

การเปรียบเทียบวิธีการประมาณค่าพารามิเตอร์ของการแจกแจงค่าสุดขีดโดยประยุกต์กับ
การพยากรณ์ปริมาณน้ำฝนสูงสุดของกรุงเทพมหานคร

A COMPARING PARAMETER ESTIMATION METHODS OF EXTREME VALUE
DISTRIBUTION APPLIED TO FORECAST MAXIMUM RAINFALL IN BANGKOK
PROVINCE

ภราดร สุขแป้น
PARADORN SUKPAN

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
วิทยาศาสตรมหาบัณฑิต สาขาวิชาสถิติประยุกต์
คณะวิทยาศาสตร์

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

ปีการศึกษา 2567

ลิขสิทธิ์ของคณะวิทยาศาสตร์

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

A COMPARING PARAMETER ESTIMATION METHODS OF EXTREME VALUE
DISTRIBUTION APPLIED TO FORECAST MAXIMUM RAINFALL IN BANGKOK
PROVINCE



A THESIS SUBMITTED IN PARTIAL FULFILLMENT OF THE REQUIREMENTS
FOR THE DEGREE OF MASTER OF SCIENCE PROGRAM IN APPLIED STATISTICS

SCHOOL OF SCIENCE

KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

2024

COPYRIGHT OF SCHOOL OF SCIENCE

KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

ชื่อเรื่อง	การเปรียบเทียบวิธีการประมาณค่าพารามิเตอร์ของการแจกแจงค่าสุดขีด โดยประยุกต์กับการพยากรณ์ปริมาณน้ำฝนสูงสุดของกรุงเทพมหานคร
นักศึกษา	ภราดร สุขแป้น
รหัสประจำตัว	66056063
ปริญญา	วิทยาศาสตรมหาบัณฑิต สาขาวิชาสถิติประยุกต์
ปีการศึกษา	2567
อาจารย์ที่ปรึกษาหลัก	รองศาสตราจารย์ ดร.อัชฌา อระวีพร

บทคัดย่อ

การศึกษานี้มีวัตถุประสงค์เพื่อเปรียบเทียบวิธีการประมาณค่าพารามิเตอร์การแจกแจงค่าสุดขีดวงนัยทั่วไปและการแจกแจงพารेटอวงนัยทั่วไปซึ่งประกอบไปด้วยพารามิเตอร์บ่งตำแหน่ง พารามิเตอร์บ่งขนาด และพารามิเตอร์บ่งรูปร่าง และประยุกต์ใช้กับข้อมูลปริมาณน้ำฝนสูงสุดในกรุงเทพมหานครระหว่างปี พ.ศ. 2537 ถึง พ.ศ. 2566 โดยใช้ในการแจกแจงค่าสุดขีดวงนัยทั่วไปสำหรับปริมาณน้ำฝนสูงสุดรายปี และการแจกแจงพารेटอวงนัยทั่วไปสำหรับปริมาณน้ำฝนสูงสุดรายเดือนซึ่งใช้ค่าเกณฑ์ต่างกัน วิเคราะห์ข้อมูลจาก 4 สถานี ได้แก่ ศูนย์การประชุมแห่งชาติสิริกิติ์ ดอนเมือง บางนา และคลองเตย โดยประมาณพารามิเตอร์ของแต่ละการแจกแจงใช้ 4 วิธี ได้แก่ วิธีภาวะน่าจะเป็นสูงสุด วิธีภาวะน่าจะเป็นสูงสุดทั่วไป วิธีของเบส์ และวิธีโมเมนต์เชิงเส้น โดยใช้เกณฑ์คัดเลือก ได้แก่ ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองสำหรับการจำลองข้อมูล และค่าเฉลี่ยของเปอร์เซ็นต์ความผิดพลาดสัมบูรณ์สำหรับข้อมูลปริมาณน้ำฝนสูงสุด ผลการศึกษาพบว่า ในส่วนของข้อมูลจำลองสำหรับการแจกแจงค่าสุดขีดวงนัยทั่วไปนั้น วิธีภาวะน่าจะเป็นสูงสุด วิธีภาวะน่าจะเป็นสูงสุดทั่วไป และวิธีโมเมนต์เชิงเส้น ให้ประสิทธิภาพสูงสุดสำหรับข้อมูลที่มีรูปแบบการแจกแจงไวส์บูล กัมเบล และฟรีเซท ตามลำดับ สำหรับการจำลองข้อมูลจากการแจกแจงพารेटอวงนัยทั่วไปนั้น วิธีภาวะน่าจะเป็นสูงสุด วิธีภาวะน่าจะเป็นสูงสุดทั่วไป และวิธีโมเมนต์เชิงเส้น ให้ประสิทธิภาพสูงสุดสำหรับข้อมูลที่มีรูปแบบทางสั้น ทางกลาง และทางหนา ตามลำดับ สำหรับปริมาณน้ำฝนสูงสุดรายปี การแจกแจงค่าสุดขีดวงนัยทั่วไปที่ประมาณค่าด้วยวิธีภาวะน่าจะเป็นสูงสุดทั่วไปให้ตัวแบบที่เหมาะสมที่สุดสำหรับสถานีศูนย์การประชุมแห่งชาติสิริกิติ์และคลองเตย ขณะที่วิธีภาวะน่าจะเป็นสูงสุดเหมาะกับสถานีบางนา และวิธีโมเมนต์เชิงเส้นเหมาะกับสถานีดอนเมือง สำหรับปริมาณน้ำฝนสูงสุดรายเดือน การแจกแจงพารेटอวงนัยทั่วไปให้ตัวแบบที่เหมาะสม

ที่สุดเมื่อใช้วิธีโม่เมนต์เชิงเส้นในทุกสถานี โดยประสิทธิภาพของตัวแบบขึ้นอยู่กับทางเลือกค่าเกณฑ์ที่เหมาะสม นอกจากนี้ ค่าประมาณระดับการเกิดซ้ำของปริมาณน้ำฝนสูงสุดทั้งรายปีและรายเดือนมีแนวโน้มเพิ่มขึ้นในทุกช่วงเวลา และมีอัตราการเพิ่มขึ้นของระดับการเกิดซ้ำอย่างรวดเร็ว ดังนั้นหน่วยงานที่เกี่ยวข้องควรให้ความสำคัญกับมาตรการป้องกันและบรรเทาอุทกภัย เนื่องจากแนวโน้มการเกิดซ้ำของปริมาณน้ำฝนอยู่ในระดับสูงกว่าสถานีอื่น ๆ

คำสำคัญ: การแจกแจงค่าสุดขีดน้อยทั่วไป การแจกแจงพาราเรโตนน้อยทั่วไป ค่าสุดขีด ระดับการเกิดซ้ำ



Title A COMPARING PARAMETER ESTIMATION METHODS OF
EXTREME VALUE DISTRIBUTION APPLIED TO FORECAST
MAXIMUM RAINFALL IN BANGKOK PROVINCE

Student PARADORN SUKPAN

Student ID 66056063

Degree Master of Science Program in Applied Statistics

Academic Year 2024

Advisor Associate Professor AUTCHA ARAVEEPORN, Ph.D.

ABSTRACT

This study aims to compare parameter estimation methods for the Generalized Extreme Value Distribution (GEVD) and the Generalized Pareto Distribution (GPD), both of which include location, scale, and shape parameters. These distributions are applied to analyze the maximum rainfall data in Bangkok from 1994 to 2023, where GEVD is used for annual maximum rainfall and GPD for monthly maximum rainfall with varying threshold values. Data from four stations—Queen Sirikit National Convention Center, Don Mueang, Bang Na, and Khlong Toei—are analyzed using four parameter estimation methods: Maximum Likelihood Estimation (ML), Generalized Maximum Likelihood Estimation (GML), Bayesian Estimation, and the L-Moments Method. The selection criteria include the Mean Squared Error for simulated data and the Mean Absolute Percentage Error for observed rainfall data. The findings indicate that for simulated GEVD data, ML, GML, and L-Moments provide the best performance for Weibull, Gumbel, and Fréchet distributions, respectively. For simulated GPD data, ML, GML, and L-Moments perform optimally for short-tailed, medium-tailed, and heavy-tailed distributions, respectively. For the actual annual maximum rainfall data, GEVD estimated using GML provides the best fit for the Queen Sirikit National Convention Center and Khlong Toei stations, while ML is the most suitable for Bang Na, and L-Moments for Don Mueang. For monthly maximum rainfall, GPD estimated using L-Moments is the

most appropriate for all stations, depending on the selected threshold value. Additionally, the estimated return levels of maximum rainfall, both annually and monthly, exhibit an increasing trend over time, with a particularly rapid rise at the Queen Sirikit National Convention Center and Bang Na stations. Therefore, relevant authorities should prioritize flood prevention and mitigation measures due to the heightened recurrence of extreme rainfall events compared to other stations.

Keywords: Generalized Extreme Value Distribution, Generalized Pareto Distribution, Extreme Value, Return Level



กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงลงได้ด้วยความช่วยเหลือและการสนับสนุนจากหลายฝ่าย ผู้วิจัยขอกราบขอบพระคุณ รองศาสตราจารย์ ดร.อัครฉภา อระวีพร อาจารย์ที่ปรึกษาวิทยานิพนธ์ ที่ให้คำแนะนำ องค์ความรู้ และข้อเสนอแนะที่เป็นประโยชน์ต่อการดำเนินงานวิจัย ตลอดจนให้กำลังใจและสนับสนุนผู้วิจัยในทุกขั้นตอนของการศึกษา

นอกจากนี้ ผู้วิจัยขอขอบพระคุณ ประธานกรรมการ รศ.ดร. วราฤทธิ์ พานิชกิจโกศลกุล อาจารย์ประจำภาควิชาคณิตศาสตร์และสถิติ คณะวิทยาศาสตร์และเทคโนโลยีมหาวิทยาลัย

ธรรมศาสตร์ (ศูนย์รังสิต) และผู้ช่วยศาสตราจารย์ ดร.พรพรรณทิพา วาณิชจิรัฐติกาล อาจารย์บัณฑิตประจำผู้เป็นคณะกรรมการสอบที่ให้ข้อคิดเห็นอันมีค่าและช่วยชี้แนะให้ผู้วิจัยสามารถปรับปรุงและพัฒนางานวิจัยให้สมบูรณ์ยิ่งขึ้น

ขอขอบพระคุณ กองทุนวิจัย สถาบันเทคโนโลยีพระจอมเกล้าคุณทหารลาดกระบัง ประจำปี 2566 ที่ให้ทุนสนับสนุนการวิจัยสำหรับอาจารย์ที่ปรึกษาของผู้ช่วยวิจัยระดับบัณฑิตศึกษา ซึ่งเป็นปัจจัยสำคัญที่ช่วยให้การศึกษาครั้งนี้สำเร็จลุล่วงไปได้

ขอขอบพระคุณคณาจารย์ภาควิชาสถิติ คณะวิทยาศาสตร์ สถาบันเทคโนโลยีพระจอมเกล้าคุณทหารลาดกระบัง และครอบครัวที่เป็นแรงผลักดันสำคัญ คอยให้กำลังใจและสนับสนุนผู้วิจัยเสมอมา ความสำเร็จในครั้งนี้เกิดขึ้นได้จากทุกการสนับสนุนที่ได้รับ และขอขอบคุณเพื่อน พี่น้อง ที่ให้คำปรึกษาและช่วยเหลือให้การทำงานมาโดยตลอดจนวิทยานิพนธ์นี้สำเร็จไปได้ด้วยดี

ภราดร สุขแป้น

สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....ค	ค
บทคัดย่อภาษาอังกฤษ.....จ	จ
กิตติกรรมประกาศ.....ช	ช
สารบัญ.....ช	ช
สารบัญตาราง.....ฉ	ฉ
สารบัญรูปภาพ.....ต	ต
บทที่ 1 บทนำ..... 1	1
1.1 ความเป็นมาและความสำคัญของปัญหา..... 1	1
1.2 วัตถุประสงค์ของงานวิจัย..... 6	6
1.3 ขอบเขตของงานวิจัย..... 6	6
1.4 เกณฑ์การตัดสินใจ..... 8	8
1.5 ประโยชน์ที่คาดว่าจะได้รับ..... 8	8
1.6 นิยามศัพท์..... 9	9
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง..... 10	10
2.1 ทฤษฎีที่เกี่ยวข้อง..... 11	11
2.1.1 สถิติเชิงพรรณนา (Descriptive Statistics)..... 11	11
2.1.2 การวิเคราะห์ค่าสุดขีด (Extreme Value Analysis)..... 14	14
2.2 วิธีการประมาณค่าพารามิเตอร์ในทางสถิติที่ใช้ในงานวิจัย..... 19	19
2.2.1 วิธีภาวะน่าจะเป็นสูงสุด (Maximum Likelihood Estimation: ML)..... 19	19
2.2.2 วิธีภาวะน่าจะเป็นสูงสุดทั่วไป (Generalized Maximum Likelihood Method: GML)..... 21	21

สารบัญ (ต่อ)

	หน้า
2.2.3 วิธีของเบส์ (Bayesian Method).....	24
2.2.4 วิธีโมเมนต์เชิงเส้น (L-Moment Estimation).....	27
2.3 ระดับการเกิดซ้ำ.....	29
2.4 เกณฑ์การคัดเลือก.....	30
2.4.1 วิธีค่าเฉลี่ยความคลาดเคลื่อนกำลังสอง (Mean Square Error: MSE)	30
2.4.2 วิธีค่าเฉลี่ยของเปอร์เซ็นต์ความผิดพลาดสัมบูรณ์ (Mean Absolute Percentage Error: MAPE).....	31
2.5 งานวิจัยที่เกี่ยวข้อง.....	31
บทที่ 3 วิธีการดำเนินงานวิจัย.....	35
3.1 การเก็บรวบรวมข้อมูล.....	35
3.2 การวิเคราะห์ข้อมูล.....	38
3.2.1 ข้อมูลจำลอง.....	38
3.2.2 ข้อมูลจริง.....	39
3.3 การสรุปและอภิปรายผล.....	40
3.4 ขั้นตอนที่ใช้ในการวิจัย.....	41
บทที่ 4 ผลการวิจัยและการอภิปรายผล.....	45
4.1 การแจกแจงค่าสุดขีดวางนัยทั่วไป.....	45
4.1.1 การประมาณค่าพารามิเตอร์สำหรับข้อมูลจำลอง.....	45
4.1.2 ค่าสถิติพื้นฐานสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายปี.....	51
4.1.3 การประมาณค่าพารามิเตอร์สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายปี.....	53
4.1.4 ระดับการเกิดซ้ำสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายปี.....	55

สารบัญ (ต่อ)

	หน้า
4.2 การแจกแจงพารโตนวามันยัทั่วยุ.....	63
4.2.1 การประมาณค่าพารามิเตอร์สำหรับข้อมูลจำลอง.....	63
4.2.2 ค่าสถิติพื้นฐานสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือน	82
4.2.3 การประมาณค่าพารามิเตอร์สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือน	83
4.2.4 ระดับการเกิดซ้ำสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือน.....	89
บทที่ 5 สรุปผลการวิจัยและข้อเสนอแนะ	106
5.1 สรุปผลการวิจัยสำหรับข้อมูลจำลอง	106
5.1.1 ข้อมูลจำลอง จากการแจกแจงค่าสุดขีดวามันยัทั่วยุ.....	106
5.1.2 ข้อมูลจำลอง จากการแจกแจงพารโตนวามันยัทั่วยุ.....	106
5.2 สรุปผลการวิจัยสำหรับข้อมูลจริง.....	107
5.2.1 ข้อมูลปริมาณน้ำฝนสูงสุดรายปี สำหรับตัวแบบจากการแจกแจงค่าสุดขีดวามันยัทั่วยุ.....	107
5.2.2 ข้อมูลปริมาณน้ำฝนสูงสุดรายเดือน สำหรับตัวแบบจากการแจกแจงพารโตนวามันยัทั่วยุ.....	108
5.3 ข้อเสนอแนะ.....	108
บรรณานุกรม.....	110
ภาคผนวก.....	114
ภาคผนวก ก.....	115
ภาคผนวก ข.....	132
ประวัติผู้เขียน.....	181

สารบัญตาราง

ตารางที่	หน้า
4.1 ผลการจำลองข้อมูลการประมาณค่าพารามิเตอร์กรณี $\mu = 3, \sigma = 1$ และ $\xi = -0.7$	46
4.2 ผลการจำลองข้อมูลการประมาณค่าพารามิเตอร์กรณี $\mu = 3, \sigma = 1$ และ $\xi = 0$	48
4.3 ผลการจำลองข้อมูลการประมาณค่าพารามิเตอร์กรณี $\mu = 3, \sigma = 1$ และ $\xi = 0.7$	50
4.4 ค่าสถิติพื้นฐานสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายปีแต่ละสถานี ตั้งแต่ พ.ศ. 2537 - 2566	52
4.5 ค่าประมาณพารามิเตอร์สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายปีของสถานี ศูนย์การประชุมแห่งชาติสิริกิติ์.....	53
4.6 ค่าประมาณพารามิเตอร์สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายปีของสถานีดอนเมือง.....	54
4.7 ค่าประมาณพารามิเตอร์สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายปีของสถานีบางนา.....	54
4.8 ค่าประมาณพารามิเตอร์สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายปีของสถานีคลองเตย.....	55
4.9 ระดับการเกิดซ้ำสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายปีแต่ละวิธีการของสถานี ศูนย์การประชุมแห่งชาติสิริกิติ์.....	56
4.10 ระดับการเกิดซ้ำสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายปีแต่ละวิธีการของสถานีดอนเมือง.....	57
4.11 ระดับการเกิดซ้ำสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายปีแต่ละวิธีการของสถานีบางนา.....	58
4.12 ระดับการเกิดซ้ำสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายปีแต่ละวิธีการของสถานีคลองเตย.....	59
4.13 ผลการจำลองข้อมูลการประมาณค่าพารามิเตอร์กรณี $\mu = 2, \sigma = 2, \xi = -0.3$ และกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 85.....	64
4.14 ผลการจำลองข้อมูลการประมาณค่าพารามิเตอร์กรณี $\mu = 2, \sigma = 2, \xi = -0.3$ และกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 90.....	66
4.15 ผลการจำลองข้อมูลการประมาณค่าพารามิเตอร์กรณี $\mu = 2, \sigma = 2, \xi = -0.3$ และกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 95.....	68
4.16 ผลการจำลองข้อมูลการประมาณค่าพารามิเตอร์กรณี $\mu = 2, \sigma = 2, \xi = 0$ และกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 85.....	70
4.17 ผลการจำลองข้อมูลการประมาณค่าพารามิเตอร์กรณี $\mu = 2, \sigma = 2, \xi = 0$ และกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 90.....	72
4.18 ผลการจำลองข้อมูลการประมาณค่าพารามิเตอร์กรณี $\mu = 2, \sigma = 2, \xi = 0$ และกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 95.....	74

สารบัญตาราง (ต่อ)

ตารางที่	หน้า
4.19 ผลการจำลองข้อมูลการประมาณค่าพารามิเตอร์กรณี $\mu = 2, \sigma = 2, \xi = 0.3$ และกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 85.....	76
4.20 ผลการจำลองข้อมูลการประมาณค่าพารามิเตอร์กรณี $\mu = 2, \sigma = 2, \xi = 0.3$ และกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 90.....	78
4.21 ผลการจำลองข้อมูลการประมาณค่าพารามิเตอร์กรณี $\mu = 2, \sigma = 2, \xi = 0.3$ และกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 95.....	80
4.22 ค่าสถิติพื้นฐานสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนแต่ละสถานี ตั้งแต่ พ.ศ. 2537 – 2566.....	82
4.23 ค่าประมาณพารามิเตอร์สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนของสถานี ศูนย์การประชุมแห่งชาติสิริกิติ์ เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 85.....	83
4.24 ค่าประมาณพารามิเตอร์สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนของสถานี ศูนย์การประชุมแห่งชาติสิริกิติ์ เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 90.....	84
4.25 ค่าประมาณพารามิเตอร์สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนของสถานี ศูนย์การประชุมแห่งชาติสิริกิติ์ เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 95.....	84
4.26 ค่าประมาณพารามิเตอร์สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนของสถานี ดอนเมือง เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 85.....	85
4.27 ค่าประมาณพารามิเตอร์สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนของสถานี ดอนเมือง เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 90.....	85
4.28 ค่าประมาณพารามิเตอร์สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนของสถานี ดอนเมือง เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 95.....	86
4.29 ค่าประมาณพารามิเตอร์สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนของสถานี บางนา เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 85.....	86
4.30 ค่าประมาณพารามิเตอร์สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนของสถานี บางนา เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 90.....	87
4.31 ค่าประมาณพารามิเตอร์สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนของสถานี บางนา เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 95.....	87

สารบัญตาราง (ต่อ)

ตารางที่	หน้า
4.45 ระดับการเกิดซ้ำสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนในรอบปีแต่ละวิธีการของสถานี คลองเตย เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 90.....	100
4.46 ระดับการเกิดซ้ำสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนในรอบปีแต่ละวิธีการของสถานี คลองเตย เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 95.....	101



สารบัญรูปลูกภาพ

รูปที่		หน้า
2.1	การแจกแจงปกติ 3 ลักษณะที่มีค่าส่วนเบี่ยงเบนมาตรฐานต่างกัน.....	12
2.2	ลักษณะการกระจายของข้อมูลที่มีการแจกแจงแบบสมมาตร (Symmetrical Distribution) การแจกแจงแบบเบ้ขวา (Positive Distribution) และการแจกแจงแบบเบ้ซ้าย (Negative Distribution)	13
2.3	การแจกแจง 3 ลักษณะตามค่าอิกซอส-เคอร์โทซิส.....	14
2.4	การเลือกค่าสถิติสำหรับแบบจำลอง GEVD และ GPD.....	15
2.5	การแจกแจงค่าสถิติวงนัยทั่วไป เมื่อกำหนดพารามิเตอร์บ่งรูปร่างมีค่าต่าง ๆ.....	16
2.6	การแจกแจงพาริตอวงนัยทั่วไป เมื่อกำหนดพารามิเตอร์บ่งรูปร่างมีค่าต่าง ๆ.....	18
3.1	ปริมาณน้ำฝนสูงสุดรายปี สถานีศูนย์การประชุมแห่งชาติสิริกิติ์ ตั้งแต่ พ.ศ. 2537 – 2566.....	35
3.2	ปริมาณน้ำฝนสูงสุดรายปี สถานีดอนเมือง ตั้งแต่ พ.ศ. 2537 – 2566.....	36
3.3	ปริมาณน้ำฝนสูงสุดรายปี สถานีบางนา ตั้งแต่ พ.ศ. 2537 – 2566.....	36
3.4	ปริมาณน้ำฝนสูงสุดรายปี สถานีคลองเตย ตั้งแต่ พ.ศ. 2537 – 2566.....	36
3.5	ปริมาณน้ำฝนสูงสุดรายเดือน สถานีศูนย์การประชุมแห่งชาติสิริกิติ์ ตั้งแต่ พ.ศ. 2537 – 2566.....	37
3.6	ปริมาณน้ำฝนสูงสุดรายเดือน สถานีดอนเมือง ตั้งแต่ พ.ศ. 2537 – 2566.....	37
3.7	ปริมาณน้ำฝนสูงสุดรายเดือน สถานีบางนา ตั้งแต่ พ.ศ. 2537 – 2566.....	37
3.8	ปริมาณน้ำฝนสูงสุดรายเดือน สถานีคลองเตย ตั้งแต่ พ.ศ. 2537 – 2566.....	38
3.9	การแจกแจงค่าสถิติวงนัยทั่วไปภายใต้พารามิเตอร์บ่งรูปร่างที่แตกต่างกัน.....	38
3.10	การแจกแจงพาริตอวงนัยทั่วไปภายใต้พารามิเตอร์บ่งรูปร่างที่แตกต่างกัน.....	39
3.11	กระบวนการในการประมาณค่าพารามิเตอร์จากการแจกแจง GEVD.....	41
3.12	กระบวนการในการประมาณค่าพารามิเตอร์จากการแจกแจง GPD.....	42
3.13	กระบวนการในการประมาณค่าพารามิเตอร์จากการแจกแจง GEVD โดยใช้ข้อมูลจริง.....	43
3.14	กระบวนการในการประมาณค่าพารามิเตอร์จากการแจกแจง GPD โดยใช้ข้อมูลจริง.....	44
4.1	ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองของประมาณค่าพารามิเตอร์กรณี $\mu = 3, \sigma = 1$ และ $\xi = -0.7$	47

สารบัญรูปรภาพ (ต่อ)

รูปที่	หน้า
4.2 ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองของประมาณค่าพารามิเตอร์กรณี $\mu = 3, \sigma = 1$ และ $\xi = 0$	49
4.3 ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองของประมาณค่าพารามิเตอร์กรณี $\mu = 3, \sigma = 1$ และ $\xi = 0.7$	51
4.4 ฮิสโตแกรมข้อมูลปริมาณน้ำฝนสูงสุดรายปีสำหรับแต่ละสถานีระหว่าง พ.ศ. 2537 - 2566.....	52
4.5 กราฟระดับการเกิดซ้ำของปริมาณน้ำฝนสูงสุดรายปีตามรอบปีการเกิด จำแนกราย สถานีตรวจวัดระดับน้ำ.....	60
4.6 แผนภาพ Diagnostic Plot ของข้อมูลปริมาณน้ำฝนสูงสุดรายปี สถานีศูนย์การ ประชุมแห่งชาติสิริกิติ์.....	60
4.7 แผนภาพ Diagnostic Plot ของข้อมูลปริมาณน้ำฝนสูงสุดรายปี สถานีดอนเมือง.....	61
4.8 แผนภาพ Diagnostic Plot ของข้อมูลปริมาณน้ำฝนสูงสุดรายปี สถานีบางนา.....	61
4.9 แผนภาพ Diagnostic Plot ของข้อมูลปริมาณน้ำฝนสูงสุดรายปี สถานีคลองเตย.....	62
4.10 ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองของประมาณค่าพารามิเตอร์กรณี $\mu = 2,$ $\sigma = 2, \xi = -0.3$ และกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 85.....	65
4.11 ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองของประมาณค่าพารามิเตอร์กรณี $\mu = 2,$ $\sigma = 2, \xi = -0.3$ และกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 90.....	67
4.12 ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองของประมาณค่าพารามิเตอร์กรณี $\mu = 2,$ $\sigma = 2, \xi = -0.3$ และกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 95.....	69
4.13 ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองของประมาณค่าพารามิเตอร์กรณี $\mu = 2,$ $\sigma = 2, \xi = 0$ และกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 85.....	71
4.14 ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองของประมาณค่าพารามิเตอร์กรณี $\mu = 2,$ $\sigma = 2, \xi = 0$ และกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 90.....	73
4.15 ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองของประมาณค่าพารามิเตอร์กรณี $\mu = 2,$ $\sigma = 2, \xi = 0$ และกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 95.....	75

สารบัญรูปภาพ (ต่อ)

รูปที่	หน้า
4.16 ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองของประมาณค่าพารามิเตอร์กรณี $\mu = 2$, $\sigma = 2, \xi = 0.3$ และกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 85.....	77
4.17 ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองของประมาณค่าพารามิเตอร์กรณี $\mu = 2$, $\sigma = 2, \xi = 0.3$ และกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 90.....	79
4.18 ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองของประมาณค่าพารามิเตอร์กรณี $\mu = 2$, $\sigma = 2, \xi = 0.3$ และกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 95.....	81
4.19 อีส์ไต่แกรมข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนสำหรับแต่ละสถานี.....	83
4.20 กราฟระดับการเกิดซ้ำของปริมาณน้ำฝนสูงสุดรายเดือนตามรอบปีการเกิด จำแนกรายสถานี ตรวจวัดระดับน้ำ.....	102
4.21 แผนภาพ Diagnostic Plot ข้อมูลปริมาณน้ำฝนสูงสุดรายเดือน สถานีศูนย์การ ประชุมแห่งชาติสิริกิติ์.....	102
4.22 แผนภาพ Diagnostic Plot ข้อมูลปริมาณน้ำฝนสูงสุดรายเดือน สถานีดอนเมือง.....	103
4.23 แผนภาพ Diagnostic Plot ข้อมูลปริมาณน้ำฝนสูงสุดรายเดือน สถานีบางนา.....	104
4.24 แผนภาพ Diagnostic Plot ข้อมูลปริมาณน้ำฝนสูงสุดรายเดือน สถานีคลองเตย.....	104

บทที่ 1

บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา

สถิติเชิงอนุมาน (Inference Statistics) เป็นแขนงหนึ่งของสถิติที่ใช้ในการวิเคราะห์ข้อมูลจากตัวอย่าง (Sample) เพื่อสรุปและคาดเดาเกี่ยวกับพารามิเตอร์ (Parameter) ของประชากร (Population) เนื่องจากการเก็บข้อมูลจากประชากรทั้งหมดมักทำไม่ได้เพราะข้อจำกัดด้านค่าใช้จ่ายและเวลา จึงต้องใช้ตัวอย่างในการประมาณค่าพารามิเตอร์ เช่น ค่าเฉลี่ย (Mean) หรือค่าความแปรปรวน (Variance) ของประชากร จากข้อมูลจากตัวอย่างซึ่งจะถูกนำมาคำนวณเป็นค่าสถิติ (Statistic) เพื่อใช้ในการอนุมานค่าพารามิเตอร์ ซึ่งการอนุมานนี้สามารถทำได้โดยการประมาณค่า (Estimation) รวมถึงการทดสอบสมมติฐาน (Hypothesis Testing) เพื่อตรวจสอบข้อสรุปเกี่ยวกับค่าพารามิเตอร์ (วีระศักดิ์, 2557) กระบวนการนี้ช่วยให้สามารถนำข้อมูลจากตัวอย่างมาทำความเข้าใจประชากรได้อย่างมีประสิทธิภาพ แม้ว่าจะมีความไม่แน่นอนจากการสุ่มตัวอย่างก็ตาม

การประมาณทางสถิติเป็นกระบวนการที่ใช้คาดเดาค่าของพารามิเตอร์ของประชากรโดยใช้ข้อมูลจากตัวอย่าง ซึ่งสามารถแบ่งออกได้เป็นสองประเภทหลัก ได้แก่ การประมาณค่าแบบจุด (Point Estimation) และการประมาณค่าแบบช่วง (Interval Estimation) การประมาณค่าแบบจุดคือการใช้ค่าสถิติจากตัวอย่างมาเป็นตัวแทนของค่าพารามิเตอร์ ซึ่งให้ค่าเดียว การประมาณค่าแบบจุดนี้มีคุณสมบัติสำคัญหลัก ๆ คือ ไม่เอนเอียง (Unbiasedness) คงเส้นคงวา (Consistency) พอเพียง (Sufficient) และประสิทธิภาพ (Efficiency) (ธนวัฒน์, 2560) แม้ว่าการประมาณค่าแบบจุดจะให้ค่าเดียวที่ดีที่สุดตามข้อมูลตัวอย่าง แต่มีข้อจำกัดในเรื่องความไม่แน่นอน เนื่องจากไม่สามารถบอกถึงความผันผวนจากการสุ่มตัวอย่างได้ ส่วนการประมาณค่าแบบช่วง (Interval Estimation) จะให้ช่วงของค่าที่คาดว่าพารามิเตอร์ของประชากรจะอยู่ในช่วงนั้น พร้อมทั้งระบุระดับความเชื่อมั่น (Confidence Level) เช่น 95% หรือ 99% ซึ่งบ่งชี้ถึงความน่าจะเป็นที่ค่าพารามิเตอร์จริงจะอยู่ในช่วงที่คำนวณได้ และช่วยให้เห็นภาพความไม่แน่นอนที่มาจากสุ่มตัวอย่างมากขึ้น

การประมาณค่าพารามิเตอร์เป็นขั้นตอนสำคัญในสถิติเชิงอนุมาน โดยมีเป้าหมายเพื่อหาค่าตัวแทนของคุณลักษณะในประชากร เช่น ค่าเฉลี่ย หรือค่าความแปรปรวน ซึ่งไม่สามารถวัดได้จากประชากรทั้งหมด การประมาณค่าพารามิเตอร์จากตัวอย่างสามารถทำได้หลายวิธี ขึ้นอยู่กับข้อมูลและลักษณะของการแจกแจงต่าง ๆ และลักษณะของปัญหาที่ต้องการแก้ไข โดยวิธีการประมาณ

ค่าพารามิเตอร์ที่สำคัญ ได้แก่ วิธีภาวะน่าจะเป็นสูงสุด (Maximum Likelihood Estimation: ML) วิธีของเบส์ (Bayes) และวิธีโมเมนต์ (Moments) เช่นงานวิจัยของ Araveeporn (2014) ได้ศึกษาการประมาณค่าพารามิเตอร์ของการแจกแจงปัวซอง (Poisson Distribution) ด้วยวิธีภาวะน่าจะเป็นสูงสุด วิธีมาร์คอฟเชน มอนติคาร์โล (Markov Chain Monte Carlo) วิธีของเบส์ อัณมณี และอัชฌา (2561) ได้ทำการเปรียบเทียบการประมาณค่าพารามิเตอร์ของการแจกแจงทวินามเชิงลบ (Negative Binomial Distribution) ด้วยวิธีภาวะน่าจะเป็นสูงสุด วิธีของเบส์ และวิธีมาร์คอฟเชน มอนติคาร์โล ดุสิต (2561) ได้ศึกษาการประมาณค่าพารามิเตอร์ของการแจกแจงไวล์บูล (Weibull Distribution) เมื่อข้อมูลถูกตรวจตัดแบบสุ่ม ด้วยวิธีภาวะน่าจะเป็นสูงสุด วิธีโมเมนต์ วิธีของเบส์ และวิธีกำลังสองน้อยที่สุด (Least Squares) Luengo et al. (2020) ได้ศึกษาการประมาณค่าพารามิเตอร์ด้วยวิธีมอนติคาร์โล โดยเปรียบเทียบกับวิธีภาวะน่าจะเป็นสูงสุดของการแจกแจงคงที่ (Stationary Distribution)

ทฤษฎีค่าสุดขีด (Extreme Value Theorem) ได้ถูกศึกษาและพัฒนาโดยกล่าวถึงคุณสมบัติของเหตุการณ์ที่มีตัวแปรสุ่มซึ่งจัดอยู่ในลักษณะที่เรียกว่า ค่าสุดขีด (Extreme Value) อาจจะเป็นค่าสูงสุดหรือต่ำสุด พร้อมทั้งศึกษารูปแบบการแจกแจงความน่าจะเป็นของตัวแปรสุ่มเหล่านี้ การวิเคราะห์ข้อมูลเมื่อข้อมูลมีค่าสุดขีดเกิดขึ้น นักวิเคราะห์ส่วนใหญ่จะตัดข้อมูลส่วนนั้นทิ้งไปไม่นำมาพิจารณา เนื่องจากมีความซับซ้อนและยุ่งยากในการวิเคราะห์ (ปิยภัทร และอรุณ, 2558) แต่ในความเป็นจริงหากต้องการทราบถึงความน่าจะเป็นในการเกิดขึ้นของเหตุการณ์ที่มีค่าสูงสุดหรือต่ำสุดซึ่งอยู่ในส่วนของปลายหางซึ่งมีค่าน้อยมาก เช่น ปริมาณน้ำฝนสูงสุด-ต่ำสุดในแต่ละวัน ความเร็วลมสูงสุดในรอบเดือน อุณหภูมิสูงสุด-ต่ำสุดในแต่ละวัน ในการวิเคราะห์แบบจำลองค่าสุดขีดด้วยทฤษฎีค่าสุดขีดสามารถแบ่งออกได้เป็น 2 ประเภทตามลักษณะของการเลือกข้อมูลค่าสุดขีดที่นำมาวิเคราะห์ ได้แก่ วิธีกำหนดช่วงเพื่อหาค่าสูงสุด (Block Maxima Model) ซึ่งใช้กับข้อมูลในช่วงคาบเวลาที่สนใจ เช่น รายปี รายเดือน รายวัน โดยเลือกข้อมูลที่มีค่าสูงสุดหรือต่ำสุดในแต่ละช่วงคาบเวลามาทำการวิเคราะห์ วิธีการดังกล่าวเหมาะสมกับการแจกแจงค่าสุดขีดวงนัยทั่วไป (Generalized Extreme Value Distribution: GEVD) และวิธีค่าสูงสุดที่มีค่าเกินเกณฑ์ที่กำหนด (Peak Over Threshold Model) เหมาะสำหรับข้อมูลที่มีจำนวนมาก หรือเป็นข้อมูลที่เก็บรวบรวมเป็นรายวัน มีการกำหนดค่าเกณฑ์ (Threshold) ที่เหมาะสมกับข้อมูลที่จะนำมาวิเคราะห์ และพิจารณาความไม่เป็นอิสระของข้อมูล แก้ไขโดยการจัดกลุ่มค่าสุดขีด (Declustering) ที่มีค่าเกินกว่าเกณฑ์ วิธีการดังกล่าวเหมาะสมกับการแจกแจงพาราโตวงนัยทั่วไป (Generalized Pareto Distribution: GPD) (ปิยภัทร และอรุณ, 2558) ในทางทฤษฎีค่าสุดขีด จะมีการวิเคราะห์ถึงระดับการเกิดซ้ำ (Return Level) และคาบเวลาการเกิดซ้ำ (Return Period) ซึ่งเป็นการวิเคราะห์ข้อมูลในอดีตเพื่อวิเคราะห์ความถี่ของเหตุการณ์ค่าสุดขีดในรูปแบบของความน่าจะเป็นหรือวิเคราะห์เพื่อหาโอกาสที่เหตุการณ์จะเกิดขึ้นอีก โดยใช้หลัก

ทฤษฎีค่าสุดขีดเพื่อหาปริมาณของค่าสุดขีดของเหตุการณ์ที่จะเกิดขึ้นในคาบเวลาของการเกิดซ้ำ (ปิยภัทร และอรุณ, 2558)

การแจกแจงค่าสุดขีดวงนัยทั่วไป หรือ GEVD เป็นการแจกแจงความน่าจะเป็นที่ประกอบด้วย 3 พารามิเตอร์ คือ พารามิเตอร์บ่งตำแหน่ง (Location Parameter) พารามิเตอร์บ่งขนาด (Scale Parameter) และพารามิเตอร์บ่งรูปร่าง (Shape Parameter) สามารถเขียนการแจกแจงค่าสุดขีดได้ 3 การแจกแจง ประกอบด้วย การแจกแจงกัมเบล (Gumbel Distribution) การแจกแจงฟรีเชท (Fréchet Distribution) และการแจกแจงไวล์บูล (Weibull Distribution) ขึ้นอยู่กับค่าพารามิเตอร์บ่งรูปร่าง (ปิยภัทร และอรุณ, 2558) สำหรับงานวิจัยที่มีการศึกษาเกี่ยวกับทฤษฎีค่าสุดขีดและมุ่งเน้นศึกษาถึงการแจกแจงค่าสุดขีดวงนัยทั่วไปนั้นมีหลากหลายชิ้นงาน เช่น Ng et al. (2022) ได้ทำการศึกษาหาตัวแบบการแจกแจงความน่าจะเป็นที่เหมาะสมสำหรับข้อมูลอุณหภูมิตั้งรายเดือนและรายปีในบริเวณคาบสมุทรมาเลเซีย โดยศึกษาจากตัวแบบการแจกแจงความน่าจะเป็น 10 การแจกแจง โดยมีกรประมาณค่าพารามิเตอร์และทดสอบภาวะสารูปสนิทธิ (Goodness of Fit Tests) ด้วยวิธีการต่าง ๆ อย่างเหมาะสม ผลจากการศึกษาพบว่า การแจกแจงความน่าจะเป็นที่มีจำนวนพารามิเตอร์มากกว่า เป็นตัวแบบที่เหมาะสมสำหรับสถานีตรวจวัดสภาพอากาศแต่ละแห่ง รวมถึงการแจกแจงค่าสุดขีดวงนัยทั่วไป Rehman and Zhang (2023) ได้ทำการวิเคราะห์ความเสี่ยงจากการเกิดแผ่นดินไหวในเขตการมุดตัวของเปลือกโลกมาครานโดยใช้ทฤษฎีค่าสุดขีด และกำหนดค่าพารามิเตอร์จากการแจกแจงค่าสุดขีดวงนัยทั่วไป พบว่าค่าพารามิเตอร์บ่งรูปร่างของการแจกแจงค่าสุดขีดวงนัยทั่วไปมีค่ามากกว่าศูนย์ ทำให้การแจกแจงแบบฟรีเชทซึ่งเป็นรูปแบบหนึ่งของการแจกแจงค่าสุดขีดวงนัยทั่วไปเป็นตัวแบบการแจกแจงที่ดีที่สุดในการคาดการณ์ความรุนแรงในการสั่นสะเทือนของแผ่นดินไหวในบริเวณดังกล่าว

การแจกแจงพาเรโตวงนัยทั่วไป หรือ GPD เป็นการแจกแจงความน่าจะเป็นที่ประกอบด้วย 3 พารามิเตอร์ คือ พารามิเตอร์บ่งตำแหน่ง พารามิเตอร์บ่งขนาด และพารามิเตอร์บ่งรูปร่าง สามารถเขียนการแจกแจงพาเรโตวงนัยทั่วไปได้ 3 การแจกแจง ประกอบด้วย การแจกแจงเลขชี้กำลัง (Exponential Distribution) การแจกแจงพาเรโต (Pareto Distribution) และการแจกแจงแกมมา (Gamma Distribution) ขึ้นอยู่กับค่าพารามิเตอร์บ่งรูปร่าง (ประภาวรณ และปิยภัทร, 2560) สำหรับงานวิจัยที่มีการศึกษาเกี่ยวกับทฤษฎีค่าสุดขีดและมุ่งเน้นศึกษาถึงการแจกแจงพาเรโตวงนัยทั่วไปนั้นมีหลากหลายชิ้นงาน เช่น ธนโชติ และมานัตต์ (2564) ได้ทำการศึกษาหาตัวแบบที่เหมาะสมกับข้อมูลปริมาณน้ำฝนรายเดือนบริเวณลุ่มแม่น้ำปิงตอนบน จังหวัดเชียงใหม่ โดยใช้การแจกแจงพาเรโตวงนัยทั่วไปและเพื่อหาระดับการเกิดซ้ำ ของปริมาณน้ำฝนรายเดือนในรอบปีการเกิดซ้ำต่าง ๆ วิกานดา และคณะ (2566) ได้ทำการวิเคราะห์หาตัวแบบจำลองที่เหมาะสมจากทฤษฎีค่าสุดขีด

สำหรับข้อมูลความสูงของคลื่นทะเลสูงสุดบริเวณรอบ ๆ ชายฝั่งอ่าวไทย โดยเปรียบเทียบ 2 การแจกแจง คือ การแจกแจงค่าสุดขีดวงนัยทั่วไป และการแจกแจงพาราโตวงนัยทั่วไป ใช้วิธีการประมาณค่าพารามิเตอร์ด้วยวิธีภาวะน่าจะเป็นสูงสุด สำหรับการแจกแจงค่าสุดขีดวงนัยทั่วไป และวิธีค่าสูงสุดที่มีค่าเกินเกณฑ์ที่กำหนด สำหรับการแจกแจงพาราโตวงนัยทั่วไป ผลการศึกษาพบว่า ข้อมูลความสูงคลื่นทะเลรอบ ๆ ชายฝั่งอ่าวไทยของพื้นที่ที่ผู้วิจัยเลือก เหมาะสมกับการแจกแจงพาราโตวงนัยทั่วไป จากงานวิจัยต่าง ๆ ที่มีการศึกษาเกี่ยวกับทฤษฎีค่าสุดขีดจึงสรุปได้ว่า การวิเคราะห์ค่าสุดขีดจะช่วยในการประกอบการตัดสินใจและหาแนวทางในการป้องกัน และแก้ไขสถานการณ์ต่าง ๆ ได้

การประมาณค่าพารามิเตอร์ของการแจกแจงค่าสุดขีดวงนัยทั่วไปและการแจกแจงพาราโตวงนัยทั่วไปเป็นขั้นตอนสำคัญในการวิเคราะห์ค่าสุดขีด ซึ่งวิธีการประมาณค่าพารามิเตอร์มีหลายวิธี โดยวิธีภาวะน่าจะเป็นสูงสุด (ML) เป็นวิธีที่การประมาณค่าพารามิเตอร์ในสถิติที่ใช้กันอย่างแพร่หลาย หลักการพื้นฐานคือการหาค่าของพารามิเตอร์ที่ทำให้ฟังก์ชันความน่าจะเป็นของข้อมูลที่สังเกตได้มีค่าสูงสุด กล่าวคือเป็นการประมาณค่าพารามิเตอร์ที่ทำให้ข้อมูลที่สังเกตนั้นมีความเป็นไปได้ที่จะเกิดขึ้นมากที่สุด วิธีการหาภาวะน่าจะเป็นสูงสุดแบบทั่วไป (Generalized Maximum Likelihood Estimation: GML) เป็นการขยายจากการประมาณค่าแบบภาวะน่าจะเป็นสูงสุด (ML) แบบดั้งเดิม ซึ่งมีประโยชน์เมื่อสมการของฟังก์ชันน่าจะเป็นซับซ้อนและไม่สามารถแก้ได้ทางวิเคราะห์ นอกจากนี้ยังมีวิธีของเบส์ เป็นวิธีการประมาณค่าที่ใช้ฟังก์ชันการแจกแจงก่อน (Prior Distribution) ผสมกับฟังก์ชันของข้อมูลจริง เพื่อสร้างการแจกแจงภายหลัง (Posterior Distribution) และวิธีโมเมนต์เชิงเส้น (L-Moment Estimation) เป็นวิธีที่ใช้ในการสรุปการแจกแจงความน่าจะเป็นของข้อมูล ซึ่งเป็นทางเลือกที่มีความแกร่งในการประมาณค่าพารามิเตอร์ ดังเช่นงานวิจัยของ Adlouni et al. (2007) ได้ศึกษาเกี่ยวกับการพัฒนาวิธีภาวะน่าจะเป็นสูงสุด สำหรับประมาณค่าพารามิเตอร์ของการแจกแจงค่าสุดขีดวงนัยทั่วไปให้มีประสิทธิภาพมากขึ้น โดยเพิ่มตัวแปรร่วม (Covariates) เข้าไปในพารามิเตอร์ โดยในการศึกษาครั้งนี้ได้ทำการเปรียบเทียบประสิทธิภาพในการประมาณค่าพารามิเตอร์ด้วยวิธีภาวะน่าจะเป็นสูงสุดและวิธีภาวะน่าจะเป็นสูงสุดทั่วไป กรณีแบบจำลองของการแจกแจงค่าสุดขีดวงนัยทั่วไปคงที่ กรณีไม่คงที่ที่พารามิเตอร์บ่งตำแหน่งมีความสัมพันธ์เชิงเส้นกับตัวแปรร่วม กรณีไม่คงที่ที่มีความสัมพันธ์กำลังสองกับตัวแปรร่วม และกรณีไม่คงที่ที่มีความสัมพันธ์เชิงเส้นในพารามิเตอร์บ่งตำแหน่งและพารามิเตอร์บ่งขนาด ผลการจำลองแสดงให้เห็นว่าวิธีภาวะน่าจะเป็นสูงสุดทั่วไปมีประสิทธิภาพดีกว่าวิธีภาวะน่าจะเป็นสูงสุดในทุกกรณีที่ศึกษา Yoon et al. (2010) ได้ศึกษาวิธีการประมาณค่าพารามิเตอร์แบบเบส์สำหรับการแจกแจงค่าสุดขีดวงนัยทั่วไป ซึ่งผลระหว่างวิธีของเบส์และวิธีภาวะน่าจะเป็นสูงสุดทั่วไปเพื่อให้สามารถวิเคราะห์ความไม่แน่นอนได้อย่างสมบูรณ์ โดยกำหนดพารามิเตอร์ของการแจกแจงก่อนของบีตา (Beta Prior Distribution) บนพารามิเตอร์บ่งรูปร่างซึ่งได้จากการวิเคราะห์โดยอิงจากการจำลอง ในการวิเคราะห์เปรียบเทียบ

ประสิทธิภาพสำหรับพารามิเตอร์บ่งรูปร่างมีประสิทธิภาพเท่ากับหรือดีกว่าเล็กน้อยเมื่อเทียบกับวิธีภาวะน่าจะเป็นสูงสุดทั่วไป และมีประสิทธิภาพสูงกว่าในหลาย ๆ วิธี Khan et al. (2017) ได้ทำการวิเคราะห์ความถี่ของเหตุการณ์ปริมาณน้ำฝนสูงสุดในภูมิภาคต่าง ๆ ของปากีสถาน โดยพัฒนาแบบจำลองการวิเคราะห์ความถี่โดยใช้วิธีการโมเมนต์เชิงเส้น และโมเมนต์เชิงเส้นบางส่วน (Partial L-Moments) โดยใช้การแจกแจงค่าสุดขีดวงนัยทั่วไป การแจกแจงโลจิสติกวงนัยทั่วไป (Generalized Logistic Distribution) การแจกแจงปกติวงนัยทั่วไป (Generalized Normal Distribution) และการแจกแจงพาเรโตวงนัยทั่วไป ในการศึกษาดำเนินการโดยใช้สถิติ Z และแผนภาพแสดงสัดส่วนระหว่างวิธีโมเมนต์เชิงเส้นและโมเมนต์เชิงเส้นบางส่วนของแต่ละการแจกแจงเพื่อระบุคุณสมบัติทางสถิติของเหตุการณ์น้ำฝนรุนแรงในพื้นที่ศึกษาอื่น อีกทั้งได้ทำการศึกษากการจำลอง มอลติคาร์โล (Monte Carlo Simulation) เพื่อวิเคราะห์คุณสมบัติการสุ่มตัวอย่างทั้งสองวิธี ผลการศึกษาพบว่าวิธีโมเมนต์เชิงเส้นบางส่วนมีประสิทธิภาพดีกว่าวิธีโมเมนต์เชิงเส้นในการประมาณค่าเหตุการณ์ที่มีคาบเวลาการเกิดต่ำสูง Louzaoui and Arrouchi (2020) ได้มุ่งเน้นการพัฒนาวิธีการประมาณค่าพารามิเตอร์โดยวิธีภาวะน่าจะเป็นสูงสุดสำหรับดัชนีค่าสุดขีดสูงสุด โดยใช้ค่าสถิติที่บันทึกไว้ลำดับที่ k หรือ k -record values การศึกษานี้พิสูจน์ว่าความน่าจะเป็นที่กำหนดจาก k -record values สอดคล้องกันอย่างไม่มีข้อจำกัดในค่าดัชนีค่าสุดขีดสูงสุด งานวิจัยนี้มีจุดมุ่งหมายเพื่อเสนอทางเลือกใหม่ในการประมาณค่าด้วยวิธีภาวะน่าจะเป็นสูงสุดผ่าน k -record values สำหรับการวิเคราะห์ข้อมูลในบริบทของทฤษฎีค่าสุดขีดซึ่งเหมาะสมกับสถานการณ์ต่าง ๆ ที่เกี่ยวข้องกับการปรากฏการณ์ทางธรรมชาติ เศรษฐกิจ และความน่าเชื่อถือของข้อมูล

กรุงเทพมหานคร ตั้งอยู่บนพื้นที่ราบลุ่มตอนปลายของแม่น้ำเจ้าพระยา มีการเติบโตทางเศรษฐกิจและการพัฒนาของเมืองอย่างรวดเร็ว ซึ่งมักประสบปัญหาน้ำท่วมอย่างต่อเนื่อง ซึ่งส่งผลกระทบต่อชีวิตความเป็นอยู่ของประชาชน ระบบคมนาคม และโครงสร้างพื้นฐานต่าง ๆ สาเหตุมาจากภูมิประเทศที่เป็นที่ลุ่มต่ำ การพัฒนาเมืองที่รวดเร็วโดยขาดการจัดการระบายน้ำที่มีประสิทธิภาพ รวมถึงผลกระทบจากการเปลี่ยนแปลงสภาพภูมิอากาศ ฝนตกหนักในช่วงเดือนพฤษภาคมถึงตุลาคม และการขาดผังเมืองและการควบคุมการใช้ที่ดินที่เหมาะสม ส่งผลให้เกิดน้ำท่วมขังในหลายพื้นที่ นอกจากนี้ ปัญหาแผ่นดินทรุดยังทำให้สถานการณ์น้ำท่วมในกรุงเทพฯ ทวีความรุนแรงขึ้น ทำให้เกิดความเสียหายต่อทรัพย์สิน บ้านเรือน และธุรกิจ (ตุนลดดา และอนุเฝ้า, 2566) Tanprayoon et al. (2022) ได้นำเสนอการขยายตัวของ การแจกแจงค่าสุดขีดวงนัยทั่วไป เพื่อให้การแจกแจงเดิมมีความยืดหยุ่นมากขึ้น การขยายตัวนี้เรียกว่า การแจกแจงค่าสุดขีดแบบโกมเพิร์ตซ์ค่าสุดขีดทั่วไป (Gompertz-General Extreme Value Distribution) ซึ่งถูกนำมาใช้ในการประมาณระดับการเกิดซ้ำของปริมาณน้ำฝนในจังหวัดลพบุรี ในขณะที่ Martin and Stedinger (2000) ได้ทำการประมาณ

ค่าพารามิเตอร์ทั้งสามของการแจกแจงค่าสุดขีดวงนัยทั่วไป ซึ่งมีการใช้งานที่กว้างขวางในการอธิบายเหตุการณ์ค่าสุดขีดประจำปี เช่น น้ำท่วม ปริมาณน้ำฝน ความเร็วลม และค่าสูงสุดอื่น ๆ

ด้วยปัญหาดังกล่าวข้างต้น ทางผู้วิจัยจึงได้ทำการศึกษาเกี่ยวกับของการแจกแจงค่าสุดขีดโดยประยุกต์กับการพยากรณ์ปริมาณน้ำฝนสูงสุดของกรุงเทพมหานคร ซึ่งการศึกษาดังกล่าวถือว่าเป็นประโยชน์ต่อหน่วยงานที่เกี่ยวข้อง ซึ่งสามารถนำผลการศึกษาจากงานวิจัยนี้มาใช้ประกอบการวางแผนเพื่อการป้องกันหรือช่วยลดความรุนแรงในการเกิดอุทกภัยในพื้นที่กรุงเทพมหานคร โดยใช้การแจกแจงค่าสุดขีดวงนัยทั่วไปและการแจกแจงพาริตัววงนัยทั่วไป โดยใช้วิธีภาวะน่าจะเป็นสูงสุด วิธีภาวะน่าจะเป็นสูงสุดทั่วไป วิธีของเบส์ และวิธีโมเมนต์เชิงเส้น

1.2 วัตถุประสงค์ของงานวิจัย

- 1) เพื่อศึกษาวิธีการประมาณค่าพารามิเตอร์ของการแจกแจงค่าสุดขีดวงนัยทั่วไป และการแจกแจงพาริตัววงนัยทั่วไป ด้วยวิธีภาวะน่าจะเป็นสูงสุด วิธีภาวะน่าจะเป็นสูงสุดทั่วไป วิธีของเบส์ และวิธีโมเมนต์เชิงเส้น
- 2) เพื่อเปรียบเทียบประสิทธิภาพของการประมาณค่าพารามิเตอร์ของการแจกแจงค่าสุดขีดวงนัยทั่วไป และการแจกแจงพาริตัววงนัยทั่วไป ด้วยวิธีภาวะน่าจะเป็นสูงสุด วิธีภาวะน่าจะเป็นสูงสุดทั่วไป วิธีของเบส์ และวิธีโมเมนต์เชิงเส้น
- 3) วิเคราะห์ปริมาณน้ำฝนสูงสุด การหาแบบจำลองค่าสุดขีด ตลอดจนสภาพอุทกวิทยาภายในกรุงเทพมหานคร เพื่อวิเคราะห์ระดับการเกิดซ้ำ ในคาบเวลาการเกิดซ้ำที่กำหนด สำหรับข้อมูลปริมาณน้ำฝนสูงสุดในแต่ละเขตพื้นที่ของกรุงเทพมหานครด้วยการแจกแจงค่าสุดขีดวงนัยทั่วไป และการแจกแจงพาริตัววงนัยทั่วไป

1.3 ขอบเขตของงานวิจัย

- 1) ศึกษาการประมาณค่าพารามิเตอร์ด้วยวิธีการประมาณค่า 4 วิธี ประกอบด้วย ด้วยวิธีภาวะน่าจะเป็นสูงสุด วิธีภาวะน่าจะเป็นสูงสุดทั่วไป วิธีของเบส์ และวิธีโมเมนต์เชิงเส้น
- 2) การแจกแจงค่าสุดขีดวงนัยทั่วไป (GEVD) ซึ่งมีฟังก์ชันความหนาแน่นความน่าจะเป็น (Probability Density Function: PDF) (Beirlant et al., 2004) ของ GEVD ดังนี้

$$f(x; \mu, \sigma, \xi) = \begin{cases} \frac{1}{\sigma} \left[1 + \xi \left(\frac{x - \mu}{\sigma} \right) \right]^{(-1/\xi) - 1} \exp \left\{ - \left(1 + \xi \left(\frac{x - \mu}{\sigma} \right) \right)^{-1/\xi} \right\} & , \xi \neq 0 \\ \frac{1}{\sigma} \exp \left(\frac{x - \mu}{\sigma} \right)^{-1} \exp \left\{ - \exp \left(\frac{x - \mu}{\sigma} \right) \right\} & , \xi = 0 \end{cases} \quad (1.1)$$

สำหรับ $\left\{ 1 + \xi \left(\frac{x - \mu}{\sigma} \right) \right\} > 0, -\infty < \mu, \xi < \infty, \sigma > 0$ (Coles, 2001)

โดยที่ μ เป็น พารามิเตอร์บ่งตำแหน่ง (Location Parameter)

σ เป็น พารามิเตอร์บ่งขนาด (Scale Parameter) และ

ξ เป็น พารามิเตอร์บ่งรูปร่าง (Shape Parameter)

กำหนดค่าพารามิเตอร์บ่งตำแหน่งเท่ากับ 3 พารามิเตอร์บ่งขนาดเท่ากับ 1 และพารามิเตอร์บ่งรูปร่างเท่ากับ -0.7, 0 และ 0.7 ตามลำดับ และกำหนดขนาดตัวอย่างเท่ากับ 30, 50, 70 และ 100 ตามลำดับ โดยค่าพารามิเตอร์และขนาดตัวอย่างดังกล่าวใช้ในการประมาณค่าพารามิเตอร์สำหรับการแจกแจงค่าสุดขีดวงนัยทั่วไป

3) การแจกแจงพารโโตวงนัยทั่วไป (GPD) ซึ่งมีฟังก์ชันความหนาแน่นความน่าจะเป็น (Probability Density Function: PDF) ของ GPD ได้ดังนี้

$$g(y; \sigma, \xi, \mu) = \begin{cases} \frac{1}{\sigma} \left[1 + \xi \left(\frac{y - \mu}{\sigma} \right) \right]^{(1/\xi) - 1} & , y \geq 0 & , \xi \neq 0 \\ \frac{1}{\sigma} \exp \left(- \frac{y - \mu}{\sigma} \right) & , 0 \leq y \leq \frac{1}{|\xi|} & , \xi = 0 \end{cases} \quad (1.2)$$

โดยที่ μ เป็น พารามิเตอร์บ่งตำแหน่ง (Location Parameter)

σ เป็น พารามิเตอร์บ่งขนาด (Scale Parameter) และ

ξ เป็น พารามิเตอร์บ่งรูปร่าง (Shape Parameter)

กำหนดค่าพารามิเตอร์บ่งตำแหน่งเท่ากับ 2 พารามิเตอร์บ่งขนาดเท่ากับ 2 และพารามิเตอร์บ่งรูปร่างเท่ากับ -0.3, 0 และ 0.3 ตามลำดับ กำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ (Percentile) ที่ได้จากการสุ่มข้อมูลในแต่ละครั้ง ขนาดตัวอย่างเท่ากับ 300, 500, 700 และ 1,000 ตามลำดับ โดยขนาดตัวอย่างดังกล่าวใช้ในการประมาณค่าพารามิเตอร์สำหรับการแจกแจงพาริตัววงนัยทั่วไป

4) กำหนดการทดลองสุ่มซ้ำ 1,000 ครั้ง ในแต่ละรูปแบบของการประมาณค่าพารามิเตอร์

5) นำข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนและรายปีของกรุงเทพมหานคร 4 สถานี ประกอบด้วย ศูนย์การประชุมแห่งชาติสิริกิติ์ ดอนเมือง บางนา และคลองเตย มาประมาณค่าพารามิเตอร์ และนำไปคำนวณค่าระดับการเกิดซ้ำ โดยข้อมูลดังกล่าวนำมาจากกรมอุตุนิยมวิทยา

1.4 เกณฑ์การตัดสินใจ

สำหรับข้อมูลจำลอง การประมาณค่าพารามิเตอร์พิจารณาจากค่าเฉลี่ยความคลาดเคลื่อนกำลังสอง (Mean Square Error: MSE) ต่ำสุด ส่วนข้อมูลปริมาณน้ำฝนสูงสุดในแต่ละเขตพื้นที่ของกรุงเทพมหานครพิจารณาจากค่าพยากรณ์ที่ได้จากแต่ละตัวแบบ และพิจารณาค่าเฉลี่ยของเปอร์เซ็นต์ความผิดพลาดสัมบูรณ์ (Mean Absolute Percentage Error: MAPE) โดยค่าที่ต่ำจะถือว่ามีความแม่นยำในการพยากรณ์สูง

1.5 ประโยชน์ที่คาดว่าจะได้รับ

- 1) ได้ตัวแบบที่เหมาะสมสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือน และรายปี ภายในแต่ละเขตพื้นที่ของกรุงเทพมหานคร
- 2) เพื่อเป็นแนวทางในการศึกษาเกี่ยวกับวิธีการประมาณค่าพารามิเตอร์ของการแจกแจงค่าสุดขีดวงนัยทั่วไป และการแจกแจงพาริตัววงนัยทั่วไป ภายใต้วิธีการในการประมาณค่าที่แตกต่างกัน
- 3) เพื่อเป็นแนวทางในการเลือกใช้วิธีการประมาณค่าภายใต้สถานการณ์ต่าง ๆ ได้อย่างเหมาะสม

