



# การปรับพารามิเตอร์ที่เหมาะสมสำหรับการหาค่าที่เหมาะสมภูมิคุ้มกันหมู่ ไวรัสโคโรนา

ศิริชัย ยศวังใจ<sup>1\*</sup> และ กิตติพงษ์ ม้าลำพอง<sup>2</sup>

<sup>1</sup>ภาควิชาเทคโนโลยีวิศวกรรมอุตสาหกรรม, วิทยาลัยเทคโนโลยีอุตสาหกรรม,  
มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

<sup>2</sup>โรงเรียนเตรียมวิศวกรรมศาสตร์ ไทย-เยอรมัน, วิทยาลัยเทคโนโลยีอุตสาหกรรม,  
มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

\* ผู้ประสานงานเผยแพร่ (Corresponding Author), E-mail: sirichai.y@cit.kmutnb.ac.th

วันที่รับบทความ: 2 เมษายน 2565; วันที่ทบทวนบทความ: 19 พฤษภาคม 2565; วันที่ตอบรับบทความ: 8 มิถุนายน 2565

วันที่เผยแพร่ออนไลน์: 12 สิงหาคม 2565

**บทคัดย่อ:** การหาค่าที่เหมาะสมภูมิคุ้มกันหมู่ไวรัสโคโรนา (Coronavirus Herd Immunity Optimizer: CHIO) เป็นวิธีเมตาฮีริสติกที่พัฒนามาจากแรงบันดาลใจของแนวคิดการมีภูมิคุ้มกันหมู่ ซึ่งจำลองพฤติกรรมทางธรรมชาติของไวรัสโคโรนาที่ทำให้เกิดโรค วิธี CHIO เลียนแบบกลไกการสร้างภูมิคุ้มกันทางธรรมชาติผ่านการประยุกต์จิตวิทยาหมู่ ซึ่งถูกพิจารณาให้เป็นหนึ่งในวิธีการรับภูมิคุ้มกันจากโรคติดเชื้อ วัตถุประสงค์ของบทความนี้เพื่อทบทวนงานวิจัยที่ผ่านมา หาค่าพารามิเตอร์ที่มีผลต่อค่าคำตอบ วิธีการหาค่าตอบมีพารามิเตอร์ที่ประกอบด้วยอัตราการแพร่เชื้อ ( $BR_t$ ) เกณฑ์อายุสูงสุดของการติดเชื้อ ( $Max_{age}$ ) จำนวนประชากร ( $HIS$ ) จำนวนรอบสูงสุดในการค้นหาคำตอบ ( $Max_{Iter}$ ) การทดลองของวิธี CHIO ถูกออกแบบเพื่อทดสอบด้วยวิธีแบบแฟคทอเรียลเต็มรูปแบบที่ 3 ระดับ ( $3^k$  Full Factorial Design) และวิเคราะห์ความแปรปรวน (ANOVA) พารามิเตอร์จะถูกปรับแต่งเพื่อให้ได้ค่าที่เหมาะสมในแต่ละฟังก์ชันเทียบเคียง บทความนี้นำเสนอและเปรียบเทียบประสิทธิภาพระหว่างวิธี CHIO กับวิธีในงานวิจัยของ Al-Betar et al. ด้วยฟังก์ชันเทียบเคียงจำนวน 23 ฟังก์ชัน ผลการทดลอง พบว่า วิธี CHIO มีค่าคำตอบที่ดีที่สุดจำนวน 12 ฟังก์ชัน จากทั้งหมด 23 ฟังก์ชัน และวิธี CHIO ที่ปรับแต่งพารามิเตอร์มีค่าคำตอบต่ำกว่าวิธีของ Al-Betar et al. จำนวน 3 ฟังก์ชัน

**คำสำคัญ:** การหาค่าที่เหมาะสมภูมิคุ้มกันหมู่ไวรัสโคโรนา; พารามิเตอร์ที่เหมาะสม; การออกแบบการทดลอง



# Optimal Parameter Tuning of Coronavirus Herd Immunity Optimizer

Sirichai Yodwangjai<sup>1\*</sup> and Kittipong Malampong<sup>2</sup>

<sup>1</sup> Department of Industrial Engineering, College of Industrial Technology, King Mongkut's University of Technology North Bangkok

<sup>2</sup> Thai-German Pre-Engineering School, College of Industrial Technology, King Mongkut's University of Technology North Bangkok

\* Corresponding author, E-mail: sirichai.y@cit.kmutnb.ac.th

Received: 2 April 2022; Revised: 19 May 2022; Accepted: 8 June 2022

Online Published: 12 August 2022

**Abstract:** The Coronavirus Herd Immunity Optimizer (CHIO) is a recently developed meta-heuristic optimization algorithm that was inspired by the herd immunity concept. It simulates the behavior of a natural entity and was motivated by the appearance of a pathogenic coronavirus. The CHIO mimics the mechanism of obtaining natural immunity against through the application of herd psychology, which is considered to be one of the methods of acquiring immunity from infectious diseases. The objectives of this article are to review CHIO, and to find the parameter that impacts the result. The algorithm has parameters that include the basic reproduction rate ( $BR_r$ ), the maximum age of infected cases ( $Max_{age}$ ), the size of the population ( $HIS$ ), and the maximum of iteration ( $MaxIter$ ). The CHIO experiment is designed to test with  $3^k$  Full Factorial Design and analyzed analysis of variance (ANOVA). The parameter is tuned to find optimal parameters in each benchmark function. This article presents and compares performances between CHIO and method in Al-Betar et al.'s paper with different twenty-three benchmark test functions. The results showed that 12 out of 23 benchmarks function in the best solution. Moreover, the results achieved by parameter tuning of CHIO are compared against the results of Al-Betar et al.'s paper with 3 benchmark functions.

**Keywords:** Coronavirus herd immunity optimizer; Optimal parameter; Design of experiment



## 1. บทนำ

ปัญหาการหาค่าที่เหมาะสมที่สุด (Optimization Problem) เป็นปัญหาหนึ่งที่ได้รับ ความสนใจในการศึกษาอย่างแพร่หลาย ปัญหาดังกล่าวมีวัตถุประสงค์เพื่อหาค่าผลเฉลยที่ดีที่สุดจากผลเฉลยที่เป็นไปได้ทั้งหมด มีทั้งผลเฉลยหรือค่าคำตอบที่สูงสุดและต่ำสุดขึ้นอยู่กับฟังก์ชันต่าง ๆ โดยปัญหาการหาค่าที่เหมาะสมที่สุดได้นำไปประยุกต์ใช้กับหลากหลายสาขาวิชา เช่น การวิจัยดำเนินงาน (Operation Research) วิศวกรรมระบบควบคุม (Control Engineering) วิศวกรรมไฟฟ้า (Electrical Engineering) เป็นต้น

การหาค่าคำตอบที่ดีที่สุดด้วยวิธีดั้งเดิม (Conventional Optimization) ถูกนำมาใช้ในการแก้ปัญหาที่มีขนาดเล็กและข้อจำกัดน้อย ส่วนการหาค่าคำตอบด้วยการประมาณ (Approximation Optimization) จะใช้ในการแก้ปัญหาที่มีขนาดใหญ่ขึ้นและมีความซับซ้อนภายในระยะเวลาที่เหมาะสม แต่คำตอบที่ได้จะไม่ใช่คำตอบที่ดีที่สุด

วิธีเมตาฮิวริสติกเป็นหนึ่งในวิธีการหาค่าคำตอบด้วยการประมาณ มีการแบ่งคำตอบออกเป็น 2 กลุ่มคือ คำตอบเชิงเดี่ยว (Single Solution) และคำตอบเชิงกลุ่ม (Population Solution) [1] โดยคำตอบเชิงเดี่ยวจะเป็นการใช้ตัวแทนคำตอบเพียง 1 คำตอบเพื่อค้นหาคำตอบในแต่ละรอบเท่านั้น เช่น วิธีทาบู (Tabu Search) [2] และวิธีอบอ่อนเหนียวจำลอง (Simulated Annealing) [3] ในทางกลับกันคำตอบเชิงกลุ่มจะมีตัวแทนคำตอบมากกว่า 1 คำตอบในการค้นหาคำตอบในแต่ละรอบ ซึ่งกลุ่มของคำตอบที่มีอยู่อาจจะถูกเลือกทั้งหมดหรือเลือกเพียงบางส่วนเท่านั้น

นอกจากการใช้จำนวนคำตอบเพื่อค้นหาคำตอบในแต่ละรอบแล้ว ยังมีการแบ่งตามลักษณะของการหาคำตอบตามความฉลาดของกลุ่ม (Swarm Intelligence Algorithm) เช่น วิธีอาณานิคมมด (Ant Colony Optimization) [4] วิธีการกลุ่มอนุภาค Particle Swarm Optimization) [5] วิธีอาณานิคมผึ้งเทียม (Artificial Bee Colony Optimization) [6] ตามกายภาพ (Physical-based Algorithm) เช่น วิธีหาค่าที่เหมาะสมที่สุดแบบโน้มถ่วง (Gravitational Search Algorithm) [7] วิธีหาค่าที่เหมาะสมแบบวัฏจักรน้ำ (Water Cycle Algorithm) [8] เชิงวิวัฒนาการ (Evolutionary Algorithm) เช่น วิธีเชิงพันธุกรรม (Genetic Algorithm) [9] วิธีมีมีติก (Memetic Algorithm) [10] วิธีการหาค่าที่เหมาะสมเชิงชีวภูมิศาสตร์ (Biogeography-based Optimization) [11] และจากแรงบันดาลใจทางธรรมชาติ (Nature Inspired Algorithm) [12] วิธีการหาค่าที่เหมาะสมภูมิคุ้มกันหมู่ไวรัสโคโรนา (Coronavirus Herd Immunity Optimizer: CHIO) เป็นวิธีหนึ่งที่ได้รับแรงบันดาลใจจากพื้นฐานทางธรรมชาติของมนุษย์ (Human-based) ซึ่งแนวคิดของภูมิคุ้มกันหมู่ใช้ในการแก้ปัญหาการระบาดของไวรัสโคโรนา (COVID19) อัตราการแพร่กระจายเชื้อไวรัสโคโรนาขึ้นอยู่กับความสัมพันธ์ใกล้ชิดกันระหว่างผู้ป่วยกับคนอื่น ๆ การเว้นระยะห่างทางสังคมเป็นแนวทางที่ช่วยป้องกันการติดเชื้อ ภูมิคุ้มกันหมู่เป็นหลักการหนึ่งที่ควบคุมการระบาดอย่างยั่งยืน ช่วยปกป้องกลุ่มคนที่ไม่ภูมิคุ้มกันจากเชื้อไวรัสได้โดยอัตโนมัติและยังป้องกันการระบาดซ้ำในภายหลัง

