

การเริ่มทำงานใหม่โดยใช้การกลายพันธุ์ของตำแหน่งอนุภาคสุดท้ายและ  
ตำแหน่งที่ดีที่สุดสำหรับวิธีการหาค่าเหมาะที่สุดแบบอนุภาคกลุ่ม

RERUN OF PARTICLE SWARM OPTIMIZATION USING MUTATION OF  
PARTICLE TRAP POSITION AND GBEST



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาด้านหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต  
สาขาวิชาวิศวกรรมคอมพิวเตอร์

คณะวิศวกรรมศาสตร์

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

พ.ศ.2561

KMITL-2018-EN-M-070-093

การเริ่มทำงานใหม่โดยใช้การกลายพันธุ์ของตำแหน่งอนุภาคสุดท้ายและ  
ตำแหน่งที่ดีที่สุดสำหรับวิธีการหาค่าเหมาะสมที่สุดแบบอนุภาคกลุ่ม

RERUN OF PARTICLE SWARM OPTIMIZATION USING MUTATION OF  
PARTICLE TRAP POSITION AND GBEST



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต  
สาขาวิชาวิศวกรรมคอมพิวเตอร์  
คณะวิศวกรรมศาสตร์  
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง  
พ.ศ.2561  
KMITL-2018-EN-M-070-093

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

RERUN OF PARTICLE SWARM OPTIMIZATION USING MUTATION OF PARTICLE  
TRAP POSITION AND GBEST



A THESIS SUBMITTED IN PARTIAL FULFILLMENT  
OF THE REQUIREMENT FOR THE DEGREE OF  
MASTER OF ENGINEERING IN COMPUTER ENGINEERING  
FACULTY OF ENGINEERING  
KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG  
2018

KMITL-2018-EN-M-070-093

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



COPYRIGHT 2018

FACULTY OF ENGINEERING

KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น เมื่ออนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

คณะวิศวกรรมศาสตร์  
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง  
ใบรับรองวิทยานิพนธ์

หัวข้อวิทยานิพนธ์ การเริ่มทำงานใหม่โดยใช้การกลายพันธุ์ของตำแหน่งอนุภาคสุดท้ายและตำแหน่งที่ดีที่สุดสำหรับวิธีการหาค่าเหมาะสมที่สุดแบบอนุภาคกลุ่ม

Thesis Title Rerun of Particle Swarm Optimization using Mutation of Particle Trap Position and GBEST

นักศึกษา นางสาวโรธร เขยโสภา

รหัสประจำตัว 56601137

ปริญญา วิศวกรรมศาสตรมหาบัณฑิต

สาขาวิชา วิศวกรรมคอมพิวเตอร์

อาจารย์ที่ปรึกษาวิทยานิพนธ์ รศ.กฤตวัน ศิริบุญ

หมายเลขวิทยานิพนธ์ KMITL-2018-EN-M-070-093

คณะกรรมการสอบวิทยานิพนธ์		ลายมือชื่อ
รศ.ดร.สุรพงศ์	เอื้อวัฒนามงคล	สุรพงศ์ สุรพงศ์
รศ.ดร.เกียรติกุล	เจียรนัยธนะกิจ	เกียรติกุล
รศ.ดร.บุญฉวี	เครือตราชู	บุญฉวี เครือตราชู
ผศ.ดร.สมศักดิ์	วัลย์รัชต์	วัลย์รัชต์
รศ.กฤตวัน	ศิริบุญ	กฤตวัน ศิริบุญ

วัน / เดือน / ปี ที่สอบ วันพุธที่ 11 กรกฎาคม พ.ศ. 2561 เวลา 11.00-13.00 น.  
สถานที่สอบ ณ ห้อง HM-304 อาคารเฉลิมพระเกียรติ

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง  
KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

คณะวิศวกรรมศาสตร์ รับรองแล้ว

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น เมื่อผู้สอบเห็นใบรับรองนี้แล้ว  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้อง **คืนบัตร** คณะวิศวกรรมศาสตร์ **คืนบัตร** ที่มีกรนำไปใช้

หัวข้อวิทยานิพนธ์	การเริ่มทำงานใหม่โดยใช้การกลายพันธุ์ของตำแหน่งอนุภาคสุดท้ายและตำแหน่งที่ดีที่สุดสำหรับวิธีการหาค่าเหมาะสมที่สุดแบบอนุภาคกลุ่ม
นักศึกษา	นางสาวโรธร เชยโกคา
รหัสนักศึกษา	56601137
ปริญญา	วิศวกรรมศาสตรมหาบัณฑิต
สาขาวิชา	วิศวกรรมคอมพิวเตอร์
พ.ศ.	2561
อาจารย์ที่ปรึกษาวิทยานิพนธ์	รศ.กฤตวัน ศิริบูรณ์

### บทคัดย่อ

ขั้นตอนวิธีการหาค่าเหมาะสมที่สุดแบบอนุภาคกลุ่ม (Particle Swarm Optimization) เป็นวิธีการค้นหาค่าตอบของอนุภาคทั้งหมดภายในปริภูมิคำตอบ (Search Space) แต่ PSO ก็ยังมีปัญหาอยู่ คือ ปัญหาค่าเหมาะสมที่สุดสัมพัทธ์ (Local Optima) วิทยานิพนธ์นี้จึงมีความคิดที่จะนำแนวทางการเริ่มทำงานใหม่มาใช้เมื่ออนุภาคติดอยู่ใน Local Optima โดยใช้การกลายพันธุ์ของตำแหน่งอนุภาคสุดท้ายและตำแหน่งที่ดีที่สุดของอนุภาค (GBEST) นำมาหาค่าตอบเพื่อให้ได้ผลลัพธ์ที่ดียิ่งขึ้น ซึ่งวิทยานิพนธ์นี้ได้ทำการทดลองกับฟังก์ชันมาตรฐาน 26 ฟังก์ชัน โดยผลการทดลองที่ได้แสดงให้เห็นว่าวิธีที่นำเสนอมีประสิทธิภาพมากกว่าเมื่อเปรียบเทียบกับวิธีการอื่น

<b>Thesis</b>	Rerun of Particle Swarm Optimization using Mutation of Particle Trap Position and GBEST
<b>Student</b>	Miss.Varothon Cheypoca
<b>Student ID.</b>	56601137
<b>Degree</b>	Master of Engineering
<b>Program</b>	Computer Engineering
<b>Year</b>	2018
<b>Thesis Advisor</b>	Assoc.Prof.Kritawan Siriboon

## ABSTRACT

Particle Swarm Optimization (PSO) algorithm use particles to search for solution in search space. One problem of PSO is the trapping in local optima problem. This thesis introduces a new algorithm when particles are trapped in local optima (Rerun). It uses the mutation of particle trap position and best particle position (GBEST) to get a better value (Fitness). The proposed method is tested on 26 benchmark test functions with satisfactory results.



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นอนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงด้วยดี เนื่องจากได้รับความกรุณาและการดูแลที่เต็มเปี่ยมด้วยความกรุณาอย่างยิ่งจากอาจารย์ปรึกษาวิทยานิพนธ์ รศ.กฤตวัน ศิริบุรณ และ รศ.ดร. บุญธีร์ เครือตราชู ที่ได้ให้คำปรึกษาแนะนำชี้แนะแนวทางในการศึกษาเรียนรู้จนกระทั่งแล้วเสร็จจึงขอกราบขอบพระคุณเป็นอย่างสูงมา ณ โอกาสนี้

ขอขอบคุณเจ้าหน้าที่และอาจารย์ทุกท่าน ภาควิชาคอมพิวเตอร์ คณะวิศวกรรมศาสตร์ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง ตลอดจนนักวิจัยทุกท่านที่เอื้อเฟื่องานวิจัยจนทำให้วิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงไปได้ด้วยดี

ขอขอบคุณเพื่อน ๆ พี่ ๆ น้อง ๆ ทุกคนที่อยู่ในห้องวิจัยที่คอยให้ความช่วยเหลือสนับสนุนในเรื่องต่าง ๆ จนทำให้วิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงไปได้ด้วยดี

สุดท้ายขอขอบพระคุณครอบครัวของข้าพเจ้าทุกคนที่ได้ให้การสนับสนุนในเรื่องต่าง ๆ จนทำให้วิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงไปได้ด้วยดี

หวังว่าผู้อ่านคงจะได้ความรู้จากวิทยานิพนธ์ฉบับนี้ไม่มากก็น้อย และหากวิทยานิพนธ์ฉบับนี้มีข้อผิดพลาดประการใด ข้าพเจ้าขอน้อมรับไว้แต่เพียงผู้เดียว

วโรธร เขยโกคา

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

# สารบัญ

หน้า

บทคัดย่อภาษาไทย.....	I
บทคัดย่อภาษาอังกฤษ.....	II
กิตติกรรมประกาศ.....	III
สารบัญ .....	IV
สารบัญตาราง.....	VI
สารบัญรูป.....	VII

บทที่ 1 บทนำ .....	1
1.1 ความเป็นมาและความสำคัญของปัญหา .....	1
1.2 จุดมุ่งหมายและวัตถุประสงค์.....	2
1.3 สมมติฐานของการศึกษา.....	2
1.4 ขอบเขตของการวิจัย .....	2
1.5 ขั้นตอนของการศึกษา.....	2
1.6 เครื่องมือและอุปกรณ์ที่ใช้ในการวิจัย.....	2
1.7 โครงสร้างของวิทยานิพนธ์.....	3
บทที่ 2 ทฤษฎีพื้นฐานที่เกี่ยวข้อง .....	4
2.1 ขั้นตอนวิธีการหาค่าเหมาะสมที่สุดแบบอนุภาคกลุ่ม.....	4
2.1.1 นิยามที่ใช้กับ PSO .....	4
2.1.2 ขั้นตอนการทำงานของ PSO .....	5
2.2 Local Optimum และ Global Optimum .....	7
2.3 ปัญหาการหาจุดที่ดีที่สุด.....	7
2.3.1 ปัญหาการหาจุดที่ดีที่สุดแบ่งได้ 2 ลักษณะ .....	8
บทที่ 3 งานวิจัยที่เกี่ยวข้อง .....	10
3.1 การเพิ่มประสิทธิภาพ PSO ด้วยการเริ่มต้นใหม่ .....	10
3.2 ขั้นตอนวิธีการปรับปรุงการหาค่าความเหมาะสมที่ดีที่สุดแบบกลุ่มอนุภาคแบบ หลากหลายกลุ่มโดยใช้การกระจายตำแหน่งของอนุภาคเมื่อติดในจุดสูงสุดสัมพัทธ์ร่วมกับการ เปลี่ยนตำแหน่งของอนุภาคที่ดีที่สุดของกลุ่ม.....	11
3.3 การปรับปรุงการหาค่าเหมาะสมที่สุดแบบกลุ่มอนุภาคโดยใช้การเรียนรู้แบบเพิ่มและจุด เซนทรอยด์ของตำแหน่งที่ดีที่สุด .....	12
3.3.1 IAC-PSO ขั้นตอนการทำงาน .....	12
บทที่ 4 งานที่นำเสนอ .....	14

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## สารบัญ (ต่อ)

หน้า

4.1 การแก้ปัญหาการติดใน Local Optima ของ PSO โดยประยุกต์ใช้การเริ่มทำงานใหม่	14
4.2 การเปลี่ยนตำแหน่งอนุภาคโดยใช้วิธีการกลายพันธุ์.....	15
4.3 การเปลี่ยนตำแหน่ง GBEST โดยใช้วิธีการกลายพันธุ์.....	16
4.4 การเริ่มทำงานใหม่โดยใช้การกลายพันธุ์ของตำแหน่งอนุภาคสุดท้ายและตำแหน่งที่ดีที่สุดสำหรับวิธีการหาค่าเหมาะสมที่สุดแบบอนุภาคกลุ่ม .....	18
บทที่ 5 ผลการทดลอง.....	20
5.1 การทดลองวัดประสิทธิภาพของการใช้การกลายพันธุ์ของอนุภาคและตำแหน่ง PBEST และ GBEST แบบต่าง ๆ และการใช้ Multi-Swarm ในการดึงอนุภาคออกจากตำแหน่ง Local Optima.....	25
5.2 การทดลองปรับเปลี่ยนค่าพารามิเตอร์ต่าง ๆ ที่เหมาะสมของวิธี MPG-PSO.....	31
5.3 ทดลองเปลี่ยนตำแหน่งของค่าคำตอบที่ดีที่สุดจากตำแหน่งจุด (0, 0).....	34
5.4 การทดลองวัดประสิทธิภาพการค้นหาของขั้นตอนวิธีที่นำเสนอเปรียบเทียบกับ MPG-PSO และ IAC-PSO.....	36
บทที่ 6 สรุปผลการทดลองและข้อเสนอแนะ .....	41
6.1 สรุปผลการทดลอง .....	41
6.2 ข้อเสนอแนะ .....	41
เอกสารอ้างอิง .....	42
ภาคผนวก.....	43
ภาคผนวก ก ปัญหาของฟังก์ชันมาตรฐานที่ใช้ในการทดลอง .....	44
ภาคผนวก ข งานวิจัยที่ได้รับการตีพิมพ์ .....	71
ประวัติผู้เขียน.....	78

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

# สารบัญตาราง

ตารางที่	หน้า
5.1 ค่าพารามิเตอร์ที่ใช้ทดลองกับฟังก์ชันคณิตศาสตร์.....	23
5.2 จำนวนมิติของปัญหาฟังก์ชันคณิตศาสตร์.....	24
5.3 ผลการค้นหาคำตอบของฟังก์ชันมาตรฐานด้วย PSO, PSORE, MPSOSM, GBEST 1, GBEST 2, GBEST 3 และ MPG-PSO .....	26
5.4 ผลการค้นหาคำตอบของฟังก์ชันมาตรฐานด้วย PSO, PSORE, MPSOSM, GBEST 1, GBEST 2, GBEST 3 และ MPG-PSO (ต่อ).....	27
5.5 ผลการค้นหาคำตอบของวิธี MPG-PSO โดยทำการเปลี่ยนค่า Local Optima Threshold เป็น 50 และ 150 ตามลำดับ .....	32
5.6 ผลการค้นหาคำตอบของวิธี MPG-PSO โดยทำการเปลี่ยนเปอร์เซ็นต์การกลายพันธุ์ตำแหน่งอนุภาคจาก 20 เปอร์เซ็นต์ เป็น 10 และ 30 เปอร์เซ็นต์ ตามลำดับ.....	33
5.7 ผลการค้นหาคำตอบของวิธี MPG-PSO โดยทำการเปลี่ยนเปอร์เซ็นต์การกลายพันธุ์ GBEST จาก 30 เปอร์เซ็นต์ เป็น 20 และ 40 เปอร์เซ็นต์ ตามลำดับ .....	34
5.8 ผลการค้นหาคำตอบของวิธี MPG-PSO โดยทำการเปลี่ยนตำแหน่งของค่าคำตอบที่ดีที่สุดจากตำแหน่งจุด (0, 0) ไปทาง Upper Limit 25 เปอร์เซ็นต์.....	35
5.9 ค่าพารามิเตอร์ที่ใช้เปรียบเทียบ MPG-PSO กับ IAC-PSO.....	36
5.10 ผลการค้นหาคำตอบของฟังก์ชันมาตรฐาน 2 มิติ ด้วย MPG-PSO กับ IAC-PSO.....	36
5.11 ผลการค้นหาคำตอบของฟังก์ชันมาตรฐาน 50 มิติ ด้วย MPG-PSO กับ IAC-PSO.....	37
5.12 ผลการค้นหาคำตอบของฟังก์ชันมาตรฐาน 100 มิติ ด้วย MPG-PSO กับ IAC-PSO .....	37

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

# สารบัญรูป

รูปที่	หน้า
2.1	ขั้นตอนการทำงานของ PSO..... 5
2.2	แสดงตัวอย่าง Local Optima และ Global Optima..... 7
2.3	ฟังก์ชัน Rosenbrock..... 8
2.4	ตัวอย่างปัญหา Unimodal Problem..... 8
2.5	ตัวอย่างปัญหา Multi-modal Problem ..... 9
3.1	แสดงผังงานวิธี PSORE..... 10
3.2	ตัวอย่างการทำการเริ่มต้นใหม่..... 11
3.3	ตัวอย่างการสลับ GBEST ระหว่าง 2 กลุ่มอนุภาค..... 11
3.4	แสดงผังงานวิธี IAC-PSO..... 13
4.1	รหัสจำลองแสดงการทำงานของ MPG-PSO ..... 18
4.2	แสดงผังงานวิธี MPG-PSO..... 19
5.1	การทำงานของ GBEST 1 ..... 21
5.2	การทำงานของ GBEST 2 ..... 21
5.3	การทำงานของ GBEST 3 ..... 22
5.4	การทำงานของ MPG-PSO ..... 22
5.5	กราฟแสดงการทำงานของฟังก์ชัน Rosenbrock..... 29
5.6	กราฟแสดงการทำงานของฟังก์ชัน Ackley ด้วยวิธี IAC-PSO ..... 38
5.7	กราฟแสดงการทำงานของฟังก์ชัน Ackley ด้วยวิธี MPG-PSO อนุภาค 30 ตัว ..... 38
5.8	กราฟแสดงการทำงานของฟังก์ชัน Ackley ด้วยวิธี MPG-PSO อนุภาค 160 ตัว ..... 39
5.9	กราฟแสดงการทำงานของฟังก์ชัน Rastrigin ด้วยวิธี IAC-PSO ..... 39
5.10	กราฟแสดงการทำงานของฟังก์ชัน Rastrigin ด้วยวิธี MPG-PSO อนุภาค 30 ตัว ..... 39
5.11	กราฟแสดงการทำงานของฟังก์ชัน Rastrigin ด้วยวิธี MPG-PSO อนุภาค 160 ตัว ..... 40

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

# บทที่ 1

## บทนำ

### 1.1 ความเป็นมาและความสำคัญของปัญหา

ขั้นตอนวิธีการค่าเหมาะสมที่สุดแบบอนุภาคกลุ่ม (Particle Swarm Optimization, PSO) ถูกคิดค้นขึ้นครั้งแรกในปี 1995 โดย Kennedy and Eberhart [1, 2] ขั้นตอนในการหาค่าความเหมาะสมจะพิจารณาจากพฤติกรรมกรหาอาหารของฝูงสัตว์ เช่น ฝูงนก และการแลกเปลี่ยนข้อมูลระหว่างนกในฝูง สิ่งมีชีวิตแต่ละตัวจะถูกแทนด้วยอนุภาคและเคลื่อนที่กระจายอยู่ในขอบเขตของปริภูมิคำตอบ (Search Space) โดยแต่ละตำแหน่งของอนุภาคจะมีการหาค่าความเหมาะสม (Fitness) ซึ่ง PSO จะหาค่าตอบด้วยการเลื่อนตำแหน่งของอนุภาคไปหาอนุภาคที่มีค่าความเหมาะสมที่ดีที่สุด (GBEST) ตามสมการการเคลื่อนที่ ความเร็วในการเคลื่อนที่จะขึ้นกับระยะห่างระหว่างอนุภาคนั้น ๆ หากว่าระหว่างทางที่ทำการเคลื่อนที่อนุภาคได้พบตำแหน่งที่ดีกว่า อนุภาคนั้นจะกลายเป็นอนุภาคที่มีค่าความเหมาะสมที่ดีที่สุดและอนุภาคตัวอื่นจะเคลื่อนที่เข้ามาหาแทน

PSO ได้ถูกนำไปประยุกต์เพื่อเพิ่มประสิทธิภาพและแก้ไขปัญหามากมาย แต่ PSO ก็ยังมีข้อเสียที่สำคัญ คือ การติดอยู่ในค่าเหมาะสมที่สุดสัมพัทธ์ (Local optima) เพื่อหลีกเลี่ยงปัญหานี้ นักวิจัยหลายท่านทดลองใช้วิธีต่าง ๆ ในการแก้ปัญหา เช่น การแบ่งกลุ่มของอนุภาค, การเริ่มต้นใหม่ (Rerun), การรีโพซิชั่น (Reposition) [3] และทดลองเปลี่ยนสมการการปรับปรุงตำแหน่งของอนุภาค โดยวิทยานิพนธ์นี้มุ่งเน้นไปที่วิธีการเริ่มต้นใหม่เมื่ออนุภาคมีการติดอยู่ใน Local Optima ด้วยการใช้ตำแหน่งที่แตกต่างกันในการทำงานแต่ละครั้ง เพื่อเพิ่มโอกาสในการหาค่าตอบที่ดีขึ้น นักวิจัยหลายท่านพยายามที่จะทำการกระบวนการการกลายพันธุ์อนุภาคเล็กน้อยให้ใกล้กับตำแหน่งที่อนุภาคติดอยู่แทนที่จะเป็นตำแหน่งใหม่โดยการสุ่ม ความคิดนี้ได้มีการใช้อย่างกว้างขวางในขั้นตอนการกลายพันธุ์ในขั้นตอนวิธีเชิงพันธุกรรม (GA) [4] โดยการกลายพันธุ์นี้มักจะทำได้ดีถ้าตำแหน่งที่อนุภาคติดอยู่ใกล้กับตำแหน่งของคำตอบ

การทำกระบวนการเริ่มต้นใหม่ด้วยการสุ่มตำแหน่งแบบหลากหลายในวงกว้างอาจเพิ่มโอกาสในการหาค่าคำตอบที่ดีที่สุด แต่ก็ไม่มีการรับประกันว่าจะพบค่าคำตอบที่ดีที่สุดในการค้นหาครั้งใหม่ ในทางตรงกันข้ามตำแหน่งอนุภาคก่อนการเริ่มต้นใหม่อาจจะมีบางมิติที่พบค่าคำตอบที่ดีที่สุดอยู่ก่อนแล้ว ดังนั้นตำแหน่งใหม่ควรมีความหลากหลายเพียงพอที่จะหลีกเลี่ยงการกลับมาติดใน Local Optima อีกครั้ง และในเวลาเดียวกันก็ไม่ควรที่จะทิ้งบางมิติที่พบค่าคำตอบที่ดีที่สุดอยู่แล้วออกไป เพื่อจำกัดพื้นที่การค้นหาและเวลาในการค้นหาค่าตอบ วิทยานิพนธ์ฉบับนี้ได้เสนอการใช้การกลายพันธุ์จากตำแหน่งที่อนุภาคติดอยู่ในตำแหน่ง (Trap Position) พร้อมกับการกลายพันธุ์ของ GBEST เพื่อเพิ่มความหลากหลายในการทำงานรอบต่อไป

## 1.2 จุดมุ่งหมายและวัตถุประสงค์

จุดมุ่งหมายและวัตถุประสงค์ของวิทยานิพนธ์ฉบับนี้ เพื่อนำเสนอแนวทางการค้นหาค่าความเหมาะสมที่ดีที่สุดด้วยวิธีการเริ่มต้นใหม่และการกลายพันธุ์มาประยุกต์ใช้ เพื่อลดปัญหาการติดใน Local Optima โดยต้องการทำให้คำตอบที่ได้ดีขึ้นและใช้เวลาในการค้นหาน้อยลง โดยใช้ฟังก์ชันมาตรฐานทั้งหมด 26 ฟังก์ชันในการเปรียบเทียบ

## 1.3 สมมติฐานของการศึกษา

การประยุกต์ใช้การเริ่มต้นใหม่และการกลายพันธุ์โดยการนำเอาเปอร์เซ็นต์มากำหนดขอบเขตนั้น จะสามารถหลีกเลี่ยงการติดอยู่ใน Local Optima ได้ เมื่อเปรียบเทียบกับทดลองเปลี่ยนวิธีการกลายพันธุ์ในรูปแบบต่าง ๆ

## 1.4 ขอบเขตของการวิจัย

1. พัฒนาการเริ่มต้นใหม่และการกลายพันธุ์เพื่อแก้ปัญหาการติด Local Optima และลดเวลาในการค้นหาคำตอบ ซึ่งเป็นข้อเสียหลักของ PSO
2. โดยวิทยานิพนธ์ฉบับนี้ได้ทำการวัดประสิทธิภาพด้วยฟังก์ชันมาตรฐาน 26 ฟังก์ชัน

## 1.5 ขั้นตอนของการศึกษา

1. ศึกษาความรู้พื้นฐานเกี่ยวกับ PSO
2. ศึกษางานวิจัยที่เกี่ยวข้องสำหรับการประยุกต์ใช้ในรูปแบบต่าง ๆ
3. ศึกษาวิธีการประยุกต์ใช้การเริ่มต้นใหม่และการกลายพันธุ์
4. ศึกษาวิธีการประยุกต์ใช้ GBEST ในรูปแบบต่าง ๆ
5. ทดลองการปรับเปลี่ยน GBEST ในรูปแบบต่าง ๆ ร่วมกับฟังก์ชันมาตรฐาน
6. เปรียบเทียบผลที่ได้กับวิธีการหาค่าความเหมาะสมในรูปแบบอื่น ๆ
7. สรุปผลการทดลอง
8. ส่งบทความวิจัยเพื่อตีพิมพ์และจัดทำรูปเล่มวิทยานิพนธ์

## 1.6 เครื่องมือและอุปกรณ์ที่ใช้ในการวิจัย

1. เครื่องคอมพิวเตอร์ส่วนบุคคลหน่วยประมวลผลกลาง Intel Core i3 ความเร็ว 2.27 GHz หน่วยความจำหลัก 8 GB
2. ระบบปฏิบัติการวินโดวส์ 7 รุ่น Professional
3. โปรแกรม Microsoft Visual C++ 2013

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## 1.7 โครงสร้างของวิทยานิพนธ์

วิทยานิพนธ์ฉบับนี้แบ่งเนื้อหาออกเป็น 6 บท ดังนี้

บทที่ 1 อธิบายถึงความเป็นมาและความสำคัญของปัญหา จุดมุ่งหมายและวัตถุประสงค์ สมมติฐานของการศึกษา ขอบเขตของการวิจัย ขั้นตอนของการศึกษา เครื่องมือและอุปกรณ์ที่ใช้ในการวิจัย

บทที่ 2 อธิบายถึงนิยามรวมถึงทฤษฎีพื้นฐานที่เกี่ยวข้อง

บทที่ 3 อธิบายถึงงานวิจัยที่นำมาใช้เปรียบเทียบและเกี่ยวข้อง ได้แก่ PSORE MPSOSM และ IAC-PSO

บทที่ 4 อธิบายถึงวิธีการใช้การกลายพันธุ์ของตำแหน่งอนุภาคสุดท้ายและตำแหน่งที่ดีที่สุดในการเริ่มต้นใหม่สำหรับ PSO

บทที่ 5 อธิบายการทดลองและเปรียบเทียบผลลัพธ์กับ PSO ในรูปแบบต่าง ๆ โดยดำเนินการทดลองกับฟังก์ชันมาตรฐาน 26 ฟังก์ชัน

บทที่ 6 อธิบายถึงการสรุปผลการทดลองและข้อเสนอแนะ



## บทที่ 2

# ทฤษฎีพื้นฐานที่เกี่ยวข้อง

### 2.1 ขั้นตอนวิธีการหาค่าเหมาะสมที่สุดแบบอนุภาคกลุ่ม

ขั้นตอนวิธีการหาค่าเหมาะสมที่สุดแบบอนุภาคกลุ่ม (Particle Swarm Optimization, PSO) เป็นวิธีการหาค่าตอบที่เหมาะสมที่สุด ถูกคิดค้นขึ้นโดย อีเบอร์ฮาร์ท (Eberhart) และเคนเนดี (Kennedy) ในปี 1995 ซึ่งได้แนวคิดมาจากการสังเกตการเคลื่อนไหวของฝูงนก และการแลกเปลี่ยนข้อมูลระหว่างออกหาอาหาร เพื่อที่จะทำการเคลื่อนที่ไปยังแหล่งอาหารที่ได้รับข้อมูลมา โดยแนวคิดนี้จะหาค่าตอบโดยการใช้อนุภาค (Particle) เป็นตัวแทนของนกที่อยู่ในฝูง ให้เคลื่อนที่ไปบนพื้นที่ที่ต้องการค้นหา (Search Space) เพื่อหาค่าตอบที่ดีที่สุด (Best Fitness หรือ GBEST)