1.6 นิยามศัพท์

- 1) ตัวประมาณค่าที่ไม่เอนเอียง (Unbiased Estimator) คือ ตัวประมาณค่าที่ค่าคาดหวังของตัวประมาณค่าเท่ากับค่าพารามิเตอร์
- 2) ตัวประมาณค่าที่คงเส้นคงวา (Consistency Estimator) คือ ตัวประมาณค่าที่มีค่าเข้าใกล้ค่าพารามิเตอร์เมื่อเพิ่มขนาดของกลุ่มตัวอย่าง
- 3) ตัวประมาณค่าที่มีความพอเพียง (Sufficient Estimator) คือ ตัวประมาณค่าที่ได้มาจากข้อมูลทุกตัวในกลุ่มตัวอย่าง
- 4) ตัวประมาณค่าที่มีประสิทธิภาพ (Efficiency Estimator) คือ ตัวประมาณค่าที่ไม่มีความเอนเอียงและมีความแปรปรวนต่ำสุด
- 5) วิธีภาวะน่าจะเป็นสูงสุด (Maximum Likelihood Estimation) เป็นวิธีการทางสถิติที่ใช้ในการหาค่าประมาณพารามิเตอร์ของแบบจำลองที่ทำให้ความน่าจะเป็น (Likelihood) ของข้อมูลที่สังเกตได้สูงที่สุด
- 6) วิธีภาวะน่าจะเป็นสูงสุดทั่วไป (Generalized Maximum Likelihood Estimation) เป็นวิธีการขยายจากการประมาณค่าภาวะน่าจะเป็นสูงสุดที่ใช้ในการหาค่าประมาณของพารามิเตอร์ในกรณีที่มีเงื่อนไขหรือสมมติฐานที่ไม่เป็นไปตามข้อกำหนดมาตรฐานของวิธีภาวะน่าจะเป็นสูงสุด
- 7) วิธีของเบส์ (Bayesian) เป็นวิธีการประมาณค่าพารามิเตอร์บนพื้นฐานความน่าจะเป็นแบบมีเงื่อนไข อาศัยหลักการที่ว่าข้อมูลในอนาคตหรือการแจกแจงภายหลัง แปรผันกับผลคูณของข้อมูลในปัจจุบันหรือฟังก์ชันควอร์จะเป็น และข้อมูลในอดีตเรียกว่าการแจกแจงก่อน
- 8) วิธีโมเมนต์เชิงเส้น (L-Moment Estimation) เป็นวิธีผลรวมเชิงเส้นที่คาดการณ์ไว้ของลำดับทางสถิติ มีความไวต่อข้อมูลที่ปลายหางมีจำนวนน้อยมาก จะหาลักษณะการแจกแจงที่เหมาะสมโดยสร้างจากรายละเอียดของข้อมูลพื้นฐานเนื่องจากเป็นวิธีที่เหมาะสมสำหรับการวิเคราะห์ข้อมูลที่มีความเบ้
- 9) ค่าเฉลี่ยของเปอร์เซ็นต์ความผิดพลาดสัมบูรณ์ (Mean Absolute Percentage Error) เป็นวิธีการวัดความแม่นยำในการพยากรณ์ โดยคำนวณจากเปอร์เซ็นต์ความผิดพลาดในการพยากรณ์ค่าที่ต่ำจะมีความแม่นยำสูง
- 10) ค่าเฉลี่ยความคลาดเคลื่อนกำลังสอง (Mean Squared Error) เป็นวิธีการวัดความแม่นยำโดยแก้ปัญหาวิธีค่าเฉลี่ยของความผิดพลาด พิจารณาความแตกต่างระหว่างค่าจริงกับค่าพยากรณ์

บทที่ 2

ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

งานวิจัยนี้เป็นการศึกษาเพื่อเปรียบเทียบวิธีการประมาณค่าพารามิเตอร์ของตัวแบบการแจกแจงค่าสุดขีดวงนัยทั่วไปและการแจกแจงพาวเรโตนัยทั่วไป และนำไปประยุกต์สำหรับข้อมูลปริมาณน้ำฝนสูงสุดของแต่ละเขตพื้นที่ในกรุงเทพมหานครของประเทศไทย โดยทำการประมาณค่าพารามิเตอร์ของแต่ละการแจกแจงด้วยวิธีภาวะน่าจะเป็นสูงสุด วิธีภาวะน่าจะเป็นสูงสุดทั่วไป วิธีของเบส์ และวิธีโมเมนต์เชิงเส้น โดยมีการแจกแจงทางสถิติ ทฤษฎีที่เกี่ยวข้อง และสถิติที่ใช้ในการวิจัย ดังนี้

2.1 ทฤษฎีที่เกี่ยวข้อง

2.1.1 สถิติเชิงพรรณนา

2.1.2 การวิเคราะห์ค่าสุดขีด

2.2 วิธีประมาณค่าพารามิเตอร์

2.2.1 วิธีภาวะน่าจะเป็นสูงสุด

2.2.2 วิธีภาวะน่าจะเป็นสูงสุดทั่วไป

2.2.3 วิธีของเบส์

2.2.4 วิธีโมเมนต์เชิงเส้น

2.3 ระดับการเกิดซ้ำ

2.4 เกณฑ์การคัดเลือก

2.5 งานวิจัยที่เกี่ยวข้อง

2.1 ทฤษฎีที่เกี่ยวข้อง

2.1.1 สถิติเชิงพรรณนา (Descriptive Statistics)

เป็นการวิเคราะห์ข้อมูลที่เกี่ยวข้องกับการอธิบายและสรุปผลลัพธ์ของข้อมูลที่มีอยู่ โดยมุ่งเน้นการอธิบายลักษณะทางความสัมพันธ์ การกระจายตัว และลักษณะอื่น ๆ ของข้อมูล โดยใช้ตัวชี้วัดหรือค่าสถิติที่สามารถสรุปเป็นข้อมูลที่เข้าใจง่ายและช่วยในการวิเคราะห์ในลักษณะต่าง ๆ โดยกำหนดให้ $X = (x_1, x_2, \dots, x_n)$ เป็นกลุ่มตัวอย่างของประชากรที่สนใจ (ปัทมกร, 2564)


2.1.1.1 ค่าเฉลี่ย (Mean) เป็นตัวชี้วัดที่ใช้บ่งบอกถึงความเฉลี่ยหรือค่าที่อยู่ในตรงกลางของข้อมูล โดยคำนวณจากผลบวกของค่าข้อมูลทั้งหมดหารด้วยจำนวนข้อมูล กำหนดให้ $X = (x_1, x_2, \dots, x_n)$ เป็นชุดข้อมูลของค่าตัวแปรของกลุ่มตัวอย่างสามารถคำนวณค่าเฉลี่ยจากกลุ่มตัวอย่างได้จากสมการที่ (2.1)

$$\bar{x} = \frac{\sum_{i=1}^n x_i}{n} \quad (2.1)$$

2.1.1.2 ส่วนเบี่ยงเบนมาตรฐาน (Standard Deviation) เป็นค่าวัดทางสถิติที่บ่งบอกถึงการกระจายของค่าข้อมูลจากค่าเฉลี่ยไปทางด้านซ้ายหรือด้านขวา ซึ่งเป็นระยะห่างเฉลี่ยกำลังสองของค่าข้อมูลทุกค่าจากค่าเฉลี่ย สามารถคำนวณส่วนเบี่ยงเบนมาตรฐานของกลุ่มตัวอย่างได้จากสมการที่ (2.2)

$$S.D. = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1}} \quad (2.2)$$

ส่วนเบี่ยงเบนมาตรฐานมีหน่วยเช่นเดียวกับหน่วยของตัวแปร การกระจายของค่าข้อมูลจากค่าเฉลี่ยแปรผันตรงกับค่าส่วนเบี่ยงเบนมาตรฐาน ดังรูปที่ 2.1 ส่วนเบี่ยงเบนมาตรฐานที่มีค่ามากบ่งบอกถึงค่าข้อมูลมีการกระจายตัวมาก ในทางกลับกัน ส่วนเบี่ยงเบนมาตรฐานมีค่าน้อยแสดงถึงการกระจายของข้อมูลมีน้อย



รูปที่ 2.1 การแจกแจงปกติ 3 ลักษณะที่มีค่าส่วนเบี่ยงเบนมาตรฐานต่างกัน


2.1.1.3 ความเบ้ (Skewness) เป็นความไม่สมมาตรของลักษณะการแจกแจงของข้อมูล สามารถแบ่งออกได้ 2 ลักษณะ ได้แก่ การแจกแจงแบบเบ้ขวา (Positive Skewness) และการแจกแจงแบบเบ้ซ้าย (Negative Skewness) แสดงลักษณะเส้นโค้งจากการแจกแจงแบบเบ้ขวาและเบ้ซ้าย ดังรูปที่ 2.2 การระบุความเบ้ของลักษณะการแจกแจงของค่าตัวแปรได้จากการสังเกตจากค่ากลางของข้อมูล และยังสามารถระบุได้จากการวัดค่าสัมประสิทธิ์ความเบ้ (coefficient of skewness) ซึ่งมีการคำนวณด้วยกันหลายวิธี ในที่นี้จะกล่าวเฉพาะการวัดค่าสัมประสิทธิ์ความเบ้ด้วยวิธีโมเมนต์ แทนด้วยสัญลักษณ์ สามารถคำนวณได้จากสมการที่ (2.3)

$$g_1 = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^3}{\left[\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \right]^{\frac{3}{2}}} \quad (2.3)$$

เมื่อ $m_3 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^3$ คือ โมเมนต์ศูนย์กลางที่ 3 ของตัวแปร X_i และ

$m_2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$ คือ โมเมนต์ศูนย์กลางที่ 2 ของตัวแปร X_i

ถ้าค่าสัมประสิทธิ์ความเบ้เท่ากับ 0 แสดงว่า ข้อมูลมีลักษณะการแจกแจงสมมาตร ถ้าค่าสัมประสิทธิ์ความเบ้มีค่าน้อยกว่า 0 แสดงว่า ข้อมูลมีลักษณะการแจกแจงแบบเบ้ซ้าย ในขณะที่ถ้าสัมประสิทธิ์ความเบ้มีค่ามากกว่า 0 แสดงว่า ข้อมูลมีลักษณะการแจกแจงแบบเบ้ขวา



รูปที่ 2.2 ลักษณะการกระจายของข้อมูลที่มีการแจกแจงแบบสมมาตร (Symmetrical Distribution) การแจกแจงแบบเบ้ขวา (Positive Distribution) และการแจกแจงแบบเบ้ซ้าย (Negative Distribution)


2.1.1.4 ความโด่ง (Kurtosis) เป็นค่าสถิติที่อธิบายรูปร่างของลักษณะการแจกแจงอีกค่าหนึ่ง ที่แสดงถึงความหนาของปลายหางทั้งสองข้างของโค้งการแจกแจงข้อมูล แทนด้วยสัญลักษณ์ g_2 สามารถคำนวณโดยวิธีโมเมนต์ได้จากสมการที่ (2.4)

$$g_2 = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^4}{\left[\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \right]^2} - 3 \quad (2.4)$$

เมื่อ $m_4 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^4$ คือ โมเมนต์ศูนย์กลางที่ 4 ของตัวแปร X_i และ $m_2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$ คือ โมเมนต์ศูนย์กลางที่ 2 ของตัวแปร X_i

ค่าความโด่งที่คำนวณได้จากสมการที่ (2.4) เรียกว่า ค่าอิกเซส-เคอร์โทซิส (Excess Kurtosis) ลักษณะความโด่งของโค้งการแจกแจงแบ่งออกได้ 3 ลักษณะ แสดงดังรูปที่ 2.3 ดังนี้


- พลาติเคอร์ติก (Platykurtic) เป็นการแจกแจงที่มีความโด่งต่ำกว่าความโด่งของการแจกแจงปกติ ซึ่งจะมีค่าอิกเซส-เคอร์โทซิส น้อยกว่า 0
- เมโซเคอร์ติก (Mesokurtic) เป็นการแจกแจงที่มีความโด่งเท่ากับความโด่งของการแจกแจงปกติ ซึ่งจะมีค่าอิกเซส-เคอร์โทซิส เท่ากับ 0
- เลปโทเคอร์ติก (leptokurtic) เป็นการแจกแจงที่มีความโด่งมากกว่าความโด่งของการแจกแจงปกติ ซึ่งจะมีค่าอิกเซส-เคอร์โทซิส มากกว่า 0



รูปที่ 2.3 การแจกแจง 3 ลักษณะตามค่าอิกเซส-เคอร์โทซิส

2.1.2 การวิเคราะห์ค่าสุดขีด (Extreme Value Analysis)

ทฤษฎีค่าสุดขีด (Extreme Value Theorem) เป็นทฤษฎีที่กล่าวถึงคุณสมบัติของเหตุการณ์ที่มีตัวแปรสุ่มซึ่งจัดอยู่ในลักษณะที่เรียกว่า “ค่าสุดขีด” โดยการศึกษาทฤษฎีค่าสุดขีดเริ่มต้นมาตั้งแต่ทศวรรษที่ 19 และได้ถูกพัฒนาอย่างต่อเนื่อง โดยนักคณิตศาสตร์ Kotz and Nagaraja (2000) ได้กล่าวว่าการแจกแจงค่าสุดขีดถูกค้นพบครั้งแรกในปี ค.ศ.1709 โดย Bernulli และถูกประยุกต์ใช้ครั้งแรกโดย Fuller ในปี ค.ศ.1914 การวิเคราะห์แบบจำลองค่าสุดขีดด้วยทฤษฎีค่าสุดขีดด้วยสามารถแบ่งได้ 2 ประเภท ตามลักษณะของการเลือกข้อมูลค่าสุดขีดที่นำมาวิเคราะห์ ได้แก่ วิธีกำหนดช่วงเพื่อหาค่าสูงสุด (Block maxima model) ใช้กับข้อมูลในช่วงคาบเวลาที่สนใจ เช่น รายปี รายเดือน รายไตรมาส หรือรายสัปดาห์ โดยเลือกข้อมูลที่มีค่าสูงสุดหรือต่ำสุดในแต่ละช่วงคาบเวลามาวิเคราะห์ เหมาะสมกับการแจกแจงค่าสุดขีดวงนัยทั่วไป (Generalized Extreme Value Distribution: GEVD) ซึ่งค่าสังเกตที่รวบรวมไว้ควรจะมีจำนวนมากกว่า 30 ปีขึ้นไป ดังรูปที่ 2.4 แสดงถึงการเลือกค่าสุดขีด (จุดสีดำ) ในแต่ละช่วงเวลาที่น่าสนใจ และวิธีค่าสูงสุดที่มีค่าเกินเกณฑ์ที่กำหนด (Peak over threshold model) ใช้กับข้อมูลเมื่อข้อมูลมีจำนวนมาก หรือเป็นข้อมูลที่เก็บรวบรวมเป็นรายวัน โดยมีการกำหนดค่าเกณฑ์ (Threshold) ที่เหมาะสมกับข้อมูลมาวิเคราะห์ และพิจารณาความไม่เป็นอิสระของข้อมูล สามารถแก้ไขได้โดยการจัดกลุ่มค่าสุดขีด (Declustering) ที่มีค่าเกินกว่าเกณฑ์จึงเหมาะสมกับการแจกแจงพาราโตวงนัยทั่วไป (Generalized Pareto Distribution: GPD) ดังรูปที่ 2.4 แสดงถึงลักษณะการเลือกค่าสุดขีดที่มีค่าเกินกว่าค่าเกณฑ์ที่กำหนดไว้



รูปที่ 2.4 การเลือกค่าสุดขีดสำหรับแบบจำลอง GEVD และ GPD

2.1.2.1 การแจกแจงค่าสุดขีดวงนัยทั่วไป (Generalized Extreme Value Distribution: GEVD)

การแจกแจงค่าสุดขีดวงนัยทั่วไป (Generalized Extreme Value Distribution: GEVD) ใช้กับข้อมูลในช่วงคาบเวลาที่สนใจ เช่น รายปี รายเดือน รายไตรมาส หรือรายสัปดาห์ โดยเลือกข้อมูลที่มีค่าสูงสุดหรือต่ำสุดในแต่ละช่วงคาบเวลามาวิเคราะห์ (Jenkinson, 1955)

กำหนดให้ X_i สำหรับ $i = 1, 2, \dots, n$ เป็นตัวแปรสุ่มที่อิสระต่อกันและมีฟังก์ชันการแจกแจงสะสม $F(x; \theta)$ แบบเดียวกัน ค่าสูงสุดของตัวแปรสุ่มคือ $X_{(n)} = \text{Max}(X_1, X_2, \dots, X_n)$ Galambos (1978) ได้สร้างฟังก์ชันการแจกแจงสะสม (Cumulative Distribution Function: CDF) สำหรับการแจกแจงค่าสุดขีดวงนัยทั่วไป คือ

$$F(x; \mu, \sigma, \xi) = \begin{cases} \exp\left\{-\left(1 + \xi\left(\frac{x - \mu}{\sigma}\right)\right)^{-1/\xi}\right\} & , \xi \neq 0 \\ \exp\left\{-\exp\left(\frac{x - \mu}{\sigma}\right)\right\} & , \xi = 0 \end{cases} \quad (2.5)$$

และฟังก์ชันการแจกแจงความน่าจะเป็น (Probability Distribution Function: PDF) (Beirlant et al., 2004) สำหรับการแจกแจงค่าสุดขีดวงนัยทั่วไป คือ

$$f(x; \mu, \sigma, \xi) = \begin{cases} \frac{1}{\sigma} \left[1 + \xi\left(\frac{x - \mu}{\sigma}\right)\right]^{-(1/\xi)-1} \exp\left\{-\left(1 + \xi\left(\frac{x - \mu}{\sigma}\right)\right)^{-1/\xi}\right\} & , \xi \neq 0 \\ \frac{1}{\sigma} \exp\left(\frac{x - \mu}{\sigma}\right)^{-1} \exp\left\{-\exp\left(\frac{x - \mu}{\sigma}\right)\right\} & , \xi = 0 \end{cases} \quad (2.6)$$

สำหรับ $\left\{1 + \xi \left(\frac{x - \mu}{\sigma}\right)\right\} > 0, -\infty < \mu, \xi < \infty, \sigma > 0$ (Coles, 2001)

โดยที่ μ เป็น พารามิเตอร์บ่งตำแหน่ง (Location Parameter)

σ เป็น พารามิเตอร์บ่งขนาด (Scale Parameter) และ

ξ เป็น พารามิเตอร์บ่งรูปร่าง (Shape Parameter)


ซึ่งการแจกแจงค่าสุดขีดวงนัยทั่วไปสามารถเขียนฟังก์ชันการแจกแจงค่าสุดขีดได้ 3 รูปแบบ ขึ้นกับค่าของพารามิเตอร์บ่งรูปร่าง

โดยที่ $\xi = 0$ เรียกการแจกแจงค่าสุดขีดวงนัยทั่วไปว่าการแจกแจงกัมเบล

$\xi > 0$ เรียกการแจกแจงค่าสุดขีดวงนัยทั่วไปว่าการแจกแจงฟริเชท

$\xi < 0$ เรียกการแจกแจงค่าสุดขีดวงนัยทั่วไปว่าการแจกแจงไวส์บูล

แสดงดังรูปที่ 2.5



รูปที่ 2.5 การแจกแจงค่าสุดขีดวงนัยทั่วไป เมื่อกำหนดพารามิเตอร์บ่งรูปร่างมีค่าต่าง ๆ

โดยมีค่าเฉลี่ย และความแปรปรวน ดังนี้

$$E(X) = \begin{cases} \mu - \frac{\sigma}{\xi} + \frac{\sigma}{\xi} \Gamma(1-\xi) & , \xi \neq 0, \xi < 1 \\ \mu + \sigma\gamma & , \xi = 0 \\ \infty & , \xi \geq 1 \end{cases} \quad (2.7)$$

เมื่อ γ คือ ค่าคงที่ของออยเลอร์ (Euler's Constant)

$$Var(X) = \begin{cases} \frac{\sigma^2}{\xi} [\Gamma(1-2\xi) - (\Gamma(1-\xi))^2] & , \xi \neq 0, \xi < \frac{1}{2} \\ \frac{\sigma^2 \pi^2}{6} & , \xi = 0 \\ \infty & , \xi \geq \frac{1}{2} \end{cases} \quad (2.8)$$

2.1.2.2 การแจกแจงพารโตนัยทั่วไป (Generalized Pareto Distribution)

การแจกแจงพารโตนัยทั่วไป (Generalized Pareto Distribution: GPD) เป็นการแจกแจงที่จะอาศัยค่าเกณฑ์ (Threshold) ที่เหมาะสมในการพิจารณาค่าสุดขีด สำหรับการเลือกค่าสังเกตจะคัดเลือกจากค่าสังเกตที่มีค่าสูงกว่าค่าเกณฑ์ที่กำหนดขึ้น

ให้ Y_1, \dots, Y_k เป็นตัวแปรสุ่มที่อิสระกันและมีฟังก์ชันการแจกแจงสะสม $G(y; \theta)$ แบบเดียวกัน การแจกแจงพารโตนัยทั่วไปเป็นการแจกแจงที่ประกอบด้วย 3 พารามิเตอร์ คือ พารามิเตอร์บ่งตำแหน่ง (Location Parameter: μ) พารามิเตอร์บ่งขนาด (Scale Parameter: σ) พารามิเตอร์บ่งรูปร่าง (Shape Parameter: ξ) โดยที่ $Y > u$ ฟังก์ชันการแจกแจงสะสม (Cumulative Density Function: CDF) ของการแจกแจงพารโตนัยทั่วไป คือ

$$G(y; \mu, \sigma, \xi) = \begin{cases} 1 - \left[1 + \xi \left(\frac{y - \mu}{\sigma} \right) \right]^{-\frac{1}{\xi}} & , \xi \neq 0 \\ 1 - \exp\left(-\frac{y - \mu}{\sigma}\right) & , \xi = 0 \end{cases} \quad (2.9)$$

และฟังก์ชันการแจกแจงความน่าจะเป็น (Probability Distribution Function: PDF) สำหรับการแจกแจงพารโตนัยทั่วไป คือ

$$g(y; \mu, \sigma, \xi) = \begin{cases} \frac{1}{\sigma} \left[1 + \xi \left(\frac{y - \mu}{\sigma} \right) \right]^{-\frac{1}{\xi}} & , y \geq 0 \quad , \xi \neq 0 \\ \frac{1}{\sigma} \exp\left(-\frac{y - \mu}{\sigma}\right) & , 0 \leq y \leq \frac{1}{|\xi|} \quad , \xi = 0 \end{cases} \quad (2.10)$$

โดยมีค่าเฉลี่ยและความแปรปรวน ดังนี้

$$E(Y) = \mu + \frac{\sigma}{1 - \xi} \quad , \xi < 1 \quad (2.11)$$

$$Var(Y) = \frac{\sigma^2}{(1 - 2\xi)(1 - \xi)^2} \quad , \xi < \frac{1}{2} \quad (2.12)$$


ซึ่งการแจกแจงพารโตนัยทั่วไปสามารถแบ่งเป็น 3 รูปแบบ ขึ้นอยู่กับพารามิเตอร์รูปร่าง

โดยที่ $\xi = 0$ จะมีลักษณะแบบหางกลาง (Medium-tail) แบบเลขชี้กำลัง

$\xi > 0$ จะมีลักษณะแบบหางหนา (Heavy-tail) และ

$\xi < 0$ จะมีลักษณะแบบหางสั้น (Short-tail)

แสดงดังรูปที่ 2.6



รูปที่ 2.6 การแจกแจงพารโตนัยทั่วไป เมื่อกำหนดพารามิเตอร์รูปร่างมีค่าต่าง ๆ

2.2 วิธีการประมาณค่าพารามิเตอร์ในทางสถิติที่ใช้ในงานวิจัย

เป็นกระบวนการทางสถิติที่ใช้ในการหาค่าของพารามิเตอร์ในแต่ละการแจกแจง การเลือกใช้วิธีการประมาณค่าพารามิเตอร์ที่เหมาะสมจะทำให้ได้ตัวแบบที่มีประสิทธิภาพ โดยวิธีการที่ใช้ในงานวิจัยนี้ ประกอบด้วย วิธีภาวะน่าจะเป็นสูงสุด วิธีภาวะน่าจะเป็นสูงสุดทั่วไป วิธีของเบส์ และวิธีโมเมนต์เชิงเส้น โดยมีรายละเอียดดังต่อไปนี้

2.2.1 วิธีภาวะน่าจะเป็นสูงสุด (Maximum Likelihood Estimation: ML)

การประมาณค่าพารามิเตอร์ด้วยวิธีภาวะน่าจะเป็นสูงสุดเป็นวิธีที่ใช้กันมากและเป็นวิธีที่ง่าย เพราะวิธีนี้เป็นวิธีการหาตัวประมาณค่าที่ทำให้ฟังก์ชันภาวะน่าจะเป็น (Likelihood Function) มีค่าสูงสุด และตัวประมาณค่าที่หาได้ด้วยวิธีนี้จะเรียกว่า ตัวประมาณภาวะน่าจะเป็นสูงสุด

นิยามที่ 1 ให้ X_1, \dots, X_n เป็นตัวอย่างสุ่มจากประชากรที่มีฟังก์ชันความหนาแน่นความน่าจะเป็น $f(x; \theta)$ ฟังก์ชันภาวะน่าจะเป็น (Likelihood Function) ของตัวอย่างสุ่ม คือ ฟังก์ชันความน่าจะเป็นร่วมของ X_1, \dots, X_n โดยที่เป็นฟังก์ชันของพารามิเตอร์ θ ฟังก์ชันภาวะน่าจะเป็น เขียนแทนด้วย L หรือ $L(\theta; X_1, \dots, X_n)$ นั่นคือ

$$\begin{aligned}
 L(\theta) &= L(\theta; X_1, \dots, X_n) \\
 &= f(X_1, \dots, X_n; \theta) \\
 &= f(X_1; \theta) \dots f(X_n; \theta) \\
 &= \prod_{i=1}^n f(X_i; \theta)
 \end{aligned}
 \tag{2.13}$$

นิยามที่ 2 ตัวประมาณภาวะน่าจะเป็นสูงสุด (Maximum Likelihood Estimator) ของพารามิเตอร์ θ คือ $\hat{\theta} = \hat{\theta}(X_1, \dots, X_n)$ ที่ทำให้ฟังก์ชันภาวะน่าจะเป็น $L(\theta)$ มีค่าสูงที่สุด

ขั้นตอนการประมาณค่าพารามิเตอร์โดยวิธีภาวะน่าจะเป็นสูงสุดสำหรับการแจกแจงค่าสุ่มขีดวางนัยทั่วไป ดังนี้

- 1) พิจารณาฟังก์ชันความหนาแน่นความน่าจะเป็นของตัวแปรสุ่ม X จากสมการที่ (2.6)
- 2) สร้างฟังก์ชันภาวะน่าจะเป็น (Likelihood function) ของตัวแปรสุ่มจากการแจกแจงค่าสุ่มขีดวางนัยทั่วไป เมื่อ $\xi \neq 0$

$$L(\mu, \sigma, \xi) = \frac{1}{\sigma^n} \prod_{i=1}^n \left[1 + \xi \left(\frac{x_i - \mu}{\sigma} \right) \right]^{(-1/\xi)-1} \exp \left\{ -\sum_{i=1}^n \left(1 + \xi \left(\frac{x_i - \mu}{\sigma} \right) \right)^{-1/\xi} \right\} \quad (2.14)$$

3) สร้างฟังก์ชันลึอกภวะน่าจะเป็น (Log-likelihood Function) ของตัวแปรสุ่มจากการแจกแจงค่าสุดขีดวงนัยทั่วไป

$$l(\mu, \sigma, \xi) = -n \log(\sigma) - \left(1 + \frac{1}{\xi} \right) \sum_{i=1}^n \log \left[1 + \xi \left(\frac{x_i - \mu}{\sigma} \right) \right] - \sum_{i=1}^n \left(1 + \xi \left(\frac{x_i - \mu}{\sigma} \right) \right)^{-1/\xi} \quad (2.15)$$

4) ประมาณค่าพารามิเตอร์ ด้วยการอนุพันธ์ย่อย (Partial Derivative) จากฟังก์ชันที่ได้ในขั้นตอนที่ 3) จะได้ตัวประมาณแบบ ML ของ $\hat{\mu}, \hat{\sigma}, \hat{\xi}$ จาก

$$\frac{\partial l(\mu, \sigma, \xi)}{\partial \mu} = 0, \quad \frac{\partial l(\mu, \sigma, \xi)}{\partial \sigma} = 0, \quad \frac{\partial l(\mu, \sigma, \xi)}{\partial \xi} = 0$$

จากการอนุพันธ์ย่อยเพื่อที่จะทำให้ฟังก์ชันลึอกภวะน่าจะเป็นสูงสุด ทำได้ยากเนื่องจากสมการมีความซับซ้อนและไม่สามารถแก้สมการภวะน่าจะเป็นได้ จึงใช้การประมาณค่าด้วยวิธีการการวิเคราะห์เชิงตัวเลข (Numerical Analysis) ด้วยวิธีการของนิวตัน-ราฟสัน (Newton - Rapson) (Nocedal and Wright, 1999)

สำหรับการประมาณค่าพารามิเตอร์ของการแจกแจงพาวเรโตวงนัยทั่วไป มีขั้นตอนดังนี้

1) พิจารณาฟังก์ชันความหนาแน่นความน่าจะเป็นของตัวแปรสุ่ม Y จากสมการที่ (2.10)

2) สร้างฟังก์ชันภวะน่าจะเป็น (Likelihood function) ของตัวแปรสุ่มจากการแจกแจงพาวเรโตวงนัยทั่วไป เมื่อ $\xi \neq 0$ และ k คือ จำนวนของข้อมูลที่มีค่าเกินเกณฑ์

$$L(\mu, \sigma, \xi) = \frac{1}{\sigma^k} \prod_{i=1}^k \left[\left(1 + \xi \left(\frac{y_i - \mu}{\sigma} \right) \right)^{-\left(1 + \frac{1}{\xi} \right)} \right] \quad (2.16)$$

3) สร้างฟังก์ชันลึอกภาวะน่าจะเป็น (Log-likelihood Function) ของตัวแปรสุ่มจากการแจกแจงพาราโตวางนัยทั่วไป

$$l(\mu, \sigma, \xi) = -k \log(\sigma) - \left(1 + \frac{1}{\xi}\right) \sum_{i=1}^k \log \left[1 + \xi \left(\frac{y_i - \mu}{\sigma}\right)\right] \quad (2.17)$$

4) ประมาณค่าพารามิเตอร์ ด้วยการอนุพันธ์ย่อย (Partial Derivative) จากฟังก์ชันที่ได้ในขั้นตอนที่ 3) จะได้ตัวประมาณแบบ ML ของ $\hat{\mu}, \hat{\sigma}, \hat{\xi}$ จาก

$$\frac{\partial l(\mu, \sigma, \xi)}{\partial \mu} = 0, \quad \frac{\partial l(\mu, \sigma, \xi)}{\partial \sigma} = 0, \quad \frac{\partial l(\mu, \sigma, \xi)}{\partial \xi} = 0$$

จากการอนุพันธ์ย่อยเพื่อที่จะทำให้ฟังก์ชันลึอกภาวะน่าจะเป็นสูงสุด ทำได้ยากเนื่องจากสมการมีความซับซ้อนและไม่สามารถแก้สมการภาวะน่าจะเป็นได้ จึงใช้การประมาณค่าด้วยวิธีการการวิเคราะห์เชิงตัวเลขด้วยวิธีการของนิวตัน-ราฟสัน (Newton - Rapson)

2.2.2 วิธีภาวะน่าจะเป็นสูงสุดทั่วไป (Generalized Maximum Likelihood Method: GML)

วิธีภาวะน่าจะเป็นสูงสุดทั่วไป นำเสนอโดย Kiefer and Wolfowitz (1956) เป็นวิธีที่ใช้ในการประมาณค่าพารามิเตอร์ในกรณีที่ไม่เป็นไปตามสมมติฐานของวิธีภาวะน่าจะเป็นสูงสุด (ML) ซึ่งมักถูกสมมติว่าข้อมูลเป็นไปตามการแจกแจงที่เฉพาะเจาะจง เช่น การแจกแจงปกติ การแจกแจงทวินาม หรืออาจไม่ทราบการแจกแจงของข้อมูล แต่ GML จะสมมติให้ข้อมูลเป็นฟังก์ชันที่ยืดหยุ่นมากขึ้นสามารถใช้ได้กับรูปแบบการกระจายข้อมูลที่หลากหลาย รวมถึงสถิติที่ไม่อิงพารามิเตอร์ บางบทความจะเรียกวิธี GML ว่าตัวประมาณภาวะน่าจะเป็นสูงสุดไม่อิงพารามิเตอร์ (Nonparametric Maximum Likelihood Estimator) หรือ NPML หลักการของวิธี GML เหมือนกับ ML คือ การหาพารามิเตอร์ที่ทำให้ตัวประมาณแบบภาวะน่าจะเป็นทั่วไปมีค่าสูงที่สุด โดยมีวิธีการต่าง ๆ เช่น วิธีภาวะน่าจะเป็นเชิงประจักษ์ (Empirical likelihood) วิธีภาวะน่าจะเป็น (quasi-likelihood) หรือสมการการประมาณค่า (Greenshtein and Ritov, 2022)

Martin and Stedinger (2000) ได้นำเสนอในกรณีของข้อมูลทางด้านอุทกศาสตร์ โดยเพิ่มข้อจำกัดเกี่ยวกับการแจกแจงของพารามิเตอร์บ่งรูปร่าง ξ โดยกำหนดให้พารามิเตอร์บ่งรูปร่างมีความน่าจะเป็นก่อน (Prior Density) $\pi(\xi)$ เท่ากับการแจกแจงบีตา (Beta Distribution) สามารถแสดงได้ดังนี้

$$\pi(\xi) = \frac{(0.5 + \xi)^{u-1} (0.5 - \xi)^{v-1}}{B(u, v)}, \quad -0.5 \leq \xi \leq 0.5, u = 6, v = 9 \quad (2.18)$$

เมื่อ $B(u, v) = \frac{\Gamma(u)\Gamma(v)}{\Gamma(u+v)}$ โดยมีค่าเฉลี่ย $E(\xi) = -0.1$ และความแปรปรวน $Var(\xi) = 0.015$

ซึ่งตัวประมาณค่าพารามิเตอร์ของวิธี GML นั้นเหมือนกับวิธี ML โดยที่ฟังก์ชันภาวะน่าจะเป็นทั่วไป (Generalized Likelihood Function) มีพื้นฐานมาจากทฤษฎีของเบส์ เขียนแทนด้วย

$$GL(X; \mu, \sigma, \xi) = L(X; \mu, \sigma, \xi) \pi(\xi) \quad (2.19)$$

ดังนั้น ฟังก์ชันล็อกภาวะน่าจะเป็นทั่วไป (Generalized Log-Likelihood Function) เขียนแทนด้วย l_G สามารถคำนวณได้จากสมการที่ (2.20)

$$l_G = \log(L(X | \theta_i)) + \log\{\pi(\xi)\} \quad (2.20)$$

เมื่อ $L(X | \theta_i)$ เป็นฟังก์ชันภาวะน่าจะเป็น ในขั้นตอนที่ 2 จากนั้นหาอนุพันธ์ย่อยเพื่อทำให้ฟังก์ชันล็อกภาวะน่าจะเป็นทั่วไปมีค่าสูงสุด ซึ่งการประมาณค่าพารามิเตอร์ที่ทำให้ฟังก์ชันล็อกภาวะน่าจะเป็นทั่วไปมีค่าสูงสุดสามารถใช้การวิเคราะห์เชิงตัวเลขด้วยวิธีการของนิวตัน-ราฟสัน (Newton-Rapson) ได้เช่นเดียวกับวิธี ML (Yoon et al., 2010)

ขั้นตอนการประมาณค่าพารามิเตอร์ด้วยวิธีภาวะน่าจะเป็นสูงสุดทั่วไป (GML) สำหรับการแจกแจงค่าสุดขีดวงนัยทั่วไป มี 4 ขั้นตอน ดังต่อไปนี้

1) พิจารณาฟังก์ชันความหนาแน่นความน่าจะเป็นของตัวแปรสุ่ม X จากสมการที่ (2.6) และความน่าจะเป็นก่อน $\pi(\xi)$ จากสมการที่ (2.18)

2) สร้างฟังก์ชันภาวะน่าจะเป็นทั่วไป (Generalized Likelihood function) ของตัวแปรสุ่มจากการแจกแจงค่าสุดขีดวงนัยทั่วไป เมื่อ $\xi \neq 0$

$$GL(\mu, \sigma, \xi) = \frac{1}{\sigma^n} \prod_{i=1}^n \left[1 + \xi \left(\frac{x_i - \mu}{\sigma} \right) \right]^{(-1/\xi)-1} \exp \left\{ - \sum_{i=1}^n \left(1 + \xi \left(\frac{x_i - \mu}{\sigma} \right) \right)^{-1/\xi} \right\} \pi(\xi) \quad (2.21)$$

3) สร้างฟังก์ชันลอกลักษณะน่าจะเป็น (Log-likelihood Function) ของตัวแปรสุ่มจากการแจกแจง GEVD

$$l_G(\mu, \sigma, \xi) = -n \log(\sigma) - \left(1 + \frac{1}{\xi} \right) \sum_{i=1}^n \log \left[1 + \xi \left(\frac{x_i - \mu}{\sigma} \right) \right] - \sum_{i=1}^n \left(1 + \xi \left(\frac{x_i - \mu}{\sigma} \right) \right)^{-1/\xi} + \log \{ \pi(\xi) \} \quad (2.22)$$

4) ประมาณค่าพารามิเตอร์ ด้วยการอนุพันธ์ย่อย (Partial Derivative) จากฟังก์ชันที่ได้ในขั้นตอนที่ 3) จะได้ตัวประมาณแบบ GML ของ μ, σ, ξ จาก

$$\frac{\partial l_G(\mu, \sigma, \xi)}{\partial \mu} = 0, \quad \frac{\partial l_G(\mu, \sigma, \xi)}{\partial \sigma} = 0, \quad \frac{\partial l_G(\mu, \sigma, \xi)}{\partial \xi} = 0$$

จากการอนุพันธ์ย่อยเพื่อที่จะทำให้ฟังก์ชันลอกลักษณะน่าจะเป็นทั่วไปมีค่าสูงที่สุด ทำได้ยากเนื่องจากสมการมีความซับซ้อนและไม่สามารถแก้สมการภาวะน่าจะเป็นได้ จึงใช้การประมาณค่าด้วยวิธีการการวิเคราะห์เชิงตัวเลขด้วยวิธีการของนิวตัน-ราฟสัน (Newton - Rapson)

สำหรับการประมาณค่าพารามิเตอร์ของการแจกแจงพาราโตวงนัยทั่วไป มีขั้นตอนดังนี้

1) พิจารณาฟังก์ชันความหนาแน่นความน่าจะเป็นของตัวแปรสุ่ม Y จากสมการที่ (2.10) และความน่าจะเป็นก่อน $\pi(\xi)$ จากสมการที่ (2.18)

2) สร้างฟังก์ชันภาวะน่าจะเป็น (Likelihood function) ของตัวแปรสุ่มจากการแจกแจงพาราโตนวายนัยทั่วไป เมื่อ $\xi \neq 0$ และ k คือ จำนวนของข้อมูลที่มีค่าเกินเกณฑ์

$$GL(\mu, \sigma, \xi) = \frac{1}{\sigma^k} \prod_{i=1}^k \left[1 + \xi \left(\frac{y_i - \mu}{\sigma} \right) \right]^{-\left(1 + \frac{1}{\xi}\right)} \pi(\xi) \quad (2.23)$$

3) สร้างฟังก์ชันลอกลักษณะน่าจะเป็น (Log-likelihood Function) ของตัวแปรสุ่มจากการแจกแจงพาราโตนวายนัยทั่วไป

$$l_G(\mu, \sigma, \xi) = -k \log(\sigma) - \left(1 + \frac{1}{\xi}\right) \sum_{i=1}^k \log \left[1 + \xi \left(\frac{y_i - \mu}{\sigma} \right) \right] + \log \{ \pi(\xi) \} \quad (2.24)$$

4) ประมาณค่าพารามิเตอร์ ด้วยการอนุพันธ์ย่อย (Partial Derivative) จากฟังก์ชันที่ได้ในขั้นตอนที่ 3) จะได้ตัวประมาณแบบ GML ของ μ, σ, ξ จาก

$$\frac{\partial l_G(\mu, \sigma, \xi)}{\partial \mu} = 0, \quad \frac{\partial l_G(\mu, \sigma, \xi)}{\partial \sigma} = 0, \quad \frac{\partial l_G(\mu, \sigma, \xi)}{\partial \xi} = 0$$

2.2.3 วิธีของเบย์ส์ (Bayesian Method)

เป็นวิธีการประมาณค่าพารามิเตอร์บนพื้นฐานความน่าจะเป็นแบบมีเงื่อนไข วิธีนี้อาศัยหลักการที่ว่าข้อมูลในอนาคตหรือเรียกว่าการแจกแจงภายหลัง แปรผันกับผลคูณของข้อมูลในปัจจุบันหรือเรียกว่าฟังก์ชันครจะจะเป็น และข้อมูลในอดีตหรือเรียกว่าการแจกแจงก่อน

กำหนดให้ X_1, X_2, \dots, X_n เป็นตัวอย่างสุ่มจากประชากรที่มีฟังก์ชันความหนาแน่นความน่าจะเป็น $f(x; \theta) = f(x|\theta)$ โดยที่ θ เป็นค่าของตัวแปรเชิงสุ่ม Θ ที่เป็นไปได้ทั้งหมด Θ มี

ฟังก์ชันความหนาแน่นจะเป็น $g(\theta)$ และ $f(x|\theta)$ เป็นฟังก์ชันความหนาแน่นจะเป็นแบบมีเงื่อนไข (Condition Density Function) ของ X เมื่อกำหนดให้ $\Theta = \theta$

นิยามที่ 3 ฟังก์ชัน $g(\theta)$ เรียกว่า ฟังก์ชันการแจกแจงก่อน (Prior Distribution Function) ของ Θ และ $h(\theta|x_1, x_2, \dots, x_n)$ เรียกว่า ฟังก์ชันความหนาแน่นของ Θ เมื่อกำหนดให้ $X_1 = x_1, \dots, X_n = x_n$ หรือเรียกว่าฟังก์ชันการแจกแจงภายหลัง (Posterior Distribution Function) ของ Θ ฟังก์ชันความหนาแน่นร่วมของ X_1, X_2, \dots, X_n เมื่อกำหนด $\Theta = \theta$ คือ

$$\begin{aligned} f(x_1, \dots, x_n | \theta) &= f(x_1 | \theta) \dots f(x_n | \theta) \\ &= \prod_{i=1}^n f(x_i | \theta) \end{aligned} \quad (2.25)$$

จะได้ฟังก์ชันการแจกแจงภายหลังของ θ คือ

$$h(\theta|x_1, x_2, \dots, x_n) = \frac{f(x_1, \dots, x_n | \theta) g(\theta)}{\int f(x_1, \dots, x_n | \theta) g(\theta) d\theta} = \frac{\prod_{i=1}^n f(x_i | \theta) g(\theta)}{\int \prod_{i=1}^n f(x_i | \theta) g(\theta) d\theta} \quad (2.26)$$

หรือพิจารณาในรูปแบบของวงศ์คู่สังยุค (Conjugate Function)

$$h(\theta|x_1, x_2, \dots, x_n) \propto \prod_{i=1}^n f(x_i | \theta) g(\theta) \quad (2.27)$$

นิยามที่ 4 ให้ X_1, X_2, \dots, X_n เป็นตัวอย่างสุ่มจากประชากรที่มีฟังก์ชันความหนาแน่นความน่าจะเป็น $f(x|\theta)$ โดยที่ θ เป็นค่าของตัวแปรสุ่ม Θ ที่มีฟังก์ชันการแจกแจงก่อน $g(\theta)$ ตัวประมาณแบบภายหลังของเบส์ (Posterior Bayes Estimator) ของฟังก์ชัน $\tau(\theta)$ เทียบกับฟังก์ชันการแจกแจงก่อน $g(\theta)$ คือ

$$\begin{aligned}
\hat{\tau}(\theta) &= E(\tau(\Theta)|X_1, X_2, \dots, X_n) \\
&= \int \tau(\theta) h(\theta|x_1, x_2, \dots, x_n) d\theta \\
&= \frac{\int \tau(\theta) f(x_1, \dots, x_n|\theta) g(\theta) d\theta}{\int f(x_1, \dots, x_n|\theta) g(\theta) d\theta}
\end{aligned} \tag{2.28}$$

เนื่องจากการหารูปแบบของการแจกแจงภายหลังสำหรับการแจกแจงค่าสุดขีดวางนัยทั่วไปและการแจกแจงพาราโตวางนัยทั่วไปนั้นทำได้ยาก จึงได้มีการประมาณพารามิเตอร์แบบเบส์ด้วยขั้นตอนวิธีเมโทรโพลิส-แอสติงส์ (Metropolis-Hastings Algorithm) (Robert and Casella, 1999) โดยมีขั้นตอนการประมาณค่าพารามิเตอร์ด้วยวิธีดังกล่าว ดังนี้

1) กำหนดฟังก์ชันการแจกแจงภายหลังของการแจกแจงค่าสุดขีดวางนัยทั่วไปและการแจกแจงพาราโตวางนัยทั่วไป ผลคูณของฟังก์ชันภาวะน่าจะเป็นกับฟังก์ชันการแจกแจงก่อนของพารามิเตอร์คือ

$$f(x|\mu, \sigma, \xi) \propto f(\mu, \sigma, \xi|x) f(\mu) f(\sigma) f(\xi) \tag{2.29}$$

เมื่อ $f(\mu, \sigma, \xi|x)$ แทนฟังก์ชันภาวะน่าจะเป็น

$f(\mu)$, $f(\sigma)$ และ $f(\xi)$ แทนฟังก์ชันการแจกแจงก่อนของพารามิเตอร์

กำหนดให้ μ มีการแจกแจงปกติ (Normal Distribution) $\mu \sim N(\mu_0, \sigma_0^2)$

σ มีการแจกแจงแกมมาผกผัน (Inverse-Gamma Distribution) $\sigma \sim IG(a, b)$

ξ มีการแจกแจงเอกรูปแบบต่อเนื่อง (Uniform Distribution) $\xi \sim U(a, b)$

2) กำหนดค่าเริ่มต้นของแต่ละพารามิเตอร์จากการแจกแจงก่อน $\theta^{(0)} = (\mu^{(0)}, \sigma^{(0)}, \xi^{(0)})$ และสร้างข้อมูลได้ค่าพารามิเตอร์ชุดใหม่ $\theta' = (\mu', \sigma', \xi')$ จากการแจกแจงนำเสนอ (Proposal Distribution) หรือ $f(\theta'|\theta^{(i)})$

3) คำนวณค่าความน่าจะเป็นที่จะถูกยอมรับพารามิเตอร์ หรือ α จาก

$$\alpha = \min \left(1, \frac{f(\theta' | x) f(\theta^{(t)} | \theta')}{f(\theta^{(t)} | x) f(\theta' | \theta^{(t)})} \right) \quad (2.30)$$

4) กำหนด $\theta^{(t+1)} = \theta'$ ด้วยความน่าจะเป็น α ดังนั้น $\theta^{(t+1)} = \theta^{(t)}$

2.2.4 วิธีโมเมนต์เชิงเส้น (L-Moment Estimation)

วิธีประมาณโมเมนต์เชิงเส้น (Hosking, 1990) เป็นวิธีผลรวมเชิงเส้นที่คาดการณ์ไว้ของลำดับทางสถิติ มีข้อดีกว่าวิธีโมเมนต์ธรรมดาทั้งด้านทฤษฎีและการนำไปใช้งาน เช่น วิธีโมเมนต์เชิงเส้นมีความไวต่อข้อมูลที่ปลายหางที่มีจำนวนน้อยมาก วิธีโมเมนต์เชิงเส้นจะหาลักษณะของการแจกแจงที่เหมาะสมโดยสร้างจากรายละเอียดของข้อมูลพื้นฐานเนื่องจากเป็นวิธีที่เหมาะสมสำหรับการวิเคราะห์ข้อมูลที่มีความเบ้ เช่น ข้อมูลสุดขีดของปริมาณน้ำฝน ข้อมูลความถี่ของน้ำท่วม ข้อมูลค่าสุดขีดของความเร็วม (Park et al., 2014)

การคำนวณวิธีโมเมนต์เชิงเส้นสำหรับข้อมูลลำดับ (The r -th L-moment (λ)) จำเป็นต้องใช้วิธีโมเมนต์ถ่วงน้ำหนักความน่าจะเป็น (Probability Weighted Moments: PWM) ลำดับที่ r หรือ $P_r = E[X((X))^r]$ โดยวิธีโมเมนต์เชิงเส้นสามารถคำนวณได้จากความสัมพันธ์ระหว่างวิธี L-Moment และ PWMs ดังนี้

1) คำนวณโมเมนต์เชิงเส้นสำหรับข้อมูล โดยที่

$$\text{L-Mean:} \quad \lambda_1 = p_0 \quad (2.31)$$

$$\text{L-Scale:} \quad \lambda_2 = 2p_1 - p_0 \quad (2.32)$$

$$\text{L-Skewness:} \quad \lambda_3 = 6p_2 - 6p_1 + p_0 \quad (2.33)$$

สมการทั่วไปของ p_r สำหรับ $r = 1, 2, 3, \dots$ คือ

$$p_r = \frac{\mu}{r+1} + \frac{\sigma}{r+1} \left[\psi \left(\frac{r+1}{\xi} + 1 \right) - \psi(1) \right] + \frac{\sigma}{r+1} \log \xi \quad (2.34)$$

2) คำนวณอัตราส่วนโมเมนต์เชิงเส้น (L-moments Ratios)

$$\text{L-CV: } \tau_2 = \frac{\lambda_2}{\lambda_1} \quad (2.35)$$

$$\text{L-Skewness: } \tau_3 = \frac{\lambda_3}{\lambda_2} \quad (2.36)$$

3) ประมาณค่าพารามิเตอร์ปรงรูปร่าง (ξ) โดยใช้ความสัมพันธ์ระหว่างอัตราส่วนโมเมนต์เชิงเส้นลำดับที่ 3 (τ_3) และ ξ

$$\tau_3 = \frac{2(1-3^{-\xi})}{1-2^{-\xi}} - 3 \quad (2.37)$$

จากสมการข้างต้นไม่เป็นสมการเชิงเส้น จึงใช้การประมาณค่าด้วยวิธีการการวิเคราะห์เชิงตัวเลขด้วยวิธีการของนิวตัน-ราฟสัน (Newton - Rapson)

4) ประมาณค่าพารามิเตอร์ปรงขนาด ($\hat{\sigma}$) โดยใช้ความสัมพันธ์ระหว่าง L-Scale (λ_2) และ σ

$$\hat{\sigma} = \frac{\lambda_2 \xi}{(1-2^{-\xi}) \Gamma(1+\xi)} \quad (2.38)$$

5) ประมาณค่าพารามิเตอร์ปรงตำแหน่ง ($\hat{\mu}$) ใช้ความสัมพันธ์ระหว่าง L-Mean (λ_1) และ μ

$$\hat{\mu} = \lambda_1 - \hat{\sigma} \left(1 - \frac{\Gamma(1+\xi)}{\xi} \right) \quad (2.39)$$

2.3 ระดับการเกิดซ้ำ

เป็นการวิเคราะห์ข้อมูลในอดีตเพื่อวิเคราะห์ความถี่เหตุการณ์ค่าสุดขีดในรูปแบบความน่าจะเป็นเพื่อหาโอกาสที่เหตุการณ์เหล่านั้นจะเกิดซ้ำอีก โดยใช้หลักทฤษฎีค่าสุดขีดเพื่อหาปริมาณของค่าสุดขีดของเหตุการณ์ที่จะเกิดขึ้นในคาบเวลาของการเกิดซ้ำ (Return Period) (ปิยภัทร และอรุณ, 2558)

การคำนวณระดับการเกิดซ้ำ (x_T) ซึ่งก็คือตำแหน่งของข้อมูล โดยกำหนดให้ p คือความน่าจะเป็นของเหตุการณ์ที่ $x > x_T$ โดยเฉลี่ย 1 ครั้ง ในรอบปี T ซึ่ง T คือ คาบเวลาหรือรอบปีในการเกิดซ้ำที่มีความสัมพันธ์กับความน่าจะเป็นของเหตุการณ์โดยที่ $T = \frac{1}{p}$ หมายความว่า รอบการเกิดซ้ำ T ปี คือ จำนวนรอบปีที่เกิดค่าสุดขีดหรือเกิดภัยพิบัติ $x > x_T$ เกิดขึ้นเฉลี่ย 1 ครั้ง สามารถคำนวณระดับการเกิดซ้ำสำหรับการแจกแจงค่าสุดขีดวงนัยทั่วไป ได้ดังนี้

$$\hat{x}_T^{GEVD} = \hat{\mu} - \frac{\hat{\sigma}}{\hat{\xi}} \left\{ 1 - \left[-\log \left(1 - \frac{1}{T} \right) \right]^{-\hat{\xi}} \right\} \quad (2.40)$$

สำหรับการแจกแจงพารโตนวงนัยทั่วไป ซึ่งมีพารามิเตอร์ σ และ ξ เมื่อมีข้อมูลที่มีค่าเกินเกณฑ์ u แสดงว่า $Y > u$ ซึ่งสามารถเขียนสมการทั่วไปสำหรับโอกาสที่จะเกิดเหตุการณ์ดังกล่าว ได้ดังนี้

$$P(Y > u) = \zeta_u \left(1 + \xi \left(\frac{y-u}{\sigma} \right) \right)^{-1/\xi} \quad (2.41)$$

โดยกำหนดให้ $\zeta_u = P(Y > u)$ ดังนั้น ระดับการเกิดซ้ำ หมายถึง ค่าเฉลี่ยของค่าที่สูงเกินกว่าค่า u ทุก ๆ ค่าสังเกต ณ คาบเวลา T ที่สนใจ นั่นคือ

$$\zeta_u \left(1 + \xi \left(\frac{y-u}{\sigma} \right) \right)^{-1/\xi} = \frac{1}{T} \quad (2.42)$$

และสามารถจัดรูปสมการระดับการเกิดซ้ำ สำหรับการแจกแจงพาริตัววงนัยทั่วไป ได้ดังนี้

$$y_T^{GPD} = \hat{\mu} - \frac{\hat{\sigma}}{\xi} \left[(T\xi_u)^\xi - 1 \right] \quad (2.43)$$

เมื่อ n_y คือ จำนวนค่าสังเกตต่อปี และ N คือจำนวนปี จะได้ $T = N \times n_y$

เมื่อแทนค่าตัวประมาณพารามิเตอร์จากการแจกแจงค่าสุดขีดวงนัยทั่วไปและการแจกแจงพาริตัววงนัยทั่วไป จะสามารถประมาณค่าความน่าจะเป็นสูงสุดของระดับการเกิดซ้ำได้

2.4 เกณฑ์การคัดเลือก

ในการศึกษาครั้งนี้ จะพิจารณาความเหมาะสมของข้อมูลด้วยวิธีค่าเฉลี่ยความคลาดเคลื่อนกำลังสอง (Mean Square Error: MSE) ต่ำสุดสำหรับข้อมูลจำลอง และวิธีค่าเฉลี่ยของเปอร์เซ็นต์ความผิดพลาดสัมบูรณ์ (Mean Absolute Percentage Error: MAPE) ต่ำสุดสำหรับข้อมูลปริมาณน้ำฝนสูงสุดในแต่ละเขตพื้นที่ของกรุงเทพมหานคร

2.4.1 วิธีค่าเฉลี่ยความคลาดเคลื่อนกำลังสอง (Mean Square Error: MSE)

เป็นค่าที่ใช้วัดความถูกต้องของการพยากรณ์ที่วัดจากค่าความคลาดเคลื่อน โดยที่ค่า MSE จะวัดต่อความคลาดเคลื่อนที่มีขนาดใหญ่ เนื่องจากค่าดังกล่าวถูกคำนวณโดยการนำค่าความคลาดเคลื่อนแต่ละค่ายกกำลังสอง โดย MSE สามารถคำนวณได้ดังสมการที่ (2.47)

$$MSE = \frac{1}{m} \sum_{i=1}^m (\theta - \hat{\theta}_i)^2 \quad (2.47)$$

โดยที่ θ_i แทน ค่าของพารามิเตอร์จากการแจกแจงค่าสุดขีดวงนัยทั่วไปและการแจกแจงพาริตัววงนัยทั่วไป เมื่อ $\theta = (\mu, \sigma, \xi)$

$\hat{\theta}_i$ แทน ค่าประมาณของพารามิเตอร์ที่ได้จากการจำลองจากการแจกแจงค่าสุดขีดวงนัยทั่วไปและการแจกแจงพาริตัววงนัยทั่วไป เมื่อ $\theta_i = (\mu_i, \sigma_i, \xi_i)$

m แทน จำนวนรอบในการจำลองข้อมูลที่ได้จากการแจกแจงค่าสุ่มชี้ดวงนัยทั่วไป และการแจกแจงพารามิเตอร์ดวงนัยทั่วไป

2.4.2 วิธีค่าเฉลี่ยของเปอร์เซ็นต์ความผิดพลาดสัมบูรณ์ (Mean Absolute Percentage Error: MAPE)

เป็นค่าที่ใช้วัดความถูกต้องของการพยากรณ์ที่วัดจากค่าความคลาดเคลื่อน โดยค่าวัดความถูกต้องนี้ไม่มีหน่วยจึงเหมาะสมสำหรับเปรียบเทียบข้อมูลหลายชุดเมื่อใช้วิธีการพยากรณ์เดียวกัน หรือเปรียบเทียบวิธีการพยากรณ์หลายวิธีเมื่อใช้ข้อมูลชุดเดียวกัน โดยการคำนวณค่า MAPE สำหรับการแจกแจงค่าสุ่มชี้ดวงนัยทั่วไปสามารถคำนวณได้ดังสมการที่ (2.48)

$$MAPE = \frac{1}{9} \sum_{T=1}^9 \left| \frac{x_T - \hat{x}_T^{GPD}}{x_T} \right| \times 100 \quad (2.48)$$

โดยที่ x_T แทน ค่าของข้อมูลจริง ณ คาบเวลาการเกิดซ้ำ T

\hat{x}_T^{GPD} แทน ค่าที่ได้จากการประมาณระดับการเกิดซ้ำ ณ คาบเวลาการเกิดซ้ำ T

สำหรับการแจกแจงพารามิเตอร์ดวงนัยทั่วไปสามารถคำนวณค่า MAPE ได้ดังสมการที่ (2.49)

$$MAPE = \frac{1}{9} \sum_{T=1}^9 \left| \frac{y_T - \hat{y}_T^{GPD}}{y_T} \right| \times 100 \quad (2.49)$$

โดยที่ y_T แทน ค่าของข้อมูลจริง ณ คาบเวลาการเกิดซ้ำ T

\hat{y}_T^{GPD} แทน ค่าที่ได้จากการประมาณระดับการเกิดซ้ำ ณ คาบเวลาการเกิดซ้ำ T

2.5 งานวิจัยที่เกี่ยวข้อง

ประภาวรณ และปิยภัทร (2560) ได้ศึกษาทฤษฎีค่าสุ่มชี้ดวงเพื่อหาแบบจำลองที่เหมาะสมกับข้อมูลอุณหภูมิสูงสุดของภาคตะวันออกเฉียงเหนือของประเทศไทย โดยใช้การแจกแจงค่าสุ่มชี้ดวงนัย

ทั่วไป และการแจกแจงพาริตัววางนัยทั่วไป พร้อมทั้งหาระดับการเกิดซ้ำของอุณหภูมิสูงสุดจากข้อมูล ทั้ง 25 สถานี โดยทำการวิเคราะห์ผ่านโปรแกรม R จากการศึกษา พบว่า การแจกแจงไวบูล และการแจกแจงกัมเบล เป็นการแจกแจงที่เหมาะสมสำหรับข้อมูลอุณหภูมิสูงสุดของสถานีจำนวน 15 สถานี และ 10 สถานี ตามลำดับ และการแจกแจงที่เหมาะสมเมื่อศึกษาด้วยการแจกแจงพาริตัววางนัยทั่วไป ได้แก่ การแจกแจงแกมมา จำนวน 24 สถานี และการแจกแจงเอกซ์โพเนนเชียล จำนวน 1 สถานี และเมื่อพิจารณาระดับการเกิดซ้ำในแต่ละคาบเวลา พบว่า ระดับการเกิดซ้ำของทุกสถานีมีค่าสูงขึ้นเมื่อจำนวนรอบปีการเกิดซ้ำเพิ่มขึ้น

กฤตยา และคณะ (2561) ได้ศึกษาหาตัวแบบที่เหมาะสมกับปริมาณน้ำฝนสูงสุดรายปีในภาคตะวันออกเฉียงเหนือของประเทศไทยจำนวน 25 สถานี ด้วยการแจกแจงค่าสุดขีดวางนัยทั่วไป การแจกแจงพาริตัวประเภทที่ 3 และการแจกแจงโลจิสติกวางนัยทั่วไป โดยใช้วิธีการประมาณโมเมนต์เชิงเส้นตรง ใช้ความคลาดเคลื่อนรากที่สองสัมพัทธ์ หรือ RRME เป็นเกณฑ์สำหรับเลือกการแจกแจงที่ดีที่สุด ผลจากการศึกษาพบว่า ร้อยละ 56 ของสถานีในพื้นที่ภาคตะวันออกเฉียงเหนือ ปริมาณน้ำฝนสูงสุดมีการแจกแจงโลจิสติกวางนัยทั่วไป ร้อยละ 36 ปริมาณน้ำฝนสูงสุดมีการแจกแจงค่าสุดขีดวางนัยทั่วไป และร้อยละ 8 ปริมาณน้ำฝนสูงสุดมีการแจกแจงพาริตัวประเภทที่ 3

วิภาดา และคณะ (2566) ได้ทำการศึกษาหาตัวแบบจำลองที่เหมาะสมจากทฤษฎีค่าสุดขีดสำหรับข้อมูลความสูงของคลื่นทะเลบริเวณรอบ ๆ ชายฝั่งอ่าวไทยทั้ง 3 จังหวัด ได้แก่ ตราด เพชรบุรี และสุราษฎร์ธานี รายสัปดาห์ ตั้งแต่ปี พ.ศ.2550 ถึง พ.ศ.2562 โดยเปรียบเทียบ 2 การแจกแจงคือ การแจกแจงค่าสุดขีดวางนัยทั่วไป และการแจกแจงพาริตัววางนัยทั่วไป และใช้วิธีการประมาณค่าด้วยวิธีภาวะน่าจะเป็นสูงสุด สำหรับการแจกแจงค่าสุดขีดวางนัยทั่วไป และวิธีค่าสูงสุดที่มีค่าเกินเกณฑ์ที่กำหนด สำหรับการแจกแจงพาริตัววางนัยทั่วไป เพื่อคาดการณ์ระดับการเกิดซ้ำ ค่าสุดขีดของความสูงคลื่นทะเลในอีก 2 ปี 5 ปี 10 ปี และ 20 ปี ข้างหน้า โดยใช้สารสนเทศของอะกะอิเกะ (Akaike's Information Criterion: AIC) เป็นเกณฑ์ในการตัดสินใจเลือกตัวแบบ ผลการวิจัยพบว่า ข้อมูลความสูงคลื่นทะเลรอบ ๆ ชายฝั่งบริเวณที่คัดเลือกรายสัปดาห์เหมาะสมกับการแจกแจงพาริตัววางนัยทั่วไป

ธนโชติ และมานัดถ์ (2564) ได้ศึกษาหาตัวแบบที่เหมาะสมกับข้อมูลปริมาณน้ำฝนรายเดือนบริเวณลุ่มแม่น้ำปิงตอนบน จังหวัดเชียงใหม่ โดยใช้การแจกแจงพาริตัววางนัยทั่วไปและเพื่อหาระดับการเกิดซ้ำของปริมาณน้ำฝนรายเดือน ในรอบปีการเกิดซ้ำต่าง ๆ โดยใช้ข้อมูล 14 ปี จำนวน 6 สถานี พบว่า สถานีเภอเวียงแหง สถานีอำเภอสันทราย สถานีอำเภอดอยสะเก็ด สถานีอำเภอเมือง และ สถานีอำเภอแม่แตง ตัวแบบการแจกแจงพาริตัววางนัยทั่วไปที่กระบวนการคงที่เหมาะสมที่สุด ขณะที่ สถานีอำเภอแม่แตง ตัวแบบการแจกแจงพาริตัววางนัยทั่วไปเมื่อพารามิเตอร์แสดงตำแหน่ง

