

การพยากรณ์การถ่ายโอนมวลในกระบวนการออสโมซิสในสับประรดด้วยโครงข่ายประสาทเทียม

Prediction of Mass Transfer during the Osmosis Process of Pineapple using Artificial Neural Networks

สิริมา ชินสาร¹

Sirima Chinnasarn¹

Received: 31 August 2015; Accepted: 4 December 2015

บทคัดย่อ

การถ่ายโอนมวลสารเป็นกลไกหลักที่เกิดขึ้นในระหว่างกระบวนการออสโมซิสซึ่งมีปัจจัยที่เกี่ยวข้องหลายปัจจัย การพยากรณ์การถ่ายโอนมวลสารในกระบวนการออสโมซิสด้วยตัวแบบเชิงคำนวณจึงเป็นสิ่งที่มีความจำเป็นที่จะช่วยลดต้นทุนในการศึกษา งานวิจัยนี้จึงนำเสนอการพยากรณ์การถ่ายโอนมวลสารในกระบวนการออสโมซิสสับประรดด้วยโครงข่ายประสาทเทียม 3 ประเภทคือ BPNN, RBF และ SVM ซึ่งทั้งสามประเภทเป็นวิธีการเรียนรู้ของเครื่องจักรแบบมีผู้สอน โดยโครงข่ายทั้ง 3 แบบจะถูกใช้ในการพยากรณ์ค่าปริมาณน้ำที่สูญเสียและปริมาณของแข็งที่เพิ่มขึ้นในกระบวนการออสโมซิสในสับประรด ผลการศึกษาพบว่าโครงข่ายประสาทเทียมแบบ BPNN เหมาะสมกับการทำนายปริมาณน้ำที่สูญเสียส่วนโครงข่ายประสาทเทียมแบบ BPNN เหมาะสมกับการทำนายค่าปริมาณของแข็งที่เพิ่มขึ้น

คำสำคัญ: การทำนายการถ่ายโอนมวลสารในกระบวนการออสโมซิส โครงข่ายประสาทเทียม

Abstract

Mass transfer is a principal mechanism occurring during the osmotic process. It involves many factors. Prediction of mass transfer during the osmotic process, based on a scientific computer model is necessary to reduce processing cost. In this research, BPNN, RBF and SVM were used for mass transfer predicting during the osmotic process of pineapple. They were used for predicting water loss and solid gain. Experimental results showed that the BPNN was suitable for water loss prediction. However, the RBF was optimal learning machine for estimating solid gain.

Keywords: Prediction of Mass Transfer during Osmosis Process, Artificial Neural Networks

บทนำ

สับประรดเป็นพืชเศรษฐกิจของไทยที่สามารถเก็บเกี่ยวได้ตลอดทั้งปี จึงมีการนำมาแปรรูปเป็นผลิตภัณฑ์ต่างๆ เพื่อเพิ่มมูลค่าและยืดอายุการเก็บรักษา วิธีการแปรรูปสับประรดวิธีการหนึ่งคือ การออสโมซิสสับประรดร่วมกับการอบแห้งเพื่อให้ได้ผลิตภัณฑ์อาหารว่างชนิดใหม่ที่มีรสชาติอร่อยและอายุการเก็บรักษานาน โดยการออสโมซิสเป็นวิธีการลดปริมาณน้ำในอาหารลงด้วยการแช่ชิ้นอาหารลงในสารละลายออสโมติก เช่น สารละลายน้ำตาล สารละลายเกลือ หรือสารละลายผสม

ระหว่างน้ำตาลและสารดูดความชื้น ซึ่งสารละลายออสโมติกที่ใช้เป็นสารละลายเข้มข้นที่มีค่าแรงดันสูงทำให้เกิดความแตกต่างของแรงดันออสโมติกระหว่างภายในเซลล์ของชิ้นอาหารและสารละลายภายนอก เกิดเป็นแรงขับให้มีการถ่ายโอนมวลสารระหว่างชิ้นอาหารและสารละลายภายนอกผ่านเยื่อหุ้มเซลล์หรือเซลล์เมมเบรนที่ทำหน้าที่เป็นเยื่อเลือกผ่าน น้ำภายในเซลล์อาหารจะแพร่ออกจากเซลล์สู่สารละลายภายนอก ในขณะที่ยวกันตัวถูกละลายภายนอกก็จะแพร่เข้าสู่ภายในเซลล์ของอาหาร เราสามารถเพิ่มอัตราการถ่ายโอนมวลสารดังกล่าว

¹ ภาควิชาวิทยาศาสตร์การอาหาร คณะวิทยาศาสตร์ มหาวิทยาลัยบูรพา ต.แสนสุข อ.เมือง จ.ชลบุรี 20131

¹ Department of Food Science, Faculty of Science, Burapha University, TambonSaensuk, Muang District, Chonburi, Province, 20131, Thailand, Email: sirima@buu.ac.th

ได้ด้วยการใช้สัญญาณภาคในการเตรียมขั้นต้น ซึ่งจะช่วยให้เนื้อเยื่อของสับประรดมีความพูนมากขึ้นจึงทำให้น้ำและสารละลายออสโมติกสามารถแพร่ผ่านเซลล์เมมเบรนได้ดียิ่งขึ้น และเนื่องจากอัตราการถ่ายโอนมวลสารเป็นปัจจัยสำคัญที่มีผลต่อการลดปริมาณน้ำในอาหารด้วยกระบวนการออสโมซิส ดังนั้นหากเราสามารถสร้างแบบจำลองที่สามารถอธิบายกระบวนการดังกล่าวได้จะมีประโยชน์อย่างยิ่งต่อการพัฒนากระบวนการในระดับสูงต่อไป แต่การถ่ายโอนมวลสารในระหว่างกระบวนการออสโมซิสนั้นมีปัจจัยที่เกี่ยวข้องกับการถ่ายโอนมวลสารหลายๆปัจจัยร่วมกัน ซึ่งการสร้างแบบจำลองแบบ Empirical model มักมีข้อจำกัดของการนำแบบจำลองนั้นไปใช้ ที่จะต้องควบคุมสภาวะของการทดลองให้เป็นสภาวะเช่นเดียวกับสภาวะที่ได้สร้างแบบจำลองขึ้น แบบจำลองเหล่านั้นจะนำไปสู่การต่อยอดในระบบการผลิตขนาดใหญ่ขึ้นได้ยาก เพื่อแก้ไขปัญหา นั้น งานวิจัยนี้จึงสนใจใช้ระบบโครงข่ายประสาทเทียม(Artificial Neural Network) เข้ามาช่วยในการสร้างแบบจำลองที่สามารถตอบสนองต่อการนำไปใช้ในระบบอุตสาหกรรมได้ดียิ่งขึ้น

