

วารสารวิศวกรรมศาสตร์

การพยากรณ์ด้วยวิธีการพยากรณ์เชิงสาเหตุ

นันทชัย กานตานันทะ*

ภาควิชาวิศวกรรมอุตสาหการ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเกษตรศาสตร์ กรุงเทพมหานคร ประเทศไทย 10900

อีเมล: nantachai.k@ku.ac.th*

บทคัดย่อ บทความนี้มีวัตถุประสงค์เพื่ออธิบายถึงหลักการทำงานของวิธีการพยากรณ์เชิงสาเหตุซึ่งศึกษาความสัมพันธ์ในเชิงความเป็นเหตุและผลระหว่างตัวแปร โดยวิธีที่บทความนี้รวบรวมมาได้แก่ การวิเคราะห์การถดถอยเชิงเส้น โครงข่ายประสาทเทียม พืชซีลोजิก ระบบนิวโรฟัซซี ระบบผสมของขั้นตอนวิธีทางพันธุกรรมและการวิเคราะห์การถดถอยเชิงเส้น ระบบผสมของขั้นตอนวิธีทางพันธุกรรมและโครงข่ายประสาทเทียม ระบบผสมของขั้นตอนวิธีทางพันธุกรรมและพืชซีลोजิก และระบบผสมขั้นตอนวิธีทางพันธุกรรมร่วมกับโครงข่ายประสาทเทียมและพืชซีลोजิก นอกจากนี้ยังได้สรุปจุดเด่นและจุดด้อย รวมถึงตัวอย่างการนำไปใช้แต่ละวิธี และเปรียบเทียบประสิทธิภาพในการพยากรณ์ของวิธีดังกล่าวจากงานวิจัยที่เกี่ยวข้อง

คำสืบค้น: การพยากรณ์, การวิเคราะห์การถดถอย, โครงข่ายประสาทเทียม, พืชซีลोजิก, ระบบผสม

วารสารวิศวกรรมศาสตร์ (ISSN: 1906-3636) ปีที่ 4 ฉบับที่ 1

วันที่ส่ง 3 สิงหาคม 2555

วันที่ตอบรับ 8 ตุลาคม 2555

วันที่ตีพิมพ์ 20 พฤศจิกายน 2555

Online at <http://www.ej.eng.chula.ac.th/>

DOI:10.4186/ejth.2012.4.1.33

Forecasting by Causal Methods

Nantachai Kantanantha*

Department of Industrial Engineering, Faculty of Engineering, Kasetsart University, Bangkok 10900, Thailand

E-mail: nantachai.k@ku.ac.th*

Abstract. This article aims to explain the principles of the causal methods which study the cause-and-effect relationships between the variables. The methods gathered in this article include linear regression analysis, artificial neural networks, fuzzy logic, neuro-fuzzy system, genetic algorithm-linear regression analysis hybrid system, genetic algorithm-artificial neural networks hybrid system, genetic algorithm-fuzzy logic hybrid system, and genetic algorithm-artificial neural networks-fuzzy logic hybrid system. In addition, the strengths and weaknesses of each method are summarized along with the examples of their applications. The forecasting efficiency of these methods is compared from the relevant researches.

Keywords: Forecasting, regression analysis, artificial neural networks, fuzzy logic, hybrid system.

Engineering Journal (ISSN: 1906-3636) Volume 4 Issue 1

Received 3 August 2012

Accepted 8 October 2012

Published 20 November 2012

Online at <http://www.ej.eng.chula.ac.th/>

DOI:10.4186/ejth.2012.4.1.33

1. บทนำ

การพยากรณ์เป็นการคาดการณ์ถึงสิ่งที่จะเกิดขึ้นในอนาคตและนำค่าที่พยากรณ์ได้มาใช้ประโยชน์ในการวางแผนและการตัดสินใจ ปัจจุบันการพยากรณ์ถูกนำไปใช้ในด้านต่างๆอย่างแพร่หลาย เช่น การพยากรณ์ยอดขาย การพยากรณ์ราคาของผลผลิตทางการเกษตร การพยากรณ์อากาศ เป็นต้น ในอดีตนั้น การพยากรณ์มักใช้การคาดเดาหรือประสบการณ์ แต่ในปัจจุบันได้มีองค์ความรู้ใหม่ๆที่พัฒนาขึ้นทำให้การพยากรณ์มีความแม่นยำมากขึ้นและสามารถรองรับความซับซ้อนของปัจจัยที่มีผลต่อค่าพยากรณ์ได้มากขึ้น บทความนี้ได้รวบรวมวิธีการพยากรณ์เชิงสาเหตุที่เป็นที่นิยม รวมถึงวิธีการใหม่ที่ได้รับการพัฒนาขึ้น โดยอธิบายถึงหลักการทํางาน รวมถึงข้อเด่นและข้อด้อยของแต่ละวิธี และยกตัวอย่างงานวิจัยที่เปรียบเทียบประสิทธิภาพในการพยากรณ์ของวิธีเหล่านี้

2. เทคนิคการพยากรณ์

เทคนิคที่ใช้ในการพยากรณ์สามารถจำแนกได้เป็น 2 ประเภทได้แก่

1. เทคนิคการพยากรณ์เชิงคุณภาพ (Qualitative Forecasting Techniques) เป็นเทคนิคที่ใช้ดุลพินิจและขึ้นกับประสบการณ์ของผู้เชี่ยวชาญ มักใช้ในกรณีที่ข้อมูลในอดีตมีจำกัดหรือไม่เลย เช่น การพยากรณ์ความต้องการของผลิตภัณฑ์ใหม่
 2. เทคนิคการพยากรณ์เชิงปริมาณ (Quantitative Forecasting Techniques) เป็นเทคนิคที่ใช้ข้อมูลในอดีตมาสร้างตัวแบบทางคณิตศาสตร์เพื่อใช้ในการพยากรณ์ โดยเทคนิคในกลุ่มนี้สามารถแบ่งได้เป็น 2 ประเภทใหญ่ๆ ได้แก่
 - 2.1 วิธีอนุกรมเวลา (Time Series Methods) เป็นวิธีที่ใช้เฉพาะข้อมูลในอดีตเพื่อพยากรณ์ค่าในอนาคต จากการวิเคราะห์แนวโน้ม (Trend) ฤดูกาล (Seasonal) วัฏจักร (Cyclical) และความผิดปกติ (Irregular) โดยมีตัวแปรอิสระคือเวลาเพียงอย่างเดียว
 - 2.2 วิธีการพยากรณ์เชิงสาเหตุ (Causal Methods) เป็นวิธีที่ศึกษาถึงความสัมพันธ์ในเชิงเหตุและผลของตัวแปรที่สนใจกับตัวแปรอื่นที่เป็นสาเหตุหรือมีอิทธิพลต่อตัวแปรที่สนใจ เมื่อหาหรือประมาณความสัมพันธ์ระหว่างตัวแปรได้แล้วก็สามารถพยากรณ์ค่าของตัวแปรที่สนใจได้โดยอาศัยค่าของตัวแปรที่เป็นสาเหตุ
- บทความนี้จะกล่าวถึงเฉพาะเทคนิคในการพยากรณ์ด้วยวิธีการพยากรณ์เชิงสาเหตุเท่านั้น

3. การพยากรณ์ด้วยวิธีการพยากรณ์เชิงสาเหตุ

วิธีการพยากรณ์เชิงสาเหตุเป็นการพยากรณ์ที่อาศัยความสัมพันธ์ระหว่างตัวแปรโดยใช้ฟังก์ชันในการแปลงข้อมูลของตัวแปรที่เป็นสาเหตุ (x) มาเป็นค่าของตัวแปรที่สนใจ (y) ดังสมการที่ (1)

$$y = f(x) \quad (1)$$

ฟังก์ชันที่ใช้ในวิธีการพยากรณ์เชิงสาเหตุนี้มีรูปแบบไม่ตายตัว เปลี่ยนแปลงได้ตามหลักการของวิธีต่างๆ ดังแสดงตัวอย่างในหัวข้อ 3.1 ถึง 3.5 ซึ่งบางวิธี ฟังก์ชันที่มีรูปแบบที่ชัดเจนทำให้ทราบถึงความสัมพันธ์ระหว่างตัวแปร เช่น วิธีการวิเคราะห์การถดถอยเชิงเส้น แต่บางวิธี ฟังก์ชันมีลักษณะคล้ายกล่องดำ (Black Box) ไม่แสดงความสัมพันธ์ระหว่างตัวแปรอย่างชัดเจน เช่น วิธีโครงข่ายประสาทเทียม

3.1. การวิเคราะห์การถดถอยเชิงเส้น (Linear Regression Analysis, LRA)

