



ข่าวงานนิวัตสำหรับกระบวนการทางเคมี Neural Networks for Chemical Process

วชิรา ดาวสุด

Wachira Daosud

ภาควิชาวิศวกรรมเคมี คณะวิศวกรรมศาสตร์ มหาวิทยาลัยบูรพา

Correspondent author: wachira@bua.ac.th

บทคัดย่อ

ข่าวงานนิวัตได้นำไปศึกษาและประยุกต์ใช้เพื่อแก้ปัญหาในด้านวิศวกรรมเพิ่มขึ้น ด้วยศักยภาพของข่าวงานนิวัตที่ให้แบบจำลองที่ดีสำหรับกระบวนการต่างๆ โดยเฉพาะอย่างยิ่งการนำไปประยุกต์ใช้กับกระบวนการทางเคมี เช่น การระบุกระบวนการที่ไม่เป็นเชิงเส้นและการควบคุมกระบวนการ ดังนั้น บทความนี้จะนำเสนอข่าวงานนิวัตที่ประยุกต์ใช้กับกระบวนการทางเคมี พร้อมแสดงรายละเอียดเกี่ยวกับการพัฒนาข่าวงานนิวัตสำหรับกระบวนการทางเคมีอย่างเป็นขั้นเป็นตอน ตั้งแต่การเลือกโครงสร้างของข่าวงาน การเรียนรู้ การทดสอบ และการตรวจสอบ ในที่นี้ จะยกกรณีศึกษากับกระบวนการกำจัดสนิมเหล็กด้วยกรด โดยจะแสดงการประยุกต์ใช้ข่าวงานนิวัตเป็นสองส่วนหลักๆ คือ แบบจำลองของกระบวนการและการควบคุมกระบวนการ ซึ่งในแต่ละส่วนได้สรุปการนำข่าวงานไปใช้ในกระบวนการที่สำคัญทั้งในด้านโครงสร้างและรูปแบบการนำไปใช้ ผลการศึกษาจะแสดงประสิทธิผลและความสามารถในการนำไปประยุกต์ใช้ของข่าวงานนิวัตในการแก้ปัญหาสำหรับกระบวนการเคมี ซึ่งให้ผลเป็นที่น่าพอใจทั้งในด้านการจำลองกระบวนการและการควบคุมกระบวนการและมีศักยภาพในการนำไปใช้กับกระบวนการทางเคมีที่ไม่เป็นเชิงเส้นและซับซ้อนสูง

Abstract

Neural Networks have been studied and applied to solving several engineering problems increasingly due to their capabilities in providing good mathematical models of processes, in particular, the applicability on chemical processes such as nonlinear process identification and control. Therefore, this paper presents the neural networks with respect to the implementation on chemical processes including details regarding the development of neural networks on chemical processes step by step from initially the selection of neural networks structure, training, testing and validating. Here, the case study is defined on steel pickling process with demonstration on the implementation of the neural networks mainly in two parts: process models and control. Each part has been concluded focusing on the structure and approach. This study has shown the effectiveness and applicability of the neural networks on the problem solving of chemical processes which give satisfactorily performances with respect to process modeling and control, and their capability in the application to highly nonlinear and complex chemical processes.

คำสำคัญ: ข่าวงานนิวัต กระบวนการเคมี การจำลองกระบวนการ การควบคุมกระบวนการ

Keywords: neural networks, chemical process, modeling, process control

1. บทนำ

เป็นที่ทราบกันดีอยู่แล้วว่ากระบวนการผลิตในอุตสาหกรรมเคมีนั้นมีความซับซ้อนและพฤติกรรมของกระบวนการมีความไม่เป็นเชิงเส้นสูง กระบวนการจะเกี่ยวข้องกับหลายตัวแปรที่มีผลกระทบซึ่งกันและกัน ดังนั้นจึงเป็นการยากที่จะหาพฤติกรรมทางพลศาสตร์หรือการตอบสนองของกระบวนการที่ถูกต้อง เพื่อนำไปใช้ประโยชน์ในด้านต่างๆ เช่น การทำนายคุณสมบัติของผลิตภัณฑ์ การหาสถานะในการผลิตหรือแม้แต่การควบคุมกระบวนการผลิตให้ได้ตามเป้าหมายที่ต้องการ โดยการใช้อกฎการอนุรักษ์ (conservation law) เพียงอย่างเดียว ซึ่งแบบจำลองของกระบวนการทางเคมีที่ได้จากหลักการนี้อาจจะไม่สามารถเป็นตัวแทนของกระบวนการได้ เนื่องจากไม่สามารถหาค่าพารามิเตอร์ที่ถูกต้องของกระบวนการได้ หรือแบบจำลองกระบวนการที่ได้อยู่ภายใต้สมมติฐานต่างๆ ดังนั้นจึงมีวิธีการหนึ่งที่น่าสนใจและมีประสิทธิภาพที่ดีในการหาแบบจำลองของกระบวนการทางเคมี การประมาณค่าพารามิเตอร์ต่างๆ ของกระบวนการเคมีและยังสามารถเป็นตัวควบคุมกระบวนการทางเคมีได้อย่างน่าพอใจ ซึ่งวิธีการที่กล่าวถึงนี้คือ ข่ายงานนิวรัล (neural networks)

ข่ายงานนิวรัล เป็นศาสตร์แขนงหนึ่งด้านปัญญาประดิษฐ์ (artificial intelligence, AI) และเป็นโมเดลทางคณิตศาสตร์ โดยพยายามลอกเลียนแบบระบบการทำงานที่ซับซ้อนของสมองมนุษย์ ซึ่งที่ผ่านมาข่ายงานนิวรัลมีบทบาทมากในการนำไปใช้เป็นตัวช่วยแก้ปัญหาในด้านต่างๆ เช่น ในด้านเศรษฐศาสตร์ (1,2) การพยากรณ์ด้านการเงิน (3,4) ด้านการแพทย์ในการวินิจฉัยโรคต่างๆ (5-7) โดยสรุปแล้วข่ายงานนิวรัลสามารถนำไปประยุกต์ใช้ในงานที่มีลักษณะต่างๆ ดังนี้

1. การทำนาย (prediction) เช่น การทำนายพฤติกรรมของกระบวนการในอุตสาหกรรมและการทำนายราคาหุ้นในตลาดหลักทรัพย์ เป็นต้น

2. การจำแนกลักษณะสำคัญและจำแนกรูปแบบ (character and pattern recognition) เช่น การจดจำลักษณะลายมือ การวิเคราะห์เสียงและแปลความหมาย การตรวจสอบข้อผิดพลาดบางจุดในการผลิต เป็นต้น

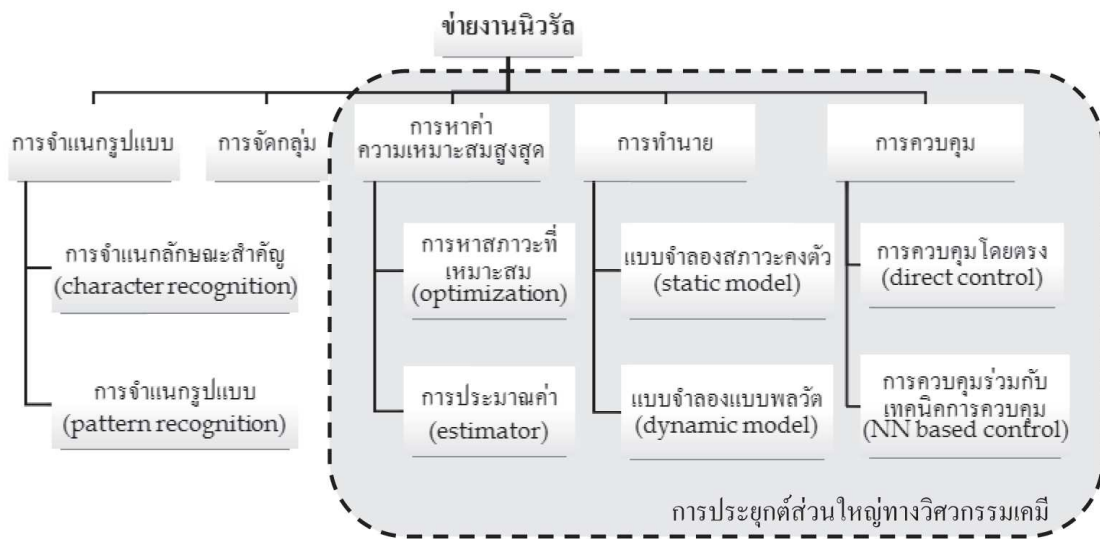
3. การจัดกลุ่ม (clustering) เช่น การวิเคราะห์ข้อมูลภาพถ่ายดาวเทียม

4. การหาค่าความเหมาะสมสูงสุด (optimization) เช่น การหาสถานะที่ดีที่สุดในการผลิตเพื่อให้ได้กำไรมากที่สุดหรือใช้ต้นทุนต่ำที่สุด การเลือกเส้นทางในการเดินทางที่เหมาะสมที่สุด เป็นต้น

5. การควบคุม (control) เช่น การควบคุมกระบวนการในการผลิตให้ได้ตามเป้าหมาย การควบคุมในด้านความปลอดภัย และการควบคุมหุ่นยนต์ เป็นต้น

ในด้านวิศวกรรมสาขาต่างๆ ได้มีการนำข่ายงานนิวรัลไปใช้งานอย่างมากมาย โดยเฉพาะอย่างยิ่งทางด้านวิศวกรรมเคมี มีการประยุกต์ใช้ข่ายงานนิวรัลในหลายงานซึ่งงานด้านหลักๆ ที่ประยุกต์ใช้ข่ายงานนิวรัลจะอยู่ในลักษณะของงาน การทำนาย การหาค่าความเหมาะสมสูงสุดและการควบคุม เช่น การหาแบบจำลองของกระบวนการทางเคมีที่ซับซ้อน (complex chemical process modeling) การหาค่าความเหมาะสมสูงสุดในกระบวนการผลิตทางเคมี (optimization in chemical manufacturing process) และการควบคุมกระบวนการ (process control) ซึ่งสามารถแสดงบทบาทของข่ายงานนิวรัลในการนำไปใช้ในด้านต่างๆ ทางวิศวกรรมเคมีดังรูปที่ 1 แต่เนื่องจากการใช้ข่ายงานนิวรัลในการแก้ปัญหาในด้านต่างๆ นั้น จะมีความแตกต่างกันในรายละเอียดของการสร้างข่ายงาน โครงสร้างของข่ายงาน รวมถึงรูปแบบการนำไปประยุกต์ใช้

ดังนั้นบทความนี้จึงได้กล่าวถึงการประยุกต์ใช้ข่ายงานนิวรัลสำหรับกระบวนการทางเคมีโดยเฉพาะ โดยได้แบ่งเนื้อหาที่จะกล่าวถึงออกเป็นส่วนๆ ดังนี้ ในส่วนแรกจะกล่าวถึง โครงสร้าง องค์ประกอบ สถาปัตยกรรม การเรียนรู้และขั้นตอนการหาแบบจำลองข่ายงานนิวรัล จากนั้นจะประยุกต์ใช้ข่ายงานนิวรัลสำหรับกระบวนการทางเคมี โดยจะใช้กระบวนการกำจัดสนิมเหล็กด้วยกรดเป็นกรณีศึกษาตัวอย่างเพื่อให้เห็นภาพการสร้างข่ายงานและการประยุกต์ใช้อย่างชัดเจน และได้แบ่งเนื้อหาการประยุกต์ใช้เป็น 2 ส่วนหลักๆ คือ การประยุกต์ใช้ข่ายงานนิวรัลเป็นแบบจำลองกระบวนการและการประยุกต์ใช้ข่ายงานนิวรัลในการควบคุมกระบวนการ ในส่วนแรกของการประยุกต์ใช้จะกล่าวถึงขั้นตอนโดยละเอียดในการสร้าง



รูปที่ 1 การประยุกต์ใช้ข่ายงานนิวรัล

แบบจำลองข่ายงานนิวรัล ตั้งแต่การเตรียมข้อมูลในการสร้างจนถึงการวัดประสิทธิภาพของข่ายงานนิวรัลที่สร้างขึ้น และในส่วนของ การควบคุมจะแสดงถึงโครงสร้างการควบคุมแบบต่างๆ ที่ใช้ข่ายงานนิวรัลเป็นตัวควบคุมและการใช้ข่ายงานนิวรัลร่วมกับเทคนิคการควบคุมต่างๆ ในการควบคุมกระบวนการ ทำให้มีประสิทธิภาพในการควบคุมที่ดี บทความนี้จะ เป็นพื้นฐานให้นักวิจัยได้เรียนรู้และประยุกต์ใช้ข่ายงานนิวรัลสำหรับการหาแบบจำลองของกระบวนการและการควบคุมกระบวนการทางเคมีอย่างเป็นรูปธรรม

