

## บทที่ 6

### การพัฒนาวิธีการฮิวริสติกส์

การศึกษาในครั้งนี้ได้กำหนดให้ปัญหามี 3 ขนาดคือ ขนาดเล็กขนาดกลาง และขนาดใหญ่ซึ่งข้อมูลทั้งหมดจะนำไปใช้ในการประมวลผลด้วยซอฟต์แวร์สำเร็จรูป LINGO Version 11 ด้วยหน่วยประมวลผล Intel(R) Celeron(R) D CPU (220 @1.2 GHz) และหน่วยความจำ (RAM) 1.87 GB พบว่าใช้เวลาประมวลผล(Runtime) นานและได้คำตอบที่ค่อนข้างมากและยังไม่เหมาะสม ดังนั้นผู้วิจัยจึงได้พัฒนาวิธีการฮิวริสติกส์โดยใช้โปรแกรม Visual Basic C# ในการประมวลผลของการแก้ปัญหาาระบบโลจิสติกส์และโซ่อุปทาน

ข่าว : กรณีศึกษาจังหวัดอุบลราชธานี โดยจะทำการทดสอบกับตัวอย่างปัญหาในการเปรียบเทียบความแม่นยำกับวิธีการที่พัฒนาขึ้น

#### 6.1 วิธีฮิวริสติกส์ (Heuristic) และเมตาฮิวริสติกส์ (Meta-Heuristic)

เมื่อปัญหามีขนาดใหญ่ขึ้น จำนวนคำตอบที่เป็นไปได้ในขอบเขตของปัญหามีมากขึ้น ทำให้การใช้เวลาในการค้นหาคำตอบมากขึ้นเช่นกัน วิธีการในการค้นหาคำตอบแบ่งออกเป็น 2 กลุ่มใหญ่ๆ คือ วิธีการหาคำตอบที่ดีที่สุด หรือ Exact method และอีกวิธีคือ วิธีฮิวริสติก (Heuristic) วิธี Exact method ที่รู้จักกันดี เช่น Simplex method, Branch and bound เป็นต้น ส่วนวิธีฮิวริสติก (Heuristic) เป็นวิธีการค้นหาผลเฉลยคำตอบที่ดีในช่วงเวลาที่เหมาะสม คำตอบที่ได้จากวิธีการฮิวริสติก ไม่สามารถรับประกันได้ว่าเป็นคำตอบที่ดีที่สุดของปัญหา แต่เป็นคำตอบที่ดีในช่วงเวลาที่เหมาะสม โดยทั่วไปวิธีฮิวริสติกถูกออกแบบขึ้นมาแก้ปัญหาที่มีลักษณะที่แตกต่างกัน ตามแต่ลักษณะปัญหานั้นๆ วิธีฮิวริสติกจึงไม่มีรูปแบบตายตัว สามารถปรับเปลี่ยนไปตามปัญหาขึ้นอยู่กับความเหมาะสมตามแต่ลักษณะปัญหา ดังนั้นวิธีฮิวริสติกที่สามารถหาคำตอบของปัญหาหนึ่งจึงไม่สามารถนำไปใช้หาคำตอบของอีกปัญหาหนึ่งได้ หรือแม้กระทั่งนำไปใช้ในการหาคำตอบของปัญหาเดิมแต่มีสมการเงื่อนไขของปัญหาเปลี่ยนแปลงไป

Nagy and Salhi (1996) นำเสนอวิธีการทางฮิวริสติกเพื่อแก้ปัญหาข้อจำกัดของขนาดปัญหา โดยวิธีฮิวริสติกที่นำมาใช้เป็นวิธีการประมาณการแบ่งลูกค้าออกเป็นกลุ่มๆ เรียกว่า “Cluster-Based” ในการจัดสรรลูกค้าให้กับศูนย์กระจายสินค้า และขั้นตอนต่อจากนั้นจะเป็นการสร้างเส้นทางด้วยวิธี Clarke and Wright Saving Heuristic อีก 3 ปีต่อมา Tuzun and Burke (1999) ได้นำเสนอวิธีทาบูเซิร์ช (Tabu Search) แบบสองเฟสเพื่อใช้ในการแก้ปัญหาการเลือกสถานที่ตั้งและจัดเส้นทางขนส่งที่มีขนาดของปัญหา 200 ลูกค้า โดยเปรียบเทียบคำตอบที่ได้และเวลาที่ใช้กับวิธีฮิวริสติกแบบ Saving ซึ่งผลที่ได้ปรากฏว่าวิธี Tabu Search ที่ออกแบบมาได้คำตอบที่ดีกว่าวิธี Saving แต่ใช้เวลาในการคำนวณมากกว่า

ณกร อินทร์พยุง (2548) ได้สรุปว่าปัญหาที่เหมาะสมสำหรับการแก้ด้วยวิธีฮิวริสติกจะมีลักษณะต่างๆ ประกอบด้วย (1) ปัญหาการตัดสินใจที่มีโครงสร้างไม่สมบูรณ์ (Ill = structured problem) (2) ปัญหาที่ผู้วิจัยพยายามทำให้เป็นปัญหาที่มีโครงสร้างสมบูรณ์แต่ได้ละเลยเงื่อนไขของปัญหาบางอย่างหรือทำให้ง่ายขึ้น

(3) ปัญหาที่มีตัวแปรการตัดสินใจและเงื่อนไขของปัญหาที่เป็นจำนวนมาก และ (4) ปัญหาที่ไม่ต้องการคำตอบที่ดีที่สุด (Goof feasible solution)

ตัวอย่างของวิธีฮิวริสติกที่นิยมใช้ในงานวิจัยด้านโลจิสติกส์ เช่น วิธีในกลุ่มของ Constructive เช่น วิธีละโมบ (Greedy) และวิธีประหยัด (Saving) วิธีหาคำตอบแบบเนเบอร์ฮูด (Neighborhood search) หรือวิธีโลคอล (Local search)

ดังนั้นวิธีฮิวริสติกจึงถูกพัฒนาให้มีความยืดหยุ่น รวดเร็วและมีประสิทธิภาพมากยิ่งขึ้น เรียกว่า เมตาฮิวริสติก (Meta-Heuristic)

Blum and Roli (2003) ซึ่งได้กล่าวว่าหลักการเบื้องต้นของวิธีเมตาฮิวริสติกส์ มีดังต่อไปนี้คือ 1) เมตาฮิวริสติกมีระเบียบวิธีในการค้นหาคำตอบที่ดีที่สุดภายในเซตของคำตอบที่เป็นไปได้ 2) เมตาฮิวริสติกมีจุดประสงค์เพื่อหาคำตอบที่ดีที่สุดหรือคำตอบที่ใกล้เคียงที่ดีที่สุด ภายในระยะเวลาที่เหมาะสม 3) วิธีเมตาฮิวริสติกอาจมีทั้งแบบซับซ้อนและไม่ซับซ้อน เช่น วิธีโลคอลเซิร์ช (Local Search) วิธีระบบมด (Ant System) วิธีทางพันธุกรรม (Genetic Algorithm) วิธีการค้นหาต้องห้าม (Tabu Search) และวิธีเลียนแบบการอบอ่อน (Simulated Annealing) เป็นต้น 4) เมตาฮิวริสติกอาจเกิดจากการรวมหลากหลายวิธีเทคนิคเพื่อค้นหาคำตอบที่ดีที่สุดภายในพื้นที่คำตอบที่เป็นไปได้ 5) เมตาฮิวริสติกมีระเบียบขั้นตอนที่แน่นอนแต่สามารถปรับเปลี่ยนในรายละเอียดเมื่อนำไปใช้แต่ละปัญหา และ 6) เมตาฮิวริสติกบางประเภทมีการใช้ความจำชั่วคราวมากขึ้น ในการจดจำคำตอบเดิม เพื่อให้การค้นหาคำตอบที่ไม่ซ้ำที่เดิมเช่น Tabu search วิธี Ant system

นอกจากนี้ Blum and Roli (2003) ยังได้เสนอการแบ่งเมตาฮิวริสติกไว้ 6 ประเภทดังนี้ 1) เมตาฮิวริสติกที่เกิดจากแรงบันดาลใจจากธรรมชาติ ได้แก่ วิธีระบบมด (Ant System) วิธีทางพันธุกรรม (Genetic Algorithm) วิธีเลียนแบบการอบอ่อน (Simulated Annealing) และวิธีการเกาะกลุ่มประชากรแบบ PSO (Particle Swarm Optimization) เป็นต้น 2) เมตาฮิวริสติกที่ไม่ได้เกิดจากแรงบันดาลใจจากธรรมชาติ ได้แก่ วิธีการค้นหาต้องห้าม (Tabu Search) เป็นต้น 3) เมตาฮิวริสติกแบบใช้ประชากรคือในหนึ่งรอบของการค้นหาคำตอบจะได้คำตอบมากกว่าหนึ่งคำตอบให้เลือก เช่น วิธีระบบมด (Ant System) วิธีทางพันธุกรรม (Genetic Algorithm) วิธีการลอกแบบ (Memetic Algorithm) และวิธีการเกาะกลุ่มประชากรแบบ PSO (Particle Swarm Optimization) เป็นต้น 4) เมตาฮิวริสติกแบบไม่ใช้ประชากร คือในหนึ่งรอบของการค้นหาคำตอบจะได้คำตอบออกมาเพียงหนึ่งคำตอบเท่านั้น เช่น วิธีเลียนแบบการอบอ่อน (Simulated Annealing) วิธีการค้นหาต้องห้าม (Tabu Search) และวิธีการค้นหาในพื้นที่คำตอบที่เป็นไปได้แบบวนซ้ำ (Iterate Local Search) เป็นต้น 5) เมตาฮิวริสติกแบบสมการเป้าหมายคงที่ คือในหนึ่งรอบของการคำนวณอาจมีการเปลี่ยนแปลงสมการเป้าหมาย เพื่อให้ได้คำตอบใหม่ๆ เกิดขึ้น เช่น วิธี Guided Local Search เป็นต้น 6) เมตาฮิวริสติกแบบไม่มีการเปลี่ยนแปลงสมการเป้าหมาย เช่น วิธีระบบมด (Ant System) วิธีทางพันธุกรรม (Genetic Algorithm) วิธีเลียนแบบการอบอ่อน (Simulated Annealing) และวิธีการลอกแบบ (Memetic Algorithm) เป็นต้น

