

การออกแบบขนาดและรูปร่างของโครงถักสามมิติอย่างเหมาะสม ด้วยวิธีการปรับปรุงการเรียนรู้อย่าง  
ครอบคลุมเพื่อหาค่าเหมาะสมที่สุดของกลุ่มอนุภาคร่วมกับแบบจำลองการถดถอยของกระบวนการ  
เกาส์เซียน



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต  
สาขาวิชาวิศวกรรมโยธา ภาควิชาวิศวกรรมโยธา  
คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย  
ปีการศึกษา 2565  
ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

A combined enhanced comprehensive learning particle swarm optimization with  
Gaussian process regression model for size and shape optimization of space trusses.



A Thesis Submitted in Partial Fulfillment of the Requirements  
for the Degree of Master of Engineering in Civil Engineering

Department of Civil Engineering

FACULTY OF ENGINEERING

Chulalongkorn University

Academic Year 2022

Copyright of Chulalongkorn University

หัวข้อวิทยานิพนธ์

การออกแบบขนาดและรูปร่างของโครงสร้างสามมิติอย่าง  
เหมาะสม ด้วยวิธีการปรับปรุงการเรียนรู้อย่างครอบคลุม  
เพื่อหาค่าเหมาะสมที่สุดของกลุ่มอนุภาคร่วมกับแบบจำลอง  
การถดถอยของกระบวนการเกาส์เซียน

โดย

น.ส.วรัญญา เจริญยิ่ง

สาขาวิชา

วิศวกรรมโยธา

อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก

รองศาสตราจารย์ ดร.เสวกชัย ตั้งอร่ามวงศ์

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้บัณฑิตวิทยาลัย  
ของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต

..... คณบดีคณะวิศวกรรมศาสตร์  
(ศาสตราจารย์ ดร.สุพจน์ เตชวรสินสกุล)

คณะกรรมการสอบวิทยานิพนธ์

..... ประธานกรรมการ  
(รองศาสตราจารย์ ดร.พิชชา จองวิวัฒน์สกุล)

..... อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก  
(รองศาสตราจารย์ ดร.เสวกชัย ตั้งอร่ามวงศ์)

..... กรรมการภายนอกมหาวิทยาลัย  
(รองศาสตราจารย์ ดร.กนต์ไชย ธนาพรรวีศักดิ์)

วรัญญา เจริญยิ่ง : การออกแบบขนาดและรูปร่างของโครงถักสามมิติอย่างเหมาะสม ด้วยวิธีการปรับปรุงการเรียนรู้อย่างครอบคลุมเพื่อหาค่าเหมาะสมที่สุดของกลุ่มอนุภาค ร่วมกับแบบจำลองการถดถอยของกระบวนการเกาส์เซียน. ( A combined enhanced comprehensive learning particle swarm optimization with Gaussian process regression model for size and shape optimization of space trusses.) อ.ที่ปรึกษาหลัก : รศ. ดร.เสวกชัย ตั้งอร่ามวงศ์

บทความนี้นำเสนอหนึ่งในเครื่องมือการเรียนรู้ของเครื่อง คือวิธีการถดถอยของกระบวนการเกาส์เซียน (Gaussian process regression, GPR) ร่วมกับอัลกอริทึมการปรับปรุงการเรียนรู้แบบครอบคลุมเพื่อหาค่าเหมาะสมที่สุดของกลุ่มอนุภาค (Enhanced Comprehensive Learning Particle Swarm Optimization, ECLPSO) เพื่อหาขนาดและรูปร่างที่เหมาะสมอย่างพร้อมกันของโครงถัก 3 มิติ ภายใต้แรงกระทำจากภายนอก เมื่อเทียบกับเทคนิคการออกแบบด้วยวิธีเมตา-ฮิวริสติก แนวทางนี้จะสามารถลดขั้นตอนในการวิเคราะห์โครงสร้างด้วยระเบียบวิธีไฟไนต์เอลิเมนต์ที่ใช้เวลานานได้ โดยเป็นการสร้างแบบจำลองการทำนายพฤติกรรมของโครงสร้าง จากชุดข้อมูลอินพุต เช่น ตำแหน่งพิกัดข้อต่อและขนาดชิ้นส่วน และข้อมูลเอาต์พุตที่สร้างโดยชุดข้อมูลการวิเคราะห์โครงสร้าง เช่น แรงภายในชิ้นส่วนและการเคลื่อนที่ของตำแหน่งข้อต่อ จากนั้นอัลกอริทึม ECLPSO จะดำเนินการร่วมกับแบบจำลอง GPR ที่มีการคาดคะเนการตอบสนองที่แม่นยำเพียงพอ ผลลัพธ์ที่ได้จากวิธีการที่นำเสนอ คือน้ำหนักรวมของโครงสร้างที่มีค่าต่ำที่สุด ซึ่งแสดงให้เห็นถึงความแม่นยำและประสิทธิภาพของอัลกอริทึม

จุฬาลงกรณ์มหาวิทยาลัย  
CHULALONGKORN UNIVERSITY

สาขาวิชา วิศวกรรมโยธา  
ปีการศึกษา 2565

ลายมือชื่อนิสิต .....  
ลายมือชื่อ อ.ที่ปรึกษาหลัก .....

# # 6470269621 : MAJOR CIVIL ENGINEERING

KEYWORD: Enhanced comprehensive learning particle swarm optimization,  
Space trusses, Machine learning, Gaussian process regression, Size  
and shape optimization

Warunya Charoenying : A combined enhanced comprehensive learning  
particle swarm optimization with Gaussian process regression model for  
size and shape optimization of space trusses.. Advisor: Assoc. Prof.  
SAWEKCHAI TANGARAMVONG, Ph.D.

The paper proposes the combined machine learning-based, called Gaussian process regression (GPR), method with enhanced comprehensive learning particle swarm optimization (ECLPSO) algorithm to perform the simultaneous size and shape optimization of space trusses under applied forces. At variance with standard meta-heuristic design techniques, the approach advantageously by-passes the need to iteratively call the time-consuming finite element analyses for structural responses through the construction of the GPR predictive model. The model maps out the accurate structural behaviors from the sufficient input (i.e., nodal coordinates and member sizes) and output (member forces and nodal displacements) dataset generated by a series of structural analyses. The ECLPSO algorithm is then performed solely on the computed GPR model presenting the sufficiently accurate response predictions. The accuracy and robustness of the proposed method are illustrated through the designs of space trusses successfully solved, where the minimum total weight can be achieved.

Field of Study: Civil Engineering

Student's Signature .....

Academic Year: 2022

Advisor's Signature .....

## กิตติกรรมประกาศ

วิทยานิพนธ์นี้ได้รับการสนับสนุนงบประมาณวิจัยจากทุนวิศวกรรมโยธา 100 ปี และกองทุน  
รัชดาภิเษกสมโภช ภาควิชาวิศวกรรมโยธา คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

ขอขอบคุณอาจารย์ที่ปรึกษา รศ.ดร.เสวกชัย ตั้งอร่ามวงศ์ ที่ให้แรงบันดาลใจ ก่อให้เกิดหัวข้อ  
งานวิจัยชิ้นนี้ ทั้งยังให้คำแนะนำ ความรู้ และกำลังใจอันสำคัญกับผู้วิจัยตลอดระยะเวลาที่ผ่านมา  
รวมทั้งรศ.ดร.พิชชา จองวิวัฒน์สกุล ประธานการสอบวิทยานิพนธ์ และรศ.ดร.กนต์ไชย ธนาพรวิภักดิ์  
กรรมการภายนอกมหาวิทยาลัย ที่ให้ความอนุเคราะห์และให้คำปรึกษาเป็นอย่างดี และขอขอบคุณ  
นายอานัติ สุธา นิสิตระดับปริญญาเอกที่คอยสนับสนุนผู้วิจัยอย่างเต็มที่ ทั้งได้ให้คำปรึกษาเกี่ยวกับ  
กระบวนการวิจัย และการใช้โปรแกรมวิเคราะห์ออกแบบงานวิจัยนี้เสร็จสมบูรณ์

วรัญญา เจริญยิ่ง



## สารบัญ

	หน้า
.....	ค
บทคัดย่อภาษาไทย.....	ค
.....	ง
บทคัดย่อภาษาอังกฤษ.....	ง
กิตติกรรมประกาศ.....	จ
สารบัญ.....	ฉ
สารบัญตาราง.....	ฉ
สารบัญรูปภาพ.....	ญ
บทที่ 1 บทนำ.....	1
1.1 กล่าวนำ.....	1
1.2 วัตถุประสงค์.....	2
1.3 ขอบเขตการวิจัย.....	2
1.4 ระเบียบวิธีการวิจัย.....	3
บทที่ 2 งานวิจัยที่เกี่ยวข้อง.....	4
2.1 การออกแบบขนาดและรูปร่างของโครงถักอย่างเหมาะสม (Size and shape truss structural optimization).....	4
2.2 วิธีการรวมสติฟเนสโดยตรง (Direct Stiffness Method).....	6
2.2.1 การวิเคราะห์โครงสร้างแบบเชิงเส้น (Linear Analysis).....	6
2.2.2 การวิเคราะห์โครงสร้างโดยใช้คอมพิวเตอร์ในการคำนวณ.....	7
2.3 การถดถอยของกระบวนการเกาส์เซียน (Gaussian Process Regression).....	8
2.3.1 การถดถอย (Regression).....	8

2.3.2 การทำนายค่าเป้าหมายด้วยกระบวนการเกาส์เซียน .....	9
2.4 การปรับปรุงที่คาดหวัง (Expected Improvement, EI).....	13
2.5 การปรับปรุงการเรียนรู้แบบครอบคลุมเพื่อหาค่าเหมาะสมที่สุดของกลุ่มอนุภาค (Enhanced Comprehensive Learning Particle Swarm Optimization, ECLPSO) .....	14
2.5.1 การหาค่าเหมาะสมที่สุดของกลุ่มอนุภาค .....	14
2.5.2 การเรียนรู้แบบครอบคลุมเพื่อหาค่าเหมาะสมที่สุดของกลุ่มอนุภาค .....	17
2.5.3 การปรับปรุงการเรียนรู้แบบครอบคลุมเพื่อหาค่าเหมาะสมที่สุดของกลุ่มอนุภาค .....	21
บทที่ 3 ตัวอย่างปัญหาการวิเคราะห์โครงสร้าง .....	25
3.1 Problem Statement .....	25
3.2 โครงงัด 3 มิติ จำนวน 25 ชิ้นส่วน .....	26
3.3 โครงงัด 3 มิติ จำนวน 39 ชิ้นส่วน .....	28
3.4 โครงงัด 3 มิติ จำนวน 120 ชิ้นส่วน .....	30
3.5 โครงงัด 3 มิติ จำนวน 1,152 ชิ้นส่วน .....	32
บทที่ 4 ผลการศึกษา .....	35
4.1 อัลกอริทึมการปรับขนาดและรูปร่างเพื่อหาค่าที่เหมาะสม .....	35
4.1.2 อัลกอริทึม ECLPSO-GPR.....	35
4.1.2 อัลกอริทึม ECLPSO-GPR with EI .....	38
4.2 ผลลัพธ์การหาค่าที่เหมาะสมของโครงงัด 3 มิติ จำนวน 25 ชิ้นส่วน .....	41
4.3 ผลลัพธ์การหาค่าที่เหมาะสมของโครงงัด 3 มิติ จำนวน 39 ชิ้นส่วน .....	44
4.4 ผลลัพธ์การหาค่าที่เหมาะสมของโครงงัด 3 มิติ จำนวน 120 ชิ้นส่วน .....	46
4.5 ผลลัพธ์การหาค่าที่เหมาะสมของโครงงัด 3 มิติ จำนวน 1,152 ชิ้นส่วน .....	49
บทที่ 5 สรุปและอภิปรายผล .....	53
5.1 สรุปผลการวิจัย .....	53
5.2 ข้อเสนอแนะ .....	53



บรรณานุกรม.....	55
ประวัติผู้เขียน.....	58



จุฬาลงกรณ์มหาวิทยาลัย  
**CHULALONGKORN UNIVERSITY**

## สารบัญตาราง

	หน้า
ตารางที่ 1 ความรู้เชิงบรรทัดฐาน .....	21
ตารางที่ 2 ข้อมูลของโครงถัก 3 มิติจำนวน 25 ชั้นส่วน.....	27
ตารางที่ 3 ข้อมูลของโครงถัก 3 มิติจำนวน 39 ชั้นส่วน.....	29
ตารางที่ 4 ข้อมูลของโครงถัก 3 มิติ รูปทรงโดมจำนวน 120 ชั้นส่วน .....	31
ตารางที่ 5 ข้อมูลของโครงถัก 3 มิติ รูปทรงโดมจำนวน 1,152 ชั้นส่วน .....	33
ตารางที่ 6 อัลกอริทึม ECLPSO-GPR with EI.....	39
ตารางที่ 7 ผลลัพธ์การหาค่าที่เหมาะสมของโครงถัก 3 มิติ จำนวน 25 ชั้นส่วน .....	41
ตารางที่ 8 ผลลัพธ์การหาค่าที่เหมาะสมของโครงถัก 3 มิติ จำนวน 39 ชั้นส่วน .....	44
ตารางที่ 9 ผลลัพธ์การหาค่าที่เหมาะสมของโครงถัก 3 มิติ จำนวน 120 ชั้นส่วน .....	46
ตารางที่ 10 ผลลัพธ์การหาค่าที่เหมาะสมของโครงถัก 3 มิติ จำนวน 1,152 ชั้นส่วน .....	49

## สารบัญรูปภาพ

	หน้า
รูปที่ 1 ขั้นตอนการทำงานของเครื่อง (Thai, 2022).....	1
รูปที่ 2 โครงถัก 2 มิติ และแบบจำลองการวิเคราะห์โครงสร้าง (Kassimali, 2018).....	8
รูปที่ 3 ขั้นตอนพื้นฐานของปัญหาการเรียนรู้ (Abu-Mostafa et al., 2012).....	9
รูปที่ 4 แบบจำลองการถดถอยของกระบวนการเกาส์เซียน .....	13
รูปที่ 5 การปรับปรุงชุดข้อมูลการฝึกสอนด้วยฟังก์ชัน EI (Jones et al., 1998).....	13
รูปที่ 6 ผังการทำงานของอัลกอริทึม PSO (Liang et al., 2006).....	16
รูปที่ 7 การเลือกดัชนีตัวอย่างสำหรับอนุภาค i (Liang et al., 2006) .....	18
รูปที่ 8 ฟังก์ชันความน่าจะเป็นในการเรียนรู้สำหรับจำนวนอนุภาคที่แตกต่างกัน (Van et al., 2022) .....	19
รูปที่ 9 ผังการทำงานของอัลกอริทึม CLPSO (Liang et al., 2006).....	20
รูปที่ 10 ผังการทำงานของอัลกอริทึม ECLPSO (Muong et al.).....	24
รูปที่ 11 โครงถัก 3 มิติจำนวน 25 ชั้นส่วน (Ho-Huu et al., 2015).....	26
รูปที่ 12 โครงถัก 3 มิติจำนวน 39 ชั้นส่วน (Ho-Huu et al., 2015).....	28
รูปที่ 13 โครงถัก 3 มิติ รูปทรงโดมจำนวน 120 ชั้นส่วน .....	30
รูปที่ 14 โครงถัก 3 มิติ จำนวน 1,152 ชั้นส่วน.....	32
รูปที่ 15 ผังการทำงานของกรอกแบบขนาดและรูปร่างที่เหมาะสมของโครงถัก .....	37
รูปที่ 16 ผังการทำงานของอัลกอริทึม GPR-ECLPSO ที่มีการปรับปรุงด้วยฟังก์ชัน EI .....	40
รูปที่ 17 รูปทรงโครงถัก 3 มิติ จำนวน 25 ชั้นส่วนที่เหมาะสม.....	42
รูปที่ 18 ระยะการเคลื่อนที่ของข้อต่อของโครงถัก 3 มิติ จำนวน 25 ชั้นส่วน .....	42
รูปที่ 19 ความเค้นภายในชั้นส่วนของโครงถัก 3 มิติ จำนวน 25 ชั้นส่วน.....	43
รูปที่ 20 รูปทรงโครงถัก 3 มิติ จำนวน 39 ชั้นส่วนที่เหมาะสม.....	45

รูปที่ 21 ความเค้นภายในชิ้นส่วนของโครงถัก 3 มิติ จำนวน 39 ชิ้นส่วน..... 45

รูปที่ 22 รูปทรงโครงถัก 3 มิติ จำนวน 120 ชิ้นส่วนที่เหมาะสม..... 47

รูปที่ 23 ระยะการเคลื่อนที่ของข้อต่อของโครงถัก 3 มิติ จำนวน 120 ชิ้นส่วน..... 47

รูปที่ 24 ความเค้นภายในชิ้นส่วนของโครงถัก 3 มิติ จำนวน 120 ชิ้นส่วน ..... 48

รูปที่ 25 รูปทรงโครงถัก 3 มิติ จำนวน 1,152 ชิ้นส่วนที่เหมาะสม ..... 51

รูปที่ 26 ระยะการเคลื่อนที่ของข้อต่อของโครงถัก 3 มิติ จำนวน 1,152 ชิ้นส่วน..... 51

