

การทำนายค่า CBR ของดินโดยการโปรแกรมหลายนิพจน์

Prediction of California Bearing Ratio by Multi-Expression Programming

ณรงค์เดช อินทร์ต้นชัยกิจ

Narongdej Intaratchaiyakit

สาขาวิชาวิศวกรรมโยธา คณะวิศวกรรมศาสตร์และสถาปัตยกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีราชมงคลตะวันออก

Department of Civil Engineering, Faculty of Engineering and Architecture,

Rajamangala University of Technology Tawan-ok

E-mail: mydej456@yahoo.co.th โทร. 081-628-8063

บทคัดย่อ

California Bearing Ratio (CBR) เป็นการทดลองที่สำคัญในงานด้านโยธา เช่น เขื่อน และผิวทาง เป็นต้น CBR มักจะได้รับการทดลองในห้องปฏิบัติการโดยใช้เวลานาน ค่าใช้จ่ายสูง และขั้นตอนที่ยากซึ่งมีอิทธิพลต่อความก้าวหน้าของโครงการก่อสร้าง ดังนั้นการพัฒนาแบบจำลองที่ใช้การโปรแกรมหลายนิพจน์ (Multi-expression programming, MEP) จำนวน 6 รูปแบบจำลองซึ่งมีตัวแปรป้อนเข้าหลากหลาย แบบจำลอง I เป็นแบบจำลองที่เหมาะสมมากที่สุดเนื่องจากมีค่าสัมประสิทธิ์การตัดสินใจค่อนข้างสูงในชุดการฝึกฝน และชุดการทดสอบ และเมื่อนำแบบจำลอง MEP ไปเปรียบเทียบกับแบบจำลองการถดถอยเชิงเส้นพหุคูณ (Multiple linear regression, MLR) และโครงข่ายประสาทเทียม (Artificial neural network, ANN) จะพบว่าแบบจำลอง MEP เป็นแบบจำลองที่เหมาะสมมากที่สุด และแบบจำลอง MEP สามารถถูกนำมาใช้ได้เพราะค่าความเชื่อถือได้มีค่าสูง สมการคณิตศาสตร์ที่ได้จากแบบจำลอง MEP จะนำไปประยุกต์ใช้ในการทำนายค่า CBR สำหรับการออกแบบเบื้องต้นในงานด้านปฐพีเพื่อที่จะลดค่าใช้จ่าย และเวลา

คำสำคัญ : ค่าซีบีอาร์ การโปรแกรมหลายนิพจน์ โครงข่ายประสาทเทียม ปัญญาประดิษฐ์

Abstract

California Bearing Ratio (CBR) is a crucial experiment for civil work, such as dams and pavement. CBR is always experimental in the lab, using time-consuming, expensive, and challenging processes that have an effect on how quickly building projects move forward. Hence, the model development used six multi-expression programming (MEP) models that had diverse input variables. Model I was the most proper MEP model because Model 1's coefficients of determination were relatively high in the training and testing sets. When the MEP model is compared to the multiple linear regression (MLR) and artificial neural network (ANN) models, the MEP model is found to be the most suitable model, and the MEP model can be employed because of its high level of reliability. The mathematical equation from the MEP model is applied to predict the CBR values for preliminary design in geotechnical work to reduce cost and time.

Keywords : California Bearing Ratio, multi-expression programming, artificial neural network, artificial intelligence

1. บทนำ

งานถนนซึ่งเป็นงานดินอย่างหนึ่งที่ต้องมีชั้นรองพื้นทางที่ดีด้วยการพิจารณาค่าต่าง ๆ เช่น ค่าความสามารถรับแรงอัด การทรุดตัว และการบวมตัว เป็นต้น (Taskiran, 2010) องค์ประกอบของผิวทางแบบยึดหยุ่น ได้แก่ แอสฟัลต์ คอนกรีต (Asphalt concrete) ชั้นพื้นทาง (Base layer) ชั้นรองพื้นทาง (Subbase layer) และชั้นดินเดิม (Subgrade

layer) แต่ละชั้นเหล่านี้มีความแตกต่างกันในสมบัติของวัสดุ และความแข็งแรงของผิวทาง (Taha, Gabr, and El-Badawy, 2019)

ค่าซีบีอาร์ (California Bearing Ratio, CBR) แสดงถึงค่าอัตราส่วนระหว่างความแข็งแรงของดินเดิมต่อความแข็งแรงของหินคลุกมาตรฐานมีหน่วยเป็นเปอร์เซ็นต์ นอกจากนี้ CBR เป็นการทดสอบเพื่อหาค่าความแข็งแรงของดินเดิม (Taha et al., 2019) และความหนาของผิวทาง (Ramasubbarao and Sankar, 2013) ชั้นดินเดิมจะต้องแข็งแรงเพียงพอต่อการรองรับผิวทาง และน้ำหนักบรรทุกทุกล้อรถ การออกแบบและพฤติกรรมของผิวทางยึดหยุ่นขึ้นอยู่กับเสถียรภาพของดินเดิม โดยเสถียรภาพของดินเดิมนั้นสามารถเพิ่มขึ้นได้โดยการบดอัดดินที่ปริมาณความชื้นที่เหมาะสม (Optimum moisture content, OMC) ซึ่งเป็นจุดที่ดินมีความหนาแน่นแห้งสูงสุด (Maximum dry density, MDD) ค่า OMC และ MDD เป็นพารามิเตอร์สำคัญที่ส่งผลต่อค่า CBR (Lakshmi, Subramanian, Lalithambikhai, Vela, and Ashni, 2016) หลาย ๆ งานวิจัยก่อนหน้านี้ได้รายงานไว้ว่า ชนิดของดิน และสมบัติของดินได้มีผลต่อค่า CBR (Zumrawi, 2012) ค่า CBR มักจะถูกนำมาใช้ในการทาง สนามบิน ที่จอดรถและการออกแบบงานผิวทาง รวมถึง CBR ได้มีอิทธิพลต่องานทางด้านวิศวกรรมปฐพี และโครงสร้างดิน เช่น เชื้อดิน คันทางถนน ตัวค้ำสะพาน และวัสดุหลังกำแพงกันดิน (Yildirim and Gunaydin, 2011) CBR ได้ถูกนำมาหาความสัมพันธ์กับค่ามอดุลัสยึดหยุ่น และสมบัติของดินทางวิศวกรรม (Alawi and Rajab, 2013)