Clark and Wright (1964) ทำการจัดเส้นทางการเดินทางที่มีหลายขนาด โดยส่งสินค้าออกจากศูนย์กลางการกระจายสินค้าเพียงแห่งเดียว ผู้วิจัยได้ใช้วิธีการทางฮิวริสติกจัดเรียงลำดับของค่าประหยัด (Saving) และเชื่อมเส้นทางต่างๆ เข้าด้วยกัน ทำให้ทราบจำนวนรถบรรทุกที่ต้องการใช้และปริมาณสินค้าในแต่ละคัน จาก การคำนวณค่าเวลาหรือระยะทางใช้จ่ายในการขนส่งที่ประหยัดที่สุด นอกจากวิธีฮิวริสติกที่กล่าวมา ในอดีตที่ผ่านมามีการศึกษาหาวิธีหาคำตอบโดยใช้วิธีฮิวริสติกเพื่อแก้ไขปัญหาต่างๆ เช่น วิธีเซิงพันธุกรรม วิธี GRASP (Greedy Randomized Adaptive Search Procedure) วิธี SA (Simulated Annealing) เป็นต้น

Steven and et al. (1994) ทำวิจัยเกี่ยวกับปัญหาการเก็บขนวัตถุซึ่งเป็นปัญหาที่มีเป้าหมายวิ่งเก็บขนวัตถุให้ได้มากที่สุดในหนึ่งเที่ยวซึ่งในงาน วิจัยนี้จะเรียกว่าทัวร์ เก็บขนวัตถุจากจุด (Node) ซึ่งกระจายอยู่ที่นั่นไปในพื้นที่ที่ระบุแต่ละจุดจะมีน้ำหนักหรือปริมาตรของวัตถุที่จะต้องเก็บต่างกัน ข้อจำกัดของปัญหาประเภทนี้คือ เวลาและความจุของรถที่วิ่งในแต่ละทัวร์ งานวิจัยนี้ได้ใช้ฮิวริสติกในการจัดเส้นทางและทัวร์ ซึ่งผู้นำการวิจัยค้นพบว่า เมื่อทำการจัดเส้นทางและทัวร์ด้วยวิธีฮิวริสติกมีข้อดีสามประการคือ 1) ปัญหานั้นมีคำตอบที่เป็นไปได้อย่างน้อยหนึ่งคำตอบวิธีฮิวริสติกจะค้นพบได้อย่างแน่นอน 2) วิธีฮิวริสติกจะให้คำตอบที่เหมาะสมที่สุดหรือไม่ก็เป็นคำตอบที่ใกล้เคียงกับคำตอบที่เหมาะสมที่สุดเป็นอย่างมากได้ 3) เป็นวิธีที่แก้ปัญหาขนาดใหญ่ได้ด้วยการใช้เวลาในการคำนวณน้อย

Clark and Wright (1964) ทำการจัดเส้นทางการเดินทางที่มีหลายขนาดโดยส่งสินค้าออกจากศูนย์กระจายสินค้าเพียงแห่งเดียว ผู้วิจัยได้ใช้วิธีการทางฮิวริสติกจัดเรียงลำดับของค่าประหยัด (Saving) และเชื่อมเส้นทางต่างๆ เข้าด้วยกันทำให้ทราบจำนวนรถบรรทุกที่ต้องการใช้และปริมาณสินค้าในแต่ละคัน

Matin and et al. (1998) เสนอแนวทางของการปรับปรุงประสิทธิภาพของการกระจายสินค้าประเภทเบเกอรี่โดยมีข้อกำหนดคือ ช่วงเวลาในการส่งสินค้า ผู้วิจัยได้ใช้วิธีการสร้างเส้นทางในการเดินทางโดยใช้ระยะเวลาเป็นฟังก์ชันวัตถุประสงค์ และใช้เทคนิค Nearest-neighbor heuristics โดยหาระยะเวลาในการเดินทางระหว่างลูกค้าจากข้อมูลระยะทางในการเดินทางและความเร็วเฉลี่ยด้วยการสร้างตารางความสัมพันธ์ระหว่างระยะทางการเดินทางและเวลาเดินทางรถ และหาเวลาในการนำสินค้าลงด้วยการสร้างกราฟความสัมพันธ์ของจำนวนสินค้าและเวลาที่ใช้ในการนำสินค้าลงจากรถ

Christofides and Mingozzi (1979) เสนอวิธีปรับปรุงเส้นทาง ภายหลังจากได้เส้นทางเบื้องต้น ผู้วิจัยได้เสนอการปรับปรุงเส้นทางด้วยการแลกเปลี่ยนเส้นทางเพื่อให้ได้ระยะทางใหม่ที่เกิดขึ้นมีค่าน้อยกว่าค่าเดิม โดยมีการเริ่มต้นจากการสมมติ เส้นทางเริ่มต้นขึ้นมาแล้วค่อยปรับปรุงจนกระทั่งได้เส้นทางที่ดีที่สุด

สรุประเบียบวิธีอัลกอริทึมของเมตาฮิวริสติกส์

มีงานวิจัยจำนวนมากมายที่ได้เสนอวิธีอัลกอริทึมของเมตาฮิวริสติกส์ที่เป็นที่นิยม ดังนั้นทางผู้วิจัยจึงได้สรุปมาเฉพาะในส่วนที่มีความสำคัญ และจะสามารถนำมาประยุกต์ใช้ในการศึกษาโซ่อุปทานข้าว ดังนี้

(1) การค้นหาในพื้นที่บางส่วนในพื้นที่คำตอบที่เป็นไปได้ (local search) เป็นวิธีการพื้นฐานของเมตาฮิวริสติก ซึ่งมีความจำเป็นค่อนข้างมากหากการ local search ไม่สามารถค้นหาคำตอบที่ดีที่สุดในแต่ละพื้นที่ย่อยได้ เราก็ไม่สามารถสรุปได้ว่าพื้นที่คำตอบที่ดีที่สุดนั้น อยู่ในพื้นที่คำตอบที่เป็นไปได้ วิธี local search มี

การค้นหาคำตอบหลาย ๆ คำตอบ และมุ่งหาคำตอบที่ดีที่สุดในพื้นที่เฉพาะที่กำหนด โดยส่วนใหญ่ใช้วิธีการ neighborhood search หลาย ๆ ครั้งเพื่อหาคำตอบที่ดีที่สุด

(2) วิธีการเลียนแบบการอบอ่อน (Simulated Annealing) เป็นวิธีเมตาฮิวริสติกที่ได้รับการพัฒนาขึ้นในช่วงแรก ๆ ในการหาคำตอบของปัญหาการตัดสินใจที่มีความซับซ้อนรวมทั้งมีตัวแปรและเงื่อนไขของปัญหาจำนวนมาก แนวคิดพื้นฐานตาม Metropolis and et al. (1953) คือเป็นการใช้อัลกอริทึมในการจำลองการควบคุมการเย็นตัวของวัตถุในอ่างความร้อน เรียกขั้นตอนนี้ว่า Annealing หลังจากนั้น Kirkpatrick and et al. (1983) ได้นำวิธีการจำลองดังกล่าวมาใช้ในการแก้ปัญหาการตัดสินใจที่ต้องการค่าต่ำสุดหรือค่าสูงสุด คำตอบที่หามาได้โดยวิธี SA จะค่อย ๆ เข้าสู่คำตอบที่ดีที่สุดเหมือนในช่วงเวลาการเย็นตัวของวัตถุ คุณภาพของคำตอบที่ได้ขึ้นอยู่กับพารามิเตอร์ในการควบคุมอุณหภูมิและโครงสร้างของเนเบอร์ฮูดที่ใช้เป็นหลัก

