

บทที่ 2

ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

2.1 มลพิษทางน้ำ

น้ำเสียตามพระราชบัญญัติส่งเสริมและรักษาสิ่งแวดล้อมแห่งชาติ หมายถึง ของเสียที่อยู่ในสภาพที่เป็นของเหลวรวมทั้งมวลสารที่ปะปนหรือปนเปื้อนอยู่ในของเหลวนั้น ลักษณะของน้ำเสียแบ่งออกได้ 3 ด้าน คือ ด้านกายภาพ ด้านเคมี และด้านชีวภาพ

1. ลักษณะของน้ำเสียทางกายภาพ เช่น

- ปริมาณของแข็งที่ละลายน้ำได้ทั้งหมด หมายถึง ปริมาณของแข็งที่ละลายน้ำและสามารถไหลผ่านกระดาษกรองใยแก้ว แล้วนำน้ำไปที่กรองได้ ไประเหยจนแห้ง แล้วจึงนำไปอบ
- ของแข็งแขวนลอย หมายถึง ปริมาณของแข็งแขวนลอยที่เหลือค้ำบนกระดาษกรองใยแก้ว
- ความขุ่น หมายถึง สมบัติทางแสงของสารแขวนลอยซึ่งทำให้แสงกระจาย และดูดกลืนมากกว่าที่จะอมให้แสงผ่านเป็นเส้นตรง ความขุ่นของน้ำเกิดการมีสารแขวนลอยต่างๆ เช่น ดิน ดินตะกอน

2. ลักษณะของน้ำเสียทางเคมี เช่น

- ออกซิเจนละลาย การหาดีไอ(DO)หรือออกซิเจนละลาย สามารถทำได้ทั้งวิธีทางเคมี และใช้เครื่องวัดโดยตรง
- บีโอดี(BOD)หมายถึง ปริมาณออกซิเจนที่ใช้ในการย่อยสลายสารอินทรีย์โดยแบคทีเรีย
- ซีโอดี(COD)หมายถึง ปริมาณออกซิเจนทั้งหมดที่ต้องการใช้เพื่อออกซิเดชันสารอินทรีย์ในน้ำด้วยสารเคมีซึ่งมีอำนาจในการออกซิไดส์สูงในสารละลายที่เป็นกรด ให้เป็นก๊าซคาร์บอนไดออกไซด์ในน้ำ ค่าซีโอดีมีความสำคัญในการวิเคราะห์คุณภาพน้ำทั้ง การควบคุมระบบบำบัดน้ำทั้ง การควบคุมระบบบำบัดน้ำเสีย ค่า COD นี้มีหน่วยเป็น มิลลิกรัม/ลิตร
- ค่าความกรด-ด่าง(pH)มีความสำคัญในการควบคุมคุณภาพน้ำและน้ำเสียควบคุมให้เหมาะสมกับการเจริญเติบโตของสิ่งมีชีวิต เพื่อไม่ให้เกิดการกัดกร่อนของท่อ เพื่อใช้ในการควบคุมสารเคมีที่ใช้บำบัดน้ำเสียให้ทำงานได้อย่างมีประสิทธิภาพ โดยทั่วไปน้ำมีค่า pH อยู่ในช่วง 5-8 ค่า pH เป็นค่าที่แสดงปริมาณความเข้มข้นของอนุภาคไฮโดรเจนในน้ำ
- ไนโตรเจน เป็นธาตุที่มีความสำคัญในการสังเคราะห์โปรตีน ทำให้พืชน้ำมีการเจริญเติบโตได้อย่างรวดเร็ว
- สารโลหะหนักชนิดต่างๆขึ้นอยู่กับชนิดของอุตสาหกรรม สารโลหะหนักยอมให้มีได้ในน้ำในปริมาณที่น้อยมากเนื่องจากบางตัวให้ความเป็นพิษสูง แต่บางชนิดหากที่ปริมาณไม่มากนักจะมีผลต่อสิ่งมีชีวิตในน้ำ

3. ลักษณะของเสียทางชีวภาพ เช่น

- แบคทีเรีย คือ จุลินทรีย์เซลล์เดียว มีขนาดเล็ก ไม่สามารถมองเห็นได้ด้วยตาเปล่า เป็นผู้ย่อยสลายในแหล่งน้ำ
- รา เป็นจุลินทรีย์ที่มีหลายเซลล์ ไม่มีคลอโรฟิลล์ ราคามีความสำคัญในการย่อยสลายพวกคาร์บอนที่มีค่า pH ต่ำ ราคามีบทบาทสำคัญในการย่อยสลายสารอินทรีย์ในระบบบำบัดน้ำเสียบางระบบ

โดยแหล่งกำเนิดน้ำเสียสามารถ แบ่งได้หลักๆดังนี้

1. น้ำเสียจากชุมชน หมายถึง น้ำที่เกิดจากการใช้ประโยชน์ในกิจกรรมต่างๆ และระบายน้ำทิ้งลงสู่ท่อระบายน้ำ แหล่งรองรับน้ำเสีย หรือแหล่งน้ำธรรมชาติ โดยไม่ได้ผ่านการบำบัด

