

## บทที่ 2

### เทคนิคการพยากรณ์เชิงปริมาณ

เทคนิคการพยากรณ์เชิงปริมาณสามารถแบ่งเป็นประเภทใหญ่ ๆ 2 ประเภท คือประเภทที่ 1 ค่าพยากรณ์อาศัยข้อมูลที่เกิดขึ้นในอดีตเป็นพื้นฐานปัจจัยสำคัญ โดยมีได้อาศัยปัจจัยอื่น ๆ ภายนอกเลย ดังนั้นข้อมูลที่ใช้ในการพยากรณ์อาจจะใช้จำนวนน้อยได้ แต่ข้อสำคัญอยู่ที่การเลือกเทคนิควิธีการพยากรณ์ การตัดสินใจเลือกใช้วิธีหนึ่ง ๆ ให้เหมาะสมกับสถานการณ์ปัญหาหนึ่ง ๆ จะมีความสำคัญมากกว่า เทคนิควิธีการพยากรณ์ประเภทนี้มี Naive , Smoothing techniques , Time series , Box-Jenkins , Adaptive filtering เป็นต้น ประเภทที่ 2 ค่าพยากรณ์ได้ถูกกำหนดขึ้นโดยความสัมพันธ์บางลักษณะกับข้อมูลที่จะพยากรณ์ การพยากรณ์วิธีนี้จึงต้องอาศัยข้อมูลของสิ่งอื่น ๆ ที่อาจจะมากระทบต่อสิ่งที่พยากรณ์ แต่ก็ยังต้องใช้ข้อมูลในอดีตมาช่วยในการพยากรณ์ด้วย เทคนิคที่ใช้มี การวิเคราะห์การถดถอย ( Regression analysis ) , การพยากรณ์เชิงเศรษฐมิติ ( Econometric forecasting )

เทคนิควิธีการพยากรณ์แบบต่าง ๆ จะเหมาะสมกับสถานการณ์ในการพยากรณ์ข้อมูลในอดีตที่ใช้ปัจจัยที่ต้องคำนึงถึงที่ได้กล่าวไว้แล้วในบทที่ 1 สามารถเลือกวิธีการพยากรณ์ได้ โดยแต่ละวิธีมีรายละเอียดการคำนวณและความเหมาะสมที่จะเลือกใช้ดังต่อไปนี้

#### 1. วิธีของ Naive

วิธีวิเคราะห์อนุกรมเวลาที่ง่ายที่สุด คือ NFI ( Naive forecasting I ) วิธีนี้ เป็นการนำค่าข้อมูลจริงเมื่อเวลาปัจจุบันที่สุดใช้เป็นค่าพยากรณ์ในช่วงเวลาถัดไป ดังนั้นความต้องการของสินค้าสำหรับสัปดาห์ถัดไปจะถูกทำนายจากยอดขายของสัปดาห์นี้ ซึ่งหมายความว่าเราจะให้น้ำหนัก 1.0 สำหรับยอดขายในสัปดาห์นี้ และให้น้ำหนัก 0.0 สำหรับยอดขายในสัปดาห์ก่อนหน้า ถ้าข้อมูลอนุกรมเวลาจำนวนมากที่พยากรณ์แสดงรูปแบบปัจจัยฤดูกาล วิธีที่เหมาะสมที่สุดที่ควรนำมาใช้ คือ Naive II วิธีนี้ใช้ค่าข้อมูลที่ปัจจุบันที่สุดเป็นฐานสำหรับการพยากรณ์ แต่ได้กำจัดปัจจัยฤดูกาลของข้อมูลปัจจุบันนั้น จากนั้นนำค่าข้อมูลที่ปราศจากปัจจัยฤดูกาลมาปรับใหม่แล้วใช้เป็นค่าพยากรณ์ต่อไป

สิ่งสำคัญในการประยุกต์วิธี Naive เพื่อไปใช้ในการพยากรณ์ คือ ความถูกต้องแม่นยำเป็นพื้นฐานเปรียบเทียบกับทางเลือกอื่น มันไม่ธรรมดาที่ค้นพบวิธี Naive วิธีหนึ่งที่จะให้ความถูกต้องเพียงพอสำหรับสถานการณ์แน่นอน มันอาจจะเป็นกรณีที่เสียค่าใช้จ่ายแพงกว่าแต่ไม่ให้ความถูกต้องเพียงพอที่จะนำไปประยุกต์ใช้ได้

