

การพยากรณ์อนุกรมเวลาแบบเชิงเส้น แบบไม่ใช่เชิงเส้น และโมเดลผสมผสาน

Time Series Forecasting: Linear Approach, Non-Linear Approach and Hybrid Models

ศุภามณ จันทร์สกุล

บทคัดย่อ

การพยากรณ์อนุกรมเวลาเป็นการพยากรณ์เชิงปริมาณที่มีทั้งวิธีการแบบเชิงเส้น และวิธีการแบบไม่ใช่เชิงเส้น ซึ่งต่างมีข้อจำกัดโดยวิธีการแบบเชิงเส้นไม่สามารถอธิบายข้อมูลแบบไม่ใช่เชิงเส้น ในทางกลับกันวิธีการแบบไม่ใช่เชิงเส้นก็ไม่สามารถอธิบายข้อมูลแบบเชิงเส้นได้เช่นเดียวกัน จึงเกิดการผสมผสานตัวแบบโดยใช้วิธีการแบบเชิงเส้น ผสมผสานกับวิธีการแบบไม่ใช่เชิงเส้นเกิดเป็นตัวแบบผสมเรียกว่าโมเดลผสมผสานที่สามารถชดเชยข้อจำกัดของตัวแบบเดี่ยวทั้งแบบเชิงเส้นและแบบไม่ใช่เชิงเส้นทำให้การพยากรณ์มีความถูกต้องและแม่นยำขึ้น

คำสำคัญ: การพยากรณ์อนุกรมเวลาแบบเชิงเส้น, การพยากรณ์อนุกรมเวลาแบบไม่ใช่เชิงเส้น, วิธีบ็อกซ์-เจนกินส์, โมเดลผสมผสาน, วิธีโครงข่ายประสาทเทียม

Abstract

Time series is one method in Quantitative forecasting which includes both Linear approach and Non-linear approach. Both approaches have limitations such the data with one approach can not be fully explained by another approach. For more accurate forecasting, Hybrid models are developed which use both approaches to explain data mutually.

Keywords: time series forecasting, linear approach, non-linear approach, box-jenkins, hybrid models, Artificial Neural Network (ANN)

ความนำ

การพยากรณ์เชิงปริมาณ (Quantitative Forecasting) เป็นการพยากรณ์ที่ใช้รายละเอียดของข้อมูล queเก็บรวบรวมอย่างต่อเนื่องในอดีตสามารถทำได้หลายวิธีโดยแบ่งได้เป็น 3 กลุ่มดังนี้ กลุ่มที่ 1 การวิเคราะห์อนุกรมเวลาโดยศึกษารูปแบบอนุกรมเวลา (Time series model) ซึ่งมีวิธีการพยากรณ์หลายวิธีได้แก่ Naive method, วิธีแยกส่วนประกอบ (Decomposition method), วิธีปรับให้เรียบ (Smoothing method) และวิธี Box-Jenkins กลุ่มที่ 2 การศึกษาวิเคราะห์ลักษณะความสัมพันธ์ระหว่างปัจจัยหรือตัวแปรโดยใช้วิธีการวิเคราะห์ถดถอยแบบง่ายและแบบพหุ, การวิเคราะห์ทางเศรษฐมิติ และการวิเคราะห์หลายตัวแปรโดยวิเคราะห์อนุกรมเวลาหลายชุดพร้อมกัน กลุ่มที่ 3 การตรวจสอบการดำเนินงานของระบบด้วยการวิเคราะห์อนุกรมเวลาโดยใช้ tracking signal เพื่อแสดงว่าการดำเนินงานของระบบอยู่ในภาวะที่ควบคุมได้ (in control) หรือควบคุมไม่ได้ (out of control) นอกจากนี้ยังมีการพยากรณ์เชิงปริมาณอื่น ๆ ได้แก่ Vector Autoregressive, วิธีโครงข่ายประสาทเทียม (Artificial Neural Network) เป็นต้น (ทรงศิริ แต่สมบัติ, 2549) โดยรายละเอียดของการพยากรณ์ในแต่ละวิธีมีรายละเอียดต่าง ๆ ซึ่งแตกต่างกันไป การวิเคราะห์อนุกรมเวลามีวิธีการพยากรณ์หลายวิธีซึ่งแบ่งเป็น 2 กลุ่มใหญ่คือ (1) วิธีการแบบเชิงเส้น (Linear Approach) มีวิธีที่นิยมใช้อย่างแพร่หลายได้แก่วิธี Box-Jenkins และ (2) วิธีการแบบไม่เชิงเส้น (Non-linear Approach) ได้แก่ วิธีโครงข่ายประสาทเทียม (Artificial Neural Network)

เนื่องจากวิธีการพยากรณ์อนุกรมเวลาทั้งแบบเชิงเส้นและแบบไม่เชิงเส้นต่างมีข้อดีของแต่วิธีจึงได้เกิดการผสมผสานทั้งสองวิธีและเรียกโมเดลผสมผสานหรือ “Hybrid Models” เพื่อปรับปรุงการพยากรณ์โดยแก้ปัญหาในส่วนที่วิธีการแบบเชิงเส้นและวิธีการแบบไม่เชิงเส้นไม่สามารถอธิบายได้ซึ่งทำให้

การพยากรณ์มีประสิทธิภาพมากขึ้น สารานในบทความนี้จึงได้นำเสนอการวิเคราะห์อนุกรมเวลาแบบเชิงเส้น (Linear Approach) ด้วยวิธี Box-Jenkins การวิเคราะห์อนุกรมเวลาแบบไม่เชิงเส้น (Non-linear Approach) ด้วยวิธีโครงข่ายประสาทเทียม (Artificial Neural Network) และการวิเคราะห์อนุกรมเวลาด้วยโมเดลผสมผสาน (Hybrid Models) นอกจากนี้ยังสรุปข้อดี-ข้อจำกัดของการพยากรณ์แต่ละวิธีซึ่งมีรายละเอียดต่างๆดังต่อไปนี้

การวิเคราะห์อนุกรมเวลาแบบเชิงเส้น (Linear Approach)

อนุกรมเวลา (Time series) หมายถึง การเก็บรวบรวมข้อมูลของตัวแปรหนึ่งหรือกลุ่มค่าสังเกตตามลำดับเวลาอย่างสม่ำเสมอต่อเนื่องในช่วงเวลาหนึ่ง (ทรงศิริ แต่สมบัติ, 2549; ภูมิฐาน รังกุลธนวัฒน์, 2556; ศิริลักษณ์ สุวรรณวงศ์, 2556)

ส่วนประกอบของอนุกรมเวลา (Component of time Series) มีดังนี้

1. แนวโน้ม (trend) เป็นส่วนที่ทำให้อนุกรมมีค่าเพิ่มขึ้นหรือลดลงเมื่อเวลาผ่านไป
2. ความผันแปรตามฤดูกาล (seasonal variations) เป็นส่วนของอนุกรมเวลาที่มีการเคลื่อนไหวเนื่องจากอิทธิพลของฤดูกาลโดยเกิดขึ้นในลักษณะซ้ำกันทุกปี ความผันแปรตามวัฏจักร (cycle) เป็นส่วนของอนุกรมเวลาที่มีการเคลื่อนไหวเนื่องจากอิทธิพลของวัฏจักร โดยหนึ่งวัฏจักรมีระยะเวลานานมากกว่า 1 ปี การนับเวลาของวัฏจักรโดยวัฏจักรนับจากจุดสูงสุดจุดหนึ่ง (peak) ไปจุดสูงสุดอีกจุดหนึ่ง หรือนับจากจุดต่ำสุดจุดหนึ่ง (trough) ไปจุดต่ำสุดอีกจุดหนึ่งซึ่งมีระยะเวลานานมากกว่า 1 ปี แบบแผนของวัฏจักรที่พบแบ่งเป็นช่วงได้แก่ ช่วงรุ่งเรือง (prosperity) เป็นจุดสูงสุด (peak) ของวัฏจักร ช่วงถดถอย (recession) เป็นช่วงที่ทำ

ให้อนุกรมเวลามีค่าลดลง ช่วงตกต่ำ (depression) เป็นจุดต่ำสุดของวัฏจักร และช่วงฟื้นตัว (recovery) เป็นช่วงที่ทำให้อนุกรมเวลามีค่าเพิ่มขึ้น