2. หาปริมาณออกซิเจนที่จุลินทรีย์ใช้ย่อยสลายสารอินทรีย์ต่างๆในน้ำเสีย วิธีนี้ถือว่าเป็นวิธีทางชีววิทยา

3. หาปริมาณจุลินทรีย์ในน้ำ

4. วัดความเข้มข้นของสารต่างๆที่ละลายอยู่ในน้ำ

2.2 การประมาณค่าระดับออกซิเจน

การประมาณการค่าออกซิเจนที่มีอยู่ในน้ำสามารถบ่งบอกถึงการเปลี่ยนแปลงของคุณภาพน้ำและช่วยในการประเมินการเผ่าระวัง วางแผนจัดการป้องกันและแก้ไขปัญหาคอนคุณภาพน้ำได้อย่างเหมาะสม โดยเฉพาะบริเวณที่มีแนวโน้มระดับมลพิษน้ำสูงหรือเป็นบริเวณที่มีประชากรในกลุ่มที่มีผลกระทบต่อระดับมลพิษทางน้ำ เช่น บริเวณอาคารบ้านเรือนที่อยู่ริมน้ำ การคมนาคมทางน้ำ เป็นต้น ซึ่งจำเป็นต้องทราบระดับคุณภาพทางน้ำ การตรวจวัดจริงเป็นวิธีการที่ใช้ดำเนินการศึกษาที่นิยมใช้ แต่การตรวจวัดจริงนั้นทำได้จำกัด เช่น สามารถตรวจวัดได้เพียงชั่วระยะเวลาหนึ่ง หรือบางครั้งต้องใช้เวลามาก ความไม่เพียงพอของจำนวนเครื่องมือและงบประมาณมีจำนวนจำกัด ดังนั้น การประมาณระดับออกซิเจนที่เป็นพารามิเตอร์หลักตัวหนึ่งที่สามารถบ่งบอกถึงระดับคุณภาพน้ำได้โดยการใช้แบบจำลองโครงข่ายใยประสาทประดิษฐ์ ซึ่งเป็นอีกแนวทางของการเผ่าระวังคุณภาพน้ำและลดข้อจำกัดของการตรวจวัดจริง


2.3 โครงข่ายใยประสาทประดิษฐ์

แบบจำลองโครงข่ายใยประสาทประดิษฐ์ ประกอบด้วย ระบบการคำนวณแบบไม่เป็นเชิงเส้นซึ่งมีวิธีการดำเนินระบบเป็นแบบขนานและมีรูปแบบการเรียนรู้แบบโครงข่ายใยประสาทชีวภาพ(Lippmann, 1987) โดยประกอบไปด้วยนิวรอล (หรือ โหนด หรือ หน่วยประมวลผล) ซึ่งรวมกันอยู่เป็นชั้น ๆ ซึ่งสามารถรับข้อมูลเข้าได้หลายค่า และสามารถคำนวณผล โดยจะให้ผลลัพธ์ค่าเดียวหรือหลายค่าก็ได้ (Klimasauskas, 1993) ซึ่งการคำนวณในระบบประกอบไปด้วยฟังก์ชันง่าย ๆ เช่นฟังก์ชันการรวม และ ฟังก์ชันการคูณ (Arciszewski and Ziarko, 1992) โดยมีความสามารถในการเรียนรู้จากตัวอย่างหลาย ๆ ตัวอย่าง ซึ่งจะหาแนวทางการแก้ปัญหา แม้แต่ข้อมูลที่ถูกป้อนเข้ามาไม่สมบูรณ์หรือผิดพลาด ระบบจะเปรียบเทียบกับผลลัพธ์ที่คลาดเคลื่อน และปรับเปลี่ยนวิธีการ

ประมวลผลเพื่อให้ผลลัพธ์ถูกต้องที่สุด ระบบจะประมวลผลข้อมูลโดยคอมพิวเตอร์อย่างรวดเร็ว (Flood and Kartam, 1994)