การวิเคราะห์การถดถอยเป็นวิธีที่ใช้เทคนิคทางสถิติในการวิเคราะห์ความสัมพันธ์ระหว่างตัวแปรอิสระ (Independent Variable) ซึ่งเป็นตัวแปรที่มีการกำหนดค่าที่แน่นอนไว้ล่วงหน้าและตัวแปรตาม (Dependent Variable) ซึ่งเป็นตัวแปรที่เปลี่ยนแปลงไปตามตัวแปรอิสระ ในกรณีที่ความสัมพันธ์ของสัมประสิทธิ์ในสมการการถดถอยเป็นแบบเชิงเส้นจะเรียกวิธีนี้ว่าการวิเคราะห์การถดถอยเชิงเส้น (LRA) ซึ่งสามารถแบ่งออกเป็น 2 ประเภท คือ

1. การวิเคราะห์การถดถอยเชิงเส้นอย่างง่าย (Simple Linear Regression Analysis) เป็นการวิเคราะห์ความสัมพันธ์ที่มีตัวแปรตามและตัวแปรอิสระอย่างละ 1 ตัว โดยมีสมการการถดถอยเชิงเส้นอย่างง่ายดังสมการที่ (2)

$$y = \beta_0 + \beta_1 x + \varepsilon \quad (2)$$

โดยที่ y คือ ตัวแปรตาม; x คือ ตัวแปรอิสระ; β_0 และ β_1 คือ สัมประสิทธิ์ของสมการการถดถอย; ε คือ ค่าความผิดพลาด

สัมประสิทธิ์ของสมการการถดถอยเป็นพารามิเตอร์ที่ไม่ทราบค่าจึงต้องทำการประมาณค่า ซึ่งวิธีที่นิยมใช้ในการประมาณค่าคือวิธีกำลังสองน้อยที่สุด (Least Squares Method)

2. การวิเคราะห์การถดถอยเชิงเส้นพหุคูณ (Multiple Linear Regression Analysis) เป็นการวิเคราะห์ความสัมพันธ์ที่มีตัวแปรตาม 1 ตัวและตัวแปรอิสระตั้งแต่ 2 ตัวขึ้นไป ซึ่งสมการการถดถอยเชิงเส้นพหุคูณสามารถแสดงได้ดังสมการที่ (3)

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n + \varepsilon \quad (3)$$

โดยที่ $x_1, x_2, \dots, x_n$ คือ ตัวแปรอิสระ; $\beta_0, \beta_1, \dots, \beta_n$ คือ สัมประสิทธิ์ของสมการการถดถอย

การประมาณค่าของสัมประสิทธิ์ในสมการการถดถอยเชิงเส้นพหุคูณนั้น นิยมใช้วิธีกำลังสองน้อยที่สุดเช่นกัน


การวิเคราะห์การถดถอยมีข้อสมมติฐานพื้นฐาน 4 ข้อคือ ที่ค่าใดๆของตัวแปรอิสระ (1) ประชากรของค่าความผิดพลาดมีค่าเฉลี่ยเท่ากับศูนย์ (2) ประชากรของค่าความผิดพลาดมีความแปรปรวนคงที่ (3) ประชากรของค่าความผิดพลาดมีการแจกแจงแบบปกติ และ (4) ค่าความผิดพลาดมีความเป็นอิสระต่อกัน [1]

การวิเคราะห์การถดถอยเชิงเส้นเป็นวิธีการพยากรณ์เชิงสาเหตุที่นิยมใช้มากที่สุด โดยในการพยากรณ์ ตัวแปรตามของสมการคือสิ่งที่ต้องการพยากรณ์ ในขณะที่ตัวแปรอิสระคือปัจจัยต่างๆที่มีผลต่อตัวแปรตาม เช่น การใช้การวิเคราะห์การถดถอยเชิงเส้นพหุคูณเพื่อหาความสัมพันธ์ระหว่างตัวแปรทางสภาพอากาศและความต้องการพลังงานไฟฟ้ารายเดือน และใช้ความสัมพันธ์ดังกล่าวในการพยากรณ์หาความต้องการพลังงานไฟฟ้ารายเดือน [2]-[3] แต่การวิเคราะห์การถดถอยเชิงเส้นก็มีข้อจำกัดหลายประการ เช่น ไม่เหมาะกับการพยากรณ์ในกรณีที่ความสัมพันธ์ไม่เป็นเชิงเส้น (Non-linear Relationships) และใช้สำหรับการพยากรณ์ที่มีผลลัพธ์ที่เป็นตัวเลขเท่านั้น นอกจากนี้ผู้ที่พยากรณ์โดยวิธีนี้มักละเลยในการตรวจสอบว่าข้อมูลที่เป็นไปตามข้อสมมติฐานของการวิเคราะห์การถดถอยหรือไม่ ซึ่งอาจส่งผลให้ผลการพยากรณ์ที่ได้ผิดพลาดไปมากและมีความน่าเชื่อถือลดลง

3.2. โครงข่ายประสาทเทียม (Artificial Neural Networks, ANN)

โครงข่ายประสาทเทียม (ANN) เป็นตัวแบบทางคณิตศาสตร์ที่จำลองการทำงานของสมองมนุษย์ในการเรียนรู้และจดจำด้วยการทำงานแบบเชื่อมต่อ (Connectionist) โดยการนำข้อมูลต่างๆมาประมวลผล วิเคราะห์ ตีความ และผลลัพธ์ที่ได้เรียกว่าความรู้ (Knowledge) อันเกิดจากกระบวนการเรียนรู้ (Learning Process)


แนวคิดเกี่ยวกับการสร้างตัวแบบทางคณิตศาสตร์เพื่อเลียนแบบการทำงานของสมองนั้นถูกเสนอโดย W. McCulloch และ W. Pitts ในปี ค.ศ. 1943 และภายหลัง ในปี ค.ศ. 1958 F. Rosenblatt ได้สร้าง ANN ที่ใช้งานได้เป็นคนแรก โดยทั่วไป เซลล์ประสาทของ ANN ถูกจำลองโดยเมื่อมีข้อมูลนำเข้า (Input) ส่งเข้ามาก็จะคูณกับค่าน้ำหนัก (Weight) ซึ่งแทนความสำคัญที่ให้กับข้อมูลนำเข้าแต่ละตัว ผลรวมของค่าถ่วงน้ำหนักที่เกิดจากผลคูณของข้อมูลนำเข้าและค่าน้ำหนักจะถูกนำไปวิเคราะห์ ตีความโดยฟังก์ชันกระตุ้น (Activation Function) เกิดเป็นผลลัพธ์ (Output) ซึ่งแสดงดังรูปที่ 1



รูปที่ 1 แบบจำลองของเซลล์ประสาทหนึ่งเซลล์

นักวิจัยได้เสนอรูปแบบโครงสร้างหรือสถาปัตยกรรมของ ANN หลายรูปแบบเพื่อนำไปใช้ในการทำงานที่แตกต่างกัน เช่น แบบป้อนไปข้างหน้า (Feedforward) แบบย้อนกลับ (Feedback หรือ Recurrent) และแบบแข่งขัน (Competitive) นอกจากนี้ ANN ยังมีการเรียนรู้ซึ่งเป็นการปรับค่าน้ำหนักเพื่อให้โครงข่ายได้เรียนรู้และแสดงพฤติกรรมที่ต้องการ โดยการเรียนรู้แบ่งได้เป็น 2 ประเภท คือ การเรียนรู้แบบมีการสอน (Supervised Learning) และการเรียนรู้แบบไม่มีการสอน (Unsupervised Learning)

ในการนำ ANN มาใช้ในการพยากรณ์นั้น โครงสร้างที่นิยมใช้คือโครงข่ายประสาทเทียมแบบหลายชั้น (Multi-Layer Perceptron, MLP) ซึ่งเป็นโครงสร้างแบบป้อนไปข้างหน้า โครงสร้างนี้จะประกอบไปด้วยชั้น (Layer) ต่างๆ 3 ชั้น ได้แก่ ชั้นข้อมูลเข้า (Input Layer) ชั้นซ่อน (Hidden Layer) และชั้นข้อมูลออก (Output Layer) โดยที่ชั้นซ่อนอาจมีมากกว่าหนึ่งชั้น ในแต่ละชั้นจะประกอบด้วยโหนดหรือเซลล์ประสาทหนึ่งเซลล์หรือมากกว่า และข้อมูลจะถูกส่งจากชั้นข้อมูลเข้าไปถึงชั้นข้อมูลออกโดยไม่มีการส่งย้อนกลับ แม้โหนดในชั้นเดียวกันก็ไม่มีการเชื่อมต่อกัน ดังแสดงในรูปที่ 2 และใช้เทคนิคการเรียนรู้แบบมีการสอนชนิดแพร่กลับ (Back Propagation) ซึ่งเป็นวิธีที่ปรับค่าน้ำหนักที่เชื่อมต่อระหว่างโหนดให้เหมาะสมโดยพิจารณาจากผลต่างระหว่างผลลัพธ์ที่ได้กับผลลัพธ์ที่ต้องการ



