



## บทที่ 2

### การศึกษาที่ผ่านมา

การศึกษานี้ได้ทบทวนผลการศึกษาที่ผ่านมาที่เกี่ยวข้องกับการศึกษานี้ โดยแบ่งออกเป็นการศึกษาใน 4 หัวข้อ คือ 1) การพัฒนาและประยุกต์ใช้ BPNN ในงานอุทกวิทยา 2) การพัฒนาวิธีการเรียนรู้ในแบบจำลอง ANN 3) การประยุกต์ใช้ GA ในด้านวิศวกรรมแหล่งน้ำ และ 4) การประยุกต์ใช้ GA ร่วมกับ ANN

#### 2.1 การพัฒนาและประยุกต์ใช้ BPNN ในงานอุทกวิทยา

ถึงแม้ว่าแบบจำลอง BPNN จะถูกนำมาใช้ในงานด้านวิศวกรรมแหล่งน้ำมานานมาก แต่จากการรวบรวมบทความวิจัยพบว่า ปัจจุบันยังมีงานวิจัยเกี่ยวกับแบบจำลอง BPNN ในด้านวิศวกรรมแหล่งน้ำอย่างต่อเนื่องจนถึงปัจจุบัน ดังนี้

Carriere (1996) ได้สร้างชลภาพน้ำท่า ด้วยแบบจำลอง BPNN ที่มีวิธีการแปลงค่าข้อมูลในขั้นนำเข้าแบบ Bipolar และ ซิกมอยด์ฟังก์ชันในชั้นแอบแฝงและชั้นผลลัพธ์ พบว่า ให้ผลการจำลองชลภาพน้ำท่าที่มีความถูกต้องสูง

Hall (1996) ได้ศึกษาอิทธิพลของช่วงพิสัยของค่าข้อมูลไว้หน่วยของ BPNN ในการพยากรณ์น้ำท่า พบว่า การพยากรณ์ข้อมูลที่มีขนาดมากกว่าช่วงพิสัยของค่าไว้หน่วยของข้อมูลในการเรียนรู้ BPNN ให้การพยากรณ์ที่ไม่ดี

Furundzic (1998) ได้ประยุกต์ใช้แบบจำลองโครงข่ายใยประสาทเทียมแบบ Self Organizing Map (SOM) เพื่อแบ่งกลุ่มของข้อมูลนำเข้าออกเป็น 3 กลุ่มและจัดสร้างแบบจำลองโครงข่ายใยประสาทเทียมแบบ MLP 3 แบบจำลองตามกลุ่มข้อมูลที่ได้จากแบบจำลอง SOM เทียบกับวิธี Stepwise Regression พบว่า BPNN ให้ผลการพยากรณ์ที่มีความถูกต้องมากกว่า

Dibike และ Solomatine (1999) ได้เปรียบเทียบผลการพยากรณ์น้ำท่าจากโครงข่ายใยประสาทเทียมที่มีโครงสร้างในการเรียนรู้ที่แตกต่างกัน 2 รูปแบบ คือ BPNN และ Radial Basis Function (RBF) พบว่า BPNN ให้ผลการพยากรณ์ที่มีความถูกต้องมากกว่า RBF ทั้งในช่วงการเรียนรู้และทดสอบ แต่ BPNN ใช้เวลาเรียนรู้ที่นานกว่า RBF

Tokar และคณะ (1999) ได้สร้างแบบจำลองพยากรณ์น้ำท่ารายวันในลุ่มน้ำ Little Pratum รัฐแมริแลนด์ ประเทศสหรัฐอเมริกา ด้วยแบบจำลอง BPNN เพื่อศึกษาข้อมูลนำเข้าที่มีนัยสำคัญ ช่วงข้อมูลที่เหมาะสมในการเรียนรู้ และจำนวนข้อมูลที่ใช้เรียนรู้ ของ BPNN พบว่าข้อมูลที่มีผลต่อการพยากรณ์น้ำท่า คือ ข้อมูลน้ำท่า ข้อมูลฝนและอุณหภูมิ โดยการเลือกใช้ข้อมูลในปีฝนมากให้ผลการเรียนรู้ที่ดีกว่า เพราะครอบคลุมเหตุการณ์หลายเหตุการณ์ และผลของจำนวนชุดข้อมูลที่ใช้เรียนรู้ไม่มีผลต่อการพยากรณ์มากนัก ถึงอย่างไรก็ตาม ยังได้เสนอว่าโครงข่าย BPNN ที่มีขนาดใหญ่ควรมีจำนวนชุดข้อมูลในการเรียนรู้ที่มากขึ้นตามไปด้วย และได้มีการเปรียบเทียบผลการพยากรณ์กับแบบจำลองทางสถิติและแบบจำลองเชิงความคิด พบว่า BPNN ใช้เวลาในการเรียนรู้น้อยกว่าแบบจำลองเชิงความคิด และให้ผลการพยากรณ์ที่ดีกว่าแบบจำลองความถดถอย