3. ความผันแปรจากเหตุการณ์ไม่ปกติ (irregular fluctuations) เป็นส่วนของอนุกรมเวลาที่มีการเคลื่อนไหวเนื่องจากเหตุการณ์ที่ไม่ได้คาดการณ์เป็นการเปลี่ยนแปลงที่ไม่สามารถพยากรณ์ล่วงหน้าได้และไม่เกิดบ่อยเช่น ภัยธรรมชาติน้ำท่วม สึนามิ, สงคราม, วิกฤติ, การนัดหยุดงาน เป็นต้น

จากส่วนประกอบของอนุกรมเวลาทำให้เกิดอนุกรมเวลาซึ่งมีตัวแบบอนุกรมเวลา (Model of time series) ที่นิยม 2 ตัวแบบได้แก่ ตัวแบบการบวก (Additive Model) และตัวแบบการคูณ (Multiplicative Model) หรือเป็นอนุกรมเวลาแบบคลาสสิกซึ่งมีลักษณะดังนี้ (ศิริลักษณ์ สุวรรณวงศ์, 2556; อรรถกร เก่งพล และธิดารัตน์ สลักคำ, 2557)

$$\text{ตัวแบบการบวก } Y_t = T_t + S_t + C_t + I_t$$

ตัวแบบการบวกมีพื้นฐานว่าส่วนประกอบทั้งสี่เป็นอิสระต่อกัน ถ้าส่วนประกอบใดส่วนประกอบหนึ่งเปลี่ยนไปไม่ว่าจะเพิ่มหรือลดไม่มีผลต่อการเปลี่ยนแปลงของส่วนประกอบอื่นๆ ที่เหลือ

$$\text{ตัวแบบการคูณ } Y_t = T_t * S_t * C_t * I_t$$

ตัวแบบการคูณมีพื้นฐานว่าส่วนประกอบทั้งสี่มีความสัมพันธ์กัน ถ้าส่วนประกอบใดส่วนประกอบหนึ่งเปลี่ยนไปไม่ว่าจะเพิ่มหรือลดมีผลกระทบต่อค่าเปลี่ยนแปลงของส่วนประกอบอื่นๆ ที่เหลือ

ลักษณะข้อมูลที่จะนำมาวิเคราะห์อนุกรมเวลาต้องเป็นข้อมูลที่เก็บรวบรวมมานานพอสมควรและมีความสัมพันธ์กับเวลาโดยการเปลี่ยนแปลงค่าสังเกตได้ต้องมีสาเหตุมาจากเวลาที่เปลี่ยนแปลงไปเท่านั้น และข้อมูลที่เก็บรวบรวมต้องมีช่วงเวลาที่เท่ากัน สำหรับการวิเคราะห์อนุกรมเวลาแบบเชิงเส้นลักษณะความสัมพันธ์ของค่าสังเกตปัจจุบันเป็นฟังก์ชันเชิงเส้นของค่าสังเกตในอดีต

การวิเคราะห์อนุกรมเวลาด้วยวิธีบ็อกซ์-เจนกินส์ (Box-Jenkins)

เป็นวิธีการพยากรณ์ที่เหมาะสมมีความถูกต้องเมื่อพยากรณ์ในระยะสั้นและสามารถใช้ได้กับข้อมูลที่มีการเคลื่อนไหวทุกประเภทโดยการพยากรณ์ต้องเลือกตัวแบบที่เหมาะสมกับชุดข้อมูลโดยพิจารณาจากค่าสหสัมพันธ์ 2 แบบคือ (1) ค่าฟังก์ชันสหสัมพันธ์ในตนเอง (Autocorrelation Function--ACF) เป็นฟังก์ชันที่ได้จากค่าสหสัมพันธ์ระหว่างค่าสังเกตในอนุกรมชุดหนึ่งกับค่าสังเกตในอนุกรมชุดเดิมที่ช่วงเวลาเหลื่อมกัน (lags) 1,2,... ช่วงเวลา โดย ณ จุดใดสัก กั้นจะมีค่ามากและค่อยๆ ลดเมื่อจุดนั้นห่างไป ฟังก์ชันสหสัมพันธ์ในตนเองมีความแตกต่างจากสหสัมพันธ์ (Correlation) โดยฟังก์ชันสหสัมพันธ์ในตนเองจะหาจากข้อมูลตัวแปรเดียว ส่วนสหสัมพันธ์จะหาจากข้อมูล 2 ตัวแปร และ (2) ฟังก์ชันสหสัมพันธ์ในตนเองบางส่วน (Partial Autocorrelation Function--PACF) ซึ่งเป็นฟังก์ชันค่าสหสัมพันธ์บางส่วนระหว่างค่าสังเกตในอนุกรมชุดหนึ่งกับค่าสังเกตในอนุกรมชุดเดิมที่ช่วงเวลาเหลื่อม (lags) 1,2,... ช่วงเวลาเมื่อควบคุมอนุกรมที่อยู่ระหว่างช่วงเวลาเหลื่อมให้มีค่าคงที่ ถ้า ACF และ PACF มีค่าเท่ากับ 0 ทุกช่วงเวลาห่างจะได้แบบจำลองที่เรียกว่า white noise ถ้า ACF และ PACF ที่ได้จากการแปลงอนุกรมเวลาให้คุณสมบัติคงที่โดยการหาผลต่างมีค่าเท่ากับ 0 จะได้แบบจำลองหรือตัวแบบที่เรียกว่า Random walk

ในการวิเคราะห์อนุกรมเวลาด้วยวิธี Box-Jenkins แบ่งเป็น 2 ลักษณะตามการเคลื่อนไหวของอนุกรมเวลาดังนี้ (นงลักษณ์ วิรัชชัย, ม.ป.ป.; ทรงศิริ แต้สมบัติ, 2549; ภูมิฐาน รังคกุลนุวัฒน์, 2556; อรรถกร เก่งพล และธิดารัตน์ สลักคำ, 2557; ภัทร วรภู, 2556)

1. อนุกรมเวลาที่มีความนิ่ง (Stationary) เป็นอนุกรมเวลาที่มีค่าเฉลี่ย ค่าความแปรปรวน และความแปรปรวนร่วมของตัวแปรในแต่ละช่วงเวลามีค่าคงที่ นอกจากนั้นฟังก์ชันสหสัมพันธ์ในตนเองมีความคงที่

ตลอดช่วงเวลา เมื่ออนุกรมเวลาที่มีความนิ่งจะกำหนดตัวแบบในรูปแบบ ARMA (p,q)

2. อนุกรมเวลาที่ไม่มีความนิ่ง (Nonstationary) เป็นอนุกรมเวลาที่มีค่าเฉลี่ย ค่าความแปรปรวน และความแปรปรวนร่วมของตัวแปรในแต่ละช่วงเวลาไม่คงที่ เนื่องจากชุดข้อมูลมีลักษณะแนวโน้มหรือฤดูกาลต้องทำให้ชุดข้อมูลมีคุณสมบัติคงที่ทางสถิติด้วยการหาผลต่างเพื่อทำให้อนุกรมเวลาที่มีความนิ่ง โดยถ้าเป็นอนุกรมเวลาที่ไม่มีความนิ่งเนื่องจากแนวโน้มจะกำหนดตัวแบบอนุกรมเวลาในรูปแบบ ARIMA (p,d,q) ส่วนอนุกรมเวลาที่ไม่มีความนิ่งเนื่องจากฤดูกาลจะกำหนดตัวแบบอนุกรมเวลาในรูปแบบ SARIMA (p,d,q)

ตัวแบบอนุกรมเวลาที่พบบ่อยได้แก่ ARIMA (Auto-Regressive Integrated Moving Average) แสดงลำดับ p,d,q ใช้สัญลักษณ์ ARIMA (p,d,q) ซึ่งมีรายละเอียดดังนี้

