

# การพยากรณ์ผลผลิตภาพการผลิตของกระบวนการ ผลิตฮาร์ดดิสก์ไดร์ฟโดยใช้โครงข่ายประสาทเทียม

ดุษฎีพงษ์ เชษฐโชติศักดิ์<sup>1)</sup> และกริชชนะ คันธนู<sup>2)</sup>

- <sup>1)</sup> ผู้ช่วยศาสตราจารย์ ภาควิชาวิศวกรรมอุตสาหการ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยขอนแก่น 40002  
<sup>2)</sup> นักศึกษาปริญญาโท ภาควิชาวิศวกรรมอุตสาหการ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยขอนแก่น 40002

Email: cdanai@kku.ac.th

## บทคัดย่อ

บทความนี้นำเสนอการใช้ Neural Networks ในการพยากรณ์ผลผลิตภาพการผลิตของกระบวนการผลิตชิ้นส่วนฮาร์ดดิสก์ไดร์ฟ โดย Neural Networks ที่ใช้คือ Multilayer Perceptrons ซึ่งทำการปรับค่าน้ำหนักโดยใช้ Backpropagation Algorithm Neural Networks จำนวน 8 ตัวได้ถูกพัฒนาขึ้น โดยใช้หลักการของ Mixture of Local Experts ซึ่ง Networks ทั้ง 7 ตัวจะทำหน้าที่เป็น Local Experts ของแต่ละสถานะงานย่อยในระบบการผลิตเพื่อที่จะทำการพยากรณ์ประสิทธิภาพหรือจำนวนชิ้นส่วนที่ผลิตได้ในแต่ละสถานะงานนั้นๆ และ Network ตัวที่ 8 จะเป็น Gating Network ซึ่งจะรวบรวมข้อมูลจาก Network ย่อยมาเพื่อทำการพยากรณ์ผลผลิตภาพการผลิตทั้งระบบต่อไป ผลการทดลองแสดงให้เห็นว่า Neural Networks ที่สร้างขึ้นมีความสามารถในการพยากรณ์ในระดับที่ยอมรับได้ บทความนี้ยังแสดงการนำเอาวิธี Noise Injection มาใช้ร่วมกับ วิธี Cross-validation Stop Training ในการสร้าง Neural Networks ซึ่งผลการทดลองชี้ให้เห็นว่าวิธีดังกล่าวช่วยเพิ่มความสามารถในการพยากรณ์ให้แก่ Neural Networks ได้

**คำสำคัญ:** โครงข่ายประสาทเทียม, การพยากรณ์ผลผลิตภาพการผลิต, Mixture of Local Experts

# Yield Prediction using Artificial Neural Networks

Danaipong Chetchotsak<sup>1)</sup> and Kritchana Kuntanoo<sup>2)</sup>

<sup>1)</sup> Assistant Professor, Department of Industrial Engineering, Faculty of Engineering, Khon Kaen University 40002

<sup>2)</sup> Master Student, Department of Industrial Engineering, Faculty of Engineering, Khon Kaen University 40002

Email: cdanai@kku.ac.th

## ABSTRACT

This paper presents a yield prediction method for a hard disk drive manufacturing process using artificial neural networks. The networks presented are multilayer perceptrons trained by the backpropagation algorithm. Eight networks are used to predict the yield based on the concept of Mixture of Local Expert. Seven of them act as a local expert and predict yields of each work station in the whole process. The eighth network serves as a gating network which combines and executes information from each local network and then makes a prediction. The experimental results suggest that the networks built have a fair forecast capability. This paper also uses the Noise Injection approach in conjunction with the cross-validation stop training method to build a neural network. The experiment shows that such approaches help to improve yield prediction capability.