โครงข่ายประสาทเทียมเป็นรูปแบบของการประมวลผลข้อมูลโดยเลียนแบบการทำงานของระบบประสาทของมนุษย์ จึงมีลักษณะเด่นที่สำคัญ คือ มีความสามารถในการเรียนรู้และปรับตัวได้ โดยมีโครงสร้างการประมวลผลที่เป็นโครงข่ายที่เชื่อมต่อกันอย่างทั่วถึง ทำให้โครงข่ายประสาทเทียมสามารถค้นหาความสัมพันธ์ระหว่างข้อมูลที่สลับซับซ้อนได้ดี จึงมีการนำโครงข่ายประสาทเทียมมาประยุกต์ใช้ในงานวิจัยด้านต่างๆ เช่น การเรียนรู้รูปแบบ การแยกประเภท การพยากรณ์ หรือ การหาค่าเหมาะที่สุด (optimization) เป็นต้น^{1,3,4,5} จากความสามารถในการแก้ปัญหาที่มีความสัมพันธ์ซับซ้อนดังกล่าว โครงข่ายประสาทเทียมจึงเป็นเครื่องมือที่มีความเป็นไปได้ในการนำมาใช้สร้างแบบจำลองสำหรับการถ่ายโอนมวลสารในระหว่างการออสโมซิสสับประรดที่ผ่านการเตรียมขั้นต้นด้วยสัญญาณภาคเพื่อเพิ่มความสามารถในการถ่ายโอนมวลสารของชิ้นสับประรดและทำการออสโมซิสด้วยสารละลายผสมระหว่างน้ำตาลซูโครสและกลีเซอรอล

จากข้อมูลใน (Table 2, 3) กำหนดให้ x_1 แทน Vacuum time, x_2 แทน Soaking time และ y แทน Actual value (ค่าข้อมูลจริงจากการทดลอง) จากการสังเกตพฤติกรรมของค่าของ x_1 และ x_2 พบว่า $x_1 = \{0,15\}$ และ $x_2 = \{20, 40, 60, 120, 180, 240\}$ ในการประมาณค่าของ $y = w_1x_1 + w_2x_2 + w_0$ โดยใช้วิธีการทางพีชคณิตโดยตรงนั้น จากลักษณะดังกล่าวของตัวแปรต้นทั้งสองตัวแปร จะทำได้ค่อนข้างยาก ดังนั้น งานวิจัยนี้มีวัตถุประสงค์เพื่อ

ศึกษาตัวแบบของโครงข่ายประสาทเทียมที่เหมาะสมสร้างตัวแบบเพื่อการพยากรณ์การถ่ายโอนมวลสารในสับประรดระหว่างกระบวนการออสโมซิสด้วยโครงข่ายประสาทเทียมและเปรียบเทียบประสิทธิภาพตัวแบบการพยากรณ์การถ่ายโอนมวลสารในสับประรดระหว่างกระบวนการออสโมซิสตามวิธีการที่กล่าวไว้ข้างต้น

วัสดุอุปกรณ์และวิธีการศึกษา

กระบวนการออสโมซิสสับประรด

ใช้วัตถุดิบ คือ สับประรดพันธุ์ศรีราชาที่มีปริมาณของแข็งที่ละลายได้ทั้งหมด 13 ± 1 องศาบริกซ์ ปอกเปลือกและหั่นเป็นชิ้นขนาด $2 \times 2 \times 1$ เซนติเมตร ปริมาณ 100 กรัม แช่ในสารละลายออสโมติกซึ่งเป็นสารละลายผสมระหว่างซูโครส 32.5เปอร์เซ็นต์โดยน้ำหนัก ร่วมกับกลีเซอรอล 32.5เปอร์เซ็นต์โดยน้ำหนัก ที่อุณหภูมิ 50 องศาเซลเซียส ใช้อัตราส่วนระหว่างสารละลายออสโมติกต่อสับประรด 3: 1 (โดยน้ำหนัก) เตรียมขั้นต้นก่อนการออสโมซิสด้วยการลดความดันภายในพลาสติกที่ใช้ออสโมซิสลงเป็น 200 ± 10 mbar ด้วยชุดเครื่องทำสุญญากาศแบบไดอะเทรม คงความดันนี้ไว้เป็นเวลา 15 นาที จากนั้นถอดพลาสติกออกจากชุดเครื่องทำสุญญากาศแล้วแช่พลาสติกลงในอ่างน้ำควบคุมอุณหภูมิไว้ที่ 50 องศาเซลเซียส เป็นเวลา 240 นาที ตัวอย่างจะถูกนำมาวิเคราะห์การถ่ายโอนมวลสาร ทุกๆ 20, 40, 60, 120, 180 และ 240 นาที โดยนำชิ้นสับประรดออกจากพลาสติก ชั้บให้แห้งด้วยกระดาษซับ นำไปชั่งน้ำหนักและหาความชื้นบันทึกเป็นน้ำหนักและความชื้นหลังการออสโมซิส ทำการทดลองทั้งหมด 3 ซ้ำคำนวณอัตราการถ่ายโอนมวลสาร คือ ปริมาณน้ำที่สูญเสีย (Water lose; WL) และปริมาณของแข็งที่เพิ่มขึ้น (Solid Gain; SG)⁷ ดังนี้

$$WL(\%) = \frac{(W_i M_i - W_f M_f)}{W_i} \times 100$$

$$SG(\%) = \frac{\left(\frac{W_f(100-M_f)}{100}\right) - \left(\frac{W_i(100-M_i)}{100}\right)}{W_i} \times 100$$

