

## บทที่ 2

### เอกสารและงานวิจัยที่เกี่ยวข้อง

#### บทนำ

ในการศึกษาวิจัยเรื่อง “การพยากรณ์ความต้องการ โดยใช้กฎผู้เชี่ยวชาญ” ผู้วิจัยได้ศึกษาค้นคว้าเอกสารตลอดจนงานวิจัยต่าง ๆ ซึ่งเป็นองค์ความรู้เกี่ยวกับงานด้านการพยากรณ์ที่เผยแพร่โดยผู้เชี่ยวชาญด้านการพยากรณ์ มาทำการรวบรวมส่วนที่น่าสนใจและเกี่ยวข้องกับหัวข้องานวิจัยดังกล่าวข้างต้น แบ่งเป็นหัวข้อ ดังต่อไปนี้

- 2.1 การพยากรณ์
- 2.2 เทคนิคการพยากรณ์
- 2.3 ระบบผู้เชี่ยวชาญและการนำระบบผู้เชี่ยวชาญมาใช้ในการพยากรณ์
- 2.4 การวัดผลการพยากรณ์
- 2.5 ข้อมูลและการแข่งขันของ M3-Competition

#### 2.1 การพยากรณ์

การพยากรณ์เป็นศาสตร์ที่ผสมผสานระหว่างศิลปะและวิทยาศาสตร์อย่างพิถีพิถัน ความสำเร็จในการดำเนินธุรกิจส่วนใหญ่ขึ้นอยู่กับความถูกต้องแม่นยำในการพยากรณ์ การพยากรณ์หมายถึงการคาดคะเนเหตุการณ์หรือข้อมูลในอนาคต (Future event) เครื่องมือการพยากรณ์ที่ใช้จะต้องมีความถูกต้องในระดับที่ยอมรับได้ รวมทั้งมีความง่ายและยืดหยุ่นในทางปฏิบัติ โดยทั่วไป เราสามารถเขียนแบบจำลองการพยากรณ์ได้ดังสมการ (2.1)

$$\hat{Y} = X + \varepsilon \quad (2.1)$$

โดยที่	$\hat{Y}$	คือ ค่าการพยากรณ์
	$X$	คือ ส่วนประกอบหรือตัวแปรที่สามารถกำหนดหรือวัดค่าได้ (Deterministic component)
	$\varepsilon$	คือ ตัวแปรสุ่มหรือตัวแปรที่วัดค่าไม่ได้ (Random component)

ปรีชา พันธุมสินชัย (2541) กล่าวถึงการพยากรณ์ไว้ว่า ตัวเลขการพยากรณ์หรือการประมาณการเป็นสิ่งจำเป็นสำหรับการวางแผนและช่วยให้การตัดสินใจอยู่บนพื้นฐานที่มีเหตุผล และได้สรุปเกี่ยวกับผลการวิจัยด้านการพยากรณ์ไว้ดังนี้

1. วิธีการพยากรณ์โดยใช้ประสบการณ์หรือวิจารณญาณของคน (Judgmental methods) เช่น จากฝ่ายผู้จัดการขายที่มีข้อมูลสนับสนุนมากมาย ก็ไม่จำเป็นต้องแม่นยำกว่าวิธีการที่ใช้ตัวเลขแบบคำนวณเป็นรูปธรรม (Objective methods)
2. วิธีการประเภทมีมูลเหตุและผล (Causal method) ไม่จำเป็นที่จะแม่นยำกว่าวิธีการอนุमानหรือคาดการณ (Extrapolation methods) ที่ใช้ข้อมูลอนุกรมเวลา (Time series)
3. เทคนิคพยากรณ์ที่ยากไม่จำเป็นต้องพยากรณ์ได้แม่นยำกว่าเทคนิคที่ง่ายกว่าเสมอไป

## 2.2 เทคนิคการพยากรณ์

ในหัวข้อนี้ผู้วิจัยได้ทำการรวบรวมตัวอย่างเทคนิคการพยากรณ์ที่สำคัญและเกี่ยวข้องกับงานวิจัยเพื่อประโยชน์ในการทำความเข้าใจโมเดลการพยากรณ์ในส่วนถัดไป ดังนี้

- Moving Average (MA)
- Monte Carlo simulation (MC)
- Single Exponential Smoothing
- Naive2
- Box-Jenkins