รูปที่ 27 ความเค้นภายในชิ้นส่วนของโครงถัก 3 มิติ จำนวน 1,152 ชิ้นส่วน ..... 52




# บทที่ 1

## บทนำ

### 1.1 กล่าวนำ

ในช่วงไม่กี่ปีที่ผ่านมาการเรียนรู้ของเครื่อง หรือ Machine Learning (ML) ได้ถูกนำมาใช้อย่างแพร่หลายและประสบความสำเร็จในการแก้ปัญหาต่างๆ เช่น การวิเคราะห์โครงสร้าง (structural analysis) การหาค่าเหมาะสมที่สุดของโครงสร้าง (structural optimization) การตรวจจับความเสียหาย (damage detection) การวิเคราะห์ความน่าเชื่อถือ (reliability analysis) และอื่นๆ สำหรับการประยุกต์ใช้การเรียนรู้ของเครื่องกับการหาค่าที่เหมาะสมที่สุดของโครงสร้าง วิธีการที่ได้รับความนิยมมากที่สุดคือการสร้างแบบจำลองตัวแทน (surrogate model) จากข้อมูลที่มีการรวบรวมไว้ และให้ข้อมูลผลลัพธ์ที่ดีที่สุดซึ่งได้จากแบบจำลอง (Mai et al., 2023)



รูปที่ 1 ขั้นตอนการทำงานของเครื่อง (Thai, 2022)

การหาค่าเหมาะสมที่สุด (Optimization) หมายถึงการค้นหาวิธีที่ดีที่สุดในการลดหรือเพิ่มฟังก์ชันวัตถุประสงค์ของปัญหาที่กำหนด สำหรับปัญหาการหาค่าเหมาะสมที่สุดของโครงสร้างคือการลดต้นทุนของโครงสร้างด้วยการหาค่าเหมาะสมที่ทำให้โครงสร้างมีน้ำหนักน้อยที่สุด โดยในการศึกษาได้นำเสนออัลกอริทึมการปรับปรุงการเรียนรู้ของเครื่องอย่างครอบคลุมเพื่อหาค่าเหมาะสมที่สุดของกลุ่มอนุภาค หรือ Enhanced Comprehensive Learning Particle Swarm Optimization (ECLPSO) (Yu & Zhang, 2014) ซึ่งเป็นหนึ่งในอัลกอริทึมเมตาฮีริสติก (Metaheuristic algorithm) ที่ได้มีการปรับปรุงคุณสมบัติการค้นหา (exploitation) และการสำรวจ (exploration) เพิ่มเติมจากอัลกอริทึมการหาค่าเหมาะสมที่สุดของกลุ่มอนุภาค หรือ Particle swarm optimization (PSO)

(Kennedy & Eberhart, 1995) โดยหลักการการทำงานของอัลกอริทึม ECLPSO คือกระบวนการลองผิดลองถูก ที่ทำการค้นหาตำแหน่งของอนุภาคและทำซ้ำเพื่อให้ได้ค่าที่เหมาะสมที่สุด สำหรับปัญหาการหาค่าที่เหมาะสมที่สุดของโครงถักจำเป็นต้องมีการตรวจสอบข้อจำกัดในการออกแบบของตัวแปรที่เลือกใช้ กล่าวคือจะต้องมีการวิเคราะห์โครงสร้างในทุกการวนซ้ำ ส่งผลให้ในปัญหาโครงสร้างที่มีความซับซ้อน เช่น โครงสร้างขนาดใหญ่ที่มีจำนวนชิ้นส่วนมาก โครงสร้างที่มีการวิเคราะห์แบบไม่เชิงเส้น หรือโครงสร้างที่เกี่ยวข้องกับระบบไดนามิก ซึ่งจำเป็นต้องมีการวิเคราะห์โครงสร้างด้วยระเบียบวิธีไฟไนต์เอลิเมนต์ที่มีความซับซ้อนมากขึ้นจำนวนหลายครั้ง

ดังนั้น ในการศึกษาครั้งนี้ได้มีการนำการเรียนรู้ของเครื่องมาใช้ในการแก้ปัญหาดังกล่าว โดยนำเสนอวิธีการถดถอยของกระบวนการเกาส์เซียน หรือ Gaussian Process Regression (GPR) ในการสร้างแบบจำลองตัวแทนจากข้อมูลที่มีการรวบรวมไว้ และให้ข้อมูลผลลัพธ์ที่ดีที่สุดซึ่งได้จากแบบจำลองทางคณิตศาสตร์ ร่วมกับอัลกอริทึมการปรับปรุงการเรียนรู้อย่างครอบคลุมเพื่อหาค่าที่เหมาะสมที่สุดของกลุ่มอนุภาคเพื่อใช้ในการแก้ปัญหาการหาค่าที่เหมาะสมที่สุดของโครงถักโดยการปรับขนาดและรูปร่างให้เหมาะสม

## 1.2 วัตถุประสงค์

วัตถุประสงค์หลักของงานวิจัยนี้คือ

1. เพื่อหาค่าที่เหมาะสมที่สุดของโครงถักด้วยการปรับขนาดและรูปร่างของโครงถักพร้อมกัน โดยใช้อัลกอริทึมการปรับปรุงการเรียนรู้อย่างครอบคลุมเพื่อหาค่าที่เหมาะสมที่สุดของกลุ่มอนุภาค ร่วมกับวิธีการถดถอยของกระบวนการเกาส์เซียน
2. เพื่อให้ได้น้ำหนักขั้นต่ำของโครงถักภายใต้ข้อกำหนดการออกแบบหรือข้อจำกัดในการออกแบบของแต่ละปัญหา
3. เพื่อเสนออัลกอริทึมในการเพิ่มประสิทธิภาพเพื่อให้ได้ผลลัพธ์ที่รวดเร็วและเหมาะสมที่สุด

## 1.3 ขอบเขตการวิจัย

งานวิจัยนี้ได้ทำการวิเคราะห์โครงสร้างในระนาบ 3 มิติ โดยมีขอบเขตดังนี้

1. ใช้โปรแกรม Python ในทุกกระบวนการของการศึกษา รวมถึงการวิเคราะห์โครงสร้างและขั้นตอนการหาค่าที่เหมาะสมที่สุดของโครงถัก
2. วิเคราะห์โครงสร้างโดยใช้วิธีการรวมสติเฟนส์โดยตรง (Direct Stiffness Method)

3. อัลกอริทึมการทำงานร่วมกันระหว่างวิธีการถดถอยของกระบวนการเกาส์เซียนและการปรับปรุงการเรียนรู้อย่างครอบคลุมเพื่อหาค่าเหมาะสมที่สุดของกลุ่มอนุภาคถูกนำไปใช้ในโปรแกรม Python
4. ตัวอย่างโครงถัก 3 มิติ ที่ใช้ในการศึกษามีข้อกำหนดและข้อจำกัดในการออกแบบที่เกี่ยวข้องกับแต่ละปัญหา รวมถึงมีข้อจำกัดของความเค้น และ/หรือข้อจำกัดการเคลื่อนที่ของข้อต่อ
4. การปรับขนาดและรูปร่างให้เหมาะสมจะดำเนินการพร้อมกัน
5. ตัวแปรขนาดและรูปร่างจะต้องเลือกจากรายการที่มีให้ซึ่งประกอบด้วยตัวแปรต่อเนื่อง และ/หรือตัวแปรไม่ต่อเนื่องตามที่กำหนดไว้ในแต่ละปัญหา
6. ตรวจสอบผลลัพธ์และเปรียบเทียบกับงานวิจัยอื่น

#### 1.4 ระเบียบวิธีการวิจัย

การหาค่าเหมาะสมที่สุดของโครงถักดำเนินการโดยการใช้โปรแกรม Python ที่เขียนขึ้นเพื่อแก้ปัญหาในการหาค่าเหมาะสมที่สุด ซึ่งประกอบด้วยขั้นตอนการนำเข้าข้อมูล ขั้นตอนการวิเคราะห์ ขั้นตอนการหาค่าที่เหมาะสม และขั้นตอนการส่งออกข้อมูล โดยโปรแกรมเริ่มต้นด้วยการป้อนข้อมูลโครงสร้างที่ประกอบไปด้วยข้อมูลชิ้นส่วนโครงสร้าง ตำแหน่งพิกัดของข้อต่อ โมดูลัสความยืดหยุ่น และความหนาแน่นของวัสดุ การวิเคราะห์เชิงเส้นของโครงถักดำเนินการโดยใช้วิธีการรวมสติเฟนส์โดยตรง ผลลัพธ์ที่ได้จากการวิเคราะห์คือค่าความเค้นของชิ้นส่วน ระยะการเคลื่อนที่ของข้อต่อ และน้ำหนักรวมของโครงสร้าง

ทำการหาค่าเหมาะสมที่สุดของตัวอย่างโครงถัก ด้วยอัลกอริทึมการทำงานร่วมกันระหว่างวิธีการถดถอยของกระบวนการเกาส์เซียนและการปรับปรุงการเรียนรู้อย่างครอบคลุมเพื่อหาค่าเหมาะสมที่สุดของกลุ่มอนุภาค ด้วยจำนวนประชากรและจำนวนการวนซ้ำทั้งหมดตามที่กำหนด โดยจำนวนตัวแปรของปัญหาคือผลรวมของตัวแปรขนาดและตัวแปรรูปร่าง ซึ่งกระบวนการหาค่าเหมาะสมที่สุดเริ่มต้นจากการวนซ้ำครั้งแรกจนกระทั่งถึงจำนวนการวนซ้ำสูงสุดเพื่อให้ได้น้ำหนักรวมของโครงสร้างที่มีค่าน้อยที่สุด โดยตัวแปรที่ใช้จะต้องเลือกจากข้อมูลที่กำหนดไว้ และทำการตรวจสอบข้อจำกัดการออกแบบของโครงสร้างในทุกการวนซ้ำเพื่อให้ผลลัพธ์ที่ได้ผ่านทุกข้อจำกัดของการออกแบบ ซึ่งในกระบวนการหาค่าเหมาะสมที่สุดจะต้องดำเนินการตามที่กล่าวข้างต้นซ้ำหลายครั้งเพื่อค้นหาผลลัพธ์ที่ดีที่สุด

## บทที่ 2 งานวิจัยที่เกี่ยวข้อง

### 2.1 การออกแบบขนาดและรูปร่างของโครงถักอย่างเหมาะสม (Size and shape truss structural optimization)

โครงถักหรือโครงข้อหมุนเป็นโครงสร้างสองหรือสามมิติซึ่งประกอบด้วยชิ้นส่วนที่เป็นเส้นตรงเชื่อมต่อกันที่บริเวณข้อต่อ เพื่อคงสภาพและรักษาเสถียรภาพภายใต้แรงดึงหรือแรงบีบอัด การวิจัยเกี่ยวกับการหาค่าเหมาะสมที่สุดของโครงถัก (Truss optimization) เป็นหนึ่งในสาขางานวิจัยการหาค่าเหมาะสมที่สุดของโครงสร้าง (Structural optimization, SO) ที่ได้รับความนิยม แบ่งออกได้เป็นสามประเภท คือ การปรับขนาดให้เหมาะสม (Size optimization) โดยการเลือกหน้าตัดที่เหมาะสมที่สุดของแต่ละชิ้นส่วน การปรับรูปร่างให้เหมาะสม (Shape optimization) โดยการปรับเลื่อนตำแหน่งของข้อต่อ และการปรับทอพอโลยีให้เหมาะสม (Topology optimization) โดยการปรับเพิ่มหรือลดชิ้นส่วนของโครงสร้างและข้อต่อ (Tejani et al., 2018)

การหาค่าเหมาะสมที่สุดของโครงถักมีจุดประสงค์เพื่อลดต้นทุนของโครงสร้างให้เหลือน้อยที่สุดภายใต้ข้อจำกัดในการออกแบบคือ ค่าความเค้นสูงสุด (Ultimate strength) และ ข้อจำกัดด้านสถานะการใช้งาน (Serviceability) โดยการปรับขนาดและรูปร่างของโครงถักให้เหมาะสมร่วมกันจะทำให้ได้ผลลัพธ์ที่ดีกว่าการปรับขนาดหรือรูปร่างให้เหมาะสมเพียงอย่างเดียว และสามารถเขียนให้อยู่ในรูปของฟังก์ชันน้ำหนักรวมของโครงสร้างดงสมการ  $W(X_A, X_G)$  ซึ่งประกอบไปด้วยตัวแปรสองประเภท ได้แก่ ตัวแปรขนาดหรือพื้นที่หน้าตัด  $A \in R^n = [A_1, A_2, \dots, A_n]$  และตัวแปรรูปร่างหรือตำแหน่งพิกัดของข้อต่อ  $(x, y, z) \in R^{m \times m \times m} = [(x_1, y_1, z_1), \dots, (x_m, y_m, z_m)]$  เมื่อ  $n$  และ  $m$  คือจำนวนชิ้นส่วนและข้อต่อของโครงสร้างตามลำดับ (Van et al., 2022) ในการปรับรูปร่างให้เหมาะสมเนื่องจากตำแหน่งของข้อต่อที่เปลี่ยนไปส่งผลให้ความยาวของชิ้นส่วนมีการเปลี่ยนแปลงซึ่งต้องนำมาใช้ในการวิเคราะห์โครงสร้างทุกครั้ง

ผลลัพธ์ของการหาค่าเหมาะสมที่สุดจะต้องอยู่ภายใต้ข้อจำกัดในการออกแบบดังที่ระบุไว้ข้างต้น ซึ่งการปรับแก้ข้อจำกัดในการออกแบบของแต่ละปัญหาสามารถทำได้โดยการกำหนดฟังก์ชันปรับแก้ (penalty function) ดังสมการต่อไปนี้ (Jawad et al., 2021)



$$W' = W(X_A, X_G) \varphi_p K \quad (2.1)$$

$$\varphi_p = (1 + C)^\varepsilon \quad (2.2)$$

เมื่อ  $W'$  หมายถึง น้ำหนักรวมของโครงถักหลังการปรับแก้ข้อจำกัดในการออกแบบ

$\varphi$  หมายถึง สัมประสิทธิ์ตัวคูณ สามารถคำนวณได้จากสมการที่ 2.2

$K$  และ  $\varepsilon$  หมายถึง ค่าคงที่ในการปรับแก้ ซึ่งในการศึกษานี้กำหนดให้มีค่าเท่ากับ 1

$C$  หมายถึง ผลรวมของค่าที่ใช้ในการปรับแก้ข้อจำกัดในการออกแบบ ซึ่งรวมถึงข้อจำกัดในด้านความเค้น สถานะการใช้งาน และการโก่งเดาะ สามารถคำนวณได้จากสมการที่ 2.3

$$C = \sum_{j=1}^m C_\delta^j + \sum_{i=1}^n C_\sigma^i + \sum_{i=1}^n C_{\sigma(buckling)}^i \quad (2.3)$$

ค่าการปรับแก้ข้อจำกัดความเค้น (Strength Constraint,  $C_\sigma^i$ )

$$\left. \begin{aligned} C_\sigma^i &= \left| \frac{\sigma_i - \sigma_{\min}}{\sigma_{\min}} \right| && \text{if } \sigma_i < \sigma_{\min} \\ C_\sigma^i &= \left| \frac{\sigma_i - \sigma_{\max}}{\sigma_{\max}} \right| && \text{if } \sigma_i > \sigma_{\max} \\ C_\sigma^i &= 0 && \text{if } \sigma_{\min} \leq \sigma_i \leq \sigma_{\max} \end{aligned} \right\} \quad (2.4)$$

ค่าการปรับแก้ข้อจำกัดการโก่งเดาะ (Buckling Constraint,  $C_{\sigma(buckling)}^i$ )

$$\left. \begin{aligned} C_{\sigma(buckling)}^i &= \left| \frac{\sigma_i^{buckling} - \sigma_{\max}^{buckling}}{\sigma_{\max}^{buckling}} \right| && \text{if } \sigma_i^{buckling} > \sigma_{\max}^{buckling} \\ C_{\sigma(buckling)}^i &= 0 && \text{if } \sigma_i^{buckling} \leq \sigma_{\max}^{buckling} \end{aligned} \right\} \quad (2.5)$$

ค่าการปรับแก้ข้อจำกัดสถานะการใช้งาน (Strength Constraint,  $C_\delta^j$ )

$$\left. \begin{aligned} C_\delta^j &= \left| \frac{\delta_j - \delta_{\min}}{\delta_{\min}} \right| && \text{if } \delta_j < \delta_{\min} \\ C_\delta^j &= \left| \frac{\delta_j - \delta_{\max}}{\delta_{\max}} \right| && \text{if } \delta_j > \delta_{\max} \\ C_\delta^j &= 0 && \text{if } \delta_{\min} \leq \delta_j \leq \delta_{\max} \end{aligned} \right\} \quad (2.6)$$

## 2.2 วิธีการรวมสติฟเนสโดยตรง (Direct Stiffness Method)

วิธีการรวมสติฟเนสโดยตรง (Direct Stiffness Method) หรือ matrix stiffness method เป็นวิธีการวิเคราะห์โครงสร้างวิธีหนึ่งที่ได้รับคามนิยมมากในปัจจุบัน และได้ถูกนำมาใช้ในการวิเคราะห์โครงสร้างหลายประเภท โดยทั่วไปวิธีการนี้เหมาะสำหรับการนำไปใช้กับการวิเคราะห์โครงสร้างโดยใช้คอมพิวเตอร์ในการคำนวณเพื่อวิเคราะห์โครงสร้างที่มีขนาดใหญ่และมีความซับซ้อน ซึ่งรวมทั้งโครงสร้าง statically determinate และ statically indeterminate

