี อย่างไรก็ตาม การทดสอบ CBR ในห้องปฏิบัติการจะมีความยากลำบาก ใช้เวลานาน ราคาแพง และอาจจะไม่ถูกต้องเนื่องจากตัวอย่างดินถูกรบกวนและคุณภาพการทดสอบต่ำ

ดังนั้นการพัฒนาแบบจำลองการทำนายค่า CBR จึงเป็นสิ่งจำเป็น (Wai, 2006) ตัวอย่างเช่น Agarwal and Ghanekar (1970) เสนอสมการความสัมพันธ์ระหว่าง CBR กับขีดจำกัดเหลว (Liquid limit, LL) ขีดจำกัดพลาสติก (Plastic limit, PL) หรือดัชนีพลาสติก (Plasticity index, PI) พบว่าไม่มีความสัมพันธ์กันอย่างมีนัยสำคัญ แต่สมการความสัมพันธ์ระหว่าง CBR กับความชื้นที่เหมาะสม (Optimum Moisture Content, OMC) และ LL มีนัยสำคัญ National Cooperative Highway Research Program of United States of America (NCHRP) (2001) รายงานสองสมการ ซึ่งแต่ละสมการแสดงความสัมพันธ์ระหว่างคุณสมบัติดัชนีของดิน กับ CBR โดยสมการ (1) ใช้สำหรับวัสดุดินเม็ดหยาบที่ไม่มีพลาสติก และสมการ (2) ใช้สำหรับดินเม็ดละเอียดมากกว่า 12% ที่มีความเป็นพลาสติกบางส่วน ดังนี้

$$CBR = 28.09(D_{60})^{0.358} \quad (1)$$

โดย D_{60} คือ เส้นผ่านศูนย์กลางที่ผ่าน 60% (มม.) จากสมการ (1) D_{60} อยู่ระหว่าง 0.01 มม. ถึง 30 มม. ดังนั้น ค่า CBR ที่แนะนำ คือ 5% สำหรับ D_{60} น้อยกว่า 0.01 มม. ในขณะที่ค่า CBR ที่แนะนำ คือ 95% สำหรับ D_{60} ที่มากกว่า 30 มม. อีกสมการหนึ่งเกี่ยวกับดินเม็ดละเอียดได้อธิบายความสัมพันธ์ระหว่าง CBR และสมบัติดัชนีของดิน (เปอร์เซ็นต์ที่ผ่านตะแกรงเบอร์ 200 และดัชนีพลาสติก) ดังนี้

$$CBR = \frac{75}{1+0.728*wPI} \quad (2)$$

$$wPI = P_{200} * PI \quad (3)$$

โดย wPI คือ ดัชนีพลาสติกซึ่งถูกถ่วงน้ำหนัก P_{200} เท่ากับ เปอร์เซ็นต์ที่ผ่านตะแกรงเบอร์ 200 ในรูปแบบทศนิยม PI คือ ดัชนีพลาสติกที่ใช้ในหน่วยเปอร์เซ็นต์ กรวด (Gravel, G) ทราย (Sand, S) ดินเม็ดละเอียด (Fine content, FC) ความหนาแน่นแห้งสูงสุด (Maximum dry density, MDD) LL, PL และ OMC ส่งผลต่อค่า CBR ของดินเม็ดละเอียด ตัวแปรที่สำคัญที่สุดที่ใช้การวิเคราะห์การถดถอยเชิงเส้นอย่างง่าย (Simple linear regression analysis, SLRA) ท่ามกลาง G, S, FC, LL, PL, MDD และ OMC สำหรับการทำนายค่า CBR คือ MDD การวิเคราะห์การถดถอยเชิงเส้นพหุคูณ (Multiple linear regression analysis, MLRA) มีค่าสัมประสิทธิ์ของการตัดสินใจสูงกว่า SLRA (Ramasubbarao and Sankar, 2013; Rehman *et al*., 2015) Rakaraddi and Gomarsi (2015) รายงานว่า MLRA มีค่าความสัมพันธ์ระหว่างตัวแปร 2 ตัวที่ดีมากกว่า SLRA Rehman *et al*. (2017) พัฒนาค่าความสัมพันธ์ระหว่างตัวแปรต้นและตัวแปรตาม รวมทั้งโนโมกราฟหรือเส้นโค้งทำนายเพื่อทำนายค่า CBR, OMC และ MDD ในเทอมของ C_u, D_{30}, และ D_{50}

2. วิธีการศึกษา

2.1 ข้อมูลที่ใช้ในงานวิจัย

ในการศึกษานี้ใช้วิธี MLRA และ ANN ในการประมาณค่า CBR ของดินจากข้อมูลทั้งหมด 96 กรณีจากการรายงานโดย Farias *et al*. (2018) ข้อมูลถูกแบ่งออกเป็นสามชุด คือ ชุดการฝึกฝน ชุดการตรวจสอบ และชุดการทดสอบ 80% ของข้อมูลถูกใช้สำหรับการพัฒนาแบบจำลอง 10% ใช้สำหรับการตรวจสอบแบบจำลอง และส่วนที่เหลืออีก 10% ใช้สำหรับการทดสอบแบบจำลอง ตัวแปรต้น และตัวแปรตามได้มีช่วงของข้อมูล ดังตารางที่ 1 ซึ่งได้ถูกนำมาใช้ทำให้ค่าทั้งตัวแปรต้น และตัวแปรตามให้เป็นค่ามาตราฐานที่อยู่ระหว่าง 0 และ 1