AR = Autoregression แสดงลำดับที่ p หมายถึง กระบวนการถดถอยในตนเองเป็นการวิเคราะห์เพื่อหาฟังก์ชันแสดงความสัมพันธ์ระหว่างค่าสังเกตในข้อมูลอนุกรมเวลาที่ขึ้นอยู่กับค่าของตนเองในอดีตที่ผ่านมาเมื่อเวลาห่างกัน k หน่วย ตัวอย่างเช่น Autoregression ลำดับที่ 1 เขียนสัญลักษณ์ว่า AR (1)

I = Integrated แสดงลำดับที่ d หมายถึง กระบวนการหาผลต่าง (differencing) เป็นการวิเคราะห์เพื่อขจัดอิทธิพลแนวโน้มหรือฤดูกาลที่ทำให้ข้อมูลอนุกรมเวลามีการเปลี่ยนแปลงโดยการแทนที่ค่าสังเกตแต่ละค่าในอนุกรมเวลาด้วยผลต่างระหว่างค่าสังเกตนั้นกับค่าสังเกตในอดีตที่ผ่านมาเมื่อเวลาห่างกัน k หน่วย การหาผลต่างจะทำให้อนุกรมมีความนิ่งมากขึ้น โดยปกติแล้วมักทำการหาผลต่างไม่เกิน 2 ครั้งข้อมูลก็จะมีคุณสมบัติ stationary ตัวอย่างเช่น I (1) หรือ ARIMA (0,1,0)

MA = Moving Average แสดงลำดับที่ q หมายถึง กระบวนการหาค่าเฉลี่ยเคลื่อนที่เป็นการ

วิเคราะห์เพื่อปรับฟังก์ชันข้อมูลอนุกรมเวลาที่มีค่าสังเกตกระเพื่อมขึ้นลง (fluctuation) ให้เป็นโค้งเรียบโดยการหาค่าเฉลี่ยของอนุกรมเวลาในช่วงนั้นกับค่าสังเกตในช่วงเวลาก่อนหน้า ตัวอย่างเช่น MA (1) หรือ ARIMA (0,0,1)

ดังนั้น ARIMA (p,d,q) จึงหมายถึงโมเดลที่มีฟังก์ชันการถดถอยในตนเองลำดับที่ p มีการวิเคราะห์ค่าผลต่างลำดับที่ d และมีการวิเคราะห์ค่าเฉลี่ยเคลื่อนที่ลำดับที่ q ส่วนการวิเคราะห์อนุกรมเวลาด้วยวิธี Box-Jenkins แบ่งขั้นตอนออกเป็น 4 ขั้นตอนดังนี้ (นงลักษณ์ วิรัชชัย, ม.ป.ป.; ทรงศิริ แต่สมบัติ, 2549; พงษ์ศิริ สิริพานิช และคณะ, 2550; จินตพร หนัวินัน และคณะ, 2555; วรางคณา กิริติวิบูลย์ และ เจ๊ะอัฐพาน มาหิละ, 2554; Kwangbox Jeong, Choongwan Koo, and Taehoon Hong, 2014; ภัทร วรภู, 2556)

ขั้นตอนที่ 1 การตรวจสอบลักษณะข้อมูลและการระบุโมเดล (model identification) เป็นขั้นตอนตรวจสอบลักษณะข้อมูลเช่น ข้อมูลมีแนวโน้มหรือไม่ มีองค์ประกอบฤดูกาลหรือไม่ และระบุข้อมูลอนุกรมเวลาว่ามีฟังก์ชันทางคณิตศาสตร์เป็นแบบใด มีพารามิเตอร์ประมาณค่าไบบ้าง ตลอดจนตรวจสอบความคงที่หรือความนิ่ง (stationary check) ของอนุกรมเวลาด้วยการหาค่าเฉลี่ย (mean) ความแปรปรวน (variance) ถ้าข้อมูลอนุกรมเวลาที่มีความคงที่ค่าสังเกตหลายค่าในแต่ละช่วงเวลาต้องมีค่าใกล้เคียงกัน แต่ถ้าข้อมูลอนุกรมเวลาไม่มีความคงที่ที่ต้องทำให้เกิดความคงที่ด้วยการหาผลต่าง (differencing) จนอนุกรมเวลาคงที่จะได้ลำดับการหาผลต่าง d การตรวจสอบ stationary ของข้อมูลโดยพิจารณาจากการพลอตกราฟ นอกจากนั้นแล้วยังสามารถพิจารณาจากการทดสอบ Unit root เมื่ออนุกรมอยู่ในรูปแบบ AR(1) หรือการทดสอบ Augmented Dickey and Fuller (ADF) test เมื่ออนุกรมอยู่ในรูปแบบ AR(p) โดยมีสมมติฐานในการทดสอบคือ

H_0 : ข้อมูลไม่มีความคงที่ (nonstationary)

H_1 : ข้อมูลมีความคงที่ (stationary)




ผลการทดสอบถ้าปฏิเสธ H_0 แสดงว่าข้อมูลอนุกรมเวลามีคุณสมบัติ stationary แต่ถ้าผลการทดสอบยอมรับ H_0 แสดงว่าข้อมูลอนุกรมเวลามีคุณสมบัติ nonstationary ต้องทำการหาผลต่าง โดยปกติแล้วมักทำการหาผลต่างไม่เกิน 2 ครั้งข้อมูลก็จะมีความคงที่ กระบวนการหาผลต่างมากเกินไปจะทำให้ความแปรปรวนจากกระบวนการหาผลต่างมากกว่ากระบวนการเดิมเสมอ (มุกดา แฉ่นมินทร์, 2549; ภูมิฐาน รังกุลนุวัฒน์, 2556; ภัทร วรภู, 2556)

ส่วนวิธีการระบุโมเดลข้อมูลโดยพิจารณาจากวิธีพลอตกราฟของอนุกรมเวลา หรือวิธีพิจารณาฟังก์ชัน

สหสัมพันธ์ในตนเอง (Autocorrelation Function--ACF) และฟังก์ชันสหสัมพันธ์ในตนเองบางส่วน (Partial Autocorrelation Function--PACF) นำค่า ACF และ PACF มาเขียนกราฟเรียกแผนภาพ correlogram เพื่อหารูปแบบ AR และ MA ซึ่งแสดงลำดับ p และ q ที่เหมาะสมกับข้อมูลอนุกรมเวลา ลักษณะฟังก์ชันสหสัมพันธ์ในตนเอง (ACF) จะมีเครื่องหมายบวกและลบสลับกันและจำนวนค่าสังเกตในการคำนวณ ACF มีค่าลดลงเมื่อช่วงเวลาเหลื่อมมีค่ามาก ส่วนฟังก์ชันสหสัมพันธ์ในตนเองบางส่วน (PACF) มักมีค่าลดลงแต่เครื่องหมายไม่เปลี่ยนแปลง โดยรูปแบบที่เหมาะสมกับข้อมูลดังตาราง 1

ตาราง 1

รูปแบบที่เหมาะสมของโมเดล ARIMA (p,d,q) โดยพิจารณา ACF และ PACF

โมเดล	ACF	PACF
AR (p)/ ARIMA ($p,0,0$)	ลดลงเรื่อย ๆ (die down) เข้าหา 0 มีค่าบวกและลบสลับกัน	มีจำนวนหางกันเกิน p ช่วง มีค่าสูง (spike) ภายหลัง lag p มีค่าเท่ากับ 0
ตัวอย่าง AR (2)/ ARIMA (2,0,0)		
MA (q)/ ARIMA (0,0, q)	มีจำนวนหางกันเกิน q ช่วง มีค่าสูง (spike) ภายหลัง lag p มีค่าเท่ากับ 0	ลดลงเรื่อย ๆ (die down) เข้าหา 0
ตัวอย่าง MA (2)/ ARIMA (0,0,2)		
ARIMA ($p,0,q$)	ลดลงเรื่อย ๆ (die down) เข้าหา 0 มีค่าบวกและลบสลับกัน	ลดลงเรื่อย ๆ (die down) เข้าหา 0
ตัวอย่าง ARIMA (1,0,1)		

ที่มา. ดัดแปลงจากลักษณะโมเดลแยกตามรูปแบบฟังก์ชัน ACF และ PACF (นงลักษณ์ วิรัชชัย, ม.ป.ป.)