### 2.2.1 การวิเคราะห์โครงสร้างแบบเชิงเส้น (Linear Analysis)

สำหรับวัสดุเนื้อเดียวกัน (homogeneous) ซึ่งมีคุณสมบัติเหมือนกันทุกทิศทาง (isotropic) และยืดหยุ่นเชิงเส้น (linear elastic) สามารถเขียนความสัมพันธ์ระหว่างแรงกระทำภายนอกและการเคลื่อนที่ได้ดังสมการสมมูลนี้

$$\mathbf{P} = \mathbf{K}\mathbf{U} \quad (2.7)$$

เมื่อ  $\mathbf{P}$  หมายถึง แรงกระทำภายนอก

$\mathbf{K}$  หมายถึง เมทริกซ์สติฟเนสของโครงสร้าง

$\mathbf{U}$  หมายถึง ระยะเวลาการเคลื่อนที่

เมทริกซ์สติฟเนสของแต่ละชิ้นส่วน (element stiffness matrix) สามารถคำนวณหาได้ดังสมการที่ 2.8 และสามารถคำนวณเมทริกซ์สติฟเนสของโครงสร้าง (structural stiffness matrix) โดยการนำเมทริกซ์สติฟเนสของชิ้นส่วน ทุกชิ้นส่วนมาประกอบกันดังสมการที่ 2.10

$$[\mathbf{k}_g] = \left( \frac{AE}{L} \right)_n \begin{bmatrix} [\mathbf{S}] & [-\mathbf{S}] \\ [-\mathbf{S}] & [\mathbf{S}] \end{bmatrix} \quad (2.8)$$

$$\text{โดย } [\mathbf{S}] = \begin{bmatrix} c^2 & cs \\ cs & s^2 \end{bmatrix} \quad \begin{matrix} c = \cos \theta \\ s = \sin \theta \end{matrix} \quad (2.9)$$

$$\text{และ } [\mathbf{K}] = \left[ \sum_{e=1}^{N_e} \mathbf{L}_e^T \mathbf{k}_g \mathbf{L}_e \right] \quad (2.10)$$

เมื่อ  $[\mathbf{k}_g]$  หมายถึง เมทริกซ์สติฟเนสของชิ้นส่วน

$E$  หมายถึง ค่าโมดูลัสยืดหยุ่นของวัสดุ (Young's modulus)

- $A$  หมายถึง พื้นที่หน้าตัดของชิ้นส่วน
- $L$  หมายถึง ความยาวของชิ้นส่วน
- $\theta$  หมายถึง มุมระหว่างแกนพิกัดของโครงสร้างและแกนพิกัดของชิ้นส่วน
- $[K]$  หมายถึง เมทริกซ์สติฟเนสของโครงสร้าง
- $L_e$  หมายถึง เมทริกซ์กำหนดตำแหน่ง (localizing matrix) ของชิ้นส่วน  $e$


### 2.2.2 การวิเคราะห์โครงสร้างโดยใช้คอมพิวเตอร์ในการคำนวณ

ในการวิเคราะห์โครงสร้างโดยใช้คอมพิวเตอร์ในการคำนวณจำเป็นต้องมีการป้อนข้อมูลนำเข้าที่จำเป็นทั้งหมด และต้องป้อนในรูปแบบของเมทริกซ์หรืออาร์เรย์ตามที่ระบุในโปรแกรม Python โดยสามารถแบ่งออกเป็นหกประเภทดังนี้ (Kassimali, 2018)

1. ข้อมูลของข้อต่อ (Joint data )
7. ข้อมูลของฐานรองรับ (Support data)
8. ข้อมูลคุณสมบัติของวัสดุ (Material property data)
9. ข้อมูลคุณสมบัติภาคตัดขวาง (Cross-sectional property data)
10. ข้อมูลชิ้นส่วน (Member data)
11. ข้อมูลน้ำหนักบรรทุก (Load data)

วิธีการรวมสติฟเนสโดยตรงสามารถทำได้ตามขั้นตอนต่อไปนี้:

1. เตรียมแบบจำลองการวิเคราะห์และรวบรวมข้อมูลนำเข้าทั้งหมดให้อยู่ในรูปเมทริกซ์
12. กำหนดสติฟเนสเมทริกซ์ ( $\mathbf{K}$ ) ของโครงสร้าง
13. ทำการหาค่าการเคลื่อนที่ของข้อต่อโดยการป้อนข้อมูลแรงที่ทราบ ( $P$ ) และสติฟเนสเมทริกซ์ ( $\mathbf{K}$ ) ของโครงสร้าง ในสมการ  $\mathbf{P} = \mathbf{K}\mathbf{U}$  โดยที่  $U$  คืออาร์เรย์การเคลื่อนที่ของข้อต่อ
14. คำนวณระยะการเคลื่อนที่และแรงที่เกิดขึ้นของชิ้นส่วนโครงสร้าง และแรงกระทำที่ฐานรองรับ
15. ตรวจสอบผลลัพธ์โดยสมการสมดุล (equilibrium equations)



รูปที่ 2 โครงสร้าง 2 มิติ และแบบจำลองการวิเคราะห์โครงสร้าง (Kassimali, 2018)

## 2.3 การถดถอยของกระบวนการเกาส์เซียน (Gaussian Process Regression)

กระบวนการเกาส์เซียน หรือ Gaussian Processes (GPs) เป็นกระบวนการในการกำหนดการกระจายฟังก์ชันและเป็นการกำหนดการอนุมานที่เกิดขึ้นโดยตรงในพื้นที่ของฟังก์ชัน โดยเป็นหนึ่งในแบบจำลองตัวแทน (Surrogate Model) ซึ่งเป็นที่รู้จักและใช้กันอย่างแพร่หลายในการจำแนกประเภท (classification) และการถดถอย (regression) รวมทั้งในปัญหาต่าง ๆ

### 2.3.1 การถดถอย (Regression)

การถดถอย (Regression) เป็นกระบวนการที่ใช้ในการอธิบายชุดของจุดข้อมูลด้วยการปรับฟังก์ชันให้แสดงถึงคุณลักษณะของจุดข้อมูล และใช้ฟังก์ชันดังกล่าวเพื่อดำเนินการคาดการณ์ที่จุดข้อมูลใหม่ (Melo, 2012) โดยปัญหาการถดถอยเป็นปัญหาการเรียนรู้แบบมีผู้สอน (Supervised learning) ซึ่งเรียนรู้จากการประมวลผลข้อมูลนำเข้าไปยังข้อมูลส่งออกโดยกำหนดชุดข้อมูลการฝึก (training data) จำนวน  $N$  ชุด ดังสมการที่ 2.11


$$D = (X, y) = \{(x_i, y_i) | i = 1, \dots, N\} \quad (2.11)$$

เมื่อ  $N$  หมายถึง จำนวนของชุดข้อมูล

$x_i \in \mathbb{R}^D$  หมายถึง เวกเตอร์ของตัวแปรนำเข้า ซึ่งเขียนอยู่ในรูปของเมทริก  $\mathbf{X} \in \mathbb{R}^{N \times D}$

$y_i \in \mathbb{R}$  หมายถึง ตัวแปรส่งออกที่เกี่ยวข้อง ซึ่งเขียนอยู่ในรูปของเวกเตอร์  $\mathbf{y} \in \mathbb{R}^N$

ในอัลกอริทึมการเรียนรู้  $A$  ที่มีการใช้ชุดข้อมูล  $D$  ได้มีการเลือกฟังก์ชัน  $g$  ซึ่งเป็นหนึ่งในชุดสมมติฐาน หรือ Hypothesis set ( $H$ ) และทำการวนซ้ำเพื่อเลือกฟังก์ชันที่ให้ผลลัพธ์ตรงกับฟังก์ชัน  $f$  มากที่สุดในชุดข้อมูลการฝึก (Abu-Mostafa et al., 2012) ดังแสดงในรูปที่ 3



รูปที่ 3 ขั้นตอนพื้นฐานของปัญหาการเรียนรู้ (Abu-Mostafa et al., 2012)

### 2.3.2 การทำนายค่าเป้าหมายด้วยกระบวนการเกาส์เซียน

แบบจำลองการถดถอยของกระบวนการเกาส์เซียน (GPR) สามารถได้มาจากการแจกแจงแบบเกาส์เซียนหลายตัวแปร โดยสามารถกำหนดรูปร่างของการแจกแจงได้จากค่าเฉลี่ยและความแปรปรวนร่วมที่อยู่ในรูปเอกซ์โพเนนเชียล ซึ่งแบบจำลองนี้ได้มีการศึกษากันอย่างแพร่หลายและนำมาประยุกต์ใช้โดยการใช้แบบจำลองการถดถอยเชิงเส้นร่วมกับสัญญาณรบกวนที่อยู่ในรูปของเกาส์เซียน (Gaussian noise) เพื่อหาฟังก์ชันที่เหมาะสม (Williams & Rasmussen, 2006)

#### 1. Gaussian Process Priors

กระบวนการเกาส์เซียนเป็นชุดของตัวแปรสุ่มที่มีการแจกแจงแบบเกาส์เซียน หรือ การแจกแจงแบบปกติ (normal distribution) ที่สอดคล้องกันโดยมีค่าเฉลี่ย ( $\mu$ ) เท่ากับ 0 และมีค่าความแปรปรวน ( $\Sigma$ ) เท่ากับ  $\sigma^2$  เป้าหมายของการถดถอยของกระบวนการเกาส์เซียนคือการสร้างความสัมพันธ์ระหว่างข้อมูลเวกเตอร์อินพุต  $\mathbf{x}$  และข้อมูลเอาต์พุต  $y$  ของชุดข้อมูลสำหรับการฝึกสอน ดังสมการที่ 2.12

$$\mathbf{y} = f(\mathbf{x}) + \varepsilon \quad (2.12)$$

โดย  $f(\mathbf{x}) = \mathbf{x}^T \mathbf{w}$  และ  $\varepsilon \sim \mathbf{N}(0, \sigma_N^2)$

เมื่อ  $y$  หมายถึง ค่าเป้าหมายที่สังเกตได้ (observed target value)

$\varepsilon$  หมายถึง สัญญาณรบกวนของเกาส์เซียน

$\mathbf{w}$  หมายถึง พารามิเตอร์น้ำหนัก (weight parameter)

Gaussian Process Priors สามารถเขียนให้อยู่ในรูปของฟังก์ชันความหนาแน่นของความน่าจะเป็น หรือ Probability Density Function ในรูปของค่าเฉลี่ย  $m(x)$  และ เคอร์เนล (kernel) หรือ ฟังก์ชันความแปรปรวนร่วม  $k(x, x')$  ร่วมกับสัญญาณรบกวนของเกาส์เซียน  $\sigma_N^2$  ซึ่งจะได้ Prior ของฟังก์ชันการถดถอยของกระบวนการเกาส์เซียนดังสมการที่ 2.13 (Murphy, 2012)

$$f(\mathbf{x}) \sim GP(m(\mathbf{x}), k(\mathbf{x}, \mathbf{x}')) ; \mathbf{x}, \mathbf{x}' \in \mathbb{R}^D \quad (2.13)$$

$$m(\mathbf{x}) = E[f(\mathbf{x})] \quad (2.14)$$

$$k(\mathbf{x}, \mathbf{x}') = E[(f(\mathbf{x}) - m(\mathbf{x}))(f(\mathbf{x}') - m(\mathbf{x}'))] \quad (2.15)$$

เมื่อ  $m(\mathbf{x})$  หมายถึง ฟังก์ชันค่าเฉลี่ยที่คาดหวัง (expected function) ของอินพุต  $x$

$k(\mathbf{x}, \mathbf{x}')$  หมายถึง ฟังก์ชันเคอร์เนลที่ได้จากข้อมูลอินพุต  $x$  และ  $x'$  ที่แตกต่างกัน  
ดังสมการที่ 2.15

## 16. Likelihood

ในการเรียนรู้ชุดข้อมูลการฝึกอบรม ได้มีการกำหนดค่าควรจะเป็น (likelihood) ของข้อมูล เป็นการแจกแจงแบบเกาส์เซียน  $p(y|f, \mathbf{X})$  โดยมีการกำหนดเซตข้อมูลใน prior ที่มีค่าเฉลี่ยเท่ากับ 0 และมีฟังก์ชันความแปรปรวนร่วม คือ เมทริกซ์  $\mathbf{K}$

$$\begin{bmatrix} y_1 \\ \vdots \\ y_N \end{bmatrix} \sim N_n \left( \begin{bmatrix} m(x_1) = 0 \\ \vdots \\ m(x_N) = 0 \end{bmatrix}, \begin{bmatrix} k(x_1, x_1) & \cdots & k(x_1, x_N) \\ \vdots & \ddots & \vdots \\ k(x_N, x_1) & \cdots & k(x_N, x_N) \end{bmatrix} \right) \quad (2.16)$$

จากคุณสมบัติของการแจกแจงแบบเกาส์เซียน จะได้การกระจายของขอบค่าควรจะเป็น (marginal likelihood) ของ  $y$  ซึ่งเป็นผลของการคำนวณแบบอินทิเกรตของผลคูณระหว่าง likelihood และ prior ดังนี้

$$p(y|\mathbf{X}) = \int p(y|f, \mathbf{X})p(f|\mathbf{X})df \quad (2.17)$$

โดย prior จะมีการแจกแจงแบบเกาส์เซียน  $f|\mathbf{X} \sim N(0, \sigma_n^2)$  เช่นเดียวกับ likelihood ที่มีการแจกแจงแบบเกาส์เซียน  $y|f \sim N(f, \sigma_n^2 I)$  โดยสามารถใช้ฟังก์ชันลอการิทึมเพื่อลดความซับซ้อนในการคำนวณหาผลลัพธ์การอินทิเกรตของฟังก์ชัน  $f$  ได้ดังสมการที่ 2.18

$$\log p(y|\mathbf{X}) = -\frac{1}{2}y^T C_N^{-1}y - \frac{1}{2}\log|C_N| - \frac{n}{2}\log 2\pi \quad (2.18)$$

เมื่อ  $C_N = K(\mathbf{X}, \mathbf{X}) + \sigma_n^2 I$

## 17. Posterior Predictions from GPR

มีวัตถุประสงค์เพื่อการทำนายฟังก์ชัน  $f_*$  ซึ่งเป็นฟังก์ชันที่ให้ค่าที่คาดหวัง ( $y_*$ ) จากข้อมูลทดสอบ  $x_*$  สามารถเขียนให้อยู่ในรูปดังสมการต่อไปนี้ (Melo, 2012)

$$\begin{bmatrix} \mathbf{y} \\ \mathbf{y}_* \end{bmatrix} \sim N \left( \mathbf{0}, \begin{bmatrix} K(\mathbf{X}, \mathbf{X}) + \sigma_n^2 I & K(\mathbf{X}, \mathbf{X}_*) \\ K(\mathbf{X}_*, \mathbf{X}) & K(\mathbf{X}_*, \mathbf{X}_*) \end{bmatrix} \right) \quad (2.19)$$

เมื่อ  $\mathbf{K}$  หมายถึง เมทริกซ์ที่ประกอบไปด้วยฟังก์ชัน  $k(x, x')$  ใด ๆ ซึ่งสามารถทำหน้าที่เป็นฟังก์ชันความแปรปรวนร่วม (covariance function) ระหว่างค่าสังเกตสองค่า ดังสมการที่ 2.20

$$\text{cov}(y_p, y_q) = k(x_p, x_q) + \sigma_n^2 \delta_{pq} \quad (2.20)$$

จากสมการที่ 2.20  $\delta_{pq}$  คือ Kronecker delta ซึ่งเป็นฟังก์ชันของตัวแปรสองตัว โดยมีค่าเท่ากับ 1 เมื่ออินพุตของตัวแปรทั้งสองมีค่าเท่ากัน และมีค่าเท่ากับ 0 เมื่ออินพุตมีค่าไม่เท่ากัน โดยสามารถเขียนให้อยู่ในรูปของสมการที่ 2.21 ได้ดังนี้

$$\text{cov}(y) = K(X, X) + \sigma_n^2 I \quad (2.21)$$

ในขั้นตอนการทำนายดังสมการที่ 2.19 ประกอบไปด้วยการประมาณค่าเฉลี่ยและความแปรปรวนสำหรับ  $y_*$  จะเห็นว่า การประมาณการแจกแจงแบบมีเงื่อนไขของ  $y_*$  ที่กำหนดด้วย  $y$  ผลลัพธ์ที่ได้คือ  $y$  และ  $y_*$  เป็นเวกเตอร์สุ่มแบบเกาส์เซียนร่วมกัน ซึ่งหาได้จากสมการดังต่อไปนี้

$$y_* | y \sim N(\bar{f}_*, \text{cov}(f_*)) \quad (2.22)$$

$$\bar{f}_* = k_*^T C_N^{-1} y \quad (2.23)$$


$$\text{cov}(f_*) = k_{**} - k_*^T C_N^{-1} k_* \quad (2.24)$$

โดย  $k_* = K(x, x_*)$ ,  $C_N = K(X, X) + \sigma_n^2 I$  และ  $k_{**} = K(X_*, X_*)$

เมื่อ  $\bar{f}_*$  หมายถึง เมทริกซ์ของสัมประสิทธิ์การถดถอย โดยเป็นค่าเฉลี่ยของการทำนายซึ่งทำให้ได้ค่าที่ดีที่สุดสำหรับ  $y_*$

$\text{cov}(f_*)$  หมายถึง ค่าความแปรปรวน ซึ่งบ่งบอกความไม่แน่นอนของการประมาณ

จากสมการข้างต้นสามารถสรุปได้ว่าผลลัพธ์การคาดคะเน  $\bar{f}_*$  ได้จากการพิจารณาข้อมูลฝึกสอนที่ประกอบไปด้วยข้อมูลอินพุต ( $x$ ) และข้อมูลเอาต์พุต ( $y$ ) แต่ค่าความแปรปรวน ( $\text{cov}(f_*)$ ) ขึ้นอยู่กับข้อมูลอินพุตเพียงอย่างเดียว