ตารางที่ 1 ขอบเขตของข้อมูล ซึ่งถูกใช้สำหรับการพัฒนาแบบจำลอง

ตัวแปร	ค่ามากสุด	ค่าน้อยสุด	พิสัย
G (%)	94	0	94
S (%)	100	2	98
FC (%)	98	0	98
LL (%)	51	15	36
PI (%)	24	1	23
OMC (%)	17	4.5	12.5
MDD (g/cm^3)	2.29	1.62	0.67
CBR (%)	81	1	80

2.2 การวิเคราะห์การถดถอยเชิงเส้นพหุคูณ (MLRA)

นักวิจัยหลายคนได้กล่าวถึงตัวแปรหลาย ๆ ตัว ที่ส่งผลต่อค่าซีบีอาร์ ได้แก่ LL, PI, OMC, MDD, G, S และ FC ดังนั้นตัวแปรเหล่านี้จึงถูกนำมาใช้เป็นตัวแปรต้น สำหรับ MLRA ในขณะที่ CBR เป็นตัวแปรตาม ความสัมพันธ์ระหว่างตัวแปรต้น และตัวแปรตามของ MLRA ได้แสงดังสมการต่อไปนี้

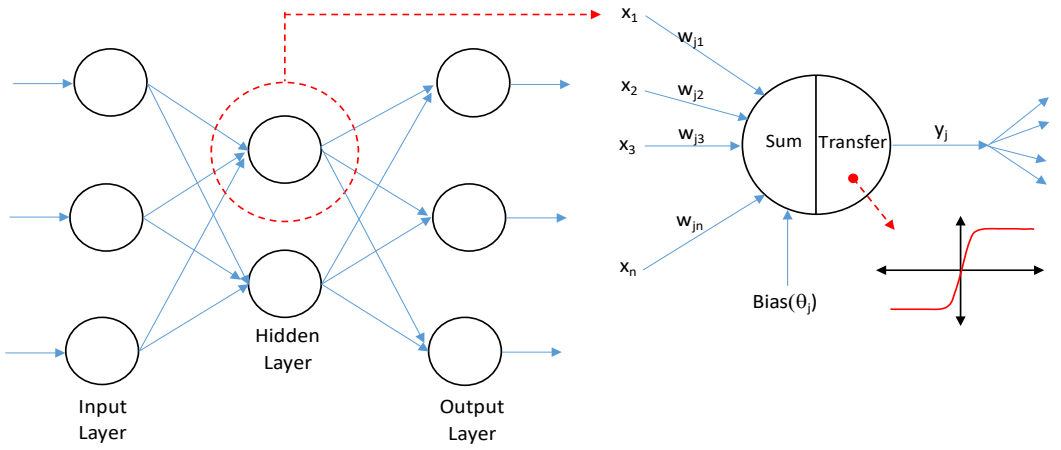
$$Y = \alpha + \beta_1 X_1 + \beta_2 X_2 + \cdots + \beta_n X_n + e \quad (4)$$

โดย Y คือ ตัวแปรตาม; α คือ ระยะตัดแกน Y; $\beta_1 X_1 + \beta_2 X_2 + \cdots + \beta_n$ คือ ค่าความชันของ X_1, X_2, ..., X_n ตามลำดับ e คือ พจน์ของค่าความผิดพลาด (Yildirim and Gunaydin, 2011) การหาผลลัพธ์สามารถกระทำโดย Y จะถูกแทนที่ด้วย CBR ในขณะที่ตัวแปรต้น คือ LL, PI, OMC, MDD, G, S และ FC การวิเคราะห์ดำเนินการใน Python 3.8.5 และแบบจำลอง CBR ที่พัฒนาขึ้นโดยใช้ MLRA ประสิทธิภาพการทำนายของแบบจำลอง MLR ที่พัฒนาขึ้น สามารถประเมินได้จากค่าสัมประสิทธิ์ของการตัดสินใจ (Coefficient of determination, R^2) และค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์ (Mean absolute error, MAE) ระหว่างค่า CBR ที่วัดได้ และค่า CBR ที่ได้จากการทำนาย สำหรับชุดการฝึกฝน ชุดการตรวจสอบ และชุดการทดสอบ

2.3 โครงข่ายประสาทเทียม (ANN)

การประยุกต์ใช้โครงข่ายประสาทเทียม (Artificial neural network, ANN) ในวิศวกรรมปฐพีและสาขาวิชาอื่น ๆ ได้ประเมินตัวแปรหลาย ๆ ตัว (Basma and Kallas, 2004; Das and Basudhar, 2008; Gunaydin *et al*., 2010) แบบจำลองที่ซับซ้อนจะมีความซับซ้อนในการแก้ไขปัญหา แต่ ANN สามารถแก้ปัญหาได้อย่างรวดเร็วโดยไม่ต้องใช้แบบจำลองทางกายภาพ (Taskiran, 2010; Shahin, 2015) การประมาณค่า CBR ในงานวิจัยหลายประเภทไม่สามารถเข้าถึงได้โดยใช้วิธีการทางสถิติเนื่องจากค่าสัมประสิทธิ์สหสัมพันธ์ต่ำ นอกจากนี้ CBR มักจะแสดงในลักษณะของพารามิเตอร์ของดินน้อยกว่าสองพารามิเตอร์ (เช่น ขนาดคละ พลาสติกซิตี้ และคุณสมบัติของการบดอัดของดิน) อย่างไรก็ตาม การประมาณค่า CBR ของดินเม็ดละเอียดในตุรกีได้ใช้ทั้ง ANN และโปรแกรมนิพจน์ของยีน (Gene expression

