

ข้อเสนอโครงการวิศวกรรมไฟฟ้า วิชา 2102490 ปีการศึกษา 2558

ชื่อโครงการ (ไทย) การหาโครงสร้างเชิงสาเหตุสำหรับข้อมูลอนุกรมเวลาด้วยวิธีทดสอบทางสถิติบน
การประมาณแบบจำลอง

Project Name (English) Exploring Granger causality for time series via statistical tests
on estimated models

ชื่อนิติ นาย นันทนัช รักษาศรี หมายเลขประจำตัว 5530299121 SRA ACO

อาจารย์ที่ปรึกษา อาจารย์ จิตโกมุท ส่งศิริ

ห้องปฏิบัติการวิจัย ระบบควบคุม

1 หลักการและเหตุผล

ในปัจจุบัน ข้อมูลอนุกรมเวลา (time series) นั้นเกี่ยวข้องกับชีวิตประจำวันไม่มากนักน้อย ตัวอย่างเช่น ราคาของหุ้นในแต่ละวัน ปริมาณน้ำฝนในแต่ละเดือน ปริมาณความต้องการใช้ไฟฟ้าในแต่ละวัน หรือแม้กระทั่งสัญญาณคลื่นไฟฟ้าทางสมอง ถ้าสามารถทราบถึงความสัมพันธ์ระหว่างตัวแปรต่างๆของข้อมูลอนุกรมเวลา ก็จะสามารถอธิบายการเปลี่ยนแปลงหรือพลวัตของข้อมูลอนุกรมเวลามีผลจากอะไรบ้าง ข้อมูลอนุกรมเวลาที่สนใจในโครงการนี้คือ EEG (electroencephalogram) หรือการตรวจคลื่นไฟฟ้าทางสมอง เป็นการบันทึกสัญญาณไฟฟ้าที่เกิดจากผลรวมของกระแสไฟฟ้าของกลุ่มเซลล์ในสมอง โดยเลือกใช้แบบจำลองถดถอยตัวเอง (Autoregressive (AR) model) มาอธิบาย เนื่องจากแบบจำลอง AR นั้นค่าสัญญาณขาออกที่เวลาปัจจุบันจะขึ้นกับค่าของสัญญาณขาออกของเวลาในอดีตและสัญญาณรบกวนในปัจจุบันเท่านั้น ดังสมการ

$$y(t) = c + A_1y(t-1) + A_2y(t-2) + \dots + A_p y(t-p) + v(t) \quad (1)$$

เมื่อ $y(t)$ และ $v(t)$ คือสัญญาณขาออก และสัญญาณรบกวนที่เวลา t ตามลำดับ ดังนั้นแบบจำลอง AR จึงเป็นแบบจำลองที่ดีแบบจำลองหนึ่งสำหรับการอธิบายสัญญาณ EEG

สำหรับโครงการนี้ การอธิบายความสัมพันธ์ของตัวแปรในข้อมูลอนุกรมเวลา หรือโครงสร้างเชิงสาเหตุ จะถูกอธิบายด้วยเงื่อนไขความสัมพันธ์ระหว่างเหตุและผล (Granger causality) โดยจาก [1] หลักการพื้นฐานของเงื่อนไขความสัมพันธ์ระหว่างเหตุและผลคือ ถ้าหากตัวแปร x มีผลต่อตัวแปร y แล้วการที่รู้ค่าของตัวแปร x ก่อน ย่อมจะช่วยให้การทำนายค่าของตัวแปร y มีความแม่นยำมากขึ้นกว่าการที่ไม่รู้ค่าของตัวแปร x มาก่อน ดังนั้นเมื่อนำมาประยุกต์ใช้กับแบบจำลอง AR เงื่อนไขความสัมพันธ์ระหว่าง

เหตุและผลของแบบจำลองนั้นสามารถเขียนได้ในรูปสมการเชิงเส้นของค่าสัมประสิทธิ์หรือค่าพารามิเตอร์ของแบบจำลอง หรือก็คือ y_j ไม่ใช่สาเหตุแบบ Granger ต่อ y_i ก็ต่อเมื่อ

$$(A_k)_{ij} = 0 \quad (2)$$

เมื่อ $(A_k)_{ij}$ คือสมาชิกตัวที่ (i, j) ของเมทริกซ์ A_k ซึ่งคือพารามิเตอร์ของแบบจำลอง AR สำหรับทุกค่า $k = 1, 2, \dots, p$

การประมาณค่าพารามิเตอร์ของแบบจำลองจะเลือกใช้วิธีการประมาณแบบความควรจะเป็นสูงสุด (maximum likelihood (ML) estimation) ถ้าค่าของพารามิเตอร์มีค่าเท่ากับศูนย์ จะสามารถบอกได้ว่าข้อมูลอนุกรมเวลาไม่สัมพันธ์กัน โดยปรกติแล้วเมทริกซ์ A_k ที่ประมาณได้อาจจะมีบางสมาชิกที่ไม่เท่ากับศูนย์ จึงต้องตั้งสมมติฐานขึ้นมาเพื่อทดสอบสมการ (2) ว่าเป็นจริงหรือไม่ กล่าวคือ การทดสอบหารูปแบบโครงสร้างของค่าที่เป็นศูนย์ในพารามิเตอร์ของแบบจำลอง AR

