การประยุกต์ใช้โครงข่ายประสาทเทียมสำหรับการพยากรณ์อุปสงค์ในห่วงโซ่อุปทานของอุตสาหกรรมแขนจับยึดหัวอ่านในฮาร์ดดิสก์ไดร์ฟ

ดาริกา เรือนคำ*, วิมลิน เหล่าศิริถาวร, พงค์ศักดิ์ โหลิชยโชติกุล
ภาควิชาวิศวกรรมอุตสาหการ มหาวิทยาลัยเชียงใหม่ เชียงใหม่ 50200
โทร 053-944125-6โทรสาร 053-944185 E-mail u4306110@hotmail.com

บทคัดย่อ

ในงานวิจัยนี้ได้ทำการศึกษาและหารูปแบบการพยากรณ์ปริมาณยอดขายของผลิตภัณฑ์แขนจับยึดหัวอ่านฮาร์ดดิสก์ของบริษัทกรณีศึกษาแห่งหนึ่งในอุตสาหกรรมอิเล็กทรอนิกส์ ซึ่งผลิตส่วนประกอบในฮาร์ดดิสก์ไดรฟ์ในนิคมอุตสาหกรรมลำพูน ซึ่งได้นำโครงข่ายประสาทเทียมมาประยุกต์ใช้ในการหารูปแบบของการพยากรณ์ โดยโครงข่ายประสาทเทียมที่ใช้มีลักษณะโครงสร้างแบบมัลติเลเยอร์เพอร์เซพตรอน (Multilayer Perceptron) ที่มีการเรียนรู้แบบแบ็คพรอพาเกชั่นอัลกอริทึม (Back propagation Algorithm) และใช้ข้อมูลในรูปแบบอนุกรมเวลาเป็นปัจจัยนำเข้า ผลการพยากรณ์ที่ได้ถูกนำมาเปรียบเทียบกับ การพยากรณ์แบบ ARIMA (Box - Jenkins) การพยากรณ์แบบวินเตอร์ การพยากรณ์แบบเอ็กซ์โปเนนเชียลสองครั้ง เอ็กซ์โปเนนเชียลครั้งเดียว ค่าเฉลี่ยแบบเคลื่อนที่ 3 เวลา และค่าอุปสงค์ประมาณจากลูกค้า(Customer Demand Forecast : CDF) ผลการวิจัยแสดงค่าจากการพยากรณ์โดยโครงข่ายประสาทเทียม มีความแม่นยำกว่าการพยากรณ์ด้วยเทคนิคต่างๆ ดังกล่าวข้างต้น และแม่นยำกว่าค่าอุปสงค์พยากรณ์จากลูกค้า โดยการพยากรณ์แบบโครงข่ายประสาทเทียมแสดงค่าร้อยละของค่าความคลาดเคลื่อนเฉลี่ยสัมบูรณ์ (Mean Absolute Percentage Square Error: MAPE) เท่ากับ 7.37 ส่วนการพยากรณ์แบบ ARIMA มีค่าเท่ากับ 28.72 การพยากรณ์แบบวินเตอร์ มีค่าเท่ากับ 35.09 การพยากรณ์แบบเอ็กซ์โปเนนเชียลสองครั้ง มีค่าเท่ากับ 35.54 การพยากรณ์แบบเอ็กซ์โปเนนเชียลครั้งเดียว มีค่าเท่ากับ 29.74 การพยากรณ์แบบค่าเฉลี่ยแบบเคลื่อนที่ 3 เวลา มีค่าเท่ากับ 28.37 และค่าอุปสงค์ประมาณจากลูกค้า มีค่าเท่ากับ 14.75 จากผลการวิจัยจึงสรุปได้ว่าการพยากรณ์โดยโครงข่ายประสาทเทียมมีค่าแม่นยำมากที่สุด

เมื่อได้ค่าการพยากรณ์ที่เหมาะสมที่สุดแล้วจึงทำการศึกษาผลกระทบบูลวิป โดยใช้ค่าจากการพยากรณ์โดยโครงข่ายประสาทเทียม จำลองวางแผนการผลิต การจัดซื้อ และวัดประสิทธิภาพเปรียบเทียบกับวิธีการเดิมคือใช้ค่าอุปสงค์ประมาณจากลูกค้า พบว่าประสิทธิภาพในการวางแผนการผลิต และการจัดซื้อเพิ่มขึ้น 10%

คำหลัก: โครงข่ายประสาทเทียม; อนุกรมเวลา; แบ็คพรอพาเกชั่นอัลกอริทึม; มัลติเลเยอร์เพอร์เซพตรอน; ARIMA

1. ที่มาและความสำคัญ

ในปัจจุบันห่วงโซ่อุปทาน (Supply Chain) ซับซ้อนมากขึ้นทำให้ระบบการพยากรณ์ในอดีต ไม่ค่อยเหมาะสมกับสถานการณ์ปัจจุบัน ซึ่งการพยากรณ์ที่ไม่เที่ยงตรงณ.จุดใดจุดหนึ่งในห่วงโซ่อุปทานจะส่งผลกระทบไปทั่วทั้งห่วงโซ่อุปทาน อันเนื่องมาจากผลกระทบบูลวิป (Bullwhip Effect) ส่งผลกระทบต่อการวาง

แผนการผลิตในโรงงาน และการวางแผนการผลิตให้ตรงตามอุปสงค์ของลูกค้าทั้งในแง่ของเวลาและปริมาณ ซึ่งเป็นปัญหาที่ยากยิ่งสำหรับธุรกิจ

ปัญหาดังกล่าวเกิดขึ้นในโรงงานกรณีศึกษา ซึ่งเป็นโรงงานผลิตชิ้นส่วนอิเล็กทรอนิกส์ ที่เป็นส่วนประกอบในฮาร์ดดิสก์ไดร์ฟ พบว่าอุปสงค์ของลูกค้ามีความไม่แน่นอนค่อนข้างสูง ส่งผลให้วิธีการพยากรณ์ที่บริษัทใช้ในปัจจุบันไม่สามารถพยากรณ์อุปสงค์ได้อย่างแม่นยำเพียงพอ ซึ่งความผิดพลาดจากการพยากรณ์นี้จะนำมาซึ่งปัญหาในการวางแผนการผลิตหลายประการ เช่นซื้อวัตถุดิบมากเกินไปทำให้เกิดต้นทุนสินค้าคงคลังที่สูง ทำให้เกิดการทำงานล่วงเวลา และค่าใช้จ่ายการซ่อมบำรุงเครื่องจักรที่สูงขึ้น การซื้อวัตถุดิบที่น้อยเกินไป ทำให้การผลิตหยุดชะงัก และเสียโอกาสในการขาย ดังนั้นการพยากรณ์อุปสงค์ที่แม่นยำจึงเป็นปัจจัยสำคัญในการบริหารห่วงโซ่อุปทาน

