

การพยากรณ์ปริมาณน้ำไหลเข้าอ่างเก็บน้ำโดยระบบโครงข่ายประสาทประดิษฐ์ (Reservoir Inflow Forecasting by Artificial Neural Networks)

วารวุธ วุฒิวณิชย์ สันติ ทองพำนัก นิมิต เจริญพันธ์พิพัฒน์ อารียา ฤทธิมา และ นัทพันธุ เกษมพันธ์¹

Varawoot Vudhivanich, Santi Thongpumnak, Nimit Cherdchanpipat

Areeya Rittima and Nattapan Kasempan¹

บทคัดย่อ

การศึกษานี้ได้นำโครงข่ายประสาทประดิษฐ์(Artificial Neural Networks: ANNs) มาใช้ในการพยากรณ์ปริมาณน้ำไหลเข้าอ่างเก็บน้ำรายวันของอ่างเก็บน้ำลำพระเพลิงและอ่างเก็บน้ำลำตะคอง ซึ่งอยู่ในลุ่มน้ำมูลตอนบนจังหวัดนครราชสีมา โดยใช้ข้อมูล อุตุ - อุทกวิทยารายวันซึ่งประกอบด้วย ปริมาณน้ำที่ไหลเข้าอ่างเก็บน้ำ ปริมาณน้ำท่าของสถานีเหนือน้ำ ข้อมูลฝน อุณหภูมิ ความชื้นสัมพัทธ์และความกดอากาศ เพื่อสร้างแบบจำลอง ANNs สำหรับการพยากรณ์ปริมาณน้ำไหลเข้าอ่างเก็บน้ำรายวัน ผลจากการศึกษาโดยใช้ข้อมูลรายวันระหว่างปี ค.ศ. 1987–2000 สำหรับอ่างเก็บน้ำลำตะคอง และปี ค.ศ. 1992–2000 สำหรับอ่างเก็บน้ำลำพระเพลิง พบว่าตัวแปรนำเข้าของ ANNs ซึ่งประกอบด้วยข้อมูลอุตุ - อุทกวิทยา ให้ผลการพยากรณ์ในการฝึกอบรมและการทดสอบแบบจำลอง แม่นยำกว่าการใช้ข้อมูลน้ำฝนและน้ำท่าเป็นตัวแปรนำเข้าเพียงอย่างเดียว โดยแบบจำลองที่เหมาะสมสำหรับอ่างเก็บน้ำลำตะคองคือ 10-63-1 และแบบจำลองที่เหมาะสมของอ่างเก็บน้ำลำพระเพลิง คือ 15-17-17-17-1 โดยมีค่า R^2 เท่ากับ 0.90 ของการฝึกฝนแบบจำลองของทั้งสองอ่างเก็บน้ำ ในขณะที่ค่า R^2 ของการทดสอบแบบจำลองโดยใช้ข้อมูลช่วงปี 1999–2000 มีค่าเท่ากับ 0.55 และ 0.72 สำหรับอ่างเก็บน้ำลำตะคองและอ่างเก็บน้ำลำพระเพลิงตามลำดับ

ABSTRACT

This study applied the artificial neural networks(ANNs) for daily reservoir inflow forecasting of Lam Takong and Lam Phra Ploeng reservoirs in the Upper Mun basin, Nakhon Ratchasima province. The daily meteo-hydrological data including the reservoir inflow, runoff from the upstream gages, rainfall, temperature, relative humidity and air pressure in the vicinity area of the reservoirs were used to develop the ANNs models for daily reservoir inflow forecasting. The daily data between 1987-2000 and 1992-2000 were used in the study for Lam Takong and Lam Phra Ploeng Reservoirs respectively. The result showed that the models that used both the meteorological data and the hydrological data as the input variables gave better forecast than the models that used only rainfall-runoff data. The best model for Lam Takong and Lam Phra Ploeng Reservoirs were 10-63-1 and 15-17-17-17-1 respectively. The R^2 for training of both reservoirs were 0.90. The R^2 for testing using the data of 1999-2000 were 0.55 and 0.72 for Lam Takong and Lam Phra Ploeng Reservoirs respectively.