(3) Tabu Search (TS) โดยที่ Lin and Kwok (2006) ได้กล่าวว่า เป็นระเบียบวิธีที่คล้ายกันกับ Simulated Annealing คือ เป็นระเบียบวิธีประเภทเชิงเรียนรู้ประสบการณ์ Tabu Search ซึ่งใช้วิธีหาคำตอบที่ดีกว่าโดยจดจำและป้องกันค่าเดิมๆ ที่แยกไว้ใน Tabu list ซึ่งจะช่วยให้การปรับปรุงรอบการค้นต่อๆ ไปจนกว่าจะถึงเกณฑ์ที่ยอมรับได้แต่วิธีนี้อาศัยหน่วยความจำของเครื่องคอมพิวเตอร์เข้ามาเกี่ยวข้องค่อนข้างมากทำให้การทำงานที่ยู่ยากซับซ้อน

(4) Genetic Algorithm (GA) โดย Doerner, Gutjahr and Nolz (2009) ได้กล่าวว่า เป็นระเบียบวิธีการหาค่าความเหมาะสมแบบ Stochastic โดยมีแนวคิดสมมติฐานเชิงพันธุกรรมเลียนแบบขั้นตอนการวิวัฒนาการทางธรรมชาติ (Natural Evolution) ตั้งอยู่บนพื้นฐานแนวคิดการคัดเลือกเผ่าพันธุ์ตามธรรมชาติ นำมาประยุกต์เชิงเลขในการค้นหาคำตอบของปัญหาการตัดสินใจที่มีความสลับซับซ้อนมีตัวแปรและเงื่อนไขจำนวนมากได้ดี

วิธีการเปลี่ยนแปลงลักษณะทางพันธุกรรม แบ่งออกเป็น 2 ประเภทคือ

(4.1) วิธีข้ามฟาก (Crossover) เป็นการแลกเปลี่ยนยีนระหว่างโครโมโซมเพื่อสร้างโครโมโซมใหม่

(4.2) วิธีผ่าเหล่า (Mutation) เป็นการสลับตำแหน่งของยีนภายในโครโมโซมแต่ละตัว

ประชากรที่ผลิตออกมาใหม่เป็นประชากรรุ่นลูกที่มีพันธุกรรมดี และมีการพัฒนาออกเป็นหลายๆ รุ่น ดังนั้นวิธีหาคำตอบเชิงพันธุกรรมนี้ บางครั้งอาจถูกเรียกว่าเป็นการหาคำตอบโดยใช้กลุ่มของประชากร (Population-based search) ซึ่งแตกต่างจากวิธี SA และวิธี TS ซึ่งมีการหาคำตอบหนึ่งจากคำตอบหนึ่งไป อีกคำตอบหนึ่ง เมื่อเปรียบเทียบกับวิธี GA อาจเปรียบเสมือนการพัฒนาของโครโมโซมเพียง 1 ตัวเท่านั้น

(5) Ant Colony Optimization (ACO) โดย Doerner, Focke and Gutjahr (2007) ได้กล่าวว่า ระเบียบวิธีที่เลียนแบบพฤติกรรมกรหาแหล่งอาหารของมดจากแหล่งที่อยู่อาศัยเมื่อนำพฤติกรรมกรหาอาหารของมดมาหาเชิงเลขระเบียบวิธีนี้จะให้ผลดีในค่าคำตอบเหมาะสมปรากฏเฉพาะที่มีข้อจำกัดการประยุกต์ใช้ที่การกำหนดข้อจำกัดหากฟังก์ชันมีค่า Local Optima จำนวนมากและเป็นค่าที่เท่าๆกันหรือใกล้เคียงกันอาจจะไม่เจอ Global Optima เช่นเดียวกับพฤติกรรมมดที่เจออาหารในขนาดปริมาณที่เท่าๆกันหลายจุดมดจะตอม

เฉพาะจุดที่เจอก่อนเป็นจำนวนมากแทนที่จะตอมในปริมาณที่เท่าๆกันต่อเมื่อใช้รอบการค้นหาก็อกก็จะเจอ Global Optima ได้เช่นกันจึงเป็นวิธีที่ต้องระมัดระวังในการใช้พารามิเตอร์ต่างๆค่อนข้างมาก

(6) Particle Swarm Optimization (PSO) เป็นระเบียบวิธีการหาค่าความเหมาะสมแบบ Stochastic ซึ่งได้รับแรงบันดาลใจจากพฤติกรรมการฟุ้งกระจายอนุภาคเป็นกลุ่มเช่นกลุ่มของฝูงนกที่กำลังบินตามจ่าฝูง PSO ประกอบด้วยกลุ่มของอนุภาคที่กำลังเคลื่อนที่ในหลายมิติเป็นการค้นหาค่าตอบของการแก้ปัญหาบนพื้นฐานจำนวนจริงแต่ละอนุภาคตำแหน่งความเร็วในเวกเตอร์เก็บในหน่วยความจำเปรียบเทียบกับอนุภาคที่อยู่ใกล้กัน (neighbor particle) แล้วคัดเลือกศึกษาอนุภาคที่มีศักยภาพความเร็วและเวกเตอร์ที่เป็นเวกเตอร์นำเคลื่อนตัวไปในทิศทางใหม่ ๆ จนกว่าจะได้เวกเตอร์คำตอบครอบคลุม (Global Solution Vector)

(7) Differential Evolution (DE) เป็นระเบียบวิธีการหาค่าความเหมาะสมแบบ Stochastic และเป็น Random base Global Search Space ซึ่งทำการสุ่มหาค่าตอบแบบครอบคลุมโดยมีแนวคิดสมมุติฐานเชิงพันธุกรรมเช่นเดียวกับ GAs แต่มีข้อดีที่โดดเด่นกว่าคือมีโครงสร้างของระเบียบวิธีที่ซับซ้อนน้อยกว่ามีความยืดหยุ่นมาก (Generalizations) นอกจากนั้นยังสามารถใช้ค่าจำนวนจริง (Floating Point Real Number) ในการคำนวณโดยไม่จำเป็นต้องแปลงค่าตัวแปรตัดสินใจเป็นเลขฐานสองจึงเป็นเหตุผลสำคัญที่ทำให้วิธีการ DE มีความรวดเร็วและมีประสิทธิภาพสูง (Robustness) ในการค้นหาค่าตอบกว่าวิธีอื่น

## 6.2 แนวความคิด และทฤษฎีเกี่ยวกับโลจิสติกส์แบบหลายวัตถุประสงค์ (Multi-Objective Logistics)

กมลชนก สุทธิวาทพุดิ และคณะ (2544) ได้ให้คำนิยามของโลจิสติกส์ หมายถึง การจัดการลำเลียงขนส่งสินค้าเพื่อให้เกิดต้นทุนต่ำที่สุด โดยเริ่มจากกระบวนการจัดหาวัตถุดิบไปจบที่ผู้บริโภค โดยมีการจัดการวางแผน การจัดสายงาน การควบคุมกิจกรรมในส่วนที่มีการเคลื่อนย้ายและไม่มีการเคลื่อนย้าย รวมไปถึงการอำนวยความสะดวกในกระบวนการไหลสินค้า

Budadeeand et al. (2007) ได้ทำการศึกษาการเลือกสถานที่ตั้งโรงงานเอทานอลที่ใช้ชานอ้อยซึ่งเป็นของเหลือจากกระบวนการผลิตน้ำตาล โดยมองถึงความคุ้มค่าทางเศรษฐศาสตร์ ผลกระทบต่อสิ่งแวดล้อม และพบว่าการใช้ชานอ้อยในการผลิตเอทานอลมีความคุ้มค่าทางเศรษฐศาสตร์ และลดผลกระทบต่อสิ่งแวดล้อม

นัทพงศ์ นันทสำเร็จ (2553) ได้ศึกษาปัญหาเลือกสถานที่ตั้งโรงงานเอทานอลจากวัตถุดิบชานอ้อย แบบหลายวัตถุประสงค์ ซึ่งได้แก่ ด้านเศรษฐศาสตร์ ด้านความเสี่ยง ด้านสิ่งแวดล้อม พบว่าการให้น้ำหนักของสมการเป้าหมายที่ต่างกันจะส่งผลให้การเปิดโรงงานเอทานอลในพื้นที่และจำนวนที่ต่างกัน

โดยทั่วไปแล้วการตัดสินใจด้านโลจิสติกส์อาจมีวัตถุประสงค์เพียงอย่างเดียว เช่น เพื่อลดระยะทางในการขนส่ง ลดเวลาในการขนส่ง ลดขนาดของยานพาหนะ หรือเพิ่มผลกำไรจากการดำเนินการ เป็นต้น อย่างไรก็ตามหากเป็นการตัดสินใจในวัตถุประสงค์ที่มากกว่าหนึ่งวัตถุประสงค์ (Multiple objective) สิ่งที่มีเกิดขึ้นก็คือวัตถุประสงค์บางอย่างจะเกิดความขัดแย้งกันเองภายใน ดังนั้น จึงต้องมีการเปลี่ยนมุมมองของปัญหาให้เป็นแบบหลายวัตถุประสงค์ (Multi objective)

Jezefowicz and et al. (2008) ได้ระบุรูปแบบหลายวัตถุประสงค์ (Multiple-objective problem: MOP) ไว้ดังแสดงในสมการ (6.1)

$$\text{MOP} = \begin{cases} \text{Min } F(x) = (f_1(x), f_2(x), \dots, f_n(x)) \\ \text{s.t. } x \in D \end{cases} \quad (6.1)$$