รูปที่ 2 โครงข่ายประสาทเทียมแบบหลายชั้น


ANN ถูกนำมาประยุกต์ใช้อย่างแพร่หลาย ไม่ว่าจะเป็นการรู้จำแบบ (Pattern Recognition) การจัดหมวดหมู่และแยกแยะ (Clustering and Segmentation) รวมถึงการพยากรณ์ โดยในด้านการพยากรณ์นั้น มักใช้ในกรณีที่ความสัมพันธ์ระหว่างตัวแปรที่มีความซับซ้อนหรือเป็นแบบไม่เชิงเส้น เช่น ในงานวิจัย [4]-[6] แต่การนำ ANN ไปใช้นั้น ผู้ใช้ ANN จะต้องเลือกจำนวนของชั้นซ่อนและจำนวนโหนดของแต่ละชั้นซ่อนให้เหมาะสมกับข้อมูล ซึ่งในปัจจุบันยังไม่มีวิธีหรือหลักการที่แน่ชัดในการเลือกจำนวนดังกล่าว ผู้ใช้ ANN อาจต้องใช้วิธีปรับค่าของจำนวนชั้นซ่อนและจำนวนโหนดไปเรื่อยๆ จนกว่าจะเจอจำนวนที่เหมาะสม เช่น จำนวนที่ให้ค่าความผิดพลาดน้อยที่สุด แต่ทั้งนี้ก็มีวิธีที่ช่วยในการเลือกโดยที่ผู้ใช้ไม่ต้องคอยปรับไปเรื่อยๆ เช่น การใช้ขั้นตอนวิธีทางพันธุกรรม (Genetic Algorithm) มาช่วยในการหาจำนวนที่เหมาะสม ซึ่งจะกล่าวถึงวิธีนี้ในหัวข้อ 3.5 ต่อไป

3.3. ฟัซซีลอจิก (Fuzzy Logic, FL)

ฟัซซีลอจิกหรือตรรกศาสตร์คลุมเครือ (FL) เป็นวิธีทางคณิตศาสตร์ที่ช่วยในการตัดสินใจภายใต้ความคลุมเครือ ไม่ชัดเจน คล้ายกับตรรกะทางความคิดของมนุษย์ คิดค้นโดย L. A. Zadeh ในปี ค.ศ. 1965 ที่อาศัยฟัซซีเซต (Fuzzy Set) เพื่อสื่อถึงความไม่แน่นอน [7] โดยในฟัซซีเซตนี้จะกำหนดค่าความเป็นสมาชิก (Degree of Membership) ให้มีค่าอยู่ระหว่าง 0 และ 1 ซึ่งแตกต่างจากเซตแบบฉบับ (Classical Set) ที่มีการกำหนดค่าความเป็นสมาชิกเพียงสองค่าเท่านั้นคือ 0 หมายถึงไม่เป็นสมาชิก และ 1 หมายถึงเป็นสมาชิก การกำหนดระดับความเป็นสมาชิกของตัวแปรที่สนใจนั้นอาศัยฟังก์ชันความเป็นสมาชิก (Membership Function) ซึ่งมีอยู่หลายชนิด เช่น ฟังก์ชันสามเหลี่ยม ฟังก์ชันสี่เหลี่ยมคางหมู ฟังก์ชันซิกมอยด์ ฟังก์ชันเกาส์เซียน เป็นต้น การเลือกใช้ฟังก์ชันความเป็นสมาชิกจะขึ้นอยู่กับข้อมูลของตัวแปรนั้นๆ นอกจากนี้ ฟัซซีเซตยังใช้กับตัวแปรเชิงภาษา (Linguistic Variables) เพื่อแสดงคุณภาพหรือปริมาณได้อีกด้วย [8]

โครงสร้างพื้นฐานของระบบฟัซซี แสดงดังรูปที่ 3 โดยการทำงานของระบบฟัซซีมี 3 ขั้นตอน คือ ขั้นตอนที่ 1 การแปลงค่าของข้อมูลนำเข้าเป็นค่าฟัซซีนำเข้า (Fuzzification) เป็นการคำนวณค่าความเป็นสมาชิกของข้อมูลนำเข้า (Crisp Input) โดยใช้ฟังก์ชันความเป็นสมาชิก ขั้นตอนที่ 2 การอนุมานหรือตีความ (Fuzzy Inferencing) เป็นการนำค่าฟัซซีนำเข้าไปตีความหรืออนุมานผ่านกฎฟัซซีที่ตั้งขึ้นมาและได้ผลลัพธ์เป็นค่าฟัซซีส่งออก โดยกฎฟัซซีที่นิยมใช้คือ กฎฟัซซีแบบ ถ้า-แล้ว

(Fuzzy If-Then Rule) ที่อาศัยหลักการของเหตุและผล และในขั้นตอนสุดท้าย การทำค่าฟัซซีให้เป็นค่าปกติ (Defuzzification) เป็นการนำค่าฟัซซีที่ส่งออกมาแปลงเป็นค่าปกติ (Crisp Output) ซึ่งหลายวิธี เช่น วิธีถ่วงเฉลี่ยถ่วงน้ำหนัก วิธีการหาจุดศูนย์กลาง เป็นต้น จะเห็นได้ว่าการทำงานของ FL คล้ายกับ ANN ในการประมาณค่าความสัมพันธ์ ต่างกันตรงที่ FL ไม่ได้ใช้การเรียนรู้ แต่อาศัยองค์ความรู้ที่อยู่ในฐานความรู้ (Knowledge Base)



รูปที่ 3 โครงสร้างพื้นฐานของระบบฟัซซี

FL ถูกนำไปใช้ในการพยากรณ์เนื่องจากมีจุดเด่นตรงที่มีตรรกะการใช้เหตุผลเหมือนมนุษย์และใช้ประสบการณ์ของผู้เชี่ยวชาญมากกว่าการใช้ทฤษฎี นอกจากนี้ยังสามารถรองรับกับพฤติกรรมแบบพลวัต (Dynamic Behaviors) รวมถึงความไม่แน่นอนได้ด้วย เช่น มีการนำ FL ไปใช้พยากรณ์การใช้พลังงานในระบบการผลิตที่จะเปลี่ยนแปลงไปเนื่องจากปัจจัยที่เกี่ยวข้องมีการเปลี่ยนแปลง [9] ผลลัพธ์ที่ได้จะช่วยให้การวางแผนที่เหมาะสมเพื่อรักษาประสิทธิภาพการผลิตให้อยู่ในระดับที่ต้องการได้ หรือการใช้ FL ในการพยากรณ์ยอดขายในอุตสาหกรรมเครื่องนุ่งห่มที่ความต้องการของลูกค้ามีการเปลี่ยนแปลงตลอดเวลา โดยที่ยอดขายเป็นแบบฤดูกาลและมีช่วงอายุของสินค้าสั้น [10] แต่ทั้งนี้ FL เองก็มีข้อจำกัดในการใช้เช่นกัน กล่าวคือ FL เป็นการประมาณโดยใช้ตรรกะภายใต้ความไม่แน่นอน ดังนั้นจึงไม่เหมาะที่จะใช้กับงานที่ต้องการความแม่นยำสูง นอกจากนี้ การที่ FL ไม่มีความสามารถในการเรียนรู้ด้วยตัวเอง จึงไม่สามารถใช้หาคำตอบของปัญหาที่ไม่มีใครรู้คำตอบ ดังนั้นผู้เชี่ยวชาญจึงมีความจำเป็นอย่างมากในการตั้งกฎฟัซซีในฐานความรู้ หากไม่สามารถหาผู้เชี่ยวชาญมาช่วยได้ก็ไม่สามารถใช้ FL ได้อย่างมีประสิทธิภาพ ซึ่งแนวทางในการแก้ไขข้อจำกัดนี้จะกล่าวถึงในหัวข้อถัดไป

3.4. ระบบนิวโรฟัซซี (Neuro-Fuzzy System)