ซึ่งบริษัทชั้นนำทั้งหลายก็ยอมรับเช่นเดียวกันว่า สามารถบริหารอุปสงค์ของลูกค้าได้ในระดับหนึ่งเท่านั้น ความแปรปรวนของอุปสงค์เป็นสาเหตุหลักอันหนึ่งที่ก่อให้เกิดความไม่สอดคล้องกันของโซ่อุปทานและโซ่อุปสงค์ ที่สภาวะในอุดมคติทุกบริษัทปรารถนาที่จะรู้ขนาดอุปสงค์ และต้องการให้อุปสงค์ภายในโซ่คุณค่า(Value Chain) มีความสม่ำเสมอ ทั้งนี้เพื่อทำให้บริษัทสามารถตอบสนองความต้องการของลูกค้าได้ด้วยต้นทุนที่ต่ำที่สุด หากนึกภาพของโซ่อุปทานที่สินค้าถูกผลิตขึ้นมาในปริมาณที่พอเหมาะ และสินค้านั้นบรรทุกเต็มยานพาหนะขนส่งพอดี ถูกส่งไปยังจุดที่มีการใช้สินค้านั้นตรงตามเวลาพอดีที่ลูกค้าเริ่มปฏิบัติงานและปริมาณการใช้สินค้านั้นเพียงพอจนกว่าจะถึงการจัดส่งครั้งต่อไป โซ่อุปทานในอุดมคติคือ โซ่อุปทานที่มีความสอดคล้องกันของปริมาณสินค้าที่เหมาะสม และเงื่อนไขของการปฏิบัติงานที่มีความแน่นอนในระดับสูง รวมทั้งไม่จำเป็นต้องมีการเก็บคลังสินค้าสำรอง ไม่มีการทำงานที่ซ้ำซ้อน ไม่ต้องมีสินค้าคงคลัง และมีค่าใช้จ่ายในการขนส่งที่ต่ำที่สุด ซึ่งสินค้าจะถูกผลิต จัดส่ง และใช้ไปตามปริมาณที่ได้ทำนายไว้ในช่วงระยะเวลาที่แน่นอน (สาธิต, 2548)

เนื่องจากมีผลกระทบบูลวิปเกิดขึ้นภายในโซ่อุปทาน ผลกระทบบูลวิปนี้ไม่ว่าจะอยู่ที่ใดในโซ่อุปทานก็มีผลกระทบต่อโซ่อุปทานโดยรวม ความแปรปรวนของอุปสงค์ก่อให้เกิดภาระหนักแก่บริษัทในแง่ของต้นทุนการผลิต และความซับซ้อนของการทำงานที่เพิ่มขึ้น การจัดการผลกระทบบูลวิปจึงเป็นสิ่งจำเป็นเพื่อที่จะทำให้โซ่อุปทานมีประสิทธิภาพสูงสุด

ดังนั้นการดำเนินธุรกิจควรคำนึงถึงความสำคัญของอุปสงค์ที่แท้จริงของลูกค้า โดยลดผลกระทบบูลวิปและสร้างความพึงพอใจให้ลูกค้า

จากวรรณกรรมปริทัศน์ พบว่าเทคนิคโครงข่ายประสาทเทียม ได้เริ่มนำมาใช้ในการพยากรณ์เช่น การพยากรณ์ปริมาณการส่งออกข้าว, การพยากรณ์ความต้องการสินค้าในซุปเปอร์มาร์เก็ต, การพยากรณ์ยอดขายแหวน เป็นต้น พบว่ามีประสิทธิภาพในการพยากรณ์ มากกว่าเทคนิคดั้งเดิม

งานวิจัยฉบับนี้จึงมุ่งเน้นที่จะประยุกต์เทคนิคโครงข่ายประสาทเทียมแบบแพร่กระจายย้อนกลับ ในการพยากรณ์อุปสงค์ในห่วงโซ่อุปทาน เพื่อให้สามารถทราบอุปสงค์ของลูกค้าล่วงหน้าได้อย่างแม่นยำมากยิ่งขึ้น โดยใช้ข้อมูลจากในอดีตมาทำการวิเคราะห์

2. บทความปริทัศน์และทฤษฎีพื้นฐาน

Carbonneau *et al*. (2007) ได้ทำการประยุกต์ใช้เทคนิคแมชชีน เลินนิ่ง (Machine Learning) เพื่อการพยากรณ์ความต้องการสำหรับห่วงโซ่อุปทาน ซึ่งงานวิจัยนี้มีวัตถุประสงค์เพื่อศึกษาความเป็นไปได้และทำการวิเคราะห์เชิงเปรียบเทียบของการพยากรณ์ถึงสัญลักษณ์ความต้องการที่ผิดเพี้ยน (Distorted Demand

Signal) ในห่วงโซ่อุปทาน โดยใช้เทคนิคแมชชีน เลินนิ่ง แบบไม่เป็นเส้นตรง โดยเน้นที่การพยากรณ์ความต้องการตั้งแต่ต้นน้ำไปจนถึงปลายห่วงโซ่อุปทาน ซึ่งเทคนิคใหม่ที่นำมาใช้ในการวิเคราะห์ ได้แก่ โครงข่ายประสาทเทียม (Artificial Neural Networks: ANN),โครงข่ายประสาทเทียมแบบรีเคอร์เร้นท์(Recurrent Neural Networks: RNN) และ ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machines: SVM) สมรรถภาพของเทคนิคดังกล่าวจะนำไปเปรียบเทียบกับการพยากรณ์วิธีเก่า ประกอบด้วย วิธีอย่างง่าย (Naïve Forecasting), วิธีพยากรณ์แบบเฉลี่ย, วิธีพยากรณ์เฉลี่ยแบบเคลื่อนที่ (Moving Average), วิธีพยากรณ์แบบแนวโน้ม และ การวิเคราะห์การถดถอยเชิงเส้น สรุปได้ดังรูปที่ 1

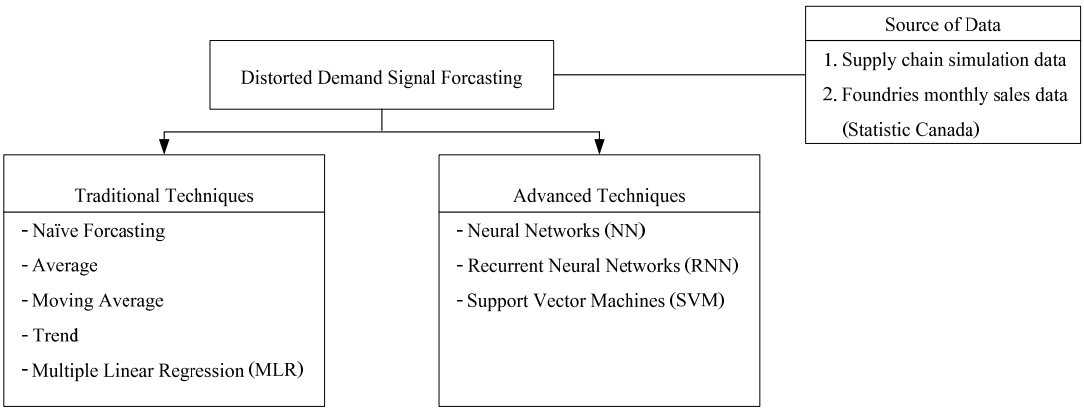

รูปที่ 1: การพยากรณ์อุปสงค์ในห่วงโซ่อุปทาน โดยเปรียบเทียบระหว่างเทคนิคเก่าและใหม่

