

แบบจำลองโครงข่ายประสาทเทียมสำหรับ Clarifier—
กรณีศึกษา : โรงงานผลิตน้ำประปาบางเขน
Clarifier Models using Artificial Neural Networks—
Case Study: Bangkhen Water Treatment Plant

วารภรณ์ ม้วนทอง¹ วรุณศักดิ์ เลี่ยมแหลม¹ เสฎฐา ศาสนนันท์^{2*}

¹ภาควิชาวิศวกรรมโยธา คณะวิศวกรรมศาสตร์ มหาวิทยาลัยธรรมศาสตร์ ตำบลคลองหนึ่ง
อำเภอคลองหลวง จังหวัดปทุมธานี 12120

²ภาควิชาวิศวกรรมโยธา คณะวิศวกรรมศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ ตำบลองครักษ์
อำเภอองครักษ์ จังหวัดนครนายก 26120

*Corresponding author: E-mail: e41stomos@gmail.com

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์ในการประยุกต์ใช้แบบจำลองโครงข่ายประสาทเทียม สำหรับทำนายค่าความขุ่นของน้ำที่ออกจากแคลรีไฟเออร์ ด้วยข้อมูลการปฏิบัติงานในรูปแบบของอนุกรมเวลา โดยข้อมูลอินพุตประกอบด้วย ค่าความขุ่นน้ำดิบ, ค่าความเป็นต่างของน้ำดิบ, ค่าความความเป็นกรด-เบสของน้ำดิบ, ค่าปริมาตรความเข้มข้นสารส้มที่จ่าย, ค่าปริมาตรความเข้มข้นโพลลิเอ็คโตรไลต์ที่จ่าย, ค่าอัตราการไหล, ค่าความเร็วรอบของใบกวน, ค่าอัตราการระบายตะกอน, ค่าความเข้มข้นตะกอน และค่าความขุ่นของน้ำที่ออกจากแคลรีไฟเออร์ ของสำนักงานประปาบางเขน การประปานครหลวง เป็นข้อมูลที่เก็บรวบรวมตั้งแต่วันที่ 1 มกราคม พ.ศ. 2553 ถึงวันที่ 31 ธันวาคม พ.ศ. 2553 ซึ่งครอบคลุมถึงการเปลี่ยนแปลงตามฤดูกาล โดยรูปแบบของแบบจำลอง ANN ข้อมูลอินพุตจะแบ่งออกเป็น 3 กลุ่ม คือ กลุ่มข้อมูลฝึกสอน กลุ่มข้อมูลตรวจสอบ และกลุ่มข้อมูลทดสอบ สถาปัตยกรรมของแบบจำลองที่ดีที่สุดหาได้จากค่าสัมประสิทธิ์การตัดสินใจ (r^2) และค่าคลาดเคลื่อนสัมบูรณ์เฉลี่ย (MAE) ที่ได้จากการทดลองด้วยการเรียนรู้แบบการลองผิดลองถูก ซึ่งการทดลองกำหนดให้มีชั้นซ่อนไม่เกิน 2 ชั้น และจำนวนนิวรอนในชั้นซ่อนตั้งแต่ 5 ถึง 100 จากการพิจารณาค่า Autocorrelation Function (ACF) ควรใช้ช่วงเวลาย้อนหลังไม่เกิน 8 ชั่วโมง อย่างไรก็ตามเพื่อให้แน่ใจว่าได้ทำการตรวจสอบประสิทธิภาพของแบบจำลอง ดังนั้นจะทำการทดลองตั้งแต่ช่วงเวลาปัจจุบัน ถึงช่วงเวลาย้อนหลัง 20 ชั่วโมง

จะพบว่าแบบจำลอง ANN ที่ชั้นซ่อน 2 ชั้น แสดงผลประสิทธิภาพการทำนายที่ดีกว่าแบบจำลองชั้นซ่อน 1 ชั้น แบบจำลองที่มีประสิทธิภาพดีในการทำนายที่ดีที่สุด คือแบบจำลองแบบ 2 ชั้นซ่อน โดยชั้นซ่อนที่หนึ่งมีจำนวนนิวรอนเท่ากับ 45 นิวรอน และชั้นซ่อนที่สองเท่ากับ 80 นิวรอน โดยใช้ข้อมูลย้อนหลังในการทำนายเท่ากับ 8 ชั่วโมง โดยแบบจำลองนี้ให้ค่าสัมประสิทธิ์การตัดสินใจ (r^2) เท่ากับ 0.92 และ ค่าคลาดเคลื่อนสัมบูรณ์เฉลี่ย (MAE) เท่ากับ 0.016 NTU แบบจำลอง ANN สำหรับการทำนายค่าความขุ่นของน้ำที่ออกจากแคลรีไฟเออร์นี้แสดงให้เห็นว่าประสิทธิภาพของการทำนายของแบบจำลองเป็นที่ยอมรับได้ เนื่องจากให้ค่าความผิดพลาดน้อยกว่าความคลาดเคลื่อนของเครื่องมือวัด

คำสำคัญ: โครงข่ายประสาทเทียม การทำนาย อนุกรมเวลา

ABSTRACT

The objective of this research is to apply Artificial Neural Networks (ANN) modeling for predicting clarified water turbidity, using operation data in time series format. The input data includes raw water turbidity, raw water alkalinity, raw water pH, alum dosage, polyelectrolyte dosage, plant flow rate, turbine speed, sludge drainage rate, sludge concentration, and clarified water turbidity. This data belongs to Bangkhen Water Treatment Plant, Metropolitan Waterworks Authority. The data was collected during the period of January 1st to December 31st, 2010, covering seasonal changes. As a typical ANN modeling, the input data was divided into 3 sets consisting of Training, Validation, and Testing sets. The best model architecture was obtained by considering the Coefficient of Determination (r^2) and the Mean Absolute Error (MAE), obtained from a number of numerical experiments based on trial and error. The experiment was limited to two hidden layer models, and the number of neurons was set from 5 to 100 neurons. By considering the Autocorrelation Function (ACF), there is a suggestion of using less than an 8-hour temporal span. However, the numerical experiment was carried out from the present to a temporal span of 20 hours in order to assure that the model performance was entirely evaluated.

ANN model with two hidden layers obviously exhibited better performance than the one hidden layer model. The best prediction performance model came with the two hidden layer architecture, which is 45 neurons in the first hidden layer and 80 neurons in the second hidden layer and an 8 hours temporal span. This model gave an r^2 of 0.92 and a Mean Absolute Error of 0.016 NTU. This clarified that the ANN model is promising for practical application because its MAE of 0.016 NTU was less than the measurement error of the turbidity meter.