วิธีต่างๆทางคณิตศาสตร์ที่ได้กล่าวไปต่างก็มีข้อดีและข้อเสียแตกต่างกัน ไม่มีวิธีใดที่จะดีกว่าวิธีอื่นในทุกๆด้าน ยกตัวอย่างเช่น ANN มีข้อดีตรงที่มีความสามารถในการเรียนรู้และจดจำรูปแบบต่างๆได้ และยังสามารถปรับแต่งความรู้ที่ซ่อนอยู่ภายในโครงข่ายได้ แต่มีข้อเสียตรงที่ไม่สามารถอธิบายเหตุผลของการตัดสินใจได้ ในขณะที่ FL มีจุดเด่นตรงที่มีการใช้เหตุผลในเชิงตรรกะเหมือนความคิดของมนุษย์ สามารถอธิบายการตัดสินใจได้จากกฎฟัซซีและสามารถใช้กับข้อมูลที่คลุมเครือได้ แต่ข้อเสียของ FL อยู่ตรงที่ไม่สามารถเรียนรู้และปรับแต่งกฎต่างๆด้วยตัวเอง ต้องอาศัยผู้เชี่ยวชาญหรือผู้มีความรู้มากำหนดโครงสร้างและกฎให้ ด้วยเหตุนี้จึงมีนักวิจัยสนใจนำวิธีต่างๆมาผสมกันเป็นระบบผสม (Hybrid System) เพื่อนำข้อดีของแต่ละวิธีมารวมกันและขจัดข้อจำกัดของแต่ละวิธีออกไป หนึ่งในระบบผสมดังกล่าวได้แก่ การนำ ANN ผสมกับ FL ได้เป็น ระบบโครงข่ายประสาทเทียมแบบฟัซซี หรือ ระบบนิวโรฟัซซี ซึ่งระบบนิวโรฟัซซีที่เป็นที่นิยม ได้แก่ ระบบ

อนุมานนิวโรฟัซซีแบบปรับตัวได้ (Adaptive Neuro-Fuzzy Inference Systems, ANFIS) ที่เสนอโดย J.-S. R. Jang [11] ในปี ค.ศ. 1993 และมีโครงสร้างพื้นฐานแสดงดังรูปที่ 4 ซึ่งเป็นกรณีที่มีข้อมูลนำเข้า 2 ตัว คือ x_1 และ x_2 และมีข้อมูลออกเพียงตัวเดียว คือ y และมีกฎฟัซซีแบบ Takagi-Sugeno-Kang (TSK) จำนวน 2 กฎ ดังนี้

กฎข้อที่ 1: ถ้า x_1 คือ A_1 และ x_2 คือ B_1 แล้ว $y_1 = p_1x_1 + q_1x_2 + r_1$

กฎข้อที่ 2: ถ้า x_1 คือ A_2 และ x_2 คือ B_2 แล้ว $y_2 = p_2x_1 + q_2x_2 + r_2$

โดยที่ A_1 A_2 B_1 และ B_2 เป็นฟัซซีเซตของพจน์ภาษา เช่น เล็ก กลาง ใหญ่ ส่วน p_1 p_2 q_1 q_2 r_1 และ r_2 เป็นพารามิเตอร์ของข้อตามของกฎฟัซซี โหนดรูปสี่เหลี่ยมแสดงถึงโหนดที่มีพารามิเตอร์ที่สามารถปรับค่าได้ ในขณะที่โหนดรูปวงกลมแสดงถึงโหนดที่ไม่สามารถปรับค่าของพารามิเตอร์ได้



รูปที่ 4 โครงสร้างของระบบอนุมานนิวโรฟัซซีแบบปรับตัวได้

โครงสร้างของ ANFIS แบ่งออกเป็น 5 ชั้น ได้แก่

- ชั้นที่ 1 ทำหน้าที่แปลงข้อมูลนำเข้าเป็นค่าฟัซซีโดยการคำนวณค่าความเป็นสมาชิกจากฟังก์ชันความเป็นสมาชิก อาจเป็นฟังก์ชันรูประฆังคว่ำหรือฟังก์ชันอื่นๆที่สามารถหาอนุพันธ์ได้ เช่น ฟังก์ชันสามเหลี่ยม ฟังก์ชันสี่เหลี่ยมคางหมู และโหนดในชั้นนี้เป็นรูปสี่เหลี่ยมแสดงว่าค่าพารามิเตอร์สามารถปรับค่าได้ ซึ่งพารามิเตอร์ในโหนดนี้หมายถึงพารามิเตอร์ของฟังก์ชันความเป็นสมาชิก เรียกว่า พารามิเตอร์ของข้อตั้ง (Premise Parameters)
- ชั้นที่ 2 ทำหน้าที่คูณสัญญาณที่ส่งมาจากชั้นที่ 1 เข้าด้วยกันโดยใช้ T-norm Operator และส่งออกไปยังชั้นที่ 3 ซึ่งจำนวนโหนดในชั้นนี้จะมีจำนวนเท่ากับจำนวนของกฎฟัซซีและสัญญาณที่ส่งออกไป (w) เป็น Firing Strength ของกฎแต่ละข้อ โหนดในชั้นนี้เป็นรูปวงกลมแสดงว่าไม่สามารถปรับค่าพารามิเตอร์ได้
- ชั้นที่ 3 ทำหน้าที่ปรับค่า Firing Strength ให้มีผลรวมจากกฎทุกข้อมีค่าเป็นหนึ่ง โดยการหารค่า Firing Strength ด้วยผลรวมของ Firing Strength จากกฎทุกข้อ ผลลัพธ์ที่ได้เรียกว่า Normalized Firing Strength ($\bar{w}$) โหนดในชั้นนี้เป็นรูปวงกลมแสดงว่าไม่สามารถปรับค่าพารามิเตอร์ได้

ขั้นที่ 4 ทำหน้าที่คำนวณผลลัพธ์จากข้อตามของกฎฟัซซี โดยได้ผลลัพธ์เป็น $\bar{w}_i (p_i x_1 + q_i x_2 + r_i)$ สำหรับกฎข้อที่ i โหนดในขั้นนี้เป็นรูปสี่เหลี่ยมแสดงว่าพารามิเตอร์ของโหนดนี้ (p_i q_i และ r_i) สามารถปรับค่าได้ พารามิเตอร์เหล่านี้เรียกว่า พารามิเตอร์ของข้อตาม (Consequent Parameters)

ขั้นที่ 5 ทำหน้าที่รวมสัญญาณจากทุกโหนดของขั้นที่ 4 เข้าด้วยกัน โหนดในขั้นนี้เป็นรูปวงกลมแสดงว่าไม่สามารถปรับค่าพารามิเตอร์ได้

การเรียนรู้ของ ANFIS จะใช้ขั้นตอนการเรียนรู้แบบผสม (Hybrid Learning Algorithm) จากวัฏจักรการเรียนรู้แบบสองทาง โดยในการคำนวณไปข้างหน้า (Forward Pass) จะปรับค่าพารามิเตอร์ของข้อตามโดยใช้วิธีการประเมินกำลังสองน้อยที่สุด (Least Squares Estimate) ในขณะที่การคำนวณย้อนหลัง (Backward Pass) จะใช้วิธีปรับตามความลาดชัน (Gradient Descent) สำหรับการปรับค่าพารามิเตอร์ของข้อตั้ง

การใช้ ANFIS ในการพยากรณ์เริ่มได้รับความนิยมมากขึ้นในปัจจุบันเนื่องจากคุณสมบัติในการเรียนรู้และการใช้เหตุผลทำให้ผลลัพธ์มีความแม่นยำมากขึ้น เช่น การใช้ ANFIS ในการพยากรณ์การใช้พลังงานของอาคารในระหว่างการออกแบบอาคารขั้นต้น ซึ่งผลที่ได้สามารถนำไปใช้เลือกระบบควบคุมที่เหมาะสมได้ [12] ส่วนเรื่องข้อจำกัดของ ANFIS นั้น เวลาที่ใช้ในการเรียนรู้ เป็นสิ่งที่ผู้ใช้ ANFIS ต้องตระหนักถึง ปัญหานี้จะทวีความรุนแรงมากขึ้นเมื่อใช้กับระบบที่มีพฤติกรรมแบบพลวัตชนิดไม่เชิงเส้น (Non-linear Dynamic Behaviors) เพราะในระบบแบบนี้จะมีกฎฟัซซีแบบ ถ้า-แล้วจำนวนมาก ทำให้ต้องใช้เวลาในการเรียนรู้นานมากขึ้น จึงไม่เหมาะกับการนำไปใช้งานแบบทำงานทันที (Real-time Applications) แต่ก็มีวิธีที่จะช่วยจำกัดจำนวนของกฎฟัซซีได้โดยใช้การจัดกลุ่มข้อมูล (Data Clustering) เช่น การจัดกลุ่มแบบลบออก (Subtractive Clustering) [13]


3.5. ขั้นตอนวิธีทางพันธุกรรม (Genetic Algorithm, GA)