ซึ่งในการวัดประสิทธิภาพของเทคนิคแมชชีน เลินนิ่ง ใช้แหล่งข้อมูลมาจาก 2 แห่ง ในการเตรียมข้อมูล โดยข้อมูลแรกมาจากแบบจำลองของส่วนประกอบห่วงโซ่อุปทาน และแหล่งที่สองมาจากข้อมูลจริงที่ได้รับมาจาก Canadian Foundries (Statistics Canada)

จากการเปรียบเทียบผลทดสอบโดยใช้ค่าเฉลี่ยความผิดพลาด (Mean Average Error: MAE) ปรากฏว่า RNN และ LS-SVM มีผลลัพธ์ดีที่สุด โดยชุดข้อมูลความต้องการของ Canadian Foundries มีความแม่นยำของทั้งสองวิธีสูงกว่าชุดข้อมูลแบบจำลองความต้องการ โดยทั้งสองกรณี SVM ชุดฝึกสอนมีความแม่นยำดีที่สุด ซึ่งส่งผลกระทบต่อชุดทดสอบน้อยที่สุด ส่วนการพยากรณ์ด้วยวิธีประมาณค่าแนวโน้มและการพยากรณ์อย่างง่าย มีผลการพยากรณ์แย่ที่สุด ซึ่งมีระดับความผิดพลาดสูงที่สุด มีการทดสอบความแตกต่างของข้อมูลที่ได้จากเทคนิคการพยากรณ์ที่ต่างกันด้วยการทดสอบแบบ T-Test ผลปรากฏว่า RNN และ SVM ข้อมูลการพยากรณ์มีความแม่นยำมากที่สุด การพยากรณ์อย่างง่าย, วิธีพยากรณ์แบบเฉลี่ย, วิธีพยากรณ์เฉลี่ยแบบเคลื่อนที่ (Moving Average) และวิธีพยากรณ์แบบแนวโน้ม มีสมรรถภาพไม่ดี อย่างไรก็ตาม ผลการวิเคราะห์ทางสถิติ แสดงให้เห็นว่า เทคนิคการพยากรณ์ระหว่างวิธี RNN, SVM, ANN, และ MLR ไม่มีความแตกต่างกันอย่างมีนัยสำคัญทางสถิติ โดย RNN ดีกว่าเนื่องจากความสามารถในการตวจจับรูปแบบชั่วคราวที่ดีกว่า.

Lee *et al.* (2006) ประยุกต์ใช้โครงข่ายประสาทเทียมสำหรับการกำหนดปริมาณการผลิตเพื่อตอบสนองความต้องการตามใบสั่ง ซึ่งในการศึกษาเพื่อให้ทราบถึงปริมาณความต้องการที่มีจำนวนมากเกินไปของใบสั่งซื้อ (Surplus Demand) นอกจากนั้นได้ใช้โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ เป็นรูปแบบสำหรับการเรียนรู้ข้อมูลในอดีตของผู้ซื้อและผู้ผลิต โดยโครงสร้างของโครงข่ายประสาทเทียมหลายชั้น มี 6

ปัจจัยนำเข้า ค่าถ่วงน้ำหนักระหว่างโหนดเป็นความสัมพันธ์ระหว่างค่าสังเกตของทั้ง 6 ปัจจัยต่อสัปดาห์ และปริมาณความต้องการที่มากเกินไปต่อสัปดาห์ โดยการวัดสมรรถภาพตามนโยบายที่กำหนด.

Chiu and Lin (2004) นำเสนองานวิจัยโดยมีแนวคิดในการนำโครงข่ายประสาทเทียมมาทำการวางแผนห่วงโซ่อุปทาน (Supply Chain Planning: SCP) แบบจำลองห่วงโซ่อุปทานถูกประยุกต์ใช้เพื่อวางแผนของอุปทานสำหรับการประกอบสินค้าตามใบสั่งโดยใช้ระยะเวลาการส่งที่สั้นในตลาดเฉพาะเขตสำหรับโครงข่ายห่วงโซ่อุปทานที่สัมพันธ์กันของบริษัทขนาดเล็กที่ขายคอมพิวเตอร์ส่วนบุคคล (Personal Computers: PCs) 5 แห่ง ในการศึกษานี้แบบจำลองห่วงโซ่อุปทานประกอบด้วยตัวแทนใน 4 ส่วน คือ ลูกค้า (Customer) ผู้ขายปัจจัยการผลิต (Supplier) กระบวนการผลิต (Production) และการส่งสินค้า (Delivery) โดยแบบจำลองนี้มีจุดเด่นคือ สามารถเปลี่ยนได้ตามสเป็คของลูกค้าได้อย่างรวดเร็ว เหมือนเทคโนโลยีที่มีความทันสมัย ซึ่งงานวิจัยนี้ทำการเปรียบเทียบผลข้อมูลระหว่าง ระบบตัวแทนการประมูล(Agent-Based Auction Mechanism) กับ โครงข่ายประสาทเทียม.

2.1 การจัดการห่วงโซ่อุปทาน (Supply Chain Management)

การจัดการห่วงโซ่อุปทาน เป็นการบริหารการทำงานร่วมกันระหว่างกิจการที่อยู่ในสายการผลิตตลอดสายตั้งแต่ต้นกระบวนการผลิตไปจนจบกระบวนการที่ผู้บริโภค โดยการแบ่งปันข่าวสารข้อมูลที่จำเป็น และใช้ทรัพยากรที่มีอยู่อย่างจำกัดร่วมกัน เพื่อให้บรรลุวัตถุประสงค์ในการลดต้นทุนให้ต่ำที่สุด และตอบสนองความต้องการของผู้บริโภคได้สูงสุด ผลที่ได้รับจะทำให้ผู้ประกอบการตลอดสายสามารถใช้ประโยชน์จากทรัพยากรของตนได้มีประสิทธิภาพมากขึ้น ได้รับผลตอบแทนจากการดำเนินงานดีขึ้น สามารถแข่งขันในตลาดได้ดีขึ้น Chopra (1999)

ผลกระทบบูลวิป ได้มีผู้ให้จำกัดความว่า เป็นปรากฏการณ์ของความไม่แน่นอนที่เปลี่ยนแปลงขยายเพิ่มขึ้นทุกขั้นตอน H. Lee (1997) ที่มีการถ่ายทอดต่อเนื่องภายในห่วงโซ่อุปทาน โดยที่ความแปรปรวนของอุปสงค์ที่เกิดขึ้นแต่ละขั้นตอนขยายเพิ่มขึ้น เมื่อมีการถ่ายทอดของข้อมูลภายในห่วงโซ่อุปทาน และมีความสัมพันธ์กับต้นทุนที่เพิ่มสูงขึ้นด้วย ดังเช่น ต้นทุนในการจัดเก็บคงคลัง ค่าใช้จ่ายเนื่องจากสินค้าสำรองขาด ต้นทุนของกำลังการผลิตส่วนเกินหรือกำลังการผลิตที่ไม่เพียงพอ การบริการลูกค้าที่ลดลง และต้นทุนในการแก้ปัญหา

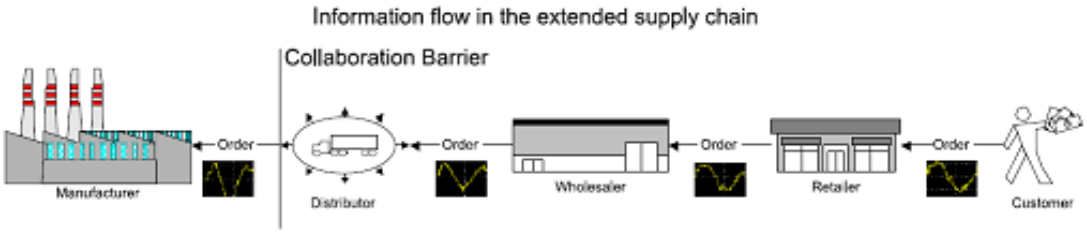

รูปที่ 2: แสดงการเกิดผลกระทบบูลวิปของอุปสงค์ในห่วงโซ่อุปทาน
ที่มา : Carbonneau, R. *etal*. (2007).

