

แบบจำลองโครงข่ายประสาทเทียมที่เหมาะสม
ในการทำนายร้อยละข้าวหักจากเครื่องสีข้าวขนาดเล็ก

Optimization of Neural Network in the Prediction of the Percentage of Broken Rice in a
Small Rice Mill

จักรพงษ์ คำสีเขียว และ สุขอังคณา ลี*

ภาควิชาวิศวกรรมอุตสาหการ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยอุบลราชธานี อ.วารินชำราบ จ.อุบลราชธานี 34190

* E-mail: Ensuk-ch@ubu.ac.th

บทคัดย่อ

บทความนี้ได้นำเสนอวิธีการหาโครงสร้างของโครงข่ายประสาทเทียม ที่เหมาะสมเพื่อใช้ในการทำนายค่าร้อยละข้าวหักที่ได้จากการสีข้าวด้วยเครื่องสีข้าวขนาดเล็กแบบลูกหินแกนนอนลูกเดียว โดยแบบจำลองโครงข่ายประสาทเทียมที่ใช้ในการวิจัยนี้เป็นแบบที่มีโครงสร้างหลายชั้น ใช้การเรียนรู้ของโครงข่ายชนิดมีการสอน แบบป้อนไปข้างหน้า ด้วยเทคนิควิธีการแพร่ย้อนกลับ โดยทดลองหาจำนวนหน่วยย่อยในชั้นซ่อนที่แตกต่างกันตั้งแต่ 5, 10, และ 15 หน่วยย่อย ตัวแปรที่นำมาใช้ในการพิจารณาเป็นตัวแปรที่มีผลต่อการแตกหักของข้าวสารที่เกิดจากกระบวนการสีข้าว ในการทดลองใช้ข้าวหอมมะลิ 105 ความชื้นร้อยละ 14 งานวิจัยนี้ได้แบ่งเงื่อนไขที่ใช้ในการสีข้าวออกเป็น 3 กรณี คือ กรณีที่ 1 เปิดช่องปล่อยข้าวเปลือกที่ 900 ตร.มม. กรณีที่ 2 เปิดช่องปล่อยข้าวเปลือกที่ 1,125 ตร.มม. และกรณีที่ 3 เปิดช่องปล่อยข้าวเปลือกที่ 1,350 ตร.มม. โดยมีตัวแปรที่ใช้ในการทดลอง คือ ระยะห่างระหว่างลูกหินขัดข้าวกับแท่งยางขัดข้าว ความเร็วรอบของลูกหินขัดข้าว และระยะเวลาในการสีข้าว

ผลการวิจัยพบว่า โครงสร้างของโครงข่ายประสาทเทียมที่เหมาะสมในการทำนายค่าร้อยละข้าวหักที่ได้จากการสีข้าวด้วยเครื่องสีข้าวขนาดเล็ก ในกรณีที่เปิดช่องปล่อยข้าวเปลือกที่ 900 ตร.มม. คือ แบบ 4 – 10 -1, กรณีที่เปิดช่องปล่อยข้าวเปลือกที่ 1,125 ตร.มม คือ แบบ 4 – 15 – 1, และกรณีที่เปิดช่องปล่อยข้าวเปลือกที่ 1,350 ตร.มม คือ แบบ 4 – 15 – 1 ผลการทำนายพบว่าทั้ง 3 กรณี มีความแม่นยำใกล้เคียงกัน โดยผลการทำนายในกรณีที่ 1 ถึง 3 ให้ค่า Regression เท่ากับ 0.99283 0.99702 0.98417 ตามลำดับ และมีผลของค่าความคลาดเคลื่อน Mean square error (MSE) เท่ากับ 0.795 0.187 0.643 ตามลำดับ

คำสำคัญ เครื่องสีข้าวขนาดเล็ก ลูกหินขัดแกนนอน โครงข่ายประสาทเทียม วิธีแพร่ย้อนกลับ

Abstract

This research aimed to predict the percentage of broken rice in a small rice mill by the artificial neural network model (ANNM). Feed-forward back propagation was used to predict the percentage of broken rice after milling. The study tested 5, 10, and 15 nodes. Milling experiments used jasmine rice 105 with a maximum moisture content of 14 percent. This research was based on experimental conditions involving three different areas of inlet to release the paddy into the milling chamber, 900 mm², 1125 mm², and 1350 mm². Three variables were introduced, the level of clearance between the rice-polishing cylinder and rubber, the velocity of rice-polishing cylinder, and the duration of the rice milling. Results indicated that the artificial neural network model was appropriate in the prediction of the percentage of broken rice in the small rice mill. The optimum artificial neural network architecture for the 900, 1125, and 1350 mm² inlets were 4 – 10 – 1, 4 – 15 -1, and 4 – 15 – 1 respectively. The prediction showed that all three conditions were similar. The predicted results in conditions 1, 2, and 3 had regression values of 0.99283, 0.99702 and 0.98417 respectively and the values of the error mean square error (MSE) were 0.795, 0.187, and 0.643 respectively.

Keywords: Small rice milling; Single horizontal abrasive; Artificial neural network; Back propagation

1. บทนำ

ปัจจุบันได้มีการพัฒนาระบบคอมพิวเตอร์ให้มีความสามารถในการทำงานใกล้เคียงกับการทำงานของสมองของมนุษย์ โดยมีการศึกษาและเลียนแบบลักษณะการทำงานของเซลล์สมองของมนุษย์ ซึ่งมีความสามารถในการเรียนรู้จากประสบการณ์และกฎเกณฑ์ทั่วไป เทคโนโลยีที่ได้รับการศึกษาและพัฒนาจากหลักการดังกล่าว เรียกว่า โครงข่ายประสาทเทียม (Artificial Neural Network: ANN) ซึ่งเป็นศาสตร์หนึ่งของทฤษฎีปัญญาประดิษฐ์ (Artificial Intelligence: AI) [1] เทคโนโลยีด้านปัญญาประดิษฐ์ ดังเช่นโครงข่ายประสาทเทียมเป็นเทคนิคที่มีความยืดหยุ่นตัวในการแก้ปัญหาได้สูง มีความสะดวกในการใช้งานกับการทำนายสถานะที่มีค่าปัจจัยหรือตัวแปรจำนวนมากได้ดี ซึ่งถือว่ามีประสิทธิภาพสูงในการทำนายความสัมพันธ์ของปัญหา เมื่อเปรียบเทียบกับเทคนิคทางด้านคณิตศาสตร์และสถิติ ซึ่งเป็นเทคนิคที่ใช้ในการทำนายปัญหาแบบดั้งเดิม โครงข่ายประสาทเทียมจึงได้รับความสนใจจากนักวิจัยและนักวิทยาศาสตร์ในหลายสาขาเมื่อไม่นานมานี้ โดยเฉพาะภาคอุตสาหกรรมและการผลิตที่ได้มีการพัฒนาโครงข่ายประสาทเทียมเพิ่มขึ้นอย่างต่อเนื่อง เพื่อเพิ่มขอบเขตที่หลากหลายกับการนำไปประยุกต์ใช้ในอุตสาหกรรมด้านต่างๆ รวมไปถึงกระบวนการผลิต, การทำนาย หรือการพยากรณ์, การวิเคราะห์ความผิดพลาดของกระบวนการ, และการประมาณค่าตัวแปรเพื่อใช้ในกระบวนการควบคุมกระบวนการผลิต [2], [3], [4] และที่สำคัญโครงข่ายประสาทเทียมยังสามารถนำไปประยุกต์ใช้กับงานอื่นๆอีกมากมาย [5], [6], [7], [8], [9], [10], [11], [12]

โครงข่ายประสาทเทียมมีการเรียนรู้ได้ด้วยการรับข้อมูลตัวอย่างเข้ามาจำนวนหนึ่งแล้วค่อยๆ ทำการปรับค่าน้ำหนักจนกว่าจะได้ผลลัพธ์ที่ใกล้เคียงกับค่าผลลัพธ์ที่ต้องการความสามารถของโครงข่ายประสาทเทียมสามารถเรียนรู้ได้จากตัวอย่างข้อมูลที่มีอยู่เป็นจำนวนมากได้เป็นอย่างดีและมีความเที่ยงตรงสูงถึงแม้จะมีกระบวนการหรือมีรูปแบบในการปฏิบัติงานที่ซับซ้อนและมีความยุ่งยากในการประมวลผลก็ตาม ซึ่งสามารถที่จะตอบปัญหาที่ยุ่งยากและค้นหาความสัมพันธ์ระหว่างข้อมูล หรือสร้างแบบจำลองทางคณิตศาสตร์ที่ซับซ้อนได้ดี จึงมีความเหมาะสมที่จะนำมาใช้งานในการทำนายหรือการพยากรณ์ (Prediction) [13]

