

การหาจำนวนยูนิตซ่อนที่เหมาะสมของโครงข่ายประสาทเทียมในการพยากรณ์ผลผลิตภาพการผลิตของกระบวนการผลิตฮาร์ดดิสก์ไดรฟ์

Finding the Number of Hidden Units in Neural Network Yield Prediction of Hard Disk Drive Process

กริชชนะ คันธนู (Kritchana Kuntanoo)* ดร.दनัยพงศ์ เชษฐโชติศักดิ์ (Dr.Danaipong Chetchotsak)**

บทคัดย่อ

บทความนี้ได้นำเสนอวิธีการหาจำนวนยูนิตซ่อนที่เหมาะสมของโครงข่ายประสาทเทียมที่ใช้ในการพยากรณ์ผลผลิตภาพการผลิตของกระบวนการผลิตชิ้นส่วนฮาร์ดดิสก์ไดรฟ์ โครงข่ายประสาทเทียมนี้มีข้อมูลป้อนเข้า 8 ตัว และมีผลลัพธ์ 1 ตัว คือ ค่าผลผลิตภาพการผลิตของกระบวนการผลิตฮาร์ดดิสก์ไดรฟ์ และทดลองหาจำนวนยูนิตซ่อนที่แตกต่างกันตั้งแต่ 5, 10, 15 และ 20 ตามลำดับ เพื่อให้ได้ค่าความผิดพลาดในการพยากรณ์ผลผลิตภาพการผลิตของกระบวนการผลิตฮาร์ดดิสก์ไดรฟ์ให้น้อยที่สุด ในการทดลองครั้งนี้ผู้จัดทำได้เพิ่ม Noise ลงในข้อมูลและกำหนดให้ 10% เพื่อหาโครงสร้างและค่าความผิดพลาดที่ต่ำที่สุดเพื่อใช้ในการพยากรณ์ค่าผลผลิตภาพการผลิตของกระบวนการผลิตฮาร์ดดิสก์ไดรฟ์ การเรียนรู้ของโครงข่ายประสาทเทียมใช้วิธี Backpropagation algorithm เพื่อทำการปรับเปลี่ยนค่าน้ำหนักของโครงข่ายประสาทเทียม ผลการทดลองแสดงให้เห็นว่าเมื่อใช้วิธีดังกล่าวร่วมกับจำนวนยูนิตซ่อนเท่ากับ 15 หน่วย และจำนวนรอบในการเรียนรู้ 50,000 รอบ ทำให้ความสามารถในการพยากรณ์ของโครงข่ายประสาทเทียมเหมาะสมที่สุด

ABSTRACT

This paper presents a finding number of hidden units in neural network prediction for hard disk drive process. This architecture of neural networks has 8 inputs and 1 output. These inputs are the yield and number of drive in each work stations and output are the cumulative yield. In experimentation presents the error of 5, 10, 15 and 20 hidden units and finding the number of hidden units that take minimize error of the network. This paper also uses the Noise Injection approach in conjunction and noise constant at 10% and trained by backpropagation algorithm. The experiment shows the number of hidden unit is 15 and learning cycles is 50,000 cycles that such approaches the minimization of error.

คำสำคัญ : โครงข่ายประสาทเทียม การพยากรณ์ผลผลิตภาพการผลิต ยูนิตซ่อน

Key Words : Artificial neural network, Yield prediction, Hidden units

* นักศึกษา หลักสูตรวิศวกรรมศาสตรมหาบัณฑิต สาขาวิศวกรรมอุตสาหการ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยขอนแก่น

