



วิธีการเชิงพันธุกรรมสำหรับการวางแผนกำลังการผลิตที่ขึ้นกับความเชี่ยวชาญของพนักงาน โดยพิจารณาการเรียนรู้และการหลงลืม

ชยธัช เฟื่องก้ามัญ* และ ภัทรศยา ตันติวัฒนกุล

ภาควิชาวิศวกรรมอุตสาหการ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

* ผู้นิพนธ์ประสานงาน โทรศัพท์ 08 1558 2595 อีเมล: chayathach.p@eng.kmutnb.ac.th DOI: 10.14416/j.kmutnb.2022.09.010

รับเมื่อ 27 พฤษภาคม 2564 แก้ไขเมื่อ 14 กรกฎาคม 2564 ตอรับเมื่อ 21 กรกฎาคม 2564 เผยแพร่ออนไลน์ 14 กันยายน 2565

© 2023 King Mongkut's University of Technology North Bangkok. All Rights Reserved.

บทคัดย่อ

แรงงานถือเป็นปัจจัยหนึ่งที่ต้องคำนึงถึงในการวางแผนการผลิต คุณลักษณะพิเศษของแรงงานคือ มีการเรียนรู้และการหลงลืมตามประสบการณ์ และความสามารถในการทำกิจกรรมการผลิตแบบใดแบบหนึ่ง ซึ่งส่งผลต่อกำลังการผลิตของพนักงานแต่ละคน และส่งผลต่อกำลังการผลิตรวม การวางแผนการผลิต และมอบหมายงานสำหรับองค์กรที่มีสินค้าหลากหลาย และความต้องการสินค้าไม่คงที่ มีความยุ่งยากในการตัดสินใจโดยเฉพาะกับผู้วางแผนที่เป็นมนุษย์ งานวิจัยนี้นำเสนอการนำอัตราการเรียนรู้และการหลงลืมมาพิจารณากำหนดกำลังการผลิตของพนักงานในการวางแผนการผลิต และมอบหมายงานให้พนักงานแต่ละคน การมอบหมายงานที่เหมาะสมกับความเชี่ยวชาญของพนักงานจะช่วยลดเวลาที่ใช้ในการผลิตลง หรือทำให้มีกำลังการผลิตเพิ่มขึ้นได้เมื่อเทียบกับการวางแผนการผลิตด้วยนโยบายมอบหมายงานแบบตายตัว โดยงานวิจัยนี้ใช้วิธีการเชิงพันธุกรรมในการหาคำตอบ หรือแผนการผลิตโดยมีเป้าหมายเพื่อกำไรสูงสุด มีการทดสอบพารามิเตอร์ของวิธีการเชิงพันธุกรรม 4 รูปแบบ ได้แก่ C4M3, C4M7, C8M3 และ C8M7 ผลการทดลองพบว่า วิธีการเชิงพันธุกรรมมีประสิทธิภาพที่ดีกว่าคือ ให้ผลกำไรที่สูงกว่าเมื่อเปรียบเทียบกับนโยบายการมอบหมายงานแบบตายตัว โดยรูปแบบพารามิเตอร์ที่เหมาะสมคือ C8M3 เนื่องจากมีประสิทธิภาพในการหาคำตอบที่ให้กำไรสูงสุดและใช้เวลาในการหาคำตอบน้อย

คำสำคัญ: วิธีการเชิงพันธุกรรม การวางแผนการผลิต การเรียนรู้และการหลงลืม การเพิ่มกำลังการผลิต

การอ้างอิงบทความ: ชยธัช เฟื่องก้ามัญ และ ภัทรศยา ตันติวัฒนกุล, “วิธีการเชิงพันธุกรรมสำหรับการวางแผนกำลังการผลิตที่ขึ้นกับความเชี่ยวชาญของพนักงานโดยพิจารณาการเรียนรู้และการหลงลืม,” วารสารวิชาการพระจอมเกล้าพระนครเหนือ, ปีที่ 33, ฉบับที่ 2, หน้า 506–515, เม.ย.-มิ.ย. 2566.



A Genetic Algorithm Approach for Production Capacity Planning Depends on Workers' Expertise with Consideration of Learning and Forgetting

Chayathach Phuaksaman* and Phattarasaya Tantiwattanakul

Department of Industrial Engineering, Faculty of Engineering, King Mongkut's University of Technology North Bangkok, Bangkok, Thailand

* Corresponding Author, Tel. 08 1558 2595, E-mail: chayathach.p@eng.kmutnb.ac.th DOI: 10.14416/j.kmutnb.2022.09.010

Received 27 May 2021; Revised 14 July 2021; Accepted 21 July 2021; Published online: 14 September 2022

© 2023 King Mongkut's University of Technology North Bangkok. All Rights Reserved.

Abstract

Workforce is one of the factors that should be considered in production planning. The special characteristics of workforce include learning and forgetting corresponding to experience and frequency of performing the production activity affecting capability of workers and total production capacity. The production planning and worker assignment of multiple products with time-varying demand are complicated for decision-making, especially for human planners. This research proposed the use of learning and forgetting rates to determine workforce capacity for production planning and work assignment. A suitable assignment by considering the worker's expertise can reduce production time or increase production capacity when compared with the fixed assignment policy. A genetic algorithm was used to find the production plan with maximum profit. The parameters of genetic algorithm were tested in 4 models, i.e. C4M3, C4M7, C8M3, and C8M7. From the results showed that the proposed genetic algorithm approach had better performance than the fixed assignment policy. The suitable parameter of the genetic algorithm is C8M3 providing high performance in finding the best solution with less calculating time.

Keywords: Genetic Algorithm, Production Planning, Learning and Forgetting, Increased Production Capacity

Please cite this article as: C. Phuaksaman and P. Tantiwattanakul, "A genetic algorithm approach for production capacity planning depends on workers' expertise with consideration of learning and forgetting," *The Journal of KMUTNB*, vol. 33, no. 2, pp. 506–515, Apr.–Jun. 2023 (in Thai).



