

# ECONOMIC PULSE

การประมาณการ GDP ด้วยการใช้ Machine Learning  
จากข้อมูลภาพถ่ายแสงไฟยามค่ำคืน

(A Machine Learning Approach to Measure Quarterly Economic Growth  
from Nighttime Light Data)

ปุณณิ บุญชูช่วย


ข้อคิดเห็นที่ปรากฏในบทความนี้เป็นความเห็นของผู้เขียน  
ซึ่งไม่จำเป็นต้องสอดคล้องกับความเห็นของธนาคารแห่งประเทศไทย

Issue 2

August 22, 2023

**การประมาณการ GDP ด้วยการ ใช้ Machine Learning จากข้อมูลภาพถ่ายแสงไฟยามค่ำคืน**  
(A Machine Learning Approach to Measure Quarterly Economic Growth from Nighttime Light Data)

ผู้เขียน: ปุณณ์ บุญช่วย



"ข้อมูลภาพถ่ายแสงไฟยามค่ำคืน  
สามารถวัดกิจกรรม  
ทางเศรษฐกิจ และประมาณการ  
GDP โดยเฉพาะอย่างยิ่ง GDP  
ภาคบริการ ได้อีกด้วย"

**บทคัดย่อ**

บทความนี้นำเสนอวิธีการประมาณการอัตราการขยายตัวของ GDP จากการใช้ข้อมูลภาพถ่ายดาวเทียม 2 มิติที่แสดงแสงไฟยามค่ำคืนขององค์การบริหารการบินและอวกาศแห่งชาติสหรัฐฯ (National Aeronautics and Space Administration: NASA) ด้วยการ ใช้เทคนิค Machine Learning เนื่องจากความสว่างของแสงไฟยามค่ำคืนสะท้อนการแพร่กระจายหรือการกระจุกตัวของปริมาณกิจกรรมทางเศรษฐกิจที่เกิดขึ้นในบริเวณใดบริเวณหนึ่งได้ดี โดยเฉพาะพื้นที่โล่งหรือกลางแจ้ง โดยผลการศึกษาแสดงให้เห็นว่าวิธีการทาง Machine Learning สามารถประมาณการ GDP รวม และ GDP ภาคบริการ จากข้อมูลภาพถ่ายแสงไฟยามค่ำคืนได้แม่นยำมากกว่าวิธีทางสถิติ เช่น แบบจำลอง ARIMA

**1. บทนำ**

ผลิตภัณฑ์มวลรวมในประเทศ (Gross Domestic Product: GDP) เป็นตัวเลขทางเศรษฐกิจที่สำคัญ ซึ่งในปัจจุบันประเทศไทยใช้ข้อมูล GDP ที่จัดทำและเผยแพร่โดยสำนักงานสภาพัฒนาการเศรษฐกิจและสังคมแห่งชาติ (สศช.) ในการติดตามและประเมินภาวะเศรษฐกิจ อย่างไรก็ตาม ข้อมูล GDP มีกำหนดการเผยแพร่เป็นรายไตรมาส และมีความล่าช้าประมาณ 7 สัปดาห์หลังจากวันสิ้นสุดไตรมาส ทำให้หน่วยงานภาครัฐและเอกชนมีความจำเป็นที่จะต้องใช้เครื่องชี้เศรษฐกิจอื่น ๆ หรือใช้การประมาณการเศรษฐกิจจากข้อมูลเศรษฐกิจมหภาค เช่น ความเชื่อมั่นของผู้ประกอบการและธุรกิจ (Business Sentiment Index: BSI) เพื่อช่วยให้สามารถประเมินภาพเศรษฐกิจได้อย่างทันต่่วงที และตัดสินใจดำเนินนโยบายต่าง ๆ ได้อย่างถูกต้องและทันต่อสถานการณ์

อย่างไรก็ดี การประมาณการเศรษฐกิจจากข้อมูลเศรษฐกิจมหภาคมีความท้าทาย เนื่องจากต้องใช้ข้อมูลหลายชนิดในการประมาณการ ซึ่งข้อมูลเหล่านั้นต้องนำมาจากหลายแหล่ง และหากมีข้อมูลใดข้อมูลหนึ่งที่หยุดเผยแพร่หรือเผยแพร่ล่าช้าจากการเก็บข้อมูล การประมาณการ GDP อาจแม่นยำน้อยลงได้ซึ่งส่งผลกระทบต่อ การดำเนินนโยบาย โดยเฉพาะอย่างยิ่งในช่วงวิกฤติ เช่น การแพร่ระบาดของโควิด 19

