

การศึกษาความเหมาะสมของโครงข่ายในแบบจำลองโยธาเทียม  
สำหรับการพยากรณ์น้ำท่ารายวัน ในพื้นที่ลุ่มน้ำปราจีนบุรี



นายธนพล พิमान

สถาบันวิทยบริการ  
จุฬาลงกรณ์มหาวิทยาลัย

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต

สาขาวิชาวิศวกรรมแหล่งน้ำ ภาควิชาวิศวกรรมแหล่งน้ำ

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

ปีการศึกษา 2545

ISBN 974-17-2680-5

ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

OPTIMIZATION OF NETWORKS IN ARTIFICIAL NEURAL NETWORKS MODEL  
FOR DAILY RUNOFF FORECASTING IN PRACHINBURI WATERSHED

Mr.Thanapon Piman

สถาบันวิทยบริการ

A Thesis Submitted in Partial Fulfillment of the Requirements  
for the Degree of Master of Engineering in Water Resources Engineering

Department of Water Resources Engineering

Faculty of Engineering

Chulalongkorn University

Academic Year 2002

ISBN 974-17-2680-5

หัวข้อวิทยานิพนธ์

การศึกษาความเหมาะสมของโครงข่ายในแบบจำลองใยประสาทเทียม  
สำหรับการพยากรณ์น้ำท่ารายวัน ในพื้นที่ลุ่มน้ำปราจีนบุรี

โดย

นายธนพล พิमान

สาขาวิชา

วิศวกรรมแหล่งน้ำ

อาจารย์ที่ปรึกษา

ผู้ช่วยศาสตราจารย์ ดร.ทวนทัน กิจไพศาลสกุล

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้นำวิทยานิพนธ์ฉบับนี้เป็นส่วน  
หนึ่งของการศึกษาตามหลักสูตรปริญญาโทบริหารบัณฑิต



..... คณบดีคณะวิศวกรรมศาสตร์

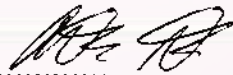
(ศาสตราจารย์ ดร.สมศักดิ์ ปัญญาแก้ว)

คณะกรรมการสอบวิทยานิพนธ์



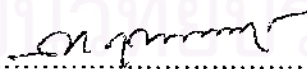
..... ประธานกรรมการ

(ผู้ช่วยศาสตราจารย์ ดร.เสวี จันทร์โยธิน)



..... อาจารย์ที่ปรึกษา

(ผู้ช่วยศาสตราจารย์ ดร.ทวนทัน กิจไพศาลสกุล)



..... กรรมการ

(รองศาสตราจารย์ ดร.สุจิตต์ คุณธนกุลวงศ์)



..... กรรมการ

(รองศาสตราจารย์ ดร.ธนิศ ธงทอง)

ธนพล ทิฆามาน : การศึกษาความเหมาะสมของโครงข่ายในแบบจำลองไฮประสาทเทียม  
สำหรับการพยากรณ์น้ำท่ารายวัน ในพื้นที่ลุ่มน้ำปราจีนบุรี (OPTIMIZATION OF  
NETWORKS IN ARTIFICIAL NEURAL NETWORKS MODEL FOR DAILY RUNOFF  
FORECASTING IN PRACHIN WATERSHED) อ.ที่ปรึกษา : ผศ.ดร.ทวนทัน กิจไพศาล  
สกุล , 284 หน้า , ISBN 974-17-2680-5

ในปัจจุบันได้มีการศึกษาและพัฒนาแบบจำลองไฮประสาทเทียม (Artificial Neural Networks, ANN) มาใช้ในการพยากรณ์น้ำท่ารายวันกันอย่างแพร่หลาย โดยในการพัฒนาแบบจำลอง ANN นั้นมักจะประสบปัญหาในการคัดเลือกชุดตัวแปรนำเข้าและลักษณะโครงข่ายภายในแบบจำลอง อันได้แก่ จำนวนชั้นแอบแฝง (hidden layer) และจำนวนหน่วย (node) ในชั้นแอบแฝงที่เหมาะสม ซึ่งทำให้เสียเวลามากในการพัฒนาแบบจำลอง

ในการศึกษาวิทยานิพนธ์นี้จึงมีจุดมุ่งหมายเพื่อหาแนวทางในการคัดเลือกชุดตัวแปรนำเข้าและลักษณะโครงข่ายภายในที่เหมาะสมในแบบจำลอง ANN เพื่อใช้ในการพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า 1-7 วัน ณ สถานีวัดน้ำท่า 6 แห่ง ในพื้นที่ลุ่มน้ำปราจีนบุรี โดยได้จัดสร้างแบบจำลองแยกออกตามฤดูกาล คือ แบบจำลองที่ใช้สำหรับฤดูฝนและสำหรับฤดูแล้ง จากผลการศึกษาพบว่า ฟังก์ชันความสัมพันธ์ระหว่างตัวแปรต่างๆ เทียบกับเวลา (correlation function) สามารถนำมาใช้เป็นแนวทางในการคัดเลือกชุดตัวแปรนำเข้าที่เหมาะสมสู่แบบจำลองได้ดี และจำนวนหน่วยในชั้นแอบแฝงที่เหมาะสมในแบบจำลอง ANN นั้น พบว่าควรมีจำนวนเท่ากับจำนวนตัวแปรนำเข้า โดยถ้าหากแบบจำลองมีจำนวนตัวแปรนำเข้าตั้งแต่ 5 ตัวขึ้นไป ควรแบ่งชั้นแอบแฝงออกเป็น 2 ชั้น และในแต่ละชั้นจะมีจำนวนหน่วยเป็นครึ่งหนึ่งของจำนวนตัวแปรนำเข้า

สำหรับการพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้าหลายวันนั้นควรใช้แบบจำลอง ANN ร่วมกับการพยากรณ์โดยวิธี Standard step ซึ่งจะทำการพยากรณ์ล่วงหน้าวันต่อวัน เนื่องจากให้ผลการพยากรณ์ที่ดีกว่าการพยากรณ์โดยวิธี Direct step ที่จะพยากรณ์ล่วงหน้าภายในครั้งเดียว นอกจากนี้ยังพบว่าแบบจำลอง ANN ให้ผลการพยากรณ์ที่ดีกว่าแบบจำลองถดถอยเชิงเส้นตัวแปรอิสระหลายตัว (Multiple Linear Regression, MLR) โดยเฉพาะเมื่อระยะเวลาในการพยากรณ์ยาวนานขึ้น และเมื่อนำแบบจำลองอนุกรมเวลา อันได้แก่ MA(2) และ AR(2) มาใช้ในการปรับปรุงผลการพยากรณ์ของแบบจำลอง ANN พบว่าช่วยให้แบบจำลองมีประสิทธิภาพในการพยากรณ์เพิ่มขึ้นประมาณ 0.6-14.7%

ภาควิชา.....วิศวกรรมแหล่งน้ำ.....  
สาขาวิชา.....วิศวกรรมแหล่งน้ำ.....  
ปีการศึกษา.....2545.....

ลายมือชื่อนิสิต.....  
ลายมือชื่ออาจารย์ที่ปรึกษา.....

# # 4370321321: MAJOR WATER RESOURCES ENGINEERING

KEY WORD: OPTIMIZATION / ARTIFICIAL NEURAL NETWORKS / RUNOFF FORECASTING

THANAPON PIMAN : OPTIMIZATION OF NETWORKS IN ARTIFICIAL NEURAL NETWORKS MODEL FOR DAILY RUNOFF FORECASTING IN PRACHIN WATERSHED. THESIS ADVISOR : ASSIST.PROF. TUANTAN KITPAISALSAKUL, Ph.D., 284 pp. , ISBN 974-17-2680-5

At present, Artificial neural networks (ANN) have been studied and developed for forecasting daily runoff widely. However, the development of ANN models always have problems such as the selection of optimal input parameters and network architectures that related to number of layers and nodes in hidden layers. These problems consume considerable times in model development.

The purpose of this thesis was to determine the method in selecting optimal input parameters and network architectures in ANN models for forecasting daily runoff 1-7 days ahead at 6 runoff gauging stations in Prachin watershed. The models were developed and classified according to seasons; rainfall season and dry season. From the study results, it was found that correlation functions were applicable to select optimal input parameters into ANN models. For the optimal number of nodes in the hidden layer, it was found that the optimal nodes of hidden layer should be equal to a number of input parameters. If a number of input parameters equal five or more, the hidden layer should be divided in two layers in which each layer contain half a number of input parameters.

For forecasting daily runoff several days ahead, it was recommended to apply the ANN models along with the Standard step method that forecast ahead day by day since this method could give better forecast than the Direct step method that forecasting once. In addition, it was found that the ANN models could give better forecast than the Multiple linear regression models (MLR) especially in longer forecasting time period. The time series models; MA(2) and AR(2) could improve the forecasting results of ANN models as the efficiency in forecasting increased about 0.6-14.7%.

Department ...Water Resources Engineering... Student's signature.....*T. P.*  
Field of study. Water Resources Engineering... Advisor's signature.....*Tuantan Kitpaisalsakul*  
Academic year.....2002.....

## กิตติกรรมประกาศ

ในการทำวิทยานิพนธ์ของข้าพเจ้าครั้งนี้ ข้าพเจ้าได้รับคำแนะนำ ความช่วยเหลือ และความอนุเคราะห์ จากบุคคลและหน่วยงานต่างๆ ดังต่อไปนี้

ขอขอบพระคุณ ผู้ช่วยศาสตราจารย์ ดร.ทวนทัน กิจไพศาลสกุล อาจารย์ที่ปรึกษาวิทยานิพนธ์ ที่ได้ให้คำปรึกษาแนะนำ อย่างใกล้ชิดมาโดยตลอด ทั้งยังให้การช่วยสนับสนุน ผลักดัน ในการทำวิทยานิพนธ์ของข้าพเจ้าครั้งนี้ให้สำเร็จลุล่วงไปได้ด้วยดี

ขอขอบพระคุณ ผู้ช่วยศาสตราจารย์ ดร.เสรี จันทโรยธำ รองศาสตราจารย์ ดร.สุจิต คุณ-ธนกุลวงศ์ และผู้ช่วยศาสตราจารย์ ดร.ธนิต ธงทอง ประธานและกรรมการสอบวิทยานิพนธ์ที่ได้กรุณาสละเวลาของท่านในการให้คำชี้แนะ และตรวจแก้ไขวิทยานิพนธ์ รวมทั้งคณาจารย์ทุกท่านที่ได้ประสิทธิ์ประสาทวิชาการต่างๆ แก่ข้าพเจ้า

ขอขอบพระคุณ รองศาสตราจารย์ ดร.ชัยพันธุ์ รักรวิชัย หัวหน้าภาควิชาวิศวกรรมแหล่งน้ำ ที่ช่วยชี้ข้อบกพร่องในด้านต่างๆ ของข้าพเจ้า ตลอดทั้งยังได้ให้แนวทางแก้ไข และคำสอนเชิงปรัชญาสำหรับการดำเนินชีวิตในวันข้างหน้า

ขอขอบคุณ ภาควิชาวิศวกรรมแหล่งน้ำ และบุคลากรของภาคทุกท่าน ที่ให้ความช่วยเหลือ ในด้านอุปกรณ์คอมพิวเตอร์ และการติดต่อประสานงานในเรื่องต่างๆ ขอขอบคุณ พี่ๆ เพื่อนๆ น้องๆ ชาวแหล่งน้ำทุกท่าน ที่ช่วยเป็นกำลังใจ และให้ความช่วยเหลือในด้านต่างๆ มาด้วยดีตลอด รวมทั้งขอขอบคุณบุคคลต่างๆ ที่ช่วยในการจัดเตรียมรูปเล่มวิทยานิพนธ์

ขอขอบคุณ กรมชลประทาน กรมพัฒนาและส่งเสริมพลังงาน และบริษัทโปรเกรส เทคโนโลยีคอนกรีตแท่นส์ จำกัด ที่ให้ความอนุเคราะห์ ในเรื่องข้อมูลต่างๆ

ขอขอบคุณ ทบวงมหาวิทยาลัย และบัณฑิตวิทยาลัย จุฬาลงกรณ์ มหาวิทยาลัย ที่ให้การสนับสนุนด้านงบประมาณในการทำวิทยานิพนธ์

ท้ายสุดนี้ข้าพเจ้าขอขอบพระคุณ บิดา มารดา และคนในครอบครัวของข้าพเจ้า เป็นอย่างยิ่ง ที่คอยให้โอกาส ความเป็นห่วงเป็นใย และกำลังใจ ที่ดีต่อข้าพเจ้า มาโดยตลอด

ธนพล พิमान

## สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ง
บทคัดย่อภาษาอังกฤษ.....	จ
กิตติกรรมประกาศ.....	ฉ
สารบัญ.....	ช
สารบัญตาราง.....	ฎ
สารบัญรูป.....	ฏ
<b>บทที่ 1 บทนำ</b>	
1.1 ความเป็นมาและความสำคัญของปัญหา.....	1
1.2 วัตถุประสงค์ของการศึกษา.....	2
1.3 ขอบข่ายการศึกษา.....	3
1.4 ขั้นตอนการดำเนินการศึกษาและระยะเวลาที่ใช้.....	5
1.5 ประโยชน์ที่คาดว่าจะได้รับ.....	5
<b>บทที่ 2 ทบทวนผลการศึกษาที่ผ่านมา</b>	
2.1 แบบจำลองการพยากรณ์น้ำท่าที่ผ่านมา.....	7
2.2 การประยุกต์ใช้แบบจำลอง ANN ในงานด้านแหล่งน้ำ.....	8
2.3 การพัฒนาแบบจำลอง ANN.....	11
2.4 การประยุกต์ใช้แบบจำลองอนุกรมเวลา.....	13
2.5 สรุปสิ่งที่ได้จากการศึกษาที่ผ่านมา.....	14
2.5.1 ด้านอุทกวิทยา.....	14
2.5.2 ด้านแบบจำลอง ANN.....	15
2.5.3 ด้านการปรับปรุงผลการพยากรณ์.....	16
<b>บทที่ 3 ทฤษฎีที่ใช้ในการศึกษา</b>	
3.1 ฟังก์ชันความสัมพันธ์ของตัวแปรเดียวกันและต่างกันเทียบกับเวลา.....	17
3.1.1 การวิเคราะห์ความสัมพันธ์ของตัวแปรเดียวกันเทียบกับเวลา.....	17

3.1.2 การวิเคราะห์ความสัมพันธ์ของตัวแปรเดียวกันในส่วนสุดท้ายเทียบกับเวลา.....	19
3.1.3 การวิเคราะห์ความสัมพันธ์ของตัวแปรต่างกันเทียบกับเวลา.....	23
3.2 แบบจำลอง Back Propagation Neural Network (BPNN).....	25
3.2.1 โครงสร้างของแบบจำลอง BPNN.....	25
3.2.2 หลักการทำงานพื้นฐานของแบบจำลอง.....	25
3.2.3 ขั้นตอนการทำงานกระบวนการเรียนรู้ในแบบจำลอง.....	27
3.2.4 ข้อพิจารณาพื้นฐานในการพัฒนาแบบจำลอง ANN.....	30
3.3 แบบจำลองอนุกรมเวลา.....	34
3.3.1 แบบจำลอง Autoregressive (AR).....	34
3.3.2 แบบจำลอง Moving Average (MA).....	35
3.3.3 แบบจำลอง Autoregressive-Moving Average (ARMA).....	36
3.3.4 การเลือกชนิดและอันดับของแบบจำลองอนุกรมเวลา.....	37
3.4 แบบจำลองถดถอยเชิงเส้นแบบตัวแปรอิสระหลายตัว (MLR).....	38
3.5 ตัวแปรสถิติที่ใช้วัดประสิทธิภาพของแบบจำลอง.....	39
<b>บทที่ 4 พื้นที่ศึกษาและการวิเคราะห์ข้อมูล</b>	
4.1 สภาพพื้นที่ศึกษา.....	41
4.1.1 สภาพภูมิประเทศและระบบลุ่มน้ำ.....	41
4.1.2 สภาพภูมิอากาศ.....	44
4.1.3 สภาพอุตุ-อุทกวิทยา.....	44
4.2 การวิเคราะห์ข้อมูล.....	49
4.2.1 ข้อมูลที่ใช้ในการศึกษา.....	49
4.2.2 การประมาณค่าปริมาณน้ำฝนที่ขาดหายไป.....	51
4.2.3 การตรวจสอบความน่าเชื่อถือของข้อมูล.....	53
4.2.4 การแบ่งช่วงข้อมูลสำหรับฤดูฝน-ฤดูแล้ง.....	56
4.2.5 การแบ่งช่วงข้อมูลเปรียบเทียบ ปรึบทาน และรับรองผล แบบจำลอง.....	57



**บทที่ 5 วิธีการดำเนินการศึกษา**

5.1 การพัฒนาแบบจำลอง ANN.....	58
5.1.1 การวิเคราะห์และคัดเลือกข้อมูล.....	58
5.1.2 การปรับเทียบแบบจำลอง.....	62
5.1.3 การปรับทานแบบจำลอง.....	65
5.1.4 การคัดเลือกแบบจำลองและการนำไปประยุกต์ใช้งาน.....	65
5.2 การปรับปรุงผลการพยากรณ์.....	66
5.3 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN และ MLR.....	67

**บทที่ 6 ผลการศึกษา**

6.1 แบบจำลองการพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้าในฤดูฝน.....	68
6.1.1 การคัดเลือกชุดตัวแปรนำเข้าสู่สำหรับพยากรณ์อัตราการไหลน้ำท่า รายวันล่วงหน้า 1 วัน.....	68
6.1.2 การคัดเลือกโครงข่ายภายในที่เหมาะสมในแบบจำลอง ANN.....	88
6.1.3 การปรับปรุงผลการพยากรณ์และการพยากรณ์ล่วงหน้ามากกว่า 1 วัน.	90
6.1.4 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN และ MLR.	107
6.1.5 การประยุกต์ใช้แบบจำลอง ANN.....	108
6.2 แบบจำลองการพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้าในฤดูแล้ง.....	116
6.2.1 การคัดเลือกชุดตัวแปรนำเข้าสู่สำหรับพยากรณ์อัตราการไหลน้ำท่า รายวันล่วงหน้า 1 วัน.....	116
6.2.2 การคัดเลือกโครงข่ายภายในที่เหมาะสมในแบบจำลอง ANN.....	127
6.2.3 การปรับปรุงผลการพยากรณ์และการพยากรณ์ล่วงหน้ามากกว่า 1 วัน.	128
6.2.4 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN และ MLR.	152
6.2.5 การประยุกต์ใช้แบบจำลอง ANN.....	154

**บทที่ 7 สรุปผลและข้อเสนอแนะ**

7.1 สรุปผลการศึกษา.....	166
7.2 ข้อเสนอแนะ.....	173

สารบัญ (ต่อ)

ญ

หน้า

รายการอ้างอิง.....	175
ภาคผนวก	
ภาคผนวก ก รูปตัดตามยาวและตามขวางของแม่น้ำต่างๆในพื้นที่ศึกษา.....	179
ภาคผนวก ข การวิเคราะห์ข้อมูลเบื้องต้น.....	186
ภาคผนวก ค การคัดเลือกโครงข่ายภายในที่เหมาะสมในแบบจำลอง ANN.....	193
ภาคผนวก ง การตรวจสอบความเป็นอิสระของอนุกรมค่าความผิดพลาด.....	233
ภาคผนวก จ ค่าพารามิเตอร์ในแบบจำลอง ANN และแบบจำลองอนุกรมเวลา ...	255
ภาคผนวก ฉ การพยากรณ์อัตราการไหลน้ำท่ารายวันโดยใช้แบบจำลอง MLR ....	274
ภาคผนวก ช การวิเคราะห์ $\Delta Q_{peak}$ และ $\Delta T_{peak}$	281
ประวัติผู้เขียนวิทยานิพนธ์.....	284

สถาบันวิทยบริการ  
จุฬาลงกรณ์มหาวิทยาลัย

## สารบัญตาราง

	หน้า
ตาราง 1-1 ระยะเวลาที่ใช้ในการดำเนินการ.....	6
ตาราง 3-1 ลักษณะของฟังก์ชันความสัมพันธ์แบบ autocorrelation และ partial autocorrelation เพื่อใช้คัดเลือกแบบจำลองอนุกรมเวลา.....	37
ตาราง 4-1 สรุปช่วงพิสัยของค่าเฉลี่ยรายปีของตัวแปรภูมิอากาศที่สำคัญในลุ่มน้ำปราจีนบุรี.....	45
ตาราง 4-2 ปริมาณน้ำท่าเฉลี่ยรายปีของสถานีวัดน้ำท่าในพื้นที่ศึกษา.....	47
ตาราง 4-3 อัตราการไหลน้ำท่าเฉลี่ยรายวันของสถานีวัดน้ำท่าในพื้นที่ศึกษา.....	47
ตาราง 4-4 ช่วงข้อมูลและแหล่งที่มาของสถานีวัดน้ำท่าที่ใช้ในการศึกษา.....	51
ตาราง 4-5 ช่วงข้อมูลและแหล่งที่มาของสถานีวัดน้ำท่าที่ใช้ในการศึกษา.....	51
ตาราง 5-1 การคัดเลือกค่าพารามิเตอร์ในแบบจำลอง ANN.....	64
ตาราง 6-1 ชุดตัวแปรนำเข้าเบื้องต้นสำหรับการพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า 1 วัน ในฤดูฝน.....	71
ตาราง 6-2 ค่าความสัมพันธ์แบบ cross correlation ระหว่างอัตราการไหลน้ำท่ารายวัน ณ สถานี KGT.3 และ สถานีวัดน้ำท่าด้านเหนือในฤดูฝน.....	72
ตาราง 6-3 ผลการทดสอบตัวแปรนำเข้าสำหรับพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า 1 วัน ณ สถานี 150401 ในช่วงฤดูฝน.....	74
ตาราง 6-4 ผลการทดสอบตัวแปรนำเข้าสำหรับพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า 1 วัน ณ สถานี KGT.14 ในช่วงฤดูฝน.....	75
ตาราง 6-5 ผลการทดสอบตัวแปรนำเข้าสำหรับพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า 1 วัน ณ สถานี KGT.15A ในช่วงฤดูฝน.....	76
ตาราง 6-6 ผลการทดสอบตัวแปรนำเข้าสำหรับพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า 1 วัน ณ สถานี KGT.12 ในช่วงฤดูฝน.....	77
ตาราง 6-7 ผลการทดสอบตัวแปรนำเข้าสำหรับพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า 1 วัน ณ สถานี KGT.10 ในช่วงฤดูฝน.....	78
ตาราง 6-8 ผลการทดสอบตัวแปรนำเข้าสำหรับพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า 1 วัน ณ สถานี KGT.3 ในช่วงฤดูฝน.....	79
ตาราง 6-9 การคัดเลือกค่าโมเมนตัมและอัตราการเรียนรู้.....	85

## สารบัญตาราง (ต่อ)

	๘ หน้า
ตาราง 6-10 สรุปโครงข่ายภายในที่เหมาะสมในแบบจำลอง ANN สำหรับพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า 1 วัน ในฤดูฝน.....	86
ตาราง 6-11 ชุดตัวแปรนำเข้าที่ใช้ในการพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้าในฤดูฝน โดยวิธี Standard step.....	90
ตาราง 6-12 สรุปผลการพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้ามากกว่า 1 วัน ในฤดูฝน.....	91
ตาราง 6-13 การเปรียบเทียบผลการพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้าในฤดูฝนระหว่างแบบจำลอง ANN และ MLR.....	105
ตาราง 6-14 ชุดตัวแปรนำเข้าเบื้องต้นสำหรับการพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า 1 วัน ในฤดูแล้ง.....	118
ตาราง 6-15 ค่าความสัมพันธ์แบบ cross correlation ระหว่างอัตราการไหลน้ำท่ารายวัน ณ สถานี KGT.3 และ สถานีวัดน้ำท่าด้านเหนือในฤดูแล้ง.....	118
ตาราง 6-16 ผลการทดสอบตัวแปรนำเข้าสำหรับพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า 1 วัน ณ สถานี 150401 ในช่วงฤดูแล้ง.....	120
ตาราง 6-17 ผลการทดสอบตัวแปรนำเข้าสำหรับพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า 1 วัน ณ สถานี KGT.14 ในช่วงฤดูแล้ง.....	120
ตาราง 6-18 ผลการทดสอบตัวแปรนำเข้าสำหรับพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า 1 วัน ณ สถานี KGT.15A ในช่วงฤดูแล้ง.....	121
ตาราง 6-19 ผลการทดสอบตัวแปรนำเข้าสำหรับพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า 1 วัน ณ สถานี KGT.12 ในช่วงฤดูแล้ง.....	121
ตาราง 6-20 ผลการทดสอบตัวแปรนำเข้าสำหรับพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า 1 วัน ณ สถานี KGT.10 ในช่วงฤดูแล้ง.....	122
ตาราง 6-21 ผลการทดสอบตัวแปรนำเข้าสำหรับพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า 1 วัน ณ สถานี KGT.3 ในช่วงฤดูแล้ง.....	123
ตาราง 6-22 การเปรียบเทียบค่าประสิทธิภาพของแบบจำลองที่ใช้พยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า 1 วัน ในฤดูแล้งและฤดูฝน.....	124
ตาราง 6-23 สรุปโครงข่ายภายในที่เหมาะสมในแบบจำลอง ANN สำหรับพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า 1 วัน ในฤดูแล้ง.....	125

## สารบัญตาราง (ต่อ)

ฐ  
หน้า

ตาราง 6-24	สรุปผลการพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้ามากกว่า 1 วัน ในฤดูแล้ง.....	129
ตาราง 6-25	ชุดตัวแปรนำเข้าที่ใช้ในการพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า ในฤดูแล้ง โดยวิธี Standard step.....	130
ตาราง 6-26	การเปรียบเทียบผลการพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้าในฤดู แล้งระหว่างแบบจำลอง ANN และ MLR.....	150
ตาราง 7-1	สรุปผลการพยากรณ์อัตราการไหลน้ำท่ารายวัน ณ สถานีวัดน้ำท่าต่างๆ จากแบบจำลองสำหรับฤดูฝน.....	168
ตาราง 7-2	สรุปผลการพยากรณ์อัตราการไหลน้ำท่ารายวัน ณ สถานีวัดน้ำท่าต่างๆ จากแบบจำลองสำหรับฤดูแล้ง.....	169



สถาบันวิทยบริการ  
จุฬาลงกรณ์มหาวิทยาลัย

## สารบัญรูป

	หน้า
รูป 1-1 ที่ตั้งลุ่มน้ำและพื้นที่ศึกษา.....	4
รูป 3-1 แสดงนิยามค่าความสัมพันธ์แบบ autocorrelation ของอนุกรมเวลาต่อเนื่องชุดหนึ่ง.....	18
รูป 3-2 Correlogram ของอนุกรมเวลาต่อเนื่องและไม่ต่อเนื่อง.....	19
รูป 3-3 Partial correlogram และ correlogram ของอนุกรมเวลา $Z_t$ .....	22
รูป 3-4 แสดงขอบเขตความเป็นอิสระต่อกันในตัวเองของอนุกรม $Y_t$ ที่ระดับนัยสำคัญ 95%.....	23
รูป 3-5 กราฟความสัมพันธ์แบบ cross correlation ระหว่างอนุกรมเวลา X และ Y.....	24
รูป 3-6 ลักษณะโครงสร้างของแบบจำลอง BPNN.....	25
รูป 3-7 หลักการทำงานพื้นฐานของหน่วยย่อยในแบบจำลอง BPNN.....	26
รูป 3-8 รูปแบบต่างๆของฟังก์ชันกระตุ้น (Activation Function).....	26
รูป 3-9 ขั้นตอนการทำงานของกระบวนการเรียนรู้ในแบบจำลอง BPNN.....	29
รูป 3-10 แนวทางเดินการลู่เข้าหาความคลาดเคลื่อนต่ำสุดสำหรับค่า $\eta$ ต่างๆ.....	32
รูป 3-11 พฤติกรรมของค่าโมเมนตัมกับอัตราการเรียนรู้.....	33
รูป 3-12 ตัวอย่างการพิจารณาชนิดและอันดับจำกัดของแบบจำลองอนุกรมเวลาโดยใช้ลักษณะกราฟ correlogram และ partial correlogram.....	38
รูป 4-1 ลักษณะภูมิประเทศของพื้นที่ศึกษาและลุ่มน้ำย่อย.....	42
รูป 4-2 แผนผังระบบลุ่มน้ำที่ทำการศึกษา.....	43
รูป 4-3 การแพร่กระจายของปริมาณน้ำฝนรายเดือนเฉลี่ยในลุ่มน้ำปราจีนบุรี.....	45
รูป 4-4 แผนที่แสดงชั้นปริมาณฝนรายปีเฉลี่ยในบริเวณพื้นที่ศึกษา	46
รูป 4-5 แผนที่แสดงชั้นปริมาณฝนรายปีเฉลี่ยต่อหน่วยพื้นที่รับน้ำฝนในบริเวณพื้นที่ศึกษา.....	48
รูป 4-6 ที่ตั้งสถานีวัดน้ำฝนและสถานีวัดน้ำท่าในพื้นที่ศึกษาและพื้นที่ใกล้เคียง.....	50
รูป 4-7 ความสัมพันธ์ระหว่างฝนสะสมรายปีสถานีต่างๆกับฝนสะสมรายปีเฉลี่ย 10 สถานี.....	54
รูป 4-8 ความสัมพันธ์ระหว่างน้ำท่าสะสมรายปีสถานีต่างๆกับน้ำท่าสะสมรายปีเฉลี่ย 5 สถานี.....	55
รูป 4-9 ตัวอย่างโค้งปริมาณน้ำฝนสะสมรายวันของสถานีวัดน้ำฝนที่ใช้ในการศึกษา.....	56

## สารบัญรูป (ต่อ)

ผ

หน้า

รูป 5-1	ขั้นตอนวิธีการดำเนินการศึกษา.....	59
รูป 5-2	ขั้นตอนการพัฒนาแบบจำลอง ANN สำหรับการพยากรณ์อัตราการไหลน้ำท่า รายวันล่วงหน้า.....	60
รูป 5-3	ขั้นตอนการคัดเลือกชุดตัวแปรนำเข้าเพื่อใช้พยากรณ์อัตราการไหลน้ำท่ารายวัน ล่วงหน้า 1 วัน .....	63
รูป 6-1	กราฟความสัมพันธ์สำหรับคัดเลือกตัวแปรนำเข้าในการพยากรณ์ $Q_{t+1}$ ณ สถานี 150401 ในช่วงฤดูฝน.....	69
รูป 6-2	กราฟความสัมพันธ์สำหรับคัดเลือกตัวแปรนำเข้าในการพยากรณ์ $Q_{t+1}$ ณ สถานี KGT.14 ในช่วงฤดูฝน.....	69
รูป 6-3	กราฟความสัมพันธ์สำหรับคัดเลือกตัวแปรนำเข้าในการพยากรณ์ $Q_{t+1}$ ณ สถานี KGT.15A ในช่วงฤดูฝน.....	70
รูป 6-4	กราฟความสัมพันธ์สำหรับคัดเลือกตัวแปรนำเข้าในการพยากรณ์ $Q_{t+1}$ ณ สถานี KGT.12 ในช่วงฤดูฝน.....	70
รูป 6-5	กราฟความสัมพันธ์สำหรับคัดเลือกตัวแปรนำเข้าในการพยากรณ์ $Q_{t+1}$ ณ สถานี KGT.10 ในช่วงฤดูฝน.....	71
รูป 6-6	กราฟความสัมพันธ์สำหรับคัดเลือกตัวแปรนำเข้าในการพยากรณ์ $Q_{t+1}$ ณ สถานี KGT.3 ในช่วงฤดูฝน.....	71
รูป 6-7	เปรียบเทียบค่าความผิดพลาดในการพยากรณ์ $Q_{t+1}$ ณ สถานี KGT.3 ใน ฤดูฝน จากแบบจำลอง M2, M9 และ M11.....	86
รูป 6-8	การตรวจสอบความเป็นอิสระของอนุกรมค่าความผิดพลาดในการพยากรณ์ $Q_{t+1}$ จากแบบจำลอง ANN สำหรับฤดูฝน ณ สถานีวัดน้ำท่าต่างๆ.....	91
รูป 6-9	การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริง ในฤดูฝน ณ สถานี 150401 ช่วงปรับทานแบบจำลอง.....	96
รูป 6-10	การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริง ในฤดูฝน ณ สถานี KGT.14 ช่วงปรับทานแบบจำลอง.....	97
รูป 6-11	การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริง ในฤดูฝน ณ สถานี KGT.15A ช่วงปรับทานแบบจำลอง.....	97
รูป 6-12	การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริง ในฤดูฝน ณ สถานี KGT.12 ช่วงปรับทานแบบจำลอง.....	98

## สารบัญรูป (ต่อ)

ณ

หน้า

รูป 6-13	การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริง ในฤดูฝน ณ สถานี KGT.10 ช่วงปรับทานแบบจำลอง.....	101
รูป 6-14	การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริง ในฤดูฝน ณ สถานี KGT.3 ช่วงปรับทานแบบจำลอง.....	103
รูป 6-15	การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริง ในฤดูฝน ณ สถานี 150401 ช่วงรับรองผลแบบจำลอง.....	109
รูป 6-16	การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริง ในฤดูฝน ณ สถานี KGT.14 ช่วงรับรองผลแบบจำลอง.....	109
รูป 6-17	การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริง ในฤดูฝน ณ สถานี KGT.15A ช่วงรับรองผลแบบจำลอง.....	110
รูป 6-18	การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริง ในฤดูฝน ณ สถานี KGT.12 ช่วงรับรองผลแบบจำลอง.....	111
รูป 6-19	การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริง ในฤดูฝน ณ สถานี KGT.10 ช่วงรับรองผลแบบจำลอง.....	112
รูป 6-20	การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริง ในฤดูฝน ณ สถานี KGT.3 ช่วงรับรองผลแบบจำลอง.....	113
รูป 6-21	กราฟความสัมพันธ์สำหรับคัดเลือกตัวแปรนำเข้าในการพยากรณ์ $Q_{t+1}$ ณ สถานี 150401 ในช่วงฤดูแล้ง.....	117
รูป 6-22	กราฟความสัมพันธ์สำหรับคัดเลือกตัวแปรนำเข้าในการพยากรณ์ $Q_{t+1}$ ณ สถานี KGT.14 ในช่วงฤดูแล้ง.....	117
รูป 6-23	กราฟความสัมพันธ์สำหรับคัดเลือกตัวแปรนำเข้าในการพยากรณ์ $Q_{t+1}$ ณ สถานี KGT.15A ในช่วงฤดูแล้ง.....	118
รูป 6-24	กราฟความสัมพันธ์สำหรับคัดเลือกตัวแปรนำเข้าในการพยากรณ์ $Q_{t+1}$ ณ สถานี KGT.12 ในช่วงฤดูแล้ง.....	118
รูป 6-25	กราฟความสัมพันธ์สำหรับคัดเลือกตัวแปรนำเข้าในการพยากรณ์ $Q_{t+1}$ ณ สถานี KGT.10 ในช่วงฤดูแล้ง.....	119
รูป 6-26	กราฟความสัมพันธ์สำหรับคัดเลือกตัวแปรนำเข้าในการพยากรณ์ $Q_{t+1}$ ณ สถานี KGT.3 ในช่วงฤดูแล้ง.....	119



## สารบัญรูป (ต่อ)

ด

หน้า

รูป 6-27	การตรวจสอบความเป็นอิสระของอนุกรมค่าความผิดพลาดในการพยากรณ์ $Q_{t+1}$ จากแบบจำลอง ANN สำหรับฤดูแล้ง ณ สถานีวัดน้ำท่าต่างๆ.....	129
รูป 6-28	การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริง ในฤดูแล้ง ณ สถานี 150401 ช่วงปรับทานแบบจำลอง.....	134
รูป 6-29	การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริง ในฤดูแล้ง ณ สถานี KGT.14 ช่วงปรับทานแบบจำลอง.....	138
รูป 6-30	การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริง ในฤดูแล้ง ณ สถานี KGT.15A ช่วงปรับทานแบบจำลอง.....	139
รูป 6-31	การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริง ในฤดูแล้ง ณ สถานี KGT.12 ช่วงปรับทานแบบจำลอง.....	142
รูป 6-32	การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริง ในฤดูแล้ง ณ สถานี KGT.10 ช่วงปรับทานแบบจำลอง.....	146
รูป 6-33	การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริง ในฤดูแล้ง ณ สถานี KGT.3 ช่วงปรับทานแบบจำลอง.....	148
รูป 6-34	การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริง ในฤดูแล้ง ณ สถานี 150401 ช่วงรับรองผลแบบจำลอง.....	155
รูป 6-35	การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริง ในฤดูแล้ง ณ สถานี KGT.14 ช่วงรับรองผลแบบจำลอง.....	157
รูป 6-36	การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริง ในฤดูแล้ง ณ สถานี KGT.15A ช่วงรับรองผลแบบจำลอง.....	158
รูป 6-37	การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริง ในฤดูแล้ง ณ สถานี KGT.12 ช่วงรับรองผลแบบจำลอง.....	160
รูป 6-38	การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริง ในฤดูแล้ง ณ สถานี KGT.10 ช่วงรับรองผลแบบจำลอง.....	162
รูป 6-39	การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริง ในฤดูแล้ง ณ สถานี KGT.3 ช่วงรับรองผลแบบจำลอง.....	163

# บทที่ 1

## บทนำ

### 1.1 ความเป็นมาและความสำคัญของปัญหา

การพยากรณ์ปริมาณน้ำท่าหรืออัตราการไหลน้ำท่าล่วงหน้า มีความสำคัญต่อการวางแผนและการจัดการน้ำในด้านต่างๆ เช่น การชลประทาน การป้องกันน้ำท่วม และการผลิตไฟฟ้า เป็นต้น ทำให้ได้รับประโยชน์เพิ่มขึ้นหรือความเสียหายลดลง จากการศึกษาที่ผ่านมาพบว่า ได้มีการนำแบบจำลองทางคณิตศาสตร์มาประยุกต์ใช้ในการพยากรณ์ปริมาณน้ำท่าอยู่หลายวิธี โดยวิธีที่ให้ผลการพยากรณ์เป็นที่ยอมรับกันทั่วไป คือ การพยากรณ์ปริมาณน้ำท่าจากข้อมูลน้ำฝน เช่น TANK Model, NAM Model หรือ SSARR Model เป็นต้น โดยแบบจำลองทางคณิตศาสตร์เหล่านี้ต้องอาศัยหลักการต่างๆทางทฤษฎี เพื่อที่จะจำลองกระบวนการทางอุทกวิทยาในการเกิดน้ำท่า ซึ่งเป็นกระบวนการที่มีความซับซ้อน และไม่เป็นเชิงเส้นอย่างมาก แต่มีข้อจำกัด คือ แบบจำลองต้องการข้อมูลคุณสมบัติต่างๆ ทางกายภาพของพื้นที่ลุ่มน้ำ ซึ่งจะมีค่าแตกต่างกันตามพื้นที่ ทำให้แบบจำลองมีพารามิเตอร์ต่างๆ จำนวนมาก จึงมักก่อให้เกิดความยุ่งยากต่อการสร้างแบบจำลองและการใช้งาน นอกจากนี้ยังพบว่า มีแบบจำลองที่นำข้อมูลน้ำฝนและน้ำท่าในอดีตมาวิเคราะห์ทางหลักสถิติ แล้วจัดทำเป็นสมการความสัมพันธ์ เพื่อนำไปใช้ในการพยากรณ์หรือสังเคราะห์ปริมาณน้ำท่าที่จะเกิดขึ้นในอนาคต ซึ่งข้อดีคือไม่ต้องใช้ข้อมูลทางกายภาพ ตัวอย่างเช่น แบบจำลอง Multiple Linear Regression Model (MLR), Extended Linear Perturbation Model (LPME) หรือ HEC 4 Model เป็นต้น โดยแบบจำลองเหล่านี้ มีจำนวนพารามิเตอร์ไม่มากและง่ายต่อการใช้งานซึ่งเหมาะกับพื้นที่ที่ไม่มีข้อมูลทางกายภาพ แต่มักจะประสบปัญหาคือการพยากรณ์จะมีค่าผิดพลาดมากเมื่อใช้กับเหตุการณ์ที่มีความผันแปรสูงหรืออยู่นอกช่วงข้อมูลในอดีต และพยากรณ์ได้ดีเพียงแค่ช่วงเวลาล่วงหน้าสั้นๆ ดังนั้นจึงควรมีแบบจำลองที่ไม่ต้องอาศัยข้อมูลทางกายภาพ แต่สามารถเรียนรู้ความสัมพันธ์ระหว่างผลลัพธ์กับปัจจัยต่างๆ ได้ดี และแบบจำลองยังควรสามารถปรับปรุงได้ง่ายต่อการเรียนรู้เหตุการณ์ต่างๆ ให้ทันต่อสภาพปัจจุบัน เพื่อเพิ่มประสิทธิภาพในการพยากรณ์ปริมาณน้ำท่าให้ใกล้เคียงที่สุดกับสภาพความเป็นจริงตามธรรมชาติ

ในปัจจุบันพบว่า ได้มีการนำแบบจำลองใยประสาทเทียม (Artificial Neural Networks, ANN) มาประยุกต์ใช้ในงานที่ต้องการเรียนรู้ความสัมพันธ์ระหว่างตัวแปรต่างๆ เพื่อใช้พยากรณ์ล่วงหน้ากันอย่างแพร่หลาย โดยแบบจำลองนี้ได้พยายามเลียนแบบสมองมนุษย์ เพื่อจะทำให้คอมพิวเตอร์สามารถที่จะ เรียนรู้ จดจำ และวิเคราะห์ความสัมพันธ์ข้อมูลได้ ดังนั้นทำให้แบบจำลอง ANN สามารถเรียนรู้และจดจำเหตุการณ์ต่างๆที่เกิดขึ้นในอดีตได้ ตลอดทั้งยังสามารถ

วิเคราะห์ความสัมพันธ์ของข้อมูลได้อย่างต่อเนื่อง ซึ่งค่อนข้างเหมาะกับงานด้านแหล่งน้ำที่มีการเก็บข้อมูลเป็นระยะเวลาสั้น และเป็นปัญหาที่มีความผันแปรกับเวลาสูง โดยแบบจำลอง ANN ที่นำมาประยุกต์ใช้ในงานด้านแหล่งน้ำนั้น มีหลักการคล้ายกับแบบจำลองทางสถิติ คือ นำข้อมูลในอดีตที่ผ่านมาของตัวแปรต่างๆ มาแบ่งออกเป็นตัวแปรนำเข้า (input) และผลลัพธ์ (output) แล้วจัดสร้างเป็นแบบจำลอง โดยแบบจำลองชนิดนี้มักจะประสบปัญหาในการคัดเลือกตัวแปรนำเข้าต่างๆ ที่เหมาะสม ซึ่งแต่เดิมนั้นจะใช้วิธีการลองผิดลองถูก (trial & error) จนได้แบบจำลองที่มีความถูกต้องมากที่สุด ทำให้เสียเวลามากในการพัฒนาแบบจำลอง


ดังนั้นในการศึกษาครั้งนี้จึงมีความมุ่งเน้นที่จะพัฒนาแนวทางใหม่ในการคัดเลือกชุดตัวแปรนำเข้าที่มีความสำคัญต่อการพยากรณ์ปริมาณน้ำท่ารายวันให้มีหลักการมากขึ้นจากวิธีเดิม (วิธี trial & error) และประยุกต์ใช้แบบจำลอง ANN ในการพยากรณ์ปริมาณน้ำท่ารายวันที่ไหลออกจากลุ่มน้ำซึ่งมีลักษณะทางกายภาพที่ต่างๆกัน เพื่อเปรียบเทียบความแตกต่าง ตลอดทั้งเสนอวิธีการปรับปรุงผลการพยากรณ์โดยใช้แบบจำลองอนุกรมเวลา (Time Series Model) เพื่อเพิ่มประสิทธิภาพในการพยากรณ์ และเปรียบเทียบผลการพยากรณ์ที่ได้กับแบบจำลอง MLR ซึ่งเป็นแบบจำลองความสัมพันธ์อย่างง่ายที่นิยมใช้กันทั่วไปในการปฏิบัติ

## 1.2 วัตถุประสงค์ของการศึกษา

- 1) ศึกษาฟังก์ชันความสัมพันธ์ อันได้แก่ autocorrelation, partial correlation และ cross correlation
- 2) ประยุกต์ใช้ฟังก์ชันความสัมพันธ์ในการคัดเลือกชุดตัวแปรนำเข้าที่เหมาะสม เข้าสู่แบบจำลอง ANN
- 3) ศึกษา ทดสอบ ค่าพารามิเตอร์ต่างๆที่สำคัญในแบบจำลอง ANN ตลอดทั้งคัดเลือกลักษณะโครงข่ายภายในที่เหมาะสม
- 4) ประยุกต์ใช้แบบจำลอง ANN ที่ทำการพัฒนาขึ้นโดยวิธีการข้างต้น เพื่อทำเป็นแบบจำลองพยากรณ์น้ำท่ารายวันล่วงหน้า ในพื้นที่ศึกษา
- 5) เสนอวิธีการปรับปรุงผลการพยากรณ์จากแบบจำลอง ANN โดยใช้แบบจำลองอนุกรมเวลา
- 6) เปรียบเทียบผลการพยากรณ์ที่ได้จากแบบจำลอง ANN กับแบบจำลอง MLR


### 1.3 ขอบข่ายการศึกษา

- 1) แบบจำลองคณิตศาสตร์ที่ใช้ในการศึกษาค้างนี้มี 3 แบบจำลองคือ
  - แบบจำลอง ANN ชนิด Back Propagation Neural Network (BPNN) จากโปรแกรมสำเร็จรูป Qnet2000
  - แบบจำลองอนุกรมเวลา ซึ่งได้แก่ แบบจำลอง Autoregressive (AR), Moving Average (MA) และ Autoregressive-Moving Average (ARMA) จากโปรแกรมสำเร็จรูป SPSS
  - แบบจำลอง MLR จากโปรแกรมสำเร็จรูป Microsoft Excel
- 2) พื้นที่ที่ใช้ในศึกษาค้างนี้ตั้งอยู่ในลุ่มน้ำปราจีนบุรี ซึ่งอยู่ทางทิศตะวันออกของประเทศไทย ลักษณะลุ่มน้ำวางตัวตามแนวทิศตะวันออก-ตก อยู่ระหว่างเส้นรุ้งที่  $13^{\circ}02'$  และ  $14^{\circ}38'$  (เหนือ) และอยู่ระหว่างเส้นแวงที่  $101^{\circ}10'$  และ  $102^{\circ}33'$  (ตะวันออก) โดยสถานีที่จะทำการพยากรณ์อัตราการไหลรายวัน คือ สถานีวัดน้ำท่า KGT.3 อ.กบินทร์บุรี จ.ปราจีนบุรี ของกรมชลประทาน ซึ่งเป็นสถานีที่ตั้งอยู่ตอนต้นของแม่น้ำปราจีนบุรี ใช้วัดปริมาณน้ำท่าที่ไหลมารวมกันจากลุ่มน้ำย่อยต่างๆ ในพื้นที่ อันได้แก่ ลุ่มน้ำหनुมาน, ลุ่มน้ำพระปรอง และลุ่มน้ำคลองพระสทิง รวมเป็นพื้นที่รับน้ำทั้งสิ้น 7,502 ตร.กม. ดังรูป 1-1
- 3) ทำการพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้าในช่วง 1-7 วัน
- 4) ในการศึกษาจะใช้ข้อมูลปริมาณน้ำฝนเฉลี่ยรายวัน จากสถานีวัดน้ำฝนในบริเวณพื้นที่ศึกษาและพื้นที่ใกล้เคียงจำนวน 11 สถานี และใช้ข้อมูลปริมาณน้ำท่าเฉลี่ยรายวันในบริเวณพื้นที่ศึกษาจำนวน 5 สถานี (รายละเอียดกล่าวไว้ในบทที่ 4)
- 5) ทำการจัดสร้างแบบจำลองแยกตามฤดูกาล ได้แก่ แบบจำลองที่ใช้ในช่วงฤดูฝน (พ.ค.-พ.ย.) และแบบจำลองที่ใช้ในช่วงฤดูแล้ง (ธ.ค.-เม.ย)
- 6) ข้อมูลที่ใช้เริ่มตั้งแต่ปี พ.ศ.2513 - พ.ศ.2526 และ พ.ศ.2529 -2541 รวม 27 ปี
- 7) ค่าพารามิเตอร์ในแบบจำลอง ANN ที่จะทำการศึกษา ทดสอบ คือ ค่าอัตราเร็วการเรียนรู้ ( $\eta$ ) และ ค่าโมเมนต์ดัม ( $\alpha$ )
- 8) ลักษณะโครงข่ายภายในแบบจำลอง ANN ที่จะทำการศึกษา ทดสอบ ได้แก่ จำนวนหน่วย (node) ในชั้นแอบแฝง (hidden layer) และจำนวนชั้นแอบแฝง ซึ่งจะแบ่งเป็น 1 และ 2 ชั้น



- เขตพื้นที่ลุ่มน้ำหลัก
- - - - - เขตพื้นที่ลุ่มน้ำย่อย
- ~ ~ ~ ~ ~ คูน้ำ
- ⊙ จังหวัด
- อำเภอ

15.01	แม่น้ำประจักษ์บุรี	C.A.	9821	กม <sup>2</sup>
15.02	คลองพระอาทิตย์	C.A.	2605	กม <sup>2</sup>
15.03	แม่น้ำห้วยทราย	C.A.	2578	กม <sup>2</sup>
15.03/1	แม่น้ำพระปรังคณ			
15.03/2	ห้วยไทร			
15.04	แม่น้ำห้วยทราย	C.A.	2117	กม <sup>2</sup>
15.05	แม่น้ำประจักษ์บุรีสายเหนือ	C.A.	2523	กม <sup>2</sup>
15.05/1	แม่น้ำประจักษ์คาม			
15.05/2	ห้วยทราย			
15.05/3	คลองยาว			
15.05/4	แม่น้ำประจักษ์บุรีสายใต้			
15.05/5	แม่น้ำประจักษ์บุรีสายกลาง			



ที่มา: โครงการศึกษาข้อมูลและศักยภาพการหัดนาลุ่มน้ำประจักษ์บุรี, 2537

รูป 1-1 ที่ตั้งลุ่มน้ำและพื้นที่ศึกษา

#### 1.4 ขั้นตอนการดำเนินการศึกษาและระยะเวลาที่ใช้

- 1) ตรวจสอบและทบทวนเอกสารงานวิจัยที่ผ่านมา
- 2) ศึกษาหลักการและทฤษฎี ตลอดจน การจัดสร้างและพัฒนาแบบจำลองการพยากรณ์ อัตราการไหลน้ำท่ารายวัน โดยใช้แบบจำลอง ANN และ MLR
- 3) รวบรวมข้อมูลต่างๆ ที่ใช้ในการศึกษา
- 4) ตรวจสอบและวิเคราะห์ข้อมูลน้ำฝน น้ำท่าเบื้องต้น
- 5) จัดสร้างฟังก์ชันความสัมพันธ์ของตัวแปรต่างๆเทียบกับเวลา
- 6) ประยุกต์ใช้แบบจำลอง ANN และ MLR ในการพยากรณ์อัตราการไหลน้ำท่ารายวัน ในพื้นที่ศึกษา
- 7) ปรับปรุงผลการพยากรณ์โดยใช้แบบจำลองอนุกรมเวลา
- 8) วิเคราะห์และสรุปผลการศึกษา
- 9) จัดทำรายงานวิทยานิพนธ์

โดยระยะเวลาที่ใช้ในแต่ละขั้นตอนแสดงได้ดังตาราง 1-1

#### 1.5 ประโยชน์ที่คาดว่าจะได้รับ

- 1) เสนอการใช้ฟังก์ชันความสัมพันธ์ในการคัดเลือกชุดตัวแปรนำเข้าที่มีนัยสำคัญต่อผลลัพธ์ สำหรับการพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า
- 2) เสนอผลการประยุกต์ใช้แบบจำลอง ANN ในการพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า ในพื้นที่ที่มีลักษณะทางกายภาพที่แตกต่างกัน
- 3) เสนอวิธีปรับปรุงผลการพยากรณ์โดยใช้แบบจำลองอนุกรมเวลา
- 4) เสนอผลการเปรียบเทียบระหว่างแบบจำลอง ANN และ MLR

ตาราง 1-1 ระยะเวลาที่ใช้ในการดำเนินการ

ขั้นตอนการดำเนินการ	พ.ศ.2545												พ.ศ.2546		
	1	2	3	4	5	6	7	8	9	10	11	12	1	2	3
1) ตรวจสอบและทบทวนเอกสารงานวิจัยที่ผ่านมา															
2) ศึกษาหลักการและทฤษฎี ของแบบจำลอง ANN และ MLR															
3) รวบรวมข้อมูลต่างๆ ที่ใช้ในการศึกษา															
4) ตรวจสอบและวิเคราะห์ข้อมูลน้ำฝน น้ำท่า เบื้องต้น															
5) จัดสร้างฟังก์ชันความสัมพันธ์ของตัวแปรต่างๆ เทียบกับเวลา															
6) ประยุกต์ใช้แบบจำลอง ANN และ MLR ในการพยากรณ์ อัตราการไหลน้ำท่ารายวันในพื้นที่ศึกษา															
7) ปรับปรุงผลการพยากรณ์โดยใช้แบบจำลองอนุกรมเวลา															
8) วิเคราะห์และสรุปผลการศึกษา															
9) จัดทำรายงานวิทยานิพนธ์															

## บทที่ 2

### ผลการศึกษาที่ผ่านมา

#### 2.1 แบบจำลองการพยากรณ์น้ำท่าที่ผ่านมา

วีระชัย (2530) ได้ศึกษาความสัมพันธ์ระหว่างน้ำฝน – น้ำท่า ในลุ่มน้ำป่าสัก โดยใช้แบบจำลอง Tank Model จากการศึกษาพบว่าแบบจำลอง Tank Model สามารถนำมาใช้ประมาณปริมาณน้ำท่าจากสถิติน้ำฝนได้ดี มีนัยสำคัญที่ความเชื่อมั่น 99.9% นอกจากนี้ยังได้ให้ข้อเสนอแนะว่าปัญหาสำคัญในการทำแบบจำลอง Tank Model คือ การกำหนดค่าคงที่ในแบบจำลองให้เหมาะสม ซึ่งค่าคงที่เหล่านี้มีมากถึง 19 ตัว

วีระพล (2531) กล่าวว่าแบบจำลองคณิตศาสตร์ที่ประกอบด้วยวิธีการวิเคราะห์ความสัมพันธ์ระหว่างน้ำฝนและน้ำท้านั้น จะเรียกแบบจำลองนี้ว่าแบบจำลองน้ำฝน-น้ำท่า (Rainfall-Runoff Model) โดยแบบจำลองในลักษณะความสัมพันธ์ระหว่างน้ำฝนและน้ำท้านั้น มีผู้เสนอหลายวิธีด้วยกัน เช่น Sacramento Watershed Model, Tank Model, SSARR Model (Streamflow Synthesis and Reservoir Regulation) และ NAM Model เป็นต้น โดยแบบจำลองที่นิยมใช้ในประเทศไทยคือ Tank Model และ SSARR Model โดยทั้งสองรูปแบบได้จำลองเป็นคอมพิวเตอร์โมเดลขนาดใหญ่ ดังนั้นจำเป็นต้องใช้คอมพิวเตอร์เมนเฟรมที่มีความจำสูง และการใช้ค่อนข้างยุ่งยากในเรื่องการปรับค่าพารามิเตอร์ต่างๆ ของรูปแบบจำลอง

Nam (1991) ได้ศึกษาการพยากรณ์น้ำท่าที่ไหลเข้าอ่างเก็บน้ำฮัวบิन्ह (Hoabinh Reservoir) ซึ่งตั้งอยู่บนแม่น้ำตา ประเทศเวียดนาม จากข้อมูลน้ำฝนและอัตราการไหลรายวัน โดยใช้แบบจำลอง Multiple Linear Regression และแบบจำลอง Linear Perturbation Model Extended Version พบว่าข้อมูลฝนเพียงอย่างเดียวไม่เพียงพอต่อการพยากรณ์น้ำท่า จึงจำเป็นต้องปรับปรุงโดยใช้ข้อมูลน้ำท่าของสถานีที่เหนือและท้ายน้ำของจุดที่พิจารณาเพิ่มเติม และจากผลการพยากรณ์พบว่าแบบจำลองทั้งสองชนิดให้ผลดีและไม่แตกต่างกันทางนัยสำคัญ แต่แบบจำลอง MLR จะง่ายต่อการใช้งานมากกว่า

สุชาติ (2539) ได้พัฒนาแบบจำลองน้ำฝน-น้ำท่ารายเดือน โดยใช้แบบจำลอง WRECU-I ซึ่งเป็นแบบจำลองชนิด Non-linear lumped และเป็น Deterministic Model มาประยุกต์ใช้ในการ



สังเคราะห์น้ำท่ารายเดือนในลุ่มน้ำเพชรบุรี และลุ่มน้ำชายฝั่งทะเลประจวบคีรีขันธ์ โดยใช้ข้อมูลป้อนเข้าคือปริมาณฝนรายเดือนย้อนหลัง 3 เดือน รวมเดือนปัจจุบัน และเปรียบเทียบผลการสังเคราะห์กับแบบจำลอง HEC4-PC พบว่าแบบจำลอง WRECU-I สังเคราะห์น้ำท่ารายเดือนในช่วงที่มีการไหลสูงได้แม่นยำทั้งปริมาณและช่วงเวลาที่เกิด ได้ดีกว่าแบบจำลอง HEC4-PC แต่ผลการสังเคราะห์จะผิดพลาดมากในช่วงการไหลต่ำ

## 2.2 การประยุกต์ใช้แบบจำลอง ANN ในงานด้านแหล่งน้ำ

วิวัฒนาการในการพัฒนาแบบจำลอง ANN นั้น มีมาตั้งแต่ปี ค.ศ.1943 ซึ่งได้มีการพยายามพัฒนาแบบจำลองให้มีความสามารถเรียนรู้และประมวลผลได้เหมือนกับสมองมนุษย์ โดยจะมีการทำงานพื้นฐานอยู่ 3 ชั้นตอนคือ รับข้อมูล, ประมวลผล และแสดงผลการประมวล ทำให้แบบจำลอง ANN มีโครงข่ายพื้นฐานอยู่ 3 ชั้นคือ ชั้นรับข้อมูล (input layer) ชั้นแอบแฝง (hidden layer) และชั้นแสดงผล (output layer) โดยแต่ละชั้นจะประกอบด้วยหน่วยย่อยๆ (node) ซึ่งทำหน้าที่คล้ายเซลล์สมองมนุษย์ นับตั้งแต่นั้นต่อมาแบบจำลอง ANN ได้มีการพัฒนาเพิ่มขึ้นอย่างกว้างขวางทั้งในด้าน ลักษณะของโครงข่าย การทำงาน และกระบวนการเรียนรู้ เป็นต้น และมีการนำไปประยุกต์ใช้ในการแก้ปัญหาต่างๆ ในหลายๆ สาขามากมาย จนถึงปัจจุบัน

สำหรับการนำแบบจำลอง ANN มาประยุกต์ใช้กับงานด้านแหล่งน้ำนั้น ได้มีการริเริ่มนำมาประยุกต์ใช้ขึ้นประมาณปี ค.ศ. 1990 โดยเริ่มจาก French และคณะ (1992) ได้มีการพัฒนาแบบจำลอง ANN ซึ่งใช้กระบวนการเรียนรู้แบบ Back Propagation Algorithm มาใช้ เพื่อทำนายปริมาณฝนที่ตกตามสถานที่และเวลาต่างๆ กัน Crespo และ Mora (1993) ได้ประยุกต์ใช้หลักการของแบบจำลอง ANN ในการประมาณการการเกิดภัยแล้ง และนับจากนั้นต่อมาได้มีการนำแบบจำลอง ANN มาประยุกต์ใช้กับงานด้านแหล่งน้ำกันอย่างแพร่หลายดังนี้

Siang (1992) ได้นำ Back Propagation Neural Networks (BPNN) มาประยุกต์ใช้ในการคาดการณ์คุณภาพน้ำรายเดือนโดยตัวแปร อุณหภูมิ, pH และค่าความเหนียวน้ำ ในชั้นตัวแปรนำเข้า และนอกจากนี้ยังใช้คาดการณ์ปริมาณน้ำท่ารายเดือนล่วงหน้า 1 เดือน ที่เมืองเวียนเตียน ประเทศลาว และสถานีวัดน้ำท่าในแม่โขงอีก 5 สถานี จากการศึกษาพบว่าการคาดการณ์ปริมาณน้ำท่ารายเดือน โดยใช้แบบจำลอง BPNN ที่มีโครงสร้างที่ประกอบด้วย 1 ชั้นแอบแฝง และในชั้นแอบแฝงจะผันแปรหน่วย ตั้งแต่ 1-3 หน่วย โดยการเพิ่มจำนวนหน่วยในชั้นแอบแฝงนั้น ไม่ได้ช่วย

ให้ผลลัพธ์ดีขึ้น เท่าที่ควร และผลที่ได้จากการคาดการณ์โดยใช้แบบจำลอง BPNN พบว่าให้ผลดีกว่า เมื่อนำไปเทียบกับแบบจำลอง Box-Jenkins

Gul (1993) ได้นำแบบจำลอง BPNN ที่มีจำนวนชั้นแอบแฝงจำนวน 1 ชั้น มาใช้ในการพยากรณ์ปริมาณน้ำท่าล่วงหน้ารายวันกับแม่น้ำน่าน ที่สถานีวัดน้ำท่าอำเภอเมือง และสถานีบ้านแก่งสว่าง จังหวัดน่าน โดยใช้ข้อมูลน้ำเข้าเป็นปริมาณน้ำฝน และน้ำท่ารายวันของแต่ละสถานี ในพื้นที่ลุ่มน้ำย้อนหลัง 5 วัน ซึ่งใช้การคัดเลือกตัวแปรนำเข้าแบบ trial & error โดยผลการศึกษาพบว่า ในการพยากรณ์ปริมาณน้ำท่าเพื่อให้ผลการพยากรณ์ที่ดีนั้น ข้อมูลน้ำเข้าจะต้องประกอบด้วย ข้อมูลน้ำฝนรายวันย้อนหลังของสถานีในพื้นที่ทางด้านเหนือลำน่าน ข้อมูลปริมาณน้ำท่ารายวันย้อนหลังของสถานีวัดน้ำท่าที่อยู่เหนือลำน่านของสถานีที่จะทำการพยากรณ์ และปริมาณน้ำท่ารายวันย้อนหลังของสถานีที่จะทำการพยากรณ์

Danh (1995) ได้พัฒนาแบบจำลอง Tank Model, Tank-AR(1) Model และ BPNN model เพื่อใช้ในการพยากรณ์อัตราการไหลรายวัน ในลุ่มน้ำดานิม (Da Nhim Basin) และลุ่มน้ำลาเงา (La Nga Basin) ในประเทศเวียดนาม พบว่าแบบจำลอง BPNN ให้ผลการพยากรณ์ดีที่สุด รองลงมาคือ Tank-AR(1) Model และ Tank Model ตามลำดับ

Tokar และคณะ (1999) ใช้โครงข่ายประสาทเทียมเพื่อพยากรณ์ปริมาณน้ำท่ารายวัน ในลุ่มน้ำ Little Patuxent River ในรัฐแมริแลนด์ ประเทศสหรัฐอเมริกา มีพื้นที่ลุ่มน้ำ 98 กม.<sup>2</sup> โดยให้ปริมาณน้ำท่าที่ขึ้นอยู่กับตัวแปรต่างๆ ทางอุทกวิทยา เช่น ปริมาณน้ำฝนเฉลี่ยรายวัน จากสถานีวัดน้ำฝนในพื้นที่ อุณหภูมิ และการหลอมละลายของหิมะ เป็นต้น และคัดเลือกตัวแปรนำเข้าด้วยวิธี sensitivity analysis โดยจะเปรียบเทียบผลการคำนวณกับแบบจำลองทางสถิติและแบบจำลองทางกายภาพ อันได้แก่ แบบจำลองความถดถอย (Regression Model) และ แบบจำลอง Simple Conceptual Model ตามลำดับ โดยพบว่าแบบจำลองใช้โครงข่ายประสาทเทียม ใช้เวลาในการปรับเทียบแบบจำลองน้อยกว่าแบบจำลอง Simple Conceptual Model และให้ผลการคำนวณที่ดีกว่าแบบจำลองความถดถอย

Manusthiparom (2000) ทำการพยากรณ์ระดับน้ำและอัตราการไหลรายชั่วโมงล่วงหน้า 1, 2 และ 3 ชั่วโมง ในแม่น้ำเจ้าพระยา ณ สถานีวัด C4 (สะพานพุทธ) ซึ่งตั้งอยู่ห่างจากปากแม่น้ำเจ้าพระยาเป็นระยะทาง 48 กม. โดยใช้แบบจำลอง BPNN และ MIKE-11 HD Model สำหรับตัวแปรนำเข้าสู่แบบจำลองนั้น ได้แก่ ระดับน้ำและอัตราการไหลรายชั่วโมง ณ สถานีวัดบางไทร เป็น

ขอบเขตด้านต้นน้ำ ซึ่งตั้งอยู่ห่างจากสถานีวัด C4 ไปทางต้นน้ำเป็นระยะทาง 64 กม. ระดับน้ำขึ้น-น้ำลง ที่วัดจากสถานีป้อมพระจุล จะใช้เป็นขอบเขตด้านท้ายน้ำ โดยตั้งอยู่ห่างจากปากแม่น้ำ 1 กม. นอกจากนี้ยังใช้ปริมาณน้ำท่าระหว่างขอบเขตที่กำหนดที่ไหลลงสู่แม่น้ำเจ้าพระยาเป็นตัวแปรรวมอยู่ด้วย จากผลการศึกษาพบว่าเมื่อนำแบบจำลอง BPNN มาใช้ร่วมกับ AR(3) Model จะทำให้ผลการพยากรณ์นั้นมีประสิทธิภาพมากที่สุด

Tingsanchali (2001) ได้นำแบบจำลอง BPNN มาประยุกต์ใช้ในการพยากรณ์ปริมาณน้ำท่ารายวัน ณ สถานีวัดน้ำท่า Z.11 ซึ่งตั้งอยู่ในลุ่มน้ำประแส มีพื้นที่รับน้ำทั้งหมด 1,280 กม.<sup>2</sup> ในการศึกษาครั้งนี้ ได้ให้ปริมาณน้ำท่ารายวันล่วงหน้า 1 วัน นั้น ขึ้นอยู่กับข้อมูลน้ำฝนและน้ำท่ารายวัน ณ วันปัจจุบันและวันที่ผ่านมา ซึ่งได้มาจากการคัดเลือกตัวแปรนำเข้าแบบ trial & error โดยจะใช้ข้อมูลในช่วงปี 1993-1997 สำหรับการปรับเทียบและทดสอบแบบจำลอง จากผลการศึกษาพบว่าแบบจำลอง BPNN สามารถให้ผลการพยากรณ์ปริมาณน้ำท่ารายวันล่วงหน้า 1 วัน ได้ดีเพียงพอต่อการนำไปใช้งาน ซึ่งจะเป็นประโยชน์กับลุ่มน้ำที่มีข้อมูลทางกายภาพจำกัด

เสรีและคณะ (2544) พยากรณ์ระดับน้ำที่หาดใหญ่ โดยใช้โครงข่ายประสาทเทียมสำหรับข้อมูลที่ใช้ประกอบไปด้วย ข้อมูลน้ำฝนและระดับน้ำสถานี X44 (คลองคูตะเภา) และใช้ค่าสัมประสิทธิ์ความสัมพันธ์ของตัวแปรชนิดเดียวกัน (autocorrelation) กับค่าสัมประสิทธิ์ความสัมพันธ์ของตัวแปรต่างกัน (cross correlation) ผสมกับการ trial & error ในการพิจารณาจำนวนข้อมูลนำเข้าที่มีนัยสำคัญ ซึ่งให้แบบจำลองเรียนรู้ข้อมูลปี พ.ศ.2543 และทดสอบผลการพยากรณ์กับข้อมูลน้ำท่วมปี พ.ศ.2531 พบว่าผลการคำนวณเป็นที่น่าพอใจคือมีค่า  $R^2$  เท่ากับ 0.97 และ 0.95 ในช่วงการเรียนรู้และการทดสอบตามลำดับ

วุฒิชัย (2544) ได้นำแบบจำลอง ANN แบบ Back Propagation มาใช้ในการคาดการณ์ปริมาณน้ำท่ารายวัน 1 และ 2 วันล่วงหน้า ในแม่น้ำจันทบุรี (สถานี Z13) และแม่น้ำคลองคูตะเภา (สถานี X90) โดยใช้ตัวแปรอิสระคือ ปริมาณฝนเฉลี่ยรายวันทั่วทั้งพื้นที่ และปริมาณน้ำท่ารายวันในพื้นที่ลุ่มน้ำที่ทำการศึกษา และใช้ค่าสัมประสิทธิ์ความสัมพันธ์แบบ autocorrelation กับค่าสัมประสิทธิ์ความสัมพันธ์แบบ cross correlation เท่ากับ 0.6 ในการพิจารณาจำนวนข้อมูลนำเข้า โดยผลการศึกษาพบว่า ผลการคาดการณ์ปริมาณน้ำท่ารายวัน 1 วันล่วงหน้า ให้ผลน่าเชื่อถืออยู่ในเกณฑ์ดี และมีความน่าเชื่อถือลดลงเมื่อทำการคาดการณ์ปริมาณน้ำท่ารายวัน 2 วันล่วงหน้า

Kitpaisalsakul และ Piman (2002) ได้นำแบบจำลอง ANN มาประยุกต์ใช้สำหรับพยากรณ์อัตราการไหลน้ำท่ารายวัน ล่วงหน้า 1, 2 และ 3 วัน ณ สถานีวัดน้ำท่า KGT.10 ที่ตั้งอยู่ใกล้กับจุดออกของลุ่มน้ำคลองพระสทิง ซึ่งตั้งอยู่ในภาคตะวันออกเฉียงเหนือของประเทศไทย จากผลการศึกษาพบว่าตัวแปรนำเข้าที่มีอิทธิพลต่อการพยากรณ์อัตราการไหลน้ำท่ารายวัน คือ ปริมาณน้ำฝนและน้ำท่ารายวัน ในวันที่ผ่านมาจากสถานีวัดต่างๆ ที่ตั้งอยู่ในพื้นที่ลุ่มน้ำ นอกจากนี้ยังได้มีการนำผลการพยากรณ์จากแบบจำลอง ANN มาเปรียบเทียบกับผลพยากรณ์จากแบบจำลอง MLR ที่ใช้ตัวแปรนำเข้าชุดเดียวกับแบบจำลอง ANN ซึ่งพบว่าในการพยากรณ์ล่วงหน้า 1 วัน ผลการพยากรณ์จากแบบจำลองทั้ง 2 มีค่าใกล้เคียงกันกับข้อมูลที่วัดจริง แต่เมื่อพยากรณ์ล่วงหน้า 2 และ 3 วัน พบว่า แบบจำลอง ANN ให้ผลการพยากรณ์ดีกว่าแบบจำลอง MLR อย่างชัดเจน

Kitpaisalsakul และ Suttinon (2002) ได้ทำการเปรียบเทียบผลการพยากรณ์ระดับน้ำขึ้น-น้ำลง ล่วงหน้า 3, 12 และ 24 ชั่วโมง ณ สถานีวัดบ่อมพระจุล ซึ่งตั้งอยู่บริเวณปากแม่น้ำเจ้าพระยา จากแบบจำลอง ANN และแบบจำลอง HARMONIC โดยแบบจำลอง ANN จะใช้ข้อมูลระดับน้ำขึ้น-น้ำลง รายชั่วโมงย้อนหลังไป 25 ชั่วโมง เป็นข้อมูลนำเข้า ส่วนแบบจำลอง HARMONIC นั้นจะใช้ข้อมูลระดับน้ำขึ้น-น้ำลง เฉลี่ยตลอดทั้งปีเป็นข้อมูลนำเข้า จากผลการศึกษาพบว่า ผลการพยากรณ์ในระยะสั้น (3 และ 12 ชั่วโมง) จากแบบจำลอง ANN จะมีประสิทธิภาพมากกว่าแบบจำลอง HARMONIC อย่างเห็นได้ชัด แต่ความแตกต่างของผลการพยากรณ์จากแบบจำลองทั้ง 2 นี้ จะลดลงเมื่อใช้กับการพยากรณ์ในช่วงระยะยาว (24 ชั่วโมง)

### 2.3 การพัฒนาแบบจำลอง ANN

ในหัวข้อนี้จะมุ่งเน้นถึงการทบทวนผลการศึกษาที่เกี่ยวข้องกับการพัฒนารูปแบบต่างๆ ในแบบจำลอง ANN อาทิเช่น ลักษณะโครงข่าย กระบวนการเรียนรู้ ฟังก์ชันกระตุ้น และ วิธีการพิจารณาจำนวนหน่วยที่เหมาะสมในชั้นแอบแฝง เป็นต้น ที่มีความแตกต่างไปจากเดิมคือ จะใช้ลักษณะโครงข่ายแบบการทำงานเคลื่อนที่ไปข้างหน้าอย่างเดียว (feed forward), กระบวนการเรียนรู้แบบ Back Propagation Algorithm, ฟังก์ชันกระตุ้นแบบซิกมอยด์ และ วิธีการพิจารณาจำนวนหน่วยที่เหมาะสมในชั้นแอบแฝง โดยวิธีลองผิดลองถูก

Thirumalaiah และ Deo (1998) นำแบบจำลองโครงข่ายใยประสาทเทียม มาใช้ในการพยากรณ์ระดับน้ำในแม่น้ำล่วงหน้า 1 และ 2 วัน โดยใช้ข้อมูลในปัจจุบันและอดีตของสถานีวัดระดับน้ำด้านเหนือ น้ำ และจุดที่พิจารณา ในการเรียนรู้ (training) และทดสอบ (testing) แบบ

จำลอง นอกจากนี้ยังได้ใช้กระบวนการเรียนรู้ที่ต่างกัน 3 วิธีคือ Back Propagation, Cascade Correlation และ Conjugate Gradient พบว่าแบบจำลองโครงข่ายใยประสาทเทียมสามารถนำมาประยุกต์ใช้ได้ดี ( $r^2=0.956$  และ  $0.885$  ของการพยากรณ์ล่องหน้า 1 และ 2 วัน ตามลำดับ) และยังพบว่ากระบวนการเรียนรู้แบบ Cascade Correlation ให้ผลลัพธ์ลู่เข้าเร็วที่สุด

Fernando และคณะ (1998) ได้นำฟังก์ชันกระตุ้นแบบ Radial Basis Function (RBF) และกระบวนการเรียนรู้แบบ Orthogonal Least-Square (OLS) มาประยุกต์ใช้กับโครงข่ายใยประสาทเทียม ในการพยากรณ์ปริมาณน้ำท่าล่องหน้า 1 ชม. ในพื้นที่ลุ่มน้ำขนาด  $3.12 \text{ km}^2$  และนำผลมาเปรียบเทียบกับโครงข่ายใยประสาทเทียมที่ใช้การเรียนรู้แบบ Back Propagation พบว่าผลการพยากรณ์ที่ได้มีค่าความผิดพลาดไม่แตกต่างกันมาก แต่การใช้วิธีการเรียนรู้แบบ OLS และฟังก์ชันกระตุ้นแบบ RBF จะช่วยลดเวลาในการลู่เข้าสู่คำตอบ เมื่อเปรียบเทียบกับวิธีการเรียนรู้แบบ Back Propagation

Abrahart และคณะ (1999) ได้ใช้ Pruning Algorithm และ Genetic Algorithm (GA) เพื่อใช้หารูปแบบของโครงสร้าง (network architectures) และข้อมูลนำเข้าที่มีนัยสำคัญในแบบจำลอง ANN เพื่อช่วยประหยัดเวลาในการคำนวณและค่าใช้จ่าย โดยในการศึกษารั้งนี้ได้นำแบบจำลอง ANN มาประยุกต์ใช้ในการพยากรณ์ปริมาณน้ำท่ารายชั่วโมงในพื้นที่ลุ่มน้ำขนาดเล็ก (Upper River Wye, Wales) ซึ่งมีพื้นที่ประมาณ  $10.55 \text{ km}^2$  โดยจะใช้ข้อมูลนำเข้าเริ่มต้นจำนวนทั้งหมด 23 ตัว และแบ่งชั้นแอบแฝงออกเป็น 2 ชั้น แต่ละชั้นมีจำนวนหน่วยเริ่มต้น 16 และ 14 หน่วย (รวม 30 หน่วย) สำหรับชั้นแสดงผลนั้นจะมีหน่วยเดียว คือปริมาณน้ำท่าในชั่วโมงถัดไป รวมทั้งโครงข่ายจะมีการเชื่อมโยงด้วยค่าถ่วงน้ำหนักทั้งสิ้น 590 ตัวจากผลการศึกษาพบว่า วิธีการทั้งสองให้ผลการพยากรณ์ที่ดี ไม่แตกต่างกันมากนัก และสามารถลดจำนวนหน่วยในชั้นแอบแฝงกับจำนวนค่าถ่วงน้ำหนักที่ไม่มีนัยสำคัญได้เป็นอย่างดี โดยวิธี Pruning Algorithm สามารถลดจำนวนหน่วยในชั้นแอบแฝงกับจำนวนค่าถ่วงน้ำหนักได้อยู่ในช่วงระหว่าง 19-24 หน่วย และ 64-258 ตัว ตามลำดับ และวิธี GA สามารถลดจำนวนหน่วยในชั้นแอบแฝงได้อยู่ในช่วง 4-17 หน่วย และจำนวนค่าถ่วงน้ำหนัก 49-269 ตัว

