

การพัฒนาวิธีการค้นหาแบบนกกาเหว่าโดยการผสมผสานด้วยเจเนติกอัลกอริทึม  
สำหรับหาค่าที่เหมาะสมของการทำเหมะลอกแบบออสโมซิส

วีระ พุ่มเกิด

ดุษฎีนิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปรัชญาดุษฎีบัณฑิต

สาขาวิชาการวิจัยและสถิติทางวิทยาการปัญญา

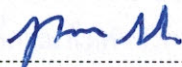
วิทยาลัยวิทยาการวิจัยและวิทยาการปัญญา มหาวิทยาลัยบูรพา


สิงหาคม 2560

ลิขสิทธิ์เป็นของมหาวิทยาลัยบูรพา

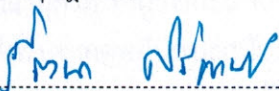
คณะกรรมการควบคุมดัชนีพนธ์และคณะกรรมการสอบดัชนีพนธ์ ได้พิจารณา  
ดัชนีพนธ์ของ วีระ พุ่มเกิด ฉบับนี้แล้ว เห็นสมควรรับเป็นส่วนหนึ่งของการศึกษาตามหลักสูตร  
ปรัชญาดุษฎีบัณฑิต สาขาวิชาการวิจัยและสถิติทางวิทยาการปัญญา ของมหาวิทยาลัยบูรพาได้

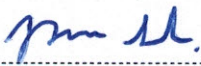
คณะกรรมการควบคุมดัชนีพนธ์

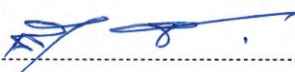
  
..... อาจารย์ที่ปรึกษาหลัก  
(ผู้ช่วยศาสตราจารย์ ดร. พูลพงศ์ สุขสว่าง)


  
..... อาจารย์ที่ปรึกษาร่วม  
(รองศาสตราจารย์ ดร. เสรี ชัดเข้ม)

คณะกรรมการสอบดัชนีพนธ์

  
..... ประธาน  
(ศาสตราจารย์ ดร. รัตนา ศิริพานิช)


  
..... กรรมการ  
(ผู้ช่วยศาสตราจารย์ ดร. พูลพงศ์ สุขสว่าง)

  
..... กรรมการ  
(รองศาสตราจารย์ ดร. เสรี ชัดเข้ม)

  
..... กรรมการ  
(ผู้ช่วยศาสตราจารย์ ดร. สุชาดา กรเพชรปาณี)

  
..... กรรมการ  
(ดร. กนก พานทอง)

วิทยาลัยวิทยาการวิจัยและวิทยาการปัญญาอนุมัติให้รับดัชนีพนธ์ฉบับนี้เป็นส่วนหนึ่ง  
ของการศึกษาตามหลักสูตรปรัชญาดุษฎีบัณฑิต สาขาวิชาการวิจัยและสถิติทางวิทยาการปัญญาของ  
มหาวิทยาลัยบูรพา

  
..... คณบดีวิทยาลัยวิทยาการวิจัย  
(ผู้ช่วยศาสตราจารย์ ดร. สุชาดา กรเพชรปาณี) และวิทยาการปัญญา  
วันที่ 14 เดือน สิงหาคม พ.ศ. 2560

## ประกาศคุณูปการ

คุษฎีนิพนธ์เรื่องการพัฒนาวิธีการค้นหาแบบนกกาเหว่าโดยการผสมผสานด้วยเจเนติก อัลกอริทึมสำหรับหาค่าที่เหมาะสมของการทำแห้งมะละกอบบบอสมอซิสนบนี้ สำเร็จลุล่วงได้ด้วย ความกรุณา ช่วยเหลือแนะนำและให้คำปรึกษาอย่างดียิ่งจาก ผู้ช่วยศาสตราจารย์ ดร.พูลพงศ์ สุขสว่าง อาจารย์ที่ปรึกษาหลัก ที่กรุณาให้คำปรึกษาแนะนำแนวทางที่ถูกต้องตลอดจนแก้ไข ข้อบกพร่องต่าง ๆ ด้วยความละเอียดถี่ถ้วนและเอาใจใส่ และรองศาสตราจารย์ ดร.เสรี ชัดเข้ม อาจารย์ที่ปรึกษาร่วมที่ได้กรุณาถ่ายทอดความรู้ แนวคิด วิธีการ คำแนะนำ และตรวจสอบแก้ไข ข้อบกพร่องต่าง ๆ ด้วยความเอาใจใส่ยิ่ง ผู้วิจัยกราบขอบพระคุณเป็นอย่างสูง

ขอขอบพระคุณผู้ทรงคุณวุฒิ และผู้เชี่ยวชาญทุกท่าน ที่ได้กรุณาปรับปรุงแก้ไขข้อบกพร่อง และให้คำแนะนำในการปรับปรุงวิธีการให้ถูกต้องสมบูรณ์ยิ่งขึ้น รวมทั้งบุคคลที่ผู้วิจัยได้อ้างอิงทาง วิชาการตามที่ปรากฏในบรรณานุกรม ซึ่งผู้วิจัยไม่สามารถกล่าวนามในที่นี้ได้ทั้งหมด ไว้ ณ โอกาสนี้

คุณค่าทั้งหลายที่ได้รับจากคุษฎีนิพนธ์ฉบับนี้ ผู้วิจัยขอมอบเป็นกตัญญูทเวทีแต่บิดา มารดา และบูรพาจารย์ที่เคยอบรมสั่งสอน ตลอดจนผู้มีพระคุณทุกท่าน

วีระ พุ่มเกิด

52810066: สาขาวิชา: การวิจัยและสถิติทางวิทยาการปัญญา;

ปร.ด. (การวิจัยและสถิติทางวิทยาการปัญญา)

คำสำคัญ: การค้นหาแบบนกกาเหว่า/ เจเนติกอัลกอริทึม/ วิธีการผสมผสาน/ ออสโมซิส

วีระ พุ่มเกิด: การพัฒนาวิธีการค้นหาแบบนกกาเหว่าโดยการผสมผสานด้วยเจเนติกอัลกอริทึมสำหรับหาค่าที่เหมาะสมของการทำแห้งมะละกอแบบออสโมซิส (DEVELOPMENT OF CUCKOO SEARCH BY HYBRID WITH GENETIC ALGORITHM FOR PAPAYA OSMOSIS DEHYDRATION OPTIMIZATION) อาจารย์ผู้ควบคุมคุณุณีพนธ์: พูลพงศ์ สุขสว่าง, ค.ด., เสรี ชัดเข้ม, ค.ด. 155 หน้า. ปี พ.ศ. 2560.

การศึกษานี้มีวัตถุประสงค์เพื่อพัฒนาวิธีการค้นหาแบบนกกาเหว่าโดยการผสมผสานด้วยเจเนติกอัลกอริทึม (CSGA) สำหรับหาค่าที่เหมาะสมของการทำแห้งมะละกอแบบออสโมซิส และเปรียบเทียบประสิทธิภาพกับวิธีการค้นหาแบบนกกาเหว่า (CS) และวิธีพื้นผิวตอบสนอง (RSM) ดำเนินการศึกษา โดยนำวิธีการค้นหาแบบนกกาเหว่า (CS) ไปผสมผสานกับเจเนติกอัลกอริทึม แล้วทดสอบการทำงานของอัลกอริทึมด้วยฟังก์ชันมาตรฐาน Sphere Model, Schwefel's Problem, Schwefel's Problem, Schwefel's Problem และ Generalized Rosenbrock's Function หลังจากนั้นเปรียบเทียบค่าความคลาดเคลื่อนของค่าที่เหมาะสมที่ได้จากอัลกอริทึม CSGA, CA และ RSM กับค่าที่ได้จากการทดลองทำแห้งมะละกอโดยใช้แผนการทดลองแบบบ็อกซ์-เบนเคน

ผลการวิจัยปรากฏว่า

1. วิธีการค้นหาแบบนกกาเหว่าโดยการผสมผสานด้วยเจเนติกอัลกอริทึม (CSGA) สำหรับหาค่าที่เหมาะสมของการทำแห้งมะละกอแบบออสโมซิส เป็นกระบวนการค้นหาชุดคำตอบของตัวแปร  $\theta$ , C และ T ที่ทำให้ค่า SG และ WL เป็นไปตามเกณฑ์ที่กำหนดจากสมการ

$$SG = a + b_1\theta + b_2C + b_3T + b_4\theta^2 + b_5C^2 + b_6T^2 + b_7\theta \times C + b_8\theta \times T + b_9C \times T + b_{10}\theta \times C \times T$$

$$\text{และ } WL = c + w_1\theta + w_2C + w_3T + w_4\theta^2 + w_5C^2 + w_6T^2 + w_7\theta \times C + w_8\theta \times T + w_9C \times T + w_{10}\theta \times C \times T$$

โดยใช้หลักการสุ่มชุดคำตอบที่เกิดจากการผสมชุดคำตอบตั้งต้นที่มีค่าใกล้เคียงกับเกณฑ์ที่กำหนดเพื่อให้ได้ชุดคำตอบที่เป็นไปได้ทั้งหมด จากนั้นคัดเลือกชุดคำตอบของตัวแปร  $\theta$ , C และ T ที่ทำให้ค่า SG มีค่าเข้าใกล้ 4.0 และ WL มีค่าสูงสุด

2. วิธี CSGA ที่พัฒนาขึ้น มีค่าเฉลี่ยเวลาในการค้นหาชุดคำตอบได้รวดเร็วกว่าวิธี CS ทั้ง 5 ฟังก์ชัน โดยวิธี CSGA มีประสิทธิภาพและค่าร้อยละของความคลาดเคลื่อนดีกว่าวิธี CS และวิธี RSM

3. ค่าที่เหมาะสมของการทำแห้งมะละกอแบบออสโมซิส คือ  $\theta = 60$  °Brix, C = 42 °c และ T = 6 Hrs จะทำให้การทำแห้งมะละกอมีประสิทธิภาพสูงสุดที่ SG = 4.0, WL = 33.7 และร้อยละของความคลาดเคลื่อนประมาณ 0.04

52810066: MAJOR: RESEARCH AND STATISTICS IN COGNITIVE SCIENCE;

Ph.D. (RESEARCH AND STATISTICS IN COGNITIVE SCIENCE)

KEYWORDS: OSMOSIS/ HYBRID/ GENETIC ALGORITHM/ CUCKOO SEARCH

WEERA BHUMGERD: DEVELOPMENT OF CUCKOO SEARCH BY HYBRIDE WITH GENETIC ALGORITHM FOR PAPAYA OSMOSIS DEHYDRATION OPTIMIZATION. ADVISORY COMMITTEE: POONPONG SUKSAWANG, Ph.D., SEREE CHADCHAM, Ph.D.

155 p. 2017.

The goals of this research were to develop a cuckoo search by hybrid with genetic algorithm (CSGA) for papaya osmosis dehydration optimization and compare the performance of cuckoo search (CS) algorithm and response surface method (RSM). The study were hybridized cuckoo search with genetic algorithm and tested by benchmark functions; Sphere Model, Schwefel's Problem, Schwefel's Problem, Schwefel's Problem, and Generalized Rosenbrock's Function. Then, compare the error of the optimize values obtained from the CSGA, CA and RSM algorithms with the values obtained from the papaya drying experiments by using the Box-Benken experimental.

The results were as follows:

1. The hybrid of cuckoo search with genetic algorithm (CSGA) for papaya osmosis dehydration was derived from the responses to the search for  $\theta$ , C, and T variables was used to define the criteria of WL and SG according to the specified principles from these quadratic equations.

$SG = a + b_1\theta + b_2C + b_3T + b_4\theta^2 + b_5C^2 + b_6T^2 + b_7\theta \times C + b_8\theta \times T + b_9C \times T + b_{10}\theta \times C \times T$   
and  $WL = c + w_1\theta + w_2C + w_3T + w_4\theta^2 + w_5C^2 + w_6T^2 + w_7\theta \times C + w_8\theta \times T + w_9C \times T + w_{10}\theta \times C \times T$

This method was accomplished by sampling the optimizing values by selecting those closest to the specified principles in order to get all possible values. Then the sampling of the values of the variables;  $\theta$ , C, and T, which were close to 4.0 was done, with WL at the highest rate and SG at the closest 4.

2. CSGA showed greater speed in searching answers than CS with all five functions. Moreover, CSGA had a lower error value rate than CS and RSM.

3. The optimized values for papaya osmosis dehydration were  $\theta = 60$  °Brix, C = 42 °c, and T = 6 Hrs. The highest performance of papaya osmosis dehydration were at SG = 4.0 and WL = 33.7; the error value was 0.04.

# สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ง
บทคัดย่อภาษาอังกฤษ.....	จ
สารบัญ.....	ฉ
สารบัญตาราง.....	ช
สารบัญภาพ.....	ฅ
บทที่	
1 บทนำ.....	1
ความเป็นมาและความสำคัญของปัญหา.....	1
วัตถุประสงค์ของการวิจัย.....	5
กรอบแนวทางการวิจัย.....	6
สมมติฐานของการวิจัย.....	10
ประโยชน์ที่คาดว่าจะได้รับจากการวิจัย.....	10
ขอบเขตของการวิจัย.....	10
นิยามศัพท์เฉพาะ.....	11
2 เอกสารและงานวิจัยที่เกี่ยวข้อง.....	13
ตอนที่ 1 วิธีการหาค่าที่เหมาะสมของการค้นหาแบบนกกาเหว่า (Cuckoo Search) และ งานวิจัยที่เกี่ยวข้อง.....	13
ตอนที่ 2 วิธีการหาค่าที่เหมาะสมของเจเนติกอัลกอริทึม (Genetic Algorithm) และ งานวิจัยที่เกี่ยวข้อง.....	34
ตอนที่ 3 การทำแห้ง (Dehydration) และงานวิจัยที่เกี่ยวข้อง.....	56
3 วิธีดำเนินการวิจัย.....	65
ระยะที่ 1 การพัฒนาวิธีการค้นหาแบบนกกาเหว่าโดยการผสมผสานด้วย เจเนติกอัลกอริทึม.....	65
ระยะที่ 2 การเปรียบเทียบประสิทธิภาพของวิธี CSGA ที่พัฒนาขึ้นกับวิธี CS และวิธี RSM.....	79
ระยะที่ 3 การหาค่าที่เหมาะสมของการทำแห้งมะละกอแบบออสโมซิส.....	82
4 ผลการวิจัย.....	89
ตอนที่ 1 ผลการพัฒนาวิธีการค้นหาแบบนกกาเหว่าโดยการผสมผสานด้วยเจเนติก อัลกอริทึม.....	89
ตอนที่ 2 ผลการเปรียบเทียบประสิทธิภาพของวิธี CSGA ที่พัฒนาขึ้นกับวิธีการค้นหา แบบนกกาเหว่า (CS) และวิธี RSM.....	93
ตอนที่ 3 ผลการหาค่าที่เหมาะสมของการทำแห้งมะละกอแบบออสโมซิส.....	100

## สารบัญ (ต่อ)

บทที่	หน้า
สรุปและอภิปรายผลการวิจัย.....	106
สรุปผลการวิจัย.....	107
อภิปรายผลการวิจัย.....	107
ข้อเสนอแนะ.....	110
ข้อเสนอแนะในการนำผลการวิจัยไปใช้.....	110
ข้อเสนอแนะในการทำวิจัยต่อไป.....	111
บรรณานุกรม.....	112
ภาคผนวก.....	117
ภาคผนวก ก หนังสือรับรองผลการพิจารณาจริยธรรมการวิจัยในมนุษย์.....	118
ภาคผนวก ข รูปการทำแห้งมะละกอด้วยวิธีออสโมซิส.....	120
ภาคผนวก ค ฟังก์ชันมาตรฐาน.....	129
ภาคผนวก ง ผลการทำแห้งแบบออสโมซิส.....	136
ภาคผนวก จ ผลการวิเคราะห์ข้อมูลด้วย RSM.....	142
ภาคผนวก ฉ ผลการวิเคราะห์ข้อมูลด้วยอัลกอริทึม CS และ CSGA.....	152
ประวัติย่อของผู้วิจัย.....	155

## สารบัญตาราง

ตารางที่	หน้า
2-1 การเปรียบเทียบคำศัพท์ระหว่างพันธุศาสตร์กับเจเนติกอัลกอริทึม.....	35
2-2 สัดส่วนความเหมาะสมที่มีโอกาสถูกเลือกจากการสุ่ม (การรีโพรดักชัน).....	49
2-3 ค่าต่ำสุด ค่าสูงสุดของตัวแปรในกระบวนการออสโมซิส.....	61
3-1 ชุดฟังก์ชันมาตรฐาน (Benchmark Optimization Function).....	80
3-2 การกำหนดค่าพารามิเตอร์ของอัลริทึม CS และ CSGA.....	80
3-3 การวางแผนการทดลองแบบ Box-Behnken.....	85
4-1 การเปรียบเทียบความแตกต่างของวิธีการหาค่าที่เหมาะสม.....	90
4-2 ผลการเปรียบเทียบประสิทธิภาพระหว่าง CS กับ CSGA.....	93
4-3 ค่าความคลาดเคลื่อนของการทำแห้งมะละกอบบออสโมซิส.....	100
4-4 ผลของปริมาณน้ำที่ลดลงและปริมาณของน้ำตาลที่เพิ่มขึ้น.....	101
4-5 ผลการวิเคราะห์ความแปรปรวนของ Water Loss.....	102
4-6 ผลการวิเคราะห์ความแปรปรวนของ Sugar Gain.....	103
4-7 ค่าที่เหมาะสมของพารามิเตอร์ของการทำแห้งมะละกอบบออสโมซิส.....	104



## สารบัญญภาพ

ภาพที่		หน้า
1-1	กรอบแนวทางการพัฒนาอัลกอริทึม CSGA.....	8
2-1	แผนภาพแสดงการเคลื่อนที่ของ Lévy-flights.....	18
2-2	ผังขั้นตอนวิธีการค้นหาของนกกาเหว่า.....	20
2-3	การวางไข่ของนกกาเหว่าภายใน Egg Laying Radius (ELR).....	22
2-4	ผังการอพยพถิ่นที่อยู่ของนกกาเหว่า.....	23
2-5	Pseudo-code for Cuckoo Optimization Algorithm.....	24
2-6	3D Plot of Cost Function F1.....	27
2-7	Initial Habitats of Cuckoos.....	27
2-8	Habitats of Cuckoos in 2nd Iteration.....	28
2-9	Habitats of Cuckoos in 3rd Iteration.....	28
2-10	Habitats of Cuckoos in 4th Iteration.....	29
2-11	Habitats of Cuckoos in 5th Iteration.....	29
2-12	Habitats of Cuckoos in 6th Iteration.....	30
2-13	Habitats of Cuckoos in 7th Iteration.....	30
2-14	3d Plot of Rastrigin Function.....	31
2-15	วัฏจักรของ GA.....	37
2-16	ขั้นตอนทั่วไปของ GA กับการเชื่อมโยงเข้ากับระบบ.....	38
2-17	โครโมโซมที่เข้ารหัสแบบฐานสองจากคำตอบในระบบ.....	39
2-18	ฟังก์ชันวัตถุประสงค์กับการเชื่อมโยง GA เข้ากับระบบ.....	40
2-19	ฟังก์ชันวัตถุประสงค์และฟังก์ชันกำหนดค่าความเหมาะสม.....	42
2-20	การกำหนดค่าโอกาส $p$ เพื่อใช้ในขั้นตอนการคัดเลือก.....	44
2-21	วงล้อรูเล็ตจากค่าความเหมาะสมของแต่ละโครโมโซม.....	46
2-22	วงล้อรูเล็ตจากกระบวนการเฟ้นสุ่มครอบครัว.....	47
2-23	ปฏิบัติการทางสายพันธุ์.....	50
2-24	ครอสโอเวอร์แบบจุดเดียว.....	49
2-25	ครอสโอเวอร์แบบหลายจุด.....	50
2-26	การแปรผันยีนในการผ่าเหล่า.....	51
2-27	ตัวอย่างขั้นตอนของการรีโพรดักชัน ครอสโอเวอร์ และมิวเตชัน.....	52
2-28	ขั้นตอนการทำงานของเจเนติกอัลกอริทึม.....	54
2-29	การเคลื่อนที่ของน้ำและสารละลายในอาหาร.....	57
2-30	การเปลี่ยนแปลงของอัตราความชื้นกับอุณหภูมิของวัตถุดิบ.....	58
2-31	การเคลื่อนที่ของน้ำและสารละลายแบบออสโมซิส.....	59
2-32	การถ่ายเทมวลผ่านเนื้อเยื่อของผลไม้.....	59

## สารบัญภาพ (ต่อ)

ภาพที่	หน้า
2-33 ความสัมพันธ์ระหว่าง Water Activity กับ Relative Reaction Rate.....	60
3-1 ขั้นตอนการพัฒนาวิธีการหาค่าที่เหมาะสมแบบผสมผสาน CSGA.....	66
3-2 ผังขั้นตอนวิธีการค้นหาแบบนกกาเหว่า (CS).....	68
3-3 ผังแนวทางการปรับปรุงวิธีการค้นหาของนกกาเหว่า.....	70
3-4 ขั้นตอนการดำเนินงานของเจเนติกอัลกอริทึม (Genetic Algorithm).....	74
3-5 ผังขั้นตอนวิธีการผสมผสานระหว่างการค้นหาแบบนกกาเหว่ากับเจเนติกอัลกอริทึม.....	75
3-6 ผังขั้นตอนวิธีการ Crossover และ Mutation.....	78
3-7 การทดสอบประสิทธิภาพของอัลกอริทึม CSGA และ CS.....	82
3-8 ผังวิธีการเปรียบเทียบความสามารถระหว่างอัลกอริทึม.....	83
3-9 ผังการทดลองทำเหมืองละกอบแบบออสโมซิส.....	86
3-10 ผังขั้นตอนการหาค่าที่เหมาะสมด้วย CSGA กับ CS.....	87
4-1 ผลการเปรียบเทียบอัลกอริทึมของ RSM, CS, และ CSGA.....	91
4-2 Pseudo-code ของ CSGA และ CS.....	91
4-3 กราฟร้อยละความแตกต่างของประสิทธิภาพในการหาค่าที่เหมาะสม.....	94
4-4 ผลการเปรียบเทียบประสิทธิภาพด้วย Sphere Model.....	95
4-5 ผลการเปรียบเทียบประสิทธิภาพด้วย Schwefel's Problem.....	96
4-6 ผลการเปรียบเทียบประสิทธิภาพด้วย Schwefel's Problem.....	97
4-7 ผลการเปรียบเทียบประสิทธิภาพด้วย Schwefel's Problem.....	98
4-8 ผลการเปรียบเทียบประสิทธิภาพด้วย Generalized Rosenbrock's Function.....	99
4-9 กราฟ Contour Plot ของ WL.....	102
4-10 กราฟ Contour Plot ของ SG.....	104

# บทที่ 1

## บทนำ

### ความเป็นมาและความสำคัญของปัญหา

วิทยาศาสตร์และเทคโนโลยีการอาหารเป็นศาสตร์ที่ศึกษาเกี่ยวกับกระบวนการแปรรูปอาหาร การตรวจรับวัตถุดิบ การประเมินคุณภาพทางประสาทสัมผัส การควบคุมคุณภาพอาหาร วิศวกรรมอาหาร การพัฒนาผลิตภัณฑ์อาหาร ความปลอดภัยของอาหาร และโภชนาการของอาหาร องค์ความรู้ในเรื่องการแปรรูปอาหารนั้นมีบทบาทที่สำคัญต่อการพัฒนาเศรษฐกิจและการธุรกิจส่งออกผลิตผลทางการเกษตรของประเทศโดยเฉพาะผลไม้ที่ผ่านการอบแห้ง การแปรรูปผลไม้ด้วยวิธีการทำแห้งนั้น สามารถช่วยยืดอายุการเก็บรักษาและสามารถสร้างผลิตภัณฑ์ใหม่ ๆ นอกจากนี้ วิทยาศาสตร์และเทคโนโลยีการอาหารยังเข้ามามีบทบาทในการแก้ไขปัญหาการขาดแคลนการผลิตการเกษตรตกต่ำในฤดูเก็บเกี่ยว เนื่องจากผลผลิตมีปริมาณมากเกินกว่าความต้องการของผู้บริโภคหรือเรียกสั้น ๆ ว่าสินค้าล้นตลาด โดยการนำผลผลิตทางการเกษตรไปยืดอายุการเก็บรักษาด้วยเทคนิคและวิธีการแปรรูปอาหาร เพื่อรอเวลาให้เลยฤดูกาลเก็บเกี่ยวจึงนำผลผลิตออกจำหน่ายในราคาที่สูงกว่าเดิม วิธีการดังกล่าวสามารถแก้ปัญหาการขาดแคลนการผลิตทางการเกษตรล้นตลาดได้ในระดับหนึ่ง ประกอบกับกระบวนการแปรรูปด้วยวิธีการอบแห้ง สามารถทำให้ผักและผลไม้หลายชนิดมีมูลค่าเพิ่มขึ้นในขณะที่น้ำหนักลดลง ดังนั้นการศึกษาค้นคว้าเพื่อพัฒนาวิธีการแปรรูปให้มีความเหมาะสมจะสามารถช่วยยืดอายุการเก็บรักษาให้ยาวนานขึ้นและสามารถนำมาบริโภคในยามที่ขาดแคลนได้ กระบวนการแปรรูปมีหลายวิธีด้วยกัน กระบวนการแปรรูปด้วยวิธีการทำแห้ง (Drying) เป็นวิธีหนึ่งที่ได้รับคามนิยมนำมาใช้ในการแปรรูปผักและผลไม้ อาทิเช่น ลำไย ทูเรียน กล้วย ขนุน เผือก ฟักทอง มะละกอ เป็นต้น ในอดีตที่ผ่านมาผลไม้ที่ผ่านกระบวนการแปรรูปด้วยวิธีการทำแห้งแล้วส่งออกไปยังต่างประเทศมีมูลค่าสูงถึง 10,910 ล้านบาท โดยมีการขยายตัวเพิ่มขึ้นสูงสุดถึงร้อยละ 53 ของการส่งออกผลไม้ ทำให้ประเทศไทยกลายเป็นผู้ส่งออกอันดับที่ 3 ของโลก รองจากประเทศตุรกีและประเทศสหรัฐอเมริกา โดยมีตลาดส่งออกที่สำคัญอยู่ในกลุ่มประเทศอาเซียนและสาธารณรัฐประชาชนจีน (สถาบันอาหาร, 2560)

ในอดีตที่ผ่านมานักวิทยาศาสตร์และเทคโนโลยีการอาหารได้นำเสนอวิธีการแปรรูปอาหารโดยใช้กระบวนการดองน้ำออกจากอาหารด้วยความร้อน ทั้งความร้อนจากธรรมชาติและความร้อนที่เกิดจากตู้อบลมร้อน (Enitan & Adeyemo, 2011) จึงนิยมเรียกกระบวนการดังกล่าวว่า กระบวนการอบแห้ง ต่อมาได้มีการพัฒนากระบวนการดองน้ำออกขึ้นมาใหม่โดยไม่มีการใช้ความร้อนส่งผลให้ต้องเปลี่ยนคำที่ใช้เรียกจากกระบวนการอบแห้งเป็นกระบวนการทำแห้ง การแปรรูปด้วยวิธีการทำแห้งแบบออสโมซิสนั้น เป็นวิธีการยืดอายุการเก็บรักษาอาหารที่มีซับซ้อนน้อยสามารถทำได้ในระดับครัวเรือน จึงได้รับความนิยมนำไปใช้แปรรูปผลไม้กันแพร่หลายโดยเฉพาะผลไม้ที่มีมูลค่าทางเศรษฐกิจค่อนข้างสูง เนื่องจากกระบวนการทำแห้งแบบออสโมซิสนั้นสามารถรักษาคุณสมบัติต่าง ๆ ของผลไม้ได้ใกล้เคียงกับผลไม้สด รวมทั้งยังทำให้น้ำหนักของผลไม้ลดลง ซึ่งทำให้สะดวกต่อการขนส่ง

(Sagar & Kumar, 2010) นอกจากนี้ยังพบว่า หากมีการใช้วิธีการอบแห้งร่วมกับกระบวนการทำแห้งแบบออสโมซิสแล้ว จะสามารถรักษาคุณสมบัติต่าง ๆ ของผลไม้ไว้ได้ใกล้เคียงกับผลไม้สดมากขึ้น (Jain, Verma, Murdia, Jain, & Sharma, 2011) จึงมีความพยายามที่พัฒนากระบวนการทำแห้งแบบออสโมซิสร่วมกับกระบวนการอบแห้งผลไม้ด้วยลมร้อน โดยใช้วิธีการทำแห้งแบบออสโมซิสดึงน้ำในผลไม้ออกบางส่วน (WL) และในขณะเดียวกันก็เพิ่มปริมาณน้ำตาลเข้าไปในผลไม้ (SG) (Wang & Xu, 2015) วิธีการนี้เรียกว่าการปรับสภาพวัตถุดิบสำหรับเข้าสู่กระบวนการอบแห้งต่อไป ผลไม้อบแห้งที่ได้จากวิธีการดังกล่าวนี้จะมีลักษณะปรากฏในด้านต่าง ๆ ดีกว่าวิธีการอบแห้งเพียงอย่างเดียว ในขณะเดียวกันยังสามารถยืดอายุการเก็บรักษาได้เช่นเดียวกับวิธีดั้งเดิม (Raoult-Wack, 1994) วิธีการนี้มีความเหมาะสมสำหรับนำไปใช้ในกระบวนการแปรรูปผลิตภัณฑ์ผลไม้อบแห้งที่ต้องการคุณภาพสูง (Yeomans & Yang, 2014) เนื่องจากสามารถรักษาและปรับปรุงคุณสมบัติด้านประสาทสัมผัสของผลไม้ไว้ได้ดีกว่าการอบแห้งเพียงอย่างเดียว เนื่องด้วยเหตุผลดังต่อไปนี้ (1) การเพิ่มขึ้นระหว่างอัตราส่วนของน้ำตาลและกรดในผลไม้ (2) การปรับปรุงพื้นผิวผลไม้ และ (3) ความคงตัวของเม็ดสีในระหว่างการเก็บรักษาของผลไม้แห้ง (Sagar & Kumar, 2010) ผลที่ได้สอดคล้องกับจุดประสงค์หลักของกระบวนการทำแห้งที่ต้องการรักษาคุณสมบัติเชิงหน้าที่และรักษาคุณค่าทางโภชนาการไว้ให้มากที่สุด (Yeomans & Yang, 2014; Raoult-Wack, 1994)

กระบวนการทำแห้งแบบออสโมซิสประกอบไปด้วยหลักการที่สำคัญดังต่อไปนี้ การลดปริมาณน้ำในผลไม้โดยการดึงน้ำออกและแทนที่ด้วยสารละลายตัวกลาง (Hypertonic) (Sagar & Kumar, 2010) โดยเริ่มจากการนำผลไม้แช่ลงในสารละลายตัวกลาง เพื่อให้ น้ำในผลไม้ถูกดึงออกมาแล้วละลายรวมไปกับสารละลายตัวกลาง เนื่องมาจากความแตกต่างของความเข้มข้นระหว่างน้ำในผลไม้และน้ำในสารละลายตัวกลาง กระบวนการดึงน้ำออกด้วยวิธีออสโมซิสนั้นสัดส่วนของปริมาณน้ำในผลไม้จะเป็นตัวกำหนดความเข้มข้นของสารละลายที่ใช้เป็นตัวกลาง กระบวนการดึงน้ำออกด้วยวิธีการออสโมซิสนั้น สามารถใช้ร่วมกับกระบวนการแปรรูปผลไม้รูปแบบอื่น ๆ โดยเฉพาะเมื่อนำไปใช้ร่วมกับกระบวนการอบแห้งแล้วส่งเสริมให้ผลิตภัณฑ์ผลไม้อบแห้งที่มีคุณภาพดีขึ้น สามารถลดการเปลี่ยนแปลงสภาพในระหว่างการเก็บรักษา จึงมีความเหมาะสมสำหรับการผลิตเพื่อส่งออกไปยังตลาดต่างประเทศ (Sagar & Kumar, 2010)

ปัจจัยสำคัญของกระบวนการทำแห้งผลไม้แบบออสโมซิสนั้นประกอบด้วย (1) อุณหภูมิของน้ำเชื่อม (C) มีหน่วยเป็นองศาเซลเซียส (2) ความเข้มข้นของน้ำเชื่อม ( $\theta$ ) มีหน่วยเป็นปริกซ์ และ (3) ระยะเวลาของการออสโมซิส (T) มีหน่วยเป็นชั่วโมง (Jain et al., 2011; Sagar & Kumar, 2010) เนื่องจากมีตัวแปรหลายตัวที่ส่งผลต่อค่าร้อยละของปริมาณน้ำในมะละกอลดลง (Water Loss: WL) และค่าร้อยละของปริมาณน้ำตาลในมะละกอลดที่เพิ่มขึ้น (Sugar Gain: SG) ของการทำแห้งแบบออสโมซิส สำหรับการนำไปใช้ในเชิงอุตสาหกรรมนั้นมีความจำเป็นอย่างยิ่งที่จะต้องรู้ค่าที่แน่นอนของแต่ละตัวแปรในกระบวนการทำแห้งแบบออสโมซิส นักวิทยาศาสตร์และเทคโนโลยีการแปรรูปอาหารได้นำวิธีพื้นผิวตอบสนอง (Response Surface Method: RSM) มาใช้ในการหาค่าที่เหมาะสมของตัวแปรต่าง ๆ โดยนำไปใช้ร่วมกับวิธีการวางแผนการทดลองที่เหมาะสม เช่น Factorial Design, Central Composite Design และ Box-Behnken เป็นต้น เดิมทีนั้นวิธีพื้นผิวตอบสนองนิยมนำไปใช้ในการหาค่าที่เหมาะสมด้านวิทยาศาสตร์ (วิธีเชิงประจักษ์) (Box & Behnken, 1960, pp.

455-475; Montgomery & Myers, 1995) ดำเนินการโดยใช้ข้อมูลจากการทดลองทำแห้งแบบ ออสโมซิสมาสร้างสมการอธิบายอิทธิพลของตัวแปรแต่ละตัว (Montgomery & Myers, 1995) แล้ว นำมาวิเคราะห์หาค่าที่ได้รับการตอบสนองจากอิทธิพลหรือปัจจัยหลาย ๆ ตัว (Moghaddam & Khajeh, 2011a)

เนื่องจาก RSM เป็นวิธีการหาค่าที่เหมาะสมโดยอาศัยหลักการทางคณิตศาสตร์และเทคนิค ทางสถิติ (Eren & Kaymak-Ertekin, 2007) การนำไปใช้ในการหาค่าที่เหมาะสมยังมีข้อจำกัดอยู่ หลายประการ เช่น (1) จำนวนตัวแปรที่เพิ่มมากขึ้น ส่งผลต่อประสิทธิภาพในการหาค่าที่เหมาะสม ลดลง แต่ในขณะที่สภาวะการณปัจจุบันมีแนวโน้มที่จำนวนปัจจัยหรือจำนวนตัวแปรเพิ่มมากขึ้นเรื่อย ๆ (2) การที่ต้องปฏิบัติตามกฎเกณฑ์ทางคณิตศาสตร์อย่างเคร่งครัดของวิธีพื้นผิวตอบสนองนั้น ทำให้ การหาค่าที่เหมาะสมของอนุพันธ์อันดับที่ 1 ให้เป็นไปด้วยความยากลำบากยิ่งขึ้นและ (3) พื้นที่ในการ หาค่าที่เหมาะสมที่คำนวณได้นั้น มีลักษณะค่อนข้างหยาบและขาดความต่อเนื่อง (Box & Behnken, 1960) เพื่อแก้ปัญหาดังกล่าว จึงมีนักวิจัยบางส่วนพยายามศึกษาค้นคว้า เพื่อหาวิธีการใหม่ ๆ ที่มีความเหมาะสมกับลักษณะทางธรรมชาติของแต่ละปัญหาและสามารถนำมาทดแทนวิธีการแบบดั้งเดิม อยู่เสมอ (Sharma, Singhingh, & Dilbaghi, 2009)

ปัจจุบันเทคโนโลยีด้านการคำนวณและอุปกรณ์ต่าง ๆ ก้าวหน้าไปมาก ทำให้มีการพัฒนา วิธีการหาค่าที่เหมาะสมแบบใหม่ ๆ ขึ้นมามากมาย วิธีการคำนวณเชิงวิวัฒนาการ (Evolutionary Computation) (Yang, 2010) เป็นอีกแนวทางหนึ่ง เทคนิคการหาค่าที่เหมาะสมทางวิทยาศาสตร์ และวิศวกรรมศาสตร์นิยมนำมาใช้ทดแทนการหาค่าที่เหมาะสมแบบดั้งเดิม โดยมีความเหมาะสม สำหรับปัญหาที่มีความซับซ้อน การคำนวณเชิงวิวัฒนาการมีต้นกำเนิดจากทฤษฎีวิวัฒนาการของ สิ่งมีชีวิตที่ค้นพบโดย Charles Darwin ปี ค.ศ. 1842 จากนั้นนักวิจัยได้นำทฤษฎีมาประยุกต์กับ การคำนวณของคอมพิวเตอร์ กลายเป็นวิธีการคำนวณเชิงวิวัฒนาการ โดยจัดให้อยู่ในกลุ่มของวิธี เมตาฮิวริสติก (Metaheuristic) เป็นวิธีที่หาค่าที่เหมาะสม โดยอาศัยการวนซ้ำและสุ่มค่าพารามิเตอร์ จากนั้นทำการค้นหาพื้นที่ของคำตอบที่เป็นไปได้ (Feasible Solution) ให้กว้างที่สุดเท่าที่จะเป็นไปได้ วิธีการหาค่าที่เหมาะสมแบบเมตาฮิวริสติกมีจุดเด่นในส่วนของอัลกอริทึมที่เรียบง่าย มีจำนวน พารามิเตอร์น้อย สามารถหาค่าที่เหมาะสม (ผลลัพธ์) ได้รวดเร็วและมีความแม่นยำสูง นอกจากนี้ยังสามารถใช้กับข้อมูลที่ไม่จำเป็นต้องมีการไล่ระดับและมีวิธีการทำงานที่ไม่เป็นเชิงอนุพันธ์ ทำให้ สะดวกต่อการนำไปใช้ โดยที่ฟังก์ชันวัตถุประสงค์เป็นเพียงฟังก์ชันที่กำหนดขึ้นโดยนัย แตกต่างจากวิธี ดั้งเดิมที่ฟังก์ชันวัตถุประสงค์จะถูกสร้างขึ้นด้วยการจำลอง (Yang, 2010; Singh, Majumder, & Goyal, 2008) สำหรับวิธีที่อยู่ในกลุ่มของเมตาฮิวริสติก (Metaheuristic) มีส่วนประกอบสองส่วน ด้วยกัน ดังนี้ ส่วนประกอบที่หนึ่ง คือ Intensification (Exploitation) หมายถึง การมุ่งเน้นไปที่ การค้นหาพื้นที่ในระดับท้องถิ่นด้วยการใช้ประโยชน์จากข้อมูลวิธีการแก้ปัญหาที่มีอยู่ในปัจจุบัน และ ส่วนที่สอง คือ Diversification (Exploration) หมายถึง วิธีการสำรวจและค้นหาพื้นที่ในระดับสากล เพื่อแก้ปัญหาที่มีความหลากหลายและซับซ้อน (Arora & Singh, 2013) อย่างไรก็ตามวิธีการแบบ เมตาฮิวริสติกยังมีจุดอ่อนตรงที่ไม่สามารถรับประกันได้ว่า ค่าที่ได้จะเป็นคำตอบที่ดีที่สุดเหมือน คำตอบที่ได้จากวิธีแม่นยำตรง (Exact Method) ดังนั้นผลลัพธ์จากการค้นหาแต่ละครั้งอาจจะไม่ซ้ำกัน (Yang, 2010; Supagit, 2011)

วิธีการหาค่าที่เหมาะสมแบบเจเนติกอัลกอริทึม (Genetic Algorithm: GA) จัดอยู่ในกลุ่มของวิธี Metaheuristic เป็นวิธีการหาค่าที่เหมาะสมแบบเฟ้นสุ่มที่อาศัยการเลียนแบบหลักการถ่ายทอดทางพันธุกรรมตามธรรมชาติ เพื่อหาค่าที่เหมาะสมโดยรวม ด้วยการอาศัยจุดคำตอบที่สมมุติขึ้นมาหลาย ๆ จุดก่อน จากนั้นค้นหาจุดที่เหมาะสมที่สุดด้วยการประยุกต์หลักการของวิวัฒนาการ (Genetic) โดยที่มีโอกาสที่จะอยู่รอดมากที่สุด (Goldberg, 2006) เพื่อหาคำตอบที่ดียิ่งขึ้นในแต่ละรุ่นของการถ่ายทอดทางพันธุกรรม สำหรับในแต่ละรุ่นของการถ่ายทอดจะมีการประเมินความเหมาะสมของจุดคำตอบแต่ละจุด แล้วพิจารณาเลือกจุดที่เป็นคำตอบใหม่จากค่าความเหมาะสมนี้ โดยอาศัยวิธีการทางพันธุศาสตร์มาประยุกต์ วิธีการทางพันธุศาสตร์ที่ใช้ประกอบด้วย การรีโพรดักชัน การครอสโอเวอร์ และการผ่าเหล่าจุดคำตอบแต่ละจุด ประกอบไปด้วยสายอักขระของตัวแปรที่ถูกใส่รหัสไว้เรียกว่า โครโมโซมหรือจีโนม ซึ่งสามารถถอดรหัสเป็นค่าของตัวแปรจริงได้ โดยทั่วไปนิยมใส่รหัสตัวแปรให้เป็นเลขฐานสอง สามารถปรับปรุงประสิทธิภาพการทำงานด้วยการดำเนินการ เช่น ตัวเลือกการสืบพันธุ์ การกลายพันธุ์และการครอสโอเวอร์ แต่ปัญหาหลักในการหาค่าที่เหมาะสมของเจเนติกอัลกอริทึม คือจะมีความล่าช้าในการลู่เข้าหาคำตอบและบางครั้งอาจมีการทำลายนินที่ดีในโครโมโซม (Goldberg & Holland, 1988)

การค้นหาแบบนกกาเหว่า (Cuckoo Search: CS) เป็นวิธีการหาค่าที่เหมาะสมที่จัดอยู่ในกลุ่มของ Heuristic ที่กำลังได้รับความนิยมนำไปใช้กันอย่างแพร่หลาย วิธีการนี้ได้รับการพัฒนาและนำเสนอโดย Xin-She Yang จากมหาวิทยาลัยเคมบริดจ์และ Suash Deb จากวิทยาลัยวิศวกรรมรามาน นำเสนอในวารสารด้านการวิจัยเมื่อปี ค.ศ. 2009 การค้นหาแบบนกกาเหว่า มีหลักการพื้นฐานอยู่ที่พฤติกรรมการบินผิงไข่ของนกกาเหว่ากับนกที่สายพันธุ์ใกล้เคียงกันบางชนิด และดำเนินการค้นหารังที่เหมาะสมสำหรับวางไข่ด้วย Lévy-flights ซึ่งเป็นวิธีการแก้ปัญหาที่ชาญฉลาด ประกอบกับมีจำนวนพารามิเตอร์น้อยที่ต้องปรับน้อย จึงสามารถหาผลลัพธ์ได้อย่างรวดเร็ว และมีรูปแบบการนำไปใช้งานค่อนข้างง่าย ปัจจุบันการหาค่าที่เหมาะสมด้วยวิธีการค้นหาแบบนกกาเหว่า ได้รับความนิยมนำไปใช้งานเพิ่มขึ้น เนื่องจากเป็นวิธีที่เรียบง่าย มีจำนวนพารามิเตอร์น้อยและมีความแม่นยำสูง แต่มีข้อเสียคล้ายคลึงกับวิธีการที่อยู่ในกลุ่มวิธีการค้นหาทั่วไป คือ มีโอกาสที่การค้นหาค่าที่เหมาะสม (คำตอบ) จะไปตกอยู่ใน Local Optima ซึ่งเป็นค่าที่เหมาะสมที่เกิดขึ้นเฉพาะพื้นที่บริเวณใดบริเวณหนึ่งเท่านั้น แต่ค่าที่เหมาะสมที่หาได้คืออัลกอริทึมที่มีประสิทธิภาพสูงนั้นควรตกอยู่ใน Global Optima ดังนั้นเพื่อเพิ่มความสามารถในการหาคำตอบของวิธีการค้นหาแบบนกกาเหว่าและปรับปรุงเหมาะสมต่อลักษณะตามธรรมชาติของปัญหา ควรมีการนำอัลกอริทึมไปพัฒนาก่อนการนำไปใช้งาน (Rajabioun, 2011; Yang & Deb, 2013)

การพัฒนาอัลกอริทึมสำหรับใช้ในการหาค่าที่เหมาะสมนั้น มีวัตถุประสงค์เพื่อให้ได้ อัลกอริทึมที่มีความเหมาะสมกับปัญหาที่ต้องการนำไปใช้งานในแต่ละด้าน โดยมีลักษณะที่ต้องพิจารณาดังต่อไปนี้ (1) เป็นวิธีที่เรียบง่ายและสะดวกต่อการนำไปใช้ (2) มีสมดุลที่ตรงระหว่างการสำรวจกับการใช้ประโยชน์ (3) สามารถหาจุดที่ดีที่สุดในระดับสากลได้อย่างแท้จริง (4) สามารถบรรจบกัน (หาค่าที่เหมาะสม) ได้อย่างรวดเร็ว และ (5) ควรเป็นวิธีการที่มีจำนวนพารามิเตอร์สำหรับการปรับแต่งค่อนข้างน้อย (Kanagaraj, Ponnambalam, & Jawahar, 2013) ในการพัฒนาอัลกอริทึมนี้สามารถจำแนกออกได้สองแนวทาง ได้แก่การพัฒนา (Modified Algorithm) และ

การผสมผสาน (Hybrid Algorithm) สำหรับการศึกษาวิจัยในครั้งนี้ได้เลือกใช้วิธีการพัฒนาอัลกอริทึมด้วยวิธีผสมผสาน (Hybrid Algorithm) ระหว่างการค้นหาแบบนกกาเหว่ากับเจเนติกอัลกอริทึม โดยการปรับปรุงจากวิธีการ Kanagaraj et al. (2013) และเพื่อให้มีความเหมาะสมกับวิธีการทำแห้งแบบออสโมซิส จึงดำเนินการพัฒนาอัลกอริทึมให้สามารถหาค่าที่เหมาะสมโดยใช้ฟังก์ชันวัตถุประสงค์ 2 ฟังก์ชันวัตถุประสงค์ได้พร้อมกัน สำหรับวิธีการพัฒนาอัลกอริทึมแบบผสมผสานนั้นเป็นการนำจุดเด่นของแต่ละอัลกอริทึมมารวมเข้าด้วยกัน ดังนั้นอัลกอริทึมที่ผ่านการผสมผสานจึงมีความสามารถในการค้นหาค่าตอบในระดับสากล (Global Optima) ตามลักษณะของเจเนติกอัลกอริทึม แต่มีจำนวนพารามิเตอร์น้อย สามารถทำการปรับได้ง่าย สะดวก รวดเร็วตามลักษณะวิธีการค้นหาแบบนกกาเหว่า และยังสามารถเพิ่มประสิทธิภาพในการหาค่าที่เหมาะสมได้ดีกว่าเดิมประมาณ 1.5% และ 47% เมื่อเทียบกับวิธีเจเนติกอัลกอริทึมและวิธีการค้นหาของนกกาเหว่า (Oysu & Bingul, 2009) นอกจากนี้ยังสามารถนำไปใช้ได้กับปัญหาที่มีความหลากหลาย ทั้งในกรณีปัญหาขนาดเล็กและกรณีปัญหาขนาดใหญ่ (Kanagaraj et al., 2013)

จากเหตุผลและความสำคัญดังกล่าวมาประกอบกับความต้องการขยายขอบเขตการใช้งานไปยังด้านเทคโนโลยีการแปรรูปอาหาร ผู้วิจัยมีแนวคิดที่จะพัฒนาอัลกอริทึมด้วยวิธีผสมผสานระหว่างเจเนติกอัลกอริทึมกับวิธีการค้นหาแบบนกกาเหว่า เพื่อนำไปใช้งานด้านวิทยาศาสตร์และเทคโนโลยีการอาหาร โดยเฉพาะในกระบวนการทำแห้งผลไม้แบบออสโมซิส หลังทำการพัฒนาอัลกอริทึมเรียบร้อยแล้วนำไปทดสอบหาประสิทธิภาพทำงานด้วยฟังก์ชันมาตรฐาน (Benchmark Functions) แล้วนำค่าที่ทำการเปรียบเทียบกัน สำหรับขั้นตอนสุดท้ายได้นำวิธีการหาค่าที่เหมาะสมแบบไฮบริดไปหาค่าที่เหมาะสมของข้อมูลที่ได้จากการทดลองจากกระบวนการทำแห้งมะละกอแบบออสโมซิส จากนั้นนำค่าที่เหมาะสมที่ได้ไปเปรียบเทียบกับวิธีการค้นหาแบบนกกาเหว่ามาตรฐาน (Jain et al., 2011) อัลกอริทึมที่ได้พัฒนาขึ้นมาใหม่นั้นมีความเหมาะสมต่อการนำไปใช้หาค่าที่เหมาะสมในกระบวนการทำแห้งผลไม้แบบออสโมซิส ที่อยู่ภายใต้ข้อจำกัดดังนี้ ข้อมูลเป็นข้อมูลเชิงทดลองที่มีจำนวนค่อนข้างน้อยและมีความผันแปรของวัตถุดิบที่ใช้การผลิตสูง และเหตุผลอีกประการหนึ่งคือ ต้องการวิธีการที่พัฒนาขึ้นเพื่อใช้เฉพาะกรณี (Li & Yin, 2015; Kanagaraj et al., 2013) ซึ่งมีความแตกต่างจากวิธีการแบบดั้งเดิม (RSM) ที่ใช้วิธีการเดียวกันกับทุกปัญหา ผู้วิจัยคาดว่าวิธีการที่ได้รับการพัฒนาขึ้นมาใหม่นั้นจะประสิทธิภาพในการหาค่าที่เหมาะสมได้ดีกว่าวิธีดั้งเดิมสามารถหาค่าที่เหมาะสมได้ใกล้เคียงกับค่าแท้จริง เมื่อนำค่าที่ได้ไปใช้ในกระบวนการทำแห้งแบบออสโมซิสแล้ว ส่งผลให้กระบวนการผลิตเป็นไปอย่างมีประสิทธิภาพ สามารถลดต้นทุนในการผลิตประหยัดเวลา สามารถลดจำนวนตัวอย่างที่นำมาทำการทดลอง และสามารถนำข้อมูลที่ได้บันทึกค่าของปัจจัยต่าง ๆ ที่ใช้ในกระบวนการผลิตมาใช้เป็นข้อมูลสำหรับหาค่าที่เหมาะสมด้วยวิธีการที่พัฒนาขึ้น (Michalewicz, 1994, pp. 13-15)

### วัตถุประสงค์ของการวิจัย

1. เพื่อพัฒนาวิธีการค้นหาแบบนกกาเหว่าโดยการผสมผสานด้วยเจเนติกอัลกอริทึม (CSGA) สำหรับหาค่าที่เหมาะสมของการทำแห้งมะละกอแบบออสโมซิส
2. เพื่อเปรียบเทียบประสิทธิภาพของวิธี CSGA ที่พัฒนาขึ้นกับวิธีการค้นหาแบบ

นกกาเหว่า (CS) และวิธีพื้นผิวตอบสนอง (RSM)

### 3. เพื่อหาค่าที่เหมาะสมของการทำแห้งมะละกอแบบออสโมซิส

#### กรอบแนวทางการวิจัย

การศึกษานี้เป็นการศึกษาวิจัย เพื่อพัฒนาวิธีการหาค่าที่เหมาะสมรูปแบบใหม่ ๆ สำหรับใช้หาค่าที่เหมาะสมของปัจจัยต่าง ๆ ในกระบวนการทำแห้งมะละกอแบบออสโมซิส โดยเปรียบเทียบกับวิธีการหาค่าที่เหมาะสมแบบพื้นผิวตอบสนอง (RSM) เป็นวิธีที่พัฒนาขึ้นมาบนพื้นฐานของคณิตศาสตร์ เมื่อนำไปใช้หาค่าที่เหมาะสมจึงมีข้อจำกัดอยู่หลายประการ ในงานวิจัยนี้จึงได้นำเสนอวิธีการใหม่สำหรับหาค่าที่เหมาะสมของการทำแห้งมะละกอแบบออสโมซิสด้วยวิธีการค้นหาแบบนกกาเหว่า แต่การนำวิธีการค้นหาแบบนกกาเหว่าไปใช้หาค่าที่เหมาะสมของวิธีการทำแห้งมะละกอแบบออสโมซิสนั้น ต้องมีการนำอัลกอริทึมไปทำการพัฒนาเพื่อเพิ่มประสิทธิภาพการหาค่าที่เหมาะสมและให้มีความสอดคล้องกับบริบทของปัญหานั้น ๆ งานวิจัยนี้ได้เลือกแนวทางในการพัฒนาอัลกอริทึมด้วยวิธีผสมผสานด้วยเจเนติกอัลกอริทึม (GA) ได้เป็นอัลกอริทึมผสมผสานที่มีชื่อเรียกว่า CSGA โดยใช้วิธีการผสมผสานจากงานวิจัยของ Kanagaraj et al. (2013) เป็นแนวทางในการผสมผสานระหว่างวิธีการค้นหาแบบนกกาเหว่า (CS) กับเจเนติกอัลกอริทึม (GA) สามารถนำมาเขียนเป็นกรอบแนวทางการวิจัยได้ดังนี้

กรอบแนวทางการพัฒนาวิธีการหาค่าที่เหมาะสมแบบผสมผสาน (CSGA) นั้นประกอบด้วย 3 ระยะ ดังต่อไปนี้ ระยะที่ 1 พัฒนาการค้นหาแบบนกกาเหว่าโดยการผสมผสานด้วยเจเนติกอัลกอริทึม ระยะที่ 2 เปรียบเทียบประสิทธิภาพของวิธี CSGA ที่พัฒนาขึ้นกับวิธี CS และวิธีพื้นผิวตอบสนอง (RSM) และระยะที่ 3 หาค่าที่เหมาะสมของการทำแห้งมะละกอแบบออสโมซิส โดยมีรายละเอียดดังต่อไปนี้

ระยะที่ 1 พัฒนาการค้นหาแบบนกกาเหว่าโดยการผสมผสานด้วยเจเนติกอัลกอริทึม เนื่องจากวิธีการค้นหาที่เหมาะสมแบบนกกาเหว่า เป็นวิธีที่จัดอยู่ในกลุ่มฮิวริสติก โดยอาศัยการเลียนแบบพฤติกรรมการค้นหาที่มีความเหมาะสมสำหรับวางไข่ของนกกาเหว่า (เลือกคำตอบหรือผลลัพธ์) นับได้ว่าเป็นวิธีการหาค่าที่เหมาะสมที่มีประสิทธิภาพสูงวิธีหนึ่ง ประกอบกับการมีขั้นตอนที่เรียบง่ายและมีจำนวนพารามิเตอร์ค่อนข้างน้อยจึงได้รับความนิยมนำไปใช้กันอย่างแพร่หลาย อย่างไรก็ตามในการนำวิธีการค้นหาแบบนกกาเหว่าไปใช้งานนั้นยังพบปัญหาในเรื่องของคำตอบที่มักจะติดอยู่ใน Local Optima ส่งผลให้คำตอบที่ได้มีแนวโน้มที่จะไม่ได้เป็นคำตอบในระดับสากล เพื่อแก้ไขข้อด้อยและเพิ่มประสิทธิภาพการทำงานของอัลกอริทึม การศึกษานี้จึงได้นำวิธีการค้นหาแบบนกกาเหว่ามาพัฒนาให้มีความเหมาะสมต่อบริบทของปัญหาการทำแห้งมะละกอแบบออสโมซิส โดยเลือกพัฒนาวิธีการค้นหาแบบนกกาเหว่าด้วยวิธีการผสมผสานกับเจเนติกอัลกอริทึม เนื่องจากเจเนติกอัลกอริทึมเป็นวิธีการหาค่าที่เหมาะสมที่มีจุดเด่นด้านการหาค่าที่เหมาะสมในระดับสากล (Global Optimization) ได้ดีจึงสามารถเข้าไปเสริมในจุดด้อยของวิธีการค้นหาแบบนกกาเหว่าได้เป็นอย่างดี นอกจากนี้เจเนติกอัลกอริทึมยังได้รับความนิยมนำไปผสมผสาน (Hybrid) กับอัลกอริทึมอื่นอยู่เสมอ

การพัฒนาอัลกอริทึมแบบผสมผสานนั้น ประกอบด้วยขั้นตอนดังนี้ 1) การคัดเลือกปัจจัยที่ส่งผลต่อการทำแห้งได้แก่ อุณหภูมิของน้ำเชื่อม (C), ความเข้มข้นของน้ำเชื่อม ( $\theta$ ) และเวลาที่แช่ใน



น้ำเชื่อม (T) ที่ทำให้ค่าของ Water Loss (WL) มีค่าต่ำที่สุด และค่าของ Sugar Gain (SG) เท่ากับ 4 ขั้นตอนที่ 2) พัฒนาให้วิธีการค้นหาแบบนกกาเหว่าสามารถหาค่าที่เหมาะสมได้พร้อมกันทั้ง 2 ฟังก์ชันวัตถุประสงค์ โดยการปรับเปลี่ยนข้อตกลงเบื้องต้นของวิธีการค้นหาแบบนกกาเหว่า ขั้นตอนที่ 3) นำวิธีการค้นหาแบบนกกาเหว่าที่ผ่านการปรับเปลี่ยนข้อตกลงแล้วไปทำการผสมผสานเข้ากับ เจเนติกอัลกอริทึม โดยเลือกมาเฉพาะขั้นตอนรายการคัดเลือกวิธีการแก้ปัญหา (Chromosome List) การเลือกโครโมโซม (Chromosome Selection) การครอสโอเวอร์ (Crossover Operation) และการผ่าเหล่า (Mutation Operation) มาผสมผสานลงในขั้นตอนกำหนดค่าพารามิเตอร์แต่ละวิธีการแก้ปัญหาด้วยวิธีการสุ่มของวิธี CS โดยปรับเปลี่ยนตำแหน่งการผสมผสานจากจากวิธีของ Kanagaraj et al (ขั้นตอนเก็บวิธีแก้ปัญหาที่ดีที่สุดไว้) และดำเนินการปรับเปลี่ยนวิธีการสุ่มในกระบวนการทางพันธุกรรม จากวิธีวงล้อสุ่มเป็นวิธี Stochastic Universal Sampling (SUS) และดำเนินการปรับเปลี่ยนค่าพารามิเตอร์ให้มีความเหมาะสมกับข้อมูลที่ได้จากการทำแห้งมะละกอแบบออสโมซิส

ระยะที่ 2 เปรียบเทียบประสิทธิภาพของวิธี CSGA ที่พัฒนาขึ้นกับวิธี CS และวิธีพื้นผิวตอบสนอง (RSM) ด้วยฟังก์ชันมาตรฐาน (Benchmark Functions) จาก Australian Research, UNSW, ADFA ของ Yao et al. (1999) และข้อมูลที่ได้จากการทำแห้งมะละกอแบบออสโมซิส จากนั้นทำการเปรียบเทียบประสิทธิภาพการทำงานของอัลกอริทึม โดยการนำเวลาที่ใช้ในการหาค่าที่เหมาะสม ค่าเบี่ยงเบนและค่าความคลาดเคลื่อนของวิธีการค้นหาแบบนกกาเหว่าและอัลกอริทึมผสมผสาน CSGA มาทดสอบประสิทธิภาพ โดยนำผลการทดสอบมาวิเคราะห์หาค่าความร้อยละความแตกต่างของประสิทธิภาพในการหาค่าที่เหมาะสม (Yao, Liu, & Lin, 1999)

ระยะที่ 3 หาค่าที่เหมาะสมของการทำแห้งมะละกอแบบออสโมซิส โดยเริ่มจากการวางแผนการทดลองแบบ Block-Behnken ประกอบด้วย อุณหภูมิของน้ำเชื่อม (C), ความเข้มข้นของน้ำเชื่อม ( $\theta$ ) และเวลาที่แช่ในน้ำเชื่อม (T) ที่ทำให้ค่าของ ค่าของ WL มีค่าต่ำที่สุดและ SG เท่ากับ 4 โดยมีขั้นตอนดังนี้ 1) ทำการทดลองทำแห้งมะละกอแบบออสโมซิส แล้วนำข้อมูลมาวิเคราะห์หาปัจจัยของ C,  $\theta$ , T ที่ระดับต่าง ๆ ตามแผนการทดลอง ขั้นตอนที่ 2) นำข้อมูลที่ได้จากการทำแห้งมะละกอแบบออสโมซิสไปสร้างฟังก์ชันความสัมพันธ์ระหว่าง C,  $\theta$ , T กับ WL และ SG เพื่อนำไปใช้เป็นฟังก์ชันวัตถุประสงค์ในการหาค่าที่เหมาะสมของอัลกอริทึม ขั้นตอนที่ 3) หาค่าที่เหมาะสมของการทำแห้งแบบออสโมซิสด้วยวิธี RSM และ CS โดยใช้ข้อมูลและฟังก์ชันวัตถุประสงค์ที่จากการทดลองทำแห้งมะละกอด้วยวิธีออสโมซิส ขั้นตอนที่ 4) นำค่าที่เหมาะสมที่ได้จากอัลกอริทึม CS, CSGA และวิธี RSM ไปทำการทดลองทำแห้งมะละกอแบบออสโมซิสอีกครั้ง จากนั้นนำผลการทดลองที่ได้มาคำนวณหาค่าร้อยละของความคลาดเคลื่อนของแต่ละวิธี แล้วนำค่าที่ได้ของแต่ละวิธีการมาทำการเปรียบเทียบกัน

หากผลการทดสอบอัลกอริทึมผสมผสาน CSGA ด้วยฟังก์ชันมาตรฐานและข้อมูลการทำแห้งมะละกอแบบออสโมซิสดีกว่าวิธีการค้นหาแบบนกกาเหว่า แสดงว่าอัลกอริทึมผสมผสาน CSGA สามารถนำไปใช้หาค่าที่เหมาะสมของกระบวนการทำแห้งมะละกอแบบออสโมซิสได้อย่างเหมาะสมและมีประสิทธิภาพ



งานวิจัยนี้ได้เลือกตำแหน่งที่ดำเนินการผสมผสานด้วยเจเนติกอัลกอริทึมในขั้นตอน หลังจากกำหนดค่าพารามิเตอร์ของวิธีการค้นหาแบบนกกาเหว่า ต่างจากงานวิจัยของ Kanagaraj et al. (2013) ที่ทำการผสมผสานในขั้นตอนหลังจากนกกาเหว่าได้รับการฝึกแล้ว สำหรับในส่วนของวิธีสุ่มตัวอย่างนั้นในงานวิจัยนี้ได้เลือกใช้วิธีสุ่มตัวอย่างแบบ Stochastic Universal Sampling (SUS) แทนวิธีวงล้อรูเล็ต ที่ใช้ในงานวิจัยของ Kanagaraj et al. (2013) เนื่องจากวิธีการสุ่มตัวอย่างแบบ SUS เป็นวิธีการสุ่มที่ใช้เพียงครั้งเดียวก็สามารถคัดเลือกโครโมโซมตามจำนวนที่ต้องการได้ นอกจากนี้วิธีสุ่มตัวอย่างแบบ SUS ยังมีข้อแตกต่างไปจากวิธีสุ่มตัวอย่างแบบวงล้อรูเล็ตตรงที่มีการใช้ตัวบ่งชี้มากกว่าหนึ่งตัว กล่าวคือสำหรับการคัดเลือก  $N$  โครโมโซมจะมีตัวชี้ทั้งหมด  $N$  ตัว โดยที่ตัวบ่งชี้แต่ละตัวจะมีระยะห่างเท่ากันและมีค่าเท่ากับ  $p_{total}/N$  วิธีนี้ทำให้สามารถลดความเหลื่อมล้ำในการได้รับการคัดเลือกของแต่ละโครโมโซมลงได้ เมื่อเทียบกับวิธีดั้งเดิมที่ใช้วิธีวงล้อรูเล็ตแล้วพบว่า โครโมโซมที่มีค่า  $p$  สูงจะถูกชี้ด้วยจำนวนตัวชี้ในจำนวนที่มากกว่าโครโมโซมที่มีค่า  $p$  ที่ต่ำกว่า ทำให้วิธีการสุ่มของวงล้อรูเล็ตนั้นเกิดความเหลื่อมล้ำขึ้นได้

นอกจากนี้แล้วการพัฒนาอัลกอริทึมด้วยวิธีการผสมผสานในงานวิจัยนี้ได้มีการปรับปรุงให้อัลกอริทึมผสมผสาน CSGA สามารถนำไปใช้กับปัญหาที่มีจำนวนฟังก์ชันวัตถุประสงค์มากกว่าหนึ่งได้ เพื่อให้มีความเหมาะสมต่อการนำไปใช้กับปัญหาของการทำห้หมะละกอแบบออสโมซิส โดยทำการปรับเปลี่ยนข้อตกลงเบื้องต้นของวิธีการค้นหาแบบนกกาเหว่าจากเดิมที่กล่าวว่า

ข้อที่ 1 นกกาเหว่าสามารถวางไข่ 1 ฟองต่อครั้ง และทิ้งไข่ของมันไว้ในรังที่เลือกสุ่ม

ข้อที่ 2 รังที่ดีและไข่ที่มีคุณภาพสูง จะดำเนินการต่อไปยังรุ่นถัดไป

ข้อที่ 3 กำหนดจำนวนรังของนกเจ้าของรังที่ใช้ได้ ( $n$ ) และค่าความน่าจะเป็นที่ไข่ของนกกาเหว่าถูกค้นพบโดยนกเจ้าของรังเท่ากับ  $p_0$  มีค่าอยู่ระหว่าง 0 ถึง 1

หลังจากดำเนินการปรับเปลี่ยนข้อตกลงข้อที่ 1 ดังนี้ นกกาเหว่าสามารถวางไข่ได้มากกว่า 1 ฟองต่อครั้ง และทิ้งไข่ของมันไว้ในรังที่เลือกสุ่ม ส่วนข้อตกลงที่ 2 และ 3 คงไว้เช่นเดิม การปรับข้อตกลงดังกล่าว ส่งผลให้อัลกอริทึมผสมผสาน CSGA สามารถหาค่าที่เหมาะสมได้มากกว่าหนึ่งค่าต่อการค้นหาค่าที่เหมาะสมหนึ่งครั้ง สอดคล้องกับวิธีการทำห้หมะแบบออสโมซิสที่ต้องทำการหาค่าที่เหมาะสมของ WL และ SG ไปพร้อมกัน

เมื่อดำเนินการพัฒนาอัลกอริทึมของนกกาเหว่าด้วยวิธีการผสมผสานเรียบร้อยแล้ว จากนั้นได้นำอัลกอริทึม CSGA ไปตรวจสอบประสิทธิภาพในการหาค่าที่เหมาะสมของอัลกอริทึมด้วยฟังก์ชันมาตรฐาน (Benchmark Function) ของ Australian Research, UNSW, ADFA (Yao, Liu, & Lin, 1999) แล้วนำผลการทดสอบที่ได้ไปเปรียบเทียบกับวิธีการค้นหาของนกกาเหว่ามาตรฐาน ในขั้นตอนสุดท้าย นำวิธีการหาค่าที่เหมาะสมแบบผสมผสานไปประยุกต์กับข้อมูลที่ได้จากกระบวนการแปรรูปทำห้หมะผลไม้ด้วยกระบวนการออสโมซิสที่ได้จากการทดลอง โดยมีปัจจัยอยู่ 3 ปัจจัย ปัจจัยละ 3 ระดับ ดังนี้ อุณหภูมิของน้ำเชื่อม (50 60 และ 70 °C) ความเข้มข้นของน้ำเชื่อม (30 40 และ 50 °Brix ) และระยะเวลา (4 5 และ 6 ชั่วโมง) เพื่อหาค่าที่เหมาะสมของทั้ง 3 ปัจจัย ที่ส่งผลให้สามารถลดปริมาณน้ำลงได้สูงสุด จากนั้นนำค่าที่เหมาะสมที่ได้จากวิธีการค้นหาแบบนกกาเหว่า วิธีผสมผสาน CSGA และวิธีพื้นผิวตอบสนอง (Response Surface Method) (Jain et al., 2011b) มาทำการเปรียบเทียบกันด้วยค่าร้อยละของความคลาดเคลื่อน