Keyword: Artificial Neural Network, Prediction, Time series

1. บทนำ

กระบวนการผลิตน้ำประปา เช่น Clarification เป็นกระบวนการพื้นฐานที่มีความสำคัญ เนื่องจากเป็นกระบวนการที่มุ่งกำจัดความขุ่นของน้ำดิบเป็นส่วนใหญ่ ในกรณีศึกษาที่โรงงานผลิตน้ำประปาบางเขน (Bangkhen Water Treatment Plant, BKWTP) ความขุ่นของน้ำดิบเฉลี่ยอยู่ที่ประมาณ 100 NTU จึงเป็นภาระอย่างหนักสำหรับ Clarifier ที่จะต้องกำจัดความขุ่นให้เหลือประมาณ 5-6 NTU [1] ดังนั้นประสิทธิภาพของ Clarifier จึงมีอิทธิพลและมีผลกระทบโดยรวมต่อประสิทธิภาพของโรงผลิตน้ำประปา หากเกิดความผิดพลาดขึ้นซึ่งไม่สามารถกำจัดความขุ่นให้เป็นไปตามที่กำหนดไว้ จะทำให้เกิดปัญหาตามมาภายในระบบผลิตในส่วนอื่นๆ แม้ว่าปัจจุบันจะมีการนำ sensor แบบ On - line มาใช้ในโรงผลิตน้ำประปา

บางเขนแล้วก็ตาม แต่ระบบควบคุมแบบอัตโนมัติของ Clarifier ยังไม่สามารถใช้งานได้อย่างเต็มประสิทธิภาพ และยังคงใช้มนุษย์ในการควบคุม ดังนั้นประสิทธิภาพของ Clarifier จึงขึ้นอยู่กับประสบการณ์และความสามารถของผู้ปฏิบัติการ (Operator)

ในบางครั้งผู้ปฏิบัติการได้ดำเนินการผิดพลาด หรือ เดิมสารเคมีมากเกินไป ทั้งนี้เนื่องจากความซับซ้อนของกระบวนการที่เกิดขึ้นใน Clarifier (Coagulation, Flocculation และ Sedimentation) ซึ่งในปัจจุบันยังไม่มีแบบจำลองทางคณิตศาสตร์ที่อธิบายความสัมพันธ์ของตัวแปรต่างๆที่เกี่ยวข้องกับประสิทธิภาพการกำจัดความขุ่น โดยมูลเหตุดังกล่าวจึงนำเสนอเทคนิคการสร้างแบบจำลองโดยใช้โครงข่ายประสาทเทียม (Artificial Neural Networks, ANN) แบบจำลองโครงข่ายประสาทเทียมนี้จะอาศัยข้อมูลอนุกรมเวลาของการเดิน

ระบบ (Operate) ถึง Clarifier ในอดีต เพื่อทำนายค่าความขุ่นของน้ำที่ออกจาก Clarifier

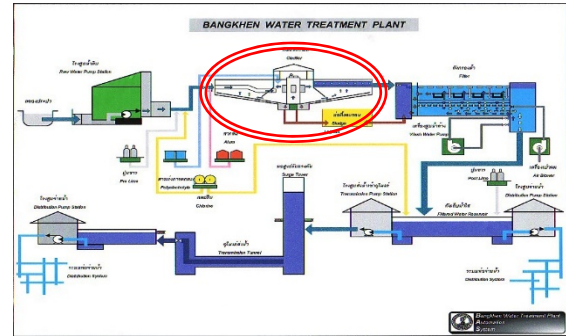
โดยมุ่งหวังให้ผู้ปฏิบัติงานนำไปเป็นแนวทางปฏิบัติในการเดินระบบ โดยแปรค่าตัวแปรควบคุม (Controllable Variable) เช่น ความเข้มข้นของสารส้ม ความเข้มข้นของโพสลิอิเล็กโทรไลต์ โดยให้แบบจำลองทำนายค่าความขุ่นของน้ำที่ออกจาก Clarifier นอกจากนี้ แบบจำลองโครงข่ายประสาทเทียมของ Clarifier ยังใช้เป็นหน่วยฝึกหัดเพื่อจำลองสถานการณ์จริง (Simulation Unit) ให้ผู้ปฏิบัติการใหม่ทดลองเดินระบบ โดยฝึกแปรค่าตัวแปรควบคุมให้เหมาะสมกับสภาพน้ำดิบที่เข้าสู่ Clarifier

การใช้เทคนิคโครงข่ายประสาทเทียม (Artificial Neural Networks, ANN) ซึ่งเป็นแบบจำลองทางคณิตศาสตร์ที่ใช้ในการประมวลผลสารสนเทศด้วยการคำนวณแบบคอนเนกชันนิสต์ (connectionist) เป็นการประยุกต์การจำลองการทำงานของสมองมนุษย์ด้วยโปรแกรมคอมพิวเตอร์ โดยมุ่งหวังให้คอมพิวเตอร์มีความชาญฉลาดในการเรียนรู้เหมือนสมองมนุษย์ที่มีความสามารถในการเรียนรู้และจดจำ (pattern recognition) การอุปมา ความรู้ (knowledge deduction) สามารถฝึกฝนได้ และสามารถนำความรู้และทักษะไปแก้ปัญหาต่างๆ [2]

2. โรงผลิตน้ำประปาบางเขน (Bangkhen Water Treatment Plant, BKWTP) และปัญหาการเดินระบบ

โรงงานผลิตน้ำประปาบางเขนมีอัตราการกำลังการผลิตทั้งหมด 3,600,000 ลบ.ม./วัน BKWTP จะรับน้ำจากแม่น้ำเจ้าพระยาบริเวณตำบลเชียงรากน้อย จังหวัดปทุมธานี โดยไหลมาตามคลองประปา กระบวนการผลิตน้ำประปาจะเริ่มด้วยการปรับปรุงคุณภาพน้ำดิบ ก่อนที่น้ำดิบจะถูกสูบส่งเข้าสู่ตักตะกอน จะมีการเติมปูนขาว (Lime) เพื่อปรับสภาพให้น้ำดิบมีความเป็นด่างเล็กน้อย เพื่อช่วยให้สารส้มทำปฏิกิริยาได้ดีขึ้น และเติมคลอรีน (Pre-chlorination) เพื่อกำจัดสี กลิ่น ตะไคร่ในน้ำดิบ เมื่อเติมสารเคมีแล้ว น้ำดิบจะไหลเข้าสู่ตัก Clarifier ซึ่งมีจำนวน 18 ตัก

จากนั้นจะไหลเข้าสู่บ่อกรอง และเข้าสู่ระบบกำจัดเชื้อโรคก่อนที่จะเข้าสู่ระบบสูบน้ำส่งและสูบน้ำจ่ายน้ำประปา ดังแสดงในรูปที่ 1



รูปที่ 1 กระบวนการผลิตน้ำประปาบางเขน
ที่มา : โรงผลิตน้ำประปาบางเขน

ถึง Clarifier ที่ใช้ใน BKWTP ปัจจุบัน ได้แสดงดังรูปที่ 2 ซึ่งเป็นถังกลมรูปกระโถนอยู่เหนือพื้นดิน มีขนาดเส้นผ่านศูนย์กลาง 58 เมตร จำนวน 18 ถัง มีอัตราการกำลังการผลิตถึงละ 200,000 ลบ.ม./วัน และมีการติดตั้งอุปกรณ์ภายในเกี่ยวกับการตกตะกอนในระบบ Solid Contact [3] ที่ใช้การหมุนเวียนตะกอนเก่า (Slurry Recirculation) เพื่อเพิ่มประสิทธิภาพของการสมานตะกอน (Flocculation)



รูปที่ 2 Clarifier ที่ใช้ในโรงผลิตน้ำประปาบางเขน
ที่มา : โรงผลิตน้ำประปาบางเขน

การควบคุมถึง Clarifier ผู้ปฏิบัติการทำได้โดยแปรค่าตัวแปรควบคุม 5 ตัวหลัก คือ ความเข้มข้นของสารส้มและโพสลิอิเล็กโทรไลต์ที่จ่าย ความเข้มข้นของ