** ผู้ช่วยศาสตราจารย์ ภาควิชาวิศวกรรมอุตสาหการ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยขอนแก่น

บทนำ


ปัจจุบันอุตสาหกรรมฮาร์ดดิสก์ไดรฟ์ (Hard Disk Drive) ในประเทศไทยผลิตฮาร์ดดิสก์ไดรฟ์ป้อนตลาดทั้งในประเทศและต่างประเทศ ซึ่งฐานการผลิตฮาร์ดดิสก์ไดรฟ์ในประเทศไทยเป็นฐานการผลิตที่ส่งออกเป็นอันดับหนึ่งของโลก และมีส่วนแบ่งตลาดถึง 42 % อีกทั้งบริษัทใหญ่ทั้ง 4 บริษัท ยังทำให้เกิดมูลค่าเพิ่มเศรษฐกิจของประเทศไทยถึง 180,000 ล้านบาท พร้อมทั้งทำให้เกิดการจ้างงานกว่า 100,000 คน (Hard Disk Drive Institute Thailand, 2549) และทำรายได้เข้าสู่ประเทศเป็นจำนวนมากต่อปี แต่ว่าในกระบวนการผลิตฮาร์ดดิสก์ไดรฟ์ยังมีความไม่แน่นอนสูง ทำให้ต้นทุนการผลิตสูงขึ้น ความสามารถในการตอบสนองลูกค้าลดลง ปัจจัยหนึ่งที่ทำให้ผลิตภาพการผลิต (Yield) ไม่แน่นอนอาจมาจากคุณภาพของวัตถุดิบที่มาจากผู้ผลิตวัตถุดิบที่แตกต่างกัน หรือความไม่เหมาะสมในการใช้งานเครื่องจักรในกระบวนการผลิต จากเหตุผลดังกล่าวจึงได้นำเอาการพยากรณ์ผลิตภาพการผลิตมาประยุกต์ใช้ เพื่อให้สามารถวางแผนการผลิตและทำการตอบสนองลูกค้าได้ดีขึ้น และยัง สามารถลดงานคงค้างในระบบ (Work In Process) และลดต้นทุนในการผลิตให้ต่ำลง

บทความนี้ได้นำเสนอการใช้โครงข่ายประสาทเทียมในการพยากรณ์ผลิตภาพการผลิตและการหาจำนวนยูนิตซ่อน (Hidden Units) ที่เหมาะสม ในที่นี้โครงข่ายประสาทเทียมจะทำหน้าที่เหมือนแบบจำลองกระบวนการผลิตฮาร์ดดิสก์ไดรฟ์ที่มีข้อมูลป้อนเข้าเป็นข้อมูลเกี่ยวกับสถานภาพการผลิตในปัจจุบัน เพื่อนำไปใช้ในการพยากรณ์ค่าผลิตภาพการผลิตของกระบวนการผลิตฮาร์ดดิสก์ไดรฟ์และช่วยให้สามารถวางแผนการผลิตตลอดจนการเตรียมความพร้อมในการผลิตฮาร์ดดิสก์ไดรฟ์ให้เพียงพอต่อความต้องการของลูกค้าและทันตามเวลาที่ต้องจัดส่งสินค้า ถ้าหากโครงข่ายประสาทเทียมสามารถเรียนรู้กระบวนการผลิตฮาร์ดดิสก์ไดรฟ์ได้

อย่างสมบูรณ์ การพยากรณ์ของโครงข่ายประสาทเทียมที่สร้างขึ้นก็จะมีค่าความผิดพลาดน้อยและมีความรวดเร็วในการประมวลผล ทำให้สะดวกต่อการใช้งาน ซึ่งจะทำให้อุตสาหกรรมการผลิตฮาร์ดดิสก์ไดรฟ์นี้สามารถตอบสนองต่อความต้องการของลูกค้าได้อย่างมีประสิทธิภาพ

กระบวนการผลิตของผลิตภัณฑ์ฮาร์ดดิสก์ไดรฟ์ที่ทำการศึกษา มีสถานงาน 4 สถานงาน ดังแสดงในรูปที่ 1 ในรูปนี้ประกอบด้วย 1) สถานี ULD คือ สถานงานที่ทำการประกอบชิ้นส่วนฮาร์ดดิสก์ไดรฟ์ 2) สถานี Pretest 3) สถานี Functional Test และ 4) สถานี Final Test 3 สถานงานหลังเป็นสถานีที่ทำการทดสอบคุณภาพและเตรียมความพร้อมในการทำงานของฮาร์ดดิสก์ไดรฟ์ ในแต่ละขั้นตอนการผลิตนั้น หากชิ้นส่วนใดไม่ผ่านการทดสอบที่สถานีใดสถานีหนึ่ง ชิ้นส่วนนั้นจะถูกนำมาเข้ากระบวนการผลิตในสถานงานดังกล่าวอีกครั้งและถ้าหากทดสอบอีกครั้งแล้วยังไม่ผ่าน ฮาร์ดดิสก์ชิ้นนั้นจะถูกส่งไปแยกชิ้นส่วนเพื่อเข้ากระบวนการผลิตใหม่ที่ สถานี ULD อีกครั้ง ส่วนในสถานงานของ ULD เองหากมีฮาร์ดดิสก์ไดรฟ์ชิ้นไหนที่ไม่ผ่านการตรวจสอบภายในสถานีชิ้นส่วนนั้นก็จะถูกนำมาตรวจสอบหาข้อผิดพลาดในเบื้องต้นก่อนนำเข้ากระบวนการผลิตอีกครั้ง แต่หากไม่สามารถแก้ไขได้ในเบื้องต้นก็จะถูกนำมาแยกชิ้นส่วนรวมกับฮาร์ดดิสก์ไดรฟ์ที่ไม่ผ่านการทดสอบใน 3 สถานงานหลัง และส่งเข้ากระบวนการผลิตใหม่ตั้งแต่ต้นอีกครั้งหนึ่ง

