



รายงานวิจัยฉบับสมบูรณ์

โครงการวิจัย

เรื่อง

การพัฒนาระบบคาดการณ์ปริมาณฝนรายสองสัปดาห์
เพื่อการบริหารจัดการน้ำในพื้นที่ลุ่มน้ำเจ้าพระยา

Development of a two-week rainfall forecasting system
for water management in the Chao Phraya River Basin

โดย

นางสาวกนกศรี ศรีนินภากร และคณะ
สถาบันสารสนเทศทรัพยากรน้ำ (องค์การมหาชน)

พฤศจิกายน พ.ศ. 2563

รายงานวิจัยฉบับสมบูรณ์

โครงการ

การพัฒนาระบบคาดการณ์ปริมาณฝนรายสัปดาห์

เพื่อการบริหารจัดการน้ำในพื้นที่ลุ่มน้ำเจ้าพระยา

Development of a two-week rainfall forecasting system

for water management in the Chao Phraya River Basin

ดร. กนกศรี ศรีนนทการ	หัวหน้าโครงการ	สถาบันสารสนเทศทรัพยากรน้ำ (องค์การมหาชน)
อ.ดร.ปิยธิดา เรืองรัมย์	ผู้ร่วมโครงการ	จุฬาลงกรณ์มหาวิทยาลัย
ดร.วินัย เซาว์วิวัฒน์	ผู้ร่วมโครงการ	สถาบันสารสนเทศทรัพยากรน้ำ (องค์การมหาชน)
นายกฤษณัย ต่อศรี	ผู้ร่วมโครงการ	สถาบันสารสนเทศทรัพยากรน้ำ (องค์การมหาชน)
Dr. Nosha Assare	ผู้ร่วมโครงการ	สถาบันสารสนเทศทรัพยากรน้ำ (องค์การมหาชน)
นายอชิป ปีทอง	ผู้ร่วมโครงการ	สถาบันสารสนเทศทรัพยากรน้ำ (องค์การมหาชน)
นายรติ สว่างวัฒนไพบูลย์	ผู้ร่วมโครงการ	สถาบันสารสนเทศทรัพยากรน้ำ (องค์การมหาชน)
Mr. Le Ngoc Hieu	ผู้ร่วมโครงการ	สถาบันสารสนเทศทรัพยากรน้ำ (องค์การมหาชน)
นางสาวสุกัลลักษณ์ วิมาลา	ผู้ร่วมโครงการ	สถาบันสารสนเทศทรัพยากรน้ำ (องค์การมหาชน)
นางอังคณา จินวงษ์	ผู้ร่วมโครงการ	สถาบันสารสนเทศทรัพยากรน้ำ (องค์การมหาชน)

ที่ปรึกษาโครงการ

Prof. Dr. Zhaohui Lin Institute of Atmospheric Physics (IAP)

ดร.สุรเจตส์ บุญญาอรุณเนตร สถาบันสารสนเทศทรัพยากรน้ำ (องค์การมหาชน)

แผนงานยุทธศาสตร์เป้าหมายด้านสังคม แผนการบริหารจัดการน้ำ
แผนงานวิจัยที่ 3 พัฒนาเทคโนโลยีและสนับสนุนด้านพฤติกรรมผู้ใช้น้ำ

สนับสนุนโดยสำนักงานคณะกรรมการส่งเสริมวิทยาศาสตร์ วิจัยและนวัตกรรม (สกสว.)

(ความเห็นในรายงานนี้เป็นของผู้วิจัย สกสว. ไม่จำเป็นต้องเห็นด้วยเสมอไป)

บทสรุปผู้บริหาร

การคาดการณ์ปริมาณฝนเป็นเครื่องมือที่สำคัญอย่างมากในการบริหารจัดการน้ำ โดยเฉพาะการคาดการณ์ปริมาณฝนรายสองสัปดาห์นั้นมีความสำคัญและท้าทาย เนื่องจากระยะเวลาสองสัปดาห์เป็นระยะเวลาที่นานมากพอในการปรับตัวหรือเปลี่ยนแปลงการปฏิบัติงานที่จะช่วยป้องกันหรือบรรเทาความเสียหายที่อาจเกิดขึ้นจากสภาพอากาศที่รุนแรงได้ ในปัจจุบันการคาดการณ์ล่วงหน้ารายสองสัปดาห์ยังอยู่ในขั้นตอนการวิจัยและพัฒนา เพราะปัจจัยที่เกี่ยวข้องที่สามารถใช้คาดการณ์ฝนระยะเวลาสองสัปดาห์ให้มีความถูกต้องยังไม่ชัดเจนมากนัก และประเทศไทยก็ยังไม่มียุทธศาสตร์ปริมาณน้ำฝนรายสองสัปดาห์เพื่อใช้งานกับการบริหารจัดการน้ำโดยตรง สถาบันสารสนเทศทรัพยากรน้ำ (องค์การมหาชน) หรือ สสน. จึงได้รับการสนับสนุนทุนวิจัยจากสำนักงานคณะกรรมการส่งเสริมวิทยาศาสตร์ วิจัยและนวัตกรรม (สกสว.) เป็นระยะเวลา 1 ปี ให้วิจัยและพัฒนาระบบคาดการณ์ปริมาณฝนรายสองสัปดาห์เพื่อใช้บริหารจัดการน้ำในพื้นที่ลุ่มน้ำเจ้าพระยา โดยเริ่มตั้งแต่วันที่ 26 สิงหาคม 2562 ถึง วันที่ 25 สิงหาคม 2563 การเน้นที่ลุ่มน้ำเจ้าพระยาก็ก็เนื่องจากว่าลุ่มน้ำเจ้าพระยาเป็นลุ่มน้ำหลักและสำคัญที่สุดของประเทศไทย ปัญหาเรื่องน้ำและความเสียหายที่เกิดขึ้นส่วนใหญ่มักเกี่ยวข้องกับลุ่มน้ำนี้

ขั้นตอนแรกของการศึกษาคือการประเมินผลเปรียบเทียบการคาดการณ์ฝนรายสองสัปดาห์จาก European Centre for Medium-range Weather Forecasts (ECMWF) และ National Centers for Environmental Prediction (NCEP) ซึ่งพบว่าผลคาดการณ์ฝน CFSv2 (Climate Forecast System) จาก NCEP มีความเหมาะสมกับการนำมาประยุกต์เพื่อใช้งานจริงสำหรับประเทศไทยมากกว่าข้อมูลจากโครงการ Sub-seasonal to seasonal (S2S) ECMWF ทั้งนี้เป็นเพราะข้อมูลการคาดการณ์ฝน S2S ECMWF ยังอยู่ในขั้นวิจัย และเสียค่าใช้จ่ายค่อนข้างสูงหากจะนำมาใช้ ส่วนข้อมูล CFSv2 เป็นข้อมูลเปิดที่ใช้ในการคาดการณ์ในทางปฏิบัติอยู่แล้ว ผลการประเมินการคาดการณ์ฝนรายสองสัปดาห์ของ CFSv2 สำหรับลุ่มน้ำเจ้าพระยาในช่วงปี พ.ศ. 2555 ถึง 2560 ให้ค่าสัมประสิทธิ์สหสัมพันธ์ระหว่างฝนจากแบบจำลองและฝนตรวจวัดเฉลี่ยมากกว่า 0.80 แต่ค่าคาดการณ์ปริมาณฝนเชิงพื้นที่ซึ่งมีความคลาดเคลื่อนอยู่พอสมควร จึงจำเป็นต้องปรับปรุง การวิจัยเพื่อเพิ่มประสิทธิภาพการคาดการณ์ฝนได้พิจารณาสามแนวทางคือ 1) การพัฒนาวิธีการเพิ่มประสิทธิภาพการคาดการณ์ด้วยแบบจำลองคู่ควบ (WRF-ROMS) ซึ่งเป็นแบบจำลองเชิงคณิตศาสตร์ที่ใช้หลักการทางพลวัตและฟิสิกส์โดยอาศัยปฏิสัมพันธ์ระหว่างแบบจำลองบรรยากาศและมหาสมุทร 2) การพัฒนาวิธีการปรับความคลาดเคลื่อนด้วยวิธีทางสถิติโดยอาศัยการศึกษาความสัมพันธ์ระหว่างฝนตรวจวัดและฝนแบบจำลองจากข้อมูลในอดีต และ 3) การพัฒนาวิธีการเพิ่มประสิทธิภาพการคาดการณ์ฝนโดยอาศัยวิธี Machine learning กับวิธีการ Hybrid ที่ผสมผสานการศึกษาข้อมูลต่าง ๆ

ที่เกี่ยวกับการเปลี่ยนแปลงของฝน ร่วมกับการศึกษาพลวัตและความสัมพันธ์ของตัวแปรทางฟิสิกส์บรรยากาศอื่น ๆ

จากการศึกษาการเพิ่มประสิทธิภาพการคาดการณ์ทั้งสามวิธีในเบื้องต้น พบว่า การเพิ่มประสิทธิภาพการคาดการณ์ด้วยแบบจำลองเชิงคณิตศาสตร์ที่ใช้หลักการทางพลวัตและฟิสิกส์โดยแบบจำลองคู่ควบ (WRF-ROMS) และการใช้วิธี Machine learning ด้วยการ Hybrid ต่างเป็นวิธีการที่ต้องใช้ข้อมูลจำนวนมาก การประมวลผลต้องอาศัยระบบคอมพิวเตอร์สมรรถนะสูงตลอดจนระยะเวลาในการคำนวณค่าจากแบบจำลองค่อนข้างนาน ดังนั้น การเพิ่มประสิทธิภาพการคาดการณ์ฝนรายสองสัปดาห์สำหรับโครงการปีแรกนี้ จะใช้การปรับความคลาดเคลื่อนด้วยวิธีทางสถิติ โดยการศึกษาความสัมพันธ์ระหว่างฝนตรวจวัดและฝนแบบจำลอง CFSv2 ของข้อมูลในอดีต และนำความรู้นั้นมาใช้ทำ Bias Correction ให้กับค่าที่คาดการณ์จากแบบจำลอง CFSv2 ด้วยวิธี Linear Scaling

การประเมินผลการปรับความคลาดเคลื่อนด้วยวิธีทางสถิติชี้ว่า ค่าสัมประสิทธิ์สหสัมพันธ์ระหว่างค่าฝนคาดการณ์หลังปรับความคลาดเคลื่อนและค่าฝนตรวจวัดจริงยังคงมีค่าสูงกว่า 0.80 ในขณะที่ความคลาดเคลื่อนของการคาดการณ์ฝนเฉลี่ยเชิงพื้นที่ลดลง โดยมีความผิดพลาดไม่เกิน 25 มม. ต่อสองสัปดาห์ เมื่อเทียบกับก่อนปรับค่าความคลาดเคลื่อนที่มีความผิดพลาดของการคาดการณ์ฝนเฉลี่ยเชิงพื้นที่ประมาณ 60-65 มม. ต่อสองสัปดาห์ เช่น ในการคาดการณ์ฝนของปี พ.ศ. 2561 และ 2562 สามารถลดความคลาดเคลื่อนของฝนจากแบบจำลอง CFSv2 ได้ประมาณ 35-40 มม. ต่อสองสัปดาห์

ทีมวิจัยได้พัฒนาระบบคาดการณ์ฝนรายสองสัปดาห์และใช้งานอยู่ในปัจจุบัน ทั้งนี้ ระบบจะคาดการณ์ฝนรายสองสัปดาห์ทุกวันจันทร์ เพื่อสนับสนุนผลการคาดการณ์ฝนให้กับทีมวิจัยอื่น ๆ สำหรับใช้กับแบบจำลองด้านน้ำต่าง ๆ เช่น นำไปใช้ในการประมาณปริมาณน้ำเข้าเขื่อนเพื่อใช้ในการบริหารจัดการเขื่อนให้มีประสิทธิภาพมากยิ่งขึ้น กล่าวโดยสรุป ผลการดำเนินการตามโครงการวิจัยนี้ได้บรรลุวัตถุประสงค์ของโครงการที่ได้กำหนดไว้ตามแผนทุกประการ ระบบที่พัฒนาไม่ได้ใช้กับลุ่มน้ำเจ้าพระยาเท่านั้น แต่ใช้ครอบคลุมพื้นที่ทั่วประเทศด้วย นอกจากนี้ ระบบดังกล่าวยังสามารถคาดการณ์ฝนระยะสั้น 3-7 วัน และรายเดือนถึงรายฤดูกาล ซึ่งทาง สสน. ได้จัดทำข้อมูลเหล่านี้ อันเป็นการสนับสนุนทีมวิจัยกลุ่มอื่นได้นำไปใช้ประโยชน์ต่อไป

บทคัดย่อ

การคาดการณ์ปริมาณฝนเป็นสิ่งจำเป็นมากสำหรับการบริหารจัดการน้ำเพื่อรับมือกับความไม่แน่นอนของสภาพภูมิอากาศ งานวิจัยนี้เป็นการศึกษาและพัฒนากระบวนการฝนรายสัปดาห์เพื่อการบริหารจัดการน้ำของกลุ่มน้ำเจ้าพระยา โดยพิจารณา 3 แนวทางคือ 1) การใช้แบบจำลองเชิงคณิตศาสตร์ที่ใช้หลักการทางพลวัตและฟิสิกส์ ได้แก่ แบบจำลองคู่ควบ (WRF-ROMS) ซึ่งเป็นแบบจำลองที่อาศัยปฏิสัมพันธ์ระหว่างแบบจำลองบรรยากาศและมหาสมุทร 2) การพัฒนาวิธีการปรับความคลาดเคลื่อนของการคาดการณ์ด้วยวิธีทางสถิติโดยอาศัยความสัมพันธ์ระหว่างฝนตรวจวัดและฝนจากแบบจำลองเมื่อใช้ข้อมูลในอดีต และ 3) การเพิ่มประสิทธิภาพการคาดการณ์ฝนโดยใช้วิธีแบบผสม (hybrid) ระหว่างแบบจำลองเชิงคณิตศาสตร์กับวิธี Machine Learning ผลการศึกษาพบว่า การใช้แบบจำลองที่ใช้หลักการทางฟิสิกส์และวิธีแบบผสมต้องมีข้อมูลจำนวนมาก ใช้ระบบคอมพิวเตอร์สมรรถนะสูง และเวลาในการคำนวณค่าจากแบบจำลองค่อนข้างนาน สำหรับโครงการปีแรก จึงใช้วิธีการปรับความคลาดเคลื่อนด้วยวิธีทางสถิติ

การประเมินผลคาดการณ์ฝนที่ใช้วิธีการปรับความคลาดเคลื่อนชี้ว่า การปรับผลคาดการณ์ฝนจากแบบจำลอง CFSv2 (Climate Forecast System) ของ National Centers for Environmental Prediction มีความเหมาะสมกับการใช้งานจริงสำหรับประเทศไทยมากกว่าข้อมูลจากโครงการ S2S European Centre for Medium-range Weather Forecasts (ECMWF) เพราะข้อมูลการคาดการณ์ฝน S2S ECMWF ยังอยู่ในขั้นวิจัย และการใช้ข้อมูลเพื่อคาดการณ์จริงต้องเสียค่าใช้จ่ายค่อนข้างสูง ส่วนข้อมูล CFSv2 เป็นข้อมูลเปิดที่ใช้คาดการณ์ในทางปฏิบัติอยู่แล้ว เมื่อใช้ CFSv2 ค่าสัมประสิทธิ์สหสัมพันธ์ระหว่างฝนจากแบบจำลองและฝนตรวจวัดสูงกว่า 0.80 แต่ค่าคาดการณ์ปริมาณฝนเชิงพื้นที่ที่มีความคลาดเคลื่อนมาก จึงปรับความคลาดเคลื่อนโดยอาศัยความสัมพันธ์ระหว่างฝนตรวจวัดและฝนจากแบบจำลอง ในการคาดการณ์ฝนของปี พ.ศ. 2561 และ 2562 การทำ Bias Correction ด้วยวิธี Linear Scaling กับผลคาดการณ์จากแบบจำลอง CFSv2 สามารถให้ความผิดพลาดของการคาดการณ์ฝนเฉลี่ยเชิงพื้นที่ไม่เกิน 25 มม. ต่อสองสัปดาห์ โดยสามารถลดความคลาดเคลื่อนของฝนจากแบบจำลอง CFSv2 ได้ถึง 35-40 มม. ต่อสองสัปดาห์ ทีมวิจัยยังได้พัฒนาระบบคาดการณ์ฝนรายสัปดาห์และนำเสนอผลในรูปแบบแผนที่บนเว็บไซต์ และ ESRI ascii และ text ไฟล์ ผ่านทาง FTP ของสถาบันสารสนเทศทรัพยากรน้ำ (องค์การมหาชน) โดยได้คาดการณ์ฝนล่วงหน้าเป็นประจำทุกสัปดาห์ เพื่อเป็นข้อมูลสนับสนุนการบริหารจัดการน้ำต่อไป

คำสำคัญ การคาดการณ์ฝนล่วงหน้าสองสัปดาห์ การปรับความคลาดเคลื่อน การบริหารจัดการน้ำ

ABSTRACT

Rain forecasts are essential for water management to cope with climate uncertainty. This research aimed to study and develop a bi-weekly rain forecasting system for water management of the Chao Phraya River Basin by considering 3 approaches: 1) using numerical models that utilize the principles of dynamics and physics. An example is the coupled model (WRF-ROMS), which is a model based on the interaction between the atmosphere and the ocean models, 2) developing a bias correction method to reduce forecast error using statistical techniques. The forecasts are adjusted based on the relationship between rain measurements and rain from a model when using historical data, and 3) improving the performance of rain prediction by using a hybrid method between a numerical model and machine learning. The study showed that the use of physics-based models and hybrid methods requires a large amount of data, a high-performance computer system, and a long computation time to get values from the model. Therefore, in the first year of the project, bias correction by some statistical methods was employed.

Evaluation of rain forecasts after bias correction indicated that rainfall forecasts from the National Centers for Environmental Prediction model CFSv2 (Climate Forecast System) were more appropriate for use in correction process for Thailand than those from the S2S European Center for Medium-range Weather Forecasts (ECMWF). S2S ECMWF rainfall forecast is still in the research stage, and using its data to make actual predictions is costly. CFSv2 data, on the other hand, is available to public and is being used for forecast in practice. The bias correction is based on the relationship between rain measurements and rain from the model. When using CFSv2 data, the correlation coefficient between rain from the model and the rain measurements was higher than 0.80, but the areal rainfall forecast was very inaccurate. When forecasting 2018 and 2019 rainfall, the bias correction by linear scaling with the forecast results from the CFSv2 model yielded the average areal rainfall having forecast error not more than 25 mm per two weeks. This reduced the error of rain forecast from the CFSv2 model by 35-40 mm per two weeks. The research team also developed a bi-weekly rain forecasting system and presented the

results in the form of web-based and ESRI ascii maps as well as text files via the FTP of Water Resources Institute (Public Organization). The forecasts are reported on a weekly basis to support water management.

Keywords: Bi-weekly rainfall forecast, bias correction, water management

สารบัญ

	หน้า
บทสรุปผู้บริหาร	ก
บทคัดย่อ	ค
Abstract	ง
สารบัญ	ฉ
สารบัญตาราง	ช
สารบัญรูป	ญ
บทที่ 1 บทนำ	1
1.1 ความเป็นมาและความสำคัญ	1
1.2 วัตถุประสงค์งานวิจัย	3
1.3 ผลที่คาดว่าจะได้รับเมื่อสิ้นสุดการวิจัย	3
1.4 ผังการดำเนินงาน	4
1.5 การดำเนินการวิจัยปีที่ 1	4
1.6 แนวทางดำเนินการในปีที่ 2	4
บทที่ 2 การทบทวนวรรณกรรม	6
2.1 โครงการ Sub-seasonal to seasonal (S2S) prediction project	6
2.2 การทบทวนวรรณกรรมการปรับแก้ความเอนเอียงเชิงสถิติของการคาดการณ์ฝน	9
2.3 การทบทวนวรรณกรรมการคาดการณ์สภาพอากาศแบบผสม (Hybrid methods)	16
บทที่ 3 การเพิ่มประสิทธิภาพการคาดการณ์ฝนโดยใช้แบบจำลองคู่ควบ WRF-ROMS	20
3.1 แบบจำลองคู่ควบ WRF-ROMS	20
3.2 ขอบเขตพื้นที่ศึกษาและการกำหนดค่าแบบจำลอง	21
3.3 การออกแบบและขอบเขตการวิจัยและการติดตั้งแบบจำลอง	23
3.4 การตรวจสอบความถูกต้องของแบบจำลองด้วยวิธีการทางสถิติ	24
3.5 การประเมินผลความแม่นยำของระบบคู่ควบ WRF-ROMS ที่ความละเอียด 25 กม.	26
3.6 ผลการประเมินความแม่นยำของแบบจำลองด้วยวิธีการ Nesting ที่ความละเอียด 5 กม.	43
บทที่ 4 การเพิ่มประสิทธิภาพการคาดการณ์ฝน โดยใช้วิธีปรับความคลาดเคลื่อนด้วยวิธีทางสถิติ	48
4.1 วิธีการปรับความคลาดเคลื่อนด้วยวิธีทางสถิติ	48

4.2	ผลการปรับค่าความคลาดเคลื่อนในช่วง Training	50
4.3	การตรวจสอบผลการปรับค่าความคลาดเคลื่อน	52
4.4	ผลการปรับค่าความคลาดเคลื่อนรายลุ่มน้ำ	57
บทที่ 5	สรุปผลและข้อเสนอแนะ	69
5.1	สรุปผลการดำเนินงาน	69
5.2	ข้อเสนอแนะ	71
	เอกสารอ้างอิง	72
	ภาคผนวก	77

สารบัญตาราง

	หน้า
ตารางที่ 1.1 ชุดข้อมูลที่ใช้ในการศึกษา	5
ตารางที่ 2.1 ข้อมูลแบบจำลอง ณ ปัจจุบัน ของ S2S project	7
ตารางที่ 2.2 รายละเอียดพื้นฐานของ CFSv1 และ CFSv2	9
ตารางที่ 2.3 Anomaly correlation ของการคาดการณ์ค่าเฉลี่ยรายฤดูกาล 3 เดือน สำหรับ lead time 0.5 เดือน ในช่วงปีค.ศ. 1982 – 2010 จาก 7 แบบจำลองภายใต้โครงการ U.S. National Multimodel Ensemble (NMME) และ equal-weight NMME	10
ตารางที่ 2.4 ค่าเฉลี่ยของ spatial correlations ของค่า precipitation anomalies ระหว่างการตรวจวัด และการคาดการณ์จาก GFS ล่วงหน้า 1 สัปดาห์ และ 2 สัปดาห์	12
ตารางที่ 2.5 ค่าเฉลี่ยของ RMSE ของค่า precipitation ระหว่างการตรวจวัด และการคาดการณ์จาก GFS ล่วงหน้า 1 สัปดาห์ และ 2 สัปดาห์ (มม./สัปดาห์)	12
ตารางที่ 2.6 วิธีการและรูปแบบของการทำ bias corrections และข้อมูลที่ใช้	15
ตารางที่ 2.7 สรุปวิธีการทาง machine learning สำหรับการเพิ่มประสิทธิภาพการคาดการณ์ฝน	19
ตารางที่ 3.1 การทดสอบความไวของแบบจำลองที่มีต่อข้อมูลเริ่มต้น/ค่าขอบ (Initial & lateral boundary conditions: ICBC) และ ฟิสิกส์ที่เกี่ยวข้องกับการคำนวณเมฆฝน (Cumulus schemes: CU option)	24
ตารางที่ 4.1 ค่าต่ำสุด ค่าสูงสุด และค่าเฉลี่ยของปริมาณฝนคาดการณ์และฝนตรวจวัด และผลการวิเคราะห์ประสิทธิภาพของการคาดการณ์เมื่อเทียบกับค่าตรวจวัด ปี 2555-2560	50
ตารางที่ 4.2 ผลการวิเคราะห์ Bias Correction CFSV2 ณ สถานีเถิน จังหวัดลำปาง ปี 2555-2560	52
ตารางที่ 4.3 ผลการวิเคราะห์ Bias Correction CFSV2 ณ สถานีเขื่อนภูมิพล จังหวัดตาก ปี 2555-2560	52
ตารางที่ 4.4 ค่าต่ำสุด ค่าสูงสุด และค่าเฉลี่ยของปริมาณฝนคาดการณ์และฝนตรวจวัด ปี 2561-2562	53
ตารางที่ 4.5 ผลการวิเคราะห์ Bias Correction CFSV2 ปี 2561-2562	54
ตารางที่ 4.6 ผลการวิเคราะห์ Bias Correction CFSV2 ณ สถานีเถิน จังหวัดลำปาง ปี 2561-2562	56
ตารางที่ 4.7 ผลการวิเคราะห์ Bias Correction CFSV2 ณ สถานีเขื่อนภูมิพล จังหวัดตาก ปี 2561-2562	57
ตารางที่ 4.8 ผลการปรับลดความคลาดเคลื่อนของฝนคาดการณ์รายสองสัปดาห์จาก CFSV2 ในพื้นที่ลุ่มน้ำปิงและลุ่มน้ำสาขา แสดงด้วยค่า RMSE	59
ตารางที่ 4.9 ผลการปรับลดความคลาดเคลื่อนของฝนคาดการณ์รายสองสัปดาห์จาก CFSV2 ในพื้นที่ลุ่มน้ำวังและลุ่มน้ำสาขา แสดงด้วยค่า RMSE	60

ตารางที่ 4.10 ผลการปรับลดความคลาดเคลื่อนของฝนคาดการณ์รายสองสัปดาห์จาก CFSV2 ในพื้นที่ลุ่มน้ำยมและลุ่มน้ำสาขา แสดงด้วยค่า RMSE	62
ตารางที่ 4.11 ผลการปรับลดความคลาดเคลื่อนของฝนคาดการณ์รายสองสัปดาห์จาก CFSV2 ในพื้นที่ลุ่มน้ำน่านและลุ่มน้ำสาขา แสดงด้วยค่า RMSE	64
ตารางที่ 4.12 ผลการปรับลดความคลาดเคลื่อนของฝนคาดการณ์รายสองสัปดาห์จาก CFSV2 ในพื้นที่ลุ่มน้ำเจ้าพระยา สะแกกรัง ป่าสัก ท่าจีนและลุ่มน้ำสาขา แสดงด้วยค่า RMSE	68

สารบัญรูป

	หน้า
รูปที่ 1.1 ประสิทธิภาพการคาดการณ์สภาพอากาศตามคาบเวลาต่าง ๆ	1
รูปที่ 1.2 พื้นที่ศึกษาลุ่มน้ำเจ้าพระยา	3
รูปที่ 1.3 ผังการดำเนินงาน	4
รูปที่ 2.1 Website ECMWF	8
รูปที่ 2.2 5-day running mean spatial correlation และ RMSE ของ precipitation anomalies ใน 4 ภูมิภาค	11
รูปที่ 2.3 ค่าเฉลี่ยรายปีของ forecasted precipitation errors จากการคาดการณ์ล่วงหน้า 1 สัปดาห์ และ 2 สัปดาห์ ใน 4 ภูมิภาค (มม./สัปดาห์)	13
รูปที่ 3.1 ระบบแบบจำลองพลวัต COAWST ที่พัฒนาโดย USGS	21
รูปที่ 3.2 พื้นที่ศึกษาของแบบจำลอง ก) WRF (Non-nesting) และ ROMS และ ข) WRF nesting จาก 25 กม. เป็น 5 กม.	22
รูปที่ 3.3 (ก) ฝนสะสมช่วงเกิดเหตุการณ์ และ (ข) TCC ระหว่างแบบจำลอง WRF-ROMS และค่าตรวจวัด และค่าที่ได้จาก S2S ECMWF ในช่วง Lead-1 (ค่าเริ่มต้น : 13 มิถุนายน 2554)	29
รูปที่ 3.4 (ก) ฝนสะสมช่วงเกิดเหตุการณ์ และ (ข) TCC ระหว่างแบบจำลอง WRF-ROMS และค่าตรวจวัด และค่าที่ได้จาก S2S ECMWF ในช่วง Lead-0 (ค่าเริ่มต้น : 20 มิถุนายน 2554)	30
รูปที่ 3.5 (ก) ฝนสะสมช่วงเกิดเหตุการณ์ และ (ข) RMSE ของแบบจำลอง WRF-ROMS และค่าที่ได้จาก S2S ECMWF ในช่วง Lead-1 (ค่าเริ่มต้น : 13 มิถุนายน 2554)	31
รูปที่ 3.6 (ก) ฝนสะสมช่วงเกิดเหตุการณ์ และ (ข) RMSE ของแบบจำลอง WRF-ROMS และค่าที่ได้จาก S2S ECMWF ในช่วง Lead-0 (ค่าเริ่มต้น : 20 มิถุนายน 2554)	32
รูปที่ 3.7 ค่าเอนเอียงเฉลี่ย (MB) ระหว่างค่าจากแบบจำลอง WRF-ROMS เมื่อใช้ G3D และ CFS เทียบกับฝนสะสมช่วงเกิดเหตุการณ์พายุไต้ฝุ่น ก) Lead-1 และ ข) Lead-0	33
รูปที่ 3.8 ค่าความน่าจะเป็นของการตรวจพบ (POD) เหตุการณ์ฝนตกไม่เกิน 10 มม. (ฝนตกเล็กน้อย) ของแบบจำลอง WRF-ROMS เมื่อใช้ G3D และ CFS ช่วงเกิดเหตุการณ์พายุไต้ฝุ่น ก) Lead-1 และ ข) Lead-0	34
รูปที่ 3.9 ค่าความน่าจะเป็นของการตรวจพบ (POD) เหตุการณ์ฝนตกตั้งแต่ 10-35 มม. (ฝนตกปานกลาง) ของแบบจำลอง WRF-ROMS เมื่อใช้ G3D และ CFS ช่วงเกิดเหตุการณ์พายุไต้ฝุ่น ก) Lead-1 และ ข) Lead-0	35

รูปที่ 3.10 (ก) ฝนสะสมช่วงเกิดเหตุการณ์ และ (ข) TCC ระหว่างแบบจำลอง WRF-ROMS และค่าตรวจวัด และค่าที่ได้จาก S2S ECMWF ในช่วง Lead-1 (ค่าเริ่มต้น : 18 กรกฎาคม 2554)	37
รูปที่ 3.11 (ก) ฝนสะสมช่วงเกิดเหตุการณ์ และ (ข) TCC ระหว่างแบบจำลอง WRF-ROMS และค่าตรวจวัด และค่าที่ได้จาก S2S ECMWF ในช่วง Lead-0 (ค่าเริ่มต้น : 25 กรกฎาคม 2554)	38
รูปที่ 3.12 (ก) ฝนสะสมช่วงเกิดเหตุการณ์ และ (ข) RMSE ระหว่างแบบจำลอง WRF-ROMS และค่าตรวจวัด และค่าที่ได้จาก S2S ECMWF ในช่วง Lead-1 (ค่าเริ่มต้น : 18 กรกฎาคม 2554)	39
รูปที่ 3.13 (ก) ฝนสะสมช่วงเกิดเหตุการณ์ และ (ข) RMSE ระหว่างแบบจำลอง WRF-ROMS และค่าตรวจวัด และค่าที่ได้จาก S2S ECMWF ในช่วง Lead-0 (ค่าเริ่มต้น : 25 กรกฎาคม 2554)	40
รูปที่ 3.14 ค่าเอนเอียงเฉลี่ย (MB) ระหว่างค่าจากแบบจำลอง WRF-ROMS เมื่อใช้ G3D และ CFS เทียบกับฝนสะสมช่วงเกิดเหตุการณ์พายุฝนกตอน ก) Lead-1 และ ข) Lead-0	41
รูปที่ 3.15 ค่าความน่าจะเป็นของการตรวจพบ (POD) เหตุการณ์ฝนตกไม่เกิน 10 มม. (ฝนตกเล็กน้อย) ของแบบจำลอง WRF-ROMS เมื่อใช้ G3D และ CFS ช่วงเกิดเหตุการณ์พายุฝนกตอน ก) Lead-1 และ ข) Lead-0	42
รูปที่ 3.16 ค่าความน่าจะเป็นของการตรวจพบ (POD) เหตุการณ์ฝนตกตั้งแต่ 10-35 มม. (ฝนตกปานกลาง) ของแบบจำลอง WRF-ROMS เมื่อใช้ G3D และ CFS ช่วงเกิดเหตุการณ์พายุฝนกตอน ก) Lead-1 และ ข) Lead-0	43
รูปที่ 3.17 ค่า TCC ของค่าคาดการณ์ด้วย WRF-ROMS แบบ (ก) Non-nesting และ (ข)-(ค) Nesting WRF ที่ความละเอียด 5 กม. กับค่าตรวจวัด	45
รูปที่ 3.18 ค่า MB ของการคาดการณ์ด้วย WRF-ROMS แบบ (ก) Non-nesting และ (ข)-(ค) Nesting WRF ที่ความละเอียด 5 กม. เมื่อเทียบกับค่าตรวจวัด	46
รูปที่ 3.19 ค่า RMSE ของการคาดการณ์ด้วย WRF-ROMS แบบ (ก) Non-nesting และ (ข)-(ค) Nesting WRF ที่ความละเอียด 5 กม.	47
รูปที่ 4.1 แผนที่แสดงตำแหน่งสถานีที่นำข้อมูลมาใช้ในการปรับแก้ความคลาดเคลื่อนของการคาดการณ์ ก) ประเทศไทย และ ข) ลุ่มน้ำเจ้าพระยา	49
รูปที่ 4.2 แผนที่แสดงปริมาณฝนคาดการณ์และฝนตรวจวัดจริงปี 2555-2560	50
รูปที่ 4.3 กราฟแสดงปริมาณฝนรายสองสัปดาห์ สถานีเถิน จังหวัดลำปาง ปีพ.ศ. 2555-2560	51
รูปที่ 4.4 กราฟแสดงปริมาณฝนรายสองสัปดาห์ สถานีเขื่อนภูมิพล จังหวัดตาก ปีพ.ศ. 2555-2560	52
รูปที่ 4.5 แผนที่แสดงปริมาณฝนคาดการณ์และฝนตรวจวัดจริงปี 2561	53
รูปที่ 4.6 แผนที่แสดงปริมาณฝนคาดการณ์และฝนตรวจวัดจริงปี 2562	53
รูปที่ 4.7 กราฟแสดงปริมาณฝนรายสองสัปดาห์ สถานีเถิน จังหวัดลำปาง ปี 2561	55