ปัจจุบันเทคนิคการพยากรณ์ได้ถูกนำมาใช้เป็นเครื่องมือในการพยากรณ์ในด้านต่างๆ และมีโปรแกรมคอมพิวเตอร์ช่วยในการวิเคราะห์ข้อมูลอยู่หลายโปรแกรม เทคนิคการพยากรณ์แบ่งออกเป็น 2 กลุ่มด้วยกัน คือ เทคนิคการพยากรณ์แบบดั้งเดิม (Tradition Statistical Method) และเทคนิคการพยากรณ์แบบสมัยใหม่ (Modern Statistical Method) เทคนิคการพยากรณ์แบบดั้งเดิม ได้แก่ วิธีการวิเคราะห์การถดถอยแบบพหุ (Multiple Regression Analysis) วิธีการปรับให้เรียบแบบเอ็กซ์โปเนนเชียล (Exponential Smoothing Method) เป็นต้น ส่วนเทคนิคการพยากรณ์แบบสมัยใหม่ได้แก่ วิธีโครงข่ายประสาทเทียม (Artificial Neural Networks) วิธีระบบผู้เชี่ยวชาญ (Expert System) และวิธีการแก้ปัญหาเชิงพันธุกรรม (Genetic Algorithm) [14] สำหรับเทคนิคการพยากรณ์แบบดั้งเดิมนั้นมีอยู่หลายวิธี แต่วิธีที่ให้ความถูกต้องสูงและเป็นที่ยอมรับมาประยุกต์ใช้มากที่สุดได้แก่ วิธีการวิเคราะห์การถดถอยเชิงเส้นตรงแบบพหุ (Multiple Linear Regression Analysis) เนื่องจากสามารถจะวิเคราะห์ความผันแปรของตัวแปรตามที่สามารถอธิบายได้ด้วยค่าความผันแปรของตัวแปรอิสระได้และจะมีประสิทธิภาพสูงมากถ้าหากสามารถหาตัวแปรอิสระที่สามารถอธิบายตัวแปรตามได้ครอบคลุมครบถ้วน

สำหรับวิธีการพยากรณ์แบบสมัยใหม่มีหลายวิธีแต่วิธีที่ได้รับความนิยมมาศึกษามากที่สุดคือ วิธีโครงข่ายประสาทเทียม (Artificial Neural Network) [15] การพยากรณ์โดยวิธีโครงข่ายประสาทเทียมมีความแตกต่างจากวิธีการพยากรณ์แบบดั้งเดิม เนื่องจากวิธีโครงข่ายประสาทเทียมสามารถวิเคราะห์ข้อมูลโดยไม่ขึ้นกับรูปแบบการแจกแจงของข้อมูล และสามารถใช้กับข้อมูลที่ไม่สมบูรณ์ (Imperfect) หรือไม่ครบถ้วน (Incomplete) ในการหาค่าพยากรณ์ได้ และจุดเด่นอีกประการหนึ่งของวิธีโครงข่ายประสาทเทียมคือให้ความถูกต้องในการทำนายที่สูงกว่าวิธีการแบบอื่นเมื่อข้อมูลมีรูปแบบไม่เป็นเชิงเส้น [16]

จากความสามารถของโครงข่ายประสาทเทียม ที่มีความเหมาะสมกับกระบวนการผลิตที่ซับซ้อน มีความยืดหยุ่นในการทำงานสูงและให้ความแม่นยำในการทำนายผลต่างๆ [17] ซึ่งจากการทบทวนวรรณกรรมที่เกี่ยวข้องพบว่ายังไม่มีมีการนำทฤษฎีโครงข่ายประสาทเทียมมาประยุกต์ใช้ในการทำนายค่าร้อยละข้าวหักที่ได้จากการสีข้าวและโดยเฉพาะกับเครื่องสีข้าวขนาดเล็ก โดยจากการศึกษาทำให้สามารถทราบได้ว่าการใช้

โครงข่ายประสาทเทียมเพื่อการทำนายความสัมพันธ์ของข้อมูลจะให้ความแม่นยำมากกว่าวิธีการทางคณิตศาสตร์หรือสถิติ ดังเช่น Olagide และคณะ [18] ได้ใช้โครงข่ายประสาทเทียม ในการทำนายผลผลิตที่ได้จากการสกัดน้ำมันถั่วลิสงจากเครื่องสกัดแบบไฮโดรลิก เทียบกับวิธีทางสถิติ โดยการใช้เทคนิค Levenberg – Marquardt Back - Propagation ผลการศึกษาพบว่าโครงข่ายประสาทเทียมให้ผลในการทำนายได้แม่นยำกว่าวิธีการทางสถิติ สอดคล้องกับงานวิจัยของ Shankar และคณะ [19] ได้ใช้โครงข่ายประสาทเทียม เทคนิค Back - Propagation ในการทำนายคุณสมบัติของวัตถุที่ได้ออกจากกระบวนการอัดรีด (Extrusion) เทียบกับวิธี Respond Surface Methodology (RSM) ซึ่งเป็นวิธีการด้านคณิตศาสตร์และสถิติ โดยใช้เครื่องอัดรีด (Extruder) แบบสกรูเดี่ยว (Single Screw) ในการทดลอง ผลการทดลองพบว่าการทำนายโดยวิธีโครงข่ายประสาทเทียม ให้ผลการทำนายที่มีความใกล้เคียงกับข้อมูลการทดสอบจริง มากกว่าวิธีการ Respond surface methodology (RSM) ทำนองเดียวกับ Rahman M.M. et al [20] ที่ได้ใช้โครงข่ายประสาทเทียม โดยใช้เทคนิค Back propagation ในการทำนายผลผลิตของการผลิตปอ ผลการทำนายพบว่าโครงข่ายประสาทเทียมสามารถทำนายผลผลิตได้อย่างแม่นยำ สอดคล้องกับงานวิจัยของ Necla Kara togun et al [21] ได้ทำการศึกษการทำนายค่า Torque และค่า Brake Specific Fuel Consumption ของเครื่องยนต์แก๊สโซลีน (Gasoline Engine) ด้วยการใช้โครงข่ายประสาทเทียม (Neural Network) แบบ Feed Forward Back Propagation โดยกำหนดให้ใช้ Leaning Algorithm แบบ Levanberg – Marquardt (LM) ซึ่งมี Active Function แบบ Logistic Sigmoid (logsig) จากการทดลองพบว่าค่าโครงสร้างของโครงข่ายประสาทเทียมที่เหมาะสมที่สุดสำหรับการทำนายค่า Torque คือ 3 – 13 – 1 โดยผลการทำนายสรุปได้ว่าการใช้โครงข่ายประสาทเทียมสามารถทำนายค่า Torque และค่า Brake Specific Fuel Consumption ของเครื่องยนต์แก๊สโซลีน (Gasoline Engine) ได้อย่างแม่นยำ

จากการสำรวจงานวิจัยที่เกี่ยวข้องสามารถสรุปได้ว่าการใช้โครงข่ายประสาทเทียมในการทำนายผลผลิตต่างๆ สามารถให้ผลการทำนายที่มีความแม่นยำ และจากการศึกษางานวิจัยที่ผ่านมาพบว่ยังไม่มีการนำทฤษฎีโครงข่ายประสาทเทียมมาประยุกต์ใช้ในการทำนายค่าร้อยละข้าวหัก โดยเฉพาะกับเครื่องสีข้าวขนาดเล็กซึ่งถือว่าเป็นเครื่องจักรอีกประเภทหนึ่งที่มีการใช้งานอย่างแพร่หลายในประเทศไทย ซึ่งส่วนมาก