การทดสอบสมมติฐานนั้นจะนำหลักการของการทดสอบ Wald มาใช้ โดยจาก [2] การทดสอบ Wald มีหลักการคือ ถ้าสมมติฐานว่าค่าที่แท้จริงของพารามิเตอร์มีค่าเท่ากับศูนย์เป็นจริง แล้วค่าพารามิเตอร์ที่ประมาณได้ควรมีค่าเข้าใกล้ศูนย์อย่างมีนัยยะสำคัญ จากนั้นจะสามารถประมาณค่าพารามิเตอร์ใหม่ได้ ภายใต้ข้อกำหนดที่ว่าค่าของสมาชิกบางตัวของพารามิเตอร์มีค่าเป็นศูนย์ ซึ่งอยู่ในรูปแบบปัญหาการหาค่าที่เหมาะสมที่สุดภายใต้ข้อกำหนดค่าคงที่เป็นศูนย์ (optimization problem with zero constrain)

โครงการนี้มีจุดประสงค์ที่จะอธิบายความสัมพันธ์ระหว่างตัวแปรต่างๆ ของข้อมูลอนุกรมเวลาผ่านค่าพารามิเตอร์ของแบบจำลอง AR โดยการหารูปแบบโครงสร้างของศูนย์ในพารามิเตอร์ของแบบจำลอง

2 การกำหนดปัญหา

พิจารณา (1) แบบจำลองถดถอยตัวเอง (Autoregressive (AR) model)

$$y(t) = c + A_1y(t-1) + A_2y(t-2) + \dots + A_p y(t-p) + v(t)$$

เมื่อ $y(t) \in \mathbb{R}^n = (y_1(t), y_2(t), \dots, y_n(t))$ เป็นค่าของสัญญาณขาออกของแบบจำลอง และ $y_i(t)$ เป็นสมาชิกตัวที่ i ของ $y(t)$, $A_1, A_2, \dots, A_p \in \mathbb{R}^{n \times n}$ เป็นค่าสัมประสิทธิ์หรือพารามิเตอร์ของแบบจำลอง, $c \in \mathbb{R}^n$ เป็นเวกเตอร์ค่าคงที่, p คืออันดับของแบบจำลองและ $v(t)$ คือสัญญาณรบกวนซึ่งกำหนดให้เป็นสัญญาณรบกวนเกาส์สีขาว (Gaussian white noise) โดยมีค่าเฉลี่ยเป็นศูนย์ และเมทริกซ์ความแปรปรวนเป็น Σ เราสามารถเขียนแบบจำลอง (1) ในรูปแบบสมการเชิงเส้นในพารามิเตอร์ได้ดังนี้

$$y(t) = AH(t) + v(t) \quad (3)$$

เมื่อ $H(t) = [1 \ y(t-1)^T \ y(t-2)^T \ \dots \ y(t-p)^T]^T \in \mathbb{R}^{np+1}$ และ $v(t) \sim \mathcal{N}(0, \Sigma)$ ค่าพารามิเตอร์ของแบบจำลองที่ต้องการประมาณคือ $A = [c \ A_1 \ A_2 \ \dots \ A_p] \in \mathbb{R}^{n \times (np+1)}$ ซึ่งจะนำวิธีการประมาณแบบ ML มาใช้ประมาณค่าพารามิเตอร์นั้น โดยจะถูกกล่าวถึงในภาคผนวกหัวข้อที่ 6.1

การทดสอบ Wald

ในหัวข้อนี้ จะกล่าวถึงการทดสอบ Wald ซึ่งเป็นการทดสอบสมมติฐาน (hypothesis test) บนพารามิเตอร์ที่ได้จากการประมาณว่าเป็นไปตามสมมติฐานที่เราตั้งไว้หรือไม่ โดยเป็นเนื้อหาสรุปมาจาก [2] กำหนดให้ตัวแปรไม่ทราบค่า $\theta \in \mathbb{R}^p$ เป็นพารามิเตอร์ที่ถูกประมาณค่าด้วยวิธีการของ ML และให้ $\mathbf{Avar}(\theta)$ คือเมทริกซ์ค่าความแปรปรวนร่วมเชิงเส้นกำกับ (Asymptotic covariance matrix) ของ θ ซึ่งสามารถหาได้จาก

$$\mathbf{Avar}(\theta) = \frac{1}{N} \mathcal{I}(\theta)^{-1}$$

เมื่อ $\mathcal{I}(\theta)$ คือเมทริกซ์ของฟิชเชอร์อินฟอร์เมชัน (Fisher information matrix) ของ θ ซึ่งอยู่ใน y (สำหรับ 1 ตัวอย่าง) โดย y คือตัวอย่างของข้อมูลและ N คือ จำนวนตัวอย่าง โดยนิยามคือ

$$\begin{aligned} \mathcal{I}(\theta) &= \mathbb{E} [(\nabla_{\theta} \log f(y|\theta))(\nabla_{\theta} \log f(y|\theta))^T] \\ &= -\mathbb{E} [\nabla_{\theta}^2 \log f(y|\theta)] \end{aligned}$$

จากนั้นตั้งสมมติฐานว่าง (null hypothesis) เพื่อใช้ในการทดสอบสมมติฐานคือ

$$H_0 : r(\theta) = 0$$

เมื่อ $r : \mathbb{R}^p \rightarrow \mathbb{R}^m$ คือฟังก์ชันข้อกำหนด (restriction function) โดย $m \leq p$ ตัวอย่างเช่น $\theta_1 = 0, \theta_1 + \theta_3 = 0$

และจาก [??] การทดสอบ Wald จะใช้การทดสอบเชิงสถิติดังนี้

$$W = r(\hat{\theta})^T \left[D_r(\hat{\theta}) \widehat{\mathbf{Avar}}(\hat{\theta}) D_r(\hat{\theta})^T \right]^{-1} r(\hat{\theta}) \quad (4)$$

