



การเปรียบเทียบการปรับแต่งขั้นตอนวิธีเชิงพันธุกรรมแบบหลายวัตถุประสงค์ ด้วยแบ่งกลุ่มประชากรเริ่มต้น โดยใช้รูปแบบความเหมาะสมในการระบายน้ำ

A Comparison of Partition of Initial population for Multi-objective Genetic Algorithm using by Optimal Drainage

พฤตพิงศ์ เพ็งศิริ (Prudtipong Pengsiri)* สุนันธา สดสี (Sunantha Sodsee)**
และ พยุง มีสัจ (Phayung Meesad)***

Received : July 19, 2018
Revised : August 17, 2018
Accepted : September 10, 2018

บทคัดย่อ

บทความนี้เป็นการนำเสนอการเปรียบเทียบขั้นตอนวิธี การหาความเหมาะสมแบบหลายวัตถุประสงค์ ด้วยวิธีการ ใหม่ ซึ่งเป็นขั้นตอนวิธีเชิงพันธุกรรมแบบหลายวัตถุประสงค์ ด้วยการแบ่งกลุ่มประชากรเริ่มต้นเรียกว่า PIMOGA (Partition of Initial population for Multi-objective Genetic Algorithm) โดยเป็นการประยุกต์การขั้นตอนวิธีการจัดกลุ่มแบบ K-Means เพื่อแบ่งกลุ่มย่อยของประชากรเริ่มต้น โดยมุ่งเน้นถึง ประสิทธิภาพในการค้นหาคำตอบแบบกว้างของรูปแบบ ความเหมาะสมในการระบายน้ำ ซึ่งได้มาจากผลลัพธ์ของ ค่าพยากรณ์ด้วยวิธีปรับเรียบเอกซ์โพเนนเชียลของวินเทอร์ เป็นพยากรณ์ข้อมูลอนุกรมเวลาแบบแนวโน้มและมีอิทธิพล ของฤดูกาล ทำให้ได้สมการความเหมาะสมของวัตถุประสงค์ ทั้งหมด 7 วัตถุประสงค์ และตัวแปรอิสระจำนวน 5 ตัวแปร ผลการทดลองของ PIMOGA พบว่า 1) ค่า $k = 3$ มีค่าเฉลี่ย ของจำนวนการเกิดรุ่นครั้งสุดท้ายมีความเหมาะสมที่นำไป ทดลองกับ PIMOGA 2) PIMOGA มีค่าการวัดค่าเวลา กิจกรรมในการทดสอบ ซึ่งสามารถเพิ่มประสิทธิภาพใน การค้นหาคำตอบที่มีการเกิดรุ่นครั้งสุดท้ายมีจำนวนน้อยกว่า MOGA และ MOPSO จึงมีความสามารถในการเพิ่ม ประสิทธิภาพในการค้นหาคำตอบแบบกว้างได้ดีกว่า MOGA และ MOPSO ยกเว้นขั้นตอนวิธีแบบ MOEA และงานวิจัยนี้

ได้นำเสนอแอปพลิเคชันเพื่อสนับสนุนการประมาณค่า ปริมาณน้ำในการระบายของโครงข่ายด้วยวิธีการ PIMOGA โดยการระบุค่าเริ่มต้นเป็นวันที่และค่าอิทธิพลฤดูกาล ซึ่งพบ ว่าสามารถประมาณค่าปริมาณน้ำในระบายได้อย่างมี ประสิทธิภาพ

คำสำคัญ: ปัญหาหาความเหมาะสมหลายวัตถุประสงค์ ขั้นตอนวิธีเชิงพันธุกรรมแบบหลายวัตถุประสงค์ ขั้นตอน วิธีการจัดกลุ่ม การแบ่งกลุ่มประชากรเริ่มต้น

Abstract

This paper proposes a new Multi-Objective Optimization Problems (MOOP), which is called a Partition of Initial Population for Multi-Objective Genetic Algorithm (PIMOGA). It applies a clustering algorithm, which is K-Means clustering algorithm, for partition an initial population into small groups aiming to achieve global solutions efficiently. This proposed work is of the drainage suitability model. This is derived from the results of the predictive value with Holt-Winters' Exponential Smoothing method, which was time series forecasted. The equation of appropriateness of all objectives 7 and 5 independent variables. The results of PIMOGA's

* ภาควิชาเทคโนโลยีสารสนเทศ คณะเทคโนโลยีสารสนเทศ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

* Department of Information Technology, Faculty of Information Technology, King Mongkut's University of Technology North Bangkok.

** ภาควิชาการสื่อสารข้อมูลและเครือข่าย คณะเทคโนโลยีสารสนเทศ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

** Department of Data Communication and Networking, Faculty of Information Technology, King Mongkut's University of Technology North Bangkok.

*** ภาควิชาการจัดการเทคโนโลยีสารสนเทศ คณะเทคโนโลยีสารสนเทศ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

*** Department of Information Technology Management, Faculty of Information Technology, King Mongkut's University of Technology North Bangkok.



experiment showed that 1) $k = 3$ had the lowest number of terminated generation. Therefore, it was suitable for PIMOGA experiment. 2) PIMOGA had time measurement Test Activity Measured Time, which can be used to increase the efficiency of searching for the last generation of solutions. MOGA and MOPSO have the ability to improve search performance. The Global Optimal Solution is better than MOGA and MOPSO, except MOEA. And this research provides an application to support the estimation of water volume in the network drainage using PIMOGA method by specifying the defaults as date and season influences. It was found that the efficiency in the estimation of water volume in the drainage.

Keywords: Multi-Objective Optimization Problems, Multi-Objectives Genetic Algorithm, Clustering Algorithms, Initial Population Partition.

1. บทนำ

ในการบริหารจัดการทรัพยากรน้ำซึ่งเป็นทรัพยากรทางธรรมชาติที่สำคัญอย่างยิ่งในประเทศไทย และคงไม่อาจปฏิเสธได้ว่าการจัดการบริหารทรัพยากรน้ำคือภาระบายน้ำจากแหล่งน้ำจะช่วยทำให้ลดการเกิดสภาวะน้ำท่วมหรือเพื่อใช้ในการเกษตร และบริโภคของภาคประชาชน ซึ่งปัญหาที่ได้กล่าวมานี้อาจเป็นปัญหาที่อยู่เหนือการควบคุมแต่ยังมีอีกหนึ่งสิ่งที่ยังมองไม่เห็นถึงแนวทางการป้องกันเกิดปัญหานี้ได้คือการจัดการบริหารทรัพยากรน้ำหรืออีกนัยหนึ่งคือการควบคุมดูแลการระบายน้ำ โดยอาศัยการระบายน้ำจากประตูระบายน้ำ (ปตร.) เป็นหลักสำคัญการระบายน้ำหากการระบายน้ำมีรูปแบบของการระบายที่แน่นอนก็จะทำให้ช่วยลดการเกิดปัญหาทั้งน้ำท่วม-น้ำแล้งได้ ในทางเดียวกันผู้วิจัยได้การศึกษาและทดลองเปรียบเทียบรูปแบบความเหมาะสมในการระบายน้ำด้วยเทคนิคการพยากรณ์แบบอนุกรมเวลา เพื่อหารูปแบบค่าความเหมาะสมในการระบายน้ำจากการเปรียบเทียบเทคนิคการพยากรณ์โดยได้พบว่ารูปแบบการระบายน้ำที่ได้ค่าพยากรณ์ที่ดีที่สุดคือรูปแบบของวิธีปรับเรียบเอกซ์โพเนนเชียลของวินเทอร์ (Holt-Winters' Exponential Smoothing) ซึ่งได้ผลลัพธ์ออกมาเป็นรูปแบบการพยากรณ์ที่เป็น ซึ่งเป็นลักษณะของ

การวิเคราะห์พยากรณ์ข้อมูลแบบแนวโน้ม (Trend Component: $T_i(t)$) และมีอิทธิพลของฤดูกาล (Seasonal Component: $S_i(t)$) จะเห็นได้ว่ารูปแบบความเหมาะสมการระบายน้ำที่พบนี้สามารถนำมาวิเคราะห์และกำหนดเป็นฟังก์ชันความเหมาะสม (Fitness Function) ของขั้นตอนวิธีเชิงพันธุกรรมแบบหลายวัตถุประสงค์ (Multi-objective Genetic Algorithm: MOGA) ขณะเดียวกันผู้วิจัยได้ทำการทดลองปรับแต่งขั้นตอนวิธีเชิงพันธุกรรมแบบหลายวัตถุประสงค์ด้วยการแบ่งกลุ่มประชากรเริ่มต้นเรียกว่า PIMOGA (Partition of Initial population for Multi-objective Genetic Algorithm) [1] ซึ่งเป็นการประยุกต์การขั้นตอนวิธีการจัดกลุ่มแบบ K-Means เพื่อแบ่งกลุ่มย่อยของประชากรเริ่มต้น ดังนั้นในงานวิจัยนี้ได้มุ่งเน้นถึงประสิทธิภาพในการค้นหาคำตอบแบบกว้าง (Global Solution) โดยได้นำมาเปรียบเทียบการหาคำตอบ (Solutions) การเกิดจำนวนของรุ่นครั้งสุดท้าย (Terminated Generation) และการวัดค่าเวลากิจกรรมในการทดสอบ (Test Activity Measured Time) ด้วยการเปรียบเทียบวิธีการ 3 ขั้นตอนวิธีคือ ขั้นตอนวิธีเชิงพันธุกรรมแบบหลายวัตถุประสงค์ (Multi-objective Genetic Algorithm: MOGA) [2] ขั้นตอนวิธีหาค่าเหมาะสมที่สุดแบบกลุ่มอนุภาค (Multi-Objective Particle Swarm Optimization Algorithm: MOPSO) [3], [4] และขั้นตอนวิธีวิวัฒนาการแบบหลายวัตถุประสงค์ (Multi-Objective Evolutionary Algorithm: MOEA) [5]