Coulibaly และคณะ (2001) พัฒนาโครงข่ายใยประสาทเทียมโดยการนำโครงข่ายแบบหน่วงเวลา (Input Time Delayed Neural Network, IDNN) และโครงข่ายแบบกลับไป-กลับมา (Recurrent Neural Network, RNN) มาใช้ในการพยากรณ์ปริมาณน้ำท่าที่ไหลเข้าเก็บน้ำซึ่งขึ้นอยู่กับตัวแปรหลายตัว อันได้แก่ ปริมาณน้ำฝน อุณหภูมิ และการหลอมละลายของหิมะ เป็นต้น โดย

พบว่าโครงข่ายแบบหน่วงเวลาช่วยในการปรับปรุงผลการพยากรณ์ ที่ได้จากแบบจำลองโครงข่ายประสาทเทียมที่นิยมใช้กันทั่วไป (Conventional Multilayer Perceptron, MLP) แต่ไม่ช่วยปรับปรุงผลการพยากรณ์ ที่ได้จากแบบจำลองโครงข่ายประสาทเทียมแบบกลับไป-กลับมา แต่อย่างไรก็ตาม พบว่าแบบจำลอง RNN ให้ผลการพยากรณ์ ที่มีประสิทธิภาพมากกว่าแบบจำลอง MLP และ IDNN

เสรี และ รุ่งเรือง (2544) ได้พัฒนาและประยุกต์ใช้โครงข่ายประสาทเทียม เพื่อการพยากรณ์และเตือนภัยน้ำท่วม โดยเลือกเหตุการณ์น้ำท่วมขนาดใหญ่เป็นกรณีศึกษา โดยโครงข่ายประสาทเทียมที่ใช้ในการศึกษา จะเป็นโครงข่ายแบบหน่วงเวลา (Time Delay Neural Network, TDNN) และใช้ Genetic Algorithm เพื่อช่วยหาโครงสร้างของโครงข่ายที่เหมาะสมที่สุด และใช้ชื่อรวมว่า Neuro-Genetic Algorithm โดยพบว่าผลการคำนวณเป็นที่น่าพอใจมาก คือ มีค่าสัมประสิทธิ์ความสัมพันธ์ ( $r^2$ ) เท่ากับ 0.98

Dolling และ Varas (2002) ได้แสดงวิธีการคัดเลือกข้อมูลนำเข้าโดยใช้วิธีการทดสอบความอ่อนไหว (sensitivity analysis) ของข้อมูลนำเข้าที่เพิ่มเข้ามา เพื่อหาจำนวนข้อมูลนำเข้าที่มีนัยสำคัญ และเสนอวิธีการหาจำนวนหน่วยและจำนวนชั้นแอบแฝงที่เหมาะสมในแบบจำลอง ANN คือวิธี Cascade Correlation Algorithm และ Pruning Algorithm นอกจากนี้ยังได้แนะนำการแบ่งข้อมูลสำหรับการเรียนรู้และทดสอบ ว่าควรมีอย่างน้อย 40% และ 20% ของข้อมูลทั้งหมดตามลำดับ โดยข้อมูลทั้ง 2 ส่วนนั้นควรครอบคลุมถึงเหตุการณ์ที่สำคัญๆ ในกระบวนการทางอุทกวิทยา จากผลการศึกษาพบว่า การนำแบบจำลอง ANN มาใช้ในการพยากรณ์ปริมาณน้ำท่ารายเดือนล่วงหน้า 7 เดือนต่อเนื่อง (ในชั้นแสดงผลจะมีข้อมูลนำออก 7 หน่วย) ในลุ่มน้ำ San Juan River ประเทศอาร์เจนตินา มีพื้นที่ลุ่มน้ำ 20 กม.<sup>2</sup> โดยใช้ข้อมูลปริมาณน้ำฝนเฉลี่ยจากสถานีวัดน้ำฝนในพื้นที่ ปริมาณหิมะละลาย อุณหภูมิเฉลี่ย ความชื้นสัมพัทธ์ และความเร็วลมเป็นต้น พบว่าการพยากรณ์ให้ผลเป็นที่น่าพอใจ ทั้งในช่วงฤดูหนาว และฤดูร้อน

## 2.4 การประยุกต์ใช้แบบจำลองอนุกรมเวลา

แบบจำลองอนุกรมเวลาจะถูกจัดสร้างขึ้นเพื่ออธิบายกระบวนการที่ก่อให้เกิดอนุกรมเวลาของตัวแปรชุดหนึ่ง และนำแบบจำลองนั้นไปใช้ในการพยากรณ์หรือสังเคราะห์ ค่าของตัวแปรต่อไป โดยแบบจำลองอนุกรมเวลาที่รู้จักกันทั่วไปนั้น ได้แก่ แบบจำลอง Autoregressive (AR),

Moving Average (MA), Autoregressive-Moving Average (ARMA) เป็นต้น จากการศึกษาที่ผ่านมาได้มีการนำแบบจำลองอนุกรมเวลามาประยุกต์ใช้ในการปรับปรุงผลการพยากรณ์ ดังนี้

Kabiling (1989) ทำการประเมินน้ำท่ารายวันที่วัดได้จากสถานีวัดน้ำท่าต่างๆ ในลุ่มน้ำป่าสัก โดยใช้แบบจำลอง Tank Model และ NAM Model และได้้นำแบบจำลองอนุกรมเวลา ARMA มาใช้ในการอธิบายและพยากรณ์อนุกรมค่าความผิดพลาดที่เกิดจากการใช้ Tank Model และ NAM Model จากผลการศึกษาพบว่า การประยุกต์ใช้แบบจำลองทั้ง 2 ร่วมกันทำให้ผลการพยากรณ์ดีขึ้นเป็นที่น่าพอใจ

Prasad (1995) ประยุกต์ใช้แบบจำลอง Tank Model และ NAM Model ร่วมกับ AR Model เพื่อปรับปรุงผลการพยากรณ์อัตราการไหลรายวันในลุ่มน้ำบากมาติ (Bagmati Basin) และลุ่มน้ำนาน (Nan Basin) พบว่าผลการพยากรณ์ให้ผลดีขึ้นเมื่อเปรียบเทียบกับผลการพยากรณ์ที่ได้จากแบบจำลอง Tank Model และ NAM Model เพียงอย่างเดียว

Win (1999) ประยุกต์ใช้แบบจำลอง Back Propagation Neural Networks (BPNN) ในการทำนายปริมาณน้ำหลากรายวันในลุ่มน้ำประแส โดยใช้ข้อมูลอัตราการไหลและน้ำฝนรายวันที่ได้มาจากการคัดเลือกแบบ trial & error พบว่าผลการพยากรณ์มีความแม่นยำสูง นอกจากนี้ยังได้มีการประยุกต์ใช้แบบจำลอง BPNN ร่วมกับ ARMA Model เพื่อปรับแก้ค่าความผิดพลาดให้ลดน้อยลง

## 2.5 สรุปสิ่งที่ได้จากการผลศึกษาที่ผ่านมา

จากผลการศึกษาที่ผ่านมาทั้งหมด สามารถสรุปออกเป็น 3 ประเด็น ได้ดังต่อไปนี้

### 2.5.1 ด้านอุทกวิทยา

- 1) แบบจำลองที่ใช้ในการประเมินน้ำท่าแบ่งออกเป็น 2 ลักษณะคือ
  - แบบจำลองทางกายภาพ ได้แก่ แบบจำลอง Tank, Nam, และ SSARR Model ซึ่งพบว่าแบบจำลองเหล่านี้ จะมีค่าพารามิเตอร์จำนวนมาก ทำให้ยากต่อการใช้งานจริง และใช้เวลาในการปรับเทียบนาน โดยแบบจำลองนี้เหมาะสำหรับพื้นที่ลุ่มน้ำขนาดใหญ่

- แบบจำลองทางสถิติ ได้แก่ แบบจำลอง WRECU-I, Linear Regression, Linear Perturbation Model Extended Version และ HEC4-PC Model ซึ่งพบว่าแบบจำลองเหล่านี้มีจำนวนพารามิเตอร์ไม่มากเมื่อเทียบกับแบบจำลองทางกายภาพ และต้องใช้กับพื้นที่ที่มีการเก็บข้อมูลมาเป็นระยะเวลายาวนาน

2) ตัวแปรต่างๆ ทางอุทกวิทยาที่ใช้ในการพยากรณ์ปริมาณน้ำท่ามีดังต่อไปนี้

- ปริมาณน้ำฝนเฉลี่ยในพื้นที่ ถ้าพื้นที่รับน้ำมีขนาดเล็กจะใช้ข้อมูลปริมาณน้ำฝนของสถานีวัดในพื้นที่โดยตรง (point rainfall) ถ้าพื้นที่รับน้ำมีขนาดใหญ่จะใช้ข้อมูลปริมาณน้ำฝนเฉลี่ยทั่วทั้งพื้นที่ (mean areal rainfall)
- ปริมาณน้ำท่าของสถานีวัดเหนือจุดที่พิจารณา
- การระเหย, อุณหภูมิ
- ปริมาณความชื้นในดิน
- ลักษณะการกายภาพของพื้นที่ลุ่มน้ำ เช่น ความชัน (ใช้ในแต่เฉพาะแบบจำลองทางกายภาพ)

3) วิธีการคัดเลือกชุดตัวแปรนำเข้ามีดังต่อไปนี้

- การ trial & error
- การใช้ค่าสัมประสิทธิ์ความสัมพันธ์แบบ autocorrelation กับค่าสัมประสิทธิ์ความสัมพันธ์แบบ cross correlation ซึ่งยังไม่มีการกำหนดที่ชัดเจนมากนัก
- การทดสอบ sensitivity analysis

### 2.5.2 ด้านแบบจำลอง ANN

- 1) แบบจำลอง ANN สามารถนำมาประยุกต์ใช้ในการพยากรณ์ปริมาณน้ำท่าในพื้นที่ขนาดเล็ก (3-100 กม.<sup>2</sup>) ได้ดี
- 2) กระบวนการเรียนรู้ในแบบจำลอง ANN มีหลายวิธี เช่น
  - Back-Propagation Method
  - Cascade Correlation Method
  - Conjugate Gradient Method



พบว่ากระบวนการเรียนรู้แบบ Back-Propagation Method เป็นวิธีที่นิยมใช้กันมากที่สุด เนื่องจากเป็นวิธีที่เข้าใจง่าย และให้ผลคำนวณในเกณฑ์ดี แต่การเข้าสู่ผลลัพธ์ของวิธีนี้จะช้ากว่าวิธี Conjugate Gradient และ Cascade Correlation Method

- 3) ได้มีการพัฒนานำเอา Pruning Algorithm, Genetic Algorithm และ Cascade Correlation Algorithm มาใช้ในการเลือกจำนวนหน่วยที่เหมาะสมในชั้นแอบแฝง แทนการลองผิดลองถูก และจากการศึกษาที่ผ่านมาพบว่าจำนวนชั้นแอบแฝงที่ใช้ในแบบจำลอง ANN สำหรับการพยากรณ์ปริมาณน้ำท่า จะใช้เพียงชั้นเดียวเป็นส่วนใหญ่
- 4) ได้มีการนำฟังก์ชันกระตุ้นแบบ Radial Basis Function มาประยุกต์ใช้ในแบบจำลอง ANN พบว่าจะช่วยลดเวลาในการเข้าสู่คำตอบ เมื่อเทียบกับซิกมอยด์ฟังก์ชัน แต่ผลการพยากรณ์ที่ได้มีค่าความผิดพลาดไม่แตกต่างกันมาก

### 2.5.3 ด้านการปรับปรุงผลการพยากรณ์

จากการศึกษาที่ผ่านมาพบว่าได้มีการนำแบบจำลองอนุกรมเวลา อันได้แก่แบบจำลอง AR Model และแบบจำลอง ARMA Model มาช่วยในการปรับปรุงผลการพยากรณ์ให้มีประสิทธิภาพมากขึ้น

## บทที่ 3

### ทฤษฎีที่ใช้ในการศึกษา


#### 3.1 ฟังก์ชันความสัมพันธ์ของตัวแปรเดียวกันและต่างกันเทียบกับเวลา (Correlation function)

ในการศึกษาครั้งนี้ ได้นำฟังก์ชันความสัมพันธ์ มาใช้ในการวิเคราะห์อนุกรมเวลา (time series) ของข้อมูลน้ำฝนและน้ำท่ารายวัน เพื่อใช้พิจารณาถึงความสัมพันธ์ระหว่างตัวแปรต่างๆ ที่จะนำเข้าสู่แบบจำลองกับผลลัพธ์ ซึ่งจะทำเป็นแนวทางในการคัดเลือกชุดตัวแปรนำเข้าที่เหมาะสมสู่แบบจำลอง ANN สำหรับการพยากรณ์อัตราการไหลน้ำท่ารายวัน ต่อไป

ฟังก์ชันความสัมพันธ์แบ่งได้เป็น 2 ประเภท คือ ฟังก์ชันความสัมพันธ์ของตัวแปรเดียวกันเทียบกับเวลา (autocorrelation function) ซึ่งจะพิจารณาถึงเฉพาะความสัมพันธ์ระหว่างอนุกรมเวลาชนิดเดียวกัน เช่น ปริมาณน้ำท่าวันนี้มีความสัมพันธ์กับปริมาณน้ำท่าวันที่แล้วมา มากน้อยขนาดไหน เป็นต้น ส่วนฟังก์ชันความสัมพันธ์อีกประเภท คือ ฟังก์ชันความสัมพันธ์ของตัวแปรต่างกันเทียบกับเวลา (cross correlation function) จะใช้พิจารณาความสัมพันธ์ระหว่างอนุกรมเวลาต่างชนิดกัน 2 ชุด เช่น การพิจารณาความสัมพันธ์ระหว่างปริมาณน้ำท่าวันนี้กับปริมาณน้ำฝนที่ตกในวันที่แล้วๆ มา เป็นต้น และนอกจากนี้ ฟังก์ชันความสัมพันธ์ของตัวแปรเดียวกันเทียบกับเวลา ยังสามารถแบ่งออกได้เป็น ฟังก์ชันความสัมพันธ์ของตัวแปรเดียวกันในส่วนสุดท้ายเทียบกับเวลา (partial autocorrelation function) ซึ่งรายละเอียดวิธีการวิเคราะห์จะกล่าวในหัวข้อต่อไป ดังนี้

##### 3.1.1 การวิเคราะห์ความสัมพันธ์ของตัวแปรเดียวกันเทียบกับเวลา (Autocorrelation analysis)

เป็นการวิเคราะห์หาค่าความสัมพันธ์ของตัวแปรชนิดเดียวกันเทียบกับช่วงเวลาถัดไป  $k$  หน่วยเวลา (lag time) ดังรูป 3-1 โดยการพิจารณาค่าความสัมพันธ์นั้น จะพิจารณาความสัมพันธ์ระหว่างตัวแปรตัวเดียวกันแต่เวลาต่างกัน ครั้งละ 2 ตัว เช่น การพิจารณาความสัมพันธ์ระหว่าง  $X_t$  กับ  $X_{t-1}$  หรือ  $X_t$  กับ  $X_{t-2}$  เป็นต้น การวิเคราะห์หาค่าความสัมพันธ์แบบนี้จะไม่คำนึงถึงตัวแปร ณ เวลาอื่นๆ เข้ามาเกี่ยวข้องเลย ดังนั้นค่าความสัมพันธ์ที่ได้ อาจจะไม่ใช่ค่าความสัมพันธ์ที่แท้จริงระหว่างตัวแปรทั้งสอง หากตัวแปรนั้นๆ มีอิทธิพลของตัวแปร ณ เวลาอื่นๆ ที่ไม่ได้นำมาพิจารณาแฝงอยู่ด้วย เช่น  $X_t$  นอกจากจะขึ้นอยู่หรือมีความสัมพันธ์กับ  $X_{t-1}$  แล้วนั้น ในความเป็นจริง  $X_t$  ยังอาจขึ้นอยู่กับปัจจัยอื่นๆ อีก เช่น  $X_{t-2}$  หรือ  $X_{t-3}$



รูป 3-1 นิยามค่าความสัมพันธ์แบบ autocorrelation ของอนุกรมเวลาต่อเนื่องชุดหนึ่ง

ค่าความสัมพันธ์แบบ autocorrelation ที่ใช้วัดความสัมพันธ์เชิงเส้นระหว่างตัวแปร  $X_t$  กับ  $X_{t+k}$  นั้นเรียกว่า ค่าสัมประสิทธิ์ความสัมพันธ์แบบ autocorrelation เขียนแทนด้วย  $\rho_k$  สำหรับกลุ่มตัวแปรทั้งหมด (population) และ  $r_k$  สำหรับกลุ่มตัวแปรตัวอย่าง (sampling) ซึ่งสามารถหาค่าได้โดยสมการ 3-1

$$\rho_k = \frac{\text{cov}(X_t, X_{t+k})}{\text{var } X_t} = \frac{\sum_{t=1}^{N-k} (X_t - \mu)(X_{t+k} - \mu)}{\sum_{t=1}^N (X_t - \mu)^2} \quad \dots\dots(3-1)$$

$$r_k = \frac{\sum_{t=1}^{N-k} (X_t - \bar{X})(X_{t+k} - \bar{X})}{\sum_{t=1}^N (X_t - \bar{X})^2}$$

เมื่อ  $k = 1, 2, \dots$

ในกรณีที่อนุกรมเวลามีข้อมูลไม่มาก ( $N < 30$ ) จะใช้สมการ 3-2 ในการหาค่า  $r_k$  แทน


$$r_k = \frac{\text{cov}(X_t, X_{t+k})}{(\text{var } X_t \cdot \text{var } X_{t+k})^{1/2}}$$

$$= \frac{\sum_{t=1}^{N-k} (X_t - \bar{X}_t)(X_{t+k} - \bar{X}_{t+k})}{\left( \sum_{t=1}^{N-k} (X_t - \bar{X}_t)^2 \sum_{t=1}^{N-k} (X_{t+k} - \bar{X}_{t+k})^2 \right)^{1/2}} \quad \dots\dots(3-2)$$

เมื่อ  $\text{cov}(X_t, X_{t+k})$  คือ ค่าความแปรปรวนร่วมระหว่างตัวแปร  $X_t$  และ  $X_{t+k}$  (covariance)  
 $\text{var}(X_t)$  คือ ค่าความแปรปรวนของตัวแปร  $X_t$  (variance)  
 $N$  คือ จำนวนข้อมูลทั้งหมด

ค่าสัมประสิทธิ์ความสัมพันธ์แบบ autocorrelation นี้จะมีค่าตั้งแต่  $-1$  ถึง  $+1$  ถ้า  $r_k$  มีค่าเป็นบวก แสดงว่าข้อมูลที่ห่างกันระยะเวลา  $k$  จะมีความสัมพันธ์กันในเชิงบวก นั่นคือถ้า  $X_t$  มาก  $X_{t+k}$  จะมีค่ามากด้วย แต่ถ้า  $r_k$  มีค่าเป็นลบ แสดงว่าข้อมูลที่ห่างกันระยะเวลา  $k$  มีความสัมพันธ์กันในทางลบ นั่นคือถ้า  $X_t$  มาก  $X_{t+k}$  จะมีค่าน้อยตาม และถ้า  $r_k = 0$  แสดงว่าข้อมูลที่ห่างกันระยะเวลา  $k$  ไม่มีความสัมพันธ์ขึ้นต่อกันเลย

เมื่อนำค่าสัมประสิทธิ์ของความสัมพันธ์แบบ autocorrelation ไปเขียนกราฟความสัมพันธ์กับ  $k$  จะได้กราฟซึ่งเรียกว่า กราฟความสัมพันธ์ตัวแปรเดียวกัน (correlogram) หรือ ฟังก์ชันความสัมพันธ์ของตัวแปรชนิดเดียวกันเทียบกับเวลา (autocorrelation function) ดังรูป 3-2



ที่มา Yevjevich, 1972

รูป 3-2 Correlogram ของอนุกรมเวลา (a) ต่อเนื่อง (b) ไม่ต่อเนื่อง

### 3.1.2 การวิเคราะห์ความสัมพันธ์ของตัวแปรเดียวกันในส่วนสุดท้ายเทียบกับเวลา (Partial autocorrelation analysis)

การวิเคราะห์ความสัมพันธ์แบบ partial autocorrelation นั้น เป็นอีกวิธีหนึ่งที่ใช้ในการหาค่าความสัมพันธ์ของตัวแปรเดียวกัน เพื่อใช้ในการพิจารณาว่าตัวแปรชนิดเดียวกันจะมีความสัมพันธ์กันถึงอันดับจำกัด (order) หรือช่วงเวลาถัดไป  $k$  กี่หน่วยเวลา

การวิเคราะห์โดยวิธีนี้นั้น จะนำค่า  $\rho_k$  (เมื่อ  $k=1, 2, \dots, N$ ) ที่คำนวณได้จากหัวข้อที่แล้ว มาเขียนให้อยู่ในรูปของสมการเส้นตรง ที่คำนึงถึงความสัมพันธ์ระหว่างค่า  $\rho_k$  กับค่า  $\rho_0$  ถึง  $\rho_{k-1}$

$$\begin{aligned} \text{ดังนั้น} \quad \rho_1 &= \phi_1(1) \rho_0 \\ \rho_2 &= \phi_1(2) \rho_0 + \phi_2(2) \rho_1 \\ &\vdots \\ \rho_k &= \phi_1(k) \rho_0 + \phi_2(k) \rho_1 + \dots + \phi_k(k) \rho_{k-1} \end{aligned}$$

โดยค่าความสัมพันธ์ในส่วนสุดท้าย ซึ่งจะพิจารณาถึงค่าความสัมพันธ์ระหว่างค่า  $\rho_k$  และ  $\rho_{k-1}$  นั้นเรียกว่า ค่าสัมประสิทธิ์ความสัมพันธ์ของตัวแปรเดียวกันในส่วนสุดท้าย ณ เวลา  $k$  เขียนแทนด้วย  $\phi_k(k)$  ในการหาค่า  $\phi_k(k)$  สามารถพิจารณาได้จากสมการรูปทั่วไป ดังสมการ 3-3 (Salas et.al., 1980)

$$\rho_j = \phi_1(k) \rho_{j-1} + \phi_2(k) \rho_{j-2} + \dots + \phi_k(k) \rho_{j-k} \quad \dots\dots(3-3)$$

เมื่อ  $j = 1, 2, \dots, k$

ตัวอย่างการหาค่า  $\phi_k(k)$  เมื่อ  $k = 1$  และ 2

สำหรับ  $k = 1$  จะได้

$$\begin{aligned} \rho_1 &= \phi_1(1) \rho_0 \quad \text{เมื่อ } \rho_0 = 1 \\ \text{จะได้} \quad \phi_1(1) &= \rho_1 \quad \dots\dots(3-4) \\ \text{และ} \quad \phi_k(k) &= 0 \quad \text{เมื่อ } k > 1 \end{aligned}$$

สำหรับ  $k = 2$

$$\begin{aligned} \text{เมื่อ } j = 1 \text{ จะได้} \quad \rho_1 &= \phi_1(2) \rho_0 + \phi_2(2) \rho_{-1} \\ \text{โดยที่} \quad \rho_{-1} &= \rho_1 \quad \text{เนื่องจาก } \rho_x \text{ มีความสมมาตรรอบแกน } k=0 \\ \therefore \text{จะได้} \quad \rho_1 &= \phi_1(2) \rho_0 + \phi_2(2) \rho_1 \quad \dots\dots(3-5) \end{aligned}$$

$$\text{เมื่อ } j = 2 \quad \rho_2 = \phi_1(2) \rho_1 + \phi_2(2) \rho_0 \quad \dots\dots(3-6)$$

$$\text{และ} \quad \phi_k(k) = 0 \quad \text{เมื่อ } k > 2$$

จากสมการที่ 3-5 และ 3-6 สามารถเขียนในรูปเมตริกได้เป็น

$$\begin{bmatrix} \rho_1 \\ \rho_2 \end{bmatrix} = \begin{bmatrix} \rho_0 & \rho_1 \\ \rho_1 & \rho_0 \end{bmatrix} \begin{bmatrix} \phi_1(2) \\ \phi_2(2) \end{bmatrix}$$

$$= \begin{bmatrix} 1 & \rho_1 \\ \rho_1 & 1 \end{bmatrix} \begin{bmatrix} \phi_1(2) \\ \phi_2(2) \end{bmatrix}$$

และสามารถแก้สมการได้ดังสมการ 3-7

$$\begin{aligned} \phi_1(2) &= \frac{\rho_1(1-\rho_2)}{(1-\rho_1^2)} \\ \phi_2(2) &= \frac{\rho_2-\rho_1^2}{(1-\rho_1^2)} \end{aligned} \quad \dots\dots(3-7)$$

ดังนั้น ค่า  $\phi_k(k)$  ณ ช่วงเวลา  $k$  ใดๆ จะสามารถเขียนในรูปเมตริกได้ดังสมการ 3-8

$$\begin{bmatrix} 1 & \rho_1 & \rho_2 & \dots & \rho_{k-1} \\ \rho_1 & 1 & \rho_1 & \dots & \rho_{k-2} \\ \rho_2 & \rho_1 & 1 & \dots & \rho_{k-3} \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \dots & 1 \end{bmatrix} \begin{bmatrix} \phi_1(k) \\ \phi_2(k) \\ \phi_3(k) \\ \cdot \\ \cdot \\ \cdot \\ \phi_k(k) \end{bmatrix} = \begin{bmatrix} \rho_1 \\ \rho_2 \\ \rho_3 \\ \cdot \\ \cdot \\ \cdot \\ \rho_k \end{bmatrix} \quad \dots\dots(3-8)$$

หรือ  $\rho_k \phi_k(k) = \rho_k$   
 $\phi_k(k) = \rho_k^{-1} \rho_k$  เมื่อ  $k = 1, 2, \dots$  \dots\dots(3-9)


นอกจากนี้ค่า  $\phi_k(k)$  ยังสามารถหาได้จากวิธีของ Durbin's (1960) ซึ่งอธิบายไว้ดัง สมการ

3-10

$$\phi_k(k) = \frac{\rho_k - \sum_{j=1}^{k-1} \phi_j(k-1)\rho_{k-j}}{1 - \sum_{j=1}^{k-1} \phi_j(k-1)\rho_j} \quad \dots\dots(3-10)$$

$$\phi_j(k) = \phi_j(k-1) - \phi_k(k)\phi_{k-j}(k-1)$$

เมื่อนำค่า  $\phi_k(k)$  มาเขียนกราฟความสัมพันธ์กับหน่วยเวลา  $k$  จะเรียกว่า กราฟความสัมพันธ์ของตัวแปรเดียวกันในส่วนสุดท้าย (partial correlogram) หรือ ฟังก์ชันความสัมพันธ์ของตัวแปรเดียวกันในส่วนสุดท้ายเทียบกับเวลา (partial autocorrelation function) ดังรูป 3-3



ที่มา ชัยพันธุ์, 2529


รูป 3-3 Partial correlogram และ correlogram ของอนุกรมเวลา  $Z_t$

จากกราฟ correlogram และ partial correlogram ถ้าตัวแปรมีความสัมพันธ์หรือขึ้นอยู่กับกัน (dependent variables) ค่า  $r_k$  และ  $\phi_k(k)$  จะมีค่าเข้าใกล้ 1 ซึ่งจะหมายถึงตัวแปรหรือค่าสัมพันธ์ประสิทธิภาพสัมพันธ์ในตัวเอง ณ หน่วยเวลานั้นๆ มีค่ามากควรแก่การสนใจ แต่ถ้าตัวแปรเป็นอิสระต่อกัน (independent variables) ค่า  $r_k$  และ  $\phi_k(k)$  จะมีค่าเป็น 0 หรือมีค่าใกล้ 0 ซึ่งจะหมายถึงตัวแปรนั้นๆ ไม่ควรแก่การสนใจ โดยขอบเขตที่ยอมรับได้ว่าตัวแปรเป็นอิสระต่อกัน ที่ระดับนัยสำคัญ 95% นั้นสามารถประมาณได้จากสมการ 3-11 (ชัยโรจน์, 2539)

$$r_k(95\%) = \pm 2\sigma_{r_k} = \pm 2\sqrt{\frac{1}{N}} \dots\dots(3-11)$$

เมื่อ  $\sigma_{r_k}$  คือ ค่าเบี่ยงเบนมาตรฐานของค่า  $r_k$  หรือ  $\phi_k(k)$   
 $N$  คือ จำนวนข้อมูลทั้งหมด

และสามารถแสดงได้ดังรูป 3-4



ที่มา ชัยโรจน์, 2539

รูป 3-4 เขตขอบเขตความเป็นอิสระต่อกันในตัวเองของอนุกรม  $Y_t$  ที่ระดับนัยสำคัญ 95%

### 3.1.3 การวิเคราะห์ความสัมพันธ์ของตัวแปรต่างกันเทียบกับเวลา (Cross correlation)

การวิเคราะห์ความสัมพันธ์แบบ cross correlation นั้นเป็นวิธีการวิเคราะห์ความสัมพันธ์ระหว่างข้อมูลอนุกรมเวลา 2 ชุด ( $X_t$ ,  $Y_t$ ) เมื่อชุดหนึ่ง ( $Y_t$ ) เป็นตัวแปรตามของอีกชุดหนึ่ง ( $X_t$ ) ตัวอย่างเช่น ความสัมพันธ์ระหว่างน้ำท่าที่เกิดจากน้ำฝน หรือ ความสัมพันธ์ระหว่างปริมาณน้ำที่ไหลเข้าอ่างเก็บน้ำกับอัตราการละลายของหิมะ เป็นต้น ซึ่งการวิเคราะห์แบบนี้จะแตกต่างกับการวิเคราะห์ความสัมพันธ์ของตัวแปรต่างกันเทียบกับเวลา ที่จะพิจารณาความสัมพันธ์เฉพาะในอนุกรมเวลาชุดนั้นๆ เพียงอย่างเดียว ( $X_t$ ,  $X_{t+k}$ ) โดยค่าความสัมพันธ์ระหว่างอนุกรมเวลา 2 ชุดนั้นๆ เรียกว่า ค่าสัมประสิทธิ์ความสัมพันธ์แบบ cross correlation เขียนแทนด้วย  $\rho_{xy}$  หรือ  $r_{xy}$  ซึ่งสามารถคำนวณได้จากสมการ 3-12

$$\rho_{xy} = \frac{\text{cov}(X_t, Y_t)}{[\text{var}(X_t) \text{var}(Y_t)]^{1/2}}$$

$$= \frac{\sum_{t=1}^N (X_t - \mu_x)(Y_t - \mu_y)}{\left[ \sum_{t=1}^N (X_t - \mu_x)^2 \sum_{t=1}^N (Y_t - \mu_y)^2 \right]^{1/2}}$$

$$r_{xy} = \frac{\sum_{t=1}^N (X_t - \bar{X})(Y_t - \bar{Y})}{\left[ \sum_{t=1}^N (X_t - \bar{X})^2 \sum_{t=1}^N (Y_t - \bar{Y})^2 \right]^{1/2}}$$

.....(3-12)




สำหรับการวิเคราะห์ Lag-cross correlation สามารถวิเคราะห์ได้ดังต่อไปนี้

$$r_{X_t, Y_{t+k}} = \frac{\sum_{t=1}^{N-k} (X_t - \bar{X})(Y_{t+k} - \bar{Y}_{t+k})}{\left[ \sum_{t=1}^{N-k} (X_t - \bar{X})^2 \sum_{t=1}^{N-k} (Y_{t+k} - \bar{Y}_{t+k})^2 \right]^{1/2}} \quad \dots\dots(3-13)$$

เมื่อ  $k = 1, 2, \dots$

เมื่อนำค่า  $r_{xy}$  หรือ  $r_{yx}$  มาเขียนกราฟความสัมพันธ์กับ  $k$  สามารถแสดงได้ดังรูป 3-5 ซึ่งจะเห็นว่ากราฟจะไม่สมมาตรรอบแกน  $k = 0$



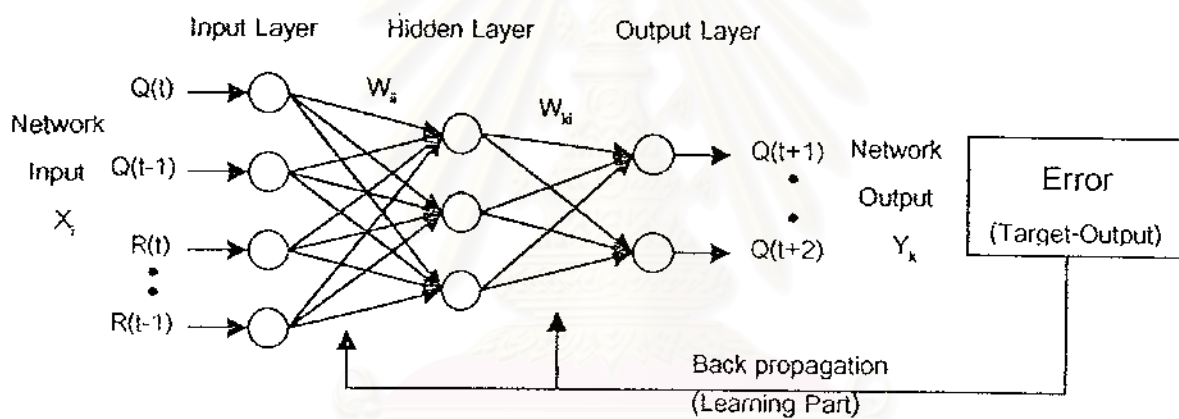
ที่มา Yevjevich, 1972

รูป 3-5 กราฟความสัมพันธ์แบบ cross correlation ระหว่างอนุกรมเวลา X และ Y

### 3.2 แบบจำลอง Back Propagation Neural Network (BPNN)

#### 3.2.1 โครงสร้างของแบบจำลอง BPNN

โครงสร้างทั่วไปของ BPNN จะประกอบด้วยชั้นหลายชั้น (multilayer) อันได้แก่ ชั้นป้อนข้อมูลเข้า (input layer) ชั้นกลาง (middle layer) หรือ ชั้นแอบแฝง (hidden layer) ซึ่งอาจมีได้หลายชั้น และชั้นแสดงผลการคำนวณ (output layer) ดังรูป 3-6 โดยแต่ละชั้นนั้นจะประกอบด้วยหน่วยย่อยๆ (nodes หรือ neurons) ซึ่งหน่วยแต่ละหน่วยของแต่ละชั้นนั้น จะถูกเชื่อมโยงด้วยค่าถ่วงน้ำหนัก (connection weight,  $W_p$ ) กับหน่วยแต่ละหน่วยในชั้นถัดไป โดยโครงข่ายชนิดนี้จะมีการทำงานแบบเคลื่อนที่ไปข้างหน้า (feedforward) เพียงอย่างเดียว




รูป 3-6 ลักษณะโครงสร้างของแบบจำลอง BPNN

สำหรับกระบวนการย้อนกลับ หรือ Back Propagation นั้นจะใช้ในช่วงกระบวนการเรียนรู้หรือปรับเทียบแบบจำลอง (learning or training) เพื่อหาค่าถ่วงน้ำหนักที่เหมาะสมให้กับแบบจำลองหรือโครงข่าย

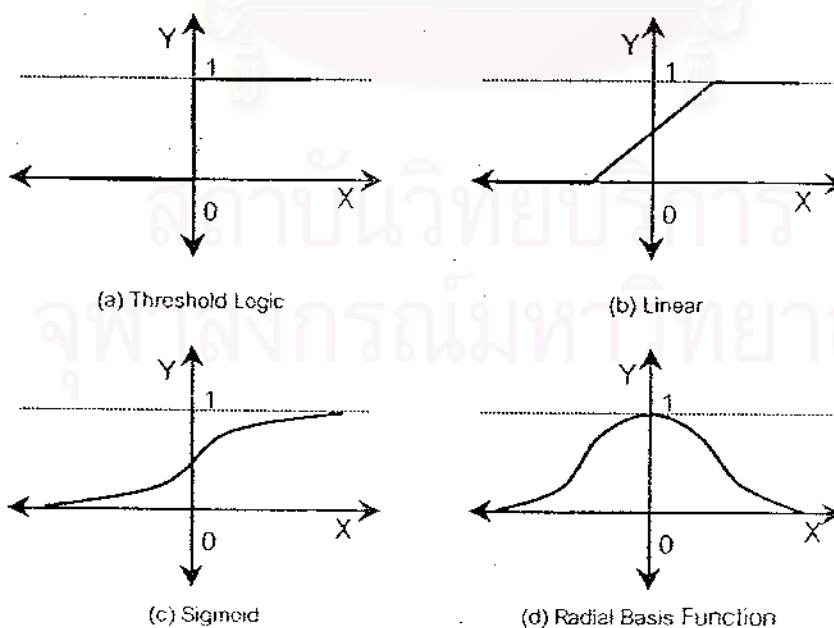
#### 3.2.2 หลักการทำงานพื้นฐานของแบบจำลอง

สำหรับหลักการทำงานพื้นฐานของแบบจำลอง BPNN นั้น คือ การทำงานในแต่ละหน่วยย่อยของโครงข่าย ซึ่งจะมีลักษณะการทำงานดังรูป 3-7 คือ



รูป 3-7 หลักการทำงานพื้นฐานของหน่วยย่อย ในแบบจำลอง BPNN

- 1) ข้อมูลป้อนเข้าที่ส่งมาจากชั้นที่ผ่านมาจะถูกนำมาคูณกับค่าถ่วงน้ำหนัก ที่เชื่อมอยู่กับหน่วยนั้นๆ
- 2) รวมผลคูณระหว่างข้อมูลที่เข้ามากับค่าถ่วงน้ำหนัก และบวกด้วยค่าเอนเอียง (bias,  $\theta$ )
- 3) ผลรวมจากข้อที่ 2 นั้นจะถูกแปลงค่าโดยผ่านฟังก์ชันกระตุ้นหรือฟังก์ชันเปลี่ยนรูป (activation or transform function) ซึ่งเป็นฟังก์ชันที่มีทั้งเป็นแบบเชิงเส้น (linear function) และไม่เป็นเชิงเส้น (non-linear function) ดังรูป 3-8
- 4) ค่าที่ผ่านฟังก์ชันกระตุ้นมาแล้วจะกลายเป็นข้อมูลป้อนเข้า ให้กับหน่วยแต่ละตัวในชั้นถัดไป



รูป 3-8 รูปแบบต่างๆ ของฟังก์ชันกระตุ้น (Activation Function)

### 3.2.3 ขั้นตอนการทำงานกระบวนการเรียนรู้ในแบบจำลอง

สำหรับขั้นตอนกระบวนการเรียนรู้ภายในแบบจำลอง BPNN นั้น สามารถแบ่งออกเป็น 2 ขั้นตอนหลักคือ การคำนวณไปข้างหน้า (forward computation) และ การปรับแก้ย้อนหลัง (backward training) ซึ่งแต่ละขั้นตอนสามารถอธิบายรายละเอียดการทำงานได้ดังต่อไปนี้

#### 1. การคำนวณไปข้างหน้า มี 3 ขั้นตอนย่อย คือ

- 1) แปลงค่าข้อมูลนำเข้า และข้อมูลออก ให้อยู่ในรูปแบบมาตรฐาน (normalization) ซึ่งเป็นค่าไร้หน่วย โดยทั่วไปจะแปลงให้อยู่ในช่วง 0 ถึง 1 เมื่อเลือกใช้ฟังก์ชันกระตุ้นแบบซิกมอยด์ แต่ในการศึกษาครั้งนี้จะใช้โปรแกรม Qnet2000 ในการทำ normalization ซึ่งจะมีค่าอยู่ในช่วง 0.15 ถึง 0.85
- 2) สมมุติค่าเริ่มต้นของ ค่าถ่วงน้ำหนักและค่าพารามิเตอร์ต่างๆ
- 3) ทำการคำนวณพื้นฐานในหน่วยแต่ละหน่วย (neuron process) ดังต่อไปนี้
  - หน่วยแต่ละหน่วยของแต่ละชั้นจะมีการรวมค่าผลคูณระหว่างค่าถ่วงน้ำหนักกับข้อมูลป้อนเข้าของชั้นที่ผ่านมา ดังสมการ 3-14

$$N_{j,m} = \sum_{i=1}^{n_{m-1}} W_{ji,m}(n) \cdot O_{i,m-1} + \theta_{j,m} \quad \dots\dots(3-14)$$

เมื่อ

$N_{j,m}$  คือ ผลรวมของผลคูณระหว่างค่าถ่วงน้ำหนักกับข้อมูลป้อนเข้าของชั้นที่ผ่านมาบวกค่าเอนเอียง ในหน่วยที่  $j^{\text{th}}$  ของชั้นที่  $m^{\text{th}}$

$W_{ji,m}(n)$  คือ ค่าถ่วงน้ำหนักที่เชื่อมระหว่างหน่วยที่  $j^{\text{th}}$  ของชั้นที่  $m$  กับหน่วยที่  $i^{\text{th}}$  ของชั้นที่  $m-1$  ในรอบที่  $n^{\text{th}}$

$O_{i,m-1}$  คือ ผลที่ออกจากหน่วยที่  $i^{\text{th}}$  ของชั้นที่  $m-1$

$\theta_{j,m}$  คือ ค่าเอนเอียงในหน่วยที่  $j^{\text{th}}$  ของชั้นที่  $m^{\text{th}}$

- ค่าผลรวม  $N_{j,m}$  ในชั้นตอนที่ 1 จะถูกแปลงค่าโดยผ่านฟังก์ชันกระตุ้นแบบซิกมอยด์ ดังสมการ 3-15 ซึ่งเป็นข้อมูลที่จะนำออกเพื่อส่งผ่านให้ชั้นถัดไป

$$O_{j,m} = f(N_{j,m}) = \frac{1}{1 + e^{-N_{j,m}}} \quad \dots\dots(3-15)$$

2. การปรับแก้ย้อนหลัง มี 2 ขั้นตอนย่อย คือ ขั้นตอนที่ 4 และ 5

- 4) เมื่อการคำนวณเคลื่อนที่มายังขั้นสุดท้าย หรือชั้นแสดงผลการคำนวณ โครงข่ายจะทำการคำนวณพจน์ของค่าความผิดพลาดของแต่ละหน่วย ( $\delta_{j,m}$ ) ในแต่ละชั้น ดังสมการ 3-16 เพื่อให้ค่าคลาดเคลื่อนลู่เข้าสู่ค่าต่ำสุด (Manusthiparom, 2000)

$$\delta_{j,m} = \begin{cases} f'(N_{j,m}) \cdot (t_j - O_{j,m}) & \text{for Output Layer} \\ f'(N_{j,m}) \cdot \sum_{k=1}^{n_{m+1}} w_{k,j,m+1} \delta_{k,m+1} & \text{for Hidden Layer} \end{cases} \quad \dots\dots(3-16)$$

เมื่อ

$\delta_{j,m}$  คือ พจน์ของความผิดพลาดของหน่วย  $j^{\text{th}}$  ในชั้นที่  $m$

$t_j$  คือ ค่าที่ได้จากข้อมูลจริงของหน่วยที่  $j^{\text{th}}$  ในชั้นแสดงผลออก

$f'$  คือ อนุพันธ์ของฟังก์ชันกระตุ้นแบบซิกมอยด์ หาได้จากสมการ 3-17

$$f'(N_{j,m}) = O_{j,m} \cdot (1 - O_{j,m}) = f(N_{j,m}) \cdot (1 - f(N_{j,m})) \quad \dots\dots(3-17)$$

และคำนวณค่าปรับแก้หรือผลต่างน้ำหนัก ( $\Delta w_{j,m}$ ) ในรอบที่  $n+1$  จากสมการ 3-18

$$\Delta w_{j,m}(n+1) = \eta \delta_{j,m} O_{i,m-1} + \alpha \Delta w_{j,m}(n) \quad \dots\dots(3-18)$$

เมื่อ

$\Delta w_{j,m}(n+1)$  คือ ผลต่างน้ำหนักที่เชื่อมระหว่างหน่วยที่  $j^{\text{th}}$  ของชั้นที่  $m$  กับหน่วยที่  $i^{\text{th}}$  ของชั้นที่  $m-1$  ในรอบที่  $n+1$

$\Delta w_{j,m}(n)$  คือ ผลต่างน้ำหนักที่เชื่อมระหว่างหน่วยที่  $j^{\text{th}}$  ของชั้นที่  $m$  กับหน่วยที่  $i^{\text{th}}$  ของชั้นที่  $m-1$  ในรอบที่  $n$

$\eta$  คือ ค่าอัตราเร็วการเรียนรู้ มีค่า 0-1

$\alpha$  คือ ค่าโมเมนตัม มีค่า 0-1


- 5) ทำการปรับค่าถ่วงน้ำหนักใหม่ในแต่ละชั้นแบบย้อนกลับ (Back Propagation) เพื่อใช้ในการคำนวณใหม่ในรอบที่  $n+1$  โดยใช้สมการ 3-19 ซึ่งได้จาก กฎของเดลตา (Delta Rule)

$$w_{j,m}(n+1) = w_{j,m}(n) + \Delta w_{j,m}(n+1) \quad \dots\dots(3-19)$$

- 6) ทำซ้ำจากข้อ 2 ถึงข้อ 5 จนได้ค่าระดับความผิดพลาดที่ต่ำกว่าที่กำหนด หรือจำนวนรอบที่คำนวณมีค่าเท่ากับจำนวนที่กำหนดไว้ จึงจะทำการหยุดการทำงานของกระบวนการปรับแก้
- 7) แปลงค่าการคำนวณที่ได้ ให้กลับอยู่ในรูปทั่วไปที่มีหน่วย (denormalization)

โดยขั้นตอนการทำงานต่างๆ ของแบบจำลอง BPNN ที่กล่าวมานั้นสามารถสรุปได้ดังรูปที่

3-9



รูป 3-9 ขั้นตอนการทำงานของกระบวนการเรียนรู้ในแบบจำลอง BPNN

### 3.2.4 ข้อพิจารณาพื้นฐานในการพัฒนาแบบจำลอง ANN

ในการจัดสร้างแบบจำลอง ANN มีองค์ประกอบหลายประการที่ต้องพิจารณาและกำหนดให้เหมาะสม ดังต่อไปนี้

- 1) จำนวนหน่วยในชั้นแอบแฝงและจำนวนชั้นแอบแฝง (Number of nodes and layers of hidden layer)

ในการหาจำนวนหน่วยในชั้นแอบแฝงและจำนวนชั้นแอบแฝงที่เหมาะสมกับโครงข่ายนั้น เป็นเรื่องยากที่จะกำหนดกฎเกณฑ์ที่แน่นอน จากผลการศึกษาที่ผ่านมา พบที่จะสามารถแบ่งวิธีการหาจำนวนหน่วย และจำนวนชั้นแอบแฝงที่เหมาะสมได้ออกเป็น 3 แบบ คือ

- Trial & error เป็นวิธีการที่นำไปใช้ในวงเริ่มต้นของการนำแบบจำลอง ANN มาประยุกต์ใช้กับงานต่างๆ ซึ่งเป็นวิธีการที่ต้องใช้เวลามาก ในการหาจำนวนหน่วย และจำนวนชั้นแอบแฝงที่เหมาะสม
- การกำหนดจำนวนหน่วยและจำนวนชั้นแอบแฝงให้สัมพันธ์กับจำนวนข้อมูลป้อนเข้าหรือจำนวนข้อมูลนำออก การนำวิธีนี้มาใช้นั้น เพื่อเป็นการลดเวลาในการหาจำนวนหน่วย และจำนวนชั้นแอบแฝงที่เหมาะสม นอกจากนี้ยังง่ายต่อการเข้าใจ และการนำไปใช้งาน ตัวอย่างเช่น เจษฎา (2543) ได้มีการกำหนดจำนวนหน่วย 3 ทางเลือกคือ มีจำนวนครึ่งหนึ่ง เท่ากับ และเป็นสองเท่า ของจำนวนข้อมูลนำเข้า ซึ่งเป็นวิธีการที่สามารถเปรียบเทียบผลที่เกิดจากความแตกต่างของจำนวนหน่วยในชั้นแอบแฝง ได้อย่างชัดเจน
- การนำทฤษฎีการหาค่าความเหมาะสม ( optimization ) มาประยุกต์ใช้ จากการศึกษามาก่อนมา ในปัจจุบันได้มีการนำเอาทฤษฎีการหาค่าความเหมาะสมมาประยุกต์ใช้ ในการหาจำนวนหน่วยและจำนวนชั้นแอบแฝงที่เหมาะสม ร่วมกับแบบจำลอง ANN หลายทฤษฎีด้วยกัน ตัวอย่างเช่น Genetic Algorithm ( Abrahart et al.,1999 ), Pruning Algorithm ( Abrahart et al.,1999 ) และ Cascade-Correlation Algorithm ( Thirumalaiah.,1998 ) โดยวิธีการต่างๆ เหล่านี้ จำเป็นที่จะต้องเข้าใจทฤษฎีเหล่านั้นอย่างถ่องแท้ หรือใช้โปรแกรมสำเร็จรูปเข้าช่วย

สำหรับในการศึกษาครั้งนี้ จะใช้การกำหนดจำนวนหน่วยในชั้นแอบแฝงและจำนวนชั้นแอบแฝงให้สัมพันธ์กับจำนวนข้อมูลนำเข้า เพื่อความสะดวกต่อการเข้าใจ และการนำไปใช้งาน

## 2) ฟังก์ชันกระตุ้น (Activation function)

จากที่ได้กล่าวไว้ในหัวข้อ 3.2.2 จะเห็นได้ว่าฟังก์ชันกระตุ้นนั้นมีหลายชนิดด้วยกัน สำหรับการเลือกฟังก์ชันกระตุ้นให้เหมาะสมกับโครงข่าย จะขึ้นอยู่กับปัญหาที่จะนำแบบจำลอง ANN มาประยุกต์ใช้ว่า มีความสัมพันธ์กับตัวแปรอย่างไร และนอกจากนี้ยังขึ้นอยู่กับกระบวนการเรียนรู้ที่ใช้ในแบบจำลอง ตัวอย่างเช่น กระบวนการเรียนรู้แบบ Back Propagation นั้น จำเป็นที่จะต้องใช้ฟังก์ชันกระตุ้นที่สามารถหาอนุพันธ์ได้ เป็นต้น

ในการศึกษาครั้งนี้ ได้เลือกฟังก์ชันกระตุ้นแบบซิกมอยด์ เพื่อใช้ร่วมกับกระบวนการเรียนรู้แบบ Back Propagation และเป็นฟังก์ชันที่ได้รับความนิยมที่สุด ในการใช้งานสำหรับการพยากรณ์ (เสรี, 2544)

## 3) กำหนดค่าเริ่มต้นของค่าถ่วงน้ำหนัก (Weight initialization)

ในช่วงการเริ่มต้นของกระบวนการเรียนรู้ ค่าเริ่มต้นของค่าถ่วงน้ำหนักที่เลือกจะมีผลต่อการลู่เข้า (convergence) หากความคลาดเคลื่อนที่ต่ำที่สุด ค่าถ่วงน้ำหนักเริ่มต้นที่ใกล้เคียงกับค่าน้ำหนักสุดท้าย ย่อมทำให้อัตราการเรียนรู้หาคำตอบเร็วขึ้น ในทางตรงกันข้ามการเลือกค่าเริ่มต้นที่ไม่ดีจะทำให้การคำนวณซ้ำกันหลายรอบ (1000 - 10,000 รอบ) จึงจะหาคำตอบสุดท้าย และอาจจะล้มเหลวหรือไม่ลู่เข้าหาคำตอบสุดท้าย (divergence) ก็เป็นไปได้

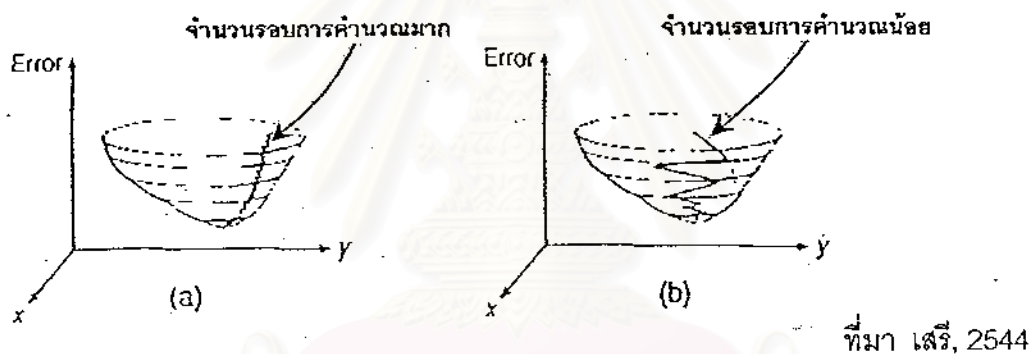
เสรี (2544) ได้กล่าวไว้ว่า นักวิจัยหลายท่านได้แสดงให้เห็นว่าการเลือกค่าถ่วงน้ำหนักให้มีค่าน้อยๆ (แต่ไม่น้อยมาก) ซึ่งอยู่ระหว่าง  $-1$  ถึง  $1$  นั้นเป็นแนวทางที่มีประสิทธิภาพในการหลีกเลี่ยงปัญหาดังกล่าว เพราะการเลือกค่าถ่วงน้ำหนักมากๆ จะทำให้ค่าอนุพันธ์ของฟังก์ชันกระตุ้นเข้าใกล้  $0$  ดังนั้นค่าปรับค่าถ่วงน้ำหนักจึงมีค่าน้อยมาก และต้องใช้เวลาในการคำนวณนานเกินความจำเป็น

โดยการศึกษานี้จะให้โปรแกรม Qnet2000 เป็นตัวกำหนดค่าเริ่มต้นของค่าถ่วงน้ำหนัก ซึ่งจะกำหนดค่าเริ่มต้นของค่าถ่วงน้ำหนักโดยวิธีการสุ่ม (random)



#### 4) อัตราเร็วในการเรียนรู้ (Learning rate, $\eta$ )

จากสมการ 3-17 จะเห็นได้ว่าค่า  $\eta$  เป็นตัวกำหนดตัวหนึ่งของขนาดของค่าปรับค่าถ่วงน้ำหนักในทุกๆรอบของการคำนวณ ดังนั้นจึงมีผลต่ออัตราการลู่เข้าด้วย ซึ่งจะมีค่าอยู่ระหว่าง 0-1 โดยจะกำหนดให้เป็นค่าคงที่ หรือกำหนดให้ผันแปรตามจำนวนรอบของการคำนวณ, แปรผันตามค่าความคลาดเคลื่อนเฉลี่ยของระบบ และแปรผันตามความแปรปรวนของข้อมูลแต่ละชุด อย่างไรก็ตาม ในกรณีที่ค่า  $\eta$  ที่เลือกมีค่ามากเกินไป ก็จะทำให้การเดินทางไปหาความคลาดเคลื่อนที่ต่ำที่สุดมีการแกว่งและอาจจะไม่มีการลู่เข้าหาคำตอบ ในทางตรงกันข้ามการเลือกค่า  $\eta$  ที่น้อยเกินไปก็เป็นการสิ้นเปลืองเวลาในการคำนวณ ดังรูป 3-10 แสดงแนวทางเดินลู่เข้าหาความคลาดเคลื่อนต่ำสุดสำหรับค่า  $\eta$  ต่างๆ



ที่มา เสรี, 2544

รูป 3-10 แนวทางเดินการลู่เข้าหาความคลาดเคลื่อนต่ำสุดสำหรับค่า  $\eta$  ต่างๆ

(a)  $\eta = 0.2$  (b)  $\eta = 0.9$


จากคู่มือการใช้โปรแกรม Qnet2000 ได้แนะนำไว้ว่า ควรกำหนดค่า  $\eta$  ให้อยู่ในช่วงระหว่าง 0.001-0.1 ซึ่งเป็นการปลอดภัยกว่าในการป้องกันการลู่ออกของคำตอบ ในการศึกษาี้จากการ trial & error เพื่อหาค่า  $\eta$  ที่เหมาะสมนั้น ได้เสนอค่า  $\eta$  มีค่าเท่ากับ 0.01

#### 5) ค่าโมเมนตัม (Momentum, $\alpha$ )

โดยทั่วไปในกระบวนการเรียนรู้ ค่าโมเมนตัมอาจจะใช้หรือไม่ใช้ก็ได้ อย่างไรก็ตามการเพิ่มค่าโมเมนตัมจะช่วยป้องกันการแกว่ง (oscillation) ของระบบ ซึ่งการเพิ่มค่าโมเมนตัมนั้น เป็นการเพิ่มสัดส่วนน้ำหนักของค่าถ่วงน้ำหนัก ณ เวลา  $n$  ให้กับค่าถ่วงน้ำหนัก ณ เวลา

ถัดไป  $\Delta w_{p,m}(n+1)$  ดังสมการ 3-29 การเพิ่มสัดส่วนดังกล่าวจะช่วยป้องกันการเปลี่ยนแปลงค่าถ่วงน้ำหนักที่รุนแรงหรือที่ผิดปกติ โดยปกติค่าโมเมนตัมจะมีค่าอยู่ระหว่าง 0-1 และการเปลี่ยนแปลงค่าโมเมนตัมกับเวลาเหมือนกับอัตราเร็วการเรียนรู้นั้นจะเป็นแนวทางที่มีประสิทธิภาพที่สุด

สำหรับค่า  $\alpha$  และ  $\eta$  นั้น มีส่วนเกี่ยวข้องกันจึงจำเป็นต้องปรับค่าไปพร้อมๆกัน ในปัญหาโดยทั่วไป อัตราเร็วในการเรียนรู้จะถูกกำหนดเริ่มต้นด้วยค่าน้อยๆ แล้วค่อยๆเพิ่มขึ้น อย่างไรก็ตามการกำหนดค่าอัตราเร็วในการเรียนรู้และค่าโมเมนตัม ยังขึ้นอยู่กับปัญหาที่พิจารณา ซึ่งไม่สามารถกำหนดเป็นกรณีทั่วๆไปได้ นักวิจัยหลายท่านได้ศึกษาอิทธิพลของค่าโมเมนตัมต่อความเร็วในการลู่เข้าหาคำตอบ รวมทั้งเสถียรภาพในการเรียนรู้ ดังรูป 3-11 แสดงพฤติกรรมของค่าโมเมนตัมกับจำนวนรอบในกระบวนการเรียนรู้ โดยกำหนด  $\eta = 1.0$  และ  $0.01$



ที่มา เสรี, 2544

รูป 3-11 พฤติกรรมของค่าโมเมนตัมกับอัตราการเรียนรู้ (a)  $\eta = 1.0$  (b)  $\eta = 0.01$

จากการ Trial & error ในการศึกษาครั้งนี้ได้เสนอใช้ค่าโมเมนตัมเท่ากับ 0.45 และ 0.95 เปลี่ยนที่ 5000 รอบ เนื่องจากในช่วงแรกถ้ากำหนดค่าโมเมนตัมมากไปจะทำให้ค่าถ่วงน้ำหนักไม่เปลี่ยนแปลงจากค่าเริ่มต้นมากนัก ซึ่งจะทำให้การคำนวณไม่ลู่เข้าสู่คำตอบ

6) ข้อกำหนดการหยุดกระบวนการเรียนรู้ของแบบจำลอง ANN

สำหรับข้อกำหนดการหยุดกระบวนการเรียนรู้ของแบบจำลอง ANN นั้น โดยทั่วไปมีวิธีที่นิยมใช้กันอยู่ 2 วิธีคือ พิจารณาจากค่าความคลาดเคลื่อนต่ำสุดซึ่งจะใช้วัดประสิทธิภาพของแบบจำลอง หรือ กำหนดโดยจำนวนรอบในการคำนวณ โดยตัววัดประสิทธิภาพของแบบจำลองนั้นนิยมใช้ค่าทางสถิติเป็นตัวแทนในการวัดซึ่งจะกล่าวต่อไปในหัวข้อ 3.5 และในการศึกษาครั้งนี้จะใช้ข้อกำหนดการหยุดโดยใช้จำนวนรอบในการคำนวณ ซึ่งพบว่าจำนวนรอบในการคำนวณที่ 10,000 รอบนั้น มีค่ามากพอที่จะทำให้ค่าความคลาดเคลื่อนลู่เข้าสู่จุดต่ำสุด

### 3.3 แบบจำลองอนุกรมเวลา

แบบจำลองอนุกรมเวลาจัดสร้างขึ้นเพื่ออธิบายกระบวนการที่ก่อให้เกิดอนุกรมเวลาแต่ละชุดนั้น โดยเมื่อทำการจัดสร้างแบบจำลองที่เหมาะสมกับอนุกรมเวลาชุดนั้นๆ ได้แล้ว ก็ให้นำแบบจำลองนี้ไปใช้ในการพยากรณ์ (forecasting) หรือสังเคราะห์ (generation) ค่าของตัวแปรต่อไป เนื่องจากแบบจำลองอนุกรมเวลาถูกสร้างขึ้นมาโดยอาศัยข้อมูลในช่วงเวลาที่ผ่านมานั้น ดังนั้นจึงระลึกไว้เสมอว่าการพยากรณ์ค่าของตัวแปรโดยใช้แบบจำลองอนุกรมเวลานี้ จะอยู่ภายใต้ข้อสมมติที่ว่าสถานการณ์ในอนาคตมีแนวโน้มที่จะเหมือนสถานการณ์ในอดีต

ในการศึกษาครั้งนี้ จะใช้แบบจำลองอนุกรมเวลาเพื่ออธิบายและพยากรณ์อนุกรมของค่าความผิดพลาดที่ยังอธิบายได้ (residuals) ที่เกิดจากแบบจำลอง ANN เพื่อปรับแก้ผลการพยากรณ์ ให้มีความถูกต้อง และมีประสิทธิภาพมากขึ้น

ปัจจุบันแบบจำลองอนุกรมเวลาสามารถจำแนกออกได้เป็น 4 ประเภท คือแบบจำลอง Autoregressive (AR), Moving Average (MA), Autoregressive-Moving Average (ARMA) และ Autoregressive Integrated Moving Average (ARIMA) โดยในที่นี้จะกล่าวถึงเฉพาะแบบจำลองอนุกรมเวลาที่นิยมใช้กันอยู่ทั่วไป อันได้แก่แบบจำลอง AR, MA และ ARMA

#### 3.3.1 แบบจำลอง Autoregressive (AR Model)

แบบจำลอง AR มีลักษณะที่สำคัญคือ ค่าของตัวแปร ณ เวลาใดก็ตามจะมีความสัมพันธ์หรือขึ้นอยู่กับค่าของตัวแปรนั้นในช่วงเวลาที่ผ่านมาแล้ว ซึ่งแสดงได้ดังสมการ 3-20

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + e_t \quad \dots\dots(3-20)$$

เมื่อ  $p$  คือ อันดับจำกัดของแบบจำลอง AR  
 $\phi$  คือ พารามิเตอร์ของแบบจำลอง AR  
 $e_t$  คือ ตัวแปรสุ่ม

โดยจะเรียกสมการ 3-20 นี้ว่า แบบจำลอง AR อันดับจำกัด  $p$  หรือ AR( $p$ ) Salas และคณะ (1980) ได้อธิบายถึงการหาค่า  $\phi$  ของแบบจำลอง AR ไว้ดังนี้

สำหรับแบบจำลอง AR(1) จากสมการ 3-20 สามารถเขียนได้เป็น

$$X_t = \phi_1 X_{t-1} + e_t$$

เมื่อกำหนดให้  $\phi_1 = \rho_1$  .....(3-21)

โดยที่ค่า  $|\phi_1| \leq 1$  เพื่อให้แบบจำลองมีคุณสมบัติเป็น stationary process

สำหรับแบบจำลอง AR(2) จากสมการ 3-20

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + e_t$$

เมื่อกำหนดให้  $\phi_1 = \frac{\rho_1(1-\rho_2)}{1-\rho_1^2}$  .....(3-22)

และ  $\phi_2 = \frac{\rho_2 - \rho_1^2}{1-\rho_1^2}$  .....(3-23)

โดยที่ค่า  $\phi_1 + \phi_2 < 1$

$$\phi_2 - \phi_1 < 1$$

$$-1 < \phi_2 < 1$$

เพื่อให้แบบจำลองมีคุณสมบัติเป็น stationary process

### 3.3.2 แบบจำลอง Moving Average (MA Model)

แบบจำลอง MA มีลักษณะสำคัญคือ ค่าของตัวแปร ณ เวลาใด ก็ตามจะมีความสัมพันธ์โดยตรงกับเทอมของตัวแปรสุ่มในช่วงเวลาที่ผ่านมาแล้ว ซึ่งสามารถเขียนแสดงได้ดังสมการ 3-24

$$X_t = e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} \quad \text{.....(3-24)}$$

เมื่อ  $q$  คือ อันดับจำกัดของแบบจำลอง MA

$\theta$  คือ ค่าพารามิเตอร์ของแบบจำลอง MA

$e_t$  คือ ค่าของตัวแปรสุ่ม ณ เวลา  $t$

สมการ 3-24 เรียกว่า แบบจำลอง MA อันดับจำกัด  $q$  หรือ MA( $q$ ) ในการหาค่า  $\theta$  ในแบบจำลอง MA(1) และ MA(2) นั้น สามารถหาได้จากสมการ 3-25 ถึง 3-27 (ชัยพันธุ์, 2529)

สำหรับ MA(1) จากสมการ 3-24 จะได้

$$X_t = e_t - \theta_1 e_{t-1}$$

เมื่อกำหนดให้

$$\rho_1 = \frac{-\theta_1}{1 + \theta_1^2} \quad \text{หรือ}$$

$$\rho_1 + \rho_1 \theta_1^2 + \theta_1 = 0 \quad \dots\dots(3-25)$$

โดยที่ค่า

$$|\theta_1| \leq 1 \quad \text{เพื่อให้แบบจำลองมีคุณสมบัติเป็น stationary process}$$

สำหรับ MA(2) จากสมการ 3-18 จะได้

$$X_t = e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2}$$

เมื่อกำหนดให้

$$\rho_1 = \frac{-\theta_1(1 - \theta_2)}{1 + \theta_1^2 + \theta_2^2} \quad \dots\dots(3-26)$$

และ

$$\rho_2 = \frac{-\theta_2}{1 + \theta_1^2 + \theta_2^2} \quad \dots\dots(3-27)$$

โดยค่า  $\theta_1$  และ  $\theta_2$  สามารถหาได้โดยวิธี trial & error

และค่า  $\theta_2 + \theta_1 \leq 1$ ,  $\theta_2 - \theta_1 \leq 1$ ,  $-1 \leq \theta_2 \leq 1$  เพื่อให้แบบจำลองมีคุณสมบัติเป็น stationary process

### 3.3.3 แบบจำลอง Autoregressive - Moving Average (ARMA Model)

เป็นแบบจำลองที่นำลักษณะสำคัญของแบบจำลอง AR และ MA มารวมกัน คือ ค่าของตัวแปร ณ เวลาใดก็ตามจะมีความสัมพันธ์โดยตรงกับค่าของตัวแปรนั้นและเทอมตัวแปรสุ่มในช่วงเวลาที่ผ่านมาแล้ว ดังสมการ 3-28

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} \quad \dots\dots(3-28)$$

- |       |          |                                  |
|-------|----------|----------------------------------|
| เมื่อ | $\phi$   | คือ ค่าพารามิเตอร์ของแบบจำลอง AR |
|       | $\theta$ | คือ ค่าพารามิเตอร์ของแบบจำลอง MA |
|       | $p$      | คือ อันดับจำกัดของแบบจำลอง AR    |
|       | $q$      | คือ อันดับจำกัดของแบบจำลอง MA    |

$e_t$  คือ ค่าของตัวแปรสุ่ม ณ เวลา  $t$

เรียกสมการ 3-28 นี้ว่า แบบจำลอง ARMA อันดับจำกัด  $p$  และ  $q$  หรือ ARMA ( $p,q$ )

สำหรับ ARMA(1,1) จากสมการ 3-28 สามารถเขียนได้เป็น

$$X_t = \phi_1 X_{t-1} + e_t - \theta_1 e_{t-1}$$

เมื่อกำหนดพารามิเตอร์  $\phi_1$  และ  $\theta_1$  นั้นสามารถได้จากสมการ 3-29 และ 3-30 ตามลำดับ (ชัยพันธุ์, 2529)

$$\phi_1 = \frac{\rho_2}{\rho_1} \quad \dots\dots(3-29)$$

และ

$$\rho_1 = \frac{(1 - \phi_1 \theta_1)(\phi_1 - \theta_1)}{1 + \theta_1^2 - 2\phi_1 \theta_1} \quad \dots\dots(3-30)$$

โดยค่า  $\theta_1$  สามารถหาได้จากวิธีการ trial & Error

และมีเงื่อนไขว่า  $|\phi_1| \leq 1$  และ  $|\theta_1| \leq 1$

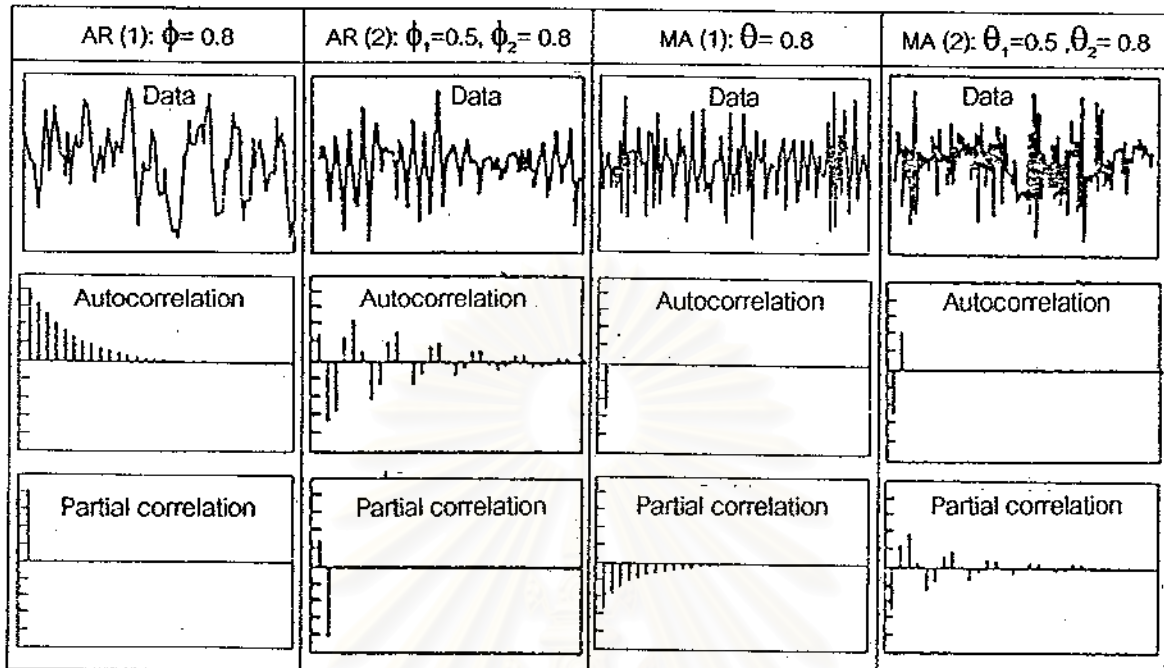
### 3.3.4 การเลือกชนิดและอันดับของแบบจำลองอนุกรมเวลา

การเลือกชนิดและอันดับของแบบจำลองอนุกรมเวลา สามารถพิจารณาได้จากลักษณะกราฟ correlogram และ partial correlogram และต้องอาศัยประสบการณ์หรือเปรียบเทียบกับตัวอย่างต่างๆ ที่ได้มีการศึกษาผ่านมา ซึ่งสามารถสรุปได้ดังตาราง 3-1

ตาราง 3-1 ลักษณะของฟังก์ชันความสัมพันธ์แบบ autocorrelation และ partial autocorrelation เพื่อใช้คัดเลือกแบบจำลองอนุกรมเวลา

โมเดล	ฟังก์ชันความสัมพันธ์แบบ autocorrelation	ฟังก์ชันความสัมพันธ์แบบ partial autocorrelation
AR(p)	มีค่าค่อยๆลดลง	มีค่าเป็นศูนย์หลังจากเวลา $p$
MA(q)	มีค่าเป็นศูนย์หลังจากเวลา $q$	มีค่าค่อยๆลดลง
ARMA(p,q)	มีค่าค่อยๆลดลง	มีค่าค่อยๆลดลง

หรือสามารถพิจารณาตัวอย่างได้ดังรูป 3-12



ที่มา ชัยพันธุ์, 2529

รูป 3-12 ตัวอย่างการพิจารณานิตและอันดับจำกัดของแบบจำลองอนุกรมเวลา  
โดยใช้ลักษณะกราฟ correlogram และ partial correlogram

### 3.4 แบบจำลองถดถอยเชิงเส้นแบบตัวแปรอิสระหลายตัว (Multiple Linear Regression Model, MLR)

MLR เป็นแบบจำลองที่สร้างความสัมพันธ์ระหว่างตัวแปรตาม  $Y$  กับตัวแปรอิสระ  $k$  ตัว ( $X_1, X_2, \dots, X_k$ ) ให้อยู่ในรูปเชิงเส้น ดังสมการ 3-31

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k \quad \dots\dots(3-31)$$

เมื่อ  $Y$  คือ ตัวแปรตาม  
 $X_1, X_2, \dots, X_k$  คือ ตัวแปรอิสระ  
 $\beta_0$  คือ ส่วนตัดแกน  $Y$  เมื่อ  $X_1, X_2, \dots, X_k = 0$   
 $\beta_1, \beta_2, \dots, \beta_k$  คือ สัมประสิทธิ์ความถดถอยของตัวแปรตาม  $Y$  ที่มีต่อตัวแปรอิสระ  $X_i$  ( $i=1, 2, \dots, k$ ) เมื่อตัวแปรอิสระอื่นมีค่าคงที่

สำหรับวิธีการหาค่าสัมประสิทธิ์ความถดถอยนั้นสามารถศึกษาได้จากตำราทางสถิติทั่วไป ในหัวข้อเรื่องการวิเคราะห์ความถดถอยเชิงเส้น, การวิเคราะห์ความสัมพันธ์ของตัวแปรมากกว่า 2 ตัว หรือใช้โปรแกรมสำเร็จรูปทางสถิติ เช่น SPSS (กัลยา, 2543) เป็นต้น

### 3.5 ตัวแปรสถิติที่ใช้วัดประสิทธิภาพของแบบจำลอง

วัตถุประสงค์หลักในการพยากรณ์ คือ การให้ผลการพยากรณ์มีความถูกต้องใกล้เคียงกับค่าจริง ในทางสถิติตัวแปรสถิติที่นิยมใช้วัดประสิทธิภาพและค่าความคลาดเคลื่อนในการคำนวณของแบบจำลอง มีดังนี้

#### 1) ดรรชนีวัดประสิทธิภาพ (Efficiency index, EI)

$$EI = \frac{\sum_{i=1}^N (Q_i - \bar{Q})^2 - \sum_{i=1}^N (Q_i - F_i)^2}{\sum_{i=1}^N (Q_i - \bar{Q})^2} = \frac{SST - SSE}{SST} \quad \text{.....(3-32)}$$

เมื่อ	SST	คือ ค่าความแปรปรวนทั้งหมดในตัวแปร Q
	SSE	คือ ผลรวมของผลต่างยกกำลังสองระหว่าง ตัวแปร Q และ F
	Q <sub>i</sub>	คือ ค่าจริงหรือค่าเป้าหมายของตัวแปร Q ณ เวลา i
	$\bar{Q}$	คือ ค่าเฉลี่ยของตัวแปร Q โดย $\bar{Q} = \frac{1}{N} \sum_{i=1}^N Q_i$
	F <sub>i</sub>	คือ ผลการคำนวณที่ได้ ณ เวลา i
	N	คือ จำนวนข้อมูลทั้งหมด

#### 2) ค่าเบี่ยงเบนมาตรฐานของค่าคลาดเคลื่อน (Standard error, S<sub>e</sub>) หรือ ค่ารากที่สองของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (Root mean square error, RMSE)

$$S_e = RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (Q_i - F_i)^2} \quad \text{.....(3-33)}$$



3) ค่าคลาดเคลื่อนเฉลี่ยสัมบูรณ์ (Mean absolute deviation, MAD)

$$MAD = \frac{1}{N} \sum_{i=1}^N |Q_i - F_i| \quad \dots\dots(3-34)$$

4) เปอร์เซนต์ค่าคลาดเคลื่อนเฉลี่ยสัมบูรณ์ (%Mean absolute deviation, %MAD)

$$\%MAD = \frac{MAD}{Q} \times 100 \quad \dots\dots(3-35)$$



สถาบันวิทยบริการ  
จุฬาลงกรณ์มหาวิทยาลัย

## บทที่ 4

### พื้นที่ศึกษาและการวิเคราะห์ข้อมูล

#### 4.1 สภาพพื้นที่ศึกษา


##### 4.1.1 สภาพภูมิประเทศและระบบลุ่มน้ำ

ลุ่มน้ำปราจีนบุรีอยู่ทางตะวันออกของประเทศไทย มีพื้นที่รับน้ำฝนประมาณ 9,821 ตร.กม. คิดเป็น 1.9% ของพื้นที่ทั้งประเทศ ครอบคลุมพื้นที่ 5 จังหวัด ได้แก่ พื้นที่ของจังหวัดปราจีนบุรี สระแก้ว จันทบุรี จังหวัดฉะเชิงเทรา และจังหวัดนครนายกประมาณร้อยละ 47.90, 41.78, 5.33, 3.45 และ 1.54 ตามลำดับ ลักษณะลุ่มน้ำวางตัวตามแนวทิศตะวันออก-ตก อยู่ระหว่างเส้นรุ้งที่  $13^{\circ}02'$  และ  $14^{\circ}38'$  (เหนือ) และอยู่ระหว่างเส้นแวงที่  $101^{\circ}10'$  และ  $102^{\circ}33'$  (ตะวันออก) ทางเหนือของลุ่มน้ำเริ่มจากเขตเทือกเขาพนมดงเร็ดติดกับลุ่มน้ำแม่น้ำมูล ทางทิศตะวันออกติดกับลุ่มน้ำโตนเลสาป ส่วนทิศใต้และทิศตะวันตกติดต่อกับลุ่มน้ำบางปะกง ดังรูป 4-1


บริเวณตอนเหนือของลุ่มน้ำเป็นเทือกเขาสูง ส่วนตอนกลางและตอนใต้เป็นที่ราบสูงและที่ราบ แม่น้ำสายหลักในลุ่มน้ำได้แก่ แม่น้ำปราจีนบุรีซึ่งเป็นแม่น้ำสาขาที่สำคัญของแม่น้ำบางปะกง ไหลจากทิศตะวันออกไปทิศตะวันตก ซึ่งเกิดจากการไหลมาบรรจบกันของแม่น้ำสาขาใหญ่ 2 สาย คือ แม่น้ำหनुมานซึ่งเป็นต้นกำเนิดอยู่ทางเทือกเขาทางตอนเหนือของจังหวัดปราจีนบุรี และแม่น้ำพระปรงที่ไหลมาจากที่สูงทางทิศตะวันออกเฉียงใต้ของจังหวัดสระแก้ว โดยจะไหลมาบรรจบกันบริเวณอำเภอท่าวุ้งบุรี จังหวัดปราจีนบุรี (สถานีวัดน้ำท่า KGT.3) และไหลไปบรรจบกับแม่น้ำนครนายกบริเวณอำเภอบางน้ำเปรี้ยวจังหวัดฉะเชิงเทรา กลายเป็นแม่น้ำบางปะกง และไหลลงสู่อ่าวไทยต่อไป ความยาวของแม่น้ำปราจีนบุรีประมาณ 105 กม.