2.3.1 แนวคิดพื้นฐานของโครงข่ายประสาทประดิษฐ์

Lippmann (1987), Chester (1993) และ Kireetoh (1995) ได้อธิบายถึงนิเวศวิทยาของโครงข่ายประสาทของมนุษย์ โดยรับสัญญาณข้อมูลที่ส่งเข้ามา และจะถูกกระตุ้น แต่ละเซลล์ประกอบด้วย ปลายในการรับกระแสประสาท เรียกว่า "เดนไดรต์" (Dendrite) ซึ่งเป็นข้อมูลป้อนเข้า และปลายในการส่งกระแสประสาท เรียกว่า "แอกซอน" (Axon) ดังรูปที่ 2.3 ซึ่งเป็นเหมือนข้อมูลที่ส่งออกมาของเซลล์ เซลล์เหล่านี้ทำงานด้วยปฏิกิริยาไฟฟ้าเคมี เมื่อมีการกระตุ้นด้วยสิ่งเร้าภายนอกหรือกระตุ้นด้วยเซลล์ด้วยกัน กระแสประสาทจะวิ่งผ่านเดนไดรต์เข้าสู่นิวเคลียส ซึ่งจะเป็นตัวตัดสินใจว่าต้องกระตุ้นเซลล์อื่น ๆ ต่อหรือไม่ ถ้ากระแสประสาทแรงพอ นิวเคลียสก็จะกระตุ้นเซลล์อื่น ๆต่อไปผ่านทางแอกซอนของมัน ผลการกระตุ้นด้วยสิ่งเร้าที่เหมือนหรือมีลักษณะพิเศษบางอย่างเหมือนกัน จะให้ผลลัพธ์สุดท้ายเป็นค่าที่ค่อนข้างแน่นอน



รูปที่ 2.1 โครงสร้างระบบประสาทในสมอง

โครงข่ายประสาทประดิษฐ์เป็นปัญญาประดิษฐ์ (Artificial Intelligence) ที่สร้างเลียนแบบระบบประสาทของมนุษย์ (Lippmann, 1987; Caudill and Butler, 1990; Klimasauskas, 1993; Medsker et al., 1993) โดยระบบการทำงานต่าง ๆ ของโครงข่ายประสาทประดิษฐ์มีลักษณะคล้ายกับระบบประสาทของมนุษย์ คือ มีการเรียนรู้จากประสบการณ์ที่ได้รับ และสามารถให้คำตอบได้แม้แต่ข้อมูลที่ป้อนเข้าจะผิดพลาด หรือไม่สมบูรณ์ โดยหาวิธีการแก้ปัญหาจากประสบการณ์การเรียนรู้ที่ผ่านมา และสามารถที่จะพัฒนาให้ไปเป็นโปรแกรมที่สามารถโต้ตอบกับมนุษย์ได้

2.3.2 การสร้างแบบจำลองโครงข่ายประสาทประดิษฐ์

โครงข่ายประสาทประดิษฐ์ คือ เครื่องจักรการเรียนรู้ ตั้งอยู่บนพื้นฐานความคิดเกี่ยวกับการปรับปรุงตัวแปรควบคุมต่าง ๆ ภายในด้วยตัวมันเอง โดยมีองค์ประกอบภายในระบบซึ่งประกอบไปด้วย 5 องค์ประกอบหลัก คือ หน่วยการเรียนรู้, โครงข่ายประสาท, แผนการเรียนรู้,

กระบวนการเรียนรู้ และ กระบวนการวิเคราะห์ (Adeli, 1992) ซึ่ง Elazouni et al. (1997) ได้จำแนกส่วนประกอบของโครงข่ายประสาทประดิษฐ์ เป็น 3 ชั้น คือ 1) การออกแบบ 2) การสร้างแบบจำลอง และ 3) การทดสอบและหาผลลัพธ์โดยชั้นการออกแบบจะประกอบไปด้วย 2 ส่วน คือ การวิเคราะห์โครงสร้างของปัญหา และการวิเคราะห์ปัญหา ส่วนชั้นการสร้างแบบจำลอง จะแบ่งย่อยออกเป็น 3 ขั้นตอนคือ 1) การเลือกข้อมูล 2) การเลือกรูปแบบโครงข่าย 3) การสอนและการทดสอบโครงข่าย

2.3.3 ข้อมูลป้อนเข้า

โครงข่ายประสาทประดิษฐ์ ประกอบไปด้วยตัวแปรอิสระ หรือ ข้อมูลป้อนเข้าและตัวแปรตาม หรือ ผลลัพธ์ โดยหลักการเลือกตัวแปรที่ใช้ในโครงข่ายที่เกี่ยวข้องจะมี 2 แบบ (Smith, 1993) คือ วิธีแรก ข้อมูลจะต้องถูกแปลงรูปให้อยู่ในรูปที่เหมาะสม และวิธีที่สอง คือการเลือกข้อมูลโดยใช้พื้นฐานระหว่าง predictiveness และ covariance โดยปกติแล้ว ตัวแปรอิสระที่ถูกเลือกจะมีความสามารถในการทำนายผลหากตัวแปรที่เลือกมีความสัมพันธ์กันในทางตรงกันข้ามหากตัวแปรอิสระ 2 ตัวมีความสัมพันธ์ต่อกัน จะทำให้แบบจำลองมีความอ่อนไหว (sensitive) และเกิดปัญหาที่เรียกว่า over fitting และ limit generalization ด้วยเหตุผลนี้ การเลือกข้อมูลจะต้องเลือกเฉพาะตัวแปรอิสระที่มีความสามารถทำนายผลเพื่อให้ได้ ผลลัพธ์หรือตัวแปรตาม โดยตัวแปรอิสระที่เลือกมานั้นจะต้องไม่มีความสัมพันธ์กัน แต่อย่างไรก็ดี ก็ขึ้นอยู่กับรูปแบบของโครงข่ายที่ใช้และเพื่อที่จะลดจำนวนตัวอย่างที่ใช้ในการสอนและเวลาที่ใช้ในการเรียนรู้ ก็ควรจะต้องมีการคัดเลือกข้อมูลป้อนเข้าให้เหมาะสม เพราะการคัดเลือกข้อมูลเป็นปัจจัยที่สำคัญในการสร้างแบบจำลอง (Wu and Lim, 1993)