2. ทฤษฎีและวรรณกรรมที่เกี่ยวข้อง

2.1 ปัญหาการหาค่าเหมาะสมที่สุดแบบวัตถุประสงค์เดียว (Single-Objective Optimization Problem)

การหาค่าเหมาะสมที่สุด (Optimization) เป็นวิธีการที่ใช้ในการหาคำตอบที่ดีที่สุดของปัญหาภายใต้เงื่อนไข หรือข้อจำกัดที่กำหนดขึ้น การหาค่าเหมาะสมที่สุดถือว่าเป็นสิ่งที่ช่วยในการแก้ปัญหาในด้านวิทยาการคอมพิวเตอร์ ปัญญาประดิษฐ์ การวิจัยการดำเนินงาน ซึ่งมีวิธีการทางคณิตศาสตร์มากมายที่สามารถประยุกต์ ใช้เพื่อหาจุดที่ดีที่สุดการหาจุดที่ดีที่สุด (Optimization or Mathematical Programming) [6] ก็คือ "การหาค่า x ซึ่งทำให้ $f(x)$ มีค่าต่ำสุดหรือสูงสุด"

2.1.1 ขั้นตอนวิธีเชิงพันธุกรรม (Genetic Algorithm: GA) ใช้หลักการคัดเลือกแบบธรรมชาติและหลักการทางสายพันธุ์อยู่ในขั้นตอนของการค้นหาคำตอบ ซึ่งปัจจุบันเป็น



ที่ยอมรับในประสิทธิภาพและมีการนำไปประยุกต์ใช้อย่างกว้างขวางในการแก้ปัญหาการหาค่าเหมาะที่สุด ลักษณะการทำงานของการค้นหาคำตอบแบบขั้นตอนเชิงฮิวริสติก (Heuristic) ในเรื่องการอยู่รอดของผู้ที่แข็งแรงที่สุด เริ่มต้น GA จึงเรียกขั้นตอนนี้ ขั้นตอนวิธีเชิงพันธุกรรมในการหาค่าเหมาะที่สุดวัตถุประสงค์เดียว (Single-objective Optimization Genetic Algorithm; SOGA) [7] โดยมีกระบวนการพื้นฐานการทำงานตามขั้นตอนดังนี้

ขั้นตอนที่ 1: พิจารณาหาคำตอบของปัญหาจากกลุ่มของคำตอบหรือประชากร (Population) [8] ของคำตอบแต่ละคำตอบจะมีคุณลักษณะเฉพาะตัวซึ่งแสดงอยู่ในรูปของโครโมโซม (Chromosome) หรือในรูปจีโนม (Genome) รูปแบบที่ง่ายที่สุดคือการกำหนดให้โครโมโซมอยู่ในรูปของตัวแปรแบบสตริง (String of Variables)

ขั้นตอนที่ 2: ทำการถอดรหัสของโครโมโซมทั้งหมดในกลุ่มประชากรเพื่อที่จะได้กลุ่มคำตอบของปัญหาที่พิจารณา

ขั้นตอนที่ 3: หลังจากได้คำตอบที่จากการถอดรหัสทำการหาค่าฟังก์ชันวัตถุประสงค์ของแต่ละคำตอบในกลุ่มประชากรทั้งหมด

ขั้นตอนที่ 4: ทำการคำนวณค่าความแข็งแรงของแต่ละคำตอบโดยใช้ค่าวัตถุประสงค์ที่ได้มา

ขั้นตอนที่ 5: เลือกกลุ่มประชากรรุ่นพ่อแม่จากกลุ่มประชากรรุ่นปัจจุบัน โดยในการเลือกนั้นจะใช้ค่าความแข็งแรงเป็นตัวบ่งชี้ว่าจะเลือกคำตอบใดจากประชากรปัจจุบันนี้

ขั้นตอนที่ 6: ทำการเปลี่ยนแปลงกลุ่มประชากรรุ่นพ่อแม่ด้วยใช้ตัวดำเนินการพันธุกรรม ซึ่งก็คือ การสลับสายพันธุ (Crossover) และการกลายพันธุ์ (Mutation) กลับไปทำซ้ำขั้นตอนที่ 2 จนกระทั่งคำตอบลู่เข้า หรือจนกระทั่งครบจำนวนการทำซ้ำที่กำหนด โดย 1 รอบของขั้นตอนที่ 2 ถึง 6 ก็คือ 1 รุ่น (Generation) ของการหาคำตอบด้วยขั้นตอนวิธีเชิงพันธุกรรม คำตอบที่ดีที่สุดของประชากรรุ่นสุดท้ายก็คือผลลัพธ์ของ GA

2.1.2 การหาค่าเหมาะที่สุดแบบกลุ่มอนุภาค (Particle Swarm Optimization; PSO) พัฒนาขึ้นโดยเอเบอร์ฮาร์ดและเคนเนดี (Kennedy and Eberthart) [4], [9] โดยมีแนวคิดมาจากการจำลองวิธีการหาค่าเหมาะที่สุดจากพฤติกรรมการบินหรือหาอาหารของฝูงสัตว์ โดยเฉพาะ

ฝูงนก ฝูงปลา PSO เป็นการจำลองการหาอาหารของฝูงนกในการหาค่าเหมาะที่สุดแบบนี้ นกแต่ละตัวในฝูงจะถูกแทนด้วยอนุภาค (Particle) ในอนุภาคแต่ละตัวจะมีค่า ฟิตเนส (Fitness Value) ที่บอกถึงระยะห่างของตัวมันจากแหล่งอาหาร โดยอนุภาคทั้งหมดจะบินตามอนุภาคที่มีค่าฟิตเนสที่ดีที่สุดในแต่ละช่วง/รอบ (Iteration) แนวคิดของ PSO จะเริ่มต้นด้วยการสุ่มหาตำแหน่งของอนุภาค จากนั้นก็จะหาค่าเหมาะที่สุดด้วยการปรับปรุงค่าในแต่ละรอบของการตัดสินใจ โดยที่อนุภาคแต่ละตัวจะมีการปรับปรุงค่าด้วยการเปลี่ยนตำแหน่งตามค่าที่ดีที่สุด ซึ่งมี 2 ค่า ได้แก่ ค่าที่ดีที่สุดของอนุภาค (Pbest : Particle Best) คือค่าตำแหน่งที่ดีที่สุดของการเคลื่อนที่ที่ผ่านมาของตัวเอง ค่าที่ดีที่สุดของสากล (Gbest : Global Best) คือค่าที่เป็นค่าที่ดีที่สุดการเคลื่อนที่ที่ผ่านมาของทั้งกลุ่ม (ฝูง) ดังนั้นในหนึ่งอนุภาคเมื่อแทนด้วยพารามิเตอร์ของปัญหาหนึ่งจะประกอบด้วยตัวแปร ดังสมการ (1)

$$P_k = \{X, V, \text{Fitness value}, Gbest, Pbest\} \quad (1)$$

โดย P คือ อนุภาคประกอบด้วย $P = \{P_1, P_2, \dots, P_k\}$

k คือ จำนวนอนุภาค

X คือ ตำแหน่งที่อนุภาคที่อยู่ในปัญหา เขียนในรูป $X_D = \{X_1, X_2, \dots, X_D\}$

D คือ จำนวนมิติของปัญหา

V คือ ค่าความเร็วในการเคลื่อนที่ของอนุภาค (Velocity) ประกอบด้วยเวกเตอร์ตามขนาดของมิติของปัญหา $V_D = \{V_1, V_2, \dots, V_D\}$

Fitness value คือ ค่าความเหมาะสมของอนุภาค นั้นสามารถคำนวณได้จากฟังก์ชันเป้าหมายซึ่งได้จาก $Fitness\ value = objective\ function(X)$

$Gbest_D$ คือ ค่าตำแหน่งที่อนุภาคนั้นได้ค่าความเหมาะสมสูงสุด โดย $Gbest_D = \{Gbest_1, Gbest_2, \dots, Gbest_D\}$

$Pbest$ คือ ค่าความเหมาะสมที่ดีที่สุดที่กลุ่มอนุภาครุ่นปัจจุบันได้มา

2.1.3 ขั้นตอนวิธีวิวัฒนาการ (Evolutionary Algorithm: EA) เป็นหลักการเดียวกับ GA โดยที่ได้เซตย่อยของการคำนวณวิวัฒนาการ ซึ่ง EA [10] โดยได้แรงบันดาลใจจากวิวัฒนาการทางชีวภาพมาใช้กลไก เช่นการสืบพันธุ์ การกลายพันธุ์การรวมตัวใหม่และการเลือก การคำตอบของตัวเปรียบเทียบ (Candidate Solutions) ในการแก้ปัญหา การเพิ่มประสิทธิภาพมีให้กับประชากรด้วยฟังก์ชัน

ความเหมาะสม (Fitness Function) เป็นตัวกำหนดคุณภาพของคำตอบ การวิวัฒนาการของประชากรจะเกิดขึ้นหลังจากการใช้งานซ้ำไปจนกว่าจะหาคำตอบได้ครบ ในความเป็นจริงความซับซ้อนของการคำนวณนี้เป็นเพราะการประเมินสมรรถภาพของฟังก์ชันความเหมาะสมเป็นวิธีหนึ่งในการแก้ปัญหา ดังนั้นอาจไม่มีการเชื่อมโยงโดยตรงระหว่างความซับซ้อนของอัลกอริทึมและความซับซ้อนของปัญหา ซึ่งกระบวนการมีการกระทำของระบบของการวิวัฒนาการคือ