เมื่อ $D_r(\theta)$ คือจาโคเบียนของฟังก์ชัน r เทียบกับ θ และ $\widehat{\mathbf{Avar}}(\hat{\theta})$ คือค่าประมาณของเมทริกซ์ค่าความแปรปรวนร่วมเชิงเส้นกำกับของ $\hat{\theta}$ โดยสำหรับการประมาณแบบ ML ค่าของ $\widehat{\mathbf{Avar}}(\hat{\theta})$ สามารถหาได้จาก

$$\widehat{\mathbf{Avar}}(\hat{\theta}_{ml}) = \left[-\sum_{i=1}^N \nabla^2 \log f(y_i|\hat{\theta}) \right]^{-1} \quad (5)$$

เราสามารถพิสูจน์ได้ว่าค่าทางสถิติของ Wald (W) จะมีการแจกแจงเข้าสู่การแจกแจงแบบไคสแควร์ (Chi-square distribution) โดยมีองศาอิสระเท่ากับ m

กำหนดให้ α คือค่าระดับนัยสำคัญ (significance level) ซึ่งนิยามคือ


$$\alpha = \mathbf{Prob}(W > \chi_{\alpha,m}^2) = 1 - P(W \leq \chi_{\alpha,m}^2) \approx 1 - F(\chi_{\alpha,m}^2)$$

โดย $F(\chi_{\alpha,m}^2)$ คือฟังก์ชันการแจกแจงแบบไคสแควร์ของ $\chi_{\alpha,m}^2$ และ $\chi_{\alpha,m}^2$ คือค่าวิกฤต (critical value) ดังนั้นจะได้ว่า

$$\chi_{\alpha,m}^2 = F^{-1}(1 - \alpha)$$

โดยการทดสอบสมมติฐานด้วยวิธีการทดสอบ Wald เราจะปฏิเสธ H_0 ถ้า

$$W > \chi_{\alpha,m}^2$$



รูป 1: รูปแสดงการแจกแจงไคสแควร์

วัตถุประสงค์ของโครงการ

1. นำเสนอรูปแบบปัญหาการเรียนรู้เงื่อนไขความสัมพันธ์ระหว่างเหตุและผล จากแบบจำลอง AR ด้วยวิธีการทดสอบสมมติฐานแบบ Wald
2. พัฒนาการเขียนโปรแกรม Matlab เพื่อแก้ปัญหาการเรียนรู้เงื่อนไขความสัมพันธ์ระหว่างเหตุและผล ดังข้อที่ 1

ขอบเขตของโครงการ

1. การทดสอบประสิทธิภาพของการทดสอบ Wald จะถูกทำบนข้อมูลที่สังเคราะห์ขึ้นมาเอง และจะนำการทดลองไปใช้จริงบนข้อมูล EEG โดยเป็นส่วนหนึ่งของโครงการของนาย ปวีศร ใจทหาร
2. ขนาดของปัญหาที่พิจารณาจะอยู่ในอันดับ $n \simeq 20-50$ โดยที่เมื่อปัญหามีอันดับที่สูงขึ้น จะพัฒนาโปรแกรมให้มีประสิทธิภาพมากขึ้นในแง่ของการคำนวณ หรือทางเลือกของภาษา

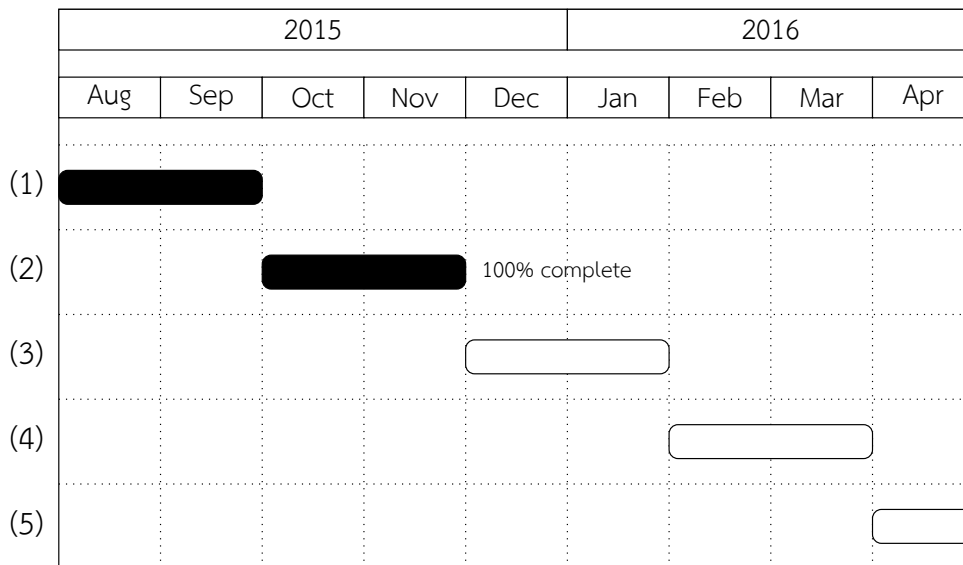
3 ระเบียบวิธีที่ใช้ในโครงการ

3.1 แนวทางในการทำโครงการ

1. ศึกษาวิธีการประมาณแบบจำลองด้วยวิธี Least-Square (LS) และ Maximum Likelihood (ML)
2. ศึกษาแบบจำลอง AR และหาค่าพารามิเตอร์ของแบบจำลองด้วยวิธี ML
3. ศึกษาหลักการของเงื่อนไขความสัมพันธ์ระหว่างเหตุและผลกับแบบจำลอง AR
4. ศึกษาการประมาณพารามิเตอร์ของแบบจำลองด้วยวิธี LS ภายใต้เงื่อนไขเชิงเส้น
5. ศึกษาวิธีการทดสอบสมมติฐานด้วยวิธีการทดสอบ Wald และทดลองการทดสอบสมมติฐานกับปัญหาเชิงเส้น และตัวแปรของแบบจำลอง AR
6. ทดลองประมาณค่าพารามิเตอร์ของแบบจำลอง AR เมื่อนำหลักการของเงื่อนไขความสัมพันธ์ระหว่างเหตุและผล และเสถียรภาพมาใช้