รูปที่ 4 แบบจำลองการถดถอยของกระบวนการเกาส์เซียน


## 2.4 การปรับปรุงที่คาดหวัง (Expected Improvement, EI)

การปรับปรุงที่คาดหวังเป็นหนึ่งในฟังก์ชันการเรียนรู้ที่ใช้ในการปรับปรุงประสิทธิภาพของแบบจำลอง GPR ด้วยการระบุไฮเปอร์พารามิเตอร์ถัดไป โดยมีหลักในการทำงานคือการหาตำแหน่งที่ให้ค่าสูงสุดของฟังก์ชัน (maximize function) ในสมการที่ 2.25 (Mai et al., 2023) และทำการเพิ่มจุดข้อมูลในตำแหน่งดังกล่าว เพื่อใช้ในการปรับปรุงชุดข้อมูลที่ใช้ในการฝึกสอนสำหรับแบบจำลอง GPR

$$EI(y) = (W_{op}(y_*) - \mu_n(y)) \Phi \left( \frac{W_{op}(y_*) - \mu_n(y)}{\sigma_n(y)} \right) + \sigma_n(y) \phi \left( \frac{W_{op}(y_*) - \mu_n(y)}{\sigma_n(y)} \right) \quad (2.25)$$

เมื่อ  $\Phi$  หมายถึง ฟังก์ชันการแจกแจงสะสมปกติมาตรฐาน

$\phi$  หมายถึง ฟังก์ชันความหนาแน่นของความน่าจะเป็นตามลำดับ



รูปที่ 5 การปรับปรุงชุดข้อมูลการฝึกสอนด้วยฟังก์ชัน EI (Jones et al., 1998)

จากรูปที่ 5.a แสดงฟังก์ชันการปรับปรุง EI ในเส้นสีเขียว เมื่อทำการสุ่มข้อมูล 5 จุดตัวอย่าง จะเห็นว่าในจุดที่  $x$  มีค่าเท่ากับ 2.8 ค่า EI ที่ได้จะมีค่ามากที่สุด จึงทำการเพิ่มจุดข้อมูลการฝึกสอนในตำแหน่งดังกล่าวดังรูปที่ 5.b จากนั้นดำเนินการทำซ้ำเพื่อเพิ่มชุดข้อมูลในการฝึกสอน เพื่อเป็นการเพิ่มประสิทธิภาพให้กับกระบวนการเกาส์เซียน

## 2.5 การปรับปรุงการเรียนรู้อย่างครอบคลุมเพื่อหาค่าเหมาะสมที่สุดของกลุ่มอนุภาค (Enhanced Comprehensive Learning Particle Swarm Optimization, ECLPSO)

### 2.5.1 การหาค่าเหมาะสมที่สุดของกลุ่มอนุภาค

ในช่วงที่ผ่านมาอัลกอริทึมแบบปัญญาารวมหมู่ หรือ Swarm Intelligence (SI) ที่มีเทคนิคการค้นหาแบบสุ่มได้รับความนิยมและเป็นอีกทางเลือกหนึ่งสำหรับการแก้ปัญหา โดยหนึ่งในอัลกอริทึม SI ที่มีชื่อเสียงคือการหาค่าเหมาะสมที่สุดของกลุ่มอนุภาค หรือ Particle Swarm Optimization (PSO) ซึ่งถูกนำเสนอเป็นครั้งแรก ในปี ค.ศ. 1995 (Kennedy & Eberhart, 1995) โดยเป็นการศึกษาและเลียนแบบพฤติกรรมหรือการเคลื่อนไหวของสัตว์ เช่น ปลาและนก อัลกอริทึม PSO ใช้อนุภาคจำนวนมากเพื่อทำการแก้ปัญหาโดยการแบ่งปันข้อมูลของแต่ละอนุภาคให้กันและกันในทุกการทำซ้ำ ดังนั้น หากอนุภาคหนึ่งมีตำแหน่งที่ดีกว่าอนุภาคอื่น ๆ อนุภาคนั้นจะให้ข้อมูลแก่อนุภาคอื่น เพื่อช่วยให้อนุภาคอื่น ๆ สามารถตามตำแหน่งของอนุภาคที่ดีที่สุดได้ ในการวนซ้ำแต่ละครั้งสมการที่ 2.26 และสมการที่ 2.27 ถูกนำมาใช้สำหรับการแก้ปัญหา  $d$  มิติ (Li et al., 2007)

$$V_i^d = wV_i^d + c_1 \text{rand}1_i^d (pbest_i^d - X_i^d) + c_2 \text{rand}2_i^d (gbest^d - X_i^d) \quad (2.26)$$

$$X_i^d = X_i^d + V_i^d \quad (2.27)$$

เมื่อ  $X_i = (X_i^1, X_i^2, \dots, X_i^D)$  หมายถึง ตำแหน่งปัจจุบันของอนุภาค  $i$

$V_i = (V_i^1, V_i^2, \dots, V_i^D)$  หมายถึง ความเร็วของอนุภาค  $i$

$\text{rand}1_i^d$  และ  $\text{rand}2_i^d$  หมายถึง ตัวเลขสุ่มที่มีค่าระหว่าง 0 และ 1

$pbest_i^d$  หมายถึง ตำแหน่งของอนุภาคที่ดีที่สุดของอนุภาค  $i$

$gbest^d$  หมายถึง ตำแหน่งของอนุภาคที่ดีที่สุดของทุก ๆ อนุภาค

$c1$  และ  $c2$  หมายถึง ค่าคงที่ของความเร่ง ซึ่งในการศึกษานี้กำหนดให้มีค่าเท่ากับ 2

$w$  หมายถึง น้ำหนักแรงเฉื่อย (Inertia weight) คำนวณได้จากสมการที่ 2.28

$$w = w_{max} - \frac{w_{max} - w_{min}}{k_{max}} \times k \quad (2.28)$$

เมื่อ  $w_{max}$  และ  $w_{min}$  กำหนดให้มีค่าเท่ากับ 0.9 และ 0.4 ตามลำดับ

โดยอัลกอริทึมจะเริ่มจากการสุ่มตำแหน่งและความเร็วเริ่มต้นของอนุภาคให้มีค่าอยู่ในขอบเขตที่กำหนดดังสมการที่ 2.29 และสมการที่ 2.30 โดยกำหนดให้ตำแหน่งเริ่มต้นเป็นตำแหน่งที่ดีที่สุดของอนุภาค (Personal best and Global best position) จากนั้นเริ่มกระบวนการทำซ้ำโดยหาค่าความเร็วและตำแหน่งของแต่ละอนุภาค ซึ่งในกระบวนการทำซ้ำในแต่ละครั้งอัลกอริทึมจะมีการปรับเปลี่ยนขอบเขตของตำแหน่งและความเร็วใหม่ดังสมการที่ 2.31 และสมการที่ 2.32 จากนั้นเปรียบเทียบผลลัพธ์ที่ได้กับค่าก่อนหน้าเพื่อทำการหาค่า Personal best position และ Global best position จนกว่าจะครบตามจำนวนวงวนที่กำหนด (Venter & Sobieszczanski-Sobieski, 2004)

$$x_0^i = x_{min} + r_1 (x_{max} - x_{min}) \quad (2.29)$$

$$v_0^i = \frac{x_{min} + r_2 (x_{max} - x_{min})}{\Delta t} \quad (2.30)$$

$$x_i^d = \min(X_{max}^d, \max(X_{min}^d, x_i^d)) \quad (2.31)$$

$$v_i^d = \min(V_{max}^d, \max(V_{min}^d, v_i^d)) \quad (2.32)$$


เมื่อ  $x_0^i$  และ  $v_0^i$  หมายถึง ตำแหน่งและความเร็วเริ่มต้นของอนุภาค

$r_1$  และ  $r_2$  หมายถึง ตัวเลขสุ่มที่มีค่าระหว่าง 0 และ 1

$[X_{max}^d, X_{min}^d]$  หมายถึง ขอบเขตสูงสุดและต่ำสุดของตำแหน่งอนุภาค

$[V_{max}^d, V_{min}^d]$  หมายถึง ขอบเขตสูงสุดและต่ำสุดของความเร็วอนุภาค โดย:

$$V_{max}^d = 0.20(X_{max}^d - X_{min}^d) \quad \text{และ} \quad V_{min}^d = -V_{max}^d \quad (\text{Yu \& Zhang, 2014})$$



$ps$ : population size

$k$ : generation counter from 1 to  $max\_gen$

$d$ : dimension

$w$ : inertia weight ( $w_0=0.9, w_1=0.4$ )

$max\_gen$ : maximum generations

$i$ : particle's id counter from 1 to  $ps$

$X_i^d$ :  $i^{\text{th}}$  particle's  $d^{\text{th}}$  dimension's value

$c_1 = c_2 = 2$

รูปที่ 6 ผังการทำงานของอัลกอริทึม PSO (Liang et al., 2006)

อย่างไรก็ตามในการแก้ปัญหาด้วย PSO อัลกอริทึมถูกออกแบบมาให้แต่ละอนุภาคมีการเรียนรู้จากค่าที่ดีที่สุดของทุก ๆ อนุภาค (Global best value) ซึ่งค่าดังกล่าวอาจไม่ใช่ค่าที่เข้าใกล้จุด

เหมาะสมที่สุด (Global optimum) ของฟังก์ชัน ในกรณีที่ได้ค่า Global best ที่ได้ยังห่างจากค่า Global optimum อัลกอริทึมอาจไม่ได้ผลลัพธ์ที่ดีเนื่องจากอนุภาคติดอยู่ใน Local optimum ซึ่งทำให้ผลลัพธ์ที่ได้ไม่มีประสิทธิภาพ

### 2.5.2 การเรียนรู้อย่างครอบคลุมเพื่อหาค่าเหมาะสมที่สุดของกลุ่มอนุภาค

เพื่อปรับปรุงข้อบกพร่องได้มีการนำเสนออัลกอริทึมการเรียนรู้อย่างครอบคลุมเพื่อหาค่าเหมาะสมที่สุดของกลุ่มอนุภาค หรือ Comprehensive Learning Particle Swarm Optimization (CLPSO) (Liang et al., 2006) เพื่อเพิ่มความสามารถในการเรียนรู้และปรับปรุงคุณสมบัติในการสำรวจได้มีการปรับปรุงโดยการให้อนุภาคเรียนรู้จากข้อมูลของค่าที่ดีที่สุดของอนุภาคตัวที่  $i$  (Personal best value) ซึ่งเมื่อใช้วิธีการดังกล่าว สมการความเร็วของอนุภาคจะมีการปรับเปลี่ยนดังสมการที่ 2.33

$$V_i^d = wV_i^d + c_1 \text{rand}1_i^d (pbest_{f_i(d)}^d - X_i^d) + c_2 \text{rand}2_i^d (gbest^d - X_i^d) \quad (2.33)$$

เมื่อ  $X_i = (X_i^1, X_i^2, \dots, X_i^D)$  หมายถึง ตำแหน่งปัจจุบันของอนุภาค  $i$

$V_i = (V_i^1, V_i^2, \dots, V_i^D)$  หมายถึง ความเร็วของอนุภาค  $i$

$\text{rand}1_i^d$  และ  $\text{rand}2_i^d$  หมายถึง ตัวเลขสุ่มสองชุดที่มีค่าระหว่าง 0 และ 1

$f_i$  หมายถึง ดัชนีตัวอย่าง (Exemplar Index)

$pbest_{f_i(d)}^d$  หมายถึง ตำแหน่งของอนุภาคที่ดีที่สุดที่ถูกกำหนดโดยดัชนีตัวอย่าง

$gbest^d$  หมายถึง ตำแหน่งของอนุภาคที่ดีที่สุดของทุก ๆ อนุภาค


$c1$  และ  $c2$  หมายถึง ค่าคงที่ของความเร่ง ในการศึกษานี้กำหนดให้มีค่าเท่ากับ 2

$w$  หมายถึง น้ำหนักแรงเฉื่อย (Inertia weight) คำนวณได้จากสมการที่ 2.28

#### 1. ดัชนีตัวอย่าง (Exemplar Index)

ดัชนีตัวอย่าง  $f_i = [f_i(1), f_i(2), \dots, f_i(D)]$  เป็นดัชนีที่กำหนดว่าอนุภาคควรเรียนรู้ข้อมูลจากค่า Personal best ของอนุภาคใดซึ่งสามารถกำหนดค่าดัชนีตัวอย่างได้จากค่าความน่าจะเป็นในการเรียนรู้ (Learning Probabilities) ตามขั้นตอนดังนี้

- 1) สร้างตัวเลขสุ่มในช่วง  $[0,1]$  และเปรียบเทียบค่าความน่าจะเป็นในการเรียนรู้ซึ่งสามารถคำนวณได้โดยใช้สมการที่ 2.34
- 2) หากค่าความน่าจะเป็นในการเรียนรู้มีค่าน้อยกว่า ดัชนีตัวอย่างจะมีค่าเท่ากับอนุภาค  $i$  ในทางกลับกันหากค่าความน่าจะเป็นในการเรียนรู้มีค่ามากกว่า ดัชนีตัวอย่างจะมีการเลือกอนุภาคแบบสุ่มสองอนุภาคและดำเนินการต่อไป
- 3) เลือกค่าดัชนีตัวอย่างจากการเปรียบเทียบหาค่าความเหมาะสม (Fitness Value) ที่ดีที่สุด




รูปที่ 7 การเลือกดัชนีตัวอย่างสำหรับอนุภาค  $i$  (Liang et al., 2006)

## 2. ความน่าจะเป็นในการเรียนรู้ (Learning Probabilities)


ค่าความน่าจะเป็นในการเรียนรู้  $Pc$  ใช้ค่าที่แตกต่างกันสำหรับแต่ละอนุภาค ในการหาค่าเหมาะสมทุก ๆ การวนซ้ำ ซึ่งสามารถคำนวณได้ดังสมการที่ 2.34

$$Pc_i = 0.05 + 0.45 \frac{\left( \exp\left(\frac{10(i-1)}{ps-1}\right) - 1 \right)}{(\exp(10) - 1)} \quad (2.34)$$

เมื่อ  $ps$  หมายถึง จำนวนประชากรของอนุภาคทั้งหมดในหนึ่งวงวน



รูปที่ 8 ฟังก์ชันความน่าจะเป็นในการเรียนรู้สำหรับจำนวนอนุภาคที่แตกต่างกัน (Van et al., 2022)



① :Insert the flowchart in Fig. 1 here.

$ps$ : population size

$k$ : generation counter from 1 to  $max\_gen$

$d$ : dimension

$w$ : inertia weight ( $w_0=0.9, w_1=0.4$ )

$max\_gen$ : maximum generations

$i$ : particle's id counter from 1 to  $ps$

$X_i^d$ :  $i^{\text{th}}$  particle's  $d^{\text{th}}$  dimension's value

$c=1.49445$   $m$ : refreshing gap

$flag_i$ : the number of generations the  $i^{\text{th}}$  particle has not improved its own  $pbest$ .

รูปที่ 9 ผังการทำงานของอัลกอริทึม CLPSO (Liang et al., 2006)



แนวคิดของอัลกอริทึม CLPSO คือการให้อนุภาคเรียนรู้จากข้อมูลของอนุภาคอื่นเพื่อปรับปรุงความสามารถในการสำรวจจึงสามารถให้ผลลัพธ์ที่ดีและแม่นยำกว่าอัลกอริทึม PSO เมื่อต้องแก้ปัญหาที่มีความซับซ้อน

### 2.5.3 การปรับปรุงการเรียนรู้อย่างครอบคลุมเพื่อหาค่าเหมาะสมที่สุดของกลุ่มอนุภาค

อัลกอริทึม CLPSO ได้มีการเพิ่มคุณสมบัติในการสำรวจให้ดีขึ้นแต่ประสิทธิภาพในการค้นหายังให้ค่าที่ไม่ดีเพียงพอส่งผลให้ผลลัพธ์ที่ได้ขาดความแม่นยำ จึงได้มีการปรับปรุงคุณสมบัติของอัลกอริทึม โดยในปี 2014 ได้มีการเสนออัลกอริทึมการปรับปรุงการเรียนรู้อย่างครอบคลุมเพื่อหาค่าเหมาะสมที่สุดของกลุ่มอนุภาค หรือ Enhanced Comprehensive Learning Particle Swarm Optimization (ECLPSO) (Yu & Zhang, 2014) ซึ่งอิงตามแนวคิดเดิมของอัลกอริทึม CLPSO แต่เพิ่มประสิทธิภาพในการค้นหาและสำรวจซึ่งทำให้สามารถให้ผลลัพธ์ที่ดีและมีความแม่นยำกว่า

#### 1. การค้นหาตามการก่อกวน (Perturbation-based Exploitation)

อัลกอริทึม ECLPSO ได้มีการปรับปรุงประสิทธิภาพการค้นหาของอัลกอริทึมด้วยการใช้ความรู้เชิงบรรทัดฐาน (normative knowledge) ดังแสดงในตารางที่ 1 โดยความรู้เชิงบรรทัดฐานคือช่วงข้อมูลของตำแหน่งที่ดีที่สุด (Personal best position) ของกลุ่มอนุภาค ซึ่งเป็นตัวกำหนดเงื่อนไขในการใช้ประโยชน์จากการค้นหาตามการก่อกวนอย่างมีประสิทธิภาพ

ตารางที่ 1 ความรู้เชิงบรรทัดฐาน

มิติ (Dimension)	1	2	...	D
ขอบเขตล่างของมิติปัจจุบัน (Present dimensional lower bound)	$\underline{P}_1$	$\underline{P}_2$	...	$\underline{P}_D$
ขอบเขตบนของมิติปัจจุบัน (Present dimensional upper bound)	$\overline{P}_1$	$\overline{P}_2$	...	$\overline{P}_D$