Tokar และ Markus (2000) ทำการพยากรณ์น้ำท่ารายเดือนในแม่น้ำ Fraser Roccoon และ Little Patuxent ในประเทศสหรัฐอเมริกา ด้วยแบบจำลอง BPNN และแบบจำลองเชิงความคิด 3 แบบจำลอง ที่มีชื่อเรียกว่า Watbal SAC-SMA และ SCRR ตามลำดับ พบว่า BPNN ให้ผลการพยากรณ์ที่มีความถูกต้องดีกว่า แบบจำลองที่เหลือ แต่อย่างไรก็ตามผลการพยากรณ์น้ำท่าที่มีค่าต่ำ (low flow) มีค่าพยากรณ์ที่สูงกว่าค่าที่วัดจริง

Burian และคณะ (2001) ได้ศึกษาผลของการเลือกใช้ข้อมูล โครงสร้างและพารามิเตอร์ของ BPNN ในการพยากรณ์ข้อมูลฝนรายชั่วโมง พบว่า 1) ช่วงของค่าข้อมูลไร้หน่วยในชั้นนำเข้า และชั้นผลลัพธ์ที่เหมาะสมอยู่ในช่วง (0, 0.8) ช่วงค่าไร้หน่วยที่มากขึ้นทำให้ประสิทธิภาพของ BPNN ลดลง 2) ควรเลือกใช้ข้อมูลจากสถานีวัดที่อยู่ใกล้จุดพยากรณ์ทำให้ได้ผลการพยากรณ์ที่ดี 3) ความยาวของจำนวนข้อมูลในการเรียนรู้ไม่มีผลในการพัฒนาแบบจำลองมากนัก และ 4) โครงสร้างแบบจำลองที่มีขนาดเล็กให้ผลการพยากรณ์ที่ดีกว่าโครงสร้างที่มีขนาดใหญ่

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

Kitpaisalsakul และ Suttianon (2002) ได้ทำการเปรียบเทียบผลการพยากรณ์ระดับน้ำขึ้น-น้ำลง ล่วงหน้า 3 12 และ 24 ชั่วโมง ณ สถานีป้อมพระจุล ซึ่งตั้งอยู่บริเวณ BPNN จะใช้ข้อมูลระดับน้ำขึ้น-น้ำลง รายชั่วโมงย้อนหลังไป 25 ชั่วโมงเป็นข้อมูลนำเข้า ส่วนแบบจำลอง HARMONIC นั้นจะใช้ข้อมูลระดับน้ำขึ้น-น้ำลงเฉลี่ยตลอดทั้งปีเป็นข้อมูลนำเข้า จากผลการศึกษาพบว่า ผลการพยากรณ์ในระยะสั้น (3 และ 12 ชั่วโมง) จากแบบจำลอง BPNN จะมีประสิทธิภาพมากกว่าแบบจำลอง HARMONIC อย่างเห็นได้ชัด แต่ความแตกต่างของผลการพยากรณ์จากแบบจำลองทั้ง 2 นี้ จะลดลงเมื่อใช้กับการพยากรณ์ในช่วงระยะยาว (24 ชั่วโมง)

ธนพล พิमान (2545) ได้ทำการพยากรณ์น้ำท่ารายวันล่วงหน้า 1-7 วัน ณ สถานีวัดน้ำท่า 6 แห่งในพื้นที่ลุ่มน้ำปราจีนบุรี โดยจัดสร้างแบบจำลองแยกออกตามฤดูกาล คือ ฤดูฝนและฤดูแล้ง พบว่า ฟังก์ชันความสัมพันธ์ระหว่างตัวแปรต่างๆ (Correlation Function) สามารถนำมาใช้เป็นแนวทางในการคัดเลือกชุดตัวแปรเข้าแบบจำลอง ANN ได้ดี และ ในการพยากรณ์น้ำท่ารายวันล่วงหน้าควรใช้แบบจำลอง ANN ร่วมกับการพยากรณ์โดยวิธี Standard Step