- 1) ตัวดำเนินการที่เปลี่ยนแปลงได้ (Variation Operator) สำหรับการสืบพันธุ์และการกลายพันธุ์ ซึ่งจะทำการสร้างความหลากหลายและความแปลกใหม่ที่จำเป็น ระหว่างที่
- 2) การคัดเลือก (Selection) ทำหน้าที่เป็นแรงที่ผลักดันคุณภาพ
- 3) ในประชากรที่ต่อเนื่องกัน (Consecutive Population) มีความง่ายที่จะเห็นว่าการวิวัฒนาการนี้ ถูกใช้งานอย่างเหมาะสม หรืออย่างน้อย ก็ใกล้เคียง โดยจะเห็นถึงการเข้าใกล้ค่าที่ถูกต้องเหมาะสมทุกๆ รอบของการวิวัฒนาการ

2.2 ปัญหาการหาค่าเหมาะสมที่สุดแบบหลายวัตถุประสงค์ (Multi-Objective Optimization Problem)

หลังจากขั้นตอน SOGA ได้มีการดัดแปลงใช้แก้ปัญหาการหาค่าเหมาะสำหรับปัญหาที่มีวัตถุประสงค์หลายอย่าง (Multi-Objective Optimization Problem: MOOP) [11] ซึ่งจะมีฟังก์ชันวัตถุประสงค์ เพื่อทำให้น้อยที่สุดหรือมากที่สุดจำนวนหนึ่ง

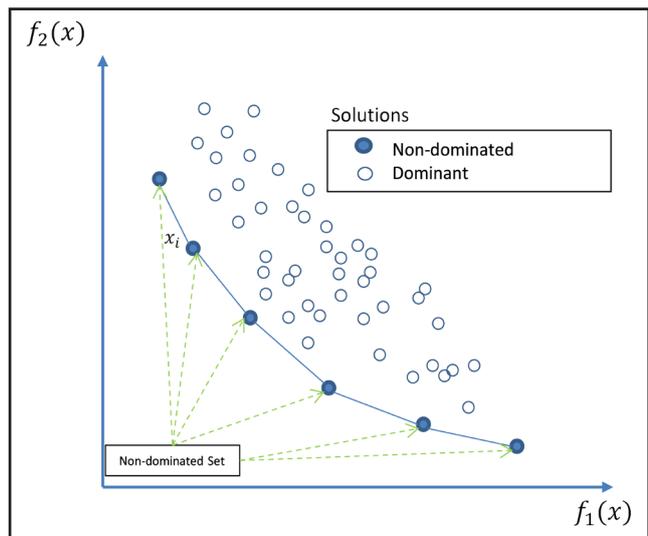
2.2.1 ขั้นตอนวิธีเชิงพันธุกรรมแบบหลายวัตถุประสงค์ (Multi-Objective Genetic Algorithm; MOGA) ทำให้ปัญหาการออกแบบที่มีหลายวัตถุประสงค์ ประกอบด้วย m วัตถุประสงค์ และตัวแปรตัดสินใจ เขียนอยู่ในรูปทั่วไปดังสมการที่ (2)

$$\text{Minimize(or Maximize): } \{f_1(x), f_2(x), \dots, f_m(x)\} \quad (2)$$

เมื่อ x คือ เวกเตอร์ของตัวแปรตัดสินใจ $f_i(x)$ คือ ฟังก์ชันวัตถุประสงค์ที่ i เมื่อ $i = 1, 2, \dots, m$ ดังนั้นรูปแบบปัญหาการหาค่าเหมาะสมที่สุดที่มีหลายวัตถุประสงค์จะเป็นการค้นหาเวกเตอร์คำตอบ x ภายใต้ m ซึ่งทำให้ได้คำตอบในพื้นที่คำตอบที่เป็นไปได้ หรือไม่มีคำตอบใดที่สามารถครอบงำชุดคำตอบ (Non-dominated Solution Set) นี้ได้ จะเรียกว่าคำตอบนี้เป็น กลุ่มคำตอบที่เหมาะสมที่สุด

(Pareto Optimal)

หลายปัญหาในโลกแห่งความจริงจะเป็นปัญหาแบบหลายวัตถุประสงค์ และแต่ละวัตถุประสงค์มักก็มีความขัดแย้งกัน อยู่ภายใต้เงื่อนไขเฉพาะที่ต้องการคำตอบ ซึ่งรูปแบบคำตอบที่ดีที่สุดของปัญหานั้น จะมีลักษณะพิเศษ คือ เป็นกลุ่มคำตอบที่ดีที่สุด โดยที่แต่ละคำตอบนั้นเป็นคำตอบที่ดีที่สุดของปัญหา และไม่มีคำตอบอื่นครอบงำ (Dominated Solution) เลย หรือที่เรียกว่า ใช้หลักการวิวัฒนาการบนพื้นฐานของพาเรโต (Pareto-based method) [12], [13] คือ ในแต่ละรอบการคำนวณ (Generation) ขณะที่ชุดประชากรใหม่ถูกสร้างขึ้น เซตคำตอบที่ไม่ถูกครอบงำจะถูกจัดกลุ่มระหว่างจำนวนสมาชิกของประชากรนั้นๆ หรือเรียกอีกอย่างหนึ่งว่า “คำตอบพาเรโตเฉพาะที่” (Local Pareto Solutions) หลังจากนั้นจะถูกนำไปดำเนินการในรอบการคำนวณครั้งต่อไปจนกระทั่งเข้าสู่หาคำตอบ (Convergence) กลุ่มคำตอบที่เหมาะสมที่สุด (Pareto Optimal Solution) ดังแสดงในภาพที่ 1



ภาพที่ 1 ตัวอย่างเซตของคำตอบที่ไม่ถูกครอบงำ

2.2.2 ขั้นตอนวิธีการหาค่าเหมาะสมที่สุดแบบกลุ่มอนุภาค (Multi-Objective Particle Swarm Optimization Algorithm: MOPSO) เป็นการเพิ่มประสิทธิภาพแบบหลายวัตถุประสงค์เป็นขั้นหนึ่งของปัญหาเกี่ยวกับการหาคำตอบที่สามารถประเมินได้ตามวัตถุประสงค์ที่มีคำตอบไม่ซ้ำกันหรือขัดแย้งกันสองรายการ ซึ่งคำตอบของปัญหาเหล่านี้จะแตกต่างกันเพื่อเพิ่มประสิทธิภาพมาตรฐานโดยที่ผลลัพธ์สุดท้ายไม่ได้เป็น “คำตอบที่ดีที่สุด” (Best Solution) โดยเป็นชุดของทางเลือกซึ่งสำหรับสมาชิกแต่ละชุดจะไม่มี



ทางออกอื่น เช่น การเพิ่มประสิทธิภาพของ PSO และเป็นสถานะปัจจุบันของศิลปะในหลายวัตถุประสงค์โดยมีขั้นตอนวิธีดังนี้

- 1) เริ่มต้นการจับกลุ่มและเก็บรวบรวม
- 2) วนนับอนุภาคในแต่ละวัตถุประสงค์ โดยที่
- 3) เลือกตัวที่นำจากการเก็บรวบรวม อัปเดต Velocity และอัปเดต Position
- 4) อัปเดตการเก็บรวบรวมคำตอบในรูปแบบ Non-Dominated และทำซ้ำ

2.2.3 ขั้นตอนวิธีวิวัฒนาการแบบหลายวัตถุประสงค์ (Multi-Objective Evolutionary Algorithm: MOEA) [5], [14] จะขึ้นอยู่กับจำนวนประชากรที่มีการทำซ้ำในชุดของคำตอบ และหลังจากแต่ละรุ่นจะให้ผลตอบแทนมากกว่าหนึ่งวิธี ซึ่ง MOEA เป็นที่นิยมมากในการแก้ปัญหาการเพิ่มประสิทธิภาพของคำตอบในหลายวัตถุประสงค์เนื่องจากสาเหตุดังต่อไปนี้

- 1) ใช้งานง่าย
- 2) ให้ผลคำตอบมากกว่าหนึ่งวิธี
- 3) มีโอกาสน้อยที่อัลกอริทึมจะติดขัด
- 4) มีความยืดหยุ่นและมีประสิทธิภาพ
- 5) ไม่จำเป็นต้องมีความรู้เรื่องปัญหาใดๆ มาก่อน

ใน MOEA หลายๆ ครั้งการแก้ปัญหาที่ดีจะสูญหายไปเมื่อมีการครอสโอเวอร์ (Crossover) หรือการกลายพันธุ์ที่มีโอกาสไม่พบคำตอบ การแก้ปัญหาเพื่อเพิ่มประสิทธิภาพหลายวัตถุประสงค์ด้วยเทคนิคตามวิวัฒนาการ มีข้อจำกัดคือไม่ทราบถึงความต้องการก่อนหน้าหรือที่ตั้งเป้าหมายไว้ ซึ่งอาจไม่สามารถใช้งานได้ตลอดเวลา เทคนิคการวิวัฒนาการนี้ขึ้นอยู่กับขั้นตอนวิธีทางพันธุกรรมข้อได้เปรียบหลักของ MOEA ก็คือไม่จำเป็นต้องมีความรู้เรื่องปัญหา ก่อน ซึ่งสามารถเขียนเป็นสมการ (3) ได้ดังนี้

$$Y = \sum_{i=1}^n w_i f_i(x) \quad (3)$$

โดย Y คือ เซตของคำตอบ

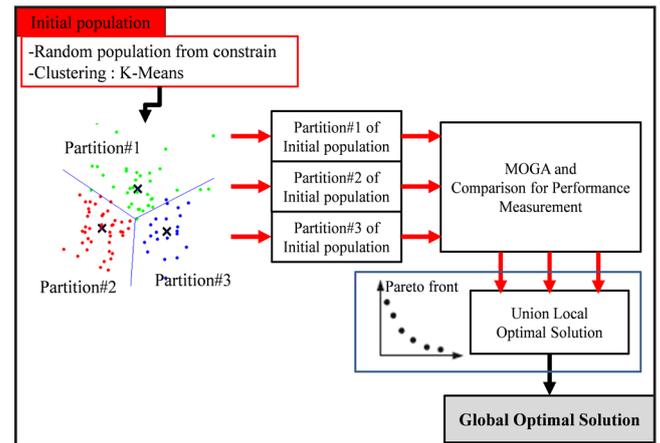
w_i คือ ตัวเลข fractional ($0 \leq w_i \leq 1$)

i คือ จำนวนวัตถุประสงค์

$f_i(x)$ คือ ฟังก์ชันวัตถุประสงค์

2.2.4 ขั้นตอนวิธีเชิงพันธุกรรมแบบหลายวัตถุประสงค์ด้วยการแบ่งกลุ่มประชากรเริ่มต้น (PIMOGA) กระบวนการในการปรับปรุงขั้นตอนวิธีเชิงพันธุกรรมแบบหลายวัตถุประสงค์โดยใช้มีการแบ่งประชากรก่อนเริ่ม ใช้ข้อมูลโดยการสุ่ม