ในช่วงที่ผ่านมา หนึ่งในข้อมูลที่ได้รับ ความสนใจในการนำมาช่วยติดตามกิจกรรมทางเศรษฐกิจ ได้แก่ ข้อมูลภาพถ่ายแสงไฟในเวลากลางคืน<sup>1</sup> โดยมีงานวิจัยในต่างประเทศหลายชิ้นที่พยายามหาความสัมพันธ์ระหว่าง ความสว่างของแสงไฟยามค่ำคืนกับกิจกรรมทางเศรษฐกิจรายไตรมาส อาทิ งานวิจัยของกองทุนการเงินระหว่าง ประเทศ (International Monetary Fund: IMF) Beyer et al. (2022) ที่ประมาณการว่าอัตราการเติบโตของ GDP 1% ส่งผลให้ค่าความสว่างของแสงไฟยามค่ำคืนเติบโตประมาณ 1.55% และงานวิจัยของ Henderson et al. (2012) พบว่าหากนำค่าประมาณการอัตราการเติบโตทางเศรษฐกิจจากข้อมูลแสงไฟยามค่ำคืนไปหาค่าเฉลี่ยกับ ค่าที่คำนวณได้จากวิธีการทางสถิติดั้งเดิม จะทำให้ประมาณการได้ใกล้เคียงกับข้อมูลจริงมากยิ่งขึ้น สำหรับในไทยเอง Chaiwat (2016) พบว่าค่าความสว่างของแสงไฟยามค่ำคืนของประเทศไทยที่เติบโต 1% ส่งผลให้มูลค่าผลิตภัณฑ์มวลรวมรายจังหวัด (Gross Provincial Products: GPP) เติบโตไปในทิศทางเดียวกันถึง 0.77%

เนื่องจากข้อมูลภาพถ่ายแสงไฟยามค่ำคืนมีความสัมพันธ์กับกิจกรรมทางเศรษฐกิจ ข้อมูลนี้จึงน่าจะมี ประโยชน์ในการประมาณการ GDP ดังนั้นงานศึกษานี้จึงนำข้อมูลภาพถ่ายแสงไฟยามค่ำคืนที่แสดงค่าความสว่าง ในแต่ละพื้นที่ของประเทศมาประมาณการ GDP โดยใช้วิธีการทาง Computer Vision ซึ่งเป็นแขนงหนึ่งใน Machine Learning (ML) ในการใช้ประโยชน์จากข้อมูลภาพถ่ายแสงไฟยามค่ำคืนให้ได้มากที่สุด และนำ ค่าประมาณการมาเปรียบเทียบกับผลจากแบบจำลองทางสถิติ ARIMA ที่ปกติสามารถประมาณการได้ดี

## 2. ข้อมูลที่ใช้ในการศึกษา

**2.1 ผลิตภัณฑ์มวลรวมในประเทศ (Gross Domestic Product หรือ GDP):** หมายถึงมูลค่าของสินค้าและ บริการขั้นสุดท้ายที่ผลิตขึ้นภายในประเทศ ณ ช่วงเวลาหนึ่ง ๆ โดยข้อมูลที่น่ามาใช้เป็นข้อมูล GDP รายไตรมาส จาก สศช. และนำมาคำนวณหาอัตราการขยายตัวจากช่วงเดียวกันปีก่อน (%YoY) เพื่อจัดผลของฤดูกาล

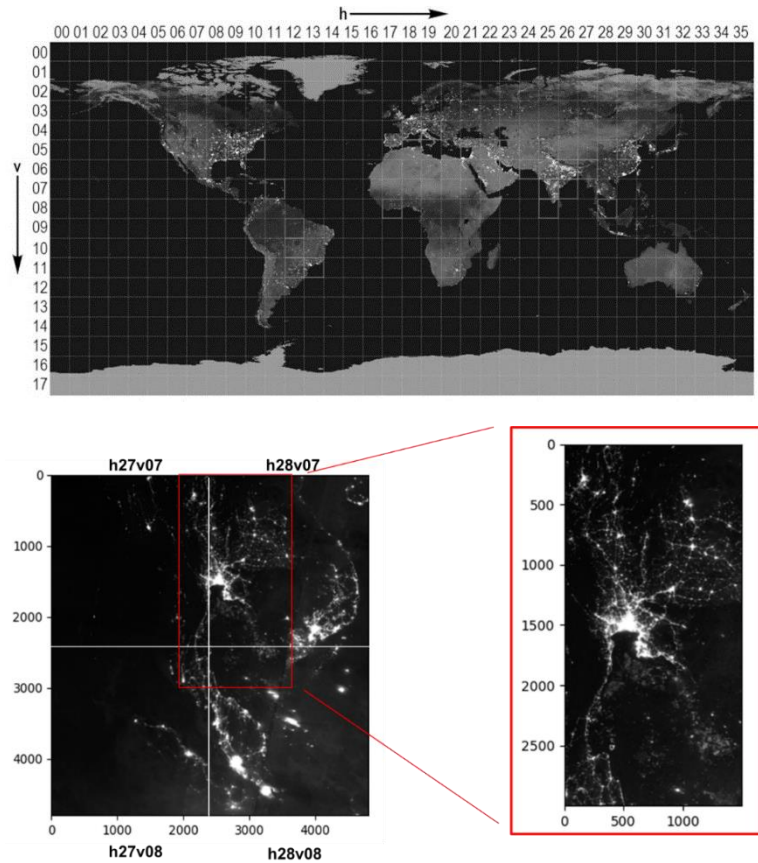
**2.2 แสงไฟยามค่ำคืน (Nighttime Light):** เป็นข้อมูลความสว่างที่อยู่ในรูปแบบของภาพถ่ายซึ่งมีความถี่ เป็นรายวัน และเริ่มมีข้อมูลตั้งแต่วันที่ 19 มกราคม 2012 จนถึงปัจจุบัน โดยชื่อของชุดข้อมูลที่ใช้คือ VNP46A1 (VIIRS/NPP Daily Gridded Day Night Band 500m Linear Lat Lon Grid Night) ซึ่งเผยแพร่บนเว็บไซต์ MODAPS (Moderate Resolution Imaging Spectroradiometer Adaptive Processing System) ของ NASA โดยข้อมูลที่น่ามาใช้คือ DNB\_At\_Sensor\_Radiance\_500m ซึ่งคือค่าความสว่าง ณ จุดใดจุดหนึ่ง วัตต์เป็นจำนวนเต็มตั้งแต่ 0 ถึง 65534 หน่วยเป็นนาโนวัตต์ต่อตารางเซนติเมตรต่อสเตอเรเดียน โดย 0 หมายถึง ไม่มีความสว่างเลย และ 65534 หมายถึงมีความสว่างมากที่สุด