เกษตรกรได้มีการนำเครื่องสีข้าวขนาดเล็กมาใช้ในการแปรรูปข้าวเปลือกกันมากขึ้น เนื่องจากสะดวก รวดเร็ว อีกทั้งผลิตผลที่ถือว่าเป็นผลพลอยได้จากการสีข้าว นั้นจะประกอบไปด้วยปลายข้าว รำ และแกลบ ซึ่งเกษตรกรสามารถนำไปจำหน่ายหรือนำไปใช้ภาคเกษตรกรรมต่างๆ ได้ ช่วยให้สามารถสร้างรายได้ให้กับเกษตรกรได้อีกทางหนึ่ง ในประเทศไทยการแตกหักจากกระบวนการสีข้าวจากเครื่องสีข้าวขนาดเล็กมีสูงถึง ร้อยละ 43 คาดกันว่าหากเทคโนโลยีการสีข้าวได้รับการพัฒนาให้มีประสิทธิภาพมากยิ่งขึ้นแล้ว จะทำให้มีมูลค่าเพิ่มขึ้นอีกหลายพันล้านบาทต่อปี [22]


เครื่องสีข้าวขนาดเล็กมีทั้งแบบลูกหินแกนตั้งและแกนนอน แต่เครื่องสีข้าวแบบลูกหินแกนนอนเป็นที่นิยมใช้งานกันมากในท้องถิ่นเนื่องจากมีราคาถูก สะดวกในการใช้งาน และง่ายต่อการบำรุงรักษา จากการศึกษาเบื้องต้นทำให้ทราบว่าปัจจุบันนี้กระบวนการสีข้าว โดยเฉพาะอย่างยิ่งกับเครื่องสีข้าวขนาดเล็กนั้น พบว่าการทำงานส่วนมากมักจะขาดความเข้มงวดในการควบคุมกระบวนการผลิต ขาดการเก็บข้อมูลหรือบันทึกข้อมูลการทำงานไว้ แต่จะปฏิบัติงานด้วยความชำนาญของพนักงาน กล่าวคือ มีการปรับตั้งค่าต่างๆ ในกระบวนการสีข้าวด้วยความชำนาญของพนักงานเอง ส่งผลให้ผลผลิตที่ได้มีความแปรผันสูง และผลกระทบที่ตามมาเนื่องจากการปรับค่าที่ไม่เหมาะสมก็อาจส่งผลเสียกับเครื่องสีข้าวโดยเกิดการสึกหรอหรือเสื่อมสภาพของอุปกรณ์ต่างๆ ภายในเครื่องสีข้าวก่อนระยะเวลาอันควร ส่งผลให้เกิดความสิ้นเปลืองในการจัดซื้อวัสดุอุปกรณ์และการบำรุงรักษาตามมา

จากข้อดีของโครงข่ายประสาทเทียม บทความนี้จึงเป็นการนำเสนอวิธีการหาโครงสร้างของโครงข่ายประสาทเทียม (Artificial Neural Network Model) ที่เหมาะสมเพื่อใช้ในการทำนายค่าร้อยละข้าวหักที่ได้จากการสีข้าวด้วยเครื่องสีข้าวขนาดเล็กแบบลูกหินแกนนอนลูกเดี่ยว (Single Horizontal Abrasive) โดยโครงสร้างของแบบจำลองโครงข่ายประสาทเทียมที่ได้จะสามารถนำไปประยุกต์ใช้ในการทำนายร้อยละข้าวหักที่ได้จากเครื่องสีข้าวขนาดเล็ก โดยผลที่ได้จะนำมาเป็นแนวทางในการนำไปใช้ในการประเมินและปรับปรุงพัฒนากระบวนการสีข้าวในอนาคตเพื่อให้เกิดประสิทธิภาพสูงสุดอีกทางหนึ่งด้วย

2.ทฤษฎีที่เกี่ยวข้อง

2.1 หลักการโครงข่ายประสาทเทียม

โครงข่ายประสาทเทียม (Artificial neural network) มักจะเรียกสั้น ๆ ว่า ข่ายงานประสาท (Neural network หรือ Neural net) คือโปรแกรมคอมพิวเตอร์สำหรับประมวลผลสารสนเทศด้วยการคำนวณแบบคอนเนคชันนิสต์ (Connectionist) เพื่อจำลองการทำงานของเครือข่ายประสาทในสมองมนุษย์ [23] ด้วยวัตถุประสงค์ที่จะสร้างเครื่องมือซึ่งมีความสามารถในการเรียนรู้การจดจำรูปแบบ (Pattern Recognition) และการอุปมาความรู้ (Knowledge deduction) เช่นเดียวกับความสามารถที่มีในสมองมนุษย์ แนวคิดเริ่มต้นของเทคนิคนี้ได้มาจากการศึกษาข่ายงานไฟฟ้าชีวภาพ (Bioelectric network) ในสมอง ซึ่งประกอบด้วยเซลล์ประสาท หรือ "นิวรอน" (Neurons) และ จุดประสานประสาท (Synapses) แต่ละเซลล์ประสาทประกอบด้วยปลายในการรับกระแสประสาท เรียกว่า "เดนไดรท์" (Dendrite) ซึ่งเป็น input และปลายในการส่งกระแสประสาทเรียกว่า "แอกซอน" (Axon) ซึ่งเป็นเหมือน output ของเซลล์ เซลล์เหล่านี้ทำงานด้วยปฏิกิริยาไฟฟ้าเคมี เมื่อมีการกระตุ้นด้วยสิ่งเร้าภายนอกหรือกระตุ้นด้วยเซลล์ด้วยกัน กระแสประสาทจะวิ่งผ่านเดนไดรท์เข้าสู่นิวเคลียสซึ่งจะเป็นตัวตัดสินใจว่าต้องกระตุ้นเซลล์อื่น ๆ ต่อหรือไม่ ถ้ากระแสประสาทแรงพอ นิวเคลียสก็จะกระตุ้นเซลล์อื่น ๆ ต่อไปผ่านทางแอกซอนของมัน ตามโมเดลนี้ข่ายงานประสาทเกิดจากการเชื่อมต่อระหว่างเซลล์ประสาท จนเป็นเครือข่ายที่ทำงานร่วมกันดังแสดงในรูปที่ 1 กว่าระยะเวลา 10 ปีที่ผ่านมาโครงข่ายประสาทเทียมโดยเฉพาะแบบหลายชั้นป้อนไปข้างหน้า (Multilayer feed forward neural network) ได้มีการศึกษากันอย่างกว้างขวาง โดยเฉพาะกับอุตสาหกรรมการผลิตด้านต่าง ๆ [24]



รูปที่ 1 แบบจำลองเซลล์ประสาทในสมองมนุษย์ [25]

แบบจำลองโครงข่ายประสาทเทียมสามารถเลียนแบบพฤติกรรมที่มีความซับซ้อนสูงได้เป็นอย่างดี มีความเหมาะสมในการทำนายพฤติกรรมที่มีลักษณะไม่เป็นเชิงเส้น (Non linear) ในงานวิจัยนี้จึงได้นำแบบจำลองโครงข่ายประสาทเทียมมาใช้ในการทำนายค่าร้อยละข้าวหักที่ได้จากการสีข้าวด้วยเครื่องสีข้าวขนาดเล็กแบบลูกหินแนวนอนลูกเดียว

3. วัสดุอุปกรณ์และวิธีดำเนินการวิจัย

3.1 เครื่องสีข้าวขนาดเล็กแบบลูกหินแนวนอนลูกเดียว (Single Horizontal Abrasive)

เครื่องสีข้าวขนาดเล็กแบบลูกหินแนวนอนลูกเดียว (Single Horizontal Abrasive) เป็นเครื่องสีข้าวที่ใช้ในการศึกษาทดลองในงานวิจัยในครั้งนี้ โดยด้านบนของห้องขັดสีมี Hopper ซึ่งเป็นภาชนะสำหรับบรรจุและปล่อยข้าวเปลือกลงสู่กระบวนการขັดสีภายในห้องขັดข้าว เครื่องสีข้าวชนิดนี้จะใช้หลักการ การส่งถ่ายกำลังด้วยมอเตอร์ในการขับเคลื่อนการหมุนของลูกหินกระเทาะ ภายในห้องขັดมีลูกหินขັดข้าวหนึ่งลูก ตัวลูกหินทำมาจากเหล็กหล่อทรงกระบอกโดยมีผิวที่ถูกพอกด้วยหินกากเพชร เพื่อให้มีความคมในการกระเทาะเปลือกและขັดข้าวข้าวเปลือก ในกระบวนการขັดลูกหินจะหมุนขนานกับพื้นระนาบ โดยด้านข้างของลูกหินจะมีลูกยางวางในแนวขนานตลอดความยาวกับลูกหิน ซึ่งระยะห่างระหว่างลูกหินกับแท่งยางสามารถปรับระยะได้ตามต้องการ ด้านล่างของห้องขັดเป็นตะแกรงรูกกลมหรือรูยาวรี เพื่อให้รำหยาบและรำละเอียดแยกตัวออกจากเมล็ดข้าวโดยการไหลลงสู่ด้านล่าง ซึ่งเครื่องสีข้าวแบบนี้มีพัดลมดูดอากาศเพื่อใช้ในการดูดแยกรำและแกลบที่ได้จากการสีข้าว ส่วนปลายข้าวและข้าวขาวจะถูกแยกออกจากกันโดยตะแกรงร่อน เครื่องสีข้าวขนาดเล็กแสดงได้ดังแสดงในรูปที่ 2