ประชากรเริ่มต้นเดียวกัน และการแบ่งกลุ่มประชากรด้วยวิธี K-Means Clustering เป็นการแบ่งกลุ่มในประชากรเริ่มต้น หากแบ่งกลุ่มมากกว่านี้จะทำให้การประมวลผลทำงานได้ช้าลง ดังนั้นการเพิ่มประสิทธิภาพในส่วนของการค้นหาคำตอบที่ดีที่สุด จึงเรียกวิธีนี้ว่า การแบ่งประชากรก่อนเริ่มในขั้นตอนวิธีเชิงพันธุกรรมแบบหลายวัตถุประสงค์ (Partition of Initial Population for Multi-Objective Genetic Algorithm: PIMOGA) โดยมีกระบวนการดังแสดงไว้ในภาพที่ 2



ภาพที่ 2 วิธีกร PIMOGA

2.3 รูปแบบความเหมาะสมของการระบายน้ำ

ศึกษาวิธีการพยากรณ์เพื่อหาเทคนิคการพยากรณ์ที่เหมาะสมสำหรับกรณีศึกษาการระบายน้ำ (Forecasting) [15] หมายถึงการประมาณค่าหรือคาดคะเนเหตุการณ์ที่ยังไม่ได้เกิดขึ้น โดยการคาดคะเนนั้นต้องอาศัยข้อมูลจากปัจจุบันหรืออดีตมาเป็นแนวทางแล้ววิเคราะห์เพื่อคาดการณ์การระบายน้ำในอนาคต ในงานวิจัยนี้ได้ศึกษาและทดลองการหารูปแบบความเหมาะสมจากค่าพยากรณ์ด้วยวิธีปรับเรียบเอกซ์โพเนนเชียลของวินเทอร์ (Holt-Winters' Exponential Smoothing) เป็นวิธีที่ได้รับความนิยมและมีประสิทธิภาพในการคาดการณ์ช่วงเวลาตามฤดูกาล แต่การใช้งานที่แตกต่างกันจะทำให้การคาดการณ์ที่แตกต่างกันขึ้นอยู่กับวิธีที่จะเริ่มต้นและวิธีการเลือกพารามิเตอร์การปรับให้เรียบ โดยใช้ค่าปรับให้เรียบ 3 ค่า ได้แก่ α β และ γ ที่มีค่าอยู่ระหว่าง 0 ถึง 1 โดยที่ α เป็นค่าปรับน้ำหนักสำหรับแนวโน้ม β เป็นค่าปรับน้ำหนักสำหรับค่าความลาดชัน (Slope) และ γ เป็นค่าปรับน้ำหนักสำหรับฤดูกาล ตามลำดับ โดยมีสมการดังนี้

$$\hat{Y}_t(p) = (\hat{T}_t(t) + p\hat{L}_t(t))\hat{S}_i(t) \quad (4)$$

โดยที่ $\hat{Y}_t(p)$ คือ ค่าคาดการณ์การระบายปริมาณน้ำ ณ เวลา t โดยที่ $p = 1, 2, \dots$

p คือ ช่วงเวลาที่เปลี่ยนแปลงไป

$\hat{T}_t(t)$ คือ ค่าแนวโน้มการระบายน้ำ ณ เวลา t

$\hat{L}_t(t)$ คือ อัตราส่วนของปริมาณน้ำ ณ เวลา t

$\hat{S}_i(t)$ คือ ค่าวัดอิทธิพลของฤดูกาลที่ i ซึ่งค่า $\hat{T}_t(t), p\hat{L}_t(t)$ และ $\hat{S}_i(t)$ ได้จากสมการเหล่านี้

$$\hat{T}_t(t) = \frac{\alpha Y_t}{\hat{S}_i(t-t-1)} + (1 - \alpha)\hat{T}_t(t-1) \quad (5)$$

$$\hat{L}_t(t) = \beta(\hat{T}_t(t) - \hat{T}_t(t-1)) + (1 - \beta)\hat{L}_t \quad (6)$$

$$\hat{S}_i(t) = \frac{\gamma Y_t}{\hat{T}_t(t)} + (1 - \gamma)\hat{S}_i(t-m) \quad (7)$$

α β และ γ คือ ค่าพารามิเตอร์ที่สามารถปรับเปลี่ยนตามความเหมาะสม (Turning Parameter) โดยมีค่ามากกว่า 0 ถึง 1 หมายถึง $0 < \alpha \leq 1, 0 < \beta \leq 1$ และ $0 < \gamma \leq 1$

เมื่อ m คือค่าที่กำหนดเริ่มต้น การสร้างสมการพยากรณ์ต้องทำการกำหนดค่าเริ่มต้นของ ค่า $\hat{T}_t(t), p\hat{L}_t(t)$ และ $\hat{S}_i(t)$ โดยมีสมการดังนี้

$$\begin{aligned} \hat{S}_1 &= \frac{Y_1}{Average(Y_1, Y_2, \dots, Y_m)} \\ \hat{S}_2 &= \frac{Y_2}{Average(Y_1, Y_2, \dots, Y_m)} \dots \\ \hat{S}_k &= \frac{Y_M}{Average(Y_1, Y_2, \dots, Y_m)} \end{aligned} \quad (8)$$

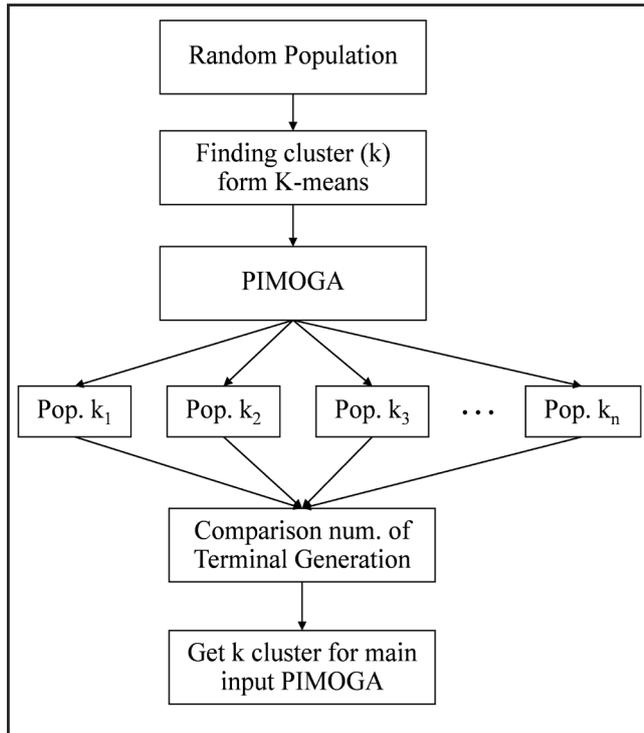
$$\hat{L}_{k+1} = \frac{Y_{m+1}}{S_1} \quad (9)$$

$$\hat{T}_{k+1} = \frac{Y_{m+1}}{S_1} - \frac{Y_m}{S_m} \quad (10)$$

3. ขั้นตอนการทดลองการเปรียบเทียบรูปแบบความเหมาะสม

3.1 ขั้นตอนการจัดกลุ่มหาค่า k ใน PIMOGA

ในขั้นตอนนี้เป็นการทดลองการจัดกลุ่มแบบ K-means [16] เนื่องจากในขั้นตอนวิธี PIMOGA ที่ผู้วิจัยได้นำเสนอต้องอาศัยการจัดกลุ่ม (k) ในลักษณะไม่มีผู้สอน (Unsupervised) เพื่อเป็นการจัดกลุ่มประชากรเริ่มต้นก่อนเข้าสู่กระบวนการ PIMOGA โดยเปรียบเทียบทุกกลุ่มประชากรจากค่าเฉลี่ยของการเกิดจำนวนของรุ่นครั้งสุดท้าย (Terminated Generation) แสดงกระบวนการดังภาพที่ 3



ภาพที่ 3 การเปรียบเทียบการจัดกลุ่มค่า k ใน PIMOGA

3.2 ขั้นตอนการวิเคราะห์หลายวัตถุประสงค์ของรูปแบบความเหมาะสมในการระบายน้ำของ PIMOGA (Multi-Objective of PIMOGA)