2.3.4 ชั้นซ่อน (Hidden Layer)

ชั้นซ่อนเป็นชั้นประมวลผลที่อยู่ระหว่างชั้นข้อมูลป้อนเข้า และชั้นแสดงผลโดยปกติแล้ว ชั้นซ่อนอาจมีมากกว่า 1 ชั้น โดยโครงข่ายจะสามารถประมวลหาฟังก์ชันที่เหมาะสมจากปัญหาที่ซับซ้อนได้หากมีชั้นซ่อนที่มากพอ (Lippmann, 1987) ข้อมูลที่ได้จากชั้นซ่อนจะได้เป็นตัวแปรใหม่ที่จะถูกส่งต่อไปให้กับชั้นแสดงผล หรือชั้นตัวแปรตาม ถ้าโครงข่ายแบบแพร่กลับ (Back-propagation) มีชั้นซ่อนที่น้อยเกินไปแล้วจะทำให้โครงข่ายไม่สามารถที่จะหาทางแก้ปัญหาได้ (Karunasekera, 1992) แต่ถึงอย่างไรก็ตามถ้าเกิดโครงข่ายมีชั้นซ่อนที่มากจนเกินไป จะทำให้โครงข่ายมีระยะเวลาในการเรียนรู้นาน William (1993) ได้ให้ข้อคิดเห็นว่า หากมีชั้นซ่อนที่มากก็ไม่ช่วยให้โครงข่ายมีประสิทธิภาพมากขึ้น หรืออีกนัยหนึ่ง Rumelhart (1988) ได้กล่าวว่าการที่มีโหนดในแต่ละชั้นที่มากเกินไป จะทำให้โครงข่ายไม่สามารถที่จะหาจุดสิ้นสุดได้ การที่มีโหนดในชั้นซ่อนมากเกินไปจะทำให้เกิดปัญหาที่เรียกว่า over fitting โดยโครงข่ายจะจำลองโครงสร้างใหม่เกินความเป็นจริงจาก noise ของข้อมูล แทนที่จะหาฟังก์ชันที่เหมาะสมในการวิเคราะห์ปัญหาให้ถูกต้องตามที่ควรจะเป็น (Smith, 1993) ดังนั้น การที่จะทำให้โครงข่ายเกิดประสิทธิภาพสูงสุด ต้องกำหนดให้มีโหนดในชั้นซ่อนอยู่ให้น้อยเท่าที่จะเป็นไปได้ (Khan, Topping and Bahreininejad, 1993) Berke และ Hajela (1991) ได้ให้ความเห็นว่า จำนวนของโหนดในชั้นซ่อนควรอยู่ระหว่างค่าเฉลี่ยของผลรวมของโหนดในชั้นข้อมูลป้อนเข้า และชั้นแสดงผล Rogers และ Ramarsh (1992) ได้ให้ข้อคิดเห็น


ว่าในการกำหนดโหนดในชั้นซ่อนควรจะดูจากผลรวมของโหนดในชั้นข้อมูลป้อนเข้าและชั้นแสดงผล Soemardi (1996) ได้แสดงความเห็นว่า จำนวนโหนดในชั้นซ่อนควรมีค่าเท่ากับร้อยละ 75 ของโหนดในชั้นข้อมูลป้อนเข้า ดังนั้นจึงสรุปจากข้อคิดเห็นได้ว่าจำนวนโหนดในชั้นซ่อนที่มากที่สุดควร จะเท่ากับผลรวมของโหนดในชั้นข้อมูลป้อนเข้า และชั้นแสดงผล และจำนวนโหนดที่น้อยที่สุด ควรจะเท่ากับร้อยละ 75 ของโหนดในชั้นข้อมูลป้อนเข้า หรือ เท่ากับค่าเฉลี่ยของผลรวมของโหนดใน ชั้นข้อมูลป้อนเข้าและชั้นแสดงผล

2.3.5 ค่าถ่วงน้ำหนักและไบแอส (Weights and biases)