วิธี CHIO เป็นการเลียนแบบกลยุทธในการสร้างภูมิคุ้มกันหมู่ มีการแทนประชากรด้วยตัวแทนคำตอบ (Individual) จากการเลือกกลุ่มของประชากรที่

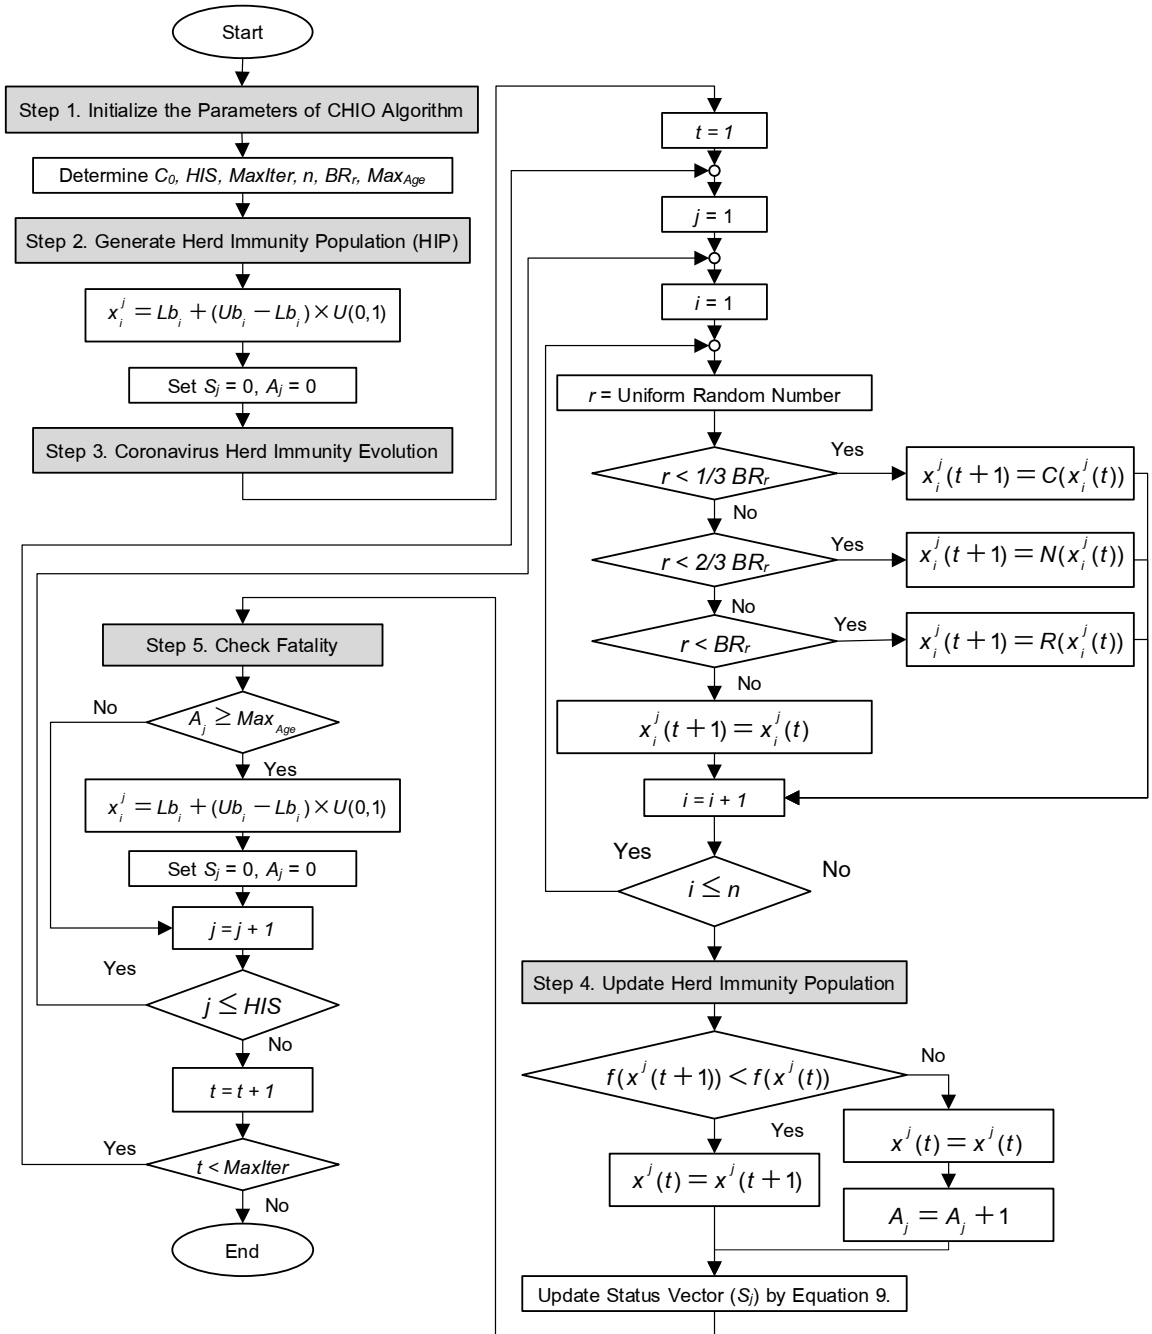


ประกอบด้วย ผู้ที่มีความเสี่ยงในการติดเชื้อ ผู้ที่ติดเชื้อ และผู้ที่มีภูมิคุ้มกัน ขั้นตอนการเลือกประชากรจะใช้เกณฑ์ระยะห่างทางสังคมมาคัดเลือก ในการค้นหาคำตอบจะมีการกำหนดพารามิเตอร์ที่ใช้ในการหาค่าคำตอบที่เหมาะสมที่สุด ซึ่งเป็นการปรับสมดุลระหว่างกระบวนการหาค่าตอบแบบสุ่มกระจาย (Exploration Mechanism) และการหาค่าตอบข้างเคียง (Exploitation Mechanism) พารามิเตอร์ของวิธี CHIO มีหลายพารามิเตอร์ แต่พารามิเตอร์ที่มีผลต่อกระบวนการหาค่าตอบประกอบด้วย จำนวนประชากร (Population Size,  $HIS$ ) เป็นจำนวนคำตอบที่ได้ในแต่ละรอบการค้นหาคำตอบ จำนวนรอบสูงสุดในการค้นหาคำตอบ (Maximum Number of Iteration,  $MaxIter$ ) อัตราการแพร่เชื้อ (Spreading Rate,  $BR$ ) เป็นกลไกการควบคุมการแพร่กระจายเชื้อไวรัสระหว่างตัวแทนคำตอบ และเกณฑ์อายุสูงสุดของการติดเชื้อ (Infected Case Threshold Age,  $Max_{Age}$ ) เป็นกลไกการควบคุมสถานะตัวแทนคำตอบที่ติดเชื้อ การกำหนดค่าพารามิเตอร์ที่ใช้ในการทดลองกับปัญหาแต่ละประเภทจะมีค่าพารามิเตอร์ที่ต่างกัน เนื่องจากข้อมูลของโจทย์ปัญหาในแต่ละข้อมีความซับซ้อนไม่เหมือนกัน การกำหนดค่าพารามิเตอร์จะได้มาจากการปรับค่าพารามิเตอร์ (Parameter Tuning) ซึ่งนิยมใช้หลักการออกแบบการทดลองแบบแฟคทอเรียลเต็มรูปแบบ (Full Factorial Design) เนื่องจากสามารถศึกษาการเปลี่ยนแปลงของค่าพารามิเตอร์พร้อมกันได้

ดังนั้น งานวิจัยนี้ได้ทำการศึกษาหาค่าพารามิเตอร์ที่เหมาะสมสำหรับการแก้ปัญหาทางวิศวกรรมเพื่อปรับสมดุลระหว่างกระบวนการหาค่าตอบแบบสุ่มกระจายและการหาค่าตอบข้างเคียง ให้มีค่าคำตอบที่เหมาะสมด้วยวิธีการหาค่าที่เหมาะสมภูมิคุ้มกันหมู่ไวรัสโคโรนา โดยเบื้องต้นกำหนดค่าพารามิเตอร์ที่ใช้ในการทดลอง เพื่อทำการออกแบบการทดลอง และทดสอบประสิทธิภาพในการหาค่าตอบกับฟังก์ชันเทียบเคียง โดยผู้วิจัยคาดหวังว่างานวิจัยนี้จะเป็นแนวทางในการประยุกต์ใช้กับปัญหาอื่น ๆ ที่เกี่ยวข้องต่อไป

## 2. การหาค่าที่เหมาะสมภูมิคุ้มกันหมู่ไวรัสโคโรนา (Coronavirus Herd Immunity Optimizer)

วิธีการหาค่าที่เหมาะสมภูมิคุ้มกันหมู่ไวรัสโคโรนา ได้ถูกพัฒนาขึ้นและเผยแพร่จากงานวิจัยของ Al-Betar et al. [13] ในปี 2021 โดยเป็นการประยุกต์วิธีการสร้างภูมิคุ้มกันของกลุ่มประชากรที่ป้องกันการติดเชื้อไวรัสโคโรนา ไม่ว่าจะเป็นการฉีดวัคซีนหรือเกิดจากภูมิคุ้มกันที่เกิดขึ้นจากการติดเชื้อที่ผ่านมา โดยแบ่งขั้นตอนการค้นหาคำตอบออกเป็น 6 ขั้นตอน ประกอบด้วย ขั้นตอนที่ 1 กำหนดพารามิเตอร์ ขั้นตอนที่ 2 การสร้างภูมิคุ้มกันหมู่ ขั้นตอนที่ 3 วิวัฒนาการภูมิคุ้มกันหมู่ ขั้นตอนที่ 4 อัปเดตภูมิคุ้มกันหมู่ ขั้นตอนที่ 5 กรณีร้ายแรง และขั้นตอนที่ 6 ครบเงื่อนไข แสดงดังรูปที่ 1 โดยมีรายละเอียดดังนี้