เมื่อ  $n$  = จำนวนวัตถุประสงค์ของปัญหา สำหรับปัญหาแบบหลายวัตถุประสงค์  $n \geq 2$

$x$  =  $(x_1, x_2, \dots, x_r)$  เป็นเวกเตอร์ของตัวแปรตัดสินใจ

$D$  = พื้นที่ของคำตอบที่เป็นไปได้

$F(x)$  = เวกเตอร์ของวัตถุประสงค์

คำตอบที่ได้จากการแก้ปัญหาการตัดสินใจแบบหลายวัตถุประสงค์จะอยู่ในรูปของเซตของพาเรโต (Pareto set) โดยในการแก้ปัญหาจะกระทำได้สามแนวทางคือ 1) แนวทาง *a priori* ซึ่งผู้ตัดสินใจจะกำหนดความสำคัญของแต่ละวัตถุประสงค์ไว้ตั้งแต่เริ่มต้น 2) แนวทาง *interactive* ซึ่งผู้ตัดสินใจจะเลือกให้ความสำคัญของแต่ละวัตถุประสงค์ระหว่างกระบวนการแก้ปัญหา กำลังดำเนินการอยู่ และ 3) แนวทาง *a posteriori* ซึ่งเซตของคำตอบที่เป็นไปได้ทั้งหมดจะได้รับนำเสนอเพื่อให้ผู้ตัดสินใจเลือก

ปัญหาการตัดสินใจด้านโลจิสติกส์แบบหลายวัตถุประสงค์ได้ถูกนำไปประยุกต์ในหลายทางด้วยกัน ไม่ว่าจะเป็น

(1) การขยายปัญหาขอบเขตของปัญหาดั้งเดิม เพื่อให้สามารถนำไปประยุกต์ใช้ได้จริง เช่น เพิ่มวัตถุประสงค์ด้านเวลา หรือวัตถุประสงค์ด้านความพึงพอใจของลูกค้า

(2) การประยุกต์ปัญหากรณีศึกษาในชีวิตจริง เช่น ปัญหาการขนส่งวัตถุดิบรายซึ่งจะมีวัตถุประสงค์ด้านความเสี่ยงด้านความปลอดภัยเพิ่มเติมด้วย เป็นต้น

ตารางที่ 6.1 การประยุกต์ใช้ Multi objective กับงานวิศวกรรม

ปัญหา	นักวิจัย	วิธีการ
Multi objective Multi-stage Problem	Jiuping Xu, Qiang Liu, Rui Wang (2008); Fulya Altiparmark, Mitsuo Gen, Lin Lin, Turan Paksoy (2006) Reza Zanjirani Farahani and Mahsa Elahipanah (2008) Z.H.Che, C.J. Chiang (2010) Cahit Perkgoz, Amir Azaron, Hideki Katagiri, Kosuke Kato, Masatoshi Sakawa (2007)	GA GA GA mPaGA GA
Multi objectiveProblem	Amir Kamali, S.M.T. Fatemi and Ghomi F. Jolai (2011) C.K.Y.Lin, R.C.W. Kwok (2006) Raul Banos, Julio Ortega, Consolacion Gil, Antonio L, Marquez, Francisco de Toro (2013) Luis A. Moncayo-Martinez and David Z. Zhang (2011) Luis A. Moncayo-Martínez, and Gustavo Recio (2014) Manuel Chica, Óscar Cerdón and Sergio Damas (2011)	PSO TS,SA SA ACO ACO GA
Multi-stage Problem	H.S. Wang (2009) Ching-Jong Liao, Yu-Lun Tsai, Chien-Wen Chao (2011)	ACO ACO
Location-allocation	Seyed Habib, A. Rahmati, Abbas Ahmadi, Mani Sharifi, Amirhossain Chambari (2014) Vahid Hajipour, Seyed Habib, A. Rahmati, Seyed Hamid Reza Pasandideh ,Seyed Taghi Akhavan Niaki (2014) Ali Zeinal Hamadani, Mostafa Abouei Ardakan, Taghi Rezvan, Mohammad Mehran Honarmandian (2013) Seyed Mohsen Mousavi, Seyed Taghi Akhavan Niaki (2013) F. Torrent-Fontbona and V. Muñoz, B. López (2013) Meilin Wen, Rui Kang (2011) Byung Duk Song, James R. Morrison, Young DaeKo (2013) Meilin Wen, Kakuzolwamura (2008)	GA GA,SA GA,SA GA SA GA GA GA

Fulya Altiparmak, Mitsuo Gen, Lin Lin, Turan Paksoy (2006) ได้ใช้วิธีการ GA สำหรับการหาค่าที่เหมาะสมของปัญหาการออกแบบเครือข่ายโซ่อุปทานหลายวัตถุประสงค์ซึ่งประกอบด้วย 3 วัตถุประสงค์ คือ 1) minimization ของต้นทุนรวม 2) maximization ของการบริการลูกค้าและ 3) maximization ของการใช้ประโยชน์ความจุของ DCs ผลการศึกษาพบว่าวิธี GA\_A1 มีประสิทธิภาพดีกว่า MO\_SA เมื่อพิจารณาจากผลเฉลย Pareto-optimal solution

Reza Zanjirani Farahania and Mahsa Elahipanaha (2008) ได้ใช้ขั้นตอนวิธีเชิงพันธุกรรม (genetic algorithm) เพื่อที่จะ Minimizing 2 วัตถุประสงค์ (bi-objective) โดยวัตถุประสงค์แรกมุ่ง minimize ต้นทุน วัตถุประสงค์ที่สอง มุ่ง minimize ผลรวมของ backorders และ surpluses ของผลิตภัณฑ์ นำมาสู่การเพิ่มระดับการให้บริการสำหรับการกระจายสินค้าแบบทันเวลาพอดีในโซ่อุปทาน โดยวัตถุประสงค์แรกประกอบด้วยต้นทุนการจัดซื้อ จัดหา ต้นทุนการขนส่ง และต้นทุนการถือครองสินค้าคงคลัง โดยต้นทุนการขนส่งจะประกอบด้วย  $C_p$  ซึ่งเป็นต้นทุนการขนส่งต่อหน่วยผลิตภัณฑ์ต่อหน่วยระยะทาง และวัตถุประสงค์ที่สองประกอบด้วย จำนวนของผลิตภัณฑ์  $p$ 's backorders ของร้านค้าปลีก และจำนวนเกินของผลิตภัณฑ์  $p$  ที่ถูกจัดส่งถึงร้านค้าปลีก

Z.H. Che and C.J. Chiang(2010) ได้ประยุกต์ใช้ Modified Pareto genetic algorithm (mPaGA) เพื่อแก้ปัญหาการวางแผนโซ่อุปทานผลิตตามสั่ง (build-to-order supply chain: BOSCO) ซึ่งเป็นการวางแผนเกี่ยวกับการเลือกผู้จัดหา (Supplier selection) การประกอบผลิตภัณฑ์ (product assembly) และการกระจายสินค้า โดยประเมินผล 3 ด้านคือ ต้นทุน (costs) เวลาการขนส่ง (delivery time) และคุณภาพ (Quality) เปรียบเทียบกับวิธี traditional PaGA (tPaGA) ปรากฏว่าวิธี mPaGA ให้ผลเฉลยที่ดีกว่าวิธี tPaGA

### 6.3 วิธีการวิวัฒนาการโดยส่วนต่าง Differential evolution (DE)

วิธีการวิวัฒนาการโดยส่วนต่าง (DE) เป็นหนึ่งในวิวัฒนาการแบบอัลกอริทึม (EAs) ในการเพิ่มประสิทธิภาพในการหาพื้นที่ทั่วโลกอย่างต่อเนื่อง (Storn and Price, 1997) กรอบทฤษฎีของมันเป็นรูปแบบง่าย ๆ และใช้เวลาน้อยในการคำนวณหาระยะเวลาการใช้งานของหน่วยประเมินผลกลาง (CPU) (Bin and et al., 2008) เนื่องจากข้อได้เปรียบของความสัมพันธ์ของตัวแปรควบคุมนั้นค่อนข้างน้อย แต่การทำงานก็ยังมีประสิทธิภาพดีอยู่ การวิวัฒนาการถูกประยุกต์ใช้อย่างแพร่หลายและมีการแสดงจุดแข็งในหลายพื้นที่ที่มีการประยุกต์ใช้ (Godfrey and Donald 2006; Quan and et al. 2007; Qian and et al., 2008)

ในวิธีการค้นหาที่ยึดตามหลักประชากร การวิวัฒนาการจะเริ่มสุ่มประชากรเริ่มต้นในขนาด  $N$  ของเวกเตอร์มิติ  $D$  การแก้ไขปัญหาวิวัฒนาการอัลกอริทึมจะไปแทนที่มิติของเวกเตอร์  $D$  ซึ่งค่าของตัวแปรแต่ละตัวในพื้นที่ของมิติจะถูกแสดงเป็นเลขในระบบจำนวนจริง เบื้องหลังใจความสำคัญของการวิวัฒนาการนี้ คือ กลไกใหม่สำหรับการสร้างเวกเตอร์ของการทดลองการวิวัฒนาการจะสร้างเวกเตอร์การทดลองโดยการเปลี่ยนแปลงและมองข้ามหลักการดำเนินงาน จากนั้นทดแทนการดำเนินงานเฉพาะรายบุคคลที่เราเรียกว่า