เปลี่ยนแปลงในเชิงฟังก์ชันแบบเลขชี้กำลังเหมาะสมมากที่สุด สำหรับค่าประมาณระดับการเกิดซ้ำของปริมาณรายเดือน สถานีอำเภอแม่วางมีระดับการเกิดซ้ำของปริมาณน้ำฝนรายเดือนมากที่สุดในทุก ๆ รอบปีการเกิดซ้ำ

วรภัทร และคณะ (2560) ได้ศึกษาวิธีการประมาณค่าพารามิเตอร์ของการแจกแจงพาเรโตวางนัยทั่วไป โดยวิธีการแปลงการลงจุดตำแหน่งที่เหมาะสม และเปรียบเทียบวิธีภาวะน่าจะเป็นสูงสุดและวิธีโมเมนต์ถ่วงน้ำหนักความน่าจะเป็น พร้อมทั้งประยุกต์ใช้วิธีการประมาณค่าพารามิเตอร์กับข้อมูลทางด้านการเงิน ผลการศึกษาพบว่า ในส่วนของการจำลองข้อมูล วิธีการประมาณค่าพารามิเตอร์ด้วยวิธีการแปลงการลงจุดตำแหน่ง มีค่าความเอนเอียงและรากของค่าคลาดเคลื่อนกำลังสองเฉลี่ยต่ำสุดสำหรับขนาดตัวอย่างขนาดเล็ก และวิธีภาวะน่าจะเป็นสูงสุดมีค่าความเอนเอียงและรากของค่าคลาดเคลื่อนกำลังสองเฉลี่ยต่ำสุดสำหรับตัวอย่างขนาดใหญ่ ในส่วนการประยุกต์ใช้ข้อมูลของหลักทรัพย์ บริษัททรูคอร์ปอเรชั่น จำกัด (มหาชน) พบว่า มูลค่าความเสี่ยงของวิธีภาวะน่าจะเป็นสูงสุด วิธีโมเมนต์ถ่วงน้ำหนักความน่าจะเป็น และวิธีการแปลงการลงจุดตำแหน่งที่เหมาะสมที่ควอนไทล์ 95% มีค่าเท่ากับ 0.1066, 0.1080 และ 0.1084 ตามลำดับ และควอนไทล์ 99% มีค่าเท่ากับ 0.1838, 0.1801 และ 0.1796 ตามลำดับ

ทศพล (2565) ได้ทำการศึกษาการสร้างแบบจำลองพารามิเตอร์บ่งรูปร่างของการแจกแจงค่าสุดขีดวางนัยทั่วไปจากข้อมูลน้ำฝน-น้ำท่า และข้อมูลภาพถ่ายดาวเทียมโดยใช้วิธีโครงข่ายประสาทเทียม โดยมีวัตถุประสงค์หลักของงานวิจัยนี้คือการหาตัวแปรที่ส่งผลต่อการเปลี่ยนแปลงพารามิเตอร์บ่งรูปร่าง โดยพิจารณาจากค่าสัมประสิทธิ์สหสัมพันธ์ พร้อมทั้งสร้างแบบจำลองพารามิเตอร์บ่งรูปร่างภายใต้การแจกแจงค่าสุดขีดวางนัยทั่วไป เพื่อนำผลมาศึกษาคาดการณ์พื้นที่เสี่ยงต่อการเกิดอุทกภัยน้ำท่วมด้วยแผนที่ระดับการเกิดซ้ำ โดยรวบรวมข้อมูลย้อนหลัง 11 ปี จำนวน 92 สถานี ทำการประมาณค่าพารามิเตอร์ด้วยแบบจำลองกระบวนการคงที่ด้วยวิธีภาวะน่าจะเป็นสูงสุด และแบบจำลองกระบวนการไม่คงที่ด้วยวิธีโครงข่ายประสาทเทียม ภายใต้การแจกแจงค่าสุดขีดวางนัยทั่วไป และทำการเปรียบเทียบแบบจำลองด้วยค่าสัมประสิทธิ์ประสิทธิภาพ แนช-ซัทคลิฟ (Nash-Sutcliffe Efficiency) พบว่า แบบจำลองกระบวนการไม่คงที่มีความเหมาะสมกับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนทั้งหมด 59 สถานี และแบบจำลองกรณีกระบวนการคงที่มีความเหมาะสมกับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนทั้งหมด 33 สถานี

Rehman ang Zhang (2023) ได้ศึกษาทฤษฎีค่าสุดขีดเพื่อวิเคราะห์ขนาดแผ่นดินไหวสูงสุดต่อปีในเขตมุดตัวของเปลือกโลกมักราน ด้วยการประยุกต์ใช้วิธีกำหนดช่วงเพื่อหาค่าสูงสุดโดยข้อมูลแผ่นดินไหวที่ใช้ในการศึกษานี้ถูกเก็บรวบรวมจากศูนย์วิทยาแผ่นดินไหวระหว่างประเทศ (ISC) กำหนดพารามิเตอร์จากการแจกแจงค่าสุดขีดวางนัยทั่วไป ผลการวิเคราะห์จากกราฟหลายรูปแบบที่

ใช้การแจกแจงค่าสุดขีดวางนัยทั่วไปแสดงให้เห็นว่ารูปแบบที่ใช้มีความแม่นยำเมื่อทำการปรับใช้กับข้อมูลแผ่นดินไหวในเขตมกราคม โดยใช้วิธีภาวะน่าจะเป็นโพรไฟล์ (Profile Likelihood) ในการประมาณค่าพารามิเตอร์บ่งรูปร่าง ซึ่งได้ค่าที่คำนวณเท่ากับ 0.29 พบว่า การแจกแจงแบบพรีเซทเป็นตัวแบบที่ดีที่สุดในการพยากรณ์ขนาดแผ่นดินไหวสูงสุดต่อปีในเขตการมุดตัวเปลือกโลกมกราคม การคำนวณระดับการเกิดซ้ำโดยประมาณสำหรับคาบเวลาการเกิดซ้ำ แตกต่างกัน 10, 20, 50 และ 100 ปี อยู่ที่ 6.35, 6.81, 7.58 และ 8.31 ตามลำดับ ทำให้เห็นว่าขนาดของแผ่นดินไหวรุนแรงขึ้นตามปีที่เพิ่มขึ้น ผู้วิจัยได้คำนวณช่วงความเชื่อมั่นด้วยวิธีภาวะน่าจะเป็นโพรไฟล์ ในขณะเดียวกัน การเกิดแผ่นดินไหวในปี 1945 ในเขตการมุดตัวเปลือกโลกมกราคมที่มีขนาด 8.1 แมกนิจูด (Mw) เป็นหนึ่งในเหตุการณ์ที่สำคัญที่สุดในพื้นที่นี้และเกิดขึ้นหนึ่งครั้งในทุก ๆ 100 ปี

Ng et al. (2022) ได้ศึกษาหาตัวแบบที่เหมาะสมที่สุดสำหรับข้อมูลอุณหภูมิสูงสุดเกิดขึ้นรายเดือนและรายปี ข้อมูลอุณหภูมิสูงสุดที่ระดับรายเดือนและรายปีได้มาจากการมอดูนิยมหาวิทยาลัยมาเลเซีย (MMD) โดยข้อมูลอุณหภูมิในระยะเวลา 40 ปีสอดคล้องกับการแจกแจงความน่าจะเป็น 10 การแจกแจงต่าง ๆ สำหรับแต่ละสถานีตรวจวัด พารามิเตอร์ของการแจกแจงได้ถูกประมาณค่าโดยวิธีภาวะน่าจะเป็นสูงสุด และวิธีโมเมนต์เชิงเส้น นอกจากนี้ยังมีการทดสอบภาวะสารูปสนิทธิ (Goodness of Fit Tests) 3 วิธีการ ได้แก่ การทดสอบคอลโมโกรอฟ-สมิรโนฟ (Kolmogorov-Smirnov test), การทดสอบแอนเดอร์สัน-ดาร์ลิง (Anderson-Darling) และ Chi-Squared Error (CSE) เพื่อประเมินประสิทธิภาพของการแจกแจง ซึ่งการแจกแจงที่เหมาะสมที่สุดเมื่อพิจารณาจากเกณฑ์การทดสอบที่ต่ำที่สุดจากผลทดสอบภาวะสารูปสนิทธิ 3 วิธีการ ผลการศึกษานี้แสดงให้เห็นว่าการแจกแจงค่าสุดขีดวางนัยทั่วไปเป็นการแจกแจงที่เหมาะสมที่สุด

บทที่ 3

วิธีการดำเนินงานวิจัย

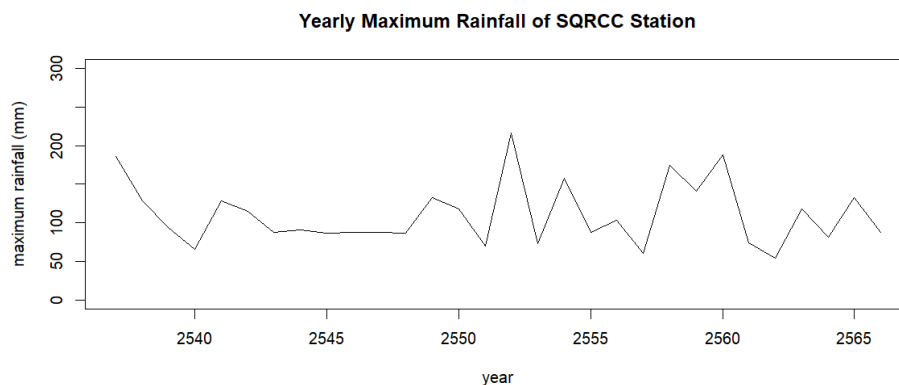
ในบทนี้กล่าวถึงวิธีการดำเนินงานวิจัย เพื่อประมาณค่าพารามิเตอร์ของการแจกแจงค่าสุดขีด
นัยทั่วไป และการแจกแจงพาวเรโตนัยทั่วไป ด้วยวิธีภาวะน่าจะเป็นสูงสุด วิธีภาวะน่าจะเป็นสูงสุดทั่วไป
วิธีของเบส์ และวิธีโมเมนต์เชิงเส้น และประยุกต์วิธีดังกล่าวสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายปี
และรายเดือนของแต่ละเขตพื้นที่ในกรุงเทพมหานคร ซึ่งขั้นตอนการดำเนินงาน ประกอบด้วย

3.1 การเก็บรวบรวมข้อมูล


ข้อมูลปริมาณน้ำฝนสูงสุดที่ใช้ในงานวิจัยชิ้นนี้เป็นข้อมูลทุติยภูมิ (Secondary Data) ซึ่งได้มา
จากกรมอุตุนิยมวิทยา ข้อมูลดังกล่าวถูกรวบรวมตั้งแต่เดือนมกราคม พ.ศ. 2537 ถึงเดือนธันวาคม
พ.ศ. 2566 รวม 360 เดือน ณ สถานีอุตุนิยมวิทยาจำนวน 4 แห่ง ได้แก่ ศูนย์การประชมแห่งชาติ
สิริกิติ์ ดอนเมือง บางนา และคลองเตย

ในการประมาณค่าพารามิเตอร์ พิจารณาจากการแจกแจงค่าสุดขีดวางนัยทั่วไปและการแจก
แจงพาวเรโตวางนัยทั่วไป โดยกำหนดข้อมูลปริมาณน้ำฝนสูงสุดออกเป็น 2 ลักษณะ ประกอบด้วย
ข้อมูลปริมาณน้ำฝนสูงสุดรายปีและข้อมูลปริมาณน้ำฝนสูงสุดรายเดือน

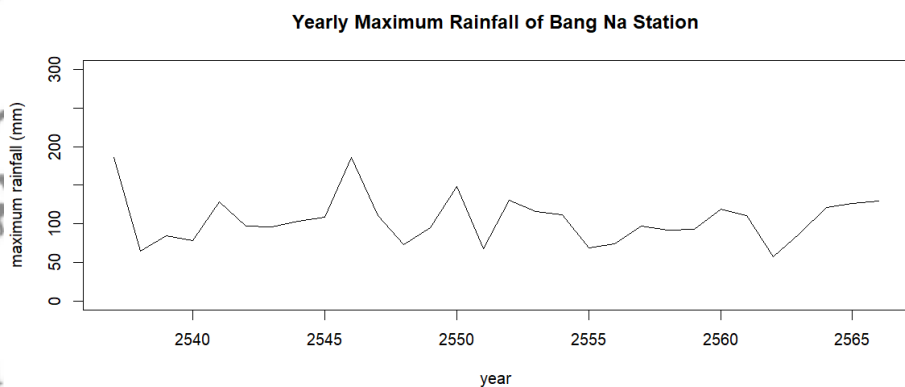
1) สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายปี ระหว่าง พ.ศ. 2537 ถึง พ.ศ. 2566 จำนวน 30 ปี
เพื่อวิเคราะห์สำหรับตัวแบบการแจกแจงค่าสุดขีดวางนัยทั่วไปด้วยวิธีกำหนดช่วงเพื่อหาค่าสูงสุด
(Block Maxima Model) ดังรูปที่ 3.1 – 3.4



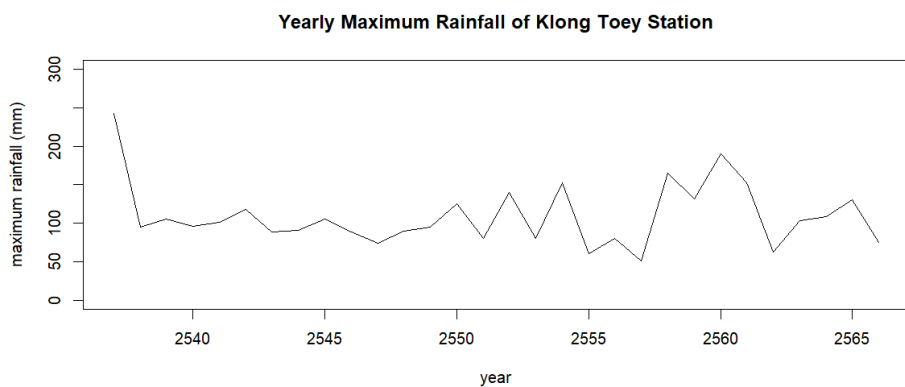
รูปที่ 3.1 ปริมาณน้ำฝนสูงสุดรายปี สถานีศูนย์การประชมแห่งชาติสิริกิติ์ ตั้งแต่ พ.ศ. 2537 – 2566



รูปที่ 3.2 ปริมาณน้ำฝนสูงสุดรายปี สถานีดอนเมือง ตั้งแต่ พ.ศ. 2537 - 2566




รูปที่ 3.3 ปริมาณน้ำฝนสูงสุดรายปี สถานีบางนา ตั้งแต่ พ.ศ. 2537 - 2566



รูปที่ 3.4 ปริมาณน้ำฝนสูงสุดรายปี สถานีคลองเตย ตั้งแต่ พ.ศ. 2537 - 2566


2) สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือน ระหว่าง พ.ศ. 2537 ถึง พ.ศ. 2566 จำนวน 360 เดือน เพื่อวิเคราะห์สำหรับตัวแบบการแจกแจงพาราไวงานัยทั่วไปด้วยวิธีค่าสูงสุดที่มีค่าเกินเกณฑ์ที่กำหนด (Peak Over Threshold Model) ดังรูปที่ 3.5 – 3.8

Monthly Maximum Rainfall of SQRCC Station




รูปที่ 3.5 ปริมาณน้ำฝนสูงสุดรายเดือน สถานีศูนย์การประชุมแห่งชาติสิริกิติ์ ตั้งแต่ พ.ศ. 2537 – 2566

Monthly Maximum Rainfall of Don Muang Station

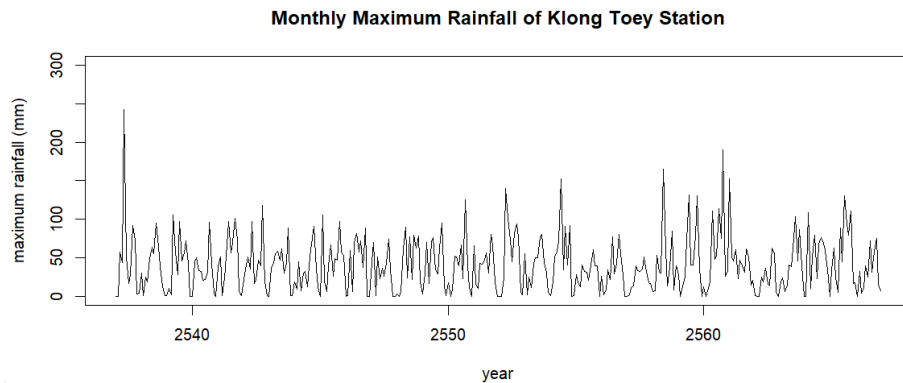


รูปที่ 3.6 ปริมาณน้ำฝนสูงสุดรายเดือน สถานีดอนเมือง ตั้งแต่ พ.ศ. 2537 – 2566

Monthly Maximum Rainfall of Bang Na Station



รูปที่ 3.7 ปริมาณน้ำฝนสูงสุดรายเดือน สถานีบางนา ตั้งแต่ พ.ศ. 2537 – 2566



รูปที่ 3.8 ปริมาณน้ำฝนสูงสุดรายเดือน สถานีคลองเตย ตั้งแต่ พ.ศ. 2537 - 2566

3.2 การวิเคราะห์ข้อมูล

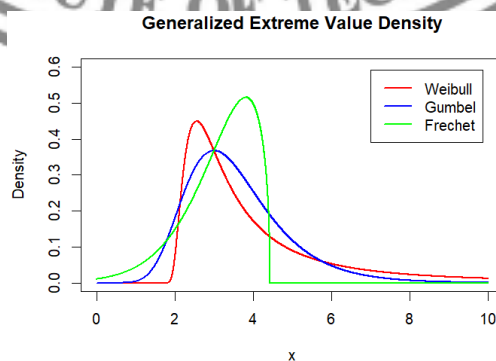
ในการวิเคราะห์ข้อมูลจะแบ่งเป็น 2 ส่วนคือข้อมูลจำลอง และข้อมูลจริง ดังต่อไปนี้

3.2.1 ข้อมูลจำลอง

การวิเคราะห์ข้อมูลจำลองได้ทำการจำลองข้อมูลของการแจกแจงค่าสุดขีดวงนัยทั่วไปและการแจกแจงพาราโตวงนัยทั่วไป ดังนี้

3.2.1.1 การแจกแจงค่าสุดขีดวงนัยทั่วไป

- 1) กำหนดขนาดตัวอย่างที่ศึกษาเท่ากับ 30, 50, 70 และ 100 ทำซ้ำจำนวน 1,000 ครั้ง โดยขนาดตัวอย่างและจำนวนครั้งในการทำซ้ำดังกล่าว นำมาใช้ในการประมาณค่าพารามิเตอร์
- 2) จำลองข้อมูลสำหรับการแจกแจงค่าสุดขีดวงนัยทั่วไป โดยกำหนดพารามิเตอร์บ่งตำแหน่งเท่ากับ 3 พารามิเตอร์บ่งขนาดเท่ากับ 1 และพารามิเตอร์บ่งรูปร่างเท่ากับ -0.7 สำหรับการแจกแจงไวบูล, 0 สำหรับการแจกแจงกัมเบล และ 0.7 สำหรับการแจกแจงเฟรเชท ตามลำดับ โดยค่าพารามิเตอร์ดังกล่าว นำมาใช้ในการประมาณค่าพารามิเตอร์ ดังรูปที่ 3.9



รูปที่ 3.9 การแจกแจงค่าสุดขีดวงนัยทั่วไปภายใต้พารามิเตอร์บ่งรูปร่างที่แตกต่างกัน

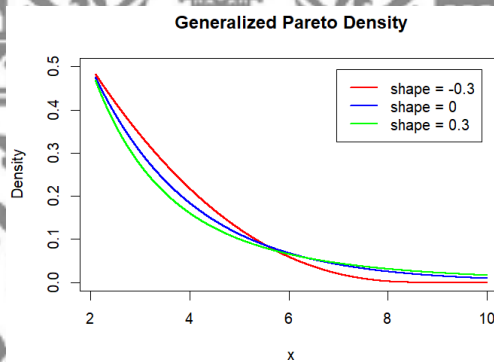
3) ได้ค่าประมาณพารามิเตอร์ของการแจกแจงค่าสุดขีดวงนัยทั่วไป คือ μ, σ, ξ โดยวิธีภาวะน่าจะเป็นสูงสุด วิธีภาวะน่าจะเป็นสูงสุดทั่วไป วิธีของเบส์ และวิธีโมเมนต์เชิงเส้น

4) เปรียบเทียบวิธีประมาณค่าพารามิเตอร์ทั้ง 4 วิธีสำหรับการแจกแจงค่าสุดขีดวงนัยทั่วไป โดยพิจารณาจากค่าเฉลี่ยความคลาดเคลื่อนกำลังสอง (Mean Squared Error: MSE) ต่ำสุด

3.2.1.2 การแจกแจงพารโรวางนัยทั่วไป

1) กำหนดขนาดตัวอย่างที่ศึกษาเท่ากับ 300, 500, 700 และ 1,000 ทำซ้ำจำนวน 1,000 ครั้ง โดยขนาดตัวอย่างและจำนวนครั้งในการทำซ้ำดังกล่าว นำมาใช้ในการประมาณค่าพารามิเตอร์

2) จำลองข้อมูลสำหรับการแจกแจงค่าพารโรวางนัยทั่วไป โดยกำหนดพารามิเตอร์บ่งตำแหน่งเท่ากับ 2 พารามิเตอร์บ่งขนาดเท่ากับ 2 และพารามิเตอร์บ่งรูปร่างเท่ากับ -0.3, 0 และ 0.3 ตามลำดับ โดยค่าพารามิเตอร์ดังกล่าว นำมาใช้ในการประมาณค่าพารามิเตอร์ ดังรูปที่ 3.10



รูปที่ 3.10 การแจกแจงพารโรวางนัยทั่วไปภายใต้พารามิเตอร์บ่งรูปร่างที่แตกต่างกัน

3) กำหนดค่าเกณฑ์ (Threshold) เท่ากับเปอร์เซ็นต์ไทล์ที่ 85, 90 และ 95 สำหรับการประมาณค่าพารามิเตอร์

4) ได้ค่าประมาณพารามิเตอร์ของการแจกแจงพารโรวางนัยทั่วไป คือ μ, σ, ξ โดยวิธีภาวะน่าจะเป็นสูงสุด วิธีภาวะน่าจะเป็นสูงสุดทั่วไป วิธีของเบส์ และวิธีโมเมนต์เชิงเส้น

5) เปรียบเทียบวิธีประมาณค่าพารามิเตอร์ทั้ง 4 วิธีสำหรับและการแจกแจงพารโรวางนัยทั่วไป โดยพิจารณาจากค่าเฉลี่ยความคลาดเคลื่อนกำลังสอง (Mean Squared Error: MSE) ต่ำสุด

3.2.2 ข้อมูลจริง

การวิเคราะห์ข้อมูลจริงประกอบไปด้วยขั้นตอนต่อไปนี้

1) ทำการวิเคราะห์ข้อมูลด้วยค่าสถิติเบื้องต้น ได้แก่ ค่าสูงสุด ค่าต่ำสุด ค่าเฉลี่ย ส่วนเบี่ยงเบนมาตรฐาน ค่าความเบ้ และค่าความโด่ง

2) ประมาณค่าพารามิเตอร์ของการแจกแจงค่าสุดขีดวงนัยทั่วไป สำหรับข้อมูลสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายปี ระหว่าง พ.ศ. 2537 ถึง พ.ศ. 2566 จำนวน 30 ค่าสังเกต โดยวิธีภาวน่าจะเป็นสูงสุด วิธีภาวน่าจะเป็นสูงสุดทั่วไป วิธีของเบส์ และวิธีโมเมนต์เชิงเส้น

3) ประมาณค่าพารามิเตอร์ของการแจกแจงพาเรโตวงนัยทั่วไป สำหรับข้อมูลสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือน ระหว่าง พ.ศ. 2537 ถึง พ.ศ. 2566 จำนวน 360 ค่าสังเกต โดยวิธีภาวน่าจะเป็นสูงสุด วิธีภาวน่าจะเป็นสูงสุดทั่วไป วิธีของเบส์ และวิธีโมเมนต์เชิงเส้น

4) ได้ค่าประมาณพารามิเตอร์ของการแจกแจงค่าสุดขีดวงนัยทั่วไปและการแจกแจงพาเรโตวงนัยทั่วไป μ, σ, ξ โดยวิธีภาวน่าจะเป็นสูงสุด วิธีภาวน่าจะเป็นสูงสุดทั่วไป วิธีของเบส์ และวิธีโมเมนต์เชิงเส้น แล้วนำไปสร้างตัวแบบพยากรณ์

5) สำหรับตัวแบบพยากรณ์ที่ได้ของการแจกแจงค่าสุดขีดวงนัยทั่วไปและการแจกแจงพาเรโตวงนัยทั่วไป นำค่าประมาณพารามิเตอร์ที่ได้สำหรับแต่ละเขตพื้นที่มาคำนวณระดับการเกิดซ้ำ (Return Level) โดยกำหนดคาบเวลาการเกิดซ้ำ (Return Period) เท่ากับ 2, 3, 4, ..., 10 ปี

6) พิจารณาความเหมาะสมของตัวแบบพยากรณ์ด้วยค่าเฉลี่ยของเปอร์เซ็นต์ความผิดพลาดสัมบูรณ์ (Mean Absolute Percentage Error : MAPE)


3.3 การสรุปและอภิปรายผล

สรุปผลตัวแบบที่ดีที่สุดสำหรับแต่ละวิธีการประมาณค่าพารามิเตอร์ ซึ่งประกอบด้วย วิธีภาวน่าจะเป็นสูงสุด วิธีภาวน่าจะเป็นสูงสุดทั่วไป วิธีของเบส์ และวิธีโมเมนต์เชิงเส้น ของข้อมูลจำลองในการปรับเปลี่ยนค่าพารามิเตอร์บ่งรูปร่าง สำหรับการแจกแจงค่าสุดขีดวงนัยทั่วไป และการแจกแจงพาเรโตวงนัยทั่วไป เพื่อหาวิธีที่ให้ตัวประมาณค่าพารามิเตอร์ที่ดีที่สุดโดยพิจารณาจากค่าคลาดเคลื่อนกำลังสองต่ำที่สุด

หลังจากนั้นนำวิธีดังกล่าวมาประยุกต์ใช้กับข้อมูลปริมาณน้ำฝนที่เก็บในเขตกรุงเทพมหานคร โดยการแจกแจงค่าสุดขีดวงนัยทั่วไปสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายปี และการแจกแจงพาเรโตวงนัยทั่วไปสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือน รวมไปถึงการคำนวณระดับการเกิดซ้ำที่รอบการเกิดซ้ำต่าง ๆ เพื่อเป็นแนวทางในการบริหารจัดการทรัพยากรน้ำในระยะยาว สำหรับหน่วยงานภาครัฐ เพื่อป้องกันปัญหาอุทกภัยในพื้นที่ การวางแผนการจัดเก็บน้ำ การระบายน้ำ การวางรากฐานโครงสร้างทางวิศวกรรมเพื่อออกแบบโครงสร้างชลประทาน


3.4 ขั้นตอนที่ใช้ในการวิจัย

การประมาณค่าพารามิเตอร์สำหรับการแจกแจงค่าสุตซ์ิตวางนัยทั่วไป มีขั้นตอนดังรูปที่ 3.11




รูปที่ 3.11 กระบวนการในการประมาณค่าพารามิเตอร์จากการแจกแจง GEVD

การประมาณค่าพารามิเตอร์สำหรับการแจกแจงพาวเรโตวางนัยทั่วไป มีขั้นตอนดังรูปที่ 3.12




รูปที่ 3.12 กระบวนการในการประมาณค่าพารามิเตอร์จากการแจกแจง GPD

การประมาณค่าพารามิเตอร์สำหรับการแจกแจงค่าสุดขีดวางนัยทั่วไปสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายปี มีขั้นตอนดังรูปที่ 3.13



รูปที่ 3.13 กระบวนการในการประมาณค่าพารามิเตอร์จากการแจกแจง GEVD โดยใช้ข้อมูลจริง

การประมาณค่าพารามิเตอร์สำหรับการแจกแจงพาวเรโรวางนัยทั่วไปสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือน มีขั้นตอนดังรูปที่ 3.14



รูปที่ 3.14 กระบวนการในการประมาณค่าพารามิเตอร์จากการแจกแจง GPD โดยใช้ข้อมูลจริง

บทที่ 4

ผลการวิจัยและการอภิปรายผล

ในบทนี้จะกล่าวถึงผลการวิเคราะห์ข้อมูลปริมาณน้ำฝนสูงสุดรายปีสำหรับการแจกแจงค่าสุดขีดวงนัยทั่วไป และข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนสำหรับการแจกแจงพาราเมเตอร์โตวงนัยทั่วไปของกรุงเทพมหานครทั้ง 4 สถานี ประกอบด้วย ศูนย์การประชุมแห่งชาติสิริกิติ์ ดอนเมือง บางนา และคลองเตย ประกอบด้วย การวิเคราะห์ข้อมูลทางสถิติพื้นฐาน การประมาณค่าพารามิเตอร์และเปรียบเทียบประสิทธิภาพของวิธีการประมาณค่าพารามิเตอร์ การประยุกต์ใช้วิธีการประมาณค่าพารามิเตอร์ที่เหมาะสมและหาระดับการเกิดซ้ำสำหรับข้อมูลปริมาณน้ำฝนสูงสุดแต่ละสถานี

4.1 การแจกแจงค่าสุดขีดวงนัยทั่วไป

เป็นการจำลองข้อมูลจากการแจกแจงค่าสุดขีดวงนัยทั่วไป ซึ่งประกอบไปด้วยพารามิเตอร์บ่งตำแหน่ง (Location Parameter: μ) พารามิเตอร์บ่งขนาด (Scale Parameter: σ) และพารามิเตอร์บ่งรูปร่าง (Shape Parameter: ξ) โดยมีการปรับพารามิเตอร์บ่งรูปร่างให้อยู่ในรูปแบบของการแจกแจงไวบูล (Weibull distribution) การแจกแจงกัมเบล (Gumbel Distribution) และการแจกแจงฟรีเชท (Fréchet Distribution) และทำการประมาณค่าพารามิเตอร์ด้วยวิธีภาวะน่าจะเป็นสูงสุด (ML) วิธีภาวะน่าจะเป็นสูงสุดทั่วไป (GML) วิธีของเบส์ (Bayesian) และวิธีโมเมนต์เชิงเส้น (L-moment) และนำวิธีดังกล่าวมาประยุกต์กับข้อมูลปริมาณน้ำฝนสูงสุดรายปี ตั้งแต่ พ.ศ. 2537–2566 จำนวน 30 ปี ของกรุงเทพมหานครทั้ง 4 สถานี ประกอบด้วย ศูนย์การประชุมแห่งชาติสิริกิติ์ ดอนเมือง บางนา และคลองเตย เพื่อวิเคราะห์ที่ตัวแบบสำหรับการแจกแจงค่าสุดขีดวงนัยทั่วไปโดยวิธีกำหนดช่วงเพื่อหาค่าสูงสุด (Block maxima model) ประกอบด้วยค่าสถิติเบื้องต้นพื้นฐาน การประมาณค่าพารามิเตอร์ หาวิธีการประมาณค่าพารามิเตอร์ที่เหมาะสมและคำนวณระดับการเกิดซ้ำสำหรับข้อมูลปริมาณน้ำฝนสูงสุดแต่ละสถานี

4.1.1 การประมาณค่าพารามิเตอร์สำหรับข้อมูลจำลอง

ในส่วนของข้อมูลจำลอง ทำการประมาณค่าพารามิเตอร์สำหรับการแจกแจงค่าสุดขีดวงนัยทั่วไปโดยใช้โปรแกรม R-Studio ซึ่งประกอบด้วยวิธีภาวะน่าจะเป็นสูงสุด (ML) วิธีภาวะน่าจะเป็นสูงสุดทั่วไป (GML) วิธีของเบส์ (Bayesian) และวิธีโมเมนต์เชิงเส้น (L-moment) โดยกำหนด

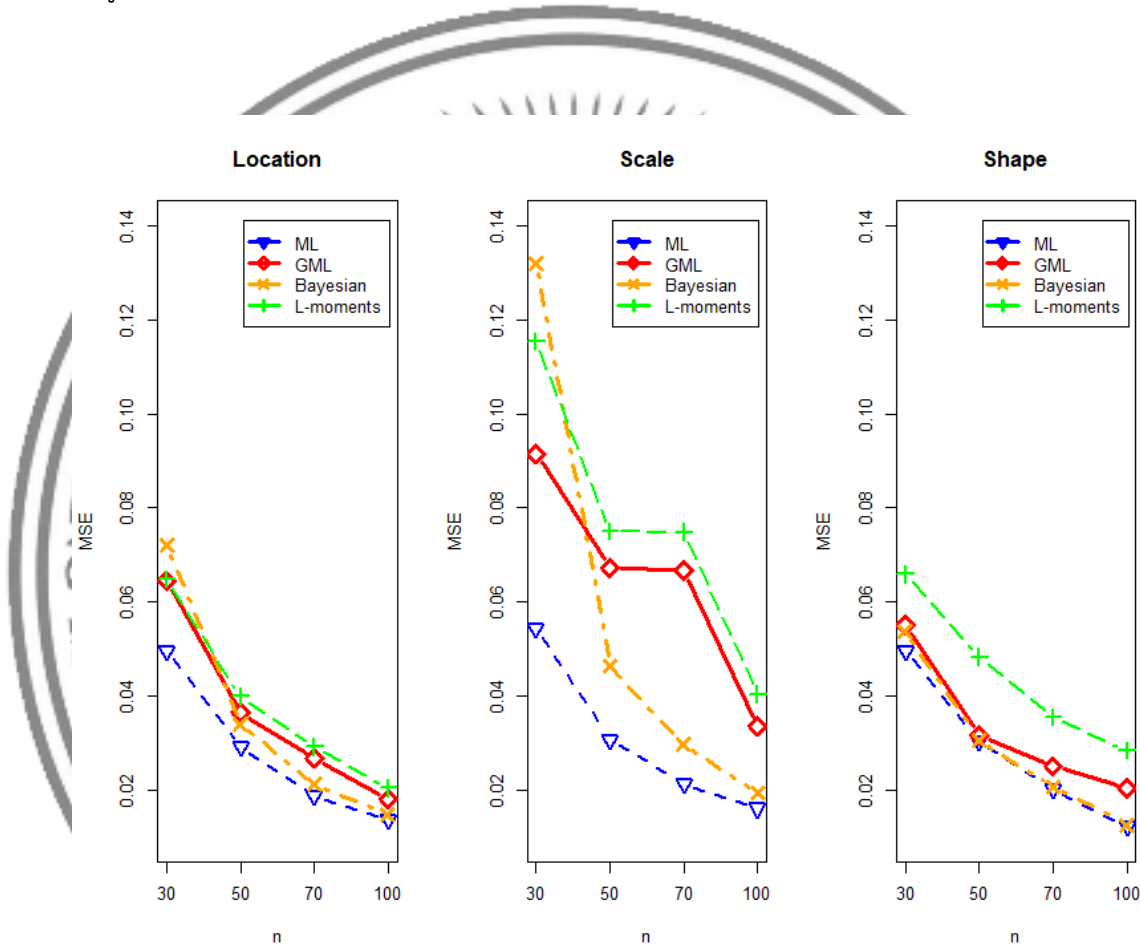
พารามิเตอร์บ่งตำแหน่ง (Location Parameter: μ) เท่ากับ 3 พารามิเตอร์บ่งขนาด (Scale Parameter: σ) เท่ากับ 1 และพารามิเตอร์บ่งรูปร่าง (Shape Parameter: ξ) เท่ากับ -0.7 สำหรับการแจกแจงไวล์บูล (Weibull distribution), 0 สำหรับการแจกแจงกัมเบล (Gumbel Distribution) และ 0.7 สำหรับการแจกแจงฟรีเชท (Fréchet Distribution) ตามลำดับ และกำหนดขนาดตัวอย่างที่ศึกษาเท่ากับ 30, 50, 70 และ 100 ทำซ้ำจำนวน 1,000 ครั้ง โดยผลลัพธ์เป็นค่าประมาณค่าพารามิเตอร์และค่าเฉลี่ยความคลาดเคลื่อนกำลังสอง (MSE) แสดงดังตารางที่ 4.1 – 4.3

ตารางที่ 4.1 ผลการจำลองข้อมูลการประมาณค่าพารามิเตอร์กรณี $\mu=3, \sigma=1$ และ $\xi=-0.7$

ขนาดตัวอย่าง	วิธีการประมาณค่าพารามิเตอร์	ค่าประมาณพารามิเตอร์			ค่าเฉลี่ยความคลาดเคลื่อนกำลังสอง (MSE)		
		Location (μ)	Scale (σ)	Shape (ξ)	Location (μ)	Scale (σ)	Shape (ξ)
30	ML	3.014	0.968	-0.713	0.0496	0.0544	0.0496
	GML	3.067	1.056	-0.545	0.0645	0.0915	0.0551
	Bayesian	3.077	1.169	-0.762	0.0721	0.1320	0.0538
	L-Moments	3.074	1.109	-0.517	0.0649	0.1154	0.0659
50	ML	3.006	0.974	-0.704	0.0292	0.0307	0.0303
	GML	3.040	1.051	-0.577	0.0365	0.0672	0.0316
	Bayesian	3.039	1.079	-0.725	0.0340	0.0464	0.0306
	L-Moments	3.052	1.093	-0.550	0.0399	0.0750	0.0483
70	ML	2.999	0.982	-0.714	0.0187	0.0213	0.0202
	GML	3.027	1.061	-0.597	0.0267	0.0667	0.0250
	Bayesian	3.026	1.055	-0.727	0.0212	0.0296	0.0206
	L-Moments	3.042	1.101	-0.577	0.0292	0.0748	0.0355
100	ML	3.001	0.987	-0.708	0.0136	0.0161	0.0123
	GML	3.031	1.054	-0.606	0.0181	0.0336	0.0204
	Bayesian	3.018	1.034	-0.715	0.0148	0.0194	0.0126
	L-Moments	3.042	1.085	-0.591	0.0204	0.0408	0.0284

หมายเหตุ ตัวเลขที่ขีดเส้นแสดงค่า MSE ที่ต่ำที่สุด

จากตารางที่ 4.1 พบว่า วิธี ML ให้ค่าการประมาณใกล้เคียงกับค่าจริงที่สุด และทำให้ค่า MSE มีค่าต่ำสุด เมื่อเทียบกับวิธีการอื่น ๆ สำหรับทุกขนาดข้อมูลตัวอย่างและทุกพารามิเตอร์ และเมื่อขนาดตัวอย่างเพิ่มขึ้น ค่าเฉลี่ยความคลาดเคลื่อนกำลังสอง (MSE) จะลดลงตามไปด้วย แสดงดังรูปที่ 4.1



รูปที่ 4.1 ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองของประมาณค่าพารามิเตอร์กรณี $\mu = 3, \sigma = 1$ และ $\xi = -0.7$

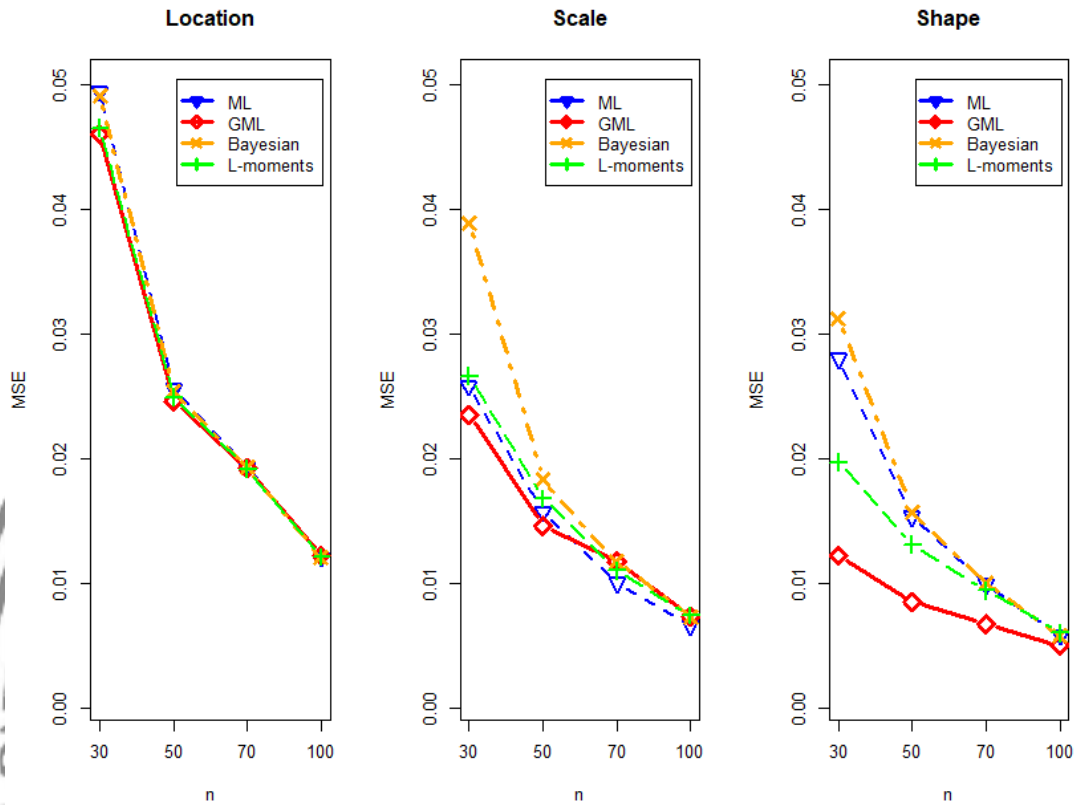
จากรูปที่ 4.1 พบว่า วิธี ML โดยทั่วไปมีประสิทธิภาพดีกว่าวิธีอื่น ๆ โดยให้ค่า MSE ที่ต่ำกว่าวิธีอื่น ๆ สำหรับทุกพารามิเตอร์ โดยเฉพาะเมื่อขนาดตัวอย่างเพิ่มขึ้น วิธี ML สามารถให้ค่า MSE ที่ต่ำกว่าอย่างสม่ำเสมอ โดยเฉพาะในกรณีที่มีขนาดตัวอย่างใหญ่ แสดงให้เห็นถึงประสิทธิภาพในการประมาณค่าพารามิเตอร์ ในขณะที่วิธี L-moments ให้ค่า MSE สูงกว่าวิธีอื่นทุกขนาดตัวอย่างซึ่งแสดงให้เห็นว่าวิธีนี้อาจไม่น่าเชื่อถือสำหรับการแจกแจงไวส์บูล

ตารางที่ 4.2 ผลการจำลองข้อมูลการประมาณค่าพารามิเตอร์กรณี $\mu=3, \sigma=1$ และ $\xi=0$

ขนาด ตัวอย่าง	วิธีการ ประมาณค่า พารามิเตอร์	ค่าประมาณพารามิเตอร์			ค่าเฉลี่ยความคลาดเคลื่อน กำลังสอง (MSE)		
		Location (μ)	Scale (σ)	Shape (ξ)	Location (μ)	Location (μ)	Scale (σ)
30	ML	3.017	0.966	0.008	0.0494	0.0258	0.0280
	GML	3.054	1.002	0.078	<u>0.0460</u>	<u>0.0235</u>	<u>0.0122</u>
	Bayesian	2.999	1.087	-0.055	0.0491	0.0389	0.0312
	L-Moments	3.002	0.993	0.007	0.0465	0.0266	0.0197
50	ML	3.012	0.972	0.006	0.0256	0.0157	0.0153
	GML	3.044	1.000	0.067	<u>0.0246</u>	<u>0.0146</u>	<u>0.0085</u>
	Bayesian	3.002	1.036	-0.028	0.0254	0.0183	0.0157
	L-Moments	3.003	0.991	0.007	0.0249	0.0168	0.0131
70	ML	3.010	0.987	0.006	0.0193	0.0100	0.0099
	GML	3.037	1.008	0.056	0.0192	<u>0.0097</u>	<u>0.0067</u>
	Bayesian	3.003	1.030	-0.017	0.0192	0.0117	0.0100
	L-Moments	3.003	0.999	0.005	0.0191	0.0110	0.0094
100	ML	3.006	0.991	0.006	0.0121	<u>0.0066</u>	0.0058
	GML	3.029	1.008	0.047	0.0122	0.0067	<u>0.0050</u>
	Bayesian	3.002	1.020	-0.009	<u>0.0120</u>	0.0073	0.0058
	L-Moments	3.002	1.000	0.005	0.0121	0.0074	0.0060

หมายเหตุ ตัวเลขที่ขีดเส้นแสดงค่า MSE ที่ต่ำที่สุด

จากตารางที่ 4.2 พบว่า สำหรับขนาดข้อมูลตัวอย่างเท่ากับ 30, 50 และ 70 เมื่อใช้วิธี GML ทำให้ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองมีค่าต่ำสุดสำหรับทุกพารามิเตอร์ แต่เมื่อขนาดตัวอย่างเพิ่มขึ้น วิธี ML หรือวิธี Bayesian อาจเป็นตัวเลือกที่เหมาะสมมากกว่าวิธี GML ซึ่งแต่ละวิธีขึ้นอยู่กับพารามิเตอร์ที่ต้องการประเมิน โดยค่าแนวโน้มของ MSE แสดงดังรูปที่ 4.2



รูปที่ 4.2 ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองของประมาณค่าพารามิเตอร์กรณี $\mu = 3, \sigma = 1$ และ $\xi = 0$

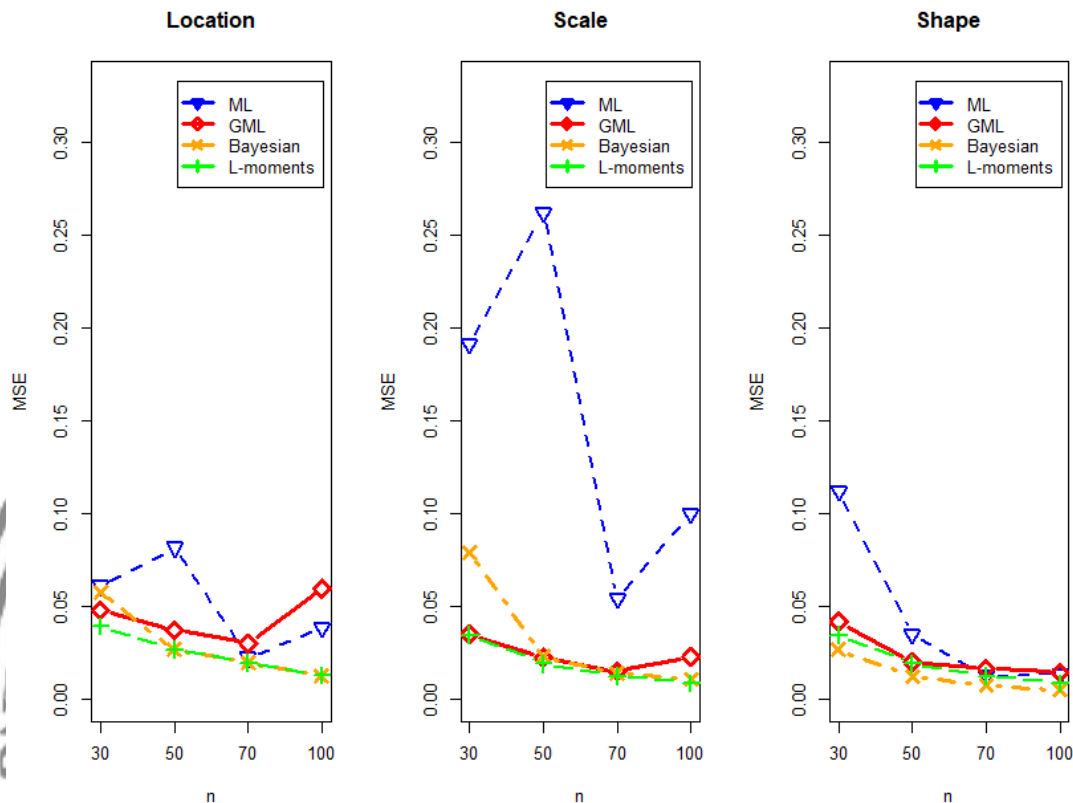
จากรูปที่ 4.2 พบว่าเมื่อขนาดตัวอย่างเพิ่มขึ้น ความแตกต่างของประสิทธิภาพระหว่างวิธีต่างๆ เพิ่มขึ้น โดยทุกวิธีให้ค่า MSE ต่ำเมื่อขนาดตัวอย่างใหญ่ขึ้น วิธี GML มีประสิทธิภาพดีในทุกพารามิเตอร์ โดยเฉพาะเมื่อขนาดตัวอย่างเล็ก ส่วนวิธี ML และ L-moments ก็ให้ผลลัพธ์ที่ดีเช่นกันในบางกรณี

ตารางที่ 4.3 ผลการจำลองข้อมูลการประมาณค่าพารามิเตอร์กรณี $\mu=3, \sigma=1$ และ $\xi=0.7$

ขนาด ตัวอย่าง	วิธีการ ประมาณค่า พารามิเตอร์	ค่าประมาณพารามิเตอร์			ค่าเฉลี่ยความคลาดเคลื่อน กำลังสอง (MSE)		
		Location (μ)	Scale (σ)	Shape (ξ)	Location (μ)	Scale (σ)	Shape (ξ)
30	ML	2.988	1.040	0.761	0.0607	0.1910	0.1116
	GML	2.932	0.927	0.576	0.0477	0.0347	0.0414
	Bayesian	2.929	1.032	0.649	0.0576	0.0786	<u>0.0263</u>
	L-Moments	2.979	0.950	0.644	<u>0.0390</u>	<u>0.0281</u>	0.0343
50	ML	2.997	1.044	0.745	0.0813	0.2619	0.0347
	GML	2.953	0.957	0.616	0.0369	0.0221	0.0197
	Bayesian	2.976	1.015	0.688	<u>0.0263</u>	0.0227	<u>0.0119</u>
	L-Moments	2.999	0.977	0.679	0.0264	<u>0.0174</u>	0.0189
70	ML	3.004	1.007	0.727	0.0220	0.0540	0.0120
	GML	2.944	0.975	0.619	0.0299	0.0148	0.0162
	Bayesian	2.975	1.014	0.692	0.0194	0.0138	<u>0.0070</u>
	L-Moments	2.984	0.987	0.673	<u>0.0193</u>	<u>0.0118</u>	0.0121
100	ML	2.984	1.046	0.735	0.0381	0.0998	0.0132
	GML	2.924	0.994	0.626	0.0593	0.0226	0.0142
	Bayesian	2.985	1.013	0.700	<u>0.0125</u>	0.0105	<u>0.0048</u>
	L-Moments	2.990	0.994	0.683	0.0126	<u>0.0082</u>	0.0084

หมายเหตุ ตัวเลขที่ขีดเส้นแสดงค่า MSE ที่ต่ำที่สุด

จากตารางที่ 4.3 พบว่า วิธี Bayesian และวิธี L-Moments โดยส่วนใหญ่จะทำให้ค่า MSE มีค่าต่ำกว่าวิธีอื่น ๆ ในแต่ละขนาดข้อมูลตัวอย่าง แต่สำหรับพารามิเตอร์บ่งขนาด มีค่า MSE ต่ำสุดเมื่อใช้วิธี Bayesian สำหรับทุกขนาดข้อมูลตัวอย่าง โดยค่าแนวโน้มของ MSE แสดงดังรูปที่ 4.3



รูปที่ 4.3 ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองของประมาณค่าพารามิเตอร์กรณี $\mu = 3, \sigma = 1$ และ $\xi = 0.7$

จากรูปที่ 4.3 พบว่าวิธี ML อาจมีความไม่เสถียรหรือประสิทธิภาพลดลงในบางขนาดตัวอย่าง โดยเฉพาะเมื่อ $n = 50$ ซึ่งเห็นได้จากค่า MSE ที่เพิ่มขึ้นเป็นจุด ๆ ในทางตรงกันข้าม วิธี GML Bayesian และ L-moments แสดงให้เห็นถึงความมีประสิทธิภาพมากกว่าวิธีอื่น นอกจากนี้วิธี L-moments ซึ่งให้ค่า MSE ต่ำที่สุดในทุกพารามิเตอร์โดยรวม แสดงให้เห็นว่าวิธี L-moments อาจเป็นวิธีที่มีประสิทธิภาพกับขนาดตัวอย่างที่แตกต่างกัน

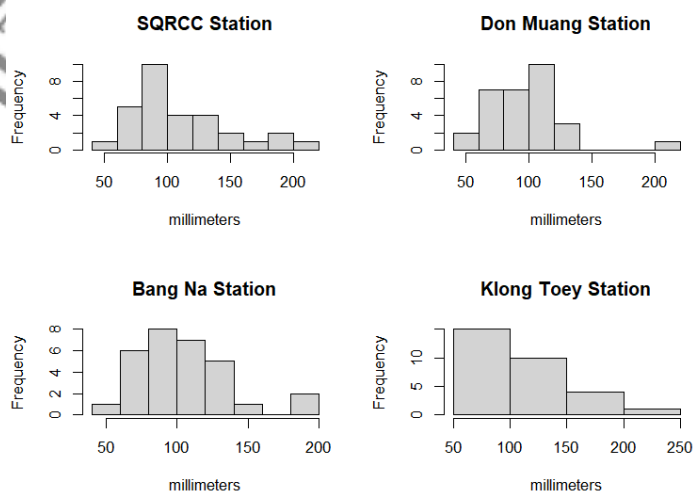
4.1.2 ค่าสถิติพื้นฐานสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายปี

สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายปีของสถานีตรวจวัดทั้ง 4 สถานีภายในกรุงเทพมหานคร รวบรวมจากกรมอุตุนิยมวิทยา ตั้งแต่ปี พ.ศ. 2537 ถึง พ.ศ. 2566 แสดงค่าสถิติพื้นฐาน ประกอบด้วย ค่าเฉลี่ย ส่วนเบี่ยงเบนมาตรฐาน สัมประสิทธิ์ความเบ้ สัมประสิทธิ์ความโด่ง ค่าต่ำสุด และค่าสูงสุด ดังตารางที่ 4.4

ตารางที่ 4.4 ค่าสถิติพื้นฐานสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายปีแต่ละสถานี ตั้งแต่ พ.ศ. 2537 - 2566

สถานี	ค่าต่ำสุด	ค่าสูงสุด	ค่าเฉลี่ย	ส่วนเบี่ยงเบนมาตรฐาน	ความเบ้	ความโด่ง
ศูนย์การประชุมแห่งชาติสิริกิติ์	54.4	216.8	110.5500	41.2436	0.9191	3.0681
ดอนเมือง	53.0	210.7	95.5300	29.2701	1.8840	9.0650
บางนา	57.7	185.9	105.4036	31.3575	0.9074	3.8152
คลองเตย	50.5	242.6	109.3033	41.0028	1.3578	5.1174

จากตารางที่ 4.4 พบว่า สถานีคลองเตยมีค่าปริมาณน้ำฝนสูงสุดรายปีซึ่งต่ำสุดเมื่อเทียบกับสถานีอื่นเท่ากับ 50.5 มิลลิเมตร ในขณะที่เดียวกัน สถานีคลองเตยมีค่าปริมาณน้ำฝนสูงสุดรายปีซึ่งสูงสุดเมื่อเทียบกับสถานีอื่นเท่ากับ 242.6 มิลลิเมตร เมื่อพิจารณาข้อมูลปริมาณน้ำฝนสูงสุดในภาพรวม พบว่า สถานีศูนย์การประชุมแห่งชาติสิริกิติ์มีปริมาณน้ำฝนสูงสุดรายปีเฉลี่ยสูงสุดเท่ากับ 110.55 มิลลิเมตร เช่นเดียวกับส่วนเบี่ยงเบนมาตรฐานที่สูงที่สุดเท่ากับ 41.2436 มิลลิเมตร หมายความว่า ปริมาณน้ำฝนสูงสุดของสถานีดอนเมืองในแต่ละปีมีการกระจายตัวสูง ในส่วนของค่าสัมประสิทธิ์ความเบ้สำหรับทุกสถานีมีค่ามากกว่าศูนย์ หมายความว่า ข้อมูลปริมาณน้ำฝนสูงสุดรายปีมีลักษณะการแจกแจงแบบเบ้ขวา และในส่วนของค่าสัมประสิทธิ์ความโด่งสำหรับทุกสถานีมากกว่าศูนย์ หมายความว่า ลักษณะความโด่งของข้อมูลปริมาณน้ำฝนสูงสุดรายปีมากกว่าความโด่งของการแจกแจงปกติ โดยแสดงลักษณะข้อมูลแบบฮิสโตแกรม ดังรูปที่ 4.4



รูปที่ 4.4 ฮิสโตแกรมข้อมูลปริมาณน้ำฝนสูงสุดรายปีสำหรับแต่ละสถานีระหว่าง พ.ศ. 2537 - 2566

จากรูปที่ 4.4 พบว่า ข้อมูลปริมาณน้ำฝนสูงสุดรายปีแต่ละสถานีนีมีลักษณะของการแจกแจงแบบเบ้ขวา โดยสถานีศูนย์การประชุมแห่งชาติสิริกิติ์และสถานีดอนเมืองพบความถี่ในการเกิดปริมาณน้ำฝนสูงสุดที่ชัดเจนเมื่อเทียบกับ 2 สถานีที่เหลือ ซึ่งสอดคล้องกับค่าสถิติพื้นฐานจากตารางที่ 4.4

4.1.3 การประมาณค่าพารามิเตอร์สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายปี

ทำการประมาณค่าพารามิเตอร์ของปริมาณน้ำฝนสูงสุดรายปีของการแจกแจงค่าสุดขีดน้อยทั่วไป ซึ่งประกอบด้วยวิธีภาวะน่าจะเป็นสูงสุด วิธีภาวะน่าจะเป็นสูงสุดทั่วไป วิธีของเบส์ และวิธีโมเมนต์เชิงเส้น จำแนกตามสถานีตรวจวัดระดับน้ำ แสดงดังตารางที่ 4.5 - 4.8

ตารางที่ 4.5 ค่าประมาณพารามิเตอร์สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายปีของสถานีศูนย์การประชุมแห่งชาติสิริกิติ์

วิธีการประมาณค่า	ค่าประมาณพารามิเตอร์		
พารามิเตอร์	Location (μ)	Scale (σ)	Shape (ξ)
ML	90.3604	22.0961	0.2727
GML	94.6272	26.9863	-0.0454
Bayesian	88.8477	25.4840	0.3437
L-Moments	89.9188	22.4688	0.2506

ตารางที่ 4.5 แสดงค่าประมาณพารามิเตอร์ของการแจกแจง GEV สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายปีของสถานีศูนย์การประชุมแห่งชาติสิริกิติ์ โดยพบว่าวิธี GML ให้ค่าประมาณของพารามิเตอร์บ่งตำแหน่งสูงสุดที่ 94.6272 ขณะที่วิธี Bayesian ให้ค่าต่ำสุดที่ 88.8477 สำหรับพารามิเตอร์บ่งขนาด วิธี GML มีค่าประมาณสูงสุดที่ 26.9863 ขณะที่ ML และ L-Moments ให้ค่าประมาณที่ใกล้เคียงกัน ส่วนพารามิเตอร์บ่งรูปร่างพบว่าวิธี ML, Bayesian และ L-Moments ให้ค่าประมาณมากกว่าศูนย์ แสดงว่าเป็นรูปแบบการแจกแจงพีรีเซท

ตารางที่ 4.6 ค่าประมาณพารามิเตอร์สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายปีของสถานีดอนเมือง

วิธีการประมาณค่า พารามิเตอร์	ค่าประมาณพารามิเตอร์		
	Location (μ)	Scale (σ)	Shape (ξ)
ML	90.2813	21.7657	0.0230
GML	91.4632	22.7662	-0.0617
Bayesian	86.7677	26.8321	0.1458
L-Moments	90.1907	21.2259	0.0316

ตารางที่ 4.6 แสดงค่าประมาณพารามิเตอร์ของการแจกแจง GEV สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายปีของสถานีดอนเมือง โดยพบว่าพารามิเตอร์บ่งตำแหน่ง วิธี GML ให้ค่าประมาณสูงสุดที่ 91.4632 ในขณะที่วิธี Bayesian ให้ค่าประมาณต่ำสุดที่ 86.7677 สำหรับพารามิเตอร์บ่งขนาด วิธี Bayesian ให้ค่าประมาณสูงสุดที่ 26.8321 ในขณะที่วิธี ML และ L-Moments ให้ค่าประมาณที่ใกล้เคียงกัน สำหรับพารามิเตอร์บ่งรูปร่าง วิธี ML, Bayesian และ L-Moments ให้ค่าประมาณของมากกว่าศูนย์ แสดงว่าเป็นรูปแบบการแจกแจงฟรีเซท

ตารางที่ 4.7 ค่าประมาณพารามิเตอร์สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายปีของสถานีบางนา

วิธีการประมาณค่า พารามิเตอร์	ค่าประมาณพารามิเตอร์		
	Location (μ)	Scale (σ)	Shape (ξ)
ML	88.2921	23.0326	0.1977
GML	92.1787	27.0925	-0.0777
Bayesian	91.6145	29.9122	0.2511
L-Moments	88.7612	25.7723	0.0986

ตารางที่ 4.7 แสดงค่าประมาณพารามิเตอร์ของการแจกแจง GEV สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายปีของสถานีบางนา โดยพบว่าพารามิเตอร์บ่งตำแหน่ง วิธี GML ให้ค่าประมาณสูงสุดที่ 92.1787 ในขณะที่วิธี ML และ L-Moments ให้ค่าประมาณที่ใกล้เคียงกัน สำหรับพารามิเตอร์บ่งขนาด วิธี Bayesian ให้ค่าประมาณสูงสุดที่ 29.9122 ในขณะที่วิธี ML ให้ค่าประมาณต่ำสุดที่ 23.0326 สำหรับพารามิเตอร์บ่งรูปร่าง วิธี ML, Bayesian และ L-Moments ให้ค่าประมาณของมากกว่าศูนย์ แสดงว่าเป็นรูปแบบการแจกแจงฟรีเซท

ตารางที่ 4.8 ค่าประมาณพารามิเตอร์สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายปีของสถานีคลองเตย

วิธีการประมาณค่า พารามิเตอร์	ค่าประมาณพารามิเตอร์		
	Location (μ)	Scale (σ)	Shape (ξ)
ML	88.8156	20.5542	0.1794
GML	90.7105	22.1556	0.0063
Bayesian	84.4663	24.9360	0.2383
L-Moments	86.8072	17.2841	0.3410

