

รายงานวิจัยฉบับสมบูรณ์

โครงการ

การพยากรณ์ยอดขายผลิตภัณฑ์ข้าวผสมโดยการประยุกต์ใช้วิธีเมต้าฮิวริสติกส์  
Forecasting the mixed rice sales using application of metaheuristics

สำนักหอสมุด มหาวิทยาลัยนเรศวร

วันลงทะเบียน.....

เลขทะเบียน.....

เลขเรียกหนังสือ...จ. ๐๙

๖๖

.๑

.ค.๕๖

๙๖.๑๒๖

๒๕๕๙

โดย

ผู้ช่วยศาสตราจารย์ ศรีสัจจา วิทย์ศักดิ์  
ผู้ช่วยศาสตราจารย์ ดร.ภูพงษ์ พงษ์เจริญ

ภาควิชาวิศวกรรมอุตสาหการ คณะวิศวกรรมศาสตร์  
มหาวิทยาลัยนเรศวร

สนับสนุนโดย

งบประมาณรายได้มหาวิทยาลัยนเรศวร

ปีงบประมาณ 2559

## บทคัดย่อ

การพยากรณ์นับว่าเป็นจุดเริ่มต้นของการวางแผนการผลิตที่สามารถช่วยแก้ปัญหาสินค้าขาดมือ หรือปัญหาการผลิตในปริมาณที่มากเกินไปเกินความต้องการของลูกค้าได้ เพราะการพยากรณ์จะช่วยในการจัดสรรทรัพยากรได้อย่างเหมาะสม ไม่ว่าจะเป็นการจัดซื้อ การบริหารทรัพยากรบุคคล การจัดตารางการผลิต และการจัดการสินค้าคงคลัง การพยากรณ์จึงนำไปสู่การลดลงของต้นทุนสินค้าคงคลัง (Inventory cost) และลดความสูญเสียโอกาสในการขายของทางสถานประกอบการ ยอดขายผลิตภัณฑ์ข้าวผสมมีความเกี่ยวข้องกับข้อมูลทั้งด้านอุปสงค์และอุปทานหลายปัจจัย เช่น ความต้องการลูกค้า การกีดกันทางการค้า เงินอุดหนุนปัจจัยทางการเกษตร สิ่งแวดล้อม สภาพอากาศ และวัตถุดิบข้าว เป็นต้น ปัจจัยเหล่านี้มักมีความไม่แน่นอนมาเกี่ยวข้องทำให้ยากต่อการคาดการณ์ งานวิจัยนี้จึงนำเสนอการพยากรณ์ยอดขายผลิตภัณฑ์ข้าวผสมโดยการประยุกต์ใช้วิธีโครงข่ายประสาทเทียม (Artificial Neural Network: ANN) โดยค่าพยากรณ์ที่ได้จากวิธี ANN ให้ค่าเฉลี่ยของราคาที่สองของกำลังสองของความคลาดเคลื่อนน้อยกว่า 0.2 นั่นคือ โมเดลของการพยากรณ์ด้วยวิธี ANN มีความแม่นยำอยู่ที่ร้อยละ 80

อย่างไรก็ตาม ในระหว่างการดำเนินโครงการได้นำส่วนหนึ่งของผลงานวิจัยไปทำการเรียบเรียงเพื่อเผยแพร่ในวารสารวิชาการระดับนานาชาติ Lecture Notes in Computer Science ซึ่งอยู่บนฐานข้อมูลระดับนานาชาติ Scopus และจัดอยู่ในกลุ่ม Quartile 2 ของ Scimago Journal & Country Rank (SJR) และสามารถอ่านรายละเอียดของบทความดังกล่าวในภาคผนวก

**คำสำคัญ:** พยากรณ์ ข้าวผสม เมตาฮิวริสติกส์ วิธีโครงข่ายประสาทเทียม



## Abstract

Forecasting is the beginnings of production planning that can solve stockout product and overproduction. Forecasting can be used to allocate resources such as procurement, labor management, production scheduling, and inventory management. Forecasting has resulted in reduced inventory costs and reduced opportunity cost of the product sale. Mixed rice sales involve demand and supply factors for example, customer demand, trade barriers, agricultura subsidies, environment, weather, and raw materials, which are uncertain. The objective of this work was to forecast the mixed rice sales using application of Artificial Neural Network (ANN). The computational result showed that the root mean square error (RMSE) obtained from ANN was less than 0.2. The forecastintg accuracy was more than 80 percent.

Furthermore, some result obtained from the computational experiments was published in the international journal "Lecture Notes in Computer Science" which is indexed in Scopus database and ranked in Quartile 2 by SJR. The paper can be shown in the appendix.

**Keywords:** *forecasting, mixed rice, metaheuristics, Artificial Neural Networks*



## กิตติกรรมประกาศ

งานวิจัยฉบับนี้สำเร็จลุล่วงไปได้ด้วยดี เนื่องมาจากการสนับสนุนด้านงบประมาณในการทำวิจัยจากงบประมาณรายได้ มหาวิทยาลัยนเรศวร ประจำปี พ.ศ. 2559

ผู้ช่วยศาสตราจารย์ ศรีสัจจา วิหยศักดิ์  
ผู้ช่วยศาสตราจารย์ ดร.กฤษณ์ พงษ์เจริญ



## สารบัญ

	หน้า
บทคัดย่อ	ก
กิตติกรรมประกาศ	ข
สารบัญ	ค
ส่วนที่ 1: Executive Summary	1
ส่วนที่ 2: เนื้อหางานวิจัย	
ความสำคัญและที่มาของปัญหา	7
วัตถุประสงค์ของโครงการวิจัย	10
ขอบเขตของโครงการวิจัย	10
ทฤษฎี และกรอบแนวความคิดของโครงการวิจัย	10
วิธีการดำเนินการวิจัย	11
ผลการดำเนินงานวิจัย	26
สรุปผลการวิจัย	29
เอกสารอ้างอิง	30
ภาคผนวก	
บทความวิจัยที่เผยแพร่	39



## ส่วนที่ 1: Executive Summary

### การพยากรณ์ยอดขายผลิตภัณฑ์ข้าวผสมโดยการประยุกต์ใช้วิธีเมตาฮีริสติกส์ Forecasting the mixed rice sales using application of metaheuristics

ประเทศไทยเป็นประเทศเกษตรกรรม โดยสภาพพื้นที่และภูมิอากาศเหมาะสมแก่การทำเกษตรกรรม จากข้อมูลของสำนักงานเศรษฐกิจการเกษตร กระทรวงเกษตรและสหกรณ์ ปี 2556 (ผลสำรวจเบื้องต้น วันที่ 21 ม.ค.2558) พบว่าประเทศไทยมีเนื้อทั้งหมด 320,696,888 ไร่ เป็นเนื้อที่ป่าไม้ 102,119,540 ไร่ เนื้อที่ใช้ประโยชน์นอกการเกษตร 69,341,116 ไร่ และใช้ทางการเกษตร 149,236,233 ไร่ คิดเป็นร้อยละ 46.53 ของเนื้อที่เป็นประเทศไทยทั้งหมด และมีประชาชนส่วนใหญ่เป็นเกษตรกรกว่าครึ่งประเทศ (34 ล้านคน) คิดเป็นร้อยละ 55.7 ของประชากรทั้งประเทศ (กรมส่งเสริมการเกษตร กระทรวงเกษตรและสหกรณ์, 2546) ซึ่งแสดงให้เห็นว่าการเกษตรนั้นมีความสำคัญต่อเศรษฐกิจของประเทศไทย และทำให้ไทยมีความสามารถพึ่งพาตนเองทางด้านอาหารได้ และจากข้อมูลผลิตภัณฑ์มวลรวมในประเทศ (Gross domestic product: GDP) ไตรมาสที่ 2 ของปี 2559 พบว่าการผลิตนอกภาคเกษตรมีการขยายตัวร้อยละ 3.7 ส่วนการผลิตภาคเกษตรมีค่า GDP หดตัวร้อยละ 0.1ปรับตัวดีขึ้นจากที่หดตัวร้อยละ 1.4 ในไตรมาสที่ 1/2559 (สำนักงานคณะกรรมการพัฒนาการเศรษฐกิจและสังคมแห่งชาติ, 2559) และมีอัตราการขยายตัวของผลิตภัณฑ์มวลรวม (Gross domestic product: GDP) ในประเทศมูลค่าที่แท้จริง (ร้อยละ) ซึ่งพบว่า ในทุกไตรมาสของปี 2558 และ 2559 ภาคการเกษตรมีอัตราการขยายตัว/หดตัวของค่า GDP ของแต่ละไตรมาสสูงกว่าภาคนอกเกษตร

การปรับลดลงและเพิ่มขึ้นเป็นผลกระทบมาจากหลายปัจจัย เช่น สภาพเศรษฐกิจโลก คู่แข่งทางการตลาด เป็นต้น ทำให้ผู้ประกอบการทางภาคเกษตรต้องมีการปรับตัว มีการวางแผนมีการวางแผนทั้งด้านการตลาด การจัดหาวัตถุดิบ การผลิต และการจัดการสินค้าคงคลังที่มีประสิทธิภาพ มีการเตรียมพร้อมรับมือกับการสภาพแวดล้อมการผลิตที่มีการเปลี่ยนแปลงในขนาดตลอดเวลา หากผู้ประกอบการทางภาคเกษตรไม่มีการเตรียมความพร้อม ในการวางแผนการจัดการของคงคลังที่ดี อาจส่งผลต่อต้นทุนการผลิต การกำหนดราคาขายผลิตภัณฑ์ และผลประโยชน์ของสถานประกอบการ เนื่องจากสินค้าทางเกษตรนั้นเป็นสินค้าที่มีข้อจำกัดทางด้านอายุของผลิตภัณฑ์ บางชนิดนั้นมีอายุเก็บได้นานเป็นปี บางชนิดเก็บได้เป็นเดือน หรือบางชนิดอาจมีอายุการเก็บได้เพียงหนึ่งถึงสองวัน ดังนั้น หากไม่มีการวางแผนวางแผนการจัดการของคงคลังที่ดี อาจทำให้คุณภาพของสินค้ามีการเปลี่ยนแปลง ซึ่งจะส่งผลต่อราคาขาย และชื่อเสียง ความน่าเชื่อถือของผู้ประกอบการ

ข้าวเป็นพืชเศรษฐกิจที่สำคัญของประเทศไทย เป็นสินค้าเกษตรกรรมหลักของประเทศเพื่อจำหน่ายในประเทศและส่งออกต่างประเทศของประเทศไทย เนื้อที่ใช้ประโยชน์ทางการเกษตรของประเทศไทยในการทำข้าวมีจำนวนมากที่สุด คือ 69,964,862 ไร่ คิดเป็นร้อยละ 46.88 ของเนื้อที่ทางการเกษตรทั้งหมด (สำนักงานเศรษฐกิจการเกษตร กระทรวงเกษตรและสหกรณ์, 2556) และจากข้อมูลธนาคารแห่งประเทศไทย ในปี 2557 พบว่าข้าวเป็นสินค้าเกษตรที่มีปริมาณการส่งออกเป็นอันดับหนึ่งของสินค้าเกษตรกรรมทั้งหมดคือ 10.9 ล้านเมตริกตัน คิดเป็นมูลค่าการส่งออก 5,438 ล้านดอลลาร์สหรัฐ และประเทศไทยได้ทำการส่งออกข้าวเป็นอันดับ 1 ของโลก (กระทรวงเกษตรและสหกรณ์, 2558) เมื่อพิจารณาการส่งออกทั้งในเชิงปริมาณและมูลค่าการส่งออกข้าวของไทย ปี 2553-2558 (สำนักวิจัยเศรษฐกิจการเกษตร, 2557) พบว่า การส่งออกมีการเปลี่ยนแปลงทั้งเพิ่มขึ้นและลดลงเช่นกันตามภาวะเศรษฐกิจ ซึ่งปริมาณการส่งออกข้าวที่เปลี่ยนแปลงอาจมีผลมาจากปริมาณอุปทานหรือปริมาณผลผลิตข้าว และปริมาณอุปสงค์หรือปริมาณความต้องการข้าวภายในประเทศ ในปี 2553-2557 (สำนักวิจัยเศรษฐกิจการเกษตร, 2557) ปริมาณความต้องการข้าวในประเทศลดลงจาก 17.79 ล้านตันข้าวเปลือกในปี 2553 เหลือ 16.32 ล้านตันข้าวเปลือกในปี 2557 หรือลดลงร้อยละ 1.56 ต่อปี และในปี 2557 ข้าวที่ใช้ในประเทศมีปริมาณ 16.32 ล้านตันข้าวเปลือก ลดลงจาก 16.53 ล้านตันข้าวเปลือกในปี 2556 หรือลดลงร้อยละ 1.27 เนื่องจากความต้องการใช้ข้าวเพื่อบริโภค ทำเมล็ดพันธุ์ และผลิตอาหารสัตว์มีแนวโน้มลดลง จึงต้องส่งเสริมการส่งออกข้าวให้มีปริมาณเพิ่มขึ้น อย่างไรก็ตาม มูลค่าการส่งออกข้าวหดตัวลงเนื่องจากการชะลอตัวของอุปสงค์โลก และราคาข้าวไทยที่อยู่ในระดับที่สูงกว่าคู่แข่ง โดยเฉพาะอย่างยิ่งเวียดนาม (สำนักยุทธศาสตร์และการวางแผนเศรษฐกิจมหภาค, 2558) จากข้างต้นผู้ประกอบการผลิตภัณฑ์ข้าวควรมีการวางแผนการประกอบกิจการเพื่อรองรับสถานการณ์ที่อาจส่งผลต่อศักยภาพการแข่งขันทางธุรกิจข้าว ซึ่งการลดต้นทุนการดำเนินงานกิจกรรมในโซ่อุปทานข้าวมีส่วนช่วยเพิ่มความสามารถการแข่งขันทางราคาขายของผลิตภัณฑ์ข้าว และเพิ่มโอกาสการแข่งขัน

โซ่อุปทานข้าวประกอบด้วยกิจกรรมหลายกิจกรรม กิจกรรมในโซ่อุปทาน (Supply chain) จะแปรสภาพทรัพยากรธรรมชาติ วัตถุดิบ และวัสดุอื่นๆ ให้กลายเป็นสินค้าสำเร็จ แล้วส่งไปจนถึงลูกค้าคนสุดท้าย (ผู้บริโภค) ดังรูปที่ 2 โดยเริ่มจากผู้จำหน่ายเมล็ดพันธุ์ข้าวทำการขายพันธุ์ข้าวให้กับเกษตรกร เกษตรกรทำการปลูกหรือผลิตข้าวเปลือก หลังจากนั้นข้าวเปลือกจะถูกรวบรวมโดยผู้รวบรวมข้าว ในที่นี้หมายถึง พ่อค้าคนกลาง โรงสี ทำข้าว และสหกรณ์การเกษตร จากนั้นข้าวเปลือกจะถูกส่งไปแปรสภาพโดยโรงสีข้าวทำหน้าที่แปรรูปขั้นต้นจากข้าวเปลือกเป็นข้าวสาร ข้าวที่ผ่านการสีแล้วอาจจะต้องผ่านขั้นตอนการผสม เพื่อปรับปรุงคุณภาพข้าวสาร ซึ่งข้าวสารผสมจะมีหลายชนิด เช่น ข้าวหอมใบเตย เกิดจากข้าวรวมใหม่ผสมข้าว พล.4 ข้าวเหลืองอ่อน เกิดจาก ข้าวพล.4 ผสมกับข้าวรวมใหม่ ข้าวหอมประทุม และข้าวรวมใหม่โรงสี เป็นต้น หรืออาจมีการนำข้าวสารไปแปรรูปเป็นผลิตภัณฑ์ต่างๆ เช่น ข้าวหุงสุกสำเร็จรูป เป็นต้น จากนั้นจึงทำการบรรจุเพื่อส่งไปยังผู้ค้าส่ง ซึ่งมีทั้งผู้ค้าส่งในประเทศ และต่างประเทศ และจะส่งต่อแก่ผู้ขายปลีก เพื่อจำหน่ายให้ผู้ค้าปลีกต่อไป

ในแต่ละกิจกรรมของโซ่อุปทานข้าวของไทยอาจประสบกับปัญหาต่างๆ ไม่ว่าจะเป็นปัญหาทางด้านการเพาะปลูก ปัญหาทางด้านการขนส่ง และปัญหาด้านสินค้าคงคลัง เป็นต้น ซึ่งจะส่งผลกระทบต่อการดำเนินธุรกิจ ต้นทุนด้านสินค้าคงคลังคิดเป็น 26% ของต้นทุนรวมของกิจกรรมโลจิสติกส์ ดังรูปที่ 3 (สำนักโลจิสติกส์ กรมอุตสาหกรรมพื้นฐานและการเหมืองแร่ กระทรวงอุตสาหกรรม, 2555) สินค้าคงคลังประกอบด้วย วัตถุดิบ (Raw material) งานระหว่างทำ (Work-in-process) วัสดุซ่อมบำรุง (Maintenance/ Repair/ Operating supplies) และสินค้าสำเร็จรูป (Finished goods) ซึ่งก่อให้เกิดต้นทุนสินค้าคงคลัง (Inventory cost) ที่ประกอบด้วย ค่าใช้จ่ายในการสั่งซื้อ (Ordering cost) ค่าใช้จ่ายเนื่องจากสินค้าขาดแคลน (Shortage cost) ค่าใช้จ่ายในการตั้งเครื่องจักรใหม่ (Setup cost) และค่าใช้จ่ายในการเก็บรักษา (Carrying cost)

การเก็บรักษาข้าวเปลือกและข้าวสารมีผลต่อต้นทุนสินค้าคงคลัง ข้าวที่เก็บในคลังเพื่อรอการแปรรูป บรรจุ และจำหน่าย ต้องมีการควบคุมสภาพการเก็บรักษาที่ดีเพื่อไม่ให้เกิดความเสียหาย มีการควบคุมอุณหภูมิและความชื้นสัมพัทธ์เพื่อมิให้เกิดเชื้อรา มีการป้องกันอันตรายจากแมลงและสัตว์ที่เข้ามากัดแทะ เช่น หนู แมลงสาบ มอด นก เป็นต้น ในกรณีนี้ข้าวผ่านการสีแล้ว การจัดเก็บที่ไม่เหมาะสมจะมีผลต่อคุณภาพของข้าว เช่น มีกลิ่นเหม็นอับ ไม่หอม เม็ดข้าวเปลี่ยนเป็นสี หรือข้าวเปลี่ยนสภาพเป็นแป้ง ซึ่งข้าวบางส่วนที่ได้รับความเสียหายอาจจะก่อให้เกิดความเสียหายต่อข้าวทั้งหมด ต้นทุนสินค้าคงคลังจึงเพิ่มขึ้น อีกทั้ง ปริมาณข้าวที่จัดเก็บควรมีความสัมพันธ์กับความต้องการในการผลิตและความต้องการในการขาย ซึ่งมีความสัมพันธ์กับปริมาณความต้องการซื้อของผู้บริโภค ข้าวที่จัดเก็บให้อยู่ในปริมาณไม่มากจะช่วยประหยัดค่าใช้จ่ายด้านสินค้าคงคลัง แต่ต้นทุนการสั่งซื้อหรือต้นทุนการส่งผลิตจะสูงขึ้น และถ้าไม่สามารถจัดหาข้าวมาได้ทันความต้องการที่จะใช้ผลิตจะทำให้สายการผลิตหยุดชะงัก เกิดต้นทุนที่เกิดจากของขาดแคลน (Shortage cost) และสถานประกอบการอาจจะเสียโอกาสทางการขาย เช่น เสียยอดขาย เสียกำไรที่ควรจะได้ เสียค่าปรับในการส่งสินค้าล่าช้า หรือไม่มีสินค้าส่ง อีกทั้ง เกิดความสูญเสียที่ไม่สามารถคำนวณเป็นตัวเงินได้ เช่น การเสียชื่อเสียง ขาดความเชื่อถือจากลูกค้า หรือเสียลูกค้า เป็นต้น ในทางตรงกันข้าม ถ้าความต้องการซื้อของผู้บริโภคน้อยกว่าความต้องการขายของผู้ผลิต จะทำให้เกิดสต็อกสินค้าคงคลัง คิดเป็นค่าใช้จ่ายในการจัดการสินค้าคงคลัง ซึ่งค่าใช้จ่ายในการจัดเก็บสินค้าคงคลังสามารถคำนวณเป็นตัวเงินได้ เช่น ค่าแรงพนักงาน ค่าไฟฟ้าเพื่อการรักษาอุณหภูมิ ค่าความเสียหายจากข้าวที่มีคุณภาพลดลง เช่น ข้าวมีกลิ่น มอดกิน การแตกหักของเม็ดข้าว หรือข้าวหมดอายุ เนื่องจากการเก็บนานเกินไป

ปัญหาด้านสินค้าคงคลังสามารถแก้ไขได้ด้วยการพยากรณ์ยอดขายที่แม่นยำ ซึ่งส่งผลกระทบต่อวางแผนการผลิตที่มีประสิทธิภาพ การพยากรณ์จึงนับว่าเป็นจุดเริ่มต้นของการวางแผนการผลิตที่ดี ทำให้การกระบวนการผลิตเป็นไปอย่างราบรื่น ช่วยแก้ปัญหาสินค้าขาดมือ หรือปัญหาการผลิตในปริมาณที่มากเกินไปเกินความต้องการของลูกค้าได้ เพราะการพยากรณ์สามารถนำมาใช้ในการจัดสรรทรัพยากรต่างๆ ได้อย่างทั่วถึงและเหมาะสม ทั้งวางแผนการการจัดซื้อ บริหารแรงงาน กำหนดกำลังการผลิต การวางแผนผังกระบวนการการผลิต การจัดตารางการผลิตหลัก และการจัดการสินค้าคงคลังที่พิจารณาความสัมพันธ์ระหว่างความต้องการขายของผู้ผลิตกับความต้องการซื้อของผู้บริโภค ทำให้ต้นทุนสินค้าคงคลัง (Inventory cost) ลดลง

จากการทบทวนวรรณกรรมที่เกี่ยวข้องกับงานวิจัยข้าว ซึ่งสืบค้นจากฐานข้อมูล ISI Web of Science ณ วันที่ 13 ตุลาคม 2558 และสืบค้นข้อมูลจากศูนย์ดัชนีการอ้างอิงวารสารไทย (Thai-Journal Citation Index Center: TCI) เมื่อวันที่ 11 ธันวาคม 2558 พบว่า งานวิจัยข้าวสามารถพบได้ในเกือบทุกกิจกรรมของโซ่อุปทานของข้าว เช่น ในการผลิตข้าวของเกษตรกร เป็นการวิจัยเรื่อง การพยากรณ์ราคาข้าวเปลือกเจ้าหอมมะลิ 105 (วารางคณา กิรติวิบูลย์, 2558) หรือในส่วนของพ่อค้าที่เป็นผู้ค้าส่งต่างประเทศ เป็นการวิจัยตัวแบบพยากรณ์มูลค่าการส่งออกข้าวหอมมะลิ (วารางคณา กิรติวิบูลย์, 2557) เป็นต้น ซึ่งยังไม่มีงานวิจัยที่ทำการพยากรณ์ข้าวที่อยู่ในขั้นตอนของการแปรรูปข้าวเป็นข้าวผสม

วิธีการพยากรณ์ที่นิยมใช้ในงานวิจัยเกี่ยวกับข้าว นั่นคือ วิธีโครงข่ายประสาทเทียม (Artificial Neural Network: ANN) เนื่องจากข้อมูลด้านอุปสงค์และอุปทานในปัญหาการพยากรณ์ข้าวไม่มีความแน่นอน และไม่สามารถทำการคาดเดาได้ เพราะได้รับผลกระทบจากหลายปัจจัยในลักษณะที่ซับซ้อน วิธีโครงข่ายประสาทเทียม (ANN) จึงถูกนำมาใช้ในการแก้ปัญหา ลักษณะดังกล่าว (Co and Boosarawongse, 2007) ดังนั้น งานวิจัยนี้จึงทำการพยากรณ์ยอดขายผลิตภัณฑ์ข้าวผสมโดยการประยุกต์ใช้วิธีเมตาดิวริสติกส์ ซึ่งใช้วิธีโครงข่ายประสาทเทียม

### 1. วัตถุประสงค์ของโครงการวิจัย

เพื่อทำการพยากรณ์ยอดขายผลิตภัณฑ์ข้าวผสมโดยการประยุกต์ใช้วิธีเมตาดิวริสติกส์

### 2. ขอบเขตของโครงการวิจัย

- 2.1 ผลิตภัณฑ์ข้าวผสมที่ใช้การพยากรณ์ประกอบด้วย ข้าวรวมเก่า 5% ข้าวรวมใหม่ 5% ข้าวรวมใหม่ 25% แป้งยี่ม สีปล่อย หอมใบเตย หอมมะลิใหม่ และเหลืองอ่อน
- 2.2 ข้อมูลยอดขายจำหน่ายผลิตภัณฑ์ข้าวผสมเป็นรายเดือน
- 2.3 การพัฒนาโปรแกรมช่วยสนับสนุนการตัดสินใจใช้ภาษา Visual Basic for applications
- 2.4 วิธีเมตาดิวริสติกส์ที่ประยุกต์ใช้เพื่อการพยากรณ์คือ โครงข่ายประสาทเทียม (Artificial Neural Network: ANN)
- 2.5 การเปรียบเทียบประสิทธิภาพของโมเดลจากการพยากรณ์ด้วยวิธี ANN ใช้การคำนวณค่าเฉลี่ยของรากที่สองของกำลังสองของความคลาดเคลื่อน (Root Mean Square Error: RMSE)

### 3. วิธีการดำเนินงานวิจัย

3.1 ศึกษารายละเอียดผลิตภัณฑ์ข้าวผสม การผลิต การเก็บรักษา และการจำหน่ายของสถานประกอบการแห่งหนึ่งในจังหวัดพิจิตร

3.2 เก็บข้อมูลเพื่อทำการคัดเลือกผลิตภัณฑ์ข้าวผสม

ผลิตภัณฑ์ข้าวที่นำมาใช้ในการวิเคราะห์ทำการคัดเลือกข้าวจากการนำปริมาณข้าว (กิโลกรัม) ที่ขายได้รายปี สำหรับปี พ.ศ. 2555 2556 และ 2557 มาทำแผนภูมิพาราโตของแต่ละปี และเลือกผลิตภัณฑ์ข้าวผสมในแต่ละปี ที่มียอดขายสะสมเกินร้อยละ 90 จึงได้ผลิตภัณฑ์ข้าวผสมที่ใช้การพยากรณ์ประกอบด้วย ข้าวรวมเก่า 5% ข้าวรวมใหม่ 5% ข้าวรวมใหม่ 25% แป้งยี่ม สีปล่อย หอมใบเตย หอมมะลิใหม่ และเหลืองอ่อน

3.3 วิเคราะห์และออกแบบแฟ้มข้อมูลนำเข้า (Input files)

ข้อมูลนำเข้าสำหรับการพยากรณ์ได้มาจากการทบทวนวรรณกรรมของงานวิจัยที่เกี่ยวข้องกับการพยากรณ์ ยอดจำหน่ายข้าวเพื่อการส่งออก (Co and Boosarawongse, 2007) ข้อมูลนำเข้าเพื่อการพยากรณ์ด้วยวิธี ANN จึงประกอบด้วย

- 3.3.1 ค่าสัมบูรณ์ของความแตกต่างของยอดขายฤดูกาลปัจจุบันและฤดูกาลก่อนหน้า
- 3.3.2 สัญลักษณ์ความแตกต่างของยอดขายฤดูกาลปัจจุบันและฤดูกาลก่อนหน้า
- 3.3.3 ค่าสัมบูรณ์ของความแตกต่างยอดขายรายเดือนระหว่างปีปัจจุบันและปีก่อนหน้า
- 3.3.4 สัญลักษณ์ความแตกต่างยอดขายรายเดือนระหว่างปีปัจจุบันและปีก่อนหน้า
- 3.3.5 ค่าสัมบูรณ์ของความแตกต่างของฤดูกาลปีปัจจุบันและปีก่อนหน้า
- 3.3.6 สัญลักษณ์ความแตกต่างของฤดูกาลปีปัจจุบันและปีก่อนหน้า
- 3.3.7 ดัชนีฤดูกาล (Seasonal Index)
- 3.3.8 ค่าสัมบูรณ์ของความแตกต่างของเดือนปัจจุบันและเดือนก่อน
- 3.3.9 สัญลักษณ์ความแตกต่างของเดือนปัจจุบันและเดือนก่อน
- 3.3.10 ยอดขาย

3.3 วิเคราะห์และออกแบบแฟ้มข้อมูลขาออก โดยแฟ้มข้อมูลขาออกประกอบด้วย ชนิดข้าวที่ใช้ในการพยากรณ์ ค่า ANN ของชุดฝึกฝน จำนวนรอบในการวนที่ให้ ค่า RMSE ของชุดฝึกฝนน้อยที่สุด ค่า RMSE ของชุดทดสอบ ค่า ANN ของชุดทดสอบ และผลของการพยากรณ์ของผลิตภัณฑ์ที่ได้จากโปรแกรม

3.4 ประยุกต์ใช้วิธี ANN ในการพยากรณ์ยอดขายผลิตภัณฑ์ข้าวผสมด้วยภาษา Visual Basic for applications ซึ่งมีลำดับการทำงานดังรูปที่ 1.1 และอธิบายได้ดังนี้



3.4.1 กำหนดค่าพารามิเตอร์ ได้แก่ จำนวนโหนดในชั้นซ่อน (Hidden) กำหนดจำนวนรอบสูงสุดในการเรียนรู้เบื้องต้น (ParaMT\_5) กำหนดค่า Momentum (ParaMT\_4) ค่าพารามิเตอร์ของอัตราการเรียนรู้ (ParaMT\_3)

3.4.2 รับค่าข้อมูลป้อนเข้าของข้อมูลชุดแรก (ข้อมูลที่ใช้ในการฝึกฝน) ในที่นี้หมายถึง ข้อมูล 10 ข้อมูล ของเดือนมกราคม ปี 2555 ถึง ธันวาคม 2556

3.4.3 สุ่มค่าน้ำหนักของแต่ละเส้นจากโหนด Input ไป Hidden

3.4.4 ทำการคูณค่าเส้นน้ำหนักกับข้อมูลนำเข้า แล้วทำการรวมผลคูณที่ได้ทุกเส้นน้ำหนักของแต่ละโหนด Hidden