Keyword: artificial neural networks, inflow forecasting, Lam Takong, Lam Phra Ploeng


email-address: fengvww@ku.ac.th

¹ภาควิชาวิศวกรรมชลประทาน คณะวิศวกรรมศาสตร์ กำแพงแสน มหาวิทยาลัยเกษตรศาสตร์ นครปฐม 73140

คำนำ

การพยากรณ์ปริมาณน้ำที่ไหลลงอ่างเก็บน้ำจะทำให้ทราบถึงปริมาณน้ำต้นทุนในอนาคตเพื่อการวางแผนจัดการอ่างเก็บน้ำ หากการพยากรณ์ปริมาณน้ำไหลลงอ่างเก็บน้ำมีความแม่นยำจะทำให้ลดปัญหาการขาดแคลนน้ำในฤดูแล้งและป้องกันอุทกภัยในช่วงฤดูฝนได้ ในทางตรงกันข้ามหากการพยากรณ์ปริมาณน้ำไหลลงอ่างเก็บน้ำผิดพลาด ก็จะนำมาซึ่งการขาดแคลนน้ำในฤดูแล้ง และเกิดอุทกภัยในฤดูฝน ส่งผลเสียหายต่อชีวิตและทรัพย์สิน เศรษฐกิจ สังคมอย่างมหาศาล และยังส่งผลกระทบต่อความมั่นคงของประเทศโดยรวมอีกด้วย

อ่างเก็บน้ำลำตะคองมีความจุ 323 ล้านลูกบาศก์เมตร และอ่างเก็บน้ำลำพระเพลิงมีความจุ 110 ล้านลูกบาศก์เมตร พื้นที่ลุ่มน้ำ 1,430 และ 807 ตารางกิโลเมตร ตามลำดับ อ่างเก็บน้ำทั้งสองตั้งอยู่ในเขตจังหวัดนครราชสีมาซึ่งเป็นส่วนหนึ่งของลุ่มน้ำมูลตอนบน ปริมาณน้ำฝนรายปีแปรผันระหว่าง 1,000-1,300 มิลลิเมตร ปริมาณน้ำท่าเฉลี่ย 381.23 ล้านลูกบาศก์เมตร/ปี พื้นที่ศึกษาแสดงในภาพที่ 1




ภาพที่ 1 พื้นที่ศึกษา

ระบบโครงข่ายประสาทประดิษฐ์(ANNs)

ANNs เป็นเทคนิคที่ได้รับความนิยมมาก เพราะอาศัยเพียงการเรียนรู้จากข้อมูลในอดีตก็สามารถให้ผลการคาดการณ์ในอนาคตได้ต่างจากแบบจำลองทางอุทกวิทยาอื่นๆซึ่งต้องใช้ข้อมูลหลากหลายในการป้อนแบบจำลอง ที่ผ่านมามีการนำโครงข่ายประสาทประดิษฐ์(ANNs)มาใช้อย่างแพร่หลายในการประมาณค่าหรือการพยากรณ์ทางวิศวกรรมชลประทานและอุทกวิทยาแหล่งน้ำ ซึ่งให้ผลเป็นที่น่าพอใจ(ทรงศักดิ์ และ วราวุธ (2546); Neelakantan and Pundarikanthan(2000); Thirumalaiah and Deo(1998); Karunanithi *et al.*(1994))

โครงข่ายประสาทประดิษฐ์ คือ แบบอย่างกระบวนการบริหารข้อมูลอันยอดเยี่ยม โดยใช้หลักการของระบบประสาทในสมองของมนุษย์ หัวใจหลักของระบบนี้คือระบบการประมวลผลข้อมูล ประกอบไปด้วยกลุ่มเซลล์ประสาทที่ทำงานร่วมกันอย่างพร้อมเพรียง เพื่อแก้ปัญหาเฉพาะด้าน โดยมีความสามารถคล้ายกับคนคือเรียนรู้จากตัวอย่างได้ ซึ่งถูกค้นพบและพัฒนาครั้งแรก โดย McCulloch และ Pitts ในปี ค.ศ. 1943 (Veelenturf,1995) ปัจจุบันมีการใช้งานซอฟต์แวร์ช่วยในการวิเคราะห์โดย ANNs อย่างแพร่หลาย(วราวุธ และ อารยะ, 2545) การเปรียบเทียบเซลล์ประสาทจริงกับเซลล์ประสาทประดิษฐ์แสดงในภาพที่ 2