การดำเนินการคัดเลือก ที่เกิดขึ้นเมื่อเวกเตอร์การทดลองนี้มีประสิทธิภาพมากกว่าเวกเตอร์ที่สอดคล้องกัน กระบวนการเหล่านี้จะถูกดำเนินการอีกครั้งจนกว่าจะมีเกณฑ์ที่ยังให้มีการหยุด ทั้งนี้การวิวัฒนาการของ ประชากรก็就会被ดำเนินการโดยผ่านวิธีการทำซ้ำของ 3 ขั้นตอนหลักซึ่งก็คือ การกลายพันธุ์ ขั้นตอนทาง พันธุกรรมแบบครอสโอเวอร์ และการคัดเลือกด้วยโดย Price, Storn and Lampinen (2005) ได้สรุปการแบ่ง ลำดับขั้นตอนที่สำคัญของการวิวัฒนาการแบบคลาสสิกไว้ดังนี้

### 6.3.1 Initial population

คือขั้นตอนการสุ่มเลือกจำนวนประชากรตั้งต้นภายใต้ขอบเขต ข้อจำกัด จำนวนหนึ่งซึ่งสามารถ กำหนดได้ หรือค่า NP: Number of population เป็น ตัวแปรตัดสินใจ เพื่อนำมาคำนวณหาค่าคำตอบ CostValue, Fitness Value หรือ Function Value ในความหมายเดียวกัน

### 6.3.2 Mutation

คือขั้นตอนการคูณตัวแปรตัดสินใจด้วยปัจจัยตัวคูณเรียกว่า Weighting Factor: F หรือเรียกว่า Mutation Factor: F อีกชื่อหนึ่งเช่นกันเพื่อจุดประสงค์ของการผ่าเหล่ากลายพันธุ์ให้ได้คำตอบใหม่ที่แปลก แตกต่างไปจากกลุ่มจำนวนประชากรในข้อแรกมีขั้นตอนย่อยดังนี้

6.3.2.1 ทำการกำหนด Target Vector ( $X_{i,G}$ ) โดยที่  $i = 1, 2, 3, \dots, NP$

6.3.2.2 สุ่มเลือกจำนวน 2 Vector ( $X_{r2,G}, X_{r3,G}$ ) จากประชากรตั้งต้นที่ไม่ซ้ำกับ Target Vector

6.3.2.3 ทำการคำนวณหา Mutant Vector ( $V_{i,G+1}$ ) จากความสัมพันธ์

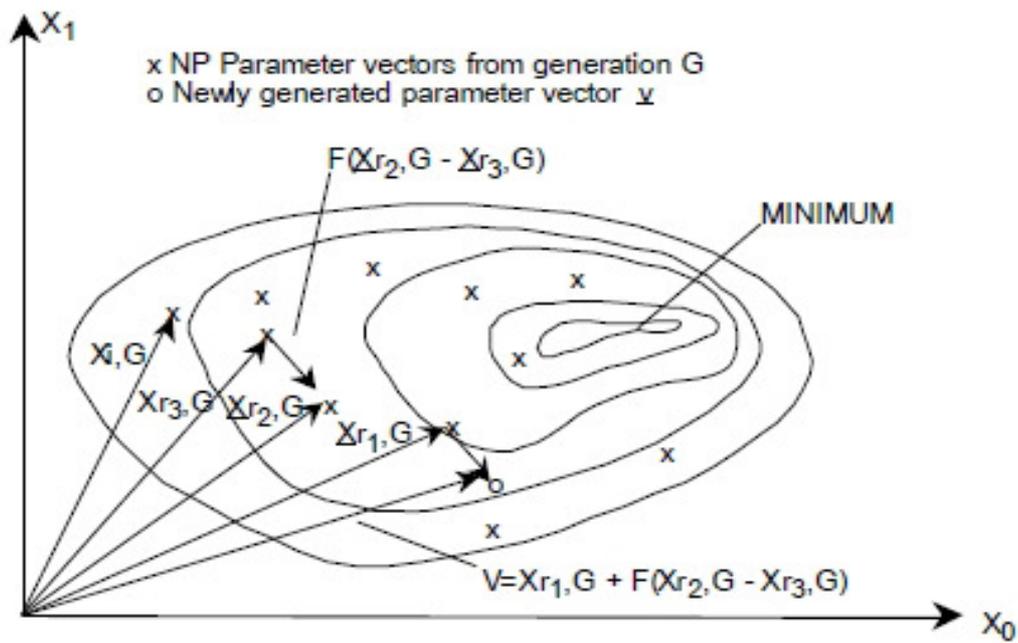
$$V_{i,G+1} = X_{r1,G} + F(X_{r2,G} - X_{r3,G}) \quad (6.2)$$

เมื่อ  $V_{i,G+1}$  = Mutant Vector

$X_{r1,G}$  = Target Vector

$X_{r2,G}, X_{r3,G}$  = Random Vector

F = Weighting Factor



ภาพที่ 6.1 การค้นหา Mutant Vector ของฟังก์ชัน 2 ตัวแปร  
ที่มา: Storn and Price (1997)

### 6.3.3 Crossover หรือ Recombination

คือขั้นตอนการผสมสายพันธุ์ซึ่งจะได้สายพันธุ์ใหม่ของคำตอบที่ดีกว่าและแยกกว่าออกมาอย่างหลากหลายเพื่อค้นหาสายพันธุ์จากตัวแปรตัดสินใจใหม่ๆโดยมีการสร้าง Trial Vector ( $U_{i,G+1}$ ) ดังแสดงในสมการที่ (6.3) เพื่อใช้ในการเปรียบเทียบและพิจารณาในการผสมสายพันธุ์ดังสมการ (6.4) ตัวอย่างการ Crossover สามารถแสดงได้ดังภาพที่ 6.2

$$U_{j,G+1} = (U_{1i,G+1}, U_{2i,G+1}, \dots, U_{Di,G+1}) \quad (6.3)$$

$$\begin{aligned} V_{j,G+1} & \text{ if } (\text{randb}(j) \leq CR) \text{ or } j = \text{rnbr}(i) \\ X_{j,G+1} & \text{ if } (\text{randb}(j) > CR) \text{ or } j \neq \text{rnbr}(i) \end{aligned} \quad (6.4)$$

เมื่อ

$U_{j,G+1}$  = Trial Vector

$V_{j,G+1}$  = Mutant Vector

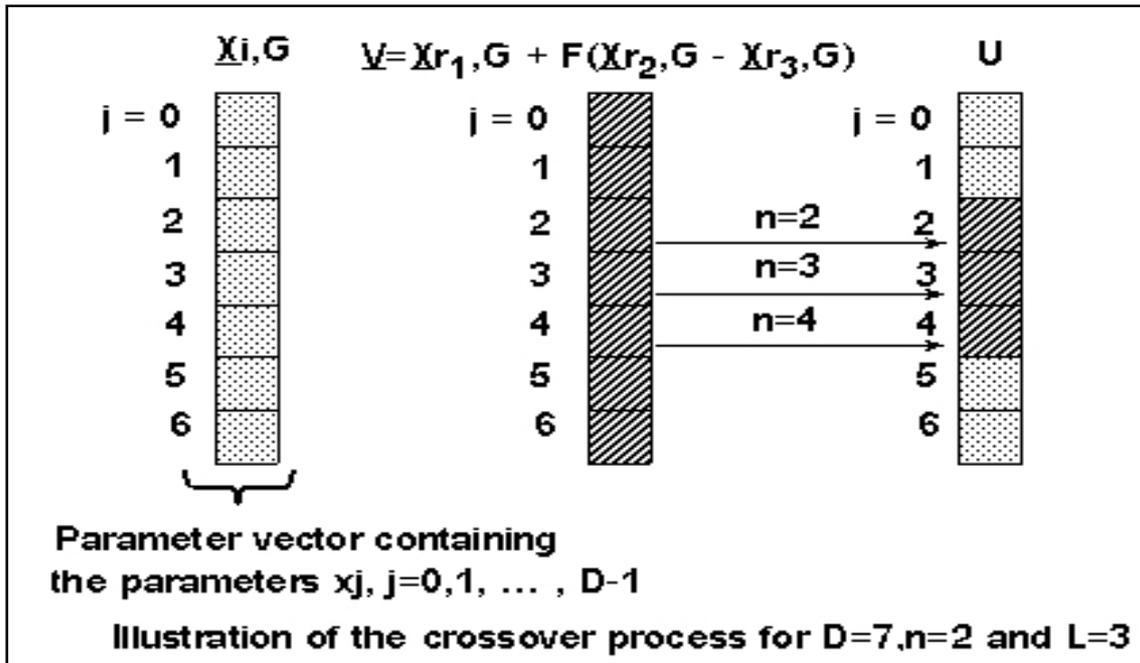
$X_{j,G+1}$  = Target Vector

$\text{randb}(j)$  = การสุ่มจำนวนจริงมีค่า 0 ถึง 1 ครั้งที่ j

CR = Crossover Constant จำนวนจริงมีค่า 0 ถึง 1

$\text{rnbr}(i)$  = Index จากการสุ่มเลือกจำนวนเต็ม 1,2, ... ,D และ

$j = 1,2, \dots, D$



ภาพที่ 6.2 การ Crossover ของ Target Vector และ Mutant Vector ที่มีค่า D=7

ที่มา: Storn and Price (1997)