### 2.2.1 Moving Average (MA)

เป็นเทคนิคหนึ่งของวิธีอนุกรมเวลาในการพยากรณ์ความต้องการในอนาคตที่มีผลมาจากความต้องการในอดีต (Ragsdale, 2004) ค่าพยากรณ์  $\hat{Y}_t$  ณ เวลา  $t+1$  สามารถหาโดยใช้ค่าเฉลี่ยของข้อมูลที่เกิดขึ้นก่อนหน้าจำนวน  $k$  ตัว ดังแสดงในสมการ (2.2)

$$\hat{Y}_t = \frac{1}{k} \sum_{i=t-k}^{t-1} X_i \quad (2.2)$$

- โดยที่  $t$  และ  $n$  คือ เวลาที่เกิดข้อมูลความต้องการ  
 $k$  คือ จำนวนข้อมูลที่ใช้เฉลี่ย  
 $X_t$  คือ ข้อมูลความต้องการที่เวลา  $t$

วิธี MA เหมาะกับข้อมูลที่มีลักษณะคงที่ไม่เปลี่ยนแปลงมากในแต่ละช่วงเวลา รวมทั้งยังมีความง่ายและยืดหยุ่นในการนำไปประยุกต์ใช้ในทางปฏิบัติ เมื่อเปรียบเทียบกับวิธีการพยากรณ์อื่น ๆ ซึ่งอาจจะต้องอาศัยรอบการกระทำซ้ำ (Iterative procedure) จำนวนมากและซับซ้อน อย่างไรก็ตามวิธี MA ยังขาดความยืดหยุ่น ไม่สามารถปรับตัวได้ทันที เมื่อปัจจัยภายนอกมีการเปลี่ยนแปลงอย่างรวดเร็ว

### 2.2.2 Monte Carlo Simulation (MC)

เป็นการจำลองสถานการณ์ความน่าจะเป็นแบบไม่ต่อเนื่อง (Discrete simulation) โดยอาศัยข้อมูลที่เกิดขึ้นจริงในอดีตมาสร้างแบบจำลองความน่าจะเป็นเพื่อพยากรณ์ความต้องการในอนาคต (Fishman, 2006) โดยมีผลการพยากรณ์มีการกระจายตัวในลักษณะเดียวกันกับข้อมูลในอดีต วิธี MC เหมาะสำหรับข้อมูลที่มีความไม่แน่นอน หรือมีลักษณะการเกิดเป็นเชิงสุ่ม ยกตัวอย่างเช่น การจำลองการสั่งซื้อสินค้าจากลูกค้า เป็นต้น

โดยทั่วไป การพยากรณ์ด้วยวิธี MC แบ่งออกเป็น 5 ขั้นตอนดังนี้

1. กำหนดการกระจายค่าความน่าจะเป็นของตัวแปร
2. สร้างความน่าจะเป็นสะสมของตัวแปร
3. สร้างช่วงตัวเลขสุ่มของตัวแปร
4. หาจำนวนครั้งในการสุ่มเพื่อจำลองสถานการณ์
5. ทำการจำลองปัญหา (Simulation)

### 2.2.3 Single Exponential Smoothing

เป็นวิธีการพยากรณ์ด้วยการปรับให้เรียบด้วยหลักการหาค่าเฉลี่ยและถ่วงน้ำหนักซึ่งเป็นการให้กำหนดความสำคัญให้กับข้อมูลด้วยค่า  $\alpha$  (Alpha) โดยวิธี Single Exponential Smoothing นี้เป็นวิธีที่เหมาะสมกับข้อมูลที่มีลักษณะคงที่ไม่มีความโน้ม (Trend) และไม่มีฤดูกาล (Seasonality) ดังสมการ(2.3)

$$F_{t+1} = F_t + \alpha(y_t - F_t) \quad (2.3)$$

โดยที่	$y$	คือ ค่าของข้อมูลที่เวลาต่าง ๆ
	$F$	คือ ค่าการพยากรณ์ข้อมูล
	$t$	คือ เวลา
	$\alpha$	คือ ค่าน้ำหนักที่ทำให้เรียบระหว่างค่าข้อมูลกับค่าพยากรณ์