เมื่อ  $\underline{P}_d$  และ  $\overline{P}_d$  หมายถึง ขอบเขตล่างและขอบเขตบนของตำแหน่งที่ดีที่สุดของกลุ่มอนุภาคซึ่งสามารถหาค่าได้ดังสมการต่อไปนี้

$$\underline{P}_d = \min \{P_{1,d}, P_{2,d}, \dots, P_{N,d}\} \quad (2.35)$$

$$\overline{P}_d = \max \{P_{1,d}, P_{2,d}, \dots, P_{N,d}\} \quad (2.36)$$

การค้นหาตามการก่อกวนมุ่งเน้นประสิทธิภาพไปที่การค้นหาและเพิ่มความแม่นยำของอัลกอริทึม CLPSO โดยขั้นตอนการทำงานในส่วนนี้ยังคงเหมือนกับอัลกอริทึม CLPSO และเงื่อนไขในการใช้การค้นหาตามการก่อกวนเมื่อสมการที่ 2.37 เป็นจริง ดังนั้นสมการความเร็วในการเคลื่อนที่ของอนุภาคจะถูกปรับปรุงดังสมการที่ 2.38 อย่างไรก็ตามถ้าสมการที่ 2.37 ไม่เป็นจริงสมการความเร็วจะใช้สมการความเร็วเดิมเช่นเดียวกับอัลกอริทึม CLPSO ซึ่งแสดงในสมการที่ 2.33

$$\left. \begin{aligned} \overline{P}_d - \underline{P}_d &\leq \alpha (\overline{X}_d - \underline{X}_d) \\ \overline{P}_d - \underline{P}_d &\leq \beta \end{aligned} \right\} \quad (2.37)$$

$$V_i^d = w_{pbe} V_i^d + c_1 \text{rand}1_i^d \left( pbest_{f_i(d)}^d + \eta \left( \frac{\overline{P}_d - \underline{P}_d}{2} - pbest_{f_i(d)}^d \right) - X_i^d \right) + c_2 \text{rand}2_i^d (gbest^d - X_i^d) \quad (2.38)$$

- เมื่อ  $\alpha$  หมายถึง อัตราส่วนสัมพัทธ์ ซึ่งมีค่าเท่ากับ 0.01
- $\beta$  หมายถึง ขอบเขตสัมบูรณ์ ซึ่งกำหนดให้มีค่าเท่ากับ 2
- $\eta$  หมายถึง ค่าสัมประสิทธิ์การก่อกวน ซึ่งสุ่มจากการแจกแจงแบบปกติโดยมีค่าเฉลี่ยและส่วนเบี่ยงเบนมาตรฐานเท่ากับ 1 และ 0.65 ตามลำดับ
- $w_{pbe}$  หมายถึง น้ำหนักแรงเฉื่อย ซึ่งในกรณีนี้มีค่าเท่ากับ 0.5

## 2. ความน่าจะเป็นในการเรียนรู้แบบปรับได้ (Adaptive Learning Probabilities)

ความน่าจะเป็นในการเรียนรู้เป็นวิธีการที่สำคัญสำหรับการค้นหาดัชนีตัวอย่างของอัลกอริทึม CLPSO อย่างไรก็ตามในอัลกอริทึม CLPSO ความน่าจะเป็นในการเรียนรู้จะขึ้นอยู่กับดัชนีของอนุภาคเท่านั้น และไม่เปลี่ยนแปลงระหว่างการวนซ้ำ ในอัลกอริทึม ECLPSO จึงได้มีการเสนอให้มีการปรับปรุงความน่าจะเป็นในการเรียนรู้ให้สามารถเปลี่ยนแปลงได้โดยใช้ข้อมูลในการจัดอันดับของอนุภาคที่ดีที่สุด (personal best) โดยความน่าจะเป็นในการเรียนรู้แบบปรับได้ของจะแทนที่สมการเดิมด้วยสมการที่ 2.39 ดังนี้

$$Pc_i = L_{\min} + (L_{\max} - L_{\min}) \frac{\exp\left(\frac{10(K_i - 1)}{ps - 1}\right) - 1}{\exp(10) - 1} \quad (2.39)$$

$$L_{\max} = L_{\min} + 0.25 + 0.45 \log_{(D+1)}(M_k + 1) \quad (2.40)$$

เมื่อ  $L_{\max}$  สามารถคำนวณได้จากสมการที่ 2.40

$L_{\min}$  กำหนดให้มีค่าเท่ากับ 0.05


$M_k$  หมายถึง จำนวนมิติก่อนหรือระหว่างการวนซ้ำในครั้งที่  $k$  เมื่อสมการที่ 2.37 เป็นจริง

สมการที่ 2.39 มีหลักการเช่นเดียวกับสมการที่ 2.34 ของอัลกอริทึม CLPSO โดยมีการรวมพารามิเตอร์การจัดอันดับ  $K_i$  ซึ่งสามารถกำหนดได้โดยการเรียงลำดับค่าความเหมาะสมที่ดีที่สุด (personal best fitness value) จากน้อยไปหามาก ดังนั้นหากอนุภาคมีค่าความเหมาะสมดีที่สุดเมื่อเทียบกับอนุภาคอื่นๆ อันดับของอนุภาคนั้นจะมีค่า 1 ( $K_i = 1$ ) ในทางกลับกันหากอนุภาคมีค่าความเหมาะสมแย่มาก อันดับของอนุภาคนั้นจะเท่ากับจำนวนประชากรทั้งหมด ( $K_i = ps$ )

เพื่อป้องกันการลู่เข้าของผลลัพธ์ก่อนกำหนดจึงจำเป็นต้องมีการปรับพารามิเตอร์  $L_{\max}$  ให้มีความเหมาะสม เนื่องจากเมื่อ  $L_{\max}$  มีค่าน้อยจะส่งผลต่อขั้นตอนการสำรวจ และ  $L_{\max}$  ที่มีค่ามากจะส่งผลต่อขั้นตอนการค้นหา ดังนั้นสมการที่ 2.40 จึงใช้เพื่อสร้างความสมดุลระหว่างการสำรวจและการค้นหาของอัลกอริทึม โดย  $L_{\max}$  จะมีค่าน้อยที่สุดเท่ากับ 0.3 เมื่อ  $M_k = 0$  และ  $L_{\max}$  จะมีค่ามากที่สุดเท่ากับ 0.75 เมื่อ  $M_k = D$

ความน่าจะเป็นในการเรียนรู้แบบปรับได้ส่งผลให้อัลกอริทึมสามารถปรับปรุงความสามารถในการค้นหาของอนุภาคจึงทำให้ความเร็วในการค้นหาคำตอบเพิ่มขึ้น ซึ่งเป็นการปรับปรุงข้อด้อยของอัลกอริทึม CLPSO

อัลกอริทึมการปรับปรุงการเรียนรู้อย่างครอบคลุมเพื่อหาค่าเหมาะสมที่สุดของกลุ่มอนุภาคมีขั้นตอนคล้ายกับอัลกอริทึม CLPSO โดยผังการทำงานของอัลกอริทึม ECLPSO แสดงดังรูปที่ 10



รูปที่ 10 ผังการทำงานของอัลกอริทึม ECLPSO (Muong et al.)

### บทที่ 3

## ตัวอย่างปัญหาการวิเคราะห์โครงสร้าง

### 3.1 Problem Statement

ในการศึกษานี้ได้มีการเสนอตัวอย่างการหาค่าที่เหมาะสมของโครงถัก 3 มิติโดยการปรับขนาดและรูปร่างของโครงถักให้เหมาะสมร่วมกันเพื่อหาน้ำหนักน้อยที่สุดของโครงถักซึ่งสามารถเขียนในรูปแบบสมการได้ดังนี้

$$\left. \begin{array}{l} \text{find} \quad X \in R^{n+ng} = \{X_A, X_G\} \\ \text{minimize} \quad W(X_A, X_G) = \sum_{i=1}^n \rho_i L_i A_i \\ \text{subject to} \quad \sigma_i^c \leq \sigma_i \leq \sigma_i^t \quad \text{for } \forall i \in \{1, 2, \dots, n\} \\ \delta_{\min} \leq \delta_j \leq \delta_{\max} \quad \text{for } \forall j \in \{1, 2, \dots, m\} \\ A_{\min} \leq A_i \leq A_{\max} \quad \text{for } \forall i \in \{1, 2, \dots, n\} \end{array} \right\} \quad (3.1)$$

- เมื่อ  $W$  หมายถึง น้ำหนักรวมของโครงสร้างที่เป็นฟังก์ชันค่าความหนาแน่นของชิ้นส่วน  $\rho_i$
- $L_i$  หมายถึง ความยาวของแต่ละชิ้นส่วน
- $A_i$  หมายถึง พื้นที่หน้าตัดของแต่ละชิ้นส่วน
- $m$  หมายถึง จำนวนขององศาอิสระ (degree of freedom)
- $n$  และ  $ng$  หมายถึง จำนวนตัวแปรขนาดและรูปร่างตามลำดับ
- $\delta_j$  หมายถึง ระยะเวลาเคลื่อนที่ (displacement) ที่ตำแหน่งองศาอิสระที่  $j$
- $\sigma_i$  หมายถึง ความเค้น (stress) ของชิ้นส่วน  $i$


ปัญหาการปรับขนาดและรูปร่างให้เหมาะสมตามสม คือการลดน้ำหนักรวมของโครงถักให้มีค่าน้อยที่สุดภายใต้ขอบเขตดังนี้

1. แรงอัด  $\sigma_i^c$  และแรงดึง  $\sigma_i^t$
2. ค่าระยะเวลาเคลื่อนที่ต่ำสุด  $\delta_{\min}$  และค่าระยะเวลาเคลื่อนที่สูงที่สุด  $\delta_{\max}$

3. พื้นที่หน้าตัดต่ำสุด  $A_{\min}$  และพื้นที่หน้าตัดสูงสุด  $A_{\max}$
4. ขอบเขตการเคลื่อนที่ที่กำหนด

### 3.2 โครงถัก 3 มิติ จำนวน 25 ชิ้นส่วน

ตัวอย่างแรกในการศึกษาคือโครงถัก 3 มิติ จำนวน 25 ชิ้นส่วนดังรูปที่ 11 แบ่งกลุ่มขนาดหน้าตัดจำนวน 8 กลุ่ม ซึ่งมีข้อมูลของโครงถักและแรงกระทำดังตารางที่ 2 คุณสมบัติของวัสดุประกอบไปด้วยค่าความหนาแน่นเท่ากับ 0.1 ปอนด์ต่อลูกบาศก์นิ้ว ( $\text{lb}/\text{in}^3$ ) และโมดูลัสความยืดหยุ่นเท่ากับ  $10^4$  กิโลปอนด์ต่อตารางนิ้ว (ksi)




รูปที่ 11 โครงถัก 3 มิติจำนวน 25 ชิ้นส่วน (Ho-Huu et al., 2015)

ตารางที่ 2 ข้อมูลของโครงถัก 3 มิติจำนวน 25 ชิ้นส่วน

Objective function:	$\min W(X_A, X_G) = \sum_{i=1}^{25} \rho_i L_i A_i$
Stress constraints:	$\begin{cases} \sigma_i^t \leq 40 \text{ (ksi)} \\  \sigma_i^c  \leq 40 \text{ (ksi)} \end{cases}, i = 1, 2, \dots, 25$
Displacement constraints:	$\delta_j^{(x,y,z)} \leq 0.35 \text{ in}, j = 1, 2, \dots, 10$
Size variables:	$A_1, A_2 = A_3 = A_4 = A_5, A_6 = A_7 = A_8 = A_9,$ $A_{10} = A_{11}, A_{12} = A_{13}, A_{14} = A_{15} = A_{16} = A_{17},$ $A_{18} = A_{19} = A_{20} = A_{21}, A_{22} = A_{23} = A_{24} = A_{25}$
Shape variables:	$x_4 = x_5 = -x_3 = -x_6,$ $y_3 = y_4 = -y_5 = -y_6,$ $z_3 = z_4 = z_5 = z_6,$ $x_8 = x_9 = -x_7 = -x_{10},$ $y_7 = y_8 = -y_9 = -y_{10}$
Permissible size variables:	$A_i \in S = \{0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9, 1.0, 1.1, 1.2, 1.3, 1.4, 1.5, 1.6, 1.7, 1.8,$ $1.9, 2.0, 2.1, 2.2, 2.3, 2.4, 2.5, 2.6, 2.7, 2.8, 2.9, 3.0, 3.1, 3.2, 3.3, 3.4\} \text{ in}^2$
Limitation of shape variables: (in)	$20 \leq x_4 \leq 60$ $40 \leq y_3 \leq 80$ $90 \leq z_3 \leq 130$ $40 \leq x_8 \leq 80$ $100 \leq y_7 \leq 140$
Loads (kips):	
Node: 1	$F_x = 1, F_y = -10, F_z = -10$
Node: 2	$F_x = 0, F_y = -10, F_z = -10$
Node: 3	$F_x = 0.5, F_y = 0, F_z = 0$
Node: 6	$F_x = 0.6, F_y = 0, F_z = 0$

### 3.3 โครงถัก 3 มิติ จำนวน 39 ชิ้นส่วน

ตัวอย่างที่สองในการศึกษาคือโครงถัก 3 มิติ จำนวน 39 ชิ้นส่วน รูปทรง tower ดังรูปที่ 12 แบ่งกลุ่มขนาดของหน้าตัดออกเป็น 5 กลุ่ม ตั้งข้อมูลของโครงถักและแรงกระทำในตารางที่ 3 คุณสมบัติของวัสดุประกอบไปด้วยค่าความหนาแน่นเท่ากับ 7,800 กิโลกรัมต่อลูกบาศก์เมตร ( $\text{kg/m}^3$ ) และโมดูลัสความยืดหยุ่นเท่ากับ  $210 \times 10^6$  กิโลนิวตันต่อตารางเมตร ( $\text{kN/m}^2$ )



รูปที่ 12 โครงถัก 3 มิติจำนวน 39 ชิ้นส่วน (Ho-Huu et al., 2015)

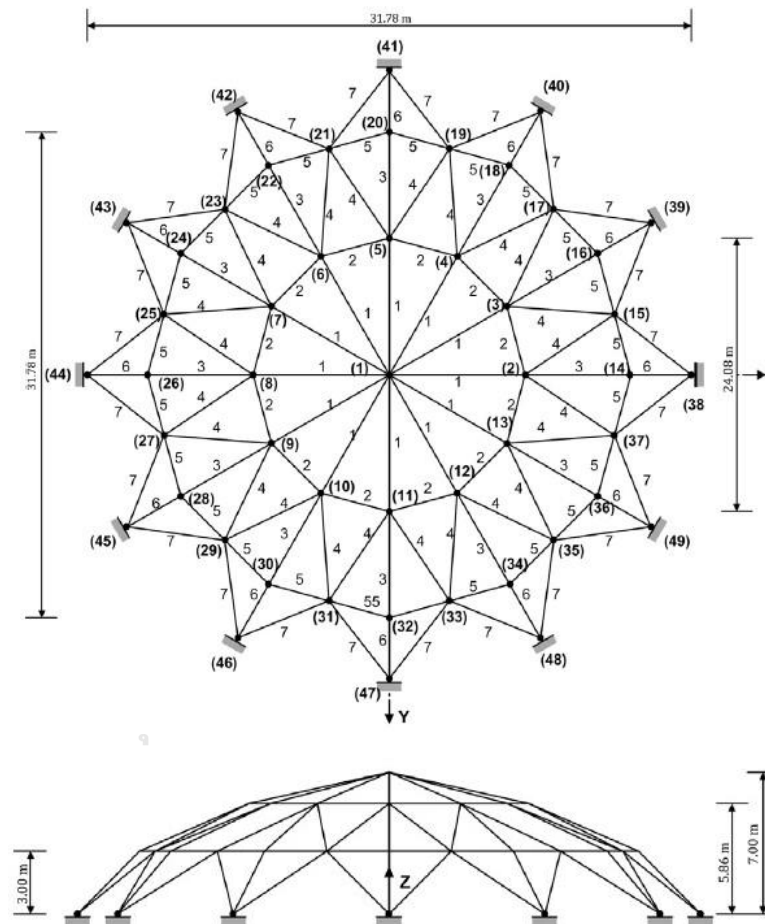


ตารางที่ 3 ข้อมูลของโครงถัก 3 มิติจำนวน 39 ชิ้นส่วน

Objective function:	$\min W(X_A, X_G) = \sum_{i=1}^{39} \rho_i L_i A_i$
Stress constraints:	$\begin{cases} \sigma_i^t \leq 240 \text{ (MPa)} \\  \sigma_i^c  \leq 240 \text{ (MPa)} \end{cases}, i = 1, 2, \dots, 39$
Displacement constraints:	$\delta_{13}^{(y)} \leq 4 \text{ mm}$
Size variables:	$A_1 = A_2 = A_3, A_4 = A_5 = A_6,$ $A_7 = A_8 = A_9, A_{10} = A_{11} = A_{12},$ $A_{13} = A_{14} = A_{15} = A_{16} = A_{17} = A_{18} = A_{19} = A_{20} = A_{21} =$ $A_{22} = A_{23} = A_{24} = A_{25} = A_{26} = A_{27} = A_{28} = A_{29} = A_{30} =$ $A_{31} = A_{32} = A_{33} = A_{34} = A_{35} = A_{36} = A_{37} = A_{38} = A_{39}$
Shape variables:	$y_4, z_4$ $y_7, z_7$ $y_{10}, z_{10}$
Permissible size variables:	$A_i \in S = \{0.1, 0.2, 0.3, \dots, 12.9, 13.0\} \text{ cm}^2$
Limitation of shape variables: (m)	$0.28 \leq y_4 \leq 1$ $0 \leq z_4 \leq 2$ $0.28 \leq y_7 \leq 1$ $1 \leq z_7 \leq 3$ $0.28 \leq y_{10} \leq 1$ $2 \leq z_{10} \leq 4$
Loads (kN):	
Node: 13	$F_x = 0, F_y = 10, F_z = 0$
Node: 14	$F_x = 0, F_y = 10, F_z = 0$
Node: 15	$F_x = 0, F_y = 10, F_z = 0$