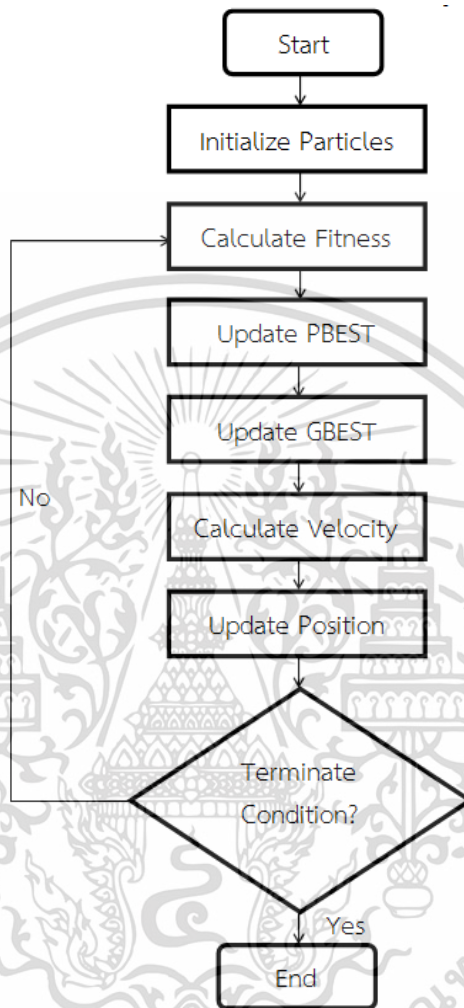
#### 2.1.1 นิยามที่ใช้กับ PSO

1. ปริภูมิคำตอบ (Search Space) คือ ขอบเขตของคำตอบที่เป็นไปได้ทั้งหมดของปัญหาที่ต้องการค้นหา
2. อนุภาค (Particle) คือ ตัวแทนของคำตอบหนึ่ง ๆ ของปัญหาที่ต้องการค้นหาใน Search Space ซึ่งมีค่าแตกต่างกันขึ้นอยู่กับปัญหา
3. ประชากร (Population) คือ จำนวนกลุ่มของอนุภาคทั้งหมดที่ใช้ในการหาค่าตอบจากการเคลื่อนที่ใน Search Space โดยจำนวนของประชากรจะมีค่าคงที่
4. จำนวนรอบการค้นหาคำตอบ (Iteration) คือ จำนวนรอบที่ใช้ในการหาค่าตอบที่ได้กำหนดไว้ให้หยุดการทำงาน เพราะ PSO ทำงานแบบวนซ้ำไปเรื่อย ๆ โดยจะทำการวนรอบการทำงานไปจนกว่าจะถึงค่าที่กำหนดไว้เพื่อหยุดการทำงาน
5. ตำแหน่งของอนุภาค (Position) คือ ตำแหน่งของอนุภาคที่อยู่ใน Search Space
6. ความเร็วของอนุภาค (Velocity) คือ เวกเตอร์ที่บอกขนาดและทิศทางที่อนุภาคจะเคลื่อนที่ไปยังตำแหน่งใหม่ ซึ่งความเร็วของอนุภาคจะถูกคำนวณขึ้นมาใหม่ในทุกรอบของการทำงาน
7. ความเร็วสูงสุด ( $V_{max}$ ) คือ ค่าความเร็วสูงสุดที่เป็นไปได้ของอนุภาค ซึ่งจะอยู่ในช่วง  $[-V_{max}, V_{max}]$
8. ค่าความเหมาะสม (Fitness Value) คือ ค่าที่ใช้กำหนดว่าตำแหน่งของอนุภาคนั้นเป็นตำแหน่งที่ดีที่สุดหรือไม่ ซึ่งค่าความเหมาะสมนี้จะขึ้นอยู่กับแต่ละปัญหา
9. ตำแหน่งที่ดีที่สุดของอนุภาค (Personal Best Solution, PBEST) คือ ตำแหน่งของอนุภาคแต่ละตัวที่มีค่าความเหมาะสมที่ดีที่สุดเท่าที่อนุภาคตัวนั้นเคยหาค่าตอบมา

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

10. ตำแหน่งที่ดีที่สุดของอนุภาคทั้งหมด (Global Best Position, GBEST) คือตำแหน่งของอนุภาคที่มีค่าความเหมาะสมที่ดีที่สุดเท่าที่อนุภาคทุกตัวเคยหาค่าตอบมา

### 2.1.2 ขั้นตอนการทำงานของ PSO



รูปที่ 2.1 ขั้นตอนการทำงานของ PSO

1. การตั้งค่าเริ่มต้น (Initialize Particles) กระบวนการการตั้งค่าเริ่มต้น เป็นกระบวนการที่อนุภาคทุกตัวทำการสุ่มตำแหน่งและค่าความเร็วเริ่มต้นที่เหมาะสมใน Search Space ซึ่งจะให้เป็นขั้นตอนแรกและทำเพียงครั้งเดียวเท่านั้น โดยค่าที่ได้จากการสุ่มจะต้องมีค่าไม่เกินขอบเขตที่กำหนดเอาไว้

2. การคำนวณหาค่าความเหมาะสม (Calculate Fitness) กระบวนการการคำนวณหาค่าความเหมาะสม เป็นกระบวนการที่นำอนุภาคแต่ละตัวไปหาค่าความเหมาะสมของตำแหน่งปัจจุบัน ตามฟังก์ชันการคำนวณค่าความเหมาะสมตามแต่ละปัญหาที่เลือก (Benchmark Test Function) แล้วนำค่าความเหมาะสมที่ได้จากการคำนวณไปใช้ในการปรับปรุงค่า PBEST และ GBEST ต่อไป

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3. การหาตำแหน่งคำตอบที่ดีที่สุดของอนุภาค (Update PBEST) กระบวนการการหาตำแหน่งคำตอบที่ดีที่สุดของอนุภาค แต่ละอนุภาคจะเลือกค่าความเหมาะสมที่ดีที่สุดของตัวเอง ถ้าค่าความเหมาะสมของ PBEST ที่คำนวณได้มีค่าดีกว่าค่าความเหมาะสมของ PBEST เดิม ให้ทำการแทนที่ค่า PBEST ด้วยค่าที่ดีกว่า

4. การหาตำแหน่งคำตอบที่ดีที่สุดของอนุภาคทั้งหมด (Update GBEST) กระบวนการการหาตำแหน่งคำตอบที่ดีที่สุดของอนุภาคทั้งหมด เป็นกระบวนการในการปรับปรุงค่า GBEST โดยนำค่าที่ได้จากการคำนวณค่าความเหมาะสมมาเปรียบเทียบกับค่าความเหมาะสมของ GBEST ปัจจุบัน ถ้าค่าที่คำนวณได้มีค่าที่ดีกว่า ให้ทำการแทนที่ค่า GBEST ด้วยค่าที่ดีกว่านั้น

5. การคำนวณหาค่าความเร็ว (Calculate Velocity) กระบวนการการคำนวณหาค่าความเร็ว จะทำการคำนวณหาค่าความเร็วของอนุภาคนั้น ๆ ซึ่งสามารถคำนวณได้ตามสมการที่ (2.1)

$$v_i(t+1) = \omega v_i(t) + c_1(p_i - x_i(t))R_1 + c_2(g - x_i(t))R_2 \quad (2.1)$$

โดยกำหนดให้

$v_i(t+1)$	คือ ความเร็วในรอบปัจจุบัน
$v_i(t)$	คือ ความเร็วในรอบเดิม
$c_1, c_2$	คือ ค่าคงที่ที่ทำหน้าที่เป็นสัมประสิทธิ์ปรับค่าความเร็ว
$\omega$	คือ ค่าสัมประสิทธิ์ความเฉื่อยของความเร็วเดิม
$R_1, R_2$	คือ ค่าที่สุ่มอยู่ในช่วง $[0, 1]$
$p_i$	คือ ตำแหน่งคำตอบที่ดีที่สุดของอนุภาคแต่ละตัว
$g$	คือ ตำแหน่งคำตอบที่ดีที่สุดของอนุภาคทั้งหมด
$x_i(t)$	คือ ตำแหน่งปัจจุบันของอนุภาค $i$

6. การเคลื่อนที่ของอนุภาค (Update Position) กระบวนการการเคลื่อนที่ของอนุภาค จะทำการปรับปรุงตำแหน่งของอนุภาค โดยอนุภาคจะเคลื่อนที่จากตำแหน่งเดิมไปยังตำแหน่งใหม่ด้วยระยะที่ได้จากการคำนวณด้วยสมการที่ (2.2)

$$x_i(t+1) = x_i(t) + v_i(t+1) \quad (2.2)$$

โดยกำหนดให้

$x_i(t)$	คือ ตำแหน่งปัจจุบันของอนุภาค $i$
$x_i(t + 1)$	คือ ตำแหน่งใหม่ที่อนุภาคจะเคลื่อนที่ไป
$v_i(t + 1)$	คือ ความเร็วใหม่ที่คำนวณได้


7. การหยุดทำการ (Terminate Condition) กระบวนการหยุดการทำงาน จะมีเงื่อนไขการหยุดทำงานอยู่สองวิธี คือ

- 1) หยุดเมื่อจำนวนรอบการทำงานครบตามจำนวนที่กำหนด
- 2) หยุดเมื่อได้ค้นพบค่าคำตอบที่ดีที่สุด

## 2.2 Local Optima และ Global Optima

Local Optima [5] คือ จุดบนค่าของขอบเขตของปัญหา ซึ่งเป็นค่าต่ำสุดหรือสูงสุดในบริเวณใดบริเวณหนึ่งของโดเมน โดย Local Optima อาจจะมีได้หลายจุดต่อหนึ่งปัญหา ดังแสดงในรูปที่ 2.2

Global Optima [6] คือ จุดบนค่าของขอบเขตของปัญหา ซึ่งเป็นค่าต่ำสุดหรือสูงสุดของตลอดทั้งโดเมน โดย Global Optima จะมีได้ไม่เกินหนึ่งจุดต่อหนึ่งปัญหา ดังแสดงในรูปที่ 2.2



รูปที่ 2.2 แสดงตัวอย่าง Local Optima และ Global Optima

## 2.3 ปัญหาการหาจุดที่ดีที่สุด (Optimization Problem)

ปัญหาการหาจุดที่ดีที่สุด คือ ปัญหาที่เกิดจากการต้องการหาค่าคำตอบที่ดีที่สุดจากคำตอบที่เป็นไปได้ทั้งหมด ซึ่งในวิทยานิพนธ์ฉบับนี้ได้นำฟังก์ชันมาตรฐาน (Benchmark Test Function) [7, 8] มาใช้ โดยแต่ละปัญหาสามารถแสดงในรูปของฟังก์ชันทางคณิตศาสตร์ เช่น ฟังก์ชัน Rosenbrock ดังรูปที่ 2.3 ซึ่งแทนด้วยฟังก์ชันทางคณิตศาสตร์ดังสมการที่ 2.3


$$f(x) = \sum_{i=1}^n [100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2] \quad (2.3)$$

โดยกำหนดให้

$x$  คือ ค่าตอบของปัญหาที่มีมิติ  $i$

$n$  คือ จำนวนมิติของปัญหา

$x_i$  คือ ค่าในมิติที่  $i$  ของ  $x$  ที่มีค่าอยู่ในช่วง  $[-2.048, 2.048]$




รูปที่ 2.3 ฟังก์ชัน Rosenbrock

โดย  $f(x)$  คือฟังก์ชันเป้าหมายที่นำมาใช้เป็นตัวแทนของปัญหาการหาจุดที่ดีที่สุด โดยจากสมการที่ (2.3) ฟังก์ชัน Rosenbrock เป็นฟังก์ชันเป้าหมาย ซึ่งเป้าหมายของปัญหาก็คือ การหาค่า  $x$  ที่ทำให้  $f(x)$  มีค่าน้อยที่สุด

### 2.3.1 ปัญหาการหาจุดที่ดีที่สุดสามารถแบ่งได้ 2 ลักษณะ คือ


1. ปัญหายุนิโมดอล (Unimodal Problem) คือ ปัญหาการหาจุดที่ดีที่สุดในช่วงขอบเขต โดยมี Local Optima และ Global Optima เป็นจุดเดียวกัน ดังรูปที่ 2.4



รูปที่ 2.4 ตัวอย่างปัญหา Unimodal Problem

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2. ปัญหา Multimodal Problem (Multi-modal Problem) คือ ปัญหาการหาจุดที่ดีที่สุด (Global Optima) เพียงจุดเดียว แต่มี Local Optima หลายจุด ดังรูปที่ 2.5



รูปที่ 2.5 ตัวอย่างปัญหา Multi-modal Problem

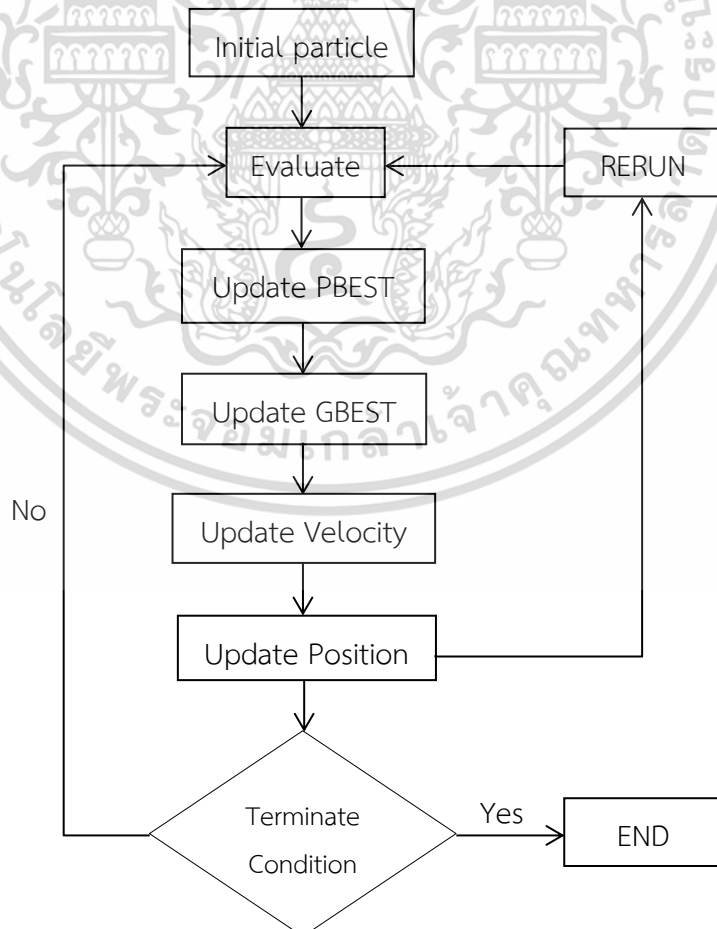


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

# บทที่ 3 งานวิจัยที่เกี่ยวข้อง

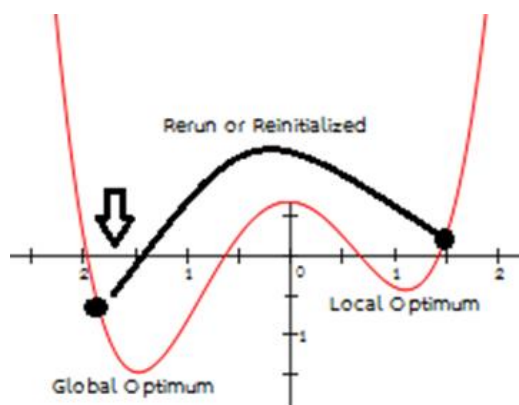
## 3.1 การเพิ่มประสิทธิภาพ PSO ด้วยการเริ่มทำงานใหม่ (Modified Particle Swarm Optimization with Rerun, PSORE)

PSO มีพฤติกรรมในการลู่เข้าหาคำตอบที่ดีที่สุด (Local Optima) เมื่อ PSO ลู่เข้าหาคำตอบที่ดีที่สุดแล้วจะไม่สามารถหาตำแหน่งที่ดีกว่าตำแหน่งเดิมได้ โดยที่อนุภาคแต่ละตัวจะทำการเคลื่อนที่อยู่รอบ ๆ ตำแหน่งนั้น ในกรณีที่ตำแหน่งนั้นไม่ใช่จุดที่มีค่าคำตอบที่ดีที่สุด PSO จะไม่สามารถหาตำแหน่งที่ดีกว่าได้ถึงแม้จะมีการเคลื่อนที่อยู่ ดังนั้นจึงจำเป็นต้องมีการทำการเริ่มทำงานใหม่ โดยเปลี่ยนตำแหน่งแต่ละอนุภาคจากตำแหน่งเดิม เพื่อให้มีโอกาสที่จะหาตำแหน่งที่ดีกว่าเดิมได้ ในวิธีการนี้จะใช้การสุ่มตำแหน่งอนุภาคใหม่และเริ่มการทำงานใหม่ โดยหวังว่า PSO จะได้คำตอบที่ต่างออกไปจากเดิมและมีโอกาสดีขึ้น นอกจากนี้ทุกครั้งที่เริ่มทำงานใหม่จะมีการรีเซ็ตค่า GBEST เพื่อให้อนุภาคหลุดออกจากตำแหน่ง GBEST เดิม



รูปที่ 3.1 แสดงผังงานวิธี PSORE


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้ในเพื่อการศึกษาเท่านั้น เมื่อผู้เขาดให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 3.2 ตัวอย่างการทำการเริ่มต้นใหม่

3.2 ขั้นตอนวิธีการปรับปรุงการหาค่าความเหมาะสมที่ดีที่สุดแบบกลุ่มอนุภาคแบบหลากหลายกลุ่มโดยใช้การกระจายตำแหน่งของอนุภาคเมื่อติดในจุดสูงสุดสัมพัทธ์ ร่วมกับการเปลี่ยนตำแหน่งของอนุภาคที่ดีที่สุดของกลุ่ม (Improving Multi-Swarm by Slightly Mutation Particle and GBEST of Stuck Swarm Along with Randomly Selecting GBEST of other Swarm, MPSOSM)

วิธี MPSOSM [9] จะใช้อนุภาคหลายกลุ่มในการค้นหาคำตอบที่ดีที่สุด โดยเริ่มจากการที่แต่ละกลุ่มของอนุภาคภายใน Search Space ทำการเคลื่อนที่เหมือนกับ PSO โดยอนุภาคของแต่ละกลุ่มจะเคลื่อนที่เข้าหาตำแหน่งที่ดีที่สุดของกลุ่มตัวเองจนติดใน Local Optima จากนั้นนำเอาอนุภาคที่ติดใน Local Optima มาทำการกระจายตำแหน่งของอนุภาคและสุ่มใช้ GBEST ของกลุ่มข้างเคียงแทน GBEST เดิมในการเริ่มทำงานใหม่ หลังจากนั้นเมื่ออนุภาคทำการเปลี่ยน GBEST และทำงานต่อไปจนทุกกลุ่มมีโอกาสที่จะติดใน Local Optima เดียวกัน ให้เลือกทำการกระจายตำแหน่งของอนุภาคแต่ละตัวของทุกกลุ่มและทำการกลายพันธุ์ (Mutation) GBEST ใหม่ที่เกิดจากตำแหน่งที่ดีที่สุดของอนุภาคในแต่ละกลุ่มที่เกิดจากการกลายพันธุ์ จากนั้นแต่ละกลุ่มก็เคลื่อนที่ไปหาคำตอบใหม่ โดยขึ้นกับตำแหน่งของอนุภาคที่ได้รับการกลายพันธุ์และ GBEST ของแต่ละกลุ่มต่อไป



รูปที่ 3.3 ตัวอย่างการสุ่มสลับ GBEST ระหว่างอนุภาค 2 กลุ่ม

### 3.3 การปรับปรุงการหาค่าเหมาะสมที่สุดแบบกลุ่มอนุภาคโดยใช้การเรียนรู้แบบเพิ่มและจุดเซนทรอยด์ของตำแหน่งที่ดีที่สุด (Improving Particle Swarm Optimization by Using Incremental Attribute Learning and Centroid of Particle's Best Positions, IAC-PSO)


ในงานวิจัย IAC-PSO [10] จะปรับการทำงานของ PSO โดยมีหลักการว่าจะทำการค้นหาในทีละมิติจากตำแหน่ง GBEST เดิม (ได้จากการทำงานของ PSO ตามปกติไปได้ระยะเวลาหนึ่ง) โดยค่า GBEST ของมิติใหม่ที่มีการค้นหาค่าได้ดีแล้วจะถูกกำหนดขอบเขตให้ค้นหาตำแหน่งใกล้เคียงเดิม ส่วนในมิติใหม่ที่กำลังจะค้นหาจะมีขอบเขตการค้นหาเท่ากับ Search Space เมื่อค้นหาค่าตอบในมิตินี้ได้แล้วก็จะทำการกำหนดขอบเขตของมิตินี้ให้แคบลงและทำการค้นหาต่อไปในมิติถัดไปจนกว่าจะครบทุกมิติ โดยในการค้นหา 1 มิตินั้น จะมีการปรับปรุงตำแหน่งของแต่ละอนุภาคเพียงแค่ 1 ครั้ง หลังจากนั้นจะทำการแบ่งอนุภาคออกเป็น 2 กลุ่ม โดยกลุ่มแรกจะมีการกำหนดขอบเขตในการค้นหา แต่อีกกลุ่มหนึ่งจะทำการเคลื่อนที่ตามปกติเหมือน PSO นอกจากนี้ในทุกกรอบของการเคลื่อนที่จะทำการเก็บค่าตำแหน่งเดิมของ GBEST และทำการคำนวณค่าเฉลี่ยของ GBEST ถ้าค่าที่ได้ดีขึ้นจะนำมาแทนที่ค่า GBEST เดิม เพื่อเป็นการหลีกเลี่ยงการติด Local Optima จากนั้นจะทำการเริ่มทำงานใหม่อีก 7 ครั้ง โดยแต่ละครั้งจะเริ่ม ณ ตำแหน่ง GBEST เดิม ที่ได้จากการรัน PSO ตามปกติไปได้ระยะเวลาหนึ่ง (ตามจำนวนรอบที่กำหนดไว้)

#### 3.3.1 IAC-PSO มีขั้นตอนของการทำงานดังนี้

1. การกำหนดจุดเริ่มต้น จะกำหนดให้ใช้ Conventional PSO ในช่วงแรกของการทำงานเพื่อหาจุดเริ่มต้น โดยจะค้นหาประมาณ 7,500-15,000 รอบ ซึ่งจะใช้จุดเริ่มต้นเหมือนกันในทุก ๆ Generation
2. การยืดหยุ่นจุดเริ่มต้นของอนุภาค คือการค้นหาจุดเริ่มต้นในแต่ละมิติจะมีการยืดหยุ่นให้อนุภาคสามารถเคลื่อนที่ได้ในระยะแคบ ๆ ใกล้เคียงกับ GBEST ที่เคยค้นหาในมิติก่อนหน้านี้ได้
3. การแบ่งกลุ่มอนุภาค อนุภาคจะถูกแบ่งออกเป็น 2 กลุ่ม ด้วยการใช้หลักความน่าจะเป็นจำนวนหนึ่งสำหรับการแบ่งกลุ่ม โดยเมื่อเริ่มทำงานอนุภาคกลุ่มแรกจะถูกกำหนดตำแหน่งเริ่มต้นด้วยค่า ๆ หนึ่งซึ่งอยู่ในช่วง  $[0, 1]$  โดยอนุภาคที่ทำการสุ่มหากได้ค่าที่กำหนดจะถูกจัดอยู่ในกลุ่มแรก และอนุภาคที่เหลือจะถูกจัดอยู่ในกลุ่มที่สอง เมื่ออนุภาคกลุ่มหนึ่งกลุ่มใดค้นหาจุด GBEST ใหม่ได้ อนุภาคทั้ง 2 กลุ่มจะช่วยกันหาค่าตอบภายในบริเวณนั้นเป็นช่วงแคบ ๆ
4. การคำนวณจุดเซนทรอยด์ โดยส่วนใหญ่แล้วค่า GBEST ที่ได้มักจะได้ค่าใกล้เคียงกับ Local Optima แล้ว IAC-PSO จึงได้กำหนดให้มีการหาจุดเซนทรอยด์จากจุด GBEST ล่าสุด เพื่อช่วยให้มีโอกาสค้นหาค่าคำตอบที่ดีขึ้นกว่า GBEST ปัจจุบัน ถ้าจุดเซนทรอยด์ที่ได้ไม่ดีกว่าค่า GBEST การทำงานก็จะยังใช้ค่า GBEST เดิมต่อไป

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

5. การวนรอบการทำงาน ในวิธี IAC-PSO ได้ใช้กลยุทธ์การเรียนรู้แบบหลาย ๆ รอบ เพื่อจะช่วยให้สามารถค้นหาค่าที่ดีที่สุดได้ดียิ่งขึ้น แต่จะทำการรีเซ็ตค่าที่ได้ก่อนหน้าทั้งหมดเพื่อเพิ่มโอกาสในการค้นหาที่ดีกว่าในรอบถัดไป



รูปที่ 3.4 แสดงผังงานวิธี IAC-PSO

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## บทที่ 4

### งานที่นำเสนอ

การแก้ปัญหาการติดใน Local Optima ที่เกิดขึ้นกับ PSO นักวิจัยได้นำสมการการกระจายตำแหน่งของอนุภาคหรือการกลายพันธุ์แบบต่าง ๆ มาใช้ในการลดปัญหาการติดใน Local Optima ของ PSO [11] นักวิจัยบางส่วนได้แบ่งกลุ่มอนุภาคออกเป็นหลาย ๆ กลุ่มเพื่อช่วยกันค้นหาใน Search Space แต่กระบวนการเหล่านั้นก็ยังคงติดอยู่ใน Local Optima ดังนั้นจึงเป็นการเสียเวลาที่จะปล่อยให้อนุภาคดำเนินการค้นหาต่อไป และจำเป็นต้องให้อนุภาคมีการเริ่มทำงานใหม่ ซึ่งจะต้องเปลี่ยนตำแหน่งอนุภาคจากตำแหน่งเดิม เพื่อป้องกันการติดใน Local Optima ซึ่งมักจะพบปัญหาว่า ถ้าเปลี่ยนตำแหน่งอนุภาคด้วยการสุ่มใน Search Space ก็จะเหมือนการเริ่มทำงานใหม่อีกครั้งในตำแหน่งที่เปลี่ยนไป แต่ไม่สามารถป้องกันไม่ให้อนุภาคกลับไปติดใน Local Optima ได้อีก จากการสังเกตตำแหน่ง Local Optima โดยมากมักจะตรงกับจุด Optima มีเพียงบางมิติที่มีค่าแตกต่างจากจุด Local Optima ที่ติดอยู่ในวิธานิพนธ์ฉบับนี้จึงเลือกที่จะปรับตำแหน่งอนุภาคจากจุดที่ติดอยู่ใน Local Optima เพียงเล็กน้อย โดยเปลี่ยนจากตำแหน่งเดิมไม่เกิน 10 เปอร์เซ็นต์ และจำนวนมิติที่เปลี่ยนไม่เกิน 20 เปอร์เซ็นต์ของจำนวนมิติทั้งหมด มิติที่เหลือให้มีค่าเท่ากับตอนที่ติดอยู่ใน Local Optima เนื่องจากถ้ามีการเปลี่ยนตำแหน่งในระยะที่มากและในจำนวนหลายมิติมากเกินไป จะทำให้อนุภาคกระโดดออกไปบริเวณกว้างและอาจกลับมาติดใน Local Optima เดิม หรือหาตำแหน่ง Global Optima ที่อยู่ใกล้เคียงไม่เจอ ในทางกลับกันถ้ากำหนดให้การกลายพันธุ์น้อยเกินไป มิติที่ผิด จะไม่มีการค้นหา เนื่องจากอนุภาคส่วนใหญ่มีตำแหน่งเดียวกับ Local Optima เดิม และอนุภาคจะเคลื่อนที่อยู่ใกล้บริเวณเดิมจนเจอ Local Optima เดิมอีกครั้ง

นอกจากนี้การแก้ปัญหาการติดใน Local Optima โดยวิธีการกลายพันธุ์เพียงอย่างเดียวไม่พอที่จะทำให้อนุภาคค้นหากว้างขึ้นได้ จึงมีการเพิ่มวิธีกำหนดค่า GBEST จากตำแหน่งของอนุภาคที่ดีที่สุดหลังการกลายพันธุ์มาทำการกลายพันธุ์อีกครั้งหนึ่ง เพื่อให้อนุภาคเคลื่อนที่ไปค้นหาค่าตอบในบริเวณใหม่ที่หลุดจากจุด Local Optima เดิม จากแนวทางเหล่านี้จึงได้เกิดวิธานิพนธ์ฉบับนี้ขึ้นเพื่อแก้ปัญหาดังกล่าว