programming, GEP) ได้ประสบความสำเร็จในความสัมพันธ์ระหว่าง CBR กับ คุณสมบัติพื้นฐานหลายอย่างของดินเม็ดละเอียด MDD, PI, OMC, S, FC, LL และ G เป็นพารามิเตอร์ที่สำคัญตามลำดับที่มีผลต่อค่า CBR ซึ่งได้จากการวิเคราะห์ความไว (Taskiran, 2010) Bhatt *et al*. (2014) แสดงให้เห็นว่า SLRA และ MLRA มีประสิทธิภาพในการทำนายค่า CBR เกี่ยวกับ G, S, OMC และ MDD ต่ำกว่า ANN แบบจำลอง ANN ทำนายค่า CBR ได้ดีกว่าแบบจำลองการถดถอยเชิงเส้นพหุคูณ (Multiple linear regression, MLR) (Erzin and Turkoz, 2016) ทั้ง ANN และการวิเคราะห์การถดถอย (Regression analysis, RA) ที่ใช้ในการพัฒนาแบบจำลองเป็นที่น่าพอใจ (Taha *et al*., 2019)



ภาพที่ 1 การทำงานของ ANN

ANN เป็นวิธีการของปัญญาประดิษฐ์ (Artificial intelligence, AI) ที่พยายามเลียนแบบสมองและระบบประสาทของมนุษย์ ANN ประกอบด้วยโหนดหรือองค์ประกอบการประมวลผล (Processing elements, PEs) โหนดเหล่านี้ถูกจัดอยู่ในชั้นป้อนเข้า หรือชั้นซ่อน และชั้นผลลัพธ์ (ภาพที่ 1) แต่ละโหนดในชั้นหนึ่งใด ๆ จะเชื่อมโยงกับโหนดอื่นผ่านการเชื่อมต่อแบบถ่วงน้ำหนัก การป้อนเข้าจากแต่ละโหนดในชั้นล่าสุด (x_i) คูณด้วยน้ำหนักการเชื่อมต่อที่ปรับเปลี่ยนได้ (w_{ji}) ที่แต่ละโหนด สัญญาณป้อนเข้าที่ถูกถ่วงน้ำหนักจะถูกรวบรวม และเพิ่มความเอนเอียง (θ_j) แล้วผ่านฟังก์ชันกระตุ้น (Activation function, f.) เช่น ฟังก์ชันกระตุ้น tanh เป็นต้น แล้วได้ผลลัพธ์ของโหนด (y_i) ผลลัพธ์ของโหนดหนึ่งใด ๆ จะให้ค่าป้อนเข้าไปยังหลาย ๆ โหนดในชั้นถัดไป กระบวนการนี้ถูกดำเนินการในสมการ (5) และ (6) และถูกแสดงในภาพที่ 1 (Shahin and Jaksa, 2002)

$$I_j = \sum w_{ji} x_i + \theta_j \quad (5)$$

$$y_j = f(I_j) \quad (6)$$

ความเอนเอียงจะถูกเพิ่มเข้าไปในโหนดชั้นซ่อนอยู่ และชั้นผลลัพธ์เท่านั้น (Erzin, Rao, Patel, Gumaste, and Singh, 2008) หนึ่งชั้นซ่อนได้เพียงพอ สำหรับ ANN (Cybenko, 1989; Hecht-Nielsen, 1989) ANN สามารถเรียนรู้ได้โดยการปรับน้ำหนักของโหนดจนกว่าจะมีข้อผิดพลาดน้อยที่สุดระหว่างค่าผลลัพธ์จริง และผลลัพธ์เป้าหมาย (Erzin *et al*., 2008) อัลกอริทึมการแพร่กระจายกลับ (Back-propagation algorithm) เป็นกระบวนการเรียนรู้ที่มีประสิทธิภาพมากที่สุดสำหรับโครงข่ายประสาทเทียมหลายชั้น (Multi - Layer Perceptron, MLP) (Khandelwal and Singh, 2009) อัลกอริทึมการแพร่กระจายกลับนี้ได้รับความนิยมอย่างกว้างขวางในวิศวกรรมธรณีเทคนิค (Erzin and Gunes, 2011; Shahin and Jaksa, 2002; Taskiran, 2010)