3.4.5 เข้าสู่ฟังก์ชันการแปลงค่า จะได้ผลลัพธ์ของโหนดชั้น Hidden

3.4.6 สุ่มค่าน้ำหนักของแต่ละเส้นจาก โหนด Hidden ไป โหนด Output

3.4.7 ทำการคูณค่าเส้นน้ำหนักกับผลลัพธ์ของโหนด Hidden แล้วทำการรวมผลคูณที่ได้ทุกเส้นน้ำหนักของแต่ละโหนด Output

3.4.8 เข้าสู่ฟังก์ชันการแปลงค่า จะได้ผลลัพธ์ของโหนดชั้น Output

3.4.9 ประเมินค่าที่ยอมรับได้ โดยพิจารณาจากค่า RMSE ในกรณีที่ค่า RMSE ที่คำนวณได้น้อยกว่าค่า RMSE ที่กำหนดไว้ จะหลุดจากเงื่อนไขการเรียนรู้ และนำไปใช้ไปกับชุดทดสอบต่อไป อีกกรณีคือ ค่า RMSE ที่คำนวณได้มากกว่าค่า RMSE ที่กำหนดจะไปขั้นตอนที่ 3.4.10

3.4.10 เช็คว่าจำนวนรอบตามที่กำหนด หากวนจนถึงรอบที่กำหนดแล้ว จะทำการเก็บค่า RMSE ที่น้อยที่สุดเพื่อนำไปใช้ไปกับชุดทดสอบต่อไป หากยังไม่ถึงรอบที่กำหนด จะทำการปรับเส้นค่าน้ำหนัก

3.4.11 ทำการปรับเส้นน้ำหนักทุกเส้น

3.4.12 นำเส้นน้ำหนักที่ทำการปรับได้มาใช้กับชุดฝึกฝน ทำการหาค่า RMSE และทำตั้งแต่ข้อ 3.4.9 -

3.4.12 จนกว่าจะหลุดจากเงื่อนไขที่ตั้งไว้ แล้วจึงนำค่าเส้นน้ำหนักที่ดีที่สุดไปใช้กับข้อมูลชุดทดสอบ เพื่อใช้งานจริงต่อไป

3.5 การเปรียบเทียบมูลค่าการสูญเสียโอกาสในการขายผลิตภัณฑ์ข้าวของสถานประกอบการก่อนและหลังจากใช้โปรแกรมช่วยการพยากรณ์ โดยมีวิธีการเปรียบเทียบโดยนำปริมาณยอดขายของข้าวผสมจริงเทียบกับผลการพยากรณ์

#### 4. ผลการวิจัย

โปรแกรมที่ใช้ในการพยากรณ์ยอดขายผลิตภัณฑ์ข้าวผสมด้วยวิธี ANN โดยใช้ภาษา Visual Basic for applications ได้ออกแบบให้มีลักษณะดังนี้

4.1 หน้าจอแรกของโปรแกรม ได้ทำการออกแบบโดยกรรมมีฟังก์ชัน รายการขายผลิตภัณฑ์รายเดือน ซึ่งสามารถเรียกดูยอดขายแต่ละเดือนได้ และฟังก์ชันพยากรณ์

4.2 การนำเข้าของแฟ้มข้อมูล การคัดเลือกผลิตภัณฑ์ข้าวที่นำมาใช้ในการวิเคราะห์ จะทำการคัดเลือกข้าวจากการนำปริมาณข้าว (กิโลกรัม) ที่ขายได้รายปี สำหรับปี 2555, 2556, และ 2557 มาทำแผนภูมิพาราโดของแต่ละปี และเลือกผลิตภัณฑ์ข้าวในแต่ละปี ที่อยู่ในร้อยละสะสม 90 ของปริมาณข้าว (กิโลกรัม) ที่ขายได้ทั้งหมด ทำให้ได้ผลิตภัณฑ์ข้าว 11 ชนิด ประกอบไปด้วย ข้าวรวมใหม่5%(เก่า) ข้าวรวมใหม่5% แป้งอ้อย เหลืองอ่อน หอมมะลิ ข้าวรวมใหม่25% สีปล่อย หอมมะลิใหม่ หอมใบเตย หอมมะลิโรงสี และเม็ดเหลือง และเนื่องจากงานวิจัยนี้ได้ทำการศึกษาข้าวผสม สัดส่วนการผสมของผลิตภัณฑ์ที่นำมาใช้ในการศึกษา จึงเหลือข้าวที่ทำการศึกษา 8 ชนิด ดังนี้ ข้าวรวมใหม่5%(เก่า) ข้าวรวมใหม่5% แป้งอ้อย เหลืองอ่อน ข้าวรวมใหม่25% สีปล่อย หอมมะลิใหม่ และหอมใบเตย

4.3 การกำหนดค่าพารามิเตอร์ โดยผู้ใช้งานโปรแกรม ค่าพารามิเตอร์ที่ใช้ในการคำนวณ ของวิธี ANN เพื่อให้ได้ค่าที่เหมาะสมที่สุด จะประกอบอัตราการเรียนรู้ Momentum และจำนวนรอบในวนเพื่อเรียนรู้

4.4 การแสดงผลลัพธ์ ออกแบบให้สามารถแสดงผล ค่า ANN ของชุดฝึกฝน ค่า ANN ของชุดทดสอบ ค่าการพยากรณ์ จำนวนรอบวนการวนที่ดีที่สุด ค่า RMSE ของชุดฝึกฝน และค่า RMSE ของชุดทดสอบ

```

Input problem dataset and Set parameters (Henden, ParaMT_3, ParaMT_4, ParaMT_5)
For jy = 1 To dataset
  For Firtloop = 1 To Hidden
    For i = 1 To inputdata
      InData(i) = inputdata
    Next i
    For Secondloop = 1 To inputdata
      If jy = 1 Then
        Wj = (Int((1001 - 1 + 1) * Rnd() + 1) / 1000) - 0.501
      End If
      N = N + (Wj * InData(Secondloop))
    Next Secondloop
    nT(Firtloop) = 1 / (1 + (e-Uvj))
  Next Firtloop
  For Thirdloop = 1 To 'Hidden
    If jy = 1 Then
      Wjk = (Int((1001 - 1 + 1) * Rnd() + 1) / 1000) - 0.501
    End If
    NN = NN + (Wjk * nT(Thirdloop))
  Next Thirdloop
  If jy = 1 Then
    WjkB = (Int((1001 - 1 + 1) * Rnd() + 1) / 1000) - 0.501
    BasiH = 1 * WjkB
  End If
  Ujk = NN + BasiH
  nY(jy) = 1 / (1 + (e-Ujk))
Next jy
RMSE = Sqr((1 / Nb) * SumQF2)
While iRMSE = 1
  count_iRMSE = count_iRMSE + 1
  If RMSE > 0.2 Then
    For jy = 1 To 1 To dataset
      SoK = OoK * (1 - OoK) * (ToK - OoK)
      For Firtloop = 1 To Hinden
        For i = 1 To input data
          InData(i) = input data
        Next i 'end 1
        For Secondloop = 1 To input data
          DWij_new = (ParaMT_3 * SSj_12 * Ool) + (ParaMT_4 * DWij)
        Next Secondloop
        Next Firtloop
        For Thirdloop = 1 To Henden
          DWkj_new = (ParaMT_3 * SoKk * OoJ) + (ParaMT_4 * DWkj))
        End If
        Next Thirdloop
        DWkjB_new = (ParaMT_3 * SoKk * 1) + (ParaMT_4 * DWkjB)
        End If
      Next jy
      Wij_new = Weightj + SumWj
      Wjk = Weightk + SumWkj05
      WjkB_new = Weightg + SumWkjB
    Elseif RMSE < 0.2 Then
      iRMSE = 0
    Elseif RMSE = 0.2 Then
      iRMSE = 0
    End If
    If count_iRMSE = ParaMT_5 Then
      iRMSE = 0
    End If
  Wend
Output the best solution

```

รูปที่ 1.1 ขั้นตอนการทำงานของการทำงานของพยากรณ์ยอดขายผลิตภัณฑ์ข้าวผสมด้วยวิธี ANN

#### 4.5 ผลการวิเคราะห์ด้านมูลค่าการสูญเสียโอกาสในการขายผลิตภัณฑ์ข้าวผสม มี 2 กรณีคือ

4.5.1 ค่าพยากรณ์โดยจากการคาดคะเนของทางสถานประกอบการซึ่งได้จากการประมาณจากยอดขายเดือนที่แล้ว คือ 100,000 กิโลกรัม ค่าพยากรณ์ยอดขายด้วยวิธี ANN คือ 120,548 กิโลกรัม ซึ่งยอดขายจริงเท่ากับ 130,540 กิโลกรัม จึงพบว่า ค่าพยากรณ์ยอดขายด้วยวิธี ANN สามารถช่วยลดมูลค่าการสูญเสียโอกาสในการขายผลิตภัณฑ์ข้าวผสมได้ ดังนี้

ค่าการสูญเสียโอกาสในการขายผลิตภัณฑ์ข้าวผสมจากการพยากรณ์ด้วยวิธี ANN

$$= 130,540 - 120,548 = 9,992 \text{ กิโลกรัม}$$

ค่าการสูญเสียโอกาสในการขายผลิตภัณฑ์ข้าวผสมจากการคาดคะเนของทางสถานประกอบการ

$$= 130,540 - 100,000 = 30,540 \text{ กิโลกรัม}$$

4.5.2 ค่าพยากรณ์โดยจากการคาดคะเนของทางสถานประกอบการซึ่งได้จากการประมาณจากยอดขายเดือนที่แล้ว คือ 88,065 กิโลกรัม ค่าพยากรณ์ยอดขายด้วยวิธี ANN คือ 36,295 กิโลกรัม ซึ่งยอดขายจริงเท่ากับ 28,069 กิโลกรัม จึงไม่เกิดการสูญเสียโอกาสในการขายผลิตภัณฑ์ข้าวผสม แต่การพยากรณ์ยอดขายด้วยวิธี ANN สามารถช่วยลดปริมาณของสินค้าคงคลังได้ ดังนี้

$$\text{ปริมาณของสินค้าคงคลังจากการพยากรณ์ด้วยวิธี ANN} = 36,295 - 28,069 = 8,226 \text{ กิโลกรัม}$$

$$\text{ปริมาณของสินค้าคงคลังจากการคาดคะเนของทางสถานประกอบการ} = 88,065 - 28,069$$

$$= 59,996 \text{ กิโลกรัม}$$

#### 5. สรุปผลการวิจัย

งานวิจัยนี้ทำการพัฒนาโปรแกรมช่วยการพยากรณ์ยอดขายผลิตภัณฑ์ข้าวผสม โดยการประยุกต์ใช้วิธีเมตาฮิวริสติกส์ คือ โครงข่ายประสาทเทียม (Artificial Neural Network: ANN) ซึ่งพบว่า ค่าพยากรณ์ที่ได้จากวิธี ANN ให้ค่า RMSE น้อยกว่า 0.2 นั่นคือ โมเดลของการพยากรณ์ด้วยวิธี ANN มีความแม่นยำอยู่ที่ร้อยละ 80 ซึ่งสามารถนำไปสู่การลดมูลค่าการสูญเสียโอกาสในการขายผลิตภัณฑ์ข้าวผสม ลดปริมาณสินค้าคงคลัง และช่วยในการวางแผนการผลิต โดยในปัจจุบันทางสถานประกอบการไม่มีการใช้เทคนิคการพยากรณ์เข้ามาช่วยในการวางแผนการผลิต ปริมาณผลิตได้มาจากการคาดคะเนตามประสบการณ์ของผู้วางแผนการผลิต ซึ่งอาจทำให้ปริมาณผลผลิตที่ได้นั้นเกินปริมาณความต้องการจริงของลูกค้า ทำให้เกิดปริมาณสินค้าคงคลังมากเกินไป ในทางตรงกันข้าม การประมาณการปริมาณการผลิตมีค่าน้อยกว่าความต้องการจริง อาจก่อให้เกิดการสูญเสียโอกาสในการขายผลิตภัณฑ์ได้ อย่างไรก็ตาม ค่าพยากรณ์สามารถมีค่าคลาดเคลื่อนจากปริมาณความต้องการจริงของลูกค้าได้ แต่จะช่วยลดความรุนแรงของผลกระทบที่จะเกิดขึ้นกับสถานประกอบการได้

## ส่วนที่ 2: เนื้อหางานวิจัย

### 1. ความสำคัญและที่มาของปัญหา

ประเทศไทยเป็นประเทศเกษตรกรรม โดยสภาพพื้นที่และภูมิอากาศเหมาะสมแก่การทำเกษตรกรรม จากข้อมูลของสำนักงานเศรษฐกิจการเกษตร กระทรวงเกษตรและสหกรณ์ ปี 2556 (ผลสำรวจเบื้องต้น วันที่ 21 ม.ค.2558) พบว่าประเทศไทยมีเนื้อทั้งหมด 320,696,888 ไร่ เป็นเนื้อที่ป่าไม้ 102,119,540 ไร่ เนื้อที่ใช้ประโยชน์นอกการเกษตร 69,341,116 ไร่ และใช้ทางการเกษตร 149,236,233 ไร่ คิดเป็นร้อยละ 46.53 ของเนื้อที่เป็นประเทศไทยทั้งหมด ดังตารางที่ 2.1 และมีประชาชนส่วนใหญ่เป็นเกษตรกรกว่าครึ่งประเทศ (34 ล้านคน) คิดเป็นร้อยละ 55.7 ของประชากรทั้งประเทศ (กรมส่งเสริมการเกษตร กระทรวงเกษตรและสหกรณ์, 2546) ซึ่งแสดงให้เห็นว่าการเกษตรนั้นมีความสำคัญต่อเศรษฐกิจของประเทศไทย และทำให้ไทยมีความสามารถพึ่งพาตนเองทางด้านอาหารได้ และจากข้อมูลผลิตภัณฑ์มวลรวมในประเทศ (Gross domestic product: GDP) ไตรมาสที่ 2 ของปี 2559 พบว่าการผลิตนอกภาคเกษตรมีการขยายตัวร้อยละ 3.7 ส่วนการผลิตภาคเกษตรมีค่า GDP หดตัวร้อยละ 0.1ปรับตัวดีขึ้นจากที่หดตัวร้อยละ 1.4 ในไตรมาสที่ 1/2559 (สำนักงานคณะกรรมการพัฒนาการเศรษฐกิจและสังคมแห่งชาติ, 2559) และมีอัตราการขยายตัวของผลิตภัณฑ์มวลรวม (Gross domestic product: GDP) ในประเทศมูลค่าที่แท้จริง (ร้อยละ) ดังตารางที่ 2.2 ถ้าพิจารณาในทุกไตรมาสของปี 2558 และ 2559 ภาคการเกษตรมีอัตราการขยายตัว/หดตัวของค่า GDP ในแต่ละไตรมาสสูงกว่าภาคนอกเกษตร

ตาราง 2.1 เนื้อที่ใช้ประโยชน์ทางการเกษตร ปี พ.ศ. 2556 (ผลสำรวจเบื้องต้น วันที่ 21 ม.ค. 2558) หน่วย: ไร่

ภาค	เนื้อที่ในประเทศไทย			เนื้อที่การใช้ประโยชน์ทางการเกษตร					เนื้อที่ใช้ประโยชน์นอกการเกษตร
	ทั้งหมด	ป่าไม้	เกษตร	นาข้าว	พืชไร่	ผลไม้อื่นต้นไม่ประดับ	ตึก ไม้ดอก/ไม้ประดับ	อื่นๆ	
รวมทั้งประเทศ	320,696,888	102,119,540	149,236,233	69,964,862	31,154,000	34,915,274	1,398,383	11,803,714	69,341,116
เหนือ	106,027,680	56,283,599	32,489,678	15,787,615	10,196,289	4,045,517	446,942	2,013,314	17,254,403
ตะวันออกเฉียงเหนือ	105,533,963	15,813,932	63,847,741	42,752,421	11,940,928	4,315,585	317,327	4,521,479	25,872,290
กลาง	64,938,253	18,971,661	31,130,407	10,200,891	9,006,395	7,394,041	506,833	4,022,248	14,836,185
ใต้	44,196,992	11,050,348							11,378,236

ที่มา: สำนักงานเศรษฐกิจการเกษตร กระทรวงเกษตรและสหกรณ์, 2556

ตาราง 2.2 อัตราการขยายตัวของผลิตภัณฑ์มวลรวมในประเทศมูลค่าที่แท้จริง (ร้อยละ)

	2558				2559	
	Q1	Q2	Q3	Q4	Q1	Q2
ภาคเกษตร	-4.6	-4.1	-5.5	-2.1	-1.4	-0.1
ภาคนอกเกษตร	3.9	3.2	3.2	4.0	3.7	3.7

หมายเหตุ: เมื่อ Q หมายถึง ไตรมาส

ที่มา: สำนักงานคณะกรรมการพัฒนาการเศรษฐกิจและสังคมแห่งชาติ, 2555

การปรับลดลงและเพิ่มขึ้นเป็นผลกระทบมาจากหลายปัจจัย เช่น สภาวะเศรษฐกิจโลก คู่แข่งทางการตลาด เป็นต้น ทำให้ผู้ประกอบการทางภาคเกษตรต้องมีการปรับตัว มีการวางแผนมีการวางแผนทั้งด้านการตลาด การจัดหาวัตถุดิบ การผลิต และการจัดการสินค้าคงคลังที่มีประสิทธิภาพ มีการเตรียมพร้อมรับมือกับการสภาพแวดล้อมการผลิตที่มีการเปลี่ยนแปลงในอนาคตตลอดเวลา หากผู้ประกอบการทางภาคเกษตรไม่มีการเตรียมความพร้อม ในการวางแผนการจัดการของคงคลังที่ดี อาจส่งผลต่อต้นทุนการผลิต การกำหนดราคาขายผลิตภัณฑ์ และผลประกอบการของสถานประกอบการ เนื่องจากสินค้าทางเกษตรนั้นเป็นสินค้าที่มีข้อจำกัดทางด้านอายุของผลิตภัณฑ์ บางชนิดนั้นมีอายุเก็บได้นานเป็นปี บางชนิดเก็บได้เป็นเดือน หรือบางชนิดอาจมีอายุการเก็บได้เพียงหนึ่งถึงสองวัน ดังนั้น หากไม่มีการวางแผนวางแผนการจัดการของคงคลังที่ดี อาจทำให้คุณภาพของสินค้ามีการเปลี่ยนแปลง ซึ่งจะส่งผลต่อราคาขาย และชื่อเสียง ความน่าเชื่อถือของผู้ประกอบการ

ข้าวเป็นพืชเศรษฐกิจที่สำคัญของประเทศไทย เป็นสินค้าเกษตรกรรมหลักของประเทศไทยเพื่อจำหน่ายในประเทศและส่งออกต่างประเทศของประเทศไทย เนื่องจากการใช้ประโยชน์ทางการเกษตรของประเทศไทยในการทำนาข้าวมีจำนวนมากที่สุด คือ 69,964,862 ไร่ คิดเป็นร้อยละ 46.88 ของเนื้อที่ทางการเกษตรทั้งหมด (สำนักงานเศรษฐกิจการเกษตร กระทรวงเกษตรและสหกรณ์, 2556) และจากข้อมูลธนาคารแห่งประเทศไทย ในปี 2557 พบว่าข้าวเป็นสินค้าเกษตรที่มีปริมาณการส่งออกเป็นอันดับหนึ่งของสินค้าเกษตรกรรมทั้งหมดคือ 10.9 ล้านเมตริกตัน คิดเป็นมูลค่าการส่งออก 5,438 ล้านดอลลาร์สหรัฐ ดังตารางที่ 2.3 และประเทศไทยได้ทำการส่งออกข้าวเป็นอันดับ 1 ของโลก ดังตารางที่ 2.4 (กระทรวงเกษตรและสหกรณ์, 2558) เมื่อพิจารณาการส่งออกทั้งในเชิงปริมาณและมูลค่าการส่งออกข้าวของไทย ปี 2553-2558 (สำนักวิจัยเศรษฐกิจการเกษตร, 2557) พบว่า การส่งออกมีการเปลี่ยนแปลงทั้งเพิ่มขึ้นและลดลงเช่นกันตามสภาวะเศรษฐกิจ ซึ่งปริมาณการส่งออกข้าวที่เปลี่ยนแปลงอาจมีผลมาจากปริมาณอุปทานหรือปริมาณผลผลิตข้าว และปริมาณอุปสงค์หรือปริมาณความต้องการข้าวภายในประเทศ ในปี 2553-2557 (สำนักวิจัยเศรษฐกิจการเกษตร, 2557) ปริมาณความต้องการข้าวในประเทศลดลงจาก 17.79 ล้านตันข้าวเปลือกในปี 2553 เหลือ 16.32 ล้านตันข้าวเปลือกในปี 2557 หรือลดลงร้อยละ 1.56 ต่อปี และในปี 2557 ข้าวที่ใช้ในประเทศมีปริมาณ 16.32 ล้านตันข้าวเปลือก ลดลงจาก 16.53 ล้านตันข้าวเปลือกในปี 2556 หรือลดลงร้อยละ 1.27 เนื่องจากความต้องการใช้ข้าวเพื่อบริโภค ทำเมล็ดพันธุ์ และผลิตอาหารสัตว์มีแนวโน้มลดลง จึงต้องส่งเสริมการส่งออกข้าวให้มีปริมาณเพิ่มขึ้น อย่างไรก็ตาม มูลค่าการส่งออกข้าวหดตัวลงเนื่องจากการชะลอตัวของอุปสงค์โลก และราคาข้าวไทยที่อยู่ในระดับที่สูงกว่าคู่แข่ง โดยเฉพาะอย่างยิ่งเวียดนาม (สำนักยุทธศาสตร์และการวางแผนเศรษฐกิจมหภาค, 2558) จากข้างต้นผู้ประกอบการผลิตภัณฑ์ข้าวควรมีการวางแผนการประกอบกิจการเพื่อรองรับต่อสถานการณ์ที่อาจส่งผลกระทบต่อสภาพการแข่งขันทางธุรกิจข้าว ซึ่งการลดต้นทุนการดำเนินงานกิจกรรมในโซ่อุปทานข้าวมีส่วนช่วยเพิ่มความสามารถการแข่งขันทางราคาขายของผลิตภัณฑ์ข้าว และเพิ่มโอกาสการแข่งขัน

ตาราง 2.3 ปริมาณสินค้าส่งออกจำแนกตามกิจกรรมการผลิต ปี 2557

สินค้าเกษตร	มูลค่า (ล้านดอลลาร์สหรัฐ)	ปริมาณ (เมตริกตัน)
1. ข้าว	5,438.69	10,969,370.45
2. ยาง	6,021.54	3,409,387.42
3. มันสำปะหลัง	2,812.68	9,821,768.36
4. ผลไม้	1,205.24	1,397,053.29
5. สินค้ากิจกรรมอื่นๆ		1,574.97
6. ผลิตภัณฑ์จากสัตว์		919.66

หมายเหตุ: 1 เมตริกตัน (ตัน) เท่ากับ 1,000 กิโลกรัม

ที่มา: ธนาคารแห่งประเทศไทย, 2557

ตาราง 2.4 ปริมาณการส่งออกข้าวข้าวของโลก หน่วย: 1, 000 เมตริกตันข้าวสาลี

ประเทศ	2554/55	2555/56	2556/57	2557/58*	2558/59*	% เปลี่ยนแปลง จากปีที่แล้ว
ไทย	6,945	6,722	10,969	9,000	10,200	13.33
อินเดีย	10,250	10,480	10,907	11,500	9,500	-17.39
เวียดนาม	7,717	6,700	6,325	6,200	7,000	12.90
ปากีสถาน	3,399	4,126	3,600	4,000	4,000	0.00
สหรัฐอเมริกา	3,298	3,295	2,998	3,350	3,250	-2.99
เมียนมาร์	1,357	1,163	1,688	2,000	1,800	-10.00
กัมพูชา	900	1,075	1,000	1,100	1,000	-9.09
อูรุกวัย	1,056	939	957	950	950	0.00
บราซิล	1,105	830	850	800	800	0.00

หมายเหตุ : ปี 2557/58 = ประเมินเบื้องต้น, ปี 2558/59 = พยากรณ์, เมื่อ 1 เมตริกตัน เท่ากับ 1, 000 กิโลกรัม (ตัน)

ที่มา: กระทรวงเกษตรและสหกรณ์, 2558

โซ่อุปทานข้าวประกอบด้วยกิจกรรมหลายกิจกรรม กิจกรรมในโซ่อุปทาน (Supply chain) จะแปรสภาพทรัพยากรธรรมชาติ วัตถุดิบ และวัสดุอื่นๆ ให้กลายเป็นสินค้าสำเร็จ แล้วส่งไปจนถึงลูกค้าคนสุดท้าย (ผู้บริโภค) โดยเริ่มจากผู้จำหน่ายเมล็ดพันธุ์ข้าวทำการขายพันธุ์ข้าวให้กับเกษตรกร เกษตรกรทำการปลูกหรือผลิตข้าวเปลือก หลังจากนั้น ข้าวเปลือกจะถูกรวบรวมโดยผู้รวบรวมข้าว ในที่นี้หมายถึง พ่อค้าคนกลาง โรงสี ทำข้าว และสหกรณ์การเกษตร จากนั้นข้าวเปลือกจะถูกส่งไปแปรสภาพโดยโรงสีข้าวทำหน้าที่แปรรูปขั้นต้นจากข้าวเปลือกเป็นข้าวสาร ข้าวที่ผ่านการสีแล้วอาจจะต้องผ่านขั้นตอนการผสมเพื่อปรับปรุงคุณภาพข้าวสาร ซึ่งข้าวสารผสมจะมีหลายชนิด เช่น ข้าวหอมใบเตย เกิดจากข้าวรวมใหม่ผสมข้าว พล.4 ข้าวเหลืองอ่อน เกิดจาก ข้าวพล.4 ผสมกับข้าวรวมใหม่ ข้าวหอมประทูม และข้าวรวมใหม่โรงสี เป็นต้น หรืออาจมีการนำข้าวสารไปแปรรูปเป็นผลิตภัณฑ์ต่างๆ เช่น ข้าวหุงสุกสำเร็จรูป เป็นต้น จากนั้นจึงทำการบรรจุเพื่อส่งไปยังผู้ค้าส่ง ซึ่งมีทั้งผู้ค้าส่งในประเทศและต่างประเทศ และจะส่งต่อแก่ผู้ขายปลีก เพื่อจำหน่ายให้ผู้ค้าปลีกต่อไป

ในแต่ละกิจกรรมของโซ่อุปทานข้าวของไทยอาจประสบกับปัญหาด้านต่างๆ ไม่ว่าจะเป็นปัญหาทางด้านการเพาะปลูก ปัญหาทางด้านการขนส่ง และปัญหาด้านสินค้าคงคลัง เป็นต้น ซึ่งจะส่งผลกระทบต่อการดำเนินธุรกิจ ต้นทุนด้านสินค้าคงคลังคิดเป็น 26% ของต้นทุนรวมของกิจกรรมโลจิสติกส์ ดังรูปที่ 3 (สำนักโลจิสติกส์ กรมอุตสาหกรรมพื้นฐานและการเหมืองแร่ กระทรวงอุตสาหกรรม, 2555) สินค้าคงคลังประกอบด้วย วัตถุดิบ (Raw material) งานระหว่างทำ (Work-in-process) วัสดุซ่อมบำรุง (Maintenance/ Repair/ Operating supplies) และสินค้าสำเร็จรูป (Finished goods) ซึ่งก่อให้เกิดต้นทุนสินค้าคงคลัง (Inventory cost) ที่ประกอบด้วย ค่าใช้จ่ายในการสั่งซื้อ (Ordering cost) ค่าใช้จ่ายเนื่องจากสินค้าขาดแคลน (Shortage cost) ค่าใช้จ่ายในการตั้งเครื่องจักรใหม่ (Setup cost) และค่าใช้จ่ายในการเก็บรักษา (Carrying cost)

การเก็บรักษาข้าวเปลือกและข้าวสารมีผลต่อต้นทุนสินค้าคงคลัง ข้าวที่เก็บในคลังเพื่อรอการแปรรูป บรรจุ และจำหน่าย ต้องมีการควบคุมสภาพการเก็บรักษาที่ดีเพื่อไม่ให้เกิดความเสียหาย มีการควบคุมอุณหภูมิและความชื้นสัมพัทธ์เพื่อมิให้เกิดเชื้อรา มีการป้องกันอันตรายจากแมลงและสัตว์ที่เข้ามากัดแทะ เช่น หนู แมลงสาบ มอด นก เป็นต้น ในกรณีที่ข้าวผ่านการสีแล้ว การจัดเก็บที่ไม่เหมาะสมจะมีผลต่อคุณภาพของข้าว เช่น มีกลิ่นเหม็นอับ ไม่หอม เม็ดข้าวเปลี่ยนเป็นสี หรือข้าวเปลี่ยนสภาพเป็นแฉ่ง ซึ่งข้าวบางส่วนที่ได้รับความเสียหายอาจจะก่อให้เกิดความเสียหายต่อข้าวทั้งหมด ต้นทุนสินค้าคงคลังจึงเพิ่มขึ้น อีกทั้ง ปริมาณข้าวที่จัดเก็บควรมีความสมดุลกับความต้องการในการผลิตและความต้องการในการขาย ซึ่งมีความสัมพันธ์กับปริมาณความต้องการซื้อของผู้บริโภค ข้าวที่จัดเก็บให้อยู่ในปริมาณไม่มากจะช่วยประหยัดค่าใช้จ่ายด้านสินค้าคงคลัง แต่ต้นทุนการสั่งซื้อหรือต้นทุนการผลิตจะสูงขึ้น และถ้าไม่สามารถจัดหาข้าวมาได้ตามความต้องการที่จะใช้ผลิตจะทำให้สายการผลิตหยุดชะงัก เกิดต้นทุนที่เกิดจากของขาดแคลน (Shortage cost) และสถานประกอบการอาจจะเสียโอกาสทางการขาย เช่น เสียยอดขาย เสียกำไรที่ควรจะได้ เสียค่าปรับในการส่งสินค้าล่าช้า หรือไม่มีสินค้าส่ง อีกทั้ง เกิดความสูญเสียที่ไม่สามารถคำนวณเป็นตัวเงินได้ เช่น การเสียชื่อเสียง ขาดความเชื่อถือจากลูกค้า หรือเสียลูกค้า เป็นต้น ในทางตรงกันข้าม ถ้าความต้องการซื้อของผู้บริโภคน้อยกว่าความต้องการขายของผู้ผลิต จะทำให้เกิดสต็อกสินค้าคงคลัง คิดเป็นค่าใช้จ่ายในการจัดการสินค้าคงคลัง ซึ่งค่าใช้จ่ายในการจัดเก็บสินค้าคงคลังสามารถคำนวณเป็นตัวเงินได้ เช่น ค่าแรงพนักงาน ค่าไฟฟ้าเพื่อการรักษาอุณหภูมิ ค่าความเสียหายจากข้าวที่มีคุณภาพลดลง เช่น ข้าวมีกลิ่น มอดกิน การแตกหักของเม็ดข้าว หรือข้าวหมดอายุเนื่องจากการเก็บนานเกินไป