การผสม (ความเร็วรอบของใบกวน) อัตราการระบาย ตะกอน และอัตราการไหลเข้าของน้ำดิบเข้าสู่ถัง Clarifier อย่างไรก็ตามอัตราการไหลเข้าของน้ำดิบไม่สามารถแปรค่าได้มากนักเนื่องจากเป็นตัวกำหนดอัตราการผลิตของโรงงานซึ่งจะต้องเพียงพอกับความต้องการของชุมชน

การกำหนดความเข้มข้นที่เหมาะสมของสารส้ม และฟอสฟอริกไทโรไลท์ โดยใช้ผลทดลองจารุเทสเป็นแนวทางเบื้องต้น การกำหนดค่าตัวแปรควบคุมที่เหมาะสมของตัวแปรที่เหลือกำหนดโดยใช้ความชำนาญของผู้ปฏิบัติงานเป็นหลัก

การกำหนดค่าที่เหมาะสมโดยใช้ประสบการณ์ของผู้ปฏิบัติการมักทำให้เกิดปัญหาในการเดินระบบ โดยเฉพาะกับผู้ปฏิบัติการที่มีประสบการณ์น้อย

3. แบบจำลองโครงข่ายประสาทเทียม (Artificial Neural Networks, ANNs)


โครงสร้างของโครงข่ายประสาทเทียม ประกอบด้วย 3 องค์ประกอบ [4] ดังนี้

1. ชั้นอินพุต (Input Layer) เป็นชั้นแรกในโครงสร้างของแบบจำลอง ANN จะประกอบด้วยนิวรอนรับข้อมูล (Input Neuron) จำนวนนิวรอนรับข้อมูลจะเท่ากับจำนวนของข้อมูลอินพุต โดยทำหน้าที่รับข้อมูลเข้าสู่แบบจำลอง ANN

2. ชั้นเอาต์พุต (Output Layer) เป็นชั้นสุดท้ายในโครงสร้างของแบบจำลอง ANN จะประกอบด้วยนิวรอนแสดงผลข้อมูล (Output Neuron) จำนวนนิวรอนของข้อมูลจะเท่ากับจำนวนของข้อมูลเอาต์พุตของตัวแปร ทำหน้าที่แสดงผลลัพธ์ (Output) ของแบบจำลอง ANN

3. ชั้นซ่อน (Hidden Layer) จะอยู่ระหว่างชั้นอินพุตและชั้นเอาต์พุตประกอบด้วยนิวรอนในชั้นซ่อน (Hidden Neuron) ทำหน้าที่ในการรวมอินพุตที่คูณด้วยน้ำหนัก (Weight) ที่แปรค่าเพื่อแปลงให้เป็นผลลัพธ์ (Output) และส่งไปยังชั้นเอาต์พุต โดยไม่มีกฎตายตัวในการกำหนดจำนวนชั้นซ่อนและนิวรอนที่เหมาะสม นักวิจัยหลายท่าน [5, 6] ได้แนะนำจำนวน

ชั้นซ่อนและนิวรอนที่เหมาะสมสามารถหาได้โดยกระบวนการลองผิดลองถูก (Trial and Error) ในแต่ละกรณีของปัญหา



รูปที่ 3 แสดงถึงระบบโครงข่ายประสาทเทียมที่มีจำนวนชั้นทั้งหมด 3 ชั้น

กระบวนการเรียนรู้ของแบบจำลอง ANN มี 2 ลักษณะ คือ การเรียนรู้แบบมีการสอน (Supervised Learning) เป็นการใช้รูปแบบ (Pattern) ของชุดข้อมูลตัวแปรอินพุตและตัวแปรเอาต์พุตสอนโครงข่ายให้เรียนรู้ความสัมพันธ์ระหว่างตัวแปรอินพุตและตัวแปรเอาต์พุต โดยโครงข่ายแบบจำลอง ANN จะปรับค่าน้ำหนักที่เชื่อมโยงเพื่อลดความผิดพลาดในการทำนายค่าเอาต์พุต และการเรียนรู้แบบไม่มีการสอน (Unsupervised Learning) จะไม่มีการตรวจสอบคำตอบว่าถูกหรือผิด ซึ่งโครงข่าย ANN จะจัดเรียงโครงสร้างด้วยตัวเองตามลักษณะของข้อมูล โดยจะสร้างค่าน้ำหนัก (weight) ที่เชื่อมโยงตัวแปรอินพุต ข้อมูลใหม่มีลักษณะที่ควรจัดรวมเข้ากลุ่มใดหลังจากนั้นจึงมีการปรับคุณลักษณะของกลุ่ม โดยการนำลักษณะของข้อมูลใหม่นี้มาช่วยกำหนดแนวทางการจัดด้วย ในการตัดสินใจว่าข้อมูลผลลัพธ์ที่ได้นี้ควรจัดรวมเข้ากลุ่มใด [7]

แบบจำลอง ANN ที่ใช้ในงานวิจัยนี้เป็นแบบ Feedforward Network ตามทิศทางการเคลื่อนที่ของข้อมูลจากชั้นอินพุตไปยังชั้นเอาต์พุต แต่การเรียนรู้จะเกิดในทิศทางย้อนกลับด้านชั้นเอาต์พุตที่เรียกว่า Back propagation โดยแต่ละนิวรอนจะทำการประเมินผล

โดยใช้ฟังก์ชันถ่ายโอน (transfer function) ซึ่งมีอยู่หลายชนิด เช่น ฟังก์ชันถ่ายโอนแบบ Symmetric hard-limit, ฟังก์ชันถ่ายโอนแบบ Logarithmic sigmoid และฟังก์ชันถ่ายโอนแบบ Hyperbolic tangent sigmoid [8] เมื่อได้ผลรวมของเอาต์พุตของแต่ละนิวรอนในทุกๆ ชั้นซ่อน (Hidden Layer) เอาต์พุตนี้จะถูกเปรียบเทียบกับเอาต์พุตจริง ผลต่างของเอาต์พุตทั้งสองจะถูกเรียนรู้โดยการสอน (Supervised learning) แบบจำลอง ANN จากนิวรอนถึงนิวรอน ในทิศทางจากชั้นเอาต์พุตถึงชั้นอินพุต โดยค่าน้ำหนักในแต่ละนิวรอนจะถูกปรับเพื่อลดผลต่างข้างต้น และทำให้แบบจำลองที่ใช้ในงานวิจัยนี้เรียกว่า Feedforward Backpropagation Artificial Neural Network

4. ข้อมูลการเดินระบบของ Clarifier ที่ใช้ในการสร้างแบบจำลอง

ข้อมูลที่ใช้เป็นข้อมูลคุณภาพน้ำจากโรงงานผลิตน้ำประปาบางเขน โดยข้อมูลที่ได้มาเป็นรายวันตั้งแต่ 1 มกราคม 2553 ถึง 31 ธันวาคม 2553 เป็นระยะเวลา 1 ปี โดยข้อมูลที่นำมาใช้ทั้งหมดมีจำนวน 10 ตัวแปร ได้แก่ ค่าความขุ่นของน้ำดิบ, ค่าความเป็นด่างของน้ำดิบ, ค่าความความเป็นกรด-เบสของน้ำดิบ, ค่าปริมาณความเข้มข้นสารส้มที่จ่าย, ค่าปริมาณความเข้มข้นโพลิอิเล็กโทรไลต์ที่จ่าย, ค่าอัตราการไหล, ค่าความเร็วรอบของใบกวน, ค่าการระบายตะกอน, ค่าเปอร์เซ็นต์ตะกอน และค่าความขุ่นของน้ำที่ออกจาก Clarifier