เมื่อ W_i คือ น้ำหนักเริ่มต้นของตัวอย่าง (กรัม), คือ น้ำหนักตัวอย่างที่เวลาใด ๆ (กรัม), M_i คือ ปริมาณความชื้นเริ่มต้นของตัวอย่าง (กรัมน้ำ/100 กรัม) และ M_f คือ ปริมาณความชื้นของตัวอย่างที่เวลาใด ๆ (กรัมน้ำ/100 กรัม)

การสร้างตัวแบบเพื่อการพยากรณ์การถ่ายโอนมวลสารในสลับประตระหว่างกระบวนการออสโมซิส

การสร้างตัวแบบโครงข่ายประสาทเทียมซึ่งใช้ในการคำนวณค่าตัวเลขของการพยากรณ์และสามารถนำค่าดังกล่าวมาเปรียบเทียบกับค่าการถ่ายโอนมวลจริงโดยนำระบบโครงข่ายประสาทเทียมแบบมีผู้สอน(Supervised Learning Artificial Neural Network) จำนวน 3 โครงข่าย ประกอบด้วยโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (Back-propagation Neural Networks: BPNN), แบบฟังก์ชันรัศมีฐาน (Radial Basis Function: RBF) และ ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machines: SVM) มาทำนายค่าการถ่ายโอนมวลเพื่อเปรียบเทียบประสิทธิภาพการทำงานของสามโครงข่ายในข้อมูลชุดนี้ ดังแสดงใน (Figure 1)

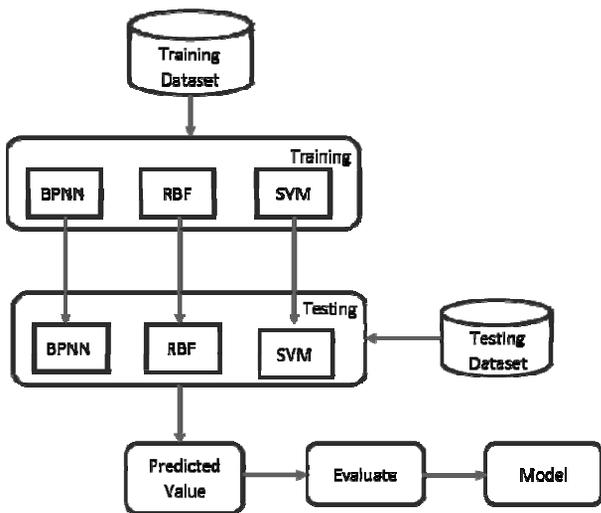


Figure 1 Prediction Process

โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ(Back-propagation Neural Networks: BPNN) เป็นขั้นตอนวิธีที่ใช้ในการเรียนรู้ของโครงข่ายประสาทเทียมที่มีโครงข่ายประสาทเทียมแบบหลายชั้น (Multilayer neural network) เพื่อใช้ในการปรับค่าน้ำหนักในเส้นเชื่อมต่อระหว่างโหนดให้เหมาะสม โดยการปรับค่าน้ำหนักจะขึ้นกับความแตกต่างของค่าเอาต์พุตที่คำนวณได้กับค่าเอาต์พุตที่ต้องการ

$$E(\vec{w}) = \frac{1}{2} \sum_{d \in D} \sum_{k \in \text{outputs}} (t_{kd} - o_{kd})^2$$

โดย

- t_{kd} คือ เซตของค่าตอบโหนดในข่ายงานประสาทฯ
- o_{kd} คือ ค่าคำตอบเป้าหมายที่ต้องการ
- k คือ โหนดของคำตอบที่กำลังสนใจ
- d คือ ตัวอย่างที่กำลังใช้ในการสอน

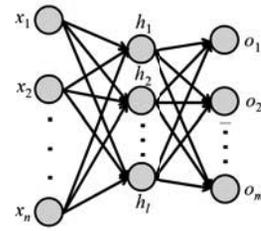


Figure 2 Back-Propagation Neural Network Structures

ขั้นตอนการประมวลผลของโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ สามารถสรุปได้ ดังนี้

1. กำหนดค่าน้ำหนักเริ่มต้น โดยในทางปฏิบัติจะกำหนดเป็นค่าจำนวนต่ำ (ใกล้ 0)
2. นำข้อมูลตัวอย่างที่ต้องการสอนเข้าชั้นนำเข้า (input layer) (X_i)
3. คำนวณค่าคำตอบในทุกโหนดที่ชั้นซ่อน (hidden layer) พร้อมการกระตุ้นค่าคำตอบ (h_j)
4. คำนวณค่าคำตอบในทุกโหนดที่ชั้นคำตอบ (output layer) พร้อมการกระตุ้นค่าคำตอบ (O_k)
5. คำนวณค่าคลาดเคลื่อนสำหรับทุกโหนดในชั้นคำตอบ
6. ปรับค่าน้ำหนักระหว่างชั้นซ่อนกับชั้นคำตอบ
7. ปรับค่าน้ำหนักระหว่างชั้นนำเข้ากับชั้นซ่อน
8. คำนวณค่าความคลาดเคลื่อนรวม แล้ววนกลับไปทำงานขั้นตอนที่ 2. ถ้าความคลาดเคลื่อนยังไม่เป็นไปตามที่กำหนด หรือ ยังไม่ครบจำนวนรอบตามกำหนดไว้

โครงข่ายประสาทเทียมแบบฟังก์ชันรัศมีฐาน (Radial Basis Function: RBF) เป็นโครงข่ายประสาทเทียมที่นำเอาแนวคิดการทำนายค่าภายในรัศมีของวงกลมหรือวงรี ซึ่งจะช่วยลดจำนวนของเส้นแบ่ง (Hyperplane) ลงได้ดังแสดงใน (Figure 3)