## สมมติฐานของการวิจัย

1. วิธีการค้นหาแบบนกกาเหว่าโดยการผสมผสานด้วยเจเนติกอัลกอริทึม (CSGA) มีประสิทธิภาพในด้านของการหาค่าที่เหมาะสมและเวลาดีกว่าวิธีการค้นหาแบบนกกาเหว่า (CS) เมื่อเปรียบเทียบโดยการหาค่าต่ำสุดของฟังก์ชันมาตรฐาน (Benchmark Functions) ของ Australian Research, UNSW, ADFA (Yao et al., 1999) ได้แก่ Sphere Model, Schwefel's Problem, Schwefel's Problem และ Generalized Rosenbrock's Function
2. วิธีการค้นหาแบบนกกาเหว่าโดยการผสมผสานด้วยเจเนติกอัลกอริทึม (CSGA) มีประสิทธิภาพในการหาค่าที่เหมาะสมและค่าร้อยละของความคลาดเคลื่อนดีกว่าวิธีการค้นหาแบบนกกาเหว่า (CS) และวิธีพื้นผิวตอบสนอง (RSM) เมื่อนำไปประยุกต์กับข้อมูลที่ได้จากการทำแห้งแบบออสโมซิส

## ประโยชน์ที่คาดว่าจะได้รับการวิจัย

1. ได้วิธีการหาค่าที่เหมาะสมที่พัฒนาขึ้นมาใหม่ด้วยการผสมผสานระหว่างวิธีการค้นหาแบบนกกาเหว่ากับเจเนติกอัลกอริทึม (CSGA)
2. ได้วิธีการหาค่าที่เหมาะสมที่มีประสิทธิภาพดีกว่าวิธีการค้นหาแบบนกกาเหว่า (CS)
3. ได้วิธีการหาค่าที่เหมาะสมที่มีความเหมาะสมสำหรับการนำไปใช้กับกระบวนการทำแห้งแบบออสโมซิส

## ขอบเขตของการวิจัย

1. ข้อมูลที่ใช้ในการเปรียบเทียบประสิทธิภาพของทั้งสองวิธี ได้แก่ ฟังก์ชันมาตรฐาน (Benchmark Functions) ของ Australian Research, UNSW, ADFA (Yao & Liu, 1999)
2. วัตถุดิบที่ใช้ในการหาค่าที่เหมาะสมของการทำแห้งแบบออสโมซิส ได้แก่ มะละกอพันธุ์แขกดำ อายุประมาณ 3-4 สัปดาห์ เก็บจากสวนนายปรุง อำเภอสทาลายา จังหวัดนครปฐม นำมาเป็นวัตถุดิบสำหรับศึกษาวิจัยการแปรรูปมะละกอด้วยกระบวนการทำแห้งแบบออสโมซิส
3. ตัวแปรประกอบตัวแปรอิสระและตัวแปรตาม ดังรายละเอียดต่อไปนี้
 

ตัวแปรอิสระ คือ ปัจจัยที่ส่งผลต่อกระบวนการแปรรูปมะละกออบแห้งแบบออสโมซิส มีปัจจัยที่สำคัญ ดังต่อไปนี้

  - 1) อุณหภูมิของน้ำเชื่อม (C) เท่ากับ 50, 60 และ 70 °C
  - 2) ความเข้มข้นของน้ำเชื่อม (θ) เท่ากับ 30, 40 และ 50 °Brix
  - 3) เวลาที่แช่ในน้ำเชื่อม (T) เท่ากับ 4, 5 และ 6 ชั่วโมง

ตัวแปรตามมี 2 ตัวแปร ดังนี้

  - 1) ร้อยละของปริมาณน้ำที่ลดลงของมะละกอ (Water Loss: WL)
  - 2) ร้อยละของปริมาณน้ำตาลที่เพิ่มขึ้นของมะละกอ (Sugar Gain: SG)

การหาค่าที่เหมาะสมของทั้ง 3 ปัจจัย เป็นการหาค่าที่เหมาะสมของมะละกอที่ผ่านกระบวนการทำแห้งแบบออสโมซิส แล้วส่งผลให้ร้อยละของปริมาณน้ำที่ลดลงสูงสุดของมะละกอ

(WL) และร้อยละของปริมาณน้ำตาลที่เพิ่มขึ้นในมะละกอเท่ากับ 4 การหาค่าที่เหมาะสมดังกล่าวนี้จะก่อให้เกิดความประหยัดทั้งด้านต้นทุนและระยะเวลาในกระบวนการทำแห้ง นอกจากนี้ยังได้ผลิตภัณฑ์ผลไม้แห้งที่มีคุณภาพสูง สำหรับข้อมูลของทั้งสามปัจจัยนั้นได้มาจากการทดลองที่เลือกใช้การวางแผนการทดลองแบบ Box-Benken ตามวิธีของ Jain et al เมื่อทำการทดลองจนได้ค่าของตัวแปรจนครบแล้วนำมาวิเคราะห์หาค่า WL และ SG จากนั้นนำมาสร้างฟังก์ชันวัตถุประสงค์สำหรับใช้ตรวจสอบการเข้ากันพอดี (Fitness) ของค่าที่เหมาะสมที่ได้จากอัลกอริทึม (Jain et al, 2011)

### นิยามศัพท์เฉพาะ

การทำแห้ง (Dehydration) หมายถึง กระบวนการนำน้ำออกจากผลไม้ เพื่อลดปริมาณน้ำในผลไม้ที่ลดลงด้วยกระบวนการใช้ระบบออสโมซิส

WL (Water Loss) หมายถึง ค่าร้อยละของปริมาณน้ำที่ลดลงของมะละกอหลังจากผ่านกระบวนการทำแห้งแบบออสโมซิสที่อุณหภูมิของน้ำเชื่อม (C) ความเข้มข้นของน้ำเชื่อม ( $\theta$ ) และเวลาที่มะละกอในน้ำเชื่อม (T) ที่ระดับต่าง ๆ

SG (Sugar Gain) หมายถึง ค่าร้อยละของปริมาณน้ำตาลที่เพิ่มขึ้นของมะละกอหลังจากผ่านกระบวนการทำแห้งแบบออสโมซิสที่อุณหภูมิของน้ำเชื่อม (C) ความเข้มข้นของน้ำเชื่อม ( $\theta$ ) และเวลาที่มะละกอในน้ำเชื่อม (T) ที่ระดับต่าง ๆ

อัลกอริทึม (Algorithm) หมายถึง ชุดของคำสั่งที่มีขั้นตอนที่แน่นอน สำหรับใช้ในการแก้ปัญหา เพื่อให้ได้ค่าที่เหมาะสมของฟังก์ชันวัตถุประสงค์

ฟังก์ชันวัตถุประสงค์ (Objective Function) หมายถึง ความสัมพันธ์ระหว่างค่าของพารามิเตอร์ของการทำแห้งแบบออสโมซิส ได้แก่ (C), ( $\theta$ ) และ (T) กับค่าร้อยละของปริมาณน้ำในมะละกอที่ลดลงหลังจากผ่านการทำแห้งแบบออสโมซิส WL และค่าร้อยละของปริมาณน้ำตาลในมะละกอที่เพิ่มขึ้นหลังจากผ่านการทำแห้งแบบออสโมซิส SG โดยนำมาเขียนให้อยู่ในรูปของสมการทางคณิตศาสตร์

วิธีการค้นหาแบบนกกาเหว่า (Cuckoo Search) หมายถึง กระบวนการค้นหาค่าตอบ หรือกระบวนการค้นหาค่าที่เหมาะสมของฟังก์ชันวัตถุประสงค์ โดยใช้อัลกอริทึมที่สร้างขึ้นมาด้วยวิธีการเลียนแบบพฤติกรรมการค้นหารังที่เหมาะสมสำหรับวางไข่ของนกกาเหว่า โดยอาศัยประสบการณ์การเลือกรังที่มีโอกาสสูงที่ไข่จะได้รับการฟักและเลี้ยงดูจากนกเจ้าของรัง

รัง (Nests) หมายถึง รังของนกชนิดอื่นที่นกกาเหว่าเลือกวางไข่ โดยอาศัยประสบการณ์ที่นกกาเหว่าเลือกแล้วว่าเป็นรังที่เหมาะสม โดยมีค่าที่เหมาะสมของฟังก์ชันวัตถุประสงค์ของการทำแห้งแบบออสโมซิส ที่หาได้จากวิธีการค้นหารัง (คำตอบหรือผลลัพธ์) ที่มีความเหมาะสมแบบนกกาเหว่า โดยที่รังแต่ละรังจะบรรจุค่า C,  $\theta$  และ T ไว้

เจเนติกอัลกอริทึม (Genetic Algorithm) หมายถึง กระบวนการหาค่าตอบ หรือค่าที่เหมาะสมของฟังก์ชันวัตถุประสงค์ด้วยวิธีการเลียนแบบกระบวนการถ่ายทอดทางพันธุกรรมของสิ่งมีชีวิต ประกอบด้วยการรีโพรดักชัน (Reproduction) การครอสโอเวอร์ (Crossover) และการผ่าเหล่า (Mutation)

การรีโพรดักชัน (Reproduction) หมายถึง การจำลองยีนส์ของสิ่งมีชีวิตอีกชุดหนึ่ง เพื่อดำรงเผ่าพันธุ์และถ่ายทอดวิธีการค้นหาที่เหมาะสม จากวิธีหนึ่งไปสู่วิธีอีกวิธีหนึ่งที่มีประสิทธิภาพ ในการค้นหาคำตอบเพิ่มขึ้นเรื่อย ๆ โดยอาศัยการเลียนแบบจากวิธีทางพันธุกรรมของนกกาเหว่าที่ก่อให้เกิดนกกาเหว่ารุ่นใหม่ขึ้นมา โดยมีลักษณะที่เหมือนหรือคล้ายกับนกพ่อก่อน โดยเฉพาะความสามารถในการค้นหาที่ที่เหมาะสม จะถูกถ่ายทอดไปยังรุ่นต่อไป

การครอสโอเวอร์ (Crossover) หมายถึง กระบวนการถ่ายทอดวิธีการค้นหาคำตอบ หรือค่าที่เหมาะสมโดยนำสองวิธีมารวมกันได้วิธีการค้นหาคำตอบแบบใหม่ขึ้นมาที่คล้ายกับวิธีการค้นหาคำตอบสองทั้งสองวิธีแรก เป็นวิธีที่เลียนแบบมาจากการถ่ายทอดพันธุกรรมที่มีการนำโครโมโซมของนกพ่อก่อนและโครโมโซมของนกแม่มาผสมกัน เพื่อสร้างโครโมโซมใหม่ขึ้นมาด้วยวิธีการสลับค่าของโครโมโซมระหว่างนกได้รับคัดเลือกเป็นนกพ่อก่อน วิธีการสลับค่ามีหลายแบบ เช่น การสุ่มตำแหน่งยีนส์ที่ต้องการสลับค่า และการสลับค่าแบบระบุตำแหน่งยีนส์ จำนวนของการสลับค่าของยีนส์ขึ้นอยู่กับค่าความน่าจะเป็นในการแลกเปลี่ยนยีนส์

การผ่าเหล่า (Mutation) หมายถึง กระบวนการถ่ายทอดวิธีการค้นหาคำตอบ หรือค่าที่เหมาะสมโดยนำสองวิธีมารวมกันได้วิธีการค้นหาคำตอบแบบใหม่ขึ้นมาโดยมีความแตกต่างจากสองวิธีแรกโดยสิ้นเชิง เป็นวิธีที่เลียนแบบมาจากการถ่ายทอดทางพันธุกรรมด้วยการเปลี่ยนแปลงคุณลักษณะภายในโครโมโซมบางตำแหน่งของนกพ่อก่อน ที่ส่งผลให้เกิดลักษณะที่แตกต่างไปจากนกพ่อก่อน ด้วยการสุ่มค่าพารามิเตอร์ใหม่ให้แก่ยีนส์ โดยยีนส์ในตำแหน่งใดที่จะถูกกำหนดค่าให้กำหนดจากโอกาสจากค่าความน่าจะเป็นในการกลายพันธุ์

โครโมโซม (Chromosome) หมายถึง วิธีการหาคำตอบที่มีการถ่ายทอดต่อกันไปในแต่ละรุ่น เป็นวิธีที่เลียนแบบมาจากดีเอ็นเอ (DNA = Deoxyribonucleic Acid) ของสิ่งมีชีวิตเชื่อมกับโปรตีนทำหน้าที่สำคัญในการถ่ายทอดลักษณะทางพันธุกรรม และควบคุมการทำงานของเซลล์

วิธีผสมผสาน (Hybrid) หมายถึง การนำวิธีการหาคำตอบหรือค่าที่เหมาะสมตั้งแต่ 2 วิธีขึ้นไป มาผสมผสานหรือเชื่อมต่อเข้าด้วยกัน เพื่อนำจุดเด่นของแต่ละวิธีมารวมกันไว้ในอัลกอริทึมเดียว โดยมีวัตถุประสงค์เพื่อเพิ่มประสิทธิภาพในการหาคำตอบหรือค่าที่เหมาะสมของปัญหา

รูปแบบการบินแบบเลวี (Lévy-flights) หมายถึง พฤติกรรมการบินหาอาหารของแมลง โดยมีรูปแบบเฉพาะตัวดังนี้ แมลงจะทำการบินสำรวจพื้นที่ที่ต้องการหาอาหาร ด้วยการบินตรงไปแล้วเลี้ยวทำมุม 90 องศา ไปเรื่อย ๆ โดยไม่สนใจระยะทาง นับว่าเป็นรูปแบบเฉพาะของ Lévy-flights แล้วนำมาสร้างเป็นฟังก์ชันทางคณิตศาสตร์

## บทที่ 2

### เอกสารและงานวิจัยที่เกี่ยวข้อง

การพัฒนาวิธีการค้นหาแบบนกกาเหว่าโดยการผสมผสานด้วยเจเนติกอัลกอริทึมสำหรับหาค่าที่เหมาะสมของการทำแห้งมะละกอแบบออสโมซิส ผู้วิจัยได้ศึกษาค้นคว้าเอกสารที่เกี่ยวข้อง โดยนำเสนอการทบทวนเอกสารและงานวิจัยที่เกี่ยวข้องดังนี้

ตอนที่ 1 วิธีการหาค่าที่เหมาะสมของการค้นหาแบบนกกาเหว่า (Cuckoo Search) และงานวิจัยที่เกี่ยวข้อง

ตอนที่ 2 วิธีการหาค่าที่เหมาะสมของเจเนติกอัลกอริทึม (Genetic Algorithm) และงานวิจัยที่เกี่ยวข้อง

ตอนที่ 3 การทำแห้ง (Dehydration) และงานวิจัยที่เกี่ยวข้อง

#### ตอนที่ 1 วิธีการหาค่าที่เหมาะสมของการค้นหาแบบนกกาเหว่า (Cuckoo Search) และงานวิจัยที่เกี่ยวข้อง

การหาค่าที่เหมาะสม (Optimization) เกิดจากนักวิทยาศาสตร์มีความต้องการแก้ไขโจทย์ปัญหาทางคณิตศาสตร์ได้คิดค้นวิธีการหาค่าเหมาะสมที่สุด เพื่อนำมาใช้ในการหาค่าตอบที่เหมาะสมที่สุด ส่วนใหญ่แล้วเป็นการสมการด้านคณิตศาสตร์และฟิสิกส์

ก่อนปี ค.ศ. 1940 วิธีที่ใช้ในการหาค่าเหมาะสมที่สุดของฟังก์ชันหลายตัวแปรนั้นยังมีค่อนข้างน้อย เช่น วิธี Least Square นิยมนำไปใช้กับปัญหาด้านฟิสิกส์ ส่วนวิธี Newton Method นิยมนำไปใช้กับปัญหาด้านเคมี

ในช่วงปี ค.ศ. 1940 – 1950 มีการนำเสนอสาขาใหม่ด้านการหาค่าเหมาะสมที่สุด เป็นที่รู้จักกันในชื่อวิธีการกำหนดเชิงเส้น (Linear Programming) ต่อมา ได้มีการศึกษาและพัฒนาขึ้นมาอย่างต่อเนื่อง จนกระทั่งมีการนำวิธีการหาค่าเหมาะสมที่สุดไปใช้ในหลากหลายสาขา เช่น สาขาวิทยาศาสตร์ สาขาวิศวกรรม สาขาคณิตศาสตร์ และสาขาเศรษฐศาสตร์

ปัจจุบันการนำวิธีการหาค่าเหมาะสมที่สุดไปใช้นั้น ไม่ได้จำกัดอยู่แค่ด้านวิศวกรรมเท่านั้น แต่มีการนำไปใช้กันอย่างแพร่หลายในทุกสาขาวิชา โดยเฉพาะสาขาเศรษฐศาสตร์นั้น พบว่า มีการนำวิธีการหาค่าเหมาะสมที่สุดไปใช้กันอย่างกว้างขวางจนกลายเป็นวิธีการมาตรฐานสำหรับการคำนวณหาต้นทุนและผลตอบแทนในการลงทุน เช่น ตลาดหลักทรัพย์ อสังหาริมทรัพย์ พันธบัตร หุ้น การประกันภัย การผลิตและบริโภค

ต่อมาได้มีการพัฒนาเทคนิควิธีการหาค่าที่เหมาะสมที่มีประสิทธิภาพและได้รับความนิยมค่อนข้างสูง จนเป็นที่รู้จักกันในนาม Modern Optimization Method ซึ่งเป็นวิธีการที่ไม่มีแบบแผน (Nontraditional) โดยมีการนำวิธีดังกล่าวไปใช้บูรณาการร่วมกับสาขาวิชาด้านพันธุศาสตร์ เช่น ขั้นตอนวิธีเชิงพันธุกรรม (Genetic Algorithm) การจำลองการอบเหนียว (Simulated Annealing) ขั้นตอนวิธีการหาค่าที่เหมาะสมที่สุดแบบกลุ่มอนุภาค (Particle Swarm Optimization) และขั้นตอนวิธีวิธีการหาค่าเหมาะสมที่สุดด้วยระบบอาณาจักรมด (Ant Colony Optimization)

หลักการพื้นฐานของวิธีการหาค่าเหมาะสม วิธีการหาค่าเหมาะสมเป็นกระบวนการทางคณิตศาสตร์ที่ให้ผลลัพธ์เชิงปริมาณ (Quantity) ผลลัพธ์ที่ได้จึงอยู่ในรูปของจำนวนหรือค่าของตัวเลข ดังนั้น ปัญหาที่นำมาใช้ในการหาค่าเหมาะสมที่สุดจะอยู่ในรูปของแบบจำลองทางคณิตศาสตร์ (Mathematical Model) ส่วนวัตถุประสงค์ของการหาค่าเหมาะสมที่สุดนั้นเป็นไปเพื่อต้องการหาค่าสูงสุด (Maximum) หรือค่าต่ำสุด (Minimum) ของฟังก์ชันวัตถุประสงค์ (Objective Function) และการหาค่าของฟังก์ชันวัตถุประสงค์ ซึ่งอาจจะมีการกำหนดเงื่อนไขหรือข้อจำกัด (Constraints) ดังนั้นการกำหนดฟังก์ชันวัตถุประสงค์และการกำหนด Constraints เป็นสิ่งที่สำคัญมากในการหาค่าสูงสุดหรือต่ำสุด (Rajabioun, 2011)

### ตัวออกแบบ

ตัวแปรออกแบบ (Design Variable) คือตัวแปรที่เป็นคำตอบของวิธีการหาค่าเหมาะสมที่สุด (การแก้ปัญหา) ตัวแปรที่กำหนดขึ้นมานั้นจะต้องสามารถอธิบายลักษณะของระบบได้ มีความสอดคล้องกับปัญหาแต่ละประเภท

### ฟังก์ชันวัตถุประสงค์

ฟังก์ชันวัตถุประสงค์ (Objective Function) คือ ฟังก์ชันที่ต้องการหาค่าสูงสุดหรือค่าต่ำสุด ในการหาค่าเหมาะสมที่สุดนั้น ต้องเริ่มจากการสร้างฟังก์ชันวัตถุประสงค์ให้อยู่ในรูปของสมการทางคณิตศาสตร์ที่ประกอบด้วยตัวแปรออกแบบ สำหรับหาค่าสูงสุดหรือค่าต่ำสุดของฟังก์ชันวัตถุประสงค์ รูปแบบทั่วไปของฟังก์ชันวัตถุประสงค์สามารถเขียนให้อยู่ในรูปของสมการคณิตศาสตร์ดังนี้

$$J = f(x)$$

โดยที่  $x = [x_1, x_2, \dots, x_m]^T$  หรือตัวแปรที่มีจำนวน Dimension เป็น  $m$  สำหรับปัญหาของการหาค่าเหมาะสมที่สุดส่วนใหญ่แล้วเป็นปัญหาด้านการหาค่าต่ำสุด (Minimum Problem)

ปกติแล้วการหาค่าเหมาะสมที่สุดจะมีการสร้างฟังก์ชันวัตถุประสงค์เพียงฟังก์ชันเดียว แต่ในบางปัญหาอาจมีการกำหนดฟังก์ชันวัตถุประสงค์มากกว่าหนึ่งฟังก์ชันได้ เรียกว่า Multicriteria หรือ Multigoal Operation (Abakarov, Sushkov, Almonacid, & Simpson, 2009)

### ข้อจำกัด

ข้อจำกัด (Constraints) เป็นเงื่อนไขหรือข้อจำกัดของฟังก์ชันวัตถุประสงค์ สามารถจำแนกได้ 2 ประเภท คือ Internal Constraints และ External Constraints โดยที่ External Constraints เป็นข้อจำกัดของระบบที่อยู่เหนือการควบคุมของผู้ออกแบบ สำหรับ Internal Constraints เป็นข้อจำกัดที่กำหนดโดยผู้ออกแบบระบบ รูปแบบทั่วไปของข้อจำกัดสามารถแสดงในรูปของสมการดังนี้

$$U_{min} \leq u(t) \leq U_{max}$$

ข้อจำกัดจะมีความสัมพันธ์ต่อตัวแปรที่เลือกไว้ในฟังก์ชันวัตถุประสงค์ หากฟังก์ชันของข้อจำกัดมีการเปลี่ยนแปลงค่า จะส่งผลให้ค่าของฟังก์ชันวัตถุประสงค์เปลี่ยนแปลงด้วย ดังนั้นในการ



หาค่าเหมาะสมที่สุดที่ได้จากฟังก์ชันวัตถุประสงค์ต้องมีความสอดคล้องกับข้อจำกัดที่กำหนดไว้ โดยปกติแล้วจะแบ่งตามเงื่อนไขที่กำหนดโดยเครื่องหมาย  $=, \leq, \geq$  มีบางกรณีที่ปัญหาไม่ได้มีการกำหนดข้อจำกัด โดยเรียกกรณีนี้ว่า Unconstrained Problem

### ฟังก์ชันกำลังสอง

ปัญหาส่วนใหญ่ที่นำมาหาค่าเหมาะสมที่สุด ส่วนใหญ่แล้วจะอยู่ในรูปของ Non-linear หรือเป็นปัญหาที่มีฟังก์ชันวัตถุประสงค์อยู่ในรูปของสมการกำลังสองหรือมากกว่า (Quadratic Function) สามารถเขียนได้ดังสมการ

$$f(x) = x^T A x$$

โดยที่  $A$  เป็นเมทริกซ์สมมาตรจำนวนจริง (Real Symmetric Matrix) สำหรับ  $x$  ทุกค่าที่เป็นจำนวนจริงที่ไม่ใช่ศูนย์ ในกรณีของจำนวนเชิงซ้อน (Complex Number)

สมการโดยทั่วไปของ Quadratic Function และเมื่อหาค่าอนุพันธ์อันดับหนึ่ง (Gradient) ของ Quadratic Form สามารถเขียนให้อยู่ในรูปสมการได้ดังนี้

$$f(x) = \frac{1}{2} x^T A x + b^T x + c$$

$$\nabla f(x) = A x + b$$

### คุณสมบัติความเหมาะสม

ปัญหาการหาค่าเหมาะสมส่วนใหญ่แล้วเป็นการหาค่าต่ำสุด การอธิบายส่วนใหญ่จะเน้นไปที่การหาค่าต่ำสุด เนื่องจากวิธีในการหาค่าสูงสุดนั้นจะมีความคล้ายคลึงกับวิธีการหาค่าต่ำสุด สามารถทำได้โดยใส่เครื่องหมายลบ (-) เข้าไปในฟังก์ชันวัตถุประสงค์แล้วทำการหาค่าต่ำสุด หลังจากนั้นจึงใส่เครื่องหมายลบ (-) ของคำตอบที่ได้จากการหาค่าต่ำสุดอีกครั้ง โดยเรียกวิธีการนี้ว่า คุณสมบัติความเหมาะสม (Optimality) สามารถเขียนเป็นสมการได้ดังนี้

$$\text{maximize } f(x) = -\text{maximize}[-f(x)]$$

### Local Optima และ Global Optima

สำหรับความหมายของ Local Optima และ Global Optima สามารถอธิบายได้ด้วยกราฟ จุดที่อยู่สูงกว่าจุดข้างเคียงนั้นเรียกว่า Local Maximum ส่วนจุดที่อยู่สูงกว่าจุด Local Maximum ทั้งหมดนั้นเรียกว่า Global Maximum ในทางกลับกัน Global Minimum เป็นจุดที่อยู่ต่ำที่สุดของ Local Minimum ทั้งหมด สามารถอธิบายในเชิงคณิตศาสตร์ได้ดังนี้

1. ฟังก์ชัน  $f(x)$  จะมี Local Maximum ที่จุด  $x^*$  ก็ต่อเมื่อ

$$f(x) \leq f(x^*)$$

โดยที่จุด  $x$  ทุกตัวสอดคล้องกับเงื่อนไข  $|x - x^*| < \epsilon, \epsilon > 0$

2. ฟังก์ชัน  $f(x)$  จะมี Local Minimum ที่จุด  $x^*$  ก็ต่อเมื่อ

$$f(x) \geq f(x^*)$$

โดยที่จุด  $x$  ทุกตัวสอดคล้องกับเงื่อนไข  $|x - x^*| < \varepsilon, \varepsilon > 0$

วิธีการหาค่าที่เหมาะสมโดยทั่วไปแล้วสามารถเขียนให้อยู่ในรูปฟังก์ชันคณิตศาสตร์ดังนี้

$$\text{minimize } f_i(x), (i = 1, 2, 3 \dots M)$$

$$\text{Subject to } h_j(x), (j = 1, 2, 3 \dots J)$$

$$g_k(x), (k = 1, 2, 3 \dots K)$$

เมื่อ  $f_i(x), h_j(x)$  และ  $g_k(x)$  เป็นฟังก์ชัน Design Vector

$$x = (x_1, x_2, \dots, x_n)^T$$

$x_1$  เป็นส่วนประกอบของ  $x$  เรียกว่าตัวแปรออกแบบหรือตัวแปรตัดสินใจและมีความต่อเนื่องไม่ต่อเนื่องหรือผสมทั้งสองแบบ

ฟังก์ชัน  $f_i(x)$  เมื่อ  $i = 1, 2, 3 \dots M$  เรียกว่าฟังก์ชันวัตถุประสงค์ ในกรณีที่  $M = 1$  จะมีวัตถุประสงค์เดียว พื้นที่ที่วัดด้วยตัวแปรตัดสินใจเรียกว่า พื้นที่ออกแบบหรือพื้นที่ค้นหา  $R^n$  ในขณะที่พื้นที่ถูกสร้างด้วยค่าของฟังก์ชันวัตถุประสงค์ที่เรียกว่าพื้นที่การแก้หรือพื้นที่ตอบสนอง และเรียก  $h_j(x)$  และ  $g_k(x)$  ว่าข้อจำกัด การหาค่าที่ดีที่สุดด้วยอสมการ  $\geq 0$  (Yang, 2010, pp 2-7)

ในสถานการณ์ปัจจุบันปัญหาเริ่มมีความสลับซับซ้อนและมีความท้าทายมากยิ่งขึ้น เมื่อไม่ทราบวัตถุประสงค์ทั้งหมด แนวทางเดียวที่สามารถแก้ปัญหาได้คือวิธีการหาค่าที่ดีที่สุดที่เหมาะสม โดยสามารถจำแนกออกได้เป็น 2 กรณีดังนี้ Single Objective  $M = 1$  และ Multiobjective  $M > 1$  แต่ในโลกแห่งความเป็นจริงแล้วส่วนใหญ่มักพบ Multiobjective มากกว่ากรณีแรก ดังนั้นนักวิจัยจึงพยายามแสวงหาวิธีค่าที่เหมาะสมรูปแบบใหม่ ๆ ขึ้นมาใช้ งาน โดยที่ส่วนใหญ่แล้วเป็นวิธีที่จัดอยู่ในกลุ่ม Metaheuristic เช่น การค้นหาของนกกาเหว่า (Cuckoo Search) เจเนติกอัลกอริทึม (Genetic Algorithm) และวิธีกลุ่มอนุภาค (PSO)

ในขั้นตอนวิธีดั้งเดิมมักจะมีกฎเกณฑ์แน่นอน เช่น วิธีเชิงเส้นตรง บางวิธีอาศัยพื้นฐานจากการไล่ระดับ เช่น วิธี Newton-Raphson Algorithm โดยหาค่าจากฟังก์ชันและอนุพันธ์ของฟังก์ชันได้ผลดีกับปัญหาที่มีข้อมูลต่อเนื่องกัน แต่ในความเป็นจริงแล้ว กลับมีปัญหบางส่วนที่ฟังก์ชันไม่มีความต่อเนื่อง ทำให้วิธีการแก้ปัญหาแบบดั้งเดิมไม่สามารถทำงานได้ดีพอ วิธีการแก้ปัญหาโดยใช้การเลียนแบบธรรมชาติจึงเป็นทางเลือกที่ดี เนื่องจากเป็นวิธีการค่าที่เหมาะสมแบบไม่มีการไล่ระดับ ไม่มีการใช้อนุพันธ์ เลือกใช้แต่ค่าของฟังก์ชัน เช่นวิธีของ Hooke-Jeeves Pattern Search และ Nelder-Mead

ขั้นตอนวิธีการแก้ปัญหาแบบสุ่มมี 2 ชนิดคือ Heuristic และ Metaheuristic มีความแตกต่างกันเพียงเล็กน้อย (Yang, 2010, pp. 1-6)

1. Heuristic มีความหมายตรงกับ “การค้นหาแบบลองผิดลองถูก” สามารถแก้ปัญหาการหาสถานะที่เหมาะสมได้อย่างมีเหตุผล แต่ไม่สามารถรับรองได้ว่าการแก้ปัญหาจะสัมฤทธิ์ผลใดตลอด มีความเหมาะสมสำหรับการแก้ปัญหาที่ไม่ได้ต้องการผลเลิศแต่ค่อนข้างง่ายต่อการได้คำตอบ

2. Metaheuristic มีความหมายตรงกับ “ระดับที่สูงขึ้น” ได้ประสิทธิภาพดีกว่า Heuristic โดยเฉพาะความสามารถในการสุ่มและการค้นหาในระดับท้องถิ่น การให้นิยามดังกล่าวมีทั้งผู้ที่เห็นด้วยและไม่เห็นด้วย และเมื่อไม่นานมานี้มีแนวโน้มที่ในการนิยามโดยใช้คำว่า Stochastic Algorithm

### วิธีการค้นหาแบบนกกาเหว่า (Cuckoo Search)

นกมากกว่าเก้าพันสายพันธุ์ที่มีพฤติกรรมคล้ายกับนกขุนทอง โดยที่ทุกตัววางไข่ในรังแล้วฟักไข่ซึ่งนับได้ว่าเป็นรูปแบบที่สะดวกและรวดเร็วในการสืบพันธุ์ ตัวอ่อนของนกจะได้รับการปกป้องจากเปลือกไข่ในขณะที่ฟักไข่ แต่เนื่องจากไข่มีขนาดใหญ่จึงค่อนข้างยากลำบากสำหรับนกตัวเมียที่จะดูแลรักษาไข่หลายฟองในเวลาเดียวกัน โดยเฉพาะการเคลื่อนย้ายไข่นั้นจะส่งผลกระทบต่อการบินของแม่นกให้ไปไปด้วยความยากลำบากอย่างมากและยังต้องใช้พลังงานค่อนข้างมาก ไข่นกอุดมไปด้วยโปรตีนที่มีคุณค่าทางโภชนาการสูงนับว่าเป็นสิ่งที่ดึงดูดนักล่าได้เป็นอย่างดี ดังนั้นจึงต้องเลือกสถานที่ที่ปลอดภัยเพื่อใช้สำหรับการฟักไข่ การค้นหาสถานที่ที่มีความปลอดภัยเพื่อใช้เป็นสถานที่สำหรับฟักไข่เพื่อเพิ่มประชากรนกใหม่ นั้นนับว่าเป็นการค้นหาแนวทางในการแก้ปัญหาที่ท้าทายมากสำหรับแม่นก อย่างไรก็ตามนกยังสามารถแก้ปัญหาอย่างชาญฉลาดด้วยการใช้ศิลปะการออกแบบ วิศวกรรม และสถาปัตยกรรมที่ค่อนข้างซับซ้อน นกส่วนใหญ่สร้างรังโดยให้มีลักษณะดังต่อไปนี้ รังไม่มีความโดดเด่น หลบซ่อนอยู่ตามต้นไม้ต่าง ๆ เพื่อหลีกเลี่ยงการค้นพบจากนักล่าจำนวนมากประสบความสำเร็จในการซ่อนตัวอยู่ในรังที่ลับตาแม้แต่มนุษย์ก็แทบจะไม่อาจพบเห็น (Rajabioun, 2011)


แต่มินกกาเหว่าบางชนิดที่อาศัยไหวพริบในการใช้รังร่วมกับนกชนิดอื่น ๆ เพื่อสร้างสมาชิกใหม่ พฤติกรรมลักษณะนี้เรียกว่า "การเปียนฟักไข่" โดยนกกาเหว่าที่ต้องการวางไข่จะไม่มีการสร้างรังของตัวเองแต่จะอาศัยการวางไข่ในรังของนกสายพันธุ์อื่นแทนแล้วปล่อยให้เจ้าของรังฟักและเลี้ยงดูลูกของตัวเองจนเจริญเติบโต เป็นที่ยอมรับว่านกกาเหว่ามีความเชี่ยวชาญในศิลปะการใช้กลยุทธ์ที่ชาญฉลาดดังกล่าว โดยกลยุทธ์ที่นกกาเหว่าใช้จะอาศัยหลักการพื้นฐานคือ การลักลอบการสร้างความปลอดภัยและความรวดเร็ว แม่นกกาเหว่าจะเคลื่อนย้ายไข่ของแม่นกเจ้าของรังออกแล้ววางไข่ของตัวเองลงไปแทน จากนั้นก็บินออกไปพร้อมกับไข่ของเจ้าของรังที่นำกลับออกไปเป็นผลพลอยได้ โดยใช้เวลาในกระบวนการทั้งหมดประมาณสิบวินาที นกกาเหว่าสามารถวางไข่ลงในรังของนกหลายสายพันธุ์โดยอาศัยการเลียนแบบสี ขนาดและรูปแบบไข่ของตัวเอง เพื่อให้ตรงกับลักษณะไข่ของเจ้าของรัง แม่นกกาเหว่าจะมีความเชี่ยวชาญการเลียนแบบไข่ของนกเจ้าของรังสายพันธุ์ใดสายพันธุ์หนึ่งโดยเฉพาะ วิธีการจัดการวางไข่เลียนแบบไข่ของเจ้าของรังได้อย่างถูกต้องนั้นก็ เป็นอีกหนึ่งในความสลับซับซ้อนของธรรมชาติ นกหลายชนิดเรียนรู้ที่จะตรวจสอบไข่นกกาเหว่าที่วางในรังของตัวเอง เมื่อพบไข่ของนกตัวอื่นจะทำการโยนออกนอกรังหรืออาจหอดทิ้งรังไป เพื่อเริ่มต้นสร้างรังใหม่อีกครั้ง ดังนั้นนกกาเหว่าต้องพยายามอย่างต่อเนื่องในการปรับปรุงการลอกเลียนไข่ของเจ้าของรัง ในขณะที่เจ้าของรังก็พยายามที่จะค้นหาวิธีการในการตรวจสอบไข่ปรสิต การต่อสู้ระหว่างนกเจ้าของ

รังและนกที่วางไข่ปรสิตเสมือนกับการแข่งขันเพื่อเอาตัวรอดของนกในการดำรงชีพพันธุ์ของตนเอง (Gandomi, Yang, & Alavi, 2013)

การค้นหาแบบนกกาเหว่า เป็นขั้นตอนวิธีการเพิ่มประสิทธิภาพที่ได้รับแรงบันดาลใจจากธรรมชาติ วิธีการค้นหาแบบนกกาเหว่าได้รับการพัฒนาโดย Xin-She Yang จากมหาวิทยาลัยเคมบริดจ์ และ Suash Deb จากวิทยาลัยวิศวกรรมรามานและได้รับการนำเสนอในปี 2009 วิธีการค้นหาแบบนกกาเหว่า (CS) ตั้งอยู่บนพื้นฐานของการเบียนฟักไข่กับนกที่สายพันธุ์ใกล้เคียงกันบางชนิดและดำเนินการปรับปรุงวิธีด้วย Lévy-flights โดยผลจากการศึกษาวิจัยที่ผ่านมาจนถึงในปัจจุบันส่วนใหญ่พบว่า วิธีการค้นหาของนกกาเหว่า (CS) มีประสิทธิภาพสูงกว่าวิธีกลุ่มอนุภาค (PSO) และวิธีเจเนติกอัลกอริทึม (GA) (Yang & Deb, 2009)

นกกาเหว่านอกจากจะเป็นนกที่สวยงามมีเสน่ห์และมีเสียงที่ไพเราะ แล้วยังมีกลยุทธ์เชิงรุกในการสืบพันธุ์ที่ชาญฉลาดอีกด้วย เช่น สายพันธุ์ *Ani* และ *Guira* วางไข่ลงในรังของนกอื่น แล้วเคลื่อนย้ายไข่ของนกเจ้าของรังทิ้งไปนอกรัง เพื่อเพิ่มโอกาสให้กับไข่ของตัวเองที่จะได้รับการฟักไข่ การเบียนฟักไข่สามารถจำแนกออกได้เป็น 3 ประเภทดังนี้ การเบียนฟักไข่ที่เฉพาะเจาะจงกันภายในกลุ่ม การร่วมมือกันเลี้ยงดูลูกนก และการเข้ายึดรังของตัวอื่น ในระหว่างที่นกฟักไข่หากนกเจ้าของรังพบว่าไข่แปลกปลอมเข้ามา แล้วจะทำการกำจัดออกไปนอกรังหรืออาจละทิ้งรังไปแล้วสร้างรังใหม่นกกาเหว่าสายพันธุ์ *Tapera* มีความสามารถพิเศษในการลอกเลียนแบบไข่ทั้งรูปร่างและสีสันทให้มี ความใกล้เคียงกับไข่ของเจ้าของรังที่ต้องการวางไข่เพื่อเพิ่มโอกาสที่ไข่จะได้รับการฟัก อย่างไรก็ตาม สิ่งที่น่าพิศวงก็คือช่วงเวลาในการวางไข่ โดยนกกาเหว่าเลือกรังที่นกเจ้าของรังเพิ่งจะวางไข่ของตัวเองใหม่ ๆ แต่ไข่ของนกกาเหว่าได้รับการฟักเป็นตัวก่อน เนื่องจากระยะเวลาฟักตัวของไข่นกกาเหว่าจะสั้นกว่านกเจ้าของรัง เมื่อลูกนกฟักออกมาแล้วจะถูกกระตุ้นสัญชาตญาณ แล้วกำจัดไข่ที่เหลือออกไปนอกรังโดยอาศัยวิธีการกำจัดไข่แบบเตาสุ่ม เพื่อเป็นการเพิ่มส่วนแบ่งอาหารที่ลูกนกกาเหว่าจะได้รับจากแม่นก จากการศึกษาแสดงให้เห็นว่าลูกนกกาเหว่ามีความสามารถในการเลียนแบบพฤติกรรมได้ใกล้เคียงกับลูกนกเจ้าของรัง ทั้งนี้เพื่อสร้างโอกาสในการได้รับอาหารจากแม่นกเพิ่มขึ้น

จากการศึกษาพบว่า การบินของสัตว์หลาย ๆ ชนิดรวมถึงการบินเพื่อค้นหารังที่มีความเหมาะสมสำหรับการวางไข่ของนกกาเหว่า มีลักษณะที่คล้ายคลึงกัน สามารถอธิบายได้โดยอาศัยรูปแบบของ Lévy-flights ได้ดังต่อไปนี้



ภาพที่ 2-1 แผนภาพแสดงการเคลื่อนที่ของ Lévy-flights (Yang & Deb, 2009)

วิธีการสร้างแนวทางการแก้ปัญหาใหม่

$$x_i^{t+1} = x_i^t + \alpha \oplus \text{Lévy}(\lambda)$$

เมื่อ  $\lambda$  คือขนาดขั้นตอนที่เกี่ยวข้องกับมาตราส่วนของปัญหาที่สนใจ ในสมการถัดไปเป็นสมการสำหรับสุ่มทางเดิน โดยทั่วไปแล้วการสุ่มทางเดินจะเป็นแบบ Markove chain ที่มีสถานะหรือตำแหน่งถัดไปขึ้นอยู่กับตำแหน่งปัจจุบันและความน่าจะเป็นของการเปลี่ยนแปลงเครื่องหมาย  $\oplus$  หรือ Entrywise Multiplications โดยมีความคล้ายคลึงกับการปฏิบัติการที่ใช้ในขั้นตอนวิธีการหาค่าที่เหมาะสมที่สุดแบบกลุ่มอนุภาค (Particle Swarm Optimization) แต่การสุ่มทางเดินของ Lévy-flights จะมีประสิทธิภาพมากกว่าในการสำรวจพื้นที่ค้นหา

$$\text{Lévy}(\lambda) \sim \mathcal{U} = t^{-\lambda}, \quad 1 < \lambda \leq 3$$

การสุ่มหาการเคลื่อนที่ของ Lévy-flights จะมีการนำ Mantegna's Algorithm มาช่วยในการสร้างตัวเลขสุ่ม เนื่องจาก Mantegna's Algorithm สามารถสร้างตัวเลขตามการกระจายที่มีเสถียรภาพ ดังสมการ

$$\sigma_x = \left[ \frac{\Gamma(1 + \alpha) \sin \frac{\pi\alpha}{2}}{\Gamma\left(\frac{1 + \alpha}{2}\right) \alpha 2^{\left(\frac{\alpha-1}{2}\right)}} \right]^{\frac{1}{\alpha}}$$

$$\sigma_x = 1$$

ในการหาทางเดินถัดไป

$$step = \frac{u}{|v|^{\frac{1}{\alpha}}}$$

โดยที่  $u = randn[s] * \sigma_x$

$$v = randn[s] * \sigma_y$$

เมื่อ  $randn[s]$  คือฟังก์ชันสุ่มจำนวนเต็มจาก 1 ถึง  $s$  จะได้

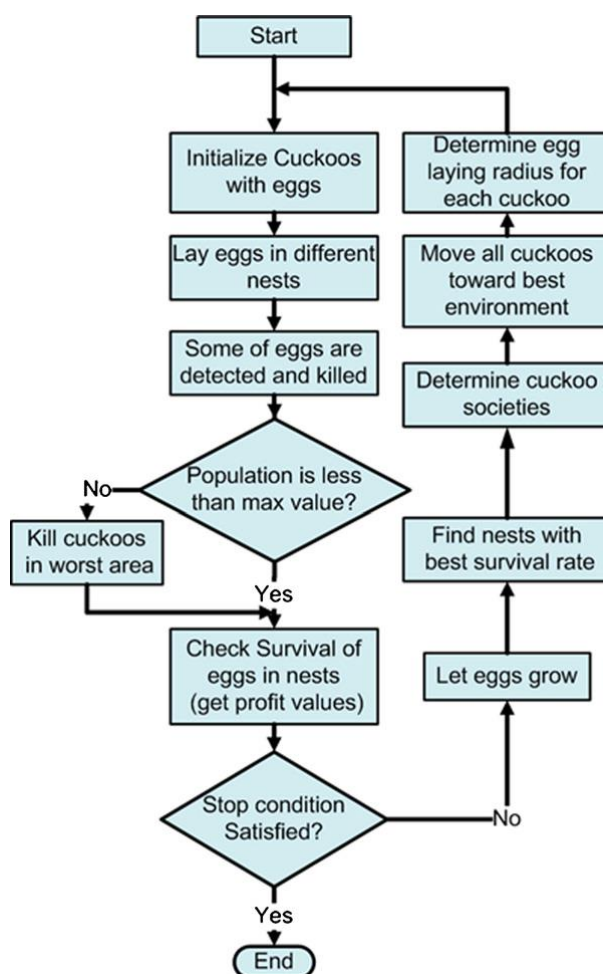
$$stepsize = 0.01 * step * (s - xbest)$$

เมื่อ  $xbest$  คือตำแหน่งก่อนหน้าที่ดีที่สุด

วิธีการค้นหาแบบนกกาเหว่า (Cuckoo Search) ตั้งอยู่บนแนวคิดพื้นฐานของวิธีการค้นหาแบบนกกาเหว่า มี 3 ข้อดังนี้

1. นกกาเหว่าแต่ละตัวจะวางไข่จำนวน 1 ฟองต่อครั้งในรังที่มีการสุ่มเลือก
2. รังที่ดีและไข่ที่มีคุณภาพสูง จะดำเนินการไปยังรุ่นถัดไปได้
3. กำหนดจำนวนของรังของนกโฮสต์ที่ใช้ได้  $n$  และความน่าจะเป็นที่นกเจ้าของรังจะพบไข่ของนกกาเหว่าคือ  $pa \in [0,1]$  จากนั้นนกเจ้าของรังจะกำจัดไข่ออกนกรังหรืออาจจะทิ้งรังแล้วไปสร้างรังใหม่

การหาค่าโดยประมาณด้วยสัดส่วนของ  $x_n$  จากจำนวน  $n$  รังที่ถูกทดแทนด้วยรังใหม่ ด้วยการสุ่มรังขึ้นมาทดแทนแล้วทดสอบการเข้ากันได้พอดีของฟังก์ชัน (Yang & Deb, 2009)



ภาพที่ 2-2 ผังขั้นตอนวิธีการของการค้นหาของนกกาเหว่า (Rajabioun, 2011)

จากข้อกำหนดเบื้องต้นทั้ง 3 ข้อ สามารถนำมาสรุปเป็นขั้นตอนพื้นฐานของวิธีการค้นหาแบบนกกาเหว่า (Cuckoo Search) ได้ดังนี้

1. กำหนดฟังก์ชันวัตถุประสงค์  $f(x), x = (x_1, x_2 \dots x_d)^T$
2. สร้างประชากรเริ่มต้นของ  $n$  โดยเป็นจำนวนรังเริ่มต้น  $x_i (i = 1, 2 \dots n)$

3. ตรวจสอบว่าครบรอบตามเกณฑ์ที่กำหนดหรือไม่ (ถึงเกณฑ์ที่ต้องหยุด) ถ้าใช่ให้ทำตามขั้นตอนที่ 9 ถ้าไม่ใช่ให้ทำตามขั้นตอนที่ 4

4. ประเมินคุณภาพของรังจากฟังก์ชันวัตถุประสงค์  $F_i$  หลังจากนั้นเลือกรังใหม่มาประเมินคุณภาพตามฟังก์ชัน  $F_j$

5. นำค่าที่ได้มาเปรียบเทียบกัน ถ้าค่า  $F_i$  มากกว่าค่า  $F_j$  ให้แทนที่รัง  $j$  เป็นคำตอบใหม่

6. โดยที่การค้นพบรังใหม่นั้นต้องมีค่าความน่าจะเป็นมากกว่าค่า  $p_a$  ที่กำหนดไว้ สำหรับรังที่ไม่ผ่านค่า  $p_a$  ให้ทิ้งค่ารังแล้วสุ่มเลือกค่ารังใหม่

7. เก็บคำตอบที่ดีที่สุด หรือรังที่มีคุณภาพ


8. เรียงลำดับผลลัพธ์ที่ได้ จากนั้นกลับไปทำขั้นตอนที่ 3

9. ผลลัพธ์สุดท้ายจะได้คำตอบที่ดีที่สุด หรือรังที่มีคุณภาพดี

วิธีการค้นหาของนกกาเหว่ามีขั้นตอนเหมือนกับอัลกอริทึมวิวัฒนาการโดยทั่วไป กล่าวคือวิธีการค้นหาของนกกาเหว่า เริ่มต้นจากประชากรนกกาเหว่าได้วางไข่ในรังของนกเจ้าของรัง ไข่ของนกกาเหว่าบางส่วนที่มีความคล้ายกับไข่นกเจ้าบ้านมีโอกาสที่จะเจริญเติบโตและกลายเป็นนกกาเหว่าเต็มวัย ส่วนไข่ที่โดนตรวจพบโดยนกเจ้าของรังจะถูกกำจัดทิ้งไป จำนวนไข่ที่สามารถเจริญเติบโตจะเป็นตัวยืนยันถึงความเหมาะสมของรังในพื้นที่นั้น ๆ ยิ่งจำนวนไข่ที่อยู่รอดได้มีมากขึ้นเท่าไรก็ยิ่งส่งผลให้ผลตอบแทนในเขตพื้นที่นั้นมีมากขึ้นเท่านั้น ดังนั้นตำแหน่งที่ไข่สามารถอยู่รอดได้คือที่มาของคำว่า Cuckoo Optimization Algorithm (COA) เป็นไปเพื่อหาผลลัพธ์ที่เหมาะสม

การค้นหาของนกกาเหว่าเพื่อหาพื้นที่ที่เหมาะสมที่สุดในการวางไข่ โดยพิจารณาจากอัตราการรอดชีวิตของไข่สูงที่สุด หลังจากไข่เจริญเติบโตกลายเป็นนกกาเหว่าเต็มวัยแล้วจะมีการอยู่รวมกันเป็นสังคม โดยที่ในแต่ละชุมชนมีขอบเขตที่อาศัยดำรงชีวิตเป็นของตัวเอง ดังนั้นที่อยู่อาศัยที่ดีที่สุดของทุกชุมชนต่างเป็นที่ต้องการอพยพเข้าไปอยู่อาศัยของนกกาเหว่าจากชุมชนอื่น ๆ เมื่อพิจารณาจากจำนวนของไข่ของนกกาเหว่าแต่ละตัวและระยะทางระหว่างนกกาเหว่าไปยังจุดเป้าหมาย (ที่อยู่อาศัยที่ดีที่สุด) โดยนกกาเหว่าจะเริ่มวางไข่ภายในรังที่สุ่มขึ้นมาภายในรัศมี กระบวนการนี้จะดำเนินต่อไปจนกว่าตำแหน่งที่ดีที่สุดที่มีมูลค่าผลตอบแทนสูงสุดและส่วนใหญ่ของประชากรนกกาเหว่าจะรวมตัวกันรอบ ๆ ของตำแหน่งเดียวกัน

การหาค่าที่เหมาะสมด้วยวิธีการค้นหาแบบนกกาเหว่านั้น มีความจำเป็นต้องกำหนดค่าของตัวแปรของปัญหาในรูปของอาร์เรย์ การหาค่าที่เหมาะสมด้วย GA และ PSO จะเรียกอาร์เรย์นี้ว่า "โครโมโซม" และ "อนุภาคตำแหน่ง" ตามลำดับ แต่ในวิธีการหาค่าที่เหมาะสมด้วยอัลกอริทึมนกกาเหว่า (COA) เรียกว่า "ที่อยู่อาศัย" ในการหาค่าที่เหมาะสมของปัญหาจำนวน  $N_{var}$  มิติ



ภาพที่ 2-3 การวางไข่ของนกกาเหว่าภายใน Egg Laying Radius (ELR) (Rajabioun, 2011)

ถิ่นที่อยู่เป็นอาร์เรย์ของ  $1 \times N_{var}$  เป็นตัวแทนตำแหน่งของการใช้ชีวิตในปัจจุบันของนกกาเหว่า โดยอาร์เรย์นี้ถูกกำหนดไว้ดังนี้

$$Habitat = [x_1, x_2, \dots, x_{Nvar}]$$

ค่าของตัวแปรแต่ละตัว ( $x_1, x_2, \dots, x_{Nvar}$ ) คือจำนวนของเลขลอย ส่งผลให้ผลตอบแทนของถิ่นที่อยู่ที่จะได้รับการประเมินด้วยฟังก์ชันของผลตอบแทน  $f_p$  ถิ่นที่อยู่ของ  $A(x_1, x_2, \dots, x_{Nvar})$  ดังนั้น

$$Profit = f_p(habitat) = f_p(x_1, x_2, \dots, x_{Nvar})$$

ในฐานะที่พบว่า Cuckoo Optimization Algorithm COA เป็นอัลกอริทึมที่เพิ่มฟังก์ชันผลตอบแทน การใช้ COA แก้ปัญหาการลดค่าใช้จ่ายต่ำที่สุด สามารถหาได้จากฟังก์ชันผลตอบแทนต่อไปนี้

$$Profit = -cost(habitat) = -fc(x_1, x_2, \dots, x_{Nvar})$$


การเริ่มต้นขั้นตอนวิธีการหาค่าที่เหมาะสม สร้างเมทริกซ์ถิ่นที่อยู่ขนาด  $N_{pop} \times N_{var}$  แล้วสุ่มจำนวนไข่ที่จะผลิตสำหรับนกกาเหว่าที่อาศัยในถิ่นที่อยู่นี้ ตามปกติแล้วนกกาเหว่าแต่ละตัวจะวางไข่ประมาณ 5-20 ฟอง จากนั้นนำค่าที่ได้จากการประมาณนี้มากำหนดเป็นขีดจำกัดบนและล่างในการวางไข่ของนกกาเหว่าแต่ละตัว โดยการวางไข่จะอยู่ภายในระยะสูงสุดจากถิ่นที่อยู่และเรียกว่ารัศมีการวางไข่ Egg Laying Radius (ELR) โดยมีขีดจำกัดสูงสุดเรียกว่า  $var_{hi}$  และขีดจำกัดต่ำที่สุดเรียกว่า  $var_{low}$  เป็นตัวแปร โดยที่นกกาเหว่าแต่ละตัวมีไข่วางรัศมี (ELR) เป็นสัดส่วนกับจำนวนรวมของไข่ทั้งหมด จำนวนไข่ในปัจจุบัน ตัวแปร  $var_{hi}$  และ  $var_{low}$  และขีดจำกัด สามารถแสดงความสัมพันธ์ได้ดังนี้

$$ELR = \alpha \times \frac{\text{Number of current cuckoo's eggs}}{\text{Total number of eggs}} \times (var_m - var_{low})$$



เมื่อค่าสูงสุดเป็นจำนวนเต็ม

นกกาเหว่าเริ่มวางไข่โดยเริ่มจากเลือกรังนกที่อยู่ในบริเวณ ELR ของตัวเอง เมื่อนกทุกตัววางไข่เรียบร้อยแล้ว โอกาสที่ไข่ที่มีความคล้ายกับไข่เจ้าของรังน้อยกว่าจะถูกค้นพบและโดนกำจัดเท่ากับ  $p\%$  ของจำนวนไข่ทั้งหมด (ประมาณ 10%) หากโอกาสเจริญเติบโต มีไข่เพียง 1 ฟองต่อหนึ่งรังเท่านั้นที่สามารถเจริญเติบโตต่อไปได้ (Rajabioun, 2011)



ภาพที่ 2-4 ผังการอพยพถิ่นที่อยู่ของนกกาเหว่า (Rajabioun, 2011)

### การวางไข่ของนกกาเหว่า (Cuckoos' Style for Egg Laying)

การวางไข่ของนกกาเหว่าจะอาศัยหลักการสุ่มจากรังนกที่อยู่ใน *Egg Laying Radius (ELR)* ดังแสดงในภาพที่ 2-3 ไข่ของนกกาเหว่าบางส่วนมีลักษณะปรากฏที่ไม่เหมือนกับไข่ของนกเจ้าของรังที่นกกาเหว่าเข้าไปวางไข่ มีความเป็นไปได้ว่าไข่ของนกกาเหว่าอาจถูกตรวจพบและถูกกำจัดออกนอกรัง คิดเป็น  $p\%$  (ประมาณ 10%) ที่ไม่มีโอกาสได้รับการฟักและเจริญเติบโตต่อไป โดยปกติแล้วไข่ของนกกาเหว่า จะได้รับการฟักและเลี้ยงดูโดยนกเจ้าของรัง เมื่อไข่ของนกกาเหว่าได้รับการฟักออกมาแล้วลูกนกกาเหว่า จะเขี้ยวไข่เจ้าของรังทิ้งไป แต่หากไข่ของนกเจ้าของรังฟักก่อนไข่ของนกกาเหว่าฟัก ลูกนกกาเหว่า จะกินอาหารได้ที่แม่นกเจ้าของรังนำกลับมาป้อนให้ได้มากกว่า ทำให้เจริญเติบโตได้รวดเร็วกว่าลูกนกเจ้าของรัง และในไม่ช้าลูกนกเจ้าของรังจะตายเนื่องจากการอดอาหาร ดังนั้นในรังก็จะเหลือเพียงลูกนกกาเหว่าเท่านั้น (Rajabioun, 2011)

### การอพยพของนกกาเหว่า (Immigration of Cuckoos)

นกกาเหว่าจะอาศัยอยู่ในชุมชนของตนเองชั่วคราวระยะเวลาหนึ่ง ครั้นเมื่อเจริญเติบโตจนกลายเป็นนกกาเหว่าโตเต็มวัยและถึงเวลาที่ต้องวางไข่นกกาเหว่าก็จะอพยพไปยังถิ่นที่อยู่ที่ดีกว่า นกกาเหว่า จะเลือกแหล่งที่อยู่อาศัยที่ดีขึ้นกว่าเดิมและมีลักษณะของไข่คล้ายกับไข่ของนกเจ้าของรัง มีอาหารอุดมสมบูรณ์เพียงพอต่อการเลี้ยงลูกอ่อนรุ่นต่อไป หลังจากที่ดินนกกาเหว่ามีการรวมกลุ่มกันใน

พื้นที่แตกต่างออกไปสิ่งที่สำคัญที่นักใช้ในการตัดสินใจสำหรับการอพยพคือผลตอบแทนสูงสุด การที่นกกาเหว่าอาศัยอยู่ในสิ่งแวดล้อมที่หลากหลายก็เป็นเรื่องยากสำหรับนกเหว่าที่จะพิจารณาเข้าร่วมกับนกกาเหว่ากลุ่มหนึ่งกลุ่มใด ดังนั้นเพื่อแก้ปัญหาดังกล่าวการเข้าร่วมกลุ่มของนกกาเหว่าจะอาศัยการจำแนกด้วยค่า K-means (โดยปกติค่า k ประมาณ 3-5 เพียงพอต่อการสร้างแบบจำลอง) ปัจจุบันการเข้าร่วมกลุ่มของนกกาเหว่าจะพิจารณาจากค่าเฉลี่ยของผลตอบแทน เมื่อค่าเฉลี่ยของผลตอบแทนมีค่าสูงสุดแล้วกลุ่มของนกกาเหว่านั้นก็จะเป็นจุดหมายปลายทางของการอพยพครั้งใหม่ของนกกาเหว่าจากแหล่งอื่น ๆ หลังจากนั้นนกกาเหว่าจะอพยพตรงไปยังเป้าหมายแต่จะไม่ได้บินไปยังทุกถิ่นที่อยู่ที่กำหนดไว้เป็นจุดหมายปลายทาง แต่บินไปเพียงบางส่วนของเส้นทางและมีการเบี่ยงเบนเกิดขึ้น ดังแสดงในภาพที่ 2-3 นกกาเหว่าเพียงแค่บินไป  $\lambda\%$  ของระยะทางทั้งหมดตรงไปยังที่อยู่เป้าหมายโดยมีค่าเบี่ยงเบน  $\varphi$  radians ดังนั้นพารามิเตอร์ทั้ง  $\lambda\%$  และ  $\varphi$  สามารถช่วยในการค้นหาของนกกาเหว่าสมรรถิ์ผลในทุกสภาวะ โดยให้นิยามของพารามิเตอร์ทั้งสองตัวดังนี้ สำหรับนกแต่ละตัวแล้ว  $\lambda$  และ  $\varphi$  สามารถนิยามได้ดังนี้ (Valian, 2012; Rajabioun, 2011)

$$\lambda U(0, 1)$$

$$\varphi U(-\omega, \omega)$$

เมื่อ  $\lambda U(0,1)$  หมายถึงตัวเลขสุ่ม  $\lambda$  (มีการกระจายที่สม่ำเสมอ) ระหว่าง 0 และ 1  $\omega$  คือ ค่าพารามิเตอร์ที่จำกัดการเบี่ยงของจากถิ่นที่อยู่เป้าหมาย ประมาณ  $\omega$  of  $x/6$  (rad)

1. *Initialize cuckoo habitats with some random point on the profit function*
  2. *Dedicate some eggs to each cuckoo*
  3. *Define ELR for each cuckoo*
  4. *Let cuckoo to lay eggs inside their corresponding ELR*
  5. *Kill those eggs that are recognized by host birds*
  6. *Let eggs hatch and chicks grow*
  7. *Evaluate the habitat of each newly grown cuckoo*
  8. *Limit cuckoos' maximum number in environment and kill those who live in worst habitats*
  9. *Cluster cuckoos and find best group and select goal habitat*
  10. *Let new cuckoo population immigrate toward goal habitat*
- If stop condition is satisfied, stop, If not go to 2*

ภาพที่ 2-5 Pseudo-code for Cuckoo Optimization Algorithm (Rajabioun, 2011)

การบรรจบกันที่ดีจะเกิดขึ้นเมื่อประชากรนกกาเหว่าสามารถค้นหาผลตอบแทนสูงสุด เมื่อนกกาเหว่าที่อพยพทั้งหมดมุ่งตรงไปยังจุดเป้าหมายและบรรลุถึงถิ่นที่อยู่ตามที่กำหนดไว้ นกที่พร้อมวางไข่แต่ละตัวจะพิจารณาจำนวนไข่ที่จะวางโดยคำนวณจาก ELR ของนกตัวละตัว หลังจากนั้นนกกาเหว่าจะเริ่มกระบวนการวางไข่

จำนวนนกที่ไม่สามารถเจริญเติบโตเป็นนกเต็มวัยจากสภาวะแวดล้อมที่ไม่เหมาะสมในถิ่นที่อยู่ (Eliminating Cuckoos in Worst Habitats) จากข้อเท็จจริงทางธรรมชาติที่ว่าประชากรนกกาเหว่าพยายามปรับเข้าสู่ภาวะสมดุลเสมอ ดังนั้นจำนวน  $N_{max}$  จะคอยควบคุมและจำกัดจำนวนสูงสุดของนกกาเหว่าที่อาศัยอยู่ในสภาวะแวดล้อมนั้น ๆ ทั้งนี้มีสาเหตุมาจากข้อจำกัดด้านอาหาร การตายที่เกิดจากนักล่าและไม่สามารถหารังที่เหมาะสมต่อการวางไข่ได้ ในการสร้างแบบจำลองที่นำเสนอจำนวน  $n_{max}$  ของนกกาเหว่าที่อยู่รอดมีจำนวนมากกว่าวิธีอื่น (Rajabioun, 2011)

การลู่เข้าหาค่าที่เหมาะสม (Convergence) หลังจากผ่านกระบวนการทำซ้ำ ๆ ประชากรนกกาเหว่าทั้งหมดได้เคลื่อนย้ายไปยังถิ่นที่อยู่ที่ดีกว่าโดยประกอบด้วยลักษณะดังต่อไปนี้ ไข่มีลักษณะคล้ายกับไข่ของเจ้าของรังและมีแหล่งอาหารเพียงพอ ถิ่นที่อยู่สามารถให้ผลตอบแทนสูงสุดและเกิดสูญเสียของไข่น้อยมาก รวมทั้งมีการบรรจบกันได้อย่างรวดเร็ว นกกาเหว่ามากกว่า 95% มีความต้องการถิ่นที่อยู่ที่ดีคล้ายกัน จึงสามารถนำมากำหนดเป็น Cuckoo Optimization Algorithm (COA) โดยมีขั้นตอนดังภาพที่ 2.4 COA ได้มีการนำไปประยุกต์ใช้ในปัญหาการหาค่าที่เหมาะสมที่ใช้เป็นตัวเปรียบเทียบ การพิสูจน์ทางทฤษฎีเกี่ยวกับความน่าจะเป็นของการลู่เข้าหาค่าตอบนั้นพบว่าปฏิบัติตามกฎของขั้นตอนวิธีการเพิ่มประสิทธิภาพด้วยวิธีการสุ่ม (Stochastic Optimization Algorithms) โดยพิจารณาตามกระบวนการพื้นฐานทางธรรมชาติของมาร์คอฟและมีการจัดหมวดหมู่ของรายละเอียดของสภาวะสมดุลหรือสภาวะย้อนกลับของอัลกอริทึมทำให้เกิดการสูญเสียประสิทธิภาพ นอกจากนี้หากมีการยืนยันในการลู่เข้าหา Global Optima ในสภาวะที่แข็งแกร่งหรืออ่อนแอส่งผลให้การหลอมเข้าหากันเกิดขึ้นซ้ำ สำหรับจุดแข็งของ Stochastic Algorithms ที่มีแหล่งกำเนิดมาจากข้อเท็จจริงที่อยู่บนพื้นฐานตามธรรมชาติของความน่าจะเป็น เพื่อให้แน่ใจว่าอัลกอริทึมไม่ติดอยู่ที่ Local Optima และไม่มีความสำเร็จในการใช้ข้อมูลไต่ระดับและไม่อาศัยเทคนิคหรือการเชิงอนุพันธ์ (Rajabioun, 2011; Yang, 2013; Valian, 2012)

การตรวจสอบมาตรฐานในการเพิ่มประสิทธิภาพของอัลกอริทึม (Cuckoo Benchmarks on Cuckoo Optimization Algorithm) ในการหาค่าที่เหมาะสมแบบ Cuckoo Optimization Algorithm (COA) ด้วยวิธีการทดสอบโดยฟังก์ชันมาตรฐาน ได้แก่ฟังก์ชัน Rastrigin 10 มิติ ตัวอย่างผลที่ได้จากกรณีศึกษาการทดสอบประสิทธิภาพของวิธีการค้นหาแบบนกกาเหว่า