2.2 โครงข่ายประสาทเทียม (Artificial Neural Network)

โครงข่ายประสาทเทียม คือโมเดลทางคณิตศาสตร์ เพื่อจำลองการทำงานของเครือข่ายประสาทในสมองมนุษย์ ด้วยวัตถุประสงค์ที่จะสร้างเครื่องมือซึ่งมีความสามารถในการเรียนรู้การจดจำรูปแบบ (Pattern Recognition) และการอุปมานความรู้ (Knowledge Deduction) เช่นเดียวกับความสามารถที่มีในสมองมนุษย์

แนวคิดเริ่มต้นของเทคนิคนี้ได้มาจากการศึกษาข่ายงานไฟฟ้าชีวภาพ (Bioelectric Network) ในสมอง ซึ่งประกอบด้วย เซลล์ประสาท หรือ “นิวรอล” (Neurons) และ จุดประสานประสาท (Synapses) แต่ละเซลล์ประสาทประกอบด้วยปลายในการรับกระแสประสาท เรียกว่า "เดนไดรท์" (Dendrite) ซึ่งเป็นข้อมูลนำเข้า (Input) และปลายในการส่งกระแสประสาทเรียกว่า "แอคซอน" (Axon) ซึ่งเป็นเหมือนข้อมูลนำออก (Output) ของเซลล์ เซลล์เหล่านี้ทำงานด้วยปฏิกิริยาไฟฟ้าเคมี เมื่อมีการกระตุ้นด้วยสิ่งเร้าภายนอกหรือกระตุ้นด้วยเซลล์ด้วยกัน กระแสประสาทจะวิ่งผ่านเดนไดรท์เข้าสู่นิวเคลียสซึ่งจะเป็นตัวตัดสินว่าต้องกระตุ้นเซลล์อื่น ๆ ต่อหรือไม่ ถ้ากระแสประสาทแรงพอ นิวเคลียสก็จะกระตุ้นเซลล์อื่น ๆ ต่อไปผ่านทางแอคซอน ตามแบบจำลองนี้ข่ายงานประสาทเกิดจากการเชื่อมต่อระหว่างเซลล์ประสาท จนเป็นเครือข่ายที่ทำงานร่วมกัน Khaw,J (1999)

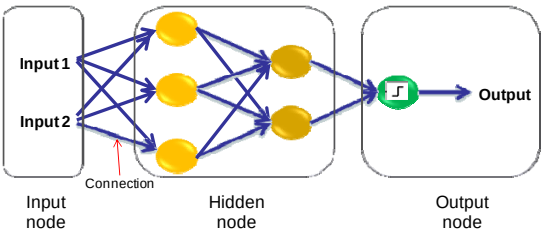

รูปที่ 3: แสดงโครงสร้างของโครงข่ายประสาทเทียม

$$y_i = f(w_i^1 x_1 + w_i^2 x_2 + w_i^3 x_3 + ... + w_i^m x_m) = f(\sum_j w_i^j x_j) \quad (1)$$

เมื่อ y_i = ตัวแปรนำออก

x_i = ตัวแปรนำเข้าจากโหนดอื่นๆ

w_{ij} = น้ำหนัก (Weight) ของแต่ละเส้น (Connection)

2.2.1 การเรียนรู้โดยวิธี แพร่กระจายย้อนกลับ (Back propagation Algorithm)

กระบวนการเรียนรู้โดยใช้วิธี แพร่กระจายย้อนกลับ เป็นการเรียนรู้แบบหนึ่งที่จัดอยู่ในแบบต้องมีการสอน (Supervised Learning) ซึ่งมีการแสดงทั้งข้อมูลขาเข้า และผลลัพธ์ที่เป็นเป้าหมายให้โครงข่ายประสาทเทียมได้ทราบ จากข้อมูลขาเข้าที่ได้รับ โครงข่ายประสาทเทียมจะทำการประมวลหาค่าผลลัพธ์ออกมา หลังจากนั้นค่าความผิดพลาดระหว่างผลลัพธ์ที่ได้กับผลลัพธ์ที่เป็นเป้าหมายจะถูก“แพร่” ย้อนกลับเข้ามาในโครงข่ายประสาทเทียมเพื่อใช้ในการปรับค่าน้ำหนักเส้นเชื่อมต่อ จนกระทั่งค่าความผิดพลาดลดน้อยลงต่ำกว่าค่าที่กำหนดในช่วงเริ่มต้นของกระบวนการเรียนรู้ ค่าน้ำหนักเส้นเชื่อมต่อถูกกำหนดโดยการสุ่มโดยใช้ค่าน้อยๆ เมื่อได้รับข้อมูลคู่หนึ่งจากชุดข้อมูลสำหรับการเรียนรู้ โครงข่ายประสาทเทียมก็จะทำการประมวลผลจนได้ค่าผลลัพธ์ y_s ออกมา ซึ่งค่าผลลัพธ์ดังกล่าวเป็นผลจากค่าน้ำหนักเส้นเชื่อมต่อในขณะนั้น

$$E = \frac{1}{2}\sum_1^i (Z_i - o_i)^2 \quad (2)$$

โดย z_i คือ ผลลัพธ์เป้าหมาย และ o_i คือ ผลลัพธ์ที่ได้จากโครงข่ายประสาทเทียม

การปรับค่าน้ำหนักมีสมการดังนี้

$$\Delta w_{ij} = \alpha.\delta_i.x_i \tag{3}$$

เมื่อ α คือ อัตราการเรียนรู้ (Learning Rate) และ δ_i คือ ค่าผิดพลาดของนิวรอนในเลเยอร์ถัดไป ค่าผิดพลาดของนิวรอนที่อยู่ในชั้นแอบแฝงคำนวณได้จากสมการ

$$\delta_i = f^{'}(I_i).\sum_j \delta_j w_{ij} \tag{4}$$

ค่าผิดพลาดของนิวรอนที่อยู่ในชั้นชั้นเอาท์พุทคำนวณได้จากสมการ

$$\delta_i = f^{'}(I_i).(z_i - o_i) \tag{5}$$

การคำนวณค่าผิดพลาดจะทำภายในชั้นแอบแฝงก่อนชั้นเอาท์พุท ขั้นตอนนี้จะดำเนินการไปเรื่อยๆ จนกระทั่งอินพุทชุดใหม่ถูกป้อนเข้าสู่โครงข่ายประสาทเทียม