7. ทดลองใช้ค่าระดับนัยสำคัญหลายๆค่าเพื่อหาแบบจำลองที่เหมาะสมที่สุด
8. ทดลองทำการทดสอบอัตราส่วนความควรจะเป็น (likelihood ratio test) เพื่อใช้แยกแยะรูปแบบโครงสร้างของเงื่อนไขความสัมพันธ์ระหว่างเหตุและผล
9. เขียนรายงาน

3.2 แผนงาน



รูป 2: Gantt Chart การทำโครงงานวิศวกรรม ปีการศึกษา 2558 จนถึงเดือน เม.ย. 59 โดยมีรายละเอียดดังนี้

- (1) ศึกษาและทบทวนวรรณกรรม (LS,MS estimation, Granger causality, AR model)
- (2) ศึกษาการประมาณแบบจำลองด้วยวิธี LS ภายใต้เงื่อนไขเชิงเส้น, การทดสอบ Wald และทดสอบกับปัญหาเชิงเส้นและพารามิเตอร์ของแบบจำลอง AR
- (3) ทดลองประมาณค่าพารามิเตอร์ของแบบจำลอง AR เมื่อนำหลักการของ Granger causality และ Stability มาใช้
- (4) ทดลองใช้ค่าระดับนัยสำคัญหลายๆค่าเพื่อหาแบบจำลองที่เหมาะสมที่สุดและทำการทดสอบอัตราส่วนความควรจะเป็นเพื่อใช้แยกแยะรูปแบบของเงื่อนไขความสัมพันธ์ระหว่างเหตุและผล และทดสอบกับข้อมูลจริง
- (5) เขียนรายงานวิชา 2102499

3.3 ผลลัพธ์ในแต่ละขั้นตอน (Deliveries)

1. สามารถประมาณค่าพารามิเตอร์ของแบบจำลองด้วยวิธี LS และ ML ได้
2. เข้าใจรูปแบบและการนำไปใช้ของแบบจำลอง AR และสามารถประมาณค่าพารามิเตอร์ในแบบจำลองด้วยวิธี ML
3. เข้าใจหลักการของเงื่อนไขความสัมพันธ์ระหว่างเหตุและผล เมื่อนำมาใช้กับแบบจำลอง AR
4. เข้าใจวิธีการแก้ปัญหาของการประมาณพารามิเตอร์ของแบบจำลองภายใต้เงื่อนไขเชิงเส้น
5. สามารถหาค่าประมาณของพารามิเตอร์ของปัญหาเชิงเส้นและของแบบจำลอง AR เมื่อมีข้อจำกัดว่าตำแหน่งใดๆมีค่าเท่ากับศูนย์

6. สามารถประมาณค่าพารามิเตอร์ของแบบจำลอง AR ใหม่ โดยสอดคล้องกับหลักการของเงื่อนไขความสัมพันธ์ระหว่างเหตุและผล และแบบจำลองที่ประมาณได้มีเสถียรภาพ
7. สามารถหาแบบจำลองที่เหมาะสมที่สุดที่ใช้ในการประมาณข้อมูลอนุกรมเวลา
8. สามารถแยกแยะรูปแบบโครงสร้างของเงื่อนไขความสัมพันธ์ระหว่างเหตุและผล เพื่อนำมาพิจารณาข้อมูลอนุกรมเวลาได้ว่าควรอยู่ในหมวดหมู่อะไร
9. รายงานฉบับสมบูรณ์

4 ความก้าวหน้าตามแผนงาน

4.1 การทดสอบ Wald กับปัญหาค่ากำลังสองน้อยสุด (Least-Square)

การทดลองในส่วนนี้จะถูกกล่าวถึงในภาคผนวกหัวข้อที่ 6.2 โดยจากผลจากผลการทดลองจะเห็นว่าค่าความผิดพลาดแบบที่สองจะมีค่าลดลงเมื่อเพิ่มค่าของระดับนัยสำคัญและจำนวนตัวอย่าง แต่จะมีค่าเพิ่มมากขึ้นเมื่อค่าความแปรปรวนของสัญญาณรบกวนมีค่ามากขึ้น ในขณะที่ค่าความผิดพลาดแบบที่หนึ่งจะมีค่าประมาณเท่ากับค่าระดับนัยสำคัญเสมอ เนื่องจากการทดสอบสมมติฐานได้นิยามให้ค่าระดับนัยสำคัญและค่าความผิดพลาดแบบที่หนึ่งเป็นค่าเดียวกัน

