



รายงานการศึกษา
ค่าคาดการณ์อัตราการว่างงานของประเทศไทย
(ฉบับสมบูรณ์)

สำนักงานสถิติแห่งชาติ
สำนักงานปลัดกระทรวงแรงงาน

กันยายน 2566

คำนำ

รายงานการศึกษาค่าคาดการณ์อัตราการว่างของประเทศไทย (ฉบับสมบูรณ์) เป็นรายงานจัดทำร่วมกันระหว่างสำนักงานสถิติแห่งชาติ และสำนักงานปลัดกระทรวงแรงงาน เพื่อศึกษาและพยากรณ์ค่าการคาดการณ์อัตราการว่างงานของประเทศไทย สำหรับใช้ในการประเมินส่วนราชการตามตัวชี้วัดการประเมินส่วนราชการตามมาตรการปรับปรุงประสิทธิภาพในการปฏิบัติราชการ ประจำปีงบประมาณ 2566 ของสำนักงานสถิติแห่งชาติ และสำนักงานปลัดกระทรวงแรงงาน โดยเป้าหมายรอบ 6 เดือน คือ การจัดทำรายงานการศึกษาค้นคว้ารวบรวมแนวคิดและทฤษฎีที่เกี่ยวข้อง และการประชุมหารือกับผู้กำหนดนโยบาย ผู้มีส่วนได้ส่วนเสีย และผู้ที่เกี่ยวข้อง

สำหรับการจัดทำชุดข้อมูลการคาดการณ์อัตราการว่างงาน (Forecast Unemployment) นับว่าเป็นความสำคัญและความจำเป็นในการพัฒนา เพื่อให้มีชุดข้อมูลจากแหล่งข้อมูลในประเทศที่มีความถูกต้องและน่าเชื่อถือ เนื่องจากชุดข้อมูลการคาดการณ์อัตราการว่างงาน (Forecast Unemployment) เป็นตัวชี้วัดสำคัญที่ใช้ประกอบในการจัดอันดับความสามารถในการแข่งขันของประเทศโดย IMD ซึ่งในการดำเนินการที่ผ่านมา IMD ใช้ข้อมูลของประเทศไทยจาก World Economic Outlook Database ที่จัดทำโดย IMF เป็นแหล่งข้อมูลหลัก สำนักงานสถิติแห่งชาติและสำนักงานปลัดกระทรวงแรงงานตระหนักถึงความสำคัญของการมีชุดข้อมูลดังกล่าว จึงได้ร่วมกับสำนักงานปลัดกระทรวงแรงงานศึกษาค่าคาดการณ์อัตราการว่างของประเทศไทย และจัดทำรายงานฉบับนี้ขึ้น ทั้งนี้ หวังว่า รายงานการศึกษาค่าคาดการณ์อัตราการว่างของประเทศไทย จะเป็นประโยชน์ต่อหน่วยงานต่าง ๆ ทั้งภาครัฐ ภาคธุรกิจเอกชน ภาคประชาชน และภาคส่วนต่าง ๆ สำหรับใช้ในการวางแผน กำหนดนโยบาย และมาตรการด้านแรงงาน เพื่อรับมือหรือลดผลกระทบที่อาจจะเกิดขึ้นในอนาคต ตลอดจนเป็นเครื่องชี้ภาวะเศรษฐกิจและสังคมของประเทศต่อไป

สำนักงานสถิติแห่งชาติ และสำนักงานปลัดกระทรวงแรงงาน
ผู้จัดทำ

กิตติกรรมประกาศ

สำนักงานสถิติแห่งชาติและสำนักงานปลัดกระทรวงแรงงาน ขอขอบคุณ ดร. ณัฐนันท์ วิจิตรอักษร จากสถาบันวิจัยเพื่อการพัฒนาประเทศไทย (ทีดีอาร์ไอ) ที่ได้ให้ความกรุณาอย่างสูงในการเป็นที่ปรึกษาโครงการ ให้คำแนะนำ ปรับปรุงแก้ไข ตลอดจนพัฒนาตัวแบบการพยากรณ์ เพื่อให้ได้ตัวแบบการพยากรณ์ค่าคาดการณ์อัตราการว่างงานที่มีความถูกต้องและเหมาะสมกับบริบทของประเทศไทย

นอกจากนี้ ขอขอบคุณผู้ทรงคุณวุฒิทุกท่านที่ให้ข้อเสนอแนะที่เป็นประโยชน์ต่อผลการศึกษาคือความเชี่ยวชาญและประสบการณ์ที่ท่านมีนับเป็นส่วนสำคัญในการพัฒนางานในอนาคต ทำให้งานศึกษานี้สามารถต่อยอดพัฒนานำไปสู่ความก้าวหน้าทางวิชาการของสำนักงานสถิติแห่งชาติ

สุดท้ายนี้ สำนักงานสถิติแห่งชาติขอขอบคุณหน่วยงานที่เกี่ยวข้องที่ให้ความร่วมมือและสนับสนุนการทำงานของสำนักงานสถิติแห่งชาติมาโดยตลอด รวมถึงการจัดทำรายงานฉบับนี้ให้สำเร็จ ลุล่วงด้วยดีและหวังว่ารายงานฉบับนี้จะเป็นประโยชน์ในการเชื่อมต่อการทำงานของทุกท่านในอนาคตต่อไป

คำนำ

กิตติกรรมประกาศ

บทที่ 1 บทนำ	1
1.1 หลักการและเหตุผล.....	1
1.2 วัตถุประสงค์.....	2
1.3 ประโยชน์ที่คาดว่าจะได้รับ	2
1.4 แผนการดำเนินงาน	3
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง	4
2.1 กรอบนโยบายเกี่ยวกับด้านแรงงานของประเทศไทย	4
2.2 การว่างงานของประเทศไทยและทฤษฎีตลาดแรงงาน.....	7
2.3 แนวคิดและทฤษฎีเกี่ยวกับการพยากรณ์.....	18
2.4 ทบทวนวรรณกรรมและงานวิจัยที่เกี่ยวข้อง	27
บทที่ 3 วิธีการศึกษา	36
3.1 ข้อมูลที่ใช้ในการวิเคราะห์	36
3.2 เทคนิคการพยากรณ์.....	38
3.3 หลักการพิจารณาวิธีการพยากรณ์ที่เหมาะสมที่สุด.....	43
3.4 ขั้นตอนการพยากรณ์อัตราการว่างงาน	44
บทที่ 4 ผลการศึกษา.....	45
4.1 การพยากรณ์อัตราการว่างงาน โดยใช้ข้อมูลรายปี.....	46
4.2 การพยากรณ์อัตราการว่างงาน โดยใช้ข้อมูลรายไตรมาส	53
4.3 การพยากรณ์อัตราการว่างงาน โดยใช้ข้อมูลรายเดือน	57
บทที่ 5 สรุปผลและข้อเสนอแนะจากผู้เชี่ยวชาญ.....	65
5.1 สรุปผล	65
5.2 ข้อเสนอแนะจากผู้เชี่ยวชาญ.....	66
เอกสารอ้างอิง	69
ภาคผนวก	71

บทที่ 1

บทนำ

1.1 หลักการและเหตุผล

ปัจจุบัน ประเทศไทยพยายามที่จะพัฒนาเศรษฐกิจให้เจริญเติบโตขึ้น โดยการแสวงหาแนวทางและการดำเนินนโยบายด้านเศรษฐกิจต่าง ๆ เพื่อให้บรรลุเป้าหมายทางเศรษฐกิจ (Economic Goal) ซึ่งการจ้างงานเต็มที่ (Full Employment) เป็นเป้าหมายหนึ่งที่สำคัญมากในระบบเศรษฐกิจ คือการใช้ประโยชน์จากปัจจัยการผลิตโดยเฉพาะอย่างยิ่งปัจจัยที่เป็นแรงงานได้อย่างเต็มที่ ซึ่งระบบเศรษฐกิจใดหากมีการว่างงานมาก ย่อมที่จะส่งผลกระทบต่อเสถียรภาพของประเทศ เพราะว่าการจ้างงานนั้นมีความข้องเกี่ยวกับการเจริญเติบโตของระบบเศรษฐกิจ อีกทั้งเป้าหมายการพัฒนาที่ยั่งยืน (Sustainable Development Goals : SDGs) เป้าหมายข้อที่ 8 คือ ส่งเสริมการเจริญเติบโตทางเศรษฐกิจที่ยั่งยืนและทั่วถึง และการจ้างงานเต็มที่ และงานที่มีคุณค่าสำหรับทุกคน (Decent Work and Economic Growth) ดังนั้น เป้าหมายในเรื่องของการจ้างงาน ต้องพยายามทำให้เกิดขึ้นมากที่สุด ซึ่งจะเห็นได้ว่าในปัจจุบันประเทศไทยมีกรอบนโยบายของประเทศที่สำคัญในด้านแรงงาน เช่น ยุทธศาสตร์ชาติระยะ 20 ปี (พ.ศ. 2561 – 2580) โดยการยกระดับศักยภาพทักษะ และสมรรถนะแรงงานอย่างต่อเนื่องสอดคล้องกับความต้องการของตลาดแรงงาน มีการทำงานตามหลักการการทำงานที่มีคุณค่า เพื่อสร้างผลิตภาพเพิ่มให้กับประเทศ และนโยบายไทยแลนด์ 4.0 ที่สนับสนุนการนำระบบเทคโนโลยีสารสนเทศมาใช้ในการบริหารจัดการแรงงานและเพิ่มศักยภาพฝีมือแรงงานเข้าสู่มาตรฐานสากล

การพยากรณ์ข้อมูลสถิติ เป็นเครื่องมือหนึ่งที่สำคัญในการช่วยวางแผนและการตัดสินใจเกี่ยวกับการดำเนินงานด้านต่าง ๆ ทั้งทางด้านสังคม ด้านเศรษฐกิจ และด้านดิจิทัล ไม่ว่าจะเป็นระยะสั้นหรือระยะยาว เพราะข้อมูลพยากรณ์ที่ได้ สามารถวางแผนหรือออกนโยบายเชิงป้องกันได้ล่วงหน้า เป็นการส่งสัญญาณให้ผู้กำหนดนโยบาย สามารถลดความเสี่ยงในการดำเนินการของรัฐได้ดีในระดับหนึ่ง ซึ่งสำนักงานสถิติแห่งชาติ มีอำนาจหน้าที่ตามพระราชบัญญัติสถิติ พ.ศ. 2550 และตามกฎหมายกระทรวงแบ่งส่วนราชการสำนักงานสถิติแห่งชาติ กระทรวงดิจิทัลเพื่อเศรษฐกิจและสังคม พ.ศ. 2560 ในการผลิตและวิเคราะห์ข้อมูลสถิติพื้นฐานทางด้านเศรษฐกิจและสังคมในระดับมหภาค รวมทั้งพัฒนาตัวชี้วัดและชุดข้อมูลสถิติสารสนเทศ เพื่อใช้ในการวิเคราะห์แนวโน้มและคาดการณ์ภาวะการณ์ต่าง ๆ ของประเทศ ประกอบกับกระทรวงแรงงาน มีภารกิจในด้านการพัฒนาโอกาสในการสร้างความสมดุลของตลาดแรงงาน เพื่อสร้างความยั่งยืนให้ภาคแรงงานของประเทศ และการพัฒนาเทคโนโลยีและสารสนเทศ เพื่อบูรณาการสารสนเทศที่ทันสมัย มีเสถียรภาพ

ดังนั้น สำนักงานสถิติแห่งชาติและสำนักงานปลัดกระทรวงแรงงาน จึงมีความจำเป็นอย่างยิ่งที่จะต้องดำเนินการศึกษาและพัฒนาตัวแบบการพยากรณ์ค่าคาดการณ์อัตราการว่างงาน เพื่อให้ได้ตัวแบบการพยากรณ์ที่มีความถูกต้องและเหมาะสมกับบริบทของประเทศไทย ซึ่งจะเป็นประโยชน์ต่อหน่วยงานต่าง ๆ ทั้งภาครัฐ ภาคเอกชน ภาคประชาชน และภาคส่วนต่าง ๆ สำหรับใช้ในการวางแผนและการกำหนดนโยบายด้านแรงงานของประเทศ ตลอดจนรับมือหรือลดผลกระทบที่อาจเกิดขึ้นในอนาคตได้

1.2 วัตถุประสงค์

1. เพื่อศึกษาและพัฒนาตัวแบบการพยากรณ์ค่าคาดการณ์อัตราการว่างงานที่มีความถูกต้องและเหมาะสมกับบริบทของประเทศไทย
2. เพื่อพยากรณ์ค่าคาดการณ์อัตราการว่างงานของประเทศไทย
3. เพื่อจัดทำชุดข้อมูลค่าคาดการณ์อัตราการว่างงานของประเทศไทย สำหรับการรายงานการจัดอันดับขีดความสามารถในการแข่งขันของประเทศไทย โดย International Institute for Management Development (IMD)

1.3 ประโยชน์ที่คาดว่าจะได้รับ

1. มีตัวแบบการพยากรณ์ค่าคาดการณ์อัตราการว่างงานที่มีความถูกต้องและน่าเชื่อถือ
2. สามารถนำข้อมูลค่าคาดการณ์พยากรณ์อัตราการว่างงานไปใช้เป็นตัวชี้วัดในการรายงานการจัดอันดับขีดความสามารถในการแข่งขันของประเทศไทย
2. ภาครัฐมีข้อมูลค่าคาดการณ์พยากรณ์อัตราการว่างงาน เพื่อนำไปใช้ในการวิเคราะห์ประกอบการกำหนดนโยบาย รวมถึงการวางแผนหรือออกนโยบายเชิงป้องกันได้ล่วงหน้า
3. ภาคเอกชนสามารถใช้ข้อมูลค่าคาดการณ์อัตราการว่างงาน เพื่อสนับสนุนการตัดสินใจในการดำเนินงาน
4. ภาคประชาชนสามารถใช้ข้อมูลค่าคาดการณ์อัตราการว่างงาน เพื่อการตัดสินใจในการดำรงชีพของตนเองและครอบครัวให้สอดคล้องเหมาะสมกับสภาพเศรษฐกิจและสังคม

บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

2.1 กรอบนโยบายเกี่ยวกับด้านแรงงานของประเทศไทย

1. ยุทธศาสตร์ชาติระยะ 20 ปี (พ.ศ. 2561 – 2580) โดยยุทธศาสตร์ชาติระยะ 20 ปี (พ.ศ. 2561 – 2580) ให้ความสำคัญในการยกระดับศักยภาพ ทักษะ และสมรรถนะแรงงานอย่างต่อเนื่องสอดคล้องกับความต้องการของตลาดแรงงาน มีการทำงานตามหลักการการทำงานที่มีคุณค่า เพื่อสร้างผลิตภาพเพิ่มให้กับประเทศ

2. นโยบายรัฐบาล ให้ความสำคัญทั้งหมด 6 ข้อ ดังต่อไปนี้

2.1 เร่งสร้างโอกาส อาชีพ และการมีรายได้ที่มั่นคงแก่ผู้ที่เข้าสู่ตลาดแรงงาน รวมทั้งสตรีผู้ด้อยโอกาส และแรงงานต่างด้าวที่ถูกกฎหมาย

2.2 ยกระดับคุณภาพแรงงาน โดยให้แรงงานทั้งระบบมีโอกาสเข้าถึงการเรียนรู้และพัฒนาทักษะฝีมือแรงงานในทุกระดับอย่างมีมาตรฐาน

2.3 เชื่อมโยงข้อมูลและการดำเนินการระหว่างหน่วยงานของรัฐกับเอกชน เพื่อให้ตรงกับความต้องการของพื้นที่และของประเทศโดยรวม

2.4 ส่งเสริมให้แรงงานนอกระบบเข้าสู่ระบบที่ถูกกฎหมายมากขึ้น

2.5 ป้องกันและแก้ไขปัญหาการค้ามนุษย์ รวมถึงปัญหาผู้หลบหนีเข้าเมือง การทารุณกรรมต่อแรงงานต่างด้าว

2.6 เตรียมความพร้อมเข้าสู่สังคมที่มีความหลากหลาย เนื่องจากการเข้าสู่ประชาคมอาเซียนโดยสร้างความเข้มแข็งและความพร้อมแก่แรงงานไทย และร่วมพัฒนาระบบความ

3. นโยบายกระทรวงแรงงาน ปีงบประมาณ 2566 กระทรวงแรงงานกำหนดนโยบายที่มีความสอดคล้องกับเป้าหมายการพัฒนาที่ยั่งยืน (Sustainable Development Goals) ,แนวโน้มการพัฒนาภาคแรงงานในยุคดิจิทัล , เศรษฐกิจชีวภาพ เศรษฐกิจหมุนเวียน และเศรษฐกิจสีเขียว (Bioeconomy, Circular Economy and Green Economy: BCG Model) , ยุทธศาสตร์ชาติ ๒๐ ปี และแผนพัฒนาเศรษฐกิจและสังคมแห่งชาติฉบับที่ ๑๓ กำหนดยุทธศาสตร์ด้านการพัฒนาและเสริมสร้างศักยภาพ ทรัพยากรมนุษย์ ในหมวดหมายที่ ๑๒ ไทยมีกำลังคนสมรรถนะสูง มุ่งเรียนรู้อย่างต่อเนื่อง ดังนี้

พลิกโฉมแรงงานและสถานประกอบการ

2.1 ส่งเสริมการมีงานทำ และการจ้างงาน ยกระดับคุณภาพชีวิตแรงงาน

2.2 ยกระดับฝีมือและพัฒนาทักษะแรงงาน ลงทุนด้านการพัฒนาทุนมนุษย์ เพื่อรองรับเศรษฐกิจใหม่

2.3 เร่งรัดการดูแลแรงงานนอกระบบ แรงงานสูงอายุ และแรงงานคนพิการ เพื่อยกระดับคุณภาพชีวิตให้ดีขึ้น และช่วยสร้างเศรษฐกิจของประเทศ

2.4 เร่งรัดการแก้ไขปัญหาแรงงานต่างด้าวและป้องกันการค้ามนุษย์ด้านแรงงาน เพื่อมุ่งสู่การเป็น Tier 1

2.5 เร่งรัดการป้องกันปัญหาอาชญากรรมในสถานประกอบการ

2.6 บูรณาการความร่วมมือทุกภาคส่วนในการให้บริการด้านแรงงาน พัฒนาและปรับปรุง ระบบค่าจ้างและ รายได้ สวัสดิการ สิทธิประโยชน์ และความปลอดภัยในการทำงาน

2.7 สื่อสารเชิงรุกด้านแรงงาน เพื่อให้แรงงานรับรู้บริการของกระทรวงแรงงานและสิทธิประโยชน์แรงงาน

4. นโยบายไทยแลนด์ 4.0 โดยนโยบายไทยแลนด์ 4.0 ให้ความสำคัญในด้านของการนำระบบเทคโนโลยีสารสนเทศมาใช้ในการบริหารจัดการแรงงานและเพิ่มศักยภาพฝีมือแรงงานเข้าสู่มาตรฐานสากล

5. กรอบยุทธศาสตร์การพัฒนาทรัพยากรมนุษย์ของประเทศ ระยะ 20 ปี (พ.ศ.2560 – 2579) โดยกระทรวงแรงงานได้จัดทำกรอบยุทธศาสตร์การพัฒนาทรัพยากรมนุษย์ของประเทศ ระยะ 20 ปี (พ.ศ. 2560 – 2579) ที่เชื่อมโยงกับยุทธศาสตร์ชาติระยะ 20 ปี แผนพัฒนาเศรษฐกิจและสังคมแห่งชาติ ฉบับที่ 12 โดยกำหนดวิสัยทัศน์ในอีก 20 ปีข้างหน้า คือทรัพยากรมนุษย์มีคุณค่าสูงสู่ความยั่งยืน แบ่งการดำเนินการเพื่อบรรลุวิสัยทัศน์เป็น 4 ช่วง ๆ ละ 5 ปี ดังต่อไปนี้

4.1 ช่วงที่ 1 Productive Manpower (พ.ศ.2560 – 2564)

ช่วงที่ 1 Productive Manpower (พ.ศ.2560 – 2564) เป็นช่วงของการวางรากฐานด้านแรงงานให้เป็นมาตรฐานสากล เป็นยุคของรากฐานด้านแรงงานที่เป็นมาตรฐานสากล โดยการจัดอุปสรรคด้านแรงงานใน การพัฒนาประเทศ จัดระเบียบแรงงานต่างดาว (Zoning) เร่งพัฒนามาตรฐานการดำเนินงานด้านแรงงานให้เป็นสากล มุ่งเน้นให้แรงงานทุกคนได้รับการคุ้มครองทางสังคมและมีความปลอดภัย เดินหน้าขับเคลื่อนแผนการใช้ทรัพยากรมนุษย์ในการพัฒนาประเทศ เพื่อเตรียมความพร้อมของทรัพยากรมนุษย์ทั้งด้านปริมาณ และคุณภาพ เร่งรัดการรับมือกับปัญหาการขาดแคลนแรงงาน รวมถึงส่งเสริมให้แรงงานไทยเป็นหัวหน้างาน มีทักษะที่หลากหลาย (multi-skilled) เติมทักษะใหม่ด้วยการ re-skill และเติมทักษะด้าน STEM ให้แก่แรงงานเพื่อให้เกิดการเปลี่ยนผ่านในโลกของการทำงานที่ราบรื่น (smooth transition) ทำงานอย่างมีประสิทธิภาพ สอดคล้องกับการพัฒนาเศรษฐกิจในระยะถัดไป และพร้อมเผชิญต่อความท้าทายที่จะเกิดขึ้นในอนาคตเพื่อรองรับการพัฒนาแรงงานให้มีทักษะการเป็นแรงงานในยุค Thailand 4.0 ผลสัมฤทธิ์ที่คาดว่าจะได้รับมี 2 มิติ คือ

มิติคน : แรงงานไทยมีผลิตภาพสูง มีทักษะที่หลากหลาย (multi-skilled) มีทักษะใหม่ (re-skilled) มีทักษะด้าน STEM สามารถทำงานในยุคเริ่มต้นของการเข้าสู่ Thailand 4.0 ได้อย่างราบรื่น

มิติมาตรฐานการขับเคลื่อนวงจรแรงงาน : มีมาตรฐานอาชีพตามกรอบคุณวุฒิวิชาชีพแห่งชาติ 8 ระดับที่เชื่อมโยงกับมาตรฐานฝีมือแรงงานแห่งชาติครบทุกสาขาอาชีพตามอุตสาหกรรมแห่งอนาคต (New Engine of Growth)

4.2 ช่วงที่ 2 Innovative Workforce (พ.ศ.2565 – 2569)

ช่วงที่ 2 Innovative Workforce (พ.ศ.2565 – 2569) เป็นช่วงของการสร้างทรัพยากรมนุษย์ให้เป็นประชากรของโลก (Global Citizen) เป็นยุคของทรัพยากรมนุษย์ของประเทศที่เป็นประชาชนของโลก (Global Citizen) เพื่อให้แรงงานสามารถนำเทคโนโลยีและนวัตกรรมมาใช้ในการเพิ่มผลิตภาพได้อย่างมีประสิทธิภาพรองรับต่อ Thailand 4.0 อย่างเต็มรูปแบบ และ

กฎระเบียบต่างๆ ด้านแรงงานจะต้องมีความยืดหยุ่นรองรับรูปแบบการจ้างงานใหม่ในยุคดิจิทัล การสร้างระบบการจ้างงานที่เอื้อต่อแรงงานสูงวัยอย่างครบวงจร ทั้งตำแหน่งงาน สภาพแวดล้อมการทำงานและสวัสดิการ รวมทั้งการพัฒนาแรงงานให้มีความพร้อมในการทำงานภายใต้สังคม พหุวัฒนธรรม และการจ้างงานข้ามแดน ผลสัมฤทธิ์ที่คาดว่าจะได้รับมี 2 มิติ คือ

มิติคน : แรงงานไทยมีทักษะ ความรู้ความสามารถ สมรรถนะที่สามารถทำงานในยุคที่ภาคเศรษฐกิจใช้เทคโนโลยีขั้นสูงและนวัตกรรมเต็มรูปแบบได้อย่างราบรื่น

มิติมาตรฐานการขับเคลื่อนวงจรแรงงาน : มีระบบการจ้างงานที่หลากหลายรูปแบบ เป็นระบบที่ยืดหยุ่นเหมาะสมกับคุณลักษณะของทรัพยากรมนุษย์หลากหลายประเภท

4.3 ช่วงที่ 3 Creative Workforce (พ.ศ.2570 – 2574)

ช่วงที่ 3 Creative Workforce (พ.ศ.2570 – 2574) เป็นช่วงของการสร้างทรัพยากรมนุษย์ให้มีความคิดสร้างสรรค์ในการสร้างมูลค่าเพิ่มให้แก่การทำงาน เป็นยุคของทรัพยากรมนุษย์ที่มีความคิดสร้างสรรค์ในการสร้างมูลค่าเพิ่มให้แก่การทำงาน เพื่อสร้าง ความยั่งยืนด้านแรงงานสู่ความยั่งยืนในการดำรงชีวิต เพื่อให้บรรลุวาระการพัฒนาที่ยั่งยืนในกรอบของ สหประชาชาติ (SDG) เป้าหมายข้อที่ 8 “ส่งเสริมการเติบโตทางเศรษฐกิจที่ต่อเนื่อง ครอบคลุม และยั่งยืน การจ้างงานเต็มที่ (Full Employment) และมีผลิตภาพ (Productivity) และการมีงานที่สมควรสำหรับทุกคน (Decent Work)” และเพื่อให้กำลังแรงงานมีทักษะด้าน STEM มีความคิดสร้างสรรค์ และมีทักษะ R&D ในการสร้างมูลค่าเพิ่มให้แก่การทำงาน

ผลสัมฤทธิ์ที่คาดว่าจะได้รับ คือ ประเทศไทยบรรลุวาระการพัฒนาที่ยั่งยืนในกรอบของ สหประชาชาติ (SDGs) การจ้างงานเต็มที่ (Full Employment) และมีผลิตภาพ (Productivity) และการมีงานที่มีคุณค่าถ้วนหน้า (Decent Work)

4.4 ช่วงที่ 4 Brain Power (พ.ศ.2575 – 2579)

ช่วงที่ 4 Brain Power (พ.ศ.2575 – 2579) เป็นช่วงของการเข้าสู่สังคมการทำงานแห่งปัญญา เป็นยุคของสังคมการทำงานแห่งปัญญา โดยการเพิ่มจำนวนทรัพยากรมนุษย์ที่มีทักษะด้าน STEM เพื่อให้เป็นทรัพยากรมนุษย์ ที่สามารถใช้ความรู้ความสามารถ และสติปัญญาในการทำงานที่มูลค่าสูง (High Productivity) เพื่อให้มีรายได้สูง (High Income) และประเทศสามารถหลุดพ้นจากกับดักรายได้ ปานกลาง (Middle Income Trap: MIT)

ผลสัมฤทธิ์ที่คาดว่าจะได้รับ คือ ประเทศสามารถหลุดพ้นจากกับดักรายได้ปานกลาง (Middle Income Trap: MIT) ด้วยทรัพยากรมนุษย์ที่มีคุณค่าสูงอย่างยั่งยืน

6. เป้าหมายการพัฒนาที่ยั่งยืน (Sustainable Development Goals: SDGs) เป็นเป้าหมายที่มุ่งสู่การบรรลุวาระการพัฒนาที่ยั่งยืนในเป้าหมายข้อที่ 8 คือ ส่งเสริมการเจริญเติบโตทางเศรษฐกิจ ที่ยั่งยืนและทั่วถึง และการจ้างงานเต็มที่ และงานที่มีคุณค่าสำหรับทุกคน (Decent Work and Economic Growth)

2.2 การว่างงานของประเทศไทยและทฤษฎีตลาดแรงงาน

2.2.1 นิยาม

ผู้ว่างงาน หมายถึง บุคคลที่มีอายุ 15 ปีขึ้นไป และในสัปดาห์แห่งการสำรวจมีลักษณะอย่างหนึ่งอย่างใด ดังต่อไปนี้ (สำนักงานสถิติแห่งชาติ)

1. ไม่ได้ทำงานและไม่มียานประจำ แต่ได้หางาน สมัครงานหรือรอการบรรจุ ในระหว่าง 30 วันก่อนวันสัมภาษณ์
2. ไม่ได้ทำงานและไม่มียานประจำ และไม่ได้หางานทำในระหว่าง 30 วันก่อนวันสัมภาษณ์ แต่พร้อมที่จะทำงานในสัปดาห์แห่งการสำรวจ

ผู้มีงานทำ หมายถึง บุคคลที่มีอายุ 15 ปีขึ้นไป และในสัปดาห์แห่งการสำรวจมีลักษณะอย่างหนึ่งอย่างใด ดังต่อไปนี้ (สำนักงานสถิติแห่งชาติ)

1. ได้ทำงานตั้งแต่ 1 ชั่วโมงขึ้นไป โดยได้รับค่าจ้าง เงินเดือน ผลกำไร เงินปันผลค่าตอบแทนที่มีลักษณะอย่างอื่น สำหรับผลงานที่ทำ เป็นเงินสด หรือสิ่งของ
2. ไม่ได้ทำงานหรือทำงานน้อยกว่า 1 ชั่วโมง แต่เป็นบุคคลที่มีลักษณะอย่างหนึ่งอย่างใด ดังต่อไปนี้ (ซึ่งจะถือว่าเป็น ผู้ที่ปกติมีงานประจำ)
 - ยังได้รับค่าตอบแทน ค่าจ้าง หรือผลประโยชน์อื่นๆ หรือผลกำไรจากงานหรือธุรกิจ ในระหว่างที่ไม่ได้ทำงาน
 - ไม่ได้รับค่าตอบแทน ค่าจ้าง หรือผลประโยชน์อื่นๆ หรือผลกำไรจากงานหรือธุรกิจ ในระหว่างที่ไม่ได้ทำงาน แต่ยังมีงานหรือธุรกิจที่จะกลับไปทำ
3. ทำงานอย่างน้อย 1 ชั่วโมง โดยไม่ได้รับค่าจ้างในวิสาหกิจ หรือไร่นาเกษตรของหัวหน้าครัวเรือนหรือของสมาชิกในครัวเรือน

กำลังแรงงานที่รอฤดูกาล หมายถึง บุคคลที่มีอายุ 15 ปีขึ้นไป ในสัปดาห์แห่งการสำรวจเป็นผู้ไม่เข้าข่ายค่านิยามของผู้มีงานทำ หรือผู้ว่างงาน แต่เป็นผู้รอฤดูกาลที่เหมาะสมเพื่อที่จะทำงาน และเป็นบุคคลที่ตามปกติจะทำงานที่ไม่ได้รับสิ่งตอบแทนในไร่นาเกษตร หรือธุรกิจซึ่งทำกิจกรรมตามฤดูกาล โดยมีหัวหน้าครัวเรือนหรือสมาชิกคนอื่น ๆ ในครัวเรือนเป็นเจ้าของหรือผู้ดำเนินการ (สำนักงานสถิติแห่งชาติ)

กำลังแรงงานรวม หมายถึง บุคคลทุกคนที่มีอายุ 15 ปีขึ้นไป ในสัปดาห์แห่งการสำรวจเป็นผู้ อยู่ในกำลังแรงงานปัจจุบัน หรือเป็นผู้ถูกจัดจำแนกอยู่ในประเภทกำลังแรงงานที่รอฤดูกาลตามค่านิยามที่ได้ระบุข้างต้น (สำนักงานสถิติแห่งชาติ)

ผู้อยู่นอกกำลังแรงงาน หมายถึง บุคคลที่ไม่เข้าข่ายค่านิยามของผู้ที่อยู่ในกำลังแรงงานในสัปดาห์แห่งการสำรวจ ซึ่งได้แก่ (สำนักงานสถิติแห่งชาติ)

1. บุคคลซึ่งในสัปดาห์แห่งการสำรวจมีอายุต่ำกว่า 15 ปี
2. บุคคลซึ่งในสัปดาห์แห่งการสำรวจมีอายุ 15 ปีขึ้นไป แต่ไม่ได้ทำงาน และไม่พร้อมที่จะทำงานเนื่องจากเป็นผู้ที่
 - ทำงานบ้าน
 - เรียนหนังสือ

- ยังเด็กเกินไป (มีอายุน้อยกว่า 18 ปี) หรือชราภาพ (มีอายุเกิน 60 ปี)
- ไม่สามารถทำงานได้ เนื่องจากพิการทางร่างกายหรือจิตใจ หรือเจ็บป่วยเรื้อรัง
- ไม่สมัครใจทำงาน
- ทำงานโดยไม่ได้รับค่าจ้าง ผลกำไร ส่วนแบ่ง หรือสิ่งตอบแทนอื่น ๆ ให้แก่บุคคลซึ่งมิได้เป็นสมาชิกในครัวเรือนเดียวกัน
- ทำงานให้แก่องค์กร หรือสถาบันการกุศลต่าง ๆ โดยไม่ได้รับค่าจ้างผลกำไรส่วนแบ่ง หรือสิ่งตอบแทนอย่างใด
- ไม่พร้อมที่จะทำงาน เนื่องจากเหตุผลอื่น

งาน หมายถึง กิจกรรมที่ทำที่มีลักษณะอย่างหนึ่งอย่างใด ดังต่อไปนี้

1. กิจกรรมที่ทำแล้วได้รับค่าตอบแทนเป็นเงินหรือสิ่งของ ค่าตอบแทนที่เป็นเงิน อาจจ่ายเป็นรายเดือน รายสัปดาห์ รายวัน หรือรายชิ้น (สำนักงานสถิติแห่งชาติ)
2. กิจกรรมที่ทำแล้วได้ผลกำไร หรือหวังที่จะได้รับผลกำไร หรือส่วนแบ่งเป็นการตอบแทน
3. กิจกรรมที่ทำให้กับธุรกิจของสมาชิกในครัวเรือน โดยไม่ได้รับค่าจ้างหรือผลกำไรตอบแทนอย่างใด ซึ่งสมาชิกในครัวเรือนที่ประกอบธุรกิจนั้น จะมีสถานภาพการทำงาน เป็นประกอบธุรกิจส่วนตัว หรือนายจ้าง (สำนักงานสถิติแห่งชาติ)

อาชีพ หมายถึง ประเภทหรือชนิดของงานที่บุคคลนั้นทำอยู่ บุคคลส่วนมากมีอาชีพเดียวสำหรับบุคคลที่ในสำปดาร์แห่งการสำรวจมีอาชีพมากกว่า 1 อาชีพ ให้นับอาชีพที่มีชั่วโมงทำงานมากที่สุด การจัดจำแนกประเภทอาชีพ ตั้งแต่ไตรมาสที่ 1 พ.ศ. 2554 ปรับใช้ตาม International Standard Classification of Occupation, 2008 (ISCO – 08) ขององค์การแรงงาน ระหว่างประเทศ (ILO) ก่อน พ.ศ. 2553 การจัดประเภทอาชีพจำแนกตามความเหมาะสมกับลักษณะอาชีพของประเทศไทย โดยอ้างอิง The International Standard Classification of Occupation, 1988 (ISCO –88) (สำนักงานสถิติแห่งชาติ)

อุตสาหกรรม หมายถึง ประเภทของกิจกรรมทางเศรษฐกิจที่ได้ดำเนินการ โดยสถานประกอบการที่บุคคลนั้นกำลังทำงานอยู่ หรือประเภทของธุรกิจ ซึ่งบุคคลนั้นได้ดำเนินการอยู่ในสำปดาร์ แห่งการสำรวจ ถ้าบุคคลหนึ่งมีอาชีพมากกว่าหนึ่งอย่าง ให้บันทึกอุตสาหกรรมตามอาชีพที่บันทึกไว้ การจัด จำแนกประเภทอุตสาหกรรม ตั้งแต่ไตรมาสที่ 1 พ.ศ. 2554 ปรับใช้ตาม Thailand Standard Industrial Classification, (TSIC 2009) ก่อน พ.ศ. 2553 การจัดประเภทอุตสาหกรรมจำแนกตามความเหมาะสม กับลักษณะอุตสาหกรรมของประเทศไทย โดยอ้างอิง International Standard Industrial Classification of All Economic Activities, (ISIC : 1989) (สำนักงานสถิติแห่งชาติ)

ค่าคาดการณ์อัตราการว่างงาน คือ ค่าคาดการณ์ผู้ว่างงานต่อกำลังแรงงานทั้งหมด โดยการสร้างตัวแบบพยากรณ์ที่เหมาะสมที่สุด จากข้อมูลในอดีตและปัจจัยอื่นๆ ที่เกี่ยวข้อง เพื่อให้ทราบถึงแนวโน้มการเปลี่ยนแปลงอัตราการว่างงานในอนาคต (สำนักงานสถิติแห่งชาติ)

วิธีการคำนวณอัตราการว่างงาน

$$\text{อัตราการว่างงาน} = \frac{\text{ผู้ว่างงาน} \times 100}{\text{กำลังแรงงานรวม}}$$

i. สาเหตุของการว่างงาน

การว่างงานที่เกิดขึ้นในแต่ละยุคสมัยมีความแตกต่างกัน อันเกิดจากความเปลี่ยนแปลงของสภาพเศรษฐกิจ สังคม และตลาดแรงงาน สำหรับสาเหตุการว่างงานที่สำคัญ ๆ อาจจำแนกได้ 2 ประการคือ (สุรางค์รัตน์ วศินารมณ และภาวนา พัฒนศรี, 2538: 11-14)

1. สาเหตุการว่างงานที่เกิดจากปัจจัยภายใน

สำหรับปัจจัยภายในที่เป็นสาเหตุที่ทำให้เกิดภาวะว่างงานนั้น ส่วนใหญ่เป็นเรื่องที่เกี่ยวข้องกับเหตุผลเฉพาะตัวบุคคล คือ

1.1. การจงใจหรืออาจเรียกว่าว่างงานโดยสมัครใจ (Voluntary Unemployment)

คือ ผู้ที่ประสงค์จะทำงานแต่จงใจเป็นผู้ว่างงาน เพราะไม่ปรารถนาที่จะทำเนื่องจากไม่พอใจในค่าจ้างและสภาพการทำงาน

1.2. ความบกพร่องในการปรับตัวให้เข้ากับงานที่ทำ มีผลมาจากการที่บุคคลมีความผิดปกติทางจิตใจ มีความบกพร่องทางร่างกาย ความบกพร่องทางสังคมของบุคคล

1.3. เพศ ลักษณะงานบางอย่างก่อให้เกิดการเลือกปฏิบัติต่อผู้สมควรเข้าทำงาน รวมทั้งภาวะการเบียดเบียนทางเพศ

1.4. ความพิการ กลุ่มคนพิการมักจะได้รับพิจารณาเป็นอันดับสุดท้าย หรืออาจไม่ได้รับการพิจารณา ถ้าสังคมนั้นขาดกฎหมายรองรับที่จะให้ความคุ้มครองคนพิการในด้านการประกอบอาชีพ

1.5. อายุ เด็กและเยาวชนอาจไม่ได้รับการจ้างให้ทำงานทั้งในแง่วุฒิภาวะการศึกษาและเงื่อนไขอื่น ๆ ทางกฎหมายที่ห้ามมิให้กลุ่มดังกล่าวทำงานบางประเภท โดยเฉพาะงานที่เกี่ยวข้องเครื่องจักร งานอันตรายตามที่กฎหมายกำหนด เป็นต้น

1.6. ผู้ที่มีโรคภัยแรง เช่น โรคเอดส์มักถูกเลิกจ้าง ฉะนั้น การที่พบว่าผู้ติดเชื้อและผู้ที่เป็นพาหะนำเชื้อเอดส์ จึงถือได้ว่าโรคนี้มีผลต่อการว่างงานได้ด้วยเช่นกัน

1.7. การเลือกงาน การที่บุคคลบางกลุ่มเลือกงาน โดยขาดการประเมินความสามารถของตนเองย่อมทำให้เสียโอกาสในการมีงานทำ

1.8. ผู้ที่มีฐานะยากจน เป็นกลุ่มที่เสี่ยงต่อการมีโอกาสในการมีงานทำ เพราะมีข้อจำกัดหลายด้าน ทั้งในด้านการศึกษา และการเข้าถึงบริการจัดหางาน และตามข้อเท็จจริงกลุ่มนี้เป็นกลุ่มที่ประสบกับภาวะการว่างงานที่นานกว่ากลุ่มอื่น

