



การเปรียบเทียบแบบจำลองภูมิอากาศโลกจากการลดขนาดด้วย โครงข่ายประสาทเทียมในการประเมินน้ำฝน

Comparison of Global Climate Models Downscaled by Artificial Neural Network to Estimate Rainfall

Virun Chulkaivalsucharit* and Uma Seeboonruang

วิรุณ จุลไกวัลสุจริต* และ อูมา สีบุญเรือง

ภาควิชาวิศวกรรมสิ่งแวดล้อม คณะวิศวกรรมศาสตร์

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง กรุงเทพฯ 10520

*E-mail : virun.j@gmail.com

บทคัดย่อ

ปัจจุบันปัญหาภัยพิบัติต่างๆ ไม่ว่าจะเป็นน้ำท่วมหรือภัยแล้งล้วนส่งผลให้เกิดความสูญเสียทั้งชีวิตและทรัพย์สิน แบบจำลองภูมิอากาศโลกเป็นเครื่องมือหนึ่งที่ถูกใช้เพื่อทำนายการเปลี่ยนแปลงสภาพภูมิอากาศรวมไปถึงปริมาณน้ำฝน หากแต่แบบจำลองภูมิอากาศโลกนั้นมีความละเอียดต่ำและแต่ละประเทศได้มีการสร้างแบบจำลองบนพื้นฐานที่แตกต่างกันจึงจำเป็นต้องมีการลดขนาดแบบจำลองและคัดเลือกแบบจำลองที่เหมาะสมกับพื้นที่ศึกษา โดยในบทความนี้ได้นำข้อมูลแบบจำลองภูมิอากาศโลก HADcm3 จากประเทศอังกฤษ ECHAM5 จากประเทศเยอรมัน BCCR-BCM2.0 จากประเทศนอร์เวย์ และ CGCM3.1(T47) จากประเทศแคนาดา มาทำการลดขนาดแบบจำลองโดยใช้โครงข่ายประสาทเทียมร่วมด้วยกับข้อมูลน้ำฝนจากกรมอุตุนิยมวิทยาตั้งแต่ปี ค.ศ.1965-2014 และทำการใช้ตัวแปรทางสถิติในการคัดเลือกแบบจำลองในโครงการAR4 (the Fourth Assessment Report of the Intergovernmental Panel on Climate Change) 4 แบบจำลองสำหรับพื้นที่จังหวัดเชียงใหม่ หอนกคาย สุโขทัย อุบลราชธานี และภูเก็ต โดยพบว่าแบบจำลอง HADcm3 เหมาะสมกับจังหวัดเชียงใหม่ หอนกคาย และภูเก็ต แบบจำลองBCM2.0 เหมาะสมกับจังหวัดสุโขทัย แบบจำลอง ECHAM50 เหมาะสมกับจังหวัดอุบลราชธานี ในขณะที่แบบจำลอง CGCM ไม่เหมาะสมกับพื้นที่ใดเลยโดยความเหมาะสมที่กล่าวมาข้างต้นนี้อยู่ในหน่วยต่อปี และการเปลี่ยนแปลงปริมาณน้ำฝนที่ได้จากแบบจำลองพบว่าปริมาณน้ำฝนในเวลา 5 ปี (ค.ศ.2014-2018) จังหวัดเชียงใหม่ลดลง 5.22% จังหวัดหอนกคายลดลง 16.37% จังหวัดอุบลราชธานี ลดลง 10.71% จังหวัดภูเก็ตลดลง 24.17% จังหวัดสุโขทัยเพิ่มขึ้น 13.98% ในเวลา 10 ปี (ค.ศ.2014-2023) จังหวัดเชียงใหม่ลดลง 10.79% จังหวัดหอนกคายลดลง 9.40% จังหวัดอุบลราชธานี ลดลง 2.44% จังหวัดภูเก็ตลดลง 14.68% จังหวัดสุโขทัย