จากความซับซ้อนดังกล่าวจึงเป็นการยากที่จะพยากรณ์ค่าผลิตภาพการผลิตให้มีความแม่นยำ บทความนี้จึงนำเสนอการใช้โครงข่ายประสาทเทียมในการพยากรณ์ผลิตภาพการผลิต โดยผลิตภาพการผลิตนิยามจากอัตราส่วนระหว่างจำนวนฮาร์ดดิสก์ไดรฟ์ที่ผลิตได้และจำนวนฮาร์ดดิสก์ไดรฟ์ที่ผ่านการตรวจสอบคุณภาพแล้ว



รูปที่ 1 กระบวนการผลิตฮาร์ดดิสก์ไดรฟ์

โครงข่ายประสาทเทียม (Artificial Neural Networks) พัฒนารับขึ้นมามีตั้งแต่ พ.ศ. 2483 และได้รับการพัฒนาอย่างต่อเนื่องจนถึงปัจจุบัน โครงข่ายประสาทเทียมเป็นวิทยาการที่พยายามเลียนแบบการทำงานของระบบประสาทหรือสมองของมนุษย์ โดยอาศัยโครงสร้างที่ประกอบไปด้วยหน่วยประมวลผล (Processing Elements : PE) ง่ายๆ หรือ Neurons จำนวนมาก และการเชื่อมต่อระหว่าง Neurons เหล่านั้น ทำให้การทำงานของโครงข่ายประสาทเทียมเป็นไปในรูปแบบของการประมวลผลพร้อมกันจำนวนมาก จุดเด่นของโครงข่ายประสาทเทียม คือ ความสามารถในการเรียนรู้ (Learning Ability) จากการสอนด้วยตัวอย่าง (Training Samples) และสามารถทำงานได้หลังจากการเรียนรู้แล้ว โดยตัวอย่างนั้นอาจจะเป็นปัญหาที่มีความซับซ้อนยุ่งยากมาก หรืออาจเป็นปัญหาที่ไม่สามารถหรือไม่เหมาะสมที่จะใช้การคำนวณธรรมดาตามประยุกต์ใช้ได้ ส่วนในตัวของโครงข่ายประสาทเทียมเองก็ประกอบไปด้วยสมการและการคำนวณทางคณิตศาสตร์ง่าย ๆ ไม่ซับซ้อน เพียงแต่อาศัยการ

ทำงานในรูปแบบของการประมวลผลพร้อมกันจำนวนมากดังที่ได้กล่าวมาแล้ว จึงทำให้โครงข่ายประสาทเทียมสามารถทำงานได้ด้วยความรวดเร็วสำหรับข้อมูลเพิ่มเติมผู้อ่านสามารถอ่านเพิ่มเติมได้ใน Fausett (1994) Haykin (1994) และ Chetchotsak (2004)

จากการทบทวนวรรณกรรมที่เกี่ยวข้องพบว่ามีการใช้โครงข่ายประสาทเทียมในการพยากรณ์ค่าผลผลิตการผลิตที่ใช้กับกระบวนการผลิตผลิตภัณฑ์อิเล็กทรอนิกส์หลายบทความด้วยกันตัวอย่างเช่น : การพยากรณ์ค่าผลผลิตการผลิต Surface Mount Technology (SMT) (Vellore et al., 2002) การพยากรณ์ค่าผลผลิตการผลิตสำหรับสายการผลิตแบบ Reflow (Lu et al., 1997) การพยากรณ์ค่าผลผลิตการผลิต Printed Circuit Boards (PCB) (Vaithianathasamy et al., 2001) นอกจากนี้ยังมีงานวิจัยที่เกี่ยวข้องกับการใช้โครงข่ายประสาทเทียมเพื่อทำการพยากรณ์ผลผลิตการผลิตที่เป็นที่ยอมรับและได้รับการตีพิมพ์อย่างเป็นทางการในช่วงเวลาที่ผ่านมานี้ ซึ่งได้แก่ Kaul (2004) และ Grzesiak (2006) เป็นต้น