1.9. ระดับการศึกษา ทักษะคิดต่อการศึกษามีผลทำให้เกิดการว่างงานได้ ถ้าผู้ที่ได้รับการศึกษาในแต่ละระดับมีทัศนคติต่องานที่ต้องการทำในทางที่ไม่ถูกต้องภูมิลำเนาผู้ที่อยู่ในกำลังแรงงานเป็นจำนวนไม่น้อยที่พยายามรอคอยงานอยู่ต่างถิ่นโดยมุ่งหวังว่าจะไม่กลับภูมิลำเนาในทางตรงกันข้าม บางส่วนกลับรอคอยงานที่สามารถจะกลับสู่ภูมิลำเนาได้

2. สาเหตุการว่างงานที่เกิดจากปัจจัยภายนอก

2.1. ปริมาณกำลังแรงงาน ซึ่งเพิ่มขึ้นอย่างไม่ได้สัดส่วนกับความต้องการกำลังแรงงานของตลาดแรงงาน

2.2. ความต้องการของตลาดแรงงาน ภาวะความต้องการของตลาดแรงงานที่มีต่อสาขาอาชีพ

2.3. ระบบการศึกษา การปรับปรุงหลักสูตรการศึกษา ระบบการเรียนการสอน รวมทั้งการเปลี่ยนทัศนคติของประชาชนทั่วไปในเรื่องการศึกษา

2.4. การส่งเสริมการลงทุน การเปลี่ยนแปลงทางเศรษฐกิจ ภาวะเศรษฐกิจในยุคโลกาภิวัตน์ มีผลต่อการเปิดโอกาสให้บริษัทข้ามชาติเข้ามาลงทุน ซึ่งมีผลต่อการเพิ่มอัตราการจ้างงาน

2.5. ภัยแล้งซึ่งเกิดจากธรรมชาติมีผลต่อการเคลื่อนย้ายแรงงานจากภาคเกษตรไปสู่ภาคอุตสาหกรรมก่อให้เกิดการว่างงานในช่วงการหางานทำ

2.6. แนวโน้มการปลดคนงาน เนื่องมาจากการนำเทคโนโลยีที่สูงขึ้นมาใช้ในระบบการผลิตโดยใช้เครื่องจักรแทนแรงงานคน

2.7. ภาวะการแข่งขันทั้งในระดับโลกและประเทศ การที่สถานประกอบการต่าง ๆ พยายามที่จะลดปัญหาการขาดแคลนแรงงานด้วยการลงทุนเพื่อพัฒนาทรัพยากรมนุษย์

2.8. ภาวะค่าครองชีพที่สูงมากขึ้น มีผลทำให้ผู้ที่มีรายได้ไม่พอเพียงต้องขวนขวายหางานใหม่ทำให้เกิด “ภาวะการว่างงานชั่วคราว” ขึ้น

2.9. งานที่ขาดเสถียรภาพจากการที่ภาวะทางเศรษฐกิจเปลี่ยนแปลงจากอุตสาหกรรมการผลิตไปสู่ฐานในการบริการนั้น งานที่ทำมักขาดความมั่นคงเนื่องจากการย้ายฐานการผลิตไปสู่ที่มีการลงทุนต่ำ

การว่างงานเกิดขึ้นด้วยสาเหตุต่าง ๆ กันไป ซึ่งอาจแบ่งประเภทการว่างงานได้ 6 ประเภท ดังนี้ (สมศักดิ์ สามัคคีธรรม, 2538: 193)

1. การว่างงานเนื่องมาจากอุปสงค์มวลรวมมีไม่เพียงพอ (Deficient Demand Unemployment) เป็นการว่างงานที่เกิดขึ้นในช่วงเศรษฐกิจตกต่ำสินค้าเหลือ/ล้นตลาด ทำให้นายทุนต้องลดการผลิตและปลดคนงานออก ก่อให้เกิดการว่างงานระยะสั้นที่เกิดจากวัฏจักรของเศรษฐกิจ (Cyclical Unemployment) กับกรว่างงานระยะยาวที่เกิดจากผลความเจริญเติบโตทางเศรษฐกิจไม่เพียงพอ (Growth - Gap Unemployment)

2. การว่างงานเพราะความฝืดของกลไกตลาดแรงงาน (Frictional Unemployment) คือ การว่างงานอันเนื่องมาจากบุคคลเปลี่ยนงานเดิม โดยกลุ่มนี้จะมีการกลับเข้าสู่ตลาดแรงงานงานใหม่อีก ถือเป็นกรว่างงานระยะสั้นซึ่งสามารถศึกษาได้จากอัตราการเข้าออกของสถานประกอบการ

3. การว่างงานเพราะโครงสร้าง (Structural Unemployment) เป็นการว่างงานที่เกิดขึ้นจากข้อเท็จจริงที่ว่าตลาดแรงงานมิได้มีเพียงตลาดเดียว แต่ประกอบด้วยตลาดย่อย ๆ เป็นจำนวนมากจึงมีการเคลื่อนย้ายแรงงานจากตลาดแรงงานแห่งหนึ่งไปสู่อีกแห่งหนึ่ง จึงทำให้เกิดการว่างงานเพราะโครงสร้างขึ้น

4. การว่างงานตามฤดูกาล (Seasonal Unemployment) ได้แก่ การว่างงานที่เกิดจากการรอฤดูกาลเกษตร พบมากในการทำงานภาคเกษตรกรรม

5. การว่างงานแอบแฝง (Disguised Unemployment) หมายถึง สภาพที่มีแรงงานส่วนเกินทำให้ผลผลิตส่วนเพิ่มของแรงงาน (Marginal Product of Labour) อยู่ในระดับที่ใกล้เคียงกับศูนย์หรือเท่ากับอัตราค่าจ้างพอยังชีพ ดังนั้น ในสาขาเศรษฐกิจที่มีการว่างงานแอบแฝง จะสามารถลดจำนวนแรงงานบางส่วน หรือโยกย้ายแรงงานออกจากสาขาเศรษฐกิจนั้น โดยไม่ทำให้ผลผลิตลดลงแต่อย่างใด

6. การทำงานต่ำกว่าระดับ (Underemployment) หมายถึง แรงงานที่ประกอบธุรกิจให้ครัวเรือน ซึ่งมีจำนวนมากเกินไปเมื่อเทียบกับปัจจัยอื่น ๆ ที่นำมาใช้ร่วมกับแรงงานในการผลิต แรงงานส่วนเกินนี้จะไม่ก่อให้เกิดผลผลิตเพิ่มขึ้น ฉะนั้นถ้าลดแรงงานส่วนเกินออก ผลผลิตรวมจะไม่ลดลง อย่างไรก็ตาม SNA ให้ข้อคิดว่า การทำงานต่ำกว่าระดับครอบคลุมถึงลักษณะที่เป็นการว่างงานบางส่วน (Partial lack of work) ได้รับรายได้ต่ำ (Low employment income) ใช้ทักษะต่ำ (Under utilization of skill) หรือผลผลิตต่ำ (Low Productivity)

McConnell et al (1999) ได้อธิบาย 3 สาเหตุหลักของการว่างงานดังต่อไปนี้

1. Frictional unemployment เป็นการว่างงานที่เกิดจากความไม่พอดีกันระหว่างผู้ว่างงานที่กำลังหางานที่ต้องการไม่ได้กับนายจ้างที่ยังหาลูกจ้างมาเติมเต็มตำแหน่งงานที่ว่างได้ แม้ว่าลูกจ้างจะมีทักษะตามที่นายจ้างต้องการก็ตาม รวมทั้งอุปสงค์โดยรวมของระบบเศรษฐกิจเอื้อต่อการจ้างงานทั้งหมดในตลาดแรงงานก็ตาม สาเหตุของการว่างงานประเภทนี้มาจากทั้งฝ่ายผู้ว่างงานและฝ่ายนายจ้าง ฝ่ายผู้ว่างงานมี 5 สาเหตุหลักคือ

- 1.1 ผู้ว่างงานลาออกจากงานเดิมเพื่อหางานใหม่
- 1.2 ผู้ว่างงานถูกปลดออกจากงานเดิม
- 1.3 ผู้ว่างงานเป็นแรงงานที่เริ่มต้นเข้าสู่กำลังแรงงานเป็นครั้งแรก
- 1.4 ผู้ว่างงานเป็นแรงงานที่กลับเข้าสู่กำลังแรงงานอีกครั้งหลังจากที่ออกไปจากกำลังแรงงานเป็นระยะเวลาหนึ่ง
- 1.5 ย้ายงานจากประเภทหนึ่งไปสู่อีกประเภทหนึ่งภายในระยะเวลาหนึ่ง (เช่น 30 วัน)

ส่วนฝ่ายนายจ้างมี 3 สาเหตุหลักคือ

- 1) นายจ้างต้องการเลือกผู้สมัครงานที่เหมาะสมแทนลูกจ้างที่ลาออกไป
- 2) นายจ้างปลดลูกจ้างบางส่วนออกเพื่อรับลูกจ้างใหม่ที่ดีกว่า
- 3) นายจ้างรับสมัครลูกจ้างเพิ่มขึ้นเนื่องจากการขยายกิจการ

2. Structural unemployment เป็นการว่างงานที่เกิดจากการเปลี่ยนแปลงในองค์ประกอบของอุปสงค์และอุปทานของแรงงาน จนทำให้อุปสงค์ของแรงงานไม่สอดคล้องกับอุปทานของแรงงาน องค์ประกอบในที่นี้มิใช่เป็นเรื่องของปริมาณของแรงงานแต่เป็นเรื่องของคุณภาพแรงงาน องค์ประกอบที่ไม่สอดคล้องกันสองประเภทที่พบกันมากคือ

- 1) ทักษะของแรงงานไม่สอดคล้องกับทักษะที่นายจ้างต้องการ
- 2) สถานที่ที่มีแรงงานว่างงานไม่สอดคล้องกับสถานที่ที่ทำงานของนายจ้างที่ต้องการแรงงาน

3. Demand-deficient unemployment เป็นการว่างงานที่เกิดขึ้นจากสภาวะถดถอยของระบบเศรษฐกิจ โดยมีสาเหตุหลักมาจากอุปสงค์โดยรวมของระบบเศรษฐกิจลดลงอย่างมาก ซึ่งทำให้หน่วยธุรกิจปลดคนงานออกเป็นจำนวนมาก การว่างงานประเภทนี้มักทำให้มีอัตราการว่างงานสูงกว่าการว่างงานประเภทอื่น ๆ ในบางครั้ง นักวิชาการจะเรียกการว่างงานประเภทนี้ว่าเป็นการว่างงานตามวัฏจักรเศรษฐกิจ (cyclical unemployment) McConnell et al (1999) ได้อธิบายเพิ่มเติมลักษณะและกลไกของการว่างงานประเภทนี้ โดยความสำคัญอยู่ตรงที่ว่าเมื่ออุปสงค์ของแรงงานลดลงจากอุปสงค์ต่อสินค้าที่ลดลง ทำให้หน่วยธุรกิจไม่ต้องการจ้างแรงงานจำนวนเท่าเดิมในค่าจ้างระดับเดิม หากกลไกตลาดแรงงานทำงานอย่างสมบูรณ์ ค่าจ้างที่ลดลงน่าจะทำให้เกิดสมดุลของอุปสงค์แรงงานและอุปทานของแรงงานใหม่ ซึ่งจะทำให้ไม่เกิดการว่างงานขึ้น แต่เป็นที่น่าเสียดายว่าค่าจ้างในตลาดแรงงานมักจะเผชิญการต่อต้านลดลง (rigid downward) นั่นคือ แรงงานส่วนใหญ่ยังคงเรียกร้องให้คงค่าจ้างไว้ ซึ่งสามารถทำได้ในกรณีที่สหภาพแรงงานที่เข้มแข็ง หรือในกรณีที่รัฐบาลเข้าแทรกแซงค่าจ้างขั้นต่ำ เป็นต้น ผลลัพธ์ที่เกิดขึ้นคือ หน่วยธุรกิจต้องปลดคนงานจำนวนมากออกเพื่อรักษาความแตกต่างของรายรับที่ลดลงเนื่องจากการจำหน่ายสินค้าได้น้อยลงและรายจ่ายที่ลดลงเนื่องจากการปลดคนงานให้เหลือจำนวนน้อยลง

2.2.3 ทฤษฎีที่อธิบายปัจจัยที่มีผลต่ออัตราการว่างงาน

จากการทบทวนทฤษฎีที่เกี่ยวข้องกับการว่างงาน พบว่า มีปัจจัยทางเศรษฐกิจและสังคมจำนวนมากที่มีผลต่อการว่างงานหรืออัตราการว่างงานของแต่ละประเทศ โดยผลการทบทวนสามารถสรุปได้ดังต่อไปนี้

1) ผลิตภัณฑ์มวลรวมในประเทศ (GDP)

Okun's law เป็นกฎที่อธิบายความสัมพันธ์ระหว่างอัตราการว่างงานและผลผลิต กฎนี้กล่าวว่า ทุก ๆ การลดลงร้อยละ 1 ของอัตราการว่างงาน จะทำให้ GDP (*Gross Domestic Product*) เพิ่มขึ้นร้อยละ 2 และ GNP (*Gross National Product*) เพิ่มขึ้นร้อยละ 3 ซึ่งสะท้อนความสัมพันธ์ที่ตรงข้ามกันระหว่างอัตราการว่างงานกับ GDP และ GNP อย่างไรก็ตาม ถึงแม้ว่าความสัมพันธ์เชิงลบนี้จะสามารถใช้ได้กับทุกประเทศ เนื่องจากเมื่อเศรษฐกิจขยายตัว ความต้องการแรงงานจึงมากขึ้นผู้ประกอบการจ้างแรงงานเพิ่มขึ้น ส่งผลให้อัตราการว่างงานลดลง แต่ค่าสัมประสิทธิ์ของ Okun จะเปลี่ยนไปในแต่ละประเทศขึ้นกับสภาพของเศรษฐกิจในประเทศนั้น ๆ (Kim et al, 2019)

2) เงินเฟ้อ

ทฤษฎีสำคัญที่อธิบายความสัมพันธ์ระหว่างอัตราการว่างงานและเงินเฟ้อ คือเส้นโค้งฟิลลิปส์ (Philips Curve) ซึ่งเป็นกราฟที่แสดงความสัมพันธ์ระหว่างอัตราเงินเฟ้อกับอัตราการว่างงานที่บ่งบอกถึงสภาวะเศรษฐกิจ ความสัมพันธ์นี้กล่าวว่า เศรษฐกิจโดยทั่วไปอยู่ในภาวะที่ต้องเลือก (trade-off) ระหว่างเศรษฐกิจดี อัตราการว่างงานต่ำ กับภาวะเงินเฟ้อสูง ถ้าเศรษฐกิจไม่ดี การว่างงานสูง เงินเฟ้อมักจะปรับลดลง อย่างน้อยในระยะสั้น ตามอุปสงค์ที่ลดลง อย่างไรก็ตาม Milton Friedman และ Edmund Phelps กล่าวว่า การชดเชยระหว่างเงินเฟ้อและอัตราการว่างงานเกิดขึ้นเพียงแค่ชั่วคราวหรือในระยะสั้นเท่านั้น ในระยะยาว เมื่อแรงงานพบว่า แม้ค่าแรงจะเพิ่มขึ้น แต่ราคาของสินค้าก็แพงขึ้นด้วย หรือกล่าวได้ว่าค่าจ้างที่แท้จริงไม่ได้เพิ่มขึ้นอย่างที่คิด แรงงานก็จะปรับการคาดการณ์เงินเฟ้อของตัวเองขึ้น และเรียกร้องค่าจ้างที่สูงขึ้น หรือลดการทำงานลงที่ค่าจ้างระดับเดิม ทำให้การว่างงานเพิ่มขึ้น

สุดท้ายเงินเพื่อที่จะเพิ่มขึ้น ในขณะที่การว่างงานเพิ่มกลับขึ้นไปอยู่ที่ระดับอัตราธรรมชาติของการว่างงาน (Natural rate of unemployment) (กฤษฎา สัตยวิจิตร, 2555)

3) จำนวนประชากร

การเปลี่ยนแปลงของอัตราการว่างงานอาจมีความเกี่ยวข้องกับการเติบโตของประชากร กล่าวคือ หากไม่มีการควบคุมประชากรของประเทศอย่างเหมาะสม อาจทำให้เกิดปัญหาการว่างงาน จากการดูดซับของการจ้างงานที่มีจำกัด ส่งผลต่อความไม่เท่าเทียมกันในการกระจายรายได้ให้กับประชากรในประเทศนั้น

สอดคล้องกับทฤษฎีประชากรของมัลธัส (Malthus Population Theory) ที่อธิบายการเติบโตของประชากรว่าการเพิ่มขึ้นของอัตราการเกิดจะเพิ่มการเติบโตของประชากรแบบทวีคูณ (exponential) จากข้อมูลของมัลธัสการตรวจสอบการป้องกัน (preventative check) และการตรวจสอบเชิงบวก (positive check) เช่น โรคและสภาพแวดล้อมในการดำรงชีวิตและการทำงานที่ไม่ดีอาจลดการเติบโตของอัตราประชากรของประเทศได้ ดังนั้นมัลธัสคาดว่า การเติบโตของประชากรที่ไม่มีการควบคุมจะทำให้เกิดการว่างงานที่สูงขึ้น (Maqbool et al, 2013)

2.2.4 ทฤษฎีการแสวงหางานทำและการว่างงาน

นักเศรษฐศาสตร์สำนักนีโอคลาสสิก (Neoclassical school) เช่น ฟรีดแมน (Friedman) และเฟลปส์ (Phelps) ได้เสนอแนวคิดเรื่องการว่างงาน โดยเชื่อว่าในระบบเศรษฐกิจจะมีอัตราการว่างงานตามธรรมชาติอยู่อัตราหนึ่ง ซึ่งถูกกำหนดโดยความผิดพลาดของตลาดแรงงาน (หรือการว่างงานผิด) และการว่างงานเพราะโครงสร้างเศรษฐกิจ การดำเนินนโยบายบริหารอุปสงค์มวลรวมแบบขยายตัว อาจมีผลช่วยลดอัตราการว่างงาน ลงต่ำกว่าอัตราตามธรรมชาติเฉพาะในระยะสั้นเท่านั้น แต่ในระยะยาวเมื่อคนงานมีประสบการณ์เกี่ยวกับผลการดำเนินนโยบายการเงินการคลังแบบขยายตัว คนงานจะสามารถปรับปรุงพฤติกรรมเสนอขายแรงงานของตนอย่างถูกต้อง ทำให้อัตราการว่างงานกลับเข้าสู่อัตราธรรมชาติอย่างเดิม ดังนั้น ตามแนวคิดนี้การไม่มีงานทำ (Non - employment) จะมี 3 ประการ คือ

- 1) การไม่มีงานทำเพราะผลแห่งการตัดสินใจของครัวเรือนที่ไม่ต้องการให้สมาชิกบางคนทำงานในตลาดแรงงาน
- 2) การว่างงานในรูปของการลงทุนแสวงหางานทำ
- 3) การว่างงานเพราะความบกพร่องในตลาดแรงงาน

นักเศรษฐศาสตร์สำนักนีโอคลาสสิก จึงนำเอาทฤษฎีการแสวงหางานทำมาอธิบายอัตราการว่างงานตามธรรมชาติ ทฤษฎีนี้อธิบายว่าการที่คนงานต้องแสวงหางานทำและนายจ้างต้องแสวงหาลูกจ้างที่ดีเพราะเหตุผล 2 ประการคือ

- 1) งานแต่ละอย่างในตลาดแรงงานแตกต่างกันมากเช่น งานบางอย่างต้องใช้สติปัญญา บางอย่างต้องใช้ฝีมือ บางอย่างต้องใช้กำลัง เป็นต้น คนงานก็ล้วนแตกต่างกันในหลาย ๆ ด้านแต่คนงานมักไม่มีข้อมูลเกี่ยวกับงานที่ตนต้องการทำว่ามีอยู่ที่ไหน เงื่อนไขการจ้างเป็นอย่างไร ฉะนั้นเพื่อให้ได้มาซึ่งข้อมูลประกอบการตัดสินใจเลือก คนงานจึงต้องยอมสละเวลา (คือยอมว่างงาน) และรายได้เพื่อหางานทำ

2) เนื่องจากการหางานทำและการคัดเลือกคนงานย่อมมีค่าใช้จ่ายสูง ค่าใช้จ่ายเหล่านี้เป็นค่าใช้จ่ายที่จมหายไปไม่มีวันได้คืนมา (Sunk cost) ดังนั้น ถ้าคนงานต้องการยึดงานใดเป็นอาชีพนาน ๆ เขาย่อมต้องลงทุนแสวงหางานก่อนข้างนาน จนกว่าจะแน่ใจว่าได้งานดี มิฉะนั้น จะเสียค่าใช้จ่ายไปโดยไม่คุ้ม

ทฤษฎีการแสวงหางานทำอธิบายถึงการเข้าสู่ตลาดแรงงานในรูปของการมีงานทำ โอกาสที่จะได้ทำงานและการว่างงาน สืบเนื่องจากความพร้อมและทักษะความสามารถในการหางาน และอธิบายถึงปัจจัยที่มีความสัมพันธ์กับการมีงานทำและทักษะในการหางาน ได้แก่ การรับข่าวสารแรงงาน โอกาสมีงานทำ ทฤษฎีนี้มีแนวคิดที่ว่าในสภาพที่ตลาดแรงงานมีการให้ข่าวสารข้อมูลน้อย ทั้งนายจ้างและแรงงานขาดความรู้เกี่ยวกับโอกาสของการจ้างงานในตลาดแรงงาน ผู้ที่หางานทำมักจะหลีกเลี่ยงงานแรกที่ได้รับการเสนอเนื่องจากขาดข้อมูลเปรียบเทียบ จึงมักใช้เวลาหางานอื่นและข้อมูลอื่นประกอบ การใช้เวลาเพื่อจะหางานทำนี้จึงนับเป็นการลงทุนอย่างหนึ่งของผู้หางานทำในกรณีนี้การว่างงานจะเกิดขึ้นเพราะปัญหาการขาดประสิทธิภาพของตลาดแรงงานในการให้ข่าวสารข้อมูลที่ชัดเจนและกว้างขวางพอที่จะทำให้ผู้หางานและผู้จ้างงานพบกันในเวลาที่เหมาะสมยิ่งขึ้น


ข้อสรุปของทฤษฎีนี้คือ การว่างงานไม่ได้เกิดจากปัญหาความไม่สมัครใจเพียงอย่างเดียวและอาจเป็นไปได้ที่การว่างงานเป็นจำนวนมากเป็นการว่างงานชั่วคราว และเป็นไปโดยสมัครใจ เพราะใช้เวลาว่างหางานทำถือเป็นการลงทุนเพื่อผลในอนาคต และปัจจัยที่สำคัญที่จะมีผลต่อการตัดสินใจเข้าสู่ตลาดแรงงานก็คือ ระบบข่าวสารแรงงานที่ได้รับ อัตราค่าจ้างที่พอใจ ทักษะในการหางานและฐานะทางเศรษฐกิจ

2.2.5 ทฤษฎีการจ้างงานของนักเศรษฐศาสตร์สำนักคลาสสิก

ทฤษฎีการจ้างงานของนักเศรษฐศาสตร์สำนักคลาสสิกมีความเห็นว่า ระดับการจ้างงานถูกกำหนดโดยอุปสงค์และอุปทานแรงงาน ระดับการจ้างงานจะมีความสัมพันธ์ตรงกับระดับผลผลิต กล่าวคือ ถ้าระดับการจ้างงานเพิ่มขึ้น ระดับผลผลิตก็จะสูงขึ้นด้วย หรือถ้าระดับการจ้างลดลง ระดับผลผลิตก็จะลดลงด้วย หรือถ้าระดับการจ้างคงที่ ระดับผลผลิตจะคงที่ นั่นคือระดับผลผลิตจะขึ้นอยู่กับระดับการจ้างเท่านั้น

1) อุปสงค์แรงงาน (Demand for Labour)

อุปสงค์แรงงาน (Demand for Labour) หมายถึง จำนวนความต้องการแรงงาน ซึ่งสำนักคลาสสิกเชื่อว่ามีความสัมพันธ์ในทิศทางตรงกันข้ามกับอัตราค่าจ้างที่แท้จริง กล่าวคือ ถ้าระดับอัตราค่าจ้างสูง ผู้ผลิตมีอุปสงค์แรงงานน้อย แต่ถ้าอัตราค่าจ้างแท้จริงต่ำ อุปสงค์แรงงานก็จะเพิ่มขึ้น ดังนั้นลักษณะเส้นอุปสงค์ในสินค้านั้นคือเส้นลาดลงจากซ้ายไปทางขวา ดังภาพ



ภาพแสดงเส้นอุปสงค์แรงงานตามแนวคิดของสำนักคลาสสิก

ค่าจ้างที่แท้จริง (Real Wage) หมายถึงอำนาจซื้อจากค่าจ้างที่เป็นตัวเงิน (Money Wage) นั่นคือ ถ้าให้

RW = ค่าจ้างที่แท้จริง

W = ค่าจ้างที่เป็นตัวเงิน


P = ระดับราคาสินค้า

$RW = W/P$

หรืออาจกล่าวได้ว่า ค่าจ้างที่แท้จริงขึ้นอยู่กับค่าจ้างที่เป็นตัวเงินและระดับสินค้า ค่าจ้างที่แท้จริงจะลดลงถ้าระดับราคาสินค้าเพิ่มเร็วกว่าอัตราเพิ่มค่าจ้างที่เป็นตัวเงิน และอัตราค่าจ้างที่แท้จริงจะเพิ่มขึ้นถ้าระดับราคาสินค้าเพิ่มช้ากว่าอัตราค่าจ้างที่เป็นตัวเงิน

2) อุปทานแรงงาน (Supply of Labour)


อุปทานแรงงาน (Supply of Labour) หมายถึง จำนวนชั่วโมงทำงานทั้งหมดของแรงงานในช่วงเวลาใดเวลาหนึ่ง หรือหมายถึง จำนวนคนที่ต้องการทำงานโดยได้รับค่าจ้างหรือผลตอบแทน นักเศรษฐศาสตร์สำนักคลาสสิกเชื่อว่าอุปทานแรงงานมีความสัมพันธ์ทางตรงกับอัตราค่าจ้างที่แท้จริง คือถ้าอัตราค่าจ้างสูง คนงานก็จะเสนอตัวเข้าทำงานจำนวนมากขึ้น แต่ถ้าค่าจ้างแรงงานที่แท้จริงลดต่ำลง คนงานก็จะเสนอตัวทำงานน้อยลง ดังนั้น เส้นอุปทานแรงงานจึงมีลักษณะเหมือนกับเส้นอุปทานในสินค้าทั่วไปคือเอียงลาดจากซ้ายมือขึ้นไปทางขวามือ ดังตัวอย่าง



ภาพแสดงเส้นอุปทานแรงงานตามแนวคิดของสำนักคลาสสิก

3) อัตราค่าจ้างดุลยภาพ

นักเศรษฐศาสตร์สำนักคลาสสิกมีความเห็นว่า อุปสงค์และอุปทานแรงงาน เป็นปัจจัยกำหนดระดับการจ้างงานและอัตราค่าจ้างและอัตราค่าจ้างที่แท้จริง ณ จุดตัดของเส้นอุปสงค์และอุปทานแรงงาน ดังแสดงในภาพ



ภาพแสดงอัตราค่าจ้างดุลยภาพ

เส้นอุปสงค์แรงงานตัดกับเส้นอุปทานแรงงาน ณ จุด E ระดับอัตราค่าจ้างที่แท้จริงเท่ากับ OW และระดับการจ้างงานเท่ากับ OQ ณ ระดับอัตราค่าจ้างและระดับการจ้างงานดังกล่าวเป็นระดับอัตราค่าจ้างดุลยภาพและระดับการจ้างงานดุลยภาพ กล่าวคือ ถ้าระดับอัตราค่าจ้างและระดับการจ้างงานเปลี่ยนแปลงไปจากระดับดุลยภาพแล้ว ก็จะปรับตัวเข้าสู่ระดับอัตราค่าจ้างและระดับการจ้างงานในที่สุด เช่น ถ้าอัตราค่าจ้างสูงขึ้นชั่วคราว สมมติ ณ OW_1 จะเกิดอุปทานแรงงานส่วนเกิน ณ ระดับอัตราค่าจ้างนั้น แรงงานที่ว่างอยู่จะแข่งขันกันเสนอตัวเข้าทำงานในอัตราค่าจ้างที่ต่ำลง ณ ระดับ OW ซึ่งจำนวนอุปสงค์แรงงานจะเท่ากับอุปทานแรงงานพอดี หรือถ้าอัตราค่าจ้างที่ลดต่ำลงกว่าอัตราค่าจ้างดุลยภาพ สมมติ ณ ระดับ OW_2 ก็จะเกิดอุปสงค์ส่วนเกินขึ้นในตลาดแรงงาน การขาดแคลนแรงงานทำให้ผู้ผลิตเสนออัตราค่าจ้างสูงขึ้นจนถึงระดับ OW ซึ่งจำนวนอุปสงค์แรงงานเท่ากับอุปทานแรงงาน

อย่างไรก็ตาม อัตราค่าจ้างดุลยภาพ ที่ถูกกำหนดโดยอุปสงค์และอุปทานแรงงานนั้น มีเงื่อนไขว่า ตลาดแรงงานจะมีลักษณะเป็นตลาดแข่งขันสมบูรณ์ คือมีผู้ต้องการจ้างงานและผู้ต้องการที่จะทำงานจำนวนมาก ไม่มีสหภาพแรงงาน องค์กรของนายจ้างหรือรัฐบาลเข้ามาแทรกแซง อัตราค่าจ้างและผลผลิตของแรงงานไม่ขึ้นกับอัตราค่าจ้าง การเปลี่ยนแปลงอัตราค่าจ้างที่เป็นตัวเงินมีผลต่อการเปลี่ยนแปลงรายได้ที่แท้จริง ถ้าระดับราคาสินค้าทั่วไปเพิ่มเร็วกว่าอัตราค่าจ้างที่เป็นตัวเงินมีผลทำให้รายได้ที่แท้จริงลดลง แต่ถ้าระดับราคาสินค้าเพิ่มช้ากว่าอัตราการเพิ่มค่าจ้างที่เป็นตัวเงินรายได้ที่แท้จริงจะสูงขึ้น

ในทฤษฎีของนักเศรษฐศาสตร์สำนักคลาสสิกระดับการจ้างงานดุลยภาพ จะถูกกำหนดโดยอุปสงค์และอุปทานแรงงาน และเป็นระดับการจ้างเต็มที่ (Full Employment) ณ ระดับการจ้างงานเต็มที่ ถ้ามีการว่างงานเกิดขึ้น จึงเป็นการว่างงานโดยความสมัครใจทั้งสิ้น เนื่องจาก

(1) การว่างงานที่เกิดขึ้นนั้นเนื่องจากคนงานเรียกร้องค่าจ้างที่เป็นตัวเงินสูงเกินไปไม่ยอมรับค่าจ้าง ณ ระดับค่าจ้างที่ปรากฏ จึงสมัครใจที่จะว่างงาน แต่ถ้าคนงานยอมรับค่าจ้างที่เป็นตัวเงินที่ต่ำลง ค่าจ้างที่แท้จริงจะลดลง ระดับการจ้างงานก็จะเพิ่มขึ้นถึงระดับการจ้างงานเต็มที่ที่การว่างงานก็จะหมดไป

(2) จากความเชื่อที่ว่า ระดับอัตราค่าจ้างที่เป็นตัวเงินจะถูกกำหนดโดยการต่อรองระหว่างผู้ประกอบการและคนงานและค่าจ้างที่เป็นตัวเงินจะเป็นปัจจัยกำหนดค่าจ้างที่แท้จริง ดังนั้นคนงานจึงอยู่ในฐานะสามารถกำหนดระดับค่าจ้างที่แท้จริง และกำหนดระดับการจ้างงานได้ ดังนั้นระดับค่าจ้างที่ปรากฏ ถ้ามีการว่างงานเกิดขึ้น จึงเป็นการว่างงานโดยสมัครใจ

นอกจากนี้ในทฤษฎีของสำนักคลาสสิก ระบบเศรษฐกิจจะอยู่ ณ ระดับการจ้างงานเต็มที่เสมอ และเป็นระดับที่ผลผลิตสูงสุด ณ ระดับการจ้างงานเต็มที่ อุปสงค์รวมของระบบเศรษฐกิจเท่ากับอุปทานรวมเสมอ ซึ่งอธิบายโดยใช้กฎของเซย์ (Say's Law) ซึ่งเป็นนักเศรษฐศาสตร์ที่มีชื่อเสียงคนหนึ่งของสำนักคลาสสิก มีความเชื่อว่า ระบบเศรษฐกิจมีการจ้างงานเต็มที่เนื่องจากอุปทานก่อให้เกิดอุปสงค์ (Supply creates its own demand) โดยให้คำอธิบายว่า ในการผลิตผู้ผลิตจะจ่ายค่าตอบแทนปัจจัยการผลิตให้กับเจ้าของและเจ้าของปัจจัยการผลิตจะนำรายได้ที่ได้รับนั้นไปจับจ่ายซื้อสินค้าและบริการ ผู้ผลิตก็จะขายสินค้าได้โดยรับกำไรปกติจึงจูงใจให้ทำการผลิตเพิ่มขึ้นจึงไม่มีผลผลิตส่วนเกินเกิดขึ้นในตลาด แต่อาจมีผลผลิตบางชนิดล้นเกินเกิดขึ้นซึ่งเป็นลักษณะเพียงชั่วคราวเท่านั้น เนื่องจากการปรับตัวอุปสงค์ที่เปลี่ยนแปลงจากสินค้าชนิดหนึ่งไปยังสินค้าอีกชนิดหนึ่ง เมื่ออุปสงค์สามารถปรับตัวได้แล้วสินค้าทุกชนิดที่ผลิตขึ้นก็จะจำหน่ายได้หมด ระบบเศรษฐกิจจึงมีอุปสงค์รวมเท่ากับอุปทานรวมเสมอ และเป็นระดับที่ผลผลิตสูงสุด มีการจ้างงานเต็มที่ การว่างงานที่เกิดขึ้นเป็นการว่างงานโดยสมัครใจ และเป็นปรากฏการณ์ที่เกิดขึ้นเพียงชั่วคราว ถ้าหากปล่อยให้มีการแข่งขันเสรีกลไกราคาจะปรับตัวโดยอัตโนมัติ การว่างงานก็จะหมดไป โดยเหตุผลตามกฎของเซย์

2.2.6 ทฤษฎีการจ้างงานของเคนส์

ทฤษฎีการจ้างงานของเคนส์ ไม่ปฏิเสธทฤษฎีของสำนักคลาสสิกโดยสิ้นเชิง โดยยอมรับว่าระดับผลผลิตมีความสัมพันธ์โดยตรงกับการจ้างงาน คือ เมื่อมีการจ้างงานเพิ่มทำให้ผลผลิตเพิ่ม และเมื่อลดการจ้างงานทำให้ผลผลิตลด トラバドที่การจ้างงานยังต่ำกว่าระดับการจ้างงานเต็มที่ การขยายผลผลิตทำให้การจ้างงานเพิ่มขึ้น แต่เคนส์มีความเห็นแย้งกับสำนักคลาสสิกที่ว่า ระบบเศรษฐกิจอยู่ในระดับดุลยภาพ คือ อุปสงค์รวมเท่ากับอุปทานรวม และระดับการจ้างงานเต็มที่เสมอ เคนส์มีความเห็นว่าผลผลิตจะถูกกำหนดโดยอุปสงค์รวมของระบบเศรษฐกิจ ซึ่งไม่จำเป็นต้องเท่ากับอุปทานรวมเสมอไป อุปสงค์รวมอาจต่ำกว่าอุปทานรวมได้ ดังนั้น ระดับการจ้างงานจึงอาจต่ำกว่าระดับการจ้างงานเต็มที่

ทฤษฎีของสำนักคลาสสิกไม่ได้วิเคราะห์ความสัมพันธ์ระหว่างค่าจ้างกับอุปสงค์รวมของระบบเศรษฐกิจ เนื่องจากหน่วยธุรกิจแต่ละหน่วยเป็นหน่วยย่อยของระบบเศรษฐกิจ แต่ในระบบเศรษฐกิจโดยส่วนรวม ค่าจ้างคือ รายได้ในสัดส่วนที่สูงสุดของครัวเรือนและเป็นปัจจัยสำคัญในการกำหนดรายจ่ายเพื่อการบริโภค ดังนั้น ถ้าอัตราค่าจ้างที่แท้จริงลดลงจะส่งผลให้รายจ่ายเพื่อการบริโภคลดลงด้วย ซึ่งหน่วยธุรกิจจะพบว่าสินค้าที่ผลิตขึ้นไม่สามารถขายได้ ดังนั้น การลดอัตราค่าจ้างจะยังมีผลให้การว่างงานรุนแรงยิ่งขึ้น ถ้าอัตราค่าจ้างที่แท้จริงลดลง ซึ่งอาจเป็นผลจากการลดลงของค่าจ้างที่เป็นตัวเงิน แต่ระดับราคาสินค้าคงที่หรือระดับราคาสินค้าเพิ่มขึ้นในอัตราที่ช้ากว่าอัตราเพิ่มค่าจ้างที่เป็นตัวเงิน จะส่งผลให้กำไรของผู้ผลิตเพิ่มขึ้น ผู้รับกำไรก็สามารถเพิ่มการออมได้มากกว่าอัตราเพิ่มของรายได้ของผู้รับรายได้จากค่าจ้าง การลดอัตราค่าจ้างที่แท้จริงจะเพิ่มกำไร จึงส่งผลให้รายจ่ายเพื่อการบริโภคลดลงและการออมเพิ่มขึ้น เมื่อระบบเศรษฐกิจมีการออมเพิ่มและรายจ่ายเพื่อการบริโภคลดลง จึงส่งผลให้รายได้ประชาชาติและการจ้างงานลดหรือการว่างงานเพิ่มขึ้น จึงสามารถสรุปได้ว่าตามทฤษฎีการจ้างงานของเคนส์ การว่างงานเกิดขึ้นได้เมื่ออุปสงค์รวมไม่เพียงพอ ถ้าต้องการไม่ให้มีการว่างงานเกิดขึ้นจึงจำเป็นต้องให้มีอุปสงค์รวมเพียงพอ

2.3 แนวคิดและทฤษฎีเกี่ยวกับการพยากรณ์

1. การพยากรณ์ (Forecasting) หมายถึง การคาดการณ์ถึงสิ่งใดสิ่งหนึ่งที่จะเกิดขึ้นในช่วงเวลาในอนาคต และนำค่าพยากรณ์ที่ได้นั้นมาใช้ประโยชน์เพื่อการตัดสินใจใด ๆ การพยากรณ์นั้นมีบทบาทที่สำคัญกับทุกด้าน ทั้งหน่วยงานของรัฐบาลและเอกชน การพยากรณ์ทำหน้าที่เป็นเครื่องมือในการวางแผนเพื่อช่วยองค์กรหรือธุรกิจเตรียมความพร้อมในการรับมือกับความไม่แน่นอนที่อาจเกิดขึ้นในอนาคต ช่วยในการตัดสินใจเกี่ยวกับการดำเนินงานในทุกธุรกิจและทุกสาขาอาชีพ การพยากรณ์ที่ทำกันโดยทั่วไปมีอยู่ 3 วิธี คือ

- 1) พยากรณ์โดยอาศัยประสบการณ์และความชำนาญ
- 2) พยากรณ์โดยอาศัยเหตุการณ์และหลักฐาน
- 3) การพยากรณ์ทางสถิติเป็นการพยากรณ์โดยใช้ข้อมูลสถิติ

2. ประโยชน์ของการพยากรณ์

กุนทลี รีนรมย์ (2548) ได้กล่าวถึงประโยชน์ของการพยากรณ์ที่สำคัญสำหรับองค์กรธุรกิจอยู่หลายประการดังต่อไปนี้

2.1 การพยากรณ์ช่วยในการกำหนดตารางการใช้ทรัพยากรที่มีอยู่ในปัจจุบัน (Scheduling existing Resources) ทำให้ทราบว่าทรัพยากรในองค์กรที่มีอยู่ในปัจจุบันมีอะไรบ้าง เช่น เครื่องจักร คนงาน เงินสดหมุนเวียน ฯลฯ มีการใช้ไปเท่าใด ถูกใช้อย่างมีประสิทธิภาพหรือไม่ และมีลักษณะการใช้อย่างไร

2.2 การพยากรณ์จะทำให้องค์กรสามารถแสวงหาทรัพยากรอื่นๆ มาเพิ่มเติม (Acquiring additional Resources) จากพื้นฐานข้อมูลที่มีอยู่ในปัจจุบัน ผนวกกับ Lead time หรือ ระยะเวลาที่กำหนดไว้ในแผน องค์กรจะสามารถเสาะแสวงหาทรัพยากรที่คาดว่าจะต้องการใช้ในอนาคตได้อย่างทันการณ์ เช่น วัสดุอุปกรณ์ เงิน บุคลากร และวัตถุดิบต่างๆ เป็นต้น