4.2 การทดสอบ Wald กับปัญหาค่ากำลังสองน้อยสุด (LS) บนแบบจำลอง AR

เพื่อสังเกตรูปแบบโครงสร้างของศูนย์ในพารามิเตอร์ของแบบจำลองที่ถูกประมาณได้เมื่อใช้ค่าระดับนัยสำคัญต่างๆกัน เริ่มต้นจากการสร้างแบบจำลองตามสมการ (3) โดยใช้ค่า $y(t) \in \mathbb{R}^n$ อันดับของแบบจำลอง $p = 4$ และจำนวนข้อมูลทั้งหมด 1,000 จุด ($t = 1, 2, \dots, 1000$) พารามิเตอร์ของแบบจำลอง $A_k \in \mathbb{R}^{n \times n}$ สำหรับ $k = 1, 2, 3, 4$ จะถูกสร้างให้มีบางสมาชิก $(A_k)_{ij}$ เป็นศูนย์จำนวนครึ่งหนึ่งของจำนวนพารามิเตอร์ทั้งหมด หรือก็คือ 50% และ $v(t) \sim \mathcal{N}(0, 10I_n)$ โดยใช้ค่า $n = 20$ แล้วจึงทำการประมาณค่าพารามิเตอร์ A, Σ ซึ่งเป็นผลเฉลยแบบปิด (closed-form) ของปัญหา ML จากสมการ (10), (11) ในส่วนของภาคผนวกหัวข้อที่ 6.1 ตามลำดับ

จากนั้นจึงใช้วิธีการจากภาคผนวกหัวข้อที่ 6.3 เพื่อนำพารามิเตอร์ของแบบจำลองไปทดสอบ Wald ซึ่งจะได้รูปแบบของสมการใหม่ในรูปแบบของสมการ (14) และฟังก์ชันข้อกำหนดสำหรับทดสอบคู่ (i, j) ใดๆ ดัง (15) ซึ่งสามารถเขียนได้เป็น

$$r(\hat{\theta}) = [e_i^T \otimes I_p] \hat{\theta}$$

เมื่อ \otimes คือตัวดำเนินการ kronecker product และ $\hat{\theta} \in \mathbb{R}^{n^2 p}$ คือค่าประมาณของ θ ในสมการ (13) ซึ่งมีจำนวนตัวแปรทั้งหมด $n^2 p = 1600$ และค่าประมาณของเมทริกซ์ค่าความแปรปรวนร่วมของ $\hat{\theta}$ ซึ่ง

หาได้จาก (5) คือ

$$\widehat{\mathbf{Avar}}(\hat{\theta}) = \left[\sum_{t=p+1}^N \bar{H}(t)^T \hat{\Sigma}^{-1} \bar{H}(t) \right]^{-1}$$

และค่าทางสถิติของ Wald (W) สำหรับคู่ $(\hat{A}_k)_{ij}$ ใดๆจาก (4) จะลดรูปเป็น

$$W_{ij} = \hat{B}_{ij}^T \left[\widehat{\mathbf{Avar}}(\hat{\theta})_{ij} \right]^{-1} \hat{B}_{ij}$$


โดยกำหนดให้ $\widehat{\mathbf{Avar}}(\hat{\theta})_{ij}$ คือเมทริกซ์ย่อยขนาด $p \times p$ ในแนวทแยงมุม (main diagonal block) ของ $\widehat{\mathbf{Avar}}(\hat{\theta})$ ที่สอดคล้องกับพารามิเตอร์ B_{ij}

จากนั้นจึงทำการทดสอบ Wald สำหรับ $(A_k)_{ij}$ แต่ละคู่ (i, j) โดยใช้ค่าระดับนัยสำคัญต่างกัน และพิจารณาค่าความผิดพลาดทั้งสองแบบของการทดสอบสมมติฐาน ซึ่งคือค่าความผิดพลาดแบบที่หนึ่ง (Type I error) คือค่าความน่าจะเป็นที่ค่าพารามิเตอร์ที่ประมาณได้ไม่เท่ากับศูนย์เมื่อกำหนดให้ค่าจริงของพารามิเตอร์เท่ากับศูนย์


$$\text{Type I Error} = \mathbf{Prob}((\hat{A}_k)_{ij} \neq 0 | (A_k)_{ij} = 0)$$

และค่าความผิดพลาดแบบที่สอง (Type II error) คือค่าความน่าจะเป็นที่ค่าพารามิเตอร์ที่ประมาณได้เท่ากับศูนย์เมื่อกำหนดให้ค่าจริงของพารามิเตอร์ไม่เท่ากับศูนย์

$$\text{Type II Error} = \mathbf{Prob}((\hat{A}_k)_{ij} = 0 | (A_k)_{ij} \neq 0)$$




(a) ค่าความผิดพลาดแบบที่หนึ่ง




(b) ค่าความผิดพลาดแบบที่สอง

รูป 3: รูปแสดงค่าความผิดพลาดทั้งสองแบบ เมื่อเปลี่ยนแปลงค่าระดับนัยสำคัญ (α)

จากการทดลองจะเห็นว่าค่าความผิดพลาดแบบที่สองจะมีค่าลดลงตามค่าระดับนัยสำคัญที่เพิ่มขึ้น ในขณะที่ค่าความผิดพลาดแบบที่หนึ่งจะมีค่าเพิ่มขึ้นตามค่าระดับนัยสำคัญที่เพิ่มขึ้น ดังรูปที่ 3 และแสดงตัวอย่างรูปแบบโครงสร้างของศูนย์ของพารามิเตอร์ที่ประมาณได้เทียบกับค่าจริงในรูปที่ 4



(a) $\alpha = 0.01$



(b) $\alpha = 0.1$

รูป 4: รูปแสดงตัวอย่างรูปแบบโครงสร้างของศูนย์ของพารามิเตอร์ที่ประมาณได้เมื่อเทียบกับค่าจริง เมื่อ

□ แทนจุดข้อมูลที่ไม่เท่ากับศูนย์ทั้งคู่ของค่าจริงและค่าประมาณ ○ แทนจุดที่ค่าจริงเท่ากับศูนย์แต่ค่าประมาณไม่เป็นศูนย์ + แทนจุดที่ค่าจริงไม่เท่ากับศูนย์แต่ค่าประมาณเป็นศูนย์และช่องว่างคือจุดข้อมูลที่เป็นศูนย์ทั้งคู่ของค่าจริงและค่าประมาณ