เพิ่มขึ้น 49.68% และในเวลาและ 25 ปี (ค.ศ.2023-2038) จังหวัดเชียงใหม่ลดลง 6.95% จังหวัดหนองคายเพิ่มขึ้น 0.68% จังหวัดอุบลราชธานี ลดลง 1.09% จังหวัดภูเก็ตลดลง 12.20% จังหวัดสุโขทัยเพิ่มขึ้น 29.07%

คำสำคัญ :แบบจำลองภูมิอากาศโลก; การเปลี่ยนแปลงสภาพภูมิอากาศ; โครงข่ายประสาทเทียม; การจัดการน้ำAR4; ตัวแปรทางสถิติ

Abstract

Recently, a disaster as Flooding and drought has damaged lives and assets. The Global Climate Models has been tool for predicting Climate Change including a future-rainfall. Because it had coarse resolution and many models and made from many countries, needed a downscaling process to be increasing accuracy and selecting suitable models to use in an area. This research used 4 models of the Fourth Assessment Report of the Intergovernmental Panel on Climate Change (AR4) consisting of HADcm3 model, ECHAM5 model, BCCR-BCM2.0 model and CGCM3.1 (T47) model from England, Germany, Norway and Canada, respectively. Moreover, an observed rainfall-data (A.D.1965-2014) of 5Province from Thai Meteorological Department, consisting of Chaingmai, Nongkai, Sukhothai, Ubonratchathani and Phuket provinces, and an Artificial Neural Networks were used to downscaling, statistic variable was also used to appropriate models. Base on annual units, the resultant selection shown the best suitability for HADcm3 was 3 provinces composed of Chaingmai, Nongkai and Phuket whereas BCCR-BCM and ECHAM5 were with Sukhothai and Ubonratchathani, respectively. CGCM was not suitability for any province base on annual units. The 5-years future rainfall (A.D.2014-2018) from selectively downscaled models compared with historic rainfall data presented a decreasing rainfall 5.22% in Chaingmai, 16.37% in Nongkai, 10.71% in Ubonratchathani and 24.17% in Phuket while it increased 13.98% in Sukothai. The 10-years future rainfall (A.D.2014-2023) from selectively downscaled models compared with historic rainfall data presented a decreasing rainfall 10.79% in Chaingmai, 9.4% in Nongkai, 2.44% in Ubonratchathani and 14.68% in Phuket whilst it increased 49.68% in Sukothai. The 25-years future rainfall (A.D.2014-2038) from selectively downscaled models compared with historic rainfall data presented a decreasing rainfall 6.95% in Chaingmai and 1.09% in Ubonratchathani while it increased 13.98 in Sukothai, 0.68% in Nongkai and 12.20% in Phuket.

Keywords : Global Climate Models; Climate Change; Artificial Neural Networks; water management; AR4; statistic variable

บทนำ

บทความนี้มีวัตถุประสงค์เพื่อทำการคัดเลือกแบบจำลองภูมิอากาศโลก(AR4) หลังจากผ่านกระบวนการลดขนาดด้วยโครงข่ายประสาทเทียม 4 แบบจำลอง ได้แก่ BCM2.0 CGCM HADcm3 และ ECAM50M โดยมีพื้นที่ศึกษา 5 จังหวัดประกอบไปด้วย จังหวัด เชียงใหม่ หนองคาย สุโขทัย อุบลราชธานี และภูเก็ต

แบบจำลองภูมิอากาศโลก [1] เป็นแบบจำลองทางตัวเลขที่แสดงถึงกระบวนการทางกายภาพมีความละเอียดต่ำเมื่อนำมาใช้ต้องทำการลดขนาดแบบจำลองก่อนการลดขนาดแบบจำลองสามารถทำได้สองวิธีหลักๆ ได้แก่ วิธีการทางสถิตศาสตร์ (Statics) และวิธีการทางพลวัต (Dynamic) โดยการลดขนาดแบบจำลองด้วยโครงข่ายประสาทเทียมจัดว่าเป็นการลดขนาดด้วยวิธีการทางสถิตศาสตร์ โดยแบบจำลองดังกล่าวจะทำการจำลองล่วงหน้าไปในอนาคตโดยมีการใช้สถานการณ์จำลองเพื่อสะท้อนถึงการเปลี่ยนแปลงของภูมิอากาศ สถานการณ์จำลองถูกแบ่งออกเป็น 4 ประเภทหลักๆ ได้แก่ สถานการณ์ A1 A2 B1 และ B2 แต่ละสถานการณ์จะมีความหมายต่างกันโดยในการวิจัยนี้ใช้สถานการณ์ A1B ซึ่งมีความใกล้เคียงกับสถานการณ์ปัจจุบันมากที่สุด