ค่าตัวแปรทางสถิติ (Statistic parameters) ของตัวแปรทั้งหมดได้แสดงอยู่ในตารางที่ 1

ตารางที่ 1 แสดงค่าตัวแปรทางสถิติ

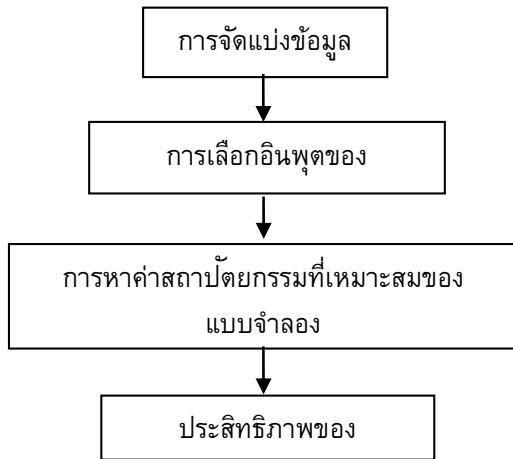
ตัวแปร	ค่าเฉลี่ย	ค่าเบี่ยงเบนมาตรฐาน	Regression Coefficient*
ความขุ่นของน้ำดิบ (NTU)	47.89	44.49	0.447
ความเป็นด่างของน้ำดิบ (mg/L as CaCO ₃)	99.04	12.03	-0.151
ความเป็นกรด-เบสของน้ำดิบ (pH unit)	7.50	0.08	-0.230
ปริมาณความเข้มข้นของสารส้มที่จ่าย (mg/L)	32.40	16.95	0.336
ปริมาณความเข้มข้นของโพลิอิเล็กโทรไลต์ที่จ่าย (mg/L)	0.010	0.024	0.421
อัตราการไหล (m ³ /d)	2291280.8	226593.7	0.121
ความเร็วรอบของใบกวน (RPM)	739.15	40.52	0.040
การระบายตะกอน **(hour)	3.85	1.56	-0.334
เปอร์เซ็นต์ตะกอน (%)	6.84	2.96	-0.309
ความขุ่นที่ออกจาก Clarifier (NTU)	4.16	1.56	1

*เทียบกับค่าความขุ่นของน้ำที่ออกจาก Clarifier

** การระบายตะกอนจะระบายแบบอัตโนมัติครั้งละ 1 นาที และหยุดระบายตะกอนเป็นช่วงเวลา

5. การสร้างแบบจำลอง ANN

การจัดเตรียมข้อมูลเพื่อการสร้างแบบจำลอง ANN ประกอบด้วย 4 ขั้นตอน ดังแสดงในรูปที่ 4



รูปที่ 4 การสร้างแบบจำลอง ANN

5.1 การจัดแบ่งข้อมูล

ขั้นตอนแรก คือ การจัดแบ่งข้อมูล ในการสร้างแบบจำลอง ANN จำเป็นต้องแบ่งข้อมูลออกเป็น 3 ส่วนหลักๆ โดยแบ่งข้อมูลออกเป็น Training set, Test set และ Validation set การแบ่งชุดข้อมูลควรทำให้ชุดข้อมูลทั้ง 3 ชุดจะต้องเป็นตัวแทนซึ่งกันและกัน [9] โดยมีค่าเฉลี่ยใกล้เคียงกัน นอกจากนี้แล้วช่วงของข้อมูล Training set ควรจะต้องครอบคลุมช่วงของ Test set และ Validation set เพื่อหลีกเลี่ยงการประมาณนอกช่วง (Extrapolation) งานวิจัยนี้ได้แบ่งข้อมูลโดยใช้วิธีการสุ่ม (Random) ให้มีอัตราส่วนของจำนวนข้อมูล Training set: Test set: Validation set เท่ากับ 4:1:1 [9]

5.2 การเลือกอินพุตของแบบจำลอง

ขั้นตอนที่สอง คือ การเลือกอินพุตของแบบจำลอง แบบจำลอง ANN จะสนใจความสัมพันธ์ของอินพุตที่ป้อนเข้าเป็นสำคัญ หรือเป็นการสร้างความสัมพันธ์แบบ Black Box Model การเลือกตัวแปรอินพุตของแบบจำลองที่เกี่ยวข้องกับข้อมูลอนุกรมเวลา มีส่วนสำคัญสองส่วน คือ ชนิดของตัวแปรอินพุต และ ระยะเวลาย้อนหลัง (Time lag)

ชนิดของตัวแปรอินพุต ในการพิจารณาเลือกชนิดของตัวแปรจะใช้การวิเคราะห์ความถดถอยแบบเชิงเส้น (Linear Regression Analysis) โดยพิจารณาจากสัมประสิทธิ์การถดถอย (Regression Coefficient, r) ถ้าค่าสัมประสิทธิ์การถดถอยมีค่าน้อยกว่า ± 0.5 จะถือว่าตัวแปรอินพุตดังกล่าวไม่มีความสัมพันธ์แบบเชิงเส้นกับตัวแปรเอาต์พุตดังแสดงในตารางที่ 1 [10]

จากตารางที่ 1 พบว่า ค่า r ของทุกตัวแปรอินพุตกับตัวแปรเอาต์พุต (ค่าความขุ่นของน้ำที่ออกจาก Clarifier) มีค่าน้อยมากและมีค่าต่ำกว่า 0.5 แสดงว่าค่าความขุ่นของน้ำที่ออกจาก Clarifier ไม่มีความสัมพันธ์เชิงเส้นกับตัวแปรอินพุต ในการสร้างแบบจำลองของความสัมพันธ์แบบไม่เชิงเส้น นักวิจัยหลายท่าน [11, 12, 13] ได้แนะนำให้ใช้ ANN ในการสร้างแบบจำลอง โดยตัวแปรทุกตัวที่แสดงอยู่ในตารางที่ 1 จะถูกเลือกเป็นอินพุตของแบบจำลอง

ระยะเวลาย้อนหลัง (time lag) ที่เหมาะสมจะพิจารณาโดยใช้ค่า Autocorrelation Function (ACF) กรณีที่มีข้อมูลเป็นข้อมูลอนุกรมเวลา (time series) ค่า ACF เป็นค่าที่แสดงผลข้อมูลในอดีตของข้อมูลอนุกรมเวลาที่มีผลกับค่าในเวลาปัจจุบัน ค่า ACF สามารถหาได้จากความสัมพันธ์ดังต่อไปนี้ [14]

ค่าสัมประสิทธิ์ของ Autocorrelation ที่ lag k คือ

$$C_k = \frac{1}{N-k} \sum_{t=1}^{N-k} (x_t - \bar{x})(x_{t+k} - \bar{x}) \quad (1)$$