2.3 การพยากรณ์ทำให้ทราบว่าองค์กรธุรกิจต้องการทรัพยากรอะไร (Determining what resources are desired) การพยากรณ์ที่มีความถูกต้องแม่นยำจะช่วยให้องค์กรสามารถตัดสินใจได้ว่าทรัพยากรอะไรคือสิ่งที่องค์กรต้องการอย่างแท้จริง ทำให้องค์กรไม่เสียเวลาและไม่เสียเงินไปกับสิ่งที่ไม่จำเป็น

2.4 การพยากรณ์จะสามารถนำมาใช้ในการวางแผนช่องทางการจัดจำหน่าย (Channel of Distribution) เพื่อให้สินค้ามีพอเพียงกับความต้องการของผู้บริโภค และสามารถต่อสู้กับคู่แข่งได้ ทั้งนี้เพื่อจะรักษาส่วนแบ่งการตลาดเอาไว้อย่างต่อเนื่อง

2.5 การพยากรณ์จะสามารถใช้ในการวางแผนจัดหางบประมาณ สำหรับหน่วยงานต่างๆ ขององค์กร เพื่อให้สามารถทำยอดขายได้ถึงเป้าหมายที่ได้ทำการพยากรณ์ไว้

2.6 การพยากรณ์ช่วยในการวางแผนส่งเสริมการขาย (Promotions) ให้กับลูกค้าได้อย่างมีประสิทธิภาพ และสอดคล้องกับสถานการณ์ที่คาดว่าจะเกิดขึ้นในอนาคต กล่าวคือถ้าผลของการพยากรณ์ในอนาคตเป็นไปในทิศทางที่เพิ่มขึ้น ผู้บริหารก็ต้องวางแผนวิธีการส่งเสริมการขายให้เหมาะสม เพื่อให้บรรลุเป้าหมายที่พยากรณ์ไว้ แต่ถ้าผลการพยากรณ์เป็นไปในทิศทางที่ลดลง ผู้บริหารก็ต้องวางแผนคิดหาวิธีส่งเสริมการขายให้มากขึ้น เพื่อช่วยพยุงยอดขายและกระตุ้นให้ผู้บริโภค มาซื้อเพิ่มขึ้น เช่น อาจจะใช้วิธีลด แลก แจก แถม เป็นต้น เพราะฉะนั้นการพยากรณ์จะช่วยให้ผู้บริหารสามารถตัดสินใจเตรียมหาวิธีการรับมือและป้องกันไม่ให้อยอดขายลดลงตามที่พยากรณ์ไว้

2.7 การพยากรณ์เป็นเครื่องมือที่ช่วยในการควบคุมและรักษาส่วนแบ่งตลาด (Market Share) ให้มีความต่อเนื่องในด้านบวก ขณะเดียวกันก็สามารถใช้เป็นเครื่องมือในการประเมินผลการดำเนินงานได้ เพราะผู้บริหารสามารถนำค่าที่พยากรณ์ได้มาใช้เป็นเครื่องมือในการตรวจสอบว่าวิธีการหรือกลยุทธ์ที่องค์กรใช้อยู่เป็นวิธีที่เหมาะสมหรือไม่ ถ้าการพยากรณ์ให้ผลที่ตลาดเคลื่อนจากยอดขายที่เกิดขึ้นจริง ให้สังเกตว่าความคลาดเคลื่อนเกิดจากสาเหตุอะไร จะได้สามารถดำเนินการแก้ไขหรือป้องกันไม่ให้เกิดความผิดพลาดขึ้นอีกได้อย่างทันท่วงที

2.8 การพยากรณ์สามารถใช้เป็นเครื่องมือในการกำหนดเป้าหมายในการดำเนินงาน ทำให้ผู้บริหารสามารถประเมินสถานการณ์และสร้างความคาดหวังในอนาคต นอกจากนี้การพยากรณ์ยังทำให้ผู้ที่เกี่ยวข้องกับงานการขายมีความกระตือรือร้นในการทำงานมากขึ้นอีกด้วย เพราะเขาจะทราบข้อมูลยอดขายในอนาคตว่าจะเป็นเท่าไร ตามที่ปรากฏอยู่ในแผนการตลาด พนักงานขายที่ดีจะต้องพยายามทำงานให้ได้ตามเป้าหมายยอดขายนั้นๆ

3. ช่วงเวลาที่ใช้พยากรณ์

หมายถึงช่วงเวลาในอนาคตที่ต้องการพยากรณ์ (Forecasting period) ช่วงเวลาที่กล่าวถึงนี้อาจมีหน่วยเป็นวัน สัปดาห์ เดือน ไตรมาส หรือปี สำหรับเทคนิคการพยากรณ์ที่แตกต่างกันจะเหมาะสมกับช่วงเวลาที่ต้องการพยากรณ์ต่างกัน ช่วงเวลาที่ใช้พยากรณ์แบ่งออกเป็น 4 ระยะ คือ (ศิริลักษณ์ สุวรรณวงศ์, 2535)

3.1 ช่วงเวลาที่สั้นมาก (Immediate – term Forecasting) เป็นการพยากรณ์ที่มีเวลาน้อยกว่าหรือเท่ากับ 1 ช่วงเวลาในอนาคตที่ต้องการพยากรณ์ เช่นถ้าข้อมูลเป็นรายไตรมาสการพยากรณ์ในช่วงเวลาที่สั้นมากจะเป็นการพยากรณ์ข้อมูลในช่วงเวลาที่ไม่เกินไตรมาสถัดไป

3.2 ช่วงเวลาที่สั้น (Short - Term Forecasting) เป็นการพยากรณ์ ในช่วงเวลา 1- 3 ช่วงเวลาในอนาคตที่ต้องการพยากรณ์

3.3 ช่วงเวลาระยะปานกลาง (Medium - Term Forecasting) เป็นการพยากรณ์ในช่วงเวลาที่มากกว่า 3 เดือนจนถึง 2 ปี โดยข้อมูลเป็นรายเดือน ถ้าข้อมูลมีลักษณะเป็นอย่างอื่น เช่น รายสัปดาห์ หรือรายไตรมาส ผู้พยากรณ์ต้องพิจารณาว่าช่วงเวลาเท่าใดเป็นระยะเวลากลาง การพยากรณ์ช่วงเวลาระยะกลางที่พบบ่อย เช่น การวางแผนการผลิตของบริษัทแห่งหนึ่ง

3.4 ช่วงระยะยาว (Long - Term Forecasting) เป็นการพยากรณ์ ในช่วงเวลา 2 ปีขึ้นไป การพยากรณ์ระยะยาวใช้ในการวางแผนระยะยาว

4. รูปแบบของข้อมูล

การเลือกวิธีการพยากรณ์จะต้องคำนึงถึงรูปแบบของข้อมูลในอดีต ซึ่งถ้าสังเกตข้อมูลอนุกรมเวลา แต่ละชุดจะมองเห็นถึงการเปลี่ยนแปลงขึ้นๆ ลงๆ ซึ่งสาเหตุของการเปลี่ยนแปลงที่เกิดขึ้นกับข้อมูลนั้น เนื่องจากอิทธิพลขององค์ประกอบต่าง ๆ 4 ประการ (พิภพ ลลิตาภรณ์, 2549) คือ

4.1 องค์ประกอบของแนวโน้ม (Trend) เป็นองค์ประกอบที่ แสดงถึงทิศทางของข้อมูล แต่ละชุด ตั้งแต่อดีตจนถึงระยะเวลาสุดท้ายของข้อมูลที่รวบรวมได้ ซึ่งทิศทางของข้อมูลนั้นอาจจะพุ่งไปในแนวที่สูงขึ้น หรือลดต่ำลง ข้อมูลอนุกรมเวลาที่เมื่อองค์ประกอบของค่าแนวโน้มส่วนใหญ่จะเกี่ยวข้องกับความสัมพันธ์ของข้อมูลในระยะเวลาที่ค่อนข้างยาวนาน เช่น อุปสงค์สินค้า การใช้พลังงาน เป็นต้น ลักษณะของแนวโน้มอาจจะเป็นเส้นตรงเส้นโค้งหรืออื่น ๆ ก็ได้

4.2 องค์ประกอบของการเปลี่ยนแปลงตามฤดูกาล (Seasonal) หมายถึงการที่ข้อมูล อนุกรมเวลามีรูปแบบการเคลื่อนไหวขึ้นหรือลงทำนองเดียวกันในช่วงเวลาเดียวกันของรอบเวลาหนึ่ง ซึ่งส่วนใหญ่จะไม่เกิน 1 ปี โดยที่ หน่วยของระยะเวลาอาจจะเป็นราย 3 เดือน 5 เดือน รายเดือน รายสัปดาห์ รายวัน หรือแม้แต่ว่าชั่วโมงก็ได้ข้อมูลที่มักได้รับผลกระทบจากความเคลื่อนไหว หรือ เปลี่ยนแปลงตามฤดูกาล ได้แก่การผลิต การขาย เป็นต้น สำหรับรูปแบบของดัชนีฤดูกาล โดยทั่วไปมี 6 รูปแบบ ดังนี้

4.3 องค์ประกอบของการผันแปรตามวัฏจักร (Cyclical) เป็นลักษณะการเคลื่อนไหว ของข้อมูลที่ขึ้น ๆ ลง ๆ คล้ายกับลูกคลื่นที่มีผลกระทบกระเทือนต่อธุรกิจโดยทั่ว ๆ ไปรูปแบบของ การผันแปรตามวัฏจักรนี้แตกต่างจากการผันแปรตามฤดูกาล คือเราจะไม่ทราบว่าช่วงของการเกิดวัฏจักรหนึ่ง ๆ นั้นว่าจะใช้ระยะเวลายาวนานเท่าใด เนื่องจากการเปลี่ยนแปลงตามวัฏจักรส่วนใหญ่ เป็นปรากฏการณ์ที่เกิดขึ้นในด้านธุรกิจและเศรษฐศาสตร์ ดังนั้นการผันแปรตามวัฏจักรโดยทั่วไป จะแสดงถึงภาวะการเกิดซ้ำกันของภาวะธุรกิจเฟื่องฟูถดถอย และตกต่ำภาวะต่าง ๆ เหล่านี้ อาจจะสั้นหรือยาวก็ได้

4.4 องค์ประกอบความผันแปรเชิงสุ่ม ซึ่งเป็นผลอันเนื่องมาจากความผิดปกติ (Irregular) เป็นการเปลี่ยนแปลงของข้อมูลอนุกรมเวลาที่เกิดจากปัจจัยที่ไม่อาจคาดคะเนได้ล่วงหน้า เช่น การเกิดภาวะผิดปกติทางดินฟ้าอากาศ การเกิดน้ำท่วม การนัดหมายหยุดงานของบุคลากร และ การเกิดสงคราม เป็นต้น ซึ่งเป็นปรากฏการณ์ที่เราไม่อาจทำนายได้ล่วงหน้า

5. เทคนิคการพยากรณ์

โดยทั่วไปแล้วสามารถแบ่งออกเป็น 2 ประเภท ได้แก่ การพยากรณ์เชิงคุณภาพ (Qualitative forecasting methods) และการพยากรณ์เชิงปริมาณ (Quantitative forecasting methods)

5.1 การพยากรณ์เชิงคุณภาพ (Qualitative Forecasting Methods) เป็นเทคนิคการพยากรณ์ที่ขึ้นอยู่กับประสบการณ์ การประเมินความคิดเห็น ของผู้เชี่ยวชาญ (Expert opinion) และใช้ดุลยพินิจของบุคคลเพื่อทำนายการเปลี่ยนแปลงในระยะยาว เป็นการพยากรณ์ที่ใช้วิจารณญาณ (Judgmental Forecasting) โดยจะถือเกณฑ์วิจารณญาณส่วนบุคคล หรือมีการตกลงกันของคณะกรรมการเกี่ยวกับเหตุการณ์ หรือสถานการณ์ในอนาคต โดยทั่วไปแล้วเทคนิคนี้จะถูกนำมาใช้สำหรับการพยากรณ์ระยะยาว (Long-range Projection) หรือเมื่อองค์กรมีข้อมูลอยู่จำกัด ไม่สามารถหาได้ หรือข้อมูลที่มีอยู่ในปัจจุบันไม่เกี่ยวข้อง หรือเมื่อข้อมูลที่มีอยู่ไม่สามารถนำมาใช้ได้ นอกจากนี้เทคนิคนี้ยังเหมาะกับการใช้แนะนำผลิตภัณฑ์ใหม่เข้าสู่ตลาด หรือมีการเปลี่ยนแปลงเทคโนโลยีใหม่ เนื่องจากไม่มีข้อมูลอยู่

5.2 การพยากรณ์เชิงปริมาณ (Quantitative Forecasting Methods) จะใช้เทคนิคทางคณิตศาสตร์บนพื้นฐานของข้อมูล ปริมาณความต้องการที่ เก็บรวบรวมไว้ในอดีต (Historical Data) รวมทั้งข้อมูลที่เกี่ยวข้องอื่น ๆ เพื่อใช้ในการพยากรณ์ โดยจะจำแนกวิธีการพยากรณ์ออกเป็น 2 วิธีใหญ่ ๆ คือ 1) การพยากรณ์ด้วยเทคนิคอนุกรมเวลา (Time Series Forecasting) ซึ่งจะมีข้อสมมุติที่ว่า ค่าพยากรณ์ที่เกิดขึ้นจะขึ้นกับข้อมูลที่ผ่านมาในอดีต ดังนั้นวิธีการนี้จึงจะใช้เฉพาะข้อมูลเชิงปริมาณที่เก็บรวบรวมไว้ในอดีตมาพยากรณ์ และ 2) การพยากรณ์เชิงสาเหตุ (Causal or Associating Forecasting) จะสมมุติว่าปัจจัยอื่น ๆ ตั้งแต่ 1 ตัวแปรขึ้นไป (ตัวแปรอิสระ) มีความสัมพันธ์กับปริมาณความต้องการ ซึ่งจะนำเข้ามาใช้ในตัวแทนที่จะพยากรณ์ความต้องการในอนาคต เนื่องจากการพยากรณ์เชิงปริมาณนั้นขึ้นกับข้อมูลในอดีต ดังนั้นค่าการพยากรณ์จะมีความเชื่อถือลดลงเมื่อระยะเวลาการพยากรณ์เพิ่มขึ้น ดังนั้นหากองค์กรใดต้องการที่จะพยากรณ์ในระยะยาว ควรจะนำเอาการพยากรณ์ทั้งเชิงปริมาณและคุณภาพเข้ามารวมวิเคราะห์ ด้วย (ทรงศิริแต่สมบัติ, 2539)

6. การเลือกเทคนิคในการพยากรณ์

วิธีการพยากรณ์มีผู้พัฒนาขึ้นหลายวิธี โดยแต่ละวิธีก็จะเหมาะสมกับข้อมูลที่มีลักษณะการเคลื่อนไหวที่แตกต่างกันออกไป รวมทั้งขึ้นอยู่กับวัตถุประสงค์ของการนำเอาค่าพยากรณ์ที่ได้ไปใช้งาน และจำเป็นอย่างยิ่งที่จะต้องเลือกวิธีการพยากรณ์ให้เหมาะสมกับการนำไปใช้ ดังนั้น ก่อนที่จะดำเนินการพยากรณ์ ผู้พยากรณ์จะต้องทราบและตระหนักถึงรายละเอียดต่าง ๆ ที่เกี่ยวข้องดังต่อไปนี้

6.1 ระยะเวลาในการพยากรณ์ล่วงหน้า ผู้พยากรณ์มักจะพยากรณ์การเกิดขึ้นของเหตุการณ์แตกต่างกัน ขึ้นอยู่กับวัตถุประสงค์ของการนำค่าพยากรณ์ไปใช้งาน ระยะเวลาในการพยากรณ์ล่วงหน้าสามารถแบ่งได้เป็น ระยะสั้น ระยะกลาง และ ระยะยาว การพยากรณ์ระยะสั้นจะเป็นช่วงเวลาที่พยากรณ์ล่วงหน้าไม่เกิน 3 เดือน ระยะกลาง เป็นช่วงเวลาตั้งแต่ 3 เดือนขึ้นไป จนถึง 2 ปี และระยะยาว เป็นช่วงเวลาที่ต้องการพยากรณ์ไปล่วงหน้าตั้งแต่ 2 ปีขึ้นไป ระยะเวลาในการ

พยากรณ์ล่วงหน้านี้จะส่งผลถึงเทคนิคที่จะเลือกใช้ในการพยากรณ์ โดยแต่ละช่วงเวลาก็จะเหมาะสมกับเทคนิคการพยากรณ์ที่แตกต่างกันออกไป เช่น หากผู้พยากรณ์ต้องการที่จะพยากรณ์ในระยะยาวแล้วการพยากรณ์เชิงคุณภาพจะมีความเหมาะสมมากกว่า ข้อมูลที่ใช้ในการพยากรณ์นั้น อาจจะมีหน่วยวัดเป็นรายชั่วโมง รายวัน รายสัปดาห์ รายเดือน หรือรายไตรมาส ก็ได้ขึ้นกับประเด็นของเรื่องการศึกษา เช่น ห้างสรรพสินค้าแห่งหนึ่งพิจารณาจำนวนลูกค้าที่เข้ามาใช้บริการในแต่ละวันที่ห้างเปิดบริการเพื่อจัดสรรพนักงานให้บริการได้สอดคล้องกับจำนวนลูกค้าในแต่ละช่วงเวลา หรือ บริษัทแห่งหนึ่งผลิตเสื้อผ้าสำเร็จรูปต้องการพยากรณ์ยอดขายสินค้าเสื้อผ้าสำเร็จรูปในแต่ละเดือน เป็นต้น อย่างไรก็ตามข้อมูลที่น่ามาใช้ในการวิเคราะห์นั้นจะต้องมีขนาดใหญ่พอสมควร รวมทั้งมีความทันสมัยด้วย

6.2 รูปแบบของข้อมูล ส่วนประกอบของข้อมูลจะเป็นตัวกำหนดเทคนิคที่ใช้ในการพยากรณ์ ดังนั้นก่อนที่ผู้พยากรณ์จะเลือกวิธีที่จะใช้เทคนิคในการพยากรณ์ จำเป็นอย่างยิ่งที่จะต้องนำข้อมูลที่มีอยู่มาพล็อตกราฟลงจุด เพื่อดูลักษณะการเคลื่อนไหวของข้อมูลเบื้องต้นก่อน

6.3 ค่าใช้จ่ายในการพยากรณ์ ค่าใช้จ่ายเป็นหลักเกณฑ์สำคัญที่ใช้ในการตัดสินใจเลือกเทคนิคการพยากรณ์ซึ่งประกอบด้วยค่าใช้จ่ายที่เกิดขึ้น เพื่อพัฒนาตัวแบบที่ใช้ในการพยากรณ์ ค่าใช้จ่ายที่เกิดขึ้นจากการเก็บข้อมูลที่ให้ตัวแบบที่สร้างขึ้นมีความถูกต้องแม่นยำตลอดเวลา และค่าใช้จ่ายที่เกิดขึ้นจากความผิดพลาดที่มาจากพยากรณ์ ความสำคัญของค่าใช้จ่ายแต่ละประเภทจะขึ้นอยู่กับวิธีการและสถานการณ์ เช่น วิธีการพยากรณ์เชิงคุณภาพและเชิงเทคโนโลยีส่วนมากจะต้องประมาณค่าใช้จ่ายแยกเป็นส่วนๆ รวมทั้งจะต้องมีการประมาณปัจจัยนำเข้าทางทรัพยากรมนุษย์ การได้ข้อมูลจากภายนอกจะเป็นค่าใช้จ่ายส่วนใหญ่ที่เกิดขึ้น และ ค่าใช้จ่ายเหล่านี้จะเกิดขึ้นอีกทุกครั้งที่พยากรณ์ใหม่ สำหรับการพยากรณ์เชิงปริมาณแล้ว ค่าใช้จ่ายส่วนใหญ่ไม่ขึ้นอยู่กับสถานการณ์ ทางด้านการบริการจัดการ วิธีการพยากรณ์เชิงปริมาณที่ใช้กันในองค์กรส่วนใหญ่จะใช้คอมพิวเตอร์ ค่าใช้จ่ายในด้านการพัฒนาจึงเป็นเรื่องของการเขียนและดัดแปลงโปรแกรมที่จะใช้ในการพยากรณ์ ซึ่งจะรวมถึงทรัพยากรมนุษย์ที่ต้องใช้เพื่อพัฒนาโปรแกรม และค่าใช้จ่ายของเวลาคอมพิวเตอร์เพื่อจัดระบบการทำงานของวิธีการที่ใช้ เป็นต้น

6.4 ระดับความแม่นยำในการพยากรณ์ ระดับความแม่นยำของการพยากรณ์และความคลาดเคลื่อนที่เกิดขึ้นจะขึ้นกับสถานการณ์ที่ต้องการจะพยากรณ์ ในบางกรณี ความผิดพลาด 20% ก็สามารถยอมรับได้ ในขณะที่บางกรณีความผิดพลาด 1% ก็ก่อให้เกิดความเสียหายมากมายต่อองค์กร และหากพิจารณาในแง่ของการวิเคราะห์การตัดสินใจแล้วก็จะพบว่า มีความแตกต่างระหว่างการตัดสินใจที่ดี (Good Decision) และผลลัพธ์ที่ดี (Good Outcome) ถ้าหากผู้พยากรณ์สามารถออกแบบจำลองสถานการณ์ได้ท่ามกลางความไม่แน่นอน ก็น่าที่จะส่งเสริมสนับสนุนการพยากรณ์โดยไม่ต้องคำนึงถึงระดับความแม่นยำมากนัก

6.5 ข้อมูลในอดีตที่เก็บรวบรวมไว้ ข้อมูลในอดีตที่มีอยู่จะเป็นตัวตัดสินใจ หลักในการที่จะเลือกเทคนิคการพยากรณ์ นอกจากนั้นแล้วความถูกต้องของข้อมูลก็เป็นปัจจัยที่สำคัญอย่างยิ่งในการพยากรณ์ ดังนั้นหากองค์กรใดยังไม่ได้จัดเก็บข้อมูลในอดีต จำเป็นอย่างยิ่งที่จะต้องรีบดำเนินการ

6.6 ความง่ายในการที่ผู้ปฏิบัติจะนำไปใช้ต่อความง่ายของเทคนิคการพยากรณ์ในการที่ผู้ปฏิบัติจะนำไปใช้ต่อเป็นปัจจัยที่สำคัญอีกปัจจัยหนึ่ง หากผู้บริหารหรือผู้ที่เกี่ยวข้องขาดความรู้ความ

เข้าใจในเทคนิคการพยากรณ์ที่นำมาใช้การพยากรณ์ที่ทำขึ้นก็จะไม่มีความหมาย หรือถูกนำไปประยุกต์ใช้อย่างไม่ถูกต้อง เช่น วิธีการของบ็อก-เจนกินส์ (Box and Jenkins Method) ไม่เป็นที่นิยมในหลายองค์กร เนื่องจากเทคนิคดังกล่าวยุ่งยากเกินไปสำหรับผู้ใช้งาน ที่จะเข้าใจแนวความคิดพื้นฐานของวิธีการในระดับที่จะมั่นใจได้ว่า วิธีการดังกล่าวสามารถนำไปประยุกต์ใช้ได้อย่างถูกต้อง

7. กระบวนการพยากรณ์

กระบวนการพยากรณ์ (Forecasting Process) หมายถึง ขั้นตอนการเลือกเทคนิคการพยากรณ์ ตั้งแต่หนึ่งวิธีขึ้นไป ที่สามารถประยุกต์ใช้กับข้อมูลที่จำเป็นต่อการพยากรณ์ ซึ่งประกอบด้วย 9 ขั้นตอน ต่อไปนี้ (กิตติพงศ์อินทร์ทอง, 2556)

7.1 การกำหนดวัตถุประสงค์ของการพยากรณ์ (Specific Objectives) เป็น การกำหนดวัตถุประสงค์ให้ชัดเจนว่าการพยากรณ์จะไปใช้ในการตัดสินใจอย่างไร เช่น ใช้เพื่อตัดสินใจ ลงทุน (การพยากรณ์ระยะยาว) หรือเพื่อวางแผนกลยุทธ์ (การพยากรณ์ระยะกลาง)

7.2 การกำหนดสิ่งที่จะพยากรณ์ให้ชัดเจน (Determine what to forecast) เช่น พยากรณ์ ยอดขายเป็นหน่วยสินค้า หรือเป็นตัวเงิน (บาทหรือดอลลาร์) การพยากรณ์เป็นยอดขายรวม ยอดขายสายผลิตภัณฑ์ยอดขายของแต่ละภูมิภาค ยอดขายในประเทศ หรือยอดขายต่างประเทศ เป็นต้น

7.3 การเก็บรวบรวมข้อมูล (Data Collection) เป็นการเก็บรวบรวมข้อมูลที่เกี่ยวข้องกับการพยากรณ์อย่างเหมาะสม และเป็นข้อมูลที่ถูกต้อง ขั้นตอนนี้เป็นขั้นตอนที่ยากและใช้เวลามากที่สุดในการเก็บรวบรวมข้อมูลจะต้องพิจารณาถึงข้อกำหนดด้านเวลา (Identify time dimensions) โดยพิจารณา 2 ประการคือ ช่วงระยะเวลาการพยากรณ์ (Length and periodicity) เช่น ประจำปี ประจำไตรมาส ประจำเดือน ประจำวัน และความเร่งด่วนในการพยากรณ์ (Urgency) ถ้ามีความจำเป็นเร่งด่วน วิธีที่ใช้ในการพยากรณ์จะมีความซับซ้อนน้อยกว่า และข้อกำหนดเกี่ยวกับข้อมูล (Data considerations) การพิจารณาจากปริมาณและประเภทของข้อมูลที่มีเป็นข้อมูลภายในหรือภายนอกบริษัทเป็นข้อมูลรายปี รายเดือน เป็นข้อมูลที่เป็นตัวเงินหรือหน่วยสินค้า

7.4 การลดข้อมูล (Data Reduction) บางครั้งข้อมูลที่เกี่ยวข้องมีมากเกินไป และทำให้การพยากรณ์มีความถูกต้องน้อยลง จึงจำเป็นต้องลดข้อมูลบางตัวที่อาจจะไม่เกี่ยวข้องกับการพยากรณ์ลง

7.5 การเลือกแบบจำลองในการพยากรณ์ (Model Selection) การเลือกวิธีการพยากรณ์ ขึ้นอยู่กับรูปแบบของข้อมูล จำนวนข้อมูลที่มีและระยะเวลาการพยากรณ์ การเลือกวิธีการพยากรณ์ที่เหมาะสมกับข้อมูลจะช่วยลดความผิดพลาดในการพยากรณ์รูปแบบการพยากรณ์ ที่ยิ่งง่ายจะยิ่งดีต่อการยอมรับของผู้ตัดสินใจ วิธีการพยากรณ์จะต้องมีความสมดุลระหว่างความถูกต้อง และเป็นวิธีที่ง่ายต่อความเข้าใจ

7.6 การพยากรณ์ (Model Extrapolation) เป็นการพยากรณ์เหตุการณ์ที่ผ่านไป โดยใช้ข้อมูลจริงที่มีอยู่ และประเมินว่าวิธีใดเหมาะสม (fit) กับข้อมูลในอดีตก่อน โดยการวัดค่าคลาดเคลื่อนที่เกิดขึ้น

7.7 การเตรียมการพยากรณ์ (Forecast Preparation) เมื่อมีวิธีการพยากรณ์มากกว่า 2 วิธีขึ้นไปที่เหมาะสม การรวมค่าการพยากรณ์จากวิธีเหล่านั้นจะทำให้ค่าพยากรณ์ดีขึ้นกว่าการใช้วิธีเดียว

7.8 การนำเสนอผลการพยากรณ์ (Forecast Presentation) การนำเสนอค่าพยากรณ์ ให้กับผู้บริหารหรือผู้ใช้ด้วยการเขียนเป็นลายลักษณ์อักษรหรือนำเสนอด้วยวาจา (Written/oral) เป็นขั้นตอนนี้มีความสำคัญมากเช่นกัน เพราะสามารถสร้างความเข้าใจให้กับผู้บริหารหรือผู้ใช้ได้

7.9 การตรวจสอบผลการพยากรณ์ (Tracking Results) การติดตามผลอย่างต่อเนื่อง ว่าผลการพยากรณ์เมื่อเปรียบเทียบกับค่าจริงแล้วมีความถูกต้องอย่างไร ซึ่งวิธีที่เคยพยากรณ์ได้ดีที่สุด อาจมีความถูกต้องลดลง เนื่องจากสภาพแวดล้อมเปลี่ยนไปอาจจะต้องหาวิธีอื่นมาแทนการพยากรณ์สามารถเรียนรู้ได้จากความผิดพลาด การทบทวนค่าคลาดเคลื่อนของการพยากรณ์อย่างรอบคอบจะช่วยให้สามารถเข้าใจถึงสาเหตุของความเบี่ยงเบนระหว่างค่าจริงกับค่าพยากรณ์ได้ดีขึ้น

8. การพิจารณาเลือกตัวแบบพยากรณ์

ในการเลือกตัวแบบหรือวิธีการพยากรณ์ลำดับแรกผู้พยากรณ์จำเป็นต้องศึกษารูปแบบ ของชุดข้อมูลอย่างละเอียดก่อน เช่น ทำการตรวจสอบว่าชุดข้อมูลมีรูปแบบอย่างไร รูปแบบองค์ประกอบของแนวโน้ม วัฏจักร ฤดูกาล หรือว่ามีเพียงตัวแปรสุ่มเพียงอย่างเดียว ซึ่งวิธีการที่จะทำให้ทราบถึงองค์ประกอบของข้อมูลเหล่านี้ สามารถทำได้จากการวาดกราฟและการวิเคราะห์ค่าสัมประสิทธิ์สหสัมพันธ์ เมื่อทราบรูปแบบของชุดข้อมูลแล้ว จึงนำไปเลือกตัวแบบหรือวิธีการพยากรณ์โดยเกณฑ์ในการเลือก วิธีการพยากรณ์ที่เหมาะสมมีดังนี้ (กิตติพงษ์ อินทร์ทอง, 2556)

8.1 ชุดข้อมูลที่มีลักษณะคงที่ (Stationary Data) คือ อนุกรมที่มีค่าเฉลี่ยไม่เปลี่ยนแปลงเมื่อเวลาผ่านไป วิธีการพยากรณ์จะใช้ข้อมูลในอดีตเป็นค่าพยากรณ์ในอนาคต โดยที่เทคนิคการพยากรณ์สำหรับข้อมูลที่มีลักษณะคงที่จะใช้เมื่อ

- 1) ข้อมูลที่ไม่ค่อยเปลี่ยนแปลง เช่น จำนวนของเสียต่อสัปดาห์ ซึ่งมีอัตราเดียวกันทุกสัปดาห์
- 2) ต้องการรูปแบบง่ายๆ เพราะขาดข้อมูล หรือเพื่อให้ง่ายต่อการอธิบาย หรือการปฏิบัติ เช่น ธุรกิจหรือองค์กรใหม่และมีข้อมูลในอดีตเล็กน้อย
- 3) ข้อมูลที่มีลักษณะเป็นแนวโน้ม อาจมีการเปลี่ยนรูปเป็นข้อมูลคงที่ เช่น การเปลี่ยนรูปอนุกรมโดยวิธีถอยรูดที่สองหรือการหาผลต่าง
- 4) ข้อมูลที่เป็นกลุ่มของค่าคลาดเคลื่อนจากการพยากรณ์ เทคนิควิธีการพยากรณ์ที่เหมาะสมกับชุดข้อมูลที่มีลักษณะคงที่ ได้แก่ วิธีนาอีฟ (Native Methods) วิธีค่าเฉลี่ยอย่างง่าย (Simple Average Methods) วิธีค่าเฉลี่ยเคลื่อนที่ (Moving Average) วิธีบ็อกซ์และเจนกินส์ (Box-Jenkins Methods)

8.2 ชุดข้อมูลที่มีลักษณะเป็นแนวโน้ม (Data with a Trend) คือ อนุกรมเวลาที่มีการเพิ่มขึ้นหรือลดลงเมื่อเวลาเพิ่มขึ้นในระยะยาว หรือกล่าวได้ว่าอนุกรมเวลาที่มีลักษณะเป็นแนวโน้ม ค่าเฉลี่ยจะมีการเปลี่ยนแปลงเมื่อเวลาเพิ่มขึ้น และสามารถคาดได้ว่าจะเพิ่มขึ้นหรือลดลงในช่วงเวลาที่พยากรณ์เวลาใด เทคนิคการพยากรณ์สำหรับข้อมูลที่มีแนวโน้มจะใช้เมื่อประสบสถานการณ์ดังนี้

- 1) มีการเพิ่มขึ้นของผลิตผลและเทคโนโลยีใหม่ที่ทำให้รูปแบบการดำรงชีวิต (Lifestyle) ของผู้บริโภคเปลี่ยนแปลงไป
- 2) เมื่อมีการเพิ่มขึ้นหรือลดลงของจำนวนประชากร ทำให้ความต้องการสินค้า หรือบริการเปลี่ยนแปลงไปในทิศทางเดียวกัน

3) เมื่ออำนาจการซื้อได้รับผลกระทบจากตัวแปรทางเศรษฐกิจเนื่องจากเงินเฟ้อ

4) เมื่อผู้บริโภครู้จักหรือยอมรับผลิตภัณฑ์มากขึ้น

เทคนิควิธีการพยากรณ์ที่เหมาะสมกับชุดข้อมูลที่มีลักษณะแบบแนวโน้มคือ วิธีค่าเฉลี่ยเคลื่อนที่ (Moving Average) วิธีปรับเรียบเอ็กซ์โปเนนเชียลของโฮลท์ (Holt's Exponential Smoothing Method) วิธีการวิเคราะห์ความถดถอย (Simple Regression) วิธีปรับให้เรียบเอ็กซ์โปเนนเชียลซ้ำสองครั้งหรือวิธีของบราวน์ (Double Exponential Smoothing) วิธีบ็อกซ์และเจนกินส์ (Box-Jenkins Methods)

8.3 ชุดข้อมูลที่มีลักษณะฤดูกาล (Seasonal Data) คือ อนุกรมฤดูกาลเป็นอนุกรมเวลาที่มีรูปแบบที่เปลี่ยนแปลงซ้ำเติมในช่วงเวลาเดียวกันทุกปี การพัฒนาเทคนิคการพยากรณ์สำหรับอนุกรมฤดูกาล มักเป็นวิธีที่เกี่ยวข้องกับการแยกส่วนประกอบอนุกรมเวลา โดยมีการประมาณค่าดัชนีฤดูกาลจากอนุกรมในอดีต ค่าดัชนีเหล่านี้ใช้เพื่อเพิ่มหรือขจัดค่าฤดูกาลในการพยากรณ์ออกจากค่าสังเกต เทคนิคการพยากรณ์สำหรับข้อมูลที่มีลักษณะฤดูกาลจะใช้เมื่อประสบสถานการณ์ดังนี้

1) สภาพของอากาศมีอิทธิพลต่อข้อมูลที่สนใจ เช่น ยอดขายเครื่องปรับอากาศในฤดูร้อน กิจกรรมในฤดูร้อนหรือฤดูหนาว (เช่น การว่ายน้ำ) เสื้อผ้า และผลิตผลเกษตรตามฤดูกาล

2) เวลาตามปฏิทินมีผลต่อข้อมูลที่สนใจ เช่น ยอดขายร้านค้าปลีกในวันหยุด วันปีใหม่

เทคนิควิธีการพยากรณ์ที่ใช้สำหรับชุดข้อมูลที่มีลักษณะแบบฤดูกาลได้แก่ วิธีแยกองค์ประกอบอนุกรมเวลา (Classical Decomposition) วิธี Census X-12 วิธีปรับเรียบเอ็กซ์โปเนนเชียลวินเตอร์ (Winter's Exponential Smoothing) วิธีการวิเคราะห์ถดถอยพหุคูณ (Multiple Regression) และวิธีบ็อกซ์และเจนกินส์ (Box-Jenkins Methods)

8.4 ชุดข้อมูลที่มีลักษณะที่เคลื่อนไหวตามวัฏจักร (Cyclical Series) คือ อนุกรมเวลาที่มีการเคลื่อนไหวตามวัฏจักร มีลักษณะการเคลื่อนไหวขึ้นลงคล้ายรูปคลื่นรอบๆ เส้นแนวโน้ม โดยลักษณะของข้อมูลจะเกิดขึ้นซ้ำกันทุก 2-3 ปีหรือมากกว่านั้น การสร้างแบบจำลองของรูปแบบวัฏจักรทำได้ยาก เพราะมีรูปแบบไม่แน่นอน และขนาดของการเคลื่อนไหวมักจะแตกต่างกัน โดยสามารถนำวิธีแยกส่วนประกอบอนุกรมเวลามาวิเคราะห์ข้อมูลที่เคลื่อนไหวตามวัฏจักรได้ เนื่องจากวัฏจักรจะมีลักษณะที่ไม่ปกติ การวิเคราะห์ส่วนประกอบของวัฏจักรจำเป็นต้องหาตัวชี้้นำทางเศรษฐกิจ

1) เทคนิคการพยากรณ์สำหรับข้อมูลที่มีลักษณะที่เคลื่อนไหวตามวัฏจักร จะใช้เมื่อสถานการณ์ ดังนี้

1.1) วงจรของธุรกิจมีอิทธิพลต่อข้อมูลที่สนใจ เช่น ปัจจัยทางเศรษฐกิจ การตลาดหรือการแข่งขัน

1.2) เกิดการเปลี่ยนแปลงในรสนิยม เช่น แฟชั่น ดนตรีอาหาร เป็นต้น

1.3) เกิดการเปลี่ยนแปลงของประชากร เช่น เกิดสงคราม อดอยาก โรคระบาด และภัยธรรมชาติ

1.4) เกิดการเปลี่ยนแปลงในวงจรชีวิตของผลิตภัณฑ์เช่น ชั้นแนะนำ ชั้นเจริญเติบโต ชั้นอิ่มตัว และชั้นถดถอย

2) เทคนิควิธีการพยากรณ์ที่ใช้สำหรับชุดข้อมูลที่เคลื่อนไหวตามวัฏจักร ได้แก่ วิธีแยกองค์ประกอบอนุกรมเวลา (Classical Decomposition) วิธีการวิเคราะห์ถดถอยพหุคูณ (Multiple Regression) วิธี บ็อกซ์และเจนกินส์ (Box-Jenkins Methods) ตัวชี้วัดภาวะทางเศรษฐกิจ (Economic Indicators) แบบจำลองทางเศรษฐมิติ (Econometric Models)

3) เทคนิคหรือวิธีการพยากรณ์ที่ได้กล่าวมานี้ จะสัมพันธ์กับระยะเวลา สำหรับการพยากรณ์ ในระยะสั้นและระยะกลางจะสามารถใช้เทคนิคการพยากรณ์ได้หลากหลายวิธี แต่เมื่อช่วงระยะเวลา ในการพยากรณ์เพิ่มขึ้น จำนวนเทคนิคที่จะนำมาประยุกต์ใช้จะลดน้อยลง เช่น เทคนิคค่าเฉลี่ย เคลื่อนที่ และวิธีการปรับเรียบจะใช้คาดการณ์เกี่ยวกับเศรษฐกิจได้ไม่ตึกนัก ในขณะที่แบบจำลองทาง เศรษฐมิติ (Econometric Models) จะใช้ได้ตึกกว่า โดยสามารถจำแนกวิธีการพยากรณ์ให้มีความ เหมาะสมกับระยะเวลาได้ดังนี้

- 3.1) วิธีการวิเคราะห์ถดถอย เหมาะสำหรับการพยากรณ์ในระยะสั้น ระยะกลางและระยะยาว
- 3.2) วิธีค่าเฉลี่ยเคลื่อนที่การแยกส่วนประกอบอนุกรมเวลา เหมาะสำหรับการพยากรณ์ระยะ สั้นและระยะกลาง
- 3.3) แบบจำลองทางเศรษฐมิติ เหมาะสำหรับการพยากรณ์ระยะสั้นและระยะกลาง
- 3.4) ส่วนการพยากรณ์เชิงคุณภาพมักใช้ในการพยากรณ์ระยะยาว โดยผู้ที่ต้องการพยากรณ์ จะคาดการณ์โดยอาศัยประสบการณ์