2.4 การพัฒนาแบบจำลอง ANN

นักวิจัยหลายคนกล่าวถึงว่า ตัวแปรหลาย ๆ ตัวได้ส่งผลต่อค่าซีบีอาร์ ได้แก่ LL, PI, OMC, MDD, G, S และ FC ดังนั้นตัวแปรเหล่านี้จึงถูกนำมาใช้เป็นตัวแปรนำเข้าสำหรับแบบจำลอง ANN ที่พัฒนาขึ้น เพื่อหาแบบจำลอง ANN ที่เหมาะสม และสร้างสูตรสำหรับการประมาณค่า CBR ซึ่งจำเป็นต้องตรวจสอบแบบจำลอง ANN หลาย ๆ แบบ แบบจำลอง 6 แบบ ได้ถูกสร้างขึ้นในการศึกษาครั้งนี้ โดยการรวมกันของตัวแปรป้อนเข้าอย่างเหมาะสม รวมทั้งความแตกต่างในสถาปัตยกรรม ANN จะถูกใช้ทำนายค่า CBR ที่เหมาะสมมากสุด ดังตารางที่ 2 ข้อมูลที่นำมาใช้กับแบบจำลอง ANN ที่พัฒนาขึ้นจะถูกทำให้เป็นค่ามาตรฐานระหว่าง 0 ถึง 1 เพื่อลดผลกระทบของมิติและเพื่อฝึกฝน ANN สำหรับการหาค่าน้ำหนักและความเอนเอียง ส่วนการแปลงข้อมูลให้เป็นค่ามาตรฐาน (Normalization) จะมีสมการดังต่อไปนี้

$$X_n = \frac{X - Xmin}{X_{max} - X_{min}} \quad (7)$$

ส่วนฟังก์ชันกระตุ้น relu และ tanh ถูกใช้ในชั้นซ่อน และชั้นผลลัพธ์ โครงข่ายประสาทเทียมแบบป้อนไปข้างหน้า ซึ่งประกอบด้วยโครงข่ายประสาทเทียมแบบหลายชั้น ถูกฝึกฝนด้วยอัลกอริทึมแบบแพร่กลับ (Back-propagation algorithm) และใช้อัลกอริทึมอดัม (Adam algorithm) สำหรับการทำให้ฟังก์ชันการสูญเสียมีค่าน้อยสุด การวิเคราะห์ถูกดำเนินการใน Python 3.8.5 ประสิทธิภาพการทำนายของแบบจำลอง ANN ที่พัฒนาขึ้น สามารถประเมินได้จากค่าสัมประสิทธิ์ของการตัดสินใจ (Coefficient of determination, R^2) และค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์ (Mean absolute error, MAE) ระหว่างค่า CBR ที่วัดได้ และค่า CBR ที่ได้จากการทำนาย สำหรับชุดการฝึกฝน ชุดการตรวจสอบ และชุดการทดสอบ

2.5 ความเชื่อถือได้

ความเชื่อถือได้ (Reliability) คือ สิ่งที่ใช้วัดความน่าเชื่อถือของเครื่องมือที่ไปใช้วัดตัวอย่าง หากนำเครื่องมือไปวัดตัวอย่าง 2 ครั้ง แล้วผลที่ได้จะต้องคล้ายกันหรือสอดคล้องกัน ซึ่งเป็นวิธีการวัดซ้ำ สำหรับการศึกษาวิจัยครั้งนี้จะใช้วิธีการวัดซ้ำ ซึ่งจะใช้วัดความสัมพันธ์ระหว่าง CBR ที่ประมาณค่า และ CBR ที่วัดได้ บนข้อมูลตัวอย่างทดสอบทั้งหมด 96 กรณี ที่ระดับความเชื่อมั่น (Confidence level, CI) เท่ากับ 0.95 การวิเคราะห์ถูกดำเนินการใน Python 3.8.5 โดยความสัมพันธ์กันในทิศทางเดียวกันและสูง จะแสดงถึงเครื่องมือ (แบบจำลอง) มีความน่าเชื่อถือสูง

ตารางที่ 2 แบบจำลอง ANN ซึ่งถูกใช้ประมาณค่า CBR

แบบจำลอง	ตัวแปรป้อนเข้า	โครงสร้าง (ANN)	ฟังก์ชันกระตุ้น
1	G, S, FC, LL, PI, OMC, MDD	7-1-1	relu - tanh
2	S, FC, LL, PI, OMC, MDD	6-3-1	relu - tanh
3	S, PI, OMC, MDD	4-3-1	relu - tanh
4	LL, PI, OMC, MDD	4-4-1	relu - tanh
5	FC, PI, OMC, MDD	4-2-1	tanh - tanh
6	G, S, PI, MDD	4-1-1	tanh - tanh