#### การทดสอบด้วยฟังก์ชัน (Test Cost functions)

ฟังก์ชันที่ใช้เปรียบเทียบหาค่าตอบของปัญหามีดังนี้

Function F1: Rastrigin

$$f = x \times \sin(4x) + 1.1y \times \sin(2y)$$

$$f = x \times \sin(4x) + \sin(2y)$$

$$0 < x, y < 10, \text{ minimum: } f(9.039) = 8.5547$$

Function F2: Rastrigin

$$f = 0.5 + \frac{\sin^2(\sqrt{x^2+y^2}-0.5)}{1+0.1(x^2+y^2)}$$

$$0 < x, y < 2, \text{ minimum: } f(0.05) = 0.5$$

Function F3: Rastrigin

$$f = (a^2 + b^2)^{0.25} \times \sin\{30 [(x + 0.5)^2 + y^2]^{0.1}\} + |x| + |y|$$

$$-\infty < x, y < +\infty, \text{ minimum: } f(-0.02) = -0.2471$$

Function F4: Rastrigin

$$f = j_0(x^2 + y^2) + 0.1|1 - x| + 0.1|1 - y|$$

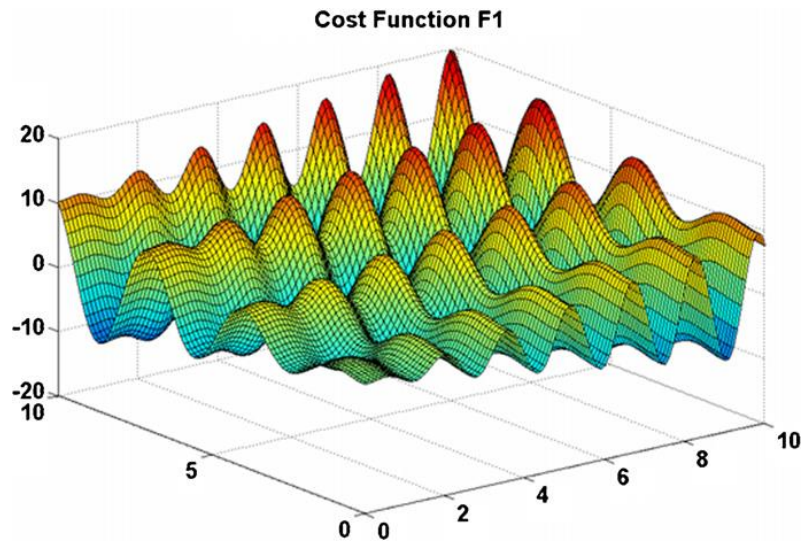
$$-\infty < x, y < +\infty, \text{ minimum: } f(1, 1.6606) = -0.3356$$

Function F5: Rastrigin

$$f = 10n + \sum_{i=1}^n (x_i^2 - 10 \cos(2\pi x_i)), n = 9$$


$$-5.12 \leq x_i \leq 5.12, f(0, 0, \dots, 0) = 0$$

ฟังก์ชันที่ 1 (F1) ฟังก์ชันนี้มี global minimum of  $-18.5547$  at  $(x, y) = (9.039, 8.668)$  in Interval  $0 < x, y < 10$ . ภาพที่ 2.6 กราฟของฟังก์ชันในรูปแบบ 3D



ภาพที่ 2-6 3D Plot of Cost Function F1 (Rajabioun, 2011)


จำนวนเริ่มต้นของนกกาเหว่าตั้งไว้เฉพาะที่ 20 นกแต่ละตัวสามารถวางไข่ได้ระหว่าง 5 และ 10 ฟอง ภาพที่ 2.6 กระจายเริ่มต้นของนกกาเหว่าในสภาพแวดล้อมของปัญหา ภาพที่ 2.7-2.12 ถิ่นที่อยู่อาศัยของประชากรนกกาเหว่าในผลลัพธ์เนื่องมาจากการวนซ้ำ (Rajabioun, 2011)



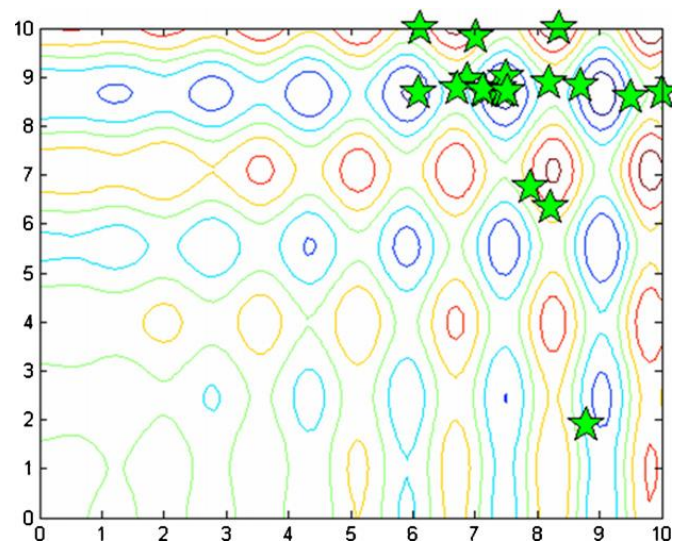
ภาพที่ 2-7 Initial Habitats of Cuckoos, (Rajabioun, 2011)

การลู่เข้าหาผลลัพธ์จะเกิดขึ้นที่การวนซ้ำรอบที่ 7 เช่นเดียวกับกับ Cuckoo Optimization Algorithm (COA) และ Global Minimum ดังจะเห็นได้จากภาพที่ 2-7 ถึง 2-12 นกกาเหว่าจะพบ Minima 2 ครั้งในรอบที่ 4 จากนั้นจะนกกาเหว่าจำนวนหนึ่งอพยพไปยัง Global Minimum ในรอบที่ 5 ส่วนรอบที่ 6 นกกาเหว่าส่วนใหญ่เข้าสู่ Global Minimum และสุดท้ายนกกาเหว่าทุกตัวอยู่ใกล้ถิ่นที่อยู่ที่ดีที่สุดในรอบที่ 7 เรียกตำแหน่งนี้ว่าคำตอบของปัญหา (Global

Minimum of the Problem) มีค่า Habitat คือ 9.0396 และ 8.6706 และมีค่า Cost Value เท่ากับ  $-18.5543$




ภาพที่ 2-8 Habitats of Cuckoos in 2nd Iteration, (Rajabioun, 2011)




ภาพที่ 2-9 Habitats of Cuckoos in 3rd Iteration, (Rajabioun, 2011)

การเปรียบเทียบระหว่าง PSO กับ GA แบบ Crossover โดยใช้การสุ่มจากวงล้อรูเล็ต กำหนดได้ประชากรเริ่มต้นเท่ากับ 20 มิวเทชันและซีเลคชันคือ 0.2 และ 0.5 ตามลำดับ






ภาพที่ 2-10 Habitats of Cuckoos in 4th Iteration, (Rajabioun, 2011)




ภาพที่ 2-11 Habitats of Cuckoos in 5th Iteration, (Rajabioun, 2011)




ภาพที่ 2-12 Habitats of Cuckoos in 6th Iteration, (Rajabioun, 2011)

กำหนดค่าพารามิเตอร์ทั้งทางปัญญาและทางสังคมไว้ที่ 2 เนื่องจากความแตกต่างกันของประชากรเริ่มต้นของแต่ละวิธีจะส่งผลกระทบต่อผลลัพธ์สุดท้ายและความเร็วของอัลกอริทึมสามารถดำเนินการทดสอบด้วยชุดของฟังก์ชันการทดสอบด้วยการพิจารณาจากค่าเฉลี่ยของประสิทธิภาพในการดำเนินงานของแต่ละวิธี



ภาพที่ 2-13 Habitats of Cuckoos in 7th Iteration, (Rajabioun, 2011)





ภาพที่ 2-14 3D Plot of Rastrigin Function, (Rajabioun, 2011)

ผลการทดสอบด้วยฟังก์ชัน F1, F2, F3 และ F4 แสดงให้เห็นว่าทั้งสามวิธีสามารถเข้าถึง Global Minimum แต่ที่น่าสนใจคือการลู่เข้าหา Cuckoo Optimization Algorithm (COA) ได้อย่างรวดเร็วกว่าอีกสองวิธีและแสดงให้เห็นว่ามีศักยภาพเหนือกว่าทั้ง GA และ PSO โดยเลือกฟังก์ชัน F5 มาทดสอบ 10-Dimensional Rastrigin Function เป็นฟังก์ชันที่มี Local Minima และเป็นหนึ่งในปัญหาที่แก้ได้ยาก (Rajabioun, 2011; Yang & S, 2011; Valian & Valian, 2012) การศึกษาวิจัยของ Lim et al. (2014) ได้นำ Algorithm Cuckoo Search with Genetic Algorithm (อัลกอริทึมผสมผสาน CSGA) ไปใช้ในการหาเส้นทางที่เหมาะสมสำหรับ Printed Circuit Board (PCB) กระบวนการชุดเจาะหลุม อัลกอริทึมผสมผสาน CSGA แสดงให้เห็นว่าสามารถหาค่าที่เหมาะสมเป็นไปด้วยความรวดเร็ว จึงมีแนวคิดที่จะเพิ่มจุดและตำแหน่งของการไฮบริดระหว่างวิธีการค้นหาของนกกาเหว่า (CS) และเจเนติกอัลกอริทึม (GA) เพิ่มประสิทธิภาพของขั้นตอนวิธี

#### งานวิจัยที่เกี่ยวข้องกับวิธีการค้นหาแบบนกกาเหว่า

Rajabioun (2011) ได้นำเสนออัลกอริทึมวิวัฒนาการที่เหมาะสมสำหรับการหาผลลัพธ์ที่เหมาะสมจากปัญหาที่ไม่เป็นเชิงเส้น โดยวิธีการหาผลลัพธ์ที่เหมาะสมนี้อาศัยแรงบันดาลใจจากชีวิตของครอบครัวนกกาเหว่า มีความพิเศษในวิถีการดำเนินชีวิต ลักษณะในการวางไข่และการปรับปรุงพันธุ์เป็นแรงจูงใจพื้นฐานที่ได้รับสำหรับการพัฒนาอัลกอริทึมนกกาเหว่าขึ้นมาโดยมีลักษณะคล้ายกับวิธีการวิวัฒนาการอื่น ๆ การหาผลลัพธ์ที่เหมาะสมแบบนกกาเหว่า (COA) เริ่มต้นด้วยการกำหนดประชากรเริ่มต้น ประชากรของนกกาเหว่ามีความแตกต่างกันโดยสามารถจำแนกออกได้สองประเภทคือ นกกาเหว่าที่โตเต็มวัยและไข่ของนกกาเหว่า สำหรับความพยายามในการอยู่รอดของนกกาเหว่านั้นนับได้ว่าเป็นพื้นฐานสำคัญของวิธีการหาค่าที่เหมาะสมแบบนกกาเหว่า อย่างไรก็ตามยังนกกาเหว่าที่โตเต็มวัยหรือไข่ของนกไม่สามารถอยู่รอดได้ในสังคมแห่งการแข่งขันเพื่อความอยู่รอด มีนกกาเหว่าบางส่วนอพยพไปยังสภาพแวดล้อมที่ดีกว่า มีการแข่งขันน้อยกว่า และเริ่มต้นวางไข่เพื่อขยายเผ่าพันธุ์ ความพยายามอยู่รอดของนกกาเหว่านั้น คือการลู่เข้าหาสังคมของนกกาเหว่าเพื่อรวมเป็นสังคม

เดียวกันโดยส่วนใหญ่มีจุดมุ่งหมายและการแสวงหาผลตอบแทนเดียวกัน โดยสามารถทำการทดสอบประสิทธิภาพในการจัดการกับปัญหาหรือการหาผลลัพธ์ของอัลกอริทึมด้วยฟังก์ชันมาตรฐานและทดสอบด้วยข้อมูลจริง (Rajabioun, 2011)

Kanagaraj, Ponnambalam, and Lim (2014) ได้ศึกษาการนำไฮบริดระหว่างอัลกอริทึมนกกาเหว่ากับเจเนติกอัลกอริทึม (Hybrid Algorithm Cuckoo Search with Genetic Algorithm: CSGA) ไปใช้ในการหาเส้นทางที่เหมาะสมสำหรับ Printed Circuit Board (PCB) กระบวนการชุดเจาะหลุม ไฮบริด CSGA แสดงให้เห็นว่าสามารถหาผลลัพธ์ได้ใกล้เคียงและรวดเร็วกว่า CS และ GA ทั้งปัญหาขนาดเล็กและขนาดใหญ่ นอกจากนี้ CSGA มีจำนวนพารามิเตอร์ที่ต้องปรับค่อนข้างน้อย มีเพียงพารามิเตอร์พื้นฐานคือขนาดประชากรและจำนวนรุ่นเท่านั้นเกณฑ์การหยุดสามารถเลือกปรับให้เหมาะสม เพื่อความสมดุลระหว่างเวลาและวิธีการแก้ปัญหาที่มีคุณภาพที่ต้องการด้วยผู้ใช้ โดยสามารถตั้งค่าอย่างใดอย่างหนึ่งจำนวนสูงสุดของรุ่นหรือหยุดถ้าอัลกอริทึมไม่มีการเปลี่ยนแปลงในการแก้ปัญหาที่ในรุ่นต่อ ๆ ไป การกำหนดขนาดของประชากรจะขึ้นอยู่กับขนาดของปัญหาและลักษณะเฉพาะของ CSGA เหล่านี้ทำให้อัลกอริทึมง่ายต่อการดำเนินการและนำไปใช้งานด้านวิศวกรรม (Kanagaraj, Ponnambalam, & Lim, 2014)

Ljouad, Amine, and Rziza (2014) ได้ศึกษาอัลกอริทึมวิวัฒนาการมักเกิดจากแรงขับเคลื่อนจากพฤติกรรมทางธรรมชาติของสัตว์แต่ละชนิด จนนำไปสู่พฤติกรรมการบิน การบิน และวิธีที่ใช้ในการสื่อสาร วิธีหนึ่งในกลุ่มเมตาฮิวริสติกอัลกอริทึมที่มีประสิทธิภาพมากที่สุด และสามารถใช้สำหรับพื้นที่ค้นหาที่ไม่ต่อเนื่องได้แก่วิธีการค้นหาแบบนกกาเหว่าโดยอาศัยพฤติกรรมการบินผสมผสานกับรูปแบบของ Lévy flight ที่พัฒนามาจากสัตว์และแมลงต่าง ๆ วิธีการเพิ่มประสิทธิภาพการทำงานของวิธีการค้นหาแบบนกกาเหว่าก็มีหลายวิธี การนำไปผสมผสานกับตัวกรองกาลมานเป็นอีกวิธีหนึ่งที่มีความนิยม โดยนำวิธีการค้นหาแบบนกกาเหว่าที่ผ่านการพัฒนาแล้วไปผสมผสานกับตัวกรองกาลมานในขั้นตอนของการทำนาย ด้วยการปรับปรุงคุณภาพของประชากรเริ่มต้น การใช้วิธีการผสมผสานกาลมานร่วมกับการค้นหาแบบนกกาเหว่า สามารถเพิ่มประสิทธิภาพในการค้นหาพื้นที่อยู่อาศัยในตำแหน่งที่เป็นไปตามวัตถุประสงค์ ด้วยการพัฒนาตัวแบบ Lévy flight ด้วยวิธีการผสมผสานวิวัฒนาการแบบกาลมานได้มีการนำไปทดสอบกับชุดข้อมูลที่หลากหลายเช่น Caviar SPEVI และอื่น ๆ เมื่อนำผลไปเปรียบเทียบกับวิธีการหาผลลัพธ์แบบกลุ่มอนุภาค (Particle Swarm Optimization) ปรากฏว่าวิธีการผสมผสานแบบกาลมานมีประสิทธิภาพเหนือกว่าวิธีการหาผลลัพธ์แบบกลุ่มอนุภาค โดยเฉพาะความรวดเร็วในการคำนวณ (Ljouad, Amine, & Rziza, 2014)

Li and Yin (2015) ได้ศึกษาวิธีการค้นหาแบบนกกาเหว่าซึ่งเป็นวิธีที่มีความเรียบง่ายและมีประสิทธิภาพการหาผลลัพธ์ในระดับสากลที่ค่อนข้างดี นิยมนำไปใช้ในการหาผลลัพธ์ในสถานการณ์จริงกันอย่างแพร่หลาย บทความนี้ได้นำเสนอการพัฒนาวิธีการใหม่ที่อาศัยหลักการพื้นฐานจากกฎของการผ่าเหล่าเพื่อหาค่าที่ดีที่สุดเฉพาะตัวจากประชากรทั้งหมด เพื่อความสมดุลของการแสวงหาผลประโยชน์และการสำรวจของอัลกอริทึมจึงได้นำกฎของการผ่าเหล่ามาผสมผสานกับหลักการเชิงเส้นเพื่อปรับลดอิทธิพลของกฎความน่าจะเป็น จากนั้นปรับค่าพารามิเตอร์ด้วยตนเองด้วยวิธีการสุ่มค่าอย่างสม่ำเสมอเพื่อเพิ่มความหลากหลายให้แก่ประชากร ซึ่งมีความสัมพันธ์กับความสำเร็จของพารามิเตอร์ใหม่ทั้งสองที่นำเสนอใหม่ในช่วงก่อนหน้า ทดสอบประสิทธิภาพการทำงานของ SACS

ด้วยฟังก์ชันมาตรฐานจำนวน 16 ฟังก์ชัน ทำการคัดเลือกโดยอาศัยข้อมูลจากเอกสารทางวิชาการ ผลการทดสอบแสดงให้เห็นว่าประสิทธิภาพของวิธีการดำเนินการที่ดีกว่าหรืออย่างน้อยก็สามารถเปรียบได้กับวิธีการที่ได้จากการรวบรวมข้อมูล เมื่อพิจารณาถึงคุณภาพของการแก้ปัญหาที่ได้รับ ในส่วนสุดท้ายการทดลองได้รับการดำเนินการเกี่ยวกับระบบ Lorenz และ Chen ทั้งสองระบบใช้การประมาณพารามิเตอร์ด้วย Chaotic ผลการจำลองแสดงให้เห็นเพิ่มเติมว่าที่วิธีการนำเสนออันนี้มีประสิทธิภาพมาก (Li & Yin, 2015)

Amiri and Mahmoudi (2016) ได้ศึกษาการจัดกลุ่มข้อมูลเป็นเทคนิคสำหรับจัดกลุ่มข้อมูลที่เหมือนและไม่เหมือนไว้ด้วยกัน อัลกอริทึมจำนวนมากล้มเหลวในการจัดกลุ่มเมื่อมีการดำเนินการร่วมกับข้อมูลประเภทหลายมิติ บทความนี้ได้นำเสนอวิธีการจัดกลุ่มที่มีประสิทธิภาพด้วยวิธีการหาผลลัพท์แบบนกกาเหว่า (Cuckoo Optimization Algorithm: COAC) โดยนำไปพัฒนาด้วยวิธีการผสมผสานระหว่างวิธีการค้นหาแบบนกกาเหว่ากับวิธีฟัซซี (Fuzzy Cuckoo Optimization Algorithm: FCOAC) วิธีการหาผลลัพท์แบบนกกาเหว่าได้รับแรงบันดาลใจจากการดำเนินชีวิตของกาเหว่าเพื่อแก้ปัญหาที่ไม่มีความต่อเนื่อง วิธีการแบบเมตาฮิวริสติกนี้ยังมีความเหมาะสมกับการจัดกลุ่มข้อมูลที่มีขนาดใหญ่และหาผลลัพท์ที่เหมาะสมด้วยฟัซซีลอจิก โดยเริ่มต้นด้วยการสร้างสมการแก้ปัญหาแบบสุ่มจากประชากรนกกาเหว่าและชุดข้อมูลตามเป้าหมายและคำนวณต้นทุนของฟังก์ชันจากแต่ละปัญหา ขั้นตอนสุดท้ายหาผลลัพท์ที่เหมาะสมด้วยฟัซซีลอจิกและเปรียบเทียบประสิทธิภาพด้วยการประเมินและเปรียบเทียบกับ COAC, Black hole, CS, K-mean, PSO และ GSA ปรากฏว่าอัลกอริทึม FCOAC ที่ให้ผลการหาผลลัพท์ที่เหมาะสมที่สุด (Amiri, and Mahmoudi, 2016)

อัลกอริทึมวิวัฒนาการส่วนใหญ่แล้วเกิดจากแรงขับเคลื่อนจากพฤติกรรมทางธรรมชาติของสัตว์แต่ละชนิด วิธีการค้นหาแบบนกกาเหว่าเป็นวิธีหนึ่งในกลุ่มเมตาฮิวริสติกอัลกอริทึมที่มีประสิทธิภาพสูงมาก สามารถนำไปใช้กับพื้นที่ค้นหาที่ไม่ต่อเนื่องได้ (ข้อมูลไม่ต่อเนื่อง) โดยอาศัยพฤติกรรมการสืบพันธุ์ผสมผสานกับรูปแบบของ Lévy flight ที่พัฒนามาจากสัตว์และแมลงต่าง ๆ (Ljouad, Amine, & Rziza, 2014) ในการนำไปใช้นั้นควรมีการปรับปรุงหรือพัฒนาให้มีความเหมาะสมกับลักษณะของงาน เช่น Ljouad, Amine, and Rziza (2014) ได้ทำการพัฒนาตัวแบบ Lévy flight ด้วยวิธีการผสมผสานแบบคาลมานได้มีการนำไปทดสอบกับชุดข้อมูลที่หลากหลายได้แก่ Caviar SPEVI และอื่น ๆ ต่อมา Amiri and Mahmoudi (2016) วิธีการผสมผสานระหว่างวิธีการค้นหาแบบนกกาเหว่ากับวิธีฟัซซี (Fuzzy Cuckoo Optimization Algorithm: FCOAC) ต่อมา Li and Yin (2015) ได้ศึกษาวิธีการค้นหาแบบนกกาเหว่าผสมผสานกับเจเนติกอัลกอริทึมโดยอาศัยกฎการผ่าเหล่า

การพัฒนาวิธีการค้นหาแบบนกกาเหว่าสามารถจำแนกได้เป็น 2 แนวทางด้วยกัน ได้แก่ วิธีการปรับปรุงอัลกอริทึมและวิธีการผสมผสานอัลกอริทึม สำหรับวิธีการปรับปรุงอัลกอริทึมนั้นเป็นวิธีที่ยากและมีความซับซ้อนตรงข้ามกับวิธีการผสมผสานนั้นได้รับความนิยมนำไปในงานวิจัยอย่างมาก เนื่องจากวิธีการการปรับปรุงนั้นมีขั้นตอนการดำเนินงานที่เรียบง่ายและกับมีจำนวนพารามิเตอร์ที่ต้องปรับค่าน้อย วิธีการผสมผสานระหว่างวิธีการค้นหาแบบนกกาเหว่ากับอัลกอริทึมที่มีจุดเด่นมาเสริมจุดด้อยของอัลกอริทึมหลัก ทั้งนี้เพื่อเป็นการปรับปรุงประสิทธิภาพในการหาค่าที่เหมาะสมของอัลกอริทึมผสมผสาน CSGA แต่ภายใต้วิธีการที่เรียบง่ายนั้นกลับให้ผลต่อการเพิ่มประสิทธิภาพของอัลกอริทึมได้ค่อนข้างดี สอดคล้องกับผลการศึกษาวิจัยของ Oysu และ Bingul จากงานวิจัยแสดง

ให้เห็นว่ามีประสิทธิภาพเหนือกว่าวิธีการหาค่าผลลัพธ์แบบนกกกว่ามาตรฐาน ทั้งในด้านความแม่นยำและความรวดเร็วในการคำนวณประมาณ 1.5% และ 47% เมื่อเทียบกับวิธีเจเนติกอัลกอริทึมและอัลกอริทึมการค้นหาของนกกว่ามาตรฐาน (Oysu & Bingul, 2009)

## ตอนที่ 2 วิธีการหาค่าที่เหมาะสมของเจเนติกอัลกอริทึม (Genetic Algorithm) และงานวิจัยที่เกี่ยวข้อง

เจเนติกอัลกอริทึม (Genetic Algorithm) เป็นวิธีการค้นหาผลลัพธ์ที่ดีที่สุด (ค่าที่เหมาะสม) โดยใช้หลักการคัดเลือกแบบธรรมชาติและหลักการทางสายพันธุ์ เจเนติกอัลกอริทึมเป็นวิธีการคำนวณโดยมีการประยุกต์หลักเข้ากับหลักวิวัฒนาการของสิ่งมีชีวิต เข้าไปในขั้นตอนของการค้นหาคำตอบ และได้รับการจัดให้อยู่ในกลุ่มของวิธีการคำนวณเชิงวิวัฒนาการ (Evolutionary Computing) เมื่อคอมพิวเตอร์มีความสามารถในการคำนวณเพิ่มมากขึ้น วิธีการดังกล่าวจึงถูกจัดให้อยู่ในกลุ่มเมตาฮีริสติก ปัจจุบันเป็นที่ยอมรับกันว่าวิธีการแบบเมตาฮีริสติกมีประสิทธิภาพสูงมากและมีการนำไปประยุกต์ใช้อย่างกว้างขวางในการแก้ปัญหาหรือการหาค่าที่เหมาะสมที่สุด

เจเนติกอัลกอริทึมหรือเรียกโดยย่อว่า “GA” ได้รับการพัฒนาขึ้นในช่วงทศวรรษที่ 60 โดยจำลองแนวคิดด้านทฤษฎีการวิวัฒนาการของสิ่งมีชีวิตในระบบชีววิทยามาใช้ในการคำนวณด้วยคอมพิวเตอร์ เจเนติกอัลกอริทึมได้รับความนิยมและเป็นที่ยอมรับกันอย่างกว้างขวาง ด้วยการเผยแพร่ของ Holland (1975) ในหนังสือชื่อ "Adaptation in Natural and Artificial Systems" โดยตีพิมพ์เป็นครั้งแรก ในปี ค.ศ. 1975 หลังจากนั้นจึงมีการนำวิธีเจเนติกอัลกอริทึมไปประยุกต์กับงานในด้านต่าง ๆ กันอย่างแพร่หลาย (Holland & Goldberg, 1989; Holland, 1975) จากนั้นจึงมีการศึกษาและพัฒนาองค์ประกอบต่าง ๆ ของเจเนติกอัลกอริทึมให้มีประสิทธิภาพดียิ่งขึ้น เจเนติกอัลกอริทึมถือว่าเป็นวิธีการค้นหาผลลัพธ์ที่เหมาะสมที่สุดเชิงผสมผสาน (Combinatorial Optimization) แบบปัญญาเชิงคำนวณที่มีความสามารถในการค้นหาคำตอบอย่างชาญฉลาดและลดความยุ่งยากในขั้นตอนต่าง ๆ ของการค้นหาลงไป ซึ่งวิธีการค้นหาคำตอบดังกล่าวนี้มีข้อได้เปรียบและความแตกต่างไปจากวิธีดั้งเดิม เช่น การโปรแกรมเชิงเส้น วิธีซิมเพล็กซ์ และวิธีการค้นหาผลเฉลยรูปแบบปิด ในปัจจุบันเจเนติกอัลกอริทึมได้รับความนิยมนำไปใช้ในเกือบทุกสาขาวิชา นอกจากนี้ เจเนติกอัลกอริทึมยังได้นำไปใช้ร่วมกับเครื่องมืออื่น ๆ ได้อย่างมีประสิทธิภาพ เช่น ระบบฟัซซีลอจิก ระบบที่ใช้เวฟเล็ต ระบบเครือข่ายประสาทเทียม เป็นต้น จะเห็นได้ว่าประสิทธิภาพและสมรรถนะของเจเนติกอัลกอริทึมนี้ยอมรับกันว่าเป็นวิธีที่มีประสิทธิภาพสูงจนมีการนำไปใช้กันอย่างแพร่หลาย

เจเนติกอัลกอริทึมเป็นวิธีการหาค่าที่เหมาะสมแบบเฟ้นสุ่มโดยเลียนแบบหลักการถ่ายทอดทางพันธุกรรมของธรรมชาติ เพื่อหาค่าที่เหมาะสมโดยรวมได้อาศัยการสมมุติจุดคำตอบขึ้นมาหลาย ๆ จุดก่อน แล้วประยุกต์หลักการค้นหาจุดที่เหมาะสมที่สุด ซึ่งเป็นจุดที่มีโอกาสที่จะอยู่รอดมากที่สุดเพื่อหาคำตอบที่ดียิ่งขึ้นในแต่ละรุ่นของการถ่ายทอดทางพันธุกรรมสำหรับในแต่ละรุ่นของการถ่ายทอดจะมีการประเมินความเหมาะสมของจุดคำตอบแต่ละจุด แล้วพิจารณาเลือกจุดคำตอบใหม่จากค่าความเหมาะสมนี้โดยอาศัยวิธีการทางพันธุศาสตร์มาประยุกต์ใช้ในเจเนติกอัลกอริทึม ขั้นตอนของเจเนติกอัลกอริทึมประกอบด้วยการรีโพรดักชัน การครอสโอเวอร์และการผ่าเหล่า จุดคำตอบแต่

ละจุด ประกอบด้วยสายอักขระของตัวแปรที่ถูกใส่รหัสไว้เรียกว่า โครโมโซมหรือจีโนม ซึ่งสามารถถอดรหัสเป็นค่าของตัวแปรจริงได้ โดยทั่วไปนิยมใส่รหัสตัวแปรให้เป็นเลขฐานสอง

### พันธุศาสตร์กับเจเนติกอัลกอริทึม

Mendel เป็นนักวิทยาศาสตร์ด้านพันธุศาสตร์ที่ค้นพบว่า ลักษณะต่าง ๆ ของสิ่งมีชีวิต เช่น ลักษณะผิวของเมล็ดพืช สีของเมล็ดพืช ฯลฯ ที่ถ่ายทอดไปยังลูกหลานนั้น ถูกควบคุมโดยหน่วยควบคุมลักษณะที่เรียกว่า ยีนส์ และลักษณะย่อยของยีนส์ เรียกว่าอัลลีล เช่น ยีนส์ควบคุมลักษณะผิวของเมล็ดจะมีอัลลีลเป็นผิวเรียบและผิวขรุขระเป็นต้น ซึ่งแต่ละยีนส์จะเรียงตัวอยู่บนโครโมโซมภายในเซลล์ตำแหน่งของยีนส์แต่ละยีนส์บนโครโมโซม เรียกว่า โลกัส แต่ละแบบของชุดยีนส์เรียกว่า จีโนไทป์ ซึ่งแสดงลักษณะภายนอกที่ปรากฏหรือที่เรียกว่า ฟิโนไทป์ เมื่อเปรียบเทียบเจเนติกอัลกอริทึมกับพันธุศาสตร์แล้ว สายอักขระแบบทวิภาคเทียบได้กับ โครโมโซม จีโนไทป์และออแกนิซึมหรือรวมทั้งฟีโนไทป์ที่เกิดจากการขยายนิพจน์ของจีโนไทป์ภายใต้สภาวะแวดล้อม

ตารางที่ 2-1 การเปรียบเทียบคำศัพท์ระหว่างพันธุศาสตร์กับเจเนติกอัลกอริทึม

พันธุศาสตร์	เจเนติกอัลกอริทึม
โครโมโซม	สายอักขระ
ยีนส์	ลักษณะ (บิต)
โลกัส	โครงสร้าง
จีโนไทป์	โครงสร้างคำตอบ

จากหลักการของเจเนติกอัลกอริทึม สามารถสรุปถึงแนวทางที่แตกต่างระหว่างการหาค่าที่เหมาะสมโดยใช้เจเนติกอัลกอริทึมกับการหาค่าที่เหมาะสมวิธีอื่น ๆ ดังนี้

1. เจเนติกอัลกอริทึมใช้รหัสของตัวแปรเป็นเครื่องมือในการหาค่าที่เหมาะสม แทนที่จะใช้ค่าของตัวแปรโดยตรง ดังนั้นวิธีนี้จึงสะดวกในการแก้ปัญหาเกี่ยวกับตัวแปรชนิดใดก็ได้ ซึ่งตัวแปรนั้นไม่จำเป็นต้องต่อเนื่อง
2. เจเนติกอัลกอริทึมเป็นวิธีการหาค่าที่เหมาะสมจากจุดเริ่มต้นหลาย ๆ จุด เป็นการหาจุดที่เหมาะสมโดยรวม โดยเทคนิคการหาค่าความเหมาะสมแบบขนาน ทำให้คำตอบที่ได้เป็นค่าที่ใกล้เคียงกับค่าความเหมาะสมโดยรวม
3. เจเนติกอัลกอริทึมใช้ข้อมูลเพียงแค่ว่าฟังก์ชันเป้าหมายเท่านั้น ดังนั้นวิธีนี้สามารถใช้กับฟังก์ชันเป้าหมายได้ทุกชนิด โดยที่ฟังก์ชันเป้าหมายไม่จำเป็นต้องต่อเนื่องหรือสามารถหาอนุพันธ์ได้
4. เจเนติกอัลกอริทึมใช้ทฤษฎีความน่าจะเป็นในการหาคำตอบ

### การใส่รหัสและถอดรหัส

เนื่องจากเจเนติกอัลกอริทึมใช้รหัสของตัวแปรในการหาค่าที่เหมาะสม ดังนั้นถ้าเลือกวิธีใส่รหัสที่เหมาะสมย่อมทำให้เจเนติกอัลกอริทึมมีประสิทธิภาพดีขึ้น โดยทั่วไปนิยมใช้เลขฐานสอง (0

และ 1) เป็นส่วนประกอบของสายอักขระในการใส่รหัสความยาวของสายอักขระ เป็นตัวกำหนดความละเอียดของตัวแปรที่เราต้องการ ตัวอย่างเช่น ตัวแปรต่อเนื่อง  $x$  มีค่าอยู่ในช่วง  $-1$  ถึง  $2$  และต้องการความละเอียดถึงทศนิยมตำแหน่งที่ 6 ดังนั้นในช่วงตัวแปร  $-1$  ถึง  $2$  จึงควรถูกแบ่งเป็นช่วงอย่างน้อย  $(2 - (-1)) * 1,000,000 = 3,000,000$  ช่วงย่อย ๆ นั้น หมายถึง ต้องใช้สายอักขระที่มีความยาว 22 บิต

$$2097152 = 2^{21} < 3000000 < 2^{22} = 4194304$$

วิธีการถอดรหัสจากสายอักขระให้เป็นค่าจริงของตัวแปรนั้น สามารถทำได้ 2 ขั้นตอนดังต่อไปนี้

1. แปลงจากเลขฐานสอง  $\langle b_{21} b_{20} \dots b_0 \rangle$  ให้เป็นเลขฐานสิบซึ่งมีค่า  $x$  โดยอาศัยสมการ

$$x = \sum_{i=0}^{21} b_i \times 2^i$$

2. หาค่าจริงของตัวแปร  $x$  จากการประมาณค่าในช่วง ด้วยสมการ

$$x = -1.0 + x' \times \left[ \frac{2 - (-1)}{2^{22} - 1} \right]$$

โดยกำหนดให้  $-1$  คือ ขอบล่างของตัวแปร และ  $2$  คือ ขอบบนของตัวแปร การกำหนดประชากรเริ่มต้นโดยทั่วไปนิยมกำหนดประชากรเริ่มต้นโดยการสุ่มเลือกจำนวนสายอักขระเท่ากับจำนวนประชากรทั้งหมด

เจเนติกอัลกอริทึมเจเนติกอัลกอริทึมเป็นขั้นตอนในการค้นหาคำตอบให้กับระบบเจเนติกอัลกอริทึม (GA) นับว่าเป็นเครื่องมือในการช่วยคำนวณอย่างหนึ่งที่ทำงานให้กับระบบ สำหรับวิวัฒนาการของเจเนติกอัลกอริทึม (GA) โดยธรรมชาติแล้วประกอบไปด้วย 3 กระบวนการที่สำคัญ

1. การคัดเลือกสายพันธุ์ (Selection) คือขั้นตอนในการคัดเลือกประชากรที่ดีในระบบสำหรับนำไปเป็นต้นกำเนิดสายพันธุ์ เพื่อให้กำเนิดลูกหลานในรุ่นถัดไป

2. ปฏิบัติการทางสายพันธุ์ (Genetic Operation) คือกรรมวิธีการเปลี่ยนแปลงโครโมโซมด้วยวิธีการทางสายพันธุ์ เป็นขั้นตอนการสร้างลูกหลานรุ่นใหม่ ด้วยการรวบรวมพันธุ์ของต้นกำเนิดสายพันธุ์ ทั้งนี้เพื่อให้ได้ลูกหลานที่มีส่วนผสมผสานมาจากพ่อแม่หรือได้จากการแปรผันยีนส์ของพ่อแม่ที่เป็นพื้นฐานสำคัญต่อการสร้างลูกหลานสายพันธุ์ใหม่

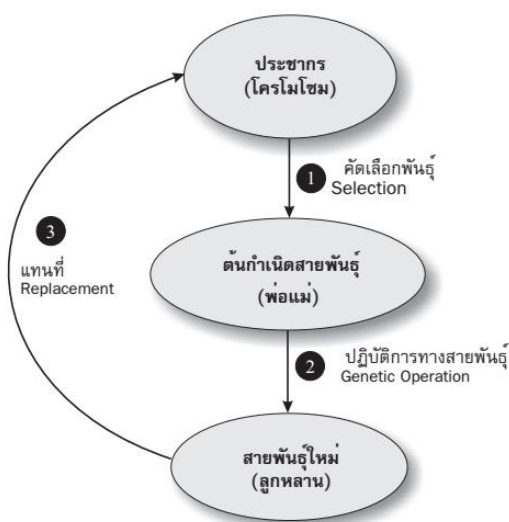
3. การแทนที่ (Replacement) คือขั้นตอนการนำเอาลูกหลานกำเนิดใหม่ไปแทนที่ประชากรเก่าในรุ่นก่อนเป็นขบวนการในการคัดเลือกกว่าควรจะเอาลูกหลานในกลุ่มใด จำนวนเท่าไรไปแทนประชากรเก่าในกลุ่มใด วิวัฒนาการของเจเนติกอัลกอริทึมแสดงให้เห็นถึงความเหมือนกับการอยู่รอดของสิ่งมีชีวิตในธรรมชาติ สิ่งมีชีวิตที่มีการปรับตัวให้เข้ากับสภาพแวดล้อมได้ดีกว่าจะสามารถอยู่รอดได้ ในขณะที่สิ่งมีชีวิตอื่น ๆ ที่ไม่สามารถปรับตัวเองได้จะต้องสูญพันธุ์ไป การปรับตัวดังกล่าวนี้แสดงให้เห็นว่า สิ่งมีชีวิตนั้นมีวิวัฒนาการตลอดเวลา ไดโนเสาร์ต้องสูญพันธุ์ไปจากโลกนี้ก็เนื่องมาจาก

การไม่มีวิวัฒนาการที่เพียงพอต่อการอยู่รอดในขณะที่มีชีวิตหลาย ๆ ชนิดในปัจจุบันที่วิวัฒนาการมาจากไดโนเสาร์และมีการปรับตัวให้สามารถอยู่ในสภาวะแวดล้อมที่เปลี่ยนแปลงไปได้ จึงสามารถรักษาเผ่าพันธุ์อยู่มาจนถึงปัจจุบันได้ เจเนติกอัลกอริทึมมีการจำลองวิวัฒนาการของสิ่งมีชีวิตในระบบธรรมชาติ กล่าวคือกระบวนการภายในของเจเนติกอัลกอริทึมทำให้คำตอบของระบบที่มีอยู่เกิดวิวัฒนาการในตัวเองอันจะนำไปสู่การปรับตัวให้กลายเป็นคำตอบที่ดีกว่าและดีที่สุดได้

ประชากร (Population) ประกอบด้วยกลุ่มของโครโมโซม (Chromosome) ซึ่งเป็นตัวแทนของคำตอบในระบบที่ต้องการค้นหา

ต้นกำเนิดสายพันธุ์ (Parents) กลุ่มประชากรที่ถูกคัดเลือกเพื่อเป็นตัวแทนในการให้กำเนิดสายพันธุ์ใหม่ในรุ่นถัดไป (Next Generation) ประชากรกลุ่มนี้จะเปรียบเสมือนกับเป็น ‘พ่อแม่’ สำหรับใช้ในการสืบทอดสายพันธุ์ให้ลูกหลานต่อไป

สายพันธุ์ใหม่ (Offspring) หรือ ลูกหลานเป็นประชากรกลุ่มใหม่ที่ได้รับการถ่ายทอดสายพันธุ์มาจากพ่อแม่ โดยคาดหวังที่จะได้รับสายพันธุ์ที่ดีที่สุดเพื่อถ่ายทอดต่อ ๆ กันในประชากรรุ่นถัดไป



ภาพที่ 2-15 วัฏจักรของ GA (สถาบันเทคโนโลยีพระจอมเกล้าพระนครเหนือ, 2559)

วิธีการทางพันธุศาสตร์ที่ใช้ประกอบด้วยการรีโพรดักชัน การครอสโอเวอร์และการผ่าเหล่า โดยจุดคำตอบแต่ละจุดประกอบไปด้วยสายอักขระของตัวแปรที่ใส่รหัสไว้เรียกว่าโครโมโซมหรือจีโนม ซึ่งสามารถถอดรหัสเป็นค่าของตัวแปรจริงได้ โดยทั่วไปนิยมใส่รหัสตัวแปรให้เป็นเลขฐานสอง

จากหลักการข้างต้นแสดงให้เห็นว่าการคำนวณหาค่าที่เหมาะสมโดยใช้เจเนติกอัลกอริทึม นั้นจะแตกต่างจากวิธีอื่น ๆ ดังนี้

1. เจเนติกอัลกอริทึมใช้รหัสของตัวแปรเป็นเครื่องมือในการหาค่าที่เหมาะสม แทนที่จะใช้ค่าของตัวแปรโดยตรง ดังนั้นวิธีนี้จึงสะดวกในการแก้ปัญหาเกี่ยวกับตัวแปรชนิดใดก็ได้ ซึ่งตัวแปรนั้นไม่จำเป็นต้องต่อเนื่อง

2. เจเนติกอัลกอริทึมเป็นวิธีการหาค่าที่เหมาะสมจากจุดเริ่มต้นหลาย ๆ จุด เป็นการหาจุดที่เหมาะสมโดยรวม โดยเทคนิคการหาค่าความเหมาะสมแบบขนาน ทำให้คำตอบที่ได้เป็นค่าที่ใกล้เคียงกับค่าความเหมาะสมโดยรวม

3. เจเนติกอัลกอริทึมใช้ข้อมูลเพียงแค่ว่าฟังก์ชันเป้าหมายเท่านั้น ดังนั้นวิธีนี้สามารถใช้กับฟังก์ชันเป้าหมายได้ทุกชนิด โดยที่ฟังก์ชันเป้าหมายไม่จำเป็นต้องต่อเนื่องหรือสามารถหาอนุพันธ์ได้

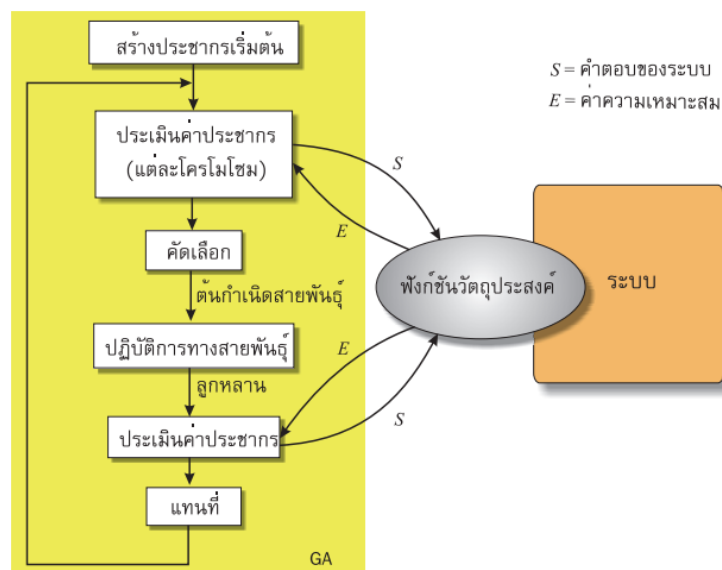
4. เจเนติกอัลกอริทึมใช้ทฤษฎีความน่าจะเป็นในการหาคำตอบ

ขั้นตอนการทำงานของเจเนติกอัลกอริทึม กระบวนการและขั้นตอนการทำงานของเจเนติกอัลกอริทึมมีขั้นตอนดังต่อไปนี้

#### ขั้นตอนการทำงานทั่วไปของเจเนติกอัลกอริทึม

1. สร้างประชากร โดยปกติจะใช้การสุ่ม (Random)

2. ประเมินค่าโครโมโซมของกลุ่มประชากรทั้งหมดด้วยฟังก์ชันวัตถุประสงค์ เนื่องจากระบบไม่สามารถเข้าใจค่าของโครโมโซมภายใน GA ดังนั้นโครโมโซมจะต้องผ่านการถอดรหัสก่อนที่จะนำไปทำการคำนวณด้วยฟังก์ชันวัตถุประสงค์ได้



ภาพที่ 2-16 ขั้นตอนทั่วไปของ GA กับการเชื่อมโยงเข้ากับระบบ (สถาบันเทคโนโลยีพระจอมเกล้าพระนครเหนือ, 2559)

3. คำนวณหาค่าความเหมาะสมแล้วส่งกลับไปยัง GA

4. ใช้ค่าความเหมาะสมทำการคัดเลือกโครโมโซมบางกลุ่ม เพื่อนำมาเป็นต้นกำเนิดสายพันธุ์ ซึ่งจะนำไปใช้เป็นตัวแทนในการถ่ายทอดสายพันธุ์ให้กับรุ่นถัดไป


5. นำต้นกำเนิดสายพันธุ์มาทำการสร้างลูกหลาน ด้วยปฏิบัติการทางสายพันธุ์ โครโมโซมที่ได้ในขั้นตอนนี้ก็คือ โครโมโซมลูกหลาน



6. คำนวณค่าความเหมาะสมของโครโมโซมลูกหลาน โดยใช้ขั้นตอนเดียวกับข้อ 3
7. โครโมโซมในประชากรเดิมจะถูกแทนที่ด้วยลูกหลานที่ได้จากข้อ 5 ประชากรเพียงบางส่วนเท่านั้นที่จะถูกแทนที่ด้วยกลวิธีเฉพาะสำหรับขั้นตอนของการแทนที่โดยใช้ค่าความเหมาะสมในการตัดสินใจ
8. เริ่มต้นทำซ้ำจากขั้นตอนในข้อ 2 ไปเรื่อย ๆ จนกระทั่งได้คำตอบที่ต้องการ คำตอบที่ได้จะมาจากโครโมโซมที่ดีที่สุดในกลุ่มประชากร โดยสามารถใช้ค่าจากฟังก์ชันวัตถุประสงค์สำหรับประเมินว่า คำตอบที่หาได้นั้นเป็นที่ต้องการแล้วหรือไม่ จากกระบวนการของเจเนติกอัลกอริทึมแสดงให้เห็นว่าสิ่งที่จำเป็นต้องทำสำหรับการออกแบบเพื่อนำเจเนติกอัลกอริทึมมาใช้ได้แก่ โครโมโซมประชากรและการเข้ารหัส การประเมินค่าความเหมาะสม การคัดเลือกต้นกำเนิดสายพันธุ์ ปฏิบัติการทางสายพันธุ์และการแทนที่



รูปที่ 3.3: คำตอบในมุมมองของ GA และโลกจริง



ภาพที่ 2-17 โครโมโซมที่เข้ารหัสแบบฐานสองจากคำตอบในระบบ (สถาบันเทคโนโลยีพระจอมเกล้าพระนครเหนือ, 2559)

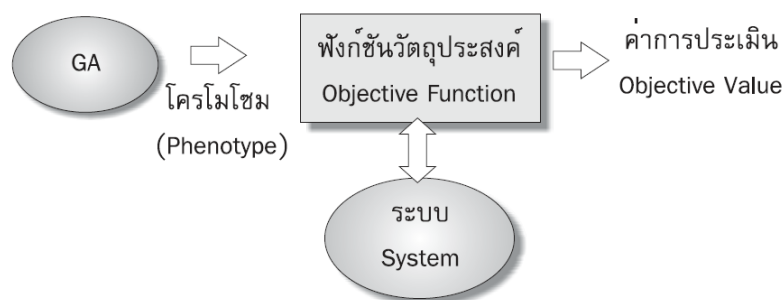
โครโมโซมประชากรและการเข้ารหัส (Population & Encoding Scheme) เจเนติกอัลกอริทึมพิจารณาคำตอบของปัญหาจากกลุ่มของคำตอบหรือประชากร (Population) ของคำตอบ แต่ละคำตอบจะมีคุณลักษณะเฉพาะตัวซึ่งแสดงอยู่ในรูปของโครโมโซม (Chromosome) หรือในรูปจีโนม (Genome) การเข้ารหัสประชากรเป็นขั้นตอนแรกและเป็นขั้นตอนที่สำคัญ เพราะเป็นการออกแบบให้โครโมโซมเป็นตัวแทนของคำตอบจากระบบในการใช้งานเจเนติกอัลกอริทึม รูปแบบที่ง่ายที่สุดคือการกำหนดให้โครโมโซมอยู่ในรูปของตัวแปรแบบสตริง (String of Variables)

$$s = [s_1, s_2, s_3, \dots, s_L]$$

โดยที่  $s$  คือโครโมโซมหนึ่ง ๆ และแต่ละ  $s_i, i = 1, 2, 3, \dots, L$  คือแต่ละตัวแปรในชุดคำตอบของระบบ (แต่ละระบบจะมีจำนวนตัวแปรไม่เท่ากัน ขึ้นอยู่กับลักษณะของปัญหา ความซับซ้อนและการออกแบบการแก้ปัญหาของระบบนั้น ๆ)

เมื่อพิจารณาโครโมโซมหนึ่ง ๆ เราสามารถมองได้ว่าเป็นการนำเอาคำตอบทั้งชุดของระบบมาวางเรียงต่อกันเป็น สายเจเนติกอัลกอริทึมจะมองโครโมโซมเป็นหนึ่งคำตอบ ประกอบไปด้วย

องค์ประกอบที่เรียกว่ายีน (Gene) ซึ่งในทางชีววิทยาถือว่าเป็นส่วนที่เก็บคุณลักษณะสำคัญของสิ่งมีชีวิตเอาไว้ เช่น สีของตาหรือผม เป็นต้น ดังนั้นโครโมโซมในเจเนติกอัลกอริทึม จึงเป็นที่เก็บคุณลักษณะของคำตอบของระบบเอาไว้ เพื่อใช้ในการสืบทอดสายพันธุ์กรรมให้ประชากรรุ่นถัดไป กระบวนการภายในของเจเนติกอัลกอริทึม จะมองคำตอบของระบบอยู่ในรูปของโครโมโซมที่เรียกว่า จีโนไทป์ (Genotype) รูปแบบ ดังกล่าวมีความแตกต่างจากรูปของตัวแปรที่เราสามารถเข้าใจได้ในระบบปกติที่เรียกว่า ‘ฟีโนไทป์’ (Phenotype) เช่น ตัวแปรชนิดจำนวนจริงหรือจำนวนเต็ม การเข้ารหัสจึงเป็นการจัดวางรูปแบบคำตอบของระบบให้อยู่ในรูปที่เจเนติกอัลกอริทึม สามารถเข้าใจและทำงานได้ด้วยตัวอย่างวิธีการเข้ารหัสวิธีหนึ่ง ก็คือแบบสายอักขระเลขฐานสอง (Holland, 1975) (Binary String Encoding) โครโมโซมได้มาจากการเรียงกันด้วยคำตอบของระบบแบบปิดต่อบิต วิธีการเข้ารหัสแบบนี้เป็นวิธีที่ง่ายและเป็นวิธีที่นิยมใช้กันทั่วไปวิธีหนึ่ง วิธีเข้ารหัสอื่น ๆ เช่น การเข้ารหัสแบบจำนวนเต็ม (Integer) และการเข้ารหัสแบบค่าจริง (Real-Valued Encoding) ฯลฯ ข้อดีของวิธีการเข้ารหัสทั้งสองแบบคือ สามารถเข้าใจและตรวจดูค่าได้ทันทีโดยไม่ต้องถอดรหัส ส่วนวิธีการเข้ารหัสแบบค่าจริงเป็นอีกวิธีหนึ่ง ที่มีข้อดีเหนือกว่าวิธีอื่น ๆ ในด้านการคำนวณเชิงตัวเลข อันเนื่องมาจากวิธีดังกล่าวสามารถใช้ตัวแปรแบบจำนวนจริงในการคำนวณโดยตรง จึงไม่มีการสูญเสียความละเอียดของตัวเลขแต่อย่างใดและสามารถใช้วิธีคำนวณที่หลากหลายกว่าต่อโครโมโซมได้โดยตรง



ภาพที่ 2-18 ฟังก์ชันวัตถุประสงค์กับการเชื่อมโยง GA เข้ากับระบบ (สถาบันเทคโนโลยีพระจอมเกล้าพระนครเหนือ, 2559)

วิธีการเข้ารหัสแต่ละวิธีจะมีคุณสมบัติที่ไม่เหมือนกันขึ้นอยู่กับปัจจัยหลาย ๆ อย่างเช่น ชนิดของคำตอบหรือวิธีการคำนวณในระบบ ฯลฯ โดยปกติแล้วถ้าเจเนติกอัลกอริทึมใช้โครโมโซมที่อยู่ในรูปของฟีโนไทป์ ไม่จำเป็นต้องมีขั้นตอนการเข้ารหัส เนื่องจากโครโมโซมที่เป็นฟีโนไทป์อยู่ในรูปเดียวกันกับคำตอบของระบบซึ่งสามารถเข้าใจได้ทันที ปกติแล้วในเจเนติกอัลกอริทึม จะใช้โครโมโซมหลาย ๆ ชุดแทนคำตอบของระบบ คือ  $s_i, i = 1, 2, 3, \dots, N$  ( $N$  โครโมโซม) นั่นคือในวัฏจักรหนึ่ง ๆ ของเจเนติกอัลกอริทึม จะมีคำตอบอยู่หลาย ๆ ชุด ปกติขนาดของประชากรจะมีจำนวนอยู่ระหว่าง 30 - 100 โครโมโซม ในระบบที่เป็นเวลาจริง (Real-time System) อาจมีการใช้ไมโครเจเนติกอัลกอริทึม (Micro-GA) ซึ่งมีขนาดของประชากรเพียงประมาณ 10 โครโมโซม เพื่อเพิ่มความเร็วใน

การคำนวณขนาดของประชากร แน่ใจว่าคำตอบของระบบควรจะเป็นคำตอบที่ดีที่สุดจากประชากรที่มีอยู่ ดังนั้นจำนวนของโครโมโซมที่เหมาะสมนั้นจะขึ้นอยู่กับระบบและการออกแบบ จึงไม่มีกฎเกณฑ์ที่แน่นอนในการระบุจำนวนที่เหมาะสมของโครโมโซมในแต่ละครั้งได้ อย่างไรก็ตามก็มีหลักแนวคิดที่ว่าจำนวนโครโมโซมที่น้อยเกินไปอาจจะมีผลให้ประชากรที่มีอยู่ทั้งหมดไม่สามารถขยายพันธุ์ครอบคลุมไปถึงคำตอบของระบบได้ตามที่ต้องการ ในขณะที่จำนวนโครโมโซมที่มากเกินไปก็จะก่อให้เกิดความล่าช้าในการคำนวณและทำให้เกิดความซ้ำซ้อนกันของโครโมโซมซึ่งอาจจะมีผลให้เจเนติกอัลกอริทึมไม่สามารถลู่เข้าหาคำตอบได้ตามที่คาดไว้

$$f(s(t)) = f(s_1(t), s_2(t), \dots, s_L(t))$$

โดยที่  $s_1(t), s_2(t), \dots, s_L(t)$  คือ คำตอบของระบบที่ผ่านการถอดรหัสให้อยู่ในรูปพีโนไทป์เรียบร้อยแล้ว

### การประเมินค่าความเหมาะสม (Fitness Evaluation)

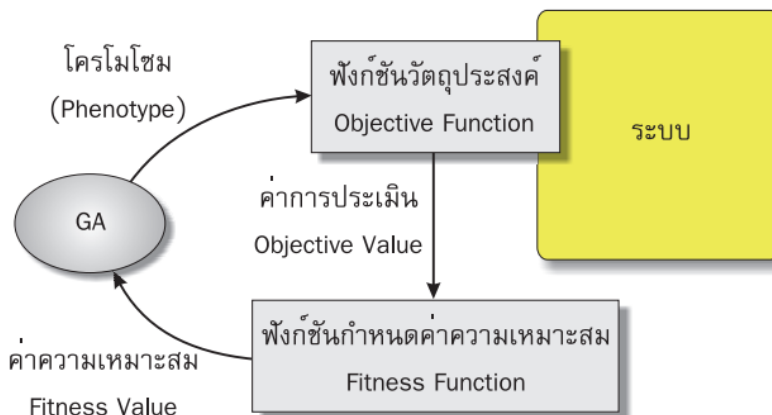
เจเนติกอัลกอริทึมจะพิจารณาเลือกจุดคำตอบใหม่ ๆ จากจุดคำตอบเดิมโดยอาศัยค่าที่เหมาะสมที่ไม่เป็นลบ โดยทั่วไปค่าที่เหมาะสมนี้จะมีค่าเท่ากับค่าของฟังก์ชันเป้าหมาย แต่ในบางกรณีค่าที่เหมาะสมนี้ อาจจะได้จากการจัดลำดับชั้นของค่าฟังก์ชันเป้าหมาย ดังนั้นการประเมินค่าความเหมาะสมเป็นขั้นตอนในการประเมินว่าโครโมโซมหนึ่ง ๆ ดีหรือไม่ดีอย่างไร เมื่อเทียบกับโครโมโซมอื่น ๆ ที่มีอยู่ในกลุ่มประชากรนั้น ๆ โดยปกติแล้วการประเมินค่าความเหมาะสมของโครโมโซมจะประกอบไปด้วยการคำนวณค่าของสองฟังก์ชัน ดังนี้

#### 1. ฟังก์ชันวัตถุประสงค์ (Objective Function)

ฟังก์ชันวัตถุประสงค์เป็นส่วนสำคัญในกระบวนการของ GA ที่ใช้ในการประเมินผลคำตอบของระบบว่าดีหรือไม่ดี ฟังก์ชันวัตถุประสงค์เป็นฟังก์ชันที่ทำการประเมินคำตอบจากโครโมโซมโดยเทียบกับเป้าหมายของระบบ ในกรณีที่ระบบเป็นปัญหาของการค้นหาค่าน้อยที่สุด (Minimization Problem) โครโมโซมที่เป็นคำตอบที่ดีที่สุดของระบบจะมีค่าตัวเลขจากฟังก์ชันวัตถุประสงค์ที่น้อยที่สุด ตัวอย่างของฟังก์ชันวัตถุประสงค์ ได้แก่ ฟังก์ชันทั่ว ๆ ไปที่ใช้คำนวณค่าความผิดพลาดของระบบ (Error) เช่น MSE (Mean-Squared Error) SSE (Sum-Squared Error) หรือ RMSE (Root-Mean-Squared Error) เป็นต้น ดังนั้นวัตถุประสงค์ของระบบดังกล่าวก็คือต้องการให้ค่าความผิดพลาดของระบบมีค่าน้อยที่สุด ค่าการประเมิน (Evaluation Value) ที่ได้จากฟังก์ชันวัตถุประสงค์จะเป็นตัวบอกว่าคำตอบของระบบขณะนั้นดีหรือไม่ดีเท่าไร ในกรณีนี้ สำหรับคำตอบหนึ่ง ๆ แล้ว ค่าความผิดพลาดที่น้อยกว่าหมายถึงคำตอบนั้นจะเป็นคำตอบที่ดีกว่า ค่าการประเมินที่ได้จากฟังก์ชันวัตถุประสงค์ บางครั้งจะเรียกว่าค่าวัตถุประสงค์ (Objective Value) เนื่องจากฟังก์ชันวัตถุประสงค์ต้องใช้ตัวระบบเป็นที่คำนวณค่าการประเมิน ดังนั้นฟังก์ชันวัตถุประสงค์จึงถือเป็นส่วนสำคัญในการเชื่อมโยง GA เข้ากับระบบในโลกจริง จะสังเกตได้ว่าโครโมโซมที่นำไปประเมินค่าด้วยฟังก์ชันวัตถุประสงค์จะต้องอยู่ในรูปที่ระบบเข้าใจ (นั่นคืออยู่ในรูปพีโนไทป์) ดังนั้นถ้ากำหนดให้โครโมโซม  $s$  ที่เวลา  $t$  ใด ๆ คือ  $s(t)$  เราสามารถเขียนความสัมพันธ์ของค่าการประเมินของโครโมโซมนี้กับฟังก์ชันวัตถุประสงค์ได้ดังนี้

$$f(s(t)) = f(s_1(t), s_2(t), \dots, s_L(t))$$

โดยที่  $s_1(t), s_2(t), \dots, s_L(t)$  คือคำตอบของระบบที่ผ่านการถอดรหัสให้อยู่ในรูปฟีโนไทป์เรียบร้อยแล้ว



ภาพที่ 2-19 ฟังก์ชันวัตถุประสงค์และฟังก์ชันกำหนดค่าความเหมาะสม (สถาบันเทคโนโลยีพระจอมเกล้าพระนครเหนือ, 2559)

## 2. ฟังก์ชันกำหนดค่าความเหมาะสม (Fitness Function)

ฟังก์ชันกำหนดค่าความเหมาะสมเป็นฟังก์ชันที่ทำการจับคู่ค่าการประเมินที่ได้จากฟังก์ชันวัตถุประสงค์ไปเป็นค่าความเหมาะสม (Fitness Value) จุดประสงค์ของฟังก์ชันนี้คือเพื่อทำการกำหนดค่าความเหมาะสมให้กับโครโมโซมแต่ละตัว โดยทำการเปรียบเทียบกันเองภายในกลุ่มประชากร ค่าความเหมาะสมเหล่านี้จะนำไปใช้เป็นมาตรฐานวัด เพื่อตัดสินใจคัดเลือกโครโมโซมที่จะใช้ในการสืบสายพันธุ์ในรุ่นถัดไป สาเหตุที่เจเนติกอัลกอริทึมไม่ใช้ค่าการประเมินในการคัดเลือกโครโมโซมก็เนื่องมาจากค่าการประเมินที่ได้จากฟังก์ชันวัตถุประสงค์นั้นจะมีค่าขึ้นอยู่กับระบบ จึงทำให้ตัวเลขที่ได้มีความหลากหลายและแตกต่างกันเกินไป ยกตัวอย่างเช่นขนาดค่าความผิดพลาดของระบบสามารถมีค่าน้อยที่สุดคือศูนย์และมากที่สุดที่ไม่จำกัดขนาดและเครื่องหมาย เห็นได้ชัดว่าเป็นการไม่สะดวกนักที่จะนำค่าดังกล่าวมาใช้ในการคัดเลือกโครโมโซม เนื่องจากค่านี้อาจจะมีความแตกต่างกันเกินไป (โดยเฉพาะในแต่ละรอบของเจเนติกอัลกอริทึมที่มีการประเมินโครโมโซม ค่าความผิดพลาดอาจจะแตกต่างกันโดยสิ้นเชิงได้) ฟังก์ชันกำหนดค่าความเหมาะสมจึงเป็นการคำนวณค่าการประเมินของโครโมโซมทั้งหมดเทียบกับโครโมโซมด้วยกันเองและปรับให้มีค่าที่อยู่บนบรรทัดฐานเดียวกัน

$$E(F_i) = E[E_{min}], [E_{min}], i = 1, 2, \dots, N$$

โดยที่  $E(F_i)$  คือฟังก์ชันกำหนดค่าความเหมาะสมจากค่าการประเมิน  $F_i$  (ของโครโมโซมตัวที่  $i$ )  $E_{min}$  และ  $E_{min}$  เป็นค่าต่ำสุดและค่าสูงสุดของค่าความเหมาะสม โดยปกติจะมีค่าคงที่ตลอดระยะเวลาการทำงานของเจเนติกอัลกอริทึม (ซึ่งต่างกับค่าการประเมินที่สามารถเปลี่ยนแปลงไปตาม

สถานะของคำตอบที่คำนวณได้ในแต่ละรอบของเจเนติกอัลกอริทึม) แสดงความสัมพันธ์ระหว่างฟังก์ชันวัตถุประสงค์กับฟังก์ชันกำหนดค่าความเหมาะสม เทคนิคของฟังก์ชันกำหนดค่าความเหมาะสมมีอยู่หลายแบบ เทคนิคที่ง่ายและนิยมใช้ เช่น วิธีกำหนดอย่างเป็นสัดส่วน (Proportional) หรือวิธีการกำหนดบรรทัดฐานเชิงเส้น (Linear Normalization) ฯลฯ รายละเอียดของเทคนิคดังกล่าวมีดังต่อไปนี้

วิธีกำหนดค่าความเหมาะสมอย่างเป็นสัดส่วน Proportional Fitness Function

1. กำหนดให้ประชากรประกอบไปด้วยโครโมโซมทั้งหมด  $N$  ตัว คือ  $s_i, i = 1, 2, \dots, N$
2. กำหนดให้ค่าการประเมินของโครโมโซมตัวที่  $i$  คือ  $F_i(s_i)$
3. ค่าความเหมาะสมของแต่ละโครโมโซมสามารถคำนวณได้ดังนี้

$$E(F_i) = \frac{F_i}{\sum_{i=1}^N F_i}$$

4. ค่าความเหมาะสมที่ได้จากวิธีนี้จะถูกทำให้อยู่ในบรรทัดฐานเดียวกัน นั่นคือมีค่าไม่เกิน 1 อย่างไรก็ตามวิธีนี้ ไม่สามารถใช้กับค่าการประเมินที่ติดลบได้

วิธีกำหนดค่าความเหมาะสมอย่างเป็นบรรทัดฐานเชิงเส้น (Linear Normalization Fitness Function)

1. ทำการจัดเรียงโครโมโซมด้วยค่าการประเมินตามลำดับ โดยที่เรียงจากมากไปน้อยถ้าระบบต้องการหาคำตอบที่มีค่ามากที่สุด ในขณะที่เรียงจากน้อยไปมากจะใช้สำหรับระบบที่ต้องการหาคำตอบที่มีค่าน้อยที่สุด กำหนดให้ตัวชี้ที่แสดงลำดับของการเรียงเป็น  $r$
2. ให้โครโมโซมที่ดีที่สุดมีค่าความเหมาะสมเป็น  $E_{best}$  แล้วโครโมโซมตัวที่  $i$  จะมีค่าความเหมาะสมคือ

$$i = E_{best} - (r - 1) \times \lambda$$

โดยที่  $\lambda$  คือค่าอัตราการลดลง (Decrement Rate)

3. ค่าความเหมาะสมของโครโมโซมจะมีค่าไม่เกิน  $E_{best}$  ในขณะที่โครโมโซมที่อยู่ในอันดับแรก ๆ จะมีค่าความเหมาะสมที่ดีกว่าตามสัดส่วนของ  $r - 1$
4. ค่าอัตราการลดลงจะมีค่าแตกต่างกันไปตามลักษณะของค่าการประเมิน (ซึ่งอาจจะไม่เหมือนกันในแต่ละระบบ)

#### การคัดเลือกสายพันธุ์ (Selection)

การคัดเลือกสายพันธุ์เป็นขั้นตอนในการคัดเลือกโครโมโซม ที่ดีที่สุดจากภายในกลุ่มประชากรทั้งหมด ซึ่งโครโมโซมที่ได้จะถูกนำไปใช้เป็นตัวต้นกำเนิดสายพันธุ์หรือ ‘พ่อแม่’ เพื่อใช้ในการให้กำเนิดลูกหลานในรุ่นถัดไป โดยปกติแล้วเพื่อให้ได้สายพันธุ์ที่ดี ต้นกำเนิดของสายพันธุ์จะต้องดีด้วย จึงกลายเป็นปัญหาว่าจะทำการคัดเลือกต้นกำเนิดสายพันธุ์ที่ดีได้อย่างไรการคัดเลือกสายพันธุ์เป็นการจำลองการคัดเลือกโครโมโซมที่จะสามารถอยู่รอดได้ในแต่ละรุ่น สำหรับ GA นั้นจะทำการคัดเลือกโครโมโซมโดยการพิจารณาที่ค่าความเหมาะสมของโครโมโซมนั้น ๆ ดังนั้นโครโมโซมไหนมีค่าความเหมาะสมที่ดี ย่อมหมายถึงการเป็นโครโมโซมที่ดีและควรมีโอกาสที่จะให้ลูกหลาน (Offspring) ใน