ข้อมูลดินที่ได้มาจากการสำรวจดินอาจมีปริมาณน้อยเพราะงบประมาณ และเวลาจำกัด รวมทั้งแผนงานไม่ดีพอ แต่การทดสอบ CBR ในห้องปฏิบัติการนั้นเป็นเรื่องที่กระทำได้ยาก ใช้เวลามาก ค่าใช้จ่ายสูง และความถูกต้องอาจต่ำ อาจเพราะการทดสอบที่ไม่ได้มาตรฐานและปัญหาของตัวอย่างดินถูกรบกวน ส่งผลทำให้เกิดการพัฒนาสมการประมาณค่า CBR (Wai, 2006) Agarwal and Ghanekar (1970) สร้างสมการความสัมพันธ์ระหว่าง CBR กับพิกัดเหลว (Liquid limit, LL) พิกัดพลาสติก (Plastic limit, PL) หรือดัชนีพลาสติก (Plasticity index, PI) พบว่าไม่ได้มีนัยสำคัญในความสัมพันธ์ต่อกัน ส่วนสมการที่มีค่า CBR เป็นตัวแปรไม่อิสระ กับ OMC และ LL เป็นตัวแปรอิสระ จะพบว่ามีความสำคัญในความสัมพันธ์ต่อกัน กรวด (Gravel, G) ทราย (Sand, S) ดินเม็ดละเอียด (Fine content, FC) MDD, LL, PL และ OMC มีอิทธิพลต่อค่า CBR ของดินเม็ดละเอียด แต่ตัวแปร MDD เป็นตัวแปรที่มีอิทธิพลมากที่สุดในการวิเคราะห์การถดถอยเชิงเส้นอย่างง่าย (Simple linear regression analysis, SLRA) ท่ามกลางตัวแปร G, S, FC, LL, PL และ MDD การวิเคราะห์การถดถอยเชิงเส้นพหุคูณ (Multiple linear regression analysis, MLRA) มีค่าสัมประสิทธิ์ของการตัดสินใจสูงกว่า SLRA (Ramasubbarao and Sankar, 2013; Rehman, Farooq, Mujtaba, and Altaf, 2015)


Rakaraddi and Gomarsi (2015) แสดงถึง MLRA จะให้ความสัมพันธ์ระหว่างตัวแปร 2 ตัวที่ดีมากกว่า SLRA Rehman, Farooq, and Mujtaba (2017) ประมาณค่า CBR, OMC และ MDD โดยตัวแปรป้อนเข้าที่มีประสิทธิภาพคือ สัมประสิทธิ์ความสม่ำเสมอ (Coefficient of uniform, C_u) เส้นผ่านศูนย์กลางที่ผ่าน 30% (D_{30}) และเส้นผ่านศูนย์กลางที่ผ่าน 50% (D_{50}) Roy, T.K., Chattopadhyay, and Roy, S.K. (2009) เสนอสมการเพื่อประมาณค่า CBR บนพื้นฐานของ MDD หน่วยน้ำหนักน้ำ (Water unit weight, γ_w) และ OMC สำหรับดินเม็ดละเอียด Patel and Desai (2010) เสนอความสัมพันธ์ค่า CBR บนพื้นฐานของ OMC และ MDD Singh, Reddy, and Yadu (2011) ได้ทำนายค่า CBR โดยพิจารณาผลของระดับการบดอัด และปริมาณความชื้น Ferede (2010) ประมาณค่า CBR สำหรับดินเม็ดละเอียดได้ใช้ LL, PL, PI และเปอร์เซ็นต์ดินเม็ดละเอียด (Percentage of fines, F_{200}) ส่วนการประมาณค่า CBR สำหรับดินเม็ดหยาบได้ใช้เส้นผ่านศูนย์กลางที่ผ่าน 60% (D_{60}), OMC และ MDD Sivrikaya, Kayadelen, and Cecen (2013) ทำนายค่า CBR บนพื้นฐานของพารามิเตอร์การบดอัดดินสำหรับดินเม็ดหยาบโดยใช้วิธี MLRA และการโปรแกรมจีพีนของยีน (Gene expression programming, GEP)

สาขาวิชาวิศวกรรมปฐพี และสาขาวิชาต่าง ๆ ได้มีการประยุกต์ใช้โครงข่ายประสาทเทียม (Artificial neural network, ANN) พร้อมกับการวิเคราะห์ด้วยหลาย ๆ ตัวแปร (Basma and Kallas, 2004; Das and Basudhar,

2008; Gunaydin, Gokoglu, and Fener, 2010; Najjar, Basheer, and Naouss, 1996; Rafiq, Bugmann, and Easterbrook, 2001) แบบจำลองที่มีความสลับซับซ้อนจะแก้ไขปัญหาด้วยวิธีที่ซับซ้อน แต่สามารถแก้ปัญหาโดยปราศจากการใช้สมการทางกายภาพด้วย ANN (Taskiran, 2010; Shahin, 2015) วิธีการทางสถิติอาจไม่สามารถใช้ประมาณค่า CBR ในหลาย ๆ งานวิจัยที่ผ่านมาได้เพราะค่าสัมประสิทธิ์สหสัมพันธ์ต่ำและพารามิเตอร์ที่นำมาเกี่ยวข้องกับค่า CBR มักจะน้อยกว่า 2 พารามิเตอร์ แต่พารามิเตอร์สมบัติพื้นฐาน MDD, PI, OMC, S, FC, LL และ G ได้มีความสัมพันธ์กับ CBR ของดินเม็ดละเอียดด้วยวิธี ANN และ GEP (Taskiran, 2010) การทำนายค่า CBR ด้วยตัวแปร G, S, OMC และ MDD โดยวิธี ANN จะมีประสิทธิภาพสูงกว่าวิธี SLRA และ MLRA (Bhatt, Jain, and Pradesh, 2014) นอกจากนี้การทำนายค่า CBR โดยวิธี ANN จะมีประสิทธิภาพสูงกว่าวิธีการถดถอยเชิงเส้นพหุคูณ (Multiple linear regression, MLR) (Erzin and Turkoz, 2016) การพัฒนาแบบจำลองด้วยวิธี ANN และการวิเคราะห์การถดถอย (Regression analysis, RA) เป็นที่น่ายอมรับได้ (Taha et al., 2019)