1. บทนำ

ปัญหาในการวางแผนการผลิตนั้น มีองค์ประกอบหลักที่กำหนดกำลังการผลิต คือ กำลังแรงงาน และกำลังของเครื่องจักรอุปกรณ์ที่ใช้ในการผลิต ในส่วนของแรงงานนั้น มีคุณลักษณะพิเศษตามพฤติกรรมทางธรรมชาติของมนุษย์คือ มีการเรียนรู้และการหลงลืมตามประสบการณ์ และความถี่ในการทำกิจกรรมการผลิตแบบใดแบบหนึ่ง ซึ่งจะส่งผลต่อกำลังการผลิตของพนักงานแต่ละคน และย่อมส่งผลต่อการผลิตรวม ทั้งนี้เพื่อให้เกิดประสิทธิภาพในการผลิตจึงต้องมีการวางแผนทั้งปริมาณการผลิต และการมอบหมายงานให้กับแรงงานอย่างเหมาะสม โดยคำนึงถึงลักษณะทางธรรมชาติของแรงงานดังที่ได้กล่าวไปแล้ว เพื่อให้เกิดความสามารถในการผลิตที่สอดคล้องกับความต้องการสินค้า รวมถึงการบริหารต้นทุนให้ต่ำที่สุด เพื่อความได้เปรียบในการแข่งขัน ซึ่งเป็นประเด็นสำคัญในการจัดการในส่วนของการผลิต และในฐานะส่วนหนึ่งของการจัดการห่วงโซ่อุปทานและลอจิสติกส์ [1] การจัดการปัญหาวางแผนการผลิตมีความซับซ้อนเนื่องจากประเภทสินค้าที่หลากหลาย จำนวนแรงงานที่มาก หรือมีกระบวนการผลิตหลายขั้นตอน ทำให้มีความลำบากในการวางแผนการผลิต โดยเฉพาะการใช้ผู้ทำการตัดสินใจที่เป็นมนุษย์ในการประมวลผลและเรียบเรียงการตัดสินใจวางแผนการผลิต ดังนั้นงานวิจัยนี้นำเสนอการพัฒนาวิธีการทางฮิวริสติกสำหรับปัญหาการวางแผนการผลิตที่มีสินค้าหลายชนิด เพื่อให้ผู้วางแผนการผลิตสามารถนำฮิวริสติกที่พัฒนาขึ้นไปใช้ในการวางแผนได้โดยมีต้นทุนรวมในการผลิตที่ต่ำกว่าการใช้นโยบายแบบตายตัว

ปัญหาที่ทำการศึกษานี้มีการพิจารณาการเรียนรู้ และหลงลืมของพนักงาน [2]–[4] ซึ่งเป็นลักษณะทางธรรมชาติของกำลังแรงงานที่เป็นมนุษย์ที่มีความสามารถในการจดจำเรียนรู้ทักษะในการทำงาน และการหลงลืมเมื่อไม่ได้ใช้ทักษะที่เรียนรู้มาในการทำงาน จึงทำให้ปัญหาในการตัดสินใจการจัดการกำลังแรงงาน และการหมุนเวียนแรงงานมีความซับซ้อนขึ้นเพราะมีการอนุญาตให้เกิดการหมุนเวียนงาน (Job Rotation) [5] ซึ่งเป็นแนวคิดในการสร้างทักษะที่หลากหลายให้กับพนักงาน เพื่อความสะดวกในกรณีปรับเปลี่ยนแรงงาน

ลดการพึ่งพาทักษะของพนักงานกลุ่มใดกลุ่มหนึ่งมากเกินไป ซึ่งจะทำให้เกิดปัญหาการผลิตหยุดชะงักได้หากมีการสูญเสียพนักงานที่มีทักษะไปโดยไม่มีพนักงานกลุ่มอื่นทดแทน

โดยทั่วไปแล้วนโยบายที่ใช้ในการมอบหมายงานจะเป็นแบบตายตัวคือ พนักงานแต่ละคนจะถูกมอบหมายให้ทำงานใดงานหนึ่งไปตลอดช่วงเวลาที่ยาวนาน ซึ่งอาจจะทำให้พนักงานมีความชำนาญในการผลิตสินค้าประเภทใดประเภทหนึ่งเป็นพิเศษ แต่ไม่ชำนาญในการผลิตสินค้าประเภทอื่น ในกรณีที่สินค้าแต่ละชนิดมีความต้องการไม่แน่นอน ซึ่งสามารถพบได้ในอุตสาหกรรมหลายประเภท เช่น การประกอบชิ้นส่วนอิเล็กทรอนิกส์ การตัดเย็บเสื้อผ้าในเชิงอุตสาหกรรม การประกอบชิ้นส่วนยานยนต์ หลายครั้งพบว่า ในการผลิตไม่สามารถมีกำลังการผลิตที่สอดคล้องกับความต้องการได้ ทำให้เสียโอกาสในการขาย เนื่องจากกำลังการผลิตไม่เพียงพอ ซึ่งหากมีการจัดสรรมอบหมายแรงงานอย่างเหมาะสมในช่วงการวางแผน อาจทำให้กำลังการผลิตสอดคล้องมากกว่านโยบายแบบตายตัว

การคำนวณหาคำตอบของปัญหาแบ่งออกเป็น 2 กลุ่มใหญ่ คือ วิธีที่ได้คำตอบที่ดีที่สุด (Exact Method) และวิธีการทางฮิวริสติก (Heuristic) ซึ่งอาจจะได้หรือไม่ได้คำตอบที่ดีที่สุด แต่ใช้ระยะเวลาในการคำนวณที่สั้นกว่าแบบที่ได้คำตอบที่ดีที่สุดค่อนข้างมาก และคุณภาพของคำตอบก็ดีเพียงพอต่อความต้องการในการวางแผนต่างๆ วิธีการเชิงพันธุกรรม (Genetic Algorithm; GA) เป็นวิธีการหนึ่งในวิธีการทางฮิวริสติกที่มีการใช้กันอย่างแพร่หลาย โดยเฉพาะสำหรับปัญหาที่มีขนาดใหญ่ และเป็นหนึ่งในวิธีการที่มีประสิทธิภาพสำหรับปัญหาการจัดตารางการผลิต [6], [7]