รูปที่ 2 เครื่องสีข้าวขนาดเล็กที่ใช้ในการทดลอง

3.2 การสีข้าวและการเก็บข้อมูลที่ใช้นางานวิจัย


ในงานวิจัยนี้ได้นำข้อมูลตัวแปรและการกำหนดค่าต่างๆ ที่ใช้ในการทดลองจากการทบทวนวรรณกรรมงานวิจัยในส่วนที่เกี่ยวกับการแตกหักของข้าวสารที่เกิดจากการสีข้าวด้วยเครื่องสีข้าวขนาดเล็กแบบลูกหินแนวนอนลูกเดียว (Single Horizontal Abrasive) โดยใช้ข้าวเปลือกหอมมะลิ 105 ที่ความชื้น 14 เปอร์เซ็นต์ในการทดลอง และทำการสีข้าวโดยมีตัวแปรที่ใช้ในการทดลอง คือ ขนาดพื้นที่หน้าตัดช่องปล่อยข้าวเปลือก ระยะห่างระหว่างลูกหินขัดข้าวกับแท่งยางขัดข้าว และความเร็วยรอบของลูกหินขัดข้าว ดังแสดงในรูปที่ 3, 4, 5



รูปที่ 3 ขนาดพื้นที่หน้าตัดช่องปล่อยข้าวเปลือก



รูปที่ 4 (A) แสดงระยะห่างระหว่างลูกหินขัดข้าวกับแท่งยางขัดข้าว
(B) แสดงการตั้งระยะห่างของลูกหินด้วย Feeler Gauge



รูปที่ 5 (A) แสดงตำแหน่งในการวัดความเร็วยรอบของลูกหินขัดข้าว
(B) แสดงการวัดและปรับตั้งความเร็วยรอบของลูกหินขัดข้าว

การวิจัยได้สรุปชุดการทดลองแยกออกเป็น 3 กรณี ดังแสดงในตารางที่ 1 จากการทดลองทั้ง 3 กรณี กำหนดให้แต่ละกรณีมีการแบ่งเงื่อนไขการทดลองสีข้าวออกเป็นกรณีละ 9 เงื่อนไข การสีข้าวเพื่อเก็บข้อมูลจากแต่ละเงื่อนไขทำได้โดยแบ่งเวลาในการเก็บตัวอย่างข้าวสารของแต่ละเงื่อนไขออกเป็นเงื่อนไขละ 5 นาที โดยทำการแยกเก็บทุกๆ 10 วินาที จากนั้นนำข้าวสารที่ได้จากแต่ละเงื่อนไขไปหาร้อยละข้าวหัก ซึ่งสามารถคำนวณได้จากสมการที่ 1 ข้อมูลที่ได้จะถูกนำมาใช้กับโครงข่ายประสาทเทียมที่ได้ออกแบบไว้ต่อไป

$$\text{เปอร์เซ็นต์ข้าวหัก} = \frac{\text{น้ำหนักข้าวรวม} - \text{น้ำหนักต้นข้าว}}{\text{น้ำหนักข้าวรวม}} \times 100 \quad (1)$$

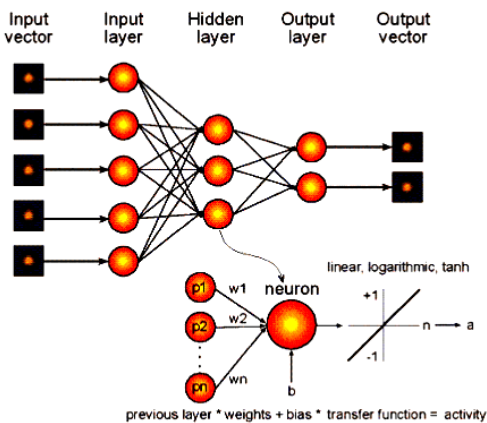
ตารางที่ 1 ชุดกรณีเงื่อนไขที่ใช้ในการสีข้าว

| | ขนาดพื้นที่หน้าตัดช่องปล่อยข้าวเปลือก (mm ²) | ความเร็วยรอบของลูกหินขัดข้าว (rpm) | ระยะห่างระหว่างลูกหินกับแท่งยางขัดข้าว (mm) | | | |
|-----------|--|------------------------------------|---|--|--|--|
| กรณีที่ 1 | 900 | 1,380 1,420 1,460 | 1.3 1.5 1.7 | | | |
| กรณีที่ 2 | 1,125 | 1,380 1,420 1,460 | 1.3 1.5 1.7 | | | |
| กรณีที่ 3 | 1,350 | 1,380 1,420 1,460 | 1.3 1.5 1.7 | | | |

3.3 การออกแบบสถาปัตยกรรมโครงสร้างของโครงข่ายประสาทเทียมที่ใช้ในงานวิจัย

งานวิจัยนี้เลือกใช้แบบจำลองโครงข่ายประสาทเทียมแบบหลายชั้นป้อนไปข้างหน้า (Multilayer feed forward

neural network) และใช้กระบวนการเรียนรู้แบบแพร่กระจายย้อนกลับของเลเวนเบิร์ก-มาควาร์ดท์ (Levenberg-Maquardt's Back-propagation) ซึ่งเป็นหนึ่งในโครงสร้างของแบบจำลองโครงข่ายประสาทเทียมที่นิยมใช้ที่สุด [26] เนื่องจากเป็นโครงสร้างที่ไม่ซับซ้อนและใช้เวลาไม่นานในการฝึกหัดโครงข่ายประสาทเทียม [27] โดยทั่วไปแล้วโครงข่ายของแบบจำลองประกอบด้วยชั้นจำนวน 3 ชั้น ได้แก่ ชั้นข้อมูลนำเข้า (Input layer) ชั้นแฝง (Hidden layer) และชั้นแสดงผลหรือชั้นส่งออก (Output layer) ดังแสดงในรูปที่ 6 และจากงานวิจัยที่ผ่านมา พบว่า โครงข่ายประสาทเทียมที่ประกอบด้วยชั้นซ่อน (Hidden Layer) 1 - 2 ชั้นมีความสามารถเพียงพอที่จะแก้ปัญหาต่างๆ ได้ [28] และการกำหนดจำนวนหน่วยย่อยในชั้นซ่อนไม่มีหลักการที่แน่นอน อาศัยการลองผิดลองถูก [29]



รูปที่ 6 กระบวนการเรียนรู้แบบแพร่กระจายย้อนกลับ [30]

เทคนิคของโครงข่ายประสาทเทียมแบบแพร่กระจายย้อนกลับ (Back Propagation) นั้น ข้อมูลจากชั้นข้อมูลนำเข้าจะถูกคำนวณและส่งผ่านฟังก์ชันถ่ายโอน (Transfer Function) จากชั้นแฝง (Hidden Layer) ไปยังชั้นแสดงผล (Output Layer) โดยหลักการของกระบวนการเรียนรู้ของแบบจำลองคือ การเปลี่ยนแปลงค่าถ่วงน้ำหนัก (Weight) ของแต่ละการเชื่อมต่อเพื่อปรับผลลัพธ์ของแบบจำลองให้ใกล้เคียงกับค่าความจริงมากที่สุดโดยอาศัยการแพร่กลับเพื่อปรับค่าน้ำหนักในการเชื่อมต่อระหว่างนิวรอนให้เหมาะสม การปรับค่าน้ำหนักนี้จะขึ้นกับความแตกต่างของค่าเอาต์พุตที่คำนวณได้กับค่าเอาต์พุตที่ต้องการ โดยชุดข้อมูลที่ใช้ฝึกหัด (Training) โครงข่ายประสาทเทียมจะมีคำตอบไว้คอยตรวจสอบว่าโครงข่ายประสาทเทียมให้คำตอบที่ถูกต้องหรือไม่ ถ้า