ลำน้ำสาขาในแม่น้ำพระปรงได้แก่ คลองประตอง คลองพระปรง คลองพระสทิง และห้วยไคร้ ส่วนลำน้ำสาขาที่สำคัญของแม่น้ำหनुมานได้แก่ ห้วยโสมง และลำพระยาธาร และสาขาย่อยของลำพระยาธารได้แก่ ห้วยยาง ห้วยชัน ห้วยไสน้อย และห้วยไสใหญ่ และทางด้านท้ายน้ำของแม่น้ำปราจีนบุรี มีลำน้ำสาขาที่สำคัญคือ คลองประจันตคาม ห้วยเกษียร คลองหนองแก้ว และคลองยาง

ในการศึกษาครั้งนี้ได้ทำการแบ่งพื้นที่ศึกษาออกเป็นพื้นที่ย่อย 6 พื้นที่ ที่มีลักษณะทางกายภาพที่แตกต่างกัน (รูป 4-1) โดยให้สถานีวัดน้ำท่าที่ตั้งอยู่ในพื้นที่เป็นเกณฑ์ในการแบ่ง และได้แสดงแผนผังระบบลุ่มน้ำที่ทำการศึกษา ดังรูป 4-2 เพื่อพยากรณ์ปริมาณน้ำท่าที่สถานีวัดน้ำท่า



รูป 4-1 ลักษณะภูมิประเทศของพื้นที่ศึกษาและลุ่มน้ำย่อย



รูป 4-2 แผนผังระบบส่งน้ำที่ทำการศึกษา

ต่างๆ อันได้แก่ สถานีวัดน้ำท่า KGT.3 ซึ่งเป็นสถานีที่ใช้วัดปริมาณน้ำท่าที่ไหลมาบรรจบกัน บริเวณอำเภอekinบุรี จังหวัดปราจีนบุรี โดยมีพื้นที่รับน้ำฝน 7,502 ตร.กม. สถานีวัดน้ำท่า 150401, KGT.14, KGT.15A, KGT.12 และ KGT.10 ซึ่งตั้งอยู่ทางด้านเหนือของสถานีวัดน้ำท่า KGT.3 โดยสถานีเหล่านี้ใช้วัดปริมาณน้ำท่าที่ไหลออกจากลุ่มน้ำย่อยต่างๆ อันได้แก่ ลุ่มน้ำไดน้อย-ไดใหญ่ ลำพระยาธาร ห้วยโสมง พระปรองตอนบน และคลองพระสึง ตามลำดับ สำหรับลักษณะรูปตัดตามยาวของลำน้ำในแต่ละลุ่มน้ำย่อย และรูปตัดตามขวางของลำน้ำที่แต่ละสถานีวัดน้ำท่า ได้แสดงรายละเอียดไว้ในภาคผนวก ก

#### 4.1.2 สภาพภูมิอากาศ

ลุ่มน้ำปราจีนบุรีอยู่ภายใต้อิทธิพลของลมมรสุม 2 ชนิด คือ ลมมรสุมตะวันตกเฉียงใต้และลมมรสุมตะวันออกเฉียงเหนือ ก่อให้เกิดฤดูกาล 3 ฤดูคือ ฤดูฝนเริ่มตั้งแต่กลางเดือนพฤษภาคมถึงกลางเดือนพฤศจิกายน ฤดูหนาวตั้งแต่กลางเดือนพฤศจิกายนถึงกลางเดือนกุมภาพันธ์ และฤดูร้อนจะเริ่มตั้งแต่กลางเดือนกุมภาพันธ์ถึงกลางเดือนพฤษภาคม แต่ในการศึกษารั้งนี้จะแบ่งฤดูออกเป็นแค่ 2 ฤดู คือ ฤดูฝน ซึ่งเริ่มตั้งแต่เดือนพฤษภาคม-เดือนพฤศจิกายน และฤดูแล้ง ตั้งแต่เดือนธันวาคม-เดือนเมษายน เพื่ออำนวยความสะดวกและการนำไปใช้

#### 4.1.3 สภาพ อุต-อุตสาหกรรม

##### 4.1.3.1 อุตนิคมวิทยา

ข้อมูลอุตุนิยมวิทยาหรือข้อมูลภูมิอากาศในลุ่มน้ำปราจีนบุรี จากสถานีตรวจวัดภูมิอากาศของกรมอุตุนิยมวิทยา 2 สถานี ได้แก่ สถานีอำเภอเมืองปราจีนบุรี และสถานีอำเภอekinบุรี สามารถสรุปช่วงพิสัยของค่าเฉลี่ยรายปี จำนวน 34 ปี (พ.ศ.2506-2539) ของตัวแปรภูมิอากาศที่สำคัญได้ดังตาราง 4-1

##### 4.1.3.2 ปริมาณน้ำฝน


เมื่อพิจารณาการแพร่กระจายของปริมาณฝนรายเดือนเฉลี่ยที่ได้จากสถานีวัดน้ำฝนจำนวน 36 สถานี ในพื้นที่ลุ่มน้ำ (โครงการศึกษาเพื่อจัดทำแผนหลักการพัฒนาและจัดการทรัพยากรน้ำภาคตะวันออกเฉียงเหนือ กรมชลประทาน, 2543) แสดงได้ดังรูป 4-3 ซึ่งจะพบว่าปริมาณฝนใน

ตาราง 4-1 ลักษณะพิสัยของค่าเฉลี่ยรายปีของตัวแปรภูมิอากาศที่สำคัญ ในลุ่มน้ำปราจีนบุรี


ตัวแปรภูมิอากาศ	ช่วงพิสัยของค่าเฉลี่ยรายปี
อุณหภูมิ (องศาเซลเซียส)	27.7-28.2
ความชื้นสัมพัทธ์ (%)	72.0-77.0
ความเร็วลมเฉลี่ย (น็อต)	1.8-1.9
ปริมาณเมฆปกคลุม (0-10 หน่วย)	6.0-6.1
ปริมาณการระเหยจากผิวดิน (มม.)	1,654-1,748

ที่มา: โครงการศึกษาเพื่อจัดทำแผนหลักการพัฒนาและจัดการทรัพยากรน้ำภาคตะวันออกเฉียงเหนือตอนบน, 2543

ฤดูฝน (พ.ค.-พ.ย) มีค่าประมาณ 1450 มม. และฤดูแล้ง (ธ.ค.-เม.ย) มีค่าประมาณ 180 มม. ซึ่งมีค่าแตกต่างกันอย่างชัดเจน แสดงให้เห็นว่าในช่วงฤดูฝน จะมีฝนตกชุกมากในพื้นที่ซึ่งมักทำให้เกิดน้ำท่วมบ่อยครั้ง และในทางกลับกันในช่วงฤดูแล้งมีปริมาณฝนตกที่เบาบางมากจนอาจทำให้เกิดการขาดแคลนน้ำได้ นอกจากนี้เมื่อได้พิจารณาแผนที่แสดงชั้นปริมาณน้ำฝนรายปีเฉลี่ยในรูป 4-4 พอสรุปได้ว่า ลุ่มน้ำปราจีนบุรีมีปริมาณน้ำฝนรายปีเฉลี่ยมีค่าผันแปรตั้งแต่ 1300 – 2500 มม. โดยจะมีฝนชุกและกระจายตัวอย่างหนาแน่นในทางตอนเหนือของพื้นที่ ในบริเวณลุ่มน้ำใสน้อย-ใสใหญ่ เนื่องจากเป็นที่อกเขาสูง โดยมีค่าปริมาณน้ำฝนรายปีเฉลี่ยประมาณ 1500-2500 มม. ส่วนทางตอนกลางและตอนใต้ของพื้นที่นั้น มีค่าปริมาณน้ำฝนรายปีเฉลี่ยประมาณ 1300-1700 มม. และมีการกระจายของฝนตัวในบริเวณกว้าง



รูป 4-3 การแพร่กระจายของปริมาณน้ำฝนรายเดือนเฉลี่ย ในลุ่มน้ำปราจีนบุรี



ที่มา: โครงการศึกษาเพื่อจัดทำแผนหลักการพัฒนาและจัดการทรัพยากรน้ำภาคตะวันออกเฉียงเหนือ กรมชลประทาน, 2543

รูป 4-4 แผนที่แสดงเส้นชั้นปริมาณฝนรายปีเฉลี่ยในบริเวณพื้นที่ศึกษา

#### 4.1.3.3 ปริมาณน้ำท่า

สภาพน้ำท่าในลุ่มน้ำปราจีนบุรีจากแผนที่แสดงชั้นปริมาณน้ำท่าเฉลี่ยต่อหน่วยพื้นที่รับน้ำฝน ดังรูป 4-5 พบว่ามีค่าผันแปรอยู่ระหว่าง 10-45 ลิตร/วินาที/ตร.กม โดยทางตอนเหนือของพื้นที่จะมีค่าชั้นปริมาณน้ำท่าเฉลี่ยต่อหน่วยพื้นที่รับน้ำฝนสูงคือ 20-45 ลิตร/วินาที/ตร.กม เนื่องจากมีฝนตกชุก ทางตอนกลางของพื้นที่จะมีค่าประมาณ 10-15 ลิตร/วินาที/ตร.กม ส่วนทางตอนล่างของพื้นที่นั้นจะมีค่าประมาณ 15-35 ลิตร/วินาที/ตร.กม ซึ่งสอดคล้องกับการกระจายตัวและปริมาณฝนรายปีเฉลี่ยที่ตกในพื้นที่ (รูป 4-4) โดยปริมาณน้ำท่าเฉลี่ยรายปีและอัตราการไหลเฉลี่ยรายวันจำนวน 27 ปี (พ.ศ.2513-พ.ศ.2526 และ พ.ศ.2529-2541) ในพื้นที่ศึกษาแยกตามสถานีวัดน้ำท่าในแต่ละลุ่มน้ำย่อยที่ใช้ในการศึกษา จำนวน 6 สถานี ดังตาราง 4-2 และ 4-3


ตาราง 4-2 ปริมาณน้ำท่าเฉลี่ยรายปีของสถานีวัดน้ำท่าในพื้นที่ศึกษา

สถานีวัดน้ำท่า	พื้นที่รับน้ำ (ตร.กม.)	ปริมาณน้ำท่าเฉลี่ยรายปี				
		ฤดูฝน		ฤดูแล้ง		รวมทั้งปี
		(ล้าน ลบ.ม.)	%	(ล้าน ลบ.ม.)	%	
KGT.3	7,502	3,136	91.4	295	8.6	3,431
150401	636	530	93.5	37	6.5	567
KGT.14	366	130	94.2	8	5.8	138
KGT.15A	530	343	92.7	27	7.3	370
KGT.12	1,540	533	91.4	50	8.6	583
KGT.10	2,523	734	91.5	68	8.5	802

ตาราง 4-3 อัตราการไหลน้ำท่าเฉลี่ยรายวันของสถานีวัดน้ำท่าในพื้นที่ศึกษา

สถานีวัดน้ำท่า	อัตราการไหลน้ำท่าเฉลี่ยรายวัน (ลบ.ม./วินาที)							
	ฤดูฝน				ฤดูแล้ง			
	เฉลี่ย	เบี่ยงเบน	สูงสุด	ต่ำสุด	เฉลี่ย	เบี่ยงเบน	สูงสุด	ต่ำสุด
KGT.3	117.30	194.30	1,754.00	0.00	6.77	8.30	111.90	0.00
150401	27.73	34.94	548.00	0.00	0.96	1.10	12.50	0.00
KGT.14	7.19	13.95	286.90	0.00	0.25	0.29	3.89	0.00
KGT.15A	19.86	30.01	492.70	0.00	0.65	1.00	13.60	0.00
KGT.12	32.39	45.46	480.50	0.00	1.27	1.71	15.15	0.00
KGT.10	44.41	67.18	960.00	0.00	1.94	3.20	101.60	0.00





ที่มา: โครงการศึกษาเพื่อจัดทำแผนการจัดการพัฒนาและจัดการทรัพยากรน้ำภาคตะวันออก กรมชลประทาน, 25-13

รูป 4-5 แผนที่แสดงเส้นชั้นปริมาณน้ำท่ารายปีเฉลี่ยต่อหน่วยพื้นที่รับน้ำฝนในบริเวณพื้นที่ศึกษา

จากตาราง 4-2 เมื่อนำปริมาณน้ำท่ารวมทั้งปีที่ได้จากสถานีวัดน้ำท่าในแต่ละลุ่มน้ำย่อยมาเปรียบเทียบกับปริมาณน้ำท่าที่สถานี KGT.3 จะเห็นได้ว่าปริมาณน้ำท่าที่สถานี KGT.3 นั้นส่วนใหญ่มาจากลุ่มน้ำคลองพระสทิง (KGT.10) รองลงมาคือ พระปรองตอนบน (KGT.12) ไหลน้อย-ไหลใหญ่ (150401) ห้วยโลม่ง (KGT.15A) และลำพระยาธาร (KGT.14) ซึ่งคิดเป็น 23.4%, 17.0%, 16.5%, 10.8% และ 4.0% ตามลำดับ สำหรับปริมาณอีกประมาณ 28% นั้นมาจากลุ่มน้ำหุมนานและพระปรองสายหลัก (พื้นที่ย่อย 6 รูป 4-1) จากตาราง 4-3 จะเห็นได้ว่าอัตราการไหลเฉลี่ยรายวันของสถานี KGT.3 ในช่วงฤดูฝนมีค่าค่อนข้างสูงทั้งนี้เนื่องจากสถานี KGT.3 เป็นจุดรวมของแม่น้ำหลักในลุ่มน้ำปราจีนบุรีคือ แม่น้ำหุมนานและแม่น้ำพระปรอง ทำให้น้ำที่ตัดลำน้ำที่จุดนี้มีขนาดใหญ่ (รูป ก-5) นอกจากนี้ยังจะเห็นได้ว่าอัตราการไหลรายวันของสถานีวัดน้ำท่าต่างๆ มีความผันผวนมาก (พิจารณาจากค่าเบี่ยงเบน) เมื่อเทียบกับอัตราการไหลเฉลี่ยรายวันทั้งในฤดูฝนและฤดูแล้ง ทั้งนี้อาจสืบเนื่องมาจากลักษณะภูมิประเทศ หรือในแต่ละลุ่มน้ำนั้นยังมีลุ่มน้ำย่อยๆ ประกอบกันอีกหลายลุ่มน้ำ


## 4.2 การวิเคราะห์ข้อมูล

### 4.2.1 ข้อมูลที่ใช้ในการศึกษา

ข้อมูลที่ใช้ในการศึกษาค้างนี้ประกอบด้วยข้อมูลปริมาณน้ำฝนรายวันและข้อมูลอัตราการไหลน้ำท่ารายวัน เนื่องจากในพื้นที่ลุ่มน้ำที่ใช้ในการศึกษามีสถานีวัดน้ำฝนและน้ำท่าอยู่เป็นจำนวนมาก ดังรูป 4-6 ดังนั้นในการเลือกสถานีวัดน้ำฝนและน้ำท่าที่จะนำข้อมูลมาใช้ในการศึกษาค้างนี้ จะคัดเลือกจากความสมบูรณ์ในการจดบันทึกของข้อมูล ความยาวของข้อมูล และการกระจายตัวของสถานีน้ำฝนที่ต้องครอบคลุมทั่วทั้งพื้นที่ศึกษา

จากการคัดเลือกได้จำนวนสถานีวัดน้ำฝนในพื้นที่ศึกษาและพื้นที่ใกล้เคียงจำนวน 11 สถานีและจำนวนสถานีวัดน้ำท่าในพื้นที่จำนวน 6 สถานี ซึ่งสามารถสรุปช่วงของข้อมูลและแหล่งที่มาของสถานีต่างๆที่ใช้ในการศึกษาได้ดังตารางที่ 4-4 และ 4-5

จากตาราง 4-4 และ 4-5 จะเห็นได้ว่าช่วงของข้อมูลที่รวบรวมมาได้มีความยาวไม่เท่ากัน ทั้งนี้สืบเนื่องมาจากการเริ่มวัดข้อมูลที่แตกต่างกัน และการเก็บรวบรวมข้อมูลแต่ละส่วนของแต่ละหน่วยงานที่ต่างกัน นอกจากนี้จะเห็นได้ว่ามีข้อมูลบางปีขาดหายไป สาเหตุเกิดเนื่องมาจากเครื่องมือที่ใช้วัดมีความชำรุดเสียหาย ดังนั้นในการศึกษาค้างนี้ จึงได้เลือกช่วงข้อมูลที่มีการเก็บรวบรวมข้อมูลอย่างสมบูรณ์และเลือกช่วงความยาวของข้อมูลในแต่ละสถานีให้มีความยาวเท่ากันคือ ช่วงข้อมูลปี พ.ศ.2513-พ.ศ.2526 และ พ.ศ.2529-2541 จำนวน 27 ปี เพื่อใช้ในการศึกษาต่อไป



ที่มา: โครงการศึกษาข้อมูลและศักยภาพการพัฒนาลุ่มน้ำปราจีนบุรี, 2537

รูป 4-6 ที่ตั้งสถานีวัดน้ำฝนและสถานีวัดน้ำท่าในพื้นที่ศึกษาและพื้นที่ใกล้เคียง

ตาราง 4-4 ช่วงข้อมูลและแหล่งที่มาของสถานีวัดน้ำฝนที่ใช้ในการศึกษา

ลำดับ	หมายเลขสถานี	ชื่อสถานี	ประเภท	ช่วงข้อมูล	ที่มา	หมายเหตุ
1	44043	อ.กบินทร์บุรี จ.ปราจีนบุรี	M	2495-2543	กรมชลประทาน	- ขาดข้อมูล ปี 2527
2	44181	ลำพระยาธาร จ.ปราจีนบุรี	A	2510-2543	กรมชลประทาน	
3	44191	ห้วยโสมง จ.ปราจีนบุรี	A	2511-2543	กรมชลประทาน	
4	74022	อ.วัฒนานคร จ.สระแก้ว	M	2495-2543	กรมชลประทาน	
5	74071	ลำพระสทิง จ.สระแก้ว	A	2510-2543	กรมชลประทาน	
6	74081	บ้านเคียง อ.เมือง จ.สระแก้ว	A	2513-2543	กรมชลประทาน	
7	25142	บ้านใหม่สามใจ จ.นครราชสีมา	M	2496-2543	กรมชลประทาน	
8	25152	อ.ปักธงชัย จ.นครราชสีมา	M	2498-2543	กรมชลประทาน	
9	03231	คลองสียัด จ.ฉะเชิงเทรา	A	2510-2543	กรมชลประทาน	
10	06082	อ.โป่งน้ำร้อน จ.จันทบุรี	M	2499-2543	กรมชลประทาน	
11	150401	บ้านสะพานหิน อ.นาดี จ.ปราจีนบุรี	M	2507-2542	กรมพัฒนาและ ส่งเสริมพลังงาน	

หมายเหตุ: M = ไม่อัตโนมัติ A = อัตโนมัติ

ตาราง 4-5 ช่วงข้อมูลและแหล่งที่มาของสถานีวัดน้ำท่าที่ใช้ในการศึกษา

ลำดับ	หมายเลขสถานี	ชื่อสถานี	ประเภท	ช่วงข้อมูล	ที่มา	หมายเหตุ
1	KGT.3	อ.กบินทร์บุรี จ.ปราจีนบุรี	M	2508-2542	กรมชลประทาน	- ขาดข้อมูล ปี 2528
2	KGT.10	บ้านวังเคียง จ.สระแก้ว	A	2509-2542	กรมชลประทาน	
3	KGT.12	บ้านเคียง จ.สระแก้ว	A	2509-2542	กรมชลประทาน	
4	KGT.14	บ้านทุ่งแฝก จ.ปราจีนบุรี	A	2509-2542	กรมชลประทาน	
5	KGT.15A	บ้านเคียงดินสอ จ.ปราจีนบุรี	A	2511-2541	กรมชลประทาน	
6	150401	บ้านสะพานหิน อ.นาดี จ. ปราจีนบุรี	A	2507-2541	กรมพัฒนาและ ส่งเสริมพลังงาน	

หมายเหตุ: M = ไม่อัตโนมัติ A = อัตโนมัติ

#### 4.2.2 การประมาณค่าปริมาณน้ำฝนรายวันที่ขาดหายไป

เมื่อนำข้อมูลปริมาณน้ำฝนรายวันและอัตราการไหลรายวันของสถานีต่างๆที่ใช้ในการศึกษา มาตรวจสอบอย่างละเอียดตามช่วงเวลาที่ได้คัดเลือกไว้ในหัวข้อ 4.2.1 พบว่า มีข้อมูลปริมาณน้ำฝนรายวันของสถานี 44181, 44191, 74071 และ 74081 บางช่วงเวลาขาดหายไป ดังนั้นจึงจำเป็นต้องประมาณค่าปริมาณน้ำฝนรายวันที่ขาดหายไป เพื่อเติมข้อมูลให้มีความสมบูรณ์และต่อเนื่องมากที่สุด ก่อนที่จะนำไปใช้ต่อไป

ในการศึกษาครั้งนี้ได้เลือกใช้วิธี Inverse Distance Method เพื่อใช้สำหรับประมาณค่าปริมาณน้ำฝนรายวันของแต่ละสถานีที่ขาดหายไป เนื่องจากเป็นวิธีที่ได้รับการยอมรับว่าให้ผลเป็นที่น่าเชื่อถือและมีความแม่นยำมากที่สุดเมื่อเทียบกับวิธีอื่นๆ เช่น วิธีค่าเฉลี่ยแบบคณิตศาสตร์ หรือ วิธี normal ratio เป็นต้น (Singh, 1992 และ Singh, 1989) โดยวิธีนี้จะให้ปริมาณน้ำฝนรายวันที่จะประมาณขึ้นนั้น ขึ้นอยู่กับปริมาณน้ำฝนรายวันของสถานีต่างๆ ที่อยู่ใกล้เคียงในวันเดียวกัน และระยะทางระหว่างสถานีที่อยู่ใกล้เคียง กับสถานีที่จะทำการประมาณค่าข้อมูลที่หายไป ดังสมการ 4-1 แต่อย่างไรก็ตามวิธีนี้ไม่เหมาะที่จะนำไปใช้ในพื้นที่ที่เป็นภูเขา

$$r_x = W_1r_1 + W_2r_2 + \dots + W_nr_n \quad i = 1, 2, \dots, n$$

และ

$$W_i = \frac{1/D_i^2}{\sum_{i=1}^n (1/D_i^2)} \quad \dots\dots(4-1)$$

- เมื่อ
- $r_x$  คือ ปริมาณน้ำฝนที่จะประมาณค่า
  - $r_i$  คือ ปริมาณน้ำฝนของสถานีใกล้เคียง
  - $W_i$  คือ ค่าถ่วงน้ำหนัก (weight factor) ของแต่ละสถานีใกล้เคียง
  - $D_i$  คือ ระยะทางระหว่างสถานีต่างๆ ที่อยู่ใกล้เคียง กับสถานีที่ทำการประมาณค่าข้อมูลที่หายไป
  - $n$  คือ จำนวนสถานีที่อยู่ใกล้เคียงที่นำมาใช้ในการประมาณค่า โดยทั่วไป  $n$  จะมีค่าไม่เกิน 5 (Singh, 1992)

การเลือกสถานีที่อยู่ใกล้เคียงนั้นจะพิจารณาจากสภาพภูมิประเทศที่มีความคล้ายคลึงกันของที่ตั้งสถานี ระยะทางระหว่างสถานี และการวิเคราะห์ความสัมพันธ์ (correlation) ของปริมาณน้ำฝนรายวันระหว่างแต่ละสถานี บนสมมุติฐานที่ว่าปริมาณน้ำฝนของสถานีใกล้เคียงกันควรจะมีความสัมพันธ์ที่ต่ำกว่าสถานีที่อยู่ไกลออกไป และได้แสดงผลการวิเคราะห์ไว้ในตาราง ข-1 ซึ่งสามารถแบ่งกลุ่มสถานีวัดน้ำฝนที่จะเติมข้อมูลที่ขาดหายไปได้ออกเป็น 2 กลุ่ม โดยเมื่อพิจารณา ระยะทางระหว่างสถานีในแต่ละกลุ่ม และหาค่า weight factor แสดงได้ดังต่อไปนี้

### กลุ่มที่ 1

ระยะทางระหว่างสถานี (D, กม.<sup>2</sup>)

สถานี	44191	44132	44181	150401
44191	0	9.28	16.28	12.25
44132	9.28	0	14.42	4.50
44181	16.28	14.42	0	16.02
150401	12.25	4.50	16.02	0
$\Sigma(1/D_i^2)$	0.022	0.066	0.012	0.060

Weight factor

สถานี	44191	44132	44181	150401
44191	0	0.176	0.302	0.111
44132	0.527	0	0.385	0.824
44181	0.171	0.073	0	0.0650
150401	0.302	0.750	0.312	0
รวม	1.00	1.00	1.00	1.00

### กลุ่มที่ 2

ระยะทางระหว่างสถานี (D, กม.<sup>2</sup>)

สถานี	74081	74092	74071	74012
74081	0	4.70	16.80	16.52
74092	4.70	0	12.25	13.00
74071	16.80	12.25	0	3.25
74012	16.52	13.00	3.25	0
$\Sigma(1/D_i^2)$	0.052	0.058	0.105	0.104

Weight factor

สถานี	74081	74092	74071	74012
74081	0	0.783	0.034	0.035
74092	0.863	0	0.064	0.057
74071	0.068	0.115	0	0.908
74012	0.070	0.102	0.903	0
รวม	1.00	1.00	1.00	1.00

ตัวอย่างการเติมข้อมูลปริมาณฝนรายวันที่ขาดหายไป ณ สถานีวัด 44191 ในวันที่ 15 กันยายน 2539 เมื่อสถานีที่อยู่ใกล้เคียงวัดข้อมูลได้ค่าดังนี้ สถานี 44132 = 1.50 มม. สถานี 44181 = 1.40 มม. และ สถานี 150401 = 2.30 มม. โดยใช้สมการ 4-1 แสดงได้ดังนี้


$$r_x = (0.527 \times 1.50) + (0.171 \times 1.40) + (0.302 \times 2.30) = 1.72 \text{ มม.}$$

โดยผลการเติมของมูลปริมาณน้ำฝนรายวันที่ขาดหายไปของสถานีต่างๆ แสดงไว้ในตาราง ข-2

#### 4.2.3 การตรวจสอบความน่าเชื่อถือของข้อมูล


การตรวจสอบความน่าเชื่อถือของข้อมูล (consistency) นั้น มีไว้เพื่อพิจารณาความมั่นคงของข้อมูลว่าข้อมูลมีทิศทางไปในทางเดียวกันหรือไม่ เนื่องจากในระหว่างการเก็บข้อมูลอาจมีการเปลี่ยนแปลงที่ตั้งของเครื่องวัด หรือเปลี่ยนแปลงวิธีการเก็บข้อมูล โดยวิธีที่นิยมใช้กันทั่วไปคือวิธี Double mass curve ซึ่งเป็นการเปรียบเทียบค่าสะสมของปริมาณน้ำฝนหรือน้ำท่ารายปีของสถานีที่จะตรวจสอบความน่าเชื่อถือ กับค่าสะสมรายปีเฉลี่ยของสถานีต่างๆ ที่ตั้งอยู่รอบๆ สำหรับ

การศึกษาค้นคว้านี้ได้ใช้ค่าสะสมของปริมาณน้ำฝนรายปีเฉลี่ย 10 สถานี และใช้ค่าสะสมของปริมาณน้ำท่ารายปีเฉลี่ย 5 สถานี เพื่อใช้ตรวจสอบความน่าเชื่อถือของข้อมูลน้ำฝนและน้ำท่า ของสถานีต่างๆที่ใช้ในการศึกษา โดยผลการทำ Double mass curve แสดงดังรูป 4-7 และ 4-8



รูป 4-7 ความสัมพันธ์ระหว่างฝนสะสมรายปีสถานีต่างๆ กับฝนสะสมรายปีเฉลี่ย 10 สถานี

จากรูป 4-7 พบว่าข้อมูลส่วนใหญ่มีความน่าเชื่อถือ และมีความมั่นคงไปในทางเดียวกัน มีเพียงบางสถานีที่พอปรากฏความไม่มั่นคงไปในทางเดียวกัน แต่ก็ไม่ชัดเจนมากนัก เช่น สถานี 74022 ซึ่งมีจุดหักการเปลี่ยนแปลงความสัมพันธ์ที่ประมาณปี 2519 และในปี 2529 ซึ่งในความเป็นจริงความสัมพันธ์น่าจะไปในทางเดียวกันกับสถานีใกล้เคียงอันได้แก่ สถานี 74081 และ 74071



รูป 4-8 ความสัมพันธ์ระหว่างน้ำท่าสะสมรายปีสถานีต่างๆ กับน้ำท่าสะสมรายปีเฉลี่ย 5 สถานี

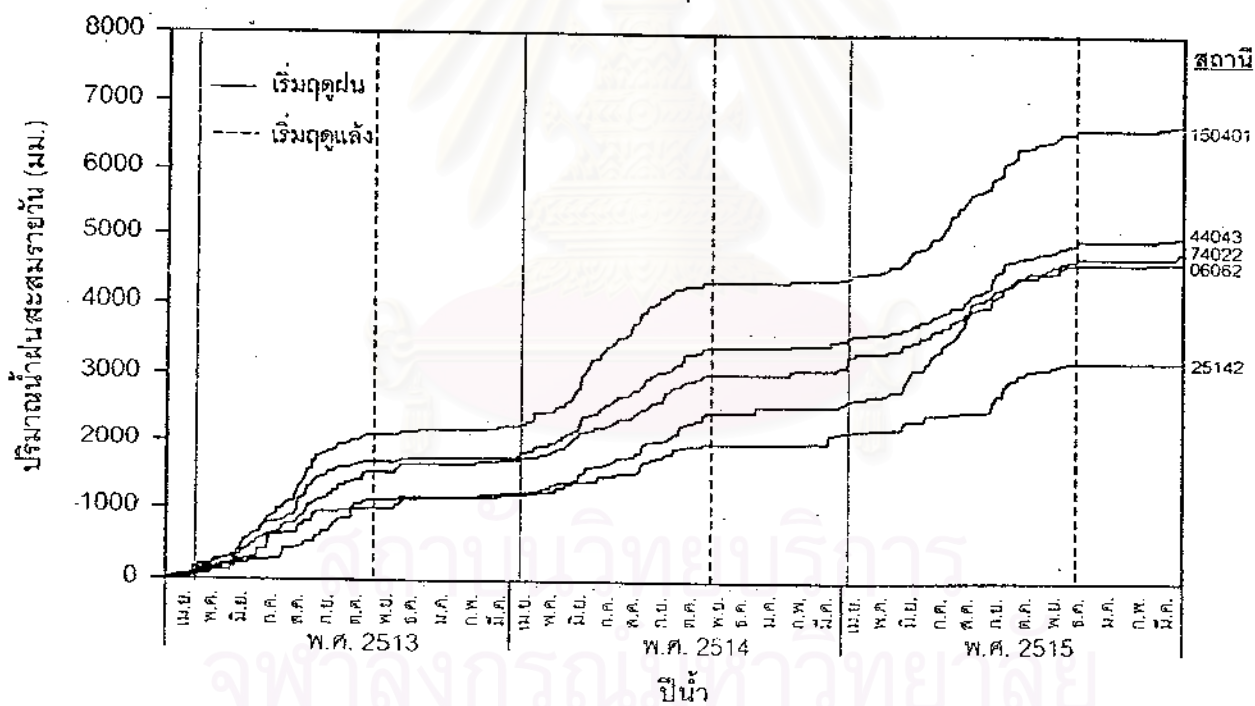
จากรูป 4-8 ความสัมพันธ์ระหว่างน้ำท่าสะสมรายปีสถานีต่างๆ กับน้ำท่าสะสมรายปีเฉลี่ย 5 สถานี มีความมั่นคงไปในทางเดียวกันดี แสดงให้เห็นถึงข้อมูลมีความน่าเชื่อถือ มีเพียงสถานี KGT.12 ที่มีความสัมพันธ์เปลี่ยนแปลงบ้างเล็กน้อย แต่ก็ไม่ชัดเจนมากนัก ในปี 2527 แต่ทั้งนี้การตรวจสอบข้อมูลน้ำท่าด้วยวิธี Double mass curve เป็นเพียงการประยุกต์ใช้เพื่อตรวจสอบข้อมูลเบื้องต้นเท่านั้น



4.2.4 การแบ่งช่วงข้อมูลสำหรับฤดูฝน-ฤดูแล้ง

จากที่ได้กล่าวไว้ในขอบข่ายการศึกษาว่า การศึกษาคั้งนี้จะจัดสร้างแบบจำลองการพยากรณ์อัตราการไหลน้ำท่ารายวันแยกออกเป็น 2 แบบจำลอง คือ แบบจำลองที่ใช้ในฤดูฝนกับฤดูแล้ง ทั้งนี้เนื่องจากปริมาณน้ำท่าของทั้งสองฤดูมีความแตกต่างกันอย่างเด่นชัด ดังนั้นการแบ่งช่วงข้อมูลที่ชัดเจนเพื่อใช้ในการพัฒนาแบบจำลองจำลองการพยากรณ์สำหรับฤดูฝนและฤดูแล้งนั้นจึงมีความสำคัญอย่างยิ่ง เพื่อประสิทธิภาพในการพยากรณ์ของแบบจำลองทั้งสอง และความสะดวกในการนำไปใช้งาน

ในการแบ่งช่วงข้อมูลสำหรับฤดูฝนและฤดูแล้งนั้น จะพิจารณาจากสภาพภูมิอากาศและการทำโค้งปริมาณน้ำฝนสะสมรายวันของสถานีวัดน้ำฝนแต่ละสถานี เพื่อพิจารณาวันที่ฝนเริ่มตกเร็วที่สุด (โค้งปริมาณน้ำฝนสะสมรายวันจะเริ่มชันขึ้น) และวันที่ฝนหยุดตกช้าสุด (โค้งปริมาณน้ำฝนสะสมรายวันเริ่มคงที่) ในแต่ละปีของข้อมูลที่ใช้ในการศึกษา ดังตัวอย่างในรูป 4-9 ทั้งนี้เนื่องจากฤดูฝนในแต่ละปี ในแต่ละพื้นที่ อาจเริ่มหรือหยุดตกไม่พร้อมกัน



รูป 4-9 ตัวอย่างโค้งปริมาณน้ำฝนสะสมรายวันของสถานีวัดน้ำฝนที่ใช้ในการศึกษา

จากการศึกษาพบว่า ฝนส่วนใหญ่จะเริ่มตกในช่วงต้นเดือนพฤษภาคมและหยุดตกในช่วงกลางเดือนพฤศจิกายน แต่มีบ้างบางปีที่จะเริ่มตกตั้งแต่กลางเดือนเมษายนและหยุดตกต้นเดือนธันวาคม (ตาราง ข-3) ดังนั้นในการศึกษาคั้งนี้จึงได้พยายามแบ่งช่วงข้อมูลให้ครอบคลุมช่วงที่ฝนตกมากที่สุดและสอดคล้องกับสภาพภูมิอากาศในพื้นที่ศึกษา คือ จะใช้ช่วงข้อมูลตั้งแต่เดือน

พฤษภาคม-พฤศจิกายน ให้เป็นข้อมูลสำหรับใช้ในช่วงฤดูฝน และใช้ข้อมูลตั้งแต่เดือนธันวาคม-เมษายน เป็นข้อมูลสำหรับใช้ในช่วงฤดูแล้ง

นอกจากนี้จากรูป 4-9 ยังสังเกตได้ว่าปริมาณน้ำฝนสะสมของสถานีวัด 150401 มีค่ามากกว่าสถานีอื่นๆ โดยเฉพาะอย่างยิ่ง เมื่อเทียบกับสถานี 25142 จะเห็นได้ว่ามีค่ามากกว่าเกือบ 2 เท่า ทั้งนี้เนื่องจากที่ตั้งของสถานีวัดทั้ง 2 อยู่คนละด้านของเทือกเขา โดยสถานี 150401 นั้นตั้งอยู่ในด้านที่รับลมมรสุมตะวันตกเฉียงใต้ หรือ ลมมรสุมในฤดูฝน ซึ่งจะทำให้ฝนตกหนักมากในด้านนี้ เมื่อเทียบกับที่ตั้งของสถานี 25142 ซึ่งอยู่อีกด้านหนึ่งของเทือกเขา

#### 4.2.5 การแบ่งช่วงข้อมูลปรับเทียบ ปรับทาน และรับรองผล

การแบ่งช่วงข้อมูลในการปรับเทียบ (calibration, training) และปรับทาน (verification, testing) แบบจำลองเป็นสิ่งสำคัญที่จะแสดงให้ว่าแบบจำลองนั้นสามารถใช้งานได้ในทุกๆ เหตุการณ์ ดังนั้นการเลือกช่วงข้อมูลสำหรับการปรับเทียบและปรับทาน จึงควรที่จะครอบคลุมในหลายๆ ช่วงเหตุการณ์ของข้อมูล สำหรับช่วงข้อมูลที่ใช้รับรองผล (validation) นั้น คือช่วงข้อมูลที่จะแสดงว่าแบบจำลองสามารถใช้งานได้จริงในเหตุการณ์ปัจจุบัน จึงควรเป็นช่วงข้อมูลล่าสุดที่มีการเก็บบันทึก ในการศึกษาครั้งนี้จึงแบ่งข้อมูลออกเป็น 3 ชุด คือ

1. ข้อมูลที่ใช้ในการปรับเทียบแบบจำลอง จำนวน 23 ปี
2. ข้อมูลที่ใช้ในการปรับทานแบบจำลอง จำนวน 3 ปี แยกตามฤดูกาล คือ
  - แบบจำลองที่ใช้ในฤดูฝน ประกอบด้วยปีที่มี น้ำมาก ปกติ และน้อย
  - แบบจำลองที่ใช้ในฤดูแล้ง ประกอบด้วยปีที่ แล้งมาก ปกติ และน้อย
3. ข้อมูลที่ใช้ในการรับรองผลของแบบจำลอง จะใช้ข้อมูลปีล่าสุดที่มีการเก็บรวบรวมข้อมูล คือ ปี 2541

สำหรับการแบ่งช่วงข้อมูลที่ใช้ในการปรับทานนั้น จะใช้วิธีการแจกแจงความถี่แบบ Weibull (Singh, 1992) โดยการนำปริมาณน้ำท่ารายปีที่สถานีวัด KGT.3 ในช่วงฤดูฝนและฤดูแล้ง มาจัดอันดับตามขนาดปริมาณน้ำท่าจากมากไปน้อย เพื่อนำไปหาค่าความถี่ของการเกิดซ้ำ (exceedance probability) ดังตาราง ข-4 และ ข-5 โดยปีที่เลือกใช้ในการปรับทานนั้นจะพิจารณาปีที่มีความถี่ของการเกิดซ้ำที่ 20%, 50% และ 80% จากการศึกษาพบว่าในฤดูฝนปีที่ใช้ในการปรับทานคือปี 2534 (ฝนมาก), 2523 (ฝนปกติ) และ 2532 (ฝนน้อย) ในฤดูแล้งปีที่ใช้ในการปรับทานคือ ปี 2537 (แล้งมาก), 2534 (แล้งปกติ) และ 2530 (แล้งน้อย) โดยช่วงข้อมูลส่วนที่เหลือนั้นก็ให้นำไปใช้ในการปรับเทียบแบบจำลองต่อไป

## บทที่ 5

### วิธีการดำเนินการศึกษา

ในการศึกษาค้นคว้าครั้งนี้จะกล่าวถึงวิธีการดำเนินการศึกษาออกเป็น 3 ส่วน หลักๆ คือ 1) การพัฒนาแบบจำลอง ANN สำหรับการพยากรณ์อัตราการใช้พลังงานรายวันล่วงหน้า 2) การปรับปรุงผลการพยากรณ์โดยใช้แบบจำลองอนุกรมเวลา เพื่อเพิ่มประสิทธิภาพในการพยากรณ์ และ 3) การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับ MLR โดยภาพรวมของขั้นตอนในการศึกษาค้นคว้านี้ได้แสดงดังรูป 5-1

#### 5.1 การพัฒนาแบบจำลอง ANN


การพัฒนาแบบจำลองการพยากรณ์อัตราการใช้พลังงานรายวันล่วงหน้า โดยใช้แบบจำลอง ANN นั้น สามารถแบ่งออกได้เป็น 4 ขั้นตอนหลัก ดังแสดงในรูป 5-2 โดยรายละเอียดและวิธีการในแต่ละขั้นตอน อธิบายได้ดังต่อไปนี้

##### 5.1.1 การวิเคราะห์และการคัดเลือกข้อมูล (Information Analysis)


ขั้นตอนนี้เป็นขั้นตอนแรกในการจัดเตรียม วิเคราะห์ และคัดเลือกข้อมูลเบื้องต้น เพื่อกำหนดขอบเขต และแนวทางในการศึกษาที่จะนำข้อมูลเหล่านั้นไปใช้สร้างแบบจำลองต่อไป โดยขั้นตอนนี้จะประกอบด้วย การจัดเตรียม ตรวจสอบ และการแบ่งช่วงข้อมูล การคัดเลือกชุดตัวแปรนำเข้าและผลลัพธ์ ตลอดจนการกำหนดวิธีการการพยากรณ์อัตราการใช้พลังงานรายวันล่วงหน้าที่มีมากกว่า 1 วัน

1) การจัดเตรียมข้อมูล เป็นการรวบรวมข้อมูลน้ำฝน น้ำท่า และข้อมูลทางกายภาพต่างๆ ในพื้นที่ศึกษาและพื้นที่ใกล้เคียง จากหน่วยงานต่างๆ ที่มีการวัดและจดบันทึกข้อมูลไว้ เพื่อใช้ในการจัดสร้างแบบจำลอง และเป็นข้อมูลประกอบการพิจารณา ในการศึกษาต่อไป

2) การวิเคราะห์ข้อมูลเบื้องต้น เป็นการตรวจสอบความมั่นคงของข้อมูล ว่าข้อมูลที่เก็บรวบรวมมานั้นมีความน่าเชื่อถือมากน้อยเพียงใดก่อนนำข้อมูลไปใช้ และนอกจากนี้ยังมีการเติมข้อมูลที่ขาดหายไปบางส่วน เพื่อให้ข้อมูลที่นำไปใช้ มีความต่อเนื่อง และสมบูรณ์มากที่สุด



รูป 5-1 ขั้นตอนวิธีการดำเนินการศึกษา



รูป 5-2 ขั้นตอนการพัฒนาแบบจำลอง ANN สำหรับการพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า

### 3) การแบ่งช่วงข้อมูล จะแบ่งออกเป็น 2 ส่วน คือ

- การแบ่งช่วงข้อมูลสำหรับฤดูฝนและฤดูแล้ง เนื่องจากปริมาณและลักษณะการเกิดของน้ำท่าในช่วงฤดูฝนและฤดูแล้งนั้น มีลักษณะที่แตกต่างกันอย่างชัดเจน คือ ในช่วงฤดูฝนปริมาณน้ำท่าจะมากเนื่องจากฝนที่ตกหนักในพื้นที่ ส่วนในฤดูแล้งปริมาณน้ำท่าส่วนใหญ่จะมาจากน้ำที่สะสมอยู่ในพื้นที่ลุ่มน้ำหรือน้ำใต้ดิน ทำให้ปริมาณน้ำท่าในช่วงนี้มีปริมาณน้อย ดังนั้นจึงเป็นสิ่งจำเป็นที่จะต้องจัดสร้างแบบจำลองในการพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้าแยกออกตามฤดูกาล ซึ่งส่งผลให้การแบ่งข้อมูลในช่วงฤดูฝนและฤดูแล้ง เป็นสิ่งสำคัญเนื่องจากช่วงข้อมูลที่จะทำการแบ่งนั้น จะต้องเป็นตัวแทนที่ดี และสะท้อนถึงลักษณะเฉพาะของแต่ละฤดู

- การแบ่งช่วงข้อมูลสำหรับปรับเทียบ ปรับทาน และ รับรองผลแบบจำลอง สำหรับการแบ่งข้อมูลส่วนนี้นั้นเป็นการแบ่งช่วงข้อมูลที่จะนำไปใช้ในการพัฒนาแบบจำลอง โดยข้อมูลสำหรับการปรับเทียบ และปรับทานแบบจำลองนั้น ควรที่จะครอบคลุมในหลายๆ ช่วงของเหตุการณ์น้ำท่าที่เกิดขึ้นในแต่ละพื้นที่ลุ่มน้ำ เช่น ช่วงเหตุการณ์ที่มีน้ำน้อย น้ำปกติ และน้ำมาก หรือช่วงเหตุการณ์ที่แล้งน้อย แล้งปกติ และแล้งมาก เป็นต้น เพื่อให้แบบจำลองสามารถเรียนรู้ และจดจำ ได้ในหลากหลายเหตุการณ์ และยังเป็นการยืนยันว่า แบบจำลองที่พัฒนาขึ้นนั้นสามารถใช้ได้กับทุกๆ เหตุการณ์ ที่เคยเกิดขึ้นในอดีต สำหรับข้อมูลที่ใช้ในการรับรองผลแบบจำลองนั้น ควรเป็นช่วงข้อมูลปัจจุบันหรือข้อมูลที่มีการเก็บบันทึกล่าสุด เพื่อเป็นการรับรองผลว่าแบบจำลองที่ผ่านการปรับเทียบ และ ปรับทานมาแล้วนั้น สามารถใช้ได้จริงในเหตุการณ์ปัจจุบัน

4) การคัดเลือกชุดตัวแปรนำเข้าและผลลัพธ์ ในการศึกษาครั้งนี้ได้ใช้ข้อมูลปริมาณฝนเฉลี่ยรายวันทั่วทั้งพื้นที่ ซึ่งได้มาจากวิธี รูปเหลี่ยมธีเอสเซน (Thiessen Polygon) เนื่องจากพื้นที่ลุ่มน้ำมีขนาดใหญ่ และอัตราการไหลน้ำท่ารายวันย้อนหลัง มาใช้เป็นตัวแปรที่จะนำมาคัดเลือกเป็นชุดตัวแปรนำเข้าสำหรับพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้าครั้งละ 1 วัน (มีผลลัพธ์ตัวเดียว) โดยวิธีการคัดเลือกชุดตัวแปรนำเข้านั้นจะแยกตามชนิดของตัวแปรดังนี้

- ตัวแปรนำเข้าชนิดเดียวกัน คือ อัตราการไหลน้ำท่ารายวัน ณ วันปัจจุบัน และวันที่ผ่านมา ( $Q_t, Q_{t-1}, Q_{t-2}, \dots$ ) ของสถานีตัวมันเอง โดยวิธีการคัดเลือกตัวแปรนำเข้าชนิดเดียวกันนี้ จะใช้การวิเคราะห์ความสัมพันธ์แบบ auto และ partial correlation มาเป็นแนวทางในการคัดเลือก

- ตัวแปรนำเข้าต่างชนิดกัน คือ ปริมาณฝนเฉลี่ยทั่วทั้งพื้นที่ในแต่ละลุ่มน้ำย่อย ณ วันปัจจุบัน และวันที่ผ่านมา ( $R_t, R_{t-1}, R_{t-2}, \dots$ ) โดยวิธีการคัดเลือกตัวแปรนำเข้าต่างชนิดกันนั้น จะใช้การวิเคราะห์ความสัมพันธ์แบบ cross correlation และยังได้นำกราฟ น้ำฝน-น้ำท่า (rainfall-

runoff hydrograph) ที่แสดงถึงลักษณะเฉพาะของแต่ละลุ่มน้ำย่อย มาเป็นแนวทางในการคัดเลือกเพื่อใช้ประกอบการตัดสินใจเพิ่มเติมด้วย ซึ่งจะแสดงไว้ในผลการศึกษา ในหัวข้อ 6.1.1 สำหรับขั้นตอนในการคัดเลือกชุดตัวแปรนำเข้านั้น แสดงได้ดังรูป 5-3

5) **วิธีการพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้ามากกว่า 1 วัน** แบ่งได้เป็น 2 วิธีคือ

- Direct step คือ การใช้ชุดตัวแปรนำเข้าสู่ชุดเดียวกันกับชุดตัวแปรนำเข้าของแบบจำลองการพยากรณ์ล่วงหน้า 1 วัน ตลอดการพยากรณ์ ตัวอย่างเช่น

$$Q_{t+1} = f(Q_t, Q_{t-1}, R_t, R_{t-1})$$

$$Q_{t+2} = f(Q_t, Q_{t-1}, R_t, R_{t-1})$$

- Standard step คือ การใช้ชุดตัวแปรนำเข้าแบบการเลื่อนไปข้างหน้า เพื่อพยายามรักษาความหมายของชุดตัวแปรนำเข้าให้ยังคงมีความหมายเหมือนกับชุดตัวแปรนำเข้าของแบบจำลองการพยากรณ์ล่วงหน้า 1 วัน โดยจะการนำเอาผลการพยากรณ์ล่วงหน้าในวันที่แล้วมาใช้เป็นตัวแปรนำเข้าให้กับการพยากรณ์ล่วงหน้าในวันถัดไป และตัดตัวแปรนำเข้าในวันหลังสุดออก

$$Q_{t+1} = f(Q_t, Q_{t-1}, R_t, R_{t-1})$$

$$Q_{t+2} = f(Q_{t+1}, Q_t, R_t)$$


หมายเหตุ ไม่มีการพยากรณ์ฝนล่วงหน้า ( $R_{t+1}$ )

### 5.1.2 การปรับเทียบแบบจำลอง (Model calibration or Training model)

จากหัวข้อที่ผ่านมาเมื่อได้ทำการแบ่งช่วงข้อมูลและคัดเลือกชุดตัวแปรนำเข้ากับผลลัพธ์แล้วนั้น ก็จะนำข้อมูลเหล่านั้นมาใช้ในการจัดสร้างและปรับเทียบแบบจำลอง โดยก่อนที่จะจัดสร้างและปรับเทียบแบบจำลองนั้น จำเป็นที่จะต้องคำนึงถึงค่าพารามิเตอร์ต่างๆ ( $\alpha$  และ  $\eta$ ) กับลักษณะโครงข่ายภายในที่เหมาะสมสำหรับแบบจำลอง ANN เสียก่อน แล้วจึงจะเข้าสู่กระบวนการเรียนรู้ (learning หรือ training process) เพื่อหาค่าถ่วงน้ำหนักที่เหมาะสมที่สุดในแบบจำลองนั้นๆ ต่อไป

1) **การคัดเลือกค่าพารามิเตอร์และโครงข่ายภายในที่เหมาะสมในแบบจำลอง ANN**

- การคัดเลือกค่าพารามิเตอร์ ในการศึกษาคั้งนี้มีค่าพารามิเตอร์ในแบบจำลอง ANN ที่จะต้องทำการคัดเลือกและทดสอบสรุปดังตาราง 5-1



รูป 5-3 ขั้นตอนการคัดเลือกชุดตัวแปรนำเข้าเพื่อใช้พยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า 1 วัน



ตาราง 5-1 การคัดเลือกค่าพารามิเตอร์ในแบบจำลอง ANN

ค่าพารามิเตอร์	ค่าที่ใช้ในการศึกษา	วิธีการคัดเลือก
1. ฟังก์ชันกระตุ้น	ซิกมอยด์ฟังก์ชัน	จากการศึกษาที่ผ่านมา
2. อัตราการเรียนรู้ ( $\eta$ )	0.01	Trial & Error
3. โมเมนตัม ( $\alpha$ )	0.45 และ 0.95 (เปลี่ยนที่ 5000 รอบ)	Trial & Error

ซึ่งรายละเอียดวิธีการคัดเลือกได้กล่าวไว้แล้วในหัวข้อ 3.2.4 สำหรับผลการคัดเลือกจะแสดงไว้ในบทต่อไป

- การหาโครงข่ายภายในที่เหมาะสมในแบบจำลอง ANN คือ การคัดเลือกจำนวนหน่วยในชั้นแอบแฝง และจำนวนชั้นแอบแฝง โดยจำนวนหน่วยและจำนวนชั้นแอบแฝงในแบบจำลอง ANN นั้น มีผลต่อเวลาที่ใช้ในการคำนวณหรือเรียนรู้ และประสิทธิภาพของแบบจำลอง คือ ถ้าแบบจำลองมีจำนวนหน่วยในชั้นแอบแฝงน้อยไป ก็จะทำให้แบบจำลองเรียนรู้ได้ไม่ดีเท่าที่ควร ถึงแม้จะใช้เวลาในการคำนวณน้อยก็ตาม แต่ถ้าแบบจำลองมีจำนวนหน่วยและจำนวนชั้นแอบแฝงมากเกินไป ก็จะทำให้เสียเวลาในการเรียนรู้และการคำนวณมากตามไปด้วย

ในการศึกษาครั้งนี้ได้กำหนดจำนวนหน่วยและจำนวนชั้นแอบแฝง ให้สัมพันธ์กับจำนวนตัวแปรนำเข้า คือ จะกำหนดจำนวนหน่วยเป็น 0.5, 1, และ 2 เท่า ของตัวแปรนำเข้า โดยใช้จำนวนชั้นแอบแฝง 1 และ 2 ชั้น ตัวอย่างเช่น แบบจำลองมีตัวแปรนำเข้า 8 ตัว การทดลองจะกำหนดจำนวนหน่วยในแบบจำลองที่มีชั้นแอบแฝง 1 ชั้น เป็น 4, 8, และ 16 หน่วย สำหรับแบบจำลองที่มีชั้นแอบแฝง 2 ชั้น จะกำหนดจำนวนหน่วยเป็น 2-2, 4-4, และ 8-8 หรือ ถ้าแบบจำลองมีตัวแปรนำเข้า 7 ตัว การทดลองจะกำหนดจำนวนหน่วยในแบบจำลองที่มีชั้นแอบแฝง 1 ชั้น เป็น 3, 7, และ 14 หน่วย สำหรับแบบจำลองที่มีชั้นแอบแฝง 2 ชั้น จะกำหนดจำนวนหน่วยเป็น 2-1, 4-3, และ 7-7 เป็นต้น เพื่อจัดทำเป็นแนวทางในการคัดเลือกโครงข่ายภายในที่เหมาะสม ในแบบจำลอง ANN ต่อไป ซึ่งจะช่วยลดเวลาในการพัฒนาแบบจำลอง ANN ได้อีกทางหนึ่ง

2) จัดสร้างแบบจำลองการพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า จะนำเอาชุดตัวแปรนำเข้าและค่าพารามิเตอร์ต่างๆ ตลอดจนทั้งจำนวนหน่วยในชั้นแอบแฝงที่ผ่านการคัดเลือก มาจัดสร้างเป็นแบบจำลองในกรณีต่างๆ แยกตามลุ่มน้ำย่อย

3) การเข้าสู่กระบวนการเรียนรู้ ในขั้นตอนนี้จะให้แบบจำลองที่จัดสร้างขึ้นในกรณีต่างๆ นั้น ได้เรียนรู้ข้อมูลที่แบ่งไว้สำหรับการปรับเทียบแบบจำลอง เพื่อหาค่าของถ่วงน้ำหนักที่เหมาะสมกับแบบจำลองนั้นๆ โดยกระบวนการเรียนรู้ที่ใช้ในการศึกษาคั้งนี้จะใช้กระบวนการเรียนรู้แบบคำนวณย้อนกลับ (Back propagation)

### 5.1.3 การปรับทานแบบจำลอง (Model verification or Testing model)

เมื่อแบบจำลองต่างๆ ผ่านการปรับเทียบมาแล้วนั้น ขั้นตอนต่อไป คือ การนำแบบจำลองเหล่านั้นมาทดสอบกับช่วงข้อมูลที่เตรียมไว้สำหรับการปรับทานแบบจำลอง เพื่อทดสอบดูว่าแบบจำลองต่างๆ เหล่านั้น สามารถนำมาประยุกต์ใช้ในหลายๆ ช่วงของเหตุการณ์น้ำท่าได้มากน้อยเพียงใด ซึ่งมีรายละเอียด ดังต่อไปนี้

1) การทดสอบแบบจำลอง คือ การนำข้อมูลที่ใช้ในการปรับทานแบบจำลองมาทดสอบกับแบบจำลองที่ผ่านการปรับเทียบมาแล้ว

2) การคำนวณค่าความผิดพลาดและประสิทธิภาพของแบบจำลอง คือ การเปรียบเทียบผลการพยากรณ์ที่ได้จากแบบจำลองกับข้อมูลที่จัดจริง ทั้งในช่วงการปรับเทียบและปรับทานแบบจำลอง เพื่อนำมาคำนวณหาความผิดพลาดในเชิงสถิติต่างๆ (RMSE, MAD และ Max absolute error) และประสิทธิภาพ (EI) แต่ละแบบจำลอง

### 5.1.4 การคัดเลือกแบบจำลองและการนำไปประยุกต์ใช้ในงาน (Model selection and application)

ในขั้นตอนนี้จะทำการประเมินและเปรียบเทียบผลการพยากรณ์จากแบบจำลองต่างๆ เพื่อคัดเลือกแบบจำลองที่เหมาะสมที่สุดในการพยากรณ์อัตราการไหลของน้ำท่ารายวันล่วงหน้าที่ออกจากแต่ละลุ่มน้ำย่อย และนำไปประยุกต์ใช้งานต่อไป

1) การเปรียบเทียบและประเมินแบบจำลอง คือ การนำเอาผลการพยากรณ์จากแบบจำลองที่ใช้ชุดตัวแปรนำเข้าจาก (1) การคัดเลือกโดยฟังก์ชันความสัมพันธ์ และ (2) การ trial & error มาเปรียบเทียบค่าความผิดพลาดและประสิทธิภาพของแต่ละแบบจำลอง ซึ่งจะรวมทั้งการเปรียบเทียบแบบจำลองเมื่อมีการปรับเปลี่ยนลักษณะโครงสร้างภายในตามกรณีต่างๆ ที่ได้กำหนดไว้ เพื่อนำมาใช้ในการประเมินผลการพยากรณ์ ว่าแต่ละแบบจำลองนั้นมีความแม่นยำในการพยากรณ์ และความเหมาะสมที่จะนำไปใช้มากน้อยเพียงใด

2) การคัดเลือกแบบจำลองที่เหมาะสม จากผลการประเมินในข้อที่ 1 ก็จะทำให้การคัดเลือกแบบจำลองที่เหมาะสมกับการพยากรณ์อัตราการใช้พลังงานในแต่ละลุ่มน้ำย่อย

3) การนำแบบจำลองไปประยุกต์ใช้งาน คือ การนำแบบจำลองที่ผ่านการคัดเลือกมาแล้วนั้น ไปประยุกต์งานใช้กับเหตุการณ์จริงในปัจจุบัน โดยในการศึกษาค้นคว้าครั้งนี้ได้นำเอาข้อมูลที่มีการเก็บบันทึกในปีล่าสุดมาใช้เสมือนกับเหตุการณ์ในปัจจุบันเพื่อทดสอบแบบจำลอง และเป็นการรับรองผลการพยากรณ์จากแต่ละแบบจำลอง ว่าสามารถนำไปประยุกต์ใช้งานได้กับเหตุการณ์ในปัจจุบัน

## 5.2 การปรับปรุงผลการพยากรณ์ (Residual adjustment)

ในขั้นตอนนี้จะเริ่มจากการนำอนุกรมค่าความผิดพลาด (residual series) ที่เกิดจากแบบจำลอง ANN มาวิเคราะห์เพื่อพิจารณาว่าอนุกรมชุดนี้มีความเป็นอิสระต่อกันหรือไม่ โดยจะใช้การวิเคราะห์ความสัมพันธ์แบบ auto correlation และ partial correlation แล้วนำมาเขียนเป็นกราฟ correlogram และ partial correlogram เพื่อใช้ในการพิจารณา โดยรายละเอียดได้กล่าวไว้แล้วในหัวข้อ 3.1.1 กับ 3.1.2 และพิจารณาได้ดังรูป 3-4

ถ้าอนุกรมค่าความผิดพลาดมีความเป็นอิสระต่อกัน (independent series) แสดงว่าอนุกรมชุดนั้นมีลักษณะเป็นตัวแปรสุ่ม (random series) ซึ่งจะเป็นตัวชี้ว่าแบบจำลองนั้นไม่สามารถที่จะปรับปรุงผลการพยากรณ์ได้อีก แต่ถ้าอนุกรมค่าความผิดพลาดไม่อิสระต่อกัน (dependent series) หรือ พบความสัมพันธ์ภายในที่มีนัยสำคัญ ก็ให้นำเอาอนุกรมชุดนั้นมาใช้ในการสร้างแบบจำลองการพยากรณ์ค่าความผิดพลาดล่วงหน้า โดยใช้แบบจำลองอนุกรมเวลา อันได้แก่แบบจำลอง AR, MA หรือ ARMA Model สำหรับวิธีการเลือกแบบจำลองอนุกรมเวลานั้นได้กล่าวไว้แล้วในหัวข้อ 3.3.4 และเมื่อนำผลการพยากรณ์ล่วงหน้าจากแบบจำลอง ANN มารวมกับ

ผลการพยากรณ์ค่าความผิดพลาดล่วงหน้า จากแบบจำลองอนุกรมเวลา ก็จะทำให้ผลการพยากรณ์มีความแม่นยำขึ้น หรือ แบบจำลองมีประสิทธิภาพเพิ่มมากขึ้น

### 5.3 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับ MLR

เมื่อได้ทำการพัฒนาแบบจำลอง ANN สำหรับการพยากรณ์อัตราการไหลรายวันล่วงหน้า ในแต่ละลุ่มน้ำย่อยเสร็จเรียบร้อยแล้วนั้น ก็จะนำผลการพยากรณ์ที่ได้จากแต่ละแบบจำลองมา เปรียบเทียบกับผลการพยากรณ์จากแบบจำลอง MLR ที่ถูกสร้างขึ้นโดยใช้ชุดตัวแปรนำเข้าสู่ชุด เดียวกันกับแบบจำลอง ANN เพื่อพิจารณาถึงความแตกต่างของแบบจำลองทั้ง 2 ในการนำมา ประยุกต์ใช้สำหรับการพยากรณ์อัตราการไหลน้ำท่ารายวัน



สถาบันวิทยบริการ  
จุฬาลงกรณ์มหาวิทยาลัย

## บทที่ 6

### ผลการศึกษา

การศึกษาค้นคว้าครั้งนี้มีวัตถุประสงค์ 5 ประการ คือ 1) หาแนวทางในการคัดเลือกชุดตัวแปรนำเข้า 2) พัฒนาแบบจำลอง ANN เพื่อใช้พยากรณ์อัตราการไหลน้ำท่ารายวันในพื้นที่ที่มีลักษณะทางกายที่แตกต่างกัน 3) หาแนวทางในการคัดเลือกค่าพารามิเตอร์ต่างๆ และลักษณะโครงข่ายภายในที่เหมาะสมในแบบจำลอง ANN 4) นำเสนอวิธีการปรับปรุงผลการพยากรณ์ให้มีความแม่นยำมากขึ้น และ 5) เปรียบเทียบผลการพยากรณ์กับแบบจำลอง MLR ดังนั้นในบทนี้จะกล่าวถึงผลการศึกษาให้ครอบคลุมประเด็นต่างๆ ที่ได้กล่าวมาข้างต้นแยกตามชนิดของแบบจำลองซึ่งจะแบ่งออกเป็น 2 กลุ่มตามฤดูกาล คือ แบบจำลองที่ใช้สำหรับฤดูฝนและแบบจำลองที่ใช้สำหรับฤดูแล้งที่ใช้พยากรณ์ ณ สถานีวัดน้ำท่าต่างๆ

#### 6.1 แบบจำลองการพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้าในฤดูฝน


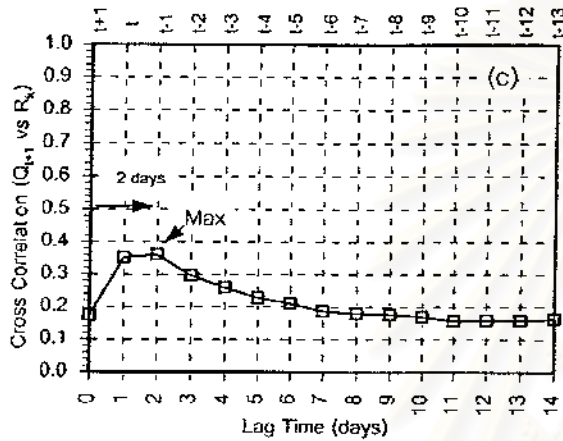
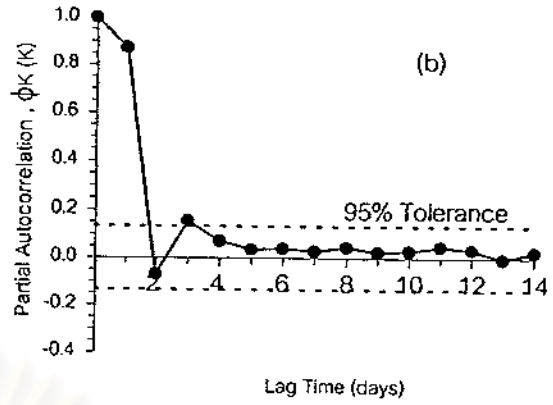

##### 6.1.1 การคัดเลือกชุดตัวแปรนำเข้าสำหรับพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า 1 วัน

การคัดเลือกชุดตัวแปรนำเข้าสู่แบบจำลอง ANN สำหรับพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า 1 วัน ในช่วงฤดูฝน แบ่งออกเป็น 2 ขั้นตอน คือ การคัดเลือกชุดตัวแปรนำเข้าเบื้องต้น และการทดสอบตัวแปรนำเข้าที่มีนัยสำคัญ





##### 6.1.1.1 การคัดเลือกชุดตัวแปรนำเข้าเบื้องต้น

คือ การคัดเลือกตัวแปรนำเข้าที่คาดว่าจะมีอิทธิพลต่อการพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า 1 วัน ( $Q_{t+1}$ ) ซึ่งจะใช้กราฟความสัมพันธ์ อันได้แก่ กราฟ autocorrelation, partial autocorrelation, cross correlation และ กราฟน้ำฝน-น้ำท่า มาใช้เป็นแนวทางในการคัดเลือกชุดตัวแปรนำเข้าเบื้องต้น โดยผลการจัดสร้างแยกตามสถานีวัดน้ำท่าต่าง ๆ แสดงได้ดังรูป 6-1 ถึง 6-6





จากรูป 6-1 ถึง 6-6 รูป a, b, c และ d คือ กราฟความสัมพันธ์แบบ autocorrelation partial autocorrelation, cross correlation และ กราฟน้ำฝน-น้ำท่า ตามลำดับ เมื่อค่าสัมพันธ์ที่ lag time 0 ของรูป a กับ b จะเปรียบเสมือนค่าความสัมพันธ์ระหว่าง  $Q_{t+1}$  กับ  $Q_t$  ซึ่งจะมีค่าเท่า







รูป 6-1 กราฟความสัมพันธ์สำหรับคัดเลือกชุดตัวแปรนำเข้าในการพยากรณ์  $Q_{t+1}$  ณ สถานี 150401 ในช่วงฤดูฝน







รูป 6-2 กราฟความสัมพันธ์สำหรับคัดเลือกชุดตัวแปรนำเข้าในการพยากรณ์  $Q_{t+1}$  ณ สถานี KGT.14 ในช่วงฤดูฝน







รูป 6-3 กราฟความสัมพันธ์สำหรับคัดเลือกชุดตัวแปรนำเข้าในการพยากรณ์  $Q_{t+1}$  ณ สถานี KGT.15A ในช่วงฤดูฝน



รูป 6-4 กราฟความสัมพันธ์สำหรับคัดเลือกชุดตัวแปรนำเข้าในการพยากรณ์  $Q_{t+1}$  ณ สถานี KGT.12 ในช่วงฤดูฝน



รูป 6-5 กราฟความสัมพันธ์สำหรับคัดเลือกชุดตัวแปรนำเข้าในการพยากรณ์  $Q_{t+1}$  ณ สถานี KGT.10 ในช่วงฤดูฝน



รูป 6-6 กราฟความสัมพันธ์สำหรับคัดเลือกชุดตัวแปรนำเข้าในการพยากรณ์  $Q_{t+1}$  ณ สถานี KGT.3 ในช่วงฤดูฝน



กับ 1 เดมอ (ความสัมพันธ์ระหว่างตัวมันเองกับตัวมันเอง) สำหรับที่ lag time 1, 2, 3,..... นั้นจะหมายถึงค่าความสัมพันธ์ระหว่าง  $Q_{t+1}$  กับ  $Q_t, Q_{t-1}, Q_{t-2}, \dots$  ตามลำดับ ส่วนค่าสัมพันธ์ที่ lag time 0 ของรูป c นั้น จะเปรียบเสมือนค่าความสัมพันธ์ระหว่าง  $Q_{t+1}$  กับ  $R_{t+1}$  (ฝนเฉลี่ยทั่วทั้งพื้นที่ ณ เวลา  $t+1$ ) ซึ่งจะมีค่าไม่เท่ากับ 1 เนื่องจากเป็นตัวแปรต่างชนิดกัน สำหรับที่ lag time 1, 2, 3,..... นั้นจะหมายถึงค่าความสัมพันธ์ระหว่าง  $Q_{t+1}$  กับ  $R_t, R_{t-1}, R_{t-2}, \dots$  ตามลำดับ เพื่อความเหมาะสมและเป็นที่ยอมรับร่วมกัน สำหรับการศึกษานี้จะเรียกเวลาในปัจจุบันและเวลาย้อนหลังในรูปของ  $t, t-1, t-2, \dots$  แทน คำว่า lag time โดยที่ lag time 1 จะกำหนดให้เปรียบเสมือนเวลา ณ ปัจจุบัน ( $t$ ) และ ที่ lag time 2 จะหมายถึง เวลาย้อนหลัง 1 วัน ( $t-1$ ) เป็นต้น

สำหรับเกณฑ์ในการคัดเลือกตัวแปรนำเข้าเบื้องต้น โดยใช้กราฟ a-d นั้น อธิบายแยกตามชนิดของตัวแปร ได้ดังต่อไปนี้

1) ตัวแปรนำเข้าชนิดเดียวกัน คือ การคัดเลือกจำนวนวันย้อนหลังของอัตราการผลิตน้ำท่ารายวันของสถานีตัวมันเอง ซึ่งจะใช้กราฟ a และ b มาเป็นแนวทางในการคัดเลือก โดยเมื่อพิจารณาความสัมพันธ์ในกราฟความสัมพันธ์แบบ autocorrelation (กราฟ a) ของสถานีวัดน้ำท่า 150401, KGT.14 และ KGT.15A มีลักษณะคล้ายกัน คือ มีค่าสูงและลดลงอย่างรวดเร็วในช่วงเวลา  $t$  และ  $t-1$  (มีค่าความสัมพันธ์ประมาณ 0.42-0.88) ซึ่งจะแตกต่างอย่างชัดเจนเมื่อเทียบกับความสัมพันธ์ในช่วงต่อมาที่มีค่าน้อยและลดลงช้าๆ อย่างคงที่ ซึ่งอาจจะตีความได้ว่า ค่า  $Q_t$  และ  $Q_{t-1}$  นั้น น่าจะมีอิทธิพลต่อ  $Q_{t+1}$  สำหรับค่าความสัมพันธ์จากกราฟ a ของสถานีวัดน้ำท่า KGT.10, KGT.12 และ KGT.3 จะมีค่าสูงมากในช่วงแรก (มากกว่า 0.9) และจะมีค่าลดลงช้าๆ อย่างต่อเนื่องในช่วงเวลาย้อนหลังถัดมา จากกราฟจะเห็นได้ว่าไม่มีจุดแตกต่างของกราฟที่ชัดเจนมากนักเมื่อเทียบกับ 3 สถานีที่ผ่านมา ทำให้ยากต่อการตีความหมายในการคัดเลือกจำนวนวันย้อนหลังที่น่าสนใจ ดังนั้นการนำกราฟความสัมพันธ์แบบ autocorrelation มาใช้เป็นแนวทางในการคัดเลือกตัวแปรนำเข้าที่เป็นอัตราการผลิตน้ำท่ารายวันย้อนหลัง จึงอาจยังไม่ชัดเจนมากนัก

สำหรับค่าความสัมพันธ์ในกราฟความสัมพันธ์แบบ partial autocorrelation (กราฟ b) ของสถานีวัดน้ำท่าต่างๆ พบว่ามีลักษณะที่คล้ายกัน คือ มีค่าความสัมพันธ์ที่มากกว่าขอบเขตความเป็นอิสระของตัวแปร ( $\pm 95\%$  Tolerance) ในช่วงแรกของกราฟ (ณ เวลา  $t$  ถึง  $t-1$ ) แล้วจะลู่เข้าสู่ ศูนย์ในช่วงเวลาย้อนหลังถัดมา ซึ่งหมายความว่าอัตราการผลิตน้ำท่าย้อนหลังที่มีสัมพันธ์ที่ดีต่อ  $Q_{t+1}$  และมีค่ามากพอแก่การสนใจ คือ  $Q_t$  กับ  $Q_{t-1}$  โดยสถานีวัดน้ำท่าที่มีค่าความสัมพันธ์มากกว่าขอบเขต  $\pm 95\%$  Tolerance ณ เวลา  $t$  ได้แก่ สถานี 150401 และ KGT.14 ส่วนสถานีวัดน้ำท่าที่มีค่าความสัมพันธ์มากกว่าขอบเขต  $\pm 95\%$  Tolerance ณ เวลา  $t$  และ  $t-1$  คือ สถานี KGT.15A, KGT.10, KGT.12 และ KGT.3

จะเห็นได้ว่าการคัดเลือกตัวแปรนำเข้าที่เป็นอัตราการไหลน้ำท่ารายวันย้อนหลัง โดยใช้กราฟความสัมพันธ์แบบ partial autocorrelation นั้นจะมีความชัดเจนมากกว่ากราฟความสัมพันธ์แบบ autocorrelation แต่ทั้งนี้ในการสร้างกราฟความสัมพันธ์แบบ partial autocorrelation จำเป็นที่จะต้องหาค่าความสัมพันธ์แบบ autocorrelation ขึ้นมาก่อน

2) ตัวแปรนำเข้าต่างชนิดกัน คือ การคัดเลือกจำนวนวันย้อนหลังของปริมาณฝนเฉลี่ยทั่วทั้งพื้นที่รายวัน ซึ่งจะใช้กราฟ c และ d มาเป็นแนวทางในการคัดเลือก โดยเมื่อพิจารณาความสัมพันธ์ของกราฟความสัมพันธ์แบบ cross correlation (กราฟ c) ระหว่างน้ำท่าและน้ำฝนของสถานีวัดน้ำท่าต่างๆ พบว่ามีค่าความสัมพันธ์เพิ่มขึ้นในช่วงแรกจนถึงจุดสูงสุด แล้วจึงจะมีค่าลดลงอย่างต่อเนื่องจนเกือบคงที่ในช่วงเวลาย้อนหลังถัด และเมื่อนับจำนวนวันย้อนจากเวลาที่  $t+1$  ไปจนถึงวันที่มีค่าความสัมพันธ์สูงสุด จากกราฟ c ของสถานีวัดน้ำท่าต่างๆ (ยกเว้นที่ KGT.3) พบว่ามีค่าสอดคล้องกับค่า  $T_c$  (time of concentration) จากกราฟความสัมพันธ์ระหว่างน้ำฝน-น้ำท่า (กราฟ d) ซึ่งเลือกมาจากเหตุการณ์ในอดีตของแต่ละสถานีและเป็นเหตุการณ์ที่มีลักษณะเป็นพายุฝนลูกเดียว เพื่อพิจารณาการขึ้นลงของกราฟน้ำท่าได้อย่างชัดเจน