### 6.3.4 การประยุกต์กระบวนการ Recombination

เพื่อแก้ปัญหาในงานวิจัยในขั้นตอนนี้ทางผู้วิจัยได้พัฒนาโปรแกรม Differential Evolution (DE) เข้าสู่กระบวนการ Recombination เพื่อหาค่า Trial Vector โดยการปรับเปลี่ยนกระบวนการ Recombination ซึ่งเป็นขั้นตอนการผสมสายพันธุ์อันจะได้ทั้งสายพันธุ์ใหม่ของคำตอบที่ดีกว่าและแยกว่า ออกมาอย่างหลากหลายเพื่อหาสายพันธุ์จากตัวแปรตัดสินใจใหม่ๆโดยกระบวนการ Recombination จะมีวิธีการประยุกต์กระบวนการด้วยกัน 3 วิธี คือ 1) Vector transition process, 2) Vector exchange process , 3) Vector insertion process(ระพีพันธ์ ปิตาคะโส, 2557)

#### 6.3.4.1 วิธี Vector transition process

กระบวนการ Vector transition process จะเป็นการสุ่มตัวเลขสมมุติขึ้นมา แล้วนำตัวเลขที่ทำการสุ่มไปแทนในตำแหน่งที่ต้องการ ดังตัวอย่างภาพที่ 6.3 ได้ทำการสุ่มตัวเลขสมมุติมา 3 ค่า โดยค่าที่สุ่มจะอยู่ระหว่าง 0-1 จากนั้นนำค่าที่สุ่มได้มาแทนตำแหน่งที่ 1, 2 และ 3

Original vector

1	2	3	4	5	6	7	8
0.92	0.08	0.65	0.05	0.99	0.02	0.68	0.44

Accompany vector

1	2	3	4	5	6	7	8
0.45	0.15	0.65	0.05	0.73	0.02	0.68	0.44

ภาพที่ 6.3 ตัวอย่างของ Vector transition process

#### 6.3.4.2 วิธี Vector exchange process

กระบวนการ Vector exchange process จะเป็นการสลับตำแหน่งของเวกเตอร์ เพื่อรวมวนค่า ดังตัวอย่างภาพที่ 6.4 ได้ทำการสลับค่า 0.08 ที่อยู่ตำแหน่งที่ 2 ไปไว้ที่ตำแหน่งที่ 6 แล้วนำค่าตำแหน่งที่ 6 มาไว้ตำแหน่งที่ 2

Original vector

1	2	3	4	5	6	7	8
0.92	0.08	0.65	0.05	0.99	0.02	0.68	0.44

Accompany vector

1	2	3	4	5	6	7	8
0.92	0.02	0.65	0.05	0.99	0.08	0.68	0.44

ภาพที่ 6.4 ตัวอย่างของ Vector exchange process

#### 6.3.4.3 วิธี Vector insertion process

กระบวนการ Vector insertion process จะเป็นการเคลื่อนย้ายตำแหน่ง เพื่อนำมาแทรกไว้ก่อนหน้าในตำแหน่งที่ต้องการ ดังตัวอย่างภาพที่ 6.5 จะเป็นการย้ายค่าจากตำแหน่งที่ 6 มาแทรกตำแหน่งที่ 3 ตำแหน่งที่ 3, 4, 5 เดิมจะถูกขยับเปลี่ยนตำแหน่งเป็น 4, 5, 6 แทน

Original vector

1	2	3	4	5	6	7	8
0.92	0.08	0.65	0.05	0.99	0.02	0.68	0.44

Accompany vector

1	2	3	4	5	6	7	8
0.92	0.08	0.02	0.65	0.05	0.99	0.68	0.44

ภาพที่ 6.5 ตัวอย่างของ Vector insertion process

6.3.5 Selection

คือขั้นตอนการคัดเลือกประชากรในรุ่นต่อไป (G+1) โดยคัดเลือกเอาแต่เฉพาะคำตอบที่ดีกว่าโดยการเปรียบเทียบ Function Value หรือ Cost Value ของ Trial Vector กับ Target Vector ในกรณีที่ค่า Function Value ของ Trial Vector ดีกว่า Target Vector จะถูกแทนที่ด้วย Trial Vector ในรุ่นต่อไปดังสมการที่ (6.5)

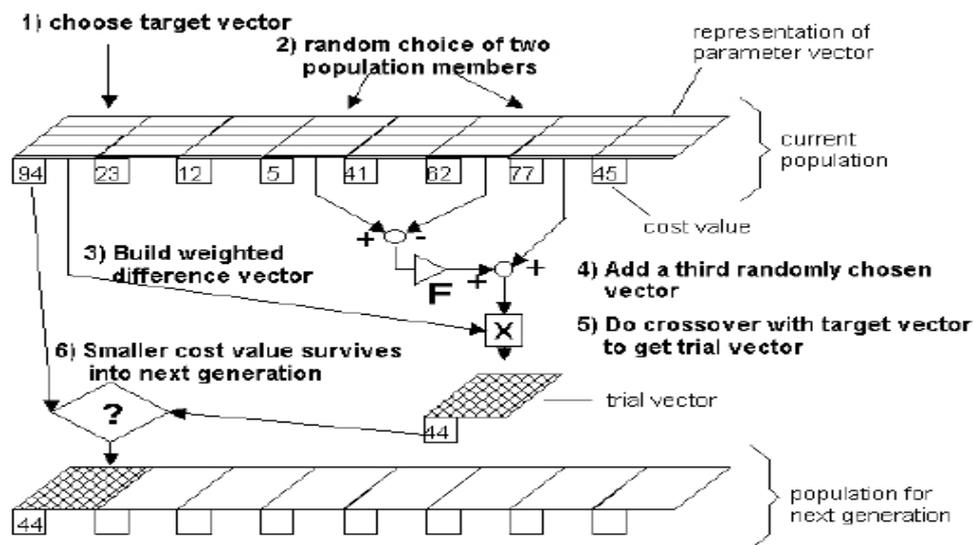
$$X_{i,G+1} = \begin{cases} U_{i,G+1} & \text{if } f(U_{i,G+1}) \leq f(X_{i,G}) \\ X_{i,G} & \text{Otherwise} \end{cases} \quad i = 1, 2, \dots, n \quad (6.5)$$

6.3.6 Evaluation & Re-Generation

ดำเนินการซ้ำจากข้อ 6.3.2 ถึงข้อ 6.3.4 โดยเปลี่ยน Target Vector จนถึง  $i = NP$

6.3.7 Reach Convergence Tolerance

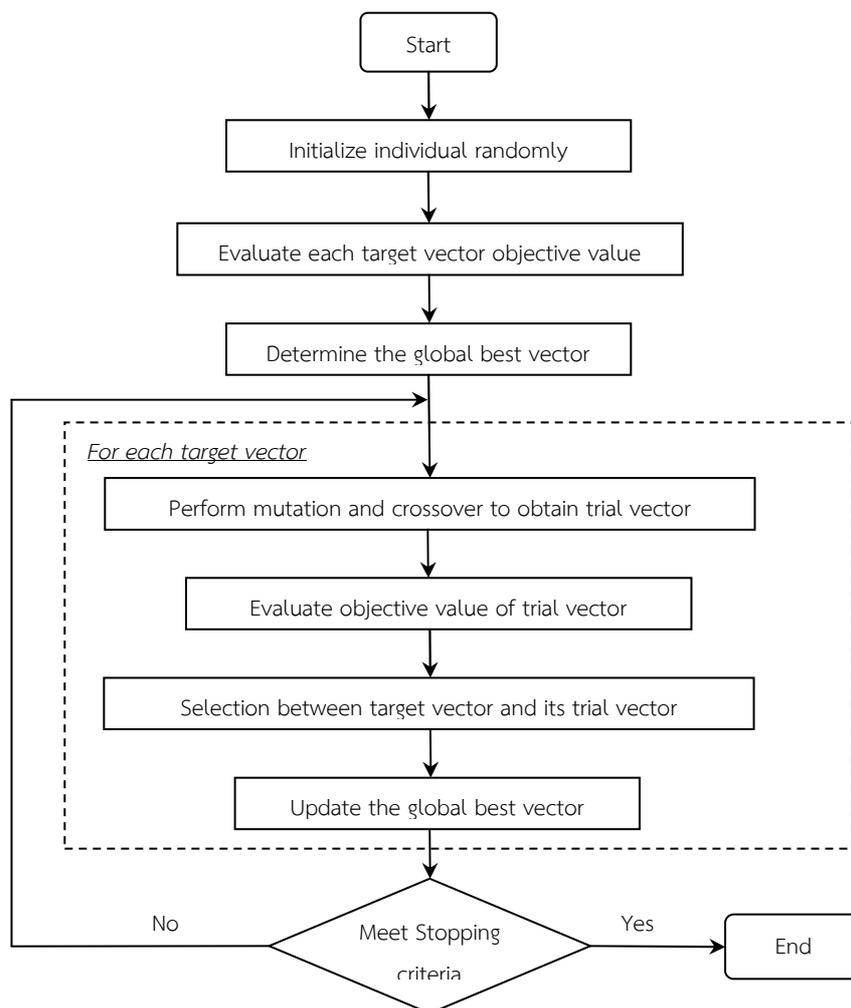
นำ Target Vector ที่ได้จากข้อ 6.3.4 มาทำซ้ำขั้นตอนทั้งหมดจนครบตามความต้องการโดยแสดงในภาพที่ 6.6