ข้อมูลภาพถ่ายที่ได้มานั้นใช้พิกัดทางภูมิศาสตร์ในการระบุตำแหน่งว่าภาพถ่ายอยู่ในบริเวณใด โดยทั้งโลก จะมีไฟล์ภาพถ่ายทั้งหมด 648 ไฟล์ (18 (v00 ถึง v17) x 36 (h00 ถึง h35)) โดยประเทศไทยตั้งอยู่ในพื้นที่ ทั้งหมด 4 ไฟล์ ได้แก่ h27v07, h28v07, h27v08 และ h28v08 (ดังแสดงในภาพที่ 1) ซึ่งใน 4 ไฟล์นี้ บริเวณ ที่เป็นแสงไฟของประเทศไทยจะอยู่ใน Array 2 มิติขนาด 3000 x 1500 pixel โดยสามารถนำภาพถ่ายในแต่ละ

<sup>1</sup> ข้อมูลแสงไฟยามค่ำคืนแม้มีความสัมพันธ์กับกิจกรรมทางเศรษฐกิจ แต่ยังมีข้อจำกัดบางประการ ได้แก่ (1) แสงไฟในบางบริเวณ เช่น ร้านค้า ห้างสรรพสินค้า ถนน หรือโรงงาน เปิดใช้งานตลอดเวลาแม้จะมีหรือไม่มีกิจกรรมทางเศรษฐกิจ (2) ไม่สามารถสะท้อนกิจกรรมทางเศรษฐกิจที่เกิดขึ้นในช่วง กลางวัน (3) สภาพอากาศหรือแสงสะท้อนจากก้อนเมฆอาจทำให้ค่าความสว่างที่วัดได้เกิดความคลาดเคลื่อน

วันมาเฉลี่ยหาค่าความสว่างของแต่ละ pixel เพื่อทำเป็นภาพถ่ายความสว่างเฉลี่ยของแสงไฟยามค่ำคืนค่าคืนรายไตรมาส และนำค่าความสว่างในแต่ละ pixel ของภาพถ่ายรายไตรมาสไปคำนวณหาค่า growth (%YoY)

ภาพที่ 1 ความสว่างของแสงไฟจากภาพถ่ายดาวเทียมทั่วโลก (รูปบน) และประเทศไทย (รูปล่าง)




หมายเหตุ: สีขาวหมายถึงค่าความสว่างของแสงไฟสูง และสีดำหมายถึงค่าสว่างของแสงไฟต่ำ  
ที่มา: ดัดแปลงจาก Román et al. (2019) และการทำ data visualization ของข้อมูล VNP46A1

จากการวิเคราะห์ข้อมูลแสงไฟยามค่ำคืนค่าคืนของไทย **ข้อเท็จจริง (Stylized Facts) ที่สำคัญ** มีดังนี้

1. ค่าความสว่างของแสงไฟยามค่ำคืนค่าคืนมีความสัมพันธ์กับกิจกรรมทางเศรษฐกิจ เพราะกิจกรรมทางเศรษฐกิจมักจะมีกระจุกตัวมากในเขตเมืองซึ่งมีแสงไฟที่มนุษย์สร้างขึ้นมากกว่าพื้นที่ในชนบท โดยไตรมาสที่ 3 ของปี 2019 (ก่อนการแพร่ระบาดของโควิด 19) ที่มีค่าความสว่างรวมทั้งประเทศ = 126.5 ล้านนาโนวัตต์ต่อตารางเซนติเมตรต่อสเทอเรเดียน สว่างมากกว่าไตรมาสที่ 2 ของปี 2020 (ช่วงการแพร่ระบาดระลอกแรก) ที่มีค่าความสว่างรวมทั้งประเทศ = 107.9 ล้านนาโนวัตต์ต่อตารางเซนติเมตรต่อสเทอเรเดียน สอดคล้องกับกิจกรรมทางเศรษฐกิจที่ลดลงในช่วง lockdown และ GDP ที่ลดลง และในไตรมาสที่ 1 ของปี 2023 ความสว่างรวมทั้งประเทศได้เพิ่มกลับขึ้นมาที่ 125.2 ล้านนาโนวัตต์ต่อตารางเซนติเมตรต่อสเทอเรเดียน สอดคล้องกับกิจกรรมทางเศรษฐกิจที่ฟื้นตัว
2. แสงไฟยามค่ำคืนสามารถใช้เพื่อวัดการกระจายเชิงพื้นที่ของกิจกรรมทางเศรษฐกิจได้ ด้วยการระบุ clusters ของกิจกรรมทางเศรษฐกิจภายในจังหวัดหรือภูมิภาค ทำให้ข้อมูลชุดนี้สามารถนำมาใช้ศึกษาทำความเข้าใจการกระจายเชิงพื้นที่ของการเติบโตทางเศรษฐกิจและกำหนดนโยบายที่จำเพาะต่อการส่งเสริมการเติบโตทางเศรษฐกิจในพื้นที่ใดพื้นที่หนึ่งได้ดียิ่งขึ้น (ดังแสดงในภาพที่ 2)