A1 เป็นสถานการณ์ที่โลกมีการเติบโตทางเศรษฐกิจอย่างรวดเร็วและจำนวนประชากรมีจำนวนมากสุดที่กลางศตวรรษแล้วลดจำนวนลงรวมไปถึงมีการ


เพิ่มขึ้นของเทคโนโลยีใหม่ที่มีประสิทธิภาพเพิ่มขึ้น โดยในสถานการณ์ A1 สามารถแยกย่อยออกไปตามแหล่งการใช้พลังงานได้ A1F ซึ่งหมายถึงมีการใช้พลังงานฟอสซิลเพียงอย่างเดียว A1T ไม่มีการใช้พลังงานฟอสซิล และ A1B มีการใช้พลังงานต่างๆ อย่างสมดุล

A2 เป็นสถานการณ์ที่โลกมีความแตกต่างกันอย่างมาก การเพิ่มขึ้นของจำนวนประชากรเป็นไปอย่างต่อเนื่อง และเศรษฐกิจเติบโตช้าในแต่ละส่วน

B1 เป็นสถานการณ์ที่โลกมีการเติบโตทางเศรษฐกิจอย่างรวดเร็วและจำนวนประชากรมีจำนวนมากสุดที่กลางศตวรรษแล้วลดจำนวนลงมีการเพิ่มขึ้นของเทคโนโลยีใหม่ที่มีประสิทธิภาพเพิ่มขึ้นเกิดการเปลี่ยนแปลงโครงสร้างทางเศรษฐกิจอย่างรวดเร็วมีการให้ความรู้เกี่ยวกับสิ่งแวดล้อมรวมไปถึงการลดการใช้วัสดุที่ก่อให้เกิดมลภาวะและเริ่มมีการใช้เทคโนโลยีสะอาดที่มีประสิทธิภาพ

B2 เป็นสถานการณ์ที่โลกให้ความสำคัญกับการแก้ปัญหาท้องถิ่นด้าน สังคม เศรษฐกิจ และสิ่งแวดล้อมการเพิ่มขึ้นของประชากรเป็นไปอย่างต่อเนื่องแต่น้อยกว่า A2

สำหรับแบบจำลองภูมิอากาศโลกนั้นมีความแตกต่างกันสำหรับแต่ละแบบจำลองดังแสดงไว้ดังตารางที่ 1 โดยสาเหตุในการเลือกแบบจำลองเหล่านี้เนื่องจากเป็นแบบจำลองที่เป็นสากลและมีตัวแปรที่เหมาะสมในการใช้งานครบถ้วน



รูปที่ 1 ลักษณะการแบ่งสถานการณ์ในแบบจำลองภูมิอากาศโลก

(<http://www.ipcc.ch/ipccreports/sres/emission/index.php?idp=3>)


ตารางที่ 1 ตารางแสดงความแตกต่างของแบบจำลอง

แบบจำลอง	ประเทศ	ความละเอียด
HADcm3	อังกฤษ	ละติจูด 2.75° xลองจิจูด 3.75°
ECHAM5	เยอรมัน	ละติจูด 2.8° xลองจิจูด 2.8°
CGCM3.1(T47)	แคนาดา	ละติจูด 3.8° xลองจิจูด 3.8°
BCCR-BCM2.0	นอร์เวย์	ละติจูด 2.8° xลองจิจูด 2.8°