### 3.4 โครงถัก 3 มิติ จำนวน 120 ชิ้นส่วน

ตัวอย่างที่สามที่ทำการศึกษาคือโครงถัก 3 มิติ จำนวน 120 ชิ้นส่วนดังรูปที่ 13 ซึ่งเป็นรูปทรงสมมาตร และมีการแบ่งกลุ่มขนาดหน้าตัดชิ้นส่วนจำนวน 7 กลุ่ม ดังข้อมูลของโครงถักและแรงกระทำในตารางที่ 4 คุณสมบัติของวัสดุประกอบไปด้วยค่าความหนาแน่นเท่ากับ 0.288 ปอนด์ต่อลูกบาศก์นิ้ว ( $\text{lb}/\text{in}^3$ ) และโมดูลัสความยืดหยุ่นเท่ากับ 30,450 กิโลปอนด์ต่อตารางนิ้ว ( $\text{ksi}$ )




รูปที่ 13 โครงถัก 3 มิติ รูปทรงโดมจำนวน 120 ชิ้นส่วน

ตารางที่ 4 ข้อมูลของโครงถัก 3 มิติ รูปทรงโดมจำนวน 120 ชิ้นส่วน

Objective function:	$\min W(X_A, X_G) = \sum_{i=1}^{120} \rho_i L_i A_i$
Stress constraints:	$\sigma_i \leq 0.6F_y ; F_y = 58 \text{ ksi}$
Buckling constraints:	$\sigma_c \leq \begin{cases} \left(1 - \frac{(KL/r)^2}{2C_c^2}\right) F_y / \left(\frac{5}{3} + \frac{3(KL/r)}{8C_c} - \frac{(KL/r)^3}{8C_c^3}\right) & \text{if } (KL/r) < C_c \\ \frac{12\pi^2 E}{23(KL/r)^2} & \text{if } (KL/r) \geq C_c \end{cases}$
	When $K = 1, C_c = \sqrt{\frac{2\pi^2 E}{F_y}}, r = 0.4993A^{0.6777}$ (o-section)
Displacement constraints:	$\delta_j^{(x,y,z)} \leq 0.2 \text{ in}, j = 1, 2, \dots, 37$
Size variables:	Section 1 to 12: $A_1$ Section 13 to 24: $A_2$ Section 25 to 36: $A_3$ Section 37 to 60: $A_4$ Section 61 to 84: $A_5$ Section 85 to 96: $A_6$ Section 97 to 120: $A_7$
Shape variables:	Node 1: $Z_1$ Node 2 to 13: $Z_2$ Node 14 to 37: $Z_3$
Permissible size variables:	$A_i \in S = [0.155, 20] \text{ in}^2$
Limitation of shape variables: (in)	
Node 2 to 13:	$166.85 \leq Z \leq 226.85$
Node 14 to 37:	$88.11 \leq Z \leq 148.11$
Loads (kips):	
Node 1:	$F_z = 13.490$
Node 2 to 13:	$F_z = 6.744$
Node 14 to 37:	$F_z = 2.248$

### 3.5 โครงถัก 3 มิติ จำนวน 1,152 ชิ้นส่วน

ตัวอย่างที่สี่ที่ทำการศึกษาในงานวิจัยนี้คือการหารูปร่างที่เหมาะสมของโครงถัก 3 มิติ จำนวน 1,152 ชิ้นส่วน ที่มีฐานรองรับ 4 มุม ดังรูปที่ 14 โดยชิ้นส่วนมีขนาดหน้าตัดเท่ากับ 8 ตารางเซนติเมตร (cm<sup>2</sup>) และมีการเคลื่อนที่ของข้อต่อทุกตำแหน่งในแนวแกน z คุณสมบัติของวัสดุประกอบไปด้วยค่าความหนาแน่นเท่ากับ 7,800 กิโลกรัมต่อลูกบาศก์เมตร (kg/m<sup>3</sup>) และโมดูลัสความยืดหยุ่นเท่ากับ  $210 \times 10^6$  กิโลนิวตันต่อตารางเมตร (kN/m<sup>2</sup>) ข้อมูลของโครงถักและแรงกระทำแสดงดังตารางที่ 5



รูปที่ 14 โครงถัก 3 มิติ จำนวน 1,152 ชิ้นส่วน

ตารางที่ 5 ข้อมูลของโครงถัก 3 มิติ รูปทรงโดมจำนวน 1,152 ชิ้นส่วน

Objective function:	$\min W(X_A, X_G) = A \sum_{i=1}^{1152} \rho_i L_i$
Stress constraints:	$\begin{cases} \sigma_i^t \leq 240 \text{ (MPa)} \\  \sigma_i^c  \leq 240 \text{ (MPa)} \end{cases}, i = 1, 2, \dots, 1152$
Displacement constraints:	$\delta_j^{(x,y,z)} \leq 4 \text{ mm}, j = 1, 2, \dots, 312$
Member size:	$A = 8 \text{ cm}^2$
Shape variables:	$Z_1$ Node 1, 13, 157, 169
	$Z_2$ Node 2, 12, 14, 26, 144, 156, 158, 168
	$Z_3$ Node 3, 11, 27, 39, 131, 143, 159, 167
	$Z_4$ Node 4, 10, 40, 52, 118, 130, 160, 166
	$Z_5$ Node 5, 9, 53, 65, 105, 117, 161, 165
	$Z_6$ Node 6, 8, 66, 78, 92, 104, 162, 164
	$Z_7$ Node 7, 79, 91, 163
	$Z_8$ Node 15, 25, 145, 155
	$Z_9$ Node 16, 24, 28, 38, 132, 142, 146, 154
	$Z_{10}$ Node 17, 23, 41, 51, 119, 129, 147, 153
	$Z_{11}$ Node 18, 22, 54, 64, 106, 116, 148, 152
	$Z_{12}$ Node 19, 21, 67, 77, 93, 103, 149, 151
	$Z_{13}$ Node 20, 80, 90, 150
	$Z_{14}$ Node 29, 37, 133, 141
	$Z_{15}$ Node 30, 36, 42, 50, 120, 128, 134, 140
	$Z_{16}$ Node 31, 35, 55, 63, 107, 115, 135, 139
	$Z_{17}$ Node 32, 34, 68, 76, 94, 102, 136, 138
	$Z_{18}$ Node 33, 81, 89, 137
	$Z_{19}$ Node 43, 49, 121, 127
	$Z_{20}$ Node 44, 48, 56, 62, 108, 114, 122, 126
	$Z_{21}$ Node 45, 47, 69, 75, 95, 101, 123, 125
	$Z_{22}$ Node 46, 82, 88, 124
	$Z_{23}$ Node 57, 61, 109, 113
	$Z_{24}$ Node 58, 60, 70, 74, 96, 100, 110, 112

	$Z_{25}$	Node 59, 83, 87, 111
	$Z_{26}$	Node 71, 73, 97, 99
	$Z_{27}$	Node 72, 84, 86, 98
	$Z_{28}$	Node 85
	$Z_{29}$	Node 171, 180, 182, 193, 290, 301, 303, 312
	$Z_{30}$	Node 172, 179, 194, 205, 278, 289, 304, 311
	$Z_{31}$	Node 173, 178, 206, 217, 266, 277, 305, 310
	$Z_{32}$	Node 174, 177, 218, 229, 254, 265, 306, 309
	$Z_{33}$	Node 175, 176, 230, 241, 242, 253, 307, 308
	$Z_{34}$	Node 183, 192, 291, 300
	$Z_{35}$	Node 184, 191, 195, 204, 279, 288, 292, 299
Shape variables:	$Z_{36}$	Node 185, 190, 207, 216, 267, 276, 293, 298
	$Z_{37}$	Node 186, 189, 219, 228, 255, 264, 294, 297
	$Z_{38}$	Node 187, 188, 231, 240, 243, 252, 295, 296
	$Z_{39}$	Node 196, 203, 280, 287
	$Z_{40}$	Node 197, 202, 208, 215, 268, 275, 281, 286
	$Z_{41}$	Node 198, 201, 220, 227, 256, 263, 282, 285
	$Z_{42}$	Node 199, 200, 232, 239, 244, 251, 283, 284
	$Z_{43}$	Node 209, 214, 269, 274
	$Z_{44}$	Node 210, 213, 221, 226, 257, 262, 270, 273
	$Z_{45}$	Node 211, 212, 233, 238, 245, 250, 271, 272
	$Z_{46}$	Node 222, 225, 258, 261
	$Z_{47}$	Node 223, 224, 234, 237, 246, 249, 259, 260
	$Z_{48}$	Node 235, 236, 247, 248
Limitation of shape variables: (m)		$-1.5 \leq Z \leq 1.5$
Loads (kN):		
Node 72:		$F_z = -10$
Node 84 to 86:		$F_z = -10$
Node 98:		$F_z = -10$

## บทที่ 4

### ผลการศึกษา

#### 4.1 อัลกอริทึมการปรับขนาดและรูปร่างเพื่อหาค่าที่เหมาะสม

อัลกอริทึมการปรับปรุงการเรียนรู้อย่างครอบคลุมเพื่อหาค่าเหมาะสมที่สุดของกลุ่มอนุภาค ร่วมกับแบบจำลองการถดถอยของกระบวนการเกาส์เซียน หรือ ECLPSO-GPR ถูกนำมาใช้ในการแก้ปัญหาการลดน้ำหนักของโครงข่ายผ่านโปรแกรม Python เพื่อออกแบบขนาดและรูปร่างที่ดีที่สุด ปัญหาโครงข่ายต่าง ๆ โดยฟังก์ชันวัตถุประสงค์ของปัญหาการหาค่าที่เหมาะสมของโครงข่ายระบุไว้ใน บทที่ 3 เพื่อหาตัวแปรที่เหมาะสมจำนวน 2 ประเภทคือ ตัวแปรขนาด และตัวแปรรูปร่าง ภายใต้ข้อจำกัดในการออกแบบประกอบด้วยข้อจำกัดด้านความเค้น ระยะการเคลื่อนที่ และการโก่งตัวตามทีละขั้นสำหรับปัญหาแต่ละข้อ

ในการศึกษานี้ได้มีการพัฒนาอัลกอริทึม ECLPSO-GPR เพื่อใช้ในการหาค่าที่เหมาะสมของโครงข่าย จำนวน 2 อัลกอริทึมคือ

1. อัลกอริทึม ECLPSO-GPR ที่มีการใช้แบบจำลอง GPR ในการทำนายผลการวิเคราะห์น้ำหนักของโครงสร้างจากข้อมูลอินพุต และหาขนาดและรูปร่างที่ดีที่สุดโดยใช้อัลกอริทึม ECLPSO
2. อัลกอริทึม ECLPSO-GPR ที่มีการปรับปรุงด้วยฟังก์ชันการเรียนรู้ EI เพื่อเพิ่มประสิทธิภาพของแบบจำลอง GPR โดยอัลกอริทึม ECLPSO จะนำมาใช้ในการหาค่าที่เหมาะสมเพื่อหาไฮเปอร์พารามิเตอร์ และ ฟังก์ชันการเรียนรู้ EI

#### 4.1.2 อัลกอริทึม ECLPSO-GPR

ขั้นตอนการหาค่าที่เหมาะสมของโครงข่ายของอัลกอริทึม ECLPSO-GPR สามารถแสดงได้ดังขั้นตอนต่อไปนี้


1. ป้อนข้อมูลโครงข่ายประกอบด้วยพิกัดของข้อต่อ ข้อมูลการเชื่อมต่อของชิ้นส่วน และพารามิเตอร์อื่นๆ
2. ป้อนข้อมูลพารามิเตอร์สำหรับอัลกอริทึม GPR และอัลกอริทึม ECLPSO
3. ทำการสุ่มตัวแปรขนาดและรูปร่าง ซึ่งอยู่ในช่วงตัวแปรที่กำหนดสำหรับแต่ละปัญหา และทำการวิเคราะห์โครงข่ายด้วยวิธีการรวมสถิติโดยตรงเพื่อหาน้ำหนักของโครงสร้าง โดยมีการ

ปรับแก้ค่าน้ำหนักรวมของโครงสร้างเนื่องจากข้อจำกัดในการออกแบบโดยใช้สมการที่ 2.3 ในบทที่ 2

4. นำข้อมูลในข้อที่ 3 มาใช้เป็นข้อมูลนำเข้าและส่งออกสำหรับการฝึกสอนอัลกอริทึม GPR
  5. เริ่มการปรับให้เหมาะสมด้วยการสร้างตำแหน่งและความเร็วเริ่มต้น และทำการหาค่าน้ำหนัก (ค่าความเหมาะสม) ของโครงถักโดยการทำนายจากแบบจำลองการถดถอย
  6. กำหนดให้ค่าเริ่มต้นเป็นตำแหน่งข้อมูลที่ดีที่สุด (personal best positions และ global best position)
  7. เริ่มต้นการวนซ้ำครั้งแรก ( $k = 1$ ) และปฏิบัติตามขั้นตอนการเพิ่มประสิทธิภาพโดยใช้ อัลกอริทึม ECLPSO ในบทที่ 2
  8. ก่อนการปรับปรุงตำแหน่งที่ดีที่สุด (personal best positions) สำหรับการวนซ้ำแต่ละครั้ง ให้ทำการควบคุมข้อจำกัดโดยการปรับแก้ค่าน้ำหนักรวมของโครงสร้าง
  9. ในระหว่างกระบวนการของทุก ๆ การวนซ้ำ ให้บันทึกตำแหน่งที่ดีที่สุด (global best position) และค่าความเหมาะสม (น้ำหนัก) ที่ดีที่สุด (global best fitness value) เพื่อใช้ในการสร้างกราฟ
  10. แสดงผลลัพธ์การหาค่าความเหมาะสม ซึ่งรวมถึงพื้นที่หน้าตัดที่เหมาะสมที่สุดและพิกัดโหนด ที่ดีที่สุด convergence curve และรูปร่างที่เหมาะสมของโครงถักโครงสร้างโครงถัก
- ผังการทำงานของการทำงานหาค่าที่เหมาะสมของโครงถักด้วยอัลกอริทึม ECLPSO-GPR สามารถสรุปได้

ดังรูปที่ 15





รูปที่ 15 ผังการทำงานของกรออกแบบขนาดและรูปร่างที่เหมาะสมของโครงถัก

#### 4.1.2 อัลกอริทึม ECLPSO-GPR with EI


ทำการเพิ่มประสิทธิภาพของแบบจำลองการทำนายโดยใช้ฟังก์ชันการเรียนรู้การปรับปรุงที่คาดหวัง (Expected Improvement, EI) ในการสร้างจุดข้อมูลฝึกสอนใหม่ที่มีความแม่นยำสูง โดยอัลกอริทึม ECLPSO จะนำมาใช้ในการหาค่าที่เหมาะสมเพื่อหาค่าไฮเปอร์พารามิเตอร์ของแบบจำลอง GPR และใช้ในการหาค่าที่เหมาะสมในการเพิ่มจุดข้อมูลของฟังก์ชันการเรียนรู้ EI ดังขั้นตอนต่อไปนี้

1. ป้อนข้อมูลโครงหลักประกอบด้วยพิกัดของข้อต่อ ข้อมูลการเชื่อมต่อของชิ้นส่วน และพารามิเตอร์อื่นๆ
3. ป้อนข้อมูลพารามิเตอร์สำหรับอัลกอริทึม GPR และอัลกอริทึม ECLPSO
4. ทำการสุ่มตัวแปรขนาดและรูปร่างเริ่มต้นด้วย Latin hypercube sampling (LHS) ซึ่งอยู่ในช่วงตัวแปรที่กำหนดสำหรับแต่ละปัญหา และทำการวิเคราะห์โครงหลักด้วยวิธีการรวมสถิติเนสโดยตรงเพื่อหาน้ำหนักของโครงสร้าง โดยมีกรปรับแก้ค่าน้ำหนักรวมของโครงสร้างเนื่องจากข้อจำกัดในการออกแบบโดยใช้สมการที่ 2.3 ในบทที่ 2
5. นำข้อมูลในข้อที่ 3 มาใช้เป็นข้อมูลนำเข้าและส่งออกสำหรับการฝึกสอนอัลกอริทึม GPR โดยผลลัพธ์ที่ได้จากแบบจำลองจะประกอบไปด้วยค่าเฉลี่ยข้อมูลน้ำหนักโครงสร้าง และค่าความแปรปรวนของแบบจำลอง
6. จากขั้นตอนข้างต้นทำการหาค่า hyperparameter ที่เหมาะสมของแบบจำลองด้วยวิธีการ maximum likelihood estimation โดยใช้อัลกอริทึม ECLPSO ในการหาค่าที่น้อยที่สุดของฟังก์ชัน negative log-likelihood
7. ทำการปรับปรุงประสิทธิภาพของแบบจำลองด้วยการใช้ฟังก์ชันการเรียนรู้ในการหาค่าตำแหน่งที่เหมาะสมที่จะใช้เป็นข้อมูลในการฝึกสอนของแบบจำลอง โดยใช้อัลกอริทึม ECLPSO ในการหาค่าตำแหน่งที่ฟังก์ชัน EI มีค่ามากที่สุด
8. นำตำแหน่งข้อมูลในข้อที่ 6 มาทำการวิเคราะห์โครงหลักด้วยวิธีการรวมสถิติเนสโดยตรง เพื่อหาค่าน้ำหนักรวมที่น้อยที่สุด และนำข้อมูลดังกล่าวเพิ่มในชุดข้อมูลการฝึกสอนของแบบจำลอง GPR
9. ทำซ้ำในกระบวนการที่ 6 และ 7 จนครบตามจำนวนที่กำหนด
10. แสดงผลลัพธ์การหาค่าความเหมาะสม ซึ่งรวมถึงพื้นที่หน้าตัดที่เหมาะสมที่สุดและพิกัดโหนดที่ดีที่สุด convergence curve และรูปร่างที่เหมาะสมของโครงสร้างโครงหลัก