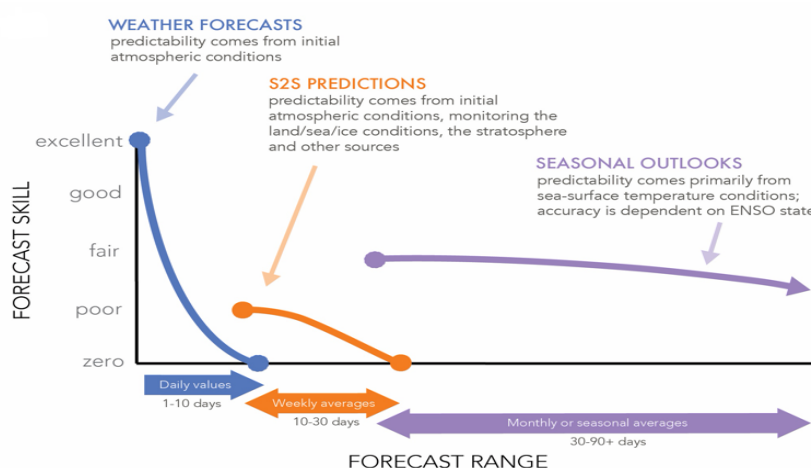
รูปที่ 4.8 กราฟแสดงปริมาณฝนรายสองสัปดาห์ สถานีเถิน จังหวัดลำปาง ปี 2562	55
รูปที่ 4.9 กราฟแสดงปริมาณฝนรายสองสัปดาห์ สถานีเขื่อนภูมิพล จังหวัดตาก ปี 2561	56
รูปที่ 4.10 กราฟแสดงปริมาณฝนรายสองสัปดาห์ สถานีเขื่อนภูมิพล จังหวัดตาก ปี 2562	57
รูปที่ 4.11 ตัวอย่างผลการปรับลดความคลาดเคลื่อนของฝนคาดการณ์รายสองสัปดาห์ ในลุ่มน้ำสาขา ของกลุ่มน้ำปิง ในปีพ.ศ. 2561 และ 2562	58
รูปที่ 4.12 ตัวอย่างผลการปรับลดความคลาดเคลื่อนของฝนคาดการณ์รายสองสัปดาห์ ในลุ่มน้ำสาขา ของกลุ่มน้ำวัง ในปีพ.ศ. 2561 และ 2562	60
รูปที่ 4.13 ตัวอย่างผลการปรับลดความคลาดเคลื่อนของฝนคาดการณ์รายสองสัปดาห์ในลุ่มน้ำสาขา ของกลุ่มน้ำยม ในปี พ.ศ. 2561 และ 2562	61
รูปที่ 4.14 ตัวอย่างผลการปรับลดความคลาดเคลื่อนของฝนคาดการณ์รายสองสัปดาห์ในลุ่มน้ำสาขา ของกลุ่มน้ำน่าน ในปี พ.ศ. 2561 และ 2562	63
รูปที่ 4.15 ตัวอย่างผลการปรับลดความคลาดเคลื่อนของฝนคาดการณ์รายสองสัปดาห์ในลุ่มน้ำสาขา ของกลุ่มน้ำเจ้าพระยา ในปีพ.ศ. 2561 และ 2562	65
รูปที่ 4.16 ตัวอย่างผลการปรับลดความคลาดเคลื่อนของฝนคาดการณ์รายสองสัปดาห์ในลุ่มน้ำสาขา ของกลุ่มน้ำสะแกกรัง ในปีพ.ศ. 2561 และ 2562	66
รูปที่ 4.17 ตัวอย่างผลการปรับลดความคลาดเคลื่อนของฝนคาดการณ์รายสองสัปดาห์ในลุ่มน้ำสาขา ของกลุ่มน้ำป่าสัก ในปีพ.ศ. 2561 และ 2562	66
รูปที่ 4.18 ตัวอย่างผลการปรับลดความคลาดเคลื่อนของฝนคาดการณ์รายสองสัปดาห์ในลุ่มน้ำสาขา ของกลุ่มน้ำท่าจีน ในปีพ.ศ. 2561 และ 2562	67

บทที่ 1

บทนำ

1.1 ความเป็นมาและความสำคัญ

เทคโนโลยีที่ใช้คาดการณ์สภาพอากาศและภูมิอากาศได้มีการพัฒนาอย่างต่อเนื่อง ซึ่งในปัจจุบันภาพรวมความสามารถในการคาดการณ์สภาพอากาศล่วงหน้ามีระดับแตกต่างกันตามระยะเวลาดังแสดงไว้ในรูปที่ 1.1 จะเห็นได้ว่า ความสามารถในการคาดการณ์สภาพอากาศระยะสั้นจะสูงโดยเฉพาะอย่างยิ่งเมื่อเป็นการคาดการณ์รายวันล่วงหน้าเพียง 1-2 วัน และความสามารถจะลดลงตามการคาดการณ์ล่วงหน้าที่นานขึ้น การคาดการณ์ระยะ 1-10 วัน ส่วนใหญ่จะใช้แบบจำลองพยากรณ์อากาศเชิงตัวเลข (Numerical Weather Prediction, NWP) ที่อาศัยกฎทางพลวัตและกฎเกณฑ์ทางฟิสิกส์ในการจำลองกระบวนการต่าง ๆ ของระบบโลก โดยมีสภาพบรรยากาศปัจจุบันเป็นข้อมูลหลัก สำหรับการคาดการณ์ที่มีความสามารถรองลงมาคือ การคาดการณ์รายฤดูกาลที่เป็น การคาดการณ์สภาพอากาศเฉลี่ยรายเดือนหรือรายสามเดือน ซึ่งโดยทั่วไปจะอาศัยความสัมพันธ์ของอุณหภูมิผิวน้ำทะเล เช่น ปรากฏการณ์ El Niño-Southern Oscillation (ENSO), Indian Ocean Dipole (IOD) และดัชนีความเชื่อมโยงระยะไกลอื่น ๆ เป็นปัจจัยในการคาดการณ์ ส่วนการคาดการณ์ที่มีความสามารถในการคาดการณ์ต่ำคือ การคาดการณ์สภาพอากาศเฉลี่ยรายสัปดาห์ในช่วงระยะเวลาตั้งแต่ 10-30 วันล่วงหน้า ซึ่งถือว่ายู่ในกลุ่มของการคาดการณ์กึ่งฤดูกาลถึงฤดูกาล “sub-seasonal to seasonal prediction (S2S)”



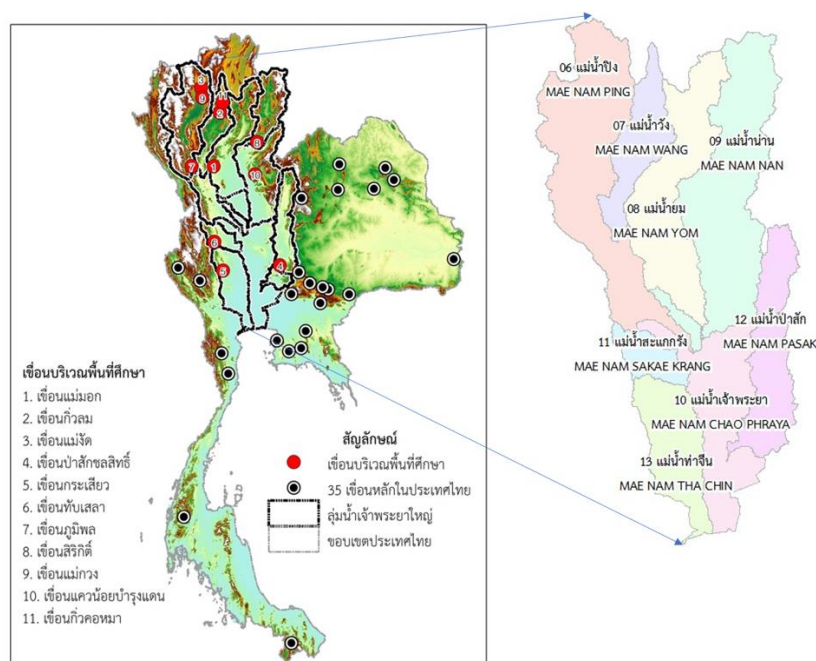
ที่มา: Potential applications of subseasonal-to-seasonal (S2S) predictions.

Meteorological Applications (White et al., 2017)

รูปที่ 1.1 ประสิทธิภาพการคาดการณ์สภาพอากาศตามคาบเวลาต่าง ๆ

การคาดการณ์ปริมาณฝนเป็นเครื่องมือที่สำคัญเป็นอย่างมากในการบริหารจัดการน้ำ ปัจจุบันประเทศไทยมีระบบการคาดการณ์ระยะสั้นและรายฤดูกาลสำหรับใช้ในการบริหารจัดการน้ำจากกรมอุตุนิยมวิทยา และ สถาบันสารสนเทศทรัพยากรน้ำ (องค์การมหาชน) โดยเป็นข้อมูลสนับสนุนให้กับทางสำนักงานทรัพยากรน้ำแห่งชาติ (สทนช.) ส่วนระบบการคาดการณ์ปริมาณฝนล่วงหน้ารายสองสัปดาห์ที่ใช้กันอยู่ยังมีขีดจำกัดของการคาดการณ์ ค่าคาดการณ์ที่ได้มีความผิดพลาดสูง ทั้งนี้ข้อมูลคาดการณ์รายสองสัปดาห์มีความสำคัญเนื่องจากช่วงเวลาสองสัปดาห์เป็นระยะเวลาที่มากพอในการปรับตัวหรือเปลี่ยนแปลงการปฏิบัติงานที่จะช่วยป้องกันหรือบรรเทาความเสียหายที่อาจเกิดขึ้นจากสภาพอากาศที่รุนแรง, White et al. (2017) แต่ทว่าขณะนี้ยังไม่มีการพัฒนาระบบการคาดการณ์ล่วงหน้ารายสองสัปดาห์ในประเทศไทยเพื่อใช้งานกับการบริหารจัดการน้ำโดยตรง ดังนั้น จึงถือว่าเป็นความจำเป็นเร่งด่วนที่จะต้องดำเนินการศึกษาและพัฒนาระบบการคาดการณ์ปริมาณฝนรายสองสัปดาห์ให้ได้ผลการคาดการณ์ที่มีความถูกต้องแม่นยำขึ้นและเหมาะสมกับการใช้งานในประเทศ อันจะทำให้ได้ข้อมูลสนับสนุนสำหรับระดับนโยบายและระดับปฏิบัติงานนำไปใช้งาน และส่งผลให้การบริหารจัดการน้ำโดยรวมมีประสิทธิภาพสูงขึ้น

พื้นที่ศึกษาในโครงการนี้จะเน้นที่ลุ่มน้ำเจ้าพระยาดังแสดงในรูปที่ 1.2 เพราะลุ่มน้ำเจ้าพระยาเป็นลุ่มน้ำหลักและสำคัญที่สุดของประเทศไทย ปัญหาเรื่องน้ำและความเสียหายที่เกิดขึ้นหลายครั้งมีความเกี่ยวข้องกับลุ่มน้ำเจ้าพระยา ด้วยข้อมูลคาดการณ์รายสองสัปดาห์ การบริหารจัดการน้ำจะเป็นไปอย่างมีประสิทธิภาพมากขึ้น ทำให้สามารถลดค่าใช้จ่ายและความสูญเสียได้ อย่างไรก็ตาม การพัฒนาแบบจำลองพลวัตในโครงการนี้จะครอบคลุมพื้นที่ทั่วประเทศด้วยเพื่อเตรียมการพัฒนาต่อยอดงานวิจัยในระยะต่อไป แต่การตรวจสอบปรับเพิ่มประสิทธิภาพการคาดการณ์ให้ดีขึ้นจากแบบจำลองพลวัตจะเน้นในส่วนของลุ่มน้ำเจ้าพระยาเป็นหลัก



รูปที่ 1.2 พื้นที่ศึกษาลุ่มน้ำเจ้าพระยา

1.2 วัตถุประสงค์งานวิจัย

1.2.1 ศึกษาขีดจำกัดและประสิทธิภาพของระบบการคาดการณ์ฝนรายสองสัปดาห์ที่มีอยู่ในปัจจุบันที่สามารถนำมาประยุกต์ใช้กับการบริหารจัดการน้ำสำหรับพื้นที่ลุ่มน้ำเจ้าพระยา

1.2.2 พัฒนาระบบคาดการณ์ปริมาณฝนรายสองสัปดาห์เพื่อสนับสนุนการบริหารจัดการน้ำสำหรับพื้นที่ลุ่มน้ำเจ้าพระยา

1.3 ผลที่คาดว่าจะได้รับเมื่อสิ้นสุดการวิจัย

Output

- 1) ระบบคาดการณ์ปริมาณน้ำฝนรายสองสัปดาห์เพื่อการบริหารจัดการน้ำสำหรับพื้นที่ลุ่มน้ำเจ้าพระยา
- 2) องค์ความรู้สำหรับการเพิ่มประสิทธิภาพการคาดการณ์ฝนรายสองสัปดาห์ในพื้นที่อื่น


Outcome

- 1) เป็นข้อมูลนำเข้าสำหรับระบบต่าง ๆ ที่ใช้ในการบริหารจัดการน้ำสำหรับพื้นที่ลุ่มน้ำเจ้าพระยา
- 2) ต้นแบบระบบคาดการณ์ปริมาณฝนรายสองสัปดาห์สำหรับพื้นที่อื่น ๆ

Impact

- 1) ส่งเสริมการพัฒนาวิทยาศาสตร์และเทคโนโลยีการคาดการณ์ฝนเพื่อการบริหารจัดการน้ำ
- 2) ส่งเสริมการพัฒนาศักยภาพความรู้ในระดับประเทศ

1.4 ผังการดำเนินงาน



รูปที่ 1.3 ผังการดำเนินงาน

1.5 การดำเนินการวิจัยปีที่ 1

- 1) ศึกษาและเปรียบเทียบระบบการคาดการณ์ฝนรายสองสัปดาห์ของหน่วยงานต่าง ๆ ที่ใช้อยู่ในปัจจุบัน
- 2) ศึกษาข้อดีและข้อเสียของวิธีการเพิ่มประสิทธิภาพการคาดการณ์ฝนวิธีต่าง ๆ ที่จะนำมาประยุกต์ใช้ในการคาดการณ์ปริมาณฝนรายสองสัปดาห์สำหรับพื้นที่ลุ่มน้ำเจ้าพระยา
- 3) เลือกวิธีการเพิ่มประสิทธิภาพการคาดการณ์ฝนที่เหมาะสมกับข้อมูลและการใช้งาน ทำการทดสอบและประเมินผล
- 4) พัฒนาระบบคาดการณ์ฝนรายสองสัปดาห์ที่ใช้วิธีที่เลือก
- 5) คาดการณ์ฝนด้วยระบบที่สร้างขึ้น และสนับสนุนข้อมูลคาดการณ์ฝนกับทีมวิจัยอื่น ๆ สำหรับใช้ในการบริหารจัดการน้ำต่อไป

1.6 แนวทางดำเนินการในปีที่ 2

- 1) ศึกษาข้อจำกัดของระบบคาดการณ์ที่ใช้อยู่ และหาวิธีการเพิ่มความแม่นยำในการคาดการณ์

2) ศึกษาวิจัยความเป็นไปได้ในการใช้วิธีการคาดการณ์แบบอื่นเพื่อผลลัพธ์ที่ดีขึ้น ซึ่งได้แก่การใช้วิธีแบบผสม (Hybrid methods) โดยการสร้างแบบจำลองที่ใช้วิธีการทางสถิติ หรือ Machine learning กับผลลัพธ์ของการคาดการณ์จาก Dynamic model

ตารางที่ 1.1 ชุดข้อมูลที่ใช้ในการศึกษา

ข้อมูล	ช่วงเวลาของข้อมูล	ความละเอียด	แหล่งที่มา
ข้อมูลฝนรายวันจากการตรวจวัดรายสถานี	พ.ศ. 2524 - 2561 (ค.ศ. 1981-2018)	93 สถานี (missing ไม่เกิน 5%)	สถานีหลักของกรมอุตุนิยมวิทยา
	พ.ศ. 2555 - 2561 (ค.ศ. 2012-2018)	642 สถานี (ผ่านการคัดกรองแล้ว)	สถานีตรวจวัดรายอำเภอของกรมอุตุนิยมวิทยา
	(ค.ศ. 2009-2018)	173 สถานี (missing ไม่เกิน 20%)	สถาบันสารสนเทศทรัพยากรน้ำ (องค์การมหาชน)
ผลคาดการณ์ฝนสะสมราย 6 ชม. จาก Hindcast ของ S2S ECMWF	(ค.ศ. 1998-ปัจจุบัน)	T639/319 L91 (ประมาณ 34 กม.)	ECMWF (S2S project)
ข้อมูล CFSV1 Reanalysis ราย 6 ชม.	(ค.ศ. 1979-2011)	0.5 degree (ประมาณ 50 กม.)	https://nomads.ncdc.noaa.gov/data/cfsr
ข้อมูล CFSv2 ราย 6 ชั่วโมง รอบ 00UTC ทั้งหมด 4 Member	(ค.ศ. 2020 - ปัจจุบัน)	1x1 degree (ประมาณ 100 กม.)	https://nomads.ncep.noaa.gov/pub/data/nccf/com/cfs/prod/cfs/

บทที่ 2

การทบทวนวรรณกรรม

2.1 โครงการ Sub-seasonal to seasonal (S2S) prediction project

ปัจจุบันได้มีผลลัพธ์จากแบบจำลองโลกที่ถูกพัฒนาขึ้นสำหรับการคาดการณ์ในช่วงรายฤดูกาลย่อยภายใต้โครงการที่มีชื่อว่า Sub-seasonal to seasonal (S2S) prediction project ซึ่งมีการพัฒนามามากกว่า 10 ปี โดยการสนับสนุนของกรมอดุนิยมวิทยาโลก และได้รับความร่วมมือจากสถาบันวิจัยชั้นนำต่าง ๆ ทั้งสิ้น 11 หน่วยงาน (Vitart et al., 2008) ดังแสดงในตารางที่ 2.1 เห็นได้ชัดว่าแต่ละหน่วยงานมีรูปแบบและการตั้งค่าแบบจำลอง (model configuration) ที่แตกต่างกัน และมีผลลัพธ์ของแบบจำลองเป็นเวลาหลายสิบปี จึงเป็นข้อดีในการนำมาศึกษาความเป็นไปได้ของเหตุการณ์จากหลากหลายแบบจำลอง อย่างไรก็ตามในเวลานี้ แบบจำลองในโครงการดังกล่าวเผยแพร่เฉพาะข้อมูลคาดการณ์ในอดีต (hindcast) เท่านั้น และยังไม่ได้เผยแพร่ข้อมูลตามเวลาจริง (real time) หรืออาจมีบางหน่วยงานที่เผยแพร่ข้อมูลตามเวลาจริงแบบมีค่าธรรมเนียมรายปีในการจัดเตรียมข้อมูลให้ผู้ใช้ ซึ่งมีราคาค่อนข้างสูง นอกจากนี้ หากพิจารณาความละเอียดเชิงพื้นที่ ยังคงมีไม่มากพอที่จะนำมาใช้ศึกษาบนพื้นที่ขนาดเล็กได้โดยตรง จะเห็นได้ว่าข้อมูลแบบจำลองในโครงการ S2S มีข้อจำกัดหลายอย่างในการนำมาประยุกต์ใช้สำหรับระบบปฏิบัติการ แต่เหมาะสำหรับการวิจัยโดยนำมาศึกษาและประเมินความสามารถของแบบจำลองในการคาดการณ์สำหรับพื้นที่ใดพื้นที่หนึ่งได้

European Centre for Medium-Range Weather Forecasts หรือ ECMWF เป็นหน่วยงานอิสระของรัฐบาลสหภาพยุโรปที่มีหน้าที่รับผิดชอบงานวิจัยด้านอากาศทั้งข้อมูลตรวจวัดและแบบจำลอง รวมทั้งการเผยแพร่ข้อมูลดังกล่าวให้กับนักวิจัยและหน่วยงานต่าง ๆ ทั่วโลก ปัจจุบัน ECMWF เป็นหน่วยงานหนึ่งในโครงการ S2S โดยให้บริการข้อมูลคาดการณ์ล่วงหน้า 46 วัน สามารถเข้าถึงและดาวน์โหลดได้ฟรีผ่านทาง <https://apps.ecmwf.int/datasets/data/s2s/> ยกเว้นข้อมูล Real-time operation ที่จะมีค่าธรรมเนียมการใช้ข้อมูล ซึ่งราคาจะแตกต่างกันตามรูปแบบที่กำหนด ในกรณีต้องการศึกษาราย 2 สัปดาห์ หากสนใจจะใช้บริการของ ECMWF ชุดคาดการณ์ 15 วัน อาจเป็นหนึ่งตัวเลือก ทั้งนี้ ค่าธรรมเนียมจะขึ้นอยู่กับจำนวนตัวแปรที่เลือกด้วย ดังแสดงในรูปที่ 2.1

ตารางที่ 2.1 ข้อมูลแบบจำลอง ณ ปัจจุบัน ของ S2S project (เข้าถึงได้เฉพาะข้อมูลในอดีตเท่านั้น)

No.	Model	Time range	Resolution	Ens.Size	Freq.	Re-forecast	Rfc. Length	Rfc. Freq.
1	BoM	d 0-62	T47L17	3*11	2/week	fix	1981-2013	6/month
2	CMA	d 0-60	T106L40	4	daily	fix	1994-2014	daily
3	CNR-ISAC	d 0-32	0.75x0.56 L54	41	weekly	fix	1981-2010	every 5 days
4	CNRM	d 0-32	T255L91	51	weekly	fix	1993-2014	4/month
5	ECCC	d 0-32	0.45x0.45 L40	21	weekly	on the fly	1998-2017	weekly
6	ECMWF	d 0-46	Tco639/319 L91	51	2/week	on the fly	past 20 years	2/week
7	HMCR	d 0-61	1.1x1.4 L28	20	weekly	on the fly	1985-2010	weekly
8	JMA	d 0-33	Tl479/Tl319L100	50	weekly	fix	1981-2010	3/month
9	KMA	d 0-60	N216L85	4	daily	on the fly	1991-2010	4/month
10	NCEP	d 0-44	T126L64	16	daily	fix	1999-2010	daily
11	UKMO	d 0-60	N216L85	4	daily	on the fly	1993-2016	4/month

หมายเหตุ: Rfc. คือ Re-forecasts

ECMWF

Search site... Contact Login

Home About Forecasts Computing Research Learning Publications

Charts Datasets Quality of our forecasts Documentation Access to forecasts

Set III - Atmospheric model Ensemble 15-day forecast (ENS)

Ensemble (ENS) of forecasts providing an estimate of the reliability of a single forecast. [Order real-time forecasts >](#)

Access to archive datasets

Reanalysis datasets

Real-time datasets

WMO and ACMA datasets

ENS offers "High Frequency products" (hourly products) until step 90 and 4 daily runs: 00, 06, 12 and 18 UTC

Post-processed Products are not available at 06/18 runs or in hourly steps.

The following sub-sets are available from the ENS Model:

III-i: Atmospheric fields (direct model output)

The products consist of 1 control and 50 perturbed forecasts plus the equivalent high-resolution (HRES) products. Customers can choose to receive the equivalent HRES at no extra cost. The high resolution product is suppressed beyond day 10. The fields are provided

Order real-time forecasts

National meteorological services of ECMWF Member and Co-operating States and their authorised users are granted full access to ECMWF real-time products via their [computing representative](#).

All other users need a licence to gain access to the Catalogue of ECMWF Real-time Products.

1. Select products

If you have not already done so, you first need to consult the [Catalogue of ECMWF Real-Time Products](#) and make your selection of ECMWF products using the templates provided within the catalogue.

2. Contact your licensor

- If you are located within one of the ECMWF Member States or Cooperating States, please contact one of the [catalogue contacts points](#) (not necessarily in your country of residence).

* รายละเอียดเพิ่มเติม สามารถดูได้ที่

<https://www.ecmwf.int/en/forecasts/datasets/set-iii> และ

<https://www.ecmwf.int/en/forecasts/accessing-forecasts/payment-rules-and-options/tariffs> สำหรับค่าธรรมเนียมรายปี

รูปที่ 2.1 Website ECMWF

ปัจจุบันหน่วยงานต่าง ๆ ที่มีหน้าที่ในการเฝ้าระวังด้านสภาพอากาศทั่วโลกได้นำข้อมูลคาดการณ์ S2S ECMWF มาใช้ทั้งในงานวิจัยและเพื่อประกอบการวางแผนและตัดสินใจในการบริหารจัดการน้ำในช่วงเวลาตั้งแต่ 2 สัปดาห์ไปจนถึง 3 เดือน (S2S time scale) Jie et al. (2017) ได้ศึกษาและประเมินความแม่นยำของผลคาดการณ์ โดยพิจารณาจากความสามารถในการคาดการณ์รูปแบบและความแรงของมรสุมเอเชีย (Asian monsoon) พบว่า ECMWF สามารถคาดการณ์รูปแบบของมรสุมได้ดีกว่าแบบจำลองอื่น ๆ อาทิ NCEP, JMA, CNRM, BoM และ UKMO แต่ก็ยังมีค่าความคลาดเคลื่อนอยู่ และยังพบว่าความสามารถของการคาดการณ์ขึ้นอยู่กับพื้นที่หรือดัชนีมรสุมที่ใช้ อาทิ ดัชนีของ Webster and Yang จะมีความแม่นยำอยู่ในช่วง 9–31 วัน ดัชนี Indian Summer Monsoon ประมาณ 3–17 วัน เป็นต้น นอกจากนี้ ก็พบว่าผลคาดการณ์ของ S2S สามารถทำนายรูปแบบวัฏจักรภายในช่วงฤดูกลางฝน (Boreal Summer Intraseasonal Oscillation หรือ BSISO) ได้ค่อนข้างดีในช่วงไม่เกิน 24 วัน ถึงแม้ว่าค่าคาดการณ์ที่ได้จะต่ำกว่าค่าตรวจวัดบ้างจากการศึกษาดังกล่าวจึงสังเกตเห็นความเป็นไปได้ของการนำผลของแบบจำลองจาก ECMWF มาศึกษาความแม่นยำในการคาดการณ์ฝนสำหรับพื้นที่ประเทศไทย

2.2 การทบทวนวรรณกรรมการปรับแก้ความเอนเอียงเชิงสถิติของการคาดการณ์ฝน

ระบบ Climate Forecast System (CFS) ของ the National Centers for Environmental Prediction (NCEP) ได้เผยแพร่ข้อมูล hindcast จากแบบจำลอง CFSv1 ในช่วงปี ค.ศ. 1982-2009 และจากแบบจำลอง CFSv2 ในช่วงปีค.ศ. 1982-2011 (Peng et al., 2013) ความแตกต่างของ CFSv2 จาก CFSv1 คือ CFSv2 มีความละเอียดเชิงพื้นที่ที่สูงขึ้น และความเข้มข้นของก๊าซคาร์บอนไดออกไซด์ใน CFSv1 ใช้เป็นค่าคงที่ที่ระดับ ณ ปีค.ศ. 1988 ในขณะที่ CFSv2 ค่าความเข้มข้นของก๊าซคาร์บอนไดออกไซด์จะเปลี่ยนตามเวลา โดยใช้ค่าตั้งต้นเป็นค่าตรวจวัด ณ ขณะเริ่มต้นการคาดการณ์ หลังจากนั้นจะใช้เป็นค่าคงที่ตลอดช่วงเวลาการคาดการณ์ 9 เดือน รายละเอียดพื้นฐานของ CFSv1 และ CFSv2 แสดงดังตารางที่ 2.2

ตารางที่ 2.2 รายละเอียดพื้นฐานของ CFSv1 และ CFSv2

	CFSv1	CFSv2
Horizontal resolution	T62 (~2°)	T126 (~1°)
Vertical resolution	64 levels	64 levels
Ensemble size	15	20
Initial conditions for 0.5-month outlook (example given is for the DJF seasonal mean forecast, made in November)	Five initial conditions from each near 1 and 11 November, and 21 October	Four initial conditions from each of 17, 12, 7, and 2 November, and 27 October
Climatological base period	1982–2004	1982–2004
Maximum forecast lead time	9 months	9 months
Source of initial condition data	NCEP/DOE reanalysis	CFSR
Carbon dioxide concentration setting	Fixed at 1988 level	Evolving

ที่มา : Peng et al. (2013)

Saha et al. (2014) ได้วิเคราะห์และเปรียบเทียบการคาดการณ์รายฤดูกาลของ CFSv2 กับ CFSv1 และแบบจำลองอื่น ๆ ภายใต้โครงการ U.S. National Multimodel Ensemble (NMME) ซึ่งมี NCEP เป็นแกนหลัก แบบจำลองรวมทั้งหมด 7 แบบ เป็นแบบจำลอง global coupled atmosphere-ocean ที่พัฒนาขึ้นในประเทศสหรัฐอเมริกา ผลการเปรียบเทียบ anomaly correlation (AC) จากแบบจำลองทั้งเจ็ด และแบบจำลองเฉลี่ยที่ให้น้ำหนักกับทุกแบบจำลองเท่ากัน แสดงในตารางที่ 2.3 โดยระยะเวลา lead time ในการคาดการณ์รายฤดูกาลที่ใช้คือ 0.5 เดือน ตัวแปรในการเปรียบเทียบประกอบด้วย อุณหภูมิพื้นผิวน้ำทะเล (SST), อุณหภูมิอากาศที่ความสูง 2 เมตร (T2m), และความชื้นฝน (prate) พบว่า แบบจำลอง CFSv2 มีค่าสหสัมพันธ์สูงเมื่อเทียบกับแบบจำลองอื่น ๆ ในการคาดการณ์ SST และ equal-weight NMME ให้ค่าสหสัมพันธ์ที่สูงที่สุด ส่วนค่าสหสัมพันธ์ของการคาดการณ์ความชื้นฝนมีค่าค่อนข้างต่ำมากสำหรับทุกแบบจำลอง คืออยู่ในช่วง 0.04 – 0.17 โดยค่าสหสัมพันธ์ของ CFSv2 อยู่ที่ 0.12

ตารางที่ 2.3 Anomaly correlation ของการคาดการณ์ค่าเฉลี่ยรายฤดูกาล 3 เดือน สำหรับ lead time 0.5 เดือน ในช่วงปีค.ศ. 1982 – 2010 จาก 7 แบบจำลองภายใต้โครงการ U.S. National Multimodel Ensemble (NMME) และ equal-weight NMME

	NH SST (K)	Niño-3.4 SST (K)	NH T2m (K)	NH prate (mm day ⁻¹)
CFSv1	0.29	0.82	0.11	0.10
CFSv2	0.41	0.82	0.29	0.12
A	0.27	0.81	0.12	0.10
B	0.27	0.82	0.12	0.11
C	0.42	0.80	0.25	0.12
D	0.34	0.78	0.23	0.08
E	0.14	0.80	0	0.04
NMME	0.45	0.87	0.27	0.17

ที่มา : Saha et al. (2014)

หยาดน้ำฟ้า (precipitation) และอุณหภูมิ เป็นตัวแปรหลักที่มีผลกระทบต่อสังคม เมื่อเปรียบเทียบกับตัวแปรทางอุตุนิยมวิทยาอื่นๆ หยาดน้ำฟ้าถือได้ว่าเป็นตัวแปรที่คาดการณ์ได้ยาก เนื่องจากมีลักษณะการเกิดเป็นช่วง และมีช่วงระยะเวลาการเกิดที่สั้น สำหรับการคาดการณ์อุณหภูมิเหนือพื้นผิว 2 เมตร (T2m) โดยทั่วไปจะคาดการณ์ได้ดีกว่าหยาดน้ำฟ้า แต่อย่างไรก็ตาม ประสิทธิภาพในการคาดการณ์ T2m ได้รับผลกระทบจากความซับซ้อนของ lower boundary conditions และสภาพภูมิประเทศ Fan and van den Dool (2011) ได้ทำการศึกษา forecast errors (biases) ในการคาดการณ์หยาดน้ำฟ้า และ T2m ด้วยแบบจำลอง NCEP Global Forecast System (GFS) โดยใช้ค่าเฉลี่ยรายสัปดาห์ของการคาดการณ์ล่วงหน้า 1 สัปดาห์ (week-1) และ 2 สัปดาห์ (week-2) และทำการปรับแก้ความเอนเอียงเชิงสถิติอย่างง่าย โดยใช้ค่า running mean ดังแสดงในสมการที่ (1) และ (2)

$$\text{Bias1} = 1/N \sum [\text{Pf}(\text{week1}) - \text{Po}(\text{week1})] \quad (1)$$


$$\text{Bias2} = 1/N \sum [\text{Pf}(\text{week2}) - \text{Po}(\text{week2})] \quad (2)$$

โดย Pf คือ ค่าเฉลี่ยรายสัปดาห์ หรือค่าสะสมรายสัปดาห์ของตัวแปรคาดการณ์

Po คือ ค่าเฉลี่ยรายสัปดาห์ หรือค่าสะสมรายสัปดาห์จากการตรวจวัด

N คือ จำนวนวัน (เช่น 30 หรือ 7 วัน โดยทั่วไป N ค่าใหญ่ จะให้ผลดีกว่า)

รูปที่ 2.2 แสดง 5-day running mean spatial correlation และ root mean square errors (RMSE) ของ precipitation anomalies ใน 4 ภูมิภาค ได้แก่ North America (NA), South America (SA), Asia-Australia (AS), และ Africa (AF) เปรียบเทียบระหว่างก่อนและหลังการปรับแก้ความเอนเอียงเชิงสถิติ โดยข้อมูลหยาดน้ำฟ้าจากการตรวจวัด ใช้ข้อมูล CPC daily U.S. (Higgins et al., 1996) และ Global Unified Precipitation Analysis (Chen et al., 2008) ที่ทำการกระจายข้อมูลลงสู่กริดขนาด $0.5^{\circ} \times 0.5^{\circ}$ ผลการศึกษาพบว่า การปรับแก้ความเอนเอียงเชิงสถิติที่ใช้ในการศึกษาไม่ค่อยช่วยในการปรับ anomaly pattern ของ GFS-forecast precipitation ในภูมิภาค North America แต่ช่วยบ้างในภูมิภาค Asia-Australia และช่วยอย่างมากในภูมิภาค South America และ Africa



Time series of 5-day running mean spatial correlation & RMSE of week-1 & week-2 observed & forecasted precipitation anomalies over North America (NA), South America (SA), Asia-Australia (AS) & Africa (AF), bias correction based on 30 days mean forecast errors.