2.3 วิธีการตัวแบบบอกซ์-เจนกินส์ หรือตัวแบบ ARIMA

วิธีบอกซ์-เจนกินส์ เป็นวิธีการสร้างตัวแบบพยากรณ์สำหรับอนุกรมเวลาที่นำเอาสหพันธ์ของอนุกรมเวลา $\{....,Y_{t-2},Y_{t-1},Y_t,Y_{t+1},....\}$ ที่ปรากฏไปวิเคราะห์ใช้ประโยชน์โดยพิจารณาสหสัมพันธ์ระหว่าง Y ที่ตำแหน่งเวลาหรือคาบเวลา $t(Y_t)$ และ Y ที่ตำแหน่งเวลาหรือคาบเวลาต่าง ๆ ที่ผ่านมา $(Y_{t-1},Y_{t-2},....)$ โดยเมื่อได้ตัวแบบแล้ว ตัวแบบนี้จะแสดงความสัมพันธ์ระหว่าง Y_t กับ Y_{t-1},Y_{t-2} และจะใช้ตัวแบบนี้พยากรณ์ค่า Y_{t+1},Y_{t+2} ในอนาคตซึ่งต่างจากวิธีการพยากรณ์อนุกรมเวลาโดยทั่วไป เช่น วิธีการปรับให้เรียบ จะมีข้อสมมุติพื้นฐานข้อหนึ่งคือ อนุกรมเวลา $\{....,Y_{t-2},Y_{t-1},Y_t,Y_{t+1},....\}$ ไม่มีสหสัมพันธ์ ซึ่งบ่อยครั้งพบว่าข้อสมมุตินี้ไม่เป็นจริง นั้นคือ มีหลายกรณีที่อนุกรมเวลา $\{....,Y_{t-2},Y_{t-1},Y_t,Y_{t+1},....\}$ มีสหสัมพันธ์ ถ้าเป็นเช่นนี้ การใช้วิธีที่มีข้อสมมติตัวแปรอนุกรมเวลาไม่มีสหสัมพันธ์อาจจะไม่เหมาะสม ทั้งนี้เพราะวิธีการเหล่านี้ไม่ได้นำสหสัมพันธ์ที่ปรากฏไปใช้ประโยชน์ในการสร้างตัวแบบพยากรณ์ ฉะนั้นจึงได้มีผู้คิดค้นหาวิธีการสร้างตัวแบบพยากรณ์ สำหรับอนุกรมเวลาที่ได้นำเอาสหสัมพันธ์ที่ปรากฏไปวิเคราะห์ใช้ประโยชน์ และโดยทั่วไปวิธีเหล่านี้จะให้ผลพยากรณ์ที่ดีกว่า ในหลายวิธีเหล่านี้ วิธีหนึ่งที่เป็นที่รู้จักและใช้กันมากก็คือ วิธีบอกซ์-เจนกินส์ ซึ่งพัฒนาโดย Box and Jenkins

ตัวแบบ ARIMA (p , d , q) จะมีรูปแบบตามสมการที่ (6)

$$\phi_P(B)(1-B)^d Y_t = \delta + \phi_q(B)a_t \qquad \text{หรือ}$$

$$\phi_P(B)W_t = \delta + \phi_q(B)a_t \tag{6}$$

ซึ่งให้ $W_t = (1-B)^d Y_t$ และ δ (อาจมีค่าเท่ากับศูนย์) เป็นพารามิเตอร์แสดงระดับค่าเฉลี่ยคงที่ของอนุกรม W_t และ Y_t เป็นอนุกรมที่ถูกแปลงให้มีความแปรปรวนคงที่แล้ว ถ้าอนุกรมแรกเริ่มไม่คงที่ในความแปรปรวน

ตัวแบบ ARIMA $(p,d,q)(P,D,Q)_s$ จะมีรูปแบบตามสมการ (31)

$$\phi_p(B)\Phi_p(B^s)(1-B)^d(1-B^s)^D Y_t = \delta + \theta_q(B)\Theta_Q(B^s)a_t \tag{7}$$

โดยที่ $\Phi_p(B^s) = (1-\Phi_s B^s - \Phi_{2s}B^{2s} - .... - \Phi_{ps}B^{ps})$

$\Theta_p(B^s) = (1-\Theta_s B^s - \Theta_{2s}B^{2s} - .... - \Theta_{ps}B^{ps})$

3. วิธีการดำเนินการ

จากการเอกสารและผลงานวิจัยที่เกี่ยวข้อง เราสามารถกำหนดวิธีดำเนินการวิจัย โดยการสร้างแบบจำลองการพยากรณ์อุปสงค์ของห่วงโซ่อุปทานบริษัทกรณีศึกษาโดยมีขั้นตอนการวิจัย ดังต่อไปนี้

3.1 สำรวจและคัดเลือกข้อมูลปัญหาปัจจุบันของห่วงโซ่อุปทานผลิตภัณฑ์ B (มกราคม พ.ศ. 2547-มิถุนายน พ.ศ. 2550) เป็นจำนวน 120 สัปดาห์ทำงานของโรงงานกรณีศึกษา โดยวิเคราะห์ข้อมูลอุปสงค์และอุปทานเบื้องต้นของห่วงโซ่อุปทานดังกล่าว เพื่อวัดประสิทธิภาพการตอบสนองลูกค้า การบริหารการผลิตและทรัพยากรการผลิต เพื่อกำหนดทิศทางในการแก้ปัญหา

ตารางที่ 1: แสดงช่วงข้อมูลที่ใช้ในงานวิจัย

ผลิตภัณฑ์	คาบเวลาเริ่มต้น	คาบเวลาสิ้นสุด	คาบเวลาทั้งหมด
ผลิตภัณฑ์ B	กุมภาพันธ์ 2006	มิถุนายน 2008	รวม 120 ข้อมูลสัปดาห์

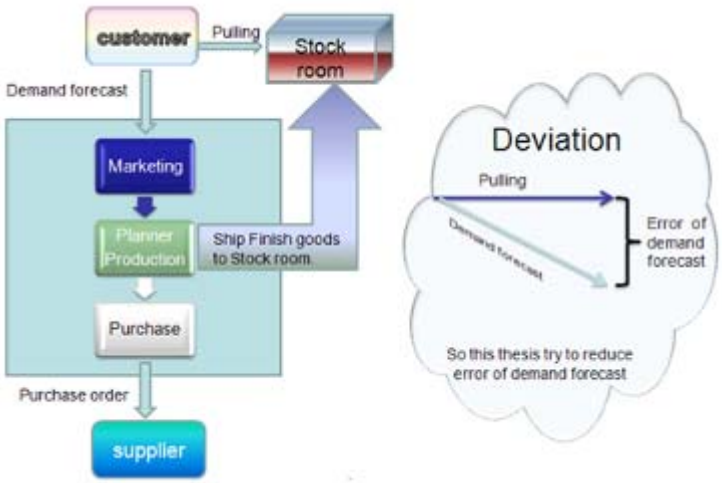

รูปที่ 4 : แสดงห่วงโซ่อุปทานอย่างง่ายภายในและภายนอกของโรงงานกรณีศึกษา และปัญหาที่เกิดขึ้น