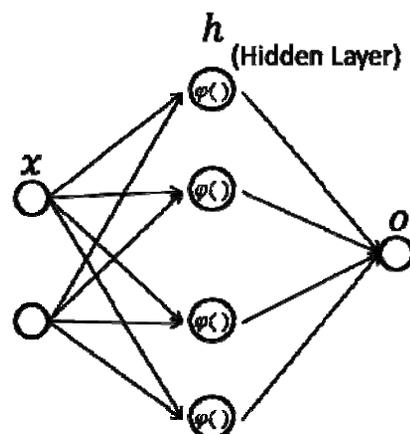


Figure 3 Radial Basis Functions Network Structures

โดย RBF มีขั้นตอนคำนวณที่สำคัญดังนี้

1. กำหนดจำนวนจุดศูนย์กลาง ค่ารัศมีของแต่ละวงกลมพร้อมฟังก์ชันการคำนวณของแต่ละวงกลม $\varphi()$
2. นำข้อมูลตัวอย่างที่ต้องการสอนเข้าชั้นนำเข้า (input layer) (x_i) แล้วคำนวณค่าคำตอบใน Hidden Layer โดยฟังก์ชันที่กำหนดไว้ $\varphi()$ ในขั้นตอนที่ 1
3. คำนวณค่าคำตอบในทุกโหนดที่ชั้นคำตอบ (output layer) พร้อมการกระตุ้นค่าคำตอบ (O_k)
4. คำนวณค่าคลาดเคลื่อนสำหรับทุกโหนดในชั้นคำตอบ
5. ปรับค่าน้ำหนักระหว่างชั้นซ่อนกับชั้นคำตอบ
6. ปรับตำแหน่งจุดศูนย์กลางของแต่ละวงกลม
7. คำนวณค่าความคลาดเคลื่อนรวม แล้ววนกลับไปทำงานขั้นตอนที่ 2. ถ้าความคลาดเคลื่อนยังไม่เป็นไปตามที่กำหนด หรือ ยังไม่ครบจำนวนรอบตามกำหนดไว้

ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine: SVM) จุดมุ่งหมายที่สำคัญของแนวคิด SVM คือ การหาเส้นแบ่ง Hyperplane ซึ่งใช้แบ่งข้อมูลออกเป็นคลาส เพื่อให้ได้ผลลัพธ์ที่ดี โดยพิจารณาจากสมการเส้นตรง Hyper planes และ SVM จะทำการค้นหาจุดของข้อมูลที่อยู่ใกล้เส้นแบ่ง Hyper planes ซึ่งจุดนี้เรียกว่า "Support Vector" มีหลักการดังนี้

1. นำข้อมูลคำนวณหาค่า y ซึ่งค่า จากสมการ $y = w^T x + b$
2. คำนวณหาเส้นแบ่ง ซึ่งเรียกว่าเส้น Optimal Hyperplane จากสมการ $w^T x + b = 0$
3. ระยะทาง (d) หรือ maximum margin จากเส้นขอบ ณ จุดไปยัง hyperplane แสดงดังสมการ

$$d = \frac{|w^T x_i + b|}{\|w\|}$$

w คือ เวกเตอร์น้ำหนัก (Weight Vector)

x_i คือ Input

b คือ ค่าคงที่ที่กำหนดขึ้นเพื่อให้เหมาะสมกับการจัดกลุ่ม

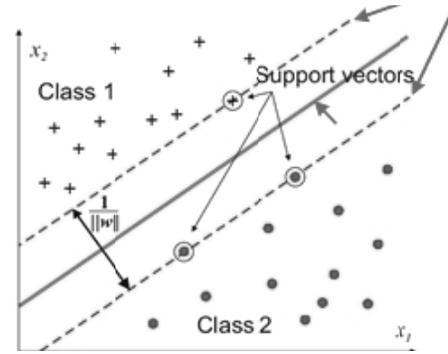


Figure 4 Support Vector Separation Hyperplane

4. เลือกจุดที่อยู่ใกล้เส้นตรง Optimal Hyperplane ทั้งเหนือเส้นซึ่งเรียกว่า "ขอบล่าง" ซึ่งเป็นขอบล่างสุดของคลาส ที่อยู่เหนือเส้นตรง Optimal Hyperplane และได้เส้นเรียกว่า "ขอบบน" ซึ่งเป็นขอบบนสุดของคลาสที่อยู่ใต้เส้นตรง Optimal Hyperplane เพื่อที่จะหาระยะทางระหว่างเส้นขอบทั้งสองโดยจะเลือกเอาค่าระยะทางที่ห่างจากเส้นตรง Optimal Hyperplane ที่น้อยที่สุดเป็นตัวเลือกในการจัดกลุ่มข้อมูล

โครงข่ายประสาทเทียมสำหรับการทำนายปริมาณน้ำที่สูญเสียในสารละลายซูโครสร่วมกับกลีเซอรอล

การทำนายปริมาณน้ำที่สูญเสียในสารละลายซูโครสร่วมกับกลีเซอรอลสำหรับงานวิจัยนี้ จะเปรียบเทียบจาก 3 วิธีคือ BPNN, SVM และ RBF โดยแต่ละวิธีจะมีโครงสร้างและพารามิเตอร์ที่ได้จากการทดลองแล้วว่า ได้ผลลัพธ์ที่ดีที่สุดโดยพิจารณาจากค่า MAE ที่ได้ต่ำที่สุดจากค่าพารามิเตอร์ต่าง ๆ สำหรับข้อมูลชุดนี้ ดังนี้

BPNN

- hiddenLayers: 4
- learningRate: 0.3
- momentum: 0.1
- trainingTime: 5000

RBF

- minStdDev: 0.1
- numClusters: 10

SVM

- C: 1
- Kernel: PolyKernel
- regOptimizer: RegSMOImproved

โครงข่ายประสาทเทียมสำหรับการทำนายปริมาณของแข็งที่เพิ่มขึ้นในสารละลายซูโครส ร่วมกับกลีเซอรอล การทำนายปริมาณของแข็งที่เพิ่มขึ้นในสารละลายซูโครส ร่วมกับกลีเซอรอลสำหรับงานวิจัยนี้ จะเปรียบเทียบจาก 3 วิธี คือ BPNN, SVM และ RBF โดยแต่ละวิธีจะมีโครงสร้างและพารามิเตอร์ที่ได้จากการทดลองแล้วว่าได้ผลลัพธ์ที่ดีที่สุดโดยพิจารณาจากค่า MAE ที่ได้ต่ำที่สุดจากค่าพารามิเตอร์ต่าง ๆ สำหรับข้อมูลชุดนี้ ดังนี้