Kneale, See และ Smith (2002) ได้ทำการพยากรณ์ระดับน้ำในแม่น้ำ Tyne ล่วงหน้า 2-6 ชั่วโมง ด้วยแบบจำลอง BPNN และ Time Delay Neural Network (TDNN) จากการเปรียบเทียบด้วยค่าความถูกต้องทางสถิติ 9 วิธี พบว่า TDNN ให้ผลการพยากรณ์ที่ดีกว่า

Jain และ Indurthy (2003) ได้พัฒนาแบบจำลองเพื่อพยากรณ์การเกิดน้ำท่าแบบรายเหตุการณ์ (Event-based) ในลุ่มน้ำ Salado Creek ที่มีขนาดพื้นที่รับน้ำ 63,232 ตร.กม. ด้วยวิธีการสร้างแบบจำลองน้ำฝน-น้ำท่า 3 วิธี รวม 8 แบบจำลอง ประกอบด้วย 1) วิธีชลภาพน้ำท่าหนึ่งหน่วย (Unit Hydrograph) 2 แบบจำลอง 2) วิธีวิเคราะห์ความถดถอย จำนวน 4 แบบจำลอง และ 3) แบบจำลอง BPNN 2 แบบจำลอง ที่มีจำนวนชั้นแอบแฝง 1 และ 2 ชั้น ผลการศึกษาพบว่า แบบจำลอง BPNN ให้ความถูกต้องในการพยากรณ์ที่ดีกว่าแบบจำลองอื่นๆ

Jain , Singh และ Van Genuchten (2004) ได้สร้างแบบจำลองความสัมพันธ์ของ Water Retention Curve หรือ WRC ด้วยแบบจำลอง BPNN กับแบบจำลองที่นิยมใช้ทั่วไป ได้แก่ Brooks และ Corey (1964) , Van Genuchten (1980) และ Assouline et al (1998) ในดินชนิดต่างๆ มาเปรียบเทียบกัน พบว่า แบบจำลอง BPNN ให้ผลที่ดีกว่าวิธีการของ Assouline et al และให้ผลที่ใกล้เคียงกับวิธีที่เหลือ และได้นำแบบจำลอง BPNN สร้างแบบจำลองความสัมพันธ์ของ Suction Head และ Moisture Content ในฤดูฝนและฤดูแล้ง ซึ่งพบว่า แบบจำลอง BPNN ให้ความถูกต้องในการพยากรณ์ที่มีค่าใกล้เคียงไม่มีดี

Huang, Xu และ Chan-Hilton (2004) ได้สร้างแบบจำลองพยากรณ์น้ำท่าในแม่น้ำ Apalachicola รายวัน รายเดือน รายสามเดือน และรายปี ด้วยแบบจำลอง ANN ที่มีวิธีการเรียนรู้ที่แตกต่างกัน 4 วิธี ได้แก่ BP (BPNN), Conjugated Gradient (CG), Levenberg-Marquardt (LM) และ Scaled Conjugate Gradient (SCG) เปรียบเทียบกัน พบว่า โครงข่ายใยประสาทเทียมที่มีวิธีการเรียนรู้แบบ LM ให้ผลการพยากรณ์ที่ดีที่สุด โดยให้ค่า R ในการพยากรณ์น้ำท่ารายวัน รายเดือน รายสามเดือน และรายปี เท่ากับ 0.98, 0.95, 0.91 และ 0.83 ตามลำดับ

Ozgun (2004) ได้สร้างแบบจำลองพยากรณ์น้ำท่ารายเดือน ณ สถานีวัดน้ำ Isakoy ที่ตั้งอยู่ในแม่น้ำ Goksudere ประเทศตุรกี ด้วยแบบจำลอง BPNN และ แบบจำลอง Auto-Regressive (AR) พบว่า BPNN ให้ผลการพยากรณ์ที่มีความถูกต้องมากกว่า AR โดยให้ค่าผลรวมของค่าความผิดพลาดยกกำลังสองที่น้อยกว่า และให้ค่า ส.ป.ส. สหสัมพันธ์ที่สูงกว่า นอกจากนี้ ผลการพยากรณ์จาก BPNN กับช่วงข้อมูลน้ำท่าวัดจริงที่มากกว่า 30 ลบ.ม./วิ ซึ่งมีจำนวน 20 เหตุการณ์ พบว่า BPNN ให้ค่าพยากรณ์ที่ต่ำกว่าค่าที่วัดจริง 0.2-74 เปอร์เซ็นต์