รูปแบบความเหมาะสมในการระบายน้ำนี้ได้มาจากค่าการพยากรณ์แบบอนุกรมเวลา (Time Series Forecasting) โดยใช้ข้อมูลการระบายน้ำที่ ปตร. เขื่อนพระรามหก จากโครงการส่งน้ำและบำรุงรักษาป่าสักใต้ สำนักงานชลประทานที่ 10 กรมชลประทาน จ.พระนครศรีอยุธยา และได้เปรียบเทียบการพยากรณ์ไว้ 4 เทคนิค ได้แก่

3.2.1 วิธีการพยากรณ์โดยการวิเคราะห์การถดถอย

เชิงเส้นอย่างง่าย (Simple Linear Regression: SLR) มีรูปสมการดังนี้

$$Y = a + bX \quad (11)$$

โดยที่ Y คือ ค่าคาดการณ์การระบายปริมาณน้ำ

X คือ ปริมาณน้ำในช่วงเวลาระบายน้ำ

a คือ ค่าคงที่ (Constant)

b คือ ความชัน (Slope)

3.2.2 วิธีถัวเฉลี่ยเคลื่อนที่ (Moving Average: MA)

รูปสมการดังนี้



$$\hat{Y}_t = \frac{(Y_t + Y_{t-1} + \dots + Y_{t-k+1})}{k} \quad (12)$$

โดย Y_t คือ ปริมาณน้ำ ณ เวลา t

k คือ จำนวนข้อมูลที่ใช้ในการหาค่าเฉลี่ย

\hat{Y}_t คือ ค่าคาดการณ์การระบายปริมาณน้ำ ณ เวลา $t+1$

3.2.3 วิธีปรับเรียบเอ็กซ์โพเนนเชียลแบบง่าย (Simple Exponential Smoothing: SES) รูปสมการดังนี้

$$\hat{Y}_t = \alpha Y_t + (1 - \alpha) \hat{Y}_{t-1} \quad (13)$$

โดยที่ Y_t คือ ปริมาณน้ำ ณ เวลา t

\hat{Y}_t คือ ค่าคาดการณ์การระบายปริมาณน้ำ ณ

เวลา $t+1$

\hat{Y}_{t-1} คือ ค่าพยากรณ์ที่ ณ เวลา $t-1$

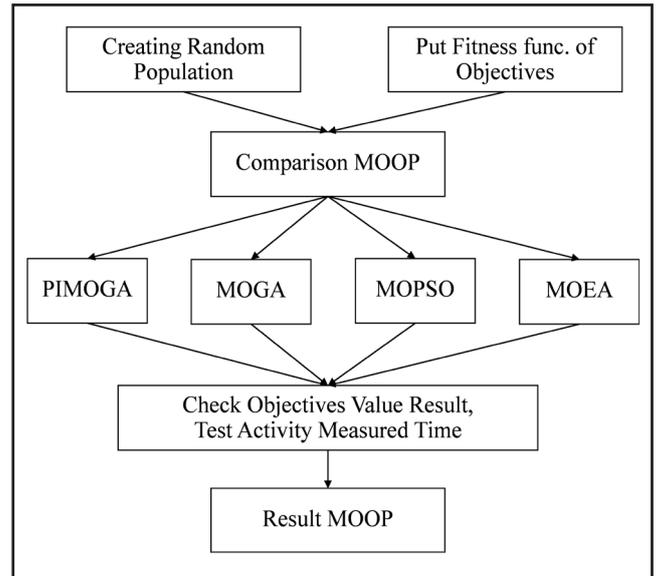
α คือ ค่าสัมประสิทธิ์ปรับให้เรียบ α มีค่าอยู่ระหว่าง 0 ถึง 1

3.2.4 วิธีปรับเรียบเอ็กซ์โพเนนเชียลของวินเทอร์ (Holt-Winters' Exponential Smoothing) จะอ้างถึงในสมการที่ (4) ถึง (10) ซึ่งในงานวิจัยนี้จำเป็นต้องกำหนดค่าพารามิเตอร์เริ่มต้นโดยอ้างถึงสมการที่ 8 เป็นการระบุค่าอิทธิพลของฤดูกาลดังตัวแปรที่ S_1, S_2 และ S_3 เพื่อให้สามารถประมาณค่าปริมาณน้ำในการระบายด้วยวิธีการ PIMOGA ได้อย่างสมบูรณ์

3.3 ขั้นตอนการเปรียบเทียบ PIMOGA และขั้นตอนวิธีการหาความเหมาะสมแบบหลายวัตถุประสงค์

ขั้นตอนนี้เป็นการเปรียบเทียบให้เห็นถึงความสามารถหาความเหมาะสมจากรูปแบบความเหมาะสมในการระบายน้ำแบบหลายวัตถุประสงค์ของ PIMOGA ซึ่งแสดงดังภาพที่ 4

จากภาพที่ 4 ทำการเปรียบเทียบกับขั้นตอนวิธีการหาความเหมาะสม (Multi-Objective Optimization Problems: MOOP) แบบต่างๆ ได้แก่ 3 ขั้นตอนวิธีคือ ขั้นตอนวิธีเชิงพันธุกรรมแบบหลายวัตถุประสงค์ (MOGA) ขั้นตอนวิธีการหาค่าเหมาะสมที่สุดแบบกลุ่มอนุภาค (MOPSO) ในขั้นตอนการเปรียบเทียบแสดงให้เห็นถึงค่าความเหมาะสมในแต่ละวัตถุประสงค์ประกอบไปด้วยค่ามากที่สุด (Max) ค่าต่ำที่สุด (Min) ค่าช่วง (Range) ค่าเฉลี่ยเบี่ยงเบนมาตรฐาน (SD) และค่าเฉลี่ย (Average)



ภาพที่ 4 การเปรียบเทียบ MOOP ในวิธีการ PIMOGA

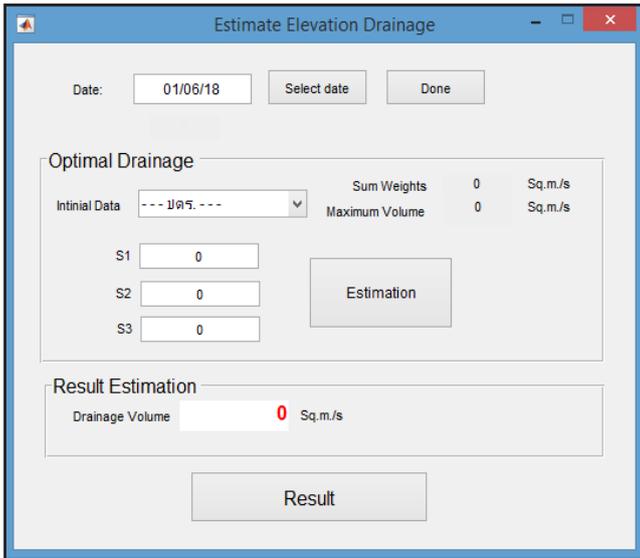
3.4 การประยุกต์ใช้งานประมาณค่าปริมาณน้ำในการระบายด้วยวิธีการ PIMOGA

ในงานวิจัยนี้ได้พัฒนาแอปพลิเคชันเพื่อสนับสนุนการประมวลผลของการประมาณค่าปริมาณน้ำในการระบายโดยใช้โปรแกรม MatLAB เวอร์ชัน 2016b ซึ่งจะแสดงให้เห็นถึงการประมาณค่าปริมาณน้ำที่ระบายในแต่ละ ปรต. ที่อยู่ในโครงข่ายการระบายน้ำเดียวกัน [17] โดยมีจำนวนทั้งหมด 6 ปรต. ได้แก่ เขื่อนพระรามหก ปรต.พระนารายณ์ ปรต. พระมหินทร์ ปรต.พระเอกาทศรถ ปรต.พระศรีศิลป์ และปรต.พระศรีเสาวภาค ในแอปพลิเคชันมีการทำงานอยู่ 3 ส่วนคือ 1) ส่วนการระบุวันที่ (Date) 2) ส่วนส่วนการเลือก ปรต. ที่จะประมาณการระบายน้ำและระบุค่าอิทธิพลของฤดูกาล (Optimal Drainage) และ 3) ส่วนแสดงผลการประมาณค่าปริมาณน้ำในการระบาย (Result Estimation) ซึ่งการใช้งานจะต้องระบุค่าเริ่มต้นในการประมวลผลไว้ 2 ส่วนคือ ส่วนการระบุวันที่ และส่วนการเลือก ปรต. ที่จะประมาณการระบายน้ำและระบุค่าอิทธิพลของฤดูกาล ($\hat{S}_i(t)$) ในตัวแปรที่ S_1, S_2 และ S_3 มีหน่วยเป็น m³/s แสดงดังภาพที่ 5

4. ผลการทดลอง

4.1 ผลการทดลองการจัดกลุ่มหาค่า k ใน PIMOGA

แสดงผลลัพธ์การหาค่าตอบใน Terminal Generation ของวิธีการ PIMOGA ในการแทนค่า k ตั้งแต่ 1 ถึง 10 ดังตารางที่ 1 พบว่าการจัดกลุ่มข้อมูลประชากรเริ่มต้นเพื่อหาค่า k ใน



ภาพที่ 5 แอปพลิเคชันสนับสนุนการประมาณค่าปริมาณน้ำในการระบาย

PIMOGA นั้น ได้ทดลองหาความเหมาะสมเป็นจำนวน 10 ครั้งปรากฏว่าการจัดกลุ่มประชากรเริ่มต้นที่ $k = 3$ มีค่าเฉลี่ยการเกิดจำนวนของรุ่นครั้งสุดท้าย (Average of Terminated Generation) เป็นจำนวนน้อยที่สุดคือ 111.50 รองลงมาเป็น $k = 4$ คือ 127.10 ซึ่งแสดงให้เห็นว่าหากมีการจัดกลุ่มประชากรเริ่มต้นมากเท่าใดก็จะทำให้เกิดจำนวนของรุ่นครั้งสุดท้ายมากตามไปด้วย สาเหตุเพราะในกระบวนการของ PIMOGA นั้นต้องการสุ่มประชากรที่ทำให้ข้อมูลประชากรเริ่มต้นนั้นเปลี่ยนนระยะการลู่เข้าเพื่อได้คำตอบตามวัตถุประสงค์