โดยค่า  $T_c$  นี้ หมายถึง ระยะเวลาที่น้ำฝนจากจุดไกลสุดของกลุ่มน้ำเคลื่อนที่มาถึงจุดวัดน้ำท่า ซึ่งจะเป็นตัวชี้ถึงจำนวนวันที่ฝนมีอิทธิพลต่อปริมาณน้ำท่าที่ไหลบนผิวดิน (direct runoff) มาถึงสถานีวัดน้ำท่า สำหรับการหาค่า  $T_c$  จากกราฟน้ำฝน-น้ำท่านั้นจะเริ่มวัดจากเวลาที่ฝนหยุดตกไปถึงจุดเปลี่ยนโค้ง (point of inflection) บนโค้งการลดลง ของกราฟน้ำท่า จากกราฟ d ของรูป 6-1 ถึง 6-6 พบว่าค่า  $T_c$  ของแต่ละสถานีวัดมีค่าที่แตกต่างกัน โดยค่า  $T_c$  นี้ จะขึ้นอยู่กับลักษณะกายภาพและขนาดลุ่มน้ำเหนือสถานีวัดเป็นหลัก คือ ลุ่มน้ำที่มีขนาดเล็กและชัน เช่น ลุ่มน้ำลำพระยาธาร (KGT.14) จะมีค่า  $T_c$  น้อยกว่าลุ่มน้ำขนาดใหญ่และราบ เช่น ลุ่มน้ำพระปรองดองบน (KGT.12) สำหรับที่สถานี KGT.3 จะเห็นจำนวนวันย้อนจากเวลาที่  $t+1$  ไปถึงวันที่มีค่าความสัมพันธ์สูงสุด (4 วัน) มีค่าน้อยกว่า  $T_c$  (7 วัน) ทั้งนี้เนื่องจากปริมาณฝนทั่วทั้งพื้นที่ที่นำมาใช้หาค่าความสัมพันธ์แบบ cross correlation จะพิจารณาเฉพาะปริมาณฝนที่ตกในพื้นที่ย่อยที่ 6 (รูป 4-1) ซึ่งมีขนาดเล็กกว่าพื้นที่ลุ่มน้ำที่อยู่เหนือ KGT.3 ทั้งหมด

นอกจากนี้ยังเห็นได้ว่า ค่าความสัมพันธ์แบบ cross correlation ณ สถานี KGT.14 ที่ค่าสูงสุดมีค่าประมาณ 0.45 และมีค่ามากที่สุดเมื่อเทียบกับสถานีอื่นๆ ทั้งนี้เนื่องจากลักษณะลุ่มน้ำที่อยู่เหนือสถานีเหล่านี้มีพื้นที่ขนาดเล็กและมีความชันมาก ทำให้ปริมาณน้ำฝนส่วนใหญ่ที่ตกลงมาเปลี่ยนเป็นน้ำท่าในเวลาอันสั้น ค่าความสัมพันธ์ระหว่างน้ำท่าและน้ำฝนจึงมีค่าสูง เมื่อเปรียบเทียบกับฝนที่ตกในพื้นที่ลุ่มน้ำขนาดใหญ่และมีความชันน้อย ทำให้ปริมาณน้ำฝนส่วนใหญ่ที่ตกลง

มาจะค่อยๆ เปลี่ยนเป็นน้ำท่าซึ่งจะใช้เวลานาน ส่งผลให้ค่าความสัมพันธ์ระหว่างน้ำท่าและน้ำฝนมีค่าต่ำ

จากผลที่ได้กล่าวมาทั้งหมดแสดงให้เห็นว่าลักษณะกราฟความสัมพันธ์แบบ cross correlation ระหว่างอัตราการไหลน้ำท่ารายวันกับปริมาณฝนเฉลี่ยทั่วทั้งพื้นที่รายวัน มีความสอดคล้องกับกราฟน้ำฝน-น้ำท่า ในแต่ละพื้นที่ลุ่มน้ำ ดังนั้นในการเลือกจำนวนวันย้อนหลังของปริมาณฝนเฉลี่ยทั่วทั้งพื้นที่ ที่คาดว่าจะมีอิทธิพลต่อ  $Q_{t+1}$  จึงสามารถพิจารณาจากความสัมพันธ์แบบ cross correlation ได้ ซึ่งจะเริ่มนับจำนวนวันย้อนจากเวลาที่  $t+1$  ไปถึงวันที่มีค่าความสัมพันธ์ระหว่างน้ำฝน-น้ำท่าสูงสุด

จากการคัดเลือกชุดตัวแปรนำเข้าเบื้องต้นโดยใช้กราฟความสัมพันธ์ทั้ง 4 กราฟ สามารถสรุปชุดตัวแปรนำเข้าที่คาดว่าจะมีอิทธิพลต่อการนำไปใช้ในการพยากรณ์  $Q_{t+1}$  ณ สถานีวัดน้ำท่าต่างๆ ได้ดังตาราง 6-1

ตาราง 6-1 ชุดตัวแปรนำเข้าเบื้องต้นสำหรับการพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า 1 วัน ในฤดูฝน

สถานีวัดน้ำท่า	ชุดตัวแปรนำเข้า		
	อัตราการไหลน้ำท่ารายวันย้อนหลัง	ปริมาณฝนเฉลี่ยทั่วทั้งพื้นที่รายวันย้อนหลัง	อัตราการไหลน้ำท่าจากสถานีวัดน้ำท่าที่ตั้งอยู่เหนือน้ำ
150401 (Q1)	$Q1_t$	$R1_t, R1_{t-1}$	-
KGT.14 (Q2)	$Q2_t$	$R2_t$	-
KGT.15A (Q3)	$Q3_t, Q3_{t-1}$	$R3_t, R3_{t-1}$	-
KGT.12 (Q4)	$Q4_t, Q4_{t-1}$	$R4_t, R4_{t-1}, R4_{t-2}, R4_{t-3}, R4_{t-4}, R4_{t-5}$	-
KGT.10 (Q5)	$Q5_t, Q5_{t-1}$	$R5_t, R5_{t-1}, R5_{t-2}$	-
KGT.3 (Q6)	$Q6_t, Q6_{t-1}$	$R6_t, R6_{t-1}, R6_{t-2}, R6_{t-3}$	$Q1_t, Q2_t, Q3_t, Q4_t, Q5_t$
พิจารณาจาก	กราฟ Auto correlation และ Partial correlation	กราฟ Cross correlation และ กราฟน้ำฝน-น้ำท่า	ค่า Cross correlation

จากตารางที่ 6-1 จะสังเกตเห็นได้ว่าที่สถานี KGT.3 มีการนำเอาอัตราการไหลน้ำท่า ณ เวลา  $t$  ของสถานีวัดน้ำท่าต่าง ๆ ที่ตั้งอยู่เหนือน้ำ มาใช้เป็นตัวแปรนำเข้าเพิ่มเติมด้วย โดยวิธีการคัดเลือกนั้นจะพิจารณาจากค่าความสัมพันธ์แบบ cross correlation ระหว่างอัตราการไหลน้ำท่ารายวัน ณ

KGT.3 กับ อัตราการไหลน้ำท่ารายวัน ณ สถานีวัดน้ำท่าต่างๆ ที่ตั้งอยู่เหนือน้ำดังตาราง 6-2 พบว่ามีค่าความสัมพันธ์สูงสุด ณ เวลา  $t$  และมีค่าลดลงอย่างต่อเนื่องในช่วงเวลาถัดมา ซึ่งอาจจะหมายถึงน้ำท่าใช้เวลาที่เดินทางจากสถานีวัดน้ำท่าต่างๆ มายังสถานี KGT.3 ประมาณ 1 วัน

ตาราง 6-2 ค่าความสัมพันธ์แบบ cross correlation ระหว่างอัตราการไหลน้ำท่ารายวัน ณ สถานี KGT.3 และสถานีวัดน้ำท่าด้านเหนือในฤดูฝน

Time (Days)	KGT.3				
	Q150401	KGT.14	KGT.15A	KGT.12	KGT.10
t	0.802	0.608	0.745	0.900	0.790
t-1	0.795	0.591	0.735	0.876	0.787
t-2	0.782	0.596	0.728	0.842	0.776
t-3	0.760	0.579	0.707	0.804	0.751
t-4	0.736	0.560	0.684	0.764	0.719
t-5	0.712	0.540	0.661	0.723	0.684
t-6	0.686	0.522	0.638	0.683	0.644

จากผลการศึกษาพบว่าจำนวนวันย้อนหลังของอัตราการไหลน้ำท่ารายวันและปริมาณฝนเฉลี่ยทั่วทั้งพื้นที่ที่คาดว่าจะนำมาใช้เป็นตัวแปรนำเข้าในการพยากรณ์  $Q_{t+1}$  ที่ออกจากลุ่มน้ำต่างๆ ในช่วงหน้าฝนนั้น ขึ้นอยู่กับลักษณะของอัตราการไหลน้ำท่าและลักษณะทางกายภาพของพื้นที่ลุ่มน้ำ อันได้แก่ ขนาดพื้นที่ความชัน เป็นต้น โดยพื้นที่ที่มีอัตราการไหลน้ำท่าขึ้นลงอย่างช้าๆ จะเป็นพื้นที่ขนาดใหญ่และมีความชันน้อย (สถานี KGT12, KGT10 และ KGT 3) ซึ่งใช้จำนวนวันย้อนหลังมากกว่า พื้นที่ที่มีขนาดเล็กและมีความชันมาก ซึ่งจะมีลักษณะอัตราการไหลน้ำท่าที่ขึ้นลงอย่างรวดเร็ว (สถานี 150401, KGT.14 และ KGT.15A)

#### 6.1.1.2 การทดสอบชุดตัวแปรนำเข้าที่มีนัยสำคัญ

เป็นการนำเอาตัวแปรแต่ละตัวที่ผ่านการคัดเลือกเบื้องต้นในหัวข้อที่ 6.1.1.1 มาทดสอบเพื่อพิจารณาว่าตัวแปรที่คัดเลือกมานั้นมีนัยสำคัญเพียงพอต่อการนำไปพยากรณ์  $Q_{t+1}$  หรือไม่ ซึ่งจะให้การทดสอบ แบบ sensitivity นอกจากนี้ในการศึกษาค้างนี้ยังเพิ่มตัวแปรนำเข้าที่เป็นอัตราการไหลน้ำท่ารายวันและปริมาณฝนเฉลี่ยทั่วทั้งพื้นที่ของแต่ละสถานีย้อนหลังเพิ่มไปอีก 1 วันจากเดิมมาทดสอบเพิ่มเติมด้วย สำหรับจำนวนข้อมูลที่ใช้สำหรับปรับเทียบแบบจำลองมีทั้งหมด 4916

ชุด และที่ใช้สำหรับปรับทานมีทั้งหมด 642 ชุด ส่วนจำนวนหน่วยในชั้นแบบแฝงในแบบจำลอง ANN นั้น จะกำหนดให้มี 3 หน่วยทุกการทดสอบ เนื่องจากจำนวนหน่วยดังกล่าวเป็นจำนวนหน่วยที่น้อยที่สุดที่ทำให้ทุกแบบจำลองทำงานได้ (trial & error) และเพื่อความสะดวกในการเปรียบเทียบ โดยผลการทดสอบชุดตัวแปรนำเข้าแสดงได้ดังตาราง 6-3 ถึง 6-8

ในการทดสอบตัวแปรนำเข้าของทุกสถานะนั้น จะเริ่มจากการทดสอบตัวแปรนำเข้า  $Q_1$  พร้อมทั้งหาค่าประสิทธิภาพของแบบจำลอง (EI) และค่าความผิดพลาดต่างๆ ก่อน จากนั้นจึงจะเพิ่มตัวแปรอื่นๆ เข้ามา แล้วพิจารณาอัตราการเปลี่ยนแปลงค่าประสิทธิภาพของแบบจำลอง (rate of improvement) ที่เพิ่มตัวแปรใหม่เข้ามา เมื่อเทียบกับประสิทธิภาพของแบบจำลองที่เกิดจากตัวแปรนำเข้า  $Q_1$  หรือแบบจำลองเดิมก่อนหน้าที่จะเพิ่มตัวแปรนำเข้าใหม่เข้าไป ทั้งนี้เนื่องจากตัวแปรนำเข้า  $Q_1$  เป็นตัวแปรที่มีความสัมพันธ์ที่ดีกับ  $Q_{1,1}$  มากที่สุดเมื่อเทียบกับตัวแปรนำเข้าอื่นๆ (พิจารณาค่าความสัมพันธ์ กราฟ a, b จากรูป 6-1 ถึง 6-6) ดังนั้นถ้าในแบบจำลองมี  $Q_1$  อยู่ด้วย จะช่วยป้องกันการลู่ออกของโปรแกรมหากใช้ตัวแปรอื่นๆ ที่มีค่าความสัมพันธ์ไม่มากเป็นตัวแปรนำเข้าเพียงตัวเดียว

การหาค่าอัตราการเปลี่ยนแปลงค่าประสิทธิภาพของแบบจำลอง คำนวณได้จากสมการ 6-1

$$\text{Rate of improvement (\%)} = \frac{\text{EI ใหม่ (\%)} - \text{EI เดิม (\%)}}{100 - \text{EI เดิม (\%)}} \times 100 \quad \dots\dots(6-1)$$

เมื่อ

EI ใหม่ (%) - EI เดิม (%) คือ %ประสิทธิภาพของแบบจำลองใหม่ที่เพิ่มขึ้นหรือลดลง จากแบบจำลองเดิม

100 - EI เดิม (%) คือ %ปรากฏการณ์ที่เหลือ ที่แบบจำลองเดิมยังไม่สามารถอธิบายได้

ดังนั้นอัตราการเปลี่ยนแปลงค่าประสิทธิภาพของแบบจำลองจะหมายถึง ปรากฏการณ์ที่ตัวแปรใหม่ได้อธิบายเพิ่มขึ้นเปรียบเทียบกับปรากฏส่วนที่เหลือที่ยังอธิบายไม่ได้จากตัวแปรชุดเดิม โดยตัวอย่างการคำนวณแสดงได้ดังต่อไปนี้ จากตาราง 6-3

Model 1: ตัวแปรนำเข้า  $Q_1$  มีประสิทธิภาพในช่วงปรับเทียบเท่ากับ 77.63 %

Model 2: ตัวแปรนำเข้า  $Q_1$  และ  $Q_{1,1}$  มีประสิทธิภาพในช่วงปรับเทียบเท่ากับ 78.43 %

ตาราง 6-3 ผลการทดสอบตัวแปรนำเข้าสำหรับพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า 1 วัน ณ สถานี 150401 ในช่วงฤดูฝน

Statistic of Basin	Train Period	Test Period
$Q_{avg}$ (m <sup>3</sup> /s)	28.25	23.79
Std. (m <sup>3</sup> /s)	35.87	27.79
Max (m <sup>3</sup> /s)	548.0	194
Min (m <sup>3</sup> /s)	0.0	0.0

Station : 150401 (Area 1)

DA : 636 Km<sup>2</sup> n : 10,000 Intervals

Forecast : 1 Day Ahead Hidden Layer : 3 Nodes (1 Layer)

Training Period No. : 4916 Momentum (α) : 0.45:0.95 (Change at 5000 Intervals)

Testing Period No. : 642 Learning Rate (η) : 0.01

Models	Input Variables	Training					Testing					Remark
		EI (%)	Rate of Improvement (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	Rate of Improvement (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	
1	Q <sub>t</sub>	77.63	-	16.97	6.87	416.7	70.77	-	15.39	6.92	143.7	
2	Q <sub>t</sub> , R <sub>t-1</sub>	78.43	3.58	16.66	6.69	403.6	70.86	0.30	15.19	6.80	143.2	Compare with M1
3	Q <sub>t</sub> , R <sub>t</sub>	82.56	22.01	14.98	6.10	288.0	72.87	7.18	14.48	6.31	145.3	Compare with M1
4	Q <sub>t</sub> , R <sub>t-1</sub>	78.79	5.18	16.52	6.65	393.1	71.15	1.31	15.28	6.78	143.6	Compare with M1
5	Q <sub>t</sub> , R <sub>t-1</sub> , R <sub>t-2</sub>	77.92	1.29	16.86	6.77	416.9	70.65	-0.39	15.43	6.92	143.6	Compare with M1
6	Q <sub>t</sub> , R <sub>t</sub> , R <sub>t-1</sub> , R <sub>t-2</sub>	82.99	23.93	14.90	6.18	253.7	73.57	9.59	14.29	6.47	145.2	Compare with M1
7	Q <sub>t</sub> , R <sub>t</sub> , R <sub>t-1</sub> , R <sub>t-1</sub> , R <sub>t-2</sub>	83.13	0.83	14.74	6.13	244.0	72.74	-3.15	14.51	6.52	145.2	Compare with M6

ตาราง 6-4 ผลการทดสอบตัวแปรนำเข้าสำหรับพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า 1 วัน ณ สถานี KGT.14 ในช่วงฤดูฝน

Station :	KGT.14 (Area 2)	
DA :	336 km <sup>2</sup>	n : 10,000 Intervals
Forecast :	1 Day Ahead	Hidden Layer : 3 Nodes (1 Layer)
Training Period No. :	49:6	Momentum (α) : 0.45:0.95 (Change at 5000 Intervals)
Testing Period No. :	642	Learning Rate (η) : 0.01

Statistic of Basin	Train Period	Test Period
Q <sub>avg</sub> (m <sup>3</sup> /s)	7.23	6.87
Std. (m <sup>3</sup> /s)	14.28	11.44
Max (m <sup>3</sup> /s)	286.9	120.62
Min (m <sup>3</sup> /s)	0.0	0.0

Models	Input Variables	Training					Testing					Remark
		EI (%)	Rate of Improvement (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	Rate of Improvement (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	
1	Q2 <sub>t</sub>	46.13	-	10.48	3.96	235.6	48.43	-	8.22	3.78	76.9	
2	Q2 <sub>t-1,t</sub>	47.26	2.10	10.37	3.90	227.2	47.69	-1.43	8.28	3.80	75.2	Compare with M2
3	Q2 <sub>t</sub> , R2 <sub>t</sub>	70.31	44.88	7.78	3.08	118.7	68.51	38.93	6.42	2.92	58.0	Compare with M3
4	Q2 <sub>t</sub> , R2 <sub>t-1</sub>	48.16	0.06	10.48	3.94	235.4	48.65	0.43	8.20	3.76	78.8	Compare with M1
5	Q2 <sub>t-1,t-1</sub> , R2 <sub>t-1,t-1</sub>	70.57	0.88	7.75	3.16	119.3	68.40	-0.32	6.43	3.06	59.8	Compare with M3

ตาราง 6-5 ผลการทดสอบตัวแปรนำเข้าสำหรับพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า 1 วัน ณ สถานี KGT.15A ในช่วงฤดูฝน

Statistic of Basin	Train Period	Test Period
$Q_{avg}$ (m <sup>3</sup> /s)	19.58	22.04
Std. (m <sup>3</sup> /s)	29.90	30.86
Max (m <sup>3</sup> /s)	492.7	219.41
Min (m <sup>3</sup> /s)	0.0	0.0

Station : KGT.15A (Area 3)  
 DA : 530 Km<sup>2</sup> n : 10,000 Intervals  
 Forecast : 1 Day Ahead Hidden Layer : 3 Nodes (1 Layer)  
 Training Period No. : 4916 Momentum (α) : 0.45:0.95 (Change at 5000 Intervals)  
 Testing Period No. : 642 Learning Rate (η) : 0.01

Models	Input Variables	Training					Testing					Remark
		EI (%)	Rate of Improvement (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	Rate of Improvement (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	
1	Q3 <sub>t</sub>	67.55	-	17.03	7.65	382.2	61.44	-	19.16	9.00	204.1	
2	Q3 <sub>t-1</sub>	70.91	10.35	16.13	7.28	346.9	61.85	1.08	19.31	8.79	204.3	Compare with M1
3	Q3 <sub>t-1,t-2</sub>	71.79	3.03	15.88	7.20	346.2	61.32	-1.41	19.19	8.85	204.6	Compare with M2
4	Q3 <sub>t</sub> , R3 <sub>t</sub>	79.75	37.58	13.46	6.16	286.5	77.93	42.77	14.50	6.39	137.9	Compare with M1
5	Q3 <sub>t</sub> , R3 <sub>t-1</sub>	69.95	7.38	16.39	7.54	344.2	61.83	1.01	19.06	8.95	204.3	Compare with M1
6	Q3 <sub>t</sub> , R3 <sub>t-2</sub>	66.47	2.82	16.79	7.52	371.5	61.66	0.57	19.35	8.82	204.0	Compare with M1
7	Q3 <sub>t</sub> , R3 <sub>t-1,t-2</sub>	81.51	36.43	12.82	5.93	269.6	78.56	43.80	14.52	6.27	139.7	Compare with M1
8	Q3 <sub>t-1,t-2</sub> , R3 <sub>t-1,t-2</sub>	82.03	2.80	12.68	5.80	250.3	78.18	-1.78	14.62	6.35	143.3	Compare with M7



ตาราง 6-6 ผลการทดสอบตัวแปรนำเข้าสำหรับพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า 1 วัน ณ สถานี KGT.12 ในช่วงฤดูฝน

Station :	KGT.12	(Area 4)
DA :	1,540	km <sup>2</sup>
Forecast :	1	Day Ahead
Training Period No. :	4916	Momentum (α) : 0.45; 0.95 (Change at 5000 intervals)
Testing Period No. :	642	Learning Rate (η) : 0.01
		n : 10,000 Intervals
		Hidden Layer : 3 Nodes (1 Layer)
Statistic of Basin	Q <sub>avg</sub> (m <sup>3</sup> /s)	Train Period
	Std. (m <sup>3</sup> /s)	Test Period
	Max (m <sup>3</sup> /s)	
	Min (m <sup>3</sup> /s)	

Models	Input Variables	Training					Testing					Remark
		EI (%)	Rate of Improvement (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	Rate of Improvement (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	
1	Q4 <sub>t</sub>	96.19	-	9.13	4.79	160.4	95.91	-	7.18	4.09	41.0	
2	Q4 <sub>t-1,t-1</sub>	98.22	53.35	6.23	3.13	144.7	97.80	46.22	5.26	2.94	39.2	Compare with M1
3	Q4 <sub>t-1,t-1,t-2</sub>	97.30	-52.10	7.69	5.62	141.7	96.50	-59.07	6.64	5.28	39.9	Compare with M2
4	Q4 <sub>t</sub> , R4 <sub>t</sub>	96.58	10.10	8.78	4.64	141.9	95.99	2.17	7.10	3.89	43.1	Compare with M1
5	Q4 <sub>t</sub> , R4 <sub>t-1</sub>	96.90	18.55	8.24	4.29	157.1	96.35	10.81	6.78	3.73	35.8	Compare with M1
6	Q4 <sub>t</sub> , R4 <sub>t-2</sub>	96.83	18.67	8.33	4.35	168.9	96.36	11.17	6.76	3.76	39.9	Compare with M1
7	Q4 <sub>t</sub> , R4 <sub>t-3</sub>	96.88	12.80	8.52	4.52	155.6	96.33	10.45	6.79	3.92	39.4	Compare with M1
8	Q4 <sub>t</sub> , R4 <sub>t-4</sub>	96.53	8.94	8.71	4.59	133.4	95.96	1.42	7.13	4.05	37.3	Compare with M1
9	Q4 <sub>t</sub> , R4 <sub>t-5</sub>	96.44	6.49	8.73	4.61	133.5	95.99	1.95	7.11	4.01	37.2	Compare with M1
10	Q4 <sub>t</sub> , R4 <sub>t-6</sub>	96.23	1.09	9.08	4.71	159.9	95.96	1.31	7.13	4.02	40.7	Compare with M1
11	Q4 <sub>t</sub> , R4 <sub>t-1,t-2</sub>	98.71	28.89	5.24	2.76	114.0	98.34	24.47	4.57	2.57	34.9	Compare with M2
12	Q4 <sub>t-1,t-1,t-2</sub> , R4 <sub>t-1,t-1,t-2</sub>	98.76	1.58	5.23	2.76	113.0	98.04	-16.04	4.76	2.99	35.3	Compare with M11

ตาราง 6-7 ผลการทดสอบตัวแปรนำเข้าสำหรับพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า 1 วัน ณ สถานี KGT.10 ในช่วงฤดูฝน

Station :	KGT.10 (Area 5)	
DA :	2,523 Km <sup>2</sup> n : 10,000 Intervals	
Forecast :	1 Day Ahead Hidden Layer : 3 Nodes (1 Layer)	
Training Period No. :	4916 Momentum (α) : 0.45-0.95 (Change at 5000 Intervals)	
Testing Period No. :	642 Learning Rate (η) : 0.01	
Statistic of Basin	Train Period	Test Period
Q <sub>avg</sub> (m <sup>3</sup> /s)	45.25	37.94
Std. (m <sup>3</sup> /s)	69.56	48.98
Max (m <sup>3</sup> /s)	960.0	301
Min (m <sup>3</sup> /s)	0.0	0.0

Models	Input Variables	Training					Testing					Remark
		EI (%)	Rate of Improvement (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	Rate of Improvement (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	
1	Q5 <sub>t</sub>	85.87	-	26.15	12.57	675.8	86.57	-	17.95	10.31	104.5	
2	Q5 <sub>t-1</sub>	89.11	22.95	22.95	11.16	624.1	88.91	17.39	16.31	9.76	88.6	Compare with M1
3	Q5 <sub>t-1,t-2</sub>	89.38	2.51	22.67	10.71	618.4	89.77	7.81	15.66	9.26	81.9	Compare with M2
4	Q5 <sub>t</sub> , R5 <sub>t</sub>	86.92	7.45	25.16	11.90	667.5	86.57	-0.05	17.95	10.03	97.8	Compare with M1
5	Q5 <sub>t</sub> , R5 <sub>t-1</sub>	88.54	18.93	23.55	11.29	581.2	88.86	17.05	16.35	8.87	98.8	Compare with M1
6	Q5 <sub>t</sub> , R5 <sub>t-2</sub>	87.96	14.84	24.13	11.89	569.2	88.43	13.84	16.66	9.39	86.8	Compare with M1
7	Q5 <sub>t</sub> , R5 <sub>t-3</sub>	86.19	2.29	25.85	12.52	694.6	86.79	1.60	17.80	10.24	101.0	Compare with M1
10	Q5 <sub>t-1,t-2</sub> , R5 <sub>t-1,t-2</sub>	91.20	19.19	20.55	10.17	515.5	91.26	21.19	14.48	8.36	73.5	Compare with M2
11	Q5 <sub>t-1,t-2</sub> , R5 <sub>t-1,t-2,t-3</sub>	91.60	4.55	20.03	9.92	512.2	91.33	0.79	14.35	8.14	73.6	Compare with M10

ตาราง 6-8 ผลการทดสอบแบบปรับนำเข้าสู่สำหรับพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า 1 วัน ณ สถานี KGT.3 ในช่วงฤดูฝน

Station :	KGT.3 (Area 6)	Statistic of Basin	Train Period	Test Period
DA :	7.502 Km <sup>2</sup>	Q <sub>avg</sub> (m <sup>3</sup> /s)	177.40	176.19
Forecast :	1 Day Ahead	Std. (m <sup>3</sup> /s)	198.28	169.85
Training Period No. :	4916	Max (m <sup>3</sup> /s)	1754.0	502.1
Testing Period No. :	642	Min (m <sup>3</sup> /s)	0.0	0.0

Hidden Layer :	3	Nodes	(1 Layer)
Momentum (α) :	0.45-0.95	(Change at 5000 Intervals)	
Learning Rate (η) :	0.01		

Models	Input Variables	Training					Testing					Remark
		EI (%)	Rate of Improvement (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	Rate of Improvement (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	
1	Q6 <sub>t</sub>	96.75	-	35.76	19.81	1142.5	96.93	-	29.76	17.93	266.7	Compare with M1
2	Q6 <sub>t,t-1</sub>	97.86	34.07	29.04	14.67	1007.1	97.88	30.94	24.73	13.90	218.1	Compare with M1
3	Q6 <sub>t,t-1,t-2</sub>	97.86	0.02	28.03	16.48	982.5	97.95	3.11	24.34	12.85	218.6	Compare with M2
4	Q6 <sub>t</sub> , R6 <sub>t</sub>	97.20	13.89	33.18	18.05	1143.2	97.51	18.95	26.79	16.40	246.7	Compare with M1
5	Q6 <sub>t</sub> , R6 <sub>t,t-1</sub>	97.90	35.58	28.70	16.32	816.3	98.27	43.76	22.32	14.36	121.3	Compare with M1
6	Q6 <sub>t</sub> , R6 <sub>t,t-2</sub>	97.28	16.47	32.68	17.97	1007.8	97.09	5.09	28.99	16.94	266.0	Compare with M1
7	Q6 <sub>t</sub> , R6 <sub>t,t-3</sub>	96.91	5.07	35.18	19.18	1149.7	96.98	1.47	29.54	17.33	270.8	Compare with M1
8	Q6 <sub>t</sub> , R6 <sub>t,t-4</sub>	96.79	1.41	35.51	19.51	1145.5	96.94	0.29	29.72	17.65	265.0	Compare with M1
9	Q1 <sub>t</sub> , Q2 <sub>t</sub> , Q3 <sub>t</sub> , Q4 <sub>t</sub> , Q5 <sub>t</sub>	95.25	-	43.23	25.75	531.0	95.28	-	36.91	23.31	177.7	ไม่เหมาะสมเนื้อหา
10	Q1 <sub>t,t-1,t-2,t-3,t-4,t-5</sub> , Q2 <sub>t,t-1,t-2,t-3,t-4,t-5</sub> , Q3 <sub>t,t-1,t-2,t-3,t-4,t-5</sub> , Q4 <sub>t,t-1,t-2,t-3,t-4,t-5</sub> , Q5 <sub>t,t-1,t-2,t-3,t-4,t-5</sub>	95.36	2.82	44.42	26.75	461.6	95.35	1.56	36.62	23.09	163.0	Compare with M9
11	Q6 <sub>t,t-1,t-2,t-3,t-4,t-5</sub> , Q1 <sub>t</sub> , Q2 <sub>t</sub> , Q3 <sub>t</sub> , Q4 <sub>t</sub> , Q5 <sub>t</sub> , R6 <sub>t,t-1,t-2,t-3,t-4,t-5</sub>	96.03	54.59	19.57	11.26	619.7	99.10	57.57	16.11	10.39	119.5	Compare with M10
12	Q6 <sub>t,t-1,t-2,t-3,t-4,t-5</sub> , Q1 <sub>t</sub> , Q2 <sub>t</sub> , Q3 <sub>t</sub> , Q4 <sub>t</sub> , Q5 <sub>t</sub> , R6 <sub>t,t-1,t-2,t-3,t-4,t-5</sub>	98.97	-5.68	19.59	11.34	621.2	98.80	-33.35	16.43	11.04	135.3	Compare with M11

$$\text{Rate of improvement (\%)} = \frac{78.43 - 77.63}{100 - 77.63} \times 100 = 3.58\%$$

โดยถ้าค่าอัตราการเปลี่ยนแปลงค่าประสิทธิภาพของแบบจำลองมีค่าเป็นบวก แสดงว่าตัวแปรใหม่ที่เพิ่มเข้าไปสามารถอธิบายปรากฏการณ์ส่วนที่เหลืออยู่ได้เพิ่มขึ้น แต่ถ้าค่าอัตราการเปลี่ยนแปลงค่าประสิทธิภาพของแบบจำลองมีค่าเป็นลบ แสดงว่าตัวแปรใหม่ที่เพิ่มเข้าไปนั้นไม่สามารถอธิบายปรากฏการณ์ส่วนที่เหลืออยู่ได้ ในการศึกษาครั้งนี้จะถือว่าตัวแปรที่เพิ่มขึ้นมาใหม่ที่ทำให้ค่าอัตราการเปลี่ยนแปลงค่าประสิทธิภาพของแบบจำลอง มีค่ามากกว่า 5% (ระดับความเชื่อมั่น 95%) เป็นตัวแปรที่มีนัยสำคัญต่อการนำไปเป็นข้อมูลนำเข้าสู่แบบจำลอง การใช้ค่าอัตราการเปลี่ยนแปลงค่าประสิทธิภาพของแบบจำลองเป็นเกณฑ์ในการตัดสินใจตัดสินสุดตัวแปรนำเข้านั้น เนื่องจากวิธีนี้แสดงให้เห็นถึงความสำคัญของตัวแปรต่างๆ ที่มีต่อ  $Q_{t+1}$  ได้อย่างชัดเจน สำหรับรายละเอียดผลการทดสอบนั้น ขอกล่าวแยกเป็นสถานีฯ ดังนี้

สถานี 150401 เป็นสถานีวัดน้ำท่าที่ออกจากกลุ่มน้ำใส่น้อย-ใสใหญ่ จากตาราง 6-3 จะเห็นว่าตัวแปรนำเข้าที่มีนัยสำคัญ ได้แก่  $Q_{1t}$ ,  $R_{1t}$  และ  $R_{1,t-1}$  โดยตัวแปรที่มีนัยสำคัญมากที่สุดคือ  $Q_{1t}$  รองลงมา คือ  $R_{1t}$  และ  $R_{1,t-1}$  และเมื่อนำตัวแปรเหล่านี้มารวมกันเป็นชุดตัวแปรนำเข้า (M6) จะทำให้แบบจำลองมีประสิทธิภาพ 82.99% ในช่วงปรับเทียบ และ 73.57% ในช่วงปรับทาน สำหรับค่าความคลาดเคลื่อนในการพยากรณ์ซึ่งวัดได้จากตัวแปรทางสถิติ มีค่าดังนี้ ในช่วงปรับเทียบ มีค่า RMSE = 14.80 ม.<sup>3</sup>/วินาที, MAD = 6.18 ม.<sup>3</sup>/วินาที และค่า Max absolute error = 253.7 ม.<sup>3</sup>/วินาที ในช่วงปรับทานแบบจำลองมีค่า RMSE=14.29 ม.<sup>3</sup>/วินาที, MAD=6.47 ม.<sup>3</sup>/วินาที และค่า Max absolute error =145.2 ม.<sup>3</sup>/วินาที

สถานี KGT.14 เป็นสถานีวัดน้ำท่าที่ออกจากกลุ่มน้ำลำพระยาธาร จากตาราง 6-4 จะเห็นว่า ตัวแปรนำเข้าที่มีนัยสำคัญ ได้แก่  $Q_{2t}$  และ  $R_{2t}$  ซึ่งจะสังเกตได้ว่า เมื่อเพิ่มตัวแปรนำเข้า  $R_{2t}$  เข้ามาในแบบจำลอง M3 จะทำให้แบบจำลองมีประสิทธิภาพ และอัตราการเปลี่ยนแปลงประสิทธิภาพเพิ่มขึ้นอย่างมาก ทั้งในช่วงปรับเทียบและปรับทาน โดยประสิทธิภาพของแบบจำลองจะเพิ่มขึ้นจาก 46.13% เป็น 70.31% (เพิ่มขึ้น 29.18%) ในช่วงปรับเทียบ และเพิ่มขึ้นจาก 48.93% เป็น 68.51% (เพิ่มขึ้น 20.08%) ในช่วงปรับทาน และมีอัตราการเปลี่ยนแปลงประสิทธิภาพเท่ากับ 44.88% ในช่วงปรับเทียบ และ 38.93% ในช่วงปรับทาน ซึ่งมีค่ามากที่สุดเมื่อเทียบกับสถานีวัดอื่นๆ ทั้งนี้แสดงให้เห็นว่าปริมาณฝนเฉลี่ยทั่วทั้งพื้นที่ ณ วันปัจจุบันมีความสำคัญมากต่อการพยากรณ์  $Q_{t+1}$  ในกลุ่มน้ำลำพระยาธาร สำหรับค่าคลาดเคลื่อนในการพยากรณ์  $Q_{t+1}$  ของแบบ

จำลอง M3 มีดังนี้ ในช่วงปรับเทียบมีค่า  $RMSE = 7.78 \text{ ม.}^3/\text{วินาที}$ ,  $MAD = 3.08 \text{ ม.}^3/\text{วินาที}$  และ  $\text{Max absolute error} = 118.7 \text{ ม.}^3/\text{วินาที}$  และในช่วงปรับทานมีค่า  $RMSE = 6.42 \text{ ม.}^3/\text{วินาที}$ ,  $MAD = 2.92 \text{ ม.}^3/\text{วินาที}$  และ  $\text{Max absolute error} = 58.0 \text{ ม.}^3/\text{วินาที}$

นอกจากนี้ยังพบว่า ค่าประสิทธิภาพของแบบจำลองในการพยากรณ์  $Q_{t+1}$  ณ สถานีวัด KGT.14 มีค่าน้อยที่สุด เมื่อเทียบกับสถานีวัดอื่นๆ ทั้งนี้เนื่องจากลักษณะกราฟน้ำท่าของกลุ่มน้ำลำพระยาธาร มีลักษณะขึ้นลงอย่างรวดเร็ว ในระยะเวลาอันสั้น ดังนั้นในการใช้ข้อมูลรายวันมาใช้ในการพยากรณ์ อาจจะไม่เหมาะสมมากนัก

สถานี KGT.15A เป็นสถานีวัดน้ำท่าที่ออกจากกลุ่มน้ำห้วยโสมง จากตาราง 6-5 พบว่าตัวแปรนำเข้าที่มีนัยสำคัญ คือ  $Q3_t$ ,  $Q3_{t-1}$ ,  $R3_t$  และ  $R3_{t-1}$  ซึ่งจะสังเกตได้ว่ามีตัวแปรนำเข้านั้นคล้ายกับสถานี 150401 ทั้งนี้อาจเนื่องจากมีพื้นที่ลุ่มน้ำทั้ง 2 มีขนาดใกล้เคียงกัน แต่จะแตกต่างกันที่สถานี KGT.15A มีตัวแปรนำเข้า  $Q3_t$  เพิ่มขึ้นมา และเมื่อเปรียบเทียบค่านัยสำคัญของตัวแปรนำเข้า พบว่าตัวแปรนำเข้า  $Q3_t$  ของสถานี KGT.15A มีนัยสำคัญน้อยกว่า  $Q2_t$  ของสถานี 150401 แต่ตัวแปรนำเข้า  $R3_t$  และ  $R3_{t-1}$  ของสถานี KGT.15 มีนัยสำคัญมากกว่า  $R2_t$  และ  $R2_{t-1}$  ของสถานี 150401 ทั้งนี้อาจเนื่องจากพื้นที่ลุ่มน้ำทั้ง 2 มีลักษณะกายภาพของที่แตกต่างกัน เช่น ความชัน ความยาวลำน้ำ (รูป ก-2 และ ก-3) โดยค่าประสิทธิภาพและค่าความคลาดเคลื่อนในการพยากรณ์ของแบบจำลอง M7 มีดังนี้ ในช่วงปรับเทียบ  $EI = 81.51\%$ ,  $RMSE = 12.82 \text{ ม.}^3/\text{วินาที}$ ,  $MAD = 5.93 \text{ ม.}^3/\text{วินาที}$  และ  $\text{Max absolute error} = 259.8 \text{ ม.}^3/\text{วินาที}$  สำหรับในช่วงปรับทานจะมีค่า  $EI = 78.56\%$ ,  $RMSE = 14.62 \text{ ม.}^3/\text{วินาที}$ ,  $MAD = 6.27 \text{ ม.}^3/\text{วินาที}$  และ  $\text{Max absolute error} = 139.7 \text{ ม.}^3/\text{วินาที}$  ซึ่งมีค่าใกล้เคียงกับแบบจำลอง M6 ของสถานีวัด 150401

สถานี KGT.12 เป็นสถานีวัดน้ำท่าที่ออกจากกลุ่มน้ำพระปรองตอนบน จากตาราง 6-6 พบว่าตัวแปรนำเข้าที่มีนัยสำคัญ คือ  $Q4_t$ ,  $Q4_{t-1}$  และ  $R4_t$  ถึง  $R4_{t-5}$  (จำนวน 8 ตัว) ซึ่งจะเห็นได้ว่าจำนวนตัวแปรนำเข้าของสถานีนี้มีจำนวนมากกว่า 3 สถานีที่ผ่านมามาก ทั้งนี้เนื่องจากลักษณะกราฟน้ำท่าของกลุ่มน้ำพระปรองตอนบนมีลักษณะขึ้นลงอย่างช้าๆ ไม่ผันแปรมากเมื่อเทียบกับกลุ่มน้ำใส่น้อย-ใสใหญ่, ลำพระยาธาร และห้วยโสมง (พิจารณากราฟ d จากรูป 6-1 ถึง 6-4 ประกอบ) ทั้งนี้อาจเนื่องจากพื้นที่ลุ่มน้ำของพระปรองตอนบนมีขนาดใหญ่ และมีความชันน้อยมาก (รูป ก-3) ทำให้ฝนที่ตกลงมาค่อยๆเปลี่ยนแปลงเป็นน้ำท่า

จากตาราง 6-6 จะเห็นได้ว่า ตัวแปรนำเข้า  $Q_t$  มีนัยสำคัญสูงมากในการพยากรณ์  $Q_{t+1}$  เมื่อเทียบกับ 3 สถานีที่ได้กล่าวมา คือ จะทำให้แบบจำลองมีประสิทธิภาพสูงถึง 96.19% และ 95.91% ในช่วงปรับเทียบและปรับทานตามลำดับ แต่เมื่อเพิ่มตัวแปรนำเข้าที่เป็นฝนเฉลี่ยทั่วทั้ง

พื้นที่รายวันย้อนหลังเข้ามา พบว่า อัตราการเปลี่ยนแปลงประสิทธิภาพของแบบจำลองมีค่าเพิ่มขึ้นอยู่ระหว่าง 6-18% (ช่วงปรับเทียบ) และ 2-11% (ช่วงปรับทาน) ซึ่งเห็นได้ว่าตัวแปรนำเข้าดังกล่าวมีนัยสำคัญที่จะนำไปใช้พยากรณ์  $Q_{t+1}$  น้อยกว่า 3 สถานีที่ได้กล่าวมา โดยประสิทธิภาพและค่าความคลาดเคลื่อนในการพยากรณ์ของแบบจำลอง ที่ใช้ตัวแปรนำเข้าที่มีนัยสำคัญทั้งหมด (M11) แสดงได้ดังนี้ ในช่วงปรับเทียบ ค่า EI = 98.74%, RMSE = 5.24 ม.<sup>3</sup>/วินาที, MAD = 2.76 ม.<sup>3</sup>/วินาที และ Max absolute error = 114.0 ม.<sup>3</sup>/วินาที ในช่วงปรับทาน ค่า EI = 98.34%, RMSE = 4.57 ม.<sup>3</sup>/วินาที, MAD = 2.57 ม.<sup>3</sup>/วินาที และ Max absolute error = 34.9 ม.<sup>3</sup>/วินาที

สถานี KGT.10 เป็นสถานีวัดน้ำท่าที่ออกจากกลุ่มน้ำคลองพระสทิง จากตาราง 6-7 พบว่า ตัวแปรนำเข้าที่มีนัยสำคัญคือ  $Q5_t$ ,  $Q5_{t-1}$  และ  $R5_t$  ถึง  $R5_{t-2}$  (จำนวน 5 ตัว) ซึ่งเป็นที่น่าสังเกตว่าพื้นที่ลุ่มน้ำคลองพระสทิงมีขนาดใหญ่กว่าลุ่มน้ำพระปรองตอนบน เกือบถึง 2 เท่า แต่แบบจำลองของสถานี KGT.10 กลับใช้ตัวแปรนำเข้าที่เป็นจำนวนวันย้อนหลังของปริมาณฝนเฉลี่ยทั่วทั้งพื้นที่รายวันน้อยกว่าสถานีวัด KGT.12 โดยที่ KGT.10 ใช้จำนวนวันย้อนหลัง 3 วัน และที่ KGT.12 ใช้จำนวนวันย้อนหลัง 6 วัน ทั้งนี้อาจสืบเนื่องมาจากความชันของพื้นที่ลุ่มน้ำคลองพระสทิง (KGT.10) มีค่ามากกว่าพื้นที่ลุ่มน้ำคลองพระปรองตอนบน (KGT.12) และสภาพธรณีวิทยาของลุ่มน้ำคลองพระสทิงที่มีสภาพพื้นที่เป็นทิวเขาส่วนใหญ่ (รูป 4-1) จึงทำให้ความสามารถดูดซับน้ำได้น้อยกว่าลุ่มน้ำคลองพระปรองตอนบน เป็นผลให้ฝนที่ตกในลุ่มน้ำคลองพระสทิงใช้เวลาในการแปลงสภาพเป็นน้ำท่าน้อยกว่าฝนที่ตกในลุ่มน้ำพระปรองตอนบน (กราฟ d รูป 6-5 และ 6-6) แต่เมื่อพิจารณาค่านัยสำคัญของตัวแปรนำเข้าของสถานี KGT.10 กับ KGT.12 พบว่ามีลักษณะคล้ายกัน คือ  $Q5_t$  จะมีนัยสำคัญสูงมากที่สุดเมื่อเทียบกับ  $R5_t$  ถึง  $R5_{t-2}$  โดยประสิทธิภาพของแบบจำลองและค่าคลาดเคลื่อนในการพยากรณ์  $Q_{t+1}$  ของแบบจำลอง M10 มีค่าดังนี้ในช่วงปรับเทียบ EI = 91.20%, RMSE = 20.55 ม.<sup>3</sup>/วินาที, MAD = 10.17 ม.<sup>3</sup>/วินาที และ Max absolute error = 515.5 ม.<sup>3</sup>/วินาที ในช่วงปรับทาน EI = 91.26%, RMSE = 14.48 ม.<sup>3</sup>/วินาที MAD = 8.38 ม.<sup>3</sup>/วินาที และ Max absolute error = 74.1 ม.<sup>3</sup>/วินาที


สถานี KGT.3 เป็นสถานีวัดน้ำท่าที่ออกจากลุ่มน้ำหุมนานและคลองพระปรอง จากตาราง 6-8 ได้แบ่งการทดสอบตัวแปรนำเข้าสำหรับพยากรณ์  $Q_{t+1}$  ออกเป็น 3 กรณีหลัก คือ

1) ใช้ตัวแปรนำเข้าเป็นอัตราการไหลน้ำท่ารายวันของสถานีตัวมันเองย้อนหลังและปริมาณฝนเฉลี่ยทั่วทั้งพื้นที่รายวันย้อนหลัง (เฉพาะพื้นที่ย่อยที่ 6 รูป 4-1)

2) ใช้ตัวแปรนำเข้าเป็นอัตราการไหลน้ำท่ารายวันย้อนหลังของสถานีวัดที่ตั้งอยู่ด้านเหนือ  
น้ำ อันได้แก่ สถานี 150401, KGT.14, KGT.15A, KGT.12 และ KGT.10

3) รวมกรณี (1) กับ (2)

จากผลการพยากรณ์พบว่าแบบจำลองที่สร้างขึ้นด้วยชุดตัวแปรนำเข้าในกรณีที่ 1 (M1-M8) จะให้ค่า EI สูงกว่า และให้ค่า RMSE กับ MAD ต่ำกว่าแบบจำลองที่ใช้ชุดตัวแปรนำเข้าในกรณีที่ 2 (M9 และ M10) แต่เป็นที่น่าสังเกตว่าแบบจำลองที่สร้างขึ้นด้วยชุดตัวแปรนำเข้าในกรณีที่ 2 จะให้ค่า Max absolute error น้อยกว่าแบบจำลองที่ใช้ชุดตัวแปรนำเข้าในกรณีที่ 1 อย่างชัดเจน ทั้งนี้อาจสืบเนื่องมาจากการพยากรณ์โดยใช้ตัวแปรนำที่เป็นการไหลน้ำท่าของสถานีตัวมันเอง (กรณีที่ 1) จะมีความแม่นยำของการพยากรณ์ในเรื่องของปริมาณอัตราการไหลน้ำท่ารายวันมากกว่าแบบจำลองที่ใช้ตัวแปรนำเข้าที่เป็นอัตราการไหลน้ำท่าของสถานีที่ตั้งอยู่เหนือน้ำ (กรณีที่ 2) แต่จะให้ความแม่นยำน้อยกว่า ในเรื่องของเวลาการเกิดอัตราการไหลสูงสุด (peak flow) ของกราฟน้ำท่าแต่ละลูก ดังรูป 6-7 เป็นการเปรียบเทียบผลการพยากรณ์ ณ เวลาการเกิดอัตราการไหลน้ำท่าสูงสุดของกราฟน้ำท่าลูกหนึ่งจากแบบจำลอง ANN ที่ใช้ชุดตัวแปรนำเข้าต่างกันทั้ง 3 กรณี กับข้อมูลที่วัดจริง



รูป 6-7 เปรียบเทียบค่าความผิดพลาดในการพยากรณ์  $Q_{t+1}$  ในฤดูฝน ณ สถานี KGT.3 จากแบบจำลอง M2, M9 และ M11

เมื่อนำตัวแปรนำเข้าทั้ง 2 กรณีมารวมกันจัดสร้างเป็นแบบจำลองขึ้นมาใหม่นั้น (M11) ส่งผลทำให้ผลการพยากรณ์มีประสิทธิภาพสูงขึ้นถึง 99.03% และ 99.10% ในช่วงปรับเทียบและปรับทานตามลำดับ และมีค่าคลาดเคลื่อนในการพยากรณ์ลดลงดังต่อไปนี้ ในช่วงปรับเทียบมีค่า RMSE = 19.57 ม.<sup>3</sup>/วินาที, MAD = 19.57 ม.<sup>3</sup>/วินาที และ Max absolute error = 619.7 ม.<sup>3</sup>/วินาที ในช่วงปรับทาน RMSE = 16.11 ม.<sup>3</sup>/วินาที, MAD = 10.39 ม.<sup>3</sup>/วินาที และ Max absolute error = 119.8 ม.<sup>3</sup>/วินาที ซึ่งมีค่าน้อยมากเมื่อเทียบกับค่าเบี่ยงเบนมาตรฐาน (std.) ของอัตราการไหลน้ำท่ารายวัน ณ สถานีวัด KGT.3 ซึ่งมีค่าเท่ากับ 198.28 ม.<sup>3</sup>/วินาที และ 169.85 ม.<sup>3</sup>/วินาที ในช่วงปรับเทียบและปรับทานตามลำดับ โดยตัวแปรนำเข้าที่มีนัยสำคัญที่ใช้ในแบบจำลอง M11 คือ Q6, Q6<sub>t-1</sub>, Q1, Q2, Q3, Q4, Q5, R6, R6<sub>t-1</sub>, R6<sub>t-2</sub> และ R6<sub>t-3</sub> มีทั้งหมด 11 ตัวแปร

นอกจากนี้ จากตาราง 6-3 ถึง 6-8 ยังสังเกตได้ว่าเมื่อเพิ่มตัวแปรนำเข้าที่เป็นปริมาณฝนเฉลี่ยทั่วทั้งพื้นที่รายวันย้อนหลังเข้าไปในแบบจำลองต่างๆ ของทุกๆ สถานี จะทำให้ค่า Max absolute error ของการพยากรณ์ลดอย่างชัดเจน ซึ่งอาจเป็นเหตุผลเดียวกันกับที่ได้กล่าวไว้ในผลการทดสอบของสถานี KGT.3 เรื่องการเพิ่มตัวแปรนำเข้าที่เป็นอัตราการไหลน้ำท่ารายวันย้อนหลังของสถานีที่ตั้งอยู่ด้านเหนือ

กล่าวโดยสรุปจากการทดสอบชุดตัวแปรนำเข้ามีประเด็นสำคัญดังนี้

1) จากตาราง 6-3 ถึง 6-5 จะเห็นได้ว่าชุดตัวแปรนำเข้าที่มีนัยสำคัญสำหรับการพยากรณ์ Q<sub>t-1</sub> ณ สถานีวัดน้ำท่าต่างๆ เป็นไปตามชุดตัวแปรที่คัดเลือกมาจากกราฟความสัมพันธ์ต่างๆ ที่ได้กล่าวไว้ในหัวข้อที่ 6.1.1.1 (ตาราง 6-1) แสดงว่าการคัดเลือกตัวแปรนำเข้าที่เป็นอัตราการไหลน้ำท่ารายวันของสถานีตัวมันเองและปริมาณฝนเฉลี่ยทั่วทั้งพื้นที่รายวันย้อนหลัง ด้วยวิธีนี้สามารถนำมาใช้เป็นแนวทางในการคัดเลือกได้ ซึ่งจะทำให้ประหยัดเวลาให้การคัดเลือกตัวแปรนำเข้าเป็นอย่างมาก เมื่อเทียบกับวิธีเดิมที่ต้อง trial & error

2) เมื่อเปรียบเทียบระหว่างจำนวนตัวแปรนำเข้าและค่าความสัมพันธ์ของตัวแปรนำเข้าแต่ละชนิดที่ใช้ในการพยากรณ์ Q<sub>t-1</sub> ระหว่างลุ่มน้ำที่มีพื้นที่ขนาดเล็กและมีความชันมากกับพื้นที่ขนาดใหญ่และมีความชันน้อย พบว่า

- การพยากรณ์อัตราการไหลน้ำท่ารายวันในลุ่มน้ำขนาดใหญ่จะใช้จำนวนตัวแปรนำเข้ามากกว่าการพยากรณ์อัตราการไหลน้ำท่ารายวันในลุ่มน้ำขนาดเล็ก
- ค่าความสัมพันธ์ของตัวแปรนำเข้าชนิดเดียวกันในลุ่มน้ำขนาดใหญ่จะมีค่าสูงกว่าในลุ่มน้ำขนาดเล็ก แต่ค่าความสัมพันธ์ของตัวแปรต่างชนิดกันในลุ่มน้ำขนาดใหญ่จะมีค่าต่ำกว่า



3) ประสิทธิภาพของแบบจำลองในการพยากรณ์นั้นมีความสอดคล้องกับลักษณะของกราฟน้ำท่าในแต่ละพื้นที่ คือ ถ้ากราฟน้ำท่ามีความผันผวนมากหรือมีการเปลี่ยนแปลงอย่างรวดเร็ว ประสิทธิภาพในการพยากรณ์จะต่ำกว่าพื้นที่ที่มีกราฟน้ำท่าที่มีการเปลี่ยนแปลงอย่างช้า หรือมีความผันผวนน้อย และจากตาราง 6-3 ถึง 6-8 สามารถสรุปสถานีที่มีการพยากรณ์  $Q_{n+1}$  ได้แม่นยำจากมากไปน้อย ได้ดังนี้ KGT.3, KGT.12, KGT.10, 150401, KGT.15A และ KGT.14 ซึ่งพิจารณาจากค่าประสิทธิภาพของแบบจำลอง ในช่วงการปรับเทียบ ซึ่งจะมีค่าเป็น 99.03%, 98.74%, 91.20%, 82.99%, 81.51%, และ 70.31% ตามลำดับ

#### 6.1.2 การคัดเลือกค่าพารามิเตอร์และโครงข่ายภายในที่เหมาะสมในแบบจำลอง ANN

จากที่ได้กล่าวไว้ในหัวข้อ 5.1.2 เรื่องการคัดเลือกค่าพารามิเตอร์ที่เหมาะสมในแบบจำลอง ANN อันได้แก่ค่าโมเมนตัมและอัตราการเรียนรู้ โดยการ trial & error นั้นแสดงผลการทดสอบได้ดังตารางที่ 6-9 สำหรับแบบจำลองที่นำมาทดสอบคือแบบจำลอง M11 (ตาราง 6-8) ซึ่งใช้สำหรับพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า 1 วัน ณ สถานี KGT.3 ทั้งนี้เนื่องจากแบบจำลองนี้ใช้ตัวแปรนำเข้ามากกว่าที่สุด ทำให้โครงสร้างของแบบจำลองมีขนาดใหญ่และมีขั้นตอนในการคำนวณมากเมื่อเทียบกับแบบจำลองอื่นๆ ซึ่งจะทำให้เห็นความแตกต่างของผลการทดสอบในแต่ละกรณีอย่างชัดเจนเมื่อปรับเปลี่ยนค่าพารามิเตอร์ต่างๆ

ตาราง 6-9 การคัดเลือกค่าโมเมนตัมและอัตราการเรียนรู้

การคัดเลือกโมเมนตัม เมื่อกำหนด $\eta = 0.010$		การคัดเลือกอัตราการเรียนรู้ เมื่อกำหนด $\alpha = 0.45:0.95$	
โมเมนตัม ( $\alpha$ )	RMSE ( $m^3/วินาที$ )	อัตราการเรียนรู้ ( $\eta$ )	RMSE ( $m^3/วินาที$ )
0.10	29.94	0.001	38.47
0.20	27.02	0.002	33.42
0.30	25.61	0.004	28.77
0.40	24.78	0.006	24.85
0.45	24.35	0.008	22.31
0.50	ลู่ออก	0.010	19.57
0.45:0.75 **	21.24	0.0125	ลู่ออก
0.45:0.85 **	20.86	0.01:0.0125 **	ลู่ออก
0.45:0.95 **	19.57		
0.45:1.00 **	ไม่เสถียร		

หมายเหตุ \*\* คือ ค่าช่วงแรก : ค่าช่วงหลัง และเปลี่ยนที่รอบการคำนวณ 5000 รอบ

จากผลการทดสอบจะเห็นได้ว่าการใช้ค่าโมเมนตัมที่มีค่าไม่มากนักในช่วงแรกของการทดสอบจะช่วยป้องกันการลู่ออกของแบบจำลอง และการเพิ่มค่าโมเมนตัมในช่วงหลังของการทดสอบนั้นจะช่วยทำให้แบบจำลองเข้าสู่ค่าตอบได้ดีขึ้น หรือจะทำให้แบบจำลองมีค่าความคลาดเคลื่อนในการพยากรณ์ (RMSE) น้อยลง สำหรับการทดสอบค่าอัตราการเรียนรู้นั้นจะเห็นได้ว่าค่านี้มีความอ่อนไหวมากซึ่งสังเกตได้จากค่า RMSE ที่จะลดลงอย่างรวดเร็วเมื่อเพิ่มค่าอัตราการเรียนรู้เพียงเล็กน้อย และถ้าหากใช้ค่าอัตราการเรียนรู่มากไปก็จะทำให้แบบจำลองลู่ออกได้ จึงจำเป็นที่จะต้องระมัดระวังเป็นพิเศษในการคัดเลือกหรือปรับเปลี่ยนค่านี้

หลังจากได้คัดเลือกชุดตัวแปรนำเข้าและค่าพารามิเตอร์ที่มีความเหมาะสมแล้ว ในขั้นตอนต่อไปคือการคัดเลือกจำนวนหน่วย และจำนวนชั้นแอบแฝงที่เหมาะสมในแบบจำลอง ANN ตามกรณีที่ได้ตั้งไว้ในหัวข้อ 5.1.2 โดยผลการคัดเลือกสรุปแยกตามสถานีวัดน้ำทำดังตาราง 6-10

ตาราง 6-10 สรุปโครงข่ายภายในที่เหมาะสมในแบบจำลอง ANN สำหรับพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า 1 วัน ในฤดูฝน

สถานีวัดน้ำท่า	จำนวนตัวแปรนำเข้า	จำนวนหน่วยที่เหมาะสม		เปรียบเทียบ		ปรับทวน	
		ชั้นแอบแฝง	ชั้นแอบแฝง	EI	RMSE	EI	RMSE
		ที่ 1	ที่ 2	(%)	(ม. <sup>3</sup> /วินาที)	(%)	(ม. <sup>3</sup> /วินาที)
150401	3	3	-	82.99	14.80	73.57	14.29
KGT.14	2	2	-	70.36	7.78	68.56	6.42
KGT.15A	4	4	-	81.55	12.84	77.42	14.66
KGT.12	8	4	4	98.68	5.36	98.26	4.69
KGT.10	5	3	2	91.36	20.44	91.23	14.51
KGT.3	11	6	5	99.31	16.46	99.23	14.90

สำหรับรายละเอียดการคัดเลือกได้แสดงไว้ในตาราง ค1-1 ถึง ค1-6 ซึ่งจะเห็นได้ว่าจากผลการปรับจำนวนหน่วยและจำนวนชั้นแอบแฝงเพื่อหาโครงข่ายภายในที่เหมาะสมในแบบจำลอง ANN นั้น ไม่ได้ทำให้ประสิทธิภาพของแบบจำลองในการพยากรณ์แตกต่างกันชัดเจนมากนัก ในการพิจารณาโครงข่ายภายในที่เหมาะสม จะพิจารณาจากโครงข่ายที่ทำให้ค่าประสิทธิภาพของแบบจำลองในช่วงปรับเทียบมีค่ามากที่สุดเป็นหลัก

จากตาราง 6-10 พบว่าโครงข่ายภายในที่เหมาะสมในแบบจำลอง ANN นั้น จะมีจำนวนหน่วยทั้งหมดในชั้นแอบแฝงเท่ากับจำนวนตัวแปรนำเข้าสู่แบบจำลอง และจะเห็นได้ว่าแบบจำลองที่มีจำนวนตัวแปรน้อย (1-4 ตัว) จะใช้จำนวนชั้นแอบแฝงเพียงชั้นเดียว ส่วนแบบจำลองที่มี



จำนวนตัวแปรมาก (5-11 ตัว) จะใช้ชั้นแอบแฝง 2 ชั้น ทั้งนี้อาจเนื่องมาจากจำนวนชั้นแอบแฝง 2 ชั้นสามารถแยกแยะความสัมพันธ์ระหว่างตัวแปรนำเข้ากับผลลัพธ์ได้ดีกว่าชั้นแอบแฝงชั้นเดียวในกรณีที่เป็นแบบจำลอง ANN มีตัวแปรนำเข้าเป็นจำนวนมากหรือความหลากหลายของผลลัพธ์ที่เกิดจากตัวแปรนำเข้าหลายตัว ดังนั้นจากผลที่ได้พอแสดงให้เห็นว่าจำนวนหน่วยและจำนวนชั้นแอบแฝงมีความสัมพันธ์กับจำนวนตัวแปรนำเข้าอยู่บ้าง จึงอาจเป็นอีกแนวทางหนึ่งในการคัดเลือกโครงข่ายภายในที่เหมาะสมในแบบจำลอง ANN เพื่อประหยัดเวลาในการ trial & error และง่ายต่อการนำไปประยุกต์ใช้งาน

### 6.1.3 การปรับปรุงผลการพยากรณ์และการพยากรณ์ล่วงหน้ามากกว่า 1 วัน



ก่อนที่จะทำการพยากรณ์อัตราการไหลน้ำท่ารายล่วงหน้าไปอีก 1 วันถัดไปนั้น จำเป็นที่จะต้องนำอนุกรมค่าความผิดพลาดจากการพยากรณ์ในวันที่ผ่านมาโดยแบบจำลอง ANN มาตรวจสอบความเป็นอิสระต่อกัน โดยใช้กราฟ auto และ partial autocorrelation เพื่อพิจารณาว่าอนุกรมชุดนั้นสามารถที่จะอธิบายอะไรได้อีกหรือไม่ ซึ่งถ้าหากอนุกรมค่าความผิดพลาดมีความเป็นอิสระต่อกันแสดงว่าเราไม่สามารถอธิบายอะไรจากอนุกรมชุดนั้นได้อีกหรือกล่าวได้อีกนัยหนึ่งว่า อนุกรมชุดนั้นเป็นอนุกรมของตัวแปรสุ่ม ซึ่งไม่สามารถนำมาจัดสร้างเป็นแบบจำลองการพยากรณ์ค่าความผิดพลาดล่วงหน้าได้ หรือไม่สามารถปรับปรุงผลการพยากรณ์ได้ แต่ถ้าหากพบว่าอนุกรมค่าความผิดพลาดมีความไม่เป็นอิสระต่อกันหรือมีความสัมพันธ์ภายในซึ่งกันและกัน แสดงว่าเราสามารถที่จะอธิบายอนุกรมชุดนั้นได้ด้วยความสัมพันธ์ หรือสามารถนำมาจัดสร้างเป็นแบบจำลองการพยากรณ์ค่าความผิดพลาดล่วงหน้าได้ โดยใช้แบบจำลองอนุกรมเวลาเพื่อนำไปปรับปรุงผลการพยากรณ์ต่อไป

ตัวอย่างการตรวจสอบความเป็นอิสระต่อกันของอนุกรมค่าความผิดพลาดจากการพยากรณ์อัตราการไหลน้ำท่ารายล่วงหน้า 1 วัน โดยแบบจำลอง ANN ที่ผ่านการจัดสร้างและคัดเลือกมาแล้ว แสดงได้ดังรูป 6-8



จากรูป 6-8 จะเห็นได้ว่า ค่าความสัมพันธ์แบบ auto และ partial autocorrelation ของสถานีวัดน้ำท่าต่างๆ มีค่าใกล้เคียงศูนย์และอยู่ภายในขอบเขตความเป็นอิสระต่อกัน (95% Tolerance) แสดงว่าอนุกรมค่าความผิดพลาดของสถานีวัดน้ำท่าต่างๆ มีความเป็นอิสระต่อกัน ดังนั้นจึงไม่สามารถจัดสร้างแบบจำลองการพยากรณ์ค่าความผิดพลาดล่วงหน้า และนำไปปรับปรุงผลการพยากรณ์อัตราการไหลน้ำท่ารายล่วงหน้า 1 วัน ได้





(a) สถานี 150401





(b) สถานี KGT.14





(c) สถานี KGT.15A



(d) สถานี KGT.12



(e) สถานี KGT.10



(f) สถานี KGT.3

รูป 6-8 การตรวจสอบความเป็นอิสระของอนุกรมค่าความผิดพลาดจากการพยากรณ์

$Q_{k+1}$  ของแบบจำลอง ANN สำหรับฤดูฝน ณ สถานีวัดน้ำท่าต่างๆ

การพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้ามากกว่า 1 วัน ในการศึกษาครั้งนี้ได้แบ่งวิธีการพยากรณ์ออกเป็น 2 แบบ คือ วิธี Direct step ซึ่งจะใช้ตัวแปรนำเข้าสู่ชุดเดียวกันตลอด และวิธี Standard step ซึ่งจะนำผลการพยากรณ์จากวันที่แล้ว ที่ผ่านการตรวจสอบความเป็นอิสระและปรับปรุงผลการพยากรณ์แล้ว มาเป็นตัวแปรนำเข้าในแบบจำลองที่จะพยากรณ์อัตราการไหลน้ำท่าในวันถัดไป สำหรับชุดตัวแปรนำเข้าที่ใช้ในการพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้าโดยวิธี Standard step สรุปแยกตามสถานีได้ดังตารางที่ 6-11

สำหรับจำนวนวันล่วงหน้ามากที่สุดที่สามารถจะพยากรณ์อัตราการไหลน้ำท่าในฤดูฝนได้นั้น ขึ้นอยู่กับค่า  $T_c$  ของแต่ละลุ่มน้ำ (กราฟ d รูป 6-1 ถึง 6-6) เนื่องจากค่าดังกล่าวเป็นตัวชี้ถึงระยะเวลาที่ฝนมีอิทธิพลต่อน้ำท่า หรือกล่าวอีกนัยหนึ่งว่าเราไม่สามารถอธิบายการเกิดของน้ำท่าจากฝนได้หากจำนวนวันล่วงหน้าที่พยากรณ์เกินค่า  $T_c$  โดยผลการพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้าหลายวันและการปรับปรุงผลการพยากรณ์ในแต่ละสถานี สามารถสรุปได้ดังตาราง 6-12 ซึ่งพบว่า

1) การพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้ามากกว่า 1 วัน ณ สถานีต่างๆ โดยวิธี Standard Step จะให้ผลการพยากรณ์ที่ดีกว่าวิธี Direct Step เพียงเล็กน้อยในช่วงการพยากรณ์ล่วงหน้า 2 – 3 วันแรก แต่เมื่อระยะเวลาในการพยากรณ์ล่วงหน้ายาวนานขึ้น การพยากรณ์โดยวิธี Standard Step นั้น จะให้ผลการพยากรณ์ที่ดีกว่าวิธี Direct Step อย่างชัดเจน (พิจารณาได้จากสถานี KGT.12, KGT.3) ทั้งนี้สืบเนื่องมาจากชุดตัวแปรนำเข้าโดยวิธี Direct Step เป็นชุดตัวแปรที่ถูกคัดเลือกมาจากการพิจารณาความสัมพันธ์กับ  $Q_{t-1}$  เท่านั้น ดังนั้นที่ระยะเวลากการพยากรณ์ยาวนานขึ้นชุดตัวแปรนำเข้าต่างๆ เหล่านี้ไม่น่าจะมีอิทธิพลหรือความสัมพันธ์กับผลลัพธ์ แต่อาจจะยังส่งผลอยู่บ้างในช่วงการพยากรณ์ล่วงหน้า 2 – 3 วันแรก ซึ่งจะแตกต่างจากวิธี Standard Step ที่นำเอาผลการพยากรณ์จากวันที่แล้วมาใช้เป็นตัวแปรนำเข้าสำหรับการพยากรณ์ล่วงหน้าในวันถัดไป เพื่อที่จะรักษาความสัมพันธ์ระหว่างชุดตัวแปรนำเข้ากับผลลัพธ์ให้คงความหมายเหมือนกับการพยากรณ์  $Q_{t-1}$  ไว้ตลอด

2) ค่าประสิทธิภาพของแบบจำลองจะมีค่าลดลง และค่าความผิดพลาดในการพยากรณ์จะมีค่าเพิ่มขึ้นเรื่อยๆ เมื่อการพยากรณ์ล่วงหน้ายาวนานขึ้น เนื่องจาก

- ขาดข้อมูลปริมาณน้ำฝนในช่วงระหว่างวันปัจจุบันถึงวันที่จะทำการพยากรณ์ล่วงหน้า สำหรับการพยากรณ์ที่ KGT.3 ที่ระยะเวลากการพยากรณ์ยาวนานขึ้น นอกจากขาดข้อมูลปริมาณน้ำฝนแล้ว ยังขาดข้อมูลอัตราการไหลน้ำท่ารายวันล่วงหน้าที่ออกจากลุ่มน้ำต่างๆ ซึ่งจะเริ่มจากลุ่มน้ำที่พยากรณ์น้ำท่าล่วงหน้าได้ไม่นานเช่น KGT.14, KGT.15 และ 150401

ตาราง 6-11 ชุดตัวแปรนำเข้าเข้าที่ใช้ในการพยากรณ์อัตราดอกเบี้ยเงินฝากในอุตสาหกรรม โดยวิธี Standard step

การพยากรณ์	สถานการณ์นำเข้า						
	150401	KGT.14	KGT.15A	KGT.12	KGT.10	KGT.3	
1	Q1 <sub>t</sub> , R1 <sub>t</sub> , R1 <sub>t+1</sub>	Q2 <sub>t</sub> , R2 <sub>t</sub>	Q3 <sub>t</sub> , Q3 <sub>t+1</sub> , R3 <sub>t</sub> , R3 <sub>t+1</sub>	Q4 <sub>t</sub> , Q4 <sub>t+1</sub> , R4 <sub>t</sub> , R4 <sub>t+1</sub> , R4 <sub>t+2</sub> , R4 <sub>t+3</sub> , R4 <sub>t+4</sub> , R4 <sub>t+5</sub>	Q5 <sub>t</sub> , Q5 <sub>t+1</sub> , R5 <sub>t</sub> , R5 <sub>t+1</sub> , R5 <sub>t+2</sub>	Q6 <sub>t</sub> , Q6 <sub>t+1</sub> , Q1 <sub>t</sub> , Q2 <sub>t</sub> , Q3 <sub>t</sub> , Q4 <sub>t</sub> , Q5 <sub>t</sub> R6 <sub>t</sub> , R6 <sub>t+1</sub> , R6 <sub>t+2</sub> , R6 <sub>t+3</sub>	
2	FQ1 <sub>t+1</sub> , R1 <sub>t</sub>	-	FQ3 <sub>t+1</sub> , Q3 <sub>t</sub> , R3 <sub>t</sub>	FQ4 <sub>t+1</sub> , Q4 <sub>t</sub> , R4 <sub>t</sub> , R4 <sub>t+1</sub> , R4 <sub>t+2</sub> , R4 <sub>t+3</sub> , R4 <sub>t+4</sub>	FQ5 <sub>t+1</sub> , Q5 <sub>t</sub> , R5 <sub>t</sub> , R5 <sub>t+1</sub>	FQ6 <sub>t+1</sub> , FQ1 <sub>t+1</sub> , FQ2 <sub>t+1</sub> , FQ3 <sub>t+1</sub> , FQ4 <sub>t+1</sub> , FQ5 <sub>t+1</sub> Q6 <sub>t</sub> , R6 <sub>t</sub> , R6 <sub>t+1</sub> , R6 <sub>t+2</sub>	
3	-	-	-	FQ4 <sub>t+2</sub> , FQ4 <sub>t+1</sub> , R4 <sub>t</sub> , R4 <sub>t+1</sub> , R4 <sub>t+2</sub> , R4 <sub>t+3</sub>	FQ5 <sub>t+2</sub> , FQ5 <sub>t+1</sub> , R5 <sub>t</sub>	FQ6 <sub>t+2</sub> , FQ6 <sub>t+1</sub> , FQ1 <sub>t+2</sub> , FQ4 <sub>t+2</sub> , FQ5 <sub>t+2</sub> , R6 <sub>t</sub> , R6 <sub>t+1</sub>	
4	-	-	-	FQ4 <sub>t+3</sub> , FQ4 <sub>t+2</sub> , R4 <sub>t</sub> , R4 <sub>t+1</sub> , R4 <sub>t+2</sub>	-	FQ6 <sub>t+3</sub> , FQ6 <sub>t+2</sub> , FQ4 <sub>t+3</sub> , FQ5 <sub>t+3</sub> , R6 <sub>t</sub>	
5	-	-	-	FQ4 <sub>t+4</sub> , FQ4 <sub>t+3</sub> , R4 <sub>t</sub> , R4 <sub>t+1</sub>	-	FQ6 <sub>t+4</sub> , FQ6 <sub>t+3</sub> , FQ4 <sub>t+4</sub>	
6	-	-	-	FQ4 <sub>t+5</sub> , FQ4 <sub>t+4</sub> , R4 <sub>t</sub>	-	FQ6 <sub>t+5</sub> , FQ6 <sub>t+4</sub> , FQ4 <sub>t+5</sub>	
7	-	-	-	-	-	FQ6 <sub>t+6</sub> , FQ6 <sub>t+5</sub> , FQ4 <sub>t+6</sub>	

ตาราง 6-12 สรุปผลการพยากรณ์อัตราดอกเบี้ยรายวันล่วงหน้ามากกว่า 1 วัน ในเดือน

สถานี วัดน้ำท่า	พหุคูณ องศา	ปรับเทียบ (Training Period)										ปรับฐาน (Testing Period)									
		Direct Step					Standard Step					ANN-Residual Adjustment					ปรับเสริม $\Delta EI(\%)$				
		ลักษณะ โครงสร้าง	EI (%)	RMSE (ม <sup>3</sup> /วินาที)	ลักษณะ โครงสร้าง	EI (%)	RMSE (ม <sup>3</sup> /วินาที)	แบบจำลอง	EI (%)	RMSE (ม <sup>3</sup> /วินาที)	ปรับเสริม $\Delta EI(\%)$	EI (%)	RMSE (ม <sup>3</sup> /วินาที)	ANN+Residual Adjustment	EI (%)	RMSE (ม <sup>3</sup> /วินาที)	ปรับเสริม $\Delta EI(\%)$				
150401	2	3-6-1	66.86	20.65	2-2-1	66.89	20.64	MA(2)	74.87	18.04	7.98	53.23	19.01	63.84	18.94	68.53	15.59	14.69			
KGT.15A	2	4-2-2-1	52.50	20.17	3-3-1	53.65	20.38	MA(2)	82.01	18.51	8.45	51.21	21.55	51.34	21.52	59.27	19.69	7.92			
KGT.12	2	8-4-4-1	95.18	10.27	7-4-3-1	95.20	10.24	MA(2)	97.32	7.68	2.12	93.52	9.03	93.79	8.84	95.80	7.27	2.01			
	3	8-8-1	99.75	14.97	6-3-3-1	93.01	12.36	MA(2)	94.45	11.06	1.43	85.84	13.35	90.38	11.00	91.16	10.54	0.78			
	4	8-8-1	84.06	18.67	5-5-1	89.59	15.79	MA(2)	90.91	14.19	2.32	78.95	16.31	84.27	14.09	85.11	13.68	0.84			
	5	8-8-1	76.88	22.48	4-2-2-1	84.13	18.63	MA(2)	87.06	16.94	2.92	69.76	19.50	77.86	16.99	79.14	18.19	1.28			
	6	8-8-1	69.32	25.90	3-3-1	79.50	21.17	AR(2)	83.07	19.48	3.57	63.29	21.49	71.76	18.95	72.36	18.64	0.60			
KGT.10	2	5-10-1	77.85	32.74	4-4-1	78.36	32.36	MA(2)	86.51	25.50	8.25	75.44	24.27	75.52	24.23	87.28	17.47	11.76			
	3	5-5-1	67.29	39.78	3-3-1	72.60	36.41	MA(2)	79.09	32.06	6.49	63.49	29.59	70.68	26.53	77.37	23.30	6.71			
KGT.3	2	11-6-5-1	97.55	31.05	10-5-5-1	97.79	29.43	MA(2)	98.44	24.82	0.65	96.96	29.81	97.29	27.97	98.35	21.76	1.06			
	3	11-6-5-1	93.60	50.17	7-4-3-1	95.01	44.28	MA(2)	95.85	40.47	0.84	92.41	46.78	93.79	42.33	95.11	37.56	1.32			
	4	11-6-5-1	88.51	67.22	5-5-1	91.03	59.39	MA(2)	93.21	51.91	2.18	86.95	61.36	89.36	55.39	92.33	47.03	2.97			
	5	11-6-5-1	82.83	81.92	3-3-1	87.81	69.21	MA(2)	90.24	62.27	2.43	81.75	72.55	85.53	62.34	89.10	58.05	2.57			
	6	11-6-5-1	77.13	94.83	3-3-1	84.82	77.25	MA(2)	87.58	70.25	2.76	76.91	81.61	83.02	69.97	85.06	65.64	2.04			
	7	11-6-5-1	71.16	106.51	3-3-1	82.12	83.84	AR(2)	85.03	77.52	2.91	71.83	90.14	79.61	76.68	81.45	73.13	1.84			