ปัญหาด้านสินค้าคงคลังสามารถแก้ไขได้ด้วยการพยากรณ์ยอดขายที่แม่นยำ ซึ่งส่งผลกระทบต่อวางแผนการผลิตที่มีประสิทธิภาพ การพยากรณ์จึงนับว่าเป็นจุดเริ่มต้นของการวางแผนการผลิตที่ดี ทำให้การกระบวนการผลิตเป็นไปอย่างราบรื่น ช่วยแก้ปัญหาสินค้าขาดมือ หรือปัญหาการผลิตในปริมาณที่มากเกินไปเกินความต้องการของลูกค้าได้ เพราะการพยากรณ์สามารถนำมาใช้ในการจัดสรรทรัพยากรต่างๆ ได้อย่างทั่วถึงและเหมาะสม ทั้งวางแผนการการจัดซื้อ บริหารแรงงาน กำหนดกำลังการผลิต การวางแผนผังกระบวนการการผลิต การจัดการการผลิตหลัก และการจัดการสินค้าคงคลังที่พิจารณาความสมดุลระหว่างความต้องการขายของผู้ผลิตกับความต้องการซื้อของผู้บริโภค ทำให้ต้นทุนสินค้าคงคลัง (Inventory cost) ลดลง

จากการทบทวนวรรณกรรมที่เกี่ยวข้องกับงานวิจัยข้าว ซึ่งสืบค้นจากฐานข้อมูล ISI Web of Science ณ วันที่ 13 ตุลาคม 2558 และสืบค้นข้อมูลจากศูนย์ดัชนีการอ้างอิงวารสารไทย (Thai-Journal Citation Index Center: TCI) เมื่อวันที่ 11 ธันวาคม 2558 พบว่า งานวิจัยข้าวสามารถพบได้ในเกือบทุกกิจกรรมของโซ่อุปทานของข้าว เช่น ในการผลิตข้าวของเกษตรกร เป็นการวิจัยเรื่อง การพยากรณ์ราคาข้าวเปลือกเจ้าหอมมะลิ 105 (วารางคณา กิรติวิบูลย์, 2558) หรือในส่วนของพ่อค้าที่เป็นผู้ค้าส่งต่างประเทศ เป็นการวิจัยตัวแบบพยากรณ์มูลค่าการส่งออกข้าวหอมมะลิ (วารางคณา กิรติวิบูลย์, 2557) เป็นต้น ซึ่งยังไม่มีงานวิจัยที่ทำการพยากรณ์ข้าวที่อยู่ในขั้นตอนของการแปรรูปข้าวเป็นข้าวผสม

วิธีการพยากรณ์ที่นิยมใช้ในงานวิจัยเกี่ยวกับข้าว นั่นคือ วิธีโครงข่ายประสาทเทียม (Artificial Neural Network: ANN) เนื่องจากข้อมูลด้านอุปสงค์และอุปทานในปัญหาการพยากรณ์ข้าวไม่มีความแน่นอน และไม่สามารถทำการคาดเดาได้ เพราะได้รับผลกระทบจากหลายปัจจัยในลักษณะที่ซับซ้อน วิธีโครงข่ายประสาทเทียม (ANN) จึงถูกนำมาใช้ในการแก้ปัญหา ลักษณะดังกล่าว (Co and Boosarawongse, 2007) ดังนั้น งานวิจัยนี้จึงทำการพยากรณ์ยอดขายผลิตภัณฑ์ข้าวผสมโดยการประยุกต์ใช้วิธีเมตาดิวริสติกส์ ซึ่งใช้วิธีโครงข่ายประสาทเทียม

## 2. วัตถุประสงค์ของโครงการวิจัย

เพื่อทำการพยากรณ์ยอดขายผลิตภัณฑ์ข้าวผสมโดยการประยุกต์ใช้วิธีเมตาดิวริสติกส์

## 3. ขอบเขตของโครงการวิจัย

3.1 ผลิตภัณฑ์ข้าวผสมที่ใช้การพยากรณ์ประกอบด้วย ข้าวรวมเก่า 5% ข้าวรวมใหม่ 5% ข้าวรวมใหม่ 25% แป้งอัม สีส ปล่อย หอมใบเตย หอมมะลิใหม่ และเหลืองอ่อน

3.2 ข้อมูลยอดขายจำหน่ายผลิตภัณฑ์ข้าวผสมเป็นรายเดือน

3.3 การพัฒนาโปรแกรมช่วยสนับสนุนการตัดสินใจใช้ภาษา Visual Basic for applications

3.4 วิธีเมตาดิวริสติกส์ที่ประยุกต์ใช้เพื่อการพยากรณ์คือ โครงข่ายประสาทเทียม (Artificial Neural Network: ANN)

3.5 การเปรียบเทียบประสิทธิภาพของโมเดลจากการพยากรณ์ด้วยวิธี ANN ใช้การคำนวณค่าเฉลี่ยของรากที่สองของกำลังสองของความคลาดเคลื่อน (Root Mean Square Error: RMSE)

## 4. ทฤษฎี และกรอบแนวความคิดของโครงการวิจัย

### 4.1 การพยากรณ์ (Forecasting)

การพยากรณ์เป็นการคาดคะเนความต้องการสินค้าและบริการ ของลูกค้าเป้าหมาย ในอนาคต (ล่วงหน้า) ในช่วงเวลาใดเวลาหนึ่ง โดยอาศัยข้อมูลในอดีตมาช่วยในการวิเคราะห์ความต้องการ และนำค่าพยากรณ์ที่ได้นั้นมาใช้ประโยชน์ เพื่อการตัดสินใจใดๆ โดยแบ่งตามหน้าที่หลักๆ ที่เกี่ยวข้องดังนี้

1. ด้านการเงินและการบัญชี (Financial planning) เป็นข้อมูลพื้นฐานในการจัดทำงบประมาณการขาย เพื่อจัดสรรทรัพยากรให้ทุกส่วนขององค์กร อย่างทั่วถึงและเหมาะสม

2. ด้านการตลาด (Market planning) ใช้กำหนดโควตาการขายของพนักงาน หรือนำไปสร้างเป็นยอดขายของแต่ละผลิตภัณฑ์ เพื่อใช้ในการควบคุมกิจกรรมของฝ่ายขายและฝ่ายการตลาด

3. ด้านการผลิต (Production planning) นำมาใช้เป็นข้อมูลในการดำเนินการต่างๆ ในฝ่ายการผลิตคือ การบริหารสินค้าคงคลังและการจัดซื้อ การบริหารแรงงาน การกำหนดกำลังการผลิต การเลือกทำเลที่ตั้งสำหรับการผลิต คลังเก็บสินค้า หรือศูนย์กระจายสินค้า การวางแผนผังกระบวนการการผลิต

4. ตารางการผลิตหลัก (Master scheduling) สามารถนำข้อมูลที่พยากรณ์มาใช้เป็นข้อมูลในการจัดตารางการผลิตหลัก

การพยากรณ์ (Types of forecasting) มี 2 ประเภท

1. การพยากรณ์เชิงปริมาณ การพยากรณ์เชิงปริมาณ (Quantitative forecasting) เป็นการพยากรณ์โดยอาศัยข้อมูลหรือตัวเลขจากอดีต (เช่น ยอดขาย กำลังการผลิต) มาสร้างตัวแบบ และพยากรณ์ไปในอนาคต

2. การพยากรณ์เชิงคุณภาพ การพยากรณ์เชิงคุณภาพ (Qualitative forecasting) เป็นกลุ่มของวิธีการพยากรณ์ที่อาศัยข้อมูลและวิธีการเชิงคุณภาพ ใช้กับลักษณะของปัญหาที่ไม่มีข้อมูลย้อนหลังหรือมีข้อมูลไม่มากพอมาใช้ในการสร้างตัวแบบ

### 4.2 พฤติกรรมของความต้องการมี 4 ประเภทหลัก คือ

1. แนวโน้ม (Trends) เป็นการเปลี่ยนแปลงของความต้องการที่มีแนวโน้มของการเพิ่มขึ้นหรือลดลง อย่างค่อยเป็นค่อยไปตามเวลาที่ผ่านไป เช่น ความต้องการของคอมพิวเตอร์ส่วนบุคคลที่มีแนวโน้มเพิ่ม ขึ้นเรื่อยๆ

2. วัฏจักร (Cycles) เป็นพฤติกรรมของความถี่ที่มีการเปลี่ยนแปลงขึ้นๆ ลงๆ เป็นวัฏจักรตามช่วงเวลาที่ผ่านมา โดยปกติจะมากกว่า 1 ปี เช่น เครื่องปรับอากาศที่ความต้องการจะพุ่งขึ้นสูงในฤดูร้อน และค่อนข้างสม่ำเสมอเป็นวัฏจักรทุกปี

3. รูปแบบตามฤดูกาล (Seasonal patterns) เป็นพฤติกรรมของความถี่ที่มีการเปลี่ยนแปลงเป็นช่วงๆ เช่น อาหารเสริมผิวขาว

4. องค์ประกอบอื่นที่ไม่สามารถพยากรณ์ได้ (Random component)

#### 4.3 วิธีโครงข่ายประสาทเทียม (Artificial Neural Networks)

โครงข่ายประสาทเทียม (Garson, 1998) คือ แบบจำลองทางคณิตศาสตร์ที่พัฒนาขึ้นเพื่อจำลองการทำงานของโครงข่ายประสาทในสมองมนุษย์ (ธนาวุฒิ, 2552) ซึ่งประกอบด้วยเซลล์ประสาท (Neuron) และจุดประสานประสาทหรือไซแนปส์ (Synapses) โดยโครงสร้างของการส่งสัญญาณประสาทประกอบจากการเชื่อมต่อระหว่างเซลล์ประสาทหลายพันล้านเซลล์ เซลล์ประสาทแต่ละเซลล์ประกอบด้วยแขนงรับสัญญาณประสาทซึ่งเป็นเสมือนหน่วยรับข้อมูลป้อนเข้า เรียกว่า “เดนไดรต์” (dendrites) และส่วนปลายของเซลล์ประสาทในการส่งสัญญาณประสาทซึ่งเป็นเสมือนหน่วยส่งข้อมูลออกของเซลล์ เรียกว่า “แอกซอน” (axon) โดยการส่งสัญญาณประสาทดังกล่าว อาจทำให้เกิดได้ทั้งการกระตุ้นและยับยั้ง วิธีการประมวลผลภายในเซลล์ประสาทแต่ละเซลล์ยังมีการขยายหรือลดขนาดของสัญญาณอีกด้วย โดยสัญญาณจากเดนไดรต์ต่างๆ จะรวมกันเข้าสู่เซลล์ประสาท และหากสัญญาณรวมมีความแรงเกินค่าระดับ (threshold) ของเซลล์ประสาทรุ่นนั้นๆ เซลล์ประสาทจะส่งสัญญาณออกทางแอกซอนต่อไป กระบวนการเรียนรู้ในสิ่งมีชีวิตจะมีผลให้เกิดการสร้างไซแนปส์ระหว่างเซลล์ประสาทขึ้นมาใหม่ หรือทำให้เกิดการเปลี่ยนแปลงสภาพของไซแนปส์ต่างๆ ในโครงข่ายของเซลล์ประสาท โครงข่ายประสาทของสิ่งมีชีวิตจึงไม่ได้ทำงานแบบเป็นลำดับขั้นตอน (sequential) แต่เพียงอย่างเดียว

โครงข่ายประสาทเทียมประกอบด้วย 5 องค์ประกอบคือ

1. ข้อมูลป้อนเข้า (Input) เป็นข้อมูลที่ป้อนเข้าเป็นตัวเลข หากเป็นข้อมูลเชิงคุณภาพ ต้องแปลงให้อยู่ในรูปเชิงปริมาณที่โครงข่ายประสาทเทียมยอมรับได้

2. ข้อมูลส่งออก (Output) คือ ผลลัพธ์ที่เกิดขึ้นจริง (actual output) จากกระบวนการเรียนรู้ของโครงข่ายประสาทเทียม

3. ค่าน้ำหนัก (Weights) คือ สิ่งที่ได้จากการเรียนรู้ของโครงข่ายประสาทเทียม หรือเรียกอีกอย่างหนึ่งว่า ค่าความรู้ (knowledge) ค่าน้ำหนักจะถูกเก็บเป็นทักษะเพื่อใช้ในการจดจำข้อมูลอื่นๆ ที่อยู่ในรูปแบบเดียวกัน

4. ฟังก์ชันผลรวม (Summation function: S) เป็นผลรวมของข้อมูลป้อนเข้าและค่าน้ำหนัก

5. ฟังก์ชันการแปลง (Transfer function) เป็นการคำนวณการจำลองการทำงานของโครงข่ายประสาทเทียม เช่น ซิกมอยด์ฟังก์ชัน (Sigmoid function) ฟังก์ชันไฮเพอริโบลิกแทนเจนต์ (Hyperbolic tangent function) เป็นต้น

โครงข่ายประสาทเทียมเป็นศาสตร์แขนงหนึ่งทางด้านปัญญาประดิษฐ์ที่ประยุกต์ใช้ความรู้จากหลากหลายสาขามารวมเข้าด้วยกัน นับว่าเป็นศาสตร์ที่กำลังมีบทบาทอย่างยิ่งในปัจจุบัน กล่าวโดยสรุปโครงข่ายประสาทเทียมสามารถนำมาประยุกต์ใช้กับงานด้านต่างๆ ได้ดังนี้

1. การจำแนกรูปแบบ (Pattern recognition) เช่น การมองเห็นวัตถุ หรือการวิเคราะห์ เสียงพูดเพื่อแปลความหมาย

2. การทำนาย (Prediction) หรือการพยากรณ์ (Forecasting) เช่น การทำนายราคาหุ้นของตลาดหลักทรัพย์ การพยากรณ์อัตราการไหลของน้ำ การพยากรณ์ราคาสินค้า เป็นต้น

3. การควบคุม (Control) เช่น การควบคุมระบบของเครื่องปรับอากาศ การควบคุมระบบเครื่องยนต์ และการควบคุมหุ่นยนต์ เป็นต้น

4. การหาความเหมาะสม (Optimisation) เช่น การเลือกระยะทางที่ใกล้ หรือสั้นที่สุดในการเดินทาง (Shortest path)

5. การจัดกลุ่ม (Clustering) และการจัดหมู่ (Categorisation) เช่น การวิเคราะห์ข้อมูลจากภาพถ่ายดาวเทียม หรือภาพถ่ายทางอากาศ

#### 5. วิธีการดำเนินการวิจัย

5.1 ศึกษารายละเอียดผลิตภัณฑ์ข้าวผสม การผลิต การเก็บรักษา และการจำหน่ายของสถานประกอบการแห่งหนึ่งในจังหวัดพิจิตร



## 5.2 เก็บข้อมูลเพื่อทำการคัดเลือกผลิตภัณฑ์ข้าวผสม

ผลิตภัณฑ์ข้าวที่นำมาใช้ในการวิเคราะห์ทำการคัดเลือกข้าวจากการนำปริมาณข้าว (กิโลกรัม) ที่ขายได้รายปี สำหรับปี พ.ศ. 2555 2556 และ 2557 มาทำแผนภูมิพาราโตของแต่ละปี และเลือกผลิตภัณฑ์ข้าวผสมในแต่ละปี ที่มียอดขายละเอียดสะสมเกินร้อยละ 90 จึงได้ผลิตภัณฑ์ข้าวผสมที่ใช้การพยากรณ์ประกอบด้วย ข้าวรวมเก่า 5% ข้าวรวมใหม่ 5% ข้าวรวมใหม่ 25% แป้งยี่ม สีปล่อย หอมใบเตย หอมมะลิใหม่ และเหลืองอ่อน

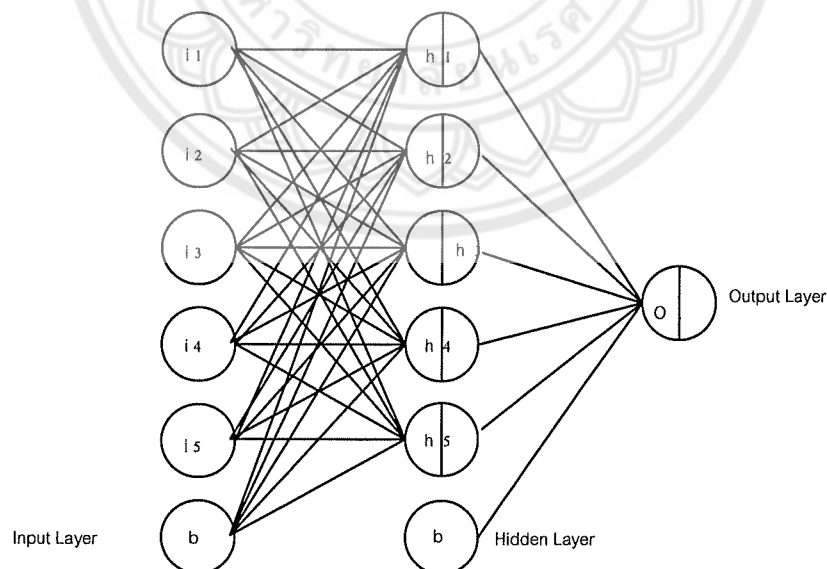
### 5.2 วิเคราะห์และออกแบบแฟ้มข้อมูลนำเข้า (Input files)

ข้อมูลนำเข้าสำหรับการพยากรณ์ได้มาจากการทบทวนวรรณกรรมของงานวิจัยที่เกี่ยวข้องกับการพยากรณ์ ยอดจำหน่ายข้าวเพื่อการส่งออก (Co and Boosarawongse, 2007) ข้อมูลนำเข้าเพื่อการพยากรณ์ด้วยวิธี ANN จึงประกอบด้วย

- 5.2.1 ค่าสัมบูรณ์ของความแตกต่างของยอดขายฤดูกาลปัจจุบันและฤดูกาลก่อนหน้า
- 5.2.2 สัญลักษณ์ความแตกต่างของยอดขายฤดูกาลปัจจุบันและฤดูกาลก่อนหน้า
- 5.2.3 ค่าสัมบูรณ์ของความแตกต่างยอดขายรายเดือนระหว่างปีปัจจุบันและปีก่อนหน้า
- 5.2.4 สัญลักษณ์ความแตกต่างยอดขายรายเดือนระหว่างปีปัจจุบันและปีก่อนหน้า
- 5.2.5 ค่าสัมบูรณ์ของความแตกต่างของฤดูกาลปีปัจจุบันและปีก่อนหน้า
- 5.2.6 สัญลักษณ์ความแตกต่างของฤดูกาลปีปัจจุบันและปีก่อนหน้า
- 5.2.7 ดัชนีฤดูกาล (Seasonal Index)
- 5.2.8 ค่าสัมบูรณ์ของความแตกต่างของเดือนปัจจุบันและเดือนก่อน
- 5.2.9 สัญลักษณ์ความแตกต่างของเดือนปัจจุบันและเดือนก่อน
- 5.2.10 ยอดขาย

5.3 วิเคราะห์และออกแบบแฟ้มข้อมูลขาออก โดยเพิ่มข้อมูลขาออกประกอบด้วย ชนิดข้าวที่ใช้ในการพยากรณ์ ค่า ANN ของชุดฝึกฝน จำนวนรอบในการวนที่ให้ ค่า RMSE ของชุดฝึกฝนน้อยที่สุด ค่า RMSE ของชุดทดสอบ ค่า ANN ของชุดทดสอบ และผลของการพยากรณ์ของผลิตภัณฑ์ที่ได้จากโปรแกรม

5.4 ประยุกต์ใช้วิธี ANN ในการพยากรณ์ยอดขายผลิตภัณฑ์ข้าวผสมด้วยภาษา Visual Basic for applications โดยกำหนดให้โครงข่ายประสาทเทียมมีโครงสร้างดังนี้ Neural Network Architecture 5-5-1 (Input = 5, Hidden = 5, Output = 1) ดังรูปที่ 2.1 และมีลำดับการทำงานดังรูปที่ 2.2 และอธิบายได้ดังนี้



รูปที่ 2.1 Three Layer Neural Network Architecture (5-5-1)

ที่มา: การประยุกต์ใช้ Artificial Neural Networks (ANNs) ในงานชลประทาน, 2547

ตาราง 2.5 ข้อมูลก่อนการป้อนเข้า ANN

ช่วงเวลา	ข้อมูลปัจจัยป้อนเข้า					ค่าจริงล่วงหน้า (เป็นข้อมูลป้อนเข้า เพื่อใช้ในส่วนของ RMSE)
	1	2	3 (ค่าจริง)	4	5	
1	9.05	0.00	3.89	6.62	0.29	3.11
2	0.00	9.05	3.11	3.89	6.62	1.78
3	0.58	0.00	1.78	3.11	3.89	1.62
4	30.98	0.58	1.62	1.78	3.11	1.16
5	1.60	30.98	1.16	1.62	1.78	1.94

ที่มา: การประยุกต์ใช้ Artificial Neural Networks (ANNs) ในงานชลประทาน, 2547

จากข้อมูลในตารางที่ 2.5 นำไปทำการแปลงข้อมูลโดยใช้สมการ (between 0.05 – 0.95) =  $[0.90(\text{Data}-\text{Min}) / (\text{Max}-\text{Min})] + 0.05$  เพื่อให้อยู่ในรูปของ Linear Function Normalized Input Data จะได้ดังตาราง 2.6

ตัวอย่างคำนวณการแปลงข้อมูลของปัจจัยที่ 1

จากตารางที่ 14 การแปลงข้อมูลของปัจจัยที่ 1 ณ ช่วงเวลาที่ 1 สามารถอธิบายได้ดังนี้

ข้อมูลของปัจจัยที่ 1 ณ ช่วงเวลาที่ 1 มีค่าเท่ากับ 9.05 แปลงให้อยู่ในรูปของ Linear Function Normalized Input Data แทนค่าโดยใช้สมการ (between 0.05 – 0.95) =  $[0.90(\text{Data}-\text{Min}) / (\text{Max}-\text{Min})] + 0.05$  จะได้

$$\left[ \frac{0.9(9.05-0)}{(30.98-0)} \right] + 0.05 = 0.313$$

ดังนั้น ข้อมูลของปัจจัยที่ 1 ณ ช่วงเวลาที่ 1 มีค่าเท่ากับ 9.05 แปลงให้อยู่ในรูปของ Linear Function Normalized Input Data จะมีค่ากับ 0.313

ตาราง 2.6 ข้อมูลที่แปลงแล้วเพื่อทำการป้อนเข้า ANN

ช่วงเวลา	ข้อมูลปัจจัยป้อนเข้า					ค่าจริงล่วงหน้า (เป็นข้อมูลป้อนเข้า เพื่อใช้ในส่วนของ RMSE)
	1	2	3 (ค่าจริง)	4	5	
1	0.313	0.050	0.163	0.242	0.058	0.140
2	0.050	0.313	0.140	0.163	0.242	0.102
3	0.067	0.050	0.102	0.140	0.163	0.097
4	0.950	0.067	0.097	0.102	0.140	0.084
5	0.096	0.950	0.084	0.097	0.102	0.106

หลังจากการแปลงข้อมูลก่อนนำเข้า ANN แล้วนั้น ขั้นตอนต่อไปสามารถอธิบายได้ดังรูปที่ 2.2 ซึ่งจะอธิบายขั้นตอนในการพัฒนาการพยากรณ์โดยประยุกต์ใช้วิธีโครงข่ายประสาทเทียมได้ตามหมายเลขในภาพดังนี้

เมื่อ JY คือ ข้อมูลป้อนเข้า

Momentum ( $\alpha$ ) คือ ค่าคงที่ เป็นตัวกำหนดผลกระทบของการเปลี่ยนแปลงน้ำหนักในทิศทางปัจจุบันของการเคลื่อนไหว