Caulibaly, Hache, Fortin และ Bobee (2005) ได้พยากรณ์น้ำท่ารายวันล่วงหน้า 1-4 วัน ในพื้นที่ลุ่มน้ำ Kipawa และ Matawin ซึ่งมีพื้นที่ 5,960 และ 4,118 ตร.กม. ตั้งอยู่ในรัฐควิเบค ประเทศแคนาดา ด้วยวิธี Weight-Average Method (WAM) ซึ่งได้นำผลการพยากรณ์น้ำท่าจากแบบจำลองทางกายภาพ ชื่อว่า HSAMI จากแบบจำลองทางสถิติ ชื่อว่า Nearest-Neighbor Model (NNM) และจากแบบจำลอง BPNN มารวมกันและแปลงเป็นผลการพยากรณ์ด้วยวิธีหาค่าถ่วงน้ำหนักเฉลี่ยของผลลัพธ์จาก 3 แบบจำลอง พบว่า ผลการพยากรณ์จากวิธี WAM ให้ความถูกต้องที่ดีกว่าผลการพยากรณ์ที่ได้จากแบบจำลอง HSAMI, NNM และ BPNN

Jy และ Shastri (2005) ได้พัฒนาแบบจำลอง BPNN เพื่อพยากรณ์น้ำท่าในแม่น้ำ North Buffalo Creek ที่สถานีเหนือน้ำล่วงหน้า 15 นาที ถึง 60 นาทีและสถานีท้ายน้ำ 2 สถานี ล่วงหน้า 1 และ 3 ชม. ตามลำดับ โดยใช้ข้อมูลฝนและน้ำท่าราย 15 นาที พบว่า ผลการพยากรณ์ที่สถานีเหนือน้ำให้ผลที่ดี ขณะที่ผลการพยากรณ์ ณ สถานีท้ายน้ำ 2 สถานีพบว่า สถานีที่อยู่ใกล้กับสถานีเหนือน้ำมากกว่ามีความถูกต้องมากกว่าสถานีที่อยู่ไกลจากสถานีเหนือน้ำมากกว่า

## 2.2 การพัฒนาวิธีการเรียนรู้ในแบบจำลอง ANN

นอกจากแบบจำลอง BPNN ซึ่งใช้กระบวนการเรียนรู้แบบย้อนกลับเพื่อหาค่าถ่วงน้ำหนักของแบบจำลองโครงข่ายใยประสาทเทียมที่มีโครงข่ายหลายชั้นนิยมใช้กันมากแล้ว ยังได้มีบทความวิจัยอีกส่วนหนึ่งได้วิจัยการใช้วิธีการเรียนรู้ในแบบต่างๆ มาใช้แทนที่การเรียนรู้แบบ

ย้อนกลับ บางงานวิจัยได้ทำการเปรียบเทียบวิธีการเรียนรู้แบบต่างๆ กับแบบจำลอง BPNN ไว้ ซึ่งสามารถสรุปได้ดังนี้

Fahlman และคณะ (1991) ได้เสนอวิธี Cascade-Correlation (CC) เป็นวิธีใช้ในการเรียนรู้และคัดเลือกโครงสร้างที่เหมาะสมสำหรับโครงข่ายประสาทเทียม โดยเริ่มต้นจากโครงสร้างที่น้อยสุด หลังจากนั้นทำการเรียนรู้โดยอัตโนมัติ และเพิ่มจำนวนโหนดในชั้นแอบแฝงทีละโหนด จนได้โครงข่ายประสาทเทียมที่ดีที่สุด พบว่า วิธี CC ใช้เวลาในการเรียนรู้เร็วกว่า BPNN

Riedmiller และคณะ (1993) ได้เสนอวิธีการเรียนรู้สำหรับโครงข่ายประสาทเทียม ที่เรียกว่า Resilient Back Propagation (RPROP) ซึ่งได้ทำการปรับค่าถ่วงน้ำหนัก ในช่วงการเรียนรู้ (training) ตามค่าของความผิดพลาดของฟังก์ชัน เพื่อเป็นการกำจัดข้อเสียของวิธี BP พบว่าวิธี RPROP ลู่เข้าสู่คำตอบเร็วกว่าวิธี BP ประมาณ 4 เท่า และเร็วกว่าวิธี Quickprop ประมาณ 1.5 เท่า

Karunithi และคณะ (1994) ได้ใช้วิธีการเรียนรู้แบบ CC มาใช้ในโครงข่ายประสาทเทียม และแบบจำลอง Power Law มาใช้พยากรณ์อัตราการไหลในแม่น้ำ Huron จากข้อมูลอัตราการไหลของสถานีที่อยู่เหนือน้ำขึ้นไป 30 กม. และอยู่ถัดไปท้ายน้ำ 20 กม. พบว่า ในการพยากรณ์ข้อมูลที่มีอัตราการไหลสูง ANN ให้ผลการพยากรณ์ที่ดีกว่าแบบจำลอง Power Law ส่วนผลการพยากรณ์ข้อมูลอัตราการไหลที่มีค่าต่ำ แบบจำลองทั้งสองให้ผลการพยากรณ์ที่ใกล้เคียงกัน