โครงข่ายประสาทเทียม (Artificial Neural Networks) [2] คือรูปแบบเทคนิคการจัดกลุ่มข้อมูลโดยได้แรงบันดาลใจมาจากการทำงานของระบบประสาทในสิ่งมีชีวิตโดยแนวคิดพื้นฐานของโครงข่ายประสาทคือโครงสร้างของระบบการเข้าถึงข้อมูลซึ่งประกอบไปด้วยการเชื่อมต่อระหว่างกันของปมประสาทจำนวนมาก โครงข่ายประสาทเทียมคล้ายเคียงกับเทคนิคของมนุษย์ในการเรียนรู้โดยการใช้ตัวอย่างในการแก้ไขปัญหา โครงข่ายประสาทเทียมเป็นโปรแกรมที่มีความสามารถในการกำหนดค่าที่จำเพาะเช่นการจัดจำรูปแบบซึ่งเรียกว่าการเทรน (train) โดยโครงข่ายประสาทเทียมมีความแตกต่างตามแต่ละเส้นทางที่มันเชื่อมต่อกัน โดยแต่ละเส้นทางจะมีค่าถ่วงน้ำหนักต่างกัน โดยประเภทของ

โครงข่ายประสาทเทียมแบ่งออกเป็นสามประเภทหลักๆ ได้แก่ การเรียนรู้แบบย้อนกลับ (Back-propagation) การเรียนรู้แบบรัศมี (Radius-propagation) และการเรียนรู้แบบเส้นประสาทแขนง (Neuro-Fuzzy propagation)

การเชื่อมโยงไปข้างหน้าแบบหลายชั้นของโครงข่ายประสาทเทียม (Multi-Layer Feed Forward Neural Networks) ในการศึกษาจะใช้โครงข่ายประสาทเทียมแบบหลายชั้นซึ่งลักษณะของโครงข่ายประสาทเทียมแบบนี้คือแต่ละปมประสาทในชั้นก่อนจะเชื่อมกับทุกปมประสาทในชั้นถัดไปโดยชั้นที่อยู่ระหว่างชั้นนำเข้ากับนำออกข้อมูลนั้นจะเรียกว่า Hidden Layer ดังรูปที่ 2 แสดงให้เห็นถึงชั้นนำเข้าข้อมูลและชั้นนำออกข้อมูล



รูปที่ 2 การเชื่อมโยงไปข้างหน้าแบบหลายชั้นของโครงข่ายประสาทเทียมแบบหนึ่ง hidden layer

(https://www.researchgate.net/publication/224401922_A_cascade_of_artificial_neural_networks_to_predict_transformers_oil_parameters)

ทุกปัญหาสามารถแก้ไขได้โดยการใช้โครงข่ายประสาทเทียมโดยใช้เพียงหนึ่ง hidden layer แต่บางครั้งก็ใช้มากกว่าเพื่อประสิทธิภาพที่มากขึ้น

โครงข่ายประสาทเทียมที่ใช้ในการศึกษานี้ เป็นประเภทการเรียนรู้แบบย้อนกลับ (Back propagation, BP) [3-7] โดยโครงข่ายประเภทนี้จะทำการรับสัญญาณจากชั้นข้อมูลผ่านไปยัง hidden layer แล้วทำการส่งออกในชั้นนำออก โดยโครงข่ายประเภทนี้ใช้ในการคำนวณค่าความสัมพันธ์ที่ไม่เป็นเส้นตรงโดยใช้การจัดการของค่าถ่วงน้ำหนัก (weight) โดยปมประสาททั่วไปจะทำการคำนวณเป็นผลรวมของข้อมูลที่ได้จากชั้นก่อนหน้าแบบเส้นตรงบวกด้วยค่าเบี่ยงเบนโดยเรียกสัมประสิทธิ์ว่าค่าถ่วงน้ำหนักดังสมการที่ (1)

$$h_j = b_j + \sum_{i=1}^{NI} w_{ji} x_i \quad (1)$$

โดย i คือตำแหน่งของข้อมูลนำเข้า, j คือตำแหน่งของปมประสาท, h คือค่าที่คำนวณได้ของปมประสาท, w คือค่าถ่วงน้ำหนัก, x คือค่าที่ได้จากการนำเข้าข้อมูล, NI คือขนาดของข้อมูลนำเข้าสำหรับการปมประสาทใน hidden layer จะทำการคำนวณแบบไม่เป็นเส้นตรงโดยปกติสมการที่ไม่เป็นเส้นตรงนี้คือ ฟังก์ชันของซิกมอยด์ ดังรูปที่ 4