Chakraborty และ Hasin [8] พัฒนาวิธีการเชิงพันธุกรรมแบบหลายวัตถุประสงค์ (Multi-objective Genetic Algorithm; MOGA) สำหรับปัญหาการวางแผนผลิตรวมแบบหลายช่วงเวลาและหลายผลิตภัณฑ์ โดยมี 3 วัตถุประสงค์ คือ 1) ต้นทุนรวมต่ำสุด ซึ่งประกอบด้วยต้นทุนการผลิตและต้นทุนแรงงาน 2) ต้นทุนการเก็บสินค้าคงคลังและต้นทุนสินค้าค้างส่งต่ำสุด และ 3) อัตราการเปลี่ยนแปลงจำนวนพนักงานต่ำสุด โดยมีการทดสอบพารามิเตอร์ของ

วิธีการเชิงพันธุกรรม จากผลการทดลองวิธีการ MOGA มีประสิทธิภาพที่ดีโดยเฉพาะสำหรับปัญหาการวางแผนผลิตรวมที่มีขนาดใหญ่

Hahn และคณะ [9] นำเสนอแนวทางการวางแผนการผลิตรวมที่เหมาะสมในสถานะที่เหมาะสมกับบริบทของอุตสาหกรรมเคมีภัณฑ์ โดยได้ออกแบบตัวแบบทางคณิตศาสตร์ด้วยการโปรแกรมจำนวนเต็มเชิงเส้นตรง และแก้ปัญหาด้วยตัวแก้ปัญหาคณิตศาสตร์ (Solver) และวิธีการทางฮิวริสติกเพื่อให้ได้แผนการผลิตและจำนวนทรัพยากรการผลิตที่เหมาะสม

ชัยมณี และสุพิทักษ์ [10] ศึกษาการจัดตารางการผลิตสำหรับระบบการผลิตแบบไหลเลื่อนยืดหยุ่น (Flexible Flow Shop Scheduling) เพื่อลดค่าใช้จ่ายรวมของระบบ วิธีการทางฮิวริสติกถูกพัฒนาขึ้นเพื่อแก้ปัญหา กำหนดการเชิงเส้นจำนวนเต็ม (Integer Linear Programming) ผลการทดลองเปรียบเทียบกับคำตอบที่ดีที่สุดพบว่า กระบวนการฮิวริสติกให้คำตอบที่ดีและใช้เวลาในการประมวลผลสั้นกว่า

Liu และคณะ [11] ประยุกต์ใช้วิธีการ HBFA (Hybrid Bacteria Foraging Algorithm) ในการวางแผนการผลิตและมอบหมายงานโดยพิจารณาการเรียนรู้และหลงลืม ในระบบการผลิตแบบเซลล์ลาร์ของอุตสาหกรรมการผลิตหัวต่อไฟเบอร์ ซึ่งพบปัญหาความหลากหลายของผลิตภัณฑ์ทำให้เกิดการผลิตที่ล่าช้าและ/หรือผลิตเสร็จก่อนกำหนด โดยมีวัตถุประสงค์เพื่อลดต้นทุน หรือค่าเสียหายในกรณีที่ไม่มีสินค้าในเวลาที่ต้องการ (Backorder Cost) และต้นทุนสินค้าคงคลัง (Inventory Cost)

Kataoka และคณะ [12] นำเสนอแบบจำลองการมอบหมายงานแบบหลายช่วงเวลา (Multi-period Worker Assignment Model) ภายใต้เงื่อนไขข้อจำกัดในการทำงาน รวมถึงทักษะการเรียนรู้และหลงลืม โดยแบบจำลองที่นำเสนอสามารถลดเวลาการปฏิบัติงานและช่วยให้อัตราการผลิตสูงขึ้น

จากการทบทวนงานวิจัยข้างต้นพบว่า มีงานวิจัยที่เกี่ยวข้องกับปัญหาการวางแผนและมอบหมายงานซึ่งมีทั้งการพัฒนาตัวแบบเพื่อหาคำตอบที่เหมาะสม และการใช้วิธี

การฮิวริสติกต่างๆ โดยงานวิจัยนี้นำเสนอการประยุกต์ใช้วิธีการเชิงพันธุกรรม ในการวางแผนการผลิตและมอบหมายงานให้แก่พนักงานโดยพิจารณาคุณลักษณะการเรียนรู้ และการหลงลืมของทักษะที่ขึ้นกับความชำนาญในการผลิตสินค้าแต่ละชนิด โดยมีเป้าหมายให้แผนการผลิตที่นำเสนอมีต้นทุนรวมในการผลิตดีขึ้นกว่านโยบายมอบหมายงานแบบตายตัว

2. วัสดุ อุปกรณ์และวิธีการวิจัย

2.1 พารามิเตอร์และตัวแปรที่ใช้ในงานวิจัย

I คือ จำนวนพนักงาน โดยที่ i แทนดัชนีแสดงลำดับของพนักงาน ($i = 1, 2, \dots, I$)

J คือ จำนวนสินค้า โดยที่ j แทนดัชนีแสดงชนิดสินค้า ($j = 1, 2, \dots, J$)

T คือ จำนวนคาบเวลาของการวางแผนการผลิต โดยที่ t แทนดัชนีคาบเวลา ($t = 1, 2, \dots, T$)

$L_j^i(t)$ คือ อัตราการเรียนรู้ของพนักงาน i ในการผลิตสินค้า j ในคาบเวลาที่ t

$S_j^i(t-1)$ คือ กำลังการผลิตของพนักงาน i ในการผลิตสินค้า j ในคาบเวลาที่ $t-1$ (หน่วย: ชิ้นต่อคนต่อวัน)

CL คือ สัมประสิทธิ์การเรียนรู้

$F_j^i(t)$ คือ อัตราการหลงลืมของพนักงาน i ในการผลิตสินค้า j ในคาบเวลาที่ t

CF คือ สัมประสิทธิ์การหลงลืม

$P_j(t)$ คือ ราคาขายของสินค้า j ในคาบเวลาที่ t (หน่วย: ดอลลาร์ต่อชิ้น)