ภาพที่ 2 ความสว่างของแสงไฟยามค่ำคืบจากภาพถ่ายดาวเทียมในประเทศไทยของพื้นที่ต่าง ๆ <sup>2</sup>



ที่มา: จากการทำ data visualization ของข้อมูล VNP46A1

### 3. การประมาณค่า GDP

#### 3.1 แบบจำลอง

วิธีประมาณการ GDP ในบทความนี้ใช้ 2 วิธี ได้แก่ (1) Machine Learning (ML) และ (2) แบบจำลองทางสถิติ Autoregressive Integrated Moving Average (ARIMA) โดยจะนำผลลัพธ์จากทั้งสองวิธีมาเปรียบเทียบกันเพื่อประเมินว่าข้อมูลภาพถ่ายแสงไฟยามค่ำคืบที่ถูกนำมาประมวลผลด้วยแบบจำลอง ML สามารถช่วยเพิ่มความแม่นยำในการประมาณการ GDP ได้ดีเพียงใด โดยใช้ข้อมูลทั้งหมด 41 ไตรมาส คือ ตั้งแต่ไตรมาสที่ 1 ของปี 2013 ซึ่งเป็นไตรมาสแรกที่มีข้อมูล จนถึงไตรมาสที่ 1 ของปี 2023 และนอกจากการประมาณการ GDP รวมแล้ว ยังประมาณการ GDP ในหมวดภาคบริการที่น่าจะมีความสัมพันธ์กับแสงไฟยามค่ำคืบสูงด้วย

**(1) ML:** เป็นเครื่องมือทาง Computer Vision<sup>3</sup> ที่ดัดแปลงมาจากแบบจำลอง VGG-16 Convolutional Neural Network (CNN)<sup>4</sup> ซึ่งเป็น algorithm ในสาขา Deep Learning ที่ใช้รูปภาพเป็น input และให้ค่าสัมประสิทธิ์ที่แสดงถึงความสำคัญ (learnable weights and biases) ต่อลักษณะและรายละเอียดของบริเวณต่าง ๆ ในรูปภาพ ซึ่งเป็นแบบจำลองที่สามารถเรียนรู้ได้ผ่านการใส่ input ปริมาณมาก ๆ และเรียนรู้ซ้ำ ๆ หลายรอบ เพื่อให้ได้ผลลัพธ์ที่ใกล้เคียงค่าที่ถูกต้องมากที่สุด ซึ่งจะต่างจากแบบจำลองทางเศรษฐมิติแบบดั้งเดิมที่พยายามหาสมการเส้นตรงหรือเส้นโค้งที่ผ่านจุดข้อมูลให้ได้มากที่สุด

การทำงานของแบบจำลอง CNN นั้นจะดึงลักษณะหรือรายละเอียดออกมาจากภาพถ่ายแสงไฟยามค่ำคืบโดยการจัดกลุ่ม pixels ในภาพถ่ายเป็นกลุ่มย่อยขนาดเล็กในรูปแบบของ matrix และนำ matrix เหล่านั้นมาดำเนินการเชิงคณิตศาสตร์ ไม่ว่าจะเป็นการบวก ลบ คูณ หรือหารกับ parameter ต่าง ๆ ในแบบจำลองที่

<sup>2</sup> พื้นที่ต่าง ๆ ได้แก่ (1) กรุงเทพมหานคร ปริมณฑล และจังหวัดอื่น ๆ ในภาคกลางตอนล่าง (2) นิคมอุตสาหกรรมภาคตะวันออก (ฉะเชิงเทรา ชลบุรี และระยอง) และ (3) เชียงใหม่และบริเวณใกล้เคียง

<sup>3</sup> Computer Vision เป็นศาสตร์ที่ศึกษาเกี่ยวกับการดึงข้อมูลจากรูปภาพหรือวิดีโอเพื่อมาประมวลผล วิเคราะห์ และเข้าใจข้อมูล และนำผลลัพธ์ที่ได้ไปใช้ในการพยากรณ์หรือการตัดสินใจ

<sup>4</sup> ดูรายละเอียดของแบบจำลอง VGG-16 CNN ในภาคผนวก

กำหนดค่าน้ำหนักไว้ เพื่อให้ได้ผลลัพธ์เป็น matrix ที่สามารถนำมาใช้วิเคราะห์หรือประมวลผลในการประมาณการผลลัพธ์ขั้นสุดท้ายได้