9. การเปรียบเทียบความคลาดเคลื่อนของตัวแบบพยากรณ์

ในการพยากรณ์ใดๆ ย่อมต้องการให้มีความคลาดเคลื่อนน้อยที่สุด ดังนั้น ในการเลือกใช้แบบจำลอง การพยากรณ์จึงควรพิจารณาว่าการพยากรณ์ที่ได้นั้น มีความแม่นยำมากน้อยเพียงใดวิธีการประเมินความ แม่นยำของการพยากรณ์มีหลายวิธี เช่น Root Mean Square Error (RMSE) Mean Absolute Error (MAE) Mean Absolute percent Error (MAPE) และ Mean Square Error (MSE) เป็นต้น แต่ในที่นี้ จะกล่าวถึง เพียงวิธีเดียว คือ วิธี Mean Absolute Percentage Error: MAPE คือค่าเฉลี่ยของค่าสัมบูรณ์เปอร์เซ็นต์ ความคลาดเคลื่อนของผลต่างระหว่างค่าที่เกิดขึ้นจริงกับค่าพยากรณ์ ซึ่งเป็นค่าใช้วัดความถูกต้องของการ พยากรณ์ที่เหมาะสมกับการเปรียบเทียบอนุกรมเวลาหลายชุด เมื่อใช้วิธีการพยากรณ์เดียวกัน หรือเปรียบเทียบ วิธีการพยากรณ์หลายวิธีเมื่อใช้อนุกรมเวลาชุดเดียวกัน ซึ่งตัวแบบที่เหมาะสมที่สุดจะให้ค่า MAPE ต่ำสุด สามารถคำนวณได้จากสมการดังนี้ (สุพรรณิ อึ้งปัญสัต วงศ์, 2555)

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right| * 100$$

เมื่อ Y_t แทนอนุกรมเวลา ณ เวลา t

เมื่อ \hat{Y}_t แทนค่าพยากรณ์ของอนุกรมเวลา ณ เวลา t

เมื่อ n แทนจำนวนข้อมูลที่ศึกษา

และมีเกณฑ์ที่ใช้สำหรับการพยากรณ์ ดังนี้

- | | |
|-----------------------------------|--------------------------------|
| ถ้าค่า MAPE น้อยกว่า 10% | จัดว่าการพยากรณ์ค่อนข้างแม่นยำ |
| ถ้าค่า MAPE อยู่ระหว่าง 10% - 20% | จัดว่าการพยากรณ์ใช้ได้ตึก |
| ถ้าค่า MAPE อยู่ระหว่าง 20% - 50% | จัดว่าการพยากรณ์ค่อนข้างแม่นยำ |
| ถ้าค่า MAPE มากกว่า 50% | จัดว่าการพยากรณ์ไม่แม่นยำ |

2.4 ทบทวนวรรณกรรมและงานวิจัยที่เกี่ยวข้อง

2.4.1 ปัจจัยที่ส่งผลการว่างงานหรืออัตราการว่างงาน

GDP ในด้านงานวิจัยที่ศึกษาผลของ GDP ต่ออัตราการว่างงาน Kim et al. (2019) ได้ศึกษาความสัมพันธ์ของกฎ Okun ในประเทศอาเซียน+6 พบว่ากฎของ Okun ใช้ไม่ได้กับประเทศต่าง ๆ ในกลุ่มอาเซียน+6 ยกเว้นประเทศไทย ฟิลิปปินส์ และมาเลเซีย เนื่องจากการลงทุนโดยตรงจากต่างประเทศ (FDI) เป็นตัวหลักสำคัญในการเจริญเติบโตทางเศรษฐกิจ รวมไปถึงการขาดแคลนแรงงานที่มีฝีมือ และการมีแรงงานที่ไม่มีฝีมือมากเกินไป ในทางกลับกัน กฎของ Okun ใช้ได้ในไทย มาเลเซียและฟิลิปปินส์เนื่องจากประเทศเหล่านี้มีอัตราการว่างงานต่ำกว่าคุณลักษณะเฉพาะของตลาดแรงงาน นอกจากนี้เมื่อทำการกำจัดแนวโน้มของ GDP ออกไป พบว่า ความสัมพันธ์เชิงลบของอัตราการว่างงานและผลผลิตมากขึ้นในช่วงเศรษฐกิจถดถอย เนื่องจากการเจริญเติบโตทางเศรษฐกิจของประเทศอาเซียน+6 ขึ้นอยู่กับการลงทุนโดยตรงจากต่างประเทศเป็นอย่างมาก

เงินเพื่อ งานวิจัยจำนวนมากได้ทำการทดสอบทฤษฎีของเส้นโค้งฟิลลิปส์ เช่น กฤษฏา สัตยวินิจ (2555) ได้ทำการศึกษาภาพรวมของการเคลื่อนไหวของอัตราเงินเฟ้อกับอัตราการว่างงานของประเทศไทยรวมถึงวิเคราะห์ดุลยภาพในระยะยาวและการปรับตัวในระยะสั้นของอัตราเงินเฟ้อกับอัตราการว่างงานของประเทศไทย และทดสอบความสัมพันธ์ระหว่างอัตราเงินเฟ้อกับอัตราการว่างงานของประเทศไทยโดยผลการศึกษาพบว่าอัตราเงินเฟ้อและอัตราการว่างงานของไทยมีการเคลื่อนไหวในทิศทางตรงข้ามกัน ในกรณีที่อัตราการว่างงานเกิดเบี่ยงเบนออกไปจากดุลยภาพจะใช้เวลาปรับตัวกลับเข้าสู่ดุลยภาพเพียง 2.4 วัน และอัตราเงินเฟ้อเป็นสาเหตุของการว่างงานแต่การว่างงานนั้นไม่เป็นสาเหตุของอัตราเงินเฟ้อ ซึ่งสัมพันธ์กับการศึกษาของงานวิจัยของอนันต์ พานทอง (2550) ที่พบว่าการเปลี่ยนแปลงอัตราการว่างงานมีผลค่อนข้างน้อยต่ออัตราเงินเฟ้อ จากผลการศึกษาที่กล่าวมานั้นสนับสนุนทฤษฎีของเส้นโค้งฟิลลิปส์บางส่วนเท่านั้น

นอกจากนี้ Kanyarat (2002) พบว่าความสัมพันธ์ของเส้นโค้งฟิลลิปส์หรือการชดเชยระหว่างเงินเฟ้อและอัตราการว่างงานในประเทศไทยเกิดขึ้นหลังจากวิกฤตการณ์ต้มยำกุ้ง (Asian Crisis) ในขณะที่ นนทลี ศรีสว่าง พบว่าความผันผวนของอัตราเงินเฟ้อส่งผลลบต่อความผันผวนของอัตราการว่างงานและความผันผวนของอัตราการว่างงานส่งผลทางลบต่อความผันผวนของอัตราเงินเฟ้อเช่นเดียวกัน

จำนวนประชากร/กำลังแรงงาน ในด้านผลกระทบเชิงประจักษ์ของจำนวนประชากร Maqbool et al. (2013) ศึกษาสาเหตุของอัตราการว่างงานในปากีสถานในช่วงปี 1976 - 2012 พบว่าจำนวนประชากรและอัตราการว่างงานมีความสัมพันธ์เชิงบวกในปากีสถาน กล่าวคือหากจำนวนประชากรเพิ่มขึ้น อัตราการว่างงานก็จะเพิ่มขึ้นด้วย ขณะเดียวกัน Mahmood, Akhtar, Amin, and Idrees (2011) ศึกษาปัจจัยที่ส่งผลต่ออัตราการว่างงานในเปชวาร์ ปากีสถานพบว่าการเติบโตของประชากรและอัตราการว่างงานมีความสัมพันธ์เชิงบวกในกลุ่มของผู้ที่มีการศึกษา สอดคล้องกับ Asif (2013) ที่พบผลกระทบอย่างมีนัยสำคัญของจำนวนประชากรต่ออัตราการว่างงานในประเทศจีน อินเดีย และปากีสถาน ในช่วงปี 1980-2009 นอกจากนี้ Bakare (2011) ศึกษาสาเหตุของการ

ว่างงานของคนในเมือง ประเทศไนจีเรีย พบความสัมพันธ์เชิงบวกของอัตราการว่างงานและจำนวนประชากรเช่นเดียวกันตัวอย่างงานวิจัยข้างต้นล้วนแล้วแต่สนับสนุนทฤษฎีของมัลธัส

อย่างไรก็ตาม จำนวนประชากรและกำลังแรงงานที่เพิ่มขึ้นอาจส่งผลให้อัตราการว่างงานลดลง เนื่องจากอัตราการว่างงาน คำนวณจากจำนวนผู้ว่างงานหารด้วยกำลังแรงงาน จะเห็นได้ว่าหากกำลังแรงงานเพิ่มขึ้นในอัตราที่มากกว่าผู้ว่างงาน ในภาพรวมจะส่งผลให้อัตราการว่างงานลดลง ทั้งนี้ งานวิจัยบางส่วนพบความสัมพันธ์ข้างต้น เช่น Aqil et al. (2014) พบความสัมพันธ์เชิงลบระหว่างจำนวนประชากรและอัตราการว่างงานในปากีสถาน กล่าวคือ หากมีการเติบโตของประชากรเพิ่มขึ้น อัตราการว่างงานจะลดลง อย่างไรก็ตาม การจ้างงานเหล่านั้นอาจเป็นการจ้างงานของเด็ก การจ้างงานที่ไม่มีคุณภาพ มีชั่วโมงการทำงานต่ำ หรือการว่างงานแฝง ปรากฏการณ์เช่นนี้อาจเป็นผลจากการเพิ่มขึ้นของประชากร นำไปสู่กำลังงานและการจ้างงานที่เพิ่มขึ้น แต่เป็นการจ้างงานที่ไม่ได้มีคุณภาพ นอกจากนี้ยังมี Loku and Deda (2013) ที่พบความสัมพันธ์เชิงลบระหว่างจำนวนประชากรและอัตราการว่างงานในสาธารณรัฐคองโก โดยผู้เขียนได้ให้เหตุผลของอัตราการว่างงานที่มีผลต่อการเติบโตประชากรโดยกล่าวว่าอัตราการว่างงานทำให้อัตราการเกิดของประชากรลดลงเนื่องจากผู้ว่างงานจะขาดสวัสดิการในการเลี้ยงลูก นอกจากนี้ผู้ว่างงานส่วนใหญ่จะมีความเครียด โดยบุคคลเหล่านั้นมักจะใช้ความรุนแรงกับลูก ทำให้ลูกเกิดความเครียด หดหู่ ส่งผลต่อการเรียน การเข้าสังคม หรือแม้แต่มีความเสี่ยงในการฆ่าตัวตาย แต่ผู้เขียนไม่ได้กล่าวถึงเหตุผลของการเติบโตของประชากรต่ออัตราการว่างงาน

อัตราการเจริญพันธุ์ อัตราการเจริญพันธุ์ (Fertility Rate) สะท้อนจำนวนบุตรเฉลี่ยที่ผู้หญิงแต่ละคนให้กำเนิด โดยปกติแล้วการศึกษารายผลของการเพิ่มขึ้นของอัตราการเจริญพันธุ์ จะให้ผลเช่นเดียวกับการเพิ่มขึ้นของจำนวนประชากร กล่าวคือ อัตราการเจริญพันธุ์เพิ่มขึ้น ทำให้กำลังแรงงานเพิ่มขึ้น ในขณะที่ตำแหน่งงานเพิ่มขึ้นไม่ทัน จึงอาจส่งผลให้อัตราการว่างงานเพิ่มขึ้น อย่างไรก็ตาม ในบางประเทศอาจให้ผลกลับกันคืออัตราการเจริญพันธุ์เพิ่มขึ้น แต่อัตราการว่างงานลดลง เช่น มาเลเซีย ในช่วงปี 1991-2018

นอกจากนี้ หากตัวเลขอัตราการเจริญพันธุ์น้อยกว่า 2 แสดงว่าแนวโน้มประชากรของประเทศนั้นจะไม่เพิ่มขึ้น ซึ่งอาจจะทำให้ผลิตจำนวนแรงงานใหม่ได้ไม่เพียงพอที่จะเข้ามาทดแทนแรงงานที่กำลังเกษียณหรือออกจากตลาดแรงงานไป จึงส่งผลสืบเนื่องให้ตลาดแรงงานหาแรงงานได้ยากขึ้น จึงมีอัตราการว่างงานลดลง ทั้งนี้ ปรากฏการณ์ข้างต้นสอดคล้องกับกรณีของประเทศไทยที่เข้าสู่สังคมผู้สูงอายุ ในขณะที่อัตราการเจริญพันธุ์มีแนวโน้มลดลง แม้สถานการณ์เช่นนี้เกิดขึ้นในหลาย ๆ ประเทศ เช่น ญี่ปุ่น และสหรัฐอเมริกา กล่าวคือทั้งสองประเทศมีอัตราการเจริญพันธุ์ลดลง และเข้าสู่สังคมสูงอายุ อย่างไรก็ตาม ทั้งสองประเทศจัดเป็นประเทศพัฒนาแล้ว ในขณะที่ประเทศไทยที่พบเหตุการณ์เช่นเดียวกัน จึงค่อนข้างน่าเป็นกังวล

จากข้อมูลประมาณการอัตราการเจริญพันธุ์ของสถาบันวิจัยประชากรและสังคม มหาวิทยาลัยมหิดล พบว่าในปี 2565 อยู่ที่ร้อยละ 1.21 ลดลงจากร้อยละ 1.58 ในปี 2561 สะท้อนแนวโน้มการเกิดที่ลดลงในประเทศไทย ซึ่งส่งผลต่อทิศทางของจำนวนประชากรและกำลังแรงงานในอนาคตด้วย

ผลผลิตภาคอุตสาหกรรม การขยายตัวของภาคการผลิต (Industrialization) หรือผลผลิตอุตสาหกรรมเพิ่มขึ้น ทำให้การจ้างงานโดยรวมขยายตัว และการว่างงานลดลง เช่น ในตุรกี มาเลเซีย และกลุ่มประเทศ BRICS (บราซิล รัสเซีย อินเดีย จีน และแอฟริกาใต้) ในขณะที่ในฟิจิ อัตราการว่างเพิ่มขึ้น เมื่อมีการขยายตัวของภาคอุตสาหกรรม

ในกรณีของสหรัฐอเมริกา Gunduz (2020) พบความสัมพันธ์ระยะยาวระหว่างอัตราการว่างงานของกับตัวแปรดัชนีการผลิตภาคอุตสาหกรรม โดยการว่างงานจะลดลงเมื่อมีผลผลิตเพิ่มขึ้น โดยเฉพาะในช่วงที่มีการดำเนินนโยบายเศรษฐกิจแบบขยายตัว ตั้งแต่ปี 2008 และ 2018 ทั้งนี้ ผลข้างต้นอาจเกี่ยวข้องกับมาตรการผ่อนคลายเชิงปริมาณ (Quantitative Easing: QE) ของธนาคารกลางสหรัฐ (FED) ซึ่งนโยบายการเงินแบบขยายตัวนี้ทำให้อัตราการเติบโตในสหรัฐอเมริกาดี เสถียรภาพและอัตราการว่างงานลดลงอย่างเห็นได้ชัด อีกทั้งยังมีการศึกษาที่พบว่าอัตราการว่างงานในประเทศอุตสาหกรรมส่วนใหญ่มีแนวโน้มที่จะแปรผันน้อยกว่าต่อการเปลี่ยนแปลงของ GDP สะท้อนว่าตลาดแรงงานของประเทศอุตสาหกรรมเหล่านี้มีกฎเกณฑ์ที่เข้มงวดมากกว่า ไม่ว่าจะเป็นการคุ้มครองการจ้างงาน เช่น ญี่ปุ่น สภาพแรงงานที่เข้มแข็ง ทำให้นายจ้างไม่สามารถเลิกจ้างแรงงานได้ง่ายในช่วงที่เศรษฐกิจตกต่ำ

ปัจจัยอื่น ๆ ที่อาจส่งผลต่ออัตราการว่างงาน ที่พบได้ในงานวิจัยที่ผ่านมา เช่น การลงทุนโดยตรงจากต่างประเทศ (FDI) การส่งออกของประเทศ และการพัฒนาทางเทคโนโลยี

นอกจากนี้ ยังมีงานวิจัยที่ศึกษาเกี่ยวกับปัจจัยทางเศรษฐกิจและสังคมที่ส่งผลต่อการว่างงานในประเทศไทยโดยเฉพาะ ได้แก่ ชาลิสสา สาคร (2565) ที่ทำการศึกษปัจจัยที่มีผลกระทบต่อ การว่างงาน และวิเคราะห์สภาพปัญหาการว่างงาน ในประเทศไทย ใช้ข้อมูลพื้นฐานด้านเศรษฐกิจและสังคมระดับหมู่บ้าน (กชช.2ค) เป็นแบบสอบถาม กชช.2ค 3 รอบปี ของกรมพัฒนาชุมชน กระทรวงมหาดไทย โดยแบ่งปัจจัยที่คาดว่าจะส่งผลต่อการว่างงานเป็น 4 กลุ่ม คือ 1) สภาพและโครงสร้างพื้นฐานทางเศรษฐกิจ 2) สุขภาวะและอนามัย 3) ความรู้และการศึกษา 4) การมีส่วนร่วมและความเข้มแข็งของชุมชน โดยใช้วิธีการวิเคราะห์ panel data ในรูปแบบวิธี Pooled Regression ซึ่งพบว่า ปัญหาการว่างงานในประเทศไทยนั้นมีหลายสาเหตุ เช่น การเพิ่มขึ้นของจำนวนประชากรในประเทศ สภาพเศรษฐกิจที่ตกต่ำ การผลิตนักศึกษาออกมาเพิ่มขึ้นเรื่อยๆ รวมไปถึงสถานการณ์ภัยธรรมชาติต่างๆ ปัจจัยที่มีความสัมพันธ์กับการว่างงานในเชิงบวก คือ การทำเกษตร เลี้ยงสัตว์ ประมง ทะเล รายได้อุตสาหกรรมครัวเรือน รายได้อุตสาหกรรมท้องถิ่น ความปลอดภัยในการทำงาน ขาดโอกาสในการศึกษา อบรมด้านสุขภาพ ชุมชนมีกิจกรรมสาธารณะ และผู้สูงอายุไม่ได้รับการดูแล ปัจจัยที่มีความสัมพันธ์กับการว่างงานในเชิงลบ คือ ชุมชนมีแหล่งท่องเที่ยวที่เกิดรายได้ ประมงน้ำจืด มีเครื่องจักรใช้งาน รายได้พืช รายได้ประมง คนพิการ อบรมด้านการศึกษา และแหล่งสินเชื่อ

โดยสรุปมีปัจจัยทางเศรษฐกิจและสังคมจำนวนมาก ที่ส่งผลต่อการว่างงานและอัตราการว่างงาน โดยจะแตกต่างกันไปตามบริบทของแต่ละประเทศ ซึ่งปัจจัยที่สำคัญสรุปได้ดังตารางต่อไปนี้

ตารางสรุปความสัมพันธ์ระหว่างตัวแปรอิสระต่าง ๆ และอัตราการว่างงาน จากการทบทวนทฤษฎีและงานวิจัยที่เกี่ยวข้อง

ตัวแปรอิสระ	ความสัมพันธ์	เหตุผล/ทฤษฎี	งานวิจัย	แหล่งข้อมูลของตัวแปร
GDP / GDP growth	ลบ	การขยายตัวของเศรษฐกิจ ส่งผลให้เกิดความต้องการแรงงานเพิ่มขึ้น จึงทำให้อัตราการว่างงานลดลง ซึ่ง Okun's Law ได้อธิบายความสัมพันธ์เชิงลบระหว่างอัตราการเติบโตของ GDP และอัตราการว่างงานไว้	Kim et al. (2019)	สำนักงานสภาพัฒนาการเศรษฐกิจและสังคมแห่งชาติ
เงินเฟ้อ	ลบ	เมื่อเศรษฐกิจเติบโตขึ้น ส่งผลให้เงินเฟ้อปรับเพิ่มขึ้น ในขณะที่เดียวกันการว่างงานจะลดลง จึงมีการชดเชยกันระหว่างเงินเฟ้อและอัตราการว่างงาน (Phillips curve) นอกจากนี้ Milton Friedman และ Edmund Phelps เสนอว่าการชดเชยระหว่างเงินเฟ้อและอัตราการว่างงานเกิดขึ้นเพียงแค่ชั่วคราวหรือในระยะสั้นเท่านั้น เมื่อเศรษฐกิจเคลื่อนที่เข้ามาสู่ดุลยภาพระยะกลางแล้วการชดเชยดังกล่าวจะหายไป หรือเมื่ออัตราการว่างงานเท่ากับอัตราธรรมชาติของการว่างงาน (Natural rate of unemployment)	กฤษฎา สัตยวินิจ (2555) อนันต์ พานทอง (2550) Kanyarat (2002)	สำนักงานนโยบายและยุทธศาสตร์การค้า
จำนวนประชากร / กำลังแรงงาน	บวก/ลบ	การเติบโตของประชากรที่มากเกินไปโดยไม่มีการควบคุมอย่างเหมาะสม อาจทำให้เกิดปัญหาการว่างงาน จากการดูดซับของการจ้างงานที่มีจำกัด ในขณะที่การเพิ่มขึ้นของประชากรหรือกำลังแรงงานอาจทำให้อัตราการว่างงานลดลง เมื่อผู้ว่างงานเพิ่มขึ้นน้อยกว่ากำลังแรงงาน	Maqbool et al. (2013) Asif (2013) Chen (2017) Aqil et al. (2014) Loku and Deda (2013)	กรมการปกครอง สำนักงานสถิติแห่งชาติ IMF
อัตราการเจริญพันธุ์	บวก/ลบ	อัตราการเจริญพันธุ์เพิ่มขึ้น ทำให้กำลังแรงงานเพิ่มขึ้น ในขณะที่ตำแหน่งงานเพิ่มขึ้นไม่ทัน จึงอาจส่งผลให้อัตราการว่างงานเพิ่มขึ้น อย่างไรก็ตาม ในบางประเทศอาจให้ผลกลับกันคืออัตราการเจริญพันธุ์เพิ่มขึ้น แต่อัตราการว่างงานลดลง เช่น มาเลเซีย ในช่วงปี 1991-2018	Yunusova et al. (2021) Sacon et al (2022)	สถาบันวิจัยประชากรและสังคม มหาวิทยาลัยมหิดล
ดัชนีผลผลิตอุตสาหกรรม	ลบ	การขยายตัวของภาคการผลิต ทำให้การจ้างงานโดยรวมขยายตัว และการว่างงานลดลง	Yunusova et al. (2021) Gunduz (2020) Neely (2010)	สำนักงานเศรษฐกิจอุตสาหกรรม
การส่งออก	ลบ	การขยายตัวของการส่งออก ทำให้การจ้างงานโดยรวมขยายตัว และการว่างงานลดลง นอกจากนี้ นโยบายการส่งเสริมการส่งออกอาจช่วยลดการว่างงานได้	Gaston (2013) Ugarte and Olarreaga (2020)	ธนาคารแห่งประเทศไทย

2.4.2 การพยากรณ์การว่างงานในประเทศไทย

การพยากรณ์การว่างงานในประเทศไทยที่ผ่านมา ใช้เทคนิคการพยากรณ์ที่หลากหลาย ตัวอย่างเช่น วรางคณา เรียนสุทธิ (2559) ได้ทำการศึกษาการพยากรณ์จำนวนผู้ว่างงานในประเทศไทย โดยใช้เทคนิคอนุกรมเวลา เพื่อศึกษาและสร้างตัวแบบพยากรณ์ที่เหมาะสมที่สุดของจำนวนผู้ว่างงานในประเทศไทย โดยใช้ข้อมูลจำนวนผู้ว่างงานรายเดือน ตั้งแต่ มกราคม 2555 ถึง สิงหาคม 2558 จำนวน 44 ชุด จากกองวิจัยตลาดแรงงาน กรมการจัดหางาน โดยใช้เทคนิคพยากรณ์อนุกรมเวลาด้วยกันทั้งหมด 3 วิธี ได้แก่ 1) วิธีอนุกรมเวลาบอกซ์- เจนกินส์ 2) วิธีการพยากรณ์รวม 3) วิธีการปรับเรียบด้วยเส้นโค้งเลขชี้กำลังสองของวินเทอร์แบบบวก โดยใช้โปรแกรม SPSS เป็นเครื่องมือช่วยในการดำเนินการศึกษา สำหรับการเปรียบเทียบเลือกเทคนิคการพยากรณ์ที่เหมาะสมจากเทคนิคพยากรณ์ทั้งหมด ใช้ค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (MAPE) และรากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ยต่ำที่สุด (RMSE) เป็นตัววัด โดยจะเลือกเทคนิคพยากรณ์ที่ให้ค่าความคลาดเคลื่อน MAPE และ RMSE ต่ำที่สุด นำมาสร้างตัวแบบพยากรณ์ที่เหมาะสมสำหรับใช้พยากรณ์ต่อไป ผลการศึกษาพบว่าวิธีการพยากรณ์รวมเป็นวิธีที่มีความเหมาะสมกับอนุกรมเวลาชุดนี้มากที่สุด เนื่องจากได้ค่า MAPE และ RMSE ต่ำที่สุด จึงมีความเหมาะสมสำหรับการพยากรณ์ต่อไป

วีรภัทร อุสาหกิจ, สุชิตา คักกันหา, สุภกิจ จิตต์ธรรม (2564) ก็ได้ศึกษาการพยากรณ์จำนวนผู้ว่างงานของประเทศไทยเช่นเดียวกัน โดยใช้ข้อมูลจากธนาคารแห่งประเทศไทย 60 ค่า แบ่งข้อมูลออกเป็น 2 ชุด ชุดที่ 1 คือ ข้อมูลปี พ.ศ. 2558-2562 ชุดที่ 2 คือ ข้อมูลปี พ.ศ. 2563 จำนวน 12 ค่า เป็นข้อมูลในการตรวจสอบความถูกต้องของการพยากรณ์ เพื่อสร้างตัวแบบพยากรณ์ที่เหมาะสมที่สุดของจำนวนผู้ว่างงานในประเทศไทย โดยใช้วิธีการวิเคราะห์อนุกรมเวลาด้วยวิธีการพยากรณ์เดี่ยว 3 วิธี คือ 1) วิธีการถดถอยแบบอนุกรมเวลา 2) วิธีการปรับให้เรียบแบบเลขชี้กำลัง 3) วิธีบอกซ์- เจนกินส์ และวิธีการพยากรณ์รวมโดยหาตัวถ่วงน้ำหนัก 2 วิธี คือ 1) วิธีการให้น้ำหนักเท่ากัน 2) วิธีความคลาดเคลื่อนกำลังสองเฉลี่ยผกผัน โดยใช้โปรแกรม SPSS เป็นเครื่องมือช่วยในการดำเนินการศึกษา และเปรียบเทียบจากค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (MAPE) และความคลาดเคลื่อนกำลังสองเฉลี่ยต่ำที่สุด (MSE) ที่น้อยที่สุดในการเลือกตัวแบบพยากรณ์ที่เหมาะสม ซึ่งพบว่าวิธีการพยากรณ์รวมเป็นวิธีที่มีความเหมาะสมกับอนุกรมเวลาชุดนี้มากที่สุด ซึ่งค่าพยากรณ์จากวิธีการพยากรณ์รวมมีความถูกต้อง น่าเชื่อถือ เมื่อกำหนดค่าน้ำหนักที่เหมาะสม

ดร.กวิณ เอี่ยมตระกูล ได้ศึกษาการใช้ Google ประเมินค่าสถิติตลาดแรงงาน งานศึกษาฉบับนี้ ได้นำประโยชน์จากฐานข้อมูลขนาดใหญ่ (Big Data) ของ Google ในแอปพลิเคชัน Google Trends ซึ่งมีศักยภาพเพียงพอในการเป็นเครื่องชี้วัดเศรษฐกิจโดยแสดงพฤติกรรมความสนใจของประชาชนทุกระดับและแสดงผลแบบ Real Time มาใช้ในการติดตามและประเมินผลเศรษฐกิจด้านการว่างงานของไทย โดยในงานศึกษาฉบับนี้ ประเมินการอัตราการว่างงานระหว่างเดือนเมษายน - กรกฎาคม 2563 โดยเปรียบเทียบผลการทดสอบระหว่าง 1) แบบจำลอง ARIMA (Auto Regressive and Moving Average) โดยใช้ข้อมูลอัตราการว่างงานในอดีต และ 2) แบบจำลองกำลังสองน้อยที่สุดที่ใช้ข้อมูลปริมาณการค้นหาจาก Google Trends ของคำว่า “สมัครงาน” และ “หางาน” ทั้งนี้ ผลการศึกษาพบว่า แบบจำลองกำลังสองน้อยที่สุด โดยใช้ข้อมูลปริมาณการค้นหาจาก Google Trends ประเมินการอัตราการว่างงาน ในเดือนเมษายน - กรกฎาคม 2563 ในช่วงร้อยละ 0.8 ถึง 1.3 และ

ให้ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองต่ำที่สุด โดยต่ำกว่าแบบจำลอง ARIMA ที่ประมาณการอัตราการว่างงานที่ร้อยละ 1.0 ถึง 1.1 เนื่องจากคนส่วนใหญ่ให้ความสนใจในการค้นหาว่า “เราไม่ทิ้งกัน” มากที่สุดในช่วงเวลาดังกล่าว แต่ภายหลังจากมาตรการเยียวยาล่าสุดลง กอรปกับสถานการณ์ทางเศรษฐกิจที่ชะลอตัวลง ภาคธุรกิจได้รับผลกระทบมากขึ้น ประชาชนจึงให้ความสนใจในการค้นหาว่า “สมัครงาน” และ “หางาน” มากยิ่งขึ้น ตั้งแต่เดือนมิถุนายนเป็นต้นมา ทั้งนี้ แม้ว่าแบบจำลองกำลังสองน้อยที่สุดประมาณการอัตราการว่างงานไตรมาสที่สอง 2563 ที่ร้อยละ 1.0[2] ต่ำกว่าอัตราการว่างงานไตรมาสที่สองที่สำนักงานสถิติแห่งชาติเผยแพร่ ที่ร้อยละ 2.0 หรือมีผู้ว่างงานจำนวน 7.45 แสนคน จากจำนวนแรงงาน 38.17 ล้านคน และมีผู้มีงานทำ ซึ่งขณะนี้ไม่ได้ทำงานและไม่ได้รับเงินเดือน แต่มีงานที่จะกลับไปทำจำนวน 2.08 ล้านคน หากแต่การมีข้อมูลเบื้องต้นที่มีความถี่เป็นรายเดือน ก็มีส่วนช่วยให้ติดตามภาวะเศรษฐกิจได้อย่างทันท่วงที อย่างไรก็ตาม การนำข้อมูลปริมาณการค้นหาจาก Google Trends มาใช้ จำเป็นต้องมีความระมัดระวังในการคัดเลือกคำค้นหา การเลือกคำที่แตกต่างกัน หรือคำเดียวกัน แต่คนละช่วงเวลา ผลลัพธ์ก็จะมีผลแตกต่างกัน

2.4.3 การพยากรณ์การว่างงานในต่างประเทศ

จากการทบทวนวรรณกรรมที่เกี่ยวข้องกับการพยากรณ์อัตราการว่างงานในบริบทของต่างประเทศ พบว่าเทคนิคการพยากรณ์และผลการศึกษาที่น่าสนใจ กล่าวคือ Dritsakis Nikolaos และคณะ (2561) ศึกษาการพยากรณ์อัตราการว่างงานของประเทศกรีซ โดยใช้ข้อมูลอัตราการว่างงานรายปีจากธนาคารแห่งชาติกรีซ ตั้งแต่ปี พ.ศ. 2503 ถึงปี พ.ศ. 2556 เพื่อพยากรณ์อัตราการว่างงานล่วงหน้า 3 ปี คือ ปี พ.ศ. 2557 ถึงปี พ.ศ. 2559 และพยากรณ์ข้อมูลอนุกรมเวลาดังกล่าวด้วยวิธีบอกซ์-เจนกินส์ (Box-Jenkins method) ผลการศึกษาพบว่าตัวแบบที่เหมาะสมที่สุดสำหรับการพยากรณ์อัตราการว่างงานของประเทศกรีซในช่วงเวลาที่ดำเนินการศึกษา คือตัวแบบ ARIMA (1,2,1)

Xitao Liu และ Lihui Li (2565) ศึกษาการพยากรณ์อัตราการว่างงานโดยใช้แบบจำลองอนุกรมเวลาและแบบจำลองโครงข่ายประสาทเทียม (Neural Network) โดยใช้ข้อมูลอัตราการว่างงานจากการจดทะเบียนในเขตเมือง และข้อมูลขนาดใหญ่ (Big Data) ในการสร้างแบบจำลองโครงข่ายประสาทเทียม เช่น ข้อมูลการจัดหางานบนอินเทอร์เน็ต ข้อมูลบนโซเชียลมีเดีย และข้อมูลการค้นหา เป็นต้น ซึ่งเป็นการศึกษาการพยากรณ์ด้วยการผนวกวิธีสถิติแบบดั้งเดิม (Traditional Statistical) เข้ากับวิธีการเรียนรู้ของเครื่อง (Machine Learning) เพื่อสร้างแบบจำลองพยากรณ์อัตราการว่างงานของประเทศจีน โดยในขั้นแรกเป็นการพยากรณ์จำนวนผู้ว่างงานและอัตราการว่างงานในประเทศจีนโดยใช้โครงข่ายประสาทเทียมแบบ Two-Weight และแบบจำลองอนุกรมเวลาด้วยตัวแบบ ARIMA หลังจากนั้นจึงนำผลจากการพยากรณ์ที่ได้จากสองวิธีมาถ่วงน้ำหนัก เพื่อพยากรณ์จำนวนผู้ว่างงานและอัตราการว่างงานในประเทศจีนต่อไป

Christos Katris (2562) ศึกษาการพยากรณ์อัตราการว่างงานด้วยวิธีอนุกรมเวลาและวิธีการเรียนรู้ของเครื่อง (Machine Learning) ใน 22 ประเทศ โดยใช้ข้อมูลการว่างรายเดือนจาก Eurostat Database เพื่อศึกษาและเปรียบเทียบตัวแบบในการพยากรณ์ทั้งหมด 7 ตัวแบบ ได้แก่ ARIMA, FARIMA, ARIMA/GARCH, Holt-Winters, Artificial Neural Networks (ANN), Support Vector Regression (SVR) และ ตัวแปรพหุการถดถอยแบบปรับ Splines (Multivariate Adaptive

Regression Splines: MARS) ผลการศึกษาพบว่า ตัวแบบ FARIMA เหมาะสมสำหรับการพยากรณ์ข้อมูลล่วงหน้า 1 เดือน ตัวแบบ Holt-Winters เหมาะสมสำหรับการพยากรณ์ล่วงหน้า 3 เดือน และ Artificial Neural Networks (ANN) เหมาะสมสำหรับการพยากรณ์ล่วงหน้า 12 เดือน

Michał Gostkowski และ Tomasz Rokicki (2564) ศึกษาการเลือกตัวแบบพยากรณ์อัตราการว่างงาน โดยใช้ข้อมูลอัตราการว่างงานรายเดือนจากสำนักงานสถิติกลางของโปแลนด์ ตั้งแต่เดือนมกราคม พ.ศ. 2558 ถึงเดือนธันวาคม พ.ศ. 2561 เพื่อศึกษาและเปรียบเทียบตัวแบบที่เหมาะสมสำหรับใช้พยากรณ์อัตราการว่างงาน ทั้งหมด 5 ตัวแบบ ได้แก่ วิธีหาค่าแบบตรงตัว (Naive method), ตัวแบบการถดถอย (Regression model), ARIMA, ตัวแบบ Holt และตัวแบบ Winters ผลการศึกษาพบว่าตัวแบบที่เหมาะสมสำหรับใช้พยากรณ์อัตราการว่างงานข้อมูลชุดดังกล่าว คือตัวแบบ Winters และ ตัวแบบการถดถอยแบบกำลังสอง (Quadratic trend model)

Oscar Claveria (2562) ได้ทำการศึกษาการพยากรณ์อัตราการว่างงานโดยใช้ระดับความคาดหวังในการหางานทำของผู้บริโภคเป็นส่วนหนึ่งในการศึกษา และสร้างแบบจำลองอัตราการว่างงาน ใน 8 ประเทศกลุ่มยุโรป โดยใช้ข้อมูลจากการสำรวจผ่านข้อคำถามที่ทำการรวบรวมใหม่ 5 หมวดหมู่คำตอบที่เกี่ยวข้องกับความคาดหวังในการหางานทำ โดยเลือกใช้วิธี ARIMA ในการหาแบบจำลองของแต่ละประเทศ โดยออกแบบการศึกษา 2 วิธีที่เป็นอิสระต่อกัน วิธีแรก สร้างแบบจำลอง ARIMA แบบปกติ วิธีที่ 2 นำตัวแปรความคาดหวังในการทำงานเพิ่มใน model ARIMA โดยใช้ dynamic regression model หรือ ARIMAX เพื่อทดสอบดูว่าตัวแบบที่สองวิธีมีการปรับปรุงความแม่นยำเพิ่มขึ้น ทดสอบโดยใช้ค่า MAPE และค่า DM เพื่อเปรียบเทียบผลการพยากรณ์ จากการศึกษาพบว่า ความคาดหวังในการหางานทำของผู้บริโภคช่วยในการอ้างอิงอัตราการคาดการณ์อัตราการว่างงานในชุดข้อมูลของ 8 ประเทศในยุโรป ซึ่งตัวแปรสามารถนำไปปรับปรุงการพยากรณ์ของตัวแบบในชุดข้อมูลนี้ได้ดียิ่งขึ้น

Alessia Naccarato และคณะ (2561) ได้ศึกษาการพยากรณ์อัตราการว่างงานของเยาวชนในประเทศอิตาลี โดยใช้ google trends จากข้อมูลอัตราการว่างงานรายเดือนจากสำนักงานสถิติประเทศอิตาลี ตั้งแต่ปี 2547 ในการสร้างตัวแบบ โดยมีจุดประสงค์เพื่อศึกษาแนะนำการใช้ข้อมูลการค้นหาออนไลน์เพื่อนำมาปรับปรุงการคาดการณ์ทางเศรษฐกิจ โดยทำการศึกษา 2 รูปแบบ คือ ใช้วิธีอนุกรมเวลา ARIMA เพื่อหาค่าคาดการณ์อัตราการว่างงาน และวิธี VAR model ที่ผสมระหว่างหาค่าคาดการณ์อัตราการว่างงาน และข้อมูลค้นหาใน google trends ร่วมด้วย ซึ่งผลการศึกษาพบว่าการว่างงานของเยาวชนในประเทศอิตาลีและการใช้อินเทอร์เน็ตหางานมีความสัมพันธ์กัน ผลการใช้ข้อมูล Google Trends ในการสร้างตัวแบบส่งผลให้มีข้อผิดพลาดในการคาดการณ์ลดลงโดยเฉลี่ยจากชุดข้อมูลตัวอย่าง

2.4.4 งานวิจัยที่ใช้เทคนิคการพยากรณ์ที่น่าสนใจ

นอกจากงานวิจัยที่พยากรณ์จำนวนผู้ว่างงานหรืออัตราการว่างงานแล้ว ยังมีงานวิจัยที่มุ่งเน้นไปยังตัวแปรอื่นๆ แต่ใช้เทคนิคการพยากรณ์ที่น่าสนใจที่ ตัวอย่างเช่น กานต์สินี เจริญกิจวัชรชัย (2561) ได้ทำการศึกษาปัญญาประดิษฐ์กับการพยากรณ์ค่าจ้างแรงงานไทย เพื่อสร้างสมการแบบจำลองพยากรณ์ค่าจ้างแรงงานและศึกษาปัจจัยที่มีอิทธิพลต่อการกำหนดค่าจ้างแรงงาน โดยใช้ข้อมูลสำรวจภาวะเศรษฐกิจและสังคมของครัวเรือน (SES) และข้อมูลสำรวจภาวะการทำงานของ