ขั้นตอนวิธีทางพันธุกรรมหรือเจเนติกอัลกอริทึม (GA) เป็นวิธีที่ใช้หาค่าที่เหมาะสมที่สุดจากกลุ่มคำตอบที่สุ่มมาได้ (Search Space) ชนิดระเบียบวิธีศึกษาสำนึกหรือฮิวริสติก (Heuristic) คิดค้นโดย John Holland [14] ในปี ค.ศ. 1975 ซึ่งได้รับแรงบันดาลใจจากทฤษฎีวิวัฒนาการของ Charles Darwin และได้มีการนำไปประยุกต์ใช้ในการหาค่าที่ดีที่สุดหรือเหมาะสมที่สุดอย่างแพร่หลาย

ขั้นตอนการทำงานของ GA เริ่มต้นจากการสร้างประชากรของคำตอบ (Population) หรือที่เรียกว่าโครโมโซม (Chromosome) ขึ้นมาก่อนจากการสุ่ม จากนั้นจึงทำการถอดรหัสโครโมโซมและคำนวณค่าความเหมาะสม (Fitness Value) ของแต่ละโครโมโซมจากฟังก์ชันวัตถุประสงค์ (Objective Function) ประชากรเหล่านี้จะต้องผ่านตัวดำเนินการทางพันธุกรรม (Genetic Operators) เพื่อให้เกิดการปรับเปลี่ยนสายพันธุ์ ซึ่งมีอยู่ 3 วิธี คือ

1. การคัดเลือก (Selection) เป็นการพิจารณาว่าโครโมโซมใดจะอยู่รอดในรุ่นต่อไป โดยโครโมโซมที่มีค่าความเหมาะสมสูงจะมีโอกาสอยู่รอดหรือได้รับการคัดเลือกมาก ในขณะที่โครโมโซมที่มีค่าความเหมาะสมต่ำก็จะมีโอกาสอยู่รอดน้อย
2. การผสมข้ามพันธุ์ (Crossover) เป็นการสร้างโครโมโซมขึ้นมาใหม่เพื่อให้แตกต่างจากโครโมโซมรุ่นเดิม ทำให้มีโอกาสที่จะได้โครโมโซมที่ดีกว่าเดิม โดยการสุ่มโครโมโซมที่ผ่านการคัดเลือกมาแล้วคู่หนึ่ง เรียกว่าโครโมโซมพ่อแม่ และทำการแลกเปลี่ยนยีนกันได้เป็นโครโมโซมลูก ดังแสดงในรูปที่ 5(a)
3. การกลายพันธุ์ (Mutation) เป็นการเปลี่ยนแปลงค่าของยีนบางตัวในโครโมโซมเพื่อให้เกิดโครโมโซมใหม่ ช่วยป้องกันไม่ให้เกิดอยู่ที่คำตอบแบบวงแคบเฉพาะถิ่น (Local Optimum) ดังแสดงในรูปที่ 5(b)

กระบวนการดังกล่าวจะถูกทำซ้ำไปเรื่อยๆจนกว่าจะตรงกับเงื่อนไขในการหยุดค้นหา ซึ่งจะได้โครโมโซมที่เหมาะสมที่สุด หรือใกล้เคียงค่าที่ดีที่สุด



รูปที่ 5 ตัวดำเนินการทางพันธุกรรม

ในด้านการพยากรณ์นั้น GA ไม่ถูกนำมาใช้ในการพยากรณ์โดยตรง แต่มักนำไปผสมกับวิธีการพยากรณ์อื่นๆ เพื่อเลือกโครงสร้างหรือหาค่าพารามิเตอร์ของวิธีการพยากรณ์นั้นๆ ทำให้ประสิทธิภาพในการพยากรณ์ดีขึ้น เช่น

1. การใช้ขั้นตอนวิธีทางพันธุกรรมร่วมกับการวิเคราะห์การถดถอยเชิงเส้น (GA-LRA) มักเป็นการนำ GA ไปใช้ในการเลือกตัวแปรอิสระในตัวแบบถดถอย โดยกำหนดให้ในแต่ละโครโมโซมจะประกอบด้วยยีนแบบทวิภาค ซึ่งมีจำนวนเท่ากับจำนวนของตัวแปรอิสระ ถ้ายีนใดมีค่าเท่ากับ 1 ตัวแปรอิสระที่สมนัย (Correspond) กับยีนนั้นก็จะถูกรวมอยู่ในสมการ แต่ถ้ามีค่าเท่ากับ 0 ตัวแปรอิสระนั้นก็จะไม่อยู่ในสมการ ซึ่งผลลัพธ์ที่ได้ในหลายงานวิจัยพบว่าไม่ด้อยกว่าการเลือกตัวแปรอิสระด้วยวิธีปกติ เช่น วิธี Best Subsets วิธี Forward Selection วิธี Backward Selection หรือวิธี Stepwise Regression และยังมีควมยืดหยุ่นในเกณฑ์การประเมินตัวแบบถดถอยจากการกำหนดฟังก์ชันวัตถุประสงค์ที่ต้องการได้ นอกจากนี้ยังมีการนำ GA ไปประยุกต์ใช้ในการหาค่าสัมประสิทธิ์ของสมการถดถอย โดยกำหนดขอบเขตบนและขอบเขตล่างของค่าสัมประสิทธิ์แต่ละตัว และให้ GA หาค่าสัมประสิทธิ์ที่อยู่ภายในขอบเขตที่กำหนดที่จะทำให้ความผิดพลาดในการพยากรณ์น้อยที่สุด เช่น [15] ได้ใช้ GA ในการหาค่าสัมประสิทธิ์ของสมการถดถอยเชิงเส้นเพื่อพยากรณ์ความต้องการที่อยู่อาศัย
2. การใช้ขั้นตอนวิธีทางพันธุกรรมร่วมกับการข่ายประสาทเทียม (GA-ANN) มักเป็นการนำ GA ไปใช้ในการเลือกข้อมูลนำเข้าของ ANN นอกจากนี้ยังนิยมนำไปใช้ในการหาโครงสร้างของ ANN ที่เหมาะสมจากการปรับค่าพารามิเตอร์ในส่วนองจำนวนของชั้นซ่อนและจำนวนโหนดในแต่ละชั้นซ่อน หรือการเลือกค่าน้ำหนักที่เชื่อมต่อระหว่างโหนด ซึ่งช่วยให้ได้ค่าพารามิเตอร์ที่เหมาะสมที่สุดโดยไม่ต้องใช้วิธีทดลองทำ (Trial and error) เช่นในงานวิจัยของ [16]-[17] ที่ใช้ GA ในการเลือกค่าน้ำหนักของ ANN
3. การใช้ขั้นตอนวิธีทางพันธุกรรมร่วมกับการฟัซซีลอจิก (GA-FL) มักเป็นการนำ GA ไปใช้ในการปรับค่าพารามิเตอร์ของฟังก์ชันความเป็นสมาชิกทั้งในส่วนองข้อตั้งและข้อตาม เนื่องจากการปรับค่าพารามิเตอร์ด้วยมือ (Manual Tuning) เพื่อให้ได้ค่าที่เหมาะสมใช้เวลานาน นอกจากนี้ยังมีการนำไปใช้สร้างและคัดเลือกกฎฟัซซีที่โดยปกติจะใช้ข้อมูลจากผู้เชี่ยวชาญ ซึ่งอาจจะมีความลำบากในการหาข้อมูลหรือมีราคาแพง หรืออาจจะไม่มีผู้เชี่ยวชาญมาช่วย

สร้างระบบฟัซซีในขณะนั้น โดย GA สามารถช่วยในการสร้างและเลือกกฎฟัซซีที่เหมาะสมได้ เช่น [18] ใช้ GA ในการประมาณค่าพารามิเตอร์ของฟังก์ชันความเป็นสมาชิก

4. การใช้ขั้นตอนวิธีทางพันธุกรรมร่วมกับโครงข่ายประสาทเทียมและฟัซซีลอจิก (GA-ANN-FL) มีการนำมาผสมกันหลายรูปแบบ เช่น การนำ GA มาใช้ในการเลือกจำนวนกฎฟัซซีที่เหมาะสมที่สุดสำหรับ ANFIS โดยในขั้นแรกจะใช้ GA สร้างประชากรของพารามิเตอร์ที่แสดงถึงจำนวนกฎฟัซซี แล้วจึงสร้างระบบฟัซซีจากค่าพารามิเตอร์ที่ได้และให้ ANFIS ทำการประเมินค่าความเหมาะสม หากยังไม่ได้ตามเงื่อนไขการหยุดค้นหาก็จะมีการสร้างประชากรของพารามิเตอร์ชุดใหม่โดยใช้ตัวดำเนินการทางพันธุกรรม แล้วทำการสร้างระบบฟัซซีและประเมินค่าความเหมาะสมใหม่อีกครั้ง ทำซ้ำเช่นนี้ไปเรื่อยๆจนกว่าจะตรงกับเงื่อนไขการหยุดค้นหา หรืออาจเป็นการผสมในรูปแบบอื่น เช่น [19] ใช้ ANN พยากรณ์ความต้องการน้ำและใช้ FL แก้ไขความผิดพลาดของค่าพยากรณ์ ในขณะที่ GA ถูกใช้ในการปรับค่าพารามิเตอร์ของ FL