Gupta และคณะ (1997) ได้นำวิธีการเรียนรู้ที่เรียกว่า Linear Least Squares Simplex และ Multistart Downhill Simplex Nonlinear รวมเรียกว่า LLSSIM มาเปรียบเทียบกับวิธี BP และวิธี CC มาใช้ในโครงข่ายประสาทเทียมเพื่อพยากรณ์น้ำท่ารายวันในแม่น้ำ Leaf River Beam พบว่า วิธี LLSSIM ให้ความถูกต้องในการพยากรณ์มากกว่าวิธี BP และ CC

Moller (1997) ได้ทำการเปรียบเทียบวิธีการเรียนรู้ต่างๆ 4 วิธี ได้แก่ CC BP CGL และ BGFS ในโครงข่ายประสาทเทียม พบว่า กระบวนการเรียนรู้แบบ CC เหมาะสมที่สุด และได้เสนอกระบวนการเรียนรู้แบบ Scaled Conjugate Gradient (SCG) ที่ให้ผลการคำนวณเร็วกว่า BP, CGL, BGFS

Fernando และคณะ (1998) ได้นำวิธีการเรียนรู้แบบ Orthogonal Least-Square (OLS) มาใช้ในแบบจำลองโครงข่ายประสาทเทียมที่มีโครงข่ายแบบ RBF และใช้แบบจำลอง

BPNN ในการพยากรณ์น้ำท่าล่วงหน้า 1 ชม. พบว่า แบบจำลองทั้งสองให้ความถูกต้องที่ใกล้เคียงกัน แต่วิธีการเรียนรู้แบบ OLS ใช้เวลาในการเรียนรู้น้อยกว่า BPNN

Igel และ Husken (2000) ได้ทำการปรับปรุงวิธีของ BPNN มาเป็นวิธี Resilient Back Propagation (RPROP) ซึ่งพบว่าช่วยทำให้การเรียนรู้เร็วขึ้นและผลการคำนวณดีขึ้นกว่า BPNN

Thirumalaiah และ Deo (2000) ได้เปรียบเทียบวิธีการเรียนรู้ 3 วิธีในโครงข่ายประสาทเทียม ได้แก่ Back Propagation (BP), Conjugate Gradient (CG) และ Cascade Correlation (CC) ในการพยากรณ์น้ำท่าล่วงหน้า 1-3 ชั่วโมง พยากรณ์ระดับน้ำรายวันล่วงหน้า 1-2 วัน และความแห้งแล้ง พบว่า ในการพยากรณ์น้ำท่าและระดับน้ำ วิธีการเรียนรู้แบบ CC ให้ผลดีที่สุด ขณะที่ผลการพยากรณ์ความแห้งแล้ง BP และ CG ให้ผลการคำนวณที่ใกล้เคียงกันแต่ดีกว่า CC และแบบจำลองทั้ง 3 ให้ผลดีกว่าแบบจำลองทางสถิติ

จากผลการศึกษาข้างต้นแสดงให้เห็นว่า การใช้รูปแบบการเรียนรู้แบบต่างๆ มีผลต่อการพยากรณ์ของโครงข่ายประสาทเทียม และให้ผลที่ดีกว่าการเรียนรู้แบบ BPNN แต่อย่างไรก็ตาม BPNN ยังนิยมใช้กันมากทั้งนี้อาจเป็นเพราะว่า โปรแกรมสำเร็จรูปของแบบจำลอง ANN มักเป็นโปรแกรมที่ใช้การเรียนรู้แบบ BP ดังนั้นการใช้การเรียนรู้แบบต่างๆ ผู้วิจัยจำเป็นต้องมีการพัฒนาและสร้างแบบจำลองขึ้นมาใช้เอง จึงทำให้ไม่เป็นที่เผยแพร่มากนักและมีการศึกษาน้อย