ประชากร (LFS) จำนวน 10 ปี ตั้งแต่ 2550-2560 โดยใช้เทคนิคการพยากรณ์ 3 วิธี ได้แก่ 1) วิธีทางเศรษฐมิติ (LM) การวิเคราะห์การถดถอยเชิงเส้นพหุคูณ 2) เทคนิควิธีการทางปัญญาประดิษฐ์ อัลกอริทึมโครงข่ายประสาทเทียม (Artificial Neural Networks :ANN) 3) เทคนิควิธีการทางปัญญาประดิษฐ์อัลกอริทึม (Random Forest) ซึ่งเป็นเทคนิควิธีการพยากรณ์ในรูปแบบของปัญญาประดิษฐ์ โดยใช้โปรแกรม R studio เป็นเครื่องมือช่วยในการดำเนินการศึกษาซึ่งเปรียบเทียบค่าพยากรณ์จากค่า MAPE และ MSE โดยผลการศึกษาพบว่าปัจจัยที่มีอิทธิพลต่อการกำหนดค่าจ้างแรงงานในช่วง 10 ปีที่ผ่านมา ประกอบไปด้วย 3 ปัจจัยหลัก คือปัจจัยด้านคุณลักษณะทั่วไปของแรงงาน ปัจจัยที่เกี่ยวข้องกับอาชีพและกิจการ และปัจจัยทางด้านภูมิศาสตร์ โดยผลจากการพยากรณ์ด้วยแบบจำลองต่างๆ พบว่า แบบจำลองทางปัญญาประดิษฐ์ ในส่วนของอัลกอริทึม Random Forest มีความแม่นยำในการพยากรณ์มากกว่าแบบจำลองทางสถิติ และสามารถบอกถึง ปัจจัยที่มีความสำคัญต่อการกำหนดค่าจ้างแรงงานได้เช่นเดียวกับแบบจำลองทางสถิติ ในขณะที่แบบจำลองทางปัญญาประดิษฐ์อัลกอริทึมโครงข่ายประสาทเทียมนั้น ถึงแม้ว่ามีความแม่นยำสูงกว่าแบบจำลองทางสถิติ แต่ยังมีข้อจำกัดด้านความสามารถในการอธิบายผลของแบบจำลอง และพบว่ามีข้อจำกัดในการประมวลผลข้อมูลที่ประกอบด้วยปัจจัยที่อยู่ในรูปแบบข้อมูลเชิงตัวแปรหุ่น

นอกจากนี้ยังมีการศึกษาการเปรียบเทียบเทคนิคทางด้านพยากรณ์ อภิญา หิรัญวงษ์ (2552) ได้ศึกษาการพยากรณ์ราคาพืชน้ำมันโดยวิธีบ็อกซ์ - เจนกินส์และโครงข่ายประสาทเทียม เพื่อหาตัวแบบที่เหมาะสมในการพยากรณ์ โดยใช้ข้อมูลอดีตของข้อมูลราคาถั่วเหลืองและปาล์มน้ำมันรายเดือนจากสำนักงานเศรษฐกิจการเกษตร กระทรวงเกษตรและสหกรณ์ ตั้งแต่ตุลาคม 2540 ถึงกันยายน 2551 โดยใช้เทคนิคการพยากรณ์ 2 วิธีคือ 1) วิธีอนุกรมเวลาบ็อกซ์ - เจนกินส์ 2) วิธีโครงข่ายประสาทเทียม เปรียบเทียบผลการพยากรณ์จากค่าผลบวกกำลังสองของความคาดเคลื่อน (SSE) ค่าต่ำที่สุด พบว่าสำหรับการพยากรณ์ข้อมูลชุดนี้ ได้ผลการศึกษา คือการพยากรณ์ราคาถั่วเหลืองเลือกใช้วิธีโครงข่ายประสาทเทียม และการพยากรณ์ราคาปาล์มน้ำมันเลือกใช้วิธีบ็อกซ์- เจนกินส์ เนื่องจากได้ค่า SSE ต่ำที่สุด จึงมีความเหมาะสมสำหรับการพยากรณ์ต่อไป

ผุสดี บุญรอด และกรวิวัฒน์ พลเยี่ยม (2560) ได้ศึกษาการพยากรณ์ราคามันสำปะหลัง เพื่อหาตัวแบบที่เหมาะสมโดยใช้ข้อมูลจากสมาคมแป้งมันสำปะหลังและสำนักงานเศรษฐกิจการเกษตร จำนวน 10 ปี (พ.ศ. 2549-2558) ตั้งแต่เดือนมกราคม พ.ศ. 2549 ถึงเดือนธันวาคม พ.ศ. 2558 ซึ่งเป็นข้อมูลอนุกรมเวลาแบบรายสัปดาห์ที่ถูกจัดเรียงตามเวลาของการบันทึก โดยใช้เทคนิคการพยากรณ์ 3 วิธี ได้แก่ 1) โครงข่ายประสาทเทียมแบบหลายชั้น (artificial neural network) 2) เคเนียร์เนสเนเบอร์ (k-NearestNeighbor, k-NN) 3) การวิเคราะห์การถดถอยเชิงเส้น (linear regression analysis) โดยใช้โปรแกรม RapidMiner Studio 7 เป็นเครื่องมือช่วยในการดำเนินการศึกษาซึ่งเปรียบเทียบค่าพยากรณ์จากค่า MAPE โดยผลการศึกษาพบว่าโครงข่ายประสาทเทียมแบบหลายชั้นมีค่า MAPE เท่ากับ 3.96 เคเนียร์เนสเนเบอร์มีค่า MAPE เท่ากับ 7.11 และการวิเคราะห์การถดถอยเชิงเส้นมีค่า MAPE เท่ากับ 11.10 จึงสามารถสรุปได้ว่าแบบจำลองการพยากรณ์โดยใช้โครงข่ายประสาทเทียมแบบหลายชั้นมีประสิทธิภาพดีที่สุดสำหรับการพยากรณ์ข้อมูลชุดนี้ ซึ่งสามารถนำไปประยุกต์ใช้และต่อยอดในการพยากรณ์ราคามันสำปะหลังได้ดีกว่าวิธีอื่น ๆ

และงานวิจัยที่น่าสนใจจาก ดร.ณัฐนันท์ วิจิตรอักษร (2565) ได้ศึกษาการวิเคราะห์และคาดการณ์ข้อมูลเศรษฐกิจมหภาคของไทยโดยใช้วิธีความถี่ผสม ซึ่งข้อมูลเศรษฐกิจมหภาคเป็นข้อมูลสำคัญในการตัดสินใจของทั้งภาครัฐและเอกชนในประเทศไทย ซึ่งการเผยแพร่ข้อมูลเศรษฐกิจมหภาคที่สำคัญ โดยปกติจะมีความถี่ต่ำกว่า เช่น รายไตรมาส มักจะไม่เป็นไปตามเวลาที่กำหนด การใช้ข้อมูลที่มีความถี่สูงกว่า เช่น รายเดือนและรายวันเพื่อวิเคราะห์หรือคาดการณ์ข้อมูลที่มีความถี่ต่ำกว่าจะสามารถลดผลกระทบจากระยะเวลาการรอข้อมูลได้ การศึกษานี้ใช้วิธีข้อมูลความถี่ผสมในการวิเคราะห์และคาดการณ์ข้อมูลเศรษฐกิจมหภาคที่สำคัญของไทย การถดถอยของการสุ่มตัวอย่างข้อมูลแบบผสมที่มีข้อกำหนดต่างๆ ถูกนำมาใช้และดำเนินการผ่านข้อมูลเศรษฐกิจมหภาค เช่น ผลิตภัณฑ์มวลรวมในประเทศและอัตราเงินเฟ้อ โดยชุดข้อมูลในการวิเคราะห์ประกอบด้วยตัวแปรทางเศรษฐกิจมหภาคและการเงินที่สำคัญบางอย่าง รวมถึงปริมาณห่วงโซ่รายไตรมาส ได้แก่ ผลิตภัณฑ์มวลรวมภายในประเทศ (GDP) ณ ราคาปี 2545 จากสำนักงานคณะกรรมการพัฒนาการเศรษฐกิจและสังคมแห่งชาติ (สศช.) ประเทศไทย, จำนวนแรงงานรายไตรมาสในกำลังแรงงาน (LF) จากสำนักงานสถิติแห่งชาติ (สศช.), อัตราเงินเฟ้อรายเดือน อัตราและดัชนีราคาหุ้นรายวันจาก CEIC อัตราดอกเบี้ยและอัตราแลกเปลี่ยนรายวันจากธนาคารแห่งประเทศไทย (ธปท.) ตัวแปรทั้งหมดนี้ จะถูกแปลงเป็นเปอร์เซ็นต์การเปลี่ยนแปลงโดยมีการเปลี่ยนแปลงในไตรมาสต่อไตรมาสสำหรับ GDP และ LF ซึ่งเป็นการเปลี่ยนแปลงแบบปีต่อปีสำหรับ อัตราเงินเฟ้อ และการเปลี่ยนแปลงของดัชนีหุ้น อัตราดอกเบี้ยและอัตราแลกเปลี่ยนในวันก่อนหน้า โดยจุดประสงค์หลักคือการวิเคราะห์และคาดการณ์ตัวแปรความถี่ต่ำ (GDP, LF และอัตราเงินเฟ้อ) โดยใช้ตัวแปรความถี่ที่สูงขึ้น นั่นหมายความว่าเราใช้อัตราเงินเฟ้อรายเดือนและอัตราผลตอบแทนของหุ้นรายวัน อัตราดอกเบี้ย และอัตราแลกเปลี่ยนเป็นตัวทำนายเพื่อคาดการณ์ GDP รายไตรมาสและ LF ในทำนองเดียวกัน และใช้ข้อมูลรายวันเพื่อคาดการณ์อัตราเงินเฟ้อรายเดือน เพื่อประโยชน์ในการเปรียบเทียบ จึงเลือกสร้างตัวแบบการคาดการณ์ตัวแปรความถี่ที่ต่ำกว่าโดยใช้แบบจำลอง ARIMA และระบุเป็น แบบจำลองมาตรฐาน ในการประเมินและค้นหาแบบจำลองที่เหมาะสมที่สุดและการคาดการณ์ โดยเปรียบเทียบแบบจำลองจากค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ยต่ำที่สุด (RMSE) และเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (MAPE) และ Diebold-Mariano (DM) เพื่อประเมินความแม่นยำในการพยากรณ์ โดยแบ่งข้อมูลออกเป็นชุดการฝึกและชุดทดสอบ ซึ่งชุดหลังจะได้รับการประเมินเทียบกับการคาดการณ์ที่ไม่ได้อยู่ในกลุ่มตัวอย่าง เนื่องจากมุ่งเน้นไปที่แบบจำลองการคาดการณ์ระยะสั้น การคาดการณ์ที่สร้างขึ้นทั้งหมดจึงล้าหน้าไป 1 ก้าว และขอบเขตการคาดการณ์เป็นเพียงหนึ่งปี เพื่อให้รูปแบบตามฤดูกาลสมบูรณ์ อย่างแม่นยำ สำหรับข้อมูลรายไตรมาส จะมีการสร้างค่าคาดการณ์สี่ค่า ในขณะที่มีจุดข้อมูลสิบสองจุดสำหรับ ซึ่งข้อมูลจะถูกแยกออกเป็นช่วงนอกตัวอย่าง COVID และไม่ใช้ COVID เพื่อประเมินประสิทธิภาพของแบบจำลอง จากผลการศึกษาพบว่าโมเดลความถี่ผสมส่วนใหญ่ไม่ว่าจะเป็น MIDAS หรือ VAR มีประสิทธิภาพดีกว่าโมเดลค่าเฉลี่ยเคลื่อนที่แบบบูรณาการแบบถดถอยอัตโนมัติ ARIMA ซึ่งใช้เป็นโมเดลมาตรฐาน ในแง่ของข้อผิดพลาดในการพยากรณ์ของข้อมูลชุดนี้ ยกเว้นกรณีอัตราเงินเฟ้อรายเดือนที่มีข้อมูลโควิด บางกรณีจากการศึกษานี้คือ (1) ผลตอบแทนรายวัน

บทที่ 3 วิธีการศึกษา

3.1 ข้อมูลที่ใช้ในการวิเคราะห์

แหล่งข้อมูลที่ใช้ในการวิเคราะห์

แหล่งข้อมูลที่ใช้สำหรับการพยากรณ์ได้จากข้อมูลจากการสำรวจภาวะการทำงานของประชากร สำนักงานสถิติแห่งชาติ ซึ่งเป็นข้อมูลจำนวนผู้ว่างงาน กำลังแรงงานรวม และอัตราการว่างงาน นอกจากนี้ ยังมีการใช้ข้อมูลทางเศรษฐกิจและสังคมอื่น ๆ ในแบบจำลอง ได้แก่ GDP และการเกิดสถานการณ์โควิด-19 รายละเอียดดังตาราง

ข้อมูล	แหล่งข้อมูล	ปี/หมายเหตุ
จำนวนผู้ว่างงาน	สำรวจภาวะการทำงาน ของประชากร สำนักงานสถิติแห่งชาติ	รายเดือน ปี 2545-2565 จำนวน 237 เดือน (เริ่มสำรวจรายเดือนในปี 2545) รายไตรมาส ปี 2544-2565 จำนวน 88 ไตรมาส รายปี ปี 2544-2565 จำนวน 22 ปี
จำนวนกำลัง แรงงานรวม	สำรวจภาวะการทำงาน ของประชากร สำนักงานสถิติแห่งชาติ	รายเดือน ปี 2545-2565 จำนวน 237 เดือน (เริ่มสำรวจรายเดือนในปี 2545) รายไตรมาส ปี 2544-2565 จำนวน 88 ไตรมาส รายปี ปี 2544-2565 จำนวน 22 ปี
อัตราการว่างงาน	สำรวจภาวะการทำงาน ของประชากร สำนักงานสถิติแห่งชาติ	รายเดือน ปี 2545-2565 จำนวน 237 เดือน รายไตรมาส ปี 2544-2565 จำนวน 88 ไตรมาส รายปี ปี 2544-2565 จำนวน 22 ปี
มูลค่า GDP (constant price)	สำนักงานสภา พัฒนาการเศรษฐกิจ และสังคมแห่งชาติ	ปี 2544-2565
Real GDP Growth (Forecast)	IMF	ปี 2566-2570 (แปลงข้อมูลให้เป็นหน่วยเดียวกัน)
สถานการณ์โควิด	ประกาศสถานการณ์ไค วิด ศบค.	ไม่มีสถานการณ์โควิด (ปี 2544-2562) มีสถานการณ์ไค วิด (ปี 2563-2564)

การตรวจสอบข้อมูล

การตรวจสอบข้อมูลจากในอดีตถึงปัจจุบัน เพื่อพิจารณาความผิดปกติของข้อมูลและรูปแบบของข้อมูล โดยทำการนำข้อมูลจำนวนผู้ว่างงานรายไตรมาสรายปี มา plot กราฟ เป็นดังนี้



จากการตรวจสอบข้อมูลจำนวนผู้ว่างงานจากตั้งแต่ปี 2545 – 2565 พบว่ารูปแบบของข้อมูลอยู่ในรูปแบบ U-shape ซึ่งไม่มีลักษณะที่เป็น linear ทำให้เทคนิคการพยากรณ์บางวิธีไม่สามารถนำมาใช้ในการวิเคราะห์ครั้งนี้ได้ เช่น การวิเคราะห์ข้อมูลอนุกรมเวลาด้วยวิธีกำลังสองน้อยที่สุด สำหรับวิธีการศึกษาในครั้งนี้ ใช้วิธีการพยากรณ์ 2 ประเภทด้วยกัน คือ การพยากรณ์ที่ใช้ข้อมูลจากอดีต กับวิธีการพยากรณ์ที่ใช้ตัวแปรภายนอก (extraneous variable) เข้ามาร่วมอธิบายด้วย เนื่องจากผลจากงานวิจัยหลายฉบับ ยืนยันว่า การว่างงานมีเหตุผลจากปัจจัยทางเศรษฐกิจและปัจจัยอื่นเกี่ยวข้องด้วย

ตัวแปรที่ใช้ในการวิเคราะห์

ตัวแปรภายนอก (extraneous variable) มีดังนี้

x_1 = การเกิดสถานการณ์โควิด ได้แก่ $x = 0$; ไม่มีสถานการณ์โควิด

$x = 1$; มีสถานการณ์โควิด

x_2 = ผลิตภัณฑ์รวมในประเทศ

3.2 เทคนิคการพยากรณ์

ในการศึกษานี้จะนำเทคนิคการพยากรณ์มาใช้ในการพยากรณ์จำนวนผู้ว่างงานและกำลังแรงงานรวม โดยจะกล่าวถึง 2 วิธี คือ 1) วิธีการปรับให้เรียบเอ็กซ์โพเนนเชียล (Exponential Smoothing Technique) 2) วิธีการของบ็อกซ์-เจนกินส์ (Box-Jenkins Technique)

3.2.1 วิธีการปรับให้เรียบเอ็กซ์โพเนนเชียล (Exponential Smoothing Technique)

เป็นการพยากรณ์ระยะสั้นที่ทันใจ และระยะสั้น รวมถึงการพยากรณ์ ในระยะปานกลางได้บ้าง จะมีการกำจัดอิทธิพลของความไม่แน่นอนออกไป เพื่อให้เรียบขึ้น ที่ให้สามารถพยากรณ์ หรือประมาณค่าตัวแปรในอนาคตได้ การพยากรณ์แบบ Exponential Smoothing จะให้ความสำคัญกับข้อมูลในอดีตและมีการกำหนด น้ำหนักความสำคัญให้กับข้อมูลในอดีตที่เกิดขึ้นด้วย โดยในงานวิเคราะห์นี้จะกล่าวถึง วิธี Winter's Method

1) Exponential Smoothing Adjusted for Trend and Seasonal Variation (Winters' Method)

วิธีนี้เหมาะสำหรับใช้กับข้อมูลที่มีแนวโน้ม และอิทธิพลของฤดูกาล (Trend –Season Data) ใช้พยากรณ์ระยะสั้นจนถึงระยะปานกลาง ข้อมูลไม่ควรเป็นรายปี เพราะจะทำให้ไม่สามารถแยกอิทธิพลของฤดูกาลได้ ข้อมูลควรอยู่ในรายเดือน รายสัปดาห์ รายไตรมาส และต้องมีข้อมูลอย่างน้อย 36 รายการขึ้นไป ถ้าเป็นข้อมูลรายเดือนหรืออย่างน้อย 12 รายการขึ้นไป ถ้าเป็นข้อมูลรายไตรมาส วิธี Winters Method ใช้หลักการของเทคนิคเอ็กซ์โพเนนเชียล คือ ให้ความสำคัญแก่ข้อมูลแต่ละตัวไม่เท่ากัน และมีค่าคงที่สำหรับปรับให้เรียบ 3 ค่า คือ α (alpha), γ (gamma) และ δ (delta) โดยที่

α = ค่าคงที่ที่ทำให้เรียบระหว่างข้อมูลกับค่าพยากรณ์

โดย $0 \leq \alpha \leq 1$, ถ้า α มีค่าเข้าใกล้ 1 แสดงว่าให้ความสำคัญแก่ข้อมูลล่าสุดมากกว่าข้อมูลอื่น

γ = ค่าคงที่ที่ทำให้เรียบระหว่างแนวโน้มจริงกับค่าประมาณของแนวโน้ม

โดย $0 \leq \gamma \leq 1$ ถ้า γ มีค่าเข้าใกล้ 1 แสดงว่าให้ความสำคัญแก่ข้อมูลล่าสุดมากกว่าข้อมูลอื่น

δ = ค่าคงที่ที่ทำให้เรียบระหว่างค่าฤดูกาลจริงกับค่าประมาณฤดูกาล

โดย $0 \leq \delta \leq 1$ ถ้า δ มีค่าเข้าใกล้ 1 แสดงว่าให้ความสำคัญแก่ข้อมูลล่าสุดมากกว่าข้อมูลอื่น

3.2.2 วิธีการของบ็อกซ์-เจนกินส์ (Box-Jenkins Technique)

วิธีของบ็อกซ์-เจนกินส์ (วิจิต หล่อจิระชุนท์กุล และจิราวัลย์ จิตรถเวช, 2548) การพยากรณ์ด้วยวิธีของบ็อกซ์-เจนกินส์เป็นการพยากรณ์เชิงปริมาณวิธีหนึ่งที่มีแนวคิดที่ว่าพฤติกรรมในอดีตของสิ่งที่ ต้องการพยากรณ์ นั้นเพียงพอที่จะพยากรณ์ พฤติกรรมในอนาคตของตัวเองได้ โดยในการพยากรณ์ข้อมูลอนุกรมเวลาดำวยวิธีของบ็อกซ์-เจนกินส์นี้จะแตกต่างจากการพยากรณ์โดยวิธีอื่น ซึ่งผู้ที่สร้างตัวแบบพยากรณ์นั้นต้องกำหนดรูปแบบของความสัมพันธ์ก่อนที่จะทำการวิเคราะห์ต่อไป

โดยเฉพาะเมื่อนุกรมเวลาไม่มีแนวโน้มวัฏจักรหรือฤดูกาลที่ชัดเจน ทำให้ยากในการกำหนดรูปแบบหรือการวิเคราะห์การถดถอยที่เหมาะสมได้ ซึ่งจะต้องทำการกำหนดรูปแบบของความสัมพันธ์ระหว่างตัวแปรอิสระกับตัวแปรตามก่อน แต่วิธีพยากรณ์ของบ็อกซ์-เจนกินส์สามารถแก้ปัญหาดังกล่าวได้ เพราะวิธีพยากรณ์ของบ็อกซ์-เจนกินส์นั้นไม่มีการกำหนดรูปแบบที่ตายตัวขึ้นก่อนทำการวิเคราะห์ โดยในระหว่างการวิเคราะห์รูปแบบจะถูกกำหนดขึ้นมาเอง ซึ่งสามารถทำตามขั้นตอนของบ็อกซ์-เจนกินส์ได้ดังนี้

1) คำนวณหาค่าของฟังก์ชันสหสัมพันธ์ในตัวเอง (Autocorrelation Function: ACF) และฟังก์ชันสหสัมพันธ์ในตัวเองบางส่วน (Partial Autocorrelation Function: PACF)

เป็นขั้นตอนแรกสำหรับการวิเคราะห์อนุกรมเวลาที่มีสมบัตินิ่ง (stationary) คือการนำอนุกรมเวลาที่เราต้องการหาค่าพยากรณ์มาคำนวณหาค่า ACF และ PACF เพื่อใช้เป็นแนวทางในการกำหนดรูปแบบหรือใช้ในการเลือกตัวแบบซึ่งจะบอกถึงลำดับหรือจำนวนเทอมของข้อมูลที่จะต้องพิจารณาย้อนหลังที่มีค่าสังเกต N คือ $X_1, X_2, X_3 \dots X_N$ คำนวณหาค่า ACF จากสมการ

$$r_j = \frac{\sum_{i=1}^{n-j} (x_{t_i} - \bar{x})(x_{t_{i+j}} - \bar{x})}{\sum_{i=1}^n (x_{t_i} - \bar{x})^2}$$

- เมื่อ X_t คือ ข้อมูลหรือค่าสังเกต ณ เวลา t
- j คือ จำนวนช่วงเวลาที่ข้อมูลอยู่ห่างกัน $j = 1, 2, 3, \dots, k$
- N คือ จำนวนข้อมูลทั้งหมด
- \bar{x} คือ ค่าเฉลี่ยของข้อมูลทั้งหมด

คำนวณหาค่า PACF จากสมการ

$$\hat{\phi}_{kk} = \begin{cases} \eta, & k = 1 \\ \frac{r_k - \sum_{j=1}^{k-1} (\hat{\phi}_{(k-1)j} r_{k-j})}{1 - \sum_{j=1}^{k-1} (\hat{\phi}_{(k-1)j} r_j)}, & k = 2, 3, 4, \dots \end{cases}$$

และ $\hat{\phi}_{kj} = \hat{\phi}_{(k-1)j} - \hat{\phi}_{(kk)} \hat{\phi}_{(k-1)(k-j)} \quad , j = 1, 2, 3, \dots, k-1$

2) การกำหนดตัวแบบสำหรับการพยากรณ์ เป็นขั้นตอนที่พิจารณาว่าตัวแบบใดที่เหมาะสมกับข้อมูลที่น่ามาวิเคราะห์ โดยพิจารณาจากค่า ACF และค่า PACF ซึ่งสามารถสรุปได้ดังตาราง ตารางการพิจารณาค่า ACF และ PACF

ตัวแบบ	ACF	PACF
AR(p)	ลดลงเข้าหา 0 อย่างรวดเร็ว	หลัง lag p มีค่าเท่ากับ 0
MA(q)	หลัง lag q มีค่าเท่ากับ 0	ลดลงเข้าหา 0 อย่างรวดเร็ว
ARMA(p,q)	ลดลงเข้าหา 0 อย่างรวดเร็ว	ลดลงเข้าหา 0 อย่างรวดเร็ว

ตัวแบบเชิงปริมาณที่ใช้ในการพยากรณ์ของงานวิจัยนี้คือกระบวนการ ARIMA(p,d,q) p คือจำนวนเทอมที่ถอยในตัวเอง d คืออันดับของผลต่างที่ทำให้ข้อมูลนิ่ง q คือจำนวนเทอมของค่าเฉลี่ยเคลื่อนที่ ตัวอย่างเช่น กระบวนการ ARIMA(2,1,2) มีผลต่างอันดับที่ 1 (d=1) ที่ทำให้ข้อมูลนิ่ง และมีเทอมการถดถอย และเทอมค่าเฉลี่ยเคลื่อนที่ 2 เทอมเท่ากัน ถ้า d=0 กระบวนการ ARIMA(p,d=0,q) หมายถึง ARMA(p,q) ข้อสังเกตกระบวนการ ARIMA(p,0,0) หมายถึงกระบวนการ AR(p) และกระบวนการ ARIMA(0,0,q) หมายถึงกระบวนการ MA(q) ตัวแบบ ARIMA(p,d,q) ได้มาจากกระบวนการ ARMA(p,q) ซึ่งอยู่ในรูปแบบทั่วไปดังต่อไปนี้

1. A pth-order autoregressive model : AR(p)

$$X_t = \mu + \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + u_t$$

เมื่อ X_t คือ ตัวแปรตอบสนอง ณ เวลา t

μ คือ ค่าคงที่ของตัวแบบ

u_t คือ ค่าความคลาดเคลื่อนสุ่ม ณ เวลา t

$\phi_1, \phi_2, \dots, \phi_p$ คือ สัมประสิทธิ์ของเทอมถดถอย

$X_{t-1}, X_{t-2}, \dots, X_{t-p}$ คือ ตัวแปรตอบสนอง ณ lag ที่ t-1, t-2, ..., t-p

2. A qth-order moving average model : MA(q)

$$X_t = \mu + \theta_1 u_{t-1} + \theta_2 u_{t-2} + \dots + \theta_q u_{t-q}$$

เมื่อ X_t คือ ตัวแปรตอบสนอง ณ เวลา t

μ คือ ค่าเฉลี่ยคงที่

u_t คือ ค่าความคลาดเคลื่อนสุ่ม ณ เวลา t

$\theta_1, \theta_2, \dots, \theta_q$ คือ สัมประสิทธิ์ของเทอมค่าเฉลี่ยเคลื่อนที่

$u_{t-1}, u_{t-2}, \dots, u_{t-q}$ คือ เทอมค่าเฉลี่ยเคลื่อนที่ q เทอม

3. A pth and qth-order autoregressive moving average model : ARMA(p,q)

$$X_t = \mu + \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + u_t + \theta_1 u_{t-1} + \theta_2 u_{t-2} + \dots + \theta_q u_{t-q}$$

เมื่อ X_t คือ ตัวแปรตอบสนอง ณ เวลา t

μ คือ ค่าคงที่ของตัวแบบ

u_t คือ ค่าความคลาดเคลื่อนสุ่ม ณ เวลา t

$\phi_1, \phi_2, \dots, \phi_p$ คือ สัมประสิทธิ์ของเทอมถดถอย

$\theta_1, \theta_2, \dots, \theta_q$ คือ สัมประสิทธิ์ของเทอมค่าเฉลี่ยเคลื่อนที่

$u_{t-1}, u_{t-2}, \dots, u_{t-q}$ คือ เทอมค่าเฉลี่ยเคลื่อนที่ q เทอม

$X_{t-1}, X_{t-2}, \dots, X_{t-p}$ คือ ตัวแปรตอบสนอง ณ lag ที่ t-1, t-2, ..., t-p

3) **ประมาณค่าพารามิเตอร์** เป็นขั้นตอนการประมาณค่าพารามิเตอร์ที่มีอยู่ในตัวแบบอนุกรมเวลา โดยใช้การประมาณค่าพารามิเตอร์ด้วยวิธีความควรจะเป็นสูงสุด (Maximum likelihood) $L = (\phi, \theta, \delta, \sigma_u^2 | X_t, = 1, 2, 3, \dots, N)$ และค่าตัวประมาณของ ϕ, θ และ δ สามารถคำนวณได้จากการทำให้ผลบวกต่ำสุดของความคลาดเคลื่อนกำลังสองมีค่าต่ำสุด นั่นคือ

$$\sum_{t=1}^n \varepsilon_t^2$$

โดยที่ $\varepsilon_t = X_t - \widehat{\phi}_1 X_t - \dots - \widehat{\phi}_p X_{t-p} - \widehat{\delta} + \widehat{\theta}_1 \varepsilon_{t-1} + \dots + \widehat{\theta}_q \varepsilon_{t-q}$ เป็นค่าประมาณของ u_t ซึ่งพิจารณาจากสมการ

$u_t = X_t - \widehat{\phi}_1 X_t - \dots - \widehat{\phi}_p X_{t-p} - \widehat{\delta} + \widehat{\theta}_1 u_{t-1} + \dots + \widehat{\theta}_q u_{t-q}$ เมื่อหาค่าประมาณของ ϕ, θ และ δ ได้แล้ว จะได้ค่าประมาณของ σ_u^2 คือ

$$\sigma_u^2 = \frac{1}{N} \sum_{t=1}^n \varepsilon_t^2$$

ให้ $\widehat{\beta}$ แทนตัวประกอบค่าพารามิเตอร์ต่างๆ สถิติที่ใช้ทดสอบตัวประมาณคือสถิติ t ซึ่ง

$$t_{\widehat{\beta}} = \frac{\widehat{\beta}}{SE(\widehat{\beta})}$$

โดย $SE(\widehat{\beta})$ คือความคลาดเคลื่อนมาตรฐานของ $\widehat{\beta}$ และมีองศาเสรีคือจำนวนเทอม N ลบด้วยพารามิเตอร์ที่ต้องการประมาณค่า

4) การตรวจสอบความเหมาะสมของตัวแบบ

หลังจากได้ตัวแบบอนุกรมเวลาที่ได้คัดเลือกไว้และได้ประมาณค่าพารามิเตอร์เรียบร้อยแล้ว จะเป็นการนำตัวแบบมาตรวจสอบความเหมาะสม ซึ่งหลักในการตรวจสอบความเหมาะสมของตัวแบบ จะพิจารณาจากคุณสมบัติความน่าจะเป็นสุ่มของค่าความคลาดเคลื่อน u_t โดยเฉพาะที่เกี่ยวข้องกับความไม่มี สหสัมพันธ์ในตัวเอง นั่นคือ ถ้าตัวแบบที่ได้เลือกไว้มีความเหมาะสมและทราบค่าพารามิเตอร์เราจะใช้สถิติ Q ซึ่งมีการแจกแจงไคกำลังสอง โดยมีสูตรการคำนวณดังนี้

$$Q(k) = \{(N - d)[(n - d) + 2]\} \sum_{j=1}^k \frac{r_j^2}{[(N - d) - j]}$$

สถิติ Q เป็นสถิติที่ใช้ทดสอบความไม่มีสหสัมพันธ์ในตัวเองของค่าความคลาดเคลื่อน u_t โดยที่มีองศาเสรีของสถิติ $Q = k$ ลบด้วยจำนวนพารามิเตอร์ที่ต้องการประมาณค่าของของตัวแบบที่เลือกไว้

เมื่อ K คือ จำนวนช่วงเวลาที่ย้อนข้อมูลอยู่ห่างกัน K (จำนวน lag)

N คือ จำนวนค่าสังเกตทั้งหมดของค่าอนุกรมเวลา

d คือ อันดับของผลต่างของอนุกรม

r_j คือ ค่าอัตสหสัมพันธ์ที่ lag j

ข้อดีของ ARIMA

- เป็นโมเดลที่เข้าใจได้ง่าย ใช้กันอย่างแพร่หลาย
- เป็นโมเดลที่สามารถอธิบายผลลัพธ์ได้
- เป็นโมเดลที่ยืดหยุ่น สามารถใช้ได้กับข้อมูลอนุกรมเวลาที่หลากหลาย
- เป็นโมเดลที่สามารถใช้ได้กับข้อมูลขนาดเล็ก
- เป็นโมเดลที่สามารถใช้ได้กับข้อมูลที่ขาดหาย (missing value)

ข้อจำกัดของ ARIMA

- หากมีข้อมูลที่มีความผิดปกติ เช่น เพิ่มขึ้นหรือลดลงอย่างรวดเร็วซึ่งส่งผลต่อค่ากลางของตัวแปร model จะไม่สามารถพยากรณ์ได้อย่างแม่นยำ
- ไม่สามารถใช้ได้ดีกับตัวแปรที่มีความสัมพันธ์ไม่เป็นเส้นตรงกับตัวมันเองในอดีต (nonlinear dependencies)
- ไม่สามารถใช้ได้ดีในชุดข้อมูลที่มีค่าผิดปกติ (outliers) หรือค่าที่สูงหรือต่ำกว่าค่าอื่น ๆ ในชุดข้อมูลอย่างมาก (extreme value)
- ไม่สามารถใช้ได้ดีกับข้อมูลที่ทำให้ข้อมูลมีลักษณะสุมด้วยวิธีการอื่น นอกเหนือจากการ differencing

5) แนวทางการประยุกต์ใช้ ARIMA Model

ARIMA Model เหมาะสำหรับการพยากรณ์ข้อมูลที่มีความสัมพันธ์กับตัวมันเองในอดีต แต่มีจุดอ่อนที่ใช้เฉพาะข้อมูลในอดีตเท่านั้น มิได้ใช้ตัวแปรอื่น ๆ ที่อาจส่งผลต่อตัวแปรตามในแบบจำลองได้ แต่เนื่องจากงานศึกษาการพยากรณ์อัตราการว่างงานจำนวนหนึ่งพบว่าตัวแปรทางเศรษฐกิจอื่น ๆ อาจส่งผลต่ออัตราการว่างงานได้ ดังนั้นจึงควรจะผนวกตัวแปรดังกล่าวเข้าไปในแบบจำลอง เพื่อช่วยในการพยากรณ์ให้มีความแม่นยำมากขึ้น ด้วยเหตุนี้จึงได้ขยายแบบจำลอง ARIMA โดยเพิ่มตัวแปรอธิบายภายนอก (X) เข้าไป หรือเรียกว่าแบบจำลอง ARIMAX (Auto Regressive (AR) Integrated (I) Moving Average (MA) with Exogenous Variables (X))

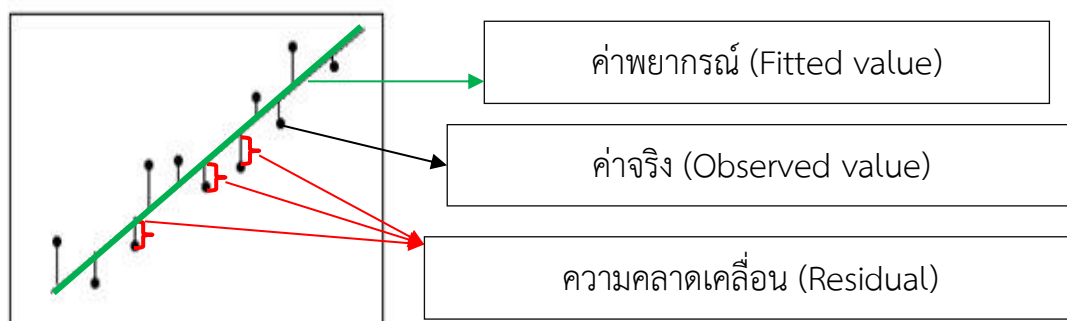
ARIMAX เป็นแบบจำลองการทำนายที่นิยมในสถิติและการวิเคราะห์ข้อมูลเวลาจริง (time series analysis) ที่นำเสนอความสามารถในการผนวกข้อมูลเสริม (exogenous variables) เข้ากับโมเดล ARIMA (AutoRegressive Integrated Moving Average) เพื่อเพิ่มประสิทธิภาพในการทำนาย โดยทั่วไปแล้ว ARIMA นั้นมีการใช้ข้อมูลเวลาที่มีความสัมพันธ์กันแบบนัยสำคัญ (significant autocorrelation) ในขณะที่ ARIMAX มีความสามารถในการรวมข้อมูลเสริมที่มีผลต่อตัวแปรตามที่ต้องการทำนาย

นอกจากนี้ ARIMAX ยังมีความสามารถในการจัดการกับปัญหาการทำนายที่มีตัวแปรที่มีผลต่อตัวแปรตามน้อยชนิด และช่วยให้การทำนายเป็นไปอย่างมีประสิทธิภาพมากยิ่งขึ้น อย่างไรก็ตามการใช้ ARIMAX ต้องคำนึงถึงการเลือกตัวแปรเสริมที่มีผลต่อตัวแปรตามอย่างเหมาะสม และการตรวจสอบความเหมาะสมของโมเดลที่ได้ผลลัพธ์ เนื่องจากหากเลือกตัวแปรที่ไม่เหมาะสม อาจนำไปสู่ผลการพยากรณ์ที่ไม่แม่นยำ

3.3 หลักการพิจารณาวิธีการพยากรณ์ที่เหมาะสมที่สุด

เนื่องจากข้อมูลอนุกรมเวลาชุดหนึ่ง อาจใช้เทคนิคการวิเคราะห์ได้หลายวิธี เพื่อคัดเลือกตัวแบบที่คาดว่าจะให้ค่าพยากรณ์มีความคลาดเคลื่อนต่ำที่สุด ดังนั้นในการคัดเลือกตัวแบบ อาจคำนวณค่าวัดความคลาดเคลื่อน (e_t) ระหว่าง ค่าที่แท้จริง (Y_t) กับ ค่าพยากรณ์ (\hat{Y}_t)

$$e_t = Y_t - \hat{Y}_t$$



Definition: Residual = Observed value - Fitted value

ในที่นี้ พิจารณาจากค่ารากที่สองของค่าเฉลี่ยความคลาดเคลื่อนกำลังสอง (Root of Mean Squared Error : RMSE) ในการเลือกแบบพยากรณ์โดยเลือกเทคนิคการพยากรณ์ที่ให้ค่าความคลาดเคลื่อน RMSE ต่ำสุด เมื่อได้ตัวแบบที่เหมาะสมแล้ว จะทำการทดสอบประสิทธิภาพของตัวแบบโดยการเปรียบเทียบระหว่างค่าจริงและค่าที่พยากรณ์ได้ ซึ่งหากค่าความคลาดเคลื่อนน้อยแสดงว่าตัวแบบนั้นมีประสิทธิภาพ

$$RMSE = \sqrt{\sum_{t=1}^n \frac{(Y_t - \hat{Y}_t)^2}{n}}$$

เมื่อ Y_t คือ ค่าของข้อมูลจริง

\hat{Y}_t คือ ค่าพยากรณ์

n คือ ขนาดของอนุกรมเวลา

นอกจากนี้ ยังพิจารณาค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error : MAPE) ซึ่งสามารถหาได้จากค่าเฉลี่ยของค่าเปอร์เซ็นต์ความคลาดเคลื่อนมาเฉลี่ยกัน ให้ผลเป็นเปอร์เซ็นต์ ทำให้สามารถเข้าใจถึงระดับความแม่นยำได้ง่าย โดยไม่ต้องคำนึงถึงขนาดของสิ่งที่พยากรณ์ (scale-independent)

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right|$$

เมื่อ Y_t คือ ค่าของข้อมูลจริง

\hat{Y}_t คือ ค่าพยากรณ์

n คือ ขนาดของอนุกรมเวลา

โดยการเลือกแบบจำลองการพยากรณ์อัตราการว่างงานระหว่างแบบจำลอง Exponential smoothing, Holt's, ARIMA และ ARIMAX เป็นการนำแบบจำลองที่มีประสิทธิภาพที่ดีที่สุดของแต่ละวิธีมาเปรียบเทียบกันตามเกณฑ์ข้างต้นเพื่อหาแบบจำลองที่ดีที่สุด

3.4 ขั้นตอนการพยากรณ์อัตราการว่างงาน

ขั้นที่ 1 รวบรวมข้อมูลจำนวนผู้ว่างงานและกำลังแรงงานรวม รายเดือน รายไตรมาส และรายปี จากสำรวจภาวะการทำงานประชากร สำนักงานสถิติแห่งชาติ (ทดสอบความนิ่งของข้อมูล และความคงที่ของความแปรปรวน)

ขั้นที่ 2 ทดสอบสหสัมพันธ์ไขว้ (Cross Correlation) ของตัวแปรอิสระที่ใช้ในแบบจำลองที่ ใน lag ต่างๆ กับตัวแปรตามที่น่าสนใจ เพื่อนำตัวแปรอิสระของ lag ที่มีความสัมพันธ์กับตัวแปรตามมากที่สุดมาใช้ในแบบจำลอง ARIMAX