รูปที่ 1 แสดงผังงานของวิธี CHIO



ขั้นตอนที่ 1 กำหนดพารามิเตอร์ (Initial the CHIO-parameter) ประกอบด้วย 2 ส่วน คือ พารามิเตอร์ของวิธีการหาค่าที่เหมาะสม (Algorithmic Parameters) และพารามิเตอร์ของกระบวนการหาค่าตอบ (Operational Parameters) โดยพารามิเตอร์ของวิธีการหาค่าที่เหมาะสมมี 4 ค่า ประกอบด้วยจำนวนผู้ป่วยที่ติดเชื้อเริ่มต้น (Infected Case,  $c_0$ ) จำนวนประชากร ( $HIS$ ) จำนวนรอบสูงสุดในการค้นหาค่าตอบ ( $MaxIter$ ) และขนาดของปัญหา (Problem Dimension,  $n$ ) ในส่วนของพารามิเตอร์ของกระบวนการหาค่าตอบมี 2 ค่า ประกอบด้วย อัตราการแพร่เชื้อ ( $BR_r$ ) เกณฑ์อายุสูงสุดของการติดเชื้อ ( $Max_{Age}$ )

วิธีการนี้ต้องการหาค่าฟังก์ชันวัตถุประสงค์ (Objective Function) ที่ต่ำสุดในฟังก์ชันเทียบเคียง (Benchmark Function) โดยกำหนดให้  $\min f(x)$   $x \in \{Lb, Ub\}$  ซึ่ง  $Lb$  เป็นขอบเขตล่างสุดของตัวแทนค่าตอบ (Lower Bound of Individual) และ  $Ub$  เป็นขอบเขตบนสุดของตัวแทนค่าตอบ (Upper Bound of Individual)

ขั้นตอนที่ 2 การสร้างภูมิคุ้มกันหมู่ (Generate Herd Immunity Population,  $HIP$ ) เป็นการสร้างกลุ่มตัวแทนค่าตอบด้วยการสุ่ม (Random Value) ตามจำนวน  $HIS$  รูปแบบตัวแทนค่าตอบจะอยู่ในรูปของเมทริกซ์ 2 มิติ ซึ่งขนาดของ  $HIP$  เท่ากับ  $n \times HIS$  โดยแต่ละแถว  $j$  ในเมทริกซ์กลุ่มตัวแทนค่าตอบ แสดงด้วยตัวแทนค่าตอบ  $x_j$  ซึ่งค่า  $x_i^j$  เป็นอัตราภูมิคุ้มกันสร้างมาจาก  $Lb_i + (Ub_i - Lb_i) \times U(0,1) \quad \forall i = 1, 2, \dots, n$  ดังสมการที่ (1)

นอกจากการระบุ  $x_j$  แล้ว มีการกำหนดสถานะของ  $HIS$  ใน  $HIP$  ด้วยค่าเวกเตอร์  $S$  แทนกรณีความเสี่ยงติดเชื้อไวรัสโคโรนาด้วย 0 และกรณีที่ติดเชื้อแล้วด้วย 1 ซึ่งจำนวนสถานะเวกเตอร์  $S$  จะมีจำนวนเท่ากับ  $c_0$  โดยเริ่มต้นจะกำหนดให้  $S_j$  เท่ากับ 0

ขั้นตอนที่ 3 วิวัฒนาการภูมิคุ้มกันหมู่ไวรัสโคโรนา (Coronavirus Herd Immunity Evolution) เป็นการหาค่าตอบใหม่  $x^j(t+1)$  ที่ได้รับอิทธิพลมาจากยีนส์  $x_i^j$  ในตัวแทนค่าตอบ  $x^j$  การกำหนดกฎการเว้นระยะห่างทางสังคม (Social Distancing) ด้วยค่า  $BR_r$  ที่เปรียบเทียบกับค่า  $r$  โดยเป็นค่าเลขที่ได้จากการสุ่มระหว่าง 0 ถึง 1 ซึ่งจะแบ่งในแต่ละกรณีตามสมการที่ (2)

กรณีติดเชื้อ (Infected Case): ค่ายีนส์  $x_i^j(t+1)$  มีผลมาจากระยะห่างทางสังคม ซึ่งมีความต่างระหว่างยีนส์ปัจจุบันกับยีนส์ที่มีการติดเชื้อ โดยค่า  $r \in [0, 1/3 BR_r]$  ค่า  $x_i^c(t)$  เป็นการสุ่มเลือกจาก  $x^c$  ของเวกเตอร์  $S$ ,  $c = \{i | S_i = 1\}$  ซึ่งค่า  $x_i^j(t+1)$  และ  $C(x_i^j(t))$  คำนวณจากสมการที่ (3) – (4)

$$HIP = \begin{bmatrix} x_1^1 & x_2^1 & \dots & x_n^1 \\ x_1^2 & x_2^2 & \dots & x_n^2 \\ \vdots & \vdots & \dots & \vdots \\ x_1^{HIS} & x_2^{HIS} & \dots & x_n^{HIS} \end{bmatrix} \quad (1)$$

$$x_i^j(t+1) \leftarrow \begin{cases} x_i^j(t) & r \geq BR_r \\ C(x_i^j(t)) & r < 1/3 \times BR_r \\ N(x_i^j(t)) & r < 2/3 \times BR_r \\ R(x_i^j(t)) & r < BR_r \end{cases} \quad (2)$$

$$x_i^j(t+1) = C(x_i^j(t)) \quad (3)$$

$$C(x_i^j(t)) = x_i^j(t) + r \times (x_i^j(t) - x_i^c(t)) \quad (4)$$



กรณีเสี่ยงต่อการติดเชื้อ (Susceptible Case): ค่า ยีนส์  $x_i^j(t+1)$  มีผลมาจากระยะห่างทางสังคมจากค่า  $r \in [1/3BR_r, 2/3BR_r)$  ซึ่งเป็นความคลาดเคลื่อนระหว่างยีนส์ปัจจุบันกับยีนส์ที่ไม่พบเชื้อ  $x^m$  ค่า  $x_i^m(t)$  เป็นการกระจายของ  $x^m$  อย่างสุ่ม และเป็นศูนย์กลางของเวกเตอร์  $S$ ,  $m = \{i | S_i = 0\}$  ซึ่งค่า  $x_i^j(t+1)$  และ  $N(x_i^j(t))$  คำนวณจากสมการที่ (5) – (6)

$$x_i^j(t+1) = N(x_i^j(t)) \quad (5)$$

$$N(x_i^j(t)) = x_i^j(t) + r \times (x_i^j(t) - x_i^m(t)) \quad (6)$$

กรณีภูมิคุ้มกัน (Immune Case): ค่ายีนส์ใหม่  $x_i^j(t+1)$  มีอิทธิพลมาจากระยะห่างทางสังคม จากค่า  $r \in [2/3BR_r, BR_r]$  ซึ่งเป็นความคลาดเคลื่อนระหว่างยีนส์ปัจจุบันกับยีนส์ที่ไม่พบเชื้อ  $x^v$  ค่า  $x_i^v(t)$  เป็นการกระจายของกรณีที่มีความต้านทานเชื้อโรค  $x^v$  อย่างสุ่ม และเป็นศูนย์กลางของเวกเตอร์  $S$  ซึ่ง  $f(x_i^v) = \arg \min_{j \in \{k | S(k)=2\}} f(x_i^j)$  ซึ่งหาค่า  $x_i^j(t+1)$  และ  $R(x_i^j(t))$  คำนวณจากสมการที่ (7) – (8)

$$x_i^j(t+1) = R(x_i^j(t)) \quad (7)$$

$$R(x_i^j(t)) = x_i^j(t) + r \times (x_i^j(t) - x_i^v(t)) \quad (8)$$

นอกจาก 3 กรณี ข้างต้นที่กล่าวไป เมื่อทำการสุ่มค่า  $r$  ที่มีค่ามากกว่า  $BR_r$  จะแทนค่ายีนส์  $x_i^j(t+1)$  ด้วย  $x_i^j(t)$  ในรอบนั้น ๆ

ขั้นตอนที่ 4 อัปเดตภูมิคุ้มกันหมู่ (Update Herd Immunity Population) โดยกำหนดให้ค่าอัตราภูมิคุ้มกัน  $f(x^j(t+1))$  เป็นค่าวัตถุประสงค์ของตัวแทนคำตอบ  $x^j(t+1)$  โดยตัวแทนคำตอบปัจจุบัน  $x^j(t)$  จะถูกแทนที่ด้วย  $x^j(t+1)$  ในกรณีที่ตัวแทนคำตอบดีกว่า  $f(x^j(t+1)) < f(x^j(t))$  ค่าเวกเตอร์  $S_j$  ของแต่ละตัวแทนคำตอบ  $x^j$  จะอัปเดตตามเกณฑ์ภูมิคุ้มกัน ด้วยสมการที่ (9)

$is\_corona(x^j(t+1))$  มีค่าเป็นไบนารี ซึ่งขึ้นอยู่กับประเภทของ  $x^j(t+1)$  ในกรณีที่  $x^j(t+1)$  ถูกยืนยันว่าเป็นตัวแทนคำตอบที่ติดเชื้อ ค่า  $is\_corona(x^j(t+1))$  จะเท่ากับ 1 โดยค่า  $\Delta f(x) = \frac{\sum_{i=1}^{HIS} f(x_i)}{HIS}$  ซึ่งเป็นค่าเฉลี่ยของอัตราภูมิคุ้มกันหมู่ อัตราภูมิคุ้มกันของกลุ่มตัวแทนคำตอบขึ้นอยู่กับระยะห่างทางสังคมที่คำนวณได้ก่อนหน้านี้ ถ้าอัตราภูมิคุ้มกันใหม่ดีกว่าอัตราภูมิคุ้มกันเฉลี่ย แสดงให้เห็นว่าประชากรมีภูมิคุ้มกันไวรัส และค่าเวกเตอร์อายุ (Age Vector)  $A_j$ ,  $A_j = A_j + 1$  ถ้า  $S_j = 1$

$$S_j \rightarrow \left\{ \begin{array}{l} 1 \quad f(x^j(t+1)) < \frac{f(x^j(t+1))}{\Delta f(x)} \wedge S_j = 0 \wedge is\_corona(x^j(t+1)) \\ 2 \quad f(x^j(t+1)) < \frac{f(x^j(t+1))}{\Delta f(x)} \wedge S_j = 1 \end{array} \right\} \quad (9)$$