**Keywords :** Artificial Neural Networks, Yield Prediction, Mixture of Local Expert

## บทนำ

ในปัจจุบันผลผลิตภาพการผลิต (Yield) ของกระบวนการผลิตฮาร์ดดิสก์ไดร์ฟมีความไม่แน่นอนสูง ซึ่งส่งผลให้กระบวนการมีต้นทุนที่สูงขึ้น ผลผลิตไม่เป็นไปตามเป้าหมาย และอุตสาหกรรมขาดความสามารถในการตอบสนองความต้องการของลูกค้า ความไม่แน่นอนดังกล่าว อาจสืบเนื่องมาจากคุณภาพของวัตถุดิบที่ใช้ ซึ่งมาจากซัพพลายเออร์ผู้ส่งวัตถุดิบที่แตกต่างกัน และอาจเกิดจากเครื่องจักรในกระบวนการผลิตที่มีประสิทธิภาพและประสิทธิผลต่ำ ดังนั้นการพยากรณ์ผลผลิตภาพการผลิตจึงมีความจำเป็นต่อการผลิตฮาร์ดดิสก์ไดร์ฟ การพยากรณ์จะช่วยให้การวางแผนการผลิตให้ได้ผลผลิตเป็นไปตามเป้าหมาย ลดงานที่อยู่ในระหว่างกระบวนการผลิต ลดของเสียพร้อมกับลดงานที่ต้องนำกลับมาทำใหม่ ลดต้นทุนในการผลิต และเพิ่มความสามารถในการนำส่งสินค้าได้ทันเวลา

บทความนี้จะนำเสนอรูปแบบการพยากรณ์ผลผลิตภาพการผลิตของกระบวนการผลิตฮาร์ดดิสก์ไดร์ฟโดยใช้โครงข่ายประสาทเทียม (Neural Networks) ข้อดีของการใช้ Neural Networks คือสามารถจัดการกับข้อมูลที่มีความสัมพันธ์แบบไม่เป็นเส้นตรงได้ซึ่งเป็นคุณลักษณะโดยทั่วไปของรูปแบบการพยากรณ์ ในที่นี้ Neural Networks จะทำหน้าที่เสมือนเป็น Simulator ที่เลียนแบบกระบวนการผลิตฮาร์ดดิสก์ไดร์ฟ ซึ่งหาก Neural Networks สามารถเลียนแบบกระบวนการผลิตฮาร์ดดิสก์ไดร์ฟได้อย่างสมบูรณ์ การนำเอา Neural Networks ไปใช้ในการพยากรณ์ก็จะมีความแม่นยำ และเนื่องจากความสามารถในการประมวลผลข้อมูลและคำนวณได้อย่างรวดเร็ว Neural Networks จึงเหมาะที่จะใช้ในการพยากรณ์ผลผลิตภาพการผลิตมากกว่าการใช้วิธีจำลองเหตุการณ์จากกระบวนการ (Process Simulation)

อย่างไรก็ตาม เนื่องจากคุณลักษณะของอุตสาหกรรมฮาร์ดดิสก์ไดร์ฟที่มี Product Life Cycle ที่สั้น จึงทำให้ข้อมูลที่ใช้ในการสร้าง Neural Networks ไม่เพียงพอและอาจส่งผลให้เกิด Overfitting<sup>1</sup> บทความนี้จะได้นำเอาวิธี Noise Injection (Raviv and Intrator, 1996) มาใช้ร่วมกับวิธี Cross-validation Stop Training (Hine, 1997) เพื่อใช้ในการสร้าง Neural Networks เพื่อหลีกเลี่ยงการเกิด Overfitting

ดังนั้นวัตถุประสงค์ของงานวิจัยมีดังต่อไปนี้ 1) เพื่อทำการศึกษาดูว่ามีความเป็นไปได้หรือไม่ที่จะนำเอา Neural Networks ไปใช้ในการพยากรณ์ผลผลิตภาพการผลิตของกระบวนการผลิตฮาร์ดดิสก์ไดร์ฟ 2) เพื่อหารูปแบบ Network Architecture ที่เหมาะสมสำหรับการพยากรณ์ผลผลิตภาพการผลิต และ 3) เพื่อศึกษาดูว่าวิธี Noise Injection และวิธี Cross-validation Stop Training สามารถเพิ่มความสามารถในการพยากรณ์ผลผลิตภาพการผลิตได้หรือไม่