ANN เป็นแขนงอย่างหนึ่งของปัญญาประดิษฐ์ (Artificial intelligence, AI) ซึ่งจะพยายามทำงานคล้ายสมองและระบบประสาทของมนุษย์ ANN ประกอบด้วยจุดต่ออยู่ในชั้นป้อนเข้า ชั้นซ่อน และชั้นผลลัพธ์ โดยแต่ละจุดต่อของชั้นใด ๆ จะเชื่อมต่อกับจุดต่ออื่น ๆ ด้วยการเชื่อมต่อแบบถ่วงน้ำหนัก การป้อนเข้าจากแต่ละจุดต่อในชั้นล่าสุดคูณด้วยการแปรเปลี่ยนน้ำหนักเชื่อมต่อที่แต่ละจุดต่อ การป้อนเข้าที่ถูกถ่วงน้ำหนักจะถูกรวมเข้าด้วยกัน และเพิ่มความเอนเอียงแล้วผ่านฟังก์ชันกระตุ้นจึงได้ผลลัพธ์ของจุดต่อ ผลลัพธ์ของจุดต่อใด ๆ จะกลายเป็นค่าป้อนเข้าไปสู่จุดต่อในชั้นถัดไป (Shahin and Jaksa, 2002) Park, Kweon, and Lee (2009) ใช้ ANN เป็นเครื่องมือที่มีความน่าเชื่อถือในการประมาณค่ามอดูลัสยืดหยุ่นของชั้นรองพื้นทางและชั้นดินเดิมจากสมบัติวัสดุเบื้องต้น เพราะการทดสอบจะมีราคาแพงและซับซ้อน

การโปรแกรมหลายนิพจน์ (Multi-expression programming, MEP) ได้ถูกนำมาประยุกต์ใช้ในงานด้านวิศวกรรมโยธาและอื่น ๆ เช่น การทำนายค่ากำลังอัดของคอนกรีตที่ผสมเถ้ากลบโดย MEP (Amin et al., 2022) Ma and Liu (2016) ได้ใช้ MEP ทำนายค่าการผลิตของบ่อน้ำมันแล้วได้ผลที่น่าพอใจมากกว่าการใช้ ANN Wang and Yin (2020) ได้พัฒนาแบบจำลอง MEP เพื่อทำนายพารามิเตอร์การบดอัดดิน (ปริมาณความชื้นที่เหมาะสม และความหนาแน่นแห้งสูงสุด) ได้ผลลัพธ์ดีกว่า SLRA และ MLRA Fallahpour, Wong, Rajoo, and Tian (2021) ได้ใช้ MEP ทำนายการบริโภคไฟฟ้าในจีนได้ดีกว่า GEP Abdalla and Mohammed (2022) ได้ใช้ MEP ประมาณค่ากำลังรับแรงอัดของมอร์ตาร์ซีเมนต์ซึ่งถูกดัดแปลงโดยเถ้าลอยแล้วได้ผลลัพธ์ที่ดีกว่า ANN นอกจากนี้ Abdalla and Salih (2022) รายงานว่า MEP สามารถทำนายค่ากำลังรับแรงอัดของมอร์ตาร์ซีเมนต์ซึ่งถูกดัดแปลงโดยแคลเซียมไฮดรอกไซด์ให้ผลที่น่าพอใจมากกว่า ANN Onyelowe et al. (2022) ได้ใช้ GEP และ MEP ในการทำนายค่ากำลังรับแรงอัดตามแนวแกนของดินไม่อิ่มตัวเนื่องจากการทดสอบค่ากำลังรับแรงอัดตามแนวแกนของดินไม่อิ่มตัวในห้องปฏิบัติการจะใช้เวลา นาน และยาก แล้วผลลัพธ์จากการทำนายด้วย GEP และ MEP เป็นที่น่าพึงพอใจมากกว่า MLRA



ภาพที่ 1 ช่วงของข้อมูลสำหรับการพัฒนาแบบจำลอง MEP

2. วิธีการศึกษา

2.1 ข้อมูลที่ใช้ในงานวิจัย

การศึกษานี้ได้ใช้วิธีการโปรแกรมหลายนิพจน์ (Multi-expression programming, MEP) ในการประมาณค่า CBR ของดินโดยใช้ข้อมูลจำนวน 96 ตัวอย่าง จาก Farias, Araujo, and Ruiz (2018) ข้อมูลถูกแบ่งออกเป็นสามชุด คือ ชุดการฝึกฝน ชุดการตรวจสอบ รวมถึงชุดการทดสอบ โดยข้อมูลเพื่อการพัฒนาแบบจำลองเท่ากับ 80% ส่วนข้อมูลเพื่อตรวจสอบแบบจำลองเท่ากับ 10% และข้อมูลเพื่อทดสอบแบบจำลองเท่ากับ 10% ตัวแปรอิสระและตัวแปรไม่อิสระจะมีช่วงของข้อมูล ดังภาพที่ 1 ซึ่งจะนำมาใช้ทำให้ค่าตัวแปรอิสระ และตัวแปรไม่อิสระให้เป็นค่ามาตรฐานอยู่ระหว่าง 0 และ 1