ขั้นที่ 3 แบ่งข้อมูลออกเป็น Train – Test และเลือกแบบจำลองโดยวิธีที่ใช้ในการพยากรณ์จะประกอบด้วย Exponential smoothing, Holt's , ARIMA และ ARIMAX จากนั้นเลือกวิธีการพยากรณ์ที่เหมาะสมที่สุด โดยเปรียบเทียบค่าความคลาดเคลื่อนจากค่า RMSE และ MAPE

ขั้นที่ 4 ใช้ข้อมูล 100% ในการ Fit Model และทำการพยากรณ์ข้อมูลล่วงหน้าจากตัวแบบที่เหมาะสมที่สุด

ขั้นที่ 5 คำนวณอัตราการว่างงาน ที่ได้จากค่าพยากรณ์จำนวนผู้ว่างงานและกำลังแรงงานรวม

เครื่องมือที่ใช้ในการวิเคราะห์ ในการศึกษานี้ การวิเคราะห์ด้วยอนุกรมเวลาด้วยโปรแกรม R (Package fpp3 สำหรับการพยากรณ์โดยใช้จำนวน และ fpp2 สำหรับการพยากรณ์โดยใช้อัตรา)

บทที่ 4 ผลการศึกษา

ในการพยากรณ์ จะแบ่งการดำเนินการออกเป็น 1) การพยากรณ์โดยใช้ข้อมูลรายปี 2) การพยากรณ์โดยใช้ข้อมูลรายไตรมาส และ 3) การพยากรณ์โดยใช้ข้อมูลรายเดือน ซึ่งในแต่ละส่วนจะมีแบบจำลองสำหรับพยากรณ์ข้อมูลผู้ว่างงานและกำลังแรงงาน จากนั้นมาคำนวณหาอัตราการว่างงาน ภายหลัง รวมถึงแบบจำลองพยากรณ์อัตราการว่างงาน ทั้งนี้ วิธีที่ใช้ในการพยากรณ์จะประกอบด้วย Holt, Exponential Smoothing, ARIMA และ ARIMAX

ก่อนที่จะทำการพยากรณ์ จำเป็นต้องเลือก lag ของข้อมูลอิสระ หรือ GDP ที่จะนำใช้ในแบบจำลอง ARIMAX โดยการหาค่าสหสัมพันธ์ไขว้ (Cross Correlation) ของตัวแปร GDP ที่ lag ต่าง ๆ กับตัวแปรตามที่น่าสนใจ ได้แก่ จำนวนผู้ว่างงาน จำนวนกำลังแรงงาน และอัตราการว่างงาน เพื่อช่วยให้ผลของการพยากรณ์ที่ได้มีความแม่นยำมากขึ้น ซึ่งค่าสหสัมพันธ์ไขว้ของข้อมูลรายปี และรายไตรมาสสามารถสรุปได้ดังตาราง

ค่าสหสัมพันธ์ไขว้ของข้อมูลรายปี

	GDP	GDP lag1	GDP lag2	GDP lag3	GDP lag4	GDP growth	GDP growth lag1	GDP growth lag2
ผู้ว่างงาน	-0.60	-0.56	-0.50	-0.49	-0.46	0.04	-0.02	0.18
อัตราการว่างงาน	-0.65	-0.61	-0.57	-0.55	-0.52	0.09	0.04	0.20
กำลังแรงงาน	0.83	0.82	0.81	0.82	0.80	-0.38	-0.37	-0.42

จากตารางพบว่า ความสัมพันธ์ระหว่างการว่างงานและ GDP มีทิศทางตรงกันข้ามตามสมมติฐาน โดยมีความสัมพันธ์กันมากที่สุดในปีเดียวกัน นอกจากนี้ความสัมพันธ์ของข้อมูลกำลังแรงงานและ GDP มีความสัมพันธ์เชิงบวก และมีความสัมพันธ์กันสูงในปีเดียวกัน อย่างไรก็ตามอัตราการเติบโตของ GDP ไม่มีความสัมพันธ์กับตัวแปรตามที่น่าสนใจ จึงเลือกใส่ตัวแปร GDP ที่เป็นมูลค่าลงไป ในแบบจำลอง ARIMAX ของการพยากรณ์จำนวนผู้ว่างงาน กำลังแรงงานและอัตราการว่างงานที่เวลาเดียวกันในข้อมูลรายปี

ค่าสหสัมพันธ์ไขว้ของข้อมูลรายไตรมาส

	GDP	GDP lag1	GDP lag2	GDP lag3	GDP lag4	GDP growth	GDP growth lag1	GDP growth lag2
ผู้ว่างงาน	-0.54	-0.50	-0.51	-0.53	-0.49	-0.04	-0.04	0.08
อัตราการว่างงาน	-0.579	-0.54	-0.56	-0.576	-0.53	0.01	0.01	0.10
กำลังแรงงาน	0.78	0.78	0.803	0.805	0.78	-0.29	-0.31	-0.21

เช่นเดียวกันกับข้อมูลรายไตรมาส อัตราการว่างงานและจำนวนผู้ว่างงานมีความสัมพันธ์กับ GDP ณ ไตรมาสเดียวกันมากที่สุด แต่กำลังแรงงานมีความสัมพันธ์กับ GDP lag 3 มากที่สุด และตัวแปรตามที่น่าสนใจทุกตัวไม่มีความสัมพันธ์กับอัตราการเติบโตของ GDP ดังนั้นจึงเลือกใส่ตัวแปร GDP ในการพยากรณ์จำนวนผู้ว่างงานและอัตราการว่างงานด้วยข้อมูลรายไตรมาสในแบบจำลอง ARIMAX และใส่ตัวแปร GDP lag3 ในการพยากรณ์จำนวนกำลังแรงงานด้วยข้อมูลรายไตรมาสในแบบจำลอง ARIMAX

4.1 การพยากรณ์อัตราการว่างงาน โดยใช้ข้อมูลรายปี


ในขั้นตอนแรก จะเป็นการคัดเลือกแบบจำลองสำหรับการใช้พยากรณ์ข้อมูลจำนวนผู้ว่างงานและกำลังแรงงานรวม โดยแบ่งข้อมูลออกเป็น Train – Test และเลือกแบบจำลองที่ให้ Forecast Error (RMSE และ MAPE) ต่ำที่สุด ซึ่งในการศึกษาครั้งนี้จะใช้เทคนิคการพยากรณ์ในการเลือกตัวแบบที่เหมาะสม 4 วิธี คือ

- 1) Exponential Smoothing
- 2) Holt's method
- 3) ARIMA
- 4) ARIMAX


4.1.1 จำนวนผู้ว่างงาน

Model	ETS ETS(M,N,N)	HOLT'S ETS(A,A,N)	ARIMA ARIMA(2,2,0)
AICc	531.56	539.88	472.91
Ljung-Box	0.632	0.597	0.309
RMSE (in-sample)	113653	114000	90290
MAPE (in-sample)	15.70	19.60	14.10
RMSE (out-of-sample)	111433	139000	329000
MAPE (out-of-sample)	18.30	22.20	52.30
2564 (748,268)	651,071	602,375	916,078
2565 (527,025)	651,071	658,782	960,581


Model	ARIMAX covid ARIMA(0,2,0)	ARIMAX GDP ARIMA(2,2,0)	ARIMAX covid + GDP ARIMA(1,0,0)
AICc	467.78	470.16	524.88
Ljung-Box	0.023	0.493	0.513
RMSE (in-sample)	88347	76145	82064
MAPE (in-sample)	13.50	12.90	12.50
RMSE (out-of-sample)	196000	207000	156000
MAPE (out-of-sample)	31.90	31.20	25.60
2564 (748,268)	620,211	808,285	613,637
2565 (527,025)	280,731	813,692	351,496




a) ETS




b) Holt's




c) ARIMA



d) ARIMAX - covid



e) ARIMAX - GDP



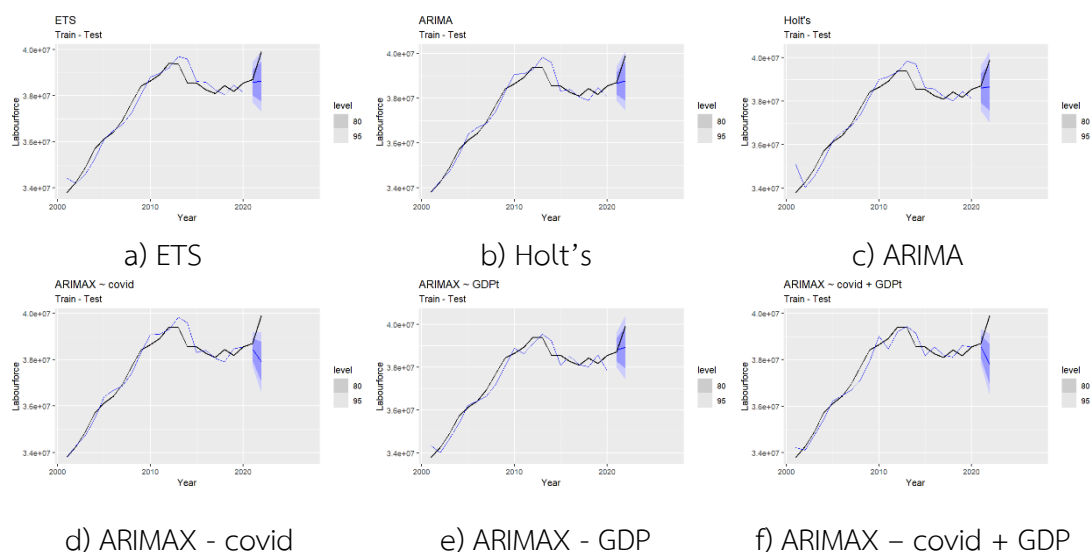
f) ARIMAX - covid + GDP

จากตารางแสดงค่าสถิติต่าง ๆ ที่เกี่ยวข้องกับเกณฑ์การพิจารณาตัวแบบข้างต้น จะเห็นว่าค่าแบบจำลอง ETS(M,N,N) ให้ค่า Forecast Error ต่ำที่สุด แต่เมื่อพิจารณารูปกราฟ a) จะพบว่าแนวโน้มของค่าพยากรณ์ที่ได้ ไม่สอดคล้องกับจริงของข้อมูลในช่วง Test set จึงพิจารณาเลือกแบบจำลองด้วยวิธี ARIMAX ซึ่งจะพบว่า แบบจำลอง ARIMAX ที่มีการใส่ตัวแปรอธิบายทั้ง Covid และ GDP ให้ค่า Forecast Error ต่ำที่สุด ดังนั้น จึงเลือกแบบจำลอง ARIMAX - covid + GDP สำหรับเป็นตัวแทนในการพยากรณ์ข้อมูลจำนวนผู้ว่างงาน

4.1.2 กำลังแรงงานรวม

	ETS	HOLT'S	ARIMA
Model	ETS(M,Ad,N)	ETS(A,A,N)	ARIMA(0,2,1)
AICc	591.08	596.41	517.89
Ljung-Box	0.454	0.765	0.648
RMSE (in-sample)	371394	468000	352000
MAPE (in-sample)	0.78	0.94	0.71
RMSE (out-of-sample)	913477	883000	795000
MAPE (out-of-sample)	1.76	1.69	1.46
2564 (38,699624)	38,582,230	38,601,453	38,662,032
2565 (39,903,313)	38,616,805	38,658,525	38,779,640

	ARIMAX covid	ARIMAX GDP	ARIMAX covid + GDP
Model	ARIMA(0,2,1)	ARIMA(2,0,0)	ARIMA(2,0,0)
AICc	519.22	587.81	586.20
Ljung-Box	0.852	0.288	0.384
RMSE (in-sample)	337000	374000	328000
MAPE (in-sample)	0.65	0.87	0.74
RMSE (out-of-sample)	1420000	<u>699000</u>	1490000
MAPE (out-of-sample)	2.82	<u>1.37</u>	2.80
2564 (38,699624)	38,454,115	38,804,978	38,571,975
2565 (39,903,313)	37,907,118	38,920,788	37,801,077



จากตารางแสดงค่าสถิติต่าง ๆ ที่เกี่ยวข้องกับเกณฑ์การพิจารณาตัวแบบข้างต้น จะเห็นว่าค่าแบบจำลอง แบบจำลอง ARIMAX ที่มีการใส่ตัวแปรอธิบาย GDP ให้ค่า Forecast Error ต่ำที่สุด ดังนั้น จึงเลือกแบบจำลอง ARIMAX - GDP สำหรับเป็นตัวแทนในการพยากรณ์ข้อมูลกำลังแรงงานรวม

ขั้นตอนต่อไปเป็นการนำแบบจำลองที่ได้จาก 4.1.1 และ 4.1.2 มาพยากรณ์ข้อมูลใน 5 ปีข้างหน้า โดยในขั้นตอนนี้ จะทำการ Fit Model กับข้อมูลทั้งหมด (2544 – 2565) ใหม่อีกครั้ง เพื่อให้แบบจำลองได้เรียนรู้ถึงเหตุการณ์ช่วงสถานการณ์โควิด อีกทั้งยังเป็นการเพิ่มจำนวนของข้อมูล ช่วยเพิ่มความน่าเชื่อถือของการพยากรณ์ได้มากยิ่งขึ้น พร้อมทั้งทำการทดลองแปลง (Transform) ตัวแปรด้วยการใช้ Log กับตัวแปรตาม และ/หรือ ตัวแปรอธิบาย ซึ่งได้ผลลัพธ์ของการพยากรณ์ ตามตารางด้านล่างนี้

	Model 1 ไม่แปลงข้อมูล	Model 2 Log (จำนวนผู้ว่างงาน) และ log(GDP)	Model 3 Log (จำนวนผู้ว่างงาน)	Model 4 Log (GDP)
Model	ARIMA(1,0,1)	ARIMA(2,0,0)	ARIMA(2,0,0)	ARIMA(1,0,0)
AICc	575.84	-7.71	-6.41	573.23
RMSE (in-sample)	74004	69082	73581	77922
MAPE (in-sample)	11.60	10.40	10.60	11.40
2566	401,393	486,838	486,169	468,943
2567	337,802	428,844	428,917	411,769
2568	281,244	376,826	376,048	360,159
2569	229,598	336,586	332,603	312,795
2570	180,853	307,549	298,597	268,393

	Model 1 ไม่แปลงข้อมูล	Model 2 Log (กำลังแรงงานรวม) และ log(GDP)	Model 3 Log (กำลังแรงงานรวม)	Model 4 Log (GDP)
Model	ARIMA(3,0,0)	ARIMA(3,0,0)	ARIMA(3,0,0)	ARIMA(2,0,0)
AICc	645	-124	-122	646
RMSE (in-sample)	355000	347000	357000	427000
MAPE (in-sample)	0.74	0.73	0.75	0.92
2566	40,357,705	40,327,749	40,393,868	40,494,279
2567	41,168,766	41,081,493	41,248,471	40,726,641
2568	41,411,889	41,245,540	41,546,219	40,751,352
2569	41,728,779	41,460,920	41,905,628	40,667,995
2570	41,730,505	41,361,293	41,948,217	40,536,227

จากตารางข้างต้นจะเห็นว่าแบบจำลองที่ทำการแปลงข้อมูลด้วยการใช้ Log ทั้งตัวแปรตามและตัวแปรอธิบายให้ค่าสถิติ AICc, RMSE และ MAPE ต่ำที่สุด ทั้งในส่วนของจำนวนผู้ว่างงานและกำลังแรงงานรวม จึงเลือกแบบจำลองดังกล่าวเพื่อพยากรณ์จำนวนผู้ว่างงานและกำลังแรงงานรวมใน 5 ปีข้างหน้า และนำข้อมูลพยากรณ์ดังกล่าวมาคำนวณอัตราการว่างงาน ซึ่งจะได้ผลการพยากรณ์ ดังนี้

ปี	จำนวนผู้ว่างงาน (A)	กำลังแรงงานรวม (B)	อัตราการว่างงาน		ช่วงการ พยากรณ์
	ค่าพยากรณ์ ARIMA(2,0,0)	ค่าพยากรณ์ ARIMA(3,0,0)	(A/B)*100	พยากรณ์ โดยใช้อัตรา โดยใช้อัตรา	
2566	486,838	40,327,749	1.21	1.11	1.11-1.21
2567	428,844	41,081,493	1.04	1.13	1.04-1.13
2568	376,826	41,245,540	0.91	1.13	0.91-1.13
2569	336,586	41,460,920	0.81	0.99	0.81-0.99
2570	307,549	41,361,293	0.74	0.89	0.74-0.89

4.1.3 อัตราการว่างงาน

ในส่วนถัดมาจะเป็นการจะเป็นการคัดเลือกแบบจำลองสำหรับการพยากรณ์อัตราการว่างงานตัวมันเอง โดยแบ่งข้อมูลออกเป็น Train – Test และเลือกแบบจำลองที่ให้ Forecast Error (RMSE และ MAPE ของ Test Set) ต่ำที่สุด จากนั้นจึงนำแบบจำลองดังกล่าวไปใช้กับข้อมูล 100% เพื่อหาค่าพยากรณ์ในอีก 5 ปีข้างหน้า ซึ่งในการศึกษาครั้งนี้จะใช้เทคนิคการพยากรณ์ในการเลือกตัวแบบที่เหมาะสม 4 วิธี คือ

- 1) Exponential Smoothing
- 2) Holt's method
- 3) ARIMA
- 4) ARIMAX

Model	ETS ETS(M,N,N)	HOLT'S ETS(A,A,N)	ARIMA ARIMA(1,0,1)
AICc	21.16	23.82	17.6
RMSE (in-sample)	0.31	0.28	0.28
MAPE (in-sample)	15.26	17.99	13.03
RMSE (out-of-sample)	0.32	0.58	0.63
MAPE (out-of-sample)	20.64	31.48	39.70
2564 (1.90)	1.69	1.91	2.16
2565 (1.30)	1.69	2.11	2.16


Model	ARIMAX covid ARIMAX(1,0,1)	ARIMAX GDP ARIMAX(1,0,1)	ARIMAX Covid + GDP ARIMAX(2,2,0)
AICc	18.22	13.19	11.82
RMSE (in-sample)	0.24	0.21	0.20
MAPE (in-sample)	10.21	12.04	11.44
RMSE (out-of-sample)	0.14	0.22	0.10
MAPE (out-of-sample)	9.24	12.54	6.74
2564 (1.90)	1.76	1.87	1.81
2565 (1.30)	1.16	1.61	1.42



a) ETS

b) Holt's

c) ARIMA



d) ARIMAX - covid

e) ARIMAX - GDP

f) ARIMAX – covid + GDP

จากรูป a) ถึง f) เป็นการพยากรณ์ที่ได้จากการใช้ข้อมูล Training data (ข้อมูลในช่วง 2544-2563) ในการพยากรณ์ข้อมูลออกไป 2 ปี เพื่อเทียบกับข้อมูลจริงในปี 2564-2565 (Test set) โดยกราฟสีน้ำเงิน คือ กราฟของข้อมูลจริงที่ได้จากการสำรวจภาวะการทำงานของประชากร สำนักงานสถิติแห่งชาติ เส้นสีเขียว คือ ข้อมูลการพยากรณ์ที่ได้จากแบบจำลอง สำหรับการพิจารณาเลือกแบบจำลอง ทำได้โดยเปรียบเทียบข้อมูลจริงที่เกิดขึ้นกับค่าพยากรณ์ที่ได้ หรือเปรียบเทียบกราฟเส้นสีน้ำเงินและกราฟเส้นสีเขียว ซึ่งเกณฑ์การพิจารณาแบบจำลองดังที่กล่าวไปแล้วในหัวข้อ 3.3 คือการเปรียบเทียบค่า RMSE และ MAPE ที่น้อยที่สุดของข้อมูลในชุด Test set (Forecast Error/ Out of Sample Error) พบว่าแบบจำลอง ARIMAX (2,2,0) ที่มีการใส่ตัวแปรอธิบายทั้ง Covid และ GDP ให้ค่า Forecast Error ต่ำที่สุดดังตาราง ดังนั้น จึงเลือกแบบจำลองนี้ในการพยากรณ์ข้อมูลอัตราการว่างงาน

เมื่อได้แบบจำลองที่ให้ค่า Forecast Error ต่ำที่สุดแล้ว จึงนำแบบจำลองดังกล่าวไปใช้กับข้อมูลทั้งชุด (ข้อมูลปี 2544-2565) และพยากรณ์ข้อมูลออกไปจำนวน 5 ปี ซึ่งให้ผลการพยากรณ์ดังตารางด้านล่าง ในช่องของการพยากรณ์โดยใช้อัตราการว่างงาน

ปี	จำนวนผู้ว่างงาน (A)	กำลังแรงงานรวม (B)	อัตราการว่างงาน (A/B)*100	อัตราการว่างงาน พยากรณ์ โดยใช้อัตรา	ช่วงการ พยากรณ์
	ค่าพยากรณ์ ARIMA(2,0,0)	ค่าพยากรณ์ ARIMA(3,0,0)			
2566	486,838	40,327,749	1.21	1.11	1.11-1.21
2567	428,844	41,081,493	1.04	1.13	1.04-1.13
2568	376,826	41,245,540	0.91	1.13	0.91-1.13
2569	336,586	41,460,920	0.81	0.99	0.81-0.99
2570	307,549	41,361,293	0.74	0.89	0.74-0.89

4.2 การพยากรณ์อัตราการว่างงาน โดยใช้ข้อมูลรายไตรมาส


ในขั้นตอนแรก จะเป็นการคัดเลือกแบบจำลองสำหรับการใช้พยากรณ์ข้อมูลจำนวนผู้ว่างงาน และกำลังแรงงานรวม โดยแบ่งข้อมูลออกเป็น Train – Test และเลือกแบบจำลองที่ให้ Forecast Error (RMSE และ MAPE) ต่ำที่สุด ซึ่งในการศึกษาครั้งนี้จะใช้เทคนิคการพยากรณ์ในการเลือกตัวแบบที่เหมาะสม 5 วิธี คือ

- 1) Exponential Smoothing
- 2) Holt-Winters' Addictive
- 3) Holt-Winters' Multiplicative
- 4) ARIMA
- 5) ARIMAX


4.2.1 จำนวนผู้ว่างงาน

Model	ETS	Addictive	Multiplicative	ARIMA
	ETS (A,N,A)	ETS (A,A,A)	ETS (M,A,M)	ARIMA (0,1,1)(0,1,1)[4]
AICc	68.23	74.13	74.82	-51.03
Ljung-Box	0.787	0.546	0.887	0.597
RMSE (in-sample)	79033	75868	76283	73127
MAPE (in-sample)	11.6	11.8	11.6	11.5
RMSE (out-of-sample)	262956	415000	378000	543000
MAPE (out-of-sample)	39.5	63.6	57.5	52.30


Model	ARIMAX	ARIMAX	ARIMAX
	covid ARIMA (0,1,1)(0,1,1)[4]	GDP ARIMA (0,1,1)(0,1,1)[4]	covid + GDP ARIMA (0,0,3)(1,1,0)[4]
AICc	-66.75	-65.97	-75.46
Ljung-Box	0.451	0.145	0.499
RMSE (in-sample)	60085	66286	59614
MAPE (in-sample)	10.4	10.7	10.1
RMSE (out-of-sample)	93790	402000	78009
MAPE (out-of-sample)	14.0	62.1	10.3




a) ETS




b) Addictive




c) Multiplicative




d) ARIMA



e) ARIMAX - covid



f) ARIMAX - GDP




g) ARIMAX - covid + GDP

จากตารางแสดงค่าสถิติต่าง ๆ ที่เกี่ยวข้องกับเกณฑ์การพิจารณาตัวแบบข้างต้น จะเห็นว่าค่าแบบจำลอง ARIMAX ที่มีการใส่ตัวแปรอธิบายทั้ง Covid และ GDP ให้ค่า Forecast Error ต่ำที่สุด ดังนั้น จึงเลือกแบบจำลอง ARIMAX - covid + GDP สำหรับเป็นตัวแทนในการพยากรณ์ข้อมูลจำนวนผู้ว่างงาน


4.2.2 กำลังแรงงานรวม

Model	ETS	Addictive	Multiplicative	ARIMA
	ETS (M,Ad,A)	ETS (A,A,A)	ETS (M,A,M)	ARIMA (0,1,1)(0,1,1)[4]
AICc	-411.15	-410.14	-410.29	-504.84
Ljung-Box	0.629	0.676	0.685	0.980
RMSE (in-sample)	282662	289000	289000	328000
MAPE (in-sample)	0.566	0.561	0.561	0.636
RMSE (out-of-sample)	619866	492000	490000	445000
MAPE (out-of-sample)	1.45	1.18	1.18	1.04


Model	ARIMAX covid ARIMA (0,1,1)(0,1,1)[4]	ARIMAX GDP ARIMA (1,0,0)(0,1,1)[4]	ARIMAX covid + GDP ARIMA (1,0,1)(0,1,1)[4]
AICc	-502.85	-511.71	-511.5
Ljung-Box	0.978	0.968	0.883
RMSE (in-sample)	328000	313000	305000
MAPE (in-sample)	0.640	0.651	0.651
RMSE (out-of-sample)	566000	495000	891000
MAPE (out-of-sample)	1.35	1.18	1.96




a) ETS




b) Addictive




c) Multiplicative




d) ARIMA



e) ARIMAX - covid



f) ARIMAX - GDP



g) ARIMAX - covid + GDP

จากตารางแสดงค่าสถิติต่าง ๆ ที่เกี่ยวข้องกับเกณฑ์การพิจารณาตัวแบบข้างต้น จะเห็นว่าค่าแบบจำลอง ARIMAX ที่มีการใส่ตัวแปรอธิบาย GDP ให้ค่า Forecast Error ต่ำที่สุด ดังนั้น จึงเลือกแบบจำลอง ARIMAX - GDP สำหรับเป็นตัวแบบในการพยากรณ์ข้อมูลกำลังแรงงานรวม

ขั้นตอนต่อไปเป็นการนำแบบจำลองที่ได้จาก 4.2.1 และ 4.2.2 มาพยากรณ์ข้อมูลใน 5 ปีข้างหน้า โดยในขั้นตอนนี้ จะทำการ Fit Model กับข้อมูลทั้งหมด (2544 ไตรมาส 1 – 2565 ไตรมาส 4)

ใหม่อีกครั้ง เพื่อให้แบบจำลองได้เรียนรู้ถึงเหตุการณ์ช่วงสถานการณ์โควิด อีกทั้งยังเป็นการเพิ่มจำนวนของข้อมูล ช่วยเพิ่มความน่าเชื่อถือของการพยากรณ์ได้มากยิ่งขึ้น และนำข้อมูลพยากรณ์จำนวนผู้ว่างงานและกำลังแรงงานรวมที่ได้จากแบบจำลองข้างต้นมาคำนวณอัตราการว่างงาน ซึ่งจะได้ผลการพยากรณ์ใน 3 ปีข้างหน้า ดังนี้

ปี ไตรมาส	จำนวนผู้ว่างงาน (A)	กำลังแรงงานรวม (B)	อัตราการว่างงาน		ช่วงการ พยากรณ์
	ค่าพยากรณ์ ARIMA(0,0,3)(0,1,0)[4]	ค่าพยากรณ์ ARIMA(1,0,0)(0,1,1)[4]	(A/B)*100	พยากรณ์ โดยใช้อัตรา	
2566 Q1	488,941	40,283,039	1.21	1.28	1.21-1.28
2566 Q2	472,573	40,406,396	1.17	1.28	1.17-1.28
2566 Q3	478,453	40,538,836	1.18	1.22	1.18-1.22
2566 Q4	441,162	40,545,096	1.09	1.10	1.09-1.10
2567 Q1	469,484	40,680,417	1.15	1.24	1.15-1.24
2567 Q2	453,428	40,796,734	1.11	1.22	1.11-1.22
2567 Q3	460,314	40,920,043	1.12	1.17	1.12-1.17
2567 Q4	427,601	40,919,895	1.04	1.08	1.04-1.08
2568 Q1	456,200	41,053,909	1.11	1.20	1.11-1.20
2568 Q2	439,413	41,167,079	1.07	1.18	1.07-1.18
2568 Q3	446,310	41,284,994	1.08	1.13	1.08-1.13
2568 Q4	416,684	41,281,120	1.01	1.05	1.01-1.05

4.3 การพยากรณ์อัตราการว่างงาน โดยใช้ข้อมูลรายเดือน

ขั้นตอนที่ 1 เนื่องจากสถานการณ์โควิด-19 ทำให้ไม่มีการเข้าไปสำรวจภาวะการทำงานของประชากร จึงต้องประมาณค่าสูญหายจำนวนผู้ว่างงานและจำนวนกำลังแรงงานรวม ในเดือนเมษายน – มิถุนายน พ.ศ. 2563 และเดือนมกราคม – ธันวาคม พ.ศ. 2564 ด้วยวิธี Seasonally Decomposed Missing Value Imputation และวิธี Exponential Weighted Moving Average หลังจากนั้นนำค่าที่ได้จากการประมาณทั้ง 2 วิธี มาเฉลี่ยเป็นรายไตรมาส เพื่อเปรียบเทียบกับค่าจริงรายไตรมาสที่สำนักงานสถิติแห่งชาติเผยแพร่ แล้วเลือกค่าที่ได้จากการประมาณวิธีที่ใกล้เคียงกับค่าจริงมากที่สุด โดยพิจารณาจากค่าความคลาดเคลื่อนที่ต่ำที่สุด (RMSE และ MAPE) ซึ่งจะได้ผลดังตาราง

ตารางที่ 1 จำนวนผู้ว่างงานที่ได้จากการประมาณค่าสูญหายในเดือนเมษายน – มิถุนายน พ.ศ. 2563 และเดือนมกราคม – ธันวาคม พ.ศ. 2564 (หน่วย: คน)

ปี	เดือน	จำนวนผู้ว่างงานที่ได้จากการประมาณฯ ด้วยวิธี Seasonally Decomposed Missing Value Imputation	จำนวนผู้ว่างงานที่ได้จากการประมาณฯ ด้วยวิธี Exponential Weighted Moving Average
2563	เมษายน	498,201	465,329
2563	พฤษภาคม	651,949	591,156
2563	มิถุนายน	714,287	719,024
...
2564	มกราคม	670,702	677,713
2564	กุมภาพันธ์	647,886	676,621
2564	มีนาคม	667,354	654,360
2564	เมษายน	679,858	654,360
2564	พฤษภาคม	739,547	654,360
2564	มิถุนายน	707,072	681,995
2564	กรกฎาคม	726,714	671,215
2564	สิงหาคม	716,246	698,400
2564	กันยายน	717,921	698,400
2564	ตุลาคม	760,546	698,400
2564	พฤศจิกายน	742,751	668,586
2564	ธันวาคม	686,696	657,740

ตารางที่ 2 จำนวนกำลังแรงงานรวมที่ได้จากการประมาณค่าสูญหายในเดือนเมษายน – มิถุนายน พ.ศ. 2563 และเดือนมกราคม – ธันวาคม พ.ศ. 2564 (หน่วย: คน)

ปี	เดือน	จำนวนกำลังแรงงานรวมที่ได้ จากการประมาณฯ ด้วยวิธี Seasonally Decomposed Missing Value Imputation	จำนวนกำลังแรงงานรวมที่ได้ จากการประมาณฯ ด้วยวิธี Exponential Weighted Moving Average
2563	เมษายน	38,044,060	38,306,367
2563	พฤษภาคม	38,344,314	38,473,369
2563	มิถุนายน	38,853,385	38,654,186
...	...		
2564	มกราคม	39,115,240	39,213,952
2564	กุมภาพันธ์	39,464,662	39,257,020
2564	มีนาคม	39,438,944	39,340,320
2564	เมษายน	39,254,965	39,340,320
2564	พฤษภาคม	39,540,258	39,340,320
2564	มิถุนายน	40,022,645	39,443,965
2564	กรกฎาคม	39,844,082	39,641,595
2564	สิงหาคม	39,866,877	39,705,133
2564	กันยายน	39,672,479	39,705,133
2564	ตุลาคม	39,510,615	39,705,133
2564	พฤศจิกายน	39,977,986	39,696,529
2564	ธันวาคม	40,071,347	39,664,833

ตารางที่ 3 ค่าความคลาดเคลื่อนจากการประมาณฯ จำนวนผู้ว่างงานด้วยวิธี Seasonally Decomposed Missing Value Imputation

ไตรมาส ปี	ค่าจริง	ค่าเฉลี่ยจากการ ประมาณการ	ค่าความคลาด เคลื่อน	RMSE	MAPE
ไตรมาสที่ 2/2563	745,177	621,479	123,698		
ไตรมาสที่ 1/2564	758,093	661,981	96,112		
ไตรมาสที่ 2/2564	731,828	708,825	23,003	107,225.13	13.06
ไตรมาสที่ 3/2564	871,266	720,294	150,972		
ไตรมาสที่ 4/2564	631,887	729,998	-98,111		

ตารางที่ 4 ค่าความคลาดเคลื่อนจากการประมาณฯ จำนวนผู้ว่างงานด้วยวิธี Exponential Weighted Moving Average

ไตรมาส ปี	ค่าจริง	ค่าเฉลี่ยจากการ ประมาณการ	ค่าความคลาด เคลื่อน	RMSE	MAPE
ไตรมาสที่ 2/2563	745,177	591,837	153,340		
ไตรมาสที่ 1/2564	758,093	669,565	88,528		
ไตรมาสที่ 2/2564	731,828	663,572	68,256	119,128.47	13.85
ไตรมาสที่ 3/2564	871,266	689,338	181,928		
ไตรมาสที่ 4/2564	631,887	674,909	-43,022		

ตารางที่ 5 ค่าความคลาดเคลื่อนจากการประมาณฯ จำนวนกำลังแรงงานรวมด้วยวิธี Seasonally Decomposed Missing Value Imputation

ไตรมาส ปี	ค่าจริง	ค่าเฉลี่ยจากการ ประมาณการ	ค่าความคลาด เคลื่อน	RMSE	MAPE
ไตรมาสที่ 2/2563	38,172,745	38,413,920	-241,174.7		
ไตรมาสที่ 1/2564	38,748,394	39,339,616	-591,221.8		
ไตรมาสที่ 2/2564	38,778,174	39,605,956	-827,782.3	885,181.13	2.09
ไตรมาสที่ 3/2564	38,641,394	39,794,479	-1,153,085.6		
ไตรมาสที่ 4/2564	38,630,536	39,853,316	-1,222,779.6		

ตารางที่ 6 ค่าความคลาดเคลื่อนจากการประมาณฯ จำนวนกำลังแรงงานรวมด้วยวิธี Exponential Weighted Moving Average

ไตรมาส ปี	ค่าจริง	ค่าเฉลี่ยจากการ ประมาณการ	ค่าความคลาด เคลื่อน	RMSE	MAPE
ไตรมาสที่ 2/2563	38,172,745	38,477,974	-305,229		
ไตรมาสที่ 1/2564	38,748,394	39,270,431	-522,037		
ไตรมาสที่ 2/2564	38,778,174	39,374,868	-596,694	765,330.27	1.82
ไตรมาสที่ 3/2564	38,641,394	39,683,954	-1,042,560		
ไตรมาสที่ 4/2564	38,630,536	39,688,832	-1,058,295		

เมื่อเปรียบเทียบค่าเฉลี่ยจากการประมาณการกับค่าจริงรายไตรมาส เพื่อหาวิธีการประมาณค่าสูญหายจากค่าความคลาดเคลื่อนที่ต่ำที่สุด (RMSE และ MAPE) พบว่า การประมาณค่าสูญหายจำนวนผู้ว่างงานด้วยวิธี Seasonally Decomposed Missing Value Imputation ให้ค่าความคลาดเคลื่อนต่ำที่สุด ส่วนการประมาณค่าสูญหายจำนวนกำลังแรงงานรวมด้วยวิธี Exponential Weighted Moving Average ให้ค่าความคลาดเคลื่อนต่ำที่สุด ดังนั้นจึงใช้ข้อมูลจากการประมาณค่าสูญหายในวิธีข้างต้นสำหรับการพยากรณ์ในขั้นถัดไป


ขั้นตอนที่ 2 จะเป็นการคัดเลือกแบบจำลองสำหรับการใช้พยากรณ์ข้อมูลจำนวนผู้ว่างงานและกำลังแรงงานรวม โดยแบ่งข้อมูลออกเป็น Train Set (เดือนมกราคม พ.ศ. 2545 – ธันวาคม พ.ศ. 2563) และ Test Set (เดือนมกราคม พ.ศ. 2564 – ธันวาคม พ.ศ. 2565) จากนั้นเลือกแบบจำลองที่ให้ค่าความคลาดเคลื่อน Forecast Error (RMSE และ MAPE) ต่ำที่สุด ซึ่งในการศึกษาครั้งนี้จะใช้เทคนิคการพยากรณ์ในการเลือกตัวแบบที่เหมาะสม 4 วิธี คือ

- 1) Exponential Smoothing
- 2) Holt's method
- 3) ARIMA
- 4) ARIMAX


4.3.1 จำนวนผู้ว่างงาน ทำการแปลงข้อมูลให้อยู่ในรูป Logarithm เพื่อให้ข้อมูลมีความแปรปรวนที่เสถียรขึ้น (Variance Stable)

Model	ETS	Holt Winter's Additive	Holt Winter's Multiplicative
	ETS(A,N,A)	ETS(A,A,A)	ETS(M,A,M)
AICc	433.7575	448.7337	461.3994
Ljung-Box	0.0273	0.0262	0.00156
RMSE (in-sample)	74065	80104	76910
MAPE (in-sample)	12.3	12.5	12.7
RMSE (out-of-sample)	279425	608772	1243152
MAPE (out-of-sample)	43.4	96.2	192


Model	ARIMA	ARIMAX covid
	ARIMA(2,1,3)(0,1,1)[12]	ARIMA(2,1,3)(0,1,1)[12]
AICc	-159.3277	-164.6255
Ljung-Box	0.311	0.225
RMSE (in-sample)	70893	68812
MAPE (in-sample)	11.5	11.4
RMSE (out-of-sample)	478252	121916
MAPE (out-of-sample)	74.5	19.2




a) ETS




b) Holt Winter's Additive



c) Holt Winter's Multiplicative



d) ARIMA




e) ARIMAX – covid

จากตารางแสดงค่าสถิติต่าง ๆ ที่เกี่ยวข้องกับเกณฑ์การพิจารณาตัวแบบข้างต้น จะเห็นว่าแบบจำลอง ARIMA(2,1,3)(0,1,1)[12] ที่มีการใส่ตัวแปรอธิบาย Covid ให้ค่าความคลาดเคลื่อน Forecast Error ต่ำที่สุด ดังนั้น จึงเลือกแบบจำลอง ARIMAX - covid สำหรับเป็นตัวแทนในการพยากรณ์ข้อมูลจำนวนผู้ว่างงาน


4.3.2 กำลังแรงงานรวม

	ETS	Holt Winter's Additive	Holt Winter's Multiplicative
Model	ETS(M,Ad,N)	ETS(A,A,A)	ETS(M,A,M)
AICc	7037.406	7053.75	7062.451
Ljung-Box	0.0786	0.0525	0.00749
RMSE (in-sample)	308569	319057	327289
MAPE (in-sample)	0.647	0.682	0.697
RMSE (out-of-sample)	708962	437557	247479
MAPE (out-of-sample)	1.55	0.909	0.514


	ARIMA	ARIMAX covid
Model	ARIMA(0,1,2)(0,1,1)[12]	ARIMA(0,1,2)(0,1,2)[12]
AICc	6064.708	6063.908
Ljung-Box	0.119	0.205
RMSE (in-sample)	303718	300090
MAPE (in-sample)	0.613	0.607
RMSE (out-of-sample)	373374	873240
MAPE (out-of-sample)	0.785	1.89




a) ETS




b) Holt Winter's Additive



c) Holt Winter's Multiplicative



d) ARIMA



e) ARIMAX - covid

จากตารางแสดงค่าสถิติต่าง ๆ ที่เกี่ยวข้องกับการพิจารณาตัวแบบข้างต้น จะเห็นว่าแบบจำลอง Holt Winter's Multiplicative ให้ค่าความคลาดเคลื่อน Forecast Error ต่ำที่สุด ดังนั้นจึงเลือกแบบจำลอง Holt Winter's Multiplicative สำหรับเป็นตัวแทนในการพยากรณ์ข้อมูลกำลังแรงงานรวม