สำหรับการพยากรณ์ผลผลิตภาพการผลิตโดยใช้ Neural Networks นั้นยังคงเป็นเรื่องที่ใหม่สำหรับอุตสาหกรรมฮาร์ดดิสก์ไดร์ฟ อย่างไรก็ตามจากการรวบรวมจากบทความที่เกี่ยวข้องนั้น ได้มีการ

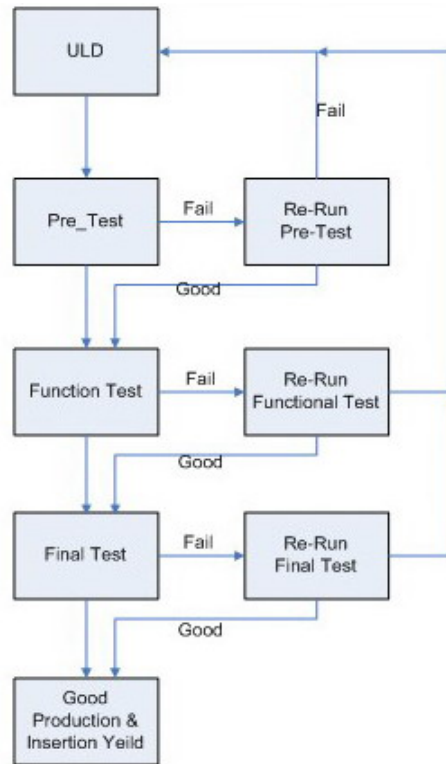
<sup>1</sup> Overfitting คือเหตุการณ์ที่ Neural Networks เรียนรู้ข้อมูลได้ดีเกินไปในระหว่างกระบวนการ Training แต่ทำข้อผิดพลาดอย่างมากในระหว่างกระบวนการ Test

นำเอา Neural Networks ไปใช้ในการพยากรณ์ผลผลิตภาพการผลิต ซึ่งสามารถยกตัวอย่างได้ดังนี้: การพยากรณ์ ผลผลิตภาพการผลิตของปริมาณน้ำมันในหลุมขุดเจาะ (Olajide *et al.*, 2007) การพยากรณ์ผลผลิตภาพการผลิตน้ำมันที่ผลิตได้ (Sharma *et al.*, 2006 and Grzesiak *et al.*, 2006) การพยากรณ์ความสามารถของต้นส้มในการออกผล (Ye *et al.*, 2006) การพยากรณ์ผลผลิตผลจากข้าวโพดและถั่วเหลือง (Kaul *et al.*, 2005) และการพยากรณ์ผลผลิตภาพการผลิตจากกระบวนการ Surface Mount Technology (SMT) ในการผลิตแผ่น PCB (Vellore *et al.*, 2002) บทความที่กล่าวมาทั้งหมดใช้ Neural Networks แบบ Multilayer Perceptrons ซึ่งทำการปรับค่าน้ำหนักโดย Backpropagation Algorithm แต่ในบทความของ Vellore *et al.* (2002) ได้มีการใช้ Radial Basis Neural Networks ควบคู่ไปด้วย อย่างไรก็ตาม ผลการทดลองได้ชี้ให้เห็นว่า Backpropagation Neural Networks มีประสิทธิภาพการทำงานที่ดีกว่า