หมายเหตุ: 1)  $\Delta EI = (EI \text{ จากแบบจำลอง ANN-Residual Adjustment}) - (EI \text{ จากแบบจำลอง ANN โดยวิธี Standard step})$

- 2) รายละเอียดผลการทดสอบแบบจำลองแสดงไว้ใน ภาคผนวก ๑2
- 3) ผลการตรวจสอบความน่าเชื่อถือของอนุกรมค่าความผิดพลาดจากการพยากรณ์ แสดงไว้ใน ภาคผนวก ๑1
- 4) KGT.14 ไม่สามารถพยากรณ์ล่วงหน้าได้มากกว่า 1 วัน

- ความสัมพันธ์ระหว่างชุดตัวแปรนำเข้ากับผลลัพธ์ จะมีค่าน้อยลงเมื่อการพยากรณ์ล่วงหน้ายาวนานขึ้น (เฉพาะการพยากรณ์โดยวิธี Direct Step)
- ค่าความผิดพลาดในการพยากรณ์ที่สะสมเรื่อยมา จากการนำผลการพยากรณ์ของวันที่แล้ว มาใช้เป็นตัวแปรนำเข้าสำหรับการพยากรณ์ล่วงหน้าในวันถัดไป (เฉพาะการพยากรณ์โดยวิธี Standard Step)


3) มีการนำแบบจำลองอนุกรมเวลามาใช้ในการพยากรณ์ค่าความผิดพลาดล่วงหน้า เพื่อช่วยปรับปรุงประสิทธิภาพในการพยากรณ์ล่วงหน้ามากกว่า 1 วันของแบบจำลอง ANN จากวิธี Standard Step ทำให้ผลการพยากรณ์แม่นยำมากขึ้น โดยประสิทธิภาพของแบบจำลองจะมีค่าเพิ่มขึ้นประมาณ 6.5 - 15% สำหรับแบบจำลองที่ใช้พยากรณ์ ณ สถานี 150401, KGT.14, KGT.15 และ KGT.10 สำหรับที่สถานี KGT.12 และ KGT.3 นั้น ประสิทธิภาพของแบบจำลองมีค่าเพิ่มขึ้นอยู่ระหว่าง 0.6 - 3.6% ซึ่งจะเห็นได้ว่ามีค่าชว่นน้อยกว่า 4 สถานีที่ผ่านมา ทั้งนี้เนื่องมาจากประสิทธิภาพของแบบจำลอง ณ สถานีวัด KGT.12 และ KGT.3 มีค่าสูงมาก ทำให้ช่วงเปอร์เซ็นต์ค่าความผิดพลาดที่เหลือของแบบจำลอง (100% - ประสิทธิภาพแบบจำลอง) ที่จะนำมาปรับปรุงผลการพยากรณ์มีค่าน้อยเมื่อเทียบกับ 4 สถานีที่ผ่านมา ดังนั้นการปรับปรุงการพยากรณ์โดยใช้แบบจำลองอนุกรมเวลาจึงส่งผลให้แบบจำลองมีประสิทธิภาพเพิ่มขึ้นไม่มาก

นอกจากนี้ยังเห็นได้ว่าแบบจำลองอนุกรมเวลาที่เหมาะสมในการนำมาใช้ปรับปรุงผลการพยากรณ์ต่อจากแบบจำลอง ANN คือ แบบจำลอง MA (2) แต่ทั้งนี้การเลือกแบบจำลองอนุกรมเวลานั้นยังขึ้นอยู่กัลักษณะข้อมูลอนุกรมเวลาที่นำมาใช้สร้างแบบจำลองเป็นสำคัญ สำหรับค่าถ่วงน้ำหนักของแบบจำลอง ANN และค่าพารามิเตอร์ในแบบจำลองอนุกรมเวลาในแต่ละกรณีที่ผ่านมาการเลือกมาแล้วนั้น แสดงไว้ในภาคผนวก จ1


เมื่อนำผลการพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้าโดยวิธี Standard step และปรับปรุงผลการพยากรณ์โดยแบบจำลองอนุกรมเวลาในช่วงปรับทานแบบจำลอง ซึ่งแบ่งเป็นปีน้ำน้อย น้ำเฉลี่ย น้ำมาก ของสถานีต่างๆมาเขียนกราฟเปรียบเทียบกับข้อมูลที่วัดจริง แสดงได้ดังรูปที่ 6 - 9 ถึง 6 - 14 ซึ่งจะเห็นได้ว่า

- 1) เมื่อระยะเวลาการพยากรณ์ยาวนานขึ้น ผลการพยากรณ์ที่ได้จากแบบจำลองก็จะมีค่าความผิดพลาดและมีความผันผวนมากขึ้น หรือความแม่นยำในการพยากรณ์ก็จะลดลงตามลำดับ
- 2) ความแม่นยำในการพยากรณ์ขึ้นอยู่กับลักษณะอัตราการไหลน้ำท่าของแต่ละสถานีหรือแต่ละลุ่มน้ำ คือ สถานีที่มีอัตราการไหลน้ำท่าผันผวนมากจะมีความแม่นยำในการพยากรณ์น้อยกว่าสถานีที่มีความผันผวนน้อย






a) การพยากรณ์ล่วงหน้า 1 วัน จากแบบจำลอง ANN




b) การพยากรณ์ล่วงหน้า 2 วัน จากแบบจำลอง ANN+MA(2)

รูป 6-9 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูฝน ณ สถานี 150401 ช่วงปรับทานแบบจำลอง




การพยากรณ์ล่วงหน้า 1 วัน จากแบบจำลอง ANN

รูป 6-10 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูฝน ณ สถานี KGT.14 ช่วงปรับทานแบบจำลอง




การพยากรณ์ล่วงหน้า 1 วัน จากแบบจำลอง ANN

รูป 6-11 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูฝน ณ สถานี KGT.15A ช่วงปรับทานแบบจำลอง




b) การพยากรณ์ล่วงหน้า 2 วัน จากแบบจำลอง ANN+MA(2)

รูป 6-11 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูฝน ณ สถานี KGT.15A ช่วงรับทานแบบจำลอง (ต่อ)




a) การพยากรณ์ล่วงหน้า 1 วัน จากแบบจำลอง ANN

รูป 6-12 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูฝน ณ สถานี KGT.12 ช่วงรับทานแบบจำลอง




b) การพยากรณ์ล่วงหน้า 2 วัน จากแบบจำลอง ANN+MA(2)




c) การพยากรณ์ล่วงหน้า 3 วัน จากแบบจำลอง ANN+MA(2)

รูป 6-12 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูฝน ณ สถานี KGT.12 ช่วงปริมาณน้ำฝนแบบจำลอง (ต่อ)




d) ภาพพยากรณ์ล่วงหน้า 4 วัน จากแบบจำลอง ANN+MA(2)




e) ภาพพยากรณ์ล่วงหน้า 5 วัน จากแบบจำลอง ANN+MA(2)

รูป 6-12 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูฝน ณ สถานี KGT.12 ของบริษัทนแบบจำลอง (ต่อ)




ก) การพยากรณ์ล่วงหน้า 6 วัน จากแบบจำลอง ANN+AR(2)

รูป 6-12 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูฝน ณ สถานี KGT.12 ช่วงปรับทานแบบจำลอง (ต่อ)




ข) การพยากรณ์ล่วงหน้า 1 วัน จากแบบจำลอง ANN

รูป 6-13 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูฝน ณ สถานี KGT.10 ช่วงปรับทานแบบจำลอง




b) การพยากรณ์ล่วงหน้า 2 วัน จากแบบจำลอง ANN+MA(2)




c) การพยากรณ์ล่วงหน้า 3 วัน จากแบบจำลอง ANN+MA(2)

รูป 6-13 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูฝน ณ สถานี KGT.10 ช่วงรับทานแบบจำลอง (ต่อ)




a) การพยากรณ์ล่วงหน้า 1 วัน จากแบบจำลอง ANN




b) การพยากรณ์ล่วงหน้า 2 วัน จากแบบจำลอง ANN+MA(2)

รูป 6-14 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูฝน ณ สถานี KGT.3 ช่วงปรับทานแบบจำลอง






c) การพยากรณ์ล่วงหน้า 3 วัน จากแบบจำลอง ANN+MA(2)




d) การพยากรณ์ล่วงหน้า 4 วัน จากแบบจำลอง ANN+MA(2)

รูป 6-14 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูฝน ณ สถานี KGT.3 ช่วงรับทานแบบจำลอง (ต่อ)




e) การพยากรณ์ล่วงหน้า 5 วัน จากแบบจำลอง ANN+MA(2)



g) การพยากรณ์ล่วงหน้า 6 วัน จากแบบจำลอง ANN+MA(2)

รูป 6-14 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูฝน ณ สถานี KGT.3 ช่วงปรับทามแบบจำลอง (ต่อ)



g) การพยากรณ์ล่วงหน้า 7 วัน จากแบบจำลอง ANN+AR(2)

รูป 6-14 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูฝน ณ สถานี KGT.3 ช่วงปริมาณแบบจำลอง (ต่อ)

สงวนลิขสิทธิ์  
จุฬาลงกรณ์มหาวิทยาลัย

3) การพยากรณ์จะผิดพลาดมาก ณ เวลาการเกิดอัตราการไหลน้ำท่าสูงสุดของกราฟน้ำท่าแต่ละลูก

#### 6.1.4 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN และ MLR

เมื่อทำการจัดสร้างแบบจำลอง MLR โดยใช้ตัวแปรนำเข้าสู่ชุดเดียวกับแบบจำลอง ANN ที่พยากรณ์ล่วงหน้าโดยวิธี Standard Step (ตาราง 6 - 11) ได้แสดงผลการจัดสร้างแบบจำลองไว้ในภาคผนวก ฉ1 และเมื่อนำผลการพยากรณ์มาเปรียบเทียบกับผลการพยากรณ์จากแบบจำลอง ANN (ก่อนการปรับปรุงผลการพยากรณ์) สรุปได้ดังตาราง 6 - 13 ซึ่งจะเห็นได้ว่า

1) ผลการพยากรณ์โดยใช้แบบจำลอง MLR ให้ความแม่นยำในการพยากรณ์น้อยกว่าแบบจำลอง ANN ในทุกสถานี

2) เมื่อนำค่าความแตกต่างของประสิทธิภาพของแบบจำลอง ANN และ MLR ในการพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า 1 วัน ในช่วงเปรียบเทียบ ณ สถานีต่างๆมาเปรียบเทียบกัน จะเห็นได้ว่า ที่สถานี KGT.14 มีค่าความแตกต่างมากที่สุด รองลงมาคือ KGT.15A, 150401, KGT.10, KGT.3 และ KGT.12 โดยมีค่าความแตกต่างกันประมาณ 11.0%, 5.9%, 3.5%, 2.7%, 0.5% และ 0.2% ตามลำดับ ทั้งนี้อาจเนื่องมาจากน้ำท่า ณ สถานี KGT.14 มีการเปลี่ยนแปลงอย่างรวดเร็วและใช้ระยะเวลาอันสั้น หรือมีความไม่เป็นเชิงเส้นสูง เมื่อเทียบกับน้ำท่า ณ สถานีวัดอื่นๆ ทำให้แบบจำลอง MLR ซึ่งเป็นแบบจำลองเชิงเส้นใช้การได้ไม่ดีมากนัก

3) เมื่อระยะเวลาการพยากรณ์ยาวนานขึ้น ประสิทธิภาพของแบบจำลอง MLR จะด้อยกว่าแบบจำลอง ANN เพิ่มมากขึ้นตามลำดับ พิจารณาได้จากผลการพยากรณ์ ณ สถานี KGT.12 และ KGT.3

จากผลการเปรียบเทียบจะเห็นได้ว่าแบบจำลอง ANN สามารถนำมาประยุกต์ใช้ในการพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้าได้ดีกว่าแบบจำลอง MLR โดยเฉพาะอย่างยิ่งเมื่อนำมาประยุกต์ใช้ในพื้นที่ลุ่มน้ำที่มีอัตราการไหลน้ำท่าเปลี่ยนแปลงอย่างรวดเร็ว หรือใช้ในการพยากรณ์ล่วงหน้าในเวลายาวนาน ทั้งนี้อาจสืบเนื่องมาจากแบบจำลอง ANN มีจำนวนพารามิเตอร์มากกว่าแบบจำลอง MLR ทำให้สามารถเรียนรู้ความสัมพันธ์ระหว่างตัวแปรนำเข้าและผลลัพธ์ได้ดีกว่าแบบจำลอง MLR และนอกจากนี้อาจเนื่องมาจากความไม่เป็นเชิงเส้นของความสัมพันธ์ระหว่างน้ำฝน-น้ำท่า ทำให้แบบจำลอง ANN ซึ่งเป็นแบบจำลองชนิดไม่เป็นเชิงเส้นมีความเหมาะสมกว่าแบบจำลอง MLR ซึ่งเป็นแบบจำลองเชิงเส้น


ตาราง 6-13 การเปรียบเทียบผลการพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้าในฤดูฝน  
ระหว่างแบบจำลอง ANN กับ MLR

สถานี วัดน้ำท่า	พหุภพ ส่วนหน้า (วัน)	เปรียบเทียบ (Training Period)					เปรียบเทียบ (Testing Period)				
		ANN		MLR		% ความ แตกต่าง $\Delta EI(\%)$	ANN		MLR		% ความ แตกต่าง $\Delta EI(\%)$
		EI (%)	RMSE (ม <sup>3</sup> /วินาที)	EI (%)	RMSE (ม <sup>3</sup> /วินาที)		EI (%)	RMSE (ม <sup>3</sup> /วินาที)	EI (%)	RMSE (ม <sup>3</sup> /วินาที)	
150401	1	82.99	14.80	79.54	16.23	3.45	73.57	14.29	72.85	14.48	0.73
	2	66.89	20.64	60.39	22.58	6.49	54.84	18.94	50.19	19.61	4.36
KGT.14	1	70.36	7.78	59.34	9.11	10.97	68.56	6.42	59.78	7.26	8.72
KGT.15A	1	81.55	12.84	75.68	14.75	5.87	77.42	14.66	76.28	15.03	1.14
	2	53.55	20.38	47.15	21.74	6.40	51.34	21.52	45.06	22.87	6.28
KGT.12	1	98.68	5.36	98.52	5.69	0.17	98.26	4.69	98.19	4.77	0.07
	2	95.20	10.24	93.96	11.49	1.24	93.79	8.84	92.82	9.51	0.97
	3	93.01	12.36	87.26	16.69	5.75	90.38	11.00	84.96	13.76	5.43
	4	88.59	15.79	79.38	21.24	9.22	84.27	14.06	76.44	17.22	7.84
	5	84.13	18.63	70.91	25.22	13.22	77.86	15.69	67.63	20.18	10.23
	6	79.49	21.17	62.23	28.74	17.26	71.76	18.85	59.31	22.62	12.45
KGT.10	1	91.36	20.44	88.67	23.42	2.70	91.23	14.51	90.31	15.25	0.92
	2	78.36	32.36	73.26	35.97	5.10	75.52	24.23	71.99	25.92	3.52
	3	72.60	36.41	59.93	44.03	12.67	70.66	26.53	57.64	31.88	13.02
KGT.3	1	99.31	16.46	98.86	21.22	0.46	99.23	14.90	99.15	15.62	0.08
	2	97.79	29.48	96.72	35.93	1.07	97.29	27.97	97.24	28.20	0.06
	3	95.01	44.28	92.86	52.98	2.15	93.79	42.33	92.86	45.38	0.86
	4	91.03	59.39	87.47	70.18	3.55	89.36	55.39	87.08	61.04	2.28
	5	87.81	69.21	81.31	85.72	6.50	86.53	62.34	80.98	74.07	5.54
	6	84.82	77.25	74.69	99.75	10.13	83.02	69.97	74.95	85.01	8.08
	7	82.12	83.84	68.07	112.04	14.05	79.61	76.68	69.73	93.44	9.88


หมายเหตุ:  $\Delta EI = (EI \text{ จากแบบจำลอง ANN}) - (EI \text{ จากแบบจำลอง MLR})$

#### 6.1.5 การประยุกต์ใช้แบบจำลอง ANN

เมื่อนำแบบจำลอง ANN และแบบจำลองอนุกรมเวลาที่ผ่านการคัดเลือก มาทดสอบกับข้อมูลที่เตรียมไว้สำหรับรับรองผลแบบจำลองซึ่งข้อมูลปีล่าสุดที่มีการจัดบันทึก (ปี พ.ศ.2541) เพื่อพิจารณาว่าแบบจำลองนั้นสามารถนำมาประยุกต์ใช้งานกับเหตุการณ์ในปัจจุบันได้ดีหรือไม่ โดยผลการทดสอบแสดงได้ดังรูป 6-15 ถึง 6-20




๑) การพยากรณ์ล่วงหน้า 1 วัน จากแบบจำลอง ANN




๒) การพยากรณ์ล่วงหน้า 2 วัน จากแบบจำลอง ANN+MA(2)

รูป 6-15 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูฝน ณ สถานี 150401 ช่วงรับร่องผลแบบจำลอง




๑) การพยากรณ์ล่วงหน้า 1 วัน จากแบบจำลอง ANN

รูป 6-16 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูฝน ณ สถานี KGT.14 ช่วงรับร่องผลแบบจำลอง




a) การพยากรณ์ล่วงหน้า 1 วัน จากแบบจำลอง ANN




b) การพยากรณ์ล่วงหน้า 2 วัน จากแบบจำลอง ANN+MA(2)

รูป 6-17 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูฝน ณ สถานี KGT.15A ช่วงรับร่องผลแบบจำลอง




a) การพยากรณ์ล่วงหน้า 1 วัน จากแบบจำลอง ANN


รูป 6-18 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูฝน ณ สถานี KGT.12 ช่วงรับร่องผลแบบจำลอง



b) การพยากรณ์ล่วงหน้า 2 วัน จากแบบจำลอง ANN+MA(2)



c) การพยากรณ์ล่วงหน้า 3 วัน จากแบบจำลอง ANN+MA(2)




d) การพยากรณ์ล่วงหน้า 4 วัน จากแบบจำลอง ANN+MA(2)

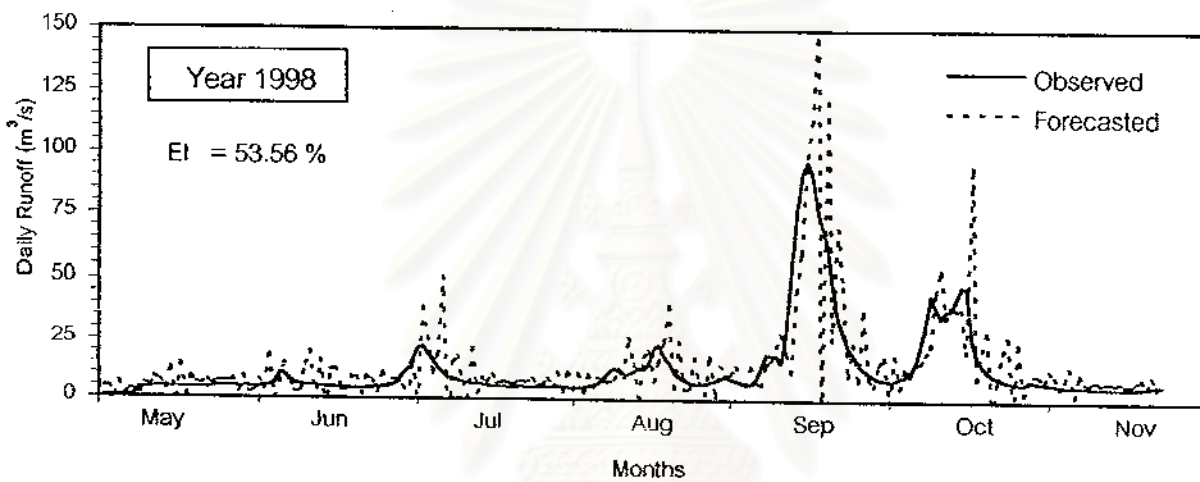
รูป 6-18 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูฝน

ณ สถานี KGT.12 ช่วงรับรองผลแบบจำลอง (ต่อ)






e) การพยากรณ์ล่วงหน้า 5 วัน จากแบบจำลอง ANN+MA(2)




f) การพยากรณ์ล่วงหน้า 6 วัน จากแบบจำลอง ANN+AR(2)

รูป 6-18 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูฝน ณ สถานี KGT.12 ช่วงรับร่องผลแบบจำลอง (ต่อ)




a) การพยากรณ์ล่วงหน้า 1 วัน จากแบบจำลอง ANN

รูป 6-19 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูฝน ณ สถานี KGT.10 ช่วงรับร่องผลแบบจำลอง




b) การพยากรณ์ล่วงหน้า 2 วัน จากแบบจำลอง ANN+MA(2)




c) การพยากรณ์ล่วงหน้า 3 วัน จากแบบจำลอง ANN+MA(2)

รูป 6-19 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูฝน ณ สถานี KGT.10 ช่วงรับร่องผลแบบจำลอง (ต่อ)




a) การพยากรณ์ล่วงหน้า 1 วัน จากแบบจำลอง ANN


รูป 6-20 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูฝน ณ สถานี KGT.3 ช่วงรับร่องผลแบบจำลอง



b) การพยากรณ์ล่วงหน้า 2 วัน จากแบบจำลอง ANN+MA(2)




c) การพยากรณ์ล่วงหน้า 3 วัน จากแบบจำลอง ANN+MA(2)




d) การพยากรณ์ล่วงหน้า 4 วัน จากแบบจำลอง ANN+MA(2)


รูป 6-20 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูฝน ณ สถานี KGT.3 ช่วงรับรองผลแบบจำลอง (ต่อ)



e) การพยากรณ์ล่วงหน้า 5 วัน จากแบบจำลอง ANN+MA(2)



f) การพยากรณ์ล่วงหน้า 6 วัน จากแบบจำลอง ANN+MA(2)



g) การพยากรณ์ล่วงหน้า 7 วัน จากแบบจำลอง ANN+AR(2)

รูป 6-20 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูฝน ณ สถานี KGT.3 ช่วงรับชมผลแบบจำลอง (ต่อ)

จะเห็นได้ว่าแบบจำลองที่ยังใช้การได้ดีนั้น ( $EI > 80\%$ ) ได้แก่ แบบจำลอง ณ สถานี 150401, KGT.12, KGT.10 และ KGT.3 สำหรับแบบจำลอง ณ สถานี KGT.14 และ KGT.15A นั้นมีค่า EI ต่ำกว่า 80% มาก อาจเนื่องมาจากในปีนี้อัตราการไหลน้ำท่าที่ออกจากกลุ่มน้ำลำพระยาธาร (KGT.14) และห้วยสโมง (KGT.15A) มีค่าต่ำมากเมื่อเทียบกับปีน้ำน้อยในช่วงการปรับเทียบแบบจำลอง ทำให้แบบจำลองสำหรับฤดูฝนของสถานีวัดน้ำท่าทั้ง 2 แห่งนี้ใช้การได้ไม่ดีมากนัก สังเกตได้จากค่าพยากรณ์ส่วนใหญ่มีค่าสูงกว่าความเป็นจริงมาก

## 6.2 แบบจำลองการพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้าในฤดูแล้ง

### 6.2.1 การคัดเลือกชุดตัวแปรนำเข้าสู่สำหรับพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า 1 วัน


ในการคัดเลือกชุดตัวแปรนำเข้าสู่เพื่อพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้าในช่วงฤดูแล้ง จะมีขั้นตอนการคัดเลือกเช่นเดียวกับในฤดูฝน คือ

#### 6.2.1.1 การคัดเลือกชุดตัวแปรนำเข้าสู่เบื้องต้น


แนวทางในการคัดเลือกชุดตัวแปรนำเข้าสู่เบื้องต้นสำหรับใช้ในแบบจำลองการพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้าในฤดูแล้ง จะใช้กราฟความสัมพันธ์เพียง 3 กราฟ ซึ่งได้แก่ กราฟ autocorrelation, partial autocorrelation และ cross correlation โดยทั้งนี้ไม่นำกราฟความสัมพันธ์ระหว่างน้ำท่า-น้ำฝน มาพิจารณาประกอบเหมือนกับในฤดูฝนนั้น เนื่องจากปริมาณน้ำท่าในช่วงฤดูแล้งส่วนใหญ่มาจากปริมาณน้ำที่สะสมตามชั้นดินหรือชั้นน้ำใต้ดินที่ดูดซึมไว้ตั้งแต่ช่วงฤดูฝนที่ผ่านมาเป็นหลัก สำหรับปริมาณน้ำท่าในฤดูแล้งที่เกิดเนื่องจากฝนตกหนักในพื้นที่มีน้อยมาก โดยผลการจัดสร้างกราฟความสัมพันธ์ต่างๆ แยกตามสถานี แสดงได้ดังรูป 6-21 ถึง 6-26 ซึ่งจะเห็นได้ว่า

1) กราฟ auto correlation (กราฟ a) มีลักษณะคล้ายกันเกือบทุกสถานี คือ จะมีค่าความสัมพันธ์ลดลงต่อเนื่องอย่างช้าๆ ยกเว้นที่สถานี KGT.10 ที่ลักษณะกราฟจะลดลงอย่างรวดเร็วในช่วงเวลาที่ย้อนหลัง 1-2 วัน แรก จากนั้นค่าความสัมพันธ์จะลดลงอย่างช้าๆ ในช่วงต่อมา ทั้งนี้อาจเนื่องมาจากลักษณะข้อมูลอัตราการไหลน้ำท่ารายวันในฤดูแล้งที่สถานี KGT.10 มีความแตกต่างจากสถานีวัดน้ำท่าอื่นๆ


2) กราฟ partial autocorrelation (กราฟ b) ของแต่ละสถานีจะมีลักษณะคล้ายกันและเหมือนกันกับในฤดูฝน คือ จะมีค่าความสัมพันธ์มากกว่าขอบเขตความเป็นอิสระ ในช่วงเวลาที่ย้อน




รูป 6-20 กราฟความสัมพันธ์สำหรับคัดเลือกชุดตัวแปรนำเข้าในการพยากรณ์  $Q_{k+1}$  ณ สถานี 150401 ในช่วงฤดูแล้ง




รูป 6-21 กราฟความสัมพันธ์สำหรับคัดเลือกชุดตัวแปรนำเข้าในการพยากรณ์  $Q_{k+1}$  ณ สถานี KGT.14 ในช่วงฤดูแล้ง




รูป 6-22 กราฟความสัมพันธ์สำหรับคัดเลือกชุดตัวแปรนำเข้าในการพยากรณ์  $Q_{t+1}$  ณ สถานี KGT.15A ในช่วงฤดูแล้ง



รูป 6-23 กราฟความสัมพันธ์สำหรับคัดเลือกชุดตัวแปรนำเข้าในการพยากรณ์  $Q_{t+1}$  ณ สถานี KGT.12 ในช่วงฤดูแล้ง



รูป 6-24 กราฟความสัมพันธ์สำหรับคัดเลือกชุดตัวแปรนำเข้าในการพยากรณ์  $Q_{t+1}$  ณ สถานี KGT.10 ในช่วงฤดูแล้ง



รูป 6-25 กราฟความสัมพันธ์สำหรับคัดเลือกชุดตัวแปรนำเข้าในการพยากรณ์  $Q_{t+1}$  ณ สถานี KGT.3 ในช่วงฤดูแล้ง



หลัง 1-2 วัน จากนั้นจะมีค่าลู่เข้าสู่ศูนย์หรืออยู่ภายในขอบเขตความเป็นอิสระ ซึ่งยังคงแสดงให้เห็นว่า  $Q_t$  และ  $Q_{t-1}$  เป็นตัวแปรที่มีค่ามากพอแก่การสนใจเพื่อใช้เป็นตัวแปรนำเข้ากับแบบจำลอง

3) กราฟ cross correlation (กราฟ c) ของสถานี 150401, KGT.14, KGT.15A, KGT.12 และ KGT.3 มีลักษณะเหมือนกัน คือ กราฟมีค่าความสัมพันธ์ใกล้เคียงศูนย์ที่เวลาย้อนหลังต่างๆ ซึ่งแสดงให้เห็นว่าความสัมพันธ์ระหว่างน้ำท่ากับน้ำฝนรายวันย้อนหลังมีค่าน้อยมาก สำหรับที่สถานี KGT.10 นั้น จะเห็นได้ว่าลักษณะกราฟมีความแตกต่างจากสถานีอื่นๆ คือ มีค่าความสัมพันธ์มีค่าเพิ่มขึ้นในช่วงเวลาย้อนหลัง 1-3 วันแรก จากนั้นก็จะมีค่าลดลงเข้าใกล้ศูนย์ และเมื่อนำกราฟ cross correlation ของ KGT.10 ในช่วงฤดูแล้งกับฤดูฝนมาเปรียบเทียบกัน (พิจารณากราฟ c รูป 6-5 และ 6-25 ประกอบ) จะสังเกตได้ว่ากราฟทั้ง 2 จะมีลักษณะเหมือนกัน แต่จะแตกต่างกันคือ ค่าความสัมพันธ์ในช่วงฤดูแล้งจะมีค่าน้อยกว่าในฤดูฝน ซึ่งอาจแสดงให้เห็นว่าปริมาณน้ำฝนรายวันย้อนหลังน่าจะมีอิทธิพลต่ออัตราการไหลน้ำท่ารายวันในฤดูแล้งอยู่บ้าง

จากกราฟความสัมพันธ์ทั้ง 3 แบบ ของแต่ละสถานี กล่าวโดยสรุปได้ว่า

- $Q_t$  กับ  $Q_{t-1}$  ยังคงเป็นตัวแปรที่มีค่ามากพอแก่การสนใจ เพื่อใช้เป็นตัวแปรนำเข้าเบื้องต้นในการพยากรณ์  $Q_{t+1}$  เหมือนกับในช่วงฤดูฝน

- ในช่วงฤดูแล้งค่าความสัมพันธ์ระหว่างน้ำท่า-น้ำฝนรายวันย้อนหลังจะมีค่าน้อยมาก ทั้งนี้มาจากสาเหตุที่ได้กล่าวไว้แล้วข้างต้น คือ ในช่วงฤดูแล้งมีฝนตกหนักในพื้นที่น้อยมาก ดังนั้นการนำปริมาณฝนเฉลี่ยทั่วทั้งพื้นที่รายวันย้อนหลังมาใช้เป็นตัวแปรนำเข้าอาจจะไม่ส่งผลต่อการพยากรณ์  $Q_{t+1}$  มากนัก

- การที่พบว่า ณ สถานี KGT.10 มีค่าความสัมพันธ์ระหว่างน้ำท่ากับน้ำฝนรายวันย้อนหลังเกิดขึ้นนั้น อาจเนื่องมาจากมีฝนตกก่อนฤดูในพื้นที่ลุ่มน้ำเหนือสถานี KGT.10 (คลองพระสทิง) ซึ่งอาจจะเกิดจากที่ตั้งของลุ่มน้ำคลองพระสทิงนั้นอยู่ในเขตที่จะได้รับอิทธิพลของลมมรสุมในฤดูฝนก่อนพื้นที่ลุ่มน้ำอื่นๆ

เมื่อใช้วิธีการคัดเลือกชุดตัวแปรนำเข้าจากกราฟความสัมพันธ์ทั้ง 3 ในแบบเดียวกันกับที่ใช้คัดเลือกชุดตัวแปรนำเข้าในฤดูฝน จะได้ชุดตัวแปรนำเข้าเบื้องต้นที่คาดว่าจะมีอิทธิพลต่อการนำไปใช้ในการพยากรณ์  $Q_{t+1}$  ในฤดูแล้ง ณ สถานีวัดน้ำท่าต่างๆ ดังตาราง 6-14

ตาราง 6-14 ชุดตัวแปรนำเข้าเบื้องต้นสำหรับการพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า  
1 วันในฤดูแล้ง

สถานีวัดน้ำท่า	ชุดตัวแปรนำเข้า		
	อัตราการไหลน้ำท่ารายวันย้อนหลัง	ปริมาณฝนเฉลี่ยทั่วทั้งพื้นที่รายวันย้อนหลัง	อัตราการไหลน้ำท่าจากสถานีวัดน้ำท่าที่ตั้งอยู่เหนือน้ำ
150401 (Q1)	Q1 <sub>t</sub>	-	-
KGT.14 (Q2)	Q2 <sub>t</sub>	-	-
KGT.15A (Q3)	Q3 <sub>t</sub>	-	-
KGT.12 (Q4)	Q4 <sub>t</sub>	-	-
KGT.10 (Q5)	Q5 <sub>t</sub> , Q5 <sub>t-1</sub>	R5 <sub>t</sub> , R5 <sub>t-1</sub> , R5 <sub>t-2</sub>	-
KGT.3 (Q6)	Q6 <sub>t</sub> , Q6 <sub>t-1</sub>	-	Q1 <sub>t</sub> , Q2 <sub>t</sub> , Q3 <sub>t</sub> , Q4 <sub>t</sub> , Q5 <sub>t</sub>
พิจารณาจาก	กราฟ Auto correlation และ Partial correlation	กราฟ Cross correlation	ค่า Cross correlation

จากตาราง 6-14 จะเห็นได้ว่าตัวแปรนำเข้าเบื้องต้นที่ใช้พยากรณ์  $Q_{t+1}$  ส่วนใหญ่จะเป็นเพียงอัตราการไหลรายวันย้อนหลังของสถานีตัวมันเอง ทั้งนี้เนื่องจากฝนรายวันที่ตกในพื้นที่ลุ่มน้ำนั้นมีอิทธิพลน้อย (ยกเว้น KGT.10) และข้อมูลน้ำท่าที่ไหลมาจากใต้ผิวดินหรือชั้นน้ำใต้ดินจากแหล่งต่างๆในพื้นที่ลุ่มน้ำในทางปฏิบัติทำการวัดและหาข้อมูลได้ยาก จึงขาดข้อมูลส่วนนี้ซึ่งน่าจะเป็นปัจจัยหลักในการนำมาพยากรณ์ปริมาณน้ำท่าในฤดูแล้ง สำหรับที่สถานี KGT.3 จะยังคงใช้อัตราการไหลน้ำท่าของสถานีต่างๆที่ตั้งอยู่เหนือน้ำมาเป็นตัวแปรนำเข้าเพิ่มเติมด้วย โดยวิธีการคัดเลือกก็จะพิจารณาจากค่าความสัมพันธ์แบบ cross correlation เหมือนกับที่ใช้คัดเลือกในฤดูฝน ดังตาราง 6-15

ตาราง 6-15 ค่าความสัมพันธ์แบบ cross correlation ระหว่างอัตราการไหลน้ำท่ารายวัน ณ สถานี KGT.3 และสถานีวัดน้ำท่าด้านเหนือน้ำ ในฤดูแล้ง

Time (Days)	KGT.3				
	Q150401	KGT.14	KGT.15A	KGT.12	KGT.10
t	0.789	0.487	0.566	0.776	0.660
t-1	0.756	0.472	0.538	0.748	0.654
t-2	0.717	0.450	0.510	0.704	0.646
t-3	0.682	0.422	0.485	0.653	0.629
t-4	0.647	0.390	0.460	0.608	0.576
t-5	0.611	0.359	0.433	0.572	0.529
t-6	0.578	0.337	0.409	0.541	0.496

### 6.2.1.2 การทดสอบชุดตัวแปรนำเข้าที่มีนัยสำคัญ

การทดสอบชุดตัวแปรนำเข้าที่มีนัยสำคัญสำหรับการพยากรณ์  $Q_{t+1}$  ในฤดูแล้ง จะใช้จำนวนข้อมูลเพื่อปรับเทียบแบบจำลองทั้งหมด 3478 ชุด และใช้ปรับทานแบบจำลองจำนวนทั้งหมด 455 ชุดข้อมูล สำหรับวิธีการทดสอบนั้นจะใช้วิธีการเดียวกับที่ใช้ในฤดูฝนแต่จะแตกต่างกันตรงการทดสอบตัวแปรนำเข้าที่เป็นปริมาณฝนเฉลี่ยทั่วทั้งพื้นที่รายวันย้อนหลังในฤดูแล้งนั้น จะพิจารณารวมกันเป็นชุดเดียว (ไม่แยกพิจารณาที่ละตัวเหมือนในฤดูฝน) ทั้งนี้เพื่อต้องการเห็นอิทธิพลของฝนรายวันย้อนหลังที่มีต่อ  $Q_{t+1}$  เพิ่มมากขึ้น เนื่องจากถ้าแยกพิจารณาที่ละตัวจะทำให้เห็นอิทธิพลของฝนรายวันย้อนหลังที่มีต่อ  $Q_{t+1}$  ไม่ชัดเจนมากนัก และจำนวนวันย้อนหลังของปริมาณฝนเฉลี่ยทั่วทั้งพื้นที่ในฤดูแล้งจะกำหนดให้มีค่าเท่ากับจำนวนวันย้อนหลังในช่วงฤดูฝน สำหรับผลการทดสอบแยกตามสถานีวัดน้ำท่าต่างๆ แสดงได้ดังตาราง 6-16 ถึง 6-21 ซึ่งสามารถสรุปผลการทดสอบได้ดังต่อไปนี้

1) ชุดตัวแปรนำเข้าเพื่อใช้พยากรณ์  $Q_{t+1}$  ณ สถานีวัดน้ำท่าต่างๆ ที่ผ่านการคัดเลือกจากการทดสอบนั้น ยังคงสอดคล้องกับชุดตัวแปรนำเข้าเบื้องต้นที่คัดเลือกมาโดยวิธีการใช้กราฟความสัมพันธ์ทั้ง 3 กราฟ (ตาราง 6-14) ซึ่งให้ผลเช่นเดียวกับการคัดเลือกตัวแปรนำเข้าในฤดูฝน

2) แบบจำลองการพยากรณ์  $Q_{t+1}$  ณ สถานี KGT.3 ให้มีความแม่นยำในการพยากรณ์มากที่สุด รองลงมาคือ แบบจำลอง ณ สถานี 150401, KGT.12, KGT.15A, KGT.10 และ KGT.14 ซึ่งพิจารณาได้จากประสิทธิภาพของแบบจำลองในช่วงปรับเทียบ ซึ่งมีค่าดังนี้ 97.28%, 96.33%, 96.20%, 92.24%, 84.11% และ 83.76% ตามลำดับ โดยความแม่นยำในการพยากรณ์ของแต่ละสถานีนั้น ยังคงขึ้นอยู่กับลักษณะอัตราการไหลน้ำท่าในแต่ละสถานี คือ ถ้าอัตราการไหลน้ำท่าในฤดูแล้งของแต่ละวันมีค่าไม่แตกต่างหรือผันแปรมากนัก ประสิทธิภาพในการพยากรณ์ของแบบจำลองก็จะมีค่าสูง นอกจากนี้ยังเห็นได้ว่าการนำอัตราการไหลน้ำท่าจากสถานีวัดน้ำท่าด้านเหนือ น้ำ มาใช้พยากรณ์  $Q_{t+1}$  ณ สถานี KGT.3 ยังคงช่วยให้แบบจำลองมีประสิทธิภาพในการพยากรณ์เพิ่มขึ้นมาก

3) เมื่อนำค่าประสิทธิภาพในการพยากรณ์  $Q_{t+1}$  ของแบบจำลองที่ใช้พยากรณ์อัตราการไหลน้ำท่าในฤดูแล้ง ณ สถานีวัดน้ำท่าต่างๆ ที่ผ่านการคัดเลือกมาเปรียบเทียบกับค่าประสิทธิภาพของแบบจำลองในฤดูฝน สามารถแสดงผลการเปรียบเทียบได้ดังตาราง 6-22

ตาราง 6-16 ผลการทดสอบตัวแปรนำเข้าสำหรับพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า 1 วัน ณ สถานี 150401 ในช่วงฤดูแล้ง

Station :	150401	(Area 1)
DA :	636	Km <sup>2</sup>
Forecast :	1	Day Ahead
Training Period No. :	3478	Momentum (α) : 0.45:0.95 (Change at 5000 Intervals)
Testing Period No. :	455	Learning Rate (η) : 0.01
		n : 10,000 Intervals
		Hidden Layer : 3 Nodes (1 Layer)

Statistic of Basin	Train Period	Test Period
Q <sub>avg</sub> (m <sup>3</sup> /s)	0.99	0.73
Std. (m <sup>3</sup> /s)	1.13	0.84
Max (m <sup>3</sup> /s)	12.5	5.8
Min (m <sup>3</sup> /s)	0.0	0.0

Models	Input Variables	Training					Testing					
		EI (%)	Rate of Improvement (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	Rate of Improvement (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	Remark
1	Q <sub>1,t-1</sub>	96.33	2.83	0.217	0.062	6.13	98.70	-7.49	0.096	0.058	0.66	Compare with M1
2	Q <sub>1,t-1</sub>	96.43	2.83	0.214	0.063	6.19	98.61	-7.49	0.100	0.058	0.65	Compare with M1
3	Q <sub>1,t-1</sub> , R <sub>1,t-1</sub>	96.47	3.73	0.213	0.060	5.53	98.70	-0.61	0.093	0.051	0.61	Compare with M1

ตาราง 6-17 ผลการทดสอบตัวแปรนำเข้าสำหรับพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า 1 วัน ณ สถานี KGT.14 ในช่วงฤดูแล้ง

Station :	KGT.14	(Area 2)
DA :	336	Km <sup>2</sup>
Forecast :	1	Day Ahead
Training Period No. :	3478	Momentum (α) : 0.45:0.95 (Change at 5000 Intervals)
Testing Period No. :	455	Learning Rate (η) : 0.01
		n : 10,000 Intervals
		Hidden Layer : 3 Nodes (1 Layer)

Statistic of Basin	Train Period	Test Period
Q <sub>avg</sub> (m <sup>3</sup> /s)	0.27	0.11
Std. (m <sup>3</sup> /s)	0.31	0.16
Max (m <sup>3</sup> /s)	3.9	1.21
Min (m <sup>3</sup> /s)	0.0	0.0

Models	Input Variables	Training					Testing					
		EI (%)	Rate of Improvement (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	Rate of Improvement (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	Remark
1	Q <sub>2,t-1</sub>	83.76	-0.59	0.124	0.033	3.43	81.50	-1.52	0.068	0.020	1.20	Compare with M1
2	Q <sub>2,t-1</sub>	83.69	-0.59	0.125	0.031	3.44	81.22	-1.52	0.069	0.020	1.20	Compare with M1
3	Q <sub>2,t-1</sub> , R <sub>2,t-1</sub>	84.50	4.53	0.121	0.034	3.44	81.12	-2.06	0.099	0.021	1.13	Compare with M1

ตาราง 6-18 ผลการทดสอบตัวแปรนำเข้าสำหรับพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า 1 วัน ณ สถานี KGT.15A ในช่วงฤดูแล้ง

Statistic of Basin		Train Period	Test Period
$Q_{avg}$	( $m^3/s$ )	0.67	0.51
Std.	( $m^3/s$ )	1.07	0.48
Max	( $m^3/s$ )	13.6	3.23
Min	( $m^3/s$ )	0.0	0.0

Station : KGT.15A (Area 3)  
 DA : 530  $Km^2$  n : 10,000 Intervals  
 Forecast : 1 Day Ahead Hidden Layer : 3 Nodes (1 Layer)  
 Training Period No. : 3478 Momentum ( $\alpha$ ) : 0.45:0.95 (Change at 5000 Intervals)  
 Testing Period No. : 455 Learning Rate ( $\eta$ ) : 0.01

Models	Input Variables	Training					Testing					Remark
		EI (%)	Rate of Improvement (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	EI (%)	Rate of Improvement (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	
1	$Q_3$	92.24	1.44	0.299	0.089	6.83	87.93	0.122	0.055	1.48	Compare with M1	
2	$Q_3, I_{t-1}$	92.36	1.44	0.296	0.087	6.93	86.79	0.124	0.055	1.48	Compare with M1	
3	$Q_3, R_3, I_{t-1}$	92.55	3.91	0.292	0.088	6.89	87.50	0.121	0.054	1.36	Compare with M1	

ตาราง 6-19 ผลการทดสอบตัวแปรนำเข้าสำหรับพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า 1 วัน ณ สถานี KGT.12 ในช่วงฤดูแล้ง

Statistic of Basin		Train Period	Test Period
$Q_{avg}$	( $m^3/s$ )	1.34	0.72
Std.	( $m^3/s$ )	1.79	1.06
Max	( $m^3/s$ )	15.2	6.21
Min	( $m^3/s$ )	0.0	0.0

Station : KGT.12 (Area 4)  
 DA : 1,540  $Km^2$  n : 10,000 Intervals  
 Forecast : 1 Day Ahead Hidden Layer : 3 Nodes (1 Layer)  
 Training Period No. : 3478 Momentum ( $\alpha$ ) : 0.45:0.95 (Change at 5000 Intervals)  
 Testing Period No. : 455 Learning Rate ( $\eta$ ) : 0.01

Models	Input Variables	Training					Testing					Remark
		EI (%)	Rate of Improvement (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	EI (%)	Rate of Improvement (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	
1	$Q_4$	96.20	3.46	0.349	0.105	8.92	98.58	0.126	0.065	1.16	Compare with M1	
2	$Q_4, I_{t-1}$	96.34	3.46	0.343	0.103	8.74	98.63	0.124	0.067	1.16	Compare with M1	
3	$Q_4, R_4, I_{t-1}, I_{t-2}, I_{t-3}, I_{t-4}, I_{t-5}$	96.38	4.54	0.323	0.107	8.44	98.38	0.134	0.068	1.26	Compare with M1	

ตาราง 6-20 ผลการทดสอบตัวแปรนำเข้าสำหรับพยากรณ์อัตราการไหลหน้าท่ารายวันล่วงหน้า 1 วัน ณ สถานี KGT.10 ในช่วงฤดูแล้ง

Station : KGT.10 (Area 5)

DA : 2,523 Km<sup>2</sup>

Forecast : 1 Day Ahead

Training Period No. : 3478

Testing Period No. : 455

n : 10,000 Intervals

Hidden Layer : 3 Nodes (1 Layer)

Momentum (α) : 0.45-0.95 (Change at 5000 Intervals)

Learning Rate (η) : 0.01

Statistic of Basin		Train Period	Test Period
Q <sub>avg</sub>	(m <sup>3</sup> /s)	1.98	1.60
Std.	(m <sup>3</sup> /s)	3.36	1.95
Max	(m <sup>3</sup> /s)	101.6	22.56
Min	(m <sup>3</sup> /s)	0.0	0.0

Models	Input Variables	Training					Testing					Remark
		EI (%)	Rate of Improvement (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	Rate of Improvement (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	
1	Q5 <sub>t</sub>	70.62	-	1.019	0.404	31.92	82.26	-	0.620	0.305	10.00	
2	Q5 <sub>t,t-1</sub>	77.16	22.28	0.860	0.373	25.04	83.20	5.28	0.576	0.280	7.63	Compare with M1
3	Q5 <sub>t,t-1,t-2</sub>	76.44	-3.15	0.886	0.380	25.13	81.23	-11.73	0.609	0.293	8.66	Compare with M2
	Q5 <sub>t,t-1,t-2</sub>	84.71	30.43	0.779	0.260	14.32	87.88	27.88	0.458	0.216	3.40	Compare with M3

ตาราง 6-21 ผลการทดสอบปรับนำเข้าสู่สำหรับพยากรณ์อัตราการไหลน้ำทำรายวันล่วงหน้า 1 วัน ณ สถานี KGT.3 ในช่วงแล้ง

Station :	KGT.3 (Area 6)	
DA :	7.502 Km <sup>2</sup>	
Forecast :	1 Day Ahead	
Training Period No. :	4916	
Testing Period No. :	642	
	n : 10,000 Intervals	
	Hidden Layer : 3 Nodes (1 Layer)	
	Momentum (α) : 0.45; 0.95 (Change at 5000 Intervals)	
	Learning Rate (η) : 0.01	
Statistic of Basin	Train Period	Test Period
Q <sub>avg</sub> (m <sup>3</sup> /s)	6.73	6.69
Std. (m <sup>3</sup> /s)	8.11	6.84
Max (m <sup>3</sup> /s)	111.9	41.1
Min (m <sup>3</sup> /s)	0.0	0.0

Models	Input Variables	Training					Testing					Remark
		EI (%)	Rate of Improvement (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	Rate of Improvement (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	
1	Q6 <sub>t</sub>	95.96	-	1.630	0.528	35.8	98.11	-	0.931	0.353	13.9	
2	Q6 <sub>t, t-1</sub>	96.71	18.61	1.471	0.483	34.3	98.03	-3.99	0.961	0.362	14.0	Compare with M1
3	Q6 <sub>t, t-1, t-2</sub>	96.24	-14.44	1.573	0.515	34.7	98.06	1.63	0.953	0.366	13.9	Compare with M2
4	Q6 <sub>t, R<sub>t, t-1, t-2, t-3</sub></sub>	96.16	4.82	1.596	0.523	34.9	98.25	7.39	0.907	0.355	14.0	Compare with M1
5	Q1 <sub>t, t-1</sub> , Q2 <sub>t, t-1</sub> , Q3 <sub>t, t-1</sub> , Q4 <sub>t, t-1</sub> , Q5 <sub>t, t-1</sub>	79.32	-	3.689	2.454	42.3	76.59	-	3.312	2.255	11.9	ไม่เหมาะสมกับข้อมูล
6	Q1 <sub>t, t-1</sub> , Q2 <sub>t, t-1</sub> , Q3 <sub>t, t-1</sub> , Q4 <sub>t, t-1</sub> , Q5 <sub>t, t-1</sub>	82.77	16.67	3.368	2.279	43.8	78.83	9.57	3.149	2.183	11.7	Compare with M5
7	Q6 <sub>t, t-1</sub> , Q1 <sub>t, t-1</sub> , Q2 <sub>t, t-1</sub> , Q3 <sub>t, t-1</sub> , Q4 <sub>t, t-1</sub> , Q5 <sub>t, t-1</sub>	97.28	17.36	1.337	0.497	34.7	98.21	9.30	0.915	0.400	12.2	Compare with M2
8	Q6 <sub>t, t-1</sub> , Q1 <sub>t, t-1</sub> , Q2 <sub>t, t-1</sub> , Q3 <sub>t, t-1</sub> , Q4 <sub>t, t-1</sub> , Q5 <sub>t, t-1</sub>	97.34	2.21	1.325	0.564	31.7	98.06	-8.81	0.955	0.514	12.2	Compare with M7

ตาราง 6-22 การเปรียบเทียบค่าประสิทธิภาพของแบบจำลองที่ใช้พยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า 1 วันในฤดูแล้งและฤดูฝน

สถานีวัดน้ำท่า	เปรียบเทียบ		ปรับทาน	
	EI (%) แบบจำลองฤดูแล้ง	EI (%) แบบจำลองฤดูฝน	EI (%) แบบจำลองฤดูแล้ง	EI (%) แบบจำลองฤดูฝน
150401	96.33	82.99	98.70	73.57
KGT.14	83.76	70.31	81.50	68.51
KGT.15A	92.24	81.51	86.79	78.56
KGT.12	96.20	98.74	98.58	98.34
KGT.10	84.11	91.20	87.88	91.26
KGT.3	97.28	99.06	98.21	99.10

จากผลการเปรียบเทียบจะเห็นได้ว่า

- ณ สถานี 150401, KGT.14 และ KGT.15A ค่าประสิทธิภาพของแบบจำลองฤดูแล้งมีค่ามากกว่าแบบจำลองฤดูฝน ทั้งในช่วงเปรียบเทียบและปรับทาน เนื่องจากอัตราการไหลน้ำท่ารายวันในช่วงฤดูแล้งมีค่าต่ำและอัตราการไหลน้ำท่าของแต่ละวันมีค่าไม่แตกต่างกันมากนัก เมื่อเทียบกับฤดูฝน (พิจารณาจากค่าสถิติของแต่ละลุ่มน้ำ) ดังนั้นในการพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้าในฤดูแล้งจึงมีค่าใกล้เคียงกับความเป็นจริงมากกว่าในฤดูฝน

- ณ สถานี KGT.10 ค่าประสิทธิภาพของแบบจำลองฤดูแล้งมีค่าน้อยกว่าแบบจำลองฤดูฝนทั้งในช่วงเปรียบเทียบและปรับทาน สืบเนื่องมาจากเมื่อนำข้อมูลอัตราการไหลน้ำท่ารายวันของ KGT.10 ในช่วงฤดูแล้งมาพิจารณานั้น พบว่า ในช่วงกลางเดือนเมษายนของข้อมูลส่วนใหญ่จะมีอัตราการไหลน้ำท่ารายวันเพิ่มขึ้นจากเดิมอย่างมาก เนื่องจากฝนที่ตกก่อนฤดูทำให้ผลการพยากรณ์บริเวณส่วนนี้จากแบบจำลองฤดูแล้งมีค่าผิดพลาดจากความเป็นจริงมาก ส่งผลให้ค่าประสิทธิภาพของแบบจำลองฤดูแล้ง ณ สถานี KGT.10 มีค่าต่ำกว่าแบบจำลองสำหรับฤดูฝน

#### 6.2.2 การคัดเลือกค่าพารามิเตอร์และโครงข่ายภายในที่เหมาะสมในแบบจำลอง ANN

ค่าพารามิเตอร์  $\alpha$  และ  $\eta$  ที่จะใช้ในช่วงการปรับเทียบแบบจำลองฤดูแล้งนั้น จะยังคงใช้ค่าเดียวกับที่ใช้ในแบบจำลองสำหรับฤดูฝนคือ ค่า  $\alpha = 0.45$  และ  $0.95$  ซึ่งจะเปลี่ยนที่รอบการ



คำนวณ 5000 รอบและค่า  $\eta = 0.01$  ส่วนการคัดเลือกโครงข่ายภายในที่เหมาะสมกับแบบจำลอง ANN ในการพยากรณ์  $Q_{n+1}$  ในฤดูแล้ง แสดงได้ดังตาราง 6-23

ตาราง 6-23 โครงข่ายภายในที่เหมาะสมในแบบจำลอง ANN สำหรับพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า 1 วันในฤดูแล้ง



สถานีวัดน้ำท่า	จำนวนตัวแปรนำเข้า	จำนวนหน่วยที่เหมาะสม		เปรียบเทียบ		ปรับทาน	
		ชั้นแอบแฝงที่ 1	ชั้นแอบแฝงที่ 2	EI (%)	RMSE (ม. <sup>3</sup> /วินาที)	EI (%)	RMSE (ม. <sup>3</sup> /วินาที)
150401	1	2	-	96.33	0.217	98.68	0.097
KGT.14	1	2	-	83.77	0.124	81.52	0.068
KGT.15A	1	2	-	92.28	0.298	87.52	0.120
KGT.12	1	2	-	96.21	0.348	98.63	0.124
KGT.10	5	3	2	86.07	0.718	87.98	0.450
KGT.3	7	4	3	98.01	1.291	98.55	0.883

รายละเอียดการคัดเลือกได้แสดงไว้ในภาคผนวก ค3



จากตารางที่ 6-23 พบว่าโครงข่ายภายในที่เหมาะสมกับแบบจำลอง ANN ที่มีตัวแปรนำเข้าเพียงตัวเดียว (150401, KGT.14, KGT.15A และ KGT.12) คือ โครงข่ายที่มีชั้นแอบแฝงชั้นเดียวและมีจำนวนหน่วย 2 หน่วย ส่วนแบบจำลอง ANN ที่มีตัวแปรนำเข้าหลายตัว (KGT.10 และ KGT.3) ลักษณะโครงข่ายภายในที่เหมาะสมยังคงให้ผลเหมือนกับในแบบจำลองฤดูฝน คือจะใช้จำนวนชั้นแอบแฝง 2 ชั้น และแต่ละชั้นจะมีจำนวนหน่วยประมาณครึ่งหนึ่งของจำนวนตัวแปรนำเข้า

### 6.2.3 การปรับปรุงผลการพยากรณ์และการพยากรณ์ล่วงหน้ามากกว่า 1 วัน



เมื่อนำอนุกรมค่าความผิดพลาดจากแบบจำลอง ANN ที่ใช้พยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า 1 วันในฤดูแล้ง ณ สถานีต่างๆ มาตรวจสอบความเป็นอิสระต่อกัน โดยให้กราฟ autocorrelation และ partial autocorrelation นั้น แสดงผลได้ดังรูป 6-27 ซึ่งจะเห็นได้ว่าอนุกรมค่าความผิดพลาดจากแบบจำลอง ณ สถานีต่างๆ มีความเป็นอิสระต่อกันจึงไม่สามารถนำมาจัดสร้างเป็นแบบจำลองเพื่อปรับปรุงผลการพยากรณ์ต่อไปได้





(a) สถานี 150401





(b) สถานี KGT.14





(c) สถานี KGT.15A



(d) สถานี KGT.12



(e) สถานี KGT.10



(f) สถานี KGT.3

รูป 6-27 การตรวจสอบความเป็นอิสระของอนุกรมค่าความผิดพลาดจากผลการพยากรณ์

$Q_{t+1}$  ของแบบจำลอง ANN สำหรับฤดูแล้ง ณ สถานีวัดน้ำท่าต่างๆ

สำหรับการพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้ามากกว่า 1 วันของแต่ละสถานี โดยวิธี Direct Step และ Standard Step ตลอดทั้งการปรับปรุงผลการพยากรณ์โดยใช้แบบจำลองอนุกรมเวลานั้นแสดงผลได้ดังตารางที่ 6-24 (ชุดตัวแปรนำเข้าที่ใช้ในการพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้าโดยวิธี Standard step แสดงดังตาราง 6-25) โดยจำนวนวันล่วงหน้ามากที่สุดที่จะพยากรณ์ในแต่ละสถานีนั้น จะพิจารณาจากค่าประสิทธิภาพของแบบจำลอง คือ จะหยุดทำการพยากรณ์ล่วงหน้า เมื่อประสิทธิภาพของแบบจำลองทั้งในช่วงปรับเทียบและปรับทานมีค่าต่ำกว่า 80% และจะพยากรณ์ล่วงหน้าไม่เกิน 7 วัน ทั้งนี้เนื่องจากในฤดูแล้งไม่มีตัวชี้วัดทางกายภาพที่จะมาอธิบายถึงจำนวนวันที่จะพยากรณ์ได้มากที่สุดเหมือนในฤดูฝนซึ่งจะใช้ค่า  $T_c$  เป็นตัวชี้วัด

จากผลการศึกษาในตาราง 6-24 พบว่า

1) การพยากรณ์ล่วงหน้ามากกว่า 1 วัน โดยวิธี Standard step ให้ผลการพยากรณ์ที่ดีกว่าวิธี Direct step โดยเฉพาะเมื่อระยะเวลาการพยากรณ์ล่วงหน้ายาวนานขึ้น การพยากรณ์ล่วงหน้าโดยวิธี Standard step จะให้ผลการพยากรณ์ดีกว่าวิธี Direct step อย่างชัดเจน และให้ผลการศึกษาเช่นเดียวกับในฤดูฝน

2) เมื่อระยะเวลาการพยากรณ์ล่วงหน้ายาวนานขึ้นจะทำให้ความแม่นยำในการพยากรณ์ลดลงตามลำดับ ทั้งนี้เกิดจากค่าความผิดพลาดที่สะสมมา จากผลการพยากรณ์ในวันที่ผ่านมา

3) การพยากรณ์อัตราการไหลน้ำท่ารายวันในช่วงฤดูแล้ง ณ สถานี 150401, KGT.14, KGT.15A และ KGT.12 สามารถพยากรณ์ล่วงหน้าได้ยาวนานมากกว่าในฤดูฝน เพราะอัตราการไหลน้ำท่าในฤดูแล้งมีความผันผวนน้อยกว่าในฤดูฝน

4) แบบจำลองอนุกรมเวลาที่เหมาะสมในการนำมาใช้ปรับปรุงผลการพยากรณ์ให้มีความแม่นยำขึ้นนั้น คือแบบจำลอง MA(2) โดยจะช่วยปรับปรุงผลการพยากรณ์ให้มีประสิทธิภาพเพิ่มขึ้นประมาณ 1-9% ทั้งในช่วงปรับเทียบและปรับทานแบบจำลอง โดยเฉพาะการพยากรณ์ล่วงหน้า 2 วัน ณ สถานี KGT.10 การพยากรณ์ค่าความผิดพลาดล่วงหน้าจากแบบจำลอง MA(2) ช่วยเพิ่มประสิทธิภาพในการพยากรณ์ถึง 8.32% ในช่วงปรับเทียบและ 7.76% ในช่วงปรับทานแบบจำลอง

เมื่อนำผลการพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้าโดยวิธี Standard step และการปรับปรุงผลการพยากรณ์โดยใช้แบบจำลองอนุกรมเวลา ในช่วงปรับทานแบบจำลอง ซึ่งแบ่งเป็นปีที่แล้งมาก แล้งเฉลี่ย และแล้งน้อย ของสถานีต่างๆ มาพิจารณาเปรียบเทียบกับข้อมูลที่วัดจริง แสดงได้ดังรูปที่ 6-28 ถึง 6-33 ซึ่งจะเห็นได้ว่า

ตาราง 6-24 สรุปผลการพยากรณ์อัตราการทำลายส่วนหมักกว่า 1 วัน ในฤดูแล้ง

สถานี วัดน้ำท่า	พายุกรร ตั้งหน้า (วัน)	ปรับเทียบ (Training Period)										ปรับเทียบ (Testing Period)																			
		Direct Step					Standard Step					ANN+Residual Adjustment					ปรับเทียบ					ANN+Residual Adjustment					ปรับเทียบ				
		ลักษณะ โครงสร้าง	EI (%)	RMSE (ม.กิโลกรัม)	ลักษณะ โครงสร้าง	EI (%)	RMSE (ม.กิโลกรัม)	แบบจำลอง พยากรณ์	EI (%)	RMSE (ม.กิโลกรัม)	ปรับเทียบ $\Delta EI$ (%)	EI (%)	RMSE (ม.กิโลกรัม)	ANN+Residual Adjustment	EI (%)	RMSE (ม.กิโลกรัม)	ปรับเทียบ $\Delta EI$ (%)	EI (%)	RMSE (ม.กิโลกรัม)	ANN+Residual Adjustment	EI (%)	RMSE (ม.กิโลกรัม)	ปรับเทียบ $\Delta EI$ (%)	EI (%)	RMSE (ม.กิโลกรัม)	ปรับเทียบ $\Delta EI$ (%)					
150401	2	1-2-1	93.88	0.269	1-2-1	93.94	0.267	MA(2)	95.93	0.219	1.99	96.68	0.144	96.78	0.142	98.23	0.106	1.44	98.23	0.106	1.44	98.23	0.106	1.44	98.23	0.106	1.44				
	3	1-2-1	92.00	0.296	1-2-1	93.27	0.271	MA(2)	94.20	0.252	0.93	94.68	0.172	96.19	0.146	97.51	0.118	1.32	97.51	0.118	1.32	97.51	0.118	1.32	97.51	0.118	1.32				
	4	1-2-1	90.40	0.312	1-2-1	92.27	0.280	MA(2)	93.63	0.254	1.36	92.47	0.194	95.32	0.153	97.30	0.116	1.98	97.30	0.116	1.98	97.30	0.116	1.98	97.30	0.116	1.98				
	5	1-2-1	84.98	0.389	1-2-1	87.93	0.344	MA(2)	88.62	0.332	0.79	90.07	0.212	94.79	0.153	96.08	0.133	1.30	96.08	0.133	1.30	96.08	0.133	1.30	96.08	0.133	1.30				
	6	1-2-1	80.67	0.410	1-2-1	84.46	0.378	MA(2)	86.60	0.351	2.14	87.53	0.227	93.27	0.167	94.86	0.146	1.59	94.86	0.146	1.59	94.86	0.146	1.59	94.86	0.146	1.59				
	7	1-2-1	77.46	0.431	1-2-1	82.28	0.391	MA(2)	84.29	0.368	2.01	84.83	0.243	92.42	0.171	93.65	0.156	1.22	93.65	0.156	1.22	93.65	0.156	1.22	93.65	0.156	1.22				
	2	1-2-1	78.07	0.143	1-2-1	78.37	0.139	MA(2)	82.37	0.126	4.00	87.91	0.090	87.97	0.090	87.75	0.076	0.78	87.75	0.076	0.78	87.75	0.076	0.78	87.75	0.076	0.78				
KGT.15A	2	1-2-1	85.64	0.392	1-2-1	85.77	0.391	MA(2)	90.11	0.326	4.34	80.64	0.146	80.94	0.145	87.09	0.119	6.15	87.09	0.119	6.15	87.09	0.119	6.15	87.09	0.119	6.15				
	3	1-2-1	80.45	0.443	1-2-1	84.03	0.400	MA(2)	88.52	0.340	4.49	78.02	0.152	79.69	0.146	88.56	0.119	6.87	88.56	0.119	6.87	88.56	0.119	6.87	88.56	0.119	6.87				
	4	1-2-1	76.18	0.474	1-2-1	81.76	0.415	MA(2)	84.90	0.377	3.15	74.36	0.159	76.64	0.153	80.72	0.139	4.08	80.72	0.139	4.08	80.72	0.139	4.08	80.72	0.139	4.08				
	5	1-2-1	73.75	0.481	1-2-1	77.98	0.441	MA(2)	82.36	0.395	4.39	70.95	0.168	72.48	0.162	78.45	0.143	5.95	78.45	0.143	5.95	78.45	0.143	5.95	78.45	0.143	5.95				
	6	1-2-1	68.45	0.528	1-2-1	74.57	0.459	MA(2)	78.33	0.423	3.77	66.47	0.181	70.15	0.165	75.56	0.149	5.41	75.56	0.149	5.41	75.56	0.149	5.41	75.56	0.149	5.41				
	2	1-2-1	90.88	0.623	1-2-1	90.90	0.523	MA(2)	95.87	0.352	4.87	96.73	0.182	96.97	0.176	98.45	0.125	1.49	98.45	0.125	1.49	98.45	0.125	1.49	98.45	0.125	1.49				
KGT.12	3	1-2-1	87.63	0.691	1-2-1	89.87	0.535	MA(2)	92.37	0.484	2.50	94.95	0.215	96.54	0.178	97.64	0.151	0.99	97.64	0.151	0.99	97.64	0.151	0.99	97.64	0.151	0.99				
	4	1-2-1	85.13	0.631	1-2-1	87.34	0.582	MA(2)	89.95	0.519	2.61	92.93	0.242	95.25	0.199	96.75	0.164	1.49	96.75	0.164	1.49	96.75	0.164	1.49	96.75	0.164	1.49				
	5	1-2-1	81.80	0.671	1-2-1	84.86	0.621	MA(2)	86.54	0.595	1.68	90.74	0.262	94.09	0.209	95.01	0.192	0.93	95.01	0.192	0.93	95.01	0.192	0.93	95.01	0.192	0.93				
	6	1-2-1	77.15	0.724	1-2-1	81.36	0.673	MA(2)	83.44	0.634	2.08	85.18	0.309	92.22	0.226	93.22	0.211	1.00	93.22	0.211	1.00	93.22	0.211	1.00	93.22	0.211	1.00				
	7	1-2-1	72.93	0.752	1-2-1	77.92	0.717	MA(2)	80.28	0.678	2.35	85.29	0.289	90.16	0.237	91.31	0.222	1.15	91.31	0.222	1.15	91.31	0.222	1.15	91.31	0.222	1.15				

ตาราง 6-24 สรุปผลการพยากรณ์อัตราการใช้พลังงานไฟฟ้ารายวันล่วงหน้ามากกว่า 1 วัน ในฤดูแล้ง (ต่อ)

สถานี วัดน้ำท่า	พยากรณ์ ล่วงหน้า (วัน)	เปรียบเทียบ (Training Period)										เปรียบเทียบ (Testing Period)														
		Direct Step					Standard Step					ANN+Residual Adjustment					ปรับสภาพ					ปรับสภาพ				
		ลักษณะ โครงสร้าง	EI (%)	RMSE (ม <sup>3</sup> /วินาที)	ลักษณะ โครงสร้าง	EI (%)	RMSE (ม <sup>3</sup> /วินาที)	แบบจำลอง อนุกรมเวลา	EI (%)	RMSE (ม <sup>3</sup> /วินาที)	ที่เพิ่มขึ้น $\Delta EI$ (%)	EI (%)	RMSE (ม <sup>3</sup> /วินาที)	EI (%)	RMSE (ม <sup>3</sup> /วินาที)	EI (%)	RMSE (ม <sup>3</sup> /วินาที)	EI (%)	RMSE (ม <sup>3</sup> /วินาที)	EI (%)	RMSE (ม <sup>3</sup> /วินาที)	EI (%)	RMSE (ม <sup>3</sup> /วินาที)	ที่เพิ่มขึ้น $\Delta EI$ (%)		
KGT-10	2	5-5-1	72.22	1.003	4-4-1	72.71	0.984	MA(2)	81.02	0.828	8.32	74.95	0.625	75.04	0.611	83.81	0.502	7.76								
	3	5-5-1	63.89	1.129	3-3-1	68.09	1.061	MA(2)	74.94	0.941	6.86	69.44	0.684	72.79	0.827	77.43	0.671	4.65								
	2	7-4-3-1	94.06	1.914	7-4-3-1	94.64	1.824	MA(2)	95.76	1.620	1.12	95.94	1.508	96.53	1.239	97.18	1.117	0.65								
KGT-3	3	7-4-3-2	89.49	2.485	7-4-3-1	93.23	1.884	MA(2)	94.91	1.729	1.68	93.57	1.615	94.14	1.548	96.28	1.234	2.14								
	4	7-4-3-3	86.82	2.722	6-3-3-1	91.02	2.239	MA(2)	92.66	2.025	1.63	91.32	1.847	93.24	1.678	95.71	1.275	2.47								
	6	7-4-3-4	81.78	3.136	5-3-2-1	88.53	2.469	MA(2)	90.22	2.279	1.70	88.64	2.082	91.71	1.817	94.50	1.386	2.79								
	6	7-4-3-5	77.62	3.441	5-3-2-1	85.99	2.664	MA(2)	88.29	2.435	2.30	84.82	2.385	89.01	1.936	93.79	1.442	4.78								
	7	7-4-3-6	74.34	3.634	5-3-2-1	83.17	2.818	MA(2)	86.80	2.554	3.43	80.14	2.897	87.80	2.073	92.20	1.573	4.60								


หมายเหตุ: 1)  $\Delta EI = (EI \text{ จากแบบจำลอง ANN+Residual Adjustment}) - (EI \text{ จากแบบจำลอง ANN โดยวิธี Standard step})$

2) รายละเอียดผลการทดสอบแบบจำลองแสดงไว้ใน ภาคผนวก ค4


3) ผลการตรวจสอบความแม่นยำของอนุกรมเวลาจากพยากรณ์ แสดงไว้ใน ภาคผนวก ง2

ตาราง 6-25 สรุปตัวแปรนำเข้าที่ใช้ในการพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า ในฤดูแล้ง โดยวิธี Standard step


การพยากรณ์		สถานีต้นน้ำท่า					
ล่วงหน้า (วัน)	150401	KGT.14	KGT.15A	KGT.12	KGT.10	KGT.3	
1	Q <sub>1</sub>	Q <sub>2</sub>	Q <sub>3</sub>	Q <sub>4</sub>	Q <sub>5</sub> , Q <sub>5,t-1</sub> , R <sub>5</sub> , R <sub>5,t-1</sub> , R <sub>5,t-2</sub>	Q <sub>6</sub> , Q <sub>6,t-1</sub> , Q <sub>1</sub> , Q <sub>2</sub> , Q <sub>3</sub> , Q <sub>4</sub> , Q <sub>5</sub>	
2	FQ <sub>1,t-1</sub>	FQ <sub>2,t-1</sub>	FQ <sub>3,t-1</sub>	FQ <sub>4,t-1</sub>	FQ <sub>5,t-1</sub> , Q <sub>5</sub> , R <sub>5</sub> , R <sub>5,t-1</sub>	FQ <sub>6,t-1</sub> , Q <sub>6</sub> , FQ <sub>1,t-1</sub> , FQ <sub>2,t-1</sub> , FQ <sub>3,t-1</sub> , FQ <sub>4,t-1</sub> , FQ <sub>5,t-1</sub>	
3	FQ <sub>1,t-2</sub>	-	FQ <sub>3,t-2</sub>	FQ <sub>4,t-2</sub>	FQ <sub>5,t-2</sub> , FQ <sub>5,t-1</sub> , R <sub>5</sub>	FQ <sub>6,t-2</sub> , FQ <sub>6,t-1</sub> , FQ <sub>1,t-2</sub> , FQ <sub>2,t-2</sub> , FQ <sub>3,t-2</sub> , FQ <sub>4,t-2</sub> , FQ <sub>5,t-2</sub>	
4	FQ <sub>1,t-3</sub>	-	FQ <sub>3,t-3</sub>	FQ <sub>4,t-3</sub>	-	FQ <sub>6,t-3</sub> , FQ <sub>6,t-2</sub> , FQ <sub>1,t-3</sub> , FQ <sub>3,t-3</sub> , FQ <sub>4,t-3</sub> , FQ <sub>5,t-3</sub>	
5	FQ <sub>1,t-4</sub>	-	FQ <sub>3,t-4</sub>	FQ <sub>4,t-4</sub>	-	FQ <sub>6,t-4</sub> , FQ <sub>6,t-3</sub> , FQ <sub>1,t-4</sub> , FQ <sub>3,t-4</sub> , FQ <sub>4,t-4</sub>	
6	FQ <sub>1,t-5</sub>	-	FQ <sub>3,t-5</sub>	FQ <sub>4,t-5</sub>	-	FQ <sub>6,t-5</sub> , FQ <sub>6,t-4</sub> , FQ <sub>1,t-5</sub> , FQ <sub>3,t-5</sub> , FQ <sub>4,t-5</sub>	
7	FQ <sub>1,t-6</sub>	-	-	FQ <sub>4,t-6</sub>	-	FQ <sub>6,t-6</sub> , FQ <sub>6,t-5</sub> , FQ <sub>1,t-6</sub> , FQ <sub>3,t-6</sub> , FQ <sub>4,t-6</sub>	



รูป 6-28 การเปรียบเทียบผลพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูแล้ง ณ สถานีวัดน้ำท่า 150401 ช่วงปรับเทียบแบบจำลอง




c) การพยากรณ์ล่วงหน้า 3 วัน จากแบบจำลอง ANN + MA(2)




d) การพยากรณ์ล่วงหน้า 4 วัน จากแบบจำลอง ANN + MA(2)

รูป 6-28 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูฝน ณ สถานีวัดน้ำท่า 150401 ช่วงปรับทามแบบจำลอง (ต่อ)






๑) การพยากรณ์ล่วงหน้า 5 วัน จากแบบจำลอง ANN + MA(2)



๒) การพยากรณ์ล่วงหน้า 6 วัน จากแบบจำลอง ANN + MA(2)


รูป 6-28 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูฝน ณ สถานีวัดน้ำท่า 150401 ช่วงปรับพารามแบบจำลอง (ต่อ)



g) การพยากรณ์ล่วงหน้า 7 วัน จากแบบจำลอง ANN + MA(2)

รูป 6-28 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูฝน ณ สถานีวัดน้ำท่า 150401 ช่วงรับทานแบบจำลอง (ต่อ)


สำนักวิทยบริการ  
จุฬาลงกรณ์มหาวิทยาลัย




a) การพยากรณ์ล่วงหน้า 1 วัน จากแบบจำลอง ANN

b) การพยากรณ์ล่วงหน้า 2 วัน จากแบบจำลอง ANN + MA(2)

รูป 6-29 การเปรียบเทียบผลพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูแล้ง ณ สถานีวัดน้ำท่า KGT.14 ช่วงปรับทานแบบจำลอง




a) การพยากรณ์ล่วงหน้า 1 วัน จากแบบจำลอง ANN




b) การพยากรณ์ล่วงหน้า 2 วัน จากแบบจำลอง ANN + MA(2)

รูป 6-30 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูแล้ง ณ สถานีวัดน้ำท่า KGT.15A ช่วงปรับทานแบบจำลอง




c) การพยากรณ์ล่วงหน้า 3 วัน จากแบบจำลอง ANN + MA(2)



d) การพยากรณ์ล่วงหน้า 4 วัน จากแบบจำลอง ANN + MA(2)


รูป 6-30 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูแล้ง ณ สถานีวัดน้ำท่า KGT.15A ช่วงรับพายุแบบจำลอง (ต่อ)




e) การพยากรณ์ล่วงหน้า 5 วัน จากแบบจำลอง ANN + MA(2)