ขั้นตอนที่ 2 การประมาณค่าพารามิเตอร์ในโมเดล (model parameter estimation) หลังการระบุโมเดล ARIMA (p,d,q) ต่อไปคือการประมาณ

ค่าพารามิเตอร์ในโมเดลด้วยวิธี Conditional least squares, Unconditional least squares และวิธีประมาณค่าแบบ maximum likelihood อนุกรมที่ได้ใหม่จะถูก

นำมาเปรียบเทียบกับอนุกรมเดิมเพื่อคำนวณหาอนุกรม
เศษเหลือ (residual)

ขั้นตอนที่ 3 การวินิจฉัยโมเดล (model diagnosis) เพื่อวินิจฉัยความเหมาะสมของโมเดลโดย
ตรวจสอบ ACF และ PACF ของอนุกรมเศษเหลือควร
จะอยู่ใกล้ 0 และความแปรปรวนของอนุกรมเศษเหลือ
ควรมีค่าคงที่ (homoscedasticity) ส่วนการทดสอบทาง
สถิติโดยใช้ *Ljung-Box Q-statistics* ทดสอบเศษเหลือ
อย่างน้อยหนึ่งในสี่ของค่าสังเกตทั้งหมดแต่ไม่เกิน 50
ค่าโดยผลการทดสอบควรยอมรับสมมติฐานศูนย์
หรือไม่มีนัยสำคัญทางสถิติทุกช่วงเวลาทดสอบแสดง
ว่าได้แบบจำลองที่เหมาะสม แต่ถ้าปฏิเสธสมมติฐาน
ศูนย์แสดงว่าอนุกรมเศษเหลือหรือความคลาดเคลื่อน
ยังมีสหสัมพันธ์อยู่ต้องปรับปรุงแบบจำลองหรือตัว
แบบใหม่ การพิจารณาลักษณะตัวแบบที่เหมาะสมควร
มีค่า Information Criterion ได้แก่ Bayesian
Information Criteria (BIC), Akaike Information
Criterion (AIC) ต่ำที่สุด มีค่าประมาณที่ให้ค่าความ
คลาดเคลื่อนได้แก่ ค่าเปอร์เซ็นต์ความคลาดเคลื่อน
เฉลี่ยสัมบูรณ์ (MAPE) ความคลาดเคลื่อนเฉลี่ยสัมบูรณ์
(MAE) ค่ารากที่สองของค่าเฉลี่ยความคลาดเคลื่อนยก
กำลังสอง (RMSE) ค่าความคลาดเคลื่อนกำลังสอง
เฉลี่ย (MSE) มีค่าน้อยที่สุด และมีค่าสัมประสิทธิ์
สหสัมพันธ์ยกกำลังสอง (R^2) จากการวิเคราะห์แบบ
ถดถอยเชิงเส้นพหุคูณสูงซึ่งแสดงว่าโมเดลมีความ
เหมาะสมดี ถ้าไม่เหมาะสมต้องทำการกำหนดรูปแบบ
ใหม่

ขั้นตอนที่ 4 การพยากรณ์ (forecasting) ใช้
ตัวแบบที่ดีที่สุดขั้นตอนที่ 3 เพื่อพยากรณ์ค่าสังเกตที่
ควรจะเป็นตามช่วงเวลาในอนาคต

ข้อดีของการวิเคราะห์อนุกรมเวลาแบบเชิง
เส้นคือสามารถวิเคราะห์ข้อมูลอนุกรมเวลาแบบเชิง
เส้นและสามารถพยากรณ์ข้อมูลอนุกรมเวลาที่มีแบบ
แผน seasonal โดยใช้ SARIMA ซึ่งเมื่อเปรียบเทียบกับ

การวิเคราะห์ถดถอยพหุ (MRA) ตัวแบบ ARIMA
เหนือกว่า MRA ส่วนข้อจำกัดของการวิเคราะห์อนุกรม
เวลาแบบเชิงเส้น โดยถึงแม้ว่าตัวแบบจะมีการ
ตรวจสอบแล้วแต่เศษเหลือจากตัวแบบอาจยังมี
ส่วนประกอบแบบไม่เชิงเส้นคงเหลืออยู่ในเศษเหลือ
(Zhang, 2003) ซึ่งตัวแบบอนุกรมเวลาแบบเชิงเส้น
ARIMA หรือ SARIMA ไม่สามารถอธิบายอนุกรม
เวลาแบบไม่เชิงเส้นเหล่านั้นได้อย่างมีประสิทธิภาพ
(Kwangbox Jeong, Choongwan Koo, and Taehoon
Hong, 2014)

การวิเคราะห์อนุกรมเวลาแบบไม่เชิงเส้น

(Non-linear Approach)

การวิเคราะห์อนุกรมเวลาแบบไม่เชิงเส้น
ได้แก่ วิธีโครงข่ายประสาทเทียม (Artificial Neural
Network--ANN) และ Support Vector Machine
(SVM) (Vapnik V, 1995 อ้างถึงใน ภัทธ วรรณ, 2556)
ในบทความนำเสนอวิธีโครงข่ายประสาทเทียมซึ่งเป็น
ตัวแบบที่ได้รับความนิยมเนื่องจากประสบความสำเร็จ
ในการประยุกต์ใช้ทางศาสตร์ด้านต่างๆ ซึ่งวิธี
โครงข่ายประสาทเทียมมีสาระดังนี้

วิธีโครงข่ายประสาทเทียม

(Artificial Neural Network--ANN)


ANN model เป็น non-linear approach ที่มี
โครงสร้างพื้นฐานคล้ายใยประสาทในสมองของมนุษย์
จึงเรียกว่าโครงข่ายประสาทเทียม โดย ANN มีการ
คำนวณที่เลียนแบบการทำงานของระบบสมองของ
มนุษย์และมีการส่งสัญญาณรวมถึงการแก้ปัญหาที่
ซับซ้อนผ่านเซลล์ประสาท (Neural) หรือเรียกโหนด
(node) ที่เชื่อมโยงกันหลายชั้น ตัวแบบ ANN สามารถ
ประยุกต์นำมาใช้พยากรณ์ข้อมูลอนุกรมเวลาแต่ต้อง
ปรับตัวแปรอิสระโดยทำให้ข้อมูลในอดีตกลายเป็นตัว
แปรอิสระตามช่วงเวลาต่าง ๆ (Lag) (ภัทธ วรรณ, 2556)

โครงสร้างการทำงานของ ANN เรียก โครงข่ายทำงานแบบป้อนไปข้างหน้า (feedforward neural network) หรือโครงข่ายประสาทเทียมแบบหลายชั้น (multi-layer

perceptron--MLP) ประกอบไปด้วย ข้อมูลเข้า (input layer), ชั้นซ่อน (hidden layer) ซึ่งอาจมีมากกว่า 1 ชั้น และชั้นข้อมูลออก (output layer) ดังภาพที่ 2 และ 3

ภาพ 2


โครงข่ายประสาทเทียมที่มีชั้นซ่อน 1 ชั้น



ที่มา. จาก การใช้แบบจำลองโครงข่ายประสาทเทียมสำหรับปฐพีศาสตร์, โดย ทวี ชัยพิมลพลิน, ม.ป.ป., มหาวิทยาลัยเชียงใหม่

ภาพ 3

โครงข่ายประสาทเทียมแบบหลายชั้น



ที่มา. จาก การพยากรณ์ด้วยวิธีการพยากรณ์เชิงสาเหตุ, 2555 (หน้า 35-48), โดย นันทชัย กานตานันทะ, 4(1).