### ภาพรวมของกระบวนการผลิตฮาร์ดดิสก์ไดรฟ์

แผนภาพการผลิตฮาร์ดดิสก์ไดรฟ์แสดงในรูปที่ 1 ในรูปนี้ สถานี ULD คือสถานีงานที่ทำการประกอบชิ้นส่วนฮาร์ดดิสก์ไดรฟ์ ส่วนสถานี Pretest, Functional Test, และ Final Test เป็นสถานีที่ทำการทดสอบคุณภาพของฮาร์ดดิสก์ไดรฟ์ ในแต่ละขั้นตอนการผลิตนั้น หากชิ้นส่วนใดไม่ผ่านการทดสอบที่สถานีหนึ่งๆ ชิ้นส่วนนั้นก็จะถูกทำการ Retest และหากยังทดสอบไม่ผ่านอีกครั้ง ชิ้นส่วนนั้นก็จะถูกส่งไปผ่านกระบวนการ Rework โดยกลับไปสถานี ULD อีกครั้ง

แผนภาพกระบวนการผลิตดังกล่าว ชี้ให้เห็นว่าขั้นตอนในการผลิตฮาร์ดดิสก์ไดรฟ์ค่อนข้างซับซ้อนและเป็นการยากที่จะพยากรณ์ค่าผลผลิตภาพการผลิต ซึ่งนิยามจากอัตราส่วนระหว่างจำนวนฮาร์ดดิสก์ไดรฟ์ที่สั่งผลิตและป้อนเข้าไปในกระบวนการผลิตต่อจำนวนฮาร์ดดิสก์ไดรฟ์ที่ผ่านกระบวนการประกอบและผ่านการตรวจสอบคุณภาพที่สถานีงานต่างๆ ณ เวลาหนึ่งๆ



รูปที่ 1 กระบวนการผลิตฮาร์ดดิสก์ไดร์ฟ

### รูปแบบการพยากรณ์ โดยใช้โครงข่ายประสาทเทียม

โครงข่ายประสาทเทียม (Neural Networks) คือ ระบบประมวลผล และคำนวณข้อมูล ซึ่งทำงานเลียนแบบระบบประสาท เมื่อเปรียบเทียบกับสมองมนุษย์ Neural Networks สามารถที่จะประมวลผล เรียนรู้ และจดจำข้อมูลได้ เนื่องจากมีความเร็วในการประมวลผลและประสิทธิภาพในการเรียนรู้ข้อมูล Neural Networks จึงถูกฝึก (Train) ในการทำงานที่ยากได้ โครงข่ายประสาทเทียมมีการใช้งานอย่างกว้างขวาง เช่นใน Signal Processing ระบบควบคุม งานทางการแพทย์ การพยากรณ์ งานทางอุตสาหกรรม และธุรกิจ เป็นต้น (สำหรับรายละเอียดเพิ่มเติมเกี่ยวกับ Neural Networks ผู้อ่านสามารถอ่านเพิ่มเติมได้ใน Haykins (1994))



### การทดลอง

ข้อมูลการผลิตชิ้นส่วนฮาร์ดดิสก์ไดรฟ์<sup>3</sup> ในช่วงเดือนมิถุนายน-พฤศจิกายน 2549 ได้ถูกรวบรวม และใช้ในการสร้าง Neural Networks อย่างไรก็ตามข้อมูลที่มีอยู่นั้นมีจำนวนจำกัด ทั้งนี้เนื่องจากคุณลักษณะเฉพาะของอุตสาหกรรมฮาร์ดดิสก์ไดรฟ์ กล่าวคือ อุตสาหกรรมนี้มี Product Life Cycle ที่สั้น ทำให้ช่วงระยะเวลาในการผลิตและการขายมีระยะเวลาที่สั้นจึงทำให้ข้อมูลที่ใช้ในการสร้าง Neural Networks มีจำนวนจำกัด