## 2. วิธีเฉลี่ยเคลื่อนที่ ( Moving average )

เมื่อช่วงการพยากรณ์สั้นการสุ่มค่าข้อมูลมา เช่นวิธี Naive เป็นทางเลือกหนึ่ง อีกทางเลือกหนึ่งที่จะลดอิทธิพลจากการสุ่มบนค่าพยากรณ์ที่แตกต่างกัน คือการหาค่าเฉลี่ยของค่าข้อมูลในอดีตจำนวนมาก วิธีเฉลี่ยเคลื่อนที่จึงเป็นอีกวิธีหนึ่งซึ่งง่ายในการลดอิทธิพลที่เกิดจากการสุ่ม วิธีการคือให้หาค่าเฉลี่ยของค่าข้อมูล  $N$  ค่าชุดแรกในอดีต จากนั้นตัดค่าข้อมูลค่าแรกที่เก็บรวบรวมมาออกแล้วนำค่าข้อมูลที่  $N+1$  เข้ามาหาค่าเฉลี่ย กระทำเช่นนี้เรื่อยไป วิธีการเฉลี่ยเคลื่อนที่ที่เหมาะสมสำหรับใช้ในการพยากรณ์ช่วงระยะสั้น และค่า ของข้อมูลต้องไม่เปลี่ยนแปลงมาก เช่น

$$F_{t+1} = 1/N [ X_t + X_{t-1} + \dots + X_{t-N+1} ]$$

เมื่อ  $F_{t+1}$  เป็นค่าพยากรณ์ในวาระที่  $t+1$        $X_t$  เป็นค่าข้อมูล ณ วาระ  $t$

$X_{t-1}$  เป็นค่าข้อมูล ณ วาระ  $t-1$        $X_{t-N+1}$  เป็นค่าข้อมูล ณ วาระ  $t-N+1$

$N$  เป็นจำนวนข้อมูลที่ต้องการทำการเฉลี่ยหรือจำนวนเวลา

นอกจากนี้ยังมีวิธีการของ Double Moving Average สามารถดูรายละเอียดได้ในบทที่ 3

## 3. เทคนิคทำให้เรียบของเอกซ์โปเนนเชียล ( Exponential Smoothing )

วิธีการพยากรณ์ข้อมูลอนุกรมเวลาจะเหมือนกับวิธีการเฉลี่ยเคลื่อนที่ แต่ไม่ใช่ตัวถ่วงน้ำหนักที่คงที่สำหรับข้อมูลปัจจุบัน โดยจะให้ตัวถ่วงน้ำหนักสำหรับข้อมูลปัจจุบัน ที่เพิ่งได้รับเข้ามา มากกว่าข้อมูลเก่าหรือข้อมูลในอดีต แนวความคิดที่ให้น้ำหนักมากกว่า สำหรับข้อมูลข่าวสารที่ปัจจุบันกว่านี้เป็นการหยั่งรู้อย่างมากอันหนึ่ง สำหรับผู้บริหาร และ ทำให้มีความหมายบนการศึกษาความถูกต้องของวิธี Exponential Smoothing วิธีการคำนวณของวิธีพยากรณ์นี้ไม่มีความจำเป็นที่จะต้องเก็บค่าข้อมูลในอดีตทั้งหมดก่อนการพยากรณ์ ข้อมูลที่ต้องการมีเพียงตัวถ่วงน้ำหนักที่จะกำหนดให้สำหรับข้อมูลปัจจุบัน ที่สุด ( ตัวถ่วงน้ำหนักนี้เรียกว่า เอลฟา  $\alpha$  ) และ ตัวถ่วงน้ำหนักสำหรับค่าพยากรณ์ ที่ปัจจุบันที่สุด มีที่แตกต่างกันมากมาย ที่มีลักษณะใกล้เคียงกับ Exponential Smoothing ซึ่งมีรายละเอียดในผลงานการเขียนบนพื้นฐานหลักการง่าย ๆ ที่จะใช้ตัวถ่วงน้ำหนักลดลงสำหรับค่าข้อมูลก่อนหน้า การแปรผันนี้ค้นพบโดยทำการปรับค่าสำหรับบางสิ่งบางอย่าง เช่นรูปแบบของแนวโน้มและรูปแบบฤดูกาล เมื่อมีการปรับค่าแล้วจะหมายถึงเทคนิคการพยากรณ์ที่สูงกว่า Exponential Smoothing ซึ่งจะกล่าวถึงรายละเอียดต่อไป