ผลการทดลองหาค่า k ในการจัดกลุ่มประชากรเริ่มต้นของกระบวนการของ PIMOGA แสดงดังตารางที่ 1

4.2 ผลการทดลอง PIMOGA รูปแบบความเหมาะสมในการระบายน้ำหลายวัตถุประสงค์

จากการทดลองพบว่ารูปแบบความเหมาะสมในการระบายน้ำด้วยวิธีปรับเรียบเอกซ์โพเนนเชียลของวินเทอร์ได้ค่าการพยากรณ์ที่ MAPE ต่ำที่สุดคือ ซึ่งมากกว่า 0.068 โดยการปรับค่าพารามิเตอร์ที่ $\alpha = 0.882$, $\beta = 0.051$ และ $\gamma = 0.312$ เป็นค่าคงที่ ดังนั้นรูปแบบความเหมาะสมในการระบายน้ำหรือเป็นฟังก์ชันความเหมาะสมของ PIMOGA (Fitness Function of PIMOGA) ได้อ้างอิงสมการที่ (5) ถึง (10) ซึ่งสามารถเขียนออกมาเป็นรูปแบบสมการเชิงเส้น (Linear Equations) วัตถุประสงค์ (f_n) ทั้งหมด 7 วัตถุประสงค์ และ

ตารางที่ 1 ผลการทดลองหาค่า k ใน PIMOGA

Terminal Gen.	Number of K-Means							
	k=3	k=4	k=5	k=6	k=7	k=8	k=9	k=10
1	115	125	170	120	127	326	158	188
2	130	152	104	102	110	114	102	157
3	104	161	121	303	126	122	231	102
4	112	159	352	102	122	106	102	318
5	103	103	102	124	177	102	102	102
6	110	104	122	103	307	244	140	119
7	104	102	177	187	102	123	102	231
8	102	124	159	141	164	102	244	102
9	121	107	124	208	140	161	207	131
10	114	134	122	121	102	159	142	105
Average	111.5	127.1	155.3	151.1	147.7	155.9	153.0	155.5

มีตัวแปรในสมการจำนวนตัวแปรอิสระ (x_n) และมีจำนวน 5 ตัวแปร ($n = 5$) แสดงดังสมการที่ (14) ถึง (20) ดังต่อไปนี้ กำหนดให้ S_i เป็นเริ่มต้นดังนี้

$$S_1 = \frac{x_1}{x_1 + x_2 + x_3}$$

$$S_2 = \frac{x_1}{x_1 + x_2 + x_3}$$

$$S_3 = \frac{x_1}{x_1 + x_2 + x_3}$$

$$f_1 = \alpha \frac{x_3}{S_1} \tag{14}$$

$$f_2 = \frac{x_3}{S_1} - \frac{x_2}{S_2} \tag{15}$$

$$f_3 = \gamma \frac{x_3}{f_1} + ((1 - \gamma)S_1) \tag{16}$$

$$f_4 = \alpha \frac{x_4}{S_2} + ((1 - \alpha)(f_1 + f_2)) \tag{17}$$

$$f_5 = \beta(y_4 - f_1) + (1 - \beta)f_3 \tag{18}$$

$$f_6 = \gamma \left(\frac{x_4}{f_1 - f_2} \right) + ((1 - \gamma)S_2) \tag{19}$$

$$f_7 = (f_4 + x_5 f_5) S_2 \tag{20}$$

4.3 ผลการทดลองการเปรียบเทียบ PIMOGA และขั้นตอนวิธีการหาความเหมาะสมแบบหลายวัตถุประสงค์

การกำหนดค่าพารามิเตอร์ในการทดลอง PIMOGA ไว้ในตารางที่ 2 และการทดลอง PIMOGA การกำหนดค่าพารามิเตอร์ให้กับขั้นตอนวิธีการหาความเหมาะสมของ 4 วิธีคือ PIMOGA, MOGA, MOPSO และ MOEA ซึ่งทำให้ได้ผลลัพธ์ในการทดลองแสดงดังตารางที่ 3 ถึง 6



ตารางที่ 2 พารามิเตอร์ที่ใช้ในการทดลอง

Parameter	Value
Population size	100
Maximum Number of Generation	200
Crossover probability	0.5
Mutation probability	0.1

ตารางที่ 3 ผลการทดลองของ PIMOGA

Test Activity Measured Time		0.0018	Last Gen.	113	Average
Objective	Min	Max	Range	SD	
f_1	-5.1715	146.7261	151.8975	66.3851	54.6296
f_2	-13.5319	96.8218	110.3537	46.5057	28.2513
f_3	-10.4445	111.7133	122.1579	43.5482	21.9325
f_4	-2.6710	162.4484	165.1194	62.6664	54.3113
f_5	-11.5161	75.0176	86.5337	29.1629	12.8125
f_6	-1.3034	67.0082	68.3117	27.4247	25.1752
f_7	-13.0068	24.5037	37.5105	11.0999	2.4182
Average	-8.2350	97.7484	105.9835	40.9704	28.5044

ตารางที่ 4 ผลการทดลองของ MOGA

Test Activity Measured Time		0.0031	Last Gen.	182	Average
Objective	Min	Max	Range	SD	
f_1	-4.1E+00	1.27E+06	1.27E+06	4.8E+05	1.8E+05
f_2	-6.2996	172.8025	179.1021	78.0892	65.2035
f_3	-2.2040	230.8515	233.0554	94.8390	58.2442
f_4	-6.1E+06	1.23E+02	6.1E+06	2.3E+06	-8.8E+5
f_5	-15.0476	36.0957	51.1433	15.5235	3.5518
f_6	-9.6E+06	1.23E+02	9.6E+06	3.6E+06	-1.3E+6
f_7	-1.0467	122.0337	123.0804	47.3610	44.9998
Average	-8.2350	97.7484	105.9835	40.9704	28.5044

ตารางที่ 5 ผลการทดลองของ MOPSO

Test Activity Measured Time		0.0027	Last Gen.	122	Average
Objective	Min	Max	Range	SD	
f_1	8.9049	370.44	361.5351	97.3358	103.47
f_2	-27.1614	378.00	405.1614	111.989	84.95
f_3	0.0496	0.5592	0.5096	0.1718	0.2612
f_4	7.1980	179.419	172.2210	47.0702	61.5251
f_5	-14.1523	3.9576	18.1099	4.0353	-1.8916
f_6	-1.3314	0.6582	1.9896	0.4711	0.0470
f_7	41.5571	1557.35	1515.8	341.69	356.49
Average	2.1521	355.7706	353.61	86.1099	86.4087