ขั้นตอนที่ 3 นำแบบจำลองที่ได้จาก 4.1.1 และ 4.1.2 มาพยากรณ์ข้อมูล 1 ปีข้างหน้า โดยในขั้นตอนนี้ จะทำการ Fit Model กับข้อมูลทั้งชุด (พ.ศ. 2544 – 2565) ใหม่อีกครั้ง เพื่อให้แบบจำลองได้เรียนรู้ถึงเหตุการณ์ช่วงโควิด อีกทั้งยังเป็นการเพิ่มค่าสังเกต เพื่อเพิ่มความถูกต้องของการพยากรณ์ได้มากยิ่งขึ้น ซึ่งได้ค่าสถิติต่าง ๆ ดังตาราง

	จำนวนผู้ว่างงาน	กำลังแรงงานรวม
Model	ARIMA(2,1,3)(0,1,1)[12]	ETS(M,A,M)
AICc	-199.0184	7799.487
RMSE (in-sample)	68530	309831
MAPE (in-sample)	11.0	0.651

จากตารางข้างต้น ได้เลือกแบบจำลองดังกล่าว สำหรับพยากรณ์จำนวนผู้ว่างงานและจำนวนกำลังแรงงานรวมใน 1 ปีข้างหน้า และนำข้อมูลพยากรณ์ดังกล่าวมาคำนวณอัตราการว่างงาน ซึ่งจะได้ผลการพยากรณ์ ดังตาราง

ปี	เดือน	จำนวนผู้ว่างงาน	กำลังแรงงานรวม	อัตราการว่างงาน (A/B)*100
		(A) ค่าพยากรณ์ ARIMA(2,0,0)	(B) ค่าพยากรณ์ ARIMA(3,0,0)	
2566	มกราคม	526,450.3	40,204,547	1.3
2566	กุมภาพันธ์	464,933.5	40,283,954	1.2
2566	มีนาคม	459,548.7	40,345,079	1.1
2566	เมษายน	455,930.9	40,138,864	1.1
2566	พฤษภาคม	527,908.5	40,516,491	1.3
2566	มิถุนายน	511,958.8	40,950,918	1.3
2566	กรกฎาคม	515,074.9	40,697,537	1.3
2566	สิงหาคม	481,826.4	40,833,185	1.2
2566	กันยายน	472,228.4	40,646,207	1.2
2566	ตุลาคม	525,799.8	40,458,876	1.3
2566	พฤศจิกายน	487,413.6	40,850,976	1.2
2566	ธันวาคม	415,891.5	40,843,936	1.0

สรุปวิธีการพยากรณ์และผลการพยากรณ์รายเดือน ที่ได้ศึกษาเบื้องต้น

จากการศึกษาการพยากรณ์อนุกรมเวลา โดยใช้ข้อมูลจำนวนผู้ว่างและกำลังแรงงานรวม จำแนกเป็นรายเดือน ตั้งแต่เดือนมกราคม พ.ศ. 2545 – ธันวาคม พ.ศ. 2565 สามารถสรุปวิธีการพยากรณ์รายเดือนเปรียบเทียบกับค่าจริงจากผลสำรวจภาวะการทำงานของประชากร (รายเดือน) ดังตาราง

ปี	เดือน	อัตราการว่างงาน	
		คำนวณจากค่าพยากรณ์	ค่าจริง จากผลสำรวจภาวะการ ทำงานของประชากร (รายเดือน)
2566	มกราคม	1.3	1.2
2566	กุมภาพันธ์	1.2	0.9
2566	มีนาคม	1.1	1.0
2566	เมษายน	1.1	1.0
2566	พฤษภาคม	1.3	1.3
2566	มิถุนายน	1.3	0.9
2566	กรกฎาคม	1.3	1.2
2566	สิงหาคม	1.2	1.0
2566	กันยายน	1.2	
2566	ตุลาคม	1.3	
2566	พฤศจิกายน	1.2	
2566	ธันวาคม	1.0	

หมายเหตุ: ค่าจริงอัตราการว่างงาน ข้อมูลเผยแพร่ล่าสุดเดือนสิงหาคม พ.ศ. 2566

บทที่ 5

สรุปผลและข้อเสนอแนะจากผู้เชี่ยวชาญ

5.1 สรุปผล

การรายงานการจัดอันดับขีดความสามารถในการแข่งขันของประเทศ โดย International Institute for Management Development (IMD) ทั้งนี้ในการคาดการณ์พบว่า แหล่งที่มาของข้อมูลการคาดการณ์อัตราการว่างงานใน IMD ที่ใช้ใน 2022 มาจาก 2 แหล่ง ได้แก่

- แหล่งข้อมูลของแต่ละประเทศ (National source)
- การคาดการณ์ของ IMF, International Monetary Fund, World Economic Outlook Database, April 2022

โดยผลการคาดการณ์ของ IMF เป็นดังนี้

Subject Descriptor	Unemployment rate
Units	Percent of total labor force
Country/Series-specific Notes	Source: National Statistics Office . Labour Force Survey, Latest actual data: 2020, Employment type: National definition, Data last updated: 03/2022
2020*	2*
2021	1.5
2022	1
2023	1
2024	1
2025	1
2026	1
2027	1
Estimates Start After	2020

จากการศึกษาการจัดทำชุดข้อมูลค่าคาดการณ์อัตราการว่างงานของประเทศไทย ของสำนักงานสถิติแห่งชาติและสำนักงานปลัดกระทรวงแรงงาน เพื่อสามารถจัดส่งข้อมูลใช้ในการจัดอันดับแทนการใช้ข้อมูลจากแหล่งข้อมูลจากองค์กรระหว่างประเทศ ผลสรุปเป็นดังนี้

ปี (1)	จำนวนผู้ว่างงาน ค่าพยากรณ์ (2)	กำลังแรงงาน รวม (B) ค่าพยากรณ์ (3)	อัตราการว่างงาน (A/B)*100 (4)	พยากรณ์ โดยใช้อัตรา (5)	ช่วงการ พยากรณ์ (6)	ค่าพยากรณ์ จาก IMF (7)
2566	486,838	40,327,749	1.21	1.11	1.11-1.21	1.00
2567	428,844	41,081,493	1.04	1.13	1.04-1.13	1.00
2568	376,826	41,245,540	0.91	1.13	0.91-1.13	1.00
2569	336,586	41,460,920	0.81	0.99	0.81-0.99	1.00
2570	307,549	41,361,293	0.74	0.89	0.74-0.89	1.00

จากตารางข้างต้นเป็นข้อมูลที่ได้จากการพยากรณ์โดยใช้ข้อมูลรายปี คอลัมน์ที่ (2) และ (3) เป็นข้อมูลค่าพยากรณ์จำนวนผู้ว่างงานและกำลังแรงงานจากแบบจำลอง ARIMAX ที่มีการใส่ตัวแปร COVID และ GDP เข้าไปในแบบจำลอง จากนั้นนำค่าพยากรณ์ที่ได้ไปหาค่าคาดการณ์อัตราการว่างงานในคอลัมน์ที่ (4) ในส่วนของคอลัมน์ที่ (5) คือค่าพยากรณ์ที่ได้จากการคาดการณ์อัตราการว่างงานตัวมันเอง ซึ่งจะเห็นได้ว่าผลการพยากรณ์อัตราการว่างงานด้วยข้อมูลรายปี โดยใช้ตัวแปรตามคือจำนวนผู้ว่างงานและกำลังแรงงาน และตัวแปรตามคืออัตราการว่างงานมีค่าค่อนข้างใกล้เคียงกัน และใกล้เคียงกับผลการพยากรณ์ที่ IMF คาดการณ์ไว้ และเพื่อให้การพยากรณ์มีความยืดหยุ่นมากขึ้น จึงจัดทำเป็นช่วงของค่าคาดการณ์อัตราการว่างงานในคอลัมน์ (6) เพื่อลดโอกาสของความผิดพลาดในการพยากรณ์

5.2 ข้อเสนอแนะจากผู้เชี่ยวชาญ

จากผลการศึกษาค่าคาดการณ์อัตราการว่างงานของประเทศไทย ได้มีการจัดประชุมนำเสนอผลการศึกษาต่อผู้เชี่ยวชาญเพื่อให้ความเห็นในเรื่องการพัฒนาและปรับปรุงตัวแบบที่ใช้ในการพยากรณ์ ซึ่งผู้เชี่ยวชาญได้ให้ความคิดเห็นตลอดจนข้อเสนอแนะแนวทางเพื่อการพัฒนาตัวแบบการพยากรณ์ต่อไปในอนาคต สรุปได้ดังนี้

1. ดร.กวิน เอี่ยมตระกูล เศรษฐกรชำนาญการ สำนักงานเศรษฐกิจการคลัง ให้ความเห็นว่าการใช้ข้อมูล Time Series ควรใช้ข้อมูลจำนวน 25 ปีขึ้นไป และมีข้อเสนอแนะว่า อาจจะใช้ Error correlation model ซึ่งเป็นการพยากรณ์อัตราการว่างงานในระยะยาว ในการเปรียบเทียบกับแบบจำลองที่ได้ศึกษาข้างต้น นอกจากนี้ อาจจะใช้ Structural break model ในการพยากรณ์อัตราการว่างงาน แทนการใส่ตัวแปร Dummy สถานการณ์โควิดได้

2. ดร.นรพัทธ์ อัครวัลลภ ผู้อำนวยการส่วนนวัตกรรมข้อมูลเศรษฐกิจและงานวิจัย สำนักงานเศรษฐกิจการคลัง ให้ความเห็นว่าเป็นขั้นตอนคัดเลือกแบบจำลองที่เหมาะสม การใส่ค่าของตัวแปรอิสระ GDP ของข้อมูลที่ใช้สำหรับการทดสอบ (Test-set) ควรใส่มูลค่า GDP ที่เป็นค่าพยากรณ์ อาจจะไม่เหมาะสมกว่าการใช้มูลค่า GDP ที่เกิดขึ้นจริงแล้ว และยังมีข้อเสนอแนะถึงแบบจำลอง

ARIMAX ที่ศึกษาข้างต้น น่าจะเหมาะสมกับการพยากรณ์ในระยะสั้น ซึ่งการพยากรณ์ 5 ปี เป็นการพยากรณ์ระยะกลาง หากต้องการพยากรณ์อัตราการว่างงานล่วงหน้า 5 ปี ควรใช้แบบจำลองที่เหมาะสมกับการพยากรณ์ในระยะกลาง หรืออาจใช้วิธี HP filter เพื่อหาค่าพยากรณ์อัตราธรรมชาติของการว่างงาน (Natural rate of unemployment) หรือหา Potential rate ของอัตราการว่างงาน ซึ่งน่าจะเหมาะสมกับการพยากรณ์ในระยะยาวมากกว่า

3. ดร.นครินทร์ อมเรศ ผู้อำนวยการฝ่ายยุทธศาสตร์ความร่วมมือระหว่างองค์กร ธนาการไทยพาณิชย์ ให้ความเห็นว่า การใช้แบบจำลอง ARIMA และเพิ่มตัวแปรอิสระ GDP ซึ่งเป็นข้อมูลรายปี เข้ามาอธิบายถึงความผันแปรของการว่างงาน และใช้ Package จากโปรแกรม R เพื่อหา P,D,Q นั้น เป็นวิธีการที่ค่อนข้างดีแล้ว แต่มีข้อสังเกตคือ ในแบบจำลองรายเดือนไม่ได้มีการเพิ่มตัวแปรอิสระ GDP เข้าไปด้วย เนื่องจากไม่มีข้อมูล GDP รายเดือน ซึ่งเสน่ห์ของการสำรวจภาวะการทำงานของประชากร คือการที่มีจำนวนตัวอย่างประมาณแปดหมื่นครัวเรือนต่อไตรมาส และเป็นการสำรวจที่ดำเนินการเป็นประจำในทุกเดือนต่อเนื่องกันมา ดังนั้น การพยากรณ์การว่างงานรายเดือนอาจใช้ตัวแปรอิสระอื่นเข้ามาทดแทน เพื่ออธิบายถึงความผันแปรของการว่างงานได้ดีขึ้น อีกทั้ง จะเป็นการตรวจสอบ Robustness ของการพยากรณ์ของทั้ง 3 ชุดข้อมูล คือ รายปี รายไตรมาส และรายเดือน จะเป็นการช่วยเพิ่มความน่าเชื่อถือของแบบจำลอง ซึ่งในอนาคตอาจลองใช้แบบจำลอง ARIMA with Structural Break ร่วมกับการอธิบายในมุมมองเชิงโครงสร้างทางเศรษฐศาสตร์ อาจจะช่วยให้อธิบายตัวเลขการว่างงานและภาวะตลาดแรงงานได้ดียิ่งขึ้น

นอกจากนี้ ดร.นครินทร์ อมเรศ ยังมีความเห็นในเรื่องของคำนิยามการสำรวจภาวะการทำงานของประชากร ที่นิยามผู้มีงานทำ คือ ผู้ที่ทำงานมากกว่า 1 ชั่วโมงต่อสัปดาห์ ซึ่งจะแตกต่างกับประเทศในแถบอเมริกา จะเห็นจากการที่บางครั้งเศรษฐกิจไม่ดีหรือ GDP ต่ำ แต่ตัวเลขการว่างงานยังคงต่ำด้วย อาจไม่สะท้อนถึงภาวะเศรษฐกิจของประเทศ

4. Professor Jos Hawleg จาก The Ohio State University ให้ความคิดเห็นในเรื่องของนิยามการสำรวจภาวะการทำงานของประชากร ที่อาจไม่สะท้อนถึงภาวะเศรษฐกิจของประเทศ ซึ่งในการวิเคราะห์ประเด็นเรื่องการว่างงาน มีข้อเสนอว่า อาจมีการรวมผู้ว่างงานบางประเภท (work status) ที่มีผลต่อภาคเศรษฐกิจเข้ามาในการวิเคราะห์ด้วย นอกจากนี้ ยังมีข้อเสนอแนะถึงการวิเคราะห์ประเด็นการว่างงานตามกลุ่มอายุ หรือตามรายภาคอุตสาหกรรม มีความน่าสนใจ และเป็นประโยชน์ต่อผู้กำหนดนโยบายด้านแรงงานของประเทศ

5. ผศ.ดร.ศุภชัย ศรีสุชาติ คณะอนุกรรมการด้านเศรษฐกิจ จากมหาวิทยาลัยธรรมศาสตร์ ให้ความคิดเห็นในเรื่องของจำนวนข้อมูลที่ใช่แบบจำลองว่า การพยากรณ์ข้อมูลอัตราการว่างงานรายปี อาจใช้ข้อมูลการว่างงานรายไตรมาสหรือรายเดือนมาพยากรณ์ เนื่องจากข้อมูลการว่างงานรายไตรมาสหรือรายเดือนมีจำนวนของข้อมูลที่มากกว่า จะช่วยเพิ่มความน่าเชื่อถือของแบบจำลองมากกว่า การใช้ข้อมูลรายปี ซึ่งมีจำนวนข้อมูลทั้งหมด 22 ปี มาพยากรณ์ข้อมูลอัตราการว่างงานใน 5 ปี ข้างหน้า รวมไปถึงการแบ่งข้อมูล Train-Test เพื่อคัดเลือกแบบจำลองที่เหมาะสม จะเห็นว่าการแบ่ง

ข้อมูลรายปีเป็นช่วง Test มีจำนวนข้อมูลเพียงแค่ 2 ปีเท่านั้น อาจทำให้เห็นภาพได้ไม่ชัด การใช้ข้อมูลรายไตรมาสหรือรายเดือนน่าจะมีความเหมาะสมกว่า เนื่องจากจำนวนของข้อมูลที่มากกว่า โดยอาจทดลองเปลี่ยนช่วง Train-Test เป็นในช่วงที่ต่างกัน เพื่อทดสอบความนิ่งของแบบจำลองและผลพยากรณ์ และยังมีข้อแนะนำให้ตรวจสอบถึงการเปลี่ยนแปลงโครงสร้างเศรษฐกิจ (Structural change) เช่น การเกิดน้ำท่วม หรือการปรับค่าจ้างขั้นต่ำ ว่ามีผลต่อการว่างงานหรือไม่ หากมีผลก็ควรรวมปัจจัยเหล่านี้เข้ามาในแบบจำลอง ARIMAX ด้วย นอกจากนี้ ยังมีข้อแนะนำถึงการศึกษาในอนาคตเรื่องของการพยากรณ์การว่างงานรายภาคอุตสาหกรรม (sector) ซึ่งมีความน่าสนใจ และเป็นประโยชน์ต่อภาครัฐสามารถใช้เป็นข้อมูลประกอบการกำหนดนโยบายในตลาดแรงงานได้ดียิ่งขึ้น

6. ศาสตราจารย์ ดร. ภูมิฐาน รังคกุลณวัฒน์ ศาสตราจารย์ ภาควิชาสหกรณ์ คณะเศรษฐศาสตร์ มหาวิทยาลัยเกษตรศาสตร์ ให้ความเห็นตามทฤษฎี โดยแนะนำให้พิจารณาความมีนัยสำคัญทางสถิติของค่าสัมประสิทธิ์ของตัวแปรต่าง ๆ ที่ใส่เข้าไปในแบบจำลอง และให้ลองทดสอบว่าหลังจากที่ใส่ตัวแปรล่าช้า (Lag) ของตัวแปรตามในแบบจำลองแล้ว ยังมีปัญหา Autocorrelation อีกหรือไม่ เนื่องจากตามทฤษฎี แบบจำลองที่ดีที่สุด คือแบบจำลองที่ค่าสัมประสิทธิ์ของตัวแปรต่าง ๆ มีนัยสำคัญ และไม่มี Autocorrelation นอกจากนี้แนะนำให้ดูตัวแปรทางเศรษฐกิจอื่น ๆ ที่ส่งผลกระทบต่ออัตราการว่างงานจากวารสารวิชาการของต่างประเทศ เพื่อให้การพยากรณ์มีความแม่นยำมากขึ้น รวมถึงลองรูปแบบ function อื่น เช่น รูปแบบการ take log รูปแบบยกกำลังสอง เป็นต้น และแนะนำให้ศึกษาอัตราการว่างงานจำแนกตามจังหวัด ภาค และสาขาอุตสาหกรรม เพื่อที่จะได้เห็นปัญหาในแต่ละกลุ่ม และเป็นประโยชน์ต่อการกำหนดนโยบายของประเทศต่อไป

เอกสารอ้างอิง

- Aqil, M., Qureshi, M. A., Ahmed, R. R., and Qadeer, S. (2014). Determinants of Unemployment in Pakistan. *International Journal of Physical and Social Sciences*, 4(4), 676-682.
- Arshad, S. and Ali, A. (no date) Trade-off between inflation, interest and unemployment rate of Pakistan: Revisited, *Bulletin of Business and Economics (BBE)*. Available at: <https://bbejournal.com/index.php/BBE/article/view/260> (Accessed: March 9, 2023).
- Kim et al. (2019) An empirical analysis of Okun's laws in ASEAN using time-varying parameter model, *Physica A: Statistical Mechanics and its Applications*. North-Holland. Available at: <https://www.sciencedirect.com/science/article/abs/pii/S0378437119317339> (Accessed: March 9, 2023).
- Chen, L. X., Chew, Y. B., Lim, R. L. H., Tan, W. Y., & Twe, K. Y. (2017). Macroeconomic factors affecting unemployment rate in China (Doctoral dissertation, UTAR). <http://eprints.utar.edu.my/2542/1/BF-2017-1303383.pdf>
- Econ0952ns abs - Chiang Mai University (no date). Available at: http://cmuir.cmu.ac.th/bitstream/6653943832/11154/2/econ0952ns_abs.pdf (Accessed: March 9, 2023).
- Ellis, C. (2023) When to use Arima models, *Crunching the Data*. Available at: <https://crunchingthedata.com/when-to-use-arima/#:~:text=Advantages%20of%20ARIMA%20models%201%20Well%20understood.%20The,performance.%20...%207%20Can%20handle%20missing%20data.%20> (Accessed: March 9, 2023).
- Gunduz, M. (2020). The Link between Unemployment and Industrial Production: The Fourier Approach with Structural Breaks. *Ekonomicheskie i Sotsialnye Peremeny*, 13(3), 228-240. http://library.vscs.ac.ru/Files/articles/1597039528_228240_eng.pdf
- LOKU, A.F.R.I.M. and DEDA, G.A.Z.M.E.N.D. (no date) UNEMPLOYMENT IN RELATION OF GROWTH POPULATION.
- Sacon, C., & Nunthasen, K. (2022). FACTORS AFFECTING UNEMPLOYMENT IN THAILAND (Doctoral dissertation, Maejo University). <http://202.28.38.45/dspace/bitstream/123456789/892/1/6112304004.pdf>

Yunusova et al. (2021). Unemployment And Factors Affecting Unemployment in Developing Countries.

https://www.researchgate.net/publication/353716157_unemployment_and_factors_affecting_unemployment_in_developing_countries

กรองกาญจน์ และคณะ (2561). การเปรียบเทียบสถิติทดสอบสำหรับสมมติฐานเชิงเส้นในการวิเคราะห์ถดถอย กรณีความคลาดเคลื่อนมีความแปรปรวนไม่คงที่. มหาวิทยาลัยหอการค้าไทย. <https://scholar.utcc.ac.th/bitstream/6626976254/3908/1/0044%20กรองกาญจน์%20สุขพันธ์.pdf>

กฤษฎา สัตย์วินิจ (no date) ความสัมพันธ์ระหว่างอัตราเงินเฟ้อกับอัตราการว่างงานของประเทศไทย. Available at: <https://ir.stou.ac.th/bitstream/123456789/2291/1/130942.pdf> (Accessed: February 25, 2023).

พิพัฒน์ เหลืองนฤมิตชัย (2021) เงินเฟ้อ vs ว่างงาน : Phillips Curve ตายแล้ว?, The 101 World. Available at: <https://www.the101.world/the-end-of-phillips-curve/> (Accessed: March 9, 2023).

สุทิน ชนะบุญ. (2564). สถิติและการวิเคราะห์ข้อมูลในงานวิจัยเบื้องต้น. สำนักงานสาธารณสุขจังหวัดขอนแก่น. <https://www.kkpho.go.th/i2021/index.php/component/attachments/download/1933>

กฤษณี รื่นรมย์. 2548. การพยากรณ์การขาย. กรุงเทพฯ : โรงพิมพ์จุฬาลงกรณ์มหาวิทยาลัย


พิภพ ลลิตตาภรณ์, (2549), การวางแผนและควบคุมการผลิต, พิมพ์ครั้งที่ 12, สมาคมส่งเสริมเทคโนโลยี (ไทย-ญี่ปุ่น), กรุงเทพฯ, 648 หน้า.

ศิริลักษณ์ สุวรรณวงศ์. (2556). เทคนิคการพยากรณ์เชิงปริมาณ : การวิเคราะห์อนุกรมเวลา. นครปฐม : สำนักพิมพ์มหาวิทยาลัยมหิดล.

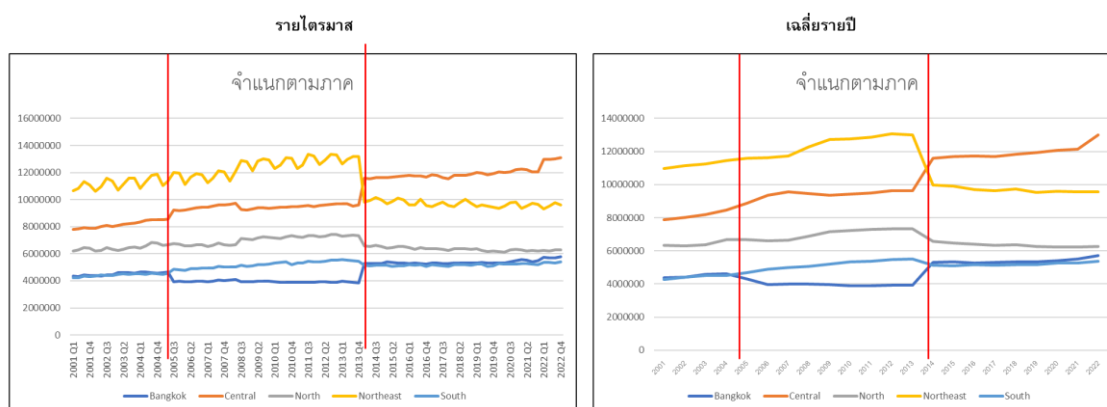
ภาคผนวก

1. Data Exploration

1.1 กำลังแรงงานรวม




ข้อสังเกต ปี 2544 – 2555 กำลังแรงงานรวมมีแนวโน้มเพิ่มขึ้น และตั้งแต่ปี 2557 – 2560 เริ่มมีแนวโน้มลดลง หลังจากนั้นตั้งแต่ปี 2562 เริ่มกลับมามีแนวโน้มเพิ่มขึ้น



ข้อสังเกต กำลังแรงงานรวม จำแนกตามภาค พบว่า ปี 2557 เป็นช่วงจุดเปลี่ยนแนวโน้มที่สลับกันระหว่างภาคตะวันออกเฉียงเหนือกับภาคกลาง และ กทม. กับภาคใต้




ข้อสังเกต กำลังแรงงานรวม จำแนกตามเขตการปกครอง พบว่า ปี 2557 มีการเปลี่ยนแปลงของจำนวนกำลังแรงงานรวม




ข้อสังเกต กำลังแรงงานรวม จำแนกตามภาคอุตสาหกรรม พบว่า ปี 2552 กำลังแรงงานภาคเกษตรกรรมกับภาคบริการฯเริ่มมีแนวโน้มสลับกัน และหลังจากปี 2554 มีความแตกต่างกันมาก


1.2 จำนวนผู้มีงานทำ



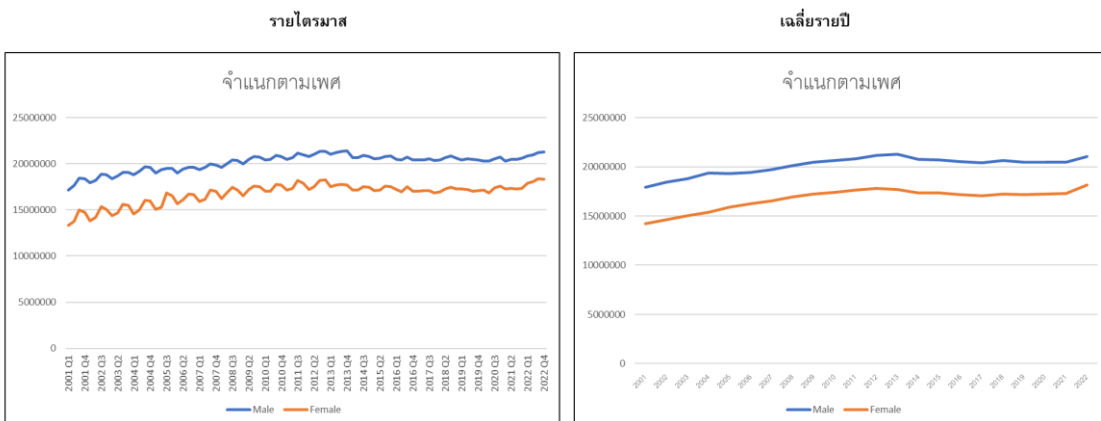
ข้อสังเกต ปี 2544 – 2555 ผู้มีงานทำมีแนวโน้มเพิ่มขึ้น และตั้งแต่ปี 2557 – 2560 เริ่มมีแนวโน้มลดลง หลังจากนั้นตั้งแต่ปี 2562 เริ่มกลับมามีแนวโน้มเพิ่มขึ้น




ข้อสังเกต ผู้มีงานทำ จำแนกตามภาค พบว่า ปี 2557 เป็นช่วงจุดเปลี่ยนแนวโน้มที่สลับกันระหว่างภาคตะวันออกเฉียงเหนือกับภาคกลาง และ กทม. กับภาคใต้ (ปี 2548 ก็เกิดเหตุการณ์ลักษณะนี้)



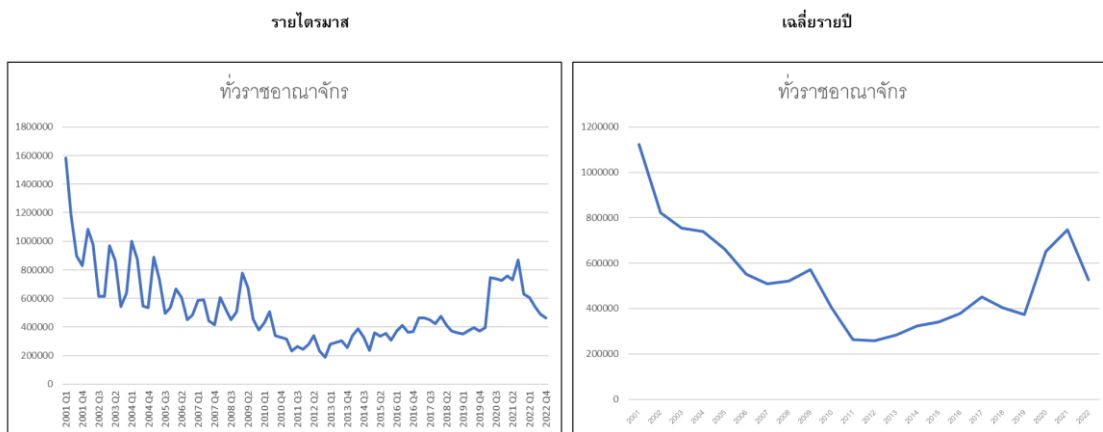
ข้อสังเกต ผู้มีงานทำ จำแนกตามเขตการปกครอง พบว่า ปี 2557 มีการเปลี่ยนแปลงของจำนวนผู้มีงานทำ






ข้อสังเกต ผู้มีงานทำ จําแนกตามภาคอุตสาหกรรม พบว่า ปี 2557 เป็นจุดเปลี่ยนแนวโน้มที่มีความแตกต่างกันมาก


1.3 จำนวนผู้ว่างงาน




ข้อสังเกต ปี 2544 – 2554 มีแนวโน้มลดลง หลังจากปี 2555 – 2560 มีแนวโน้มเพิ่มขึ้นจนถึงช่วง Covid-19




รายไตรมาส




เฉลี่ยรายปี




รายไตรมาส




เฉลี่ยรายปี




รายไตรมาส



เฉลี่ยรายปี




1.4 จำนวนผู้รอดูกาล





ข้อสังเกต ปี 2544 – 2552 มีแนวโน้มลดลงอย่างต่อเนื่อง









1.5 จำนวนผู้อยู่นอกกำลังแรงงาน



ข้อสังเกต ผู้อยู่นอกกำลังแรงงาน จำแนกตามภาค พบว่า ปี 2557 มีความแตกต่างระหว่างภาคตะวันออกเฉียงเหนือกับภาคกลาง



ข้อสังเกต ผู้อยู่นอกกำลังแรงงาน จำแนกตามเขตการปกครอง พบว่า ปี 2557 มีการเปลี่ยนแปลงของจำนวนผู้อยู่นอกกำลังแรงงาน



2. ชุดคำสั่งโปรแกรม R

สำหรับใช้ประมวลผลการพยากรณ์ โดย
สำนักงานสถิติแห่งชาติ

2.1 ชุดคำสั่งการพยากรณ์รายปี

```
data <- Dataset |>
  as_tsibble(index = Year)

#Split Train-Test
train <- data |> filter(Year <= 2020)
test <- data |> filter(Year > 2020 & Year <= 2022
)
```

2.1.1 กำลังแรงงานรวม

```
data |> autoplot(LF)

#Fit Model for Train
fit_train <- train |>
  model(ARIMA(LF ~ COVID+GDPT, stepwise =
FALSE, approx = FALSE))
report(fit_train)

#Residual Check
bind_rows(
  `Regression residuals` =
  as_tibble(residuals(fit_train, type =
"regression")),
  `ARIMA residuals` =
  as_tibble(residuals(fit_train, type =
"innovation")),
  .id = "type"
) |>
mutate(
  type = factor(type, levels=c(
  "Regression residuals", "ARIMA residuals"))
) |>
ggplot(aes(x = Year, y = .resid)) +
  geom_line() +
  facet_grid(vars(type))

fit_train |> gg_tsresiduals()
```

```
augment(fit_train) |>
  features(.innov, ljung_box, dof = 2, lag = 10)

#Forecast Test Data (2020 - 2022)
data_test <- new_data(train, 2) |>
  mutate(COVID = test$COVID, GDPT =
test$GDPT)
fit_train |>
  forecast(new_data = data_test) |>
  autoplot(data) +
  autolayer(fitted(fit_train),col="blue", linewidth
= 0.02) +
  labs(title = "ARIMAX ~ covid + GDPT ", subtitle
= "Train - Test",
  y = "Labourforce")
```

```
#Evaluate Model
#In-sample training accuracy
fit_train |>
  accuracy()
#Out-of-sample forecast accuracy
fit_train |>
  forecast(new_data = data_test) |>
  accuracy(test)

# 100% Data
#Fit Model
fit <- data[-c(23:25),] |>
  model(ARIMA(LF ~ COVID+GDPT, stepwise =
FALSE, approx = FALSE))
report(fit)

#Residual Check
bind_rows(
  `Regression residuals` =
  as_tibble(residuals(fit, type = "regression")),
  `ARIMA residuals` =
  as_tibble(residuals(fit, type = "innovation")),
  .id = "type"
) |>
```

```

mutate(
  type = factor(type, levels=c(
    "Regression residuals", "ARIMA residuals"))
) |>
ggplot(aes(x = Year, y = .resid)) +
geom_line() +
facet_grid(vars(type))

fit |> gg_tsresiduals()

augment(fit) |>
  features(.innov, ljung_box, dof = 1, lag = 10)

#Forecast 2023 - 2025 ARIMAX ~ covid + GDPT
f_GDP <- data |> filter(Year > 2022 & Year <=
2025 )

data_future <- new_data(data[-c(23:25)], 3) |>
  mutate(COVID = f_GDP$COVID, GDPT =
f_GDP$GDPT)
fit |>
  forecast(new_data = data_future) |>
  autoplot(data) +
  autolayer(fitted(fit),col="blue", linewidth =
0.02) +
  labs(title = "ARIMAX ~ covid + GDPT", subtitle
= "Forecast 2023 - 2025",
  y = "Labourforce")

a <- forecast(fit, new_data = data_future)
view(a)

#Evaluate Model
#In-sample training accuracy
fit |>
  accuracy()

2.1.2 จำนวนผู้ว่างงาน
data |> autoplot(UNEM)

```

```

#Fit Model for Train
fit_train <- train |>
  model(ARIMA(UNEM ~ COVID+GDPT, stepwise
= FALSE, approx = FALSE))
report(fit_train)

#Residual Check
bind_rows(
  `Regression residuals` =
  as_tibble(residuals(fit_train, type =
"regression")),
  `ARIMA residuals` =
  as_tibble(residuals(fit_train, type =
"innovation")),
  .id = "type"
) |>
  mutate(
    type = factor(type, levels=c(
      "Regression residuals", "ARIMA residuals"))
  ) |>
  ggplot(aes(x = Year, y = .resid)) +
  geom_line() +
  facet_grid(vars(type))

fit_train |> gg_tsresiduals()

augment(fit_train) |>
  features(.innov, ljung_box, dof = 2, lag = 10)

#Forecast Test Data (2020 - 2022)
data_test <- new_data(train, 2) |>
  mutate(COVID = test$COVID, GDPT =
test$GDPT)
fit_train |>
  forecast(new_data = data_test) |>
  autoplot(data) +
  autolayer(fitted(fit_train),col="blue", linewidth
= 0.02) +
  labs(title = "ARIMAX ~ covid + GDPT ", subtitle
= "Train - Test",
  y = "Unemployment")

```

```

#Evaluate Model
#In-sample training accuracy
fit_train |>
  accuracy()
#Out-of-sample forecast accuracy
fit_train |>
  forecast(new_data = data_test) |>
  accuracy(test)

# 100% Data
#Fit Model
fit <- data[-c(23:25),] |>
  model(ARIMA(UNEM ~ COVID+GDPT, stepwise
= FALSE, approx = FALSE))
report(fit)

#Residual Check
bind_rows(
  `Regression residuals` =
  as_tibble(residuals(fit, type = "regression")),
  `ARIMA residuals` =
  as_tibble(residuals(fit, type = "innovation")),
  .id = "type"
) |>
  mutate(
    type = factor(type, levels=c(
      "Regression residuals", "ARIMA residuals"))
  ) |>
  ggplot(aes(x = Year, y = .resid)) +
  geom_line() +
  facet_grid(vars(type))

fit |> gg_tsresiduals()

augment(fit) |>
  features(.innov, ljung_box, dof = 2, lag = 10)

#Forecast 2023 - 2025 ARIMAX ~ covid + GDPT
f_GDP <- data |> filter(Year > 2022 & Year <=
2025 )

```

```

data_future <- new_data(data[-c(23:25),], 3) |>
  mutate(COVID = f_GDP$COVID, GDPT =
f_GDP$GDPT)
fit |>
  forecast(new_data = data_future) |>
  autoplot(data) +
  autolayer(fitted(fit),col="blue", linewidth =
0.02) +
  labs(title = "ARIMAX ~ covid + GDPT", subtitle
= "Forecast 2023 - 2025",
  y = "Unemployment")

```

```

a <- forecast(fit, new_data = data_future)
view(a)

```

```

#Evaluate Model
#In-sample training accuracy
fit |>
  accuracy()

```

2.1.3 อัตราการว่างงาน

```

data |> autoplot(UNEM_RATE)

```

```

#Fit Model for Train
fit_train <- train |>
  model(ARIMA(UNEM_RATE ~ COVID+GDPT,
stepwise = FALSE, approx = FALSE))
report(fit_train)

```

```

#Residual Check
bind_rows(
  `Regression residuals` =
  as_tibble(residuals(fit_train, type =
"regression")),
  `ARIMA residuals` =
  as_tibble(residuals(fit_train, type =
"innovation")),
  .id = "type"
) |>
  mutate(
    type = factor(type, levels=c(

```



```

    "Regression residuals", "ARIMA residuals"))
  ) |>
  ggplot(aes(x = Year, y = .resid)) +
  geom_line() +
  facet_grid(vars(type))

fit_train |> gg_tsresiduals()

augment(fit_train) |>
  features(.innov, ljung_box, dof = 2, lag = 10)

#Forecast Test Data (2020 - 2022)
data_test <- new_data(train, 2) |>
  mutate(COVID = test$COVID, GDpT =
test$GDpT)
fit_train |>
  forecast(new_data = data_test) |>
  autoplot(data) +
  autolayer(fitted(fit_train),col="blue", linewidth
= 0.02) +
  labs(title = "ARIMAX ~ covid + GDpT", subtitle
= "Train - Test",
  y = "Unemployment Rate")

#Evaluate Model
#In-sample training accuracy
fit_train |>
  accuracy()
#Out-of-sample forecast accuracy
fit_train |>
  forecast(new_data = data_test) |>
  accuracy(test)

# 100% Data
#Fit Model
fit <- data[-c(23:25),]|>
  model(ARIMA(UNEM_RATE ~ COVID+GDpT ,
stepwise = FALSE, approx = FALSE))
report(fit)

```

```

#Residual Check
bind_rows(
  `Regression residuals` =
  as_tibble(residuals(fit, type = "regression")),
  `ARIMA residuals` =
  as_tibble(residuals(fit, type = "innovation")),
  .id = "type"
) |>
  mutate(
    type = factor(type, levels=c(
      "Regression residuals", "ARIMA residuals"))
  ) |>
  ggplot(aes(x = Year, y = .resid)) +
  geom_line() +
  facet_grid(vars(type))

fit |> gg_tsresiduals()

augment(fit) |>
  features(.innov, ljung_box, dof = 0, lag = 10)

#Forecast 2023 - 2025 ARIMAX ~ covid
f_GDP <- data |> filter(Year > 2022 & Year <=
2025 )

data_future <- new_data(data[-c(23:25),], 3) |>
  mutate(COVID = f_GDP$COVID, GDpT =
f_GDP$GDpT)
fit |>
  forecast(new_data = data_future) |>
  autoplot(data) +
  autolayer(fitted(fit),col="blue", linewidth =
0.02) +
  labs(title = "ARIMAX ~ covid + GDpT", subtitle
= "Forecast 2023 - 2025",
  y = "Unemployment Rate")

a <- forecast(fit, new_data = data_future)
view(a)

```

```
#Evaluate Model
#In-sample training accuracy
fit |>
  accuracy()
```

2.2 ชุดคำสั่งการพยากรณ์รายไตรมาส

```
data <- Dataset |>
  mutate(Quarter = yearquarter(Qtr)) |>
  select(-Qtr) |>
  as_tsibble(index = Quarter)

#Split Train-Test

train <- data |> filter(year(Quarter) <= 2020)
test <- data |> filter(year(Quarter) > 2020)
```