ในการใช้ GA นั้น ผู้พยากรณ์ต้องกำหนดค่าของพารามิเตอร์ ประกอบด้วย ขนาดของประชากร จำนวนรุ่น รวมถึงอัตราการข้ามสายพันธุ์และอัตราการกลายพันธุ์ หากกำหนดค่าพารามิเตอร์ได้เหมาะสมจะทำให้สามารถหาคำตอบได้ในเวลาไม่นาน แต่หากกำหนดไม่เหมาะสม อาจส่งผลให้ใช้เวลานานในการหาคำตอบหรืออาจจะหาไม่ได้เลย โดยการกำหนดขนาดของประชากรที่น้อยเกินไป อาจทำให้ GA ไม่สามารถค้นหาคำตอบที่ดีจากกลุ่มคำตอบที่สุ่มมาได้ แต่หากกำหนดขนาดของประชากรที่มากเกินไป อาจทำให้ GA ใช้เวลาในการค้นหาคำตอบนาน นอกจากนี้ยังไม่มีการตายตัวในการกำหนดอัตราการข้ามสายพันธุ์และอัตราการกลายพันธุ์ จากการวิเคราะห์งานวิจัยในช่วงที่ผ่านมา มีหลายงานวิจัยที่แนะนำให้กำหนดอัตราการข้ามสายพันธุ์ไว้ที่ระดับสูง ประมาณ 60 ถึง 90 เปอร์เซ็นต์ ในขณะที่ให้กำหนดอัตราการกลายพันธุ์ไว้ในระดับที่ต่ำมาก ประมาณ 0 ถึง 5 เปอร์เซ็นต์ แต่ก็มีบางงานวิจัยที่ระบุอัตราการข้ามสายพันธุ์และอัตราการกลายพันธุ์ที่เหมาะสมต่างไปจากนี้ ปัจจุบันมีงานวิจัยที่มุ่งเน้นการหาค่าพารามิเตอร์ที่ดีที่สุดสำหรับ GA อย่างเช่น [20]-[21] แต่ผลวิจัยที่ได้พบว่า ไม่มีค่าพารามิเตอร์ที่ดีที่สุดสำหรับทุกปัญหา และสิ่งที่ผู้พยากรณ์พึงระลึกไว้เสมอคือผลลัพธ์ที่ได้จาก GA นั้นอาจไม่ใช่ค่าที่ดีที่สุดเสมอไป ค่าที่ได้ อาจจะเป็นเพียงคำตอบแบบวงแคบเฉพาะถิ่น หรือคำตอบที่เป็นไปได้ (Feasible Solution) เท่านั้น

4. จุดเด่นและจุดด้อยของวิธีการพยากรณ์เชิงสาเหตุ

วิธีการพยากรณ์เชิงสาเหตุแต่ละวิธีมีจุดเด่นและจุดด้อยแตกต่างกัน นอกจากนี้ยังมีการนำไปใช้งานที่หลากหลาย ตารางที่ 1 ได้สรุปจุดเด่นและจุดด้อยของวิธีการพยากรณ์เชิงสาเหตุที่กล่าวถึงในหัวข้อที่ 3 และยกตัวอย่างการนำไปใช้งานของแต่ละวิธี

โดยทั่วไปการวิเคราะห์การถดถอยเชิงเส้นเป็นวิธีที่ได้รับความนิยมมากที่สุดและมีการใช้อย่างแพร่หลาย เพราะง่ายในการใช้งานและตีความ แต่ในการพยากรณ์ส่วนใหญ่ ความสัมพันธ์ของตัวแปรมักไม่เป็นเชิงเส้น การวิเคราะห์การถดถอยจึงให้ผลการพยากรณ์ที่มีความคลาดเคลื่อนสูง วิธีการพยากรณ์ที่พัฒนาขึ้นมา เช่น โครงข่ายประสาทเทียม ฟัซซีลอจิก และขั้นตอนวิธีทางพันธุกรรม ซึ่งเป็นวิธีแบบปัญญาประดิษฐ์ (Artificial Intelligence) จึงได้รับความนิยมมากขึ้น เพราะสามารถใช้กับงานที่มีความซับซ้อนหรือไม่มีความสัมพันธ์ที่แน่ชัดและยังให้ผลการพยากรณ์ที่ดีอีกด้วย

ตารางที่ 1 จุดเด่นและจุดด้อยของวิธีการพยากรณ์เชิงสาเหตุและตัวอย่างการนำไปใช้งาน

วิธีการพยากรณ์	จุดเด่น	จุดด้อย	ตัวอย่างการนำไปใช้งาน
การวิเคราะห์การถดถอยเชิงเส้น (LRA)	1. ง่ายต่อการอธิบาย ความสัมพันธ์ระหว่างตัวแปร 2. ให้ผลการพยากรณ์ที่ดีถ้า ความสัมพันธ์ของตัวแปรเป็น แบบเชิงเส้น	1. ไม่เหมาะกับการพยากรณ์ที่ ความสัมพันธ์ของตัวแปรเป็น แบบไม่เชิงเส้น 2. ให้ผลการพยากรณ์เป็นตัวเลข เท่านั้น	1. ผลผลิตการเกษตร 2. ยอดขายสินค้า 3. ความต้องการพลังงาน 4. อุณหภูมิ
โครงข่ายประสาทเทียม (ANN)	1. มีความสามารถในการเรียนรู้ 2. ใช้การกับพยากรณ์ที่ ความสัมพันธ์เป็นแบบไม่เชิงเส้น ได้	1. ไม่สามารถอธิบายและให้ เหตุผลเกี่ยวกับความสัมพันธ์ของ ตัวแปรและผลลัพธ์ที่ได้ 2. ไม่มีหลักการที่ชัดเจนในการ กำหนดโครงสร้างของ ANN เช่น จำนวนชั้นซ่อน จำนวนโหนดใน แต่ละชั้นซ่อน รูปแบบการเรียนรู้ ฟังก์ชันกระตุ้นที่เหมาะสม	1. ปริมาณน้ำฝน 2. โหลดไฟฟ้า 3. ความเร็วลม 4. ดัชนีตลาดหลักทรัพย์ 5. อัตราแลกเปลี่ยน
ฟัซซีลอจิก (FL)	1. มีเหตุผลเชิงตรรกะ 2. สามารถใช้ในการตัดสินใจที่ คลุมเครือได้	1. ไม่มีกระบวนการเรียนรู้ด้วย ตัวเองเพื่อปรับแต่งกฎและตัวแปร 2. ต้องอาศัยผู้เชี่ยวชาญในการ ตั้งกฎและตัวแปรต่างๆ รวมถึง การประเมินความถูกต้องของ ระบบ	1. โหลดไฟฟ้า 2. ยอดขายสินค้า 3. การใช้พลังงาน 4. การจราจร
ระบบนิวโรฟัซซี (Neuro-Fuzzy System)	1. รวมข้อดีของ ANN และ FL โดยสามารถเรียนรู้ด้วยตัวเอง และสามารถตีความและให้เหตุ ผลได้	1. ระบบมีความซับซ้อนมากขึ้น 2. ใช้เวลาในการเรียนรู้มาก	1. การใช้พลังงาน 2. โหลดไฟฟ้า 3. ปริมาณน้ำฝน
ระบบผสมของขั้นตอนวิธีทาง พันธุกรรม (GA Hybrid System)	1. ช่วยในการหาค่าพารามิเตอร์ หรือโครงสร้างที่เหมาะสมของ วิธีการพยากรณ์ไปผสม	1. ต้องกำหนดค่าพารามิเตอร์ ของ GA เช่น จำนวนประชากร จำนวนรุ่น อัตราการข้ามสาย พันธุ และ อัตราการกลายพันธุ์ 2. ค่าที่ได้จาก GA อาจไม่ใช่ค่าที่ ดีที่สุด	1. โหลดไฟฟ้า 2. ความเร็วลม 3. อัตราแลกเปลี่ยน 4. ความต้องการที่อยู่อาศัย