ตารางที่ 4.8 แสดงค่าประมาณพารามิเตอร์ของการแจกแจง GEV สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายปีของสถานีคลองเตย โดยพบว่าพารามิเตอร์บ่งตำแหน่ง วิธี GML ให้ค่าประมาณสูงสุดที่ 90.7105 ในขณะที่วิธี Bayesian ให้ค่าประมาณต่ำสุดที่ 84.4663 สำหรับพารามิเตอร์บ่งขนาด วิธี Bayesian ให้ค่าประมาณสูงสุดที่ 24.9360 ในขณะที่วิธี L-Moments ให้ค่าประมาณต่ำสุดที่ 17.2841 สำหรับพารามิเตอร์บ่งรูปร่างทุกวิธี ให้ค่าประมาณของมากกว่าศูนย์ แสดงว่าเป็นรูปแบบการแจกแจงฟรีเซท

4.1.4 ระดับการเกิดซ้ำสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายปี

สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายปีแต่ละสถานีตรวจวัดระดับน้ำ ทำการหาระดับการเกิดซ้ำคาบเวลาการเกิดซ้ำ 2, 3, ..., 10 ปี ด้วยการแจกแจงค่าสุดขีดน้อยทั่วไปจากสมการที่ (2.40) แสดงดังตารางที่ 4.9 - 4.12

ตารางที่ 4.9 ระดับการเกิดซ้ำสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายปีแต่ละวิธีการของสถานีศูนย์การ
ประชุมแห่งชาติสิริกิติ์

คาบเวลาการ เกิดซ้ำ	ปริมาณ น้ำฝนสูงสุด รายปี	ML	GML	Bayesian	L-Moments
2	174.3	98.8774	104.4361	98.8118	98.5439
3	141.5	112.9769	118.4955	115.1125	112.6790
4	188.3	123.1451	127.3156	127.1739	122.7747
5	74.3	131.3094	133.7568	137.0296	130.8277
6	54.4	138.2189	138.8267	145.4830	137.6086
7	118.0	144.2554	143.0032	152.9492	143.5086
8	81.7	149.6437	146.5511	159.6752	148.7570
9	132.5	154.5288	149.6329	165.8214	153.5010
10	87.2	159.0099	152.3553	171.4988	157.8412
MAPE	-	59.2475%	56.9069%	65.9066%	58.6913%

หมายเหตุ ตัวเลขที่ขีดเส้นแสดงค่า MAPE ที่ต่ำที่สุด

จากตารางที่ 4.9 พบว่า เมื่อพิจารณาค่าความคลาดเคลื่อนเฉลี่ยแบบเปอร์เซ็นต์ (MAPE) พบว่าวิธี GML ให้ค่า MAPE ต่ำที่สุดที่ 56.9069% แสดงถึงความแม่นยำที่สูงกว่าวิธีอื่น รองลงมาคือ ML และ L-Moments ขณะที่ Bayesian มีค่า MAPE สูงสุดที่ 65.9066% สรุปได้ว่าวิธี GML อาจเป็นทางเลือกที่ดีที่สุดในการประมาณค่าปริมาณน้ำฝนสูงสุดรายปีสำหรับสถานีศูนย์การประชุมแห่งชาติสิริกิติ์

ตารางที่ 4.10 ระดับการเกิดซ้ำสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายปีแต่ละวิธีการของสถานี
ดอนเมือง

ระดับการ เกิดซ้ำ	ปริมาณ น้ำฝนสูงสุด รายปี	ML	GML	Bayesian	L-Moments
2	107.7	98.2925	99.7136	96.9031	98.0155
3	108.9	110.1354	111.4527	112.1256	109.6273
4	83.9	117.7921	118.7645	122.5487	117.1628
5	93.2	123.4992	124.0783	130.6269	122.7938
6	65.0	128.0620	128.2454	137.2811	127.3046
7	78.6	131.8686	131.6677	142.9684	131.0737
8	62.2	135.1370	134.5677	147.9520	134.3142
9	74.9	138.0022	137.0811	152.3985	137.1583
10	53.0	140.5540	139.2971	156.4204	139.6937
MAPE	-	68.2525%	67.9392%	80.9747%	67.3674%

หมายเหตุ ตัวเลขที่ขีดเส้นแสดงค่า MAPE ที่ต่ำที่สุด

จากตารางที่ 4.10 พบว่า เมื่อพิจารณาค่า MAPE สำหรับวิธี L-Moments ให้ค่าต่ำที่สุดที่ 67.3674% แสดงถึงความแม่นยำที่สูงกว่าวิธีอื่น รองลงมาคือ GML และ ML ขณะที่ Bayesian มีค่า MAPE สูงสุดที่ 80.9747% สรุปได้ว่าวิธี L-Moments อาจเป็นทางเลือกที่ดีที่สุดในการประมาณค่า ปริมาณน้ำฝนสูงสุดรายปีสำหรับสถานีดอนเมือง

ตารางที่ 4.11 ระดับการเกิดซ้ำสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายปีแต่ละวิธีการของสถานีบางนา

ระดับการเกิดซ้ำ	ปริมาณน้ำฝนสูงสุดรายปี	ML	GML	Bayesian	L-Moments
2	91.6	97.0471	101.9684	101.6917	98.3799
3	92.9	111.0545	115.7981	120.1495	113.0933
4	119.0	120.8307	124.3518	133.6623	122.9267
5	110.9	128.5070	130.5385	144.6240	130.4234
6	57.7	134.8933	135.3725	153.9738	136.5211
7	88.0	140.3959	139.3310	162.1946	141.6798
8	120.9	145.2507	142.6768	169.5722	146.1615
9	126.0	149.6078	145.5705	176.2918	150.1306
10	129.8	153.5693	148.1170	182.4809	153.6971
MAPE		32.6020%	33.1971%	50.5559%	34.0115%

หมายเหตุ ตัวเลขที่ขีดเส้นแสดงค่า MAPE ที่ต่ำที่สุด

จากตารางที่ 4.11 พบว่า เมื่อพิจารณาค่า MAPE สำหรับวิธี ML ให้ค่าต่ำที่สุดที่ 32.6020% แสดงถึงความแม่นยำที่สูงกว่าวิธีอื่น รองลงมาคือ GML และ L-Moments ขณะที่ Bayesian มีค่า MAPE สูงสุดที่ 50.5559% สรุปได้ว่าวิธี ML อาจเป็นทางเลือกที่ดีที่สุดในการประมาณค่าปริมาณน้ำฝนสูงสุดรายปีสำหรับสถานีบางนา

ตารางที่ 4.12 ระดับการเกิดซ้ำสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายปีแต่ละวิธีการของสถานี

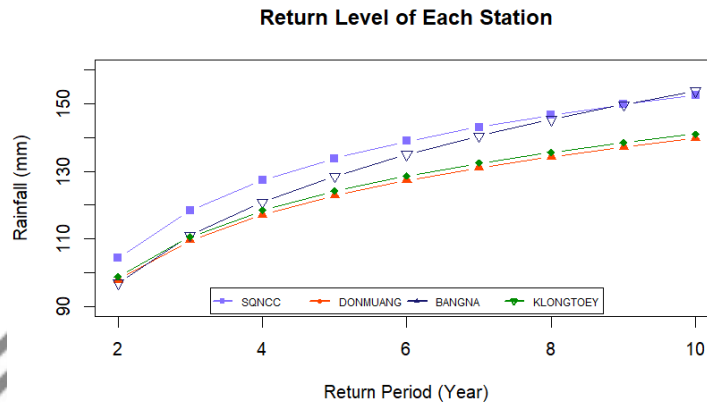
คลองเตย

ระดับการเกิดซ้ำ	ปริมาณน้ำฝนสูงสุดรายปี	ML	GML	Bayesian	L-Moments
2	165.5	96.6021	98.8402	93.9914	93.5549
3	132.0	108.9572	110.7675	108.6917	105.0780
4	190.3	117.5117	118.4222	119.1572	113.6389
5	152.5	124.1923	124.0992	127.4867	120.6536
6	62.2	129.7272	128.6208	134.4886	126.6831
7	103.4	134.4801	132.3812	140.5725	132.0176
8	108.4	138.6616	135.6016	145.9783	136.8302
9	130.3	142.4053	138.4184	150.8596	141.2334
10	74.8	145.8016	140.9219	155.3216	145.3053
MAPE	-	42.9611%	40.8104%	47.2129%	42.8064%

หมายเหตุ ตัวเลขที่ขีดเส้นแสดงค่า MAPE ที่ต่ำที่สุด


จากตารางที่ 4.12 พบว่า เมื่อพิจารณาค่า MAPE สำหรับวิธี GML ให้ค่าต่ำที่สุดที่ 40.8104% แสดงถึงความแม่นยำที่สูงกว่าวิธีอื่น รองลงมาคือ ML และ L-Moments ขณะที่ Bayesian มีค่า MAPE สูงสุดที่ 47.2129% สรุปได้ว่าวิธี GML อาจเป็นทางเลือกที่ดีที่สุดในการประมาณค่าปริมาณน้ำฝนสูงสุดรายปีสำหรับสถานีคลองเตย

เมื่อพิจารณา ในภาพรวม สรุปได้ว่า วิธี ML มีประสิทธิภาพดีกว่าวิธีการอื่นสำหรับสถานีบางนาเนื่องจากค่า MAPE ต่ำที่สุด สำหรับวิธี GML จะมีประสิทธิภาพดีกว่าวิธีการอื่นสำหรับสถานีศูนย์การประชุมแห่งชาติสิริกิติ์และสถานีคลองเตยเนื่องจากค่า MAPE ต่ำที่สุด และสำหรับวิธี L-Moments จะมีประสิทธิภาพดีกว่าวิธีการอื่นสำหรับสถานีดอนเมืองเนื่องจากค่า MAPE ต่ำที่สุด และค่าระดับการเกิดซ้ำของแต่ละสถานีตรวจวัดระดับน้ำ ที่ให้ค่า MAPE ต่ำสุดแสดงดังรูปที่ 4.5



รูปที่ 4.5 กราฟระดับการเกิดซ้ำของปริมาณน้ำฝนสูงสุดรายปี ตามรอบปีการเกิด จำแนกรายสถานี ตรวจวัดระดับน้ำ


จากรูปที่ 4.5 พบว่าระดับการเกิดซ้ำมีแนวโน้มเพิ่มขึ้นตามคาบเวลาการเกิดซ้ำที่เพิ่มขึ้นสำหรับทุกสถานี เมื่อคัดเลือกตัวแบบและวิธีการที่เหมาะสมกับข้อมูลปริมาณน้ำฝนสูงสุดแต่ละสถานี จึงพิจารณาความเหมาะสมจากแผนภาพความน่าจะเป็นต่อความน่าจะเป็น (Probability-Probability Plot: PP Plot) แผนภาพควอไทล์ต่อควอไทล์ (Quantile-Quantile Plot: QQ Plot) และแผนภาพความหนาแน่นของความน่าจะเป็น (Probability Density Plot) ดังรูปที่ 4.6 – 4.9



รูปที่ 4.6 แผนภาพ Diagnostic Plot ของข้อมูลปริมาณน้ำฝนสูงสุดรายปี สถานีศูนย์การประชุมแห่งชาติสิริกิติ์

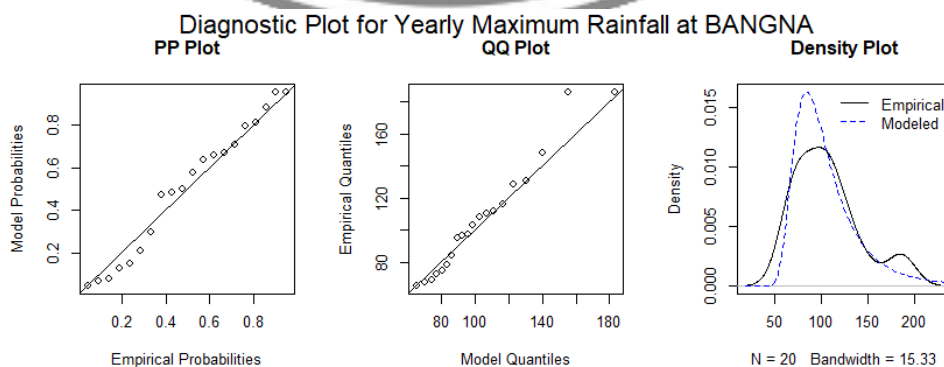
จากรูปที่ 4.6 พบว่า กราฟการวินิจฉัยสำหรับปริมาณน้ำฝนสูงสุดรายปีที่สถานีศูนย์การประชุมแห่งชาติสิริกิติ์แสดงการเปรียบเทียบระหว่างค่าจากแบบจำลองกับข้อมูลจริงผ่าน PP Plot, QQ Plot, และ Density Plot โดย PP Plot แสดงว่าค่าความน่าจะเป็นของแบบจำลองสอดคล้องกับค่าจากข้อมูลจริงค่อนข้างดี เนื่องจากจุดกระจายอยู่ใกล้เส้นทแยงมุม QQ Plot แสดงให้เห็นว่าค่าควอ

ไทล์ของแบบจำลองและข้อมูลจริงมีแนวโน้มไปในทิศทางเดียวกัน แม้จะมีความแตกต่างเล็กน้อยที่ปลายค่ามากที่สุด ขณะที่ Density Plot แสดงการแจกแจงของข้อมูลจริง (เส้นดำ) เทียบกับแบบจำลอง (เส้นประสีน้ำเงิน) พบว่าแบบจำลองสามารถสะท้อนแนวโน้มของข้อมูลจริงได้ดี แม้ว่าจะมีความแตกต่างเล็กน้อยในช่วงความหนาแน่นสูงสุด สรุปได้ว่าแบบจำลองที่ใช้สามารถอธิบายการกระจายของปริมาณน้ำฝนสูงสุดรายปีได้ดี แต่ยังคงมีความคลาดเคลื่อนในบางช่วงของข้อมูล




รูปที่ 4.7 แผนภาพ Diagnostic Plot ของข้อมูลปริมาณน้ำฝนสูงสุดรายปี สถานีดอนเมือง

จากรูปที่ 4.7 พบว่า กราฟการวินิจฉัยสำหรับปริมาณน้ำฝนสูงสุดรายปีที่สถานีดอนเมือง แสดงการเปรียบเทียบระหว่างค่าจากแบบจำลองกับข้อมูลจริงผ่าน PP Plot, QQ Plot, และ Density Plot โดย PP Plot แสดงว่าค่าความน่าจะเป็นของแบบจำลองสอดคล้องกับค่าจากข้อมูลจริงค่อนข้างดี เนื่องจากจุดกระจายอยู่ใกล้เส้นทแยงมุม QQ Plot แสดงให้เห็นว่าค่าควไทล์ของแบบจำลองและข้อมูลจริงมีแนวโน้มไปในทิศทางเดียวกัน แม้จะมีความแตกต่างเล็กน้อยที่ปลายค่ามากที่สุด ขณะที่ Density Plot แสดงการแจกแจงของข้อมูลจริง (เส้นดำ) เทียบกับแบบจำลอง (เส้นประสีน้ำเงิน) พบว่าแบบจำลองสามารถสะท้อนแนวโน้มของข้อมูลจริงได้ดี แม้ว่าจะมีความแตกต่างเล็กน้อยในช่วงความหนาแน่นสูงสุด สรุปได้ว่าแบบจำลองที่ใช้สามารถอธิบายการกระจายของปริมาณน้ำฝนสูงสุดรายปีได้ดี แต่ยังคงมีความคลาดเคลื่อนในบางช่วงของข้อมูล



รูปที่ 4.8 แผนภาพ Diagnostic Plot ของข้อมูลปริมาณน้ำฝนสูงสุดรายปี สถานีบางนา

จากรูปที่ 4.8 พบว่า กราฟการวินิจฉัยสำหรับปริมาณน้ำฝนสูงสุดรายปีที่สถานีบางนาแสดง การเปรียบเทียบระหว่างค่าจากแบบจำลองกับข้อมูลจริงผ่าน PP Plot, QQ Plot, และ Density Plot โดย PP Plot แสดงว่าค่าความน่าจะเป็นของแบบจำลองสอดคล้องกับค่าจากข้อมูลจริงค่อนข้างดี เนื่องจากจุดกระจายอยู่ใกล้เส้นทแยงมุม QQ Plot แสดงให้เห็นว่าค่าควอไทล์ของแบบจำลองและ ข้อมูลจริงมีแนวโน้มไปในทิศทางเดียวกัน แม้จะมีความแตกต่างเล็กน้อยที่ปลายค่ามากที่สุด ขณะที่ Density Plot แสดงการแจกแจงของข้อมูลจริง (เส้นดำ) เทียบกับแบบจำลอง (เส้นประสีน้ำเงิน) พบว่าแบบจำลองสามารถสะท้อนแนวโน้มของข้อมูลจริงได้ดี แม้จะมีความแตกต่างเล็กน้อยในช่วง ความหนาแน่นสูงสุด สรุปได้ว่าแบบจำลองที่ใช้สามารถอธิบายการกระจายของปริมาณน้ำฝนสูงสุด รายปีได้ดี แต่ยังคงมีความคลาดเคลื่อนในบางช่วงของข้อมูล



รูปที่ 4.9 แผนภาพ Diagnostic Plot ของข้อมูลปริมาณน้ำฝนสูงสุดรายปี สถานีคลองเตย

จากรูปที่ 4.9 พบว่า กราฟการวินิจฉัยสำหรับปริมาณน้ำฝนสูงสุดรายปีที่สถานีคลองเตย แสดงการเปรียบเทียบระหว่างค่าจากแบบจำลองกับข้อมูลจริงผ่าน PP Plot, QQ Plot, และ Density Plot โดย PP Plot แสดงว่าค่าความน่าจะเป็นของแบบจำลองสอดคล้องกับค่าจากข้อมูลจริงค่อนข้าง ดี เนื่องจากจุดกระจายอยู่ใกล้เส้นทแยงมุม QQ Plot แสดงให้เห็นว่าค่าควอไทล์ของแบบจำลองและ ข้อมูลจริงมีแนวโน้มไปในทิศทางเดียวกัน แม้จะมีความแตกต่างเล็กน้อยที่ปลายค่ามากที่สุด ขณะที่ Density Plot แสดงการแจกแจงของข้อมูลจริง (เส้นดำ) เทียบกับแบบจำลอง (เส้นประสีน้ำเงิน) พบว่าแบบจำลองสามารถสะท้อนแนวโน้มของข้อมูลจริงได้ดี แม้จะมีความแตกต่างเล็กน้อยในช่วง ความหนาแน่นสูงสุด สรุปได้ว่าแบบจำลองที่ใช้สามารถอธิบายการกระจายของปริมาณน้ำฝนสูงสุด รายปีได้ดี แต่ยังคงมีความคลาดเคลื่อนในบางช่วงของข้อมูล

เมื่อพิจารณาแผนภาพจากรูปที่ 4.6-4.9 ในภาพรวม PP Plot, QQ Plot และ Density Plot จะเห็นว่า ข้อมูลที่นำมาวิเคราะห์การแจกแจงมีลักษณะการกระจายใกล้เคียงกับการแจกแจงที่ทำการ ทดสอบ โดยที่ข้อมูลสถานีบางนาซึ่งมีค่า MAPE ที่ต่ำกว่าสถานีอื่น ๆ ลักษณะแผนภาพ PP Plot ของ

ข้อมูลเป็นไปตามเส้นทแยงมุม เช่นเดียวกับกับแผนภาพ QQ Plot ส่วนแผนภาพ Density Plot ก็จะทำให้เห็นว่า ลักษณะการกระจายของข้อมูลจริงเป็นไปตามลักษณะการกระจายของเส้นโค้งของการแจกแจงที่ทดสอบ ในขณะที่ข้อมูลสถานีดอนเมืองซึ่งมีค่า MAPE มากกว่าสถานีอื่น ๆ มีลักษณะแผนภาพ PP Plot ของข้อมูลเป็นไปตามเส้นทแยงมุม แต่ในขณะที่ QQ Plot มีบางจุดที่ไม่เป็นไปตามเส้นทแยงมุม ในขณะที่ Density Plot มีลักษณะการกระจายของข้อมูลจริงที่ไม่เป็นไปตามลักษณะของการกระจายของเส้นโค้งเท่าที่ควรเมื่อเปรียบเทียบกับสถานีอื่น ๆ

4.2 การแจกแจงพารามิเตอร์ทั่วไป

เป็นการจำลองข้อมูลจากการแจกแจงพารามิเตอร์ทั่วไป ซึ่งประกอบไปด้วยพารามิเตอร์บ่งตำแหน่ง (Location Parameter: μ) พารามิเตอร์บ่งขนาด (Scale Parameter: σ) และพารามิเตอร์บ่งรูปร่าง (Shape Parameter) โดยมีการปรับพารามิเตอร์บ่งรูปร่างให้อยู่ในรูปแบบหางกลาง (Medium-tail) แบบเลขชี้กำลัง (Exponential Distribution) แบบหางหนา (Heavy-tail) และแบบหางสั้น (Short-tail) และทำการประมาณค่าพารามิเตอร์ด้วยวิธีการน่าจะเป็นสูงสุด (ML) วิธีการน่าจะเป็นสูงสุดทั่วไป (GML) วิธีของเบย์ส์ (Bayesian) และวิธีโมเมนต์เชิงเส้น (L-moment) โดยนำวิธีดังกล่าวมาประยุกต์กับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือน ตั้งแต่ พ.ศ. 2537–2566 จำนวน 30 ปี หรือ 360 เดือน ของกรุงเทพมหานครทั้ง 4 สถานี ประกอบด้วย ศูนย์การประชุมแห่งชาติสิริกิติ์ ดอนเมือง บางนา และคลองเตย เพื่อวิเคราะห์ตัวแบบสำหรับการแจกแจงค่าสุดขีดนี้ทั่วไป ทั่วไป โดยวิธีค่าสูงสุดที่มีค่าเกินเกณฑ์ที่กำหนด (Peak over threshold model) ประกอบด้วยค่าสถิติเบื้องต้น การประมาณค่าพารามิเตอร์ หาวิธีการประมาณค่าพารามิเตอร์ที่เหมาะสมและคำนวณระดับการเกิดซ้ำสำหรับข้อมูลปริมาณน้ำฝนสูงสุดแต่ละสถานี

4.2.1 การประมาณค่าพารามิเตอร์สำหรับข้อมูลจำลอง

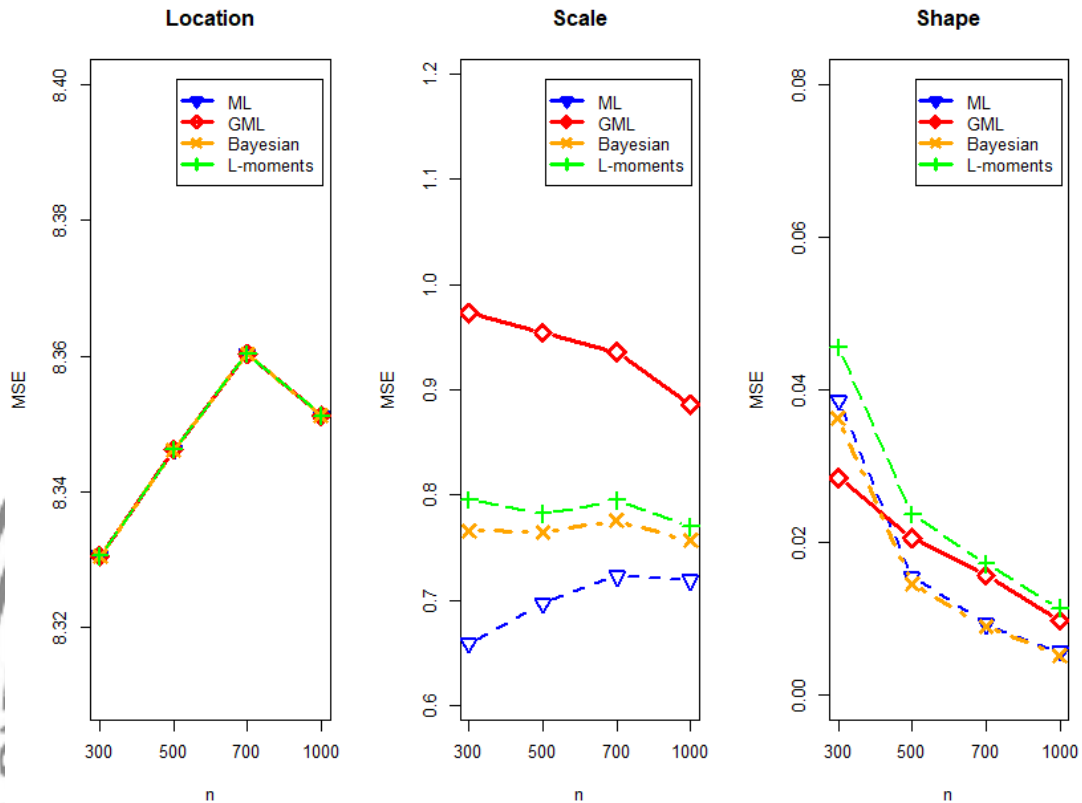
ในส่วนของการจำลอง การประมาณค่าพารามิเตอร์สำหรับการแจกแจงพารามิเตอร์ทั่วไปซึ่งประกอบด้วยวิธีการน่าจะเป็นสูงสุด วิธีการน่าจะเป็นสูงสุดทั่วไป วิธีของเบย์ส์ และวิธีโมเมนต์เชิงเส้น โดยกำหนดพารามิเตอร์บ่งตำแหน่งเท่ากับ 2 พารามิเตอร์บ่งขนาดเท่ากับ 2 และพารามิเตอร์บ่งรูปร่างเท่ากับ -0.3 สำหรับรูปแบบหางสั้น, 0 สำหรับรูปแบบหางกลางแบบเลขชี้กำลัง และ 0.3 สำหรับรูปแบบหางหนา ตามลำดับ กำหนดค่าเกณฑ์โดยพิจารณาจากข้อมูลที่เกินจากเปอร์เซ็นต์ไทล์ที่ 85, 90 และ 95 ตามลำดับ ขนาดตัวอย่างที่ศึกษาเท่ากับ 300, 500, 700 และ 1,000 กำหนดจำนวนรอบในการทำซ้ำเท่ากับ 1,000 ครั้ง โดยผลลัพธ์แสดงดังตารางที่ 4.13 – 4.21

ตารางที่ 4.13 ผลการจำลองข้อมูลการประมาณค่าพารามิเตอร์กรณี $\mu = 2, \sigma = 2, \xi = -0.3$ และ กำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 85

ขนาดตัวอย่าง	วิธีการประมาณค่าพารามิเตอร์	ค่าประมาณพารามิเตอร์			ค่าเฉลี่ยความคลาดเคลื่อนกำลังสอง (MSE)		
		Location (μ)	Scale (σ)	Shape (ξ)	Location (μ)	Scale (σ)	Shape (ξ)
300	ML	4.8823	1.2351	-0.3872	8.3305	<u>0.6591</u>	0.0386
	GML	4.8823	1.0371	-0.2155	8.3305	0.9728	<u>0.0285</u>
	Bayesian	4.8823	1.1614	-0.2581	8.3305	0.7663	0.0362
	L-Moments	4.8823	1.1511	-0.3085	8.3305	0.7956	0.0456
500	ML	4.8864	1.1874	-0.3464	8.3462	<u>0.6970</u>	0.0155
	GML	4.8864	1.0389	-0.2188	8.3462	0.9544	0.0206
	Bayesian	4.8864	1.1446	-0.2735	8.3462	0.7648	<u>0.0146</u>
	L-Moments	4.8864	1.1398	-0.2994	8.3462	0.7825	0.0237
700	ML	4.8898	1.1634	-0.3307	8.3603	<u>0.7230</u>	0.0093
	GML	4.8898	1.0452	-0.2297	8.3603	0.9359	0.0157
	Bayesian	4.8898	1.1313	-0.2785	8.3603	0.7761	<u>0.0090</u>
	L-Moments	4.8898	1.1252	-0.2921	8.3603	0.7952	0.0172
1,000	ML	4.8885	1.1608	-0.3270	8.3512	<u>0.7190</u>	0.0057
	GML	4.8885	1.0680	-0.2518	8.3512	0.8858	0.0098
	Bayesian	4.8885	1.1383	-0.2914	8.3512	0.7568	<u>0.0052</u>
	L-Moments	4.8885	1.1339	-0.3001	8.3512	0.7698	0.0114

หมายเหตุ ตัวเลขที่ขีดเส้นแสดงค่า MSE ที่ต่ำที่สุด

จากตารางที่ 4.13 เมื่อกำหนดให้ค่าพารามิเตอร์บ่งตำแหน่งถูกประมาณด้วยค่าเกณฑ์ในตำแหน่งเปอร์เซ็นต์ไทล์ที่ 85 พิจารณาว่าค่าประมาณพารามิเตอร์บ่งขนาด พบว่า เมื่อใช้วิธี ML ให้ค่า MSE ต่ำสุดสำหรับทุกขนาดตัวอย่าง และเมื่อพิจารณาค่าประมาณพารามิเตอร์บ่งรูปร่าง พบว่า วิธี Bayesian ให้ประสิทธิภาพที่ดีกว่าวิธีการอื่น ๆ และค่า MSE มีแนวโน้มลดลงเมื่อขนาดตัวอย่างเพิ่มขึ้น โดยค่าแนวโน้มของ MSE แสดงดังรูปที่ 4.10



รูปที่ 4.10 ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองของประมาณค่าพารามิเตอร์กรณี $\mu=2$, $\sigma=2$, $\xi=-0.3$ และกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 85

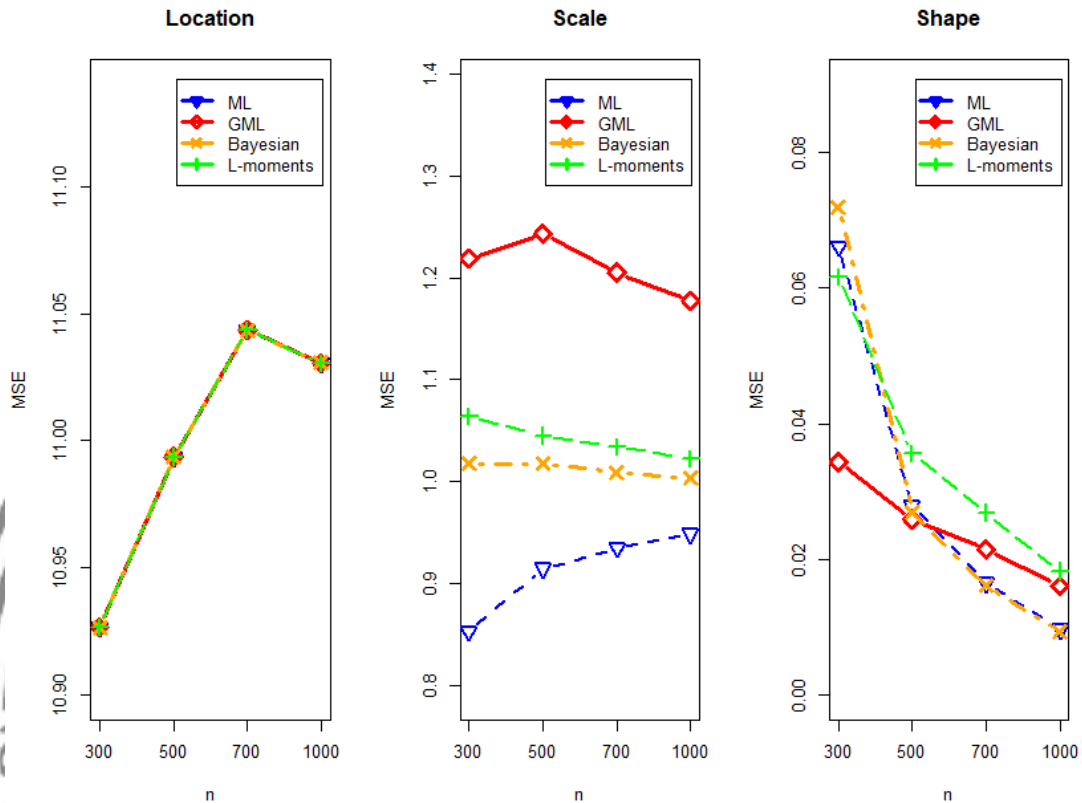
จากรูปที่ 4.10 พบว่า ค่าประมาณพารามิเตอร์ทั้งตำแหน่งทั้ง 4 วิธีเป็นเส้นเดียวกัน เนื่องจากค่าดังกล่าวถูกกำหนดด้วยค่าเกณฑ์ในตำแหน่งเปอร์เซ็นต์ไทล์ที่ 85 สำหรับค่าประมาณพารามิเตอร์ทั้งขนาดพบว่าวิธี Bayesian และ L-Moments มีแนวโน้มของค่า MSE ที่ลดลงเมื่อขนาดตัวอย่างเพิ่มขึ้น สำหรับวิธี ML ให้ค่า MSE ต่ำสุดสำหรับทุกขนาดตัวอย่าง ถึงแม้ว่าค่า MSE จะมีแนวโน้มเพิ่มขึ้นอย่างต่อเนื่องเมื่อขนาดตัวอย่างเพิ่มขึ้นก็ตาม และค่าประมาณพารามิเตอร์รูปร่างพบว่าสำหรับทุกวิธีมีแนวโน้มของค่า MSE ที่ลดลงอย่างต่อเนื่องเมื่อขนาดตัวอย่างเพิ่มขึ้น แต่วิธี ML และ Bayesian ให้ค่า MSE ที่ต่ำกว่าและใกล้เคียงกันทุกขนาดตัวอย่าง

ตารางที่ 4.14 ผลการจำลองข้อมูลการประมาณค่าพารามิเตอร์กรณี $\mu = 2, \sigma = 2, \xi = -0.3$ และกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 90

ขนาดตัวอย่าง	วิธีการประมาณค่าพารามิเตอร์	ค่าประมาณพารามิเตอร์			ค่าความคลาดเคลื่อนกำลังสอง (MSE)		
		Location (μ)	Scale (σ)	Shape (ξ)	Location (μ)	Scale (σ)	Shape (ξ)
300	ML	5.3008	1.1315	-0.4244	10.9267	<u>0.8524</u>	0.0661
	GML	5.3008	0.9207	-0.2153	10.9267	1.2189	<u>0.0344</u>
	Bayesian	5.3008	1.0303	-0.2120	10.9267	1.0173	0.0719
	L-Moments	5.3008	1.0094	-0.2980	10.9267	1.0638	0.0616
500	ML	5.3130	1.0687	-0.3713	10.9936	<u>0.9145</u>	0.0279
	GML	5.3130	0.8975	-0.2021	10.9936	1.2433	<u>0.0259</u>
	Bayesian	5.3130	1.0117	-0.2569	10.9936	1.0174	0.0269
	L-Moments	5.3130	1.0007	-0.2977	10.9936	1.0451	0.0356
700	ML	5.3211	1.0499	-0.3464	11.0434	<u>0.9344</u>	0.0165
	GML	5.3211	0.9141	-0.2133	11.0434	1.2051	0.0215
	Bayesian	5.3211	1.0099	-0.2680	11.0434	1.0092	<u>0.0162</u>
	L-Moments	5.3211	1.0017	-0.2922	11.0434	1.0342	0.0269
1,000	ML	5.3198	1.0362	-0.3326	11.0305	<u>0.9482</u>	0.0097
	GML	5.3198	0.9235	-0.2247	11.0305	1.1772	0.0161
	Bayesian	5.3198	1.0073	-0.2786	11.0305	1.0033	<u>0.0093</u>
	L-Moments	5.3198	1.0010	-0.2930	11.0305	1.0224	0.0183

หมายเหตุ ตัวเลขที่ขีดเส้นแสดงค่า MSE ที่ต่ำที่สุด

จากตารางที่ 4.14 เมื่อกำหนดให้ค่าพารามิเตอร์บ่งตำแหน่งถูกประมาณด้วยค่าเกณฑ์ในตำแหน่งเปอร์เซ็นต์ไทล์ที่ 90 พิจารณาค่าประมาณพารามิเตอร์บ่งขนาด พบว่า เมื่อใช้วิธี ML ให้ค่า MSE ต่ำสุดสำหรับทุกขนาดตัวอย่าง โดยขนาดตัวอย่างเพิ่มขึ้น จะทำให้ MSE มีค่าเพิ่มขึ้น และเมื่อพิจารณาค่าประมาณพารามิเตอร์บ่งรูปร่าง พบว่า วิธี GML และวิธี Bayesian ให้ประสิทธิภาพไม่ต่างกัน โดยค่าแนวโน้มของ MSE แสดงดังรูปที่ 4.11



รูปที่ 4.11 ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองของประมาณค่าพารามิเตอร์กรณี $\mu = 2$, $\sigma = 2$, $\xi = -0.3$ และกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 90

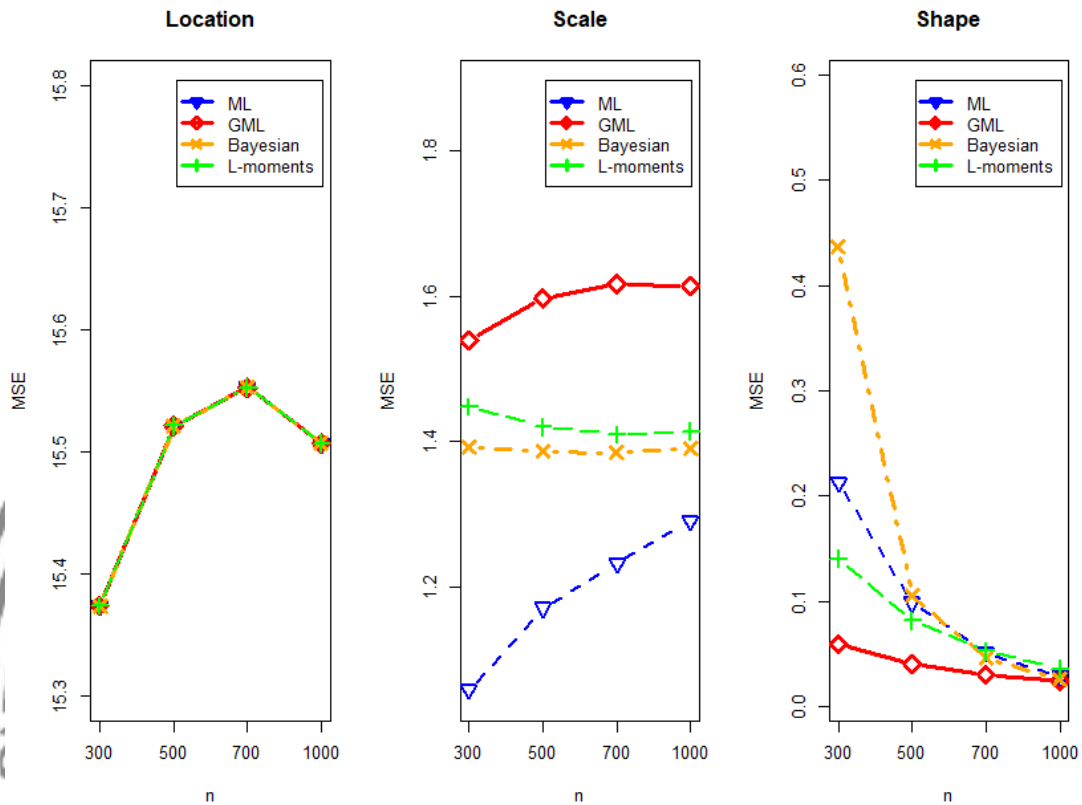
จากรูปที่ 4.11 พบว่า ค่าประมาณพารามิเตอร์บ่งตำแหน่งทั้ง 4 วิธีเป็นเส้นเดียวกัน เนื่องจากค่าดังกล่าวถูกกำหนดด้วยค่าเกณฑ์ในตำแหน่งเปอร์เซ็นต์ไทล์ที่ 90 สำหรับค่าประมาณพารามิเตอร์บ่งขนาดพบว่าวิธี Bayesian และ L-Moments มีแนวโน้มของค่า MSE ที่ลดลงเมื่อขนาดตัวอย่างเพิ่มขึ้น สำหรับวิธี ML ให้ค่า MSE ต่ำสุดสำหรับทุกขนาดตัวอย่าง ถึงแม้ว่าค่า MSE จะมีแนวโน้มเพิ่มขึ้นอย่างต่อเนื่องเมื่อขนาดตัวอย่างเพิ่มขึ้นก็ตาม และค่าประมาณพารามิเตอร์บ่งรูปร่างพบว่าสำหรับทุกวิธีมีแนวโน้มของค่า MSE ที่ลดลงอย่างต่อเนื่องเมื่อขนาดตัวอย่างเพิ่มขึ้น แต่วิธี ML และ Bayesian ให้ค่า MSE ใกล้เคียงกันทุกขนาดตัวอย่าง

ตารางที่ 4.15 ผลการจำลองข้อมูลการประมาณค่าพารามิเตอร์กรณี $\mu = 2, \sigma = 2, \xi = -0.3$ และ กำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 95

ขนาดตัวอย่าง	วิธีการประมาณค่าพารามิเตอร์	ค่าประมาณพารามิเตอร์			ค่าความคลาดเคลื่อนกำลังสอง (MSE)		
		Location (μ)	Scale (σ)	Shape (ξ)	Location (μ)	Scale (σ)	Shape (ξ)
300	ML	5.9157	1.0566	-0.5620	15.3740	<u>1.0587</u>	0.2125
	GML	5.9157	0.7888	-0.2556	15.3740	1.5396	<u>0.0596</u>
	Bayesian	5.9157	0.8963	-0.0318	15.3740	1.3924	0.4364
	L-Moments	5.9157	0.8469	-0.3099	15.3740	1.4484	0.1404
500	ML	5.9365	0.9593	-0.4648	15.5214	<u>1.1711</u>	0.0986
	GML	5.9365	0.7518	-0.2207	15.5214	1.5973	<u>0.0407</u>
	Bayesian	5.9365	0.8495	-0.1909	15.5214	1.3875	0.1055
	L-Moments	5.9365	0.8386	-0.3153	15.5214	1.4200	0.0819
700	ML	5.9416	0.9135	-0.4161	15.5526	<u>1.2324</u>	0.0514
	GML	5.9416	0.7387	-0.2061	15.5526	1.6173	<u>0.0305</u>
	Bayesian	5.9416	0.8406	-0.2397	15.5526	1.3849	0.0462
	L-Moments	5.9416	0.8333	-0.3135	15.5526	1.4098	0.0526
1,000	ML	5.9362	0.8769	-0.3758	15.5069	<u>1.2910</u>	0.0284
	GML	5.9362	0.7369	-0.2062	15.5069	1.6141	<u>0.0250</u>
	Bayesian	5.9362	0.8316	-0.2638	15.5069	1.3908	0.0262
	L-Moments	5.9362	0.8236	-0.3060	15.5069	1.4143	0.0359

หมายเหตุ ตัวเลขที่ขีดเส้นแสดงค่า MSE ที่ต่ำที่สุด

จากตารางที่ 4.15 เมื่อกำหนดให้ค่าพารามิเตอร์บ่งตำแหน่งถูกประมาณด้วยค่าเกณฑ์ในตำแหน่งเปอร์เซ็นต์ไทล์ที่ 95 พิจารณาว่าค่าประมาณพารามิเตอร์บ่งขนาด พบว่า เมื่อใช้วิธี ML ให้ค่า MSE ต่ำสุดสำหรับทุกขนาดตัวอย่าง โดยขนาดตัวอย่างเพิ่มขึ้น จะทำให้ MSE มีค่าเพิ่มขึ้น และเมื่อพิจารณาค่าประมาณพารามิเตอร์บ่งรูปร่าง พบว่า วิธี GML ให้ค่า MSE ต่ำสุดสำหรับทุกขนาดตัวอย่าง โดยขนาดตัวอย่างเพิ่มขึ้น จะทำให้ MSE มีค่าลดลง ค่าแนวโน้มของ MSE แสดงดังรูปที่ 4.12



รูปที่ 4.12 ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองของประมาณค่าพารามิเตอร์กรณี $\mu=2$, $\sigma=2$, $\xi=-0.3$ และกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 95

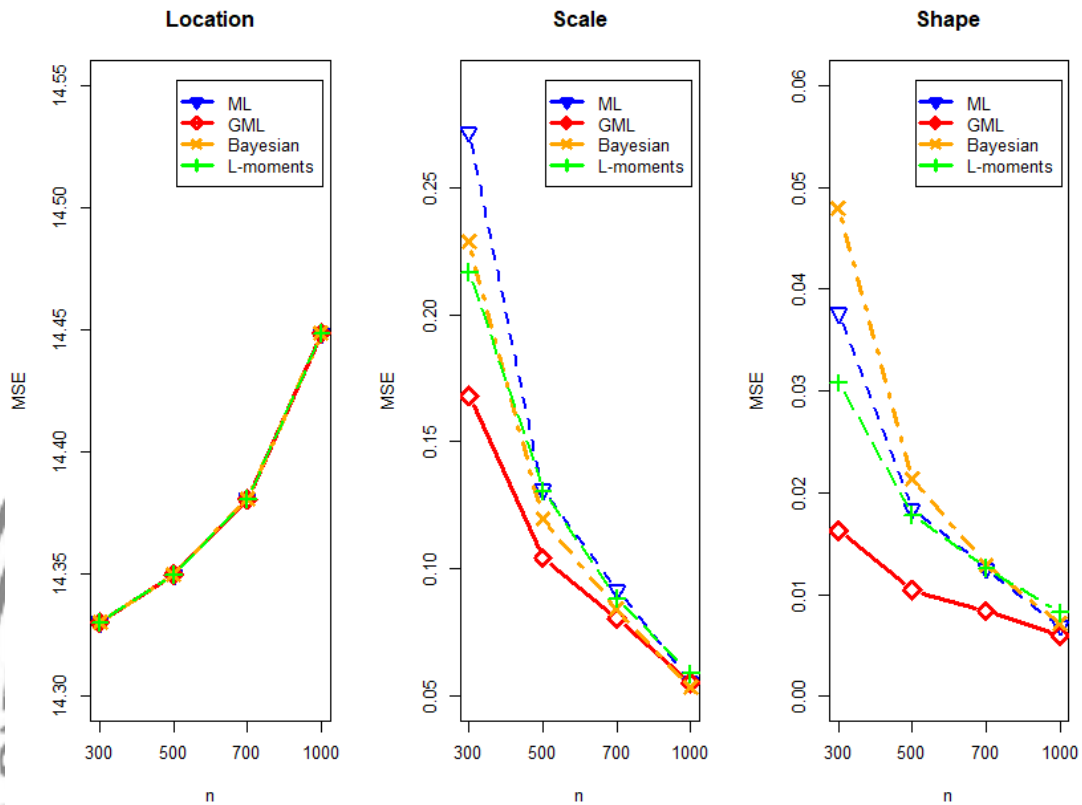
จากรูปที่ 4.12 พบว่า ค่าประมาณพารามิเตอร์บ่งตำแหน่งทั้ง 4 วิธีเป็นเส้นเดียวกัน เนื่องจากค่าดังกล่าวถูกกำหนดด้วยค่าเกณฑ์ในตำแหน่งเปอร์เซ็นต์ไทล์ที่ 95 สำหรับค่าประมาณพารามิเตอร์บ่งขนาดพบว่าวิธี ML และ GML มีแนวโน้มเพิ่มขึ้นของค่า MSE อย่างต่อเนื่องเมื่อขนาดตัวอย่างเพิ่มขึ้น อย่างไรก็ตาม วิธี ML ยังคงให้ค่า MSE ที่ต่ำสุด และค่าประมาณพารามิเตอร์บ่งรูปร่างพบว่าสำหรับทุกวิธีมีแนวโน้มของค่า MSE ที่ลดลงอย่างต่อเนื่องเมื่อขนาดตัวอย่างเพิ่มขึ้น แต่เมื่อพิจารณาวิธี Bayesian พบว่า ในช่วงขนาดตัวอย่าง 300 ถึง 500 ส่งผลให้ค่า MSE ลดลงอย่างรวดเร็ว

ตารางที่ 4.16 ผลการจำลองข้อมูลการประมาณค่าพารามิเตอร์กรณี $\mu = 2, \sigma = 2, \xi = 0$ และ กำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 85

ขนาดตัวอย่าง	วิธีการประมาณค่าพารามิเตอร์	ค่าประมาณพารามิเตอร์			ค่าความคลาดเคลื่อนกำลังสอง (MSE)		
		Location (μ)	Scale (σ)	Shape (ξ)	Location (μ)	Scale (σ)	Shape (ξ)
300	ML	5.7752	2.1218	-0.0591	14.3302	0.2714	0.0376
	GML	5.7752	2.1853	-0.0940	14.3302	<u>0.1682</u>	<u>0.0163</u>
	Bayesian	5.7752	2.0252	0.0851	14.3302	0.2287	0.0479
	L-Moments	5.7752	2.0061	-0.0062	14.3302	0.2166	0.0308
500	ML	5.7823	2.0687	-0.0343	14.3498	0.1310	0.0184
	GML	5.7823	2.1677	-0.0822	14.3498	<u>0.1044</u>	<u>0.0104</u>
	Bayesian	5.7823	2.0167	0.0454	14.3498	0.1196	0.0213
	L-Moments	5.7823	2.0046	-0.0032	14.3498	0.1306	0.0178
700	ML	5.7882	2.0584	-0.0277	14.3807	0.0918	0.0125
	GML	5.7882	2.1537	-0.0734	14.3807	<u>0.0806</u>	<u>0.0084</u>
	Bayesian	5.7882	2.0231	0.0262	14.3807	0.0841	0.0129
	L-Moments	5.7882	2.0091	-0.0037	14.3807	0.0884	0.0126
1,000	ML	5.7983	2.0334	-0.0175	14.4486	0.0557	0.0069
	GML	5.7983	2.1262	-0.0616	14.4486	0.0552	<u>0.0060</u>
	Bayesian	5.7983	2.0073	0.0196	14.4486	<u>0.0534</u>	0.0072
	L-Moments	5.7983	2.0006	-0.0015	14.4486	0.0589	0.0082

หมายเหตุ ตัวเลขที่ขีดเส้นแสดงค่า MSE ที่ต่ำที่สุด

จากตารางที่ 4.16 เมื่อกำหนดให้ค่าพารามิเตอร์บ่งตำแหน่งถูกประมาณด้วยค่าเกณฑ์ในตำแหน่งเปอร์เซ็นต์ไทล์ที่ 85 พิจารณาว่าค่าประมาณพารามิเตอร์บ่งขนาด พบว่า เมื่อใช้วิธี GML มีประสิทธิภาพมากกว่าวิธีการอื่น ๆ และเมื่อพิจารณาว่าค่าประมาณพารามิเตอร์บ่งรูปร่าง พบว่า วิธี GML ให้ค่าคลาดเคลื่อนกำลังสองต่ำสุดสำหรับทุกขนาดตัวอย่าง โดยขนาดตัวอย่างเพิ่มขึ้น จะทำให้ MSE มีค่าลดลง ค่าแนวโน้มของ MSE แสดงดังรูปที่ 4.1



รูปที่ 4.13 ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองของประมาณค่าพารามิเตอร์กรณี $\mu=2$, $\sigma=2$, $\xi=0$ และกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 85

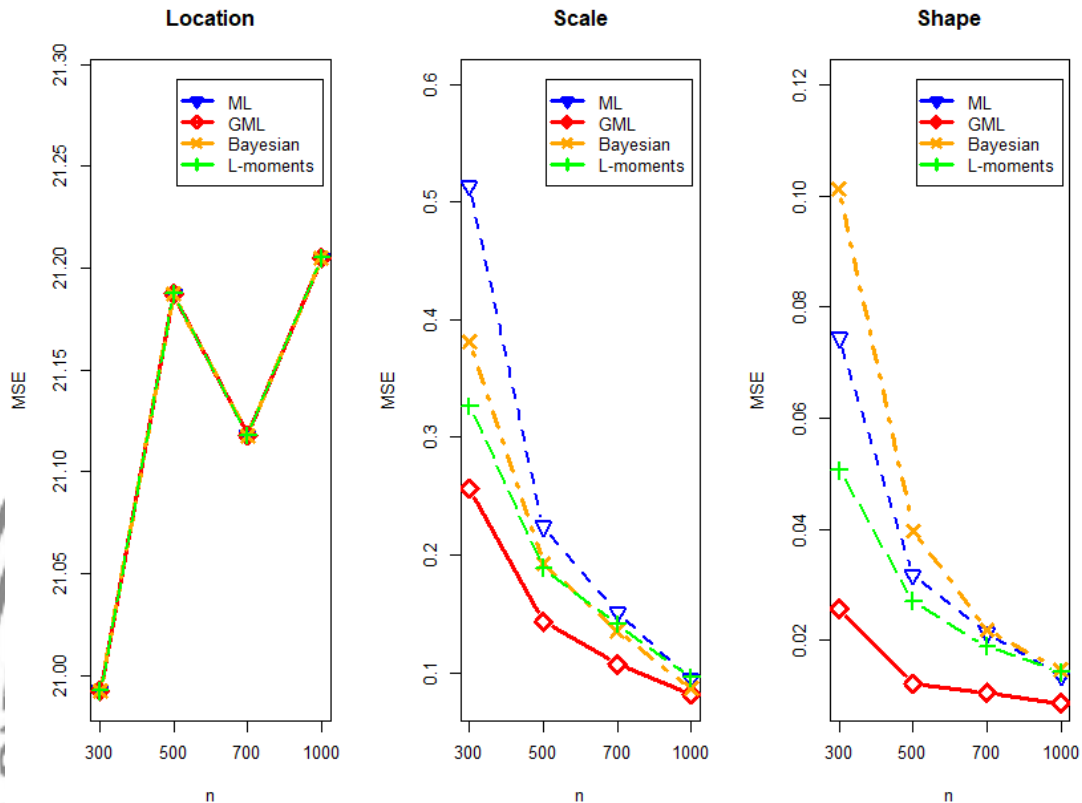
จากรูปที่ 4.13 พบว่า ค่าประมาณพารามิเตอร์บ่งตำแหน่งทั้ง 4 วิธีเป็นเส้นเดียวกัน เนื่องจากค่าดังกล่าวถูกกำหนดด้วยค่าเกณฑ์ในตำแหน่งเปอร์เซ็นต์ไทล์ที่ 85 โดยเมื่อขนาดตัวอย่างเพิ่มขึ้น ส่งผลให้ค่า MSE มีแนวโน้มเพิ่มขึ้นตาม สำหรับค่าประมาณพารามิเตอร์บ่งขนาดพบว่าทุกวิธีมีแนวโน้มของค่า MSE ลดลงเมื่อขนาดตัวอย่างเพิ่มขึ้น และค่าประมาณพารามิเตอร์บ่งรูปร่างพบว่าสำหรับทุกวิธีมีแนวโน้มของค่า MSE ที่ลดลงอย่างต่อเนื่องเมื่อขนาดตัวอย่างเพิ่มขึ้น แต่เมื่อพิจารณาวิธี GML พบว่า ให้ค่า MSE ต่ำสุดสำหรับทุกขนาดตัวอย่างของค่าประมาณพารามิเตอร์บ่งขนาดและพารามิเตอร์บ่งรูปร่าง

ตารางที่ 4.17 ผลการจำลองข้อมูลการประมาณค่าพารามิเตอร์กรณี $\mu = 2, \sigma = 2, \xi = 0$ และ กำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 90

ขนาด ตัวอย่าง	วิธีการ ประมาณค่า พารามิเตอร์	ค่าประมาณพารามิเตอร์			ค่าความคลาดเคลื่อน กำลังสอง (MSE)		
		Location (μ)	Scale (σ)	Shape (ξ)	Location (μ)	Scale (σ)	Shape (ξ)
300	ML	6.5700	2.2329	-0.1105	20.9926	0.5135	0.0744
	GML	6.5700	2.2043	-0.1077	20.9926	<u>0.2563</u>	<u>0.0257</u>
	Bayesian	6.5700	2.0815	0.1220	20.9926	0.3810	0.1013
	L-Moments	6.5700	2.0445	-0.0287	20.9926	0.3264	0.0506
500	ML	6.5956	2.1020	-0.0518	21.1873	0.2241	0.0317
	GML	6.5956	2.1796	-0.0920	21.1873	<u>0.1433</u>	<u>0.0122</u>
	Bayesian	6.5956	2.0172	0.0761	21.1873	0.1930	0.0397
	L-Moments	6.5956	1.9912	-0.0002	21.1873	0.1890	0.0271
700	ML	6.5901	2.0943	-0.0496	21.1178	0.1511	0.0214
	GML	6.5901	2.1733	-0.0896	21.1178	<u>0.1072</u>	<u>0.0106</u>
	Bayesian	6.5901	2.0373	0.0356	21.1178	0.1354	0.0220
	L-Moments	6.5901	2.0220	-0.0147	21.1178	0.1412	0.0190
1,000	ML	6.6011	2.0574	-0.0262	21.2049	0.0945	0.0136
	GML	6.6011	2.1551	-0.0735	21.2049	<u>0.0815</u>	<u>0.0087</u>
	Bayesian	6.6011	2.0181	0.0315	21.2049	0.0861	0.0147
	L-Moments	6.6011	2.0018	0.0006	21.2049	0.0956	0.0143

หมายเหตุ ตัวเลขที่ขีดเส้นแสดงค่า MSE ที่ต่ำที่สุด

จากตารางที่ 4.17 เมื่อกำหนดให้ค่าพารามิเตอร์บ่งตำแหน่งถูกประมาณด้วยค่าเกณฑ์ในตำแหน่งเปอร์เซ็นต์ไทล์ที่ 90 เมื่อพิจารณาค่าประมาณพารามิเตอร์บ่งขนาดและพารามิเตอร์บ่งรูปร่าง พบว่า เมื่อใช้วิธี GML มีประสิทธิภาพมากกว่าวิธีการอื่น ๆ เนื่องจากให้ค่า MSE ต่ำสุดสำหรับทุกขนาดตัวอย่าง โดยขนาดตัวอย่างเพิ่มขึ้น จะทำให้ MSE มีค่าลดลง ค่าแนวโน้มของ MSE แสดงดังรูปที่ 4.14



รูปที่ 4.14 ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองของประมาณค่าพารามิเตอร์กรณี $\mu = 2$, $\sigma = 2$, $\xi = 0$ และกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 90

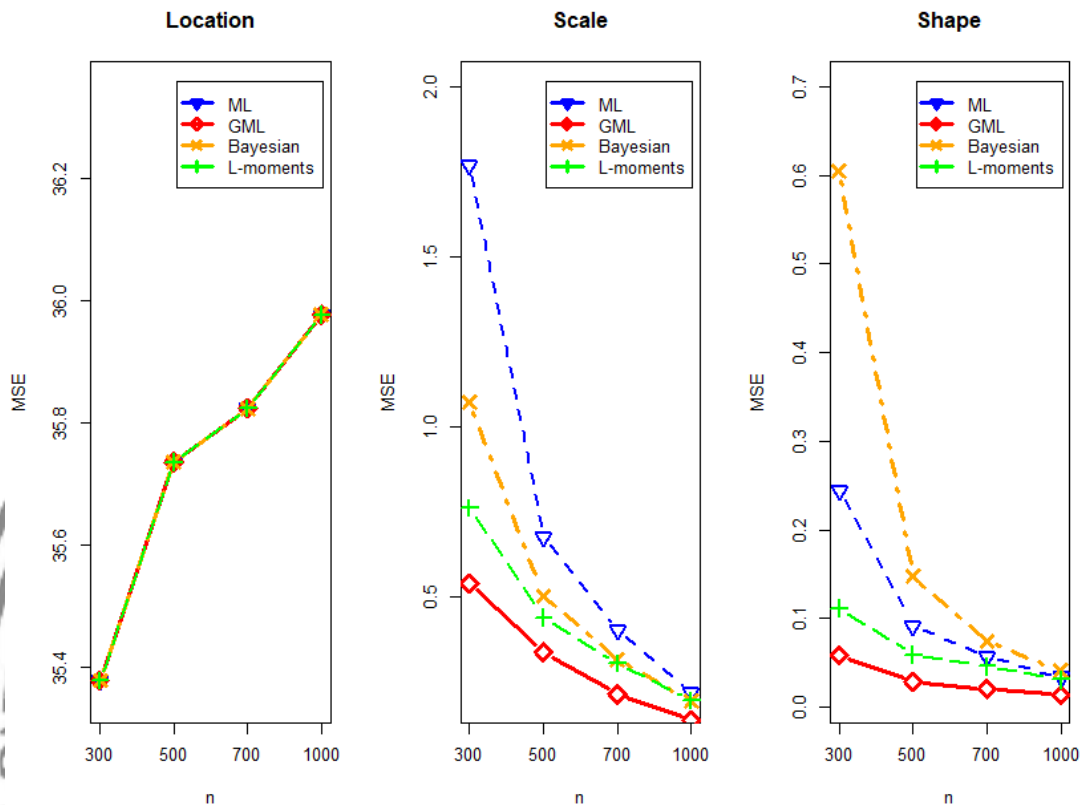
จากรูปที่ 4.14 พบว่า ค่าประมาณพารามิเตอร์บ่งตำแหน่งทั้ง 4 วิธีเป็นเส้นเดียวกัน เนื่องจากค่าดังกล่าวถูกกำหนดด้วยค่าเกณฑ์ในตำแหน่งเปอร์เซ็นต์ไทล์ที่ 90 สำหรับค่าประมาณพารามิเตอร์บ่งขนาดพบว่าทุกวิธีมีแนวโน้มของค่า MSE ลดลงเมื่อขนาดตัวอย่างเพิ่มขึ้น และค่าประมาณพารามิเตอร์บ่งรูปร่างพบว่าสำหรับทุกวิธีมีแนวโน้มของค่า MSE ที่ลดลงอย่างต่อเนื่องเมื่อขนาดตัวอย่างเพิ่มขึ้น แต่เมื่อพิจารณาวิธี GML พบว่า ให้ค่า MSE ต่ำสุดสำหรับทุกขนาดตัวอย่างของค่าประมาณพารามิเตอร์บ่งขนาดและพารามิเตอร์บ่งรูปร่าง

ตารางที่ 4.18 ผลการจำลองข้อมูลการประมาณค่าพารามิเตอร์กรณี $\mu = 2, \sigma = 2, \xi = 0$ และ กำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 95

ขนาด ตัวอย่าง	วิธีการ ประมาณค่า พารามิเตอร์	ค่าประมาณพารามิเตอร์			ค่าความคลาดเคลื่อน กำลังสอง (MSE)		
		Location (μ)	Scale (σ)	Shape (ξ)	Location (μ)	Scale (σ)	Shape (ξ)
300	ML	7.9273	2.5708	-0.2435	35.3788	1.7679	0.2438
	GML	7.9273	2.2463	-0.1349	35.3788	<u>0.5372</u>	<u>0.0582</u>
	Bayesian	7.9273	2.2127	0.3535	35.3788	1.0724	0.6049
	L-Moments	7.9273	2.0811	-0.0481	35.3788	0.7597	0.1113
500	ML	7.9650	2.2876	-0.1205	35.7360	0.6735	0.0912
	GML	7.9650	2.2462	-0.1135	35.7360	<u>0.3349</u>	<u>0.0283</u>
	Bayesian	7.9650	2.1022	0.1749	35.7360	0.5020	0.1477
	L-Moments	7.9650	2.0456	-0.0150	35.7360	0.4374	0.0591
700	ML	7.9758	2.1812	-0.0821	35.8238	0.3993	0.0569
	GML	7.9758	2.2049	-0.1017	35.8238	<u>0.2120</u>	<u>0.0203</u>
	Bayesian	7.9758	2.0584	0.1091	35.8238	0.3129	0.0748
	L-Moments	7.9758	2.0417	-0.0209	35.8238	0.3026	0.0458
1,000	ML	7.9919	2.0816	-0.0548	35.9771	0.2166	0.0334
	GML	7.9919	2.1539	-0.0923	35.9771	<u>0.1354</u>	<u>0.0135</u>
	Bayesian	7.9919	1.9979	0.0710	35.9771	0.1897	0.0406
	L-Moments	7.9919	1.9989	-0.0166	35.9771	0.1936	0.0309