จำนวนที่มากกว่าได้ ซึ่งย่อมเป็นการบ่งบอกว่าโอกาสในการอยู่รอดในรุ่นถัดไปก็จะมีเพิ่มมากขึ้นด้วย ได้มีการนำเสนอเทคนิควิธีของการคัดเลือกสายพันธุ์อย่างหลากหลาย ซึ่งทั้งหมดสามารถแบ่งออกได้เป็นสองกลุ่มหลักคือ

วิธีที่ใช้ค่าความเหมาะสมโดยตรง วิธีนี้จะใช้ค่าความเหมาะสม (Fitness Value) ของแต่ละโครโมโซมสำหรับการคัดเลือกสายพันธุ์

วิธีใช้ค่าความเหมาะสมโดยอ้อม วิธีนี้จะมีการแปลงค่าความเหมาะสมให้อยู่ในช่วงที่ต้องการ เช่นการทำให้เป็นบรรทัดฐานอยู่ในช่วง  $[0, 1]$  แล้วใช้สำหรับการคัดเลือกสายพันธุ์ต่อไป ขั้นตอนในการคัดเลือกสายพันธุ์ประกอบไปด้วย 2 ขั้นตอนใหญ่ ๆ ได้แก่

1. การกำหนดค่าโอกาส  $p$  ในการถูกคัดเลือกเพื่อเป็นต้นกำเนิดสายพันธุ์ให้กับโครโมโซม
2. การแปลงค่าโอกาส  $p$  ไปเป็นจำนวนของโครโมโซมลูกหลาน

ในขั้นตอนการคัดเลือกดังกล่าว GA จะใช้ค่าโอกาส  $p$  แทนค่าความเหมาะสม ผลลัพธ์จากการคัดเลือกคือจำนวนลูกหลานที่ได้จากโครโมโซมนั้น ๆ โครโมโซมที่มีโอกาสในการถูกคัดเลือกสูงจะให้จำนวนของโครโมโซมลูกหลานที่สูงด้วย ดังนั้นสิ่งที่เราต้องพิจารณาคือการคำนวณหาค่า  $p$  ที่เหมาะสม



ภาพที่ 2-20 การกำหนดค่าโอกาส  $p$  เพื่อใช้ในขั้นตอนการคัดเลือก

วิธีการกำหนดค่าโอกาส  $p$  ในการถูกคัดเลือกที่ใช้กันแพร่หลายทั่ว ๆ ไปเช่น วิธีการแบ่งเป็นสัดส่วน (Proportionate) วิธีของโบลต์ซมันน์ (Boltzmann) วิธีการจัดอันดับ (Ranking) และวิธีจัดการแข่งขัน (Tournament) ฯลฯ ส่วนการแปลงค่าโอกาส  $p$  ไปเป็นจำนวนโครโมโซมลูกหลาน หรือที่เรียกว่าการชักตัวอย่าง (Sampling) จะใช้วิธีของวงล้อรูเล็ต (Roulette Wheel Sampling) หรือวิธีกระบวนการสุ่มครอบคลุมจักรวาล (Stochastic Universal Sampling หรือ SUS)

#### การกำหนดค่าโอกาสในการถูกคัดเลือก

หลักการโดยทั่วไปของการกำหนดโอกาส  $p$  คือการใช้ค่าความเหมาะสมของแต่ละโครโมโซมเพื่อช่วยในการคัดเลือกตัวอย่างวิธีการกำหนดค่าโอกาสมีรายละเอียดต่อไปนี้

การคัดเลือกด้วยการแบ่งเป็นสัดส่วน (Proportionate Selection) วิธีการนี้จะทำการคัดเลือกโครโมโซมอย่างเป็นสัดส่วนจากค่าความเหมาะสมของโครโมโซมนั้น ๆ ถ้ากำหนดให้โครโมโซม  $s$  มีค่าความเหมาะสมเป็น  $E(s)$  ค่าโอกาสในการถูกคัดเลือกของโครโมโซมนี้คือ

$$p(s) = \frac{E(s)}{E}$$

โดยที่  $E$  คือ ค่าความเหมาะสมเฉลี่ยของโครโมโซมทั้งหมด ค่า  $p(s)$  แสดงให้เห็นว่าโครโมโซมแต่ละตัวสามารถเป็นต้นกำเนิดสายพันธุ์ในอัตราส่วนที่แตกต่างกัน โครโมโซมที่มีค่าความเหมาะสมมากก็จะมีโอกาสในการสืบสายพันธุ์ด้วยอัตราที่สูงกว่าโครโมโซมที่มีค่าความเหมาะสมน้อยกว่าข้อจำกัดของการคัดเลือกสายพันธุ์ด้วยวิธีการนี้ คือ ค่าความเหมาะสมจะต้องมีค่าเป็นบวกเท่านั้น อย่างไรก็ตามเราสามารถใส่ค่าเอกซ์โพเนนเชียลของค่าความเหมาะสมซึ่งจะมีค่าเป็นบวกเสมอแทนได้ (วิธีดังกล่าวจะกลายเป็นวิธีของโบลต์ซมันน์นั่นเอง) วิธีการแบ่งเป็นสัดส่วนเป็นวิธีที่ง่ายแต่อาจจะสามารถนำไปสู่คำตอบแบบวงแคบเฉพาะถิ่นได้ (Local Optimum) วิธีการแบบอื่น ๆ จึงถูกพัฒนาและศึกษาในประสิทธิภาพต่อการทำงานของ GA ดังเช่น วิธีของโบลต์ซมันน์หรือวิธีแบบจัดอันดับ

การคัดเลือกแบบโบลต์ซมันน์ (Boltzmann Selection) วิธีของโบลต์ซมันน์เป็นวิธีการแก้ปัญหาของโครโมโซมที่มีค่าความเหมาะสมที่เป็นลบ นอกจากนี้แล้วยังมีจุดประสงค์เพื่อลดความแตกต่างของค่าความเหมาะสมของประชากรโดยรวม พิจารณาโอกาสในการถูกคัดเลือกของโครโมโซม  $s$  ที่มีค่าความเหมาะสมเป็น  $E(s)$  สามารถเขียนสมการความสัมพันธ์ในรูปเอกซ์โพเนนเชียลที่ใช้ในการคำนวณหาค่าของค่าความเหมาะสมได้ดังนี้

$$p(s) = \frac{e^{E(s)}}{\bar{E}}$$

การคัดเลือกแบบจัดอันดับ (Ranking Selection) วิธีการนี้เป็นวิธีการที่ค่อนข้างง่าย โดยโครโมโซมจะถูกจัดเรียงให้มีอันดับ  $r$  ตามค่าความเหมาะสม โครโมโซมที่มีค่าความเหมาะสมที่ดีที่สุดจะมีอันดับ  $N$  โดยที่  $N$  คือจำนวนโครโมโซมทั้งหมด ( $N$  จะเป็นค่าอันดับที่มากที่สุด) ในขณะที่โครโมโซมที่มีค่าความเหมาะสมที่ด้อยที่สุดจะมีอันดับ 1 โอกาสในการถูกคัดเลือกของโครโมโซมจะมีค่าเท่ากับ

$$p(s = r/E)$$

วิธีการจัดอันดับมีข้อดีที่ค่า  $p$  จะไม่แปรผันกับขนาดของค่าความเหมาะสมแต่จะขึ้นกับอันดับของโครโมโซมอย่างไรก็ตามวิธีการดังกล่าวจะมีผลทำให้การลู่เข้าสู่คำตอบของ GA ช้า เนื่องจากโครโมโซมที่ด้อยกว่ามีโอกาสในการถูกคัดเลือกที่ดีขึ้นเมื่อเทียบกับวิธีที่กล่าวมาก่อนข้างต้น

การคัดเลือกแบบจัดการแข่งขัน (Tournament Selection) เป็นวิธีการเดียวกับการแข่งขันกีฬาทั่ว ๆ ไปทำได้โดยการสุ่มแบ่งกลุ่มคัดเลือกโครโมโซม แล้วเลือกเอาโครโมโซมที่ดีที่สุดในกลุ่มนั้นเพื่อหาโครโมโซมผู้ชนะเป็นต้นกำเนิดสายพันธุ์ต่อไป จำนวนของโครโมโซมในแต่ละกลุ่มนั้นจะแตกต่างกันออกไป โดยปกติแล้วจะใช้วิธีสุ่มแบบจับคู่โครโมโซม (นั่นคือมีเพียง 2 โครโมโซมที่ถูกสุ่มเลือกเข้ามาในแต่ละการแข่งขัน) หลักการจัดการแข่งขันมีดังต่อไปนี้

1. ทำการสุ่มเลือกโครโมโซม  $K$  ตัวสำหรับจัดการแข่งขันขนาด  $K$  (Tournament Size) เลือกโครโมโซมที่มีค่าประเมินดีที่สุดจากการแข่งขัน ด้วยค่าความน่าจะเป็นเท่ากับ  $p$



2. เลือกโครโมโซมที่มีค่าประเมินดีเป็นอันดับสอง (รองอันดับหนึ่ง) ด้วยค่าความน่าจะเป็นเท่ากับ  $p \times (1 - p)$

3. เลือกโครโมโซมที่มีค่าประเมินดีเป็นอันดับถัดไป (รองอันดับสอง) ด้วยค่าความน่าจะเป็นเท่ากับ  $p \times (1 - p)^2$

4. เลือกโครโมโซมที่มีค่าประเมินดีเป็นรองอันดับที่  $n$  ด้วยค่าความน่าจะเป็นเท่ากับ  $p \times (1 - p)^n$


ถ้ากำหนดให้ค่า  $p = 1$  การคัดเลือกจะเลือกโครโมโซมที่ดีที่สุดเสมอ ในขณะที่ถ้า  $K = 1$  การคัดเลือกเปรียบเสมือนกับการสุ่มเลือกโครโมโซม โครโมโซมที่ชนะการแข่งขันและถูกคัดเลือกแล้วสามารถออกจากการแข่งขันหรืออยู่ต่อ (เพื่อสามารถถูกเลือกได้อีก) ก็ได้ สามารถปรับขนาดของการแข่งขัน  $K$  เพื่อให้ได้ความเข้มข้นในการแข่งขันที่เหมาะสม กล่าวคือถ้า  $K$  มีขนาดใหญ่หรือการแข่งขันขนาดใหญ่ โครโมโซมที่ไม่ดีมาก (ค่าการประเมินน้อย) ก็จะมีโอกาสชนะน้อย

วิธีการแข่งขันมีความเหมาะสมในการทำให้ปัญหาความเหลื่อมล้ำของค่าความเหมาะสมของโครโมโซมหมดไป นอกไปจากนั้นแล้ววิธีการแข่งขันยังเขียนโปรแกรมได้ง่ายและทำงานเป็นแบบขนานได้อีกด้วย

#### การแปลงค่าโอกาสเป็นจำนวนโครโมโซมลูกหลาน

หลังจากที่ได้ทำการกำหนดค่าโอกาส  $p$  ในการถูกคัดเลือกให้กับแต่ละโครโมโซมจนหมดแล้ว ขั้นตอนต่อไปก็คือการชักตัวอย่าง ซึ่งเป็นการนำเอาค่าโอกาสนั้นไปทำการแปลงให้เป็นค่าตัวเลข ตัวเลขดังกล่าวจะแสดงถึงจำนวนของลูกหลานที่โครโมโซมนั้น ๆ จะสามารถให้กำเนิดในขั้นต่อไปได้ วิธีการแปลงค่าโอกาสให้เป็นจำนวนโครโมโซมลูกหลานที่นิยมใช้มีดังต่อไปนี้

วิธีการชักตัวอย่างแบบวงล้อรูเล็ต (Roulette Wheel Sampling) ในขั้นตอนแรกจะทำการสร้างวงล้อรูเล็ตขึ้นมาก่อน โดยกำหนดให้  $p_{total}$  คือผลรวมของค่าโอกาสในการถูกคัดเลือกของโครโมโซมในประชากรทั้งกลุ่ม ค่านี้จะมีค่าเทียบเท่ากับเส้นรอบวงของวงล้อรูเล็ต หลังจากนั้นค่า  $p$  ของโครโมโซมแต่ละตัวจะถูกแปลงไปยังบนวงล้อรูเล็ตภายในช่วง  $[0, p_{total}]$  โดยที่ขนาดบนวงล้อรูเล็ตสำหรับแต่ละโครโมโซมจะสัมพันธ์กับค่า  $p$  ของโครโมโซมนั้น ๆ ตัวอย่างของวงล้อรูเล็ตสำหรับกลุ่มประชากร  $s$  ที่มีค่าความเหมาะสม  $E = \{3, 1, 5, 20, 8\}$  ค่า  $p_i$  คือค่าโอกาสในการถูกคัดเลือกของโครโมโซมตัวที่  $i$  ซึ่งได้มาจากวิธีการแบ่งเป็นสัดส่วน สังเกตว่าค่า  $p$  ของโครโมโซมจะสัมพันธ์โดยตรงกับค่าความเหมาะสมของโครโมโซม




ภาพที่ 2-21 วงล้อรูเล็ตจากค่าความเหมาะสมของแต่ละโครโมโซม (สถาบันเทคโนโลยีพระจอมเกล้าพระนครเหนือ, 2559)



จากรูปดังกล่าวโครโมโซม  $s_4$  ซึ่งมีค่าความเหมาะสมเท่ากับ 20 เป็นค่าสูงที่สุดในกลุ่มจะมีขนาดบวกล้อรูเล็กที่สุดและมีโอกาสในการถูกคัดเลือกสูงที่สุด (ด้วยค่า  $P_4$ ) ในขณะที่โครโมโซม  $s_2$  ซึ่งมีค่าความเหมาะสมเท่ากับ 1 เป็นค่าต่ำที่สุดในกลุ่มจะมีขนาดบวกล้อรูเล็กที่สุดและมีโอกาสในการถูกคัดเลือกต่ำที่สุด (ด้วยค่า  $p_2$ ) ขั้นตอนในการคัดเลือกโครโมโซมจะเริ่มจากการสุ่มค่าตัวชี้ซึ่งเป็นตัวเลขระหว่าง 0 ถึง  $p_{total}$  และถ้าตัวเลขดังกล่าวตรงกับโครโมโซมใดบวกล้อรูเล็กโครโมโซมนั้นจะถูกเลือกกระบวนการนี้เปรียบได้กับการหมุนวงล้อในเกมรูเล็ต

ในแต่ละครั้งของการหมุนวงล้อก็จะได้โครโมโซมที่จะเป็นต้นกำเนิดสายพันธุ์มาหนึ่งตัว การสุ่มตัวเลขเพื่อคัดเลือกโครโมโซมจะดำเนินไปเรื่อย ๆ จนกระทั่งได้ต้นกำเนิดสายพันธุ์เท่ากับจำนวนที่ต้องการ ดังนั้นสำหรับการคัดเลือกต้นกำเนิดสายพันธุ์จำนวน  $N$  โครโมโซมจะต้องทำการหมุนวงล้อรูเล็ตทั้งหมด  $N$  ครั้ง เราจะเห็นได้ชัดเจนว่าโครโมโซมที่มีค่าความเหมาะสมที่สูง จะมีโอกาสถูกคัดเลือกมากกว่าโครโมโซมที่มีค่าความเหมาะสมที่ต่ำกว่า ซึ่งเป็นปรากฏการณ์ปกติในธรรมชาติทั่ว ๆ ไปค่า  $p$  ที่ใช้จากตัวอย่างในภาพ 2-20 ได้มาจากการแบ่งเป็นสัดส่วน จะเห็นได้ชัดเจนว่าโอกาสของโครโมโซมตัวที่สองที่จะถูกเลือกนั้น อาจมีค่าน้อยมากอันจะทำให้เกิดความเหลื่อมล้ำในการคัดเลือก



ภาพที่ 2-22 วงล้อรูเล็ตจากกระบวนการเพิ่มสุ่มครอบครัว (สถาบันเทคโนโลยีพระจอมเกล้าพระนครเหนือ, 2559)

วิธีอื่น ๆ ที่มีประสิทธิภาพดีกว่าจึงเป็นที่นิยมใช้มากกว่า เช่น วิธีการจัดอันดับ ซึ่งจะให้ค่าของโอกาสในการถูกคัดเลือกที่ไม่แปรผันไปตามขนาดของค่าความเหมาะสม ดังแสดงในรูปที่ 2-21 จะเห็นได้ว่าโอกาสการถูกคัดเลือกของ  $p_4$  เพิ่มขึ้นเป็นสัดส่วนที่เหมาะสม (ถูกจัดเป็นอันดับสุดท้าย) ในขณะที่  $p_4$  และ  $p_5$  มีค่าโอกาสในการถูกคัดเลือกที่ใกล้เคียงกันอันเนื่องมาจากมีอันดับที่ติดกัน วิธีวงล้อรูเล็ตเป็นขบวนการสุ่มคัดเลือกโครโมโซม ในบางโอกาสอาจจะมีโครโมโซมใดโครโมโซมหนึ่งเท่านั้นที่บังเอิญถูกสุ่มในการคัดเลือกทุกครั้ง

ถ้าเกิดกรณีดังกล่าวขึ้น ประชากรในรุ่นถัดไปจะประกอบไปด้วยโครโมโซมชนิดเดียวกันหมดทั้งกลุ่ม ซึ่งไม่เป็นประโยชน์ต่อการค้นหาคำตอบแต่อย่างใด วิธีวงล้อรูเล็ตสามารถปรับปรุงได้

หลายวิธี วิธีหนึ่งที่ย่างและมีประสิทธิภาพคือ กำหนดให้ในแต่ละครั้งที่โครโมโซมถูกคัดเลือก ขนาดของโครโมโซมนั้น ๆ บนวงล้อรูเล็ตจะมีค่าลดลงจนกระทั่งมีขนาดเป็นศูนย์ วิธีนี้ทำให้แต่ละโครโมโซมที่เหลืออยู่ มีขอบเขตในการถูกเลือกที่เท่าเทียมกัน ในขณะเดียวกัน ก็ช่วยลดโอกาสความเป็นใหญ่ในหมู่ประชากรของโครโมโซมตัวใดตัวหนึ่งได้

### วิธีการชักตัวอย่างแบบกระบวนการฟื้นฟูสุ่มครอบจักรวาล (Stochastic Universal Sampling หรือ SUS)

วิธี SUS เป็นการชักตัวอย่างที่ถูกเรียกใช้เพียงครั้งเดียว ก็สามารถคัดเลือกโครโมโซมตามจำนวนที่ต้องการได้ วิธีชักตัวอย่างแบบ SUS มีข้อแตกต่างไปจากแบบวงล้อรูเล็ตตรงที่มีการใช้ตัวชี้มากกว่าหนึ่งตัว นั่นคือสำหรับการคัดเลือก  $N$  โครโมโซมจะมีตัวชี้ทั้งหมด  $N$  ตัว โดยที่ตัวชี้แต่ละตัวจะมีระยะห่างเท่ากันและมีค่าเท่ากับ  $p_{total}/N$  ดังแสดงในรูปที่ 2-21 SUS จะเริ่มจากการสุ่มสลัปที่โครโมโซมบนวงล้อรูเล็ต ถัดมาตัวชี้  $ptr$  ซึ่งเป็นตัวชี้เริ่มต้นจะถูกสุ่มขึ้นมาในช่วง  $p_{total}/N [0, p_{total}]$  ตัวชี้ที่เหลือจำนวน  $N - 1$  ตัวถัดจากตัวชี้  $ptr$  จะถูกคำนวณโดยมีระยะห่างระหว่างตัวชี้ที่ติดกันเท่ากับ  $p_{total}/N$  โครโมโซมที่จะถูกคัดเลือกได้แก่โครโมโซมจำนวนทั้งสิ้น  $N$  โครโมโซมซึ่งถูกตัวชี้  $N$  ตัวชี้อยู่ วิธีนี้ช่วยลดความเหลื่อมล้ำในแต่ละโครโมโซมสำหรับการคัดเลือกลงเมื่อเทียบกับวิธีดั้งเดิมของวงล้อรูเล็ต โครโมโซมที่มีค่า  $p$  สูงจะถูกชี้ด้วยจำนวนตัวชี้ในจำนวนที่มากกว่าโครโมโซมที่มีค่า  $p$  ที่ต่ำกว่า

หลังจากขั้นตอนของการคัดเลือกแล้ว โครโมโซมที่ถูกคัดเลือกจะกลายเป็นต้นกำเนิดสายพันธุ์ ซึ่งมีหน้าที่ในการให้กำเนิดโครโมโซมลูกหลานด้วยกรรมวิธีเฉพาะของ GA ดังรายละเอียดในหัวข้อถัดไป

### การรีโพรดักชัน

การรีโพรดักชันเป็นขั้นตอนที่จะเลือกว่าสายอักขระแต่ละตัวในกลุ่มประชากรนั้นจะอยู่รอดหรือไม่ในรุ่นต่อไปโดยพิจารณาจากค่าที่เหมาะสมของสายอักขระแต่ละตัว ถ้าสายอักขระใดมีค่าที่เหมาะสมสูงก็มีโอกาสที่จะอยู่รอดสูง ส่วนสายอักขระที่มีค่าที่เหมาะสมต่ำจะมีโอกาสอยู่รอดต่ำ

ตารางที่ 2-2 สัดส่วนความเหมาะสมที่มีโอกาสถูกเลือกจากการสุ่ม (การรีโพรดักชัน)

ลำดับที่	สายอักขระ	ค่าความเหมาะสม	สัดส่วนความเหมาะสม
1	01101	169	14.4
2	11000	576	49.2
3	01000	64	5.5
4	10011	361	30.9
ผลรวม		1170	100.0

ตัวอย่างค่าที่เหมาะสมของสายอักขระจำนวน 4 ตัวดังตารางที่ 2-2 ที่คิดเป็นสัดส่วนเทียบกับผลรวมค่าที่เหมาะสมของประชากรทั้งหมด จากนั้นนำสัดส่วนดังกล่าวไปจัดให้อยู่ในรูปแบบวงกลม การเลือกสายอักขระจะทำการหมุนแผนภูมิวงกลมดังกล่าวอย่างสุ่มจำนวน 4 ครั้ง (เท่ากับ

จำนวนประชากรทั้งหมด) แผนภูมิวงกลมดังกล่าวแสดงสัดส่วนความเหมาะสมที่สายอักขระแต่ละตัว  
 นั้นมีโอกาสถูกเลือกจากการสุ่ม ถ้ามีสัดส่วนความเหมาะสมมากโอกาสที่ได้รับการเลือกก็มาก

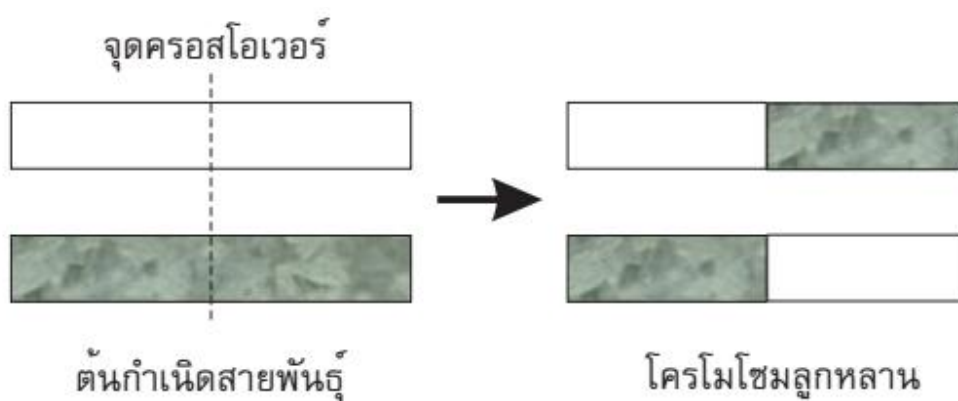
### ปฏิบัติการทางสายพันธุ์ (Genetic Operation)

หลังจากจบวนการคัดเลือกได้ดำเนินไปจนเสร็จสมบูรณ์ โครโมโซมลูกหลานจะถูกสร้างขึ้น  
 ใหม่ จากโครโมโซมที่ถูกคัดเลือกมาเป็นต้นกำเนิดสายพันธุ์ โดยการนำเอาโครโมโซมที่เป็นต้นกำเนิด  
 สายพันธุ์นั้นมาทำการเปลี่ยนแปลงให้เกิดโครโมโซมใหม่ขึ้นมา กลายเป็นโครโมโซมลูกหลาน ขั้นตอน  
 ดังกล่าวนี้นับเป็นขั้นตอนสำคัญอีกขั้นตอนหนึ่งในวัฏจักรของ GA ที่ซึ่งมีการคาดหวังว่าโครโมโซม  
 ลูกหลานที่เกิดขึ้นมานั้น จะได้รับส่วนดีของโครโมโซมต้นกำเนิดสายพันธุ์โดยผ่านปฏิบัติการทางสาย  
 พันธุ์นี้ หากพิจารณาถึงการเปลี่ยนแปลงอันเนื่องมาจาก



ภาพที่ 2-23 ปฏิบัติการทางสายพันธุ์ (สถาบันเทคโนโลยีพระจอมเกล้าพระนครเหนือ, 2559)

ปฏิบัติการทางสายพันธุ์ที่เกิดขึ้นกับประชากรอันเป็นคำตอบของระบบนั้น สามารถเปรียบ  
 ปฏิบัติการทางสายพันธุ์เหมือนกับการก้าวเดินไปสู่คำตอบของระบบ โดยปกติทั่วไปปฏิบัติการทาง  
 สายพันธุ์ของ GA จะมีอยู่ 2 วิธีหลัก ๆ คือ การทำครอสโอเวอร์และการผ่าเหล่า ดังรายละเอียด  
 ต่อไปนี้



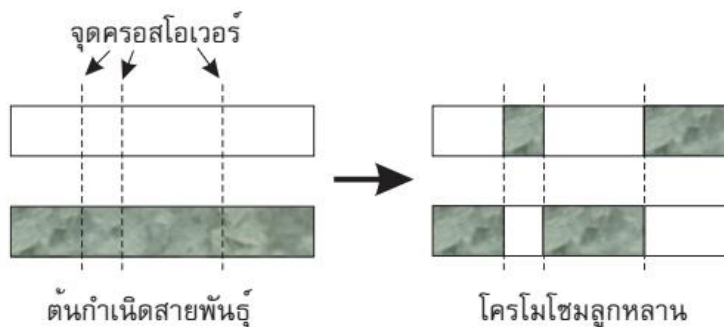
ภาพที่ 2-24 ครอสโอเวอร์แบบจุดเดียว (สถาบันเทคโนโลยีพระจอมเกล้าพระนครเหนือ, 2559)

### ครอสโอเวอร์ (Crossover)

ครอสโอเวอร์เป็นวิธีการรวมตัวใหม่ของโครโมโซม (Recombination Operator) โดยทำการรวมส่วนย่อยระหว่างโครโมโซมต้นกำเนิดสายพันธุ์ ตั้งแต่สองโครโมโซมขึ้นไป เพื่อให้กลายเป็นโครโมโซมลูกหลาน โครโมโซมลูกหลานที่ได้จากการครอสโอเวอร์นี้จะมีพันธุกรรมจากต้นกำเนิดสายพันธุ์อยู่ในตัว โดยปกติทั่วไปแล้วจะมีการกำหนดอัตราการทำครอสโอเวอร์เอาไว้ซึ่งส่วนใหญ่จะใช้ความน่าจะเป็น ( $p_c$ ) เป็นตัวกำหนดอัตราดังกล่าว วิธีการทำครอสโอเวอร์มีได้หลายแบบดังต่อไปนี้

การทำครอสโอเวอร์แบบจุดเดียว (Single-Point Crossover) การทำครอสโอเวอร์แบบจุดเดียวนั้น โครโมโซมลูกหลานจะมีสายพันธุ์ของแต่ละต้นกำเนิดอยู่อย่างละหนึ่งส่วน จุดตัดในการทำครอสโอเวอร์นั้นโดยปกติจะได้อาจมาจากการสุ่มเลือก ตัวอย่างของการทำครอสโอเวอร์แบบจุดเดียว

การทำครอสโอเวอร์แบบหลายจุด (Multiple-Point Crossover) พิจารณาตัวอย่างการทำครอสโอเวอร์แบบหลายจุด ดังแสดงในภาพที่ 2-25 ที่ซึ่งมีการใช้จุดตัดทั้งหมด 3 จุด ดังนั้นโครโมโซมลูกหลานจะมีสายพันธุ์ของต้นกำเนิดอยู่มากกว่าหนึ่งส่วน หลักการเลือกจุดของครอสโอเวอร์นั้นมีอยู่หลายแบบ แต่ละแบบจะให้ผลต่อการเปลี่ยนแปลงของสายพันธุ์ในโครโมโซมลูกหลานที่แตกต่างกันออกไปด้วย วิธีที่ง่ายและเป็นที่ยอมรับทั่วไปคือการสุ่มเลือกจุดครอสโอเวอร์ การทำครอสโอเวอร์แบบหลายจุดจะให้ผลของลูกหลานที่มีความหลากหลายมากกว่าการทำครอสโอเวอร์แบบจุดเดียว อันจะมีผลให้การลู่เข้าสู่คำตอบของระบบสามารถครอบคลุมพื้นที่ของคำตอบได้มากยิ่งขึ้น อย่างไรก็ตามการทำครอสโอเวอร์แบบหลายจุด ซึ่งทำให้เกิดการเปลี่ยนแปลงของโครโมโซมลูกหลานได้มากกว่าการทำครอสโอเวอร์แบบจุดเดียวนั้น อาจจะทำให้มีโอกาสเบี่ยงเบนของคำตอบที่มีอยู่ในโครโมโซมลูกหลานได้ในอัตราที่สูงกว่าเช่นกัน



ภาพที่ 2-25 ครอสโอเวอร์แบบหลายจุด (สถาบันเทคโนโลยีพระจอมเกล้าพระนครเหนือ, 2559)

ครอสโอเวอร์แบบสม่ำเสมอ (Uniform Crossover) การทำครอสโอเวอร์แบบจุดเดียวและหลายจุด มีการกำหนดจุดตัดเอาไว้ก่อนที่จะทำการสลับส่วนย่อยของโครโมโซมที่จุดนั้น ๆ วิธีดังกล่าวมีความแตกต่างไปจากการทำครอสโอเวอร์แบบสม่ำเสมอ ที่ซึ่งถูกออกแบบให้ทุกจุดบนโครโมโซมสามารถเป็นจุดตัดได้ ในทางปฏิบัติจะมีการใช้ครอสโอเวอร์แมสก์หรือตัวพราง (Crossover Mask) ช่วยในการทำครอสโอเวอร์ ตัวพรางดังกล่าวจะเป็นชนิดไบนารีและมีขนาดจำนวนบิตเท่ากับความยาวของโครโมโซม ค่าของตัวพรางที่ตำแหน่งต่าง ๆ จะเป็นตัวบอกถึงการครอสโอเวอร์ระหว่างต้นกำเนิดสายพันธุ์ ณ ตำแหน่งที่ตัวพรางมีค่าเป็น 1 โครโมโซมลูกหลานจะได้รับการสลับส่วนย่อยของ

โครโมโซมต้นกำเนิดสายพันธุ์ ถ้าตำแหน่งที่แมสก์มีค่าเป็น 0 โครโมโซมลูกหลานจะยังคงเป็นส่วนย่อยของโครโมโซมต้นกำเนิดของสายพันธุ์ โดยไม่มีการสลับส่วนหนึ่งแต่อย่างใด การทำครอสโอเวอร์เป็นผลจากปฏิบัติการทางสายพันธุ์ที่ใช้โครโมโซมต้นกำเนิดสายพันธุ์มากกว่า 1 โครโมโซมขึ้นไป ปฏิบัติการทางสายพันธุ์ในหัวข้อต่อไปจะได้กล่าวถึงรายละเอียดการผ่าเหล่า ที่ซึ่งเกิดขึ้นกับโครโมโซมตัวเดียวเท่านั้น

กล่าวโดยสรุปได้ว่าการครอสโอเวอร์เป็นกระบวนการที่สายอักขระคู่หนึ่ง ๆ จะแลกเปลี่ยนบิตกันในบางตำแหน่ง เพื่อให้กำเนิดสายอักขระโครงสร้างใหม่ขึ้นมาด้วยความน่าจะเป็นค่าหนึ่ง ซึ่งเรียกว่า ความน่าจะเป็นของการครอสโอเวอร์ ความน่าจะเป็นของการครอสโอเวอร์ คือ ตัวเลขจำนวนจริงระหว่าง 0 ถึง 1 ที่ได้กำหนดขึ้นเพื่อแสดงให้เห็นว่าสายอักขระมีโอกาสจะครอสโอเวอร์มากหรือน้อยเพียงใด ภาพแสดงการครอสโอเวอร์โดยในขั้นแรกจะสุ่มเลขจำนวนจริงในช่วง 0 ถึง 1 ถ้าตัวเลขที่สุ่มนี้มีค่าสูงกว่า ความน่าจะเป็นของการครอสโอเวอร์ แสดงว่าสายอักขระนั้นจะไม่เกิดการครอสโอเวอร์ หากตัวเลขจำนวนจริงที่ทำการสุ่มขึ้นมา นั้น มีค่าต่ำกว่าความน่าจะเป็นของการครอสโอเวอร์ จะเกิดครอสโอเวอร์โดยสายอักขระคู่หนึ่งจะถูกสุ่มขึ้นมาเรียกว่าสายอักขระพ่อแม่ จากนั้นจะสุ่มตำแหน่งของครอสโอเวอร์ ขึ้นมาโดยที่สายอักขระคู่นั้นจะเปลี่ยนแปลงบิตกันตั้งแต่ตำแหน่งที่อยู่หลังตำแหน่งครอสโอเวอร์ เป็นต้นไป เพื่อให้กำเนิดสายอักขระใหม่ขึ้นมาเรียกว่าสายอักขระลูก กระบวนการถ่ายทอดนี้จะกระทำจนได้สายอักขระชุดใหม่ขึ้นมาจนครบจำนวนประชากรที่เราต้องการ

#### การผ่าเหล่า (Mutation)

การผ่าเหล่าเป็นวิธีการแปรผันยีนหรือส่วนย่อยของโครโมโซม ซึ่งสามารถเปรียบเทียบได้กับการกลายพันธุ์ของสิ่งมีชีวิตในทางชีววิทยา ปกติแล้วอัตราการผ่าเหล่าจะมีค่าค่อนข้างต่ำ หรืออาจกล่าวได้ว่าความน่าจะเป็นในการผ่าเหลานั้นมีค่าน้อย ถ้าการผ่าเหล่าคือการเปลี่ยนแปลงยีนส์ในโครโมโซมแล้ว การผ่าเหล่าจะเป็นการเปลี่ยนแปลงเชิงตัวเลขของโครโมโซม เพราะในทางปฏิบัติแล้ว ยีนส์ของโครโมโซมก็คือบิตในระบบตัวเลขของคอมพิวเตอร์ การผ่าเหล่าเปรียบเสมือนกับการก้าวเดินไปสู่คำตอบของระบบเช่นเดียวกับการทำครอสโอเวอร์ นอกเหนือไปจากนั้นแล้ว การผ่าเหล่ายังสามารถถูกพิจารณาเป็นการทำให้เกิดความหลากหลายขึ้นในกลุ่มประชากร มีผลให้คำตอบที่เกิดขึ้นในขอบข่ายของ GA ครอบคลุมพื้นที่การค้นหาคำตอบทั่วถึงยิ่งขึ้น



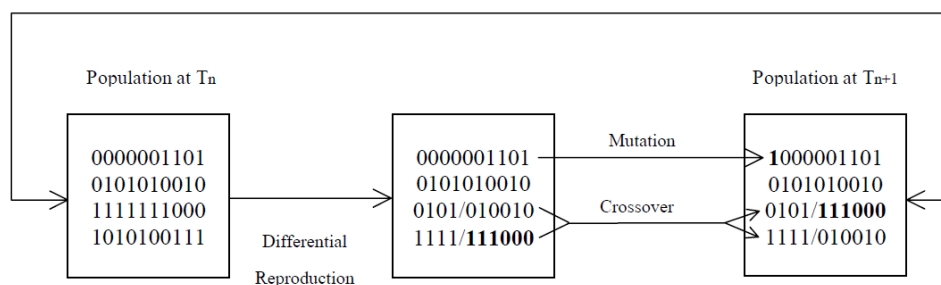
ภาพที่ 2-26 การแปรผันยีนในการผ่าเหล่า (สถาบันเทคโนโลยีพระจอมเกล้าพระนครเหนือ, 2559)

อย่างไรก็ตามอัตราในการผ่าเหล่าเป็นปัจจัยที่สำคัญอีกอย่างหนึ่งที่ต้องคำนึงถึง เนื่องจากจะมีผลต่อพฤติกรรมการทำงานของ GA มีผลการค้นคว้ารายงานว่า อัตราการผ่าเหล่าจะขึ้นอยู่กับ

ขนาดของประชากร เพื่อให้การสำรวจพื้นที่ในการค้นหาคำตอบเป็นไปอย่างทั่วถึง (Prügel-Bennett, 2001) ดังนั้นการกำหนดอัตราการผ่าเหล่าต้องมีความเหมาะสมที่สุดต่อระบบด้วย เพื่อก่อให้เกิดผลในการค้นหาคำตอบที่มีประสิทธิภาพยิ่งขึ้น จากที่กล่าวมาทั้งหมด สามารถสรุปได้ว่าจุดประสงค์หลัก ๆ ของการผ่าเหล่าก็คือเพื่อให้ GA สามารถหลุดพ้นออกจากคำตอบที่เหมาะสมที่สุดแบบวงแคบเฉพาะถิ่นได้ (Local Optimum) โดยการป้องกันไม่ให้โครโมโซมประชากรเกิดการเปลี่ยนแปลงในทิศทางที่มีความคล้ายคลึงกันไปหมด อาจจะกล่าวได้ว่าวิวัฒนาการของคำตอบที่ต้องได้หยุดลงครอสโอเวอร์และการผ่าเหล่าเป็นการสร้างและการเปลี่ยนแปลงของต้นกำเนิดสายพันธุ์ ซึ่งให้ผลเป็นโครโมโซมลูกหลาน การทำครอสโอเวอร์มีผลให้โครโมโซมลูกหลานได้รับสายพันธุ์จากต้นกำเนิด โดยโครโมโซมลูกหลานจะได้รับส่วนที่ดีจากส่วนย่อยของต้นกำเนิดสายพันธุ์ไป ในขณะที่การผ่าเหล่าเป็นการสร้างความแปรผันขึ้นในโครโมโซมลูกหลาน เพื่อให้เกิดประชากรใหม่ที่ดีกว่าขึ้น ปฏิบัติการทางสายพันธุ์ทั้งสองถูกใช้ใน GA โดยหวังว่าการเปลี่ยนแปลงที่เกิดขึ้น จะมีผลทำให้โครโมโซมลูกหลานมีสายพันธุ์ที่ดีขึ้น จนสามารถนำไปสู่คำตอบที่ดีที่สุดต่อไป

กล่าวได้ว่า การผ่าเหล่าเป็นกระบวนการที่ป้องกันการลู่เข้าก่อนกำหนด และป้องกันการสูญเสียข้อมูลที่สำคัญบางอย่างในระหว่างกระบวนการถ่ายทอด โดยการเปลี่ยนค่าสายอักขระที่ตำแหน่งใด ๆ ด้วยความน่าจะเป็นค่าหนึ่งซึ่งเรียกว่า ความน่าจะเป็นของการผ่าเหล่า การผ่าเหล่าโดยในขั้นแรกจะสุ่มตัวเลขจำนวนจริงในช่วง 0 ถึง 1 แล้วเปรียบเทียบกับตัวเลขจำนวนจริงที่สุ่มกับความน่าจะเป็นของการผ่าเหล่า ถ้าตัวเลขจำนวนจริงที่สุ่มมีค่าสูงกว่า ความน่าจะเป็นของการผ่าเหล่า ก็จะไม่เกิดมิวเทชัน แต่ถ้าตัวเลขจำนวนจริงที่สุ่มมีค่าต่ำกว่า ความน่าจะเป็นของการผ่าเหล่า ก็จะทำให้เกิดมิวเทชันที่ปิดตำแหน่งนั้นโดยที่จะเปลี่ยนบิตที่ตำแหน่งนั้น จาก 0 เป็น 1 หรือ 1 เป็น 0

เงื่อนไขการหยุดของเจเนติกอัลกอริทึมมีอยู่หลายวิธี เช่น ค่าฟังก์ชันเป้าหมายเปลี่ยนแปลงไป น้อยกว่าค่าที่ยอมรับได้ หรือการเปลี่ยนแปลงบิตในสายอักขระแต่ละตัวน้อยกว่าจำนวนที่ยอมรับได้ แต่โดยทั่วไปจะหยุดหาคำตอบเมื่อครบจำนวนรอบสูงสุดที่กำหนดเอาไว้ (Holland & Goldberg, 1989)



Tn เป็นจำนวนประชากรในการเลือกสุ่มรุ่นแรก

Tn + 1 เป็นจำนวนประชากรในการเลือกสุ่มรุ่นต่อไป

ภาพที่ 2-27 ตัวอย่างขั้นตอนของการรีโพรดักชัน ครอสโอเวอร์ และมิวเทชัน (สถาบันเทคโนโลยีพระจอมเกล้าพระนครเหนือ, 2559)



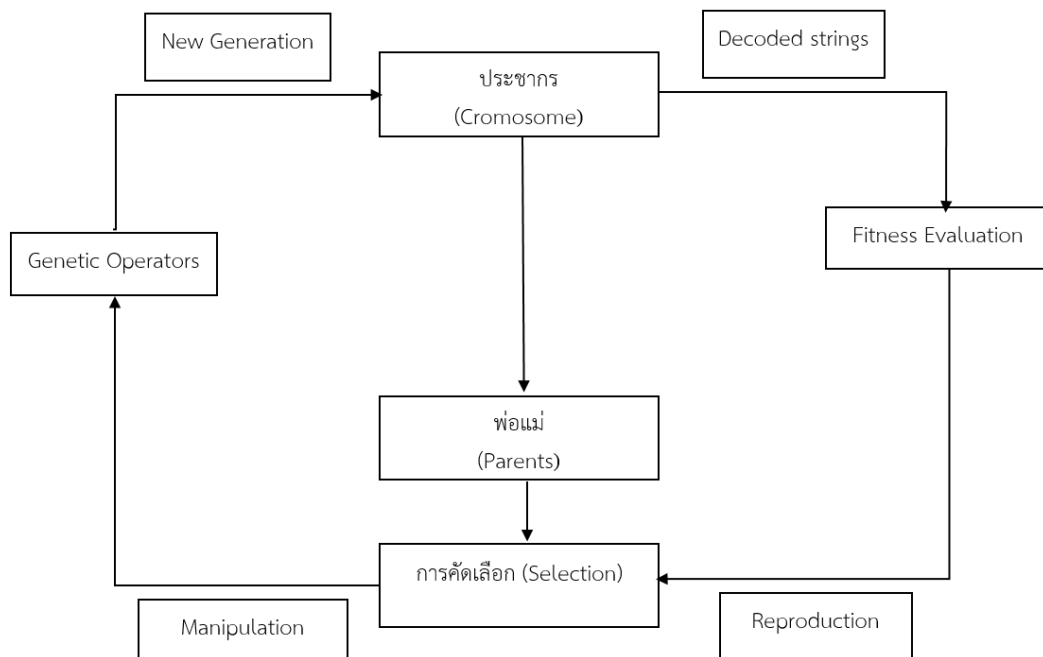
## การแทนที่ (Replacement)

การแทนที่เป็นขั้นตอนหลังจากที่ GA ได้โครโมโซมลูกหลานเรียบร้อยแล้ว และจะนำโครโมโซมลูกหลานใหม่นี้ไปแทนที่ประชากรรุ่นเก่า จุดประสงค์ในการแทนที่นั้นค่อนข้างชัดเจน กล่าวคือการนำโครโมโซมลูกหลานมาแทนที่ประชากรรุ่นก่อน จะทำให้ประชากรรุ่นใหม่ประกอบไปด้วยโครโมโซมใหม่ ๆ ซึ่งเป็นโครโมโซมที่ดีกว่าเพราะได้สืบสายพันธุ์ที่ดีจากต้นกำเนิดสายพันธุ์ที่ผ่านการคัดเลือกแล้ว กลยุทธ์ในการคัดเลือกกว่าโครโมโซมไหนจะถูกแทนที่นั้นสามารถแบ่งได้เป็น 2 วิธี คือ

1. การแทนที่ประชากรทั้งรุ่น (Generational GA) เป็นการนำประชากรลูกหลานไปแทนที่ประชากรเก่าทั้งหมด ดังนั้นถ้าในระบบหนึ่งมีจำนวนประชากรเท่ากับ  $N$  จำนวนของโครโมโซมลูกหลานที่จะมาแทนที่จะต้องมีความยาว  $N$  เช่นกัน วิธีนี้เป็นวิธีที่ง่ายเนื่องจากไม่จำเป็นต้องมีขั้นตอนของการคัดเลือก ว่าประชากรส่วนไหนจะถูกแทนที่ แต่การที่ไม่มีขั้นตอนดังกล่าวกลายเป็นข้อเสีย นั่นคือ โครโมโซมที่ดี ๆ ในรุ่นก่อนจะถูกแทนที่ไปด้วยวิธีแก้ปัญหาง่าย ๆ คือ ก่อนที่จะทำการแทนที่ให้คัดเลือกเก็บโครโมโซมที่ดีที่สุด 2-3 ตัวแรกเอาไว้โดยอาจจะใช้วิธีการคัดเลือกดังที่อธิบายมาแล้วก่อนหน้านี้ วิธีดังกล่าวอาจเรียกได้ว่าเป็นกลยุทธ์คัดเลือกแบบหัวกระทิ (Elitist Strategy) อย่างไรก็ตามประชากรที่เหลืออยู่อาจจะถูกครอบงำด้วยโครโมโซมหัวกระทินี้ได้โดยง่าย กล่าวคือถ้าไม่มีโครโมโซมใหม่ที่ดีกว่าเกิดขึ้น โครโมโซมที่ดีที่สุดจากรุ่นก่อนก็จะถูกเก็บไว้อยู่ตลอดไป และไม่ก่อให้เกิดการเปลี่ยนแปลงใด ๆ ขึ้น ทำให้ GA ไม่สามารถสร้างวิวัฒนาการโครโมโซมใหม่ ๆ ขึ้นมาได้ ถึงแม้ว่าผลของโครโมโซมหัวกระทิจะมีโอกาสเกิดขึ้นได้ แต่วิธีนี้ก็ได้รับการพิสูจน์แล้วว่าทำให้ระบบโดยรวมดีขึ้น

2. การแทนที่ประชากรแบบบางส่วน (Partial GA) เป็นการนำเอาประชากรลูกหลานไปแทนที่ประชากรเดิมเพียงบางส่วนเท่านั้น ดังนั้นจะต้องมีการคัดเลือกประชากรที่จะถูกแทนที่ ซึ่งโดยปกติจะพิจารณาจากค่าความเหมาะสมของโครโมโซมนั้นเอง โครโมโซมเก่าจะถูกแทนที่ด้วยโครโมโซมใหม่เพียง 1 หรือ 2 ตัวเท่านั้น กลวิธีในการแทนที่มีอยู่หลายวิธี เช่น การแทนที่ประชากรที่ด้อยที่สุด หรือการแทนที่ประชากรโดยการสุ่มเลือก เป็นต้น เราได้พิจารณารายละเอียดองค์ประกอบต่าง ๆ ของ GA เรียบร้อยแล้ว เนื้อหาในส่วนต่อไปจะเป็นตัวอย่างการนำเอา GA ไปประยุกต์ใช้งานด้านต่าง ๆ ในการใช้ GA กับแต่ละปัญหานั้น สิ่งที่จะต้องพิจารณาก็คือพารามิเตอร์ของ GA ดังที่ได้กล่าวมาแล้วทั้งหมด การเลือกพารามิเตอร์ของ GA สำหรับแต่ละปัญหานั้นจะมีความเหมาะสมแตกต่างกันไป ผู้ใช้งาน GA จึงควรต้องเข้าใจธรรมชาติการทำงานของ GA ให้ดี แล้วทำการปรับแต่งพารามิเตอร์เพื่อให้ได้ผลลัพธ์ที่เหมาะสมที่สุดให้ได้

ผังการทำงานของเจเนติกอัลกอริทึม ขั้นตอนการหาค่าความเหมาะสมโดยรวมของเจเนติกอัลกอริทึม แสดงดังภาพที่ 2-28



ภาพที่ 2-28 ขั้นตอนการทำงานของเจเนติกอัลกอริทึม (สถาบันเทคโนโลยีพระจอมเกล้าพระนครเหนือ, 2559)

ขั้นตอนการทำงานของเจเนติกอัลกอริทึมแสดงขั้นตอนทั่วไปของเจเนติกอัลกอริทึมและการเชื่อมโยงเข้ากับระบบในโลกจริงเพื่อทำการค้นหาคำตอบที่ต้องการ คำตอบของระบบที่ต้องการให้เจเนติกอัลกอริทึม ทำการค้นหาจะอยู่ในรูปของโครโมโซมในกลุ่มของประชากร (แน่นอนว่าคำตอบที่ต้องการจะต้องเป็นโครโมโซมที่ดีที่สุดในกลุ่ม) ดังนั้นระบบจะสามารถรู้ได้ว่าคำตอบที่มีอยู่ในเจเนติกอัลกอริทึม ณ เวลานั้น ๆ นั้นดีหรือไม่ดีอย่างไรด้วยการประเมินค่าของโครโมโซม ระบบจะมีการเชื่อมต่อกับเจเนติกอัลกอริทึม ผ่านฟังก์ชันวัตถุประสงค์สำหรับการประเมินค่าของโครโมโซม

เจเนติกอัลกอริทึมจึงเป็นวิธีการค้นหาคำตอบแบบสุ่ม โดยมีพื้นฐานมาจากกระบวนการคัดเลือกทางธรรมชาติ และกระบวนการคัดเลือกทางพันธุศาสตร์ โดยการคัดเลือกสายอักขระที่มีความเหมาะสมจากกลุ่มของสายอักขระทั้งหมด ด้วยวิธีสุ่มและนำสายอักขระเหล่านี้ไปผ่านกระบวนการคัดเลือก ที่เลียนแบบกระบวนการคัดเลือกทางธรรมชาติ เพื่อหาสายอักขระที่มีความเหมาะสมในการอยู่รอด ซึ่งสายอักขระที่มีความเหมาะสมนั้นก็คือ คำตอบที่ดีที่สุดหรือใกล้เคียงคำตอบที่ดีที่สุด (Holland, 1975)

#### งานวิจัยที่เกี่ยวข้องกับเจเนติกอัลกอริทึม

Gonçalves, Mendes, and Resende (2004) ได้นำเสนออัลกอริทึมทางพันธุกรรมแบบผสมผสานสำหรับแก้ปัญหาการจัดตารางงานของร้านค้า ด้วยการนำวิธีการสุ่มโครโมโซมขึ้นมาเป็นตัวแทนของปัญหาและสร้างตารางงานขึ้นโดยใช้กฎลำดับความสำคัญ โดยกำหนดลำดับความสำคัญตามขั้นตอนวิธีทางพันธุกรรมและอาศัยกระบวนการคัดกรองพารามิเตอร์ หลังจากมีการกำหนดตารางงานแล้วจะนำไปใช้ในการแก้ปัญหาในท้องถิ่น วิธีการนี้ได้รับการทดสอบด้วยชุดข้อมูลมาตรฐาน



ที่นำมาจากเอกสารงานวิจัยและเปรียบเทียบกับวิธีการอื่น ๆ ผลการคำนวณพบว่าอัลกอริทึมมีประสิทธิภาพเป็นไปตามความต้องการ (Gonçalves, Mendes, & Resende, 2004)

HwaKim, Abraham, and Cho (2007) ได้ศึกษาพฤติกรรมการหาอาหารทางสังคมของแบคทีเรีย *Escherichia coli* และนำมาใช้เพื่อแก้ปัญหาการเพิ่มประสิทธิภาพด้วยวิธีการผสมผสานระหว่างขั้นตอนวิธีทางพันธุกรรม (GA) และกลไกการหาอาหารของแบคทีเรีย (BF) เพื่อใช้สำหรับปัญหาการเพิ่มประสิทธิภาพของฟังก์ชัน ก่อนอื่นเรานำเสนอวิธีการที่นำเสนอโดยใช้ฟังก์ชันการทดสอบสี่แบบและมีการศึกษาประสิทธิภาพของอัลกอริทึมด้วยการเน้นการกลายพันธุ์การครอสโอเวอร์การเปลี่ยนแปลงของขนาดขั้นตอนขั้นตอน Chemotactic และอายุการใช้งานของแบคทีเรียอัลกอริทึมที่เสนอจะถูกใช้เพื่อปรับแต่งตัวควบคุม PID ของตัวควบคุมแรงดันไฟฟ้าแบบอัตโนมัติ (AVR) ผลการจำลองแสดงให้เห็นว่าแนวทางที่นำเสนอมีประสิทธิภาพมากและสามารถขยายไปได้อย่างง่ายดายสำหรับปัญหาการเพิ่มประสิทธิภาพในระดับสากล (HwaKim, Abraham, & Cho, 2007)

Guillot, Santos, and Estoup (2008) ได้ศึกษาวิธีการจัดตำแหน่งตัวควบคุม Static VAR Compensator (SVC) ที่ดีที่สุดเพื่อปรับปรุงแรงดันไฟฟ้าโดยใช้อัลกอริทึมพันธุกรรมแบบใหม่โดยใช้วิธีการเขียนโปรแกรมแบบลำดับต่อเนื่อง (GA-SQP) โดยนำอัลกอริทึมไปใช้ในการกำหนดตำแหน่งสูงสุดของคอนโทรลเลอร์ SVC สำหรับแก้ปัญหาการไหลของพลังงานที่เหมาะสม (OPF) และปรับปรุงแรงดันไฟฟ้าพร้อม ๆ กันจากนั้น OPF จะทำการปรับปรุงแรงดันไฟฟ้าภายในขอบเขตของการสร้างกระแสไฟจริงและข้อจำกัดต่าง ๆ เช่น ข้อจำกัดความร้อนของสาย ข้อจำกัดแรงดันไฟฟ้าและข้อจำกัดการทำงานระบบของ SVC โดยทำการทดสอบด้วยเครื่องยนต์ของรถบัสจำนวน 5 เครื่อง แสดงประสิทธิภาพการทำงานของอัลกอริทึม GA-SQP เพื่อปรับปรุงแรงดันไฟฟ้าของระบบ ผลการทดลองแสดงให้เห็นอย่างชัดเจนว่าการเสนอแนะระบบ SVC ด้วยพารามิเตอร์และตำแหน่งที่เหมาะสมสามารถปรับปรุงแรงดันไฟฟ้าได้ (Guillot, Santos, & Estoup, 2008)

Yang, Zhou, Lu, and Fang (2008) ได้ศึกษาความเสถียรของระบบไฟฟ้าภายใต้สภาพอากาศที่แตกต่างกันและค่าใช้จ่ายของระบบที่สอดคล้องกันเป็นสองประเด็นหลักในการออกแบบระบบผลิตไฟฟ้าที่มีประสิทธิภาพด้วยพลังงานลมแบบผสมผสาน บทความนี้ได้แนะนำวิธีการปรับขนาดที่เหมาะสม เพื่อเพิ่มประสิทธิภาพการกำหนดค่าแบบผสมผสานของระบบลมและสงอาทิตย์ โดยใช้แบตเตอรี่เป็นตัวเก็บพลังงาน ด้วยการใช้ขั้นตอนวิธีทางพันธุกรรม (GA) ซึ่งมีความสามารถในการหาค่าตอบที่ดีที่สุดโดยใช้วิธีง่ายที่สุด ในการคำนวณและมีความสามารถในการปรับขนาดที่เหมาะสมที่สุดวิธีหนึ่งที่เหมาะสมสำหรับคำนวณเพื่อกำหนดค่าระบบที่เหมาะสมที่สุดของความน่าจะเป็นที่ลูกค้าเกิดความสูญเสีย (LPSP) ค่าใช้จ่ายขั้นต่ำต่อปีของระบบ (ACS) ตัวแปรของการตัดสินใจที่รวมอยู่ในกระบวนการเพิ่มประสิทธิภาพคือหมายเลขโมดูล PV จำนวนกังหันลม จำนวนแบตเตอรี่ มุมลาดของโมดูล PV และความสูงของการติดตั้งกังหันลม วิธีการที่เสนอนี้ใช้ในการวิเคราะห์ระบบไฮบริดซึ่งจัดหาพลังงานสำหรับสถานีถ่ายทอดโทรคมนาคมและพบประสิทธิภาพการเพิ่มประสิทธิภาพที่ดีเยี่ยม นอกจากนี้ยังมีความสัมพันธ์ระหว่างความเชื่อถือได้ของระบบไฟฟ้าและการกำหนดค่าระบบ (Yang, Zhou, Lu, & Fang, 2008)

Santosh, Gajendra, Vibhakar, and Krishna (2011) ได้ศึกษาสมรรถนะของเทคนิค


การจัดสรรคลื่นความถี่โดยใช้เจเนติกอัลกอริทึมและวิเคราะห์ประสิทธิภาพด้วย MATLAB คลื่นวิทยุ นับว่าเป็นหนึ่งในสาขาที่น่าสนใจของยุคปัจจุบัน การใช้ประโยชน์จากสเปกตรัมอย่างมีประสิทธิภาพ จึงเป็นสิ่งจำเป็นสอดคล้องกับความต้องการที่เพิ่มขึ้นของคลื่นวิทยุ นักวิจัยหลายคนได้แสดงให้เห็นว่าวิธีการใช้ใบอนุญาตการใช้คลื่นนั้นใช้ไม่ได้ผลและมีผู้ใช้หลักน้อยกว่า 70% ของความถี่ที่ได้รับอนุญาต นักวิจัยกลุ่มหนึ่งกำลังพยายามหาเทคนิคที่มีประสิทธิภาพในการใช้ประโยชน์จากคลื่นมาตรฐานต่ำที่ได้รับอนุญาต หนึ่งในแนวทางคือ การนำ "Cognitive Radio" มาใช้ ทำให้วิทยุสามารถเรียนรู้จากสภาพแวดล้อมและสามารถเปลี่ยนแปลงพารามิเตอร์บางอย่างได้ จากความรู้ดังกล่าวนี้ ส่งผลให้วิทยุสามารถใช้ประโยชน์จากช่องคลื่นความถี่แบบไดนามิกในคลื่นความถี่ที่ได้รับอนุญาตได้เต็มประสิทธิภาพ (Santosh, Gajendra, Vibhakar, & Krishna, 2011)

เจเนติกอัลกอริทึม (Genetic Algorithm) เป็นวิธีการค้นหาผลลัพธ์ที่ดีที่สุด (ค่าที่เหมาะสม) โดยใช้หลักการคัดเลือกแบบธรรมชาติและหลักการทางสายพันธุ์ เจเนติกอัลกอริทึม เป็นวิธีการคำนวณโดยมีการประยุกต์หลักเข้ากับหลักวิวัฒนาการ (Evolutionary Computing) ของสิ่งมีชีวิตเข้าไปในขั้นตอนของการค้นหาคำตอบและได้รับการจัดให้อยู่ในกลุ่มเมตาฮิวริสติก ปัจจุบันเป็นที่ยอมรับกันว่า วิธีการหาค่าที่เหมาะสมแบบเมตาฮิวริสติกมีประสิทธิภาพสูงมากและมีการนำไปใช้อย่างกว้างขวาง เช่น การเพิ่มสมรรถนะของเทคนิคการจัดสรรคลื่นความถี่ โดยใช้เจเนติกอัลกอริทึม (Santosh, Gajendra, Vibhakar, & Krishna, 2011) การหาวิธีจัดตำแหน่งตัวควบคุม Static VAR Compensator (SVC) ที่เหมาะสมเพื่อปรับปรุงแรงดันไฟฟ้าด้วยเจเนติกอัลกอริทึมที่ได้รับการปรับปรุงใหม่ (Guillot, Santos, & Estoup, 2008) และการปรับปรุงความเสถียรของระบบไฟฟ้าภายใต้สภาพอากาศที่แตกต่างกันและค่าใช้จ่ายของระบบที่สอดคล้องกันเป็นสองประเด็นหลักในการออกแบบระบบผลิตไฟฟ้าที่มีประสิทธิภาพด้วยพลังงานลมแบบผสมผสาน (Yang, Zhou, Lu, & Fang, 2008) ต่อมาเจเนติกอัลกอริทึมได้รับความนิยมนำไปพัฒนาให้มีความเหมาะสมกับแต่ละปัญหา เช่น การนำอัลกอริทึมทางพันธุกรรมแบบผสมผสานไปใช้สำหรับแก้ปัญหาการจัดการจัดตารางงานของร้านค้าและศึกษาพฤติกรรมกรรมการหาอาหารทางสังคมของแบคทีเรีย *Escherichia coli* และนำมาใช้เพื่อแก้ปัญหาการเพิ่มประสิทธิภาพด้วยวิธีการผสมผสานระหว่างขั้นตอนวิธีทางพันธุกรรม (GA) และกลไกการหาอาหารของแบคทีเรีย (BF) งานวิจัยปัจจุบันแสดงให้เห็นว่าเจเนติกอัลกอริทึมได้รับความนิยมนำไปผสมผสานกับอัลกอริทึมอื่น เพื่อเพิ่มประสิทธิภาพของอัลกอริทึมอยู่เสมอ

### ตอนที่ 3 การทำแห้ง (Dehydration) และงานวิจัยที่เกี่ยวข้อง

การทำแห้ง คือ การนำน้ำออกจากวัตถุใด ๆ ที่ต้องการทำให้ปริมาณน้ำในวัตถุนั้นลดลง (ความชื้นลดลง) โดยส่วนใหญ่วัตถุนั้นจะอยู่ในสถานะของแข็ง น้ำที่ระเหยออกจากวัตถุนั้นนี้อาจจะไม่ต้องระเหยที่จุดเดือดก็ได้ แต่สามารถใช้พัดลมอากาศพัดผ่านวัตถุนั้นเพื่อดึงน้ำออกมา วัตถุจะแห้งได้มากหรือน้อยจะขึ้นอยู่กับธรรมชาติของวัตถุนั้น ๆ ในการทำแห้ง เมื่อทำให้ของเหลวในวัตถุระเหยกลายเป็นไอ จะได้ผลิตภัณฑ์ของแข็งที่มีสัดส่วนของของเหลวต่ำลง ซึ่งนอกจากจะมีกรณีที่วัตถุดิบมีสภาพเป็นของแข็งที่เปียกชื้นแล้ว ยังมีกรณีที่การทำแห้งแล้วได้เป็นของเหลวข้น (Slurry) หรือได้เป็นของเหลวใสหรือผลิตภัณฑ์ที่มีลักษณะเป็นผง

การทำแห้งด้วยการออสโมซิสเป็นวิธีการลดปริมาณน้ำบางส่วนออกจากผลไม้ด้วยกระบวนการออสโมซิส โดยการนำผลไม้ไปแช่ลงในสารละลายที่มีความเข้มข้นสูงกว่า (Hypertonic Solution) และค่า Water Activity ต่ำกว่าเมื่อเทียบกับสารละลายในผลไม้ ก่อให้เกิดความแตกต่างของแรงดันออสโมติก (Osmotic Pressure) ระหว่างภายในเซลล์ของผลไม้กับสารละลายภายนอก เกิดเป็นแรงขับ (Driving Force) ทำให้เกิดการถ่ายเทมวลระหว่างสารละลายภายในเซลล์กับสารละลายภายนอกจากบริเวณที่มีความเข้มข้นสูงไปยังบริเวณที่มีความเข้มข้นต่ำผ่านเซลล์เมมเบรนของผลไม้ซึ่งทำหน้าที่เป็นเยื่อเลือกผ่าน (Naknean, 2012) การถ่ายเทมวลจะเกิดขึ้นในทิศทางที่สวนกัน (Counter Current Flow) ดังภาพที่ 2-29




ภาพที่ 2-29 การเคลื่อนที่ของน้ำและสารละลายในอาหาร (ทิพาพร อวยุวิทยา, 2556)

วิธีออสโมติกดีไฮเดรชันมีความหมายรวมถึง การแช่ซึม (Infiltration) ได้รับการนำเสนอครั้งแรกในปี ค.ศ. 1966 โดย James D. Ponting เป็นกระบวนการกำจัดน้ำบางส่วนออกจากเซลล์หรือเนื้อเยื่ออาหาร ด้วยวิธีการแช่อาหารลงในสารละลายออสโมติก (Osmotic Solution) ที่มีความเข้มข้นสูง (ส่วนใหญ่เป็นสารละลายน้ำตาลและสารละลายเกลือ) เพื่อเป็นการเพิ่มแรงดันออสโมติกให้สารละลาย จนเกิดการถ่ายเทมวลสารระหว่างน้ำที่อยู่ภายในเซลล์และน้ำตาลที่อยู่ในสารละลาย เกิดการถ่ายเทในลักษณะที่สวนทางกันผ่านทางเซลล์เมมเบรนระหว่างอาหารและสารออสโมติก โดยน้ำภายในเซลล์ของอาหารจะเคลื่อนที่ไปยังสารละลายออสโมติก ส่งผลให้ปริมาณน้ำในอาหารลดลง (Water Loss) ในขณะเดียวกัน ตัวถูกละลายที่อยู่ในสารละลายจะเคลื่อนที่สวนทางเข้าไปภายในเซลล์ของอาหาร ส่งผลต่อปริมาณของแข็งในอาหารเพิ่มขึ้น (Solid Gain) การถ่ายเทมวลระหว่างสารละลายและอาหารจะเกิดขึ้นไปเรื่อย ๆ จนกระทั่งเข้าสู่ภาวะสมดุลตามกฎการแพร่ของฟิค (Fick's Diffusion Law) ที่ว่าระบบจะพยายามรักษาสมดุลทางเทอร์โมไดนามิกส์ โดยสังเกตได้จากอัตราการถ่ายเทมวลของน้ำและตัวทำละลายมีค่าคงที่ (Silva, Garcia, Amado, & Mauro, 2015)

ในระหว่างการออสโมซิสนั้นการแพร่ของสารละลายจะช้ากว่าการแพร่ของน้ำ ในการทำแห้งผลไม้ด้วยการออสโมซิสนั้นสามารถควบคุมปริมาณน้ำที่ต้องการดึงออกและปริมาณตัวถูกละลายที่ต้องการเพิ่มขึ้นในผลไม้ได้ โดยอาศัยความแตกต่างของอัตราเร็วของน้ำและตัวถูกละลาย (Fitto, 1994); Raoult-Wack, 1994) หากเซลล์ของผลไม้ได้รับความเสียหาย เช่น การลวก ความร้อนจะทำให้เซลล์ผลไม้มีผลทำให้การแพร่ของน้ำและตัวถูกละลายถึงจุดสมดุลได้เร็วขึ้น (ไพบูลย์ ธรรมรัตน์วาลิก, 2532)

ลักษณะเด่นของผลิตภัณฑ์ผลไม้ที่ผ่านการทำแห้งโดยวิธีการออสโมซิสแล้วนำไปอบแห้ง เมื่อเปรียบเทียบกับวิธีทำแห้งด้วยลมเพียงอย่างเดียว พบว่าผลิตภัณฑ์สามารถรักษาสี กลิ่นรสและสารระเหยต่าง ๆ ได้ใกล้เคียงกับลักษณะตามธรรมชาติ ส่งผลให้ผลิตภัณฑ์มีคุณภาพดีเป็นที่ยอมรับของผู้บริโภคและยังสามารถรักษาคุณค่าโภชนาการได้ดี (Petrotos & Lazarides, 2001)