อัลกอริทึม ECLPSO-GPR with EI แสดงดังตารางที่ 6 และผังการทำงานของการหาค่าที่เหมาะสมของโครงถักสามารถสรุปได้ดังรูปที่ 16

ตารางที่ 6 อัลกอริทึม ECLPSO-GPR with EI

Algorithm: ECLPSO-GPR with EI
<p><b>Input:</b> Truss structural data            GPR parameter  <math>n_0</math>: number of the initial data  <math>N_{\max}</math>: maximum iterations</p> <p><b>Output:</b> <math>X</math> best position  <math>y</math> best solution</p>
<ol style="list-style-type: none"> <li>1. Using LHS to obtain <math>n_0</math> combinations of hyperparameters <math>X_{n_0}</math> from the design space.</li> <li>2. Training the model with the above hyperparameters to obtain the weight values <math>y_{op_{n_0}}</math></li> <li>3. Collect a set of initial observations <math>D_{n_0} = (X_i, y_{op_i}) \forall i = 1, 2, \dots, n_0</math></li> <li>4. Target <math>y_{op}(X) = \min y_{op}</math></li> <li>5. Set <math>n = n_0</math></li> <li>6. <b>while</b> <math>n \leq N_{\max}</math> <b>do</b></li> <li>7. Find GP hyperparameter by the maximum likelihood estimation method (using ECLPSO to optimize negative log-likelihood)</li> <li>8. Build the GP model on <math>D_n</math></li> <li>9. Find <math>X_{n+1}</math> by using ECLPSO to maximize EI function (Eq.2.25)</li> <li>10. Training the model with the hyperparameters <math>X_{n+1}</math> to evaluate <math>y_{op_{n+1}}</math></li> <li>11. Append <math>D_{n+1} = D_n \cup \{(X_{n+1}, y_{op_{n+1}})\}</math></li> <li>12. Update <math>y_{op}(X)</math></li> <li>13. <math>n = n + 1</math></li> <li>14. <b>end while</b></li> </ol>




รูปที่ 16 ผังการทำงานของอัลกอริทึม GPR-ECLPSO ที่มีการปรับปรุงด้วยฟังก์ชัน EI

#### 4.2 ผลลัพธ์การหาค่าที่เหมาะสมของโครงถัก 3 มิติ จำนวน 25 ชิ้นส่วน

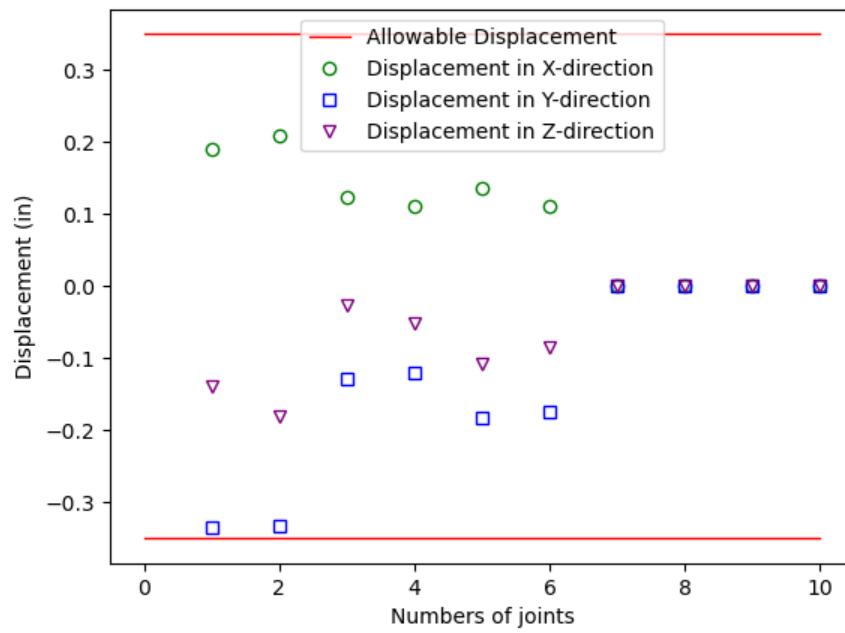
ตัวอย่างการศึกษาที่ 1 มีจำนวนตัวแปรทั้งหมด 13 ตัวแปร ประกอบไปด้วยตัวแปรขนาด 8 ตัวแปร และตัวแปรรูปร่าง 5 ตัวแปร ซึ่งใช้ในการออกแบบภายใต้ข้อจำกัดระยะการเคลื่อนที่ ( $\delta_j^{(x,y,z)} \leq 0.35$  in) และข้อจำกัดของความเค้น ( $\sigma_i' \leq 40$  (ksi) และ  $|\sigma_i^c| \leq 40$  (ksi)) ได้ผลการศึกษาดังตารางที่ 7

ตารางที่ 7 ผลลัพธ์การหาค่าที่เหมาะสมของโครงถัก 3 มิติ จำนวน 25 ชิ้นส่วน

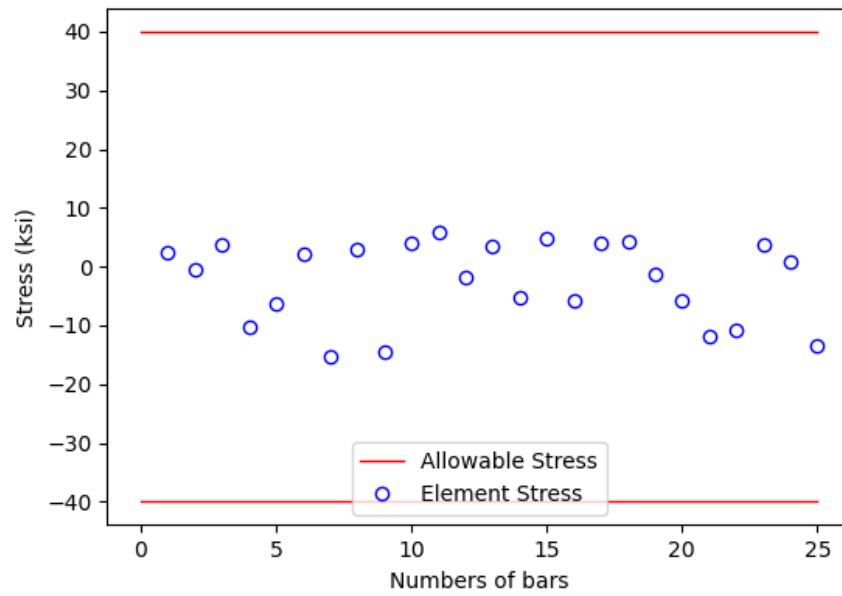
Design Variables	(Gholizadeh , 2013)	(Ho-Huu et al., 2015)	ECLPSO	This study ECLPSO-GPR	
	SCPSO	D-ICDE		without EI	with EI
A1	0.1	0.1	0.1	0.8	0.2
A2	0.1	0.1	0.1	0.1	0.2
A3	1.0	0.9	1.1	1.1	0.9
A4	0.1	0.1	0.1	0.4	0.1
A5	0.1	0.1	0.1	0.8	0.3
A6	0.1	0.1	0.1	0.1	0.1
A7	0.1	0.1	0.1	0.1	0.3
A8	0.9	1.0	0.9	1.0	1.0
X4	36.9520	36.83	39.9664	30.5856	36.0605
Y4	54.5786	58.53	57.4330	54.2412	55.5611
Z4	129.9758	122.67	124.1553	123.4425	122.0912
X8	51.7317	49.21	58.0017	47.0952	45.5010
Y8	139.5316	136.74	138.6544	132.7714	132.4484
Weight (lb)	117.227	118.76	120.02	145.00	138.86
Max. stress (ksi)	-24.9912	-	-19.0274	-19.0168	-15.2834
Max. Displacement (in)	-	-	0.3479	0.3432	0.3348
Structural analyzes	4500	6000	6000	600	600



รูปที่ 17 รูปทรงโครงถัก 3 มิติ จำนวน 25 ชิ้นส่วนที่เหมาะสม



รูปที่ 18 ระยะการเคลื่อนที่ของข้อต่อของโครงถัก 3 มิติ จำนวน 25 ชิ้นส่วน



รูปที่ 19 ความเค้นภายในชิ้นส่วนของโครงถัก 3 มิติ จำนวน 25 ชิ้นส่วน




### 4.3 ผลลัพธ์การหาค่าที่เหมาะสมของโครงถัก 3 มิติ จำนวน 39 ชิ้นส่วน

ตัวอย่างการศึกษาที่ 2 มีจำนวนตัวแปรทั้งหมด 11 ตัวแปร ประกอบไปด้วยตัวแปรขนาด 5 ตัวแปร และตัวแปรรูปร่าง 6 ตัวแปร ซึ่งใช้ในการออกแบบภายใต้ข้อจำกัดระยะการเคลื่อนที่ ( $\delta_{13}^{(y)} \leq 4 \text{ mm}$ ) และข้อจำกัดของความเค้น ( $\sigma_i^c \leq 240 \text{ (MPa)}$  และ  $|\sigma_i^c| \leq 240 \text{ (MPa)}$ ) ได้ผลการศึกษาดังตารางที่ 8


ตารางที่ 8 ผลลัพธ์การหาค่าที่เหมาะสมของโครงถัก 3 มิติ จำนวน 39 ชิ้นส่วน

Design Variables	(Wang et al., 2002)	(Ho-Huu et al., 2015)	ECLPSO	This study ECLPSO-GPR	
		D-ICDE		without EI	with EI
A1	11.01	13.0	11.9	11.9	12.8
A2	8.63	12.9	11.0	11.2	10.3
A3	6.69	9.0	7.9	8.7	9.9
A4	4.11	2.7	3.3	4.6	3.9
A5	4.37	1.6	1.7	2.7	1.9
Y4	0.805	0.9232	0.9826	0.9325	0.9375
Z4	1.186	0.5380	0.8513	1.2113	1.0797
Y7	0.654	0.7958	0.9582	0.8230	0.9216
Z7	2.204	2.1637	1.9744	2.3368	2.3753
Y10	0.466	0.5105	0.7618	0.6625	0.8216
Z10	3.092	3.4131	2.9777	2.8697	3.1731
Weight (kg)	203.18	140.35	133.77	169.38	147.97
Max. stress (MPa)	-	-	-60.3734	-60.6960	64.3755
Displacement: $y_{13}$ (mm)	-	-	3.9920	3.5046	3.8386
Structural analyzes	-	1140	1200	400	400





รูปที่ 20 รูปทรงโครงถัก 3 มิติ จำนวน 39 ชิ้นส่วนที่เหมาะสม



รูปที่ 21 ความเค้นภายในชิ้นส่วนของโครงถัก 3 มิติ จำนวน 39 ชิ้นส่วน


#### 4.4 ผลลัพธ์การหาค่าที่เหมาะสมของโครงถัก 3 มิติ จำนวน 120 ชิ้นส่วน

ตัวอย่างการศึกษาที่ 3 มีจำนวนตัวแปรทั้งหมด 11 ตัวแปร ประกอบไปด้วยตัวแปรขนาด 5 ตัวแปร และตัวแปรรูปร่าง 6 ตัวแปร ซึ่งใช้ในการออกแบบภายใต้ข้อจำกัดระยะการเคลื่อนที่ ( $\delta_j^{(x,y,z)} \leq 0.2 \text{ in}$ ) และข้อจำกัดของความเค้น ( $\sigma_t \leq 0.6F_y$ ) และข้อจำกัดของการโก่งเดาะ

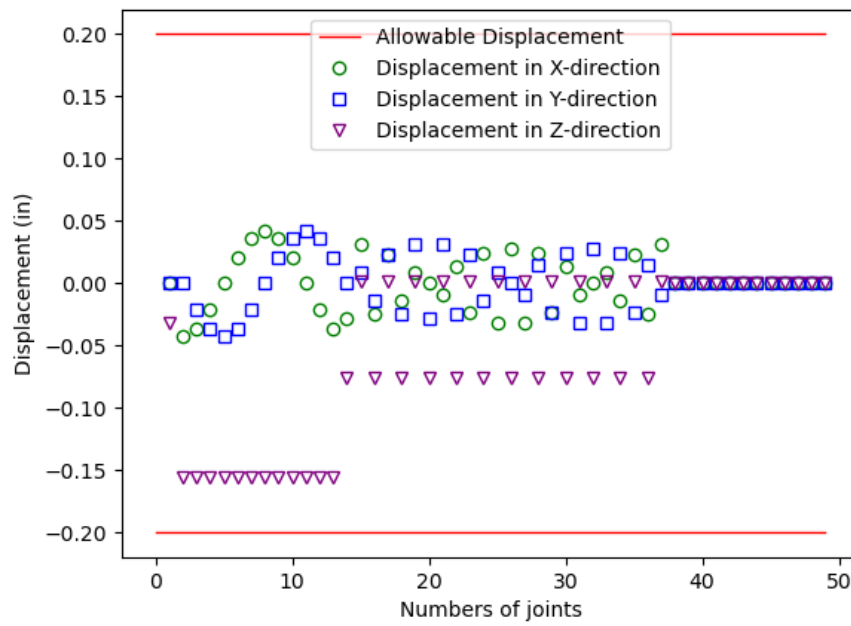
$$\sigma_c \leq \begin{cases} \left(1 - \frac{(KL/r)^2}{2C_c^2}\right) F_y / \left(\frac{5}{3} + \frac{3(KL/r)}{8C_c} - \frac{(KL/r)^3}{8C_c^3}\right) & \text{if } (KL/r) < C_c \\ \frac{12\pi^2 E}{23(KL/r)^2} & \text{if } (KL/r) \geq C_c \end{cases} \quad \text{) ได้ผลการศึกษาดังตารางที่ 9}$$

ตารางที่ 9 ผลลัพธ์การหาค่าที่เหมาะสมของโครงถัก 3 มิติ จำนวน 120 ชิ้นส่วน

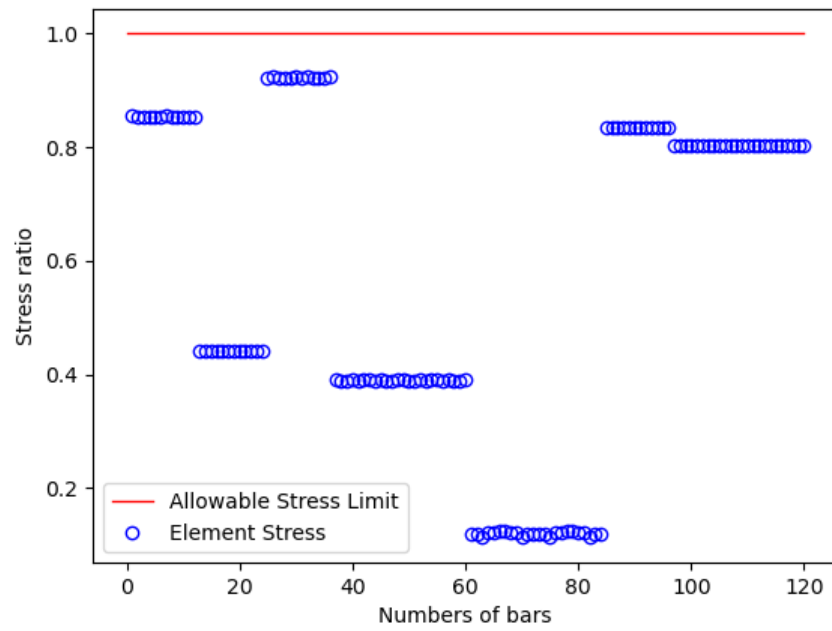
Design Variables	Original Structure	ECLPSO	This study ECLPSO-GPR	
			without EI	with EI
A1	10	2.8412	3.0877	3.0169
A2	10	2.4570	3.1666	3.5048
A3	10	3.3233	3.9505	3.4265
A4	10	2.1162	2.6024	3.1523
A5	10	0.1602	3.0847	0.6214
A6	10	2.5103	2.7799	2.7023
A7	10	2.2736	2.6678	2.4925
Z2	196.85	222.5178	221.1596	221.6132
Z3	118.11	104.3549	103.9232	104.0378
Weight (lb)	71053.52	15804.14	21168.33	19330.54
Max. stress (ksi)	-3.328	-6.5926	-5.2700	-4.7121
Max. Displacement (in)	0.1629	0.1939	0.1597	0.1556
Structural analyzes	-	6000	600	600



รูปที่ 22 รูปทรงโครงถัก 3 มิติ จำนวน 120 ชิ้นส่วนที่เหมาะสม



รูปที่ 23 ระยะการเคลื่อนที่ของข้อต่อของโครงถัก 3 มิติ จำนวน 120 ชิ้นส่วน



รูปที่ 24 ความเค้นภายในชิ้นส่วนของโครงถัก 3 มิติ จำนวน 120 ชิ้นส่วน




#### 4.5 ผลลัพธ์การหาค่าที่เหมาะสมของโครงถัก 3 มิติ จำนวน 1,152 ชิ้นส่วน

ตัวอย่างการศึกษาที่ 4 มีขนาดหน้าตัด 8 ตารางเซนติเมตร และมีตัวแปรรูปร่างจำนวน 48 ตัวแปร ซึ่งใช้ในการออกแบบภายใต้ข้อจำกัดระยะการเคลื่อนที่ ( $\delta_j^{(x,y,z)} \leq 4 \text{ mm}$ ) และข้อจำกัดของความเค้น ( $\sigma_i' \leq 240 \text{ (MPa)}$  และ  $|\sigma_i^c| \leq 240 \text{ (MPa)}$ ) ได้ผลการศึกษาดังตารางที่ 10