โครงข่ายประสาทเทียมแบบหลายชั้น (multi-layer perceptron--MLP) มีโครงสร้างประกอบไปด้วย 3 ชั้น โดยในแต่ละชั้นจะมีจำนวนเซลล์และมีการเชื่อมโยงกันทุกเซลล์ซึ่งจะมีค่าเบี่ยงเบน (bias) และค่าน้ำหนัก (weight) เป็นตัวแปรอิสระของฟังก์ชันในการประมวลผล ในแต่ละชั้นมีรายละเอียดดังนี้ (ภัทร วรรณ, 2556; ทวีชัยพิมลผลิน, ม.ป.ป.; Kwangbox Jeong, Choongwan Koo, and Taehoon Hong, 2014)

1. ข้อมูลเข้า (input layer) เป็นชั้นที่รับข้อมูลเพื่อสร้างตัวแบบจะมี 1 layer โดยจำนวน Input neurons ในชั้นข้อมูลนำเข้าคือจำนวนปัจจัยต่างๆ ที่เป็นข้อมูลตั้งต้น ซึ่งขึ้นอยู่กับจำนวนตัวแปรอิสระที่เลือกใช้ในการสร้างตัวแบบโดยตัวแปรจะถูกผสมผสานใน input layer ผ่าน combination function ดังสมการ

$$f(x) = \sum_i w_{ii} x_i + \beta_i$$
 โดย f คือ combination function w_{ii} คือ น้ำหนักระหว่าง i th neuron ที่ input layer และ i th neuron ที่ hidden layer ส่วน X_i คือ i th neuron ที่ input layer และ β_i คือ ค่าเบี่ยงเบนของ i th neuron

2. ชั้นซ่อน (hidden layer) อยู่ถัดจากชั้นข้อมูลเข้าซึ่งอาจมีมากกว่า 1 ชั้น จำนวนชั้นซ่อนและ Hidden neurons แต่ละชั้นซ่อนขึ้นอยู่กับความซับซ้อนของข้อมูล ในกรณีที่มีความซับซ้อนของข้อมูลค่อนข้างมากจำนวนเซลล์ในชั้นซ่อนจะมีจำนวนมาก ผู้วิจัยต้องประมาณค่าพารามิเตอร์จำนวนเซลล์ในชั้นซ่อนซึ่งไม่มีกฎเกณฑ์ที่แน่นอนในการกำหนดแต่สามารถพิจารณาได้จากจำนวนความคลาดเคลื่อนน้อยที่สุด โดยจำนวนเซลล์ในชั้นซ่อนที่เหมาะสมจะมีผลต่อประสิทธิภาพของแบบจำลอง ในชั้นซ่อนจะมีการคำนวณการถ่วงน้ำหนักของใยประสาทผ่าน activation function (transfer function เช่น hyperbolic tangent function) ดังสมการ

$$g(f(x)) = \frac{\sinh(f(x))}{\cosh(f(x))} = \frac{e^{f(x)} - e^{-f(x)}}{e^{f(x)} + e^{-f(x)}}$$
 โดย g คือ hyperbolic tangent function ซึ่งเป็น transfer function

3. ชั้นข้อมูลออก (output layer) เป็นชั้นสุดท้ายของโครงข่ายจะมี 1 layer โดยจำนวนเซลล์ในชั้นจะเป็นจำนวนตัวแปรที่แบบจำลองประมวลผลได้ ลักษณะของใยประสาทที่กำหนดโดยใช้ combination function และ activation function ซึ่งจะแสดงในชั้นข้อมูลออกและเป็นการพยากรณ์ที่นำไปใช้จริงโดย ANN จะปรับน้ำหนักในแต่ละชั้นเพื่อให้ได้ค่าพยากรณ์ที่ใกล้เคียงกับค่าจริงมากที่สุด ฟังก์ชันที่นิยมใช้ในการวัดความคลาดเคลื่อนระหว่างค่าจริงและค่าพยากรณ์คือค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (MSE)

สิ่งสำคัญในการพัฒนา ANN model คือกระบวนการวิเคราะห์ MLP ซึ่งแบ่งเป็น training phase และ validation phase ดังนี้ การวิเคราะห์ในช่วง training phase จะมีชุดข้อมูล training ที่ถูกใช้พัฒนาโครงข่ายที่เหมาะสม (optimal MLP network) ผ่านกระบวนการ iterative learning process ส่วนการวิเคราะห์ในช่วง validation phase จะมีการตรวจสอบความตรงของโครงข่ายที่สร้างใน training phase ด้วยชุดข้อมูลเพื่อประเมินความสามารถในการพยากรณ์เมื่อเทียบกับค่าสังเกตได้ (Kwangbox Jeong, Choongwan Koo, and Taehoon Hong, 2014) ข้อจำกัดในการใช้โครงข่ายประสาทเทียมคือการกำหนดค่า (calibration) ของโมเดลที่อยู่บนพื้นฐานของการเชื่อมโยงซึ่งถูกกำหนดค่าใน training process ดังนั้นความแม่นยำของการวิเคราะห์โครงข่ายประสาทเทียมจึงขึ้นอยู่กับความแม่นยำของการ training process เพราะ training process แสดงความสัมพันธ์ระหว่าง input และ output (Shu, Henson, & Willse, 2013)

การวิเคราะห์อนุกรมเวลาแบบไม่เชิงเส้นโดยโครงข่ายประสาทเทียมหรือ ANN model แม้จะมีข้อดีหลายอย่างอันได้แก่ มีความยืดหยุ่นสูง สามารถใช้กับตัวแปรที่ไม่เป็นเส้นตรง สามารถนำไปใช้ได้หลากหลาย และใช้ในข้อมูลที่มีความซับซ้อนสูง แต่ก็มีข้อจำกัดโดยไม่สามารถอธิบายลักษณะ seasonal และ trend ในการ

วิเคราะห์อนุกรมเวลาแบบเชิงเส้นได้อีกทั้งโครงข่ายประสาทเทียมมีความซับซ้อน ไม่มีหลักการในการกำหนดจำนวนชั้นซ่อนและจำนวนโหนดในชั้นซ่อนต้องทราบตัวแปรที่แน่นอนก่อนนำไปใช้ในแบบจำลองและอธิบายความสัมพันธ์ของตัวแปรเป็นสมการอย่างง่ายได้ยาก (จิรนนท์ เจริญชัย และ สุรัชย์ จันทร์จรัส, 2556; พงษ์ศิริ ศิริพานิช และคณะ, 2550; Kwangbox Jeong, Choongwan Koo, and Taehoon Hong, 2014) จากข้อดีของการวิเคราะห์อนุกรมเวลาแบบเชิงเส้นและการวิเคราะห์อนุกรมเวลาแบบไม่เชิงเส้นดังกล่าวข้างต้นจึงทำให้เกิดความนิยมในการพัฒนาโมเดลผสมผสาน (Hybrid model) เพื่อพัฒนาความแม่นยำในการพยากรณ์โดยรวม linear approach และ non-linear approach เข้าด้วยกันซึ่งมีรายละเอียดดังกล่าวต่อไป

การวิเคราะห์อนุกรมเวลาด้วยโมเดลผสมผสาน (Hybrid Models)

จากข้อดีของการวิเคราะห์อนุกรมเวลาแบบเชิงเส้นและไม่เชิงเส้นทำให้เกิดการวิเคราะห์อนุกรมเวลาด้วยโมเดลผสมผสาน (Hybrid Models) ซึ่งสามารถทำได้ด้วยวิธีการ Traditional hybrid และวิธีการสร้างตัวแบบ Hybrid combined โดยในแต่ละวิธีการมีสาระดังนี้ (พงษ์ศิริ ศิริพานิช, 2550; พงษ์ศิริ ศิริพานิช และคณะ, 2550; ภัทร วรภู, 2556)

วิธีการ Traditional hybrid

หลักการของวิธีการ Traditional hybrid โดยตัวแบบผสมจะเป็นกระบวนการต่อเนื่องโดยเริ่มจากสร้างตัวแบบ linear แล้วนำค่าเศษเหลือจากการพยากรณ์ไปทำการพยากรณ์ต่อด้วยตัวแบบ non-linear ซึ่งข้อมูลทั้งสองส่วนทำการวิเคราะห์ไม่พร้อมกัน วิธีการ Traditional hybrid มีขั้นตอนดังนี้

1. นำข้อมูลเข้าสู่ตัวแบบโดยข้อมูลแบ่งออกเป็น 2 ส่วนคือ ส่วนประกอบแบบเชิงเส้น (linear

approach) และส่วนประกอบแบบไม่เชิงเส้น (non-linear approach) แสดงความสัมพันธ์ดังนี้

$$Y_t = L_t + N_t + \varepsilon_t$$

โดย Y_t คือค่าสังเกตของอนุกรมเวลาที่เวลา t , L_t คือส่วนประกอบแบบเชิงเส้น (linear approach), N_t คือส่วนประกอบแบบไม่เชิงเส้น (non-linear approach) และ ε_t คือความคลาดเคลื่อนที่เวลา t