ขั้นตอนที่ 5 กรณีร้ายแรง (Fatal case) ถ้าอัตราภูมิคุ้มกัน  $f(x^j(t+1))$  ของตัวแทนคำตอบที่ติดเชื้อไวรัส ( $S_j=1$ ) ไม่สามารถปรับปรุงให้ดีขึ้น ( $A_j = A_j + 1$ ) จะถูกกำหนดด้วยค่า  $Max_{Age}$  ถ้าค่า  $A_j \geq Max_{Age}$  เป็นกรณีที่ตัวแทนคำตอบใช้ไม่ได้ (เสียชีวิต) ซึ่งจะมีการสร้างตัวแทนคำตอบใหม่  $x_i^j(t+1)$ ,  $x_i^j(t+1) = Lb_i + (Ub_i - Lb_i) \times U(0,1)$   $\forall i=1,2,\dots,n$  และ ค่า  $A_j, S_j$  จะกำหนดใหม่เท่ากับ 0 ซึ่งเป็นการสร้างความหลากหลายของตัวแทนคำตอบ (Diversity Solution)

ขั้นตอนที่ 6 ครบเงื่อนไข (Stop Criterion) เป็นกระบวนการค้นหาคำตอบซ้ำจากขั้นตอนที่ 3 ถึงขั้นตอนที่ 6 ซึ่งเงื่อนไขของการค้นหาคำตอบขึ้นอยู่กับจำนวนของผู้ที่ไม่พบเชื้อและมีภูมิคุ้มกันครบ หรือจำนวนรอบสูงสุดในการค้นหาคำตอบ

เริ่มต้นงานวิจัยของ Al-Betar et al. [13] นำเสนอวิธี CHIO เริ่มต้นเพื่อทดสอบประสิทธิภาพในการค้นหาคำตอบกับฟังก์ชันเทียบเคียง ซึ่งกำหนดพารามิเตอร์สำหรับการทดลองออกเป็น 3 พารามิเตอร์ ประกอบด้วย  $BR_r$ ,  $Max_{age}$  และกลยุทธ์การเว้นระยะห่างทางสังคม (Social Distancing Strategy) งานวิจัยได้กำหนดพารามิเตอร์แต่ละตัวไว้หลายระดับ ทุกการทดลองกำหนดให้  $HIS$  เท่ากับ 30 และ  $MaxIter$  เท่ากับ 100,000 โดยการทดลองแรกเป็นการทดสอบผลกระทบจากค่า  $BR_r$  ระหว่างค่า 0.005 – 0.5 พบว่า การกำหนดค่า  $BR_r$  ที่มากจะใช้เวลาในการหาคำตอบแบบสุ่มกระจายมากขึ้นและการลู่เข้าหาคำตอบเป็นไปได้ช้า การทดลองที่สองเป็นการทดสอบผลกระทบจากค่า  $Max_{age}$  ระหว่างค่า 50 – 500 พบว่า การกำหนดค่า  $Max_{age}$  ที่น้อยจะใช้

เวลาในการหาคำตอบแบบสุ่มกระจายสูง และการทดลองที่สาม เป็นการทดลองกลยุทธ์การเว้นระยะห่างทางสังคมในวิวัฒนาการภูมิคุ้มกัน พบว่าการสุ่มเลือกคำตอบจากทั้ง 3 กรณี ประกอบด้วยกรณีติดเชื้อ กรณีเสี่ยงต่อติดเชื้อ และ กรณีมีภูมิคุ้มกัน มีการลู่เข้าหาคำตอบดีที่สุด

การประยุกต์ใช้วิธี CHIO ในการแก้ปัญหาทางวิศวกรรมยังไม่เป็นที่แพร่หลายนักและปัญหาส่วนใหญ่จะแก้ปัญหาทางวิศวกรรมไฟฟ้า โดยมีการรวบรวมงานวิจัยที่ผ่านการเผยแพร่มาดังนี้

Alweshah [14] แก้ปัญหาการจำแนกประเภท (Classification Problem) โดยใช้วิธี CHIO ในการเพิ่มประสิทธิภาพของวิธีโครงข่ายประสาทเทียมแบบความน่าจะเป็น (Probabilistic Neural Network: PNN) วิธี PNN จะสร้างตัวแทนคำตอบด้วยการสุ่มและทำการสอน (Training) จากชุดข้อมูล จากนั้นใช้วิธี CHIO ในการปรับค่าความแม่นยำของน้ำหนักใน PNN เพื่อทดสอบกับชุดข้อมูลจริงจำนวน 11 ชุด ข้อมูล ผลการทดลองพบว่า วิธี CHIO-PNN มีความแม่นยำในการทดลองสูงถึง 90.3 เปอร์เซ็นต์ เมื่อเทียบกับวิธี PNN และวิธีอื่น ๆ และมีอัตราการลู่เข้าหาคำตอบดี Mahboob et al. [15] ประยุกต์วิธี CHIO ในการเลือกคุณสมบัติของระบบการตรวจจับการบุกรุก (Intrusion Detection System) ที่มีทางเลือกจำนวนมากเพื่อปรับปรุงระบบให้มีความแม่นยำ ร่วมกับวิธีโครงข่ายประสาทเทียม (Artificial Neural Networks: ANN) และวิธีเพื่อนบ้านใกล้ที่สุด (K-Nearest Neighbor Algorithm) งานวิจัยนี้ได้ใช้วิธี ANN ให้สอนร่วมกับวิธีหาค่าที่เหมาะสมบรรสาน (Harmony Search) และวิธีหาค่าที่เหมาะสมอาณาณินคัมผึ่งเทียม





(Artificial Bee Colony) Arikusū and Bayhan [16] ประยุกต์วิธี CHIO สำหรับออกแบบตัวควบคุมพีไอดี (PID) สำหรับระบบเครื่องปรับแรงดันไฟฟ้าอัตโนมัติ เพื่อเปรียบเทียบกับวิธีการอื่น ๆ Amini et al. [17] นำเสนอแบบจำลองทางคณิตศาสตร์สำหรับปัญหาการจ่ายโหลดอย่างประหยัด (Economic Dispatch Problem) ในการวางแผนขยายระบบส่งไฟฟ้า (Transmission Expansion Planning: TEP) ที่พิจารณาผลกระทบจากจุดคว่ำ (Value-Point Effect) โหลดไฟฟ้าไม่แน่นอน (Load Uncertainty) แหล่งพลังงานกระจายตัวไม่แน่นอน (Distributed Generation Uncertainty) แผนงานที่ใช้แรงจูงใจ (Incentive-based Demand Response) และรถยนต์ไฟฟ้าปลั๊กอิน เพื่อให้มีต้นทุนรวมต่ำสุด และประยุกต์ใช้วิธี CHIO ในการแก้ปัญหา TEP และนำไปเปรียบเทียบกับวิธีอัลกอริทึมบรานแอนบาวนด์ (Branch-and-Bound Algorithm) และทดสอบกับระบบ IEEE ชนิด 24 บัส ผลการทดลองพบว่า วิธี CHIO มีประสิทธิภาพในการแก้ปัญหาดังกล่าว ปัญหาลักษณะเดียวกัน Refaat et al. [18] ได้พิจารณาผลกระทบการไม่ร่วมกันของการจัดสรรการชดเชยกำลังไฟฟ้ารีแอกทีฟ (Reactive Power Compensator) ในการจ่ายกระแสไฟฟ้า โดยใช้ CHIO ในการแก้ปัญหาในแบบจำลองการไหลของกระแสไฟฟ้าตรงและกระแสไฟฟ้าสลับ ซึ่งทดสอบกับระบบ IEEE ชนิด 24 บัส และระบบจริงในประเทศอียิปต์ Alqarni [19] ประยุกต์วิธี CHIO กับปัญหาการจัดเก็บพลังงานในแบตเตอรี่ เพื่อยกระดับประสิทธิภาพของระบบการเชื่อมต่อไฟฟ้าแบบไมโครกริด ใน 3 ขั้นตอน โดยมีวัตถุประสงค์ในแต่ละ

ขั้นตอนที่แตกต่างกัน ขั้นตอนแรกเน้นการอัตราการบริโภคที่สูงสุดของพลังงานหมุนเวียน ขั้นตอนที่สองเพื่อลดความสูญเสียพลังงานที่ต่ำสุด

อีกหนึ่งปัญหาคือ การหาค่าที่เหมาะสมที่สุดแบบวัตถุประสงค์หลายอย่าง (Multi-objective Optimization) นั้น มีการพิจารณาวัตถุประสงค์ที่มากกว่า 1 วัตถุประสงค์ เช่น วัตถุประสงค์หลักต้องการหาค่าต่ำสุดและอีกวัตถุประสงค์รองต้องการหาค่าสูงสุด Kumar et al. [20] ประยุกต์วิธีการหาค่าที่เหมาะสมภูมิคุ้มกันหมู่ไวรัสโคโรนาแบบหลายวัตถุประสงค์ (Multi-objective CHIO: MOCHIO) สำหรับออกแบบมอเตอร์กระแสตรงแบบไร้แปรงถ่าน (BLDC Motor) โดยวัตถุประสงค์เพื่อให้มีน้ำหนักมอเตอร์ที่ต่ำสุดและประสิทธิภาพของมอเตอร์สูงสุด มีการเปรียบเทียบกับวิธีอื่น ๆ มากกว่านั้นมีการตรวจสอบความถูกต้องของวิธีการด้วยชุดทดสอบมาตรฐานซีดีที (ZDT Benchmark Function) ซึ่งผลการทดลองพบว่าวิธี MOCHIO มีประสิทธิภาพในการประยุกต์ใช้แก้ปัญหาการออกแบบมอเตอร์กระแสตรงแบบไร้แปรงถ่าน Makhadmeh et al. [21] ประยุกต์และปรับเปลี่ยนวิธี CHIO สำหรับการแก้ปัญหาการจัดตารางการใช้พลังงานในบ้านอัจฉริยะ (Power Scheduling Problem in Smart Home) ที่มีหลายวัตถุประสงค์ประกอบด้วย อัตราการใช้พลังงานสูงสุดเฉลี่ย (Peak-to-Average Ratio) ค่าการใช้พลังงาน (Electricity Bill) และระดับความสบายของผู้ใช้งาน (Comfort Level of Users) ต่อมา Naderipour et al. [22] ประยุกต์ใช้วิธี CHIO ร่วมกับการตัดสินใจแบบหลายเกณฑ์แบบตรรกะคลุมเครือ (Fuzzy Multi-criteria Approach) เพื่อแก้ปัญหาการจ่ายกระแสไฟ