5 บทสรุป

โครงการนี้จะทำการหารูปแบบโครงสร้างของศูนย์ของพารามิเตอร์ของแบบจำลอง AR มีจุดประสงค์เพื่ออธิบายความสัมพันธ์ระหว่างตัวแปรต่างๆ ของข้อมูลอนุกรมเวลาผ่านค่าพารามิเตอร์ของแบบจำลอง โดยในส่วนของภาคการศึกษาต้นจะทำการศึกษาวิธีการประมาณแบบกำลังสองน้อยสุดและแบบความควรจะเป็นสูงสุด และศึกษาการทดสอบ Wald เพื่อนำมาใช้หารูปแบบโครงสร้างของศูนย์ของพารามิเตอร์ของแบบจำลอง และภาคการศึกษาปลายจะหาแบบจำลองที่เหมาะสมสำหรับแบบจำลอง เนื่องจาก การทดสอบ Wald จะมีผลลัพธ์ของโครงสร้างของศูนย์มากกว่าหนึ่งแบบทำให้ต้องพิจารณาวิธีการเลือกแบบจำลอง และพัฒนาประสิทธิภาพของการเขียนโปรแกรม Matlab สำหรับกรณีที่อันดับของปัญหามีค่าที่สูงขึ้น

References

- [1] J. Songsiri, *Sparse Autoregressive Model Estimation for Learning Granger Causality in Time Series*, Proc. of the 38th IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP), Canada, May 2013.
- [2] W. H. Greene, *Econometric Analysis*. Prentice Hall, 2008

6 ภาคผนวก

6.1 การประมาณแบบความควรจะเป็นสูงสุด (Maximum Likelihood (ML) Estimation)

พิจารณา $y = (y_1, \dots, y_N)$ เป็นตัวอย่างหรือสัญญาณขาออกที่สังเกตได้จากแบบจำลอง, θ คือค่าพารามิเตอร์ ไม่ทราบค่าของแบบจำลองที่ต้องการจะประมาณ การประมาณค่า θ จาก y ด้วยหลักการของ ML ทำได้ โดยการเลือก θ ที่ทำให้ค่าฟังก์ชันความหนาแน่นของความน่าจะเป็นมีค่าสูงสุด

$$\hat{\theta} = \arg \max_{\theta} f(y|\theta) \quad (6)$$

โดย $f(y|\theta)$ คือฟังก์ชันความหนาแน่นของความน่าจะเป็นแบบมีเงื่อนไข (conditional likelihood function) ของ y สำหรับค่า θ หนึ่งๆ และนำหลักการของ ML มาประยุกต์ใช้กับแบบจำลอง AR จะได้ว่าฟังก์ชันความควรจะเป็นของแบบจำลองคือ

$$\begin{aligned} f(y|\theta) &= f(y|A, \Sigma) = f(y(p+1), y(p+2), \dots, y(N)|y(1), y(2), \dots, y(p), A, \Sigma) \\ &= \frac{1}{(2\pi)^{\frac{(N-p)}{2}}} \cdot \frac{1}{\det \Sigma^{\frac{(N-p)}{2}}} \cdot \exp -\frac{1}{2} \sum_{t=p+1}^N (y(t) - AH(t))^T \Sigma^{-1} (y(t) - AH(t)) \end{aligned} \quad (7)$$

เนื่องจาก (7) อยู่ในรูปของฟังก์ชันเอกซ์โพเนนเชียล (exponential function) เรามักจะพิจารณาลอการิทึมของ (7) แทน เพื่อใช้แก้ปัญหา (6) ได้สะดวกมากขึ้น

$$\log(f(y|A, \Sigma)) = \mathcal{L}(A, \Sigma) = \frac{N-p}{2} \log \det \Sigma^{-1} - \frac{1}{2} \sum_{t=p+1}^N (y(t) - AH(t))^T \Sigma^{-1} (y(t) - AH(t)) \quad (8)$$

เทอมสุดท้ายใน (8) สามารถเขียนใหม่ได้เป็นดังนี้

$$\mathcal{L}(A, \Sigma) = \frac{N-p}{2} \log \det \Sigma^{-1} - \frac{1}{2} \|L[Y - AH]\|_F^2 \quad (9)$$

โดยให้ $L^T L = \Sigma^{-1}$

$$Y = [y(p+1) \quad y(p+2) \quad \cdots \quad y(N)]_{n \times (N-p)}, \quad H = \begin{bmatrix} 1 & 1 & \cdots & 1 \\ y(p) & y(p+1) & \cdots & y(N-1) \\ y(p-1) & y(p) & \cdots & y(N-2) \\ \vdots & \vdots & & \vdots \\ y(1) & y(2) & \cdots & y(N-p) \end{bmatrix}_{(np+1) \times (N-p)}$$

จากนั้นสามารถหาค่าประมาณของ A และ Σ ได้โดยจาก (9) จะเห็นว่าปัญหา (6) จะเทียบเท่ากับปัญหากำลังสองน้อยสุด (least-square) ซึ่งจะเป็นปัญหาการหาค่าที่เหมาะสมที่สุดแบบทั่วไป (unconstrained optimization) จะได้ว่าผลเฉลยต้องสอดคล้องกับเงื่อนไขเท่ากับศูนย์ของเกรเดียนต์ของลอการิทึมของฟังก์ชันความน่าจะเป็นแบบมีเงื่อนไขของ y เทียบกับ θ คือ

$$\nabla_{\theta} \log f(y|\theta) = 0$$

ดังนั้น สำหรับการหาค่าสูงสุดของ $\mathcal{L}(A, \Sigma)$ จึงต้องหา A และ Σ ที่ทำให้เกรเดียนต์ของลอการิทึมของฟังก์ชันความน่าจะเป็นแบบมีเงื่อนไขของ y เทียบกับ A และ Σ^{-1} เท่ากับศูนย์ตามลำดับ

$$\nabla_A \mathcal{L}(A, \Sigma) = 0 \text{ และ } \nabla_{\Sigma^{-1}} \mathcal{L}(A, \Sigma) = 0$$