2. ใช้ตัวแบบ ARIMA วิเคราะห์อนุกรมเวลาเพื่อประมาณค่าพยากรณ์ของส่วนประกอบที่เป็นแบบเชิงเส้น $\hat{L}_t$

3. หาค่าเศษเหลือจากตัวแบบ ARIMA ดังสมการ $\varepsilon_t = Y_t - \hat{L}_t$

4. ค่าเศษเหลือที่ได้จากตัวแบบ ARIMA ถูกจัดให้เป็นส่วนประกอบแบบไม่เชิงเส้น $\hat{N}_t$ แล้วทำการพยากรณ์ต่อในตัวแบบ ANN จะได้ค่าพยากรณ์ส่วนประกอบที่เป็นแบบไม่เชิงเส้น $\hat{N}_t$

5. รวมค่าพยากรณ์แบบเชิงเส้นและไม่เชิงเส้น ค่าพยากรณ์รวมดังสมการ $\hat{Y}_t = \hat{L}_t + \hat{N}_t$

6. นำค่าจริงลบด้วยค่าพยากรณ์รวมจะได้ค่าเศษเหลือทั้งหมดดังสมการ $e_t = Y_t - \hat{Y}_t$

7. นำค่าเศษเหลือทั้งหมดมาวิเคราะห์ความแม่นยำของตัวแบบ

วิธีการสร้างตัวแบบ Hybrid combined

หลักการของตัวแบบผสมโดยข้อมูลนำเข้าสู่ตัวแบบแบ่งเป็น 2 ส่วนคือส่วนประกอบแบบเชิงเส้น (linear approach) และส่วนประกอบแบบไม่เชิงเส้น (non-linear approach) เหมือนวิธีการ Traditional hybrid แต่มีความแตกต่างโดยจะสร้างตัวแบบพยากรณ์แต่ละส่วนประกอบแยกกันโดยสามารถทำทั้ง 2 แบบพร้อมกันได้ หลังจากนั้นนำค่าพยากรณ์ทั้ง 2 แบบมารวมกันโดยจัดให้อยู่ในรูปแบบผลรวมเชิงเส้นตรง (Linear combination) แล้วจึงหาค่าน้ำหนัก (weight) ที่ทำให้ค่าพยากรณ์มีความคลาดเคลื่อนน้อยที่สุด ถ้าค่าความ

คลาดเคลื่อนสูงต้องเปลี่ยนค่าน้ำหนัก (weight) และจำนวนใหม่จนได้ค่าความคลาดเคลื่อนน้อยที่สุด

งานวิจัยที่เกี่ยวข้องในการพยากรณ์แบบเชิงเส้น แบบไม่เชิงเส้น และแบบผสมผสาน

จากการทบทวนงานวิจัยที่เกี่ยวข้องในการพยากรณ์ทั้งแบบเชิงเส้น แบบไม่เชิงเส้น และแบบผสมผสานแต่ละงานวิจัยสรุปสาระสำคัญของงานวิจัยได้ดังนี้

Zhang (2003) ได้ศึกษาการพยากรณ์โดยใช้อนุกรมเวลาด้วยตัวแบบผสม ARIMA+ANN ผลการศึกษาพบว่าโมเดลผสม ARIMA+ANN มีข้อดีโดยรวม linear และ nonlinear ทำให้ปรับปรุงการพยากรณ์ได้มีประสิทธิภาพพยากรณ์ได้แม่นยำถูกต้องกว่าการใช้ตัวแบบเดี่ยว ต่อมา Khashei M. และ Bijari M. (2011) พบว่าโมเดลผสมแบบเดิมของ Zhang มีข้อจำกัดโดยมีความยากในการปฏิบัติเนื่องจากข้อมูลจริงพบข้อมูลซึ่งมีแบบแผนเป็น linear หรือ nonlinear แบบแท้จริงน้อยจึงได้ศึกษาการพยากรณ์อนุกรมเวลาโดยพัฒนาตัวแบบผสม ARIMA+ANN แบบใหม่โดยผู้วิจัยใช้ ARIMA ในการระบุและขยายส่วนโครงสร้างเชิงเส้นตรงจากนั้นใช้ MLP ซึ่งใช้ใน nonlinear เพื่อวิเคราะห์ข้อมูลจาก linear และทำการพยากรณ์ผลการศึกษาพบว่าการพยากรณ์ที่ได้มีความแม่นยำมากกว่าตัวแบบผสม ARIMA+ANN แบบเดิม

พงษ์ศิริ ศิริพานิช (2550) ได้ศึกษาการพยากรณ์อนุกรมเวลาด้วยตัวแบบผสมระหว่าง ARIMA และเครือข่ายประสาทเทียม (ANN) ผลการเปรียบเทียบความถูกต้องของการพยากรณ์อนุกรมเวลาด้วยตัวแบบ ARIMA, ANN และ ARIMA+ANN พบว่าการพยากรณ์ข้อมูลราคาปิดของหุ้น PTT เมื่อใช้การพยากรณ์ด้วยตัวแบบผสม ARIMA+ANN ให้ค่าพยากรณ์อนาคตระยะสั้นได้ถูกต้องมากกว่าตัวแบบเดี่ยว ARIMA และ ANN แต่สำหรับการพยากรณ์ข้อมูลราคาปิดของหุ้น BBL พบว่า

ตัวแบบ ANN ให้ค่าพยากรณ์ถูกต้องมากที่สุดทั้งในอนาคตระยะสั้นและระยะยาว

Kwangbox Jeong และคณะ (2014) ได้ศึกษาโมเดลประมาณค่าสำหรับการกำหนดงบประมาณค่าใช้จ่ายพลังงานประจำปีในสถานศึกษาโดยใช้ SARIMA และ ANN ผลการศึกษาพบว่าโมเดลผสมผสาน SARIMA+ANN ให้ค่าพยากรณ์ถูกต้องกว่าโมเดล SARIMA โดยมีความคลาดเคลื่อน MAPE น้อยกว่า ดังนั้นการใช้โมเดลผสมผสานจึงสามารถนำไปบริหารการวางแผนงบประมาณในการประมาณค่าสำหรับการกำหนดงบประมาณค่าใช้จ่ายพลังงานประจำปีในสถานศึกษาได้อย่างถูกต้องแม่นยำและสามารถนำไปประยุกต์เข้ากับแหล่งพลังงานอื่นที่ใช้ในสถานศึกษาได้แก่ การบริโภคน้ำ และแก๊ส เป็นต้น

ฐกฤต ปานขลิบ (2556) ได้ศึกษาการพยากรณ์การใช้พลังงานไฟฟ้าในประเทศไทย โดยวิธีการถดถอยเชิงเส้นพหุคูณและโครงข่ายประสาทเทียม ผลการวิจัยพบว่าโครงข่ายประสาทเทียมมีความแม่นยำในการพยากรณ์ปริมาณการใช้พลังงานไฟฟ้าของประเทศไทยในปี 2015 และ 2020 ได้ดีมากกว่าวิธีการถดถอยเชิงเส้นพหุคูณโดยพิจารณาจากค่าสัมประสิทธิ์สหสัมพันธ์กำลังสอง (R^2), MAPE, และ RMAS

Ho S.L., Xie M. และ Goh T.N. (2002) ได้ศึกษาเปรียบเทียบการพยากรณ์อนุกรมเวลาด้วยตัวแบบ ARIMA และโครงข่ายประสาทเทียมแบบ Recurrent Neuron Network (RNN) พบว่าทั้งสองโมเดลมีความสามารถในการพยากรณ์ระยะสั้นได้ดีแต่ RNN ให้ผลการพยากรณ์ที่ดีกว่า

ภัทร วรภู (2556) ได้ศึกษาการเปรียบเทียบความแม่นยำของการพยากรณ์อนุกรมเวลาระหว่างตัวแบบผสมและตัวแบบเดี่ยว โดยเลือกตัวแบบ ARIMA เป็นตัวแบบเดี่ยวในการพยากรณ์แบบเชิงเส้น และใช้ ANN และ SVM เป็นตัวแบบเดี่ยวในการพยากรณ์แบบไม่เชิงเส้น ส่วนตัวแบบผสมใช้ ARIMAANN,