## 4. Adaptive Filtering

วิธีการพยากรณ์แบบ Adaptive Filtering เป็นวิธีที่จะใช้ในการตัดสินใจเกี่ยวกับการกำหนดพารามิเตอร์ (หรือตัวถ่วงน้ำหนัก) ของข้อมูลในอดีต เพื่อให้ค่าความคลาดเคลื่อนที่เกิดขึ้นมีค่าน้อยที่สุด ขณะที่การถ่วงน้ำหนักของวิธี Exponential Smoothing และ Moving Average มีเกณฑ์การกำหนดตัวถ่วงน้ำหนักที่แน่นอนคือวิธี Exponential Smoothing จะกำหนดตัวถ่วงน้ำหนักที่มากกว่า

ให้กับข้อมูลจริงที่ปัจจุบันที่สุด และวิธี Moving Average จะกำหนดตัวถ่วงน้ำหนักเท่ากันสำหรับข้อมูลทุกตัว แต่ของวิธี Adaptive Filtering จะค่อย ๆ ค้นหาโดยการคำนวณขนาดของตัวถ่วงน้ำหนักที่ optimal ที่สุด โดยการคำนวณขนาดของตัวถ่วงน้ำหนักวนไปเรื่อย ๆ ก็รอบก็ตาม โดยให้มีเซตตัวถ่วงน้ำหนัก ที่ได้มีค่าคงที่ค่าใดค่าหนึ่ง ดังนั้น วิธีการของ Adaptive Filtering จะคล้ายกับวิธีของ Box-Jenkins ยกเว้นถ้าใช้กระบวนการที่ต่างกันในการเลือกตัวแบบที่เหมาะสมที่สุด และการทำให้ค่าพารามิเตอร์ optimal วิธี Adaptive Filtering เป็นวิธีที่ง่ายต่อการใช้ต้องการความรู้ในการดำเนินการน้อยมาก ใช้เวลาในการดำเนินการทางคอมพิวเตอร์น้อยกว่าเมื่อเทียบกับตัวแบบเดียวกันที่ใช้ใน Box-Jenkins ข้อแตกต่างของสองวิธีนี้ ก็ค่าพารามิเตอร์จะเปลี่ยนแปลงไปด้วยค่าข้อมูลทุกตัวใน Adaptive Filtering ขณะที่วิธีของ Box-Jenkins ค่าพารามิเตอร์จะคงที่ สิ่งนี้จึงเป็นข้อได้เปรียบเสียเปรียบสำหรับข้อมูลอนุกรมเวลาบางชุด การหาค่าพยากรณ์หาได้จากสูตร

$$F_{t+1} = w_1 X_t + w_2 X_{t-1} + w_3 X_{t-2} + \dots + w_N X_{t-N+1}$$

เมื่อ  $F_{t+1}$  เป็นค่าพยากรณ์ในวาระที่  $t+1$   $X_t$  เป็นค่าข้อมูลจริง ณ วาระ  $t$

$w_1, w_2, w_3, \dots, w_N$  เป็นขนาดของตัวถ่วงน้ำหนัก  $N$  เป็นจำนวนตัวถ่วงน้ำหนัก