ภาพที่ 6.6 กระบวนการหาค่าความเหมาะสมโดยวิธี Differential Evolution จากขั้นที่ 1 ถึง 4

ที่มา: Storn and Price(1997)

มีข้อสังเกตว่าการคัดเลือกนี้สามารถใช้สำหรับการลดปัญหาที่เกิดขึ้น เมื่อประชากรในปัจจุบันนี้มีการปรับปรุง ประชากรก็ยังคงมีวิวัฒนาการไปเรื่อยๆ โดยผ่านการกลายพันธุ์ การผสมผสานลักษณะทางพันธุกรรมแบบครอสโอเวอร์ และการดำเนินการในการคัดเลือกจนกระทั่งมีเกณฑ์มาหยุด การวิวัฒนาการนี้โดยทั่วไปแล้วมันคือ การวิวัฒนาการ/rand/1/bin ซึ่งเหล่านี้เป็นที่มาของคำว่าวิวัฒนาการที่แตกต่างกัน rand คือชนิดของเวกเตอร์ฐานที่เลือกไว้ 1 คือ ตัวเลขของเวกเตอร์ความแตกต่างสำหรับการเปลี่ยนแปลง และ bin คือตัวย่อของการขยายพันธุ์แบบสองจำนวนของจำนวนค่ามิติในการสืบทอดของเวกเตอร์กลายพันธุ์



ภาพที่ 6.7 รูปแบบกระบวนการในการพัฒนาฮิวริสติกส์โดยใช้การหาค่าตอบเฉพาะแบบกระบวนการ Differential evolution (DE)  
ที่มา: Storn and Price (1997)

งานวิจัยที่เกี่ยวกับ DE ได้แก่ Lopez Cruz and et al. (2003) ที่นำเสนอประสิทธิภาพของ DE กรณีที่มีปัญหาการควบคุมที่เหมาะสมหลายรูปแบบ โดยได้อธิบายว่ามีวิธีการมากมายในการแก้ปัญหาการควบคุมที่เหมาะสมไม่ว่าจะโดยตรงหรือโดยอ้อม อาศัยข้อมูลไต่ระดับ ก็อาจมีโอกาที่จะเข้าหาพื้นที่ที่เหมาะสม วิธีการเพิ่มประสิทธิภาพที่นิยมเช่น Evolutionary Algorithms (EA) จากการศึกษาพบว่า ผลของการใช้ วิธี Evolutionary Algorithms (EA) วิธี Differential Evolution Algorithms (DEA) และวิธี Genetic algorithm (GA) DE จะมีความโดดเด่นในแง่ของประสิทธิภาพเมื่อเทียบกับ GA และมีค่าที่ต่างจากวิธี EA อาจเป็นเพราะว่า พารามิเตอร์ใน DE โดยมีพารามิเตอร์คือ ขนาดของประชากรครอสโอเวอร์ครั้งที่ และแปรผันค่าสัมประสิทธิ์ ซึ่งการเลือก ขนาดของประชากร มีบทบาทสำคัญในการแก้ปัญหาการควบคุมที่เหมาะสม การเลือกขนาดของประชากรที่มีขนาดเล็ก เปรียบเสมือนโอกาสที่จะได้ค่าของคำตอบ Global Solution จะมีโอกาสน้อยตาม แต่ถ้าหากเพิ่มขนาดประชากรก็เหมือนการเพิ่มโอกาสที่ได้ Global Solution ซึ่งถ้าเปรียบเทียบระยะเวลาคำนวณ อัลกอริทึมที่มีประสิทธิภาพที่ดีด้านเวลาก็คือ DE นั่นเอง

Dervis and Selcuk (2004) ได้อธิบายว่า Differential Evolution Algorithms (DEA) เป็นหนึ่งในวิธีการ Evolutionary Algorithms (EA) ซึ่งเป็นหนึ่งในขั้นตอนวิธีการวิวัฒนาการที่เป็นเทคนิคใหม่ในการเพิ่มประสิทธิภาพ ความสามารถในการจัดการที่เป็นลักษณะของปัญหา Non-Differentiable, Non-Linear และ Multimodal Objective Functions เนื่องจาก DE ต้องใช้เวลาในการทำงานเมื่อมีขนาดของปัญหาขนาดใหญ่ที่ซับซ้อน เพื่อเป็นการเพิ่มประสิทธิภาพในการค้นหาค่าของฟังก์ชันวัตถุประสงค์เป้าหมาย ในการศึกษาแบบจำลองของ De Jong ก็พบว่าความเร็วในการบรรจบกันของ DE มีนัยสำคัญที่ ดีกว่า อัลกอริทึมพันธุกรรม (GA) ดังนั้นอัลกอริทึม DE น่าจะเป็นวิธีการที่มีแนวโน้มในการแก้ปัญหาและช่วยเพิ่มประสิทธิภาพทางด้านวิศวกรรม ซึ่งทำให้ Liu and Lampinen (2005) ได้ทำการปรับปรุงวิธี DE โดยการปรับค่าฟัซซี่ Fuzzy Adaptive Differential Evolution Algorithm (FADE) ซึ่งทำการปรับค่า Weighing factor (F) และ Crossover rate (CR) วิธีการนี้จะปรับตัวแปรควบคุมการกลายพันธุ์และ ครอสโอเวอร์พารามิเตอร์การควบคุม การใช้ตรรกะวิธีการควบคุมฟัซซี่ พารามิเตอร์ของ FADE ตอบสนองต่อข้อมูลประชากรของคือ เวกเตอร์พารามิเตอร์ฟังก์ชันซึ่งช่วยให้ DE หาคำตอบได้เร็วขึ้นค่า F และ CR ที่ปรับใหม่สามารถให้คำตอบที่ดีกว่า DE แบบเดิม เช่นเดียวกับ Omran (2005) ที่ทำการปรับเปลี่ยนค่า F ในสูตรการกลายพันธุ์ของ DE ในการทดสอบกับกรณีศึกษา

Qin and Suganthan (2005) ใช้วิธีที่เรียกว่า SADE ทำการปรับปรุงปัจจัยควบคุม F และ CR ไม่จำเป็นต้องกำหนดไว้ล่วงหน้า ในระหว่างการพัฒนาการพารามิเตอร์ที่จะค่อยๆปรับตัวเองตามประสบการณ์การเรียนรู้ ประสิทธิภาพการทำงานโดยใช้วิธีทางฮิวริสติกที่ชื่อว่า Safe Adaptive Differential Evolution (SADE) มีรายงานเกี่ยวกับชุดของฟังก์ชัน 25 มาตราฐาน ในกรณีของ CEC2005 โดยใช้ค่าพารามิเตอร์จริง

Chakraborty, Das and Konar (2006) นำเสนอวิธีการใหม่ในการกลายพันธุ์ของ DE โดยหาการจำลองรูปแบบของ DE สองแบบ เพื่อทดสอบการกลายพันธุ์ของ 3 ปัจจัย การนำเสนอนี้จะถูกแสดงให้เห็นว่า

นัยสำคัญทางสถิติที่ดีขึ้นกว่า 3 ปัจจัย สายพันธุ์ที่นิยมใน DE โดยใช้ฟังก์ชันการทดสอบเพื่อหาประสิทธิภาพ ประสิทธิภาพเช่น วิธีการแก้ปัญหาที่มีคุณภาพ เวลาที่แก้ปัญหา ความถี่ในการแก้ปัญหา และขนาดของการแก้ปัญหา

Kaelo and Ali (2006) ใช้ตัวเลขชุดปัญหาทั้งหมด 50 ชุดในการทดสอบการกลายพันธุ์ของ DE แบบเดิม และแบบใหม่ที่พัฒนาขึ้นพบว่า วิธีใหม่สามารถให้คำตอบที่ดีถึง 20 ชุดปัญหาจากการเปรียบเทียบในส่วนก่อนหน้านั้นค่อนข้างชัดเจนว่าขั้นตอนวิธีการใหม่ที่ดีกว่า DE แบบเดิม

Yang, He and Yao (2008a) ใช้วิธีการที่เรียกว่า การค้นหาพื้นที่ใกล้เคียง (NSDE) จะเสนอขึ้นอยู่กั ลักษณะทั่วไปของกลยุทธ์การ NS ข้อดีของกลยุทธ์ NS ใน DE มุ่งเน้นไปที่การเปลี่ยนแปลงของขนาดขั้นตอนการค้นหาและความหลากหลายของประชากรหลังจากที่ใช้ค้นหาพื้นที่ใกล้เคียง ผลการทดลองแสดงให้เห็นว่า NSDE สามารถค้นหาคำตอบในพื้นที่คำตอบ มีค่าที่ใกล้เคียงกับคำตอบที่ดีที่สุด มากกว่าอัลกอริทึมอื่น ๆ ซึ่งเกี่ยวข้องกับความหลากหลายของฟังก์ชันของ NSDE มาตรฐานที่แตกต่างกัน ขยายขีดความสามารถของ NSDE โดยนำไปทดสอบกับจำนวนของปัญหามาตรฐานซึ่งมีมิติช่วง 50-200