ปมประสาทในชั้น Hidden layer รับข้อมูลจากปมประสาทของชั้นก่อนหน้าเขียนได้ดังสมการที่ (2)

$$y_j^H = f(h_j^H) \quad (2)$$

ในชั้นนำออกก็คิดในรูปแบบเดียวกันโดยใช้ตัวห้อยเป็นค่า k สำหรับความผิดพลาดและผลรวมกำลังสองของความผิดพลาดของโครงข่ายประสาทเทียมสามารถหาได้จากสมการที่ (3) และ (4)

$$e_k = t_k - y_k \quad (3)$$

$$\varepsilon = \frac{1}{2} \sum_{k=1}^{NO} e_k^2 \quad (4)$$

โดย NO คือจำนวนของปมประสาทการคำนวณหาค่าถ่วงน้ำหนักสามารถใช้กฎโซ่ทางคณิตศาสตร์ (chain rule) ในการคำนวณดังสมการที่ (5) และสามารถเขียนเมตริกแสดงค่าถ่วงน้ำหนักได้ดังสมการที่ (6) และ (7) โดยมีค่า $\propto$ คือค่าคงที่ในแต่ละขั้นตอนหรืออัตราเร็วในการเรียนรู้

$$\frac{\partial \varepsilon}{\partial w_{kl}} = \frac{\partial \varepsilon}{\partial e_k} \frac{\partial e_k}{\partial y_k} \frac{\partial y_k}{\partial h_k} \frac{\partial h_k}{\partial w_{kl}} \quad (5)$$


$$\Delta w_{kl} = -\propto \frac{\partial \varepsilon}{\partial w_{kl}} \quad (6)$$

สำหรับค่าเบี่ยงเบน (bias) นั้นมีความสามารถที่จะเปลี่ยนแปลงค่าถ่วงน้ำหนักได้จากค่าถ่วงน้ำหนักหนึ่งไปยังอีกค่าหนึ่งโดยสามารถเขียนได้ตามสมการที่ (7)

$$b_l = w_{ol} B \quad (7)$$

โดย ค่า B คือค่าคงที่ของการป้อนข้อมูลแต่ละแบบ, w_{oi} คือ ค่าถ่วงน้ำหนักของค่าเบี่ยงเบนในแต่ละปมประสาท, i คือปมประสาทโดยที่จะเป็นค่าบวกหรือลบก็ได้ขึ้นกับค่าถ่วงน้ำหนัก

ตัวแปรทางสถิติ [8, 9] ตัวแปรทางสถิติที่ถูกใช้ในการวิเคราะห์ได้แก่ค่าเบี่ยงเบน (Bias) และค่า RMSE(Root mean square error) และค่าสัมประสิทธิ์ดีเทอมินนต์ (R-Square) ในการคัดเลือกแบบจำลอง



รูปที่ 4 รูปแสดงฟังก์ชัน sigmoid

ค่าเบี่ยงเบนจะแสดงถึงความคลาดเคลื่อนของการทำนายหากมีค่าเข้าใกล้ 1 แสดงว่าค่าที่ได้จากการทำนายเท่ากับค่าจริงหากน้อยกว่า 1 แสดงว่าค่าที่ได้มีการประมาณค่าน้อยกว่าความจริงและหากมีค่ามากกว่า 1 แสดงว่าค่าที่ได้มีการประมาณค่ามากกว่าความจริงและสามารถเขียนได้ดังสมการที่ (8)