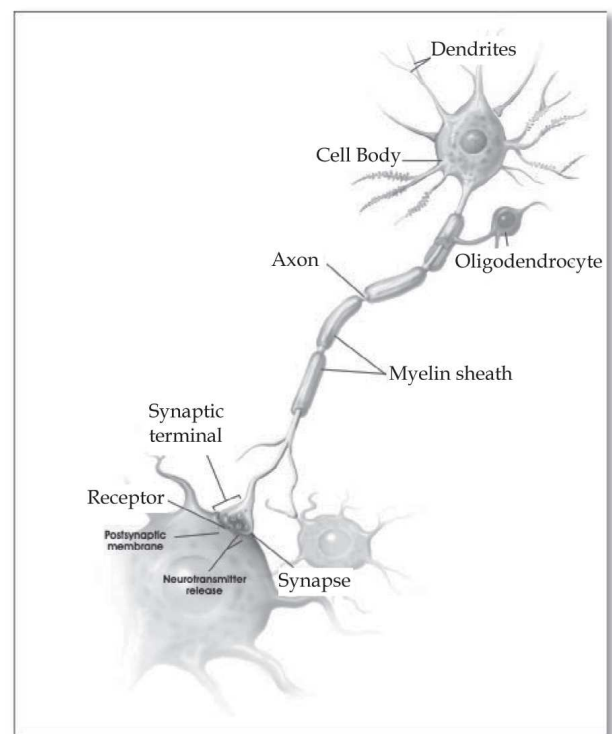
2. แบบจำลองข่ายงานนิวรัล

ข่ายงานนิวรัล (neural networks) มีหลักการที่สำคัญคือ พยายามที่จะลอกเลียนแบบการทำงานของเซลล์ประสาทในสมองของมนุษย์ โดยสมองของมนุษย์นั้นประกอบไปด้วยเซลล์ประสาทที่เรียกว่า นิวรอล (neuron) แสดงดังรูปที่ 2 โดยจะเชื่อมต่อกันและทำงานในลักษณะเป็นกลุ่มหรือเรียกว่า เน็ตเวิร์ก (network)

จากหน่วยนิวรอลที่แสดงดังรูปที่ 2 ตัวเซลล์ (cell body) จะมีเส้นใยเล็กๆอยู่รอบๆจำนวนมาก เรียกว่า เดนไดรต์ (dendrite) จะทำหน้าที่รับสัญญาณไฟฟ้าหรือข้อมูลจากนิวรอลอื่นๆ ต่อจากนั้นสัญญาณจะถูกนำมารวมกันก่อนที่จะส่งออกจากเซลล์ผ่านแอกซอน (axon) ซึ่ง

ทำหน้าที่เป็นสายส่งสัญญาณออกไปยังเดนไดรต์ของนิวรอลอื่นๆ โดยที่บริเวณจุดต่อระหว่างแขนงแอกซอนและเดนไดรต์เรียกว่า ไซแนปส์ (synapse) กระบวนการเรียนรู้ในสิ่งมีชีวิตจะทำให้เกิดการเปลี่ยนแปลงของไซแนปส์ต่างๆหรือเกิดการสร้างไซแนปส์ระหว่างเซลล์ประสาทขึ้นมาใหม่ สัญญาณที่ผ่านไซแนปส์จะถูกกระตุ้นให้เพิ่มขึ้นหรือยับยั้งให้ลดลงก็ได้

ข่ายงานนิวรัลจะมีความคล้ายกับการส่งสัญญาณ



รูปที่ 2 โครงสร้างเซลล์ประสาท (8)

ในเซลล์ประสาทของสมองมนุษย์คือ การประมวลผลจะเกิดขึ้นในหน่วยประมวลผลย่อยเรียกว่า โหนด (node) ซึ่งเป็นการจำลองการทำงานมาจากหน่วยนิวรอล การส่งสัญญาณระหว่างโหนดที่เชื่อมกันจำลองมากจากการส่งสัญญาณระหว่างเดนไดรต์และแอกซอน ภายในโหนดจะมีฟังก์ชันกำหนดสัญญาณส่งออกเรียกว่า ฟังก์ชันกระตุ้น (activation function) โดยข่ายงานนิวรัลมีความสามารถในการรวบรวมความรู้โดยใช้กระบวนการเรียนรู้ (learning process) และความรู้จะจัดเก็บอยู่ในรูปแบบค่าน้ำหนัก (weight) ซึ่งถ้ามีการเรียนรู้สิ่งใหม่ๆ ค่าน้ำหนักจะปรับเปลี่ยนไป ดังนั้นค่าน้ำหนักทำหน้าที่ที่เปรียบเสมือนความรู้ที่ได้รวบรวมไว้เพื่อใช้ในการแก้ปัญหา ดังแสดงได้ดังรูปที่ 3 จากโครงสร้างของโหนด (node) ในข่ายงานนิวรัลดังแสดงในรูปที่ 3 สามารถแบ่งองค์ประกอบที่สำคัญของข่ายงานนิวรัล ออกเป็น 5 องค์ประกอบดังนี้

1. ข้อมูลป้อนเข้า (input) จะต้องเป็นข้อมูลที่เป็นตัวเลข หากเป็นข้อมูลเชิงคุณภาพที่ไม่ได้เป็นตัวเลขต้องทำการเปลี่ยนให้อยู่ในรูปแบบข้อมูลเชิงปริมาณก่อน
2. ค่าน้ำหนัก (weights) ได้จากกระบวนการเรียนรู้ของข่ายงานที่อาศัยความสัมพันธ์ของข้อมูลของกระบวนการ
3. ฟังก์ชันผลรวม (summation function) จะทำหน้าที่รวมข้อมูลป้อนเข้าแต่ละข้อมูล (x_i) กับค่าน้ำหนักของข้อมูลนั้น (w_i) ดังแสดงในสมการที่ (1)

$$v = \sum_{i=1}^m x_i w_i \tag{1}$$

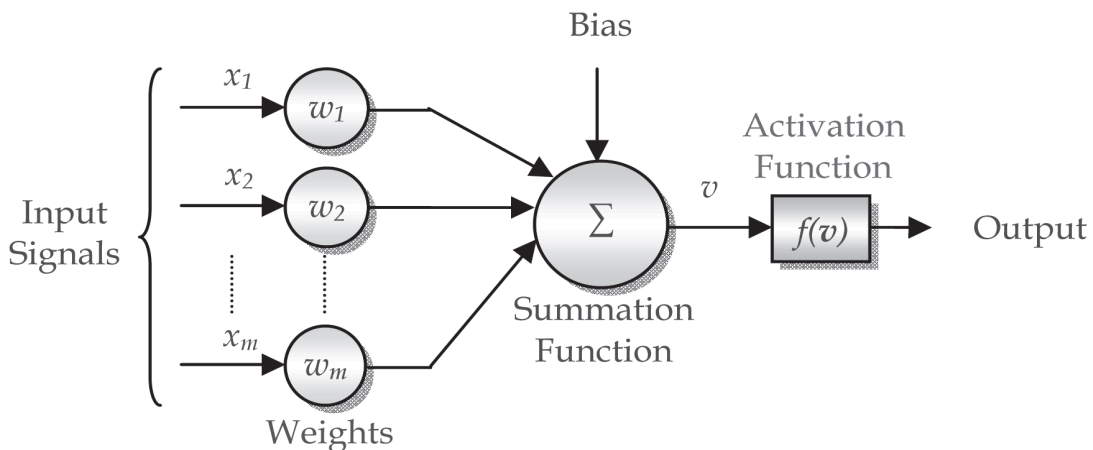
4. ฟังก์ชันกระตุ้น (activation function) หรือ ฟังก์ชันการแปลง (transfer function) เป็นฟังก์ชันที่ใช้ในการเปลี่ยนผลรวมของข้อมูลที่ได้จากฟังก์ชันผลรวมเป็นข้อมูลที่มีช่วงของข้อมูลเฉพาะ (specific scale) ซึ่งฟังก์ชันกระตุ้นอาจเป็นฟังก์ชันเชิงเส้นหรือไม่เชิงเส้นก็ได้ เช่น ฟังก์ชันขั้นบันได (step function) ฟังก์ชันซิกมอยด์ (sigmoid function) และฟังก์ชันไฮเพอร์โบลิกแทนเจนต์ (hyperbolic tangent function) เป็นต้น

5. ข้อมูลส่งออก (output) คือข้อมูลที่ได้จากการทำนายของข่ายงานนิวรัล

องค์ประกอบของข่ายงานอีกองค์ประกอบหนึ่งที่สามารถพบได้ในโครงสร้างของข่ายงานคือ ค่าเอนเอียงหรือไบแอส (bias) ซึ่งจะมีค่าเป็น 1 และเชื่อมโยงกับหน่วยอื่น ๆ ทุกหน่วย ค่าน้ำหนักของค่าเอนเอียงนี้จะถูกปรับในระหว่างการเรียนรู้ โดยในบางครั้งจะทำให้เวลาของการเรียนรู้ของข่ายงานเร็วขึ้น

2.1. ฟังก์ชันกระตุ้น (activation function)

จากที่ได้กล่าวไปในตอนต้นแล้วว่าองค์ประกอบที่สำคัญสำหรับข่ายงานนิวรัลองค์ประกอบหนึ่งคือ ฟังก์ชันกระตุ้น (activation function) หรือ ฟังก์ชันการแปลง (transfer function) เป็นฟังก์ชันที่จำกัดแอมพลิจูด (amplitude) ของข้อมูลหรือจำกัดขอบเขตของข้อมูลส่งออกจากโหนดของข่ายงาน สามารถเป็นได้ทั้งฟังก์ชันเชิงเส้นและไม่เชิงเส้น ตัวอย่างของฟังก์ชันกระตุ้น ($f(v)$)



รูปที่ 3 โครงสร้างของโหนด (node) ในข่ายงานนิวรัล

เช่น


- Threshold function เป็นฟังก์ชันที่ให้ค่าข้อมูลส่งออกจากฟังก์ชันเท่ากับ 1 หากค่าข้อมูลป้อนเข้าฟังก์ชันมากกว่าหรือเท่ากับ 0 และให้ค่าข้อมูลส่งออกจากฟังก์ชันเท่ากับ 0 หากค่าข้อมูลป้อนเข้าฟังก์ชันน้อยกว่า 0 สามารถแสดงได้ดังสมการที่ (2) และกราฟของฟังก์ชันแสดงได้ดังรูปที่ 4 (a)

$$f(v) = \begin{cases} 1 & \text{if } v \geq 0 \\ 0 & \text{if } v < 0 \end{cases} \quad (2)$$


โดย v คือผลรวมของข้อมูลที่เข้ามายังโหนด แสดงได้ดังสมการที่ (3)

$$v = \sum_{i=1}^m w_i x_i + b \quad (3)$$


- Piecewise-linear function เป็นฟังก์ชันที่ประกอบด้วยส่วนของเส้นตรงเป็นช่วง ถ้าฟังก์ชันต่อเนื่องกราฟจะเป็นเส้นโค้งเหลี่ยม สามารถแสดงได้ดังสมการที่ (4) และกราฟของฟังก์ชันแสดงได้ดังรูปที่ 4 (b)



(a)



(b)



(c)

รูปที่ 4 – (a) Threshold function (b) Piecewise-linear function (c) Sigmoid function เมื่อมีการเปลี่ยนแปลงค่าพารามิเตอร์ a

$$f(v) = \begin{cases} 1, & v \geq +0.5 \\ v, & +0.5 > v > -0.5 \\ 0, & v \leq -0.5 \end{cases} \quad (4)$$

- ฟังก์ชันซิกมอยด์ (sigmoid function) กราฟของฟังก์ชันนี้จะมีลักษณะเป็นรูปตัวเอส (s-shaped) เป็นฟังก์ชันกระตุ้นที่ใช้กันมากในข่ายงานนิวรัล ซึ่งพฤติกรรมการเพิ่มขึ้นของฟังก์ชันมีความสมดุลระหว่างความเป็นเชิงเส้นและความไม่เป็นเชิงเส้น ได้อย่างดี ฟังก์ชันซิกมอยด์จะบีบช่วงข้อมูลป้อนเข้าให้เป็นช่วงข้อมูลส่งออกที่อยู่ระหว่าง 0 ถึง 1 แสดงได้ดังสมการที่ (5)

$$f(v) = \frac{1}{1 + \exp(-av)} \quad (5)$$


โดย a คือพารามิเตอร์ความชันของฟังก์ชันซิกมอยด์ หากมีการเปลี่ยนแปลงค่าของพารามิเตอร์ a จะได้กราฟของฟังก์ชันซิกมอยด์ที่มีความชันแตกต่างกัน ดังแสดงในรูปที่ 4 (c)