ที่มา: https://www.nws.noaa.gov/ost/climate/STIP/FY09CTBSeminars/fany_062409.htm

รูปที่ 2.2 5-day running mean spatial correlation และ RMSE ของ precipitation anomalies ใน 4 ภูมิภาค

(เส้นสีแดงแสดงค่าก่อนการปรับแก้ และเส้นสีเขียวแสดงค่าหลังการปรับแก้ความเอนเอียงเชิงสถิติ)

ตารางที่ 2.4 สรุปค่าเฉลี่ย (1 เมษายน 2008 – 31 มีนาคม 2010) ของ spatial correlations และตารางที่ 2.5 สรุปค่าเฉลี่ย (1 เมษายน 2008 – 31 มีนาคม 2010) ของ RMSE ของการคาดการณ์หยาดน้ำฟ้า เปรียบเทียบก่อนและหลังทำ bias correction สำหรับภูมิภาค Asia-Australia (AS) ค่าเฉลี่ยของ spatial correlation ของการคาดการณ์ล่วงหน้า 1 สัปดาห์มีค่าเพิ่มขึ้นจาก 0.40 เป็น 0.47 และของการคาดการณ์ล่วงหน้า 2 สัปดาห์มีค่าเพิ่มขึ้นจาก 0.26 เป็น 0.29 ค่าเฉลี่ยของ RMSE ของการคาดการณ์ล่วงหน้า 1 สัปดาห์มีค่าลดลงจาก 27.62 เป็น 22.65 มม./สัปดาห์ และของการคาดการณ์ล่วงหน้า 2 สัปดาห์มีค่าลดลงจาก 29.15 เป็น 25.24 มม./สัปดาห์

ตารางที่ 2.4 ค่าเฉลี่ยของ spatial correlations ของค่า precipitation anomalies ระหว่างการตรวจวัด และการคาดการณ์จาก GFS ล่วงหน้า 1 สัปดาห์ และ 2 สัปดาห์

	Week 1		Week 2	
	Bias correction	No bias correction	Bias correction	No bias correction
NA	0.49	0.48	0.24	0.26
SA	0.45	0.25	0.31	0.18
AS	0.47	0.40	0.29	0.26
AF	0.40	0.24	0.25	0.13

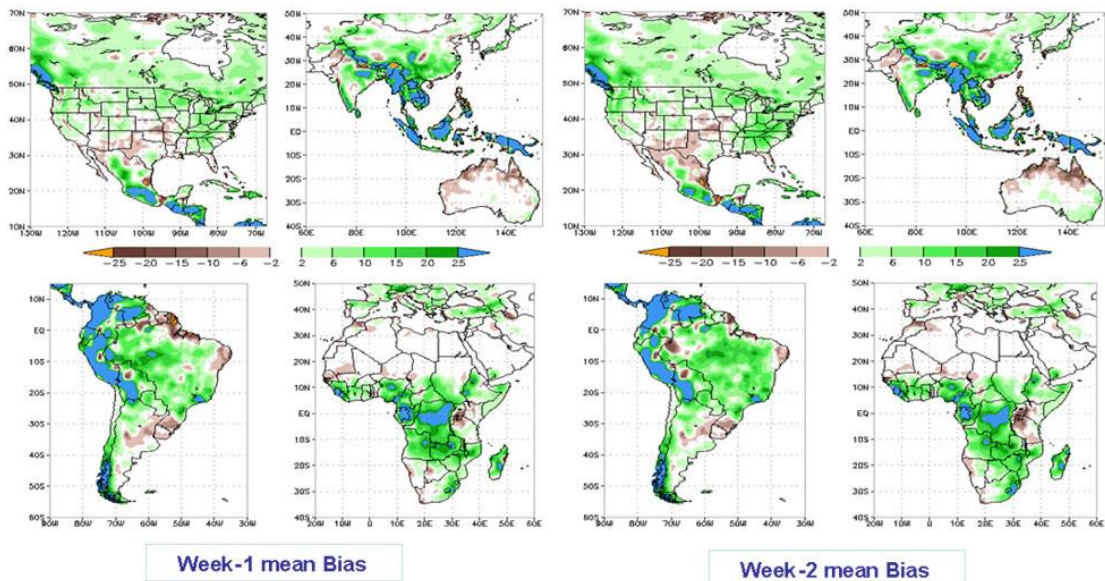
ตารางที่ 2.5 ค่าเฉลี่ยของ RMSE ของค่า precipitation ระหว่างการตรวจวัด และ การคาดการณ์จาก GFS ล่วงหน้า 1 สัปดาห์ และ 2 สัปดาห์ (มม./สัปดาห์)

	Week 1		Week 2	
	Bias correction	No bias correction	Bias correction	No bias correction
NA	19.18	22.82	21.61	23.58
SA	29.55	41.06	32.27	41.72
AS	22.65	27.62	25.24	29.15
AF	17.06	19.47	17.66	19.33

ในการปรับแก้ความเอนเอียงเชิงสถิติ นั้น หากค่าความเอนเอียง (bias) ไม่ได้เปลี่ยนแปลงตามเวลา คือ เป็นค่าคงที่ จะสามารถลดทอนความเอนเอียงได้ง่ายที่สุด โดยทำการลบค่าความเอนเอียงจากผลที่ได้จากแบบจำลอง หากค่าความเอนเอียงไม่ใช่ค่าคงที่ แต่มีลักษณะที่เป็น large-scale spatial structures และมีการแปรผันแบบปกติ และเปลี่ยนแปลงช้า ๆ ตามเวลา ก็สามารถที่จะลดทอนความเอนเอียงได้อย่างไม่ยุ่งยากมากนัก Fan and van den Dool (2011) ได้วิเคราะห์โครงสร้างเชิงพื้นที่ และเวลาของ GFS week-1 และ week-2 ensemble mean forecast errors ซึ่งสามารถแยกได้เป็นสองส่วนคือ annual mean forecast errors และ ความผันแปรจากค่า annual means โดยการวิเคราะห์ EOF ดังแสดงในสมการที่ 3

$$\text{Bias}_{1,2}(s, t) = \text{Mean} + \sum_{m=1}^M \text{PC}_m(t) \times \text{EOF}_m(s), \quad (3)$$

โดย 1,2 หมายถึง week-1 หรือ week-2 ensemble means และ s และ t แสดงตำแหน่งเชิงพื้นที่ และเวลา



Annual mean of week-1 (left) & week-2 (right) forecasted precipitation errors over North America, South America, Asia-Australia & Africa (unit: mm/week).

ที่มา https://www.nws.noaa.gov/ost/climate/STIP/FY09CTBSeminars/fany_062409.htm

รูปที่ 2.3 ค่าเฉลี่ยรายปีของ forecasted precipitation errors

จากการคาดการณ์ล่วงหน้า 1 สัปดาห์ และ 2 สัปดาห์ ใน 4 ภูมิภาค (มม./สัปดาห์)

รูปที่ 2.3 แสดงค่าเฉลี่ยรายปีของ forecasted precipitation errors จากการคาดการณ์ล่วงหน้า 1 สัปดาห์ และ 2 สัปดาห์ ใน 4 ภูมิภาค (มม./สัปดาห์) ในช่วง 1 เมษายน 2008 – 31 มีนาคม 2010 สำหรับค่าเฉลี่ยรายปีของ forecasted precipitation errors บริเวณประเทศไทยมีค่าอยู่ในช่วงประมาณ 15 ถึงมากกว่า 25 มม./สัปดาห์

วิธีการทำ bias correction สามารถทำได้หลายวิธี จากวิธีที่ไม่ซับซ้อนไปจนถึงวิธีที่มีความซับซ้อนมากขึ้น (Perfect Prognosis) อาทิ non-equal weighting (โดยให้ค่าน้ำหนักของวันที่อยู่ใกล้มากกว่า) หรือการใช้ probability density function (PDF) adjustment (Wang and Xie, 2007) จากการคาดการณ์และการตรวจวัด หรือการใช้ model output statistics (MOS) technique (Glahn and Lowry, 1972) ซึ่งใช้อยู่ในระบบปฏิบัติการของ National Weather Service โดยการหาความสัมพันธ์ระหว่าง predictands กับ predictors ที่เหมาะสมด้วยวิธีทางสถิติ

Crochemore et al. (2016) ได้ปรับแก้ความเอนเอียงเชิงสถิติของการคาดการณ์หยาดน้ำฟ้า เพื่อเพิ่มประสิทธิภาพการคาดการณ์รายฤดูกาลของปริมาณน้ำท่า ในพื้นที่ 16 ลุ่มน้ำในประเทศฝรั่งเศส โดยการทำให้ bias correction ที่ประกอบด้วยสองวิธีหลักคือ (1) linear scaling และ (2)

distribution mapping และใช้ข้อมูลหยาดน้ำฟ้าคาดการณ์รายฤดูกาลจาก ECMWF System 4 ซึ่งเป็น ensemble forecasts สำหรับ 7 เดือนล่วงหน้า ที่มีความละเอียดเชิงพื้นที่ 0.7° ในช่วงปีค.ศ. 1981-2010 ทำการคำนวณหยาดน้ำฟ้าเฉลี่ยในพื้นที่ลุ่มน้ำ โดยใช้ข้อมูลคาดการณ์ 90 วันแรกในการศึกษา สำหรับข้อมูลหยาดน้ำฟ้าจากการตรวจวัดมีความละเอียดเชิงพื้นที่ 8×8 กม. จาก SAFRAN reanalysis of MétéoFrance (Quintana-Seguí et al., 2008; Vidal et al., 2010) และนำมาหาค่าเฉลี่ยในพื้นที่ลุ่มน้ำ

การทำ bias correction ด้วยวิธี linear scaling เป็นการปรับค่าเฉลี่ยรายเดือนจากการคาดการณ์ให้สอดคล้องกับค่าเฉลี่ยรายเดือนจากการตรวจวัด โดยค่า scaling factor (หรือ bias) คำนวณจากค่าสัดส่วนระหว่างค่าจากการตรวจวัด และค่าจากการคาดการณ์ ซึ่งจะคำนวณในช่วง calibration จากนั้นจึงใช้เป็น multiplicative factor ในการปรับค่าคาดการณ์ของหยาดน้ำฟ้ารายวัน ส่วนการทำ bias correction ด้วยวิธี distribution mapping เป็นการปรับข้อมูลจากการคาดการณ์ให้มีการกระจายตัวเชิงสถิติสอดคล้องกับข้อมูลจากการตรวจวัด โดยอาจใช้ parametric distribution หรือ empirical distribution

Crochemore et al. (2016) เปรียบเทียบ bias correction 8 รูปแบบ ดังแสดงในตารางที่ 2.6 โดยเป็นการใช้ bias correction 2 วิธีที่กล่าวข้างต้น มีกรณีการใช้ข้อมูลทั้งปี กับใช้ข้อมูลแยกรายเดือน ตลอดจนการใช้ empirical distribution และ Gamma distribution ของข้อมูลรายเดือน และรายวัน

ตารางที่ 2.6 วิธีการและรูปแบบของการทำ bias corrections และข้อมูลที่ใช้

Abbreviation	Calibration based on	Description
LS-y LS-m	the whole year calendar months	Linear scaling of monthly values
EDM-y EDM-m	the whole year calendar months	Empirical distribution mapping of monthly values
GDM-y GDM-m	the whole year calendar months	Gamma distribution mapping of monthly values
EDMD-y EDMD-m	the whole year calendar months	Empirical distribution mapping of daily values

ที่มา: Crochemore et al. (2016)

ด้วยเหตุที่ ECMWF System 4 seasonal precipitation forecasts แสดงค่าความเอนเอียงรายเดือนที่สูง การทำ bias correction เมื่อใช้ข้อมูลทั้งปีจะมีประสิทธิภาพน้อยกว่าการทำแบบรายเดือน อย่างไรก็ตาม ผลการศึกษาพบว่า ในพื้นที่ลุ่มน้ำโดยส่วนใหญ่ EDMD หรือ LS มีประสิทธิภาพที่ดีในการปรับความเอนเอียงรายปีและรายเดือนด้วย EDMD-m มีประสิทธิภาพในการเพิ่ม reliability ของการคาดการณ์หยาดน้ำฟ้า และอัตราการไหล ในขณะที่ LS-m ช่วยในการเพิ่ม sharpness และ accuracy

Manzanas et al. (2015) ศึกษาเกี่ยวกับ reanalysis uncertainty ในพื้นที่ประเทศฟิลิปปินส์ และพบว่าการเลือกข้อมูล reanalysis มีความสำคัญต่อการทำ statistical downscaling ในเขตร้อน โดยได้แนะนำให้ใช้ข้อมูล ERA-Interim reanalysis (Dee et al., 2011) ในการแทนของ Perfect Prognosis ข้อมูลคาดการณ์รายฤดูกาลมาจาก GCMs 4 แบบจำลองภายใต้โครงการ ENSEMBLES multimodel seasonal hindcast (Weisheimer et al., 2009) จาก the European Centre for Medium-Range Weather Forecasts (ECMWF), the Leibniz Institute of Marine Sciences (IFM-GEOMAR), the Euro-Mediterranean Centre for Climate Change (CMCC-INGV) และ Meteo France (MF)

Manzanas et al. (2017) เปรียบเทียบวิธีการทำ statistical downscaling โดยใช้วิธี Bias Correction (BC) ที่ทันสมัยและล่าสุด ณ เวลานั้น 2 วิธี และ Perfect Prognosis (PP) 2 วิธี พื้นที่ศึกษาคือประเทศฟิลิปปินส์ โดยแบ่งพื้นที่ตาม Climatic Types (CTs) 4 แบบ (CT1, CT2, CT3, CT4) และใช้ข้อมูลฝนตรวจวัดรายวันจำนวน 42 สถานีจาก PAGASA และข้อมูล reanalysis และ seasonal forecast ในช่วงปีค.ศ. 1981-2005 สำหรับ upper-air variables ที่ใช้เป็น predictors คือ zonal wind component U ที่ 850 และ 200 hPa ความชื้นจำเพาะ Q และอุณหภูมิ T ที่ 850 hPa ส่วน surface precipitation เป็น target variable

วิธีที่ใช้เป็นตัวแทนของ PP ในการทำ Downscaling คือ Generalized Linear Models (GLMs) และ เทคนิค analog โดยใช้ predictors เป็นการผสมระหว่าง circulation 2 ตัว คือ U ที่ 850 และ 300 hPa และ thermodynamic 2 ตัว คือ Q และ T ที่ 850 hPa สำหรับเทคนิค analog (Lorenz 1963, 1969) เป็นการประมาณค่า local downscaled values โดยใช้ atmospheric configuration ที่กำหนดไว้โดยเฉพาะ ในการศึกษาที่ใช้เวอร์ชัน deterministic ของ เทคนิคจากการศึกษาของ Zorita et al. (1995) และ Cubasch et al. (1996)

สำหรับวิธีการที่ใช้เป็นตัวแทนของ BC คือ การใช้ parametric และ empirical quantile mapping โดยทำการ fit ข้อมูลฝนรายวันกับ gamma distribution และ การใช้ empirical PDF

ผลการศึกษาพบว่า BC และ PP ต่างช่วยลด systematic model biases แต่ BC ไม่ได้ช่วยในเรื่องของ skill, correlation และ reliability เนื่องจาก BC เป็นการแปลงค่าปริมาณหยาดน้ำฟ้าโดยตรง โดยไม่ได้ใช้ข้อมูลเพิ่มเติมเกี่ยวกับ underlying physical phenomena สำหรับวิธี PP สามารถช่วยเพิ่ม correlation และ reliability หรืออาจทำให้ลดลงก็ได้ เนื่องจากเป็นการใช้ physically-based large scale model predictors ในการอนุมาน local precipitation อย่างไรก็ตามการพิจารณาเลือกวิธีในการทำ statistical downscaling มีความสำคัญเป็นอย่างยิ่ง และขึ้นอยู่กับหลายปัจจัย อาทิ พื้นที่ ฤดูกาล ความเชื่อมโยงระหว่าง large scale และ local scale climate และ model skill ในการคาดการณ์ตัวแปรพื้นผิวและในอากาศชั้นบน ตลอดจนขึ้นอยู่กับวัตถุประสงค์ของการนำไปประยุกต์ใช้

2.3 การทบทวนวรรณกรรมการคาดการณ์สภาพอากาศแบบผสม (Hybrid methods)

วิธีการคาดการณ์สภาพอากาศแบบผสมหมายถึง การสร้างแบบจำลองโดยใช้วิธีการทางสถิติหรือ machine learning กับผลลัพธ์ของการคาดการณ์จาก Dynamic model จึงเป็นการผสมระหว่างกระบวนการทางฟิสิกส์และวิธีการทางสถิติเข้าด้วยกัน ซึ่งงานวิจัยส่วนนี้จะดำเนินการในปีที่สองเพื่อเพิ่มประสิทธิภาพการคาดการณ์ให้ดียิ่งขึ้น ในบทนี้จะเป็นการทบทวนวรรณกรรมที่เกี่ยวข้องกับการใช้วิธีการ machine learning กับ การคาดการณ์สภาพอากาศ

Hung et al. (2009) ประยุกต์ใช้โครงข่ายประสาทเทียม (Artificial Neural Network, ANN) เพื่อปรับปรุงประสิทธิภาพของการคาดการณ์ฝนในกรุงเทพมหานคร ประเทศไทย โดยพัฒนาโมเดล ANN ที่ใช้ข้อมูลฝนรายชั่วโมงที่ต่อเนื่องกัน 3 ปี คือปี 1997 ถึง 1999 จากสถานีตรวจวัดปริมาณน้ำฝน 75 สถานี จากการทดลองพบว่าโมเดล ANN มีประสิทธิภาพในการคำนวณที่รวดเร็ว ค่าที่คาดการณ์ของปริมาณน้ำฝนทั้ง 75 สถานีค่อนข้างตรงกับปริมาณน้ำฝนที่สังเกตได้สำหรับการคาดการณ์ล่วงหน้าระยะสั้น 1 หรือ 2 ชั่วโมง โดยมีค่าดัชนีประสิทธิภาพสูงสุดที่ 98% สำหรับบางสถานี การคาดการณ์ล่วงหน้า 3 ชั่วโมงให้ผลลัพธ์ที่อยู่ในเกณฑ์พอยอมรับได้ แต่ดัชนีประสิทธิภาพจะ

ค่อย ๆ ลดลงเมื่อระยะเวลาของการคาดการณ์ล่วงหน้าเพิ่มขึ้นจาก 4 เป็น 6 ชั่วโมง ทั้งนี้ ประสิทธิภาพของการคาดการณ์ล่วงหน้า 6 ชั่วโมงของโมเดล ANN อยู่ในระดับต่ำและการคาดการณ์ ไม่แม่นยำ โดยมีค่าดัชนีประสิทธิภาพอยู่ที่ 36-45%

Hu (1964) เริ่มใช้โมเดล ANN ในการพยากรณ์สภาพอากาศ โดยใช้ ระบบ Adaline (Adaptive Linear Element) เป็นระบบสำหรับแบ่งแยกรูปแบบ ข้อมูลนำเข้าสำหรับระบบนี้ ประกอบด้วยข้อมูลความกดอากาศที่ระดับน้ำทะเล 200 และความต่างของความกดอากาศใน 24 ชั่วโมง ที่ครอบคลุมพื้นที่ตั้งแต่บริเวณ 25N ไปถึง 65N และ 110W ไปถึง 170W หลังจากการฝึกสอน ระบบ ได้ทดสอบและพบว่าระบบนี้สามารถพยากรณ์ว่าฝนตก หรือฝนไม่ตก สำหรับพื้นที่อาวซานฟรานซิสโกในกรณีต่าง ๆ ที่อิสระกัน 100 กรณีได้ผลเป็นที่น่าพอใจเทียบเคียงกันได้กับการพยากรณ์ อย่างเป็นทางการของ U.S. Weather Bureau ในช่วงเวลาเดียวกัน Hu เชื่อว่าระบบ adaptive มีความสามารถในการพยากรณ์สภาพอากาศ โดยที่ไม่ต้องมีความเข้าใจในเรื่องหลักการพลวัตหรือมีการ วัดค่าพารามิเตอร์ทางฟิสิกส์ที่เกี่ยวข้องอย่างครบถ้วน

Toth et al. (2000) เปรียบเทียบความแม่นยำของ ANN, โมเดล auto-regressive moving average (ARMA) และวิธี non-parametric nearest neighbors ในการคาดการณ์ฝนระยะสั้น (ช่วงเวลา 1-6 ชั่วโมง) ที่เทือกเขา Apennines ในประเทศอิตาลี การพยากรณ์ฝนด้วยเทคนิคเหล่านี้ โดยเฉพาะอย่างยิ่ง ANN ช่วยให้การพยากรณ์น้ำท่วมมีความแม่นยำมากขึ้นอย่างมีนัยสำคัญเมื่อ เปรียบเทียบกับการใช้วิธีการพยากรณ์ฝนอย่างง่ายที่มักใช้กันในทางอุทกวิทยา

Geetha and Selvaraj (2011) ประยุกต์ใช้ Back Propagation Neural Networks (BPNNs) ซึ่งเป็นเทคนิคที่ใช้หลักการทำงานของเซลล์ประสาทชีวภาพกับการคาดการณ์ปริมาณฝน ผลลัพธ์ที่ได้จากแบบจำลองแสดงให้เห็นว่าแบบจำลองสามารถพยากรณ์ได้ดีทั้งในช่วงการเทรนและ ช่วงการทดสอบ

Lu and Wang (2011) ประยุกต์ใช้ Support Vector Machine (SVM) เพื่อการคาดการณ์ ปริมาณน้ำฝนรายเดือนในมณฑลกวางสีประเทศจีน SVM เป็นอัลกอริทึมที่ช่วยแก้ปัญหาการจำแนก ข้อมูล โมเดลที่ใช้เป็นการรวมในลักษณะที่ไม่เป็นเชิงเส้น (nonlinear) ของ SVM ที่มีฟังก์ชันเคอร์เนล (Kernel function) ต่างกันและพารามิเตอร์ก็ต่างกัน ผลการทดลองแสดงให้เห็นว่าโดยทั่วไปเทคนิค ดังกล่าวให้ความแม่นยำในการคาดการณ์มากกว่าโมเดลอื่น ๆ จึงอาจเป็นทางเลือกหนึ่งสำหรับการ พยากรณ์ทางอุตุนิยมวิทยา

Rasouli et al. (2012) คาดการณ์ปริมาณน้ำท่ารายวันล่วงหน้า 1 ถึง 7 วันสำหรับพื้นที่เก็บ กักน้ำขนาดเล็กในบริติชโคลัมเบีย ประเทศแคนาดา โดยประยุกต์ใช้อัลกอริทึม Machine Learning ที่ แตกต่างกัน 3 แบบ ได้แก่ support vector regression (SVR), Bayesian neural network (BNN) และ Gaussian process (GP) เพื่อเปรียบเทียบกับวิธี Multiple linear regression (MLR)

โดยทั่วไป MLR มีประสิทธิภาพต่ำกว่าโมเดลอื่นที่ไม่ใช่โมเดลเชิงเส้น และ BNN มีแนวโน้มที่จะดีกว่าโมเดลที่ไม่ใช่เชิงเส้นอื่น ๆ ที่เหลือ นอกจากนี้ เมื่อพิจารณาตัวแปรและข้อมูลที่ใช้คาดการณ์พบว่า local observations ร่วมกับ GFS output จะดีที่สุดในการคาดการณ์ล่วงหน้าระยะเวลาสั้น ๆ ในขณะที่ local observations ร่วมกับ climate indices ให้ผลดีที่สุดเมื่อคาดการณ์ล่วงหน้าระยะเวลาที่นานขึ้น

Rezaeian-Zadeh et al. (2013) เปรียบเทียบอัลกอริทึม ANN 4 ชุดในการคาดการณ์รายเดือนเกี่ยวกับปริมาณน้ำที่ไหลจากพื้นที่ลุ่มน้ำ Idenak ในจังหวัด Kohkiluyeh Boyer-Ahmad ทางตะวันตกเฉียงใต้ของประเทศอิหร่าน ซึ่งได้แก่ resilient backpropagation, scaled conjugate gradient, variable learning rate และ Levenberg-Marquardt พบว่า scaled conjugate gradient มีประสิทธิภาพมากกว่าอัลกอริทึมอื่นเมื่อพิจารณาจากค่าสัมประสิทธิ์การกำหนด (R^2) และ RMSE นอกจากนี้ข้อมูลนำเข้าที่ประกอบด้วยปริมาณฝน ณ เดือนปัจจุบันและเวลาก่อนหน้า 1 เดือน รวมกับปริมาณน้ำที่ไหลในเดือนก่อนหน้า 1 เดือน ใช้คาดการณ์ปริมาณน้ำที่ไหลรายเดือนได้มีประสิทธิภาพดีกว่าข้อมูลอื่น ๆ และโดยทั่วไปจะสามารถคาดการณ์ได้ดีสำหรับพื้นที่แห้งแล้งและกึ่งแห้งแล้ง

Solomantine (2003) ตรวจสอบประสิทธิภาพเชิงเปรียบเทียบของเทคนิคการสร้างแบบจำลอง 2 แบบคือ ANN และแบบจำลองต้นไม้ (MTs) ในการแปลงค่าปริมาณฝน - น้ำท่า โดยศึกษาการใช้เทคนิคดังกล่าวคาดการณ์ปริมาณน้ำท่าล่วงหน้า 1, 3 และ 6 ชั่วโมง ของพื้นที่ลุ่มน้ำแห่งหนึ่งในยุโรป ซึ่งพบว่าทั้งสองเทคนิคให้ผลลัพธ์ที่ดีมากสำหรับการคาดการณ์ล่วงหน้าหนึ่งชั่วโมง ผลลัพธ์ที่ดีพอสมควรสำหรับการคาดการณ์ล่วงหน้า 3 ชั่วโมงและผลลัพธ์ที่ไม่ค่อยดีสำหรับการคาดการณ์ล่วงหน้า 6 ชั่วโมง เมื่อเปรียบเทียบสองเทคนิค ทั้ง ANN และ MT มีประสิทธิภาพเกือบใกล้เคียงกันในการคาดการณ์ล่วงหน้าหนึ่งชั่วโมง และผลของ ANN ดีกว่า MT เล็กน้อยเมื่อคาดการณ์ล่วงหน้าในระยะเวลาที่นานขึ้น แต่ในอีกแง่หนึ่ง MT ใช้เวลาในกระบวนการเทรนเร็วมาก เซตระบบได้ง่าย และให้ผลที่เข้าใจได้ นอกจากนี้ยังสามารถสร้างแบบจำลองที่มีความซับซ้อนหลากหลายได้ด้วย

Stephanie et al. (2017) ใช้ ANN เพื่อจำแนกความรุนแรงของความเสียหายจากพายุลูกต่าง ๆ ในแง่ของความสูญเสียทางเศรษฐกิจ ข้อมูลที่นำเข้าคือ ประชากรที่ได้รับผลกระทบ (อยู่ในรัศมีลมแรงของพายุโซนร้อนตามเส้นทางที่พายุเคลื่อนตัว) ความเร็วลมสูงสุด (ไมล์ต่อชั่วโมง) ความกดอากาศต่ำสุด (มิลลิบาร์) คลื่นพายุสูงสุด (ฟุต) ปริมาณฝนทั้งหมด (นิ้ว) และตำแหน่งพื้นที่ดิน 4 ตำแหน่งที่พายุขึ้นชายฝั่ง ในรูปขององศาละติจูดและลองจิจูด ผลลัพธ์ที่ได้คือระดับผลกระทบตามความสูญเสียทางเศรษฐกิจ

นอกจากวิธีที่กล่าวมาข้างต้นแล้ว ยังมีงานวิจัยต่างๆ ที่ได้ศึกษาวิธีการ machine learning สำหรับการเพิ่มประสิทธิภาพการคาดการณ์ฝน ดังแสดงในตารางที่ 2.7

ตารางที่ 2.7 สรุปวิธีการทาง machine learning สำหรับการเพิ่มประสิทธิภาพการคาดการณ์ฝน

คณะวิจัย	พื้นที่ ศึกษา	ข้อมูล สำหรับ การศึกษา	เทคนิค	ตัวประเมิน	ตัวแปร
Goswami and Srividya (1996)	Global (all over India)	Yearly (135 years)	Artificial Neural Network (EBP)	Relative percentage error	Mean rainfall
Sahai et al. (2000)	Global (all over India)	Monthly (1876- 1994)	Artificial Neural Network (EBP)	RMSE, Correlation coefficient	Min-max Temperature
Kannan and Ghosh (2011)	Local (River)	Daily (50 years)	Decision tree, CART, K-mean	MSE	Temperature, pressure, wind speed, rainfall
Kannan et el. (2010)	Global (India)	Quarterly (5 years)	Regression	MSE	Min-max Temperature, wind direction, humidity, rainfall
Dutta and Tahbilder (2014)	Global (India)	Monthly (6 years)	Regression	RMSE	Min-max Temperature, wind direction, humidity, rainfall


บทที่ 3

การเพิ่มประสิทธิภาพการคาดการณ์ฝนโดยใช้แบบจำลองคู่ควบ WRF-ROMS

3.1 แบบจำลองคู่ควบ WRF-ROMS

การศึกษานี้จะใช้แบบจำลองคู่ควบระหว่างแบบจำลองบรรยากาศ (Atmospheric model) กับแบบจำลองทางสมุทรศาสตร์ (Oceanic model) ที่พัฒนามาจากระบบแบบจำลอง Coupled-Ocean-Atmosphere-Wave-Sediment Transport (COAWST) Modeling System โดยหน่วยงาน United States Geological Survey (USGS) (Warner et al., 2010) ระบบดังกล่าวเป็นการเชื่อมโยงความสัมพันธ์ของระบบต่าง ๆ ทางธรรมชาติเข้าด้วยกัน เพื่อให้แบบจำลองมีความคล้ายคลึงกับธรรมชาติจริงมากที่สุด โดยประกอบไปด้วยแบบจำลองต่อไปนี้ 1) บรรยากาศ Weather Research and Forecast Model (WRF) (2) สมุทรศาสตร์ Regional Oceanic Model (ROMS) (3) คลื่นทะเล Simulating Wave Nearshore (SWAN) และ (4) การพัดพาตะกอนคลื่น (Sediment transport model) ดังแสดงในรูปที่ 3.1 ด้วยความสำคัญของการเปลี่ยนแปลงของอุณหภูมิพื้นผิวน้ำทะเล (Sea surface temperature; SST) เพราะอาจเป็นปัจจัยหนึ่งที่มีผลต่อการแปรผันของสภาพอากาศในช่วงระยะ 2 สัปดาห์ โดยเฉพาะพื้นที่ประเทศไทยซึ่งตั้งอยู่ระหว่างมหาสมุทรเขตร้อนและมีพื้นที่ติดทั้งมหาสมุทรอินเดียและมหาสมุทรแปซิฟิก ดังนั้น งานวิจัยนี้จึงเน้นไปที่การศึกษาปฏิสัมพันธ์ของบรรยากาศกับมหาสมุทรที่มีผลต่อการแปรปรวนของฝนเป็นหลัก กล่าวคือ จะพิจารณาเฉพาะการคู่ควบระหว่าง WRF และ ROMS เท่านั้น

Torsri et al. (2014) ได้นำระบบ COAWST มาประยุกต์ใช้สำหรับคาดการณ์สภาพอากาศระยะสั้น (ไม่เกิน 7 วัน) โดยใช้ระบบคู่ควบ WRF-ROMS การศึกษาของงานวิจัยดังกล่าวแสดงให้เห็นว่า การใช้ระบบคู่ควบ WRF-ROMS ทำให้ความสามารถของการคาดการณ์ฝนสำหรับพื้นที่ประเทศไทยมีความแม่นยำมากขึ้นเมื่อเทียบกับการใช้แบบจำลองแบบไม่คู่ควบ อิทธิพลของอุณหภูมิของน้ำทะเลนั้นมีความสำคัญและมีผลต่อรูปแบบของฝนในพื้นที่ อย่างไรก็ตาม การคาดการณ์ทั้งในระยะสั้นจนถึงระยะกลาง (1 ถึง 2 สัปดาห์) นั้น ค่าความแม่นยำของการคาดการณ์โดยใช้แบบจำลองระดับภูมิภาค (Regional model) ขึ้นอยู่กับค่าเริ่มต้นด้วย (Vitart et al., 2008) นอกจากนี้ยังพบว่าความสามารถในการคาดการณ์การแปรผันในช่วงรายสัปดาห์ของอุณหภูมิผิวน้ำทะเลและปฏิสัมพันธ์กันระหว่างชั้นบรรยากาศในบริเวณมหาสมุทรอินเดีย หรือที่เรียกว่า Madden-Julian Oscillation (MJO) ก็เป็นอีกปัจจัยที่ทำให้การคาดการณ์ฝนในช่วงระยะเวลาดังกล่าวมีความแม่นยำมากขึ้น (Tian et al., 2017)




รูปที่ 3.1 ระบบแบบจำลองพลวัต COAWST ที่พัฒนาโดย USGS (Warner et al., 2010)

3.2 ขอบเขตพื้นที่ศึกษาและการกำหนดค่าแบบจำลอง

การศึกษานี้จะใช้การรันแบบคู่ควบระหว่างแบบจำลองอากาศ WRF และแบบจำลองมหาสมุทร ROMS (WRF-ROMS) แบบ 1 ต่อ 1 โดเมน สำหรับโดเมน WRF นั้น จะครอบคลุมพื้นที่ภูมิภาคเอเชียตะวันออกเฉียงใต้ มีความละเอียดเชิงพื้นที่ของกริดประมาณ 25 กม. และ โดเมนของ ROMS จะครอบคลุมพื้นที่ที่กว้างกว่าโดยรวมอิทธิพลทั้งจากมหาสมุทรอินเดียและมหาสมุทรแปซิฟิก ในส่วน ROMS จะใช้ค่าเริ่มต้นจาก Hybrid Coordinate Ocean Model (HYCOM) ซึ่งเป็นข้อมูลผนวกกันระหว่างแบบจำลองและข้อมูลตรวจวัดทางทะเล (Data assimilation) อันประกอบไปด้วย ข้อมูลอุณหภูมิพื้นผิวน้ำทะเล (Sea surface temperature) ข้อมูลความเค็ม (Salinity) และข้อมูลน้ำ (Currents) ในการศึกษาครั้งนี้ ทั้ง WRF และ ROMS มีความละเอียดเชิงพื้นที่ของกริดประมาณ 25 กม. ดังแสดงในรูปที่ 3.2 ก)

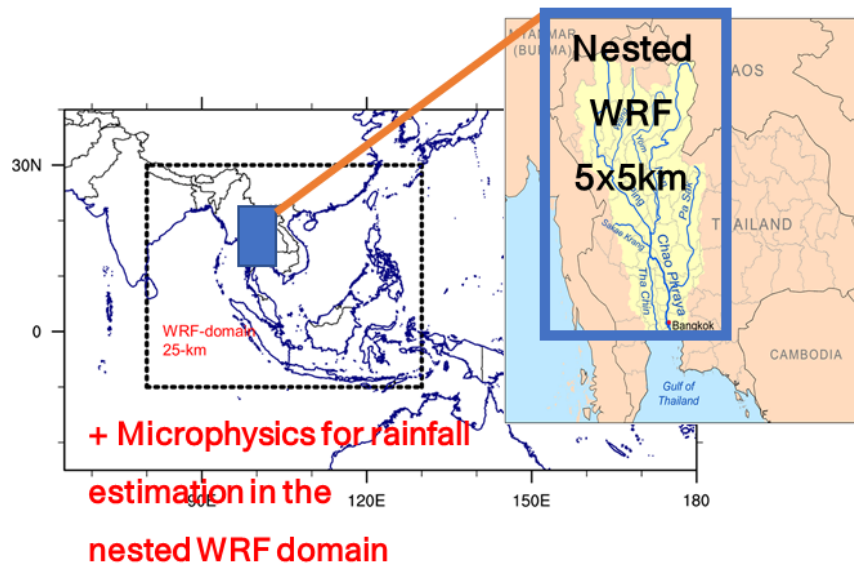
นอกจากนี้ เพื่อศึกษาประสิทธิภาพความแม่นยำของแบบจำลอง WRF-ROMS การศึกษานี้ยังได้พิจารณาความไวของแบบจำลองต่อ Microphysics options สำหรับการคำนวณเมฆฝนในระดับไมโคร โดยใช้กระบวนการ Nesting จากโดเมนที่ความละเอียด 25 กม. ให้มีความละเอียดสูงขึ้นเป็น 5 กม. โดยครอบคลุมพื้นที่ลุ่มน้ำเจ้าพระยา ดังแสดงในรูปที่ 3.2 ข)

ก) ขอบเขตพื้นที่ศึกษาสำหรับการพิจารณาความไวต่อ Cumulus options



ข) ขอบเขตพื้นที่ศึกษาสำหรับการพิจารณาความไวต่อ Microphysics options

WRF:ROMS = 2:1



รูปที่ 3.2 พื้นที่ศึกษาของแบบจำลอง ก) WRF (Non-nesting) และ ROMS และ ข) WRF nesting จาก 25 กม. เป็น 5 กม.