$D_j(t)$ คือ ความต้องการสินค้า j ในคาบเวลาที่ t (หน่วย: ชิ้นต่อวัน)

$S_j^i(t)$ คือ กำลังการผลิตของพนักงาน i ในการผลิตสินค้า j ในคาบเวลาที่ t (หน่วย: ชิ้นต่อคนต่อวัน)

$W_j^i(t)$ คือ ค่าแรงพิเศษของพนักงาน i ในการผลิตสินค้า j ในคาบเวลาที่ t (หน่วย: ดอลลาร์ต่อคนต่อวัน)

W^{min} คือ ค่าแรงขั้นต่ำ (หน่วย: ดอลลาร์ต่อคนต่อวัน)

$Y_j^i(t) = 1$ เมื่อพนักงานคนที่ i ถูกมอบหมายให้ทำการผลิตสินค้า j ในคาบเวลาที่ $t = 0$ เมื่อไม่มอบหมายงาน



รูปที่ 1 ขั้นตอนการดำเนินงานวิจัย

2.2 ขั้นตอนการดำเนินงานวิจัย

ในงานวิจัยนี้ได้กำหนดขั้นตอนการดำเนินงานวิจัยแสดงดังรูปที่ 1

2.2.1 กำหนดฟังก์ชันกำลังการผลิต

กำลังการผลิตของพนักงานแต่ละคนจะกำหนดโดยทักษะที่มีอยู่เดิมจากคาบเวลาที่ผ่านมา และการตัดสินใจว่าทำงานงานเดิมหรือไม่ ในสมการกำลังการผลิตประกอบด้วย 3 ส่วน ส่วนแรกคือส่วนของการเรียนรู้ในกรณีที่พนักงานได้ทำงานงานเดิมต่อเนื่องจากคาบเวลาที่ผ่านมา พนักงานจะมีอัตราการเรียนรู้ตามสมการที่ (1) แต่หากพนักงานไม่ได้ทำงานต่อเนื่องจากคาบเวลาที่ผ่านมา พนักงานจะมีอัตราการเรียนรู้ตามสมการที่ (2) โดยประยุกต์อ้างอิงจากงานวิจัย [2]-[5]

$$L_j^i(t) = 1 + e^{-\left(\frac{S_j^i(t-1)}{CL}\right)} \quad (1)$$

$$L_j^i(t) = 1 \quad (2)$$

ส่วนที่สองคือส่วนของการหลงลืม ในกรณีที่พนักงานไม่ได้ทำงานต่อเนื่องจากคาบเวลาที่ผ่านมา พนักงานจะมีอัตราการหลงลืมตามสมการที่ (3) หรือในกรณีที่พนักงานได้ทำงานงานเดิมต่อเนื่องจากคาบเวลาที่ผ่านมา พนักงานจะมีอัตราการหลงลืมตามสมการที่ (4)

$$F_j^i(t) = 1 - e^{-\left(\frac{S_j^i(t-1)}{CF}\right)} \quad (3)$$

$$F_j^i(t) = 1 \quad (4)$$

และส่วนที่สามคือทักษะหรือกำลังการผลิตของพนักงานที่มีอยู่เดิมจากคาบเวลาที่ผ่านมา $(S_j^i(t-1))$ ดังนั้นสมการกำลังการผลิตสามารถคำนวณได้จากอัตราการเรียนรู้คูณด้วยอัตราการหลงลืมคูณกับกำลังการผลิตของคาบเวลาที่ผ่านมา ดังสมการที่ (5)

$$S_j^i(t) = L_j^i(t) \cdot F_j^i(t) \cdot S_j^i(t-1) \quad (5)$$

2.2.2 ระบุค่ารายได้ ต้นทุน และสมการวัตถุประสงค์จากขั้นตอนที่ 1) การกำหนดกำลังการผลิตพิจารณาจากอัตราการเรียนรู้และหลงลืมของพนักงาน ซึ่งกำลังการผลิตจะส่งผลต่อรายได้ อันเกิดจากยอดขายที่สัมพันธ์โดยตรงกับความต้องการและปริมาณการผลิตที่สามารถทำได้ในแต่ละคาบเวลา โดยมีต้นทุนคือค่าแรงพนักงาน ดังนั้นรูปแบบของสมการวัตถุประสงค์จะขึ้นกับเซตของการตัดสินใจเลือกให้พนักงานแต่ละคนทำงานใดในแต่ละคาบเวลา ซึ่งมีความซับซ้อน โดยสามารถอธิบายได้ดังนี้

ส่วนของรายได้ (Income) ประกอบด้วยราคาขายคูณกับปริมาณขาย ซึ่งขึ้นกับความต้องการ และกำลังการผลิตของสินค้าชนิดนั้นๆ ในแต่ละคาบเวลา แสดงดังสมการที่ (6)

$$Income = \sum_{t=1}^T \sum_{j=1}^J P_j(t) \cdot \text{Min}\left(D_j(t), \sum_{i=1}^I S_j^i(t)\right) \quad (6)$$

ส่วนของต้นทุน (Cost) ประกอบด้วยค่าแรงขั้นต่ำ และค่าแรงพิเศษซึ่งขึ้นกับความสามารถของพนักงานแต่ละคนในแต่ละคาบเวลา โดยหากพนักงานไม่ได้รับมอบหมายให้ทำการผลิต ($Y_j^i(t) = 0$) จะจ่ายค่าจ้างตามค่าแรงขั้นต่ำ แต่หากมอบหมายให้ทำการผลิต ($Y_j^i(t) = 1$) จะได้รับค่าจ้างเพิ่มเติมตามความสามารถ เพื่อให้สอดคล้องกับลักษณะการจ้างงานที่สร้างแรงจูงใจให้พนักงานที่มีความสามารถ แสดงดังสมการที่ (7)

$$\text{Cost} = \sum_{t=1}^T \sum_{i=1}^I (W_j^i(t) \cdot Y_j^i(t) + W^{\min}) \quad (7)$$