2.2. สถาปัตยกรรมของข่ายงานนิวรัล

โครงสร้างของข่ายงานนิวรัลจะประกอบด้วยโหนดจำนวนมากเชื่อมต่อกัน โดยการเชื่อมต่อกันจะแบ่งออกเป็นชั้น (layer) ซึ่งชั้นแรกจะเป็นชั้นของข้อมูลป้อนเข้า เรียกว่า ชั้นข้อมูลป้อนเข้า (input layer) และชั้นสุดท้ายเรียกว่าชั้นข้อมูลส่งออก (output layer) ส่วนชั้นที่อยู่ระหว่างชั้นข้อมูลป้อนเข้าและชั้นข้อมูลส่งออกเรียกว่า ชั้นแอบแฝงหรือชั้นซ่อน (hidden layer) ซึ่งอาจจะมียุทธวิธีมากกว่า 1 ชั้นก็ได้ในข่ายงาน ดังนั้นจึงสามารถแบ่งประเภทของข่ายงานตามจำนวนชั้นเป็น 2 ประเภท คือ ข่ายงานนิวรัลแบบชั้นเดียว (single layer) ซึ่งโครงสร้างของข่ายงานจะมีชั้นข้อมูลป้อนเข้าและชั้นข้อมูลส่งออกเท่านั้น และข่ายงานนิวรัลแบบหลายชั้น (multi-layer) เป็นข่ายงานที่มีชั้นแอบแฝงตั้งแต่ 1 ชั้นขึ้นไป ข่ายงานชนิดนี้ส่วนใหญ่จะใช้กับปัญหาที่มีความซับซ้อนซึ่งข่ายงานนิวรัลแบบชั้นเดียวไม่สามารถแก้ปัญหาได้ หากจะแบ่งข่ายงานนิวรัลตามทิศทางของการส่งถ่ายข้อมูลสามารถแบ่งออกเป็นประเภทใหญ่ๆ ได้ 2 ประเภทคือ


1. ข่ายงานนิวรัลแบบป้อนไปข้างหน้า (feed forward neural network) ข่ายงานชนิดนี้ประกอบด้วยชั้นต่างๆ ของโหนด โดยชั้นแรกจะเป็นชั้นข้อมูลป้อนเข้า และชั้นสุดท้ายจะเป็นชั้นข้อมูลส่งออก ส่วนระหว่างชั้น

ข้อมูลป้อนเข้ากับข้อมูลส่งออกอาจจะมีหรือไม่มีชั้นแอบแฝงก็ได้ การเชื่อมต่อระหว่างชั้นของข่ายงานนิวรัลแบบป้อนไปข้างหน้าจะมีค่าน้ำหนักเป็นตัวเชื่อมและสัญญาณของข้อมูลป้อนเข้าที่เข้ามาจะถูกส่งไปข้างหน้าจนถึงชั้นของข้อมูลส่งออกเท่านั้น โดยไม่มีการป้อนกลับดังแสดงในรูปที่ 5 ข่ายงานแบบนี้จะใช้การเรียนรู้แบบมีผู้สอน (supervised learning) ให้หน่วยความจำน้อย ทำงานได้เร็ว และมีส่วนช่วยลดขนาดของข้อมูล (data reduction)



รูปที่ 5 ข่ายงานนิวรัลแบบป้อนไปข้างหน้า (feedforward neural network)

2. ข่ายงานนิวรัลแบบป้อนกลับ (feedback neural network) จะมีโครงสร้างเหมือนข่ายงานนิวรัลแบบป้อนไปข้างหน้า แต่จะมีส่วนที่เพิ่มเข้ามาคือส่วนของการป้อนกลับของข้อมูลดังแสดงในรูปที่ 6 และการป้อนกลับจะมีการหน่วงเวลาไปจากเวลาเดิม ซึ่งข่ายงานที่แสดงในรูปที่ 6 จะเรียกว่าข่ายงานรีเคอร์เรนต์ (recurrent network) เช่น ข่ายงานฮอปฟิลด์ (hopfield network) ข่ายงานเอลมาล (elman network) และข่ายงานจอร์แดน (jordan network) เป็นต้น ข่ายงานชนิดนี้จะใช้กับงานในบางประเภทที่เกี่ยวข้องกับการหน่วงของเวลาซึ่งมีพฤติกรรมแบบไม่เชิงเส้น มีความยืดหยุ่นสูง แต่ใช้หน่วยความจำค่อนข้างมาก ทำให้สิ้นเปลืองทรัพยากรในการทำงาน



รูปที่ 6 ข่ายงานนิวรัลแบบป้อนกลับ (feedback neural network)

3. การเรียนรู้สำหรับข่ายงานนิวรัล

ในการที่ข่ายงานนิวรัลจะสามารถแก้ปัญหาที่ต้องการได้นั้นสิ่งหนึ่งที่สำคัญที่จะต้องทำคือ การให้ข่ายงานนิวรัลได้เรียนรู้ในข้อมูลที่เกี่ยวข้องกับปัญหานั้นๆ เหมือนกับระบบประสาทของมนุษย์ที่จะต้องมีการเรียนรู้สัญญาณรูปแบบต่างๆ ก่อนจึงจะสามารถรู้ได้ว่า เมื่อมีข้อมูลป้อนเข้ามาในลักษณะนี้จะส่งข้อมูลส่งออกไปในลักษณะนั้น ซึ่งการเรียนรู้สามารถแบ่งออกได้เป็น 2 แบบคือ การเรียนรู้แบบมีผู้สอน (supervised learning) และการเรียนรู้แบบไม่มีผู้สอน (unsupervised learning)

1. การเรียนรู้แบบมีผู้สอน (supervised learning) การเรียนรู้แบบนี้ข้อมูลที่จะป้อนให้ข่ายงานเพื่อใช้ในการเรียนรู้จะประกอบไปด้วยข้อมูลป้อนเข้า (input data) และข้อมูลเป้าหมายของข้อมูลป้อนเข้า (target output) ในระหว่างการเรียนรู้ข่ายงานจะมีการตรวจสอบข้อมูลส่งออกจากข่ายงานกับข้อมูลเป้าหมายและจะใช้ค่าความแตกต่างนี้ในการปรับตัวเองหรือปรับค่าน้ำหนักเพื่อให้สามารถทำนายหรือส่งข้อมูลส่งออกให้ถูกต้องใกล้เคียงกับเป้าหมายมากที่สุด ตัวอย่างของการเรียนรู้แบบมีผู้สอน เช่น การเรียนรู้แบบแพร่ย้อนกลับ (backpropagation method) เป็นต้น

2. การเรียนรู้แบบไม่มีผู้สอน (unsupervised learning) เป็นการเรียนรู้แบบไม่มีการตรวจสอบกับข้อมูล เป้าหมายว่าข้อมูลที่ส่งออกมานั้นถูกต้องหรือไม่หรือเป็นการเรียนรู้แบบไม่มีการป้อนข้อมูลเป้าหมายให้กับข่ายงานนั่นเอง ข่ายงานจะจัดเรียงโครงสร้างด้วยตัวเองตามลักษณะของข้อมูล เช่น การเรียนรู้แบบเคาน์เตอร์พรอพเกชัน (counter propagation, CNP) และอะแดปทีฟรีโซแนนซ์เทียรี (adaptive resonance theory neural network, ART) เป็นต้น

การเรียนรู้ทั้งสองแบบนี้สามารถใช้ในการฝึกสอนข่ายงานได้แต่มีข้อดีข้อเสียแตกต่างกัน เช่น การเรียนรู้แบบมีผู้สอนนั้นจะทำให้ข่ายงานมีการเรียนรู้ได้เร็วกว่า ข้อมูลที่ได้มีมาตรฐานกว่า แต่ในส่วนของกระบวนการประยุกต์ใช้กับปัญหาที่ไม่ได้มีการสอนนั้นข่ายงานอาจจะแก้ไขปัญหานั้นไม่ได้ ในส่วนของกระบวนการเรียนรู้แบบไม่มีผู้สอนระบบสามารถพัฒนาไปได้เรื่อยๆ โดยไม่จำเป็นต้องมีการสอนแต่มีข้อเสียอยู่ที่เวลาที่ใช้ในการเรียนรู้ของแต่ละปัญหานั้นมากกว่าและมีความไม่เป็นมาตรฐาน สำหรับข่ายงานนิวิรัลที่ใช้ในกระบวนการทางเคมีส่วนใหญ่จะใช้การเรียนรู้แบบมีผู้สอน วิธีหนึ่งที่น่าสนใจคือ การเรียนรู้แบบแพร่ย้อนกลับ ซึ่งจะได้กล่าวถึงต่อไป

3.1 การเรียนรู้แบบแพร่ย้อนกลับ (backpropagation method, BP)

การเรียนรู้แบบแพร่ย้อนกลับนี้เป็นการเรียนรู้ที่จัดอยู่ในประเภทการเรียนรู้แบบมีผู้สอน ในกระบวนการเรียนรู้จะมีการปรับปรุงแก้ไขความสามารถของข่ายงานด้วยตัวเอง นั่นคือถ้าข่ายงานส่งคำตอบออกมาผิด จะมีการปรับค่าน้ำหนักของข่ายงานจนกว่าค่าความผิดพลาดจะน้อยลงอยู่ในเกณฑ์ที่กำหนดหรือที่ยอมรับได้ หมายความว่าคำตอบที่ส่งออกมาในครั้งถัดไปจะมีความถูกต้องมากขึ้น จากที่ได้กล่าวไว้ในตอนต้นแล้วว่า วัตถุประสงค์ของการเรียนรู้คือการปรับค่าน้ำหนักที่เหมาะสมสำหรับข่ายงานเพื่อให้ข้อมูลส่งออกจากข่ายงานมีความถูกต้องตรงตามเป้าหมาย ซึ่งวิธีการปรับค่าน้ำหนักของข่ายงานนิวิรัลแบบมีชั้นแอบแฝง 1 ชั้น โดยการเรียนรู้แบบแพร่ย้อนกลับอธิบายเป็นขั้นตอนได้ดังนี้

1. ค่าน้ำหนักและไบแอสเริ่มต้นจะกำหนดแบบสุ่มอยู่ระหว่าง -1 ถึง 1

2. ค่าข้อมูลป้อนเข้า (O_i^1) จะถูกนำมารวมกัน ผลรวมของข้อมูลป้อนเข้าสำหรับโหนด j แสดงได้ดังสมการที่ (6)

$$v_j = \sum_{i=1}^{N_i} w_{ji} O_i^1 + b_j \tag{6}$$

3. ข้อมูลส่งออกจากโหนด j (O_j^2) แสดงได้ดังสมการที่ (7)

$$O_j^2 = f(v_j) \tag{7}$$

โดย $f(v)$ คือฟังก์ชันกระตุ้นหรือฟังก์ชันการแปลงที่ใช้ในโหนดแอบแฝง

4. ค่าข้อมูลส่งออกจากโหนด j จะส่งต่อไปยังโหนด k ในชั้นส่งออก ซึ่งข้อมูลจะถูกนำมารวมกันดังแสดงในสมการที่ (8)

$$v_k = \sum_{j=1}^{N_j} w_{kj} O_j^2 + b_k \tag{8}$$

5. ข้อมูลส่งออกจากโหนด k แสดงได้ดังสมการที่ (9)

$$O_k^3 = f(v_k) \tag{9}$$

6. ค่าความผิดพลาดจะคำนวณที่ชั้นส่งออกดังสมการที่ (10)

$$e = \frac{1}{2} \sum_{k=1}^{N_k} (t_k - O_k^3)^2 \tag{10}$$

โดยที่ t_k คือ ค่าเป้าหมาย

7. ค่าน้ำหนักจะถูกปรับโดยวิธีการออฟติไมซ์ (optimization) โดยถ้าใช้วิธีการปรับค่าน้ำหนักแบบการเคลื่อนลงตามความชันทางลบ (negative gradient descent) ของค่าความผิดพลาด จะแสดงได้ดังสมการที่ (11)