3.3 การออกแบบและขอบเขตการวิจัยและการติดตั้งแบบจำลอง

เนื่องจากพื้นที่ลุ่มน้ำเจ้าพระยาเป็นพื้นที่ที่มีความสำคัญต่อเศรษฐกิจของประเทศ งานวิจัยนี้จึงเลือกพื้นที่ลุ่มน้ำเจ้าพระยาเป็นพื้นที่ศึกษา และเลือกกรณีน้ำท่วมปีพ.ศ. 2554 เป็นกรณีศึกษา เพราะเป็นเหตุการณ์น้ำท่วมใหญ่ที่เห็นได้ชัดและสร้างความเสียหายให้กับพื้นที่ดังกล่าวเป็นอย่างมาก ซึ่งเหตุการณ์น้ำท่วมส่วนหนึ่งเป็นผลมาจากพายุ จึงจะพิจารณา 2 เหตุการณ์ที่พายุส่งผลกระทบต่อไทย โดยเฉพาะลุ่มน้ำเจ้าพระยา คือ

- 1) พายุไทม่า ระหว่างวันที่ 24-30 มิถุนายน 2554
- 2) พายุทกเตน ระหว่างวันที่ 28 กรกฎาคม ถึง 4 สิงหาคม 2554

แต่ละเหตุการณ์จะพิจารณาค่าเริ่มต้นการคาดการณ์ของแบบจำลองเป็น 2 ช่วง คือ ณ ช่วงที่เหตุการณ์เกิดขึ้น หรือ lead time 0 (L-0) และก่อนเหตุการณ์เกิดขึ้น 1 สัปดาห์ หรือ lead time 1 (L-1) และศึกษาความสามารถและความแม่นยำในการคาดการณ์ฝนในระยะ 2 สัปดาห์ของแบบจำลองคู่ควบในช่วงเวลาที่แตกต่างกัน

ในการศึกษาความไวของแบบจำลอง ต่อวิธีการประมาณค่าการเกิดเมฆฝนในระดับไมโคร (Microphysics scale) ได้เพิ่มความละเอียดของพื้นที่ศึกษา (ลุ่มน้ำเจ้าพระยา) เป็น 5 กม. โดยการทำ Nesting WRF domain อีก 1 โดเมน (WRF:ROMS = 2:1 โดเมน) โดยโดเมนของ ROMS ยังเท่าเดิม ดังแสดงในรูปที่ 3.2 ทั้งนี้จะพิจารณาเฉพาะกรณีที่แบบจำลอง WRF-ROMS ที่ความละเอียด 25 กม. ให้ค่าความแม่นยำต่ำ เพื่อเป็นการทดสอบว่าการใช้เทคนิคแบบ Nesting ที่ความละเอียดสูงขึ้น ร่วมกับการพิจารณาการคำนวณเมฆฝนในระดับไมโคร จะสามารถเพิ่มความแม่นยำในการคาดการณ์ได้ดีมากกว่า Non-nesting หรือไม่ การศึกษา WRF:ROMS แบบ 2:1 โดเมน ได้พิจารณา 2 ตัวเลือกที่สอดคล้องกับรูปแบบการเกิดเมฆในพื้นที่เขตร้อนใกล้ศูนย์สูตร คือ Kessler microphysics (KS) และ Goddard microphysics scheme (GD)

นอกจากนี้ การศึกษานี้ก็จะเน้นไปที่การวิเคราะห์ความไวของแบบจำลอง (Sensitivity analysis) ต่อค่าเริ่มต้นและค่าขอบ (Initial and boundary conditions; ICBC) โดยค่า ICBC จะใช้ข้อมูลจาก 2 แหล่ง คือ ข้อมูลราย 6 ชั่วโมง ของ NCEP Climate Forecast System Reanalysis (CFSR) และ NCEP FNL (Final) operational global analysis and forecast (FNL_GFS) เมื่อรวมกับการพิจารณาความไวของแบบจำลองต่อฟิสิกส์ที่เกี่ยวข้องกับการคำนวณเมฆฝน (Cumulus schemes: CU options) จะแยกได้เป็นจำนวนทั้งสิ้น 16 กรณี ดังแสดงในตารางที่ 3.1

ตารางที่ 3.1 การทดสอบความไวของแบบจำลองที่มีต่อข้อมูลเริ่มต้น/ค่าขอบ (Initial & lateral boundary conditions: ICBC) และ ฟิสิกส์ที่เกี่ยวข้องกับการคำนวณเมฆฝน (Cumulus schemes: CU option)

EXP	ช่วงเหตุการณ์	ค่าเริ่มต้น วันที่ (Initial)	ฟิสิกส์ CU*	ข้อมูลเริ่มต้น/ค่าขอบ (ICBC)	Lead time
01	พายุไต้ฝุ่น (HM)	L-0: 20-06- 2554	BMJ	CFS	0
02					1
03		L-1: 13-06- 2554		GFS	0
04					1
05		G3D		CFS	0
06					1
07				GFS	0
08					1
09	พายุฝน (NT)	L-0: 18-07- 2554	BMJ	CFS	0
10					1
11		L-1: 25-07- 2554		GFS	0
12					1
13		G3D		CFS	0
14					1
15				GFS	0
16					1

หมายเหตุ : * ในการศึกษานี้ พิจารณา CU ที่ต่างกัน 2 แบบ คือ Betts–Miller–Janjic Scheme (BMJ) และ Grell 3D Ensemble Scheme (G3D) โดยทั้งสองรูปแบบนี้เป็นที่นิยมใช้ในการพิจารณา ค่าฝนจากการพาความร้อน (Convective rain)

3.4 การตรวจสอบความถูกต้องของแบบจำลองด้วยวิธีการทางสถิติ

เพื่อตรวจสอบความถูกต้องของแบบจำลองและความแม่นยำของการคาดการณ์ ผลลัพธ์ของแบบจำลองจากทั้งหมด 16 กรณีจะถูกนำมาเปรียบเทียบกับข้อมูลตรวจวัด ที่รวบรวมมาจากทั้งข้อมูลตรวจวัดสถานี และข้อมูลดาวเทียม โดยเบื้องต้นจะพิจารณาฝนสะสมและความแตกต่างระหว่างผล

จากแบบจำลองกับข้อมูลตรวจวัดเป็นรายสัปดาห์ (Weekly total rainfall) การประเมินค่าความแม่นยำของผลจากแบบจำลอง (Mod) กับค่าตรวจวัด (Obs) จะใช้ค่าสถิติดังต่อไปนี้

- 1) ค่าสหสัมพันธ์เชิงเวลา (Temporal correlation coefficient: TCC)

$$TCC = \frac{1}{N-1} \sum \frac{(Obs - \overline{Obs}) (Mod - \overline{Mod})}{S_{Obs} S_{Mod}}$$

เมื่อ S คือ ค่าเบี่ยงเบนมาตรฐาน

N คือจำนวนข้อมูล

- 2) รากที่สองของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (Root mean squared error: RMSE)

$$RMSE = \sqrt{\frac{1}{N} \sum (Mod - Obs)^2}$$

เมื่อ N คือ จำนวนข้อมูล

- 3) ค่าเอนเอียงเฉลี่ย (Mean bias : MB)

$$MB = \frac{1}{N} \sum (Mod - Obs)$$

เมื่อ N คือ จำนวนข้อมูล

- 4) ค่าความน่าจะเป็นของการตรวจพบ (Probability of detection: POD)

$$POD = \frac{TP}{TP + FN}$$

เมื่อ TP คือ True positive จำนวนครั้งที่เหตุการณ์เกิดขึ้น และ Mod ทำนายว่าเกิด

FP คือ False positive จำนวนครั้งที่ไม่เกิดเหตุการณ์แต่ Mod ทำนายว่าเกิด

FN คือ False negative จำนวนครั้งที่เหตุการณ์เกิดขึ้น แต่ Mod ทำนายว่าไม่เกิด
TN คือ True negative จำนวนครั้งที่ไม่เกิดเหตุการณ์และ Mod ทำนายว่าไม่เกิด
 ค่าของ **TP, FP, FN** และ **TN** แสดงในตาราง Confusion matrix ได้ดังนี้

(Contingency table) สำหรับ การคำนวณ POD ผลจาก	ข้อมูลตรวจวัด (OBS)		
		เกิดเหตุการณ์	ไม่เกิดเหตุการณ์
	เกิด เหตุการณ์	TP	FP
ไม่เกิด เหตุการณ์	FN	TN	

การศึกษานี้ แบ่งเหตุการณ์การเกิดฝนจากฝนรายวัน ออกเป็น 4 กลุ่ม ตามคำจำกัดความของกรมอุตุนิยมวิทยา ดังนี้

1. ฝนเล็กน้อย (Light rain) ฝนตกมีปริมาณตั้งแต่ 0.1 มม. ถึง 10.0 มม.
2. ฝนปานกลาง (Moderate rain) ฝนตกมีปริมาณตั้งแต่ 10.1 มม. ถึง 35.0 มม.
3. ฝนหนัก (Heavy rain) ฝนตกมีปริมาณตั้งแต่ 35.1 มม. ถึง 90.0 มม.
4. ฝนหนักมาก (Very heavy rain) ฝนตกมีปริมาณตั้งแต่ 90.1 มม. ขึ้นไป

ค่าสถิติที่กล่าวมาข้างต้น จะพิจารณาทั้งภาพรวมรายสองสัปดาห์ (2-week ACC.) และ รายสัปดาห์ (Week 1 และ Week 2) ของแต่ละ Lead time

3.5 การประเมินผลความแม่นยำของระบบคู่ควบ WRF-ROMS ที่ความละเอียด 25 กม.

ในงานวิจัยนี้ ได้มีการศึกษาในเบื้องต้นเกี่ยวกับความเหมาะสมของข้อมูลนำเข้าและค่าพารามิเตอร์ต่าง ๆ ที่เลือกใช้กับระบบคู่ควบ WRF-ROMS โดยเป็นการทดสอบเพื่อประเมินความแม่นยำและความไวของแบบจำลองต่อข้อมูลนำเข้าคือ GFS และ CFS และความไวต่อตัวเลือกทางฟิสิกส์ในการประมาณค่าฝนคือ BMJ และ G3D ด้วยการทดลองและเปรียบเทียบผลจำนวนทั้งสิ้น 16 การทดสอบ ดังรายละเอียดในตารางที่ 3.1

จากผลการประเมินพบว่า ชุดการทดสอบที่ใช้ข้อมูลนำเข้าเป็น CFS และการคำนวณค่าแบบ G3D ให้ค่าค่อนข้างดีกว่าแบบอื่น ๆ ดังนั้น การวิเคราะห์และนำเสนอผลต่อจากนี้จะนำเสนอเฉพาะผลที่ได้จากการทดสอบในชุดดังกล่าวเท่านั้น โดยจะเปรียบเทียบกับผลจากแบบจำลอง ECMWF ด้วย

3.5.1 การประเมินความแม่นยำของแบบจำลองช่วงพายุไต้ฝุ่น

ถ้ากำหนดให้ Lead-1 คือวันที่ 13-06-2554 เป็นวันเริ่มต้น เมื่อพิจารณาค่าตรวจวัดพบว่า บริเวณพื้นที่ประเทศไทยตอนบนรวมถึงพื้นที่ลุ่มน้ำเจ้าพระยาจะมีฝนตกสะสมในช่วงสองสัปดาห์นับจากวันเริ่มต้น โดยมีปริมาณสูงมากกว่า 100 มม. นั่นคือ เหตุการณ์ฝนตกหนักเกิดขึ้นในสัปดาห์ที่สองนับจากวันเริ่มต้น แต่หากกำหนดให้ Lead-0 (20-06-2554) เป็นวันเริ่มต้น เหตุการณ์ฝนตกหนักจะเกิดขึ้นในช่วงสัปดาห์แรกนับจากวันเริ่มต้น

TCC : รูปที่ 3.3 และ 3.4 แสดงการเปรียบเทียบความสัมพันธ์เชิงเวลา (TCC) ระหว่างผลจากแบบจำลอง WRF-ROMS กับข้อมูลตรวจวัด หากพิจารณาที่ Lead-1 พบว่าความแม่นยำของแบบจำลองในการคาดการณ์ช่วงเวลาที่เกิดเหตุการณ์ (Week 2) บริเวณพื้นที่ลุ่มน้ำเจ้าพระยาตอนบนเมื่อประเมินด้วยค่า TCC โดยส่วนใหญ่มีค่าอยู่ระหว่าง 0.60-0.80 และในตอนบนสุดของพื้นที่ลุ่มน้ำเจ้าพระยามีค่าสูงมากกว่า 0.80 ในกรณีนี้ เราได้เปรียบเทียบค่าความแม่นยำของแบบจำลอง WRF-ROMS กับ S2S ECMWF บริเวณลุ่มน้ำเจ้าพระยาตอนบนในช่วงเวลาเดียวกันด้วย และพบว่า WRF-ROMS ให้ค่า TCC สูงกว่า S2S ECMWF ประมาณ 0.20 แต่หากพิจารณาในช่วง Lead-0 (20-06-2554) ซึ่งเหตุการณ์ฝนตกหนักจะเกิดขึ้นในช่วงสัปดาห์แรกของวันเริ่มต้น พบว่าค่า TCC ของแบบจำลองทั้งสองมีค่าใกล้เคียงกัน

RMSE: สำหรับ RMSE (รูปที่ 3.5 และ 3.6) ในช่วง Lead-1 Week-2 บริเวณพื้นที่ลุ่มน้ำเจ้าพระยาตอนบน พบว่ามีค่าอยู่ระหว่าง 10-40 มม. ค่า RMSE สูงสุดจะพบบริเวณตอนบนสุดของพื้นที่ ซึ่งมีรูปแบบใกล้เคียงกันกับค่า RMSE ในช่วง Lead-0 Week-1 เมื่อเทียบระหว่าง WRF-ROMS กับ ECMWF เห็นได้ว่า ในช่วง Lead-0 นั้น S2S ECMWF ดีกว่า WRF-ROMS เพราะให้ค่า RMSE ที่ต่ำกว่า

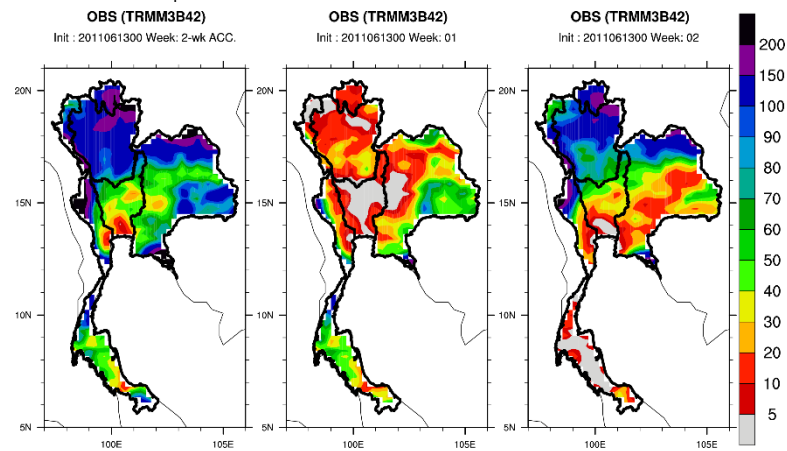
MB: รูปที่ 3.7 แสดงค่าเอนเอียงเฉลี่ยของแบบจำลอง WRF-ROMS สำหรับ Lead-1 ในภาพรวมสองสัปดาห์ ค่าคาดการณ์ที่ได้จากแบบจำลองบริเวณพื้นที่ลุ่มน้ำเจ้าพระยาค่อนข้างต่ำกว่าค่าตรวจวัดประมาณ 8 ถึง 10 มม. โดยเฉลี่ย ทั้งนี้เป็นผลมาจากการที่แบบจำลอง WRF-ROMS ให้ค่าที่ต่ำกว่าค่าตรวจวัดในสัปดาห์ที่สอง ซึ่งเฉลี่ยแล้วต่ำกว่าเกินกว่า 10 มม. เพราะเป็นช่วงที่เกิดเหตุการณ์พายุไต้ฝุ่น และมีบางพื้นที่บริเวณตอนบนสุดของลุ่มน้ำเจ้าพระยาที่ค่าคาดการณ์ต่ำกว่าค่าตรวจวัดมากถึง 20 มม. โดยเฉลี่ย สำหรับในช่วง Lead-0 โดยทั่วไปแบบจำลองก็ให้ค่าคาดการณ์ต่ำกว่าค่า

ตรวจวัด ความเอนเอียงจะสูงกว่า Lead-1 เล็กน้อย แต่โดยรวม รูปแบบการกระจายตัวเชิงพื้นที่ของ MB มีลักษณะคล้ายกัน ช่วงที่เกิดเหตุการณ์ (สัปดาห์ที่ 1) มีความเอนเอียงมาก

POD: จากผลที่ได้ในการคาดการณ์เหตุการณ์ช่วงพายุไต้ฝุ่น Lead-1 พบว่า การคาดการณ์ฝนตกเล็กน้อย (<10 มม./วัน) บริเวณพื้นที่ลุ่มน้ำเจ้าพระยา ในช่วงสองสัปดาห์ให้ค่า POD > 0.7 ความแม่นยำในการคาดการณ์การเกิดฝนตกเล็กน้อยมีค่าสูงสุดในสัปดาห์แรก และลดลงในสัปดาห์ที่สองเหลือประมาณ 0.5-0.6 บริเวณตอนบนของลุ่มน้ำเจ้าพระยา แต่ยังให้ค่า POD ค่อนข้างสูง (> 0.8) ในบริเวณตอนล่างของลุ่มน้ำเจ้าพระยา สำหรับ Lead-0 นั้น โดยภาพรวม ค่า POD บริเวณพื้นที่ลุ่มน้ำเจ้าพระยามีค่าอยู่ระหว่าง 0.6-0.8 แบบจำลองมีความแม่นยำในการทำนายเหตุการณ์ฝนตกเล็กน้อยได้ค่อนข้างสูง โดยค่า POD ในลุ่มน้ำเจ้าพระยาตอนล่างมีค่าสูงกว่าลุ่มน้ำเจ้าพระยาตอนบน หากพิจารณารายสัปดาห์พบว่า สัปดาห์แรกซึ่งเป็นช่วงที่เกิดเหตุการณ์ แบบจำลองให้ค่าความแม่นยำค่อนข้างสูง (> 0.7) ยกเว้นบางพื้นที่บริเวณตอนบนของลุ่มน้ำเจ้าพระยาที่ค่า POD มีค่าอยู่ระหว่าง 0.5-0.6 เท่านั้น รายละเอียดเพิ่มเติมแสดงในรูปที่ 3.8

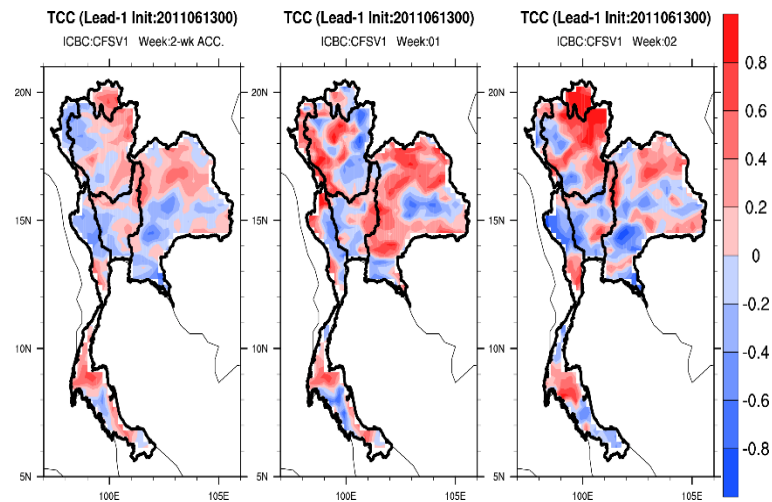
สำหรับการคาดการณ์ฝนตกปานกลาง ค่า POD (รูปที่ 3.9) ชี้ว่า แบบจำลองยังมีข้อจำกัดในการทำนายเหตุการณ์ฝนตกในระดับนี้อยู่ ถึงแม้ POD จะเป็นค่าที่แสดงภาพรวมทั้งสัปดาห์หรือทั้งสองสัปดาห์ แต่ค่า POD คำนวณจากการพิจารณาการเกิดขึ้นของเหตุการณ์ฝนรายวัน และแบบจำลองไม่สามารถคาดการณ์การเกิดเหตุการณ์ฝนรายวันในแต่ละกลุ่มได้ดีพอ โดยเฉพาะกลุ่มฝนระดับปานกลางเป็นต้นไป ดังนั้นในรายงานนี้ จึงไม่ได้แสดงค่า POD ของเหตุการณ์ฝนตกหนักและหนักมาก

ก) ฝนสะสมช่วงเกิดเหตุการณ์ (เริ่มต้น วันที่ 13-06-2554)




ข) ค่าความสัมพันธ์เชิงเวลา (TCC)

WRF-ROMS




S2S ECMWF



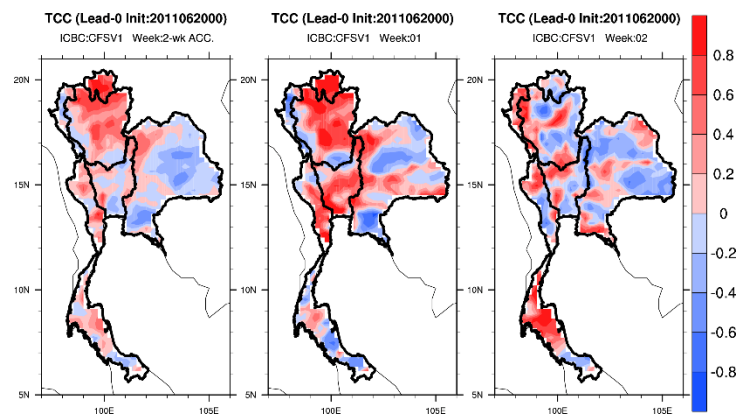
รูปที่ 3.3 ก) ฝนสะสมช่วงเกิดเหตุการณ์ และ ข) TCC ระหว่างแบบจำลอง WRF-ROMS และค่าตรวจวัด และค่าที่ได้จาก S2S ECMWF ในช่วง Lead-1 (ค่าเริ่มต้น : 13 มิถุนายน 2554)

ก) ฝนสะสมช่วงเกิดเหตุการณ์ (เริ่มต้น 20-06-2554)

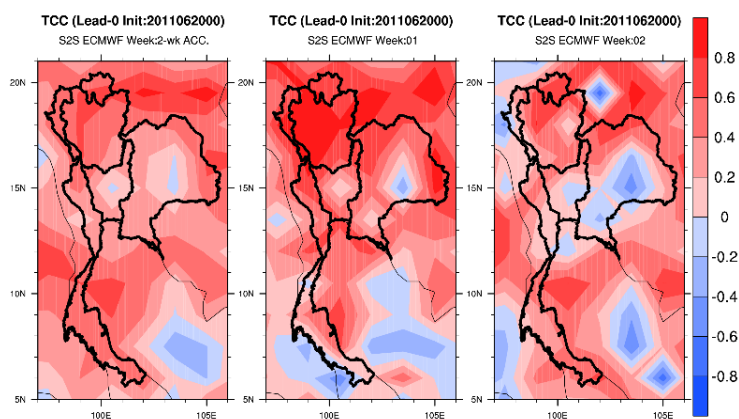


ข) ค่าความสัมพันธ์เชิงเวลา (TCC)

WRF-ROMS

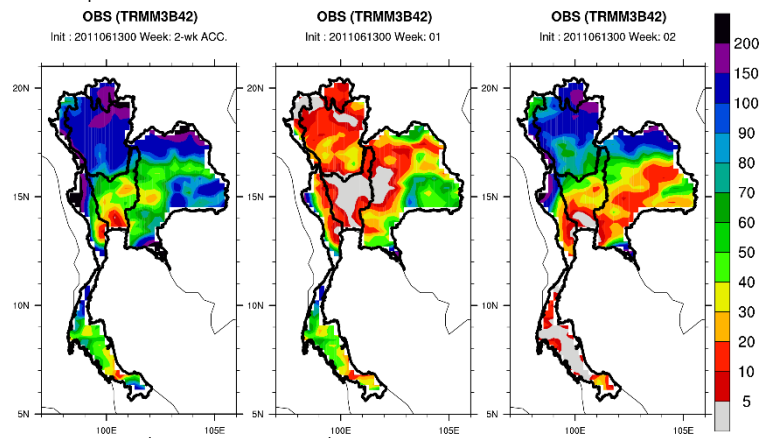


S2S ECMWF




รูปที่ 3.4 (ก) ฝนสะสมช่วงเกิดเหตุการณ์ และ (ข) TCC ระหว่างแบบจำลอง WRF-ROMS และค่าตรวจวัด และค่าที่ได้จาก S2S ECMWF ในช่วง Lead-0 (ค่าเริ่มต้น : 20 มิถุนายน 2554)

ก) ฝนสะสมช่วงเกิดเหตุการณ์ (เริ่มต้น วันที่ 13-06-2554)




ข) รากที่สองของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (RMSE)

WRF-ROMS

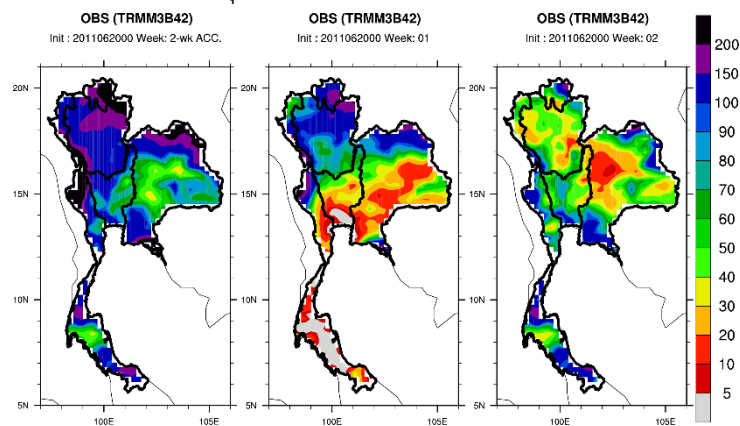


S2S ECMWF



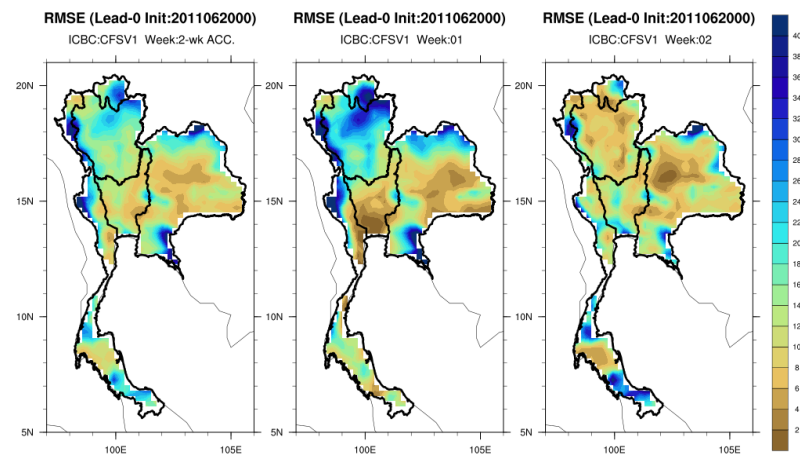
รูปที่ 3.5 ก) ฝนสะสมช่วงเกิดเหตุการณ์ และ ข) RMSE ของแบบจำลอง WRF-ROMS และค่าที่ได้จาก S2S ECMWF ในช่วง Lead-1 (ค่าเริ่มต้น : 13 มิถุนายน 2554)

ก) ฝนสะสมช่วงเกิดเหตุการณ์ (เริ่มต้น 20-06-2554)

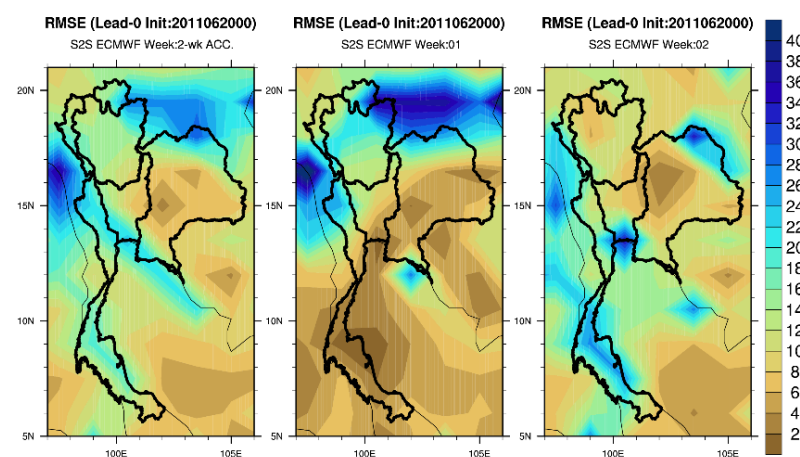


ข) รากที่สองของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (RMSE)