### 2.2.4 Naive2

Naive2 คือ วิธีดัชนีฤดูกาล (Makridakis & Hibon, 2000) ที่คำนึงถึงปัจจัยของฤดูกาล เป็นการพยากรณ์ง่าย ๆ ด้วยค่าของข้อมูลล่าสุดที่เกิดขึ้น โดยสมมติว่าข้อมูลดังกล่าวมีลักษณะของฤดูกาล ดังสมการที่ (2.4)

$$F_{t+i} = X_t * (S_t) \quad (2.4)$$

โดยที่  $X_t$  คือ ค่าที่มีการปรับฤดูกาลข้อมูลแล้วของค่า  $X_t$   
 $S_t$  คือ ค่าดัชนีฤดูกาลซึ่งคำนวณโดยใช้ Classical decomposition method สำหรับข้อมูลก่อนหน้า  $j$  ระเบียบ (รายควอเตอร์ หรือ รายเดือน)

$i$  คือ จำนวนช่วงเวลาที่ต้องการพยากรณ์ล่วงหน้า

วิธี Naive2 ที่ใช้เปรียบเทียบใน M-2 Competition นับเป็นวิธีที่มีความแม่นยำรองจากวิธี Dampen ซึ่งเป็นวิธีที่มีความแม่นยำในภาพรวมมากที่สุด และยังมีผลการพยากรณ์ที่แม่นยำเป็นอันดับต้น ๆ ในการพยากรณ์ของ M3-Competition ด้วย

### 2.2.5 Box-Jenkins

วิธี Box-Jenkins เป็นการหาตัวแบบอนุกรมเวลา ซึ่งพิจารณาค่าสหสัมพันธ์ระหว่าง  $Y$  ที่ตำแหน่งเวลาหรือคาบเวลา ( $Y_t$ ) และ  $Y$  ที่ตำแหน่งเวลาหรือคาบเวลาต่าง ๆ ที่เกิดขึ้นในอดีต ( $Y_{t-2}, Y_{t-1}, \dots$ ) เมื่อได้ตัวแบบแล้ว ตัวแบบนี้จะแสดงความสัมพันธ์ระหว่าง  $Y_t$  กับ  $Y_{t-1}, Y_{t-2}$  และจะใช้ตัวแบบนี้พยากรณ์  $Y_{t+1}, Y_{t+2}, \dots$  ในอนาคต วิธี Box-Jenkins โดยทั่วไปจะให้ความสำคัญหรือน้ำหนักของข้อมูลในอดีตที่ห่างไกล นั้นมาก ลักษณะตัวแบบ Box-Jenkins มาจากการศึกษาวิเคราะห์กระบวนการเชิงเส้นหรือตัวกรองเชิงเส้น (Linear filter) แสดงดังสมการ (2.5)

$$Y_t = u + e_t + \psi_1 e_{t-1} + \psi_2 e_{t-2} + \dots \quad (2.5)$$

โดยขั้นตอนการพยากรณ์ด้วยวิธี Box-Jenkins สามารถสรุปได้ดังนี้

1. วิเคราะห์สหสัมพันธ์ในตัวเอง (Autocorrelation) และสหสัมพันธ์ในตัวเองในบางส่วน (Partial autocorrelation) ของข้อมูลในอนุกรมเวลาและผลต่างของข้อมูล
2. ผลการวิเคราะห์ขั้นตอนที่ 1 จะใช้ในการเลือกตัวแบบพยากรณ์
3. ประมาณค่าของพารามิเตอร์ในตัวแบบและตรวจสอบความถูกต้อง
4. ถ้าผลการตรวจสอบปรากฏว่า ตัวแบบไม่มีความเหมาะสม ผู้วิเคราะห์จะต้องกลับไปขั้นที่ 2 โดยเลือกตัวแบบพยากรณ์ใหม่ โดยอาศัยผลการวิเคราะห์ในขั้นตอนที่ 1 และการตรวจสอบในขั้นตอนที่ 3 แล้วทำซ้ำขั้นตอนที่ 3 ใหม่ ถ้าผลการตรวจสอบปรากฏว่ามีความเหมาะสมในตัวแบบ ตัวแบบนี้ก็จะใช้ในการพยากรณ์