$$BIAS = \frac{\sum_{i=1}^n P_{GCM}}{\sum_{i=1}^n P_{Obs}} \quad (8)$$

สำหรับค่า RMSE นั้นเป็นค่าที่แสดงถึงความคลาดเคลื่อนในหน่วยความลึกต่อเวลาสำหรับการวิจัยนี้สามารถหาได้นั้นหมายความว่าค่า RMSE จะแสดงถึงว่าแบบจำลองนั้นๆมีการประมาณค่าที่มากเกินไปหรือน้อยเกินไปในระดับใดโดยสามารถหาได้ดังสมการที่ (9)

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (P_{GCM} - P_{Obs})^2}{n}} \quad (9)$$

สำหรับค่าสัมประสิทธิ์ดีเทอมินั้นสามารถหาได้จากสัดส่วนของผลต่างกำลังสองดังสมการที่ (10)

$$R^2 = \frac{\sum_{i=1}^n (P_{GCM} - \bar{P})^2}{\sum_{i=1}^n (P_{Obs} - \bar{P})^2} \quad (10)$$

วิธีการวิจัย

ทำการคัดเลือกตัวแปรจากแบบจำลองภูมิอากาศโลก 6 ตัวแปรได้แก่ อุณหภูมิเฉลี่ย ความชื้นสัมพัทธ์ ปริมาณน้ำฝน แรงลมในแนวเมริเดอเรียแนแรงลมในแนวโซนอล และ แรงลมเฉลี่ย เหลือเพียง 4 ตัวแปรที่มีผลกระทบต่อปริมาณน้ำฝนจากนั้นทำการจัดเรียงข้อมูลโดยรอบพื้นที่ศึกษาดังตารางที่ 2 พร้อมทั้งจัดเรียงข้อมูลที่ได้จากการสำรวจจริงดังตารางที่ 3 เพื่อทำการสร้างโครงข่ายในการเรียนรู้ข้อมูล

ตารางที่ 2 ตารางการจัดข้อมูลเพื่อการนำเข้าโครงข่ายประสาทเทียมในช่วงเวลาที่มีข้อมูลจริง

ตัวแปร	เดือนที่ 1 ปีที่ 1	เดือนที่ 2 ปีที่ 1			เดือนที่ 12 ปีที่ m
ตัวแปรที่ 1	xxx	Xxx	xxx	xxx	xxx
ตัวแปรที่ 2	xxx	Xxx	xxx	xxx	xxx
....	xxx	Xxx	xxx	xxx	xxx
....	xxx	Xxx	xxx	xxx	xxx
ตัวแปรที่ n	xxx	Xxx	xxx	xxx	xxx

ตารางที่ 3 ตารางการจัดข้อมูลจริงเพื่อทำการลดขนาดแบบจำลอง

เดือนและปี	ค่าที่ได้จากการสำรวจ
เดือนที่ 1 ปีที่ 1	xxx
....	xxx
เดือนที่ 12 ปีที่ m	xxx

จากนั้นทำการนำข้อมูลที่ได้จากการลดขนาดออกจะได้ค่าที่ย่อขนาดแล้วในเวลาที่ข้อมูลจริงพร้อมทั้งทำนายผลต่อไปโดยนำข้อมูลจากแบบจำลองไปใช้ในโครงข่ายที่ทำการสร้างไว้จากนั้นนำข้อมูลในช่วงที่มีข้อมูลจากการสำรวจไปทำการเปรียบเทียบด้วยตัวแปรทางสถิติโดยใช้เป็น RMSE รายปี RMSE รายเดือน ค่าเบี่ยงเบน สำหรับค่าสัมประสิทธิ์ดีเทอร์มิแนนต์โปรแกรมโครงข่ายประสาทเทียมจะทำการคำนวณให้แล้วทำการเปรียบเทียบเพื่อคัดเลือกแบบจำลองที่เหมาะสมกับแต่ละจังหวัดโดยใช้ตัวแปรทางสถิติที่กล่าวมาพร้อมทั้งทำการเปรียบเทียบข้อมูลที่ได้ออกมาเทียบกับข้อมูลในอดีตเพื่อทำการหาสัดส่วนที่เปลี่ยนไปของปริมาณน้ำฝน