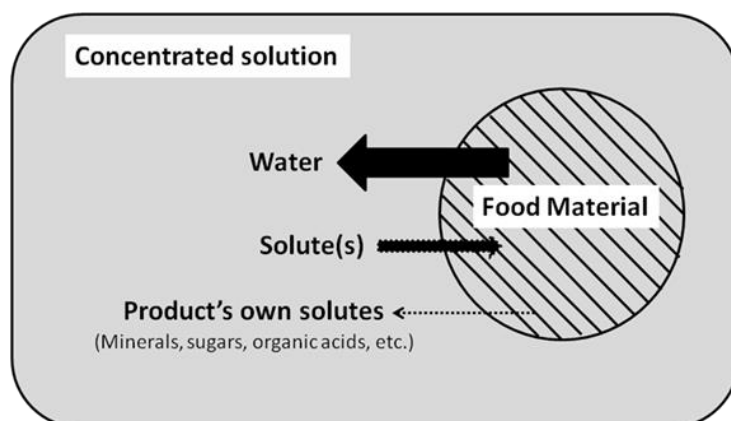
อัตราความชื้น ในการแสดงปริมาณน้ำที่มีอยู่ในอาหาร จะสามารถแสดงได้ด้วยปริมาณน้ำต่อปริมาณมวลรวมเปียกของอาหาร เรียกว่าค่า Wet Base หรือปริมาณน้ำต่อปริมาณวัตถุดิบแห้ง เรียกว่าค่า Dry Base ในขณะที่ทำแห้งมวลรวมจะมีการเปลี่ยนแปลงไปด้วย เมื่อคำนวณความชื้นแบบ Wet Basis จะทำให้ค่าความชื้นเปลี่ยนแปลงอย่างไม่สม่ำเสมอ ดังนั้นในการคำนวณทางอุตสาหกรรม จะใช้ค่าความชื้น ที่คำนวณแบบ Dry Basis ซึ่งมวลแห้งเป็นฐานในการคำนวณ เนื่องจากมวลแห้งนี้มีค่าคงที่ตลอดการอบ จึงมีความสะดวกมากกว่า ถ้าให้ความชื้นที่ Wet Basis เท่ากับ  $w_w$  และให้ความชื้นที่ Dry Basis เท่ากับ  $w_d$  แล้ว ค่าทั้งสองจะมีความสัมพันธ์กันดังต่อไปนี้



ภาพที่ 2-30 การเปลี่ยนแปลงของอัตราความชื้นกับอุณหภูมิของวัตถุดิบ (Reddy, Khetra & Kumarh เข้าถึงได้จาก <http://ecoursesonline.iasri.res.in>)

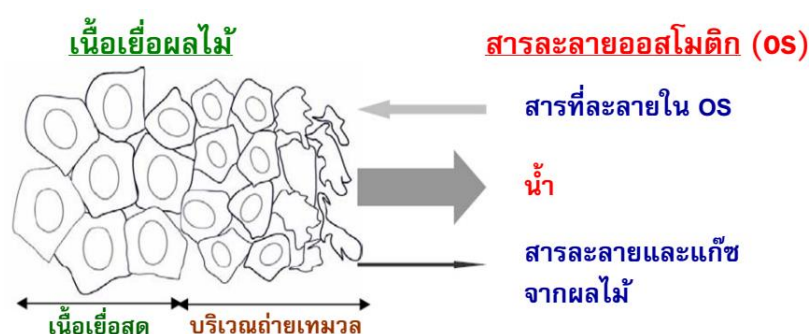
การทำแห้งด้วยวิธีออสโมซิส (Osmotic Dehydration) เป็นการแปรรูปอาหารที่สามารถลดปริมาณน้ำในอาหารลงได้ โดยส่วนใหญ่มักจะดำเนินการกับผักผลไม้ เนื่องจากเป็นวัตถุดิบที่มีปริมาณน้ำมาก ทำได้โดยการแช่ผักผลไม้ในสารละลายที่มีความเข้มข้นสูงซึ่งเรียกว่าสารละลายออสโมติก เช่น สารละลายน้ำตาล สารละลายเกลือ และสารละลายผสมระหว่างน้ำตาลและเกลือ เป็นต้น การออสโมซิสสามารถลดปริมาณน้ำในวัตถุดิบลงได้โดยไม่ต้องใช้ความร้อนสูง เป็นวิธีลดปริมาณน้ำในผักผลไม้ที่ไม่รุนแรง จึงไม่ทำให้เกิดการเสื่อมเสียคุณภาพไปจากของสดมากนัก มีการใช้ชื่อเรียกอื่นแทนการดึงน้ำออกด้วยวิธีออสโมซิส ได้แก่ กระบวนการดึงน้ำออกและการจุ่มแช่การออสโมซิส มีปัจจัยที่เกี่ยวข้องหลายประการซึ่งมีผลต่อการถ่ายโอนมวลสาร และคุณภาพของ

ผลิตภัณฑ์ บทความนี้จึงมีจุดมุ่งหมายเพื่ออธิบาย กลไกการถ่ายโอนมวลสารระหว่างการออสโมซิส และรวบรวมปัจจัย ที่เกี่ยวข้องกับการดึงน้ำออกด้วยวิธีออสโมซิส เพื่อประโยชน์ในการ ประยุกต์ใช้ การดึงน้ำออกด้วยวิธีออสโมซิสให้เหมาะสมในการพัฒนา ผลิตภัณฑ์ผักและผลไม้ต่อไป การถ่ายโอนมวลสารระหว่างการออสโมซิส (Mass Transfer During The Osmotic Dehydration Process)



ภาพที่ 2-31 การเคลื่อนที่ของน้ำและสารละลายแบบออสโมซิส (Reddy, Khetra & Kumarh เข้าถึงได้จาก <http://ecoursesonline.iasri.res.in>)

การดึงน้ำออกด้วยวิธีออสโมซิสอาศัยหลักการเคลื่อนย้ายน้ำบางส่วนจากเนื้อเยื่ออาหาร ซึ่งเกิดจากความแตกต่างของแรงดันออสโมติกระหว่างภายในเซลล์ของอาหารและสารละลายออสโมติก เกิดเป็นแรงขับ (Driving Force) ทำให้มีการถ่ายโอนมวลสารระหว่าง เซลล์ของอาหารและสารละลายออสโมติก ในลักษณะสวนทางกัน ผ่านเยื่อหุ้มเซลล์ซึ่งทำหน้าที่เป็นเยื่อเลือกผ่าน (Semi-Permeable Membrane)




ภาพที่ 2-32 การถ่ายเทมวลผ่านเนื้อเยื่อของผลไม้ (ทิพาพร อัญวิทยา, 2556)

สำหรับผักผลไม้ผนังเซลล์สามารถยืดขยายตัวได้ เมื่อมีแรงดันเกิดขึ้นภายในเซลล์ เยื่อหุ้มเซลล์จะทำหน้าที่เป็นเยื่อเลือกผ่าน โดยยอมให้น้ำแพร่ผ่านได้มากกว่าตัวถูกละลายของสารละลาย

ออสโมติก โดยการถ่ายโอนมวลสารที่เกิดขึ้นระหว่างการออสโมซิส ได้แก่ 1) น้ำภายในเซลล์ของผักผลไม้จะแพร่ออกจากเซลล์สู่สารละลายออสโมติก 2) ตัวถูกละลายของสารละลายออสโมติก เช่น น้ำตาลหรือเกลือ จะแพร่เข้าสู่ภายในเซลล์ผักผลไม้ และ 3) สารบางอย่างที่มีอยู่ภายในเซลล์ผักผลไม้ตามธรรมชาติ เช่น กรดอินทรีย์และเกลือแร่ จะแพร่ออกจากเซลล์ไปสู่สารละลายออสโมติก ทั้งนี้การถ่ายโอนมวลสารหลักที่เกิดขึ้นคือการเคลื่อนย้ายของน้ำ ภายในเซลล์ของผักผลไม้ที่เกิดสวนทางกับการเคลื่อนย้ายของตัวถูกละลายของสารละลายออสโมติก โดยการถ่ายโอนมวลสารนี้ จะเกิดขึ้นจนเข้าสู่สมดุลของสารละลายภายในและภายนอกเซลล์ ส่วนการเคลื่อนย้ายของสารที่มีอยู่ตามธรรมชาติในเซลล์ผักผลไม้ นั้น จะเกิดขึ้นเพียงเล็กน้อยเท่านั้น ดังนั้นการดึงน้ำออกด้วยวิธีออสโมซิส จะทำให้ปริมาณน้ำในผักผลไม้ลดลงแต่ปริมาณของแข็งเพิ่มขึ้นแต่ไม่เท่าปริมาณน้ำที่ลดลง ทำให้น้ำหนักสุทธิลดลงได้ รวมถึงทำให้ค่ากิจกรรมของน้ำ (Water Activity; aw) ของผักผลไม้ลดลงด้วย การถ่ายโอนมวลสารที่เกิดขึ้นระหว่างการออสโมซิส

### อัตราเร็วในการรอบกับเส้นกราฟแสดงสมบัติการอบ

เมื่อนำวัตถุดิบที่ต้องการนำมาทำแห้งที่ยังมีความเปียกชื้นอย่างเพียงพอถึงผิวหน้ามาแขวนไว้ในกระแสมร้อน แล้วติดตามตรวจวัดอัตราความชื้นกับอุณหภูมิของวัตถุดิบนั้น โดยทั่วไปแล้วกลไกการทำแห้งด้วยลมร้อนสามารถแบ่งได้เป็น 3 ระยะที่มีลักษณะแตกต่างกัน กล่าวคือ ระยะที่ 1 ช่วงอุ่นวัตถุดิบ ระยะที่ 2 ช่วงอบด้วยอัตราเร็วคงที่ และระยะที่ 3 ช่วงอบด้วยอัตราเร็วลดลง



ภาพที่ 2-33 ความสัมพันธ์ระหว่าง water Activity กับ Relative Reaction Rate (ทิพาพร อัญวิทยา, 2556)

ระยะที่ 1 ช่วงอุ่นวัตถุดิบ

ช่วง 1 เป็นช่วงที่อุณหภูมิของวัตถุดิบจะค่อย ๆ เพิ่มขึ้นจากอุณหภูมิตั้งต้น (อุณหภูมิห้อง) จนถึงอุณหภูมิสมดุลที่ขึ้นอยู่กับเงื่อนไขการอบ เรียกว่า ช่วงอุ่นวัตถุดิบ ในกรณีที่วัตถุดิบได้รับความ

ร้อนด้วยการพาความร้อนโดยลมร้อน อุณหภูมิสมดุลนี้จะมีค่าเท่ากับอุณหภูมิกระเปาะแห้งของลมร้อนนั้น

ระยะที่ 2 ช่วงอบด้วยอัตราเร็วคงที่

ในช่วง II วัตถุดิบจะมีอุณหภูมิคงที่ ปริมาณความร้อนทั้งหมดที่ได้รับจะถูกใช้ไปในการระเหยความชื้นเท่านั้น ชั้นของการระเหยจะเกิดที่ผิวหน้าของวัตถุดิบโดยอัตราเร็วในการอบจะมีค่าคงที่ ช่วงนี้เรียกว่า ช่วงอบด้วยอัตราเร็วคงที่ ซึ่งจะดำเนินไปตราบเท่าที่มีความชื้นอิสระให้ระเหยอยู่ที่ผิวหน้าของวัตถุดิบ โดยอัตราความชื้นของวัตถุดิบจะลดลงด้วยอัตราเร็วคงที่

ระยะที่ 3 ช่วงอบด้วยอัตราเร็วลดลง

เมื่ออบไปเรื่อย ๆ จนปริมาณความชื้นที่ผิวหน้าวัตถุดิบแห้งลง และความชื้นภายในเนื้อวัตถุดิบเริ่มลดลง ความชื้นอิสระภายในตัววัตถุดิบจะซึมขึ้นมาทดแทน ให้ทันกับอัตราเร็วในการระเหยที่ผิวหน้า จึงเริ่มเข้าสู่ช่วงที่ III ได้แก่ ช่วงอบด้วยอัตราเร็วลดลง ชั้นของการระเหยจะค่อย ๆ เลื่อนลงลึกเข้าไปในเนื้อวัตถุดิบ อุณหภูมิของวัตถุดิบจะเริ่มเข้าใกล้อุณหภูมิของลมร้อนจากบริเวณพื้นผิว ในการอบความร้อนจะต้องเข้าไปถึงภายในเนื้อวัตถุดิบ นอกจากนี้ความร้อนส่วนหนึ่งยังต้องใช้ไปในการให้ความร้อนตัววัตถุดิบเองอีกด้วย อัตราเร็วในการอบจึงค่อย ๆ ลดลงตามเวลาที่ผ่านไป

สภาพของความชื้นที่มีอยู่ภายในวัตถุดิบขึ้นเป็นปัจจัยที่สำคัญที่สุดที่มีอิทธิพลต่อกลไกการเคลื่อนที่ของความชื้น ในวัตถุดิบเปียกนอกจากจะมีความชื้นในรูปน้ำอิสระแล้ว ยังมีน้ำ Adsorption Water ที่เกาะติดกับพื้นผิวของแข็ง ความชื้น Bonding Water และไอน้ำในช่องว่าง นอกจากนี้ปริมาณน้ำตาลในมะละกออบแห้งเป็นที่ยอมรับของผู้บริโภคดังข้อมูลดังตาราง (Jain et al., 2011)

ตารางที่ 2-3 ค่าต่ำสุด ค่าสูงสุดของตัวแปรในกระบวนการอบส้มชิส

Parameter	Goal	Lower Limit	Upper Limit	Relative Important
Temperature (°C)	Minimize	30	50	Important
Concentration (°Brix)	Minimize	50	70	Important
Duration (Hrs)	Minimize	4	6	Important
Water Loss (%)	Maximize	23.02	44.5	Very Important
Sugar Gain (%)	Taget = 4.0	2.56	8.1	Extremely Important

ที่มา: Jain et al. (2011)

ข้อมูลค่าสูงสุดต่ำสุดของของค่า Temperature (°C) ค่า Comcentration (°Brix) และ ค่า Duration (Hrs) ส่งผลต่อปริมาณของน้ำในอาหารที่ลดลง (Water Loss) และปริมาณของแข็งที่เพิ่มขึ้น (Sugar Gain)

### งานวิจัยที่เกี่ยวข้องกับการทำแห้ง

Falade and Aworth (2005) ได้ศึกษาการถ่ายเทมวลสารระหว่างกระบวนการออสโมซิสของมะเฟืองและมะม่วง โดยแช่มะเฟืองในสารละลายซูโครสที่ความเข้มข้น 44, 52 และ 60 องศาบริกซ์ใช้อุณหภูมิ 27 และ 40 องศาเซลเซียส เป็นเวลา 8 ชั่วโมง และแช่มะม่วงในสารละลายซูโครสที่ความเข้มข้น 52, 60 และ 68 องศาบริกซ์ ใช้อุณหภูมิ 27 และ 40 องศาเซลเซียส เป็นเวลา 10 ชั่วโมง แสดงให้เห็นว่าเมื่อความเข้มข้นและอุณหภูมิของสารละลายน้ำตาลซูโครสสูงขึ้น อัตราการสูญเสียน้ำและอัตราการเพิ่มขึ้นของของแข็งมีแนวโน้มเพิ่มขึ้น ทั้งนี้เนื่องจากการเพิ่มระดับความเข้มข้นมีผลให้แรงดันออสโมติกสูงขึ้น ในขณะที่การเพิ่มอุณหภูมิมีผลให้การแพร่ของน้ำดีขึ้น โดยการทดลองนี้สอดคล้องกับงานวิจัยของ Falade et al. (2007) ซึ่งได้ทำการศึกษาผลของความเข้มข้นของสารละลายซูโครส 3 ระดับ ได้แก่ 40, 50 และ 60 องศาบริกซ์ และใช้อุณหภูมิของสารละลาย 3 ระดับคือ 20, 30 และ 40 องศาเซลเซียส ผลการศึกษาแสดงให้เห็นว่าเมื่อเพิ่มระดับความเข้มข้นของสารละลาย ค่าอัตราการสูญเสียน้ำและอัตราการเพิ่มขึ้นของของแข็งมีแนวโน้มเพิ่มขึ้น เนื่องจากมีแรงดันออสโมติกสูงขึ้น ส่วนการเพิ่มอุณหภูมิมีผลให้ความหนืดของสารละลายลดลง และยังเป็นการไล่อากาศที่อยู่ในโครงสร้างของเนื้อเยื่อ ทำให้การกำจัดน้ำด้วยแรงดันออสโมติก และการเคลื่อนที่ของของแข็งเข้าไปในเนื้อแดงได้ดีขึ้น (Falade and Aworth, 2005)

Mandala et al. (2005) ได้ศึกษาจลพลศาสตร์ของการอบแห้งแอปเปิ้ลที่ผ่านกระบวนการออสโมซิสด้วยสารละลายกลูโคสหรือซูโครสที่ความเข้มข้น 2 ระดับคือ 30 และ 45% แช่สารละลายเป็นเวลา 12 ชั่วโมง จากนั้นอบแห้งด้วยตู้อบแห้งแบบลมร้อนที่อุณหภูมิ 55 องศาเซลเซียส ผลการศึกษาแสดงให้เห็นว่าในช่วง 90 นาทีแรกของการอบแห้งความชื้นในชิ้นผลไม้ที่ผ่านการออสโมซิสในสารละลายกลูโคสจะลดลงอย่างรวดเร็วกว่าตัวอย่างที่ไม่ได้ผ่านการออสโมซิส แต่หลังจากช่วงเวลานี้อัตราการลดลงของความชื้นจะช้าลง สำหรับแอปเปิ้ลที่ผ่านการแช่ในสารละลายซูโครส ปรากฏว่าช่วง 40-50 นาทีแรกของการอบแห้ง ความชื้นจะลดลงอย่างรวดเร็ว จากนั้นอัตราการลดลงของความชื้นจะช้าลงเช่นเดียวกัน (Mandala et al., 2005)

Riva et al. (2005) ได้ศึกษาการอบแห้งชิ้นแอปปริคอตที่หั่นเป็นชิ้นลูกเต๋าหลังผ่านกระบวนการออสโมซิสในสารละลาย 3 ชนิดคือ สารละลายซูโครส 60% สารละลายซอร์บิทอลเข้มข้น 60% และสารละลายไอโซโทนิค (ซูโครส 13%) นาน 60 นาที เมื่อเปรียบเทียบอัตราการอบแห้งหลังผ่านการออสโมซิสในสารละลายซูโครสกับซอร์บิทอล แสดงให้เห็นว่าอัตราการอบแห้งใกล้เคียงกัน แต่ช่วงหลังอัตราการอบแห้งของแอปปริคอตที่ผ่านการแช่ในสารละลายน้ำตาลซูโครสจะลดลงต่ำเมื่อผ่านการแช่ในซอร์บิทอล เนื่องจากซูโครสเกิดการตกผลึกและขัดขวางการระเหยของน้ำในระหว่างกระบวนการอบแห้ง (Riva et al., 2005)

Zhang et al. (2007) ได้ศึกษาวิธีการประมาณค่าแบบจับกลุ่มอนุภาค ผลการศึกษาแสดงให้เห็นว่ามีการบรรจบกันอย่างรวดเร็วในช่วงระยะเริ่มต้นของการค้นหาแบบ Global Optimum แต่ขั้นตอนการค้นหาจะกลับกลายเป็นช้ามากเมื่อเข้าสู่กระบวนการค้นหาแบบ Global Optimum ในทางกลับกันหากใช้วิธีการไล่ระดับจากมากไปหาน้อยอนุภาคสามารถบรรจบกันได้เร็วขึ้นในการค้นหา Global Optimum ในขณะที่ความแม่นยำของการมาบรรจบกันของอนุภาคเพิ่มขึ้น ดังนั้นในบทความนี้ได้นำเสนอวิธีการประมาณค่าแบบไฮบริดโดยการผสมผสานระหว่างอัลกอริทึมของการ



ประมาณค่าแบบจับกลุ่มอนุภาค (PSO) กับอัลกอริทึมของการเรียนรู้แบบแพร่ย้อนกลับ (BP) เรียก อัลกอริทึมนี้ว่า PSO-BP และมีการฝึกเรียนรู้น้ำหนักของเครือข่ายประสาทด้วยวิธี Feedforward (FNN) ไฮบริดอัลกอริทึมไม่เพียงแต่มีความสามารถในการค้นหาแบบ Global เท่านั้น แต่ยังมี ความสามารถค้นหาแบบ Local ด้วยซึ่งเป็นจุดเด่นของอัลกอริทึมการเรียนรู้แบบแพร่ย้อนกลับ (BP) และเสนอกลยุทธ์ในการเลือก Inertial Weight สำหรับอัลกอริทึม PSO ส่วนอัลกอริทึม PSO-BP ใช้ วิธีการแก้ปัญหาเพื่อเปลี่ยนผ่านจากการค้นหาแบบจับกลุ่มอนุภาคเป็นการค้นหาแบบไล่ระดับจาก มากไปหาน้อย จากผลการทดลองแสดงให้เห็นว่าข้อเสนอของอัลกอริทึมไฮบริด PSO-BP ดีกว่าการ ประมาณค่าของอัลกอริทึมแบบจับกลุ่มอนุภาคที่มีการปรับปรุง (APSOA) ส่วนอัลกอริทึมของ BP สามารถหาคำตอบได้อย่างรวดเร็วและแม่นยำ (Zhang, Zhang, Lok, & Lyu, 2007)

Moghaddam and Khajeh (2011) ได้ศึกษาเปรียบเทียบความสามารถในการประมาณ ค่าของพื้นผิวตอบสนองต่อวิธีการ (RSM) และเครือข่ายประสาทเทียม (ANN) จากผลการประมาณค่า ปริมาณของสังกะสีที่ได้จากการสกัดจากตัวอย่างปลาโดยใช้ไมโครเวฟช่วยในกระบวนการสกัด โดย ออกแบบการทดลองแบบ Box-Behnken กำหนดระดับของตัวแปรที่ 3 ระดับจำนวน 4 ตัวแปร ปริมาณของสังกะสีที่สกัดได้ขึ้นอยู่กับตัวแปรอิสระทั้งสิ้นสี่ตัวคือ อำนาจการฉายรังสี เวลาการฉายรังสี ความเข้มข้นของกรดไนตริกและอุณหภูมิ เมื่อนำความสามารถในการคาดการณ์ของทั้งสองวิธีการที่ ได้มาเปรียบเทียบกัน ผลการศึกษาแสดงให้เห็นว่าการประมาณค่าของเครือข่ายประสาทเทียม (ANN) มีความแม่นยำมากกว่าในการประมาณค่าปริมาณของสังกะสีในการเปรียบเทียบกับค่าประมาณค่า ของพื้นผิวตอบสนองต่อวิธีการ (RSM) (Moghaddam & Khajeh, 2011b)

Enitan and Adeyemo (2011) ได้ศึกษาแนวทางการนำอัลกอริทึมวิวัฒนาการมาใช้ใน อุตสาหกรรมอาหาร อัลกอริทึมวิวัฒนาการมีการนำไปใช้กันอย่างแพร่หลายในการหาผลลัพธ์ที่ เหมาะสม เนื่องจากการใช้งานง่ายและสามารถแก้ปัญหาได้ในการสร้างแบบจำลองเพียงครั้งเดียว นิยมนำไปใช้สำหรับการตัดสินใจในอุตสาหกรรมแปรรูปอาหาร ทั้งในรูปแบบการหาผลลัพธ์ที่ เหมาะสมที่มีข้อจำกัดและไม่มีข้อจำกัด บทความนี้ได้นำเสนอเทคนิคการพัฒนาอัลกอริทึมวิวัฒนาการที่ใช้ในอุตสาหกรรมแปรรูปอาหาร เช่น เจเนติกอัลกอริทึม เครือข่ายประสาทเทียม อนุพันธ์ วิวัฒนาการและฟิชชิลอจิกโดยอ้างอิงจากการนำไปประยุกต์ใช้ในการแปรรูปอาหาร กระบวนการแปร รูปด้วยความร้อน การประกันคุณภาพของอาหาร การออกแบบกระบวนการผลิต การอบแห้ง การ หมักและกระบวนการเติมไฮโดรเจน โดยเปรียบเทียบความแตกต่างกันของอัลกอริทึมวิวัฒนาการใน ด้านเทคนิคและข้อสังเกตเกี่ยวกับขอบเขตการนำไปประยุกต์ใช้เพื่อหาหาผลลัพธ์ที่เหมาะสมใน กระบวนการแปรรูปอาหาร (Enitan & Adeyemo, 2011)

Imanirad, Yang and Yeomans (2013) ได้ศึกษาอัลกอริทึมหิ่งห้อย (Firefly Algorithm) เพื่อหาค่าพารามิเตอร์ที่สามารถดึงน้ำออกได้ดีที่สุดในกระบวนการออสโมซิสของ มะละกอ ปกติแล้วรูปแบบการทำงานของตัวแบบการดึงน้ำออกแบบออสโมซิสนั้นดำเนินการด้วย เทคนิคพื้นผิวตอบสนอง ต่อมารูปแบบของตัวแบบการหาผลลัพธ์ที่เหมาะสมได้รับการปรับปรุงโดยมี เป้าหมายให้สามารถแก้ปัญหาที่ไม่เป็นเชิงเส้นได้ หิ่งห้อยอัลกอริทึมเป็นทางเลือกหนึ่งในหลาย ๆ ทางเลือกต่าง ๆ ที่สามารถแก้ปัญหาที่ไม่เป็นเชิงเส้นได้ หิ่งห้อยอัลกอริทึมมีประสิทธิภาพในการ คำนวณดีกว่าวิธี Metaheuristics อื่น ๆ ที่ใช้กันทั่วไปเช่น เจเนติกอัลกอริทึม การสร้างแบบจำลอง

และการปรับปรุงการหาผลลัพธ์ที่เหมาะสมแบบจับกลุ่มอนุภาค (Particle Swarm Optimization) ดังนั้นวิธีการหึ่งห้อยอัลกอริทึมเป็นวิธีการคำนวณที่มีประสิทธิภาพมาก ผลการศึกษาแสดงให้เห็นว่าสามารถแก้ปัญหาการกำหนดค่าที่เหมาะสมสำหรับพารามิเตอร์ในกระบวนการออสโมติกดีกว่าการหาค่าที่เหมาะสมจากวิธีการก่อนหน้านี้ทั้งหมด (Imanirad, Yang, & Yeomans, 2013)

Granato and Maria (2014) ได้ศึกษาการใช้งานและการประยุกต์ใช้แบบจำลองทางคณิตศาสตร์ได้เพิ่มขึ้นในทางเคมีและวิทยาศาสตร์และเทคโนโลยีการอาหาร นับว่าเป็นเรื่องปกติที่นักวิจัยมักจะต้องการหาหนึ่งตำแหน่งเพื่อใช้เป็นแนวทางการในการทดสอบและการเลือกตัวแปรที่จะพัฒนาและเพิ่มประสิทธิภาพของผลิตภัณฑ์และกระบวนการ บทความนี้มีวัตถุประสงค์เพื่อให้ข้อมูลทางสถิติที่เกี่ยวข้องกับการสร้างแบบจำลองทางคณิตศาสตร์ของกระบวนการใช้การออกแบบการทดลองตามรูปแบบการวิเคราะห์การถดถอยที่เรียกว่าวิธีการการตอบสนองต่อพื้นผิว (RSM) และเพื่อรวบรวมแนวคิดที่เกี่ยวข้องจากงานวิจัยที่ตีพิมพ์เมื่อเร็ว ๆ นี้ โดยอยู่บนพื้นฐานของการเพิ่มประสิทธิภาพ RSM ของผลิตภัณฑ์และกระบวนการ โดยให้ความสนใจเป็นพิเศษในด้านจุลชีววิทยาการวิเคราะห์ทางประสาทสัมผัส การพัฒนาอาหารและโภชนาการ (Granato & Calado, 2014)

จากการศึกษาเอกสารงานวิจัยที่เกี่ยวข้องเกี่ยวกับการทำแห้งแบบออสโมซิส แสดงให้เห็นว่ามีการศึกษาและนำวิธีการทำแห้งแบบออสโมซิสไปใช้กันอย่างแพร่หลาย เช่น ศึกษาการถ่ายเทมวลสารระหว่างกระบวนการออสโมซิสของมะเฟืองและมะม่วง (Falade and Aworth, 2005) ศึกษาจลพลศาสตร์ของการอบแห้งแอปเปิ้ลที่ผ่านกระบวนการออสโมซิส (Mandala et al., 2005) และศึกษาการอบแห้งขึ้นแบริคอต (Riva et al., 2005) นอกจากนี้ยังมีงานวิจัยที่มีการนำอัลกอริทึมเข้ามาช่วยในการหาค่าที่เหมาะสมของการทำแห้งแบบออสโมซิส เช่น ศึกษาวิธีการประมาณค่าแบบจับกลุ่มอนุภาค (Zhang, Zhang, Lok, & Lyu, 2007) ศึกษาเปรียบเทียบความสามารถในการประมาณค่าของพื้นผิวตอบสนองต่อวิธีการ (RSM) และเครือข่ายประสาทเทียม (ANN) (Moghaddam & Khajeh, 2011b) ศึกษาแนวทางการนำอัลกอริทึมวิวัฒนาการมาใช้ในอุตสาหกรรมอาหาร (Enitan & Adeyemo, 2011) ศึกษาการหาค่าที่เหมาะสมของการทำแห้งแบบออสโมซิสด้วยอัลกอริทึมหึ่งห้อย (Firefly Algorithm) (Imanirad, Yang, & Yeomans, 2013) และศึกษาการใช้งานและการประยุกต์แบบจำลองทางคณิตศาสตร์ได้เพิ่มขึ้นในทางเคมีและวิทยาศาสตร์และเทคโนโลยีการอาหาร (Granato & Calado, 2014) การศึกษางานวิจัยเกี่ยวกับการทำแห้งแบบออสโมซิสแสดงให้เห็นอย่างชัดเจนว่า แนวโน้มการนำอัลกอริทึมเข้ามาช่วยในการหาค่าที่เหมาะสมมีจำนวนเพิ่มมากขึ้น โดยมีสาเหตุมาจากความแม่นยำ ความสะดวกและรวดเร็วในการหาค่าที่เหมาะสม นอกจากนี้ยังพบว่าค่าที่เหมาะสมที่ได้จากอัลกอริทึมจะมีความแม่นยำยิ่งขึ้น เมื่อนำอัลกอริทึมไปผ่านกระบวนการพัฒนาหรือปรับปรุงก่อนนำไปใช้

### บทที่ 3

## วิธีดำเนินการวิจัย

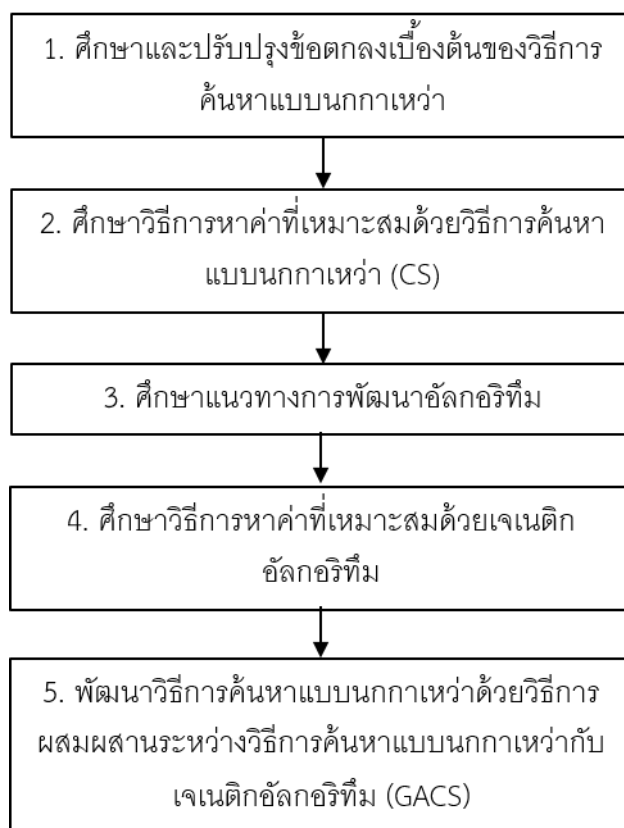
การศึกษานี้มีวัตถุประสงค์เพื่อพัฒนาวิธีการค้นหาแบบนกกาเหว่าโดยการผสมผสานด้วยเจเนติกอัลกอริทึม (CSGA) สำหรับหาค่าที่เหมาะสมของการทำแห้งมะละกอแบบออสโมซิส และเปรียบเทียบประสิทธิภาพกับวิธีการค้นหาแบบนกกาเหว่า (CS) และวิธีพื้นผิวตอบสนอง (RSM) ดำเนินการศึกษา โดยนำวิธีการค้นหาแบบนกกาเหว่า (CS) ไปผสมผสานกับเจเนติกอัลกอริทึม แล้วทดสอบการทำงานของอัลกอริทึมด้วยฟังก์ชันมาตรฐาน Sphere Model, Schwefel's Problem, Schwefel's Problem, Schwefel's Problem และ Generalized Rosenbrock's Function โดยเปรียบเทียบค่าที่เหมาะสมและเวลาที่ใช้ในการหาค่าที่เหมาะสม หลังจากนั้นเปรียบเทียบค่าความคลาดเคลื่อนของค่าที่เหมาะสมที่ได้จากอัลกอริทึม CSGA, CA และ RSM กับค่าที่ได้จากการทดลองทำแห้งมะละกอโดยใช้แผนการทดลองแบบบ็อกซ์-เบนเคน (Yao et al., 1999) ประกอบด้วยปัจจัยดังนี้ อุณหภูมิของน้ำเชื่อม (C) เท่ากับ 50, 60 และ 70 °C ระดับความเข้มข้นของน้ำเชื่อม ( $\theta$ ) เท่ากับ 30, 40 และ 50 °Brix และที่ระยะเวลา (T) เท่ากับ 4, 5 และ 6 ชั่วโมง สามารถแบ่งเป็นระยะการดำเนินงานดังนี้

- ระยะที่ 1 การพัฒนาวิธีการค้นหาแบบนกกาเหว่าโดยการผสมผสานด้วยเจเนติกอัลกอริทึม
- ระยะที่ 2 การเปรียบเทียบประสิทธิภาพของวิธี CSGA ที่พัฒนาขึ้นกับวิธี CS และวิธี RSM
- ระยะที่ 3 การหาค่าที่เหมาะสมของการทำแห้งมะละกอแบบออสโมซิส

#### ระยะที่ 1 การพัฒนาวิธีการค้นหาแบบนกกาเหว่าโดยการผสมผสานด้วยเจเนติกอัลกอริทึม

วิธีการหาค่าที่เหมาะสมของนกกาเหว่า เป็นวิธีการหาค่าที่เหมาะสม ที่จัดอยู่ในกลุ่มเมตาฮิวริสติก โดยอาศัยการเลียนแบบพฤติกรรมการค้นหารัง (ค่าที่เหมาะสมหรือคำตอบ) ที่มีความเหมาะสมสำหรับวางไข่ของนกกาเหว่า (เลือกค่าที่เหมาะสมหรือคำตอบ) นับได้ว่าเป็นวิธีหาค่าที่เหมาะสมที่มีประสิทธิภาพสูงวิธีหนึ่ง ประกอบกับมีขั้นตอนที่เรียบง่ายและมีจำนวนพารามิเตอร์ค่อนข้างน้อยจึงได้รับความนิยมอย่างแพร่หลาย อย่างไรก็ตามในการนำวิธีการค้นหาแบบนกกาเหว่าไปใช้งานนั้นยังพบปัญหาในเรื่องของค่าที่เหมาะสมที่มักจะติดอยู่ใน Local Optima ส่งผลให้ค่าที่เหมาะสมที่ได้มีแนวโน้มที่จะไม่ได้เป็นค่าที่เหมาะสมในระดับสากล (ค่าที่เหมาะสมหรือคำตอบที่เหมาะสม) เพื่อแก้ไขปัญหาดังกล่าวและเพิ่มประสิทธิภาพการทำงานของอัลกอริทึม การศึกษาวิจัยนี้ นำวิธีการค้นหาแบบนกกาเหว่ามาพัฒนาให้มีความเหมาะสมต่อบริบทของการทำแห้งมะละกอแบบออสโมซิส โดยเลือกใช้วิธีการนำไปผสมผสานกับเจเนติกอัลกอริทึม เนื่องจากเจเนติกอัลกอริทึมเป็นวิธีการหาค่าที่เหมาะสมที่มีจุดเด่นในด้านการค้นหาค่าที่เหมาะสมระดับสากล (Global Optimization) สามารถเข้าไปเสริมในจุดด้อยของวิธีการค้นหาแบบนกกาเหว่าได้เป็นอย่างดี นอกจากนี้เจเนติกอัลกอริทึมยังได้รับความนิยมนำไปผสมผสาน (Hybrid) กับอัลกอริทึมอื่นอยู่เสมอ

โดยมีขั้นตอนการพัฒนาวิธีการค้นหาแบบนกกาเหว่าด้วยวิธีการผสมผสานกับเจเนติกอัลกอริทึมดังต่อไปนี้



ภาพที่ 3-1 ขั้นตอนการพัฒนาวิธีการหาค่าที่เหมาะสมแบบผสมผสาน CSGA

การพัฒนาวิธีการหาค่าที่เหมาะสมแบบผสมผสานระหว่างวิธีการค้นหาแบบนกกาเหว่ากับเจเนติกอัลกอริทึม (CSGA) มีขั้นตอนการดำเนินงานดังนี้

1. ศึกษาและปรับปรุงข้อตกลงเบื้องต้นของวิธีการค้นหาแบบนกกาเหว่าจากเอกสารและงานวิจัยแสดงให้เห็นว่าแนวทางหรือวิธีการเพิ่มความสามารถให้กับวิธีการค้นหาแบบนกกาเหว่า เพื่อเพิ่มความสามารถในการนำไปใช้สำหรับหาค่าที่เหมาะสมของปัญหาที่มีฟังก์ชันวัตถุประสงค์มากกว่า 1 ฟังก์ชันวัตถุประสงค์วิธีการหาค่าที่เหมาะสมนั้นต้องสามารถดำเนินการได้พร้อมกันทั้งสองฟังก์ชันวัตถุประสงค์ ผู้วิจัยได้พัฒนาโดยอาศัยแนวทางจากงานวิจัยของ Yang and Deb (2013) ที่ศึกษาวิจัยเรื่อง Multiobjective Cuckoo Search for Design Optimization โดยทำการปรับเปลี่ยนข้อตกลงเบื้องต้นของวิธีการค้นหาแบบนกกาเหว่า ในงานวิจัยนี้จึงได้ทำการปรับปรุงข้อตกลงเบื้องต้นให้มีความเหมาะสมกับการหาค่าที่เหมาะสมของการทำหิ้งมะละกอแบบออสโมซิส โดยมีขั้นตอนดังนี้

1.1 ศึกษาข้อตกลงเบื้องต้นของวิธีการค้นหาแบบนกกาเหว่ามาตรฐาน มีจำนวน 3 ข้อ โดยมีรายละเอียดดังต่อไปนี้

ข้อที่ 1 นกกาเหว่าสามารถวางไข่ได้ 1 ฟองต่อครั้ง (สามารถเลือกได้ 1 ชุดคำตอบหรือค่าที่เหมาะสมต่อครั้ง) โดยวางไข่ไว้ในรังที่ได้ทำการคัดเลือกแล้วว่ามีความเหมาะสม (เป็นชุดคำตอบหรือค่าที่เหมาะสมต่อฟังก์ชันวัตถุประสงค์ของแต่ละปัญหา)

ข้อที่ 2 รังที่ดี (ชุดคำตอบหรือค่าที่เหมาะสมต่อฟังก์ชันวัตถุประสงค์ของแต่ละปัญหา) และไข่ที่มีคุณภาพสูงจะได้รับการคัดเลือกให้เป็นนกขุนทดไป

ข้อที่ 3 กำหนดให้จำนวนรังที่นกสามารถเลือกใช้ได้เท่ากับ  $n$  และค่าความน่าจะเป็นที่ไข่ของนกกาเหว่าจะถูกค้นพบโดยนกเจ้าของรังเท่ากับ  $p_0$  โดยมีค่าอยู่ระหว่าง 0 ถึง 1

ข้อตกลงเบื้องต้นของวิธีการค้นหาแบบนกกาเหว่าที่กล่าวไปแล้วนั้น เป็นวิธีการหาค่าที่เหมาะสมที่ใช้สำหรับการหาค่าที่ใช้สำหรับปัญหาที่ต้องการค่าที่เหมาะสมเพียงค่าเดียว (คำตอบเดียว) หรือมีฟังก์ชันวัตถุประสงค์เพียงฟังก์ชันเดียว หากต้องการนำไปใช้กับปัญหาที่มีค่าที่เหมาะสมหลายค่า (หลายคำตอบ) หรือปัญหาที่มีฟังก์ชันวัตถุประสงค์มากกว่า 1 ฟังก์ชันวัตถุประสงค์นั้น สามารถทำได้โดยปรับเปลี่ยนข้อตกลงเบื้องต้นของวิธีการค้นหาแบบนกกาเหว่าดังต่อไปนี้

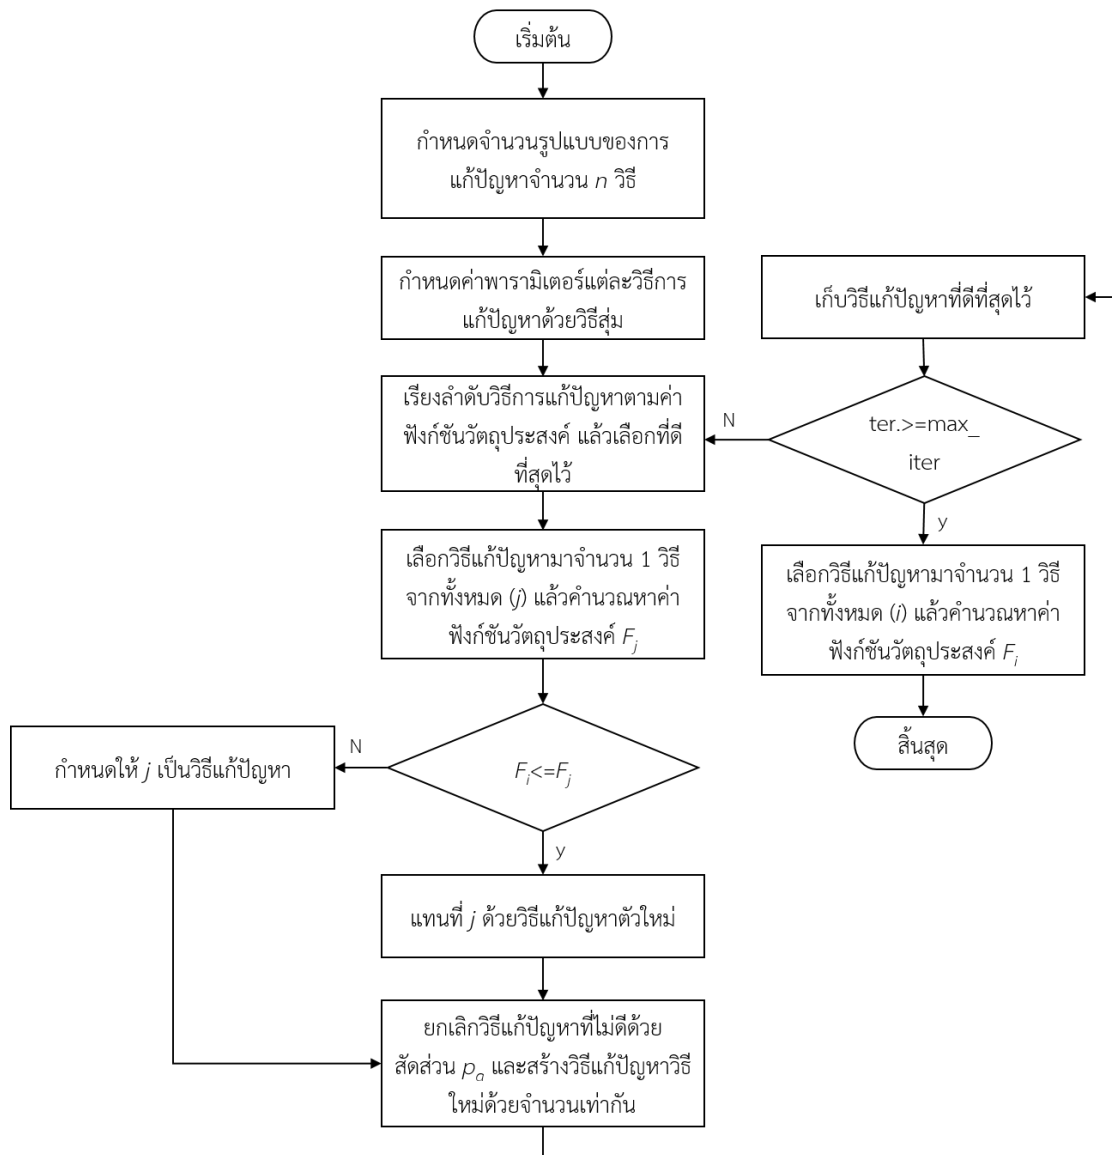
1.2 ทำการปรับปรุงข้อตกลงเบื้องต้นของวิธีการค้นหาแบบนกกาเหว่ามาตรฐาน ให้สามารถหาค่าที่เหมาะสมจากปัญหาที่มีฟังก์ชันวัตถุประสงค์มากกว่า 1 ฟังก์ชันวัตถุประสงค์ โดยทำการปรับปรุงข้อตกลงเบื้องต้นข้อที่ 1 จากเดิมที่กำหนดให้นกกาเหว่าสามารถวางไข่ได้ครั้งละหนึ่งฟองปรับเปลี่ยนเป็นกำหนดให้นกกาเหว่าสามารถวางไข่ได้มากกว่า 1 ฟองต่อครั้ง และสามารถวางไข่ลงในรังที่ได้เลือกสุ่มไว้จำนวนมากกว่า 1 รัง (ชุดคำตอบ) สำหรับข้อตกลงเบื้องต้นข้อที่ 2 และข้อที่ 3 นั้น ไม่มีการเปลี่ยนแปลง

ข้อที่ 2 รังที่ดี (ชุดคำตอบที่มีความเหมาะสมต่อฟังก์ชันวัตถุประสงค์ของแต่ละปัญหา) และไข่ที่มีคุณภาพสูงจะได้รับการคัดเลือกให้เป็นนกขุนทดไป

ข้อที่ 3 กำหนดให้จำนวนรังที่นกสามารถเลือกใช้ได้เท่ากับ  $n$  และค่าความน่าจะเป็นที่ไข่ของนกกาเหว่าจะถูกค้นพบโดยนกเจ้าของรังเท่ากับ  $p_0$  โดยมีค่าอยู่ระหว่าง 0 ถึง 1

เมื่อทำการปรับปรุงข้อตกลงเบื้องต้นของวิธีการค้นหาแบบนกกาเหว่าเรียบร้อยแล้ว การหาค่าที่เหมาะสมของวิธีการค้นหาแบบนกกาเหว่านั้นสามารถนำเสนอค่าที่เหมาะสมได้ 2 ค่า (ชุดคำตอบ) ต่อการวางไข่ของนกกาเหว่าหนึ่งครั้ง (หาค่าที่เหมาะสมด้วยฟังก์ชันวัตถุประสงค์ 2 ฟังก์ชันพร้อมกัน) โดยที่ไข่แต่ละฟองนั้นจะเป็นค่าที่เหมาะสมของฟังก์ชันวัตถุประสงค์ที่ 1 และค่าที่เหมาะสมของฟังก์ชันวัตถุประสงค์ที่ 2 (Yang & Deb, 2013)

2. ศึกษาวิธีการหาค่าที่เหมาะสมด้วยวิธีการค้นหาแบบนกกาเหว่า (CS) แบบมาตรฐาน จากเอกสารของ Yang and Deb (2013) แสดงให้เห็นว่า ขั้นตอนการทำงานของวิธีการค้นหาแบบนกกาเหว่าในการค้นหาคำตอบของปัญหา สามารถนำมาเขียนเป็นขั้นตอนได้ 11 ขั้นตอน โดยมีรายละเอียดของขั้นตอนการทำงานของวิธีการค้นหาแบบนกกาเหว่า ดังต่อไปนี้



ภาพที่ 3-2 ผังขั้นตอนวิธีการค้นหาแบบนกกาเหว่า (CS)

### ขั้นตอนการทำงานของวิธีการค้นหาของนกกาเหว่า (CS)

(1) กำหนดจำนวนรูปแบบของการแก้ปัญหาจำนวน  $n$  วิธี โดยการกำหนดให้จำนวนรังของนกกาเหว่าเท่ากับจำนวน  $n$  ซึ่งหมายถึงจำนวนวิธีการแก้ปัญหาตามปัญหาที่กำหนดไว้เพื่อหาค่าที่เหมาะสมที่สุด

(2) กำหนดค่าพารามิเตอร์แต่ละวิธีการแก้ปัญหาด้วยวิธีสุ่ม กล่าวคือ วิธีการแก้ปัญหาตามข้อ (1) จะต้องมีการกำหนดค่าเริ่มต้นให้กับแต่ละวิธี ด้วยวิธีกำหนดค่าเลขสุ่ม ตามขอบเขตของข้อมูลที่กำหนด

(3) เลือกวิธีแก้ปัญหามาจำนวน 1 วิธีจากทั้งหมด ( $i$ ) แล้วคำนวณหาค่าฟังก์ชันวัตถุประสงค์  $F_i$  โดยการเลือกวิธีแก้ปัญหามาจากข้อ (2) มา 1 วิธี จากวิธีการแก้ปัญหามีอยู่ โดยกำหนดให้เป็นวิธีที่  $i$  จากนั้นทำการคำนวณหาค่าฟังก์ชันวัตถุประสงค์ตามที่กำหนดไว้ กำหนดให้เป็น  $F_i$

(4) เลือกวิธีแก้ปัญหามาจำนวน 1 วิธีจากทั้งหมด ( $j$ ) แล้วคำนวณหาค่าฟังก์ชันวัตถุประสงค์  $F_j$  โดยการเลือกวิธีแก้ปัญหามาจากข้อ (2) มา 1 วิธีจากวิธีการแก้ปัญหามีอยู่ โดยกำหนดให้เป็นวิธีที่  $j$  จากนั้นทำการคำนวณหาค่าฟังก์ชันวัตถุประสงค์ตามที่กำหนดไว้ กำหนดให้เป็น  $F_j$

(5)  $F_i \leq F_j$  เปรียบเทียบค่าฟังก์ชันวัตถุประสงค์ ระหว่างค่า  $F_i$  และ  $F_j$  ว่า  $F_i \leq F_j$  หรือไม่

(6) แทนที่  $j$  ด้วยวิธีแก้ปัญหาคือใหม่ เมื่อ  $F_i \leq F_j$  เป็นจริง แล้วไปทำขั้นตอนที่ (8)

(7) กำหนดให้  $j$  เป็นวิธีแก้ปัญหาคือใหม่ เมื่อ  $F_i \leq F_j$  ไม่เป็นจริง แล้วไปทำขั้นตอนที่ (8)

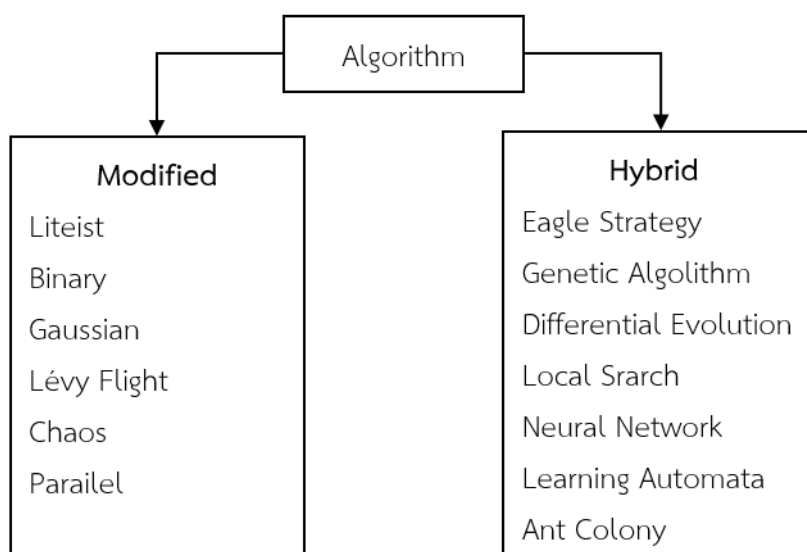
(8) ยกเลิกวิธีแก้ปัญหาคือที่ไม่ดีด้วยสัดส่วน  $p_0$  และสร้างวิธีแก้ปัญหาคือใหม่ด้วยจำนวนเท่ากัน

(9) เก็บวิธีแก้ปัญหาคือที่ดีที่สุดไว้

(10)  $Iter \geq Max\_Iter$  ทำการตรวจสอบตามเงื่อนไขว่าเป็นจริงหรือไม่ เมื่อ  $Iter \geq Max\_Iter$  เป็นจริงแล้วไปทำขั้นตอนที่ (11) และเมื่อ  $Iter \geq Max\_Iter$  ไม่เป็นจริงไปทำขั้นตอนที่ (3)

(11) เรียงลำดับวิธีแก้ปัญหาคือทั้งหมดตามค่าฟังก์ชันวัตถุประสงค์ แล้วเลือกวิธีที่ดีที่สุดไว้

3. ศึกษาแนวทางการพัฒนาอัลกอริทึมที่มีความเหมาะสมสำหรับนำมาปรับปรุงวิธีการค้นหาแบบนกกาเหว่า เพื่อเพิ่มประสิทธิภาพในการค้นหาค่าตอบในระดับสากลอันเป็นข้อบกพร่องที่สำคัญของวิธีการค้นหาแบบนกกาเหว่า นอกจากนี้ยังปรับปรุงให้อัลกอริทึมสามารถนำไปหาค่าที่เหมาะสมของการทำแห้งแบบออสโมซิส โดยการศึกษาจากเอกสารและงานวิจัยที่เกี่ยวข้องสามารถสรุปได้ดังนี้



ภาพที่ 3-3 ผังแนวทางการปรับปรุงวิธีการค้นหาของนกกาเหว่า (Kanagaraj et al., 2013)

การพัฒนาอัลกอริทึมสามารถดำเนินการได้หลายวิธี โดยสามารถสรุปตามแนวทางของ ฟิสเตอร์และคณะได้เป็นสองวิธีดังต่อไปนี้ วิธีที่ 1 เป็นการนำอัลกอริทึมมาดัดแปลง (Modified) ซึ่งเป็นวิธีการพัฒนาอัลกอริทึมโดยวิธีการปรับเปลี่ยนหรือปรับปรุงเทคนิคของอัลกอริทึมที่ใช้ในการหาค่าที่เหมาะสมจากวิธีดั้งเดิมเป็นวิธีการใหม่ที่มีความสามารถในการหาค่าที่เหมาะสมที่ดีกว่า สำหรับเทคนิคหรือวิธีการใหม่ที่ได้รับคามนิยมนำไปใช้ปรับปรุง ได้แก่ Binary, Chaos, Paraillel และ Gaussian เป็นต้น ในส่วนของวิธีที่ 2 นั้นเป็นการพัฒนาอัลกอริทึมด้วยวิธีการผสมผสาน (Hybrid) เป็นการนำอัลกอริทึมที่มีความสามารถโดดเด่นในแต่ละด้านมาผสมผสานเข้าด้วยกัน อัลกอริทึมที่นิยมนำมาผสมผสานกับอัลกอริทึม ๆ ได้แก่ Ant Colony, Learning Automata, Neural Network, Genetic Algorithm, Local Search และ Eagle Strategy เป็นต้น สำหรับหลักการพัฒนาอัลกอริทึมด้วยวิธีการผสมผสานนั้น เป็นวิธีการเพิ่มประสิทธิภาพด้วยการนำเอาจุดเด่นของอัลกอริทึมมาแต่ละตัวมาผสมผสานรวมเข้าไว้ในอัลกอริทึมเดียวกัน ทำให้ได้อัลกอริทึมใหม่มีประสิทธิภาพในการหาค่าที่เหมาะสมดีขึ้นและอัลกอริทึมมีความเหมาะสมต่องานที่ต้องการนำไปใช้ (Fister et al., 2013)

จากการศึกษาข้อมูลและงานวิจัยที่เกี่ยวข้องแล้ว แสดงให้เห็นว่า แนวทางที่เหมาะสมในการพัฒนาวิธีการค้นหาแบบนกกาเหว่านั้น คือการพัฒนาด้วยวิธีการผสมผสานกับอัลกอริทึมอื่น ๆ อย่างน้อย 1 อัลกอริทึม เนื่องจากการพัฒนาอัลกอริทึมด้วยวิธีการผสมผสานมีความเรียบง่าย สามารถรวบรวมจุดเด่นของแต่ละอัลกอริทึมเข้าไว้ด้วยกันได้เป็นอย่างดี สามารถดำเนินการได้ง่ายไม่ซับซ้อน และมีจำนวนพารามิเตอร์ที่ต้องทำการปรับค่าค่อนข้างน้อย แต่กลับสามารถหาค่าที่เหมาะสมได้อย่างรวดเร็วและมีความแม่นยำสูงกว่าอัลกอริทึมดั้งเดิม ดังนั้นเมื่อพิจารณาข้อดีและข้อเสียแล้ว สรุปได้ว่า แนวทางการเพิ่มประสิทธิภาพในการหาค่าที่เหมาะสมด้วยวิธีการค้นหาแบบนกกาเหว่าคือวิธีการผสมผสานกับอัลกอริทึมที่มีความเหมาะสม เช่น Ant Colony, Learning Automata, Neural Network, Genetic Algorithm, Local Search และ Eagle Strategy เป็นต้น



จากการศึกษาข้อมูลและงานวิจัยที่เกี่ยวข้อง แสดงให้เห็นว่า อัลกอริทึมที่มีความเหมาะสมในการนำมาผสมผสานกับวิธีการค้นหาแบบนกกาเหว่านั้นคือ เจเนติกอัลกอริทึม เนื่องจากเจเนติกอัลกอริทึมมีจุดเด่นตรงที่สามารถหาค่าที่เหมาะสมในระดับสากลได้ค่อนข้างดี เมื่อนำมาผสมผสานกับวิธีการค้นหาแบบนกกาเหว่านั้นแล้ว จะสามารถเข้ามาชดเชยความสามารถในด้านการหาค่าที่เหมาะสมในระดับสากลของอัลกอริทึมผสมผสาน CSGA (Cuckoo Search Genetic Algorithm) ได้เป็นอย่างดี ประกอบกับความเรียบง่ายของอัลกอริทึม มีจำนวนพารามิเตอร์ที่ต้องทำการปรับค่าน้อย และความรวดเร็วในการหาค่าที่เหมาะสมได้อย่างรวดเร็ว โดยไม่มีข้อจำกัดเกี่ยวกับขนาดของข้อมูล (ข้อมูลที่มีขนาดใหญ่หรือขนาดเล็ก) เมื่อนำวิธีการค้นหาแบบนกกาเหว่ามาทำการผสมผสานกับเจเนติกอัลกอริทึมแล้ว จะสามารถลดความน่าจะเป็นของค่าที่เหมาะสมที่ได้จากวิธีการค้นหาแบบนกกาเหว่า ที่เข้าไปติดอยู่ในขอบเขตของค่าที่เหมาะสม ในระดับท้องถิ่น (Trapped in Local Optima) หากสามารถลดโอกาสที่ผลลัพธ์เข้าไปตกอยู่ในขอบเขตของค่าที่เหมาะสมในระดับท้องถิ่น จะทำให้ค่าที่เหมาะสมที่ได้จากอัลกอริทึมผสมผสานระหว่างวิธีการค้นหาแบบนกกาเหว่ากับเจเนติกอัลกอริทึม นั้นมีโอกาสที่จะเป็นค่าที่เหมาะสมในระดับสากลสูงขึ้น ส่งผลให้ความคลาดเคลื่อนของค่าที่เหมาะสมที่ได้ มีค่าใกล้เคียงกับค่าของค่าที่เหมาะสมที่แท้จริงที่ควรจะเป็น ดังนั้นค่าที่เหมาะสมที่ได้จากการทำแท่งมะละกอแบบออสโมซิสของอัลกอริทึมผสมผสานนั้นจะมีค่าใกล้เคียงกับค่าที่เหมาะสมที่ได้จากการทำแท่งมะละกอแบบออสโมซิสที่ได้จากการทดลอง เพื่อเป็นการเพิ่มขีดความสามารถในการหาค่าที่เหมาะสมในระดับสากลให้กับวิธีการค้นหาแบบนกกาเหว่า การศึกษาวิจัยในครั้งนี้ได้ทำการการผสมผสานระหว่างวิธีการค้นหาแบบนกกาเหว่ากับเจเนติกอัลกอริทึม ส่งผลดีต่อประสิทธิภาพในการทำงานของอัลกอริทึมที่พัฒนาขึ้นมาใหม่ (Fister et al., 2013)

4. เจเนติกอัลกอริทึมเป็นวิธีการหาค่าที่เหมาะสมแบบเฟ้นสุ่มด้วยการเลียนแบบหลักการถ่ายทอดทางพันธุกรรมของธรรมชาติในการหาค่าเหมาะสม โดยอาศัยวิธีการสมมติจุดคำตอบขึ้นมาหลาย ๆ จุดก่อน แล้วนำมาประยุกต์เข้ากับหลักการพื้นฐานของเจเนติกอัลกอริทึม เพื่อค้นหาจุดที่เหมาะสมที่สุดซึ่งเป็นจุดที่มีโอกาสที่จะอยู่รอดมากที่สุด สามารถการเพิ่มประสิทธิภาพในการหาค่าที่เหมาะสมให้ดียิ่งขึ้นในแต่ละรุ่นของการถ่ายทอดทางพันธุกรรม สำหรับในแต่ละรุ่นของการถ่ายทอดจะมีการประเมินความเหมาะสมของจุดคำตอบแต่ละจุด แล้วพิจารณาเลือกชุดคำตอบใหม่จากค่าความเหมาะสมนี้โดยอาศัยวิธีการทางพันธุศาสตร์มาประยุกต์กับในเจเนติกอัลกอริทึม โดยมีหลักการพื้นฐานของอัลกอริทึมอยู่ที่การสืบพันธุ์ (Reproduction) ซึ่งประกอบด้วยปฏิบัติการการทางพันธุกรรม ดังต่อไปนี้ การรีโพรดักชัน การครอสโอเวอร์ (Crossover) และการผ่าเหล่า (Mutation) การรีโพรดักชันเป็นขั้นตอนที่จะทำการคัดเลือกสายอักขระแต่ละตัวในกลุ่มประชากรนั้น จะอยู่รอดหรือไม่ในรุ่นต่อไปโดยพิจารณาจากค่าที่เหมาะสมของสายอักขระแต่ละตัว ถ้าสายอักขระใดมีค่าที่เหมาะสมสูงก็มีโอกาสที่จะอยู่รอดสูง ส่วนสายอักขระที่มีค่าที่เหมาะสมต่ำจะมีโอกาสอยู่รอดต่ำ ครอสโอเวอร์เป็นวิธีการรวมตัวใหม่ของโครโมโซม (Recombination Operator) โดยทำการรวมส่วนย่อยระหว่างโครโมโซมต้นกำเนิดสายพันธุ์ ตั้งแต่สองโครโมโซมขึ้นไป เพื่อให้กลายเป็นโครโมโซมลูกหลาน โครโมโซมลูกหลานที่ได้จากการครอสโอเวอร์นี้จะมีพันธุกรรมจากต้นกำเนิดสายพันธุ์อยู่ในตัว โดยปกติทั่วไปแล้วจะมีการกำหนดอัตราการทำครอสโอเวอร์เอาไว้ซึ่งส่วนใหญ่จะใช้ความน่าจะเป็น ( $p_c$ ) เป็นตัวกำหนดอัตราดังกล่าว (รายละเอียดที่ได้กล่าวไปแล้วในบทที่ 2)

การผ่าเหล่าเป็นวิธีการแปรผันยีนหรือส่วนย่อยของโครโมโซม ซึ่งสามารถเปรียบเทียบได้กับการกลายพันธุ์ของสิ่งมีชีวิตในทางชีววิทยา ปกติแล้วอัตราการผ่าเหล่าจะมีค่าค่อนข้างต่ำ หรืออาจจะกล่าวได้ว่าความน่าจะเป็นในการผ่าเหล่านี้นั้นมีค่าน้อย ถ้าการผ่าเหล่าคือการเปลี่ยนแปลงยีนส์ในโครโมโซมแล้ว การผ่าเหล่าจะเป็นการเปลี่ยนแปลงเชิงตัวเลขของโครโมโซม เพราะในทางปฏิบัติแล้ว ยีนส์ของโครโมโซมก็คือบิตในระบบตัวเลขของคอมพิวเตอร์ การผ่าเหล่าเปรียบเสมือนกับการก้าวเดินไปสู่คำตอบของระบบเช่นเดียวกับการทำครอสโอเวอร์ นอกเหนือไปจากนั้นแล้ว การผ่าเหล่ายังเป็นกระบวนการที่สำคัญที่ทำให้เกิดความหลากหลายขึ้นในกลุ่มประชากร ส่งผลให้ค่าที่เหมาะสมที่เกิดขึ้นในขบวนการของ GA ครอบคลุมพื้นที่การค้นหาค่าที่เหมาะสม (พื้นที่ในการค้นหาคำตอบ) ทั่วถึงยิ่งขึ้น (รายละเอียดที่ได้กล่าวไปแล้วในบทที่ 2)

เมื่อพิจารณาจากขั้นตอนการดำเนินงานของเจเนติกอัลกอริทึมจากเอกสารและงานวิจัยที่เกี่ยวข้องแล้ว แสดงให้เห็นว่า ขั้นตอนที่สำคัญของเจเนติกอัลกอริทึมนั้นประกอบด้วย ขั้นตอนการคัดเลือก ขั้นตอนการครอสโอเวอร์ และขั้นตอนการผ่าเหล่า โดยขั้นตอนเหล่านี้ได้รับความนิยมนำไปผสมผสานกับอัลกอริทึมอื่น ๆ เพื่อเพิ่มประสิทธิภาพอยู่เสมอ เช่น Ant Colony, Learning Automata, Neural Network, Cuckoo Search, Local Search, Particle Swarm Optimization, Firefly Algorithm, Bat Algorithm และ Eagle Strategy เป็นต้น เนื่องจากเจเนติกอัลกอริทึมมีคุณสมบัติและลักษณะเด่นที่มีความเหมาะสมต่อการนำไปผสมผสานดังต่อไปนี้