Shaheen and et al. (2009) ได้ทำการนำเสนอวิธีการใหม่บนเงื่อนไขของวิธีการของ DE เพื่อหาตำแหน่งที่เหมาะสมและการตั้งค่าของพารามิเตอร์ของตัวควบคุมการไหล (UPFC) สำหรับการเพิ่มประสิทธิภาพของความปลอดภัยภายใต้กรณีมีเส้นเกิดเหตุฉุกเฉิน โดยเริ่มจากการวิเคราะห์เรื่องฉุกเฉินและการจัดอันดับกระบวนการที่อาจเกิดเหตุฉุกเฉินเพื่อกำหนดเส้นฉุกเฉินในระบบโดยพิจารณาเรื่องของการรับภาระโหลดเกินที่เส้นเหล่านั้นรับได้ ต่อมานำหลักการของ DE มาประยุกต์เพื่อหาตำแหน่งและการตั้งค่าพารามิเตอร์ โดยการจำลองกับระบบกำลัง IEEE 14-bus และ IEEE 30-bus พบว่าวิธีการที่นำมาแก้ปัญหาโดยใช้ DE สามารถให้คำตอบที่เหมาะสม ตำแหน่งที่จะเกิดการรับภาระโหลดเกิน และการไหลของไฟฟ้าต่ำสุดได้เมื่อนำมาทดสอบอย่างมีนัยสำคัญ

Dexuan and et al. (2011) ได้ทำการพัฒนาวิธีการ DE สำหรับการแก้ปัญหาการมอบหมายงานโดยได้ทำการปรับปรุง 2 ส่วนที่สำคัญของพารามิเตอร์ในขั้นตอนของ DE คือ Weighting Factor (F) และค่าของ Crossover Rate (CR) โดยใช้วิธีที่เรียกว่า Improve Differential Evolution (IDE) โดยให้ค่าของ F สามารถปรับค่าได้และค่าของ CR มีการเปลี่ยนค่าเป็นลักษณะเป็นขั้นๆ โดยได้เอาตัวอย่างของปัญหาเปรียบเทียบคำตอบกับวิธี DE สองวิธีได้แก่ ODE และ JADE ผลปรากฏว่า IDE ที่พัฒนาขึ้นให้คำตอบดีกว่าทั้งสองวิธี ไม่ว่าจะ เป็นลักษณะการลดต้นทุนและประสิทธิภาพที่เพิ่มขึ้นในระบบ

Jazebi and et al. (2011) ได้ทำการเปรียบเทียบวิธีการระหว่าง Differential Evolution Algorithm (DEA) กับ Particle Swarm Optimization (PSO) เพื่อแก้ปัญหาการจัดสรร การชดเชยการกระจายของไฟฟ้าสถิต (DSTATCOM) ในเครือข่ายการกระจายเมื่อมีการพิจารณาปรับโครงสร้างผลพบว่า DE ช่วยแก้ปัญหาการปรับโครงสร้างเครือข่ายของระบบการจัดจำหน่าย ในกรณีอื่น ๆ ได้การกระจายตัวของอุปกรณ์ FACTS ในการกระจายเครือข่ายระบบที่มีความยืดหยุ่นในการส่งการกระจายกระแสแบบสลับ AC (DFACTS) และ DSTATCOM วิธีการนี้ได้สามารถหาขนาดที่เหมาะสมและที่ตั้ง

ของ DSTATCOM และยังลดการสูญเสียการกระจายของเครือข่ายและแรงดัน จากข้อมูลการทดสอบสามารถสรุปได้ว่า วิธีการใช้ DSTATCOM และการปรับโครงสร้างเพื่อลดความสูญเสียของระบบและปรับปรุงรายละเอียดของแรงดันได้เป็นที่น่าพอใจ อีกทั้ง DE ยังถูกนำไปทดสอบในการศึกษาเครือข่ายการกระจายที่มีประสิทธิภาพสูงในการค้นหา คำนวณการจัดสรร DSTATCOM ในเครือข่ายการกระจายการพิจารณาปรับโครงสร้างซึ่งผลปรากฏว่าวิธี DE ให้ผลเป็นที่น่าพอใจเมื่อเทียบกับ PSO

Xianhui and et al. (2012) ได้นำเสนอวิธี PUDDE หรือ วิธีพาเรโตวิวัฒนาการแบบไม่ต่อเนื่อง ในการจัดการกับปัญหาการจัดสรรผู้ปฏิบัติงานที่เรียกว่าปัญหา Operator Allocation Problems (OAP) เพื่อการจัดสรรงานที่เหมาะสมกับการควบคุมความสมดุลของสายการประกอบเมื่อมีการสร้างฟังก์ชันเป้าหมายหลายวัตถุประสงค์และเงื่อนไข และไม่สามารถตัดสินใจได้ในวัตถุประสงค์เดียวได้ มีขั้นตอนคือใช้ วิธี DES Model ในการจำลองสถานการณ์ทั่วไปและใช้ PUDDE ในการแก้ปัญหา OAP โดยการปรับปรุงผู้ปฏิบัติงานมีสองแบบคือ ลดจำนวนหรือเพิ่มจำนวน ผลการทดลองสรุปได้ว่าวิธีการ PUDDE สามารถหาคำตอบได้อย่างมีประสิทธิภาพต่ออย่างไรก็ตามวิธีการนี้เหมาะกับการจัดสรรลดจำนวนผู้ปฏิบัติงาน หากเปรียบเทียบกับวิธีการ DE แบบเดิมแล้ว วิธีการ PUDDE จะมีประสิทธิภาพที่ดีกว่าในกรณีการหาวัตถุประสงค์ที่มีการผสมผสานของสายงานการประกอบในปัญหาเดียวกัน

## ตารางที่ 6.2 การประยุกต์ใช้ Differential Evolution (DE) เพื่อแก้ปัญหาทางวิศวกรรม

ปัญหา	นักวิจัย	วิธีการ
Optimal Problem	Emanuel Melachrinoudis (1995)	DE
	Storn and Price (1997)	DE
	Abbass (2002)	Proposed a novel self-adaptive DE scheme
	Lopez Cruz and et al. (2003)	Evolutionary Algorithms(EA), Differential Evolution Algorithms(DEA) and Genetic algorithm(GA)
	Dervis and Selcuk (2004)	Differential Evolution Algorithms(DEA)
	Bergey and Ragsdale (2005)	MDE
	Das (2005)	Proposed two modification of the classic
	Liu and Lampinen (2005)	Fuzzy Adaptive Differential Evolution Algorithm (FADE)
	Omran (2005)	Where the value of F is changed during the search. In DE
	Qin and Suganthan (2005)	Provided the first effort to adopt two different mutation schemes in a single DE variant, called SaDE.
	Chakraborty, Das and Konar (2006)	Proposed a new DE mutation scheme combining local mutation operation and global mutation operation in order to improve a specific DE scheme.

ตารางที่ 6.2 การประยุกต์ใช้ Differential Evolution (DE) เพื่อแก้ปัญหาทางวิศวกรรม (ต่อ)

ปัญหา	นักวิจัย	วิธีการ
Optimal Problem	Kaelo and Ali (2006)	Modification on the classical DE in generating mutant vectors.
	Rakesh Angira (2006)	MINLP, MDE และ M-SIMPISA
	Bilal Alatas, Erhan Akin and Ali Karci (2008)	MODENAR
	Weiyi Qian and et al. (2008)	ADEA
	Yang, He and Yao (2008a)	NSDE
	Yang (2008b)	By forming a new DE scheme, called self-adaptive DE with neighborhood search, SaNSDE.
	Shaheen and et al. (2009)	DE
	L.H.Wu (2010)	MINLP, MDE และ M-SIMPISA
	E.Zio (2011)	MODE
	Husam I. Shaheen (2011)	SADE
	Dexuan and et al. (2011)	ODE and JADE
	Jazebi and et al. (2011)	Differential Evolution Algorithm (DEA) and Particle Swarm Optimization (PSO)
Xianhui Zeng and et al. (2012)	PUDDE	

จากการทบทวน งานวิจัยที่เกี่ยวข้องกับวิธี DE เพื่อแก้ปัญหาทางวิศวกรรมจะเห็นว่าวิธีการหาคำตอบของ DE สามารถให้ค่าของคำตอบที่เหมาะสมและมีระยะเวลาในการหาคำตอบที่เร็วกว่าวิธีการหาคำตอบอื่นๆ และมีขั้นตอนการหาคำตอบที่ไม่ซับซ้อน ดังนั้นในงานวิจัยในครั้งนี้นักวิจัยจึงเลือกและนำหลักการหาคำตอบของวิธี DE มาประยุกต์ใช้ในการหาคำตอบของงานวิจัยการแก้ปัญหาในระบบโลจิสติกส์และโซ่อุปทานข้าว : กรณีศึกษาจังหวัดอุบลราชธานี