ภาพที่ 2 การเปรียบเทียบเซลล์ประสาทจริงกับเซลล์ประสาทประดิษฐ์

ก่อนที่ ANNs จะจดจำหรือทำงานได้ ต้องมีขั้นตอนในการสอนหรือฝึกฝน(Training)ก่อน ซึ่ง ANNs ที่จะนำมาใช้งานได้นั้นต้องมีค่าน้ำหนักที่เหมาะสม ดังนั้นกระบวนการเรียนรู้ ก็คือ กระบวนการปรับค่าน้ำหนัก (weight) ในการส่งผ่านระหว่างเซลล์ประสาทของANNsให้เหมาะสมกับงานที่ต้องการนั่นเอง ในการศึกษานี้จะใช้การเรียนรู้ของ ANNs แบบมีครูสอน โดยใช้การเรียนรู้แบบย้อนกลับ (Backpropagation Algorithm: BP)ซึ่งเป็นที่นิยมใช้กันโดยทั่วไป(ทรงศักดิ์ และ วราวุธ(2546); ASCE Task Committee (2000b),Tokar and Markus(2000); Toth *et al.*(2000); Campolo *et al.*(1999))ซึ่งหลักการทำงานของ BP เป็นการเรียนรู้จากชุดฝึกสอน เพื่อหาค่าน้ำหนัก(weight) ที่เหมาะสม จากนั้นนำผลที่ได้จากแบบจำลองมาเปรียบเทียบกับค่าเป้าหมาย หากผลที่ได้ยังไม่ดี ก็จะนำค่าผิดพลาดที่เกิดขึ้นย้อนกลับไปปรับแก้แบบจำลองอีกครั้ง จนกว่าผลที่ได้จากแบบจำลองจะมีค่าใกล้เคียงกับค่าเป้าหมาย

การเรียนรู้แบบย้อนกลับ(BP) มีรูปแบบง่าย ๆ ซึ่งประกอบด้วยชั้นต่างๆ อย่างน้อย 3 ชั้น ดังภาพที่ 3 ซึ่งในแต่ละชั้นแบ่งออกเป็น

1. ชั้นข้อมูลเข้า(Input Layer) ทำหน้าที่รับข้อมูลเข้าจะมีเพียง 1 ชั้น
2. ชั้นซ่อนหรือชั้นแอบแฝง(Hidden Layer) ทำหน้าที่รับข้อมูลเข้ามาทำการประมวลผลข้อมูลมีอย่างน้อย 1 ชั้น
3. ชั้นผลลัพธ์(Output Layer) ทำหน้าที่รับข้อมูลที่ได้จากการประมวลผลแล้ว จากชั้นข้อมูลสุดท้ายของชั้นซ่อน มีเพียง 1 ชั้น

สำหรับรายละเอียดและขั้นตอนการเรียนรู้ของ ANNs แบบ BP ดูเพิ่มเติมได้จาก ASCE Task Committee(2000a)



ภาพที่ 3 ตัวอย่างแบบจำลองโครงข่ายประสาทประดิษฐ์

อุปกรณ์และวิธีการ

1. ศึกษาความสัมพันธ์ของปริมาณน้ำไหลเข้าอ่างเก็บน้ำ กับข้อมูลฝน รวมทั้งข้อมูลน้ำท่าจากสถานีใกล้เคียงอ่างเก็บน้ำ และข้อมูลทางอุตุนิยมวิทยาอื่นๆ ได้แก่ อุณหภูมิ ความชื้นสัมพัทธ์และความกดอากาศ โดยใช้ข้อมูลรายวันในการฝึกฝนช่วงปี ค.ศ. 1987- 1998 และ ปี ค.ศ. 1992 – 1998 สำหรับอ่างเก็บน้ำลำตะคอง และอ่างเก็บน้ำลำพระเพลิงตามลำดับ
2. กำหนดฟังก์ชันการพยากรณ์ปริมาณน้ำที่ไหลเข้าอ่างจากอนุกรมน้ำฝนน้ำท่า ข้อมูลทางอุตุนิยมวิทยา และจากแมทริกซ์ของค่าสัมประสิทธิ์สหสัมพันธ์ (Correlation Matrix)