ค่าถ่วงน้ำหนักถูกแทนด้วยตัวเลขเพื่อแสดงถึงความแรงในการเชื่อมต่อของโหนดแต่ละ โหนดที่ถูกเชื่อมต่อเข้าด้วยกัน ซึ่งผลรวมของค่าถ่วงน้ำหนักที่ป้อนเข้าจะไปปรับปรุงการประมวลผลใน แต่ละโหนด ค่าถ่วงน้ำหนักคือค่าความแรงสัมพัทธ์ (ในทางคณิตศาสตร์) ของการเชื่อมต่อซึ่งส่งผลต่อ การส่งผ่านข้อมูลจากชั้นหนึ่งไปยังชั้นต่อไป (Medsker et al., 1993) โดยปกติค่าถ่วงน้ำหนักจะถูก กำหนด และเริ่มป้อนเข้าสู่โครงข่ายในขั้นตอนการเรียนรู้ ซึ่งต้องมีหลักการในการกำหนดค่า เพื่อที่จะให้โครงข่ายสามารถแก้โจทย์ปัญหา และลดเวลาการเรียนรู้ได้ สำหรับโครงข่ายใด ๆ ค่าถ่วง น้ำหนักจะมีค่าเท่ากับผลคูณของจำนวนโหนดของทุก ๆ การเชื่อมต่อ และค่าของไบแอสจะเท่ากับ ผลรวมของจำนวนโหนดของทุก ๆ การเชื่อมต่อ

2.3.6 ฟังก์ชันการรวมและฟังก์ชันการแปลงค่า (Summation and transfer function)

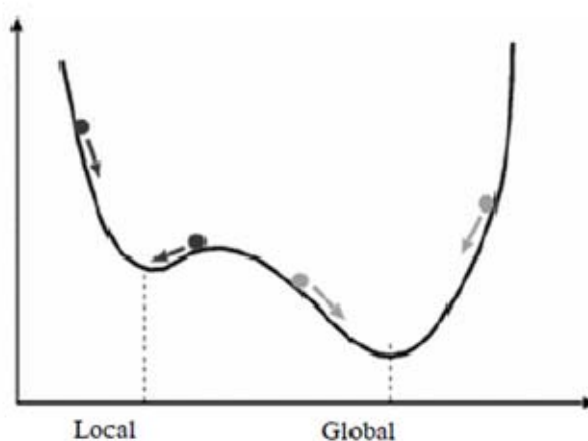
ฟังก์ชันการรวม คือ ฟังก์ชันการหาผลเฉลี่ยค่าถ่วงน้ำหนักของทุก ๆ โหนดที่เชื่อมต่อกัน โดยมีขั้นตอนคือ นำค่าของข้อมูลป้อนเข้า (Input) ในแต่ละโหนดคูณกับค่าถ่วงน้ำหนักของแต่ละ โหนดและรวมผลลัพธ์ของทุก ๆ โหนดเข้าด้วยกัน ดังรูปที่ 2.5 ส่วนฟังก์ชันการแปลงค่าคือ ความสัมพันธ์ระหว่างระดับการกระตุ้นภายในโหนด (N) กับผลลัพธ์ที่ได้ (Output) โดยจะอยู่ในรูป ของฟังก์ชันซิกมอยด์ $f(N)$ โดยมีข้อแม้ว่า 1) มีความต่อเนื่อง 2) ค่าของฟังก์ชันซิกมอยด์จะต้องเพิ่มขึ้น เมื่อ N เพิ่มขึ้น (Smith, 1993)



รูปที่ 2.2 กระบวนการทำงานของโครงข่ายประสาทประดิษฐ์ในโหนดย่อย

2.3.7 อัตราการเรียนรู้และโมเมนตัม (Learning rate and momentum)

ถ้าโครงข่ายที่มีอัลกอริทึมแบบแพร่กลับ (Back-propagation) มีขนาดที่ใหญ่และมีชุดการสอนโครงข่ายที่ใหญ่จะทำให้โครงข่ายมีการเรียนรู้ที่แน่นอน (Khan et al., 1993) โครงข่ายแบบแพร่กลับ จะมีข้อจำกัด คือ ไม่สามารถกำหนดเวลาในการเรียนรู้ที่แน่นอนได้ โดยโครงข่ายมีโอกาสที่จะหลงทาง ไม่สามารถค้นหาคำตอบที่มีความผิดพลาดน้อยที่สุด ทำให้พบกับคำตอบที่ local minimum ก่อนที่จะพบ global minimum ได้ ดังรูปที่ 2.6 ดังนั้นจึงมีความสำคัญอย่างยิ่งในการเลือกอัตราการเรียนรู้ และค่าโมเมนตัมที่เหมาะสม สำหรับการใช้อัลกอริทึมแบบแพร่กลับ แต่ถึงอย่างไรก็ดีหลักการในการหาอัตราการเรียนรู้ และค่าโมเมนตัมที่เหมาะสม คือ ต้องใช้วิธีลองผิดลองถูก (trial-and-error) (Anderson et al., 1993)