#### 4.1 การแก้ปัญหาการติดใน Local Optima ของ PSO โดยประยุกต์ใช้การเริ่มทำงานใหม่

การแก้ปัญหาการติด Local Optima มีได้หลายวิธี เช่น ให้มีการค้นหาในแนวกว้างเพื่อให้ติด Local Optima ช้า หรือเพิ่มการค้นหาให้มากขึ้น แต่ไม่มีวิธีใดจะยืนยันได้ว่าจุด Optima ที่เจอเป็น Global Optima ดังนั้นในงานวิธานิพนธ์ฉบับนี้จะไม่ได้แก้ไขวิธีการค้นหาแบบเดิม ๆ ของ PSO คือ

จะยอมให้ PSO ค้นหาตามปกติจนติดอยู่ใน Local Optima จากนั้นจะหาวิธีเปลี่ยนตำแหน่งอนุภาค  
เอกสารนี้เป็นเอกสารลิขสิทธิ์สงวนไว้สำหรับใช้ในงานวิจัย การศึกษา เท่านั้น ไม่อนุญาตให้เผยแพร่โดยไม่ได้รับอนุญาต  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

และเริ่มการค้นหาใหม่ โดยพยายามหลีกเลี่ยงที่จะกลับไปติดอยู่ที่ Local Optima เดิม เมื่ออนุภาคติดใน Local Optima ตำแหน่งของอนุภาคทั้งหมด รวมทั้ง PBEST และ GBEST จะอยู่ที่ตำแหน่งเดียวกับตำแหน่ง Local Optima ในกรณีที่บังคับให้มีการค้นหาที่ไม่กลับไปสู่ Local Optima เดิมนั้น สามารถทำได้โดยการเปลี่ยนตำแหน่งของอนุภาค เปลี่ยนตำแหน่ง PBEST และ GBEST ออกจากตำแหน่ง Local Optima เดิม การเปลี่ยนตำแหน่งอนุภาคแต่เพียงอย่างเดียวไม่สามารถที่จะเหนี่ยวนำให้อนุภาคเคลื่อนที่ออกจากตำแหน่ง Local Optima เดิมได้ เนื่องจาก PBEST และ GBEST จะดึงอนุภาคกลับไปสู่ตำแหน่งเดิม ดังนั้นจึงมีการเพิ่มขึ้นขั้นตอนการทำงานหลังจากการติดใน Local Optima ของ PSO โดยการเปลี่ยนตำแหน่งของอนุภาค PBEST และ GBEST ทำให้อนุภาคจะกระจายตัวออกจากกันหลังจากทำการเริ่มทำงานใหม่ อนุภาคจะดำเนินการค้นหาด้วยสมการการเคลื่อนที่แบบ PSO และเคลื่อนที่กลับเข้ามาวมกันที่ GBEST ใหม่ เพียงแต่ระหว่างทางที่เคลื่อนที่กลับเข้ามาหา GBEST ใหม่ อาจเจอตำแหน่งที่ดีกว่า GBEST ที่ถูกเปลี่ยนไป จึงทำให้สามารถหลุดออกจากตำแหน่ง Local Optima เดิมได้ ตำแหน่งนี้อาจจะมีค่าที่ไม่ดีกว่าตำแหน่ง Local Optima แต่อาจนำไปสู่ตำแหน่ง Local Optima อื่นที่ดีขึ้นได้ หลังจากการติด Local Optima จุดถัดไป และมีการเริ่มทำงานใหม่ไปเรื่อย ๆ

#### 4.2 การเปลี่ยนตำแหน่งอนุภาคโดยใช้วิธีการกลายพันธุ์

การนำการกลายพันธุ์มาใช้ในการลดปัญหาการติดใน Local Optima ของ PSO นั้น ถ้ากลายพันธุ์ตำแหน่งอนุภาคด้วยการสุ่มใน Search Space แบบเดิม จะไม่สามารถป้องกันไม่ให้อนุภาคกลับไปติดใน Local Optima ได้ จากการสังเกตตำแหน่ง Local Optima โดยมากมักจะตรงกับจุด Optima มีเพียงบางมิติที่มีค่าแตกต่างจากจุด Local Optima วิทยานิพนธ์ฉบับนี้จึงได้ทำการทดลองปรับค่าตำแหน่งของอนุภาคเมื่อมีการติดอยู่ใน Local Optima โดยใช้สมการในการปรับค่า เช่นเดียวกับที่ใช้ในการกลายพันธุ์ของ Genetic Algorithm ตามสมการที่ (4.1)

$$x_{id} = x_{id} \pm (x_{id} \times R) \quad (4.1)$$

โดย  $x_i$  แทนตำแหน่งของอนุภาคตัวที่  $i$  มิติที่  $d$  ค่าสุ่มที่ได้จากฟังก์ชัน  $R$  มีค่าอยู่ในช่วง  $[0, 1]$  ถ้าสุ่มค่า  $R$  เป็น 1 ค่าที่ได้จะเป็น 0 ทำให้สมการในการปรับค่านี้นี้ไม่เหมาะสมที่จะนำมาใช้ ดังนั้นจึงปรับเปลี่ยนสมการการกลายพันธุ์เป็นสมการที่ (4.2)

$$x_i = \pm(x_i \times (0.9 + (0.1 \times R))) \quad (4.2)$$

จากสมการที่ (4.2) ค่าใหม่ที่ได้จะอยู่ในช่วง  $[0.9, 1]$  ของค่าเดิม ขึ้นกับค่าที่สุ่มได้เป็น 0 และ 1 ตามลำดับ โดยอาจจะมีโอกาสในการกลับเครื่องหมายทั้งบวกและลบ 50 เปอร์เซ็นต์ นอกจากนี้ กรณีที่ตำแหน่งของคำตอบไม่ได้อยู่ที่ตำแหน่ง 0, ..., 0 โอกาสที่การค้นหาคำตอบจะได้ตำแหน่งที่ใกล้เคียงกับคำตอบมีมากขึ้น นอกจากนี้ได้ลองทำการทดลองเปลี่ยนค่า 0.9 และ 0.1 เป็น 0.85 และ 0.3 ซึ่งจะทำให้ช่วงการค้นหาอยู่ในช่วง  $[0.85, 1.15]$  แต่สำหรับชุดฟังก์ชันที่ใช้ในการทดลองมีผลการทดลองที่แย่ง จึงเลือกใช้ค่า 0.9 และ 0.1 แต่ถ้าเป็นฟังก์ชันอย่างอื่นจำเป็นที่จะต้องมีการลองค่าอื่น โดยช่วงที่ทำการค้นหาควรจะมีทั้งการเพิ่มขึ้นและลดลง

นอกจากการกำหนดขอบเขตให้กับการปรับปรุงตำแหน่งโดยเทียบกับค่าของตำแหน่งเดิมแล้ว จำนวนมิติของตำแหน่งที่ต้องปรับก็เป็นอีกปัจจัยหนึ่งที่จะทำให้ค่าที่ปรับดีขึ้น ซึ่งส่วนใหญ่หลังจากที่อนุภาคติดอยู่ใน Local Optima พบว่ามีแค่บางมิติเท่านั้นที่ไม่พบคำตอบ ดังนั้นในการเปลี่ยนตำแหน่งของอนุภาคในทุกมิตินั้น เท่ากับเป็นการเริ่มต้นใหม่ทั้งหมดทำให้เสียเวลามาก และอาจจะทำให้อนุภาคไปติดอยู่ใน Local Optima อื่นอีก โดยวิธานิพนธ์ฉบับนี้จะทำการกระจายตำแหน่งของอนุภาคแต่ละตัวโดยการสุ่มเปลี่ยนค่าตำแหน่งของอนุภาคในบางมิติจากตำแหน่งเดิมเพียง 20 เปอร์เซ็นต์ของมิติทั้งหมดของอนุภาค เพื่อให้อนุภาคมีโอกาสหาคำตอบที่มีค่าใกล้เคียง Local Optima เดิมได้ โดยไม่กลับไปติดใน Local Optima เดิมอีก

### 4.3 การเปลี่ยนตำแหน่ง GBEST โดยใช้วิธีการกลายพันธุ์

เพื่อให้อนุภาคมีโอกาสหลุดออกจาก Local Optima และมีโอกาสเคลื่อนที่ออกไปค้นหาในพื้นที่ใหม่ได้ การเปลี่ยนตำแหน่งของอนุภาคเพียงอย่างเดียวยังไม่เพียงพอที่จะทำให้ค้นหาคำตอบที่ใกล้ Local Optima เดิมเจอ ซึ่งโดยมากมักจะกลับไปติดใน Local Optima เดิม โดยเฉพาะถ้ามีการเปลี่ยนจำนวนมิติเพียงเล็กน้อย ดังนั้นจำเป็นจะต้องใช้ GBEST เป็นตัวช่วยด้วย เมื่อมีการเริ่มทำงานใหม่อนุภาคทั้งหมดจะเปลี่ยนตำแหน่งจากเดิมประมาณ 20 เปอร์เซ็นต์ของจำนวนมิติทั้งหมด โดยจะใช้การสุ่มในแต่ละมิติว่าควรจะเปลี่ยนมิติใด ในกรณีนี้ถ้าค่าที่สุ่มได้มีค่าน้อยกว่า 0.2 มิติ นั้นจะทำการเปลี่ยน ในกรณีที่จำนวนอนุภาคมีน้อย มิติที่มีค่าผิวดอาจไม่โดนสุ่มเปลี่ยนเลย เพื่อให้โอกาสมิติที่มีค่าผิวดเปลี่ยนค่าจากค่าเดิมมากขึ้น จึงได้ทำการสุ่มเปลี่ยนค่าของ GBEST เพื่อที่จะให้โอกาสมิติที่ผิวดมีโอกาสสุ่มเจอและมีการเปลี่ยนค่า โดยการเปลี่ยนค่าจะใช้สมการที่ (4.3) เช่นเดียวกับการเปลี่ยนตำแหน่งของอนุภาค (สมการที่ (4.2)) แต่จะเพิ่มจำนวนมิติที่เปลี่ยนให้เป็น 30 เปอร์เซ็นต์

$$g = \pm(g \times (0.9 + (0.1 \times R))) \quad (4.3)$$

สำหรับค่า GBEST ที่ใช้ตอนเริ่มทำงานใหม่มีทางเลือกได้หลายค่า เช่น

1. ค่า GBEST ที่ได้จากตำแหน่งของอนุภาคที่ดีที่สุดหลังการกลายพันธุ์อนุภาคตามสมการที่

(4.2) (มีการรีเซ็ตค่า PBEST แต่ไม่มีการรีเซ็ตค่า GBEST, GBEST 1)

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2. ค่า GBEST ที่ได้จากตำแหน่งของอนุภาคที่ดีที่สุดหลังการกลายพันธุ์อนุภาคตามสมการที่ (4.2) และหลังการกลายพันธุ์ GBEST ตามสมการที่ (4.3) (มีการรีเซ็ตค่า PBEST แต่ไม่มีการรีเซ็ตค่า GBEST, GBEST 2)

3. ค่า GBEST ที่ได้จากตำแหน่งของอนุภาคที่ดีที่สุดหลังการกลายพันธุ์อนุภาคตามสมการที่ (4.2) (มีการรีเซ็ตค่า PBEST และ GBEST, GBEST 3)

4. ค่า GBEST ที่ได้จากตำแหน่งของอนุภาคที่ดีที่สุดหลังการกลายพันธุ์อนุภาคตามสมการที่ (4.2) และหลังการกลายพันธุ์ GBEST ตามสมการที่ (4.3) (มีการรีเซ็ตค่า PBEST และ GBEST, MPG-PSO)

โดยถ้าใช้ค่า GBEST เดิมในข้อ 1 นั้น ถ้าอนุภาคมีการกลายพันธุ์มาก จะอาศัยโอกาสที่อนุภาคเคลื่อนที่ไปหา GBEST ถ้าเจอค่าที่ดีกว่า GBEST ก็จะหลุดจาก Local Optima ได้ แต่เนื่องจากการหาตำแหน่งที่ดีกว่า Local Optima เป็นไปได้ยาก โดยมากอนุภาคจะเคลื่อนที่เข้าสู่ Local Optima เดิม

GBEST ในข้อที่ 2 ค่า GBEST คือตำแหน่งที่ดีที่สุดของอนุภาคที่มีการกลายพันธุ์ และนำมากลายพันธุ์ GBEST อีกรอบหนึ่ง อนุภาคตัวอื่น ๆ จะเคลื่อนเข้าหาอนุภาคตัวนี้ ถ้าเจอตัวที่ดีกว่าก็จะมี การตั้งค่า GBEST ใหม่ ซึ่งอาจไม่ดีกว่า GBEST เดิม ณ จุดที่ติด Local Optima แต่อย่างน้อยก็ยังทำให้มีการค้นหาเพิ่มขึ้น และถ้ามีการเริ่มทำงานใหม่หลาย ๆ รอบ ก็อาจจะทำให้หลุดจาก Local Optima และเจอค่าใหม่ที่ดีขึ้นได้

GBEST ในข้อที่ 3 ในข้อนี้ได้มาจากตำแหน่งที่ดีที่สุดของอนุภาคที่มีการกลายพันธุ์อนุภาค หลังจากมีการรีเซ็ตค่า PBEST และ GBEST แล้ว เมื่อนำ GBEST ใหม่ มาตั้งค่าเป็น GBEST ค่า GBEST ใหม่ก็จะชักจูงให้อนุภาคต่าง ๆ เคลื่อนที่ออกจาก Local Optima เดิมได้กว้างขึ้น

GBEST ในข้อที่ 4 GBEST ในข้อนี้ได้มาจากตำแหน่งที่ดีที่สุดของอนุภาคที่มีการกลายพันธุ์อนุภาคหลังจากทำการรีเซ็ต PBEST และ GBEST แล้ว แล้วนำมากลายพันธุ์ GBEST อีกรอบหนึ่ง ซึ่ง โดยมากจะมีค่าที่ดีขึ้น เมื่อนำ GBEST ใหม่ มาตั้งค่าเป็น GBEST ค่า GBEST ใหม่ก็จะชักจูงให้อนุภาคต่าง ๆ เคลื่อนที่ออกจาก Local Optima เดิมได้กว้างขึ้น

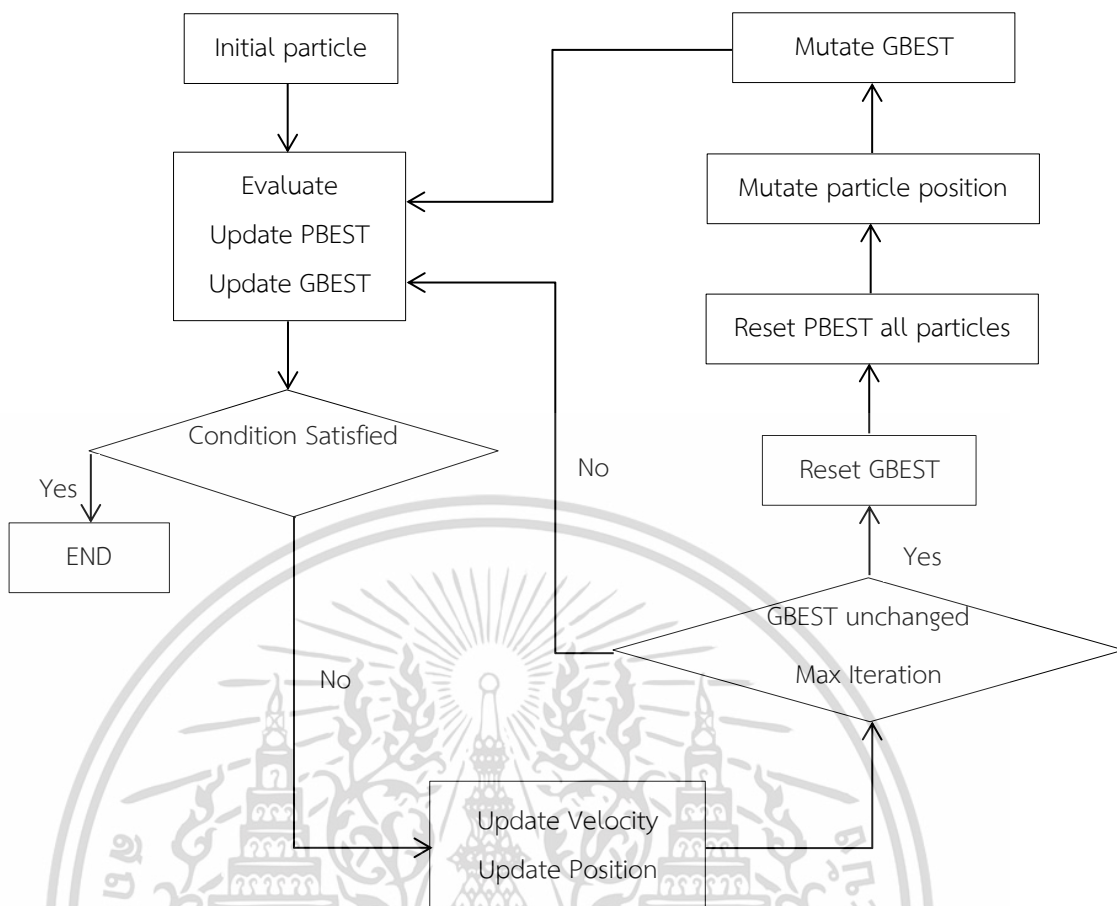
วิทยานิพนธ์ฉบับนี้ได้ทำการทดลองเปรียบเทียบ GBEST ในข้อที่ 2, 3 และ 4 เนื่องจากจะได้ GBEST หลากหลายรูปแบบ โดยเฉพาะในข้อที่ 4 จะได้ GBEST ที่ห่างจาก GBEST ณ ตำแหน่ง Local Optima มากที่สุด โดยผลการทดลองจะอยู่ในบทที่ 5

#### 4.4 การเริ่มทำงานใหม่โดยใช้การกลายพันธุ์ของตำแหน่งอนุภาคสุดท้ายและตำแหน่งที่ดีที่สุดสำหรับวิธีการหาค่าเหมาะสมที่สุดแบบอนุภาคกลุ่ม (Rerun of Particle Swarm Optimization using mutation of Particle Trap position and GBEST, MPG-PSO)

วิธีที่นำเสนอเริ่มต้นการทำงานเหมือน PSO ปกติ (ตามสมการที่ (2.1) และ (2.2)) ซึ่งอนุภาคจะเคลื่อนที่หาตำแหน่งที่ดีที่สุดภายใน Search Space แต่จะแตกต่างตรงที่เมื่ออนุภาคติดอยู่ใน Local Optima นั่นคือ ค่า GBEST ไม่ดีขึ้นหลังจาก PSO เคลื่อนที่เกินจำนวนรอบการรันที่กำหนด จะถือว่าติดอยู่ใน Local Optima และจะใช้การเริ่มทำงานใหม่โดยมีการกลายพันธุ์ตำแหน่งของอนุภาคด้วยสมการที่ (4.2) เปลี่ยนค่า PBEST และ GBEST และเริ่มการทำงานของ PSO ต่อไป จนกว่าจะติดใน Local Optima ครั้งถัดไป การเริ่มทำงานใหม่นี้เพื่อให้อนุภาคมีโอกาสหลุดออกจาก Local Optima ให้มีโอกาสเคลื่อนที่ออกไปค้นหาในพื้นที่ใหม่ได้ โดยมีขั้นตอนดังรูปที่ (4.1) และรูปที่ (4.2)

1. Initial particles position();
2. While (total number of iteration < MAX\_iteration):
3.     Update particles positions X, PBEST, GBEST using normal PSO
4.     If GBEST unchanged for Max\_iterations:
5.         reset GBEST
6.         reset PBEST of all particles
7.         randomly mutate all particle positions by EQ[4.2] for 20% of its dimensions
8.         and update PBEST and GBEST
9.         Set GBest to randomly mutate GBest EQ[4.3] for 30% of all dimension

รูปที่ 4.1 รหัสจำลองแสดงการทำงานของ MPG-PSO



รูปที่ 4.2 แสดงผังงานวิธี MPG-PSO

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## บทที่ 5

### ผลการทดลอง

ในบทที่ 5 นี้จะกล่าวถึงการทดลองเพื่อเปรียบเทียบผลลัพธ์จากการค้นหาจุดต่ำสุดของฟังก์ชันมาตรฐาน (Benchmark Test Functions) ทั้งหมด 26 ฟังก์ชัน ตามตารางที่ 5.2 โดยมีทั้งฟังก์ชันแบบ Unimodal [12] และฟังก์ชันแบบ Multimodal [13] การทดลองได้มีการใช้ขั้นตอนวิธีต่าง ๆ ดังนี้

1. ขั้นตอนวิธีการหาค่าเหมาะสมที่สุดแบบอนุภาคกลุ่ม (Particle Swarm Optimization, PSO [1])
2. การเพิ่มประสิทธิภาพ PSO ด้วยการเริ่มทำงานใหม่ (Modified Particle Swarm Optimization with Rerun, PSORE)
3. ขั้นตอนวิธีการปรับปรุงการหาค่าความเหมาะสมที่ดีที่สุดแบบกลุ่มอนุภาคแบบหลากหลายกลุ่มโดยใช้การกระจายตำแหน่งของอนุภาคเมื่อติดในจุดสูงสุดสัมพันธ์ร่วมกับการเปลี่ยนตำแหน่งของอนุภาคที่ดีที่สุดของกลุ่ม (Improving Multi-Swarm by Slightly Mutation Particle and GBEST of Stuck Swarm Along with Randomly Selecting GBEST of other Swarm, MPSOSM [9])
4. การเพิ่มประสิทธิภาพ PSO ด้วยการเริ่มการทำงานใหม่และการกลายพันธุ์อนุภาคเมื่ออนุภาคติดอยู่ใน Local Optima (GBEST 1)
5. การเพิ่มประสิทธิภาพ PSO ด้วยการเริ่มทำงานใหม่และการกลายพันธุ์อนุภาคและ GBEST เมื่ออนุภาคติดอยู่ใน Local Optima (GBEST 2)
6. การเพิ่มประสิทธิภาพ PSO ด้วยการเริ่มทำงานใหม่และการกลายพันธุ์อนุภาค โดยมีการรีเซ็ตค่า GBEST เมื่ออนุภาคติดอยู่ใน Local Optima (GBEST 3)
7. วิธีนี้คือวิธีที่นำเสนอในวิทยานิพนธ์ โดยมีการทำงานใกล้เคียงกับในข้อที่ 5 (GBEST 3) มีการเริ่มทำงานใหม่โดยใช้การกลายพันธุ์ของตำแหน่งอนุภาคเช่นเดียวกับ GBEST 3 แต่ข้อแตกต่างคือจะนำ GBEST มากลายพันธุ์อีกครั้งหนึ่ง (Rerun of Particle Swarm Optimization using mutation of Particle Trap position and GBEST, MPG-PSO)
8. การปรับปรุงการหาค่าเหมาะสมที่สุดแบบกลุ่มอนุภาคโดยใช้การเรียนรู้แบบเพิ่มและจุดเซนทรอยด์ของตำแหน่งที่ดีที่สุด (Improving Particle Swarm Optimization by Using Incremental Attribute Learning and Centroid of Particle's Best Position, IAC-PSO [10])

GBEST 1, GBEST 2, GBEST 3 และ MPG-PSO มีหลักการการทำงานที่เหมือนกันในการใช้การกลายพันธุ์อนุภาคและตำแหน่งของ GBEST ในการดึงอนุภาคออกจากตำแหน่ง Local Optima โดยมีรายละเอียดดังนี้

1. ขั้นตอนการทำงานของ GBEST 1 ดังรูปที่ 5.1



รูปที่ 5.1 การทำงานของ GBEST 1

เมื่ออนุภาคติดอยู่ใน Local Optima ดังรูปที่ 5.1(ซ้าย) จะทำการกลายพันธุ์อนุภาคเพียงเล็กน้อย ดังรูปที่ 5.1(ขวา) แต่ยังคงใช้ค่า GBEST เดิม ณ ตำแหน่งที่ติด Local Optima (ไม่มีการรีเซ็ตค่า GBEST แต่มีการรีเซ็ตค่า PBEST หลังติด Local Optima) โดยค่า GBEST จะเป็นค่าที่ดีกว่าระหว่าง GBEST ณ จุดที่ติด Local Optima และค่าที่ได้จากตำแหน่งอนุภาคหลังการกลายพันธุ์ ซึ่งโดยมากการกลายพันธุ์ของอนุภาคจะได้ค่าความเหมาะสมที่ต่ำกว่าค่าของ GBEST ณ ตำแหน่งที่ติด Local Optima

2. ขั้นตอนการทำงานของ GBEST 2 ดังรูปที่ 5.2



รูปที่ 5.2 การทำงานของ GBEST 2

เมื่ออนุภาคติดอยู่ใน Local Optima ดังรูปที่ 5.2(ซ้าย) จะทำการกลายพันธุ์อนุภาคเพียงเล็กน้อย ดังรูปที่ 5.2(กลาง) โดยค่า GBEST ที่ได้ก็เป็นเช่นเดียวกับ GBEST 1 แต่จะทำการกลายพันธุ์ GBEST นี้ต่อเพียงเล็กน้อย ดังรูปที่ 5.2(ขวา)

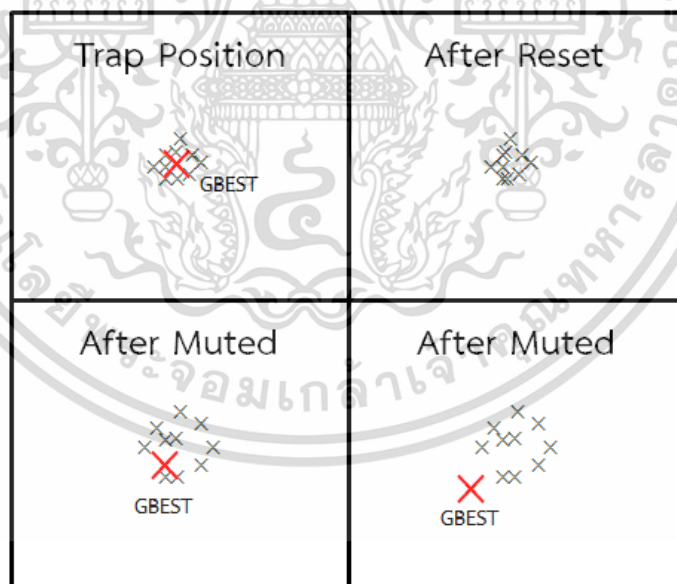
### 3. ขั้นตอนการทำงานของ GBEST 3 ดังรูปที่ 5.3



รูปที่ 5.3 การทำงานของ GBEST 3

เมื่ออนุภาคติดอยู่ใน Local Optima ดังรูปที่ 5.3(ซ้าย) จะทำการรีเซ็ตค่าของ PBEST และ GBEST ดังรูปที่ 5.3(กลาง) และทำการกลายพันธุ์อนุภาคเพียงเล็กน้อย ดังรูปที่ 5.3(ขวา) เนื่องจากการรีเซ็ตค่า GBEST ทำให้ GBEST จะอยู่ที่ตำแหน่งที่ดีที่สุดของอนุภาคหลังการกลายพันธุ์ ส่วน PBEST ของแต่ละอนุภาคจะเป็นตำแหน่งอนุภาคหลังการกลายพันธุ์

### 4. ขั้นตอนการทำงานของ MPG-PSO ดังรูปที่ 5.4



รูปที่ 5.4 การทำงานของ MPG-PSO

เมื่ออนุภาคติดอยู่ใน Local Optima ดังรูปที่ 5.4(บนซ้าย) จะทำการรีเซ็ตค่าของ PBEST และ GBEST ดังรูปที่ 5.4(บนขวา) ทำการกลายพันธุ์อนุภาคเพียงเล็กน้อย ดังรูปที่ 5.4(ล่างซ้าย) จะทำให้ได้ GBEST ค่าใหม่ออกมา (ตำแหน่งที่ดีที่สุดจากตำแหน่งอนุภาคทุกตัวหลังการกลายพันธุ์) และทำการกลายพันธุ์ GBEST ค่าใหม่เพียงเล็กน้อย ดังรูปที่ 5.4(ล่างขวา)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