$$\Delta w_{kj} = -\eta \frac{\partial e}{\partial w_{kj}} \tag{11}$$

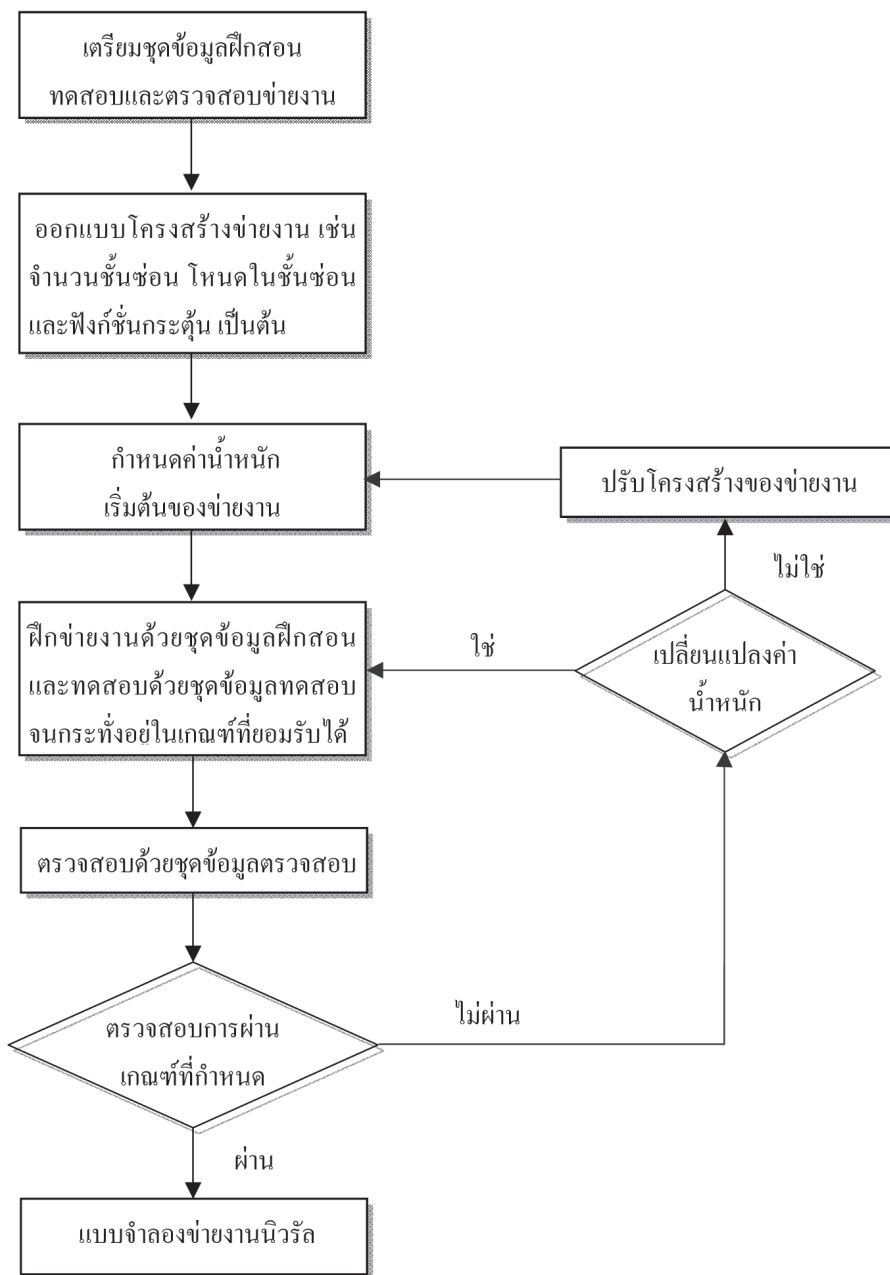
โดยที่ η คือ อัตราการเรียนรู้

ข้อดีของการเรียนรู้แบบ BP คือการคำนวณที่มีประสิทธิภาพแต่มีข้อเสียอยู่ที่จะมีการปรับค่าน้ำหนักเข้าในกรณีของจุดอานม้า (saddle point) หรือ จุดต่ำสุดเฉพาะที่ (local minimum) ดังนั้นจึงมีวิธีการเรียนรู้หลายวิธีที่เข้ามาแก้ปัญหาตรงจุดนี้เช่น Refining backpropagation,

Conjugate gradient methods และ Levenberg-Marquardt method เป็นต้น ซึ่งเป็นวิธีการทางคณิตศาสตร์ในการ ออฟติไมซ์หาค่าน้ำหนักของข่ายงานที่มีการปรับค่า น้ำหนักแตกต่างจากวิธี BP ทำให้มีการปรับค่าน้ำหนักของ ข่ายงานได้เร็วขึ้น เช่น ในการปรับค่าน้ำหนักของวิธี Levenberg-Marquardt method จะทำการปรับค่าน้ำหนัก โดยอาศัยทฤษฎี Gaussian-Newton's Method กับ ทฤษฎี Steepest Descent Method มาใช้ร่วมกัน ซึ่งจะให้ผลลัพธ์ ที่ดีกล่าวคือ จะทำให้ผู้เข้าสู่ค่าน้ำหนักที่เหมาะสมอย่างรวดเร็ว (9,10)

4. ขั้นตอนการสร้างข่ายงานนิวรัล

เมื่อเราได้ทราบถึงองค์ประกอบต่างๆของข่ายงาน นิวรัลจากที่ได้กล่าวไว้ข้างต้นแล้วต่อไปจะกล่าวถึงขั้นตอน ในการสร้างข่ายงานนิวรัลหรือการได้มาซึ่งข่ายงานนิวรัล สำหรับวัตถุประสงค์ต่างๆ ตามขั้นตอนดังต่อไปนี้และ แสดงได้ดังรูปที่ 7



รูปที่ 7 ขั้นตอนการสร้างข่ายงานนิวรัล

- ขั้นตอนแรกในการสร้างข่ายงานคือ การเตรียมชุดข้อมูลสำหรับฝึกสอนข่ายงาน (training data set) และทดสอบข่ายงาน (testing data set) โดยชุดข้อมูลสามารถเตรียมได้จากข้อมูลจริงที่เกิดขึ้น เช่น ข้อมูลที่เก็บได้จริงจากกระบวนการผลิตหรือจากการทดลองหรืออาจจะเป็นข้อมูลที่ได้จากการจำลองกระบวนการ โดยใช้แบบจำลองทางคณิตศาสตร์ของกระบวนการ ซึ่งลักษณะของชุดข้อมูลที่เตรียมขึ้นอยู่กับรูปแบบการเรียนรู้ เช่น ถ้าจะฝึกสอนข่ายงานโดยใช้การเรียนรู้แบบมีผู้สอน ชุดข้อมูลที่เตรียมต้องใช้ข้อมูลป้อนเข้า (input data) และข้อมูลส่งออก (output data) ที่สัมพันธ์กับข้อมูลป้อนเข้านั้น ซึ่งช่วงของข้อมูลจะต้องครอบคลุมช่วงของปัญหาที่สนใจ

- หลังจากเตรียมชุดข้อมูลแล้วจากนั้นทำการออกแบบโครงสร้างของข่ายงานโดยการกำหนดรูปแบบของข่ายงาน องค์ประกอบต่างๆของข่ายงาน เช่น จำนวนชั้นแอบแฝง จำนวนโหนดในชั้นแอบแฝง ฟังก์ชันกระตุ้นและค่าน้ำหนักเริ่มต้น

- ทำการฝึกสอนข่ายงานด้วยวิธีการเรียนรู้ที่เหมาะสมและชุดข้อมูลฝึกสอน ในกรณีที่เลือกการเรียนรู้แบบมีผู้สอน จะทำการฝึกสอนข่ายงานจนกระทั่งค่าความผิดพลาดหรือค่าความแตกต่างระหว่างค่าของข้อมูลส่งออกที่ทำนายได้จากข่ายงานกับค่าของข้อมูลส่งออกจริงที่ป้อนให้กับข่ายงานน้อยกว่าหรือเท่ากับค่าที่กำหนด จึงหยุดทำการฝึกสอนข่ายงาน ซึ่งค่าความผิดพลาดนี้สามารถบ่งชี้ได้จากฟังก์ชันความผิดพลาดต่างๆ เช่น ค่าเฉลี่ยคลาดเคลื่อนกำลังสอง (mean squared error: MSE) เป็นต้น

- นำข่ายงานที่ฝึกสอนแล้วมาทดสอบกับชุดข้อมูลตรวจสอบ (validation data set) และตรวจสอบค่าความผิดพลาดว่าน้อยกว่าหรือเท่ากับค่าที่กำหนดหรือไม่ หากค่าความผิดพลาดน้อยกว่าหรือได้ตามที่กำหนดถือว่าได้ข่ายงานนิวิรัลที่มีความสามารถในการทำงานได้ตามที่ต้องการ แต่หากค่าความผิดพลาดมากกว่าค่าที่กำหนดจะต้องกลับไปในขั้นตอนของการปรับค่าน้ำหนักของข่ายงานและทำการฝึกสอนข่ายงานนิวิรัลอีกครั้ง จนกว่าเมื่อทำการทดสอบกับชุดข้อมูลตรวจสอบแล้วได้ค่าความผิดพลาดน้อยกว่าหรือเท่ากับที่กำหนดไว้ แต่ถ้าหากทำการปรับค่าน้ำหนักของข่ายงานใหม่แล้วค่าความผิดพลาดของการทดสอบกับชุดข้อมูลตรวจสอบยังมากกว่าค่าที่กำหนด อาจ

จะต้องกลับไปปรับโครงสร้างของข่ายงานใหม่ เช่น ปรับจำนวนโหนดในชั้นแอบแฝง หรือจำนวนของชั้นแอบแฝง เป็นต้น

5. การประยุกต์ใช้ข่ายงานนิวิรัลสำหรับกระบวนการทางเคมี

ในหัวข้อนี้จะกล่าวถึงการนำข่ายงานนิวิรัลไปใช้ประโยชน์ในการแก้ปัญหาในด้านต่างๆ ซึ่งจะเน้นในปัญหาและการประยุกต์ใช้ข่ายงานนิวิรัลสำหรับกระบวนการทางเคมี โดยจะกล่าวถึงการประยุกต์ใช้ข่ายงานในสองกรณีหลักคือ การใช้ข่ายงานนิวิรัลเป็นแบบจำลองของกระบวนการ (neural network model) และการใช้ข่ายงานนิวิรัลเป็นตัวควบคุมกระบวนการ (neural network controller) เนื่องจากการใช้งานในสองลักษณะนี้มีการประยุกต์ใช้มากในกระบวนการทางเคมี นอกเหนือจากนี้ข่ายงานนิวิรัลยังสามารถนำไปประยุกต์ใช้ในงานด้านอื่นอีกด้วย เช่น ใช้เป็นตัวประมาณค่าสแตตและพารามิเตอร์ของกระบวนการ (11-14) เป็นต้น โครงสร้างของข่ายงานนิวิรัลที่ใช้ส่วนใหญ่จะมี 2 แบบ คือข่ายงานนิวิรัลแบบไปข้างหน้า (forward neural network, FNN) และ ข่ายงานนิวิรัลแบบผกผัน (inverse neural network, INN) และจะมีการนำไปใช้ในปัญหาที่แตกต่างกันซึ่งจะได้กล่าวถึงต่อไป


5.1 การประยุกต์ใช้ข่ายงานนิวิรัลเป็นแบบจำลองของกระบวนการ

ปัญหาที่สำคัญอย่างหนึ่งของกระบวนการผลิตทางเคมีคือ การหาการตอบสนองหรือพฤติกรรมต่างๆของกระบวนการ เช่น อุณหภูมิ ความเข้มข้น หรือความดัน เป็นต้น ว่าเปลี่ยนแปลงไปตามเวลาอย่างไร โดยทั่วไปการหาพฤติกรรมต่างๆของกระบวนการเหล่านี้สามารถทำได้โดยการใช้กฎการอนุรักษ์ เช่น การอนุรักษ์มวล พลังงาน หรือโมเมนตัม เป็นต้น แต่เนื่องจากกระบวนการทางเคมีในปัจจุบันมีความซับซ้อน มีความสัมพันธ์ระหว่างตัวแปรต่างๆในกระบวนการมากมายและค่าพารามิเตอร์ต่างๆของกระบวนการมีความไม่แน่นอนจึงเป็นการยากที่จะหาพฤติกรรมต่างๆของกระบวนการได้จากกฎการอนุรักษ์หรืออาจจะมีคลาดเคลื่อนเกิดขึ้นเนื่องจากสมมติฐาน

ต่างๆ ที่ตั้งขึ้น ดังนั้นจากเหตุผลต่างๆ ที่ได้กล่าวมา จึงมีการนำข่ายงานนิวรัลมาช่วยในการหาพฤติกรรมของกระบวนการหรือเป็นแบบจำลองของกระบวนการนั่นเอง