WRF-ROMS




S2S ECMWF

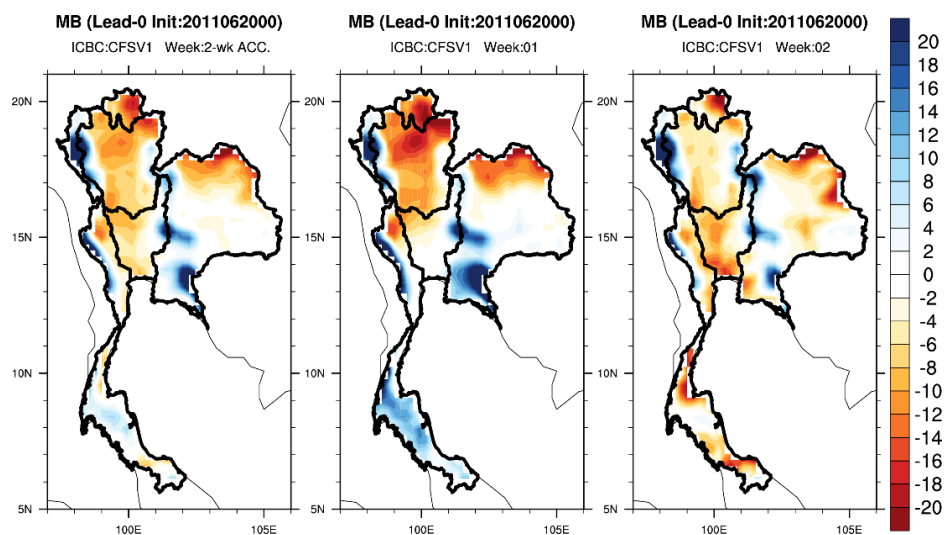


รูปที่ 3.6 ก) ฝนสะสมช่วงเกิดเหตุการณ์ และ ข) RMSE ของแบบจำลอง WRF-ROMS และค่าที่ได้จาก S2S ECMWF ในช่วง Lead-0 (ค่าเริ่มต้น : 20 มิถุนายน 2554)

ก) ค่าเอนเอียงเฉลี่ย (MB) เทียบกับฝนสะสมช่วงเกิดเหตุการณ์ (Lead-1)

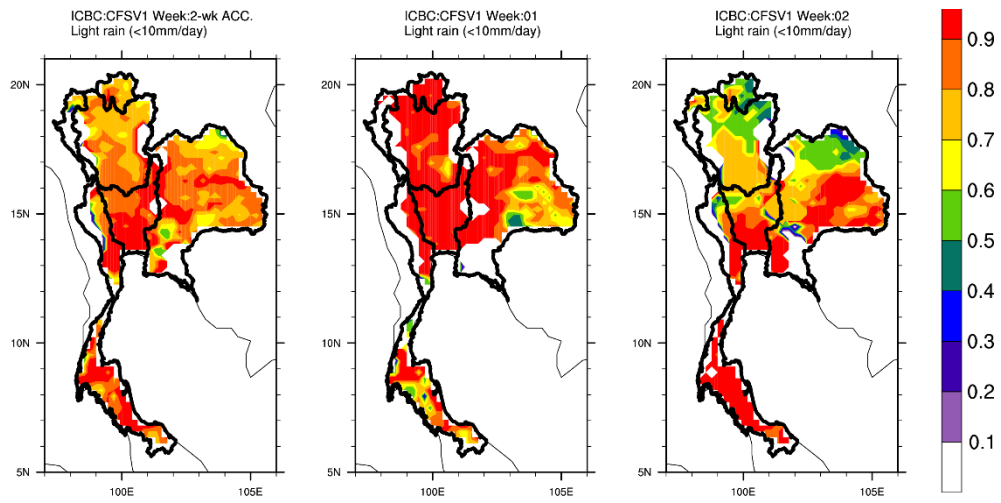


ข) ค่าเอนเอียงเฉลี่ย (MB) เทียบกับฝนสะสมช่วงเกิดเหตุการณ์ (Lead-0)




รูปที่ 3.7 ค่าเอนเอียงเฉลี่ย (MB) ระหว่างค่าจากแบบจำลอง WRF-ROMS เมื่อใช้ G3D และ CFS เทียบกับฝนสะสมช่วงเกิดเหตุการณ์พายุไต้ฝุ่น ก) Lead-1 และ ข) Lead-0

ก) POD ของเหตุการณ์ฝนตกเล็กน้อย (Lead-1: เริ่มต้น วันที่ 13-06-2554)




ข) POD ของเหตุการณ์ฝนตกเล็กน้อย (Lead-0: เริ่มต้น วันที่ 20-06-2554)

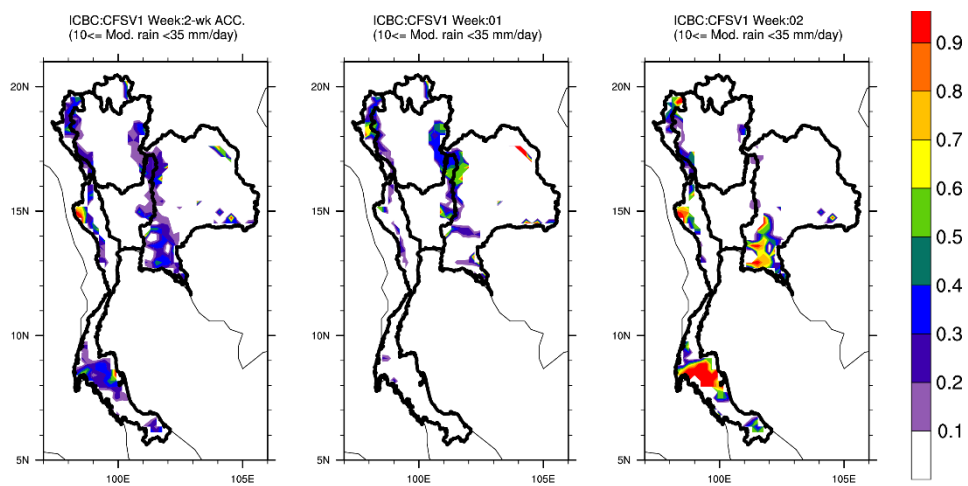


รูปที่ 3.8 ค่าความน่าจะเป็นของการตรวจพบ (POD) เหตุการณ์ฝนตกไม่เกิน 10 มม. (ฝนตกเล็กน้อย) ของแบบจำลอง WRF-ROMS เมื่อใช้ G3D และ CFS ช่วงเกิดเหตุการณ์พายุไต้ฝุ่น
ก) Lead-1 และ ข) Lead-0

ก) POD ของเหตุการณ์ฝนตกปานกลาง (Lead-1: เริ่มต้น วันที่ 13-06-2554)



ข) POD ของเหตุการณ์ฝนตกปานกลาง (Lead-0: เริ่มต้น วันที่ 20-06-2554)



รูปที่ 3.9 ค่าความน่าจะเป็นของการตรวจพบ (POD) เหตุการณ์ฝนตกตั้งแต่ 10-35 มม. (ฝนตกปานกลาง) ของแบบจำลอง WRF-ROMS เมื่อใช้ G3D และ CFS ช่วงเกิดเหตุการณ์พายุไต้ฝุ่น
ก) Lead-1 และ ข) Lead-0

3.5.2 การประเมินความแม่นยำของแบบจำลองช่วงพายุฝน

สำหรับเหตุการณ์ช่วงพายุฝน ถ้าพิจารณา Lead-1 เป็นวันที่ 18-07-2554 จะพบว่าฝนสะสมสองสัปดาห์บริเวณลุ่มน้ำเจ้าพระยามีค่าตั้งแต่ 60-200 มม. โดยปริมาณฝนสะสมสูงสุดจะพบในตอนบนของกลุ่มน้ำ ซึ่งเป็นผลมาจากฝนตกสะสมในสัปดาห์ที่ 2 นับจากวันเริ่ม ในทำนองเดียวกัน หากพิจารณา Lead-0 (25-07-2554) จะพบว่าฝนสะสมสองสัปดาห์มีค่ามากทั้งตอนบนและตอนล่างของกลุ่มน้ำเจ้าพระยา (> 90 มม.) โดยเป็นผลมาจากฝนสะสมที่มีปริมาณมากในสัปดาห์แรกนับจากวันเริ่ม


TCC: ความสัมพันธ์ระหว่างผลจากแบบจำลองกับข้อมูลตรวจวัดในช่วง Lead-1 แสดงในรูปที่ 3.10 หากพิจารณาภาพรวมทั้งสองสัปดาห์ แบบจำลองมีความสามารถในการคาดการณ์ค่อนข้างต่ำมาก แต่ถ้าพิจารณาเป็นรายสัปดาห์ โดยเฉพาะ Week 2 ที่เป็นช่วงเวลาที่พื้นที่ลุ่มน้ำเจ้าพระยาได้รับอิทธิพลจากพายุฝน โดยรวมแบบจำลอง WRF-ROMS สามารถคาดการณ์ได้ในระดับหนึ่งและมีบางพื้นที่ที่ค่าสหสัมพันธ์สูงกว่า 0.60 ส่วนแบบจำลอง ECMWF คาดการณ์ได้ดีพอสมควร ทั้งนี้ส่วนใหญ่แบบจำลอง ECMWF ให้ผลที่ดีกว่าแบบจำลอง WRF-ROMS ซึ่งเมื่อสังเกตในช่วง Lead-0 (รูปที่ 3.11) จะยิ่งเห็นได้ชัดเจน

RMSE: จากรูปที่ 3.12 และ 3.13 โดยทั่วไป แบบจำลอง WRF-ROMS ประมาณค่าฝนสะสมรายสัปดาห์บริเวณพื้นที่ลุ่มน้ำเจ้าพระยาได้ค่อนข้างใกล้เคียงกับแบบตรวจวัด โดยมีค่า RMSE ไม่เกิน 20 มม. ทั้ง Lead-1 และ Lead-0 โดยพื้นที่ลุ่มน้ำเจ้าพระยาตอนล่างจะให้ค่า RMSE ต่ำสุด เมื่อพิจารณารายสัปดาห์ Lead-1 Week 2 ช่วงที่พายุมีอิทธิพลกับประเทศไทย พบว่า ค่า RMSE บริเวณที่มีฝนตกหนัก (ตอนบนของกลุ่มน้ำ) มีค่า RMSE สูงประมาณ 40 มม. ซึ่งรูปแบบลักษณะดังกล่าวก็พบได้ใน Lead-0 Week 1 ในส่วนแบบจำลอง ECMWF การกระจายตัวเชิงพื้นที่ของ RMSE มีลักษณะใกล้เคียงกันกับของ WRF-ROMS

MB: รูปที่ 3.14 ชี้ว่า ในช่วงสัปดาห์ที่เกิดเหตุการณ์ แบบจำลอง WRF-ROMS ให้ค่าคาดการณ์ต่ำกว่าค่าตรวจวัดโดยเฉลี่ยประมาณ 6-10 มม. ทั้ง Lead-1 และ Lead-0

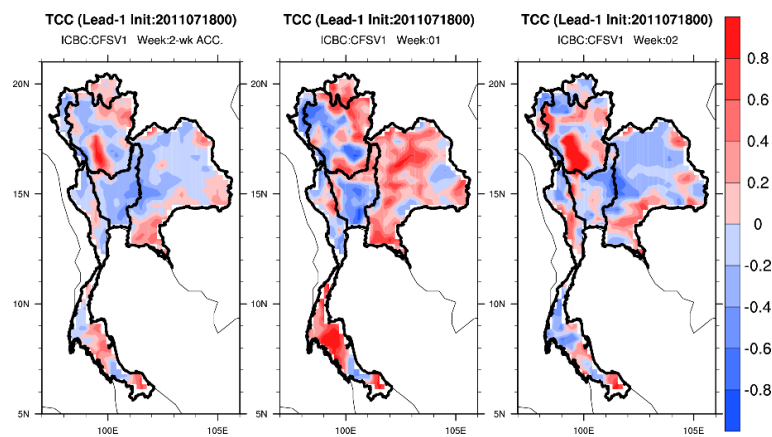
POD: หากพิจารณาการเกิดขึ้นของเหตุการณ์ฝน แบบจำลองสามารถคาดการณ์การเกิดฝนเล็กน้อยได้ค่อนข้างดี ประมาณ 70-80% แต่ยังไม่สามารถคาดการณ์การเกิดขึ้นของเหตุการณ์ที่มีปริมาณฝนมากกว่านั้นได้ ทั้ง Lead-1 และ Lead-0 (รูปที่ 3.15 และ 3.16)

ก) ฝนสะสมช่วงเกิดเหตุการณ์ (เริ่มต้น วันที่ 18-07-2554)

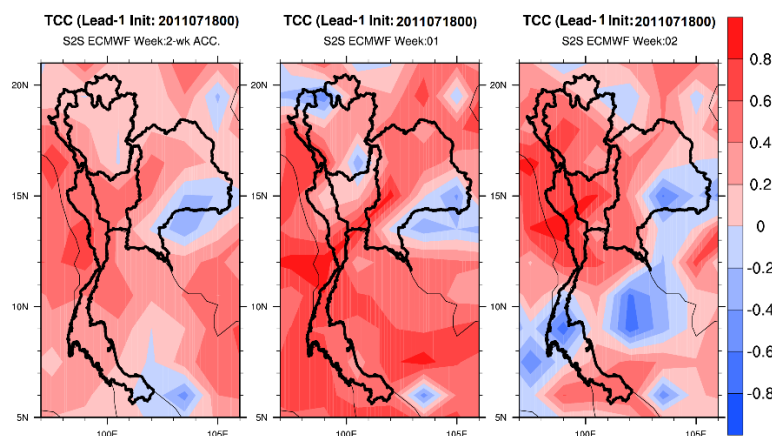


ข) ค่าความสัมพันธ์เชิงเวลา (TCC)

WRF-ROMS

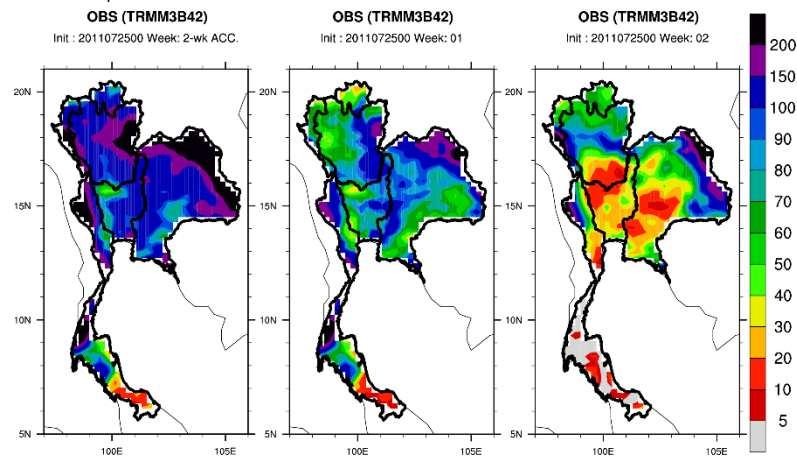


S2S ECMWF




รูปที่ 3.10 ก) ฝนสะสมช่วงเกิดเหตุการณ์ และ ข) TCC ระหว่างแบบจำลอง WRF-ROMS และค่าตรวจวัด และค่าที่ได้จาก S2S ECMWF ในช่วง Lead-1 (ค่าเริ่มต้น : 18 กรกฎาคม 2554)

ก) ฝนสะสมช่วงเกิดเหตุการณ์ (เริ่มต้น 25-07-2554)




ข) ค่าความสัมพันธ์เชิงเวลา (TCC)

WRF-ROMS

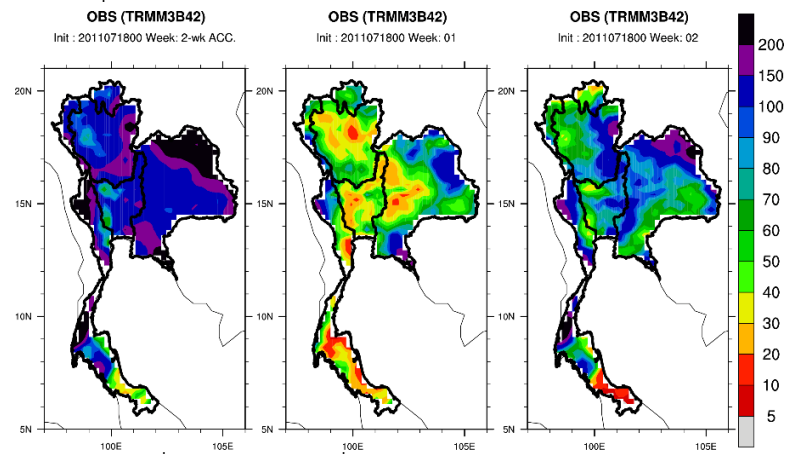


S2S ECMWF




รูปที่ 3.11 ก) ฝนสะสมช่วงเกิดเหตุการณ์ และ ข) TCC ระหว่างแบบจำลอง WRF-ROMS และค่าตรวจวัด และค่าที่ได้จาก S2S ECMWF ในช่วง Lead-0 (ค่าเริ่มต้น : 25 กรกฎาคม 2554)

ก) ฝนสะสมช่วงเกิดเหตุการณ์ (เริ่มต้น วันที่ 18-07-2554)




ข) รากที่สองของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (RMSE)

WRF-ROMS

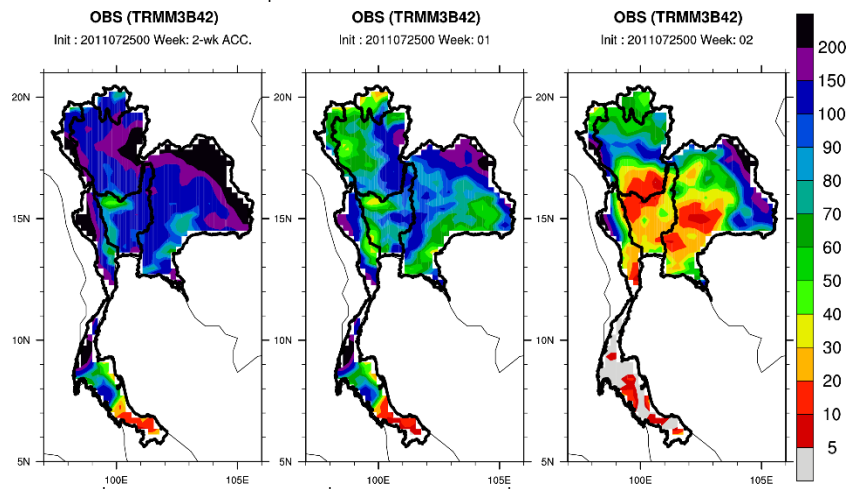


S2S ECMWF



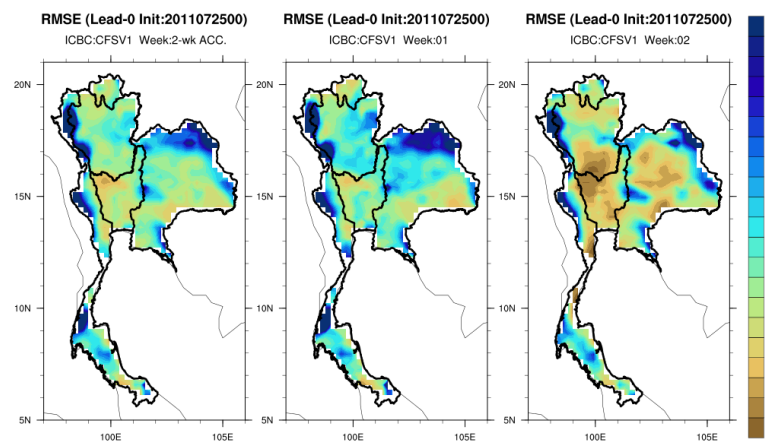
รูปที่ 3.12 (ก) ฝนสะสมช่วงเกิดเหตุการณ์ และ (ข) RMSE ระหว่างแบบจำลอง WRF-ROMS และค่าตรวจวัด และค่าที่ได้จาก S2S ECMWF ในช่วง Lead-1 (ค่าเริ่มต้น : 18 กรกฎาคม 2554)

ก) ฝนสะสมช่วงเกิดเหตุการณ์ (เริ่มต้น 25-07-2554)

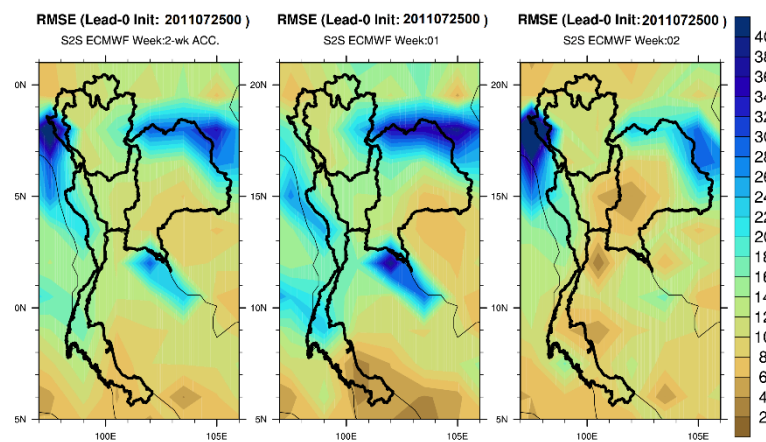


ข) รากที่สองของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (RMSE)

WRF-ROMS




S2S ECMWF




รูปที่ 3.13 ก) ฝนสะสมช่วงเกิดเหตุการณ์ และ ข) RMSE ระหว่างแบบจำลอง WRF-ROMS และค่าตรวจวัด และค่าที่ได้จาก S2S ECMWF ในช่วง Lead-0 (ค่าเริ่มต้น : 25 กรกฎาคม 2554)

ก) ค่าเอนเอียงเฉลี่ย (MB) เทียบกับฝนสะสมช่วงเกิดเหตุการณ์ (Lead-1)

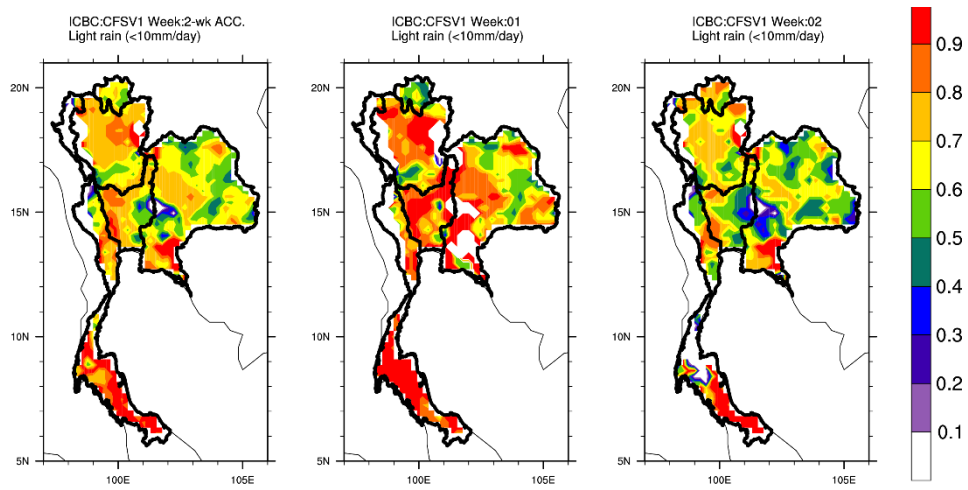


ข) ค่าเอนเอียงเฉลี่ย (MB) เทียบกับฝนสะสมช่วงเกิดเหตุการณ์ (Lead-0)

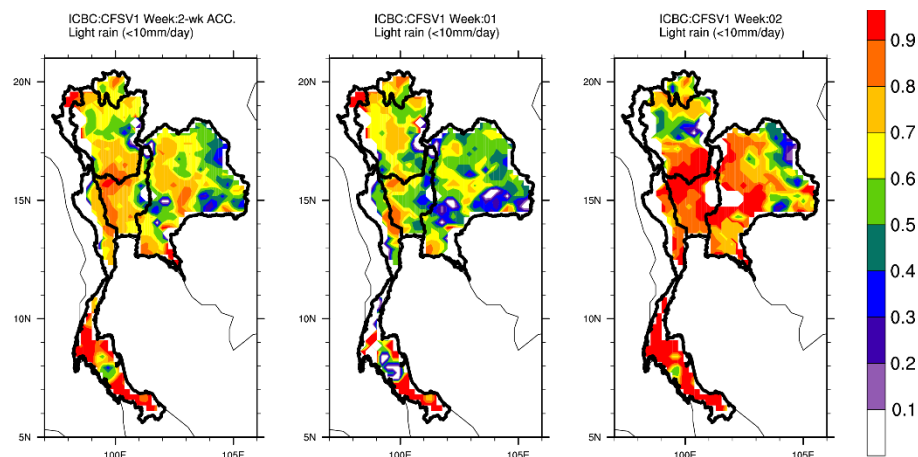


รูปที่ 3.14 ค่าเอนเอียงเฉลี่ย (MB) ระหว่างค่าจากแบบจำลอง WRF-ROMS เมื่อใช้ G3D และ CFS เทียบกับฝนสะสมช่วงเกิดเหตุการณ์พายุฝนกตอน ก) Lead-1 และ ข) Lead-0

ก) POD ของเหตุการณ์ฝนตกเล็กน้อย (Lead-1)



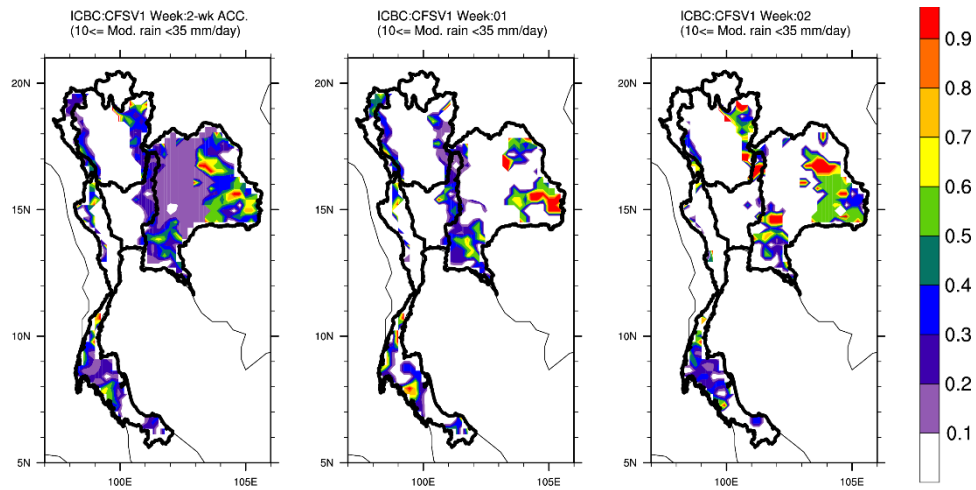
ข) POD ของเหตุการณ์ฝนตกเล็กน้อย (Lead-0)



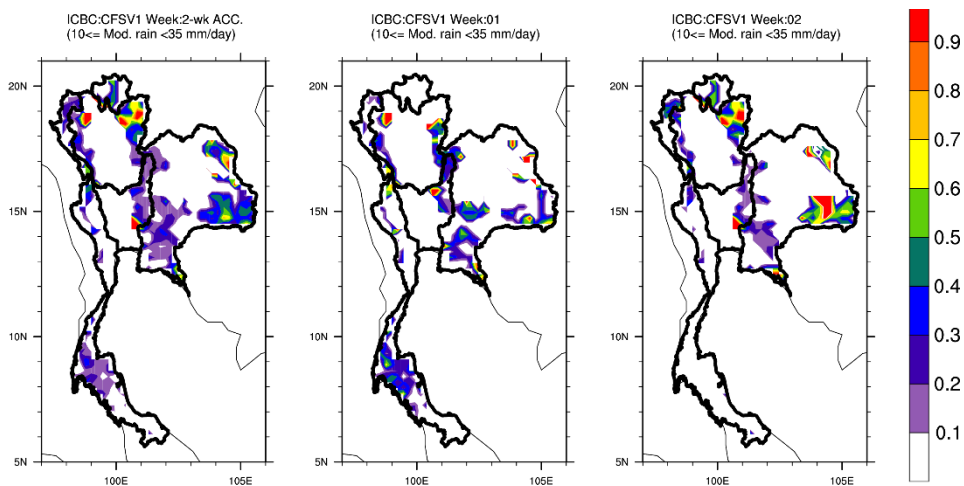
รูปที่ 3.15 ค่าความน่าจะเป็นของการตรวจพบ (POD) เหตุการณ์ฝนตกไม่เกิน 10 มม. (ฝนตกเล็กน้อย) ของแบบจำลอง WRF-ROMS เมื่อใช้ G3D และ CFS ช่วงเกิดเหตุการณ์พายุฝน

ก) Lead-1 และ ข) Lead-0

ก) POD ของเหตุการณ์ฝนตกปานกลาง (Lead-1)



ข) POD ของเหตุการณ์ฝนตกปานกลาง (Lead-0)



รูปที่ 3.16 ค่าความน่าจะเป็นของการตรวจพบ (POD) เหตุการณ์ฝนตกตั้งแต่ 10-35 มม.

(ฝนตกปานกลาง) ของแบบจำลอง WRF-ROMS เมื่อใช้ G3D และ CFS ช่วงเกิดเหตุการณ์พายุฝน

ก) Lead-1 และ ข) Lead-0

3.6 ผลการประเมินความแม่นยำของแบบจำลองด้วยวิธีการ Nesting ที่ความละเอียด 5 กม.

ผลที่ได้จาก Non-nesting ของ WRF ระบุว่าค่าความแม่นยำของแบบจำลองขึ้นอยู่กับเหตุการณ์ที่นำมาพิจารณา โดยพบว่าแบบจำลองที่ความละเอียด 25 กม. นั้น ให้ค่าความแม่นยำในการทำนายปริมาณฝนและค่า TCC บริเวณลุ่มเจ้าพระยาค่อนข้างสูงเฉพาะเหตุการณ์พายุใหญ่ แต่ไม่สามารถประมาณค่าการเกิดเหตุการณ์ฝนตกหนักในช่วงพายุฝนได้ ผลที่แสดงในหัวข้อที่ผ่านมาเป็นผลจากการใช้แบบจำลองที่ความละเอียด 25 กม. แบบคู่ควบระหว่าง WRF:ROMS แบบ 1:1 โดเมน เพื่อขยายผลศึกษาให้กว้างขึ้น จึงได้ทำการทดสอบเพิ่มเพื่อศึกษาความไวของแบบจำลองต่อการคำนวณ

เมฆฝนในระดับไมโคร (microphysics option) และเพิ่มความละเอียดของพื้นที่ศึกษา (ลุ่มน้ำเจ้าพระยา) เป็น 5 กม. โดยการทำให้ Nesting WRF domain อีก 1 โดเมน (WRF:ROMS = 2:1 โดเมน) ทั้งนี้จะพิจารณาเฉพาะกรณีพายุฝน ในช่วง Lead-1 (ค่าเริ่มต้น 18 กรกฎาคม 2554 หรือ 2011-07-18-00) เท่านั้น

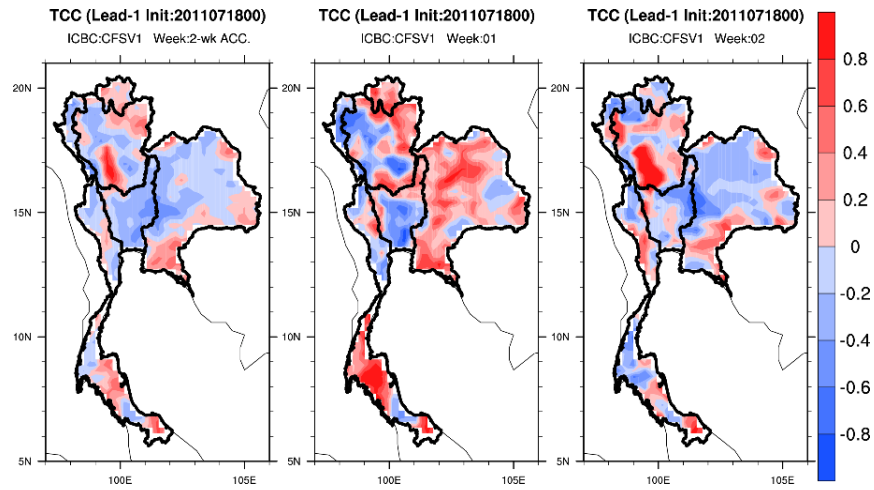
TCC: จากรูปที่ 3.17 หากพิจารณาภาพรวมสองสัปดาห์ของการคาดการณ์ในช่วงพายุฝน Lead-1 สำหรับพื้นที่ลุ่มน้ำเจ้าพระยา จะพบว่า ค่าคาดการณ์ที่ได้จาก WRF nesting มีความแม่นยำเพิ่มขึ้นอย่างเห็นได้ชัดเมื่อคำนึงถึง Microphysics ของการเกิดเมฆด้วย โดยมีค่า TCC สูงถึง 0.80 ทั้งสองรูปแบบ (KS และ GD) และหากพิจารณาตามช่วง Lead time จะพบว่า ในช่วงสัปดาห์ที่เกิดพายุ (Lead-1 Week 2) นั้น แบบจำลองมีความแม่นยำอย่างเห็นได้ชัด ($TCC > 0.80$) โดยค่าที่ได้จาก Microphysics GD มีความแม่นยำที่สูงกว่า KS ในบางพื้นที่ของลุ่มน้ำเจ้าพระยา

MB: จากรูปที่ 3.18 จะเห็นอย่างชัดเจนว่า ค่าความเอนเอียงของแบบจำลองที่ได้จากการ Nesting ดีขึ้น ก่อนการ Nesting แบบจำลองให้ค่าคาดการณ์บริเวณลุ่มน้ำเจ้าพระยาต่ำกว่าค่าตรวจวัด โดยมีค่าความเอนเอียงเฉลี่ยอยู่ระหว่าง -16 มม. ถึง -6 มม. หลังจากใช้เทคนิคแบบ Nesting ที่ความละเอียดสูง แบบจำลองให้ค่าความเอนเอียงเฉลี่ยอยู่ระหว่าง ± 2 มม. เท่านั้น โดยทั้งสองรูปแบบ, KS และ GD, ให้ค่า MB ที่ใกล้เคียงกัน


RMSE: จากรูปที่ 3.19 บริเวณพื้นที่ลุ่มน้ำเจ้าพระยาทั้งตอนบนและตอนล่าง มีค่า RMSE ลดลงอย่างชัดเจนหลังจากใช้วิธีการ Nesting กล่าวคือ ลดจาก 14-30 มม. กรณี Non-nesting เหลือเพียง 4-10 มม.