3. ผลการศึกษา

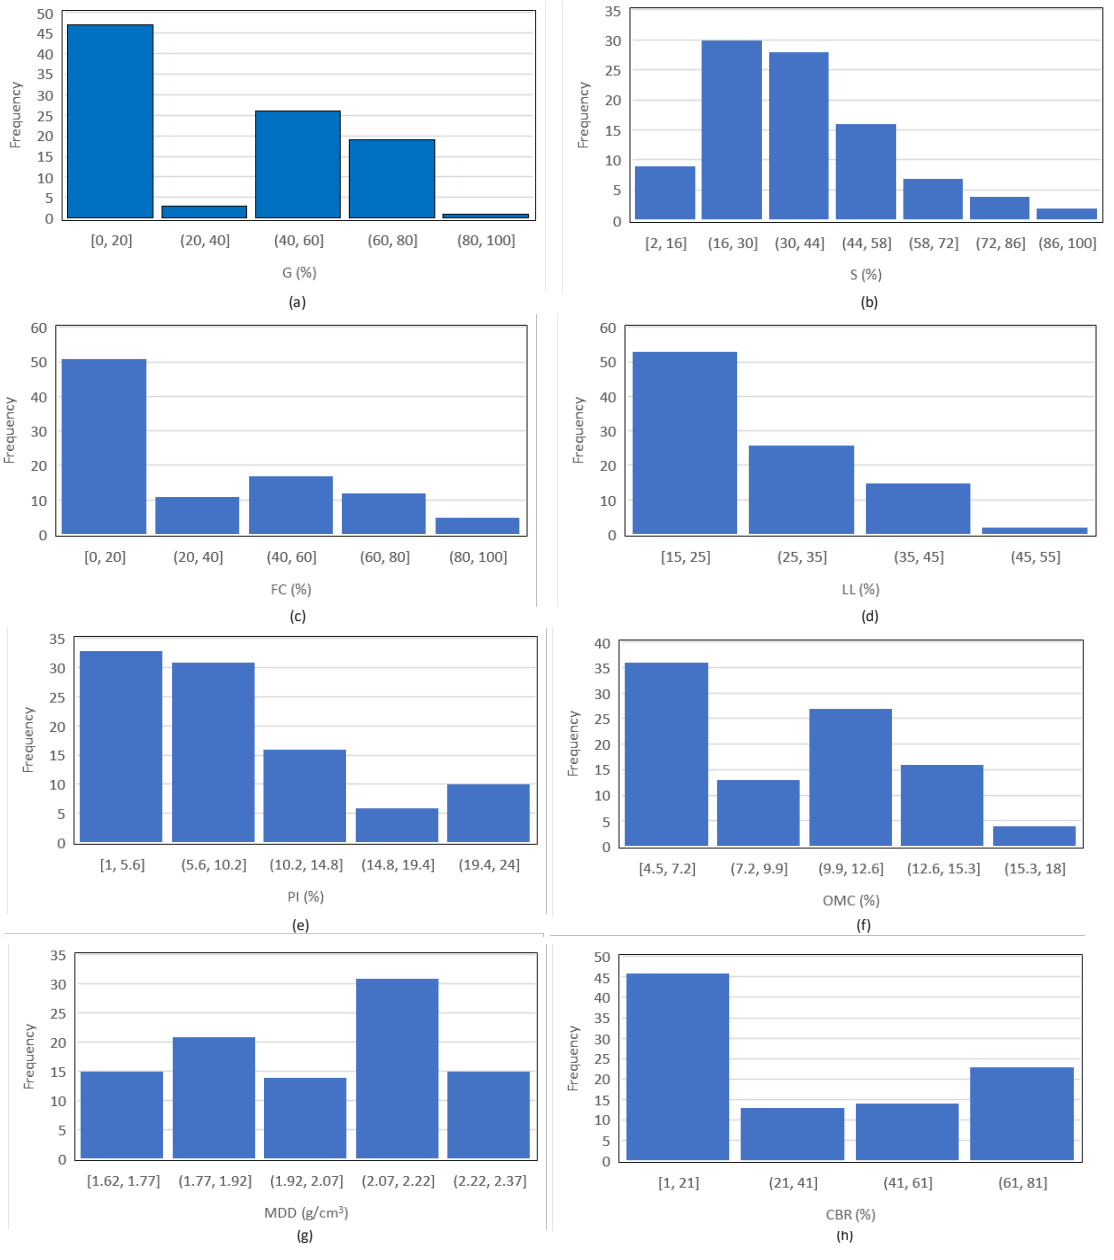
3.1 ผลการวิเคราะห์การกระจายข้อมูล

ภาพที่ 2 แสดงการกระจายของข้อมูลของแต่ละตัวแปรในรูปแบบความถี่ ดินส่วนมากจะมีค่า G ระหว่าง 0 และ 20 % (ภาพที่ 2a) และจะมี S ระหว่าง 16 ถึง 44% (ภาพที่ 2b) ขณะที่ FC ในดินส่วนมากจะมีค่าในช่วง 0 ถึง 20% (ภาพที่ 2c) ส่วนใหญ่ดินจะมี LL จาก 15 ถึง 25% (ภาพที่ 2d) ส่วน PI จะมีค่าส่วนใหญ่ในช่วงระหว่าง 1 ถึง 10.2% (ภาพที่ 2e) OMC จะมีค่าส่วนมากในช่วง 4.5 ถึง 7.2% (ภาพที่ 2f) MDD และ CBR จะมีความถี่สูงสุดในช่วง 2.07 ถึง 2.22 g/cm^3 และ 1 ถึง 21% ตามลำดับ (ภาพที่ 2g และ 2h)