### 2.3 ระบบผู้เชี่ยวชาญและการนำระบบผู้เชี่ยวชาญมาใช้ในการพยากรณ์

ระบบผู้เชี่ยวชาญ (Expert System : ES) เป็นส่วนหนึ่งของความคิดทางด้านปัญญาประดิษฐ์ (Artificial Intelligence : AI) ซึ่งเป็นวิธีในการจำลองความสามารถของบุคคลกับเครื่องคอมพิวเตอร์ให้มีการคิดซึ่งมีรูปแบบ การหาเหตุผล การรับรู้ และ ความฉลาดเหมือนมนุษย์ การประยุกต์ใช้วิธี AI ในการพยากรณ์ปัจจุบันมีสองแนวทางสำคัญ ได้แก่ วิธีนิรนัยและวิธีจำลองเซลล์เครือข่ายประสาทของสมองมนุษย์ที่ใช้ในการคิดตัดสินใจเหตุการณ์ต่าง ๆ และวิธีระบบผู้เชี่ยวชาญซึ่งเป็นการอาศัยองค์ความรู้ของผู้เชี่ยวชาญมาใช้งานด้านการพยากรณ์

ระบบผู้เชี่ยวชาญ คือ โปรแกรมคอมพิวเตอร์ที่ประกอบไปด้วยองค์ความรู้สำหรับแก้ปัญหาที่สำคัญต่าง ๆ โดยใช้กลไกการอนุมาน (Inference Engine) เป็นองค์ประกอบหลักในการทำงาน เพื่อเลียนแบบการใช้ประสบการณ์ของผู้เชี่ยวชาญในการคิดวิเคราะห์ปัญหาต่าง ๆ ด้วยการจำลองการหาเหตุผล การประมวลผล การคิดวิเคราะห์และตัดสินใจ จากองค์ความรู้ที่เก็บไว้ในรูปแบบของกฎการตัดสินใจหรือกฎผู้เชี่ยวชาญ (Rule-based Expert System) ให้มีขีดความสามารถที่ใกล้เคียงกับสติปัญญาของมนุษย์

ความพยายามในการนำความรู้ของผู้เชี่ยวชาญมาประยุกต์ใช้ในการพยากรณ์ให้มีความถูกต้องมากยิ่งขึ้นเป็นสิ่งที่นักวิจัยเริ่มให้ความสนใจ Collopy and Armstrong (1992) ประยุกต์ใช้ความรู้จากผู้เชี่ยวชาญมาสร้างกฎการพยากรณ์ เพื่อให้ผลการพยากรณ์มีความถูกต้องมากยิ่งขึ้น Collopy และ Armstrong ได้สร้างกฎการพยากรณ์ที่มีความยืดหยุ่นและสอดคล้องกับลักษณะข้อมูลในขั้นแรกทำการจำแนกลักษณะเด่นของข้อมูลความต้องการออกเป็น 28 ลักษณะ (Demand features) และได้เลือกลักษณะบางส่วนมาสร้างเป็นกฎการพยากรณ์ อาทิเช่น การเกิดแนวโน้มของข้อมูลที่ชัดเจน (Strong trend) และการเปลี่ยนระดับข้อมูล (Level discontinuity) เป็นต้น เครื่องมือ

การพยากรณ์ที่พัฒนาขึ้นถูกนำไปทดสอบและประเมินผล ซึ่งสรุปได้ว่าวิธีการพยากรณ์โดยอาศัยกฎผู้เชี่ยวชาญให้ผลการพยากรณ์ที่มีความถูกต้องมากกว่าวิธีอนุกรมเวลาแบบต่าง ๆ

Monica et al. (2000) ปรับปรุงกฎการพยากรณ์ต่อจาก Collopy และ Armstrong เกี่ยวกับลักษณะการให้ค่าน้ำหนักของกฎการพยากรณ์ โดยใช้หลักสถิติและความรู้จากปัญหา (Domain knowledge) มาปรับปรุงในส่วนสำคัญ 3 ส่วนคือ ส่วนแรก การให้ค่าน้ำหนักเกี่ยวกับผลกระทบที่คาดเดาไม่ได้ (Causal force) ส่วนที่สอง การสร้างกระบวนการตรวจสอบลักษณะเด่นของข้อมูลอนุกรมเวลา 6 ลักษณะโดยอัตโนมัติ ได้แก่ 1) ข้อมูลที่โดดมากผิดปกติ (Outlier) 2) ข้อมูลที่มีความผิดปกติในช่วงท้าย (Unusual last observation) 3) ข้อมูลที่มีการเปลี่ยนแปลงแนวโน้มพื้นฐาน (Changing basic trend) 4) ข้อมูลที่มีการเพิ่ม/ลดระดับอย่างชัดเจน (Level discontinuity) 5) ข้อมูลที่มีความไม่แน่นอนในช่วงแนวโน้มที่เพิ่งผ่านมา (Unstable recent trend) และ 6) ข้อมูลที่สามารถกำหนดรูปแบบได้ (Functional form) และส่วนที่สาม การลดจำนวนกฎการพยากรณ์ลงจาก 99 กฎ เหลือ 64 กฎ ซึ่งในการปรับปรุงกฎการพยากรณ์ครั้งนี้สร้างความถูกต้องในการพยากรณ์มากขึ้นกว่าการให้ค่าน้ำหนักเท่า ๆ กัน และมีความเหมาะสมกับข้อมูลที่มีลักษณะ เป็นแบบรายปี