5. ประสิทธิภาพในการพยากรณ์

ปัจจัยที่สำคัญในการเลือกวิธีการพยากรณ์คือความแม่นยำ จึงมีงานวิจัยจำนวนมากที่เปรียบเทียบประสิทธิภาพในการพยากรณ์จากความแม่นยำของวิธีการพยากรณ์ต่างๆ รวมถึงวิธีที่เสนอในหัวข้อที่ 3 ด้วย ดังแสดงในตารางที่ 2 จาก [22]-[24] พบว่า LRA ให้ผลการพยากรณ์ที่มีความแม่นยำน้อยกว่า ANN และ FL จากการวิเคราะห์ผลการพยากรณ์ของงานวิจัยที่ผ่านมา พบว่ามีสาเหตุหลักจากการที่ LRA ไม่สามารถอธิบายความสัมพันธ์แบบไม่เชิงเส้นระหว่างตัวแปรต่างๆ ในสมการได้ ในขณะที่ ANN มีความสามารถในการเรียนรู้รูปแบบความสัมพันธ์ต่างๆ ทั้งที่เป็นเชิงเส้นและไม่เชิงเส้น ส่วน FL ก็มี
ความสามารถในการประมาณความสัมพันธ์ในระบบที่ซับซ้อนและคลุมเครือโดยอาศัยองค์ความรู้ที่อยู่ในฐานความรู้ จึงทำ

ให้ทั้งสองวิธีนี้สามารถพยากรณ์ได้แม่นยำกว่า นอกจากนั้นตัวแบบของ LRA ก็ยังเป็นตัวแบบเฉพาะที่ (Site-specific) นั่นคือตัวแบบที่สร้างขึ้นจะเหมาะกับข้อมูลที่ใช้สร้างขึ้นเท่านั้น หากนำไปใช้กับข้อมูลอื่นก็อาจจะให้ผลที่ไม่แม่นยำและต้องมีการสร้างตัวแบบขึ้นมาใหม่

ตารางที่ 2 งานวิจัยที่เปรียบเทียบความแม่นยำของวิธีการพยากรณ์

การพยากรณ์	เกณฑ์ในการเปรียบเทียบความแม่นยำ	วิธีที่ใช้เปรียบเทียบความแม่นยำ	วิธีที่แม่นยำกว่า	เอกสารอ้างอิง
ความต้องการน้ำสูงสุด	AARE	ANN และ LRA	ANN	[22]
ความต้องการด้านการท่องเที่ยว	MAPE	ANN และ LRA	ANN	[23]
น้ำไหลผ่านตามฤดูกาล	Linguistic matches	FL และ LRA	FL	[24]
ไหลระยะสั้น	MAPE	ANN และ FL	FL	[25]
ระดับน้ำบาดาล	RMSE, R-squared	ANN และ FL	ANN	[26]
ความต้องการของลูกค้า	Average MAPE	ANFIS และ ANN	ANFIS	[27]
อุณหภูมิของโรงงานเคมี	SSE, MSE, RMSE, MAE	นิวโรฟัซซี, ANN และ FL	นิวโรฟัซซี	[28]
อัตราแลกเปลี่ยนเงินตรา	AAE, MAPE, MSE, Max	ANN และ GA-ANN	GA-ANN	[29]
ต่างประเทศ	AE, R-squared			
ระดับน้ำท่วมสูงสุด	RMSE, EI, PE	ANFIS, GA-ANN และ GA-ANN-FL	GA-ANN-FL	[30]
ค่าพารามิเตอร์ของคลื่น	Bias, SI	GA-ANFIS และ ANFIS	GA-ANFIS	[31]

สำหรับประสิทธิภาพในการพยากรณ์ระหว่าง ANN และ FL นั้น จาก [25]-[26] จะเห็นได้ว่าเป็นการยากที่จะชี้ชัดว่าวิธีใดที่ดีกว่ากัน เนื่องจากความแม่นยำในการพยากรณ์ขึ้นกับหลายปัจจัย เช่น ลักษณะของข้อมูล รูปแบบของโครงสร้างค่าพารามิเตอร์และฟังก์ชันที่เลือกใช้

ในส่วนของวิธีการพยากรณ์แบบระบบผสม จากการศึกษางานวิจัยที่ผ่านมาพบว่าระบบผสมมักให้ค่าพยากรณ์ที่แม่นยำกว่าการใช้วิธีการพยากรณ์เพียงวิธีเดียว เช่น [27]-[31] เมื่อวิเคราะห์ถึงสาเหตุก็พบว่า เป็นเพราะระบบผสมมีการนำข้อดีของวิธีการพยากรณ์ต่างมารวมกัน ทำให้มีประสิทธิภาพในการพยากรณ์ที่ดีกว่าการใช้วิธีการพยากรณ์เพียงวิธีเดียว นอกจากนี้มีระบบผสมหลายระบบที่มีการใช้หลักการของวิธีการพยากรณ์หนึ่งในการปรับค่าพารามิเตอร์ของอีกวิธีหนึ่ง ทำให้ได้ค่าพารามิเตอร์ที่เหมาะสมกับข้อมูล แม้จะไม่รับประกันว่าจะได้ค่าที่ดีที่สุด ซึ่งในทางปฏิบัติ ผู้ที่ทำการพยากรณ์สามารถปรับแต่งค่าพารามิเตอร์ของวิธีการพยากรณ์เองได้แต่มักใช้เวลาและอาจไม่ได้ค่าที่เหมาะสม การใช้ระบบผสมช่วยให้ประหยัดเวลาในการหาค่าพารามิเตอร์เหล่านี้ แต่ทั้งนี้ไม่ได้หมายความว่าระบบผสมจะเป็นทางเลือกที่ดีกว่าการใช้วิธีอื่นเสมอไป เนื่องจากระบบผสมเหล่านี้มีความซับซ้อนกว่าและใช้เวลาในการสร้างนานกว่า ผู้ที่ทำการพยากรณ์จึงควรพิจารณาข้อดีและข้อเสียรวมถึงความเหมาะสมกับข้อมูลที่มีสำหรับแต่ละทางเลือก

6. สรุป

บทความนี้ได้กล่าวถึงวิธีการพยากรณ์เชิงสาเหตุที่นิยมใช้ในปัจจุบัน 8 วิธี คือ การวิเคราะห์การถดถอยเชิงเส้น (LRA) โครงข่ายประสาทเทียม (ANN) ฟัซซีลอจิก (FL) ระบบนิวโรฟัซซี (Neuro-Fuzzy) ระบบผสมของขั้นตอนวิธีทางพันธุกรรมและการวิเคราะห์การถดถอยเชิงเส้น (GA-LRA) ระบบผสมของขั้นตอนวิธีทางพันธุกรรมและโครงข่ายประสาทเทียม (GA-ANN) ระบบผสมของขั้นตอนวิธีทางพันธุกรรมและฟัซซีลอจิก (GA-FL) และระบบผสมขั้นตอนวิธีทางพันธุกรรมร่วมกับโครงข่ายประสาทเทียมและฟัซซีลอจิก (GA-ANN-FL) โดยได้อธิบายถึงหลักการทำงานและสรุปจุดเด่นจุดด้อยของแต่ละวิธี รวมถึงตัวอย่างการนำไปใช้งานและยกตัวอย่างงานวิจัยที่เปรียบเทียบประสิทธิภาพในการพยากรณ์ของแต่ละวิธี ซึ่งผลที่ได้พบว่า หากเป็นการพยากรณ์ที่ตัวแปรที่เกี่ยวข้องมีความสัมพันธ์แบบไม่เชิงเส้น การวิเคราะห์การถดถอยเชิงเส้นมักจะทำให้ผลการพยากรณ์ที่ต่ำกว่าวิธีการอื่นๆ แต่บางกรณีก็ไม่สามารถระบุได้ว่าวิธีใดดีกว่ากัน เนื่องจากประสิทธิภาพในการพยากรณ์ขึ้นกับหลายปัจจัย นอกจากนี้ มีงานวิจัยจำนวนมากที่แสดงให้เห็นว่าระบบผสมให้ผลการพยากรณ์ที่ดีกว่าการใช้วิธีการพยากรณ์เพียงวิธีเดียว เพราะระบบผสมได้รวบรวมเอาข้อดีของแต่ละวิธีมารวมกันจึงทำให้สามารถพยากรณ์ได้แม่นยำกว่าและแนวโน้มงานวิจัยในอนาคตของการพยากรณ์เชิงสาเหตุจะมีการนำวิธีการพยากรณ์ที่มีอยู่แล้วมารวมเป็นวิธีผสมแบบใหม่เพื่อให้มีความแม่นยำในการพยากรณ์มากยิ่งขึ้น และวิธีการพยากรณ์ที่จะนำมาผสมก็ไม่จำกัดเฉพาะวิธีการพยากรณ์เชิงสาเหตุเท่านั้น สามารถนำวิธีอนุกรมเวลามาสวมกับวิธีการพยากรณ์เชิงสาเหตุได้ เช่น ระบบผสมของ ANN ตัวแบบการปรับเรียบแบบเอกซ์โพเนนเชียล (Exponential Smoothing Model) และตัวแบบ ARIMA (Autoregressive Integrated Moving Average Model) [32] นอกจากนี้อาจมีการหาค่าพารามิเตอร์ของวิธีพยากรณ์โดยใช้วิธีหาค่าที่ดีที่สุดแบบอื่นๆ นอกเหนือจาก GA เช่น ขั้นตอนวิธีการลอกแบบ (Memetic Algorithm) หรือขั้นตอนวิธีหาค่าเหมาะสมที่สุดแบบกลุ่มอนุภาค (Particle Swarm Optimization)