รูปที่ 2.3 แสดงจุด local minimum และ global minimum

เมื่ออัตราการเรียนรู้สูงจะส่งผลให้การเรียนรู้เป็นไปอย่างรวดเร็วซึ่งอาจจะทำให้การเรียนรู้จบลงที่ local minimum แต่ในทางตรงกันข้าม หากให้โครงข่ายมีอัตราการเรียนรู้ที่ต่ำจะทำให้เวลาที่ใช้ในการเรียนรู้เพื่อให้เข้าใกล้ global minimum นานขึ้น (Khan et al., 1993) ซึ่งสำหรับในแต่ละชั้นของโครงข่ายเดียวกันอาจมีค่าอัตราการเรียนรู้แตกต่างกันได้ (Bhokha, 1998) สำหรับการแก้ปัญหาที่เกิดขึ้นนี้ทำได้ด้วยการปรับอัตราการเรียนรู้ ซึ่งจะนำไปคูณกับค่าถ่วงน้ำหนักที่ถูกปรับแก้ในรอบที่ผ่านมา ทำให้อัตราการเรียนรู้เร็วขึ้น (Khan et al., 1993)

2.3.8 กระบวนการสอนหรือการเรียนรู้ (Training or Learning)

กระบวนการเรียนรู้เป็นกระบวนการหนึ่งในโครงข่ายที่เรียนรู้จากความผิดพลาดโดยมีหลักการ 3 ข้อ คือ 1) คำนวณหาคำตอบ 2) ตรวจสอบคำตอบว่าถูกต้องหรือไม่ 3) ปรับแก้ค่าถ่วงน้ำหนักแล้วคำนวณใหม่อีกครั้ง (Medsker et al., 1993) กระบวนการสอน คือ การนำข้อผิดพลาดจากการคำนวณครั้งก่อนมาปรับแก้ค่าถ่วงน้ำหนักให้กับการสอนในรอบต่อไป ทำให้คำตอบที่ได้มีความถูกต้องสูงขึ้น (Klimasauskas, 1993)


ในขั้นตอนการเรียนรู้จะเป็นกระบวนการที่เกี่ยวข้องกับ การปรับค่าน้ำหนักของแต่ละ โหนด โดยอาศัยจากประสบการณ์การเรียนรู้ของโครงข่าย การเรียนรู้ของโครงข่ายในแต่ละรอบจะนำ ผลลัพธ์ที่ประมวลได้ มาเปรียบเทียบกับค่าจริงที่ได้จากการทดลอง ซึ่งอาจจะมีคลาดเคลื่อน หลังจากนั้นโครงข่ายจะย้อนกลับไปเรียนรู้ในรอบต่อไปพร้อมกับการปรับแก้ค่าถ่วงน้ำหนักเพื่อให้การ ประมวลผลรอบต่อไปมีความแม่นยำมากขึ้น Bhokha (1998) ได้กล่าวว่าการปรับแก้ค่าถ่วงน้ำหนักจะเป็นการ ปรับขึ้นหรือปรับลงก็ได้ Klimasauskas (1993) กล่าวว่า การวัดผลว่าโครงข่ายสามารถเรียนรู้ได้ดี เพียงใดจะดูจากตัวชี้วัดต่าง ๆ เช่น ค่าความคลาดเคลื่อนกำลังสองเฉลี่ย(mean square error) ในชั้น แสดงผลลัพธ์Lippmann (1987) และ Smith (1993) ได้กล่าวไว้ว่า กระบวนการเรียนรู้สามารถแบ่ง ออกเป็น 2 ลักษณะ คือ

1) การเรียนรู้แบบมีครูสอน (supervised training) ซึ่งจะประกอบไปด้วย คู่อันดับของ ข้อมูลป้อนเข้า และผลลัพธ์จริง ซึ่งเมื่อโครงข่ายเริ่มการเรียนรู้จากข้อมูลป้อนเข้า และคำนวณหา ผลลัพธ์ได้แล้ว จึงจะนำไปเปรียบเทียบกับผลลัพธ์จริง เพื่อหาความคลาดเคลื่อนซึ่งความคลาดเคลื่อน ดังกล่าวจะถูกส่งกลับเข้าไปยังโครงข่ายพร้อมกับการปรับแก้ค่าถ่วงน้ำหนักเพื่อให้โครงข่ายคำนวณ ผลลัพธ์ใหม่ให้มีความคลาดเคลื่อนน้อยที่สุด

2) การเรียนรู้แบบไม่มีครูสอน (unsupervised training) ได้คิดค้นโดย Kohonen (1984) ซึ่งแตกต่างจากแบบจำลองที่เลียนแบบระบบสมองของมนุษย์ โดยไม่ต้องใช้ผลลัพธ์จริงมาทำ การเปรียบเทียบ แต่จะใช้คุณสมบัติทางสถิติของข้อมูลชุดทดสอบมาจัดกลุ่มเป็นหมวดหมู่หลังจากที่ ป้อนข้อมูลเข้าไปแล้ว แบบจำลองจะทำการประมวลผลลัพธ์ที่เป็นไปได้ออกมาเป็นชุด ๆ (Heaton, 2004)

2.3.8.1 การเรียนรู้แบบแพร่กลับ (Back-propagation)