ผลการทดลองและวิจารณ์

ผลการทดลองได้ค่าดังตารางที่ 4 และ 5 โดยพบว่าแบบจำลองแต่ละแบบจำลองให้ความแม่นยำและ

แม่นยำตรงในแต่ละพื้นที่ไม่เท่ากันจะพบว่าในจังหวัดเชียงใหม่ ภูเก็ต และหนองคาย นั้นแบบจำลอง HADcm3 สามารถประเมินปริมาณน้ำฝนได้เหมาะสมที่สุดในขณะที่ในเวลาที่จังหวัดอื่นๆ นั้นสามารถเลือกใช้ได้สองแบบจำลองทั้งนี้ขึ้นกับจุดมุ่งหมายของการทำนายหากต้องการทำนายในระยะยาว เช่น 5 ปี 10 ปี 25 ปี ควรเลือกใช้แบบจำลองที่มีค่า RMSE รายปีต่ำในขณะที่หากทำนายในระยะสั้นเช่นรายเดือน ราย 6 เดือน ราย 12 เดือนควรเลือกใช้แบบจำลองที่มีค่า RMS รายเดือนต่ำกว่า ในการวิจัยครั้งนี้การทำนายเป็นรายปี (ระยะยาว) จึงทำการเลือกแบบจำลอง BCM2.0 ในจังหวัดสุโขทัย และ ECHAM5 ในจังหวัดอุบลราชธานี สำหรับผลการทำนายปริมาณน้ำฝนในอนาคตนั้นถูกแสดงไว้ดังตารางที่ 6

ตารางที่ 4 ตารางแสดงค่าเบี่ยงเบนและค่าสัมประสิทธิ์เพ็ทอมินิต

Annual Bias					R-Square			
	HADcm3	ECHAM5	BCM2.0	CGCM	HADcm3	ECHAM5	BCM2.0	CGCM
เชียงใหม่	0.962	0.943	1.002	0.974	0.899	0.622	0.627	0.724
ภูเก็ต	0.989	0.909	1.027	0.863	0.566	0.584	0.592	0.535
สุโขทัย	1.105	1.087	1.050	0.924	0.649	0.615	0.598	0.664
หนองคาย	1.039	0.977	0.950	0.969	0.737	0.712	0.670	0.706
อุบลราชธานี	0.902	0.981	1.042	0.972	0.712	0.712	0.699	0.725

ตารางที่ 5 ตารางแสดงค่า RMSE รายปี

Annual Bias					Monthly Bias			
	HADcm3	ECAM50	BCM2.0	CGCM	HADcm3	ECAM50	BCM2.0	CGCM
เชียงใหม่	125.5396	207.1976	223.9161	174.8702	31.8468	61.9758	61.2182	54.5890
ภูเก็ต	358.8257	418.5276	359.0170	550.0693	100.4118	99.9998	97.2971	115.9058
สุโขทัย	252.8703	249.2301	237.0457	246.7490	65.8440	67.7455	68.7449	63.0268
หนองคาย	296.5518	315.6704	332.0203	334.6731	76.3134	79.0686	79.9494	79.9472
อุบลราชธานี	305.7092	232.7340	288.7720	254.7206	77.2199	76.8151	78.7200	74.9351

ตารางที่ 6 ตารางแสดงปริมาณน้ำฝนที่ได้จากการทำนาย (+ เพิ่มขึ้น, - ลดลง)