#### ลักษณะเด่นของเจเนติกอัลกอริทึม

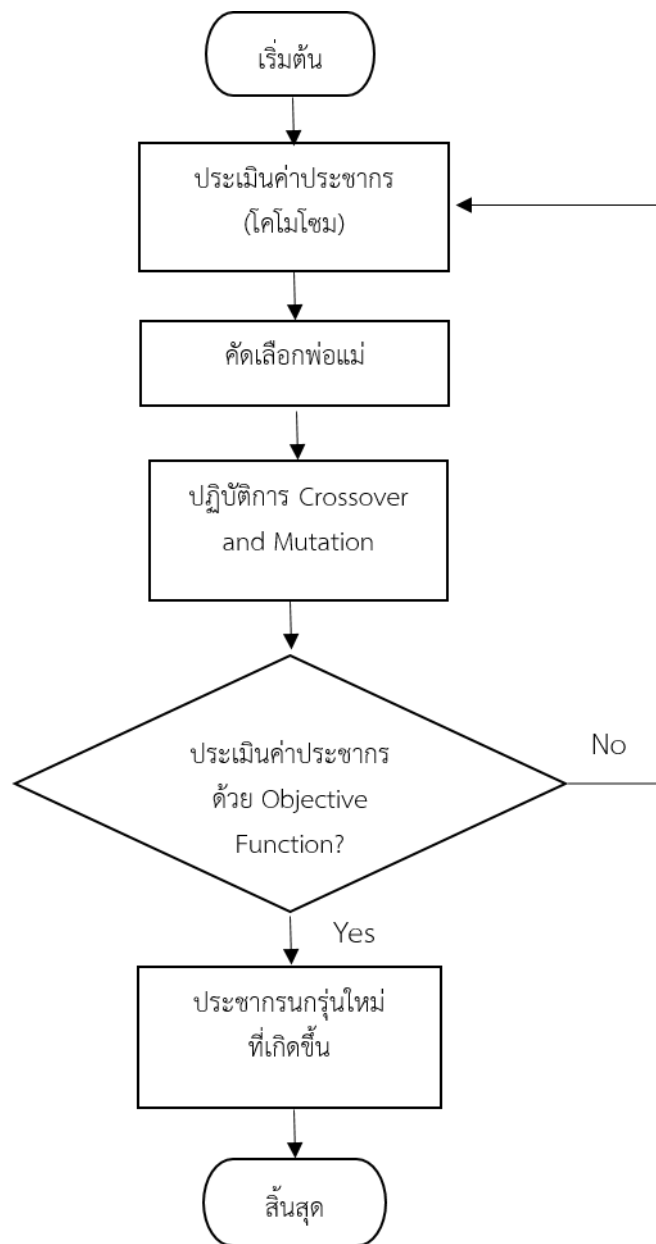
- 1) เจเนติกอัลกอริทึมใช้ทฤษฎีความน่าจะเป็นในการหาคำตอบ ผ่านการใช้รหัสของตัวแปรเป็นเครื่องมือในการหาค่าที่เหมาะสม แทนที่จะใช้ค่าของตัวแปรโดยตรง ดังนั้นวิธีนี้จึงสะดวกในการแก้ปัญหาเกี่ยวกับตัวแปรชนิดใดก็ได้ และตัวแปรนั้นไม่จำเป็นต้องมีความต่อเนื่อง
- 2) เจเนติกอัลกอริทึมเป็นวิธีการหาค่าที่เหมาะสมจากจุดเริ่มต้นหลาย ๆ จุด เป็นการหาจุดที่เหมาะสมโดยรวม ด้วยเทคนิคการหาค่าความเหมาะสมแบบขนาน ทำให้คำตอบที่ได้เป็นค่าที่ใกล้เคียงกับค่าความเหมาะสมโดยรวม
- 3) เจเนติกอัลกอริทึมใช้ข้อมูลเพียงแค่ว่าฟังก์ชันวัตถุประสงค์เท่านั้น ดังนั้นวิธีนี้สามารถใช้กับฟังก์ชันวัตถุประสงค์ได้ทุกชนิด โดยที่ฟังก์ชันวัตถุประสงค์ไม่จำเป็นต้องมีความต่อเนื่องหรือสามารถหาอนุพันธ์ได้

ปกติแล้ววิธีการค้นหาแบบนกกาเหว่านั้นเริ่มต้นด้วยการสุ่มนกกาเหว่าที่โตเต็มวัยแล้วมาจำนวนหนึ่ง (ประมาณ 20%) แล้วปล่อยให้มันได้แสวงหารังที่เหมาะสมต่อการวางไข่ (ค้นหาค่าที่เหมาะสม) โดยพิจารณาจากโอกาสที่ไข่จะได้รับการฟักและเลี้ยงดูจนเติบโต (โอกาสที่จะมีชีวิตรอด) ผู้วิจัยจึงมีแนวคิดที่จะเพิ่มความสามารถในการค้นหารังที่มีคุณภาพ (เพิ่มโอกาสในการค้นหาค่าที่เหมาะสม) โดยการประยุกต์หลักการทางพันธุกรรมเข้ากับวิธีการค้นหาแบบนกกาเหว่า ทำให้เมื่อนกกาเหว่าวางไข่แล้วมีโอกาสสูงที่ไข่จะได้รับการฟัก (โอกาสที่ได้รับการคัดเลือกเป็นค่าที่เหมาะสม) หลังจากไข่ได้รับการฟักแล้ว นกก็จะเติบโตกลายเป็นพ่อแม่รุ่นต่อไปพร้อมกับประสบการณ์ในการค้นหารังที่ได้รับถ่ายทอดจากนกก่อน ๆ วิธีการถ่ายทอดประสบการณ์ผ่านยีนส์ของพ่อแม่รุ่นนั้นเป็นขั้นตอนที่สำคัญของเจเนติกอัลกอริทึม ประกอบด้วยขั้นตอนการสร้างประชากรรุ่นใหม่

เรียกว่า รีโพรดักชัน (Reproduction) โดยวิธีการดังกล่าวนี้ประกอบด้ววิธีการครอสโอเวอร์และวิธีการผ่าเหล่า (Crossover and Mutation)

1. พัฒนาวิธีการค้นหาแบบนกกาเหว่าด้วยวิธีการผสมผสานระหว่างวิธีการค้นหาแบบนกกาเหว่ากับเจเนติกอัลกอริทึม

จากลักษณะเด่นของเจเนติกอัลกอริทึมดังที่กล่าวไปแล้วข้างต้น พบว่าเจเนติกอัลกอริทึมเป็นอัลกอริทึมที่มีความเหมาะสมและได้รับความนิยมนำไปผสมผสานกับอัลกอริทึมอื่น ๆ อยู่เสมอ ดังนั้นการศึกษาวิจัยนี้จึงได้นำวิธีการค้นหาแบบนกกาเหว่าไปผสมผสานกับเจเนติกอัลกอริทึม ได้เป็นวิธีการหาค่าที่เหมาะสมที่มีชื่อเรียกว่า “วิธีการหาค่าที่เหมาะสมแบบผสมผสานระหว่างวิธีการค้นหาแบบนกกาเหว่ากับวิธีการเจเนติกอัลกอริทึม (Cuckoo Search Genetic Algorithm)” หรืออัลกอริทึม CSGA โดยเริ่มจากกำหนดตำแหน่งของวิธีการค้นหาแบบนกกาเหว่าที่ต้องการผสมผสานกับเจเนติกอัลกอริทึม จากการศึกษางานวิจัยของ Kanagaraj et al. (2013) แสดงให้เห็นว่า มีการผสมผสานกับเจเนติกอัลกอริทึมในตำแหน่งไปที่ได้รับการฝึกแล้ว ดังนั้นกรุ่นใหม่จึงได้รับการปรับปรุงความสามารถในการค้นหาค่าที่เหมาะสมด้วยเจเนติกอัลกอริทึม สำหรับในงานวิจัยนี้ได้พิจารณาคัดเลือกตำแหน่งที่เหมาะสมต่อการผสมผสานโดยปรับปรุงจากวิธีของ Kanagaraj et al. (2013) โดยการผสมผสานขั้นตอนการครอสโอเวอร์และขั้นตอนการผ่าเหล่าลงในตำแหน่งกำหนดค่าพารามิเตอร์แต่ละวิธีแก้ปัญหา เนื่องจากการผสมผสานในตำแหน่งดังกล่าวนี้ ไปขยายพื้นที่การสำรวจในการค้นหาค่าที่เหมาะสมให้กับประชากรนกกาเหว่ารุ่นต่อไป (Kanagaraj, Ponnambalam, & Jawahar, 2013) โดยเริ่มจากการคัดเลือนกกาเหว่าที่มีความสามารถในการค้นหาค่าที่เหมาะสม (ค้นหารัง) แล้วนำมาเป็นกรุ่นพ่อแม่ เพื่อถ่ายทอดความสามารถของไปยังกรุ่นต่อไป ด้วยวิธีการครอสโอเวอร์และการผ่าเหล่า ดังนั้นนกกาเหว่ารุ่นต่อไปจะได้รับการถ่ายทอดพันธุกรรมที่บรรจุความสามารถในการค้นหาหรือค่าที่เหมาะสมในระดับสากลไว้ (Global Optima) โดยสามารถนำมาเขียนในรูปของผังขั้นตอนได้ดังต่อไปนี้

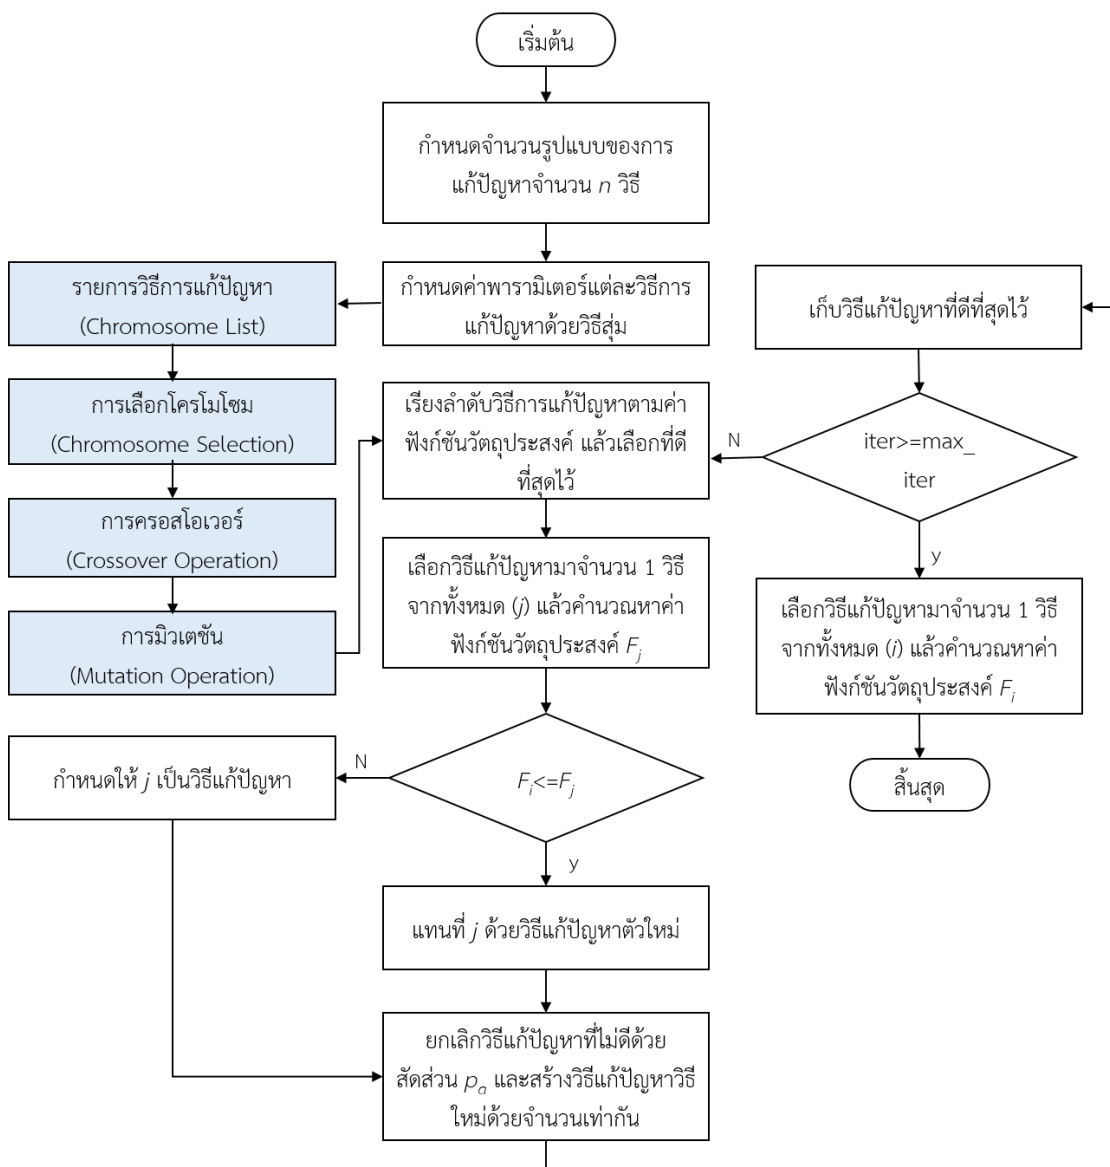


ภาพที่ 3-4 ขั้นตอนการดำเนินงานของเจเนติกอัลกอริทึม (Genetic Algorithm)

#### ขั้นตอนการทำงานของเจเนติกอัลกอริทึม

1. ประเมินค่าประชากร (โครโมโซมหรือวิธีการหาค่าที่เหมาะสม) ของกลุ่มประชากรทั้งหมดด้วยฟังก์ชันวัตถุประสงค์ เนื่องจากระบบไม่สามารถเข้าใจค่าของโครโมโซมภายใน GA ดังนั้นโครโมโซมจะต้องผ่านการถอดรหัสก่อนที่จะนำไปทำการคำนวณด้วยฟังก์ชันวัตถุประสงค์ได้
2. คัดเลือกพ่อแม่ของนกกาเหว่า โดยการคำนวณหาความน่าจะเป็นในการหาค่าความเหมาะสม เพื่อนำไปใช้คัดเลือกโครโมโซมบางส่วน สำหรับใช้เป็นต้นกำเนิดสายพันธุ์และใช้เป็นตัวแทนในการถ่ายทอดสายพันธุ์ให้กับนกกาเหว่ารุ่นถัดไป

4. ปฏิบัติการ Crossover and Mutation โดยการนำต้นกำเนิดสายพันธุ์มาสร้างนกรุ่นต่อไป ด้วยปฏิบัติการทางสายพันธุ์ โครโมโซมที่ได้ในขั้นตอนนี้จะเป็นโครโมโซมนกรุ่นต่อไป
5. ประเมินค่าประชากรด้วย Objective Function โดยการคำนวณค่าความเหมาะสมของโครโมโซมนกกาเหว่ารุ่นต่อไป โดยใช้ขั้นตอนเดียวกับข้อ 3 หากผลการคำนวณใช้ได้ ให้ไปยังขั้นที่ 6 หากไม่ ให้ไปเริ่มทำในขั้นตอนที่ 2 ใหม่
6. ประชากรนกกาเหว่ารุ่นใหม่ที่เกิดขึ้น เนื่องจากโครโมโซมในประชากรเดิมจะถูกแทนที่ด้วยโครโมโซมของลูกหลานนกกาเหว่าที่ได้จากข้อ 4 ประชากรเพียงบางส่วนเท่านั้นที่จะถูกแทนที่ด้วยกลวิธีเฉพาะสำหรับขั้นตอนของการแทนที่โดยใช้ค่าความเหมาะสมในการตัดสินใจ



ภาพที่ 3-5 ผังขั้นตอนวิธีการผสมผสานระหว่างการค้นหาแบบนกกาเหว่ากับเจเนติกอัลกอริทึม

### ขั้นตอนการทำงานของอัลกอริทึม CSGA

อัลกอริทึม CSGA เกิดจากการผสมผสานกันระหว่างวิธีการค้นหาแบบนกกาเหว่ากับ เจเนติกอัลกอริทึม ในขั้นตอนการคัดเลือก (Selection) ขั้นตอนการครอสโอเวอร์ (Crossover) และ ขั้นตอนการผ่าเหล่า (Mutation) ซึ่งเป็นขั้นตอนที่เพิ่มขึ้นจากวิธีการค้นหาแบบนกกาเหว่ามาตรฐาน

(1) กำหนดจำนวนรูปแบบของการแก้ปัญหา โดยการกำหนดให้จำนวนรังของนกกาเหว่า เท่ากับจำนวน  $n$  ซึ่งหมายถึงจำนวนวิธีการแก้ปัญหาตามปัญหาที่กำหนดไว้เพื่อหาค่าที่เหมาะสมที่สุด

(2) กำหนดค่าพารามิเตอร์ของแต่ละวิธีการแก้ปัญหาด้วยวิธีสุ่ม กล่าวคือ ในแต่ละวิธีการ แก้ปัญหาตามข้อ 1 จะต้องมีการกำหนดค่าเริ่มต้นให้กับแต่ละวิธี โดยการกำหนดค่าเริ่มต้นนั้นจะใช้วิธี กำหนดค่าเลขสุ่มตามขอบเขตของข้อมูลที่ได้กำหนดขึ้น

(3) รายการวิธีการแก้ปัญหา (Chromosome List) เป็นการดำเนินการตามปฏิบัติการ ทางพันธุกรรมของเจเนติกอัลกอริทึม ซึ่งเป็นขั้นตอนใหม่ที่เกิดขึ้นจากการผสมผสาน ประกอบไปด้วย 3 การดำเนินการ คือ การคัดเลือก (Selection) การครอสโอเวอร์ (Crossover) และการผ่าเหล่า (Mutation) ซึ่งกระบวนการเหล่านี้ จะได้กล่าวถึงในหัวข้อถัดไป

(4) การเลือกโครโมโซม (Chromosome Selection) โดยกำหนดให้วิธีแก้ปัญหาที่ได้ กล่าวถึงในลำดับขั้นตอนของ CSGA นั้น เป็นโครโมโซมและทำการคัดเลือกโครโมโซมด้วยวิธีร้อยละ ของโครโมโซมที่ดีที่สุด (กำหนดที่ร้อยละ 20)

(5) การครอสโอเวอร์ (Crossover Operation); ดำเนินการครอสโอเวอร์ด้วยวิธีเคพอยต์ ครอสโอเวอร์ (K-Points Crossover) โดยกำหนดให้  $K=2$

(6) การผ่าเหล่า (Mutation Operation); ทำการผ่าเหล่าด้วยวิธีตามขอบเขต (Boundary Mutation) โดยยืนยันที่จะมีการผ่าเหล่าจะได้ค่าใหม่ที่มีค่าอยู่ระหว่างค่าต่ำสุดและค่าสูงสุดตามที่กำหนด

(7) เลือกวิธีแก้ปัญหามาจำนวน 1 วิธีจากทั้งหมด ( $i$ ) แล้วคำนวณหาค่าฟังก์ชันวัตถุประสงค์  $F_i$  ทำการเลือกวิธีแก้ปัญหามา 1 วิธีจากวิธีการแก้ปัญหาทั้งหมดที่มีอยู่ โดยกำหนดให้เป็นวิธีที่  $i$  จากนั้นทำการคำนวณหาค่าฟังก์ชันวัตถุประสงค์ตามที่กำหนดไว้ โดยกำหนดให้เป็น  $F_i$

(8) เลือกวิธีแก้ปัญหามาจำนวน 1 วิธีจากทั้งหมด ( $j$ ) แล้วคำนวณหาค่าฟังก์ชัน วัตถุประสงค์  $F_j$  ทำการเลือกวิธีแก้ปัญหามา 1 วิธี จากวิธีการแก้ปัญหาทั้งหมดที่มีอยู่ โดยกำหนดให้ เป็นวิธีที่  $j$  จากนั้นทำการคำนวณหาค่าฟังก์ชันวัตถุประสงค์ตามที่กำหนดไว้ โดยกำหนดให้เป็น  $F_j$

(9)  $F_i \leq F_j$ ; ทำการเปรียบเทียบค่าฟังก์ชันวัตถุประสงค์ระหว่างค่า  $F_i$  และ  $F_j$  ว่า  $F_i \leq F_j$  ใช่หรือไม่ โดยให้ปฏิบัติตามขั้นตอนที่ 10 และ 11

(10) แทนที่  $j$  ด้วยวิธีแก้ปัญหาคู่ใหม่ เมื่อพิจารณาจากเงื่อนไข  $F_i \leq F_j$  เป็นจริง แล้วไป ทำขั้นตอนที่ (12)

(11) กำหนดให้  $j$  เป็นวิธีแก้ปัญหาคู่ใหม่ หากพิจารณาจากเงื่อนไข  $F_i \leq F_j$  ไม่เป็นจริง แล้วไป ทำขั้นตอนที่ (12)

(12) ยกเลิกวิธีแก้ปัญหาคู่ที่ไม่ดีด้วยสัดส่วน  $p_a$  และสร้างวิธีแก้ปัญหาคู่ใหม่ด้วยจำนวน เท่ากัน โดยทำการเรียงลำดับวิธีแก้ปัญหาคู่ทั้งหมดตามค่าฟังก์ชันวัตถุประสงค์ แล้วทำการยกเลิก รายการวิธีการแก้ปัญหาที่ไม่ดีมากที่สุดจำนวนตามสัดส่วน  $p_a$  และทำการสร้างวิธีแก้ปัญหาคู่ขึ้นมาใหม่ ขึ้นมาทดแทนด้วยจำนวนที่เท่ากัน

(13) เก็บวิธีแก้ปัญหาที่ดีที่สุดไว้

(14)  $Iter \geq Max\_Iter$  ทำการตรวจสอบว่ารอบการวนรอบว่าเป็นจริงตามเงื่อนไขหรือไม่หรือไม่ เมื่อ  $Iter \geq Max\_Iter$  เป็นจริงให้ไปทำที่ขั้นตอนที่ (15) เมื่อ  $Iter \geq Max\_Iter$  ไม่เป็นจริงให้ไปทำที่ขั้นตอนที่ (15)

(15) เลือกวิธีแก้ปัญหามาจำนวน 1 วิธีจากทั้งหมด ( $i$ ) แล้วคำนวณหาค่าฟังก์ชันวัตถุประสงค์  $F_i$

การพัฒนาวิธีการค้นหาแบบนกกาเหว่าด้วยการผสมผสานกับเจเนติกอัลกอริทึม (CSGA) นั้น เริ่มจากนำวิธีการค้นหาแบบนกกาเหว่าแบบมาตรฐานมาเชื่อมต่อเข้ากับขั้นตอนรายการวิธีการแก้ปัญหา (Chromosome List) ขั้นตอนการเลือกโครโมโซม (Chromosome Selection) ขั้นตอนการครอสโอเวอร์ (Crossover) และขั้นตอนการผ่าเหล่า (Mutation) ในขั้นตอนการกำหนดค่าพารามิเตอร์ของวิธีการค้นหาแบบนกกาเหว่า เพื่อเพิ่มประสิทธิภาพในขั้นตอนของการสร้างประชากรนกกาเหว่ารุ่นใหม่ให้กับวิธีการค้นหาแบบนกกาเหว่า โดยใช้วิธีสุ่มของเจเนติกอัลกอริทึม (Kanagaraj et al., 2013)

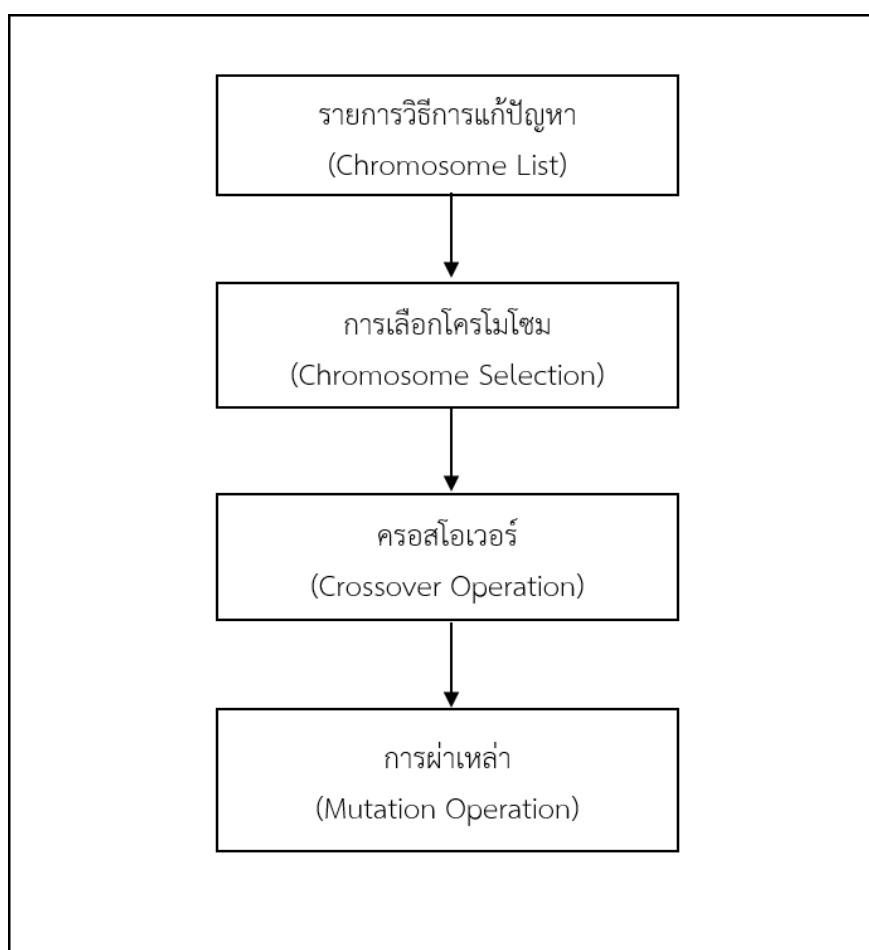
สำหรับกระบวนการถ่ายทอดทางพันธุกรรมของเจเนติกอัลกอริทึมนั้น ประกอบด้วยขั้นตอนรายการวิธีการแก้ปัญหา ต่อจากนั้นเป็นขั้นตอนการเลือกโครโมโซม (Chromosome Selection) ของนกกาเหว่าที่มีความสามารถในการค้นหาที่ที่เหมาะสมสำหรับวางไข่ (ค่าที่เหมาะสม) แล้วเข้าสู่ขั้นตอนการแลกเปลี่ยนยีนระหว่างนกพ่อแม่ ประกอบด้วยขั้นตอนการครอสโอเวอร์ (Crossover) และขั้นตอนการผ่าเหล่า (Mutation) โดยทำการเชื่อมต่อและพัฒนาการทำงานของอัลกอริทึม ด้วยการปรับปรุงจากวิธีการผสมผสานของ Kanagaraj et al. (2013) เป็นการนำเจเนติกอัลกอริทึมเข้ามาช่วยในกระบวนการสร้างนกกาเหว่ารุ่นใหม่ วิธีการนี้สามารถเพิ่มความสามารถในการค้นหาที่ที่เหมาะสม (ค่าที่เหมาะสมหรือคำตอบ) เนื่องจากความสามารถในการหาค่าที่เหมาะสมจะถูกถ่ายทอดผ่านยีนไปยังนกกาเหว่ารุ่นลูก โดยอาศัยหลักการถ่ายทอดทางพันธุกรรมของเจเนติกอัลกอริทึม กระบวนการถ่ายทอดทางพันธุกรรมจะดำเนินการผ่านขั้นตอนการครอสโอเวอร์ (Crossover) และขั้นตอนการผ่าเหล่า (Mutation) ทำให้ยีนของนกกาเหว่ารุ่นลูกมีความผิดปกติหรือแตกต่างจากยีนของนกกาเหว่ารุ่นพ่อแม่ ส่งผลให้ความสามารถในการค้นหาของนกกาเหว่ารุ่นนั้นเหนือความคาดหมาย นกกาเหว่ารุ่นลูกหรือนกกาเหว่ารุ่นหลานอาจจะมีความสามารถในการค้นหาที่ดีเลิศหรือเลวที่สุดก็ได้

ในงานวิจัยของ Kanagaraj et al. นั้นใช้วิธีสุ่มตัวอย่างโครโมโซมแบบวงล้อรูเล็ตต์ แต่ในงานวิจัยนี้ได้ดำเนินการปรับเปลี่ยนใหม่ โดยเปลี่ยนมาใช้วิธีสุ่มตัวอย่างแบบ Stochastic Universal Sampling (SUS) แทนวงล้อรูเล็ตต์ เนื่องจากวิธีสุ่มตัวอย่างโครโมโซมแบบ SUS เป็นวิธีสุ่มที่ใช้เพียงครั้งเดียวก็สามารถคัดเลือกโครโมโซมได้ตามจำนวนที่ต้องการได้ นอกจากนี้วิธีสุ่มตัวอย่างแบบ SUS ยังมีข้อแตกต่างไปจากวิธีสุ่มตัวอย่างโครโมโซมแบบวงล้อรูเล็ตต์ ตรงที่มีการใช้ตัวบ่งชี้มากกว่าหนึ่งตัว กล่าวคือสำหรับการคัดเลือก  $N$  โครโมโซมจะมีตัวชี้ทั้งหมด  $N$  ตัว โดยที่ตัวบ่งชี้แต่ละตัวจะมีระยะห่างเท่ากันและมีค่าเท่ากับ  $p_{total}/N$  วิธีนี้ทำให้สามารถลดความเหลื่อมล้ำในการได้รับการคัดเลือกของแต่ละโครโมโซมลงได้ เมื่อเทียบกับวิธีดั้งเดิมที่ใช้วิธีวงล้อรูเล็ตต์แล้วปรากฏว่า โครโมโซมที่มีค่า  $p$  สูงจะ

ถูกซ้ำด้วยจำนวนตัวซ้ำในจำนวนที่มากกว่าโครโมโซมที่มีค่า  $p$  ที่ต่ำกว่า ทำให้วิธีการสุ่มของวงล้อสุ่มเหล่านั้นเกิดความเหลื่อมล้ำขึ้นได้

### กระบวนการผสมผสาน (Hybridization Process)

วิธีการผสมผสานระหว่างวิธีเจเนติกอัลกอริทึมและวิธีการค้นหาแบบนกกาเหว่านั้นสามารถดำเนินการ ด้วยการนำขั้นตอนของการถ่ายทอดทางพันธุกรรมของเจเนติกอัลกอริทึมมาเชื่อมต่อกับขั้นตอนของการกำหนดค่าพารามิเตอร์ของแต่ละวิธีการแก้ปัญหา ด้วยวิธีสุ่มของวิธีการค้นหาแบบนกกาเหว่ามาตรฐาน เพื่อดำเนินการถ่ายทอดพันธุกรรมที่บรรลุความสามารถในการค้นหาค่าที่เหมาะสมแล้วส่งต่อไปยังนกกรุ่นถัดไป ทำให้นกกรุ่นลูกและรุ่นหลานได้รับการถ่ายทอดประสบการณ์ในการค้นหาค่าที่เหมาะสมจากนกกรุ่นก่อน ๆ ความสามารถของนกกาเหว่าจะเพิ่มขึ้นในนกแต่ละรุ่น โดยความสามารถจะเพิ่มขึ้นทั้งในด้านความเร็วและประสิทธิภาพในการหาค่าที่เหมาะสมของปัญหา โดยขั้นตอนของเจเนติกอัลกอริทึมที่นำมาเชื่อมต่อประกอบด้วยสี่ขั้นตอน ดังนี้ 1) รายการวิธีการแก้ปัญหา (Chromosome) 2) ขั้นตอนการเลือกโครโมโซม (Selection), 3) การครอสโอเวอร์ (Crossover Operation) และ 4) ขั้นตอนการผ่าเหล่า (Mutation Operation) สามารถแสดงรายละเอียดได้ดังนี้



ภาพที่ 3-6 ผังขั้นตอนวิธีการ Crossover และ Mutation



ขั้นตอนการผสมผสานระหว่างวิธีการค้นหาแบบนกกาเหว่ากับเจเนติกอัลกอริทึมมีรายละเอียด ดังนี้

1. ขั้นตอนรายการวิธีการแก้ปัญหา (Chromosome List) โดยการกำหนดให้วิธีแก้ปัญหาที่ได้กล่าวถึงในลำดับขั้นตอนของ CSGA นั้น เป็นโครโมโซม เมื่อเข้าสู่กระบวนการของ GA โดยค่าของยีน (Gene) ในโครโมโซมเป็นเลขจำนวนจริง

2. การเลือกโครโมโซม (Chromosome Selection) โดยดำเนินการคัดเลือกนกพ่อแม่ (Parents) ตามกระบวนการของเจเนติกอัลกอริทึมที่มีอยู่หลายวิธี สำหรับการวิจัยนี้ได้เลือกใช้วิธีร้อยละของโครโมโซมที่ดีที่สุด โดยการเรียงลำดับโครโมโซมตามค่าฟังก์ชันเป้าหมายแล้วเลือกเอาโครโมโซมที่ดีที่สุดมาตามร้อยละที่กำหนด โดยในการวิจัยนี้ได้กำหนดเป็นร้อยละ 20

3. การครอสโอเวอร์ (Crossover Operation) โดยดำเนินการแลกเปลี่ยนยีนระหว่างโครโมโซมของพ่อและของแม่นกกาเหว่า การดำเนินการครอสโอเวอร์มีหลายวิธี สำหรับในการวิจัยนี้เลือกใช้วิธี เคพอยต์ครอสโอเวอร์ (K-Points Crossover) โดยกำหนดให้การแลกเปลี่ยนยีนระหว่างโครโมโซมของพ่อกับแม่นกกาเหว่าเกิดขึ้นจำนวน K จุดในโครโมโซม โดยปกติแล้วจะกำหนดเป็น 2 จุด ดังนั้นในการวิจัยนี้จะใช้  $K=2$  เพื่อดำเนินการส่งต่อความสามารถในการค้นหา (ค่าที่เหมาะสม) ไปยังรุ่นต่อไป

4. การผ่าเหล่า (Mutation Operation) เป็นการดำเนินการในโครโมโซม โดยยีนบางยีน จะเกิดการผ่าเหล่า คือมีค่าเปลี่ยนไป ถ้าเป็นยีนแบบไบนารี ก็จะมีการเปลี่ยนค่าบิตจากเดิม 1 เป็น 0 หรือจาก 0 เป็น 1 เป็นต้น แต่ถ้าค่ายีนเป็นตัวเลขจำนวนจริงจะมีหลายวิธี ในการวิจัยนี้จะเลือกใช้วิธีการผ่าเหล่าตามขอบเขต (Boundary Mutation) กล่าวคือยีนที่จะมีการผ่าเหล่าจะได้ค่าใหม่ที่มีค่าอยู่ระหว่างค่าต่ำสุดและค่าสูงสุดตามที่กำหนด

## ระยะที่ 2 การเปรียบเทียบประสิทธิภาพของวิธี CSGA ที่พัฒนาขึ้นกับวิธี CS และวิธี RSM

เมื่อนำวิธีการหาค่าที่เหมาะสมแบบนกกาเหว่ามาตรฐาน (CS) ที่นำเสนอโดย Yang และ Dept มาทำการพัฒนา เพื่อเพิ่มประสิทธิภาพในการหาค่าที่เหมาะสมในกระบวนการทำหิ้งมะละกอแบบออสโมซิส โดยนำไปผสมผสานกับเจเนติกอัลกอริทึม ได้เป็นอัลกอริทึมใหม่เรียกว่าอัลกอริทึม CSGA จากนั้นนำอัลกอริทึมที่ผ่านการผสมผสานแล้วมาทดสอบประสิทธิภาพด้วยฟังก์ชันมาตรฐาน (Benchmark Function) สำหรับใช้ทดสอบอัลกอริทึมจำนวน 5 ฟังก์ชัน จากนั้นนำผลที่ได้จากการทดสอบมาเปรียบเทียบประสิทธิภาพในการหาค่าต่ำที่สุดของฟังก์ชันระหว่างอัลกอริทึมมาตรฐาน CS กับอัลกอริทึมที่ผ่านการผสมผสาน CSGA โดยมีขั้นตอนการดำเนินการดังนี้

### ขั้นตอนการเปรียบเทียบประสิทธิภาพ

ขั้นตอนการเปรียบเทียบประสิทธิภาพระหว่างอัลกอริทึมผสมผสาน CSGA กับวิธีการค้นหาแบบนกกาเหว่า มีขั้นตอน ดังนี้

1. คัดเลือกฟังก์ชันมาตรฐาน (Benchmark Optimization Function) สำหรับใช้

ทดสอบประสิทธิภาพการทำงานของอัลกอริทึม CS และ CSGA โดยคัดเลือกมาจำนวน 5 ฟังก์ชัน จาก Fast Evolutionary Programming ของ Yao and Liu (1999) มหาวิทยาลัยเบอร์มิงแฮม ประเทศอังกฤษและมหาวิทยาลัยนิวเซ้าท์เวล ประเทศออสเตรเลีย

ตารางที่ 3-1 ชุดฟังก์ชันมาตรฐาน (Benchmark Optimization Function)

$f_{No}$	ชื่อฟังก์ชัน	รูปแบบฟังก์ชัน	S
$f_1(x)$	Sphere Model	$\sum_{i=1}^n x_i^2$	$[-100,100]^n$
$f_2(x)$	Schwefel's Problem	$\sum_{i=1}^n  x_i  + \prod_{i=1}^n  x_i ^2$	$[-10,10]^n$
$f_3(x)$	Schwefel's Problem	$\sum_{i=1}^n \left( \sum_{j=1}^i x_j \right)^2$	$[-100,100]^n$
$f_4(x)$	Schwefel's Problem	$\max_i \{ x_i , 1 \leq i \leq n\}$	$[-100,100]^n$
$f_5(x)$	Generalized Rosenbrock's Function	$\sum_{i=1}^{n-1} [100(x_{i+1} - x_i^2)^2 + (x_{i-1} - 1)^2]$	$[-30,30]^n$

เมื่อค่าต่ำที่สุดของฟังก์ชันมีค่าเท่ากับ 0 จำนวน และ S เป็นสมาชิกของจำนวนจริง

2. กำหนดพารามิเตอร์ให้กับอัลกอริทึม CS และ CSGA โดยกำหนดค่าพารามิเตอร์ ดังตารางที่ 3-2 ในการกำหนดค่าพารามิเตอร์สำหรับเปรียบเทียบประสิทธิภาพให้กับอัลกอริทึมที่ผู้วิจัยได้เลือกใช้ในช่วงกลางของพารามิเตอร์แต่ละตัว โดยทำการปรับปรุงจากการศึกษาของ Kanagaraj, Ponnambalam, and Jawahar (2013)

ตารางที่ 3-2 การกำหนดค่าพารามิเตอร์ของอัลกอริทึม CS และ CSGA

วิธีการ	CS	GA	CACS
I/NE	100/100	-	100/100
DR ( $p_d$ )	35%	-	35%
LF ( $\lambda$ )	2	-	2
CR	-	80%	80%
MR	-	20%	20%

หมายเหตุ I/NE คือ อัตราส่วนของรอบการคำนวณ (I) ต่อจำนวนไข (NE)

DR ( $p_d$ ) คือ อัตราการทิ้งรังของนกเจ้าของรัง

LF ( $\lambda$ ) คือ จำนวนจุดที่สลับตำแหน่งแบบ Neighborhood Search

CR คือ ร้อยละของการสลับโครโมโซมของพ่อแม่พันธุ์ (Crossover Rate)

MR คือ จำนวนร้อยละการกลายพันธุ์ของลูกที่เกิดจากพ่อแม่พันธุ์ (Mutation Rate)

3. นำค่าพารามิเตอร์และเงื่อนไขในการหาค่าที่เหมาะสมของอัลกอริทึมไปสร้างชุดคำสั่งในโปรแกรม Matlab เมื่อโปรแกรมดำเนินการตามเงื่อนไขที่กำหนดโดยให้นำเสนอค่าต่ำที่สุด ค่าเฉลี่ย ค่าเบี่ยงเบนมาตรฐาน ( $SD$ ) และเวลาที่ใช้ในการหาค่าที่เหมาะสมโดยมีขั้นตอน ดังนี้

3.1 กำหนดจำนวนรอบสูงสุดในการหาค่าที่เหมาะสมของอัลกอริทึม

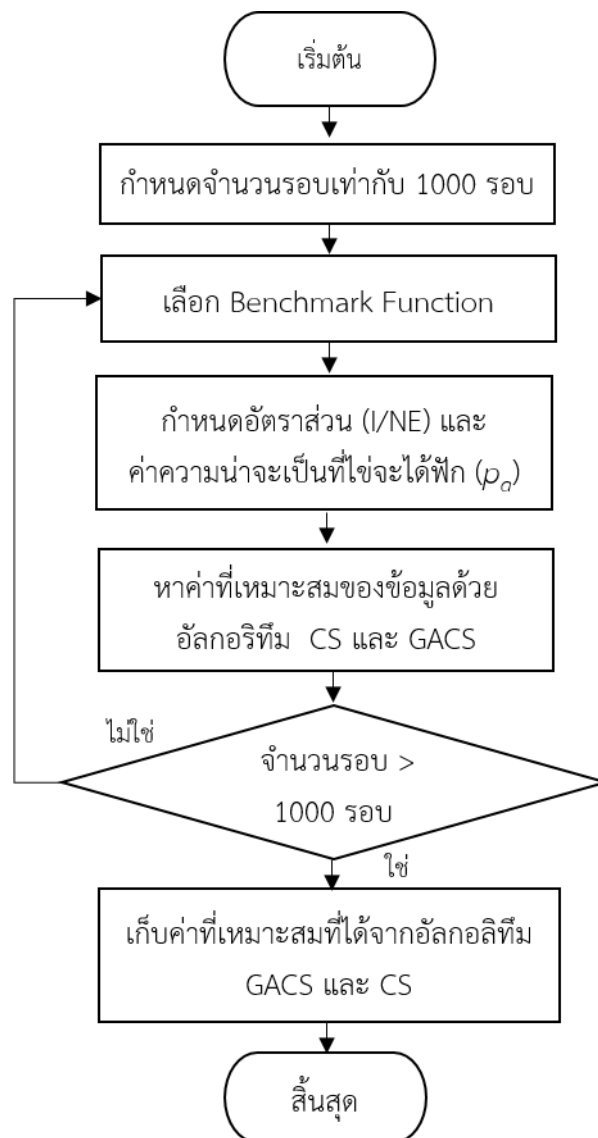
3.2 เลือกฟังก์ชันมาตรฐาน (Benchmark Optimization Function) มาทดสอบประสิทธิภาพการทำงานของอัลกอริทึม จำนวน 5 ฟังก์ชัน โดยเลือกจาก Fast Evolutionary Programming ของ Yao and Liu (1999)

3.3 กำหนดจำนวนรัง (จำนวนชุดของคำตอบ) และค่าความน่าจะเป็นที่ไข่ที่วางไว้ในรัง จะได้รับการฟักเท่ากับ  $pa$  (ค่าความน่าจะเป็นที่แต่ละชุดของคำตอบจะได้รับเลือกเป็นค่าที่เหมาะสมเท่ากับ  $pa$ )

3.4 ดำเนินการหาค่าที่เหมาะสมด้วยอัลกอริทึม CS และ CSGA

การทดสอบประสิทธิภาพของอัลกอริทึม CS และ CSGA

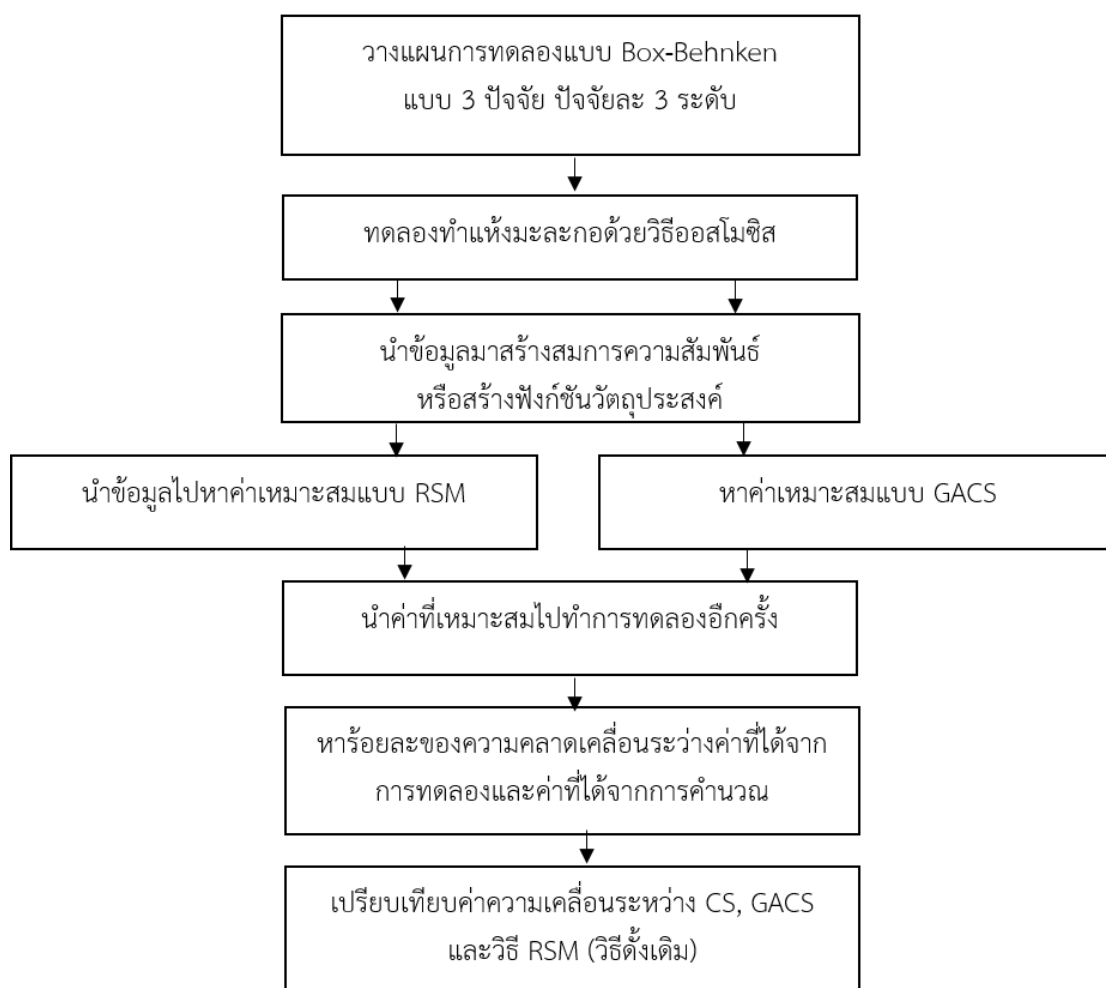
1. กำหนดจำนวนรอบเท่ากับ 1000 รอบสูงสุดสำหรับการวนรอบ
2. เลือก Benchmark Function สำหรับใช้ทดสอบประสิทธิภาพในการหาค่าที่เหมาะสมของอัลกอริทึม CS และ CSGA
3. กำหนดอัตราส่วนระหว่างรอบการคำนวณ ( $I$ ) ต่อจำนวนไข่ ( $NE$ ) และกำหนดค่าความน่าจะเป็นที่ไข่จะได้ฟัก ( $pa$ )
4. หาค่าที่เหมาะสมของ Benchmark Function ด้วยอัลกอริทึม CS และ CSGA
5. จำนวนรอบ  $> 1000$  รอบ โดยการตรวจสอบจำนวนการวนรอบปัจจุบันว่ามากกว่าจำนวนรอบที่กำหนดหรือไม่
6. ถ้าไม่ใช่ ให้ไปทำในขั้นตอนที่ 2
7. ถ้าใช่ ให้ไปทำในขั้นตอนที่ 8
8. เก็บค่าที่เหมาะสมที่ได้จากอัลกอริทึม CS และ CSGA



ภาพที่ 3-7 การทดสอบประสิทธิภาพของอัลกอริทึม CSGA และ CS

### ระยะที่ 3 การหาค่าที่เหมาะสมของการทำแห้งมะละกอแบบออสโมซิส

ในขั้นตอนนี้ได้ทำการตรวจสอบความสามารถในการหาค่าที่เหมาะสมแบบ CSGA ด้วยการนำไปหาค่าที่เหมาะสมกับข้อมูลที่ได้จากการทดลองทำแห้งแบบออสโมซิสตามวิธีของ Jain et al. (2011) จากนั้นนำค่าที่เหมาะสมของกระบวนการทำแห้งแบบออสโมซิสไปเปรียบเทียบกับวิธีพื้นผิวตอบสนอง (Response Surface Method: RSM) และวิธีการค้นหาแบบนกกาเหว่า (CS) โดยมีผังการดำเนินงานดังนี้



ภาพที่ 3-8 ผังวิธีการเปรียบเทียบความสามารถระหว่างอัลกอริทึม

การทดสอบประสิทธิภาพในการหาค่าที่เหมาะสมนั้น ได้มีการกำหนดกลุ่มประชากร กลุ่มตัวอย่างและตัวแปรดังต่อไปนี้

1. ประชากรที่ใช้ในการศึกษาครั้งนี้ได้แก่ มะละกอที่ใช้เป็นวัตถุดิบสำหรับการแปรรูปมะละกอด้วยกระบวนการทำแห้งแบบออสโมซิส
2. ตัวแปรคือปัจจัยที่ส่งผลต่อกระบวนการแปรรูปมะละกออบแห้งแบบออสโมซิส ได้แก่ ตัวแปรต้นประกอบด้วย

ระดับของอุณหภูมิของน้ำเชื่อม (C) เท่ากับ 50, 60 และ 70 °C

ระดับของความเข้มข้นของน้ำเชื่อม (θ) เท่ากับ 30, 40 และ 50 °Brix

ระดับของระยะเวลา (T) เท่ากับ 4, 5 และ 6 ชั่วโมง

ตัวแปรตามประกอบด้วย

ร้อยละของปริมาณน้ำในผลไม้ที่ลดลง (Water Loss: WL)

ร้อยละของปริมาณน้ำตาลในผลไม้ที่เพิ่ม (Sugar Gain: SG)

การหาค่าที่เหมาะสมของทั้ง 3 ปัจจัย จะส่งผลต่อปริมาณน้ำที่ลดลงและปริมาณน้ำตาลที่เพิ่มในผลมะละกอที่ผ่านกระบวนการทำแห้งแบบออสโมซิส การหาค่าที่เหมาะสมจะก่อให้เกิดความประหยัดทั้งด้านต้นทุนและระยะเวลาในกระบวนการผลิต นอกจากนี้ยังทำให้ได้ผลไม้อบที่มีคุณภาพดี สำหรับข้อมูลของทั้งสามปัจจัยจะได้มาจากการทดลองที่มีการวางแผนการทดลองแบบ Box-Benken ตามวิธีของ Jain et al. (2011) เมื่อทำการทดลองจนได้ค่าของตัวแปรครบแล้วนำมาสร้างฟังก์ชันวัตถุประสงค์สำหรับใช้ตรวจสอบการเข้ากันได้พอดี (Fitness) ของค่าที่เหมาะสมที่ได้จากอัลกอริทึม โดยที่ฟังก์ชันวัตถุประสงค์จะประกอบด้วยฟังก์ชันร้อยละของปริมาณน้ำในมะละกอที่ลดลง (Water Loss) และร้อยละปริมาณน้ำตาลในมะละกอที่เพิ่มขึ้น (Sugar Gain) โดยกำหนดค่าของร้อยละปริมาณน้ำที่ลดลง (WL) นั้นต้องลดให้สูงที่สุด ในขณะที่ร้อยละปริมาณน้ำตาลที่เพิ่มขึ้นนั้นมีเป้าหมายอยู่ที่ร้อยละ 4 (Jain et al., 2011) ปรากฏว่า มะละกอบแห้งที่มีปริมาณน้ำตาลดังกล่าวนี้เป็นที่ยอมรับของผู้บริโภค

#### วิธีการทดลองทำแห้งแบบออสโมซิส

การหาค่าที่เหมาะสมด้วยอัลกอริทึมนั้น จำเป็นต้องใช้ข้อมูลที่ได้จากการทำการทดลองในห้องปฏิบัติการหรือจากการทดลองกระบวนการผลิตจริง จากนั้นนำข้อมูลที่ได้ไปสร้างฟังก์ชันวัตถุประสงค์และใช้เป็นข้อมูลสำหรับป้อนให้ขั้นตอนวิธีการเกิดการเรียนรู้ งานวิจัยนี้ได้เลือกใช้ข้อมูลจากการทำแห้งมะละกอด้วยวิธีการออสโมซิส มะละกอมือชื่อวิทยาศาสตร์ *Carica papaya L.* ชื่อวงศ์ Caricaceae ชื่อสามัญ: Papaya ในการทดลองนี้ได้เลือกใช้มะละกอสายพันธุ์แขกดำ จากสวนลุงปรง ตำบลศาลายา อำเภอศาลายา จังหวัดนครปฐม ทำการทดลอง ณ อาคารเฉลิมพระเกียรติฯ ศูนย์วิทยาศาสตร์ มหาวิทยาลัยสวนดุสิต ใช้การวางแผนการทดลองแบบ Box Behnken และการวิเคราะห์ข้อมูลแบบ RSM ตามวิธีของ (Jain et al., 2011) โดยมีขั้นตอนและการดำเนินงาน ดังนี้

#### วัสดุอุปกรณ์

1. Moisture can
2. Reflectometer
3. ตู้อบลมร้อน ยี่ห้อ Memmert
4. เทอร์โมมิเตอร์
5. นาฬิกาจับเวลา
6. เครื่องชั่งน้ำหนัก
7. ขวดโหลแก้วปากกว้าง
8. น้ำตาลซูโครส
9. Water Bath
10. มะละกอ
11. ตะแกรง
12. เต้าไฟฟ้า
13. เครื่องแก้ว
14. อุปกรณ์ครัว
15. น้ำกลั่น

## 16. เครื่องวิเคราะห์หาปริมาณน้ำในอาหาร

ตารางที่ 3-3 การวางแผนการทดลองแบบ Box-Behnken

Treatment No	อุณหภูมิน้ำเชื่อม (°C)	ความเข้มข้นของ น้ำเชื่อม (°Brix)	เวลาที่แช่ในน้ำเชื่อม (Hrs)
1	50	70	5
2	50	50	5
3	30	70	5
4	30	50	5
5	50	60	6
6	50	60	4
7	30	60	6
8	30	60	4
9	40	70	6
10	40	70	4
11	40	50	6
12	40	50	4
13	40	60	5
14	40	60	5
15	40	60	5

### วิธีการทำแห้งแบบออสโมซิส

1. นำมะละกอกที่อยู่ในระยะท่าม (อายุประมาณ 3-4 สัปดาห์) มาปอกเปลือกแล้วมาหั่นเป็นชิ้นลูกเต๋า ขนาดประมาณ 1 ซม.

2. นำมะละกอกหั่นแล้วมาล้าง ผึ่งบนตะแกรงให้สะเด็ดน้ำ

3. บรรจุชิ้นมะละกอลงในขวดแล้วชั่งน้ำหนักขวดละประมาณ 50 กรัม

4. เตรียมน้ำเชื่อมที่มีความเข้มข้นเท่ากับ 50, 60 และ 70 °Brix ตามลำดับ

5. เติมน้ำเชื่อมลงในขวดในอัตราส่วนมะละกอก 1 ส่วนต่อน้ำเชื่อม 4 ส่วน

6. ปรับอุณหภูมิของน้ำเชื่อมให้อยู่ที่อุณหภูมิเท่ากับ 30, 40 และ 50 °C

7. จับเวลาของมะละกอกที่แช่อยู่ในน้ำเชื่อมเท่ากับ 4, 5 และ 6 ชั่วโมง

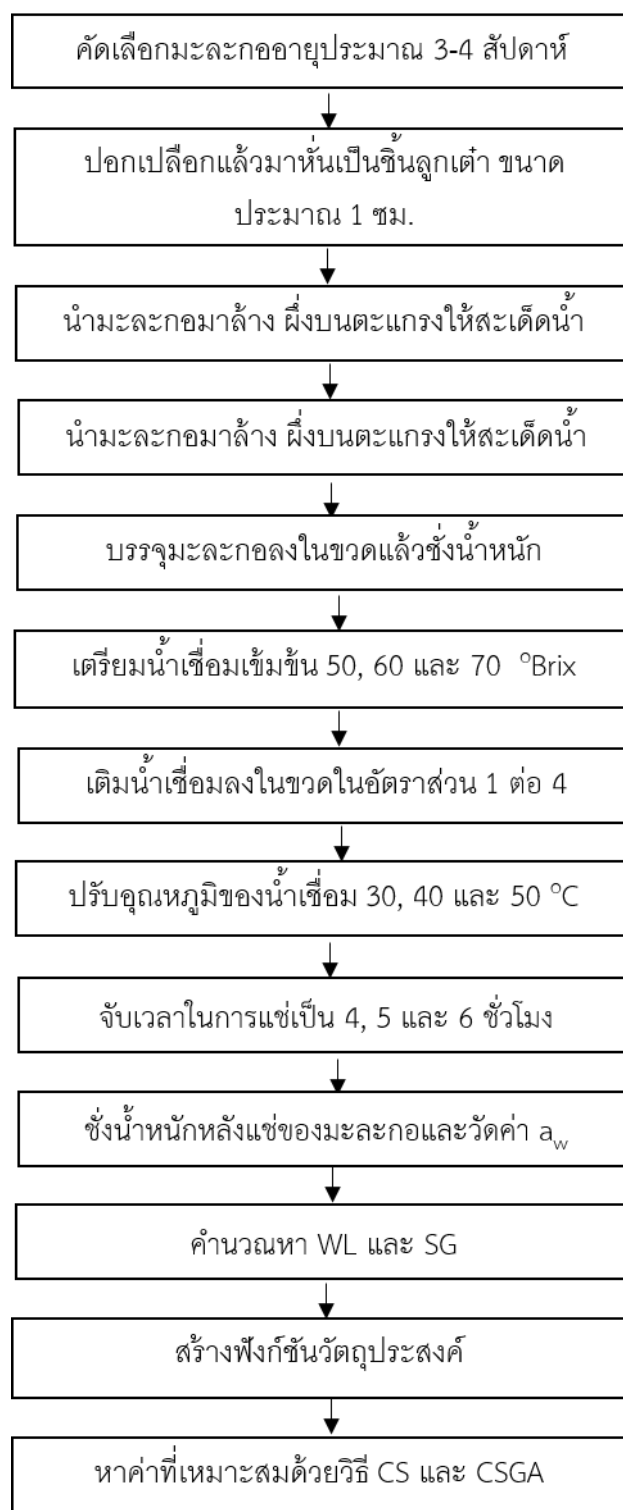
8. ชั่งน้ำหนักหลังแช่มะละกอกและวัดปริมาณปริมาตรของแข็ง (ปริมาณน้ำตาล)

9. คำนวณหาการสูญเสีย น้ำในมะละกอก (WL) และปริมาณน้ำตาลที่เพิ่มขึ้นในมะละกอก

(SG) ที่ผ่านการทำแห้งแบบออสโมซิส

10. นำข้อมูลที่ได้จากการทดลองไปสร้างฟังก์ชันวัตถุประสงค์โดยใช้วิธีการรีเกรสชัน (Regression)

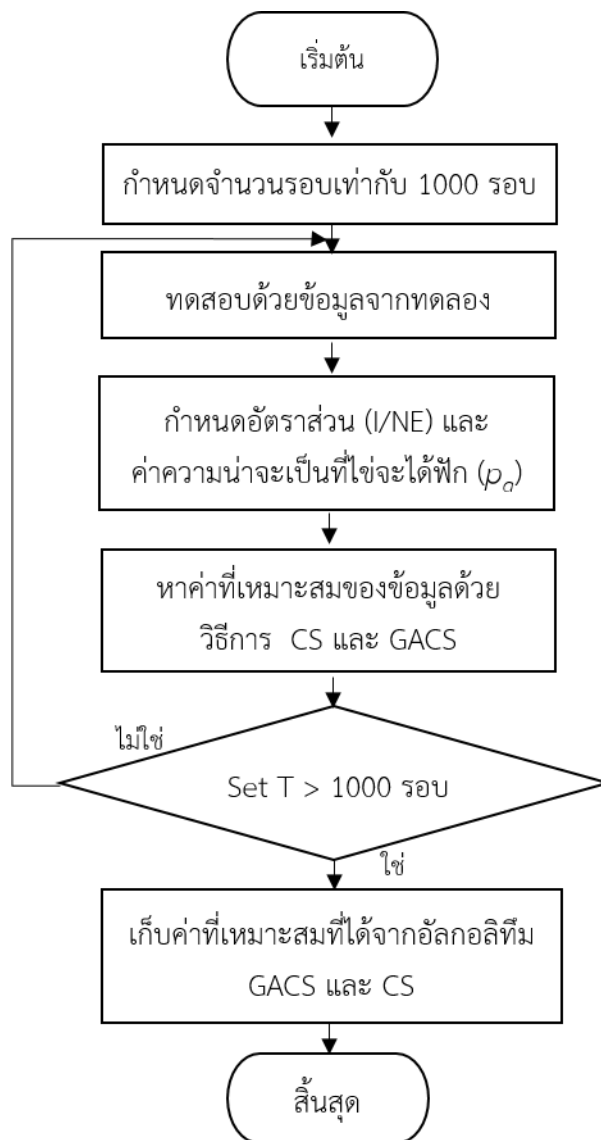
11. นำข้อมูลที่ได้จากการทดลองไปหาค่าที่เหมาะสมด้วยวิธีพื้นผิวตอบสนอง (RSM)
12. นำข้อมูลและฟังก์ชันวัตถุประสงค์ไปหาค่าที่เหมาะสมด้วยวิธี CS และ CSGA



ภาพที่ 3-9 ผังการทดลองทำแห้งมะละกอแบบออสโมซิส



เมื่อได้ข้อมูลของความเข้มข้นของน้ำเชื่อม อุณหภูมิของน้ำเชื่อม และเวลาที่แช่มะละกอกี้ ทำให้ได้ค่า WL และ SG เป็นตามที่กำหนด จากนั้นนำค่าที่ได้ไปทำการทดลองทำแห้งมะละกอกี้ครั้ง โดยใช้ข้อมูลที่ได้จากวิธี RSM, CS และ CSGA โดยมีขั้นตอนดังนี้



ภาพที่ 3-10 ผังขั้นตอนการหาค่าที่เหมาะสมด้วย CSGA กับ CS

1. กำหนดจำนวนรอบเท่ากับ 1000 รอบ
2. นำค่าที่เหมาะสมที่ได้จากวิธี RSM, CS และ CSGA ไปทำการทดลองอีกครั้ง
3. กำหนดอัตราส่วนระหว่างรอบการคำนวณ (I) ต่อจำนวนไข่ (NE) และกำหนดค่าความน่าจะเป็นที่ไข่จะได้ฟัก ( $p_0$ )

4. จำนวนรอบ > 1000 รอบ โดยการตรวจสอบจำนวนการวนรอบปัจจุบันว่ามากกว่าจำนวนรอบที่กำหนดหรือไม่
  5. ถ้าไม่ใช่ ให้ไปทำในขั้นตอนที่ 2
  6. ถ้าใช่ ให้ไปทำในขั้นตอนที่ 8
  7. เก็บค่าที่เหมาะสมที่ได้จากอัลกอริทึม CS และ CSGA
  8. นำค่าร้อยละของความคลาดเคลื่อนที่ได้จากทั้งสามวิธีไปเปรียบเทียบกัน
  9. คัดเลือกวิธีการหาค่าที่เหมาะสมที่มีค่าร้อยละของความคลาดเคลื่อนน้อยที่สุด
- วิธีการคำนวณหาค่าความคลาดเคลื่อน**

เมื่อหาค่าที่เหมาะสมจากการวิธีการ RSM และอัลกอริทึม CS และ CSGA ได้เรียบร้อยแล้ว นำค่าที่เหมาะสมที่ได้จากแต่ละวิธีไปทำการทดลองทำแห้งมะละกอแบบออสโมซิส จากนั้นนำผล WL และ SG ที่ได้จากการทดลองไปคำนวณหาความคลาดเคลื่อน โดยใช้สูตรคำนวณดังนี้

$$\%Error = \left| \frac{x_p - x_r}{x_p} \right| \times 100$$

เมื่อ  $x_p$  คือ ค่าที่เหมาะสมที่ได้จากอัลกอริทึม  
 $x_r$  คือ ค่าจริงที่ได้จากการทดลอง

หลังจากดำเนินการคำนวณหาความคลาดเคลื่อนระหว่างค่าที่เหมาะสมที่ได้จากอัลกอริทึม และค่าจริงที่ได้จากการทดลองของแต่ละวิธีเรียบร้อยแล้ว จากนั้นนำค่าความคลาดเคลื่อนที่ได้ไปเปรียบเทียบกันในแต่ละวิธี เพื่อทำการคัดเลือกวิธีการหาค่าที่เหมาะสมโดยเลือกวิธีที่มีค่าร้อยละของความคลาดเคลื่อนน้อยที่สุด สำหรับนำไปใช้ในการหาค่าที่เหมาะสมของการทำแห้งมะละกอแบบออสโมซิส

## บทที่ 4 ผลการวิจัย

การศึกษานี้มีวัตถุประสงค์เพื่อพัฒนาวิธีการค้นหาแบบนกกาเหว่าโดยการผสมผสานด้วยเจเนติกอัลกอริทึม (CSGA) สำหรับหาค่าที่เหมาะสมของการทำแห้งมะละกอบอบออสโมซิส และเปรียบเทียบประสิทธิภาพกับวิธีการค้นหาแบบนกกาเหว่า (CS) และวิธีพื้นผิวตอบสนอง (RSM) ดำเนินการศึกษา โดยนำวิธีการค้นหาแบบนกกาเหว่า (CS) ไปผสมผสานกับเจเนติกอัลกอริทึม แล้วทดสอบการทำงานของอัลกอริทึมด้วยฟังก์ชันมาตรฐาน Sphere Model, Schwefel's Problem, Schwefel's Problem, Schwefel's Problem และ Generalized Rosenbrock's Function โดยเปรียบเทียบค่าที่เหมาะสมและเวลาที่ใช้ในการหาค่าที่เหมาะสม หลังจากนั้นเปรียบเทียบค่าความคลาดเคลื่อนของค่าที่เหมาะสมที่ได้จากอัลกอริทึม CSGA, CA และ RSM กับค่าที่ได้จากการทดลองทำแห้งมะละกอบอบออสโมซิสโดยใช้แผนการทดลองแบบบ็อกซ์-เบนเคน (Yao et al., 1999) ประกอบด้วยปัจจัยดังนี้ อุณหภูมิของน้ำเชื่อม (C) เท่ากับ 50, 60 และ 70 °C ระดับความเข้มข้นของน้ำเชื่อม ( $\theta$ ) เท่ากับ 30, 40 และ 50 °Brix และที่ระยะเวลา (T) เท่ากับ 4, 5 และ 6 ชั่วโมง หลังจากนั้นนำค่าที่เหมาะสมของการทำแห้งมะละกอบอบออสโมซิสที่ได้จากวิธีการผสมผสานระหว่างการค้นหาแบบนกกาเหว่ากับเจเนติกอัลกอริทึม (CSGA) ไปทดลองทำแห้งมะละกอบอบออสโมซิส ผลการวิจัยสามารถนำเสนอได้ดังต่อไปนี้

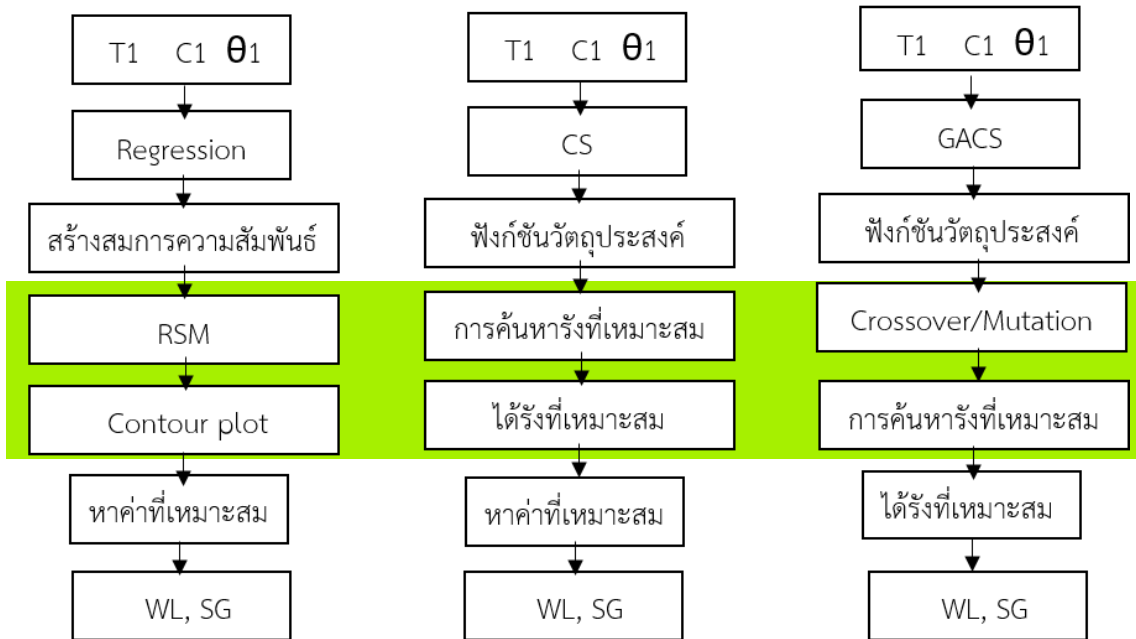
### ตอนที่ 1 ผลการพัฒนาวิธีการค้นหาแบบนกกาเหว่าโดยการผสมผสานด้วยเจเนติกอัลกอริทึม