ในบทความนี้ Neural Networks ได้สร้างขึ้นโดยวิธี Train and Test ซึ่งเรียกอีกอย่างหนึ่งว่าวิธี Data Splitting เนื่องจากเป็นวิธีที่ง่ายและเหมาะสมแก่การวิจัยเบื้องต้น ในที่นี้ข้อมูลที่ใช้ในการสร้าง Neural Networks แต่ละตัว (ตามตารางที่ 1) จะถูกแยกเป็น 2 ส่วนคือ ส่วนที่ใช้ในการฝึก (Training Set) และส่วนที่ใช้ในการทดสอบ (Test Set) ข้อมูล Training Set เป็นข้อมูลที่ใช้ในการกำหนดน้ำหนักความสัมพันธ์ระหว่าง Inputs และ Outputs ของ Neural Networks ในขณะที่ข้อมูลของ Test Set เป็นข้อมูลที่ใช้ในการทดสอบความสามารถในการพยากรณ์ผลผลิตภาพการผลิตหรือที่เรียกอีกอย่างหนึ่งว่า Generalization Capability โดยที่อัตราส่วนเป็นร้อยละระหว่างจำนวนข้อมูลใน Training Set และ Test Set ได้กำหนดไว้ที่ 70:30

Neural Networks แต่ละตัวสร้างขึ้นมี Architectures ดังนี้: Learning Rule: Ext DBD, Activation Function = TanH, Learning Cycles = 50,000 โดยในแต่ละ Networks จะทำการทดลองเพื่อเลือกจำนวน Hidden Units ที่เหมาะสม ซึ่งจะทำการทดลองใช้จำนวน Hidden Unit ตั้งแต่ 3 ขึ้นไป หากจำนวน Hidden Units ที่ใช้ให้ค่าความผิดพลาด (Errors) ที่ยอมรับได้ จึงทำการเลือกจำนวน Hidden Units และ Network Architectures ชุดดังกล่าว

ผลการทดลองเพื่อเลือก Network Architectures ได้แสดงในตารางที่ 1 และค่า Errors ที่เกิดขึ้นแสดงในตารางที่ 2 โดยที่ค่า Errors คำนวณในรูปของ Mean Absolute Percentage Error (MAPE) ซึ่งใช้สูตรการคำนวณดังนี้

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

โดยที่  $e_i = P_i - D_i$ ,  $P_i$  = ค่า Output ของ Neural Networks และ  $D_i$  = ค่าเป้าหมายจริงที่ Neural Networks ต้องการพยากรณ์

<sup>3</sup> ในบทความนี้จะไม่เปิดเผยชื่อหรือประเภทของผลิตภัณฑ์

	MAPE (%)	
	Training Set	Test Set
Neural Network 1	0.16	0.08
Neural Network 2	0.14	0.69
Neural Network 3	4.16	2.21
Neural Network 4	0.25	0.37
Neural Network 5	4.43	4.36
Neural Network 6	0.02	2.20
Neural Network 7	9.61	5.59
Neural Network 8	0.54	10.98

ตารางที่ 2 ผลการทดลอง เพื่อเลือก Network Architectures

ตัวแปรการทดลอง	ระดับ
Learning Cycles	1) 50,000 2) 250,000 3) 500,000 4) Cross-validation Stop Training
ระดับของ Noise <sup>4</sup>	1) $\sigma = 5\%$ 2) $\sigma = 10\%$ 3) $\sigma = 15\%$