ในหลายปีที่ผ่านมาได้มีการนำข่ายงานนิวรัลมาใช้เป็นแบบจำลองของกระบวนการทางเคมีต่างๆ มากมาย ตัวอย่างเช่น ใช้ในการทำนายความเข้มข้นของสารในเครื่องปฏิกรณ์แบบกะ ซึ่งจากผลการทำนายด้วยแบบจำลองข่ายงานนิวรัลสามารถทำนายความเข้มข้นของสารได้แม่นยำมากกว่า 0.95 จากการวิเคราะห์การถดถอย (15) หรือในกระบวนการทางอุตสาหกรรมปิโตรเคมี ข่ายงานนิวรัลสามารถนำไปใช้เป็นแบบจำลองของกระบวนการเพื่อทำนายการตอบสนองของกระบวนการได้อย่างน่าพอใจ เช่น ในกรณีของการกำจัดกำมะถันด้วยไฮโดรเจน (hydrodesulfurization หรือ HDS) ซึ่งเป็นกระบวนการที่ใช้กันอย่างกว้างขวางในการกำจัดกำมะถันจากก๊าซธรรมชาติและผลิตภัณฑ์ต่างๆ จากการกลั่นปิโตรเลียม เช่น น้ำมันเบนซิน น้ำมันดีเซล และน้ำมันเชื้อเพลิงเครื่องบิน หากปราศจากขั้นตอนดังกล่าวแล้วกำมะถันจะถูกเผาไหม้ ซึ่งจะทำให้เกิดฝนกรด (acid rain) ตามมาได้ (16) โดยในกระบวนการกำจัดกำมะถันออกจากเนฟทา (naphtha) นี้ จะใช้ข่ายงานนิวรัลเพื่อทำนายปริมาณกำมะถันที่เหลืออยู่หลังจากผ่านกระบวนการกำจัด ซึ่งจากผลการวิจัยแสดงให้เห็นว่าแบบจำลองข่ายงานนิวรัลสามารถนำไปใช้ได้จริงในการทำนายและยังสามารถเพิ่มความระมัดระวังและการเตรียมการเนื่องจากค่าตัวแปรบางตัวเบี่ยงเบนออกไปจากขอบเขตที่ยอมรับได้ (17) และยังมีการประยุกต์ใช้ข่ายงานนิวรัลในกระบวนการทางเคมีต่างๆ อีกมากมายซึ่งให้ผลการทำนายการตอบสนองของกระบวนการได้อย่างมีประสิทธิภาพ (18-26) โครงสร้างข่ายงานนิวรัลที่ใช้เป็นแบบจำลองของกระบวนการจะเป็นโครงสร้างข่ายงานนิวรัลแบบไปข้างหน้า (FNN) ที่ใช้ในการทำนายพฤติกรรมหรือการตอบสนองของกระบวนการ ในการสร้างแบบจำลองข่ายงานนิวรัลสำหรับกระบวนการทางเคมีจะมีขั้นตอนพื้นฐานในการสร้างข่ายงานเหมือนกันกับที่กล่าวไปแล้วในข้างต้น แต่จะมีความแตกต่างในรายละเอียดในการกำหนดค่าตัวแปรต่างๆ ที่เกี่ยวข้องกับข่ายงาน เช่น ตัวแปรเข้าข่ายงาน การทำมาตรฐานข้อมูลและความเกี่ยวเนื่องกับเวลาหรือการเปลี่ยนแปลงตามเวลา (dynamic behavior) เป็นต้น

ดังนั้นในส่วนของการประยุกต์ใช้ข่ายงานนิวรัลเป็นแบบจำลองของกระบวนการนี้ จะแสดงการหาแบบจำลองข่ายงานนิวรัลของกระบวนการทางเคมีโดยละเอียดโดยใช้กระบวนการกำจัดสนิมเหล็กด้วยกรด (26) เป็นตัวแทนของกระบวนการทางเคมีดังกล่าวกระบวนการนี้เป็นกระบวนการในอุตสาหกรรมพื้นฐานของประเทศไทย มีพฤติกรรมของกระบวนการเป็นแบบไม่เป็นเชิงเส้นสูงและตัวแปรในระบบมีผลกระทบซึ่งกันและกัน ดังนั้นจึงเป็นตัวแทนในการศึกษากระบวนการทางเคมีส่วนใหญ่ที่ดี กระบวนการกำจัดสนิมเหล็กด้วยกรดเป็นกระบวนการที่ใช้ในการกำจัดสนิมออกจากผิวของโลหะด้วยการจุ่มโลหะลงในสารละลายกรด ซึ่งจะทำการจุ่มลงในถังสารละลายกรดสามถังต่อเนื่องกัน ในกระบวนการกำจัดสนิมเหล็กด้วยกรด พฤติกรรมที่ต้องการทำนายหรือต้องการรู้คือ ความเข้มข้นของกรดไฮโดรคลอริกในถังสารละลายกรดกำจัดสนิม โดยเมื่อรู้พฤติกรรมที่เกิดขึ้นในถังแล้วจะสามารถควบคุมการกำจัดสนิมเหล็กได้อย่างมีประสิทธิภาพ กระบวนการกำจัดสนิมเหล็กด้วยกรดแสดงได้ดังรูปที่ 8



รูปที่ 8 กระบวนการกำจัดสนิมเหล็กด้วยกรด

แบบจำลองข่ายงานนิวรัลสำหรับกระบวนการนี้จะเป็นแบบข่ายงานนิวรัลแบบไปข้างหน้า (forward neural network, FNN) คือ ค่าข้อมูลขาออกจากข่ายงานจะเป็นการตอบสนองของกระบวนการหรือเป็นการทำนายการตอบสนองของกระบวนการนั่นเอง และทำการฝึกสอนข่ายงานแบบออฟไลน์ซึ่งจะไม่มี การฝึกสอนข่ายงานอีกในระหว่างการนำไปใช้งาน ในการสร้างแบบจำลองข่ายงานนิวรัลจะกล่าวถึงรายละเอียดในการสร้างแบบจำลองข่ายงานนิวรัลของถังกรดถังที่ 2 เท่านั้น ซึ่งถังอื่นๆ จะมีขั้นตอนเหมือนกันคือ

• เริ่มด้วยการเตรียมชุดข้อมูลในการฝึกสอนและชุดข้อมูลในการทดสอบข่ายงาน ซึ่งข้อมูลของกระบวนการอาจจะได้มาจากกระบวนการจริงที่ปฏิบัติงานประจำวันในอุตสาหกรรม โดยทำการเก็บข้อมูลตัวแปรของกระบวนการต่างๆ ตามเวลา (sampling time) ที่มีผลกระทบบกับค่าความเข้มข้นของกรดไฮโดรคลอริกในถังซึ่งเป็นพฤติกรรมที่ต้องการจะทำนาย เช่น อัตราการไหลที่เข้าและออกจากถังกำจัดสนิม (F_3 และ F_2) ค่าความเข้มข้นของกรดในสายขาเข้าถึง (C_3) และทำการเก็บข้อมูลค่าความเข้มข้นของกรดไฮโดรคลอริกที่เวลาต่างๆในถัง (C_2) ที่เปลี่ยนแปลงตามการเปลี่ยนแปลงของตัวแปรเหล่านั้น ข้อมูลที่ทำการเก็บจะต้องครอบคลุมในช่วงของสภาวะที่ทำการปฏิบัติงาน

จากตัวอย่างงานวิจัยนี้ข้อมูลที่ใช้ในการฝึกสอนและทดสอบไม่ได้ใช้ข้อมูลที่เก็บจากกระบวนการจริง แต่ได้มาจากแบบจำลองทางคณิตศาสตร์ของกระบวนการที่สมมติให้เป็นพฤติกรรมจริงของกระบวนการ ดังสมการที่ (12) - (14) ซึ่งเป็นแบบจำลองทางคณิตศาสตร์ของถังที่ 2 ดังแสดงในรูปที่ 8 ในการใช้แบบจำลองทางคณิตศาสตร์เป็นตัวแทนของกระบวนการจริงในการสร้างข้อมูล จะทำการปรับเปลี่ยนค่าตัวแปรอิสระที่มีอิทธิพลกับความเข้มข้นของกรดในถัง (excitation signals) ในช่วงค่าที่เหมาะสมคือ ค่าในช่วงปฏิบัติการจริงแล้วทำการจำลองกระบวนการโดยใช้โปรแกรมช่วยจำลองและเก็บข้อมูลตัวแปรอื่นๆ ที่เปลี่ยนแปลงไปตามค่าตัวแปรอิสระที่ทำการเปลี่ยนแปลงนั้น เช่น จากสมการที่ (12) - (14) จะทำการปรับเปลี่ยนค่าอัตราการไหลเข้าถังกรดถังที่ 2 (F_3) เมื่ออัตราการไหลเข้าเปลี่ยนแปลงจะทำให้พฤติกรรมต่างๆ ที่เกิดขึ้นในถังเปลี่ยนแปลงตามไปด้วย ดังนั้นจะทำการเก็บค่าความเข้มข้นของกรดในถังที่ 2 (C_2) อัตราการไหลออกจากถังที่ 2 (F_2)

ความเข้มข้นของกรดในสายเข้าถึง (C_3 และ C_1) เพื่อนำไปใช้เป็นข้อมูลในการฝึกและทดสอบข่ายงานต่อไป โดยค่าขนาดของการทำนาย (step size) และค่าเวลาการเก็บตัวอย่าง (sampling time) มีค่าเท่ากับ 0.01 นาที

$$A \frac{dh_2}{dt} = F_3 - F_2 - F_{11} \quad (12)$$

$$\frac{d(V_2 C_2)}{dt} = qC_1 + F_3 C_3 - C_2(F_2 + F_{11} + q) - V_2 r_2 \quad (13)$$

$$r_2 = kC_2 \quad (14)$$

โดยกำหนดให้ F_{11} และ q เป็นค่าคงที่

• เมื่อทำการเก็บข้อมูลที่จะใช้ในการฝึกสอนและทดสอบแล้ว ในขั้นตอนนี้ต่อไป (ดังรูปที่ 7) จะทำการกำหนดโครงสร้างของข่ายงานเริ่มต้น เช่น การกำหนดข้อมูลป้อนเข้า จำนวนชั้นแอบแฝง จำนวนโหนดในชั้นแอบแฝง ฟังก์ชันกระตุ้นและค่าน้ำหนักเริ่มต้น โดยในกระบวนการนี้จะเห็นได้ว่าตัวแปรที่มีผลกระทบบต่อความเข้มข้นของกรดในถังคือ อัตราการไหลเข้าและออกจากถังที่ 2 (F_3 และ F_2) ความเข้มข้นของกรดในสายเข้าถึง (C_3 และ C_1) และจากแบบจำลองทางคณิตศาสตร์ ดังสมการที่ (12) และ (13) เป็นสมการเชิงอนุพันธ์สามัญอันดับที่หนึ่ง ซึ่งถ้าจะประมาณสมการด้วยวิธีการเชิงตัวเลข (numerical method) อย่างน้อยต้องใช้ข้อมูลในการประมาณ 2 ช่วงเวลาดังนั้นจึงกำหนดค่าความเข้มข้นของกรดไฮโดรคลอริกที่ทำนาย ($C_2(k+1)$) เป็นฟังก์ชันกับอัตราการไหลเข้าและออกจากถังที่ 2 ที่เวลาในอดีตและปัจจุบัน ($F_3(k-1), F_3(k), F_2(k-1), F_2(k)$) ความเข้มข้นของกรดในสายเข้าถึงที่เวลาในอดีตและปัจจุบัน ($C_1(k-1), C_1(k), C_3(k-1), C_3(k)$) และความเข้มข้นของกรดในถังที่เวลาปัจจุบัน ($C_2(k)$) ดังแสดงในสมการที่ (15)

$$C_2(k+1) = f(F_2(k-1), F_2(k), F_3(k-1), F_3(k), C_1(k-1), C_1(k), C_3(k-1), C_3(k), C_2(k)) \quad (15)$$

จากความสัมพันธ์ดังสมการที่ (15) จึงสามารถกำหนดจำนวนข้อมูลป้อนเข้าหรือจำนวนโหนดได้ 9 โหนด และจำนวนโหนดในชั้นข้อมูลส่งออก 1 โหนด (คือ ค่าความเข้มข้นของกรดในถังที่ 2 ที่ต้องการทำนาย, $C_2(k+1)$) โดยจำนวนชั้นซ่อนและจำนวนโหนดในชั้นซ่อนจะไม่มีกฎเกณฑ์หรือทฤษฎีที่แน่นอนในการกำหนด หากกำหนด


จำนวนโหนดในชั้นซ่อนมากจะทำให้ใช้เวลาในการสอนมาก แต่ถ้ากำหนดจำนวนโหนดในชั้นซ่อนน้อยเกินไป ข่ายงานนิวรัลอาจจะไม่สามารถเรียนรู้จนได้คำตอบที่ถูกต้องได้ ดังนั้นจึงทำการกำหนดเริ่มจากจำนวนชั้นซ่อน 1 ชั้นและจำนวนโหนดเริ่มต้นน้อยๆ และโครงสร้างที่เหมาะสมจะทำการหาค่าครั้งด้วยเกณฑ์ต่างๆ ในการบ่งชี้ความถูกต้อง