BPNN

hiddenLayers: 4
learningRate: 0.3
momentum: 0.1
trainingTime: 5000

RBF

minStdDev: 0.1
numClusters: 9

SVM

C: 1
Kernel: NormalizedPolyKernel
regOptimizer: RegSMO

ชุดข้อมูลสำหรับการทดสอบการสร้างตัวแบบจำลองพยากรณ์

จากข้อมูลที่รวบรวมได้จากการทดลองทั้งหมด นำมาผ่านขั้นตอนการสกัดปัจจัยในแต่ละกระบวนการก็จะได้ข้อมูลนำเข้าโครงข่ายประสาทเทียม โดยในการทำงานของโครงข่ายประสาทเทียมนั้นได้ทำการสุ่มข้อมูลที่ได้จากปัจจัยตัวใหม่ ออกเป็น 4 กลุ่มเพื่อใช้ในการฝึกสอนและการทดสอบดัง (Table 1)

Table 1 Training and testing sets

Data set	Group 1	Group 2	Group 3	Group 4
Training set	60%	70%	80%	90%
Testing set	40%	30%	20%	10%

เนื่องจากว่าในงานวิจัยนี้ได้นำเอาโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (BPNN), แบบฟังก์ชันรัศมีฐาน (RBF) และ ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machines: SVM) มาใช้เพื่อทำนายค่าปริมาณน้ำที่สูญเสียและปริมาณของแข็งที่เพิ่มขึ้นเพื่อเปรียบเทียบประสิทธิภาพของ

โครงข่ายทั้งสามแบบโดยใช้ข้อมูลชุดเดียวกัน โดยข้อมูลที่ใช้ในการสร้างตัวแบบเพื่อการพยากรณ์ เพื่อหาโมเดลที่เหมาะสมจะถูกแบ่งออกเป็น 2 ชุดข้อมูลดังนี้

1. ชุดข้อมูลสารละลายซูโครส ร่วมกับกลีเซอรอล สำหรับการทำนายปริมาณน้ำที่สูญเสีย
2. ชุดข้อมูลสารละลายซูโครส ร่วมกับกลีเซอรอล สำหรับการทำนายปริมาณของแข็งที่เพิ่มขึ้น

การประมาณค่าความถูกต้องของการทำนาย

การประเมินค่าความถูกต้องของวิธีการทำนายทั้ง 3 โครงข่าย จะใช้การเปรียบเทียบหาวิธีที่เหมาะสมได้แก่ BPNN, RBF และ SVM เทียบกับค่าข้อมูลจริงจากการทดลอง โดยจะใช้ Weka tools (<http://www.cs.waikato.ac.nz/ml/weka/>) เป็นเครื่องมือในการทดลองซึ่งในแต่ละวิธีที่นำมาเปรียบเทียบกันนี้จะถูกปรับโครงสร้างและพารามิเตอร์ให้มีความเหมาะสมกับชุดข้อมูลนั้นๆ

เกณฑ์ที่ใช้ในการวัดประสิทธิภาพ ได้แก่ MAE, RMSE, RAE และ RRSE ดังนี้

เมื่อ P คือ ค่าที่ทำนายได้

A คือ ค่าจริง

A_m คือ ค่าเฉลี่ยของค่าจริงทั้งหมด

1. Mean absolute error

$$MAE = \frac{1}{n} \sum_{i=1}^n |P_i - A_i|$$

2. Root mean squared error

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (P_i - A_i)^2}$$

3. Relative absolute error

$$RAE = \frac{\sum_{i=1}^n |P_i - A_i|}{\sum_{i=1}^n |A_i - A_m|}$$

4. Root relative squared error

$$RRSE = \sqrt{\frac{\sum_{i=1}^n (P_{ij} - A_i)^2}{\sum_{i=1}^n (A_i - A_m)^2}}$$

ผลการทดลองและวิจารณ์ผลการทดลอง

จากที่กล่าวมาข้างต้นงานวิจัยนี้ จะศึกษาขั้นตอนวิธีสำหรับการสร้างตัวแบบที่เหมาะสมสำหรับการทำนายปริมาณน้ำที่สูญเสียในสารละลายซูโครส ร่วมกับกลีเซอรอล และตัวแบบที่เหมาะสมสำหรับการทำนายปริมาณของแข็งที่เพิ่มขึ้นในสารละลายซูโครส ร่วมกับกลีเซอรอลตามลำดับ โดยขั้นตอนวิธีที่เลือกใช้ในการทำนายตัวแบบในงานวิจัยนี้เป็นโครง

ข่ายประสาทเทียมแบบมีผู้สอน (Supervised learning neural network) ประกอบด้วย BPNN, RBF และ SVM ทั้งสามตัวแบบที่เลือกมานี้เป็นตัวแบบมาตรฐานเป็นที่ยอมรับทั่วไปในการสร้างตัวแบบเพื่อการพยากรณ์ จากนั้นจะนำตัวแบบทั้งสามประเภทไปทำการทำนายข้อมูลจริง คือ ปริมาณน้ำที่สูญเสียและปริมาณของแข็งที่เพิ่มขึ้นที่ได้จากการทดลองในห้องปฏิบัติการที่มีการควบคุมปัจจัยภายนอกอย่างถูกต้องและเหมาะสม โดย (Table 2) และ (Table 3) จะเป็นผลของการทำนายปริมาณน้ำที่สูญเสียในสารละลายซูโครสร่วมกับกลีเซอรอล และผลการเปรียบเทียบเกณฑ์วัดประสิทธิภาพ ตามลำดับส่วนใน (Table 4) และ (Table 5) จะเป็นผลของการทำนายปริมาณของแข็งที่เพิ่มขึ้นในสารละลายซูโครสร่วมกับกลีเซอรอล และผลการเปรียบเทียบเกณฑ์วัดประสิทธิภาพ