โดยที่ k คือ lag , $k = 0, 1, \dots, N$ ถ้าถูกตั้งค่าเป็น 0 หมายถึงว่าค่าปัจจุบัน และ \bar{x} คือค่าเฉลี่ยทั้งหมดของชุด ถูกนิยามเป็น

$$\bar{x} = \frac{1}{N} \sum_{t=0}^N x_t \quad (2)$$

Autocorrelation ที่ lag k หาได้จาก

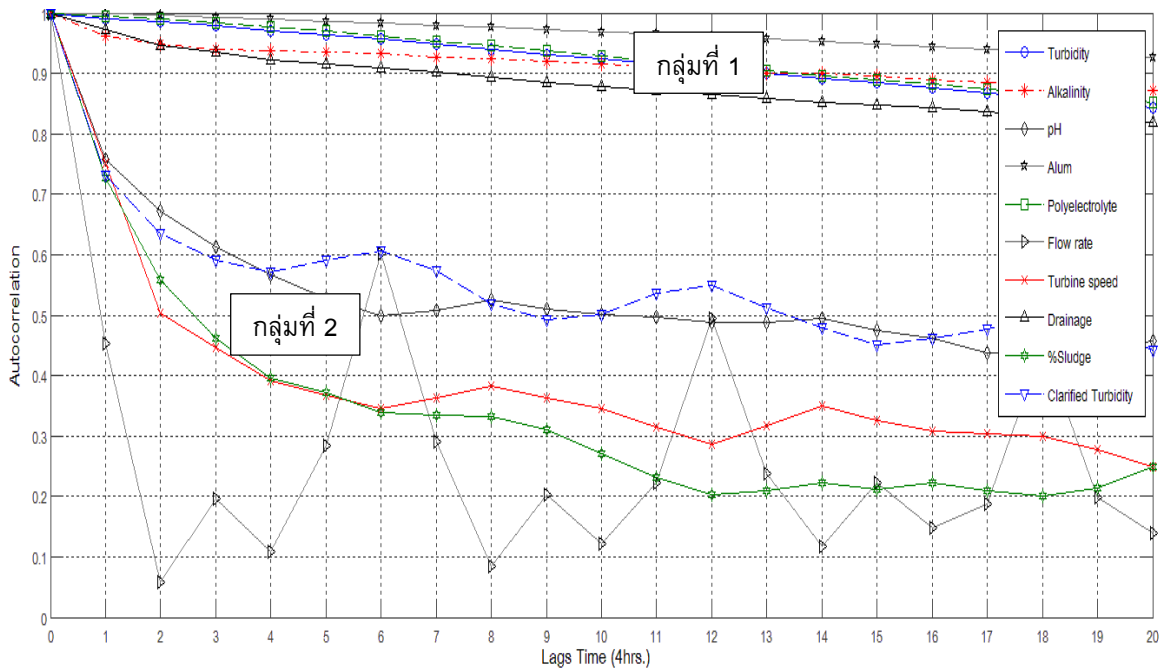
$$ACF(k) = \frac{C_k}{C_0} \quad (3)$$

ในงานวิจัยครั้งนี้ได้นำตัวแปรอินพุตทั้งหมดมาใช้ทำการหาค่า ACF ของอนุกรมเวลา โดยทำการแปรค่าเวลาย้อนหลังจากเวลาที่ปัจจุบัน (lag 0) จนถึงค่าเวลาย้อนหลัง 80 ชั่วโมง (lag 20) ดังแสดงในรูปที่ 5 ซึ่งโดยรวมจากภาพจะแยกการพิจารณาเป็น 2 กลุ่มตามลักษณะการลดลงของค่า ACF เมื่อเพิ่มช่วงเวลาย้อนหลัง ถ้าค่า ACF ที่ช่วงเวลาย้อนหลังใดๆ ของอนุกรมเวลามีค่าน้อยกว่า 0.5 จะถือว่าเป็นข้อมูลที่มีสิ่งปลอมปน (noisy data) และจะไม่นำไปใช้เป็นข้อมูลอินพุตของแบบจำลอง ANN [11]

กลุ่มที่ 1 อนุกรมเวลาของค่าความขุ่นของน้ำดิบ, ค่าความเป็นด่างของน้ำดิบ, ค่าปริมาณความเข้มข้นของสารส้มที่จ่าย, ค่าปริมาณความเข้มข้นของ

โพลิอิเล็กโทรไลต์ที่จ่าย, อัตราการระบายตะกอน พบว่าค่า ACF ของอนุกรมเวลาของค่าตัวแปรต่างๆมีค่าลดลงน้อยมาก เมื่อเวลาย้อนหลังมากขึ้นนั้นหมายความว่า ข้อมูลในอดีตของตัวแปรมีผลกับข้อมูลในปัจจุบัน

กลุ่มที่ 2 อนุกรมเวลาของค่าความเป็นกรด-เบสของน้ำดิบ, ค่าอัตราการไหล, ค่าความเร็วรอบของใบกวน, ค่าเปอร์เซ็นต์ตะกอน และค่าความขุ่นที่ออกจาก Clarifier เมื่อพิจารณาข้อมูลของกลุ่มที่มีค่า ACF ลดลงอย่างมากในช่วงแรก พบว่าข้อมูลย้อนหลังเกินกว่า 8 ชั่วโมง (2 lag) ไม่ควรนำมาใช้เป็นข้อมูลอินพุต เนื่องจากเป็นข้อมูลที่มีสิ่งปลอมปน (noisy data)



รูปที่ 5 ACF ของอินพุตและเอาต์พุตของค่าความขุ่นที่ออกจาก Clarifier ที่ในการเลือกเวลาย้อนหลัง

จากการพิจารณาค่า ACF ของข้อมูลทั้งสองกลุ่ม ไม่ควรนำข้อมูลย้อนหลังเกิน 8 ชั่วโมงมาใช้เป็นตัวแปรอินพุต อย่างไรก็ตามในการแปรค่าเวลาย้อนหลังจะทำการแปรค่าจากเวลาที่ปัจจุบัน (lag 0)

จนถึงเวลาย้อนหลังที่ 20 ชั่วโมง (lag 5) เพื่อที่จะสามารถพิจารณาประสิทธิภาพของการทำนายของแบบจำลอง เมื่อมีค่าเวลาย้อนหลังมากและน้อยกว่าช่วงเวลาย้อนหลังที่เหมาะสม ดังที่แสดงในตารางที่ 2

ตารางที่ 2 แสดงการเลือกค่าอินพุตกับค่าเวลาย้อนหลัง (time lag) และค่าเอาต์พุตที่ใช้ในแบบจำลอง