Adya et al. (2001) ได้พัฒนาเครื่องมือการพยากรณ์ด้วยกฎผู้เชี่ยวชาญ โดยเน้นในส่วนของการพัฒนาการตรวจสอบลักษณะเด่นของข้อมูลแบบอัตโนมัติทั้ง 6 ลักษณะที่กล่าวไว้ข้างต้น ด้วยการให้หลักการวัดค่าทางสถิติแบบง่าย ๆ เช่น ค่าเฉลี่ย และค่าความแปรปรวน เป็นต้น และนำข้อมูลที่ตรวจสอบได้ไปใช้ในการปรับปรุงวิธีการพยากรณ์ให้มีประสิทธิภาพมากยิ่งขึ้น

ในปี 2000 Flores และ Pearce ทำการสร้างระบบผู้เชี่ยวชาญขึ้นเพื่อใช้พยากรณ์ข้อมูลของ M3-Competition โดยแบ่งกฎออกเป็นสองส่วนที่สำคัญ ได้แก่ กฎที่ใช้ในการตรวจสอบลักษณะของข้อมูลด้วยวิธีทางสถิติ โดยการตรวจสอบลักษณะการเปลี่ยนแปลงระดับข้อมูล ความผิดปกติหรือข้อมูลที่โดดมากผิดปกติ การเกิดลักษณะแนวโน้มของข้อมูล และการเกิดฤดูกาลของข้อมูล กฎอีกส่วนหนึ่งคือกฎในการเลือกทฤษฎีการพยากรณ์ต่าง ๆ ที่เหมาะสมกับรูปแบบของข้อมูลที่พบในกฎส่วนแรก โดยในแต่ละทฤษฎีจะแยกออกเป็นแบบพยากรณ์โดยมีฤดูกาลของข้อมูลและโดยไม่มีฤดูกาลของข้อมูล ซึ่งโมเดลระบบผู้เชี่ยวชาญนี้ยังแบ่งออกเป็นสามส่วนที่สามารถใช้คนมามีส่วนช่วยในการกำหนดรูปแบบการพยากรณ์หรือการตัดสินใจในการพยากรณ์บางจุด และส่วนที่ระบบผู้เชี่ยวชาญพยากรณ์เองทั้งหมด ผลการทดลองพบว่าผลการพยากรณ์ข้อมูลรายปี รายสามเดือน และอื่น ๆ ได้ค่าเฉลี่ยไม่แตกต่างกันทางสถิติหรือเป็นไปในแนวทางเดียวกันในแต่ละระยะการพยากรณ์ เว้นแต่ข้อมูลการทดลองรายเดือนซึ่งให้ผลการทดลองแตกต่างกันทางสถิติซึ่งเป็นประเด็นที่ผู้ทดลองให้แนวคิดไว้สำหรับการขยายต่อการวิจัยในอนาคตเกี่ยวกับความแตกต่างดังกล่าว

ตารางที่ 2.1 รายละเอียดสรุปงานวิจัยการใช้ระบบผู้เชี่ยวชาญในงานด้านการพยากรณ์ที่ศึกษา  
เปรียบเทียบกับแนวทางในการพัฒนาสำหรับงานวิจัยนี้