### 2.3 การประยุกต์ใช้ GA ในด้านแหล่งน้ำ

แบบจำลองน้ำฝน-น้ำท่า มีจำนวนพารามิเตอร์ของแบบจำลองในแต่ละแบบจำลองที่แตกต่างกัน ขึ้นอยู่กับความซับซ้อนและสภาพทางกายภาพในพื้นที่ศึกษา ที่ผ่านมามีการนำเทคนิค GA มาใช้ปรับเทียบแบบจำลองน้ำฝน-น้ำท่า เพื่อหาค่าพารามิเตอร์ที่เหมาะสม และได้มีการนำไปเปรียบเทียบกับวิธีอื่นๆ ดังกล่าวต่อไปนี้

Franchini (1996) ได้ทำการปรับเทียบแบบจำลองน้ำฝน-น้ำท่า ด้วยวิธีการปรับเทียบ 2 วิธี ได้แก่ GA และ GA ร่วมกับวิธี Sequential Quadratic Programming (SQP) พบว่า การปรับเทียบแบบจำลองด้วย GA ร่วมกับวิธี SQP ให้ผลการพยากรณ์ที่มีความถูกต้องมากกว่า การปรับเทียบแบบจำลองน้ำฝน-น้ำท่าด้วย GA เพียงอย่างเดียว

Franchini และ Galeati (1997) ได้ศึกษาวิธีการปรับเทียบแบบจำลองน้ำฝน-น้ำท่าด้วย GA ในรูปแบบต่างๆ หลายรูปแบบ พบว่า การปรับเทียบแบบจำลองด้วย GA ในหลายรูปแบบ

ให้ผลการพยากรณ์ที่ใกล้เคียงกัน ทำให้การใช้ GA ปรับเทียบแบบจำลองน้ำฝน-น้ำท่าให้ผลการพยากรณ์ที่มีความน่าเชื่อถือมาก

Wang (1997) ได้ประยุกต์ใช้ GA เพื่อปรับเทียบหาค่าพารามิเตอร์ของแบบจำลองน้ำฝน-น้ำท่ารายวันในลุ่มน้ำ Bird Creek (2,344 ตร.กม.) Kizu (1,445 ตร.กม.) และ Halton (205 ตร.กม.) จากชุดข้อมูลในการปรับเทียบ 2 ชุด ได้แก่ ชุดข้อมูลที่ได้จากการสมมติค่าพารามิเตอร์ของแบบจำลองน้ำฝน-น้ำท่า เพื่อใช้ GA ปรับเทียบหาค่าพารามิเตอร์ที่กำหนดให้กับชุดข้อมูลที่ได้จากการวัดจริง พบว่า ในการปรับเทียบข้อมูลที่สมมติ GA ให้ค่าพารามิเตอร์ที่ใกล้เคียงกับค่าพารามิเตอร์ที่กำหนดในหลายๆครั้งของการคำนวณ และในการปรับเทียบชุดข้อมูลที่วัดจริง GA ให้ค่าพารามิเตอร์ที่ใกล้เคียงกันในการคำนวณหลายๆครั้ง

Bhaktitkul (2001) ได้นำ GA และวิธี Quadratic Programming มาประยุกต์ใช้ในงานจัดสรรน้ำกับระบบชลประทานของ Tukad Ayung ในเกาะบาหลี ประเทศอินโดนีเซีย ในภาวะขาดแคลนน้ำเพื่อให้จุดรับน้ำของโครงการแต่ละจุดได้รับน้ำในปริมาณที่ขาดแคลนเท่าๆ กัน พบว่าให้ผลลัพธ์ที่ใกล้เคียงกัน

Bhaktitkul และ Wardlaw (2001) ได้ประยุกต์ใช้ GA และวิธี Linear Programming ในการจัดรอบเวรการส่งน้ำในโครงการชลประทาน Hetao ประเทศมองโกเลีย พบว่า GA สามารถส่งน้ำได้ตามเงื่อนไขที่กำหนด ขณะที่วิธี Linear Programming ให้ค่าผลรวมปริมาณการส่งน้ำในคลองสายย่อยเกินปริมาณน้ำที่มีอยู่จริงในหลายช่วงเวลา

Agrawal และ Singh (2003) ได้ปรับเทียบแบบจำลองน้ำฝน-น้ำท่าในพื้นที่รับน้ำ Kasingagar ขนาด 7,820 ตร.กม. ในประเทศอินเดียด้วย GA พบว่า ผลการพยากรณ์น้ำท่ามีลักษณะน้ำท่าเหลือกับข้อมูลที่วัดได้จริงประมาณ 1-2 วัน

Samuel และ Jha (2003) ได้ใช้วิธี Graphical และ GA หาค่าพารามิเตอร์ของชั้นน้ำจากแบบจำลองของ Theis, Hantush และ Corrected Theis พบว่า GA ให้ผลการพยากรณ์ที่มีความถูกต้องมากกว่าวิธี Graphical