2.2 การโปรแกรมหลายนิพจน์

อัลกอริทึมทางพันธุกรรม (Genetic algorithm, GA) เป็นอัลกอริทึมที่ใช้ทฤษฎีวิวัฒนาการเพื่อแก้ปัญหาที่ซับซ้อนให้เหมาะสม (Goldberg, 2006) อัลกอริทึมนี้ใช้ในรูปของทศนิยมหรือเลขฐานสอง สำหรับการแก้ปัญหาซับซ้อนได้ไม่ยาก (Zhiyuan, Yongxian, and Lan, 2000) ส่วน Genetic programming (GP) คือ GA ที่พัฒนาขึ้นเพื่อสร้างนิพจน์สตริง เช่น tree (Koza, 1992) นอกจากนี้ การโปรแกรมหลายนิพจน์ (MEP) เป็นวิธี GP เชิงเส้นโดยใช้โครโมโซมเชิงเส้น (Oltean and Grosan, 2003) เพื่อให้ได้นิพจน์ที่ดีที่สุด กระบวนการอัลกอริทึม MEP จะดำเนินต่อไปจนกว่าได้ตามเป้าหมายเงื่อนไข โดยเริ่มต้นจากการ

สร้างประชากรแบบสุ่ม แล้วพ่อแม่สองคนได้รับเลือกโดยใช้กระบวนการแข่งขันแบบไบนารี (Binary tournament) และสลับสายพันธุ์ (Crossover) พ่อแม่อีกครั้งด้วยความน่าจะเป็นสลับสายพันธุ์ที่กำหนด (Crossover probability) จึงได้ลูกหลานสองคน ต่อมาลูกหลานจะกลายพันธุ์ (Mutation) ก่อนที่ตัวที่แย่ที่สุดจะถูกแทนที่ด้วยตัวที่ดีที่สุดจากประชากรปัจจุบัน

การเป็นตัวแทนของ MEP นั้นคล้ายคลึงกับ C และ Pascal compilers ที่แปลงนิพจน์ทางคณิตศาสตร์เป็นรหัสเครื่อง ยินต่อโครโมโซมซึ่งมีค่าคงที่ คือ ความยาวของโครโมโซม ยินแต่ละตัวจะให้คำแนะนำสำหรับการสร้างสัญลักษณ์เทอร์มินัล (Terminal sign) หรือสัญลักษณ์ฟังก์ชัน (Function sign) ยินที่เข้ารหัสฟังก์ชันจะประกอบด้วยตัวชี้ไปยังอาร์กิวเมนต์ของฟังก์ชัน พารามิเตอร์ของฟังก์ชันมักจะมีดัชนีของค่าน้อยกว่าตำแหน่งของฟังก์ชันนั้นของตัวมันเองในโครโมโซม สัญลักษณ์ตัวแรกในโครโมโซมจะต้องเป็นสัญลักษณ์เทอร์มินัล ส่วนตัวอย่างของโครโมโซมของ MEP ได้แสดงดังข้างล่างต่อไปนี้

- 1: x_1
- 2: x_2
- 3: /, 1, 2
- 4: x_3
- 5: pow, 3, 4
- 6: x_4
- 7: *, 6, 5

ชุดฟังก์ชัน = {/, pow, * etc.} และชุดเทอร์มินัล = $\{x_1, x_2, x_3, x_4\}$ ใช้เพื่อเข้ารหัสโปรแกรม MEP สัญลักษณ์เทอร์มินัลระบุนิพจน์พื้นฐาน และสัญลักษณ์ฟังก์ชันระบุนิพจน์ที่ซับซ้อน ยิน 1, 2, 4, 6 เข้ารหัสนิพจน์พื้นฐานที่สร้างโดยสัญลักษณ์เทอร์มินัลเดี่ยวดังต่อไปนี้

$$\begin{aligned} E_1 &= x_1 \\ E_2 &= x_2 \\ E_4 &= x_3 \end{aligned}$$

$$E_6 = x_4$$

ยีน 3 แสดงการทำงานหาร (/) บนตัวถูกดำเนินการที่ตำแหน่ง 1 และ 2 ของโครโมโซม ดังนั้นการเข้ารหัสยีน E_3 จะได้ว่า

$$E_3 = (x_1 / x_2)$$

ยีน 5 แสดงการทำงานยกกำลัง (pow) บนตัวถูกดำเนินการที่ตำแหน่ง 3 และ 4 ของโครโมโซม ดังนั้นการเข้ารหัสยีน E_5 จะได้ว่า

$$E_5 = (x_1 / x_2)^{x_3}$$

ยีน 7 แสดงการทำงานคูณ (*) บนตัวถูกดำเนินการที่ตำแหน่ง 3 และ 4 ของโครโมโซม ดังนั้นการเข้ารหัสยีน E_7 จะได้ว่า

$$E_7 = x_4 (x_1 / x_2)^{x_3}$$

นิพจน์ทั้งหมดเหล่านี้จะสามารถใช้แก้ไขปัญหาที่เกิดขึ้นได้ ความเหมาะสมของแต่ละนิพจน์ถูกคำนวณเพื่อหานิพจน์ที่มีการเข้ารหัสที่ดีที่สุดในโครโมโซม MEP ในการถดถอยเชิงสัญลักษณ์ (Oltean and Grosan, 2003)