### ตารางที่ 5.1 ค่าพารามิเตอร์ที่ใช้ทดลองกับฟังก์ชันคณิตศาสตร์

พารามิเตอร์	ค่า
จำนวนอนุภาคที่ใช้ในการทดลอง	30 อนุภาค
จำนวนครั้งของการคำนวณหาค่าความเหมาะสม (Evaluation Call)	90,000,180 ครั้ง
ขอบเขตการค้นหาค่าของแต่ละฟังก์ชัน	ตามตารางในภาคผนวก
จำนวนมิติของแต่ละฟังก์ชัน	ตามตารางในภาคผนวก
ความเร็วมากที่สุด (Max velocity)	ตามตารางในภาคผนวก
ความเร็วน้อยสุด (Min velocity)	ตามตารางในภาคผนวก
จำนวนครั้งในการทดลอง	10 ครั้งต่อฟังก์ชัน
ค่าความเฉื่อย (Weight, $\omega$ )	0.72984 [13]
ค่าคงที่ของ PBEST (Constant number PBEST, $C_1$ )	1.49618 [13]
ค่าคงที่ของ GBEST (Constant number GBEST, $C_2$ )	1.49618 [13]
รอบของการกระจายอนุภาค (Threshold of Reposition)	100

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## ตารางที่ 5.2 จำนวนมิติของปัญหาฟังก์ชันคณิตศาสตร์

พารามิเตอร์	ค่า
จำนวนมิติของฟังก์ชัน Ackley	100 มิติ
จำนวนมิติของฟังก์ชัน Griewank	100 มิติ
จำนวนมิติของฟังก์ชัน Rastrigin	100 มิติ
จำนวนมิติของฟังก์ชัน Rosenbrock	100 มิติ
จำนวนมิติของฟังก์ชัน Schwefel	100 มิติ
จำนวนมิติของฟังก์ชัน Cosine Mixture	100 มิติ
จำนวนมิติของฟังก์ชัน Exponential	100 มิติ
จำนวนมิติของฟังก์ชัน Levy	100 มิติ
จำนวนมิติของฟังก์ชัน Michalewicz	100 มิติ
จำนวนมิติของฟังก์ชัน Dixon-Price	10 มิติ
จำนวนมิติของฟังก์ชัน Step	100 มิติ
จำนวนมิติของฟังก์ชัน Schaffer	2 มิติ
จำนวนมิติของฟังก์ชัน Holder	2 มิติ
จำนวนมิติของฟังก์ชัน Beale	2 มิติ
จำนวนมิติของฟังก์ชัน Shubert	2 มิติ
จำนวนมิติของฟังก์ชัน Goldstein-Price	2 มิติ
จำนวนมิติของฟังก์ชัน Trid	10 มิติ
จำนวนมิติของฟังก์ชัน Six-Hump Camel	2 มิติ
จำนวนมิติของฟังก์ชัน Sphere	100 มิติ
จำนวนมิติของฟังก์ชัน Parallel	100 มิติ
จำนวนมิติของฟังก์ชัน Rotated	100 มิติ
จำนวนมิติของฟังก์ชัน Cigar	100 มิติ
จำนวนมิติของฟังก์ชัน Brown	100 มิติ
จำนวนมิติของฟังก์ชัน Multimod	100 มิติ
จำนวนมิติของฟังก์ชัน Zakharov	100 มิติ
จำนวนมิติของฟังก์ชัน Easom	2 มิติ
จำนวนมิติของฟังก์ชัน Rosenbrock No.1	50 และ 100 มิติ
จำนวนมิติของฟังก์ชัน Sum of Different	50 และ 100 มิติ
จำนวนมิติของฟังก์ชัน Sum Squares	50 และ 100 มิติ

สำหรับการทดลองในบทที่ 5 จะใช้ภาษา C++ ที่เขียนใน Microsoft Visual C++ 2013 คอมพิวเตอร์ที่มีหน่วยความจำหลักขนาด 8 GB ความเร็ว 2.27 GHz หน่วยประมวลผล Intel Core i3

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

โดยค่าที่ใช้เปรียบเทียบประสิทธิภาพของวิธีต่าง ๆ ที่ทำการทดลองคือค่า Best Fitness และค่า Evaluation Call ซึ่งถ้าวิธีใดสามารถหาค่าตอบได้ค่าต่ำสุด (ในหลายฟังก์ชันอยู่ที่ศูนย์) ในแต่ละฟังก์ชันคณิตศาสตร์ แสดงว่าวิธีนั้นเจอค่า Global Optima ของฟังก์ชัน และถ้าวิธีใดใช้ค่า Evaluation Call ที่น้อยกว่า วิธีนั้นก็จะมีประสิทธิภาพในการแก้ปัญหามากกว่า สำหรับค่าพารามิเตอร์ต่าง ๆ ที่ใช้ในการทดลองแสดงในตารางที่ 5.2

จุดประสงค์ของการทดลองในบทนี้ คือวัดประสิทธิภาพการค้นหาของขั้นตอนวิธีที่นำเสนอเปรียบเทียบกับวิธีต่าง ๆ ที่จะทำให้อนุภาคสามารถค้นหาต่อได้ (หลุดจาก Local Optima) โดยมี PSO, PSORE, MPSOSM, GBEST 1, GBEST 2, GBEST 3, MPG-PSO และ IAC-PSO หาจุดต่ำสุดของฟังก์ชันมาตรฐาน ซึ่งการทดลองสามารถแบ่งออกเป็น 3 ส่วน โดยแต่ละส่วนมีรายละเอียดดังนี้

1. การทดลองวัดประสิทธิภาพของการใช้การกลายพันธุ์ของอนุภาคและตำแหน่ง PBEST และ GBEST แบบต่าง ๆ และการใช้ Multi-Swarm ในการดึงอนุภาคออกจากตำแหน่ง Local Optima โดยเปรียบเทียบวิธี PSO, PSORE, MPSOSM, GBEST 1, GBEST 2, GBEST 3 และ MPG-PSO

2. การทดลองปรับเปลี่ยนค่าพารามิเตอร์ต่าง ๆ ที่เหมาะสมของวิธี MPG-PSO

3. ทดลองเปลี่ยนตำแหน่งของค่าคำตอบที่ดีที่สุดจากตำแหน่งจุด (0, 0) ไปเป็นตำแหน่งอื่น

4. การทดลองวัดประสิทธิภาพการค้นหาของขั้นตอนวิธีที่นำเสนอเปรียบเทียบกับ MPG-PSO และ IAC-PSO

### 5.1 การทดลองวัดประสิทธิภาพของการใช้การกลายพันธุ์ของอนุภาคและตำแหน่ง PBEST และ GBEST แบบต่าง ๆ และการใช้ Multi-Swarm ในการดึงอนุภาคออกจากตำแหน่ง Local Optima โดยเปรียบเทียบวิธี PSO, PSORE, MPSOSM, GBEST 1, GBEST 2, GBEST 3 และ MPG-PSO

ผลของการทดสอบวิธี PSO, PSORE, MPSOSM, GBEST 1, GBEST 2, GBEST 3 และ MPG-PSO แสดงในตารางที่ 5.3 และ 5.4 โดยทดสอบกับปัญหาฟังก์ชันมาตรฐานในภาคผนวก ก ซึ่งใช้พารามิเตอร์ตามตารางที่ 5.1 และตารางที่ 5.2 โดยค่า Evaluation Call คือ ค่าเฉลี่ยจำนวนครั้งที่ทำการหาค่าความเหมาะสม ณ ตำแหน่งของอนุภาคของฟังก์ชันที่ใช้ในการทดลอง โดยจะเป็นการเฉลี่ยของจำนวนครั้ง ณ จุดที่พบค่าที่ดีที่สุด และค่า Best Fitness Value คือ ค่าเฉลี่ยของค่าความเหมาะสมที่ดีที่สุดของการทดลองทั้งหมด (10 ครั้ง ตามตารางที่ 5.1)

ตารางที่ 5.3 ผลการค้นหาคำตอบของฟังก์ชันมาตรฐานด้วย PSO, PSORE, MPSOSM, GBEST 1, GBEST 2, GBEST 3 และ MPG-PSO

Function Name	PSO	PSORE	MPSOSM	GBEST 1	GBEST 2	GBEST 3	MPG-PSO
	Evaluation Call	Evaluation Call	Evaluation Call	Evaluation Call	Evaluation Call	Evaluation Call	Evaluation Call
ACKLEY	17,342,561	90,004,731	5,396,820	41,321,657	2,044,710	2,820,240	1,464,330
GRIEWANK	19,749,216	90,004,070	548,025	433,500	330,270	729,900	257,310
RASTRIGIN	677,953	90,005,129	3,271,440	1,952,190	2,333,280	1,520,460	1,551,240
ROSENBROCK	506,056	90,001,673	90,019,277	88,211,244	23,793,030	90,006,141	4,701,030
SCHWEFEL	4,918,451	90,005,401	90,018,003	22,303,890	83,729,580	90,032,722	47,182,200
COSINE MIXTURE	3,179,553	90,004,863	586,095	486,720	353,670	392,490	280,080
EXPONENTIAL	8,257,920	90,004,991	1,374,975	394,350	344,550	569,970	332,340
LEVY	23,671,323	90,005,039	90,020,946	87,367,022	4,276,590	90,012,811	3,557,190
MICHALEWICZ	3,512,953	142,710	78,255	58,140	88,530	160,950	55,380
DIXON-PRICE	8,340	3,120	4,920	4,200	4,500	11,700	3,690
STEP	1,314,167	90,028,472	71,070	71,790	64,530	70,230	54,330
SCHAFFER	7,260	31,020	24,735	955,830	326,670	328,920	7,800
HOLDER	8,280	14,460	17,385	51,240	19,710	37,320	630
BEALE	12,210	11,010	12,720	12,900	12,660	12,180	11,490
SHUBERT	2,220	3,060	1,680	3,630	3,180	3,540	2,220
GOLDSTEIN-PRICE	4,140	3,990	4,410	4,620	5,040	4,770	3,960
SIX-HUMP CAMEL	1,020	750	960	1,230	1,140	1,050	630
SPHERE	9,542,578	90,000,131	10,597,065	4,369,980	4,397,850	4,428,120	4,244,760
PARALLEL HYPER-ELLIPSOID	5,277,978	90,000,197	11,229,750	4,465,590	4,432,920	4,392,060	4,414,080
ROTATED HYPER-ELLIPSOID	15,686,917	90,000,233	11,020,485	4,366,470	4,341,090	4,526,010	4,142,010
CIGAR	5,670,309	90,000,188	10,456,890	4,410,960	4,458,660	4,414,620	4,216,170
BROWN	17,119,535	90,000,201	10,905,600	4,443,180	4,465,260	4,485,570	4,182,030
MULTIMOD	17,929,744	90,168,172	20,842,380	11,925,930	11,331,360	11,700,300	10,892,670
ZAKHAROV	29,999,949	90,018,840	90,000,128	53,419,950	56,686,620	55,003,560	54,198,540
TRID	2,418,056	27,136,050	141,465	1,570,432	358,710	998,700	51,990
EASOM	8,910	7,080	6,600	7,410	8,370	8,400	6,090

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 5.4 ผลการค้นหาคำตอบของฟังก์ชันมาตรฐานด้วย PSO, PSORE, MPSOSM, GBEST 1, GBEST 2, GBEST 3 และ MPG-PSO (ต่อ)

Function Name	PSO	PSORE	MPSOSM	GBEST 1	GBEST 2	GBEST 3	MPG-PSO
	Best Fitness Value	Best Fitness Value	Best Fitness Value	Best Fitness Value	Best Fitness Value	Best Fitness Value	Best Fitness Value
ACKLEY	10.719	4.337	0	1.42E-14	0	0	0
GRIEWANK	0.078	8.44E-15	0	0	0	0	0
RASTRIGIN	525.336	238.79	0	0	0	0	0
ROSENBROCK	1.33E-25	5.11E-27	3.15E-20	6.93E-27	0	3.78E-27	0
SCHWEFEL	11,745.4	6,040.1	3,434.42	0	0	1,302.53	0
COSINE MIXTURE	6.499	2.365	0	0	0	0	0
EXPONENTIAL	4.55E-10	2.89E-15	0	2.22E-16	0	0	0
LEVY	98.566	28.99	3.55E-25	5.19E-30	0	2.6E-30	0
MICHALEWICZ	0.538	0	0	0	0	0	0
DIXON-PRICE	0	0	0	0	0	0	0
STEP	328	73	0	0	0	0	0
SCHAFFER	0	0	0	0	0	0	0
HOLDER	0	0	0	0	0	0	0
BEALE	0	0	0	0	0	0	0
SHUBERT	0	0	0	0	0	0	0
GOLDSTEIN-PRICE	0	0	0	0	0	0	0
SIX-HUMP CAMEL	0	0	0	0	0	0	0
SPHERE	6.92E-322	5.43E-322	0	0	0	0	0
PARALLEL HYPER-ELLIPSOID	6.45E-321	2.1E-321	0	0	0	0	0
ROTATED HYPER-ELLIPSOID	1.33E-320	2.77E-321	0	0	0	0	0
CIGAR	2.16E-316	1.48E-317	0	0	0	0	0
BROWN	1.44E-320	1.84E-321	0	0	0	0	0
MULTIMOD	4.32E-246	223.889	0	0	0	0	0
ZAKHAROV	2.52E-84	2.72E-48	3.97E-202	0	0	0	0
TRID	9.09E-12	0	0	2.73E-12	0	0	0
EASOM	0	0	0	0	0	0	0

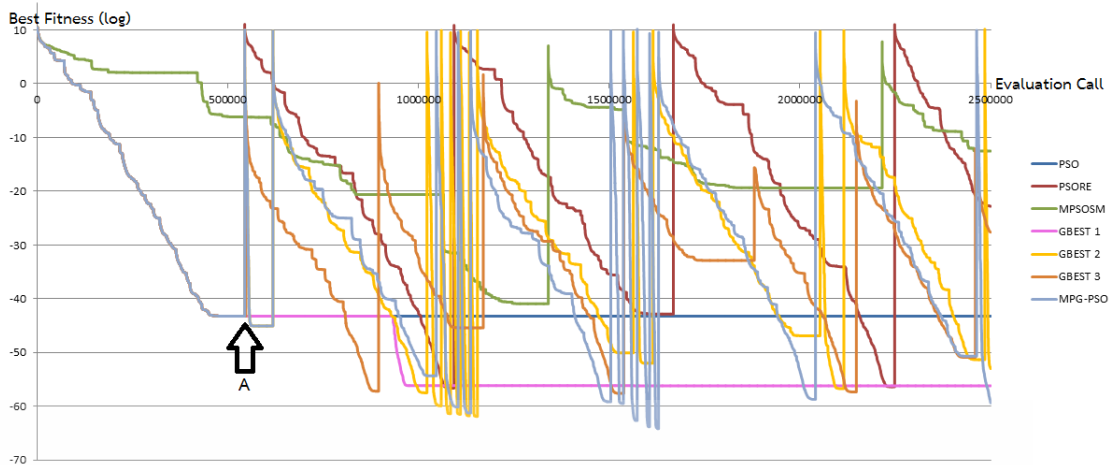
จากตารางที่ 5.3 และตารางที่ 5.4 จะเห็นว่า PSO สามารถหาคำตอบที่ดีที่สุดได้เพียง 8 ฟังก์ชัน เนื่องจาก PSO จะติดอยู่ใน Local Optima จนกระทั่งถึงรอบที่มากที่สุดที่ได้ตั้งเอาไว้ ส่วน PSORE จะทำการเริ่มการทำงานใหม่ในทุก ๆ รอบของการติด Local Optima โดยจะทำการสุ่มค่าตำแหน่งใหม่เพื่อหลีกเลี่ยงจากการติดใน Local Optima รวมทั้งมีการรีเซ็ตค่า PBEST และ GBEST เพื่อไม่ให้อนุภาคเข้าสู่หาค่าเดิมและหาตำแหน่งที่มีความเหมาะสมที่ดีขึ้น แต่เนื่องจากการสุ่มค่าตำแหน่งใหม่ภายใน Search Space ทั้งหมด ทำให้ PSORE ใช้เวลามากในการวิ่งกลับเข้ามาหาคำตอบใหม่อีกครั้ง และมักจะติดอยู่ใน Local Optima ที่เคยเจอมาแล้ว แต่ PSORE ก็ยังดีกว่า PSO ที่อนุภาคค้นหาค่าอยู่ที่ตำแหน่ง Local Optima เดิม จึงทำให้ PSORE มีผลที่ดีกว่า PSO และเจอค่าคำตอบที่ดีที่สุดเพิ่มขึ้นอีก 2 ฟังก์ชัน เมื่อเทียบกับ PSO จะหาคำตอบที่ดีที่สุดได้ 10 ฟังก์ชัน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาค้นคว้าเท่านั้น ไม่อนุญาตให้นำไปเผยแพร่โดยไม่ได้รับอนุญาต  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

MPSOSM สามารถหาค่าคำตอบที่ดีที่สุดได้ 22 ฟังก์ชัน เนื่องจากการแบ่งอนุภาคออกเป็นหลายกลุ่มช่วยกันค้นหาใน Search Space เดียวกัน แต่เป็นการค้นหาที่อิสระจากกันจนกว่าจะติดอยู่ใน Local Optima จึงจะใช้ค่า GBEST ของกลุ่มอื่นมาช่วยชักจูงให้อนุภาคในกลุ่มที่ติด ได้หลุดออกจาก Local Optima และมีโอกาสเจอค่าที่ดีที่สุด นอกจากนี้ยังมีการกลายพันธุ์ของอนุภาคเพียงเล็กน้อยอีกด้วย จึงทำให้มีการค้นหาที่กว้างกว่า PSORE และทำให้เจอ Optima เพิ่มขึ้น 12 ฟังก์ชัน

GBEST 1 มีอนุภาคกลุ่มเดียว เมื่อติดอยู่ใน Local Optima จะใช้การกลายพันธุ์ของอนุภาคเพียงอย่างเดียวในการเริ่มทำงานใหม่ เนื่องจาก GBEST 1 มีการรีเซ็ตค่า PBEST แต่ไม่รีเซ็ตค่า GBEST ดังนั้นในกรณีที่มีการกลายพันธุ์เล็กน้อย โอกาสที่จะพบตำแหน่งที่ดีขึ้นจะเกิดจากการที่อนุภาคเคลื่อนที่จากจุดที่กลายพันธุ์ไปหา GBEST และระหว่างทางเจอตำแหน่งที่ดีกว่า ก็จะทำให้ได้ GBEST ใหม่ที่ดีขึ้น แต่ในบางกรณีที่มีการกลายพันธุ์เพียงเล็กน้อย อนุภาคส่วนใหญ่มักเคลื่อนเข้าสู่ตำแหน่ง GBEST เดิม ที่ติดอยู่ใน Local Optima จึงส่งผลให้หาค่าคำตอบที่ดีที่สุดได้ 21 ฟังก์ชัน อยู่ในระดับใกล้เคียงกับ MPSOSM

GBEST 2 และ MPG-PSO สามารถหาค่าคำตอบที่ดีที่สุดได้ทั้งหมด 26 ฟังก์ชัน โดยที่ MPG-PSO เจอค่าคำตอบที่ดีที่สุดเร็วกว่า สาเหตุที่ทำให้ GBEST 2 และ MPG-PSO สามารถหาค่าคำตอบได้ทั้ง 26 ฟังก์ชัน เนื่องจากทั้ง 2 วิธี มีการกลายพันธุ์อนุภาคและกลายพันธุ์ GBEST เพิ่มต่อจาก GBEST เดิม (กรณีนี้ คือ GBEST 1 และ GBEST 3 มีการกลายพันธุ์โดยรวมจาก GBEST ณ จุดที่ติด Local Optima 20 เปอร์เซ็นต์ แต่ GBEST 1 กลายพันธุ์อนุภาคโดยตรงจากค่า GBEST ที่ติดใน Local Optima ส่วน GBEST 3 นั้นจะกลายพันธุ์ผ่านทางอนุภาคตัวที่ดีที่สุด) GBEST 2 และ MPG-PSO กลายพันธุ์ GBEST ต่ออีก 30 เปอร์เซ็นต์ ทำให้ค่าที่ค้นหาวางขึ้น แต่ GBEST 2 จะมีค่า Evaluation Call ที่เยอะกว่าเนื่องจาก GBEST 2 ได้มาจาก GBEST ณ จุดที่ติด Local Optima และกลายพันธุ์ 30 เปอร์เซ็นต์ แต่ MPG-PSO จะกลายพันธุ์เท่ากับอนุภาคตัวที่ดีที่สุด อนุภาคทุกตัว ณ จุดที่ติด Local Optima มีค่าใกล้เคียงหรือเท่ากับค่า GBEST ณ จุดที่ติด Local Optima มีการกลายพันธุ์ GBEST เท่ากับจำนวนอนุภาคและเลือกค่าที่ดีที่สุด ดังนั้นค่า GBEST ที่ได้จากการกลายพันธุ์ทางอนุภาคจะได้ค่าที่ดีกว่าค่าที่ได้จาก GBEST โดยตรง ส่งผลให้มีพื้นที่ในการค้นหาวางกว้างกว่า GBEST 1 และ GBEST 3



รูปที่ 5.5 กราฟแสดงการทำงานของฟังก์ชัน Rosenbrock

จากรูปที่ 5.5 กราฟแสดงการทำงานของฟังก์ชัน Rosenbrock เป็นกราฟแสดงค่า GBEST ณ Evaluation Call ที่เพิ่มขึ้น แสดงถึงการลู่เข้าของ GBEST โดยแกน x คือ ค่า Evaluation Call ที่เพิ่มขึ้นตามเวลา และแกน y คือ ค่า Best Fitness (log scale) จะเห็นว่าในตอนเริ่มต้น PSO, PSORE, GBEST 1, GBEST 2, GBEST 3 และ MPG-PSO ใช้ PSO ทั้งหมด ซึ่งเป็นแบบกลุ่มเดี่ยว กราฟจึงเป็นเส้นเดียวกันในตอนเริ่ม จนมาถึง Evaluation Call ประมาณ 5 แสน (จุดเอ) ณ จุดนั้น GBEST ไม่ได้ขึ้นเป็นจำนวน 100 iterations ติดกัน (1 iteration คือการเคลื่อนที่ 1 ครั้งของอนุภาค ทุกตัวตามสมการ PSO) ณ จุดนี้ PSO จะทำงานต่อไปไม่มีการเริ่มทำงานใหม่ โดยไม่มีการเปลี่ยน GBEST จะเห็นว่าค่า GBEST ของ PSO คงที่ตลอดถึงแม้ว่า Evaluation Call จะเพิ่มขึ้น นั่นก็คือกลุ่มอนุภาคของ PSO ติดอยู่ใน Local Optima และค้นหาอยู่ในบริเวณเดิม ๆ

PSORE พยายามแก้ปัญหานี้ด้วยการเหมือนกับเริ่มทำงานใหม่ โดยรีเซ็ตค่า PBEST และ GBEST ทั้งหมด สุ่มตำแหน่งอนุภาคใหม่ใน Search Space จะเห็นว่ากราฟเส้นสีน้ำตาลแดง ค่า GBEST พุ่งขึ้นไปสูงสุดเมื่อเทียบกับทุกวิธีที่ทดลอง จากนั้นค่อย ๆ ลู่เข้าหา Local Optima ใหม่อีกครั้งหนึ่ง จะเห็นว่า slope ในการลู่เข้าหาจุด Optima ค่อนข้างเท่ากันตลอด เพียงแต่ว่าอาจจะเจอ Local Optima ที่แตกต่างกัน ทุกครั้งที่เริ่มทำงานใหม่บางครั้งก็ดีขึ้นบางครั้งก็แย่ลง

GBEST 1 ก็มีการเริ่มทำงานใหม่เช่นเดียวกับ PSORE ณ จุดเอ โดยมีการกระจายอนุภาคแต่ยังคงใช้ค่า GBEST เดิม รีเซ็ตเฉพาะค่า PBEST ดังนั้นค่า PBEST จะอยู่ที่ตำแหน่งของอนุภาคที่กระจายออกไป จะเห็นว่าค่า GBEST ไม่เพิ่มขึ้นเนื่องจากไม่มีการรีเซ็ตใหม่ ดังนั้นกราฟของ GBEST 1 จะมีแต่ลดลงโดยไม่มีการเพิ่มขึ้น ถึงแม้จะมีการเริ่มทำงานใหม่เช่นเดียวกันกับ PSORE และวิธีอื่น ๆ ก็ตาม โอกาสที่จะเจอค่า GBEST ที่ดีขึ้นหลังจากเริ่มทำงานใหม่โดยการกลายพันธุ์อนุภาคจากตำแหน่งเดิม ณ จุดที่ติด Local Optima โดยมากค่าเหมาะสมของอนุภาคจะมีค่าลดลงจากตำแหน่งเดิม ซึ่งอยู่ใกล้เคียงกับ GBEST ที่ติด ณ Local Optima ดังนั้นค่า GBEST ที่ได้โดยมากจะเป็นค่าที่ดีที่สุดระหว่างค่าความเหมาะสมของตำแหน่งอนุภาคกับค่า GBEST ณ จุดที่ติด Local Optima ซึ่งส่วนมากค่าที่ติด Local Optima จะดีกว่า ทำให้ไม่เห็นค่า GBEST ที่แย่ลง แต่ก็มีบางกรณี

ไม่ว่าการณ์ใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ใหม่ทุกครั้งที GBEST ไม่เปลี่ยนแปลงค่าภายใน 100 iterations จากรูปจะเห็นว่าในบางครั้งหลังการเริ่มทำงานใหม่ PSORE จะลู่ไปหาค่าที่ดีกว่า GBEST 1 แต่ในบางครั้งหลังการเริ่มการทำงานใหม่ PSORE จะลู่ไปหาค่าที่แย่กว่า ดังแสดงในกราฟ

GBEST 2 มีการรีเซ็ต PBEST แต่ไม่มีการรีเซ็ต GBEST ณ จุดที่ติด Local Optima เช่นเดียวกับ GBEST 1 ดังนั้นหลังจากการกระจายอนุภาค ค่า GBEST ก็มักจะเป็นค่า GBEST เดิม ส่วนที่แตกต่างระหว่าง GBEST 2 กับ GBEST 1 คือ GBEST 2 จะทำการกลายพันธุ์ GBEST ที่ได้หลังการติด Local Optima อีกเพียงเล็กน้อยใน 30 เปอร์เซ็นต์ของมิติทั้งหมด จะเห็นว่าเมื่อมีการเริ่มทำงานใหม่ ค่า GBEST 2 จะแย่ง ในขณะที GBEST 1 อยู่ที่เดิม ณ จุดที่ติด Local Optima แต่เนื่องจาก GBEST 2 กลายพันธุ์จาก GBEST เดิม ไม่ได้ใช้การสุ่มใหม่เช่นเดียวกับ PSORE ดังนั้นค่าความเหมาะสมก็จะดีกว่า PSORE จะเห็นได้ว่า GBEST 2 จะมีค่าเพิ่มขึ้น แต่ไม่เพิ่มขึ้นหลังการเริ่มทำงานใหม่เท่า PSORE ถึงแม้ค่าความเหมาะสมของ GBEST หลังการเริ่มทำงานใหม่จะเพิ่มขึ้นมากทั้งคู่ แต่ความจริงแล้ว GBEST ของ GBEST 2 มีจำนวนมิติที่มีค่าเท่ากับ GBEST ณ จุดที่ติด Local Optima ถึง 70 เปอร์เซ็นต์ เนื่องจากทำการกลายพันธุ์เพียงเล็กน้อยเพียง 30 เปอร์เซ็นต์ ดังจะเห็นได้ว่าหลังจากเริ่มทำงานใหม่ GBEST 2 จะลู่ลงอย่างรวดเร็ว และมักจะลู่ลงดีกว่าเดิม ในขณะที่ PSORE จะลู่ไปหาค่าที่ Local Optima ต่าง ๆ ที่ไม่สัมพันธ์กับค่าเดิมเลย จากกราฟในช่วง Evaluation Call ประมาณ 1 ล้าน จะเห็นว่า GBEST 2 ได้ค่า GBEST ที่ดีขึ้นเรื่อย ๆ หลังจกมีการเริ่มทำงานใหม่ จนในที่สุดไม่มีค่าที่ดีขึ้นและอาจมีการเปลี่ยนแปลงใน 30 มิติที่สุ่มได้ไม่ดี ก็จะทำให้ GBEST 2 ลู่ไปหาค่าใหม่ใน Evaluation Call ประมาณ 1.5 ล้าน