$t$  เป็นคาบเวลาที่ทำการพยากรณ์ โดย  $t = N, N+1, N+2, \dots$

และการปรับค่าตัวถ่วงน้ำหนักจนกว่าจะได้ค่าถ่วงน้ำหนักที่ optimal สามารถคำนวณหาได้จากสูตร

$$w_i' = w_i + 2k e_{t+1} X_{t-i+1} \quad \text{เมื่อ } i = 1, 2, \dots, N$$

และ  $w_i'$  เป็นค่าตัวถ่วงน้ำหนักตัวที่  $i$  หลังจากได้ปรับค่าแล้ว

$w_i$  เป็นค่าตัวถ่วงน้ำหนักตัวที่  $i$  ก่อนการปรับค่า

$k$  เป็นค่าคงที่ หรือ learning constant

$e_{t+1}$  เป็นค่าความคลาดเคลื่อนจากการพยากรณ์ ณ วาระ  $t+1$

$X_{t-i+1}$  เป็นค่าข้อมูลจริง ณ วาระ  $t-i+1$

กระบวนการปรับค่าตลอดจนถึงรายละเอียดในการดำเนินการพยากรณ์ศึกษารายละเอียดได้ในบทต่อไป วิธีนี้ให้ผลการพยากรณ์ดีกว่าวิธีทำให้เรียบ (Smoothing technique) แต่มีข้อจำกัดตรงการกำหนดค่า learning constant ซึ่งถ้ากำหนดค่า  $k$  น้อยเกินไป การปรับค่าตัวถ่วงน้ำหนักเพื่อให้ได้ค่า optimal จะเป็นกระบวนการที่ดำเนินไปอย่างช้า ๆ แต่ถ้ากำหนดค่า  $k$  มากเกินไป ค่าถ่วงน้ำหนักก็จะไปสู่ค่า optimal อย่างรวดเร็วหรืออาจจะไม่ได้ค่าที่ optimal ได้ ดังนั้นการกำหนดค่า  $k$  ต้องอาศัยผู้เชี่ยวชาญมีประสบการณ์ในการพยากรณ์

## 5. วิธี Box-Jenkins

ข้อมูลอนุกรมเวลาที่ไม่มียูนิฟอร์มของปัจจัยแนวโน้ม หรือปัจจัยวัฏจักรหรือปัจจัยฤดูกาลที่เด่นชัดแล้วเหมาะที่จะใช้วิธีการพยากรณ์ที่สำคัญคือวิธีนี้ไม่จำเป็นต้องมีการกำหนดรูปแบบขึ้นก่อนทำการวิเคราะห์ แต่ระหว่างที่ทำการวิเคราะห์รูปแบบของการพยากรณ์จะถูกกำหนดขึ้นนั่นเอง ซึ่งตัวแบบที่ได้จะให้ค่าความคลาดเคลื่อนต่ำ เทคนิควิธีการพยากรณ์แบบนี้จะให้รายละเอียดข้อมูลที่ต้องการอย่างชัดเจน ถ้ารูปแบบที่กำหนดนำมาใช้อย่างถูกต้อง และถ้ารูปแบบที่กำหนดไม่ถูกต้องวิธีการวิเคราะห์ที่จัดขึ้นจะเป็นตัวชี้ว่า สำหรับหารูปแบบที่ถูกต้องเอง ดังนั้นวิธีการพยากรณ์ของ Box-Jenkins ให้รายละเอียดข้อมูลเพียงพอที่จะแยกแยะรูปแบบที่กำหนดสำหรับอย่างดีที่สุดที่สามารถประมาณค่าพารามิเตอร์รวมถึงให้ค่ากำลังสองของความคลาดเคลื่อนต่ำที่สุด นอกจากนี้ยังสามารถพิจารณาตรวจสอบค่าความคลาดเคลื่อนเพื่อใช้ในการตัดสินใจเกี่ยวกับการกำหนดรูปแบบหนึ่ง ๆ ด้วย หลักการวิเคราะห์ข้อมูลโดยวิธีเทคนิคการพยากรณ์ Box-Jenkins มีดังนี้