โดยวัตถุประสงค์เพื่อลดความสูญเสียไฟฟ้า เพิ่มคุณภาพและความน่าเชื่อถือ Ali et al [23] นำเสนอแบบจำลองของปัญหาการจ่ายโหลดอย่างประหยัดเชิงสิ่งแวดล้อมและเชิงเทคนิค (Economic-environmental-technical Dispatch problem) สำหรับปรับระบบ IEEE ชนิด 30 และ 57 บัส โดยมีหลายวัตถุประสงค์ประกอบด้วย ต้นทุนพลังงานทั้งหมด การปล่อยมลพิษ การสูญเสียพลังงาน แรงดันไฟฟ้าเบี่ยงเบน และเสถียรภาพแรงดัน วิธี CHIO และวิธีการหาค่าที่เหมาะสมอื่น ๆ นำมาใช้ในการระบุทางเลือกที่ดีที่สุด เพื่อใช้ในวิธีการกระบวนการวิเคราะห์หาค่าลำดับชั้น (AHP) และวิธีทอปปซิส (TOPSIS Method)

ยิ่งไปกว่านั้นมีการประยุกต์ใช้วิธี CHIO ในการแก้ปัญหาการหาค่าที่เหมาะสมที่สุด (Optimization Problem) ในด้านการขนส่งและโลจิสติกส์ โดย Dalbah et al. [24] ประยุกต์วิธี CHIO แก้ปัญหาการเดินทางของพนักงานขาย (Traveling Salesman Problem) โดยมีประสิทธิภาพในการแก้ปัญหาขนาดใหญ่ ในขณะที่เดียวกัน ประยุกต์วิธี CHIO ให้เหมาะกับการแก้ปัญหาการจัดเส้นทางของยานพาหนะที่พิจารณาความจุ (Capacitated Vehicle Routing Problem) [25] ซึ่งทำการเปรียบเทียบกับโจทย์ปัญหาที่สร้างขึ้นใหม่และโจทย์ปัญหามาตรฐาน

นอกจากการปรับเปลี่ยนวิธี CHIO ให้สามารถแก้ปัญหาต่าง ๆ ได้แล้ว ยังมีงานวิจัยบางส่วนที่ประยุกต์ใช้วิธี CHIO ร่วมกับตัวดำเนินการ (Operator) เพื่อหาคำตอบที่เหมาะสมอย่าง Alweshah et al. [26] นำเสนอวิธี CHIO ร่วมกับวิธี Greedy Crossover (GC) ในการค้นหาคำตอบของขั้นตอนการสำรวจหรือสุ่มกระจาย ในปัญหาการ

คัดเลือก (Feature Selection Problem) ของการวินิจฉัยทางการแพทย์ โดยทำการเปรียบเทียบวิธี CHIO และวิธี CHIO-GC กับโจทย์ปัญหาเทียบเคียงทางการแพทย์และโจทย์ปัญหาจริง นอกจากนี้งานวิจัยยังมีการประยุกต์ใช้ วิธีเพื่อนบ้านใกล้ที่สุด (K-Nearest Neighbor Algorithm) ในขั้นตอนการหาคำตอบช่วงเชิง (Exploitation Phase) ผลการทดลองพบว่า วิธี CHIO-CG มีประสิทธิภาพในการหาคำตอบและหลุดจากคำตอบท้องถิ่น (Local Optimal)

การกำหนดค่าพารามิเตอร์ที่ใช้ในการหาคำตอบของปัญหาแต่ละประเภทจะมีค่าที่แตกต่างกัน จากการทบทวนงานวิจัยที่ผ่านมาพบว่า วิธี CHIO มีการกำหนดค่าพารามิเตอร์จำนวน 5 พารามิเตอร์ ซึ่งประกอบด้วย  $c_0$ ,  $BR_r$ ,  $Max_{age}$ ,  $HIS$  และ  $MaxIter$  โดยผ่านการทดลองและมีค่าที่เหมาะสมกับปัญหานั้น ๆ แสดงดังตารางที่ 1 โดยพารามิเตอร์ที่มีการปรับแต่งค่าให้เหมาะสมกับปัญหามี 4 พารามิเตอร์ ประกอบด้วย  $BR_r$ ,  $Max_{age}$ ,  $HIS$  และ  $MaxIter$  ส่วน  $c_0$  จะกำหนดเป็นค่าคงที่เสมอ

### 3. วิธีการทดลอง

ในงานวิจัยนี้ได้กำหนดพารามิเตอร์สำหรับการทดลองออกเป็น 4 พารามิเตอร์ ประกอบด้วย  $BR_r$ ,  $Max_{Age}$ ,  $HIS$  และ  $MaxIter$  เนื่องจากการทดลองในครั้งนี้ผู้วิจัยคาดหวังให้จำนวนคำตอบทั้งหมดของแต่ละการทดลองมีจำนวนคำตอบที่เท่ากันเพื่อให้เกิดความเสมอภาคในทุกโจทย์ปัญหา ซึ่งจำนวนคำตอบทั้งหมดมาจากจำนวน  $HIS$  ในแต่ละรอบการค้นหาคำตอบ (Iteration) ดังนั้น จึงกำหนดให้จำนวนคำตอบทั้งหมดของแต่ละการทดลองคำนวณจาก  $HIS \times MaxIter$



ขั้นตอนการทดลองจะใช้การออกแบบการทดลอง (Design of Experiment) แบบ  $3^k$  Full Factorial Design เพื่อหาค่าระดับที่เหมาะสมของแต่ละพารามิเตอร์ โดยค่าพารามิเตอร์จะกำหนดไว้ที่ 3 ระดับ คือ ค่าระดับต่ำ ค่าระดับกลาง และค่าระดับสูง พารามิเตอร์แต่ละตัวกำหนดขอบเขตต่ำสุดและสูงสุดที่ได้จากการทบทวนงานวิจัยที่ผ่านมา [13-15, 21, 25, 26] โดย ค่า  $BR_r$  มีค่าต่ำสุดที่ 0.05 และค่าสูงสุดที่ 0.5 ค่า  $Max_{Age}$  มีค่าต่ำสุดที่ 100 และค่าสูงสุดที่ 500 [13] จำนวนคำตอบทั้งหมดเกิดจากการผลคูณของ  $HIS \times MaxIter$  ซึ่งกำหนด  $HIS$  ที่ 60, 30 และ 15 และ  $MaxIter$  ที่ 50,000, 100,000 และ 200,000 รอบ ตามลำดับ เพื่อให้จำนวนคำตอบทั้งหมดของแต่ละ

การทดลองมีจำนวน 3,000,000 คำตอบ [13] แสดงดังตารางที่ 2 ซึ่งการทดลองเชิงแฟกทอเรียลแบบสมบูรณ์จะต้องทำการทดลองเท่ากับ  $3^3$  เท่ากับ 27 การทดลอง และทำการทดลองซ้ำอย่างน้อย 3 ครั้ง รวม 81 การทดลอง ในการทดลองจะทดสอบกับฟังก์ชันเทียบเคียงฐานนิยมเดี่ยว (Unimodal Benchmark Functions) ฟังก์ชันเทียบเคียงพหุฐานนิยม (Multimodal Benchmark Functions) และฟังก์ชันเทียบเคียงพหุฐานนิยมกำหนดขนาด (Fixed-dimension Multimodal Benchmark Functions) จำนวนทั้งหมด 23 ฟังก์ชัน [27] โดยแต่ละฟังก์ชันจะมีลักษณะที่แตกต่างกันตามวัตถุประสงค์แสดงในตารางที่ 3 – 5

ตารางที่ 1 ค่าพารามิเตอร์ที่เหมาะสมของงานวิจัยที่ผ่านมา

ประเภทปัญหา	พารามิเตอร์ที่เหมาะสม				
	$c_0$	$BR_r$	$Max_{Age}$	$HIS$	$MaxIter$
Real-world Engineering Problem [13]	1	0.01	100	30	150,000
Classification Problem [14]	1	0.01	100	30	100
Intrusion Detection System [15]	1	0.05	100	50	250
Power Scheduling in Smart Home [21]	1	0.001	30	40	1,000
Economic Dispatch Problem [23]	1	0.05	100	50	300
Capacitated Vehicle Routing Problem [25]	1	0.5	300	100	500
Feature Selection [26]	1	0.01	100	30	100

ตารางที่ 2 ระดับพารามิเตอร์ในการทดลอง

พารามิเตอร์	ระดับพารามิเตอร์	ต่ำ	กลาง	สูง
$BR_r$	3	0.05	0.1	0.5
$Max_{Age}$	3	100	300	500
$HIS \times MaxIter$	3	60x50,000	30x100,000	15x200,000



ตารางที่ 3 ฟังก์ชันเทียบเคียงฐานนิยมเดี่ยว

ฟังก์ชันที่	ชื่อฟังก์ชัน	สมการ	$f(x)$
1.	Sphere	$f_1(x) = \sum_{i=1}^n x_i^2$	0
2.	Schwefel' problem 2.22	$f_2(x) = \sum_{i=1}^n  x_i  + \prod_{i=1}^n  x_i $	0
3.	Schwefel 1.2 Function	$f_3(x) = \sum_{i=1}^n \left( \sum_{j=1}^i x_j \right)^2$	0
4.	Schwefel 2.21 Function	$f_4(x) = \max_i \{ x_i , 1 \leq i \leq n\}$	0
5.	Rosenbrock Function	$f_5(x) = \sum_{i=1}^{n-1} [100(x_{i+1} - x_i)^2 + (x_i - 1)^2]$	0
6.	Step 2 Function	$f_6(x) = \sum_{i=1}^n ([x_i + 0.5])^2$	0
7.	Quartic Function	$f_7(x) = \sum_{i=1}^n i x_i^4 + \text{random}[0,1)$	0

ตารางที่ 4 ฟังก์ชันเทียบเคียงพหุฐานนิยม

ฟังก์ชันที่	ชื่อฟังก์ชัน	สมการ	$f(x)$
8.	Schwefel 2.26 Function	$f_8(x) = \sum_{i=1}^n -x_i \sin(\sqrt{ x_i })$	-12569.5
9.	Rastrigin Function	$f_9(x) = \sum_{i=1}^n [x_i^2 - 10 \cos(2\pi x_i) + 10]$	0
10.	Ackley Function	$f_{10}(x) = -20 \exp\left(-0.2 \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}\right) - \exp\left(\frac{1}{n} \sum_{i=1}^n \cos(2\pi x_i)\right) + 20 + e$	0
11.	Griewank Function	$f_{11}(x) = \frac{1}{4000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1$	0
12.	Generalized Penalized Function 1	$f_{12}(x) = \frac{\pi}{n} \left\{ 10 \sin(\pi y_1) + \sum_{i=1}^{n-1} (y_i - 1)^2 [1 + 10 \sin^2(\pi y_{i+1})] \right. \\ \left. + (y_n - 1)^2 \right\} + \sum_{i=1}^n u(x_i; 10, 100, 4)$ $y_i = 1 + \frac{x_i + 1}{4} u(x_i, a, k, m) = \begin{cases} k(x_i - a)^m & x_i > a \\ 0 & -a < x_i < a \\ k(-x_i - a)^m & x_i < -a \end{cases}$	0
13.	Generalized Penalized Function 2	$f_{13}(x) = 0.1 \left\{ \sin^2(3\pi x_1) + \sum_{i=1}^n (x_i - 1)^2 [1 + \sin^2(3\pi x_i + 1)] \right. \\ \left. + (x_n - 1)^2 [1 + \sin^2(2\pi x_n)] \right\} + \sum_{i=1}^n u(x_i, 5, 100, 4)$	0