3. ออกแบบและทำการฝึกอบรมแบบจำลองโครงข่ายประสาทประดิษฐ์(ANNs) สำหรับการพยากรณ์ปริมาณน้ำที่ไหลเข้าอ่างเก็บน้ำ โดยในการออกแบบ ANNs จะใช้ตัวแปรนำเข้าที่แตกต่างกันจำนวน 3 แบบจำลอง เพื่อหาโครงข่ายที่เหมาะสม ในแต่ละอ่างเก็บน้ำ โดยแบบจำลองแรกใช้ตัวแปรนำเข้าคือ ข้อมูลอุตุ-อุตุนิยมวิทยา ได้แก่ ปริมาณน้ำที่ไหลเข้าอ่างเก็บน้ำ ปริมาณน้ำท่าของสถานีเหนือน้ำ ข้อมูลฝน อุณหภูมิ ความชื้นสัมพัทธ์และความกดอากาศ แบบจำลองที่ 2 ใช้ตัวแปรนำเข้าคือ ปริมาณน้ำที่ไหลเข้าอ่างเก็บน้ำและปริมาณน้ำท่า ซึ่งพิจารณาจากการศึกษาสัมประสิทธิ์สหสัมพันธ์ในตัวเองของอนุกรม(Autocorrelation Coefficient) สำหรับแบบจำลองที่ 3 ใช้ตัวแปรนำเข้าคือปริมาณน้ำที่ไหลเข้าอ่างเก็บน้ำกับปริมาณน้ำฝนโดยพิจารณาจากการศึกษาสัมประสิทธิ์สหสัมพันธ์ในตัวเองของอนุกรม เช่นเดียวกับแบบจำลองที่ 2 แบบจำลองที่ใช้ในการศึกษาแสดงในตารางที่ 1

ตารางที่ 1 แบบจำลองที่ใช้ในการศึกษาการพยากรณ์ปริมาณน้ำไหลเข้าอ่างเก็บน้ำลำตะคองและลำพระเพลิง

Reservoir	Model	forecasting function
Lam	1	$ILK(t+1) = f \{ ILK(t), M89(t), R25272(t), R25612(t), R25644(t), R25650(t), MinRH431301(t), MaxRH431301(t), MinT431301(t), MaxT431301(t) \}$
	2	$ILK(t+1) = f \{ ILK(t), M89(t-3), M89(t-2), M89(t-1), M89(t) \}$
Takong	3	$ILK(t+1) = f \{ ILK(t), M89(t), R25272(t-3), R25272(t-2), R25272(t-1), R25272(t) \}$
	1	$ILP(t+1) = f \{ ILP(t), M145(t), R25152(t), R25511(t), R25751(t), R25781(t), MeanRH431201(t), MaxT431201(t), MeanT431201(t), MaxT431201(t), Press431201(t), MeanRH431401(t), MaxT431401(t), MeanT431401(t), MaxT431401(t) \}$
Phra	2	$ILP(t+1) = f \{ M145(t), ILP(t-3), ILP(t-2), ILP(t-1), ILP(t) \}$
	3	$ILP(t+1) = f \{ ILP(t), M145(t), R25511(t-3), R25511(t-2), R25511(t-1), R25511(t) \}$
Ploeng	1	
	2	

ตัวอย่างการเรียกชื่อข้อมูล เช่น ILK(t) คือ ปริมาณน้ำไหลเข้าอ่างเก็บน้ำลำตะคอง ณ เวลา t, M89(t) คือ ปริมาณน้ำท่าที่สถานี M.89 ณ เวลา t, R25272(t) คือ ปริมาณฝนที่สถานี 25272 ณ เวลา t, MinRH431301(t) คือ ความชื้นสัมพัทธ์ต่ำสุดที่สถานี 431301 ณ เวลา t, MeanT431401(t) คือ อุณหภูมิเฉลี่ยที่สถานี 431401 ณ เวลา t, Press431201(t) คือ ความกดอากาศที่สถานี 431201 ณ เวลา t

4. ทดสอบการพยากรณ์โดยใช้ค่า R^2 หรือ Nash Efficiency (Nash and Sutcliffe, 1970)

$$EI = R^2 = (SST - SSE) / SST \quad (1)$$

$$SST = \sum_{i=1}^N (Y_i - \bar{Y})^2 \quad (2)$$

$$SSE = \sum_{i=1}^N (Y_i - \hat{Y}_i)^2 \quad (3)$$

เมื่อ Y_i คือ ปริมาณน้ำไหลเข้าอ่างเก็บน้ำในวันที่ i
 $\hat{Y}_i$ คือ ค่าประมาณของปริมาณน้ำไหลเข้าอ่างเก็บน้ำ วันที่ i จากแบบจำลอง
 $\bar{Y}$ คือ ค่าเฉลี่ย