หมายเหตุ ตัวเลขที่ขีดเส้นแสดงค่า MSE ที่ต่ำที่สุด

จากตารางที่ 4.18 เมื่อกำหนดให้ค่าพารามิเตอร์บ่งตำแหน่งถูกประมาณด้วยค่าเกณฑ์ใน ตำแหน่งเปอร์เซ็นต์ไทล์ที่ 95 เมื่อพิจารณาค่าประมาณพารามิเตอร์บ่งขนาด พบว่า เมื่อใช้วิธี GML ให้ ค่า MSE ต่ำสุดสำหรับทุกขนาดตัวอย่าง และเมื่อพิจารณาค่าประมาณพารามิเตอร์บ่งรูปร่าง พบว่า วิธี GML มีประสิทธิภาพมากกว่าวิธีการอื่น ๆ ค่าแนวโน้มของ MSE แสดงดังรูปที่ 4.15



รูปที่ 4.15 ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองของประมาณค่าพารามิเตอร์กรณี $\mu=2$, $\sigma=2$, $\xi=0$ และกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 95

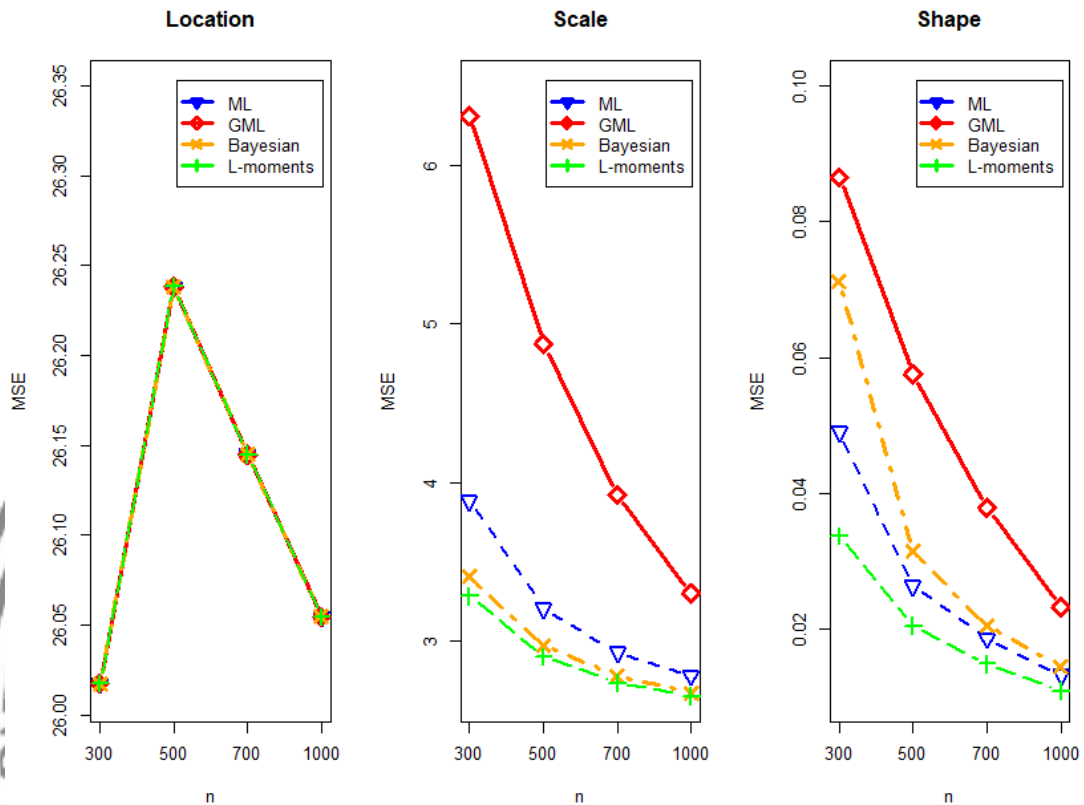
จากรูปที่ 4.15 พบว่า ค่าประมาณพารามิเตอร์บ่งตำแหน่งทั้ง 4 วิธีเป็นเส้นเดียวกัน เนื่องจากค่าดังกล่าวถูกกำหนดด้วยค่าเกณฑ์ในตำแหน่งเปอร์เซ็นต์ไทล์ที่ 95 โดยเมื่อขนาดตัวอย่างเพิ่มขึ้นส่งผลให้ค่า MSE มีแนวโน้มเพิ่มขึ้นตาม สำหรับค่าประมาณพารามิเตอร์บ่งขนาดพบว่าทุกวิธีมีแนวโน้มของค่า MSE ลดลงเมื่อขนาดตัวอย่างเพิ่มขึ้น และค่าประมาณพารามิเตอร์บ่งรูปร่างพบว่าสำหรับทุกวิธีมีแนวโน้มของค่า MSE ที่ลดลงอย่างต่อเนื่องเมื่อขนาดตัวอย่างเพิ่มขึ้น โดยวิธี Bayesian มีค่า MSE ลดลงอย่างรวดเร็วในช่วงขนาดตัวอย่าง 300 ถึง 500 แต่เมื่อพิจารณาวิธี GML พบว่า ให้ค่า MSE ต่ำสุดสำหรับทุกขนาดตัวอย่างของค่าประมาณพารามิเตอร์บ่งขนาดและพารามิเตอร์บ่งรูปร่าง

ตารางที่ 4.19 ผลการจำลองข้อมูลการประมาณค่าพารามิเตอร์กรณี $\mu = 2, \sigma = 2, \xi = 0.3$ และ กำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 85

ขนาด ตัวอย่าง	วิธีการ ประมาณค่า พารามิเตอร์	ค่าประมาณพารามิเตอร์			ค่าความคลาดเคลื่อน กำลังสอง (MSE)		
		Location (μ)	Scale (σ)	Shape (ξ)	Location (μ)	Scale (σ)	Shape (ξ)
300	ML	7.0778	3.7106	0.2535	26.0175	3.8838	0.0490
	GML	7.0778	4.1957	0.1465	26.0175	6.3098	0.0865
	Bayesian	7.0778	3.5909	0.4148	26.0175	3.4098	0.0712
	L-Moments	7.0778	3.5788	0.2678	26.0175	<u>3.2839</u>	<u>0.0337</u>
500	ML	7.1091	3.6376	0.2650	26.2381	3.2066	0.0263
	GML	7.1091	3.9880	0.1848	26.2381	4.8729	0.0575
	Bayesian	7.1091	3.5696	0.3544	26.2381	2.9747	0.0314
	L-Moments	7.1091	3.5630	0.2730	26.2381	<u>2.9050</u>	<u>0.0205</u>
700	ML	7.1039	3.6029	0.2752	26.1448	2.9295	0.0186
	GML	7.1039	3.8238	0.2211	26.1448	3.9224	0.0379
	Bayesian	7.1039	3.5593	0.3366	26.1448	2.7843	0.0205
	L-Moments	7.1039	3.5522	0.2801	26.1448	<u>2.7378</u>	<u>0.0149</u>
1,000	ML	7.0975	3.5890	0.2876	26.0546	2.7847	0.0132
	GML	7.0975	3.7079	0.2569	26.0546	3.3019	0.0232
	Bayesian	7.0975	3.5554	0.3293	26.0546	2.6757	0.0144
	L-Moments	7.0975	3.5553	0.2892	26.0546	<u>2.6564</u>	<u>0.0109</u>

หมายเหตุ ตัวเลขที่ขีดเส้นแสดงค่า MSE ที่ต่ำที่สุด

จากตารางที่ 4.19 เมื่อกำหนดให้ค่าพารามิเตอร์บ่งตำแหน่งถูกประมาณด้วยค่าเกณฑ์ในตำแหน่งเปอร์เซ็นต์ไทล์ที่ 85 เมื่อพิจารณาค่าประมาณพารามิเตอร์บ่งขนาดและพารามิเตอร์บ่งรูปร่าง พบว่า เมื่อใช้วิธี L-Moments มีประสิทธิภาพมากกว่าวิธีการอื่น ๆ เนื่องจากให้ค่า MSE ต่ำสุดสำหรับทุกขนาดตัวอย่าง โดยขนาดตัวอย่างเพิ่มขึ้น จะทำให้ MSE มีค่าลดลง ค่าแนวโน้มของ MSE แสดงดังรูปที่ 4.16



รูปที่ 4.16 ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองของประมาณค่าพารามิเตอร์กรณี $\mu=2$, $\sigma=2$, $\xi=0.3$ และกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 85

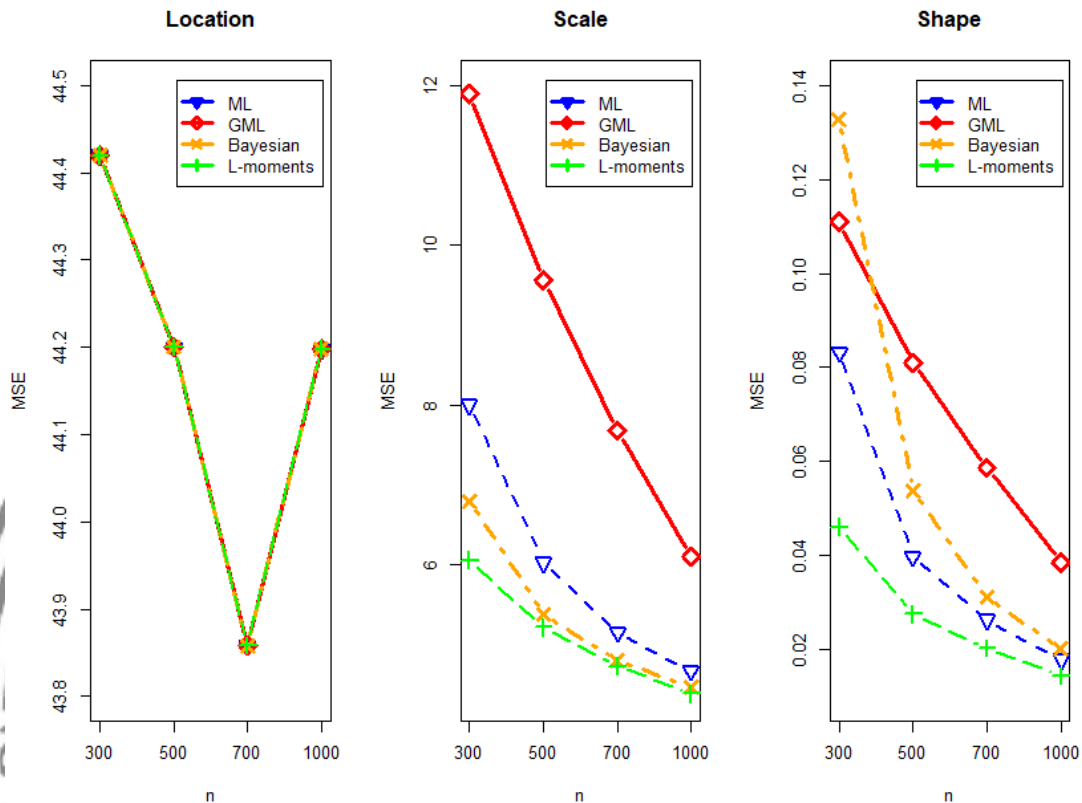
จากรูปที่ 4.16 พบว่า ค่าประมาณพารามิเตอร์บ่งตำแหน่งทั้ง 4 วิธีเป็นเส้นเดียวกัน เนื่องจากค่าดังกล่าวถูกกำหนดด้วยค่าเกณฑ์ในตำแหน่งเปอร์เซ็นต์ไทล์ที่ 85 สำหรับค่าประมาณพารามิเตอร์บ่งขนาดพบว่าทุกวิธีมีแนวโน้มของค่า MSE ลดลงเมื่อขนาดตัวอย่างเพิ่มขึ้น โดยวิธี Bayesian และ L-Moments ให้ค่า MSE ที่ใกล้เคียงกันทุกขนาดตัวอย่าง และค่าประมาณพารามิเตอร์บ่งรูปร่างพบว่าสำหรับทุกวิธีมีแนวโน้มของค่า MSE ที่ลดลงอย่างต่อเนื่องเมื่อขนาดตัวอย่างเพิ่มขึ้น แต่เมื่อพิจารณาวิธี L-Moments พบว่า ให้ค่า MSE ต่ำสุดสำหรับทุกขนาดตัวอย่างของค่าประมาณพารามิเตอร์บ่งขนาดและพารามิเตอร์บ่งรูปร่าง

ตารางที่ 4.20 ผลการจำลองข้อมูลการประมาณค่าพารามิเตอร์กรณี $\mu = 2, \sigma = 2, \xi = 0.3$ และ กำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 90

ขนาด ตัวอย่าง	วิธีการ ประมาณค่า พารามิเตอร์	ค่าประมาณพารามิเตอร์			ค่าความคลาดเคลื่อน กำลังสอง (MSE)		
		Location (μ)	Scale (σ)	Shape (ξ)	Location (μ)	Scale (σ)	Shape (ξ)
300	ML	8.6293	4.4263	0.2074	44.4196	7.9954	0.0832
	GML	8.6293	5.0360	0.0930	44.4196	11.8936	0.1110
	Bayesian	8.6293	4.2156	0.4683	44.4196	6.7860	0.1327
	L-Moments	8.6293	4.1456	0.2410	44.4196	<u>6.0560</u>	<u>0.0460</u>
500	ML	8.6267	4.2354	0.2475	44.2003	6.0230	0.0397
	GML	8.6267	4.7991	0.1403	44.2003	9.5607	0.0810
	Bayesian	8.6267	4.1028	0.3921	44.2003	5.3797	0.0537
	L-Moments	8.6267	4.0902	0.2644	44.2003	<u>5.2140</u>	<u>0.0275</u>
700	ML	8.6067	4.1152	0.2623	43.8581	5.1500	0.0262
	GML	8.6067	4.5437	0.1751	43.8581	7.6750	0.0586
	Bayesian	8.6067	4.0328	0.3589	43.8581	4.7948	0.0312
	L-Moments	8.6067	4.0278	0.2712	43.8581	<u>4.7284</u>	<u>0.0202</u>
1,000	ML	8.6371	4.0578	0.2777	44.1978	4.6673	0.0178
	GML	8.6371	4.3178	0.2213	44.1978	6.1012	0.0384
	Bayesian	8.6371	4.0093	0.3405	44.1978	4.4629	0.0200
	L-Moments	8.6371	3.9970	0.2827	44.1978	<u>4.3812</u>	<u>0.0143</u>

หมายเหตุ ตัวเลขที่ขีดเส้นแสดงค่า MSE ที่ต่ำที่สุด

จากตารางที่ 4.20 เมื่อกำหนดให้ค่าพารามิเตอร์บ่งตำแหน่งถูกประมาณด้วยค่าเกณฑ์ในตำแหน่งเปอร์เซ็นต์ไทล์ที่ 90 เมื่อพิจารณาค่าประมาณพารามิเตอร์บ่งขนาดและพารามิเตอร์บ่งรูปร่าง พบว่า เมื่อใช้วิธี L-Moments มีประสิทธิภาพมากกว่าวิธีการอื่น ๆ เนื่องจากให้ค่า MSE ต่ำสุดสำหรับทุกขนาดตัวอย่าง โดยขนาดตัวอย่างเพิ่มขึ้น จะทำให้ MSE มีค่าลดลง ค่าแนวโน้มของ MSE แสดงดังรูปที่ 4.17



รูปที่ 4.17 ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองของประมาณค่าพารามิเตอร์กรณี $\mu = 2$, $\sigma = 2$, $\xi = 0.3$ และกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 90


จากรูปที่ 4.17 พบว่า ค่าประมาณพารามิเตอร์บ่งตำแหน่งทั้ง 4 วิธีเป็นเส้นเดียวกัน เนื่องจากค่าดังกล่าวถูกกำหนดด้วยค่าเกณฑ์ในตำแหน่งเปอร์เซ็นต์ไทล์ที่ 90 สำหรับค่าประมาณพารามิเตอร์บ่งขนาดพบว่าทุกวิธีมีแนวโน้มของค่า MSE ลดลงเมื่อขนาดตัวอย่างเพิ่มขึ้น โดยวิธี Bayesian และ L-Moments ให้ค่า MSE ที่ใกล้เคียงกันสำหรับขนาดตัวอย่าง 500 ถึง 700 และค่าประมาณพารามิเตอร์บ่งรูปร่างพบสำหรับทุกวิธีมีแนวโน้มของค่า MSE ที่ลดลงอย่างต่อเนื่องเมื่อขนาดตัวอย่างเพิ่มขึ้น แต่เมื่อพิจารณาวิธี L-Moments พบว่า ให้ค่า MSE ต่ำสุดสำหรับทุกขนาดตัวอย่างของค่าประมาณพารามิเตอร์บ่งขนาดและพารามิเตอร์บ่งรูปร่าง

ตารางที่ 4.21 ผลการจำลองข้อมูลการประมาณค่าพารามิเตอร์กรณี $\mu = 2, \sigma = 2, \xi = 0.3$ และ กำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 95

ขนาด ตัวอย่าง	วิธีการ ประมาณค่า พารามิเตอร์	ค่าประมาณพารามิเตอร์			ค่าความคลาดเคลื่อน กำลังสอง (MSE)		
		Location (μ)	Scale (σ)	Shape (ξ)	Location (μ)	Scale (σ)	Shape (ξ)
300	ML	11.6411	5.9767	0.1191	94.5001	25.2261	0.2653
	GML	11.6411	6.1118	0.0762	94.5001	24.6674	0.1586
	Bayesian	11.6411	5.3566	0.7776	94.5001	18.2013	0.8266
	L-Moments	11.6411	5.0736	0.2149	94.5001	<u>14.1995</u>	<u>0.1063</u>
500	ML	11.6257	5.5573	0.1950	93.5926	16.3694	0.0974
	GML	11.6257	6.3016	0.0857	93.5926	23.3295	0.1206
	Bayesian	11.6257	5.2056	0.5437	93.5926	13.6387	0.2230
	L-Moments	11.6257	5.1395	0.2386	93.5926	<u>12.5271</u>	<u>0.0563</u>
700	ML	11.6632	5.2687	0.2264	94.0509	13.1294	0.0723
	GML	11.6632	5.9496	0.1193	94.0509	18.9217	0.1037
	Bayesian	11.6632	5.0293	0.4531	94.0509	11.4268	0.1224
	L-Moments	11.6632	5.0181	0.2485	94.0509	<u>11.0321</u>	<u>0.0458</u>
1,000	ML	11.6995	5.1519	0.2529	94.5428	11.4988	0.0410
	GML	11.6995	5.8469	0.1447	94.5428	17.4963	0.0808
	Bayesian	11.6995	5.0269	0.3924	94.5428	10.6267	0.0556
	L-Moments	11.6995	4.9942	0.2646	94.5428	<u>10.2424</u>	<u>0.0292</u>

หมายเหตุ ตัวเลขที่ขีดเส้นแสดงค่า MSE ที่ต่ำที่สุด

จากตารางที่ 4.21 เมื่อกำหนดให้ค่าพารามิเตอร์บ่งตำแหน่งถูกประมาณด้วยค่าเกณฑ์ใน ตำแหน่งเปอร์เซ็นต์ไทล์ที่ 90 เมื่อพิจารณาค่าประมาณพารามิเตอร์บ่งขนาดและพารามิเตอร์บ่งรูปร่าง พบว่า เมื่อใช้วิธี L-Moments มีประสิทธิภาพมากกว่าวิธีการอื่น ๆ เนื่องจากให้ค่า MSE ต่ำสุดสำหรับ ทุกขนาดตัวอย่าง โดยขนาดตัวอย่างเพิ่มขึ้น จะทำให้ MSE มีค่าลดลง ค่าแนวโน้มของ MSE แสดงดัง รูปที่ 4.18



รูปที่ 4.18 ค่าเฉลี่ยความคลาดเคลื่อนกำลังสองของประมาณค่าพารามิเตอร์กรณี $\mu = 2$, $\sigma = 2$, $\xi = 0.3$ และกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 95

จากรูปที่ 4.17 พบว่า ค่าประมาณพารามิเตอร์บ่งตำแหน่งทั้ง 4 วิธีเป็นเส้นเดียวกัน เนื่องจากค่าดังกล่าวถูกกำหนดด้วยค่าเกณฑ์ในตำแหน่งเปอร์เซ็นต์ไทล์ที่ 95 สำหรับค่าประมาณพารามิเตอร์บ่งขนาดพบว่าทุกวิธีมีแนวโน้มของค่า MSE ลดลงเมื่อขนาดตัวอย่างเพิ่มขึ้น โดยวิธี Bayesian และ L-Moments ให้ค่า MSE ที่ใกล้เคียงกันสำหรับขนาดตัวอย่าง 700 ถึง 1,000 และค่าประมาณพารามิเตอร์บ่งรูปร่างพบว่าสำหรับทุกวิธีมีแนวโน้มของค่า MSE ที่ลดลงอย่างต่อเนื่องเมื่อขนาดตัวอย่างเพิ่มขึ้น โดยวิธี Bayesian ให้ค่า MSE ลดลงอย่างรวดเร็วในช่วงขนาดตัวอย่าง 300 ถึง 500 แต่เมื่อพิจารณาวิธี L-Moments พบว่า ให้ค่า MSE ต่ำสุดสำหรับทุกขนาดตัวอย่างของค่าประมาณพารามิเตอร์บ่งขนาดและพารามิเตอร์บ่งรูปร่าง

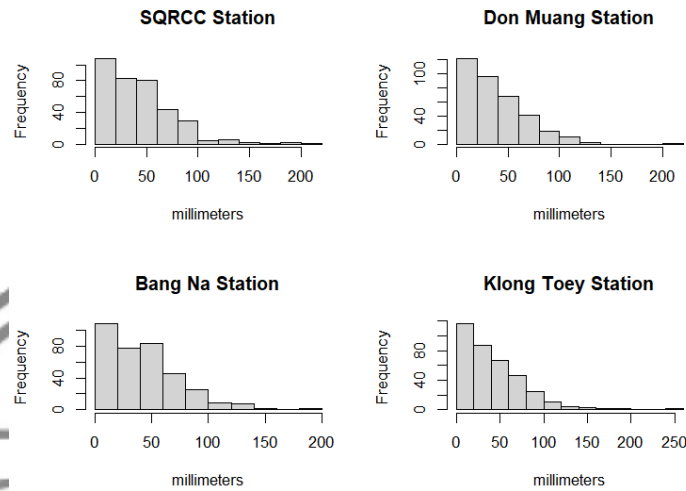
4.2.2 ค่าสถิติพื้นฐานสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือน

สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนของสถานีตรวจวัดทั้ง 4 สถานีภายใน กรุงเทพมหานคร แสดงค่าสถิติพื้นฐาน ประกอบด้วย ค่าเฉลี่ย ส่วนเบี่ยงเบนมาตรฐาน สัมประสิทธิ์ความแปรผัน สัมประสิทธิ์ความโค้ง ค่าต่ำสุด และค่าสูงสุด ดังตารางที่ 4.22

ตารางที่ 4.22 ค่าสถิติพื้นฐานสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนแต่ละสถานี ตั้งแต่ พ.ศ. 2537 - 2566

สถานี	ค่าต่ำสุด	ค่าสูงสุด	ค่าเฉลี่ย	ส่วนเบี่ยงเบนมาตรฐาน	ความแปรผัน	ความโค้ง
ศูนย์การประชุมแห่งชาติสิริกิติ์	0	216.8	41.5964	34.6669	1.3679	6.3097
ดอนเมือง	0	210.7	36.7911	30.8009	1.0355	5.1659
บางนา	0	185.9	41.5675	33.6561	0.9628	4.3538
คลองเตย	0	242.6	41.1825	35.3754	1.3651	6.4617

จากตารางที่ 4.22 พบว่า สถานีคลองเตยมีค่าปริมาณน้ำฝนสูงสุดรายเดือนสูงสุดเมื่อเทียบกับสถานีอื่นเท่ากับ 242.6 มิลลิเมตร และมีส่วนเบี่ยงเบนมาตรฐานสูงสุดเท่ากับ 35.3754 มิลลิเมตร หมายความว่า ปริมาณน้ำฝนสูงสุดของสถานีดอนเมืองในแต่ละเดือนมีการกระจายตัวสูง ในขณะที่ไม่พบค่าปริมาณน้ำฝนสูงสุดรายเดือนต่ำสุด เมื่อพิจารณาข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนในภาพรวมพบว่า สถานีศูนย์การประชุมแห่งชาติสิริกิติ์มีปริมาณน้ำฝนสูงสุดรายเดือนเฉลี่ยสูงสุดเท่ากับ 41.5964 มิลลิเมตร ในส่วนของค่าสัมประสิทธิ์ความแปรผันสำหรับทุกสถานีมีค่ามากกว่าศูนย์ หมายความว่า ข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนมีลักษณะการแจกแจงแบบเบ้ขวา และในส่วนของค่าสัมประสิทธิ์ความโค้งสำหรับทุกสถานีมากกว่าศูนย์ หมายความว่า ลักษณะความโค้งของข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนมากกว่าความโค้งของการแจกแจงปกติ โดยแสดงลักษณะข้อมูลแบบฮิสโตแกรม ดังรูปที่ 4.19



รูปที่ 4.19 ฮิสโตแกรมข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนสำหรับแต่ละสถานี

จากรูปที่ 4.19 พบว่า ข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนสำหรับแต่ละสถานีมีลักษณะของการแจกแจงแบบเบ้ขวา โดยสถานีศูนย์การประชุมแห่งชาติสิริกิติ์และสถานีดอนเมืองพบความถี่ในการเกิดปริมาณน้ำฝนสูงสุดที่ชัดเจนกว่าสถานีอื่น ซึ่งสอดคล้องกับค่าสถิติพื้นฐานจากตารางที่ 4.22

4.2.3 การประมาณค่าพารามิเตอร์สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือน

ทำการประมาณค่าพารามิเตอร์ของปริมาณน้ำฝนสูงสุดรายเดือนของการแจกแจงพาราเวอรวางนัยทั่วไป ซึ่งประกอบด้วยวิธีภาวะน่าจะเป็นสูงสุด วิธีภาวะน่าจะเป็นสูงสุดทั่วไป วิธีของเบส์ และวิธีโมเมนต์เชิงเส้น จำแนกตามสถานีตรวจวัดระดับน้ำ แสดงดังตารางที่ 4.23 - 4.34

ตารางที่ 4.23 ค่าประมาณพารามิเตอร์สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนของสถานีศูนย์การประชุมแห่งชาติสิริกิติ์ เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 85

วิธีการประมาณค่าพารามิเตอร์	ค่าประมาณพารามิเตอร์		
	Location (μ)	Scale (σ)	Shape (ξ)
ML	67.0600	30.7648	0.0296
GML	67.0600	35.1446	-0.0858
Bayesian	67.0600	31.2188	0.1497
L-Moments	67.0600	30.1863	0.0482

ตารางที่ 4.23 แสดงค่าประมาณพารามิเตอร์ของการแจกแจง GPD สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนของสถานีศูนย์การประชุมแห่งชาติสิริกิติ์ เมื่อกำหนดให้ค่าพารามิเตอร์บ่งตำแหน่งถูกประมาณด้วยค่าเกณฑ์ในตำแหน่งเปอร์เซ็นต์ไทล์ที่ 85 โดยพบว่าวิธี GML ให้ค่าประมาณของพารามิเตอร์บ่งขนาดสูงสุดที่ 35.1446 ขณะที่วิธี ML และ L-Moments ให้ประสิทธิภาพที่ใกล้เคียงกัน สำหรับพารามิเตอร์บ่งรูปร่างพบว่าวิธี ML, Bayesian และ L-Moments ให้ค่าประมาณมากกว่าศูนย์ แสดงว่าการแจกแจง GPD มีลักษณะแบบหางหนา

ตารางที่ 4.24 ค่าประมาณพารามิเตอร์สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนของสถานีศูนย์การประชุมแห่งชาติสิริกิติ์ เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 90

วิธีการประมาณค่าพารามิเตอร์	ค่าประมาณพารามิเตอร์		
	Location (μ)	Scale (σ)	Shape (ξ)
ML	81.7700	24.3124	0.1819
GML	81.7700	33.0217	-0.0811
Bayesian	81.7700	23.3567	0.4715
L-Moments	81.7700	22.3069	0.2436

ตารางที่ 4.24 แสดงค่าประมาณพารามิเตอร์ของการแจกแจง GPD สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนของสถานีศูนย์การประชุมแห่งชาติสิริกิติ์ เมื่อกำหนดให้ค่าพารามิเตอร์บ่งตำแหน่งถูกประมาณด้วยค่าเกณฑ์ในตำแหน่งเปอร์เซ็นต์ไทล์ที่ 90 โดยพบว่าวิธี GML ให้ค่าประมาณของพารามิเตอร์บ่งขนาดสูงสุดที่ 33.0217 ขณะที่วิธี L-Moments ให้ค่าต่ำสุดที่ 22.3069 สำหรับพารามิเตอร์บ่งรูปร่างพบว่าวิธี ML, Bayesian และ L-Moments ให้ค่าประมาณมากกว่าศูนย์ แสดงว่าการแจกแจง GPD มีลักษณะแบบหางหนา

ตารางที่ 4.25 ค่าประมาณพารามิเตอร์สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนของสถานีศูนย์การประชุมแห่งชาติสิริกิติ์ เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 95

วิธีการประมาณค่าพารามิเตอร์	ค่าประมาณพารามิเตอร์		
	Location (μ)	Scale (σ)	Shape (ξ)
ML	94.6900	45.8180	-0.1788
GML	94.6900	43.0395	-0.1180
Bayesian	94.6900	43.7227	0.6592
L-Moments	94.6900	36.6666	0.0552

ตารางที่ 4.25 แสดงค่าประมาณพารามิเตอร์ของการแจกแจง GPD สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนของสถานีศูนย์การประชุมแห่งชาติสิริกิติ์ เมื่อกำหนดให้ค่าพารามิเตอร์บ่งตำแหน่งถูกประมาณด้วยค่าเกณฑ์ในตำแหน่งเปอร์เซ็นต์ไทล์ที่ 95 โดยพบว่าวิธี ML ให้ค่าประมาณของพารามิเตอร์บ่งขนาดสูงสุดที่ 45.8180 ขณะที่วิธี L-Moments ให้ค่าต่ำสุดที่ 36.6666 สำหรับพารามิเตอร์บ่งรูปร่างพบว่าวิธี Bayesian และ L-Moments ให้ค่าประมาณมากกว่าศูนย์ แสดงว่าการแจกแจง GPD มีลักษณะแบบหางหนา

ตารางที่ 4.26 ค่าประมาณพารามิเตอร์สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนของสถานีดอนเมือง เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 85

วิธีการประมาณค่าพารามิเตอร์	ค่าประมาณพารามิเตอร์		
	Location (μ)	Scale (σ)	Shape (ξ)
ML	71.5250	23.6507	0.0118
GML	71.5250	26.2481	-0.0726
Bayesian	71.5250	22.6834	0.1860
L-Moments	71.5250	26.1059	-0.0909

ตารางที่ 4.26 แสดงค่าประมาณพารามิเตอร์ของการแจกแจง GPD สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนของสถานีดอนเมือง เมื่อกำหนดให้ค่าพารามิเตอร์บ่งตำแหน่งถูกประมาณด้วยค่าเกณฑ์ในตำแหน่งเปอร์เซ็นต์ไทล์ที่ 85 โดยพบว่าวิธี GML ให้ค่าประมาณของพารามิเตอร์บ่งขนาดสูงสุดที่ 26.2481 ขณะที่วิธี ML ให้ค่าต่ำสุดที่ 23.6507 สำหรับพารามิเตอร์บ่งรูปร่างพบว่าวิธี ML และ Bayesian ให้ค่าประมาณมากกว่าศูนย์ แสดงว่าการแจกแจง GPD มีลักษณะแบบหางหนา

ตารางที่ 4.27 ค่าประมาณพารามิเตอร์สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนของสถานีดอนเมือง เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 90

วิธีการประมาณค่าพารามิเตอร์	ค่าประมาณพารามิเตอร์		
	Location (μ)	Scale (σ)	Shape (ξ)
ML	82.0500	25.4354	0.0000
GML	82.0500	25.4241	-0.0719
Bayesian	82.0500	20.2701	0.3960
L-Moments	82.0500	24.8935	-0.0904

ตารางที่ 4.27 แสดงค่าประมาณพารามิเตอร์ของการแจกแจง GPD สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนของสถานีตอนเมือง เมื่อกำหนดให้ค่าพารามิเตอร์บ่งตำแหน่งถูกประมาณด้วยค่าเกณฑ์ในตำแหน่งเปอร์เซ็นต์ไทล์ที่ 90 โดยพบว่าวิธี ML ให้ค่าประมาณของพารามิเตอร์บ่งขนาดสูงสุดที่ 25.4354 ขณะที่วิธี Bayesian ให้ค่าต่ำสุดที่ 20.2701 สำหรับพารามิเตอร์บ่งรูปร่างพบว่าวิธี GML และ L-Moments ให้ค่าประมาณน้อยกว่าศูนย์ แสดงว่าการแจกแจง GPD มีลักษณะแบบหางสั้น

ตารางที่ 4.28 ค่าประมาณพารามิเตอร์สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนของสถานีตอนเมือง เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 95

วิธีการประมาณค่าพารามิเตอร์	ค่าประมาณพารามิเตอร์		
	Location (μ)	Scale (σ)	Shape (ξ)
ML	100.1400	8.8088	0.5772
GML	100.1400	7.8803	0.5667
Bayesian	100.1400	6.3263	1.5270
L-Moments	100.1400	7.8803	0.5667

ตารางที่ 4.28 แสดงค่าประมาณพารามิเตอร์ของการแจกแจง GPD สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนของสถานีตอนเมือง เมื่อกำหนดให้ค่าพารามิเตอร์บ่งตำแหน่งถูกประมาณด้วยค่าเกณฑ์ในตำแหน่งเปอร์เซ็นต์ไทล์ที่ 95 โดยพบว่าวิธี ML ให้ค่าประมาณของพารามิเตอร์บ่งขนาดสูงสุดที่ 8.8088 ขณะที่วิธี Bayesian ให้ค่าต่ำสุดที่ 6.3263 สำหรับพารามิเตอร์บ่งรูปร่างพบว่าทุกวิธี ให้ค่าประมาณมากกว่าศูนย์ แสดงว่าการแจกแจง GPD มีลักษณะแบบหางหนา

ตารางที่ 4.29 ค่าประมาณพารามิเตอร์สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนของสถานีบางนา เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 85

วิธีการประมาณค่าพารามิเตอร์	ค่าประมาณพารามิเตอร์		
	Location (μ)	Scale (σ)	Shape (ξ)
ML	67.8200	29.5666	0.0000
GML	67.8200	33.7716	-0.1042
Bayesian	67.8200	30.9909	0.1217
L-Moments	67.8200	29.7247	0.0179

ตารางที่ 4.29 แสดงค่าประมาณพารามิเตอร์ของการแจกแจง GPD สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนของสถานีบางนา เมื่อกำหนดให้ค่าพารามิเตอร์บ่งตำแหน่งถูกประมาณด้วยค่าเกณฑ์ในตำแหน่งเปอร์เซ็นต์ไทล์ที่ 85 โดยพบว่าวิธี GML ให้ค่าประมาณของพารามิเตอร์บ่งขนาดสูงสุดที่ 33.7716 ขณะที่วิธี ML และ L-Moments ให้ประสิทธิภาพไม่แตกต่างกัน สำหรับพารามิเตอร์บ่งรูปร่างพบว่าวิธี Bayesian และ L-Moments ให้ค่าประมาณมากกว่าศูนย์ แสดงว่าการแจกแจง GPD มีลักษณะแบบหางหนา

ตารางที่ 4.30 ค่าประมาณพารามิเตอร์สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนของสถานีบางนา เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 90

วิธีการประมาณค่าพารามิเตอร์	ค่าประมาณพารามิเตอร์		
	Location (μ)	Scale (σ)	Shape (ξ)
ML	81.4100	28.0224	0.0214
GML	81.4100	32.0992	-0.1027
Bayesian	81.4100	24.1178	0.4654
L-Moments	81.4100	23.8367	0.1664

ตารางที่ 4.30 แสดงค่าประมาณพารามิเตอร์ของการแจกแจง GPD สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนของสถานีบางนา เมื่อกำหนดให้ค่าพารามิเตอร์บ่งตำแหน่งถูกประมาณด้วยค่าเกณฑ์ในตำแหน่งเปอร์เซ็นต์ไทล์ที่ 90 โดยพบว่าวิธี GML ให้ค่าประมาณของพารามิเตอร์บ่งขนาดสูงสุดที่ 32.0992 ขณะที่วิธี L-Moments ให้ค่าต่ำสุดที่ 23.8367 สำหรับพารามิเตอร์บ่งรูปร่างพบว่าวิธี ML, Bayesian และ L-Moments ให้ค่าประมาณมากกว่าศูนย์ แสดงว่าการแจกแจง GPD มีลักษณะแบบหางหนา

ตารางที่ 4.31 ค่าประมาณพารามิเตอร์สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนของสถานีบางนา เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 95

วิธีการประมาณค่าพารามิเตอร์	ค่าประมาณพารามิเตอร์		
	Location (μ)	Scale (σ)	Shape (ξ)
ML	97.4950	47.8233	-0.3916
GML	97.4950	36.9880	-0.1243
Bayesian	97.4950	44.6034	0.3906
L-Moments	97.4950	39.1822	-0.1631

ตารางที่ 4.31 แสดงค่าประมาณพารามิเตอร์ของการแจกแจง GPD สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนของสถานีบางนา เมื่อกำหนดให้ค่าพารามิเตอร์บ่งตำแหน่งถูกประมาณด้วยค่าเกณฑ์ในตำแหน่งเปอร์เซ็นต์ไทล์ที่ 95 โดยพบว่าวิธี ML ให้ค่าประมาณของพารามิเตอร์บ่งขนาดสูงสุดที่ 47.8233 ขณะที่วิธี GML ให้ค่าต่ำสุดที่ 36.9880 สำหรับพารามิเตอร์บ่งรูปร่างพบว่าวิธี ML, GML และ L-Moments ให้ค่าประมาณน้อยกว่าศูนย์ แสดงว่าการแจกแจง GPD มีลักษณะแบบหางสั้น

ตารางที่ 4.32 ค่าประมาณพารามิเตอร์สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนของสถานีคลองเตย เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 85

วิธีการประมาณค่าพารามิเตอร์	ค่าประมาณพารามิเตอร์		
	Location (μ)	Scale (σ)	Shape (ξ)
ML	74.0850	20.9088	0.1325
GML	74.0850	25.1466	-0.0236
Bayesian	74.0850	21.3748	0.2614
L-Moments	74.0850	22.5128	0.0701

ตารางที่ 4.32 แสดงค่าประมาณพารามิเตอร์ของการแจกแจง GPD สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนของสถานีคลองเตย เมื่อกำหนดให้ค่าพารามิเตอร์บ่งตำแหน่งถูกประมาณด้วยค่าเกณฑ์ในตำแหน่งเปอร์เซ็นต์ไทล์ที่ 85 โดยพบว่าวิธี GML ให้ค่าประมาณของพารามิเตอร์บ่งขนาดสูงสุดที่ 25.1466 ขณะที่วิธี ML ให้ค่าต่ำสุดที่ 20.9088 สำหรับพารามิเตอร์บ่งรูปร่างพบว่าวิธี ML, Bayesian และ L-Moments ให้ค่าประมาณมากกว่าศูนย์ แสดงว่าการแจกแจง GPD มีลักษณะแบบหางหนา

ตารางที่ 4.33 ค่าประมาณพารามิเตอร์สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนของสถานีคลองเตย เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 90

วิธีการประมาณค่าพารามิเตอร์	ค่าประมาณพารามิเตอร์		
	Location (μ)	Scale (σ)	Shape (ξ)
ML	82.2600	21.7432	0.1504
GML	82.2600	27.7883	-0.0437
Bayesian	82.2600	22.3065	0.3821
L-Moments	82.2600	24.4936	0.0481

ตารางที่ 4.33 แสดงค่าประมาณพารามิเตอร์ของการแจกแจง GPD สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนของสถานีคลองเตย เมื่อกำหนดให้ค่าพารามิเตอร์บ่งตำแหน่งถูกประมาณด้วยค่าเกณฑ์ในตำแหน่งเปอร์เซ็นต์ไทล์ที่ 90 โดยพบว่าวิธี GML ให้ค่าประมาณของพารามิเตอร์บ่งขนาดสูงสุดที่ 27.7883 ขณะที่วิธี ML ให้ค่าต่ำสุด สำหรับพารามิเตอร์บ่งรูปร่างพบว่าวิธี ML, Bayesian และ L-Moments ให้ค่าประมาณมากกว่าศูนย์ แสดงว่าการแจกแจง GPD มีลักษณะแบบหางหนา

ตารางที่ 4.34 ค่าประมาณพารามิเตอร์สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนของสถานีคลองเตย เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 95

วิธีการประมาณค่าพารามิเตอร์	ค่าประมาณพารามิเตอร์		
	Location (μ)	Scale (σ)	Shape (ξ)
ML	96.7150	8.8225	0.9414
GML	96.7150	10.2535	0.6184
Bayesian	96.7150	12.9624	0.9502
L-Moments	96.7150	10.2535	0.6184

ตารางที่ 4.34 แสดงค่าประมาณพารามิเตอร์ของการแจกแจง GPD สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนของสถานีคลองเตย เมื่อกำหนดให้ค่าพารามิเตอร์บ่งตำแหน่งถูกประมาณด้วยค่าเกณฑ์ในตำแหน่งเปอร์เซ็นต์ไทล์ที่ 95 โดยพบว่าวิธี Bayesian ให้ค่าประมาณของพารามิเตอร์บ่งขนาดสูงสุดที่ 12.9624 ขณะที่วิธี ML ให้ค่าต่ำสุดที่ 8.8225 สำหรับพารามิเตอร์บ่งรูปร่างพบว่าทุกวิธีให้ค่าประมาณมากกว่าศูนย์ แสดงว่าการแจกแจง GPD มีลักษณะแบบหางหนา

4.2.4 ระดับการเกิดซ้ำสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือน

สำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนแต่ละสถานีตรวจวัดระดับน้ำ ทำการหาระดับการเกิดซ้ำที่คาบเวลาการเกิดซ้ำ 2, 3, ..., 10 ปี หรือ 24, 36, ..., 120 เดือน ด้วยการแจกแจงพาวเร่โตวางนัยทั่วไปจากสมการที่ (2.43) แสดงดังตารางที่ 4.35 – 4.46

ตารางที่ 4.35 ระดับการเกิดซ้ำสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนในรอบปีแต่ละวิธีการของ
สถานีศูนย์การประชมแห่งชาติสิริกิติ์ เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 85

ระดับการ เกิดซ้ำ	ปริมาณ น้ำฝนสูงสุด รายเดือนใน รอบปี	ML	GML	Bayesian	L-Moments
2	174.3	107.2239	109.6919	112.0579	106.9453
3	141.5	120.2577	122.2389	128.5160	120.0923
4	188.3	129.6007	130.8800	140.9159	129.5774
5	74.3	136.9026	137.4372	150.9697	137.0257
6	54.4	142.9045	142.7025	159.4782	143.1711
7	118.0	148.0045	147.0903	166.8851	148.4094
8	81.7	152.4410	150.8446	173.4635	152.9785
9	132.5	156.3690	154.1206	179.3939	157.0332
10	87.2	159.8942	157.0232	184.8026	160.6798
MAPE	–	60.5567%	59.3494%	74.1627%	60.9287%

หมายเหตุ ตัวเลขที่ขีดเส้นแสดงค่า MAPE ที่ต่ำที่สุด

จากตารางที่ 4.35 เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 85 พบว่า เมื่อพิจารณาค่า MAPE สำหรับวิธี GML ให้ค่าต่ำที่สุดที่ 59.3494% แสดงถึงความแม่นยำที่สูงกว่าวิธีอื่น รองลงมาคือ ML และ L-Moments ขณะที่ Bayesian มีค่า MAPE สูงสุดที่ 74.1627% สรุปได้ว่าวิธี GML อาจเป็นทางเลือกที่ดีที่สุดในการประมาณค่าปริมาณน้ำฝนสูงสุดรายเดือนสำหรับสถานีศูนย์การประชมแห่งชาติสิริกิติ์

ตารางที่ 4.36 ระดับการเกิดซ้ำสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนในรอบปีแต่ละวิธีการของ
สถานีศูนย์การประชมแห่งชาติสิริกิติ์ เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 90

ระดับการ เกิดซ้ำ	ปริมาณ น้ำฝนสูงสุด รายเดือนใน รอบปี	ML	GML	Bayesian	L-Moments
2	174.3	104.8429	109.6773	108.5410	103.5381
3	141.5	116.8390	121.9463	125.0015	115.3048
4	188.3	125.9031	130.4098	138.6440	124.3872
5	74.3	133.2678	136.8401	150.5126	131.8838
6	54.4	139.5110	142.0083	161.1357	138.3188
7	118.0	144.9535	146.3188	170.8235	143.9870
8	81.7	149.7929	150.0094	179.7767	149.0721
9	132.5	154.1602	153.2317	188.1335	153.6969
10	87.2	158.1470	156.0882	195.9940	157.9478
MAPE	—	58.9032%	58.7901%	78.4555%	58.4925%

หมายเหตุ ตัวเลขที่ขีดเส้นแสดงค่า MAPE ที่ต่ำที่สุด

จากตารางที่ 4.36 เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 90 พบว่า เมื่อพิจารณาค่า MAPE สำหรับวิธี L-Moments ให้ค่าต่ำที่สุดที่ 58.4925% แสดงถึงความแม่นยำที่สูงกว่าวิธีอื่น รองลงมาคือ GML และ ML ขณะที่ Bayesian มีค่า MAPE สูงสุดที่ 78.4555% สรุปได้ว่าวิธี L-Moments อาจเป็นทางเลือกที่ดีที่สุดในการประมาณค่าปริมาณน้ำฝนสูงสุดรายเดือนสำหรับสถานี ศูนย์การประชมแห่งชาติสิริกิติ์

ตารางที่ 4.37 ระดับการเกิดซ้ำสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนในรอบปีแต่ละวิธีการของ
สถานีศูนย์การประชมแห่งชาติสิริกิติ์ เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 95

ระดับการ เกิดซ้ำ	ปริมาณ น้ำฝนสูงสุด รายเดือนใน รอบปี	ML	GML	Bayesian	L-Moments
2	174.3	102.9089	102.4532	104.2608	101.4089
3	141.5	120.2540	119.1308	129.1694	116.5958
4	188.3	131.8198	130.4892	150.3840	127.5792
5	74.3	140.3899	139.0377	169.2164	136.2195
6	54.4	147.1427	145.8572	186.3449	143.3587
7	118.0	152.6828	151.5097	202.1751	149.4511
8	81.7	157.3600	156.3237	216.9727	154.7707
9	132.5	161.3939	160.5074	230.9230	159.4956
10	87.2	164.9310	164.2010	244.1613	163.7482
MAPE	-	64.2609%	63.5732%	103.3908%	62.5312%

หมายเหตุ ตัวเลขที่ขีดเส้นแสดงค่า MAPE ที่ต่ำที่สุด

จากตารางที่ 4.37 เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 95 พบว่า เมื่อพิจารณาค่า MAPE สำหรับวิธี L-Moments ให้ค่าต่ำที่สุดที่ 62.5312% แสดงถึงความแม่นยำที่สูงกว่าวิธีอื่น รองลงมาคือ GML และ ML ขณะที่ Bayesian มีค่า MAPE สูงสุดที่ 103.3908% สรุปได้ว่าวิธี L-Moments อาจเป็นทางเลือกที่ดีที่สุดในการประมาณค่าปริมาณน้ำฝนสูงสุดรายเดือนสำหรับสถานีศูนย์การประชมแห่งชาติสิริกิติ์

เมื่อพิจารณາตารางที่ 4.35-4.37 ในภาพรวม พบว่า วิธี L-Moments เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 90 ให้ค่า MAPE ที่ต่ำที่สุดเท่ากับ 58.4925% แสดงถึงความแม่นยำที่สูงกว่าวิธีอื่น ในขณะที่วิธี Bayesian ไม่ว่าจะกำหนดค่าเกณฑ์ในตำแหน่งเปอร์เซ็นต์ไทล์ที่ 85, 90 หรือ 95 ทำให้ค่า MAPE มีค่าสูงกว่าวิธีอื่นเสมอ หมายความว่า วิธี Bayesian อาจเป็นทางเลือกที่ไม่เหมาะสมสำหรับข้อมูลปริมาณน้ำฝนสูงสุดของสถานีศูนย์การประชมแห่งชาติสิริกิติ์ สรุปได้ว่าวิธี L-Moments เป็นทางเลือกที่ดีที่สุดในการประมาณค่าปริมาณน้ำฝนสูงสุดรายเดือนสำหรับสถานีศูนย์การประชมแห่งชาติสิริกิติ์

ตารางที่ 4.38 ระดับการเกิดซ้ำสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนในรอบปีแต่ละวิธีการของ
สถานีดอนเมือง เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 85

ระดับการ เกิดซ้ำ	ปริมาณ น้ำฝนสูงสุด รายเดือนใน รอบปี	ML	GML	Bayesian	L-Moments
2	107.7	102.0505	103.6310	103.8117	103.0915
3	108.9	111.8097	113.1873	115.1533	112.3415
4	83.9	118.7625	119.7989	123.5550	118.7008
5	93.2	124.1717	124.8331	130.2824	123.5202
6	65.0	128.6020	128.8862	135.9198	127.3860
7	78.6	132.3552	132.2714	140.7871	130.6049
8	62.2	135.6119	135.1734	145.0795	133.3570
9	74.9	138.4888	137.7098	148.9255	135.7569
10	53	141.0657	139.9604	152.4140	137.8820
MAPE	–	68.6697%	68.4744%	78.2538%	66.5999%

หมายเหตุ ตัวเลขที่ขีดเส้นแสดงค่า MAPE ที่ต่ำที่สุด

จากตารางที่ 4.38 เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 85 พบว่า เมื่อพิจารณาค่า MAPE สำหรับวิธี L-Moments ให้ค่าต่ำที่สุดที่ 66.5999% แสดงถึงความแม่นยำที่สูงกว่าวิธีอื่น รองลงมาคือ GML และ ML ขณะที่ Bayesian มีค่า MAPE สูงสุดที่ 78.2538% สรุปได้ว่าวิธี L-Moments อาจเป็นทางเลือกที่ดีที่สุดในการประมาณค่าปริมาณน้ำฝนสูงสุดรายเดือนสำหรับสถานี ดอนเมือง

ตารางที่ 4.39 ระดับการเกิดซ้ำสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนในรอบปีแต่ละวิธีการของ
สถานีดอนเมือง เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 90

ระดับการ เกิดซ้ำ	ปริมาณ น้ำฝนสูงสุด รายเดือนใน รอบปี	ML	GML	Bayesian	L-Moments
2	107.7	104.3179	103.6216	103.6091	103.0031
3	108.9	114.6311	113.1611	116.0113	112.1595
4	83.9	121.9484	119.7628	125.9180	118.4554
5	93.2	127.6242	124.7902	134.3046	123.2273
6	65	132.2616	128.8383	141.6500	127.0555
7	78.6	136.1825	132.2198	148.2292	130.2432
8	62.2	139.5789	135.1189	154.2165	132.9689
9	74.9	142.5748	137.6530	159.7302	135.3459
10	53	145.2547	139.9017	164.8549	137.4509
MAPE	–	72.9167%	68.4168%	87.0294%	66.1947%

หมายเหตุ ตัวเลขที่ขีดเส้นแสดงค่า MAPE ที่ต่ำที่สุด

จากตารางที่ 4.39 เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 90 พบว่า เมื่อพิจารณาค่า MAPE สำหรับวิธี L-Moments ให้ค่าต่ำที่สุดที่ 66.1947% แสดงถึงความแม่นยำที่สูงกว่าวิธีอื่น รองลงมาคือ GML และ ML ขณะที่ Bayesian มีค่า MAPE สูงสุดที่ 87.0294% สรุปได้ว่าวิธี L-Moments อาจเป็นทางเลือกที่ดีที่สุดในการประมาณค่าปริมาณน้ำฝนสูงสุดรายเดือนสำหรับสถานี ดอนเมือง

ตารางที่ 4.40 ระดับการเกิดซ้ำสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนในรอบปีแต่ละวิธีการของ
สถานีดอนเมือง เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 95

ระดับการ เกิดซ้ำ	ปริมาณ น้ำฝนสูงสุด รายเดือนใน รอบปี	ML	GML	Bayesian	L-Moments
2	107.7	101.8336	101.6536	101.6646	101.6536
3	108.9	106.3043	105.6366	107.0992	105.6366
4	83.9	110.1743	109.0721	113.6660	109.0721
5	93.2	113.6514	112.1505	121.2280	112.1505
6	65	116.8442	114.9713	129.6909	114.9713
7	78.6	119.8187	117.5945	138.9848	117.5945
8	62.2	122.6180	120.0596	149.0549	120.0596
9	74.9	125.2728	122.3943	159.8567	122.3943
10	53	127.8054	124.6190	171.3531	124.6190
MAPE	-	55.4247%	52.9999%	80.6146%	52.9999%

หมายเหตุ ตัวเลขที่ขีดเส้นแสดงค่า MAPE ที่ต่ำที่สุด

จากตารางที่ 4.40 เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 95 พบว่า เมื่อพิจารณาค่า MAPE สำหรับวิธี GML และ L-Moments ให้ค่าต่ำที่สุดที่ 52.9999% แสดงถึงความแม่นยำที่สูงกว่าวิธีอื่น ในขณะที่ Bayesian มีค่า MAPE สูงสุดที่ 80.6146% สรุปได้ว่าวิธี GML และ L-Moments อาจเป็นทางเลือกที่ดีที่สุดในการประมาณค่าปริมาณน้ำฝนสูงสุดรายเดือนสำหรับสถานีดอนเมือง

เมื่อพิจารณาตารางที่ 4.38-4.40 ในภาพรวม พบว่า วิธี GML และ L-Moments เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 95 ให้ค่า MAPE ที่ต่ำที่สุดเท่ากับ 52.9999% แต่วิธี L-Moments ให้ค่า MAPE ที่ต่ำสุดสำหรับทุก ๆ ตำแหน่งเปอร์เซ็นต์ไทล์ แสดงถึงความแม่นยำที่สูงกว่าวิธีอื่น ในขณะที่วิธี Bayesian ไม่ว่าจะกำหนดค่าเกณฑ์ในตำแหน่งเปอร์เซ็นต์ไทล์ที่ 85, 90 หรือ 95 ทำให้ค่า MAPE มีค่าสูงกว่าวิธีอื่นเสมอ หมายความว่า วิธี Bayesian อาจเป็นทางเลือกที่ไม่เหมาะสมสำหรับข้อมูลปริมาณน้ำฝนสูงสุดของสถานีดอนเมือง สรุปได้ว่าวิธี L-Moments เป็นทางเลือกที่ดีที่สุด รองลงมาคือวิธี GML สำหรับการประมาณค่าปริมาณน้ำฝนสูงสุดรายเดือนสำหรับสถานีดอนเมือง

ตารางที่ 4.41 ระดับการเกิดซ้ำสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนในรอบปีแต่ละวิธีการของ
สถานีบางนา เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 85

ระดับการ เกิดซ้ำ	ปริมาณ น้ำฝนสูงสุด รายเดือนใน รอบปี	ML	GML	Bayesian	L-Moments
2	91.6	105.6928	108.3168	110.2530	106.3351
3	92.9	117.6810	120.0497	125.1484	118.7117
4	119	126.1868	128.0787	136.1796	127.5477
5	110.9	132.7844	134.1429	145.0108	134.4328
6	57.7	138.1750	138.9942	152.4096	140.0788
7	88	142.7327	143.0245	158.7969	144.8668
8	120.9	146.6808	146.4639	164.4292	149.0251
9	126	150.1632	149.4581	169.4751	152.7012
10	129.8	153.2784	152.1056	174.0515	155.9961
MAPE	-	36.4544%	37.3809%	49.9405%	38.2558%

หมายเหตุ ตัวเลขที่ขีดเส้นแสดงค่า MAPE ที่ต่ำที่สุด

จากตารางที่ 4.41 เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 85 พบว่า เมื่อพิจารณาค่า MAPE สำหรับวิธี ML ให้ค่าต่ำที่สุดที่ 36.4544% แสดงถึงความแม่นยำที่สูงกว่าวิธีอื่น รองลงมาคือ GML และ L-Moments ขณะที่ Bayesian มีค่า MAPE สูงสุดที่ 49.9405% สรุปได้ว่าวิธี ML อาจเป็นทางเลือกที่ดีที่สุดในการประมาณค่าปริมาณน้ำฝนสูงสุดรายเดือนสำหรับสถานีบางนา

ตารางที่ 4.42 ระดับการเกิดซ้ำสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนในรอบปีแต่ละวิธีการของ
สถานีบางนา เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 90

ระดับการ เกิดซ้ำ	ปริมาณ น้ำฝนสูงสุด รายเดือนใน รอบปี	ML	GML	Bayesian	L-Moments
2	91.6	106.1735	108.2856	108.3737	103.8747
3	92.9	117.8003	119.9374	122.7567	115.4408
4	119	126.1110	127.9151	133.7779	124.1335
5	110.9	132.5925	133.9428	142.8261	131.1684
6	57.7	137.9112	138.7663	150.5598	137.1135
7	88	142.4244	142.7747	157.3479	142.2826
8	120.9	146.3459	146.1959	163.4192	146.8687
9	126	149.8141	149.1750	168.9263	150.9994
10	129.8	152.9240	151.8095	173.9763	154.7636
MAPE	–	36.3191%	37.1780%	48.2965%	35.5692%

หมายเหตุ ตัวเลขที่ขีดเส้นแสดงค่า MAPE ที่ต่ำที่สุด

จากตารางที่ 4.42 เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 90 พบว่า เมื่อพิจารณาค่า MAPE สำหรับวิธี L-Moments ให้ค่าต่ำที่สุดที่ 35.5692% แสดงถึงความแม่นยำที่สูงกว่าวิธีอื่น รองลงมาคือ ML และ GML ขณะที่ Bayesian มีค่า MAPE สูงสุดที่ 48.2965% สรุปได้ว่าวิธี L-Moments อาจเป็นทางเลือกที่ดีที่สุดในการประมาณค่าปริมาณน้ำฝนสูงสุดรายเดือนสำหรับสถานีบางนา

ตารางที่ 4.43 ระดับการเกิดซ้ำสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนในรอบปีแต่ละวิธีการของ
สถานีบางนา เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 95

ระดับการ เกิดซ้ำ	ปริมาณ น้ำฝนสูงสุด รายเดือนใน รอบปี	ML	GML	Bayesian	L-Moments
2	91.6	105.9102	104.1629	104.2768	104.5336
3	92.9	122.6045	118.4611	121.5953	119.4564
4	119	132.9408	128.1778	136.0283	129.4616
5	110.9	140.1936	135.4790	148.6362	136.9053
6	57.7	145.6668	141.2961	159.9576	142.7894
7	88	149.9991	146.1126	170.3103	147.6296
8	120.9	153.5462	150.2110	179.9000	151.7252
9	126	156.5246	153.7699	188.8691	155.2644
10	129.8	159.0750	156.9097	197.3206	158.3733
MAPE	-	42.4909%	38.7991%	57.1708%	40.1013%

หมายเหตุ ตัวเลขที่ขีดเส้นแสดงค่า MAPE ที่ต่ำที่สุด

จากตารางที่ 4.43 เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 95 พบว่า เมื่อพิจารณาค่า MAPE สำหรับวิธี GML ให้ค่าต่ำที่สุดที่ 38.7991% แสดงถึงความแม่นยำที่สูงกว่าวิธีอื่น รองลงมาคือ L-Moments และ ML ขณะที่ Bayesian มีค่า MAPE สูงสุดที่ 57.1708% สรุปได้ว่าวิธี GML อาจเป็นทางเลือกที่ดีที่สุดในการประมาณค่าปริมาณน้ำฝนสูงสุดรายเดือนสำหรับสถานีบางนา

เมื่อพิจารณตารางที่ 4.41 - 4.43 ในภาพรวม พบว่า วิธี L-Moments เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 90 ให้ค่า MAPE ที่ต่ำที่สุดเท่ากับ 35.5692% แต่วิธี L-Moments แสดงถึงความแม่นยำที่สูงกว่าวิธีอื่น ในขณะที่วิธี Bayesian สำหรับค่าเกณฑ์ทุกเปอร์เซ็นต์ไทล์ ทำให้ค่า MAPE สูงกว่าวิธีอื่นเสมอ หมายความว่า วิธี Bayesian อาจเป็นทางเลือกที่ไม่เหมาะสมสำหรับข้อมูลปริมาณน้ำฝนสูงสุด สรุปได้ว่าวิธี L-Moments เป็นทางเลือกที่ดีที่สุดสำหรับการประมาณค่าปริมาณน้ำฝนสูงสุดรายเดือนสำหรับสถานีบางนา

ตารางที่ 4.44 ระดับการเกิดซ้ำสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนในรอบปีแต่ละวิธีการของ
สถานีคลองเตย เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 85

ระดับการ เกิดซ้ำ	ปริมาณ น้ำฝนสูงสุด รายเดือนใน รอบปี	ML	GML	Bayesian	L-Moments
2	165.5	103.2756	105.8149	105.2247	104.2564
3	132	113.5970	115.6607	119.1455	114.3851
4	190.3	121.2639	122.5896	130.5727	121.7481
5	152.5	127.4154	127.9318	140.4436	127.5624
6	62.2	132.5784	132.2759	149.2287	132.3810
7	103.4	137.0421	135.9343	157.2029	136.5034
8	108.4	140.9831	139.0926	164.5428	140.1105
9	130.3	144.5177	141.8702	171.3698	143.3204
10	74.8	147.7265	144.3483	177.7713	146.2142
MAPE	–	43.1573%	41.6036%	55.3750%	42.4768%

หมายเหตุ ตัวเลขที่ขีดเส้นแสดงค่า MAPE ที่ต่ำที่สุด

จากตารางที่ 4.44 เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 85 พบว่า เมื่อพิจารณาค่า MAPE สำหรับวิธี GML ให้ค่าต่ำที่สุดที่ 41.6036% แสดงถึงความแม่นยำที่สูงกว่าวิธีอื่น รองลงมาคือ L-Moments และ ML ขณะที่ Bayesian มีค่า MAPE สูงสุดที่ 55.3750% สรุปได้ว่าวิธี ML อาจเป็นทางเลือกที่ดีที่สุดในการประมาณค่าปริมาณน้ำฝนสูงสุดรายเดือนสำหรับสถานีคลองเตย