จากค่าต่าง ๆ ดังที่กล่าวมา พอสรุปได้ว่า การใช้เทคนิค Nesting ที่ความละเอียด 5 กม. และด้วยการคำนวณการเกิดเมฆฝนในระดับ Microphysics scale ทำให้การคาดการณ์แม่นยำขึ้นจากเดิม โดยเฉพาะอย่างยิ่งการใช้ Goddard Microphysics จะให้ผลค่อนข้างดีกว่า Kessler Microphysics

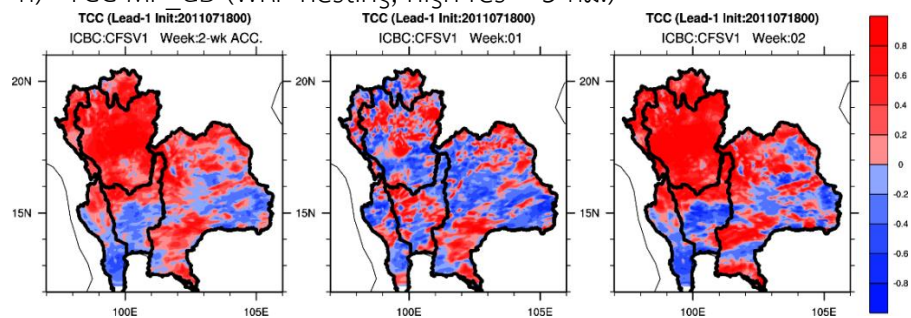
ก) TCC Non-WRF nesting (res = 25 กม.)



ข) TCC MP_KS (WRF-nesting, high res = 5 กม.)

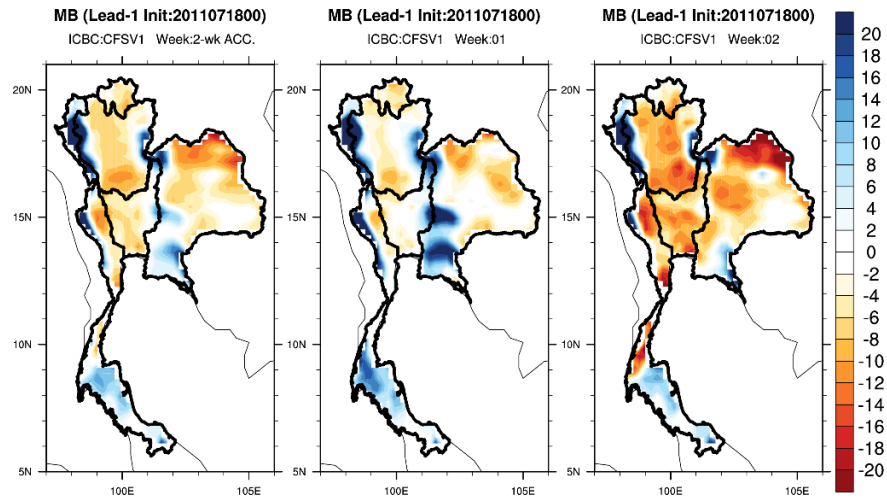


ค) TCC MP_GD (WRF-nesting, high res = 5 กม.)

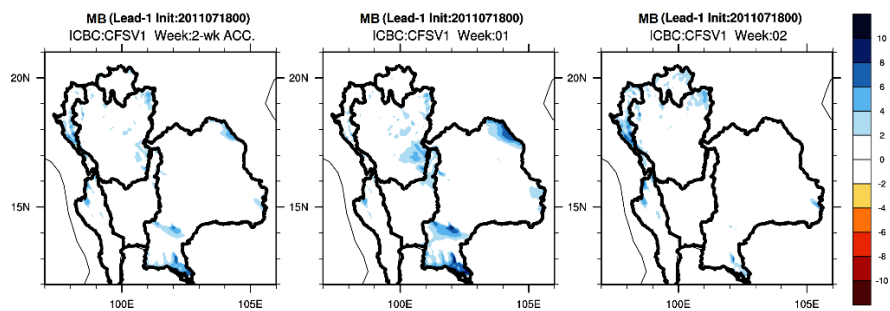


รูปที่ 3.17 ค่า TCC ของค่าคาดการณ์ด้วย WRF-ROMS แบบ (ก) Non-nesting และ (ข)-(ค) Nesting WRF ที่ความละเอียด 5 กม. กับค่าตรวจวัด

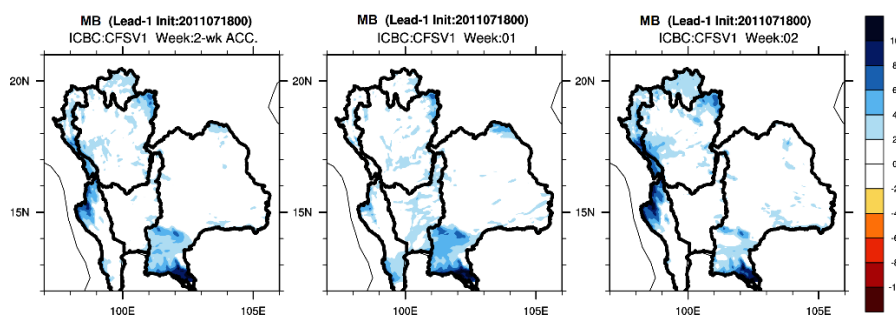
ก) MB Non-WRF nesting (res = 25 กม.)



ข) MB MP_KS (WRF-nesting, high res = 5 กม.)




ค) MB MP_GD (WRF-nesting, high res = 5 กม.)

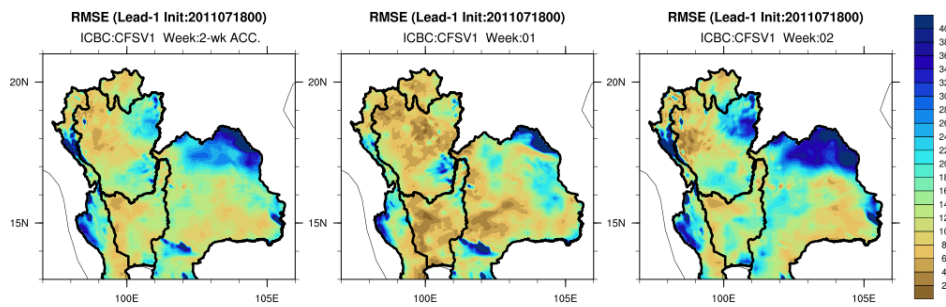


รูปที่ 3.18 ค่า MB ของการคาดการณ์ด้วย WRF-ROMS แบบ (ก) Non-nesting และ (ข)-(ค) Nesting WRF ที่ความละเอียด 5 กม. เมื่อเทียบกับค่าตรวจวัด


ก) RMSE Non-WRF nesting (res = 25 กม.)



ข) RMSE MP_KS (WRF-nesting, high res = 5 กม.)



ค) RMSE MP_GD (WRF-nesting, high res = 5 กม.)



รูปที่ 3.19 ค่า RMSE ของการคาดการณ์ด้วย WRF-ROMS แบบ (ก) Non-nesting และ (ข)-(ค) Nesting WRF ที่ความละเอียด 5 กม.

บทที่ 4

การเพิ่มประสิทธิภาพการคาดการณ์ฝน โดยใช้วิธีปรับความคลาดเคลื่อนด้วยวิธีทางสถิติ

4.1 วิธีปรับความคลาดเคลื่อนด้วยวิธีทางสถิติ

การปรับความคลาดเคลื่อนของค่าฝนคาดการณ์จาก CFSv2 ใช้วิธี Linear scaling ตามสมการต่อไปนี

$$rain_bc_{i,j} = rain_cfs_{i,j} \times \frac{\mu_{obs_{m,i}}}{\mu_{cfs_{m,i}}}$$

เมื่อ

j คือ วัน,

i คือ สถานี, $i = 1,2,3,\dots,n$

m คือ เดือน, $m = 1,2,3,\dots,12$

$rain_bc$ คือ ฝนรายวันที่ปรับความคลาดเคลื่อนแล้ว


$rain_cfs$ คือ ฝนคาดการณ์รายวันจาก CFSv2

$\mu_{cfs_{m,i}}$ คือ ปริมาณฝนเฉลี่ยรายเดือนของเดือนที่ m ที่สถานี i จาก CFSv2 (คำนวณโดยใช้ข้อมูลจากช่วง Training)


$\mu_{obs_{m,i}}$ คือ ปริมาณฝนที่ตรวจวัดได้เฉลี่ยรายเดือนของเดือนที่ m ที่สถานี i (คำนวณโดยใช้ข้อมูลจากช่วง Training)

การหาค่าพารามิเตอร์ที่เหมาะสมสำหรับการปรับแก้จะใช้ข้อมูลสถานีฝนของกรมอุตุนิยมวิทยา ทั้งสถานีตรวจวัดสภาพอากาศหลักและสถานีรายอำเภอตั้งแต่ปี พ.ศ. 2555-2560 ในช่วง Training และใช้ข้อมูลฝน พ.ศ. 2561-2562 เป็นชุดตรวจสอบผลการคาดการณ์ โดยจำนวนสถานีทั้งหมดทั่วประเทศมี 674 สถานี เป็นสถานีในกลุ่มน้ำเจ้าพระยาทั้งหมด 262 สถานี รูปที่ 4.1 แสดงแผนที่ตำแหน่งของสถานี

ก) ตำแหน่งสถานีครอบคลุมพื้นที่ประเทศไทย




ข) ตำแหน่งสถานีครอบคลุมพื้นที่
ลุ่มน้ำเจ้าพระยา



รูปที่ 4.1 แผนที่แสดงตำแหน่งสถานีที่นำข้อมูลมาใช้ในการปรับแก้ความคลาดเคลื่อนของการคาดการณ์ ก) ประเทศไทย และ ข) ลุ่มน้ำเจ้าพระยา

4.2 ผลการปรับค่าความคลาดเคลื่อนในช่วง Training

การทำค่าพารามิเตอร์ที่เหมาะสมสำหรับการปรับแก้จะใช้ข้อมูลสถานีฝนของกรมอุตุนิยมวิทยา ทั้งสถานีตรวจวัดสภาพอากาศหลักและสถานีรายอำเภอตั้งแต่ปี พ.ศ. 2555-2560 ผลการปรับแก้ ในช่วง Training แสดงดังรูปที่ 4.2 และ ตารางที่ 4.1 จะเห็นได้ว่า ฝนเชิงพื้นที่จากการทำ Bias Correction (BC) มีค่าใกล้เคียงกับข้อมูลตรวจวัดมากขึ้น โดยสามารถลดค่า RMSE ลงได้ 25 มิลลิเมตร/สองสัปดาห์ ซึ่งค่า Correlation coefficient (R) ก็ลดลงด้วย



(ก) RAW CFSV2

(ข) BC CFSV2

(ค) ค่าตรวจวัด

รูปที่ 4.2 แผนที่แสดงปริมาณฝนคาดการณ์และฝนตรวจวัดจริงปี 2555-2560


ตารางที่ 4.1 ค่าต่ำสุด ค่าสูงสุด และค่าเฉลี่ยของปริมาณฝนคาดการณ์และฝนตรวจวัด และผลการวิเคราะห์ประสิทธิภาพของการคาดการณ์เมื่อเทียบกับค่าตรวจวัด ปี 2555-2560

คาดการณ์	ค่าปริมาณฝน			ค่าสถิติ	
	ค่าสูงสุด	ค่าต่ำสุด	ค่าเฉลี่ย	R	RMSE
Observation	2506	393	1,196	-	-
Raw CFSV2	3,512	1268	2,149	0.85	57
BC CFSV2	2,929	333	1,265	0.77	32


เมื่อเปรียบเทียบปริมาณฝนแบบรายสถานีของกรมอุตุนิยมวิทยากับฝนคาดการณ์รายสองสัปดาห์ บริเวณเหนือเขื่อนภูมิพล ณ สถานีดิน จังหวัดลำปาง รหัสสถานี 328202 ตั้งแต่ปี 2555-2560 ในรูปที่ 4.3 พบว่า ในปี 2555-2556 และปี 2558 ฝนคาดการณ์รายสองสัปดาห์ Raw CFSV2 ต่างจากปริมาณฝนตรวจวัดค่อนข้างมาก แม้ว่าการปรับค่าความคลาดเคลื่อนจะทำให้ฝนคาดการณ์

BC CFSV2 และปริมาณฝนตรวจวัดมีความใกล้เคียงกันขึ้น แต่ก็ยังมีความแตกต่างอยู่พอสมควรในหลายช่วงเวลา ส่วนในปี 2557 และ 2559-2560 จะเห็นได้ว่าปริมาณฝนคาดการณ์รายสองสัปดาห์แบบ Raw CFSV2 มีค่าสูงกว่าปริมาณฝนตรวจวัด (overestimate) อย่างเห็นได้ชัดในช่วงกลางปี และเมื่อเปรียบเทียบกับปริมาณฝนตรวจวัดจริงของกรมอุตุนิยมวิทยา มีค่า R อยู่ที่ 0.82 และค่า RMSE 49.8 มิลลิเมตร/สองสัปดาห์ ดังแสดงในตารางที่ 4.2 หลังการปรับค่าความคลาดเคลื่อน ปริมาณฝนคาดการณ์ BC CFSV2 กับปริมาณฝนตรวจวัดจริงมีค่าค่อนข้างใกล้เคียงกันอยู่ในระดับน่าพอใจ ค่า R อยู่ที่ 0.73 และค่า RMSE 26.3 มิลลิเมตร/สองสัปดาห์

ในส่วนปริมาณฝนที่บริเวณท้ายเขื่อนภูมิพล ณ สถานีเขื่อนภูมิพล จังหวัดตาก รหัสสถานี 376203 ตั้งแต่ปี 2555-2560 ในรูปที่ 4.4 พบว่า ในปี 2555 และปี 2558 ปริมาณฝนตรวจวัดจริงของกรมอุตุนิยมวิทยากับฝนคาดการณ์รายสองสัปดาห์ทั้งแบบ Raw CFSV2 และ BC CFSV2 มีค่าค่อนข้างใกล้เคียงกันเกือบตลอดทั้งปี ยกเว้นช่วงปลายปี 2555 ส่วนในปี 2556-2557 และปี 2559-2560 ปริมาณฝนคาดการณ์แบบ Raw CFSV2 มักมีค่าสูงกว่าปริมาณฝนตรวจวัดจริง หลังการปรับค่าความคลาดเคลื่อน ปริมาณฝนคาดการณ์แบบ BC CFSV2 มีค่าใกล้เคียงปริมาณฝนตรวจวัดจริงมากขึ้น แต่ในบางครั้งก็อาจมีค่าค่อนข้างต่ำเกินไป (underestimate) เมื่อเปรียบเทียบปริมาณฝนคาดการณ์ Raw CFSV2 กับปริมาณฝนตรวจวัด มีค่า R อยู่ที่ 0.78 และค่า RMSE 30.4 มิลลิเมตร/สองสัปดาห์ ดังในตารางที่ 4.3 ในขณะที่เมื่อพิจารณาปริมาณฝนคาดการณ์ BC CFSV2 กับปริมาณฝนตรวจวัดจริง R มีค่า 0.71 และค่า RMSE ลดลงเหลือ 21.1 มิลลิเมตร/สองสัปดาห์



รูปที่ 4.3 กราฟแสดงปริมาณฝนรายสองสัปดาห์ สถานีฝน จังหวัดลำปาง ปีพ.ศ. 2555-2560 (หรือ ค.ศ. 2012-2017)



รูปที่ 4.4 กราฟแสดงปริมาณฝนรายสองสัปดาห์ สถานีเขื่อนภูมิพล จังหวัดตาก ปีพ.ศ. 2555-2560 (หรือ ค.ศ. 2012-2017)

ตารางที่ 4.2 ผลการวิเคราะห์ Bias Correction CFSV2 ณ สถานีเขื่อน จังหวัดลำปาง ปี 2555-2560

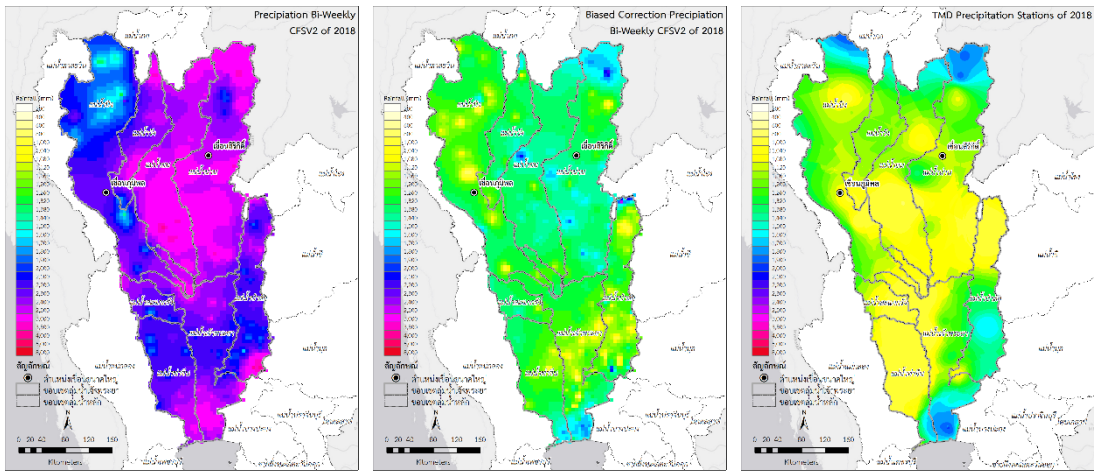
ค่าการวัด	R	RMSE
Raw CFSV2	0.82	49.8
BC CFSV2	0.73	26.3

ตารางที่ 4.3 ผลการวิเคราะห์ Bias Correction CFSV2 ณ สถานีเขื่อนภูมิพล จังหวัดตาก ปี 2555-2560

ค่าการวัด	R	RMSE
Raw CFSV2	0.78	30.4
BC CFSV2	0.71	21.1

4.3 การตรวจสอบผลการปรับค่าความคลาดเคลื่อน

การตรวจสอบผลการปรับค่าความคลาดเคลื่อนของการคาดการณ์ด้วยวิธีทางสถิติ จะใช้ข้อมูล ปี 2561 และ 2562 ดังแสดงในรูปที่ 4.5 (ก) และ 4.6 (ก) ในปี 2561 ปริมาณฝนคาดการณ์ Raw CFSV2 มีค่าสูงสุด 3,647 มิลลิเมตร ค่าต่ำสุด 1,296 มิลลิเมตร และปริมาณฝนเฉลี่ยอยู่ที่ 2,308 มิลลิเมตร ส่วนในปี 2562 ปริมาณฝนคาดการณ์ Raw CFSV2 มีค่าสูงสุด 2,986 มิลลิเมตร ค่าต่ำสุด 831 มิลลิเมตร และปริมาณฝนเฉลี่ยอยู่ที่ 1,710 มิลลิเมตร ดังแสดงในตารางที่ 4.4 เมื่อเปรียบเทียบกับปริมาณฝนตรวจวัดจริงของกรมอุตุนิยมวิทยา พบว่า ปี 2561 มีค่า R 0.84 และค่า RMSE 60 มิลลิเมตร/สองสัปดาห์ ส่วนปี 2562 มีค่า R 0.87 และค่า RMSE 51 มิลลิเมตร/สองสัปดาห์ ดังแสดงในตารางที่ 4.5

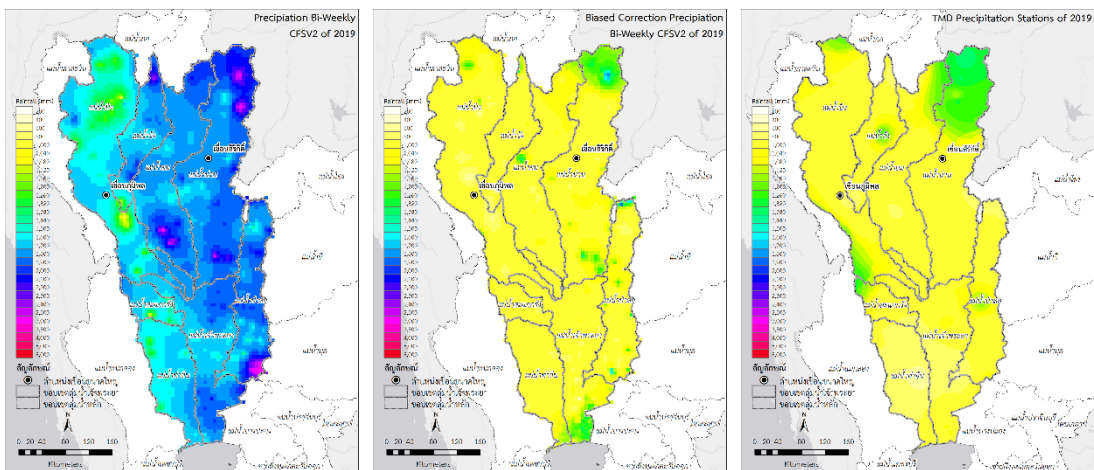


(ก) RAW CFSV2

(ข) BC CFSV2

(ค) ค่าตรวจวัด

รูปที่ 4.5 แผนที่แสดงปริมาณฝนคาดการณ์และฝนตรวจวัดจริงปี 2561



(ก) RAW CFSV2

(ข) BC CFSV2

(ค) ค่าตรวจวัด

รูปที่ 4.6 แผนที่แสดงปริมาณฝนคาดการณ์และฝนตรวจวัดจริงปี 2562

ตารางที่ 4.4 ค่าต่ำสุด ค่าสูงสุด และค่าเฉลี่ยของปริมาณฝนคาดการณ์และฝนตรวจวัด ปี 2561-2562

คาดการณ์	ปี 2561			ปี 2562		
	ค่าสูงสุด	ค่าต่ำสุด	ค่าเฉลี่ย	ค่าสูงสุด	ค่าต่ำสุด	ค่าเฉลี่ย
Observation	1,970	784	1,161	1,360	513	929
Raw CFSV2	3,647	1296	2,308	2,986	831	1,710
BC CFSV2	2,449	451	1,308	1,823	359	953


ตารางที่ 4.5 ผลการวิเคราะห์ Bias Correction CFSV2 ปี 2561-2562 (ค่าต่ำสุดและค่าสูงสุดแสดงในวงเล็บ)

คาดการณ์	ปี 2561		ปี 2562	
	R	RMSE	R	RMSE
Raw CFSV2	0.84 (0.20 -0.95)	60 (19 - 253)	0.87 (0.53 -0.93)	51 (16 - 123)
BC CFSV2	0.83 (0.10-0.93)	24 (15 - 280)	0.88 (0.59-0.96)	19 (12 - 60)


เมื่อวิเคราะห์ปริมาณฝนคาดการณ์ BC CFSV2 ที่เป็นผลจากการปรับค่าความคลาดเคลื่อนของ Raw CFSV2 ในรูปที่ 4.5 (ข) และ (ค) จะเห็นว่า ปริมาณฝนคาดการณ์มีค่าลดลงอย่างมากและค่อนข้างใกล้เคียงกับปริมาณฝนตรวจวัดจริง โดยในปี 2561 บริเวณตอนบนของเขื่อนสิริกิติ์ บริเวณตอนล่างของกลุ่มน้ำท่าจีน และตอนล่างของกลุ่มน้ำเจ้าพระยามีปริมาณฝนประมาณ 1,600-1,800 มิลลิเมตร สอดคล้องกับปริมาณฝนตรวจวัดจริง ทั้งนี้ปริมาณฝนเฉลี่ยอยู่ที่ 1,308 มิลลิเมตร สูงกว่าปริมาณฝนตรวจวัดจริง 147 มิลลิเมตร หรือประมาณ 13% มีค่า R อยู่ที่ 0.83 และค่า RMSE 24 มิลลิเมตร/สองสัปดาห์ ส่วนในปี 2562 บริเวณตอนบนของเขื่อนสิริกิติ์มีปริมาณฝนประมาณ 1,200-1,400 มิลลิเมตร ซึ่งสูงกว่าบริเวณอื่นๆ ของพื้นที่ศึกษา เช่นเดียวกับปริมาณฝนตรวจวัดจริง ดังแสดงในรูปที่ 4.6 (ข) และ (ค) ปริมาณฝนเฉลี่ยอยู่ที่ 953 มิลลิเมตร มากกว่าปริมาณฝนตรวจวัดจริงเพียง 24 มิลลิเมตร หรือประมาณ 4.5% โดยมีค่า R 0.88 และค่า RMSE 19 มิลลิเมตร/สองสัปดาห์ รายละเอียดแสดงในตารางที่ 4.4 และ 4.5

เมื่อพิจารณาปริมาณฝนแบบรายสถานีของกรมอุตุนิยมวิทยากับฝนคาดการณ์รายสองสัปดาห์ บริเวณเหนือเขื่อนภูมิพล ณ สถานีเถิน จังหวัดลำปาง รหัสสถานี 328202 ของปี 2561 พบว่า ในช่วงต้นปี (มกราคม-เมษายน) ปริมาณฝนตรวจวัดกับฝนคาดการณ์รายสองสัปดาห์ทั้งแบบ Raw CFSV2 และ BC CFSV2 ล้วนมีค่าน้อยและส่วนใหญ่อ่าใกล้เคียงกัน ปริมาณฝนค่อย ๆ เพิ่มขึ้นในช่วงเดือน พฤษภาคม-ตุลาคม ซึ่งเป็นช่วงฤดูฝนของประเทศไทย จากรูปที่ 4.7 เห็นได้ว่าปริมาณฝนคาดการณ์แบบ Raw CFSV2 มีค่าสูงกว่า (overestimate) ปริมาณฝนตรวจวัดจริงของกรมอุตุนิยมวิทยา มีค่า R อยู่ที่ 0.76 และค่า RMSE 61.2 มิลลิเมตร/สองสัปดาห์ ดังแสดงในตารางที่ 4.6 หลังการปรับความคลาดเคลื่อน ปริมาณฝนคาดการณ์ BC CFSV2 กับปริมาณฝนตรวจวัดจริงมีค่าค่อนข้างใกล้เคียงกัน ดังในรูปที่ 4.7 มีค่า R เพิ่มขึ้นเป็น 0.80 และค่า RMSE ลดลงเหลือ 23.5 มิลลิเมตร/สองสัปดาห์ ดังแสดงในตารางที่ 4.6

ปี 2562 มีลักษณะเช่นเดียวกันกับปี 2561 คือ ปริมาณฝนคาดการณ์แบบ Raw CFSV2 มีค่าสูงกว่า (overestimate) ในหลายช่วงเวลา เมื่อเปรียบเทียบกับปริมาณฝนตรวจวัดจริงของกรมอุตุนิยมวิทยา ดังแสดงในรูปที่ 4.8 โดยมีค่า R 0.85 และค่า RMSE 43.0 มิลลิเมตร/สองสัปดาห์ ดังในตารางที่ 4.6 และเมื่อปรับค่าความคลาดเคลื่อน ปริมาณฝนคาดการณ์ BC CFSV2 กับปริมาณฝนตรวจวัดจริงมีค่าใกล้เคียงกันดีเกือบตลอดทั้งปี โดยเฉพาะอย่างยิ่งในช่วงเดือนมกราคม-พฤษภาคม และธันวาคม มีค่า R 0.83 และค่า RMSE ลดลงอยู่ที่ 14.3 มิลลิเมตร/สองสัปดาห์



รูปที่ 4.7 กราฟแสดงปริมาณฝนรายสองสัปดาห์ สถานีเถิน จังหวัดลำปาง ปี 2561




รูปที่ 4.8 กราฟแสดงปริมาณฝนรายสองสัปดาห์ สถานีเถิน จังหวัดลำปาง ปี 2562

ตารางที่ 4.6 ผลการวิเคราะห์ Bias Correction CFSV2 ณ สถานีเถิน จังหวัดลำปาง ปี 2561-2562


คาดการณ์	ปี 2561		ปี 2562	
	R	RMSE	R	RMSE
Raw CFSV2	0.76	61.2	0.85	43.0
BC CFSV2	0.80	23.5	0.83	14.3

รูปที่ 4.9 แสดงปริมาณฝนรายสองสัปดาห์บริเวณท้ายเขื่อนภูมิพล ณ สถานีเขื่อนภูมิพล จังหวัดตาก รหัสสถานี 376203 ของปี 2561 จะเห็นว่า ปริมาณฝนคาดการณ์แบบ Raw CFSV2 ส่วนใหญ่มีค่าสูงกว่า (overestimate) ปริมาณฝนตรวจวัดจริงของกรมอุตุนิยมวิทยา มีเพียงช่วงเดือน เมษายน มิถุนายน และตุลาคม ที่ปริมาณฝนตรวจวัดมากกว่าฝนคาดการณ์ ค่า R อยู่ที่ 0.67 และค่า RMSE 38.8 มิลลิเมตร/สองสัปดาห์ ดังแสดงในตารางที่ 4.7 หลังปรับค่าความคลาดเคลื่อนแล้ว ปริมาณฝนคาดการณ์ BC CFSV2 กับปริมาณฝนตรวจวัดจริงโดยทั่วไปมีค่าใกล้เคียงกันมากขึ้น ยกเว้นประมาณเดือนพฤษภาคม ถึงมิถุนายน ที่การปรับค่าคาดการณ์ให้ผลไม่ค่อยดี อย่างไรก็ตาม ค่า R เพิ่มขึ้นเล็กน้อยอยู่ที่ 0.70 และค่า RMSE ลดลงเหลือ 21.7 มิลลิเมตร/สองสัปดาห์

สำหรับปี 2562 รูปที่ 4.10 แสดงให้เห็นว่า ปริมาณฝนคาดการณ์แบบ Raw CFSV2 ก็มีค่าสูงกว่า (overestimate) ปริมาณฝนตรวจวัดจริงของกรมอุตุนิยมวิทยา เป็นส่วนใหญ่ ซึ่งคล้ายกับในปี 2561 โดยมีค่า R 0.90 และค่า RMSE 17.3 มิลลิเมตร/สองสัปดาห์ ดังแสดงในตารางที่ 4.7 การปรับค่าความคลาดเคลื่อนทำให้ปริมาณฝนคาดการณ์ มีค่าลดลงมาใกล้เคียงกับปริมาณฝนตรวจวัดจริงเกือบตลอดทั้งปี มีเพียงช่วงเดือน กันยายนที่การปรับค่าความคลาดเคลื่อนให้ผลไม่ดี ปริมาณฝนคาดการณ์แบบ Raw CFSV2 กับปริมาณฝนตรวจวัดจริงมีค่าใกล้เคียงกันมากกว่า ในขณะที่ปริมาณฝนคาดการณ์ BC CFSV2 มีค่าต่ำเกินไป ทั้งนี้ปริมาณฝนคาดการณ์ BC CFSV2 กับปริมาณฝนตรวจวัดจริงมีค่า R 0.89 และค่า RMSE 9.5 มิลลิเมตร/สองสัปดาห์



รูปที่ 4.9 กราฟแสดงปริมาณฝนรายสองสัปดาห์ สถานีเขื่อนภูมิพล จังหวัดตาก ปี 2561



รูปที่ 4.10 กราฟแสดงปริมาณฝนรายสองสัปดาห์ สถานีเขื่อนภูมิพล จังหวัดตาก ปี 2562

ตารางที่ 4.7 ผลการวิเคราะห์ Bias Correction CFSV2 ณ สถานีเขื่อนภูมิพล จังหวัดตาก ปี 2561-2562


คาดการณ์	ปี 2561		ปี 2562	
	R	RMSE	R	RMSE
Raw CFSV2	0.67	38.8	0.90	17.3
BC CFSV2	0.70	21.7	0.89	9.5

4.4 ผลการปรับค่าความคลาดเคลื่อนรายลุ่มน้ำ

เพื่อศึกษาประสิทธิภาพการคาดการณ์ฝนโดยการปรับความคลาดเคลื่อนด้วยวิธี linear scaling ให้ละเอียดขึ้น จึงพิจารณาการคาดการณ์ฝนรายสองสัปดาห์แยกเป็นรายลุ่มน้ำและรายลุ่มน้ำสาขาในลุ่มน้ำเจ้าพระยาใหญ่ ซึ่งประกอบด้วยลุ่มน้ำปิง ลุ่มน้ำวัง ลุ่มน้ำยม ลุ่มน้ำน่าน ลุ่มน้ำเจ้าพระยา ลุ่มน้ำสะแกกรัง ลุ่มน้ำป่าสัก และลุ่มน้ำท่าจีน ของปีพ.ศ. 2561 และ 2562 โดยภาพรวมของทุกลุ่มน้ำ ผลการปรับลดความคลาดเคลื่อนของการคาดการณ์ฝนในปี 2561 ดีกว่าในปี 2562 ข้อมูลฝนในปี 2562 มีลักษณะเป็น 2 peaks คือ ในช่วงต้นฤดูฝน และช่วงปลายฤดูฝน แบบจำลอง CFSV2 คาดการณ์ปริมาณฝนรายสองสัปดาห์ในช่วง peak สูงกว่าฝนตรวจวัดจากกรมอุตุนิยมวิทยาค่อนข้างมาก ถึงแม้ว่าการปรับค่าความคลาดเคลื่อนจะทำให้ค่าคาดการณ์ลดต่ำลง แต่ในบางกรณีก็ยังไม่ใกล้เคียงกับปริมาณฝนตรวจวัดจริงมากพอ ค่า RMSE ก่อนการปรับค่าความคลาดเคลื่อนของฝนคาดการณ์รายสองสัปดาห์อยู่ในช่วง 46 – 68 มม. และ 44 – 60 มม. ในปี 2561 และ 2562 ตามลำดับ หลังการปรับค่าความคลาดเคลื่อนด้วยวิธี linear scaling สามารถลดค่า RMSE ลงได้ 29 – 45 มม. และ 18 – 36 มม. ในปี 2561 และ 2562 ตามลำดับ