กระบวนการทำแห้งแบบออสโมซิสนั้นมีปัจจัยที่ส่งผลต่อร้อยละของปริมาณน้ำที่ลดลง (WL) และร้อยละของปริมาณน้ำตาลที่เพิ่มขึ้น (SG) ประกอบด้วยสามปัจจัยหลัก ได้แก่ ความเข้มข้นของน้ำเชื่อม อุณหภูมิของน้ำเชื่อมและเวลาที่ใช้แช่มะละกอในน้ำเชื่อม หากสามารถหาค่าสถานะที่เหมาะสมของทั้งสามปัจจัยได้แล้ว จะสามารถทำนายร้อยละของปริมาณน้ำที่ลดลง (WL) ในขณะที่ยังมีร้อยละของปริมาณน้ำตาลที่เพิ่มขึ้น (SG) เท่ากับ 4 ได้อย่างแม่นยำ ทำให้วิธีการแก้ปัญหาดังกล่าวสามารถดำเนินการได้อย่างไม่ยากมากนัก จึงมีความพยายามหาวิธีการหาค่าที่เหมาะสมมาใช้ในกระบวนการทำแห้งแบบออสโมซิสอย่างต่อเนื่อง เพื่อเพิ่มประสิทธิภาพให้กับวิธีการหาค่าที่เหมาะสมสำหรับกระบวนการทำแห้ง จากการศึกษาเอกสารงานวิจัยที่เกี่ยวข้องสามารถสรุปความแตกต่างของอัลกอริทึม CS, CSGA และ RSM ดังต่อไปนี้

ตารางที่ 4-1 การเปรียบเทียบความแตกต่างของวิธีการหาค่าที่เหมาะสม

RSM	CS	CSGA
สร้างสมการความสัมพันธ์	สร้างฟังก์ชันวัตถุประสงค์	สร้างฟังก์ชันวัตถุประสงค์
หาค่าที่เหมาะสมด้วยการสร้างกราฟ Response Surface Method จากข้อมูลที่ได้จากการทดลอง (Contour Plot)	หาค่าที่เหมาะสมด้วยการเลียนพฤติกรรมกรวางไข่ และการค้นหารังของนกกาเหว่า (Lévy-flights)	หาค่าที่เหมาะสมด้วยการเลียนพฤติกรรมกรวางไข่ การค้นหารังของนกกาเหว่า (Lévy-flights) และปรับปรุงการถ่ายทอดทางพฤติกรรมกรค้นหารังด้วยขั้นตอนการ Crossover และ Mutation
หาค่าที่เหมาะสมได้ครั้งละหนึ่งฟังก์ชันวัตถุประสงค์	หาค่าที่เหมาะสมได้ครั้งละหนึ่งฟังก์ชันวัตถุประสงค์	สามารถหาค่าที่เหมาะสมได้มากกว่าหนึ่งฟังก์ชันวัตถุประสงค์ต่อครั้ง
กำหนดแผนการทดลอง จำนวนและระดับของตัวแปร	กำหนดค่าเริ่มต้น จำนวนรอบ และค่าพารามิเตอร์	กำหนดค่าเริ่มต้น จำนวนรอบ และค่าพารามิเตอร์
หาค่าที่เหมาะสมด้วยวิธี Response Surface Method	หาค่าที่เหมาะสมด้วยอัลกอริทึม CS	หาค่าที่เหมาะสมด้วยไฮบริดอัลกอริทึม CSGA

เมื่อเปรียบเทียบความแตกต่างกันของวิธีการหาค่าที่เหมาะสม ปรากฏว่า วิธี RSM มีความแตกต่างกันเล็กน้อยจากวิธีวิธีการค้นหาแบบนกกาเหว่า (CS) และวิธีผสมผสานระหว่างวิธีการค้นหาแบบนกกาเหว่ากับเจเนติกอัลกอริทึม (CSGA) ในขั้นตอนของการสร้างฟังก์ชันความสัมพันธ์หรือฟังก์ชันวัตถุประสงค์ แต่มีความแตกต่างกันค่อนข้างสูงในขั้นตอนของการหาค่าที่เหมาะสม สำหรับวิธี RSM นั้นสามารถหาค่าที่เหมาะสมโดยอาศัยการเขียนกราฟสามมิติแสดงถึงผลที่เกิดขึ้นจากแต่ละปัจจัย จากนั้นเขียนกราฟ Contour Plot เพื่อฉายภาพกราฟสามมิติให้อยู่ในรูปของกราฟสองมิติสำหรับหาค่าที่เหมาะสมของทั้งสามปัจจัย สำหรับวิธีการค้นหาแบบนกกาเหว่า (CS) นั้นอาศัยหาค่าที่เหมาะสมด้วยการเลียนพฤติกรรมกรวางไข่ และการค้นหารังของนกกาเหว่า (Lévy-flights) สอดคล้องกับวิธีผสมผสานระหว่างวิธีการค้นหาแบบนกกาเหว่ากับเจเนติกอัลกอริทึม (CSGA) อาศัยหาค่าที่เหมาะสมด้วยการเลียนพฤติกรรมกรวางไข่ การค้นหารังของนกกาเหว่า (Lévy-flights) และปรับปรุงการถ่ายทอดทางพฤติกรรมกรค้นหารังด้วยขั้นตอนการ Crossover และ Mutation สามารถหาค่าที่เหมาะสมได้ครั้งละสองฟังก์ชัน โดยนำสามารถนำมาเปรียบเทียบดังตารางที่ 4-1



ภาพที่ 4-1 ผลการเปรียบเทียบอัลกอริทึมของ RSM, CS และ CSGA

ผลการเปรียบเทียบอัลกอริทึมของ RSM, CS และ CSGA ปรากฏว่า RSM ใช้วิธีการเปรียบเทียบทั้งแบบกราฟสามมิติและ Contour Plot ในการหาค่าที่เหมาะสม แตกต่างจากอัลกอริทึม CS ที่ใช้วิธีการเลียนแบบพฤติกรรมกรรมการค้นหาและวางไข่ของนกกาเหว่าในการค่าที่เหมาะสม ส่วนอัลกอริทึม CSGA และวิธีการเลียนแบบพฤติกรรมกรรมการค้นหาและวางไข่ของนกกาเหว่าในการค่าที่เหมาะสมร่วมกับกระบวนการ Crossover and Mutation ของเจเนติกอัลกอริทึม และทดสอบด้วยฟังก์ชันวัตถุประสงค์

ในขั้นตอนการพัฒนาการหาค่าที่เหมาะสมด้วยวิธีการผสมผสานระหว่างวิธีการค้นหาแบบนกกาเหว่ากับเจเนติกอัลกอริทึมนำมาเขียนเป็น Pseudo-code เปรียบเทียบกับเจเนติกอัลกอริทึมได้ดังต่อไปนี้

อัลกอริทึม CS	อัลกอริทึม CSGA
Define Number of nets and generate new net rate	Define Number of nets, eggs and generate new net rate
for Iteration = 1 to Iteration Max ( $I_{Max}$ )	for Iteration = 1 to Iteration Max ( $I_{Max}$ )
Calcurate Objective function	Calcurate Objective function
	$f(x), x = (x_1, \dots, x_n)$

ภาพที่ 4-2 Pseudo-code ของ CSGA และ CS

อัลกอริทึม CS	อัลกอริทึม CSGA
Calcurate Objective function $f(x), x = (x_1, \dots, x_n)$ Generate initial population $x_i; (i = 1, 2, \dots, N)$ <b>end for</b> To sort of objective Function in each nest Roulette wheel selection Levy flights Generate new eggs Evaluate fitness, $F(y_i)$ <b>if</b> $F(y_i) > F(x_i)$ Replace $x_i$ with $y_i$ <b>end if</b> (Destroy the worst nest) Cuckoo eggs dumped into other nests Find the current best solution <b>end while</b>	$x_i; (i = 1, 2, \dots, N)$ <b>end for</b> while $n < \text{maxGeneration}$ or stopping <b>Selection</b> Number of elitism $ne = \alpha \cdot \beta$ ; Select the best $ne$ solution in Pop <b>Crossover</b> Number of crossover $nc = (\alpha - ne)/2$ ; <b>For</b> $j = 1$ to $nc$ do Randomly select two solutions $x_a$ and $x_b$ from generate $x_c$ and $x_d$ by K-point crossover to $x_a$ and $x_b$ ; $x_c$ and $x_d$ to Pop <sub>2</sub> ; <b>end for</b> <b>Mutation</b> <b>For</b> $j = 1$ to $nc$ do Select a solution $x_j$ from Pop <sub>2</sub> ; Mutate each bit of $x_j$ under the rate $\gamma$ and generate a new solution $x_j'$ ; <b>if</b> $x_j'$ is unfeasible Update $x_j'$ with a feasible solution by repairing $x_j'$ ; <b>End if</b> Update $x_j$ with $x_j'$ in Pop <sub>2</sub> ; <b>End for</b> Roulette wheel selection, Lévy-flights Generate new eggs, Evaluate fitness, $F(y_i)$ <b>if</b> $F(y_i) > F(x_i)$ Replace $x_i$ with $y_i$ <b>end if</b> Cuckoo eggs dumped into other nests <b>end while</b>

ผลการเปรียบเทียบ Pseudo-code ระหว่างเจเนติกอัลกอริทึมกับอัลกอริทึมผสมผสาน CSGA ปรากฏว่า Pseudo-code มีความแตกต่างกันในขั้นตอน Evaluate Fitness โดยที่อัลกอริทึม CSGA ได้เพิ่มขั้นตอน Selection, Crossover และ Mutation เข้าไปในวิธีการค้นหาแบบนกกาเหว่า โดยมีรายละเอียดดังภาพที่ 4-2

## ตอนที่ 2 ผลการเปรียบเทียบประสิทธิภาพของวิธี CSGA ที่พัฒนาขึ้นกับวิธี CS และวิธี RSM


ผลการเปรียบเทียบประสิทธิภาพการทำงานของอัลกอริทึม CS, CSGA และ RSM โดยแบ่งผลการวิจัยเป็น 2 ตอนดังนี้ ตอนที่ 1 เปรียบเทียบประสิทธิภาพในการทำงานด้าน Best, Mean, SD ของค่าที่เหมาะสมและเวลาที่ใช้ในการหาผลลัพธ์ระหว่างอัลกอริทึม CS และ CSGA ด้วยฟังก์ชันมาตรฐาน (Benchmark Optimization Function) หาค่าต่ำที่สุดฟังก์ชันจำนวน 5 ฟังก์ชัน ได้แก่ Sphere Model, Schwefel's Problem, Schwefel's Problem, Schwefel's Problem และ Generalized Rosenbrock's Function โดยปรับปรุงจากวิธีการของ Yao and Liu (1999) จาก Australian Research, UNSW, ADFA ตอนที่ 2 เปรียบเทียบประสิทธิภาพการทำงานของอัลกอริทึม CS, CSGA และ RSM ด้วยข้อมูลที่ได้จากการทดลองทำหิ้งมะลอกด้วยวิธีออสโมซิส ได้ผลดังนี้

ตอนที่ 1 ผลการเปรียบเทียบประสิทธิภาพในการทำงานด้วยฟังก์ชันมาตรฐาน โดยนำค่า FBest\_min, FBest\_avg, Fbest\_std และ Avg\_time ของค่าที่เหมาะสมและเวลาที่ใช้ในการหาผลลัพธ์ระหว่างอัลกอริทึม CS และ CSGA มาเปรียบเทียบกัน

ตารางที่ 4-2 ผลการเปรียบเทียบประสิทธิภาพระหว่าง CS กับ CSGA

ฟังก์ชัน	อัลกอริทึม	FBest_min ค่าต่ำที่สุด	FBest_avg ค่าต่ำที่สุด เฉลี่ย	Fbest_std ค่าเบี่ยงเบน มาตรฐาน	Avg_time (Sec) เวลาเฉลี่ย
F <sub>1</sub>	CS	$9.86 \times 10^3$	$1.84 \times 10^4$	$4.45 \times 10^3$	0.5517
	CSGA	$9.68 \times 10^4$	$1.76 \times 10^4$	$4.45 \times 10^3$	0.4490
F <sub>2</sub>	CS	56.7144	$3.95 \times 10^8$	$1.86 \times 10^9$	0.5214
	CSGA	45.3304	$2.26 \times 10^8$	$1.41 \times 10^9$	0.4515
F <sub>3</sub>	CS	$1.97 \times 10^4$	$4.27 \times 10^4$	$9.72 \times 10^3$	0.7750
	CSGA	$1.78 \times 10^4$	$4.07 \times 10^4$	$9.30 \times 10^3$	0.7620
F <sub>4</sub>	CS	40.5175	58.1089	6.6906	0.5469
	CSGA	33.9201	56.1183	6.3635	0.3889
F <sub>5</sub>	CS	$5.90 \times 10^6$	$2.46 \times 10^7$	$9.47 \times 10^6$	0.5809
	CSGA	$2.38 \times 10^6$	$1.60 \times 10^7$	$7.51 \times 10^6$	0.4849

ผลการเปรียบเทียบประสิทธิภาพในการหาค่าที่เหมาะสมระหว่างวิธีการค้นหาแบบนกกาเหว่า (CS) และวิธีผสมผสานระหว่างวิธีการค้นหาแบบนกกาเหว่ากับเจเนติกอัลกอริทึม (CSGA) ด้วยฟังก์ชันมาตรฐานจำนวน 5 ฟังก์ชัน โดยที่แต่ละอัลกอริทึมจะทำการวนซ้ำหาค่าที่เหมาะสมจำนวน 1000 รอบ จากนั้นนำค่า Best\_min, Fbest\_avg, Fbest\_std, และ Avg\_time (เวลาที่ใช้ในการหาค่าที่เหมาะสม) แสดงให้เห็นว่า วิธีหาค่าที่เหมาะสมแบบผสมผสาน CSGA สามารถหาค่า Best\_min, Fbest\_avg, Fbest\_std, และ Avg\_time ในทุกฟังก์ชัน ดีกว่าวิธีการค้นหาแบบนกกาเหว่า โดยสามารถนำมาเปรียบเทียบได้ดังนี้



ภาพที่ 4-3 กราฟร้อยละความแตกต่างของประสิทธิภาพในการหาค่าที่เหมาะสม

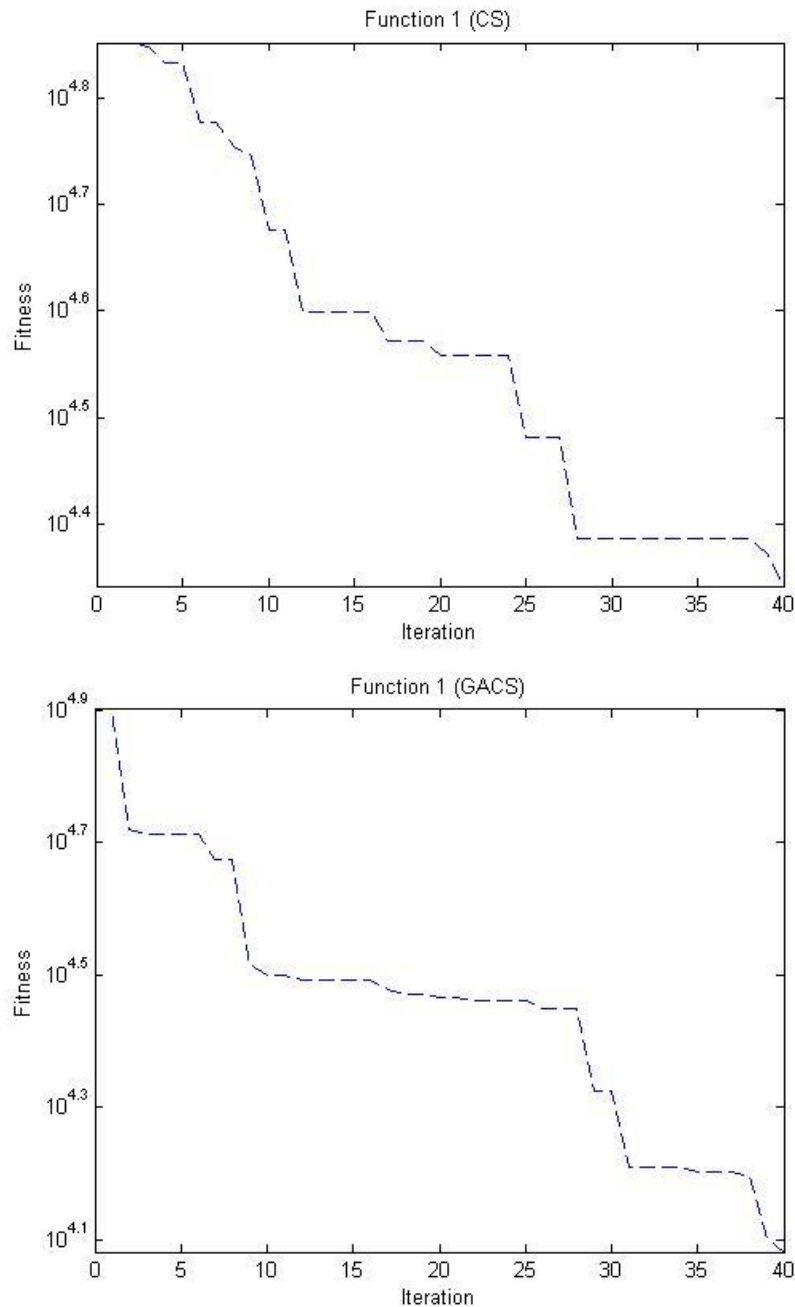
กราฟร้อยละของความแตกต่างของประสิทธิภาพในการหาค่าที่เหมาะสม โดยสามารถอธิบายความหมายของกราฟได้ดังนี้

1. ร้อยละความแตกต่างของประสิทธิภาพในการหาค่าที่เหมาะสมมีค่าเท่ากับศูนย์ หมายความว่าอัลกอริทึม CSGA และ CS มีประสิทธิภาพเท่ากัน
2. ร้อยละความแตกต่างของประสิทธิภาพในการหาค่าที่เหมาะสมมีค่ามากกว่าศูนย์ หมายความว่าอัลกอริทึม CSGA มีประสิทธิภาพดีกว่า CS
3. ร้อยละความแตกต่างของประสิทธิภาพในการหาค่าที่เหมาะสมมีค่าน้อยกว่าศูนย์ หมายความว่าอัลกอริทึม CSGA มีประสิทธิภาพด้อยกว่า CS

ผลของการเปรียบเทียบประสิทธิภาพของอัลกอริทึม CSGA และ CS ปรากฏว่า ฟังก์ชันที่ 1, 3 และ 4 อัลกอริทึม CSGA มีประสิทธิภาพดีกว่า CS เล็กน้อย โดยมีค่าร้อยละความแตกต่างของประสิทธิภาพเท่ากับ 3.8, 4.7 และ 3.4 ตามลำดับ (ค่าร้อยละความแตกต่างของประสิทธิภาพน้อยกว่าร้อยละ 5) ส่วนฟังก์ชันที่ 2 และ 5 อัลกอริทึม CSGA มีประสิทธิภาพดีกว่า CS ค่อนข้างสูงมาก



(ค่าร้อยละความแตกต่างของประสิทธิภาพมากกว่าร้อยละ 30) โดยมีค่าร้อยละความแตกต่างของประสิทธิภาพเท่ากับ 42.8 และ 35 ตามลำดับ เมื่อนำมาเปรียบในรูปของกราฟเส้นที่แสดงถึงการลู่เข้าหาคำตอบของอัลกอริทึม สามารถแสดงได้ดังนี้

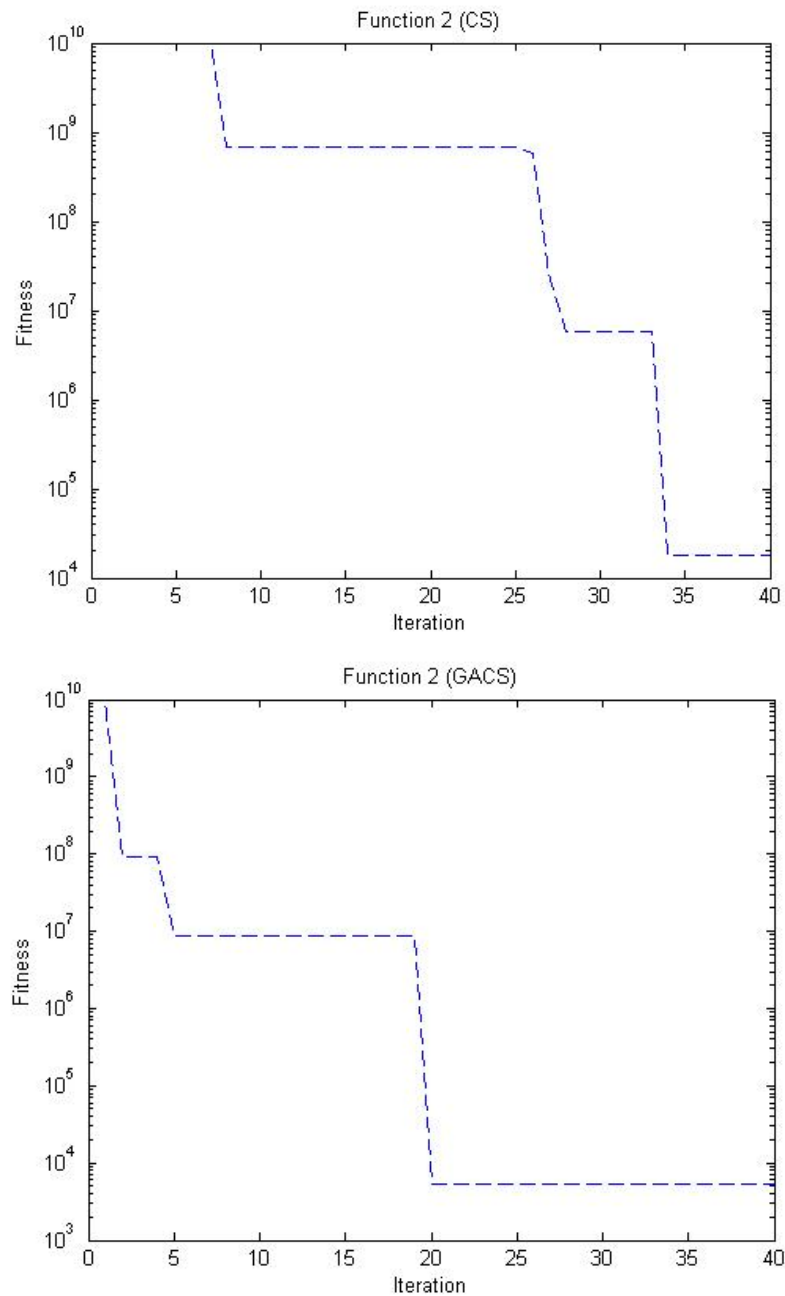


ภาพที่ 4-4 ผลการเปรียบเทียบประสิทธิภาพด้วย Sphere Model

ผลการเปรียบเทียบประสิทธิภาพในการค่าต่ำที่สุดของฟังก์ชันมาตรฐาน Sphere model ระหว่างอัลกอริทึม CSGA กับ CS ได้ผลดังนี้

ฟังก์ชันที่ 1 อัลกอริทึม CSGA สามารถหาค่าต่ำที่สุดของฟังก์ชันได้อย่างรวดเร็วในช่วง

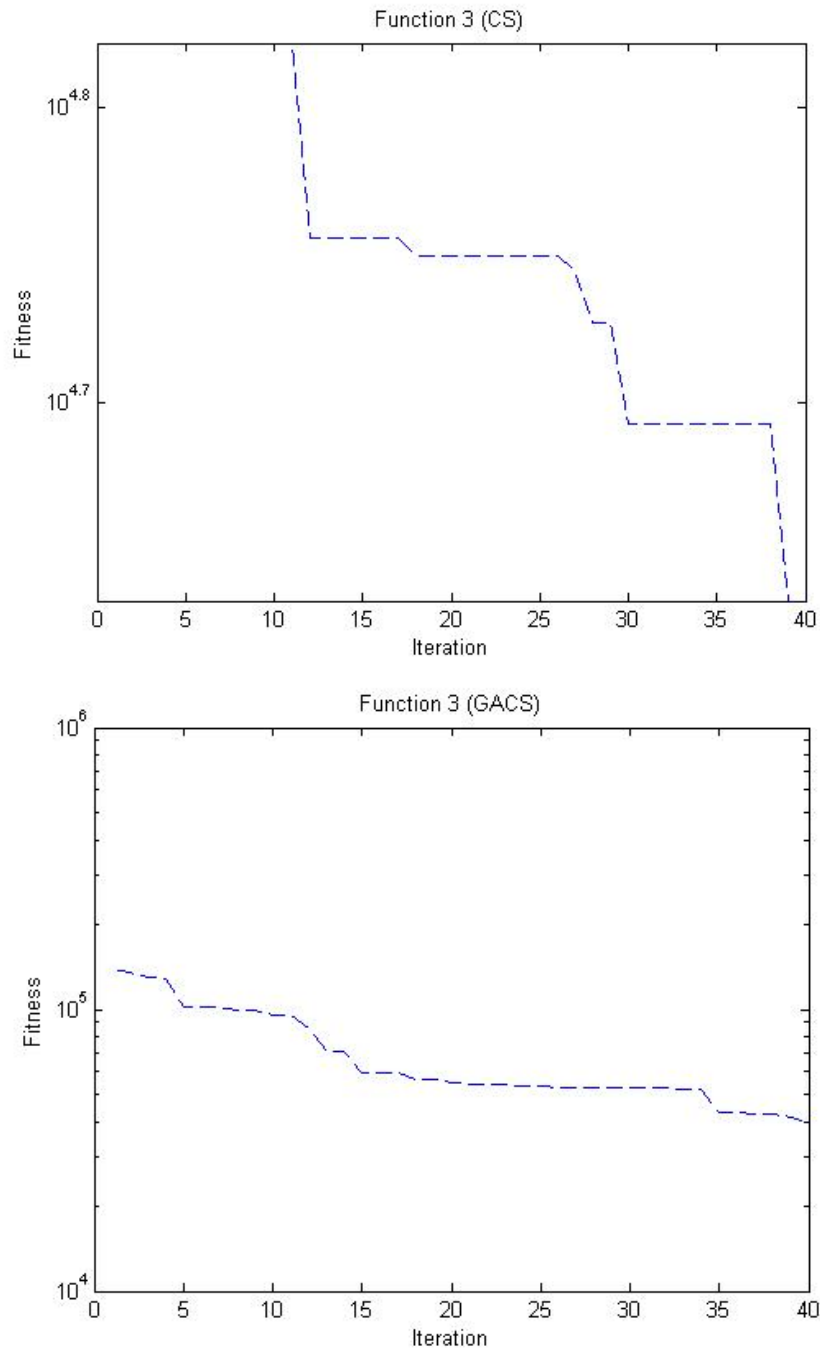
0--3 รอบ และ 7-10 รอบ แล้วข้ามลงเมื่อผ่านช่วง 10 รอบไปแล้วในขณะที่อัลกอริทึม CS สามารถหาค่าต่ำที่สุดของฟังก์ชันได้อย่างรวดเร็วในช่วงหลังจาก 10 รอบ แล้วข้ามลงเมื่อผ่าน 15 รอบไปแล้ว



ภาพที่ 4-5 ผลการเปรียบเทียบประสิทธิภาพด้วย Schwefel's Problem

ผลการเปรียบเทียบประสิทธิภาพในการค่าต่ำที่สุดของฟังก์ชันมาตรฐาน Schwefel's Problem ระหว่างอัลกอริทึม CSGA กับ CS ได้ผลดังนี้

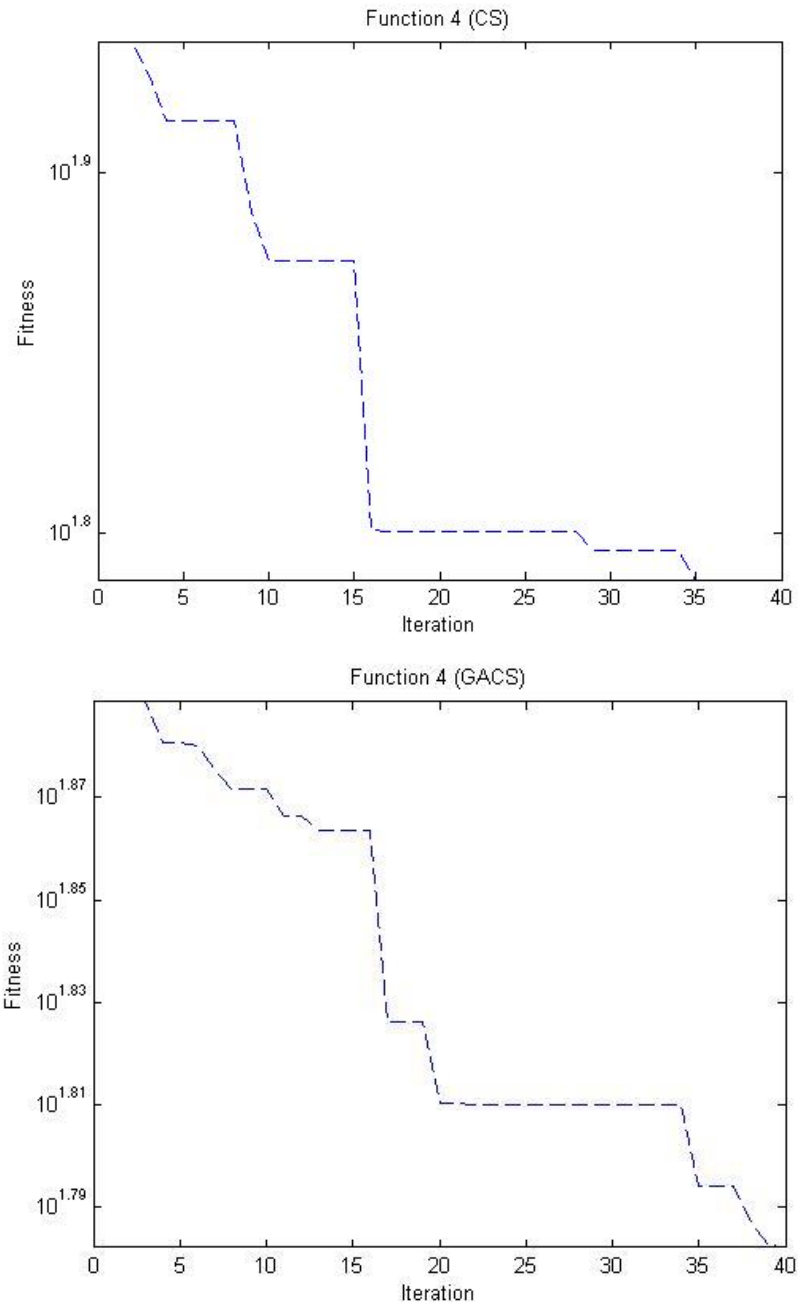
ฟังก์ชันที่ 2 อัลกอริทึม CSGA สามารถหาค่าต่ำที่สุดของฟังก์ชันได้อย่างรวดเร็วในช่วง 1-5 รอบ แล้วช้าลงเมื่อผ่านช่วง 17-20 รอบในขณะที่อัลกอริทึม CS สามารถหาค่าต่ำที่สุดของฟังก์ชันได้อย่างรวดเร็วในช่วงหลังจาก 7-9 รอบ แล้วช้าลงเมื่อผ่าน 34-35 รอบ



ภาพที่ 4-6 ผลการเปรียบเทียบประสิทธิภาพด้วย Schwefel's Problem

ผลการเปรียบเทียบประสิทธิภาพในการค่าต่ำที่สุดของฟังก์ชันมาตรฐาน Schwefel's Problem ระหว่างอัลกอริทึม CSGA กับ CS ได้ผลดังนี้

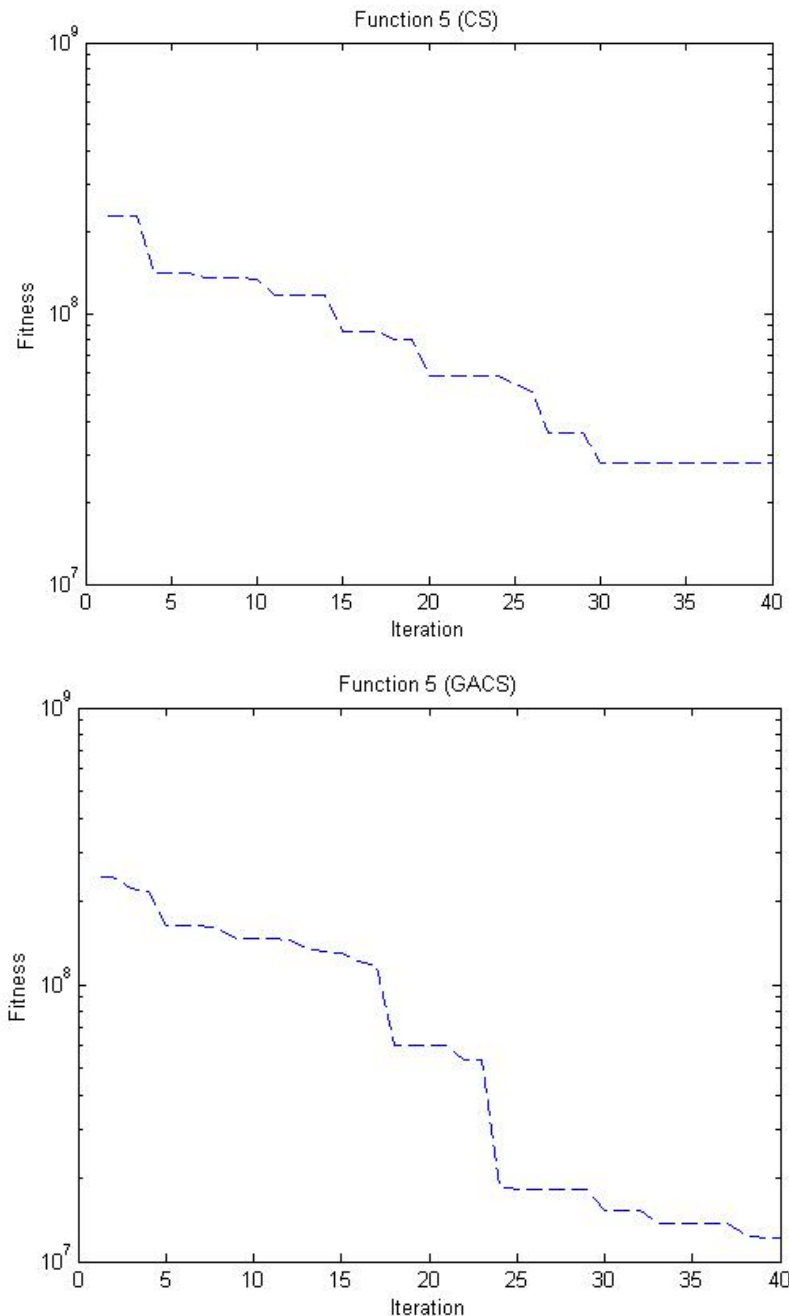
ฟังก์ชันที่ 3 อัลกอริทึม CSGA สามารถหาค่าต่ำที่สุดของฟังก์ชันได้อย่างรวดเร็วในช่วง 4-5 รอบ แล้วช้าลงเมื่อผ่านช่วง 10 รอบไปแล้วในขณะที่อัลกอริทึม CS สามารถหาค่าต่ำที่สุดของฟังก์ชันได้อย่างรวดเร็วในช่วงหลังจาก 11-13 รอบ แล้วช้าลงเมื่อผ่าน 39 รอบไปแล้ว



ภาพที่ 4-7 ผลการเปรียบเทียบประสิทธิภาพด้วย Schwefel's Problem

ผลการเปรียบเทียบประสิทธิภาพในการหาค่าต่ำที่สุดของฟังก์ชันมาตรฐาน Schwefel's Problem ระหว่างอัลกอริทึม CSGA กับ CS ได้ผลดังนี้

ฟังก์ชันที่ 4 อัลกอริทึม CSGA สามารถหาค่าต่ำที่สุดของฟังก์ชันได้อย่างรวดเร็วในช่วง 3-20 และ 16-17 รอบ แล้วช้าลงเมื่อผ่านช่วง 34 รอบไปแล้วในขณะที่อัลกอริทึม CS สามารถหาค่าต่ำที่สุดของฟังก์ชันได้อย่างรวดเร็วในช่วงหลังจาก 2-16 รอบ แล้วช้าลงเมื่อผ่าน 33 รอบไปแล้ว



ภาพที่ 4-8 ผลการเปรียบเทียบประสิทธิภาพด้วย Generalized Rosenbrock's Function

ผลการเปรียบเทียบประสิทธิภาพในการหาค่าต่ำที่สุดของฟังก์ชันมาตรฐาน Generalized Rosenbrock's Function ระหว่างอัลกอริทึม CSGA กับ CS ได้ผลดังนี้

ฟังก์ชันที่ 5 อัลกอริทึม CSGA สามารถหาค่าต่ำที่สุดของฟังก์ชันได้อย่างรวดเร็วในช่วง 16-17 และ 34 รอบไปแล้วเมื่อผ่านช่วง 17 รอบไปแล้วในขณะที่อัลกอริทึม CS สามารถหาค่าต่ำที่สุดของฟังก์ชันได้อย่างรวดเร็วในช่วงหลังจาก 2-3 และ 13 รอบไปแล้ว

สรุปผลการเปรียบเทียบความสามารถในการหาค่าต่ำที่สุดของฟังก์ชันชนิด Unimodal ระหว่างอัลกอริทึม CSGA กับ CS พบว่า อัลกอริทึม CSGA มีความสามารถหาค่าต่ำที่สุดของฟังก์ชันได้อย่างรวดเร็วส่วนใหญ่แล้วอยู่ในช่วงประมาณ 2-3 รอบ ในขณะที่อัลกอริทึม CS มีความสามารถต่ำกว่าในทุกฟังก์ชัน

ตอนที่ 2 ผลการเปรียบเทียบประสิทธิภาพการทำงานของอัลกอริทึม CS, CSGA และ RSM ด้วยค่าความคลาดเคลื่อน โดยใช้ข้อมูลที่ได้จากการทดลองทำห้ำงมะละกอด้วยวิธีออสโมซิส ได้ผลดังนี้

ตารางที่ 4.3 ค่าความคลาดเคลื่อนของการทำห้ำงมะละกอแบบออสโมซิส

วิธีการ	WL(%)	WL(%)	SG(%)	SG(%)	Error WL(%)	Error SG(%)
	ทำนาย	ทดลอง	ทำนาย	ทดลอง		
RSM	32.4	28.7	4.2	3.8	11.4	9.2
CS	32.9	30.2	3.8	4.0	8.2	7.1
CSGA	33.7	32	4.0	4.1	5.0	4.0

ผลการวิเคราะห์หาค่าความคลาดเคลื่อนของค่าที่เหมาะสมที่ได้จากอัลกอริทึม (ค่าทำนาย) กับค่าที่ได้จากการทดลอง (ค่าทดลอง) พบว่า ค่าความคลาดเคลื่อนของค่า Water Loss และ Sugar Gain ที่ได้จากวิธี RSM มีค่าเท่ากับ 11.4 และ 9.2 ตามลำดับ ในขณะที่ค่าความคลาดเคลื่อนของค่า Water Loss และ Sugar Gain ที่ได้จากอัลกอริทึม CS มีค่าเท่ากับ 8.2 และ 7.1 ตามลำดับ ในขณะที่ค่าความคลาดเคลื่อนของค่า Water Loss และ Sugar Gain ที่ได้จากอัลกอริทึม CSGA มีค่าเท่ากับ 5.0 และ 4.0 ตามลำดับ

### ตอนที่ 3 ผลการหาค่าที่เหมาะสมของการทำห้ำงมะละกอแบบออสโมซิส

ผลจากนำมะละกอพันธุ์แขกดำที่อยู่ในระยะกำลังห้ำง (อายุประมาณ 3 สัปดาห์) มาทำการทดลองทำห้ำงด้วยกระบวนการออสโมซิสโดยใช้วิธีการวางแผนการทดลองแบบบ็อกซ์-เบนเคน โดยกำหนดความเข้มข้นของน้ำเชื่อมเท่ากับ 50, 60 และ 70 บริกซ์ กำหนดอุณหภูมิเท่ากับ 30, 40 และ 50 องศาเซลเซียสและกำหนดเวลาเท่ากับ 4, 5 และ 6 ชั่วโมง แล้วนำผลการทดลองที่ได้ไปสร้างฟังก์ชันวัตถุประสงค์สำหรับการห้ำงที่เหมาะสมด้วยอัลกอริทึม CS อัลกอริทึม CSGA และวิธี RSM แล้วนำค่าที่เหมาะสมที่ได้จากทั้ง 3 วิธีไปทำการทดลองอีกครั้ง จากนั้นนำค่าที่ได้จากการทดลองและค่าที่เหมาะสมที่ได้จากอัลกอริทึม CS อัลกอริทึม CSGA และวิธี RSM ไปคำนวณหาค่าความคลาดเคลื่อน ได้ผลการทดลองดังตาราง

ตารางที่ 4-4 ผลของปริมาณน้ำที่ลดลงและปริมาณของน้ำตาลที่เพิ่มขึ้น

ลำดับ	สิ่งทดลอง	ระดับ (°C)	ระดับ (°Brix)	ระดับ (Hrs)	น.น. ก่อน	น.น. หลัง	WR (%)	SG (%)	WL (%)
1	Block 1	50	70	5	50.1	32.0	36.1	8.1	44.2
2	Block 2	50	50	5	50.0	35.2	29.7	5.7	35.4
3	Block 3	30	70	5	50.1	37.0	27.1	4.3	31.4
4	Block 4	30	50	5	50.1	39.7	20.6	2.9	23.5
5	Block 5	50	60	6	50.1	31.9	36.3	8.4	44.7
6	Block 6	50	60	4	50.0	33.7	32.6	7.0	39.6
7	Block 7	30	60	6	50.1	38.4	23.3	3.9	27.2
8	Block 8	30	60	4	50.1	39.5	21.0	2.7	23.7
9	Block 9	40	70	6	50.1	33.4	33.3	5.0	38.3
10	Block 10	40	70	4	50.0	35.0	30.0	4.3	34.3
11	Block 11	40	50	6	50.1	38.1	24.0	4.4	28.4
12	Block 12	40	50	4	50.1	39.1	21.9	3.4	25.3
13	Block 13	40	60	5	50.1	37.3	25.5	4.4	29.9
14	Block 14	40	60	5	50.1	37.2	25.7	4.2	29.9
15	Block 15	40	60	5	50.1	37.2	25.8	4.5	30.3

ผลการทดลองทำแห้งมะละกอแบบออสโมซิส พบว่า ค่าการสูญเสียน้ำ (WL) ต่ำที่สุดและสูงที่สุดคือ 23.58 และ 44.54 ตามลำดับ และได้ค่าปริมาณของแข็งที่เพิ่มขึ้น (SG) ต่ำที่สุดและสูงที่สุดคือ 2.37 และ 8.13 ตามลำดับ จากนั้นนำข้อมูลที่ได้จากการทำการทดลองไปสร้างสมการความสัมพันธ์ระหว่างเวลา (Hrs) อุณหภูมิ (°C) และความเข้มข้นของน้ำเชื่อม (°Brix) กับ WL และ SG ดังนี้

#### ผลการวิเคราะห์ด้วยวิธีพื้นผิวตอบสนอง (Response Surface Method)

ผลการวิเคราะห์ความสัมพันธ์ระหว่างเวลา (Hrs) อุณหภูมิ (°C) และความเข้มข้นของน้ำเชื่อม (°Brix) กับ WL และ SG

นำสมการไปสร้างกราฟความสัมพันธ์ระหว่างเวลา (Hrs) อุณหภูมิ (°C) และความเข้มข้นของน้ำเชื่อม (°Brix) กับ WL เพื่อนำไปหาค่าที่เหมาะสมด้วยวิธีพื้นผิวตอบสนอง (Response Surface Method)

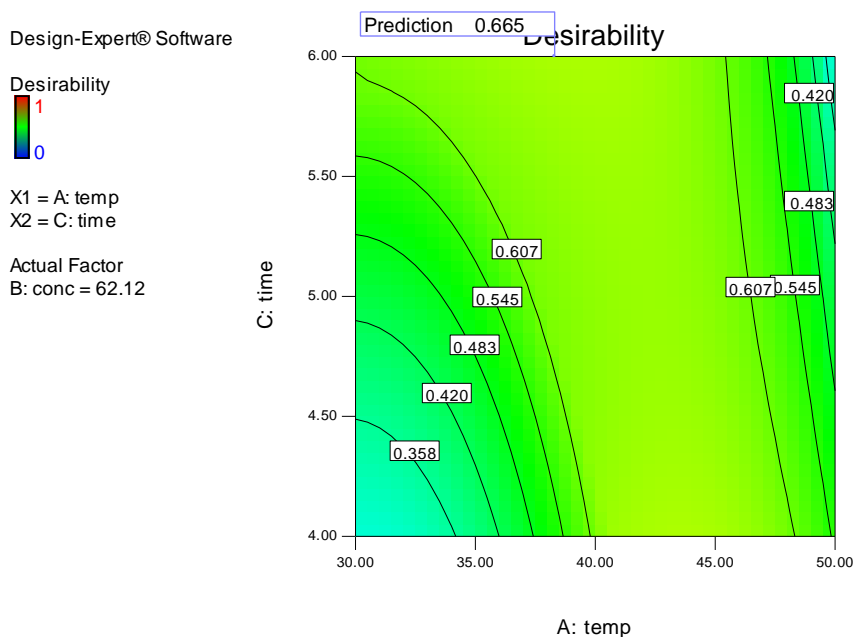
ตารางที่ 4-5 ผลการวิเคราะห์ความแปรปรวนของ Water Loss

Source	df	SS	MS	F	p
Model Significant	6	645.36	107.56	66.77	<0.0001
Temp	1	421.95	421.95	261.93	<0.0001
Residuals	8	12.89	1.61		
Lack of Fit	6	12.83	2.14	71.26	0.0139
Pure Error	2	0.06	0.03		
Cor Total	14	658.25			

ผลการวิเคราะห์หาความสัมพันธ์ของตัวอิสระกับตัวแปรตามด้วยรีเกรสชัน (Regression) พบว่ามีตัวแปรอิสระมีความสัมพันธ์กันเชิงเส้นตรงกับตัวแปรตาม โดยมีค่า R-squared เท่ากับ 0.92 จากนั้นนำผลการวิเคราะห์ไปสร้างสมการความสัมพันธ์ระหว่างเวลา (Hrs) อุณหภูมิ (°C) และความเข้มข้นของน้ำเชื่อม (°Brix) เพื่อใช้สำหรับหา WL ได้ดังต่อไปนี้

$$WL = 108.775 - 1.6337C - 0.7512\theta - 6.925T + 0.0295C^2 + 0.875T^2$$

นำสมการไปสร้างกราฟความสัมพันธ์ระหว่างเวลา (Hrs) อุณหภูมิ (°C) และความเข้มข้นของน้ำเชื่อม (°Brix) กับ WL เพื่อนำไปหาค่าที่เหมาะสมด้วยวิธีพื้นผิวตอบสนอง (Response Surface Method)



ภาพที่ 4-9 กราฟ Contour Plot ของ WL



ผลของระหว่างอุณหภูมิ (°C) และเวลา (Time) ต่อปริมาณน้ำในมะละกอที่ผ่านการทำแห้ง (WL) พบว่า ปริมาณน้ำในมะละกอแปรผันตามอุณหภูมิของน้ำเชื่อม (°C) และเวลา (Time) ที่ใช้ในการแช่มะละกอในน้ำเชื่อมที่เพิ่มขึ้น โดยมีค่าอยู่ระหว่าง 0-1 โดยมีค่า Prediction เท่ากับ 0.665

ตารางที่ 4-6 ผลการวิเคราะห์ความแปรปรวนของ Sugar Gain


Source	<i>df</i>	<i>SS</i>	<i>MS</i>	<i>F</i>	<i>p</i>
Model significant	5	38.16	7.63	31.86	0.0001
Temp	1	27.75	27.75	115.83	0.0001
Brix	1	3.64	3.64	15.22	0.0036
Time	1	2.10	2.10	8.77	0.0159
Temp <sup>2</sup>	1	4.36	4.36	18.19	0.0021
Residuals	9	2.16	0.24		
Lack of fit	7	2.16	0.31		
Pure Error	2	0.0	0.0		
Cor Total	14	40.31			

ผลการวิเคราะห์หาความสัมพันธ์ของตัวอิสระกับตัวแปรตามด้วยรีเกรสชัน (Regression) พบว่ามีตัวแปรอิสระมีความสัมพันธ์กันเชิงเส้นตรงกับตัวแปรตาม โดยมีค่า R-squared เท่ากับ 0.75 จากนั้นนำผลการวิเคราะห์ไปสร้างสมการความสัมพันธ์ระหว่างเวลา (Hrs) อุณหภูมิ (°C) และความเข้มข้นของน้ำเชื่อม (°Brix) เพื่อใช้สำหรับหา SG ได้ดังต่อไปนี้

นำผลการวิเคราะห์ข้อมูลมาสร้างสมการความสัมพันธ์ระหว่างเวลา (Hrs) อุณหภูมิ (°C) และความเข้มข้นของน้ำเชื่อม (°Brix) กับ SG ไปสร้างสมการทำนายในรูปของสมการ ดังนี้

$$SG = 19.5803 - 0.843C - 0.0425\theta + 0.5125T + 0.011C^2$$

นำสมการไปสร้างกราฟพื้นผิวตอบสนองเพื่อค่าที่เหมาะสมสำหรับไปใช้ในกระบวนการผลิตปริมาณมาก ๆ โดยอาศัยความสัมพันธ์ระหว่างเวลา (Hrs) อุณหภูมิ (°C) และความเข้มข้นของน้ำเชื่อม (°Brix) กับ SG เพื่อนำไปหาค่าที่เหมาะสมด้วยวิธีพื้นผิวตอบสนอง (Response Surface Method) ดังภาพ



ภาพที่ 4.10 กราฟ Contour Plot ของ SG

ผลการหาค่าที่เหมาะสมของอุณหภูมิ (°C) และความเข้มข้นของน้ำเชื่อม (°Brix) ต่อปริมาณการเพิ่มขึ้นของน้ำตาล (SG) ในการทำแห้งแบบออสโมซิส พบว่าค่า SG ที่เหมาะสมจะมีตำแหน่งสีเขียว หากปริมาณน้ำตาลมากหรือน้อยไป จะส่งผลต่อการยอมรับต่อผลิตภัณฑ์ของผู้บริโภค

ผลการหาค่าที่เหมาะสมของการทำแห้งแบบออสโมซิสด้วยวิธีพื้นผิวตอบสนอง (RSM) วิธีการค้นหาแบบนกกาเหว่า (CS) และวิธีผสมผสานระหว่างการค้นหาแบบนกกาเหว่ากับเจเนติกอัลกอริทึม (CSGA) ได้ผลดังนี้

ตารางที่ 4-7 ค่าที่เหมาะสมของพารามิเตอร์ของการทำแห้งมะละกอบแบบออสโมซิส

วิธีการ	อุณหภูมิ (C)	ความเข้มข้น (°Brix)	เวลา (Hrs)	Water Loss WL(%)	Sugar Gain SG(%)
RSM	38.3	62.2	6	32.4	4.2
CS	40	60	6	32.9	3.8
CSGA	42	60	6	33.7	4.0

จากการหาค่าที่เหมาะสมสำหรับการทำแห้งมะละกอบแบบออสโมซิสด้วยวิธี RSM, CS และ CSGA ผลการวิเคราะห์ พบว่า วิธี RSM สามารถวิเคราะห์หาค่า Water Loss และ Sugar Gain ได้

เท่ากับ 32.4 และ 4.2 ตามลำดับโดยใช้ความเข้มข้น อุณหภูมิ และเวลาดังนี้ 62.2, 38.3 และ 6 ตามลำดับ

วิธีการค้นหาแบบนกกาเหว่า (CS) สามารถวิเคราะห์หาค่า Water Loss และ Sugar Gain ได้เท่ากับ 32.9 และ 3.8 ตามลำดับโดยใช้อุณหภูมิของน้ำเชื่อม ความเข้มข้นของน้ำเชื่อม และเวลาที่แช่ในน้ำเชื่อม ดังนี้ 40, 60 และ 6 ตามลำดับ

วิธีผสมผสานระหว่างการค้นหาแบบนกกาเหว่ากับเจเนติกอัลกอริทึม (CSGA) สามารถวิเคราะห์หาค่า Water Loss และ Sugar Gain ได้เท่ากับ 33.7 และ 4.0 ตามลำดับโดยใช้ความเข้มข้นของน้ำเชื่อม ( $^{\circ}$ Brix) อุณหภูมิของน้ำเชื่อม (C) และเวลาที่แช่ในน้ำเชื่อม (Hrs) ดังนี้ 60, 42 และ 6 ตามลำดับ

หลักเกณฑ์การคัดเลือก

งานวิจัยนี้ใช้ผลการทดสอบการยอมรับทางประสาทสัมผัสจากงานวิจัยของ Jain et al. (2011) โดยมีรายละเอียดของการคัดเลือก ดังต่อไปนี้

1. จากงานวิจัยของค่าของ Jain et al. (2011) พบว่า Sugar Gain (SG) เท่ากับ 4.0 ผลิตภัณฑ์มะละกอแห้งได้รับคะแนนการยอมรับทางประสาทสัมผัสที่ดีที่สุด จากตารางที่ 4-7 อัลกอริทึมผสมผสาน CSGA สามารถหาค่าที่เหมาะสมที่ให้ค่า SG ได้เท่ากับ 4.0 ดีกว่าวิธี RSM และวิธีค้นหาแบบนกกาเหว่าดั้งเดิม (CS)

2. จากงานวิจัยของค่าของ Jain et al. (2011) พบว่า ค่าของ Water Loss (WL) ในผลิตภัณฑ์มะละกอแห้งควรมีค่าสูงที่สุด ทั้งนี้เพื่อยืดอายุการเก็บรักษา จากตารางที่ 4-7 อัลกอริทึมผสมผสาน CSGA สามารถหาค่าที่เหมาะสมที่ให้ค่า SG ได้เท่ากับ 4.0 ดีกว่าวิธี RSM และวิธีค้นหาแบบนกกาเหว่า (CS)

เกณฑ์การพิจารณาโดยใช้หลักการสุ่มชุดคำตอบที่เกิดจากการผสมชุดคำตอบตั้งต้นที่มีค่าใกล้เคียงกับเกณฑ์ที่กำหนดเพื่อให้ได้ชุดคำตอบที่เป็นไปได้ทั้งหมด แล้วคัดเลือกชุดคำตอบของตัวแปร  $\theta$ , C และ T ที่ทำให้ค่า SG มีค่าเข้าใกล้ 4.0 และ WL มีค่าสูงสุด

ผลการค่าที่เหมาะสมของการทำแห้งมะละกอแบบออสโมซิส ด้วยวิธีการหาค่าที่เหมาะสมแบบอัลกอริทึมผสมผสาน CSGA มีค่าของความเข้มข้นของน้ำเชื่อม อุณหภูมิของน้ำเชื่อม และเวลาที่แช่ในน้ำเชื่อม ดังนี้  $\theta = 60$   $^{\circ}$ Brix, C = 42  $^{\circ}$ c และ T = 6 Hrs ตามลำดับ โดยมีค่าร้อยละปริมาณน้ำที่ลดลงของมะละกอ Water Loss (WL) และค่าร้อยละปริมาณน้ำตาลที่เพิ่มขึ้นของมะละกอ Sugar Gain (SG) เท่ากับ 33.7 และ 4.0 ตามลำดับ โดยมีค่าร้อยละของความคลาดเคลื่อนประมาณ 0.04

## บทที่ 5

### สรุปและอภิปรายผลการวิจัย

การศึกษานี้มีวัตถุประสงค์เพื่อพัฒนาวิธีการค้นหาแบบนกกาเหว่าโดยการผสมผสานด้วย เจนติกอัลกอริทึม (CSGA) สำหรับหาค่าที่เหมาะสมของการทำห้่งมะละกอแบบออสโมซิส และ เปรียบเทียบประสิทธิภาพกับวิธีการค้นหาแบบนกกาเหว่า (CS) และวิธีพื้นผิวตอบสนอง (RSM) ดำเนินการศึกษา โดยนำวิธีการค้นหาแบบนกกาเหว่า (CS) ไปผสมผสานกับเจนติกอัลกอริทึม แล้ว ทดสอบการทำงานของอัลกอริทึมด้วยฟังก์ชันมาตรฐาน Sphere Model, Schwefel's Problem, Schwefel's Problem, Schwefel's Problem และ Generalized Rosenbrock's Function โดย เปรียบเทียบค่าที่เหมาะสมและเวลาที่ใช้ในการหาค่าที่เหมาะสม หลังจากนั้นเปรียบเทียบค่าความ คลาดเคลื่อนของค่าที่เหมาะสมที่ได้จากอัลกอริทึม CSGA, CA และ RSM กับค่าที่ได้จากการทดลอง ทำห้่งมะละกอโดยใช้แผนการทดลองแบบบ็อกซ์-เบนเคน (Yao et al., 1999)

การผสมผสานระหว่างวิธีการค้นหาแบบนกกาเหว่ากับเจนติกอัลกอริทึม เพื่อนำไปใช้ในการ หาค่าที่เหมาะสมของการทำห้่งมะละกอแบบออสโมซิส ด้วยการนำขั้นตอนการครอสโอเวอร์ (Cross Over) และขั้นตอนการผ่าเหล่า (Mutation) ของเจนติกอัลกอริทึมมาเชื่อมต่อกับวิธีการ ค้นหาแบบนกกาเหว่า โดยปรับปรุงจากวิธีของ Kanagaraj, Ponnambalam, & Jawahar (2013) โดยมีวัตถุประสงค์ เพื่อสร้างกรุ่นต่อไปที่มีความสามารถในการค้นหาห้่งที่เหมาะสมต่อการวางห้่ง (หา ค่าที่เหมาะสม) ดีกว่ากรุ่นพ่อแม่ จากนั้นนำอัลกอริทึมผสมผสานระหว่างวิธีการค้นหาแบบ นกกาเหว่ากับเจนติกอัลกอริทึม หรืออัลกอริทึม CSGA (Genetic Algorithm Cuckoo Search) ไป ทดสอบประสิทธิภาพด้วยฟังก์ชันมาตรฐาน (Benchmark Optimization Function) แล้วนำผลที่ได้ ทดสอบมาเปรียบเทียบประสิทธิภาพระหว่างอัลกอริทึม CS กับ CSGA ขั้นตอนสุดท้ายนำอัลกอริทึม CSGA ไปใช้กับข้อมูลที่ได้จากการทดลองมะละกอ ด้วยวิธีทำห้่งแบบออสโมซิส

การทดสอบประสิทธิภาพของอัลกอริทึมระหว่างอัลกอริทึม CS กับ CSGA ด้วยฟังก์ชัน มาตรฐาน (Benchmark Optimization Function) โดยคัดเลือกจำนวน 5 ฟังก์ชัน (Sphere Model, Schwefel's Problem, Schwefel's Problem, Schwefel's Problem และ Generalized Rosenbrock's Function) จาก Fast Evolutionary Programming ของ Yao and Liu (1999) มหาวิทยาลัยเบอร์มิงแฮม ประเทศอังกฤษและมหาวิทยาลัยนิวเซาท์เวล ประเทศ ออสเตรเลียตามลำดับ โดยกำหนดค่าพารามิเตอร์  $N = 25$ ,  $pa = 0.25$  และ  $tmax = 1000$  แล้ว เปรียบเทียบประสิทธิภาพการทำงานของอัลกอริทึม โดยยกการเปรียบเทียบด้วยค่า Best, Mean, SD และเวลาที่ใช้ในการหาค่าที่เหมาะสมของทั้งสองวิธี จากนั้นนำอัลกอริทึม CS กับ CSGA ไปใช้หาค่าที่ เหมาะสมในกระบวนการทำห้่งมะละกอแบบออสโมซิส แล้วนำค่าที่ได้ไปทำการทดลองอีกครั้ง เพื่อ นำค่าที่ได้จากการทดลองไปเปรียบเทียบกับค่าที่ได้จากอัลกอริทึม CS กับ CSGA ผลการศึกษาวิจัย สามารถสรุปได้ดังต่อไปนี้

## สรุปผลการวิจัย

การพัฒนาวิธีการค้นหาแบบนกกาเหว่าด้วยการผสมผสานกับเจเนติกอัลกอริทึม โดยนำขั้นตอนการครอสโอเวอร์ (Cross Over) และการมิวเตชัน (Mutation) มาผสมผสานกับวิธีการค้นหาแบบนกกาเหว่าในตำแหน่งของการสร้างกรุ่นถัดไป โดยดำเนินการพัฒนาจากแนวคิดและวิธีการผสมผสานระหว่างวิธีการค้นหาแบบนกกาเหว่ากับเจเนติกอัลกอริทึมของ Kanagaraj, Ponnambalam, and Jawahar (2013) สำหรับหาค่าที่เหมาะสมของการทำแห้งมะละกอแบบออสโมซิส สามารถสรุปผลการวิจัยได้ดังนี้

1. วิธีการค้นหาแบบนกกาเหว่าโดยการผสมผสานด้วยเจเนติกอัลกอริทึม (CSGA) สำหรับหาค่าที่เหมาะสมของการทำแห้งมะละกอแบบออสโมซิส เป็นกระบวนการค้นหาชุดคำตอบของตัวแปร  $\theta$ , C และ T ที่ทำให้ค่า SG และ WL เป็นไปตามเกณฑ์ที่กำหนดจากสมการ

$$SG = a + b_1\theta + b_2C + b_3T + b_4\theta^2 + b_5C^2 + b_6T^2 + b_7\theta \times C + b_8\theta \times T + b_9C \times T + b_{10}\theta \times C \times T$$

และ  $WL = c + w_1\theta + w_2C + w_3T + w_4\theta^2 + w_5C^2 + w_6T^2 + w_7\theta \times C + w_8\theta \times T + w_9C \times T + w_{10}\theta \times C \times T$

โดยใช้หลักการสุ่มชุดคำตอบที่เกิดจากการผสมชุดคำตอบตั้งต้นที่มีค่าใกล้เคียงกับเกณฑ์ที่กำหนดเพื่อให้ได้ชุดคำตอบที่เป็นไปได้ทั้งหมด แล้วคัดเลือกชุดคำตอบของตัวแปร  $\theta$ , C และ T ที่ทำให้ค่า SG มีค่าเข้าใกล้ 4.0 และ WL มีค่าสูงสุด

2. วิธี CSGA ที่พัฒนาขึ้น มีค่าเฉลี่ยเวลาในการค้นหาชุดคำตอบได้รวดเร็วกว่าวิธี CS ทั้ง 5 ฟังก์ชัน โดยวิธี CSGA มีประสิทธิภาพและค่าร้อยละของความคลาดเคลื่อนดีกว่าวิธี CS และวิธี RSM

3. ค่าที่เหมาะสมของการทำแห้งมะละกอแบบออสโมซิส คือ  $\theta = 60$  °Brix, C = 42 °C และ T = 6 Hrs จะทำให้การทำแห้งมะละกอมีประสิทธิภาพสูงสุดที่ SG = 4.0, WL = 33.7 และร้อยละของความคลาดเคลื่อนประมาณ 0.04

## อภิปรายผลการวิจัย

การวิจัยนี้ได้สิ่งที่ค้นพบมาอภิปรายผลดังนี้

1. ผลทดสอบประสิทธิภาพของอัลกอริทึมผสมผสานระหว่างวิธีการค้นหาแบบนกกาเหว่ากับวิธีเจเนติกอัลกอริทึมโดยด้วยฟังก์ชันมาตรฐาน (Benchmark Optimization Function) ปรากฏว่า วิธีผสมผสาน CSGA มีประสิทธิภาพดีกว่าวิธีค้นหาแบบนกกาเหว่าแบบดั้งเดิมทั้ง 5 ฟังก์ชันมาตรฐานที่ใช้ทดสอบ สอดคล้องกับผลการวิจัยของ ผลการวิจัยสอดคล้องกับการศึกษาของ Li and Yin (2015) ที่พบว่า วิธีการค้นหาแบบนกกาเหว่าเป็นวิธีที่มีความเรียบง่ายในการนำไปใช้งาน และมีประสิทธิภาพการหาค่าที่เหมาะสมในระดับสากลที่ค่อนข้างดี นิยมนำไปใช้ในการหาผลลัพธ์ (ค่าที่เหมาะสม) ในสถานการณ์จริงกันอย่างแพร่หลาย และมีการนำเสนอแนวทางในการพัฒนาอัลกอริทึมแบบผสมผสานไปสร้างอัลกอริทึมรูปแบบใหม่ ๆ ขึ้นมา โดยอาศัยหลักการพื้นฐานจากกฎของการถ่ายทอดทางพันธุกรรมของเจเนติกอัลกอริทึมได้ปฏิบัติการคัดเลือก การครอสโอเวอร์ และการผ่าเหล่า เพื่อรักษาและเพิ่มประสิทธิภาพในการหาค่าที่เหมาะสมเฉพาะตัวจากประชากรทั้งหมด นอกจากนี้ยังสามารถรักษาความสมดุลระหว่างการแสวงหาผลประโยชน์กับความสามารถในด้านการ

สำรวจของอัลกอริทึม ดังนั้นจึงได้นำกฎของการผ่าเหล่ามาผสมผสานกับหลักการเชิงเส้น เพื่อปรับลดอิทธิพลของกฎความน่าจะเป็น ผสมผสานกับการปรับค่าพารามิเตอร์ด้วยตนเอง โดยอาศัยหลักของวิธีการสุ่มค่าอย่างสม่ำเสมอ เพื่อเพิ่มความหลากหลายให้แก่ประชากร วิธีการดังกล่าวนี้มีความสัมพันธ์โดยตรงกับความสำเร็จของค่าพารามิเตอร์ทั้งสองที่กำหนดขึ้นมา เมื่อนำมาทดสอบประสิทธิภาพการทำงานของ SACS ด้วยฟังก์ชันมาตรฐานจำนวน 16 ฟังก์ชัน ผลการทดสอบพบว่าประสิทธิภาพของอัลกอริทึมผสมผสาน SACS ให้ผลลัพธ์ที่ดีกว่าหรืออย่างน้อยก็สามารถเปรียบได้กับอัลกอริทึมดั้งเดิม สุดท้ายเมื่อพิจารณาถึงคุณภาพของการแก้ปัญหา Li and Yin จึงได้นำอัลกอริทึมที่ผ่านการพัฒนาแล้วมาทดสอบด้วยวิธีการจำลองข้อมูล โดยใช้วิธีของ Lorenz และ Chen และใช้วิธีการประมาณพารามิเตอร์ด้วยวิธีของ Chaotic พบว่า ผลจากการทดสอบอัลกอริทึมผสมผสาน SACS นั้นมีประสิทธิภาพเพิ่มขึ้นเมื่อเปรียบเทียบกับอัลกอริทึมเดิม (Li & Yin, 2015)

2. ผลการทดสอบความคลาดเคลื่อน แสดงให้เห็นว่า ความคลาดของอัลกอริทึมผสมผสานมีแนวโน้มลดลงและสามารถนำไปใช้กับปัญหาที่มีความหลากหลาย สอดคล้องกับการศึกษาของ Kanagaraj et al. (2013) และ Zhang (2007) ที่ได้ศึกษาวิธีการพัฒนาแบบผสมผสาน (Hybrid Algorithm) ระหว่างการค้นหาแบบนกกาเหว่ากับเจเนติกอัลกอริทึม พบว่าอัลกอริทึมผสมผสานนั้นเป็นวิธีการที่สามารถดำเนินการได้ค่อนข้างง่าย สะดวก รวดเร็วและยังสามารถเพิ่มประสิทธิภาพขึ้นจากเดิมประมาณ 1.5% และ 47% เมื่อเทียบกับวิธีเจเนติกอัลกอริทึมและวิธีการค้นหาของนกกาเหว่ามาตรฐาน ผลการศึกษาสอดคล้องกับการศึกษาของ Moghaddam (2011) ที่ทำการศึกษาเปรียบเทียบความสามารถในการประมาณค่าของพื้นผิวตอบสนองต่อวิธีการ (RSM) และเครือข่ายประสาทเทียม (ANN) จากผลการประมาณค่าปริมาณของสังกะสีที่ได้จากการสกัดจากตัวอย่างปลาโดยใช้ไมโครเวฟช่วยในกระบวนการสกัด โดยออกแบบการทดลองแบบ Box-Behnken กำหนดระดับของตัวแปรที่ 3 ระดับจำนวน 4 ตัวแปร ปริมาณของสังกะสีที่สกัดได้ขึ้นอยู่กับตัวแปรอิสระทั้งสิ้นตัวคืออำนาจการฉายรังสี เวลาการฉายรังสี ความเข้มข้นของกรดไนตริกและอุณหภูมิ เมื่อนำความสามารถในการคาดการณ์ของทั้งสองวิธีการที่ได้มาเปรียบเทียบกัน พบว่า การประมาณค่าของเครือข่ายประสาทเทียม (ANN) มีความแม่นยำมากกว่าในการประมาณค่าปริมาณของสังกะสีในการเปรียบเทียบกับวิธีการประมาณค่าของพื้นผิวตอบสนองต่อวิธีการ (RSM) (Moghaddam & Khajeh, 2011b)