3.2 ผลการวิเคราะห์ MLRA

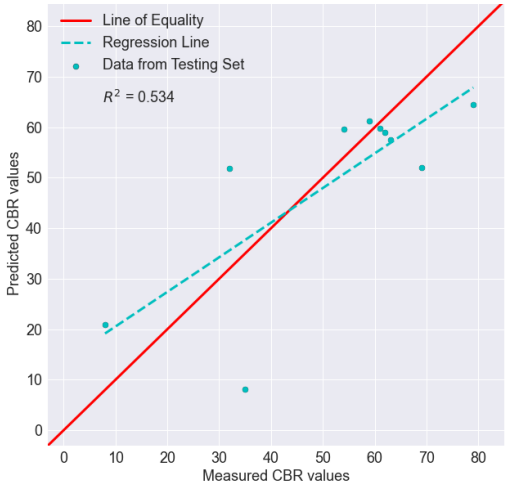
ประสิทธิภาพการทำนายของแบบจำลอง MLR ที่พัฒนาขึ้นสามารถประเมินได้จากค่าสัมประสิทธิ์ของการตัดสินใจ (R^2) และค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์ (MAE) ระหว่างค่า CBR ที่วัดได้ และค่า CBR ที่ถูกทำนาย ค่า R^2 ของสมการ (8) เท่ากับ 0.846, 0.892 และ 0.534 สำหรับชุดการฝึกฝน ชุดการตรวจสอบ และชุดการทดสอบ ตามลำดับ นอกจากนี้ ค่า MAE คือ 7.730, 8.017 และ 10.87 สำหรับชุดการฝึกฝน ชุดการตรวจสอบ และชุดการทดสอบ ตามลำดับ สมการที่ใช้ทำนายค่า CBR โดยใช้ G, S, PI และ OMC เป็นตัวแปรต้น ซึ่งได้จาก MLRA จะมีค่าดังต่อไปนี้

$$CBR = 58.435400 + 0.376590\ G + 0.116958\ S - 0.658274\ PI - 3.604220\ OMC \quad (8)$$



ภาพที่ 2 การกระจายข้อมูลของข้อมูลป้อนเข้า และผลลัพธ์

นอกจากนี้ ค่า CBR ที่คำนวณจากสมการ (8) จะถูกเปรียบเทียบกับค่า CBR ที่วัดได้ในชุดการทดสอบ โดยการนำมาพล็อตจุด ดังภาพที่ 3 จะพบว่า มีความสัมพันธ์กันปานกลางระหว่างกัน



ภาพที่ 3 ค่า CBR ซึ่งถูกประมาณค่าจากสมการ (8) เปรียบเทียบกับค่า CBR ที่วัดได้

ตารางที่ 3 น้ำหนัก และความเอนเอียง สำหรับแบบจำลอง 5

น้ำหนักระหว่างชั้นป้อนเข้า และชั้นซ่อน		น้ำหนักระหว่างชั้นซ่อน และชั้นผลลัพธ์
-1.8708048	-0.5295375	1.2511209
-0.7253409	-0.15920386	0.75452834
-1.8599731	0.6836202	
0.57240915	-0.03287369	
ความเอนเอียงระหว่างชั้นป้อนเข้า และชั้นซ่อน		ความเอนเอียงระหว่างชั้นซ่อน และชั้นผลลัพธ์
-0.1332478	0.984387	0.75696903

ตารางที่ 4 ประสิทธิภาพของแบบจำลอง ANN ซึ่งถูกใช้ประมาณค่า CBR

แบบจำลอง	ชุดการฝึกฝน		ชุดการตรวจสอบ		ชุดการทดสอบ	
	R^2	MAE	R^2	MAE	R^2	MAE
1	0.862	7.419	0.940	6.740	0.581	9.535
2	0.902	6.148	0.941	6.585	0.609	9.810
3	0.846	7.340	0.872	8.907	0.647	9.222
4	0.846	7.542	0.850	8.850	0.643	9.068
5	0.905	5.940	0.989	2.357	0.674	9.413
6	0.805	8.482	0.898	8.203	0.568	10.454

3.3 ผลการวิเคราะห์ ANN

แบบจำลองโครงข่ายประสาทเทียมที่พัฒนาขึ้นสำหรับการฝึกฝนได้แสดงในตารางที่ 2 หลังจากแบบจำลอง ANN ได้ถูกฝึกฝน แล้วจะได้น้ำหนักและความเอนเอียงสำหรับแบบจำลอง 5 ดังตารางที่ 3 ค่าฟังก์ชันกระตุ้น น้ำหนัก และความเอนเอียงจะถูกนำมาใช้ในการสร้างสูตร CBR ประสิทธิภาพของแบบจำลองได้ถูกแสดงในตารางที่ 4 โดยแบบจำลอง ANN ที่เหมาะสม คือ แบบจำลอง 5 เนื่องจากมี R^2 ค่อนข้างสูง และ MAE ต่ำในชุดการฝึกฝน นอกจากนี้ แบบจำลอง 5 ยังซับซ้อนน้อยกว่าแบบจำลอง 4 เนื่องจากมีตัวแปรป้อนเข้า 4 ตัว กับ โหนด 2 ตัวในชั้นซ่อน ในขณะที่ แบบจำลอง 3

มีตัวแปรป้อนเข้า 4 ตัว กับ โหนด 3 ตัวในชั้นซ่อน R^2 ของแบบจำลอง 5 ในชุดการทดสอบได้มีค่าสูงสุด แต่ค่า MAE ได้มีค่าน้อยกว่าแบบจำลอง 1 แบบจำลอง 2 และ แบบจำลอง 6 ดังนั้นแบบจำลอง 5 จึงถูกเลือก และมีสมการดังต่อไปนี้