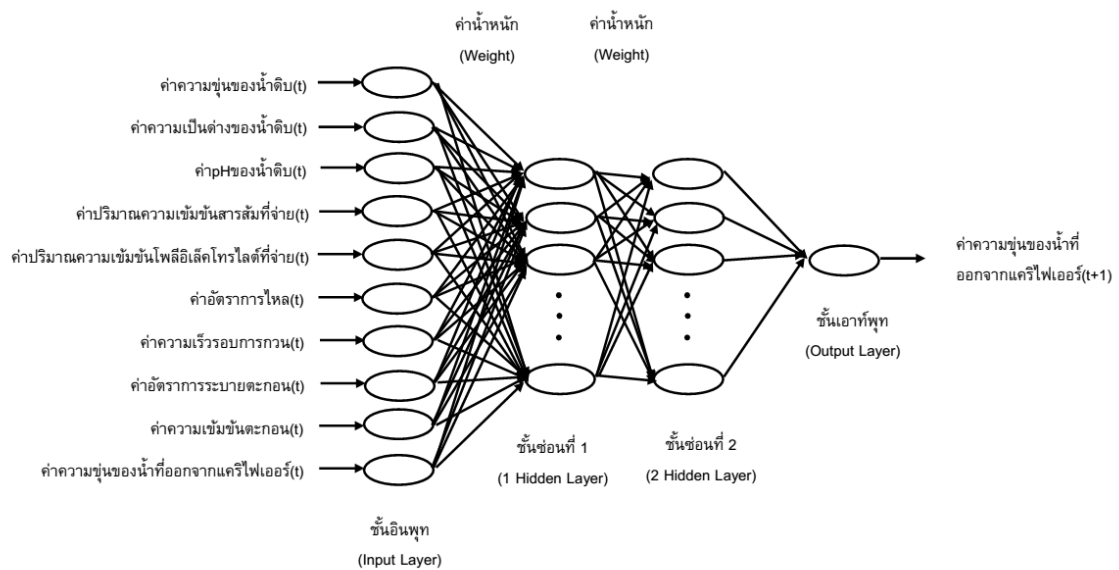
ตัวแปร	เวลาย้อนหลัง	หมายเหตุ
ความขุ่นของน้ำดิบ	เวลาปัจจุบัน (t), 4 ชั่วโมง (t-1), 8 ชั่วโมง (t-2), 12 ชั่วโมง (t-3), 16 ชั่วโมง (t-4), 20 ชั่วโมง (t-5)	อินพุต
ความเป็นต่างของน้ำดิบ		
ความเป็นกรด-เบสของน้ำดิบ		
ปริมาณความเข้มข้นของสารส้มที่จ่าย		
ปริมาณความเข้มข้นของโพลิอิเล็กโทรไลต์ที่จ่าย		
อัตราการไหล		
ความเร็วรอบของใบกวน		
การระบายตะกอน		
เปอร์เซ็นต์ตะกอน		
ความขุ่นที่ออกจาก Clarifier		
ความขุ่นที่ออกจาก Clarifier	4 ชั่วโมงข้างหน้า (t+1)	เอาต์พุต

5.3 การหาค่าสถาปัตยกรรมที่เหมาะสม

การหาค่าสถาปัตยกรรมที่เหมาะสม (Optimal architecture) ในที่นี้หมายถึง จำนวนชั้นซ่อนและนิเวรอนในชั้นซ่อนที่เหมาะสม โดยมีนักวิจัยหลายคน [5, 6] ได้แนะนำการเลือกสถาปัตยกรรมที่เหมาะสมสามารถหาได้จากวิธี Trial and Error ซึ่งสามารถกระทำได้โดยแปลค่าจำนวนชั้นซ่อนและนิเวรอนในชั้นซ่อน

ได้มีข้อโต้แย้งจากนักวิจัยหลายท่านว่า สถาปัตยกรรมที่มีชั้นซ่อน 1 ชั้น (1 Hidden layer) ไม่สามารถจำลองความสัมพันธ์ที่ซับซ้อน และแนะนำให้ใช้สถาปัตยกรรมโครงข่ายประสาทเทียมขนาดไม่เกินชั้นซ่อน 2 ชั้นและให้หาค่าเหมาะสมโดยการลองผิดลองถูก [8, 15, 16]

ตัวอย่างสถาปัตยกรรมแบบชั้นซ่อน 2 ชั้นแสดงในรูปที่ 6



รูปที่ 6 ตัวอย่างสถาปัตยกรรมแบบ 2 ชั้นซ่อนที่ใช้ในงานวิจัย

5.4 ประสิทธิภาพของแบบจำลอง

การวัดประสิทธิภาพของแบบจำลอง ANN ทำได้โดยเปรียบเทียบค่าสัมประสิทธิ์การตัดสินใจ (The Coefficient of Determination, r^2) และ ค่าคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Error, MAE) [17] บนชุดข้อมูล Test set โดยค่า r^2 จะใช้ในการวัดค่าความผิดพลาดในการทำนายโดยเฉลี่ย หาได้จากสมการที่ 4, 4-1 และ 4-2 โดยค่า MAE หาได้จากสมการที่ 5 จะเปรียบเทียบกับเกณฑ์มาตรฐาน ในที่นี้จะใช้ค่าความผิดพลาดในการวัดของเครื่องมือวัดความชื้นซึ่งมีค่าเท่ากับ $\pm 2\%$

$$r^2 = 1 - \frac{SS_r}{SS_T} \quad (4)$$

โดยที่ SS_r คือ ค่าผลรวมกำลังสองของ residual
 SS_T คือ ค่าผลรวมกำลังสองทั้งหมด

$$SS_r = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (4-1)$$

$$SS_T = \sum_{i=1}^n (y_i - \bar{y}_i)^2 \quad (4-2)$$

โดยที่ y_i คือ ค่าจากการสังเกต
 \hat{y}_i คือ ค่าจากการทำนายสำหรับ y_i
 \bar{y}_i คือ ค่าเฉลี่ยของการสังเกต

$$MAE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (5)$$

โดยที่ y_i คือ ค่าจากการสังเกต
 \hat{y}_i คือ ค่าจากการทำนายสำหรับ y_i

6. ผลการทดลอง

งานวิจัยนี้การหาค่าสถาปัตยกรรมของแบบจำลอง ANN ที่เหมาะสม โดยได้แยกพิจารณาเป็น 2 กรณี กรณีแรกเป็นแบบจำลอง ANN ที่มีชั้นซ่อน 1 ชั้น และกรณีที่สองเป็นแบบจำลอง ANN ที่มีชั้นซ่อน 2 ชั้น ทั้งสองกรณีจะทำการแปรค่าจำนวนนิวรอน (neuron) จาก 5 ไปจนถึง 100 นิวรอน โดยทำการเพิ่มนิวรอนทีละ 5 นิวรอน (5, 10, 15, ..., 100) ทำการแปรช่วงเวลาย้อนหลังจากเวลาปัจจุบันจนถึงเวลาย้อนหลังที่ 20 ชั่วโมง โดยเพิ่มช่วงเวลาย้อนหลังทีละ 4 ชั่วโมง ดังนั้นเวลาย้อนหลังที่แปรทั้งหมด คือ เวลาปัจจุบัน, 4 ชั่วโมง, 8 ชั่วโมง, 12 ชั่วโมง, 16 ชั่วโมง และ 20 ชั่วโมง

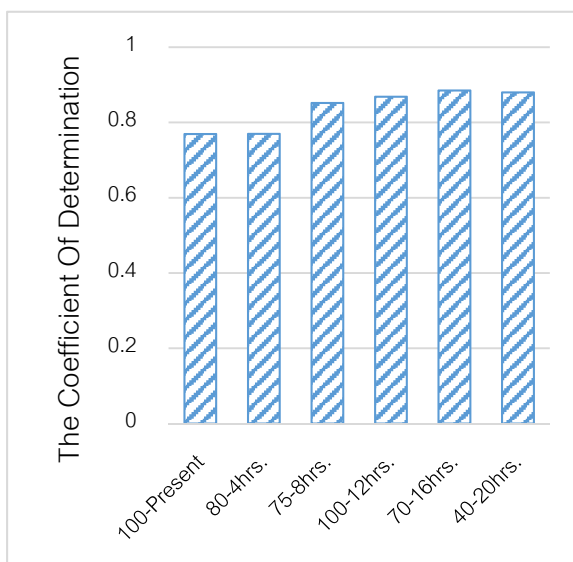
เพื่อความสะดวกในการเรียกชื่อแบบจำลองที่มีการแปรค่าสถาปัตยกรรมและเวลาย้อนหลัง ในงานวิจัยนี้จะกำหนดให้เรียกแบบจำลองโดยใช้สัญลักษณ์ที่บอกค่าจำนวนนิวรอน ในแต่ละชั้นซ่อนและเวลาย้อนหลัง เช่น แบบจำลอง xx-yy-z hrs จะหมายถึงแบบจำลองที่มีสถาปัตยกรรมแบบ 2 ชั้นซ่อน โดยชั้นซ่อนที่ 1 มี xx นิวรอน ชั้นซ่อนที่ 2 มี yy นิวรอน และใช้ข้อมูลย้อนหลัง z ชั่วโมง สำหรับในกรณีของแบบจำลองแบบ 1 ชั้นซ่อน จะใช้สัญลักษณ์แสดงสถาปัตยกรรม คือ xx-z hrs โดยจะมี xx นิวรอน (ในชั้นซ่อนที่ 1) และใช้ข้อมูลย้อนหลัง z ชั่วโมง