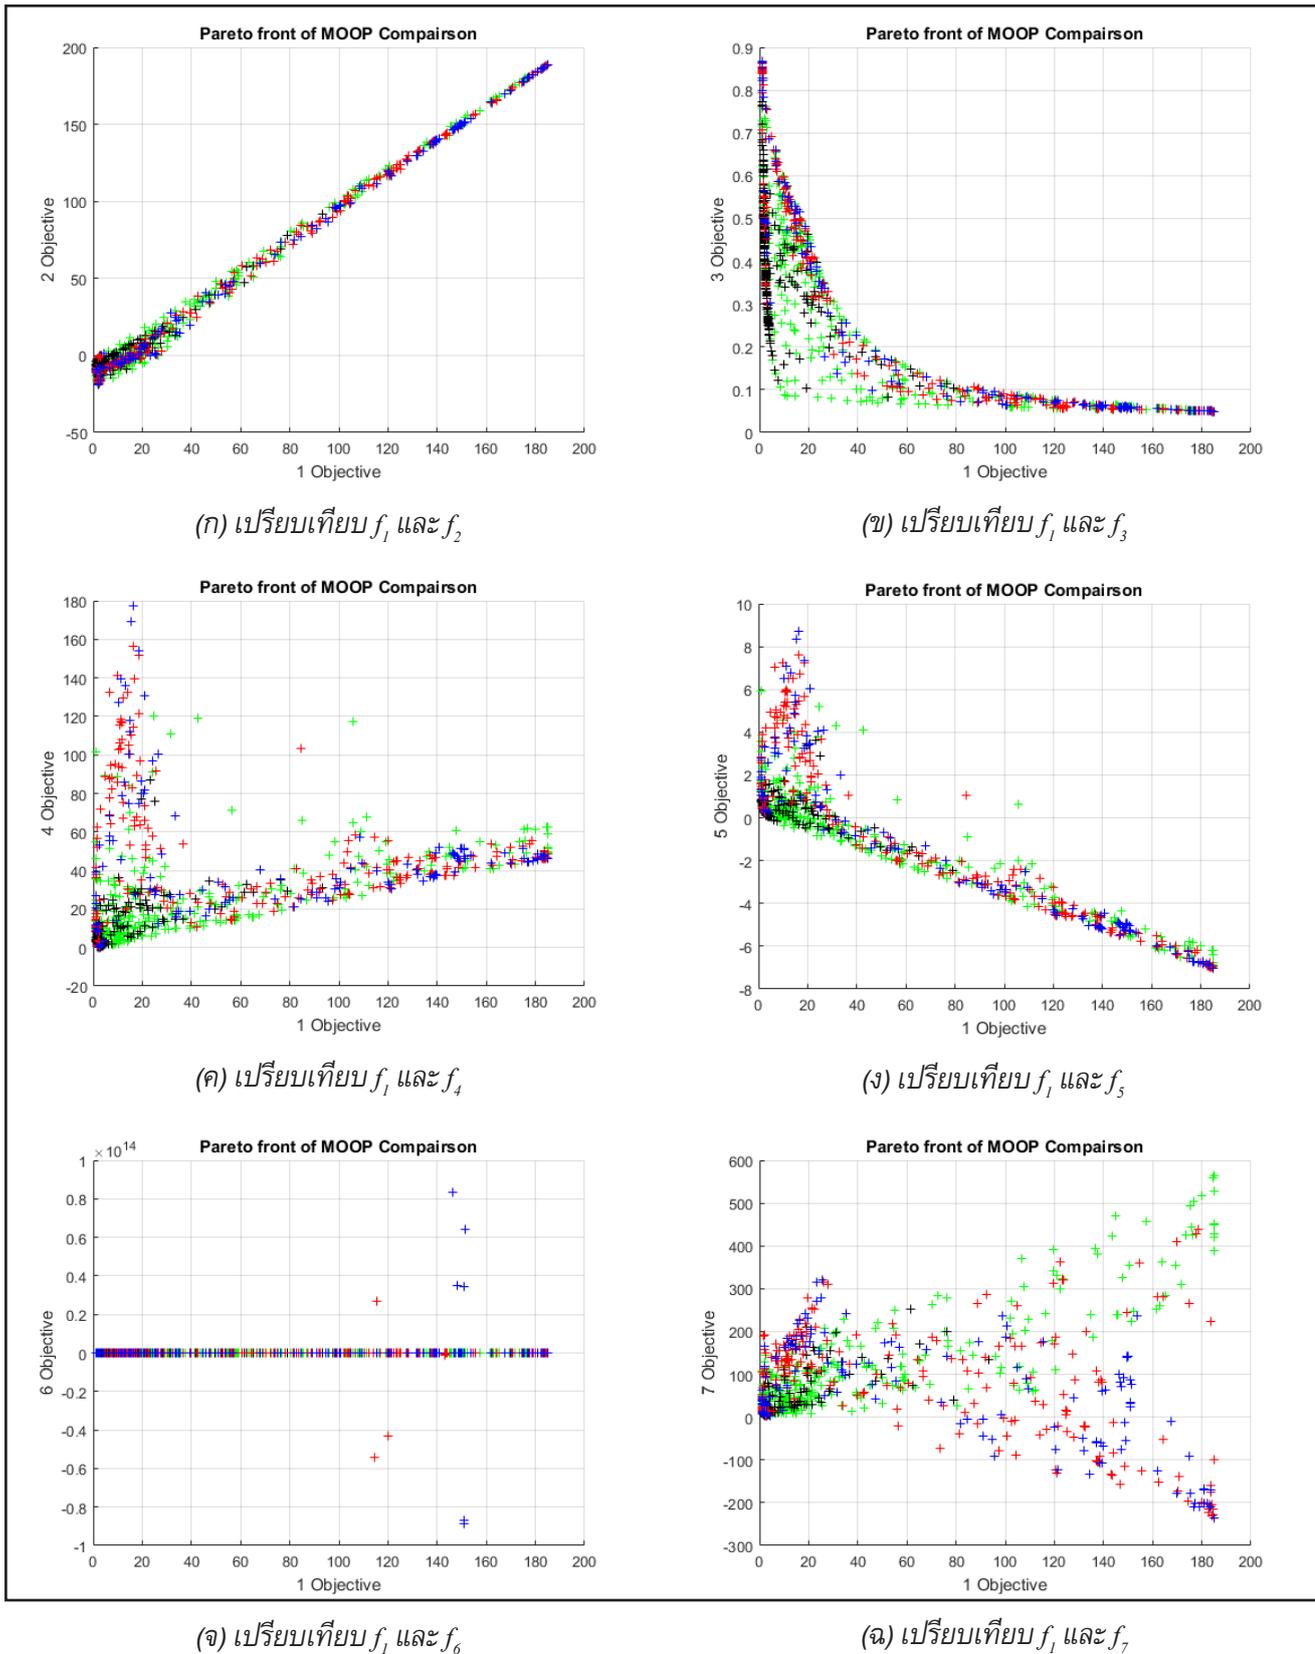
ตารางที่ 6 ผลการทดลองของ MOEA

Test Activity Measured Time		0.0045	Last Gen.	122	Average
Objective	Min	Max	Range	SD	
f_1	1.4661	5.2412	3.7750	0.7148	2.2245
f_2	-18.9000	-7.2107	11.6893	3.0004	-16.3698
f_3	0.1753	0.6267	0.4514	0.0943	0.4414
f_4	-0.1594	1.0152	1.1746	0.2877	0.0637
f_5	-0.0533	0.5717	0.6250	0.1172	0.3087
f_6	0.2517	0.5450	0.2933	0.0602	0.3766
f_7	2.0873	8.9229	6.8356	1.7789	3.4396
Average	-2.1618	1.3874	3.5492	0.8648	-1.3593

จากตารางที่ 3 ถึง 6 พบว่าการเกิดจำนวนของรุ่น
ครั้งสุดท้าย (Terminated Generation) ที่ใช้การเกิดน้อยที่สุด
คือ MOEA เท่ากับ 108 ซึ่งเป็นไปตามคุณสมบัติของ MOEA
เนื่องจากเป็นกระบวนการเชิงวิวัฒนาการเป็นอัลกอริทึมที่
ซับซ้อนและถูกพัฒนามาจาก GA จึงทำให้ได้ช่วงของคำตอบ
ที่ไม่กระจายตัวเห็นได้จากค่า Range, SD และ Average
ที่เท่ากับ 3.5492, 0.8648 และ -1.3593 ตามลำดับ ซึ่งมี
ค่าต่ำกว่าขั้นตอนวิธีแบบอื่นๆ

ส่วนผลการทดลอง PIMOGA เมื่อเปรียบเทียบกับขั้นตอน
วิธีการหาความเหมาะสมแบบ MOGA, MOPSO และ MOEA
พบว่า PIMOGA มีค่าการวัดค่าเวลาการทดลองในการทดสอบ
(Test Activity Measured Time) ที่ต่ำที่น้อยคือ 0.0018 ซึ่ง
แสดงผลลัพธ์การเปรียบเทียบในลักษณะของ Pareto Front
ดังภาพที่ 6 เปรียบเทียบ f_1 ถึง f_7 ในการทดลองยังพบว่า
PIMOGA สามารถเพิ่มประสิทธิภาพในการค้นหาคำตอบที่
มีการเกิดรุ่นครั้งสุดท้ายมีจำนวนน้อยกว่า MOGA และ
MOPSO สังเกตได้จากภาพที่ 6 (ข) ซึ่งเป็นการเปรียบเทียบ
 f_1 ในช่วงระหว่าง [15, 45] และ f_3 ในช่วงระหว่าง [0.7, 0.35]
พบว่าหาความเหมาะสมของ PIMOGA มีการหาคำตอบ
สู่เข้าหรือได้คำตอบสม่ำเสมอกว่า MOGA และ MOPSO ซึ่ง
บ่งชี้ให้เห็นถึงการเพิ่มประสิทธิภาพในการค้นหาแบบ
Global Optimal Solution ได้ดีกว่า MOGA และ MOPSO
ยกเว้นขั้นตอนวิธีแบบ MOEA ซึ่งมีการค้นหาคำตอบที่
สม่ำเสมอและใช้เวลาที่น้อยที่สุด

นอกจากนี้ในส่วนผลการทดลอง PIMOGA รูปแบบ
ความเหมาะสมในการระบายน้ำหลายวัตถุประสงค์พบว่า
การพยากรณ์ด้วยวิธีปรับเรียบเอ็กซ์โพเนนเชียลของวินเทอร์
ในการกำหนดค่า $k = 3$ และได้ทำการปรับค่าพารามิเตอร์ที่



ภาพที่ 5 การเปรียบเทียบ PIMOGA และขั้นตอนวิธีการหาความเหมาะสมแบบหลายวัตถุประสงค์

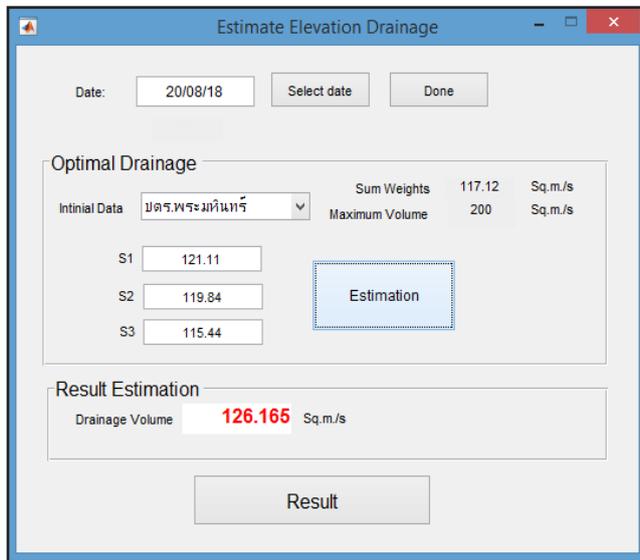


$\alpha = 0.882$, $\beta = 0.051$ และ $\gamma = 0.312$ มีค่าความคลาดเคลื่อนต่ำที่สุด ซึ่งได้ค่า $MAD = 1.347$, $MAPE = 0.068$ และ $RMSE = 1.844$ จากนั้นจึงนำมาแสดงผลความสัมพันธ์ระหว่างค่าการระบายน้ำจริงกับค่าพยากรณ์โดยวิธีปรับเรียบเอ็กซ์โพเนนเชียลของวินเทอร์