ธนชาติ สุขอนันต์วงศ์ (2547) ได้ประยุกต์ใช้ GA ในการจัดสร้างเกณฑ์ปฏิบัติการของอ่างเก็บน้ำ (Rule Curve) เพื่อวางแผนปล่อยน้ำจากอ่างเก็บน้ำเขื่อนป่าสักชลสิทธิ์เทียบกับเกณฑ์ปฏิบัติการจริง พบว่า GA สามารถช่วยลดการขาดน้ำและบรรเทาน้ำหลากเมื่อเทียบกับเกณฑ์ปฏิบัติการจริงได้พอประมาณ

## 2.4 การประยุกต์ใช้ GA ร่วมกับ ANN

ได้มีการประยุกต์ใช้ GA ร่วมกับ ANN ในแบบจำลองต่างๆ และมีรูปแบบต่างๆ ดังกล่าวต่อไปนี้

Jatinder, Gupta, Randall และ Sexton (1999) ได้ทำการเปรียบเทียบระหว่างการใช้ GA+ANN กับ BPNN ในกระบวนการเรียนรู้ของโครงข่ายประสาทเทียม จากการเปรียบเทียบข้อมูลอนุกรมเวลา พบว่า GA+ANN ให้ผลที่ดีกว่าวิธี BPNN ทั้งในด้านของประสิทธิผล ความง่ายในการใช้และประสิทธิภาพในการเรียนรู้

See และ Openshaw (1999) ได้ประยุกต์ใช้เทคนิค Fuzzy Logic และ GA กับโครงข่ายประสาทเทียมเพื่อพยากรณ์ระดับน้ำล่องหน้า 6 ชม. ที่สถานี Skeleton ซึ่งตั้งอยู่ในแม่น้ำ Ouse ซึ่งอยู่เหนือเมืองยอร์ก แบบจำลองดังกล่าว ได้ประยุกต์ใช้แบบจำลอง SQM ในการจัดความสัมพันธ์ของกลุ่มข้อมูลออกเป็น 5 ชุดตามลักษณะและรูปร่างของชลภาพ (Hydrograph) ได้แก่ ระดับน้ำต่ำ (low flat) ระดับน้ำปานกลาง (medium) ระดับน้ำเพิ่มขึ้น (rising) ระดับน้ำสูงสุด (peak) และระดับน้ำลดต่ำลง (falling) โดยนำเทคนิค Fuzzy Logic ในการสร้างเกณฑ์ตัดสินใจและใช้ GA ในการคัดเลือกเกณฑ์และตัวแปรตัดสินใจที่เหมาะสมในการเลือกใช้แบบจำลองทั้ง 5 แบบจำลอง พบว่า แบบจำลองสามารถพยากรณ์เดือนกุมภาพันธ์ได้ถูกต้องทันเวลามากกว่า 50 เปอร์เซ็นต์ ขณะที่แบบจำลอง ARMA และ Naive ให้ผลการเดือนกุมภาพันธ์ล่าช้ากว่าเหตุการณ์จริง 4-6 ชม.

Sexton และ Gupta (2000) ได้เปรียบเทียบการใช้เทคนิค GA และ BP ในการเรียนรู้ของโครงข่ายประสาทเทียมแบบ RBF เพื่อหาความสัมพันธ์ของฟังก์ชันแบบอนุกรมเวลา 5 ฟังก์ชัน พบว่า ประสิทธิภาพของ GA ดีกว่า BP ในช่วงการเรียนรู้และทดสอบ ในด้านการใช้งาน พบว่า สำหรับ GA โครงสร้างที่ดีที่สุดในการเรียนรู้ให้ผลที่ดีที่สุดในการทดสอบ แต่สำหรับ BP พบว่า โครงสร้างที่ดีที่สุดในการเรียนรู้ไม่จำเป็นต้องเป็นโครงสร้างที่ดีที่สุดในการทดสอบ โดยให้เหตุผลว่า BP เป็นวิธีการหาค่าความเหมาะสมเฉพาะแห่งซึ่งให้ค่าที่ใกล้เคียงกับค่าจริงในการเรียนรู้ แต่ให้ผลที่คลาดเคลื่อนมากเพื่อใช้กับข้อมูลทดสอบ