ตารางที่ 3 การออกแบบการทดลองเพื่อหาค่า Learning Cycles และ ระดับของ Noise


จากผลการทดลองในตารางที่ 2 จะเห็นได้ว่า Neural Network 8 ซึ่งเป็น Gating Network ที่จะทำให้การพยากรณ์ผลผลิตภาพการผลิติดนั้นมีค่า Error ค่อนข้างสูง จึงได้มีการทดลองต่อไปเพื่อที่จะหาทางลดค่า Error ดังกล่าว ในงานวิจัยนี้จึงได้นำเอาวิธี Noise Injection (Raviv and Intrator, 1996) มาใช้ในการฝึก Neural Networks กล่าวคือวิธีนี้จะทำการเพิ่ม Noise เข้าไปใน Training Data เพื่อให้ Neural Networks เรียนรู้ความสัมพันธ์ระหว่าง Inputs และ Outputs และหลีกเลี่ยงการเกิด Overfitting โดย Noise ( $\eta$ ) ที่ใช้มีการแจกแจงแบบ Normal และ  $\eta \sim N(0, \sigma)$  ตารางที่ 3 แสดงการออกแบบการทดลองเพื่อหาจำนวน Learning Cycles และ ระดับของ Noise ที่เหมาะสม ในการทดลองนี้นอกจากจะกำหนดค่า Learning Cycles ให้มีค่าคงที่ตั้งแต่ 50,000 จนถึง 500,000 แล้วนั้น ยังมีการใช้วิธี Cross-validation Stop Training (Hine, 1997) ในการกำหนดจำนวน Training Cycles โดยวิธีนี้จะทำการฝึก Neural Networks ไปจนกระทั่งค่า Error จาก Test Set มีค่าที่สูงกว่า Error ใน Training Set จึงหยุดกระบวนการฝึกทั้งนี้เพื่อป้องกันการเกิด Overfitting

<sup>4</sup> ค่า  $\sigma$  กำหนดในรูปของร้อยละของค่าเฉลี่ยของ Input แต่ละตัวใน Neural Networks



## ผลการทดลองและอภิปราย

รูปที่ 2 แสดงผลการทดลองเพื่อหาค่า Learning Cycles และระดับของ Noise ที่เหมาะสม จากผลดังกล่าวสังเกตได้ว่า เมื่อ Learning Cycles มีค่ามากขึ้น ค่า Errors ของ Neural Networks มีแนวโน้มเพิ่มขึ้น ซึ่งชี้ให้เห็นว่า Neural Networks เรียนรู้ข้อมูลจาก Training Set ได้ดีเกินไปจนเกิด Overfitting และรูปที่ 2 ยังแสดงให้เห็นว่าการ Train Neural Networks โดยใช้วิธี Cross-validation Stop Training ให้ค่า Errors ที่ต่ำกว่าการกำหนดค่า Learning Cycles ที่ค่าคงที่หนึ่งๆ อีกด้วย ทั้งนี้ผลการทดลองดังกล่าวเป็นการยืนยันว่า วิธี Cross-validation Stop Training สามารถป้องกันการเกิด Overfitting ได้ดีในระดับหนึ่ง



รูปที่ 2 ผลการทดลอง

นอกจากนั้นได้มีการค้นพบจากการทดลองว่า ปริมาณของ Noise ที่เพิ่มเข้าไปใน Training Set มีผลทำให้ค่า Errors ลดลง ในที่นี้หากไม่มีการเพิ่ม Noise (0%) ค่า Errors ของ Neural Networks มีค่าค่อนข้างสูง แต่เมื่อเพิ่ม Noise เข้าไป ค่า Errors มีแนวโน้มลดลง เหตุที่เป็นเช่นนี้สามารถอธิบายได้ว่า ปริมาณ Noise ที่เพิ่มเข้าไปใน Training Set เป็นการทำให้ Neural Networks เรียนรู้ General Relations ระหว่าง Inputs และ Outputs และหลีกเลี่ยงไม่ให้ Neural Networks จดจำข้อมูลจนทำให้เกิด Overfitting จากการทดลองนี้ ปริมาณ Noise ที่เหมาะสมคือ 5% และควรใช้วิธี Cross-validation Stop Training ในการ Train Neural Networks รูปที่ 3 แสดงผลการพยากรณ์ผลผลิตภาพการผลิต (จาก Test Set) ซึ่งเป็นการแสดงความสามารถของ Neural Network ที่สร้างขึ้นในการพยากรณ์ผลผลิตภาพการผลิตที่จะเกิดขึ้นในอนาคต และเป็นการให้ความเชื่อมั่นว่า Neural Networks ที่สร้างขึ้นสามารถใช้ในการพยากรณ์ผลผลิตภาพการผลิตของชิ้นส่วนฮาร์ดดิสก์ไดร์ฟและนำผลการพยากรณ์ไปวางแผนการผลิตได้