GBEST 3 มีการรีเซ็ตทั้ง PBEST และ GBEST ดังนั้นค่า GBEST ที่ได้หลังจากการเริ่มทำงานใหม่จะเป็นค่าของอนุภาคตัวที่มีค่าความเหมาะสมดีที่สุดหลังจากการกลายพันธุ์ ซึ่งจะห่างจาก GBEST ณ จุดที่ติด Local Optima อยู่ประมาณ 20 เปอร์เซ็นต์ (ประมาณว่าตำแหน่งอนุภาคกับตำแหน่ง GBEST ณ จุดที่ติด Local Optima มีค่าใกล้เคียงกันมาก) ดังนั้นเมื่อเทียบกับ GBEST 2 นั้น GBEST 3 จะกลายพันธุ์จาก GBEST เดิมผ่านทางตำแหน่งอนุภาคเพียง 20 เปอร์เซ็นต์ ขณะที่ GBEST 2 กลายพันธุ์จาก GBEST ณ จุดที่ติด Local Optima 30 เปอร์เซ็นต์ของจำนวนมิติทั้งหมด ดังนั้นจะเห็นจากกราฟว่าค่า GBEST 3 หลังการเริ่มทำงานใหม่จะมีค่าเพิ่มขึ้นแต่ไม่มากเท่า GBEST 2 และ PSORE หลังจากนั้นค่า GBEST นี้ก็จะเป็นตัวที่จะชักนำให้อนุภาคเคลื่อนที่เข้าหาตำแหน่ง Local Optima ใหม่ ซึ่งก็มีทั้งค่าที่ดีขึ้นและลดลงไม่แน่นอน ใกล้เคียงกับ PSORE

สำหรับวิธีที่นำเสนอ MPG-PSO มีการทำงานใกล้เคียงกับ GBEST 3 คือมีการรีเซ็ต PBEST และ GBEST ดังนั้นค่า GBEST ที่ได้จะเหมือนกับ GBEST 3 คือได้ค่าตำแหน่งที่ดีที่สุดของอนุภาคหลังการกลายพันธุ์ แต่ใน MPG-PSO จะนำตำแหน่งนี้ไปกลายพันธุ์อีก 30 เปอร์เซ็นต์ เพื่อให้การค้นหาค่าตอบกว้างขึ้น ดังนั้นจะเห็นว่าค่า GBEST หลังการเริ่มทำงานใหม่ของ MPG-PSO มีค่าอยู่ในระดับเดียวกับ GBEST 2 แต่แย่กว่า GBEST 3 เนื่องจากมีการนำ GBEST ของ GBEST 3 มากกลายพันธุ์ต่อ

อีก 30 เปอร์เซ็นต์ของจำนวนมิติทั้งหมด จากในกราฟจะเห็นว่าในส่วนของการทำงานช่วง Evaluation Call 2,500,000 แรก MGP-PSO ได้ค่า GBEST ที่ต่ำที่สุด

เนื่องจากวิธีที่กล่าวมาทั้งหมดมีความคล้ายกันมาก คือมีการเริ่มทำงานใหม่และการกลายพันธุ์อนุภาคกับ GBEST ทำให้อนุภาคเริ่มการค้นหาในบริเวณใหม่ เพื่อให้ได้ค่าที่ดีขึ้น MPSOSM ก็มีการทำงานในแบบเดียวกัน แต่มีข้อแตกต่างหลักคือแบ่งอนุภาคออกเป็นหลายกลุ่ม แต่ละกลุ่มมีการค้นหาที่เป็นอิสระต่อกันจนกว่ากลุ่มใดกลุ่มหนึ่งจะติดใน Local Optima จึงจะมีการเปลี่ยนค่า GBEST ของกลุ่มที่ติดเป็น GBEST ของกลุ่มอื่น และดำเนินการกระจายอนุภาค และเริ่มทำงานใหม่ เฉพาะกลุ่มนั้น ดังนั้นโดยหลักการแล้วการทำงานก็จะเป็นเช่นเดียวกัน แต่เนื่องจากมีการแบ่งออกเป็นหลายกลุ่ม จะเห็นว่า slope ในการลู่ออกหา Optima ช้ากว่า (มีความชันน้อยกว่า) สาเหตุที่มี slope ลดลงของ GBEST ช้ากว่า เนื่องจากจำนวนอนุภาคต่อกลุ่มมีจำนวนน้อยลง ทำให้โอกาสที่จะหาค่าที่ดีกว่ามีน้อยลง ดังนั้น slope การลดลงจึงช้ากว่า นอกจากนั้นอาจจะมีการติด Local Optima ในกลุ่มต่าง ๆ ได้เร็วขึ้นกว่า Evaluation Call 5 แสนรอบ แต่เนื่องจากค่า GBEST เป็นค่า GBEST ของบางกลุ่ม จึงทำให้บางกลุ่มหลุดออกจาก Local Optima ด้วยการดึงของ GBEST ของกลุ่มอื่น จนในที่สุดทุกกลุ่มติด Local Optima ที่เดียวกัน ค่า GBEST ทุกกลุ่มก็จะโดนกลายพันธุ์ ดังนั้น ณ จุดนั้นก็จะเห็นค่า GBEST แ่ลง ตั้งตำแหน่ง Evaluation Call 1,300,000 ซึ่ง ณ จุดนั้นติด Local Optima ทุกกลุ่ม จึงเริ่มทำงานใหม่ทุกกลุ่มพร้อมกัน จะเห็นว่า MPSOSM มีผลที่แย่ที่สุดเมื่อเทียบกับทุกวิธีที่ทดลองใน Evaluation Call ที่น้อยกว่า 2,500,000 แต่เมื่อเพิ่มจำนวน Evaluation Call ให้เยอะขึ้น MPSOSM ก็เจอคำตอบเช่นเดียวกัน จากกราฟนี้จะเห็นได้ชัดว่า MPSOSM มี Local Search ที่แย่กว่าวิธีอื่นเนื่องจากมีหลายกลุ่ม จึงมีจำนวนอนุภาคต่อกลุ่มน้อยกว่า แต่โดยรวมมี Global Search ที่ดีกว่าเพราะ MPSOSM ก็เจออนุภาคใน 22 ฟังก์ชันใกล้เคียงกับ GBEST 1 และดีกว่า PSO กับ PSORE มาก แต่เจอใน Evaluation Call ที่เยอะกว่า

## 5.2 การทดลองปรับเปลี่ยนค่าพารามิเตอร์ต่าง ๆ ที่เหมาะสมของวิธี MPG-PSO

ในหัวข้อนี้จะทำการทดลองปรับเปลี่ยนค่าพารามิเตอร์ต่าง ๆ ของวิธี MPG-PSO เพื่อหาค่าที่ดีที่สุดสำหรับฟังก์ชันที่ใช้ในการทดสอบ โดยค่าพารามิเตอร์ที่ทำการทดลองมีดังต่อไปนี้ ค่า Local Optima Threshold โดยทดลองระหว่างค่า 50 และ 150 รอบ โดยค่า 100 รอบ เป็นค่าที่ใช้ในการทดลองก่อนหน้า

โดยถ้าค่า GBEST ไม่ลดลงถึง 50 รอบ จะมีการเริ่มทำงานใหม่ ในกรณีที่เกิดมีค่าดีขึ้น หลังจากนั้น จะทำให้การทำงานช้าลงเพราะต้องเริ่มทำงานใหม่บ่อยขึ้น แต่กรณีที่เป็น 150 ถ้าโดยมากค่า GBEST มักไม่มีการเปลี่ยนแปลงหลัง 50 รอบ ก็จะเสียเวลาเพิ่มขึ้น 100 รอบทุกครั้งที่มีการติด Local Optima นอกจากนี้ประเด็นหลักคือการเริ่มทำงานใหม่ทุกครั้งที่ค่า GBEST ไม่เปลี่ยนแปลงในจำนวนรอบที่น้อยกว่า จะมีการเริ่มทำงานใหม่เร็วขึ้น และอาจจะเริ่มทำงานในระดับค่า GBEST ที่ยังไม่ติด Local Optima จริง หรือติดในระดับที่มีค่าสูงกว่า จากตารางที่ 5.5 จะเห็นว่าที่ค่า 50 รอบ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

มักจะมีจำนวน Evaluation Call น้อยกว่าในกรณีที่เจอค่าคำตอบ แต่จำนวนฟังก์ชันที่เจอคำตอบมีน้อยกว่าค่า Threshold 150 และค่า Threshold 100 จะเจอคำตอบทุกฟังก์ชัน ถึงแม้บางฟังก์ชันจะใช้ Evaluation Call มากกว่าค่า Threshold 50

**ตารางที่ 5.5 ผลการค้นหาคำตอบของวิธี MPG-PSO โดยทำการเปลี่ยนค่า Local Optima Threshold เป็น 50 และ 150 ตามลำดับ**

NO	Function	Threshold = 50		Threshold = 100		Threshold = 150	
		Evaluation Call	Best Fitness	Evaluation Call	Best Fitness	Evaluation Call	Best Fitness
1	Ackley	1,203,300	0	1,464,330	0	1,847,520	0
2	Griewank	241,170	0	257,310	0	476,820	0
3	Rastrigin	1,881,480	0	1,551,240	0	2,201,880	0
4	Rosenbrock	90,007,068	3.7E-29	4,701,030	0	838,770	0
5	Schwefel	90,022,296	236.588	47,182,200	0	90,018,832	473.465
6	Cosine Mixture	311,460	0	280,080	0	400,350	0
7	Exponential	203,760	0	332,340	0	421,770	0
8	Levy	1,213,710	0	3,557,190	0	3,372,480	0
9	Michalewicz	90,029,222	0.988799	55,380	0	90,074,370	0.993225
10	Dixon-Price	1,237,860	0	3,690	0	458,760	0
11	Step	43,230	0	54,330	0	68,190	0
12	Schaffer	56,580	0	7,800	0	8,760	0
13	Holder	5,250	0	630	0	20,910	0
14	Beale	11,070	0	11,490	0	11,820	0
15	Shubert	2,040	0	2,220	0	2,100	0
16	Goldstein-Price	4,350	0	3,960	0	5,070	0
17	Six-Hump Camel	960	0	630	0	1,050	0
18	Sphere	4,324,740	0	4,244,760	0	4,237,470	0
19	Parallel Hyper-Ellipsoid	4,313,460	0	4,414,080	0	4,308,690	0
20	Rotated Hyper-Ellipsoid	4,301,520	0	4,142,010	0	4,224,720	0
21	Cigar	4,353,300	0	4,216,170	0	4,424,460	0
22	Brown	4,257,420	0	4,182,030	0	4,443,090	0
23	Multimod	11,670,480	0	10,892,670	0	11,114,190	0
24	Zakharov	90,020,385	6.02E-234	54,198,540	0	90,000,003	6.51E-166
25	Trid	713,550	0	51,990	0	1,516,410	0
26	Easom	9,270	0	6,090	0	5,820	0

2. ทดลองเปลี่ยนเปอร์เซ็นต์ของจำนวนมิติทั้งหมดที่จะทำการกลายพันธุ์ตำแหน่งอนุภาค โดยเมื่ออนุภาคติดอยู่ใน Local Optima ถ้าไม่มีการกลายพันธุ์ก็จะไม่สามารถทำให้อนุภาคเคลื่อนที่ไปค้นหาในพื้นที่อื่น ๆ ได้ แต่ควรจะเปลี่ยนตำแหน่งไปเท่าใดจากตำแหน่งที่ติด Local Optima อยู่ รวมทั้งควรจะเปลี่ยนตำแหน่งในทุกมิติของตำแหน่งหรือในบางมิติ ตามที่ได้กล่าวมาแล้วในบทก่อนหน้า ตำแหน่งที่ติดใน Local Optima มักจะมีเพียงบางตำแหน่งในบางมิติที่มีค่าไม่ถูกต้อง ถ้าเปลี่ยนทุกมิติใหม่หมด จะเท่ากับเป็นการเริ่มการค้นหาใหม่และอาจไม่พบคำตอบ แต่ถ้าสุ่มเปลี่ยนเพียงบางมิติและสุ่มมิติที่ต้องเปลี่ยนก็จะทำให้การค้นหาเร็วขึ้น ดังนั้นในการทดลองนี้จึงทดลองเปลี่ยนเปอร์เซ็นต์จำนวนมิติที่จะสุ่มเปลี่ยนและเปรียบเทียบผลการทดลองว่าจำนวนมิติเท่าไรดีที่สุดจาก 20

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เปอร์เซ็นต์ เป็น 10 และ 30 เปอร์เซ็นต์ ตามลำดับ โดยการทดลองนี้จะใช้เปอร์เซ็นต์การกลายพันธุ์ของตำแหน่ง GBEST คงที่ที่ 30 เปอร์เซ็นต์

จากตารางที่ 5.6 จะเห็นว่า การกลายพันธุ์ 20 เปอร์เซ็นต์ของจำนวนมิติทั้งหมดให้ผลดีที่สุด โดยที่การกลายพันธุ์ 10 เปอร์เซ็นต์ มีผลทำให้ไม่เจอคำตอบใน 1 ฟังก์ชัน เนื่องจากจำนวนมิติที่เปลี่ยนมีน้อยเกินไป ขอบเขตในการค้นหาจึงแคบกว่า ในขณะที่เดียวกัน 30 เปอร์เซ็นต์ ก็มีผลที่แย่งกว่า 10 เปอร์เซ็นต์ เนื่องจากการกลายพันธุ์มากเกินไปทำให้ต้องเริ่มการทำงานใหม่และอาจจะลู่ไปหา Local Optima อื่น

ตารางที่ 5.6 ผลการค้นหาคำตอบของวิธี MPG-PSO โดยทำการเปลี่ยนเปอร์เซ็นต์การกลายพันธุ์ตำแหน่งอนุภาคจาก 20 เปอร์เซ็นต์ เป็น 10 และ 30 เปอร์เซ็นต์ ตามลำดับ

NO	Function	กลายพันธุ์ตำแหน่ง 10 เปอร์เซ็นต์		กลายพันธุ์ตำแหน่ง 20 เปอร์เซ็นต์		กลายพันธุ์ตำแหน่ง 30 เปอร์เซ็นต์	
		Evaluation Call	Best Fitness	Evaluation Call	Best Fitness	Evaluation Call	Best Fitness
1	Ackley	2,459,580	0	1,464,330	0	1,366,140	0
2	Griewank	267,180	0	257,310	0	284,550	0
3	Rastrigin	2,009,100	0	1,551,240	0	2,377,890	0
4	Rosenbrock	1,205,400	0	4,701,030	0	90,004,955	1.06E-28
5	Schwefel	11,999,820	0	47,182,200	0	90,027,210	1657.85
6	Cosine Mixture	336,480	0	280,080	0	352,020	0
7	Exponential	342,630	0	332,340	0	275,940	0
8	Levy	3,259,590	0	3,557,190	0	10,003,920	0
9	Michalewicz	201,930	0	55,380	0	301,740	0
10	Dixon-Price	640,680	0	3,690	0	855,780	0
11	Step	62,880	0	54,330	0	65,820	0
12	Schaffer	14,310	0	7,800	0	50,640	0
13	Holder	82,650	0	630	0	34,260	0
14	Beale	11,160	0	11,490	0	12,300	0
15	Shubert	2,430	0	2,220	0	2,760	0
16	Goldstein-Price	4,350	0	3,960	0	4,050	0
17	Six-Hump Camel	750	0	630	0	1,200	0
18	Sphere	4,312,530	0	4,244,760	0	4,402,290	0
19	Parallel Hyper-Ellipsoid	4,222,380	0	4,414,080	0	4,178,970	0
20	Rotated Hyper-Ellipsoid	4,336,590	0	4,142,010	0	4,343,700	0
21	Cigar	4,276,770	0	4,216,170	0	4,277,430	0
22	Brown	4,381,530	0	4,182,030	0	4,232,940	0
23	Multimod	11,442,990	0	10,892,670	0	11,102,340	0
24	Zakharov	90,095,815	1.5E-133	54,198,540	0	90,077,103	4.11E-179
25	Trid	4,142,550	0	51,990	0	1,269,330	0
26	Easom	8,250	0	6,090	0	7,410	0

3. ทดลองเปลี่ยนเปอร์เซ็นต์ของจำนวนมิติทั้งหมดที่จะทำการกลายพันธุ์ตำแหน่ง GBEST โดยเมื่ออนุภาคติดอยู่ใน Local Optima นอกจากใช้การกลายพันธุ์ของอนุภาคแล้ว ยังสามารถใช้การเปลี่ยนตำแหน่งของ GBEST เพื่อช่วยชักนำให้อนุภาคเคลื่อนที่ออกจากตำแหน่งที่ติดอยู่ใน Local Optima ได้ ในการทดลองนี้จะใช้เปอร์เซ็นต์การกลายพันธุ์ของตำแหน่งอนุภาคคงที่ที่ 20 เปอร์เซ็นต์ เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตามผลการทดลองก่อนหน้า แต่จะเปลี่ยนเปอร์เซ็นต์การกลายพันธุ์ของตำแหน่ง GBEST จาก 30 เปอร์เซ็นต์ เป็น 20 และ 40 เปอร์เซ็นต์ ตามลำดับ

จากตารางที่ 5.7 จะเห็นว่า การกลายพันธุ์ด้วย 30 เปอร์เซ็นต์ ให้ผลดีที่สุดคือทำให้เจอค่า Optima ในทุกฟังก์ชัน นอกจากนี้ยังเจอด้วยค่า Evaluation Call ที่ต่ำกว่า

**ตารางที่ 5.7 ผลการค้นหาคำตอบของวิธี MPG-PSO โดยทำการเปลี่ยนเปอร์เซ็นต์การกลายพันธุ์ GBEST จาก 30 เปอร์เซ็นต์ เป็น 20 และ 40 เปอร์เซ็นต์ ตามลำดับ**

NO	Function	กลายพันธุ์ GBEST 20 เปอร์เซ็นต์		กลายพันธุ์ GBEST 30 เปอร์เซ็นต์		กลายพันธุ์ GBEST 40 เปอร์เซ็นต์	
		Evaluation Call	Best Fitness	Evaluation Call	Best Fitness	Evaluation Call	Best Fitness
1	Ackley	1,823,550	0	1,464,330	0	1,411,440	0
2	Griewank	245,010	0	257,310	0	221,970	0
3	Rastrigin	1,708,680	0	1,551,240	0	2,127,180	0
4	Rosenbrock	5,039,790	0	4,701,030	0	90,077,892	2.47E-30
5	Schwefel	90,045,718	236.588	47,182,200	0	90,068,331	355.026
6	Cosine Mixture	358,770	0	280,080	0	398,040	0
7	Exponential	327,780	0	332,340	0	391,650	0
8	Levy	2,927,820	0	3,557,190	0	3,320,490	0
9	Michalewicz	83,490	0	55,380	0	138,330	0
10	Dixon-Price	3,480	0	3,690	0	3,660	0
11	Step	54,120	0	54,330	0	57,360	0
12	Schaffer	98,730	0	7,800	0	7,140	0
13	Holder	13,950	0	630	0	1,860	0
14	Beale	12,000	0	11,490	0	11,250	0
15	Shubert	2,400	0	2,220	0	3,510	0
16	Goldstein-Price	4,260	0	3,960	0	4,230	0
17	Six-Hump Camel	960	0	630	0	1,170	0
18	Sphere	4,294,350	0	4,244,760	0	4,312,770	0
19	Parallel Hyper-Ellipsoid	4,252,380	0	4,414,080	0	4,313,880	0
20	Rotated Hyper-Ellipsoid	4,393,050	0	4,142,010	0	4,329,840	0
21	Cigar	4,372,590	0	4,216,170	0	4,237,890	0
22	Brown	4,352,880	0	4,182,030	0	4,279,830	0
23	Multimod	11,019,480	0	10,892,670	0	11,271,600	0
24	Zakharov	90,057,818	2.86E-178	54,198,540	0	90,048,599	4.33E-164
25	Trid	151,200	0	51,990	0	92,970	0
26	Easom	6,480	0	6,090	0	7,590	0

### 5.3 ทดลองเปลี่ยนตำแหน่งของค่าคำตอบที่ดีที่สุดจากตำแหน่งจุด (0, 0) ไปเป็นตำแหน่งอื่น

เนื่องจากในการค้นหาคำตอบจะใช้วิธีของ PSO คือเคลื่อนตำแหน่งคำตอบไปหาคำตอบที่ดีที่สุด และในระหว่างทางถ้าเจอคำตอบที่ดีกว่าก็จะถูกกำหนดค่าที่ดีที่สุดใหม่ และทำการค้นหาไปเรื่อย ๆ จนกว่าค่าที่ดีที่สุดไม่ดีขึ้นแล้ว วิทยานิพนธ์ฉบับนี้ใช้วิธีการเปลี่ยนแปลงตำแหน่งอนุภาคและตำแหน่ง GBEST ณ จุดที่ติด Local Optima โดยเรียกว่าการกลายพันธุ์ของตำแหน่งอนุภาคและ GBEST ซึ่งสมการการกลายพันธุ์อยู่ในรูปแบบของการสุ่มค่า วิทยานิพนธ์ฉบับนี้เลือกค่าที่ลดลง คืออยู่ในช่วง [0.9, 1] ของค่าเดิม ดังนั้นจะเห็นว่า การกลายพันธุ์จะทำให้ค่าลดลงไปเรื่อย ๆ ทุกครั้งที่มีการกลายพันธุ์ จึงค่อนข้างเหมาะกับการหาคำตอบที่ค่าคำตอบเหมาะสมที่สุดอยู่ที่ตำแหน่ง 0, ..., 0 เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ในทางอื่นโดยไม่ได้รับอนุญาตจากผู้จัดทำเอกสารทุกครั้งที่มีการนำไปใช้

ดังนั้นในการทดลองนี้จึงทดลองเลื่อนคำตอบของแต่ละฟังก์ชันให้ไม่อยู่ที่ตำแหน่ง 0, ..., 0 โดยทำการเลื่อนไป 25 เปอร์เซ็นต์ของ Search Space เพื่อไม่ให้คำตอบอยู่ที่ตำแหน่ง 0, ..., 0 (ยกตัวอย่างเช่น ฟังก์ชันที่ 1 มี Search Space อยู่ที่  $\pm 1$  ถ้าตำแหน่ง Global Optima อยู่ที่ 1, ..., 1 จะทำการเปลี่ยนสมการของฟังก์ชันเลื่อนไปอยู่ที่ 1, ..., 1.5)

จากตารางที่ 5.8 พบว่าเมื่อมีการเปลี่ยนตำแหน่งของค่าคำตอบที่ดีที่สุดจากตำแหน่งจุด (0, 0) ไปทาง Upper Limit 25 เปอร์เซ็นต์ วิธี MPG-PSO มีฟังก์ชันที่ไม่พบคำตอบอยู่ 9 ฟังก์ชัน แต่ในกรณีที่เจอคำตอบจะเจอคำตอบใน Evaluation Call ที่น้อยกว่ามาก เช่น ฟังก์ชัน Griewank ดังนั้นการเปลี่ยนตำแหน่งมีผลต่อวิธี MPG-PSO มาก ทำให้การค้นหาใช้เวลาเพิ่มขึ้นมาก และในบางกรณี (9 ฟังก์ชัน) ก็หาไม่เจอเลย

ตารางที่ 5.8 ผลการค้นหาคำตอบของวิธี MPG-PSO โดยทำการเปลี่ยนตำแหน่งของค่าคำตอบที่ดีที่สุดจากตำแหน่งจุด (0, 0) ไปทาง Upper Limit 25 เปอร์เซ็นต์

NO.	Function	เปลี่ยนไปทาง Upper Limit 25 %		ไม่มีการเลื่อน Optima	
		Evaluation Call	Best Fitness	Evaluation Call	Best Fitness
1	Ackley	90,010,994	3.91E-14	1,464,330	0
2	Griewank	7,333,800	0	257,310	0
3	Rastrigin	90,013,749	6.96471	1,551,240	0
4	Rosenbrock	90,007,626	7.4E-30	4,701,030	0
5	Schwefel	586,950	0	47,182,200	0
6	Cosine Mixture	12,771,810	0	280,080	0
7	Exponential	90,026,745	4.44E-16	332,340	0
8	Levy	4,523,820	0	3,557,190	0
9	Michalewicz	61,350	0	55,380	0
10	Dixon-Price	90,292,020	505.169	3,690	0
11	Step	194,550	0	54,330	0
12	Schaffer	57,810	0	7,800	0
13	Holder	30	0	630	0
14	Beale	12,090	0	11,490	0
15	Shubert	2,010	0	2,220	0
16	Goldstein-Price	90,144,987	9.79E-09	3,960	0
17	Six-Hump Camel	30	0	630	0
18	Sphere	2,547,870	0	4,244,760	0
19	Parallel Hyper-Ellipsoid	1,045,950	0	4,414,080	0
20	Rotated Hyper-Ellipsoid	1,257,390	0	4,142,010	0
21	Cigar	3,540,810	0	4,216,170	0
22	Brown	90,141,316	3984.38	4,182,030	0
23	Multimod	90,161,482	1E+10	10,892,670	0
24	Zakharov	90,223,714	1E+10	54,198,540	0
25	Trid	89,940	0	51,990	0
26	Easom	5,760	0	6,090	0

#### 5.4 การทดลองวัดประสิทธิภาพการค้นหาค่าของขั้นตอนวิธีที่นำเสนอเปรียบเทียบกับ MPG-PSO และ IAC-PSO

ในหัวข้อนี้จะพิจารณาถึงความสามารถในการค้นหาคำตอบของปัญหาฟังก์ชันมาตรฐานด้วย MPG-PSO และ IAC-PSO เพื่อเปรียบเทียบผลการทดลองการหาค่าเหมาะสมที่สุดของทั้ง 2 วิธี ในฟังก์ชัน 2 มิติ, 50 มิติ และ 100 มิติ

เนื่องจากทั้ง MPG-PSO และ IAC-PSO มีวิธีการหลักเป็น PSO เหมือนกัน และมีการนำวิธีการแก้ปัญหาการติด Local Optima ด้วยการเริ่มทำงานใหม่เช่นเดียวกัน คือ หาค่าต่ำสุดของฟังก์ชันที่ทำการทดสอบ วิทยานิพนธ์ฉบับนี้จึงได้นำทั้ง 2 วิธีมาเปรียบเทียบกับ

ตารางที่ 5.9 ค่าพารามิเตอร์ที่ใช้เปรียบเทียบ MPG-PSO กับ IAC-PSO

พารามิเตอร์	ค่า
จำนวนอนุภาคที่ใช้ในการทดลอง	160
จำนวน Iteration ของ IAC-PSO	150
จำนวนครั้งของการคำนวณหาค่าความเหมาะสม คำนวณจาก Evaluation Call = $(lp + R * I * A) * \text{อนุภาค}$	ฟังก์ชัน 2 มิติ 384,000 Calls ฟังก์ชัน 50 มิติ 9,600,000 Calls ฟังก์ชัน 100 มิติ 19,200,000 Calls
จำนวนครั้งของการทำงาน PSO ในขั้นตอนแรก	ฟังก์ชัน 2 มิติ 300 ครั้ง ฟังก์ชัน 50 มิติ 7,500 ครั้ง ฟังก์ชัน 100 มิติ 15,000 ครั้ง

ตารางที่ 5.10 ผลการค้นหาคำตอบของฟังก์ชันมาตรฐาน 2 มิติ ด้วย MPG-PSO กับ IAC-PSO

Function Name	MPG-PSO		*IAC-PSO	
	Evaluation Call	Best Fitness	Evaluation Call	Best Fitness
Easom	29,280	0	20,715	0