6.1 สถาปัตยกรรมแบบชั้นซ่อน 1 ชั้น


ประสิทธิภาพการทำนายของแบบจำลอง ANN ที่ดีที่สุดของแต่ละเวลาย้อนหลังแสดงอยู่ในตารางที่ 3, รูปที่ 7 แสดงการเปรียบเทียบค่า r^2 และรูปที่ 8 แสดงการเปรียบเทียบค่า MAE ของแบบจำลองที่ประสิทธิภาพดีที่สุดของแต่ละช่วงเวลาย้อนหลัง

ตารางที่ 3 ประสิทธิภาพของแบบจำลอง ANN ที่มีชั้นซ่อน 1 ชั้น

เวลาย้อนหลัง	จำนวนนิวรอน	The coefficient of determination	Mean Absolute Error (NTU)
ปัจจุบัน (t)	100	0.77	0.055
4 ชั่วโมง (t-1)	80	0.77	0.053
8 ชั่วโมง (t-2)	75	0.85	0.037
12 ชั่วโมง (t-3)	100	0.87	0.023
16 ชั่วโมง (t-4)	70	0.89	0.018
20 ชั่วโมง (t-5)	40	0.88	0.021



รูปที่ 7 การเปรียบเทียบค่า The coefficient of Determination ของแบบจำลอง 1 ชั้นซ่อน



รูปที่ 8 การเปรียบเทียบค่า Mean Absolute Error ของแบบจำลอง 1 ชั้นซ่อน

จะพบว่าสำหรับแบบจำลอง ANN ที่มีชั้นซ่อนหนึ่งชั้น ที่เวลาย้อนหลัง 16 ชั่วโมง ให้ประสิทธิภาพในการทำนายที่ดีที่สุด โดยมีจำนวนนิวรอนเท่ากับ 70 นิวรอน (70-16hrs.) โดยมีค่า r^2 เท่ากับ 0.89 และค่า MAE เท่ากับ 0.018 NTU และเมื่อเปรียบเทียบกับความคลาดเคลื่อนของเครื่องมือวัดความขุ่น (Turbidity Meter) ซึ่งมีค่าเท่ากับ $\pm 2\%$ และค่าความขุ่นที่ออกจาก Clarifier ที่ออกแบบประมาณ 5 NTU ดังนั้นค่าความคลาดเคลื่อนของการวัดจะมีค่าเท่ากับ ± 0.1 NTU ซึ่งมีค่ามากกว่าค่า MAE ของการทำนายด้วยแบบจำลอง ANN ที่มีชั้นซ่อนหนึ่งชั้น ดังนั้นประสิทธิภาพการ


ทำนายของแบบจำลอง ANN ที่มีชั้นซ่อนหนึ่งชั้นเป็นที่ยอมรับได้

6.2 สถาปัตยกรรมแบบชั้นซ่อน 2 ชั้น


ประสิทธิภาพการทำนายของแบบจำลอง ANN ที่ดีที่สุดของแต่ละเวลาย้อนหลังแสดงอยู่ในตารางที่ 4 โดยรูปที่ 9 แสดงการเปรียบเทียบค่า r^2 และรูปที่ 10 แสดงการเปรียบเทียบค่า MAE ของแบบจำลองแบบสองชั้นซ่อน และผลของการทำนายค่าความขุ่นที่ทำนายของน้ำที่ออกจาก Clarifier ของชุดทดสอบ (Test set) แสดงอยู่ในรูปที่ 11

ตารางที่ 4 ประสิทธิภาพของแบบจำลอง ANN ที่มีชั้นซ่อน 2 ชั้น


เวลาย้อนหลัง	นิวรอนชั้น ซ่อนที่ 1	นิวรอนชั้น ซ่อนที่ 2	The coefficient of determination	Mean Absolute Error (NTU)
ปัจจุบัน (t)	40	75	0.83	0.043
4 ชั่วโมง (t-1)	60	80	0.90	0.021
8 ชั่วโมง (t-2)	45	80	0.92	0.016
12 ชั่วโมง (t-3)	75	60	0.91	0.020
16 ชั่วโมง (t-4)	70	60	0.91	0.021
20 ชั่วโมง (t-5)	55	65	0.91	0.021



รูปที่ 9 การเปรียบเทียบค่า The coefficient of determination ของแบบจำลอง 2 ชั้นซ่อน



รูปที่ 10 การเปรียบเทียบค่า Mean Absolute Error ของแบบจำลอง 2 ชั้นซ่อน



รูปที่ 11 ผลของการทำนายค่าความขุ่นที่ทำนายของน้ำที่ออกจากClarifierในชุดทดสอบ test set

จะพบว่าสำหรับแบบจำลอง ANN ที่มีชั้นซ่อนสองชั้น ที่เวลาย้อนหลัง 8 ชั่วโมง ให้ประสิทธิภาพในการทำนายที่ดีที่สุด โดยมีจำนวนนิวรอนในชั้นซ่อนที่หนึ่งเท่ากับ 45 นิวรอน ชั้นซ่อนที่สองเท่ากับ 80 นิวรอน (45-80-8hrs.) โดยมีค่า r^2 เท่ากับ 0.92 และค่า MAE เท่ากับ 0.016 NTU และเมื่อเปรียบเทียบกับค่าความคลาดเคลื่อนของการวัดจะมีค่าเท่ากับ ± 0.1 NTU ซึ่งมีค่ามากกว่าค่า MAE ของการทำนายด้วยแบบจำลอง ANN ที่มีชั้นซ่อนสองชั้น ดังนั้นประสิทธิภาพการทำนายของแบบจำลอง ANN ที่มีชั้นซ่อนสองชั้นเป็นที่ยอมรับได้

7. วิจารณ์ผลการทดลอง

ผลการทำนายของแบบจำลองทั้งชนิดหนึ่งชั้นซ่อนและสองชั้นซ่อนเป็นที่ยอมรับได้เนื่องจากค่า MAE ของแบบจำลองทั้งสองแบบมีค่าต่ำกว่าค่าความคลาดเคลื่อนของเครื่องมือวัดความขุ่น (0.1 NTU)