ต้องของการทำนาย ซึ่งงานวิจัยตัวอย่างได้ทำการหาโครงสร้างที่เหมาะสมโดยวิธีค่าเฉลี่ยความคลาดเคลื่อนกำลังสองน้อยที่สุด (minimization of mean squared error (MSE)) ดังแสดงในสมการที่ (16) สำหรับฟังก์ชันกระตุ้นได้เลือกใช้ฟังก์ชันซิกมอยด์ซึ่งเหมาะสมกับกระบวนการแบบไม่เป็นเชิงเส้น (27) และทำการเริ่มต้นค่าน้ำหนักแบบสุ่ม ดังนั้นโครงสร้างของแบบจำลองข่ายงานนิวรัลเริ่มต้นจะได้ดังรูปที่ 9

$$MSE = \frac{1}{n} \sum_{k=1}^n (C_{2tg}(k) - C_{2N}(k))^2 \quad (16)$$

โดย C_{2tg} คือ ค่าความเข้มข้นเป้าหมาย

และ C_{2N} คือ ค่าความเข้มข้นที่ทำนายโดยข่ายงานนิวรัล



รูปที่ 9 โครงสร้างแบบจำลองข่ายงานนิวรัลของถึงที่ 2

- หลังจากได้ข้อมูลต่างๆแล้ว จะต้องทำข้อมูลให้อยู่ในมาตรฐานเดียวกันเพื่อปรับความสำคัญของข้อมูลแต่ละชนิดให้มีความสำคัญเท่ากัน เช่น ค่าอัตราการไหลอาจจะมีค่าอยู่ในหลักร้อย แต่ค่าความเข้มข้นอาจจะมีค่าอยู่ในช่วงทศนิยมที่มีกำลังติดลบสูงๆ ดังนั้นหากไม่ทำการปรับความสำคัญของข้อมูล จะทำให้ค่าความเข้มข้นดูเหมือนมีค่าน้อยมากหรือมีความสำคัญน้อยมากเมื่อเทียบกับค่าของอัตราการไหล ซึ่งในการปรับข้อมูลอาจจะใช้สมการที่ (17) ในการปรับข้อมูลให้อยู่ในช่วง 0.05-0.95 (26)

$$ValueSD = \left[\frac{(ValueAC - min\ value)(0.95 - 0.05)}{(max\ value - min\ value)} \right] + 0.05 \quad (17)$$

โดย $ValueSD$ คือ ค่าของข้อมูลที่ได้ทำการปรับมาตรฐานแล้ว

$ValueAC$ คือ ค่าของข้อมูลจริง

เมื่อทำการปรับมาตรฐานข้อมูลแล้ว จากนั้นจะทำการฝึกข่ายงานที่สร้างขึ้นด้วยชุดข้อมูลฝึกสอนและทดสอบข่ายงานด้วยชุดข้อมูลทดสอบ จากตัวอย่างได้ใช้การฝึกสอนแบบ Levenberg-Marquardt โดยโครงสร้างของการฝึกสอนแสดงได้ดังรูปที่ 10 ที่แสดงให้เห็นถึงการใช้ค่าความแตกต่างของค่าความเข้มข้นของกรดจริงที่ได้จากกระบวนการกับค่าทำนายที่ได้จากข่ายงานนิวรัลเป็นสัญญาณในการฝึกสอนข่ายงาน ในแต่ละรอบของการฝึกสอนจะทำการตรวจสอบค่าความแตกต่างนี้ด้วยชุดทดสอบไปพร้อมกัน เพื่อแก้ปัญหาการเกิดโอเวอร์ฟิตติ้ง (over fitting) หรือโครงข่ายที่มีการเรียนรู้สูงเกินไปจนเกิดการจดจำข้อมูลแต่จะไม่มี การเรียนรู้ สักเกตได้จากจะให้ผลทดสอบที่ดีในชุดข้อมูลฝึกสอน แต่จะให้ผลทดสอบที่ต่ำในชุดข้อมูลทดสอบ การฝึกสอนจะดำเนินไปจนกว่าค่าความแตกต่างจะอยู่ในช่วงที่ยอมรับได้และการฝึกสอนจะหยุดลง ซึ่งเกณฑ์ในการใช้วัดค่าความแตกต่างหรือกล่าวอีกนัยหนึ่งคือประสิทธิภาพของการทำนายของข่ายงานมีอยู่ด้วยกันหลายเกณฑ์ เช่น Mean Squared Error (MSE) และ Sum of Squared Error (SSE) เป็นต้น โดยเกณฑ์ที่ใช้ในการวัดประสิทธิภาพการทำนายของแบบจำลองข่ายงานนิวรัลของกระบวนการนี้ คือ ค่า MSE ต้องน้อยกว่าหรือเท่ากับ 0.001 หมายความว่า จะยอมรับความผิดพลาดของการทำนายความเข้มข้นของกรดไฮโดรคลอริกในถึงที่ 2 ไม่เกิน ± 0.03 ของข้อมูลที่ปรับมาตรฐานแล้ว

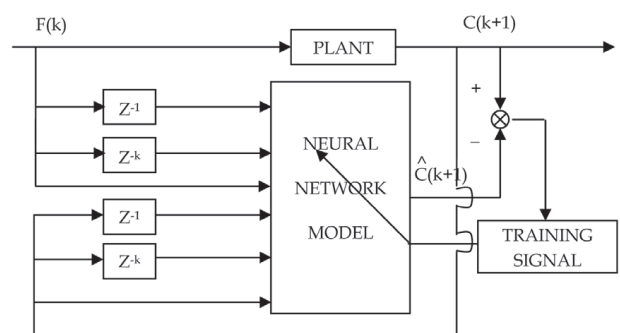
- เมื่อข่ายงานได้ผ่านขั้นตอนการฝึกสอนเรียบร้อยแล้ว จะต้องทำการตรวจสอบข่ายงานอีกครั้งโดยใช้ชุดข้อมูลตรวจสอบซึ่งเป็นข้อมูลที่ทำการเก็บหรือสร้างขึ้นครอบคลุมในช่วงของสภาวะการทำงานของกระบวนการ โดยจะเป็นข้อมูลคนละชุดกับชุดข้อมูลฝึกสอนและชุดข้อมูลทดสอบ แต่อาจจะมี ความแตกต่างในรูปแบบของข้อมูลเช่น สร้างขึ้นด้วยสัญญาณกระตุ้น (excitation signals)

ที่มีรูปแบบแตกต่างกัน เช่น แบบขั้นบันได (step function) แบบฟังก์ชันทางลาด (ramp function) และแบบฟังก์ชันพัลส์ (pulse function) เป็นต้น ถ้าค่าความผิดพลาดในการทำนายของข่ายงานจากชุดข้อมูลตรวจสอบมากกว่าค่าที่กำหนด จะต้องทำการฝึกสอนหรือปรับค่าน้ำหนักของข่ายงานใหม่ หรืออาจจะต้องทำการปรับโครงสร้างของข่ายงานใหม่แล้วทำการฝึกสอนอีกครั้งจนกว่าจะได้ค่าความผิดพลาดน้อยกว่าหรือเท่ากับที่กำหนดไว้จึงจะได้แบบจำลองข่ายงานนิเวศของกระบวนการที่ต้องการ

- ข่ายงานที่ได้หลังจากตรวจสอบด้วยชุดข้อมูลตรวจสอบแล้วสามารถทำนายพฤติกรรมของกระบวนการเคมีได้อย่างน่าพอใจในความคลาดเคลื่อนที่กำหนด แต่อาจไม่ใช่โครงสร้างที่ดีที่สุดของข่ายงาน ดังนั้นจึงต้องดำเนินการหาโครงสร้างที่ดีที่สุดของแบบจำลองข่ายงานนิเวศ ซึ่งจากกระบวนการกำจัดสนิมเหล็กด้วยกรดนี้ โครงสร้างที่กำหนดเริ่มต้นของข่ายงาน คือ [9-4-1] (ดังรูปที่ 9) หมายถึงจำนวนโหนดในชั้นข้อมูลป้อนเข้าข่ายงาน ในชั้นซ่อนและในชั้นข้อมูลส่งออกจากข่ายงานตามลำดับ จากนั้นจะทำการปรับเปลี่ยนจำนวนโหนดในชั้นซ่อนเพิ่มขึ้นเป็น 8, 12, 16 และ 20 ตามลำดับ และเริ่มกระบวนการฝึกสอนข่ายงานใหม่โดยใช้โครงสร้างของข่ายงานที่ทำการปรับเปลี่ยนจำนวนโหนดในชั้นซ่อนนั้น โดยใช้ข้อมูลในการฝึกสอน จำนวนข้อมูลของการฝึกสอนและเกณฑ์ต่างๆ ในการฝึกสอนข่ายงานแบบเดียวกันในทุกๆ โครงสร้าง จนกระทั่งผ่านขั้นตอนการตรวจสอบข่ายงานและการทำการหาค่า MSE ในแต่ละโครงสร้าง เมื่อได้ค่า MSE ของแต่ละโครงสร้างที่มีจำนวนโหนดในชั้นซ่อนที่ต่างกันแล้ว

นำค่า MSE มาเปรียบเทียบกับ โครงสร้างที่เหมาะสมที่สุดที่จะใช้เป็นตัวแทนของกระบวนการคือ โครงสร้างที่ให้ค่า MSE น้อยที่สุด ซึ่งจะได้โครงสร้างที่เหมาะสมคือ [9-4-1] ที่ให้ค่า MSE เท่ากับ 8.069×10^{-6} มีค่าน้อยที่สุดเมื่อเปรียบเทียบกับทุกโครงสร้าง ดังแสดงในตารางที่ 1 ที่แสดงถึงค่า MSE ของแต่ละโครงสร้างของแบบจำลองข่ายงานนิเวศของกระบวนการกำจัดสนิมเหล็กด้วยกรดในถังที่ 2

จะเห็นได้ว่าโครงสร้างที่เหมาะสมที่สุดมีจำนวนชั้นซ่อน 1 ชั้น และจำนวนโหนดในชั้นซ่อน 4 โหนด ซึ่งถ้าสังเกตจากค่า MSE ของโครงสร้างที่มีจำนวนโหนดในชั้นซ่อนที่ต่างกันแล้ว (ตารางที่ 1) จะพบว่า การเพิ่มจำนวนโหนดในชั้นซ่อนไม่ได้ทำให้ค่า MSE หรือค่าความผิดพลาดของการทำนายลดลงเสมอไป และยังถ้าจำนวนโหนดในชั้นซ่อนมีจำนวนมากเกินไปอาจทำให้การทำนายแย่งสังเกตได้จากตารางที่ 1 ค่า MSE ของโครงสร้างที่มีจำนวนโหนดในชั้นซ่อน 20 โหนด จะมีค่ามากที่สุดในทุกๆ โครงสร้าง



รูปที่ 10 โครงสร้างการฝึกข่ายงานนิเวศแบบป้อนไปข้างหน้า

ตารางที่ 1. ค่า MSE ของแบบจำลองข่ายงานนิเวศของกระบวนการกำจัดสนิมเหล็กด้วยกรดที่มีจำนวน โหนดในชั้นซ่อนต่างๆ

ถังกรด	จำนวนโหนดในชั้นซ่อน	ค่า Mean Squared Error (MSE) หลังจากการตรวจสอบ
ถังที่ 2 (10% HCl)	4	8.069×10^{-6}
	8	1.867×10^{-5}
	12	2.194×10^{-5}
	16	9.191×10^{-6}
	20	5.525×10^{-4}