ผู้วิจัย	รูปแบบข้อมูล	Seasonal	Trend	Level Shift	Usual	Causal	Outlier	รูปแบบอื่น ๆ ที่ใช้ในงานวิจัย	วิธีการแก้ไข
Celopy & Armstrong (1992)		✓	✓	✓	-	✓	✓	- Irrelevant Early Data - Suspicious Pattern - Unstable Recurs Trend - IRI	- random walk - linear regression - Holt's linear exponential smoothing - Brown's linear exponential smoothing
Mexican (1996)		-	✓	✓	-	✓	✓	- Functional form - Unstable Recurs Trend	- random walk - linear regression - Holt's linear exponential smoothing - Brown's linear exponential smoothing - Brown's Exponential smoothing
Adya (1998)		-	✓	✓	-	✓	✓	- functional form - Unstable Recurs Trend	- random walk - linear regression - Holt's linear exponential smoothing - Brown's linear exponential smoothing - Brown's Exponential smoothing
Fisher, B.E. and Penner, S.L (2000)		✓	✓	-	-	-	✓	- irrelevant early data	- Simple exponential smoothing without seasonality - Simple exponential smoothing with seasonality - Six-year moving average - Gardner's damped trend exponential smoothing without seasonality - Gardner's damped trend exponential smoothing seasonality - Classical decomposition without seasonality - Classical decomposition with seasonality - A combination approach which averages the forecast of all other methods
การวิจัยนี้		✓	✓	✓	✓	✓	✓		- Monte Carlo Simulation - Moving Average - Naive - Growth rate forecasting

จากตารางที่ 2.1 แสดงการสรุปรายละเอียดต่าง ๆ เกี่ยวกับการนำระบบผู้เชี่ยวชาญมาใช้ในงานด้านการพยากรณ์ที่ได้กล่าวถึงทั้งหมดในหัวข้อนี้ โดยรายละเอียดแสดงเป็นตารางแยกข้อมูลในส่วนของการตรวจสอบลักษณะของข้อมูล และทฤษฎีที่ใช้ในการพยากรณ์ของระบบที่ผู้วิจัยแต่ละกลุ่มทำการพัฒนาขึ้น เพื่อสะดวกในการเปรียบเทียบกับกรอบแบบที่เลือกใช้ในงานวิจัยนี้

#### 2.4 การวัดผลการพยากรณ์ (Forecasting evaluation)

เป็นการประเมินผลการพยากรณ์เพื่อจะบอกว่าเครื่องมือการพยากรณ์ใดมีประสิทธิภาพ ซึ่งเราให้ความสำคัญกับองค์ประกอบ 2 ส่วนคือ 1) ความง่ายและความสะดวกในการประยุกต์ใช้งาน และ 2) ความถูกต้องในการพยากรณ์ เราเปรียบเทียบผลความถูกต้องโดยใช้ค่าเฉลี่ยร้อยละความผิดพลาดสัมบูรณ์ (Mean absolute percentage error: MAPE) ค่ามัธยฐานร้อยละความผิดพลาดสัมบูรณ์ (Median absolute percentage error: MdAPE) ซึ่งมีค่าอยู่ระหว่างร้อยละ 0 – 100, MAPE และ MdAPE ยังมีค่าน้อยแสดงว่า ผลการพยากรณ์ใกล้เคียงกับข้อมูลจริงมากกว่าการใช้ MdAPE เพื่อ

ช่วยในการวัดค่ากลางของความผิดพลาดและการกระจายตัวของค่าความผิดพลาด ค่า MAPE และ MdAPE สามารถคำนวณได้ดังสมการที่ (2.6) และ (2.7) ตามลำดับ (Hibon et al., 2003)

$$MAPE = \frac{\sum_{t=1}^n \left| \frac{X_t - F_t}{X_t} \right| \times 100}{n} \quad (2.6)$$

$$MdAPE = \text{median} \left( \left| \frac{X_t - F_t}{X_t} \right| \times 100 \right) \quad (2.7)$$

โดยที่  $X_t$  คือ ค่าความต้องการจริงในช่วงเวลา (หรือตัวอย่างข้อมูล ชุดที่  $t$ )  
 $F_t$  คือ ค่าพยากรณ์ในช่วงเวลา  $t$   
 $n$  คือ จำนวนข้อมูล

เครื่องมือการวัดผลการพยากรณ์อีกลักษณะหนึ่งที่ใช้ในการวิจัยครั้งนี้เป็นเครื่องมือที่ใช้ในการเปรียบเทียบผลการทดลองของ Makridakis & Hibon (2000) กับข้อมูลของ M3-Competition คือ Symmetric mean absolute percentage error (sMAPE) ดังสมการ (2.8)

$$sMAPE = \sum \frac{|X - F|}{(X + F)/2} * 100 \quad (2.8)$$

โดยที่  $X$  คือ ค่าความต้องการจริง  
 $F$  คือ ค่าพยากรณ์

โดยค่าของ sMAPE ซึ่งเป็นวิธีที่แก้ปัญหาค่าความผิดพลาดมาก ๆ ในการวัดผลการพยากรณ์ กรณีที่ข้อมูลจริง เป็น 0 และกรณีความแตกต่างกันในการวัดผลพยากรณ์ด้วยค่า MAPE ระหว่างค่าพยากรณ์มากกว่าค่าจริงกับค่าพยากรณ์น้อยกว่าค่าจริง ซึ่งค่าพยากรณ์จะอยู่ระหว่าง -200% ถึง 200%