(2) **ARIMA**: แบบจำลองนี้ใช้ผลรวมของค่าความสว่างของแสงไฟของทั้งประเทศเทียบกับช่วงเดียวกันของปีก่อน โดยใช้ information criterion เพื่อคำนวณหาค่าสัมประสิทธิ์ในแบบจำลอง โดย  $(p, q) = (0, 3)$  ให้ค่าที่เหมาะสมกับข้อมูลที่สุด

#### 4. ผลการศึกษา

จากผลการศึกษาพบว่า การประมาณการ %YoY GDP ด้วยแบบจำลอง ML ได้ผลลัพธ์ใกล้เคียงกับแบบจำลอง ARIMA ในแง่ความคลาดเคลื่อนที่วัดโดย Root Mean Squared Error (RMSE) และ Mean Absolute Error (MAE) อย่างไรก็ตามผลลัพธ์จากแบบจำลอง ML มีค่า correlation กับข้อมูล GDP จริงที่สูงกว่าประมาณสองเท่าเมื่อเทียบกับผลจากแบบจำลอง ARIMA จึงกล่าวได้ว่าข้อมูลแสงไฟยามค่ำคินน่าจะมีความประโยชน์ในการประมาณค่า GDP นอกจากนี้เป็นที่น่าสนใจว่าผลการประมาณการ %YoY GDP ภาคบริการ ด้วยแบบจำลอง ML สามารถประมาณการได้ดีที่สุด ทั้งในแง่ RMSE MAE โดยค่า correlation จากแบบจำลองกับข้อมูลจริงนี้สูงถึง 0.95 แสดงให้เห็นว่าแสงไฟยามค่ำคินน่าจะเป็นตัวแปรชี้วัดกิจกรรมภาคบริการได้เป็นอย่างดี (ดังแสดงในตารางที่ 1)


**ตารางที่ 1** เปรียบเทียบความสามารถในการประมาณการของแบบจำลอง ML และ ARIMA

แบบจำลอง	ข้อมูลที่ให้เรียนรู้ (Output)	Root Mean Square Error (RMSE)	Mean Absolute Error (MAE)	Correlation
ML	GDP	3.01	2.29	0.56
	GDP Service	<b>1.44</b>	<b>1.12</b>	<b>0.95</b>
ARIMA	GDP	3.30	2.07	0.21
	GDP Service	3.76	2.52	0.30

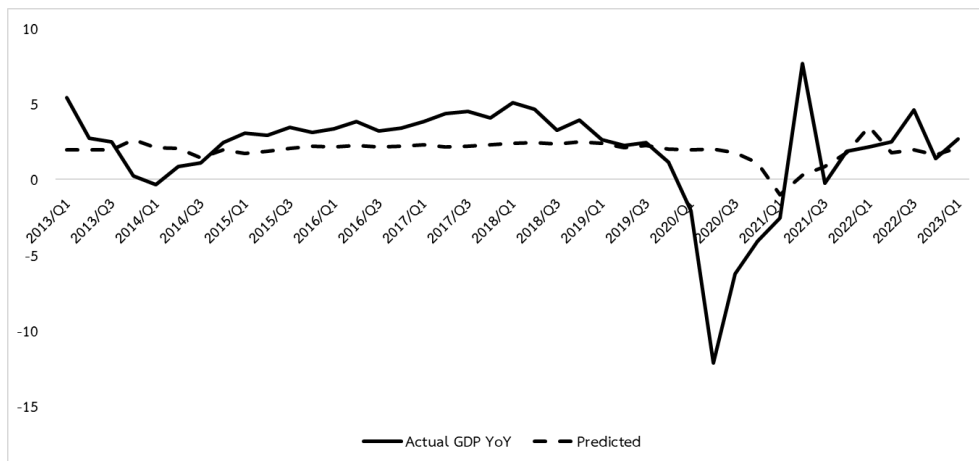
การทำความเข้าใจในการประมาณการของแบบจำลองต่าง ๆ อย่างละเอียดมากขึ้นในแต่ละช่วงเวลา ทำได้โดยการนำผลการประมาณค่าที่ได้จากแบบจำลองมาเทียบกับข้อมูลจริงในอดีต โดยจากกราฟที่ 1 จะเห็นได้ว่าผลการประมาณการ %YoY GDP จากแบบจำลอง ML ในช่วงไตรมาสที่ 2 ของปี 2015 ถึงไตรมาสที่ 3 ของปี 2019 แบบจำลอง ML ประมาณการ GDP ต่ำกว่าข้อมูลจริง ต่อมาในช่วงการแพร่ระบาดของโควิด 19 ประมาณการได้ค่าลบสอดคล้องกับข้อมูลจริง แต่ magnitude ยังต่ำกว่าข้อมูลจริง อย่างไรก็ตาม แบบจำลอง ML นั้นประมาณการได้ดีกว่าแบบจำลอง ARIMA เนื่องจากค่าประมาณการของแบบจำลอง ARIMA (ดังแสดงในกราฟที่ 2) แทบไม่มีการเปลี่ยนแปลงเลยตลอดทั้งช่วงเวลา และมีค่า Adjusted R-Squared เท่ากับ -0.03