คำตอบไม่ถูก วงจรข่ายก็จะปรับตัวเองเพื่อให้ได้คำตอบที่ดีขึ้น ซึ่งการปรับน้ำหนักทำได้ตามสมการที่ 2 ดังนี้

$$\Delta w_{ji}(n+1) = \eta \delta_j(n) \cdot y_j(n) + \alpha \Delta w_{ji}(n) \quad (2)$$

เมื่อ

x_i คือ ค่าข้อมูลต้นเข้าที่ node i

w_i คือ ค่าถ่วงน้ำหนักที่ node i

Δw_{ji} คือ ค่าปรับแก้ค่าถ่วงน้ำหนักระหว่าง node i และ j

η คือ ค่าอัตราการเรียนรู้

α คือ ค่าโมเมนตัม

δ_j คือ ค่าผลต่างระหว่างค่าจริงกับค่าที่ได้จากการ

คำนวณในรูปของอนุพันธ์ของ Transfer function ของ node j

y_j คือ ค่าผลลัพธ์ของแบบจำลองที่ node j และ n

$n+1$ คือ ค่าที่แสดงถึงรอบของการปรับแก้ที่ n หรือ


$n+1$

งานวิจัยนี้ได้ใช้งานแบบจำลองโครงข่ายประสาทเทียมเทคนิคแบบแพร่กระจายย้อนกลับ (Back Propagation) ผ่านกล่องเครื่องมือโครงข่ายประสาทเทียม (Neural network toolbox) ของซอฟต์แวร์ MATLAB โดยกำหนดให้จำนวนชั้นซ่อน (Hidden layer) ของโครงข่ายประสาทเทียมมีหนึ่งชั้นซ่อน มีจำนวนหน่วยย่อย (Node) ในชั้นซ่อน 5, 10, 15 หน่วยย่อย (Node) ตามลำดับ และกำหนดให้ฟังก์ชันถ่ายโอน (Transfer function) ของโครงข่ายประสาทเทียมในชั้นซ่อน (Hidden layer) และชั้นส่งออก (Output Layer) เป็นแบบ Log-sigmoid Transfer Function (Logsig), Linear Transfer Function (Purelin), และ Tan-sigmoid Transfer Function (Tansig) ดังแสดงในรูปที่ 7, 8, 9 โดยเรียงสลับเปลี่ยน 9 รูปแบบ ดังแสดงในตารางที่ 2 งานวิจัยนี้ได้ใช้ค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (Mean Squared Error หรือ MSE) เป็นดัชนีชี้วัดความแม่นยำของแบบจำลองโครงข่ายประสาทเทียม ค่าเฉลี่ยความผิดพลาดของโครงข่ายเป็นผลรวมค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Least Mean Square Error หรือ LMS) ที่เกิดจากการสอนโครงข่าย (Train Network) ค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (Mean Squared Error หรือ MSE) คำนวณได้จากสมการที่ 3


$$MSE = \sum_{i=1}^N (E_i)^2 / N \quad (3)$$

เมื่อ


N คือ จำนวนของข้อมูลทั้งหมดที่ใช้ในการพยากรณ์
 E_i คือ ผลต่างระหว่าง ค่าจริงของข้อมูลตัวที่ t ได้ กับ
 ค่าของข้อมูลตัวที่ t ซึ่งได้มาจากการพยากรณ์



รูปที่ 7 Log-sigmoid Transfer Function (Logsig) [31]



รูปที่ 8 Linear Transfer Function (Purelin) [31]



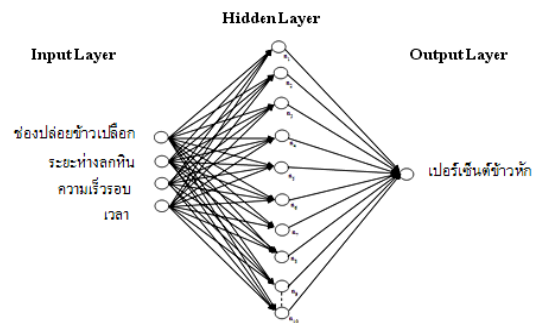
รูปที่ 9 Tan-sigmoid Transfer Function (Tansig) [31]

ตารางที่ 2 ฟังก์ชันถ่ายโอนที่กำหนดให้แก่แต่ละโครงข่าย

| Neural Network | Transfer function | |
|----------------|-------------------|--------------|
| | Hidden Layer | Output Layer |
| Network 1 | Logsig | Logsig |
| Network 2 | Purelin | Logsig |
| Network 3 | Tansig | Logsig |
| Network 4 | Logsig | Purelin |
| Network 5 | Purelin | Purelin |
| Network 6 | Tansig | Purelin |
| Network 7 | Logsig | Tansig |
| Network 8 | Purelin | Tansig |
| Network 9 | Tansig | Tansig |

3.4 ข้อมูลนำเข้า (Input) และข้อมูลส่งออก (Output) ของโครงข่ายประสาทเทียม

ข้อมูลที่ใช้เป็นข้อมูลนำเข้า (Input) ของโครงข่ายประสาทเทียมประกอบด้วย ช่องปล่อยข้าวเปลือก ความเร็วรอบของลูกหินขัดข้าว ระยะห่างระหว่างลูกหินขัดข้าวกับแท่งยางขัดข้าว และเวลาที่ใช้ในการสีข้าว โดยมีข้อมูลส่งออก (output) ของโครงข่ายประสาทเทียมคือ ร้อยละข้าวหักที่ได้จากการสีข้าว ข้อมูลทั้งหมดจะถูกนำไปใช้กับสถาปัตยกรรมโครงข่ายโครงข่ายประสาทเทียมแบบต่างๆ ที่ได้ออกแบบไว้ ดังแสดงในรูปที่ 10



รูปที่ 10 ตัวอย่างโครงข่ายประสาทเทียมที่ใช้ในงานวิจัย

ตัวแปรนำเข้า (Input) ที่ใช้กับโครงข่ายประสาทเทียม ต้องมีการแปลงค่าข้อมูล (Data transformation) เพื่อเป็นการปรับขอบเขตของข้อมูลให้อยู่ในช่วงที่เหมาะสมต่อการนำไปใช้สอนให้โครงข่ายประสาทเทียม วิธีการแปลงค่าข้อมูลดังกล่าว ใช้วิธีการทำข้อมูลให้เป็นบรรทัดฐาน (Normalization) โดยเป็นการลดค่าข้อมูลให้อยู่ในขอบเขตที่น้อยลงให้อยู่ในย่าน [0, 1] ซึ่งเป็นค่าที่อยู่ในช่วงที่เหมาะสมกับฟังก์ชันที่ใช้งานของโครงข่ายประสาทเทียม วิธีการทำข้อมูลให้เป็นบรรทัดฐาน (Normalization) นั้นมีหลายวิธี แต่ที่นิยมนำมาใช้กันบ่อยๆ แพร่หลายคือ การแปลงค่าข้อมูลในลักษณะเป็นเชิงเส้น (Min - max Normalization) ซึ่งแสดงได้ดังสมการที่ 4

$$V' = \frac{(V - \min_{old})}{(\max_{old} - \min_{old})} \quad (4)$$

เมื่อ

 V' คือ ค่าข้อมูลที่ได้หลังจากผ่านสมการ V คือ ค่าข้อมูลก่อนผ่านสมการ \min_{old} คือ ค่าที่มีค่าน้อยที่สุดของข้อมูล \max_{old} คือ ค่าที่มีค่ามากที่สุดของข้อมูล

ข้อมูลจากการสืบข่าวของแต่ละกรณีที่จะนำมาใช้ฝึกหัด (Training) และทดสอบ (Testing) ในแบบจำลองโครงข่ายประสาทเทียมนั้น แต่ละกรณีมีข้อมูลทั้งสิ้นกรณีละ 207 ชุด ข้อมูล โดยที่ชุดข้อมูลจะถูกแบ่งออกเป็น 2 ส่วน ส่วนแรกใช้เพื่อการฝึกหัด (Training) แบบจำลองโครงข่ายประสาทเทียม และส่วนที่เหลือจะใช้เพื่อทดสอบ (Testing) โดยกำหนดให้การสอน (Train) มีค่า Epoch เท่ากับ 1,000 Gradient มีค่าจาก $1.00 - 1.00 \cdot 10^{-10}$ และ Validation check เท่ากับ 6 โดยแบบจำลองโครงข่ายประสาทเทียมในการทำนายร้อยละข่าวหักที่ได้จากการสืบข่าว ซึ่งในงานวิจัยนี้แบ่งข้อมูลที่ใช้ในการฝึกหัดออกเป็น 75 เปอร์เซ็นต์และอีก 25 เปอร์เซ็นต์จะใช้เพื่อทดสอบ ของแบบจำลองโครงข่ายประสาทเทียม จากนั้นทำการเปรียบเทียบความแม่นยำของผลการทำนายร้อยละข่าว