## 2.5 ข้อมูลและการแข่งขันของ M3-Competition

ในช่วงเวลากว่า 20 ปีที่ผ่านมา มีการจัดการแข่งขันด้านการพยากรณ์ระดับโลกที่สำคัญ ต่อเนื่องกัน 3 ครั้ง คือ M-Competition, M2-Competition และ M3-Competition ด้วยชุดข้อมูล และ โมเดลการพยากรณ์ต่าง ๆ ซึ่งได้ผลการทดลองและข้อสรุปต่าง ๆ ที่น่าสนใจดังนี้

M-Competition เป็นการแข่งขันที่จัดขึ้นครั้งแรกในปี 1982 หรือ โดย Makridakis ซึ่ง ข้อมูลที่ใช้ในการแข่งขันประกอบไปด้วยข้อมูลในหลายรูปแบบทั้งประเภทรายเดือน รายไตรมาส และรายปี โดยมาจากข้อมูลทางบริษัทธุรกิจ เศรษฐศาสตร์ และสถิติจำนวนประชากร รวม 1,001 อนุกรมเวลา โมเดลที่ใช้ในการแข่งขันเพื่อเปรียบเทียบความแม่นยำในการพยากรณ์ ได้แก่ Naive, Single Exponential Smoothing, Double Exponential Smoothing, Adaptive Response Rate, Exponential Smoothing, Holt, Winters, Box-Jenkins รวมถึงเทคนิคเฉพาะบุคคลอื่น ๆ เป็นต้น ซึ่ง ในภาพรวมของการแข่งขันวัดด้วยค่า MAPE นั้นวิธี Deseasonalized Single Exponential Smoothing เป็นเทคนิคที่ให้ความแม่นยำมากที่สุด นอกจากนี้ยังได้ข้อสังเกตที่น่าสนใจ เช่น การ ผสมค่าพยากรณ์ด้วยค่าการถ่วงน้ำหนักที่ต่างกันของหลาย เทคนิคช่วยให้ได้ความแม่นยำเพิ่มขึ้น วิธีการที่ซับซ้อนไม่มีประสิทธิภาพกว่าวิธีการที่ง่าย

ต่อมา Makridakis ได้จัดการแข่งขันการพยากรณ์ ขึ้นอีกในปี 1993 เรียกการแข่งขันครั้งนี้ ว่า M2-Competition ซึ่งเป็นการแข่งขันในแบบเวลาจริง (Real-time) จำนวน 29 อนุกรมเวลา ประกอบไปด้วยข้อมูลพื้นฐานในการทำงานประมาณของบริษัท และข้อมูลทางเศรษฐศาสตร์มหภาค ในการแข่งขันครั้งนี้จึงใช้เวลาในการแข่งขันนาน 3-4 ปี เนื่องจากต้องรอข้อมูลจริงที่จะเกิดขึ้น เพื่อทดสอบผลการพยากรณ์ ในส่วนของโมเดลการพยากรณ์ที่ใช้ในการแข่งขันประกอบไปด้วย โมเดลจาก M-Competition บางส่วน และมีเทคนิคใหม่ ๆ เพิ่มขึ้นมาเช่น Dampen Trend Models หรือ Dampen นอกจากนี้ยังใช้ผู้เชี่ยวชาญด้านการพยากรณ์มาทำการพยากรณ์ร่วมด้วยจำนวน 5 คน โดยผู้เชี่ยวชาญเหล่านี้สามารถสอบถามข้อมูลใด ๆ ก็ได้เพื่อเป็นประโยชน์ในการพยากรณ์ข้อมูล ผลการทดลองวัดด้วยค่า MAPE ปรากฏว่าวิธี Dampen มีความแม่นยำรวมสูงสุด รองลงมาคือ Single Exponential Smoothing ส่วนประเด็นที่น่าสนใจสำหรับการทดลองในครั้งนี้คือ การคำนึงถึง ปัจจัยด้านฤดูกาลของข้อมูลมีผลให้ความแม่นยำในการพยากรณ์เพิ่มขึ้น และการพยากรณ์โดยใช้ บุคคลไม่ได้แม่นยำไปกว่าการพยากรณ์โดยใช้โมเดล