2.3 การพัฒนาแบบจำลอง MEP

ในการศึกษาครั้งนี้มีเป้าหมายเพื่อหาสูตรสำหรับการประมาณค่า CBR ซึ่งเป็นฟังก์ชันของตัวแปรป้อนเข้าในตารางที่ 1 การพัฒนาแบบจำลอง MEP จำนวน 6 รูปแบบจำลอง ซึ่งมีตัวแปรป้อนเข้าหลากหลาย จะต้องพิจารณาหลาย ๆ พารามิเตอร์ เช่น ชุดฟังก์ชัน ชุดเทอร์มินัล จำนวนของประชากรกลุ่มย่อย ขนาดประชากรกลุ่มย่อย และความยาวโครโมโซม เป็นต้น พารามิเตอร์เหล่านี้ได้จากการลองผิดลองถูก (Trial and error) แสดงดังตารางที่ 2 ข้อมูลที่นำมาใช้กับการพัฒนาแบบจำลอง MEP จะทำให้เป็นค่ามาตรฐานระหว่าง 0 ถึง 1 เพื่อลดปัญหาของมิติ และเพื่อฝึกฝนแบบจำลอง MEP โดยสมการแปลงข้อมูลให้เป็นค่ามาตรฐานจะมีค่าดังต่อไปนี้

$$X_n = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (1)$$

การวิเคราะห์ที่ใช้ Python 3.8.5 และ MEPX Software เพื่อใช้ทำนายค่า CBR ที่เหมาะสมมากที่สุด ประสิทธิภาพการทำนายของแบบจำลอง MEP ที่พัฒนาขึ้น สามารถประเมินได้จากค่าสัมประสิทธิ์ของการตัดสินใจ (Coefficient of determination, R^2) และค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์ (Mean absolute error, MAE) ระหว่างค่า CBR ที่วัดได้ และที่ถูกทำนายไว้ สำหรับชุดการฝึกฝน ชุดการตรวจสอบ และชุดการทดสอบ

2.4 ความเชื่อถือได้

ความเชื่อถือได้ (Reliability) คือ สิ่งที่ใช้วัดความน่าเชื่อถือของเครื่องมือที่ใช้วัดตัวอย่าง เมื่อนำเครื่องมือไปวัดตัวอย่าง 2 ครั้ง แล้วผลจากการวัดจะต้องมีลักษณะคล้ายกัน (วิธีการวัดซ้ำ) สำหรับงานวิจัยครั้งนี้จะใช้วิธีการวัดซ้ำโดยวัดความสัมพันธ์ระหว่าง CBR ที่ประมาณค่า และ CBR ที่วัดได้ จากข้อมูลตัวอย่างทดสอบทั้งหมด 96 กรณี ที่ระดับความเชื่อมั่น เท่ากับ 0.95 การหาค่าความเชื่อถือได้ถูกดำเนินการใน Python 3.8.5 โดยความสัมพันธ์กันในลักษณะเดียวกันและสูง จะบ่งชี้ว่าเครื่องมือ (แบบจำลอง) มีความน่าเชื่อถือสูง

ตารางที่ 1 ตัวแปรป้อนเข้าสำหรับแบบจำลอง MEP ซึ่งถูกใช้ประมาณค่า CBR

แบบจำลอง	ตัวแปรป้อนเข้า
I	G, S, FC, LL, PI, OMC, MDD
II	S, FC, LL, PI, OMC, MDD
III	S, PI, OMC, MDD
IV	LL, PI, OMC, MDD
V	FC, PI, OMC, MDD
VI	G, S, PI, MDD


ตารางที่ 2 พารามิเตอร์สำหรับแบบจำลอง MEP ซึ่งถูกใช้ประมาณค่า CBR

พารามิเตอร์	กำหนดค่า
ชุดฟังก์ชัน	+ , - , * , / , $\sqrt{\quad}$, exp , pow10 , ln
ชุดเทอร์มินัล	ตัวแปรป้อนเข้าในแต่ละแบบจำลอง (ตารางที่ 1)
จำนวนของประชากรกลุ่มย่อย	10
ขนาดประชากรกลุ่มย่อย	500
ความยาวโครโมโซม	50
ความน่าจะเป็นการสลับสายพันธุ์	0.9
ชนิดการสลับสายพันธุ์	สม่ำเสมอ
ความน่าจะเป็นกลายพันธุ์	0.01
ขนาดกระบวนการแข่งขันแบบไบนารี	2
จำนวนรุ่น	700

3. ผลการศึกษา

3.1 ผลการวิเคราะห์การกระจายข้อมูล

ภาพที่ 2 แสดงการกระจายของข้อมูลของตัวแปรในลักษณะความถี่ ดินส่วนใหญ่จะมีค่า G จาก 0 และ 20 % (ภาพที่ 2a) และจะมี S จาก 16 ถึง 44% (ภาพที่ 2b) ขณะที่ FC ในดินส่วนใหญ่จะมีค่าระหว่าง 0 และ 20% (ภาพที่ 2c) ส่วนมากดินจะมี LL ระหว่าง 15 และ 24% (ภาพที่ 2d) ส่วน PI จะมีค่าส่วนมากจาก 1 ถึง 10.2% (ภาพที่ 2e) OMC จะมีค่าส่วนใหญ่จาก 4.5 ถึง 7.2% (ภาพที่ 2f) MDD และ CBR จะมีความถี่สูงสุดในระหว่าง 2.07 และ 2.22 g/cm³ และ 1 ถึง 21% ตามลำดับ (ภาพที่ 2g และ 2h)



ภาพที่ 2 การกระจายข้อมูลของข้อมูลป้อนเข้า และผลลัพธ์

3.2 ผลการวิเคราะห์ MEP

ประสิทธิภาพของแบบจำลอง MEP สามารถสรุปได้ดังตารางที่ 3 R^2 ของแบบจำลอง I และ II ในชุดการฝึกฝน ได้มีค่าสูงเกือบเท่ากัน ส่วนในชุดการตรวจสอบจะพบว่าแบบจำลอง II จะมีค่า R^2 มากกว่าแบบจำลอง I อย่างไรก็ตาม ค่า R^2 ของแบบจำลอง II จะมีค่าน้อยกว่าแบบจำลอง I ในชุดการทดสอบ นั่นคือ แบบจำลอง II จะมีความถูกต้องสูงในชุดการฝึกฝน แต่ความถูกต้องน้อยในชุดการทดสอบ ขณะที่แบบจำลอง I มีค่า R^2 สูง และ MAE ต่ำทั้งสามชุดข้อมูล (ชุดการฝึกฝน ชุดการตรวจสอบ และชุดการทดสอบ) ดังนั้นแบบจำลอง MEP ที่เหมาะสม คือ แบบจำลอง I หรือสมการ (2) ดังต่อไปนี้