กราฟที่ 1 ผลการประมาณการ %YoY GDP จากแบบจำลอง ML

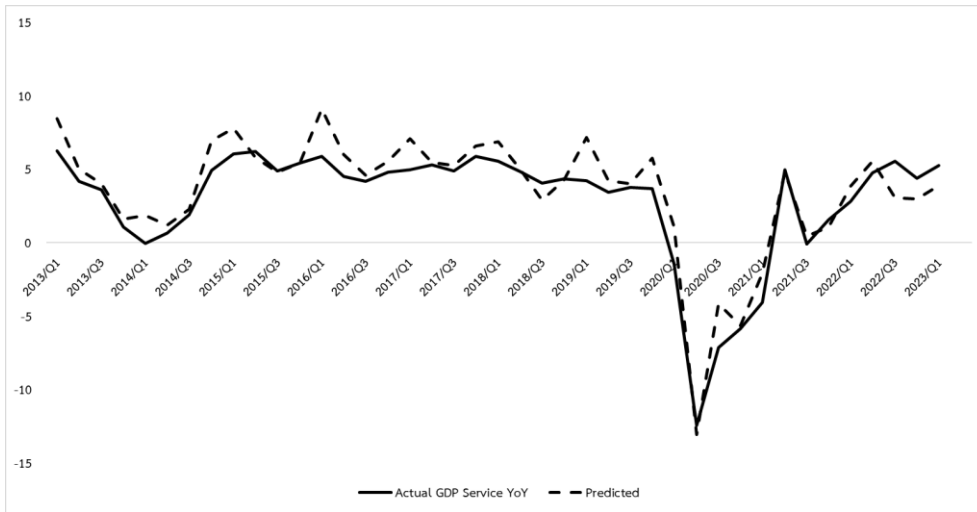


กราฟที่ 2 ผลการประมาณการ %YoY GDP จากแบบจำลอง ARIMA

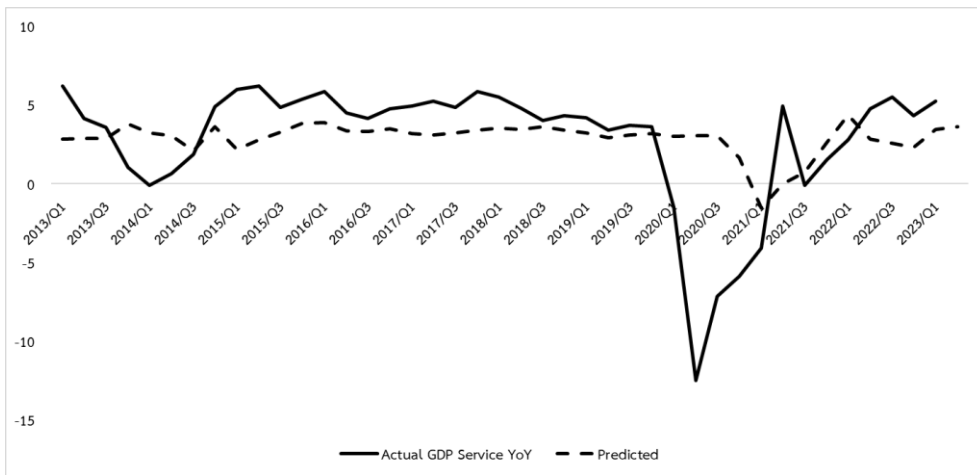


สำหรับผลการประมาณการ %YoY GDP ภาคบริการจากแบบจำลอง ML ใกล้เคียงกับข้อมูลจริงมาก ตลอดช่วงเวลาแม้ในช่วงที่คาดการณ์ GDP ภาคบริการยาก โดยเฉพาะอย่างยิ่งในช่วงการแพร่ระบาดของโควิด 19 นั้น มีความน่าสนใจว่าแบบจำลอง ML สามารถประมาณการอัตราการเติบโตที่ติดลบสูงได้อย่างแม่นยำ (ดังแสดงในกราฟที่ 3) และดีกว่าแบบจำลอง ARIMA ที่ค่าประมาณการแทบไม่มีการเปลี่ยนแปลงเลยตลอดทั้งช่วงเวลา (ดังแสดงในกราฟที่ 4) และมีค่า Adjusted R-Squared เท่ากับ 0.02 โดยในไตรมาสล่าสุด (ไตรมาสที่ 2 ของปี 2023) แบบจำลอง ML ประมาณการ %YoY GDP ภาคบริการ อยู่ที่ 3.8%

กราฟที่ 3 ผลการประมาณการ %YoY GDP ภาคบริการ จากแบบจำลอง ML



กราฟที่ 4 ผลการประมาณการ %YoY GDP ภาคบริการ จากแบบจำลอง ARIMA



**บทสรุป**

งานศึกษาได้นำข้อมูลภาพถ่ายแสงไฟยามค่ำคืนของประเทศไทยมาประมาณการอัตราการเติบโตของ GDP รายไตรมาส ซึ่งถือเป็นงานศึกษาชิ้นแรกของประเทศไทยที่ใช้ข้อมูลภาพถ่าย 2 มิติในการประมาณการ GDP ด้วยวิธีการทาง ML โดยพบว่า ข้อมูลภาพถ่ายแสงไฟยามค่ำคืนนี้สามารถใช้ประมาณการกิจกรรมทางเศรษฐกิจได้ดี โดยเฉพาะอัตราการขยายตัวของ GDP ภาคบริการ