โครงข่ายประสาทเทียมสำหรับการทำนายปริมาณน้ำที่สูญเสียในสารละลายซูโครสร่วมกับกลีเซอรอล

จากผลการทดลองดัง (Table 2) แสดงให้เห็นว่าค่าปริมาณน้ำที่สูญเสียของชุดข้อมูลสารละลายซูโครสร่วมกับกลีเซอรอลนั้น โดยมีข้อมูลที่ใช้ในการทดลอง 12 ค่า พบว่าโครงข่ายประสาทเทียมที่เหมาะสมในการสร้างตัวแบบ คือ โครงข่ายประสาทเทียมแบบ BPNN โดยในขั้นตอนพิจารณาเฉพาะค่าซึ่ง BPNN ให้ค่า (แสดงใน (Table 3)) และเมื่อพิจารณากราฟการทำนายปริมาณน้ำที่สูญเสียใน (Figure 5(ก) - (ง)) แสดงให้เห็นค่าการทำนายด้วย BPNN จะอยู่ในระนาบเดียวกันกับค่าจริง (Actual values) และเมื่อพิจารณาเฉพาะค่าความแตกต่างของการทำนาย ใน (Figure 2 (ง)) พบว่า มีค่าความแปรปรวนต่ำที่สุด ซึ่งค่าคลาดเคลื่อนหรือความแตกต่างเฉลี่ยรวมในทุกตัววัดประสิทธิภาพความถูกต้องตามที่กล่าวไว้ในข้อ 2.6 ได้แสดงไว้ใน (Table 3) ซึ่งโครงข่ายประสาทเทียมแบบ BPNN ให้ค่าความแตกต่างเฉลี่ยต่ำที่สุดในทุกตัววัดประสิทธิภาพ

Table 2 Water loss prediction of Sucrose and Glycerol solution experiments

No.	Vacuum time	Soaking time	Actual Value	Prediction Values			Difference		
				BPNN	RBF	SVM	BPNN	RBF	SVM
1	0	20	24.96	24.95	27.00	32.61	0.01	-2.04	-7.65
2	0	40	30.82	31.31	28.44	33.93	-0.49	2.38	-3.11
3	0	60	34.88	34.99	34.74	35.24	-0.11	0.14	-0.36
4	0	120	39.40	39.41	39.71	39.19	-0.01	-0.31	0.21
5	0	180	45.11	44.88	44.90	43.13	0.23	0.21	1.98
6	0	240	46.01	45.77	46.07	47.08	0.24	-0.06	-1.07
7	15	20	29.89	29.75	29.77	33.13	0.14	0.12	-3.24
8	15	40	35.03	34.74	35.78	34.44	0.29	-0.75	0.59
9	15	60	37.43	36.86	37.12	35.75	0.57	0.31	1.68
10	15	120	40.18	40.20	40.18	39.70	-0.02	0.00	0.48
11	15	180	44.75	45.00	44.76	43.64	-0.25	-0.01	1.11
12	15	240	46.48	45.58	46.48	47.59	0.90	0.00	-1.11

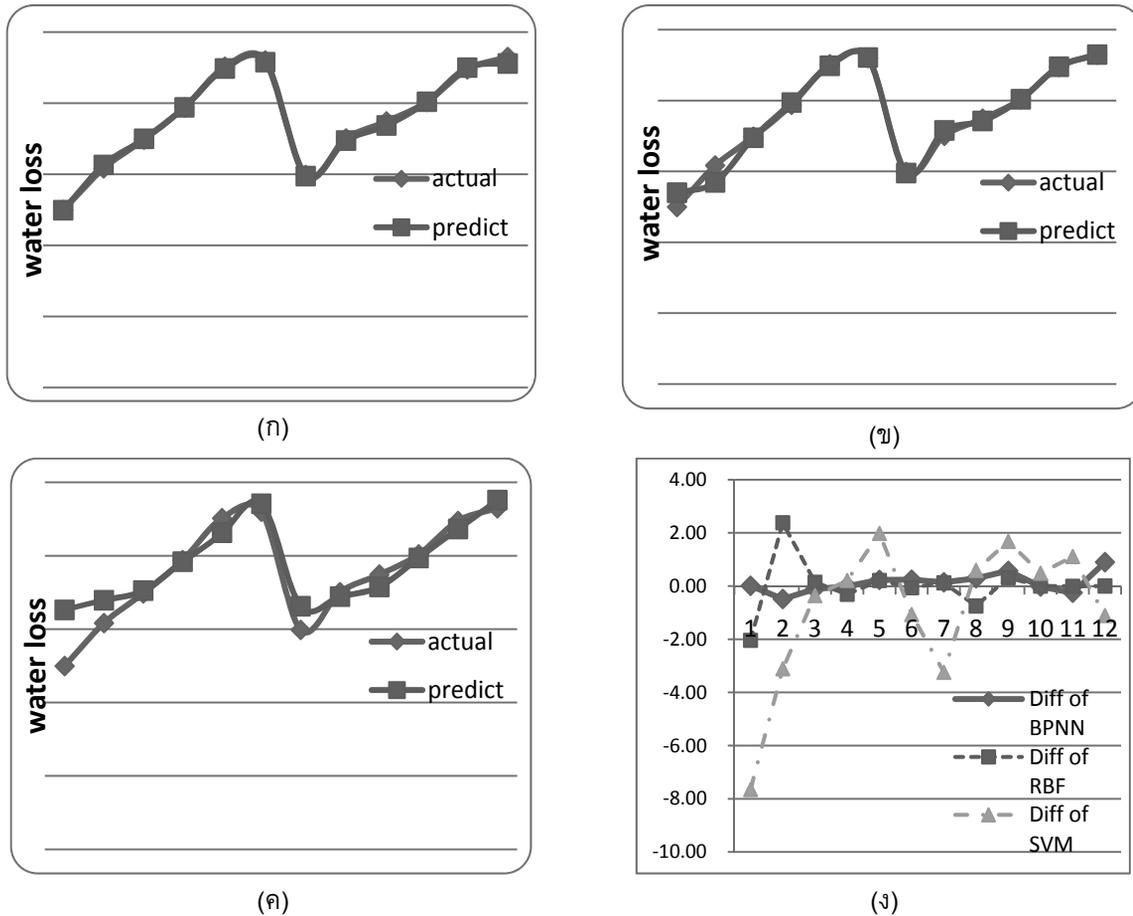


Figure 5 Comparing water loss prediction of Sucrose and Glycerol (a) Back-Propagation Neural Network Structures (b) Radial Basis Functions Network Structures (c) Support Vector Machine (d) errors from 3 predictors