1. plot จุดที่ค่าข้อมูลเพื่อพิจารณาว่าข้อมูลอนุกรมเวลามีรูปแบบใด
2. เพื่อให้การตัดสินใจในรูปแบบของ ข้อ 1 ถูกต้องหรือไม่ ให้วิเคราะห์ค่าสหสัมพันธ์ในตัวเอง ( autocorrelation ) และค่าสหสัมพันธ์ในตัวเองบางส่วน ( partial autocorrelation ) จากข้อมูลอนุกรมเวลาชุดเดิม โดยลงจุด เขียนกราฟของค่าที่ได้ กราฟของ autocorrelation และ partial autocorrelation ที่ได้เปรียบเทียบกับรูปแบบของแต่ละ model
3. model ที่ได้ให้ประมาณค่าพารามิเตอร์จากตัวแบบ และตรวจสอบความถูกต้องของตัวแบบ โดยดูจากกราฟของ residual ผลการวิเคราะห์ residual ตรวจสอบดูว่าตัวแบบที่กำหนดให้ นั้นถูกต้องหรือไม่ ถ้าไม่ถูกต้องให้กลับไปพิจารณาตัวแบบใหม่ในข้อ 2 แต่ถ้าตัวแบบถูกต้องแล้วให้นำไปใช้ในการพยากรณ์ได้

## 6. วิธีอนุกรมเวลา ( Classical Time Series or Classical Decomposition )

เทคนิคการพยากรณ์ส่วนใหญ่พยายามที่จะสร้างรูปแบบภายใต้ข้อมูลเดิมจากการสุ่ม ดังนั้นรูปแบบที่ได้เป็นการวางแผนอนาคตและใช้ในการพยากรณ์ได้ แต่ไม่มีความพยายามที่จะสร้างส่วนย่อยของรูปแบบพื้นฐานที่ได้ ในหลาย ๆ กรณีรูปแบบที่ได้สามารถแตกเป็นส่วนย่อยเพื่อความถูกต้องแม่นยำมากขึ้นในการพยากรณ์ ตัวอย่างเช่น เมื่อมีปัจจัยวัฏจักร ( C ) หรือ ปัจจัยฤดูกาล ( I ) พร้อมทั้งมีแนวโน้ม ( T ) เพิ่มขึ้นหรือลดลงในข้อมูล มันเป็นสิ่งสำคัญที่จะรู้ เมื่อค่าสูงกว่าเกิดขึ้นเพราะปัจจัยแนวโน้ม และอาจจะกำหนดขึ้นจากสภาพภูมิอากาศ , วันหยุด และวัฏจักรทางธุรกิจ เป็นต้น

โดยปกติแล้ววิธีวิเคราะห์อนุกรมเวลาจะพยายามแยกส่วนต่าง ๆ ของรูปแบบเป็น 3 ปัจจัย

คือ ปัจจัยแนวโน้ม (Trend factor) , ปัจจัยวัฏจักร (Cyclical factor) , ปัจจัยฤดูกาล (Seasonal factor) และ นอกจากนี้ ยังมีปัจจัยสุ่ม (Random disturbance) วิธีอนุกรมเวลานี้จะพยายามแยกปัจจัยสุ่มที่มีความเกี่ยวข้องกับปัจจัยอื่น ๆ ก่อนจึงแยกปัจจัยสุ่มออกมาจากปัจจัยอื่นมากกว่าที่จะแยกปัจจัยสุ่มออกมาโดยตรงจากข้อมูลอนุกรมเวลา ซึ่งข้อมูลอนุกรมเวลาที่แยกเป็นส่วน ๆ อาจเขียนได้เป็น

$$F_t = T_t \times C_t \times I_t \times E_t \quad \text{หรือ} \quad F_t = T_t C_t I_t + E_t$$

$$\text{หรือ} \quad F_t = T_t + C_t + I_t + E_t \quad \text{หรือ} \quad F_t = T_t + C_t + I_t$$