ตารางที่ 4.45 ระดับการเกิดซ้ำสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนในรอบปีแต่ละวิธีการของ
สถานีคลองเตย เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 90

ระดับการ เกิดซ้ำ	ปริมาณ น้ำฝนสูงสุด รายเดือนใน รอบปี	ML	GML	Bayesian	L-Moments
2	165.5	102.6056	106.1282	103.9769	104.1614
3	132	112.9754	116.8768	116.4603	114.6217
4	190.3	120.7261	124.3884	126.4277	122.1681
5	152.5	126.9732	130.1501	134.8631	128.0939
6	62.2	132.2354	134.8163	142.2495	132.9831
7	103.4	136.7985	138.7325	148.8639	137.1505
8	108.4	140.8377	142.1037	154.8823	140.7854
9	130.3	144.4684	145.0610	160.4237	144.0112
10	74.8	147.7712	147.6935	165.5734	146.9122
MAPE	–	43.2183%	43.0457%	50.4551%	42.8088%

หมายเหตุ ตัวเลขที่ขีดเส้นแสดงค่า MAPE ที่ต่ำที่สุด

จากตารางที่ 4.45 เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 90 พบว่า เมื่อพิจารณาค่า MAPE สำหรับวิธี L-Moments ให้ค่าต่ำที่สุดที่ 42.8088% แสดงถึงความแม่นยำที่สูงกว่าวิธีอื่น รองลงมาคือ GML และ ML ขณะที่ Bayesian มีค่า MAPE สูงสุดที่ 50.4551% สรุปได้ว่าวิธี L-Moments อาจเป็นทางเลือกที่ดีที่สุดในการประมาณค่าปริมาณน้ำฝนสูงสุดรายเดือนสำหรับสถานี คลองเตย

ตารางที่ 4.46 ระดับการเกิดซ้ำสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนในรอบปีแต่ละวิธีการของ
สถานีคลองเตย เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 95


ระดับการ เกิดซ้ำ	ปริมาณ น้ำฝนสูงสุด รายเดือนใน รอบปี	ML	GML	Bayesian	L-Moments
2	165.5	98.4698	98.6939	97.7186	98.6939
3	132	103.6411	103.9829	103.4108	103.9829
4	190.3	108.7104	108.6264	114.5644	108.6264
5	152.5	113.7051	112.8422	133.0388	112.8422
6	62.2	118.6412	116.7458	160.7024	116.7458
7	103.4	123.5291	120.4075	199.4310	120.4075
8	108.4	128.3761	123.8742	251.1062	123.8742
9	130.3	133.1876	127.1789	317.6146	127.1789
10	74.8	137.9678	130.3461	400.8476	130.3461
MAPE	-	38.4001%	36.1763%	119.7453%	36.1763%

หมายเหตุ ตัวเลขที่ขีดเส้นแสดงค่า MAPE ที่ต่ำที่สุด

จากตารางที่ 4.46 เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 95 พบว่า เมื่อพิจารณาค่า MAPE สำหรับวิธี GML และ L-Moments ให้ค่าต่ำที่สุดที่ 36.1763% แสดงถึงความแม่นยำที่สูงกว่าวิธีอื่น ในขณะที่ Bayesian มีค่า MAPE สูงสุดที่ 119.7453% สรุปได้ว่าวิธี GML และ L-Moments อาจเป็นทางเลือกที่ดีที่สุดในการประมาณค่าปริมาณน้ำฝนสูงสุดรายเดือนสำหรับสถานีคลองเตย


เมื่อพิจารณาตารางที่ 4.44-4.46 ในภาพรวม พบว่า วิธี GML และ L-Moments เมื่อกำหนดค่าเกณฑ์เท่ากับเปอร์เซ็นต์ไทล์ที่ 95 ให้ค่า MAPE ที่ต่ำที่สุดเท่ากับ 36.1763% แต่วิธี L-Moments ให้ค่า MAPE ที่ต่ำสุดสำหรับทุก ๆ ตำแหน่งเปอร์เซ็นต์ไทล์ แสดงถึงความแม่นยำที่สูงกว่าวิธีอื่น ในขณะที่วิธี Bayesian ไม่ว่าจะกำหนดค่าเกณฑ์ในตำแหน่งเปอร์เซ็นต์ไทล์ที่ 85, 90 หรือ 95 ทำให้ค่า MAPE มีค่าสูงกว่าวิธีอื่นเสมอ หมายความว่า วิธี Bayesian อาจเป็นทางเลือกที่ไม่เหมาะสมสำหรับข้อมูลปริมาณน้ำฝนสูงสุดของสถานีคลองเตย สรุปได้ว่าวิธี L-Moments เป็นทางเลือกที่ดีที่สุด รองลงมาคือวิธี GML สำหรับการประมาณค่าปริมาณน้ำฝนสูงสุดรายเดือนสำหรับสถานีคลองเตย

เมื่อพิจารณาตารางที่ 4.35–4.46 ในภาพรวม สรุปได้ว่า วิธี L-Moments มีประสิทธิภาพดีกว่าวิธีการอื่นสำหรับทุกสถานีตรวจวัดระดับน้ำ เนื่องจากค่า MAPE ต่ำที่สุด และค่าระดับการเกิดซ้ำของแต่ละสถานีตรวจวัดระดับน้ำ ที่ให้ค่า MAPE ต่ำสุดแสดงดังรูปที่ 4.20




รูปที่ 4.20 กราฟระดับการเกิดซ้ำของปริมาณน้ำฝนสูงสุดรายเดือน ตามรอบปีการเกิด จำแนกรายสถานีตรวจวัดระดับน้ำ

จากรูปที่ 4.20 พบว่า ระดับการเกิดซ้ำมีแนวโน้มเพิ่มขึ้นตามคาบเวลาการเกิดซ้ำที่เพิ่มขึ้นสำหรับทุกสถานี เมื่อคัดเลือกตัวแบบและวิธีการที่เหมาะสมกับข้อมูลปริมาณน้ำฝนสูงสุดแต่ละสถานี จึงพิจารณาความเหมาะสมจากแผนภาพความน่าจะเป็นต่อความน่าจะเป็น (Probability-Probability Plot: PP Plot) แผนภาพควอไทล์ต่อควอไทล์ (Quantile-Quantile Plot: QQ Plot) และแผนภาพความหนาแน่นของความน่าจะเป็น (Probability Density Plot) ดังรูปที่ 4.21 – 4.24




รูปที่ 4.21 แผนภาพ Diagnostic Plot ข้อมูลปริมาณน้ำฝนสูงสุดรายเดือน สถานีศูนย์การประชมแห่งชาตีสิริกิติ์

จากรูปที่ 4.21 พบว่า กราฟการวินิจฉัยสำหรับปริมาณน้ำฝนสูงสุดรายเดือนที่สถานีศูนย์การประชุมชนแห่งชาติสิริกิติ์แสดงการเปรียบเทียบระหว่างค่าจากแบบจำลองกับข้อมูลจริงผ่าน PP Plot, QQ Plot, และ Density Plot โดย PP Plot แสดงว่าค่าความน่าจะเป็นของแบบจำลองสอดคล้องกับค่าจากข้อมูลจริงค่อนข้างดี เนื่องจากจุดกระจายอยู่ใกล้เส้นทแยงมุม QQ Plot แสดงให้เห็นว่าค่าควไทล์ของแบบจำลองและข้อมูลจริงมีแนวโน้มไปในทิศทางเดียวกัน แม้จะมีความแตกต่างเล็กน้อยที่ปลายค่ามากที่สุด ขณะที่ Density Plot แสดงการแจกแจงของข้อมูลจริง (เส้นดำ) เทียบกับแบบจำลอง (เส้นประสีน้ำเงิน) พบว่าแบบจำลองสามารถสะท้อนแนวโน้มของข้อมูลจริงได้ดี สรุปได้ว่าแบบจำลองที่ใช้สามารถอธิบายการกระจายของปริมาณน้ำฝนสูงสุดรายเดือนได้ดี แต่ยังคงมีความคลาดเคลื่อนในบางช่วงของข้อมูล




รูปที่ 4.22 แผนภาพ Diagnostic Plot ข้อมูลปริมาณน้ำฝนสูงสุดรายเดือน สถานีดอนเมือง

จากรูปที่ 4.22 พบว่า กราฟการวินิจฉัยสำหรับปริมาณน้ำฝนสูงสุดรายเดือนที่สถานีดอนเมืองแสดงการเปรียบเทียบระหว่างค่าจากแบบจำลองกับข้อมูลจริงผ่าน PP Plot, QQ Plot, และ Density Plot โดย PP Plot แสดงว่าค่าความน่าจะเป็นของแบบจำลองสอดคล้องกับค่าจากข้อมูลจริงค่อนข้างดี เนื่องจากจุดกระจายอยู่ใกล้เส้นทแยงมุม QQ Plot แสดงให้เห็นว่าค่าควไทล์ของแบบจำลองและข้อมูลจริงมีแนวโน้มไปในทิศทางเดียวกัน แม้จะมีความแตกต่างเล็กน้อยที่ปลายค่ามากที่สุด ขณะที่ Density Plot แสดงการแจกแจงของข้อมูลจริง (เส้นดำ) เทียบกับแบบจำลอง (เส้นประสีน้ำเงิน) พบว่าแบบจำลองสะท้อนแนวโน้มของข้อมูลจริงได้ยังไม่ดีมากนัก สรุปได้ว่าแบบจำลองที่ใช้สามารถอธิบายการกระจายของปริมาณน้ำฝนสูงสุดรายเดือนได้ค่อนข้างดี แต่ยังคงมีความคลาดเคลื่อนในบางช่วงของข้อมูล



รูปที่ 4.23 แผนภาพ Diagnostic Plot ข้อมูลปริมาณน้ำฝนสูงสุดรายเดือน สถานีบางนา

จากรูปที่ 4.23 พบว่า กราฟการวินิจฉัยสำหรับปริมาณน้ำฝนสูงสุดรายเดือนที่สถานีบางนา การเปรียบเทียบระหว่างค่าจากแบบจำลองกับข้อมูลจริงผ่าน PP Plot, QQ Plot, และ Density Plot โดย PP Plot แสดงว่าค่าความน่าจะเป็นของแบบจำลองสอดคล้องกับค่าจากข้อมูลจริงค่อนข้างดี เนื่องจากจุดกระจายอยู่ใกล้เส้นทแยงมุม QQ Plot แสดงให้เห็นว่าค่าควอไทล์ของแบบจำลองและข้อมูลจริงมีแนวโน้มไปในทิศทางเดียวกัน แม้จะมีความแตกต่างเล็กน้อยที่ปลายค่ามากที่สุด ขณะที่ Density Plot แสดงการแจกแจงของข้อมูลจริง (เส้นดำ) เทียบกับแบบจำลอง (เส้นประสีน้ำเงิน) พบว่าแบบจำลองสามารถสะท้อนแนวโน้มของข้อมูลจริงได้ดี สรุปได้ว่าแบบจำลองที่ใช้สามารถอธิบายการกระจายของปริมาณน้ำฝนสูงสุดรายเดือนได้ดี แต่ยังคงมีความคลาดเคลื่อนในบางช่วงของข้อมูล



รูปที่ 4.24 แผนภาพ Diagnostic Plot ข้อมูลปริมาณน้ำฝนสูงสุดรายเดือน สถานีคลองเตย

จากรูปที่ 4.24 พบว่า กราฟการวินิจฉัยสำหรับปริมาณน้ำฝนสูงสุดรายเดือนที่สถานีศูนย์คลองเตยการเปรียบเทียบระหว่างค่าจากแบบจำลองกับข้อมูลจริงผ่าน PP Plot, QQ Plot, และ Density Plot โดย PP Plot แสดงว่าค่าความน่าจะเป็นของแบบจำลองสอดคล้องกับค่าจากข้อมูล

จริงค่อนข้างดี เนื่องจากจุดกระจายอยู่ใกล้เส้นทแยงมุม QQ Plot แสดงให้เห็นว่าค่าควอไทล์ของแบบจำลองและข้อมูลจริงมีแนวโน้มไปในทิศทางเดียวกัน แม้จะมีความแตกต่างเล็กน้อยที่ปลายค่ามากที่สุด ขณะที่ Density Plot แสดงการแจกแจงของข้อมูลจริง (เส้นดำ) เทียบกับแบบจำลอง (เส้นประสีน้ำเงิน) พบว่าแบบจำลองสามารถสะท้อนแนวโน้มของข้อมูลจริงได้ดี สรุปได้ว่าแบบจำลองที่ใช้สามารถอธิบายการกระจายของปริมาณน้ำฝนสูงสุดรายเดือนได้ดี แต่ยังคงมีความคลาดเคลื่อนในบางช่วงของข้อมูล

เมื่อพิจารณาแผนภาพจากรูปที่ 4.21-4.24 ในภาพรวม PP Plot, QQ Plot และ Density Plot จะเห็นว่า ข้อมูลที่นำมาวิเคราะห์การแจกแจงมีลักษณะการกระจายใกล้เคียงกับการแจกแจงที่ทำการทดสอบ โดยที่ข้อมูลสถานีบางนาซึ่งมีค่า MAPE ที่ต่ำกว่าสถานีอื่น ๆ ลักษณะแผนภาพ PP Plot ของข้อมูลเป็นไปตามเส้นทแยงมุม เช่นเดียวกับแผนภาพ QQ Plot ส่วนแผนภาพ Density Plot ก็จะทำให้เห็นว่า ลักษณะการกระจายของข้อมูลจริงเป็นไปตามลักษณะการกระจายของเส้นโค้งของการแจกแจงที่ทดสอบ ในขณะที่ข้อมูลสถานีศูนย์การประชุมแห่งชาติสิริกิติ์ซึ่งมีค่า MAPE มากกว่าสถานีอื่น ๆ มีลักษณะแผนภาพ PP Plot ของข้อมูลเป็นไปตามเส้นทแยงมุม แต่ในขณะที่ QQ Plot มีบางจุดที่ไม่เป็นไปตามเส้นทแยงมุม ในขณะที่ Density Plot มีลักษณะการกระจายของข้อมูลจริงที่ไม่เป็นไปตามลักษณะของการกระจายของเส้นโค้งเท่าที่ควรเมื่อเปรียบเทียบกับสถานีอื่น ๆ

บทที่ 5

สรุปผลการวิจัยและข้อเสนอแนะ

จากการศึกษาและเปรียบเทียบตัวแบบที่ได้จากข้อมูลปริมาณน้ำฝนสูงสุดรายปีด้วยการแจกแจงค่าสุดขีดวงนัยทั่วไป และข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนด้วยการแจกแจงพาราโลตวงนัยทั่วไป สำหรับสถานีศูนย์การประชุมชนแห่งชาติสิริกิติ์ สถานีคอนเมือง สถานีบางนา และสถานีคลองเตย เมื่อใช้วิธีการประมาณค่าพารามิเตอร์ทั้ง 4 วิธี ประกอบด้วยวิธีภาวะน่าจะเป็นสูงสุด (ML) วิธีภาวะน่าจะเป็นสูงสุดทั่วไป (GML) วิธีของเบย์ส์ (Bayesian) และวิธีโมเมนต์เชิงเส้น (L-Moments) โดยใช้ค่าเฉลี่ยความคลาดเคลื่อนกำลังสอง (MSE) สำหรับข้อมูลที่ได้จากการจำลอง และค่าเปอร์เซ็นต์ข้อผิดพลาดเฉลี่ยสัมบูรณ์ (MAPE) ต่ำสุดสำหรับข้อมูลปริมาณน้ำฝนสูงสุด พร้อมทั้งหาระดับการเกิดซ้ำสำหรับคาบเวลาการเกิดซ้ำ 2, 3, ..., 10 ปี หรือ 24, 36, ..., 120 เดือน สามารถสรุปการวิจัยและข้อเสนอแนะได้ ดังนี้

5.1 สรุปผลการวิจัยสำหรับข้อมูลจำลอง

5.1.1 ข้อมูลจำลอง จากการแจกแจงค่าสุดขีดวงนัยทั่วไป

จากการศึกษาการจำลองข้อมูลจากการแจกแจงค่าสุดขีดวงนัยทั่วไป เมื่อกำหนดให้ค่าพารามิเตอร์บ่งตำแหน่งเท่ากับ 3 พารามิเตอร์บ่งขนาดเท่ากับ 1 และพารามิเตอร์บ่งรูปร่างแตกต่างกัน 3 รูปแบบ พบว่า กรณีค่าพารามิเตอร์บ่งรูปร่างน้อยกว่าศูนย์ ซึ่งทำให้วิธี ML นั้นมีประสิทธิภาพสูงสุดเนื่องจากค่า MSE ต่ำสุด กรณีค่าพารามิเตอร์บ่งรูปร่างเท่ากับศูนย์ ซึ่งทำให้วิธี GML นั้นมีประสิทธิภาพสูงสุดเนื่องจากค่า MSE ต่ำสุด ในขณะที่วิธี L-Moments นั้นให้ประสิทธิภาพที่ดีในบางกรณี และกรณีค่าพารามิเตอร์บ่งรูปร่างมากกว่าศูนย์ ซึ่งทำให้วิธี L-Moments นั้นมีประสิทธิภาพสูงสุดเนื่องจากค่า MSE ต่ำสุด จึงสรุปได้ว่า วิธี ML เหมาะสำหรับการแจกแจงค่าสุดขีดวงนัยทั่วไปที่ข้อมูลมีรูปแบบการแจกแจงไวล์บูล วิธี GML เหมาะสำหรับข้อมูลที่มีรูปแบบการแจกแจงกัมเบล และวิธี L-Moments เหมาะสำหรับข้อมูลที่มีรูปแบบการแจกแจงพีรีเซท

5.1.2 ข้อมูลจำลอง จากการแจกแจงพาราโลตวงนัยทั่วไป

จากการศึกษาการจำลองข้อมูลจากการแจกแจงพาราโลตวงนัยทั่วไป เมื่อกำหนดให้ค่าพารามิเตอร์บ่งตำแหน่งเท่ากับ 2 พารามิเตอร์บ่งขนาดเท่ากับ 2 พารามิเตอร์บ่งรูปร่างที่แตกต่างกัน

กัน 3 รูปแบบ และค่าเกณฑ์ที่แตกต่างกัน 3 รูปแบบ ซึ่งพิจารณาจากตำแหน่งของเปอร์เซ็นต์ไทล์ที่แตกต่างกัน พบว่า วิธี ML ให้ค่า MSE ต่ำสุดสำหรับค่าเกณฑ์ทุกตำแหน่งเปอร์เซ็นต์ไทล์ในกรณีที่มีค่าพารามิเตอร์บ่งรูปร่างน้อยกว่าศูนย์ วิธี GML ให้ค่า MSE ต่ำสุดสำหรับค่าเกณฑ์ทุกตำแหน่งเปอร์เซ็นต์ไทล์ในกรณีที่มีค่าพารามิเตอร์บ่งรูปร่างเท่ากับศูนย์ และวิธี L-Moments ให้ค่า MSE ต่ำสุดสำหรับค่าเกณฑ์ทุกตำแหน่งเปอร์เซ็นต์ไทล์ในกรณีที่มีค่าพารามิเตอร์บ่งรูปร่างมากกว่าศูนย์ จึงสรุปได้ว่า วิธี ML เหมาะสำหรับการแจกแจงพาริตอวางนัยทั่วไป ที่ข้อมูลมีรูปแบบหางสั้น วิธี GML เหมาะสำหรับข้อมูลที่มีรูปแบบหางกลาง และวิธี L-Moments เหมาะสำหรับข้อมูลที่มีรูปแบบหางหนา

5.2 สรุปผลการวิจัยสำหรับข้อมูลจริง

5.2.1 ข้อมูลปริมาณน้ำฝนสูงสุดรายปี สำหรับตัวแบบจากการแจกแจงค่าสุดขีดวงนัยทั่วไป

จากการศึกษาข้อมูลปริมาณน้ำฝนสูงสุดรายปีแต่ละสถานีตรวจวัดระดับน้ำภายในกรุงเทพมหานครในระยะเวลา 30 ปี ตั้งแต่ พ.ศ.2537 - 2566 เพื่อทำการเปรียบเทียบความเหมาะสมของตัวแบบที่ได้จากแต่ละวิธีการ พบว่า ข้อมูลดังกล่าวมีความเหมาะสมที่จะนำมาวิเคราะห์โดยการแจกแจงค่าสุดขีดวงนัยทั่วไป โดยวิธีภาวะน่าจะเป็นสูงสุดทั่วไปเป็นวิธีการที่ให้ประสิทธิภาพสูงสุดสำหรับสถานีศูนย์การประชุมแห่งชาติสิริกิติ์และสถานีคลองเตย รองลงมาคือวิธีภาวะน่าจะเป็นสูงสุดและวิธีโมเมนต์เชิงเส้นสำหรับสถานีบางนาและดอนเมืองตามลำดับ ในขณะที่วิธีของเบส์นั้นให้ค่า MAPE ที่สูงกว่าวิธีการอื่น ๆ ในแต่ละสถานีตรวจวัดระดับน้ำ จึงมีความเหมาะสมกับข้อมูลปริมาณน้ำฝนสูงสุดรายปีน้อยกว่าวิธีการอื่น ๆ

เมื่อนำค่าประมาณพารามิเตอร์ไปคำนวณระดับการเกิดซ้ำในคาบเวลาการเกิดซ้ำ 2, 3, ..., 10 ปี พบว่าทุกสถานีตรวจวัดระดับน้ำมีแนวโน้มของปริมาณน้ำฝนสูงสุดที่เพิ่มขึ้นอย่างต่อเนื่อง สำหรับสถานีบางนามีแนวโน้มของระดับน้ำฝนสูงสุดที่เพิ่มขึ้นอย่างรวดเร็วมากกว่าสถานีอื่น ๆ ในขณะที่สถานีดอนเมืองและคลองเตย มีระดับการเกิดซ้ำในทุกคาบเวลาการเกิดซ้ำที่ใกล้เคียงกัน อย่างไรก็ตาม ข้อมูลปริมาณน้ำฝนสูงสุดรายปีสถานีบางนาเมื่อใช้วิธีภาวะน่าจะเป็นสูงสุดยังคงให้ประสิทธิภาพที่ดีที่สุด เนื่องจากระดับการเกิดซ้ำในแต่ละคาบเวลาการเกิดซ้ำมีความใกล้เคียงกับข้อมูลจริงมีความใกล้เคียงกัน

5.2.2 ข้อมูลปริมาณน้ำฝนสูงสุดรายเดือน สำหรับตัวแบบจากการแจกแจงพาราโรวาง นัยทั่วไป

จากการศึกษาข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนแต่ละสถานีตรวจวัดระดับน้ำภายในกรุงเทพมหานครในระยะเวลา 360 เดือน ตั้งแต่เดือนมกราคม พ.ศ. 2537 ถึงธันวาคม พ.ศ. 2566 เพื่อทำการเปรียบเทียบความเหมาะสมของตัวแบบที่ได้จากแต่ละวิธีการซึ่งจำเป็นต้องอาศัยค่าเกณฑ์พบว่า ข้อมูลดังกล่าวมีความเหมาะสมที่จะนำมาวิเคราะห์โดยการแจกแจงพาราโรวางนัยทั่วไป โดยใช้ข้อมูลที่มีค่าเกินจากเปอร์เซ็นต์ไทล์ที่แตกต่างกัน พบว่า วิธีโมเมนต์เชิงเส้นเป็นวิธีการที่ให้ประสิทธิภาพสูงสุดสำหรับทุกสถานี ไม่ว่าจะเป็นสถานีศูนย์การประชุมแห่งชาติสิริกิติ์ สถานีดอนเมือง สถานีบางนา และสถานีคลองเตย เนื่องจากให้ค่า MAPE ที่ต่ำกว่าวิธีการอื่น ๆ ซึ่งมีความเหมาะสมกับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนมากกว่าวิธีการอื่น ๆ และเมื่อนำค่าประมาณพารามิเตอร์ไปคำนวณระดับการเกิดซ้ำในคาบเวลาการเกิดซ้ำ 24, 36, ..., 120 เดือน พบว่าทุกสถานีตรวจวัดระดับน้ำมีแนวโน้มของปริมาณน้ำฝนสูงสุดที่เพิ่มขึ้นอย่างต่อเนื่อง โดยที่สถานีศูนย์การประชุมแห่งชาติสิริกิติ์และสถานีบางนามีแนวทิศของระดับการเกิดซ้ำที่เพิ่มขึ้นอย่างรวดเร็วและใกล้เคียงกันในทุกคาบเวลาการเกิดซ้ำ ในขณะที่สถานีดอนเมืองและคลองเตยมีแนวโน้มของระดับการเกิดซ้ำเพิ่มขึ้นอย่างต่อเนื่องในทุกคาบเวลาการเกิดซ้ำและใกล้เคียงกัน

จากข้อสรุปข้างต้น พบว่า สถานีบางนามีระดับการเกิดซ้ำของปริมาณน้ำฝนสูงสุดที่ใกล้เคียงกับความเป็นจริงและเหมาะสมมากที่สุด ในขณะที่สถานีดอนเมืองตัวแบบที่เหมาะสมที่สุดยังคงมีระดับการเกิดซ้ำที่แตกต่างจากข้อมูลจริงค่อนข้างมาก จึงคาดว่าข้อมูลปริมาณน้ำฝนสูงสุดสำหรับสถานีดอนเมืองจะมีความเหมาะสมกับวิธีการอื่น ๆ ที่ไม่ได้นำมาประกอบการพิจารณาในงานวิจัยชิ้นนี้ แต่อย่างไรก็ตาม ในการศึกษาครั้งนี้ใช้ข้อมูลปริมาณน้ำฝนจากสถานีต่าง ๆ เพียง 30 ปี ซึ่งอาจจะทำให้ตัวแบบและการประมาณค่าระดับการเกิดซ้ำมีความผิดพลาดเกิดขึ้นได้เนื่องจากจำนวนข้อมูลที่ไม่มากพอ และด้วยปัจจัยต่าง ๆ ที่ไม่สามารถควบคุมได้ อาจส่งผลต่อความคลาดเคลื่อนในการพิจารณาความเหมาะสมของตัวแบบ

5.3 ข้อเสนอแนะ

1) วิธีการประมาณค่าพารามิเตอร์ที่ใช้ในการวิเคราะห์สำหรับตัวแบบจากการแจกแจงค่าสุดขีดพาราโรวางนัยทั่วไปและการแจกแจงพาราโรวางนัยทั่วไปอาจไม่ใช่วิธีการที่ดีที่สุด สามารถนำวิธีการอื่น ๆ ที่ไม่ได้กล่าวถึงมาพิจารณาเพิ่มเติมสำหรับข้อมูลปริมาณน้ำฝนสูงสุดในกรุงเทพมหานคร

2) ตำแหน่งที่ตั้งของสถานีตรวจวัดระดับน้ำทั้ง 4 แห่งไม่ใช่พื้นที่ที่ใกล้เคียงกัน ซึ่งหากต้องการเปรียบเทียบอาจทำได้ยาก ด้วยปัจจัยต่าง ๆ ที่ไม่สามารถควบคุมได้ เช่น สภาพแวดล้อม ฝั่งเมือง เป็นต้น

3) ควรพิจารณาใช้แนวทางอื่น ๆ ในการเลือกตัวแบบ เช่น วิธีการเรียนรู้ด้วยเครื่อง (Machine Learning) มาประยุกต์ใช้ เพื่อเพิ่มความแม่นยำของการประมาณค่า

4) ควรมีการศึกษาผลกระทบของปัจจัยทางภูมิอากาศและสิ่งแวดล้อมที่อาจมีผลต่อปริมาณน้ำฝนสูงสุดในแต่ละพื้นที่ เช่น อุณหภูมิ ความเร็วลม ความชื้นสัมพัทธ์ ซึ่งอาจช่วยให้การพยากรณ์ระดับการเกิดข้ำมีความแม่นยำมากขึ้น

5) ในการพิจารณาความเหมาะสมเบื้องต้นของตัวแบบสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนและรายปี อาจพิจารณาได้จากลักษณะปลายหางของโค้งการแจกแจงว่ามีลักษณะแบบใด หากลักษณะปลายหางเป็นแบบหางสั้น ข้อมูลมักจะเหมาะสมกับตัวแบบที่ได้จากวิธีภาวะน่าจะเป็นสูงสุด หากลักษณะปลายหางเป็นแบบหางกลางแบบเลขชี้กำลัง ข้อมูลมักจะมีความเหมาะสมกับตัวแบบที่ได้จากวิธีภาวะน่าจะเป็นสูงสุดทั่วไป และหากลักษณะปลายหางเป็นแบบหางหนา ข้อมูลมักจะมีความเหมาะสมกับตัวแบบที่ได้จากวิธีโมเมนต์เชิงเส้น




บรรณานุกรม

- กฤตยา แสนศักดิ์, อรุณ แก้วมัน, อัจฉราพรรณ ฉันทพจน์ และปิยภัทร บุชบาบดินทร์. 2561. “การวิเคราะห์ปริมาณน้ำฝนสุดขีดด้วยวิธีโมเมนต์เชิงเส้นตรง.” *วารสารวิทยาศาสตร์บูรพา*. 23(1) : 520-532.
- ดนุลดา เนียมทอง และอนุเฝ้า ออบแพทย์. 2566. “การวิเคราะห์ความเสี่ยงพื้นที่น้ำท่วมกรุงเทพมหานครและปริมณฑล.” *การประชุมวิชาการวิศวกรรมโยธาแห่งชาติ*. 2023(28) : 1-13.
- ดุสิต ชัยประสิทธิ์. 2561. “การประมาณค่าพารามิเตอร์ของการแจกแจงไวบูลเมื่อข้อมูลถูกตรวจตัดแบบสุ่ม.” *วิทยานิพนธ์วิทยาศาสตรมหาบัณฑิต (สถิติประยุกต์) สาขาวิชาคณิตศาสตร์และสถิติ, มหาวิทยาลัยธรรมศาสตร์*.
- ทศพล ภูผิวฟ้า. 2565. “การสร้างแบบจำลองพารามิเตอร์ปรับปรุงของการแจกแจงค่าสุดขีดวงนัยทั่วไปจากข้อมูลน้ำฝน-น้ำท่า และข้อมูลภาพถ่ายดาวเทียมโดยใช้วิธีโครงข่ายประสาทเทียม.” *วิทยานิพนธ์วิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการจัดการสถิติ, มหาวิทยาลัยมหาสารคาม*.
- ชนวัฒน์ ศรีศิริวัฒน์. 2560. *สถิติเพื่อการวิจัย*. กรุงเทพฯ : มหาวิทยาลัยราชภัฏสวนสุนันทา.
- ชนโชติ ไชยโต และมานันต์ คำกอง. 2564. “ตัวแบบพยากรณ์อนุกรมเวลาของตรรกะความแห้งแล้งของฝนที่ต่างจากค่าปรกติบริเวณลุ่มน้ำปิง จังหวัดเชียงใหม่.” *วารสารวิชาการพระจอมเกล้าพระนครเหนือ*. 31(2) : 332-345.
- ปัทมกร อินแก้ว. 2564. *วิทยาการข้อมูลเบื้องต้น*. เชียงใหม่ : หน่วยพิมพ์เอกสาร งานบริการการศึกษาและพัฒนาคุณภาพนักศึกษา.
- ประภาวรรณ เสนาเพ็ง และปิยภัทร บุชบาบดินทร์. 2560. “แบบจำลองอุณหภูมิสูงสุดในภาคตะวันออกเฉียงเหนือของประเทศไทย.” *วารสารวิทยาศาสตร์บูรพา*. 22(1) : 92-107.
- ปิยภัทร บุชบาบดินทร์ และอรุณ แก้วมัน. 2558. “สถิติค่าสุดขีด.” *วารสารวิชาการพระจอมเกล้าพระนครเหนือ*. 25(2) : 315-324.

- วรภัทร เมืองสุวรรณ, มานัดฎ์ คำกอง และ พุฒิพงษ์ พุกกะมาน. 2560. “การประมาณค่าพารามิเตอร์ของการแจกแจงพาริตัววางนัยทั่วไปโดยใช้การลงจุดตำแหน่ง.” *วารสารวิทยาศาสตร์บูรพา*. 22(3) : 410-422.
- วิกานดา ผาพันธุ์, ดั่งหทัย กระแสร์ชล, เบญญาภา จ่างแสง, กมลอร มุลเมฆ และ เฉลิมรัช นนทะภา. 2566. “การวิเคราะห์ค่าสุดขีดของคลื่นทะเลบริเวณรอบชายฝั่งอ่าวไทยในจังหวัดตราด เพชรบุรี และสุราษฎร์ธานี.” *วารสารวิทยาศาสตร์และเทคโนโลยี หัวเฉียวเฉลิมพระเกียรติ*. 9(1) : 8-27.
- วีระศักดิ์ จินารัตน์. 2557. “การวิเคราะห์ข้อมูลด้วยสถิติเชิงอนุมาน.” *วารสารวิชาการมหาวิทยาลัยการจัดการและเทคโนโลยีอีสเทิร์น*. 11(2) : 80-85.
- อัญมณี กุมมาระกะ และอัชฌา อระวีพร. 2561. “การเปรียบเทียบการประมาณค่าพารามิเตอร์ของการแจกแจงทวินามเชิงลบ ด้วยวิธีภาวะน่าจะเป็นสูงสุด วิธีของเบส์ และวิธีมาร์คอฟ เชนมอนติคาร์โล.” *วารสารวิทยาศาสตร์และเทคโนโลยี*. 26(1) : 58-70.
- Adlouni, S.E. Ouarda, T.B.M.J. Zhang, X. Roy, R. and Bobée, B. 2007. “Generalized Maximum Likelihood Estimators for the Nonstationary Generalized Extreme Value Model.” *Water Resources Research*. 43(3) : 1-14.
- Araveeporn, A. 2014. “Parameter Estimation of Poisson Distribution by Using Maximum Likelihood, Markov Chain Monte Carlo, and Bayes method.” *Thammasat International Journal of Science and Technology*. 19(3) : 1-14.
- Beirlant, J. Goegebeur, Y. Teugels, J. and Segers, J. 2004. **Statistics of Extremes: Theory and Applications**. Wiley Series in Probability and Statistics4. New York : John Wiley & Sons.
- Coles, S. 2001. **An Introduction to Statistical Modeling of Extreme Values**. London : Springer-Varlag.
- Galambos, J. 1978. **The Asymptotic Theory of Extreme Order Statistics**. New York : Wiley.
- Greenshtein, E. and Ritov, Y. 2022. “Generalized Maximum Likelihood Estimation of the Mean of Parameters of Mixtures. With Applications to Sampling and to Observational Studies.” *Electronic Journal of Statistics*. 16(2) : 5934-5954.

- Hosking, J.R.M. 1990. "L-moments: Analysis and Estimation of Distributions Using Linear Combinations of Order Statistics." *Journal of the Royal Statistical Society: Series B (Methodological)*. 52(1) : 105-124.
- Jenkinson, A.F. 1955. "The Frequency Distribution of the Annual Maximum (or minimum) Values of Meteorological Elements." *Quarterly Journal of the Royal Meteorological Society*. 81 : 158-171.
- Louzaoui, A. and Arrouchi, M.E. 2020. "On the Maximum Likelihood Estimation of Extreme Value Index Based on k-Record Values." *Journal of Probability and Statistics*. 2020(2) : 1-9.
- Luengo, D. Martino, L. Bugallo, M. Elvira, V. and Särkkä, S. 2020. "A Survey of Monte Carlo Methods for Parameter Estimation." *EURASIP Journal on Advances in Signal Processing*. 2020(25) : 1-62.
- Ng, J.L. Chan, K.H. Md Noh, N.I.F. Razman, R. Surol, S. Lee, J.C. and Al-Mansob, R.A. 2022. "Statistical Modelling of Extreme Temperature in Peninsular Malaysia." *Earth and Environmental Science*. 1022(1) : 1-9.
- Khan, S.A. Hussain, I. Hussain, T. Faisal, M. Muhammad, Y.S. and Shoukry, A.M. 2017. "Regional Frequency Analysis of Extremes Precipitation Using L-Moments and Partial L-moments." *Advances in Meteorology*. 2017(5) : 1-20.
- Kiefer, J. and Wolfowitz, J. 1956. "Consistency of the Maximum Likelihood Estimator in the Presence of Infinitely Many Incidental Parameters." *The Annals of Mathematical Statistics*. 27(4) : 887-906.
- Kotz, S. and Nadaraja, S. 2000. **Extreme Value Distributions: Theory and Applications**. Singapore : Imperial College Press.
- Martins, S.E. and Stedinger, J.R. 2000. "Generalized Maximum Likelihood GEV Quantile Estimators for Hydrologic Data." *Water Resources Research*. 36(3) : 737-744.
- Nocedal, J. and Wright, S.J. 1999. **Numerical Optimization**. 2nd ed. New York : Springer.

- Park, J.S. Jeong, B.Y. Murshed, Md.S. and Seo, Y.A. 2014. "A Three-Parameter Kappa Distribution with Hydrologic Application: A Generalized Gumbel Distribution." *Springer-Verlag Berlin Heidelberg*. 28(8) : 2063-2074.
- Rehman, A. and Zhang, H. 2023. "Generalized Extreme Value Distribution for Modeling Earthquake Risk in Makran Subduction Zone Using Extreme Value Theory." *Indonesian Journal of Earth Sciences*. 3(2) : 1-8.
- Robert, C.P. and Casella, G. 1999. **Monte Carlo Statistical Methods**. New York : Springer.
- Tanprayoon, E. Tonggumnead, U. and Aryuyuen, S. 2022. "New Extension of Generalized Extreme Value Distribution: Extreme Value Analysis and Return Level Estimation of the Rainfall Data." *Trends in Sciences*. 20(1) : 1-13.
- Yoon, S. Cho, W. Heo, J.H. and Kim, C.E. 2010. "A full Bayesian Approach to Generalized Maximum Likelihood Estimation of Generalized Extreme Value Distribution." *Stochastic Environmental Research and Risk Assessment*. 24(5) : 761-770.





ภาคผนวก ก

ตาราง ก ข้อมูลปริมาณน้ำฝนสูงสุดรายปีในแต่ละสถานีตรวจวัดระดับน้ำภายในกรุงเทพมหานคร
จำนวน 30 ปี ตั้งแต่ พ.ศ. 2537 - 2566

ปี พ.ศ.	ปริมาณน้ำฝนสูงสุด (มม.)			
	ศูนย์การประชุม แห่งชาติสิริกิติ์	ดอนเมือง	บางนา	คลองเตย
2537	185.9	106.7	185.9	242.6
2538	128.9	121.6	65.1	94.5
2539	93.5	76.0	84.1	105.3
2540	65.4	101.7	78.4	95.6
2541	128.1	100.1	128.4	101.3
2542	114.5	210.7	97.2	118.2
2543	88.1	121.1	96.1	88.5
2544	90.4	58.4	103.1	91.3
2545	86.6	65.3	108.2	105.0
2546	87.6	82.0	185.9	88.2
2547	87.9	101.5	110.6	73.8
2548	86.9	102.9	72.7	90.1
2549	132.9	95.0	95.3	95.2
2550	117.9	89.8	148.4	125.1
2551	70.1	118.0	67.7	80.2
2552	216.8	123.3	130.9	140.3
2553	73.5	94.9	115.8	80.7
2554	157.4	106.9	111.4	152.2
2555	87.9	104.6	68.5	60.3
2556	103.7	82.0	74.4	80.8
2557	60.3	76.0	97.2	50.5

ตาราง ก (ต่อ) ข้อมูลปริมาณน้ำฝนสูงสุดรายปีในแต่ละสถานีตรวจวัดระดับน้ำภายในกรุงเทพมหานครจำนวน 30 ปี ตั้งแต่ พ.ศ. 2537 - 2566

ปี พ.ศ.	ปริมาณน้ำฝนสูงสุด (มม.)			
	ศูนย์การประชุมแห่งชาติสิริกิติ์	ดอนเมือง	บางนา	คลองเตย
2558	174.3	107.7	91.6	165.5
2559	141.5	108.9	92.9	132.0
2560	188.3	83.9	119.0	190.3
2561	74.3	93.2	110.9	152.5
2562	54.4	65.0	57.7	62.2
2563	118	78.6	88.0	103.4
2564	81.7	62.2	120.9	108.4
2565	132.5	74.9	126.0	130.3
2566	87.2	53.0	129.8	74.8

ตาราง ข ข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนในแต่ละสถานีตรวจวัดระดับน้ำภายในกรุงเทพมหานคร
จำนวน 360 เดือน ตั้งแต่เดือนมกราคม พ.ศ. 2537 - ธันวาคม พ.ศ. 2566

ปี พ.ศ.	เดือน	ปริมาณน้ำฝนสูงสุด (มม.)			
		ศูนย์การประชุม แห่งชาติสิริกิติ์	ดอนเมือง	บางนา	คลองเตย
2537	มกราคม	0.0	0.0	0.0	0.0
	กุมภาพันธ์	0.0	0.0	0.0	0.0
	มีนาคม	18.5	27.1	18.5	57.6
	เมษายน	66.5	40.8	66.5	43.3
	พฤษภาคม	185.9	97.9	185.9	242.6
	มิถุนายน	49.9	106.7	49.9	51.0
	กรกฎาคม	15.5	27.5	15.5	16.8
	สิงหาคม	23.0	38.9	23.0	27.4
	กันยายน	81.4	62.7	81.4	91.5
	ตุลาคม	41.6	30.5	41.6	73.3
	พฤศจิกายน	3.6	29.3	3.6	3.2
	ธันวาคม	5.3	5.9	5.3	4.3
2538	มกราคม	0.0	0.0	0.0	29.7
	กุมภาพันธ์	0.1	0.0	0.1	0.2
	มีนาคม	27.9	15.5	27.9	25.2
	เมษายน	1.4	27.6	1.4	18.7
	พฤษภาคม	43.2	68.7	43.2	49.0
	มิถุนายน	49.5	26.7	49.5	63.6
	กรกฎาคม	61.9	99.4	65.1	55.0
	สิงหาคม	128.9	40.8	58.8	94.5
	กันยายน	52.4	121.6	49.8	64.6
	ตุลาคม	34.8	53.8	52.9	38.4
	พฤศจิกายน	11.0	35.8	20.7	13.3
	ธันวาคม	0.4	0.0	0.0	1.2

ตาราง ข (ต่อ) ข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนในแต่ละสถานีตรวจวัดระดับน้ำภายใน กรุงเทพมหานครจำนวน 360 เดือน ตั้งแต่เดือนมกราคม พ.ศ. 2537 - ธันวาคม พ.ศ. 2566

ปี พ.ศ.	เดือน	ปริมาณน้ำฝนสูงสุด (มม.)			
		ศูนย์การประชุม แห่งชาติสิริกิติ์	ดอนเมือง	บางนา	คลองเตย
2539	มกราคม	0.3	5.5	7.3	1.0
	กุมภาพันธ์	9.5	5.5	17.4	10.4
	มีนาคม	2.0	4.6	10.0	1.3
	เมษายน	93.5	36.1	42.7	105.3
	พฤษภาคม	47.0	44.8	18.7	57.5
	มิถุนายน	27.4	58.8	58.9	28.2
	กรกฎาคม	92.5	33.1	27.2	97.3
	สิงหาคม	32.4	45.8	43.5	45.8
	กันยายน	61.6	76.0	66.7	56.6
	ตุลาคม	61.7	65.2	57.2	72.3
	พฤศจิกายน	40.1	56.1	84.1	42.6
	ธันวาคม	0.0	0.0	0.0	0.0
2540	มกราคม	0.0	1.0	0.0	0.0
	กุมภาพันธ์	37.6	0.3	0.8	44.2
	มีนาคม	16.6	25.0	16.3	49.7
	เมษายน	56.9	14.3	53.2	33.6
	พฤษภาคม	48.5	51.7	35.2	32.3
	มิถุนายน	25.4	14.7	55.8	20.8
	กรกฎาคม	9.0	12.3	30.6	21.4
	สิงหาคม	26.5	39.8	52.4	31.3
	กันยายน	65.4	101.7	78.4	95.6
	ตุลาคม	35.3	34.2	70.1	42.7
	พฤศจิกายน	17.4	7.2	5.3	4.3
	ธันวาคม	0.0	0.0	0.0	0.0

ตาราง ข (ต่อ) ข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนในแต่ละสถานีตรวจวัดระดับน้ำภายใน กรุงเทพมหานครจำนวน 360 เดือน ตั้งแต่เดือนมกราคม พ.ศ. 2537 - ธันวาคม พ.ศ. 2566

ปี พ.ศ.	เดือน	ปริมาณน้ำฝนสูงสุด (มม.)			
		ศูนย์การประชุม แห่งชาติสิริกิติ์	ดอนเมือง	บางนา	คลองเตย
2541	มกราคม	41.9	0.5	64.1	37.9
	กุมภาพันธ์	16.8	13.0	36.0	50.7
	มีนาคม	0.9	0.5	0.5	0.9
	เมษายน	30.9	7.2	25.7	23.5
	พฤษภาคม	67.0	73.7	43.1	52.3
	มิถุนายน	60.4	49.4	128.4	96.7
	กรกฎาคม	50.0	65.8	79.2	56.0
	สิงหาคม	67.4	100.1	82.3	69.9
	กันยายน	128.1	56.7	82.6	101.3
	ตุลาคม	63.3	32.5	111.9	73.0
	พฤศจิกายน	5.8	12.5	8.4	6.6
	ธันวาคม	0.0	0.0	0.0	0.5
2542	มกราคม	17.3	33.8	13.3	22.0
	กุมภาพันธ์	33.5	32.8	37.5	35.0
	มีนาคม	44.0	21.6	28.6	50.9
	เมษายน	43.6	48.1	75.6	35.1
	พฤษภาคม	114.5	210.7	97.2	97.2
	มิถุนายน	24.1	39.4	43.5	16.1
	กรกฎาคม	13.5	29.6	61.1	20.2
	สิงหาคม	48.2	45.9	37.7	47.0
	กันยายน	51.8	55.8	67.2	39.5
	ตุลาคม	96.4	50.8	94.1	118.2
	พฤศจิกายน	28.2	18.6	40.4	18.1
	ธันวาคม	0.5	2.4	0.2	0.4

ตาราง ข (ต่อ) ข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนในแต่ละสถานีตรวจวัดระดับน้ำภายใน กรุงเทพมหานครจำนวน 360 เดือน ตั้งแต่เดือนมกราคม พ.ศ. 2537 - ธันวาคม พ.ศ. 2566

ปี พ.ศ.	เดือน	ปริมาณน้ำฝนสูงสุด (มม.)			
		ศูนย์การประชุม แห่งชาติสิริกิติ์	ดอนเมือง	บางนา	คลองเตย
2543	มกราคม	0.0	0.0	0.0	0.0
	กุมภาพันธ์	39.9	8.5	12.2	35.9
	มีนาคม	34.5	30.2	29.1	42.2
	เมษายน	61.8	121.1	96.1	55.2
	พฤษภาคม	65.8	74.6	77.8	58.5
	มิถุนายน	52.2	35.2	37.2	47.2
	กรกฎาคม	55.3	25.5	27.5	61.3
	สิงหาคม	39.3	24.7	61.3	30.3
	กันยายน	34.1	72.8	55.2	43.4
	ตุลาคม	88.1	20.9	60.5	88.5
	พฤศจิกายน	0.0	0.8	2.7	0.2
	ธันวาคม	4.4	0.0	1.5	0.5
2544	มกราคม	7.3	15.9	0.2	18.1
	กุมภาพันธ์	3.6	2.7	2.6	9.5
	มีนาคม	54.8	29.6	35.3	45.0
	เมษายน	26.4	46.8	9.0	6.7
	พฤษภาคม	48.3	53.4	60.9	30.0
	มิถุนายน	25.5	25.7	33.1	32.3
	กรกฎาคม	27.2	31.1	20.9	12.4
	สิงหาคม	44.9	18.9	37.9	52.1
	กันยายน	81.3	58.4	71.7	67.7
	ตุลาคม	90.4	38.0	47.3	91.3
	พฤศจิกายน	37.3	1.7	103.1	34.9
	ธันวาคม	4.0	3.0	8.1	12.6

ตาราง ข (ต่อ) ข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนในแต่ละสถานีตรวจวัดระดับน้ำภายใน กรุงเทพมหานครจำนวน 360 เดือน ตั้งแต่เดือนมกราคม พ.ศ. 2537 - ธันวาคม พ.ศ. 2566

ปี พ.ศ.	เดือน	ปริมาณน้ำฝนสูงสุด (มม.)			
		ศูนย์การประชุม แห่งชาติสิริกิติ์	ดอนเมือง	บางนา	คลองเตย
2545	มกราคม	0.0	0.0	0.0	0.0
	กุมภาพันธ์	52.5	5.2	14.0	105.0
	มีนาคม	43.7	1.8	12.6	19.4
	เมษายน	5.6	21.6	5.4	5.7
	พฤษภาคม	37.1	35.5	36.0	39.8
	มิถุนายน	26.1	46.8	108.2	66.5
	กรกฎาคม	27.1	26.0	23.1	25.6
	สิงหาคม	53.6	54.5	35.6	48.4
	กันยายน	84.2	65.3	90.3	46.6
	ตุลาคม	86.6	47.0	87.6	97.0
	พฤศจิกายน	45.7	21.6	46.5	56.9
	ธันวาคม	19.4	3.0	16.6	53.3
2546	มกราคม	0.0	0.0	0.0	0.0
	กุมภาพันธ์	0.4	17.7	26.2	0.2
	มีนาคม	45.0	39.0	185.9	59.2
	เมษายน	12.3	10.5	21.9	6.1
	พฤษภาคม	71.2	67.8	68.9	69.7
	มิถุนายน	69.5	66.5	56.0	81.6
	กรกฎาคม	44.8	57.3	29.9	57.0
	สิงหาคม	87.6	75.3	58.1	72.4
	กันยายน	35.0	82.0	50.1	37.6
	ตุลาคม	54.7	11.8	44.8	88.2
	พฤศจิกายน	0.0	0.0	0.0	0.0
	ธันวาคม	0.0	0.0	0.0	0.0

ตาราง ข (ต่อ) ข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนในแต่ละสถานีตรวจวัดระดับน้ำภายใน กรุงเทพมหานครจำนวน 360 เดือน ตั้งแต่เดือนมกราคม พ.ศ. 2537 - ธันวาคม พ.ศ. 2566

ปี พ.ศ.	เดือน	ปริมาณน้ำฝนสูงสุด (มม.)			
		ศูนย์การประชุม แห่งชาติสิริกิติ์	ดอนเมือง	บางนา	คลองเตย
2547	มกราคม	43.1	18.5	62.3	44.7
	กุมภาพันธ์	53.9	34.6	110.6	69.5
	มีนาคม	1.5	1.0	0.0	0.5
	เมษายน	87.9	16.5	43.4	51.4
	พฤษภาคม	16.9	40.3	24.4	22.6
	มิถุนายน	36.1	101.5	29.8	36.4
	กรกฎาคม	27.4	68.4	35.5	25.9
	สิงหาคม	46.7	39.3	40.1	42.8
	กันยายน	78.5	49.2	62.9	73.8
	ตุลาคม	40.1	36.3	46.2	34.1
	พฤศจิกายน	5.0	19.2	0.4	0.0
	ธันวาคม	0.0	0.0	0.0	0.0
2548	มกราคม	1.9	1.3	18.9	2.3
	กุมภาพันธ์	1.4	0.0	20.1	0.1
	มีนาคม	6.4	32.6	27.5	6.4
	เมษายน	47.0	60.1	36.0	61.1
	พฤษภาคม	61.2	102.9	58.8	90.1
	มิถุนายน	18.0	91.6	58.3	23.8
	กรกฎาคม	81.5	49.0	49.7	77.6
	สิงหาคม	26.4	34.1	52.0	21.5
	กันยายน	86.9	74.3	72.7	79.4
	ตุลาคม	68.0	70.9	67.0	62.6
	พฤศจิกายน	69.6	39.5	29.9	77.9
	ธันวาคม	21.4	12.4	7.7	18.1

ตาราง ข (ต่อ) ข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนในแต่ละสถานีตรวจวัดระดับน้ำภายใน กรุงเทพมหานครจำนวน 360 เดือน ตั้งแต่เดือนมกราคม พ.ศ. 2537 - ธันวาคม พ.ศ. 2566

ปี พ.ศ.	เดือน	ปริมาณน้ำฝนสูงสุด (มม.)			
		ศูนย์การประชุมแห่งชาติสิริกิติ์	ดอนเมือง	บางนา	คลองเตย
2549	มกราคม	0.7	5.8	0.7	2.5
	กุมภาพันธ์	26.9	8.0	9.9	30.3
	มีนาคม	63.6	77.0	33.5	70.2
	เมษายน	19.1	64.5	26.6	16.5
	พฤษภาคม	73.6	95.0	51.8	70.8
	มิถุนายน	94.6	77.2	30.7	75.7
	กรกฎาคม	43.8	37.9	46.3	33.9
	สิงหาคม	25.7	36.3	38.2	29.1
	กันยายน	53.5	47.3	95.3	62.1
	ตุลาคม	132.9	54.5	26.8	95.2
	พฤศจิกายน	18.1	60.2	9.9	13.1
	ธันวาคม	0.7	0.4	4.8	0.4
2550	มกราคม	27.7	0.4	1.7	17.1
	กุมภาพันธ์	0.0	1.5	0.0	0.1
	มีนาคม	8.3	44.8	34.3	7.8
	เมษายน	49.9	57.5	41.6	52.2
	พฤษภาคม	54.6	89.8	52.6	50.7
	มิถุนายน	50.5	47.5	66.4	39.8
	กรกฎาคม	47.6	42.4	55.9	66.8
	สิงหาคม	27.9	38.9	57.4	23.0
	กันยายน	117.9	69.8	133.7	125.1
	ตุลาคม	64.6	86.1	148.4	39.3
	พฤศจิกายน	15.0	1.9	30.3	11.2
	ธันวาคม	0.0	0.0	0.0	0.0

ตาราง ข (ต่อ) ข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนในแต่ละสถานีตรวจวัดระดับน้ำภายใน กรุงเทพมหานครจำนวน 360 เดือน ตั้งแต่เดือนมกราคม พ.ศ. 2537 - ธันวาคม พ.ศ. 2566

ปี พ.ศ.	เดือน	ปริมาณน้ำฝนสูงสุด (มม.)			
		ศูนย์การประชุม แห่งชาติสิริกิติ์	ดอนเมือง	บางนา	คลองเตย
2551	มกราคม	62.1	5.0	7.8	65.9
	กุมภาพันธ์	24.7	6.8	12.9	16.8
	มีนาคม	2.9	0.7	13.4	9.9
	เมษายน	55.3	25.6	49.3	43.1
	พฤษภาคม	47.6	83.7	26.0	41.4
	มิถุนายน	51.5	68.1	38.7	46.6
	กรกฎาคม	60.6	31.3	57.8	56.0
	สิงหาคม	31.8	52.9	34.9	30.0
	กันยายน	70.1	57.3	51.9	80.2
	ตุลาคม	54.2	118.0	51.5	65.8
	พฤศจิกายน	20.6	15.6	67.7	18.3
	ธันวาคม	0.0	0.0	0.0	0.0
2552	มกราคม	0.0	0.0	0.0	0.0
	กุมภาพันธ์	0.0	0.0	0.0	0.0
	มีนาคม	12.2	36.3	16.5	24.2
	เมษายน	216.8	53.1	58.0	140.3
	พฤษภาคม	122.9	60.2	55.3	101.5
	มิถุนายน	57.9	73.5	50.4	73.1
	กรกฎาคม	41.1	36.2	43.5	44.5
	สิงหาคม	96.6	82.5	72.3	81.0
	กันยายน	58.3	57.9	89.5	94.4
	ตุลาคม	62.6	123.3	130.9	76.9
	พฤศจิกายน	38.7	22.5	18.8	5.2
	ธันวาคม	6.7	0.7	1.1	2.2

ตาราง ข (ต่อ) ข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนในแต่ละสถานีตรวจวัดระดับน้ำภายใน กรุงเทพมหานครจำนวน 360 เดือน ตั้งแต่เดือนมกราคม พ.ศ. 2537 - ธันวาคม พ.ศ. 2566

ปี พ.ศ.	เดือน	ปริมาณน้ำฝนสูงสุด (มม.)			
		ศูนย์การประชุมแห่งชาติสิริกิติ์	ดอนเมือง	บางนา	คลองเตย
2553	มกราคม	34.0	69.3	6.1	54.8
	กุมภาพันธ์	2.9	12.7	0.4	2.2
	มีนาคม	10.1	3.6	7.1	24.4
	เมษายน	7.4	85.7	32.3	11.2
	พฤษภาคม	56.7	33.7	38.7	41.9
	มิถุนายน	55.1	41.6	63.8	49.7
	กรกฎาคม	60.0	60.1	42.6	50.1
	สิงหาคม	58.4	48.5	85.3	77.6
	กันยายน	73.5	94.9	115.8	80.7
	ตุลาคม	61.4	44.4	29.2	43.3
	พฤศจิกายน	23.5	3.6	17.7	30.2
	ธันวาคม	19.1	34.6	57.5	4.5
2554	มกราคม	0.2	0.0	1.5	0.3
	กุมภาพันธ์	9.5	10.6	32.9	19.0
	มีนาคม	63.7	90.5	53.5	51.5
	เมษายน	45.8	70.8	25.6	58.7
	พฤษภาคม	57.7	61.5	81.5	72.1
	มิถุนายน	157.4	50.6	111.4	152.2
	กรกฎาคม	48.5	100.9	48.7	34.0
	สิงหาคม	56.1	56.3	65.1	91.1
	กันยายน	38.6	106.9	45.2	40.0
	ตุลาคม	58.9	37.9	55.8	91.7
	พฤศจิกายน	0.9	0.0	0.0	0.0
	ธันวาคม	0.7	0.0	0.0	0.8

ตาราง ข (ต่อ) ข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนในแต่ละสถานีตรวจวัดระดับน้ำภายใน กรุงเทพมหานครจำนวน 360 เดือน ตั้งแต่เดือนมกราคม พ.ศ. 2537 - ธันวาคม พ.ศ. 2566

ปี พ.ศ.	เดือน	ปริมาณน้ำฝนสูงสุด (มม.)			
		ศูนย์การประชุมแห่งชาติสิริกิติ์	ดอนเมือง	บางนา	คลองเตย
2555	มกราคม	24.6	0.0	8.1	27.5
	กุมภาพันธ์	56.4	0.0	11.2	17.5
	มีนาคม	17.0	5.5	33.7	12.6
	เมษายน	33.6	37.0	24.1	40.0
	พฤษภาคม	38.0	40.0	29.4	32.0
	มิถุนายน	27.2	36.6	27.6	30.6
	กรกฎาคม	60.6	104.6	19.5	20.7
	สิงหาคม	48.8	57.6	44.1	40.3
	กันยายน	87.9	53.4	68.5	60.3
	ตุลาคม	47.6	54.6	38.2	39.5
	พฤศจิกายน	29.8	80.9	47.5	39.4
ธันวาคม	7.0	44.6	0.2	0.0	
2556	มกราคม	24.4	34.9	74.4	25.7
	กุมภาพันธ์	4.3	6.7	0.5	2.2
	มีนาคม	25.6	48.0	9.7	8.3
	เมษายน	42.3	4.7	38.4	33.8
	พฤษภาคม	25.4	25.6	32.3	21.5
	มิถุนายน	39.5	82.0	58.3	77.4
	กรกฎาคม	48.6	34.7	42.7	29.4
	สิงหาคม	34.6	36.5	31.0	42.2
	กันยายน	103.7	71.3	64.4	80.8
	ตุลาคม	88.1	59.5	55.0	54.9
	พฤศจิกายน	25.4	19.6	62.9	26.6
ธันวาคม	1.6	0.4	0.7	0.0	

ตาราง ข (ต่อ) ข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนในแต่ละสถานีตรวจวัดระดับน้ำภายใน กรุงเทพมหานครจำนวน 360 เดือน ตั้งแต่เดือนมกราคม พ.ศ. 2537 - ธันวาคม พ.ศ. 2566

ปี พ.ศ.	เดือน	ปริมาณน้ำฝนสูงสุด (มม.)			
		ศูนย์การประชุม แห่งชาติสิริกิติ์	ดอนเมือง	บางนา	คลองเตย
2557	มกราคม	0.0	0.0	0.0	0.0
	กุมภาพันธ์	1.8	8.1	1.9	1.5
	มีนาคม	38.6	20.2	3.7	11.0
	เมษายน	7.7	49.8	0.6	13.2
	พฤษภาคม	26.2	50.0	66.4	39.8
	มิถุนายน	33.2	20.7	18.5	33.0
	กรกฎาคม	23.1	55.3	97.2	32.2
	สิงหาคม	60.3	76.0	50.7	35.5
	กันยายน	30.9	47.5	32.1	50.5
	ตุลาคม	49.7	52.6	74.7	32.3
	พฤศจิกายน	11.2	20.0	11.3	17.0
	ธันวาคม	19.8	7.7	24.5	16.2
2558	มกราคม	2.2	1.4	29.0	5.7
	กุมภาพันธ์	10.8	0.2	8.9	6.5
	มีนาคม	65.1	94.0	49.9	53.3
	เมษายน	56.2	17.5	49.5	30.6
	พฤษภาคม	39.7	28.2	20.6	30.2
	มิถุนายน	174.3	33.5	91.6	165.5
	กรกฎาคม	51.4	25.1	56.6	60.3
	สิงหาคม	15.5	47.0	9.4	13.6
	กันยายน	47.1	107.7	86.8	36.9
	ตุลาคม	63.4	41.2	51.5	84.8
	พฤศจิกายน	19.4	15.2	9.3	8.5
	ธันวาคม	25.5	2.3	20.0	39.6

ตาราง ข (ต่อ) ข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนในแต่ละสถานีตรวจวัดระดับน้ำภายใน กรุงเทพมหานครจำนวน 360 เดือน ตั้งแต่เดือนมกราคม พ.ศ. 2537 - ธันวาคม พ.ศ. 2566

ปี พ.ศ.	เดือน	ปริมาณน้ำฝนสูงสุด (มม.)			
		ศูนย์การประชุม แห่งชาติสิริกิติ์	ดอนเมือง	บางนา	คลองเตย
2559	มกราคม	32.0	33.0	76.1	28.0
	กุมภาพันธ์	0.0	0.0	2.0	0.1
	มีนาคม	28.8	9.2	1.8	11.7
	เมษายน	31.1	12.9	33.1	26.1
	พฤษภาคม	51.5	79.0	40.3	72.5
	มิถุนายน	141.5	66.2	90.8	132.0
	กรกฎาคม	46.7	34.8	75.4	40.5
	สิงหาคม	55.3	33.3	92.9	40.0
	กันยายน	72.7	108.9	74.0	78.3
	ตุลาคม	49.3	82.0	51.9	131.0
	พฤศจิกายน	30.5	9.0	76.3	35.0
	ธันวาคม	0.0	0.0	0.0	0.0
2560	มกราคม	35.6	11.4	36.7	12.0
	กุมภาพันธ์	0.0	0.0	0.3	0.0
	มีนาคม	79.6	21.4	29.1	10.1
	เมษายน	6.3	37.3	23.8	20.0
	พฤษภาคม	90.9	83.9	119.0	110.2
	มิถุนายน	29.4	69.1	69.5	48.0
	กรกฎาคม	80.8	57.1	28.1	52.0
	สิงหาคม	130.7	39.1	63.9	113.8
	กันยายน	86.6	37.5	43.9	75.2
	ตุลาคม	188.3	45.9	88.9	190.3
	พฤศจิกายน	24.6	4.3	20.3	25.6
	ธันวาคม	30.2	8.7	12.4	33.0