ในช่วงปี 1950 Rosenblatt ได้สร้างโครงข่ายชั้นเดียวแบบง่าย ๆ ขึ้นมาโดยมีชื่อ เรียกว่า perceptron หลังจากนั้นต่อมา Widrow และ Hoff ได้สร้างอัลกอริทึมขึ้นมาใหม่ที่สามารถ อธิบายได้ด้วยกฎของเดลตา (Delta rule) โดยใช้การเรียนรู้ข้อมูลที่มีการปรับค่าถ่วงน้ำหนักซึ่งมีชื่อ เรียกว่า Widrow-Hoff rule (Lippmann, 1987) ต่อมาในปี 1986 Rumelhart, Hilton และ Williams ได้ศึกษาค้นคว้าเพิ่มเติมจนเกิดกระบวนการเรียนรู้แบบแพร่กลับ (Back-propagation) หรือเรียกว่า Generalized Delta Rule (GDR) การเรียนรู้แบบแพร่กลับนี้ เป็นที่ยอมรับกันอย่าง แพร่หลายโดยเป็นการเรียนรู้แบบมีครูสอน และมีระบบการเชื่อมโยงแบบเคลื่อนไปข้างหน้าหลายชั้น (multilayer feed forward) (Bhokha, 1998) ดังรูปที่ 2.4 สำหรับวิธีการเรียนรู้แบบแพร่กลับ จะมี การปรับค่าถ่วงน้ำหนัก (w) ในทุก ๆ รอบการเรียนรู้เพื่อให้เกิดค่าความผิดพลาดที่น้อยที่สุด โดยจะ เริ่มต้นปรับแก้ค่าถ่วงน้ำหนักตั้งแต่ชั้น output หลังจากนั้นทำการปรับย้อนกลับมาที่ชั้นซ่อนชั้น สุดท้าย และชั้นซ่อนชั้นต่อ ๆ มา จนกระทั่งถึงชั้นซ่อนชั้นแรก



รูปที่ 2.4 โครงข่ายใยประสาทประดิษฐ์แบบแพร่กลับ

2.3.9 การหยุดการสอน (Stop training)

การหยุดการสอนโครงข่ายสามารถกระทำได้ 2 วิธี คือ 1) การกำหนดรอบการสอน (Epochs) 2) การกำหนดค่า error ที่ยอมรับได้ (Bhokha, 1998) Carpenter (1993) ได้แนะนำให้กำหนดจำนวนรอบการสอนอยู่ที่ 20,000 ถึง 100,000 รอบ และอีกวิธี คือ การกำหนดค่าความคลาดเคลื่อนระหว่างข้อมูลจริง และผลลัพธ์ที่โครงข่ายสามารถคำนวณได้ (khan et al., 1993) แต่ข้อควรระวังก็คือ การสอนโครงข่ายที่นานเกินไปจะทำให้เกิดปัญหาที่เรียกว่า over fitting ได้ ดังรูปที่ 2.5 ซึ่งเป็นปัญหาที่โครงข่ายสามารถที่จะเรียนรู้จนได้ผลลัพธ์ที่มีค่า error ที่น้อยที่สุด แต่เมื่อนำมาตรวจสอบความถูกต้องด้วยชุดทดสอบแล้ว ปรากฏว่าไม่สามารถที่จะให้ผลลัพธ์ที่ดีจริง (Bhokha, 1998)



รูปที่ 2.5 กรณี Over fitting

2.3.10 ชุดข้อมูล (Samples)

ชุดข้อมูล คือ ข้อมูลที่ทราบตัวแปรต้นและตัวแปรตามเพื่อนำมาใช้สอนโครงข่าย Yeh et al. (1993) ได้กล่าวไว้ว่า แหล่งที่มาของชุดข้อมูลแบ่งออกได้เป็น 3 ลักษณะ คือ 1) แบบสอบถาม 2) ข้อมูลทางสถิติ และ 3) จากการทดลอง โดยชุดข้อมูลดังกล่าวจะนำมาแบ่งออกเป็น 2 ชุด คือ ชุดการสอน (Training set) และ ชุดทดสอบ (Test set) Klimasauskas (1993) ได้ให้ความเห็นว่า ควรให้มีจำนวนชุดการสอนอย่างน้อย 5 ชุด เพื่อใช้ในการสอนโครงข่าย

2.3.11 การทดสอบโครงข่าย (Testing)