เมื่อ  $F_t$  เป็นค่าพยากรณ์ของข้อมูล  $X$  ณ วาระ  $t$

$T_t$  เป็นค่าปัจจัยแนวโน้ม ณ วาระ  $t$

$C_t$  เป็นค่าปัจจัยวัฏจักร ณ วาระ  $t$

$I_t$  เป็นค่าปัจจัยฤดูกาล ณ วาระ  $t$

$E_t$  เป็นค่าปัจจัยสุ่ม ณ วาระ  $t$

ในการพยากรณ์วิธีอนุกรมเวลานี้ มีข้อจำกัดเกี่ยวกับการหารูปแบบของฟังก์ชันของแนวโน้มให้สอดคล้องกับข้อมูลและบางรูปแบบมีข้อบกพร่องที่อาจจะเกิดขึ้น ผู้พยากรณ์ต้องทราบข้อบกพร่องนั้น ๆ และในการหาปัจจัยวัฏจักรยังมีข้อจำกัดที่ว่าต้องมีข้อมูลในอดีตจำนวนมากพอที่จะรู้แต่ละวงจร (cycle) ของปัจจัยวัฏจักรด้วย นอกจากนี้ที่สำคัญวิธีการพยากรณ์นี้ไม่สามารถทดสอบสมมติฐานทางสถิติได้

### 7. การวิเคราะห์การถดถอย (Regression Analysis)

รูปแบบที่ง่ายที่สุดของวิธีการพยากรณ์นี้สามารถเลือกทางที่แตกต่างกัน ที่จะตัดสินใจเกี่ยวกับการถ่วงน้ำหนักที่จะประยุกต์ค่าในอดีตของตัวแปร อย่างไรก็ตามปกติใช้ในการพยากรณ์การตลาด ตัวแบบที่ใช้คือ ตัวแบบการถดถอยเชิงพหุ (multiple regression) ซึ่งรวมตัวแปรมากกว่าหนึ่งตัว ในการถดถอยเชิงพหุการพยากรณ์ไม่ได้ขึ้นอยู่กับเพียงแค่ค่าข้อมูลในอดีต ที่จะพยากรณ์แต่ขึ้นอยู่กับตัวแปรอื่น ๆ ที่มีความเกี่ยวข้องกันด้วยเหตุด้วยผล ตัวอย่างเช่น ผู้จัดการฝ่ายผลิตต้องการที่จะพยากรณ์ยอดขายสินค้ารายเดือน โดยจะใช้การวิเคราะห์ การถดถอยเชิงพหุ การพยากรณ์จะไม่เพียงแต่พิจารณาค่าสังเกตในอดีตเกี่ยวกับยอดขายของสินค้า แต่อาจรวมถึงงบการโฆษณาและบางที่ยังต้องพิจารณาถึงความแตกต่างระหว่างราคาสินค้าของเขากับราคาสินค้าของคู่แข่ง จากเทคนิคดังกล่าวค่าของข้อมูลที่ทำกรพยากรณ์เป็นค่าตัวแปรตาม (dependent variable) จะขึ้นอยู่กับค่าของตัวแปรตัวเดียวหรือหลายตัวแปร ซึ่งตัวแปรเหล่านี้เป็นตัวแปรอิสระ (independent variable) จาก

ตัวอย่างอาจเขียนได้ คือ

ยอดขายรายเดือน =  $f$ ( ค่าใช้จ่ายในการโฆษณา , ราคาของสินค้าที่แตกต่างระหว่างบริษัทตนเอง  
กับบริษัทคู่แข่ง )

รูปแบบความสัมพันธ์ที่ได้ อาจอยู่ในรูปเชิงเส้นหรือไม่ก็ได้ขึ้นอยู่กับข้อกำหนดรูปแบบของฟังก์ชันตัวแปรตาม ( หรือสิ่งที่ต้องการพยากรณ์ ) ขึ้นอยู่กับตัวแปรอิสระตัวเดียวเป็นการวิเคราะห์การถดถอยอย่างง่าย ( simple regression analysis ) ซึ่งการประมาณค่าพารามิเตอร์อาจใช้วิธีกำลังสองน้อยที่สุด ( least square method ) หรืออาจใช้วิธีอื่น เช่น stepwise regression การพยากรณ์วิธีนี้สามารถประมาณค่าพารามิเตอร์ ทดสอบนัยสำคัญทางสถิติ และหาช่วงความเชื่อมั่นของค่าพยากรณ์ได้ แต่ต้องมีสมมติฐานของค่า residual การพยากรณ์วิธีนี้จึงเป็นที่นิยมนำไปใช้มาก