หักที่ได้จากแบบจำลองโครงข่ายประสาทเทียมแต่ละชนิด โดยใช้ค่าเฉลี่ยของผลรวมของความคลาดเคลื่อน Mean square error (MSE) และค่า Regression ที่ได้ในการเปรียบเทียบผล

4. ผลการวิจัย

การศึกษาการหาโครงสร้างของแบบจำลองโครงข่ายประสาทเทียมเพื่อใช้ในการทำนายร้อยละข่าวหักจากเครื่องสืบข่าวขนาดเล็กจากโครงสร้างของโครงข่ายประสาทเทียมที่ได้กำหนดให้มีฟังก์ชันถ่ายโอน (Transfer Function) ในโครงข่ายเป็นแบบ Tansig, Logsig, และ Purelin ที่ใช้ในการทดลอง พบว่าแบบจำลองโครงข่ายประสาทเทียมที่ได้จากทั้ง 3 กรณีสามารถให้ผลการทำนายร้อยละข่าวหักได้แม่นยำใกล้เคียงกัน

โดยผลการทดลองการทำนายร้อยละข่าวหักที่ได้จากทั้ง 3 กรณี แสดงให้เห็นว่า โครงข่ายประสาทเทียมที่ได้จากชุดการทดลองทุกกรณีที่มีฟังก์ชันถ่ายโอน (Transfer Function) ในชั้นซ่อน (Hidden Layer) เป็นแบบ Logsig และฟังก์ชันถ่ายโอน (Transfer Function) ในชั้นข้อมูลส่งออก (Output) เป็นแบบ Purelin สามารถทำนายร้อยละข่าวหักได้ถูกต้องแม่นยำที่สุด ผลที่ได้แสดงดังตารางที่ 3

ตารางที่ 3 ผลการวิเคราะห์ฟังก์ชันถ่ายโอน (Transfer Function) ที่ใช้ในการทำนาย

| ชุดกรณี | จำนวน Node | Transfer function | | Regression | | | | MSE |
|-----------|------------|-------------------|--------------|------------|------------|---------|---------|--------|
| | | Hidden Layer | Output Layer | Training | Validation | Test | All | |
| กรณีที่ 1 | 5 Node | Logsig | Purelin | 0.99024 | 0.98394 | 0.98203 | 0.98732 | 1.310 |
| | 10 Node | Logsig | Purelin | 0.99403 | 0.99418 | 0.98720 | 0.99283 | 0.795 |
| | 15 Node | Logsig | Purelin | 0.99481 | 0.98864 | 0.98892 | 0.99235 | 0.799 |
| กรณีที่ 2 | 5 Node | Logsig | Purelin | 0.99727 | 0.99588 | 0.99580 | 0.99663 | 0.242 |
| | 10 Node | Logsig | Purelin | 0.99719 | 0.99469 | 0.99707 | 0.99665 | 0.262 |
| | 15 Node | Logsig | Purelin | 0.99797 | 0.99488 | 0.99630 | 0.99702 | 0.187 |
| กรณีที่ 3 | 5 Node | Logsig | Purelin | 0.98702 | 0.97575 | 0.97805 | 0.98292 | 0.950 |
| | 10 Node | Logsig | Purelin | 0.98794 | 0.97906 | 0.97938 | 0.98437 | 0.850 |
| | 15 Node | Logsig | Purelin | 0.98870 | 0.98305 | 0.98595 | 0.98707 | 0.8430 |


จากตารางที่ 3 ผลของการวิเคราะห์การทำนายร้อยละข่าวหักที่ได้จากการทดลองแต่ละกรณีสามารถสรุปได้ดังนี้

(1) กรณีที่ 1 เปิดช่องปล่อยข่าวเปลือกที่ 900 ตร.ม.

ในกรณีที่มีการเปิดช่องปล่อยข่าวเปลือกที่ 900 ตร.ม. พบว่าผลการทำนายร้อยละข่าวหักที่ค่าแม่นยำที่สุดในกรณีนี้คือ โครงข่ายประสาทเทียมที่มีโครงสร้างแบบ 4 – 10 –

1 หรือโครงสร้างของโครงข่ายที่มีตัวแปรนำเข้า (Input) 4 ตัวแปร มีจำนวนหน่วยย่อย (Node) ในชั้นแอบแฝงหรือชั้นซ่อนจำนวน 10 Node และมีชั้นข้อมูลตัวแปรส่งออก (Output) 1 ตัวแปร โดยมีฟังก์ชันถ่ายโอน (Transfer Function) ในชั้นแรกและชั้นที่สอง เป็นแบบ Logsig และ Purelin ซึ่งมีหน่วยย่อย (Node) ในชั้นแอบแฝง (Hidden Layer) เท่ากับ 10 Node โดยให้ค่า Regression เฉลี่ยเท่ากับ 0.99283 และมีผล

ค่าความคลาดเคลื่อน Mean square error (MSE) เฉลี่ย นำมาเปรียบเทียบกับค่าร้อยละข้าวหักที่เกิดขึ้นจริงที่ได้จาก
เท่ากับ 0.795 ผลของร้อยละข้าวหักที่ได้จากการทำนายเมื่อ ทดลอง แสดงดังในรูปที่ 11




รูปที่ 11 กราฟแสดงการเปรียบเทียบค่าร้อยละข้าวหักที่ได้จากการทำนาย (Predicts) และที่ได้จากการทดลอง (Experiments)

(2) กรณีที่ 2 เปิดช่องปล่อยข้าวเปลือกที่ 1,125 ตร.มม.

ในกรณีที่มีการเปิดช่องปล่อยข้าวเปลือกที่ 1,125 ตร.ม พบว่าผลการทำนายร้อยละข้าวหักที่ให้ค่าแม่นยำที่สุดในกรณีนี้คือ โครงข่ายประสาทเทียมที่มีโครงสร้างแบบ 4 – 15 – 1 หรือโครงสร้างของโครงข่ายที่มีตัวแปรนำเข้า (Input) 4 ตัวแปร มีจำนวนหน่วยย่อย (Node) ในชั้นแอบแฝงหรือชั้นซ่อนจำนวน 15 Node และมีชั้นข้อมูลตัวแปรส่งออก (Output) 1 ตัวแปร โดยมีฟังก์ชันถ่ายโอน (Transfer Function) ในชั้น

แรกและชั้นที่สอง เป็นแบบ Logsig และ Purelin ซึ่งมีหน่วยย่อย (Node) ในชั้นแอบแฝง (Hidden Layer) เท่ากับ 15 Node โดยให้ค่า Regression เฉลี่ยเท่ากับ 0.99702 และมีผลค่าความคลาดเคลื่อน Mean square error (MSE) เฉลี่ยเท่ากับ 0.187 ผลของร้อยละข้าวหักที่ได้จากการทำนายเมื่อนำมาเปรียบเทียบกับค่าร้อยละข้าวหักที่เกิดขึ้นจริงที่ได้จากการทดลอง แสดงดังในรูปที่ 12

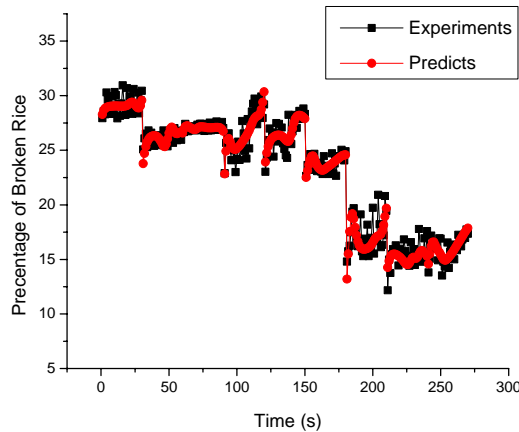


รูปที่ 12 กราฟแสดงการเปรียบเทียบค่าร้อยละข้าวหักที่ได้จากการทำนาย (Predicts) และที่ได้จากการทดลอง (Experiments)

(3) กรณีที่ 3 เปิดช่องปล่อยข้าวเปลือกที่ 1,350 ตร.มม.