ตารางที่ 5 ฟังก์ชันเทียบเคียงพหุนามนิยามกำหนดขนาด

ฟังก์ชันที่	ชื่อฟังก์ชัน	สมการ	$f(x)$
14.	Foxholes Function	$f_{14}(x) = \left( \frac{1}{500} + \sum_{j=1}^{25} \frac{1}{j + \sum_{i=1}^2 (x_i - a_{ij})^6} \right)^{-1}$	1
15.	Kowalik Function	$f_{15}(x) = \sum_{i=1}^{11} \left[ a_i - \frac{x_1 (b_i^2 + b_i x_2)}{b_i^2 + b_i x_3 + x_4} \right]^2$	0.00030
16.	Six-Hump Camel-Back	$f_{16}(x) = 4x_1^2 - 2.1x_1^4 + \frac{1}{3}x_1^6 + x_1x_2 - 4x_2^2 + 4x_2^4$	-1.0316
17.	Branin RCOS 2 Function	$f_{17}(x) = \left( x_2 - \frac{5.1}{4\pi^2} x_1^2 + \frac{5}{\pi} x_1 - 6 \right)^2 + 10 \left( 1 - \frac{1}{8\pi} \right) \cos x_1 + 10$	0.398
18.	Goldstein Price Function	$f_{18}(x) = [1 + (x_1 + x_2 + 1)^2 (19 - 14x_1 + 3x_1^2 - 14x_2 + 6x_1x_2 + 3x_2^2)] \times [30 + (2x_1 - 3x_2)^2 \times (18 - 32x_1 + 12x_1^2 + 48x_2 - 36x_1x_2 + 27x_2^2)]$	3
19.	Hartman 3 Function	$f_{19}(x) = -\sum_{i=1}^4 c_i \exp \left( -\sum_{j=1}^3 a_{ij} (x_j - p_{ij})^2 \right)$	-3.86
20.	Hartman 6 Function	$f_{20}(x) = -\sum_{i=1}^4 c_i \exp \left( -\sum_{j=1}^6 a_{ij} (x_j - p_{ij})^2 \right)$	-3.32
21.	Shekel 5	$f_{21}(x) = -\sum_{i=1}^5 \left[ (X - a_i)(X - a_i)^T + c_i \right]^{-1}$	-10.1532
22.	Shekel 7	$f_{22}(x) = -\sum_{i=1}^7 \left[ (X - a_i)(X - a_i)^T + c_i \right]^{-1}$	-10.4028
23.	Shekel 10	$f_{23}(x) = -\sum_{i=1}^{10} \left[ (X - a_i)(X - a_i)^T + c_i \right]^{-1}$	-10.5363

#### 4. ผลการทดลอง

จากการทดลองทั้งหมด 23 ฟังก์ชัน ด้วยการทดลองเชิงแฟคทอเรียลเต็มรูปที่ 3 ระดับ โดยวิเคราะห์ความแปรปรวน (ANOVA) ซึ่งพิจารณา ค่า  $P$ -Value ของแต่ละปัจจัย พบว่า ฟังก์ชัน  $f_1(x)$ ,  $f_2(x)$ ,  $f_3(x)$ ,  $f_5(x)$ ,  $f_8(x)$ ,  $f_9(x)$ ,  $f_{10}(x)$ ,  $f_{12}(x)$

และ  $f_{15}(x)$  มีค่า  $P$ -Value น้อยกว่า 0.05 แสดงว่า ค่าพารามิเตอร์ของแต่ละปัจจัยส่งผลกระทบต่อสนองของการทดลองอย่างมีนัยสำคัญ ในทางกลับกันการทดลองของฟังก์ชัน  $f_{14}(x)$ ,  $f_{16}(x)$ ,  $f_{20}(x)$  พบว่า ค่าคำตอบที่ได้ในแต่ละชุดการทดลองมีคำตอบเดียวกัน และเป็นคำตอบที่เท่ากับคำตอบของฟังก์ชันเทียบเคียง ซึ่งใน



## บทความวิจัย

การทดลองสามารถสรุปได้ว่า ค่าพารามิเตอร์ที่ทดสอบสามารถกำหนดค่าใดก็ได้ในทุกพารามิเตอร์จะให้ค่าตอบที่ไม่แตกต่างกัน

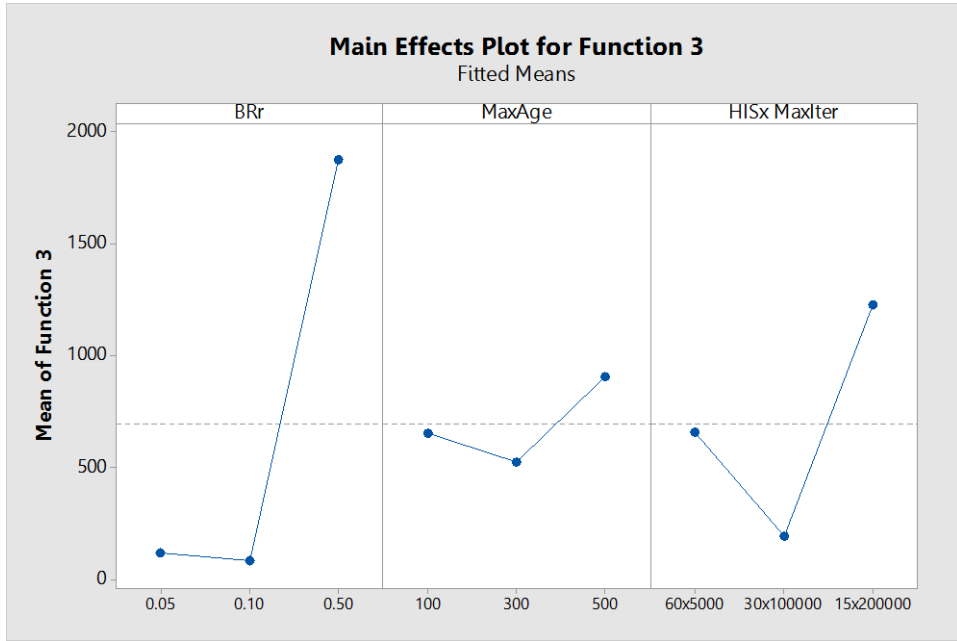
จากตารางที่ 6 เป็นตัวอย่างการวิเคราะห์ ANOVA ของฟังก์ชัน  $f_3(x)$  พบว่า ปัจจัยหลัก (Main Effect) ที่มีอิทธิพลต่อค่าคำตอบ คือ  $BR_r$  และ  $HIS \times MaxItr$  อย่างมีนัยสำคัญ ( $P-Value < 0.05$ ) โดยเมื่อพิจารณาปฏิสัมพันธ์แบบสองทาง (2-Way Interactions) พบว่า  $BR_r * HIS \times MaxItr$  และ  $Max_{Age} * HIS \times MaxItr$  มีอิทธิพลต่อค่าคำตอบอย่างมีนัยสำคัญ เช่นเดียวกับปฏิสัมพันธ์แบบสามทาง (3-Way Interactions) ที่  $BR_r * Max_{Age} * HIS \times MaxItr$  มีค่า  $P-Value < 0.05$  เมื่อพิจารณาจากกราฟ Main Effect แสดงให้เห็นว่า

การกำหนดค่า  $BR_r$ ,  $Max_{Age}$  และ  $HIS \times MaxItr$  ที่ 0.1, 300 และ  $30 \times 100,000$  ตามลำดับ ให้ค่าคำตอบต่ำสุดแสดงดังรูปที่ 2

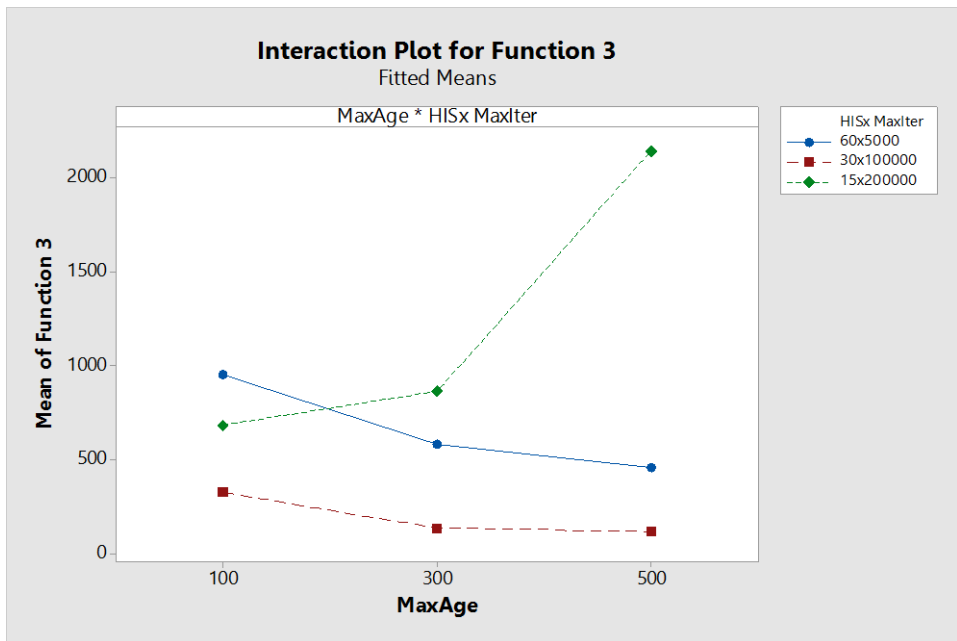
รูปที่ 3 เป็นกราฟวิเคราะห์อิทธิพลร่วมระหว่างปัจจัย (Interaction Plot) ของ  $f_3(x)$  พบว่า อิทธิพลร่วมระหว่างปัจจัย  $Max_{Age}$  กับ  $HIS \times MaxItr$  มีผลต่อค่าคำตอบไม่แตกต่างกัน ถ้ากำหนดค่า  $Max_{Age}$  ที่ 300 หรือ 500 โดยค่า  $HIS \times MaxItr$  ที่  $30 \times 100,000$  ในทางกลับกันถ้ากำหนดให้ค่า  $Max_{Age}$  ที่ 100 ค่าคำตอบที่ได้จะไม่ใช่ค่าคำตอบที่ต่ำสุด และเมื่อพิจารณาร่วมกับค่า  $HIS \times MaxItr$  ที่  $15 \times 200,000$  พบว่า มีค่าคำตอบที่สูงขึ้นมากกว่าการกำหนดที่ระดับอื่น ๆ