อุปกรณ์และวิธีการวิจัย

1. โครงสร้างของโครงข่ายประสาทเทียมที่ใช้ในการพยากรณ์

ในบทความนี้ได้้นำโครงข่ายประสาทเทียมมาใช้ในการสร้างแบบจำลองสายการผลิตฮาร์ดดิสก์ไดรฟ์ เพื่อใช้ในการพยากรณ์ผลผลิตในการผลิตของสายการผลิตดังกล่าว โดยโครงข่ายประสาทเทียมที่ใช้ในการสร้างแบบจำลองนี้จะทำการปรับค่าน้ำหนัก (Weight) โดยวิธี Backpropagation Algorithm (Rumelhart et al., 1996) ในที่นี้โครงข่ายประสาทเทียมที่ใช้ในการพยากรณ์ผลผลิตการผลิตชิ้นส่วนฮาร์ดดิสก์ไดรฟ์มีข้อมูลป้อนเข้า ทั้งหมด 8 ตัว และมีผลลัพธ์ที่ต้องการ 1 ตัว ดังแสดงในตารางที่ 1

ตารางที่ 1 โครงสร้างของโครงข่ายประสาทเทียม
ที่ใช้ในการพยากรณ์

	ข้อมูลป้อนเข้า	ผลลัพธ์ที่ ต้องการ
โครงข่าย ประสาท เทียม	$y_1(t), y_2(t),$ $y_3(t), y_4(t),$ $I_1(t), O_2(t),$ $O_3(t), O_4(t)$	$y_8(t+1)$

และจากตารางที่ 1 สัญลักษณ์ที่ใช้เป็น
ข้อมูลป้อนเข้า และผลลัพธ์ มีความหมายดังต่อไปนี้

$y_i(t)$ คือ ผลิภาพการผลิตของสถานงานที่,
 $i, i = 1, \dots, 4$ ที่เวลา t

$y_8(t)$ คือ ผลิภาพการผลิตกระบวนการผลิต
ฮาร์ดดิสก์ไดรฟ์ ที่เวลา t

$I_1(t)$ คือ จำนวนที่สั่งผลิตฮาร์ดดิสก์ไดรฟ์ใน
สถานงานที่ 1

$O_i(t)$ คือ จำนวนฮาร์ดดิสก์ไดรฟ์ที่ผลิตได้ใน
สถานงานที่ i เมื่อ $i = 2, 3, 4$ ที่เวลา t

t คือ แสดง ณ จุดของเวลา t ในปัจจุบัน
มีหน่วยเป็นวัน

2. การทดลอง

จากข้อมูลการผลิตฮาร์ดดิสก์ไดรฟ์¹ ในช่วงเดือนมิถุนายน-พฤศจิกายน 2549 ได้ถูกรวบรวมและใช้ในการสร้างรูปแบบการพยากรณ์ผลิภาพการผลิตโดยใช้โครงข่ายประสาทเทียมเนื่องจากผลิตภัณฑ์ที่ทำการศึกษามีช่วงอายุของผลิตภัณฑ์ที่สั้น จึงทำให้ไม่สามารถเก็บข้อมูลเพื่อนำมาสร้างโครงข่ายประสาทเทียมได้มากเท่าที่ควร ในบทความนี้ได้ใช้วิธี Data Splitting ในการสร้างรูปแบบการพยากรณ์จากโครงข่ายประสาทเทียม ในที่นี้ข้อมูลที่ใช้ในการสร้าง โครงข่าย