ในการทดสอบแบบจำลองใช้ข้อมูลรายวันจาก มกราคม ปี ค.ศ.1999 ถึง มีนาคม ปี ค.ศ.2000

ผลและวิจารณ์


จากการศึกษาพบว่าแบบจำลอง ANNs ที่ให้ผลการพยากรณ์ปริมาณน้ำไหลเข้าอ่างเก็บน้ำรายวันที่ดีที่สุด ทั้งสองอ่างเก็บน้ำคือ แบบจำลองที่ 1 ซึ่งใช้ข้อมูลอุตุ-อุทกวิทยา ได้แก่ข้อมูลอุตุ-อุทกวิทยา ได้แก่ ปริมาณน้ำที่ไหลเข้าอ่างเก็บน้ำ ปริมาณน้ำท่าของสถานีเหนือน้ำ ข้อมูลฝน อุณหภูมิ ความชื้นสัมพัทธ์และความกดอากาศ เป็นตัวแปรนำเข้า โดยอ่างเก็บน้ำลำตะคอง ได้ค่า $R^2 = 0.90$ และ 0.55 ในการฝึกฝนและทดสอบแบบจำลองตามลำดับ ส่วนอ่างเก็บน้ำลำพระเพลิง ได้ค่า Nash Eff. = 0.90 และ 0.72 ในการฝึกฝนและทดสอบแบบจำลองตามลำดับ ดังตารางที่ 2 และ 3 ซึ่งในส่วนของโครงสร้าง ANNs นั้นพบว่าจำนวนชั้นซ่อน (Hidden Layer) ที่เหมาะสมในแต่ละแบบจำลองจะอยู่ระหว่าง 1 – 3 ชั้นโดยจำนวน Hidden Node และ Hidden Layer จะแปรผันกับจำนวนและความซับซ้อนของข้อมูล ซึ่งในที่นี้ใช้ข้อมูลเพื่อการฝึกฝนแบบจำลองจำนวน 4,202 และ 2,375 ค่า สำหรับอ่างเก็บน้ำลำตะคองและอ่างเก็บน้ำลำพระเพลิงตามลำดับ จึงทำให้แบบจำลองมีขนาดใหญ่ ค่าพารามิเตอร์ Momentum และ Learning Rate นั้นมีผลน้อยมากในด้านความแม่นยำในการพยากรณ์ของแบบจำลองแต่การปรับให้พารามิเตอร์ดังกล่าวมีค่าสูงจะช่วยให้แบบจำลองเรียนรู้ได้รวดเร็วขึ้น เมื่อพิจารณาจากกราฟปริมาณน้ำที่ไหลเข้าอ่างเก็บน้ำในภาพที่ 4 และ 5 ซึ่งเป็นการทดสอบแบบจำลอง พบว่าลักษณะกราฟปริมาณน้ำที่ไหลเข้าอ่างเก็บน้ำจากแบบจำลอง ANNs ใกล้เคียงกับกราฟปริมาณน้ำที่ไหลเข้าอ่างเก็บน้ำ ที่ได้จากการวัดจริง

ตารางที่ 2 ผลการฝึกฝนและทดสอบ ANNs ของอ่างเก็บน้ำลำตะคอง


Model	Parameters			ANNs Structure	R^2	
	Lear. Rate	Momentum	Initial Weight		Training	Testing
1	0.9	0.9	0.9	10-63-1	0.90	0.55
2	0.9	0.9	0.9	5-20-20-20-1	0.85	0.50
3	0.9	0.9	0.9	6-20-20-20-1	0.82	0.51

ตารางที่ 3 ผลการฝึกฝนและทดสอบ ANNs ของอ่างเก็บน้ำลำพระเพลิง

Model	Parameters			ANNs Structure	R^2	
	Lear. Rate	Momentum	Initial Weight		Training	Testing
1	0.8	0.8	0.8	15-17-17-17-1	0.90	0.72
2	0.8	0.8	0.8	5-15-15-15-1	0.82	0.57
3	0.8	0.8	0.8	6-16-16-16-1	0.87	0.51



ภาพที่ 4 เปรียบเทียบปริมาณน้ำที่ไหลเข้าอ่างเก็บน้ำลำตะคอง
จาก ANNs กับค่าที่วัดได้จริงในขั้นตอนการทดสอบแบบจำลอง



ภาพที่ 5 เปรียบเทียบปริมาณน้ำที่ไหลเข้าอ่างเก็บน้ำลำพระเพลิง
จาก ANNs กับค่าที่วัดได้จริงในขั้นตอนการทดสอบแบบจำลอง