Smith (1993) กล่าวว่า การทดสอบโครงข่ายเป็นการทดสอบว่าโครงข่ายสามารถที่จะเรียนรู้จากชุดการสอน (Training set) ได้ดีเพียงไร โดยใช้ชุดข้อมูลที่ไม่เคยใช้สำหรับการสอนมาทดสอบ เรียกว่า ชุดทดสอบ (Test set) ซึ่งโครงข่ายที่สามารถให้ผลลัพธ์ที่แม่นยำได้เมื่อใช้ชุดทดสอบมาทดสอบ จะเป็นโครงข่ายที่น่าเชื่อถือในการทดสอบโครงข่ายสามารถแบ่งออกได้เป็น 2 ลักษณะ คือ 1) แบ่งข้อมูลออกเป็น 2 ชุด (McKim et al., 1996) โดยชุดแรกไว้สำหรับสอนโครงข่ายให้จดจำรูปแบบของข้อมูล และข้อมูลชุดที่สองไว้สำหรับทดสอบโครงข่าย โดยผลลัพธ์ที่แตกต่างระหว่างค่าจริง และค่าที่ได้จากชุดทดสอบจะถูกคำนวณออกมาเป็นค่าผิดพลาดของระบบ (system error) ซึ่งค่าผิดพลาดของระบบที่น้อย จะแสดงถึงความสามารถในการทำนายที่สูง 2) ใช้ชุดข้อมูลทั้งหมดเป็นทั้งชุดการสอน และชุดทดสอบ โดยนำชุดข้อมูลทั้งหมดมาสอนโครงข่ายก่อน และหลังจากนั้นนำชุดข้อมูลชุดเดิมมาทดสอบโครงข่าย

2.4 งานวิจัยที่เกี่ยวข้อง

จากผลการศึกษา Sundarambal.P et al. (2008) ได้พัฒนาการสร้างแบบจำลองโดยใช้ระบบโครงข่ายประสาทประดิษฐ์สำหรับทำนายปริมาณออกซิเจนในสัปดาห์ถัดไปในน้ำทะเลประเทศสิงคโปร์ และ Prybutok et al. (2000) ได้พยายามที่จะทำนายค่าระดับความเข้มข้นสูงสุดของโอโซนของแต่ละวัน บริเวณเขตอุตสาหกรรมทางตอนเหนือของสหรัฐอเมริกา (Houston site) และได้กล่าวไว้ว่าเป็นการยากที่จะสร้างแบบจำลองให้แม่นยำได้ เนื่องจากตัวแปรทางสิ่งแวดล้อมมีความซับซ้อนมาก ซึ่งในการศึกษาครั้งนี้ได้ทำการศึกษาสร้างแบบจำลอง Neural Network เพื่อใช้ในการทำนายค่าระดับความเข้มข้นสูงสุดของโอโซนแต่ละวันโดยทำการศึกษาเปรียบเทียบกับแบบจำลองทางสถิติทั่วไป คือ regression และ Box – Jenkins ARIMA ซึ่งข้อมูลที่ใช้ได้จาก Texas Natural Resource Conservation Commission ประกอบไปด้วยค่าความเข้มข้นเฉลี่ยรายชั่วโมงของโอโซน และ ค่าเฉลี่ยรายชั่วโมงของข้อมูลทางอุตุนิยมวิทยา เช่น อุณหภูมิ ความเร็วลม และทิศทางลม รวมทั้งข้อมูลมลพิษทางอากาศอื่น ๆ เช่น NO NO₂ CO₂ และ NO_x จากสถานีตรวจวัดอากาศ โดยข้อมูลนี้จะเลือกใช้ในช่วงเดือนที่มีความเข้มข้นของโอโซนสูงสุด คือ ตั้งแต่วันที่ 1 มิถุนายน ถึง 31 ตุลาคม เนื่องจากต้องการลดความผิดพลาดในการทำนายจากปัจจัยทางด้านฤดูกาล โดยที่ข้อมูลในช่วงวันที่ 1 มิถุนายน ถึง 30 กันยายน จะใช้ในการสร้างแบบจำลอง และได้ให้เห็นไว้ว่าค่าเฉลี่ยของข้อมูลตัวแปรอิสระที่จะทำให้แบบจำลองสามารถทำนายได้ดีควรจะอยู่ในช่วงเวลา 6.00 – 9.00 น. ส่วนข้อมูลในช่วงวันที่ 1 – 10 ตุลาคม จะใช้เป็นตัวทดสอบแบบจำลอง โดยใช้โปรแกรม SAS ในการสร้างแบบจำลอง Regression และ ARIMA และใช้โปรแกรม NeuralWare III ในการ

สร้างแบบจำลอง Neural Networks หลังจากทำการเลือกตัวแปรอิสระแล้ว ต้องทำการพิจารณาปัจจัยที่ส่งผลกระทบต่ออากาศเกิดโอโซนด้วย คือ photochemical production และ atmospheric accumulation (Robeson and Steyn, 1990) รวมทั้งปัจจัยที่สำคัญอีกประการหนึ่ง คือ มลพิษที่ปลดปล่อยออกมาจากยานพาหนะบนท้องถนน คือ NO NO₂ CO₂ และ NO_x หลังจากทำการสร้างแบบจำลองทั้งสามแล้วพบว่าค่า Mean absolute deviations (MAD) ของแบบจำลอง Regression ARIMA และ ANNs มีค่า 0.025741, 0.02879 และ 0.012945 ตามลำดับและค่า RMSE มีค่า 0.031239, 0.033023 และ 0.016418 ตามลำดับ