Table 3 Performance index of Water loss prediction

	BPNN	RBF	SVM
MAE	0.27	0.53	1.88
RMSE	0.37	0.94	2.74
RAE (%)	4.73	9.19	32.76
RRSE (%)	5.52	13.97	40.59

จากผลการทดลองใน (Table 3) เมื่อพิจารณาค่า MAE, RMSE, RAE และ RRSE พบว่า การเรียนรู้แบบ BPNN ให้ผลต่ำในทุกๆ ค่า แสดงให้เห็นว่าสำหรับการทดลองของซูโครสร่วมกับกลีเซอรอล เพื่อทำนายปริมาณน้ำที่สูญเสียด้วยการเรียนรู้ BPNN ได้ผลที่ใกล้กับค่าจริงมากที่สุด เมื่อเปรียบเทียบกับ RBF และ SVM โดยเมื่อพิจารณาควบคู่กับ (Figure 5 (ง))

ให้ผลสอดคล้องกัน คือ ผลต่างของความแตกต่าง (error) ระหว่างค่าจริงกับค่าที่ได้จากการประมาณจากวิธี BPNN มีความแปรปรวนของเส้นกราฟน้อยที่สุดเมื่อเทียบกับอีก 2 วิธี

โครงข่ายประสาทเทียมสำหรับการทำนายปริมาณของแข็งที่เพิ่มขึ้นในสารละลายซูโครสร่วมกับกลีเซอรอล

จากผลการทดลองดัง (Table 4) แสดงให้เห็นว่าค่าปริมาณของแข็งที่เพิ่มขึ้นของชุดข้อมูลซูโครสร่วมกับกลีเซอรอลนั้น โครงข่ายประสาทเทียมที่เหมาะสม คือ โครงข่ายประสาทเทียมแบบ RBF ซึ่งจากกราฟแสดงใน (Figure 6 (ง)) แสดงให้เห็นค่าความแตกต่างของการทำนายมีค่าอยู่ในระนาบเดียวกันกับค่าจริง (Actual values) ซึ่งค่าคลาดเคลื่อนหรือความแตกต่างเฉลี่ยร่วมในทุกตัววัดประสิทธิภาพความถูกต้องตามที่กล่าวไว้ในข้อ 2.6 ได้แสดงไว้ใน (Table 5) ซึ่งโครงข่ายประสาทเทียมแบบ RBF ให้ค่าความแตกต่างเฉลี่ยต่ำที่สุด

Table 4 Solid gain prediction of Sucrose and Glycerol solution experiments

No.	Vacuum time	Soaking time	Actual Value	Prediction Values			Difference		
				BPNN	RBF	SVM	BPNN	RBF	SVM
1	0	20	7.75	7.81	7.60	7.87	-0.06	0.15	-0.12
2	0	40	8.23	8.50	8.47	10.35	-0.27	-0.24	-2.12
3	0	60	9.15	9.08	9.07	10.35	0.07	0.08	-1.20
4	0	120	10.29	10.36	10.33	10.35	-0.07	-0.04	-0.06
5	0	180	12.46	11.36	12.42	10.35	1.10	0.04	2.11
6	0	240	12.66	12.72	12.68	10.35	-0.06	-0.02	2.31
7	15	20	11.81	12.55	11.84	12.06	-0.74	-0.03	-0.25
8	15	40	15.58	14.32	15.31	14.42	1.26	0.27	1.16
9	15	60	15.93	16.15	16.18	16.64	-0.22	-0.25	-0.71
10	15	120	21.31	21.22	21.28	21.67	0.09	0.03	-0.36
11	15	180	24.94	24.13	24.96	23.98	0.81	-0.02	0.96
12	15	240	24.76	24.49	24.75	24.35	0.27	0.01	0.41