Heddin คือ จำนวนโหนดในชั้นซ่อน

Firtloop, Thirdloop คือ จำนวนของโหนดในชั้นซ่อน

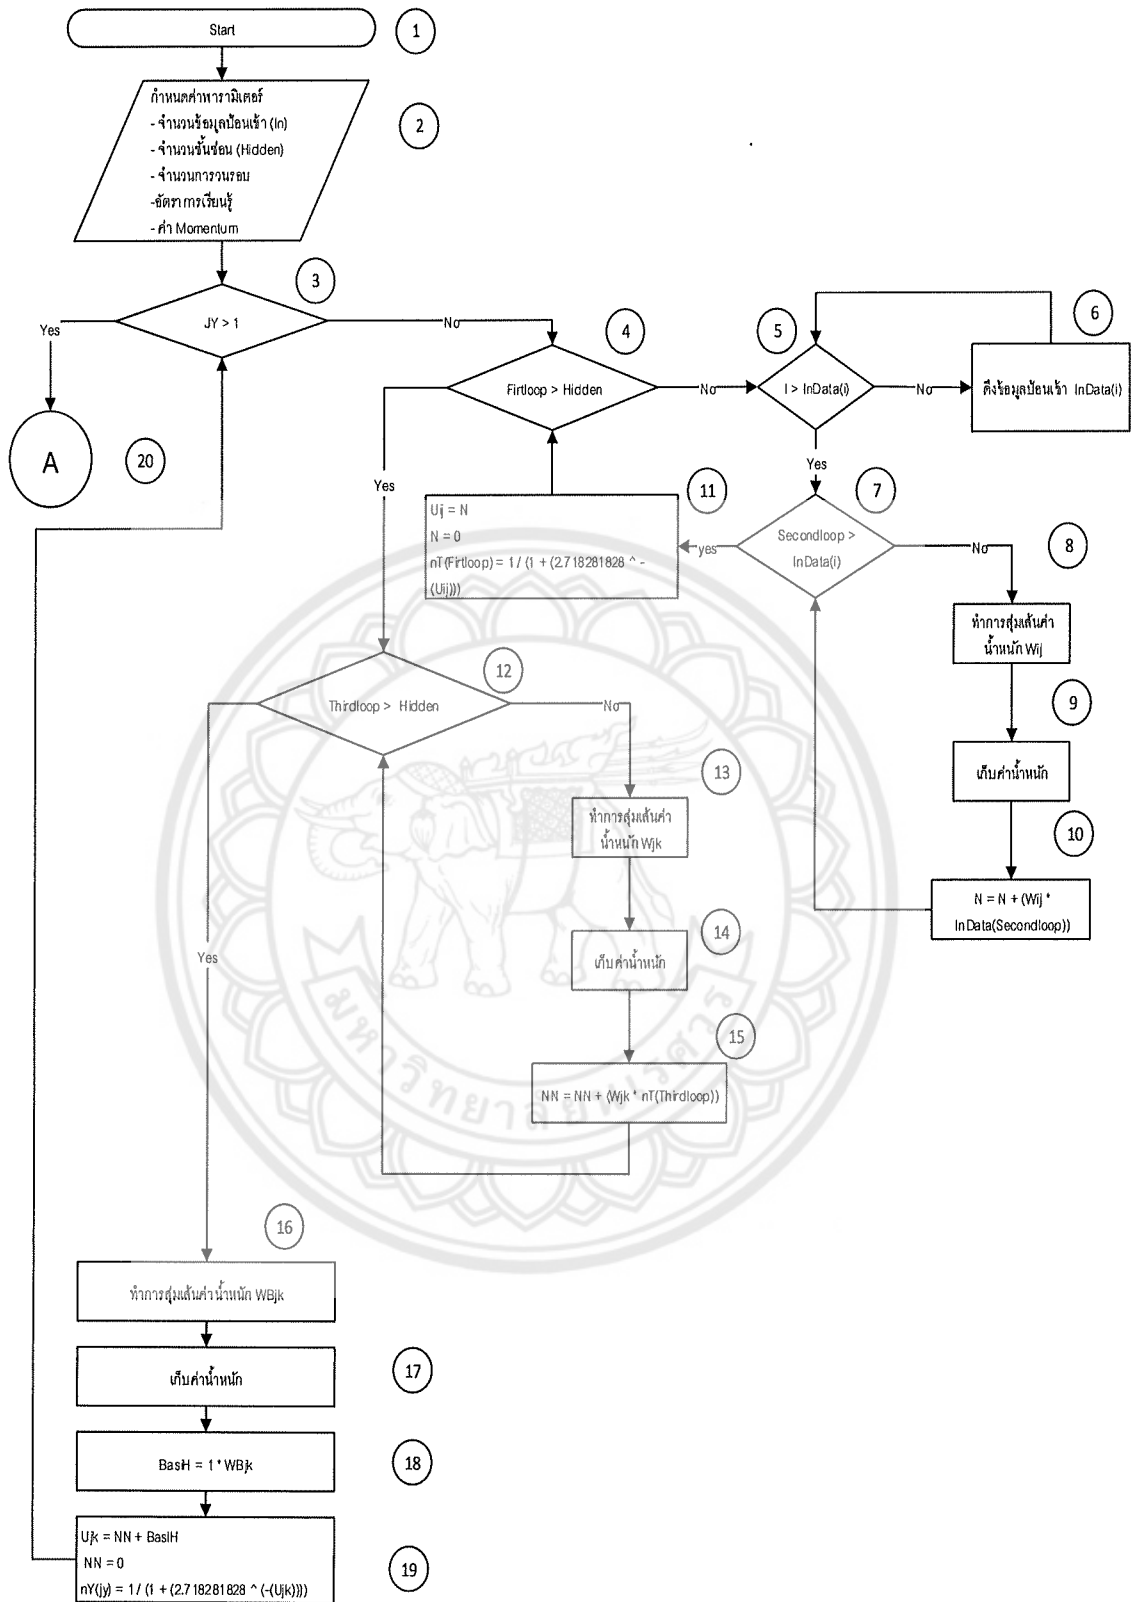
I, Secondloop คือ จำนวนโหนดในชั้น JY

j คือ ลำดับที่ของชั้นซ่อนในการคำนวณหาค่าเส้นน้ำหนัก

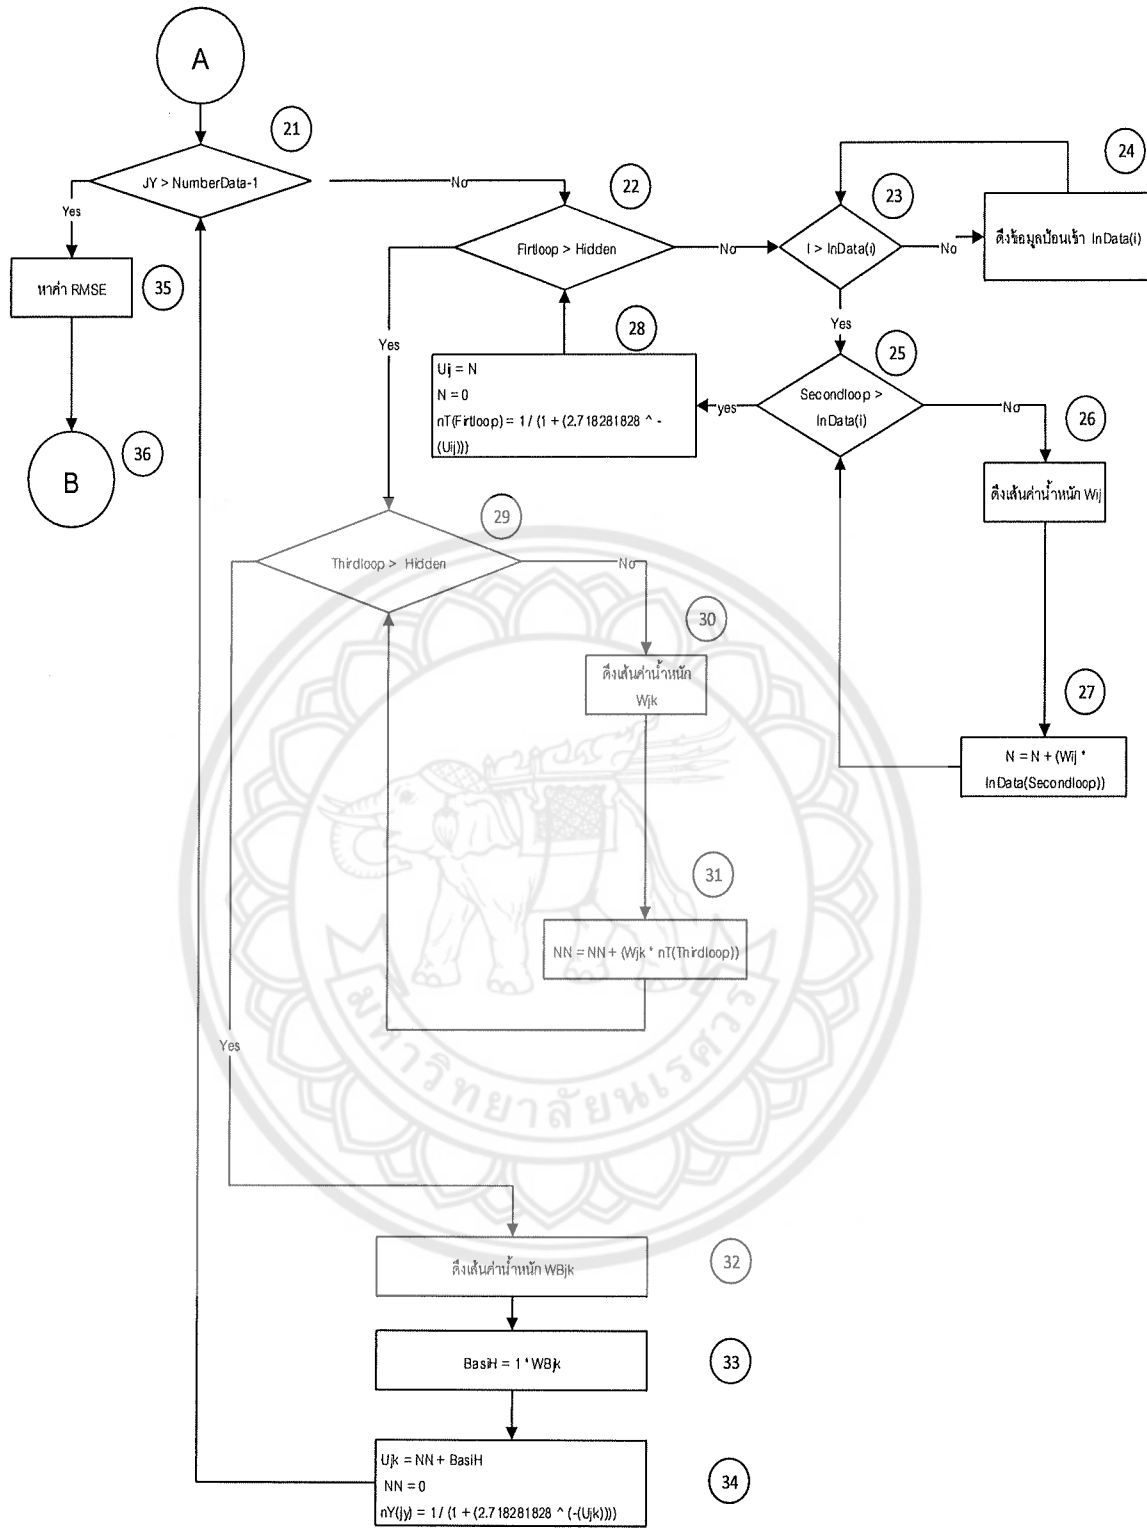
k คือ จำนวนโหนดในชั้นผลลัพธ์ของ ANN

$W_{ij}$  คือ เส้นน้ำหนักจากโหนดชั้น ข้อมูลป้อนเข้า (i) ไปยังโหนดในชั้นซ่อน (j)

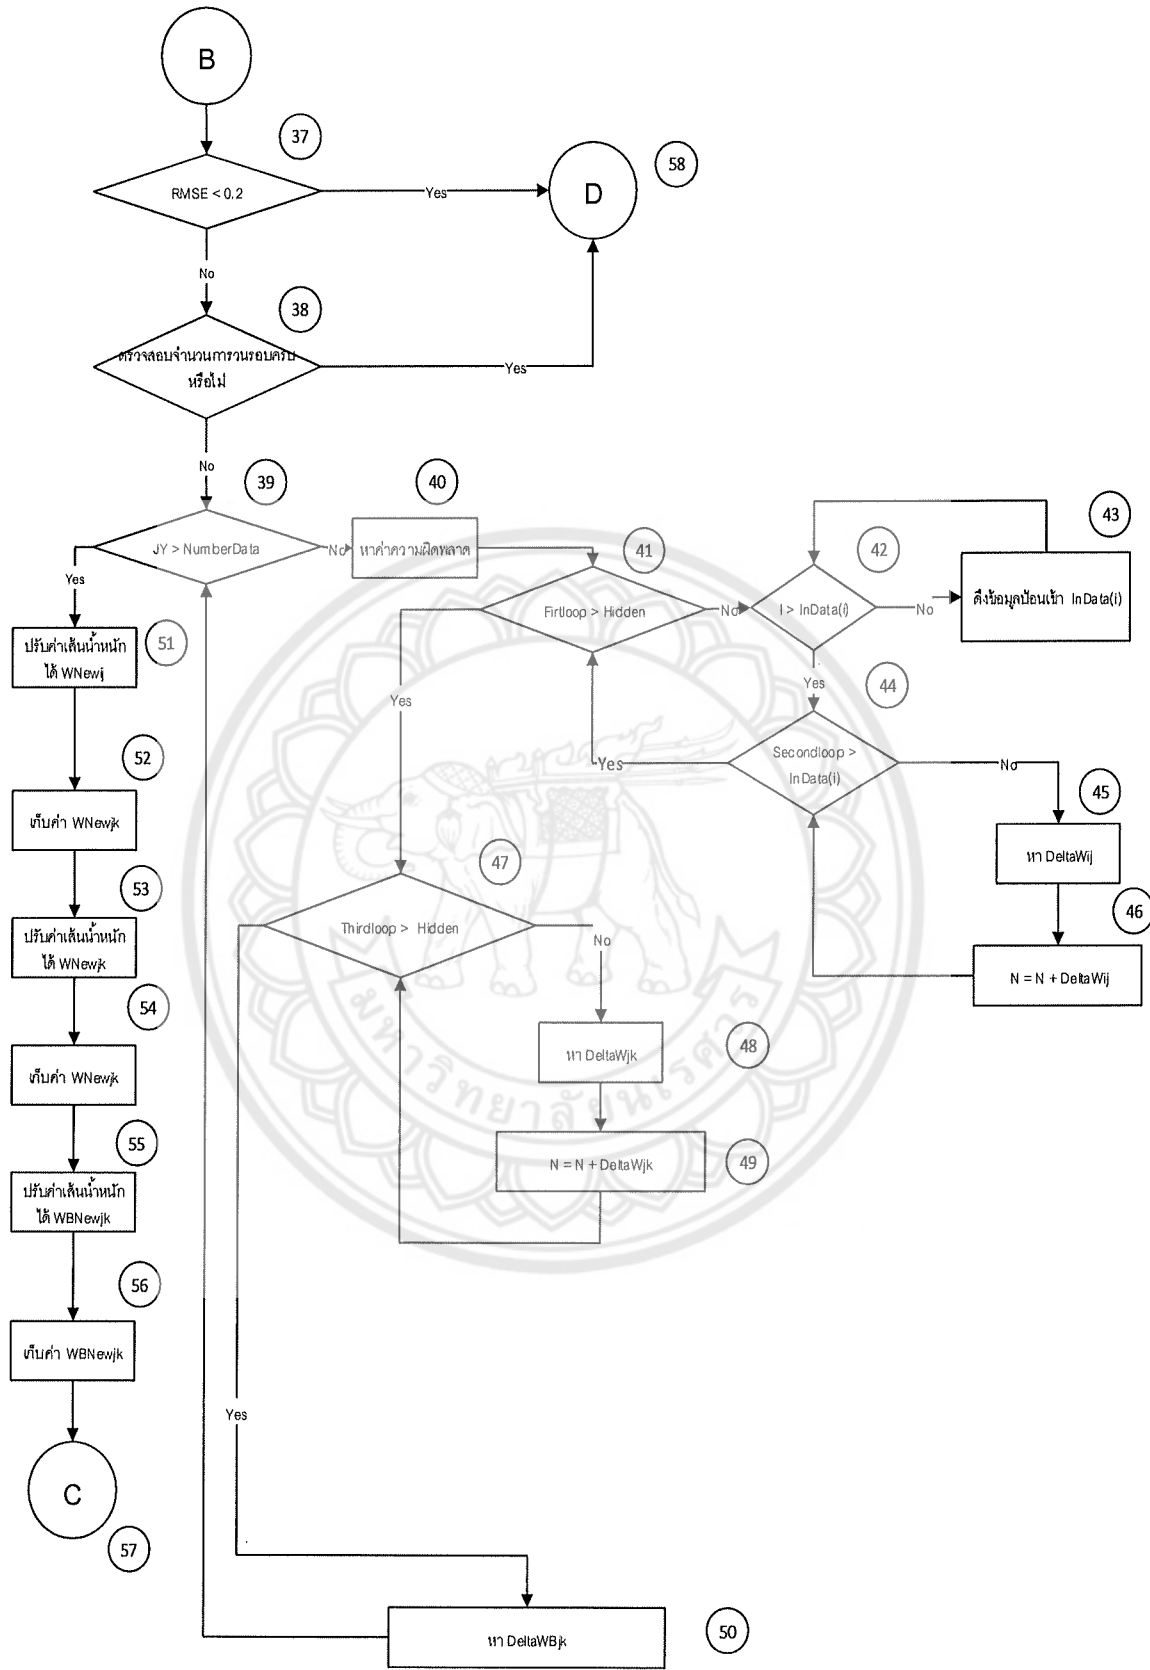
- $U_{ij}$  คือ ผลรวมทุกตัวของเส้นน้ำหนักที่ทำการคูณกับข้อมูลป้อนเข้า(i) ไปยังโหนดในชั้นซ่อน (j)  
 $O_{ij}$  คือ ผลลัพธ์ ของข้อมูลป้อนเข้า(i) ไปยังโหนดในชั้นซ่อน (j)  
 $W_{jk}$  คือ เส้นน้ำหนักจากโหนดชั้นซ่อน(j) ไปยังโหนดในชั้นผลลัพธ์(k)  
 $U_{jk}$  คือ ผลรวมทุกตัวของเส้นน้ำหนักที่ทำการคูณกับข้อมูลผลลัพธ์ของชั้นซ่อน (j) ไปยังโหนดในชั้นผลลัพธ์ (k)  
 $WB_{jk}$  คือ เส้นน้ำหนัก Bias ของโหนดชั้นซ่อน(j) ไปยังโหนดในชั้นผลลัพธ์(k)  
 $NB$  คือ ผลรวมของค่า  $WB_{jk}$  และ  $U_{jk}$   
 $O_{jk}$  คือ ค่า ผลลัพธ์ของโหนดชั้นผลลัพธ์(k) (ค่า ANN )  
 $W_{new_{ij}}$  คือ ค่าเส้นน้ำหนักจากโหนดชั้นข้อมูลป้อนเข้า (i) ไปยังโหนดชั้นซ่อน(j) ที่ปรับปรุงแล้ว  
 $U_{new_{ij}}$  คือ ผลรวมทุกตัวของเส้นน้ำหนักที่ทำการคูณกับข้อมูลป้อนเข้า(i) ไปยังโหนดในชั้นซ่อน (j) ใหม่  
 $O_{new_{ij}}$  คือ ผลลัพธ์ ของข้อมูลป้อนเข้า(i) ไปยังโหนดในชั้นซ่อน (j) ที่ปรับปรุง  
 $O_{new_H}$  คือ ผลลัพธ์ของข้อมูลในโหนด Hidden ที่ปรับปรุง  
 $W_{new_{jk}}$  คือ ค่าเส้นน้ำหนักจากโหนดชั้นซ่อน(j) ไปยังโหนดชั้นผลลัพธ์(k) ที่ปรับปรุงแล้ว  
 $WB_{new_{jk}}$  คือ ค่าเส้นน้ำหนัก Bias ของโหนดชั้นซ่อน(j) ไปยังโหนดในชั้นผลลัพธ์(k) ที่ปรับปรุงแล้ว  
 $U_{new_{jk}}$  คือ ผลรวมทุกตัวของเส้นน้ำหนักที่ทำการคูณกับข้อมูลผลลัพธ์ของชั้นซ่อน(j) ไปยังโหนดในชั้นผลลัพธ์ (k) ที่ปรับปรุงแล้ว  
 $NB_{new}$  คือ ค่าผลรวมของค่า  $WB_{new_{jk}}$  และ  $U_{new_{jk}}$   
 $O_{new_k}$  คือ ค่าผลลัพธ์ของโหนดชั้นผลลัพธ์ (k) (ค่า ANN) ที่ปรับปรุงแล้ว  
 $\delta_{ij}$  คือ ค่าของ  $\delta$  สำหรับเซลล์ประสาทในชั้น i ไปยังชั้นซ่อน j  
 $\Delta W_{ij}$  คือ ค่าของเส้นน้ำหนักที่เปลี่ยนไปของโหนด i ไปยัง โหนด j  
 $\eta$  คือ อัตราการเรียนรู้  
 $\delta_{jk}$  คือ ค่าของ  $\delta$  สำหรับเซลล์ประสาทในชั้น j ไปยังชั้นผลลัพธ์ k  
 $\Delta W_{jk}$  คือ ค่าของเส้นน้ำหนักที่เปลี่ยนไปของโหนด j ไปยัง โหนด k



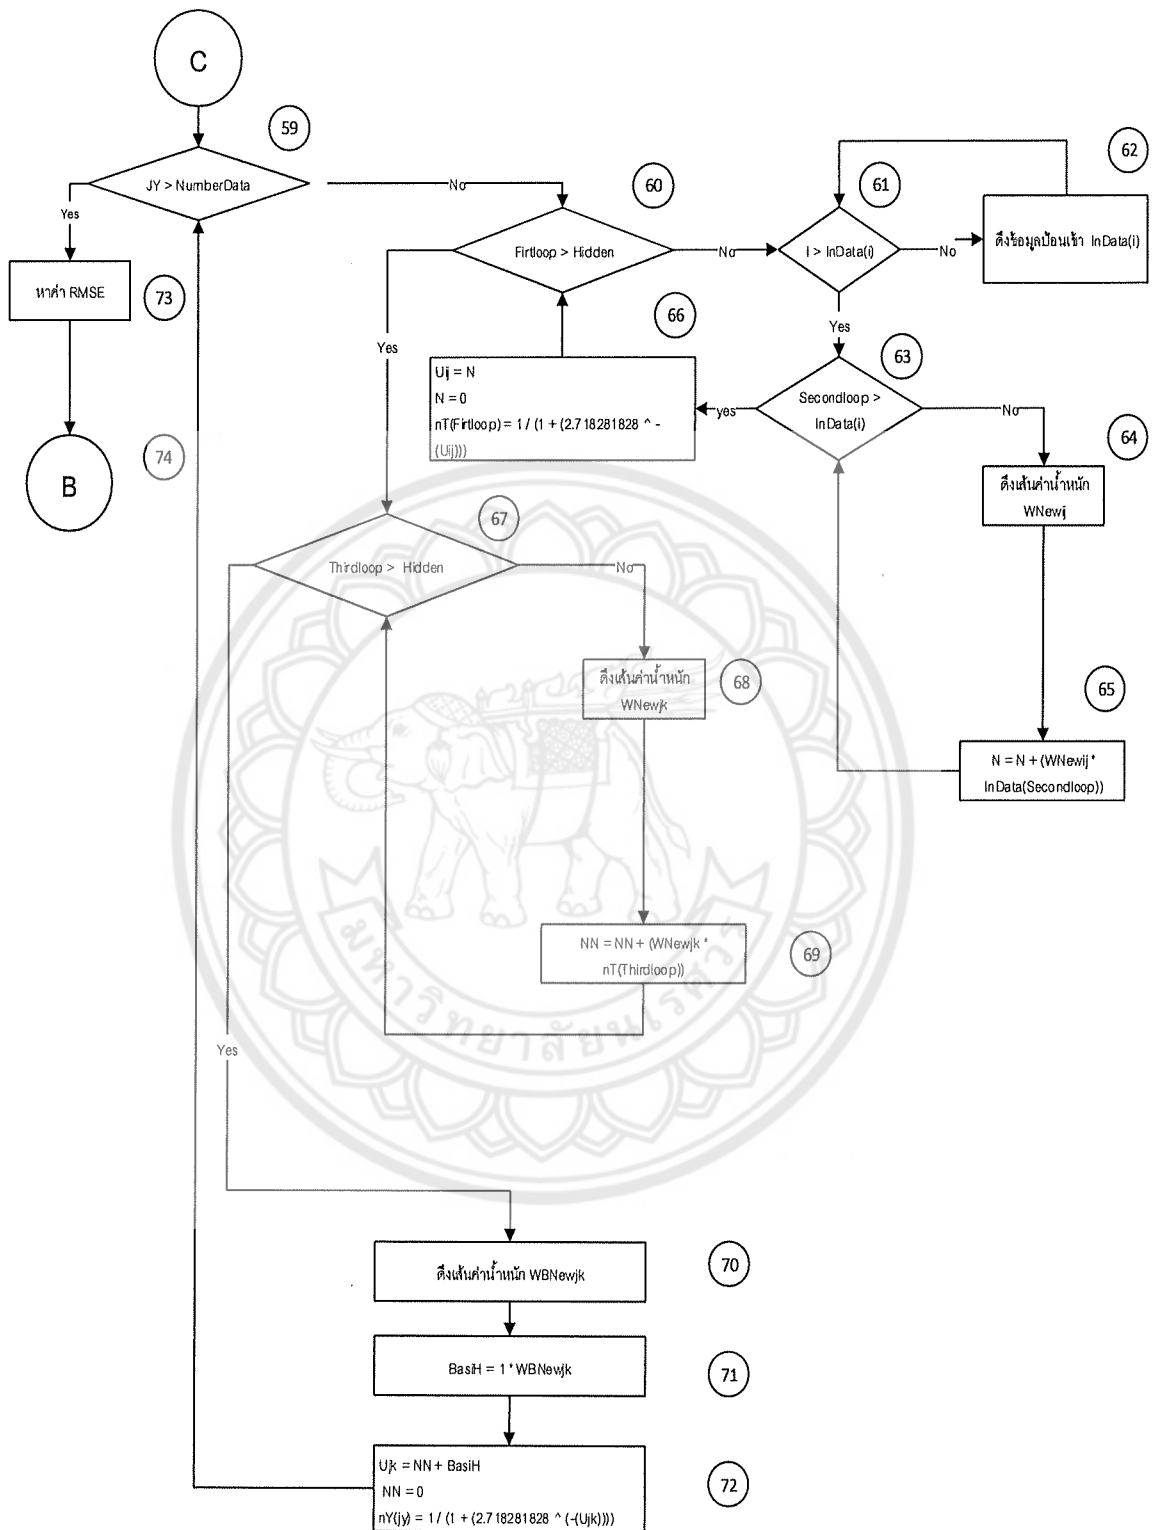
รูปที่ 2.2 ขั้นตอนการทำงานของการทำงานของพยากรณ์ยอดขายผลิตภัณฑ์ข้าวผสมด้วยวิธี ANN



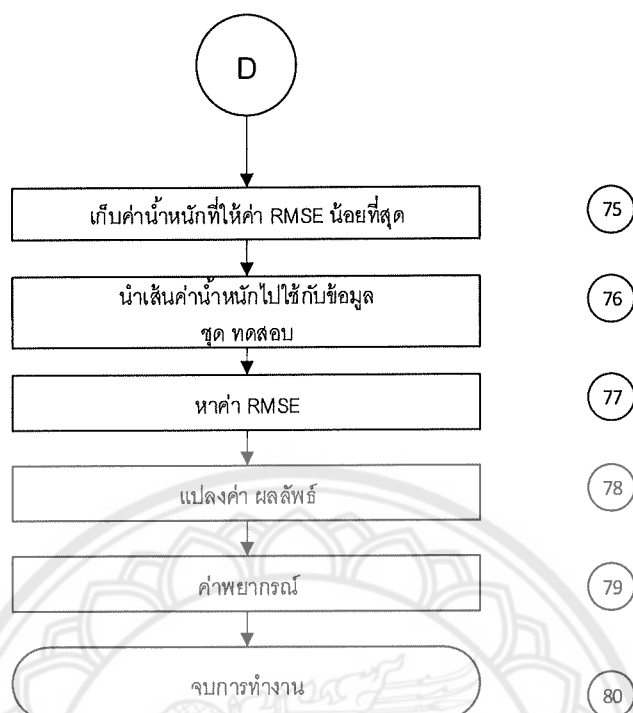
รูปที่ 2.2 ขั้นตอนการทำงานของกรพยากรณ์ยอดขายผลิตภัณฑ์ข้าวผสมด้วยวิธี ANN (ต่อ)



รูปที่ 2.2 ขั้นตอนการทำงานของการทำงานของการพยากรณ์ยอดขายผลิตภัณฑ์ข้าวผสมด้วยวิธี ANN (ต่อ)



รูปที่ 2.2 ขั้นตอนการทำงานของการทำงานของพยากรณ์ยอดขายผลิตภัณฑ์ข้าวผสมด้วยวิธี ANN (ต่อ)



รูปที่ 2.2 ขั้นตอนการทำงานของพยากรณ์ยอดขายผลิตภัณฑ์ข้าวผสมด้วยวิธี ANN (ต่อ)

ขั้นตอนที่ 1 เริ่มต้นการทำงานของโปรแกรม

ขั้นตอนที่ 2 ทำการกำหนดค่าพารามิเตอร์ที่ใช้ในวิเคราะห์ ซึ่งประกอบไปด้วย

- 1) จำนวนโหนดในชั้นซ่อน (H) ในงานวิจัยกำหนดไว้ที่  $H = 5$  (Co and Boosarawongse, 2007)
- 2) จำนวนรอบสูงสุดในการเรียนรู้เบื้องต้น ซึ่งในเบื้องต้นจะกำหนดตามความสามารถของ Excel ที่

จะรองรับได้

3) ค่า Momentum โมเมนตัมมีผลต่อการเปลี่ยนแปลงน้ำหนัก ดังนั้นหากอัตราการเรียนรู้มีขนาดเล็ก โมเมนตัมจะช่วยให้มีการเคลื่อนที่ได้เร็วขึ้นเพื่อให้ได้คำตอบที่ดีที่สุด

4) กำหนดค่าพารามิเตอร์ของอัตราการเรียนรู้ ที่อยู่ในช่วง  $[0.01, 1]$  โดยเบื้องต้นจะเริ่มที่ 0.01 เป็นพารามิเตอร์ที่บ่งบอกถึงความเร็วในการพัฒนาแบบจำลอง ซึ่งมีความเกี่ยวข้องกับค่าน้ำหนัก ถ้ามีค่าน้อยเกินไป จะทำให้พัฒนาได้ช้าหรืออาจหยุดนิ่ง หากกำหนดค่ามากเกินไปอาจทำให้โมเดลล้มเหลวได้

ขั้นตอนที่ 3 กำหนดการตัดสินใจ  $JY > 1$

ขั้นตอนที่ 4 กำหนดการตัดสินใจ  $Firtloop > Hidden$

ขั้นตอนที่ 5 กำหนดการตัดสินใจ  $I > InData(i)$

ขั้นตอนที่ 6 รับค่าข้อมูลป้อนเข้าของข้อมูลชุดแรก(ข้อมูลที่ใช้ในการฝึกฝน)ในที่นี้หมายถึง ข้อมูล 10 ข้อมูลของเดือนมกราคม ปี 2555 ถึง ธันวาคม 2556

ขั้นตอนที่ 7 กำหนดการตัดสินใจ  $Secondloop > InData(i)$

ขั้นตอนที่ 8 ทำการสุมน้ำหนักเริ่มต้นให้กับทุกๆเส้นเชื่อมภายในโครงข่ายประสาทเทียมในชั้นแรก( $W_{ij}$ ) โดยให้มีค่าอยู่ระหว่าง  $[-0.5, 0.5]$  ดังตัวอย่างในตาราง 2.7



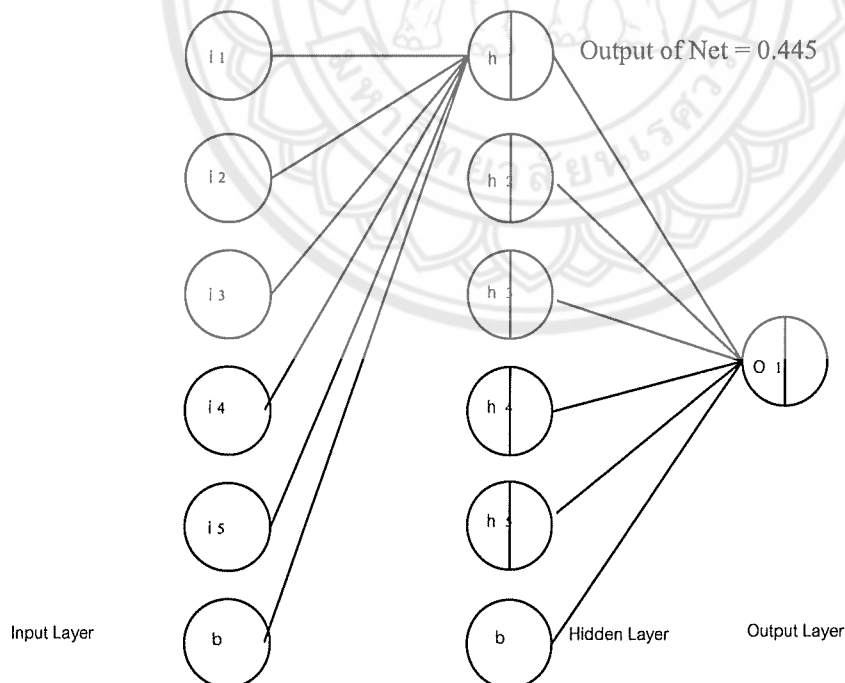
ตาราง 2.7 กำหนดค่า Weight เริ่มต้น

From	H <sub>1</sub>	H <sub>2</sub>	H <sub>3</sub>	H <sub>4</sub>	H <sub>5</sub>	Output
ln <sub>1</sub>	-0.15	2.50	1.50	0.22	0.78	
ln <sub>2</sub>	1.00	-0.23	-1.50	-1.27	0.65	
ln <sub>3</sub>	0.15	0.12	2.40	1.50	-0.55	
ln <sub>4</sub>	0.25	0.25	-2.40	-1.23	-0.45	
ln <sub>5</sub>	-2.14	-0.22	0.12	0.12	1.00	
H <sub>1</sub>						-0.15
H <sub>2</sub>						0.35
H <sub>3</sub>						-0.25
H <sub>4</sub>						1.00
H <sub>5</sub>						2.25
Bias	0.24	-0.50	-0.60	0.47	0.50	-0.23