ก) การพยากรณ์ล่วงหน้า 6 วัน จากแบบจำลอง ANN + MA(2)

รูป 6-30 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูแล้ง ณ สถานีวัดน้ำท่า KGT.15A ช่วงปริมาณแบบจำลอง (ต่อ)




a) การพยากรณ์ล่วงหน้า 1 วัน จากแบบจำลอง ANN




b) การพยากรณ์ล่วงหน้า 2 วัน จากแบบจำลอง ANN + MA(2)

รูป 6-31 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูแล้ง ณ สถานีวัดน้ำท่า KGT.12 ช่วงปรับทานแบบจำลอง




รูป 6-31 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูตั้งแต่ ณ สถานีวัดน้ำท่า KGT.12 ช่วงปรับทวนแบบจำลอง (ต่อ)






e) การพยากรณ์ล่วงหน้า 5 วัน จากแบบจำลอง ANN + MA(2)




g) การพยากรณ์ล่วงหน้า 6 วัน จากแบบจำลอง ANN + MA(2)


รูป 6-31 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูแล้ง ณ สถานีวัดน้ำท่า KGT.12 ช่วงปรับทวนแบบจำลอง (ต่อ)




g) การพยากรณ์ล่วงหน้า 7 วัน จากแบบจำลอง ANN + MA(2)

รูป 6-31 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูแล้ง ณ สถานีวัดน้ำท่า KGT.12 ช่วงรับทานแบบจำลอง (ต่อ)







รูป 6-32 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูตั้งแต่ ณ สถานีวัดน้ำท่า KGT.10 ช่วงปรับทวนแบบจำลอง




c) การพยากรณ์ล่วงหน้า 3 วัน จากแบบจำลอง ANN + MA(2)

รูป 6-32 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูแล้ง ณ สถานีวัดน้ำท่า KGT.10 ช่วงปรับทานแบบจำลอง (ต่อ)






a) ภาพพยากรณ์ล่วงหน้า 1 วัน จากแบบจำลอง ANN




b) ภาพพยากรณ์ล่วงหน้า 2 วัน จากแบบจำลอง ANN + MA(2)

รูป 6-33 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูแล้ง ณ สถานีวัดน้ำท่า KGT.3 ช่วงปรับทานแบบจำลอง




c) การพยากรณ์ล่วงหน้า 3 วัน จากแบบจำลอง ANN + MA(2)



d) การพยากรณ์ล่วงหน้า 4 วัน จากแบบจำลอง ANN + MA(2)


รูป 6-33 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูแล้ง ณ สถานีวัดน้ำท่า KGT.3 ช่วงปรับทามแบบจำลอง (ต่อ)



e) การพยากรณ์ล่วงหน้า 5 วัน จากแบบจำลอง ANN + MA(2)

f) การพยากรณ์ล่วงหน้า 6 วัน จากแบบจำลอง ANN + MA(2)

รูป 6-33 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูแล้ง ณ สถานีวัดน้ำท่า KGT.3 ช่วงปรับพารามแบบจำลอง (ต่อ)



g) การพยากรณ์ล่วงหน้า 7 วัน จากแบบจำลอง ANN + MA(2)

รูป 6-33 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูแล้ง ณ สถานีวัดน้ำท่า KGT.3 ช่วงปรับพารามิเตอร์แบบจำลอง (ต่อ)





1) ลักษณะกราฟน้ำท่าในช่วงฤดูแล้ง จะมีอัตราการไหลน้ำท่าหรือปริมาณน้ำท่าลดลงอย่างต่อเนื่องตลอดฤดู เนื่องจากปริมาณน้ำท่าในช่วงนี้ส่วนใหญ่ไม่ได้มาจากฝนตกหนักในพื้นที่ แต่จะมาจากน้ำที่สะสมอยู่ใต้ชั้นดินและจะไหลซึมออกมาสู่ลำน้ำอย่างช้าๆ ซึ่งจะแตกต่างกับลักษณะกราฟน้ำท่าในช่วงฤดูฝนอย่างชัดเจน คือ จะมีปริมาณน้ำท่าเปลี่ยนแปลงขึ้นลงตลอดฤดู เนื่องจากปริมาณน้ำท่าส่วนใหญ่มาจากกับฝนตกในพื้นที่ลุ่มน้ำโดยตรง

2) การพยากรณ์อัตราการไหลน้ำท่าในพื้นที่ที่มีอัตราการไหลน้ำท่าต่ำมากหรือมีค่าใกล้เคียงศูนย์ เช่น สถานี KGT.14 ในปี 1991 นั้น จะเห็นได้ว่าผลการพยากรณ์จะมีค่าผิดพลาดมาก

3) ณ สถานี KGT.10 ในปี 1994 และ 1987 จะเห็นได้ว่าการเสื่อมถอยของฤดูการอย่างชัดเจน คือ อัตราการไหลน้ำท่าจะเริ่มเพิ่มขึ้นและมีความผันผวนมากขึ้นตั้งแต่ช่วงต้นเดือนเมษายน ทำให้ผลการพยากรณ์ในช่วงนี้มีความแม่นยำน้อย

4) เมื่อระยะเวลาการพยากรณ์ของแต่ละสถานียาวนานขึ้นความแม่นยำในการพยากรณ์จะมีค่าลดลงและค่าที่พยากรณ์จะมีความผันผวนมากขึ้น ซึ่งจะสังเกตได้จากในช่วงเริ่มต้นของฤดูแล้ง ค่าที่พยากรณ์จะมีความผันผวนมากอย่างชัดเจน

#### 6.2.4 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN และ MLR

เมื่อทำการจัดสร้างแบบจำลอง MLR โดยใช้ตัวแปรนำเข้าสู่ชุดเดียวกับแบบจำลอง ANN ที่พยากรณ์ล่วงหน้าโดยวิธี Standard Step (ตาราง 6 - 25) ซึ่งได้แสดงผลการจัดสร้างแบบจำลองไว้ในภาคผนวก ข2 และเมื่อนำผลการพยากรณ์มาเปรียบเทียบกับผลการพยากรณ์จากแบบจำลอง ANN (ก่อนการปรับปรุงผลการพยากรณ์) สรุปได้ดังตาราง 6 - 26 ซึ่งจะเห็นได้ว่า

1) ผลการพยากรณ์โดยใช้แบบจำลอง ANN และ MLR ให้ความแม่นยำในการพยากรณ์ไม่แตกต่างกันมาก ในการพยากรณ์ล่วงหน้า 1-3 วัน แต่เมื่อระยะเวลาการพยากรณ์ยาวนานขึ้น ผลการพยากรณ์โดยใช้แบบจำลอง ANN จะให้ความแม่นยำในการพยากรณ์มากกว่าแบบจำลอง MLR อย่างชัดเจน ในทุกสถานี

2) เมื่อเปรียบเทียบเปอร์เซ็นต์ค่าความแตกต่างระหว่างแบบจำลอง ANN และ MLR สำหรับที่ใช้ในฤดูแล้ง กับฤดูฝน (ตาราง 6-13) พบว่าเปอร์เซ็นต์ค่าความแตกต่างระหว่างแบบจำลองทั้ง 2 ของแบบจำลองฤดูแล้งมีค่าน้อยกว่าแบบจำลองฝน ทั้งนี้เนื่องจากลักษณะอัตราการไหลน้ำท่าในฤดูแล้งมีความเป็นเชิงเส้นมากกว่าในฤดูฝน ทำให้แบบจำลอง MLR สามารถใช้การได้ดีกว่า

ตาราง 6-26 การเปรียบเทียบผลการพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้าในฤดูแล้ง  
ระหว่างแบบจำลอง ANN กับ MLR

สถานี วัดน้ำท่า	พยากรณ์ ล่วงหน้า (วัน)	เปรียบเทียบ (Training Period)					เปรียบเทียบ (Testing Period)				
		ANN		MLR		% ความ แตกต่าง	ANN		MLR		% ความ แตกต่าง
		EI (%)	RMSE (ม <sup>3</sup> /วินาที)	EI (%)	RMSE (ม <sup>3</sup> /วินาที)	$\Delta EI(\%)$	EI (%)	RMSE (ม <sup>3</sup> /วินาที)	EI (%)	RMSE (ม <sup>3</sup> /วินาที)	$\Delta EI(\%)$
150401	1	96.33	0.217	96.21	0.220	0.12	96.68	0.097	96.81	0.092	-0.13
	2	93.94	0.267	93.47	0.277	0.47	96.79	0.142	97.17	0.133	-0.39
	3	93.27	0.271	91.24	0.309	2.03	96.19	0.146	95.21	0.163	0.98
	4	92.27	0.280	89.91	0.326	2.36	95.32	0.153	93.18	0.185	2.14
	5	87.83	0.344	85.10	0.380	2.73	94.79	0.153	90.93	0.202	3.86
	6	84.46	0.378	81.88	0.408	2.58	93.27	0.167	88.45	0.219	4.82
	7	82.28	0.391	79.28	0.418	3.00	92.42	0.171	86.83	0.225	5.59
KGT.14	1	83.77	0.124	79.84	0.138	3.93	81.52	0.068	80.81	0.070	0.71
	2	78.37	0.139	73.01	0.155	5.36	67.97	0.090	66.72	0.093	1.25
KGT.15A	1	92.28	0.298	92.64	0.291	-0.36	87.52	0.120	88.91	0.114	-1.39
	2	85.77	0.391	85.85	0.390	-0.08	80.94	0.145	81.29	0.144	-0.35
	3	84.03	0.400	80.21	0.446	3.82	79.69	0.146	78.35	0.151	1.33
	4	81.76	0.415	77.42	0.461	4.34	76.64	0.153	74.76	0.159	1.88
	5	77.98	0.441	72.67	0.491	5.31	72.48	0.162	70.19	0.165	2.29
	6	74.67	0.459	68.58	0.526	5.99	70.15	0.165	67.06	0.177	3.10
KGT.12	1	96.21	0.348	96.15	0.351	0.06	98.63	0.124	98.58	0.126	0.05
	2	90.90	0.523	90.66	0.530	0.25	96.97	0.176	96.73	0.182	0.23
	3	89.87	0.535	87.22	0.601	2.65	96.54	0.178	95.05	0.213	1.49
	4	87.34	0.582	84.64	0.641	2.70	95.25	0.199	93.29	0.236	1.97
	5	84.86	0.621	81.33	0.680	3.53	94.09	0.209	91.44	0.252	2.65
	6	81.36	0.673	77.71	0.722	3.65	92.22	0.226	88.94	0.270	3.28
	7	77.92	0.717	72.68	0.757	5.24	90.16	0.237	86.32	0.279	3.85
KGT.10	1	86.07	0.718	82.63	0.802	3.44	87.98	0.450	88.63	0.438	-0.65
	2	72.71	0.994	66.94	1.094	5.77	76.04	0.611	75.25	0.621	0.79
	3	68.09	1.061	61.19	1.244	6.90	72.79	0.627	69.84	0.660	2.95
KGT.3	1	98.01	1.291	96.50	1.518	1.51	98.55	0.883	98.17	0.925	0.38
	2	94.64	1.824	91.48	2.296	3.16	96.53	1.239	95.64	1.248	0.88
	3	93.23	1.994	88.38	2.612	4.84	94.14	1.548	92.84	1.583	1.30
	4	91.02	2.239	85.68	2.828	5.34	93.24	1.678	91.18	1.778	2.06
	5	88.53	2.469	82.55	3.045	5.98	91.71	1.817	89.18	1.968	2.53
	6	85.99	2.664	78.73	3.282	7.26	89.01	1.935	85.91	2.238	3.10
	7	83.17	2.818	75.97	3.420	7.20	87.60	2.073	83.43	2.495	4.18


หมายเหตุ:  $\Delta EI = (EI \text{ จากแบบจำลอง ANN}) - (EI \text{ จากแบบจำลอง MLR})$

จากผลการเปรียบเทียบที่กล่าวจะเห็นได้ว่าในช่วงฤดูแล้งแบบจำลอง ANN และ MLR สามารถนำมาประยุกต์ใช้ในการพยากรณ์อัตราไหลน้ำท่ารายวันล่วงหน้าได้ดี และให้ผลการพยากรณ์ที่ไม่แตกต่างกันมากเมื่อเทียบกับฤดูฝน และทั้งนี้อาจเนื่องจากในแบบจำลอง ANN มีจำนวนพารามิเตอร์มากกว่าแบบจำลอง MLR ทำให้ผลการพยากรณ์ในช่วงระยะยาวให้ผลดีกว่าแบบจำลอง MLR ทั้งในฤดูฝนและฤดูแล้ง


#### 6.2.5 การประยุกต์ใช้แบบจำลอง ANN

เมื่อนำแบบจำลอง ANN และแบบจำลองอนุกรมเวลา สำหรับฤดูแล้ง ที่ผ่านการคัดเลือกมาทดสอบกับข้อมูลที่เตรียมไว้สำหรับรับรองผลแบบจำลองซึ่งข้อมูลปีล่าสุดที่มีการจดบันทึก (ปี พ.ศ.2541) เพื่อพิจารณาว่าแบบจำลองนั้นสามารถนำมาประยุกต์ใช้งานกับเหตุการณ์ในปัจจุบันได้ดีหรือไม่ โดยผลการทดสอบแสดงได้ดังรูป 6-34 ถึง 6-39


ซึ่งจะเห็นได้ว่าลักษณะน้ำท่าฤดูแล้งในปีนี้มีควมผันผวนน้อย ไม่มีอิทธิพลของฝนตกหนักในพื้นที่มากนัก และไม่พบการเชื่อมลำของฤดูกาล ทำให้แบบจำลองพยากรณ์อัตราไหลน้ำท่ารายวันในแต่ละสถานีสามารถใช้งานได้ดี ( $EI > 80\%$ ) เกือบทุกแบบจำลอง นั้นแสดงให้เห็นถึงแบบจำลองการพยากรณ์อัตราไหลน้ำท่ารายวันสำหรับฤดูแล้งที่พัฒนาขึ้น สามารถนำไปประยุกต์ใช้ได้กับเหตุการณ์ในปัจจุบัน



a) การพยากรณ์ล่วงหน้า 1 วัน จากแบบจำลอง ANN




b) การพยากรณ์ล่วงหน้า 2 วัน จากแบบจำลอง ANN+MA(2)




c) การพยากรณ์ล่วงหน้า 3 วัน จากแบบจำลอง ANN+MA(2)


รูป 6-34 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูแล้ง ณ สถานี 150401 ช่วงรับทรงผลแบบจำลอง



d) การพยากรณ์ล่วงหน้า 4 วัน จากแบบจำลอง ANN+MA(2)




e) การพยากรณ์ล่วงหน้า 5 วัน จากแบบจำลอง ANN+MA(2)




f) การพยากรณ์ล่วงหน้า 6 วัน จากแบบจำลอง ANN+MA(2)

รูป 6-34 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูแล้ง ณ สถานี 150401 ช่วงรับชมผลแบบจำลอง (ต่อ)




g) การพยากรณ์ล่วงหน้า 7 วัน จากแบบจำลอง ANN+MA(2)

รูป 6-34 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูแล้ง ณ สถานี 150401 ช่วงรับชมผลแบบจำลอง (ต่อ)




a) การพยากรณ์ล่วงหน้า 1 วัน จากแบบจำลอง ANN




b) การพยากรณ์ล่วงหน้า 2 วัน จากแบบจำลอง ANN+MA(2)


รูป 6-35 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูแล้ง ณ สถานี KGT.14 ช่วงรับชมผลแบบจำลอง (ต่อ)



a) การพยากรณ์ล่วงหน้า 1 วัน จากแบบจำลอง ANN




b) การพยากรณ์ล่วงหน้า 2 วัน จากแบบจำลอง ANN+MA(2)




c) การพยากรณ์ล่วงหน้า 3 วัน จากแบบจำลอง ANN+MA(2)


รูป 6-36 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูแล้ง ณ สถานี KGT.15A ช่วงรับชมผลแบบจำลอง



ด) การพยากรณ์ล่วงหน้า 4 วัน จากแบบจำลอง ANN+MA(2)




ค) การพยากรณ์ล่วงหน้า 5 วัน จากแบบจำลอง ANN+MA(2)




ข) การพยากรณ์ล่วงหน้า 6 วัน จากแบบจำลอง ANN+MA(2)

รูป 6-36 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูแล้ง ณ สถานี KGT.15A ช่วงรับชมผลแบบจำลอง (ต่อ)






a) การพยากรณ์ล่วงหน้า 1 วัน จากแบบจำลอง ANN




b) การพยากรณ์ล่วงหน้า 2 วัน จากแบบจำลอง ANN+MA(2)




c) การพยากรณ์ล่วงหน้า 3 วัน จากแบบจำลอง ANN+MA(2)


รูป 6-37 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูแล้ง ณ สถานี KGT.12 ช่วงรับของผลแบบจำลอง



d) การพยากรณ์ล่วงหน้า 4 วัน จากแบบจำลอง ANN+MA(2)




e) การพยากรณ์ล่วงหน้า 5 วัน จากแบบจำลอง ANN+MA(2)




f) การพยากรณ์ล่วงหน้า 6 วัน จากแบบจำลอง ANN+MA(2)

รูป 6-37 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูแล้ง ณ สถานี KGT.12 ช่วงรับรองผลแบบจำลอง (ต่อ)




g) การพยากรณ์ล่วงหน้า 7 วัน จากแบบจำลอง ANN+MA(2)

รูป 6-37 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูแล้ง ณ สถานี KGT.12 ช่วงรับชมผลแบบจำลอง (ต่อ)




a) การพยากรณ์ล่วงหน้า 1 วัน จากแบบจำลอง ANN




b) การพยากรณ์ล่วงหน้า 2 วัน จากแบบจำลอง ANN+MA(2)

รูป 6-38 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูแล้ง ณ สถานี KGT.10 ช่วงรับชมผลแบบจำลอง




c) การพยากรณ์ล่วงหน้า 3 วัน จากแบบจำลอง ANN+MA(2)

รูป 6-38 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูแล้ง ณ สถานี KGT.10 ช่วงรับชมผลแบบจำลอง (ต่อ)




a) การพยากรณ์ล่วงหน้า 1 วัน จากแบบจำลอง ANN




b) การพยากรณ์ล่วงหน้า 2 วัน จากแบบจำลอง ANN+MA(2)


รูป 6-39 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูแล้ง ณ สถานี KGT.3 ช่วงรับชมผลแบบจำลอง



c) การพยากรณ์ล่วงหน้า 3 วัน จากแบบจำลอง ANN+MA(2)




d) การพยากรณ์ล่วงหน้า 4 วัน จากแบบจำลอง ANN+MA(2)




e) การพยากรณ์ล่วงหน้า 5 วัน จากแบบจำลอง ANN+MA(2)

รูป 6-39 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูแล้ง ณ สถานี KGT.3 ช่วงรับรองผลแบบจำลอง (ต่อ)



f) การพยากรณ์ล่วงหน้า 6 วัน จากแบบจำลอง ANN+MA(2)



g) การพยากรณ์ล่วงหน้า 7 วัน จากแบบจำลอง ANN+MA(2)

รูป 6-39 การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับข้อมูลที่วัดจริงในฤดูแฉ้ง ณ สถานี KGT.3 ช่วงรับรองผลแบบจำลอง (ต่อ)

สถาบันวิทยบริการ  
จุฬาลงกรณ์มหาวิทยาลัย

## บทที่ 7

### สรุปผลและข้อเสนอแนะ

#### 7.1 สรุปผลการศึกษา

ในการศึกษาค้นคว้าครั้งนี้สามารถแบ่งผลการศึกษาดังกล่าวออกเป็น 6 ประเด็น คือ 1) การเสนอวิธีการคัดเลือกชุดตัวแปรนำเข้าที่มีนัยสำคัญที่ใช้ในการพยากรณ์น้ำท่ารายวัน 2) การประยุกต์ใช้แบบจำลอง ANN สำหรับการพยากรณ์น้ำท่ารายวันที่ออกจากกลุ่มน้ำย่อยต่างๆ 3) การเปรียบเทียบวิธีการพยากรณ์ล่วงหน้าหลายวันโดยวิธี Direct step และ Standard step 4) การปรับปรุงผลการพยากรณ์โดยใช้แบบจำลองอนุกรมเวลา 5) การเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN และ MLR และ 6) การคัดเลือกค่าพารามิเตอร์และลักษณะโครงข่ายภายในที่เหมาะสมในแบบจำลอง ANN ที่ใช้ในการศึกษาค้นคว้าครั้งนี้ โดยผลการศึกษาในแต่ละประเด็นสามารถสรุปได้ดังต่อไปนี้

1) วิธีการคัดเลือกชุดตัวแปรนำเข้าที่มีนัยสำคัญโดยใช้กราฟความสัมพันธ์ทั้ง 4 อันได้แก่ กราฟ autocorrelation, partial autocorrelation, cross correlation และ กราฟความสัมพันธ์ระหว่างน้ำฝน-น้ำท่าในแต่ละลุ่มน้ำนั้น ให้ผลการคัดเลือกเช่นเดียวกับวิธีการ trial & error ซึ่งแสดงให้เห็นว่าวิธีนี้สามารถนำมาประยุกต์ใช้เป็นแนวทางในการคัดเลือกชุดตัวแปรนำเข้าที่มีนัยสำคัญสำหรับการพยากรณ์น้ำท่ารายวันได้ โดยตัวแปรนำเข้าที่ใช้ในการศึกษาค้นคว้าครั้งนี้แบ่งออกเป็น 3 ประเภทคือ 1) อัตราการไหลน้ำท่ารายวันย้อนหลังของสถานีตัวมันเอง 2) ปริมาณฝนเฉลี่ยทั่วทั้งพื้นที่รายวันย้อนหลังในแต่ละลุ่มน้ำ และ 3) อัตราการไหลน้ำท่ารายวันของสถานีวัดที่ตั้งอยู่เหนือน้ำ (ใช้เฉพาะที่สถานี KGT.3 เนื่องจากเป็นสถานีที่ตั้งอยู่ท้ายน้ำของพื้นที่ศึกษา) สำหรับวิธีการคัดเลือกชุดตัวแปรในแต่ละประเภทนั้นสามารถสรุปได้ดังนี้

- การคัดเลือกอัตราการไหลน้ำท่ารายวันย้อนหลังของสถานีตัวมันเอง จะใช้กราฟความสัมพันธ์แบบ autocorrelation และ partial autocorrelation เป็นแนวทางในการคัดเลือก โดยจำนวนวันย้อนหลังซึ่งนับจากวันปัจจุบันที่มีนัยสำคัญ ต่อการพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า นั้น จะพิจารณาจากค่าความสัมพันธ์แบบ partial autocorrelation ที่มีค่ามากกว่าค่าขอบเขตความเป็นอิสระของตัวแปรที่ความเชื่อมั่น 95%
- การคัดเลือกปริมาณฝนเฉลี่ยทั่วทั้งพื้นที่รายวันย้อนหลัง จะใช้กราฟความสัมพันธ์แบบ cross correlation และกราฟน้ำฝน-น้ำท่า เป็นแนวทางในการคัดเลือก โดย

- จำนวนวันย้อนหลังของปริมาณฝนเฉลี่ยทั่วทั้งพื้นที่รายวัน ที่มีนัยสำคัญต่อการพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า จะเริ่มนับจากวันปัจจุบันไปถึงวันย้อนหลังที่ให้ค่า cross correlation สูงสุด ซึ่งจะต้องใช้ค่า  $T_c$  ที่ได้จากกราฟความสัมพันธ์ระหว่างน้ำฝน-น้ำท่าในแต่ละลุ่มน้ำ มาพิจารณาประกอบร่วมกัน
- การคัดเลือกอัตราการไหลน้ำท่ารายวันย้อนหลังของสถานีวัดที่ตั้งอยู่เหนือน้ำ จะใช้กราฟความสัมพันธ์แบบ cross correlation เป็นแนวทางในการคัดเลือก เช่นเดียวกับการคัดเลือกปริมาณฝนเฉลี่ยทั่วทั้งพื้นที่รายวันย้อนหลัง โดยจำนวนวันย้อนหลังที่มีนัยสำคัญนั้นจะเริ่มนับจากวันปัจจุบันไปถึงวันย้อนหลังที่ให้ค่า cross correlation สูงสุด

นอกจากนี้เมื่อเปรียบเทียบจำนวนครั้งที่ใช้ในการคัดเลือกชุดตัวแปรนำเข้าที่มีนัยสำคัญสำหรับการพยากรณ์น้ำท่ารายวันล่วงหน้า 1 วัน ทั้งในฤดูฝนและฤดูแล้ง ด้วยวิธีการ trial & error กับการใช้กราฟความสัมพันธ์ทั้ง 4 สรุปได้ดังนี้

สถานี	จำนวนครั้งที่ใช้ในการคัดเลือกตัวแปรนำเข้าที่มีนัยสำคัญ			
	ฤดูฝน		ฤดูแล้ง	
	วิธี Trial & Error	ใช้กราฟความสัมพันธ์	วิธี Trial & Error	ใช้กราฟความสัมพันธ์
150401	7	1	3	1
KGT.14	5	1	3	1
KGT.15A	8	1	3	1
KGT.12	12	1	3	1
KGT.10	11	1	4	1
KGT.3	12	1	8	1
หมายเหตุ	ผลจากตาราง 6-3 ถึง 6-8		ผลจากตาราง 6-16 ถึง 6-21	

ซึ่งจะเห็นได้ว่าการนำกราฟความสัมพันธ์ทั้ง 4 มาใช้เป็นแนวทางในการคัดเลือกชุดตัวแปรนำเข้าที่มีนัยสำคัญสำหรับการพยากรณ์น้ำท่ารายวันล่วงหน้า 1 วันนั้น จะช่วยลดขั้นตอนและเวลาในการคัดเลือกชุดตัวแปรนำเข้าได้อย่างมากเมื่อเทียบกับการ trial & error ซึ่งเป็นวิธีเดิมที่ใช้กันอยู่ทั่วไป

2) ผลการประยุกต์ใช้แบบจำลอง ANN สำหรับการพยากรณ์อัตราการไหลน้ำท่ารายวัน ณ สถานีวัดน้ำท่าต่างๆ ทั้งในฤดูฝนและฤดูแล้ง ในช่วงสอบทานแบบจำลอง สามารถสรุปได้ดังตาราง 7.1 และ 7.2



ตาราง 7-1 สรุปผลการพยากรณ์อัตราการใช้พลังงานไฟฟ้ารายวัน ณ สถานีวัดน้ำท่าต่างๆ จากแบบจำลองสำหรับฤดูฝน

สถานี	พื้นที่ (ตร.กม.)	จำนวนวันที่พยากรณ์ ล่วงหน้า	แบบจำลองที่ใช้	ตัวแปรนำเข้า	EI (%)	MAD		$\Delta Q_{peak}$		$\Delta T_{peak}$ (วัน)
						(ม.วินาที)	(%)	(ม.วินาที)	(%)	
150401	636	1	ANN	Q1 <sub>t</sub> , R1 <sub>t</sub> , R1 <sub>t+1</sub>	73.57	6.42	27.00	25.96	15.45	1
		2	ANN+MA(2)	FQ1 <sub>t+1</sub> , R1 <sub>t</sub>	68.53	7.39	31.06	37.50	20.13	1
KGT.14	366	1	ANN	Q2 <sub>t</sub> , R2 <sub>t</sub>	68.56	2.90	42.21	34.95	35.85	0-1
KGT.15A	530	1	ANN	Q3 <sub>t</sub> , Q3 <sub>t+1</sub> , R3 <sub>t</sub> , R3 <sub>t+1</sub>	77.42	6.25	28.40	22.30	10.70	0-1
		2	ANN+MA(2)	FQ3 <sub>t+1</sub> , Q3 <sub>t</sub> , R3 <sub>t</sub>	59.27	9.84	44.65	25.23	12.55	0-1
KGT.12	1,540	1	ANN	Q4 <sub>t</sub> , Q4 <sub>t+1</sub> , R4 <sub>t</sub> , R4 <sub>t+1</sub> , R4 <sub>t+2</sub> , R4 <sub>t+3</sub> , R4 <sub>t+4</sub> , R4 <sub>t+5</sub>	98.26	2.57	8.62	4.37	3.03	0
		2	ANN+MA(2)	FQ4 <sub>t+1</sub> , Q4 <sub>t</sub> , R4 <sub>t</sub> , R4 <sub>t+1</sub> , R4 <sub>t+2</sub> , R4 <sub>t+3</sub> , R4 <sub>t+4</sub>	95.80	3.92	13.15	10.85	7.54	0
		3	ANN+MA(2)	FQ4 <sub>t+2</sub> , FQ4 <sub>t+1</sub> , R4 <sub>t</sub> , R4 <sub>t+1</sub> , R4 <sub>t+2</sub> , R4 <sub>t+3</sub>	91.16	5.55	18.61	14.00	10.24	0-1
		4	ANN+MA(2)	FQ4 <sub>t+3</sub> , FQ4 <sub>t+2</sub> , R4 <sub>t</sub> , R4 <sub>t+1</sub> , R4 <sub>t+2</sub>	85.11	7.11	23.84	44.95	32.95	1
		5	ANN+MA(2)	FQ4 <sub>t+4</sub> , FQ4 <sub>t+3</sub> , R4 <sub>t</sub> , R4 <sub>t+1</sub>	79.14	8.21	27.53	56.66	41.61	1
		6	ANN+AR(2)	FQ4 <sub>t+5</sub> , FQ4 <sub>t+4</sub> , R4 <sub>t</sub>	72.36	9.80	32.86	56.74	41.65	1
KGT.10	2,523	1	ANN	Q5 <sub>t</sub> , Q5 <sub>t+1</sub> , R5 <sub>t</sub> , R5 <sub>t+1</sub> , R5 <sub>t+2</sub>	91.23	8.45	22.27	14.91	5.92	1
		2	ANN+MA(2)	FQ5 <sub>t+1</sub> , Q5 <sub>t</sub> , R5 <sub>t</sub> , R5 <sub>t+1</sub>	87.28	10.09	26.60	32.82	12.81	0-1
		3	ANN+MA(2)	FQ5 <sub>t+2</sub> , FQ5 <sub>t+1</sub> , R5 <sub>t</sub>	77.37	14.05	37.03	39.42	14.97	0-1
KGT.3	7,502	1	ANN	Q6 <sub>t</sub> , Q6 <sub>t+1</sub> , Q1 <sub>t</sub> , Q2 <sub>t</sub> , Q3 <sub>t</sub> , Q4 <sub>t</sub> , Q5 <sub>t</sub> , R6 <sub>t</sub> , R6 <sub>t+1</sub> , R6 <sub>t+2</sub> , R6 <sub>t+3</sub>	99.23	9.80	5.56	14.82	2.58	0
		2	ANN+MA(2)	FQ6 <sub>t+1</sub> , FQ1 <sub>t+1</sub> , FQ2 <sub>t+1</sub> , FQ3 <sub>t+1</sub> , FQ4 <sub>t+1</sub> , FQ5 <sub>t+1</sub> , Q6 <sub>t</sub> , R6 <sub>t+1</sub> , R6 <sub>t+2</sub>	98.35	14.14	8.03	15.75	2.68	0
		3	ANN+MA(2)	FQ6 <sub>t+2</sub> , FQ6 <sub>t+1</sub> , FQ1 <sub>t+2</sub> , FQ2 <sub>t+2</sub> , FQ3 <sub>t+2</sub> , R6 <sub>t+1</sub> , R6 <sub>t+2</sub>	95.11	22.35	12.69	23.57	4.12	0
		4	ANN+MA(2)	FQ6 <sub>t+3</sub> , FQ6 <sub>t+2</sub> , FQ4 <sub>t+3</sub> , FQ5 <sub>t+3</sub> , R6 <sub>t</sub>	92.33	29.47	16.73	24.16	4.21	0-1
		5	ANN+MA(2)	FQ6 <sub>t+4</sub> , FQ6 <sub>t+3</sub> , FQ4 <sub>t+4</sub>	89.10	36.06	20.47	28.01	4.91	0-1
		6	ANN+MA(2)	FQ6 <sub>t+5</sub> , FQ6 <sub>t+4</sub> , FQ4 <sub>t+5</sub>	85.06	42.67	24.22	37.56	6.52	1-2
		7	ANN+AR(2)	FQ6 <sub>t+6</sub> , FQ6 <sub>t+5</sub> , FQ4 <sub>t+6</sub>	81.45	46.35	26.31	63.85	10.94	1-2

หมายเหตุ:  $\Delta Q_{peak}$  และ  $\Delta T_{peak}$  ได้มาจากค่าเฉลี่ยของเหตุการณ์สูงสุด 3 เหตุการณ์เรียงตามขนาด ซึ่งแสดงรายละเอียดได้ในภาคผนวก ข

ตาราง 7-2 สรุปผลการพยากรณ์อัตราการไหลน้ำท่ารายวัน ณ สถานีวัดน้ำท่าต่างๆ จากแบบจำลองสำหรับฤดูแล้ง

สถานี	พื้นที่ (ตร.กม.)	จำนวนวัน ที่พยากรณ์ ล่วงหน้า	แบบจำลอง ที่ใช้	ตัวแปรนำเข้า	EI (%)	MAD	
						(ม <sup>3</sup> /วินาที)	(%)
150401	636	1	ANN	$Q1_t$	98.68	0.060	8.22
		2	ANN+MA(2)	$FQ1_{t+1}$	98.23	0.067	9.21
		3	ANN+MA(2)	$FQ1_{t+2}$	97.51	0.072	9.85
		4	ANN+MA(2)	$FQ1_{t+3}$	97.30	0.077	10.58
		5	ANN+MA(2)	$FQ1_{t+4}$	96.08	0.085	11.67
		6	ANN+MA(2)	$FQ1_{t+5}$	94.86	0.090	12.30
		7	ANN+MA(2)	$FQ1_{t+6}$	93.65	0.098	13.43
KGT.14	366	1	ANN	$Q2_t$	81.52	0.021	19.09
		2	ANN+MA(2)	$FQ2_{t+1}$	76.75	0.029	26.50
KGT.15A	530	1	ANN	$Q3_t$	87.52	0.052	10.20
		2	ANN+MA(2)	$FQ3_{t+1}$	87.09	0.064	12.53
		3	ANN+MA(2)	$FQ3_{t+2}$	86.56	0.078	15.27
		4	ANN+MA(2)	$FQ3_{t+3}$	80.72	0.090	17.68
		5	ANN+MA(2)	$FQ3_{t+4}$	78.45	0.096	18.91
		6	ANN+MA(2)	$FQ3_{t+5}$	75.56	0.112	21.90
KGT.12	1,540	1	ANN	$Q4_t$	98.63	0.064	8.89
		2	ANN+MA(2)	$FQ4_{t+1}$	98.45	0.076	10.55
		3	ANN+MA(2)	$FQ4_{t+2}$	97.54	0.085	11.83
		4	ANN+MA(2)	$FQ4_{t+3}$	96.75	0.095	13.20
		5	ANN+MA(2)	$FQ4_{t+4}$	95.01	0.117	16.23
		6	ANN+MA(2)	$FQ4_{t+5}$	93.22	0.132	18.27
		7	ANN+MA(2)	$FQ4_{t+6}$	91.31	0.144	19.93
KGT.10	2,523	1	ANN	$Q5_t, Q5_{t+1}, R5_t, R5_{t-1}, R5_{t-2}$	87.98	0.196	12.25
		2	ANN+MA(2)	$FQ5_{t+1}, Q5_t, R5_t, R5_{t-1}$	83.81	0.230	14.35
		3	ANN+MA(2)	$FQ5_{t+2}, FQ5_{t+1}, R5_t$	77.43	0.276	17.23
KGT.3	7,502	1	ANN	$Q6_t, Q6_{t+1}, Q1_t, Q2_t, Q3_t, Q4_t, Q5_t$	98.55	0.397	5.93
		2	ANN+MA(2)	$FQ6_{t+1}, Q6_t, FQ1_{t+1}, FQ2_{t+1}, FQ3_{t+1}, FQ4_{t+1}, FQ5_{t+1}$	97.18	0.585	8.75
		3	ANN+MA(2)	$FQ5_{t+2}, FQ6_{t+2}, FQ1_{t+2}, FQ2_{t+2}, FQ3_{t+2}, FQ4_{t+2}, FQ5_{t+2}$	96.28	0.705	10.54
		4	ANN+MA(2)	$FQ6_{t+3}, FQ6_{t+3}, FQ1_{t+3}, FQ3_{t+3}, FQ4_{t+3}, FQ5_{t+3}$	95.71	0.856	12.80
		5	ANN+MA(2)	$FQ6_{t+4}, FQ6_{t+4}, FQ1_{t+4}, FQ3_{t+4}, FQ4_{t+4}$	94.50	0.982	14.67
		6	ANN+MA(2)	$FQ6_{t+5}, FQ6_{t+5}, FQ1_{t+5}, FQ3_{t+5}, FQ4_{t+5}$	93.79	1.055	15.77
		7	ANN+MA(2)	$FQ6_{t+6}, FQ6_{t+6}, FQ1_{t+6}, FQ3_{t+6}, FQ4_{t+6}$	92.20	1.182	17.37

หมายเหตุ: ในฤดูแล้งจะไม่พิจารณาค่า  $\Delta Q_{peak}$  และ  $\Delta T_{peak}$

จากตาราง 7-1 สามารถสรุปผลการประยุกต์ใช้แบบจำลอง ANN สำหรับการพยากรณ์ อัตราการไหลน้ำท่ารายวันในฤดูฝนได้ดังนี้

- จำนวนวันที่สามารถพยากรณ์น้ำท่าล่วงหน้าได้มากที่สุด สำหรับการพยากรณ์น้ำท่าในพื้นที่ลุ่มน้ำขนาดเล็ก ซึ่งได้แก่การพยากรณ์ ณ สถานี 150401, KGT.14 และ KGT.15A จะมีค่าน้อยกว่าการพยากรณ์ในพื้นที่ลุ่มน้ำขนาดใหญ่ ซึ่งได้แก่การพยากรณ์ ณ สถานี KGT.12, KGT.10 และ KGT.3 เนื่องจากจำนวนวันสูงสุดที่สามารถจะพยากรณ์ล่วงหน้าได้นั้น ขึ้นอยู่กับค่า  $T_c$  ของแต่ละลุ่มน้ำ ซึ่งค่า  $T_c$  ในแต่ละลุ่มน้ำจะมีค่าแตกต่างกันออกไปตามลักษณะทางกายของพื้นที่อันได้แก่ ขนาดและความชัน เป็นต้น โดยพื้นที่ขนาดเล็กส่วนใหญ่จะมีค่า  $T_c$  น้อยกว่าพื้นที่ขนาดใหญ่
- การพยากรณ์น้ำท่าในพื้นที่ลุ่มน้ำขนาดใหญ่จะใช้จำนวนตัวแปรนำเข้ามาากกว่าการพยากรณ์ในพื้นที่ลุ่มน้ำขนาดเล็ก โดยเฉพาะจำนวนตัวแปรนำเข้าที่เป็นจำนวนวัน ย้อนหลังของปริมาณฝนเฉลี่ยทั่วทั้งพื้นที่ (R) เนื่องจากฝนที่ตกในพื้นที่ขนาดใหญ่จะใช้เวลาในการเปลี่ยนแปลงเป็นน้ำท่ามากกว่าฝนที่ตกในพื้นที่ขนาดเล็ก
- แบบจำลอง ANN สามารถนำมาประยุกต์ใช้ในการพยากรณ์น้ำท่าที่ออกจากลุ่มน้ำขนาดใหญ่ได้ดีกว่าการพยากรณ์น้ำท่าที่ออกจากลุ่มน้ำขนาดเล็ก ซึ่งพิจารณาได้จากค่าความคลาดเคลื่อนในการพยากรณ์ล่วงหน้า 1-2 วัน ในพื้นที่ลุ่มน้ำขนาดใหญ่ ซึ่งได้แก่การพยากรณ์ ณ สถานี KGT.12, KGT.10 และ KGT.3 จะมีค่าความคลาดเคลื่อนในการพยากรณ์ (% MAD) 5.56-26.60 % และมีค่าความแตกต่างของอัตราการไหลสูงสุด (%  $\Delta Q_{peak}$ ) 2.68-12.81% สำหรับการพยากรณ์น้ำท่าในพื้นที่ลุ่มน้ำขนาดเล็ก ซึ่งได้แก่การพยากรณ์ ณ สถานี 150401, KGT.14 และ KGT.15A จะมีค่า % MAD อยู่ระหว่าง 27.00-44.65 % และมีค่า %  $\Delta Q_{peak}$  อยู่ระหว่าง 10.70-35.85 % ทั้งนี้เนื่องจากในพื้นที่ลุ่มน้ำขนาดเล็กจะมีการเปลี่ยนแปลงน้ำท่าขึ้นลงในรอบวันมากกว่าในพื้นที่ลุ่มน้ำขนาดใหญ่ และการเปลี่ยนแปลงของฝนเป็นน้ำท่าในพื้นที่ลุ่มน้ำขนาดเล็กในบางเหตุการณ์ใช้เวลาน้อยกว่า 1 วัน เช่น สถานี KGT.14 ทำให้การพยากรณ์น้ำท่าเป็นรายวันนั้นอาจเป็นช่วงเวลาที่ยาวนานเกินไป จึงส่งผลต่อความคลาดเคลื่อนในการพยากรณ์
- เมื่อแยกพิจารณาผลการพยากรณ์ออกเป็นพื้นที่ต้นน้ำ ซึ่งได้แก่ การพยากรณ์ ณ สถานี 150401, KGT.14, KGT.15A, KGT.12 และ KGT.10 กับพื้นที่ท้ายน้ำซึ่งได้แก่การพยากรณ์ ณ สถานี KGT.3 ทั้งนี้เนื่องจากการพยากรณ์ในพื้นที่ทั้ง 2 ใช้ตัวแปรนำเข้าที่แตกต่างกันคือ การพยากรณ์น้ำท่าในพื้นที่ต้นน้ำจะใช้ตัวแปรนำเข้าเพียง 2

ประเภท คือ อัตราการไหลน้ำท่ารายวันย้อนหลังของสถานีตัวมันเองและปริมาณฝนเฉลี่ยทั่วทั้งพื้นที่รายวันย้อนหลัง ส่วนการพยากรณ์น้ำท่าในพื้นที่ทำนายนั้นจะใช้ตัวแปรนำเข้า 3 ประเภท คือ อัตราการไหลน้ำท่ารายวันย้อนหลังของสถานีตัวมันเอง ปริมาณฝนเฉลี่ยทั่วทั้งพื้นที่รายวันย้อนหลัง และอัตราการไหลน้ำท่ารายวันย้อนหลังของสถานีที่ตั้งอยู่เหนือน้ำ พบว่าผลการพยากรณ์น้ำท่าของพื้นที่ทำนายนำให้ความแม่นยำในการพยากรณ์ทั้งขนาดและเวลาการเกิดอัตราการไหลสูงสุดมากกว่าพื้นที่ต้นน้ำ โดยเฉพาะในการพยากรณ์ล่วงหน้า 1-3 วัน ทั้งนี้เนื่องมาจากตัวแปรนำเข้าที่เป็นอัตราการไหลน้ำท่ารายวันย้อนหลังของสถานีที่ตั้งอยู่เหนือน้ำที่เพิ่มเข้ามา

จากตาราง 7-2 สามารถสรุปผลการประยุกต์ใช้แบบจำลอง ANN สำหรับการพยากรณ์อัตราการไหลน้ำท่ารายวันในฤดูแล้งได้ดังนี้

- การพยากรณ์น้ำท่าในฤดูแล้งมีความแม่นยำมากกว่าการพยากรณ์น้ำท่ารายวันในฤดูฝน เนื่องจากน้ำท่าในฤดูแล้งมีความผันผวนน้อยกว่าในฤดูฝน เพราะในฤดูแล้งความไม่แน่นอนของปริมาณน้ำท่าที่เกิดจากฝนเริ่มหมดไป
- ค่าความคลาดเคลื่อนในการพยากรณ์น้ำท่ารายวันในฤดูแล้ง ณ สถานีวัดน้ำท่าต่างๆ ในช่วง 1-7 วันล่วงหน้า มีค่าอยู่ระหว่าง 5.93-26.50 %
- ความแตกต่างขนาดของพื้นที่ลุ่มน้ำต่อความแม่นยำในการพยากรณ์น้ำท่ารายวันในฤดูแล้งนั้นให้ผลที่ไม่ชัดเจนมากนัก เนื่องจากรูปแบบการไหลของน้ำท่าในฤดูแล้งที่ออกจากลุ่มน้ำต่าง ๆ มีลักษณะคล้ายคลึงกัน ซึ่งจะไม่แตกต่างกันอย่างชัดเจนเหมือนในฤดูฝน
- ผลการพยากรณ์น้ำท่า ณ สถานี KGT.14 มีความคลาดเคลื่อนมาก เมื่อเทียบกับผลการพยากรณ์น้ำท่า ณ สถานีอื่นๆ เนื่องจากน้ำท่าที่ไหลออกจากลุ่มน้ำมีค่าน้อยมาก และในบางช่วงเวลามีค่าเป็นศูนย์ โดยค่าที่เป็นศูนย์นี้จะก่อให้เกิดปัญหาในการคำนวณของแบบจำลองทำให้การพยากรณ์มีค่าผิดพลาดมาก ซึ่งปัญหานี้มักพบกันทั่วไปในแบบจำลองทางคณิตศาสตร์

3) ผลการพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้าโดยวิธี Standard step และ Direct step ให้ผลไม่แตกต่างกันมากในการพยากรณ์ล่วงหน้า 1-2 วันแรก แต่เมื่อระยะเวลาการพยากรณ์ยาวนานขึ้น การพยากรณ์ล่วงหน้าโดยวิธี Standard step จะให้ผลการพยากรณ์ที่แม่นยำมากกว่าวิธี Direct step อย่างชัดเจน ทั้งในแบบ จำลอง ANN ที่ใช้ในฤดูฝนและฤดูแล้ง แต่ทั้งนี้การพยากรณ์โดยวิธี Standard step นั้นจะมีจำนวนครั้งในการพยากรณ์เท่ากับจำนวนวันที่

พยากรณ์ล่วงหน้า ซึ่งจะมีจำนวนครั้งมากกว่าวิธี Direct step ที่จะพยากรณ์ล่วงหน้าภายในครั้งเดียว

4) แบบจำลองอนุกรมเวลาสามารถช่วยปรับปรุงผลการพยากรณ์ที่ได้จากแบบจำลอง ANN ให้มีประสิทธิภาพในการพยากรณ์เพิ่มขึ้นจากเดิมประมาณ 0.6-14.7% สำหรับแบบจำลอง ANN ที่ใช้ในฤดูฝน และ 0.7-8.9% สำหรับแบบจำลอง ANN ที่ใช้ในฤดูแล้ง โดยแบบจำลองอนุกรมเวลาส่วนใหญ่ที่ใช้นั้นจะเป็นแบบจำลอง MA(2)

5) เมื่อเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN และ MLR พบว่า ในฤดูฝนแบบจำลอง ANN จะให้ผลการพยากรณ์ที่ดีกว่าแบบจำลอง MLR ในทุกกรณี โดยเฉพาะเมื่อระยะเวลาการพยากรณ์ยาวนานขึ้น ทั้งนี้เนื่องจากอัตราการไหลน้ำท่าในฤดูฝนมีความผันผวนและความไม่เป็นเชิงเส้นสูงเพราะความไม่แน่นอนของเวลาและปริมาณฝนที่ตกในพื้นที่ลุ่มน้ำ ทำให้แบบจำลอง MLR ซึ่งเป็นแบบจำลองเชิงเส้นใช้การในฤดูฝนได้ไม่ดีมากนัก แต่สำหรับในฤดูแล้งนั้นพบว่า ในช่วงการพยากรณ์ล่วงหน้า 1-3 วัน ผลการพยากรณ์จากแบบจำลอง ANN และ MLR จะไม่แตกต่างกันมากนัก มีบางกรณีที่แบบจำลอง MLR ให้ผลดีกว่า ทั้งนี้สืบเนื่องมาจากปริมาณน้ำท่าในฤดูแล้งส่วนใหญ่จะมาจากปริมาณน้ำที่สะสมอยู่ใต้ผิวดิน (base flow) ซึ่งมีค่าไม่มากและความไม่แน่นอนของปริมาณน้ำท่าที่เกิดจากฝนเริ่มหมดไป ส่งผลให้อัตราการไหลน้ำท่าในฤดูแล้งมีความผันผวนน้อยลงและมีความเป็นเชิงเส้นมากขึ้นเมื่อเทียบกับฤดูฝน ทำให้แบบจำลอง MLR สามารถใช้การได้ดีขึ้น แต่เมื่อระยะเวลาการพยากรณ์ยาวนานขึ้นผลการพยากรณ์จากแบบจำลอง ANN ยังให้ผลดีกว่าแบบจำลอง MLR อย่างชัดเจน ซึ่งอาจเนื่องด้วยจำนวนพารามิเตอร์ที่มากกว่าของแบบจำลอง ANN นั้น จึงทำให้สามารถพยากรณ์ล่วงหน้าในระยะยาวได้ดีกว่าแบบจำลอง MLR ทั้งในฤดูฝนและฤดูแล้ง

6) การคัดเลือกค่าพารามิเตอร์  $\alpha$  และ  $\eta$  ที่เหมาะสมในแบบจำลอง BPNN ซึ่งเป็นแบบจำลอง ANN ที่มีรูปแบบอย่างง่ายและนิยมใช้กันทั่วไป เพื่อใช้ในกระบวนการเรียนรู้แบบย้อนกลับ และการปรับแก้ค่าถ่วงน้ำหนักแบบ Delta Rule นั้น พบว่าค่าทั้ง 2 ควรจะเริ่มจากค่าที่ไม่สูงมากนักเพื่อป้องกันการลู่ออกของการคำนวณในแบบจำลอง โดยจากการศึกษาครั้งนี้พบว่า ค่า  $\alpha$  ที่เหมาะสมจะมีค่าเริ่มต้นเท่ากับ 0.45 และจะเปลี่ยนเป็น 0.95 ที่รอบการคำนวณซ้ำ 5000 รอบ (เงื่อนไขการหยุดการคำนวณซ้ำในการศึกษาครั้งนี้จะอยู่ที่ 10,000 รอบ) เนื่องจากการเพิ่มค่า  $\alpha$  จะช่วยให้การคำนวณลู่เข้าสู่ผลลัพธ์เร็วขึ้น สำหรับค่า  $\eta$  ควรอยู่ระหว่าง 0.001-0.01 และควรกำหนดให้มีค่าคงที่ เนื่องจากค่า  $\eta$  มีความอ่อนไหวต่อการลู่เข้าสู่ผลลัพธ์มาก ถ้ามีการปรับเปลี่ยนค่า  $\eta$  ระหว่างการปรับเทียบแบบจำลองจะทำให้การคำนวณลู่ออกได้ง่าย

ในส่วนของการคัดเลือกลักษณะโครงข่ายภายในที่เหมาะสมในแบบจำลอง BPNN อันได้แก่ การคัดเลือกจำนวนหน่วยในชั้นแอบแฝงและจำนวนชั้นแอบแฝง ในการศึกษานี้ได้กำหนด

จำนวนหน่วยในชั้นแอบแฝงให้มีความสัมพันธ์กับจำนวนตัวแปรนำเข้าคือ มีจำนวนหน่วยเป็นครึ่งเท่า เท่ากับ และสองเท่าของจำนวนตัวแปรนำเข้า โดยจะใช้ชั้นแอบแฝง 1 และ 2 ชั้น จากการศึกษาพบว่า การปรับเปลี่ยนจำนวนหน่วยในชั้นแอบแฝงและจำนวนชั้นแอบแฝงตามที่กำหนดนั้น ไม่ได้ทำให้ประสิทธิภาพของแบบจำลองในการพยากรณ์แตกต่างกันอย่างชัดเจน ทั้งนี้อาจเนื่องมาจากแบบจำลอง BPNN ที่จัดสร้างขึ้นส่วนใหญ่มีจำนวนตัวแปรนำเข้าไม่มากทำให้แบบจำลองขนาดเล็ก ส่งผลให้ประสิทธิภาพของแบบจำลองไม่แตกต่างกันมากนักเมื่อมีการปรับเปลี่ยนจำนวนหน่วยและจำนวนชั้นแอบแฝง สำหรับจำนวนหน่วยในชั้นแอบแฝงที่เหมาะสมในแบบจำลอง BPNN ส่วนใหญ่ในการศึกษาครั้งนี้ จะมีจำนวนเท่ากับจำนวนตัวแปรนำเข้า โดยแบบจำลอง ANN ที่มีจำนวนตัวแปรนำเข้า 1-4 ตัว จะใช้ชั้นแอบแฝงเพียงชั้นเดียว ส่วนแบบจำลอง ANN ที่มีจำนวนตัวแปรนำเข้าตั้งแต่ 5 ตัวขึ้นไป จะใช้จำนวนชั้นแอบแฝง 2 ชั้น และในแต่ละชั้นแอบแฝงจะมีจำนวนหน่วยเป็นครึ่งหนึ่งของตัวแปรนำเข้า นอกจากนี้จำนวนหน่วยในชั้นแอบแฝงอย่างต่ำในแบบจำลอง ANN นั้น ควรมีจำนวนตั้งแต่ 2 หน่วยขึ้นไป

## 7.2 ข้อเสนอแนะ

- 1) ในอนาคตหากมีการเก็บข้อมูลที่มีความสัมพันธ์หรือมีอิทธิพลต่อน้ำท่าเพิ่มมากขึ้น เช่น การระเหย ความชื้นในดิน การเปลี่ยนแปลงสภาพพื้นที่ เป็นต้น ควรนำข้อมูลเหล่านี้มาใช้เป็นตัวแปรนำเข้าร่วมกับข้อมูลฝนและอัตราการไหลน้ำท่าของสถานีตัวมันเองซึ่งนิยมใช้กันทั่วไปในปัจจุบัน ทั้งนี้เนื่องจากตัวแปรนำเข้าเป็นปัจจัยสำคัญที่ส่งผลต่อความแม่นยำในการพยากรณ์
- 2) การพยากรณ์อัตราการไหลน้ำท่ารายวันที่ออกมาจากลุ่มน้ำขนาดใหญ่ ดังเช่น การพยากรณ์ ณ สถานี KGT.3 ควรแบ่งการพยากรณ์ออกเป็นพื้นที่ย่อยๆ เพื่อความแม่นยำในการพยากรณ์และเป็นการคำนึงถึงลักษณะทางกายภาพที่แตกต่างกันของพื้นที่ต่างๆในลุ่มน้ำ โดยการแบ่งพื้นที่ย่อยๆ นั้นจะขึ้นอยู่กับสถานีวัดน้ำท่าที่ตั้งอยู่ในพื้นที่เป็นหลัก
- 3) จากการแบ่งช่วงข้อมูลสำหรับฤดูฝนและฤดูแล้ง ณ สถานี KGT.10 นั้น จะเห็นได้ว่ามียังมีการเชื่อมล้าของฤดูกาลเกิดขึ้น ทั้งนี้อาจเนื่องมาจากช่วงเวลาเริ่มต้นและสิ้นสุดของฤดูกาลในแต่ละพื้นที่ของลุ่มน้ำขนาดใหญ่มีความแตกต่างกันมาก เป็นผลให้ประสิทธิภาพในการพยากรณ์ของแบบจำลองมีค่าลดลง ดังนั้นจึงควรมีการแบ่งข้อมูลในช่วงระหว่างการเปลี่ยนแปลงฤดู (transition) และนำมาใช้ในการจัดสร้างแบบจำลองเพิ่มเติม
- 4) การพยากรณ์โดยวิธี Standard step เป็นวิธีที่ช่วยให้สามารถพยากรณ์ล่วงหน้าได้หลายวัน แต่ก็ยังมีข้อจำกัดในเรื่องของจำนวนตัวแปรนำเข้าที่ไม่มีการพยากรณ์ล่วงหน้า ซึ่งได้แก่ ข้อ

มูลปริมาณน้ำฝนรายวัน ที่จะมีจำนวนลดลงเมื่อระยะเวลาพยากรณ์ล่วงหน้ายาวนานขึ้น ทำให้มีผลต่อความแม่นยำในการพยากรณ์ล่วงหน้าระยะยาว

5) ควรมีการเปรียบเทียบผลการพยากรณ์ระหว่างแบบจำลอง ANN กับแบบจำลองอื่นๆ ที่มีความสามารถในการพยากรณ์ที่เทียบหรือใกล้เคียงกัน เช่น แบบจำลองทางกายภาพ ที่มีความพร้อมของข้อมูล หรือแบบจำลองที่มีลักษณะเป็น Non-Linear เป็นต้น เพื่อจะได้เห็นถึงความสามารถและศักยภาพในการพยากรณ์ของแบบจำลอง ANN ได้ชัดเจนมากขึ้น นอกเหนือจากการเปรียบเทียบระหว่างแบบจำลอง MLR ซึ่งเป็นแบบจำลองเชิงเส้นอย่างง่าย

6) ควรมีการศึกษาเพิ่มเติมหรือทดลองนำแบบจำลอง ANN ในรูปแบบอื่นๆ นอกเหนือจากแบบจำลอง BPNN ซึ่งเป็นแบบจำลอง ANN อย่างง่าย มาประยุกต์ในการพยากรณ์น้ำท่ารายวัน



สถาบันวิทยบริการ  
จุฬาลงกรณ์มหาวิทยาลัย

## รายการอ้างอิง

### ภาษาไทย

- กัลยา วานิชย์บัญชา. การใช้ SPSS for Windows ในการวิเคราะห์ข้อมูล. ห้างหุ้นส่วนจำกัด ซี เค แอนด์ เฮส โฟโต้สตูดิโอ, 2543.
- เจษฎา สารสินพิทักษ์. การศึกษาแนวทางการประมาณเนื่องงานก่อสร้างอาคารด้วยแบบจำลองโครงข่ายประสาทเทียม. วิทยานิพนธ์ปริญญาโทบริหารธุรกิจ ภาควิชาวิศวกรรมโยธา บัณฑิตวิทยาลัย จุฬาลงกรณ์มหาวิทยาลัย, 2543.
- ชัยพันธุ์ รักรวิชัย. บทแนะนำ Stochastic Processes in Hydrology. ภาควิชาวิศวกรรมแหล่งน้ำ จุฬาลงกรณ์มหาวิทยาลัย, 2529.
- ชัยโรจน์ คุณพนิชิกจ. รายงานผลการประดิษฐ์เงินอุดหนุนโครงการสิ่งประดิษฐ์ เรื่อง โปรแกรมวิเคราะห์อนุกรมเวลา. จุฬาลงกรณ์มหาวิทยาลัย, 2539.
- มหาวิทยาลัยเกษตรศาสตร์, ภาควิชาภาควิชาวิศวกรรมศาสตร์ทรัพยากรน้ำ. โครงการศึกษาข้อมูลและศักยภาพการพัฒนาสูบน้ำปราจีนบุรี. กรมชลประทาน, 2537.
- มหาวิทยาลัยเกษตรศาสตร์, ภาควิชาภาควิชาวิศวกรรมศาสตร์ทรัพยากรน้ำ. โครงการศึกษาเพื่อจัดทำแผนหลักการพัฒนาและการจัดการทรัพยากรน้ำภาคตะวันออก. กรมชลประทาน, 2543.
- วีระชัย ชูพิศาลโยโรจน์. การศึกษาความสัมพันธ์ระหว่างน้ำฝน-น้ำท่าในลุ่มน้ำป่าสักโดยใช้แบบจำลองดัง. วิทยานิพนธ์ปริญญาโทบริหารธุรกิจ ภาควิชาวิศวกรรมแหล่งน้ำ บัณฑิตวิทยาลัย จุฬาลงกรณ์มหาวิทยาลัย, 2530.
- วีระพล แต่มสมบัติ. อุทกวิทยาประยุกต์. ภาควิชาวิศวกรรมศาสตร์ทรัพยากรน้ำ มหาวิทยาลัยเกษตรศาสตร์, 2531.
- วุฒิชัย บุญผ่อง. การประยุกต์ใช้ระบบโครงข่ายประสาทเทียมในการคาดการณ์ปริมาณน้ำท่ารายวัน. วิทยานิพนธ์ปริญญาโทบริหารธุรกิจ ภาควิชาวิศวกรรมโยธา บัณฑิตวิทยาลัย มหาวิทยาลัยเทคโนโลยีมหานคร, 2544.
- สุชาติ ศิริจัสกุล. แบบจำลองน้ำฝน-น้ำท่ารายเดือน. วิทยานิพนธ์ปริญญาโทบริหารธุรกิจ ภาควิชาวิศวกรรมแหล่งน้ำ บัณฑิตวิทยาลัย จุฬาลงกรณ์มหาวิทยาลัย, 2534.
- เสรี ศุภราทิตย์. คู่มือการพยากรณ์น้ำโดยใช้โครงข่ายประสาทเทียม. คณะอนุกรรมการศึกษาวิจัยด้านบริหารจัดการน้ำ สถาบันพัฒนาการชลประทาน (IDI), 2544.
- เสรี ศุภราทิตย์, ชัยยุทธ ชินฉัตร และทรงพล โนนสว่าง. การพยากรณ์ระดับน้ำที่หาดใหญ่โดยใช้



โครงการวิจัยประสาทเทียม. เอกสารการประชุมวิชาการวิศวกรรมแหล่งน้ำ แห่งชาติครั้งที่ 1. วิศวกรรมสถานแห่งประเทศไทย, 2544.

เสรี ศุภราทิตย์ และรุ่งเรือง จุลชาติ. ระบบพยากรณ์และเตือนภัยน้ำท่วมโดย Neuro-genetic algorithm (กรณีศึกษาน้ำท่วมขนาดใหญ่). เอกสารการประชุมวิชาการวิศวกรรมแหล่งน้ำ แห่งชาติครั้งที่ 1. วิศวกรรมสถานแห่งประเทศไทย, 2544.

#### ภาษาอังกฤษ

Abrahart, R. J., See, L., and Kneale P. E. Using pruning algorithms and genetic algorithms to optimize network architectures and forecasting inputs in a neural network rainfall-runoff model. Journal of Hydroinformatics. IWA Publishing, (1999): 103-114.

Coulibaly, P., Anctil F., and Bobee, B. Multivariate reservoir inflow forecasting using temporal neural networks. Journal of Hydrologic Engineering. ASCE, 6(5), (2001): 367-376.

Crespo, L., and Mora, E. Drought estimation with neural networks. Advance in Engineering Software. Elsevier, Whitstable, Kent, U.K., (1993): 167-170.

Danh, N. T. Forecasting river daily flow: a case study in Vietnam. M.Eng Thesis, Asian Institute of Technology, Thailand, 1995.

Dolling, O. R., and Varas, E. A. Artificial neural networks for streamflow prediction. Journal of Hydraulic Research. 40(5), (2002): 547-554.

Fernando, K., Achela, D., and Jayawardena, A. W. Runoff forecasting using RBE networks with OLS algorithm. Journal of Hydrologic Engineering. ASCE, 3(3), (1998): 203-209.

French, M. N., Krajewski, W. F., and Cuykendall, R. R. Rainfall forecasting in space and time using a neural networks. Journal of Hydrology. 137, (1992): 1-31.

Gul, R. The application of back propagation model to daily flow forecasting. M.Eng Thesis, Asian Institute of Technology, Thailand, 1993.

Kabling, M. B. A combined deterministic stochastic model for daily flow forecasting of Pasak River basin. M.Eng Thesis, Asian Institute of Technology, Thailand, 1989.


Kitpaisalsakul, T., and Piman, T. Development of daily runoff forecasting model using artificial neural networks and multiple linear regression. Proceeding of

- International Symposium on Lowland Technology. Segu University, (2002): 321-326.
- Kitpaisalsakul, T., and Suttinon, P. Development of artificial neural networks and harmonic analysis in forecasting tidal levels. Proceeding of International Symposium on Lowland Technology. Segu University, (2002): 327-332.
- Manusthiparom, C. Neural network models for forecasting hourly water levels and discharges of Chao Phraya River at Bangkok Memorial Bridge. M.Eng Thesis, Asian Institute of Technology, Thailand, 2000.
- Nam, N. T. K. Application of hybrid models for forecasting daily inflow to the Hoabinh Reservoir, North Vietnam. M.Eng Thesis, Asian Institute of Technology, Thailand, 1991.
- Prasad, S. Y. A hybrid approach in daily flow forecasting. M.Eng Thesis, Asian Institute of Technology, Thailand, 1995.
- Salas, J. D., Deileur, J. W., and Lane, W. L. Applied Modeling of Hydrologic Time Series. U.S.A.: Water Resources Publications, 1980.
- Siang, J. J. Application of back propagation method in forecasting problem. M.Eng Thesis, Asian Institute of Technology, Thailand, 1992.
- Singh, V. P. Hydrologic Systems Volume II. U.S.A.: Prentice-Hall, New Jersey, 1989.
- Singh, V. P. Elementary Hydrology. U.S.A.: Prentice-Hall, New Jersey, 1992.
- Thirumalaiah, K. and Deo, M. C. River stage forecasting using artificial neural networks. Journal of Hydrologic Engineering. ASCE, 3 (1), (1998): 26-32.
- Tingsanchali, T. Back propagation network for flood forecasting. Proceeding of Special Lecture on Application of Artificial Intelligence in Water Resources Engineering. Rangsit University, Thailand, 2001.
- Tokar, S. A. and Johnson, P. A. Rainfall-Runoff modeling using artificial neural networks. Journal of Hydrologic Engineering. ASCE, 4 (3), (1999): 232-239.
- Win, T. Y. Daily flood forecasting : a neural networks model of Prasae River. M.Eng Thesis, Asian Institute of Technology, Thailand, 1999.
- Yevjevich, V. M. Stochastic Process in Hydrology. U.S.A.: Water Resources Publications, LithoCrafters, 1972.



**ภาคผนวก**


สถาบันวิทยบริการ  
จุฬาลงกรณ์มหาวิทยาลัย



# ภาคผนวก ก


รูปตัดตามยาวและตามขวางของแม่น้ำในพื้นที่ศึกษา

สถาบันวิทยบริการ  
จุฬาลงกรณ์มหาวิทยาลัย




รูป ก-1 รูปตัดตามยาวของแม่น้ำในลุ่มน้ำย่อยต่างๆ ที่ใช้ในการศึกษา

สถาบันวิทยบริการ  
พระจอมเกล้าวิทยาลัย




รูป ก-2 รูปตัดตามยาวของแม่น้ำใส-โตใหญ่ และ แม่น้ำดำพระยาธาร

สถาบันวิทยบริการ  
จุฬาลงกรณ์มหาวิทยาลัย




รูป ก-3 รูปตัดตามยาวของลำน้ำห้วยโตม และคลองพระปรงตอนบน

สถาบันวิทยบริการ  
จุฬาลงกรณ์มหาวิทยาลัย





รูป ก-4 รูปตัดตามยาวของลำน้ำคลองพระสถ์ถึง





รูป ก-5 รูปตัดตามขวางของแม่น้ำปราจีนบุรี ณ สถานีวัดน้ำท่า KGT.3

สงวนลิขสิทธิ์  
สำนักงานชลประทานที่ 12





รูป ก-6 รูปตัดตามขวางของแม่น้ำลำพระยาธาร ณ สถานีวัดน้ำท่า KGT.14 และห้วยตมิง ณ สถานีวัดน้ำท่า KGT.15A



รูป ก-7 รูปตัดตามขวางของคลองพระปรางค์ตอนบน ณ สถานีวัดน้ำท่า KGT.12 และคลองพระสัก ณ สถานีวัดน้ำท่า KGT.10



# ภาคผนวก ข


การวิเคราะห์ข้อมูลเบื้องต้น

สถาบันวิทยบริการ  
จุฬาลงกรณ์มหาวิทยาลัย


ตาราง ข-1 ความสัมพันธ์ของข้อมูลปริมาณน้ำฝนรายวันระหว่างสถานีต่างๆ ในพื้นที่ศึกษา

สถานี	44043	44191	44132	44181	150401	25142	25152	74081	74092	74071	74012	74022	03231	06062
44043	1													
44191	0.533	1												
44132	0.434	0.552	1											
44181	0.460	0.621	0.562	1										
150401	0.513	0.587	0.567	0.640	1									
25142	0.244	0.236	0.224	0.259	0.234	1								
25152	0.328	0.334	0.330	0.404	0.375	0.317	1							
74081	0.499	0.559	0.408	0.473	0.448	0.231	0.305	1						
74092	0.492	0.515	0.364	0.442	0.434	0.240	0.288	0.694	1					
74071	0.412	0.394	0.327	0.345	0.342	0.217	0.260	0.457	0.481	1				
74012	0.435	0.411	0.335	0.358	0.362	0.215	0.274	0.489	0.587	0.689	1			
74022	0.365	0.335	0.279	0.305	0.314	0.208	0.236	0.376	0.390	0.409	0.445	1		
03231	0.287	0.277	0.212	0.266	0.247	0.196	0.228	0.272	0.305	0.319	0.310	0.284	1	
06062	0.279	0.295	0.270	0.300	0.314	0.133	0.242	0.288	0.278	0.244	0.246	0.264	0.231	1

สถานีที่ใช้ในการประมาณค่าข้อมูลน้ำฝนรายวันที่ขาดหายไป กลุ่มที่ 1



สถานีที่ใช้ในการประมาณค่าข้อมูลน้ำฝนรายวันที่ขาดหายไป กลุ่มที่ 2



สมมาตร

## ตาราง ข-2 การเติมข้อมูลปริมาณฝนรายวันที่ขาดหายไป

สถานี: 44181

ช่วงข้อมูล ที่ขาดหาย	สถานีที่เติม	สถานีที่ใกล้เคียง		
	44181	44191 W = 0.302	44132 W = 0.385	150401 W = 0.312
1-May-75	2.72	9.00	0.00	0.00
2-May-75	4.35	0.00	11.30	0.00
3-May-75	9.46	20.80	4.60	4.50
4-May-75	1.33	0.70	0.00	3.60
5-May-75	0.41	0.00	0.00	1.30
6-May-75	2.12	3.60	0.00	3.30
7-May-75	0.00	0.00	0.00	0.00
8-May-75	0.00	0.00	0.00	0.00
9-May-75	0.00	0.00	0.00	0.00
10-May-75	2.91	0.00	5.20	2.90
11-May-75	20.71	17.60	8.70	38.60
12-May-75	6.21	9.60	0.00	10.60
13-May-75	0.00	0.00	0.00	0.00
14-May-75	0.91	3.00	0.00	0.00
15-May-75	0.56	0.00	0.00	1.80
16-May-75	0.00	0.00	0.00	0.00
17-May-75	0.00	0.00	0.00	0.00
18-May-75	0.12	0.40	0.00	0.00
19-May-75	3.24	0.10	0.00	10.30
20-May-75	4.18	2.70	3.40	6.60
21-May-75	0.58	1.00	0.00	0.90
22-May-75	13.88	1.70	2.70	39.50
23-May-75	7.20	0.40	0.00	22.70
24-May-75	3.51	2.00	0.00	9.30
25-May-75	33.03	32.90	18.00	51.80
26-May-75	0.21	0.70	0.00	0.00
27-May-75	17.81	37.10	15.30	2.30
28-May-75	0.00	0.00	0.00	0.00
29-May-75	34.24	17.50	50.00	31.10
30-May-75	0.00	0.00	0.00	0.00
31-May-75	0.24	0.50	0.00	0.30

สถานี: 44191

ช่วงข้อมูล ที่ขาดหาย	สถานีที่เติม	สถานีที่ใกล้เคียง		
	44191	44132 W = 0.527	44181 W = 0.171	150401 W = 0.302
15-Sep-96	1.72	1.50	1.40	2.30
2-Oct-96	0.05	0.10	0.00	0.00
8-Oct-96	0.00	0.00	0.00	0.00
9-Oct-96	11.13	12.40	0.20	15.10
12-Oct-96	0.00	0.00	0.00	0.00
13-Oct-96	0.07	0.00	0.40	0.00
14-Oct-96	0.00	0.00	0.00	0.00
15-Oct-96	0.00	0.00	0.00	0.00
16-Oct-96	0.00	0.00	0.00	0.00
17-Oct-96	0.00	0.00	0.00	0.00
18-Oct-96	0.00	0.00	0.00	0.00
20-Oct-96	0.00	0.00	0.00	0.00
21-Oct-96	0.00	0.00	0.00	0.00
22-Oct-96	0.00	0.00	0.00	0.00
26-Oct-96	0.00	0.00	0.00	0.00
27-Oct-96	0.00	0.00	0.00	0.00
28-Oct-96	0.00	0.00	0.00	0.00

สถานี: 74081

ช่วงข้อมูล ที่ขาดหาย	สถานีที่เติม	สถานีที่ใกล้เคียง		
	74081	74092 W = 0.863	74071 W = 0.068	74012 W = 0.07
1-May-96	0.00	0.00	0.00	0.00
2-May-96	0.00	0.00	0.00	0.00
3-May-96	8.06	8.80	0.00	6.60
4-May-96	43.57	47.20	13.20	27.70
5-May-96	1.21	1.40	0.00	0.00
6-May-96	0.00	0.00	0.00	0.00
7-May-96	0.00	0.00	0.00	0.00
8-May-96	13.91	13.50	17.00	15.80
9-May-96	4.37	4.30	1.00	8.40
10-May-96	0.00	0.00	0.00	0.00

## ตาราง ข-2 การเติมข้อมูลปริมาณฝนรายวันที่ขาดหายไป (ต่อ)

สถานี: 74071

ช่วงข้อมูล ที่ขาดหาย	สถานีที่เติม	สถานีที่ใกล้เคียง		
	74071	74081 W = 0.034	74092 W = 0.064	74012 W = 0.903
1-Oct-79	0.00	0.00	0.00	0.00
2-Oct-79	0.00	0.00	0.00	0.00
3-Oct-79	0.01	0.40	0.00	0.00
4-Oct-79	5.51	0.00	0.00	6.10
5-Oct-79	2.59	0.00	40.50	0.00
6-Oct-79	0.00	0.00	0.00	0.00
7-Oct-79	0.00	0.00	0.00	0.00
8-Oct-79	0.00	0.00	0.00	0.00
9-Oct-79	0.00	0.00	0.00	0.00
10-Oct-79	0.00	0.00	0.00	0.00
11-Oct-79	0.00	0.00	0.00	0.00
12-Oct-79	0.00	0.00	0.00	0.00
13-Oct-79	0.00	0.00	0.00	0.00
14-Oct-79	0.00	0.00	0.00	0.00
15-Oct-79	0.00	0.00	0.00	0.00
16-Oct-79	0.00	0.00	0.00	0.00
17-Oct-79	0.00	0.00	0.00	0.00
18-Oct-79	0.00	0.00	0.00	0.00
19-Oct-79	0.00	0.00	0.00	0.00
20-Oct-79	0.00	0.00	0.00	0.00
21-Oct-79	0.00	0.00	0.00	0.00
22-Oct-79	0.00	0.00	0.00	0.00
23-Oct-79	0.00	0.00	0.00	0.00
24-Oct-79	0.58	0.00	9.10	0.00
25-Oct-79	0.00	0.00	0.00	0.00
26-Oct-79	26.86	0.00	98.00	22.80
27-Oct-79	0.52	0.00	8.20	0.00
28-Oct-79	0.00	0.00	0.00	0.00
29-Oct-79	0.00	0.00	0.00	0.00
30-Oct-79	0.00	0.00	0.00	0.00
31-Oct-79	0.00	0.00	0.00	0.00

สถานี: 74071 (ต่อ)

ช่วงข้อมูล ที่ขาดหาย	สถานีที่เติม	สถานีที่ใกล้เคียง		
	74071	74081 W = 0.034	74092 W = 0.064	74012 W = 0.903
1-Sep-88	3.29	9.50	22.40	1.70
2-Sep-88	0.00	0.00	0.00	0.00
3-Sep-88	0.00	0.00	0.00	0.00
4-Sep-88	0.00	0.00	0.00	0.00
5-Sep-88	0.00	0.00	0.00	0.00
6-Sep-88	2.25	2.50	0.00	2.40
7-Sep-88	0.36	1.40	3.40	0.10
8-Sep-88	20.48	5.50	43.40	19.40
9-Sep-88	3.78	4.50	5.80	3.60
10-Sep-88	5.48	10.60	2.40	5.50
11-Sep-88	3.95	26.90	44.60	0.20
12-Sep-88	1.58	7.00	21.00	0.00
13-Sep-88	4.12	3.70	15.80	3.30
14-Sep-88	0.00	0.00	0.00	0.00
15-Sep-88	29.44	3.10	4.00	32.20
16-Sep-88	11.41	26.90	8.80	11.00
17-Sep-88	47.53	30.00	21.30	50.00
18-Sep-88	80.12	76.20	54.50	82.00
19-Sep-88	7.44	1.00	5.60	7.80
20-Sep-88	0.97	6.80	11.50	0.00
21-Sep-88	0.00	0.00	0.00	0.00
22-Sep-88	0.00	0.00	0.00	0.00
23-Sep-88	0.00	0.00	0.00	0.00
24-Sep-88	0.00	0.00	0.00	0.00
25-Sep-88	9.83	1.30	32.90	6.50
26-Sep-88	4.09	6.20	11.20	3.50
27-Sep-88	2.80	0.00	0.00	3.10
28-Sep-88	36.69	15.50	34.50	37.60
29-Sep-88	13.23	25.10	38.20	11.00
30-Sep-88	0.47	0.50	0.00	0.50

ตาราง ข-3 สรุปผลการแบ่งช่วงข้อมูลสำหรับฤดูฝน-ฤดูแล้ง โดยใช้โค้งปริมาณน้ำฝนสะสมรายวัน