ตารางที่ 3 ประสิทธิภาพของแบบจำลอง MEP ซึ่งถูกใช้ประมาณค่า CBR

แบบจำลอง	ชุดการฝึกฝน		ชุดการตรวจสอบ		ชุดการทดสอบ	
	R ²	MAE	R ²	MAE	R ²	MAE
I	0.906	5.138	0.975	3.339	0.705	8.322
II	0.905	5.173	0.985	2.397	0.535	11.368
III	0.836	7.363	0.882	5.447	0.607	9.717
IV	0.702	9.763	0.931	5.896	0.597	11.369
V	0.886	6.051	0.978	3.605	0.579	11.137
VI	0.856	6.787	0.970	2.967	0.136	14.082

$$\text{โดย} \quad \text{CBR} = 80D_6 + 1 \quad (2)$$

$$D_1 = 10^{0.08 \cdot \text{OMC} - 0.36} + \frac{G}{47} - \frac{2\text{PI}}{23} + \frac{2}{23} \quad (3)$$

$$D_2 = \left(\frac{2\text{PI} - 2}{23} \right) D_1 \quad (4)$$


$$D_3 = \frac{\text{LL}}{36} - \frac{103}{276} + \frac{G}{94} - \frac{\text{PI}}{23} \quad (5)$$

$$D_4 = D_2 * D_3 \quad (6)$$

$$D_5 = \frac{D_4 + \frac{G}{94}}{10^{\frac{\text{PI} - 1}{23}}} \quad (7)$$

$$D_6 = \frac{D_5 + \frac{S}{98} - \frac{1}{49}}{10^{0.08 \cdot \text{OMC} - 0.36}} \quad (8)$$

ค่าฟังก์ชัน D_1 , D_2 , D_3 , D_4 , D_5 และ D_6 ได้มีตัวแปรอิสระ G , S , LL , PI และ OMC ในสมการ (3) - (8) การใช้ฟังก์ชัน D_1 ถึง D_6 ในสมการ (2) เพื่อหาค่า CBR โดยตัวแปรป้อนเข้าจะต้องมีค่าอยู่ระหว่างค่าต่ำสุดและค่าสูงสุดตามที่กำหนดในภาพที่ 1 ผลการทำนายค่าด้วยแบบจำลอง MEP จะมีค่าเบี่ยงเบนน้อยด้วยการใช้ตัวแปรป้อนเข้าที่มีค่าอยู่ระหว่างค่าต่ำสุด และค่าสูงสุด (Pala, 2006) ค่า CBR ที่คำนวณจากแบบจำลอง I หรือสมการ (2) ได้ถูกเปรียบเทียบกับค่า CBR ที่วัดได้ในชุดการทดสอบจะถูกพล็อตจุดในภาพที่ 3 แล้วจะพบว่ามีความสัมพันธ์กันอย่างมาก




ภาพที่ 3 ค่า CBR ซึ่งถูกประมาณค่าจากแบบจำลอง I เปรียบเทียบกับค่า CBR ที่วัดได้ในชุดทดสอบ

3.3 ความเชื่อถือได้


เมื่อพิจารณาแบบจำลอง I หรือสมการ (2) ที่ระดับความเชื่อมั่นเท่ากับ 0.95 จะหาค่าความเชื่อถือได้จากข้อมูลตัวอย่างทดสอบทั้งหมด 96 กรณี มีค่าเท่ากับ 0.953 ซึ่งมีค่าเข้าใกล้ 1 ทำให้แบบจำลองมีความเชื่อถือได้สูง และได้อยู่ในขอบเขตของช่วงความเชื่อมั่น ซึ่งมีค่าขอบเขตล่าง 0.93 และค่าขอบเขตบน 0.968

3.4 อภิปรายผลการวิจัย

การประเมินค่า CBR โดยใช้แบบจำลอง MLR และแบบจำลอง ANN (แบบจำลอง 5) จาก Intaratchaiyakit (2023) ได้ถูกนำมาเปรียบเทียบกับแบบจำลอง MEP (แบบจำลอง I) ในการวิจัยครั้งนี้ด้วยค่า R^2 จากภาพที่ 4 จะพบว่า ค่า R^2 ของแบบจำลอง MLR จะน้อยที่สุดในบรรดาแบบจำลอง MLR, ANN และ MEP ในทั้งสามชุดข้อมูล (ชุดการฝึกฝน ชุดการตรวจสอบ และชุดการทดสอบ) ขณะที่แบบจำลอง MEP จะให้ผลเป็นที่น่าพึงพอใจมากที่สุดเนื่องจากในชุดการฝึกฝน ค่า R^2 ของแบบจำลอง MEP ($R^2 = 0.906$) ได้มีค่ามากกว่าแบบจำลอง ANN ($R^2 = 0.905$) นอกจากนี้ ในชุดการทดสอบ ค่า R^2 ของแบบจำลอง MEP ($R^2 = 0.705$) ได้มีค่ามากกว่าแบบจำลอง ANN ($R^2 = 0.674$) ขณะที่ภาพที่ 5 แสดงค่า MAE ของแบบจำลอง MLR, ANN และ MEP โดยแบบจำลอง MLR จะมีค่า MAE มากที่สุดในบรรดาแบบจำลอง MLR, ANN และ MEP ในทั้งสามชุดข้อมูล (ชุดการฝึกฝน ชุดการตรวจสอบ และชุดการทดสอบ) ขณะที่แบบจำลอง MEP จะให้ผลเป็นที่น่าพึงพอใจมากที่สุดเนื่องจากในชุดการฝึกฝน ค่า MAE ของแบบจำลอง MEP (MAE = 5.138) มีค่าน้อยกว่าแบบจำลอง ANN (MAE = 5.94) นอกจากนี้ ในชุดการทดสอบ ค่า MAE ของแบบจำลอง MEP (MAE = 8.322) ได้มีค่าน้อยกว่าแบบจำลอง ANN (MAE = 9.413) จากเหตุผลดังกล่าว ดังนั้นแบบจำลอง MEP ที่พัฒนาขึ้นมีประสิทธิภาพที่มากกว่าแบบจำลอง MLR และ ANN ซึ่งสอดคล้องกับงานวิจัยอื่นที่ได้กล่าวถึงว่าแบบจำลอง ANN มีประสิทธิภาพที่มากกว่าแบบจำลอง MLR (Bhatt et al., 2014; Erzin and Turkoz, 2016) และแบบจำลอง MEP ได้มีประสิทธิภาพที่มากกว่าแบบจำลอง ANN สำหรับการศึกษาในครั้งนี้ นอกจากนี้ แบบจำลอง MEP ได้มีความเชื่อถือได้เท่ากับ 0.953 ซึ่งมีค่าเข้าใกล้ 1 จึงทำให้แบบจำลองมีความน่าเชื่อถือมาก