ผลการศึกษาแสดงให้เห็นว่า ML มีศักยภาพในการประมาณการ GDP สูง เนื่องจากข้อมูลภาพถ่ายแสงไฟยามค่ำคืนมีความที่เป็นรายวัน จึงสามารถนำมาต่อยอดใช้ในการจัดทำเครื่องชี้เร็วเพื่อวิเคราะห์และติดตามทิศทางกิจกรรมทางเศรษฐกิจเป็นรายวันหรือรายสัปดาห์ได้ และยังสามารพัฒนาให้ประมาณการได้ดียิ่งขึ้นโดยเทคโนโลยีที่จะทำให้คอมพิวเตอร์ประมวลผลข้อมูลขนาดใหญ่ขึ้นได้ในอนาคตน่าจะทำให้ข้อมูลภาพถ่ายแสงไฟยามค่ำคืนนำมาใช้ประโยชน์กับการทำความเข้าใจและประมาณการทางเศรษฐกิจได้ดียิ่งขึ้นไป และใช้ข้อมูลชุดอื่นร่วมด้วย เช่น ภาพถ่ายทางอากาศ ข้อมูลเชิงประชากร หรืออัตราการขยายตัวของเมือง (urbanization rate) เพื่อให้สามารถจับชีพจรเศรษฐกิจได้อย่างทันการณ์และครอบคลุมมากขึ้น



## เอกสารอ้างอิง

- Beyer, R., Hu, Y., and Yao, J. (2022). Measuring Quarterly Economic Growth from Outer Space. *International Monetary Fund*.
- Brownlee, J. (2020). A Gentle Introduction to the Rectified Linear Unit (ReLU). *Machine Learning Mastery*.
- Chaiwat, T. (2016). Night Lights, Economic Growth, and Spatial Inequality of Thailand (Discussion Paper No. 26). *Puey Ungphakorn Institute for Economic Research*.
- Elgin, C., Kose, M.A., Ohnsorge, F., and Yu S. (2021). Understanding Informality. CERP Discussion Paper 16497, *Centre of Economic Policy Research*.
- Henderson, J.V., Storeygard A., and Weil, D.N. (2012). Measuring Economic Growth from Outer Space. *American Economic Review*, 102 (2): 994-1028.
- Le, K. (2021). An overview of VGG16 and NiN models. *Medium*.
- NASA. (2021). Worldview Image of the Week: Bangkok, Thailand at Night.
- NESDC. (2022). Gross Domestic Product Chain Volume Measures: QGDP 3<sup>rd</sup> quarter 2022. *Office of the National Economic and Social Development Council*.
- Román, M.O., Wang, Z., Shrestha, R., Yao, T., and Kalb, V. (2019). Black Marble User Guide Version 1.0. *NASA*.
- Román, M.O., Wang, Z., Sun, Q., Kalb, V., Miller, S.D., Molthan, A., Schultz, L., Bell, J., Stokes, E.C., Pandey, B., and Seto, K.C., et al. (2018). NASA's Black Marble nighttime lights product suite. *Remote Sensing of Environment* 210, 113-143. doi:10.1016/j.rse.2018.03.017.
- Rosenberg, M. (2020). The Distance Between Degrees of Latitude and Longitude. *ThoughtCo*.
- Zhang, C. (2017). How to choose Last-layer activation and loss function. *DLology*.