ตาราง ข (ต่อ) ข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนในแต่ละสถานีตรวจวัดระดับน้ำภายใน กรุงเทพมหานครจำนวน 360 เดือน ตั้งแต่เดือนมกราคม พ.ศ. 2537 - ธันวาคม พ.ศ. 2566

ปี พ.ศ.	เดือน	ปริมาณน้ำฝนสูงสุด (มม.)			
		ศูนย์การประชุมแห่งชาติสิริกิติ์	ดอนเมือง	บางนา	คลองเตย
2561	มกราคม	62.3	36.5	110.9	152.5
	กุมภาพันธ์	21.1	52.7	58.5	50.6
	มีนาคม	50.0	42.0	54.1	45.8
	เมษายน	74.3	32.5	73.6	60.0
	พฤษภาคม	19.9	38.1	31.0	22.2
	มิถุนายน	30.3	48.5	29.7	47.0
	กรกฎาคม	38.0	35.2	53.6	39.6
	สิงหาคม	32.8	26.0	43.6	31.0
	กันยายน	61.8	44.7	41.2	61.1
	ตุลาคม	38.5	35.7	48.1	51.2
	พฤศจิกายน	20.8	20.0	18.7	14.4
	ธันวาคม	37.0	93.2	63.1	20.8
2562	มกราคม	1.1	0.4	0.9	1.1
	กุมภาพันธ์	0.0	0.0	0.0	0.0
	มีนาคม	9.0	0.0	2.3	0.0
	เมษายน	23.6	65.0	23.9	25.0
	พฤษภาคม	25.8	33.2	41.9	18.8
	มิถุนายน	46.1	64.8	57.0	36.8
	กรกฎาคม	49.3	26.4	57.7	15.6
	สิงหาคม	19.5	13.8	19.2	14.5
	กันยายน	54.4	30.0	52.2	62.2
	ตุลาคม	52.0	57.2	55.8	55.2
	พฤศจิกายน	6.7	10.8	13.8	5.6
	ธันวาคม	0.0	0.0	0.2	0.0

ตาราง ข (ต่อ) ข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนในแต่ละสถานีตรวจวัดระดับน้ำภายใน กรุงเทพมหานครจำนวน 360 เดือน ตั้งแต่เดือนมกราคม พ.ศ. 2537 - ธันวาคม พ.ศ. 2566

ปี พ.ศ.	เดือน	ปริมาณน้ำฝนสูงสุด (มม.)			
		ศูนย์การประชุมแห่งชาติสิริกิติ์	ดอนเมือง	บางนา	คลองเตย
2563	มกราคม	22.7	19.6	0.3	18.5
	กุมภาพันธ์	36.9	0.0	0.4	23.4
	มีนาคม	5.0	26.8	29.3	6.0
	เมษายน	16.2	31.0	28.4	14.0
	พฤษภาคม	34.8	37.0	50.6	41.0
	มิถุนายน	42.6	24.0	42.5	38.2
	กรกฎาคม	86.7	78.6	31.7	62.5
	สิงหาคม	83.9	41.8	76.9	103.4
	กันยายน	58.4	28.8	88.0	45.3
	ตุลาคม	118.0	65.2	71.7	86.4
	พฤศจิกายน	72.6	15.8	29.0	39.5
	ธันวาคม	0.0	0.0	0.0	0.0
2564	มกราคม	0.0	0.0	0.0	0.0
	กุมภาพันธ์	80.6	0.0	66.7	108.4
	มีนาคม	11.1	10.8	1.7	9.6
	เมษายน	65.2	50.0	24.9	50.6
	พฤษภาคม	80.2	44.4	120.9	79.6
	มิถุนายน	20.0	18.2	62.0	22.4
	กรกฎาคม	76.3	21.0	81.3	68.1
	สิงหาคม	51.3	34.2	61.4	76.4
	กันยายน	81.7	62.2	53.8	68.6
	ตุลาคม	75.7	20.4	91.5	59.7
	พฤศจิกายน	46.0	1.8	48.1	33.7
	ธันวาคม	0.0	0.0	0.4	0.0

ตาราง ข (ต่อ) ข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนในแต่ละสถานีตรวจวัดระดับน้ำภายใน กรุงเทพมหานครจำนวน 360 เดือน ตั้งแต่เดือนมกราคม พ.ศ. 2537 - ธันวาคม พ.ศ. 2566

ปี พ.ศ.	เดือน	ปริมาณน้ำฝนสูงสุด (มม.)			
		ศูนย์การประชุมแห่งชาติสิริกิติ์	ดอนเมือง	บางนา	คลองเตย
2565	มกราคม	30.0	28.7	41.2	33.7
	กุมภาพันธ์	63.3	47.4	32.6	63.0
	มีนาคม	43.7	23.6	54.9	25.0
	เมษายน	8.5	58.2	23.4	4.9
	พฤษภาคม	79.5	73.4	125.8	88.2
	มิถุนายน	47.3	74.9	76.0	44.6
	กรกฎาคม	132.5	51.4	126.0	130.3
	สิงหาคม	92.3	31.8	87.7	94.2
	กันยายน	85.6	50.0	86.1	78.9
	ตุลาคม	90.4	60.4	117.9	110.5
	พฤศจิกายน	33.0	25.4	31.8	16.6
	ธันวาคม	18.1	2.8	0.3	17.8
2566	มกราคม	0.0	0.0	6.0	0.0
	กุมภาพันธ์	45.3	3.8	87.2	32.4
	มีนาคม	4.6	5.8	3.6	4.1
	เมษายน	19.2	7.6	27.4	11.2
	พฤษภาคม	45.6	21.6	30.4	39.5
	มิถุนายน	27.3	34.8	56.5	24.4
	กรกฎาคม	87.2	41.0	62.5	72.4
	สิงหาคม	38.5	53.0	44.2	31.5
	กันยายน	69.1	35.8	129.8	58.6
	ตุลาคม	76.5	23.0	40.5	74.8
	พฤศจิกายน	22.4	28.5	38.0	14.9
	ธันวาคม	11.9	23.6	7.4	7.2

ภาคผนวก ข

คำสั่งโปรแกรมอาร์ที่ใช้ในงานวิจัยสำหรับการจำลองข้อมูลจากการแจกแจงค่าสุดขีดวงนัยทั่วไป

```

library(EnvStats)
library(extRemes)
# -----
# Density plot สำหรับการแจกแจงค่าสุดขีดวงนัยทั่วไป
x <- seq(0,10,len = 10000)
y1 <- dgev(x, location = 3, scale = 1, shape = -0.7)
y2 <- dgev(x, location = 3, scale = 1, shape = 0)
y3 <- dgev(x, location = 3, scale = 1, shape = 0.7)
plot(x, y1, type = "l", col = "red", lty = 1, lwd = 2, ylim = c(0,0.6), ylab = "Density",
      main = "Generalized Extreme Value Density")
points(x, y2, type = "l", col="blue", lty = 1, lwd = 2)
points(x, y3, type = "l", col="green", lty = 1, lwd = 2)
labels = c("Weibull", "Gumbel", "Frechet")
colors = c("red", "blue", "green")
A = c(1,1,1)
legend("topright", inset = 0.05, labels, lwd = 2, lty = A, col = colors)
# -----
# จำลองข้อมูลและประมาณค่าพารามิเตอร์จากการแจกแจงค่าสุดขีดวงนัยทั่วไป เมื่อ m แทน
จำนวนรอบในการทำซ้ำ n แทนขนาดตัวอย่าง และ a, b และ c แทนค่าพารามิเตอร์บ่งตำแหน่ง
พารามิเตอร์บ่งขนาด และพารามิเตอร์บ่งรูปร่างตามลำดับ
m = 1000; a = 3; b = 1; c = 0; n = 30
# สร้างเวกเตอร์สำหรับเก็บค่าประมาณพารามิเตอร์
loc1 = c(); sca1 = c(); sha1 = c() # สำหรับวิธี ML
loc2 = c(); sca2 = c(); sha2 = c() # สำหรับวิธี GML
loc3 = c(); sca3 = c(); sha3 = c() # สำหรับวิธี Bayesian
loc4 = c(); sca4 = c(); sha4 = c() # สำหรับวิธี L-moments
# for loop สำหรับการจำลองข้อมูล โดยวนซ้ำ m ครั้ง

```

```

for (r in 1:m) {
  B = TRUE
  while (B) {
    z <- rgevd(n, loc = a, scale = b, shape = c )
    fit1 <- fevd(z, type = "GEV", method = "MLE" )
    fit2 <- fevd(z, type = "GEV", method = "GMLE" )
    fit3 <- fevd(z, type = "GEV", method = "Bayesian", iter = 2000)
    fit4 <- fevd(z, type = "GEV", method = "Lmoments")
    COV = sum(parcov.fevd(fit1)) == 0 | sum(parcov.fevd(fit2)) == 0
    X = sum(parcov.fevd(fit1)[1,1]) < 0 | sum(parcov.fevd(fit2)[1,1]) < 0
    Y = sum(parcov.fevd(fit1)[2,2]) < 0 | sum(parcov.fevd(fit2)[2,2]) < 0
    Z = sum(parcov.fevd(fit1)[3,3]) < 0 | sum(parcov.fevd(fit2)[3,3]) < 0
    B = COV|X|Y|Z
    cat("Result : ", B, "\n")
  }
  loc1[r] = mean(findpars(fit1)$location)
  sca1[r] = mean(findpars(fit1)$scale)
  sha1[r] = mean(findpars(fit1)$shape)
  loc2[r] = mean(findpars(fit2)$location)
  sca2[r] = mean(findpars(fit2)$scale)
  sha2[r] = mean(findpars(fit2)$shape)
  loc3[r] = mean(findpars(fit3)$location)
  sca3[r] = mean(findpars(fit3)$scale)
  sha3[r] = mean(findpars(fit3)$shape)
  loc4[r] = findpars(fit4)[1]
  sca4[r] = findpars(fit4)[2]
  sha4[r] = findpars(fit4)[3]
  cat("Round : ", r, "\n")
}
# ประมาณค่าพารามิเตอร์สำหรับแต่ละวิธีที่ใช้ในการประมาณค่าพารามิเตอร์
est_loc = c(mean(loc1), mean(loc2), mean(loc3), mean(loc4))

```

```

est_sca = c(mean(sca1), mean(sca2), mean(sca3), mean(sca4))
est_sha = c(mean(-sha1), mean(-sha2), mean(-sha3), mean(-sha4))
est = round(data.frame(est_loc,est_sca,est_sha),4)
# คำนวณค่า MSE ของค่าประมาณพารามิเตอร์บ่งตำแหน่งสำหรับแต่ละวิธี
mse_loc1 = mean((a - loc1)^2)
mse_loc2 = mean((a - loc2)^2)
mse_loc3 = mean((a - loc3)^2)
mse_loc4 = mean((a - loc4)^2)
# คำนวณค่า MSE ของค่าประมาณพารามิเตอร์บ่งขนาดสำหรับแต่ละวิธี
mse_sca1 = mean((b - sca1)^2)
mse_sca2 = mean((b - sca2)^2)
mse_sca3 = mean((b - sca3)^2)
mse_sca4 = mean((b - sca4)^2)
# คำนวณค่า MSE ของค่าประมาณพารามิเตอร์บ่งรูปร่างสำหรับแต่ละวิธี
mse_sha1 = mean((-c - sha1)^2)
mse_sha2 = mean((-c - sha2)^2)
mse_sha3 = mean((-c - sha3)^2)
mse_sha4 = mean((-c - sha4)^2)
mse_loc = c(mse_loc1,mse_loc2,mse_loc3,mse_loc4)
mse_sca = c(mse_sca1,mse_sca2,mse_sca3,mse_sca4)
mse_sha = c(mse_sha1,mse_sha2,mse_sha3,mse_sha4)
mse = round(data.frame(mse_loc,mse_sca,mse_sha),4)
# คำนวณค่าส่วนเบี่ยงเบนมาตรฐานของค่าประมาณพารามิเตอร์บ่งตำแหน่งสำหรับแต่ละวิธี
sd_loc1 = sd(loc1, a)
sd_loc2 = sd(loc2, a)
sd_loc3 = sd(loc3, a)
sd_loc4 = sd(loc4, a)
# คำนวณค่าส่วนเบี่ยงเบนมาตรฐานของค่าประมาณพารามิเตอร์บ่งขนาดสำหรับแต่ละวิธี
sd_sca1 = sd(sca1, b)
sd_sca2 = sd(sca2, b)
sd_sca3 = sd(sca3, b)

```

```

sd_sca4 = sd(sca4, b)
# คำนวณค่าส่วนเบี่ยงเบนมาตรฐานของค่าประมาณพารามิเตอร์บ่งรูปร่างสำหรับแต่ละวิธี

sd_sha1 = sd(sha1, -c)
sd_sha2 = sd(sha2, -c)
sd_sha3 = sd(sha3, -c)
sd_sha4 = sd(sha4, -c)
sd_loc = c(sd_loc1,sd_loc2,sd_loc3,sd_loc4)
sd_sca = c(sd_sca1,sd_sca2,sd_sca3,sd_sca4)
sd_sha = c(sd_sha1,sd_sha2,sd_sha3,sd_sha4)
sd = round(data.frame(sd_loc,sd_sca,sd_sha),4)
method = c("MLE", "GMLE", "BAYSIANS", "LMOMENT")
output_GEV = data.frame(method, est, mse, sd)
# -----
# พล็อตกราฟ MSE
par(mfrow = c(1,3))
# กรณีที่ 1 เมื่อค่าประมาณพารามิเตอร์บ่งรูปร่างน้อยกว่าศูนย์
## สำหรับค่าประมาณพารามิเตอร์บ่งตำแหน่ง โดยใช้ค่า MSE ที่ได้ทั้งหมดจากแต่ละวิธี
ML = c(0.0496,0.0292,0.0187,0.0136)
GML = c(0.0645,0.0365,0.0267,0.0181)
Bayes = c(0.0721,0.0340,0.0212,0.0148)
LMOM = c(0.0649,0.0399,0.0292,0.0204)
y = c(30, 50, 70, 100) # ขนาดตัวอย่าง (n) ทั้งหมดจากการจำลอง
x = seq(1,4)
plot(x, y, type = "b", lty = 3, lwd = 2, col = "black", xaxt = "n", ylim = c(0.01,0.14),
      main = "Location", xlab = "n", ylab = " MSE ", pch = 8, cex = 1.5)
lines(x, ML, type = "b", lty = 2, lwd = 2, col = "blue", pch = 6, cex = 1.5)
lines(x, GML,type = "b", lty = 1, lwd = 2.9, col = "red", pch = 5, cex = 1.5)
lines(x, Bayes, type = "b", lty = 4, lwd = 2.9, col = "orange", pch = 4, cex = 1.5)
lines(x, LMOM, type = "b", lty = 5, lwd = 2, col = "green", pch = 3, cex = 1.5)
axis(1, at = 1:4, labels = y)
labels = c("ML", "GML", "Bayesian", "L-moments")

```

```

colors = c("blue", "red", "orange", "green")
pchh = c(6, 5, 4, 3)
legend("topright", inset = .03, labels, lwd = 3, lty = 1, col = colors, pch = pchh)
## สำหรับค่าประมาณพารามิเตอร์บ่งขนาด โดยใช้ค่า MSE ที่ได้ทั้งหมดจากแต่ละวิธี
ML = c(0.0544,0.0307,0.0213,0.0161)
GML = c(0.0915,0.0672,0.0667,0.0336)
Bayes = c(0.1320,0.0464,0.0296,0.0194)
LMOM = c(0.1154,0.0750,0.0748,0.0404)
y = c(30, 50, 70, 100)
x = seq(1,4)
plot(x, y, type = "b", lty = 3, lwd = 2, col = "black", xaxt = "n", ylim = c(0.01,0.14),
main = "Scale", xlab = "n", ylab = " MSE ", pch = 8, cex = 1.5)
lines(x, ML, type = "b", lty = 2, lwd = 2, col = "blue", pch = 6, cex = 1.5)
lines(x, GML,type = "b", lty = 1, lwd = 2.9, col = "red", pch = 5, cex = 1.5)
lines(x, Bayes, type = "b", lty = 4, lwd = 2.9, col = "orange", pch = 4, cex = 1.5)
lines(x, LMOM, type = "b", lty = 5, lwd = 2, col = "green", pch = 3, cex = 1.5)
axis(1, at = 1:4, labels = y)
labels = c("ML", "GML", "Bayesian", "L-moments")
colors = c("blue", "red", "orange", "green")
pchh = c(6, 5, 4, 3)
legend("topright", inset = .03, labels, lwd = 3, lty = 1, col = colors, pch = pchh)
## สำหรับค่าประมาณพารามิเตอร์บ่งรูปร่าง โดยใช้ค่า MSE ที่ได้ทั้งหมดจากแต่ละวิธี
ML = c(0.0496,0.0303,0.0202,0.0123)
GML = c(0.0551,0.0316,0.025,0.0204)
Bayes = c(0.0538,0.0306,0.0206,0.0126)
LMOM = c(0.0659,0.0483,0.0355,0.0284)
y = c(30, 50, 70, 100)
x = seq(1,4)
plot(x, y, type = "b", lty = 3, lwd = 2, col = "black", xaxt = "n", ylim = c(0.01,0.14),
main = "Shape", xlab = "n", ylab = " MSE ", pch = 8, cex = 1.5)
lines(x, ML, type = "b", lty = 2, lwd = 2, col = "blue", pch = 6, cex = 1.5)

```

```

lines(x, GML,type = "b", lty = 1, lwd = 2.9, col = "red", pch = 5, cex = 1.5)
lines(x, Bayes, type = "b", lty = 4, lwd = 2.9, col = "orange", pch = 4, cex = 1.5)
lines(x, LMOM, type = "b", lty = 5, lwd = 2, col = "green", pch = 3, cex = 1.5)
axis(1, at = 1:4, labels = y)
labels = c("ML", "GML", "Bayesian", "L-moments")
colors = c("blue", "red", "orange", "green")
pchh = c(6, 5, 4, 3)
legend("topright", inset = .03, labels, lwd = 3, lty = 1, col = colors, pch = pchh)
# กรณีที่ 2 เมื่อค่าประมาณพารามิเตอร์รูปร่างเท่ากับศูนย์
## สำหรับค่าประมาณพารามิเตอร์บ่งตำแหน่ง โดยใช้ค่า MSE ที่ได้ทั้งหมดจากแต่ละวิธี
ML = c(0.0494,0.0256,0.0193,0.0121)
GML = c(0.046,0.0246,0.01921,0.0122)
Bayes = c(0.0491,0.0254,0.01929,0.0120)
LMOM = c(0.0465,0.0249,0.01916,0.0121)
y = c(30, 50, 70, 100)
x = seq(1,4)
plot(x, y, type = "b", lty = 3, lwd = 2, col = "black", xaxt = "n", ylim = c(0.001,0.05),
      main = "Location", xlab = "n", ylab = " MSE ", pch = 8, cex = 1.5)
lines(x, ML, type = "b", lty = 2, lwd = 2, col = "blue", pch = 6, cex = 1.5)
lines(x, GML,type = "b", lty = 1, lwd = 2.9, col = "red", pch = 5, cex = 1.5)
lines(x, Bayes, type = "b", lty = 4, lwd = 2.9, col = "orange", pch = 4, cex = 1.5)
lines(x, LMOM, type = "b", lty = 5, lwd = 2, col = "green", pch = 3, cex = 1.5)
axis(1, at = 1:4, labels = y)
labels = c("ML", "GML", "Bayesian", "L-moments")
colors = c("blue", "red", "orange", "green")
pchh = c(6, 5, 4, 3)
legend("topright", inset = .03, labels, lwd = 3, lty = 1, col = colors, pch = pchh)
## สำหรับค่าประมาณพารามิเตอร์บ่งขนาด โดยใช้ค่า MSE ที่ได้ทั้งหมดจากแต่ละวิธี
ML = c(0.0258,0.0157,0.01,0.0066)
GML = c(0.0235,0.0146,0.0117,0.0073)
Bayes = c(0.0389,0.0183,0.0117,0.0073)

```

```

LMOM = c(0.0266,0.0168,0.011,0.0074)
y = c(30, 50, 70, 100)
x = seq(1,4)
plot(x, y, type = "b", lty = 3, lwd = 2, col = "black", xaxt = "n", ylim = c(0.001,0.05),
main = "Scale", xlab = "n", ylab = " MSE ", pch = 8, cex = 1.5)
lines(x, ML, type = "b", lty = 2, lwd = 2, col = "blue", pch = 6, cex = 1.5)
lines(x, GML,type = "b", lty = 1, lwd = 2.9, col = "red", pch = 5, cex = 1.5)
lines(x, Bayes, type = "b", lty = 4, lwd = 2.9, col = "orange", pch = 4, cex = 1.5)
lines(x, LMOM, type = "b", lty = 5, lwd = 2, col = "green", pch = 3, cex = 1.5)
axis(1, at = 1:4, labels = y)
labels = c("ML", "GML", "Bayesian", "L-moments")
colors = c("blue", "red", "orange", "green")
pchh = c(6, 5, 4, 3)
legend("topright", inset = .03, labels, lwd = 3, lty = 1, col = colors, pch = pchh)
## สำหรับค่าประมาณพารามิเตอร์บ่งรูปร่าง โดยใช้ค่า MSE ที่ได้ทั้งหมดจากแต่ละวิธี
ML = c(0.028,0.0153,0.0099,0.0058)
GML = c(0.0122,0.0085,0.0067,0.005)
Bayes = c(0.0312,0.0157,0.01,0.0058)
LMOM = c(0.0197,0.0131,0.0094,0.006)
y = c(30, 50, 70, 100)
x = seq(1,4)
plot(x, y, type = "b", lty = 3, lwd = 2, col = "black", xaxt = "n", ylim = c(0.001,0.05),
main = "Shape", xlab = "n", ylab = " MSE ", pch = 8, cex = 1.5)
lines(x, ML, type = "b", lty = 2, lwd = 2, col = "blue", pch = 6, cex = 1.5)
lines(x, GML,type = "b", lty = 1, lwd = 2.9, col = "red", pch = 5, cex = 1.5)
lines(x, Bayes, type = "b", lty = 4, lwd = 2.9, col = "orange", pch = 4, cex = 1.5)
lines(x, LMOM, type = "b", lty = 5, lwd = 2, col = "green", pch = 3, cex = 1.5)
axis(1, at = 1:4, labels = y)
labels = c("ML", "GML", "Bayesian", "L-moments")
colors = c("blue", "red", "orange", "green")
pchh = c(6, 5, 4, 3)

```

```

legend("topright", inset = .03, labels, lwd = 3, lty = 1, col = colors, pch = pchh)
# กรณีที่ 3 เมื่อค่าประมาณพารามิเตอร์บ่งรูปร่างมากกว่าศูนย์
## สำหรับค่าประมาณพารามิเตอร์บ่งตำแหน่ง โดยใช้ค่า MSE ที่ได้ทั้งหมดจากแต่ละวิธี
ML = c(0.0607,0.0813,0.022,0.0381)
GML = c(0.0477,0.0369,0.0299,0.0593)
Bayes = c(0.0576,0.0263,0.0194,0.0125)
LMOM = c(0.039,0.0264,0.0193,0.0126)
y = c(30, 50, 70, 100)
x = seq(1,4)
plot(x, y, type = "b", lty = 3, lwd = 2, col = "black", xaxt = "n", ylim = c(0.001,0.33),
     main = "Location", xlab = "n", ylab = " MSE ", pch = 8, cex = 1.5)
lines(x, ML, type = "b", lty = 2, lwd = 2, col = "blue", pch = 6, cex = 1.5)
lines(x, GML,type = "b", lty = 1, lwd = 2.9, col = "red", pch = 5, cex = 1.5)
lines(x, Bayes, type = "b", lty = 4, lwd = 2.9, col = "orange", pch = 4, cex = 1.5)
lines(x, LMOM, type = "b", lty = 5, lwd = 2, col = "green", pch = 3, cex = 1.5)
axis(1, at = 1:4, labels = y)
labels = c("ML", "GML", "Bayesian", "L-moments")
colors = c("blue", "red", "orange", "green")
pchh = c(6, 5, 4, 3)
legend("topright", inset = .03, labels, lwd = 3, lty = 1, col = colors, pch = pchh)
## สำหรับค่าประมาณพารามิเตอร์บ่งขนาด โดยใช้ค่า MSE ที่ได้ทั้งหมดจากแต่ละวิธี
ML = c(0.191,0.2619,0.054,0.0998)
GML = c(0.0347,0.0221,0.0148,0.0226)
Bayes = c(0.0786,0.0227,0.0138,0.0105)
LMOM = c(0.0343,0.0189,0.0121,0.0084)
y = c(30, 50, 70, 100)
x = seq(1,4)
plot(x, y, type = "b", lty = 3, lwd = 2, col = "black", xaxt = "n", ylim = c(0.001,0.33),
     main = "Scale", xlab = "n", ylab = " MSE ", pch = 8, cex = 1.5)
lines(x, ML, type = "b", lty = 2, lwd = 2, col = "blue", pch = 6, cex = 1.5)
lines(x, GML,type = "b", lty = 1, lwd = 2.9, col = "red", pch = 5, cex = 1.5)

```

```

lines(x, Bayes, type = "b", lty = 4, lwd = 2.9, col = "orange", pch = 4, cex = 1.5)
lines(x, LMOM, type = "b", lty = 5, lwd = 2, col = "green", pch = 3, cex = 1.5)
axis(1, at = 1:4, labels = y)
labels = c("ML", "GML", "Bayesian", "L-moments")
colors = c("blue", "red", "orange", "green")
pchh = c(6, 5, 4, 3)
legend("topright", inset = .03, labels, lwd = 3, lty = 1, col = colors, pch = pchh)
## สำหรับค่าประมาณพารามิเตอร์ปรงูปร่าง โดยใช้ค่า MSE ที่ได้ทั้งหมดจากแต่ละวิธี
ML = c(0.1116,0.0347,0.012,0.0132)
GML = c(0.0414,0.0197,0.0162,0.0142)
Bayes = c(0.0263,0.0119,0.007,0.0048)
LMOM = c(0.0343,0.0189,0.0121,0.0084)
y = c(30, 50, 70, 100)
x = seq(1,4)
plot(x, y, type = "b", lty = 3, lwd = 2, col = "black", xaxt = "n", ylim = c(0.001,0.33),
main = "Shape", xlab = "n", ylab = "MSE", pch = 8, cex = 1.5)
lines(x, ML, type = "b", lty = 2, lwd = 2, col = "blue", pch = 6, cex = 1.5)
lines(x, GML,type = "b", lty = 1, lwd = 2.9, col = "red", pch = 5, cex = 1.5)
lines(x, Bayes, type = "b", lty = 4, lwd = 2.9, col = "orange", pch = 4, cex = 1.5)
lines(x, LMOM, type = "b", lty = 5, lwd = 2, col = "green", pch = 3, cex = 1.5)
axis(1, at = 1:4, labels = y)
labels = c("ML", "GML", "Bayesian", "L-moments")
colors = c("blue", "red", "orange", "green")
pchh = c(6, 5, 4, 3)
legend("topright", inset = .03, labels, lwd = 3, lty = 1, col = colors, pch = pchh)

```

คำสั่งโปรแกรมอาร์ที่ใช้ในงานวิจัยสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายปีจากการแจกแจงค่าสุดขีดวงนัยทั่วไป

```
# -----
# สร้างกราฟอนุกรมเวลาและฮิสโทแกรมสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายปีสถานีศูนย์การ
# ประชุมแห่งชาติสิริกิติ์
qsncc <- attach(X455201_max_rainfall_data_in_each_year)
x_qsncc <- qsncc$Year
y_qsncc <- qsncc$`Max Rainfall (mm)`
plot(x_qsncc, y_qsncc, type = "l", xlab = "year", ylab = "maximum rainfall (mm)", ylim
     = c(0,300), main = "Yearly Maximum Rainfall of SQNCC Station")
hist(y_qsncc, xlab = "millimeters", main = "SQNCC Station")
# สร้างกราฟอนุกรมเวลาและฮิสโทแกรมสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายปีสถานีดอนเมือง
dm <- attach(X455601_max_rainfall_data_in_each_year)
x_dm <- dm$Year
y_dm <- dm$`maximum rainfall (mm)`
plot(x_dm, y_dm, type = "l", xlab = "year", ylab = "maximum rainfall (mm)", ylim
     = c(0,300), main = "Yearly Maximum Rainfall of Don Muang Station")
hist(y_dm, xlab = "millimeters", main = "Don Muang Station")
# สร้างกราฟอนุกรมเวลาและฮิสโทแกรมสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายปีสถานีบางนา
bn <- attach(X455301_max_rainfall_data_in_each_year)
x_bn <- bn$Year
y_bn <- bn$`maximum rainfall (mm)`
plot(x_bn, y_bn, type = "l", xlab = "year", ylab = "maximum rainfall (mm)", ylim
     = c(0,300), main = "Yearly Maximum Rainfall of Bang Na Station")
hist(y_bn, xlab = "millimeters", main = "Bang Na Station")
# สร้างกราฟอนุกรมเวลาและฮิสโทแกรมสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายปีสถานีคลองเตย
kt <- attach(X455203_max_rainfall_data_in_each_year)
x_kt <- kt$Year
y_kt <- kt$`maximum rainfall (mm)`
plot(x_kt, y_kt, type = "l", xlab = "year", ylab = "maximum rainfall (mm)", ylim
     = c(0,300), main = "Yearly Maximum Rainfall of Klong Toey Station")
```

```

hist(y_kt, xlab = "millimeters", main = "Klong Toey Station")
# -----
# คำนวณค่าสถิติพื้นฐานสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายปีแต่ละสถานีตรวจวัดระดับน้ำ
library(moments)
area <- c("SQNCC", "DONMUANG", "BANGNA", "KLONGTOEY")
mean_area <- round(c(mean(y_qsncc), mean(y_dm), mean(y_bn), mean(y_kt)), 4)
sd_area <- round(c(sd(y_qsncc), sd(y_dm), sd(y_bn), sd(y_kt)), 4)
m3_area <- round(c(skewness(y_qsncc), skewness(y_dm), skewness(y_bn),
skewness(y_kt)), 4)
m4_area <- round(c(kurtosis(y_qsncc), kurtosis(y_dm), kurtosis(y_bn), kurtosis(y_kt)), 4)
min_area <- c(min(y_qsncc), min(y_dm), min(y_bn), min(y_kt))
max_area <- c(max(y_qsncc), max(y_dm), max(y_bn), max(y_kt))
data.frame(area, mean_area, sd_area, m3_area, m4_area, min_area, max_area)
# -----
# สร้างตัวแบบและคำนวณค่าประมาณพารามิเตอร์แต่ละวิธีสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายปี
ของสถานีศูนย์การประชุมแห่งชาติสิริกิติ์
fit1_sqncc <- fevd(y_qsncc[1:20], type = "GEV", method = "MLE")
fit2_sqncc <- fevd(y_qsncc[1:20], type = "GEV", method = "GMLE")
fit3_sqncc <- fevd(y_qsncc[1:20], type = "GEV", method = "Bayesian", iter = 2000)
fit4_sqncc <- fevd(y_qsncc[1:20], type = "GEV", method = "Lmoments")
loc_sqncc <- c(mean(findpars(fit1_sqncc)$location),
              mean(findpars(fit2_sqncc)$location), mean(findpars(fit3_sqncc)$location),
              findpars(fit4_sqncc)[1])
sca_sqncc <- c(mean(findpars(fit1_sqncc)$scale), mean(findpars(fit2_sqncc)$scale),
              mean(findpars(fit3_sqncc)$scale), findpars(fit4_sqncc)[2])
sha_sqncc <- c(mean(findpars(fit1_sqncc)$shape), mean(findpars(fit2_sqncc)$shape),
              mean(findpars(fit3_sqncc)$shape), findpars(fit4_sqncc)[3])
parameter_sqncc <- data.frame(loc_sqncc, sca_sqncc, sha_sqncc)
# สร้างตัวแบบและคำนวณค่าประมาณพารามิเตอร์แต่ละวิธีสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายปี
ของสถานีดอนเมือง
fit1_dm <- fevd(y_dm[1:20], type = "GEV", method = "MLE" )

```

```

fit2_dm <- fevd(y_dm[1:20], type = "GEV", method = "GMLE" )
fit3_dm <- fevd(y_dm[1:20], type = "GEV", method = "Bayesian", iter = 2000)
fit4_dm <- fevd(y_dm[1:20], type = "GEV", method = "Lmoments")
loc_dm <- c(mean(findpars(fit1_dm)$location), mean(findpars(fit2_dm)$location),
            mean(findpars(fit3_dm)$location), findpars(fit4_dm)[1])
sca_dm <- c(mean(findpars(fit1_dm)$scale), mean(findpars(fit2_dm)$scale),
            mean(findpars(fit3_dm)$scale), findpars(fit4_dm)[2])
sha_dm <- c(mean(findpars(fit1_dm)$shape), mean(findpars(fit2_dm)$shape),
            mean(findpars(fit3_dm)$shape), findpars(fit4_dm)[3])
parameter_dm <- data.frame(loc_dm, sca_dm, sha_dm)
# สร้างตัวแบบและคำนวณค่าประมาณพารามิเตอร์แต่ละวิธีสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายปี
# ของสถานีบางนา
fit1_bn <- fevd(y_bn[1:20], type = "GEV", method = "MLE" )
fit2_bn <- fevd(y_bn[1:20], type = "GEV", method = "GMLE" )
fit3_bn <- fevd(y_bn[1:20], type = "GEV", method = "Bayesian", iter = 2000)
fit4_bn <- fevd(y_bn[1:20], type = "GEV", method = "Lmoments")
loc_bn <- c(mean(findpars(fit1_bn)$location), mean(findpars(fit2_bn)$location),
            mean(findpars(fit3_bn)$location), findpars(fit4_bn)[1])
sca_bn <- c(mean(findpars(fit1_bn)$scale), mean(findpars(fit2_bn)$scale),
            mean(findpars(fit3_bn)$scale), findpars(fit4_bn)[2])
sha_bn <- c(mean(findpars(fit1_bn)$shape), mean(findpars(fit2_bn)$shape),
            mean(findpars(fit3_bn)$shape), findpars(fit4_bn)[3])
parameter_bn <- data.frame(loc_bn, sca_bn, sha_bn)
# สร้างตัวแบบและคำนวณค่าประมาณพารามิเตอร์แต่ละวิธีสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายปี
# ของสถานีคลองเตย
fit1_kt <- fevd(y_kt[1:20], type = "GEV", method = "MLE" )
fit2_kt <- fevd(y_kt[1:20], type = "GEV", method = "GMLE" )
fit3_kt <- fevd(y_kt[1:20], type = "GEV", method = "Bayesian", iter = 2000)
fit4_kt <- fevd(y_kt[1:20], type = "GEV", method = "Lmoments")
loc_kt <- c(mean(findpars(fit1_kt)$location), mean(findpars(fit2_kt)$location),
            mean(findpars(fit3_kt)$location), findpars(fit4_kt)[1])

```

```

sca_kt <- c(mean(findpars(fit1_kt)$scale), mean(findpars(fit2_kt)$scale),
            mean(findpars(fit3_kt)$scale), findpars(fit4_kt)[2])
sha_kt <- c(mean(findpars(fit1_kt)$shape), mean(findpars(fit2_kt)$shape),
            mean(findpars(fit3_kt)$shape), findpars(fit4_kt)[3])
parameter_kt <- data.frame(loc_kt, sca_kt, sha_kt)
# -----
# คำนวณระดับการเกิดซ้ำสำหรับข้อมูลปริมาณน้ำฝนสูงสุดสถานีศูนย์การประชุมแห่งชาติสิริกิติ์
re1_sqncc <- return.level(fit1_sqncc, return.period = seq(2,10), method = c("normal"),
                        do.ci = FALSE, verbose = FALSE, qcov = NULL, qcov.base = NULL)
re2_sqncc <- return.level(fit2_sqncc, return.period = seq(2,10), method = c("normal"),
                        do.ci = FALSE, verbose = FALSE, qcov = NULL, qcov.base = NULL)
re3_sqncc <- return.level(fit3_sqncc, return.period = seq(2,10), method = c("normal"),
                        do.ci = FALSE, verbose = FALSE, qcov = NULL, qcov.base = NULL)
re4_sqncc <- return.level(fit4_sqncc, return.period = seq(2,10), method = c("normal"),
                        do.ci = FALSE, verbose = FALSE, qcov = NULL, qcov.base = NULL)
# คำนวณระดับการเกิดซ้ำสำหรับข้อมูลปริมาณน้ำฝนสูงสุดสถานีดอนเมือง
re1_dm <- return.level(fit1_dm, return.period = seq(2,10), method = c("normal"), do.ci
                      = FALSE, verbose = FALSE, qcov = NULL, qcov.base = NULL)
re2_dm <- return.level(fit2_dm, return.period = seq(2,10), method = c("normal"), do.ci
                      = FALSE, verbose = FALSE, qcov = NULL, qcov.base = NULL)
re3_dm <- return.level(fit3_dm, return.period = seq(2,10), method = c("normal"), do.ci
                      = FALSE, verbose = FALSE, qcov = NULL, qcov.base = NULL)
re4_dm <- return.level(fit4_dm, return.period = seq(2,10), method = c("normal"), do.ci
                      = FALSE, verbose = FALSE, qcov = NULL, qcov.base = NULL)
# คำนวณระดับการเกิดซ้ำสำหรับข้อมูลปริมาณน้ำฝนสูงสุดสถานีบางนา
re1_bn <- return.level(fit1_bn, return.period = seq(2,10), method = c("normal"), do.ci
                      = FALSE, verbose = FALSE, qcov = NULL, qcov.base = NULL)
re2_bn <- return.level(fit2_bn, return.period = seq(2,10), method = c("normal"), do.ci
                      = FALSE, verbose = FALSE, qcov = NULL, qcov.base = NULL)
re3_bn <- return.level(fit3_bn, return.period = seq(2,10), method = c("normal"), do.ci
                      = FALSE, verbose = FALSE, qcov = NULL, qcov.base = NULL)

```

```

re4_bn <- return.level(fit4_bn, return.period = seq(2,10), method = c("normal"), do.ci
= FALSE, verbose = FALSE, qcov = NULL, qcov.base = NULL)
# คำนวณระดับการเกิดซ้ำสำหรับข้อมูลปริมาณน้ำฝนสูงสุดสถานีคลองเตย
re1_kt <- return.level(fit1_kt, return.period = seq(2,10), method = c("normal"), do.ci =
FALSE, verbose = FALSE, qcov = NULL, qcov.base = NULL)
re2_kt <- return.level(fit2_kt, return.period = seq(2,10), method = c("normal"), do.ci =
FALSE, verbose = FALSE, qcov = NULL, qcov.base = NULL)
re3_kt <- return.level(fit3_kt, return.period = seq(2,10), method = c("normal"), do.ci =
FALSE, verbose = FALSE, qcov = NULL, qcov.base = NULL)
re4_kt <- return.level(fit4_kt, return.period = seq(2,10), method = c("normal"), do.ci =
FALSE, verbose = FALSE, qcov = NULL, qcov.base = NULL)
# -----
# pp plot, qq plot และ density plot สำหรับข้อมูลปริมาณน้ำฝนสูงสุดสถานีศูนย์การประชุม
แห่งชาติสิริกิติ์
par(mfrow = c(1,3))
plot(fit2_sqncc, main = "PP Plot", type = "probprob")
plot(fit2_sqncc, main = "QQ Plot", type = "qq")
plot(fit2_sqncc, main = "Density Plot", type = "density")
mtext("Diagnostic Plot for Yearly Maximum Rainfall at QSNCC", outer = TRUE, side = 3,
line = -1.5, cex = 1.1)
# pp plot, qq plot และ density plot สำหรับข้อมูลปริมาณน้ำฝนสูงสุดสถานีดอนเมือง
plot(fit4_dm, main = "PP Plot", type = "probprob")
plot(fit4_dm, main = "QQ Plot", type = "qq")
plot(fit4_dm, main = "Density Plot", type = "density")
mtext("Diagnostic Plot for Yearly Maximum Rainfall at DONMUANG", outer = TRUE,
side = 3, line = -1.5, cex = 1.1)
# pp plot, qq plot และ density plot สำหรับข้อมูลปริมาณน้ำฝนสูงสุดสถานีบางนา
plot(fit1_bn, main = "PP Plot", type = "probprob")
plot(fit1_bn, main = "QQ Plot", type = "qq")
plot(fit1_bn, main = "Density Plot", type = "density")

```

```

mtext("Diagnostic Plot for Yearly Maximum Rainfall at BANGNA", outer = TRUE, side =
3, line = -1.5, cex = 1.1)
# pp plot, qq plot และ density plot สำหรับข้อมูลปริมาณน้ำฝนสูงสุดสถานีคลองเตย
plot(fit2_kt, main = "PP Plot", type = "probprob")
plot(fit2_kt, main = "QQ Plot", type = "qq")
plot(fit2_kt, main = "Density Plot", type = "density")
mtext("Diagnostic Plot for Yearly Maximum Rainfall at KLONGTOEY", outer = TRUE,
side = 3, line = -1.5, cex = 1.1)
# -----
# พล็อตกราฟแสดงการเปรียบเทียบค่าประมาณระดับการเกิดซ้ำสำหรับวิธีการประมาณค่าที่ทำให้ตัว
แบบสำหรับแต่ละสถานีมีค่า MAPE ต่ำสุด
compare_year <- attach(estimate)
re <- return_level
plot(return_level, gmle_qsncc, type = 'b', lty = 1, lwd = 1.5, xlim = c(2,10), ylim =
c(90,160), col = "slateblue1", xlab = 'Return Period (Year)', ylab = 'Rainfall (mm)',
pch = 15, main = "Return Level of Each Station")
lines(return_level, lmom_dm, type = 'b', col = "orangered", lty = 1, lwd = 1.5,
pch = 17)
lines(return_level, mte_bn, type = 'b', col = "midnightblue", lty = 1, lwd = 1.5,
pch = 25)
lines(return_level, gmle_kt, type = 'b', col = "green4", lty = 1, lwd = 1.5, pch = 18)
labels <- c("SONCC", "DONMUANG", "BANGNA", "KLONGTOEY")
pchset <- c(15, 16, 17, 25, 18)
colorset <- c("slateblue1", "orangered", "midnightblue", "green4")
legend("bottom", horiz = TRUE, inset = .01, labels, lwd = 2, lty = 1, pch = pchset,
col=colorset, cex=0.6)

```

คำสั่งโปรแกรมอาร์ที่ใช้ในงานวิจัยสำหรับการจำลองข้อมูลจากการแจกแจงพารेटอวางนัยทั่วไป

```

library(extRemes)

library(evd)

# -----

# Density plot สำหรับการแจกแจงพารेटอวางนัยทั่วไป
x <- seq(2.1, 10, len = 10000)
y1 <- dgpdx(x, u = 2, sigma = 2, xi = -0.3)
y2 <- dgpdx(x, u = 2, sigma = 2, xi = 0)
y3 <- dgpdx(x, u = 2, sigma = 2, xi = 0.3)
plot(x, y1, type="l", col="red", lty=1, lwd=2, ylim=c(0,0.5), ylab = "Density", main =
      "Generalized Pareto Density")
points(x, y2, type="l", col="blue", lty=1, lwd=2)
points(x, y3, type="l", col="green", lty=1, lwd=2)
labels = c("shape = -0.3", "shape = 0", "shape = 0.3")
colors = c("red", "blue", "green")
A = c(1,1,1)
legend("topright", inset=0.05, labels, lwd=2, lty=A, col=colors)

# -----

# จำลองข้อมูลและประมาณค่าพารามิเตอร์จากการแจกแจงพารेटอวางนัยทั่วไป เมื่อ m แทนจำนวน
รอบในการทำซ้ำ n แทนขนาดตัวอย่าง a, b และ c แทนค่าพารามิเตอร์บ่งตำแหน่ง พารามิเตอร์บ่ง
ขนาด และพารามิเตอร์บ่งรูปร่างตามลำดับ และ p แทนตำแหน่งของเปอร์เซ็นต์ไทล์ที่ใช้ในการ
กำหนดค่าเกณฑ์

m = 1000; n = 700; a = 2; b = 2; c = 0.3; p = 0.95
# สร้างเวกเตอร์สำหรับเก็บค่าประมาณพารามิเตอร์

loc1 = c(); sca1 = c(); sha1 = c() # สำหรับวิธี ML
loc2 = c(); sca2 = c(); sha2 = c() # สำหรับวิธี GML
loc3 = c(); sca3 = c(); sha3 = c() # สำหรับวิธี Bayesian
loc4 = c(); sca4 = c(); sha4 = c() # สำหรับวิธี L-moments

# for loop สำหรับการจำลองข้อมูล โดยวนซ้ำ m ครั้ง
for (r in 1:m) {
  z <- rgpd(n, loc = a, scale = b, shape = c)

```

```

fit1 <- fevd(z, threshold = quantile(z,p), type = "GP", method = "MLE" )
fit2 <- fevd(z, threshold = quantile(z,p), type = "GP", method = "GMLE" )
fit3 <- fevd(z, threshold = quantile(z,p), type = "GP", method = "Bayesian",iter =2000)
fit4 <- fevd(z, threshold = quantile(z,p), type = "GP", method = "Lmoments")
loc1[r] = quantile(z,p)
sca1[r] = mean(findpars(fit1)$scale)
sha1[r] = mean(findpars(fit1)$shape)
loc2[r] = quantile(z,p)
sca2[r] = mean(findpars(fit2)$scale)
sha2[r] = mean(findpars(fit2)$shape)
loc3[r] = quantile(z,p)
sca3[r] = mean(findpars(fit3)$scale)
sha3[r] = mean(findpars(fit3)$shape)
loc4[r] = quantile(z,p)
sca4[r] = findpars(fit4)[1]
sha4[r] = findpars(fit4)[2]
cat("Round : ", r, "\n")
}
# ประมาณค่าพารามิเตอร์สำหรับแต่ละวิธีที่ใช้ในการประมาณค่าพารามิเตอร์
est_loc = c(mean(loc1), mean(loc2), mean(loc3), mean(loc4))
est_sca = c(mean(sca1), mean(sca2), mean(sca3), mean(sca4))
est_sha = c(mean sha1), mean sha2), mean sha3), mean sha4))
est = round(data.frame(est_loc,est_sca,est_sha),4)
# คำนวณค่า MSE ของค่าประมาณพารามิเตอร์บ่งตำแหน่งสำหรับแต่ละวิธี
mse_loc1 = mean((a - loc1)^2)
mse_loc2 = mean((a - loc2)^2)
mse_loc3 = mean((a - loc3)^2)
mse_loc4 = mean((a - loc4)^2)
# คำนวณค่า MSE ของค่าประมาณพารามิเตอร์บ่งขนาดสำหรับแต่ละวิธี
mse_sca1 = mean((b - sca1)^2)
mse_sca2 = mean((b - sca2)^2)

```

```

mse_sca3 = mean((b - sca3)^2)
mse_sca4 = mean((b - sca4)^2)
# คำนวณค่า MSE ของค่าประมาณพารามิเตอร์บ่งรูปร่างสำหรับแต่ละวิธี
mse_sha1 = mean((c - sha1)^2)
mse_sha2 = mean((c - sha2)^2)
mse_sha3 = mean((c - sha3)^2)
mse_sha4 = mean((c - sha4)^2)
mse_loc = c(mse_loc1,mse_loc2,mse_loc3,mse_loc4)
mse_sca = c(mse_sca1,mse_sca2,mse_sca3,mse_sca4)
mse_sha = c(mse_sha1,mse_sha2,mse_sha3,mse_sha4)
mse = round(data.frame(mse_loc,mse_sca,mse_sha),4)
# คำนวณค่าส่วนเบี่ยงเบนมาตรฐานของค่าประมาณพารามิเตอร์บ่งตำแหน่งสำหรับแต่ละวิธี
sd_loc1 = sd(loc1, a)
sd_loc2 = sd(loc2, a)
sd_loc3 = sd(loc3, a)
sd_loc4 = sd(loc4, a)
# คำนวณค่าส่วนเบี่ยงเบนมาตรฐานของค่าประมาณพารามิเตอร์บ่งขนาดสำหรับแต่ละวิธี
sd_sca1 = sd(sca1, b)
sd_sca2 = sd(sca2, b)
sd_sca3 = sd(sca3, b)
sd_sca4 = sd(sca4, b)
# คำนวณค่าส่วนเบี่ยงเบนมาตรฐานของค่าประมาณพารามิเตอร์บ่งรูปร่างสำหรับแต่ละวิธี
sd_sha1 = sd(sha1, c)
sd_sha2 = sd(sha2, c)
sd_sha3 = sd(sha3, c)
sd_sha4 = sd(sha4, c)
sd_loc = c(sd_loc1,sd_loc2,sd_loc3,sd_loc4)
sd_sca = c(sd_sca1,sd_sca2,sd_sca3,sd_sca4)
sd_sha = c(sd_sha1,sd_sha2,sd_sha3,sd_sha4)
sd = round(data.frame(sd_loc,sd_sca,sd_sha),4)
method = c("MLE","GMLE","BAYSIANS","LMOMENT")

```

```

output_GP = data.frame(method,est,mse,sd)
# -----
# พล็อตกราฟ MSE
par(mfrow=c(1,3))
# กรณีที่ 1 เมื่อค่าประมาณพารามิเตอร์บ่งรูปร่างน้อยกว่าศูนย์ ในตำแหน่งเปอร์เซ็นต์ไทล์ที่ 85
## สำหรับค่าประมาณพารามิเตอร์บ่งตำแหน่ง โดยใช้ค่า MSE ที่ได้ทั้งหมดจากแต่ละวิธี
ML = c(8.3305, 8.3462, 8.3603, 8.3512)
GML = c(8.3305, 8.3462, 8.3603, 8.3512)
Bayes = c(8.3305, 8.3462, 8.3603, 8.3512)
LMOM = c(8.3305, 8.3462, 8.3603, 8.3512)
y = c(300, 500, 700, 1000) # ขนาดตัวอย่าง (n) ทั้งหมดจากการจำลอง
x = seq(1,4)
plot(x, y, type = "b", lty = 3, lwd = 2, col = "black", xaxt = "n", ylim = c(8.31,8.40),
     main = "Location", xlab = "n", ylab = "MSE", pch = 8, cex = 1.5)
lines(x, ML, type = "b", lty = 2, lwd = 2, col = "blue", pch = 6, cex = 1.5)
lines(x, GML, type = "b", lty = 1, lwd = 2.9, col = "red", pch = 5, cex = 1.5)
lines(x, Bayes, type = "b", lty = 4, lwd = 2.9, col = "orange", pch = 4, cex = 1.5)
lines(x, LMOM, type = "b", lty = 5, lwd = 2, col = "green", pch = 3, cex = 1.5)
axis(1, at = 1:4, labels = y)
labels = c("ML", "GML", "Bayesian", "L-moments")
colors = c("blue", "red", "orange", "green")
pchh = c(6, 5, 4, 3)
legend("topright", inset = .03, labels, lwd = 3, lty = 1, col = colors, pch = pchh)
## สำหรับค่าประมาณพารามิเตอร์บ่งขนาด โดยใช้ค่า MSE ที่ได้ทั้งหมดจากแต่ละวิธี
ML = c(0.6591, 0.6970, 0.7230, 0.7190)
GML = c(0.9728, 0.9544, 0.9359, 0.8858)
Bayes = c(0.7663, 0.7648, 0.7761, 0.7568)
LMOM = c(0.7956, 0.7825, 0.7952, 0.7698)
y = c(300, 500, 700, 1000)
x = seq(1,4)

```

```

plot(x, y, type = "b", lty = 3, lwd = 2, col = "black", xaxt = "n", ylim = c(0.61,1.19), main
= "Scale", xlab = "n", ylab = " MSE ", pch = 8, cex = 1.5)
lines(x, ML, type = "b", lty = 2, lwd = 2, col = "blue", pch = 6, cex = 1.5)
lines(x, GML,type = "b", lty = 1, lwd = 2.9, col = "red", pch = 5, cex = 1.5)
lines(x, Bayes, type = "b", lty = 4, lwd = 2.9, col = "orange", pch = 4, cex = 1.5)
lines(x, LMOM, type = "b", lty = 5, lwd = 2, col = "green", pch = 3, cex = 1.5)
axis(1, at = 1:4, labels = y)
labels = c("ML", "GML", "Bayesian", "L-moments")
colors = c("blue", "red", "orange", "green")
pchh = c(6, 5, 4, 3)
legend("topright", inset = .03, labels, lwd = 3, lty = 1, col = colors, pch = pchh)
## สำหรับค่าประมาณพารามิเตอร์บ่งรูปร่าง โดยใช้ค่า MSE ที่ได้ทั้งหมดจากแต่ละวิธี
ML = c(0.0386, 0.0155, 0.0093, 0.0057)
GML = c(0.0285, 0.0206, 0.0157, 0.0098)
Bayes = c(0.0362, 0.0146, 0.0090, 0.0052)
LMOM = c(0.0456, 0.0237, 0.0172, 0.0114)
y = c(300, 500, 700, 1000)
x = seq(1,4)
plot(x, y, type = "b", lty = 3, lwd = 2, col = "black", xaxt = "n", ylim = c(0.00,0.08), main
= "Shape", xlab = "n", ylab = " MSE ", pch = 8, cex = 1.5)
lines(x, ML, type = "b", lty = 2, lwd = 2, col = "blue", pch = 6, cex = 1.5)
lines(x, GML,type = "b", lty = 1, lwd = 2.9, col = "red", pch = 5, cex = 1.5)
lines(x, Bayes, type = "b", lty = 4, lwd = 2.9, col = "orange", pch = 4, cex = 1.5)
lines(x, LMOM, type = "b", lty = 5, lwd = 2, col = "green", pch = 3, cex = 1.5)
axis(1, at = 1:4, labels = y)
labels = c("ML", "GML", "Bayesian", "L-moments")
colors = c("blue", "red", "orange", "green")
pchh = c(6, 5, 4, 3)
legend("topright", inset = .03, labels, lwd = 3, lty = 1, col = colors, pch = pchh)
# กรณีที่ 2 เมื่อค่าประมาณพารามิเตอร์บ่งรูปร่างน้อยกว่าศูนย์ ในตำแหน่งเปอร์เซ็นต์ไทล์ที่ 90
## สำหรับค่าประมาณพารามิเตอร์บ่งตำแหน่ง โดยใช้ค่า MSE ที่ได้ทั้งหมดจากแต่ละวิธี

```

```

ML = c(10.9267, 10.9936, 11.0434, 11.0305)
GML = c(10.9267, 10.9936, 11.0434, 11.0305)
Bayes = c(10.9267, 10.9936, 11.0434, 11.0305)
LMOM = c(10.9267, 10.9936, 11.0434, 11.0305)
y = c(300, 500, 700, 1000)
x = seq(1,4)
plot(x, y, type = "b", lty = 3, lwd = 2, col = "black", xaxt = "n", ylim = c(10.90,11.14),
main = "Location", xlab = "n", ylab = " MSE ", pch = 8, cex = 1.5)
lines(x, ML, type = "b", lty = 2, lwd = 2, col = "blue", pch = 6, cex = 1.5)
lines(x, GML,type = "b", lty = 1, lwd = 2.9, col = "red", pch = 5, cex = 1.5)
lines(x, Bayes, type = "b", lty = 4, lwd = 2.9, col = "orange", pch = 4, cex = 1.5)
lines(x, LMOM, type = "b", lty = 5, lwd = 2, col = "green", pch = 3, cex = 1.5)
axis(1, at = 1:4, labels = y)
labels = c("ML", "GML", "Bayesian", "L-moments")
colors = c("blue", "red", "orange", "green")
pchh = c(6, 5, 4, 3)
legend("topright", inset = .03, labels, lwd = 3, lty = 1, col = colors, pch = pchh)
## สำหรับค่าประมาณพารามิเตอร์ป้ขนาด โดยใช้ค่า MSE ที่ได้ทั้งหมดจากแต่ละวิธี
ML = c(0.8524, 0.9145, 0.9344, 0.9482)
GML = c(1.2189, 1.2433, 1.2051, 1.1772)
Bayes = c(1.0173, 1.0174, 1.0092, 1.0033)
LMOM = c(1.0638, 1.0451, 1.0342, 1.0224)
y = c(300, 500, 700, 1000)
x = seq(1,4)
plot(x, y, type = "b", lty = 3, lwd = 2, col = "black", xaxt = "n", ylim = c(0.79,1.39), main =
"Scale", xlab = "n", ylab = " MSE ", pch = 8, cex = 1.5)
lines(x, ML, type = "b", lty = 2, lwd = 2, col = "blue", pch = 6, cex = 1.5)
lines(x, GML,type = "b", lty = 1, lwd = 2.9, col = "red", pch = 5, cex = 1.5)
lines(x, Bayes, type = "b", lty = 4, lwd = 2.9, col = "orange", pch = 4, cex = 1.5)
lines(x, LMOM, type = "b", lty = 5, lwd = 2, col = "green", pch = 3, cex = 1.5)
axis(1, at = 1:4, labels = y)

```

```

labels = c("ML", "GML", "Bayesian", "L-moments")
colors = c("blue", "red", "orange", "green")
pchh = c(6, 5, 4, 3)
legend("topright", inset = .03, labels, lwd = 3, lty = 1, col = colors, pch = pchh)
## สำหรับค่าประมาณพารามิเตอร์บ่งรูปร่าง โดยใช้ค่า MSE ที่ได้ทั้งหมดจากแต่ละวิธี
ML = c(0.0661, 0.0279, 0.0165, 0.0097)
GML = c(0.0344, 0.0259, 0.0215, 0.0161)
Bayes = c(0.0719, 0.0269, 0.0162, 0.0093)
LMOM = c(0.0616, 0.0356, 0.0269, 0.0183)
y = c(300, 500, 700, 1000)
x = seq(1,4)
plot(x, y, type = "b", lty = 3, lwd = 2, col = "black", xaxt = "n", ylim = c(0.00,0.09), main
= "Shape", xlab = "n", ylab = " MSE ", pch = 8, cex = 1.5)
lines(x, ML, type = "b", lty = 2, lwd = 2, col = "blue", pch = 6, cex = 1.5)
lines(x, GML,type = "b", lty = 1, lwd = 2.9, col = "red", pch = 5, cex = 1.5)
lines(x, Bayes, type = "b", lty = 4, lwd = 2.9, col = "orange", pch = 4, cex = 1.5)
lines(x, LMOM, type = "b", lty = 5, lwd = 2, col = "green", pch = 3, cex = 1.5)
axis(1, at = 1:4, labels = y)
labels = c("ML", "GML", "Bayesian", "L-moments")
colors = c("blue", "red", "orange", "green")
pchh = c(6, 5, 4, 3)
legend("topright", inset = .03, labels, lwd = 3, lty = 1, col = colors, pch = pchh)
# กรณีที่ 3 เมื่อค่าประมาณพารามิเตอร์บ่งรูปร่างน้อยกว่าศูนย์ ในตำแหน่งเปอร์เซ็นต์ไทล์ที่ 95
## สำหรับค่าประมาณพารามิเตอร์บ่งตำแหน่ง โดยใช้ค่า MSE ที่ได้ทั้งหมดจากแต่ละวิธี
ML = c(15.374, 15.5214, 15.5526, 15.5069)
GML = c(15.374, 15.5214, 15.5526, 15.5069)
Bayes = c(15.374, 15.5214, 15.5526, 15.5069)
LMOM = c(15.374, 15.5214, 15.5526, 15.5069)
y = c(300, 500, 700, 1000)
x = seq(1,4)

```

```

plot(x, y, type = "b", lty = 3, lwd = 2, col = "black", xaxt = "n", ylim = c(15.30,15.80),
main = "Location", xlab = "n", ylab = " MSE ", pch = 8, cex = 1.5)
lines(x, ML, type = "b", lty = 2, lwd = 2, col = "blue", pch = 6, cex = 1.5)
lines(x, GML,type = "b", lty = 1, lwd = 2.9, col = "red", pch = 5, cex = 1.5)
lines(x, Bayes, type = "b", lty = 4, lwd = 2.9, col = "orange", pch = 4, cex = 1.5)
lines(x, LMOM, type = "b", lty = 5, lwd = 2, col = "green", pch = 3, cex = 1.5)
axis(1, at = 1:4, labels = y)
labels = c("ML", "GML", "Bayesian", "L-moments")
colors = c("blue", "red", "orange", "green")
pchh = c(6, 5, 4, 3)
legend("topright", inset = .03, labels, lwd = 3, lty = 1, col = colors, pch = pchh)
## สำหรับค่าประมาณพารามิเตอร์บ่งขนาด โดยใช้ค่า MSE ที่ได้ทั้งหมดจากแต่ละวิธี
ML = c(1.0587, 1.1711, 1.2324, 1.291)
GML = c(1.5396, 1.5973, 1.6173, 1.6141)
Bayes = c(1.3924, 1.3875, 1.3849, 1.3908)
LMOM = c(1.4484, 1.42, 1.4098, 1.4143)
y = c(300, 500, 700, 1000)
x = seq(1,4)
plot(x, y, type = "b", lty = 3, lwd = 2, col = "black", xaxt = "n", ylim = c(1.05,1.89), main =
"Scale", xlab = "n", ylab = " MSE ", pch = 8, cex = 1.5)
lines(x, ML, type = "b", lty = 2, lwd = 2, col = "blue", pch = 6, cex = 1.5)
lines(x, GML,type = "b", lty = 1, lwd = 2.9, col = "red", pch = 5, cex = 1.5)
lines(x, Bayes, type = "b", lty = 4, lwd = 2.9, col = "orange", pch = 4, cex = 1.5)
lines(x, LMOM, type = "b", lty = 5, lwd = 2, col = "green", pch = 3, cex = 1.5)
axis(1, at = 1:4, labels = y)
labels = c("ML", "GML", "Bayesian", "L-moments")
colors = c("blue", "red", "orange", "green")
pchh = c(6, 5, 4, 3)
legend("topright", inset = .03, labels, lwd = 3, lty = 1, col = colors, pch = pchh)
## สำหรับค่าประมาณพารามิเตอร์บ่งรูปร่าง โดยใช้ค่า MSE ที่ได้ทั้งหมดจากแต่ละวิธี
ML = c(0.2125, 0.0986, 0.0514, 0.0284)