ตารางที่ 5.11 ผลการค้นหาคำตอบของฟังก์ชันมาตรฐาน 50 มิติ ด้วย MPG-PSO กับ IAC-PSO

Function Name	MPG-PSO		*IAC-PSO	
	Evaluation Call	Best Fitness	Evaluation Call	Best Fitness
Griewank	292,448	0	496,470	0
Ackley	1,772,320	0	9,600,000	2.22E-14
Rosenbrock	413,344	0	9,600,000	4.91E-04
Dixon-Price	267,296	0	9,600,000	0.667
Trid	397,600	0	86,272	0
Zakharov	9,598,443	7.34E-127	9,600,000	1.45E-17
Rosenbrock No.1	9,599,963	113.819	9,600,000	137.558
Sum of Different	2,136,373	0	9,600,000	3.36E-40
Sum Squares	536,907	0	9,600,000	9.9E-44

ตารางที่ 5.12 ผลการค้นหาคำตอบของฟังก์ชันมาตรฐาน 100 มิติ ด้วย MPG-PSO กับ IAC-PSO

Function Name	MPG-PSO		*IAC-PSO	
	Evaluation Call	Best Fitness	Evaluation Call	Best Fitness
Rastrigin	4,574,787	0	19,200,000	11
Griewank	534,784	0	1,165,967	0
Ackley	3,531,040	0	19,200,000	5.77E-14
Rosenbrock	1,504,288	0	19,200,000	2.27E-08
Dixon-Price	1,112,096	0	19,200,000	0.667
Trid	10,619,040	0	19,200,000	1.58E-05
Zakharov	19,198,523	2.38E-45	19,200,000	3.86E-10
Rosenbrock No.1	19,199,989	233.602	19,200,000	465.480
Sum of Different	10,355,627	0	19,200,000	2.83E-35
Sum Squares	636,533	0	19,200,000	7.44E-41

จากตารางที่ 5.10, 5.11 และ 5.12 ในส่วนของการทดลอง วิธี IAC-PSO ได้มาจากวิทยานิพนธ์ของนายศรณรงค์ ศรีมาคาม [10] โดยค่า Evaluation Call ได้มาจากสมการที่ (5.1)

$$\text{Evaluation Call} = \text{Preliminary} + \text{Generation} * \text{Iteration} * \text{Dimension} \quad (5.1)$$

โดยถ้าคำนวณหาค่า Evaluation Call ของฟังก์ชันคณิตศาสตร์ขนาด 100 มิติ ค่า Preliminary คือ 15,000, ค่า Generation คือ 7, ค่า Iteration คือ 150 และค่า Dimension คือ

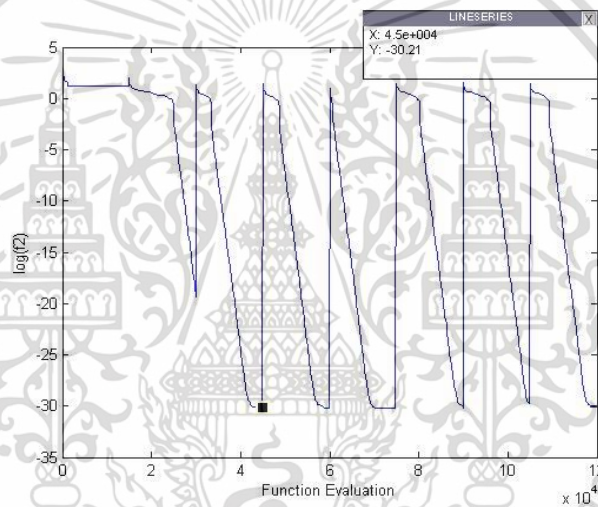
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

100 จะได้เท่ากับ  $15,000 + 7 * 150 * 100 = 120,000$  Evaluation Call แต่เนื่องจากเป็นค่า Evaluation Call ต่ออนุภาคหนึ่งตัว ดังนั้นจึงต้องใช้สมการที่ (5.2) ในการคำนวณ

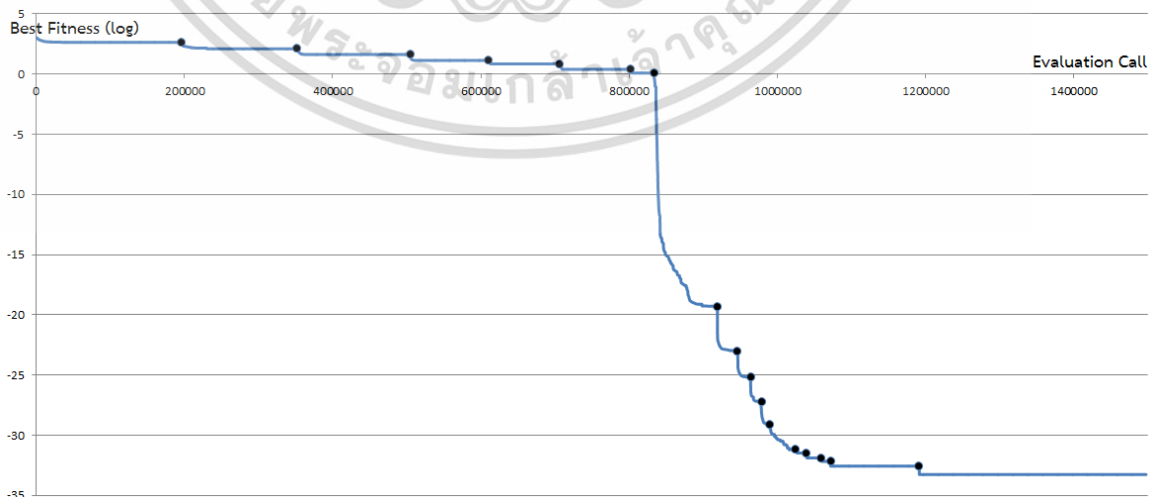
$$\text{Evaluation Call} = (\text{Preliminary} + \text{Generation} * \text{Iteration} * \text{Dimension}) * \text{Population} \quad (5.2)$$

โดยถ้าคำนวณหาค่า Evaluation Call ของฟังก์ชันคณิตศาสตร์ขนาด 100 มิติ จะได้เท่ากับ  $120,000 * 160 = 19,200,00$  Evaluation Call

จากตารางทั้ง 3 พบว่าวิธีการ MPG-PSO สามารถค้นหาคำตอบที่ดีที่สุดได้ในฟังก์ชันต่าง ๆ มากกว่าและใช้จำนวน Evaluation Call น้อยกว่า IAC-PSO เนื่องจากขั้นตอนวิธี IAC-PSO มีการค้นหาแต่ละแกนในทีละมิติ จึงทำให้ใช้เวลาในการค้นหาคำตอบนานและทุกครั้งที่มีการเริ่มทำงานใหม่ จะกลับไปใช้จุดเริ่มต้นเดิม จึงเสียเวลาในการหาคำตอบในกรณีจุดที่ติด Local Optima เดิม ใกล้เคียงกับคำตอบ




รูปที่ 5.6 กราฟแสดงการทำงานของฟังก์ชัน Ackley ด้วยวิธี IAC-PSO

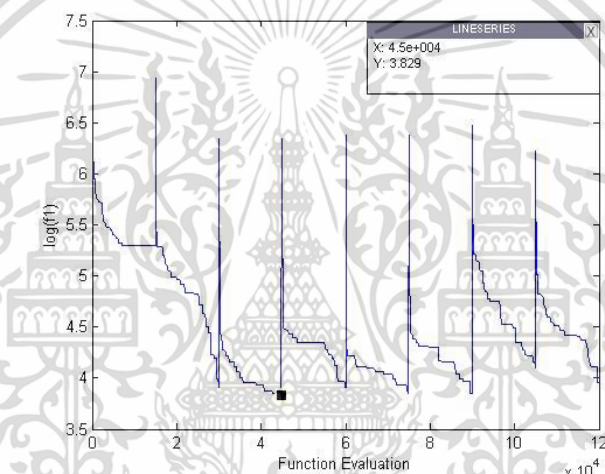


รูปที่ 5.7 กราฟแสดงการทำงานของฟังก์ชัน Ackley ด้วยวิธี MPG-PSO อนุภาค 30 ตัว

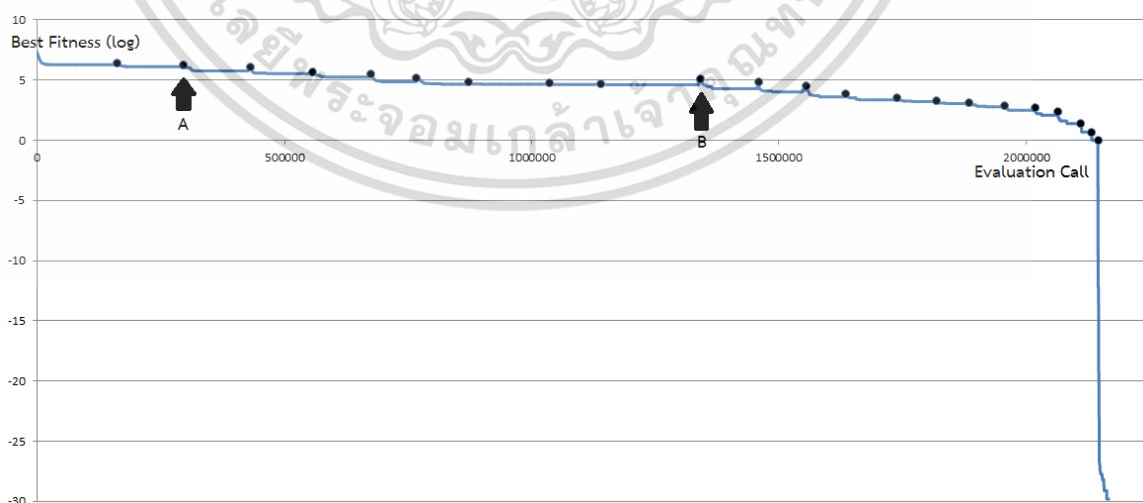
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 5.8 กราฟแสดงการทำงานของฟังก์ชัน Ackley ด้วยวิธี MPG-PSO อนุภาค 160 ตัว




รูปที่ 5.9 กราฟแสดงการทำงานของฟังก์ชัน Rastrigin ด้วยวิธี IAC-PSO



รูปที่ 5.10 กราฟแสดงการทำงานของฟังก์ชัน Rastrigin ด้วยวิธี MPG-PSO อนุภาค 30 ตัว

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 5.11 กราฟแสดงการทำงานของฟังก์ชัน Rastrigin ด้วยวิธี MPG-PSO อนุภาค 160 ตัว

จากรูปที่ 5.6 และ 5.9 ในส่วนของกราฟการทดลอง วิธี IAC-PSO ได้มาจากวิทยานิพนธ์ของ นายศรณรงค์ ศรีมาคาม [10] จุดค่าแสดงค่าต่ำสุดที่ได้ ในฟังก์ชัน Ackley ค่า  $x$  เป็น  $4.5E+04$ , ค่า  $y$  เป็น  $-30.21$  ในฟังก์ชัน Rastrigin ค่า  $x$  เป็น  $4.5E+04$ , ค่า  $y$  เป็น  $3.829$

จากรูปที่ 5.7, 5.8, 5.10 และ 5.11 แสดงการทำงานของ MPG-PSO จะแสดงการเริ่มทำงานใหม่ด้วยการใส่จุดสีดำ ณ Evaluation Call ที่เกิดการเริ่มทำงานใหม่ จุดตัวอย่างในรูปที่ 5.6 ณ จุดเอ ค่า GBEST ก่อนการเริ่มทำงานใหม่ คือ  $6.11304$  ค่า GBEST หลังการเริ่มทำงานใหม่ คือ  $6.24716$  ณ จุดบีค่า GBEST ก่อนการเริ่มทำงานใหม่ คือ  $4.85801$  ค่า GBEST หลังการเริ่มทำงานใหม่ คือ  $5.10941$

โดยจากกราฟแสดงให้เห็นถึงการพบคำตอบที่ดีที่สุดของวิธีการ MPG-PSO เนื่องจาก IAC-PSO มีการค้นหาคำตอบที่ละแกนและที่ละมิติ จึงทำให้ใช้เวลานานกว่าจะพบคำตอบที่ดีที่สุด

## บทที่ 6

# สรุปผลการทดลองและข้อเสนอแนะ

### 6.1 สรุปผลการทดลอง

วิทยานิพนธ์ฉบับนี้พยายามแก้ปัญหาการติดใน Local Optima ของ PSO โดยการใช้การเริ่มทำงานใหม่หลังจากทราบว่าค่า GBEST ไม่ดีขึ้นภายในจำนวนรอบที่กำหนด เป็นตัววัดว่า PSO ติดอยู่ใน Local Optima โดยการเริ่มทำงานใหม่จะมีการเปลี่ยนตำแหน่งอนุภาคเพียงเล็กน้อยในจำนวนมิติ 20 เฟอร์เซ็นต์ของจำนวนมิติทั้งหมด นอกจากนี้ยังมีการใช้ค่า GBEST ของตำแหน่งอนุภาคที่ดีที่สุดหลังการเปลี่ยนตำแหน่งมาทำการเปลี่ยนตำแหน่ง GBEST เพียงเล็กน้อยในจำนวนมิติ 30 เฟอร์เซ็นต์ของจำนวนมิติทั้งหมด เพื่อช่วยเหนี่ยวนำให้กลุ่มอนุภาคเคลื่อนออกจากตำแหน่ง Local Optima เดิม กระบวนการนี้จะทำไปเรื่อย ๆ จนกว่าจะครบจำนวนรอบที่กำหนด ดังนั้นในการทำงานครั้งหนึ่งอาจจะมีการเริ่มทำงานใหม่หลายครั้งขึ้นกับว่ามีการติด Local Optima ก็ครั้ง ในการติดแต่ละครั้งไม่สามารถยืนยันได้ว่าค่า GBEST จะดีขึ้นทุกครั้ง แต่สามารถบังคับให้อนุภาคเคลื่อนที่ออกจาก Local Optima และมีการค้นหาเพิ่มเติมได้ ในบางกรณีก็อาจจะกลับไปติดที่ Local Optima เดิม แต่จากผลการทดลอง MPG-PSO ที่นำเสนอสามารถหาค่า Global Optima เจอในทุกฟังก์ชันคณิตศาสตร์ และยังหาเจอใน Evaluation Call ที่น้อยกว่าวิธีที่นำมาเปรียบเทียบมาก

จุดเด่นของวิธีนี้คือ มีการทำงานที่เรียบง่ายและเหมือนกับ PSO แตกต่างแค่มีการเริ่มทำงานใหม่ โดยจุดสำคัญของวิธีนี้จะใช้การกลายพันธุ์ของตำแหน่งอนุภาคเพียงเล็กน้อยแทนที่จะสุ่มใหม่จาก Search Space ทั้งหมด นอกจากนี้จำเป็นที่จะต้องกลายพันธุ์ GBEST ด้วย จึงจะทำให้หาคำตอบ ณ จุด Global Optima ได้ในเวลาที่รวดเร็ว ถ้ามีเพียงแต่การเปลี่ยนตำแหน่งอนุภาคหรือเปลี่ยนตำแหน่ง GBEST เพียงอย่างเดียว ไม่เพียงพอที่จะทำให้เจอจุด Global Optima ได้ทุกฟังก์ชันในเวลาที่รวดเร็ว

### 6.2 ข้อเสนอแนะ

จากการทดลองในบทที่ 5 การทดลองที่มีการเปลี่ยนตำแหน่งของค่าคำตอบที่ดีที่สุดออกจากตำแหน่ง (0, 0) วิธี MPG-PSO ไม่สามารถหาคำตอบได้ใน 9 จาก 26 ฟังก์ชันคณิตศาสตร์ และในฟังก์ชันที่หาเจอก็ใช้เวลาเพิ่มขึ้นมาก จึงควรจะต้องมีการค้นคว้าเพิ่มเติมถึงขั้นตอนการกลายพันธุ์ที่เหมาะสมเพื่อแก้ไขปัญหานี้

## เอกสารอ้างอิง

- [1] R. C. Eberhart, and J. Kennedy, "Particle Swarm Optimization," IEEE International Conference on Neural Networks, pp. 1942-1948, 1995..
- [2] R. C. Eberhart, and J. Kennedy, "A New Optimizer Using Particle Swarm Theory," Proceed-ings of the 6th International Symposium on Micro Machine and Human Science, pp. 39-43, 1995.
- [3] C. Ratanavilisagul, and B. Kruatrachue, "A Modified Particle Swarm Optimization with Mutation and Reposition," ICIC international, 2014.
- [4] [https://en.wikipedia.org/wiki/Genetic\\_algorithm](https://en.wikipedia.org/wiki/Genetic_algorithm)
- [5] [https://en.wikipedia.org/wiki/Local\\_optimum](https://en.wikipedia.org/wiki/Local_optimum)
- [6] [https://en.wikipedia.org/wiki/Maxima\\_and\\_minima](https://en.wikipedia.org/wiki/Maxima_and_minima)
- [7] Momin Jamil and Xin-She Yang, "A Literature Survey of Benchmark Functions For Global Optimization Problems", Int. Journal of Mathematical Modelling and Numerical Optimization, Vol. 4, No. 2, pp. 150-194 (2013).
- [8] Virtual Library of Simulation Experiments: Test Functions and Datasets, <https://www.sfu.ca/~ssurjano/optimization.html>
- [9] K. Chengkhuntod, B. Kruatrachue, and K. Siriboon, "Improving Multi-Swarm by Slightly Mutation Particle and GBEST of Stuck Swarm Along with Randomly Selecting GBEST of other Swarm", The 21<sup>st</sup> International Computer Science and Engineering Conference 2017, November 15-18, 2017 Bangkok, Thailand.
- [10] S. Srimakham and K. Jearanaitanakij, "Improving Particle Swarm Optimization by Using Incremental Attribute Learning and Centroid of Particle's Best Position", 2017 14th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON)
- [11] H. Gao and W. Xu, "Particle swarm algorithm with hybrid mutation strategy Applied Soft Computing", pp. 5129-5142, 2011.
- [12] <http://benchmarkfcns.xyz/unimodal>
- [13] <http://benchmarkfcns.xyz/multimodal>



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## ภาคผนวก ก

# ปัญหาของฟังก์ชันมาตรฐานที่ใช้ในการทดลอง

ฟังก์ชันมาตรฐานที่นำมาทดลองจะใช้ตั้งแต่ 2 มิติ ถึง 100 มิติ ใช้ในการเปรียบเทียบประสิทธิภาพของขั้นตอนวิธีที่ใช้ค้นหาค่าคำตอบที่ดีที่สุด โดยมีทั้งหมด 26 ฟังก์ชัน สำหรับรายละเอียดของฟังก์ชันแสดงไว้ในตาราง ก.1 และรูปฟังก์ชันได้แสดงไว้ในรูป ก.1 ถึง ก.26

ตารางที่ ก.1 สรุปคุณสมบัติของฟังก์ชันมาตรฐานที่ใช้ในการทดลอง

ชื่อฟังก์ชัน	ขอบเขต $[X_{\max}, X_{\min}]$	จุดที่ดีที่สุด	จำนวนมิติ	คุณสมบัติ	$f(X^*)=0$
ACKLEY	$x \in [-32, 768, 32, 768]^n$	$f(x) = 0$	100	Multimodal	(0,...,0)
GRIEWANK	$x \in [-300, 300]^n$	$f(x) = 0$	100	Multimodal	(0,...,0)
RASTRIGIN	$x \in [-5, 12, 5, 12]^n$	$f(x) = 0$	100	Multimodal	(0,...,0)
ROSENBROCK	$x \in [-2, 048, 2, 048]^n$	$f(x) = 0$	100	Multimodal	(1,...,1)
SCHWEFEL	$x \in [-500, 500]^n$	$f(x) = 0$	100	Multimodal	(420.9687,..., 420.9687)
COSINE MIXTURE	$x \in [-1, 1]^n$	$f(x) = 0$	100	Multimodal	(0,...,0)
EXPONENTIAL	$x \in [-5, 12, 5, 12]^n$	$f(x) = 0$	100	Multimodal	(0,...,0)
LEVY	$x \in [-5, 12, 5, 12]^n$	$f(x) = 0$	100	Multimodal	(1,...,1)
MICHALEWICZ	$x \in [-65, 536, 65, 536]^n$	$f(x) = 0$	100	Multimodal	(2,20, 1,57)
DIXON-PRICE	$x \in [0, PI]^n$	$f(x) = 0$	10	Multimodal	(0,...,0)
STEP	$x \in [-100, 100]^n$	$f(x) = 0$	100	Multimodal	(0.5,..., 0.5)
SCHAFFER	$x \in [-100, 100]^n$	$f(x) = 0$	2	Multimodal	(0,...,0)
HOLDER	$x \in [-10, 10]^n$	$f(x) = 0$	2	Multimodal	(-8.05502, 9.66459)
BEALE	$x \in [-4, 5, 4, 5]^n$	$f(x) = 0$	2	Multimodal	(3,0.5)
SHUBERT	$x \in [-10, 10]^n$	$f(x) = 0$	2	Multimodal	(0,...,0)
GOLDSTEIN-PRICE	$x \in [-2, 2]^n \cdot f(X^*) = 3$	$f(x) = 0$	2	Multimodal	(0,-1)
SIX-HUMP CAMEL	$x \in [-2, 2]^n$	$f(x) = 0$	2	Multimodal	(0.0898,-0.7126)
SPHERE	$x \in [-5, 12, 5, 12]^n$	$f(x) = 0$	100	Unimodal	(0,...,0)
PARALLEL	$x \in [-5, 12, 5, 12]^n$	$f(x) = 0$	100	Unimodal	(0,...,0)
ROTATED	$x \in [-65, 536, 65, 536]^n$	$f(x) = 0$	100	Unimodal	(0,...,0)
CIGAR	$x \in [-10, 10]^n$	$f(x) = 0$	100	Unimodal	(0,...,0)
BROWN	$x \in [-1, 4]^n$	$f(x) = 0$	100	Unimodal	(0,...,0)
MULTIMOD	$x \in [-10, 10]^n$	$f(x) = 0$	100	Unimodal	(0,...,0)
ZAKHAROV	$x \in [-5, 10]^n$	$f(x) = 0$	100	Unimodal	(0,...,0)
TRID	$x \in [-100, 100]^n$	$f(x) = 0$	10	Multimodal	$(-d^2, d^2)$
EASOM	$x \in [-100, 100]^n$	$f(x) = 0$	2	Unimodal	(0,...,0)
ROSENBROCK NO.1	$x \in [-2000, 2000]^n$	$f(x) = 0$	50/100	Multimodal	(1,...,1)
SUM OF DIFFERENT	$x \in [-1, 1]^n$	$f(x) = 0$	50/100	Multimodal	(0,...,0)
SUM SQUARES	$x \in [-10, 10]^n$	$f(x) = 0$	50/100	Multimodal	(0,...,0)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

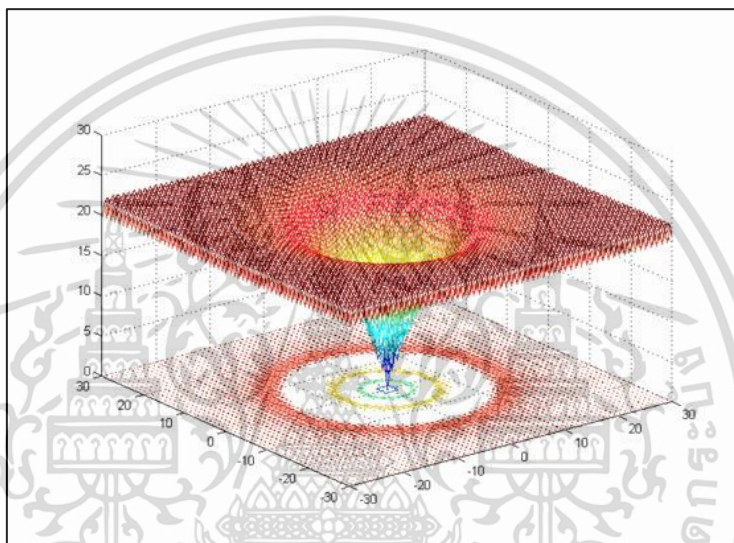
- ฟังก์ชัน ACKLEY

ฟังก์ชัน ACKLEY เป็นฟังก์ชันแบบ Multimodal โดยรูปของฟังก์ชันคือรูป ก.1 และสมการของฟังก์ชันคือสมการ ก.1

$$f(x) = -20 \exp\left(-0.2 \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}\right) - \exp\left(\frac{1}{n} \sum_{i=1}^n \cos(2\pi x_i)\right) + 20 + e \quad (\text{ก.1})$$

มีขอบเขตอยู่ในช่วง  $x \in [-30, 30]^n$

ค่าสูงสุดสัมบูรณ์ คือ  $x^* = (0, \dots, 0), f(x^*) = 0$



รูปที่ ก.1 ฟังก์ชัน ACKLEY

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


- ฟังก์ชัน GRIEWANK

ฟังก์ชัน GRIEWANK เป็นฟังก์ชันแบบ Multimodal โดยรูปของฟังก์ชันคือรูป ก.2 และสมการของฟังก์ชันคือสมการ ก.2

$$f(x) = \sum_{i=1}^n \frac{x_i^2}{4000} - \prod_{i=1}^n \cos(x_i / \sqrt{i}) + 1 \quad (\text{ก.2})$$

มีขอบเขตอยู่ในช่วง  $x \in [-300, 300]^n$

ค่าสูงสุดสัมบูรณ์ คือ  $x^* = (0, \dots, 0), f(x^*) = 0$



รูปที่ ก.2 ฟังก์ชัน GRIEWANK

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


- ฟังก์ชัน RASTRIGIN

ฟังก์ชัน RASTRIGIN เป็นฟังก์ชันแบบ Multimodal โดยรูปของฟังก์ชันคือรูป ก.3 และสมการของฟังก์ชันคือสมการ ก.3

$$f(x) = 10n + \sum_{i=1}^n (x_i^2 - 10 \cos(2\pi x_i)) \quad (\text{ก.3})$$

มีขอบเขตอยู่ในช่วง  $x \in [-5.12, 5.12]^n$

ค่าสูงสุดสัมบูรณ์ คือ  $x^* = (0, \dots, 0), f(x^*) = 0$



รูปที่ ก.3 ฟังก์ชัน RASTRIGIN

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

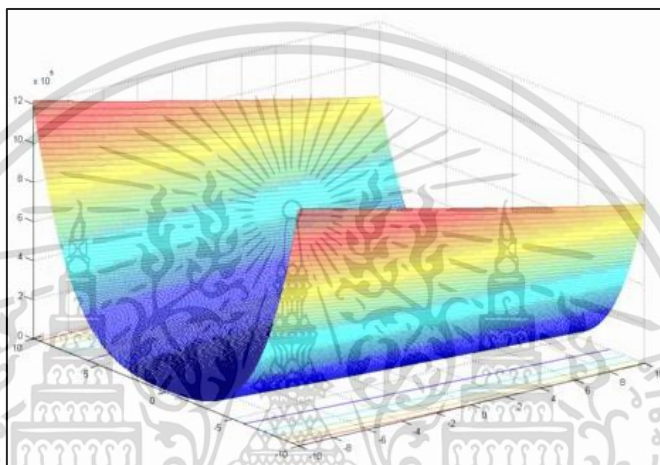
- ฟังก์ชัน ROSENBROCK

ฟังก์ชัน ROSENBROCK เป็นฟังก์ชัน Unimodal โดยรูปของฟังก์ชันคือรูป ก.4 และสมการของฟังก์ชันคือสมการ ก.4

$$f(x) = \sum_{i=1}^n [100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2] \quad (\text{ก.4})$$

มีขอบเขตอยู่ในช่วง  $x \in [-2.048, 2.048]^n$

ค่าสูงสุดสัมบูรณ์ คือ  $x^* = (1, \dots, 1), f(x^*) = 0$



รูปที่ ก.4 ฟังก์ชัน ROSENBROCK

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

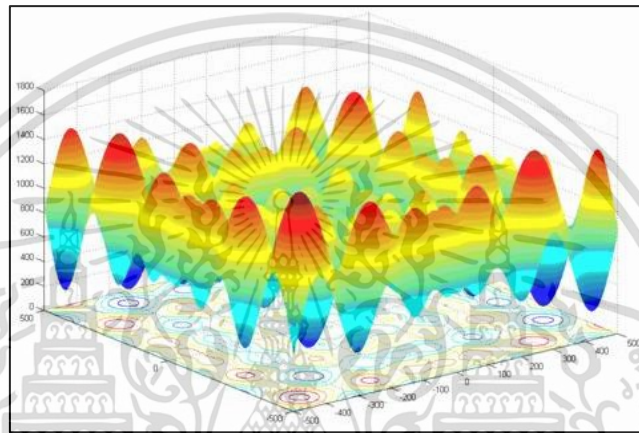
- ฟังก์ชัน SCHWEFEL

ฟังก์ชัน SCHWEFEL เป็นฟังก์ชันแบบ Multimodal โดยรูปของฟังก์ชันคือรูป ก.5 และสมการของฟังก์ชัน คือสมการ ก.5

$$f(x) = 418.9829 \times n + \sum_{i=1}^n (x_i \times \sin(\sqrt{|x_i|})) \quad (\text{ก.5})$$