โดยใช้วิธี Cross-validation Stop Training ร่วมกับวิธี Noise Injection ซึ่งผลการทดลองชี้ให้เห็นว่าทั้งสองวิธีดังกล่าวสามารถลดผลกระทบจากการเกิด Overfitting ได้ในระดับหนึ่ง

### กิตติกรรมประกาศ

ผู้แต่งบทความคนที่ 1 ขอขอบคุณพระเจ้าผู้ประทานพรและสติปัญญาในการดำเนินงานวิจัยนี้ และในงานวิจัยนี้ผู้แต่งคนที่สองได้รับทุนสนับสนุนจากศูนย์เทคโนโลยีอิเล็กทรอนิกส์และคอมพิวเตอร์แห่งชาติ (NECTEC) ตามโครงการพัฒนาระบบพยากรณ์บุคคล ในอุตสาหกรรมฮาร์ดดิสก์ไดรฟ์ ประจำปีการศึกษา 2549 และขอขอบคุณ ดร.จิตติพร ภูไฟจิตรกุล จาก Seagate Technology ที่ให้ความอนุเคราะห์ข้อมูลและสถานที่ในการศึกษาเพื่อดำเนินงานวิจัยนี้

### เอกสารอ้างอิง

- 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 networks (ANNs),” **Computers and Electronics in Agriculture**, vol. 54(2), pp. 69-83.
- Haykin, S. 1994. **Neural networks: A comprehensive foundation**. New York, NY: McMillan College Publishing,
- Hine, J. W. 1997. **Matlab Supplement to Fuzzy and Neural Approaches in Engineering**, John Wiley & Sons, New York.
- Jacob, R. A., Jordan, M.I., Nowlan, S. J., and Hilton, G. E. (1991). “Adaptive Mixture of Local Experts,” **Neural Computation**. 3(1): 79-87.
- Kaul, M., Hill, R.L., and Walthall, C. 2005 “Artificial neural networks for corn and soybean yield prediction,” **Agricultural Systems**, vol. 85(1), pp. 1-18.
- Olajide, J.O., Igbeka, J.C., Afolabi, T.J. and Emiola, O.A. 2007 “Prediction of oil yield from groundnut kernels in an hydraulic press using artificial neural network (ANN),” **To be appeared in Journal of Food Engineering**.
- 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., & Williams, R. J. 1986. Learning internal representations by error propagation. In D.E. Rumelhart & J.E. Mc Clelland (Eds.), **Parallel Distributed Processing : Exploration in the Microstructure of Cognition**. (Volume I. Foundations). Cambridge, M.A: MIT Press.
- Sharma, A.K., Sharma, R.K., and Kasana, H.S. 2006 “Prediction of first lactation 305-day milk yield in Karan Fries dairy cattle using ANN modeling,” **To be appeared in Applied Soft Computing**.
- Twomey, J.M. and Smith, A.E. 1998 “Bias and variance of validation methods for function approximation neural networks under conditions of sparse data”, **IEEE Transaction on Systems, Man, and Cybernetics—Part C: Applications and Reviews**, 28(3), pp. 417-430.
- Vellore, T.S., Manjeshwar, P. M., and Lam, S.S.Y. 2002, “A pragmatic neural network approach for SMT yield prediction.” **Intelligent Engineering System through Artificial Neural Networks**, vol. 12, pp. 651-656.
- Ye, X., Sakai, K., Garciano, L.O., Asada, S. I. and Sasao, A. 2006 “Estimation of citrus yield from airborne hyperspectral images using a neural network model,” **Ecological Modeling**, vol. 198(3-4),pp. 426-432.