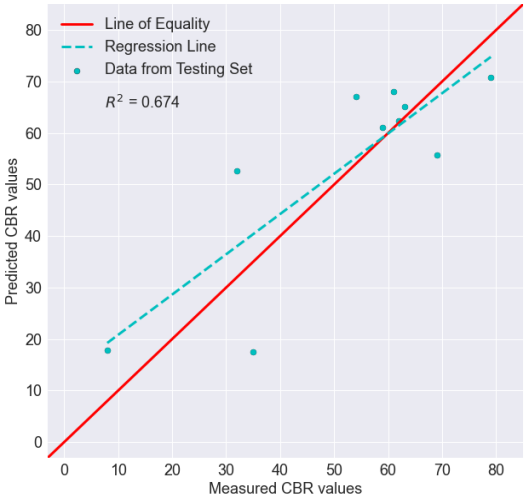
$$CBR = 1 - 80 * \tanh(1.251121\ C_1 + 0.754528\ C_2 - 0.756969) \quad (9)$$

โดย

$$C_1 = \tanh(0.019090\ FC + 0.031537\ PI + 0.816152 + 0.148798\ OMC - 0.854343 * MDD) \quad (10)$$

$$C_2 = \tanh(0.005403\ FC + 0.006922\ PI - 0.824692 - 0.054690\ OMC + 0.049065\ MDD) \quad (11)$$

การหาค่าฟังก์ชัน C_1 จากสมการ (10) และ C_2 จากสมการ (11) จะต้องใช้ตัวแปรป้อนเข้า FC, PI, OMC และ MDD การใช้ฟังก์ชัน C_1 และ C_2 ในสมการ (9) เพื่อหาค่า CBR ซึ่งสูตรที่นำเสนอนั้นจะสมเหตุผลเมื่อตัวแปรป้อนเข้ามีค่าอยู่ระหว่างค่าต่ำสุด และค่าสูงสุดของตัวแปรป้อนเข้าตามที่กำหนดในตารางที่ 1 ผลการทำนายของแบบจำลองสามารถเพิ่มค่าเบี่ยงเบนจากการใช้ตัวแปรป้อนเข้านอกเหนือจากช่วงตัวแปรป้อนเข้า (Pala, 2006) ค่า CBR ซึ่งถูกประมาณค่าโดยแบบจำลอง 5 เทียบกับค่า CBR ที่วัดได้ในชุดการทดสอบ ดังภาพที่ 4 จะพบว่ามีความสัมพันธ์กันมากระหว่างค่าเหล่านี้



ภาพที่ 4 ค่า CBR ซึ่งถูกประมาณค่าจากแบบจำลอง 5 เปรียบเทียบกับค่า CBR ที่วัดได้

3.4 ความเชื่อถือได้

จากข้างจะพบว่าแบบจำลอง 5 ซึ่งอยู่บนพื้นฐาน ANN (R^2 = 0.674 และค่า MAE = 9.413 ในชุดการทดสอบ) จะมีประสิทธิภาพที่โดดเด่นกว่าแบบจำลอง MLR (R^2 = 0.534 และค่า MAE = 10.87 ในชุดการทดสอบ) ดังนั้นแบบจำลอง 5 จึงถูกเลือกใช้ และที่ระดับความเชื่อมั่นเท่ากับ 0.95 จะหาค่าความเชื่อถือได้บนข้อมูลตัวอย่างทดสอบทั้งหมด 96 กรณี มีค่าเท่ากับ 0.953 ซึ่งมีค่าเข้าใกล้ 1 แบบจำลองจึงมีความเชื่อถือได้สูง และอยู่ในขอบเขตของช่วงความเชื่อมั่น ซึ่งมีค่าขอบเขตล่าง 0.93 และค่าขอบเขตบน 0.968

3.5 อภิปรายผลการวิจัย

การประเมินค่า CBR โดยใช้แบบจำลอง MLR และ ANN R^2 มีค่าที่ปานกลาง (R^2 = 0.534) กับค่า MAE เท่ากับ 10.87 ในชุดการทดสอบจาก MLRA ซึ่งใช้ G (%), S (%), PI (%) และ OMC (g/cm^3) เป็นตัวแปรต้น นอกจากนี้การพัฒนาแบบจำลอง ANN ด้วยตัวแปรต้นที่แตกต่างกัน จะพบว่าแบบจำลอง 5 ได้ใช้ตัวแปรต้น FC (%), PI (%), OMC (%) และ MDD (g/cm^3) มีความเหมาะสมมากสุดในบรรดาแบบจำลอง ANN เนื่องจากแบบจำลองได้มีความซับซ้อนน้อยกว่า กับ ค่า R^2 ค่อนข้างสูง (R^2 = 0.674) และค่า MAE ต่ำ (MAE = 9.413) ในชุดการทดสอบ แสดงให้เห็นว่าแบบจำลอง ANN ที่พัฒนาขึ้นมีประสิทธิภาพที่โดดเด่นกว่าแบบจำลอง MLR ผลลัพธ์นี้สอดคล้องกับของนักวิจัยคนอื่น ๆ

(Bhatt *et al.*, 2014; Erzin and Turkoz, 2016) นอกจากนี้ แบบจำลอง 5 ได้มีค่าความเชื่อถือได้เท่ากับ 0.953 ซึ่งมีค่าเข้าใกล้ 1 จึงทำให้แบบจำลองมีความน่าเชื่อถือมาก