ประสาทเทียมแต่ละตัวนั้นแสดงในตารางที่ 1 จะถูกแยกเป็น 2 ส่วนคือ 1) ชุดข้อมูลที่ใช้ในการเรียนรู้ของโครงข่ายประสาทเทียม (Training Set) คือ ส่วนที่ใช้ในการสอนให้โครงข่ายประสาทเทียมเรียนรู้และ 2) ชุดข้อมูลที่ใช้ในการทดสอบโครงข่ายประสาทเทียม (Test Set) คือ ส่วนที่ใช้ในการทดสอบข้อมูล ชุดข้อมูลที่ใช้ในการเรียนรู้ของโครงข่ายประสาทเทียมเป็นข้อมูลที่ใช้ในการกำหนดค่าน้ำหนัก ความสัมพันธ์ระหว่างข้อมูลป้อนเข้า และ ผลลัพธ์ของโครงข่ายประสาทเทียม ในขณะที่ชุดข้อมูลที่ใช้ในการทดสอบโครงข่ายประสาทเทียมเป็นข้อมูลที่ใช้ในการทดสอบความแม่นยำในการพยากรณ์ผลิภาพการผลิต ในการทดลองจะทำการแบ่งข้อมูลในชุดข้อมูลที่ใช้ในการเรียนรู้ของโครงข่ายประสาทเทียม และชุดข้อมูลที่ใช้ในการทดสอบโครงข่ายประสาทเทียมออกเป็น 70% และ 30% ตามลำดับ ทั้งนี้ข้อมูลที่ใช้ในการสร้างแบบจำลองนี้ได้นำเอาวิธี Noise Injection (Raviv and Intrator, 1996) มาใช้ในการฝึกสอน โครงข่ายประสาทเทียม กล่าวคือวิธีนี้จะทำการเพิ่ม Noise เข้าไปในชุดข้อมูลที่ใช้ในการเรียนรู้ของโครงข่ายประสาทเทียมเพื่อให้โครงข่ายประสาทเทียมเรียนรู้ความสัมพันธ์ระหว่างข้อมูลป้อนเข้า และ ผลลัพธ์ อย่างเหมาะสมและหลีกเลี่ยงการจดจำข้อมูล (Overfitting²) โดย Noise (η) ที่ใช้มีการแจกแจงแบบปกติและ $\eta \sim N(0, \sigma)$ ตารางที่ 2 แสดงการออกแบบการทดลองเพื่อหาจำนวนรอบในการเรียนรู้ และจำนวนยูนิตซ่อนที่เหมาะสม โดยในบทความนี้ใช้ระดับของ Noise คงที่ $\sigma=10\%$ ของค่าเฉลี่ยของ $y_i(t)$

โดยโครงข่ายประสาทเทียมที่สร้างขึ้นมีโครงสร้างของโครงข่ายประสาทเทียม (Networks Architectures) ดังนี้: Learning Rule: Ext DBD, Activation Function = TanH และทำการแปรผัน

¹ ในบทความนี้จะไม่เปิดเผยชื่อหรือประเภทของผลิตภัณฑ์

² Overfitting คือเหตุการณ์ที่โครงข่ายประสาทเทียม เรียนรู้ข้อมูลได้ดีเกินไปในระหว่างกระบวนการ Training แต่ทำข้อผิดพลาดอย่างมากในระหว่างกระบวนการ Test

จำนวนรอบในการเรียนรู้ ตั้งแต่ 50,000 จนถึง 500,000 และหาจำนวนรอบที่เหมาะสม โดยในโครงข่ายประสาทเทียมนี้จะทำการทดลองเพื่อหาจำนวนยูนิตซ่อนที่เหมาะสม ซึ่งจะทำการทดลองใช้จำนวนยูนิตซ่อนตั้งแต่ 5, 10, 15 และ 20 ยูนิตตามลำดับ หากจำนวนยูนิตซ่อนที่ใช้ให้ค่าความผิดพลาด (Errors) ที่ยอมรับได้จึงทำการเลือกจำนวนยูนิตซ่อน และโครงสร้างของโครงข่ายประสาทเทียมชุดดังกล่าว ซึ่งผลการทดลองดังแสดงในตารางที่ 3-5

ตารางที่ 2 การออกแบบการทดลองเพื่อหาค่าจำนวนรอบในการเรียนรู้และจำนวนยูนิตซ่อน

ตัวแปรการทดลอง	ระดับ
จำนวนรอบในการเรียนรู้	1) 50,000 2) 250,000 3) 500,000
จำนวนยูนิตซ่อน	1) 5 2) 10 3) 15 4) 20

ตารางที่ 3 ผลการทดลองที่จำนวนรอบในการเรียนรู้ 50,000 รอบ

จำนวนยูนิตซ่อน	MAPE (%)	
	เรียนรู้	ทดสอบ
5	2.30	9.70
10	1.97	11.63
15	2.02	9.40
20	1.27	9.56