พื้นที่ลุ่มน้ำปิงประกอบด้วยลุ่มน้ำสาขาจำนวน 20 ลุ่มน้ำสาขา ตัวอย่างผลการปรับลดความคลาดเคลื่อนของฝนคาดการณ์รายสองสัปดาห์ในลุ่มน้ำสาขาของลุ่มน้ำปิงในปี 2561 และ 2562

แสดงดังรูปที่ 4.11 โดยเฉลี่ยของทั้งพื้นที่ลุ่มน้ำ สามารถลดค่า RMSE จาก 46 มม. เหลือ 17 มม. โดยลดลง 29 มม. ในปี 2561 และลดค่า RMSE จาก 44 มม. เหลือ 26 มม. โดยลดลง 18 มม. ในปี 2562 รายละเอียดแสดงในตารางที่ 4.8




รูปที่ 4.11 ตัวอย่างผลการปรับลดความคลาดเคลื่อนของฝนคาดการณ์รายสองสัปดาห์ ในลุ่มน้ำสาขาของลุ่มน้ำปิง ในปีพ.ศ. 2561 และ 2562 (หรือ ค.ศ. 2018 และ 2019)

ตารางที่ 4.8 ผลการปรับลดความคลาดเคลื่อนของฝนคาดการณ์รายสองสัปดาห์จาก CFSV2 ในพื้นที่
ลุ่มน้ำปิงและลุ่มน้ำสาขา แสดงด้วยค่า RMSE

ลุ่มน้ำปิง (06)		RMSE ของ biweekly rainfall (มม)			
		2561		2562	
รหัสลุ่มน้ำย่อย	ชื่อลุ่มน้ำสาขา	ก่อนปรับค่า	หลังปรับค่า	ก่อนปรับค่า	หลังปรับค่า
0602	แม่น้ำปิงตอนบน	27	21	43	35
0603	น้ำแม่จืด	39	17	49	35
0604	แม่น้ำแม่แตง	32	18	45	36
0605	แม่น้ำปิงส่วนที่2	30	24	41	29
0606	น้ำแม่ริม	31	17	43	30
0607	น้ำแม่กวง	44	22	48	28
0608	น้ำแม่งาน	33	17	43	28
0609	น้ำแม่ลี	54	14	47	22
0610	น้ำแม่กลาง	41	18	44	25
0611	แม่น้ำปิงส่วนที่3	51	14	42	20
0612	น้ำแม่แจ่มตอนบน	42	14	48	28
0613	น้ำแม่แจ่มตอนล่าง	44	22	47	32
0614	น้ำแม่หาด	56	16	43	20
0615	น้ำแม่ตื่น	51	13	44	21
0616	แม่น้ำปิงส่วนที่4	53	15	34	17
0617	ห้วยแม่ท้อ	51	20	34	22
0618	คลองวังเจ้า	57	13	43	21
0619	คลองแม่ระกา	62	14	42	19
0620	คลองสวนหมาก	58	13	44	22
0621	แม่น้ำปิงตอนล่าง	66	14	45	21
RMSE เฉลี่ย		46	17	44	26

พื้นที่ลุ่มน้ำวังประกอบด้วยลุ่มน้ำสาขาจำนวน 7 ลุ่มน้ำสาขา ตัวอย่างผลการปรับลดความคลาดเคลื่อนของฝนคาดการณ์รายสองสัปดาห์ในลุ่มน้ำสาขาของลุ่มน้ำวังในปี 2561 และ 2562 แสดงดังรูปที่ 4.12 โดยเฉลี่ยของทั้งพื้นที่ลุ่มน้ำ สามารถลดค่า RMSE จาก 60 มม. เหลือ 19 มม. โดยลดลง 41 มม. ในปี 2561 และลดค่า RMSE จาก 55 มม. เหลือ 27 มม. โดยลดลง 28 มม. ในปี 2562 รายละเอียดแสดงในตารางที่ 4.9

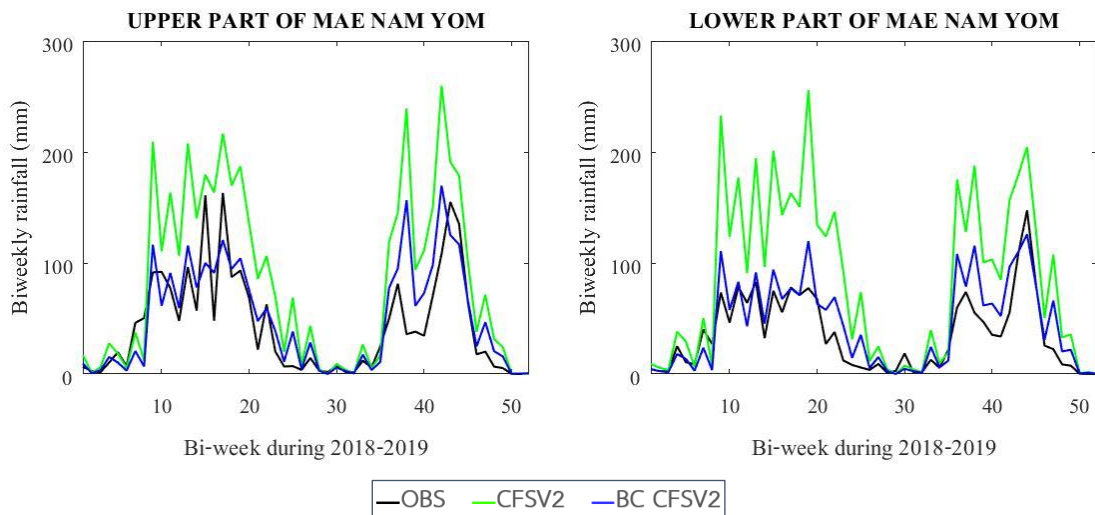


รูปที่ 4.12 ตัวอย่างผลการปรับลดความคลาดเคลื่อนของฝนคาดการณ์รายสองสัปดาห์ ในลุ่มน้ำสาขาของลุ่มน้ำวัง ในปีพ.ศ. 2561 และ 2562 (หรือ ค.ศ. 2018 และ 2019)

ตารางที่ 4.9 ผลการปรับลดความคลาดเคลื่อนของฝนคาดการณ์รายสองสัปดาห์จาก CFSV2 ในพื้นที่ลุ่มน้ำวังและลุ่มน้ำสาขา แสดงด้วยค่า RMSE

ลุ่มน้ำวัง (07)		RMSE ของ biweekly rainfall (มม)			
		2561		2562	
รหัสลุ่มน้ำย่อย	ชื่อลุ่มน้ำสาขา	ก่อนปรับค่า	หลังปรับค่า	ก่อนปรับค่า	หลังปรับค่า
0702	แม่น้ำวังตอนบน	66	19	62	33
0703	แม่น้ำสวย	53	16	55	30
0704	น้ำแม่ต๋อย	54	22	55	26
0705	แม่น้ำวังตอนกลาง	58	21	57	29
0706	น้ำแม่จาง	64	22	55	28
0707	น้ำแม่ต๋ำ	58	16	50	24
0708	แม่น้ำวัง	68	18	49	20
RMSE เฉลี่ย		60	19	55	27

พื้นที่ลุ่มน้ำยมประกอบด้วยลุ่มน้ำสาขาจำนวน 11 ลุ่มน้ำสาขา ตัวอย่างผลการปรับลดความคลาดเคลื่อนของฝนคาดการณ์รายสองสัปดาห์ในลุ่มน้ำสาขาของลุ่มน้ำยมในปี 2561 และ 2562 แสดงดังรูปที่ 4.13 โดยเฉลี่ยของทั้งพื้นที่ลุ่มน้ำ สามารถลดค่า RMSE จาก 68 มม. เหลือ 23 มม. โดยลดลง 45 มม. ในปี 2561 และลดค่า RMSE จาก 56 มม. เหลือ 27 มม. โดยลดลง 29 มม. ในปี 2562 รายละเอียดแสดงในตารางที่ 4.10




รูปที่ 4.13 ตัวอย่างผลการปรับลดความคลาดเคลื่อนของฝนคาดการณ์รายสองสัปดาห์ในลุ่มน้ำสาขาของลุ่มน้ำยม ในปี พ.ศ. 2561 และ 2562 (หรือ ค.ศ. 2018 และ 2019)

ตารางที่ 4.10 ผลการปรับลดความคลาดเคลื่อนของฝนคาดการณ์รายสองสัปดาห์จาก CFSV2 ในพื้นที่ลุ่มน้ำยมและลุ่มน้ำสาขา แสดงด้วยค่า RMSE

ลุ่มน้ำยม (08)		RMSE ของ biweekly rainfall (มม)			
		2561		2562	
รหัสลุ่มน้ำย่อย	ชื่อลุ่มน้ำสาขา	ก่อนปรับค่า	หลังปรับค่า	ก่อนปรับค่า	หลังปรับค่า
0802	แม่ข่ายมตอนบน	61	24	61	31
0803	แม่น้ำควน	59	28	61	32
0804	น้ำปี	61	24	63	35
0805	แม่น้ำงาว	60	19	57	28
0806	แม่ข่ายมตอนกลาง	68	26	55	28
0807	น้ำแม่คำมี	71	35	57	32
0808	น้ำแม่ต้า	66	22	54	27
0809	ห้วยแม่สิน	71	22	52	24
0810	แม่น้ำหมอก	74	17	51	20
0811	น้ำแม่รำพัน	74	17	49	21
0812	แม่ข่ายมตอนล่าง	80	19	54	22
RMSE เฉลี่ย		68	23	56	27

พื้นที่ลุ่มน้ำน่านประกอบด้วยลุ่มน้ำสาขาจำนวน 16 ลุ่มน้ำสาขา ตัวอย่างผลการปรับลดความคลาดเคลื่อนของฝนคาดการณ์รายสองสัปดาห์ในลุ่มน้ำสาขาของลุ่มน้ำน่านในปี 2561 และ 2562 แสดงดังรูปที่ 4.14 โดยเฉลี่ยของทั้งพื้นที่ลุ่มน้ำ สามารถลดค่า RMSE จาก 64 มม. เหลือ 26 มม. โดยลดลง 38 มม. ในปี 2561 และลดค่า RMSE จาก 59 มม. เหลือ 29 มม. โดยลดลง 30 มม. ในปี 2562 รายละเอียดแสดงในตารางที่ 4.11




รูปที่ 4.14 ตัวอย่างผลการปรับลดความคลาดเคลื่อนของฝนคาดการณ์รายสองสัปดาห์ในกลุ่มน้ำสาขา
ของลุ่มน้ำน่าน ในปี พ.ศ. 2561 และ 2562 (หรือ ค.ศ. 2018 และ 2019)

ตารางที่ 4.11 ผลการปรับลดความคลาดเคลื่อนของฝนคาดการณ์รายสองสัปดาห์จาก CFSV2 ในพื้นที่ลุ่มน้ำน่านและลุ่มน้ำสาขา แสดงด้วยค่า RMSE


ลุ่มน้ำน่าน (09)		RMSE ของ biweekly rainfall (มม)			
		2561		2562	
รหัสลุ่มน้ำย่อย	ชื่อลุ่มน้ำสาขา	ก่อนปรับค่า	หลังปรับค่า	ก่อนปรับค่า	หลังปรับค่า
0902	แม่น้ำน่านตอนบน	61	45	65	36
0903	ห้วยน้ำยาว (1)	60	34	60	34
0904	แม่น้ำน่านส่วนที่ 2	58	35	60	29
0905	น้ำยาว (2)	59	39	65	32
0906	น้ำสมน	57	29	55	29
0907	แม่น้ำน่านส่วนที่ 3	63	19	56	26
0908	น้ำสา	60	25	57	28
0909	น้ำว้า	61	31	71	30
0910	น้ำแห้ง	64	26	57	27
0911	แม่น้ำน่านส่วนที่ 4	77	25	51	23
0912	น้ำปาด	65	21	60	29
0913	คลองตรอน	71	20	52	23
0914	แม่น้ำแควน้อย	69	16	57	28
0915	น้ำภาค	66	17	59	29
0916	แม่น้ำวังทอง	63	19	58	28
0917	แม่น้ำน่านตอนล่าง	71	18	57	28
RMSE เฉลี่ย		64	26	59	29

พื้นที่ลุ่มน้ำเจ้าพระยาประกอบด้วยลุ่มน้ำสาขาจำนวน 2 ลุ่มน้ำสาขา ตัวอย่างผลการปรับลดความคลาดเคลื่อนของฝนคาดการณ์รายสัปดาห์ในลุ่มน้ำสาขาของลุ่มน้ำเจ้าพระยาในปี 2561 และ 2562 แสดงดังรูปที่ 4.15 โดยเฉลี่ยของทั้งพื้นที่ลุ่มน้ำ สามารถลดค่า RMSE จาก 60 มม. เหลือ 20 มม. โดยลดลง 40 มม. ในปี 2561 และลดค่า RMSE จาก 54 มม. เหลือ 20 มม. โดยลดลง 34 มม. ในปี 2562 รายละเอียดแสดงในตารางที่ 4.12



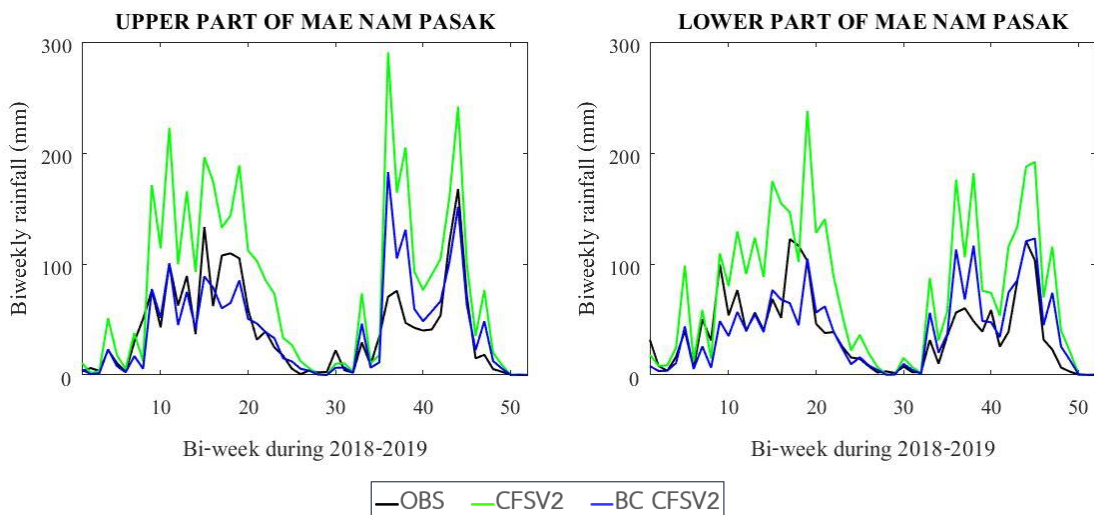
รูปที่ 4.15 ตัวอย่างผลการปรับลดความคลาดเคลื่อนของฝนคาดการณ์รายสัปดาห์ในลุ่มน้ำสาขาของลุ่มน้ำเจ้าพระยา ในปีพ.ศ. 2561 และ 2562 (หรือ ค.ศ. 2018 และ 2019)

พื้นที่ลุ่มน้ำสะแกกรังประกอบด้วยลุ่มน้ำสาขาจำนวน 4 ลุ่มน้ำสาขา ตัวอย่างผลการปรับลดความคลาดเคลื่อนของฝนคาดการณ์รายสัปดาห์ในลุ่มน้ำสาขาของลุ่มน้ำสะแกกรังในปี 2561 และ 2562 แสดงดังรูปที่ 4.16 โดยเฉลี่ยของทั้งพื้นที่ลุ่มน้ำ สามารถลดค่า RMSE จาก 60 มม. เหลือ 15 มม. โดยลดลง 45 มม. ในปี 2561 และลดค่า RMSE จาก 45 มม. เหลือ 23 มม. โดยลดลง 22 มม. ในปี 2562 รายละเอียดแสดงในตารางที่ 4.12




รูปที่ 4.16 ตัวอย่างผลการปรับลดความคลาดเคลื่อนของฝนคาดการณ์รายสองสัปดาห์ในกลุ่มน้ำสาขาของลุ่มน้ำสะแกกรัง ในปีพ.ศ. 2561 และ 2562 (หรือ ค.ศ. 2018 และ 2019)

พื้นที่ลุ่มน้ำป่าสักประกอบด้วยลุ่มน้ำสาขาจำนวน 8 ลุ่มน้ำสาขา ตัวอย่างผลการปรับลดความคลาดเคลื่อนของฝนคาดการณ์รายสองสัปดาห์ในกลุ่มน้ำสาขาของลุ่มน้ำป่าสักในปี 2561 และ 2562 แสดงดังรูปที่ 4.17 โดยเฉลี่ยของทั้งพื้นที่ลุ่มน้ำ สามารถลดค่า RMSE จาก 59 มม. เหลือ 23 มม. โดยลดลง 36 มม. ในปี 2561 และลดค่า RMSE จาก 60 มม. เหลือ 24 มม. โดยลดลง 36 มม. ในปี 2562 รายละเอียดแสดงในตารางที่ 4.12



รูปที่ 4.17 ตัวอย่างผลการปรับลดความคลาดเคลื่อนของฝนคาดการณ์รายสองสัปดาห์ในกลุ่มน้ำสาขาของลุ่มน้ำป่าสัก ในปีพ.ศ. 2561 และ 2562 (หรือ ค.ศ. 2018 และ 2019)

พื้นที่ลุ่มน้ำท่าจีนประกอบด้วยลุ่มน้ำสาขาจำนวน 2 ลุ่มน้ำสาขา ตัวอย่างผลการปรับลดความคลาดเคลื่อนของฝนคาดการณ์รายสองสัปดาห์ในลุ่มน้ำสาขาของลุ่มน้ำท่าจีนในปี 2561 และ 2562 แสดงดังรูปที่ 4.18 โดยเฉลี่ยของทั้งพื้นที่ลุ่มน้ำ สามารถลดค่า RMSE จาก 52 มม. เหลือ 18 มม. โดยลดลง 34 มม. ในปี 2561 และลดค่า RMSE จาก 46 มม. เหลือ 21 มม. โดยลดลง 25 มม. ในปี 2562 รายละเอียดแสดงในตารางที่ 4.12



รูปที่ 4.18 ตัวอย่างผลการปรับลดความคลาดเคลื่อนของฝนคาดการณ์รายสองสัปดาห์ในลุ่มน้ำสาขาของลุ่มน้ำท่าจีน ในปีพ.ศ. 2561 และ 2562 (หรือ ค.ศ. 2018 และ 2019)

ตารางที่ 4.12 ผลการปรับลดความคลาดเคลื่อนของฝนคาดการณ์รายสองสัปดาห์จาก CFSV2 ในพื้นที่ลุ่มน้ำเจ้าพระยา สะแกกรัง ป่าสัก ท่าจีนและลุ่มน้ำสาขา แสดงด้วยค่า RMSE

รหัสลุ่มน้ำย่อย	ชื่อลุ่มน้ำสาขา	RMSE ของ biweekly rainfall (มม)			
		2561		2562	
		ก่อนปรับค่า	หลังปรับค่า	ก่อนปรับค่า	หลังปรับค่า
ลุ่มน้ำเจ้าพระยา (10)					
0010	บึงบรเพ็ด	67	19	56	21
0010	แม่น้ำเจ้าพระยา	54	20	52	20
RMSE เฉลี่ย		60	20	54	20
ลุ่มน้ำสะแกกรัง (11)					
0011	น้ำแม่วัง	60	13	47	21
0011	คลองโพธิ์	59	14	45	22
0011	ห้วยทับเสลา	53	14	43	27
0011	แม่น้ำสะแกกรังตอนล่าง	66	17	45	20
RMSE เฉลี่ย		60	15	45	23
ลุ่มน้ำป่าสัก (12)					
0012	แม่น้ำป่าสักตอนบน	56	20	63	30
0012	ห้วยน้ำพุ	51	20	58	28
0012	แม่น้ำป่าสักส่วนที่ 2	63	17	60	23
0012	แม่น้ำป่าสักส่วนที่ 3	56	19	57	22
0012	ห้วยเกาะแก้ว	52	22	53	19
0012	ลำสนธิ	52	24	57	24
0012	แม่น้ำป่าสักตอนล่าง	55	24	53	23
0012	ห้วยหมวกเหล็ก	87	38	80	23
RMSE เฉลี่ย		59	23	60	24
ลุ่มน้ำท่าจีน (13)					
0013	ห้วยกระเสียว	49	19	44	23
0013	แม่น้ำท่าจีน	55	17	49	20
RMSE เฉลี่ย		52	18	46	21

บทที่ 5

สรุปผลและข้อเสนอแนะ

5.1 สรุปผลการดำเนินงาน

โครงการวิจัยนี้เป็นการศึกษาวิจัยและพัฒนาระบบคาดการณ์ฝนรายสองสัปดาห์สำหรับการบริหารจัดการน้ำโดยเน้นที่ลุ่มน้ำเจ้าพระยา จากการศึกษาเบื้องต้นเกี่ยวกับระบบคาดการณ์ฝนรายสองสัปดาห์ที่มีการใช้กันอยู่ในปัจจุบัน อันได้แก่ การคาดการณ์ฝนรายสองสัปดาห์จาก European Centre for Medium-range Weather Forecasts (ECMWF) และ National Centers for Environmental Prediction (NCEP) พบว่า ผลคาดการณ์ฝน CFSv2 (Climate Forecast System) จาก NCEP มีความเหมาะสมกับการนำมาประยุกต์เพื่อใช้งานจริงสำหรับประเทศไทย มากกว่าข้อมูลจากโครงการ Sub-seasonal to seasonal (S2S) ECMWF ด้วยเหตุที่ข้อมูลการคาดการณ์ฝน S2S ECMWF ยังอยู่ในขั้นวิจัย และเสียค่าใช้จ่ายค่อนข้างสูงหากจะนำมาใช้ ในขณะที่ข้อมูล CFSv2 เป็นข้อมูลเปิดที่ใช้คาดการณ์ในทางปฏิบัติอยู่แล้ว

ในงานวิจัยนี้ ได้เลือกพัฒนาระบบคาดการณ์ฝนรายสองสัปดาห์จากแบบจำลองคู่ควบ WRF-ROMS ระหว่างแบบจำลองบรรยากาศ กับแบบจำลองทางสมุทรศาสตร์ เนื่องจากพื้นที่ประเทศไทย ตั้งอยู่ระหว่างมหาสมุทรเขตร้อนและมีพื้นที่ติดทั้งมหาสมุทรอินเดียและมหาสมุทรแปซิฟิก ปฏิสัมพันธ์ของบรรยากาศกับมหาสมุทร และการเปลี่ยนแปลงของอุณหภูมิพื้นผิวน้ำทะเลอาจเป็นปัจจัยสำคัญที่มีผลต่อการแปรผันของสภาพอากาศ โดยเฉพาะอย่างยิ่งการแปรปรวนของฝนและรูปแบบของฝนในพื้นที่ ในช่วงระยะ 2 สัปดาห์

การจะนำระบบแบบจำลองคู่ควบ WRF-ROMS มาใช้คาดการณ์ฝนรายสองสัปดาห์ จำเป็นต้องเข้าใจขีดจำกัดและประสิทธิภาพของระบบดังกล่าว งานส่วนหนึ่งที่ทำเนิการคือ การศึกษาเกี่ยวกับพารามิเตอร์ที่เหมาะสมของแบบจำลอง และการวิเคราะห์ความไวของแบบจำลอง (Sensitivity analysis) ต่อข้อมูลนำเข้า ซึ่งคือค่าเริ่มต้นและค่าขอบ (Initial and boundary conditions, ICBC) สำหรับค่า ICBC ได้ใช้ข้อมูลจาก 2 ระบบของ NCEP คือ NCEP Climate Forecast System Reanalysis (CFRS) และ NCEP FNL (Final) Operational Global Analysis and Forecast (FNL_GFS) เพื่อเปรียบเทียบกัน รวมทั้งมีการพิจารณาความไวของแบบจำลองต่อฟิสิกส์ที่เกี่ยวข้องกับรูปแบบการคำนวณเมฆฝน (Cumulus schemes: CU options) โดยมี 2 ตัวเลือกคือ Betts-Miller-Janjic Scheme และ Grell 3D Ensemble Scheme นอกจากนี้ ได้เลือกกรณีน้ำท่วมปีพ.ศ. 2554 เป็นกรณีศึกษา เพราะเป็นเหตุการณ์น้ำท่วมใหญ่ที่สร้างความเสียหายให้กับพื้นที่ลุ่มน้ำเจ้าพระยาอย่างมากและเห็นได้ชัด เหตุการณ์น้ำท่วมนี้ส่วนหนึ่งเป็นผลมาจากพายุไต้

หมาเป็นพายุที่ส่งผลกระทบต่อไทยในช่วงปลายเดือนมิถุนายน และปลายเดือนกรกฎาคม ถึงต้นเดือนสิงหาคม เหตุการณ์พายุทั้งสองนี้ถือเป็นกรณี extreme ที่ควรต้องมีการคาดการณ์ล่วงหน้า รายละเอียดที่แม่นยำ เพื่อให้สามารถวางแผนบริหารจัดการน้ำให้เหมาะสม เป็นการบรรเทาความเดือดร้อนและความเสียหายได้ทันเวลาที่ ในการศึกษาแบบจำลองทั้ง WRF และ ROMS มีความละเอียดเชิงพื้นที่ของกริดประมาณ 25 กม. และแบบคู่ควบระหว่าง WRF:ROMS เป็นแบบ 1:1 โดเมน ผลการประเมินประสิทธิภาพพบว่า ความแม่นยำของแบบจำลองอาจสูงหรือต่ำขึ้นอยู่กับเหตุการณ์และพื้นที่ที่ได้รับผลกระทบจากพายุ โดยทั่วไปแบบจำลองทำนายการเกิดเหตุการณ์ฝนตกน้อยได้ถูกต้องพอควร แต่ไม่สามารถทำนายการเกิดเหตุการณ์ฝนตกปานกลางจนถึงหนักมากได้ การใช้ข้อมูลนำเข้าเป็น CFSR และการคำนวณค่าแบบ Grell 3D Ensemble Scheme มักให้ค่าคาดการณ์จากแบบจำลองที่ใกล้เคียงกับค่าตรวจวัดจริงมากกว่าแบบอื่น

เนื่องจากผลที่ได้จากการทดลองกับ Non-nesting ของ แบบจำลอง WRF มีความแม่นยำต่ำมากในบางกรณีที่ทดลอง จึงมีการทดสอบเพิ่มเติมเพื่อศึกษาว่าการเพิ่มความละเอียดของพื้นที่ศึกษา ซึ่งคือลุ่มน้ำเจ้าพระยา จากโดเมนเดิมที่มีความละเอียด 25 กม. ให้มีความละเอียดสูงขึ้นเป็น 5 กม. ด้วยการทำ Nesting WRF domain อีก 1 โดเมน (WRF:ROMS = 2:1 โดเมน) จะมีผลต่อความแม่นยำอย่างไร โดยได้ศึกษาความไวของแบบจำลองต่อ Microphysics options สำหรับการคำนวณเมฆฝนในระดับไมโคร (Microphysics scale) ประกอบด้วย ตัวเลือกที่นำมาพิจารณามี 2 ตัวเลือกคือ Kessler microphysics และ Goddard microphysics scheme สองตัวเลือกนี้มีความสอดคล้องกับรูปแบบการเกิดเมฆในพื้นที่เขตร้อนใกล้ศูนย์สูตร ผลการทดลองชี้ว่า การใช้เทคนิค Nesting ที่ความละเอียด 5 กม. และคำนวณการเกิดเมฆฝนในระดับไมโคร สามารถทำให้แบบจำลองคาดการณ์ปริมาณฝนแม่นยำขึ้นจากเดิมที่เป็นแบบ Non-nesting ค่าสหสัมพันธ์เชิงเวลาเพิ่มขึ้น และการใช้ Goddard microphysics ให้ผลค่อนข้างดีกว่า Kessler microphysics

การคาดการณ์ด้วยแบบจำลองคู่ควบ WRF-ROMS เป็นวิธีการที่ต้องใช้ข้อมูลจำนวนมาก การประมวลผลต้องอาศัยระบบคอมพิวเตอร์สมรรถนะสูง และระยะเวลาในการคำนวณค่าคาดการณ์จากแบบจำลองค่อนข้างนาน ดังนั้น ในปีแรกของโครงการวิจัยนี้ จึงได้ศึกษาแนวทางการพัฒนาระบบคาดการณ์ฝนรายสองสัปดาห์โดยใช้ผลคาดการณ์จากแบบจำลอง CFSV2 โดยตรงด้วย เพราะสามารถดำเนินการได้เร็วกว่า ผลการศึกษาพบว่า ค่าคาดการณ์ปริมาณฝนจากแบบจำลอง CFSV2 แม้ว่าจะมีค่าสหสัมพันธ์กับปริมาณฝนตรวจวัดจริงในระดับค่อนข้างสูง แต่ก็ยังมีความคลาดเคลื่อนหรือความเอนเอียงในการคาดการณ์สูงเกินไปเมื่อวัดโดยใช้ค่า RMSE จึงมีการนำผลคาดการณ์จากแบบจำลอง CFSV2 มาปรับลดความคลาดเคลื่อนด้วยวิธีทางสถิติ (Bias correction) วิธีที่ใช้คือ Linear scaling วิธีการดังกล่าวช่วยเพิ่มประสิทธิภาพการคาดการณ์ฝนรายสองสัปดาห์ ค่าคาดการณ์หลังการปรับค่าความคลาดเคลื่อนใกล้เคียงปริมาณฝนตรวจวัดจริงมากขึ้น และส่วนใหญ่ให้ผลที่น่า

พอใจ ค่าสหสัมพันธ์ระหว่างค่าคาดการณ์กับปริมาณฝนตรวจวัดจริงไม่ต่ำกว่า 0.70 และค่า RMSE ลดลงจากเมื่อไม่ปรับค่าความคลาดเคลื่อนมากกว่า 50% ในหลาย ๆ กรณี

ทีมวิจัยนำเสนอผลการคาดการณ์จากระบบคาดการณ์ฝนรายสองสัปดาห์ที่พัฒนาขึ้นในรูปแบบเว็บไซต์ และได้สนับสนุนข้อมูลฝนคาดการณ์ให้กับทีมวิจัยอื่นตลอดจนหน่วยงานต่าง ๆ เป็นประจำทุกสัปดาห์ เพื่อนำไปใช้ประโยชน์ต่อไปได้ ข้อมูลอยู่ในทั้งรูปแบบ ESRI ascii และ ไฟล์ที่เป็น text ซึ่งผู้ใช้ข้อมูลสามารถเข้าถึงข้อมูลผ่านทาง FTP

5.2 ข้อเสนอแนะ

กระบวนการเกิดฝนมีเหตุปัจจัยต่าง ๆ เกี่ยวข้องจำนวนมากทั้งที่วัดค่าได้และวัดค่าไม่ได้ แต่ปัจจัยก็มีความไม่แน่นอนสูง จึงทำให้การคาดการณ์ฝนเป็นงานที่ทำทายมาก งานวิจัยนี้ช่วยให้เกิดระบบคาดการณ์ฝนรายสองสัปดาห์ที่มีประสิทธิภาพในการคาดการณ์ที่น่าพอใจในระดับหนึ่ง หลายพื้นที่และหลายกรณี สามารถคาดการณ์ได้ดีมาก ในขณะที่บางพื้นที่อาจยังไม่ดีพอ แต่ก็แสดงให้เห็นถึงศักยภาพของระบบที่สมควรได้รับการวิจัยและพัฒนาต่อไปอย่างต่อเนื่องในอนาคต เพื่อให้ระบบคาดการณ์สามารถให้ข้อมูลฝนคาดการณ์ที่เป็นประโยชน์ในการสนับสนุนการบริหารจัดการน้ำอย่างมีประสิทธิภาพมากขึ้น โดยแนวทางในการทำวิจัยมีดังนี้

1. การเพิ่มประสิทธิภาพของระบบคาดการณ์ฝนรายสองสัปดาห์โดยวิธีการแบบผสม กล่าวคือมีการใช้ความรู้ทางฟิสิกส์ร่วมกับการใช้ข้อมูล (data driven) เป็นเครื่องมือในการพัฒนาแบบจำลอง
2. การปรับปรุงข้อมูลนำเข้าแบบจำลองให้มีความละเอียดและถูกต้องกับสภาพความเป็นจริงในพื้นที่และเป็นปัจจุบันมากขึ้น

เอกสารอ้างอิง

- Chen, M., Shi, W., Xie, P., Silva, V.B.S., Kousky, V.E., Higgins, R.W., and Janowiak, J.E. (2008). Assessing objective techniques for gauge-based analyses of global daily precipitation. *Journal of Geophysical Research*. 113, 1-13.
- Crochemore, L., Ramos, M-H, and Pappenberger, F. (2016). Bias correcting precipitation forecasts to improve the skill of seasonal streamflow forecasts. *Hydrol. Earth Syst. Sci.* 20, 3601–3618, doi:<https://doi.org/10.5194/hess-20-3601-2016>.
- Cubasch, U., Hegerl, G.C., and Waszkewitz, J. (1996). Prediction, detection and regional assessment of anthropogenic climate change. *Geophysica*. 32(1-2), 77-96.
- Dee, D.P., Uppala, S.M., Simmons, A.J., Berrisford, P., Poli, P., Kobayashi, S., Andrae, U., Balmaseda, M.A., Balsamo, G., Bauer, P., Bechtold, P., Beljaars, A.C.M., Van de Berg, L., Bidlot, J., Bormann, N., Delsol, C., Dragani, R., Fuentes, M., Geer, A.J., Haimberger, L., Healy, S.B., Hersbach, H., , E. V. Hólm, E.V., Isaksen, L., Kallberg, P., Köhler, M., Matricardi, M., McNally, A.P., Monge-Sanz, B.M., Morcrette, J.J., Park, B.K., Peubey, C., P. de Rosnay , Tavolato, C., Thépaut, J.N., and Vitart, F. (2011). The ERA-Interim reanalysis: configuration and performance of the data assimilation system. 137, 553-597.
- Dutta, P. S. and Tahbilder, H. (2014). Prediction of rainfall using data mining technique over Assam. *Indian Journal of Computer Science and Engineering (IJCSE)*. Vol. 5 No. 2 85-90.
- Fan, Y. and van den Dool H. (2011). Bias correction and forecast skill of NCEP GFS ensemble week-1 and week-2 precipitation, 2-m surface air temperature, and soil moisture forecasts. *Weather Forecast*. 26, 355–370.
- Geetha, G. and Selvaraj, R. S. (2011). Prediction of monthly rainfall in Chennai using back propagation neural network model. *International Journal of Engineering Science and Technology*. 3(1), 211-213.