ถึงแม้ว่าแบบจำลองทั้งสองให้ประสิทธิภาพการทำนายใกล้เคียงกัน และมีค่า MAE น้อยกว่าค่าความคลาดเคลื่อนของเครื่องมือ แบบจำลองหนึ่งชั้นซ่อน (70-16hrs.) จะต้องใช้ข้อมูลย้อนหลังในการทำนาย 16 ชั่วโมง ซึ่งมากกว่าแบบจำลองสองชั้นซ่อน (45-80-8hrs.) จะใช้ข้อมูลย้อนหลังเพียง 8 ชั่วโมง ทั้งนี้อาจมาจากสาเหตุที่แบบจำลองสองชั้นซ่อน มีจำนวนนิวรอน 125 (45+80) นิวรอน ซึ่งมากกว่าจำนวนนิวรอนหนึ่งชั้นซ่อน (70 นิวรอน) ซึ่งสามารถให้การคำนวณและผลการทำนายได้แม่นยำกว่า

เมื่อพิจารณาค่าเวลากักเก็บน้ำ (Hydraulic Retention Time, HRT) ซึ่งใช้ในการออกแบบถัง Clarifier ซึ่งมีค่าประมาณ 2-3.5 ชั่วโมง [18] ซึ่งเป็นเวลาที่น้ำจะอยู่ในถังนี้ จะเห็นว่าค่านี้น้อยกว่าค่าเวลาย้อนหลังของข้อมูลที่ต้องการทั้งสองแบบจำลอง (45-80-8hrs.) และ (70-16hrs.) ถึง 8 และ 16 ชั่วโมง หรืออีกนัยหนึ่งหมายความว่าผลของการเปลี่ยนแปลงตัวแปรใดๆ ในช่วง 8-16 ชั่วโมง จะมีผลต่อค่าความขุ่นของน้ำที่ออกจาก Clarifier ถึงแม้ว่าน้ำดิบที่เข้ามาในถังจะใช้เวลาอยู่ในถัง Clarifier เพียง 2-3.5 ชั่วโมงก็ตาม ปรากฏการณ์ที่

กล่าวนี้อาจอธิบายได้จากการหมุนเวียนของตะกอนเก่า (Slurry Recirculation) เพื่อช่วยให้เกิดตะกอนใหม่ใน Clarifier ตะกอนดังกล่าวนี้ไม่ได้ออกไปพร้อมกับน้ำ ซึ่งมีเวลาอยู่ในถัง Clarifier เกินกว่าช่วงเวลากักเก็บน้ำ (HRT) และผลของการเปลี่ยนแปลงใดๆที่เกิดขึ้นในอดีต จะยังมีผลต่อตะกอนดังกล่าวแล้วจึงเป็นผลกระทบกับสภาพปัจจุบัน

8. สรุปผลการทดลอง

จากผลการศึกษาและทดลองจะพบว่าแบบจำลองโครงข่ายประสาทเทียมสำหรับทำนายค่าความขุ่นที่ออกจาก Clarifier โดยใช้ข้อมูลตัวแปรทั้งหมดจำนวน 10 ตัวแปร ซึ่งจะใช้ตัวแปรที่ประกอบด้วยข้อมูลในเวลาปัจจุบัน และข้อมูลเวลาย้อนหลัง 4, 8, 12, 16, และ 20 ชั่วโมง โดยมีจำนวนชั้นซ่อน 1 และ 2 ชั้นซ่อนพบว่าแบบจำลอง ANN ที่มีชั้นซ่อนจำนวนหนึ่งชั้น (70-16hr) r^2 เท่ากับ 0.89 ค่า MAE เท่ากับ 0.018 สำหรับแบบจำลอง ANN ที่มีชั้นซ่อนจำนวนสองชั้นให้ผลดีกว่า โดยแบบจำลอง (45-80-8hr) ค่า r^2 เท่ากับ 0.92 และ ค่า MAE เท่ากับ 0.016 NTU

ประสิทธิภาพของการทำนายของแบบจำลองเป็นที่ยอมรับได้ เนื่องจากให้ค่าความผิดพลาดน้อยกว่าความคลาดเคลื่อนของเครื่องมือวัด อย่างไรก็ตามแบบจำลองแบบสองชั้นซ่อน (45-80-8hrs.) เป็นแบบจำลองที่มีศักยภาพสูงกว่าเนื่องจากใช้เวลาย้อนหลังน้อยกว่า

9. กิตติกรรมประกาศ

ขอขอบคุณการประสานนครหลวง Metropolitan Waterworks Authority (Thailand). www.mwa.co.th สำหรับข้อมูลที่ใช้ในงานวิจัยนี้

10. เอกสารอ้างอิง

- [1] Metropolitan Waterworks Authority(Thailand). *มาตรฐานคุณภาพน้ำประปาของการประปาฯ นครหลวง* [ระบบออนไลน์], แหล่งที่มา : www.mwa.co.th

- [2] Gurney K., "An introduction to neural networks," *UCL Press*, London, UK, 1997.
- [3] Metropolitan Waterworks Authority(Thailand). *กรรมวิธีการผลิต การประปานครหลวง*. [ระบบออนไลน์], แหล่งที่มา: www.mwa.co.th
- [4] Fausett, L., "Fundamentals of Neural Networks," *Prentice Hall*, Inc., New jersey. pp.461, 1994.
- [5] Masters, T., "Practical Neural Network Recipes in C++," *California: Academic Press*, Inc., 1993.
- [6] H.R. Maier, and G.C. Dandy, "Neural Networks for the Prediction and Forecasting of Water Resources Variables: a Review of Modeling Issues and Applications," *Environmental Modeling & Software.*, vol.15, pp.101-124, 2000.
- [7] Demuth H., Beale M., and Hagan M. "Neural Network Toolbox 5: Use's Guide," *The MathWorks, Inc.*, Natick, U.S.A., 2006.
- [8] Maren, A.J., C.T. Harston and R.M. Pap., "Handbook of Neural Computing Application," *Academic Press*, Inc., San Diego. pp.448, 1990.
- [9] G.J. Bowden, H.R. Maier, and G.C. Dandy, "Optimal division of data for neural network models in water resources applications," *Water Resour. Res.*, vol.38, no. 2, pp.1010, 2002.
- [10] Haan, C.T., "Statistical Methods in Hydrology," *The Iowa State University Press-Ames*, Iowa. pp.378, 1977.
- [11] Ikonen E. and Najim K., "Advanced Process Identification and Control," *Marcel Dekker Inc.*, New York, U.S.A., pp.310, 2002.
- [12] A.C.S. Filho, F.M.H. Silva, F.G. Lima, et al., "Using the Lag of Autocorrelation Function in Order to Identify the Anaerobic Threshold During Dynamic Physical Exercise," *Computers in Cardiology*, vol.33, pp.625-628, 2006.
- [13] Haykin, S.S., "Neural networks: a comprehensive foundation," *Prentice Hall*, pp. 842, 1999.
- [14] Box, G.E.P., Jenkins, G.M., and G.C. Reinsel., "Time Series Analysis Forecasting and Control," 3rd ed. *Prentice Hall*, Inc., New Jersey. pp.598, 1994.
- [15] Hagan, M.T., Demuth, H.B., Beale, M.H., "Neural Network Design," *PWS Publishing*, Boston, MA, 1996.
- [16] Tarassenko, L., "A Guide to Neural Computing Applications." *Arnold*, London, 1998.
- [17] Demuth, H., and Beale, M., "Neural network toolbox." *The MathWorks Inc.*USA., 2000.
- [18] Degremont, "Water Treatment Handbook," 6th Ed., *Lavoisier Publishing*, Paris, 1991.