ในกรณีที่มีการเปิดช่องปล่อยข้าวเปลือกที่ 1,350 ตร.มม. พบว่าผลการทำนายร้อยละข้าวหักที่ให้ค่าแม่นยำที่สุดในกรณีนี้คือ โครงข่ายประสาทเทียมที่มีโครงสร้างแบบ 4 – 15 – 1 หรือโครงสร้างของโครงข่ายที่มีตัวแปรนำเข้า (Input) 4 ตัวแปร มีจำนวนหน่วยย่อย (Node) ในชั้นแอบแฝงหรือชั้นซ่อนจำนวน 15 Node และมีชั้นข้อมูลตัวแปรส่งออก (Output) 1 ตัวแปร โดยมีฟังก์ชันถ่ายโอน (Transfer Function) ในชั้น

แรกและชั้นที่สอง เป็นแบบ Logsig และ Purelin ซึ่งมีหน่วยย่อย (Node) ในชั้นแอบแฝง (Hidden Layer) เท่ากับ 15 Node โดยให้ค่า Regression เฉลี่ยเท่ากับ 0.98417 และมีผลค่าความคลาดเคลื่อน Mean square error (MSE) เฉลี่ยเท่ากับ 0.643 ผลของร้อยละข้าวหักที่ได้จากการทำนายเมื่อนำมาเปรียบเทียบกับค่าร้อยละข้าวหักที่เกิดขึ้นจริงที่ได้จากการทดลอง แสดงดังในรูปที่ 13



รูปที่ 13 กราฟแสดงการเปรียบเทียบค่าร้อยละข้าวหักที่ได้จากการทำนาย (Predicts) และที่ได้จากการทดลอง (Experiments)

จากผลการศึกษาการหาโครงสร้างแบบจำลองโครงข่ายประสาทเทียมเพื่อใช้ในการทำนายร้อยละข้าวหักที่ได้จากเครื่องสีข้าวขนาดเล็กทั้ง 3 กรณี พบว่าแบบจำลองโครงข่ายประสาทเทียมที่ได้จากทั้ง 3 กรณีมีความสามารถในการทำนายค่าร้อยละข้าวหักที่ได้จากเครื่องสีข้าวขนาดเล็กได้อย่างแม่นยำ โดยสองในสามของสถาปัตยกรรมที่ได้จากการทดลองพบว่ามีหน่วยย่อย (Node) ในชั้นแอบแฝง (Hidden Layer) เท่ากับ 15 Node หรือมีโครงสร้างของโครงข่ายประสาทเทียม แบบ 4 – 15 – 1 และหากเทียบผลการทดลองที่ได้จากทั้งสามกรณี พบว่ากรณีที่ 2 ให้ผลการทำนายที่แม่นยำที่สุดคือให้ค่า โดยให้ค่า Regression เฉลี่ยเท่ากับ 0.99702 และมีผลค่าความคลาดเคลื่อน Mean square error (MSE) เฉลี่ย เท่ากับ 0.187

ทั้งนี้หากพิจารณากราฟร้อยละข้าวหักที่ได้จากการทดลอง (Experiments) ตามรูปที่ 11 - 13 พบว่า ผลของค่าร้อยละข้าวหักจากแต่ละช่วงของกลุ่มข้อมูลที่ได้จากการทดลอง (Experiments) ในกรณีที่ 2 มีการกระจายตัวน้อยกว่าผลของค่าร้อยละข้าวหักจากแต่ละช่วงของกลุ่มข้อมูลที่ได้จาก

การทดลอง (Experiments) ในกรณีที่ 1 และ 3 ซึ่งอาจมีผลทำให้การทำนายในกรณีที่ 2 มีค่าแม่นยำกว่า

โครงสร้างของโครงข่ายประสาทเทียมที่มีความเหมาะสมที่สุดที่ได้จากงานวิจัยนี้ อาจนำมาใช้ในการทำนายค่าร้อยละข้าวหักที่ได้จากเครื่องสีข้าวขนาดเล็กที่มีสภาวะการดำเนินการอยู่ภายในขอบเขตข้อมูลที่ใช้ในการฝึก (Training) ในงานวิจัยนี้ได้ แต่ไม่สามารถนำไปใช้กับการทำนายกับสภาวะในการดำเนินการที่แตกต่างหรือไม่ได้อยู่ในขอบเขตของการฝึก (Training) ในงานวิจัยนี้ เนื่องจากโครงข่ายประสาทเทียมจะมีความเฉพาะเจาะจงกับสภาวะการทดลองที่ใช้ในงานวิจัยหรือเงื่อนไขการทดลองนั้นเท่านั้น ในการฝึกสอนและเรียนรู้ของโครงข่ายประสาทเทียมภายใต้ปัจจัยและเงื่อนไขต่างๆ เป็นการฝึกสอน (Training) ที่สามารถใช้ได้เฉพาะกรณี หากมีการเปลี่ยนแปลงค่าหรือจำนวนข้อมูลป้อนเข้า (Input) จำเป็นต้องทำการฝึกสอน (Training) และคัดเลือกรูปแบบที่เหมาะสมใหม่ทุกครั้งไปเพื่อทำการวิเคราะห์ผลฝึกสอนและเรียนรู้ ก่อนที่จะนำโครงข่ายประสาทเทียมที่ได้จากการฝึกสอนนั้นๆ ไปใช้งานต่อไป

5.สรุปและเสนอแนะ

บทความนี้เป็นการศึกษาวิธีการหาโครงสร้างของโครงข่ายประสาทเทียม (Artificial Neural Network Model) ที่เหมาะสมเพื่อใช้ในการทำนายค่าร้อยละข้าวหักที่ได้จากการสีข้าวด้วยเครื่องสีข้าวขนาดเล็กแบบลูกหินแกนนอนลูกเดี่ยว (Single Horizontal Abrasive) โดยได้ศึกษาและนำเทคนิคโครงข่ายประสาทเทียม (Artificial Neural Network: ANN) ซึ่งเป็นเทคนิคที่ใช้ในการแก้ปัญหาโดยจำลองกระบวนการทำงานของสมองมนุษย์ ซึ่งมีส่วนประกอบเป็นโครงข่ายของหน่วยย่อย (Node) เชื่อมโยงกันอย่างสลับซับซ้อน โครงข่ายประสาทเทียมสามารถเรียนรู้ได้เองโดยการหาความสัมพันธ์ของข้อมูลด้วยวิธีการการเปลี่ยนแปลงค่าถ่วงน้ำหนัก (Weight) ความเชื่อมโยงของแต่ละหน่วยย่อย (Node) เพื่อปรับผลลัพธ์ของแบบจำลองให้ใกล้เคียงกับค่าความจริงมากที่สุด

ผลการวิจัยได้สรุปแยกตามชุดกรณีของการทดลองออกเป็น 3 กรณี ได้แก่

กรณีที่ 1 เปิดช่องปล่อยข้าวเปลือกที่ 900 ตร.มม.

กรณีที่ 2 เปิดช่องปล่อยข้าวเปลือกที่ 1,125 ตร.มม

กรณีที่ 3 เปิดช่องปล่อยข้าวเปลือกที่ 1,350 ตร.มม.

จากการวิจัยพบว่าโดยรวมแล้ว โครงสร้างของโครงข่ายประสาทเทียมที่เหมาะสมกับการทำนายร้อยละข้าวหักที่ได้จากการสีข้าวด้วยเครื่องสีข้าวขนาดเล็ก ทั้ง 3 กรณี มีความแม่นยำใกล้เคียงกัน โดยผลการทำนายของแต่ละกรณีให้ค่า Regression ที่ 0.99283 0.99702 0.98417 และมีผลของค่าความคลาดเคลื่อน Mean square error (MSE) ที่ 0.795 0.187 0.643 ตามลำดับ ซึ่งผลการวิจัยนี้ได้จากโครงข่ายประสาทเทียมที่มีหน่วยย่อย (Node) ในชั้นแอบแฝง (Hidden Layer) ที่ 1 กับ 2 เท่ากับ 10 15 15 หน่วยย่อย (Node) ตามลำดับ