โดยที่ $W_j^i(t)$ มีความสัมพันธ์แปรผันตรงกับความสามารถหรือกำลังการผลิต ดังสมการที่ (8)

$$W_j^i(t) = \alpha \cdot S_j^i(t) \quad (8)$$

โดยที่ α แทนสัมประสิทธิ์ค่าแรงพิเศษต่อกำลังการผลิตจากสมการรายได้และต้นทุนสามารถสรุป เป้าหมายของการแก้ปัญหาเพื่อหาคำตอบคือต้องการกำไร (Profit) สูงสุดในช่วงเวลาที่พิจารณาจะได้สมการวัตถุประสงค์แสดงดังสมการที่ (9)

$$\text{Profit} = \sum_{t=1}^T \sum_{j=1}^J P_j(t) \cdot \text{Min} \left(D_j(t), \sum_{i=1}^I S_j^i(t) \right) - \sum_{t=1}^T \sum_{i=1}^I (W_j^i(t) \cdot Y_j^i(t) + W^{\min}) \quad (9)$$

2.2.3 พัฒนาวีธีการเชิงพันธุกรรม (GA)

งานวิจัยนี้ได้พัฒนาวีธีการเชิงพันธุกรรมเพื่อใช้แก้ปัญหาที่นำเสนอข้างต้น โดยรูปแบบสำหรับวิธีการที่พัฒนาขึ้นนี้ใช้จำนวนประชากร (Population) ในแต่ละรุ่น (Generation) อย่างคงที่ โดยคำตอบเริ่มต้น (Initial Solution) จะใช้การสุ่มค่า 0 และ 1 แทนการมอบหมายงานให้แก่พนักงานในแต่ละคาบเวลา และสำหรับประชากรรุ่นถัดไปใช้นโยบายเก็บคำตอบ (Chromosome) ที่ดีที่สุดไว้จำนวนหนึ่ง (Elitist) เป็นจำนวนคงที่ และเลือกประชากรในรุ่นถัดไปที่เหลือจากการสุ่มแบบรูเล็ตต์ (Roulette Wheel) ซึ่งจะทำให้

โอกาสในการถูกเลือกขึ้นกับค่าความเหมาะสม (Fitness Value) ของคำตอบจากประชากรก่อนหน้ารวมกับคำตอบที่ได้จากกระบวนการสร้างคำตอบใหม่ หรือเรียกว่าคำตอบลูก (Offspring) โดยใช้การแลกเปลี่ยนพันธุกรรม (Crossover) และการกลายพันธุ์ (Mutation)

กระบวนการแลกเปลี่ยนพันธุกรรมใช้แบบ 2-point Cut โดยเลือกตัวคำตอบต้นแบบ (Parent Chromosome) จากการสุ่มแบบรูเล็ตต์ ในการสร้างคำตอบลูก ซึ่งทำให้ได้คำตอบลูก 2 ตัว จากคำตอบต้นแบบ 2 ตัว โดยจำนวนครั้งในการสร้างคำตอบลูกจะเป็นค่าคงที่ด้วยพารามิเตอร์ อัตราการแลกเปลี่ยนพันธุกรรม (Crossover Rate; C_r)

กระบวนการกลายพันธุ์ใช้แบบ 2-point Random Bit Change คือจะสุ่มเลือกส่วนของคำตอบซึ่งเป็นเลข 0 หรือ 1 แทนการมอบหมายงาน หรือไม่มอบหมายงาน และจะเปลี่ยนจุดที่ถูกเลือกในคำตอบจาก 0 เป็น 1 และจาก 1 เป็น 0 โดยเลือกตัวคำตอบต้นแบบจากการสุ่มแบบรูเล็ตต์ในการสร้างคำตอบลูก โดยจำนวนครั้งในการสร้างคำตอบลูกจะเป็นค่าคงที่ด้วยพารามิเตอร์ อัตราการกลายพันธุ์ (Mutation Rate; M_r)

ทั้งนี้ กระบวนการทั้งหมดจะดำเนินการจนกว่าจะครบจำนวนรุ่นของประชากรที่กำหนดไว้ กระบวนการทั้งหมดสามารถแสดงเป็นรหัสจำลอง (Pseudo Code) ได้ดังนี้

Genetics Algorithm:

Random Generate Initial Solution

Gen = 1

Repeat Until Gen > MaxGen

Crossover Count = 0

Repeat Until Crossover Count >= C_r

Crossover

Select Parents using Roulette Wheel

2-point cut Crossover

Crossover Count += 2

Mutation Count = 0

Repeat Until Mutation Count >= M_r

Mutation



Select a Parent using Roulette Wheel
 2-point random select bit change
 Mutation Count +=1
 Next Generation Population Select
 Sort All Chromosome including offspring
 and current Population based-on Fitness
 Value
 Select Elitist from the sorting
 Select the rest of next Population using
 Roulette wheel
 Gen +=1

2.2.4 กำหนดปัญหาเพื่อทดสอบ

ปัญหาที่ใช้ในการทดสอบนั้นกำหนดให้มีทั้งปัญหาขนาดเล็กและขนาดใหญ่ โดยที่ขนาดของปัญหาคำหนดด้วยจำนวนพนักงาน ชนิดสินค้า และจำนวนคาบเวลา ดังนี้ จำนวนพนักงาน 3 ระดับ ($I = 5, 7, 10$) ชนิดสินค้า 3 ระดับ ($J = 2, 3, 4$) จำนวนคาบเวลา 3 ระดับ ($T = 10, 20, 30$) รวมทั้งหมด 27 ปัญหาที่ใช้ในการทดสอบ

ปัญหาทั้งหมดจะทำการทดลองโดยปรับพารามิเตอร์ของวิธีการเชิงพันธุกรรม ซึ่งประกอบไปด้วยอัตราการแลกเปลี่ยนพันธุกรรม 2 ระดับ ($C_r = 0.4, 0.8$) และอัตราการกลายพันธุ์ 2 ระดับ ($M_r = 0.3, 0.7$) ดังนั้นจึงต้องทดสอบพารามิเตอร์ 4 รูปแบบ ได้แก่ C4M3, C4M7, C8M3, C8M7 โดยที่ C4M3 แทนการทดลองที่ใช้พารามิเตอร์ $C_r = 0.4$ และ $M_r = 0.3$ เป็นต้น และกำหนดให้เป็นการทดลองแบบแฟกทอเรียลเต็มรูป สำหรับปัญหาแต่ละขนาด โดยมีการทำซ้ำ 4 ครั้ง