ภาพที่ 4 ค่า R^2 ของแบบจำลอง MLR, ANN และ MEP



ภาพที่ 5 ค่า MAE ของแบบจำลอง MLR, ANN และ MEP

4. สรุป

การทำนายค่า CBR โดยใช้แบบจำลอง MEP จำนวน 6 รูปแบบ ซึ่งมีพารามิเตอร์ป้อนเข้าที่แตกต่างกัน จะพบว่า แบบจำลอง I มีค่า R^2 สูง และ MAE ต่ำทั้งสามชุดข้อมูล (ชุดการฝึกฝน ชุดการตรวจสอบ และชุดการทดสอบ) จึงทำให้แบบจำลอง I ถูกเลือกให้เป็นแบบจำลอง MEP ที่เหมาะสม ซึ่งแบบจำลอง MEP ที่พัฒนาขึ้นมีประสิทธิภาพที่มากกว่าแบบจำลอง MLR และ ANN นอกจากนี้ แบบจำลอง MEP ได้มีความน่าเชื่อถือมากเนื่องจากค่าความเชื่อถือได้มีค่าสูง ดังนั้นสมการคณิตศาสตร์ใหม่จึงได้จากแบบจำลอง MEP (แบบจำลอง I) แล้วนำไปประยุกต์ใช้ในการทำนายค่า CBR สำหรับการออกแบบเบื้องต้นในด้านงานปฐพีเพื่อลดค่าใช้จ่าย และเวลา

5. เอกสารอ้างอิง

- Abdalla, A., & Mohammed, A. S. (2022). Surrogate Models to Predict the Long-Term Compressive Strength of Cement-Based Mortar Modified with Fly Ash. *Arch. Computat Methods Eng.*, 29: 4187-4212. <https://doi.org/10.1007/s11831-022-09734-7>
- Abdalla, A., & Salih, A. (2022). Implementation of multi-expression programming (MEP), artificial neural network (ANN), and M5P-tree to forecast the compression strength cement-based mortar modified by calcium hydroxide at different mix proportions and curing ages. *innov. Infrastruct. Solut.*, 7(2): 153. <https://doi.org/10.1007/s41062-022-00761-8>
- Agarwal, K.B. & Ghanekar, K.D. (1970). Prediction of CBR from plasticity characteristics of soil. In: *Proceeding of 2nd south-east Asian conference on soil engineering, Singapore. June 11-15. Bangkok: Asian Institute of Technology.* 571-576.

- Alawi, M. & Rajab, M. (2013). Prediction of California bearing ratio of subbase layer using multiple linear regression models. **Road Mater. Pavement Des.**, **14**(1): 211-219. DOI: 10.1080/14680629.2012.757557
- Amin, M.N., Khan, K., Javed, M.F., Ewais, D.Y.Z., Qadir, M.G.; Faraz, M.I., Alam, M.W., Alabdullah, A.A., & Imran, M. (2022). Forecasting Compressive Strength of RHA Based Concrete Using Multi-Expression Programming. **MATLS.**, **15**: 3808. <https://doi.org/10.3390/ma15113808>
- Basma, A. A. & Kallas, N. (2004). Modeling soil collapse by artificial neural networks. **Geotech.**, **22**: 427-438.
- Bhatt, S., Jain, P. K., & Pradesh, M. (2014). Prediction of California bearing ratio of soils using artificial neural network. **AJRSTEM.**, **8**(2): 156-161.
- Das, S. K. & Basudhar, P. (2008). Prediction of residual friction angle of clay artificial neural network. **Eng Geol.**, 142-145.
- Erzin, Y. & Turkoz, D. (2016). Use of neural networks for the prediction of the CBR value of some Aegean sands. **Neural Comput.**, **27**: 1415-1426.
- Fallahpour, A., Wong, K. Y., Rajoo, S., & Tian, G. (2021). An evolutionary-based predictive soft computing model for the prediction of electricity consumption using multi expression programming. **J. Clean. Prod.**, **283**: 125287. <https://doi.org/10.1016/j.jclepro.2020.125287>
- Ferede, Z.W. (2010). **Prediction of California Bearing Ratio (CBR) value from Index Properties of Soil**. M.Sc. dissertation, Department of Civil Engineering, Addis Ababa Institute of Technology (AAIT).
- Gandomi, A. H., Alavi, A. H., & Yun, G. J. (2011). Formulation of uplift capacity of suction caissons using multi expression programming. **KSCE J. Civ. Eng.**, **15**(2): 363-373. <https://doi.org/10.1007/s12205-011-1117-9>
- Goldberg, D.E. 2006. **Genetic Algorithms**, Pearson Education India: London, UK.
- Gunaydin, O., Gokoglu, A. & Fener, M. (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., Araujo, W., & Ruiz, G. (2018). Prediction of California Bearing Ratio from Index Properties of Soils Using Parametric and Non-parametric Models. **Geotech.**, **36**: 3485-3498.
- Intaratchaiyakit, N. (2023). Estimation of California Bearing Ratio by Artificial Neural Network. **RMUTTO RJ.**, **16**(1): 1-10. (In Thai).
- Koza, J.R. (1992). **Genetic Programming: On the Programming of Computers by Means of Natural Selection**. MIT Press: Cambridge, MA, USA, Volume 1.
- Lakshmi, S.M., Subramanian, M. S., Lalithambikhai, P., Vela, A. M. & Ashni, M. (2016). Evaluation of soaked and unsoaked CBR values of soil based on the compaction characteristics. **MJCE.**, **28**(2): 172-182.
- Ma, X. & Liu, Z-b. (2016). Predicting the Oil Well Production Based on Multi Expression Programming. **The Open Petroleum Engineering Journal**, **9**(1): 21-32.