5.2 การประยุกต์ใช้ข่ายงานนิวรัลในการควบคุม

นอกจากข่ายงานนิวรัลจะใช้เป็นแบบจำลองของกระบวนการทางเคมีได้อย่างมีประสิทธิภาพแล้ว ข่ายงานนิวรัลยังสามารถประยุกต์ใช้ในการควบคุมกระบวนการทางเคมีได้อย่างดีอีกด้วย ตัวอย่างเช่น ไพศาลและคณะ (26) ได้ประยุกต์ใช้ข่ายงานนิวรัลร่วมกับการควบคุมแบบโมเดลพรีดิกทีฟ (model predictive control, MPC) ซึ่งเป็นเทคนิคการควบคุมที่อาศัยแบบจำลองเพื่อควบคุมกระบวนการกำจัดสนิมเหล็กด้วยกรด จากผลการควบคุมแสดงให้เห็นว่าตัวควบคุมข่ายงานนิวรัลร่วมกับ MPC มีประสิทธิภาพในการควบคุมกระบวนการได้ดีกว่าตัวควบคุมแบบดั้งเดิม และในกระบวนการทางเคมีอื่นๆ การประยุกต์ใช้ข่ายงานนิวรัลในการควบคุมก็ให้ผลการควบคุมที่น่าพอใจเช่นเดียวกัน เช่น การควบคุมองค์ประกอบของผลิตภัณฑ์ในเครื่องปฏิกรณ์เคมีแบบกะ (CSTR) (28,29) และในหอกลั่น (30) การประยุกต์ใช้ในการควบคุมอุณหภูมิในเครื่องปฏิกรณ์ซึ่งมีรายงานในหลายงานวิจัย (31-33) และยังมีมีการประยุกต์ใช้ในอุตสาหกรรม เช่น ในอุตสาหกรรมน้ำตาลเพื่อควบคุมความเข้มข้นของน้ำเชื่อม (syrup) (34) เป็นต้น สำหรับงานวิจัยเมื่อไม่นานมานี้ ได้มีการประยุกต์ใช้ข่ายงานนิวรัลในการควบคุมความบริสุทธิ์ของสาร tert-amyl methyl ether (TAME) ในหอกลั่นแบบมีปฏิริยา (reactive distillation column) และเปรียบเทียบกับ การควบคุมแบบดั้งเดิม ผลจากการเปรียบเทียบแสดงให้เห็นว่าการควบคุมที่ประยุกต์ใช้ข่ายงานนิวรัลให้ผลการควบคุมที่เรียบและดีกว่า นอกจากนี้ในการควบคุมกระบวนการทางด้านชีวเคมี ตัวควบคุมข่ายงานนิวรัลยังมีประสิทธิภาพในการควบคุมที่ดีกว่าตัวควบคุมแบบ พีไอดี ในด้านการปรับปรุงค่าเวลาของการตอบสนอง (settling time) เวลาหน่วง (dead time) และค่าความคลาดเคลื่อนที่สถานะคงตัว (steady state error) อีกด้วย (35)


จากงานวิจัยที่ได้มีการประยุกต์ใช้ข่ายงานนิวรัลในการควบคุมที่กล่าวมาข้างต้น จะมีรูปแบบในการนำข่ายงานนิวรัลไปใช้แตกต่างกัน ในบางกรณีจะมีการใช้ข่ายงานนิวรัลแบบผกผัน (INN) ในการควบคุมกระบวนการโดยตรง (35-37) ในโครงสร้างการควบคุมแบบนี้จะใช้ข่ายงานนิวรัลเป็นตัวควบคุมกระบวนการโดยตรงซึ่งไม่ประยุกต์ใช้ร่วมกับเทคนิคการควบคุมอื่น และในบางกรณีจะมีการ

ประยุกต์ใช้ข่ายงานนิวรัลกับเทคนิคการควบคุมแบบอื่นร่วมกัน (38-42) โดยโครงสร้างของการควบคุมในกรณีต่างๆ ที่กล่าวมานี้จะมีความแตกต่างกันและรูปแบบของข่ายงานนิวรัลที่ใช้ในการควบคุมก็จะแตกต่างกันไปด้วย ดังนั้นจึงขอยกตัวอย่างโครงสร้างการควบคุมกระบวนการส่วนใหญ่ที่ได้มีการใช้ข่ายงานนิวรัลในการควบคุม ดังนี้

1. การใช้ตัวควบคุมข่ายงานนิวรัลแบบผกผัน (INN) โครงสร้างของการควบคุมกระบวนการแสดงได้ดังรูปที่ 11 ในโครงสร้างการควบคุมแบบนี้ ข่ายงานนิวรัลจะมีหน้าที่เป็นตัวควบคุมกระบวนการ ดังนั้นข้อมูลที่ออกมาจากข่ายงานนิวรัลจะเป็นตัวแปรปรับกระบวนการ ($u(k)$) ข่ายงานนิวรัลแบบผกผันจะใช้ข้อมูลการเรียนรู้หรือการฝึกสอนแตกต่างจากข่ายงานนิวรัลแบบไปข้างหน้า (FNN) ที่ใช้เป็นแบบจำลองของกระบวนการ ยกตัวอย่างในกรณีของกระบวนการกำจัดสนิมเหล็กด้วยกรดข้อมูลป้อนเข้าและโครงสร้างของข่ายงานแสดงได้ดังรูปที่ 9 ข้อมูลที่ออกมาจากข่ายงานจะเป็นค่าความเข้มข้นของกรดไฮโดรคลอริกในถังที่ 2 ซึ่งเป็นการตอบสนองของกระบวนการเมื่อมีการเปลี่ยนแปลงตัวแปรขาเข้ากระบวนการนั่นเอง แต่สำหรับข้อมูลป้อนเข้าและข้อมูลขาออกของ INN จะแสดงได้ดังรูปที่ 12 ข้อมูลขาออกของ INN คือ $F_3(k)$ หรืออัตราการไหลจากถังสายที่ 3 ซึ่งเป็นตัวแปรปรับกระบวนการของถังกรดถังที่ 2 จากรูปทั้งสองจะสังเกตได้ว่าความแตกต่างของข้อมูลขาเข้าข่ายงานทั้งสองคือ INN จะใช้ค่าความเข้มข้นของกรดที่เวลาในอนาคต ($C_2(k+1)$) แทน โหนดข้อมูล $F_3(k)$ ในแบบจำลองกระบวนการ โดยในการประยุกต์ใช้ INN นั้นจะต้องรู้ค่าตัวแปรควบคุมในอนาคต เช่น ค่าของ $C_2(k+1)$ ซึ่งค่าที่จะป้อนเข้าข่ายงานอาจใช้ค่าเป้าหมายได้ เนื่องจากคาดหมายว่าค่าตัวแปรควบคุมในอนาคตนั้นจะต้องเข้าสู่เป้าหมาย

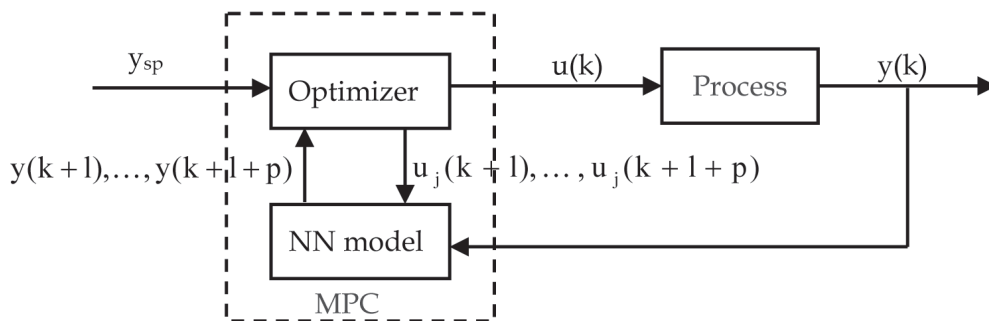


รูปที่ 11 โครงสร้างการควบคุมแบบ INN

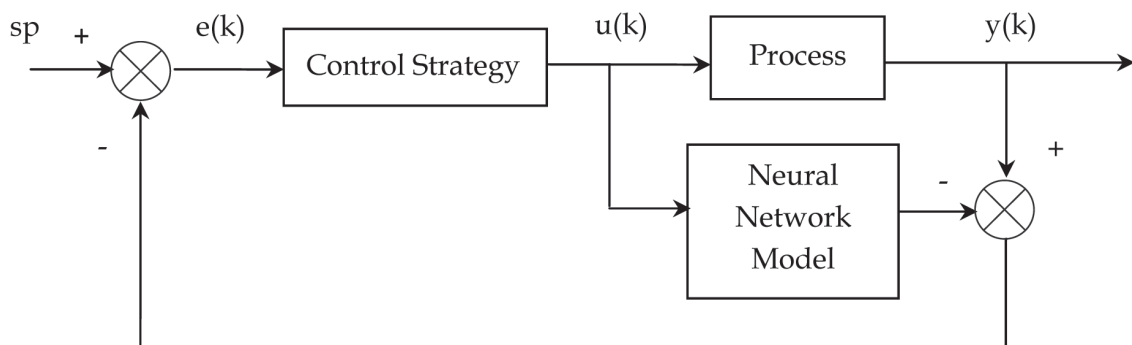


รูปที่ 12 โครงสร้างข่ายงานนิวรัลแบบ INN

2. การใช้ข่ายงานนิวรัลร่วมกับเทคนิคการควบคุมที่อาศัยแบบจำลอง (MPC) ดังแสดงในรูปที่ 13 ซึ่งการควบคุมในลักษณะนี้จะใช้ข่ายงานนิวรัลเป็นแบบจำลองของกระบวนการ (FNN) เพื่อทำนายพฤติกรรมของกระบวนการในอนาคตและทำงานร่วมกับเทคนิคต่างๆ ในการหาตัวแปรปรับที่เหมาะสมกับกระบวนการ เช่น การออปติไมซ์ (optimization) ซึ่งส่วนใหญ่จะใช้สำหรับควบคุมกระบวนการที่มีความซับซ้อนและหาแบบจำลองทางคณิตศาสตร์ของกระบวนการไม่ได้หรือแบบจำลองที่ได้จากกฎการอนุรักษ์ไม่สามารถเป็นตัวแทนของกระบวนการได้ และข่ายงานนิวรัลยังสามารถประยุกต์ใช้ในการควบคุมได้อีกหลายรูปแบบ เช่น โครงสร้างการควบคุมที่แสดงในรูปที่ 14 ซึ่งเรียกว่าเทคนิคการควบคุมแบบ IMC (internal model control) โดยจะใช้ข่ายงานนิวรัลในการทำนายค่าตัวแปรควบคุมของกระบวนการแล้วนำไปเปรียบเทียบกับค่าตอบสนองของกระบวนการจริง โดยค่าความแตกต่างที่เกิดขึ้นจะใช้เป็นสัญญาณในการคำนวณค่าตัวแปรปรับกระบวนการที่เหมาะสม



รูปที่ 13 โครงสร้างการควบคุมที่อาศัยแบบจำลองร่วมกับข่ายงานนิวรัล



รูปที่ 14 โครงสร้างการควบคุมแบบ IMC ร่วมกับข่ายงานนิวรัล

จากงานวิจัยที่ได้กล่าวถึงการนำข่างานนิวัตไปใช้ในการควบคุมข้างต้นได้แสดงให้เห็นว่า ข่างานนิวัตมีประสิทธิภาพที่ดีในการนำไปใช้ในการควบคุมกระบวนการทางเคมี ซึ่งเป็นกระบวนการที่มีความซับซ้อนและมีความไม่เป็นเชิงเส้นสูง และเมื่อนำผลการควบคุมมาเปรียบเทียบกับตัวควบคุมแบบดั้งเดิมแล้วจะให้ประสิทธิภาพในการควบคุมที่ดีกว่าในหลายด้าน เช่น ให้การควบคุมที่ราบเรียบ เวลาการตอบสนองของกระบวนการ เวลาหน่วงและค่าความคลาดเคลื่อนที่สถานะคงตัวที่น้อยกว่า ทั้งนี้เนื่องมาจาก การควบคุมที่อาศัยข่างานนิวัตนั้น เป็นการควบคุมที่ใช้ข้อมูลของกระบวนการหรือแบบจำลองของกระบวนการในการคำนวณค่าตัวแปรปรับ ซึ่งจะทำให้ตัวแปรปรับที่ได้สามารถปรับกระบวนการได้สอดคล้องกับพฤติกรรมเปลี่ยนแปลงของตัวแปรต่างๆ ในกระบวนการได้ดีกว่าการใช้ค่าความแตกต่างของตัวแปรควบคุมกับค่าเป้าหมายในการคำนวณค่าตัวแปรปรับกระบวนการเพียงอย่างเดียว ดังที่ใช้ในตัวควบคุมแบบดั้งเดิม (พี พีไอ และพี ไอดี)

6. บทสรุป

บทความนี้ได้กล่าวถึงโครงข่ายประสาทเทียมหรือข่างานนิวัตซึ่งเป็นสมองกลที่มีความฉลาดและสามารถนำไปใช้ประโยชน์ในหลายๆ ด้านได้อย่างมีประสิทธิภาพ จะเห็นได้ว่าการประยุกต์ใช้ข่างานนิวัตมีเพิ่มมากขึ้นอย่างต่อเนื่องในอุตสาหกรรมเคมี เนื่องจากข่างานนิวัตมีความสามารถที่ดีในหาความสัมพันธ์ระหว่างข้อมูลเพื่อใช้ในการแก้ปัญหาต่างๆ ในอุตสาหกรรมได้อย่างน่าพอใจ โดยผลการประยุกต์ใช้ข่างานนิวัตจะมีประสิทธิภาพดีแค่ไหนนั้นขึ้นอยู่กับโครงสร้างและวิธีการสร้างข่างานนิวัตเป็นสำคัญ จะเห็นได้ว่าแบบจำลองข่างานนิวัตสำหรับกระบวนการทางเคมีจะต้องคำนึงถึงพลศาสตร์ของกระบวนการซึ่งเป็นผลต่อเนื่องไปถึงการกำหนดข้อมูลขาเข้าของข่างานด้วย ฟังก์ชันกระตุ้นและรูปแบบของข่างานที่ใช้กันอย่างกว้างขวางคือ ฟังก์ชันซิกมอยด์และข่างานนิวัตแบบป้อนไปข้างหน้าตามลำดับ สำหรับการประยุกต์ข่างานนิวัตได้นำไปประยุกต์ใช้ในสองแนวทางคือ การใช้ข่างานนิวัตเป็นแบบจำลองของกระบวนการ