3.2 การพยากรณ์โดยวิธีอนุกรมเวลา (Time Series Method)

*3.2.1 ทำการทดสอบข้อมูลเบื้องต้น*ด้วยการ พล็อตกราฟ ค่าอุปสงค์เทียบกับเวลา (Yt) เพื่อให้เห็นภาพแนวโน้ม วงจรชีวิตผลิตภัณฑ์ วัฏจักรและ/หรือเหตุการณ์ผิดปรกติได้ง่าย (ทรงศิริ, 2539)

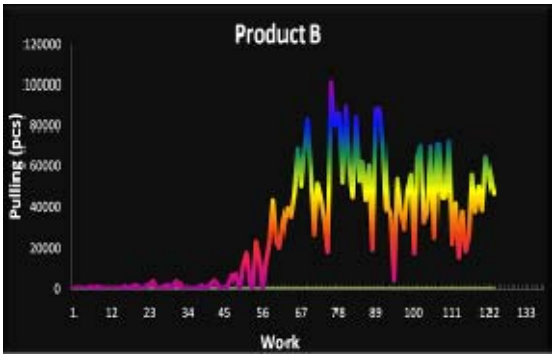

กราฟที่ 1: แสดงอุปสงค์ที่แท้จริง หรือ Pulling ของลูกค้าในผลิตภัณฑ์ชนิด B

3.2.2 สร้างแบบจำลอง Moving Average, Single Exponential Smoothing, Double Exponential Smoothing, winter's Method เพื่อพยากรณ์ค่าถัดจากคาบเวลาปัจจุบัน 12 คาบเวลา โดยทำการพยากรณ์ทีละคาบเวลา

3.2.3 การพยากรณ์แบบอารีมา มีขั้นตอนดังนี้ (นพรัตน์, 2550)

1) การกำหนดแบบจำลอง (Model Identification) เลือกรูปแบบจากการวิเคราะห์ข้อมูลในอดีต ทำการคำนวณค่าสถิติต่าง ๆ เพื่อช่วยในการตัดสินใจเลือกรูปแบบ โดยขั้นแรก ต้องพิจารณาดูว่าข้อมูลอนุกรมเวลาอยู่ในสภาพสมดุล มีการกระจายอยู่รอบ ๆ ค่าเฉลี่ยแบบคงที่ ประกอบด้วย
   - อนุกรมมีลักษณะนิ่ง (Stationary) โดยมีค่าเฉลี่ย และความแปรปรวนคงที่
   - กำหนดรูปแบบในนุกรมเวลาด้วยกราฟค่าอัตตสหสัมพันธ์(ACF) และ ค่าอัตตสหสัมพันธ์เชิงส่วน (PACF)
2) การประมาณค่าพารามิเตอร์ (Parameter Estimation) เป็นการประมาณค่าสัมประสิทธิ์ของแบบจำลอง จากรูปแบบที่ได้เลือกไว้ในขั้นที่ 1 ด้วยวิธีกำลังสองน้อยที่สุด (Least Square Method) โดยการป้อนค่าประมาณเบื้องต้น (Initial Estimates) ให้กับเครื่องคอมพิวเตอร์ เพื่อประมวลผลจนได้ค่าประมาณสุดท้าย (Final Estimates) ซึ่งเครื่องคอมพิวเตอร์ จะทำการคำนวณหลายครั้ง (Iterative) จนกว่าจะให้ มีค่าน้อยที่สุด
3) การตรวจสอบแบบจำลอง (Model Diagnostics)ตรวจสอบความเหมาะสมของแบบจำลอง โดยใช้ Modified Box – Pierce (Ljung - Box) Chi – Square Statistic
4) การพยากรณ์ (Forecasting)
   - ทำการพยากรณ์โดยแบบจำลองที่เหมาะสม
   - การพยากรณ์มีเหตุผล และสามารถอธิบายได้
   - ใช้กราฟ (Graph) ค่าสถิติ (Statistics) และช่วงความเชื่อมั่น (Confidence Intervals) ในการพิจารณากำหนดความเหมาะสมของตัวแบบจำลอง
5) ทำการทดสอบความแม่นยำของตัวแบบปริมาณการใช้พลังงานในสาขาอุตสาหกรรมโลหะขั้นมูลฐานและอุตสาหกรรมสิ่งทอโดย ARIMA โดยดัชนีที่ใช้ในการวัดค่าคลาดเคลื่อน คือ ค่าเบี่ยงเบนมาตรฐานของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Square Error: RMSE) สามารถคำนวณดังสมการที่ 7 และร้อยละของค่าความคลาดเคลื่อนเฉลี่ยสัมบูรณ์ (Mean Absolute Percentage Square Error: MAPE)

<u>3.3 แบบจำลองโครงข่ายประสาทเทียม (Artificial Neural Network Models)</u>

เมื่อได้ข้อมูลจากข้อ 3.1 เพื่อการสร้างแบบจำลองการพยากรณ์ นำชุดข้อมูลมาสุ่มแบ่งเป็น 2 ชุด

ตารางที่ 2: แสดงการแบ่งข้อมูลให้โครงข่ายประสาทเทียม

ชุดข้อมูลสำหรับ	คิดเป็นร้อยละชุดข้อมูลตั้งต้น
ฝึกสอน (Training Set)	90 (109 ข้อมูล)
ทดสอบ(Test Set)	10 (12 ข้อมูล)

3.3.1 กระบวนการฝึกสอน และทดสอบ เพื่อหาโครงสร้างที่ดีที่สุด

การค้นหาโครงสร้างที่เหมาะสมโครงข่ายประสาทเทียมแบบหลายชั้น โดยใช้ การค้นหาแบบ Grid Search โดยทดสอบจำนวนชั้นซ่อนตั้งแต่ 1 ถึง 2 ชั้น โดยชั้นซ่อนที่ 1 มีจำนวนโหนดตั้งแต่ 4 ถึง 19 โหนด ส่วนชั้นซ่อนที่ 2 มีจำนวนโหนดตั้งแต่ 9 ถึง 26 คำนวณ โดยอ้างอิงจากการศึกษาวิจัยของ Khaw et al (1995) ดังรูปที่ 5

Number of neurons in hidden layers (N: number of inputs, OP: number of outputs)

Level	Factor	
	Number of neurons in hidden layer 1	Number of neurons in hidden layer 2
Level 1	$\sqrt{(N+\mathrm{OP})}$	$(N+\mathrm{OP})/2$
Level 2	$2N+1$	$2N+1+(2N+1)/3$
Level 3	$\mathrm{OP}\times(N+1)$	$\mathrm{OP}\times(N+1)+[\mathrm{OP}\times(N+1)]/3$

รูปที่ 5: แสดงสูตรการคำนวณหาช่วงชั้นซ่อนที่เหมาะสมในการค้นหา (Khaw et al (1995))