ตารางที่ 6 ผลการวิเคราะห์ความแปรปรวนสำหรับ  $f_3(x)$

Source	DF	Adj SS	Adj MS	F-Value	P-Value
Model	26	141833285	5455126	7.76	0.000
Linear	6	73176625	12196104	17.35	0.000
$BR_r$	2	56607766	28303883	40.27	0.000
$Max_{Age}$	2	2034636	1017318	1.45	0.244
$HIS \times MaxItr$	2	14534223	7267112	10.34	0.000
2-Way Interactions	12	47868846	3989070	5.68	0.000
$BR_r * Max_{Age}$	4	4750942	1187735	1.69	0.166
$BR_r * HIS \times MaxItr$	4	32349097	8087274	11.51	0.000
$Max_{Age} * HIS \times MaxItr$	4	10768807	2692202	3.83	0.008
3-Way Interactions	8	20787815	2598477	3.70	0.002
$BR_r * Max_{Age} * HIS \times MaxItr$	8	20787815	2598477	3.70	0.002
Error	54	37950312	702784		
Total	80	179783597			



รูปที่ 2 การวิเคราะห์ Main Effects Plot ของ  $f_3(x)$



รูปที่ 3 การวิเคราะห์ Interaction Plot ของ  $f_3(x)$



จากการทดลองสามารถสรุปการหาค่าพารามิเตอร์ที่เหมาะสมของวิธี CHIO ในสมการฟังก์ชันเทียบเคียง  $f_1(x) - f_{23}(x)$  แสดงดังตารางที่ 7 จากค่าพารามิเตอร์ที่ทดลองพบว่า การกำหนด  $HIS \times MaxIter$  ของวิธี CHIO มี 2 ค่าที่เหมาะสม คือ 60x50,000 และ 30x100,000 ซึ่งหมายความว่า ถ้ากำหนดให้จำนวนคำตอบในแต่ละรอบมีค่าที่สูงและจำนวนรอบการค้นหาคำตอบที่ต่ำสามารถให้คำตอบที่ดีกว่าจำนวนคำตอบในแต่ละรอบต่ำและจำนวนรอบในการค้นหาคำตอบสูง ในทางกลับกัน ค่า  $BR_r$  ควรเป็นค่าที่ต่ำ ส่วนค่า  $Max_{Age}$  จะขึ้นอยู่กับลักษณะของฟังก์ชันเทียบเคียง

ค่าพารามิเตอร์ที่เหมาะสมในตารางที่ 7 นำมากำหนดเพื่อทดสอบกับสมการฟังก์ชันเทียบเคียงเพื่อยืนยัน จำนวน 30 ครั้ง ใน 23 ฟังก์ชัน พบว่า วิธี CHIO ให้คำตอบเท่ากับคำตอบของฟังก์ชันเทียบเคียงจำนวน 12 ฟังก์ชัน จากทั้งหมด 23 ฟังก์ชัน เมื่อพิจารณาในแต่ละกลุ่ม พบว่า มีจำนวนคำตอบในฟังก์ชันเทียบเคียงฐานนิยมเดียว และฟังก์ชันเทียบเคียงพหุฐานนิยมจำนวนกลุ่มละ 2 ฟังก์ชัน และฟังก์ชันเทียบเคียงพหุฐานนิยมกำหนดขนาดจำนวน 8 ฟังก์ชัน เมื่อทำการเปรียบเทียบกับงานวิจัยของ Al-Betar et al. [13] ที่ทดลองกับสมการฟังก์ชันกำหนด  $HIS$  ที่ 30 และ  $MaxIter$  ที่ 100,000 รอบ พบว่า วิธี CHIO มีคำตอบต่ำกว่าจำนวน 3 ฟังก์ชัน (อักษรเข้มและเอียง) ใน  $f_3(x)$ ,  $f_5(x)$  ในฟังก์ชันเปรียบเทียบฐานนิยมเดียวและ  $f_{15}(x)$  ในฟังก์ชันเปรียบเทียบพหุฐานนิยมกำหนดขนาด เมื่อพิจารณา  $BR_r$  และ  $Max_{Age}$  พบว่ามีค่าที่

ตารางที่ 7 ค่าพารามิเตอร์ที่ได้จากการทดลอง

ฟังก์ชันที่	$BR_r$	$Max_{Age}$	$HIS \times MaxIter$
1	0.05	100	60x50,000
2	0.05	100	60x50,000
3	0.1	300	30x100,000
4	0.05	300	30x100,000
5	0.05	500	30x100,000
6	0.05	300	30x100,000
7	0.05	300	60x50,000
8	0.05	300	60x50,000
9	0.05	100	60x50,000
10	0.05	300	60x50,000
11	0.05	500	60x50,000
12	0.05	100	30x100,000
13	0.05	100	60x50,000
14	0.1	300	60x50,000
15	0.5	500	30x100,000
16	0.05	100	30x100,000
17	0.1	300	60x50,000
18	0.1	300	60x50,000
19	0.05	100	30x100,000
20	0.05	100	30x100,000
21	0.05	100	30x100,000
22	0.05	100	30x100,000
23	0.5	500	30x100,000

แตกต่างกันในทุกฟังก์ชัน แต่ค่า  $HIS \times MaxIter$  เดียวกัน เมื่อเปรียบเทียบคำตอบต่ำสุดที่เท่ากับวิธีของ Al-Betar et al. [13] ใน  $f_{10}(x)$ ,  $f_{12}(x)$ ,  $f_{13}(x)$





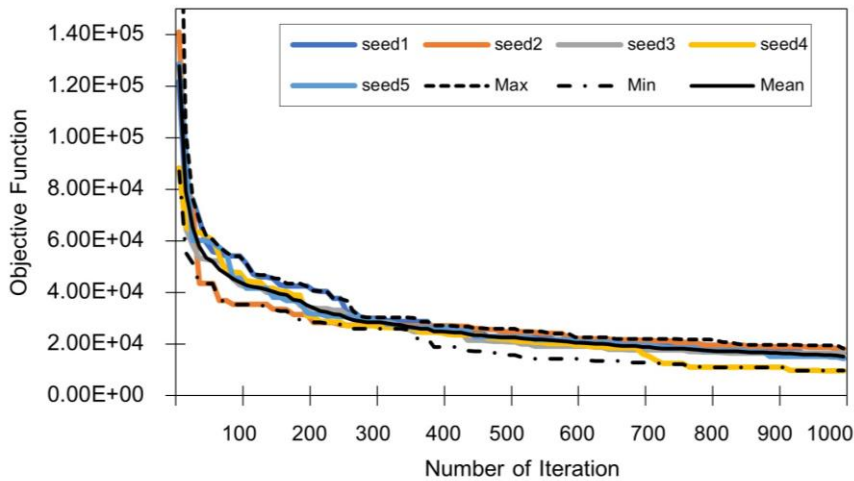
## บทความวิจัย

และ  $f_{14}(x)$  โดยค่าพารามิเตอร์ของ  $f_{12}(x)$  กำหนด  $HIS$  และ  $MaxIter$  ที่ 30 และ 100,000 ตามลำดับ เป็นค่าเดียวกับ Al-Betar et al. [13] แต่กำหนด  $BR_r$  ที่ 0.05 และ  $Max_{Age}$  ที่ 100 ส่วน  $f_{10}(x)$ ,  $f_{13}(x)$

และ  $f_{14}(x)$  จะกำหนดให้  $HIS$  ที่ 60 และ  $MaxIter$  ที่ 50,000 ซึ่งจำนวนคำตอบในแต่ละรอบจะมากกว่า เป็น 2 เท่า แต่จำนวนรอบการค้นหาคำตอบลดลง ครั้งหนึ่ง แสดงดังตารางที่ 8

ตารางที่ 8 ผลการทดลองประสิทธิภาพการค้นหาคำตอบด้วยวิธีการหาค่าที่เหมาะสมกุ่มกันหมู่ไวรัสโคโรนา

ฟังก์ชัน	$f(x)$	Al-Betar et al. [13]	Min	Mean	Max	Stdev.
1	0.0000E+00	<b>0.0000E+00</b>	<b>0.0000E+00</b>	3.6571E-03	1.1054E-02	3.7039E-03
2	0.0000E+00	3.1404E-284	1.1641E-137	3.6651E-02	6.5431E-02	2.2900E-02
3	0.0000E+00	7.8863E-01	<b>6.8871E-05</b>	8.4203E+01	2.6539E+02	7.9032E+01
4	0.0000E+00	1.0365E-13	1.6198E-04	1.4280E-01	4.2373E-01	1.4993E-01
5	0.0000E+00	6.6029E-04	<b>6.1125E-04</b>	7.6820E+00	1.9248E+01	6.4365E+00
6	0.0000E+00	<b>0.0000E+00</b>	<b>0.0000E+00</b>	1.4538E-02	2.8502E-02	1.1687E-02
7	0.0000E+00	1.8820E-03	4.0284E-03	9.0473E-03	1.4245E-02	2.3215E-03
8	-1.2570E+04	<b>-1.2570E+04</b>	<b>-1.2570E+04</b>	-1.2570E+04	-1.2570E+04	6.4022E-04
9	0.0000E+00	<b>0.0000E+00</b>	<b>0.0000E+00</b>	1.2570E-03	7.6696E-03	2.2951E-03
10	0.0000E+00	1.5099E-14	1.5099E-14	6.3922E-03	3.0850E-02	1.1031E-02
11	0.0000E+00	0.0000E+00	2.0215E-06	2.2423E-02	5.5480E-02	2.0667E-02
12	0.0000E+00	1.5705E-32	1.5705E-32	7.6352E-06	1.3399E-05	3.8802E-06
13	0.0000E+00	1.3498E-32	1.3498E-32	4.2788E-04	7.5055E-04	2.5671E-04
14	1.0000E+00	9.9800E-01	9.9800E-01	9.9800E-01	9.9800E-01	4.5168E-16
15	3.0000E-04	3.0836E-04	<b>3.0749E-04</b>	3.3870E-04	4.6428E-04	4.4883E-05
16	-1.0316E+00	<b>-1.0316E+00</b>	<b>-1.0316E+00</b>	<b>-1.0316E+00</b>	<b>-1.0316E+00</b>	6.7752E-16
17	3.9800E-01	<b>3.9789E-01</b>	<b>3.9789E-01</b>	<b>3.9789E-01</b>	<b>3.9789E-01</b>	1.6938E-16
18	3.0000E+00	<b>3.0000E+00</b>	<b>3.0000E+00</b>	<b>3.0000E+00</b>	<b>3.0000E+00</b>	0.0000E+00
19	-3.8600E+00	<b>-3.8628E+00</b>	<b>-3.8628E+00</b>	<b>-3.8628E+00</b>	<b>-3.8628E+00</b>	3.1618E-15
20	-3.3200E+00	<b>-3.3220E+00</b>	<b>-3.3220E+00</b>	<b>-3.3220E+00</b>	<b>-3.3220E+00</b>	1.8067E-15
21	-1.0153E+01	<b>-1.0153E+01</b>	<b>-1.0153E+01</b>	<b>-1.0153E+01</b>	<b>-1.0153E+01</b>	3.6134E-15
22	-1.0403E+01	<b>-1.0403E+01</b>	<b>-1.0403E+01</b>	<b>-1.0403E+01</b>	<b>-1.0403E+01</b>	7.2269E-15
23	-1.0536E+01	<b>-1.0536E+01</b>	<b>-1.0536E+01</b>	<b>-1.0536E+01</b>	<b>-1.0536E+01</b>	9.0336E-15