ปีน้ำ	ฤดูฝน		ฤดูแล้ง		
2512	-	-	1/เม.ย./13	ถึง	30/เม.ย./13
2513	1/พ.ค./13	ถึง 7/พ.ย./13	8/พ.ย./13	ถึง	11/เม.ย./14
2514	12/เม.ย./14	ถึง 10/พ.ย./14	11/พ.ย./14	ถึง	4/เม.ย./15
2515	5/เม.ย./15	ถึง 8/ธ.ค./15	9/ธ.ค./15	ถึง	25/เม.ย./16
2516	26/เม.ย./16	ถึง 25/ต.ค./16	26/ต.ค./16	ถึง	2/เม.ย./17
2517	3/เม.ย./17	ถึง 27/พ.ย./17	28/พ.ย./17	ถึง	19/พ.ค./18
2518	20/พ.ค./18	ถึง 12/พ.ย./18	13/พ.ย./18	ถึง	27/เม.ย./19
2519	28/เม.ย./19	ถึง 10/พ.ย./19	11/พ.ย./19	ถึง	14/เม.ย./20
2520	15/เม.ย./20	ถึง 2/พ.ย./20	3/พ.ย./20	ถึง	2/พ.ค./21
2521	3/พ.ค./21	ถึง 7/ต.ค./21	8/ต.ค./21	ถึง	6/พ.ค./22
2522	7/พ.ค./22	ถึง 10/ต.ค./22	11/ต.ค./22	ถึง	16/พ.ค./23
2523	17/พ.ค./23	ถึง 28/ต.ค./23	29/ต.ค./23	ถึง	29/เม.ย./24
2524	30/เม.ย./24	ถึง 1/ธ.ค./24	2/ธ.ค./24	ถึง	26/เม.ย./25
2525	27/เม.ย./25	ถึง 27/พ.ย./25	28/พ.ย./25	ถึง	17/พ.ค./26
2526	18/พ.ค./26	ถึง 7/พ.ย./26	8/พ.ย./26	ถึง	31/มี.ค./27
2527	-	-	-	-	-
2528	-	-	1/เม.ย./29	ถึง	4/พ.ค./29
2529	5/พ.ค./29	ถึง 26/ต.ค./29	27/ต.ค./29	ถึง	7/พ.ค./30
2530	8/พ.ค./30	ถึง 16/พ.ย./30	17/พ.ย./30	ถึง	19/เม.ย./31
2531	20/เม.ย./31	ถึง 18/ต.ค./31	19/ต.ค./31	ถึง	5/พ.ค./32
2532	6/พ.ค./32	ถึง 1/พ.ย./32	2/พ.ย./32	ถึง	30/เม.ย./33
2533	1/พ.ค./33	ถึง 10/พ.ย./33	11/พ.ย./33	ถึง	11/พ.ค./34
2534	12/พ.ค./34	ถึง 5/พ.ย./34	6/พ.ย./34	ถึง	10/พ.ค./35
2535	11/พ.ค./35	ถึง 3/พ.ย./35	4/พ.ย./35	ถึง	16/เม.ย./36
2536	17/เม.ย./36	ถึง 11/พ.ย./36	12/พ.ย./36	ถึง	24/เม.ย./37
2537	25/เม.ย./37	ถึง 25/ต.ค./37	26/ต.ค./37	ถึง	28/เม.ย./38
2538	29/เม.ย./38	ถึง 3/พ.ย./38	4/พ.ย./38	ถึง	2/พ.ค./39
2539	3/พ.ค./39	ถึง 12/พ.ย./39	13/พ.ย./39	ถึง	16/พ.ค./40
2540	17/พ.ค./40	ถึง 15/พ.ย./40	16/พ.ย./40	ถึง	2/พ.ค./41
2541	3/พ.ค./41	ถึง 27/พ.ย./41	28/พ.ย./41	ถึง	31/มี.ค./42


ตาราง ข-4 การแบ่งช่วงข้อมูลสำหรับปรับทานแบบจำลองในช่วงฤดูฝน ณ สถานีวัดน้ำท่า KGT.3  
โดยใช้วิธีแจกแจงความถี่แบบ Weibull

ปี	ปริมาณน้ำท่ารายปี ในฤดูฝน ณ สถานี KGT.3 (ล้าน ลบ.ม.)	การจัดเรียงลำดับ ข้อมูลตามขนาด (ล้าน ลบ.ม.)	ปีที่จัด เรียงใหม่	ลำดับ m (เมื่อ N =26)	ความถี่การเกิดซ้ำ % Prob = mx100/(N+1)	หมายเหตุ
2513	2882.8	4678.8	2526	1	3.70	
2514	3314.6	4391.5	2537	2	7.41	
2515	3564.3	4332.7	2521	3	11.11	
2516	3203.8	4304.8	2538	4	14.81	
2517	3420.6	3959.5	2534	5	18.52	ใช้ปรับทาน
2518	3686.9	3930.0	2519	6	22.22	
2519	3930.0	3915.0	2529	7	25.93	
2520	2357.5	3686.9	2518	8	29.63	
2521	4332.7	3564.3	2515	9	33.33	
2522	2167.8	3532.4	2524	10	37.04	
2523	3371.8	3520.7	2531	11	40.74	
2524	3532.4	3420.6	2517	12	44.44	
2525	3251.1	3371.8	2523	13	48.15	ใช้ปรับทาน
2526	4678.8	3314.6	2514	14	51.85	
2529	3915.0	3295.9	2533	15	55.56	
2530	1894.6	3251.1	2525	16	59.26	
2531	3520.7	3203.8	2516	17	62.96	
2532	2392.0	3159.6	2539	18	66.67	
2533	3295.9	2882.8	2513	19	70.37	
2534	3959.5	2719.2	2540	20	74.07	
2535	1404.1	2472.6	2536	21	77.78	
2536	2472.6	2392.0	2532	22	81.48	ใช้ปรับทาน
2537	4391.5	2357.5	2520	23	85.19	
2538	4304.8	2167.8	2522	24	88.89	
2539	3159.6	1894.6	2530	25	92.59	
2540	2719.2	1404.1	2535	26	96.30	



ตาราง ข-5 การแบ่งช่วงข้อมูลสำหรับปรับทานแบบจำลองในช่วงฤดูแล้ง ณ สถานีวัดน้ำท่า KGT.3  
โดยใช้วิธีแจกแจงความถี่แบบ Weibull

ปี	ปริมาณน้ำท่ารายปี ในฤดูแล้ง ณ สถานี KGT.3 (ล้าน ลบ.ม.)	การจัดเรียงลำดับ ข้อมูลตามขนาด (ล้าน ลบ.ม.)	ปีที่จัด เรียงใหม่	ลำดับ m (เมื่อ N =26)	ความถี่การเกิดซ้ำ % Prob = mx100/(N+1)	หมายเหตุ
2513	101.5	180.6	2516	1	3.70	
2514	101.0	154.9	2515	2	7.41	
2515	154.9	138.8	2524	3	11.11	
2516	180.6	131.5	2523	4	14.81	
2517	81.7	124.1	2530	5	18.52	ใช้ปรับทาน
2518	84.5	121.5	2533	6	22.22	
2519	115.3	115.3	2519	7	25.93	
2520	70.5	103.1	2531	8	29.63	
2521	60.8	101.5	2513	9	33.33	
2522	38.2	101.0	2514	10	37.04	
2523	131.5	100.5	2532	11	40.74	
2524	138.8	91.3	2529	12	44.44	
2525	73.5	90.4	2534	13	48.15	ใช้ปรับทาน
2526	47.2	86.3	2536	14	51.85	
2529	91.3	84.5	2518	15	55.56	
2530	124.1	81.7	2517	16	59.26	
2531	103.1	73.5	2525	17	62.96	
2532	100.5	70.5	2520	18	66.67	
2533	121.5	65.5	2540	19	70.37	
2534	90.4	60.8	2521	20	74.07	
2535	31.4	57.8	2539	21	77.78	
2536	86.3	54.0	2537	22	81.48	ใช้ปรับทาน
2537	54.0	47.2	2526	23	85.19	
2538	44.5	44.5	2538	24	88.89	
2539	57.8	38.2	2522	25	92.59	
2540	65.5	31.4	2525	26	96.30	



## ภาคผนวก ค

การคัดเลือกโครงข่ายภายในที่เหมาะสมในแบบจำลอง ANN

สถาบันวิทยบริการ  
จุฬาลงกรณ์มหาวิทยาลัย

ภาคผนวก ค1: แบบจำลองการพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า 1 วัน ในฤดูฝน

ตาราง ค1-1 การคัดเลือกโครงข่ายที่เหมาะสมสำหรับแบบจำลองการพยากรณ์  $Q_{t+1}$  ณ สถานี 150401

Input Variables :  $Q_{t-1}, R_{t-1}, R_{t-1,t-1}$  (3 Nodes)

Models	Hidden Nodes		Training					Testing					Remark
	Layer 1	Layer 2	EI	RMSE	MAD	Max. Abs. Error	EI	RMSE	MAD	Max. Abs. Error			
			(%)	( $m^3/s$ )	( $m^3/s$ )	( $m^3/s$ )	(%)	( $m^3/s$ )	( $m^3/s$ )	( $m^3/s$ )	( $m^3/s$ )		
1	1	-	80.04	16.03	6.74	374.52	72.33	14.62	7.02	147.57	***** Selected*****		
2	3	-	82.99	14.80	6.18	253.67	73.57	14.29	6.47	145.19			
3	6	-	82.96	14.81	6.13	258.05	73.35	14.35	6.40	145.23			
4	2	1	80.15	15.98	7.96	282.62	69.19	15.43	7.97	150.49			
5	3	3	82.98	14.81	6.10	257.28	73.15	14.40	6.35	144.88			

ตาราง ค1-2 การคัดเลือกโครงข่ายที่เหมาะสมสำหรับแบบจำลองการพยากรณ์  $Q_{t+1}$  ณ สถานี KGT.14

Input Variables :  $Q_{t-1}, R_{t-1}$  (2 Nodes)

Models	Hidden Nodes		Training					Testing					Remark
	Layer 1	Layer 2	EI	RMSE	MAD	Max. Abs. Error	EI	RMSE	MAD	Max. Abs. Error			
			(%)	( $m^3/s$ )	( $m^3/s$ )	( $m^3/s$ )	(%)	( $m^3/s$ )	( $m^3/s$ )	( $m^3/s$ )	( $m^3/s$ )		
1	1	-	70.26	7.80	3.09	118.71	68.36	6.45	2.97	58.16	***** Selected*****		
2	2	-	70.36	7.78	3.07	118.68	68.56	6.42	2.91	58.04			
3	4	-	70.30	7.78	3.08	118.69	68.53	6.42	2.92	58.01			
4	1	1	59.89	9.04	3.98	145.32	58.55	7.37	3.62	70.22			
5	2	2	59.90	9.04	3.99	142.61	58.53	7.37	3.63	70.43			

ตาราง ๕.1-3 การคัดเลือกโครงข่ายภายในที่เหมาะสมสำหรับแบบจำลองการพยากรณ์  $Q_{t+1}$  ณ สถานี KGT.15A

Input Variables :  $Q3_t, Q3_{t-1}, R3_t, R3_{t-1}$  (4 Nodes)

Models	Hidden Nodes		Training				Testing				Remark
			EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	
	Layer 1	Layer 2									
1	2	-	80.98	13.04	5.96	259.93	78.15	14.42	6.26	136.98	***** Selected*****
2	4	-	81.55	12.84	5.93	261.21	77.42	14.66	6.27	141.47	
3	8	-	81.40	12.90	5.96	264.59	77.61	14.60	6.28	138.82	
4	1	1	75.97	14.66	7.33	288.66	75.64	15.23	7.80	138.80	
5	2	2	80.90	13.07	5.85	258.36	77.81	14.54	6.53	140.24	
6	4	4	81.42	12.89	6.03	259.56	78.04	14.46	6.18	137.49	

ตาราง ๕.1-4 การคัดเลือกโครงข่ายภายในที่เหมาะสมสำหรับแบบจำลองการพยากรณ์  $Q_{t+1}$  ณ สถานี KGT.12

Input Variables :  $Q4_t, Q4_{t-1}, R4_{t-1}, R4_{t-2}, R4_{t-3}, R4_{t-4}, R4_{t-5}$  (8 Nodes)

Models	Hidden Nodes		Training				Testing				Remark
			EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	
	Layer 1	Layer 2									
1	4	-	98.59	5.56	3.08	123.56	98.08	4.92	2.85	37.04	***** Selected*****
2	8	-	98.59	5.55	3.23	126.86	98.05	4.95	3.07	34.54	
3	16	-	98.56	5.60	3.15	132.97	98.04	4.96	2.91	37.34	
4	2	2	98.57	5.60	3.16	111.43	98.06	4.94	3.02	37.36	
5	4	4	98.68	5.36	2.79	118.02	98.26	4.69	2.54	35.52	
6	8	8	98.45	5.83	3.26	132.26	97.88	5.17	3.00	38.31	

ตาราง ค1-5 การคัดเลือกโครงข่ายภายในที่เหมาะสมสำหรับจำลองการพยากรณ์  $Q_{t+1}$  ณ สถานี KGT.10

Input Variables :  $Q5_t, Q5_{t-1}, R5_t, R5_{t-1}, R5_{t-2}$  (5 Nodes)

Models	Hidden Nodes		Training					Testing					Remark
	Layer 1	Layer 2	EI	RMSE	MAD	Max. Abs. Error	EI	RMSE	MAD	Max. Abs. Error			
			(%)	( $m^3/s$ )	( $m^3/s$ )	( $m^3/s$ )	(%)	( $m^3/s$ )	( $m^3/s$ )	( $m^3/s$ )			
1	2	-	91.24	20.59	10.05	546.71	91.43	14.34	8.24	75.40	***** Selected*****		
2	5	-	91.21	20.62	10.26	519.66	91.18	14.54	8.47	72.70			
3	10	-	91.14	20.70	10.29	537.27	91.32	14.43	8.45	71.94			
4	1	1	90.41	21.54	11.56	575.82	89.70	15.72	9.58	81.06			
5	3	2	91.36	20.44	10.20	521.23	91.23	14.51	8.44	76.86			
6	5	5	91.27	20.55	10.19	533.04	91.24	14.49	8.46	74.52			

ตาราง ค1-6 การคัดเลือกโครงข่ายภายในที่เหมาะสมสำหรับจำลองการพยากรณ์  $Q_{t+1}$  ณ สถานี KGT.3

Input Variables :  $Q6_t, Q6_{t-1}, Q1_t, Q2_t, Q3_t, Q4_t, Q5_t, R6_t, R6_{t-1}, R6_{t-2}, R6_{t-3}$  (11 Nodes)

Models	Hidden Nodes		Training					Testing					Remark
	Layer 1	Layer 2	EI	RMSE	MAD	Max. Abs. Error	EI	RMSE	MAD	Max. Abs. Error			
			(%)	( $m^3/s$ )	( $m^3/s$ )	( $m^3/s$ )	(%)	( $m^3/s$ )	( $m^3/s$ )	( $m^3/s$ )			
1	5	-	99.09	18.93	11.20	539.48	99.12	15.94	10.50	118.52	***** Selected*****		
2	11	-	98.95	20.30	11.51	672.53	99.07	16.34	10.36	120.37			
3	22	-	99.06	19.20	11.31	529.65	99.12	15.97	10.31	118.62			
4	3	2	99.27	16.98	10.70	302.82	99.24	14.82	9.48	116.39			
5	6	5	99.31	16.46	10.53	219.17	99.23	14.90	9.62	120.73			
6	11	11	99.05	19.34	12.42	490.91	99.08	16.29	11.09	111.14			

ภาคผนวก ค2: แบบจำลองการพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้ามากกว่า 1 วัน ในฤดูฝน

ตาราง ค2-1 การคัดเลือกโครงข่ายที่เหมาะสมสำหรับแบบจำลองการพยากรณ์  $Q_{t+2}$  ณ สถานี 150401

1. Direct Step Input Variables :  $Q_{1,t}, R_{1,t}, R_{1,t-1}$  (3 Nodes)

Models	Hidden Nodes		Training				Testing				Remark
	Layer 1	Layer 2	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	
1	1	-	64.10	21.49	9.71	479.70	52.76	19.10	9.64	152.41	***** Selected*****
2	3	-	66.67	20.71	9.21	474.08	53.16	19.02	9.08	151.07	
3	6	-	66.66	20.65	9.19	473.87	53.23	19.01	9.07	151.07	
4	2	1	66.65	20.72	9.19	468.43	52.72	19.11	8.85	151.12	
5	3	3	66.84	20.66	9.18	474.05	53.35	18.98	9.06	150.74	

2. Standard Step Input Variables :  $FQ_{1,t}, R_{1,t}$  (2 Nodes)

Models	Hidden Nodes		Training				Testing				Remark
	Layer 1	Layer 2	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	
1	1	-	66.22	20.85	9.22	479.75	53.84	18.88	9.14	151.72	***** Selected*****
2	2	-	66.89	20.64	9.14	474.51	53.54	18.94	9.00	150.97	
3	4	-	66.88	20.64	9.12	474.83	53.47	18.96	8.99	151.01	
4	1	1	66.17	20.86	9.22	479.46	53.82	18.88	9.14	151.81	
5	2	2	66.88	20.65	9.12	474.17	53.37	18.98	8.98	150.96	

ตาราง ค2-2 การคัดเลือกโครงข่ายภายในที่เหมาะสมสำหรับแบบจำลองการพยากรณ์  $Q_{t+2}$  ณ สถานี KGT.15A

1.Direct Step Input Variables :  $Q_3, Q_{3+1}, R_3, R_{3+1}$  (4 Nodes)

Models	Hidden Nodes		Training				Testing				Remark
	Layer 1	Layer 2	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	
1	2	-	52.38	20.20	9.51	403.37	51.04	21.59	10.71	204.45	***** Selected*****
2	4	-	52.31	20.21	9.55	402.73	50.69	21.67	10.75	204.30	
3	8	-	52.45	20.18	9.50	401.35	50.91	21.62	10.69	204.40	
4	1	1	48.48	21.46	10.24	420.44	44.52	22.98	11.50	203.36	
5	2	2	52.50	20.17	9.59	398.44	51.21	21.55	10.56	204.84	
6	4	4	52.43	20.19	9.48	401.51	51.35	21.52	10.63	204.49	

2.Standard Step Input Variables :  $FQ_{3+1}, Q_3, R_3$  (3 Nodes)

Models	Hidden Nodes		Training				Testing				Remark
	Layer 1	Layer 2	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	
1	1	-	51.69	20.78	10.04	414.69	48.88	22.06	10.94	202.94	***** Selected*****
2	3	-	53.55	20.38	9.62	406.97	51.34	21.52	10.57	204.00	
3	6	-	53.35	20.42	9.68	408.13	51.18	21.56	10.62	203.80	
4	2	1	53.45	20.40	9.62	405.70	50.91	21.62	10.60	204.12	
5	3	3	53.52	20.39	9.63	407.50	51.66	21.46	10.93	203.33	

ตาราง ๓2-3 การคัดเลือกโครงข่ายภายในที่เหมาะสมสำหรับแบบจำลองการพยากรณ์  $Q_{t+2}$  ณ สถานี KGT.12

1. Direct Step      Input Variables :       $Q_4, Q_{t-1}, R_4, R_{t-1}, R_{4,t-2}, R_{4,t-3}, R_{4,t-4}, R_4$       (6 Nodes)

Models	Hidden Nodes		Training					Testing					Remark
	Layer 1	Layer 2	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )			
1	4	-	94.89	10.57	6.16	159.30	92.84	9.49	5.60	56.58			
2	8	-	94.91	10.55	6.21	152.96	93.17	9.27	5.55	53.68			
3	16	-	94.76	10.71	6.37	170.63	92.92	9.44	5.74	54.74			
4	2	2	94.62	10.84	6.09	173.64	92.82	9.51	5.52	58.33			
5	4	4	95.18	10.27	5.72	154.44	93.52	9.03	5.16	55.83		***** Selected*****	
6	8	8	94.86	10.60	6.05	161.39	92.95	9.42	5.40	57.33			

2. Standard Step      Input Variables :       $FQ_{t+1}, Q_4, R_4, R_{t-1}, R_{4,t-2}, R_{4,t-3}, R_{4,t-4}$       (7 Nodes)

Models	Hidden Nodes		Training					Testing					Remark
	Layer 1	Layer 2	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )			
1	3	-	94.98	10.48	6.13	156.55	93.00	9.39	5.67	54.37			
2	7	-	95.07	10.38	6.00	156.93	93.22	9.23	5.45	52.60			
3	14	-	95.11	10.34	5.94	154.16	93.25	9.22	5.43	52.87			
4	2	1	94.74	10.73	5.86	162.02	93.19	9.25	5.26	55.05			
5	4	3	95.20	10.24	5.74	143.55	93.79	8.84	4.99	54.23		***** Selected*****	
6	7	7	92.40	12.89	9.72	168.56	87.57	12.50	9.17	66.55			



ตาราง ๒2-4 การคัดเลือกโครงข่ายภายในที่เหมาะสมสำหรับจำลองการพยากรณ์  $Q_{t+3}$  ณ สถานี KGT.12

1.Direct Step      Input Variables :       $Q_{t-1}, Q_{t-2}, Q_{t-3}, R_{4,t-1}, R_{4,t-2}, R_{4,t-3}, R_{4,t-4}, R_{4,t-5}, R_{4,t-6}$  (8 Nodes)

Models	Hidden Nodes		Training					Testing					Remark
			Layer 1	Layer 2	EI	RMSE	MAD	Max. Abs. Error	EI	RMSE	MAD	Max. Abs. Error	
	(%)	( $m^3/s$ )			( $m^3/s$ )	( $m^3/s$ )	(%)	( $m^3/s$ )	( $m^3/s$ )	( $m^3/s$ )			
1	8	-	89.75	14.97	8.73	174.66	85.84	13.35	7.69	87.08	***** Selected*****		
2	4	4	89.68	15.02	8.77	181.67	85.75	13.39	7.76	87.31			

2.Standard Step      Input Variables :       $FO_{t+2}, FO_{t+1}, R_{4,t-1}, R_{4,t-2}, R_{4,t-3}$  (6 Nodes)

Models	Hidden Nodes		Training					Testing					Remark
			Layer 1	Layer 2	EI	RMSE	MAD	Max. Abs. Error	EI	RMSE	MAD	Max. Abs. Error	
	(%)	( $m^3/s$ )			( $m^3/s$ )	( $m^3/s$ )	(%)	( $m^3/s$ )	( $m^3/s$ )	( $m^3/s$ )			
1	6	-	92.82	12.53	7.05	174.36	89.74	11.36	6.33	71.67	***** Selected*****		
2	3	3	93.01	12.36	6.63	165.99	90.38	11.00	5.89	72.44			

ตาราง ค2-5 การคัดเลือกโครงข่ายประสาทเทียมที่เหมาะสมสำหรับแบบจำลองการพยากรณ์  $Q_{i,t+4}$  ณ สถานี KGT.12

1.Direct Step Input Variables :  $Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}, R_{t-1}, R_{t-2}, R_{t-3}, R_{t-4}, R_{t-5}$  (8 Nodes)

Models	Hidden Nodes		Training					Testing					Remark
	Layer 1	Layer 2	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)			
1	8	-	84.06	18.67	10.73	202.13	78.85	16.31	9.35	96.70	***** Selected*****		
2	4	4	83.13	19.20	11.18	202.45	78.27	16.53	9.67	99.50			

2.Standard Step Input Variables :  $FQ_{t-3}, FQ_{t-2}, R_{t-1}, R_{t-2}, R_{t-3}, R_{t-4}, R_{t-5}$  (5 Nodes)

Models	Hidden Nodes		Training					Testing					Remark
	Layer 1	Layer 2	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)			
1	5	-	88.59	15.79	8.93	186.12	84.27	14.06	7.80	83.97	***** Selected*****		
2	3	2	88.55	15.82	8.82	186.74	83.91	14.22	7.95	85.74			

Note:  $FQ_{t-3}, FQ_{t-2}$  Use from ANN+MA(2)

ตาราง 2-6 การคัดเลือกโครงข่ายภายในที่เหมาะสมสำหรับแบบจำลองการพยากรณ์  $Q_{t+5}$  ณ สถานี KGT.12

1. Direct Step      Input Variables :       $Q_{t-1}, Q_{t-2}, R_{t-1}, R_{t-2}, R_{t-3}, R_{t-4}, R_{t-5}$  (8 Nodes)

Models	Hidden Nodes		Training				Testing				Remark
	Layer 1	Layer 2	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	
	1	8	-	76.68	22.48	14.43	205.39	69.76	19.50	11.61	
2	4	4	76.74	22.55	13.00	211.22	71.35	18.98	11.87	100.17	

2. Standard Step      Input Variables :       $FQ_{t+4}, FQ_{t+3}, R_{t-1}, R_{t-2}$  (4 Nodes)

Models	Hidden Nodes		Training				Testing				Remark
	Layer 1	Layer 2	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	
	1	4	-	84.08	18.65	10.73	229.74	77.73	16.74	9.73	
2	2	2	84.13	18.63	10.61	226.98	77.86	16.69	9.58	138.06	

Note:  $FQ_{t+4}, FQ_{t+3}$  Use from ANN+MA(2)

ตาราง ค2-7 การคัดเลือกโครงข่ายภายในที่เหมาะสมสำหรับแบบจำลองการพยากรณ์  $Q_{t+6}$  ณ สถานี KGT.12

1.Direct Step Input Variables :  $Q_{4,t}, Q_{4,t+1}, R_{4,t}, R_{4,t+1}, R_{4,t+2}, R_{4,t+3}, R_{4,t+4}, R_{4,t+5}$  (8 Nodes)

Models	Hidden Nodes		Training					Testing					Remark
	Layer 1	Layer 2	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)			
1	8	-	68.78	26.13	15.57	310.15	64.28	21.19	13.40	90.07	***** Selected*****		
2	4	4	69.32	25.90	15.19	300.94	63.29	21.49	13.51	91.97			

2.Standard Step Input Variables :  $FQ_{4,t+5}, FQ_{4,t+4}, R_{4,t}$  (3 Nodes)

Models	Hidden Nodes		Training					Testing					Remark
	Layer 1	Layer 2	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)			
1	3	-	79.50	21.17	12.33	236.47	71.76	18.85	11.01	186.03	***** Selected*****		
2	2	1	79.49	21.18	12.84	216.83	72.13	18.72	10.67	179.56			

Note:  $FQ_{t+5}$   $FQ_{t+4}$  Use from ANN+MA(2)

ตาราง ป2-8 การคัดเลือกโครงข่ายภายในที่เหมาะสมสำหรับจำลองการพยากรณ์  $Q_{t+2}$  ณ สถานี KGT.10

1.Direct Step Input Variables :  $Q5_t, Q5_{t-1}, R5_t, R5_{t-1}, R5_{t-2}$  (5 Nodes)

Models	Hidden Nodes		Training					Testing					Remark
	Layer 1	Layer 2	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)			
1	2	-	77.18	32.80	17.82	603.60	75.40	24.32	14.16	126.55	***** Selected*****		
2	5	-	77.80	32.77	17.69	550.77	75.31	24.34	14.06	122.62			
3	10	-	77.85	32.74	17.77	540.85	75.44	24.27	14.17	121.23			
4	1	1	75.47	34.45	19.04	645.06	70.93	26.41	15.48	129.36			
5	3	2	77.79	32.81	17.71	590.97	75.53	24.23	13.72	126.68			
6	5	5	77.73	32.83	17.75	591.47	75.63	24.18	13.64	127.66			

2.Standard Step Input Variables :  $FQ5_{t+1}, Q5_t, R5_t, R5_{t-1}$  (4 Nodes)

Models	Hidden Nodes		Training					Testing					Remark
	Layer 1	Layer 2	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)			
1	2	-	78.21	32.47	17.29	568.82	75.35	24.32	13.67	126.52	***** Selected*****		
2	4	-	78.36	32.36	17.15	566.82	75.52	24.23	13.55	126.08			
3	8	-	78.20	32.48	17.30	569.38	75.49	24.25	13.67	125.43			
4	1	1	76.94	33.40	18.15	625.88	71.98	25.93	14.91	133.90			
5	2	2	78.29	32.41	17.24	566.91	75.32	24.33	13.66	127.41			
6	4	4	78.26	32.43	17.29	569.07	75.23	24.38	13.71	127.61			

ตาราง ๑2-9 การคัดเลือกโครงข่ายภายในที่เหมาะสมสำหรับแบบจำลองการพยากรณ์  $Q_{t+3}$  ณ สถานี KGT.10

1. Direct Step Input Variables :  $Q_{5t}, Q_{5t-1}, R_{5t}, R_{5t-1}, R_{5t-2}$  (5 Nodes)

Models	Hidden Nodes		Training					Testing					Remark
	Layer 1	Layer 2	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)			
			1	5	-	39.78	21.88	611.18	63.49	29.59	16.80	156.70	
2	3	2	66.51	40.25	630.27	62.65	29.93	16.23	160.07				

2. Standard Step Input Variables :  $FQ_{5t+2}, FQ_{5t+1}, R_{5t}$  (3 Nodes)

Models	Hidden Nodes		Training					Testing					Remark
	Layer 1	Layer 2	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)			
			1	3	-	36.41	20.00	601.76	70.66	26.53	15.62	128.41	
2	2	1	72.39	36.55	625.85	70.15	26.76	15.85	129.13				

Note:  $FQ_{t+2}$  Use from ANN+MA(2)

ตาราง ค2-10 การคัดเลือกโครงข่ายภายในที่เหมาะสมสำหรับแบบจำลองการพยากรณ์  $Q_{t+2}$  ณ สถานี KGT.3

1. Direct Step      Input Variables :       $Q_6, Q_{6-1}, Q_1, Q_2, Q_3, Q_4, Q_5, R_6, R_{6-1}, R_{6-2}, R_{6-3}$       (11 Nodes)

Models	Hidden Nodes		Training					Testing					Remark
	Layer 1	Layer 2	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )			
1	5	-	96.42	37.53	27.84	427.74	95.09	37.65	27.88	224.33			
2	11	-	97.26	32.81	21.01	420.62	96.94	29.73	19.30	203.39			
3	22	-	97.36	32.19	20.92	342.15	96.96	29.59	19.39	201.62			
4	3	2	97.53	31.17	20.24	249.26	97.02	29.30	18.54	209.29			
5	6	5	97.55	31.05	19.84	376.37	96.96	29.61	18.59	198.91		***** Selected*****	
6	11	11	97.31	32.55	20.56	493.20	96.97	29.58	18.91	206.10			

2. Standard Step      Input Variables :       $FQ_{6,t+1}, FQ_{1,t+1}, FQ_{2,t+1}, FQ_{3,t+1}, FQ_{4,t+1}, FQ_{5,t+1}, Q_{6t}, R_{6t}, R_{6,t-1}, R_{6,t-2}$       (10 Nodes)

Models	Hidden Nodes		Training					Testing					Remark
	Layer 1	Layer 2	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )			
1	5	-	97.61	30.68	19.74	446.94	97.03	29.28	18.60	246.64			
2	10	-	97.49	31.42	19.84	551.50	97.13	28.77	18.26	200.04			
3	20	-	97.38	32.08	20.18	594.10	97.13	28.76	18.28	186.00			
4	3	2	97.36	32.24	21.57	363.71	97.15	28.66	18.99	178.34			
5	5	5	97.79	29.48	19.22	212.50	97.29	27.97	17.56	187.25		***** Selected*****	
6	10	10	97.58	30.82	19.78	414.31	97.21	28.35	17.97	190.94			

ตาราง K2-11 การคัดเลือกข่ายภายในที่เหมาะสมสำหรับจำลองการพยากรณ์  $Q_{t+3}$  ณ สถานี KGT.3

1.Direct Step Input Variables :  $Q_6, Q_{6,t}, Q_{1,t}, Q_{2,t}, Q_{3,t}, Q_{4,t}, Q_{5,t}, R_{6,t}, R_{6,t-1}, R_{6,t-2}, R_{6,t-3}$  (11 Nodes)

Models	Hidden Nodes		Training				Testing				Remark
			Layer 1	Layer 2	Efficiency Index (EI)	Standard Error ( $m^3/s$ )	Mean Absolu Error ( $m^3/s$ )	Max. Error ( $m^3/s$ )	Efficiency Index (EI)	Standard Error ( $m^3/s$ )	
	1	11			-	93.05	52.26	32.83	1054.56	92.23	
2	6	5	93.60	50.17	30.32	1028.10	92.41	46.78	28.53	354.11	

2.Standard Step

Input Variables 1 :  $FQ_{6,t-2}, FQ_{6,t-1}, FQ_{4,t-2}, FQ_{5,t-2}, R_{6,t}, R_{6,t-1}$  (6 Nodes)

Models	Hidden Nodes		Training				Testing				Remark
			Layer 1	Layer 2	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	EI (%)	RMSE ( $m^3/s$ )	
	1	6			-	93.95	44.56	25.79	1060.40	92.69	
2	3	3	93.91	44.72	25.96	1058.35	92.65	42.79	25.17	365.56	

Input Variables 2 :  $FQ_{6,t-2}, FQ_{6,t-1}, FQ_{4,t-2}, FQ_{5,t-2}, R_{6,t}, R_{6,t-1}$  (7 Nodes)

Models	Hidden Nodes		Training				Testing				Remark
			Layer 1	Layer 2	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	EI (%)	RMSE ( $m^3/s$ )	
	1	7			-	94.99	44.36	25.61	1061.47	93.77	
2	4	3	95.01	44.28	25.63	1065.53	93.79	42.33	24.78	365.95	



ตาราง ค2-11 การคัดเลือกโครงข่ายภายในที่เหมาะสมสำหรับแบบจำลองการพยากรณ์  $Q_{t+3}$  ณ สถานี KGT.3 (ต่อ)

Input Variables 3 :  $FQ6_{t+2}, FQ6_{t+1}, FQ1_{t+2}, FQ3_{t+2}, FQ4_{t+2}, FQ5_{t+2}, R6_t, R6_{t-1}$  (8 Nodes)

Models	Hidden Nodes		Training					Testing					Remark
	Layer 1	Layer 2	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )			
1	8	-	94.97	44.49	25.89	1061.90	93.74	42.50	24.76	364.24			
2	4	4	94.99	44.40	25.70	1063.97	93.72	42.57	24.90	365.72			

ตาราง ค2-12 การคัดเลือกโครงข่ายภายในที่เหมาะสมสำหรับแบบจำลองการพยากรณ์  $Q_{t+4}$  ณ สถานี KGT.3

1.Digit, Step Input Variables :  $Q6_t, Q6_{t-1}, Q1_t, Q2_t, Q3_t, Q4_t, Q5_t, R6_t, R6_{t-1}, R6_{t-2}, R6_{t-3}$  (11 Nodes)

Models	Hidden Nodes		Training					Testing					Remark
	Layer 1	Layer 2	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )			
1	11	-	88.36	67.66	41.13	1396.81	87.10	61.00	38.62	358.35			
2	6	5	88.51	67.22	40.12	1404.29	86.95	61.36	38.36	353.34			

2.Standard Step Input Variables :  $FQ6_{t+3}, FQ6_{t+2}, FQ4_{t+3}, FQ5_{t+3}, R6_t$  (5 Nodes)

Models	Hidden Nodes		Training					Testing					Remark
	Layer 1	Layer 2	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )			
1	5	-	91.03	59.39	35.14	1348.61	89.36	55.39	32.66	359.04			
2	3	2	90.92	59.74	34.57	1362.64	89.00	56.33	33.22	360.90			

\*\*\*\*\* Selected\*\*\*\*\*

ตาราง ๒-13 การคัดเลือกโครงข่ายประสาทที่เหมาะสมสำหรับแบบจำลองการพยากรณ์  $Q_{t+5}$  ณ สถานี KGT.3

1. Direct Step      Input Variables :       $Q6_t, Q6_{t-1}, Q1_t, Q2_t, Q3_t, Q4_t, Q5_t, R6_t, R6_{t-1}, R6_{t-2}, R6_{t-3}$       (11 Nodes)

Models	Hidden Nodes		Training					Testing					Remark
	Layer 1	Layer 2	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )			
	1	11	-	82.70	82.48	50.27	1378.95	81.98	72.09	46.30	405.07		
2	6	5	82.93	81.92	49.43	1398.15	81.75	72.55	46.08	404.74	***** Selected*****		

2. Standard Step      Input Variables :       $FQ6_{t+3}, FQ6_{t+3}, FQ4_{t+4}$       (3 Nodes)

Models	Hidden Nodes		Training					Testing					Remark
	Layer 1	Layer 2	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )			
	1	3	-	87.81	69.21	42.15	1347.89	86.53	62.34	39.49	376.31		
2	2	1	87.75	69.39	42.77	1347.27	86.47	62.47	39.25	378.84	***** Selected*****		

Note:  $FQ_{t+4}, FQ_{t-3}, FQ_{t+4}$  Use from ANN+MR(2)

ตาราง ๒2-14 การคัดเลือกโครงข่ายภายในที่เหมาะสมสำหรับแบบจำลองการพยากรณ์  $Q_{t-6}$  ณ สถานี KG7.3

1.Direct Step      Input Variables :       $Q6, Q6_{t-1}, Q1, Q2, Q3, Q4, Q5, R6, R6_{t-1}, R6_{t-2}, R6_{t-3}$       (11 Nodes)

Models	Hidden Nodes		Training					Testing					Remark
			Layer 1	Layer 2	EI	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	EI	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	
1	11	-	76.84	95.41	59.04	1457.70	77.11	81.25	53.57	465.51			
2	6	5	77.13	94.83	57.70	1489.98	76.91	81.61	54.19	461.64	***** Selected*****		

2.Standard Step      Input Variables :       $FQ6_{t-5}, FQ6_{t-4}, FQ4_{t-5}$       (3 Nodes)

Models	Hidden Nodes		Training					Testing					Remark
			Layer 1	Layer 2	EI	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	EI	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	
1	3	-	84.82	77.25	48.71	1284.75	83.02	69.97	45.91	387.84			
2	2	1	84.53	77.99	50.06	1282.17	82.75	70.53	47.55	397.90	***** Selected*****		

Note:       $FQ1_{t-6}, FQ1_{t-1}, FQ4_{t-6}$  Use from ANN+MR(2)

ตาราง ๒-14 การคัดเลือกโครงข่ายภายในที่เหมาะสมสำหรับแบบจำลองการพยากรณ์  $Q_{t-7}$  ณ สถานี KGT.3

1. Direct Step      Input Variables :       $Q_6, Q_{6-1}, Q_1, Q_2, Q_3, Q_4, Q_5, R_6, R_{6-1}, R_6, R_{6-2}, R_{6-3}$       (11 Nodes)

Models	Hidden Nodes		Training					Testing					Remark
			Layer 1	Layer 2	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	
1	11	-	71.01	106.76	67.14	1439.53	72.75	88.65	59.68	490.48			
2	6	5	71.15	106.51	70.11	1444.86	71.89	90.14	59.63	501.27	***** Selected*****		

2. Standard Step      Input Variables :       $FQ_{6,t+6}, FQ_{6,t+5}, FQ_{4,t+6}$       (3 Nodes)

Models	Hidden Nodes		Training					Testing					Remark
			Layer 1	Layer 2	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	
1	3	-	82.12	83.84	54.17	1397.21	79.61	76.88	50.62	511.34			
2	2	1	82.10	83.89	54.20	1394.84	79.64	76.62	50.53	512.28	***** Selected*****		

Note:  $FQ_{t+6}, FQ_{t+5}$  Use from ANN+MA(2),  $FQ_{4,t+6}$  Use from ANN+AR(2)

ภาคผนวก ค3: แบบจำลองการพยากรณ์อัตราการไหลน้ำท่ารายวันล่วงหน้า 1 วัน ในฤดูแล้ง

ตาราง ค3-1 การคัดเลือกโครงข่ายที่เหมาะสมสำหรับแบบจำลองการพยากรณ์  $Q_{t+1}$  ณ สถานี 150401

Input Variables :  $Q_{t1}$  (1 Nodes)

Models	Hidden Nodes		Training				Testing				Remark
	Layer 1	Layer 2	EI	RMSE	MAD	Max. Abs. Error	EI	RMSE	MAD	Max. Abs. Error	
			(%)	( $m^3/s$ )	( $m^3/s$ )	( $m^3/s$ )	(%)	( $m^3/s$ )	( $m^3/s$ )	( $m^3/s$ )	
1	1	-	96.16	0.222	0.073	6.14	98.42	0.106	0.071	0.63	***** Selected*****
2	2	-	96.33	0.217	0.063	6.14	98.68	0.097	0.060	0.65	

ตาราง ค3-2 การคัดเลือกโครงข่ายที่เหมาะสมสำหรับแบบจำลองการพยากรณ์  $Q_{t+1}$  ณ สถานี KGT.14

Input Variables :  $Q_{t2}$  (1 Nodes)

Models	Hidden Nodes		Training				Testing				Remark
	Layer 1	Layer 2	EI	RMSE	MAD	Max. Abs. Error	EI	RMSE	MAD	Max. Abs. Error	
			(%)	( $m^3/s$ )	( $m^3/s$ )	( $m^3/s$ )	(%)	( $m^3/s$ )	( $m^3/s$ )	( $m^3/s$ )	
1	1	-	83.68	0.125	0.032	3.43	81.53	0.068	0.022	1.20	***** Selected*****
2	2	-	83.77	0.124	0.032	3.43	81.52	0.068	0.021	1.20	

ตาราง ค3-3 การคัดเลือกโครงข่ายภายในที่เหมาะสมสำหรับแบบจำลองการพยากรณ์  $Q_{t+1}$  ณ สถานี KGT.15A

Input Variables :  $Q_3$  (1 Nodes)

Models	Hidden Nodes		Training				Testing				Remark
	Layer 1	Layer 2	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	
1	1	-	91.95	0.304	0.105	6.75	86.43	0.126	0.058	1.49	***** Selected*****
2	2	-	92.26	0.298	0.088	6.84	87.52	0.120	0.052	1.44	

ตาราง ค3-4 การคัดเลือกโครงข่ายภายในที่เหมาะสมสำหรับแบบจำลองการพยากรณ์  $Q_{t+1}$  ณ สถานี KGT.12

Input Variables :  $Q_4$  (1 Nodes)

Models	Hidden Nodes		Training				Testing				Remark
	Layer 1	Layer 2	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	
1	1	-	95.05	0.398	0.176	9.17	95.95	0.212	0.182	1.56	***** Selected*****
2	2	-	96.21	0.348	0.104	8.91	98.63	0.124	0.064	1.26	

ตาราง ค3-5 การคัดเลือกโครงข่ายภายใต้ที่เหมาะสมสำหรับจำลองการพยากรณ์  $Q_{t+1}$  ณ สถานี KGT.10

Input Variables :  $Q5_t, Q5_{t-1}, R5_t, R5_{t-1}, R5_{t-2}$  (5 Nodes)

Models	Hidden Nodes		Training					Testing					Remark
			EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )			
	Layer 1	Layer 2											
1	2	-	84.05	0.781	0.264	14.33	87.76	0.470	0.220	3.41	***** Selected*****		
2	5	-	84.35	0.761	0.254	14.23	87.96	0.450	0.200	3.38			
3	10	-	84.34	0.761	0.250	14.23	87.86	0.460	0.214	3.39			
4	3	2	86.07	0.718	0.245	10.41	87.98	0.450	0.196	3.37			
5	5	5	86.01	0.717	0.244	10.41	87.95	0.451	0.199	3.39			

ตาราง ค3-6 การคัดเลือกโครงข่ายภายใต้ที่เหมาะสมสำหรับจำลองการพยากรณ์  $Q_{t+1}$  ณ สถานี KGT.3

Input Variables :  $Q_{t+1}, Q1_t, Q2_t, Q3_t, Q4_t, Q5_t$  (7 Nodes)

Models	Hidden Nodes		Training					Testing					Remark
			EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )			
	Layer 1	Layer 2											
1	3	-	97.28	1.337	0.497	34.72	98.21	0.945	0.400	12.70	***** Selected*****		
2	7	-	97.79	1.303	0.459	33.75	98.48	0.897	0.380	12.02			
3	14	-	97.82	1.300	0.458	33.67	97.98	1.018	0.420	13.32			
4	2	1	97.27	1.337	0.500	37.20	98.24	0.937	0.413	12.50			
5	4	3	98.01	1.291	0.448	35.11	98.55	0.883	0.397	12.17			
6	7	7	97.95	1.295	0.453	35.40	98.38	0.916	0.405	12.32			

ภาคผนวก ค4: แบบจำลองการพยากรณ์อัตราการใช้พลังงานสำหรับวันล่วงหน้ามากกว่า 1 วัน ในฤดูแล้ง

ตาราง ค4-1 การคัดเลือกโครงข่ายภายในที่เหมาะสมสำหรับแบบจำลองการพยากรณ์  $Q_{1,2}$  ณ สถานี 150401

1.Direct Step      Input Variables :       $Q_1$       (1 Nodes)

Models	Hidden Nodes		Training					Testing					Remark
	Layer 1	Layer 2	EI	RMSE	MAD	Max. Abs. Error	EI	RMSE	MAD	Max. Abs. Error			
			(%)	(m <sup>3</sup> /s)	(m <sup>3</sup> /s)	(m <sup>3</sup> /s)	(%)	(m <sup>3</sup> /s)	(m <sup>3</sup> /s)	(m <sup>3</sup> /s)			
1	1	-	93.71	0.272	0.103	6.35	96.30	0.153	0.103	0.94	***** Selected*****		
2	2	-	93.88	0.269	0.095	6.36	96.68	0.144	0.094	0.86			

2.Standard Step      Input Variables :       $FQ_{1,1}$       (1 Nodes)

Models	Hidden Nodes		Training					Testing					Remark
	Layer 1	Layer 2	EI	RMSE	MAD	Max. Abs. Error	EI	RMSE	MAD	Max. Abs. Error			
			(%)	(m <sup>3</sup> /s)	(m <sup>3</sup> /s)	(m <sup>3</sup> /s)	(%)	(m <sup>3</sup> /s)	(m <sup>3</sup> /s)	(m <sup>3</sup> /s)			
1	1	-	93.91	0.268	0.094	6.35	96.71	0.144	0.091	0.89	***** Selected*****		
2	2	-	93.94	0.267	0.092	6.35	96.79	0.142	0.089	0.87			

ตาราง ค4-2 การคัดเลือกโครงข่ายภายในที่เหมาะสมสำหรับแบบจำลองการพยากรณ์  $Q_{1,3}$  ณ สถานี 150401

1.Direct Step      Input Variables :       $Q_1$       (1 Nodes)

Models	Hidden Nodes		Training					Testing					Remark
	Layer 1	Layer 2	EI	RMSE	MAD	Max. Abs. Error	EI	RMSE	MAD	Max. Abs. Error			
			(%)	(m <sup>3</sup> /s)	(m <sup>3</sup> /s)	(m <sup>3</sup> /s)	(%)	(m <sup>3</sup> /s)	(m <sup>3</sup> /s)	(m <sup>3</sup> /s)			
1	1	-	91.99	0.296	0.112	6.26	94.58	0.174	0.110	1.02	***** Selected*****		
2	2	-	92.03	0.296	0.110	6.26	94.68	0.172	0.107	1.00			



2.Standard Step Input Variables : FQ1,3 (1 Nodes)

Models	Hidden Nodes		Training				Testing				Remark
	Layer 1	Layer 2	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	
1	1	-	92.94	0.278	0.112	6.33	95.50	0.158	0.110	1.11	***** Selected*****
2	2	-	93.27	0.271	0.099	6.34	96.19	0.146	0.095	1.01	

ตาราง ค4-3 การคัดเลือกโครงข่ายประสาทเทียมที่เหมาะสมสำหรับแบบจำลองการพยากรณ์ Q<sub>t-4</sub> ณ สถานี 150401

1.Direct Step Input Variables : Q1 (1 Nodes)

Models	Hidden Nodes		Training				Testing				Remark
	Layer 1	Layer 2	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	
1	1	-	90.39	0.312	0.126	6.22	92.38	0.195	0.124	1.26	***** Selected*****
2	2	-	90.40	0.312	0.125	6.22	92.47	0.194	0.122	1.24	

2.Standard Step Input Variables : FQ1,3 (1 Nodes)

Models	Hidden Nodes		Training				Testing				Remark
	Layer 1	Layer 2	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	
1	1	-	92.10	0.283	0.116	6.33	94.98	0.159	0.110	1.05	***** Selected*****
2	2	-	92.27	0.280	0.110	6.33	95.32	0.153	0.103	1.00	

ตาราง ค4-4 การคัดเลือกโครงข่ายภายในที่เหมาะสมสำหรับแบบจำลองการพยากรณ์  $Q_{t+6}$  ณ สถานี 150401

1.Direct Step      Input Variables :       $Q_{t1}$       (1 Nodes)

Models	Hidden Nodes		Training					Testing					Remark
	Layer 1	Layer 2	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )			
1	1	-	84.97	0.389	0.152	10.18	89.97	0.213	0.138	1.41			
2	2	-	84.98	0.369	0.151	10.18	90.07	0.212	0.136	1.39	***** Selected*****		

2.Standard Step      Input Variables :       $FQ_{t+4}$       (1 Nodes)

Models	Hidden Nodes		Training					Testing					Remark
	Layer 1	Layer 2	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )			
1	1	-	87.65	0.346	0.126	10.10	94.34	0.160	0.113	1.33			
2	2	-	87.83	0.344	0.119	10.10	94.79	0.153	0.104	1.26	***** Selected*****		

ตาราง ค4-5 การคัดเลือกโครงข่ายภายในที่เหมาะสมสำหรับแบบจำลองการพยากรณ์  $Q_{t+6}$  ณ สถานี 150401

1.Direct Step      Input Variables :       $Q_{t1}$       (1 Nodes)

Models	Hidden Nodes		Training					Testing					Remark
	Layer 1	Layer 2	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )			
1	1	-	80.65	0.411	0.164	10.15	87.43	0.228	0.152	1.53			
2	2	-	80.67	0.410	0.163	10.15	87.53	0.227	0.151	1.51	***** Selected*****		

2.Standard Step Input Variables : FQ1<sub>1+5</sub> (1 Nodes)

Models	Hidden Nodes		Training				Testing				Remark
	Layer 1	Layer 2	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	
1	1	-	84.23	0.38	0.137	10.07	92.77	0.173	0.125	1.38	***** Selected*****
2	2	-	84.46	0.378	0.131	10.07	93.27	0.167	0.116	1.31	

ตาราง ๓4-6 การคัดเลือกโครงข่ายภายในที่เหมาะสมสำหรับแบบจำลองการพยากรณ์ Q<sub>t-7</sub> ณ สถานี 150401

1.Direct Step Input Variables : Q1<sub>t</sub> (1 Nodes)

Models	Hidden Nodes		Training				Testing				Remark
	Layer 1	Layer 2	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	
1	1	-	77.45	0.431	0.175	10.32	84.73	0.244	0.163	1.34	***** Selected*****
2	2	-	77.46	0.431	0.174	10.32	84.83	0.243	0.161	1.31	

2.Standard Step Input Variables : FQ1<sub>1+6</sub> (1 Nodes)

Models	Hidden Nodes		Training				Testing				Remark
	Layer 1	Layer 2	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	
1	1	-	82.26	0.392	0.137	10.09	92.33	0.172	0.123	1.04	***** Selected*****
2	2	-	82.28	0.391	0.136	10.09	92.42	0.171	0.122	1.02	

ตาราง ค4-7 การคัดเลือกโครงข่ายภายในที่เหมาะสมสำหรับจำลองการพยากรณ์  $Q_{t+2}$  ณ สถานี KGT.14

1.Direct.Step      Input Variables :       $Q_{t-1}$       (1 Nodes)

Models	Hidden Nodes		Training				Testing				Remark
	Layer 1	Layer 2	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	
	1	1	-	78.00	0.146	0.048	3.40	67.90	0.090	0.034	
2	2	-	78.07	0.143	0.048	3.40	67.91	0.090	0.033	1.19	

\*\*\*\*\* Selected\*\*\*\*\*

2.Standard Step      Input Variables :       $FC2_{t+1}$       (1 Nodes)

Models	Hidden Nodes		Training				Testing				Remark
	Layer 1	Layer 2	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	
	1	1	-	78.08	0.143	0.049	3.40	67.90	0.090	0.037	
2	2	-	78.37	0.139	0.049	3.40	67.97	0.090	0.035	1.19	

\*\*\*\*\* Selected\*\*\*\*\*

ตาราง ค4-8 การคัดเลือกโครงข่ายภายในที่เหมาะสมสำหรับจำลองการพยากรณ์  $Q_{t+2}$  ณ สถานี KGT.15A

1.Direct.Step      Input Variables :       $Q_{t-1}$       (1 Nodes)

Models	Hidden Nodes		Training				Testing				Remark
	Layer 1	Layer 2	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	
	1	1	-	85.34	0.396	0.121	9.40	80.20	0.148	0.066	
2	2	-	85.64	0.392	0.110	9.47	80.64	0.146	0.055	1.62	

\*\*\*\*\* Selected\*\*\*\*\*

2.Standard Step Input Variables : FQ3<sub>1+2</sub> (1 Nodes)

Models	Hidden Nodes		Training					Testing					Remark
	Layer 1	Layer 2	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)			
1	1	-	84.45	0.408	0.142	9.23	79.29	0.151	0.076	1.64			
2	2	-	85.77	0.391	0.109	9.46	80.94	0.145	0.055	1.61			

ตาราง ตาราง 4-9 การคัดเลือกโครงข่ายภายในที่เหมาะสมสำหรับแบบจำลองการพยากรณ์ Q<sub>1+3</sub> ณ สถานี KGT.15A

1.Direct Step Input Variables : Q3 (1 Nodes)

Models	Hidden Nodes		Training					Testing					Remark
	Layer 1	Layer 2	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)			
1	1	-	80.19	0.446	0.129	10.11	77.67	0.153	0.086	1.51			
2	2	-	80.45	0.443	0.122	10.14	78.02	0.152	0.060	1.53			

2.Standard Step Input Variables : FQ3<sub>1+2</sub> (1 Nodes)

Models	Hidden Nodes		Training					Testing					Remark
	Layer 1	Layer 2	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)			
1	1	-	83.96	0.401	0.139	9.83	79.51	0.147	0.073	1.43			
2	2	-	84.03	0.400	0.137	9.84	79.69	0.146	0.071	1.43			

ตาราง ๓4-10 การคัดเลือกโครงข่ายภายในที่เหมาะสมสำหรับจำลองการพยากรณ์  $Q_{t+4}$  ณ สถานี KGT.15A

1.Direct Step      Input Variables :       $Q_3$       ( 1 Nodes)

Models	Hidden Nodes		Training				Testing				Remark
	Layer 1	Layer 2	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	
1	1	-	76.17	0.474	0.138	9.81	74.31	0.159	0.064	1.52	***** Selected*****
2	2	-	76.18	0.474	0.138	9.81	74.36	0.159	0.064	1.52	

2.Standard Step      Input Variables :       $FG3_{t+3}$       ( 1 Nodes)

Models	Hidden Nodes		Training				Testing				Remark
	Layer 1	Layer 2	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	
1	1	-	81.68	0.417	0.152	7.99	76.42	0.154	0.080	1.75	***** Selected*****
2	2	-	81.76	0.415	0.149	7.99	76.64	0.153	0.078	1.75	

ตาราง ๓4-11 การคัดเลือกโครงข่ายภายในที่เหมาะสมสำหรับจำลองการพยากรณ์  $Q_{t+5}$  ณ สถานี KGT.15A

1.Direct Step      Input Variables :       $Q_3$       ( 1 Nodes)

Models	Hidden Nodes		Training				Testing				Remark
	Layer 1	Layer 2	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	
1	1	-	73.75	0.481	0.146	8.53	70.91	0.169	0.070	1.46	***** Selected*****
2	2	-	73.75	0.481	0.145	8.55	70.95	0.168	0.070	1.47	

2.Standard Step Input Variables : FQ3<sub>1+4</sub> (1 Nodes)

Models	Hidden Nodes		Training				Testing				Remark
	Layer 1	Layer 2	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	
	1	1	-	77.86	0.442	0.169	10.73	72.21	0.163	0.092	
2	2	-	77.98	0.441	0.167	13.73	72.48	0.162	0.089	1.68	

ตาราง ๓4-12 การคัดเลือกโครงข่ายภายในที่เหมาะสมสำหรับจำลองการพยากรณ์ Q<sub>u6</sub> ณ สถานี KGT.15A

1.Direct Step Input Variables : Q3<sub>1</sub> (1 Nodes)

Models	Hidden Nodes		Training				Testing				Remark
	Layer 1	Layer 2	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	
	1	1	-	68.45	0.529	0.165	8.32	66.38	0.182	0.077	
2	2	-	68.45	0.529	0.169	8.39	66.47	0.181	0.075	1.92	

2.Standard Step Input Variables : FQ3<sub>1+5</sub> (1 Nodes)

Models	Hidden Nodes		Training				Testing				Remark
	Layer 1	Layer 2	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	
	1	1	-	74.50	0.461	0.180	9.73	69.75	0.166	0.094	
2	2	-	74.57	0.459	0.178	9.76	70.15	0.165	0.092	1.63	

ตาราง ค4-13 การคัดเลือกโครงข่ายภายในที่เหมาะสมสำหรับจำลองการพยากรณ์  $Q_{1,2}$  ณ สถานี KGT.12

1.Direct Step Input Variables :  $Q_4$  (1 Nodes)

Models	Hidden Nodes		Training				Testing				Remark
	Layer 1	Layer 2	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	
	1	1	-	90.59	0.532	0.198	10.00	96.69	0.183	0.094	
2	3	-	90.86	0.523	0.174	10.04	96.73	0.162	0.105	1.54	

2.Standard Step Input Variables :  $FQ_{4,1+2}$  (1 Nodes)

Models	Hidden Nodes		Training				Testing				Remark
	Layer 1	Layer 2	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	
	1	1	-	90.56	0.532	0.186	10.05	96.21	0.196	0.133	
2	2	-	90.90	0.523	0.173	10.03	96.97	0.176	0.102	1.54	

ตาราง ค4-14 การคัดเลือกโครงข่ายภายในที่เหมาะสมสำหรับจำลองการพยากรณ์  $Q_{1,3}$  ณ สถานี KGT.12

1.Direct Step Input Variables :  $Q_4$  (1 Nodes)

Models	Hidden Nodes		Training				Testing				Remark
	Layer 1	Layer 2	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	
	1	1	-	87.50	0.594	0.229	10.29	94.78	0.219	0.143	
2	2	-	87.63	0.591	0.220	10.32	94.95	0.215	0.134	1.49	



2.Standard Step Input Variables : FQ<sub>1,2</sub> (1 Nodes)

Models	Hidden Nodes		Training				Testing				Remark
	Layer 1	Layer 2	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	
	1	1	-	89.74	0.539	0.184	9.96	96.13	0.189	0.118	
2	2	-	89.87	0.535	0.182	9.96	96.54	0.178	0.105	1.49	

ตาราง ๑4-15 การคัดเลือกโครงข่ายภายใต้เฉพาะสมลัพท์รับเป็นจำลองการพยากรณ์ Q<sub>t+4</sub> ณ สถานี KGT.12

1.Direct Step Input Variables : Q<sub>4</sub> (1 Nodes)

Models	Hidden Nodes		Training				Testing				Remark
	Layer 1	Layer 2	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	
	1	1	-	85.08	0.632	0.260	10.31	92.65	0.244	0.161	
2	2	-	85.13	0.631	0.257	10.32	92.93	0.242	0.159	1.49	

2.Standard Step Input Variables : FQ<sub>1,3</sub> (1 Nodes)

Models	hidden Nodes		Training				Testing				Remark
	Layer 1	Layer 2	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	
	1	1	-	87.27	0.584	0.229	10.06	95.06	0.203	0.127	
2	2	-	87.34	0.582	0.222	10.07	95.25	0.199	0.121	1.64	

ตาราง ค4-16 การคัดเลือกโครงข่ายภายในที่เหมาะสมสำหรับแบบจำลองการพยากรณ์  $Q_{t+5}$  ณ สถานี KGT.12

1.Direct Step      Input Variables :     $Q_{t-4}$     (1 Nodes)

Models	Hidden Nodes				Training				Testing				Remark
	Layer 1		Layer 2		EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	
1	1	-	-	-	81.80	0.672	0.286	10.30	90.73	0.262	0.178	1.54	
2	2	-	-	-	81.80	0.671	0.286	10.30	90.74	0.262	0.178	1.54	

\*\*\*\*\* Selected\*\*\*\*\*

2.Standard Step      Input Variables :     $FO_{t+4}$     (1 Nodes)

Models	Hidden Nodes				Training				Testing				Remark
	Layer 1		Layer 2		EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	
1	1	-	-	-	84.81	0.522	0.262	10.14	93.95	0.212	0.140	1.64	
2	2	-	-	-	84.86	0.621	0.259	10.14	94.09	0.209	0.137	1.60	

\*\*\*\*\* Selected\*\*\*\*\*

ตาราง ค4-17 การคัดเลือกโครงข่ายภายในที่เหมาะสมสำหรับแบบจำลองการพยากรณ์  $Q_{t+6}$  ณ สถานี KGT.12

1.Direct Step      Input Variables :     $Q_{t-4}$     (1 Nodes)

Models	Hidden Nodes				Training				Testing				Remark
	Layer 1		Layer 2		EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	
1	1	-	-	-	77.08	0.725	0.331	10.26	84.95	0.311	0.197	1.62	
2	2	-	-	-	77.15	0.724	0.327	10.26	85.18	0.309	0.192	1.61	

\*\*\*\*\* Selected\*\*\*\*\*

2.Standard\_Step Input Variables : FQ<sub>4,1-5</sub> (1 Nodes)

Models	Hidden Nodes		Training				Testing				Remark
	Layer 1	Layer 2	EI	RMSE	MAD	Max. Abs. Error	EI	RMSE	MAD	Max. Abs. Error	
			(%)	(m <sup>3</sup> /s)	(m <sup>3</sup> /s)	(m <sup>3</sup> /s)	(%)	(m <sup>3</sup> /s)	(m <sup>3</sup> /s)	(m <sup>3</sup> /s)	
1	1	-	81.32	0.674	0.296	10.04	92.06	0.228	0.159	1.42	***** Selected*****
2	2	-	81.36	0.673	0.293	10.04	92.22	0.226	0.156	1.38	

ตาราง ค4-18 การคัดเลือกโครงข่ายที่เหมาะสมสำหรับจำลองการพยากรณ์ Q<sub>u,7</sub> ณ สถานี KGT.12

1.Direct\_Step Input Variables : Q<sub>4,1</sub> (1 Nodes)

Models	Hidden Nodes		Training				Testing				Remark
	Layer 1	Layer 2	EI	RMSE	MAD	Max. Abs. Error	EI	RMSE	MAD	Max. Abs. Error	
			(%)	(m <sup>3</sup> /s)	(m <sup>3</sup> /s)	(m <sup>3</sup> /s)	(%)	(m <sup>3</sup> /s)	(m <sup>3</sup> /s)	(m <sup>3</sup> /s)	
1	1	-	72.02	0.760	0.354	10.84	84.92	0.283	0.213	1.45	***** Selected*****
2	2	-	72.93	0.752	0.360	10.82	85.29	0.289	0.208	1.47	

2.Standard\_Step Input Variables : FQ<sub>4,1-5</sub> (1 Nodes)

Models	Hidden Nodes		Training				Testing				Remark
	Layer 1	Layer 2	EI	RMSE	MAD	Max. Abs. Error	EI	RMSE	MAD	Max. Abs. Error	
			(%)	(m <sup>3</sup> /s)	(m <sup>3</sup> /s)	(m <sup>3</sup> /s)	(%)	(m <sup>3</sup> /s)	(m <sup>3</sup> /s)	(m <sup>3</sup> /s)	
1	1	-	77.85	0.718	0.319	10.18	88.89	0.240	0.174	1.37	***** Selected*****
2	2	-	77.92	0.717	0.316	10.19	90.16	0.237	0.170	1.35	

ตาราง ค4-19 การคัดเลือกโครงข่ายภายในที่เหมาะสมสำหรับแบบจำลองการพยากรณ์  $Q_{t+2}$  ณ สถานี KGT.10

1.Direct Step Input Variables :  $Q5_t, Q5_{t-1}, R5_t, R5_{t-1}, R5_{t-2}$  (5 Nodes)

Models	Hidden Nodes		Training					Testing					Remark
	Layer 1	Layer 2	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )			
1	5	-	72.22	1.003	0.389	13.76	74.95	0.825	0.312	3.89	***** Selected*****		
2	3	2	67.22	1.089	0.519	13.69	73.42	0.843	0.394	4.27			

2.Standard Step Input Variables :  $Q5_{t+1}, Q5_t, R5_t, R5_{t-1}$  (4 Nodes)

Models	Hidden Nodes		Training					Testing					Remark
	Layer 1	Layer 2	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )			
1	4	-	72.71	0.994	0.383	13.83	76.04	0.611	0.301	3.81	***** Selected*****		
2	2	2	72.70	0.994	0.381	13.87	75.81	0.614	0.301	3.82			

ตาราง ค4-20 การคัดเลือกโครงข่ายภายในที่เหมาะสมสำหรับแบบจำลองการพยากรณ์  $Q_{t+3}$  ณ สถานี KGT.10

1.Direct Step Input Variables :  $Q5_t, Q5_{t-1}, R5_t, R5_{t-1}, R5_{t-2}$  (5 Nodes)

Models	Hidden Nodes		Training					Testing					Remark
	Layer 1	Layer 2	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )			
1	5	-	63.89	1.129	0.460	15.28	69.44	0.664	0.368	4.16	***** Selected*****		
2	3	2	62.26	1.154	0.525	15.21	67.81	0.682	0.378	4.47			

2.Standard Step      Input Variables :      Q5+2, Q5+1, R5<sub>1</sub>      (3 Nodes)

Models	Hidden Nodes		Training				Testing				Remark
	Layer 1	Layer 2	EI (%)	RMSE (m <sup>2</sup> /s)	MAD (m <sup>2</sup> /s)	Max. Abs. Error (m <sup>2</sup> /s)	EI (%)	RMSE (m <sup>2</sup> /s)	MAD (m <sup>2</sup> /s)	Max. Abs. Error (m <sup>2</sup> /s)	
1	3	-	68.09	1.051	0.411	14.44	72.79	0.627	0.318	4.21	***** Selected*****
2	2	1	65.25	1.108	0.526	14.25	71.35	0.643	0.356	4.08	

ตาราง ค4-21 การคัดเลือกโครงข่ายที่เหมาะสมสำหรับจำลองการพยากรณ์ Q<sub>t+2</sub> ณ สถานี KGT.3

1.Direct Step      Input Variables :      Q6, Q6+1, Q1, Q2, Q3, Q4, Q5<sub>1</sub>      (7 Nodes)

Models	Hidden Nodes		Training				Testing				Remark
	Layer 1	Layer 2	EI (%)	RMSE (m <sup>2</sup> /s)	MAD (m <sup>2</sup> /s)	Max. Abs. Error (m <sup>2</sup> /s)	EI (%)	RMSE (m <sup>2</sup> /s)	MAD (m <sup>2</sup> /s)	Max. Abs. Error (m <sup>2</sup> /s)	
1	7	-	93.58	1.994	0.795	39.76	95.88	1.532	0.887	11.08	***** Selected*****
2	4	3	94.08	1.914	0.744	38.59	95.94	1.508	0.859	11.79	

2.Standard Step      Input Variables :      FQ6+1, Q6, FQ1+1, FQ2+1, FQ3+1, FQ4+1, FQ5+1      (7 Nodes)

Models	Hidden Nodes		Training				Testing				Remark
	Layer 1	Layer 2	EI (%)	RMSE (m <sup>2</sup> /s)	MAD (m <sup>2</sup> /s)	Max. Abs. Error (m <sup>2</sup> /s)	EI (%)	RMSE (m <sup>2</sup> /s)	MAD (m <sup>2</sup> /s)	Max. Abs. Error (m <sup>2</sup> /s)	
1	7	-	94.23	1.894	0.684	39.14	95.97	1.491	0.816	12.92	***** Selected*****
2	4	3	94.64	1.824	0.658	39.07	96.53	1.239	0.732	11.00	

ตาราง ค4-22 การคัดเลือกโครงข่ายภายในที่เหมาะสมสำหรับแบบจำลองการพยากรณ์  $Q_{t+3}$  ณ สถานี KGT.3

1.Direct Step Input Variables :  $Q6_t, Q6_{t-1}, Q1_t, Q2_t, Q3_t, Q4_t, Q5_t$  (7 Nodes)

Models	Hidden Nodes		Training				Testing				Remark
	Layer 1	Layer 2	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	
1	7	-	87.44	2.716	1.173	40.76	93.66	1.632	1.159	13.22	***** Selected*****
2	4	3	69.49	2.495	1.148	40.28	93.57	1.615	1.190	13.01	

2.Standard Step Input Variables :  $FQ6_{t+2}, Q6_{t+1}, FQ1_{t+2}, FQ2_{t+2}, FQ3_{t+2}, FQ4_{t+2}, FQ5_{t+2}$  (7 Nodes)

Models	Hidden Nodes		Training				Testing				Remark
	Layer 1	Layer 2	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	
1	7	-	92.82	2.054	0.883	40.13	94.03	1.563	1.047	13.56	***** Selected*****
2	4	3	93.23	1.994	0.837	39.94	94.14	1.548	1.002	12.93	

ตาราง ค4-23 การคัดเลือกโครงข่ายภายในที่เหมาะสมสำหรับแบบจำลองการพยากรณ์  $Q_{t+4}$  ณ สถานี KGT.3

1.Direct Step Input Variables :  $Q6_t, Q6_{t-1}, Q1_t, Q2_t, Q3_t, Q4_t, Q5_t$  (7 Nodes)

Models	Hidden Nodes		Training				Testing				Remark
	Layer 1	Layer 2	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	
1	7	-	86.80	2.724	1.209	41.49	91.52	1.884	1.389	14.84	***** Selected*****
2	4	3	86.82	2.722	1.181	41.05	91.32	1.847	1.391	14.04	

2.Standard\_Step Input Variables :  $Q6_{t+3}, Q6_{t+2}, Q6_{t+1}, Q6_t, Q3_{t+3}, Q3_{t+2}, Q3_{t+1}, Q3_t, Q4_{t+3}, Q4_{t+2}, Q4_{t+1}, Q4_t, Q5_t$  (5 Nodes)

Models	Hidden Nodes				Training					Testing					Remark
	Layer 1		Layer 2		EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)			
1	6	-			90.02	2.354	1.126	40.95	92.51	1.716	1.239	13.84			
2	3	3			91.02	2.239	0.986	40.24	93.24	1.678	1.185	13.61			

ตาราง ๓4-24 การคัดเลือกโครงข่ายภายในที่เหมาะสมสำหรับแบบจำลองการพยากรณ์  $Q_{t+5}$  ณ สถานี KGT.3

1.Direct\_Step Input Variables :  $Q6_t, Q6_{t+1}, Q1_t, Q2_t, Q3_t, Q4_t, Q5_t$  (7 Nodes)

Models	Hidden Nodes				Training					Testing					Remark
	Layer 1		Layer 2		EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)			
1	7	-			81.07	3.209	1.388	45.16	88.16	2.147	1.526	17.35			
2	4	3			81.78	3.136	1.358	44.62	88.64	2.092	1.489	17.10			

2.Standard\_Step Input Variables :  $Q6_{t+4}, Q6_{t+3}, Q6_{t+2}, Q6_{t+1}, Q6_t, Q3_{t+4}, Q3_{t+3}, Q3_{t+2}, Q3_{t+1}, Q3_t, Q4_{t+4}, Q4_{t+3}, Q4_{t+2}, Q4_{t+1}, Q4_t, Q5_t$  (5 Nodes)

Models	Hidden Nodes				Training					Testing					Remark
	Layer 1		Layer 2		EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)			
1	5	-			88.13	2.527	1.226	41.91	91.42	1.795	1.318	14.84			
2	3	2			88.53	2.469	1.181	41.61	91.71	1.817	1.280	14.01			

ตาราง ๓4-25 การคัดเลือกโครงข่ายภายในที่เหมาะสมสำหรับจำลองการพยากรณ์  $Q_{t+6}$  ณ สถานี KGT.3

1.Direct Step Input Variables :  $Q6_t, Q6_{t-1}, Q1_t, Q2_t, Q3_t, Q4_t, Q5_t$  (7 Nodes)

Models	Hidden Nodes		Training					Testing					Remark
	Layer 1	Layer 2	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )			
1	7	-	76.56	3.524	1.576	53.29	84.77	2.299	1.701	20.83	***** Selected*****		
2	4	3	77.62	3.441	1.456	51.29	84.82	2.365	1.725	22.28			

2.Standard Step Input Variables :  $FQ6_{t+5}, Q6_{t+4}, FQ1_{t+5}, FQ3_{t+5}, FQ4_{t+5}$  (5 Nodes)

Models	Hidden Nodes		Training					Testing					Remark
	Layer 1	Layer 2	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )			
1	5	-	85.59	2.704	1.317	44.13	89.09	1.927	1.409	15.54	***** Selected*****		
2	3	2	85.99	2.664	1.292	43.77	89.01	1.935	1.416	15.62			

ตาราง ๓4-26 การคัดเลือกโครงข่ายภายในที่เหมาะสมสำหรับจำลองการพยากรณ์  $Q_{t+7}$  ณ สถานี KGT.3

1.Direct Step Input Variables :  $Q6_t, Q6_{t-1}, Q1_t, Q2_t, Q3_t, Q4_t, Q5_t$  (7 Nodes)

Models	Hidden Nodes		Training					Testing					Remark
	Layer 1	Layer 2	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )	EI (%)	RMSE ( $m^3/s$ )	MAD ( $m^3/s$ )	Max. Abs. Error ( $m^3/s$ )			
1	7	-	71.33	3.823	1.872	56.54	78.66	2.780	2.149	27.39	***** Selected*****		
2	4	3	74.34	3.634	1.872	55.63	80.14	2.697	1.989	24.29			




2. Standard Step    Input Variables :    FQ6<sub>t+6</sub>, Q6<sub>t+6</sub>, FQ1<sub>t+6</sub>, FQ3<sub>t+6</sub>, FQ4<sub>t+6</sub>    (5 Nodes)

Models	Hidden Nodes		Training				Testing				Remark
	Layer 1	Layer 2	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	
	1	5	-	83.03	2.823	1.355	45.41	87.30	2.153	1.589	
2	3	2	83.17	2.818	1.347	44.25	87.60	2.073	1.519	16.42	



ศูนย์บริการ  
 วิศวกรรมมหาวิทยาลัย





# ภาคผนวก ง


การตรวจสอบความเป็นอิสระของอนุกรมค่าความผิดพลาด

สถาบันวิทยบริการ  
จุฬาลงกรณ์มหาวิทยาลัย


ภาคผนวก ง1: การตรวจสอบค่าอนุกรมความผิดพลาดจากแบบจำลองที่ใช้ในฤดูฝน








(a) การตรวจสอบอนุกรมค่าความผิดพลาดในการพยากรณ์จากแบบจำลอง ANN




(b) การตรวจสอบอนุกรมค่าความผิดพลาดในการพยากรณ์จากแบบจำลอง ANN+MA(2)

รูป ง1-5 การตรวจสอบอนุกรมค่าความผิดพลาดในการพยากรณ์  $Q_{t+4}$  ณ สถานีวัด KGT.12




(a) การตรวจสอบอนุกรมค่าความผิดพลาดในการพยากรณ์จากแบบจำลอง ANN




(b) การตรวจสอบอนุกรมค่าความผิดพลาดในการพยากรณ์จากแบบจำลอง ANN+MA(2)

รูป ง1-6 การตรวจสอบอนุกรมค่าความผิดพลาดในการพยากรณ์  $Q_{t+5}$  ณ สถานีวัด KGT.12




(a) การตรวจสอบอนุกรมค่าความผิดพลาดในการพยากรณ์จากแบบจำลอง ANN




(b) การตรวจสอบอนุกรมค่าความผิดพลาดในการพยากรณ์จากแบบจำลอง ANN+AR(2)

รูป 1-7 การตรวจสอบอนุกรมค่าความผิดพลาดในการพยากรณ์  $Q_{t+6}$  ณ สถานีวัด KGT.12





(a) การตรวจสอบอนุกรมค่าความผิดพลาดในการพยากรณ์จากแบบจำลอง ANN




(b) การตรวจสอบอนุกรมค่าความผิดพลาดในการพยากรณ์จากแบบจำลอง ANN+MA(2)