สำหรับพารามิเตอร์อื่นกำหนดค่าดังนี้

กำลังการผลิตเริ่มต้น $S_j^i(0)$ แทนด้วยความเร็วในการผลิตสินค้าเท่ากับ 100 ชิ้นต่อคนต่อวัน เท่ากันสำหรับพนักงานทุกคน

สัมประสิทธิ์การเรียนรู้ (CL) เท่ากับ 2.0 และสัมประสิทธิ์การหลงลืม (CF) เท่ากับ 2.5

ราคาขายของสินค้า ($P_j(t)$) ของแต่ละปัญหาเป็นค่าสุ่มโดยมีค่าระหว่าง 10 ถึง 20 โดยจะใช้ราคาขายของสินค้าเท่ากันในการทดลองเปรียบเทียบผลของวิธีการเชิงพันธุกรรมกับวิธีการมอบหมายแบบตายตัว และการทดสอบพารามิเตอร์ของวิธีการเชิงพันธุกรรม

ค่าแรงขั้นต่ำ (W^{min}) เท่ากับ 10 ดอลลาร์ต่อคนต่อวัน

สัมประสิทธิ์ค่าแรงพิเศษต่อกำลังการผลิต (α) เป็นฟังก์ชันขึ้นกับกำลังการผลิตในคาบเวลา t และ $t-1$ คำนวณได้จากสมการที่ (10)

$$\alpha = 0.4 \frac{S_j^i(t)}{S_j^i(t-1)}^{2.5 \left(\frac{S_j^i(t)}{S_j^i(t-1)} \right)} \quad (10)$$

ความต้องการสินค้า ($D_j(t)$) ทำการสุ่ม โดยกำหนดให้มี 3 องค์ประกอบ คือ ความต้องการเริ่มต้น แนวโน้มของความต้องการ (Trend Factor) และความเป็นวัฏจักรของความต้องการ (Cyclical Factor) โดยความต้องการเริ่มต้นเป็นการสุ่มแบบสม่ำเสมอ (Uniform Distribution) ในช่วง 100 ถึง 1,000 หน่วย สำหรับสินค้าแต่ละชนิด สำหรับแนวโน้มของความต้องการแบ่งเป็น แนวโน้มเพิ่มขึ้น (Up Trending Demand) โดยกำหนดค่าร้อยละของการเพิ่มของความต้องการสินค้าแต่ละชนิดในแต่ละคาบเวลาด้วยการสุ่มค่าสัมประสิทธิ์ในช่วงร้อยละ 1.0 ถึง 5.0 และแนวโน้มลดลง (Down Trending Demand) โดยกำหนดค่าในช่วงร้อยละ -5.0 ถึง -1.0 สำหรับแต่ละชนิดสินค้าในแต่ละคาบเวลา และปัจจัยด้านวัฏจักรจะกำหนดเป็นพารามิเตอร์ของฟังก์ชัน Sin โดยกำหนดค่าตัวคูณค่า Sin จากค่าสุ่มในช่วง 100 ถึง 200 และสุ่มค่าสัมประสิทธิ์ตัวคูณค่าของคาบเวลา ในช่วง 0.1 ถึง 2.0 ตัวอย่างรูปแบบของฟังก์ชันวัฏจักร เช่น $150\sin 0.5T$ โดยที่ T คือคาบเวลาในการวางแผนการผลิต 150 คือค่าสุ่มของตัวคูณค่า Sin และ 0.5 คือค่าสุ่มของตัวคูณคาบเวลา โดยทั้งหมดจะสุ่มสำหรับแต่ละชนิดสินค้า

2.2.5 ทดลองแก้ปัญหาเพื่อหาพารามิเตอร์ของ GA ที่เหมาะสม

ปัญหาที่ใช้ทดลองมีทั้งหมด 27 ปัญหา แต่ละปัญหามี

การทำซ้ำ 4 ครั้ง โดยทำการทดสอบพารามิเตอร์ของวิธีการเชิงพันธุกรรม 4 รูปแบบ ซึ่งทำการทดลองรวมมีจำนวนถึง 432 การทดลอง ดังนั้นจึงทำการแบ่งกลุ่มของปัญหาเป็น 4 ขนาด เพื่อให้ง่ายต่อการสรุปผลและอภิปรายผลการทดลอง ดังนี้

กลุ่มที่ 1 ตั้งแต่ $T = 10$, $T = 5$, $T = 2$ ถึง $T = 10$, $T = 10$, $T = 2$

กลุ่มที่ 2 ตั้งแต่ $T = 10$, $T = 10$, $T = 3$ ถึง $T = 20$, $T = 7$, $T = 3$

กลุ่มที่ 3 ตั้งแต่ $T = 20$, $T = 7$, $T = 4$ ถึง $T = 30$, $T = 5$, $T = 4$

กลุ่มที่ 4 ตั้งแต่ $T = 30$, $T = 7$, $T = 2$ ถึง $T = 30$, $T = 10$, $T = 4$

ทำการสร้างโค้ดในการสร้างและแก้ปัญหาคำด้วย Python 3.7 โดยทำการรันทั้งหมด 1,000 รุ่น สำหรับทุกการทดลอง

2.2.6 สรุปผลการทดลอง

ผลการทดลองที่ได้จะนำไปสรุปประสิทธิภาพในการหาคำตอบโดยใช้พารามิเตอร์ของวิธีการเชิงพันธุกรรมที่แตกต่างกันในการทดลอง รวมถึงประสิทธิภาพด้านเวลาที่ใช้ในการหาคำตอบของแต่ละกรณี