ขั้นตอนที่ 9 เก็บค่าน้ำหนัก

ขั้นตอนที่ 10 คำนวณค่า  $U_{ij}$  โดยให้  $U_{ij} = In_i * W_{ij}$  ตัวอย่างรูปที่ 2.3

$$In_1 \times W_{11} = \\ 0.313(-1.50) = -0.469$$

รูปที่ 2.3 คำนวณค่า  $U_{ij}$ 

ที่มา: การประยุกต์ใช้ Artificial Neural Networks (ANNs) ในงานชลประทาน, 2547

ยกตัวอย่างโหนด Hidden1 จะสามารถหา  $U_{ij}$  ได้ดังต่อไปนี้

$$In_1 \times W_{11} = 0.313 \times (-1.50) = -0.469$$

$$In_2 \times W_{21} = 0.050 \times (1.00) = 0.050$$

$$In_3 \times W_{31} = 0.163 \times (0.15) = 0.024$$

$$In_4 \times W_{41} = 0.242 \times (0.25) = 0.061$$

$$In_5 \times W_{51} = 0.058 \times (-2.14) = -0.125$$

$$Bias \times W_{61} = 1.00(0.24) = 0.240$$

$N = \sum U_{ij}$  คือการหาผลรวมของค่า  $U_{ij}$  ของทุกค่าเส้นน้ำหนัก ดังตัวอย่างจะได้

$$N = -0.469 + 0.050 + 0.024 + 0.061 - 0.125 + 0.240 = -0.219$$

ขั้นตอนที่ 11 ทำการปรับค่ารวมด้วยฟังก์ชันกระตุ้น ฟังก์ชันซิกมอยด์ ในที่นี้จะได้ค่า  $O_{ij}$  จากตัวอย่างจะได้  $O_1 = 1 / (1 + e^{(-Net)}) = 0.445$

ทำแบบเดียวกันใน Hidden 2-5 จะได้ค่า  $O_{jk}$  ดังนี้

$$\text{Hidden 2, } O_2 = 1 / (1 + e^{(-Net)}) = 0.584$$

$$\text{Hidden 3, } O_3 = 1 / (1 + e^{(-Net)}) = 0.404$$

$$\text{Hidden 4, } O_4 = 1 / (1 + e^{(-Net)}) = 0.606$$

$$\text{Hidden 5, } O_5 = 1 / (1 + e^{(-Net)}) = 0.654$$

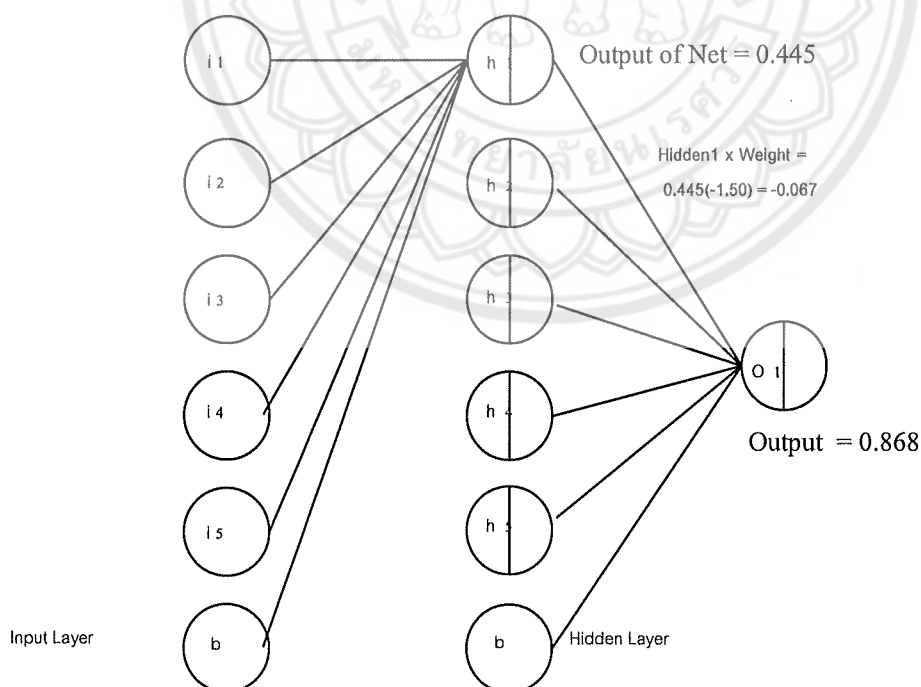
ขั้นตอนที่ 12 กำหนดการตัดสินใจ Thirdloop > Hidden

ขั้นตอนที่ 13 ทำการสุมน้ำหนักเริ่มต้นให้กับทุกๆเส้นเชื่อมภายในโครงข่ายประสาทเทียมในชั้นที่สอง ( $W_{jk}$ )

โดยให้มีค่าอยู่ระหว่าง  $[-0.5, 0.5]$  ตัวอย่างดังตาราง 14

ขั้นตอนที่ 14 เก็บค่าน้ำหนัก

ขั้นตอนที่ 15 นำค่า  $O_{ij} * W_{jk}$  กำหนดให้มีค่าเท่ากับ  $U_{jk}$  ตัวอย่างรูปที่ 2.4



รูปที่ 2.4 คำนวณค่า  $U_{jk}$

ที่มา: การประยุกต์ใช้ Artificial Neural Networks (ANNs) ในงานชลประทาน, 2547

จากตัวอย่างสามารถหา  $U_{jk}$  ได้ดังต่อไปนี้

$$\text{Hidden 1} \times \text{Weight} = O_1 * W_{11} = 0.445 \times (-0.15) = -0.067$$

$$\text{Hidden 2} \times \text{Weight} = O_2 * W_{21} = 0.584 \times (0.35) = 0.204$$

$$\text{Hidden 3} \times \text{Weight} = O_3 * W_{31} = 0.404 \times (-0.25) = -0.101$$

$$\text{Hidden 4} \times \text{Weight} = O_4 * W_{41} = 0.606 \times (1.00) = 0.606$$

$$\text{Hidden 5} \times \text{Weight} = O_5 * W_{51} = 0.654 \times (2.25) = 1.471$$

$$NN = NN + U_{jk} \text{ คือการหาผลรวมของค่า } U_{jk} \text{ ของทุกค่าเส้นค่าน้ำหนักดังตัวอย่างจะได้ } NN = -0.066 + 0.204 - 0.101 + 0.606 + 1.471 = 2.113$$

ขั้นตอนที่ 16 ทำการสุ่มเส้นน้ำหนัก Bias ( $WB_{jk}$ ) โดยให้มีค่าอยู่ระหว่าง  $[-0.5, 0.5]$  ดังตาราง 14

ขั้นตอนที่ 17 เก็บค่าน้ำหนัก

ขั้นตอนที่ 18 ทำการนำเส้นน้ำหนัก Bias + ค่า NN จะได้ค่า NB

$$\text{Bias} \times \text{Weight} = 1 \times W_{61} 1.00 \times (-0.230) = -0.230 \text{ เพราะฉะนั้น } NB = 2.113 + (-0.230) = 1.883$$

ขั้นตอนที่ 19 กำหนดให้  $U_{jk} = NB$

$$U_{jk} = \text{ผลรวมของ } U_{jk} + WB_{jk}$$

ทำการปรับค่ารวมด้วยฟังก์ชันกระตุ้น ฟังก์ชันซิกมอยด์ ในที่นี้จะได้ค่า  $O_{jk}$  จากตัวอย่างจะได้  $O_{jk} = 1 / (1 + e^{-(Net)}) = 0.868$  และหากทำแบบเดียวกันใน ข้อมูลย้อนหลังที่ 2-5 จะได้ค่า  $O_{jk}$  ดังนี้

$$\text{ข้อมูลย้อนหลังที่ 2, ผลลัพธ์} = 0.871$$

$$\text{ข้อมูลย้อนหลังที่ 3, ผลลัพธ์} = 0.861$$

$$\text{ข้อมูลย้อนหลังที่ 4, ผลลัพธ์} = 0.909$$

$$\text{ข้อมูลย้อนหลังที่ 5, ผลลัพธ์} = 0.861$$

ขั้นตอนที่ 20 ไปยัง A

ขั้นตอนที่ 21 - ขั้นตอนที่ 25 ทำเหมือนขั้นตอนที่ 3 - ขั้นตอนที่ 7

ขั้นตอนที่ 26 ดึงเส้นค่าน้ำหนัก  $W_{ij}$

ขั้นตอนที่ 27 ถึง ขั้นตอนที่ 29 ทำเหมือนขั้นตอนที่ 10 - ขั้นตอนที่ 12

ขั้นตอนที่ 30 ดึงเส้นค่าน้ำหนัก  $W_{jk}$

ขั้นตอนที่ 31 ทำเหมือนขั้นตอนที่ 15

ขั้นตอนที่ 32 ดึงเส้นค่าน้ำหนัก  $WB_{jk}$

ขั้นตอนที่ 33 - ขั้นตอนที่ 34 ทำเหมือนขั้นตอนที่ 18 - ขั้นตอนที่ 19

ขั้นตอนที่ 35 หาค่าความผิดพลาดของโหนดในชั้นผลลัพธ์ โดยการเอาผลลัพธ์ที่คำนวณได้จริงเปรียบเทียบกับค่าผลลัพธ์ที่กำหนดไว้ (ค่าจริงของทางโรงงาน) เพื่อหาค่าความผิดพลาดของข้อมูล โดยใช้วิธี RMSE จากตัวอย่างจะได้ค่า RMSE = 0.769 (ได้จากผลลัพธ์ของข้อมูลย้อนหลังที่ 1 ถึง 5)

ขั้นตอนที่ 36 ไปยัง

$$\text{ขั้นตอนที่ 37 ตรวจสอบว่า } RMSE < 0.2 \text{ หรือไม่ โดยใช้สูตร } RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (Q_i - F_i)^2}$$

จากสมการ RMSE จะพบว่ามีการใช้ข้อมูลในอดีตทั้งหมดก่อนหน้าเพื่อนำมาคำนวณหาค่า Error ในการยอมรับคำตอบของ ANN ถ้าน้อยกว่าที่ยอมรับได้จะไปขั้นตอนที่ 58 แต่ถ้ายังมากกว่าที่ยอมรับได้จะไปขั้นตอนต่อไป คือ 38 ซึ่งตรงจุดนี้จะเป็นจุดเริ่มต้นการเรียนรู้ของโครงข่ายประสาทเทียม เนื่องจากกระบวนการเรียนรู้และการปรับปรุงแก้ไขของโครงข่ายประสาทเทียมนั้น ค่าน้ำหนักจะถูกปรับจนค่าความผิดพลาดจะน้อยลงอยู่ในช่วงที่ยอมรับได้ ดังนั้นหากค่า RMSE ที่ได้ ออกมานั้นยังไม่ถึงจุดที่ยอมรับได้ โครงข่ายก็จะทำการวนรอบเข้าสู่การเรียนรู้อีกครั้งวนเช่นนี้ เพื่อให้ค่าที่ได้ในครั้งต่อไปดีขึ้นเรื่อยๆ จนถึงหรือใกล้เคียงค่าเป้าหมายที่สุด

ขั้นตอนที่ 39 ตรวจสอบ จำนวนการวนรอบว่าถึงจำนวนรอบสูงสุดในการเรียนรู้ที่กำหนดแล้วหรือยัง ถ้า แล้ว ให้ไปที่ขั้นตอนที่ 58 หากยังไม่ครบให้ไปที่ขั้นตอนที่ 40

ขั้นตอนที่ 40 หาค่าความผิดพลาด ซึ่งตรงจุดนี้จะเป็นจุดที่โครงข่ายประสาทเทียมจะทำการนำค่าผิดพลาดระหว่างค่าเป้าหมาย(ค่าจริงที่เราต้องการ)กับค่าของผลลัพธ์ที่ได้มาใช้ในการปรับค่าน้ำหนัก โดยใช้สมการ 1

$$\delta_{jk} = O_{jk}(1-O_{jk})(In_i - O_{jk}) \quad \dots\dots\dots(1)$$

จากตัวอย่างข้างต้นจะได้

กำหนดให้ Learning parameter = 0.03 และ Momentum parameter = 0.5

$$\delta_j = O_{jk}(1-O_{jk})(In_i - O_{jk}) = (0.868)(1-0.868)(0.140-0.868) = -0.083$$

ขั้นตอนที่ 41 กำหนดการตัดสินใจ Firstloop > Hidden

ขั้นตอนที่ 42 กำหนดการตัดสินใจ l > InData(i)

ขั้นตอนที่ 43 รับค่าข้อมูลป้อนเข้าของข้อมูลชุดแรก(ข้อมูลที่ใช้ในการทดลอง)

ขั้นตอนที่ 44 กำหนดการตัดสินใจ Secondloop > InData(i)

ขั้นตอนที่ 45 หา DeltaWij ดังรูปที่ 2.5 โดยใช้สมการ 2-3

$$\delta_{j,m} = O_{j,m}(1-O_{j,m}) \sum_{k=1}^{n_{m+1}} W_{kj,m+1} \delta_{k,m+1}; m : \text{hidden layer} \quad \dots\dots\dots(2)$$

ยกตัวอย่าง Hidden 1 – ข้อมูลป้อนค่าที่ 1 (ln 1) จะได้

$$\delta_{j,m} = O_{j,m}(1-O_{j,m}) \sum_{k=1}^{n_{m+1}} W_{kj,m+1} \delta_{k,m+1}; m : \text{hidden layer} = (0.445)(1-0.445) (-0.15)(-0.083) = 0.003$$

$$\Delta W_{ji,m}(n+1) = \eta \delta_{j,m} O_{i,m-1} + \alpha \Delta W_{ji,m}(n) \quad \dots\dots\dots(3)$$

$$\Delta W_{ji,m}(n+1) = \eta \delta_{j,m} O_{i,m-1} + \alpha \Delta W_{ji,m}(n) = (0.03)(0.003)(0.313) + (0.50)(0) = 0.000028$$

และทำวิธีเดียวกันจะได้

$$\text{Hidden 1 – ln2, } \Delta W = 0.000005$$

$$\text{Hidden 1 – ln3, } \Delta W = 0.000015$$

$$\text{Hidden 1 – ln4, } \Delta W = 0.000022$$

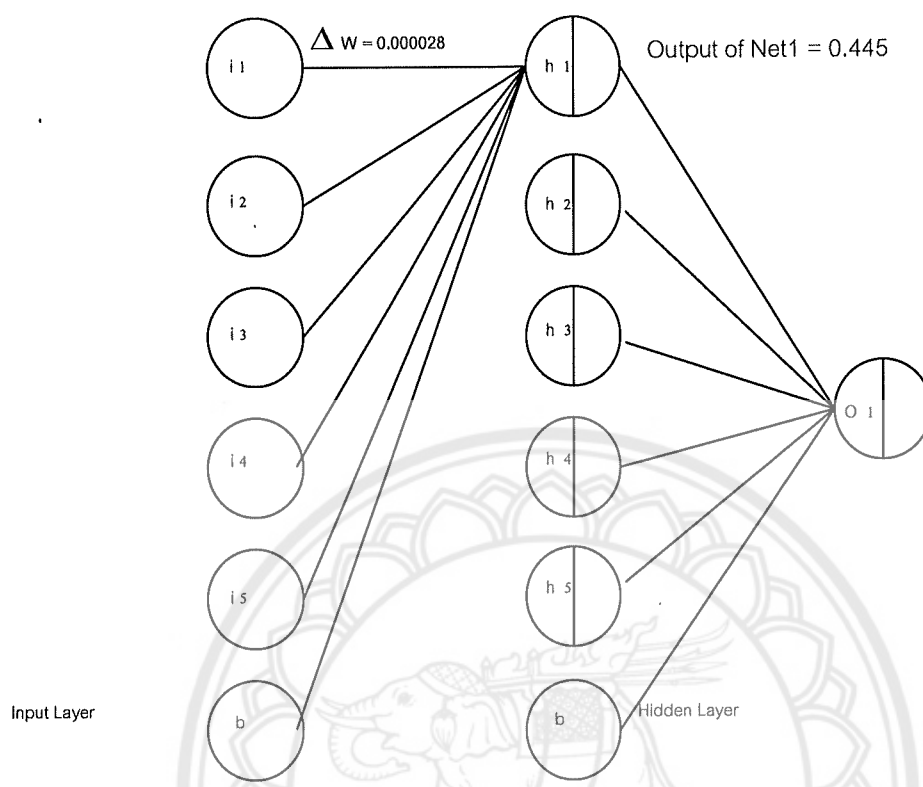
$$\text{Hidden 1 – ln5, } \Delta W = 0.000005$$

$$\text{Hidden 1 – Bias, } \Delta W = 0.000093$$

ขั้นตอนที่ 46 N = N + DeltaWij คือการหาผลรวมของค่า  $\Delta W_H$  ของทุกค่าเส้นค่าน้ำหนัก

ขั้นตอนที่ 47 กำหนดการตัดสินใจ Thirdloop > Hidden

Input1 x Weight =  
 $0.313(-1.50) = -0.469$



ตั้งรูปที่ 2.5 คำนวณค่าเส้นน้ำหนัก  $W_{new_{ij}}$   
 ที่มา: การประยุกต์ใช้ Artificial Neural Networks (ANNs) ในงานชลประทาน, 2547

ขั้นตอนที่ 48 หา  $\Delta W_{jk}$  ตั้งรูปที่ 2.6 โดยใช้สมการ 4

$$\Delta W_{jk} = \eta \delta_{jk} O_{jk-1} + \alpha \Delta W_{jk} \dots \dots \dots (4)$$

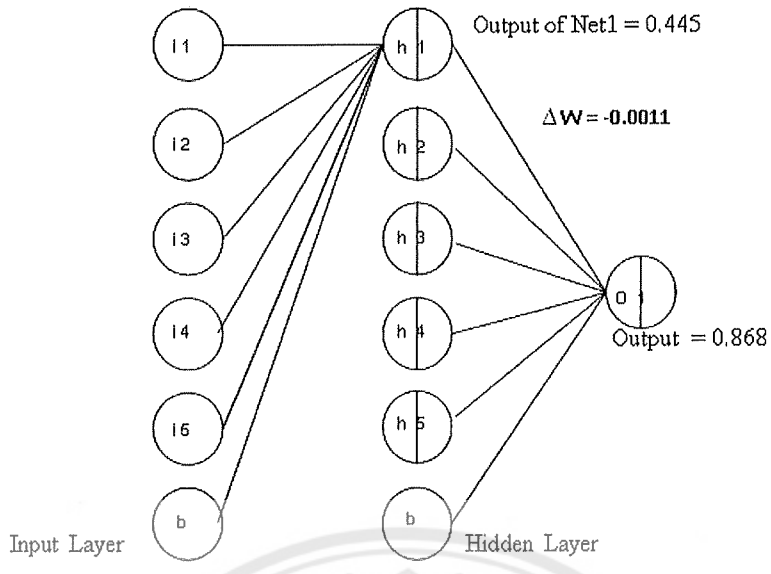
ยกตัวอย่าง  $O_1 - H_1$

$$\Delta W_{jk} = \eta \delta_{jk} O_{jk-1} + \alpha \Delta W_{jk} (n) = (0.03)(-0.083)(0.445) + (0.50)(0) = -0.0011$$

และทำวิธีเดียวกันจะได้

- $O_1 - H_2, \Delta W = -0.0015$
- $O_1 - H_3, \Delta W = -0.0010$
- $O_1 - H_4, \Delta W = -0.0015$
- $O_1 - H_5, \Delta W = -0.0016$
- $O_1 - \text{Bias}, \Delta W = -0.0025$

ว 0A  
 76  
 .9  
 .A43  
 ๙๒๑๒๖  
 ๒๕๕๙



รูปที่ 2.6 คำนวณค่าเส้นน้ำหนัก  $W_{new_{jk}}$

ที่มา: การประยุกต์ใช้ Artificial Neural Networks (ANNs) ในงานชลประทาน, 2547

ขั้นตอนที่ 49  $N = N + \Delta W_{jk}$  คือการหาผลรวมของค่า  $\Delta W_{jk}$  ของทุกค่าเส้นน้ำหนัก

ขั้นตอนที่ 50 หา  $\Delta W_{Bjk}$  โดยใช้สมการ 5

ขั้นตอนที่ 51 ปรับค่าเส้นน้ำหนัก ได้  $W_{New_{ij}}$  โดยใช้สมการ 5

$$W_{new_{ij}} = W_{ij} + \Delta W_{ij} \dots\dots\dots (5)$$

ยกตัวอย่าง Hidden 1 - ข้อมูลป้อนค่าที่ 1 (In 1) จะได้

$$W_{new_{ij}} = W_{ij} + \Delta W_{ij} = -0.15 + 0.000028 = -0.149972$$

และทำวิธีเดียวกันจะได้

$$\text{Hidden 1 - In2, } W_{new} = 1 + 0.000005 = 1.000005$$

$$\text{Hidden 1 - In3, } W_{new} = 0.15 + 0.000015 = 0.150015$$

$$\text{Hidden 1 - In4, } W_{new} = 0.25 + 0.000022 = 0.250022$$

$$\text{Hidden 1 - In5, } W_{new} = -2.14 + 0.000005 = -2.139995$$

$$\text{Hidden 1 - Bias, } W_{new} = 0.24 + 0.000093 = 2.240093$$

ขั้นตอนที่ 52 เก็บค่า  $W_{New_{ij}}$

ขั้นตอนที่ 53 ปรับค่าเส้นน้ำหนัก ได้  $W_{New_{jk}}$  โดยใช้สมการ 6

$$W_{new_{jk}} = W_{jk} + \Delta W_{jk} \dots\dots\dots (6)$$

$$O1 - H1, W_{new} = -0.15 + -0.0011 = -0.1511$$

$$O1 - H2, W_{new} = 0.35 + -0.0015 = 0.3485$$

$$O1 - H3, W_{new} = -0.25 + -0.0010 = -0.251$$

$$O1 - H4, W_{new} = 1 + -0.0015 = 0.9985$$

$$O1 - H5, W_{new} = 2.25 + -0.0016 = 2.2484$$

ขั้นตอนที่ 54 เก็บค่า  $W_{New_{ij}}$

ขั้นตอนที่ 55 ปรับค่าเส้นน้ำหนัก ได้  $W_{New_{jk}}$  โดยใช้สมการ 6

จากตัวอย่างจะได้  $O1 - W_{Bnew_{jk}} = -0.23 + -0.0025 = -0.2325$

ขั้นตอนที่ 56 เก็บค่าน้ำหนัก  $W_{Bnew_{jk}}$

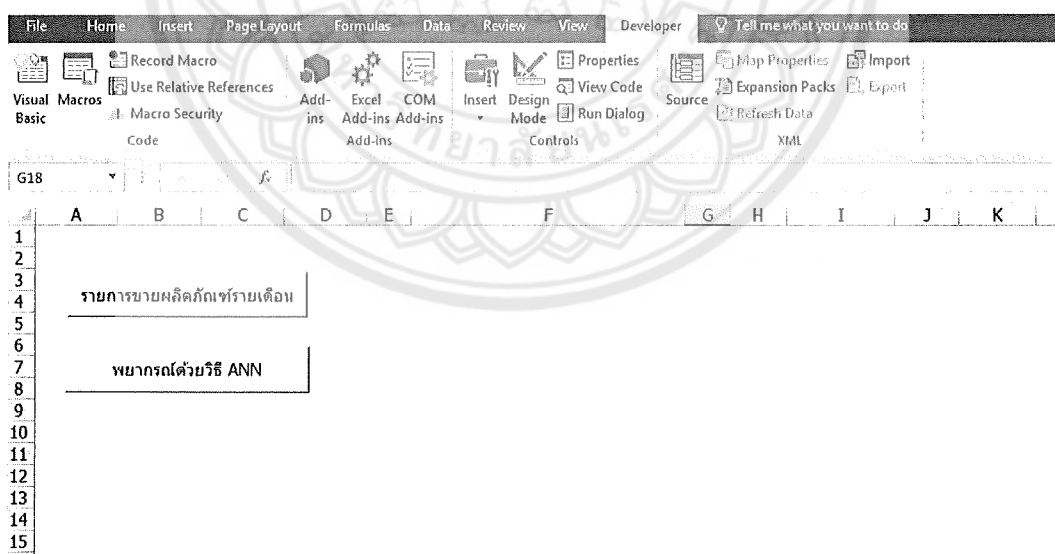
- ขั้นตอนที่ 57 ไปยัง C
- ขั้นตอนที่ 58 ไปยัง D
- ขั้นตอนที่ 59 ถึง ขั้นตอนที่ 73 ทำเหมือนขั้นตอนที่ 21 ถึง ขั้นตอนที่ 35 โดยในขั้นตอนที่ 21 นั้นจะทำการดึงข้อมูล JY > NumberData-1 แต่ในขั้นตอนที่ 39 จะทำการดึงข้อมูล JY > NumberData
- ขั้นตอนที่ 74 ไปยัง B
- ขั้นตอนที่ 75 เก็บค่าเส้นน้ำหนักของโมเดลที่ให้ค่า RMSE น้อยที่สุด
- ขั้นตอนที่ 76 นำเส้นค่าน้ำหนักไปใช้กับข้อมูลชุดทดสอบ ในงานวิจัยนี้จะเป็นข้อมูลตั้งแต่ เดือนมกราคม 2558 ถึง สิงหาคม 2558
- ขั้นตอนที่ 77 หาค่า RMSE ของชุด ทดสอบ
- ขั้นตอนที่ 78 แปลงค่า ผลลัพธ์ ที่ได้จากโมเดล
- ขั้นตอนที่ 79 ค่าพยากรณ์ที่นำไปใช้
- ขั้นตอนที่ 80 จบกระบวนการทำงานของโปรแกรม

5.5 การวิเคราะห์ผลการวิจัย โดยทำการเปรียบเทียบมูลค่าการสูญเสียโอกาสในการขายผลิตภัณฑ์ข้าวของสถานประกอบการก่อนและหลังจากใช้โปรแกรมช่วยการพยากรณ์ จะใช้ข้อมูลปริมาณการผลิตของข้าว สัดส่วนผสมของข้าวที่ต้องใช้ในการผลิต และปริมาณวัตถุดิบที่มีในคลังสินค้า โดยมีวิธีการเปรียบเทียบโดยนำปริมาณยอดขายของข้าวผสมจริงเทียบกับผลการพยากรณ์

## 6. ผลการดำเนินการวิจัย

โปรแกรมที่ใช้ในการพยากรณ์ยอดขายผลิตภัณฑ์ข้าวผสมด้วยวิธี ANN โดยใช้ภาษา Visual Basic for applications มีลักษณะดังนี้

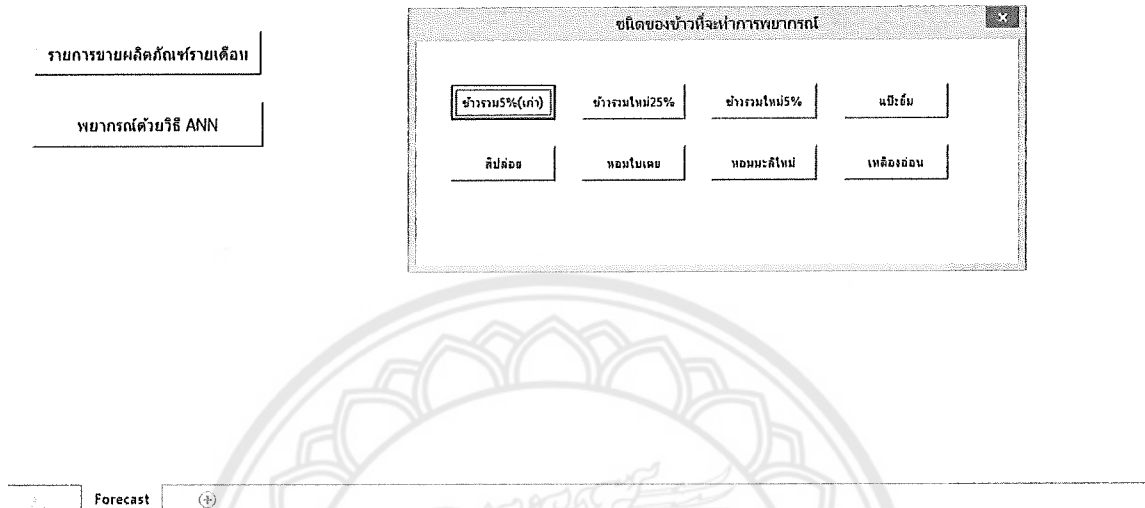
6.1 หน้าจอแรกของโปรแกรม ได้ทำการออกแบบโดยการมีฟังก์ชัน รายการขายผลิตภัณฑ์รายเดือน ซึ่งสามารถเรียกดูยอดขายแต่ละเดือนได้ และฟังก์ชันพยากรณ์ ดังรูปที่ 2.7



รูปที่ 2.7 หน้าจอแรกของโปรแกรม

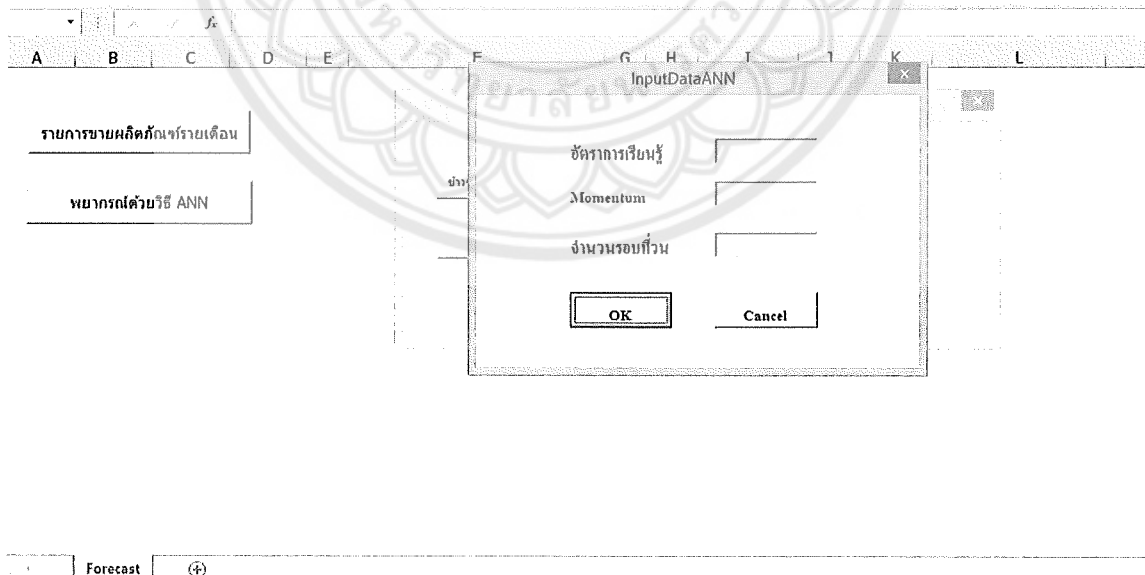
6.2 การนำเข้าของเพิ่มข้อมูล การคัดเลือกผลิตภัณฑ์ข้าวที่นำมาใช้ในการวิเคราะห์ จะทำการคัดเลือกข้าวจากการนำปริมาณข้าว (กิโลกรัม) ที่ขายได้รายปี สำหรับปี พ.ศ. 2555, 2556, และ 2557 มาทำแผนภูมิพาราโตของแต่ละปี และเลือก