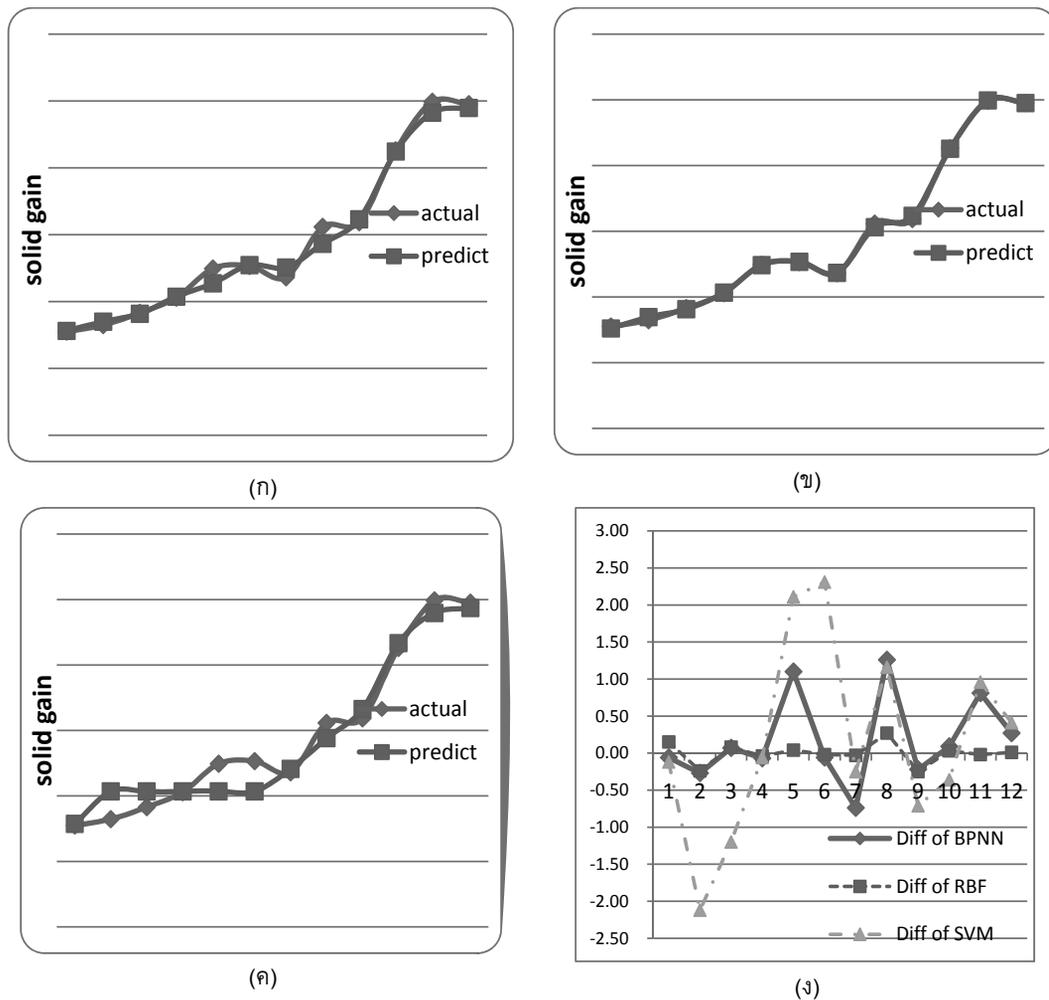


Figure 6 Comparing solid gain prediction of Sucrose and Glycerol (a) Back-Propagation Neural Network Structures

(b) Radial Basis Functions Network Structures (c) Support Vector Machine (d) errors from 3 predictors

Table 5 Performance index of Solid gain prediction

	BPNN	RBF	SVM
MAE	0.42	0.10	0.98
RMSE	0.59	0.14	1.25
RAE (%)	8.46	1.95	19.86
RRSE (%)	10.14	2.33	21.46

จากผลการทดลองใน (Table 5) เมื่อพิจารณาค่า MAE, RMSE, RAE และ RRSE พบว่า การเรียนรู้แบบ RBF ให้ผลต่ำในทุกๆ ค่า แสดงให้เห็นว่าสำหรับการทดลองของซูโครส ร่วมกับกลีเซอรอล เพื่อทำนายปริมาณของแข็งที่เพิ่มขึ้นด้วยการเรียนรู้ RBF ได้ผลที่ใกล้เคียงกับค่าจริงมากที่สุด เมื่อเปรียบเทียบกับ BPNN และ SVM โดยเมื่อพิจารณาควบคู่กับ (Figure 6 (ง)) ให้ผลสอดคล้องกัน คือ ผลต่างของความแตกต่าง (error) ระหว่างค่าจริงกับค่าที่ได้จากการประมาณจากวิธี BPNN มีความแปรปรวนของเส้นกราฟน้อยที่สุดเมื่อเทียบกับอีก 2 วิธี

สรุปผลการทดลอง

งานวิจัยนี้ นำเสนอการใช้โครงข่ายประสาทเทียมในการพยากรณ์การถ่ายโอนมวลในกระบวนการออสโมซิสในสับปะรดจากผลการทดลองพบว่า โครงข่ายประสาทเทียมแบบ BPNN เป็นโครงข่ายประสาทเทียมที่เหมาะสมกับการทำนายข้อมูลปริมาณน้ำที่สูญเสียโดยมีค่าคาดเคลื่อน MAE เท่ากับ 0.27 และโครงข่ายประสาทเทียมแบบ RBF เป็นโครงข่ายประสาทเทียมที่เหมาะสมกับการทำนายข้อมูลปริมาณของแข็งที่เพิ่มขึ้นโดยมีค่าคาดเคลื่อน MAE เท่ากับ 0.10 ทั้งนี้เนื่องจาก ตัวแบบในการประมาณค่าฟังก์ชัน (Function Approximation) แต่ละตัวนั้น จะมีความสอดคล้องและเหมาะสมกับลักษณะของข้อมูลที่ใช้ในการทำนาย (Pattern of Functions) จากงานวิจัยนี้ เราจะสามารถนำโครงข่ายประสาทเทียมไปใช้ในการทำนายลักษณะข้อมูลอื่น ๆ ได้ในอนาคต

กิตติกรรมประกาศ

งานวิจัยนี้ได้รับการสนับสนุนการวิจัยจากงบประมาณเงินรายได้จากเงินอุดหนุนรัฐบาล (งบประมาณแผ่นดิน) ประจำปีงบประมาณ พ.ศ. 2556 มหาวิทยาลัยบูรพา ผ่านสำนักงานคณะกรรมการการวิจัยแห่งชาติ

เอกสารอ้างอิง

1. รัชพันธ์ ฤทธิมณี, กัมปนาท บำรุงกิจ, ธนะชัย พันธุ์เกษมสุข, พิชญา บุญประสม. การพยากรณ์คุณภาพของส้มสายน้ำผึ้งหลังการขนส่งทางรถบรรทุกโดยใช้โครงข่ายประสาทเทียม. วิทยาศาสตร์เกษตร 2549; 37(5): 38-41.
2. Torreggiani D, Bertolo G. Osmotic pretreatments in fruit processing: chemical, physical and structural effects. Journal of Food Engineering 2001; 49: 247-253.
3. Boonprasom P, Bumroonggit G. Tangerine yield prediction using artificial neural network (ANN). CMU Journal 2005;4(1):39-48.
4. Chinnasarn K, Chinnasarn S, Pyle DL. Identification of surimi gel strength classes using backpropagation neural network and principal component analysis. Journal of Applied Sciences 2006;6(8): 1802-1807.
5. EIShazly YMS. The use of neural network to estimate mass transfer coefficient from the bottom of agitated vessel. Heat and Mass Transfer 2015; 51(4): 465-475.
6. Haykin S. Neural Networks and Learning Machines. Pearson Prentice Hall, New York, USA; 2008.
7. Wongkrajang K. Training Course on Drying and Juicing. Kasetsart University, Bangkok, Thailand; 1996.