2.2.1 กำลังแรงงานรวม

```
data |> autoplot(LF)

#Fit Model for Train
fit_train <- train |>
  model(ARIMA(LF ~ COVID+GDPT_3, stepwise =
FALSE, approx = FALSE))
report(fit_train)

#Residual Check
bind_rows(
  `Regression residuals` =
  as_tibble(residuals(fit_train, type =
"regression")),
  `ARIMA residuals` =
  as_tibble(residuals(fit_train, type =
"innovation")),
  .id = "type"
) |>
  mutate(
    type = factor(type, levels=c(
      "Regression residuals", "ARIMA residuals"))
  ) |>
  ggplot(aes(x = Quarter, y = .resid)) +
```

```
geom_line() +
  facet_grid(vars(type))
```

```
fit_train |> gg_tsresiduals()

augment(fit_train) |>
  features(.innov, ljung_box, dof = 3, lag = 20)

#Forecast Test Data (2020 Q1 - 2022 Q4)
data_test <- new_data(train, 8) |>
  mutate(COVID = test$COVID, GDPT_3 =
test$GDPT_3)
fit_train |>
  forecast(new_data = data_test) |>
  autoplot(data) +
  autolayer(fitted(fit_train),col="blue", linewidth
= 0.02) +
  labs(title = "ARIMAX ~ covid + GDPT_3 ",
  subtitle = "Train - Test",
  y = "Labourforce")
```

```
#Evaluate Model
#In-sample training accuracy
fit_train |>
  accuracy()
#Out-of-sample forecast accuracy
fit_train |>
  forecast(new_data = data_test) |>
  accuracy(test)

# 100% Data

#Fit Model
fit <- data |>
  model(ARIMA(LF ~ COVID+GDPT_3, stepwise =
FALSE, approx = FALSE))
report(fit)
```

```

#Residual Check
bind_rows(
  `Regression residuals` =
    as_tibble(residuals(fit, type = "regression")),
  `ARIMA residuals` =
    as_tibble(residuals(fit, type = "innovation")),
  .id = "type"
) |>
mutate(
  type = factor(type, levels=c(
    "Regression residuals", "ARIMA residuals"))
) |>
ggplot(aes(x = Quarter, y = .resid)) +
  geom_line() +
  facet_grid(vars(type))

```

```
fit |> gg_tsresiduals()
```

```

augment(fit) |>
  features(innov, ljung_box, dof = 2, lag = 20)

```

```
#Forecast 2023 Q1 - 2025 Q4 ARIMAX ~ covid + GDPt
```

```

#Forecast GDP 2023 Q1 - 2025 Q4
fit_GDP <- data |>
  model(ARIMA(GDPt_3, stepwise = FALSE,
approx = FALSE))
report(fit_GDP)

```

```

fit_GDP |>
  forecast(h=12) |>
  autoplot(data) +
  labs(title = "GDP Forecast")
f_GDP <- forecast(fit_GDP, h=12)
view(f_GDP)

```

```

data_future <- new_data(data, 12) |>
  mutate(COVID = 0, GDPt_3 = f_GDP$.mean)
fit |>
  forecast(new_data = data_future) |>
  autoplot(data) +

```

```

  autolayer(fitted(fit),col="blue", linewidth =
0.02) +
  labs(title = "ARIMAX ~ covid + GDPt_3",
subtitle = "Forecast 2023 Q1 - 2025 Q4 ",
y = "Labourforce")

```

```

a <- forecast(fit, new_data = data_future)
view(a)

```

```

#Evaluate Model
#In-sample training accuracy
fit |>
  accuracy()

```

2.2.2 จำนวนผู้ว่างงาน

```
data |> autoplot(UNEM)
```

```
#Fit Model for Train
```

```

fit_train <- train |>
  model(ARIMA(log(UNEM) ~ COVID+GDPt,
stepwise = FALSE, approx = FALSE))
report(fit_train)

```

```
#Residual Check
```

```

bind_rows(
  `Regression residuals` =
    as_tibble(residuals(fit_train, type =
"regression")),
  `ARIMA residuals` =
    as_tibble(residuals(fit_train, type =
"innovation")),
  .id = "type"
) |>
mutate(
  type = factor(type, levels=c(
    "Regression residuals", "ARIMA residuals"))
) |>
ggplot(aes(x = Quarter, y = .resid)) +
  geom_line() +
  facet_grid(vars(type))

```

```

fit_train |> gg_tsresiduals()

augment(fit_train) |>
  features(.innov, ljung_box, dof = 4, lag = 20)

#Forecast Test Data (2020 Q1 - 2022 Q4)
data_test <- new_data(train, 8) |>
  mutate(COVID = test$COVID, GDpT =
test$GDpT)
fit_train |>
  forecast(new_data = data_test) |>
  autoplot(data) +
  autolayer(fitted(fit_train),col="blue", linewidth
= 0.02) +
  labs(title = "ARIMAX ~ covid + GDpT ", subtitle
= "Train - Test",
  y = "Unemployment")

#Evaluate Model
#In-sample training accuracy
fit_train |>
  accuracy()
#Out-of-sample forecast accuracy
fit_train |>
  forecast(new_data = data_test) |>
  accuracy(test)

# 100% Data
#Fit Model
fit <- data |>
  model(ARIMA(log(UNEM) ~ COVID+GDpT,
stepwise = FALSE, approx = FALSE))
report(fit)

#Residual Check
bind_rows(
`Regression residuals` =
  as_tibble(residuals(fit, type = "regression")),
`ARIMA residuals` =
  as_tibble(residuals(fit, type = "innovation")),
.id = "type"
) |>
  mutate(
    type = factor(type, levels=c(
      "Regression residuals", "ARIMA residuals"))
  ) |>
  ggplot(aes(x = Quarter, y = .resid)) +
  geom_line() +
  facet_grid(vars(type))

fit |> gg_tsresiduals()

augment(fit) |>
  features(.innov, ljung_box, dof = 3, lag = 20)

#Forecast 2023 Q1 - 2025 Q4 ARIMAX ~ covid +
GDpT
#Forecast GDP 2023 Q1 - 2025 Q4
fit_GDP <- data |>
  model(ARIMA(GDpT, stepwise = FALSE, approx
= FALSE))
report(fit_GDP)
fit_GDP |>
  forecast(h=12) |>
  autoplot(data) +
  labs(title = "GDP Forecast")
f_GDP <- forecast(fit_GDP, h=12)
view(f_GDP)

data_future <- new_data(data, 12) |>
  mutate(COVID = 0, GDpT = f_GDP$.mean)
fit |>
  forecast(new_data = data_future) |>
  autoplot(data) +
  autolayer(fitted(fit),col="blue", linewidth =
0.02) +
  labs(title = "ARIMAX ~ covid + GDpT", subtitle
= "Forecast 2023 Q1 - 2025 Q4 ",
  y = "Unemployment")

a <- forecast(fit, new_data = data_future)
view(a)

```

```

#Evaluate Model
#In-sample training accuracy
fit |>
  accuracy()

2.2.3 อัตราการว่างงาน
data |> autoplot(UNEM_RATE)

#Fit Model for Train
fit_train <- train |>
  model(ARIMA(log(UNEM_RATE) ~ COVID +
  GDPt, stepwise = FALSE, approx = FALSE))
report(fit_train)

#Residual Check
bind_rows(
  `Regression residuals` =
    as_tibble(residuals(fit_train, type =
"regression")),
  `ARIMA residuals` =
    as_tibble(residuals(fit_train, type =
"innovation")),
  .id = "type"
) |>
mutate(
  type = factor(type, levels=c(
    "Regression residuals", "ARIMA residuals"))
) |>
ggplot(aes(x = Quarter, y = .resid)) +
  geom_line() +
  facet_grid(vars(type))

fit_train |> gg_tsresiduals()

augment(fit_train) |>
  features(innov, ljung_box, dof = 5, lag = 20)

#Forecast Test Data (2020 Q1 - 2022 Q4)
data_test <- new_data(train, 8) |>
  mutate(COVID = test$COVID)
fit_train |>

```

```

forecast(new_data = data_test) |>
  autoplot(data) +
  autolayer(fitted(fit_train),col="blue", linewidth
= 0.02) +
  labs(title = "ARIMAX ~ covid", subtitle = "Train -
Test",
  y = "Unemployment Rate")

```

```

#Evaluate Model
#In-sample training accuracy
fit_train |>
  accuracy()
#Out-of-sample forecast accuracy
fit_train |>
  forecast(new_data = data_test) |>
  accuracy(test)

# 100% Data
#Fit Model
fit <- data |>
  model(ARIMA(log(UNEM_RATE) ~ COVID +
  GDPt, stepwise = FALSE, approx = FALSE))
report(fit)

#Residual Check
bind_rows(
  `Regression residuals` =
    as_tibble(residuals(fit, type = "regression")),
  `ARIMA residuals` =
    as_tibble(residuals(fit, type = "innovation")),
  .id = "type"
) |>
mutate(
  type = factor(type, levels=c(
    "Regression residuals", "ARIMA residuals"))
) |>
ggplot(aes(x = Quarter, y = .resid)) +
  geom_line() +
  facet_grid(vars(type))

fit |> gg_tsresiduals()

```

```

augment(fit) |>
  features(.innov, ljung_box, dof = 3, lag = 20)

#Forecast 2023 Q1 - 2025 Q4 ARIMAX ~ covid +
GDPT
#Forecast GDP 2023 Q1 - 2025 Q4
fit_GDP <- data |>
  model(ARIMA(GDPT, stepwise = FALSE, approx
= FALSE))
report(fit_GDP)
fit_GDP |>
  forecast(h=12) |>
  autoplot(data) +
  labs(title = "GDP Forecast")
f_GDP <- forecast(fit_GDP, h=12)
view(f_GDP)

data_future <- new_data(data, 12) |>
  mutate(COVID = 0, GDPT = f_GDP$.mean)
fit |>
  forecast(new_data = data_future) |>
  autoplot(data) +
  autolayer(fitted(fit),col="blue", linewidth =
0.02) +
  labs(title = "ARIMAX ~ covid + GDPT", subtitle
= "Forecast 2023 Q1 - 2025 Q4 ",
  y = "Unemployment Rate")

a <- forecast(fit, new_data = data_future)
view(a)

#Evaluate Model
#In-sample training accuracy
fit |>
  accuracy()

```

2.3 ชุดคำสั่งการพยากรณ์รายเดือน

```

### Impute missing data ###
library(fpp2)
library(imputeTS)

#Labour Force
LF_ms <- ts(Dataset_LF_UNEM_Forecast_$LF,
frequency=12,start=2002)
LF_data_seadec <- na_seadec(LF_ms)
LF_data_ma <- na_ma(LF_ms)

write.xlsx(LF_data_seadec, file =
"LF_data_impute_seadec.xlsx")
write.xlsx(LF_data_ma, file =
"LF_data_impute_ma.xlsx")

#Unemploy
UNEM_ms <-
ts(Dataset_LF_UNEM_Forecast_$UNEM,
frequency=12,start=2002)
UNEM_data_seadec <- na_seadec(UNEM_ms)
UNEM_data_ma <- na_ma(UNEM_ms)

write.xlsx(UNEM_data_seadec, file =
"UNEM_data_impute_seadec.xlsx")
write.xlsx(UNEM_data_ma, file =
"UNEM_data_impute_ma.xlsx")

#Unemploy Rate
RATE_ms <-
ts(Dataset_UNEM_RATE_Forecast$UNEM_RATE,
frequency=12,start=2002)
RATE_data_seadec <- na_seadec(RATE_ms)
RATE_data_ma <- na_ma(RATE_ms)

write.xlsx(RATE_data_seadec, file =
"RATE_data_impute_seadec.xlsx")
write.xlsx(RATE_data_ma, file =
"RATE_data_impute_ma.xlsx")

```

2.3.1 กำลังแรงงานรวม

```
## Data tsibble ##
library(fpp3)
data_labour <-
Dataset_LF_UNEM_RATE_Forecast |>
  mutate(Mth = yearmonth(Month)) |>
  select(-Month) |>
  as_tsibble(index = Mth)
autoplot(data_labour)

##### ARIMAX #####
fit_labour <- data_labour |>
  model(ARIMA(LF ~ COVID, stepwise = F ,
approx=F))
report(fit_labour)

labour_fc <- new_data(data_labour, 60) |>
  mutate(COVID = 0)

forecast(fit_labour, new_data = labour_fc) |>
  autoplot(data_labour) +
  autolayer(fitted(fit_labour),col="blue",
linewidth = 0.1) +
  labs(title="Labour Force (100%)",
y = "Labour Force")

augment(fit_labour) |>
  features(.innov, ljung_box, dof = 5, lag = 36)

fit_labour |> accuracy()

gg_tsresiduals(fit_labour)

fc_labour <- forecast(fit_labour, new_data =
labour_fc)
View(fc_labour)
View(tail(fitted(fit_labour),12))

## Train Test ##
train_labour <- data_labour |>
  filter_index(~ "2020 Dec")
```

```
test_labour <- data_labour |>
  filter_index("2021 Jan"~.)

fit_train_labour <- train_labour |>
  model(ARIMA(LF ~ COVID, stepwise = F ,
approx=F))
report(fit_train_labour)

fc_test_labour <- new_data(train_labour,24) |>
  mutate(COVID = test_labour$COVID)

forecast(fit_train_labour, new_data =
fc_test_labour) |>
  autoplot(data_labour) +
  autolayer(fitted(fit_train_labour),col="blue",
linewidth = 0.1) +
  labs(title="Labour Force (Train:Test)",
y = "Labour Force")

augment(fit_train_labour) |>
  features(.innov, ljung_box, dof = 4, lag = 36)

fit_train_labour |> accuracy()

fit_train_labour |> forecast(new_data =
fc_test_labour) |>
  accuracy(test_labour)

gg_tsresiduals(fit_train_labour)

fc_t_labour <- forecast(fit_train_labour,
new_data = fc_test_labour)
View(fc_t_labour)
```

2.3.2 จำนวนผู้ว่างาน

```
## Data tsibble ##
library(fpp3)
data <- Dataset_LF_UNEM_RATE_Forecast |>
  mutate(Mth = yearmonth(Month)) |>
```

```

select(-Month) |>
  as_tsibble(index = Mth)
data |> autoplot(UNEM)

##### ARIMAX #####
fit_unem <- data |>
  model(ARIMA(log(UNEM) ~ COVID, stepwise =
F , approx=F))
report(fit_unem)

unem_fc <- new_data(data, 60) |>
  mutate(COVID = 0)

forecast(fit_unem, new_data = unem_fc) |>
  autoplot(data) +
  autolayer(fitted(fit_unem),col="blue", linewidth
= 0.1) +
  labs(title="Unemployment (100%)",
    y = "Unemployment")

augment(fit_unem) |>
  features(.innov, ljung_box, dof = 6, lag = 36)

fit_unem |> accuracy()

gg_tsresiduals(fit_unem)

fc_unem <- forecast(fit_unem, new_data =
unem_fc)
View(fc_unem)
View(tail(fitted(fit_unem),12))

## Train Test ##
train_unem <- data |>
  filter_index(~ "2020 Dec")
test_unem <- data |>
  filter_index("2021 Jan"~.)

fit_train_unem <- train_unem |>
  model(ARIMA(log(UNEM) ~ COVID, stepwise =
F , approx=F))

```

```

report(fit_train_unem)

fc_test_unem <- new_data(train_unem,24) |>
  mutate(COVID = test_unem$COVID)

forecast(fit_train_unem, new_data =
fc_test_unem) |>
  autoplot(data) +
  autolayer(fitted(fit_train_unem),col="blue",
linewidth = 0.1) +
  labs(title="Unemployment Train:Test",
    y = "Unemployment")

augment(fit_train_unem) |>
  features(.innov, ljung_box, dof = 6, lag = 36)

fit_train_unem |> accuracy()

fit_train_unem |> forecast(new_data =
fc_test_unem) |>
  accuracy(test_unem)

gg_tsresiduals(fit_train_unem)

fc_t_unem <- forecast(fit_train_unem,
new_data = fc_test_unem)
View(fc_t_unem)

```

2.3.3 อัตราการว่างงาน

```

## Data tsibble ##
library(fpp3)
data <- Dataset_LF_UNEM_RATE_Forecast |>
  mutate(Mth = yearmonth(Month)) |>
  select(-Month) |>
  as_tsibble(index = Mth)
data |> autoplot(UNEM_RATE)

##### ARIMAX #####
fit_rate <- data |>

```



```

model(ARIMA(log(UNEM_RATE) ~ COVID,
stepwise = F , approx=F))
report(fit_rate)

rate_fc <- new_data(data, 60) |>
mutate(COVID = 0)

forecast(fit_rate, new_data = rate_fc) |>
autoplot(data) +
autolayer(fitted(fit_rate),col="blue", linewidth =
0.1) +
labs(title="Unemployment RATE (100%)",
y = "Unemployment RATE")

augment(fit_rate) |>
features(.innov, ljung_box, dof = 6, lag = 36)

fit_rate |> accuracy()

fit_rate |> gg_tsresiduals(fit_rate)

fc_rate <- forecast(fit_rate, new_data = rate_fc)
View(fc_rate)
View(tail(fitted(fit_rate),12))

## Train Test ##
train_rate <- data |>
filter_index(~ "2020 Dec")
test_rate <- data |>
filter_index("2021 Jan"~.)

fit_train_rate <- train_rate |>
model(ARIMA(log(UNEM_RATE) ~ COVID,
stepwise = F , approx=F))
report(fit_train_rate)

fc_test_rate <- new_data(train_rate,24) |>
mutate(COVID = test_rate$COVID)

forecast(fit_train_rate, new_data = fc_test_rate)
|>
autoplot(data) +
autolayer(fitted(fit_train_rate),col="blue",
linewidth = 0.1) +
labs(title="Unemployment RATE Train:Test",
y = "Unemployment RATE")

augment(fit_train_rate) |>
features(.innov, ljung_box, dof = 6, lag = 36)

fit_train_rate |> accuracy()

fit_train_rate |> forecast(new_data =
fc_test_rate) |>
accuracy(test_rate)

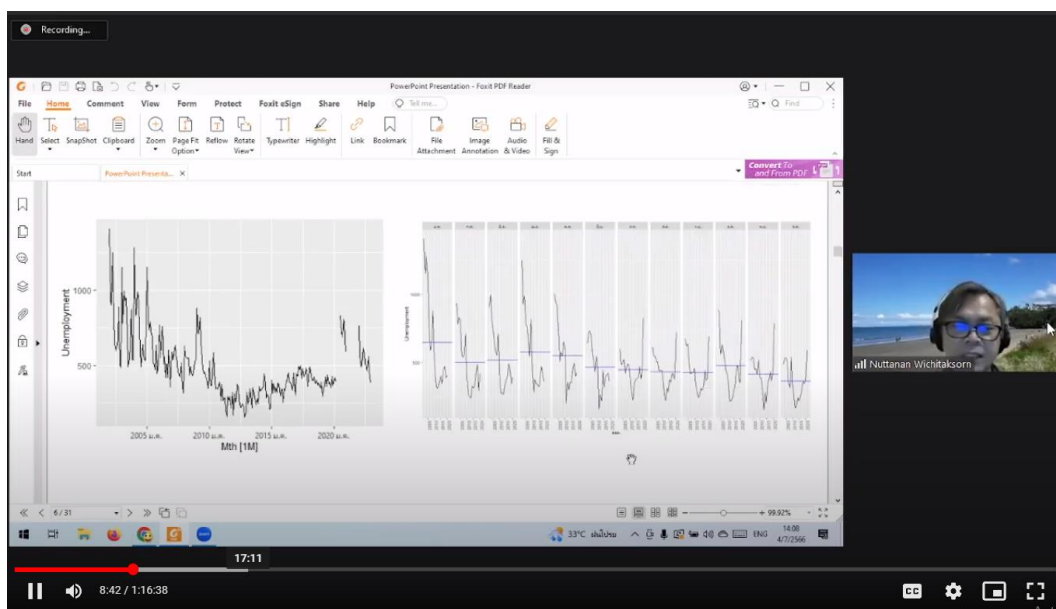
gg_tsresiduals(fit_train_rate)

fc_t_rate <- forecast(fit_train_rate, new_data =
fc_test_rate)
View(fc_t_rate)

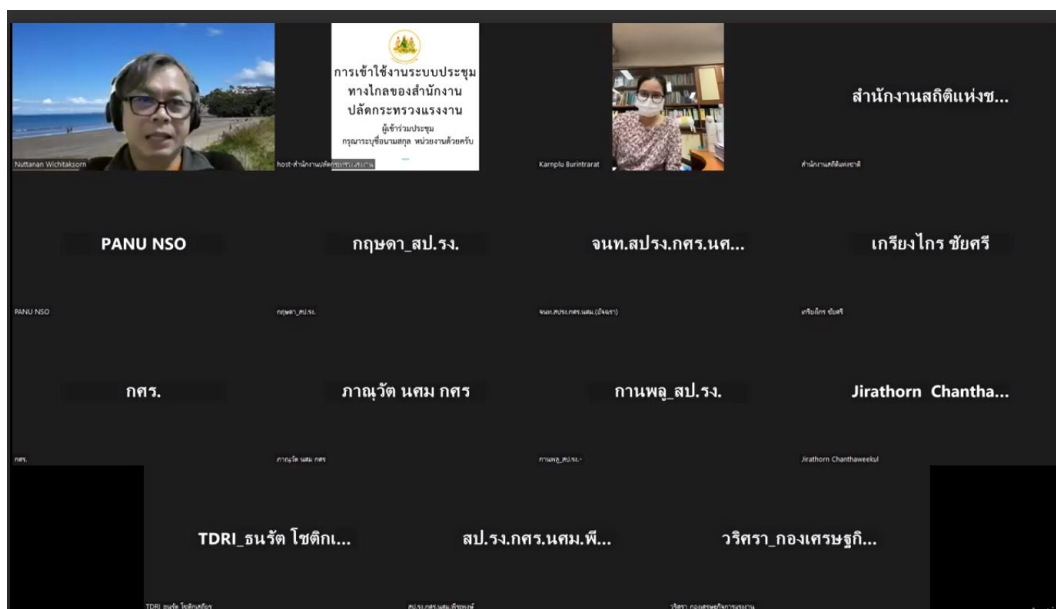
```

3. การประชุม

3.1 การอบรมเชิงปฏิบัติการจัดทำชุดข้อมูลการคาดการณ์อัตราการว่างงานของประเทศไทย (Forecast Unemployment Rate) ครั้งที่ 1 (วันอังคารที่ 4 กรกฎาคม พ.ศ. 2566) ผ่านระบบ Zoom Meeting โดย ดร.ณัฐนันท์ วิจิตรอักษร



3.2 การอบรมเชิงปฏิบัติการจัดทำชุดข้อมูลการคาดการณ์อัตราการว่างงานของประเทศไทย (Forecast Unemployment Rate) ครั้งที่ 2 (วันอังคารที่ 11 กรกฎาคม พ.ศ. 2566) ผ่านระบบ Zoom Meeting โดย ดร.ณัฐนันท์ วิจิตรอักษร



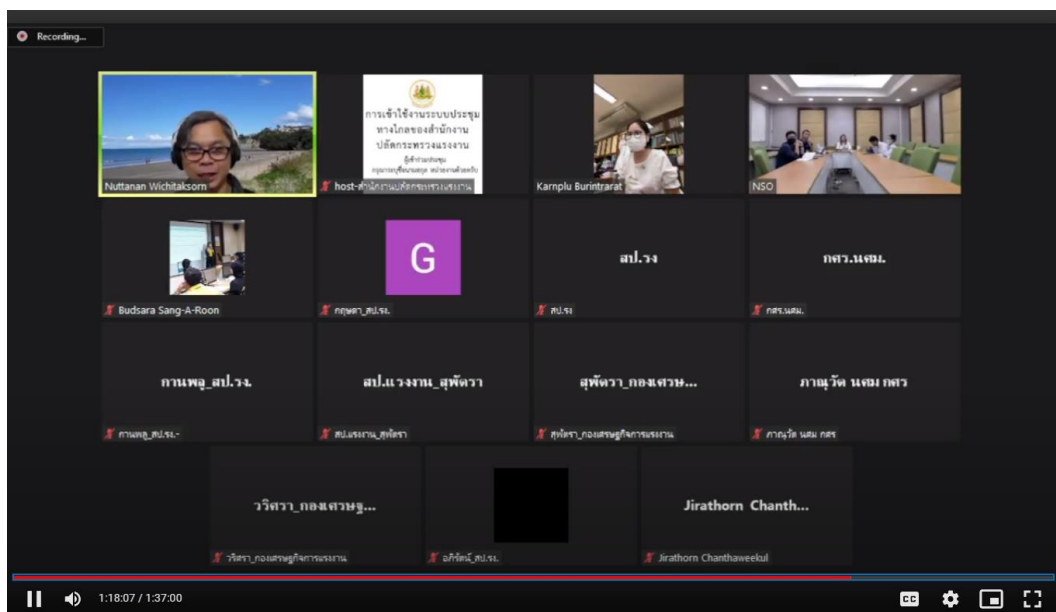
Unemployed Person - Model Selection

ARIMA(1,1,3)(0,0,1) and Auto

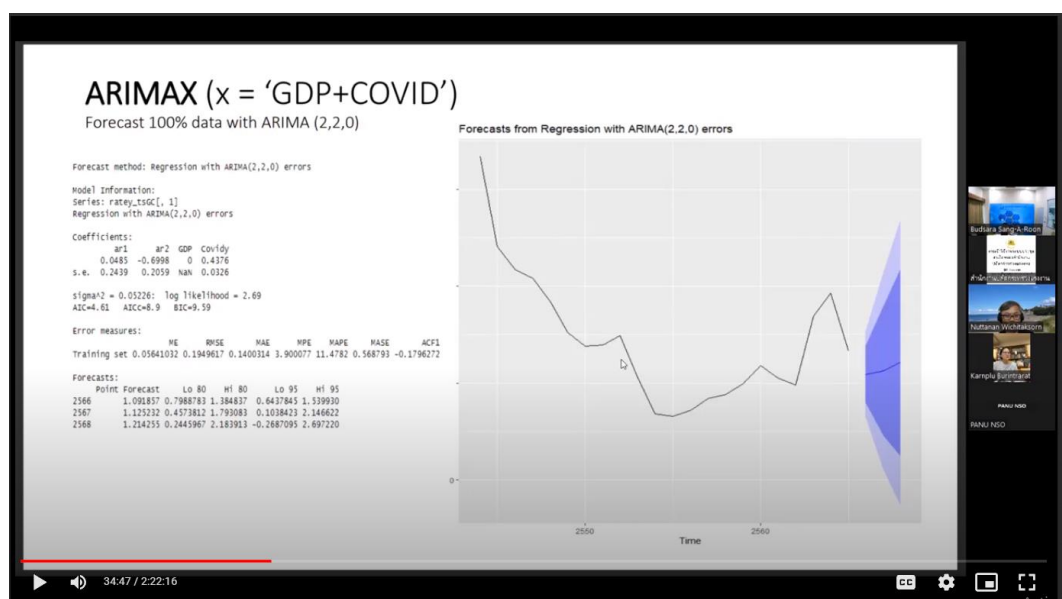
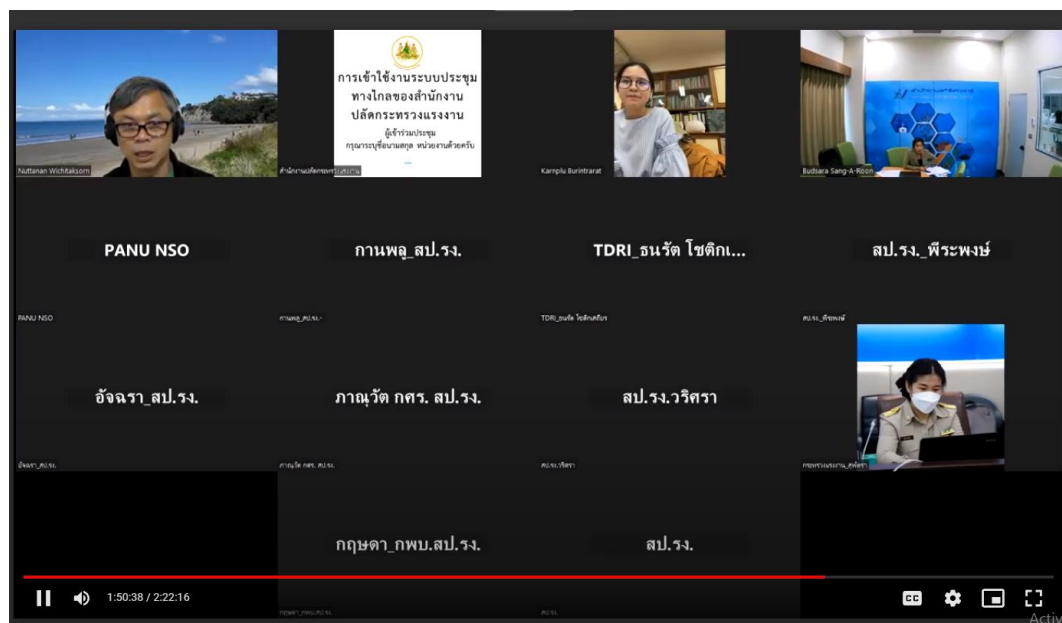
ARIMA(1,1,3)	ME	RMSE	MAE	MPE	MAPE	MASE	ACF1	Theil's U
Training set	4652.198	84397.87	59793.43	-1.039813	14.53515	0.7004784	0.0686495	NA
Test set	-334655.36	382615.02	334655.35	-60.69556	60.69556	3.9204782	0.5997607	5.067483
ARIMA(1,1,3)(0,0,1)(4)	ME	RMSE	MAE	MPE	MAPE	MASE	ACF1	Theil's U
Training set	2885.517	81355.21	60845.92	-1.523268	15.09788	0.7128083	0.00669906	NA
Test set	-168794.14	220065.23	187157.7	-32.174974	34.37444	2.1925473	0.48176922	2.974212
ARIMA(1,1,3)(0,1,1)(4)	ME	RMSE	MAE	MPE	MAPE	MASE	ACF1	Theil's U
Training set	10003.43	76211.88	49989.25	1.162131	12.47165	0.5856227	-0.014768	NA
Test set	-258721.48	323561.19	260769.63	-48.613501	48.84858	3.054909	0.58463419	4.408886
ARIMA(0,1,0)(1,0,1)(4)	ME	RMSE	MAE	MPE	MAPE	MASE	ACF1	Theil's U
Training set	5710.842	78266.4	54821.01	-0.0771191	13.46766	0.6422266	-0.0531572	NA
Test set	-233827.62	296571.1	240472.77	-44.186192	44.95978	2.8171318	0.57400043	4.046934

16

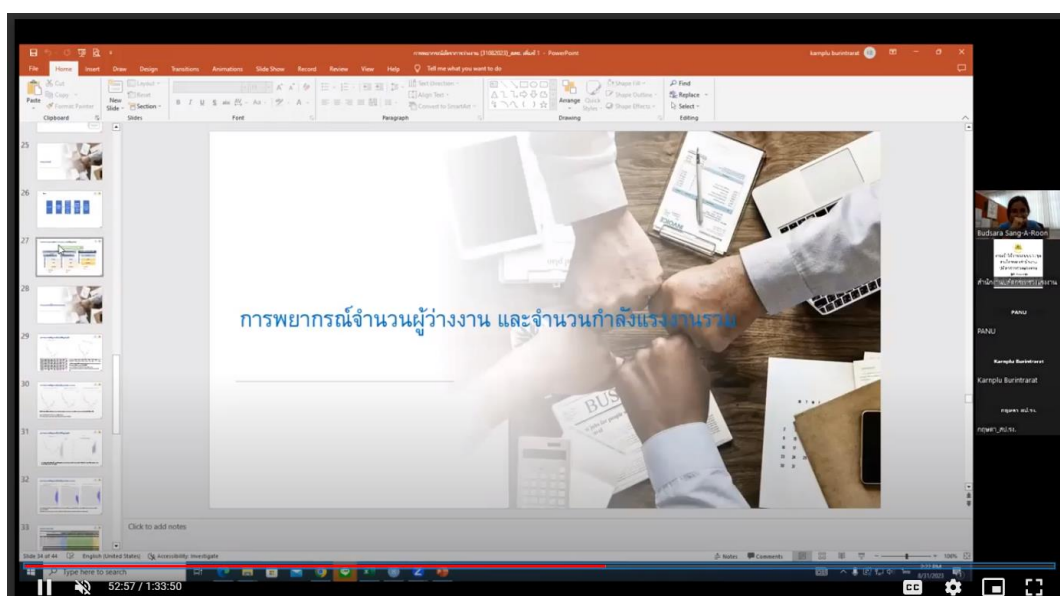
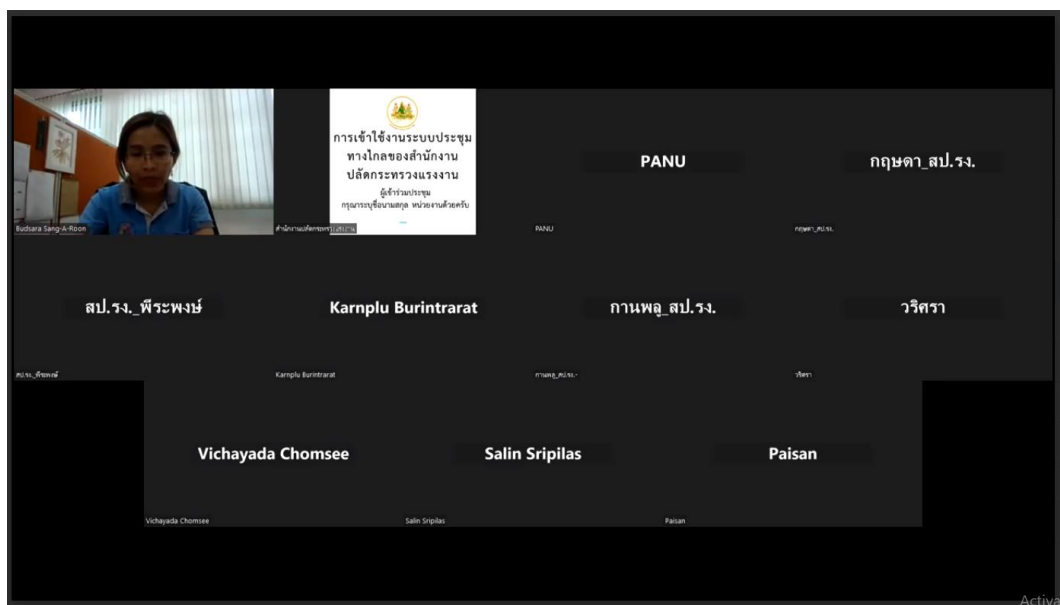
3.3 การอบรมเชิงปฏิบัติการจัดทำชุดข้อมูลการคาดการณ์อัตราการว่างงานของประเทศไทย (Forecast Unemployment Rate) ครั้งที่ 3 (วันจันทร์ที่ 24 กรกฎาคม พ.ศ. 2566) ผ่านระบบ Zoom Meeting โดย ดร.ณัฐนันท์ วิจิตรอักษร



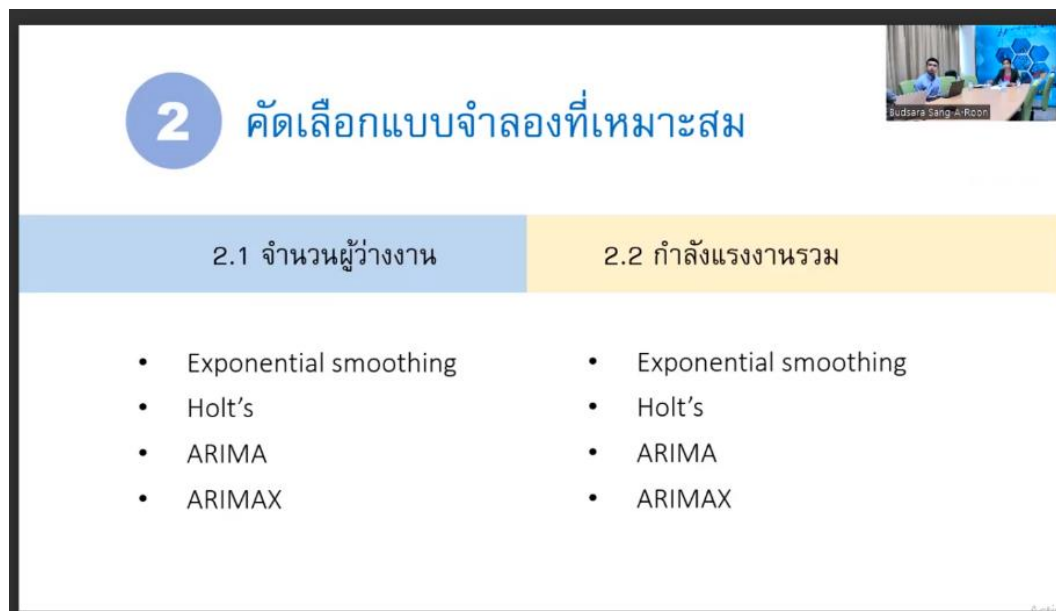
3.4 การอบรมเชิงปฏิบัติการจัดทำชุดข้อมูลการคาดการณ์อัตราการว่างงานของประเทศไทย (Forecast Unemployment Rate) ครั้งที่ 4 (วันพฤหัสบดีที่ 24 สิงหาคม พ.ศ. 2566) ผ่านระบบ Zoom Meeting โดย ดร.ณัฐนันท์ วิจิตรอักษร



3.5 การอบรมเชิงปฏิบัติการจัดทำชุดข้อมูลการคาดการณ์อัตราการว่างงานของประเทศไทย (Forecast Unemployment Rate) ครั้งที่ 5 (วันพฤหัสบดีที่ 31 สิงหาคม พ.ศ. 2566) ผ่านระบบ Zoom Meeting โดย ดร.ณัฐนันท์ วิจิตรอักษร



3.6 การประชุมผู้ทรงคุณวุฒิให้ข้อเสนอแนะต่อผลค่าคาดการณ์อัตราการว่างงานของประเทศไทย (Forecast Unemployment Rate)



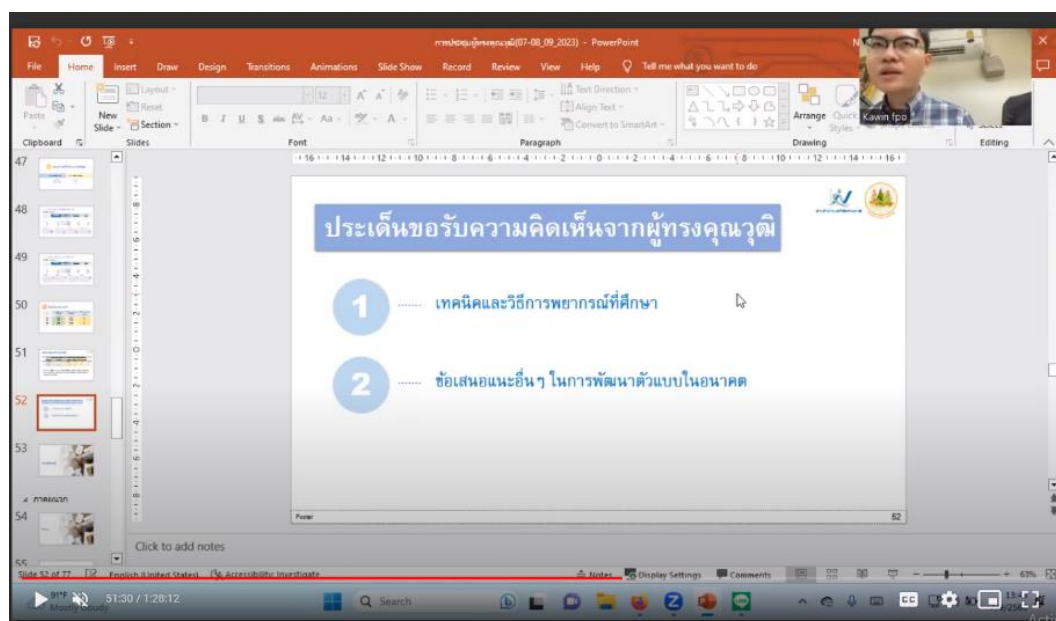
2 เลือกแบบจำลองที่เหมาะสม

2.1 จำนวนผู้ว่างงาน

- Exponential smoothing
- Holt's
- ARIMA
- ARIMAX

2.2 กำลังแรงงานรวม

- Exponential smoothing
- Holt's
- ARIMA
- ARIMAX



ประเด็นขอรับความคิดเห็นจากผู้ทรงคุณวุฒิ

- เทคนิคและวิธีการพยากรณ์ที่ศึกษา
- ข้อเสนอแนะอื่นๆ ในการพัฒนาตัวแบบในอนาคต

52



Nakarin Amarase_...