- Glahn, H.R. and Lowry, D.A. (1972). The use of model output statistics (MOS) in objective weather forecasting. *Journal of Applied Meteorology*. 11, 1203-1211.
- Goswami, P. and Srividya. (1996). A novel neural network design for long range prediction of rainfall pattern. *Current Science*. 70(6), 447-457.
- Higgins, R. W., Janowiak, J. E., and Yao, Y. (1996). A gridded hourly precipitation data base for the United States (1963-1993). NCEP/Climate Prediction Center ATLAS No. 1., 47 pp.
- Hu, M. J. C. (1964). Application of Adaline system to weather forecasting. Technical Report, Stanford Electronics Laboratories, Stanford University.
- Hung, N. Q., Babel, M. S., Weesakul, S., and Tripathi, N. K. (2009). An artificial neural network model for rainfall forecasting in Bangkok, Thailand. *Hydrology and Earth System Sciences*. 13, 1413–1425
- Jie, W., Vitart, F., Wu, T., and Liu, X. (2017). Simulations of the Asian summer monsoon in the sub-seasonal to seasonal prediction project (S2S) database. *Quarterly Journal of the Royal Meteorological Society*. 143 (706):2282-95. doi: 10.1002/qj.3085.
- Kannan, M., Prabhakaran, S., and Ramachandran, P. (2010). Rainfall forecasting using data mining technique. *International Journal of Engineering and Technology*. 2(6), 397-401.
- Kannan, S. and Ghosh, S.S. (2011). Prediction of daily rainfall state in a river basin using statistical downscaling from GCM output. *Stochastic Environmental Research and Risk Assessment*. 25(4), 457–474. doi: <https://doi.org/10.1007/s00477-010-0415-y>
- Lorenz, E.N. (1963). Deterministic nonperiodic flow. *Journal of the Atmospheric Sciences*. 20, 130-141.
- Lorenz, E.N. (1969). Atmospheric predictability as revealed by naturally occurring analogues. *Journal of the Atmospheric Sciences*. 26, 636-646.
- Lu, K. and Wang, L. (2011). A Novel Nonlinear Combination Model Based on Support Vector Machine for Rainfall Prediction. 2011 Fourth International Joint

- Conference on Computational Sciences and Optimization. 1343-1346. doi: 10.1109/CSO.2011.50.
- Manzanas, R., Brands, S., San-Martín, D., Lucero, A., Limbo, C., and Gutiérrez, J.M. (2015). Statistical downscaling in the tropics can be sensitive to reanalysis choice: a case study for precipitation in the Philippines. *J. Clim.* 28(10):4171–4184. doi:10.1175/JCLI-D-14-00331.1
- Manzanas, R., Lucero, A., Weisheimer, A., and Gutiérrez, J.M. (2017). Can bias correction and statistical downscaling methods improve the skill of seasonal precipitation forecasts? *Clim. Dyn.* 50(3-4) 1161–1176, 10.1007/s00382-017-3668-z
- Peng, P., Barnston, A.G., and Kumar, A. (2013). A comparison of skill between two versions of the NCEP Climate Forecast System (CFS) and CPC's operational short-lead seasonal outlooks. *Weather Forecasting.* 28, 445–462, doi:10.1175/WAF-D-12-00057.1.
- Quintana-Seguí, P., Le Moigne, P., Durand, Y., Martin, E., Habets, F., Baillon, M., Canellas, C., Franchistéguy, L., and Morel, S. (2008). Analysis of near surface atmospheric variables: Validation of the SAFRAN analysis over France. *Journal of Applied Meteorology and Climatology.* 47, 92-107. DOI: 10.1175/2007JAMC1636.1
- Rasouli, K., Hsieh, W.W., and Cannon, A.J. (2012). Daily streamflow forecasting by machine learning methods with weather and climate inputs. *Journal of Hydrology*, 414–415, 284-293.
- Rezaeian-Zadeh, M., Tabari, H., and Abghari, H. (2013). *Arab J Geosci.* 6, 2529-2537. <https://doi.org/10.1007/s12517-011-0517-y>
- Saha, S., Moorthi, S., Wu, X., Wang, J., Nadiga, S., Tripp, P., Behringer, D., Hou, Y-T, Chuang, H., Iredell, M., Ek, M., Meng, J., Yang, R., Mendez, M.P., van den Dool, H., Zhang, Q., Wang, W., Chen, M., and Becker, E. (2014). The NCEP Climate Forecast System Version 2, *J. Clim.* 27, 2185–2208, doi:10.1175/JCLI-D-12-00823.1. [Available at <http://nomads.ncdc.noaa.gov/data/cfsr-rfl-mmts/>.]

- Sahai, A., Soman, M., and Satyan, V. (2000). All India summer monsoon rainfall prediction using an artificial neural network. *Climate Dynamics*. 16(4), 291–302. doi: <https://doi.org/10.1007/s003820050>
- Solomantine, D.P. and Dulal, K.N. (2003). Model trees as an alternative to neural networks in rainfall-runoff modelling. *Hydrological Sciences Journal*. 48(3), 399-411, DOI: 10.1623/hysj.48.3.399.45291.
- Stephanie, F.P. and Hussam, N.M. (2017). Real-time application of the multihazard hurricane impact level model for the Atlantic Basin. *Frontiers in Built Environment*. 67(3). doi: 10.3389/fbuil.2017.00067
- Tian, D., Wood, E.F., and Yuan, X. (2017). CFSv2-based sub-seasonal precipitation and temperature forecast skill over the contiguous United States. *Hydrology and Earth System Sciences*. 21:1477-90. doi: 10.5194/hess-21-1477-2017.
- Torsri, K., Wannawong, W., Sarinnapakorn, K., Boonya-Aroonnet, S., and Chitradon, R. (2014). An application of air-sea model components in the Coupled Ocean-Atmosphere-Wave-Sediment Transport (COAWST) modeling system over an Indochina Peninsular Sub-region: Impact of high spatiotemporal SST on WRF model in precipitation prediction (poster). 2014 Asia Oceania Geosciences Society (AOGS). Sapporo, Japan.
- Toth, E., Brath, A., and Montanari, A. (2000). Comparison of shortterm rainfall prediction models for real time flood forecasting. *Journal of Hydrology*. 239, 132-147.
- Vidal, J.P., Martin, E., Franchistéguy, L., Baillon, M., and Soubeyroux, J.M. (2010). A 50-year high-resolution atmospheric reanalysis over France with the Safran system. *International Journal of Climatology*. 30, 1627–1644.
- Vitart, F., Buizza, R., Balmaseda, M.A., Balsamo, G., Bidlot, J.-R., Bonet, A., Fuentes, M., Hofstadler, A., Molteni, F., and Palmer, T.N. (2008). The new VarEPS-monthly forecasting system: A first step towards seamless prediction. *Quarterly Journal of the Royal Meteorological Society* 134 (636): 1789-1799. doi: 10.1002/qj.322.
- Wang, W. and Xie, P. (2007). A Multiplatform-Merged (MPM) SST analysis. *Journal of Climate*. 20, 1662-1679.


- Warner, J.C., Armstrong, B., He, R., and Zambon, J.B. (2010). Development of a Coupled Ocean–Atmosphere–Wave–Sediment Transport (COAWST) modeling system. *Ocean Modelling*. 35(3):230-244. doi: <https://doi.org/10.1016/j.ocemod.2010.07.010>.
- Weisheimer, A., Doblas-Reyes, F.J., Palmer, T.N., Alessandri, A., Arribas, A., Déqué, M., Keenlyside, N., MacVean, M., Navarra, A., and Rogel, P. (2009). ENSEMBLES: A new multi-model ensemble for seasonal-to-annual predictions: Skill and progress beyond DEMETER in forecasting tropical Pacific SSTs. *Geophysical Research Letters*. 36, 1-6.
- White, C.J., Carlsen, H., Robertson, A.W., Klein, R.J.T., Lazo, J.K., Kumar, A., Vitart, F., Coughlan de Perez, E., Ray, A.J., Murray, V., Bharwani, S., MacLeod, D., James, R., Fleming, L., Morse, A.P., Eggen, B., Graham, R., Kjellström, E., Becker, E., Pegion, K.V., Holbrook, N.J., McEvoy, D., Depledge, M., Perkins-Kirkpatrick, S., Brown, T.J., Street, R., Jones, L., Remenyi, T.A., Hodgson-Johnston, I., Buontempo, C., Lamb, R., Meinke, H., Arheimer, B., and Zebiak, S.E. (2017). Potential applications of subseasonal-to-seasonal (S2S) predictions. *Meteorological Applications*. Published online in Wiley Online Library (wileyonlinelibrary.com). DOI: 10.1002/met.1654
- Zorita, E., Hughes, J.P., Lettemaier, D.P., and Storch, H.V. (1995). Stochastic characterization of regional circulation patterns for climate model diagnosis and estimation of local precipitation. *Journal of Climate*. 8, 1023-1042.

ภาคผนวก

สถานที่ทำการศึกษาวิจัย



รูปที่ ก.1 สถานที่ปฏิบัติงาน สถาบันสารสนเทศทรัพยากรน้ำ (องค์การมหาชน)



รูปที่ ก.2 ระบบ HPC ของสถาบันสารสนเทศทรัพยากรน้ำ (องค์การมหาชน)
ซึ่งเป็นส่วนหนึ่งของ National e-Science Infrastructure Consortium

ภาพกิจกรรมการลงพื้นที่สำรวจ
ระหว่างวันที่ 3-5 สิงหาคม 2563

วันที่ 3 ส.ค. 2563

แก้มลิงบึงตะเคร็ง ต.บางระกำ อ.บางระกำ จ.พิษณุโลก เป็นบึงสาธารณะที่ขุดสร้างเพื่อรองรับปริมาณน้ำตามโครงการอนุรักษ์ฟื้นฟูแหล่งน้ำพื้นที่บางระกำ เพื่อแก้ไขปัญหาน้ำท่วมและภัยแล้งของพื้นที่ตำบลบางระกำ จังหวัดพิษณุโลก


สภาพปัจจุบัน : ในบึงมีน้ำค่อนข้างน้อย ทางน้ำที่เชื่อมต่อกับบึง มีน้ำน้อยมากและมีหญ้ารก บริเวณบึงอยู่ระหว่างการปรับปรุงริมตลิ่งและภูมิทัศน์ และไม่มีจุดตรวจวัดระดับน้ำในบึง



รูปที่ ก.3 แก้มลิงบึงตะเคร็ง

ประตูระบายน้ำแม่ซ้ายม บ้านหาดสะพานจันทร์ จ.สุโขทัย สร้างขึ้นโดยมีวัตถุประสงค์เพื่อเก็บกักน้ำในลำน้ำยม ช่วยลดการขาดแคลนน้ำในเขตจังหวัดสุโขทัย ทั้งด้านการอุปโภค-บริโภค และช่วยระบายน้ำในช่วงฤดูน้ำหลาก รวมทั้งเป็นประตูระบายน้ำสำคัญที่ช่วยในการผันน้ำระหว่างแม่ซ้ายมและแม่น้ำน่าน

สภาพปัจจุบัน : ในช่วงที่สำรวจเกิดฝนตกหนักติดต่อกันหลายวัน ทำให้ลำน้ำยมบริเวณประตูระบายน้ำมีน้ำเพิ่มขึ้นมาก



รูปที่ ก.4 ประตูระบายน้ำแม่ซ้ายม

โครงการแก้มลิงทุ่งทะเลหลวง จ.สุโขทัย เป็นแหล่งเก็บกักน้ำถาวรในลักษณะแก้มลิงขนาดใหญ่ โดยมีหลักการ คือใช้กักเก็บน้ำที่มีปริมาณมากในฤดูฝนเพื่อเป็นการบรรเทาปัญหาอุทกภัยในเขตชุมชนเมืองสุโขทัย โดยจะรับน้ำจากแม่น้ำยมที่ไหลบ่าล้นตลิ่งฝั่งขวา น้ำห้วยท่าแพ น้ำแม่มอก ที่ไหลบ่าจากอำเภอสวรรคโลก และน้ำแม่รำพัน น้ำแม่กองค้าย ที่ไหลบ่าจากอำเภอบ้านด่านลานหอย และไหลมารวมกันบริเวณที่ลุ่มที่เรียกว่า “ทะเลหลวง”

สภาพปัจจุบัน : ปริมาณน้ำในแก้มลิงค่อนข้างน้อย มีสันดอนเกิดขึ้นกึ่งกลางน้ำ




รูปที่ ก.5 โครงการแก้มลิงทุ่งทะเลหลวง

วันที่ 4 ส.ค. 2563

เขื่อนภูมิพล เป็นเขื่อนคอนกรีตขนาดใหญ่ที่สุดในประเทศไทย สามารถกักเก็บน้ำได้ถึง 13,462 ล้านลูกบาศก์เมตร เขื่อนนี้ให้ประโยชน์ทั้งในด้านการผลิตไฟฟ้าและการชลประทาน ครอบคลุมพื้นที่ทั้งภาคเหนือและภาคกลาง

สภาพปัจจุบัน : มีน้ำเหลืออยู่ในเขื่อนน้อยมาก เพียง 29% ของความจุเขื่อน และเป็นปริมาณน้ำที่น้อยกว่าปี 2558 ที่เกิดภัยแล้งรุนแรงในประเทศไทย



รูปที่ ก.6 เขื่อนภูมิพล

สถานีอุตุนิยมวิทยาเกษตรดอยชุมเชอ อ.แม่สอด จ.ตาก เป็นสถานีตรวจวัดสภาพอากาศหลักของกรมอุตุนิยมวิทยา ที่ใช้ตรวจวัดค่าสภาพอากาศจากภาคพื้นดิน เช่น ปริมาณฝน อุณหภูมิ ความชื้น ความกดอากาศ ความเข้มแสง และความเร็วลม เป็นต้น



รูปที่ ก.7 สถานีอุตุนิยมวิทยาเกษตรดอยชุมเชอ

วันที่ 5 ส.ค. 2563

บึงบอระเพ็ด เป็นบึงทะเลสาบน้ำจืดขนาดใหญ่ที่สุดในประเทศไทย ใช้เป็นแก้มลิงรองรับน้ำหลากจากภาคเหนือเพื่อบรรเทาปัญหาอุทกภัยและใช้กักเก็บน้ำเพื่อบรรเทาปัญหาภัยแล้ง

สภาพปัจจุบัน : ระดับน้ำต่ำมาก เกิดสันดอนดินขนาดใหญ่เป็นบริเวณกว้าง ท่าเทียบเรือเกยอยู่บนพื้นดิน



รูปที่ ก.8 บึงบอระเพ็ด

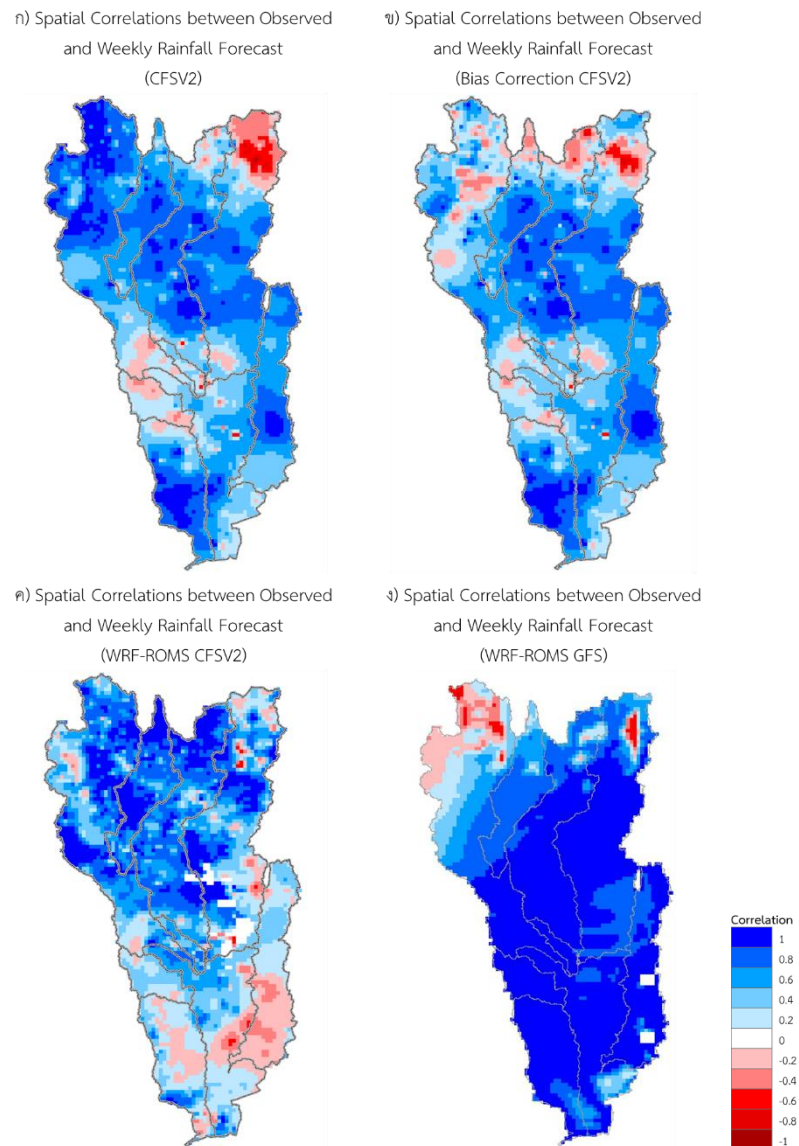
เขื่อนเจ้าพระยา อ.สรรพยา จ.ชัยนาท เป็นเขื่อนทดน้ำในแม่น้ำเจ้าพระยา ใช้สำหรับกักเก็บน้ำในลำน้ำ ยกระดับน้ำ การผันน้ำ เพื่อใช้บริหารจัดการน้ำในพื้นที่ภาคกลาง

สภาพปัจจุบัน : น้ำในแม่น้ำค่อนข้างน้อย เกิดสันดอนดิน และมีผักตบชวา




รูปที่ ก.9 เขื่อนเจ้าพระยา

แผนที่ Spatial Correlations รายสัปดาห์ วันที่ 29 ตุลาคม 2563 ถึง วันที่ 4 พฤศจิกายน 2563



รูปที่ ก.10 Spatial Correlations ระหว่างการตรวจวัดและการคาดการณ์ฝนรายสัปดาห์ ก) CFSV2 ข) Bias Correction CFSV2 ค) WRF-ROMS CFSV2 ง) WRF-ROMS GFS (วันที่ 29 ตุลาคม 2563 ถึง 4 พฤศจิกายน 2563)

แผนที่ Spatial Correlations รายสัปดาห์ วันที่ 29 ตุลาคม 2563 ถึง วันที่ 4 พฤศจิกายน 2563



รูปที่ ก.11 Spatial RMSE ระหว่างการตรวจวัดและการคาดการณ์ฝนรายสัปดาห์ ก) CFSV2 ข) Bias Correction CFSV2 ค) WRF-ROMS CFSV2 ง) WRF-ROMS GFS (วันที่ 29 ตุลาคม 2563 ถึง 4 พฤศจิกายน 2563)



การพัฒนาแบบคาดการณ์ปริมาณฝนรายสัปดาห์
สัปดาห์
เพื่อการบริหารจัดการน้ำในพื้นที่ลุ่มน้ำเจ้าพระยา

CFSv2 (Bias Corrected), Bi-Weekly Precipitation, CPF Basin
02-Nov-2020 to 15-Nov-2020



Download Files


Index of /forecast/bi-weekly/bc_cfsv2/bi-weekly

Name	Last modified	Size	Description
Parent Directory	-	-	-
bi_weekly_20200713.zip	31-Jul-2020 09:25	201K	
bi_weekly_20200720.zip	20-Jul-2020 15:04	205K	
bi_weekly_20200721.zip	21-Jul-2020 07:58	204K	
bi_weekly_20200722.zip	22-Jul-2020 07:59	202K	
bi_weekly_20200723.zip	23-Jul-2020 07:59	207K	
bi_weekly_20200724.zip	24-Jul-2020 07:59	207K	
bi_weekly_20200725.zip	25-Jul-2020 07:59	206K	
bi_weekly_20200726.zip	26-Jul-2020 07:59	205K	
bi_weekly_20200727.zip	27-Jul-2020 07:59	207K	
bi_weekly_20200728.zip	28-Jul-2020 07:59	208K	
bi_weekly_20200729.zip	29-Jul-2020 07:59	208K	
bi_weekly_20200803.zip	01-Sep-2020 12:35	195K	
bi_weekly_20200810.zip	01-Sep-2020 11:58	194K	
bi_weekly_20200817.zip	01-Sep-2020 11:38	189K	
bi_weekly_20200824.zip	31-Aug-2020 17:14	188K	
bi_weekly_20200831.zip	31-Aug-2020 17:26	190K	
bi_weekly_20200907.zip	07-Sep-2020 02:42	191K	
bi_weekly_20200914.zip	14-Sep-2020 02:42	190K	
bi_weekly_20200921.zip	21-Sep-2020 02:42	186K	
bi_weekly_20200928.zip	28-Sep-2020 02:42	187K	

URL : https://live1.hii.or.th/product/latest/forecast/bi-weekly/cfsv2_cpy.html

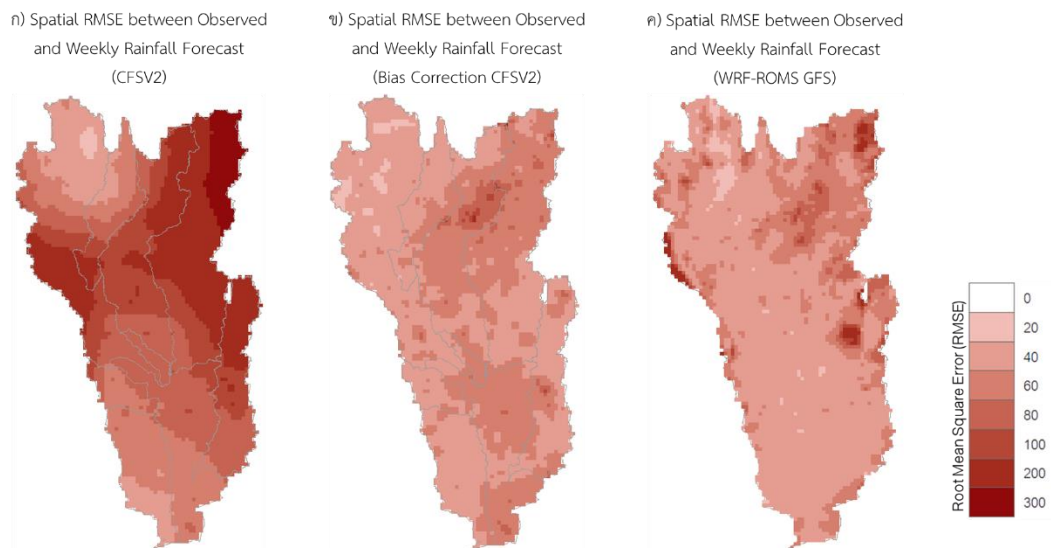
รูปที่ ก.12 เว็บไซต์แสดงผลการคาดการณ์ฝนรายสัปดาห์

แผนที่ Spatial Correlations รายสัปดาห์ วันที่ 9 สิงหาคม 2563 ถึง วันที่ 4 ตุลาคม 2563



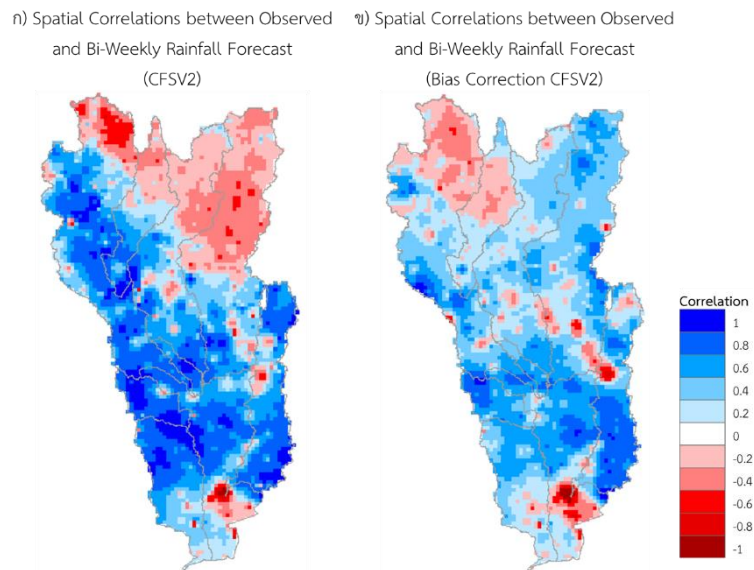
รูปที่ ก.13 ผลการวิเคราะห์ Spatial Correlations ระหว่างการตรวจวัดและการคาดการณ์ฝนรายสัปดาห์ ก) CFSV2 ข) Bias Correction CFSV2 ค) WRF-ROMS GFS (วันที่ 9 สิงหาคม 2563 ถึง วันที่ 4 ตุลาคม 2563)

แผนที่ Spatial RMSE รายสัปดาห์ วันที่ 9 สิงหาคม 2563 ถึง วันที่ 4 ตุลาคม 2563



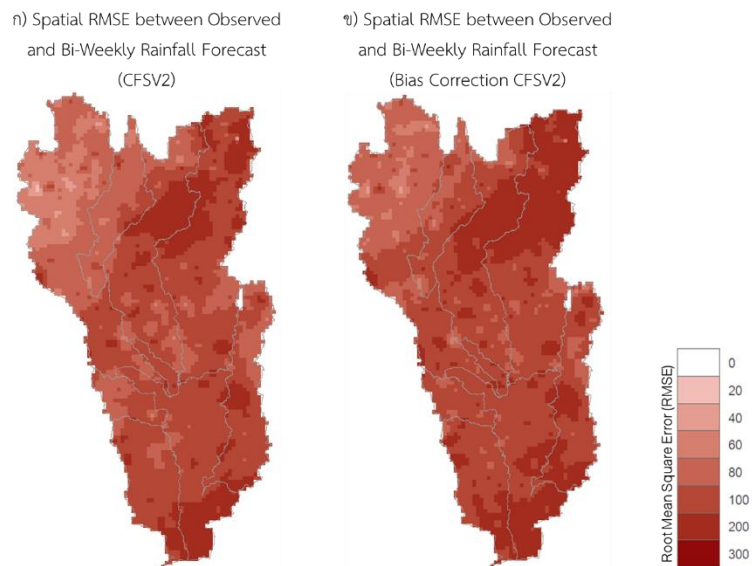
รูปที่ ก.14 ผลการวิเคราะห์ Spatial RMSE ระหว่างการตรวจวัดและการคาดการณ์ฝนรายสัปดาห์ ก) CFSV2 ข) Bias Correction CFSV2 ค) WRF-ROMS GFS (วันที่ 9 สิงหาคม 2563 ถึง วันที่ 4 ตุลาคม 2563)

แผนที่ Spatial Correlations รายสองสัปดาห์ วันที่ 9 สิงหาคม 2563 ถึง วันที่ 11 ตุลาคม 2563



รูปที่ ก.15 ผลการวิเคราะห์ Spatial Correlations ระหว่างการตรวจวัดและการคาดการณ์ฝนรายสองสัปดาห์ ก) CFSV2 ข) Bias Correction CFSV2 (วันที่ 9 สิงหาคม 2563 ถึง วันที่ 11 ตุลาคม 2563)

แผนที่ Spatial RMSE รายสองสัปดาห์ วันที่ 9 สิงหาคม 2563 ถึง วันที่ 11 ตุลาคม 2563



รูปที่ ก.16 ผลการวิเคราะห์ Spatial RMSE ระหว่างการตรวจวัดและการคาดการณ์ฝนรายสองสัปดาห์ ก) CFSV2 ข) Bias Correction CFSV2 (วันที่ 9 สิงหาคม 2563 ถึง วันที่ 11 ตุลาคม 2563)

ตารางที่ ก.1 ตารางเปรียบเทียบกิจกรรมที่เสนอในข้อเสนอโครงการและกิจกรรมที่ทำจริง

กิจกรรมที่เสนอในข้อเสนอโครงการ		เดือน											
		1	2	3	4	5	6	7	8	9	10	11	12
1. รวบรวมข้อมูลอุตุนิยมวิทยาและผลการคาดการณ์ฝนรายสองสัปดาห์ของหน่วยงานต่าง ๆ ตรวจสอบความถูกต้องของข้อมูลและจัดเตรียมข้อมูล	Plan												
	Actual												
2. วิเคราะห์ข้อมูลอุตุนิยมวิทยาและประเมินผลการคาดการณ์ปริมาณฝนรายสองสัปดาห์ของหน่วยงานต่าง ๆ ทำการคัดเลือกข้อมูลที่จะนำไปใช้ประโยชน์ต่อ	Plan												
	Actual												
3. วิเคราะห์ความต้องการและปัญหาการใช้งานข้อมูลคาดการณ์ในการตัดสินใจและออกแบบการประยุกต์ใช้ผลการคาดการณ์ให้เหมาะสมกับการบริหารจัดการน้ำ	Plan												
	Actual												
4. วิจัยการเพิ่มประสิทธิภาพผลการคาดการณ์ฝนรายสองสัปดาห์ด้วยวิธี Statistical machine learning เพื่อให้ใช้ได้ดีกับการบริหารจัดการน้ำในพื้นที่ลุ่มน้ำเจ้าพระยา*	Plan												
	Actual												
5. พัฒนาและติดตั้งระบบคาดการณ์ปริมาณฝนรายสองสัปดาห์	Plan												
	Actual												
6. สรุปผลของโครงการและนำเสนอแนวทางการประยุกต์ใช้กับการคาดการณ์ฝนรายสองสัปดาห์ในพื้นที่อื่น ๆ	Plan												
	Actual												

หมายเหตุ *กิจกรรมที่ 4 มีการเพิ่มประสิทธิภาพการคาดการณ์โดยวิธี Linear scaling ซึ่งถือว่าเป็นวิธีการทาง Statistical machine learning ประเภทหนึ่ง

ตารางที่ ก.2 ตารางเปรียบเทียบกิจกรรมที่เสนอในข้อเสนอโครงการและกิจกรรมที่แท้จริง

Output (ตามแผนงาน)	ผลสำเร็จ (%)	ผลการดำเนินงาน ⁽¹⁾
1. ได้ข้อมูลที่ครบถ้วน มีคุณภาพ และอยู่ในรูปแบบที่สะดวกสำหรับการวิเคราะห์	100	เป็นไปตามแผน
2. ได้ปัจจัยหรือตัวแปรสำคัญที่จะช่วยในการคาดการณ์ปริมาณฝนรายสองสัปดาห์	100	เป็นไปตามแผน
3. ได้ทราบขีดจำกัดและประสิทธิภาพของการคาดการณ์ฝนรายสองสัปดาห์ที่ใช้อยู่ในปัจจุบัน และได้แนวทางการประยุกต์ใช้ผลคาดการณ์กับการบริหารจัดการน้ำสำหรับพื้นที่ลุ่มน้ำเจ้าพระยา	100	เป็นไปตามแผน
4. วิธีการคาดการณ์ฝนรายสองสัปดาห์สำหรับพื้นที่ลุ่มน้ำเจ้าพระยา	100	เป็นไปตามแผน
5. ระบบคาดการณ์ฝนรายสองสัปดาห์สำหรับพื้นที่ลุ่มน้ำเจ้าพระยา	100	เป็นไปตามแผน
6. แนวทางการประยุกต์ใช้กระบวนการคาดการณ์ฝนรายสองสัปดาห์ในพื้นที่อื่น ๆ	100	เป็นไปตามแผน
ร้อยละความก้าวหน้าในการดำเนินงานต่อโครงการวิจัยตลอดทั้งโครงการ⁽²⁾		100

หมายเหตุ : (1) ผลการปฏิบัติจริง ให้ระบุผลการดำเนินกิจกรรม
 กรณีที่ 1 กิจกรรมที่ยังไม่ถึงกำหนดการดำเนินการตามแผนที่ระบุใน proposal ให้ใส่เครื่องหมาย “ - ” ในช่องผลการดำเนินงาน
 กรณีที่ 2 กิจกรรมที่ถึงกำหนดการดำเนินการตามแผนที่ระบุในข้อเสนอโครงการวิจัย (Proposal) แต่ยังไม่ได้นำผลการให้ใส่เหตุผลในช่องผลการดำเนินงาน
 (2) การคำนวณร้อยละความก้าวหน้าในการดำเนินโครงการวิจัย ให้คำนวณจากความสำเร็จรวมในทุกกิจกรรม