การเลือกใช้วิธีในการพยากรณ์ ผู้ที่ทำการพยากรณ์ควรศึกษาให้เข้าใจถึงหลักการทำงานของวิธีที่เลือกใช้อย่างถ่องแท้ว่าวิธีการนั้นมีหลักการอย่างไร เหมาะกับการพยากรณ์แบบใด ควรมีโครงสร้างอย่างไร และมีพารามิเตอร์ใดที่ต้องปรับค่าเพื่อให้เหมาะสมกับข้อมูลที่มี จึงจะทำให้วิธีการพยากรณ์ที่เลือกใช้นั้นเกิดประสิทธิภาพสูงสุด

บรรณานุกรม

- [1] B. L. Bowerman, R. T. O'Connell, and A. B. Koehler, *Forecasting, Time Series, and Regression*. Belmont, CA: Thomson Brooks/Cole, 2005.
- [2] F. Apadula, A. Bassini, A. Elli, and S. Scapin, "Relationships between meteorological variables and monthly electricity demand," *Applied Energy*, vol. 98, pp. 346-356, October 2012.
- [3] C.-L. Hor, S. J. Watson, and S. Majithia, "Analyzing the impact of weather variables on monthly electricity demand," *IEEE Transactions on Power Systems*, vol. 20, no. 4, pp. 2078-2085, 2005.
- [4] J. Abbot and J. Marohasy, "Application of artificial neural networks to rainfall forecasting in Queensland, Australia," *Advances in Atmospheric Sciences*, vol. 29, no. 4, pp. 717-730, July 2012.
- [5] A. Ouammi, D. Zejli, H. Dagdougui, and R. Benchirfa, "Artificial neural network analysis of Moroccan solar potential," *Renewable and Sustainable Energy Reviews*, vol. 16, no. 7, pp. 4876-4889, 2012.

- [6] D. C. Park, M. A. El-Sharkawi, R. J. Marks, L. E. Atlas, and M. J. Damborg, "Electric load forecasting using an artificial neural network," *IEEE Transactions on Power Systems*, vol. 6, no. 2, pp. 442-449, 1991.
- [7] L. A. Sadeh, "Fuzzy sets," *Information and Control*, vol. 8, no. 3, pp. 338-353, June 1965.
- [8] พยุง มีดีจ, ระบบฟัซซี่และโครงข่ายประสาทเทียม. เอกสารประกอบการสอน, คณะเทคโนโลยีสารสนเทศ, มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ, 2551.
- [9] H. C. W. Lau, E. N. M. Cheng, C. K. M. Lee, and G. T. S. Ho, "A fuzzy logic approach to forecast energy consumption change in a manufacturing system," *Expert Systems with Applications*, vol. 34, no. 3, pp. 1813-1824, April 2008.
- [10] S. Thomassey, "Sales forecasts in clothing industry: The key success factor of the supply chain management," *International Journal of Production Economics*, vol. 128, no. 2, pp. 470-483, 2010.
- [11] J.-S. R. Jang, "ANFIS: Adaptive-Network-based Fuzzy Inference System," *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 23, no. 3, pp. 665-685, May/June 1993.
- [12] B. Bektas Ekici and U. T. Aksoy, "Prediction of building energy needs in early stage of design by using ANFIS," *Expert Systems with Applications*, vol. 38, no. 5, pp. 5352-5358, May 2011.
- [13] M. Askari and A. H. D. Markazi, "A new evolving compact optimised Takagi-Sugeno fuzzy model and its application to nonlinear system identification," *International Journal of Systems Science*, vol. 43, no. 4, pp. 776-785, April 2012.
- [14] J. H. Holland, *Adaptation in natural and artificial systems*. Ann Arbor, MI: University of Michigan Press, 1975.
- [15] S. T. Ng, M. Skitmore, and K. F. Wong, "Using genetic algorithms and linear regression analysis for private housing demand forecast," *Building and Environment*, vol. 43, no. 6, pp. 1171-1184, 2008.
- [16] P.-C. Chen, C.-Y. Lo, H.-T. Chang, and Y. Locho, "A study of applying artificial neural network and genetic algorithm in sales forecasting model," *Journal of Convergence Information Technology*, vol. 6, no. 9, pp. 352-362, September 2011.
- [17] M. Nasser, K. Asghari, and M. J. Abedini, "Optimized scenario for rainfall forecasting using genetic algorithm coupled with artificial neural network," *Expert Systems with Applications*, vol. 35, no. 3, pp. 1415-1421, October 2008.
- [18] J.-C. Hung, "Applying a combined fuzzy systems and GARCH model to adaptively forecast stock market volatility," *Applied Soft Computing Journal*, vol. 11, no. 5, pp. 3938-3945, July 2011.
- [19] I. Pulido-Calvo and J. C. Gutiérrez-Estrada, "Improved irrigation water demand forecasting using a soft-computing hybrid model," *Biosystems Engineering*, vol. 102, no. 2, pp. 202-218, February 2009.
- [20] P. Pongcharoen, C. Hicks, P. M. Braiden, and D. J. Stewardson, "Determining optimum Genetic Algorithm parameters for scheduling the manufacturing and assembly of complex products," *International Journal of Production Economics*, vol. 78, no. 3, pp. 311-322, August 2002.

- [21] L. Núñez-Letamendia, "Fitting the control parameters of a genetic algorithm: An application to technical trading systems design," *European Journal of Operational Research*, vol. 179, no. 3, pp. 847-868, June 2007.
- [22] J. F. Adamowski, "Peak daily water demand forecast modeling using artificial neural networks," *Journal of Water Resources Planning and Management*, vol. 134, no. 2, pp. 119-128, March 2008.
- [23] C. J. S. C. Burger, M. Dolnal, M. Kathrada, and R. Law, "A practitioners guide to time-series methods for tourism demand forecasting – a case study of Durban, South Africa," *Tourism Management*, vol. 22, no. 4, pp. 403-409, August 2001.
- [24] C. Mahabir, F. E. Hicks, and A. R. Fayek, "Application of fuzzy logic to forecast seasonal runoff," *Hydrological Processes*, vol. 17, no. 18, pp. 3749-3762, December 2003.
- [25] D. K. Ranaweera, N. F. Hubele, and G. G. Karady, "Fuzzy logic for short term load forecasting," *International Journal of Electrical Power & Energy Systems*, vol. 18, no. 4, pp. 215-222, May 1996.
- [26] M. K. Mayilvaganan and K. B. Naidu, "ANN and Fuzzy Logic Models for the prediction of groundwater level of a watershed," *International Journal on Computer Science and Engineering*, vol. 3, no. 6, pp. 2523-2530, June 2011.
- [27] T. Efendigil, S. Önüt, and C. Kahraman, "A decision support system for demand forecasting with artificial neural networks and neuro-fuzzy models: A comparative analysis," *Expert Systems with Applications*, vol. 36, no. 3, pp. 6697-6707, April 2009.
- [28] A. K. Palit and D. Popovic, "Nonlinear combination of forecasts using artificial neural network, fuzzy logic and neuro-fuzzy approaches," in *The Ninth IEEE International Conference on Fuzzy Systems*, San Antonio, TX, 2000, pp. 566-571.
- [29] A. K. Nag and A. Mitra, "Forecasting daily foreign exchange rates using genetically optimized neural networks," *Journal of Forecasting*, vol. 21, no. 7, pp. 501-511, November 2002.
- [30] Y. Chidthong, H. Tanaka, and S. Supharatid, "Developing a hybrid multi-model for peak flood forecasting," *Hydrological Processes*, vol. 23, no. 12, pp. 1725-1738, June 2009.
- [31] M. Zanaganeh, S. JamshidMousavi, and A. F. E. Shahidi, "A hybrid genetic algorithm-adaptive network-based fuzzy inference system in prediction of wave parameters," *Engineering Applications of Artificial Intelligence*, vol. 22, no. 8, pp. 1194-1202, December 2009.
- [32] J.-J. Wang, J.-Z. Wang, Z.-G. Zhang, and S.-P. Guo, "Stock index forecasting based on a hybrid model," *Omega*, vol. 40, no. 4, pp. 758-766, 2012.