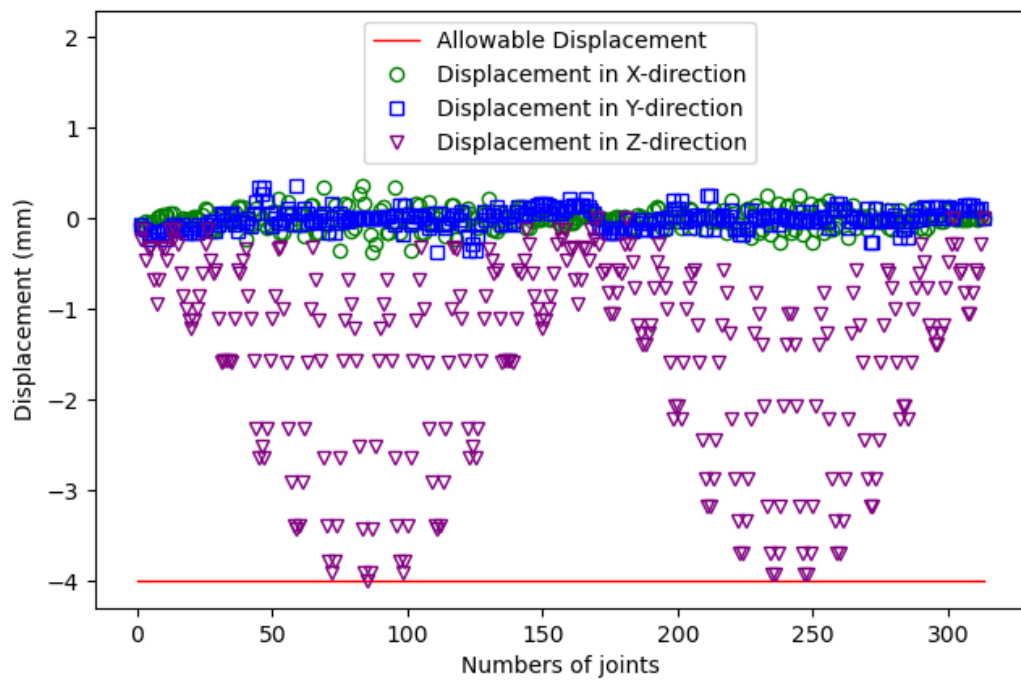
ตารางที่ 10 ผลลัพธ์การหาค่าที่เหมาะสมของโครงถัก 3 มิติ จำนวน 1,152 ชิ้นส่วน

Design Variables	Original Structure	ECLPSO	This study ECLPSO-GPR	
			without EI	with EI
Z1	0	-0.4770	1.2718	-0.7958
Z2	0	-0.7686	-0.1001	-0.8042
Z3	0	-0.6394	0.9078	-0.6384
Z4	0	-0.1018	-0.1800	-0.5255
Z5	0	-0.3722	-0.6550	-0.1038
Z6	0	-0.4204	0.6080	-0.0278
Z7	0	-0.6035	0.8546	0.1199
Z8	0	-1.0176	-0.9505	-1.1699
Z9	0	-0.6319	-0.3770	-0.5199
Z10	0	-0.2629	-0.0327	-0.0530
Z11	0	-0.1402	0.1445	-0.0974
Z12	0	-0.3009	0.1360	-0.0447
Z13	0	-0.4601	0.7192	0.2670
Z14	0	-0.4890	0.0291	-0.2391
Z15	0	0.1323	-0.2351	-0.0482
Z16	0	0.3412	-0.0742	0.4557
Z17	0	0.1748	0.4882	0.6236
Z18	0	0.3824	0.1265	0.5912
Z19	0	0.5604	0.1266	0.4620
Z20	0	0.4358	0.7755	0.6746
Z21	0	0.6242	0.3235	1.0036
Z22	0	0.9864	-0.7485	1.0665
Z23	0	0.8231	0.5172	0.4446
Z24	0	1.1928	-0.5522	0.0816

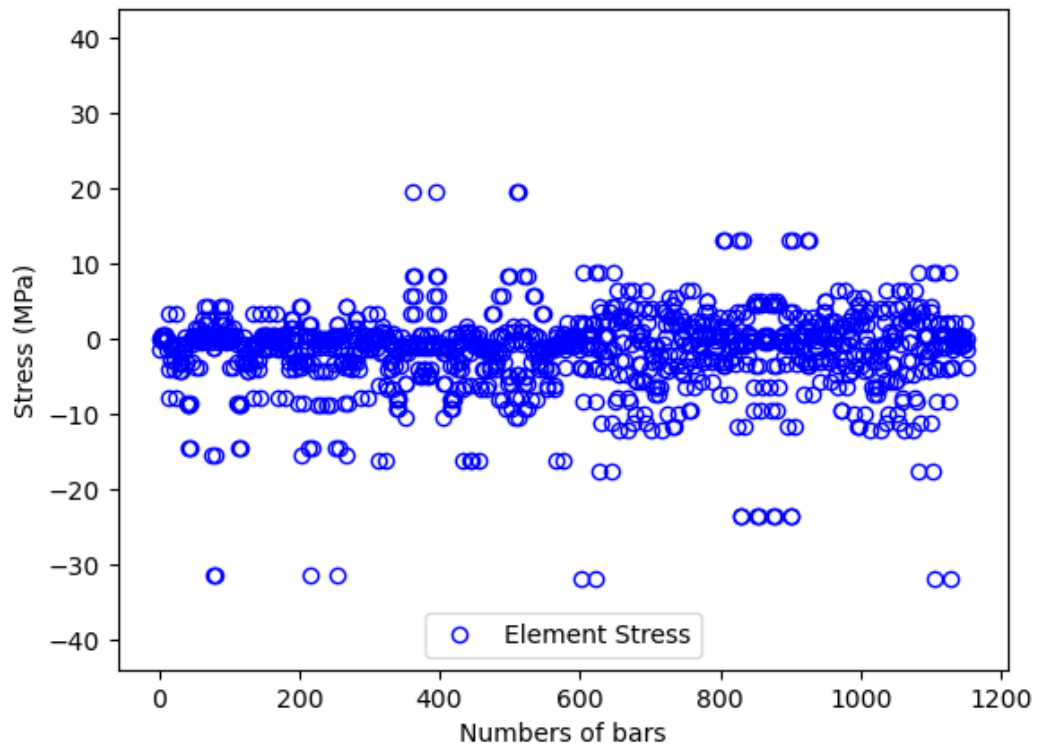
Design Variables	Original Structure	ECLPSO	This study ECLPSO-GPR	
			without EI	with EI
Z25	0	0.6314	-0.5780	1.3969
Z26	0	0.4774	-0.9406	-0.2752
Z27	0	0.1761	-1.4062	1.4833
Z28	0	-0.3446	-0.3557	-0.8321
Z29	-1.2	-0.7140	-1.1084	-0.5865
Z30	-1.2	-0.4739	-0.6613	-0.2716
Z31	-1.2	-0.4857	0.2618	-0.0020
Z32	-1.2	-0.7413	0.3173	-0.0295
Z33	-1.2	-0.6138	0.5749	0.0019
Z34	-1.2	-0.5611	-1.2036	-0.8503
Z35	-1.2	-0.1110	-0.2077	-0.3665
Z36	-1.2	-0.0699	0.4172	0.2311
Z37	-1.2	-0.0909	0.8772	0.3080
Z38	-1.2	0.0036	0.9598	0.1447
Z39	-1.2	-0.0502	0.1592	0.1954
Z40	-1.2	0.1887	0.9039	0.3517
Z41	-1.2	0.4487	0.8216	0.7244
Z42	-1.2	-0.0204	0.2190	0.7563
Z43	-1.2	1.0351	1.1709	0.3618
Z44	-1.2	0.9507	1.0321	-0.0855
Z45	-1.2	0.8007	1.3425	0.9628
Z46	-1.2	1.0937	0.4708	-0.1536
Z47	-1.2	1.3345	-0.5923	-0.2882
Z48	-1.2	1.4125	-1.4586	1.4047
Weight (kg)	11147.76	9498.09	10505.36	9823.66
Max. stress (MPa)	-12.33	-34.32	-26.76	-31.78
Max. Displacement (mm)	0.7903	3.8973	3.8443	3.9979
Structural analyzes	-	8000	1000	1000



รูปที่ 25 รูปทรงโครงถัก 3 มิติ จำนวน 1,152 ชิ้นส่วนที่เหมาะสม



รูปที่ 26 ระยะการเคลื่อนที่ของข้อต่อของโครงถัก 3 มิติ จำนวน 1,152 ชิ้นส่วน



รูปที่ 27 ความเค้นภายในชิ้นส่วนของโครงถัก 3 มิติ จำนวน 1,152 ชิ้นส่วน





## บทที่ 5

### สรุปและอภิปรายผล

#### 5.1 สรุปผลการวิจัย

การศึกษานี้นำเสนอวิธีการแก้ปัญหาของการเพิ่มประสิทธิภาพการออกแบบขนาดและรูปร่างของโครงถักอย่างเหมาะสม โดยใช้อัลกอริทึมการปรับปรุงการเรียนรู้อย่างครอบคลุมเพื่อหาค่าเหมาะสมที่สุดของกลุ่มอนุภาค ร่วมกับแบบจำลองการถดถอยของกระบวนการเกาส์เซียน (ECLPSO-GPR) วัตถุประสงค์ของการศึกษานี้คือการนำอัลกอริทึม ECLPSO-GPR มาประยุกต์ใช้กับโครงถัก 3 มิติภายใต้ข้อจำกัดด้านการออกแบบ คือข้อจำกัดความเค้นสูงสุด ข้อจำกัดการโก่งเดาะ และข้อจำกัดด้านสถานะการใช้งานหรือการเคลื่อนที่ของตำแหน่งข้อต่อ โดยทำการเปรียบเทียบผลลัพธ์ที่ได้กับผลลัพธ์ที่ได้จากอัลกอริทึม ECLPSO มาตรฐาน และ/หรือผลลัพธ์จากตัวอย่างการศึกษาอื่น

จากผลลัพธ์การหาค่าที่เหมาะสมที่สุดของโครงถักทั้ง 4 ตัวอย่างดังแสดงในบทที่ 4 พบว่าผลลัพธ์การหาค่าที่เหมาะสมของน้ำหนักรวมของโครงถักในการแก้ปัญหาโดยใช้อัลกอริทึม ECLPSO-GPR ที่ไม่มีการปรับปรุงประสิทธิภาพด้วยฟังก์ชันการเรียนรู้ EI มีจำนวนการวิเคราะห์โครงถักด้วยระเบียบวิธีไฟไนต์เอลิเมนต์ที่น้อยกว่า แต่มีค่าน้ำหนักรวมที่มากกว่าเมื่อเปรียบเทียบกับค่าที่เหมาะสมด้วยอัลกอริทึม ECLPSO และเมื่อทำการเพิ่มประสิทธิภาพของอัลกอริทึม ECLPSO-GPR โดยการปรับปรุงประสิทธิภาพด้วยฟังก์ชันการเรียนรู้ EI พบว่าที่จำนวนการวิเคราะห์โครงถักที่เท่ากัน ค่าน้ำหนักรวมของโครงสร้างมีค่าลดลง และมีค่าเข้าใกล้ค่าการออกแบบที่เหมาะสมที่สุด

#### 5.2 ข้อเสนอแนะ

สำหรับการแก้ปัญหาค่าที่เหมาะสมของโครงสร้างที่มีจำนวนตัวแปรน้อย อัลกอริทึม ECLPSO-GPR จะให้ค่าผลลัพธ์ที่มีความแม่นยำมากขึ้น อย่างไรก็ตามในการแก้ปัญหาค่าที่เหมาะสมของโครงสร้างที่มีความซับซ้อนที่จำเป็นต้องมีการวิเคราะห์โครงสร้างด้วยระเบียบวิธีไฟไนต์เอลิเมนต์ที่มีความซับซ้อนมาก เช่น โครงสร้างขนาดใหญ่ที่มีจำนวนชิ้นส่วนมาก โครงสร้างที่มีการวิเคราะห์แบบไม่เชิงเส้น หรือโครงสร้างที่เกี่ยวข้องกับระบบไดนามิก การนำอัลกอริทึม ECLPSO-GPR มาปรับใช้กับปัญหาดังกล่าวจะช่วยลดขั้นตอนในการวิเคราะห์โครงสร้างด้วยระเบียบวิธีไฟไนต์เอลิเมนต์ที่ใช้เวลานานได้ โดยสามารถปรับปรุงและพัฒนาประสิทธิภาพของอัลกอริทึม ECLPSO-GPR ได้

โดยการคัดเลือกข้อมูลที่เหมาะสมในการใช้เป็นชุดข้อมูลฝึกสอน โดยทำการระบุข้อมูลค่าผิดปกติ (Outliers) และตัดข้อมูลดังกล่าวออกจากชุดข้อมูลฝึกสอน เพื่อเพิ่มประสิทธิภาพของแบบจำลอง GPR



บรรณานุกรม



จุฬาลงกรณ์มหาวิทยาลัย  
**CHULALONGKORN UNIVERSITY**

- Abu-Mostafa, Y. S., Magdon-Ismail, M., & Lin, H.-T. (2012). *Learning from data* (Vol. 4). AMLBook New York.
- Gholizadeh, S. (2013). Layout optimization of truss structures by hybridizing cellular automata and particle swarm optimization. *Computers & structures*, 125, 86-99.
- Ho-Huu, V., Nguyen-Thoi, T., Nguyen-Thoi, M., & Le-Anh, L. (2015). An improved constrained differential evolution using discrete variables (D-ICDE) for layout optimization of truss structures. *Expert Systems with Applications*, 42(20), 7057-7069.
- Jawad, F. K., Mahmood, M., Wang, D., Osama, A.-A., & Anas, A.-J. (2021). Heuristic dragonfly algorithm for optimal design of truss structures with discrete variables. *Structures*,
- Jones, D. R., Schonlau, M., & Welch, W. J. (1998). Efficient global optimization of expensive black-box functions. *Journal of Global optimization*, 13(4), 455.
- Kassimali, A. (2018). *Structural analysis*. Cengage Learning.
- Kennedy, J., & Eberhart, R. (1995). Particle swarm optimization. Proceedings of ICNN'95-international conference on neural networks,
- Li, L.-J., Huang, Z., Liu, F., & Wu, Q. (2007). A heuristic particle swarm optimizer for optimization of pin connected structures. *Computers & structures*, 85(7-8), 340-349.
- Liang, J. J., Qin, A. K., Suganthan, P. N., & Baskar, S. (2006). Comprehensive learning particle swarm optimizer for global optimization of multimodal functions. *IEEE transactions on evolutionary computation*, 10(3), 281-295.
- Mai, H. T., Lee, S., Kim, D., Lee, J., Kang, J., & Lee, J. (2023). Optimum design of nonlinear structures via deep neural network-based parameterization framework. *European Journal of Mechanics-A/Solids*, 98, 104869.
- Melo, J. (2012). Gaussian processes for regression: a tutorial. *Technical Report*.
- Muong, S., Van, T. H., Van, C. N., & Tangaramvong, S. Simultaneous Size and Shape Structural Optimization using Enhanced Comprehensive Learning Particle Swarm Optimization.
- Murphy, K. P. (2012). *Machine learning: a probabilistic perspective*. MIT press.

- Tejani, G. G., Savsani, V. J., Patel, V. K., & Savsani, P. V. (2018). Size, shape, and topology optimization of planar and space trusses using mutation-based improved metaheuristics. *Journal of Computational Design and Engineering*, 5(2), 198-214.
- Thai, H.-T. (2022). Machine learning for structural engineering: A state-of-the-art review. *Structures*,
- Van, T. H., Tangaramvong, S., Muong, S., & Van, P. T. (2022). Combined Gaussian Local Search and Enhanced Comprehensive Learning PSO Algorithm for Size and Shape Optimization of Truss Structures. *Buildings*, 12(11), 1976.
- Venter, G., & Sobieszczanski-Sobieski, J. (2004). Multidisciplinary optimization of a transport aircraft wing using particle swarm optimization. *structural and Multidisciplinary optimization*, 26(1), 121-131.
- Wang, D., Zhang, W., & Jiang, J. (2002). Combined shape and sizing optimization of truss structures. *Computational mechanics*, 29(4), 307-312.
- Williams, C. K., & Rasmussen, C. E. (2006). *Gaussian processes for machine learning* (Vol. 2). MIT press Cambridge, MA.
- Yu, X., & Zhang, X. (2014). Enhanced comprehensive learning particle swarm optimization. *Applied Mathematics and Computation*, 242, 265-276.

## ประวัติผู้เขียน

ชื่อ-สกุล	วรัญญา เจริญยิ่ง
วัน เดือน ปี เกิด	05 มกราคม 2542
สถานที่เกิด	เชียงใหม่
วุฒิการศึกษา	2560, วิศวกรรมศาสตรบัณฑิต ภาควิชาวิศวกรรมโยธา คณะ วิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย



จุฬาลงกรณ์มหาวิทยาลัย  
CHULALONGKORN UNIVERSITY