จากเงื่อนไขข้างต้น เราจะได้ผลเฉลย A, Σ ในรูปแบบปิด (closed-form) คือ

$$\hat{A} = YH^T(HH^T)^{-1} \quad (10)$$

$$\hat{\Sigma} = \frac{1}{N-p} \sum_{t=p+1}^N (y(t) - \hat{A}H(t))(y(t) - \hat{A}H(t))^T \quad (11)$$

โดยจะสามารถคำนวณค่า $\hat{\Sigma}$ ได้เมื่อรู้ค่า \hat{A} แล้ว

6.2 การทดสอบ Wald กับปัญหาค่ากำลังสองน้อยสุด (Least-Square)

พิจารณาปัญหาค่ากำลังสองน้อยสุด (LS) เมื่อไม่มีข้อกำหนดใดๆ

$$\hat{x} = \arg \min_x \|Ax - y\|^2 = (A^T A)^{-1} A^T y$$

เราจะสร้างข้อมูลขึ้นมาเองจากสมการ

$$y = Ax + v \quad (12)$$

โดย $y \in \mathbb{R}^N$ เมื่อ N คือจำนวนตัวอย่างของข้อมูล ให้ $x \in \mathbb{R}^n, n = 100$ หรือก็คือจำนวนพารามิเตอร์ที่ต้องการประมาณมีทั้งหมด 100 ตัว และ $v \sim \mathcal{N}(0, \sigma^2 I_N)$ โดยให้ $\sigma^2 = \|x\|$ และกำหนดให้ค่าจริงของ x_i บางตัวมีค่าเท่ากับศูนย์และนำไปใช้ในการทดสอบ Wald ต่อไปเพื่อพิจารณาความแม่นยำของการทดสอบ Wald ซึ่งจะพิจารณาจากค่าความผิดพลาดทั้งสองแบบของการทดสอบสมมติฐาน โดยค่าความผิดพลาดแบบที่หนึ่ง (Type I error) คือค่าความน่าจะเป็นที่ค่าพารามิเตอร์ที่ประมาณได้ไม่เท่ากับศูนย์เมื่อกำหนดให้ค่าจริงของพารามิเตอร์เท่ากับศูนย์

$$\text{Type I Error} = \mathbf{Prob}(\hat{x}_i \neq 0 \mid x_i = 0)$$

และค่าความผิดพลาดแบบที่สอง (Type II error) คือค่าความน่าจะเป็นที่ค่าพารามิเตอร์ที่ประมาณได้เท่ากับศูนย์เมื่อกำหนดให้ค่าจริงของพารามิเตอร์ไม่เท่ากับศูนย์

$$\text{Type II Error} = \mathbf{Prob}(\hat{x}_i = 0 \mid x_i \neq 0)$$

ในที่นี้จะได้ฟังก์ชันข้อกำหนดสำหรับการทดสอบ Wald ของ \hat{x}_i ใดๆเมื่อ $i = 1, 2, \dots, 100$ คือ

$$r(\hat{x}) = e_i^T \hat{x}$$

และสำหรับประมาณของเมทริกซ์ค่าความแปรปรวนร่วมของ \hat{x} ของการประมาณกำลังสองน้อยสุดนั้น เป็นที่ทราบกันดีว่าอยู่ในรูป

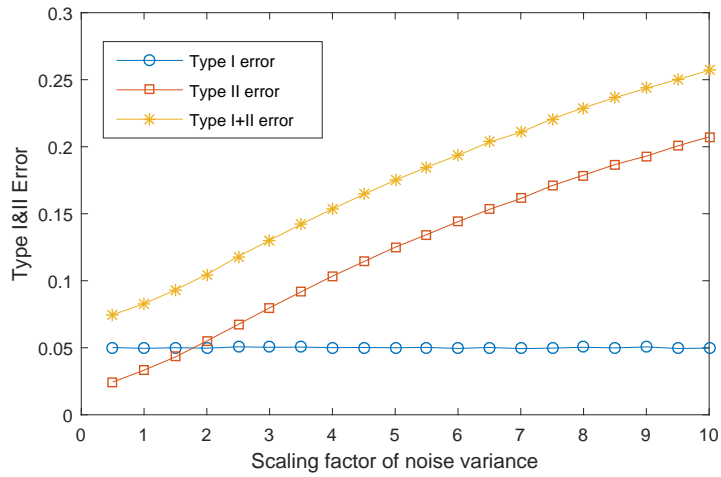
$$\widehat{\mathbf{Avar}}(\hat{x}) = \sigma^2(A^T A)^{-1} \quad \text{โดยที่ } i = 1, 2, \dots, n$$

และค่า W สำหรับ \hat{x}_i ใดๆจากสมการ (4) จะลดรูปเป็น


$$W_i = \hat{x}_i^2 [\widehat{\mathbf{Avar}}(\hat{x})_{i,i}]^{-1}$$

จากนั้นจึงทำการทดสอบ Wald โดยทดสอบบนสมการ (12) ที่สร้างขึ้นทั้งหมด 10,000 ครั้ง แต่ละครั้งจะคงค่า A และ x ไว้ ค่าที่เปลี่ยนไปคือสัญญาณรบกวน v เพื่อหาค่าความผิดพลาดทั้งสองแบบ และพิจารณาค่าต่างๆที่จะมีผลต่อค่าความผิดพลาดทั้งสองแบบที่เกิดขึ้น ในที่นี้จะพิจารณาค่าระดับนัยสำคัญ, ค่าความแปรปรวนของสัญญาณรบกวน และจำนวนตัวอย่างของข้อมูล