และการประยุกต์ใช้ข่างานนิวัตในการควบคุมกระบวนการ จะเห็นได้ว่าแบบจำลองข่างานนิวัตสามารถเป็นตัวแทนของกระบวนการทางเคมีได้อย่างน่าพอใจ ไม่ว่าจะเป็นกระบวนการที่มีความซับซ้อนหรือกระบวนการที่มีความไม่เป็นเชิงเส้นสูงก็ตามและข่างานนิวัตมีความสามารถที่ดีในการควบคุมกระบวนการและการประยุกต์ใช้ร่วมกับเทคนิคการควบคุมที่เป็นที่รู้จักต่างๆ ได้อย่างมีประสิทธิภาพ

7. สัญลักษณ์

- a คือ พารามิเตอร์ความชันของฟังก์ชันซิกมอยด์
- b คือ ค่าเอนเอียงหรือไบแอส
- C^n คือ ความเข้มข้นของกรดไฮโดรคลอริกถึงที่ n โดยที่ $n = 1, 2, \dots$
- $C_n(k)$ คือ ความเข้มข้นของกรดไฮโดรคลอริกถึงที่ n ที่เวลา k โดยที่ $n = 1, 2, \dots$
- C_{2tg} คือ ค่าความเข้มข้นเป้าหมาย
- C_{2N} คือ ค่าความเข้มข้นที่ทำนายโดยข่างานนิวัต
- e คือ ค่าความผิดพลาดที่ขั้นส่งออก
- F_n คือ อัตราการไหลเชิงปริมาตรจากถึงที่ n โดยที่ $n = 1, 2, \dots$
- $F_n(k)$ คือ อัตราการไหลเชิงปริมาตรจากถึงที่ n ที่เวลา k โดยที่ $n = 1, 2, \dots$
- $\max \text{ value}$ คือ ค่าสูงสุดของข้อมูลจริง
- $\min \text{ value}$ คือ ค่าต่ำสุดของข้อมูลจริง
- O_i^1 คือ ข้อมูลส่งออกจากโหนด i ชั้นนิวัตชั้นที่ 1
- t_k คือ ค่าเป้าหมาย
- $u(k)$ คือ ตัวแปรปรับกระบวนการที่เวลา k
- v คือ ผลรวมของข้อมูล
- ValueAC คือ ค่าของข้อมูลจริง
- ValueSD คือ ค่าของข้อมูลที่ได้ทำการปรับมาตรฐานแล้ว
- w_i คือ น้ำหนักของข้อมูลที่ i โดย $i = 1, 2, \dots$
- x_i คือ ข้อมูลป้อนเข้าข้อมูลที่ i โดย $i = 1, 2, \dots$
- η คือ อัตราการเรียนรู้

8. กิตติกรรมประกาศ

ผู้เขียนขอขอบคุณ ศาสตราจารย์ ดร. ไพศาล กิตติศุภกร คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย สำหรับคำแนะนำและข้อเสนอแนะที่เป็นประโยชน์อย่างยิ่งทำให้บทความนี้สำเร็จลุล่วงได้ด้วยดี

9. เอกสารอ้างอิง

- (1) Kourentzes N. Intermittent demand forecasts with neural networks. *Int J Prod Econ.* 2013;143(1): 198-206.
- (2) Bhatt MA, Evaluation and associations: A neural-network model of advertising and consumer choice. *J Econ Behav Organ.* 2012;82(1): 236-255.
- (3) Abdou HA, Pointon J, El-Masry A, Olugbode M, Lister RJ. A variable impact neural network analysis of dividend policies and share prices of transportation and related companies. *J Int Finan Markets, Inst Money.* 2012;22(4): 796-813.
- (4) Ozkan F. Comparing the forecasting performance of neural network and purchasing power parity: The case of Turkey. *Econ Modelling.* 2013;31: 752-758.
- (5) Chaisiwamongkol W, Junsawang P, Engchanil J, Chaimanee P, Chaiwong W, Puttamat W. Patients classification of liver cancer by applying artificial neural networks. *KKU Res. J.* 2013;18(4): 585-593. Thai.
- (6) Sato W, Hoshi K, Kawakami J, Sato K, Sugawara A, Saito Y, et al. Assisting the diagnosis of Graves' hyperthyroidism with Bayesian-type and SOM-type neural networks by making use of a set of three routine tests and their correlation with free T4. *Biomed Pharmacother.* 2010;64(1): 7-15.
- (7) Fernandez M, Caballero J. Bayesian-regularized genetic neural networks applied to the modeling of non-peptide antagonists for the human luteinizing hormone-releasing hormone receptor. *J Mol Graph Model.* 2006;25(4): 410-422.
- (8) Bethesda, MD. 8. Rebuilding the Nervous System with Stem Cells. In *Stem Cell Information* [Internet]. 2009 [updated 2009 Mar 24; cited 2013 Oct Apr 22]. Available from: <http://stemcells.nih.gov/info/scireport/pages/chapter8.aspx>
- (9) Daosud W. Neural network based model predictive control for a steel pickling process [PhD thesis]. Bangkok: Chulalongkorn University; 2006.
- (10) Edgar TF, Himmelblau DM, Lasdon LS. Unconstrained multivariable optimization. In: Glandt ED, Klein MT, Edgar TF, editors. *Optimization of chemical processes.* New York: McGraw-Hill; 2001. p. 181-211.
- (11) Rivera EC, Atala DI.P., Filho FM, Costa AC, Filho RM. Development of real-time state estimators for reaction–separation processes: A continuous flash fermentation as a study case. *Chem Eng Process.* 2010; 49(4): 402-409.
- (12) Arpornwichanop A, Shomchoam N. Control of fed-batch bioreactors by a hybrid on-line optimal control strategy and neural network estimator. *Neurocomputing.* 2009;72(10–12): 2297-2302.
- (13) Kowalska TO, Kaminski M. Application of the OBD method for optimization of neural state variable estimators of the two-mass drive system. *Neurocomputing.* 2009;72(13–15): 3034-3045.
- (14) Villalobos J.M. G, Resendiz JR, Araiza E.A. R, Mucino VH. A review of parameter estimators and controllers for induction motors based on artificial neural networks. *Neurocomputing.* 2013;118(22): 87-100.
- (15) Kashani MN, Shahhosseini S. A methodology for modeling batch reactors using generalized dynamic neural networks. *Chem Eng J.* 2010;159(1-3): 195–202.

- (16) Matos EM, Guirardello R, Mori M, Nunhez JR. Modeling and simulation of a pseudo-three-phase slurry bubble column reactor applied to the process of petroleum hydrodesulfurization. *Comput Chem Eng.* 2009;33(6): 1115-1122.
- (17) Medina EA, Paz-Paredes JI. Artificial neural network modeling techniques applied to the hydrodesulfurization process. *Math Comput Model.* 2009;49(1-2): 207-214.
- (18) Lobato J, Izares PC, Rodrigo MA, Piuleac CG, Curteanu S, Linares JJ. Direct and inverse neural networks modelling applied to study the influence of the gas diffusion layer properties on PBI-based PEM fuel cells. *Int J Hydrogen Energ.* 2010;35(15): 7889-7897.
- (19) Ko YD, Moon P, Kim CE, Ham MH, Myoung JM, Yun I. Modeling and optimization of the growth rate for ZnO thin films using neural networks and genetic algorithms. *Expert Syst Appl.* 2009;36(2): 4061-4066.
- (20) Kweon KE, Lee JH, Ko YD, Jeong MC, Myoung JM, Yun I. Neural network based modeling of HfO₂ thin film characteristics using Latin Hypercube Sampling. *Expert Syst Appl.* 2007;32(2): 358-363.
- (21) Mjalli FS, Asheh SA, Alfadala HE. Use of artificial neural network black-box modeling for the prediction of wastewater treatment plants performance. *J Environ Manage.* 2007;83(3): 329-338.
- (22) Elsayed K, Lacor C. Modeling, analysis and optimization of aircyclones using artificial neural network, response surface methodology and CFD simulation approaches. *Powder Technol.* 2011;212(1): 115-133.
- (23) Krzywanski J, Nowak W. Modeling of heat transfer coefficient in the furnace of CFB boilers by artificial neural network approach. *Int J Heat Mass Tran.* 2012;55(15-16): 4246-4253.
- (24) Pendashteh AR, Razi AF, Chaibakhsh N, Abdullah LC, Madaeni SS, Abidin ZZ. Modeling of membrane bioreactor treating hypersaline oily wastewater by artificial neural network. *J Hazard Mater.* 2011;192(2): 568-575.
- (25) Tan CK, Ward J, Wilcox SJ, Payne R. Artificial neural network modelling of the thermal performance of a compact heat exchanger. *Appl Therm Eng.* 2009;29(17-18): 3609-3617.
- (26) Kittisupakorn P, Thitiyasook P, Hussain MA, Daosud W. Neural network based model predictive control for a steel pickling process. *J Process Contr.* 2009;19(4): 579-590.
- (27) Hussain MA. Review of the applications of neural networks in chemical process control - simulation and online implementation: *Artif Intell Eng.* 1999;13(1): 55-68.
- (28) Psychogios DM, Ungar LH. Direct and indirect model based control using artificial neural networks, *Ind Eng Chem Res.* 1991;30: 2564-2573.
- (29) Nikravesh M, Farell AE, Stanford TG. Control of nonisothermal CSTR with time varying parameters via dynamic neural network control (DNNC). *Chem Eng J.* 2000;76(1): 1-16.
- (30) Ramchandran S, Rhinehart RR. A very simple structure for neural-network control of distillation. *J Process Contr.* 1995;5(2): 115-128.
- (31) Dirion JL, Ettedgui B, Cabassud M, Le Lann MV, Casamatta G. Elaboration of a neural network system for semi-batch reactor temperature control: an experimental study. *Chem Eng Process: Process Intensification.* 1996;35(3): 225-234.
- (32) Venkateswarlu Ch, Rao KV. Dynamic recurrent radial basis function network model predictive control of unstable nonlinear processes. *Chem Eng Sci.* 2005;60(23): 6718-6732.

- (33) Nikolaou M, Hanagandi V. Input–output exact linearization of nonlinear dynamical systems modeled by recurrent neural networks. *AIChE J.* 1993;39: 1890–1894.
- (34) Benne M, Perez BG, Chabriat JP, Herve P. Artificial neural networks for modelling and predictive control of an industrial evaporation process. *J Food Eng.* 2000;46(4): 227–234.
- (35) Imtiaz U, Assadzadeh A, Jamuar SS, Sahu JN. Bioreactor temperature profile controller using inverse neural network (INN) for production of ethanol. *J Process Contr.* 2013;23(5): 731– 742.
- (36) Hussain MA, Kittisupakorn P, Daosud W. Implementation of neural network based inverse model control strategies on an exothermic reactor. *ScienceAsia.* 2001;27: 41-50.
- (37) Daosud W, Thitiyasook P, Arpornwichanop A, Kittisupakorn P, Hussain MA. Neural network inverse model-based controller for the control of a steel pickling process. *Comput Chem Eng.* 2005;29(10): 2110–2119.
- (38) Vasickaninova A, Bakosova M, Meszaros A, Klemes JJ. Neural network predictive control of a heat exchanger. *Appl Therm Eng.* 2011;31(13): 2094-2100.
- (39) Mohanty S. Artificial neural network based system identification and model predictive control of a rotation column. *J Process Contr.* 2009;19(6): 991–999.
- (40) Chen H, Zouaoui Z, Chen Z, A modified Smith predictive scheme based back-propagation neural network approach for FOPDT processes control. *J Process Contr.* 2013;23(9): 1261-1269.
- (41) Hosen MA, Hussain MA, Mjalli FS, Khosravi A, Creighton D, Nahavandi S. Performance analysis of three advanced controllers for polymerization batch reactor: An experimental investigation. *Chem Eng Res Des.* Forthcoming 2013.
- (42) Stosch MV, Oliveira R, Peres J, Azevedo SF. A general hybrid semi-parametric process control framework. *J Process Contr.* 2012;22(7): 1171-1181.