มีขอบเขตอยู่ในช่วง  $x \in [-500, 500]^n$

ค่าสูงสุดสัมบูรณ์ คือ  $x^* = (-420.96, \dots, -420.96), f(x^*) = 0$



รูปที่ ก.5 ฟังก์ชัน SCHWEFEL

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


- ฟังก์ชัน COSINE MIXTURE

ฟังก์ชัน COSINE MIXTURE เป็นฟังก์ชันแบบ Multimodal โดยรูปของฟังก์ชันคือรูป ก.6 และสมการของฟังก์ชันคือสมการ ก.6

$$f(x) = -0.1 \times \sum_{i=0}^n \cos(5\pi x_i) + \sum_{i=0}^n x_i^2 + 0.1n \quad (\text{ก.6})$$

มีขอบเขตอยู่ในช่วง  $x \in [-1,1]^n$

ค่าสูงสุดสัมบูรณ์ คือ  $x^* = (0, \dots, 0), f(x^*) = 0$



รูปที่ ก.6 ฟังก์ชัน COSINE MIXTURE

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

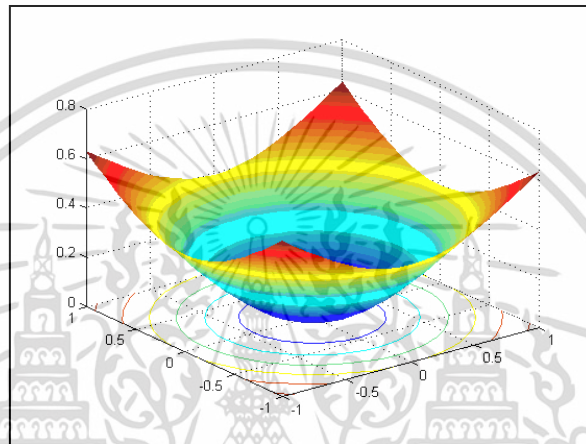
- ฟังก์ชัน EXPONENTIAL

ฟังก์ชัน EXPONENTIAL เป็นฟังก์ชันแบบ Multimodal โดยรูปของฟังก์ชันคือรูป ก.7 และสมการของฟังก์ชันคือสมการ ก.7

$$f(x) = -\exp(-0.5 \sum_{i=1}^n x_i^2) + 1 \quad (\text{ก.7})$$

มีขอบเขตอยู่ในช่วง  $x \in [-1,1]^n$

ค่าสูงสุดสัมบูรณ์ คือ  $x^* = (0, \dots, 0), f(x^*) = 0$



รูปที่ ก.7 ฟังก์ชัน EXPONENTIAL

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- ฟังก์ชัน LEVY

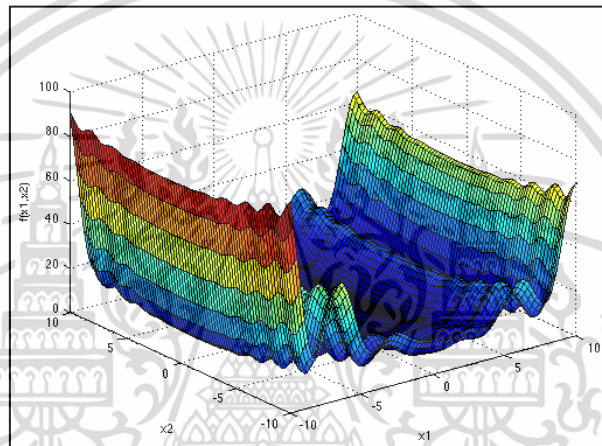
ฟังก์ชัน LEVY เป็นฟังก์ชันแบบ Multimodal โดยรูปของฟังก์ชันคือรูป ก.8 และสมการของฟังก์ชันคือสมการ ก.8

$$f(x) = \sin^2(\pi w_1) + \sum_{i=1}^{d-1} (w_i - 1)^2 [1 + 10 \sin^2(\pi w_i + 1)] + (w_d - 1)^2 [1 + \sin^2(2\pi w_d)] \quad (ก.8)$$

$$w_i = 1 + \frac{x_i - 1}{4}, \text{ for all } i = 1, \dots, d$$

มีขอบเขตอยู่ในช่วง  $x \in [-10, 10]^n$

ค่าสูงสุดสัมบูรณ์ คือ  $x^* = (1, \dots, 1), f(x^*) = 0$



รูปที่ ก.8 ฟังก์ชัน LEVY

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- ฟังก์ชัน MICHALEWICZ

ฟังก์ชัน MICHALEWICZ เป็นฟังก์ชันแบบ Multimodal โดยรูปของฟังก์ชันคือรูป ก.9 และสมการของฟังก์ชันคือสมการ ก.9


$$f(x) = -\sum_{i=1}^d \sin(x_i) \sin^{2m}\left(\frac{ix_i^2}{\pi}\right) \quad (\text{ก.9})$$

มีขอบเขตอยู่ในช่วง  $x \in [0, \pi]^n$

ค่าสูงสุดสัมบูรณ์ คือ  $d = 2: f(x^*) = -1.8013, x^* = (2.20, 1.57)$

$d = 5: f(x^*) = -4.687658$

$d = 10: f(x^*) = -9.66015$



รูปที่ ก.9 ฟังก์ชัน MICHALEWICZ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นอนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

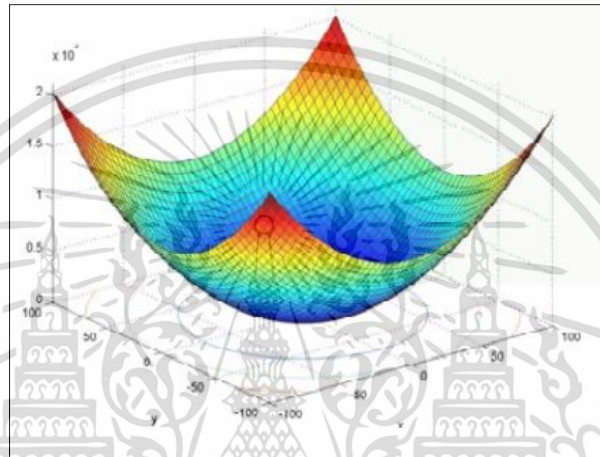
- ฟังก์ชัน STEP

ฟังก์ชัน STEP เป็นฟังก์ชันแบบ Multimodal โดยรูปของฟังก์ชันคือรูป ก.10 และสมการของฟังก์ชันคือสมการ ก.10

$$f(x) = \sum_{i=0}^{n-1} (\lfloor x_i \rfloor + 0.5)^2 \quad (\text{ก.10})$$

มีขอบเขตอยู่ในช่วง  $x \in [-100, 100]$

ค่าสูงสุดสัมบูรณ์ คือ  $x^* = (0.5, \dots, 0.5), f(x^*) = 0$



รูปที่ ก.10 ฟังก์ชัน STEP

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


- ฟังก์ชัน SCHAFFER

ฟังก์ชัน SCHAFFER เป็นฟังก์ชันแบบ Multimodal โดยรูปของฟังก์ชันคือรูป ก.11 และสมการของฟังก์ชันคือสมการ ก.11

$$f(x) = 0.5 + \frac{\sin^2 \sqrt{x^2 + y^2} - 0.5}{(1.0 + 0.001 \times (x^2 + y^2))^2} \quad (\text{ก.11})$$

มีขอบเขตอยู่ในช่วง  $x \in [-100, 100]$

ค่าสูงสุดสัมบูรณ์ คือ  $x^* = (0, \dots, 0), f(x^*) = 0$



รูปที่ ก.11 ฟังก์ชัน SCHAFFER

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- ฟังก์ชัน HOLDER

ฟังก์ชัน HOLDER เป็นฟังก์ชันแบบ Multimodal โดยรูปของฟังก์ชันคือรูป ก.12 และสมการของฟังก์ชันคือสมการ ก.12

$$f(x) = -\left| \sin(x_1) \cos(x_2) e^{\left(1 - \sqrt{\frac{x_1^2 + x_2^2}{\pi}}\right)} \right| \quad (\text{ก.12})$$

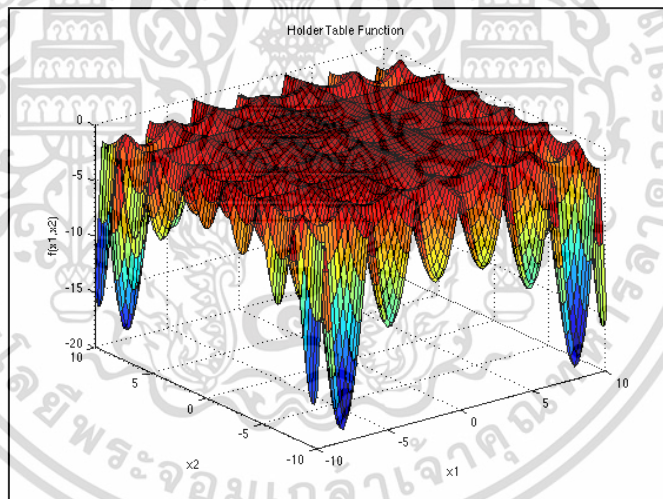
มีขอบเขตอยู่ในช่วง  $x \in [-10, 10]^n$

ค่าสูงสุดสัมบูรณ์ คือ  $x^* = (8.05502, 9.66459), f(x^*) = -19.2085$

$x^* = (8.05502, -9.66459), f(x) = -19.2085$

$x^* = (-8.05502, 9.66459), f(x) = -19.2085$

$x^* = (-8.05502, -9.66459), f(x) = -19.2085$



รูปที่ ก.12 ฟังก์ชัน HOLDER

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

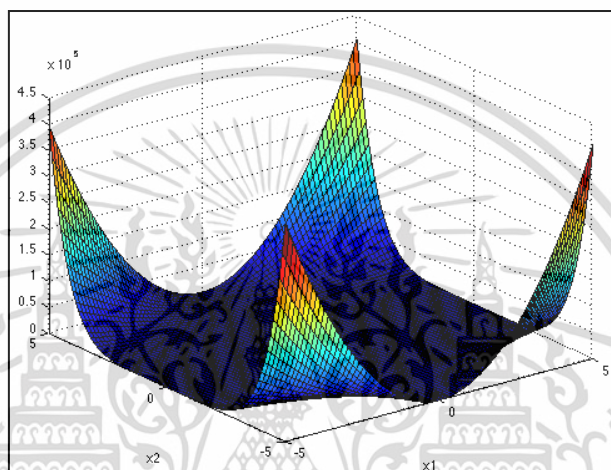
- ฟังก์ชัน BEALE

ฟังก์ชัน BEALE เป็นฟังก์ชันแบบ Multimodal โดยรูปของฟังก์ชันคือรูป ก.13 และสมการของฟังก์ชันคือสมการ ก.13

$$f(x) = (1.5 - x_1 + x_1x_2)^2 + (2.25 - x_1 + x_1x_2^2)^2 + (2.625 - x_1 + x_1x_2^3)^2 \quad (\text{ก.13})$$

มีขอบเขตอยู่ในช่วง  $x \in [-4.5, 4.5]^n$

ค่าสูงสุดสัมบูรณ์ คือ  $x^* = (3, 0.5), f(x^*) = 0$



รูปที่ ก.13 ฟังก์ชัน BEALE

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

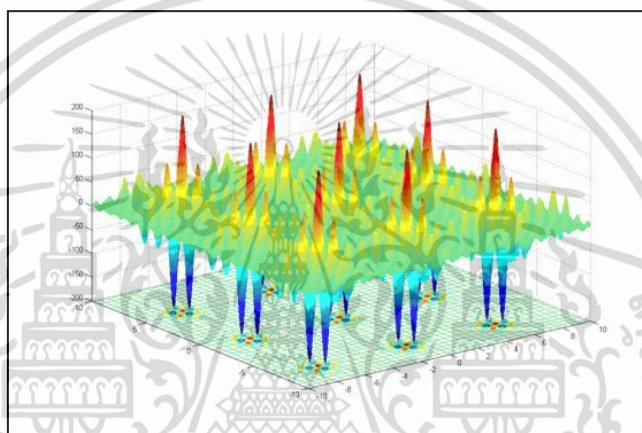
- ฟังก์ชัน SHUBERT

ฟังก์ชัน SHUBERT เป็นฟังก์ชันแบบ Multimodal โดยรูปของฟังก์ชันคือรูป ก.14 และสมการของฟังก์ชันคือสมการ ก.14

$$f(x) = \sum_{i=1}^5 i \cos((i+1)x_1 + i) \left( \sum_{i=1}^5 i \cos((i+1)x_2 + i) \right) \quad (\text{ก.14})$$

มีขอบเขตอยู่ในช่วง  $x \in [-10, 10]^n$

ค่าสูงสุดสัมบูรณ์ คือ  $f(x^*) = -186.7309$



รูปที่ ก.14 ฟังก์ชัน SHUBERT

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- ฟังก์ชัน GOLDSTEIN-PRICE


ฟังก์ชัน GOLDSTEIN-PRICE เป็นฟังก์ชันแบบ Multimodal โดยรูปของฟังก์ชันคือรูป ก.15 และสมการของฟังก์ชันคือสมการ ก.15

$$f(x^*) = [1 + (x_1 + x_2 + 1)^2 (19 - 14x_1 + 3x_1^2 - 14x_2 + 6x_1x_2 + 3x_2^2)] \quad (ก.15)$$

$$\times [30 + (2x_1 - 3x_2)^2 (18 - 32x_1 + 12x_1^2 + 48x_2 - 36x_1x_2 + 27x_2^2)]$$

มีขอบเขตอยู่ในช่วง  $x \in [-2, 2]^n$

ค่าสูงสุดสัมบูรณ์ คือ  $x^* = (0, 1), f(x^*) = 3$



รูปที่ ก.15 ฟังก์ชัน GOLDSTEIN-PRICE

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- ฟังก์ชัน TRID


ฟังก์ชัน TRID เป็นฟังก์ชันแบบ Multimodal โดยรูปของฟังก์ชันคือรูป ก.16 และสมการของฟังก์ชันคือสมการ ก.16

$$f(x) = \sum_{i=1}^d (x_i - 1)^2 - \sum_{i=2}^d x_i x_{i-1} \quad (\text{ก.16})$$

มีขอบเขตอยู่ในช่วง  $x \in [-d^2, d^2]^n$

ค่าสูงสุดสัมบูรณ์ คือ  $d = 6: f(x^*) = 3$

$d = 10: f(x^*) = -200$



รูปที่ ก.16 ฟังก์ชัน TRID

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

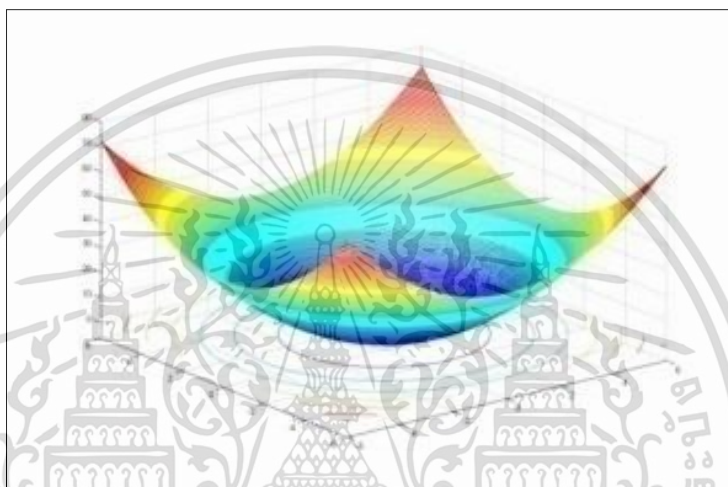
- ฟังก์ชัน SPHERE

ฟังก์ชัน SPHERE เป็นฟังก์ชัน Unimodal โดยรูปของฟังก์ชันคือรูป ก.17 และสมการของฟังก์ชันคือสมการ ก.17

$$f(x) = \sum_{i=1}^n x_i^2 \quad (\text{ก.17})$$

มีขอบเขตอยู่ในช่วง  $x \in [-5.12, 5.12]^n$

ค่าสูงสุดสัมบูรณ์ คือ  $x^* = (0, \dots, 0), f(x^*) = 0$



รูปที่ ก.17 ฟังก์ชัน SPHERE

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


- ฟังก์ชัน PARALLEL ELLIPSOID

ฟังก์ชัน PARALLEL ELLIPSOID เป็นฟังก์ชันแบบ Unimodal โดยรูปของฟังก์ชันคือรูป ก.18 และสมการของฟังก์ชันคือสมการ ก.18

$$f(x) = \sum_{i=1}^n (i \times x_i^2) \quad (\text{ก.18})$$

มีขอบเขตอยู่ในช่วง  $x \in [-5.12, 5.12]^n$

ค่าสูงสุดสัมบูรณ์ คือ  $x^* = (0, \dots, 0), f(x^*) = 0$



รูปที่ ก.18 ฟังก์ชัน PARALLEL ELLIPSOID

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


- ฟังก์ชัน ROTATED ELLIPSOID

ฟังก์ชัน ROTATED ELLIPSOID เป็นฟังก์ชันแบบ Unimodal โดยรูปของฟังก์ชันคือรูป ก.19 และสมการของฟังก์ชันคือสมการ ก.19

$$f(x) = \sum_{i=1}^n (\sum_{j=1}^i x_j^2) \quad (\text{ก.19})$$

มีขอบเขตอยู่ในช่วง  $x \in [-65.536, 65.536]^n$

ค่าสูงสุดสัมบูรณ์ คือ  $x^* = (0, \dots, 0), f(x^*) = 0$



รูปที่ ก.19 ฟังก์ชัน ROTATED ELLIPSOID

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


- ฟังก์ชัน CIGAR

ฟังก์ชัน CIGAR เป็นฟังก์ชัน Unimodal โดยรูปของฟังก์ชันคือรูป ก.20 และสมการของฟังก์ชันคือสมการ ก.20

$$f(x) = x_0^2 + 10^6 \sum_{i=1}^N x_i^2 \quad (\text{ก.20})$$

มีขอบเขตอยู่ในช่วง  $x \in [-10, 10]^n$

ค่าสูงสุดสัมบูรณ์ คือ  $x^* = (0, \dots, 0), f(x^*) = 0$



รูปที่ ก.20 ฟังก์ชัน CIGAR

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


- ฟังก์ชัน BROWN

ฟังก์ชัน BROWN เป็นฟังก์ชัน Unimodal โดยรูปของฟังก์ชันคือรูป ก.21 และสมการของฟังก์ชันคือสมการ ก.21

$$f(x) = \sum_{i=0}^{n-1} [(x_i^2)^{(x_{i+1}^2+1)} + (x_{i+1}^2)^{(x_i^2+1)}] \quad (\text{ก.21})$$

มีขอบเขตอยู่ในช่วง  $x \in [-1, 4]$

ค่าสูงสุดสัมบูรณ์ คือ  $x^* = (0, \dots, 0), f(x^*) = 0$



รูปที่ ก.21 ฟังก์ชัน BROWN

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


- ฟังก์ชัน MULTIMOD

ฟังก์ชัน MULTIMOD เป็นฟังก์ชัน Unimodal โดยรูปของฟังก์ชันคือรูป ก.22 และสมการของฟังก์ชันคือสมการ ก.22

$$f(x) = \sum_{i=1}^n |x_i| \times \prod_{i=1}^n |x_i| \quad (\text{ก.22})$$

มีขอบเขตอยู่ในช่วง  $x \in [-10, 10]^n$

ค่าสูงสุดสัมบูรณ์ คือ  $x^* = (0, \dots, 0), f(x^*) = 0$



รูปที่ ก.22 ฟังก์ชัน MULTIMOD

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

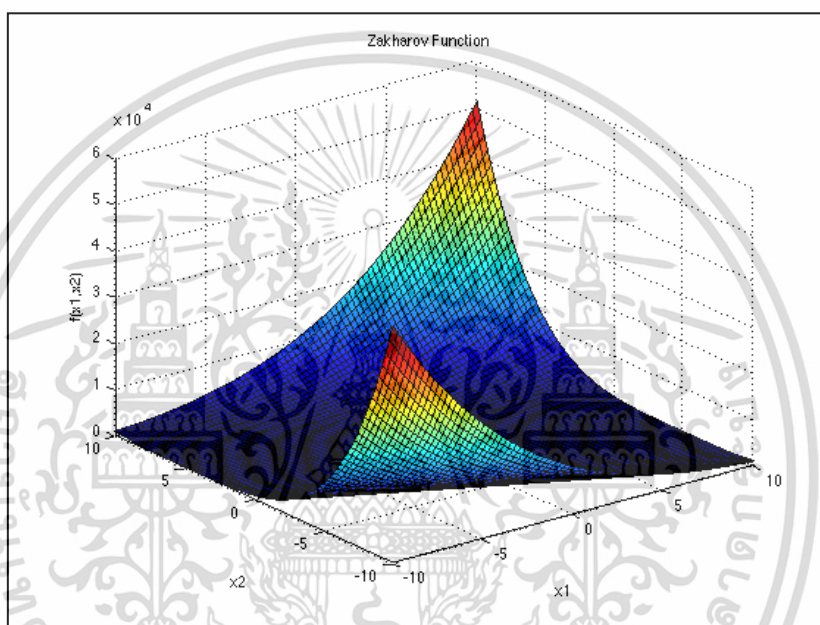
- ฟังก์ชัน ZAKHAROV

ฟังก์ชัน ZAKHAROV เป็นฟังก์ชัน Unimodal โดยรูปของฟังก์ชันคือรูป ก.23 และสมการของฟังก์ชันคือสมการ ก.23

$$f(x) = \sum_{i=1}^n x_i^2 + \left[ \sum_{i=1}^n \frac{i}{2} x_i \right]^2 + \left[ \sum_{i=1}^n \frac{i}{2} x_i \right]^4 \quad (\text{ก.23})$$

มีขอบเขตอยู่ในช่วง  $x \in [-5, 10]$

ค่าสูงสุดสัมบูรณ์ คือ  $x^* = (0, \dots, 0), f(x^*) = 0$



รูปที่ ก.23 ฟังก์ชัน ZAKHAROV

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

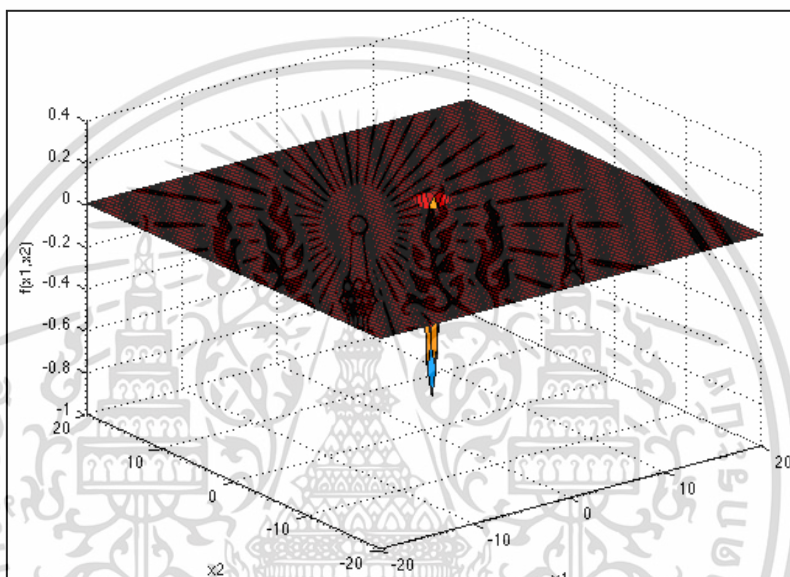
- ฟังก์ชัน EASOM

ฟังก์ชัน EASOM เป็นฟังก์ชันแบบ Unimodal โดยรูปของฟังก์ชันคือรูป ก.24 และสมการของฟังก์ชันคือสมการ ก.24

$$f(x) = -\cos(x_1) \cos(x_2) \exp(-(x_1 - \pi)^2 - (x_2 - \pi)^2) \quad (\text{ก.24})$$

มีขอบเขตอยู่ในช่วง  $x \in [-100, 100]$

ค่าสูงสุดสัมบูรณ์ คือ  $x^* = (\pi, \pi), f(x^*) = -1$



รูปที่ ก.24 ฟังก์ชัน EASOM

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


- ฟังก์ชัน DIXON-PRICE

ฟังก์ชัน DIXON-PRICE เป็นฟังก์ชันแบบ Multimodal โดยรูปของฟังก์ชันคือรูป ก.25 และสมการของฟังก์ชันคือสมการ ก.25

$$f(x) = (x_1 - 1)^2 + \sum_{i=2}^d i(2x_i^2 - x_{i-1})^2 \quad (\text{ก.25})$$

มีขอบเขตอยู่ในช่วง  $x \in [-10, 10]^n$

ค่าสูงสุดสัมบูรณ์ คือ  $f(x^*) = 0$



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

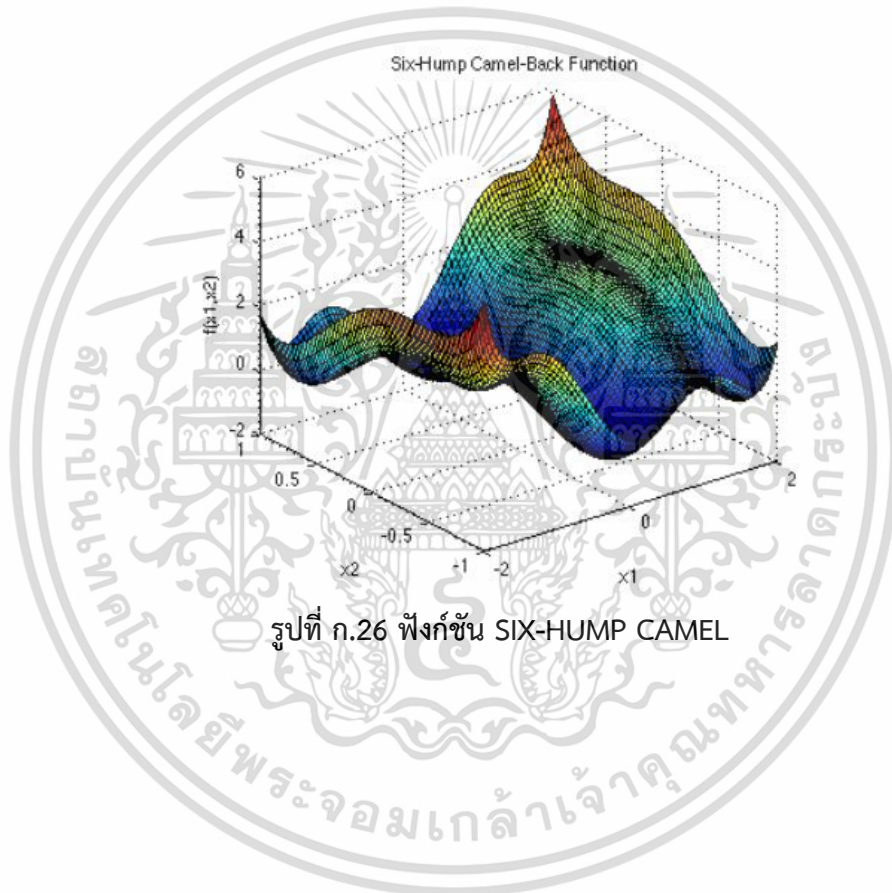
- ฟังก์ชัน SIX-HUMP CAMEL

ฟังก์ชัน SIX-HUMP CAMEL เป็นฟังก์ชันแบบ Multimodal โดยรูปของฟังก์ชันคือรูป ก.26 และสมการของฟังก์ชันคือสมการ ก.26

$$f(x) = \left(4 - 2.1x_1^2 + \frac{x_1^4}{3}\right)x_1^2 + x_1x_2 + (-4 + 4x_2^2) \quad (\text{ก.26})$$

มีขอบเขตอยู่ในช่วง  $x \in [-2, 2]^n$

ค่าสูงสุดสัมบูรณ์ คือ  $f(x^*) = 0$



รูปที่ ก.26 ฟังก์ชัน SIX-HUMP CAMEL

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



ภาคผนวก ข  
งานวิจัยที่ได้รับการตีพิมพ์

Varothon Cheypoca, Kritawan Siriboon and Boontee Kruatrachue, “The use of Global Best position in rerun of particle swarm optimization” The 4th International Conference on Engineering, Applied Sciences and Technology (ICEAST 2018), 4-7 July 2018, Phuket, Thailand

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



QR Code

# iceast 2018

The 4<sup>th</sup> International Conference on Engineering,  
Applied Sciences and Technology

**July 4-7, 2018**  
**Swissôtel Resort Phuket Patong Beach**  
**Phuket, Thailand**  
iceast2018@kmitl.ac.th  
www.iceast.org

**Submission Deadline: February 28, 2018**

**CALL FOR PAPERS**

- 1 Industrial Materials Manufacturing Engineering**
- 2 Mechanical Mechatronics Civil Engineering**
- 3 Food Chemical Agricultural Engineering**
- Telecommunications Computer Science Instrumentation and Control Electrical Electronic Engineering**

MATEC Web of Conference (Indexed by Scopus)

Proceedings Volume to be submitted for inclusion in IEEE Xplore Digital Library (Indexed by EI Compendex and Scopus)

**KMITL** **IEEE THAILAND SECTION** **TCA** **ECTI Association** **IST** **EEFAT** **TOKAI UNIVERSITY**

**National Institute of Technology, Senda College** **National Institute of Technology, Iizuka College** **National Institute of Technology, Toyama College** **FIT** **Graduate School of Information Science and Technology, Osaka University** **IST** **Graduate School of Information Science and Technology, Hokkaido University** **GROS**

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้





# iceast 2018

The 4<sup>th</sup> International Conference on Engineering,  
Applied Sciences and Technology

**"Exploring Innovative Solutions for Smart Society"**

July 4-7, 2018

Swissôtel Resort Phuket Patong Beach, Phuket, Thailand

The International Conference on Engineering, Applied Sciences and Technology (ICEAST) was inaugurated in 2007 to provide opportunities for enhancing collaboration and exploring current interdisciplinary topics. The ICEAST conferences were held in the past in 2007, 2012 and 2013. To continue the conference mission, the fourth ICEAST conference will be held at Swissôtel Resort Phuket Patong Beach in Phuket, Thailand during July 4-7, 2018. The accepted conference papers will be published in MATEC Web of Conference (indexed by SCOPUS) and the proceedings volume in IEEE Xplore Digital Library (indexed by EI Compindex and SCOPUS).