ปีค.ศ.	ปริมาณน้ำที่เปลี่ยนแปลง(%)				
	เชียงใหม่	หนองคาย	สุโขทัย	อุบลราชธานี	ภูเก็ต
2014-2018	- 5.22% จากอดีต	- 16.37% จากอดีต	+ 13.98% จากอดีต	- 10.71% จากอดีต	- 24.17% จากอดีต
2014-2023	- 10.79% จากอดีต	- 9.4% จากอดีต	+ 49.68% จากอดีต	- 2.44% จากอดีต	- 14.68% จากอดีต
2014-2038	- 6.95% จากอดีต	+ 0.68% จากอดีต	+ 29.07% จากอดีต	- 1.09% จากอดีต	+ 12.20% จากอดีต

สรุป

แบบจำลอง HADcm3 สามารถประเมินปริมาณน้ำฝนได้เหมาะสมที่สุดในจังหวัดเชียงใหม่ หนองคาย และภูเก็ตสำหรับในส่วนในจังหวัดสุโขทัยเหมาะสมกับแบบจำลอง BCM2.0 จังหวัดอุบลราชธานีเหมาะสมกับแบบจำลอง ECHAM5 สำหรับจุดมุ่งหมายในการทำนายระยะยาวโดยพิจารณาจากการเปลี่ยนแปลงปริมาณน้ำฝน

การเปลี่ยนแปลงของปริมาณน้ำฝนพบใน 5 ปีข้างหน้าหนองคายจะมีปริมาณน้ำฝนลดลงมากที่สุด อีก 10 ปีข้างหน้า ภูเก็ตจะมีปริมาณน้ำฝนลดลงมากที่สุด อีก 25 ปีข้างหน้า เชียงใหม่จะมีปริมาณน้ำฝนลดลงมากที่สุด ส่วนในจังหวัดสุโขทัยจะมีปริมาณน้ำฝนมากขึ้นมากที่สุดทั้งในระยะ 5 10 และ 25 ปี

กิตติกรรมประกาศ

บทความฉบับนี้จะเกิดขึ้นไม่ได้เลยหากขาดความอนุเคราะห์ด้านข้อมูลจากหน่วยงานต่างๆ อันได้แก่ กรมอุตุนิยมวิทยาและ Canada Climate and scenario data โครงการนี้ได้รับทุนสนับสนุนการวิจัยจากงบประมาณเงินรายได้ปี 2559 คณะวิศวกรรมศาสตร์ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

เอกสารอ้างอิง

- [1] Intergovernmental Panel on Climate Change, What is GCM?, Emission scenario. Cambridge University, 2000.
- [2] Colin Fyfe, Department of Computing and Information System, Learning in artificial neural network, Artificial Neural Network and Information Theory. The University of Paisley, 2000.
- [3] Daniel Graupe, *Introduction, Learning Performance Enhancement, Back Propagation*, Principle of Artificial Neural Network. World Scientific Publishing Co., 2007.
- [4] Siddi Tengelen., Nzeukou Armand, Performance of Using Cascade Forward Back Propagation Neural Networks for Estimating Rain Parameters with Rain Drop Size Distribution. *ATMOS OCEAN* 2014, 5:454-472.
- [5] Francois Rivest, *Knowledge Transfer in Neural Network: Knowledge-Base Cascade Correlation*. Thesis, Faculty of Graduate Studies and Research, School of computer Science, McGill University. 2002.
- [6] Khaled Shaban, Ayman EI-Hag, Andrei Matveev, *A cascade of artificial Neural Network*, IEEE T DIELECT EL IN (Impact Factor:1.28). 05/2009; 16(2): 516-523.
- [7] Dheeraj S. Badde, Anil k. Gupta, Vinayak K. Patki, *Cascade and Feed Forward Back propagation Artificial Neural Network Model for Precipitation of Compressive Strength of Ready Mix Concrete*, J MATH ENG SCI: ISSN 2278-1684; 1-6.
- [8] Piyatida Ruangrassamee., Arkom Khamkong., Pavisorn Chuenchum, Assessment of Precipitation simulations from CMIP5 climate Models in Thailand. The 3rd EIT International Conference on water Resource Engineering, 2015: 591-599.
- [9] Steel, R. G. D., J. H. Torrie. Principles and Procedures of Statistics, *Biometrische Zeitschrift*, 2007; vol4: 207-208.