รูปที่ 4 กราฟแสดงการลู่เข้าของคำตอบใน  $f_3(x)$

รูปที่ 4 เป็นกราฟแสดงการลู่เข้าของคำตอบใน  $f_3(x)$  ที่มีค่าฟังก์ชันวัตถุประสงค์ที่  $0.0000E+00$  จำนวน 1,000 รอบ โดยแสดงคำตอบที่ดีที่สุด (Best-so-far Solution) ในแต่ละการทดลองจำนวน 5 ครั้ง และแสดงค่า *Max*, *Min* และ *Mean* ของการทดลองจากรูปแสดงให้เห็นว่าวิธี CHIO มีอัตราการลู่เข้าหาคำตอบค่อนข้างเร็วและความต่างในแต่ละการทดลองที่น้อย

## 5. บทสรุป

การแก้ปัญหาทางวิศวกรรมมีความซับซ้อนและข้อจำกัดจำนวนมาก โดยนักวิจัยพยายามพัฒนาวิธีการหาคำตอบที่เหมาะสมกับระยะเวลาที่มีอยู่ ซึ่งวิธี CHIO ถือเป็นวิธีที่พัฒนาขึ้นจากแรงบันดาลใจในการป้องกันการแพร่เชื้อไวรัสโคโรนาและงานวิจัยมีการเผยแพร่จำนวนน้อย ดังนั้น งานวิจัยนี้ได้นำเสนอวิธี CHIO ในการแก้ปัญหาเกี่ยวกับฟังก์ชันเทียบเคียง ให้มีค่าวัตถุประสงค์ตามฟังก์ชันด้วย  $3^k$  Full Factorial Design ผลการทดลองพบว่า วิธี CHIO ให้ค่าคำตอบเท่ากับคำตอบของฟังก์ชันเทียบเคียงจำนวน 12 ฟังก์ชัน จาก

ทั้งหมด 23 ฟังก์ชัน และเมื่อทำการเปรียบเทียบกับงานวิจัยของ Al-Betar et al. [13] พบว่า วิธี CHIO มีค่าคำตอบต่ำกว่าจำนวน 3 ฟังก์ชัน สำหรับงานวิจัยในอนาคตผู้วิจัยคาดหวังว่าสามารถนำวิธี CHIO ไปแก้ปัญหาทางวิศวกรรมด้านอื่น ๆ รวมไปถึงพัฒนาวิธีให้สามารถแก้ปัญหาได้ดียิ่งขึ้น อีกทั้งต้องพิจารณาการเลือกพารามิเตอร์และวิธีการปรับค่าพารามิเตอร์ให้เหมาะสมกับปัญหานั้น ๆ

## 6. เอกสารอ้างอิง

- [1] E.G. Talbi, *Metaheuristics: From design to implementation*, John Wiley & Sons, Inc., NJ, USA, 2009.
- [2] M. Batsyn, I. Bychkov, L. Komosko and A. Nikolaev, Tabu search for fleet size and mix vehicle routing problem with hard and soft time windows, *International Conference on Network Analysis, Proceeding, 2016*, 3-18.



- [3] S. Kirkpatrick, C.D. Gelatt and M.P. Vecchi, Optimization by simulated annealing, *Science*, 1983, 220(4598), 671-680.
- [4] M. Dorigo, M. Birattari and T. Stutzle, Ant colony optimization, *IEEE computational intelligence magazine*, 2006, 1(4), 28-39.
- [5] R.C. Eberhart and Y. Shi, Particle swarm optimization: Developments, applications and resources, *The 2001 Congress on Evolutionary Computation (IEEE Cat. No.01TH8546)*, Proceeding, 2001, 81-86.
- [6] W.Y. Szeto, Y. Wu and S.C. Ho, An artificial bee colony algorithm for the capacitated vehicle routing problem, *European Journal of Operational Research*, 2011, 215(1), 126-135.
- [7] E. Rashedi, H. Nezamabadi-Pour and S. Saryazdi, GSA: A gravitational search algorithm, *Information sciences*, 2009, 179(13), 2232-2248.
- [8] H. Eskandar, A. Sadollah, A. Bahreininejad and M. Hamdi, Water cycle algorithm – A novel metaheuristic optimization method for solving constrained engineering optimization problems, *Computers and Structures*, 2012, 110-111, 151-166.
- [9] B.M. Baker and M.A. Ayechev, A genetic algorithm for the vehicle routing problem, *Computers and Operations Research*, 2003, 30(5), 787-800.
- [10] Z. Zhang, O. Che, B. Cheang, A. Lim and H. Qin, A memetic algorithm for the multiperiod vehicle routing problem with profit, *European Journal of Operational Research*, 2013, 229(3), 573-584.
- [11] D. Simon, Biogeography-based optimization, *IEEE transactions on evolutionary computation*, 2008, 12(6), 702-713.
- [12] A.S. Azad, M.S.A. Rahaman, J. Watada, P. Vasant, J.A.G. Vintaned, Optimization of the hydropower energy generation using meta-heuristic approaches: A review, *Energy Reports*, 2020, 6, 2230-2248.
- [13] M.A. Al-Betar, Z.A.A. Alyasseri, M.A. Awadallah and I.A. Doush, Coronavirus herd immunity optimizer (CHIO), *Neural Computing and Applications*, 2021, 33, 5011-5042.
- [14] M. Alweshah, Coronavirus herd immunity optimizer to solve classification problems, *Soft Computing*, 2022, 1-21.
- [15] A.S. Mahboob, H.S. Shahhoseini, M.R.O. Moghaddam and S. Yousefi, A coronavirus herd immunity optimizer for intrusion detection system, *The 29<sup>th</sup> Iranian Conference on Electrical Engineering (ICEE)*, Proceeding, 2021, 579-585.



- [16] Y. AriküŖu and N. Bayhan, Design of coronavirus herd immunity optimization based PID controller for an automatic voltage regulator, TOK 2021 Otomatik Kontrol Ulusal Kongresi, Proceeding, 2021, 177-182.
- [17] S. Amini, S. Ghasemi, H. Golpira and A. Anvari-Moghaddam, Coronavirus herd immunity optimizer (CHIO) for transmission expansion planning, 2021 IEEE International Conference on Environment and Electrical Engineering and 2021 IEEE Industrial and Commercial Power Systems Europe (EEEIC/I&CPS Europe), Proceeding, 2021, 1-6.
- [18] M.M. Refaat, S.H.A. Aleem, Y. Atia, Z.M. Ali and M.M. Sayed, AC and DC transmission line expansion planning using coronavirus herd immunity optimizer, The 22<sup>nd</sup> International Middle East Power Systems Conference (MEPCON 2021), Proceeding, 2021, 313-318.
- [19] M. Alqarni, Sodium sulfur batteries allocation in high renewable penetration microgrids using coronavirus herd immunity optimization, Ain Shams Engineering Journal, 2022, 13(2), 101590.
- [20] C. Kumar, D.M. Mary and T. Gunasekar, MOCHIO: A novel multi-objective coronavirus herd immunity optimization algorithm for solving brushless direct current wheel motor design optimization problem, Automatika, 2022, 63(1), 149-170.
- [21] S.N. Makhadmeh, M.A. Al-Betar, M.A. Awadallah, A.K. Abasi, Z.A.A. Alyasseri, I.A. Doush, O.A. Alomari, R. Damasevicius, A. Zajanckauskas and M.A. Mohammed, A modified coronavirus herd immunity optimizer for the power scheduling problem, Mathematics, 2022, 10(3), 315.
- [22] A. Naderipour, A. Abdullah, M.H. Marzbali and S.A. Nowdeh, An improved corona-virus herd immunity optimizer algorithm for network reconfiguration based on fuzzy multi-criteria approach, Expert Systems with Applications, 2022, 187, 115914.
- [23] Z.M. Ali, S.H.A. Aleem, A.I. Omar and B.S. Mahmoud, Economical-environmental-technical operation of power networks with high penetration of renewable energy systems using multi-objective coronavirus herd immunity algorithm, Mathematics, 2022, 10, 1201.



- [24] L.M. Dalbah, M.A. Al-Betar, M.A. Awadallah and R.A. Zitar, A coronavirus herd immunity optimization (CHIO) for travelling salesman problem, International Conference on Innovative Computing and Communications, Proceeding, 2022, 717-729.
- [25] L.M. Dalbah, M.A. Al-Betar, M.A. Awadallah and R.A. Zitar, A modified coronavirus herd immunity optimizer for capacitated vehicle routing problem, Journal of King Saud University-Computer and Information Sciences, 2022, 34(8), 4782-4795
- [26] M. Alweshah, S. Alkhalileh, M.A. Al-Betar and A.A. Bakar, Coronavirus herd immunity optimizer with greedy crossover for feature selection in medical diagnosis, Knowledge-Based Systems, 2022, 235, 107629.
- [27] M. Jamil and X. Yang, A literature survey of benchmark functions for global optimisation problems, International Journal of Mathematical Modelling and Numerical Optimisation, 2013, 4(2), 150-194.