In addition to the technical program, participants will have the opportunity to enjoy the many charms of Phuket which is one of the World's top tourism destinations. The Organizing Committee hopes that this conference will provide not only outstanding technical knowledge but also enjoyable experience for the participants.

**Honorary Chair**

- Suchatvee Suwansawat (KMITL, Thailand)

**General Chair**

- Komsan Maleesee (KMITL, Thailand)

**Co-Chairs**

- Somsak Choomchuy (KMITL, Thailand)
- Chuwong Phongcharoenpanich (KMITL, Thailand)

**International Committee**

- Tadashi Ariga (Tokai University, Japan)
- Pannapa Changpetch (Bentley University, USA)
- Hsun-Yi Chen (National Taiwan University, Taiwan)
- Chen-Yang Cheng (National Taipei University of Technology, Taiwan)
- Hector Gabriel Allende Cid (Pontificia Universidad Católica de Valparaíso, Chile)
- Giuseppe Di Fatta (University of Reading, UK)
- Tomotaka Homae (National Institute of Technology, Toyama College, Japan)
- Kwei-Long Huang (National University of Taiwan, Taiwan)
- Nobutaka Ito (Chiang Mai University, Thailand)
- Mettaya Kitiwan (Tohoku University, Japan)
- Yasuyuki Miyazawa (Tokai University, Japan)
- Satoru Seto (National Institute of Technology, Ishikawa College, Japan)
- M. Shamsuzzaman (University of Sharja, UAE)
- Munehiro Tanaka (Saga University, Japan)
- Namhun Kim (Ulsan National Institute of Science and Technology, South Korea)
- I Gede Agus Widyadana (Petra Christian University, Indonesia)
- Kuniaki Yajima (National Institute of Technology, Sendai College, Japan)
- Nerda Zura Zaibidi (Universiti Utara, Malaysia)

**Steering Committee**

- Somsak Choomchuy (KMITL, Thailand)
- Monai Krairiksh (KMITL, Thailand)
- Chuwong Phongcharoenpanich (KMITL, Thailand)
- Uma Seeboonruang (KMITL, Thailand)
- Pornchai Supnithi (KMITL, Thailand)
- Supan Tungjitkusolmun (KMITL, Thailand)

**Technical Committee**

- Sompob Polmai (KMITL, Thailand)
- Surapan Airphaiboon (KMITL, Thailand)
- Yutthapong Rangsanteri (KMITL, Thailand)
- Watchara Chatwiriya (KMITL, Thailand)
- Jarruwat Charoensuk (KMITL, Thailand)
- Apinan Namkanisorn (KMITL, Thailand)
- Sawai Pongswatd (KMITL, Thailand)
- Arthit Petchsathon (KMITL, Thailand)
- Ekkapong Cheevitsopon (KMITL, Thailand)
- Panmanas Sirisomboon (KMITL, Thailand)
- Ranon Jientrakul (KMITL, Thailand)
- Sorawat Chivapreecha (KMITL, Thailand)
- Pearawat Yutthagowith (KMITL, Thailand)
- Vanvsa Chutchavon (KMITL, Thailand)
- Montree Siriprachyanun (KMUTNB, Thailand)
- Nantakrit Yodpijit (KMUTNB, Thailand)
- Sukanya Praesomboon (KMUTNB, Thailand)
- Banhan Lila (BUU, Thailand)
- Supphachan Rajsiri (MU, Thailand)
- Anupun Terdwongworakul (KU, Thailand)
- Anirut Chaijaruwanch (CMU, Thailand)
- Wassanai Wattanutchariya (CMU, Thailand)
- Wasawat Nakkiew (CMU, Thailand)
- Chusit Pradabpet (ARU, Thailand)

**General Secretary**

- Chaowalit Hamontree (KMITL, Thailand)

**Important Dates**

Paper Submission Deadline	February 28, 2018
Notification of Acceptance	April 30, 2018
Final Paper Submission Deadline	May 15, 2018
Early Registration Deadline	May 15, 2018
Conference Date	July 4-7, 2018

**Call for Papers**

**Track 1** - Industrial Engineering, Materials and Manufacturing  
**Track 2** - Mechanical, Mechatronics and Civil Engineering  
**Track 3** - Food, Chemical and Agricultural Engineering  
**Track 4** - Telecommunications, Computer Science, Instrumentation and Control, Electrical and Electronic Engineering

**Publications**

Accepted papers will be published in:

- (Track 1-3) MATEC Web of Conference (indexed by SCOPUS).
- (Track 4) Proceedings volume in IEEE Xplore Digital Library (indexed by EI Compindex and SCOPUS).

**Registration Rate (THB)**

	Early Registration	Standard Registration
Regular Paper	12,000	14,000
Student Paper	8,000	9,000
Additional Paper	8,000	9,000
Participant	5,000	6,000

iceast2018@kmitl.ac.th  
www.iceast.org



National Institute of Technology,  
Sendai College



THAILAND SECTION



THAILAND CONCRETE ASSOCIATION



ECTI Association















เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
 ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

# The use of Global Best position in rerun of particle swarm optimization

Varothon Cheypoca, \*Kritawan Siriboon, Boontee Kruatrachue

Department of Computer Engineering, Faculty of Engineering  
King Mongkut's Institute of Technology Ladkrabang  
Bangkok, Thailand

E-mail: warothon@hotmail.com, \*Corresponding Author: kritawan.si@kmitl.ac.th, boontee.kr@kmitl.ac.th

**Abstract**— This paper studies the use of particle best position (GBEST) in rerun when particle swarm optimization (PSO) traps in local optima. Reinitialize particles positions are often used to restart PSO to get better results when trapping in local optima. This paper proposed the use of GBEST to further force particle movement out of previous local optima instead of only reset GBEST. The proposed method is tested on 26 benchmark test functions with satisfactory results.

**Keywords**—component; particle swarm optimization; GBEST; Reinitialize;

## I. INTRODUCTION

PSO has been widely used in many optimization problems. The main disadvantage is the “trapping in local optima problem”, where all particles position very closed to GBEST position with little movement and cannot further improve the GBEST. To avoid this problem, many researchers [1], [2] try various methods such as multi-swarm, rerun and changing PSO position update equation. This paper focuses on the rerun method where PSO repeats running the same problem again with different starting positions in each run. To increase the chance in finding better optima, many researchers try to reinitialize particle slightly near its trap position instead of a new random position. This idea has been widely use in mutation step in Genetic algorithm. This usually works well if the trap position is near optima position in most of its dimension.

To start another run with widely random diversity of position may increase the chance of finding new optima but there is no guarantee that it will converge to a new optima. On the contrary, the previous trap positions may have some dimensions in the optima position. Hence, the new position should diversity enough to avoid converging to the same optima and at the same time not throw away the correct parts (dimension) of the trap solution. To limit the search space and time, this paper also propose the use of mutation from particle trap position along with the mutation of GBEST to further increase diversity of the next run. This paper study the use of various GBESTs consists of GBEST at the trap position (no reset + no repo), GBEST from the new muted particles positions (reset + no repo), mutation of the trap GBEST (no reset + repo) and mutation of the new muted particles positions GBEST (reset + repo).

This paper organized into 5 sections. Section 1 is this introduction. Section 2 explains related works. The proposed method is explained in Section 3 and its experiment comparing to other method is Section 4. Section 5 is the conclusion.

## II. RELATED WORKS

### A. Particle Swarm Optimization (PSO)

Particle Swarm Optimization developed by J.Kennedy and R.Eberhart, 1995 [3], [4]. It is inspired by the behavior of bird flock or fish school. The member of the population in PSO called particle. It finds a solution in a search space by moving particles around the search-space according to from particle's current position and velocity. Each particle's move toward their best seen position (PBEST) and global best position among all particles (GBEST). GBEST will be updated if better positions are found by any particles.

$$x_i(t+1) = x_i(t) + v_i(t+1) \quad (1)$$

$$v_i(t+1) = \omega v_i(t) + c_1(p_i - x_i(t))R_1 + c_2(g - x_i(t))R_2 \quad (2)$$

$x_i(t)$  and  $v_i(t)$  are particle's position and particle's velocity of particle  $i^{th}$  at time  $t$ .  $\omega$  is an inertia weight between  $[0, 1]$ ,  $c_1$  and  $c_2$  are acceleration constants.  $R_1$  and  $R_2$  are uniform random number between  $[0, 1]$ .  $p_i$  is PBEST.  $g$  is GBEST.

### B. Modified Particle Swarm Optimization with Rerun (PSORE)

The PSO is modified to reset GBEST and reinitialized particle position when PSO trap in some local optima for some number of iteration. This may help PSO to converge to other local optima since GBEST is reset and all particles are random to the new start positions within the search space.

### C. Improving Multi-Swarm by Slightly Mutation Particle and GBEST of Stuck Swarm Along with Randomly Selecting GBEST of other Swarm (MPSOSM)

Improving Multi-Swarm by Slightly Mutation Particle and GBEST of Stuck Swarm Along with Randomly Selecting GBEST of other Swarm developed by Chengkhuntod, Kruatrachue and Siriboon [5]. MPSOSM use multi-swarm of

PSO. When a swarm is trapped, the particle is slightly muted from current position and GBEST is set to GBEST of other random swarm. If all swarm trapped in the same local optima, each swarm will has its particles and GBEST mutation from their current position.

### III. PROPOSED METHOD

The proposed method starts with normal PSO update equation and monitors GBEST improvement. If it has no improvement for some consecutive number of iterations, PSO will start the next run with the alter particles positions and GBEST. The GBEST of previous run is used to influence the updated muted position of particles as defined in update equation of PSO. This introduces more diversity in searching since particle position and GBEST may have mutation in different dimension. The details of the algorithm are in Fig 1.

(1)	Initial particles positions()
(2)	While (total number of iteration < MAX_iteration):
(3)	Update particles positions $X[i], PBEST[i], GBEST[i]$ using normal PSO
(4)	If GBEST unchanged for MAXU_iterations:
(5)	reset GBEST
(6)	reset PBEST of all particles
(7)	randomly mutate all particle positions by EQ[3] for 20% of its dimensions and update PBEST[i] and GBEST[i]
(8)	Set GBest[4] to randomly mutate GBest[i] EQ[4] for 30% of all dimension

Fig. 1. Pseudo Code

$$x_i = \pm(x_i \times (0.9 + (0.1 \times R))) \quad (3)$$

$$g = \pm(g \times (0.9 + (0.1 \times R))) \quad (4)$$

$x_i$  is position of particle  $i^{th}$ .  $R$  is uniform random number between  $[0, 1]$ .  $g$  is GBEST.

There are 4 choices of GBEST:

1: GBEST of the trap position of previous run (omit line 5 execute line 6, 7 and skip line 8). Even though GBEST can be changed due to line 7, but it usually not due to the fact the random mutation position normally has inferior fitness in comparing to previous GBEST at the trap position.

2: Muted GBEST of the trap position of previous run (omit line 5 execute line 6, 7 and line 8). GBEST as of case 1 is further muted in line 8.

3: GBEST of the muted particles positions (execute line 5, 6, 7 and skip line 8). Since GBEST is reset in line 5, the new GBEST will be from the best muted particle positions of the previous run in line 7.

4: Muted GBEST of the muted particles positions (execute line 5, 6, 7 and line 8). GBEST as of case 3 is further muted in line 8.




Fig. 2. Particle and various GBEST at Trap and muted Position.

Figure 2 show all cases of GBEST used in the proposed algorithm. Fig 2 left side shows a swarm traps in local optima, all particle positions (+) and GBEST (x) position is almost the same in all dimensions of the search space. There is GBEST(1) of the trap position picture in the center among all particles. GBEST(2) is the mutation of GBEST(1) in 30% of all dimensions of GBEST(1) positions. Fig 2 right side shows particle position after the mutation of all particles positions for 20% of all its dimensions from Fig 2 left side. After mutation, each particle distribute wider in the search space in comparing to Fig 2 left side. GBEST(3) is the best position among all particles after mutation (excluding GBEST(1)). GBEST(4) is the mutation of GBEST(3) in 30% of all dimensions of GBEST(3) positions.

The algorithm performs differently on each case. Normally GBEST of choice 1 (the previous trap position) is better than most muted particles positions and will attract all particles moving toward it. During the move, if a better position is found, there will be a new GBEST and the swarm escapes the trapping and move to another local optima. On the other hand, if no better GBEST found the swarm will end up trapping in the same position before the trap. The rerun algorithm keeps reposition GBEST and particles after each trap anticipating a better position.

GBEST of choice 2 also starts with GBEST of the trap position but muted for 30% of its dimensions. Since number of dimension muted (30%) is more than those of particle position (20%), GBEST will usually has worst position than many of particles positions. But since it is set as GBEST, it will attract at least one particle to move in it direction. And if the fitness of that particle after updated is less than GBEST, this GBEST will also influence another particle movement until the new GBEST is found. In any cases, since both the mute GBEST and GBEST of mute particle position is worse than the GBEST of the trap position; it is less likely (than case 1) that the swarm will trap at the same GBEST before rerun.

GBEST from choice 3 starts with GBEST of the muted particle position. There is no direct influence from previous GBEST from trap position. Since number of muted dimensions of particle position is 20%, the search diversity is less than case 2 & 4.

The last case, GBEST from choice 4 is the GBEST from choice 3 and muted for 30% of all dimensions, this will introduce more diversity to attract each particle. It will only

influence some particles until the new GBEST is set as in case 2, which is quite possible since GBEST start in the worst position than most particles.

#### IV. EXPERIMENT

##### A. Benchmark Test Functions

This proposed algorithm is tested with twenty-six benchmark test functions [6], [7] as shown in Table 1. Functions 1 to 17 are multimodal and functions 18 to 26 are unimodal test functions.

TABLE I BENCHMARK TEST FUNCTIONS

No.	Function Name	Dim	Search Domain	Objective Function Value	Attribute
1	ACKLEY	100	[-32, 768, 32, 768]	0	Multimodal
2	GRIEWANK	100	[-300, 300]	0	Multimodal
3	RASTRIGIN	100	[-5, 12.5, 12]	0	Multimodal
4	ROSENBRACK	100	[-2, 048, 2, 048]	0	Multimodal
5	SCHWEFEL	100	[-500, 500]	0	Multimodal
6	COSINE MIXTURE	100	[-1, 1]	0	Multimodal
7	EXPONENTIAL	100	[-1, 1]	0	Multimodal
8	LEVY	100	[-10, 10]	0	Multimodal
9	MICHALEWICZ	10	[-0, 9]	0	Multimodal
10	DIXON-PRICE	10	[-10, 10]	0	Multimodal
11	STEP	100	[-5, 12.5, 12]	0	Multimodal
12	SCHAFER	2	[-100, 100]	0	Multimodal
13	HOLDER	2	[-10, 10]	0	Multimodal
14	BEALE	2	[-4.5, 4.5]	0	Multimodal
15	SHUBERT	2	[-10, 10]	0	Multimodal
16	GOLDSTEIN-PRICE	2	[-2, 2]	0	Multimodal
17	SIX-HUMP CAMEL	2	[-2, 2]	0	Multimodal
18	SPHERE	100	[-5, 12.5, 12]	0	Unimodal
19	PARALLEL HYPER-ELLIPSOID	100	[-5, 12.5, 12]	0	Unimodal
20	ROTATED HYPER-ELLIPSOID	100	[-65, 536, 65, 536]	0	Unimodal
21	CIGAR	100	[-10, 10]	0	Unimodal
22	BROWN	100	[-1, 4]	0	Unimodal
23	MULTIMOD	100	[-10, 10]	0	Unimodal
24	ZAKHAROV	100	[-5, 10]	0	Unimodal
25	TRID	10	[-100, 100]	0	Unimodal
26	EASOM	2	[-100, 100]	0	Unimodal

##### B. Experiment setup

The results of proposed algorithm with various GBEST are compared with PSO, PSORE, MPSOSM, GBEST(1), GBEST(2), GBEST(3) and GBEST(4).

The value of  $c_1$  and  $c_2$  are both 1.496180.  $\omega$  is 0.729844. The number of particles is 30 particles. MPSOSM has 2 swarms with 15 particles in each swarm. The maximum number of generations is 3,000,000 generations. The number of experiments of each function is 5 runs.

##### C. Experiment Results

TABLE II COMPARATIVE RESULTS OF PSO, PSORE, MPSOSM, GBEST(1), GBEST(2), GBEST(3) AND GBEST(4)

FUNCTION NAME	PSO	PSORE	MPSOSM	GBEST(1)	GBEST(2)	GBEST(3)	GBEST(4)
	EC <sup>a</sup>	EC	EC	EC	EC	EC	EC
ACKLEY	90,000,180	90,014,130	5,395,828	998,76,828	2,048,710	2,350,240	1,464,130
GRIEWANK	90,000,180	90,013,130	568,025	433,804	330,273	729,903	267,140
RASTRIGIN	90,000,180	90,013,130	3,271,444	1,922,139	2,333,201	1,420,469	1,551,201
ROSENBRACK	90,000,180	90,004,980	90,069,495	90,383,622	23,793,030	90,017,280	4,761,858
SCHWEFEL	90,000,180	90,016,530	90,054,943	23,360,898	63,729,580	90,316,955	67,132,230
COSINE MIXTURE	90,000,180	90,014,910	386,095	486,721	353,679	392,469	200,880
EXPONENTIAL	90,000,180	90,013,600	1,174,975	90,889,259	344,531	345,973	332,140
LEVY	90,000,180	90,014,800	90,063,945	90,872,203	4,276,597	90,026,544	3,857,159
MICHALEWICZ	90,000,180	142,711	78,225	38,314	88,531	160,951	28,880
DIXON-PRICE	8,340	1,128	4,923	4,200	4,900	11,700	3,690
STEP	90,000,180	90,084,960	71,070	71,790	64,530	70,230	24,120
SCHAFER	7,560	31,020	24,719	935,834	329,673	328,920	7,800
HOLDER	8,208	14,460	17,385	51,244	16,710	37,320	624
BEALE	12,210	11,808	12,728	12,968	12,968	12,180	11,892
SHUBERT	2,220	3,060	1,680	3,630	3,180	3,340	3,220
GOLDSTEIN-PRICE	4,188	3,996	4,410	4,620	5,080	4,770	3,264
SIX-HUMP CAMEL	1,020	738	960	1,230	1,140	1,050	600
SPHERE	90,000,180	90,000,630	10,997,065	4,389,980	4,397,850	4,428,120	4,384,700
PARALLEL HYPER-ELLIPSOID	90,000,180	90,000,660	11,229,750	4,465,590	4,432,920	4,397,660	4,414,080
ROTATED HYPER-ELLIPSOID	90,000,180	90,000,660	11,020,485	4,366,470	4,341,090	4,326,010	4,410,810
CIGAR	90,000,180	90,000,660	10,456,890	4,419,260	4,416,660	4,414,620	4,416,120
BROWN	90,000,180	90,000,630	10,905,090	4,443,130	4,463,290	4,483,770	4,182,650
MULTIMOD	90,000,180	90,003,800	20,842,180	11,525,570	11,331,360	11,706,300	10,892,270
ZAKHAROV	90,000,180	90,018,840	90,001,515	53,439,959	56,080,621	53,063,560	54,198,540
TRID	90,000,180	29,130,050	181,465	90,890,835	358,770	998,790	41,200
EASOM	8,910	7,080	6,000	7,410	8,370	8,400	6,960

<sup>a</sup> EC = the number of Evaluation call.

FUNCTION NAME	PSO	PSORE	MPSOSM	GBEST(1)	GBEST(2)	GBEST(3)	GBEST(4)
	BF	BF	BF	BF	BF	BF	BF
ACKLEY	10/26	4/33	0	14/26	0	0	0
GRIEWANK	0/26	8/40	0	0	0	0	0
RASTRIGIN	5/26	2/31	0	0	0	0	0
ROSENBRACK	1/30	5/11	2/3	6/30	0	0	0
SCHWEFEL	11/24	6/20	3/24	0	0	0	1/25
COSINE MIXTURE	6/49	2/36	0	0	0	0	0
EXPONENTIAL	4/35	1/31	0	2/26	0	0	0
LEVY	9/59	2/35	3/25	5/19	0	0	0
MICHALEWICZ	0/10	0	0	0	0	0	0
DIXON-PRICE	0	0	0	0	0	0	0
STEP	0	0	0	0	0	0	0
SCHAFER	0	0	0	0	0	0	0
HOLDER	0	0	0	0	0	0	0
BEALE	0	0	0	0	0	0	0
SHUBERT	0	0	0	0	0	0	0
GOLDSTEIN-PRICE	0	0	0	0	0	0	0
SIX-HUMP CAMEL	0	0	0	0	0	0	0
SPHERE	0/22	5/42	0	0	0	0	0
PARALLEL HYPER-ELLIPSOID	6/48	3/21	0	0	0	0	0
ROTATED HYPER-ELLIPSOID	0	0	0	0	0	0	0
CIGAR	2/16	1/43	0	0	0	0	0
BROWN	1/46	0/32	0	0	0	0	0
MULTIMOD	4/25	0/22	0	0	0	0	0
ZAKHAROV	2/22	1/21	5/20	0	0	0	0
TRID	2/22	0	0	2/22	0	0	0
EASOM	0/20	0	0	0	0	0	0

<sup>b</sup> BF = Best Fitness Value

From the above TABLE II, PSO can only find optima solution in 8 out of 26 test functions since PSO trapped in local optima until it reached max iterations. PSORE that return in every trap with new random position helps escaping from local optima for 2 more test functions. Multi-swarm MPSOSM locates optima in 22/26 test functions. GBEST(2) and GBEST(4) find global optima in all 26 functions and GBEST(1) and GBEST(4) locate global optima much faster than GBEST(2) in most test functions. GBEST(1), GBEST(3) both has no further mutation of GBEST. They can't find local optima in 5 and 3 of 26 test functions respectively. This results suggest the use of further mutation of GBEST is necessary for locate optima point. GBEST from trap position has higher number of evaluation function call and number of optima point miss than those numbers from GBEST of mute particles positions.




Fig. 3. Function Rosenbrock




Fig. 4. Function Rosenbrock with scale Evaluation Call = 5M

Fig. 3 and Fig. 4 show the convergence of GBEST of Rosenbrock function. The X-axis is time express in number of evaluation function call in million. The Y-axis is the GBEST in log scale. The abruptly change of GBEST express in vertical line indicate the point that trapping occur and GBEST at the trap has been modified. PSO has no vertical line since there is no rerun. GBEST(1) also has none due to retaining use of GBEST at the trap position and only mute particles. All the algorithm perform the same until the first trap in local optima occur since all base on PSO (except MPSOSM that use multi-swarm). Only GBEST(2) and GBEST(4) reach optima for this function, but GBEST(4) reach much faster after 11 reruns. This favor the use of GBEST from best mutate particle than

the GBEST from trap position which has more diversity further away from GBEST at the trap. This is shown in the graph, where muted GBEST from muted particle has much less fitness (vertical line taller) while the muted GBEST from trap has shorter vertical line.

## V. CONCLUSION

This paper proposes the use of rerun to avoid trapping in local optima of PSO. From the experiment, PSO with random initialize of particle has very little improvement (2 functions) over PSO. Multi-swarm with rerun, GBEST(1) and GBEST(3) perform much better (only 3 to 5 functions miss). GBEST(4) and GBEST(2) with mute GBEST locate global optima in all test functions. Hence, further mutation of GBEST is necessary along with the particles mutation for rerun.

## REFERENCES

- [1] Zhao, S-Z., et al. "Dynamic multi-swarm particle swarm optimizer with harmony search." *Expert Systems with Applications* 38.4 (2015): 3735-3742.
- [2] B. Al-Kazemi, and C. K. Mohan, "Multi-phase discrete particle swarm optimization." In *Proc. Of 4<sup>th</sup> Int. Workshop on Frontiers on Evolut. Alg.*, Research Triangle Park, NC, 2002
- [3] J. Kennedy and R. C. Eberhart, *Particle Swarm Optimization*, IEEE International Conference on Neural Networks, pp.1942-1948, 1995.
- [4] R. C. Eberhart and J. Kennedy, "A New Optimizer Using Particle Swarm Theory," *Proceedings of the 6th International Symposium on Micro Machine and Human Science*, pp.39-43, 1995.
- [5] K. Chengkhuntod, B. Kruatrachue, and K. Siriboon, "Improving Multi-Swarm by Slightly Mutation Particle and GBEST of Stuck Swarm Along with Randomly Selecting GBEST of other Swarm," *icsec*, 2017.
- [6] Momin Jamil and Xin-She Yang, "A Literature Survey of Benchmark Functions For Global Optimization Problems", *Int. Journal of Mathematical Modelling and Numerical Optimisation*, Vol. 4, No. 2, pp. 150-194 (2013).
- [7] Virtual Library of Simulation Experiments: Test Functions and Datasets, <https://www.sfu.ca/~asurjano/optimization.html>

## ประวัติผู้เขียน

ชื่อ - นามสกุล  
วัน เดือน ปีเกิด  
การศึกษา

นางสาวโรธร เชยโกคา

11 กุมภาพันธ์ 2534

ปีการศึกษา 2552 - 2555 ระดับอุดมศึกษา

คณะวิศวกรรมศาสตร์ สาขาวิชาวิศวกรรมคอมพิวเตอร์ สถาบัน  
เทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

ปีการศึกษา 2546 - 2551 ระดับมัธยมศึกษา

โรงเรียนเตรียมอุดมศึกษาพัฒนาการ



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้