- MEPX software. (2022). **MEPX software**. Access 5 Jan 2022, from https://mepx.org/mepx_software.html.
- Najjar, Y. M., Basheer, I. A., & Naouss, W. A. (1996). On the identification of compaction characteristics by neuronets. **Comput Geotech.**, **18**(3): 167-187.
- Oltean, M. & Grosan, C. (2003). A comparison of several linear genetic programming techniques. **Complex Syst.**, **14**: 285-314.
- Onyelowe, K.C., Jalal, F.E., & Iqbal, M. (2022). Intelligent modeling of unconfined compressive strength (UCS) of hybrid cement-modified unsaturated soil with nanostructured quarry fines inclusion. **Innov. Infrastruct. Solut.**, **98**(7). <https://doi.org/10.1007/s41062-021-00682-y>
- Pala, M. (2006). A new formulation for distortional buckling stress in cold-formed steel members. **J Constr Steel Res.**, **62**: 716-722.
- Park, H. I., Kweon, G. C., & Lee, S. R. (2009). Prediction of resilient modulus of granular subgrade soils and subbase materials using artificial neural network. **Road Mater. Pavement Des.**, **10**(3): 647-665.
- Patel, R. S. & Desai, M.D. (2010). CBR Predicted by Index Properties of Soil for Alluvial Soils of South Gujarat. **IGC, Proc. IGC**, **1**: 79-82.
- Ramasubbarao, G. V. & Sankar, G. S. (2013). Predicting Soaked CBR Value of Fine Grained Soils Using Index and Compaction Characteristics. **Jordan J. Civ. Eng.**, **7**(3): 354-360.
- Rafiq M. Y., Bugmann, G., & Easterbrook, D. J. (2001). Neural network design for engineering applications. **Comput Struct.**, **79**: 1541-1552.
- Rakaraddi, P. G. & Gomarsi, V. (2015). Establishing relationship between CBR with different soil properties. **Int. Res. J. Eng. Technol.**, **4**(2): 182-188.
- Rehman, A.U., Farooq, K., Mujtaba, H., & Altaf, O. (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., Farooq, K., & Mujtaba, H. (2017). Prediction of California bearing ratio (CBR) and compaction characteristics of granular soils. **Acta Geotech. Slov.**, **14**(1): 62-72.
- Roy, T.K., Chattopadhyay, B.C., & Roy, S.K. (2009). Prediction of CBR from Compaction Characteristics of Cohesive Soil. **highw. res. J.**, July-Dec 2009. 77-88.
- Shahin, M.A. & Jaksa, M. (2002). Artificial neural network-based settlement prediction formula for shallow foundations on granular soils. **Aust. Geomech.**, 45-52.
- Shahin, M.A. (2015). A review of artificial intelligence applications in shallow foundations. **Int. J. Geotech.**, **9**: 49-60.
- Singh, D., Reddy, K.S., & Yadu, L. (2011). Moisture and Compaction Based Statistical Model for Estimating CBR of Fine-Grained Sub grade Soils. **Int. J. Earth Sci. Eng.**, **4**(6): 100-103.
- Sivrikaya, O., Kayadelen, C., & Cecen, E. (2013). Prediction of the compaction parameters for coarse-grained soils with fines content by MLR and GEP. **Acta Geotech.**, **2**: 29-41.
- Taha, S., Gabr, A. & El-Badawy, S. (2019). Regression and Neural Network Models for California Bearing Ratio Prediction of Typical Granular Materials in Egypt. **Arab J Sci Eng.**, **44**: 8691-8705.

- Taskiran, T. (2010). Prediction of California bearing ratio (CBR) of fine-grained soils by AI methods. **Adv. Eng. Softw.**, **41**(6): 886-892.
- Wai, K. M. (2006). **California bearing ratio correlation with soil index properties master of engineering (civil-geotechnics)**. Faculty of Civil Engineering, University Teknologi Malaysia.
- Wang, H.-L., & Yin, Z.-Y. (2020). High performance prediction of soil compaction parameters using multi expression programming. **Eng. Geol.**, **276**, 105758. <https://doi.org/10.1016/j.enggeo.2020.105758>.
- Yildirim, B. & Gunaydin, O. (2011). Estimation of California bearing ratio by using soft computing systems. **Expert Syst. Appl.**, **38**(5): 6381-6391.
- Zhiyuan G., Yongxian W., & Lan N. (2000). Genetic algorithms based on bin tree structure encoding. **J Tsinghua Univ.**, **40**(10): 125-128.
- Zumrawi, M. (2012). Prediction of CBR from index properties of cohesive soils. **Conference: 2nd International Conference on Civil Engineering and Building Materials (CEBM 2012)**, 17-18 Nov, 2012. At: Hong Kong Volume: Adv. Civ. Eng. - Edited by Shuenn - Yih Chang, Suad Khalid Al Bahar & Jingying Zhao.

(Received: 6/Feb/2023, Revised: 2/Oct/2023, Accepted: 22/Dec/2023)