ผลิตภัณฑ์ข้าวในแต่ละปี ที่อยู่ในร้อยละสะสม 90 ของปริมาณข้าว (กิโลกรัม) ที่ขายได้ทั้งหมด ทำให้ได้ผลิตภัณฑ์ข้าว 11 ชนิด ประกอบไปด้วย ข้าวรวมใหม่5%(เก่า) ข้าวรวมใหม่5% แป๊ะอีม หลีองอ่อน หอมมะลิ ข้าวรวมใหม่25% สีปล่อย หอมมะลิใหม่ หอมไบเตย หอมมะลิโรงสี และเม็ดหลีอง และเนื่องจากงานวิจัยนี้ได้ทำการศึกษาค้าวผสม สัดส่วนการผสมของผลิตภัณฑ์ที่นำมาใช้ในการศึกษา จึงหลีองข้าวที่ทำการศึกษา 8 ชนิด ดังนี้ ข้าวรวม5%(เก่า) ข้าวรวมใหม่5% แป๊ะอีม หลีองอ่อน ข้าวรวมใหม่25% สีปล่อย หอมมะลิใหม่ และหอมไบเตย ดังรูปที่ 2.8



รูปที่ 2.8 การนำเข้าแฟ้มข้อมูลขาเข้า

6.3 การกำหนดค่าพารามิเตอร์ โดยผู้ใช้งานโปรแกรม ค่าพารามิเตอร์ที่ใช้ในการคำนวณ ของวิธี ANN เพื่อให้ได้ค่าที่เหมาะสมที่สุด จะประกอบอัตราการเรียนรู้ Momentum และจำนวนรอบในวนเพื่อเรียนรู้ ดังรูปที่ 2.9



รูปที่ 2.9 การกำหนดค่าพารามิเตอร์



6.4 การแสดงผลลัพธ์ ออกแบบให้สามารถแสดงผล ค่า ANN ของชุดฝึกฝน ค่า ANN ของชุดทดสอบ ค่าการพยากรณ์ จำนวนรอบวนการวนที่ที่ดีที่สุด ค่า RMSE ของชุดฝึกฝน และค่า RMSE ของชุดทดสอบ ดังรูปที่ 2.10

จากภาพ 2.10 แสดง ชนิดของข้าว เป็นข้าวสีปล้อย มีผล ANN ของชุดฝึกฝน 24 เดือน และของชุดทดสอบ 8 เดือน ซึ่งค่า ANN ของเดือนกันยายน 2557 จะอยู่ที่ 0.267588 และค่าพยากรณ์พยากรณ์หลังจากการแปลงข้อมูลกลับของเดือนกันยายน 2557 จะอยู่ที่ 9931.72 ตัน จำนวนการวนรอบที่ดีที่สุด คือ 1 รอบ มีค่า RMSE ของชุดฝึกฝน 0.14 และ ชุดทดสอบ 0.13 และในภาพ 2.11 เป็นผลการพยากรณ์ของข้าวเหลืองอ่อน ซึ่งจะพบว่า ค่า RMSE ของชุดทดสอบที่ได้มีผ่านการฝึกฝนมาแล้วนั้นเพื่อนำมาใช้งานจริง มีค่า RMSE ต่ำกว่าชุดฝึกฝน เนื่องจากกระบวนการเรียนรู้ของโครงข่ายประสาทเทียม

ชนิดข้าว	ANN	ANN OF TEST DATA	Forecast of ANN (Unit: Metric Ton)	Iteration number	RMSE OF TRAINING	RMSE OF TEST DATA
สีปล้อย	0.262362	0.263793	10,485.90	1.00	0.1428620	0.13
	0.262561	0.255330	9,094.81			
	0.265158	0.267755	11,137.11			
	0.267111	0.262107	10,200.67			
	0.261161	0.258959	9,691.29			
	0.264508	0.257917	9,520.06			
	0.262134	0.259224	9,570.41			
	0.260031	0.260422	9,931.72			
	0.260666					
	0.264059					
	0.260942					
	0.259918					
	0.261350					
	0.257673					
	0.258992					
	0.264619					
	0.258219					
	0.258326					
	0.265229					
	0.258127					
	0.267504					
	0.260559					
	0.264072					
	0.264978					

รูปที่ 2.10 ผลการพยากรณ์

ชนิดข้าว	ANN	ANN OF TEST DATA	Forecast of ANN (Unit: Metric Ton)	Iteration number	RMSE OF TRAINING	RMSE OF TEST DATA
เหลืองอ่อน	0.294287	0.298976	26,515.90	1.00	0.1851367	0.15
	0.294071	0.300934	26,799.19			
	0.293567	0.296795	25,931.59			
	0.295391	0.297911	26,230.57			
	0.294466	0.299682	26,705.02			
	0.292020	0.300258	26,859.26			
	0.292430	0.303590	27,751.85			
	0.291034	0.291122	24,411.81			
	0.293792					
	0.293809					
	0.293299					
	0.293652					
	0.295083					
	0.295837					
	0.294397					
	0.295147					
	0.294963					
	0.293663					
	0.294641					
	0.295793					
	0.293407					
	0.297090					
	0.302609					
	0.296006					

รูปที่ 2.11 ผลการพยากรณ์

### 6.5 ผลการวิเคราะห์ด้านมูลค่าการสูญเสียโอกาสในการขายผลิตภัณฑ์ข้าวผสม มี 2 กรณีคือ

6.5.1 ค่าพยากรณ์โดยจากการคาดคะเนของทางสถานประกอบการซึ่งได้จากการประมาณจากยอดขายเดือนที่แล้ว คือ 100,000 กิโลกรัม ค่าพยากรณ์ยอดขายด้วยวิธี ANN คือ 120,548 กิโลกรัม ซึ่งยอดขายจริงเท่ากับ 130,540 กิโลกรัม จึงพบว่า ค่าพยากรณ์ยอดขายด้วยวิธี ANN สามารถช่วยลดมูลค่าการสูญเสียโอกาสในการขายผลิตภัณฑ์ข้าวผสมได้ ดังนี้

$$\begin{aligned} & \text{ค่าการสูญเสียโอกาสในการขายผลิตภัณฑ์ข้าวผสมจากการพยากรณ์ด้วยวิธี ANN} \\ &= 130,540 - 120,548 \\ &= 9,992 \text{ กิโลกรัม} \end{aligned}$$

$$\begin{aligned} & \text{ค่าการสูญเสียโอกาสในการขายผลิตภัณฑ์ข้าวผสมจากการคาดคะเนของทางสถานประกอบการ} \\ &= 130,540 - 100,000 \\ &= 30,540 \text{ กิโลกรัม} \end{aligned}$$

6.5.2 ค่าพยากรณ์โดยจากการคาดคะเนของทางสถานประกอบการซึ่งได้จากการประมาณจากยอดขายเดือนที่แล้ว คือ 88,065 กิโลกรัม ค่าพยากรณ์ยอดขายด้วยวิธี ANN คือ 36,295 กิโลกรัม ซึ่งยอดขายจริงเท่ากับ 28,069 กิโลกรัม จึงไม่เกิดการสูญเสียโอกาสในการขายผลิตภัณฑ์ข้าวผสม แต่การพยากรณ์ยอดขายด้วยวิธี ANN สามารถช่วยลดปริมาณของสินค้าคงคลังได้ดังนี้

$$\begin{aligned} & \text{ปริมาณของสินค้าคงคลังจากการพยากรณ์ด้วยวิธี ANN} = 36,295 - 28,069 \\ &= 8,226 \text{ กิโลกรัม} \end{aligned}$$

$$\begin{aligned} & \text{ปริมาณของสินค้าคงคลังจากการคาดคะเนของทางสถานประกอบการ} = 88,065 - 28,069 \\ &= 59,996 \text{ กิโลกรัม} \end{aligned}$$

## 7. สรุปผลการวิจัย

งานวิจัยนี้ทำการพัฒนาโปรแกรมช่วยการพยากรณ์ยอดขายผลิตภัณฑ์ข้าวผสม โดยการประยุกต์ใช้วิธีเมตาฮิวริสติกส์ คือ โครงข่ายประสาทเทียม (Artificial Neural Network: ANN) ซึ่งพบว่า ค่าพยากรณ์ที่ได้จากวิธี ANN ให้ค่า RMSE น้อยกว่า 0.2 นั่นคือ โมเดลของการพยากรณ์ด้วยวิธี ANN มีความแม่นยำอยู่ที่ร้อยละ 80 ซึ่งสามารถนำไปสู่การลดมูลค่าการสูญเสียโอกาสในการขายผลิตภัณฑ์ข้าวผสม ลดปริมาณสินค้าคงคลัง และช่วยในการวางแผนการผลิต โดยในปัจจุบันทางสถานประกอบการไม่มีการใช้เทคนิคการพยากรณ์เข้ามาช่วยในการวางแผนการผลิต ปริมาณผลิตได้มาจากการคาดคะเนตามประสบการณ์ของผู้วางแผนการผลิต ซึ่งอาจทำให้ปริมาณผลผลิตที่ได้นั้นเกินปริมาณความต้องการจริงของลูกค้า ทำให้เกิดปริมาณสินค้าคงคลังมากเกินไป ในทางตรงกันข้าม การประมาณการปริมาณการผลิตมีค่าน้อยกว่าความต้องการจริง อาจก่อให้เกิดการสูญเสียโอกาสในการขายผลิตภัณฑ์ได้ อย่างไรก็ตาม ค่าพยากรณ์สามารถมีค่าคลาดเคลื่อนจากปริมาณความต้องการจริงของลูกค้าได้ แต่จะช่วยลดความรุนแรงของผลกระทบที่จะเกิดขึ้นกับสถานประกอบการได้

## เอกสารอ้างอิง

- กาญจนา กล้าแข็ง.(2538). ประดิษฐ์ พงศ์ทองคำ และกัมปนาท มุขดี. ผลผลิตและคุณภาพของข้าว Polyploids Yield And Quality Of Polyploid Rice. วารสารวิทยาศาสตร์และเทคโนโลยี. 4(1): 79-90.
- ไกรพล ภักดีภูวนารถ. (2556). การศึกษาปัญหาและต้นทุนด้านโลจิสติกส์ของธุรกิจโรงสีข้าวในเขตภาคเหนือตอนล่าง. วิทยานิพนธ์ วท.ม., มหาวิทยาลัยนเรศวร, พิษณุโลก
- กรมชลประทาน กระทรวงเกษตรและสหกรณ์ (2547).การประยุกต์ใช้ระบบโครงข่ายประสาทเทียม Artificial Neural Networks (ANNs).สถาบันพัฒนาการชลประทาน สำนักวิจัยและพัฒนากรมชลประทาน กระทรวงเกษตรและสหกรณ์, กรุงเทพฯ
- ชลธิชา กิ่งกลาง.(2552).ปัจจัยที่มีอิทธิพลต่อพฤติกรรมการเลือกซื้อข้าวหอมมะลิบรรจุถุงของผู้บริโภคในเขตจังหวัดปทุมธานี. วารสารวิชาการมหาวิทยาลัยอีสเทิร์นเอเชีย ฉบับวิทยาศาสตร์และเทคโนโลยี.3.254-259
- ทวี บุญภิรมย์.(2558).ผลของระยะปลูกต่อการเจริญเติบโตและผลผลิตของข้าวหอมกระดังงา. วารสารมหาวิทยาลัยนราธิวาสราชนครินทร์. 7(3).115-120
- ธัญชนก ภาคสกุล และพีระยศ แข็งขัน.(2557). การเปรียบเทียบสภาพการผลิตและปัญหาในการผลิตเมล็ดพันธุ์ข้าวของเกษตรกรสมาชิกศูนย์ข้าวชุมชนระดับต้องปรับปรุงและระดับดีมากในจังหวัดร้อยเอ็ด. วารสารวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยมหาสารคาม. 33(5): 472-479.
- ธนาวุฒิ ประกอบผล.(2552). โครงข่ายประสาทเทียม Artificial Neural Networks. วารสาร มฉก. วิชาการ มหาวิทยาลัยหัวเฉียวเฉลิมพระเกียรติ.12(24): 73-87.
- นิฉา แก้วทาวงษ์.(2547).การศึกษาเปรียบเทียบการพยากรณ์ข้อมูลอนุกรมโดยวิธีการทำให้เรียบแบบเอ็กซ์โปเนนเชียลและวิธีการของบ็อกซ์-เจนกินส์ : กรณีศึกษาการพยากรณ์มูลค่าการส่งออกข้าว ยางพารา และมันสำปะหลัง.วารสารวิทยาศาสตร์ มหาวิทยาลัยนเรศวร.3(2).73-90.
- นิลวรรณ ชุ่มฤทธิ์(2554). สถิติวิศวกรรม . (1). กรุงเทพฯ: ซีเอ็ดดูเคชั่น.
- นันทน์ภัส แสงศรี(2554).ปัจจัยที่มีผลต่อการตัดสินใจบริโภคข้าวสารอินทรีย์ในเขตกรุงเทพมหานคร.สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง, กรุงเทพฯ
- บัญชา ลาวัง, สมศักดิ์ คูหาสวรรค์ และอัครงค์ เมฆโหรา.(2556).การทดสอบหาเทคโนโลยีที่เหมาะสมในการผลิตข้าวไม่ต้องหุง. วารสารเกษตรพระจอมเกล้า.31(3).25-32
- ปวีณา กองจันทร์, สันติ เต็มประเสริฐกุล และวิไลพร ไพศาล.(2551).การพยากรณ์ภาวะล้มละลายของอุตสาหกรรมโรงสีข้าว ในจังหวัดขอนแก่น และจังหวัดนครราชสีมา.Asia-Pacific Journal of Science and Technology.13(11). 1273-1287.
- ปารเมศ ชูติมา.(2545). การออกแบบการทดลองทางวิศวกรรม. (1). กรุงเทพฯ: จุฬาลงกรณ์มหาวิทยาลัย.
- ประไพศรี สุทัศน์ ณ อยุธยา และพงศ์ชนัน เหลืองไพบูลย์(2551). การออกแบบและวิเคราะห์การทดลอง. (1). กรุงเทพฯ: ห้อป.รดา อิมคิลป์, ปัญญา หมั่นเก็บ, และอัครงค์ เมฆโหรา. (2554).การศึกษาเปรียบเทียบต้นทุนโลจิสติกส์ของโซุ่ปทานข้าวสวนดุสิต และโรงสีข้าวสหกรณ์การเกษตรเพชรบูรณ์ จังหวัดร้อยเอ็ด. วารสารเกษตรพระจอมเกล้า. 29(3-1):1-10.
- พันเลิศ พรหมมาตย์, กิมาพร ชมะณะรงค์ และสุรนาท ชมะณะรงค์.(2555).ความสัมพันธ์ระหว่างการบริโภคกับการจำหน่ายข้าวสำเร็จรูปในตลาดต่างประเทศ.วารสารวิจัย มข. (ฉบับบัณฑิตศึกษา).12(3).157-166
- พยุง มีสังข์(ผู้บรรยาย). (2551).โครงข่ายประสาทเทียม.ใน ระบบฟัชซีและโครงข่ายประสาทเทียม รหัสวิชา 701801(หน้า 1-12). กรุงเทพฯ: คณะเทคโนโลยีสารสนเทศ สถาบันเทคโนโลยีพระจอมเกล้าพระนครเหนือ.
- พรนภา มูลิกพันธ์.(2556). วิธีการคำนวณที่ถูกปรับปรุงสำหรับการจัดตารางการผลิตสินค้าขนาดใหญ่.วิทยานิพนธ์ วท.ม., มหาวิทยาลัยนเรศวร, พิษณุโลก
- ภูพงษ์ พงษ์เจริญ(ผู้บรรยาย). (2556).การควบคุมของคงคลัง. ใน เอกสารประกอบการเรียนการวางแผนและการควบคุมการผลิต (หน้า 119-151). พิษณุโลก: มหาวิทยาลัยนเรศวร
- ภราดร กาญจนสุธรรม, นิพนธ์ ตั้งธรรม และเรืองโร โตกฤษณะ.(2557).การประมาณผลผลิตต่อไร่ของข้าวนาปรังด้วยข้อมูลดาวเทียม SMMS โดยใช้ดัชนีความแตกต่างพืชพรรณ (NDVI) กรณีศึกษาอำเภอเมือง.วารสารวิทยาศาสตร์และเทคโนโลยี .จังหวัดสุพรรณบุรี.22(1).55-56.

- วารภรณ์ วงศ์บุญ และจิรพงศ์ ไจรินทร์. (2550).แนวทางการเพิ่มผลผลิตข้าวโดย System of Rice Intensification (SRI). *แก่นเกษตร*. 35(1): 1-5.
- วุฒิไกร มีพัฒน์, อัจฉรัตน์ สุวรรณภักดี และอมรรัตน์ ถนนแก้ว.(2557).การศึกษาความพร้อมของโรงสีข้าวสังข์หยดในจังหวัดพัทลุง เพื่อการพัฒนาเข้าสู่หลักเกณฑ์วิธีการผลิตที่ดี.วารสารวิจัย มหาวิทยาลัยเทคโนโลยีราชมงคลศรีวิชัย.6(2).12-24
- วงศ์พัฒนา ศรีประเสริฐ.(2558).การจัดการวางแผนการตลาดเชิงกลยุทธ์ธุรกิจแปรรูป ผลิตภัณฑ์ข้าวกล้องอินทรีย์ของกลุ่มผู้ผลิตในชุมชนบ้านมะค่า ตำบลมะค่า อำเภอกันทรวิชัย จังหวัดมหาสารคาม. *SNRU Journal of Science and Technology*.7(13).45-66.
- วงศ์พัฒนา ศรีประเสริฐ.(2557). การวิเคราะห์ความเป็นไปได้ในการลงทุนธุรกิจแปรรูปผลิตภัณฑ์ข้าวกล้องอินทรีย์ของผู้ผลิตบ้านมะค่า ตำบลมะค่า อำเภอกันทรวิชัย จังหวัดมหาสารคาม.วารสารวิชาการ มหาวิทยาลัยราชภัฏอุตรดิตถ์.9(2). 279-295.
- วิทยา สุทธิดำรง.(2546). การจัดการโซ่อุปทาน ดำารการจัการยุคใหม่. (2). กรุงเทพฯ: เพียร์สัน เอ็ดดูเคชั่น อินโดไชน่า.
- ศุภณัฐ เตชะนวิชัย, อติคุณ กาญจนพิบูลย์ และจิระเสกข์ ตรีเมธสุนทร.(2552).ปัญหาการดำเนินงานของผู้ส่งออกข้าวในประเทศไทย.วารสารเศรษฐศาสตร์อุตสาหกรรม.8(2).205-214.
- สุวรรณ ภัทรเบญจพล.(2557).การสำรวจตลาดของผลิตภัณฑ์ เพื่อสุขภาพที่ผลิตจากข้าวอินทรีย์ที่มีสี.วารสารเภสัชศาสตร์อีสาน.10(3).307-321.
- สนั่น เกษารีย์ และ ผู้ช่วยศาสตราจารย์ ดร. ระพีพันธ์ ปิตาคะโส.(2555).การจัดการโลจิสติกส์และโซ่อุปทานข้าวในภาคตะวันออกเฉียงเหนือของประเทศไทย. *Asia-Pacific Journal of Science and Technology* .17(1): 125-141.
- สนั่น เกษารีย์ และ ผู้ช่วยศาสตราจารย์ ดร. ระพีพันธ์ ปิตาคะโส.(2555).การประยุกต์ใช้แผนผังสายธารคุณค่าในการเพิ่มประสิทธิภาพการจัดการโลจิสติกส์และโซ่อุปทานข้าวในภาคตะวันออกเฉียงเหนือของประเทศไทย. *Asia-Pacific Journal of Science and Technology* .17(5): 687-705.
- สำราญ เชื้อเมืองพาน, เจษฎา มิ่งฉาย และชัชญาสุ์ ช่างเรียน.(2557).การพัฒนาขีดความสามารถของกลุ่มเกษตรกรผลิตข้าวอินทรีย์ ตามมาตรฐานสากลเพื่อสุขภาพในพื้นที่จังหวัดอุตรดิตถ์.วารสารวิชาการ มหาวิทยาลัยราชภัฏอุตรดิตถ์.9. 345-366.
- สมชาติ โสภณธรรมฤทธิ์, ชัยยงค์ เตชะไพโรจน์ และสมเกียรติ ปรัชญาวารการ.(2547).เทคนิคใหม่ในการผลิตข้าวหนึ่ง.วารสารราชบัณฑิตยสถาน.29(1).78-86.
- อาทิตย์ อภิโชติชนกุล, ศุภชัย ปทุมนากุล และกัลปพฤกษ์ ผิวทองงาม.(2552). การพยากรณ์ความต้องการข้าวไทยจากต่างประเทศ โดยใช้โครงข่ายประสาทเทียม. *วิศวกรรมสาร มช.*. 36(1): 17-26.
- อรรธรณ ศรีโสมพันธ์.(2556).การวิเคราะห์การส่งผ่านราคาข้าวเหนียวในประเทศไทย” *แก่นเกษตร*. 41(1): 9-16.
- Adhikari, R., and Agrawal, R. K. (2012). Forecasting strong seasonal time series with artificial neural networks. *Journal of Scientific & Industrial Research*, 71(10), 657-666.
- Agrawal, N., and Smith, S. A. (2013). Optimal inventory management for a retail chain with diverse store demands. *European Journal of Operational Research*, 225(3), 393-403.
- Al-Wazan, H., Ibraheem, K., and Salim, A.-G. (2014). A Hybrid Algorithm to Forecast Enrolment Based on Genetic Algorithms and Fuzzy Time Series. *International Arab Journal of Information Technology*, 11(3), 250-257.
- Alberiko Gil-Alana, L., Barros, C. P., and Assaf, A. (2014). Retail sales: persistence in the short-term and long-term dynamics. *Ima Journal of Management Mathematics*, 25(3), 367-386.
- Arunraj, N. S., and Ahrens, D. (2015). A hybrid seasonal autoregressive integrated moving average and quantile regression for daily food sales forecasting. *International Journal of Production Economics*, 170, 321-335.
- Aytac, B., and Wu, S. D. (2013). Characterization of demand for short life-cycle technology products. *Annals of Operations Research*, 203(1), 255-277.

- Azadeh, S. S., Marcotte, P., and Savard, G. (2015). A non-parametric approach to demand forecasting in revenue management. *Computers & Operations Research*, 63, 23-31.
- Boylan, J. E., Chen, H., Mohammadipour, M., and Syntetos, A. (2014). Formation of seasonal groups and application of seasonal indices. *Journal of the Operational Research Society*, 65(2), 227-241.
- Buchmeister, B., Friscic, D., Lalic, B., and Palcic, I. (2012). ANALYSIS OF A THREE-STAGE SUPPLY CHAIN WITH LEVEL CONSTRAINTS. *International Journal of Simulation Modelling*, 11(4), 196-210.
- Bulut, E. (2014). Modeling seasonality using the fuzzy integrated logical forecasting (FILF) approach. *Expert Systems with Applications*, 41(4), 1806-1812.
- Cang, S., and Yu, H. (2014). A combination selection algorithm on forecasting. *European Journal of Operational Research*, 234(1), 127-139.
- Carmona Benitez, R. B., Carmona Paredes, R. B., Lodewijks, G., and Nabais, J. L. (2013). Damp trend Grey Model forecasting method for airline industry. *Expert Systems with Applications*, 40(12), 4915-4921.
- Caro, F., and Gallien, J. (2010). Inventory Management of a Fast-Fashion Retail Network. *Operations Research*, 58(2), 257-273.
- Caro, F., and Gallien, J. (2012). Clearance Pricing Optimization for a Fast-Fashion Retailer. *Operations Research*, 60(6), 1404-1422.
- Carrizosa, E., Olivares-Nadal, A. V., and Ramirez-Cobo, P. (2013). Time series interpolation via global optimization of moments fitting. *European Journal of Operational Research*, 230(1), 97-112.
- Carrizosa, E., Olivares-Nadal, A. V., and Ramirez-Cobo, P. (2016). Robust newsvendor problem with autoregressive demand. *Computers & Operations Research*, 68, 123-133.
- Chan, F. T. S., Samvedi, A., and Chung, S. H. (2015). Fuzzy time series forecasting for supply chain disruptions. *Industrial Management & Data Systems*, 115(3), 419-435.
- Cheaitou, A., Jemai, Z., Dallery, Y., and van Delft, C. (2010). Two-stage flexible supply contract with payback and information update. *European Journal of Industrial Engineering*, 4(4), 471-492.
- Chen, T.-L., and Lu, H.-C. (2012). Stochastic multi-site capacity planning of TFT-LCD manufacturing using expected shadow-price based decomposition. *Applied Mathematical Modelling*, 36(12), 5901-5919.
- Cheng, C. Q., Sa-Ngasoongsong, A., Beyca, O., Le, T., Yang, H., Kong, Z. Y., and Bukkapatnam, S. T. S. (2015). Time series forecasting for nonlinear and non-stationary processes: a review and comparative study. *IIE Transactions*, 47(10), 1053-1071.
- Cho, D. W., and Lee, Y. H. (2012). Bullwhip effect measure in a seasonal supply chain. *Journal of Intelligent Manufacturing*, 23(6), 2295-2305.
- Cho, D. W., and Lee, Y. H. (2013). SEASONAL SUPPLY CHAIN AND THE BULLWHIP EFFECT. *International Journal of Industrial Engineering-Theory Applications and Practice*, 20(1-2), 188-210.
- Choi, T.-M. (2013). Optimal apparel supplier selection with forecast updates under carbon emission taxation scheme. *Computers & Operations Research*, 40(11), 2646-2655.
- Choi, T.-M., Hui, C.-L., Liu, N., Ng, S.-F., and Yu, Y. (2014). Fast fashion sales forecasting with limited data and time. *Decision Support Systems*, 59, 84-92.
- Choi, T.-M., Yu, Y., and Au, K.-F. (2011). A hybrid SARIMA wavelet transform method for sales forecasting. *Decision Support Systems*, 51(1), 130-140.
- Chung, C., Niu, S.-C., and Sriskandarajah, C. (2012). A Sales Forecast Model for Short-Life-Cycle Products: New Releases at Blockbuster. *Production and Operations Management*, 21(5), 851-873.

- Co, H. C., and Boosarawongse, R. (2007). Forecasting Thailand's rice export: Statistical techniques vs. artificial neural networks. *Computers & Industrial Engineering*, 53(4), 610-627.
- Coghlan, A. (2015). *A Little Book of R For Time Series*.
- Corberan-Vallet, A., Bermudez, J. D., and Vercher, E. (2013). Bayesian forecasting of demand time-series data with zero values. *European Journal of Industrial Engineering*, 7(6), 777-796.
- Cybenko, G., (1989). Approximation by superpositions of a sigmoidal function. *Mathematics of Control, Signals, and Systems* 2, 303-314.
- Decker, R., and Gribba-Yukawa, K. (2010). Sales Forecasting in High-Technology Markets: A Utility-Based Approach. *Journal of Product Innovation Management*, 27(1), 115-129.
- DeYong, G. D., and Cattani, K. D. (2012). Well adjusted: Using expediting and cancelation to manage store replenishment inventory for a seasonal good. *European Journal of Operational Research*, 220(1), 93-105.
- Dindarloo, S. (2016). Reliability Forecasting of a Load-Haul-Dump Machine: A Comparative Study of ARIMA and Neural Networks. *Quality and Reliability Engineering International*, 32(4), 1545-1552.
- Du, X. F., Leung, S. C. H., Zhang, J. L., and Lai, K. K. (2013). Demand forecasting of perishable farm products using support vector machine. *International Journal of Systems Science*, 44(3), 556-567.
- Efendigil, T., and Onut, S. (2012). An integration methodology based on fuzzy inference systems and neural approaches for multi-stage supply-chains. *Computers & Industrial Engineering*, 62(2), 554-569.
- Egrioglu, E., Yolcu, U., Aladag, C. H., and Kocak, C. (2013). An ARMA Type Fuzzy Time Series Forecasting Method Based on Particle Swarm Optimization. *Mathematical Problems in Engineering*.
- ElHafsi, M., Camus, H., and Craye, E. (2010). Managing an integrated production inventory system with information on the production and demand status and multiple non-unitary demand classes. *European Journal of Operational Research*, 207(2), 986-1001.
- Funahashi, K., 1989. On the approximate realization of continuous mappings by neural networks. *Neural Networks* 2, 183-192.
- Gamberini, R., Lolli, F., Rimini, B., and Sgarbossa, F. (2010). Forecasting of Sporadic Demand Patterns with Seasonality and Trend Components: An Empirical Comparison between Holt-Winters and (S)ARIMA Methods. *Mathematical Problems in Engineering*.
- Garetti, M., & Taisch, M. (1999). Neural networks in production planning and control. *Production Planning and Control*, 10(4), 324-339.
- Gribba-Yukawa, K., and Decker, R. (2012). Comments on the Model Testing by Goodwin and Meeran (2012): Comparison of the Utility-based and the Gompertz Curve Approach for High-technology Product Sales Forecasting. *Journal of Product Innovation Management*, 29, 219-228.
- Gomes, G. S. d. S., and Ludermir, T. B. (2013). Optimization of the weights and asymmetric activation function family of neural network for time series forecasting. *Expert Systems with Applications*, 40(16), 6438-6446.
- Goodwin, P., and Meeran, S. (2012). Robust Testing of the Utility-based High-technology Product Sales Forecasting Models Proposed by Decker and Gribba-Yukawa (2010). *Journal of Product Innovation Management*, 29, 211-218.
- Guo, W. W., and Xue, H. (2014). Crop Yield Forecasting Using Artificial Neural Networks: A Comparison between Spatial and Temporal Models. *Mathematical Problems in Engineering*.
- Hwang, W.-Y., and Lee, J.-S. (2014). A new forecasting scheme for evaluating long-term prediction performances in supply chain management. *International Transactions in Operational Research*, 21(6), 1045-1060.