ARIMASVM และ ARIMAANNSVM ประเมินความแม่นยำของตัวแบบทั้ง 6 แบบด้วย RMSE, MSE, MAE, MAPE การวิเคราะห์โดยใช้ข้อมูลอนุกรมเวลามาตรฐานและอนุกรมเวลาจริงในประเทศไทยโดยเลือกข้อมูลจากหลายๆ แหล่งข้อมูล ผลการศึกษาพบว่าตัวแบบผสม ARIMAANN และ ARIMASVM มีความแม่นยำในการพยากรณ์ใกล้เคียงกับตัวแบบเดี่ยว ARIMA กับตัวแบบเดี่ยว ANN ส่วนตัวแบบผสม ARIMAANNSVM มีความแม่นยำในการพยากรณ์มากกว่าตัวแบบผสม ARIMAANN และ ARIMASVM และมีความแม่นยำในการพยากรณ์มากกว่าตัวแบบเดี่ยว ARIMA, ANN และ SVM ดังนั้นตัวแบบผสม ARIMAANNSVM จึงเป็นตัวเลือกที่ดี โดยเฉพาะในงานที่ต้องการความแม่นยำของการพยากรณ์สูง

จิรนนท์ เจริญพันธ์ และสุรัชย์ จันทร์จรัส (2556) ได้ศึกษาเครื่องมือพยากรณ์ความล้มเหลวทางการเงิน

โดยเปรียบเทียบวิธีได้แก่ โลจิสติก โพรบิท การวิเคราะห์จำแนกประเภทหลายตัวแปร และโครงข่ายประสาทเทียม พบว่าแบบจำลองโลจิสติกและโพรบิทเป็นเครื่องมือที่มีความยืดหยุ่นในการประยุกต์ใช้และง่ายต่อการทำความเข้าใจ ส่วนงานวิจัยที่ต้องการจำแนกหลายกลุ่มหลายตัวแปรเครื่องมือที่เหมาะสมควรใช้การวิเคราะห์จำแนกประเภทหลายตัวแปร และในงานที่มีความซับซ้อนมากขึ้นต้องการเทคนิคที่สูงหรือข้อมูลไม่เป็นเส้นตรงควรใช้โครงข่ายประสาทเทียมซึ่งจะทำให้การพยากรณ์มีประสิทธิภาพมากที่สุด

พัชรี คุณะสารพันธ์ (2541) ได้ศึกษาการเปรียบเทียบวิธีพยากรณ์ในการวิเคราะห์ความถดถอยพหุคูณโดยใช้วิธีวิธีดัจรีเกรสชันและวิธีที่ใช้หลักการของ

โครงข่ายประสาทเทียมในกรณีที่เกิดพหุสัมพันธ์ระหว่างตัวแปรอิสระ ใช้ข้อมูลจำลองด้วยเทคนิคมอนติคาร์โลผลการวิจัยพบว่า ANN ใช้พยากรณ์ได้ดีกว่าวิธีวิธีดัจรีเกรสชันเมื่อมีการแจกแจงแบบลอการิธึมและการแจกแจงปกติปลอมปน ส่วนวิธีวิธีดัจรีเกรสชันใช้พยากรณ์ได้ดีกว่า ANN เมื่อความคลาดเคลื่อนมีการแจกแจงปกติ

ชยกร สมศิตา, สิริภัทร เชื้อชาญวัฒนา และคำรณ สุนันติ (2553) ได้ศึกษาตัวแบบผสมสำหรับการพยากรณ์คุณภาพอากาศกรณีศึกษาข้อมูลคุณภาพอากาศในประเทศไทย เปรียบเทียบประสิทธิภาพการพยากรณ์ระยะสั้นและระยะยาวพบว่า ตัวแบบผสมระหว่างวิธีบ็อกซ์-เจนกินส์ (ARIMA) ร่วมกับโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับให้ผลการพยากรณ์ที่ถูกต้องที่สุดทั้งในการพยากรณ์ระยะสั้นและระยะยาวเมื่อเปรียบเทียบกับตัวแบบบ็อกซ์และเจนกินส์ ตัวแบบโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ

Taskaya-Temizel และ Casey (2005 อ้างถึงในภัทร วรรณ, 2556) ทำการพยากรณ์ข้อมูลยอดขายสินค้าแต่ละประเภท 9 ชุดข้อมูลที่มีอิทธิพลฤดูกาล พบว่าตัวแบบผสม (Traditional hybrid) ไม่ได้ทำให้ความแม่นยำของการพยากรณ์สูงกว่าตัวแบบเดี่ยวๆ เสมอไป

บทสรุป

จากการทบทวนวรรณกรรมดังกล่าวในส่วนต้นของบทความความสามารถสรุปข้อดี-ข้อจำกัดของการพยากรณ์แบบเชิงเส้น การพยากรณ์แบบไม่เชิงเส้น และการพยากรณ์แบบตัวแบบผสมผสาน ได้ดังนี้

ตาราง 4

เปรียบเทียบข้อดี - ข้อจำกัดของการพยากรณ์แบบเชิงเส้น แบบไม่เชิงเส้น และแบบผสมผสาน

แบบของการพยากรณ์	ข้อดี	ข้อจำกัด
Linear approach ด้วยวิธีบ็อกซ์-เจนกินส์ (Box-Jenkins)	- วิเคราะห์ข้อมูลอนุกรมเวลาแบบเชิงเส้น - สามารถพยากรณ์ข้อมูลอนุกรมเวลาที่มีแบบแผน seasonal โดยใช้ SARIMA - สามารถนำไปใช้ได้หลากหลาย - เหมาะกับการพยากรณ์ระยะสั้น	- ไม่สามารถวิเคราะห์ข้อมูลอนุกรมเวลาแบบ Non-linear - ตัวแบบอาจยังมีส่วนประกอบแบบไม่เชิงเส้นหลงเหลืออยู่ในเศษเหลือซึ่งไม่สามารถวิเคราะห์ต่อได้
แบบของการพยากรณ์	ข้อดี	ข้อจำกัด
Non-linear approach ด้วยวิธีโครงข่ายประสาทเทียม (Artificial Neural Network: ANN)	- วิเคราะห์ข้อมูลอนุกรมเวลาแบบไม่เชิงเส้น - มีความยืดหยุ่นสูง - สามารถนำไปใช้ได้หลากหลาย - ใช้ในข้อมูลที่มีความซับซ้อนสูง - สามารถพยากรณ์อนาคตได้ทั้ง ระยะสั้นและระยะยาว	- ไม่สามารถอธิบายข้อมูลที่มีลักษณะ seasonal และ trend ในอนุกรมเวลาแบบเชิงเส้นได้ - มีความซับซ้อน ไม่มีหลักการในการกำหนดจำนวนชั้นซ่อนและจำนวนโหนดในชั้นซ่อน - ต้องทราบตัวแปรที่แน่นอนก่อนนำไปใช้ในแบบจำลอง - อธิบายความสัมพันธ์ของตัวแปรเป็นสมการอย่างง่ายได้ยาก
Hybrid models	- วิเคราะห์ข้อมูลอนุกรมเวลาซึ่งประกอบด้วยแบบเชิงเส้น และแบบไม่เชิงเส้น - ให้ผลการพยากรณ์ที่ถูกต้องที่สุดทั้งในการพยากรณ์ระยะสั้นและระยะยาวเมื่อเปรียบเทียบกับตัวแบบเดี่ยวทั้งแบบเชิงเส้น และไม่เชิงเส้น - ตัวแบบผสม เป็นตัวแบบทางเลือกที่ดี โดยเฉพาะในงานที่ต้องการความแม่นยำของการพยากรณ์สูง - สามารถนำไปใช้ได้หลากหลาย	- ข้อมูลจริงพบข้อมูลซึ่งมีแบบแผนเป็น linear หรือ nonlinear แบบแท้จริงน้อย - ยังคงมีบางบริบทที่ Traditional hybrid ไม่ได้ดีกว่าตัวแบบเดี่ยวเสมอไป