และในปี 1997 การแข่งขัน M3-Competition ก็ถูกจัดขึ้นโดยใช้ฐานข้อมูลอนุกรมเวลา 3,003 รายการ ประกอบไปด้วยข้อมูลในลักษณะต่าง ๆ แบ่งเป็นแบบ รายปี รายสามเดือน รายเดือน และอื่น ๆ โดยข้อมูลส่วนใหญ่จะเป็นข้อมูลรายเดือน ในส่วนของโมเดลการพยากรณ์แบ่งออกเป็น 6 ประเภท คือ ประเภทง่าย (Naive/ Simple), ประเภทใช้รูปแบบแนวโน้มที่ชัดเจน (Explicit Trend

Model), ประเภทตัวแบบ ARIMA/ARAMA (ARIMA/ARARMA Models), ประเภท ประนีประนอม (Eclectic), ประเภทระบบผู้เชี่ยวชาญ (Expert System) และประเภทเครือข่ายประสาทหรือการเรียนรู้แบบเครื่องจักร (Neural Networks/Machine Learning) ผลการทดลองวัดด้วยค่า MAPE พบว่าวิธีการของซอฟต์แวร์ Forecast Pro3 ซึ่งเป็นวิธีการที่อยู่ในกลุ่มประเภท ประนีประนอม (Eclectic) เป็นวิธีการที่ให้ผลความแม่นยำมากที่สุด ข้อเสนอของการแข่งขันในครั้งนี้คือ 1) การใช้วิธีทางสถิติหรือวิธีการที่ซับซ้อนอาจจะไม่ได้ผลการพยากรณ์ที่ดีไปกว่าการพยากรณ์ที่ง่าย ๆ บางวิธี 2) ผลการพยากรณ์เปรียบเทียบกันแต่ละวิธีขึ้นอยู่กับวิธีการพยากรณ์ที่ใช้ 3) การผสมค่าพยากรณ์ได้ผลดีกว่าการพยากรณ์แบบเดี่ยว ๆ 4) ความแม่นยำของแต่ละทฤษฎีขึ้นอยู่กับความไกลของการพยากรณ์ (Makridakis & Hibon, 2000)

## สรุป

วิธีการที่นำเสนอนี้ เป็นการประยุกต์ใช้วิธีของผู้เชี่ยวชาญในการพยากรณ์เพื่อปรับปรุงวิธีการพยากรณ์ที่ทำการศึกษาให้มีความแม่นยำและยืดหยุ่นในการพยากรณ์มากขึ้น เนื่องจากวิธีดังกล่าวมีลักษณะเป็นการเลียนแบบลักษณะการคิดหรือตัดสินใจของผู้เชี่ยวชาญที่เป็นมนุษย์ซึ่งมีประสบการณ์ในด้านใดด้านหนึ่งโดยเฉพาะเป็นฐานความรู้สะสมไว้เพื่อช่วยในการคิดและตัดสินใจ โดยประเด็นที่สำคัญของการพัฒนาเพื่อสร้างกฎในการเลือกวิธีการพยากรณ์ให้เหมาะสมกับลักษณะของข้อมูลที่เกิดขึ้นเนื่องจากวิธีเดิมส่วนใหญ่จะเป็นการใช้วิธีใดวิธีหนึ่งในการพยากรณ์ซึ่งบางครั้งวิธีการดังกล่าวไม่เหมาะสมกับลักษณะของข้อมูล และวิธีระบบผู้เชี่ยวชาญด้านการพยากรณ์อื่นที่นำเสนอเป็นวิธีที่ยังไม่มีลักษณะที่เหมาะสมกับข้อมูลบางลักษณะเช่น ข้อมูลที่มีฤดูกาล หรือข้อมูลที่มีความไม่แน่นอนสูง โดยในบทที่ 3 จะแสดงส่วนของการออกแบบกฎการพยากรณ์ที่พัฒนาขึ้น โดยแสดงผลการทดลองและสรุปผลการทดลองในบทที่ 4 และ บทที่ 5 ตามลำดับ