4. สรุป

เป้าหมายหลักของการศึกษานี้ คือ การประเมินค่า CBR โดยใช้แบบจำลอง MLR และ ANN จะพบว่าแบบจำลอง ANN ที่พัฒนาขึ้นมีประสิทธิภาพที่โดดเด่นกว่าแบบจำลอง MLR ในการทำนายค่า CBR ทั้งนี้แบบจำลอง ANN (แบบจำลอง 5) มีความน่าเชื่อถือมากเพราะค่าความเชื่อถือได้มีค่าสูง นอกจากนี้ สูตรใหม่ที่ได้จากแบบจำลอง ANN (แบบจำลอง 5) มีประโยชน์ต่อการออกแบบเบื้องต้นในงานดินที่มีข้อจำกัดในด้านงบประมาณ และเวลาจำกัด

5. เอกสารอ้างอิง

Agarwal, K.B. and K.D. Ghanekar. 1970. **Prediction of CBR from plasticity characteristics of soil**. In: Proceeding of 2nd south-east Asian conference on soil engineering, Singapore. June 11-15. 1970. Bangkok: Asian Institute of Technology. 571-576.

Basma, A. A. and N. Kallas. 2004. **Modeling soil collapse by artificial neural networks**. Geotech. 22: 427-438.

Bhatt, S., P.K. Jain and M. Pradesh. 2014. **Prediction of California bearing ratio of soils using artificial neural network**. AIJRSTEM. 8(2): 156-161.

Cybenko, G. 1989. **Approximation by superpositions of a sigmoidal function**. MCSS. 3: 303-314.

Das, S. K. and P. Basudhar. 2008. **Prediction of residual friction angle of clay artificial neural network**. Eng Geol. 142-145.

Erzin, Y., B. H. Rao, A. Patel, S.D. Gumaste and D.N. Singh. 2008. **Artificial neural networks for predicting soil thermal resistivity**. Int J Therm Sci, 47: 1347-1358.

Erzin, Y. and N. Gunes. 2011. **The prediction of swell percent and swell pressure by using neural networks**. Comput. 16(2): 425-436.

Erzin, Y. and D. Turkoz. 2016. **Use of neural networks for the prediction of the CBR value of some Aegean sands**. Neural Comput. 27: 1415–1426.

Gunaydin, O., A. Gokoglu and M. Fener. 2010. **Prediction of artificial soil's unconfined compression strength test using statistical analyses and artificial neural networks**. Adv. Eng. Softw. 41: 1115-1123.

González Farias, I., W. Araujo and G. Ruiz. 2018. **Prediction of California Bearing Ratio from Index Properties of Soils Using Parametric and Non-parametric Models**. Geotech. 36: 3485-3498.

Hecht-Nielsen, R. 1989. **Theory of the back-propagation neural network**. In: Proceedings of the International Joint Conference on Neural Networks, Washington. DC. 593-605.

Khandelwal, M. and T.N. Singh. 2009. **Prediction of blast-induced ground vibration using artificial neural network**. International Journal of Rock Mechanics and Mining Sciences. 46(7): 1214-1222.

National Cooperative Highway Research Program. 2001. **Guide for mechanistic and empirical - design for new and rehabilitated pavement structures**. final document. In: Appendix CC-1: correlation of CBR values with soil ındex properties. West University Avenue Champaign, Illinois: Ara, Inc.

Pala, M. 2006. **A new formulation for distortional buckling stress in cold-formed steel members**. J Constr Steel Res. 62: 716-722.

Ramasubbarao, G. V. and G. S. Sankar. 2013. **Predicting Soaked CBR Value of Fine Grained Soils Using Index and Compaction Characteristics**. Jordan J. Civ. Eng. 7(3): 354-360.

Rakaraddi, P. G. and V. Gomarsi. 2015. **Establishing relationship between CBR with different soil properties**. Int. Res. J. Eng. Technol. 4(2): 182-188.

Rehman, A.U., K. Farooq, H. Mujtaba and O. Altaf. 2015. **Estimation of California bearing ratio (CBR) from index properties and compaction characteristics of coarse grained soil**. Sci. Int. Lahore 27(6): 6207-6210.

Rehman, A.U., K. Farooq and H. Mujtaba. 2017. **Prediction of California bearing ratio (CBR) and compaction characteristics of granular soils**. Acta Geotech. Slov. 14(1): 62-72.

Shahin, M.A. and M. Jaksa. 2002. **Artificial neural network-based settlement prediction formula for shallow foundations on granular soils**. Australian Geomechanics, 45-52.

Shahin, M.A. 2015. **A review of artificial intelligence applications in shallow foundations**. Int. J. Geotech. 9: 49-60.

Taskiran, T. 2010. **Prediction of California bearing ratio (CBR) of fine grained soils by AI methods**. Adv. Eng. Softw. 41(6): 886-892.

Taha, S., Gabr, A. and S. El-Badawy. 2019. **Regression and Neural Network Models for California Bearing Ratio Prediction of Typical Granular Materials in Egypt**. Arab J Sci Eng. 44: 8691-8705.

Wai, K. M. 2006. **California bearing ratio correlation with soil index properties master of engineering (civil-geotechnics)**. Faculty of Civil Engineering, University Teknology Malaysia.

Yildirim, B. and O. Gunaydin. 2011. **Estimation of California bearing ratio by using soft computing systems**. Expert Syst. Appl. 38(5): 6381-6391.

(Received: 19/Jan/2022, Revised: 17/Jun/2023, Accepted: 21/Jun/2023)