ผลการพัฒนาอัลกอริทึมผสมผสาน CSGA สามารถนำไปใช้หาค่าที่เหมาะสมการทำเหมืองมะละกอแบบออสโมซิสได้อย่างเหมาะสม สอดคล้อง Kanagaraj, Ponnambalam, & Jawahar (2013) ได้พัฒนาวิธีการค้นหาแบบนกกาเหว่าโดยการผสมผสานด้วยเจเนติกอัลกอริทึม (CSGA) เพื่อนำไปใช้ในการค้นหาเส้นทางที่ที่เหมาะสม (Kanagaraj et al., 2013) และสอดคล้องกับ Oysu and Bingul (2009) ที่ทดสอบความสามารถในการนำไปใช้งานจริงประสิทธิภาพของวิธีการพัฒนาอัลกอริทึมแบบผสมผสาน ปรากฏว่า อัลกอริทึมที่ผ่านการพัฒนาแบบผสมผสานนั้นสามารถนำไปใช้ได้กับปัญหาที่มีความหลากหลายมากขึ้นกว่าวิธีการค้นหาแบบนกกาเหว่าดั้งเดิม ทั้งในกรณีปัญหาขนาดเล็กและขนาดใหญ่ และสามารถลดค่าความคลาดเคลื่อนระหว่างค่าทำนายกับค่าจริงลงได้ดีกว่าวิธีดั้งเดิม (Oysu & Bingul, 2009) อัลกอริทึมผสมผสาน CSGA จึงสามารถนำไปใช้หาค่าที่เหมาะสมการทำเหมืองมะละกอแบบออสโมซิสได้อย่างเหมาะสม

ผลการวิจัยพบว่า อัลกอริทึมผสมผสาน CSGA สามารถเพิ่มโอกาสในการหาคำตอบได้ดียิ่งขึ้น สอดคล้องกับผลการศึกษาของ Rajabioun (2011) ได้พัฒนาวิธีการค้นหาแบบนกกาเหว่าด้วยวิธีผสมผสานแล้ว ปรากฏว่า สามารถลดโอกาสที่ค่าที่เหมาะสม (ผลลัพธ์) จะเข้าไปติดอยู่ใน Local Optima ซึ่งเป็นข้อบกพร่องหลักของวิธีการค้นหาแบบนกกาเหว่าลงได้ (Local Optima เป็นผลลัพธ์ที่เกิดขึ้นเฉพาะพื้นที่บริเวณใดบริเวณหนึ่งเท่านั้น) ส่งผลให้คำตอบที่ได้นั้นไปตกอยู่ใน Global Optima เป็นโซลูชันที่สามารถหาค่าที่เหมาะสมได้ในพื้นที่ที่กว้างขวางกว่า จึงเป็นการเพิ่มความสามารถในการหาค่าที่เหมาะสมของวิธีการค้นหาแบบนกกาเหว่าให้เป็นแบบ Global Optima (Global Optima เป็นผลลัพธ์ที่เกิดขึ้นเมื่อทำการเปรียบเทียบกับพื้นที่โดยรอบ) เนื่องจากได้รับความสามารถบางส่วนมาจากเจเนติกอัลกอริทึม ดังนั้นอัลกอริทึมผสมผสานจึงมีจุดเด่นในเรื่องของความสามารถในการหาคำตอบในระดับ Global Optima นั้นเอง (Rajabioun, 2011; Yang, 2013) เมื่อนำไปทดสอบประสิทธิภาพทำงานด้วยฟังก์ชันมาตรฐานแล้ว แสดงให้เห็นว่า วิธีการค้นหาแบบนกกาเหว่าผสมผสานมีประสิทธิภาพดีกว่าวิธีการค้นหาแบบนกกาเหว่าดั้งเดิม (CS) และสอดคล้องกับการศึกษาของ Lim et al. (2014) ที่ศึกษาวิธีการผสมผสานระหว่างวิธีการค้นหาแบบนกกาเหว่ากับเจเนติกอัลกอริทึม (Hybrid Algorithm Cuckoo Search With Genetic Algorithm: CSGA) เพื่อนำไปใช้ในการหาเส้นทางที่เหมาะสมสำหรับเจาะแผงวงจร (Printed Circuit Board: PCB) แสดงให้เห็นว่า อัลกอริทึมผสมผสาน CSGA สามารถหาผลลัพธ์ที่ใกล้เคียงและรวดเร็วกว่า CS และ GA ทั้งปัญหาขนาดเล็กและขนาดใหญ่ นอกจากนี้อัลกอริทึมผสมผสาน CSGA มีจำนวนพารามิเตอร์ที่ต้องปรับค่อนข้างน้อย มีเพียงพารามิเตอร์พื้นฐานคือขนาดประชากรและจำนวนรุ่นเท่านั้น เกณฑ์การหยุดสามารถเลือกปรับให้เหมาะสม เพื่อความสมดุลระหว่างเวลาและวิธีการแก้ปัญหาที่มีคุณภาพที่ต้องการด้วยผู้ใช้ โดยสามารถตั้งค่าอย่างใดอย่างหนึ่งจำนวนสูงสุดของรุ่นหรือหยุด หากอัลกอริทึมไม่มีการเปลี่ยนแปลงในการแก้ปัญหาในรุ่นต่อ ๆ ไป การกำหนดขนาดของประชากรจะขึ้นอยู่กับขนาดและความซับซ้อน ของปัญหา ลักษณะเฉพาะของ CSGA เหล่านี้ ส่งผลให้อัลกอริทึมมีความเรียบง่ายต่อการดำเนินการและสามารถนำไปใช้งานด้านวิศวกรรมได้อย่างเหมาะสม (Lim, Kanagaraj, & Ponnambalam, 2014) สอดคล้องกับผลการศึกษาวิจัยของ Rajabioun (2011) ปรากฏว่า คุณลักษณะที่ดีของอัลกอริทึมที่ผ่านการพัฒนาแล้ว ประกอบด้วย 1) อัลกอริทึมสามารถนำไปใช้งานได้ง่าย 2) อัลกอริทึมมีสมดุลที่ระหว่างความสามารถในการสำรวจและความสามารถในการนำไปใช้ประโยชน์ 3) อัลกอริทึมสามารถค้นหาคำตอบในระดับสากลได้อย่างแท้จริง 4) อัลกอริทึมสามารถหาค่าที่เหมาะสมได้อย่างรวดเร็ว และ 5) อัลกอริทึมมีจำนวนพารามิเตอร์สำหรับการปรับค่อนข้างน้อย คุณลักษณะที่กล่าวมาทั้งหมดเป็นคุณลักษณะที่ดีของอัลกอริทึมที่ผ่านการพัฒนาแล้ว

3. ผลการพัฒนาอัลกอริทึมผสมผสาน CSGA ไปใช้ในกระบวนการทำแห้งมะละกอแบบออสโมซิส สอดคล้องกับการศึกษาของ Yang (2013) และ Lim et al. (2014) การหาค่าที่เหมาะสมแบบผสมผสานระหว่างวิธีการค้นหาแบบนกกาเหว่ากับเจเนติกอัลกอริทึม เมื่อเปรียบเทียบกับการนำไปประยุกต์กับการหาค่าที่เหมาะสมในกระบวนการออสโมซิสแล้วพบว่า ค่าเหมาะสมที่ได้ อัลกอริทึม CSGA มีค่าใกล้เคียงกับค่าของ Water Loss (WL) และ Sugar Gain (SG) ที่ได้จากการทดลอง และเมื่อนำค่าความคลาดเคลื่อนมาเปรียบเทียบกันแล้ว พบว่า

ค่าความคลาดเคลื่อนของอัลกอริทึมผสมผสาน CSGA มีค่าน้อยกว่าวิธีการค้นหาแบบ

นกกาเหว่าและวิธี RSM สอดคล้องกับการศึกษาของ Granato (2014) ที่ศึกษาโดยเพิ่มการประยุกต์แบบจำลองทางคณิตศาสตร์ทั้งในด้านทางเคมีและด้านวิทยาศาสตร์และเทคโนโลยีการอาหาร โดยปกติแล้วนักวิจัยต้องการหาตำแหน่งหนึ่งตำแหน่งใด เพื่อใช้เป็นแนวทางการในการทดสอบและการเลือกตัวแปรที่จะดำเนินการพัฒนาและเพิ่มประสิทธิภาพของผลิตภัณฑ์และกระบวนการ Granato ได้ทำการศึกษามีวัตถุประสงค์เพื่อให้ข้อมูลทางสถิติที่เกี่ยวข้องกับการสร้างแบบจำลองทางคณิตศาสตร์ โดยใช้กระบวนการออกแบบการทดลองตามรูปแบบการวิเคราะห์การถดถอยที่มีชื่อเรียกว่าวิธีการตอบสนองต่อพื้นผิว (RSM) และเพื่อรวบรวมแนวคิดที่เกี่ยวข้องจากงานวิจัยที่ตีพิมพ์ โดยอยู่บนพื้นฐานของการเพิ่มประสิทธิภาพของวิธี RSM ของผลิตภัณฑ์และกระบวนการ โดยให้ความสนใจเป็นพิเศษในด้านจุลชีววิทยา การวิเคราะห์ทางประสาทสัมผัส การพัฒนาอาหารและโภชนาการ (Granato & Calado, 2014)

การนำไปใช้งานด้านอุตสาหกรรมการแปรรูปอาหาร และงานด้านวิทยาศาสตร์และเทคโนโลยีการอาหาร โดยนำไปใช้กับข้อมูลที่ได้จากกระบวนการทำแห้งมะละกอแบบอบสไมซิส ที่ลักษณะของข้อมูลเป็นข้อมูลเชิงทดลองที่มีจำนวนค่อนข้างน้อยและมีความผันแปรของวัตถุดิบที่ใช้การผลิตสูง จากนั้นนำค่าที่เหมาะสมที่ได้ไปเปรียบเทียบกับวิธีการค้นหาแบบนกกาเหว่ามาตรฐาน อัลกอริทึมที่ได้พัฒนาขึ้นมาใหม่นั้น พบว่าอัลกอริทึมผสมผสาน CSGA สามารถให้ค่าที่เหมาะสมได้ใกล้เคียงกับค่าจริง (ค่าที่ได้จากการทดลอง) ดังนั้นจึงมีความเหมาะสมต่อการนำไปหาค่าที่เหมาะสมของกระบวนการทำแห้งมะละกอแบบอบสไมซิส สอดคล้องกับ Enitan and Adeyemo (2011) ที่ศึกษาแนวทางในการนำอัลกอริทึมวิวัฒนาการไปใช้ในอุตสาหกรรมอาหาร พบว่า อัลกอริทึมสามารถนำไปประยุกต์ในงานด้านอุตสาหกรรมได้ เมื่อได้รับการพัฒนาอย่างเหมาะสม นอกจากนี้ยังพบต่อไปอีกว่าอัลกอริทึมวิวัฒนาการยังมีการนำไปประยุกต์ในงานด้านอื่น ๆ กันอย่างแพร่หลาย เนื่องจากเป็นวิธีการหาค่าที่เหมาะสมที่มีความเรียบง่าย สามารถนำไปใช้งานได้สะดวกและสามารถแก้ปัญหาได้ในการสร้างแบบจำลองเพียงครั้งเดียว จนได้รับความนิยมนำไปใช้สำหรับการตัดสินใจในอุตสาหกรรมแปรรูปอาหาร ทั้งในรูปแบบการหาค่าที่เหมาะสมที่มีข้อจำกัดและไม่มีข้อจำกัด (Jain et al., 2011; Li & Yin, 2015; Kanagaraj et al., 2013)

การศึกษาของ Enitan and Adeyemo (2011) ยังได้นำเสนอเทคนิคการพัฒนาอัลกอริทึมวิวัฒนาการที่ใช้ในอุตสาหกรรมการแปรรูปอาหาร เช่น เจเนติกอัลกอริทึม เครือข่ายประสาทเทียม อนุพันธ์วิวัฒนาการและฟิชชี่ลอจิก โดยอ้างอิงข้อมูลจากการนำไปใช้ในกระบวนการแปรรูปอาหาร ได้แก่ การแปรรูปด้วยความร้อน การประกันคุณภาพของอาหาร การออกแบบกระบวนการผลิต การอบแห้ง การหมักและกระบวนการเติมไฮโดรเจน ฯลฯ โดยเปรียบเทียบความแตกต่างกันของอัลกอริทึมวิวัฒนาการในด้านเทคนิคและข้อสังเกตเกี่ยวกับการขยายขอบเขตการนำไปใช้หาผลลัพธ์ที่เหมาะสมในกระบวนการแปรรูปอาหาร (Enitan & Adeyemo, 2011)

## ข้อเสนอแนะ

### ข้อเสนอแนะในการนำผลการวิจัยไปใช้

1. จากผลการวิจัยแสดงให้เห็นว่า อัลกอริทึมผสมผสาน CSGA สามารถให้ค่าที่เหมาะสม



ของการทำห้แมละกอแบบบอสโมซิสใกล้เคียงกับค่าที่ได้จากการทดลองมากที่สุด โดยให้ผลปริมาณน้ำที่สูญเสียน้ (WL) และปริมาณน้ำตาลที่เพิ่มขึ้น (SG) เท่ากับ 33.7 และ 4.0 ตามลำดับ สามารถหาค่าที่เหมาะสมของการทำห้แมละกอด้วยวิธีบอสโมซิสในดีกว่าวิธีการค้นหาแบบนกกาเหว่า

2. โรงงานอุตสาหกรรมแปรรูปอาหาร วิสาหกิจชุมชนหรือหน่วยงานที่เกี่ยวข้องกับการทำห้แมอาหารแบบบอสโมซิส สามารถนำวิธีการหาค่าที่เหมาะสมด้วยอัลกอริทึมผสมผสาน CSGA ไปประยุกต์ เพื่อเป็นทางเลือกในการเพิ่มประสิทธิภาพในการหาค่าที่เหมาะสมของกระบวนการทำห้แม

3. สถาบันการศึกษาสามารถนำผลการวิจัยเกี่ยวกับการเพิ่มประสิทธิภาพในการหาค่าที่เหมาะสมของการทำห้แมละกอแบบบอสโมซิสด้วยอัลกอริทึมผสมผสาน CSGA ไปใช้ประกอบการเรียนการสอน การวิจัย และการบริการทางวิชาการ

4. นักวิจัยหรือผู้ที่สนใจสามารถนำผลการวิจัยเกี่ยวกับการเพิ่มประสิทธิภาพในการหาค่าที่เหมาะสมด้วยอัลกอริทึมผสมผสาน CSGA ไปประยุกต์ เพื่อเป็นทางเลือกสำหรับการหาค่าที่เหมาะสมของการทำห้แมบอสโมซิสในผลไม้อื่น ๆ

#### ข้อเสนอแนะในการทำวิจัยต่อไป

1. การศึกษานี้ เป็นการศึกษาวิธีการเพิ่มประสิทธิภาพในการหาค่าที่เหมาะสมของการทำห้แมละกอแบบบอสโมซิส ควรมีการศึกษาวิธีการเพิ่มประสิทธิภาพในการหาค่าที่เหมาะสมของการทำห้แมบอสโมซิสในผลไม้อื่น ๆ

2. งานวิจัยนี้ เป็นการเพิ่มประสิทธิภาพในการหาค่าที่เหมาะสมของการทำห้แมละกอแบบบอสโมซิสโดยการผสมผสานด้วยเจเนติกอัลกอริทึม ดังนั้นในการทำวิจัยครั้งต่อไป อาจมีการปรับเปลี่ยนหรือเพิ่มอัลกอริทึมที่ใช้การผสมผสานกับวิธีการค้นหาแบบนกกาเหว่า เช่น Ant Colony, Learning Automata, Neural Network, Genetic Algorithm, Local Search และ Eagle Strategy

3. ควรมีการศึกษาเปรียบเทียบประสิทธิภาพของค่าที่เหมาะสมในการทำห้แมละกอแบบบอสโมซิสที่ได้จากอัลกอริทึมผสมผสาน CSGA กับค่าที่เหมาะสมที่ได้จากด้วยอัลกอริทึม Ant Colony, Neural Network, Eagle Fire Fly Algorithm, Bat Algorithm เป็นต้น

## บรรณานุกรม

- ทิพาพร อยู่วิทยา. (2556). เอกสารนำเสนอเรื่อง *การทำแห้งแบบออสโมซิส*. กรุงเทพฯ: ภาควิชาวิศวกรรมศาสตร์ สถาบันเทคโนโลยีพระจอมเกล้าธนบุรี.
- ไพบุลย์ ธรรมรัตน์วาลิก. (2532). *กรรมวิธีการแปรรูปอาหาร*. กรุงเทพฯ: โอเดียนสโตร์.
- สถาบันอาหาร. (2559). ตลาดส่งออกผักและผลไม้. เข้าถึงได้จาก <http://fic.nfi.or.th>
- ราชบัณฑิตยสถาน. (2556). *พจนานุกรมฉบับราชบัณฑิตยสถาน พ.ศ. ๒๕๕๔* (พิมพ์ครั้งที่ 2). กรุงเทพฯ: ราชบัณฑิตยสถาน.
- สถาบันเทคโนโลยีพระนครเหนือ, (2559), *เจเนติกอัลกอริทึม*, เข้าถึงได้จาก <http://www.st.kmutt.ac.th>.
- สุกิต นุตตยกุล. (2554). การคำนวณเชิงวิวัฒนาการระหว่างเจเนติกอัลกอริทึมกับพาทิคอลสวอมออปติมิซเซชัน. *วารสารวิทยาศาสตร์และเทคโนโลยีสารสนเทศ*, 2(2), 13 – 22.
- Abakarov, A., Sushkov, Y., Almonacid, S., & Simpson, R. (2009). Multiobjective optimization approach: Thermal food processing. *Journal of Food Science*, 74(9), 471-467.
- Abakarov, A., Sushkov, Y., Almonacid, S., & Simpson, R. (2009b). Thermal processing optimization through a modified adaptive random search. *Journal of Food Engineering*, 93(2), 200-209.
- Alcalá-Fdez, J., Sanchez, L., Garcia, S., del Jesus, M. J., Ventura, S., Garrell, J. M., & Rivas, V. M. (2009). KEEL: A software tool to assess evolutionary algorithms for data mining problems. *Soft Computing*, 13(3), 307-318.
- Amiri, E., & Mahmoudi, S. (2016). Efficient protocol for data clustering by fuzzy Cuckoo Optimization Algorithm. *Applied Soft Computing*, 41(1), 15-21.
- Arora, S., & Singh, S. (2013). *A Conceptual Comparison of Firefly Algorithm, BatAlgorithm and Cuckoo Search*. Paper presented at the International Conference on Control, Computing, Communication and Materials (ICCCCM).
- Babu, B. (2004). *Process plant simulation*. New York: Oxford University Press.
- Banga, J. R., Perez-Martin, R. I., Gallardo, J. M., & Casares, J. (1991). Optimization of the thermal processing of conduction-heated canned foods: Study of several objective functions. *Journal of Food Engineering*, 14(1), 25-51.
- Box, G. E. P., & Behnken, D. W. (1960). Some New Three Level Designs for the Study of Quantitative Variables. *Technometrics*, 2(4), 455-475.
- Chiou, J. P., & Wang, F.-S. (1999). Hybrid method of evolutionary algorithms for static and dynamic optimization problems with application to a fed-batch fermentation process. *Computers & Chemical Engineering*, 23(9), 1277-1291.

- Desai, K. M., Survase, S. A., Saudagar, P. S., Lele, S. S., & Singhal, R. S. (2008). Comparison of Artificial Neural Network (ANN) and Response Surface Methodology (RSM) in Fermentation Media Optimization: Case Study of Fermentative Production of Scleroglucan. *Biochemical Engineering Journal*, 41(3), 471-487.
- Enitan, A. M., & Adeyemo, J. (2011). Food processing optimization using evolutionary algorithms. *African Journal of Biotechnology*, 10(72), 16120-16127.
- Eren, İ., & Kaymak-Ertekin, F. (2007). Optimization of osmotic dehydration of potato using response surface methodology. *Journal of Food Engineering*, 79(1), 344-352.
- Fito, P. (1994). Modelling of vacuum osmotic dehydration of food. *Journal of Food Engineering*, 22(1), 313-328.
- Gandomi, A. H., Yang, X.-S., & Alavi, A. H. (2013). Cuckoo search algorithm: A metaheuristic approach to solve structural optimization problems. *Engineering with Computers*, 29(1), 17-35.
- Goldberg, D. E. (1989). Genetic algorithms in search, optimization and machine learning. Massachusetts: addison-wesley, Reading.
- Goldberg, D. E. (2006). *Genetic algorithms*. New delhi: Pearson Education.
- Goldberg, D. E., & Holland, J. H. (1988). Genetic algorithms and machine learning. *Machine learning*, 3(2), 95-99.
- Gonçalves, J. F., de Magalhães Mendes, J. J., & Resende, G. C. (2005). A hybrid genetic algorithm for the job shop scheduling problem. *European Journal of Operational Research*, 167(1), 77-95.
- Guillot, G., Santos, F., & Estoup, A. (2008). Analysing georeferenced population genetics data with Geneland: a new algorithm to deal with null alleles and a friendly graphical user interface. *Bioinformatics*, 24(11), 1406-1407.
- Han, G., Zhang, S., Li, X., Widjojo, N., & Chung, T.-S. (2012). Thin film composite forward osmosis membranes based on polydopamine modified polysulfone substrates with enhancements in both water flux and salt rejection. *Chemical Engineering Science*, 80(1), 219-231.
- Holland, J., & Goldberg, D. (1989). *Genetic Algorithms in Search, Optimization and Machine Learning*. Massachusetts: Addison-Wesley, Reading, 3(3), 95-99.
- Holland, J. H. (1975). *Adaptation in natural and artificial systems: An introductory analysis with applications to biology, control, and artificial intelligence*. Oxford, England: U Michigan Press.

- Imanirad, R., Yang, X.-S., & Yeomans, J. S. (2013). Modelling-to-generate-alternatives via the firefly algorithm. *Journal of Applied Operational Research*, 5(1), 14-21.
- Jain, S. K., Verma, R. C., Murdia, L. K., Jain, H. K., & Sharma, G. P. (2011a). Optimization of process parameters for osmotic dehydration of papaya cubes. *Journal of Food Science and Technology*, 48(2), 211-217.
- Jain, S. K., Verma, R. C., Murdia, L. K., Jain, H. K., & Sharma, G. P. (2011b). Optimization of process parameters for osmotic dehydration of papaya cubes. *Food Sci Technol*, 48(2), 211-217.
- Kanagaraj, G., Ponnambalam, S. G., & Jawahar, N. (2013). A hybrid cuckoo search and genetic algorithm for reliability–redundancy allocation problems. *Computers & Industrial Engineering*, 66(4), 1115–1124.
- Kim, D. H., Abraham, A., & Cho, J. H. (2007). A hybrid genetic algorithm and bacterial foraging approach for global optimization. *Information Sciences*, 177(18), 3918-3937.
- Koc, A., Heinemann, P., & Ziegler, G. (2007). Optimization of whole milk powder processing variables with neural networks and genetic algorithms. *Food and Bioprocesses Processing*, 85(4), 336-343.
- Li, X., & Yin, M. (2015). Modified cuckoo search algorithm with self adaptive parameter method. *Information Sciences*, 29(8), 80-97.
- Lim, W. C. E., Kanagaraj, G., & Ponnambalam, S. G. (2014). A hybrid cuckoo search-genetic algorithm for hole-making sequence optimization. *Journal of Intelligent Manufacturing*, 27(2), 1-13.
- Ljouad, T., Amine, A., & Rziza, M. (2014). A hybrid mobile object tracker based on the modified Cuckoo Search algorithm and the Kalman Filter. *Pattern Recognition*, 47(11), 3597-3613.
- Michalewicz, Z. (1994). GAs: What are they? *Genetic algorithms+ data structures= evolution programs* (pp. 13-15): Springer.
- Moghaddam, M. G., & Khajeh, M. (2011). Comparison of Response Surface Methodology and Artificial Neural Network in Predicting the Microwave-Assisted Extraction Procedure to Determine Zinc in Fish Muscles. *Food and Nutrition Sciences*, 2(1), 803-808.
- Montgomery, D. C. (2004). *Design and Analysis of Experiments*. Hoboken: Wiley.
- Montgomery, D. C., & Myers, R. H. (1995). Response surface methodology. *Design and Analysis of Experiments*, 80(1), 445-474.

- Nagata, Y., & Chu, K. H. (2003). Optimization of a fermentation medium using neural networks and genetic algorithms. *Biotechnology Letters*, 25(21), 1837-1842.
- Naknean, P. (2012). Factors affecting mass transfer during osmotic dehydration of fruit. *International Food Research Journal*, 19(1), 7-18.
- Oysu, C., & Bingul, Z. (2009). Application of heuristic and hybrid-GASA algorithms to tool-path optimization problem for minimizing airtime during machining. *Engineering Applications of Artificial Intelligence*, 22(3), 389-396.
- Petrotos, K. B., & Lazarides, H. N. (2001). Osmotic concentration of liquid foods. *Journal of Food Engineering*, 49(2), 201-206.
- Rajabioun, R. (2011). Cuckoo Optimization Algorithm. *Applied Soft Computing*, 11(8), 5508-5518.
- Raoult-Wack, A. L. (1994). Recent advances in the osmotic dehydration of foods. *Trends in Food Science & Technology*, 5(8), 255-260.
- Reddy, Y. K., Khetra, Y., & Kumar, S., Agriculture engineering, Retrieve from <http://ecoursesonline.iasri.res.in>.
- Sagar, V., & Kumar, P. S. (2010). Recent advances in drying and dehydration of fruits and vegetables: a review. *Journal of Food Science and Technology*, 47(1), 15-26.
- Sendín, J. O. H., Alonso, A. A., & Banga, J. R. (2010). Efficient and robust multi-objective optimization of food processing: A novel approach with application to thermal sterilization. *Journal of Food Engineering*, 98(3), 317-324.
- Sharma, P., Singh, L., & Dilbaghi, N. (2009). Response surface methodological approach for the decolorization of simulated dye effluent using *Aspergillus fumigatus fresenius*. *Journal of Hazardous Materials*, 161(2-3), 1081-1086.
- Silva, K. S., Garcia, C. C., Amado, L. R., & Mauro, M. A. (2015). Effects of Edible Coatings on Convective Drying and Characteristics of the Dried Pineapple. *Food and Bioprocess Technology*, 8(7), 1465-1475.
- Singh, A., Majumder, A., & Goyal, A. (2008). Artificial intelligence based optimization of exocellular glucansucrase production from *Leuconostoc dextranicum* NRRL B-1146. *Bioresource Technology*, 99(17), 8201-8206.
- Singh, S. K., Singh, G., Pathak, V., Roy, D., & Chandra, K. (2011). Spectrum Management for Cognitive Radio based on Genetics Algorithm. *Journal of Computer Science*, 3(2) 127-132.

- Supagit, N. (2011). Evolutionary computation between Genetic Algorithm and Particle Swarm Optimization. *Journal of Information Science and Technology*, 2(2), 13-22.
- Valian, E., & Valian, E. (2013). A cuckoo search algorithm by Lévy flights for solving reliability redundancy allocation problems. *Engineering Optimization*, 45(11), 1273-1286.
- Wang, H. R., & Xu, H. J. (2015). The Study on Food Sensory Evaluation based on Particle Swarm Optimization Algorithm. *Advance Journal of Food Science and Technology*, 8(11), 772-776.
- Yang, H., Zhou, W., Lu, L., & Fang, Z. (2008). Optimal sizing method for stand-alone hybrid solar-wind system with LPSP technology by using genetic algorithm. *Solar Energy*, 82(4), 354-367.
- Yang, X. S., & Deb, S. (2009). Cuckoo search via Lévy flights. Paper presented at the 2009 World congress on nature and biologically inspired computing (NaBIC 2009).
- Yang, X. S., & Deb, S. (2013). Multiobjective cuckoo search for design optimization. *Computers & Operations Research*, 40(6), 1616-1624.
- Yang, X. S. (2010). *Nature-inspired metaheuristic algorithms*. Bristol: Luniver press.
- Yang, X. S., & Deb, S. (2014). Cuckoo search: Recent advances and applications. *Neural Computing and Applications*, 24(1), 169-174.
- Yao, X., Liu, Y., & Lin, G. (1999). Evolutionary programming made faster. *IEEE Transactions on Evolutionary Computation*, 3(2), 82-102.
- Yeomans, J. S. (2015). Determining optimal osmotic dehydration process parameters for papaya: A parametric testing of the Firefly Algorithm for Goal Programming optimization. *Scientia Agriculturae (SA)*, 10(3), 127-136.
- Yeomans, J. S., & Yang, X. S. (2014). Determining optimal osmotic drying parameters for papaya using the firefly algorithm. *Lecture Notes in Management Science*, 6(1), 32-39.
- Zhang, J. R., Zhang, J. L., Lok, T. M., & Lyu, M. R. (2007). A hybrid particle swarm optimization-back-propagation algorithm for feedforward neural network training *Applied Mathematics and Computation*, 18(5), 1026-1037.

ภาคผนวก

ภาคผนวก ก

หนังสือรับรองผลการพิจารณาจริยธรรมการวิจัยในมนุษย์



ที่ ๐๐๔/๒๕๖๐



เอกสารรับรองผลการพิจารณาจริยธรรมการวิจัยในมนุษย์  
วิทยาลัยวิทยาการวิจัยและวิทยาการปัญญา  
มหาวิทยาลัยบูรพา

๑. ชื่อเรื่องคุณุญนิพนธ์  
ชื่อเรื่อง การพัฒนาวิธีการค้นหาแบบนกกาเหว่าโดยการผสมผสานกับจินเนติกส์อัลกอริทึมสำหรับหาค่าที่เหมาะสมของการทำแห้งแบบออสโมซิส  
TITLE DEVELOPMENT OF CUCKOO SEARCH HYBRID WITH GENETIC ALGORITHM FOR OSMOTIC DEHYDRATION OPTIMIZATION
๒. ชื่อนิสิต (นาย, นาง, นางสาว): วีระ พุ่มเกิด  
หลักสูตร ปรัชญาดุษฎีบัณฑิต (Ph.D.) สาขาวิชา การวิจัยและสถิติทางวิทยาการปัญญา  
รหัส ๕๒๘๑๐๐๖๖
๓. ผลการพิจารณาของคณะกรรมการพิจารณาจริยธรรมการวิจัยในมนุษย์  
คณะกรรมการพิจารณาจริยธรรมการวิจัยในมนุษย์ วิทยาลัยวิทยาการวิจัยและวิทยาการปัญญา ได้พิจารณาเห็นแล้วว่าเค้าโครงคุณุญนิพนธ์ดังกล่าวเป็นไปตามหลักการของจริยธรรมการวิจัยในมนุษย์ โดยที่ผู้วิจัยเคารพสิทธิและศักดิ์ศรีในความเป็นมนุษย์ ไม่มีการล่วงละเมิดสิทธิ สวัสดิภาพ และไม่ก่อให้เกิดอันตรายแก่ตัวอย่างการวิจัย กลุ่มตัวอย่าง และผู้เข้าร่วมในโครงการวิจัย

จึงเห็นสมควรให้ดำเนินการวิจัยในขอบข่ายของเค้าโครงคุณุญนิพนธ์ที่เสนอได้ ตั้งแต่วันที่ออกเอกสารรับรองผลการพิจารณาจริยธรรมการวิจัยในมนุษย์ฉบับนี้ จนถึงวันที่ ๓๑ กรกฎาคม พ.ศ. ๒๕๖๐

ออกให้ ณ วันที่ ๑๗ มีนาคม พ.ศ. ๒๕๖๐

(ลงนาม)

(ผู้ช่วยศาสตราจารย์ ดร.สุชาติา กรเพชรปามี)  
คณบดีวิทยาลัยวิทยาการวิจัยและวิทยาการปัญญา

ภาคผนวก ข  
ภาพการทำแห้งมะละกอด้วยวิธีออสโมซิส

ภาพปฏิบัติการทำแห้งมะละกอด้วยวิธีออสโมซิส



หั่นมะละกอแบบลูกเต๋า



มะละกอที่หั่นแล้ว




ซังน้ำหนั๊กมะละก่อนบรรจุขวด



ล้างมะละกอ



เตรียมน้ำเชื่อม



อุ่นน้ำเชื่อมให้ร้อน





ใส่มะละกอลงในขวด



ชั่งน้ำหนักมะละกอพร้อมขวด



ควบคุมอุณหภูมิด้วยอ่างน้ำร้อน



ปรับอุณหภูมิด้วยตู้อบลมร้อน



เทน้ำเชื่อมลงในขวดบรรจุมะละกอ



แช่มะละกอในน้ำเชื่อม






กำหนดรหัสให้แต่ละตัวอย่าง



อปไล้ความชื้นจากถ้วยหาความชื้น



นำถ้วยความชื้นออกจากตู้อบ



ชั่งน้ำหนักถ้วยหาความชื้น

ภาคผนวก ค  
ฟังก์ชันมาตรฐาน

## ฟังก์ชันมาตรฐาน

Definitions of the Benchmark Functions

Definition 1 A function  $f(x)$  is separable if

$$\arg \min_{(x_1, \dots, x_n)} f(x_1, \dots, x_n) = \left( \arg \min_{x_1} f(x_1, \dots), \dots, \arg \min_{x_n} f(\dots, x_n) \right)$$

Definition 2 A nonseparable function  $f(x)$  is called  $m$ -nonseparable function if at most  $m$  of its parameters  $x_i$  are

not independent. A nonseparable function  $f(x)$  is called fully-nonseparable 1 function if any two of its parameters  $x_i$  are not independent.

F1: Shifted Elliptic Function

The original Elliptic Function is separable, and is defined as follows:

$$F_{\text{elliptic}}(\mathbf{x}) = \sum_{i=1}^D (10^6)^{\frac{i-1}{D-1}} x_i^2$$

Where  $D$  is the dimension and  $\mathbf{x} = (x_1, x_2, \dots, x_D)$  is a  $D$ -dimensional row vector (i.e., a  $1 \times D$  matrix). The number  $10^6$  is called condition number, which is used to transform a Sphere function to an Elliptic function [38].

To make this function be nonseparable, an orthogonal matrix will be used to rotate the coordinates. The rotated Elliptic function is defined as follows:

$$F_{\text{rot.elliptic}}(\mathbf{x}) = F_{\text{elliptic}}(\mathbf{z}), \quad \mathbf{z} = \mathbf{x} * \mathbf{M}$$

Where  $D$  is the dimension,  $\mathbf{M}$  is a  $D \times D$  orthogonal matrix, and  $\mathbf{x} = (x_1, x_2, \dots, x_D)$  is a  $D$ -dimensional row vector (i.e., a  $1 \times D$  matrix).

Dimension:  $D = 1000$

$\mathbf{x} = (x_1, x_2, \dots, x_D)$ : the candidate solution – a  $D$ -dimensional row vector


$\mathbf{o} = (o_1, o_2, \dots, o_D)$ : the (shifted) global optimum

$\mathbf{z} = \mathbf{x} - \mathbf{o}$ ,  $\mathbf{z} = (z_1, z_2, \dots, z_D)$ : the shifted candidate solution – a  $D$ -dimensional row vector

Properties:

1. Unimodal

2. Shifted
3. Separable
4. Scalable
5.  $\mathbf{x} \in [-100, 100]^D$
6. Global optimum:  $\mathbf{x}^* = \mathbf{0}$ ,  $F(\mathbf{x}^*) = 0$



F<sub>2</sub>: Shifted Rastrigin's Function

The original Rastrigin's function is separable, and is defined as follows:

$$F_{\text{rastrigin}}(\mathbf{x}) = \sum_{i=1}^D [x_i^2 - 10 \cos(2\pi x_i) + 10]$$

Where  $D$  is the dimension and  $\mathbf{x} = (x_1, x_2, \dots, x_D)$  is a  $D$ -dimensional row vector (i.e., a  $1 \times D$  matrix). Similarly, to make it nonseparable, an orthogonal matrix is also used for coordinate rotation. The rotated Rastrigin's function is defined as follows:

$$F_{\text{rot\_rastrigin}}(\mathbf{x}) = F_{\text{rastrigin}}(\mathbf{z}), \quad \mathbf{z} = \mathbf{x} * \mathbf{M}$$

Where  $D$  is the dimension,  $\mathbf{M}$  is a  $D \times D$  orthogonal matrix, and  $\mathbf{x} = (x_1, x_2, \dots, x_D)$  is a  $D$ -dimensional row vector (i.e., a  $1 \times D$  matrix). Rastrigin's function is a classical multimodal problem. It is difficult since the number of local optima grows exponentially with the increase of dimensionality.

Dimension:  $D = 1000$


$\mathbf{x} = [x_1, x_2, \dots, x_D]$ : the candidate solution – a D-dimensional row vector

$\mathbf{o} = [o_1, o_2, \dots, o_D]$ : the (shifted) global optimum

$\mathbf{z} = \mathbf{x} - \mathbf{o}$ ,  $\mathbf{z} = [z_1, z_2, \dots, z_D]$ : the shifted candidate solution – a D-dimensional row vector

Properties:

1. Multimodal
2. Shifted
3. Separable
4. Scalable
5.  $\mathbf{x} \in [-5, 5]^D$
6. Global optimum:  $\mathbf{x}^* = \mathbf{o}$ ,  $F(\mathbf{x}^*) = 0$



$F_3$ : Shifted Ackley's Function

$$F_{ackley}(\mathbf{x}) = -20 \exp \left( -0.2 \sqrt{\frac{1}{D} \sum_{i=1}^D x_i^2} \right) - \exp \left( \frac{1}{D} \sum_{i=1}^D \cos(2\pi x_i) \right) + 20 + e$$

Where  $D$  is the dimension and  $\mathbf{x} = (x_1, x_2, \dots, x_D)$  is a D-dimensional row vector (i.e., a  $1 \times D$  matrix). To make it nonseparable, an orthogonal matrix is again used for coordinate rotation. The rotated Ackley's function is defined as follows:

$$F_{rot\_ackley}(\mathbf{x}) = F_{ackley}(\mathbf{z}), \quad \mathbf{z} = \mathbf{x} * \mathbf{M}$$

Where  $D$  is the dimension,  $M$  is a  $D \times D$  orthogonal matrix, and  $x = (x_1, x_2, \dots, x_D)$  is a  $D$ -dimensional row vector (i.e., a  $1 \times D$  matrix).

Dimension:  $D = 1000$


$x = (x_1, x_2, \dots, x_D)$ : the candidate solution – a  $D$ -dimensional row vector

$o = (o_1, o_2, \dots, o_D)$ : the (shifted) global optimum

$z = x - o, z = (z_1, z_2, \dots, z_D)$ : the shifted candidate solution – a  $D$ -dimensional row vector

Properties:

1. Multimodal
2. Shifted
3. Separable
4. Scalable
5.  $x \in [-32, 32]^D$
6. Global optimum:  $x = o, F(x) = 0$



F<sub>4</sub>: Single-group Shifted and  $m$ -rotated Elliptic Function

Schwefel's Problem 1.2 is a naturally nonseparable function, which is defined as follows:

$$F_{\text{schwefel}}(\mathbf{x}) = \sum_{i=1}^n \left( \sum_{j=1}^i x_j \right)^2$$



Where  $D$  is the dimension and  $\mathbf{x} = (x_1, x_2, \dots, x_D)$  is a  $D$ -dimensional row vector (i.e., a  $1 \times D$  matrix).

Dimension:  $D = 1000$

Group size:  $m = 50$

$\mathbf{x} = (x_1, x_2, \dots, x_D)$ : the candidate solution – a  $D$ -dimensional row vector

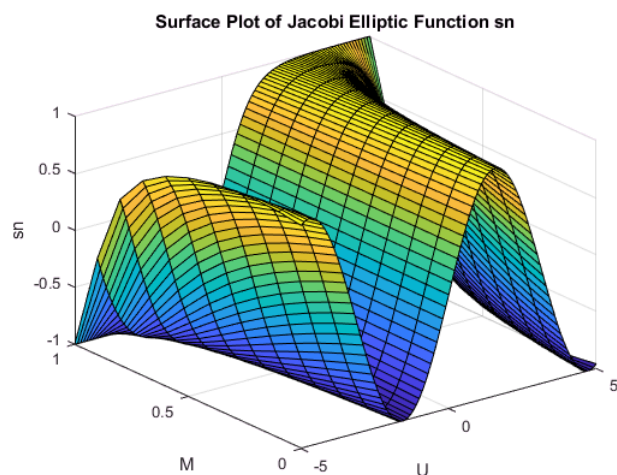
$\mathbf{o} = (o_1, o_2, \dots, o_D)$ : the (shifted) global optimum

$\mathbf{z} = \mathbf{x} - \mathbf{o}$ ,  $\mathbf{z} = (z_1, z_2, \dots, z_D)$ : the shifted candidate solution – a  $D$ -dimensional row vector

$P$ : a random permutation of  $\{1, 2, \dots, D\}$

Properties:

1. Unimodal
2. Shifted
3. Single-group  $m$ -rotated
4. Single-group  $m$ -nonseparable
5.  $\mathbf{x} \in [-100, 100]^D$
6. Global optimum:  $\mathbf{x} = \mathbf{o}$ ,  $F(\mathbf{x}) = 0$



$F_5$ : Single-group Shifted and  $m$ -rotated Rastrigin's Function

$$F_5(\mathbf{x}) = F_{rot\_rastrigin}[\mathbf{z}(P_1 : P_m)] * 10^6 + F_{rastrigin}[\mathbf{z}(P_{m+1} : P_D)]$$

Dimension:  $D = 1000$

Group size:  $m = 50$

$\mathbf{x} = (x_1, x_2, \dots, x_D)$ : the candidate solution – a  $D$ -dimensional row vector

$\mathbf{o} = (o_1, o_2, \dots, o_D)$ : the (shifted) global optimum




$z = x - o$ ,  $z = (z_1, z_2, \dots, z_D)$ : the shifted candidate solution – a  $D$ -dimensional row vector

$P$ : a random permutation of  $\{1, 2, \dots, D\}$

Properties:

1. Multimodal
2. Shifted
3. Single-group  $m$ -rotated
4. Single-group  $m$ -nonseparable
5.  $x \in [-5, 5]^D$
6. Global optimum:  $x^* = o$ ,  $F(x^*) = 0$



ฟังก์ชันมาตรฐาน (Benchmark Function)

$F_{No}$	Name of Function	$n$	$S$	$fmin$
$F_1$	Sphere model	30	$[-100,100]^{cn}$	0
$F_2$	Schwefel's problem	30	$[-10,10]^n$	0
$F_3$	Schwefel's problem	30	$[-100,100]^n$	0
$F_4$	Schwefel's problem	30	$[-1000,1000]^n$	0
$F_5$	Generalized Rosenbrock's function	30	$[-30,30]^n$	0

ภาคผนวก ง  
ข้อมูลการทำแห้งมะละกอแบบออสโมซิส

### วิธีการคำนวณค่า WL และ SG ที่ได้จากการทำแห้งมะละแบบออสโมซิส

เมื่อนำมะละกอฟันธุ์แขกดำที่อยู่ในระยะห้าม (อายุประมาณ 3 สัปดาห์) มาทำการทดลอง โดยใช้วิธีการวางแผนการทดลองแบบบ็อกซ์-เบนเคน กระบวนการออสโมซิสที่ความเข้มข้นของน้ำเชื่อม อุณหภูมิ น้ำเชื่อม และเวลาแช่ที่กำหนด จากนั้นนำข้อมูลมาวิเคราะห์หาค่า WL และ SG

$$\text{Water Loss}(\%) = WR + SG$$

$$\text{Solid Gain}(\%) = \frac{m - m_0}{M_0} \times 100$$

$$\text{Weight Reduction}(\%) = \frac{M_0 - M}{M_0} \times 100$$

- เมื่อ
- $M_0$  - Initial mass of the samples (g)
  - $M$  - Mass of sample after dehydration (g)
  - $m_0$  - Initial mass of the solids in sample (g)
  - $m$  - Mass of the solids in the sample after dehydration (g)

ตารางที่ ง-1 ผลการทดลองทำแห้งมะละกอบีบอบสโมซิส

ลำดับ	สิ่งทดลอง	ระดับ (°C)	ระดับ (°Brix)	ระดับ (Hrs)	น.น. ก่อน	น.น. หลัง	WR (%)	SG (%)	WL (%)
1	Block 1	50	70	5	50.1	31.7	36.7	8.1	44.8
2	Block 1	50	70	5	50.2	31.8	36.7	8.1	44.8
3	Block 1	50	70	5	50.1	32.1	35.9	8.1	44.0
4	Block 1	50	70	5	50.2	32.1	36.1	8.1	44.2
5	Block 1	50	70	5	50.1	31.9	36.3	8.1	44.5
.	.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.	.
40	Block 1	50	70	5	49.8	32.1	35.5	8.1	43.6
41	Block 2	50	50	5	50.2	35.4	29.5	5.7	35.2
42	Block 2	50	50	5	49.9	35.3	29.3	5.7	35.0
43	Block 2	50	50	5	49.8	35.5	28.7	5.7	34.4
44	Block 2	50	50	5	50.0	35.2	29.5	5.7	35.2
45	Block 2	50	50	5	50.1	35.0	30.1	5.7	35.8
.	.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.	.
80	Block 2	50	50	5	50.2	35.2	29.8	5.7	35.5
81	Block 3	30	70	5	49.9	36.5	35.1	4.3	39.3
82	Block 3	30	70	5	50.1	36.4	35.2	4.3	39.5
83	Block 3	30	70	5	50.2	36.5	35.1	4.3	39.3
84	Block 3	30	70	5	49.9	36.7	35.1	4.3	39.4
85	Block 3	30	70	5	49.8	36.5	35.1	4.3	39.3
.	.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.	.
120	Block 3	30	70	5	50.2	36.7	27.0	4.3	31.2

ตารางที่ ง-1 ผลการทดลองทำแห้งมะละกอแบบออสโมซิส (ต่อ)

	สิ่ง ทดลอง	ระดับ (°C)	ระดับ (°Brix)	ระดับ (Hrs)	น.น. ก่อน	น.น. หลัง	WR (%)	SG (%)	WL (%)
	Block								
161	15	40	60	5	49.8	37.2	25.3	4.5	29.8
	Block								
2	15	40	60	5	50.3	37.3	25.8	4.5	30.3
	Block								
3	15	40	60	5	50.1	37.2	25.8	4.5	30.3
	Block								
4	15	40	60	5	49.9	37.0	25.9	4.5	30.4
	Block								
5	15	40	60	5	50.1	37.0	26.2	4.5	30.7
.	.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.	.
600	Block 4	30	50	5	50.1	39.6	20.9	2.9	23.8

ตารางที่ ง-2 ผลการวิเคราะห์หาค่า WR, SG และ WL (%)

ลำดับ	สิ่งทดลอง	ระดับ (°C)	ระดับ (°Brix)	ระดับ (Hrs)	น.น. ก่อน	น.น. หลัง	WR (%)	SG (%)	WL (%)
1	Block 1	50	70	5	50.1	32.0	36.1	8.1	44.2
2	Block 2	50	50	5	50.0	35.2	29.7	5.7	35.4
3	Block 3	30	70	5	50.1	37.0	27.1	4.3	31.4
4	Block 4	30	50	5	50.1	39.7	20.6	2.9	23.5
5	Block 5	50	60	6	50.1	31.9	36.3	8.4	44.7
6	Block 6	50	60	4	50.0	33.7	32.6	7.0	39.6
7	Block 7	30	60	6	50.1	38.4	23.3	3.9	27.2
8	Block 8	30	60	4	50.1	39.5	21.0	2.7	23.7
9	Block 9	40	70	6	50.1	33.4	33.3	5.0	38.3
10	Block 10	40	70	4	50.0	35.0	30.0	4.3	34.3
11	Block 11	40	50	6	50.1	38.1	24.0	4.4	28.4
12	Block 12	40	50	4	50.1	39.1	21.9	3.4	25.3
13	Block 13	40	60	5	50.1	37.3	25.5	4.4	29.9
14	Block 14	40	60	5	50.1	37.2	25.7	4.2	29.9
15	Block 15	40	60	5	50.1	37.2	25.8	4.5	30.3

ตารางที่ ง-3 ผลการวิเคราะห์หาค่า WL และ SG

Tr No	ระดับ (°C)	อุณหภูมิ น้ำเชื่อม (°C)	ระดับ (°Brix)	ความเข้มข้น ของน้ำเชื่อม (°Brix)	ระดับ (Hrs)	เวลาที่ แช่ (Hrs)	Water Loss (%)	Sugar Gain (%)
1	1	50	1	70	0	5	44.52	7.98
2	1	50	-1	50	0	5	35.33	5.29
3	-1	30	1	70	0	5	32.26	4.29
4	-1	30	-1	50	0	5	23.58	2.97
5	1	50	0	60	1	6	44.54	8.13
6	1	50	0	60	-1	4	39.11	7.13
7	-1	30	0	60	1	6	27.12	3.76
8	-1	30	0	60	-1	4	22.32	2.37
9	0	40	1	70	1	6	37.46	4.68
10	0	40	1	70	-1	4	35.37	4.34
11	0	40	-1	50	1	6	27.99	4.38
12	0	40	-1	50	-1	4	25.49	3.32
13	0	40	0	60	0	5	30.41	4.33
14	0	40	0	60	0	5	29.87	4.27
15	0	40	0	60	0	5	29.94	4.31

ภาคผนวก จ  
ผลการวิเคราะห์ข้อมูลด้วย RSM



## ผลการวิเคราะห์ด้วย RSM

## Design Summary

Study Type	Response Surface	Runs	15
Initial Design	Box-Behnken	Blocks	No Blocks
Design Model	Quadratic		

Factor	Name	Units	Type	Low Actual	High Actual	Low
Coded	High Coded		Mean	Std. Dev.		
A	temp		Numeric	30.00	50.00	40.000
					-1.000	1.000
7.303						
B	conc		Numeric	50.00	70.00	60.000
					-1.000	1.000
7.303						
C	time		Numeric	4.00	6.00	5.000
					-1.000	1.000
0.730						

Response	Name	Units	Obs	Analysis	Minimum	
Maximum	Mean	Std. Dev.	Ratio	Trans	Model	
Y1	SG	15	Polynomial	2.500	8.200	4.833
1.639	3.280	None	RQuadratic			
Y2	WL	15	Polynomial	23.200	44.500	32.373
6.624	1.918	None	RQuadratic			

Response 1 SG Transform: None

\*\*\* The Cubic Model is Aliased! \*\*\*

### Sequential Model Sum of Squares [Type I]

Source	Sum of Squares	df	Mean Square	F Value	p-value Prob > F
Mean vs Total	3	5	0.42	13.5	0.42
Linear vs Mean	33.50	3	11.17	18.02	0.0001 Suggested
2FI vs Linear	0.38	3	0.13	0.16	0.9234
Quadratic vs 2FI	4.40	3	1.47	3.59	0.1014
Cubic vs Quadratic	2.04	3	0.68	6.366E+007	< 0.0001 Aliased
Residual	0.000	2	0.000		
Total	3	9	0.7	3.15	26.05

"*Sequential Model Sum of Squares [Type I]*": Select the highest order polynomial where the additional terms are significant and the model is not aliased.

### Lack of Fit Tests

Source	Sum of Squares	df	Mean Square	F Value	p-value Prob > F
Linear	6.82	9	0.76		
2FI	6.44	6	1.07		
Quadratic	2.04	3	0.68		
Cubic	0.000	0			
Pure Error	0.000	2	0.000		

"*Lack of Fit Tests*": Want the selected model to have insignificant lack-of-fit.

### Model Summary Statistics

Source	Std. Dev.	R-Squared	Adjusted R-Squared	Predicted R-Squared	PRESS
Linear	0.79	0.8309	0.7848	0.6590	13.75 Sug
2FI	0.90	0.8402	0.7204	0.2376	30.74
Quadratic	0.64	0.9493	0.8581	0.1894	32.68
Cubic	0.000	1.0000	1.0000		+Aliased

+ Case(s) with leverage of 1.0000: PRESS statistic not defined

"*Model Summary Statistics*": Focus on the model maximizing the "Adjusted R-

Squared" and the "Predicted R-Squared".

Response 1 SG

ANOVA for Response Surface Reduced Quadratic Model

Analysis of variance table [Partial sum of squares - Type III]

Source	Sum of Squares	df	Mean Square	F Value	p-value Prob > F
Model	38.16	5	7.63	31.86	< 0.0001significant
<i>A-temp</i>	27.75	1	27.75	115.85	< 0.0001
<i>B-conc</i>	3.64	1	3.64	15.22	0.0036
<i>C-time</i>	2.10	1	2.10	8.77	0.0159
<i>AB0.30</i>		1	0.30	1.26	0.2902
<i>A<sup>2</sup>4.36</i>		1	4.36	18.19	0.0021
Residual	2.16	9	0.24		
<i>Lack of Fit</i>	2.16	7	0.31		
<i>Pure Error</i>	0.000	2	0.000		
Cor Total	40.31	14			

The Model F-value of 31.86 implies the model is significant.

There is only a 0.01% chance that a "Model F-Value" this large could occur due to noise.

Values of "Prob > F" less than 0.0500 indicate model terms are significant.

In this case A, B, C, A<sup>2</sup> are significant model terms.

Values greater than 0.1000 indicate the model terms are not significant.

If there are many insignificant model terms

model reduction may improve your model.

Std. Dev.	0.49	R-
Squared	0.9465	
Mean	4.83	Adj R-
Squared	0.9168	
C.V. %	10.13	Pred R-
Squared	0.7523	
PRESS	9.98	Adeq
Precision	16.759	

The "Pred R-Squared" of 0.7523 is in reasonable agreement with the "Adj R-Squared" of 0.9168.

"Adeq Precision" measures the signal to noise ratio. A ratio greater than 4 is desirable. Your ratio of 16.759 indicates an adequate signal. This model can be used to navigate the design space.

Coefficient Factor	Estimate	Standard df	95% CI Error	95% CI Low
HighVIF Intercept	4.26	1	0.18	3.844.68
A- temp1.86	1	0.17	1.47	2.251.00
B- conc0.67	1	0.17	0.28	1.071.00
C- time0.51	1	0.17	0.12	0.901.00
AB0.28	1	0.24	-0.28	0.831.00
A <sup>2</sup> 1.08	1	0.25	0.51	1.651.00

Final Equation in Terms of Coded Factors:

$$\begin{aligned}
 \text{SG} &= \\
 &+4.26 \\
 &+1.86 * A \\
 &+0.67 * B \\
 &+0.51 * C \\
 &+0.28 * A * B \\
 &+1.08 * A^2
 \end{aligned}$$

### Final Equation in Terms of Actual Factors:

$$\begin{aligned}
 \text{SG} &= \\
 &+19.5803 \\
 &-0.84304 \quad * \text{ temp} \\
 &-0.042500 \quad * \text{ conc} \\
 &+0.51250 \quad * \text{ time} \\
 &+2.75000\text{E-}003 \quad * \text{ temp} * \text{ conc} \\
 &+0.010804 \quad * \text{ temp}^2
 \end{aligned}$$

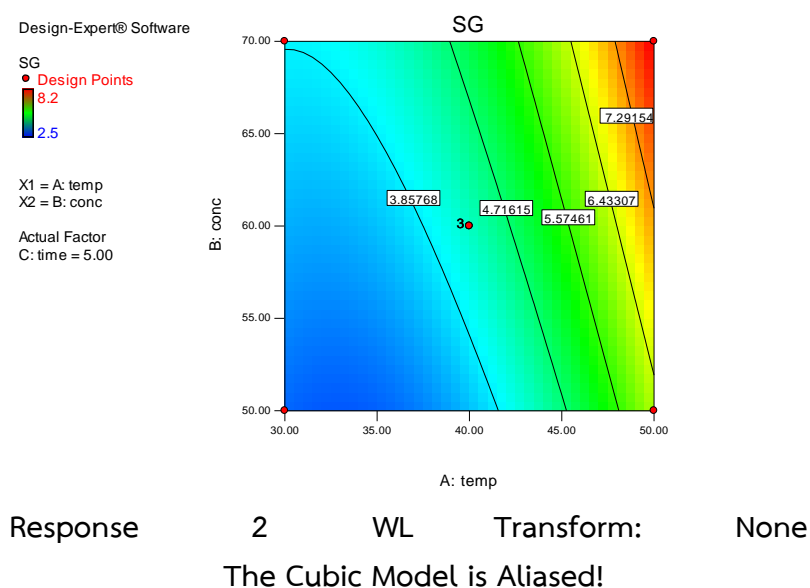
The Diagnostics Case Statistics Report has been moved to the Diagnostics Node. In the Diagnostics Node, Select Case Statistics from the View Menu.

Proceed to Diagnostic Plots (the next icon in progression). Be sure to look at the:

- 1) Normal probability plot of the studentized residuals to check for normality of residuals.

- 2) Studentized residuals versus predicted values to check for constant error.
- 3) Externally Studentized Residuals to look for outliers, i.e., influential values.
- 4) Box-Cox plot for power transformations.

If all the model statistics and diagnostic plots are OK, finish up with the Model Graphs icon.



## Sequential Model Sum of Squares [Type I]

Source	Sum of Squares	df	Mean Square	F Value	p-value Prob > F
Mean vs Total	15	1	15	72	0.49
<u>Linear vs Mean</u>	<u>609.70</u>	<u>3</u>	<u>203.23</u>	<u>46.04</u>	<u>&lt; 0.0001</u>
<u>Suggested</u>					
2FI vs Linear	0.59	3	0.20	0.033	0.9915
<u>Quadratic vs 2FI</u>	<u>35.66</u>	<u>3</u>	<u>11.89</u>	<u>4.83</u>	<u>0.0613</u>
<u>Suggested</u>					
Cubic vs Quadratic	12.24	3	4.08	136.03	0.0073
Residual	0.060	2	0.030		Aliased
Total	16378.74	15	10	91.92	

"*Sequential Model Sum of Squares [Type I]*": Select the highest order polynomial where the additional terms are significant and the model is not aliased.

## Lack of Fit Tests

Source	Sum of Squares	df	Mean Square	F Value	p-value Prob > F
<u>Linear</u>	<u>48.49</u>	<u>2</u>	<u>5.39</u>	<u>179.60</u>	<u>0.0055</u>
2FI	47.91	6	7.98	266.15	0.0037
<u>Quadratic</u>	<u>12.24</u>	<u>3</u>	<u>4.08</u>	<u>136.03</u>	<u>0.0073</u>
Cubic	0.000	0			Aliased
Pure Error	0.060	2	0.030		

"*Lack of Fit Tests*": Want the selected model to have insignificant lack-of-fit.

### Model Summary Statistics

Source	Std. Dev.	R-Squared	Adjusted R-Squared	Predicted R-Squared	PRESS
Linear	2.10	0.9262	0.9061	0.8721	84.18
2FI	2.45	0.9271	0.8725	0.7384	172.20
Quadratic	1.57	0.9813	0.9477	0.7022	196.01
Cubic	0.17	0.9999	0.9994	+ Aliased	

+ Case(s) with leverage of 1.0000: PRESS statistic not defined

"Model Summary Statistics": Focus on the model maximizing the "Adjusted R-Squared" and the "Predicted R-Squared".

Use your mouse to right click on individual cells for definitions.

### Response 2 WL ANOVA for Response Surface Reduced Quadratic Model

#### Analysis of variance table [Partial sum of squares - Type III]

Source	Sum of Squares	df	Mean Square	F Value	p-value Prob > F
Model	645.36	6	107.56	66.77	< 0.0001*
A-temp	421.95	1	421.95	261.93	< 0.0001*
B-conc	161.10	1	161.10	100.00	< 0.0001*
C-time	26.64	1	26.64	16.54	0.0036
A <sup>2</sup>	32.13	1	32.13	19.95	0.0021
B <sup>2</sup>	3.69	1	3.69	2.29	0.1685
C <sup>2</sup>	2.83	1	2.83	1.75	0.2219
Residual	12.89	8	1.61		
Lack of Fit significant	12.83	6	2.14	71.26	0.0139
Pure Error	0.060	2	0.030		
Cor Total	658.25	14			

The Model F-value of 66.77 implies the model is significant. There is only a 0.01% chance that a "Model F-Value" this large could occur due to noise.

Values of "Prob > F" less than 0.0500 indicate model terms are significant.

In this case A, B, C, A<sup>2</sup> are significant model terms. Values greater than 0.1000 indicate the model terms are not significant.

If there are many insignificant model terms (not counting those required to support hierarchy), model reduction may improve your model.

The "Lack of Fit F-value" of 71.26 implies the Lack of Fit is significant. There is only a 1.39% chance that a "Lack of Fit F-value" this large could occur due to noise. Significant lack of fit is bad -- we want the model to fit.

Std. Dev.	1.27	R-
Squared	0.9804	
Mean	32.37	Adj R-
Squared	0.9657	
C.V. %	3.92	Pred R-
Squared	0.9218	
PRESS	51.44	Adeq
Precision	27.103	

The "Pred R-Squared" of 0.9218 is in reasonable agreement with the "Adj R-Squared" of 0.9657.

"Adeq Precision" measures the signal to noise ratio. A ratio greater than 4 is desirable. Your ratio of 27.103 indicates an adequate signal. This model can be used to navigate the design space.

Coefficient Factor	Standard		Error	95% CI		VIF
	Estimate	df		Low	High	
Intercept	29.80	1	0.73	28.11	31.49	
A-temp	7.26	1	0.45	6.23	8.30	1.00
B-conc	4.49	1	0.45	3.45	5.52	1.00
C-time	1.82	1	0.45	0.79	2.86	1.00
A <sup>2</sup> 2.95		1	0.66	1.43	4.47	1.01
B <sup>2</sup> 1.00		1	0.66	-0.52	2.52	1.01
C <sup>2</sup> 0.87		1	0.66	-0.65	2.40	1.01



## Final Equation in Terms of Coded Factors:

$$\begin{aligned}
 \text{WL} &= \\
 +29.80 & \\
 +7.26 & * A \\
 +4.49 & * B \\
 +1.82 & * C \\
 +2.95 & * A^2 \\
 +1.00 & * B^2 \\
 +0.87 & * C^2
 \end{aligned}$$

## Final Equation in Terms of Actual Factors:

$$\begin{aligned}
 \text{WL} &= \\
 +108.775 & \\
 -1.63375 & * \text{temp} \\
 -0.75125 & * \text{conc} \\
 -6.92500 & * \text{time} \\
 +0.029500 & * \text{temp}^2 \\
 +1.00000\text{E-}002 & * \text{conc}^2 \\
 +0.87500 & * \text{time}^2
 \end{aligned}$$

The Diagnostics Case Statistics Report has been moved to the Diagnostics Node.  
 In the Diagnostics Node, Select Case Statistics from the View Menu.

Factor		Name		Level		Low
Level	High Level	Std. Dev.		Coding		
A	temp	44.49	30.00	50.00	0.000	Actual
B	conc	60.00	50.00	70.00	0.000	Actual
C	time	4.00	4.00	6.00	0.000	Actual

ภาคผนวก ฉ  
ผลการวิเคราะห์ข้อมูลด้วยอัลกอริทึม CS และ CSGA

ภาพที่ ฉ-1 ผลการวิเคราะห์หาค่า WL ด้วยอัลกอริทึม CS

The screenshot shows the MATLAB R2017a environment. The script being executed is as follows:

```

4 = clear;
5 = size;
6 = S=M;
7 = F=M;
8 = S=M;
9 = bestIPerson(S,1);
10 = Bk_L1=bestIPerson(S,1);
11 = Tot_time=person(L,1);
12 = for L=1:L;
13 = tic;
14 = [BESTBEST, MinL, BESTCHART, M_star]=CS(F,NET);
15 = Tot_time(L)=M;
16 = best(L)=MinL;
17 = Bk_L1(L)=M_star;
18 = end;
19 = [BEST_ML,MinL, bestIPerson(L,1)];
20 =

```

The Command Window displays the following output:

```

Rce =
6

Brsk =
60

Temp =
40

ans =
32.9037
32.9037
32.9037
32.9037
32.9037
32.9037

```

The Workspace window shows the variable 'ans' with a value of [32.9037; 32.9037; 32.9037; 32.9037; 32.9037].

ภาพที่ ฉ-2 ผลการวิเคราะห์หาค่า SG ด้วยอัลกอริทึม CS

The screenshot shows the MATLAB R2017a environment. The script being executed is as follows:

```

4 = clear;
5 = size;
6 = S=M;
7 = F=M;
8 = S=M;
9 = bestIPerson(S,1);
10 = Bk_L1=bestIPerson(S,1);
11 = Tot_time=person(L,1);
12 = for L=1:L;
13 = tic;
14 = [BESTBEST, MinL, BESTCHART, M_star]=CS(F,NET);
15 = Tot_time(L)=M;
16 = best(L)=MinL;
17 = Bk_L1(L)=M_star;
18 = end;
19 = [BEST_ML,MinL, bestIPerson(L,1)];
20 =

```

The Command Window displays the following output:

```

Rce =
6

Brsk =
60

Temp =
40

ans =
3.8163
3.8163
3.8163
3.8163
3.8163
3.8163

```

The Workspace window shows the variable 'ans' with a value of [3.8163; 3.8163; 3.8163; 3.8163; 3.8163].

ภาพที่ ฉ-3 ผลการวิเคราะห์หาค่า WL ด้วยอัลกอริทึม CSGA

```

4 = clearz
5 = c10r
6 = S=6;
7 = F=2;
8 = SET=1;
9 = bestB=error(1,1);
10 = Wu_It=error(1,1);
11 = Tot_time=error(1,1);
12 = for i=1:L
13 = tic
14 = [BESTBEST, Emis, BESTCHART, M_stex]=CS(F,NET);
15 = Tot_time(i)=c10r;
16 = bestB(i)=Emis;
17 = Wu_It(i)=M_stex;
18 = end
19 = [Best_ML]=min(bestB)
20 =

```

Command Window

```

Row =
     6

BrkL =
    60

Temp =
    60

ans =
    33.7153
    33.7153
    33.7153
    33.7153
    33.7153

```

Workspace

Name	Value
ans	[33.7153;33.7153;33.7...

ภาพที่ ฉ-4 ผลการวิเคราะห์หาค่า SG ด้วยอัลกอริทึม CSGA

```

4 = clearz
5 = c10r
6 = S=6;
7 = F=2;
8 = SET=1;
9 = bestB=error(1,1);
10 = Wu_It=error(1,1);
11 = Tot_time=error(1,1);
12 = for i=1:L
13 = tic
14 = [BESTBEST, Emis, BESTCHART, M_stex]=CS(F,NET);
15 = Tot_time(i)=c10r;
16 = bestB(i)=Emis;
17 = Wu_It(i)=M_stex;
18 = end
19 = [Best_ML]=min(bestB)
20 =

```

Command Window

```

Row =
     6

BrkL =
    60

Temp =
    60

ans =
    4.0149
    4.0149
    4.0149
    4.0149
    4.0149

```

Workspace

Name	Value
ans	[4.0149;4.0149;4.0149...