3. ผลการทดลอง

การทดลองใช้เครื่องคอมพิวเตอร์ในการประมวลผล โดยใช้ Laptop CPU i7-4710HQ 2.50 กิกะเฮิร์ตซ์ หน่วยความจำประเภท RAM 12 กิกะไบต์ ผลการทดสอบประสิทธิภาพของวิธีการเชิงพันธุกรรมเปรียบเทียบกับวิธีการมอหมายงานแบบตายตัวที่ใช้ในปัจจุบันซึ่งกำหนดให้พนักงานทำงานใดงานหนึ่งไปตลอดช่วงเวลาการวางแผนแสดงดังตารางที่ 1 โดยที่ $\Delta C4M3$, $\Delta C4M7$, $\Delta C8M3$ และ $\Delta C8M7$ แทนร้อยละของผลต่างค่าวัตถุประสงค์ของวิธีการเชิงพันธุกรรมที่ใช้พารามิเตอร์ C4M3, C4M7, C8M3 และ C8M7 ตามลำดับ เปรียบเทียบกับวิธีการมอหมายงานแบบตายตัว จากตารางที่ 1 พบว่า สำหรับปัญหา $T = 10$, $I = 5$, $J = 2$ วิธีการเชิงพันธุกรรมที่ใช้พารามิเตอร์ C4M3 ให้ค่าวัตถุประสงค์ หรือผลกำไรที่สูงกว่าวิธีการมอหมายงาน

แบบตายตัว ($\Delta C4M3$) เท่ากับ 190% และเมื่อปรับเปลี่ยนขนาดของปัญหา และพารามิเตอร์ดังแสดงในตารางที่ 1 พบว่า วิธีการเชิงพันธุกรรมให้ค่าวัตถุประสงค์ที่สูงกว่าวิธีการมอหมายงานแบบตายตัว 124–687%

ตารางที่ 1 ประสิทธิภาพของวิธีการเชิงพันธุกรรมเปรียบเทียบกับวิธีการมอหมายงานแบบตายตัว

ปัญหา (T, I, J)	$\Delta C4M3$ (%)	$\Delta C4M7$ (%)	$\Delta C8M3$ (%)	$\Delta C8M7$ (%)
10,5,2	190	184	190	183
10,7,3	328	325	328	333
10,10,4	674	669	674	687
20,5,2	275	282	275	268
20,7,3	201	200	201	199
20,10,4	339	337	339	341
30,5,2	*	*	*	*
30,7,3	142	141	142	142
30,10,4	124	124	124	125

หมายเหตุ: * คือ ไม่สามารถหาคำได้เนื่องจากค่าวัตถุประสงค์ของวิธีการมอหมายงานแบบตายตัวเท่ากับศูนย์

ผลการทดสอบด้านประสิทธิภาพในการหาคำตอบด้านค่าของวัตถุประสงค์ หรือคำตอบที่กำไรสูงสุดของพารามิเตอร์ทั้ง 4 รูปแบบ แสดงดังตารางที่ 2 โดยที่ %Best คือ ร้อยละของคำตอบที่ดีที่สุดเมื่อเทียบกับคำตอบที่ใช้พารามิเตอร์อื่น และ %Gap คือ ร้อยละของผลต่างของค่าวัตถุประสงค์จากคำตอบที่ดีที่สุด ซึ่งพารามิเตอร์ที่เหมาะสมต้องมี %Best ที่สูง และ %Gap ที่ต่ำ ตัวอย่างเช่น C8M3 เป็นพารามิเตอร์ที่เหมาะสมกับปัญหากลุ่มที่ 1 เนื่องจากคำตอบที่ได้มีค่าวัตถุประสงค์ หรือกำไรสูงสุดคิดเป็นร้อยละ 41.18 (%Best = 41.18) เมื่อเทียบกับการหาคำตอบโดยใช้พารามิเตอร์อื่น (C4M3, C4M7 และ C8M7) และมีผลต่างของค่าวัตถุประสงค์จากคำตอบที่ดีที่สุด (%Gap) น้อยที่สุดคือร้อยละ 0.21 จากตารางที่ 2 สรุปได้ว่า C8M3 เป็นพารามิเตอร์ที่เหมาะสมกับปัญหากลุ่มที่ 1 และ 2 ส่วนพารามิเตอร์ C8M7 เหมาะสมกับปัญหากลุ่มที่ 3 และ 4

ตารางที่ 2 ประสิทธิภาพในการหาคำตอบด้านค่าของวัตถุประสงค์

พารามิเตอร์	กลุ่ม	%Best	%Gap
C4M3	1	23.53	0.36
C4M7	1	14.71	0.47
C8M3	1	41.18	0.21
C8M7	1	20.59	0.38
C4M3	2	19.35	0.42
C4M7	2	22.58	0.32
C8M3	2	22.58	0.38
C8M7	2	35.48	0.36
C4M3	3	16.13	0.44
C4M7	3	19.35	0.44
C8M3	3	29.03	0.40
C8M7	3	35.48	0.33
C4M3	4	11.54	0.38
C4M7	4	19.23	0.46
C8M3	4	23.08	0.27
C8M7	4	46.15	0.17


สำหรับประสิทธิภาพด้านเวลาพบว่า พารามิเตอร์ C8M7 ใช้เวลาในการหาคำตอบมากที่สุด รองลงมาคือ C4M7, C8M3 และ C4M3 ตามลำดับ แสดงดังตารางที่ 3 โดยแนวโน้มการเพิ่มขึ้นของเวลาในการหาคำตอบเพิ่มขึ้นตามขนาดของปัญหา และเพิ่มอย่างทวีคูณ (Exponential Growth) แสดงดังรูปที่ 2

ตารางที่ 3 เวลาที่ใช้ในการหาคำตอบ (วินาที)

พารามิเตอร์	กลุ่ม 1	กลุ่ม 2	กลุ่ม 3	กลุ่ม 4
C4M3	370	634	926	1195
C4M7	430	737	1079	1398
C8M3	398	682	997	1287
C8M7	688	1166	1682	2235

4. อภิปรายผลและสรุป

การนำวิธีการเชิงพันธุกรรมมาใช้กับปัญหาการวางแผนการผลิตที่มีสินค้าหลากหลาย และความต้องการสินค้า