ตารางที่ 4 ผลการทดลองที่จำนวนรอบในการเรียนรู้ 250,000 รอบ

จำนวนยูนิตซ่อน	MAPE (%)	
	เรียนรู้	ทดสอบ
5	1.36	13.16
10	0.76	13.27
15	0.97	10.71
20	0.74	9.70

ตารางที่ 5 ผลการทดลองที่จำนวนรอบในการเรียนรู้ 500,000 รอบ

จำนวนยูนิตซ่อน	MAPE (%)	
	เรียนรู้	ทดสอบ
5	0.97	13.74
10	0.50	13.87
15	0.68	11.77
20	0.45	10.81

จากผลการทดลองดังได้แสดงในตารางที่ 3 -5 ค่าความผิดพลาดที่เกิดขึ้นคำนวณในรูปของ Mean Absolute Percentage (MAPE) ซึ่งคำนวณดังสมการที่ (1)


$$MAPE = \left(1 / n \sum_{i=1}^n |(P_i - D_i) / D_i| \right) \times 100 \quad (1)$$

โดยที่ P_i = ค่าผลลัพธ์ที่ได้จากการพยากรณ์ของโครงข่ายประสาทเทียม และ D_i = ค่าเป้าหมายจริงที่โครงข่ายประสาทเทียมต้องการพยากรณ์


ผลการทดลองและอภิปราย

ผลการทดลองแสดงใน รูปที่ 2 และ 3 ซึ่งรูปที่ 2 แสดงผลการทดลองจากชุดข้อมูลที่ใช้ในการเรียนรู้ และรูปที่ 3 แสดงผลการทดลองจาก


ชุดข้อมูลที่ใช้ในการทดสอบ จากผลดังกล่าวสังเกตได้ว่า เมื่อจำนวนรอบในการเรียนรู้มีค่ามากขึ้น ค่าความผิดพลาดของโครงข่ายประสาทเทียมที่จำนวนยูนิตซ่อนเดียวกันมีแนวโน้มลดลงในข้อมูลที่ใช้ในการเรียนรู้ของโครงข่ายประสาทเทียม แต่ในข้อมูลที่ใช้ในการทดสอบของโครงข่ายประสาทเทียมเมื่อจำนวนรอบในการเรียนรู้มีค่ามากขึ้น ค่าความผิดพลาดของ โครงข่ายประสาทเทียมที่จำนวนยูนิตซ่อนเดียวกันมีแนวโน้มเพิ่มขึ้น ซึ่งชี้ให้เห็นว่าโครงข่ายประสาทเทียมเรียนรู้ข้อมูลจากชุดข้อมูลที่ใช้ในการเรียนรู้ได้ดีเกินไปจนเกิดการจดจำข้อมูล จากรูปที่ 4 แสดงผลการทดลองหาจำนวนยูนิตซ่อนที่เหมาะสม เมื่อข้อมูลมีการเพิ่ม Noise $\sigma=10\%$ ซึ่งยูนิตซ่อนที่เหมาะสม คือ 15 ยูนิต และใช้จำนวนรอบในการเรียนรู้เท่ากับ 50,000 รอบ แต่เมื่อเปรียบเทียบกับชุดข้อมูลที่ไม่มี Noise พบว่าไม่มีความแตกต่างกัน อีกทั้งการเพิ่ม Noise เข้าไปในข้อมูลยังทำให้ค่าความผิดพลาดที่ได้จากชุดข้อมูลทดสอบเพิ่มมากกว่าชุดข้อมูลเดิมที่ไม่มีการเพิ่ม Noise เล็กน้อย จึงแสดงให้เห็นว่าในการพยากรณ์ค่าผลผลิตทางการผลิตของกระบวนการผลิตฮาร์ดดิสก์ไดรฟ์นี้ Noise ที่เพิ่มเข้าไปในชุดข้อมูลไม่สามารถลดผลกระทบจากการจดจำข้อมูลของโครงข่ายประสาทเทียมได้ แต่ควรใช้วิธีอื่นๆ อย่างเช่น Cross Validation มาใช้ร่วมกับชุดข้อมูลนี้ เพื่อลดผลกระทบจากการเกิดการจดจำข้อมูลและลดค่าความผิดพลาดที่เกิดจากการพยากรณ์ค่าผลผลิตทางการผลิต