- Ind Res, I. (2015). 2015 R&D Trends Forecast Results from the Industrial Research Institute's Annual Survey. *Research-Technology Management*, 58(1), 24-35.
- Ind Res, I. (2016). 2016 R&D Trends Forecast Results from the Industrial Research Institute's Annual Survey. *Research-Technology Management*, 59(1), 30-38.
- Khoshnevisan, B., Rafiee, S., and Mousazadeh, H. (2014). Application of multi-layer adaptive neuro-fuzzy inference system for estimation of greenhouse strawberry yield. *Measurement*, 47, 903-910.
- Khoshnevisan, B., Rafiee, S., Omid, M., Mousazadeh, H., and Sefeedpari, P. (2013). Prognostication of environmental indices in potato production using artificial neural networks. *Journal of Cleaner Production*, 52, 402-409.
- Kim, B.-S., 김재환, and Seong-Bo, K. (2013). An Approach for Improvement of Goodness of Fit on the Estimation of Paddy Rice Yield Using Satellite(MODIS) Images. *Journal of Korea Academia-Industrial cooperation Society*, 14(11), 5417-5422.
- King, M. A., Abrahams, A. S., and Ragsdale, C. T. (2014). Ensemble methods for advanced skier days prediction. *Expert Systems with Applications*, 41(4), 1176-1188.
- Kourentzes, N. (2014). On intermittent demand model optimisation and selection. *International Journal of Production Economics*, 156, 180-190.
- Kulkarni, S., Ponnaiyan, S., and Tarakci, H. (2015). Optimal ordering decisions under two returns policies. *International Journal of Production Research*, 53(12), 3720-3734.
- Kuo, C., & Reitsch, A. (1995). Neural networks vs. conventional methods of forecasting. *Journal of Business Forecasting, Methods and Systems*, 14(4), 17-22.
- Kuthambalayan, T. S., Mehta, P., and Shanker, K. (2015). Managing product variety with advance selling and capacity restrictions. *International Journal of Production Economics*, 170, 287-296.
- Lapedes, A., & Farber, R. (1987). Nonlinear Signal Processing Neural Information Processing System – Natural and Synthetic.
- Lee, C. Y., and Chiang, M. C. (2016). Aggregate demand forecast with small data and robust capacity decision in TFT-LCD manufacturing. *Computers & Industrial Engineering*, 99, 415-422.
- Leon, F., and Zaharia, M. H. (2010). Stacked Heterogeneous Neural Networks for Time Series Forecasting. *Mathematical Problems in Engineering*.
- Li, B., Li, J., Li, W., and Shirodkar, S. A. (2012a). Demand forecasting for production planning decision-making based on the new optimised fuzzy short time-series clustering. *Production Planning & Control*, 23(9), 663-673.
- Li, D.-C., Chen, C.-C., Chen, W.-C., and Chang, C.-J. (2012b). Employing dependent virtual samples to obtain more manufacturing information in pilot runs. *International Journal of Production Research*, 50(23), 6886-6903.
- Li, D.-C., Chen, W.-C., Liu, C.-W., and Lin, Y.-S. (2012c). A non-linear quality improvement model using SVR for manufacturing TFT-LCDs. *Journal of Intelligent Manufacturing*, 23(3), 835-844.
- Li, D.-C., Fang, Y.-H., Liu, C.-W., and Juang, C.-j. (2012d). Using past manufacturing experience to assist building the yield forecast model for new manufacturing processes. *Journal of Intelligent Manufacturing*, 23(3), 857-868.
- Li, H., Armbruster, D., and Kempf, K. G. (2013). A Population-Growth Model for Multiple Generations of Technology Products. *M&Som-Manufacturing & Service Operations Management*, 15(3), 343-360.
- Li, J., Wang, M., Zhou, W., and Zhou, W. (2014a). Outsourcing decision and order policy with forecast updating under capacity reservation contract. *Journal of Systems Science and Systems Engineering*, 23(1), 39-79.

- Li, Y., Li, C., and Zheng, M. (2014b). A Hybrid Neural Network and H-P Filter Model for Short-Term Vegetable Price Forecasting. *Mathematical Problems in Engineering*.
- Lin, J. T., Wu, C.-H., Chen, T.-L., and Shih, S.-H. (2011). A stochastic programming model for strategic capacity planning in thin film transistor-liquid crystal display (TFT-LCD) industry. *Computers & Operations Research*, 38(7), 992-1007.
- Liu, C., Wang, Z., Fu, H., and Zhang, Y. (2014a). A Novel Approach for Nonstationary Time Series Analysis with Time-Invariant Correlation Coefficient. *Mathematical Problems in Engineering*.
- Liu, H.-T., and Wei, M.-L. (2010). An improved fuzzy forecasting method for seasonal time series. *Expert Systems with Applications*, 37(9), 6310-6318.
- Liu, N., Ren, S., Choi, T.-M., Hui, C.-L., and Ng, S.-F. (2013). Sales Forecasting for Fashion Retailing Service Industry: A Review. *Mathematical Problems in Engineering*.
- Liu, Y., Gong, B., Xing, C., and Jian, Y. (2014b). A Virtual Machine Migration Strategy Based on Time Series Workload Prediction Using Cloud Model. *Mathematical Problems in Engineering*.
- Ljung, G. M., Ledolter, J., and Abraham, B. (2014). George Box's contributions to time series analysis and forecasting. *Applied Stochastic Models in Business and Industry*, 30(1), 25-35.
- Ma, L., Zhao, Y., Xue, W., Cheng, T. C. E., and Yan, H. (2012). Loss-averse newsvendor model with two ordering opportunities and market information updating. *International Journal of Production Economics*, 140(2), 912-921.
- Ma, M., Liu, J., and Cao, J. (2014). Short-Term Forecasting of Railway Passenger Flow Based on Clustering of Booking Curves. *Mathematical Problems in Engineering*.
- Martin, K., Chitalia, P., Pugalenti, M., Rau, K. R., Maity, S., Kumar, R., Saksena, R., Hebbar, R., Krishnan, M., Hegde, G., Kesanapally, C., Bimbraw, T. K., and Subramanian, S. (2014). Dell's Channel Transformation: Leveraging Operations Research to Unleash Potential Across the Value Chain. *Interfaces*, 44(1), 55-69.
- Mostard, J., Teunter, R., and de Koster, R. (2011). Forecasting demand for single-period products: A case study in the apparel industry. *European Journal of Operational Research*, 211(1), 139-147.
- Montgomery and Runger. (2007). *Engineering statistics*. New York, N.Y.: John Wiley & Sons.
- Montgomery. (2001). *Introduction to statistical quality control*. New York, N.Y.: John Wiley & Sons.
- Ni, Y., and Fan, F. (2011). A two-stage dynamic sales forecasting model for the fashion retail. *Expert Systems with Applications*, 38(3), 1529-1536.
- Nooraie, S. V., and Parast, M. M. (2015). A multi-objective approach to supply chain risk management: Integrating visibility with supply and demand risk. *International Journal of Production Economics*, 161, 192-200.
- Novak, V., Stepnicka, M., Dvorak, A., Perfilieva, I., Pavliska, V., and Vavrickova, L. (2010). Analysis of seasonal time series using fuzzy approach. *International Journal of General Systems*, 39(3), 305-328.
- Özçelik, R., Diamantopoulou, M.J., Brooks, J.R., Wiant Jr., H.V., (2010). Estimating tree bole volume using artificial neural network models for four species in Turkey. *Journal of Environmental Management*, 91, 742e753.
- Pai, P.-F., Hung, K.-C., and Lin, K.-P. (2014). Tourism demand forecasting using novel hybrid system. *Expert Systems with Applications*, 41(8), 3691-3702.
- Pai, P.-F., Lin, K.-P., Lin, C.-S., and Chang, P.-T. (2010). Time series forecasting by a seasonal support vector regression model. *Expert Systems with Applications*, 37(6), 4261-4265.
- Panahifar, F., Byrne, P. J., and Heavey, C. (2014). ISM analysis of CPFR implementation barriers. *International Journal of Production Research*, 52(18), 5255-5272.



- Pereira Salazar, D. S., Leitao Adeodato, P. J., and Arnaud, A. L. (2014). Continuous Dynamical Combination of Short and Long-Term Forecasts for Nonstationary Time Series. *IEEE Transactions on Neural Networks and Learning Systems*, 25(1), 241-246.
- Petropoulos, F., Makridakis, S., Assimakopoulos, V., and Nikolopoulos, K. (2014). 'Horses for Courses' in demand forecasting. *European Journal of Operational Research*, 237(1), 152-163.
- Pezeshki, Y., Baboli, A., Cheikhrouhou, N., Modarres, M., and Jokar, M. R. A. (2013). A rewarding-punishing coordination mechanism based on Trust in a divergent supply chain. *European Journal of Operational Research*, 230(3), 527-538.
- Poloni, F., and Sbrana, G. (2015). A note on forecasting demand using the multivariate exponential smoothing framework. *International Journal of Production Economics*, 162, 143-150.
- Radmehr, F., and Ghareh, N. S. (2012). FORECASTING METHOD BASED ON HIGH ORDER FUZZY TIME SERIES AND SIMULATED ANNEALING TECHNIQUE. *South African Journal of Industrial Engineering*, 23(2), 176-190.
- Ramanathan, U., and Gunasekaran, A. (2014). Supply chain collaboration: Impact of success in long-term partnerships. *International Journal of Production Economics*, 147, 252-259.
- Ren, P., Liao, Z., and Ge, P. (2014). Real-Time Forecast of Tourists Distribution Based on the Improved k-Means Method. *Mathematical Problems in Engineering*.
- Ren, S. Y., and Choi, T. M. (2016). Selection and industrial applications of panel data based demand forecasting models. *Industrial Management & Data Systems*, 116(6), 1131-1159.
- Rostami-Tabar, B., Babai, M. Z., Ducq, Y., and Syntetos, A. (2015). Non-stationary demand forecasting by cross-sectional aggregation. *International Journal of Production Economics*, 170, 297-309.
- Sakhuja, S., Jain, V., Kumar, S., Chandra, C., and Ghildayal, S. K. (2016). Genetic algorithm based fuzzy time series tourism demand forecast model. *Industrial Management & Data Systems*, 116(3), 483-507.
- Sandborn, P., Prabhakar, V., and Ahmad, O. (2011). Forecasting electronic part procurement lifetimes to enable the management of DMSMS obsolescence. *Microelectronics Reliability*, 51(2), 392-399.
- Scholz-Reiter, B., Kueck, M., and Lappe, D. (2014). Prediction of customer demands for production planning - Automated selection and configuration of suitable prediction methods. *Cirp Annals-Manufacturing Technology*, 63(1), 417-420.
- See, C.-T., and Sim, M. (2010). Robust Approximation to Multiperiod Inventory Management. *Operations Research*, 58(3), 583-594.
- Serel, D. A. (2012). Multi-item quick response system with budget constraint. *International Journal of Production Economics*, 137(2), 235-249.
- Shachmurove, Y. (2002). Applying artificial neural networks to business, economics and finance, departments of economics. *The City College of the City University of New York*. Available online from <http://www.econ.upenn.edu/Centers/CARESS/CARESSpdf/02-08.pdf>.
- Shah, M. (2012). Fuzzy based trend mapping and forecasting for time series data. *Expert Systems with Applications*, 39(7), 6351-6358.
- Shen, D., Lai, K. K., Leung, S. C. H., and Liang, L. (2011). Modelling and analysis of inventory replenishment for perishable agricultural products with buyer-seller collaboration. *International Journal of Systems Science*, 42(7), 1207-1217.
- Singh, P., and Borah, B. (2013). An efficient time series forecasting model based on fuzzy time series. *Engineering Applications of Artificial Intelligence*, 26(10), 2443-2457.

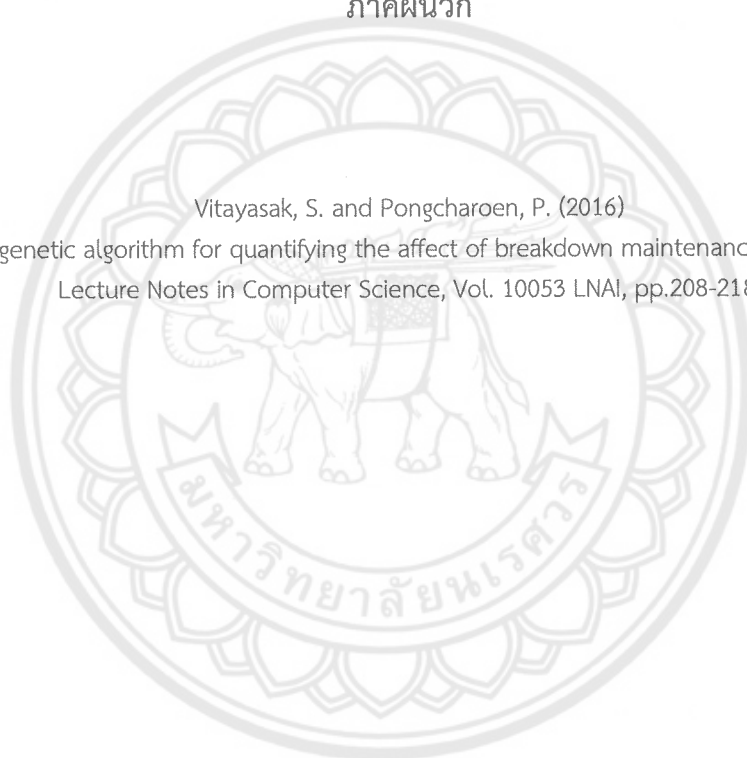
- Smith, K. A. & Gupta, J. N. D. (2000). Neural networks in business: Techniques and applications for the operations researcher. *Computers & Operations Research*, 27(11–12), 1023–1044. Available from <http://citeseer.ist.psu.edu/smith00neural.html>.
- Song, Q. (2015). Lessons Learned and Challenges Encountered in Retail Sales Forecast. *Industrial Engineering and Management Systems*, 14(2), 196-209.
- Stepnicka, M., Cortez, P., Peralta Donate, J., and Stepnickova, L. (2013). Forecasting seasonal time series with computational intelligence: On recent methods and the potential of their combinations. *Expert Systems with Applications*, 40(6), 1981-1992.
- Sung, W.-T., Chung, H.-Y., and Chang, K.-Y. (2014). Agricultural monitoring system based on ant colony algorithm with centre data aggregation. *Information Communications*, 8(7), 1132-1140.
- Takeyasu, H., Higuchi, Y., and Takeyasu, K. (2013). A Hybrid Method to Improve Forecasting Accuracy Utilizing Genetic Algorithm: An Application to the Data of Processed Cooked Rice. *Industrial Engineering & Management Systems An International Journal*, 12(3), 244-253.
- Taskin, S., and Lodree, E. J., Jr. (2010). Inventory decisions for emergency supplies based on hurricane count predictions. *International Journal of Production Economics*, 126(1), 66-75.
- Taylor, J. W., and Snyder, R. D. (2012). Forecasting intraday time series with multiple seasonal cycles using parsimonious seasonal exponential smoothing. *Omega-International Journal of Management Science*, 40(6), 748-757.
- Thomassey, S. (2010). Sales forecasts in clothing industry: The key success factor of the supply chain management. *International Journal of Production Economics*, 128(2), 470-483.
- Tiwari, D., Patil, R., and Shah, J. (2011). Unreliable newsboy problem with a forecast update. *Operations Research Letters*, 39(4), 278-282.
- Tong, C. (2010). Order postponement in a supply chain in the presence of exponential demand with gamma prior. *Operations Research Letters*, 38(2), 97-103.
- Tratar, L. F. (2015). Forecasting method for noisy demand. *International Journal of Production Economics*, 161, 64-73.
- Tsai, B.-H., Li, Y., and Lee, G.-H. (2010). Forecasting global adoption of crystal display televisions with modified product diffusion model. *Computers & Industrial Engineering*, 58(4), 553-562.
- Tsaur, R.-C. (2011). A new piecewise fuzzy exponential smoothing model based on some change-points. *Expert Systems with Applications*, 38(6), 7616-7621.
- Tucker, C. S., and Kim, H. M. (2011). Trend Mining for Predictive Product Design. *Journal of Mechanical Design*, 133(11).
- Turrado Garcia, F., Garcia Villalba, L. J., and Portela, J. (2012). Intelligent system for time series classification using support vector machines applied to supply-chain. *Expert Systems with Applications*, 39(12), 10590-10599.
- Venkatesh, K., Ravi, V., Prinzie, A., and Van den Poel, D. (2014). Cash demand forecasting in ATMs by clustering and neural networks. *European Journal of Operational Research*, 232(2), 383-392.
- Vercher, E., Corberan-Vallet, A., Segura, J. V., and Bermudez, J. D. (2012). Initial conditions estimation for improving forecast accuracy in exponential smoothing. *Top*, 20(2), 517-533.
- Wang, L., Liu, X., and Pedrycz, W. (2013). Effective intervals determined by information granules to improve forecasting in fuzzy time series. *Expert Systems with Applications*, 40(14), 5673-5679.
- Wang, S. J., Huang, C. T., Wang, W. L., and Chen, Y. H. (2010). Incorporating ARIMA forecasting and service-level based replenishment in RFID-enabled supply chain. *International Journal of Production Research*, 48(9), 2655-2677.

- Wang, T., Atasu, A., and Kurtulus, M. (2012). A Multiordering Newsvendor Model with Dynamic Forecast Evolution. *M&Som-Manufacturing & Service Operations Management*, 14(3), 472-484.
- Wang, Z.-X., and Pei, L.-L. (2014). An Optimized Grey Dynamic Model for Forecasting the ผลลัพธ์ of High-Tech Industry in China. *Mathematical Problems in Engineering*.
- Wang, Z., Zhang, Y., and Fu, H. (2014). Autoregressive Prediction with Rolling Mechanism for Time Series Forecasting with Small Sample Size. *Mathematical Problems in Engineering*.
- Wong, W. K., and Guo, Z. X. (2010). A hybrid intelligent model for medium-term sales forecasting in fashion retail supply chains using extreme learning machine and harmony search algorithm. *International Journal of Production Economics*, 128(2), 614-624.
- Wong, W. K., Xia, M., and Chu, W. C. (2010). Adaptive neural network model for time-series forecasting. *European Journal of Operational Research*, 207(2), 807-816.
- Wu, S. D., Kempf, K. G., Atan, M. O., Aytac, B., Shirodkar, S. A., and Mishra, A. (2010). Improving New-Product Forecasting at Intel Corporation. *Interfaces*, 40(5), 385-396.
- Xie, G., Zhao, Y., Jiang, M., and Zhang, N. (2013). A Novel Ensemble Learning Approach for Corporate Financial Distress Forecasting in Fashion and Textiles Supply Chains. *Mathematical Problems in Engineering*.
- Xu, X., Qi, Y., and Hua, Z. (2010). Forecasting demand of commodities after natural disasters. *Expert Systems with Applications*, 37(6), 4313-4317.
- Yan, H.-S., and Tu, X. (2012). Short-term sales forecasting with change-point evaluation and pattern matching algorithms. *Expert Systems with Applications*, 39(5), 5426-5439.
- Yan, X., and Wang, Y. (2014). A newsvendor model with capital constraint and demand forecast update. *International Journal of Production Research*, 52(17), 5021-5040.
- Yu, Y., Choi, T.-M., and Hui, C.-L. (2011). An intelligent fast sales forecasting model for fashion products. *Expert Systems with Applications*, 38(6), 7373-7379.
- Zhang, J., Pu, R., Yuan, L., Huang, W., Nie, C., and Yang, G. (2014). Integrating Remotely Sensed and Meteorological Observations to Forecast Wheat Powdery Mildew at a Regional Scale. *Ieee Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(11), 4328-4339.
- Zhang, L. (2015). DYNAMIC OPTIMIZATION MODEL FOR GARMENT DUAL-CHANNEL SUPPLY CHAIN NETWORK: A SIMULATION STUDY. *International Journal of Simulation Modelling*, 14(4), 697-709.
- Zhang, X., Prajapati, M., and Peden, E. (2011). A stochastic production planning model under uncertain seasonal demand and market growth. *International Journal of Production Research*, 49(7), 1957-1975.
- Zhang, G., Eddy, P.B., Hu, M.Y., (1998). Forecasting with artificial neural networks: the state of the art. *International Journal of Forecasting* 14, 35-62.
- Zhang, P., Qi, G.M., (2005). Neural network forecasting for seasonal and trend time series. *European Journal of Operational Research* 160, 501-514.

## ภาคผนวก

Vitayasak, S. and Pongcharoen, P. (2016)

Application of genetic algorithm for quantifying the affect of breakdown maintenance on machine layout,  
Lecture Notes in Computer Science, Vol. 10053 LNAI, pp.208-218.



# Application of Genetic Algorithm for Quantifying the Affect of Breakdown Maintenance on Machine Layout

Srisatja Vitayasak and Pupong Pongcharoen<sup>1</sup>✉

Faculty of Engineering, Department of Industrial Engineering,  
Centre of Operations Research and Industrial Applications,  
Naresuan University, Phitsanulok 65000, Thailand  
{srisatjav, pupongp}@nu.ac.th

**Abstract.** Computational intelligence (CI) has been successfully applied to solve a variety of optimisation problems under uncertain conditions in manufacturing domains. Uncertainties have an impact on product mix and material flow in manufacturing shop floor. The effective layout can reduce material handling costs, and lead to reduce up to 50 % of the total operating expenses. Machine layout design is classified into non-deterministic polynomial-time hard problem. This paper presents the application of Genetic Algorithm for generating robust layouts under uncertainties on customers' demand and breakdown maintenance. This was aimed to minimise both cost and handling distance of material flow. The experimental programme was conducted using eight different-size datasets. Minimising trade-off between material travelling distance and costs of relocating machines/equipment has been discussed. This provides a decision framework for evaluating the investment on facility re-layout design.

**Keywords:** Genetic Algorithm · Robust layout · Machine re-layout · Demand uncertainty · Maintenance

## 1 Introduction

Computational intelligence (CI), which is one important sub-branch of artificial intelligence, is the study of the design of intelligent agents [1]. An intelligent agent is an adaptive mechanism that can enable or facilitate intelligent behavior in complex and changing environments [2]. Applications of CI can be found in prediction of stock market [3], intrusion detection [4], protein classification [5], gene identification [6], traffic signal [7], facility layout [8, 9], scheduling [10], timetabling [11], vehicle routing [12], travelling salesman [13], and container packing [14]. CI has been also applied to solve the problems in uncertain conditions [15].

Uncertainties may be caused by internal and external forces [16, 17]. Internal disturbances include variable task times, rejects, rework, and machine breakdowns. Reduced number of available machines due to breakdown machines can cause longer flow time, lower productivity and higher production costs. Once materials flow is interrupted, successive resources will be idle, which can reduce utilisation. In this case,

the alternative machine is introduced to overcome the difficulties but material handling time and distances are likely to change [17].

External forces consist of competitive environment, availability of resources, product prices, product mix, and demand variability, which may be unknown. Uncertainty may arise out of actions of competitors, changing consumer preferences, technological innovations, and new regulations [17]. Variations in the level of customer demand and product mix can disrupt the efficient flow of materials within a facility. These changes affect production performance and the layout [18]. However, none of the papers took into account both demand uncertainty and machine maintenance in optimisation problems such as facility layout problem.

The objective of this paper is to demonstrate the application of Genetic Algorithm (GA) for quantifying the affect of breakdown maintenance on machine layout design. The remaining sections are organised as follows: Sect. 2 is comprehensive literature reviews including computational intelligence, production condition in facility layout problem, and machine breakdown. Application of GA on machine layout design problems is shown in Sect. 3. The experimental results are presented in Sect. 4 and finally, conclusions are drawn in Sect. 5.

## 2 Comprehensive Literature Review

The related literature reviews on application of computational intelligence, production condition in facility layout problem, and machine breakdown were presented in subsections as follows:

### 2.1 Computational Intelligence

In IEEE World Congress on Computational Intelligence (1994), computational intelligence was defined as science-based approaches and technologies for analysis, design, and development of intelligent systems. CI tools based on natural inspirations can be classified as the human-mind model based (e.g. fuzzy set theory), the artificial immune system based (e.g. evolutionary computing), the swarm intelligence based (e.g. Ant Colony Optimisation), and the emerging geo-sciences based (e.g. Earthquakes) [19]. These natural-inspiration techniques (so called metaheuristics) are an important part of CI [20].

Genetic Algorithm (GA) [21], one of metaheuristics in evolutionary computing, is a population-based, nature-inspired algorithm. A set of candidate solutions is generated as an initial set of solutions, which then undergoes an evolutionary search process. Exploitation and exploration processes are carried out simultaneously via crossover and mutation operations, respectively [22], in which GA uses probabilistic (non-deterministic) transition rules to guide exploitative search and also performs a multiple directional search by maintaining a population of potential solutions. This mechanism can be adjusted for helping to escape from local optimal.

There are a number of literatures related to the application of GA on production and operation management in the last few decades [23]. Lenin et al. [24] demonstrated the effectiveness of GA to solve single-row layout design problem. The results obtained were more favorable than other approaches. Kia et al. [25] proposed that GA can find

near-optimal solutions much less computational time than CPLEX for most datasets. Rose and Coenen [26] investigated the performance comparison of GA, and other algorithms (e.g. Particle Swarm Optimisation) for ship outfitting scheduling. The results indicated that GA was more efficient in terms of computational time.

## 2.2 Production Condition in Facility Layout Problem

Facility layout design involves arrangement of facilities into a limited manufacturing shop floor. The effective layout can reduce material handling costs, and lead to quicker transfer times between facilities, better productivity, and reduce up to 50 % of the total operating expenses [27]. When the flow of materials between the facilities does not change during the planning horizon, this problem is known as the static facility layout problem (SFLP). The dynamic facility layout problems (DFLP) take into account possible changes in the material handling over multiple periods. Variation in material flow has been resulted from customer demand, product mix, number of machines, and routing flexibility. Changing the processing route due to machine maintenance can affect the flow intensity over time period but the consideration of maintenance in FLP has not been reported in literature.

The facility layout problems (FLPs) are classified as Non-deterministic Polynomial time hard problem [28]. The approximation algorithms have been applied to solve these problems. A systematic literature review was undertaken using the ISI-Web of Science database for the period 2001 to February 2016. It can be found that GA has been extensively applied to solve FLPs both in static [24] and dynamic [25] scenarios.

## 2.3 Machine Breakdown

Machine breakdown is a stochastic event that is a major concern in industry. If operations are interrupted, it may be necessary to revise the schedule to re-optimize the remaining operations taking into account the machine downtime. The easiest solution is often to apply some dispatching rule to sequence operations immediately after the breakdown occurs [29]. A number of parameters have been used to model machine maintenance problems, for example machine failure rate has often been represented by the Poisson distribution or generated randomly. Machine lifetime is commonly modelled using the Weibull distribution. Mean time to failure has been represented by the normal distribution or the exponential distribution. Breakdown maintenance has also been considered in the context of robust scheduling [30].

# 3 Application of GA on Machine Layout Design Problems

## 3.1 Problem Statement

Machine layout design (MLD) under dynamic production condition can be robust, and re-layout. Changing production condition due to external forces is product demand. Demand profiles can be obtained from empirical data (the demand value is known in advance and changes over time periods) or by using different types of distributions

(exponential, normal distribution, or uniform) [31]. Breakdown maintenance (BM) can be considered as one of internal production conditions. Once a machine is broken down, an alternative machine will be assigned for production. This will effect to material handling distance on the changing route of machine sequence. For example, machine sequence is M1-M2-M3, if the M2 is unavailable because of BM, the alternate machine (M9) is therefore selected. The machine sequence is adapted as M1-M9-M3 by which, material handling distance is changed. The evaluation function ( $Z$ ) for the efficiency of robust layout design can be used to minimise total material handling distance (MHD) as defined by Eq. (1)

$$\text{Minimise } Z = \sum_{i=1}^M \sum_{j=1}^M \sum_{g=1}^N \sum_{k=1}^P d_{ij} f_{ijgk} D_{gk} \quad (1)$$

$M$  is the number of machines,  $i$  and  $j$  are machine indexes ( $i$  and  $j = 1, 2, 3, \dots, M$ ).  $N$  is the number of product types,  $g$  is a product index ( $g = 1, 2, 3, \dots, N$ ) and  $P$  is the number of time periods,  $k$  is a time period index ( $k = 1, 2, 3, \dots, P$ ).  $d_{ij}$  is the distance from machines  $i$  to  $j$  ( $i \neq j$ ),  $f_{ijgk}$  is the frequency of material flow of product  $g$  from machines  $i$  to  $j$  on period  $k$ , and  $D_{gk}$  is the customer demand of product  $g$  on period  $k$ .

Rectangular machine layout design is concerned with the placement of machines into a limited shop floor area having gap between machines. Machines are sequentially arranged row by row, from left to right, starting at the first row and respecting floor length and the gap [32]. When there is not enough area for placing the next machine at the end of the row, it is placed in the next row. Vehicles moving between rows move to the left or right side of the row and then up or down to the destination row.