#### 8. วิธีการพยากรณ์เชิงเศรษฐมิติ ( Econometric Forecasting )

การพยากรณ์วิธีนี้ขยายหลักการจากวิธีการวิเคราะห์การถดถอย โดยการวิเคราะห์การถดถอยสมมติให้ตัวแปรอิสระแต่ละตัวอยู่นอกอิทธิพลตัวแปรตาม และตัวแปรเป็นอิสระต่อกันรวมอยู่ในสมการที่ใช้ในการตัดสินใจ อย่างไรก็ตาม ข้อสมมตินี้ใช้ในบางสถานการณ์เท่านั้นในด้านเศรษฐศาสตร์ สมมติฐานของตัวแปรอิสระไม่เป็นจริง บ่อยครั้งที่มีความเป็นอิสระต่อกันระหว่างตัวแปรทั้งหมดในสมการการพยากรณ์ และการวิเคราะห์การถดถอย ไม่สามารถหาความสัมพันธ์ระหว่างตัวแปรอิสระเหล่านั้นได้ การพยากรณ์เชิงเศรษฐมิติสามารถที่จะหาความสัมพันธ์ระหว่างตัวแปรอิสระบางตัวได้ สามารถแสดงความสัมพันธ์ที่ถูกต้องได้โดยพัฒนาระบบสมการภายในเวลาเดียวกันได้ จากสิ่งเหล่านี้ โดยธรรมชาติของการพยากรณ์ วิธีนี้จึงสามารถหาฟังก์ชันรูปแบบความสัมพันธ์ ต่าง ๆ ของตัวแปรทั้งหลายได้ ตัวอย่างเช่น

$$\text{ยอดขาย} = f( \text{GNP} , \text{ราคาสินค้า} , \text{ค่าใช้จ่ายในการโฆษณา} )$$

จากสมการนี้เป็นการวิเคราะห์การถดถอยเชิงพหุ แต่ในการพยากรณ์เชิงเศรษฐมิติจะมีสมการดังนี้

$$\text{ยอดขาย} = f( \text{GNP} , \text{ราคาสินค้า} , \text{ค่าใช้จ่ายในการโฆษณา} )$$

$$\text{ต้นทุนของสินค้า} = f( \text{ระดับการผลิต} , \text{ระดับสินค้าคงคลัง} )$$

$$\text{ค่าใช้จ่ายในการขาย} = f( \text{ค่าใช้จ่ายในการโฆษณา} , \text{ค่าใช้จ่ายในการขายอื่น ๆ} )$$

$$\text{ราคาสินค้า} = \text{ต้นทุนของสินค้า} + \text{ค่าใช้จ่ายในการขาย}$$

จากตัวอย่างแทนที่จะมีสมการของความสัมพันธ์เพียงหนึ่งสมการในการวิเคราะห์การถดถอย ขณะที่การพยากรณ์เชิงเศรษฐมิติมีถึง 4 สมการ มีขั้นตอนดังนี้ คือ

- ตัดสินใจรูปแบบของฟังก์ชันของแต่ละสมการ
- ประมาณค่าพารามิเตอร์ทั้งหมดในเวลาเดียวกัน

- ทดสอบนัยสำคัญทางสถิติของผลลัพธ์และรวมถึงตรวจสอบความถูกต้องของสมมติฐาน  
ข้อได้เปรียบ หลักของวิธีการพยากรณ์เชิงเศรษฐมิตินี้ คือ ค่าของตัวแปรอิสระหลาย ๆ ตัวอาจ  
กำหนดขึ้นเองภายในตัวแบบของมันเอง ดังนั้นผู้พยากรณ์จึงไม่ต้องไปประมาณค่าตัวแปรอิสระวิธี  
การพยากรณ์เชิงเศรษฐมิติ จะให้ประโยชน์มากในกรณีที่ชนิดของข้อมูลมีความเกี่ยวข้องกัน การ  
กำหนดฟังก์ชันรูปแบบเป็นปัญหาชุกกว่าในการวิเคราะห์การถดถอย อีกทั้งยังเป็นปัญหาในการ  
นำไปประยุกต์ใช้และแพง อย่างไรก็ตาม ผลประโยชน์ที่ได้รับจากวิธีนี้อาจจะทดแทนได้ดีสำหรับ  
กรณีเกิดค่าใช้จ่ายสูงมาก