อย่างไรก็ตามถึงแม้ว่าวิธีผสมผสานตัวแบบหรือ Hybrid models จะมีข้อดีอยู่หลายประการตลอดจนชัดเจนข้อจำกัดของตัวแบบเดี่ยวทั้งแบบเชิงเส้นและแบบไม่เชิงเส้นทำให้การพยากรณ์มีความถูกต้องและ

แม่นยำขึ้นโดยพบงานวิจัยต่างๆ ที่พยายามพัฒนาตัวแบบผสมในการวิเคราะห์ข้อมูลหลากหลายในด้านต่างๆ และพบว่าตัวแบบผสมหรือ Hybrid models ให้ความแม่นยำในการพยากรณ์สูงมากกว่าการใช้ตัวแบบเดี่ยวที่เป็นแบบ

เชิงเส้นหรือแบบไม่ใช่เชิงเส้น แต่จากงานวิจัยต่างๆ ก็ยังพบว่ามีการวิจัยบางส่วนให้ผลการศึกษว่า Traditional hybrid ไม่ได้ดีกว่าตัวแบบเดี่ยวเสมอไป ดังนั้นจึงควรมีการศึกษาและพัฒนาตัวแบบหรือ Hybrid models จากตัวแบบต่างๆ หรือพัฒนารูปแบบขั้นตอนการวิเคราะห์

ตลอดจนการทดลองใช้ในการพยากรณ์ที่หลายหลากในบริบทต่างๆ เพื่อศึกษาความแม่นยำของตัวแบบผสม หรือรูปแบบขั้นตอนการวิเคราะห์ที่พัฒนาขึ้นเพื่อศึกษาผลการพยากรณ์อนาคตทั้งระยะสั้นและระยะยาว

เอกสารอ้างอิง

- จินตพร หนัวินัน, บุญอ้อม โคมที และประสิทธิ์ พยัคฆพงษ์. (2555). การเปรียบเทียบวิธีการพยากรณ์ 4 วิธี สำหรับความต้องการพลังงานไฟฟ้าสูงสุดในภาคกลางของประเทศไทย. *Graduate Research Conference*. มหาวิทยาลัยขอนแก่น.
- จิรนนท์ เจริญชัย และ สุรัชย์ จันทร์จรัส. (2556). เครื่องมือพยากรณ์ความล้มเหลวทางการเงิน. *วารสารนักบริหาร*, 35(4), 34-41.
- ชยกร สมศิลา, สิริภัทร เชื้อชาญวัฒนา และคำธณ สุณัติ. (2553). ตัวแบบผสมสำหรับการพยากรณ์คุณภาพอากาศ กรณีศึกษาข้อมูลคุณภาพอากาศในประเทศไทย. *การประชุมวิชาการเสนอผลงานวิจัยระดับบัณฑิตศึกษาครั้งที่ 11*. มหาวิทยาลัยขอนแก่น.
- ฐกฤต ปานชลธิ. (2556). การพยากรณ์การใช้พลังงานไฟฟ้าในประเทศไทย โดยวิธีการถดถอยเชิงเส้นพหุคูณและโครงข่ายประสาทเทียม. *วารสารวิทยาศาสตร์ประยุกต์*, 12(2), 58-67.
- ทรงศิริ แต่สมบัติ. (2549). *การพยากรณ์เชิงปริมาณ*. กรุงเทพมหานคร: มหาวิทยาลัยเกษตรศาสตร์.
- ทวี ชัยพิมลสิน. (ม.ป.ป.). *การใช้แบบจำลองโครงข่ายประสาทเทียมสำหรับภูมิศาสตร์*. เชียงใหม่: มหาวิทยาลัยเชียงใหม่.
- นงลักษณ์ วิรัชชัย. (ม.ป.ป.). *การวิเคราะห์แนวโน้มและการพยากรณ์ (Trend Analysis and Forecasting)*. เอกสารประกอบการบรรยาย ภาควิชาวิจัยและจิตวิทยาการศึกษา คณะครุศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย.
- นันทชัย กานตานันทะ. (2555). การพยากรณ์ด้วยวิธีการพยากรณ์เชิงสาเหตุ. *วารสารวิศวกรรมศาสตร์*, 4(1), 35-48.
- พงษ์ศิริ ศิริพานิช. (2550). *การพยากรณ์อนุกรมเวลาด้วยตัวแบบผสมระหว่าง ARIMA และโครงข่ายประสาทเทียม*. วิทยานิพนธ์ปริญญาวิทยาศาสตรมหาบัณฑิต สาขาคณิตศาสตร์และเทคโนโลยีสารสนเทศ ภาควิชาคณิตศาสตร์, มหาวิทยาลัยศิลปากร.
- พงษ์ศิริ ศิริพานิช, ปราณี นิลกรณ์ และ สุดา ตระการเถลิงศักดิ์. (2550). การพยากรณ์อนุกรมเวลาด้วยตัวแบบผสม ARIMA และ โครงข่ายประสาทเทียม. *การประชุมวิชาการด้านการวิจัยดำเนินงานแห่งชาติ ประจำปี ๒๕๕๐*.
- พัชรีย์ คุณะสารพันธ์. (2541). *การเปรียบเทียบวิธีพยากรณ์ในการวิเคราะห์ความถดถอยพหุคูณ โดยใช้วิธีรีดจ์รีเกรสชัน และวิธีที่ใช้หลักการของโครงข่ายประสาทเทียมในกรณีที่เกิดพหุสัมพันธ์ระหว่างตัวแปรอิสระ*. วิทยานิพนธ์ปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาสถิติ ภาควิชาสถิติ, จุฬาลงกรณ์มหาวิทยาลัย.

- ภัทร วรภู. (2556). การเปรียบเทียบความแม่นยำของการพยากรณ์อนุกรมเวลาระหว่างตัวแบบผสมและตัวแบบเดี่ยว. วิทยานิพนธ์ปริญญาวิศวกรรมศาสตรมหาบัณฑิต สาขาวิชาวิศวกรรมอุตสาหการ ภาควิชาวิศวกรรมอุตสาหการ, จุฬาลงกรณ์มหาวิทยาลัย.
- ภูมิฐาน รังคกุลนุวัฒน์. (2556). การวิเคราะห์อนุกรมเวลาสำหรับเศรษฐศาสตร์และธุรกิจ. กรุงเทพมหานคร: จุฬาลงกรณ์มหาวิทยาลัย.
- มุกดา แม้นมินทร์. (2549). อนุกรมเวลาและการพยากรณ์. กรุงเทพมหานคร: ประกายพรีก.
- วรางคณา กิริติวิบูลย์ และ เจ๊ะอัฐพาน มาหิละ. (2554). ตัวแบบพยากรณ์ความเร็วลมตามแนวชายฝั่ง จังหวัดสงขลา. วารสารวิจัยพลังงาน. 8(2): 63-72.
- ศิริลักษณ์ สุวรรณวงศ์. (2556). เทคนิคการพยากรณ์เชิงปริมาณ: การวิเคราะห์อนุกรมเวลา. กรุงเทพมหานคร: มหาวิทยาลัยมหิดล.
- อรรถกร เก่งพล และธิดารัตน์ สลักคำ. (2557). การพัฒนาตัวแบบพยากรณ์ที่เหมาะสมสำหรับการเกิดของเสียในอุตสาหกรรมฮาร์ดดิสก์ไดรฟ์. วารสารวิชาการพระจอมเกล้าพระนครเหนือ, 24(2), 318-328.
- Ho, S. L., Xie, M. & Goh, T. N. (2002). A comparative study of neural network and box-jenkins ARIMA modeling in time series prediction. *Computer & Industrial Engineering*, 42(1), 371-375.
- Khashei, M. and Bijari, M. (2011). A novel hybridization of artificial neural networks and ARIMA models for time series forecasting. *Applied Soft Computing*, 11(1), 2664–2675.
- Kwangbox Jeong, Choongwan Koo & Taehoon Hong. (2014). An estimation model for determining facilities using SARIMA (seasonal autoregressive integrated moving average) and ANN (artificial neural network), *Energy*. 7(1), 71-79.
- Shu, Z., Henson, R. & Willse, J. (2013). Using neural network analysis to define methods of DINA model estimation for small sample sizes. *Journal of Classification*, 30(2), 173-194.
- Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50(1), 159 – 175.