ซึ่งทำการเลือกโครงข่ายประสาทเทียมแบบหลายชั้นที่มีค่าความผิดพลาดการฝึกสอนแบบย้อนกลับของชุดข้อมูลทดสอบที่สามารถยอมรับได้ แล้วจึงนำโครงข่ายประสาทเทียมแบบหลายชั้นนั้นไปทำการเรียนรู้ด้วยวิธีการแพร่ย้อนกลับโดยมีการปรับค่าอัตราการเรียนรู้ (Learning Rate ; η) และโมเมนตัม (Momentum ; α) ให้เหมาะสมกับงานวิจัย โครงสร้างของโครงข่ายประสาทเทียมที่มีค่าความผิดพลาดในการประมาณ ค่าชุดข้อมูลที่สามารถยอมรับได้ จากนั้นทำการฝึกสอนใหม่ โดยหลักการไขว้อย่างมีเหตุผล ให้โครงข่ายประสาทเทียมที่ผ่านเงื่อนไขเพื่อปรับค่าน้ำหนัก ก่อนทำการทดสอบแบบจำลองโดยทำการพยากรณ์ความต้องการของลูกค้าสำหรับช่วงเวลาถัดจากเดือนปัจจุบัน 12 คาบเวลา

โดยผลการค้นหาโครงสร้างที่เหมาะสมที่สุดได้แก่โครงสร้าง 20-13-13-1 หรือ ส่วนนำเข้า 20 โหนด (เนื่องจากโปรแกรม alyuda แบ่ง ปัจจัยนำเข้า year เป็น 3 categories), มีชั้นซ่อนที่ 1 และ 2 จำนวน 13 โหนด เท่ากัน, มีปัจจัยนำออก 1 โหนด.

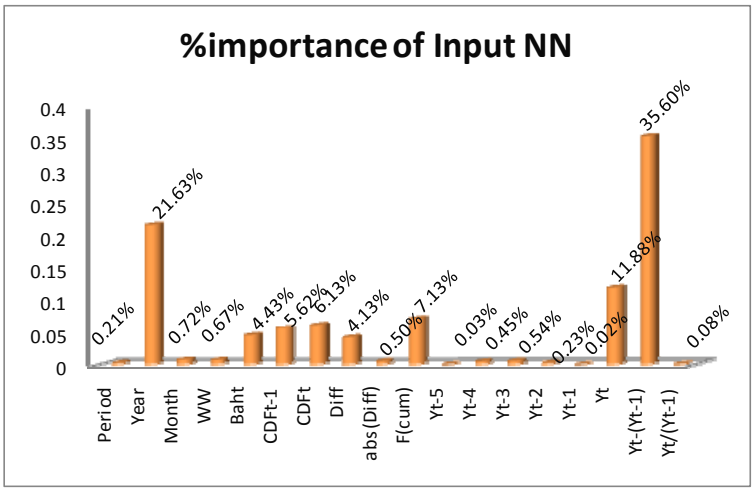

กราฟที่ 2: แสดงส่วนนำเข้าสำหรับโครงข่ายประสาทเทียม และ ค่าร้อยละความสำคัญเฉลี่ย

โดย *Period* คือ อนุกรมเวลาที่ 1…120, *Year* คือปีที่(2005-2008), *Month* คือ เดือนที่ (1-12), *WW* คือ สัปดาห์การทำงานของลูกค้าที่ (1-52), *Baht* คือ อัตราแลกเปลี่ยนเงินบาทกับดอลล่าร์, *CDFt* คือ

(Customer Demand Forecast) ค่าอุปสงค์พยากรณ์จากลูกค้าในคาบเวลาปัจจุบัน, *CDFt-1* คือ ค่าอุปสงค์พยากรณ์จากลูกค้าถัดจากคาบเวลาปัจจุบัน 1 คาบเวลา, *Diff* คือ ค่าความผิดพลาดระหว่างค่าอุปสงค์ที่แท้จริงกับค่าอุปสงค์พยากรณ์จากลูกค้า ($Yt-(CDF_{t-1})$), *abs(Diff)* คือ ค่าสัมบูรณ์ของค่า diff, *ฉสะสม* คือ ค่าความผิดพลาดจากการพยากรณ์อุปสงค์จากลูกค้าสะสม, *Yt to Yt-5* คือ ค่าอุปสงค์ที่แท้จริงย้อนไปในอดีต 0 ถึง 5 คาบเวลา, Y_t-Y_{t-1} คือ ค่าแตกต่างระหว่างค่าอุปสงค์ของลูกค้าคาบเวลาปัจจุบันกับอดีต, Y_t/Y_{t-1} คือ ค่าสัดส่วนระหว่างค่าอุปสงค์ของลูกค้าคาบเวลาปัจจุบันกับอดีต

3.3.2 ทำการทดสอบความแม่นยำของตัวแบบ

โดยทำการพยากรณ์ทีละค่า ทั้งหมด 12 คาบเวลา เริ่มจากค่าที่ 109 ไปจนถึงค่าที่ 120 ใช้ดัชนีวัดค่าความผิดพลาดโดย MAPE

3.4 วิเคราะห์ประสิทธิภาพ

นำผลการทดสอบแบบจำลองจากข้อ 3.2 และ 3.3 มาเปรียบเทียบด้วยค่าเฉลี่ยของเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์ MAPE และแสดงผลด้วยกราฟการเปรียบเทียบค่าจริงกับค่าที่ได้จากการพยากรณ์

4. ผลของการวิจัย

ผลการทดสอบจากการพยากรณ์แบบจำลองการพยากรณ์อุปสงค์ในห่วงโซ่อุปทานของอุตสาหกรรมผลิตแขนจับยึดหัวอ่านในฮาร์ดดิสก์ไดรฟ์ ในส่วนโครงข่ายประสาทเทียมได้โครงสร้างที่เหมาะสมที่สุดคือ 20-13-13-1 กล่าวคือ มีปัจจัยนำเข้า 18 ข้อมูล มีชั้นซ่อนที่ 1 จำนวน 13 โหนด ชั้นซ่อนที่ 2 จำนวน 13 โหนด และมีปัจจัยนำออก 1 ค่าโดยใช้โมเมนตั้ม 0.1 และอัตตราการเรียนรู้ที่ 0.07 พบว่าค่าประสิทธิภาพของการพยากรณ์โดยโครงข่ายประสาทเทียมนั้นมีค่าความผิดพลาดเฉลี่ย 7.37% ดังกราฟที่ 3(2) ส่วนการพยากรณ์โดย อารีมา p=2,d=1,q=2 มีค่า MAPE = 28.82% กราฟที่ 3(3), ส่วนการพยากรณ์จากอนุกรมเวลาอื่นๆ แสดงในกราฟที่ 3(4) โดย วิธีค่าเฉลี่ยเคลื่อนที่มี MAPE = 28.37%, Single exponential smoothing MAPE = 29.74%, Double exponential smoothing MAPE = 35.54%,และ Winter's method MAPE= 35.09%

เมื่อทำการเปรียบเทียบค่าจากการพยากรณ์ พบว่าการพยากรณ์โดยโครงข่ายประสาทเทียมมีค่า MAPE ต่ำที่สุด และเมื่อนำมาเปรียบเทียบกับการพยากรณ์อุปสงค์จากลูกค้า CDF ดังกราฟที่ 3(1) ซึ่งมีค่า MAPE 14.75% ดังนั้นการพยากรณ์โดยวิธีโครงข่ายประสาทเทียมในการพยากรณ์ค่าอุปสงค์มีความถูกต้องโดยการพยากรณ์ 12 คาบเวลา มากว่า การพยากรณ์วิธีเดิม (CDF) โดยเฉลี่ย 50.06%