### 3.2 Genetic Algorithm on MLD Problems

The GA pseudo-code for the proposed MLD is shown in Fig. 1 [33]. It comprises the following steps: (i) encode the problem, which produces a list of genes using a numeric string. Each chromosome contains a number of genes, each representing a machine number, so that the length of each chromosome is equal to the total number of machines needed to be arranged; (ii) prepare input data: the number of machines ( $M$ ), the dimensions of machines (width:  $M_W$  x length:  $M_L$ ), maintenance plan, alternative machines, the number of products ( $N$ ) and the machine sequences ( $M_S$ ); (iii) specify parameters: the population size (Pop), the number of generations (Gen), the probability of crossover ( $P_c$ ), the probability of mutation ( $P_m$ ), floor length ( $F_L$ ), floor width ( $F_W$ ), the gap between machines ( $G$ ), and the number of periods ( $P$ ); (iv) create the demand levels of each product in each period ( $D_{gk}$ ); (v) randomly generate an initial population based on the defined Pop; (vi) apply crossover and mutation operators to generate new offspring considering  $P_c$  and  $P_m$  respectively; (vii) arrange machines row by row based on  $F_L$  and  $F_W$ ; (viii) evaluate the fitness function value; (ix) select the best chromosome having the shortest material handling distance using the elitist selection mechanism; (x) choose chromosomes for next generation by using the roulette wheel selection; and (xi) stop the GA process according to the number of generations. When the GA process is terminated, the best-so-far solution is reported.



```

Input problem dataset and Parameter setting (Pop, Gen, Pc, Pm, FL, FW, G, P)
Create demand level (Dit) for each product associated with demand distribution
Randomly create initial population (Pop)
Set a = 1 (first generation)
While a ≤ Gen do
  For b = 1 to cross do (cross = round ((Pc x Pop)/2))
    Crossover operation
  End loop for b
  For c = 1 to mute do (mute = round(Pm x Pop))
    Mutation operation
  End loop for c
  Arrange machines row by row based on FL, FW and G
  Calculate material handling distance based on either re-layout or robust layout
  Selection of the best solution using elitist selection
  Chromosome selection using roulette wheel method
  a = a + 1
End loop while
Output the best solution

```

Fig. 1. Pseudo-code of Genetic Algorithm

## 4 Experimental Design and Analysis

The computational experiments were conducted using eight datasets, all of which had different numbers of non-identical machines with various product types [34]. Each type of product had different demand profiles and machine sequences. The program was developed and coded in modular style using the Tool Command Language and Tool Kit programming language [35]. The experiments were conducted on a personal computer with an Intel Core i5 2.8 GHz CPU and 4 GB DDR3 RAM. The combination of population size and the number of generations (Pop\*Gen) determines the amount of search and the computational time required. In this work Pop\*Gen was set to 2,500 solutions, probabilities of crossover and mutation were set at 0.9 and 0.5 [31]. The appropriate genetic operators were presented in the following subsection.

### 4.1 Genetic Operators on GA Performance

A dataset (9 products to be processed on 15 machines) was used to compare the solution quality obtained from crossover operators (Enhanced edge recombination crossover: EERX [36] and two-point centre crossover: 2PCX [37]) and mutation operators (Two operations adjacent swap: 2OAS and two operations random swap: 2ORS [37]). The EERX and 2OAS were the best operators for scheduling problem [38]. The FLP was solved by GA with 2PCX [39] and 2ORS [40].

The computational experiment was repeated five times. The results in term of mean, standard deviation (SD), maximum (Max) and minimum (Min) of total material handling distances are summarised in Table 1. This suggested that the appropriate crossover and mutation operators for MLD problem were 2PCX and 2ORS. This also confirmed that the GA performance depends on the selection of the genetic operators.

Table 1. Relative performance of genetic operators (unit: metre)

Crossover operator	Mutation operator	Mean	SD	Max	Min
EERX	2OAS	1,464.25	35.56	1,411.15	1,498.25
	2ORS	1,477.35	20.43	1,442.95	1,497.05
2PCX	2OAS	1,437.33	37.68	1,373.55	1,469.45
	2ORS	<b>1,421.35</b>	15.17	1,397.35	1,436.55

For the next experiment, two scenarios under ten time-periods were considered: robust design, with no relocation when demand changed; and re-layout after demand changes. In order to denote the difference on the affect of breakdown maintenance (BM), the symbol (\*) was introduced as the last letter of the variable only in BM scenario. For example, the material handling distance calculated without BM is denoted as MHD while in BM scenario, it is termed MHD\*. In each period, the percentage of breakdown maintenance machines (%BMM) was determined at 10 %, 20 % and 30 %. During periods of maintenance, alternative machines were used. Each experiment was replicated thirty times using different random seeds. With eight datasets, thirty replications, three values of %BMM and two types of layout, a total of 1,440 ( $8 \times 30 \times 3 \times 2$ ) computational runs have been carried out. Each solution was evaluated on the ratio of the distance travelled with/without maintenance (MHD/MHD\*) as shown in the subsection as follows.

#### 4.2 Material Handling Distance (MHD) Based on Re-layout and Robust Layout

The second experiment aimed to minimise the MHD based on re-layout and robust layout design. The Mean, SD, Min, and Max of the distances travelled are shown in Table 2, where the lowest mean value of MHD for each dataset is indicated in bold. They were analysed using an analysis of variance (ANOVA) to calculate P values. The number of machines moved (NMM) and the machine movement distances (MMD) by re-layout between the periods are included in Table 2.

The average total distance for re-layout was shorter than with the robust layout in almost all datasets because the layout was redesigned according to the production flow over time period. The Student's t-test was applied to compare the differences in means of MHD. There were statistically significant differences between re-layout and robust layout with a 95 % confidence interval except for 40M20N and 40M40N. The robust layout produced a lower distance than re-layout with some datasets. The process of re-layout generated movement of machines between the periods, which effects the MMD and NMM. These costs of movements are considered in the next section.

In most datasets, the distance (MHD\*) for re-layout was shorter than the robust layout. The ANOVA showed that the %BMM ratios significantly affected the material handling distance with a 95 % confidence interval (since the P values were less than 0.05 for all datasets). An increase in the number of BM machines caused more changes in machine sequences, so MHD\* increased. However, the machine sequences depended upon the alternative machines defined.

Table 2. Values of total material handling distance (MHD) (unit: metre)

Dataset	Value	Robust layout						Re-layout						P-value
		MHD	MHD* based on C <sub>MH</sub>			MHD	MMD	NMM	MHD* based on C <sub>MH</sub>					
			IG	SP	SP1				IG	SP	SP1			
10 machines 5 positions (10M5N)	Mean	511,631.1	595,992.6	618,108.0	718,532.9	232,442.7	589.1	62.6	587,660.1	642,151.2	701,921.8			
	SD	11,037.7	18,962.6	32,179.8	19,664.1	6,716.8	703.0	10.4	17,136.1	17,878.6	16,117.7	0.001		
	Min	523,969.5	578,595.5	629,210.6	705,025.1	415,617.1	188.2	85.0	609,711.6	621,781.7	639,811.9			
	Max	565,028.6	649,591.9	701,533.1	771,022.3	512,662.9	960.7	81.0	633,335.7	675,029.9	737,229.1			
20M10N	Mean	3,935,972.5	3,542,101.9	3,628,718.5	3,911,221.4	3,291,791.1	2,128.5	178.1	3,180,769.7	3,500,226.8	3,941,684.0	0.001		
	SD	66,000.2	70,083.5	60,221.3	93,397.2	41,598.7	1,111.0	1.4	44,129.4	92,969.9	58,685.8			
	Min	3,16,870.4	3,40,568.5	3,491,732.5	3,751,832.7	1,222,102.6	1,863.7	178.0	3,093,131.5	3,34,799.5	3,841,101.1			
	Max	3,525,202.9	3,692,350.4	3,825,789.1	4,136,080.9	3,511,841.0	2,490.0	180.0	3,503,212.0	3,718,805.9	4,135,541.0			
20M20N	Mean	10,536,085.3	10,888,497.5	11,491,341.5	10,040,630.5	10,040,630.5	1,987.7	172.3	10,235,923.3	10,665,973.0	11,324,710.7	0.001		
	SD	174,047.6	177,661.7	379,407.2	64,531.2	64,531.2	428.5	2.3	142,267.8	148,163.7	266,137.2			
	Min	9,549,434.2	10,135,672.5	10,873,095.3	9,911,473.3	9,911,473.3	1,633.0	173.0	9,987,597.7	10,141,000.0	10,940,383.4			
	Max	10,614,211.9	11,017,028.8	11,629,420.2	10,145,080.9	10,145,080.9	2,266.9	180.0	10,518,105.6	11,324,764.3	11,721,392.6			
20M40N	Mean	19,591,343.6	20,441,211.1	21,280,686.2	20,518,881.1	19,544,224.0	1,622.1	177.1	20,139,126.0	21,155,152.9	20,711,559.3	0.001		
	SD	211,498.2	18,814.1	35,670.7	461,285.2	86,578.0	192.8	2.7	165,903.9	258,857.8	313,379.9			
	Min	19,216,235.6	19,887,820.5	20,614,917.8	20,049,214.7	19,196,354.8	1,411.9	166.0	19,776,615.4	20,599,824.7	20,343,844.6			
	Max	20,141,262.1	21,181,869.2	22,199,719.9	21,191,810.5	19,559,391.6	2,421.7	180.0	20,151,603.2	21,206,322.8	21,189,155.8			
30M15N	Mean	1,895,278.6	8,276,170.0	8,292,326.7	9,096,616.4	7,751,296.3	3,445.4	268.7	8,211,361.7	8,411,664.6	8,909,979.9	0.001		
	SD	195,541.8	213,714.2	20,010.6	197,351.2	84,920.4	304.2	4.1	101,229.6	116,774.8	119,417.6			
	Min	2,477,276.1	7,915,148.6	8,041,912.4	8,663,158.8	7,602,578.3	2,608.1	333.0	7,992,155.8	8,170,155.6	8,246,664.1			
	Max	8,205,071.8	8,948,410.7	8,884,123.3	9,448,025.8	7,968,781.0	3,853.0	230.0	8,364,279.9	8,825,909.0	9,276,441.8			
40M20N	Mean	15,209,235.0	17,166,328.0	17,689,169.6	16,897,215.4	15,869,665.0	5,386.1	358.2	16,976,117.6	17,412,157.8	18,026,417.5	0.001		
	SD	604,071.8	599,320.1	711,878.6	638,833.9	627,025.4	2,941.8	1.4	331,004.9	309,105.6	331,044.9			
	Min	14,168,156.5	16,275,826.0	16,382,959.9	15,114,971.6	14,526,384.7	4,899.7	153.0	16,516,226.2	16,562,780.6	16,516,276.2			
	Max	16,133,139.1	18,203,575.0	19,249,222.1	20,951,025.8	15,415,321.8	5,791.1	160.0	17,581,220.7	17,874,512.5	17,851,230.7			
40M40N	Mean	27,952,468.8	30,354,735.4	32,107,292.4	31,014,129.5	28,081,365.5	5,386.1	358.8	30,161,892.5	32,183,001.3	33,012,227.2	0.001		
	SD	665,215.5	710,209.0	732,860.0	693,114.6	478,026.0	2,252.2	1.3	540,129.6	478,920.7	536,009.0			
	Min	26,478,184.2	28,081,376.1	29,685,120.7	32,110,045.9	21,262,728.6	4,011.6	63.0	29,208,265.1	30,092,518.1	32,852,183.2			
	Max	29,016,217.4	31,551,315.4	33,501,573.4	35,319,095.2	29,229,287.2	5,871.5	360.0	31,609,091.3	33,103,931.1	35,191,161.1			
50M25N	Mean	25,216,694.2	27,178,083.7	30,770,244.4	31,879,869.1	24,834,671.4	7,245.8	448.5	26,918,721.8	29,659,717.6	30,616,340.6	0.001		
	SD	709,262.7	668,805.8	1,410,183.5	1,193,502.1	2,219,955.1	3,125.5	3.0	456,108.4	501,289.9	528,307.5			
	Min	23,928,776.0	25,890,044.3	28,698,533.1	29,248,545.6	23,883,824.6	6,891.8	413.0	25,888,164.1	28,778,971.4	29,112,717.3			
	Max	26,910,652.2	28,643,767.9	31,601,791.3	33,655,833.1	25,311,240.1	8,248.3	450.0	27,376,455.7	30,672,412.1	31,119,425.5			

### 4.3 Total Cost for Robust Layout and Re-layout

The results obtained from the above section will be used to determine the total costs of both robust and re-layout approaches. For robust layout, the total cost was determined from the MHD multiplied by the material handling cost ( $C_{MH}$ ), in which the  $C_{MH}$  was assumedly equals to one currency unit per metre. The total cost (TC) of re-layout included material handling cost and machine shifting costs as shown in Eqs. (2) and (3). The shifting costs were related to the NMM and the MMD. The average shifting costs based on the NMM ( $C_{MV}$ ) and the MMD ( $C_{MD}$ ) were set at 1,000 currency units per machine moved [18], and 50 currency units per metre, respectively. Both total costs without maintenance (TC) and total costs with maintenance (TC\*), which were calculated using the MHD and MHD\* obtained from the previous experiment, are shown in Table 3.

$$Total\ cost\ of\ re\text{-}layout = C_{MH} \sum_{i=1}^M \sum_{j=1}^M \sum_{g=1}^N \sum_{k=1}^P d_{ijf_{ijgk}} D_{gk} + \sum_{k=1}^P C_{MV} (NMM_{k+1}) \tag{2}$$

$$Total\ cost\ of\ re\text{-}layout = C_{MH} \sum_{i=1}^M \sum_{j=1}^M \sum_{g=1}^N \sum_{k=1}^P d_{ijf_{ijgk}} D_{gk} + \sum_{k=1}^P C_{MD} (MMD_{k-1}) \tag{3}$$

Total cost (TC) of robust layout was lower than TC of re-layout both in terms of the NMM and the MMD except for 20M20N, 20M40N and 50M25N. A Student's t-test showed that there were statistically significant differences in the mean of total cost between robust layout and re-layout in some types of shifting cost. The mean total cost had no statistically significant difference between the layout designs for the 40M20N and 50M25N cases, so the layout was robustly designed or redesigned. The re-layout

Table 3. Values of total cost (unit: currency unit)

Dataset	Type	Robust layout						Re-laid out					
		TC*(MMD) based on %BMM						TC*(MMD) based on %BMM					
		10	20	30	40	50	60	10	20	30	40	50	60
10M5N	Min	516,254	502,992.6	619,006.9	716,537.9	533,091.4	617,151.1	671,913.9	730,535.2	586,145.7	650,200.4	705,051.2	763,671.5
	Max	1,025,315	1,086,966	1,217,918	1,369,041	1,036,366	1,199,011	1,321,816	1,493,961	1,152,266	1,309,709	1,492,219	1,673,119
	Mean	852,966.5	849,276.5	920,249.0	1,010,244.1	786,644.3	844,482.9	914,101.1	999,406.9	852,234.5	910,012.9	989,261.7	1,073,311.9
20M10N	Min	3,338,077.7	3,242,104.0	3,622,341.5	3,941,721.4	3,397,598.8	3,585,571.4	3,899,034.2	4,048,590.7	3,470,191.1	3,659,189.7	3,895,626.5	4,121,451.0
	Max	66,309.2	70,004.5	80,272.4	97,072.2	61,095.2	64,299.1	61,605.9	66,105.8	61,228.0	64,103.5	62,565.4	68,702.6
	Mean	32,165,704.4	31,405,768.5	3,601,374.5	3,751,832.7	3,331,030.6	3,496,907.5	3,588,321.5	3,905,075.3	3,401,192.6	3,569,570.5	3,660,739.5	3,889,493.3
30M15N	Min	3,255,325.9	3,697,330.4	3,523,769.1	4,136,690.9	3,463,156.6	3,303,134.0	3,585,130.9	4,244,594.3	3,233,304.0	3,772,512.0	3,911,366.9	4,314,347.6
	Max	10,754,695.5	10,882,307.5	11,401,110.5	10,940,610.5	10,139,097.5	10,335,531.5	10,553,331.2	11,473,471.9	10,213,597.2	10,411,100.0	10,641,296.7	11,551,377.4
	Mean	6,849,434.2	6,615,662.5	6,973,095.3	6,911,473.3	6,001,276.4	6,009,129.2	6,021,535.7	6,183,521.9	6,099,473.3	6,164,598.7	6,181,001.2	6,110,283.4
40M40N	Min	10,611,240.9	10,274,068.8	12,629,329.4	10,145,018.9	10,254,087.9	10,637,773.3	11,205,913.8	11,825,185.2	10,324,039.9	10,722,106.6	11,208,761.3	11,919,392.7
	Max	19,591,434.6	19,411,171.1	17,791,068.7	20,581,998.1	19,443,181.8	19,238,321.1	21,291,239.0	20,010,665.4	19,321,665.4	20,311,138.4	21,133,280.1	20,891,922.7
	Mean	13,113,398.2	13,181,144.1	13,516,912.1	14,178,282.2	13,273,358.2	13,237,163.7	13,826,826.0	14,212,765.5	13,683,914.1	13,768,608.5	13,868,368.2	14,210,109.9
10M15N	Min	19,236,235.6	19,887,820.5	20,611,947.8	20,019,024.7	19,284,193.3	19,664,853.9	20,606,530.7	20,547,491.6	19,773,334.8	19,653,615.4	20,773,823.7	20,222,391.6
	Max	30,141,262.1	31,191,292.7	31,194,719.9	31,892,800.5	30,693,671.7	30,627,653.2	31,792,317.1	31,735,821.3	30,725,491.8	30,657,602.2	31,889,272.8	31,335,453.6
	Mean	23,139,822.2	23,814,144.1	24,156,912.1	24,018,282.2	23,273,358.2	23,237,163.7	23,826,826.0	24,212,765.5	23,683,914.1	23,768,608.5	23,868,368.2	24,210,109.9
20M10N	Min	8,205,071.8	8,042,410.7	8,551,324.5	8,418,623.8	8,079,591.0	8,335,530.0	8,866,121.3	9,305,430.3	8,176,281.0	8,631,722.9	8,982,929.0	9,515,843.5
	Max	15,762,271.0	1,166,328.0	1,680,409.6	1,880,218.1	1,573,413.5	1,245,736.0	1,681,716.2	1,724,733.9	1,567,249.0	1,734,011.6	1,710,667.5	1,734,447.4
	Mean	12,168,426.5	12,272,826.0	12,612,059.0	12,444,703.6	11,777,272.2	11,677,592.2	12,422,537.6	12,617,597.2	12,385,384.2	12,635,795.2	12,722,761.6	12,875,726.2
30M15N	Min	16,453,329.4	16,391,250.0	16,730,277.4	17,014,125.8	16,693,211.5	17,862,110.1	18,101,470.5	17,367,110.1	15,714,321.5	17,043,322.5	18,181,322.5	17,943,256.7
	Max	57,052,465.5	59,334,123.4	62,101,222.1	64,041,259.3	58,310,828.1	59,711,353.1	62,482,252.9	64,182,189.7	58,249,822.2	60,820,339.2	62,341,355.0	64,371,193.9
	Mean	39,212,718.8	40,706,001.0	42,576,530.0	44,111,114.6	40,876,268.2	42,446,613.1	44,930,866.5	47,026,261.4	43,729,841.1	45,416,960.0	47,612,529.2	49,434,555.5
40M40N	Min	26,319,217.0	26,511,445.1	27,591,577.1	28,109,693.2	26,681,811.1	27,486,652.8	28,576,337.6	29,442,231.1	26,738,167.2	27,364,031.3	28,662,991.1	29,566,169.4
	Max	35,760,942.2	37,110,092.2	39,230,211.4	40,570,601.1	35,259,097.5	37,231,691.2	39,932,056.0	41,894,649.0	35,283,171.4	37,367,223.5	40,108,217.6	41,948,639.6
	Mean	35,782,718.0	36,800,014.1	38,698,531.1	39,248,538.6	36,241,881.6	37,422,925.1	39,681,217.0	41,292,429.1	37,433,084.6	38,335,161.1	39,188,834.4	40,611,212.3

approach consumed time repositioning machines and required shifting costs, which increased the total cost. For re-layout, the total cost in terms of the NMM was higher than the moving distance cost. Whether the layout was robustly designed or redesigned to another layout in the next period depended on the shifting cost and number of machines and product types (datasets). However, it should be noted that the shifting costs considered in this work were excluded and other costs related to the shutting down of the manufacturing line were also omitted.

With breakdown maintenance, the lowest mean total cost for each %BMM is highlighted in Table 3. The total cost (TC\*) of robust layout was lower than re-layout based on both types of shifting cost for 10M5N, 20M10N, 30M15N and 40M40N. For all %BMM, the difference in mean total cost between robust layout and re-layout for 10M5N and 20M10N were statistically significant with a 95% confidence interval (since the P values obtained from the Student's t-test were less than 0.05). The total cost (TC\*) of robust layout was higher than the TC\* of re-layout in terms of MMD on the dataset of 20M40N but there were statistically insignificant differences.

The robust layout was more effective than re-layout for some datasets and some types of shifting costs. Within both types of shifting cost for re-layout, the total cost in terms of the number of machines moved was higher than in terms of moving distance. This confirmed that the shifting cost and number of machines and product types (datasets) have an influence on machine layout design. However, the appropriate % BMM determined whether the layout should be robust or re-laid out.

### 5 Conclusions

This paper has presented the application of Genetic Algorithm for quantifying the affect of manufacturing machine layout design with/without maintenance consideration for stochastic demand environments. The analysis considered scenarios where 10 %, 20 %

and 30 % of machines had breakdown maintenance. The material handling distances for both re-layout and robust layout increased when some machines were maintained during each period. This was caused by changes in routings due to the use of alternative machines. The experimental results indicated that the material handling distance for re-layout was shorter than for robust layout. However, redesigning the machine layout according to demand levels generated shifting costs.

The total costs of the robust layout designs that did not consider maintenance were lower than those that involved re-layout for almost all the datasets. Robust layout designs also produced lower cost in breakdown maintenance situations. This was because re-layout caused machines to be moved which caused shifting costs. However, shifting costs may have according to the machine movements, which has an influence on total cost for re-layout designs. It can be beneficial for companies to consider both demand and machine uncertainty when designing layouts, providing that the future demand and availability of machines are properly forecast and planned. Investors should make decisions based on a trade-off between rearrangement cost and material handling cost. Future research should be focused on designing the machine layout without considering preventive machine maintenance and both of preventive and breakdown maintenance.

**Acknowledgement.** This work was part of the research project supported by the Naresuan University Research Fund under the grant number R2559C230.

## References

1. Poole, D., Mackworth, A., Goebel, R.: *Computational Intelligence: A Logical Approach*. Oxford University Press, New York (1998)
2. Engelbrecht, A.P.: *Computational Intelligence: An Introduction*, 2nd edn. Wiley, Hoboken (2007)
3. Tsang, E.: Forecasting - where computational intelligence meets the stock market. *Front. Comput. Sci. China* **3**, 53–63 (2009)
4. Wu, S.X., Banzhaf, W.: The use of computational intelligence in intrusion detection systems: a review. *Appl. Soft Comput.* **10**, 1–35 (2010)
5. Vipsita, S., Rath, S.K.: Sequence-based protein superfamily classification using computational intelligence techniques: a review. *Int. J. Data Min. Bioinform.* **11**, 424–457 (2015)
6. Bandyopadhyay, S., Maulik, U., Roy, D.: Gene identification: classical and computational intelligence approaches. *IEEE Trans. Syst. Man Cybern. Part C-Appl. Rev.* **38**, 55–68 (2008)
7. Araghi, S., Khosravi, A., Creighton, D.: A review on computational intelligence methods for controlling traffic signal timing. *Expert Syst. Appl.* **42**, 1538–1550 (2015)
8. Dapa, K., Loreunthup, P., Vitayasak, S., Pongcharoen, P.: Bat algorithm, genetic algorithm and shuffled frog leaping algorithm for designing machine layout. In: Ramanna, S., Lingras, P., Sombatheera, C., Krishna, A. (eds.) *MIWA1 2013*. LNCS (LNAI), vol. 8271, pp. 59–68. Springer, Heidelberg (2013). doi:10.1007/978-3-642-44949-9\_6
9. Karray, F., Zanelidin, E., Hegazy, T., Shabeeb, A., Elbeltagi, E.: Computational intelligence tools for solving the facilities layout planning problem. In: *Proceedings of the 2000 American Control Conference*, vol. 1–6, pp. 3954–3958. IEEE, New York (2000)

10. Chansombat, S., Musikapun, P., Pongcharoen, P., Hicks, C.: A modified bat algorithm for production scheduling in the capital goods industry. In: 22nd International Conference on Production Research, ICPR 2013 (2013)
11. Lutuksin, T., Pongcharoen, P.: Best-worst ant colony system parameter investigation by using experimental design and analysis for course timetabling problem. In: 2nd International Conference on Computer and Network Technology, ICCNT 2010, Bangkok, pp. 467–471 (2010)
12. Chainate, W., Pongcharoen, P., Thapatsuwan, P.: Clonal selection of artificial immune system for solving the capacitated vehicle routing problem. *J. Next Gener. Inf. Technol.* **4**, 167–179 (2013)
13. Pongcharoen, P., Chainate, W., Pongcharoen, S.: Improving artificial immune system performance: inductive bias and alternative mutations. In: Bentley, P.J., Lee, D., Jung, S. (eds.) ICARIS 2008. LNCS, vol. 5132, pp. 220–231. Springer, Heidelberg (2008). doi:10.1007/978-3-540-85072-4\_20
14. Thapatsuwan, P., Sepsirisuk, J., Chainate, W., Pongcharoen, P.: Modifying particle swarm optimisation and genetic algorithm for solving multiple container packing problems. In: 2009 International Conference on Computer and Automation Engineering, ICCAE 2009, Bangkok, pp. 137–141 (2009)
15. Chen, G.Y.-H.: A new data structure of solution representation in hybrid ant colony optimization for large dynamic facility layout problems. *Int. J. Prod. Econ.* **142**, 362–371 (2013)
16. Kulturel-Konak, S.: Approaches to uncertainties in facility layout problems: perspectives at the beginning of the 21(st) century. *J. Intell. Manuf.* **18**, 273–284 (2007)
17. Sethi, A., Sethi, S.: Flexibility in manufacturing: a survey. *Int. J. Flex. Manuf. Syst.* **2**, 289–328 (1990)
18. Moslemipour, G., Lee, T.S.: Intelligent design of a dynamic machine layout in uncertain environment of flexible manufacturing systems. *J. Intell. Manuf.* **23**, 1849–1860 (2012)
19. Goel, L., Gupta, D., Panchal, V.K., Abraham, A.: Taxonomy of nature inspired computational intelligence: a remote sensing perspective. In: 4th World Congress on Nature and Biologically Inspired Computing, NaBIC 2012, Mexico City, pp. 200–206 (2012)
20. Yang, X.-S., Cui, Z., Xiao, R., Gandomi, A.H., Karamanoglu, M.: *Swarm Intelligence and Bio-Inspired Computation: Theory and Applications*. 1st edn. (2013)
21. Gen, M., Cheng, R., Lin, L.: *Network Models and Optimization: Multiobjective Genetic Algorithm Approach (Decision Engineering)*. Springer, Heidelberg (2008)
22. Pongcharoen, P., Hicks, C., Braiden, P.M., Stewardson, D.J.: Determining optimum Genetic Algorithm parameters for scheduling the manufacturing and assembly of complex products. *Int. J. Prod. Econ.* **78**, 311–322 (2002)
23. Chaudhry, S.S., Luo, W.: Application of Genetic Algorithms in production and operations management: a review. *Int. J. Prod. Res.* **43**, 4083–4101 (2005)
24. Lenin, N., Kumar, M.S., Islam, M.N., Ravindran, D.: Multi-objective optimization in single-row layout design using a genetic algorithm. *Int. J. Adv. Manuf. Technol.* **67**, 1777–1790 (2013)
25. Kia, R., Khaksar-Haghani, F., Javadian, N., Tavakkoli-Moghaddam, R.: Solving a multi-floor layout design model of a dynamic cellular manufacturing system by an efficient genetic algorithm. *J. Manuf. Syst.* **33**, 218–232 (2014)
26. Rose, C.D., Coenen, J.M.G.: Comparing four metaheuristics for solving a constraint satisfaction problem for ship outfitting scheduling. *Int. J. Prod. Res.* **53**, 5782–5796 (2015)
27. Tompkins, J.A., White, J.A., Bozer, Y.A., Tanchoco, J.M.A.: *Facilities Planning*, 4th edn. Wiley, Hoboken (2010)

28. Loiola, E.M., de Abreu, N.M.M., Boaventura-Netto, P.O., Hahn, P., Querido, T.: A survey for the quadratic assignment problem. *Eur. J. Oper. Res.* **176**, 657–690 (2007)
29. Blackstone, J.H., Phillips, D.T., Hogg, G.L.: A state-of-the-art survey of dispatching rules for manufacturing job shop operations. *Int. J. Prod. Res.* **20**, 27–45 (1982)
30. Xiong, J., Xing, L.-N., Chen, Y.-W.: Robust scheduling for multi-objective flexible job-shop problems with random machine breakdowns. *Int. J. Prod. Econ.* **141**, 112–126 (2013)
31. Vitayasak, S., Pongcharoen, P.: Identifying optimum parameter setting for layout design via experimental design and analysis. *Adv. Mater. Res.* **931–932**, 1626–1630 (2014)
32. Lecchai, N., Iamtan, T., Pongcharoen, P.: Comparison on rank-based ant system and shuffled frog leaping for design multiple row machine layout. *SWU Eng. J.* **4**, 102–115 (2009)
33. Vitayasak, S., Pongcharoen, P.: Genetic Algorithm based robust layout design by considering various demand variations. In: Tan, Y., Shi, Y., Buarque, F., Gelbukh, A., Das, S., Engelbrecht, A. (eds.) *ICSI 2015*. LNCS, vol. 9140, pp. 257–265. Springer, Heidelberg (2015). doi:10.1007/978-3-319-20466-6\_28
34. Vitayasak, S., Pongcharoen, P.: Backtracking Search Algorithm for designing a robust machine layout. *WIT Trans. Eng. Sci.* **95**, 411–420 (2014)
35. Ousterhout, J.K.: *Tcl and Tk toolkit*, 2nd edn. Addison Wesley, Boston (2010)
36. Starkweather, T., McDaniel, S., Mathias, K., Whitley, D., Whitley, C.: A comparison of genetic sequencing operators. In: *Proceedings of the Third International Conference on Genetic Algorithms*, pp. 69–76 (1991)
37. Murata, T., Ishibuchi, H.: Performance evaluation of genetic algorithms for flow shop scheduling problems. In: *Proceedings of the First IEEE Conference on Evolutionary Computation*, pp. 812–817 (1994)
38. Pongcharoen, P., Stewardson, D.J., Hicks, C., Braiden, P.M.: Applying designed experiments to optimize the performance of genetic algorithms used for scheduling complex products in the capital goods industry. *J. Appl. Stat.* **28**, 441–455 (2001)
39. Eklund, N.H.W., Embrechts, M.J., Goetschalckx, M.: Efficient chromosome encoding and problem-specific mutation methods for the flexible bay facility layout problem. *IEEE Trans. Syst. Man Cybern. Part C-Appl. Rev.* **36**, 495–502 (2006)
40. Hu, M.H., Wang, M.J.: Using genetic algorithms on facilities layout problems. *Int. J. Adv. Manuf. Technol.* **23**, 301–310 (2004)