รูปที่ 2 เวลาที่ใช้ในการหาคำตอบ

ไม่คงที่ โดยนำการเรียนรู้และการหลงลืมของทักษะความชำนาญของพนักงานมากำหนดเป็นกำลังการผลิตนั้น ช่วยให้การวางแผนมีประสิทธิภาพมากยิ่งขึ้น คือ มีผลกำไรมากขึ้น 124–687% เมื่อเทียบกับวิธีการมอบหมายงานแบบตายตัวที่ใช้ในปัจจุบัน และจากผลการทดลอง C8M3 เป็นพารามิเตอร์ที่เหมาะสมกับปัญหากลุ่มที่ 1 และ 2 ในขณะที่พารามิเตอร์ C8M7 เหมาะสมกับปัญหากลุ่มที่ 3 และ 4 ซึ่งเมื่อพิจารณาเวลาที่ใช้ในการหาคำตอบร่วมด้วยจึงสรุปได้ว่ารูปแบบของพารามิเตอร์ที่เหมาะสมสำหรับปัญหาการวางแผนการผลิตคือ C8M3 หรือ $C_r = 0.8$ และ $M_r = 0.3$ เนื่องจากมีประสิทธิภาพในการหาคำตอบที่ต่ำที่สุดได้ตามวัตถุประสงค์ รวมถึงใช้เวลาในการหาคำตอบน้อยซึ่งเหมาะสมต่องานวางแผนการผลิต

การวางแผนการผลิตและมอบหมายงานโดยพิจารณาการเรียนรู้และการหลงลืมของพนักงานช่วยให้การวางแผนการผลิตมีประสิทธิภาพมากขึ้น การมอบหมายงานที่เหมาะสมกับความเชี่ยวชาญของพนักงานจะช่วยลดเวลาที่ใช้ในการผลิตลง หรือทำให้กำลังการผลิตเพิ่มขึ้นได้เมื่อเทียบกับการมอบหมายงานแบบตายตัว นอกจากนั้น การหมุนเวียนให้ทำงานอื่นเป็นการสร้างทักษะที่หลากหลายให้กับพนักงาน เพื่อความสะดวกในกรณีปรับเปลี่ยนแรงงาน และลดปัญหาการผลิตหยุดชะงักหากสูญเสียพนักงานที่มีทักษะไปโดยไม่มี

พนักงานทำงานทดแทน

อย่างไรก็ตาม การใช้วิธีการเชิงพันธุกรรมในการหาคำตอบอาจจะไม่ได้คำตอบที่ดีที่สุด แต่สามารถชดเชยได้ด้วยความรวดเร็วในการประมวลผล โดยงานวิจัยในอนาคตควรคำนึงถึงเงื่อนไขอื่นเพิ่มเติม เช่น ชัดความสามารถในการผลิตสูงสุดของพนักงาน ทางเลือกในการเลิกจ้างพนักงาน และการรับพนักงานใหม่เพื่อเพิ่มกำลังการผลิต รวมถึงการปรับปรุงวิธีการเชิงพันธุกรรมให้ดียิ่งขึ้นทั้งในการปรับค่าพารามิเตอร์ต่างๆ และการพัฒนาในส่วนของรูปแบบการแลกเปลี่ยนพันธุกรรมและการกลายพันธุ์

เอกสารอ้างอิง

- [1] A. Cheraghalikhani, F. Khoshalhan, and H. Mokhtari, "Aggregate production planning: A literature review and future research directions," *International Journal of Industrial Engineering Computations*, vol. 10, no. 2, pp. 309–330, 2019.
- [2] L. E. Yelle, "The learning curve: Historical review and comprehensive survey," *Decision Sciences*, vol. 10, no. 2, pp. 302–328, 1979.
- [3] M. Y. Jaber and M. Bonney, "A comparative study of learning curves with forgetting," *Applied Mathematical Modelling*, vol. 21, no. 8, pp. 523–531, 1997.
- [4] A. B. Badiru, *Handbook of Industrial and Systems Engineering*, 2nd ed. Boca Raton: CRC Press, 2013, pp. (30-1)-(30-27).
- [5] P. Kampkötter, C. Harbring, and D. Sliwka, "Job rotation and employee performance – evidence from a longitudinal study in the financial services industry," *The International Journal of Human Resource Management*, vol. 29, no. 10, pp. 1709–1735, 2016.
- [6] Y. Demir and S. K. İşleyen, "An effective genetic algorithm for flexible job-shop scheduling with overlapping in operations," *International Journal of Production Research*, vol. 52, no. 13, pp. 3905–3921, 2014.
- [7] W. Xu, Y. Hu, W. Luo, L. Wang, and R. Wu, "A multi-objective scheduling method for distributed and flexible job shop based on hybrid genetic algorithm and tabu search considering operation outsourcing and carbon emission," *Computers & Industrial Engineering*, vol. 157, 2021, Art. no. 107318.
- [8] R. Chakraborty and M. Hasin, "Solving an aggregate production planning problem by using multi-objective genetic algorithm (MOGA) approach," *International Journal of Industrial Engineering Computations*, vol. 4, no. 1, pp. 1–12, 2013.
- [9] G. J. Hahn and M. Brandenburg, "A sustainable aggregate production planning model for the chemical process industry," *Computers & Operations Research*, vol. 94, pp. 154–168, 2017.
- [10] A. Chaimanee and W. Supithak, "Flexible flow shop scheduling problem with sequence dependent setup time under just-in-time philosophy," *The Journal of KMUTNB*, vol. 25, no. 2, pp. 219–231, 2015 (in Thai).
- [11] C. Liu, J. Wang, and J. Y. Leung, "Worker assignment and production planning with learning and forgetting in manufacturing cells by hybrid bacteria foraging algorithm," *Computers & Industrial Engineering*, vol. 96, pp. 162–179, 2016.
- [12] T. Kataoka, K. Morikawa, and K. Takahashi, "Strategic human resource management simulation considering work elements, skills, learning and forgetting," *Procedia Manufacturing*, vol. 39, pp. 1633–1640, 2019.