4.4 ผลการประยุกต์ใช้งานการประมาณค่าปริมาณน้ำในการระบายด้วยวิธีการ PIMOGA

จากแอปพลิเคชันที่สนับสนุนการประมวลผลของการประมาณค่าปริมาณน้ำในการระบาย ผู้วิจัยได้ทำการทดลองโดยการระบุค่าเริ่มต้น แสดงดังภาพที่ 7 เป็นการใช้งานแอปพลิเคชันในการประมาณค่าปริมาณน้ำของปตร. พระมหินทร์ โดยระบุค่าเริ่มต้นก่อนการประมวลผล การประมาณค่าปริมาณน้ำในการระบายใน 2 ส่วนคือ ส่วนการระบุวันที่ ในรูปแบบ วัน/เดือน/ปี (dd/mm/yy) เป็น 20/08/18 (วันที่ 20 สิงหาคม 2018) โดยเลือก ปตร.พระมหินทร์ และระบุค่าอิทธิพลของฤดูกาลในตัวแปรที่ $S_1 = 121.11$, $S_2 = 119.84$ และ $S_3 = 115.44$ (m³/s) พบว่าได้ผลลัพธ์การประมาณค่าปริมาณน้ำในการระบายเท่ากับ 126.165 m³/s นอกจากนี้ผู้วิจัยยังได้ทำการทดลองหาค่าประมาณปริมาณน้ำที่ ปตร. อื่น ซึ่งแสดงผลดังตารางที่ 7

จากตารางที่ 7 เป็นการระบุค่าเริ่มต้นในแอปพลิเคชันที่



ภาพที่ 7 ผลการประมาณค่าปริมาณน้ำในแอปพลิเคชัน

สนับสนุนการประมาณค่าปริมาณน้ำด้วยวิธีการ PIMOGA ซึ่งแสดงให้เห็นถึงผลลัพธ์ในการประมาณค่าปริมาณน้ำในการระบาย ซึ่งจากการทดลองที่ 4.2 และ 4.3 เป็นการนำเทคนิคการพยากรณ์ด้วยวิธีปรับเรียบเอ็กซ์โพเนนเชียลของ

ตารางที่ 7 ผลการประมาณค่าปริมาณน้ำในการระบาย

ชื่อ ปตร.	วันที่	S_1 (m ³ /s)	S_2 (m ³ /s)	S_3 (m ³ /s)	ประมาณค่าปริมาณน้ำในการระบาย (m ³ /s)
เขื่อนพระรามหก	06/06/18	120.23	110.24	101.54	125.249
พระนารายณ์	01/11/15	80.112	90.5	92.33	83.456
พระมหินทร์	20/08/18	121.11	119.84	115.44	126.165
พระเอกาทศรถ	12/10/14	100.56	123.23	133.33	104.758
พระศรีศัลป์	12/10/17	65	73.21	62.32	67.713
พระศรีเสาวภาค	31/12/16	35.25	48.52	22.12	36.721

วินเทอร์มาเป็นฟังก์ชันความเหมาะสมของ PIMOGA (Fitness Function) พบว่าสามารถหาความเหมาะสมในการระบายน้ำกับการนำไปใช้งานได้ ในสถานการณ์จริง

5. สรุปและอภิปรายงานวิจัย

บทความวิจัยนี้ ได้มุ่งเน้นการปรับแต่งกระบวนการพื้นฐานของ MOGA โดยเพิ่มประสิทธิภาพด้วยการแบ่งกลุ่มประชากรเริ่มต้น หรือเรียกว่าวิธีการ PIMOGA โดยการทดลองเปรียบเทียบขั้นตอนวิธีการหาความเหมาะสมแบบหลายวัตถุประสงค์ ได้แก่ MOGA, MOPSO และ MOEA ซึ่งใช้สมการเชิงเส้นของฟังก์ชันความเหมาะสมในการระบายน้ำจากผลลัพธ์ของการพยากรณ์ด้วยวิธีปรับเรียบเอ็กซ์โพเนนเชียลของวินเทอร์ โดยมีวัตถุประสงค์ทั้งหมด 7 วัตถุประสงค์ และมีตัวแปรในสมการจำนวนตัวแปรอิสระ 5 ตัวแปร ซึ่งเป็นการบ่งชี้ให้เห็นว่ากระบวนการ PIMOGA ที่ผู้วิจัยได้นำเสนอเพื่อหาความเหมาะสมในการระบายน้ำนั้นมีประสิทธิภาพที่ดีกว่า MOGA และ MOPSO แต่อย่างไรก็ตาม PIMOGA ต้องอาศัยการจัดกลุ่มประชากรเริ่มก่อนเข้ากระบวนการและใช้การประมวลผลแบบขนาน หากการจัดกลุ่มประชากรที่มากเกินไปก็จะทำให้เกิดความล่าช้าในการประมวลผลได้เช่นเดียวกัน

จากการทดลองในการนำเทคนิคการพยากรณ์ด้วยวิธีปรับเรียบเอ็กซ์โพเนนเชียลของวินเทอร์มาเป็น Fitness Function และการเลือกจัดกลุ่มประชากรเริ่มต้นที่ $k = 3$ ซึ่งเป็นพารามิเตอร์หลักให้กับการประมาณค่าปริมาณน้ำในการระบายด้วยวิธี PIMOGA พบว่าสามารถนำไปพัฒนาแอปพลิเคชันสนับสนุนงานวิจัยนี้โดยได้ผลลัพธ์เป็นการประมาณค่าปริมาณน้ำในการระบายน้ำในโครงข่ายฯ ได้



อย่างมีประสิทธิภาพ ซึ่งสามารถนำผลลัพธ์ที่ได้จาก
แอปพลิเคชันนี้ไปเป็นส่วนการบริหารจัดการทรัพยากรน้ำได้ใน
อนาคต

6. เอกสารอ้างอิง

- [1] P. Pengsiri and S. Sodsee. "A Modification of Multi-Objective Optimization Genetic Algorithm with Initial Population Partition." *In Data Mining and Machine Learning*, 2015.
- [2] Y. Gao, L. Shi, and P. Yao. "Study on multi-objective genetic algorithm." *In Proceedings of the 3rd World Congress on Intelligent Control and Automation*, Vol. 1, pp. 646–650, 2000.
- [3] M. Mavrovouniotis, C. Li, and S. Yang. "A survey of swarm intelligence for dynamic optimization: Algorithms and applications." *Swarm and Evolutionary Computation*, Vol. 33, pp. 1–17, April 2017.
- [4] Skywalker. "[Algorithm] Particle Swarm Optimization." *AlgorithmTutorial*, 23 April 2013.
- [5] J. Zhang and L. Xing. "A Survey of Multiobjective Evolutionary Algorithms." *In 2017 IEEE International Conference on Computational Science and Engineering (CSE) and IEEE International Conference on Embedded and Ubiquitous Computing (EUC)*, Vol. 1, pp. 93–100, 2017.
- [6] K. Sakakibara, T. Matsumoto, I. Taniguchi, and H. Tamaki. "Optimization of design of decentralized energy networks by mathematical programming techniques." *In 15th International Symposium on Soft Computing and Intelligent Systems (SCIS), 2014 Joint 7th International Conference on and Advanced Intelligent Systems (ISIS)*, pp. 359–364, 2014.
- [7] D. E. Goldberg. *Genetic Algorithms in Search, Optimization and Machine Learning*, 1st ed. Boston, MA, USA: Addison-Wesley Longman Publishing Co., Inc., 1989.
- [8] B. Kazimipour, X. Li, and A. K. Qin. "A review of population initialization techniques for evolutionary algorithms." *In 2014 IEEE Congress on Evolutionary Computation (CEC)*, pp. 2585–2592, 2014.
- [9] J. Kennedy and R. Eberhart. "Particle swarm optimization." *In IEEE International Conference on Neural Networks, Proceedings*, Vol. 4, pp. 1942–1948, 1995.
- [10] E. R. Hruschka, R. J. G. B. Campello, A. Freitas, and A. C. P. L. F. De Carvalho. "A Survey of Evolutionary Algorithms for Clustering." *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, Vol. 39, No. 2, pp. 133–155, March 2009.
- [11] S. Sodsee. *A multi-objective bisexual reproduction genetic algorithm for computer network design / Sunantha Sodsee*. Available Online at http://dric.nrct.go.th/bookdetail.php?book_id=166627. accessed on 19 April 2015.
- [12] M. Oltean, C. Grosan, A. Abraham, and M. Koppen. "Multiobjective optimization using adaptive Pareto archived evolution strategy." *In 5th International Conference on Intelligent Systems Design and Applications, ISDA '05. Proceedings*, pp. 558–563, 2005.
- [13] H. Abbass, R. Sarker, and C. Newton. "PDE: a Pareto-frontier differential evolution approach for multi-objective optimization problems." *In Proceedings of the 2001 Congress on Evolutionary Computation*, Vol. 2, pp. 971–978, 2001.
- [14] K. Deb. *Multi-Objective Optimization Using Evolutionary Algorithms*. John Wiley & Sons, 2001.
- [15] L. Ruekkasaem. "Demand Forecasting for Production Planning : A Case Study of Cleanroom Apparel." *J. Parichart*, Vol. 28, No. 3, pp. 291–304, 2014.
- [16] S. Na, L. Xumin, and G. Yong. "Research on k-means Clustering Algorithm: An Improved k-means Clustering Algorithm." *In 2010 Third International Symposium on Intelligent Information Technology and Security Informatics (IITSI)*, pp. 63–67, 2010.
- [17] Royal Irrigation Department. *Regional Irrigation Office 10*. Available Online at http://irrigation.rid.go.th/rid10/web%20Eng%202010/index_2.htm. accessed on 12 August 2017.