รูปที่ 2 ผลการทดลองของชุดข้อมูลที่ใช้ในการเรียนรู้



รูปที่ 3 ผลการทดลองของชุดข้อมูลที่ใช้ในการทดสอบ



รูปที่ 4 ผลการพยากรณ์ผลผลิตทางการผลิต (จากชุดข้อมูลที่ใช้ในการทดสอบ)

บทสรุป

บทความนี้ได้นำเสนอการหาจำนวน ยูนิตซ่อนที่เหมาะสมของการพยากรณ์ผลผลิตทางการผลิตของกระบวนการผลิตฮาร์ดดิสก์ไดรฟ์โดยใช้โครงข่ายประสาทเทียม ซึ่งปรับค่าน้ำหนักโดย Backpropagation Algorithm ในที่นี้ โครงข่ายประสาทเทียมที่สร้างขึ้นมีข้อมูลป้อนเข้า ทั้งหมด 8 ตัว และผลลัพธ์ 1 ตัว โดยที่ข้อมูลป้อนเข้า ทั้ง 8 ตัว คือ จำนวนและประสิทธิภาพการผลิตของทั้ง 4 สถานีการผลิต และโครงข่ายประสาทเทียมดังกล่าวจะทำหน้าที่พยากรณ์ผลผลิตทางการผลิตเพื่อนำไปใช้ในการวางแผนการผลิตต่อไป นอกจากนี้บทความนี้ยังได้นำเสนอวิธีในการสร้างโครงข่ายประสาทเทียมโดยใช้วิธี Noise Injection

กิตติกรรมประกาศ

ขอขอบคุณทุนสนับสนุนจากศูนย์เทคโนโลยีอิเล็กทรอนิกส์และคอมพิวเตอร์แห่งชาติ (NECTEC) ตามโครงการพัฒนาทรัพยากรบุคคล ในอุตสาหกรรมฮาร์ดดิสก์ไดรฟ์ ประจำปีการศึกษา 2549

เอกสารอ้างอิง

- Chetchotsak, D. 2004. Intelligent computing for industrial and manufacturing applications. Khon Kaen : Khon Kaen University.
- Fausett, L. 1994. Fundamentals of Neural Network. Englewood Cliffs, NJ: Prentice Hall.
- Grzesiak, W., Blaszczyk, P. and Lacroix, R. 2006. “Methods of predicting milk yield in dairy cows–Predictive capabilities of Wood’s lactation curve and artificial Neural Network (ANNs),” Computers and Electronics in Agriculture, vol. 54(2), pp. 69–83.
- Hard Disk Drive Institute Thailand (HDDI). 2549. ความเป็นมาของสถาบัน HDDI. (สืบค้นเมื่อวันที่ 28 มิถุนายน 2550) http://www3.easywebtime.com/hdd_eng/essential.html.
- Haykin, S. 1994. Neural Network: A comprehensive foundation. New York, NY: McMillan College Publishing,
- Kaul, M., Hill, RL., and Walthall, C. 2004. “Artificial Neural Network for corn and soybean yield prediction,” Agricultural Systems, vol. 85(1), pp. 1–18.
- Lu et al., 1997. Yield modeling for mass reflow process of 0201 components using Neural Networks. Intelligent Engineering system through Artificial Neural Networks, (11), 931–936.
- Raviv, Y. and Intrator, N. 1996. “Bootstrapping with noise: An alternative regularization technique”, Connection Science, 8(3–4), pp. 355–372.
- Rumelhart, D. E., Hilton, G. E., and Williams, R. J. 1996. Learning internal representations by error propagation. In D.E. Rumelhart and J.E. Mc Clelland (Eds.), Parallel Distributed Processing : Exploration in the Microstructure of Cognition. (Volume I. Foundations). Cambridge, M.A: MIT Press.
- Sharma, AK., Sharma, RK., and Kasana, HS. 2006. “Prediction of first lactation 305–day milk yield in Karan Fries dairy cattle using ANN modeling,” To be appeared in Applied Soft Computing.
- Vaithianathasamy, S., Lam, SSY., and Srihari, K. 2001. Process Yield Prediction for an EMS Provider Using Neural Network Models Proceedings – 10th Industrial Engineering Research Conference, Dallas, Texas.
- Vellore, TS., Manjeshwar, PM., and Lam, SSY. 2002, “A pragmatic neural network approach for SMT yield prediction.” Intelligent Engineering System through Artificial Neural Network, vol. 12, pp. 651–656.