จากงานวิจัยนี้สามารถแสดงให้เห็นว่าโครงข่ายประสาทเทียม แบบหลายชั้นป้อนไปข้างหน้า (Multilayer Feed Forward) ด้วยเทคนิคแบบแพร่กระจายย้อนกลับ (Back Propagation) โดยใช้การเรียนรู้แบบแบบมีผู้ฝึกหัด (Supervised Learning) ใช้กฎการเรียนรู้ (Training Function) แบบ Levenberg Marquardt Algorithm (TRAINLM) และใช้ Adaption Learning Function แบบ Gradient descent with momentum weight and bias learning function (LEARNGDM) มีประสิทธิภาพเพียงพอที่จะนำไปใช้ในการประยุกต์เพื่อทำนายค่าร้อยละข้าวหักที่ได้จากการสีข้าวด้วยเครื่องสีข้าวขนาดเล็ก

6. กิตติกรรมประกาศ

ขอขอบคุณภาควิชาวิศวกรรมอุตสาหการ ที่ให้การสนับสนุนเครื่องมือและทุนการวิจัย ขอขอบพระคุณ ดร. นันทวัฒน์ วีระยุทธ อาจารย์ประจำภาควิชาวิศวกรรมเครื่องกล และ อ.ตะวันฉาย โพธิ์หอม อาจารย์ประจำภาควิชาวิศวกรรมอุตสาหการ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยอุบลราชธานี ที่ให้คำปรึกษา คำแนะนำ ให้ความรู้ในเชิงวิชาการ และมีส่วนช่วยเหลือ ในการดำเนินการวิจัยให้สำเร็จลุล่วงไปด้วยดี

7.บรรณานุกรม

- [1] Kumar, S.,Jain, A., 2008. "Knowledge extraction from trained neural network hydrologic models." **Proc. of the National Conference HYDRO 2008**, , MNIT Jaipur, Rajasthan, India. 15-16 December
- [2] Psychogios DC, Ungar LH. 1992. "A hybrid neural network – first Principles approach to process modeling". **AIChE Journal** ; 38:1499–511.
- [3] Samad T, Mathur A. 1992. "Parameter estimation for process control with neural networks." **Int J Approx Reason**;7:149–64.
- [4] Leib TM, Mills PL, Lerou JJ, Turner JR. 1995. "Evaluation of neural networks for simulation of three phase bubble column reactors." **Trans IChemE Journal**;73A:690–6.
- [5] Otawara K, Fan LT, Tsutsumi A, Yano T, Kuramoto K, Yoshida K. 2002. "An artificial neural network as a model for chaotic behavior of a three phase Fluidized bed." **Chaos Soliton Fract Journal**; 13:353–62.
- [6] Satish S, Setty YP. 2005. "Modeling of a continuous Fluidized bed dryer using artificial neural networks." **Int Commun Heat Mass**;32:539–47.
- [7] Fernandes FAN, Lona LMF. 2005. "Neural network applications in polymerization processes." **Brazilian Journal of Chemical Engineering**;22(03):401–18.

- [8] Subramanian N, Yajnik A, Murthy RSR. 2004. "Artificial neural network as an alternative to multiple regression analysis in optimizing formulation parameters of cytarabine liposomes." **AAPS PharmSciTech**; 5(1).
- [9] Lertworasirikul S, Tipsuwan Y. 2008. "Moisture content and water activity prediction of semi-finished cassava crackers from drying process with artificial neural network." **J Food Eng** ; 84:65–74.
- [10] Behzadi SS, Klocker J, Huttlin H, Wolschann P, Viernstein H. 2005. "Validation of Fluid bed granulation utilizing artificial neural network." **Int J Pharm**; 291:139–48.
- [11] Kerdpi boon S, Kerr WL, Devahastin S. 2006. "Neural network prediction of physical property changes of dried carrot as a function of fractal dimension and moisture content." **Food Res Int**; 39:1110–8.
- [12] Hernandez-perez JA, Garcia-alvarado MA, Trystram G, Heyd B. 2004. "Neural networks for the heat and mass transfer prediction during drying of cassava and mango." **Innov Food Sci Emer Technol**; 5:57–64
- [13] สอาด เณรรอด. 2552. แบบจำลองทำนายผลการวิเคราะห์น้ำมันเครื่องยนต์รถบรรทุกขนาด 85 ตันของเหมืองแม่เมาะโดยโครงข่ายประสาทเทียม. วิทยานิพนธ์ปริญญาวิศวกรรมศาสตรมหาบัณฑิต คณะวิศวกรรมศาสตร์: มหาวิทยาลัยเชียงใหม่.
- [14] ทัดดาว แนบเนียน. 2545. การเปรียบเทียบการพยากรณ์ด้วยวิธีโครงข่ายประสาทเทียมและวิธีของ บ็อกซ์ และเจนกินส์ : กรณีศึกษา อัตราแลกเปลี่ยนเงินตราต่างประเทศ. วิทยานิพนธ์วิทยาศาสตรมหาบัณฑิต สาขาสถิติประยุกต์ บัณฑิตวิทยาลัย, มหาวิทยาลัยเกษตรศาสตร์.
- [15] สุพรรณา เหลืองอำนาจศิริ. 2551. การศึกษาเปรียบเทียบตัวแบบการพยากรณ์ปริมาณการส่งออกแป้งมันสำปะหลัง โดยวิธีการวิเคราะห์การถดถอยเชิงเส้นตรงแบบพหุ และวิธีโครงข่ายประสาทเทียม. วิทยานิพนธ์ วิทยาศาสตรมหาบัณฑิต สาขาสถิติประยุกต์ บัณฑิตวิทยาลัย, มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง.
- [16] Makridakis, S., and S. C. Wheelwright, and R. J. Hyndman. 1998. **Forecasting: Methods and Applications**. New York: John Wiley & Sons.
- [17] Assidjo, E. B., Yao, K. Kisselmina., D. Amané. 2008. "Modeling of an industrial drying process by artificial neural networks," **Brazilian Journal of Chemical Engineering** 2008, Vol. 25, No. 03, pp. 515 522.
- [18] Olajide J.O., J.C. Igbeka, T.J. Afolabi, O.A. Emiola. 2007. "Prediction of oil yield from groundnut kernels in an Hydraulic press using artificial neural network (ANN)" **Journal of Food Engineering** 2007, Volume 81, Issue 4, August Pages 643-646.
- [19] Shankar T.J., S. Bandyopadhyay 2007. "Prediction of Extrudate Properties Using Artificial Neural Networks" **Food and Bioproducts Processing** 2007, Volume 85, Issue 1, March. Pages 29-33.
- [20] Rahman M.M., B.K. Bala 2010. "Modelling of jute production using artificial neural networks" **Biosystems Engineering**, Volume 105, Issue 3, March. Pages 350-356, 2010.
- [21] Necla Kara Togun, Sedat Baysec 2010. "Prediction of Torque and Specific Fuel Consumption of a Gasoline Engine by Using Artificial Neural Networks" **Applied Energy**, Volume 87, Issue 1, January. Pages 349-355, 2010.
- [22] Visetkul M. 1984. "Improvement of Rice Processing Technology" **Thailand Engineering Journal** 1984 37 (4): 110 -115.

- [23] H.M. Yao, H.B. Vuthaluru, M.O. Tade and D. Djukanovic, 2005. "Artificial neural network-based prediction of hydrogen content of coal in power station boilers," *Fuel* **84** **2005**, pp. 1535–1542.
- [24] L.H. Ungar, E.J. Hartman, J.D. Keeler and G.D. Martin, 1996. "Process modelling and control using neural networks," *Am Inst Chem Eng Symp Ser* **92**, pp. 57–66.
- [25] **How Science is Bringing Music Instruction Back to Expressive Development**, Neurology Applied: **Available online: www.thomasjwestmusic.com/neurologyapplied.htm**
- [26] Movagharnjad, K., Nikzad, M., 2007. "Modeling of tomato drying using artificial neural network," *Computers and electronics in agriculture*, Vol. 59, pp. 78-85.
- [27] Hagan, M.T., Demuth, H.B., and Beals, M., 1996. **Neural Network Design**. PWS Publishing Company, USA.
- [28] Maier, H. R., Dandy, G. C., 2001. "Neural Network Based Modelling of Environmental Variables" A Systematic Approach. **Mathematical and Computer Modelling**. 33,669-682.
- [29] Hsiao, S. W., Huang, H. C., 2002. "A neural network based approach for product form design". **Design Studies**. 23.:67-84.
- [30] Kucera, M., 2003. "Numerical approach to microfossil proxy data," Lecture notes for Summer school Paleocyanography: Theory and field evidence, **IAMC Geomare 2003**, pp 66-90.
- [31] T.T Nguyen, 1997. "Neural Network Optimal Power Flow," in **APSCOM-97**, Hong Kong, November.