Pendharkar (2001) ได้ทำการเปรียบเทียบการใช้เทคนิค BPNN, GA+ANN และ GA+BPNN นำมาใช้ในการจำแนกข้อมูลเลขฐานสอง (Binary Classification) และการพยากรณ์โรคหัวใจของผู้ป่วย พบว่า ประสิทธิภาพของการเรียนรู้และการทดสอบขึ้นอยู่กับความแปรปรวนเทคนิคที่ใช้ และการกระจายข้อมูล มีความสำคัญมากน้อยตามลำดับ และพบว่า ในช่วงการ



เรียนรู้เทคนิค GA+BPNN ให้ผลที่ดีที่สุด ตามด้วย GA+ANN และ BPNN ตามลำดับ และในช่วงการทดสอบเทคนิค GA+BPNN และ GA+ANN ให้ผลที่ไม่แตกต่างกัน แต่ทั้งคู่ให้ผลที่ดีกว่า BPNN สำหรับการพยากรณ์ข้อมูลโรคหัวใจ พบว่า GA+BPNN ให้ผลที่ดีกว่าหรือเท่ากับ GA+ANN และ BPNN

Rajkumar และ Thompson (2002) ได้ประยุกต์ใช้ BPNN และ GA+ANN เพื่อพยากรณ์การแทรกตัวของน้ำเค็ม โดย GA คัดเลือกจำนวนข้อมูลนำเข้าและจำนวนโหนดในชั้นแอบแฝงของแบบจำลอง ANN พบว่า GA+ANN ช่วยลดจำนวนข้อมูลนำเข้าจากเดิม 7,669 ข้อมูลเหลือ 7,597 ข้อมูล ลดจำนวนโหนดในชั้นแอบแฝงจากเดิม 30 โหนดเป็น 8 โหนด ผลคือแบบจำลอง ANN มีขนาดเล็กลงและมีความถูกต้องมากขึ้น

Alsultanny และ Aqel (2003) ได้ประยุกต์ใช้ GA+ANN โดยใช้ GA ทำการคัดเลือกหาโครงสร้างและพารามิเตอร์ของโครงข่ายประสาทเทียมที่เหมาะสม ในงาน Image Processing พบว่า GA สามารถลดจำนวนโหนดในชั้นแอบแฝงที่เหมาะสมและลดเวลาในการเรียนรู้ของโครงข่ายประสาทเทียม

Jain และ Srinivasulu (2004) ได้พัฒนาแบบจำลองโครงข่ายประสาทเทียมเพื่อพยากรณ์น้ำท่ารายวันในลุ่มน้ำ Kentucky ที่มีขนาดพื้นที่ลุ่มน้ำ 17,820 ตร.กม. ด้วยแบบจำลอง GA+ANN และ BPNN แบบจำลองที่ใช้มีโครงข่ายขนาด 5-4-1 พบว่า GA+ANN ให้ผลการพยากรณ์ที่ดีกว่า BPNN โดยผลการพยากรณ์ข้อมูลน้ำท่าที่มีค่าต่ำ GA+ANN ให้ผลการพยากรณ์ที่มีค่า AARE น้อยกว่า BPNN ประมาณ 50 เปอร์เซ็นต์ และได้มีการพัฒนาร่วมกับแบบจำลองเชิงความคิดเพื่อคำนวณค่า effective rainfall แทนข้อมูลฝน พบว่า ทำให้แบบจำลองมีความถูกต้องมากขึ้น

Armano, Marchesi, และ Murru (2005) ได้พยากรณ์ดัชนีห้วยด้วยแบบจำลอง GA+ANN เปรียบเทียบกับข้อมูลจริง พบว่าแบบจำลอง GA+ANN ให้ผลการพยากรณ์ที่ดี

Khu , Savic, Liu และ Madsen (2005) ได้ใช้วิธี GA และโครงข่ายประสาทเทียมแบบ RBF เพื่อปรับเทียบแบบจำลองน้ำฝน-น้ำท่า ที่ชื่อว่า MIKE11/NAM เทียบกับวิธี GA วิธีเดียวในพื้นที่ลุ่มน้ำ Treggevaede ซึ่งตั้งอยู่ในประเทศเดนมาร์ก มีขนาดพื้นที่ลุ่มน้ำ 130 ตร.กม. มีปริมาณฝนเฉลี่ย 710 มม./ปี และมีน้ำท่าเฉลี่ย 240 มม./ปี พบว่า การปรับเทียบแบบจำลอง MIKE11/NAM ด้วย GA ร่วมกับ RBF ให้ผลที่ใกล้เคียงกับการปรับเทียบแบบจำลองด้วย GA เพียงอย่างเดียว แต่ให้จำนวนรอบในการคำนวณลดลง 40 เปอร์เซ็นต์