รูป 1-8 การตรวจสอบอนุกรมค่าความผิดพลาดในการพยากรณ์  $Q_{t+2}$  ณ สถานีวัด KGT.10






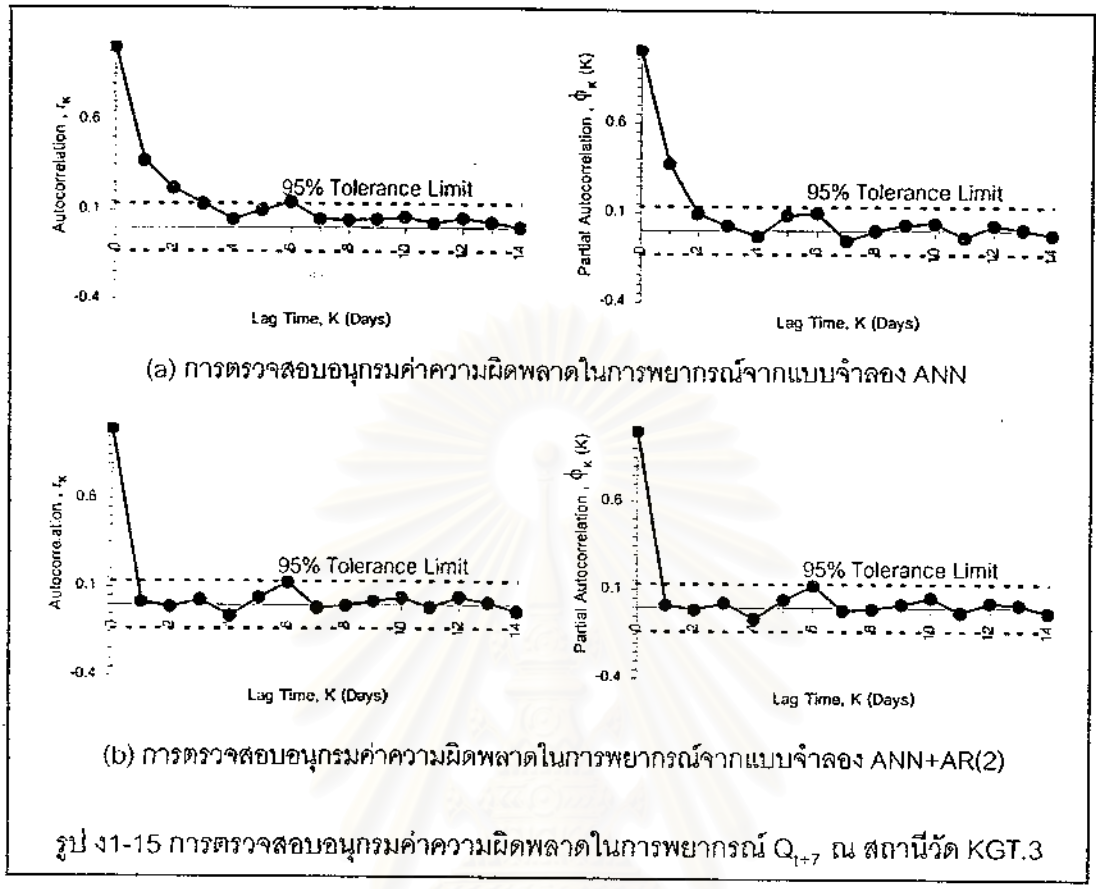
รูปง 1-11 การตรวจสอบอนุกรมค่าความผิดพลาดในการพยากรณ์  $Q_{t+3}$  ณ สถานีวัด KGT.3



รูปง 1-12 การตรวจสอบอนุกรมค่าความผิดพลาดในการพยากรณ์  $Q_{t+2}$  ณ สถานีวัด KGT.3














สถาบันวิทยบริการ  
จุฬาลงกรณ์มหาวิทยาลัย


ภาคผนวก ง2: การตรวจสอบค่าอนุกรมความผิดพลาดจากแบบจำลองที่ใช้ในฤดูแล้ง













(a) การตรวจสอบอนุกรมค่าความผิดพลาดในการพยากรณ์จากแบบจำลอง ANN




(b) การตรวจสอบอนุกรมค่าความผิดพลาดในการพยากรณ์จากแบบจำลอง ANN+MA(2)

รูป 2-9 การตรวจสอบอนุกรมค่าความผิดพลาดในการพยากรณ์  $Q_{t+3}$  ณ สถานีวัด KGT.15A




(a) การตรวจสอบอนุกรมค่าความผิดพลาดในการพยากรณ์จากแบบจำลอง ANN




(b) การตรวจสอบอนุกรมค่าความผิดพลาดในการพยากรณ์จากแบบจำลอง ANN+MA(2)

รูป 2-10 การตรวจสอบอนุกรมค่าความผิดพลาดในการพยากรณ์  $Q_{t+4}$  ณ สถานีวัด KGT.15A




(a) การตรวจสอบอนุกรมค่าความผิดพลาดในการพยากรณ์จากแบบจำลอง ANN




(b) การตรวจสอบอนุกรมค่าความผิดพลาดในการพยากรณ์จากแบบจำลอง ANN+MA(2)

รูป 2-11 การตรวจสอบอนุกรมค่าความผิดพลาดในการพยากรณ์  $Q_{t+5}$  ณ สถานีวัด KGT.15A




(a) การตรวจสอบอนุกรมค่าความผิดพลาดในการพยากรณ์จากแบบจำลอง ANN




(b) การตรวจสอบอนุกรมค่าความผิดพลาดในการพยากรณ์จากแบบจำลอง ANN+MA(2)

รูป 2-12 การตรวจสอบอนุกรมค่าความผิดพลาดในการพยากรณ์  $Q_{t+6}$  ณ สถานีวัด KGT.15A








รูป 2-13 การตรวจสอบอนุกรมค่าความผิดพลาดในการพยากรณ์  $Q_{t+2}$  ณ สถานีวัด KGT.12





รูป 2-14 การตรวจสอบอนุกรมค่าความผิดพลาดในการพยากรณ์  $Q_{t+3}$  ณ สถานีวัด KGT.12







(a) การตรวจสอบอนุกรมค่าความผิดพลาดในการพยากรณ์จากแบบจำลอง ANN





(b) การตรวจสอบอนุกรมค่าความผิดพลาดในการพยากรณ์จากแบบจำลอง ANN+MA(2)

รูปง 2-17 การตรวจสอบอนุกรมค่าความผิดพลาดในการพยากรณ์  $Q_{t+6}$  ณ สถานีวัด KGT.12







(a) การตรวจสอบอนุกรมค่าความผิดพลาดในการพยากรณ์จากแบบจำลอง ANN





(b) การตรวจสอบอนุกรมค่าความผิดพลาดในการพยากรณ์จากแบบจำลอง ANN+MA(2)

รูปง 2-18 การตรวจสอบอนุกรมค่าความผิดพลาดในการพยากรณ์  $Q_{t+7}$  ณ สถานีวัด KGT.12







(a) การตรวจสอบอนุกรมค่าความผิดพลาดในการพยากรณ์จากแบบจำลอง ANN





(b) การตรวจสอบอนุกรมค่าความผิดพลาดในการพยากรณ์จากแบบจำลอง ANN+MA(2)

รูป ง2-21 การตรวจสอบอนุกรมค่าความผิดพลาดในการพยากรณ์  $Q_{t+2}$  ณ สถานีวัด KGT.3


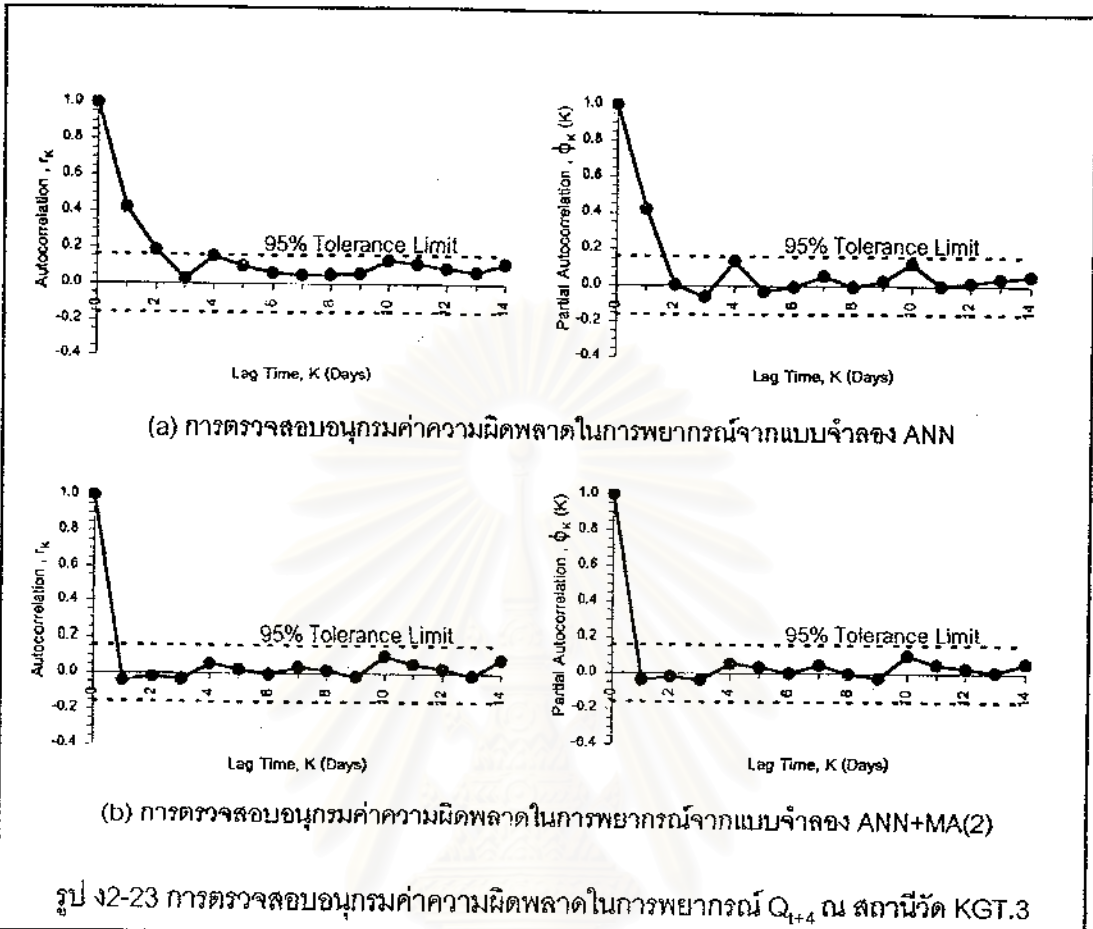




(a) การตรวจสอบอนุกรมค่าความผิดพลาดในการพยากรณ์จากแบบจำลอง ANN




(b) การตรวจสอบอนุกรมค่าความผิดพลาดในการพยากรณ์จากแบบจำลอง ANN+MA(2)

รูป ง2-22 การตรวจสอบอนุกรมค่าความผิดพลาดในการพยากรณ์  $Q_{t+3}$  ณ สถานีวัด KGT.3







## ภาคผนวก จ

ค่าพารามิเตอร์ในแบบจำลอง ANN และ แบบจำลองอนุกรมเวลา

สถาบันวิทยบริการ  
จุฬาลงกรณ์มหาวิทยาลัย



ภาคผนวก จ1: ค่าพารามิเตอร์ในแบบจำลอง ANN และ แบบจำลองอนุกรมเวลา ที่ใช้ในฤดูฝน

ตาราง จ1-1 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+1}$  ณ สถานี 150401

Layer 1 to 2	$Q1_t$	$R1_t$	$R1_{t-1}$	Bias	← Input
H11	-12.08	1.64687	-0.5433	-0.6435	
H12	-1.3708	-1.2572	-1.8249	2.81445	
H13	-1.9099	-1.217	1.46242	-0.9019	
Layer 2 to 3	H11	H12	H13	Bias	← Input
$Q1_{t+1}$	-6.5143	-3.8601	-3.7716	3.21586	

↑  
Output

- หมายเหตุ** 1) Bias มีค่าเท่ากับ 1 เสมอ  
2) H11 หมายถึง Hidden layer ชั้นที่ 1 Node ที่ 1

ตาราง จ1-2 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+2}$  ณ สถานี 150401

Layer 1 to 2	$Q1_{t+1}$	$R1_t$	Bias
H11	-7.7949	0.87032	-0.6273
H12	-1.2511	-1.3329	1.58504
Layer 2 to 3	H11	H12	Bias
$Q1_{t+2}$	-5.1642	-2.3319	0.87825

ตาราง จ1-3 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+1}$  ณ สถานี KGT.14

Layer 1 to 2	$Q2_{t+1}$	$R2_t$	Bias
H11	-0.192	-4.7451	2.69458
H12	-11.763	3.09796	-0.9987
Layer 2 to 3	H11	H12	Bias
$Q2_{t+2}$	-4.8217	-6.5566	3.08081

ตาราง จ1-4 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+1}$  ณ สถานี KGT.15A

Layer 1 to 2	$Q3_t$	$Q3_{t-1}$	$R3_t$	$R3_{t-1}$	Bias
H11	-7.7597	-4.7639	2.76671	0.74603	-1.0942
H12	-1.0421	0.32041	-0.8292	-0.1726	-0.474
H13	-1.2968	3.30482	-3.9061	-1.2423	3.88311
H14	-3.9513	1.3605	-1.7955	0.05948	1.2849
Layer 2 to 3	H11	H12	H13	H14	Bias
$Q3_{t+1}$	-5.8007	-0.3753	-4.2772	-2.9193	4.90462

ตาราง จ1-5 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+2}$  ณ สถานี KGT.15A

Layer 1 to 2	$Q3_{t+1}$	$Q3_t$	$R3_t$	Bias
H11	-1.724	0.47248	-1.5584	1.73627
H12	-2.6725	-1.1321	-0.3777	-1.7704
H13	-8.4347	-5.2444	1.5203	-0.5127
Layer 2 to 3	H11	H12	H13	Bias
$Q3_{t+2}$	-3.0633	-1.5034	-5.3351	1.28519

ตาราง จ1-6 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+1}$  ณ สถานี KGT.12

Layer 1 to 2	$Q4_t$	$Q4_{t-1}$	$R4_t$	$R4_{t-1}$	$R4_{t-2}$	$R4_{t-3}$	$R4_{t-4}$	$R4_{t-5}$	Bias
H11	5.57494	-2.5051	-0.6045	-0.3229	0.72141	0.24214	-0.3298	0.26267	-1.3672
H12	6.49502	-3.1043	0.63398	1.18452	-0.1218	-0.0535	-0.1574	-0.4379	-1.8378
H13	6.65108	0.08748	-0.135	-0.4657	-0.1608	-0.2886	-0.0175	0.02744	-0.3758
H14	5.93296	-2.1515	0.14348	-0.7329	-0.2498	0.03111	0.51516	0.24723	-2.6327
Layer 2 to 3	H11	H12	H13	H14	Bias				
H21	-2.029	-2.3963	-2.6238	-1.986	1.02682				
H22	-0.9241	-2.0308	0.74206	-2.9918	2.28842				
H23	-1.986	-2.2039	-1.9881	-1.7955	0.5566				
H24	-1.7502	-2.1723	-1.3775	-1.9291	0.22373				
Layer 3 to 4	H21	H22	H23	H24	Bias				
$Q4_{t+1}$	-3.4114	-3.0941	-3.0084	-2.6507	1.99106				

ตาราง จ1-7 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+2}$  ณ สถานี KGT.12

Layer 1 to 2	$Q4_{t+1}$	$Q4_t$	$R4_t$	$R4_{t-1}$	$R4_{t-2}$	$R4_{t-3}$	$R4_{t-4}$	Bias
H11	4.67217	-2.0559	-0.7966	-0.2664	-0.4389	-0.4447	0.06078	-1.3019
H12	5.3041	-1.2958	0.35514	-0.7818	-0.898	0.43115	0.08084	-3.2933
H13	5.93436	2.35898	-0.5066	-1.6651	-2.1695	-0.4805	0.18589	0.2393
H14	6.05693	-2.2746	1.01339	1.50239	1.75317	0.2785	-0.1656	-1.5543
Layer 2 to 3	H11	H12	H13	H14	Bias			
H21	-1.7203	-2.357	-3.5731	-1.8555	1.39354			
H22	-1.9307	-2.3501	-3.179	-1.8311	1.08688			
H23	-1.9008	-3.5761	0.62955	-2.4481	2.49776			
Layer 3 to 4	H21	H22	H23	Bias				
$Q4_{t+2}$	-3.8188	-3.6822	-3.0828	1.27519				

ตาราง จ1-8 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+3}$  ณ สถานี KGT.12

Layer 1 to 2	$Q4_{t+2}$	$Q4_{t+1}$	$R4_t$	$R4_{t-1}$	$R4_{t-2}$	$R4_{t-3}$	Bias
H11	2.97451	2.38036	1.5805	2.41332	1.83523	0.59827	-2.7156
H12	0.675	6.89327	0.02084	-1.0025	-0.1943	0.53839	-4.9553
H13	1.89676	6.91728	-0.9092	-1.8438	-1.888	-0.9487	0.72975
Layer 2 to 3	H11	H12	H13	Bias			
H21	-1.4557	-2.2008	-2.6534	0.65076			
H22	-1.0042	-1.8388	-3.5294	1.05997			
H23	-2.0809	-3.3809	-0.4756	1.90143			
Layer 3 to 4	H21	H22	H23	Bias			
$Q4_{t+3}$	-2.8048	-3.4449	-2.574	0.89964			

ตาราง จ1-9 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+4}$  ณ สถานี KGT.12

Layer 1 to 2	$Q_{t+3}$	$Q_{t+2}$	$R_{t-1}$	$R_{t-2}$	$R_{t-3}$	Bias
H11	-2.858	0.51751	0.87078	0.6321	0.52327	0.71238
H12	1.99078	-1.0931	0.87515	1.0449	0.67394	-0.5637
H13	-1.7688	0.94103	-1.911	-1.2181	-0.606	-0.5069
H14	-1.522	0.20411	0.39456	0.01372	-0.1121	-0.5428
H15	-5.3637	-2.2897	1.05251	1.30615	0.73163	-1.3475
Layer 2 to 3	H11	H12	H13	H14	H15	Bias
$Q_{t+4}$	-2.8932	2.41309	-2.337	-1.4864	-3.7852	0.48818

ตาราง จ1-9 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+5}$  ณ สถานี KGT.12

Layer 1 to 2	$Q_{t+4}$	$Q_{t+3}$	$R_{t-1}$	$R_{t-2}$	Bias
H11	-9.5076	-3.068	0.40508	-0.0851	-0.6225
H12	6.00421	-2.1674	-0.0875	0.20231	-2.8821
Layer 2 to 3	H11	H12	Bias		
H21	3.21195	-4.1707	-0.1651		
H22	3.64644	-4.0288	-0.6686		
Layer 3 to 4	H21	H22	Bias		
$Q_{t+5}$	-3.834	-3.8025	1.12802		

ตาราง จ1-10 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+6}$  ณ สถานี KGT.12

Layer 1 to 2	$Q_{t+4}$	$Q_{t+3}$	$R_{t-1}$	Bias
H11	-1.8886	0.72316	-1.0928	0.2433
H12	-7.1363	0.67701	0.0198	-1.1708
H13	-4.1078	1.34804	0.76	-0.1796
Layer 2 to 3	H11	H12	H13	Bias
$Q_{t+6}$	-2.355	-4.8168	-4.1814	1.5271

ตาราง จ1-11 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+1}$  ณ สถานี KGT.10

Layer 1 to 2	$Q5_t$	$Q5_{t-1}$	$R5_t$	$R5_{t-1}$	$R5_{t-2}$	Bias
H11	7.62237	-3.6609	0.05434	0.70353	0.71353	-3.1206
H12	2.60456	0.0225	0.87491	0.52401	0.442	-1.7082
H13	6.28116	0.46358	-0.3944	-0.8215	-1.4433	1.10453
Layer 2 to 3	H11	H12	H13	Bias		
H21	-2.9044	-1.4366	-2.3801	0.82062		
H22	-5.1097	-1.3992	-2.3324	2.47299		
Layer 3 to 4	H21	H22	Bias			
$Q5_{t+1}$	-3.2488	-3.9795	0.39175			

ตาราง จ1-12 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+2}$  ณ สถานี KGT.10

Layer 1 to 2	$Q5_{t+1}$	$Q5_t$	$R5_t$	$R5_{t-1}$	Bias
H11	-3.7889	0.78943	-1.6077	-0.7671	1.78634
H12	0.24084	-0.0334	-0.1112	-0.1722	-0.6298
H13	-0.6926	0.10644	0.69273	-0.976	-0.4975
H14	-8.6704	-4.0064	1.41853	2.13322	-1.5438
Layer 2 to 3	H11	H12	H13	H14	Bias
$Q5_{t+2}$	-2.4027	0.35372	-1.0491	-4.8634	0.50555

ตาราง จ1-13 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+3}$  ณ สถานี KGT.10

Layer 1 to 2	$Q5_{t+2}$	$Q5_{t+1}$	$R5_t$	Bias
H11	-6.4466	-1.1399	1.70018	-1.4836
H12	-4.85	1.10591	-1.3245	0.93545
H13	-5.2139	-0.0317	1.02042	-1.6901
Layer 2 to 3	H11	H12	H13	Bias
$Q5_{t+3}$	-3.7353	-2.7943	-3.1772	0.40952

ตาราง จ1-14 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+1}$  ณ สถานี KGT.3

Layer 1 to 2	$Q6_t$	$Q6_{t-1}$	$Q1_t$	$Q2_t$	$Q3_t$	$Q4_t$	$Q5_t$	$R6_t$	$R6_{t-1}$	$R6_{t-2}$	$R6_{t-3}$	Bias
H11	1.5132	0.08964	0.2119	0.17703	-0.011	-0.161	0.31555	0.02853	-0.0384	0.1583	-0.4254	-2.5351
H12	0.34374	-0.2662	0.10572	-0.262	-0.0388	0.01124	-0.0465	-0.2427	-0.0002	-0.374	-0.3891	-1.96
H13	3.23716	0.01661	1.60507	1.82248	1.47954	-1.145	0.29802	-0.1492	1.33333	0.88362	-0.8001	-6.2257
H14	3.04921	-0.2513	0.01135	0.06784	-0.0129	0.06054	0.30055	-0.0691	-0.1538	-0.0703	0.01695	-2.87
H15	5.60368	0.03189	-0.3925	-0.2577	-0.1344	0.2534	0.08011	0.66521	0.26161	0.13138	0.23429	-3.2556
H16	4.18577	-0.3404	2.07331	1.94434	2.38543	2.16711	3.38044	0.09738	0.25198	-0.1189	0.01211	-2.3508
Layer 2 to 3	H11	H12	H13	H14	H15	H16	Bias					
H21	-0.6754	0.12495	-1.9604	-0.8752	-1.7568	-1.1461	-0.3293					
H22	-0.2366	-0.2017	-3.5246	-0.8794	-1.9341	0.18706	1.42888					
H23	-0.359	-0.2529	-1.9744	-0.8647	-1.6886	-2.211	0.14418					
H24	-0.2467	-0.3276	-2.0726	-1.1544	-1.6579	-1.3531	-0.1509					
H25	-0.6794	-0.078	-2.1329	-0.6986	-1.3716	-1.8782	-0.0454					
Layer 3 to 4	H21	H22	H23	H24	H25	Bias						
$Q6_{t+1}$	-1.7888	-2.5159	-2.2041	-1.8214	-2.0347	1.94979						

ตาราง จ1-15 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+2}$  ณ สถานี KGT.3

Layer 1 to 2	$Q6_{t+1}$	$Q1_{t+1}$	$Q2_{t+1}$	$Q3_{t+1}$	$Q4_{t+1}$	$Q5_{t+1}$	$Q6_t$	$R6_t$	$R6_{t-1}$	$R6_{t-2}$	Bias
H11	3.50395	3.06632	-0.3043	0.42764	-0.2595	-0.5077	0.48306	2.19176	0.74227	-0.102	-3.0417
H12	-2.193	-1.7418	-2.6139	-2.0181	-1.9556	-1.4239	-3.3712	0.61704	0.25088	0.18118	0.65019
H13	-0.1151	0.30774	-0.4214	-0.3841	-0.112	-0.2639	-0.1149	-0.4537	-0.4924	-0.2756	-1.641
H14	2.94143	1.44227	1.81727	2.60512	1.11185	1.40626	0.13104	0.06706	0.86359	-1.0536	-7.8909
H15	2.43987	1.3841	-0.541	-0.0442	-0.2026	-0.2551	0.19875	-0.7728	-0.0135	0.78889	-2.7541
Layer 2 to 3	H11	H12	H13	H14	H15	Bias					
H21	-0.4642	1.56265	0.01921	-2.9662	-1.0175	-0.3554					
H22	-0.5246	1.73393	-0.3362	-2.9749	-0.5717	-0.5918					
H23	-1.3165	1.90046	0.01486	-2.7998	-0.6714	-0.2931					
H24	-0.6776	1.24687	0.13821	-2.6069	-0.9443	-0.7584					
H25	-0.7226	1.03876	-0.1379	-2.2978	-0.7709	-1.0124					
Layer 3 to 4	H21	H22	H23	H24	H25	Bias					
$Q6_{t+2}$	-2.0056	-1.9862	-2.0103	-1.9345	-1.8946	1.93149					

ตาราง จ1-16 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+3}$  ณ สถานี KGT.3

Layer 1 to 2	$Q6_{t+2}$	$Q6_{t+1}$	$Q1_{t+2}$	$Q4_{t+2}$	$Q5_{t+2}$	$R6_t$	$R6_{t-1}$	Bias
H11	-1.0058	0.32779	-0.1518	-0.4241	-0.2766	-0.9931	-1.0096	-0.9673
H12	6.5289	0.48985	0.30345	1.75216	3.25696	-0.9247	-0.4731	-1.0907
H13	-1.6909	0.09432	-0.1316	-1.7056	0.22912	-1.8064	-1.484	0.34891
H14	5.89467	-0.8082	-0.609	-0.3646	0.28873	-0.4541	-0.5631	-3.0216
Layer 2 to 3	H11	H12	H13	H14	Bias			
H21	0.54555	-3.4179	0.69284	-3.3135	0.49442			
H22	1.15589	-1.3545	2.55754	-3.7915	1.84026			
H23	0.59997	-2.6618	0.7473	-3.3746	0.04778			
Layer 3 to 4	H21	H22	H23	Bias				
$Q6_{t+3}$	-2.8774	-2.8932	-2.3965	1.45201				

ตาราง จ1-17 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+4}$  ณ สถานี KGT.3

Layer 1 to 2	$Q6_{t+3}$	$Q6_{t+2}$	$Q4_{t+3}$	$Q5_{t+3}$	$R6_t$	Bias
H11	4.34071	-1.0689	0.68323	0.13024	0.17317	-2.2914
H12	7.07006	0.02739	0.19308	0.38887	-0.3034	-4.0475
H13	6.36784	2.32534	1.30668	2.58236	0.01029	-2.2958
Layer 2 to 3	H11	H12	H13	Bias		
H21	-2.1232	-2.766	-4.0513	0.47717		
H22	-1.8277	-4.2417	-1.2251	2.45185		
Layer 3 to 4	H21	H22	Bias			
$Q6_{t+4}$	-3.8317	-1.9703	0.47959			

ตาราง จ1-18 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+5}$  ณ สถานี KGT.3

Layer 1 to 2	$Q6_{t+4}$	$Q6_{t+3}$	$Q4_{t+4}$	Bias
H11	-3.2093	0.93855	-0.2308	0.84857
H12	-2.4243	0.75804	-0.3078	0.15475
H13	-7.4015	-1.6625	-1.1205	-0.6868
Layer 2 to 3	H11	H12	H13	Bias
$Q6_{t+5}$	-3.3062	-2.4912	-5.2767	1.99453

ตาราง จ1-19 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+6}$  ณ สถานี KGT.3

Layer 1 to 2	$Q6_{t+4}$	$Q6_{t+3}$	$Q4_{t+4}$	Bias
H11	-5.4676	-1.3228	-1.9429	-0.841
H12	-4.235	1.38866	-1.3197	-0.5238
H13	-2.8495	0.58241	0.35463	0.70415
Layer 2 to 3	H11	H12	H13	Bias
$Q6_{t+6}$	-3.8619	-4.4773	-3.015	1.59352

ตาราง จ1-20 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+7}$  ณ สถานี KGT.3

Layer 1 to 2	$Q6_{t+5}$	$Q6_{t+4}$	$Q4_{t+5}$	Bias
H11	-8.5178	-6.9492	-4.7713	0.4468
H12	-7.5944	2.79653	-0.5406	2.15075
H13	-2.5241	0.012	-1.6382	-2.8281
Layer 2 to 3	H11	H12	H13	Bias
$Q6_{t+7}$	-5.6091	-2.3361	-2.0115	0.56935

ตาราง จ1-21 ค่าพารามิเตอร์ในแบบจำลองอนุกรมเวลาที่ใช้ปรับปรุงผลการพยากรณ์ในฤดูฝน

สถานี	พยากรณ์ ล่วงหน้า (วัน)	แบบจำลองอนุกรมเวลา			
		MA(2)		AR(2)	
		$\theta_1$	$\theta_2$	$\phi_1$	$\phi_2$
150401	2	-0.5477	0.0212	-	-
KGT.15A	2	-0.4507	0.0404	-	-
KGT.12	2	-0.7564	-0.0727	-	-
	3	-0.4843	-0.1795	-	-
	4	-0.4440	-0.2489	-	-
	5	-0.3813	-0.2152	-	-
	6	-	-	0.3414	0.0673

สถานี	พยากรณ์ ล่วงหน้า (วัน)	แบบจำลองอนุกรมเวลา			
		MA(2)		AR(2)	
		$\theta_1$	$\theta_2$	$\phi_1$	$\phi_2$
KGT.10	2	-0.7983	-0.0477	-	-
	3	-0.5538	-0.0908	-	-
KGT.3	2	-0.6487	-0.1141	-	-
	3	-0.4524	-0.0694	-	-
	4	-0.5208	-0.2449	-	-
	5	-0.4330	-0.2378	-	-
	6	-0.3648	-0.2204	-	-
	7	-	-	0.3699	0.1043

หมายเหตุ : ไม่สามารถปรับปรุงผลการพยากรณ์  $Q_{t+n}$  ในทุกสถานี



ภาคผนวก จ2: ค่าพารามิเตอร์ในแบบจำลอง ANN และ แบบจำลองอนุกรมเวลา ที่ใช้ในฤดูแล้ง

ตาราง จ2-1 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+1}$  ณ สถานี 150401

Layer 1 to 2	$Q1_t$	Bias	
H11	-2.3351	1.0426	
H12	-5.5903	-0.6029	
Layer 2 to 3	H11	H12	Bias
$Q1_{t+1}$	-4.5322	-5.0548	2.28106

ตาราง จ2-2 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+2}$  ณ สถานี 150401

Layer 1 to 2	$Q1_{t+1}$	Bias	
H11	-3.0907	-0.6346	
H12	-2.2268	-0.0528	
Layer 2 to 3	H11	H12	Bias
$Q1_{t+2}$	-4.4677	-4.5029	1.2600

ตาราง จ2-3 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+3}$  ณ สถานี 150401

Layer 1 to 2	$Q1_{t+2}$	Bias	
H11	-2.5938	1.85468	
H12	-6.139	-0.7877	
Layer 2 to 3	H11	H12	Bias
$Q1_{t+3}$	-4.1808	-5.1367	2.49193

ตาราง จ2-4 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+4}$  ณ สถานี 150401

Layer 1 to 2	$Q1_{t+3}$	Bias	
H11	-4.9013	-0.7983	
H12	-2.1987	0.89764	
Layer 2 to 3	H11	H12	Bias
$Q1_{t+4}$	-4.7619	-4.3233	1.88986

ตาราง จ2-5 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+5}$  ณ สถานี 150401

Layer 1 to 2	$Q1_{t+4}$	Bias	
H11	-2.7043	1.5304	
H12	-5.6278	-0.5147	
Layer 2 to 3	H11	H12	Bias
$Q1_{t+5}$	-3.5401	-5.5585	1.86465

ตาราง จ2-6 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+6}$  ณ สถานี 150401

Layer 1 to 2	$Q1_{t+5}$	Bias	
H11	-5.5604	-0.3218	
H12	-2.2671	1.42575	
Layer 2 to 3	H11	H12	Bias
$Q1_{t+6}$	-5.1956	-4.1537	2.09085

ตาราง จ2-7 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+7}$  ณ สถานี 150401

Layer 1 to 2	$Q1_{t+6}$	Bias	
H11	-1.4469	-0.1354	
H12	-4.3695	0.47673	
Layer 2 to 3	H11	H12	Bias
$Q1_{t+7}$	-1.6402	-5.6909	0.80852

ตาราง จ2-8 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+1}$  ณ สถานี KGT.14

Layer 1 to 2	$Q2_t$	Bias	
H11	-5.6164	-1.9613	
H12	-7.4654	0.87347	
Layer 2 to 3	H11	H12	Bias
$Q2_{t+1}$	-2.8741	-3.2748	-0.1182

ตาราง จ2-9 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+2}$  ณ สถานี KGT.14

Layer 1 to 2	$Q2_{t+1}$	Bias	
H11	-2.6893	-0.5229	
H12	-2.8567	-0.1012	
Layer 2 to 3	H11	H12	Bias
$Q2_{t+2}$	-2.7425	-2.79	0.113

ตาราง จ2-10 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+1}$  ณ สถานี KGT.15A

Layer 1 to 2	$Q3_t$	Bias	
H11	-2.6837	-0.0679	
H12	-2.5797	-0.0176	
Layer 2 to 3	H11	H12	Bias
$Q3_{t+1}$	-3.9451	-5.7785	2.13526

ตาราง จ2-11 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+2}$  ณ สถานี KGT.15A

Layer 1 to 2	$Q3_{t+1}$	Bias	
H11	-7.8516	-0.3635	
H12	-3.4802	3.26756	
Layer 2 to 3	H11	H12	Bias
$Q3_{t+2}$	-5.4578	-4.994	3.9296

ตาราง จ2-12 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+3}$  ณ สถานี KGT.15A

Layer 1 to 2	$Q3_{t+2}$	Bias	
H11	-3.5605	0.07215	
H12	-2.5725	0.8029	
Layer 2 to 3	H11	H12	Bias
$Q3_{t+3}$	-4.4813	-4.4231	2.03483

ตาราง จ2-13 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+4}$  ณ สถานี KGT.15A

Layer 1 to 2	$Q3_{t+3}$	Bias	
H11	-4.3935	0.20925	
H12	-2.6321	0.99249	
Layer 2 to 3	H11	H12	Bias
$Q3_{t+4}$	-4.9763	-3.7751	1.96867

ตาราง จ2-14 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+5}$  ณ สถานี KGT.15A

Layer 1 to 2	$Q3_{t+4}$	Bias	
H11	-3.9116	-0.1184	
H12	-2.5214	0.72908	
Layer 2 to 3	H11	H12	Bias
$Q3_{t+5}$	-4.8041	-4.4498	1.86562

ตาราง จ2-15 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+6}$  ณ สถานี KGT.15A

Layer 1 to 2	$Q3_{t+5}$	Bias	
H11	-3.0566	0.85348	
H12	-4.6698	0.26274	
Layer 2 to 3	H11	H12	Bias
$Q3_{t+6}$	-3.8829	-4.4614	1.56414

ตาราง จ2-16 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+1}$  ณ สถานี KGT.12

Layer 1 to 2	$Q4_t$	Bias	
H11	-3.6029	2.72277	
H12	-7.7126	-0.4236	
Layer 2 to 3	H11	H12	Bias
$Q4_{t-1}$	-4.7313	-6.0641	3.56071

ตาราง จ2-17 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+2}$  ณ สถานี KGT.12

Layer 1 to 2	$Q_{t+1}$	Bias	
H11	-3.2909	2.50056	
H12	-6.7947	-0.6132	
Layer 2 to 3	H11	H12	Bias
$Q_{t+2}$	-4.3862	-6.292	3.18394

ตาราง จ2-18 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+3}$  ณ สถานี KGT.12

Layer 1 to 2	$Q_{t+2}$	Bias	
H11	-2.7974	1.72752	
H12	-6.2292	-0.5354	
Layer 2 to 3	H11	H12	Bias
$Q_{t+3}$	-3.6604	-5.8614	2.0648

ตาราง จ2-19 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+4}$  ณ สถานี KGT.12

Layer 1 to 2	$Q_{t+3}$	Bias	
H11	-5.8857	-0.4225	
H12	-2.6491	0.87854	
Layer 2 to 3	H11	H12	Bias
$Q_{t+4}$	-4.8641	-4.2615	1.55882

ตาราง จ2-20 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+5}$  ณ สถานี KGT.12

Layer 1 to 2	$Q_{t+4}$	Bias	
H11	-5.1956	0.06417	
H12	-2.8247	0.63526	
Layer 2 to 3	H11	H12	Bias
$Q_{t+5}$	-4.659	-4.1947	1.11123

ตาราง ๑2-21 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+6}$  ณ สถานี KGT.12

Layer 1 to 2	$Q_{t+5}$	Bias	
H11	-5.7935	0.39728	
H12	-3.0553	0.85373	
Layer 2 to 3	H11	H12	Bias
$Q_{t+6}$	-4.9067	-3.782	1.04172

ตาราง ๑2-22 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+7}$  ณ สถานี KGT.12

Layer 1 to 2	$Q_{t+6}$	Bias	
H11	-6.1645	0.70749	
H12	-2.4046	1.23172	
Layer 2 to 3	H11	H12	Bias
$Q_{t+7}$	-4.7359	-3.7066	1.55131

ตาราง ๑2-23 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+1}$  ณ สถานี KGT.10

Layer 1 to 2	$Q_{5t}$	$Q_{5t-1}$	$R_{5t}$	$R_{5t-1}$	$R_{5t-2}$	Bias
H11	-8.6491	-0.3225	0.81173	0.02679	0.34603	-0.3302
H12	2.87349	0.95903	1.0145	2.06885	0.26705	-4.8083
H13	-1.4191	1.85045	-1.9524	0.0005	-2.1292	-0.9462
Layer 2 to 3	H11	H12	H13	Bias		
H21	4.66322	-3.7016	2.0127	0.06363		
H22	1.54851	-1.8337	0.60072	-1.2252		
Layer 3 to 4	H21	H22	Bias			
$Q_{5t+1}$	-5.7975	-1.6788	3.21271			

ตาราง ๑2-24 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+2}$  ณ สถานี KGT.10

Layer 1 to 2	$Q5_{t+1}$	$Q5_t$	$R5_t$	$R5_{t-1}$	Bias
H11	-6.4016	-2.7046	1.25185	2.24192	-0.8238
H12	-1.8886	0.38053	-0.6089	-1.1283	0.9199
H13	-1.9484	0.29252	-0.4184	-0.5583	0.29398
H14	-1.1445	0.37606	-1.1959	-1.3882	0.51992
Layer 2 to 3	H11	H12	H13	H14	Bias
$Q5_{t+2}$	-4.7614	-2.4125	-2.0148	-1.7897	2.18662

ตาราง ๑2-25 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+3}$  ณ สถานี KGT.10

Layer 1 to 2	$Q5_{t+2}$	$Q5_{t+1}$	$R5_t$	Bias
H11	0.71162	-0.821	-2.995	0.28905
H12	-4.0971	0.13726	-0.3309	-0.9701
H13	-6.8339	1.38004	2.22331	-0.45
Layer 2 to 3	H11	H12	H13	Bias
$Q5_{t+3}$	-3.303	-2.8991	-4.7987	1.51157

ตาราง ๑2-26 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+1}$  ณ สถานี KGT.3

Layer 1 to 2	$Q6_t$	$Q6_{t-1}$	$Q1_t$	$Q2_t$	$Q3_t$	$Q4_t$	$Q5_t$	Bias
H11	1.81896	-0.4246	0.63937	-0.14	-0.0831	0.62185	0.71205	-2.2557
H12	5.94021	0.52669	-0.6855	-0.31	-0.2792	-0.3131	0.66419	-0.7677
H13	1.62966	-0.39	0.75856	0.36593	-0.1141	0.48415	0.0073	-2.1956
H14	2.86138	0.32845	0.74824	0.12666	0.21513	0.45043	-0.1901	-3.5045
Layer 2 to 3	H11	H12	H13	H14	Bias			
H21	-0.9892	-1.944	-1.0317	-0.9862	0.42083			
H22	-1.1506	-1.3106	-1.0312	-1.7166	2.13035			
H23	-0.8503	-2.9268	-0.6706	-1.6459	0.86063			
Layer 3 to 4	H21	H22	H23	Bias				
$Q6_{t+1}$	-2.7286	-3.0291	-2.9217	2.12581				

ตาราง ๑2-27 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+2}$  ณ สถานี KGT.3

Layer 1 to 2	$Q6_{t+1}$	$Q6_t$	$Q1_{t+1}$	$Q2_{t+1}$	$Q3_{t+1}$	$Q4_{t+1}$	$Q5_{t+1}$	Bias
H11	1.94236	0.24483	1.26894	-1.0407	0.16392	2.20813	-1.4863	-2.4972
H12	1.45465	-1.7491	0.39943	1.28676	-0.5838	-2.3483	3.01178	-2.9111
H13	2.91152	1.26512	-0.9919	0.58315	-0.5925	0.25722	1.01736	-1.4182
H14	3.77819	3.25715	-0.6359	-0.8393	0.8645	-0.2432	-1.1942	-0.8604
Layer 2 to 3	H11	H12	H13	H14	Bias			
H21	-0.3629	-1.4126	-1.6589	-2.3327	0.17554			
H22	-3.1448	-3.8888	-0.5065	0.76841	1.64599			
H23	-0.5416	-1.5663	-1.8854	-3.8075	1.27352			
Layer 3 to 4	H21	H22	H23	Bias				
$Q6_{t+2}$	-2.6862	-4.4314	-3.9639	2.94902				

ตาราง ๑2-28 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+3}$  ณ สถานี KGT.3

Layer 1 to 2	$Q6_{t+2}$	$Q6_{t+1}$	$Q1_{t+2}$	$Q2_{t+2}$	$Q3_{t+2}$	$Q4_{t+2}$	$Q5_{t+2}$	Bias
H11	2.07336	-1.2269	0.63329	1.34398	-0.9289	-2.1921	2.72066	-3.5256
H12	6.24955	2.88265	-2.3095	-1.4136	-0.1509	-0.5381	-0.4332	-0.2662
H13	2.15312	-0.152	3.37953	-0.7563	-0.6587	1.76566	0.52544	-5.4333
H14	-0.2349	0.99583	-2.3225	-1.4895	-0.5296	-1.5961	-0.7665	0.27152
Layer 2 to 3	H11	H12	H13	H14	Bias			
H21	-1.678	-2.1832	-1.8232	1.63043	0.27008			
H22	-2.7521	-0.4378	-3.1845	1.53384	1.66759			
H23	-1.6735	-2.3274	-1.5718	1.45439	0.04876			
Layer 3 to 4	H21	H22	H23	Bias				
$Q6_{t+3}$	-2.8803	-3.92	-3.154	3.50182				



ตาราง ๑2-29 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+4}$  ณ สถานี KGT.3

Layer 1 to 2	$Q6_{t+3}$	$Q6_{t+2}$	$Q1_{t+3}$	$Q3_{t+3}$	$Q4_{t+3}$	$Q5_{t+3}$	Bias
H11	3.67088	1.56481	-0.7924	0.12383	0.04787	0.87274	-0.9247
H12	3.20108	-0.7344	2.00942	0.04684	0.19043	0.03855	-3.5046
H13	4.02562	0.70749	-0.58	-0.5189	-0.0575	0.792	-0.9143
Layer 2 to 3	H11	H12	H13	Bias			
H21	-0.4365	-2.6408	-0.7067	1.65767			
H22	-2.1622	-1.8307	-2.2276	1.17702			
H23	-1.3321	-2.0242	-1.295	0.85889			
Layer 3 to 4	H21	H22	H23	Bias			
$Q6_{t+4}$	-2.9612	-3.5359	-2.7116	2.04141			

ตาราง ๑2-30 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+5}$  ณ สถานี KGT.3

Layer 1 to 2	$Q6_{t+4}$	$Q6_{t+3}$	$Q1_{t+4}$	$Q3_{t+4}$	$Q4_{t+4}$	Bias
H11	2.96612	-0.627	1.97911	-0.2834	0.45669	-2.1669
H12	2.0945	0.05522	2.68906	0.11316	1.56694	-4.247
H13	7.14974	0.27776	-1.5573	0.08081	-0.3198	-2.5748
Layer 2 to 3	H11	H12	H13	Bias		
H21	-2.1022	-3.769	-0.1679	4.21946		
H22	-2.5367	-1.0976	-5.2465	1.28111		
Layer 3 to 4	H21	H22	Bias			
$Q6_{t+5}$	-3.6408	-4.3586	3.11065			

ตาราง ๑2-31 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+6}$  ณ สถานี KGT.3

Layer 1 to 2	$Q6_{t+5}$	$Q6_{t+4}$	$Q1_{t+5}$	$Q3_{t+5}$	$Q4_{t+5}$	Bias
H11	2.3442	-0.7171	3.42363	-0.0295	1.65161	-5.3219
H12	6.6618	2.03501	-0.694	0.00721	-0.0844	-2.5769
H13	0.91617	-0.068	0.58337	-0.2582	0.25185	-1.6356
Layer 2 to 3	H11	H12	H13	Bias		
H21	-4.6305	-0.4644	-0.1782	2.67327		
H22	-1.5687	-4.29	-0.7289	1.52524		
Layer 3 to 4	H21	H22	Bias			
$Q6_{t+6}$	-3.9075	-3.4608	3.29156			

ตาราง ๑2-32 ค่าถ่วงน้ำหนักในแบบจำลอง ANN สำหรับพยากรณ์  $Q_{t+7}$  ณ สถานี KGT.3

Layer 1 to 2	$Q6_{t+6}$	$Q6_{t+5}$	$Q1_{t+6}$	$Q3_{t+6}$	$Q4_{t+6}$	Bias
H11	3.3894	-0.1865	2.24457	0.40714	0.70226	-5.1863
H12	2.40169	-1.3294	1.15476	-0.0891	0.30796	-2.3515
H13	7.16685	2.01713	-0.6214	-0.154	-0.0701	-2.3101
Layer 2 to 3	H11	H12	H13	Bias		
H21	-3.2521	-1.924	-0.8546	3.10852		
H22	-1.6413	-1.5418	-3.2941	1.34542		
Layer 3 to 4	H21	H22	Bias			
$Q6_{t+7}$	-3.9445	-3.6616	3.3038			

ตาราง ๑2-33 ค่าพารามิเตอร์ในแบบจำลองอนุกรมเวลาที่ใช้ปรับปรุงผลการพยากรณ์ในฤดูแล้ง

สถานี	พยากรณ์ ล่วงหน้า (วัน)	แบบจำลองอนุกรมเวลา		สถานี	พยากรณ์ ล่วงหน้า (วัน)	แบบจำลองอนุกรมเวลา	
		MA(2)				MA(2)	
		$\theta_1$	$\theta_2$			$\theta_1$	$\theta_2$
150401	2	-0.7287	0.1351	KGT.12	2	-0.8954	-0.2842
	3	-0.4562	-0.0759		3	-0.5653	-0.0130
	4	-0.5156	-0.2774		4	-0.5156	-0.2773
	5	-0.2707	-0.1741		5	-0.4710	-0.2727
	6	-0.4074	-0.1927		6	-0.3981	-0.2897
	7	-0.3454	-0.1834		7	-0.3364	-0.2218
	KGT.14	2	-0.4252		0.1508	KGT.10	2
KGT.15A	2	-0.8537	0.0688	KGT.3	3	-0.5173	-0.1451
	3	-0.6986	-0.1885		2	-0.8235	-0.0876
	4	-0.4891	-0.2120		3	-0.5798	-0.2236
	5	-0.5081	-0.2913		4	-0.4784	-0.2551
	6	-0.3082	-0.2699		5	-0.4286	-0.2176
				6	-0.4068	-0.2752	
				7	-0.3630	-0.2596	

หมายเหตุ : ไม่สามารถปรับปรุงผลการพยากรณ์  $Q_{t+1}$  ในทุกสถานี



# ภาคผนวก จ

การพยากรณ์อัตราค่ารถไฟเหาะน้ำทำรายวันโดยใช้แบบจำลอง MLR

สถาบันวิทยบริการ  
จุฬาลงกรณ์มหาวิทยาลัย

ภาคผนวก จ1 : การพยากรณ์อัตราการไหลน้ำท่ารายวันในฤดูฝน โดยใช้แบบจำลอง MLR

ตาราง จ1-1 ผลการพยากรณ์อัตราการไหลน้ำท่ารายวัน ณ สถานี 150401 โดยใช้แบบจำลอง MLR

Forecasting day ahead  (day)	Training				Testing			
	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)
1	79.54	16.23	6.68	371.67	72.85	14.48	6.83	146.98
2	60.39	22.58	10.49	481.39	50.19	19.61	10.27	151.20

Note :  $Q1_{t+1} = 0.7149 + 0.8438Q1_t + 0.5390R1_t + 0.0929R1_{t-1}$

$$Q1_{t+2} = 3.0531 + 0.8465Q1_{t+1} + 0.2004R1_t$$

ตาราง จ1-2 ผลการพยากรณ์อัตราการไหลน้ำท่ารายวัน ณ สถานี KGT.14 โดยใช้แบบจำลอง MLR

Forecasting day ahead  (day)	Training				Testing			
	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)
1	59.34	9.11	4.07	159.08	59.78	7.26	3.67	72.97

Note :  $Q2_{t+1} = -0.5640 + 0.5488Q2_t + 0.5566R2_t$

ตาราง จ1-3 ผลการพยากรณ์อัตราการไหลน้ำท่ารายวัน ณ สถานี KGT.15A โดยใช้แบบจำลอง MLR

Forecasting day ahead  (day)	Training				Testing			
	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)
1	75.68	14.75	7.05	299.69	76.28	15.03	7.40	138.96
2	47.15	21.74	10.71	415.99	45.06	22.87	11.77	202.06

Note :  $Q3_{t+1} = -0.0948 + 0.8792Q3_t - 0.1511Q3_{t-1} + 0.7368R3_t + 0.0197R3_{t-1}$

$$Q3_{t+2} = 2.5886 + 0.5479Q3_{t+1} - 0.9467Q3_t + 1.2810R3_t$$

ตาราง ฉ1-4 ผลการพยากรณ์อัตราการไหลน้ำท่ารายวัน ณ สถานี KGT.12 โดยใช้แบบจำลอง MLR

Forecasting day ahead  (day)	Training				Testing			
	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)
1	98.52	5.69	2.95	148.32	98.19	4.77	2.67	36.93
2	93.96	11.49	6.50	196.35	92.82	9.51	5.73	55.46
3	87.26	16.69	9.75	223.01	84.96	13.76	8.44	86.33
4	79.38	21.24	12.57	227.75	76.44	17.22	10.60	101.24
5	70.91	25.22	14.98	246.56	67.63	20.18	12.44	112.36
6	62.23	28.74	17.00	326.70	59.31	22.62	14.29	102.54

Note :  $Q_{4,t+1} = -0.6419 + 1.6122Q_{4,t} - 0.6505Q_{4,t-1} + 0.1084R_{4,t} + 0.1407R_{4,t-1} + 0.0680R_{4,t-2} + 0.0143R_{4,t-3}$   
 $+ 0.0084R_{4,t-4} + 0.0280R_{4,t-5}$

$Q_{4,t+2} = -0.8320 + 1.4201Q_{4,t+1} - 0.4678Q_{4,t} + 0.1878R_{4,t} + 0.1151R_{4,t-1} + 0.0571R_{4,t-2} + 0.0198R_{4,t-3}$   
 $+ 0.0076R_{4,t-4}$

$Q_{4,t+3} = -0.4904 + 1.2624Q_{4,t+2} - 0.3204Q_{4,t+1} + 0.2015R_{4,t} + 0.1042R_{4,t-1} + 0.0520R_{4,t-2} + 0.0126R_{4,t-3}$

$Q_{4,t+4} = -0.0168 + 1.0052Q_{4,t+3} - 0.0829Q_{4,t+2} + 0.2299R_{4,t} + 0.1124R_{4,t-1} + 0.0514R_{4,t-2}$

$Q_{4,t+5} = 0.8826 + 1.3586Q_{4,t+4} - 0.4068Q_{4,t+3} + 0.0820R_{4,t} + 0.0204R_{4,t-1}$

$Q_{4,t+6} = 1.0811 + 1.4564Q_{4,t+5} - 0.4945Q_{4,t+4} + 0.0204R_{4,t}$

ตาราง ฉ1-5 ผลการพยากรณ์อัตราการไหลน้ำท่ารายวัน ณ สถานี KGT.10 โดยใช้แบบจำลอง MLR

Forecasting day ahead  (day)	Training				Testing			
	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)
1	98.67	23.42	11.23	621.94	90.31	15.25	9.32	77.10
2	73.26	35.97	19.59	695.74	71.99	25.92	15.76	135.43
3	59.93	44.03	24.61	748.92	57.64	31.88	19.02	162.67

Note :  $Q_{5,t+1} = -2.4021 + 1.1512Q_{5,t} - 0.2817Q_{5,t-1} + 0.3401R_{5,t} + 0.6584R_{5,t-1} + 0.2836R_{5,t-2}$

$Q_{5,t+2} = -2.1480 + .8676Q_{5,t+1} - 0.0262Q_{5,t} + 0.8672R_{5,t} + 0.5662R_{5,t-1}$

$Q_{5,t+3} = 1.4110 + 1.0090Q_{5,t+2} - 0.1453Q_{5,t+1} + 0.7203R_{5,t}$

ตาราง ข1-6 ผลการพยากรณ์อัตราการไหลน้ำท่ารายวัน ณ สถานี KGT.3 โดยใช้แบบจำลอง MLR

Forecasting day ahead  (day)	Training				Testing			
	EI	RMSE	MAD	Max. Abs.	EI	RMSE	MAD	Max. Abs.
	(%)	(m <sup>3</sup> /s)	(m <sup>3</sup> /s)	Error (m <sup>3</sup> /s)	(%)	(m <sup>3</sup> /s)	(m <sup>3</sup> /s)	Error (m <sup>3</sup> /s)
1	98.85	21.22	12.21	634.32	99.15	15.62	10.46	115.89
2	96.72	35.93	22.80	813.21	97.24	28.20	19.53	146.27
3	92.86	52.98	33.07	1145.74	92.86	45.38	29.62	364.65
4	87.47	70.18	42.64	1401.03	87.08	61.04	39.15	364.04
5	81.31	85.72	52.28	1386.76	80.98	74.07	47.99	415.60
6	74.69	99.75	61.97	1451.32	74.95	85.01	56.56	481.17
7	68.07	112.04	71.42	1493.60	69.73	93.44	64.47	506.20

Note :

$$Q_{6,t+1} = -5.1006 + 0.8890Q_{6,t} - 0.0882Q_{6,t-1} + 0.1045Q_{1,t} + 0.7194Q_{2,t} + 0.3540Q_{3,t} + 0.2018Q_{4,t}$$

$$+ 0.1941Q_{5,t} + 0.6902R_{6,t} + 0.7882R_{6,t-1} + 0.0725R_{6,t-2} + 0.0881R_{6,t-3}$$

$$Q_{6,t+2} = -5.1006 + 0.3724Q_{6,t+1} - 0.9610Q_{6,t} + 0.3163Q_{1,t+1} + 1.7049Q_{2,t+1} + 0.7075Q_{3,t+1}$$

$$+ 0.4596Q_{4,t+1} + 0.4591Q_{5,t+1} + 1.2074R_{6,t} + 1.21943R_{6,t-1} + 0.0148R_{6,t-2}$$

$$Q_{6,t+3} = -2.1578 + 0.9389Q_{6,t+2} - 0.0680Q_{6,t+1} + 0.1859Q_{1,t+2} + 0.1042Q_{4,t+2} + 0.1865Q_{5,t+2}$$

$$+ 1.0653R_{6,t} + 0.1034R_{6,t-1}$$

$$Q_{6,t+4} = 2.6997 + 1.0459Q_{6,t+3} - 0.1171Q_{6,t+2} + 0.0097Q_{4,t+3} + 0.1628Q_{5,t+3} + 0.4117R_{6,t}$$

$$Q_{6,t+5} = 3.6162 + 1.5038Q_{6,t+4} - 0.5222Q_{6,t+3} + 0.0131Q_{4,t+4}$$

$$Q_{6,t+6} = 4.0614 + 1.4723Q_{6,t+5} - 0.4971Q_{6,t+4} + 0.0084Q_{4,t+5}$$

$$Q_{6,t+7} = 4.7176 + 1.3787Q_{6,t+6} - 0.3986Q_{6,t+5} + 0.0340Q_{4,t+6}$$

สถาบันวิทยบริการ  
จุฬาลงกรณ์มหาวิทยาลัย

## ภาคผนวก ข2 : การพยากรณ์อัตราการไหลน้ำท่ารายวันในฤดูแล้ง โดยใช้แบบจำลอง MLR

ตาราง ข2-1 ผลการพยากรณ์อัตราการไหลน้ำท่ารายวัน ณ สถานี 150401 โดยใช้แบบจำลอง MLR

Forecasting day ahead  (day)	Training				Testing			
	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)
1	96.21	0.220	0.062	6.12	98.81	0.092	0.054	0.67
2	93.47	0.277	0.093	6.35	97.17	0.133	0.084	0.69
3	91.24	0.309	0.115	6.25	95.21	0.163	0.107	0.89
4	89.91	0.326	0.130	6.21	93.18	0.185	0.123	1.07
5	85.10	0.380	0.146	10.17	90.93	0.202	0.136	1.27
6	81.88	0.408	0.159	10.14	88.45	0.219	0.150	1.43
7	79.28	0.418	0.169	10.11	86.83	0.225	0.161	1.24

Note :

$$Q_{1,t+1} = 0.0375 + 0.9349Q_{1,t} \qquad Q_{1,t+5} = 0.0237 + 0.9531Q_{1,t+4}$$

$$Q_{1,t+2} = 0.0285 + 0.9444Q_{1,t+1} \qquad Q_{1,t+6} = 0.0234 + 0.9538Q_{1,t+5}$$

$$Q_{1,t+3} = 0.0237 + 0.9499Q_{1,t+2} \qquad Q_{1,t+7} = 0.0204 + 0.9565Q_{1,t+6}$$

$$Q_{1,t+4} = 0.0215 + 0.9520Q_{1,t+3}$$

ตาราง ข2-2 ผลการพยากรณ์อัตราการไหลน้ำท่ารายวัน ณ สถานี KGT.14 โดยใช้แบบจำลอง MLR

Forecasting day ahead  (day)	Training				Testing			
	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)
1	79.84	0.138	0.042	3.42	80.81	0.070	0.031	1.18
2	73.01	0.155	0.059	3.39	66.72	0.093	0.045	1.17

Note :

$$Q_{2,t+1} = 0.0256 + 0.8845Q_{2,t}$$

$$Q_{2,t+2} = 0.0140 + 0.9289Q_{2,t+1}$$

ตาราง ข2-3 ผลการพยากรณ์อัตราการไหลน้ำท่ารายวัน ณ สถานี KGT.15A โดยใช้แบบจำลอง MLR

Forecasting day ahead (day)	Training				Testing			
	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)
1	92.64	0.291	0.070	6.96	88.91	0.114	0.036	1.41
2	85.85	0.390	0.106	9.61	81.29	0.144	0.053	1.60
3	80.21	0.446	0.127	10.33	78.35	0.151	0.065	1.49
4	77.42	0.461	0.144	10.12	74.76	0.159	0.070	1.40
5	72.67	0.491	0.153	9.06	70.19	0.165	0.077	1.41
6	68.58	0.526	0.155	8.83	67.06	0.177	0.080	1.91

Note :

$$Q3_{t+1} = 0.0313 + 0.9268Q3_t$$

$$Q3_{t+2} = 0.0294 + 0.9295Q3_{t+1}$$

$$Q3_{t+3} = 0.0529 + 0.8700Q3_{t+2}$$

$$Q3_{t+4} = 0.0227 + 0.9396Q3_{t+3}$$

$$Q3_{t+5} = 0.0162 + 0.9498Q3_{t+4}$$

$$Q3_{t+6} = 0.0073 + 0.9665Q3_{t+5}$$

ตาราง ข2-4 ผลการพยากรณ์อัตราการไหลน้ำท่ารายวัน ณ สถานี KGT.12 โดยใช้แบบจำลอง MLR

Forecasting day ahead (day)	Training				Testing			
	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)
1	96.15	0.351	0.108	8.93	98.58	0.126	0.069	1.21
2	90.66	0.530	0.184	10.01	96.73	0.182	0.113	1.47
3	87.22	0.601	0.229	10.31	95.05	0.213	0.139	1.48
4	84.64	0.641	0.263	10.33	93.29	0.236	0.160	1.49
5	81.33	0.680	0.289	10.32	91.44	0.252	0.174	1.48
6	77.71	0.722	0.313	10.28	88.94	0.270	0.190	1.50
7	75.68	0.757	0.333	10.83	86.32	0.279	0.204	1.47

Note :

$$Q4_{t+1} = 0.0323 + 0.9491Q4_t$$

$$Q4_{t+2} = 0.0394 + 0.9435Q4_{t+1}$$

$$Q4_{t+3} = 0.0251 + 0.9542Q4_{t+2}$$

$$Q4_{t+4} = 0.0175 + 0.9604Q4_{t+3}$$

$$Q4_{t+5} = 0.0154 + 0.9624Q4_{t+4}$$

$$Q4_{t+6} = 0.0162 + 0.9622Q4_{t+5}$$

$$Q4_{t+7} = 0.0169 + 0.9619Q4_{t+6}$$



ตาราง ข2-5 ผลการพยากรณ์อัตราการไหลน้ำท่ารายวัน ณ สถานี KGT.10 โดยใช้แบบจำลอง MLR

Forecasting day ahead  (day)	Training				Testing			
	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)
1	82.63	0.802	0.291	14.24	88.63	0.438	0.218	3.40
2	66.94	1.094	0.462	13.95	75.25	0.621	0.354	4.15
3	61.19	1.244	0.563	17.26	69.84	0.660	0.421	4.04

Note :  $Q5_{t+1} = 0.1146 + 0.9334Q5_t - 0.0459Q5_{t-1} + 0.0134R5_t + 0.0254R5_{t-1} + 0.0246R5_{t-2}$

$Q5_{t+2} = 0.1634 + 0.6094Q5_{t+1} - 0.2428Q5_t + 0.0329R5_t + 0.0360R5_{t-1}$

$Q5_{t+3} = 0.1023 + 1.0773Q5_{t+2} - 0.1613Q5_{t+1} + 0.0264R5_t$

ตาราง ข2-6 ผลการพยากรณ์อัตราการไหลน้ำท่ารายวัน ณ สถานี KGT.3 โดยใช้แบบจำลอง MLR

Forecasting day ahead  (day)	Training				Testing			
	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)	EI (%)	RMSE (m <sup>3</sup> /s)	MAD (m <sup>3</sup> /s)	Max. Abs. Error (m <sup>3</sup> /s)
1	96.50	1.518	0.559	35.88	98.17	0.925	0.431	12.61
2	91.48	2.296	0.938	39.99	95.64	1.248	0.709	11.27
3	88.38	2.612	1.199	40.46	92.84	1.583	0.909	10.99
4	85.68	2.828	1.357	39.41	91.18	1.778	1.152	10.66
5	82.55	3.045	1.503	42.46	89.18	1.968	1.233	11.32
6	78.73	3.282	1.614	48.87	85.91	2.238	1.327	10.24
7	75.97	3.420	1.727	52.40	83.43	2.495	1.398	12.89

Note :  $Q6_{t+1} = -0.0593 + 1.0918Q6_t - 0.2202Q6_{t-1} + 0.4110Q1_t + 0.0902Q2_t + 0.0587Q3_t + 0.0226Q4_t + 0.2364Q5_t$

$Q6_{t+2} = -0.1790 + 0.0221Q6_{t+1} - 0.7477Q6_t + 0.6577Q1_{t-1} + 0.1821Q2_{t+1} + 0.1121Q3_{t+1} + 0.0340Q4_{t+1} + 0.5348Q5_{t+1}$

$Q6_{t+3} = -0.0803 + 0.7391Q6_{t+2} - 0.1027Q6_{t+1} + 0.3680Q1_{t+2} + 0.5309Q2_{t+2} + 0.0640Q3_{t+2} + 0.1641Q4_{t+2} + 0.3176Q5_{t+2}$

$Q6_{t+4} = -0.4191 + 1.9390Q6_{t+3} - 0.4482Q6_{t+2} + 1.1339Q1_{t+3} + 0.2445Q3_{t+3} + 0.4000Q4_{t+3} + 0.9491Q5_{t+3}$

$Q6_{t+5} = 0.0792 + 1.2382Q6_{t+4} - 0.3062Q6_{t+3} + 0.2278Q1_{t+4} + 0.0221Q3_{t+4} + 0.0544Q4_{t+4}$

$Q6_{t+6} = 0.1986 + 0.0458Q6_{t+5} - 0.7955Q6_{t+4} + 0.4732Q1_{t+5} - 0.0209Q3_{t+5} + 0.1119Q4_{t+5}$

$Q6_{t+7} = 0.3108 + 0.6845Q6_{t+6} - 0.2112Q6_{t+5} + 0.3300Q1_{t+6} + 0.0636Q3_{t+6} + 0.1061Q4_{t+6}$



# ภาคผนวก ซ

การวิเคราะห์  $\Delta Q_{\text{peak}}$  และ  $\Delta T_{\text{peak}}$

สถาบันวิทยบริการ  
จุฬาลงกรณ์มหาวิทยาลัย

ตาราง ข-1 การเปรียบเทียบ  $\Delta Q_{peak}$  ระหว่างข้อมูลที่วัดจริงกับผลการพยากรณ์จากแบบจำลองที่ใช้ในฤดูฝน

สถานี 150401

Date	Observed	1 day ahead			2 days ahead		
		Forecasted	$ \Delta Q_{peak} $	% $\Delta Q_{peak}$	Forecasted	$ \Delta Q_{peak} $	% $\Delta Q_{peak}$
19-Aug-91	194.00	135.93	58.07	29.93	157.77	36.23	18.68
26-Aug-91	192.00	142.20	49.80	25.94	142.56	49.44	25.75
12-Aug-89	168.00	142.04	25.96	15.45	141.14	26.86	15.99
Average	168.00	142.04	25.96	15.45	147.16	37.51	20.14

สถานี KGT.14

Date	Observed	1 day ahead		
		Forecasted	$ \Delta Q_{peak} $	% $\Delta Q_{peak}$
19-Aug-91	120.62	62.58	58.04	48.12
25-Aug-89	78.94	35.12	43.82	55.51
28-Sep-80	75.78	72.79	2.99	3.94
Average	91.78	56.83	34.95	35.86

สถานี KGT.15A

Date	Observed	1 day ahead			2 days ahead		
		Forecasted	$ \Delta Q_{peak} $	% $\Delta Q_{peak}$	Forecasted	$ \Delta Q_{peak} $	% $\Delta Q_{peak}$
12-Aug-89	219.41	200.24	19.17	8.74	226.16	6.75	3.08
26-Jun-89	209.90	235.15	25.25	12.03	203.58	6.32	3.01
28-Aug-91	198.44	175.97	22.47	11.32	135.83	62.61	31.55
Average	209.25	203.79	22.30	10.70	188.52	25.23	12.55

สถานี KGT.12

Date	Observed	1 day ahead			2 days ahead			3 days ahead			4 days ahead			5 days ahead			6 days ahead		
		Forecasted	$ \Delta Q_{peak} $	% $\Delta Q_{peak}$	Forecasted	$ \Delta Q_{peak} $	% $\Delta Q_{peak}$	Forecasted	$ \Delta Q_{peak} $	% $\Delta Q_{peak}$	Forecasted	$ \Delta Q_{peak} $	% $\Delta Q_{peak}$	Forecasted	$ \Delta Q_{peak} $	% $\Delta Q_{peak}$	Forecasted	$ \Delta Q_{peak} $	% $\Delta Q_{peak}$
15-Sep-80	154.70	161.33	6.63	4.28	170.44	15.74	10.17	158.85	4.15	2.68	147.03	7.67	4.96	162.31	7.61	4.92	163.67	8.97	5.80
29-Oct-80	135.58	131.14	4.44	3.27	149.67	14.09	10.39	166.87	31.29	23.08	258.12	122.54	90.38	288.82	153.24	113.02	283.17	147.59	108.86
14-Oct-91	132.54	130.48	2.06	1.56	129.80	2.74	2.07	125.98	6.56	4.95	127.88	4.66	3.52	141.69	9.15	6.90	146.20	13.66	10.30
Average	140.94	140.98	4.38	3.04	149.97	10.86	7.54	150.57	14.00	10.24	177.67	44.96	32.95	197.60	56.66	41.51	197.68	56.74	41.65

สถานี KGT.10

Date	Observed	1 day ahead			2 days ahead			3 days ahead		
		Forecasted	$ \Delta Q_{peak} $	% $\Delta Q_{peak}$	Forecasted	$ \Delta Q_{peak} $	% $\Delta Q_{peak}$	Forecasted	$ \Delta Q_{peak} $	% $\Delta Q_{peak}$
11-Oct-91	301.00	311.03	10.03	3.33	277.41	23.59	7.84	267.12	33.88	11.25
27-Sep-91	273.00	260.84	12.16	4.45	239.79	33.21	12.16	224.74	48.26	17.68
13-Sep-80	226.04	203.51	22.53	9.97	184.39	41.65	18.43	189.91	38.13	15.99
Average	266.68	258.46	14.91	5.92	233.86	32.82	12.81	227.26	39.42	14.97

สถานี KGT.3

Date	Observed	1 day ahead			2 days ahead			3 days ahead			4 days ahead			5 days ahead			6 days ahead			7 days ahead		
		Forecasted	$ \Delta Q_{peak} $	% $\Delta Q_{peak}$	Forecasted	$ \Delta Q_{peak} $	% $\Delta Q_{peak}$	Forecasted	$ \Delta Q_{peak} $	% $\Delta Q_{peak}$	Forecasted	$ \Delta Q_{peak} $	% $\Delta Q_{peak}$	Forecasted	$ \Delta Q_{peak} $	% $\Delta Q_{peak}$	Forecasted	$ \Delta Q_{peak} $	% $\Delta Q_{peak}$	Forecasted	$ \Delta Q_{peak} $	% $\Delta Q_{peak}$
15-Aug-89	602.10	587.85	14.25	2.37	573.04	29.06	4.83	576.22	25.88	4.30	585.93	16.17	2.69	598.46	3.64	0.61	623.35	21.25	3.53	686.73	84.63	14.06
21-Aug-91	572.00	584.32	12.32	2.15	558.75	13.25	2.32	568.58	3.42	0.60	611.69	39.69	6.94	640.30	68.30	11.94	656.10	84.10	14.70	686.34	94.34	16.49
31-Aug-91	554.90	572.79	17.89	3.22	559.83	4.93	0.89	596.30	41.40	7.46	571.51	16.61	2.99	566.99	12.09	2.18	562.24	7.34	1.32	542.33	12.57	2.26
Average	576.33	581.66	14.82	2.58	563.87	15.75	2.68	580.37	23.57	4.12	589.71	24.16	4.21	601.91	28.01	4.91	613.89	37.56	6.52	631.80	63.85	10.94

ตาราง ข-2 การเปรียบเทียบ  $\Delta T_{peak}$  ระหว่างข้อมูลที่วัดจริงกับผลการพยากรณ์จากแบบจำลองที่ใช้ในฤดูฝน

สถานี 150401

Event	Date	Observed	1 day ahead	2 days ahead
1	18-Aug-91	154.00	79.57	95.74
	19-Aug-91	122.00	126.74	110.18
	20-Aug-91	168.00		
	21-Aug-91	96.00	126.23	117.07
2	27-Aug-91	101.00	71.52	72.61
	28-Aug-91	132.00	87.55	85.36
	29-Aug-91	115.00		
	30-Aug-91	90.00	105.50	102.89
3	11-Aug-89	164.00	18.81	16.62
	12-Aug-89	169.00	119.41	104.60
	13-Aug-89	102.00		
	14-Aug-89	73.60	85.74	80.65

สถานี KGT.14

Event	Date	Observed	1 day ahead
1	17-Aug-91	12.97	15.70
	18-Aug-91	51.42	23.38
	19-Aug-91		
	20-Aug-91	30.95	45.25
	24-Aug-89	8.02	3.27
2	25-Aug-89	7.00	29.11
	26-Aug-89	16.52	35.12
	27-Aug-89	8.02	11.94
3	27-Sep-80	26.58	20.60
	28-Sep-80		
	29-Sep-80	44.35	44.68
	30-Sep-80	49.75	35.76

สถานี KGT.15A

Event	Date	Observed	1 day ahead	2 days ahead
1	11-Aug-89	187.35	191.67	93.48
	12-Aug-89	219.77	200.20	225.00
	13-Aug-89	157.50	157.77	109.51
	14-Aug-89	104.52	89.99	119.89
2	25-Jun-89	3.98	4.78	1.81
	26-Jun-89	209.90	68.43	7.08
	27-Jun-89	112.53	235.15	203.58
	28-Jun-89	26.08	58.28	69.70
3	27-Aug-91	36.13	42.92	32.16
	28-Aug-91	188.77	61.92	48.93
	29-Aug-91	169.96		
	30-Aug-91	78.60	110.34	105.71

สถานี KGT.12

Event	Date	Observed	1 day ahead	2 days ahead	3 days ahead	4 days ahead	5 days ahead	6 days ahead
1	14-Sep-80	145.00	131.58	123.61	116.01	94.13	118.77	87.92
	15-Sep-80	152.00	152.98	138.99	144.38	122.16	160.48	
	16-Sep-80	132.14	154.77	170.44	159.88	141.03	162.21	163.88
	17-Sep-80	108.30	112.14	117.58	154.09	145.97	134.31	143.54
2	27-Oct-80	131.38	124.44	91.02	218.65	114.07	112.74	130.65
	28-Oct-80	135.00	137.00	149.67	54.64	50.09	59.39	110.21
	29-Oct-80	117.70	130.48	112.31				
	30-Oct-80	75.96	98.32	113.19	85.01	19.23	26.56	72.19
3	13-Oct-91	131.58	127.84	122.35	114.89	123.43	113.84	131.43
	14-Oct-91				123.91	116.20	117.48	110.64
	15-Oct-91	120.54	123.52	121.12				
	16-Oct-91	101.10	105.33	104.96	102.91	116.81	125.08	112.21

สถานี KGT.10

Event	Date	Observed	1 day ahead	2 days ahead	3 days ahead
1	10-Oct-91	227.20	187.31	180.92	176.56
	11-Oct-91	207.00	248.53	226.77	216.62
	12-Oct-91	277.40	311.60	277.41	267.12
	13-Oct-91	164.40	227.65	249.59	256.38
2	26-Sep-91	240.00	202.33	196.01	201.92
	27-Sep-91	279.00	239.46	209.00	224.74
	28-Sep-91	223.20	260.63	239.79	208.27
	29-Sep-91	161.20	192.77	229.19	219.47
3	12-Sep-80	205.06	179.50	150.73	134.11
	13-Sep-80	226.04	188.71	184.00	169.91
	14-Sep-80	178.16	203.53	181.96	184.76
	15-Sep-80	71.92	138.09	168.18	158.01

สถานี KGT.3

Event	Date	Observed	1 day ahead	2 days ahead	3 days ahead	4 days ahead	5 days ahead	6 days ahead	7 days ahead
1	14-Aug-89	573.20	577.74	553.01	550.73	487.35	469.06	408.75	372.94
	15-Aug-89	602.10	587.65	573.03	576.22	585.93	598.46	600.97	572.60
	16-Aug-89	592.40	572.69	569.98	557.20	556.60	546.10	623.15	685.74
	17-Aug-89	544.80	534.54	550.33	554.76	532.33	575.73	507.66	605.75
2	20-Aug-91	532.40	531.75	528.84	425.14	586.54	480.25	389.04	529.03
	21-Aug-91				568.58	401.90	618.74	537.69	417.63
	22-Aug-91	568.40	560.89	546.68	537.33		440.31	656.70	595.01
	23-Aug-91	555.80	553.27	530.39	540.15	521.95	406.65	402.99	666.24
3	24-Aug-91	526.10	523.49	540.44	503.95	527.33	498.28	629.93	370.35
	30-Aug-91	531.50	554.54	559.72	499.56	449.37	448.58	493.60	370.46
	31-Aug-91				566.30	542.97	493.07	485.54	507.22
	1-Sep-91	546.80	537.03	519.92	525.25		566.93	520.77	542.33
	2-Sep-91	523.40	510.73	528.24	488.72	492.08	538.37		529.65
3-Sep-91	489.20	474.65	482.02	510.22	472.71	445.70	499.31	533.02	

บริการ  
วิทยาลัย

## ประวัติผู้เขียนวิทยานิพนธ์

ชื่อ นายธนพล พิमान

เกิด 30 เมษายน 2522 อ.เมือง จ.สุราษฎร์ธานี

### การศึกษา

- พ.ศ. 2536 สำเร็จการศึกษาระดับมัธยมศึกษา จากโรงเรียนสุราษฎร์ธานี  
จ.สุราษฎร์ธานี
- พ.ศ. 2538 สำเร็จการศึกษาระดับมัธยมศึกษา จากศูนย์การศึกษานอกโรงเรียน  
จ.สุราษฎร์ธานี
- พ.ศ.2542 สำเร็จการศึกษาปริญญาตรี สาขาวิศวกรรมโยธา คณะวิศวกรรมศาสตร์  
จากมหาวิทยาลัยสงขลานครินทร์ วิทยาเขตหาดใหญ่ จ.สงขลา
- พ.ศ.2545 สำเร็จการศึกษาปริญญาโท ภาควิชาวิศวกรรมแหล่งน้ำ  
คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

### ประสบการณ์ทำงาน

- พ.ศ.2544 ผู้ช่วยวิจัย โครงการ The Master Plan Study for The Coastal  
Channels and Development in The Kingdom of Thailand สถาบัน  
พณิชยนาวิ จุฬาลงกรณ์มหาวิทยาลัย
- พ.ศ.2545 ผู้ช่วยวิจัย โครงการศึกษาเพื่อจัดทำแผนปฏิบัติการแก้ไขผลกระทบ ด้าน  
ชลศาสตร์และการกัดเซาะตลิ่งอันเนื่องจาก เขื่อนทดน้ำบางปะกง  
จ.ฉะเชิงเทรา เสนอ กรมชลประทาน กระทรวงเกษตรและสหกรณ์