```

```

GML = c(0.0596, 0.0407, 0.0305, 0.025)
Bayes = c(0.4364, 0.1055, 0.0462, 0.0262)
LMOM = c(0.1404, 0.0819, 0.0526, 0.0359)
y = c(300, 500, 700, 1000)
x = seq(1,4)
plot(x, y, type = "b", lty = 3, lwd = 2, col = "black", xaxt = "n", ylim = c(0.01,0.59), main = "Shape", xlab = "n", ylab = " MSE ", pch = 8, cex = 1.5)
lines(x, ML, type = "b", lty = 2, lwd = 2, col = "blue", pch = 6, cex = 1.5)
lines(x, GML,type = "b", lty = 1, lwd = 2.9, col = "red", pch = 5, cex = 1.5)
lines(x, Bayes, type = "b", lty = 4, lwd = 2.9, col = "orange", pch = 4, cex = 1.5)
lines(x, LMOM, type = "b", lty = 5, lwd = 2, col = "green", pch = 3, cex = 1.5)
axis(1, at = 1:4, labels = y)
labels = c("ML", "GML", "Bayesian", "L-moments")
colors = c("blue", "red", "orange", "green")
pchh = c(6, 5, 4, 3)
legend("topright", inset = .03, labels, lwd = 3, lty = 1, col = colors, pch = pchh)
# กรณีที่ 4 เมื่อค่าประมาณพารามิเตอร์บ่งรูปร่างเท่ากับศูนย์ ในตำแหน่งเปอร์เซ็นต์ไทล์ที่ 85
## สำหรับค่าประมาณพารามิเตอร์บ่งตำแหน่ง โดยใช้ค่า MSE ที่ได้ทั้งหมดจากแต่ละวิธี
ML = c(14.3302, 14.3498, 14.3807, 14.4486)
GML = c(14.3302, 14.3498, 14.3807, 14.4486)
Bayes = c(14.3302, 14.3498, 14.3807, 14.4486)
LMOM = c(14.3302, 14.3498, 14.3807, 14.4486)
y = c(300, 500, 700, 1000)
x = seq(1,4)
plot(x, y, type = "b", lty = 3, lwd = 2, col = "black", xaxt = "n", ylim = c(14.30,14.55),
main = "Location", xlab = "n", ylab = " MSE ", pch = 8, cex = 1.5)
lines(x, ML, type = "b", lty = 2, lwd = 2, col = "blue", pch = 6, cex = 1.5)
lines(x, GML,type = "b", lty = 1, lwd = 2.9, col = "red", pch = 5, cex = 1.5)
lines(x, Bayes, type = "b", lty = 4, lwd = 2.9, col = "orange", pch = 4, cex = 1.5)
lines(x, LMOM, type = "b", lty = 5, lwd = 2, col = "green", pch = 3, cex = 1.5)
axis(1, at = 1:4, labels = y)

```

```

labels = c("ML", "GML", "Bayesian", "L-moments")
colors = c("blue", "red", "orange", "green")
pchh = c(6, 5, 4, 3)
legend("topright", inset = .03, labels, lwd = 3, lty = 1, col = colors, pch = pchh)
## สำหรับค่าประมาณพารามิเตอร์บ่งขนาด โดยใช้ค่า MSE ที่ได้ทั้งหมดจากแต่ละวิธี
ML = c(0.2714, 0.131, 0.0918, 0.0557)
GML = c(0.1682, 0.1044, 0.0806, 0.0552)
Bayes = c(0.2287, 0.1196, 0.0841, 0.0534)
LMOM = c(0.2166, 0.1306, 0.0884, 0.0589)
y = c(300, 500, 700, 1000)
x = seq(1,4)
plot(x, y, type = "b", lty = 3, lwd = 2, col = "black", xaxt = "n", ylim = c(0.05,0.29), main
= "Scale", xlab = "n", ylab = " MSE ", pch = 8, cex = 1.5)
lines(x, ML, type = "b", lty = 2, lwd = 2, col = "blue", pch = 6, cex = 1.5)
lines(x, GML,type = "b", lty = 1, lwd = 2.9, col = "red", pch = 5, cex = 1.5)
lines(x, Bayes, type = "b", lty = 4, lwd = 2.9, col = "orange", pch = 4, cex = 1.5)
lines(x, LMOM, type = "b", lty = 5, lwd = 2, col = "green", pch = 3, cex = 1.5)
axis(1, at = 1:4, labels = y)
labels = c("ML", "GML", "Bayesian", "L-moments")
colors = c("blue", "red", "orange", "green")
pchh = c(6, 5, 4, 3)
legend("topright", inset = .03, labels, lwd = 3, lty = 1, col = colors, pch = pchh)
## สำหรับค่าประมาณพารามิเตอร์บ่งรูปร่าง โดยใช้ค่า MSE ที่ได้ทั้งหมดจากแต่ละวิธี
ML = c(0.0376, 0.0184, 0.0125, 0.0069)
GML = c(0.0163, 0.0104, 0.0084, 0.006)
Bayes = c(0.0479, 0.0213, 0.0129, 0.0072)
LMOM = c(0.0308, 0.0178, 0.0126, 0.0082)
y = c(300, 500, 700, 1000)
x = seq(1,4)
plot(x, y, type = "b", lty = 3, lwd = 2, col = "black", xaxt = "n", ylim = c(0.00,0.06), main
= "Shape", xlab = "n", ylab = " MSE ", pch = 8, cex = 1.5)

```

```

lines(x, ML, type = "b", lty = 2, lwd = 2, col = "blue", pch = 6, cex = 1.5)
lines(x, GML,type = "b", lty = 1, lwd = 2.9, col = "red", pch = 5, cex = 1.5)
lines(x, Bayes, type = "b", lty = 4, lwd = 2.9, col = "orange", pch = 4, cex = 1.5)
lines(x, LMOM, type = "b", lty = 5, lwd = 2, col = "green", pch = 3, cex = 1.5)
axis(1, at = 1:4, labels = y)
labels = c("ML", "GML", "Bayesian", "L-moments")
colors = c("blue", "red", "orange", "green")
pchh = c(6, 5, 4, 3)
legend("topright", inset = .03, labels, lwd = 3, lty = 1, col = colors, pch = pchh)
# กรณีที่ 5 เมื่อค่าประมาณพารามิเตอร์บ่งรูปร่างเท่ากับศูนย์ ในตำแหน่งเปอร์เซ็นต์ไทล์ที่ 90
## สำหรับค่าประมาณพารามิเตอร์บ่งตำแหน่ง โดยใช้ค่า MSE ที่ได้ทั้งหมดจากแต่ละวิธี
ML = c(20.9926, 21.1873, 21.1178, 21.2049)
GML = c(20.9926, 21.1873, 21.1178, 21.2049)
Bayes = c(20.9926, 21.1873, 21.1178, 21.2049)
LMOM = c(20.9926, 21.1873, 21.1178, 21.2049)
y = c(300, 500, 700, 1000)
x = seq(1,4)
plot(x, y, type = "b", lty = 3, lwd = 2, col = "black", xaxt = "n", ylim = c(20.99,21.29),
main = "Location", xlab = "n", ylab = " MSE ", pch = 8, cex = 1.5)
lines(x, ML, type = "b", lty = 2, lwd = 2, col = "blue", pch = 6, cex = 1.5)
lines(x, GML,type = "b", lty = 1, lwd = 2.9, col = "red", pch = 5, cex = 1.5)
lines(x, Bayes, type = "b", lty = 4, lwd = 2.9, col = "orange", pch = 4, cex = 1.5)
lines(x, LMOM, type = "b", lty = 5, lwd = 2, col = "green", pch = 3, cex = 1.5)
axis(1, at = 1:4, labels = y)
labels = c("ML", "GML", "Bayesian", "L-moments")
colors = c("blue", "red", "orange", "green")
pchh = c(6, 5, 4, 3)
legend("topright", inset = .03, labels, lwd = 3, lty = 1, col = colors, pch = pchh)
## สำหรับค่าประมาณพารามิเตอร์บ่งขนาด โดยใช้ค่า MSE ที่ได้ทั้งหมดจากแต่ละวิธี
ML = c(0.5135, 0.2241, 0.1511, 0.0945)
GML = c(0.2563, 0.1433, 0.1072, 0.0815)

```

```

Bayes = c(0.381, 0.193, 0.1354, 0.0861)
LMOM = c(0.3264, 0.189, 0.1412, 0.0956)
y = c(300, 500, 700, 1000)
x = seq(1,4)
plot(x, y, type = "b", lty = 3, lwd = 2, col = "black", xaxt = "n", ylim = c(0.08,0.60), main
= "Scale", xlab = "n", ylab = " MSE ", pch = 8, cex = 1.5)
lines(x, ML, type = "b", lty = 2, lwd = 2, col = "blue", pch = 6, cex = 1.5)
lines(x, GML,type = "b", lty = 1, lwd = 2.9, col = "red", pch = 5, cex = 1.5)
lines(x, Bayes, type = "b", lty = 4, lwd = 2.9, col = "orange", pch = 4, cex = 1.5)
lines(x, LMOM, type = "b", lty = 5, lwd = 2, col = "green", pch = 3, cex = 1.5)
axis(1, at = 1:4, labels = y)
labels = c("ML", "GML", "Bayesian", "L-moments")
colors = c("blue", "red", "orange", "green")
pchh = c(6, 5, 4, 3)
legend("topright", inset = .03, labels, lwd = 3, lty = 1, col = colors, pch = pchh)
## สำหรับค่าประมาณพารามิเตอร์ปรับปรุง โดยใช้ค่า MSE ที่ได้ทั้งหมดจากแต่ละวิธี
ML = c(0.0744, 0.0317, 0.0214, 0.0136)
GML = c(0.0257, 0.0122, 0.0106, 0.0087)
Bayes = c(0.1013, 0.0397, 0.022, 0.0147)
LMOM = c(0.0506, 0.0271, 0.019, 0.0143)
y = c(300, 500, 700, 1000)
x = seq(1,4)
plot(x, y, type = "b", lty = 3, lwd = 2, col = "black", xaxt = "n", ylim = c(0.01,0.12), main
= "Shape", xlab = "n", ylab = " MSE ", pch = 8, cex = 1.5)
lines(x, ML, type = "b", lty = 2, lwd = 2, col = "blue", pch = 6, cex = 1.5)
lines(x, GML,type = "b", lty = 1, lwd = 2.9, col = "red", pch = 5, cex = 1.5)
lines(x, Bayes, type = "b", lty = 4, lwd = 2.9, col = "orange", pch = 4, cex = 1.5)
lines(x, LMOM, type = "b", lty = 5, lwd = 2, col = "green", pch = 3, cex = 1.5)
axis(1, at = 1:4, labels = y)
labels = c("ML", "GML", "Bayesian", "L-moments")
colors = c("blue", "red", "orange", "green")

```

```

pchh = c(6, 5, 4, 3)
legend("topright", inset = .03, labels, lwd = 3, lty = 1, col = colors, pch = pchh)
# กรณีที่ 6 เมื่อค่าประมาณพารามิเตอร์บ่งรูปร่างเท่ากับศูนย์ ในตำแหน่งเปอร์เซ็นต์ไทล์ที่ 95
## สำหรับค่าประมาณพารามิเตอร์บ่งตำแหน่ง โดยใช้ค่า MSE ที่ได้ทั้งหมดจากแต่ละวิธี
ML = c(35.3788, 35.736, 35.8238, 35.9771)
GML = c(35.3788, 35.736, 35.8238, 35.9771)
Bayes = c(35.3788, 35.736, 35.8238, 35.9771)
LMOM = c(35.3788, 35.736, 35.8238, 35.9771)
y = c(300, 500, 700, 1000)
x = seq(1,4)
plot(x, y, type = "b", lty = 3, lwd = 2, col = "black", xaxt = "n", ylim = c(35.35,36.35),
main = "Location", xlab = "n", ylab = " MSE ", pch = 8, cex = 1.5)
lines(x, ML, type = "b", lty = 2, lwd = 2, col = "blue", pch = 6, cex = 1.5)
lines(x, GML,type = "b", lty = 1, lwd = 2.9, col = "red", pch = 5, cex = 1.5)
lines(x, Bayes, type = "b", lty = 4, lwd = 2.9, col = "orange", pch = 4, cex = 1.5)
lines(x, LMOM, type = "b", lty = 5, lwd = 2, col = "green", pch = 3, cex = 1.5)
axis(1, at = 1:4, labels = y)
labels = c("ML", "GML", "Bayesian", "L-moments")
colors = c("blue", "red", "orange", "green")
pchh = c(6, 5, 4, 3)
legend("topright", inset = .03, labels, lwd = 3, lty = 1, col = colors, pch = pchh)
## สำหรับค่าประมาณพารามิเตอร์บ่งขนาด โดยใช้ค่า MSE ที่ได้ทั้งหมดจากแต่ละวิธี
ML = c(1.7679, 0.6735, 0.3993, 0.2166)
GML = c(0.5372, 0.3349, 0.212, 0.1354)
Bayes = c(1.0724, 0.502, 0.3129, 0.1897)
LMOM = c(0.7597, 0.4374, 0.3026, 0.1936)
y = c(300, 500, 700, 1000)
x = seq(1,4)
plot(x, y, type = "b", lty = 3, lwd = 2, col = "black", xaxt = "n", ylim = c(0.20,2.00), main =
"Scale", xlab = "n", ylab = " MSE ", pch = 8, cex = 1.5)
lines(x, ML, type = "b", lty = 2, lwd = 2, col = "blue", pch = 6, cex = 1.5)

```

```

lines(x, GML,type = "b", lty = 1, lwd = 2.9, col = "red", pch = 5, cex = 1.5)
lines(x, Bayes, type = "b", lty = 4, lwd = 2.9, col = "orange", pch = 4, cex = 1.5)
lines(x, LMOM, type = "b", lty = 5, lwd = 2, col = "green", pch = 3, cex = 1.5)
axis(1, at = 1:4, labels = y)
labels = c("ML", "GML", "Bayesian", "L-moments")
colors = c("blue", "red", "orange", "green")
pchh = c(6, 5, 4, 3)
legend("topright", inset = .03, labels, lwd = 3, lty = 1, col = colors, pch = pchh)
## สำหรับค่าประมาณพารามิเตอร์รูปร่าง โดยใช้ค่า MSE ที่ได้ทั้งหมดจากแต่ละวิธี
ML = c(0.2438, 0.0912, 0.0569, 0.0334)
GML = c(0.0582, 0.0283, 0.0203, 0.0135)
Bayes = c(0.6049, 0.1477, 0.0748, 0.0406)
LMOM = c(0.1113, 0.0591, 0.0458, 0.0309)
y = c(300, 500, 700, 1000)
x = seq(1,4)
plot(x, y, type = "b", lty = 3, lwd = 2, col = "black", xaxt = "n", ylim = c(0.01,0.70), main = "Shape", xlab = "n", ylab = " MSE ", pch = 8, cex = 1.5)
lines(x, ML, type = "b", lty = 2, lwd = 2, col = "blue", pch = 6, cex = 1.5)
lines(x, GML,type = "b", lty = 1, lwd = 2.9, col = "red", pch = 5, cex = 1.5)
lines(x, Bayes, type = "b", lty = 4, lwd = 2.9, col = "orange", pch = 4, cex = 1.5)
lines(x, LMOM, type = "b", lty = 5, lwd = 2, col = "green", pch = 3, cex = 1.5)
axis(1, at = 1:4, labels = y)
labels = c("ML", "GML", "Bayesian", "L-moments")
colors = c("blue", "red", "orange", "green")
pchh = c(6, 5, 4, 3)
legend("topright", inset = .03, labels, lwd = 3, lty = 1, col = colors, pch = pchh)

```

```

# กรณีที่ 7 เมื่อค่าประมาณพารามิเตอร์บ่งรูปร่างมากกว่าศูนย์ ในตำแหน่งเปอร์เซ็นต์ไทล์ที่ 85
## สำหรับค่าประมาณพารามิเตอร์บ่งตำแหน่ง โดยใช้ค่า MSE ที่ได้ทั้งหมดจากแต่ละวิธี

ML = c(26.0175, 26.2381, 26.1448, 26.0546)
GML = c(26.0175, 26.2381, 26.1448, 26.0546)
Bayes = c(26.0175, 26.2381, 26.1448, 26.0546)
LMOM = c(26.0175, 26.2381, 26.1448, 26.0546)
y = c(300, 500, 700, 1000)
x = seq(1,4)
plot(x, y, type = "b", lty = 3, lwd = 2, col = "black", xaxt = "n", ylim = c(26.01,26.35),
main = "Location", xlab = "n", ylab = " MSE ", pch = 8, cex = 1.5)
lines(x, ML, type = "b", lty = 2, lwd = 2, col = "blue", pch = 6, cex = 1.5)
lines(x, GML,type = "b", lty = 1, lwd = 2.9, col = "red", pch = 5, cex = 1.5)
lines(x, Bayes, type = "b", lty = 4, lwd = 2.9, col = "orange", pch = 4, cex = 1.5)
lines(x, LMOM, type = "b", lty = 5, lwd = 2, col = "green", pch = 3, cex = 1.5)
axis(1, at = 1:4, labels = y)
labels = c("ML", "GML", "Bayesian", "L-moments")
colors = c("blue", "red", "orange", "green")
pchh = c(6, 5, 4, 3)
legend("topright", inset = .03, labels, lwd = 3, lty = 1, col = colors, pch = pchh)
## สำหรับค่าประมาณพารามิเตอร์บ่งขนาด โดยใช้ค่า MSE ที่ได้ทั้งหมดจากแต่ละวิธี

ML = c(3.8838, 3.2066, 2.9295, 2.7847)
GML = c(6.3098, 4.8729, 3.9224, 3.3019)
Bayes = c(3.4098, 2.9747, 2.7843, 2.6757)
LMOM = c(3.2839, 2.905, 2.7378, 2.6564)
y = c(300, 500, 700, 1000)
x = seq(1,4)
plot(x, y, type = "b", lty = 3, lwd = 2, col = "black", xaxt = "n", ylim = c(2.65,6.5), main
= "Scale", xlab = "n", ylab = " MSE ", pch = 8, cex = 1.5)
lines(x, ML, type = "b", lty = 2, lwd = 2, col = "blue", pch = 6, cex = 1.5)
lines(x, GML,type = "b", lty = 1, lwd = 2.9, col = "red", pch = 5, cex = 1.5)
lines(x, Bayes, type = "b", lty = 4, lwd = 2.9, col = "orange", pch = 4, cex = 1.5)

```

```

lines(x, LMOM, type = "b", lty = 5, lwd = 2, col = "green", pch = 3, cex = 1.5)
axis(1, at = 1:4, labels = y)
labels = c("ML", "GML", "Bayesian", "L-moments")
colors = c("blue", "red", "orange", "green")
pchh = c(6, 5, 4, 3)
legend("topright", inset = .03, labels, lwd = 3, lty = 1, col = colors, pch = pchh)
## สำหรับค่าประมาณพารามิเตอร์บ่งรูปร่าง โดยใช้ค่า MSE ที่ได้ทั้งหมดจากแต่ละวิธี
ML = c(0.049, 0.0263, 0.0186, 0.0132)
GML = c(0.0865, 0.0575, 0.0379, 0.0232)
Bayes = c(0.0712, 0.0314, 0.0205, 0.0144)
LMOM = c(0.0337, 0.0205, 0.0149, 0.0109)
y = c(300, 500, 700, 1000)
x = seq(1,4)
plot(x, y, type = "b", lty = 3, lwd = 2, col = "black", xaxt = "n", ylim = c(0.01,0.10), main
= "Shape", xlab = "n", ylab = "MSE ", pch = 8, cex = 1.5)
lines(x, ML, type = "b", lty = 2, lwd = 2, col = "blue", pch = 6, cex = 1.5)
lines(x, GML, type = "b", lty = 1, lwd = 2.9, col = "red", pch = 5, cex = 1.5)
lines(x, Bayes, type = "b", lty = 4, lwd = 2.9, col = "orange", pch = 4, cex = 1.5)
lines(x, LMOM, type = "b", lty = 5, lwd = 2, col = "green", pch = 3, cex = 1.5)
axis(1, at = 1:4, labels = y)
labels = c("ML", "GML", "Bayesian", "L-moments")
colors = c("blue", "red", "orange", "green")
pchh = c(6, 5, 4, 3)
legend("topright", inset = .03, labels, lwd = 3, lty = 1, col = colors, pch = pchh)
# กรณีที่ 8 เมื่อค่าประมาณพารามิเตอร์บ่งรูปร่างมากกว่าศูนย์ ในตำแหน่งเปอร์เซ็นต์ไทล์ที่ 90
## สำหรับค่าประมาณพารามิเตอร์บ่งตำแหน่ง โดยใช้ค่า MSE ที่ได้ทั้งหมดจากแต่ละวิธี
ML = c(44.4196, 44.2003, 43.8581, 44.1978)
GML = c(44.4196, 44.2003, 43.8581, 44.1978)
Bayes = c(44.4196, 44.2003, 43.8581, 44.1978)
LMOM = c(44.4196, 44.2003, 43.8581, 44.1978)
y = c(300, 500, 700, 1000)

```

```

x = seq(1,4)
plot(x, y, type = "b", lty = 3, lwd = 2, col = "black", xaxt = "n", ylim = c(43.8,44.5), main
= "Location", xlab = "n", ylab = " MSE ", pch = 8, cex = 1.5)
lines(x, ML, type = "b", lty = 2, lwd = 2, col = "blue", pch = 6, cex = 1.5)
lines(x, GML,type = "b", lty = 1, lwd = 2.9, col = "red", pch = 5, cex = 1.5)
lines(x, Bayes, type = "b", lty = 4, lwd = 2.9, col = "orange", pch = 4, cex = 1.5)
lines(x, LMOM, type = "b", lty = 5, lwd = 2, col = "green", pch = 3, cex = 1.5)
axis(1, at = 1:4, labels = y)
labels = c("ML", "GML", "Bayesian", "L-moments")
colors = c("blue", "red", "orange", "green")
pchh = c(6, 5, 4, 3)
legend("topright", inset = .03, labels, lwd = 3, lty = 1, col = colors, pch = pchh)
## สำหรับค่าประมาณพารามิเตอร์บ่งขนาด โดยใช้ค่า MSE ที่ได้ทั้งหมดจากแต่ละวิธี
ML = c(7.9954, 6.023, 5.15, 4.6673)
GML = c(11.8936, 9.5607, 7.675, 6.1012)
Bayes = c(6.786, 5.3797, 4.7948, 4.4629)
LMOM = c(6.056, 5.214, 4.7284, 4.3812)
y = c(300, 500, 700, 1000)
x = seq(1,4)
plot(x, y, type = "b", lty = 3, lwd = 2, col = "black", xaxt = "n", ylim = c(4.35,12.00),
main = "Scale", xlab = "n", ylab = " MSE ", pch = 8, cex = 1.5)
lines(x, ML, type = "b", lty = 2, lwd = 2, col = "blue", pch = 6, cex = 1.5)
lines(x, GML,type = "b", lty = 1, lwd = 2.9, col = "red", pch = 5, cex = 1.5)
lines(x, Bayes, type = "b", lty = 4, lwd = 2.9, col = "orange", pch = 4, cex = 1.5)
lines(x, LMOM, type = "b", lty = 5, lwd = 2, col = "green", pch = 3, cex = 1.5)
axis(1, at = 1:4, labels = y)
labels = c("ML", "GML", "Bayesian", "L-moments")
colors = c("blue", "red", "orange", "green")
pchh = c(6, 5, 4, 3)
legend("topright", inset = .03, labels, lwd = 3, lty = 1, col = colors, pch = pchh)
## สำหรับค่าประมาณพารามิเตอร์บ่งรูปร่าง โดยใช้ค่า MSE ที่ได้ทั้งหมดจากแต่ละวิธี

```

```

ML = c(0.0832, 0.0397, 0.0262, 0.0178)
GML = c(0.111, 0.081, 0.0586, 0.0384)
Bayes = c(0.1327, 0.0537, 0.0312, 0.02)
LMOM = c(0.046, 0.0275, 0.0202, 0.0143)
y = c(300, 500, 700, 1000)
x = seq(1,4)
plot(x, y, type = "b", lty = 3, lwd = 2, col = "black", xaxt = "n", ylim = c(0.01,0.14), main = "Shape", xlab = "n", ylab = " MSE ", pch = 8, cex = 1.5)
lines(x, ML, type = "b", lty = 2, lwd = 2, col = "blue", pch = 6, cex = 1.5)
lines(x, GML,type = "b", lty = 1, lwd = 2.9, col = "red", pch = 5, cex = 1.5)
lines(x, Bayes, type = "b", lty = 4, lwd = 2.9, col = "orange", pch = 4, cex = 1.5)
lines(x, LMOM, type = "b", lty = 5, lwd = 2, col = "green", pch = 3, cex = 1.5)
axis(1, at = 1:4, labels = y)
labels = c("ML", "GML", "Bayesian", "L-moments")
colors = c("blue", "red", "orange", "green")
pchh = c(6, 5, 4, 3)
legend("topright", inset = .03, labels, lwd = 3, lty = 1, col = colors, pch = pchh)
# กรณีที่ 9 เมื่อค่าประมาณพารามิเตอร์บ่งรูปร่างมากกว่าศูนย์ ในตำแหน่งเปอร์เซ็นต์ไทล์ที่ 95
## สำหรับค่าประมาณพารามิเตอร์บ่งตำแหน่ง โดยใช้ค่า MSE ที่ได้ทั้งหมดจากแต่ละวิธี
ML = c(94.5001, 93.5926, 94.0509, 94.5428)
GML = c(94.5001, 93.5926, 94.0509, 94.5428)
Bayes = c(94.5001, 93.5926, 94.0509, 94.5428)
LMOM = c(94.5001, 93.5926, 94.0509, 94.5428)
y = c(300, 500, 700, 1000)
x = seq(1,4)
plot(x, y, type = "b", lty = 3, lwd = 2, col = "black", xaxt = "n", ylim = c(93.50,94.90),
main = "Location", xlab = "n", ylab = " MSE ", pch = 8, cex = 1.5)
lines(x, ML, type = "b", lty = 2, lwd = 2, col = "blue", pch = 6, cex = 1.5)
lines(x, GML,type = "b", lty = 1, lwd = 2.9, col = "red", pch = 5, cex = 1.5)
lines(x, Bayes, type = "b", lty = 4, lwd = 2.9, col = "orange", pch = 4, cex = 1.5)
lines(x, LMOM, type = "b", lty = 5, lwd = 2, col = "green", pch = 3, cex = 1.5)

```

```

axis(1, at = 1:4, labels = y)
labels = c("ML", "GML", "Bayesian", "L-moments")
colors = c("blue", "red", "orange", "green")
pchh = c(6, 5, 4, 3)
legend("topright", inset = .03, labels, lwd = 3, lty = 1, col = colors, pch = pchh)
## สำหรับค่าประมาณพารามิเตอร์บ่งขนาด โดยใช้ค่า MSE ที่ได้ทั้งหมดจากแต่ละวิธี
ML = c(25.2261, 16.3694, 13.1294, 11.4988)
GML = c(24.6674, 23.3295, 18.9217, 17.4963)
Bayes = c(18.2013, 13.6387, 11.4268, 10.6267)
LMOM = c(14.1995, 12.5271, 11.0321, 10.2424)
y = c(300, 500, 700, 1000)
x = seq(1,4)
plot(x, y, type = "b", lty = 3, lwd = 2, col = "black", xaxt = "n", ylim = c(10.24,28.00),
main = "Scale", xlab = "n", ylab = " MSE ", pch = 8, cex = 1.5)
lines(x, ML, type = "b", lty = 2, lwd = 2, col = "blue", pch = 6, cex = 1.5)
lines(x, GML, type = "b", lty = 1, lwd = 2.9, col = "red", pch = 5, cex = 1.5)
lines(x, Bayes, type = "b", lty = 4, lwd = 2.9, col = "orange", pch = 4, cex = 1.5)
lines(x, LMOM, type = "b", lty = 5, lwd = 2, col = "green", pch = 3, cex = 1.5)
axis(1, at = 1:4, labels = y)
labels = c("ML", "GML", "Bayesian", "L-moments")
colors = c("blue", "red", "orange", "green")
pchh = c(6, 5, 4, 3)
legend("topright", inset = .03, labels, lwd = 3, lty = 1, col = colors, pch = pchh)
## สำหรับค่าประมาณพารามิเตอร์บ่งรูปร่าง โดยใช้ค่า MSE ที่ได้ทั้งหมดจากแต่ละวิธี
ML = c(0.2653, 0.0974, 0.0723, 0.041)
GML = c(0.1586, 0.1206, 0.1037, 0.0808)
Bayes = c(0.8266, 0.223, 0.1224, 0.0556)
LMOM = c(0.1063, 0.0563, 0.0458, 0.0292)
y = c(300, 500, 700, 1000)
x = seq(1,4)

```

```
plot(x, y, type = "b", lty = 3, lwd = 2, col = "black", xaxt = "n", ylim = c(0.02,0.90), main
= "Shape", xlab = "n", ylab = "MSE", pch = 8, cex = 1.5)
```

```
lines(x, ML, type = "b", lty = 2, lwd = 2, col = "blue", pch = 6, cex = 1.5)
```

```
lines(x, GML, type = "b", lty = 1, lwd = 2.9, col = "red", pch = 5, cex = 1.5)
```

```
lines(x, Bayes, type = "b", lty = 4, lwd = 2.9, col = "orange", pch = 4, cex = 1.5)
```

```
lines(x, LMOM, type = "b", lty = 5, lwd = 2, col = "green", pch = 3, cex = 1.5)
```


```
axis(1, at = 1:4, labels = y)
```

```
labels = c("ML", "GML", "Bayesian", "L-moments")
```

```
colors = c("blue", "red", "orange", "green")
```

```
pchh = c(6, 5, 4, 3)
```

```
legend("topright", inset = .03, labels, lwd = 3, lty = 1, col = colors, pch = pchh)
```



คำสั่งโปรแกรมอาร์ที่ใช้ในงานวิจัยสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายปีจากการแจกแจงพาเรโต วางนัยทั่วไป

```
# -----
# สร้างกราฟอนุกรมเวลาและฮิสโทแกรมสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนสถานีศูนย์การ
# ประชุมแห่งชาติสิริกิติ์
xm_qsncc <- sqncc$`เดือน/ปี`
ym_qsncc <- sqncc$`maximum rainfall (mm)`
plot(xm_qsncc, ym_qsncc, type = "l", xlab = "year", ylab = "maximum rainfall (mm)",
      ylim = c(0,300), main = "Monthly Maximum Rainfall of SQNCC Station")
hist(ym_qsncc, xlab = "millimeters", main = "SQNCC Station")
# สร้างกราฟอนุกรมเวลาและฮิสโทแกรมสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนสถานีดอนเมือง
xm_dm <- dm$`เดือน/ปี`
ym_dm <- dm$`maximum rainfall (mm)`
plot(xm_dm, ym_dm, type = "l", xlab = "year", ylab = "maximum rainfall (mm)", ylim =
      c(0,300), main = "Monthly Maximum Rainfall of Don Muang Station")
hist(ym_dm, xlab = "millimeters", main = "Don Muang Station")
# สร้างกราฟอนุกรมเวลาและฮิสโทแกรมสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนสถานีบางนา
xm_bn <- bn$`เดือน/ปี`
ym_bn <- bn$`maximum rainfall (mm)`
plot(xm_bn, ym_bn, type = "l", xlab = "year", ylab = "maximum rainfall (mm)", ylim =
      c(0,300), main = "Monthly Maximum Rainfall of Bang Na Station")
hist(ym_bn, xlab = "millimeters", main = "Bang Na Station")
# สร้างกราฟอนุกรมเวลาและฮิสโทแกรมสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนสถานีคลองเตย
xm_kt <- kt$`เดือน/ปี`
ym_kt <- kt$`maximum rainfall (mm)`
plot(xm_kt, ym_kt, type = "l", xlab = "year", ylab = "maximum rainfall (mm)", ylim =
      c(0,300), main = "Monthly Maximum Rainfall of Klong Toey Station")
hist(ym_kt, xlab = "millimeters", main = "Klong Toey Station")
# -----
# คำนวณค่าสถิติพื้นฐานสำหรับข้อมูลปริมาณน้ำฝนสูงสุดรายเดือนแต่ละสถานีตรวจวัดระดับน้ำ
library(moments)
```

```

area <- c("SQNCC", "DONMUANG", "BANGNA", "KLONGTOEY")
mean_area1 <- round(c(mean(ym_qsncc), mean(ym_dm), mean(ym_bn),
                      mean(ym_kt)), 4)
sd_area1 <- round(c(sd(ym_qsncc),sd(ym_dm),sd(ym_bn),sd(ym_kt)),4)
m3_area1 <- round(c(skewness(ym_qsncc), skewness(ym_dm), skewness(ym_bn),
                  skewness(ym_kt)), 4)
m4_area1 <- round(c(kurtosis(ym_qsncc), kurtosis(ym_dm), kurtosis(ym_bn),
                  kurtosis(ym_kt)), 4)
min_area1 <- c(min(ym_qsncc), min(ym_dm), min(ym_bn), min(ym_kt))
max_area1 <- c(max(ym_qsncc), max(ym_dm), max(ym_bn), max(ym_kt))
data.frame(area, mean_area1, sd_area1, m3_area1, m4_area1, min_area1, max_area1)
# -----
# สร้างตัวแบบและคำนวณค่าประมาณพารามิเตอร์แต่ละวิธีสำหรับข้อมูลปริมาณน้ำฝนสูงสุดราย
เดือนของสถานีศูนย์การประชุมแห่งชาติสิริกิติ์
p = c(0.85, 0.90, 0.95)
t_qsncc = c()
loc1_qsncc = c(); sca1_qsncc = c(); sha1_qsncc = c()
loc2_qsncc = c(); sca2_qsncc = c(); sha2_qsncc = c()
loc3_qsncc = c(); sca3_qsncc = c(); sha3_qsncc = c()
loc4_qsncc = c(); sca4_qsncc = c(); sha4_qsncc = c()
for (r in 1:3) {
  t_qsncc[r] <- quantile(ym_qsncc[1:240], p[r])
  fit1m_qsncc <- fevd(ym_qsncc[1:240], threshold = t_qsncc[r], type = "GP", method =
    "MLE")
  fit2m_qsncc <- fevd(ym_qsncc[1:240], threshold = t_qsncc[r], type = "GP", method =
    "GMLE")
  fit3m_qsncc <- fevd(ym_qsncc[1:240], threshold = t_qsncc[r], type = "GP", method =
    "Bayesian", iter = 2000)
  fit4m_qsncc <- fevd(ym_qsncc[1:240], threshold = t_qsncc[r], type = "GP", method =
    "Lmoments")
  loc1_qsncc[r] = t_qsncc[r]

```

```

sca1_qsncc[r] = mean(findpars(fit1m_qsncc)$scale)
sha1_qsncc[r] = mean(findpars(fit1m_qsncc)$shape)
loc2_qsncc[r] = t_qsncc[r]
sca2_qsncc[r] = mean(findpars(fit2m_qsncc)$scale)
sha2_qsncc[r] = mean(findpars(fit2m_qsncc)$shape)
loc3_qsncc[r] = t_qsncc[r]
sca3_qsncc[r] = mean(findpars(fit3m_qsncc)$scale)
sha3_qsncc[r] = mean(findpars(fit3m_qsncc)$shape)
loc4_qsncc[r] = t_qsncc[r]
sca4_qsncc[r] = findpars(fit4m_qsncc)[1]
sha4_qsncc[r] = findpars(fit4m_qsncc)[2]
}
perc = c("85", "90", "95")
all_qsncc = data.frame(perc, loc1_qsncc, sca1_qsncc, sha1_qsncc, loc2_qsncc,
  sca2_qsncc, sha2_qsncc, loc3_qsncc, sca3_qsncc, sha3_qsncc,
  loc4_qsncc, sca4_qsncc, sha4_qsncc)
# สร้างตัวแบบและคำนวณค่าประมาณพารามิเตอร์แต่ละวิธีสำหรับข้อมูลปริมาณน้ำฝนสูงสุดราย
เดือนของสถานีดอนเมือง
p = c(0.85, 0.90, 0.95)
t_dm = c()
loc1_dm = c(); sca1_dm = c(); sha1_dm = c()
loc2_dm = c(); sca2_dm = c(); sha2_dm = c()
loc3_dm = c(); sca3_dm = c(); sha3_dm = c()
loc4_dm = c(); sca4_dm = c(); sha4_dm = c()
for (r in 1:3) {
  t_dm[r] <- quantile(ym_dm[1:240],p[r])
  fit1m_dm <- fevd(ym_dm[1:240], threshold = t_dm[r], type = "GP", method = "MLE")
  fit2m_dm <- fevd(ym_dm[1:240], threshold = t_dm[r], type = "GP", method =
    "GMLE")
  fit3m_dm <- fevd(ym_dm[1:240], threshold = t_dm[r], type = "GP", method =
    "Bayesian", iter = 2000)

```

```

fit4m_dm <- fevd(ym_dm[1:240], threshold = t_dm[r], type = "GP", method =
    "Lmoments")
loc1_dm[r] = t_dm[r]
sca1_dm[r] = mean(findpars(fit1m_dm)$scale)
sha1_dm[r] = mean(findpars(fit1m_dm)$shape)
loc2_dm[r] = t_dm[r]
sca2_dm[r] = mean(findpars(fit2m_dm)$scale)
sha2_dm[r] = mean(findpars(fit2m_dm)$shape)
loc3_dm[r] = t_dm[r]
sca3_dm[r] = mean(findpars(fit3m_dm)$scale)
sha3_dm[r] = mean(findpars(fit3m_dm)$shape)
loc4_dm[r] = t_dm[r]
sca4_dm[r] = findpars(fit4m_dm)[1]
sha4_dm[r] = findpars(fit4m_dm)[2]
}
perc = c("85", "90", "95")
all_dm = data.frame(perc, loc1_dm, sca1_dm, sha1_dm, loc2_dm, sca2_dm,
    sha2_dm, loc3_dm, sca3_dm, sha3_dm, loc4_dm, sca4_dm, sha4_dm)
# สร้างตัวแบบและคำนวณค่าประมาณพารามิเตอร์แต่ละวิธีสำหรับข้อมูลปริมาณน้ำฝนสูงสุดราย
เดือนของสถานีบางนา
p = c(0.85, 0.90, 0.95)
t_bn = c()
loc1_bn = c(); sca1_bn = c(); sha1_bn = c()
loc2_bn = c(); sca2_bn = c(); sha2_bn = c()
loc3_bn = c(); sca3_bn = c(); sha3_bn = c()
loc4_bn = c(); sca4_bn = c(); sha4_bn = c()
for (r in 1:3) {
    t_bn[r] <- quantile(ym_bn[1:240], p[r])
    fit1m_bn <- fevd(y7_bn[1:240], threshold = t_bn[r], type = "GP", method = "MLE" )
    fit2m_bn <- fevd(ym_bn[1:240], threshold = t_bn[r], type = "GP", method = "GMLE" )

```

```

fit3m_bn <- fevd(ym_bn[1:240], threshold = t_bn[r], type = "GP", method =
  "Bayesian", iter = 2000)
fit4m_bn <- fevd(ym_bn[1:240], threshold = t_bn[r], type = "GP", method =
  "Lmoments")
loc1_bn[r] = t_bn[r]
sca1_bn[r] = mean(findpars(fit1m_bn)$scale)
sha1_bn[r] = mean(findpars(fit1m_bn)$shape)
loc2_bn[r] = t_bn[r]
sca2_bn[r] = mean(findpars(fit2m_bn)$scale)
sha2_bn[r] = mean(findpars(fit2m_bn)$shape)
loc3_bn[r] = t_bn[r]
sca3_bn[r] = mean(findpars(fit3m_bn)$scale)
sha3_bn[r] = mean(findpars(fit3m_bn)$shape)
loc4_bn[r] = t_bn[r]
sca4_bn[r] = findpars(fit4m_bn)[1]
sha4_bn[r] = findpars(fit4m_bn)[2]
}
perc = c("85", "90", "95")
all_bn = data.frame(perc, loc1_bn, sca1_bn, sha1_bn, loc2_bn, sca2_bn, sha2_bn,
  loc3_bn, sca3_bn, sha3_bn, loc4_bn, sca4_bn, sha4_bn)
# สร้างตัวแบบและคำนวณค่าประมาณพารามิเตอร์แต่ละวิธีสำหรับข้อมูลปริมาณน้ำฝนสูงสุดราย
เดือนของสถานีคลองเตย
p = c(0.85, 0.90, 0.95)
t_kt = c()
loc1_kt = c(); sca1_kt = c(); sha1_kt = c()
loc2_kt = c(); sca2_kt = c(); sha2_kt = c()
loc3_kt = c(); sca3_kt = c(); sha3_kt = c()
loc4_kt = c(); sca4_kt = c(); sha4_kt = c()
for (r in 1:3) {
  t_kt[r] <- quantile(ym_kt[1:240], p[r])
  fit1m_kt <- fevd(ym_kt[1:240], threshold = t_kt[r], type = "GP", method = "MLE" )

```

```

fit2m_kt <- fevd(ym_kt[1:240], threshold = t_kt[r], type = "GP", method = "GMLE" )
fit3m_kt <- fevd(ym_kt[1:240], threshold = t_kt[r], type = "GP", method =
  "Bayesian",iter = 2000)
fit4m_kt <- fevd(ym_kt[1:240], threshold = t_kt[r], type = "GP", method =
  "Lmoments")

loc1_kt[r] = t_kt[r]
sca1_kt[r] = mean(findpars(fit1m_kt)$scale)
sha1_kt[r] = mean(findpars(fit1m_kt)$shape)
loc2_kt[r] = t_kt[r]
sca2_kt[r] = mean(findpars(fit2m_kt)$scale)
sha2_kt[r] = mean(findpars(fit2m_kt)$shape)
loc3_kt[r] = t_kt[r]
sca3_kt[r] = mean(findpars(fit3m_kt)$scale)
sha3_kt[r] = mean(findpars(fit3m_kt)$shape)
loc4_kt[r] = t_kt[r]
sca4_kt[r] = findpars(fit4m_kt)[1]
sha4_kt[r] = findpars(fit4m_kt)[2]
}
perc = c("85", "90", "95")
all_kt = data.frame(perc, loc1_kt, sca1_kt, sha1_kt, loc2_kt, sca2_kt, sha2_kt, loc3_kt,
  sca3_kt, sha3_kt, loc4_kt, sca4_kt, sha4_kt)

# -----
# คำนวณระดับการเกิดซ้ำสำหรับข้อมูลปริมาณน้ำฝนสูงสุดสถานีศูนย์การประชมแห่งชาติสิริกิติ์
# Return Level 85%
qsncc_count <- length(ym_qsncc[1:240][ym_qsncc[1:240] > t_qsncc[1]])
months_qsncc <- length(ym_qsncc[1:240])
lambda_monthly_qsncc <- qsncc_count / months_qsncc
lambda_yearly_qsncc <- lambda_monthly_qsncc * 12
T_years <- seq(2,10)
re1m85_qsncc <- loc1_qsncc[1] + (sca1_qsncc[1] / sha1_qsncc[1]) * ((T_years *
  lambda_yearly_qsncc) ^ sha1_qsncc[1] - 1)

```

```

re2m85_qsncc <- loc2_qsncc[1] + (sca2_qsncc[1] / sha2_qsncc[1]) * ((T_years *
lambda_yearly_qsncc) ^ sha2_qsncc[1] - 1)
re3m85_qsncc <- loc3_qsncc[1] + (sca3_qsncc[1] / sha3_qsncc[1]) * ((T_years *
lambda_yearly_qsncc) ^ sha3_qsncc[1] - 1)
re4m85_qsncc <- loc4_qsncc[1] + (sca4_qsncc[1] / sha4_qsncc[1]) * ((T_years *
lambda_yearly_qsncc) ^ sha4_qsncc[1] - 1)
return85_qsncc <- data.frame(Return_Period_Years = T_years, Return_MLE =
re1m85_qsncc, Return_GMLE = re2m85_qsncc, Return_BAY = re3m85_qsncc,
Return_LMOM = re4m85_qsncc)
# Return Level 90%
qsncc_count <- length(ym_qsncc[1:240][ym_qsncc[1:240] > t_qsncc[2]])
months_qsncc <- length(ym_qsncc[1:240])
lambda_monthly_qsncc <- qsncc_count / months_qsncc
lambda_yearly_qsncc <- lambda_monthly_qsncc * 12
T_years <- seq(2,10)
re1m90_qsncc <- loc1_qsncc[2] + (sca1_qsncc[2] / sha1_qsncc[2]) * ((T_years *
lambda_yearly_qsncc) ^ sha1_qsncc[2] - 1)
re2m90_qsncc <- loc2_qsncc[2] + (sca2_qsncc[2] / sha2_qsncc[2]) * ((T_years *
lambda_yearly_qsncc) ^ sha2_qsncc[2] - 1)
re3m90_qsncc <- loc3_qsncc[2] + (sca3_qsncc[2] / sha3_qsncc[2]) * ((T_years *
lambda_yearly_qsncc) ^ sha3_qsncc[2] - 1)
re4m90_qsncc <- loc4_qsncc[2] + (sca4_qsncc[2] / sha4_qsncc[2]) * ((T_years *
lambda_yearly_qsncc) ^ sha4_qsncc[2] - 1)
return90_qsncc <- data.frame(Return_Period_Years = T_years, Return_MLE =
re1m90_qsncc, Return_GMLE = re2m90_qsncc, Return_BAY = re3m90_qsncc,
Return_LMOM = re4m90_qsncc)
# Return Level 95%
qsncc_count <- length(ym_qsncc[1:240][ym_qsncc[1:240] > t_qsncc[3]])
months_qsncc <- length(ym_qsncc[1:240])
lambda_monthly_qsncc <- qsncc_count / months_qsncc
lambda_yearly_qsncc <- lambda_monthly_qsncc * 12

```

```

T_years <- seq(2,10)
re1m95_qsncc <- loc1_qsncc[3] + (sca1_qsncc[3] / sha1_qsncc[3]) * ((T_years *
lambda_yearly_qsncc) ^ sha1_qsncc[3] - 1)
re2m95_qsncc <- loc2_qsncc[3] + (sca2_qsncc[3] / sha2_qsncc[3]) * ((T_years *
lambda_yearly_qsncc) ^ sha2_qsncc[3] - 1)
re3m95_qsncc <- loc3_qsncc[3] + (sca3_qsncc[3] / sha3_qsncc[3]) * ((T_years *
lambda_yearly_qsncc) ^ sha3_qsncc[3] - 1)
re4m95_qsncc <- loc4_qsncc[3] + (sca4_qsncc[3] / sha4_qsncc[3]) * ((T_years *
lambda_yearly_qsncc) ^ sha4_qsncc[3] - 1)
return95_qsncc <- data.frame(Return_Period_Years = T_years, Return_MLE =
re1m95_qsncc, Return_GMLE = re2m95_qsncc, Return_BAY = re3m95_qsncc,
Return_LMOM = re4m95_qsncc)
# กำหนดระดับการเกิดซ้ำสำหรับข้อมูลปริมาณน้ำฝนสูงสุดสถานีตอนเมือง
# Return Level 85%
dm_count <- length(ym_dm[1:240][ym_dm[1:240] > t_dm[1]])
months_dm <- length(ym_dm[1:240])
lambda_monthly_dm <- dm_count / months_dm
lambda_yearly_dm <- lambda_monthly_dm * 12
T_years <- seq(2,10)
re1m85_dm <- loc1_dm[1] + (sca1_dm[1] / sha1_dm[1]) * ((T_years *
lambda_yearly_dm) ^ sha1_dm[1] - 1)
re2m85_dm <- loc2_dm[1] + (sca2_dm[1] / sha2_dm[1]) * ((T_years *
lambda_yearly_dm) ^ sha2_dm[1] - 1)
re3m85_dm <- loc3_dm[1] + (sca3_dm[1] / sha3_dm[1]) * ((T_years *
lambda_yearly_dm) ^ sha3_dm[1] - 1)
re4m85_dm <- loc4_dm[1] + (sca4_dm[1] / sha4_dm[1]) * ((T_years *
lambda_yearly_dm) ^ sha4_dm[1] - 1)
return85_dm <- data.frame(Return_Period_Years = T_years, Return_MLE =
re1m85_dm, Return_GMLE = re2m85_dm, Return_BAY = re3m85_dm, Return_LMOM
= re4m85_dm)
# Return Level 90%

```

```

dm_count <- length(ym_dm[1:240][ym_dm[1:240] > t_dm[2]])
months_dm <- length(ym_dm[1:240])
lambda_monthly_dm <- dm_count / months_dm
lambda_yearly_dm <- lambda_monthly_dm * 12
T_years <- seq(2,10)
re1m90_dm <- loc1_dm[2] + (sca1_dm[2] / sha1_dm[2]) * ((T_years *
lambda_yearly_dm) ^ sha1_dm[2] - 1)
re2m90_dm <- loc2_dm[2] + (sca2_dm[2] / sha2_dm[2]) * ((T_years *
lambda_yearly_dm) ^ sha2_dm[2] - 1)
re3m90_dm <- loc3_dm[2] + (sca3_dm[2] / sha3_dm[2]) * ((T_years *
lambda_yearly_dm) ^ sha3_dm[2] - 1)
re4m90_dm <- loc4_dm[2] + (sca4_dm[2] / sha4_dm[2]) * ((T_years *
lambda_yearly_dm) ^ sha4_dm[2] - 1)
return90_dm <- data.frame(Return_Period_Years = T_years, Return_MLE =
re1m90_dm, Return_GMLE = re2m90_dm, Return_BAY = re3m90_dm, Return_LMOM
= re4m90_dm)
# Return Level 95%
dm_count <- length(ym_dm[1:240][ym_dm[1:240] > t_dm[3]])
months_dm <- length(ym_dm[1:240])
lambda_monthly_dm <- dm_count / months_dm
lambda_yearly_dm <- lambda_monthly_dm * 12
T_years <- seq(2,10)
re1m95_dm <- loc1_dm[3] + (sca1_dm[3] / sha1_dm[3]) * ((T_years *
lambda_yearly_dm) ^ sha1_dm[3] - 1)
re2m95_dm <- loc2_dm[3] + (sca2_dm[3] / sha2_dm[3]) * ((T_years *
lambda_yearly_dm) ^ sha2_dm[3] - 1)
re3m95_dm <- loc3_dm[3] + (sca3_dm[3] / sha3_dm[3]) * ((T_years *
lambda_yearly_dm) ^ sha3_dm[3] - 1)
re4m95_dm <- loc4_dm[3] + (sca4_dm[3] / sha4_dm[3]) * ((T_years *
lambda_yearly_dm) ^ sha4_dm[3] - 1)

```

```

return95_dm <- data.frame(Return_Period_Years = T_years, Return_MLE =
re1m95_dm, Return_GMLE = re2m95_dm, Return_BAY = re3m95_dm, Return_LMOM
= re4m95_dm)
# คำนวณระดับการเกิดซ้ำสำหรับข้อมูลปริมาณน้ำฝนสูงสุดสถานีบางนา
# Return Level 85%
bn_count <- length(ym_bn[1:240][ym_bn[1:240] > t_bn[1]])
months_bn <- length(ym_bn[1:240])
lambda_monthly_bn <- bn_count / months_bn
lambda_yearly_bn <- lambda_monthly_bn * 12
T_years <- seq(2,10)
re1m85_bn <- loc1_bn[1] + (sca1_bn[1] / sha1_bn[1]) * ((T_years *
lambda_yearly_bn) ^ sha1_bn[1] - 1)
re2m85_bn <- loc2_bn[1] + (sca2_bn[1] / sha2_bn[1]) * ((T_years *
lambda_yearly_bn) ^ sha2_bn[1] - 1)
re3m85_bn <- loc3_bn[1] + (sca3_bn[1] / sha3_bn[1]) * ((T_years *
lambda_yearly_bn) ^ sha3_bn[1] - 1)
re4m85_bn <- loc4_bn[1] + (sca4_bn[1] / sha4_bn[1]) * ((T_years *
lambda_yearly_bn) ^ sha4_bn[1] - 1)
return85_bn <- data.frame(Return_Period_Years = T_years, Return_MLE = re1m85_bn,
Return_GMLE = re2m85_bn, Return_BAY = re3m85_bn, Return_LMOM = re4m85_bn)
# Return Level 90%
bn_count <- length(ym_bn[1:240][ym_bn[1:240] > t_bn[2]])
months_bn <- length(ym_bn[1:240])
lambda_monthly_bn <- bn_count / months_bn
lambda_yearly_bn <- lambda_monthly_bn * 12
T_years <- seq(2,10)
re1m90_bn <- loc1_bn[2] + (sca1_bn[2] / sha1_bn[2]) * ((T_years *
lambda_yearly_bn) ^ sha1_bn[2] - 1)
re2m90_bn <- loc2_bn[2] + (sca2_bn[2] / sha2_bn[2]) * ((T_years *
lambda_yearly_bn) ^ sha2_bn[2] - 1)

```

```

re3m90_bn <- loc3_bn[2] + (sca3_bn[2] / sha3_bn[2]) * ((T_years *
lambda_yearly_bn) ^ sha3_bn[2] - 1)
re4m90_bn <- loc4_bn[2] + (sca4_bn[2] / sha4_bn[2]) * ((T_years *
lambda_yearly_bn) ^ sha4_bn[2] - 1)
return90_bn <- data.frame(Return_Period_Years = T_years, Return_MLE = re1m90_bn,
Return_GMLE = re2m90_bn, Return_BAY = re3m90_bn, Return_LMOM = re4m90_bn)
# Return Level 95%
bn_count <- length(ym_bn[1:240][ym_bn[1:240] > t_bn[3]])
months_bn <- length(ym_bn[1:240])
lambda_monthly_bn <- bn_count / months_bn
lambda_yearly_bn <- lambda_monthly_bn * 12
T_years <- seq(2,10)
re1m95_bn <- loc1_bn[3] + (sca1_bn[3] / sha1_bn[3]) * ((T_years *
lambda_yearly_bn) ^ sha1_bn[3] - 1)
re2m95_bn <- loc2_bn[3] + (sca2_bn[3] / sha2_bn[3]) * ((T_years *
lambda_yearly_bn) ^ sha2_bn[3] - 1)
re3m95_bn <- loc3_bn[3] + (sca3_bn[3] / sha3_bn[3]) * ((T_years *
lambda_yearly_bn) ^ sha3_bn[3] - 1)
re4m95_bn <- loc4_bn[3] + (sca4_bn[3] / sha4_bn[3]) * ((T_years *
lambda_yearly_bn) ^ sha4_bn[3] - 1)
return95_bn <- data.frame(Return_Period_Years = T_years, Return_MLE = re1m95_bn,
Return_GMLE = re2m95_bn, Return_BAY = re3m95_bn, Return_LMOM = re4m95_bn)
# คำนวณระดับการเกิดซ้ำสำหรับข้อมูลปริมาณน้ำฝนสูงสุดสถานีคลองเตย
# Return Level 85%
kt_count <- length(ym_kt[1:240][ym_kt[1:240] > t_kt[1]])
months_kt <- length(ym_kt[1:240])
lambda_monthly_kt <- kt_count / months_kt
lambda_yearly_kt <- lambda_monthly_kt * 12
T_years <- seq(2,10)
re1m85_kt <- loc1_kt[1] + (sca1_kt[1] / sha1_kt[1]) * ((T_years * lambda_yearly_kt) ^
sha1_kt[1] - 1)

```

```

re2m85_kt <- loc2_kt[1] + (sca2_kt[1] / sha2_kt[1]) * ((T_years * lambda_yearly_kt) ^
  sha2_kt[1] - 1)
re3m85_kt <- loc3_kt[1] + (sca3_kt[1] / sha3_kt[1]) * ((T_years * lambda_yearly_kt) ^
  sha3_kt[1] - 1)
re4m85_kt <- loc4_kt[1] + (sca4_kt[1] / sha4_kt[1]) * ((T_years * lambda_yearly_kt) ^
  sha4_kt[1] - 1)
return85_kt <- data.frame(Return_Period_Years = T_years, Return_MLE = re1m85_kt,
  Return_GMLE = re2m85_kt, Return_BAY = re3m85_kt, Return_LMOM =
  re4m85_kt)
# Return Level 90%
kt_count <- length(ym_kt[1:240][ym_kt[1:240] > t_kt[2]])
months_kt <- length(ym_kt[1:240])
lambda_monthly_kt <- kt_count / months_kt
lambda_yearly_kt <- lambda_monthly_kt * 12
T_years <- seq(2,10)
re1m90_kt <- loc1_kt[2] + (sca1_kt[2] / sha1_kt[2]) * ((T_years * lambda_yearly_kt) ^
  sha1_kt[2] - 1)
re2m90_kt <- loc2_kt[2] + (sca2_kt[2] / sha2_kt[2]) * ((T_years * lambda_yearly_kt) ^
  sha2_kt[2] - 1)
re3m90_kt <- loc3_kt[2] + (sca3_kt[2] / sha3_kt[2]) * ((T_years * lambda_yearly_kt) ^
  sha3_kt[2] - 1)
re4m90_kt <- loc4_kt[2] + (sca4_kt[2] / sha4_kt[2]) * ((T_years * lambda_yearly_kt) ^
  sha4_kt[2] - 1)
return90_kt <- data.frame(Return_Period_Years = T_years, Return_MLE = re1m90_kt,
  Return_GMLE = re2m90_kt, Return_BAY = re3m90_kt, Return_LMOM =
  re4m90_kt)
# Return Level 95%
kt_count <- length(ym_kt[1:240][ym_kt[1:240] > t_kt[3]])
months_kt <- length(ym_kt[1:240])
lambda_monthly_kt <- kt_count / months_kt
lambda_yearly_kt <- lambda_monthly_kt * 12

```

```

T_years <- seq(2,10)
re1m95_kt <- loc1_kt[3] + (sca1_kt[3] / sha1_kt[3]) * ((T_years * lambda_yearly_kt) ^
  sha1_kt[3] - 1)
re2m95_kt <- loc2_kt[3] + (sca2_kt[3] / sha2_kt[3]) * ((T_years * lambda_yearly_kt) ^
  sha2_kt[3] - 1)
re3m95_kt <- loc3_kt[3] + (sca3_kt[3] / sha3_kt[3]) * ((T_years * lambda_yearly_kt) ^
  sha3_kt[3] - 1)
re4m95_kt <- loc4_kt[3] + (sca4_kt[3] / sha4_kt[3]) * ((T_years * lambda_yearly_kt) ^
  sha4_kt[3] - 1)
return95_kt <- data.frame(Return_Period_Years = T_years, Return_MLE = re1m95_kt,
  Return_GMLE = re2m95_kt, Return_BAY = re3m95_kt, Return_LMOM =
  re4m95_kt)
# -----
# pp plot, qq plot และ density plot สำหรับข้อมูลปริมาณน้ำฝนสูงสุดสถานี QSNCC
fit4m_qsncc <- fevd(ym_qsncc[1:240], threshold = quantile(ym_qsncc[1:240],0.90),
  type = "GP", method = "Lmoments")
par(mfrow = c(1,3))
plot(fit4m_qsncc, main = "PP Plot", type = "probprob")
plot(fit4m_qsncc, main = "QQ Plot", type = "qq")
plot(fit4m_qsncc, main = "Density Plot", type = "density")
mtext("Diagnostic Plot for Monthly Maximum Rainfall at QSNCC", outer = TRUE, side =
  3, line = -1.5, cex = 1.1)
# pp plot, qq plot และ density plot สำหรับข้อมูลปริมาณน้ำฝนสูงสุดสถานีดอนเมือง
fit2m_dm <- fevd(ym_dm[1:240], threshold = quantile(ym_dm[1:240],0.95), type =
  "GP", method = "GMLE" )
plot(fit2m_dm, main = "PP Plot", type = "probprob")
plot(fit2m_dm, main = "QQ Plot", type = "qq")
plot(fit2m_dm, main = "Density Plot", type = "density")
mtext("Diagnostic Plot for Monthly Maximum Rainfall at DONMUANG", outer = TRUE,
  side = 3, line = -1.5, cex = 1.1)
# pp plot, qq plot และ density plot สำหรับข้อมูลปริมาณน้ำฝนสูงสุดสถานีบางนา

```

```

fit1m_bn <- fevd(ym_bn[1:240], threshold = quantile(ym_bn[1:240],0.90), type = "GP",
                method = "MLE" )
plot(fit1m_bn, main = "PP Plot", type = "probprob")
plot(fit1m_bn, main = "QQ Plot", type = "qq")
plot(fit1m_bn, main = "Density Plot", type = "density")
mtext("Diagnostic Plot for Monthly Maximum Rainfall at BANGNA", outer = TRUE, side
      = 3, line = -1.5, cex = 1.1)
# pp plot, qq plot และ density plot สำหรับข้อมูลปริมาณน้ำฝนสูงสุดสถานีคลองเตย
fit4m_kt <- fevd(ym_kt[1:240], threshold = quantile(ym_kt[1:240],0.95), type = "GP",
                method = "Lmoments")
plot(fit4m_kt, main = "PP Plot", type = "probprob")
plot(fit4m_kt, main = "QQ Plot", type = "qq")
plot(fit4m_kt, main = "Density Plot", type = "density")
mtext("Diagnostic Plot for Monthly Maximum Rainfall at KLONGTOEY", outer = TRUE,
      side = 3, line = -1.5, cex = 1.1)
# -----
# พล็อตกราฟแสดงการเปรียบเทียบค่าประมาณระดับการเกิดซ้ำสำหรับวิธีการประมาณค่าที่ทำให้ตัว
# แบบสำหรับแต่ละสถานีมีค่า MAPE ต่ำสุด
plot(return_level, lmom_qsncc_90, type = 'b', lty = 1, lwd = 1.5, xlim = c(2,10), ylim =
      c(90,160), col = "slateblue1", xlab = 'Return Period (Year)', ylab = 'Rainfall
      (mm)', pch = 15, main = "Return Level of Each Station")
lines(return_level, gmle_dm_95, type = 'b', col = "orangered", lty = 1, lwd = 1.5,
      pch = 17)
lines(return_level, mle_bn_90, type = 'b', col = "midnightblue", lty = 1, lwd = 1.5,
      pch = 25)
lines(return_level, gmle_kt_95, type = 'b', col = "green4", lty = 1, lwd = 1.5, pch = 18)
labels <- c("SQNCC", "DONMUANG", "BANGNA", "KLONGTOEY")
pchset <- c(15, 16, 17, 25, 18)
colorset <- c("slateblue1", "orangered", "midnightblue", "green4")
legend("bottom", horiz = TRUE, inset = .01, labels, lwd = 2, lty = 1, pch = pchset,
      col=colorset, cex=0.6)

```

ประวัติผู้เขียน

ชื่อ-สกุล	นายภราดร สุขแป้น
วัน เดือน ปี เกิด	16 พฤศจิกายน 2540
สถานที่เกิด	โรงพยาบาลบ้านโป่ง 12 ถนนแสงชูโต ต.บ้านโป่ง อ.บ้านโป่ง จ.ราชบุรี 70110
ประวัติการศึกษา	(2563) วิทยาศาสตรบัณฑิต สาขาสถิติธุรกิจและการประกันภัย เกรดเฉลี่ย 3.58 (มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ) (2568) วิทยาศาสตรมหาบัณฑิต สาขาสถิติประยุกต์ เกรดเฉลี่ย 4.00 (สถาบันเทคโนโลยีพระจอมเกล้าคุณทหารลาดกระบัง)
ที่อยู่ปัจจุบัน	22/63 ถนนติวานนท์ ต.ตลาดขวัญ อ.เมืองนนทบุรี จ.นนทบุรี 11000
ผลงานตีพิมพ์	Parameter Estimation for Generalized Extreme Value Distribution in Rainfall Forecasting: A Case Study of Bangkok, Journal of Applied Science and Engineering
รางวัลที่ได้รับ	-
ทุนการศึกษา	ทุนสนับสนุนการวิจัยสำหรับอาจารย์ที่ปรึกษาของผู้ช่วยวิจัยระดับ บัณฑิตศึกษา กองทุนวิจัย สถาบันเทคโนโลยีพระจอมเกล้าคุณทหาร ลาดกระบัง ประจำปี 2566