## ภาคผนวก

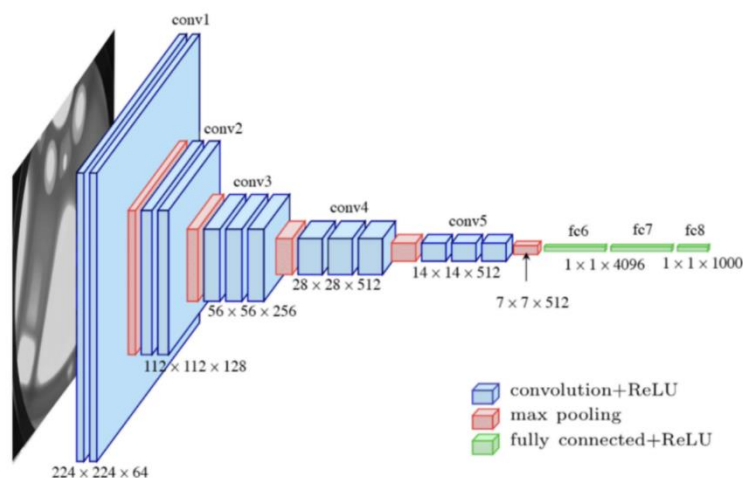
### ลักษณะของแบบจำลอง VGG-16 CNN

ลักษณะของแบบจำลอง CNN จะเลียนแบบโครงสร้างการทำงานของเซลล์ประสาทในสมองมนุษย์ โดยเฉพาะเซลล์ประสาทที่เกี่ยวข้องกับการมองเห็น กล่าวคือเซลล์ประสาทแต่ละเซลล์จะตอบสนองต่อบริเวณ การมองเห็นที่จำเพาะเจาะจง และเมื่อนำข้อมูลภาพจากเซลล์ประสาทจำนวนมาก ๆ มาประกอบรวมกันทำให้ สมองรับรู้ว่าคุณลักษณะนี้ตากำลังมองภาพใดอยู่ ซึ่งเซลล์ประสาท 1 เซลล์ เทียบเท่ากับ parameter ในแบบจำลอง CNN (หรือ regressor ในแบบจำลองเศรษฐมิติทั่วไป) 1 ตัว แต่เนื่องจากข้อมูลจากเซลล์ประสาทแต่ละเซลล์ มีความสำคัญไม่เท่ากัน (เช่น หากสมองต้องการทราบว่าภาพที่อยู่ตรงหน้าเป็นควางใช้หรือไม่ เซลล์ประสาทที่ ตรวจสอบว่าภาพนี้มีบริเวณที่มีลักษณะคล้ายเขาสัตว์หรือไม่ ย่อมต้องมีความสำคัญมากกว่าเซลล์ประสาทที่ ตรวจสอบว่าภาพนี้มีบริเวณที่มีลักษณะคล้ายขาทั้ง 4 ข้างหรือไม่) จึงทำให้ข้อมูลจากเซลล์ประสาทแต่ละตัว ได้รับการถ่วงน้ำหนักไม่เท่ากัน เทียบได้กับค่าน้ำหนัก (weights) ในแบบจำลอง CNN (หรือค่าสัมประสิทธิ์ (coefficients) ในแบบจำลองเศรษฐมิติทั่วไป)

แบบจำลอง VGG-16 CNN เป็น algorithm ที่ชนะการแข่งขัน ImageNet Large Scale Visual Recognition Challenge (ILSVRC) 2014 ในการจำแนกภาพ (image classification) โดยสามารถจำแนกรูปภาพของ ImageNet ซึ่งเป็นชุดข้อมูลที่มีรูปภาพของสิ่งมีชีวิต/สิ่งไม่มีชีวิตกว่า 1,000 ชนิด/อย่าง รวมทั้งสิ้นกว่า 14 ล้านรูป โดย VGG-16 มีความแม่นยำถึง 92.7%

แบบจำลองนี้ประกอบไปด้วย 13 Convolutional Layers, 5 Max Pooling Layers, 1 Flatten Layer และ 3 Dense (Fully Connected) Layers (ดังแสดงในภาพที่ 3) ซึ่งจะมีจำนวน parameter ทั้งหมดประมาณ 138 ล้าน parameters สำหรับที่มาของชื่อ VGG-16 นั้น VGG ย่อมาจาก Visual Geometry Group และ 16 หมายถึงจำนวน layer ที่มี weights ซึ่งหมายถึง Convolutional Layers และ Dense Layers ซึ่งทั้ง 16 layers นี้ จะใส่ ReLU (Rectified Linear Unit) เป็น activation function ยกเว้น layer สุดท้ายที่ไม่ใส่ activation function เพราะต้องการให้ประมาณการออกมาเป็นค่าที่ arbitrary

ภาพที่ 3 โครงสร้างของแบบจำลอง VGG-16



ที่มา: Le (2021)

## ผู้เขียน



บุณณิ บุญชูช่วย: [phunnbo@bot.or.th](mailto:phunnbo@bot.or.th)

เศรษฐกร ฝ่ายเศรษฐกิจมหภาค สายนโยบายการเงิน ธนาคารแห่งประเทศไทย  
นักเรียนทุนธนาคารแห่งประเทศไทย ผู้สำเร็จการศึกษาทั้งในสาขา Economics และ  
สาขา Computer Science จาก Brown University ประเทศสหรัฐอเมริกา ปัจจุบัน  
มีหน้าที่ติดตามภาวะเศรษฐกิจด้านอุปทาน อาทิ ภาคบริการ และจัดทำประมาณการ  
เศรษฐกิจและเงินเฟ้อด้วยแบบจำลองต่าง ๆ

**Disclaimer:** ข้อคิดเห็นที่ปรากฏในบทความนี้เป็นความเห็นของผู้เขียน ซึ่งไม่จำเป็นต้องสอดคล้องกับความเห็น  
ของธนาคารแห่งประเทศไทย (ธปท.) และการกล่าว คัด หรืออ้างอิงข้อมูลบางส่วนตามสมควรในบทความนี้  
จะต้องกระทำโดยถูกต้องและอ้างอิงถึงผู้เขียนโดยชัดเจน

**Tags:** Nighttime lights, Economic measurement, Quarterly GDP, Machine Learning, Computer Vision,  
Forecasting

**Economic Pulse** เป็นบทความวิชาการขนาดสั้นโดยบุคลากรของธนาคารแห่งประเทศไทย ซึ่งนำเสนอ  
งานวิเคราะห์ด้านเศรษฐกิจการเงินหรือด้านนโยบาย เพื่อสื่อสารต่อสาธารณชน นักวิชาการ และนักวิเคราะห์