สรุปผลการศึกษา

โครงสร้างแบบจำลอง ANNs ในการพยากรณ์ปริมาณน้ำไหลเข้าอ่างเก็บน้ำรายวันจะแปรเปลี่ยนไปตามลักษณะและจำนวนของชุดฝึกสอน ซึ่งหากชุดฝึกสอนมีจำนวนมากก็ต้องใช้โครงสร้าง ANNs ที่ซับซ้อนขึ้น รวมถึงเวลาที่ใช้ในการฝึกฝนมากขึ้นด้วย ทั้งนี้โครงสร้างของแบบจำลองที่ดีที่สุดในแต่ละพื้นที่จะแตกต่างกันไป ผลการศึกษาพบว่าโครงสร้าง ANNs ที่ดีที่สุดสำหรับอ่างเก็บน้ำลำตะคองคือ 10-63-1 ในขณะที่โครงสร้าง ANNs ที่ดีที่สุดสำหรับอ่างเก็บน้ำลำพระเพลิงคือ 15-17-17-17-1 ดังนั้นจึงต้องมีการทดลองเพื่อหาโครงข่ายที่ดีที่สุดสำหรับนำไปใช้งาน

ปริมาณน้ำไหลเข้าอ่างเก็บน้ำรายวันมีความผันแปรสูง ยากที่จะพยากรณ์อย่างแม่นยำได้ แต่ผลที่ได้จากการพยากรณ์โดย ANNs มีความแม่นยำอยู่ในเกณฑ์ที่น่าพอใจ สามารถนำไปใช้ในการพยากรณ์ปริมาณน้ำไหลเข้าอ่างเก็บน้ำเพื่อใช้ในการวางแผนและบริหารจัดการอ่างเก็บน้ำให้เกิดประโยชน์สูงสุดได้

เอกสารอ้างอิง

ทรงศักดิ์ ภัทราวุธมิตชัย และ วราวุธ วุฒิวิณิชย์. 2546. การพยากรณ์สภาพน้ำท่าในลุ่มน้ำลำภาชีโดยระบบโครงข่ายประสาทประดิษฐ์. น. 480-489. ใน **การประชุมทางวิชาการของมหาวิทยาลัยเกษตรศาสตร์ ครั้งที่ 41 (สาขาวิศวกรรมศาสตร์และสถาปัตยกรรมศาสตร์)**.มหาวิทยาลัยเกษตรศาสตร์, กรุงเทพฯ.

วราวุธ วุฒิวิณิชย์ และ อารยะ เหล่าสุวรรณ. 2545. Artificial Neural Networks Software. **ชลกรฉบับ**

วันชชาติ. สมาคมศิษย์เก่าวิศวกรรมชลประทานในพระบรมราชูปถัมภ์, กรุงเทพฯ. น.42-57.

ASCE Task Committee. 2000a. Artificial neural networks in hydrology I:preliminary concepts.

J. Hydrologic Engrg. 5(2): 115-123.

ASCE Task Committee. 2000b. Artificial neural networks in hydrology II:hydrologic applications.

J. Hydrologic Engrg. 5(2): 124-137.

Campolo,M., P.Andreussi and A. Soldati. 1999. River flood forecasting with neural model. **Water Resour. Res.** 35: 1191-1197.

Karunanithi,N., E.J. Grenney, D. Whitley and K. Bovee. 1994. Neural networks for river flow prediction.

J. Comp. in Civ. Engrg. 8(2): 201-220.

Nash,J.E. and J.V. Sutcliffe. 1970. River flow forecasting through conceptual model, part I:

a discussion of principles, **J. Hydrol.** 10(3): 282-290.

Neelakantan, T.R. and N.V. Pundarikanthan. 2000. neural network-based simulation-optimization model for reservoir operation. **J. Water Res. Plng. And Mgmt.** 126(2): 57-64.

Thirumalaiah, K., and M.C. Deo. 1998. Riverstage forecasting using artificial neural networks.

J. Hydrologic Engrg. 3(1): 26-32.

Tokar, A.S. and M. Markus. 2000. Precipitation-Runoff Modeling Using Artificial Neural Networks and Conceptual Models. **J. Hydrologic Engrg.** 5(2): 156-161.

Toth,E., Brath, A. and A. Montanari. 2000. Comparison of short-term rainfall prediction models for real-time. **J. Hydrol.** 239(2000): 132-147.

Veelenturf, L.P.J. 1995. **Analysis and Applications of Artificial Neural Networks**. Prentice Hall International(UK) Ltd., Hertfordshire.