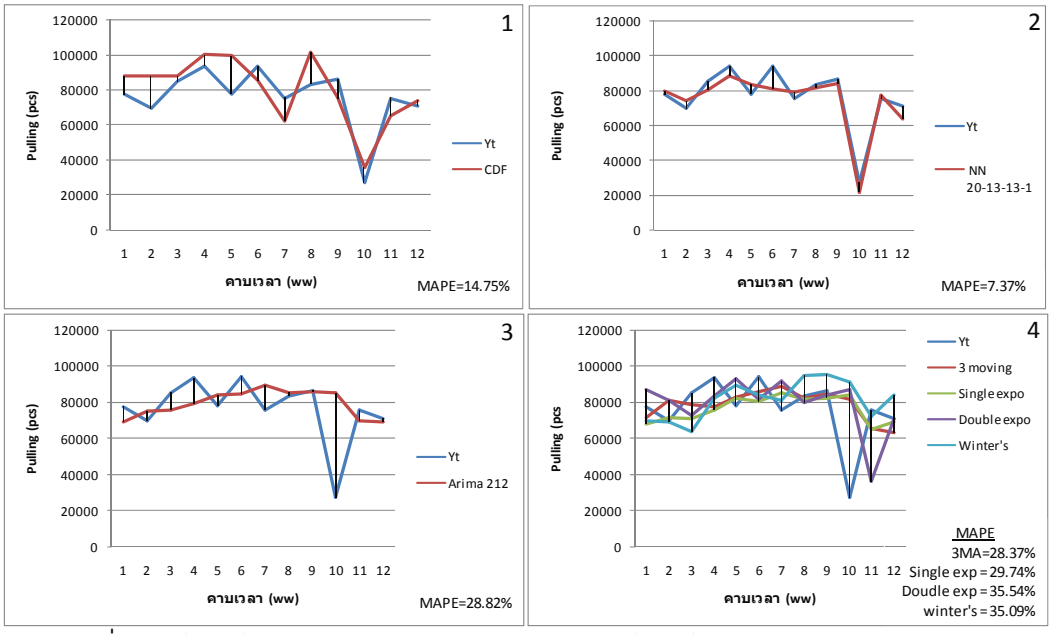

กราฟที่ 3: เปรียบเทียบระหว่าง Pulling และ CDF (1), เปรียบเทียบระหว่าง Pulling และ NN (2), เปรียบเทียบระหว่าง Pulling และ ARIMA (3), เปรียบเทียบระหว่าง Pulling และ Traditional method (4).

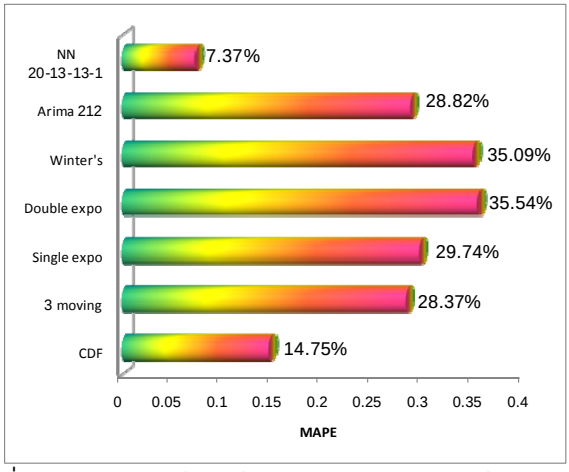

กราฟที่ 4: แสดงการเปรียบเทียบ MAPE ของแต่ละวิธีการพยากรณ์

5. บทวิจารณ์และบทสรุป

จากผลการวิจัยสรุปได้ว่าการพยากรณ์ด้วยเทคนิคโครงข่ายประสาทเทียม เป็นเทคนิคที่เหมาะสมที่สุดมีค่าความผิดพลาดร้อยละ 7.37% โดยใช้ปัจจัยนำเข้าส่วนหนึ่งมาจากข้อมูลของลูกค้า ซึ่งเป็นข้อมูลข่าวสารในห่วงโซ่อุปทาน เมื่อนำตัวเลขที่ได้จากการพยากรณ์โดยโครงข่ายประสาทเทียม ไปใช้ภายในห่วงโซ่อุปทาน ในส่วนการวางแผนการผลิตพบว่าสามารถเพิ่มประสิทธิภาพในการวางแผนการผลิตให้ตรงตามความต้องการของลูกค้าเพิ่มขึ้นโดยเฉลี่ยมากกว่าร้อยละ 10 ในส่วนการจัดซื้อก็สามารถเพิ่มประสิทธิภาพขึ้นโดยเฉลี่ยมากกว่าร้อยละ 10 เช่นเดียวกัน

ดังนั้นจึงสามารถสรุปได้ว่าเทคนิคโครงข่ายประสาทเทียมมีความเหมาะสมในการสร้างแบบจำลองการพยากรณ์อุปสงค์ในห่วงโซ่อุปทานของผลิตภัณฑ์แขนจับยึดหัวอ่านซึ่งเป็นส่วนประกอบหนึ่งในฮาร์ดดิสก์ไดรฟ์ และทำให้ประสิทธิภาพโดยรวมของห่วงโซ่อุปทานดีขึ้น

6. บรรณานุกรม

[1] ทรงศิริ แต้สมบัติ. เทคนิคการพยากรณ์เชิงปริมาณ. กรุงเทพมหานคร: มหาวิทยาลัยเกษตรศาสตร์, 2541.

[2] ทรงศิริ แต้สมบัติ. เทคนิคการพยากรณ์เชิงปริมาณ. กรุงเทพมหานคร: มหาวิทยาลัยเกษตรศาสตร์, 2539.

[3] นพรัตน์ ศิริโชติ, ศิริจันทร์ ทองประเสริฐ. เปรียบเทียบการพยากรณ์ความต้องการพลังงานของภาคอุตสาหกรรมในประเทศไทยด้วยโครงข่ายประสาทเทียม และ ARIMA. การประชุมวิชาการข่ายงานวิศวกรรมอุตสาหการ, 24-26 ตุลาคม 2550.

[4] สาธิต พะเนียงทอง, Supply Chain Strategy : การจัดการโซ่อุปทานเชิงกลยุทธ์, กรุงเทพฯ : ซีเอ็ดยูเคชั่น, 2548

[5] Carbonneau, R., Laframboise, K. and Vahidov, R. 2007. Application of machine learning techniques for supply chain demand forecasting. European Journal of Operational Research. (Article in press).

[6] Chopra, Sunil, and Meindl, Peter, Supply Chain Manegement: Strategy, Planning, and Operation.Upper Saddle River, New Jersey: Prentice-Hall Inc, 1999.

[7] Chiu, M. and Lin, G. 2004. Collaboration supply chain planning using the artificial neural network approach. J. of Manufacturing Technology Management, 15: 787 – 796.

[8] H. Lee, P. Padmanabhan, and S. Whang, The bullwhip effect in supply chains, Sloan Management Review 38 (1997), 93-102.

[9] Khaw,J. F. C.,Lim, B.S., & Lim L.E.N. Optimal design of neural network using the Tagushi method,Neurocomputing, 7,255-245 ,1999.