จากผลการทดลองจะเห็นว่าค่าความผิดพลาดแบบที่สองจะมีค่าลดลงเมื่อเพิ่มค่าของระดับนัยสำคัญ และจำนวนตัวอย่าง แต่จะมีค่าเพิ่มมากขึ้นเมื่อค่าความแปรปรวนของสัญญาณรบกวนมีค่ามากขึ้น ในขณะที่ค่าความผิดพลาดแบบที่หนึ่งจะมีค่าประมาณเท่ากับค่าระดับนัยสำคัญเสมอ เนื่องจากการทดสอบสมมติฐานได้นิยามให้ค่าระดับนัยสำคัญและค่าความผิดพลาดแบบที่หนึ่งเป็นค่าเดียวกัน



รูป 5: รูปแสดงค่าความผิดพลาดแบบที่หนึ่ง (เส้นสีฟ้า), ค่าความผิดพลาดแบบที่สอง (เส้นสีแดง) และผลรวมค่าความผิดพลาดทั้งสองแบบ (เส้นสีเหลือง) เมื่อเปลี่ยนแปลงค่าความแปรปรวนของสัญญาณรบกวน โดย $\alpha = 0.05$, $N = 150$



รูป 6: รูปแสดงค่าความผิดพลาดแบบที่หนึ่ง (เส้นสีฟ้า), ค่าความผิดพลาดแบบที่สอง (เส้นสีแดง) และผลรวมค่าความผิดพลาดทั้งสองแบบ (เส้นสีเหลือง) เมื่อเปลี่ยนแปลงค่าระดับนัยสำคัญ (α) โดย $\sigma^2 = 10||x||$, $N = 150$



รูป 7: รูปแสดงค่าความผิดพลาดแบบที่หนึ่ง (เส้นสีฟ้า), ค่าความผิดพลาดแบบที่สอง (เส้นสีแดง) และผลรวมค่าความผิดพลาดทั้งสองแบบ (เส้นสีเหลือง) เมื่อเปลี่ยนแปลงจำนวนของตัวอย่าง โดย $\alpha = 0.05$, $\sigma^2 = 10||x||$

6.3 การทดสอบ Wald สำหรับเงื่อนไขความสัมพันธ์ระหว่างเหตุและผล

จาก (3) แบบจำลอง AR มีพารามิเตอร์ที่ต้องการประมาณค่าคือ A ซึ่งเป็นเมทริกซ์ แต่เนื่องจากการทดสอบ Wald ค่าพารามิเตอร์ที่ต้องการประมาณค่าต้องอยู่ในรูปเวกเตอร์ ดังนั้นจึงต้องเปลี่ยนรูปแบบของสมการ (3) ใหม่ โดยพารามิเตอร์ที่ต้องการประมาณของแบบจำลองคือ

$$\theta = [B_{11}^T \ \cdots \ B_{1n}^T \ B_{21}^T \ \cdots \ B_{2n}^T \ \cdots \ B_{nn}^T]^T \in \mathbb{R}^{n^2 p} \quad (13)$$

เมื่อ $B_{ij} = ((A_1)_{ij}, (A_2)_{ij}, \dots, (A_p)_{ij}) \in \mathbb{R}^p$ ดังนั้นแบบจำลอง AR จาก (3) จะเปลี่ยนรูปเป็นรูปแบบของสมการใหม่คือ

$$y(t) = \bar{H}(t)\theta + v(t) \quad (14)$$

เมื่อกำหนดให้ $\bar{y}_i = \begin{bmatrix} y_i(t-1) \\ y_i(t-2) \\ \vdots \\ y_i(t-p) \end{bmatrix}_{p \times 1}$ และ $\bar{y} = \begin{bmatrix} \bar{y}_1 \\ \bar{y}_2 \\ \vdots \\ \bar{y}_n \end{bmatrix}_{np \times 1}$ จะได้ $\bar{H}(t) = \begin{bmatrix} \bar{y}^T & 0 & 0 & \cdots & 0 \\ 0 & \bar{y}^T & 0 & \cdots & 0 \\ 0 & 0 & \bar{y}^T & \cdots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \cdots & \bar{y}^T \end{bmatrix}_{n \times n^2 p}$

จากนั้นจึงใช้การทดสอบ Wald สำหรับทดสอบ $(A_k)_{ij}$ เมื่อ $k = 1, 2, \dots, p$ โดยทดสอบทีละคู่ (i, j) สำหรับ $j > i, i = 1, 2, \dots, n$ ทั้งหมด $n^2 - n$ ครั้ง โดยฟังก์ชันข้อกำหนดในการทดสอบ Wald สำหรับแต่ละคู่ (i, j) คือ

$$r(\theta) = \begin{bmatrix} (A_1)_{ij} \\ (A_2)_{ij} \\ \vdots \\ (A_p)_{ij} \end{bmatrix} \quad (15)$$

หลังจากทำการทดสอบ Wald จะสามารถหาโครงสร้างเชิงสาเหตุของพารามิเตอร์ A ของแบบจำลอง AR ได้ออกมาในรูปแบบโครงสร้างของศูนย์ซึ่งจะถูกกล่าวถึงในหัวข้อที่ 4.2