

## บทที่ 4

### บทสรุปและข้อเสนอแนะ

#### บทสรุป

จุดประสงค์ของการศึกษาวิทยานิพนธ์ฉบับนี้ เป็นการศึกษาการประยุกต์เครือข่ายนิเวรอล เพื่อใช้ในการชดเชยแบบปรับได้ของแขนกล ซึ่งทำงานอยู่ในสภาวะการเปลี่ยนแปลงค่าพารามิเตอร์ อันได้แก่ มวลของโหลด ( $\Delta m_2$ ) ตำแหน่งของจุดศูนย์กลางมวลของข้อต่อที่ 2 ( $\Delta l_{c_2}$ ) และ โมเมนต์ความเฉื่อยของข้อต่อที่ 2 ( $\Delta I_2$ ) เครือข่ายนิเวรอลที่ใช้เป็นเครือข่ายนิเวรอลชนิด Backpropagation (BNN) BNN เป็นเครือข่ายนิเวรอลซึ่งมีความสามารถในการประมาณค่าฟังก์ชัน มีการเรียนรู้แบบใช้การแนะนำ (supervised learning) และมีการเชื่อมต่อแบบป้อนไปข้างหน้า การเรียนรู้ของ BNN เป็นการแปลงข้อมูลความรู้ให้อยู่ในรูปพารามิเตอร์ของ BNN ได้แก่ ค่าน้ำหนัก ค่าน้ำหนักไบแอส และค่าสัมประสิทธิ์ของฟังก์ชันซิกมอยด์โดยใช้อัลกอริทึม Backpropagation การชดเชยแบบปรับได้ด้วย BNN ได้ใช้หลักการจากทฤษฎีการประมาณค่าฟังก์ชัน คือ ฟังก์ชันต่อเนื่อง  $f(x)$  ใดๆ ซึ่งประกอบด้วยตัวแปร  $x$  และพารามิเตอร์  $p$  สามารถประมาณค่าได้ในรูป (Sanner, 1992)

$$f(x) \cong \sum_{i=1}^N b_i \cdot Y_i(x) \quad (4-1)$$

โดยที่  $N$  คือจำนวนพจน์

$b_i$  คือค่าสัมประสิทธิ์ของพจน์ที่  $i$

$Y_i(x)$  คือฟังก์ชันมูลฐาน (basis function) ของพจน์ที่  $i$  ของฟังก์ชัน  $f(x)$

เมื่อพารามิเตอร์  $p$  ของ  $f(x)$  มีการเปลี่ยนแปลงอย่างไม่ทราบค่า แทน  $f(x)$  ที่ค่าพารามิเตอร์เปลี่ยนแปลงนี้ด้วยฟังก์ชัน  $f(x)$  จาก (4-1) สามารถประมาณค่าความแตกต่างระหว่างฟังก์ชันที่เกิดจากการเปลี่ยนแปลงค่าพารามิเตอร์ ได้คือ

$$f(x) - f(x) \cong \sum_{i=1}^N \tilde{b}_i \cdot Y_i(x) \quad (4-2)$$

โดยที่  $\tilde{b}_i$  คือค่าสัมประสิทธิ์ของพจน์ที่  $i$

การชดเชยแบบปรับได้ด้วย BNN ได้ใช้หลักการจากสมการ(4-2)สำหรับสร้างตัวชดเชย และใช้การปรับค่าสัมประสิทธิ์ของฟังก์ชันมูลฐานแทนการปรับค่าพารามิเตอร์ของตัวชดเชย การชดเชยทำโดยใช้ BNN เรียนรู้ฟังก์ชันของสมการค่าความผิดพลาดของแขนกล ซึ่งมีการเปลี่ยนแปลงค่าพารามิเตอร์ให้อยู่ในรูปสมการ(4-2) และปรับค่าน้ำหนักชั้นนอกสุดของ BNN ด้วยอัลกอริทึม Backpropagation เพื่อลดค่าความผิดพลาดของตำแหน่งลงเข้าใกล้ศูนย์ นอกจากนี้ได้วิเคราะห์เสถียรภาพของการชดเชยแบบปรับได้ เพื่อพิสูจน์ว่าการชดเชยแบบปรับได้ด้วย BNN สามารถลดค่าความผิดพลาดของตำแหน่งลงเข้าใกล้ศูนย์ ซึ่งได้แสดงไว้ในบทที่ 3 ในหัวข้อการวิเคราะห์เสถียรภาพ

การชดเชยแบบปรับได้สามารถควบคุมตำแหน่งได้ผลดี เมื่อค่าโหลดของแขนกลเปลี่ยนแปลงในช่วง [ 0 Kg , 5 Kg] เมื่อค่าโหลดเปลี่ยนแปลงมากกว่า 5 Kg ทำให้ผลตอบการควบคุมตำแหน่งมีการพุ่งเกิน(overshoot)และการแกว่งก่อนเข้าสู่สถานะอยู่ตัวดังแสดงในรูป 3-3 ถึง 3-12 ของบทที่ 3 การแก้ปัญหาการพุ่งเกินและการแกว่งได้ใช้การชดเชยแบบปรับได้ด้วย BNN ร่วมกับการเลือกตัวควบคุมที่มีค่าพารามิเตอร์กระจายอยู่ในช่วงการทำงาน ซึ่งทำให้การพุ่งเกินและการแกว่งก่อนเข้าสู่สถานะอยู่ตัวลดลง ดังแสดงในรูป 3-14 ถึง 3-23 ของบทที่ 3

### ปัญหาที่เกิดขึ้น

- 1) ปัญหาหลักของการทำวิทยานิพนธ์เกี่ยวกับเครือข่ายนิวรอล คือการเรียนรู้ด้วย BNN จะใช้เวลานาน เช่น เวลาที่ใช้ในการเรียนรู้ข้อมูล 1250 ชุด จำนวน 10,000 รอบ สำหรับ BNN ขนาด  $10 \times 50 \times 1$   $10 \times 100 \times 1$  และ  $10 \times 200 \times 1$  ใช้เวลาประมาณ 75 , 150 และ 300 ช.ม. ตามลำดับ บนเครื่อง HP Workstation รุ่น Apollo series 700
- 2) ความผิดพลาดเชิงเลขที่เกิดขึ้นเนื่องจากการเรียนรู้ของ BNN จำเป็นต้องแปลงพิสัย (range) ของข้อมูลเอาต์พุตให้อยู่ในช่วง [0.1,0.9] และการแปลงพิสัยของค่าเอาต์พุตของ BNN ให้อยู่ในพิสัยของข้อมูลเอาต์พุต ซึ่งทำให้ค่าผิดพลาดของการเรียนรู้ถูกขยายขึ้นเมื่อแปลงพิสัยของค่าเอาต์พุตไปสู่พิสัยที่ใหญ่กว่า



- 3) การกำหนดค่าพารามิเตอร์เริ่มต้นมีผลต่อค่าผิดพลาดเฉลี่ยของการเรียนรู้ การกำหนดค่าพารามิเตอร์เริ่มต้นได้แนะนำไว้ในขั้นตอนการเรียนรู้ของบทที่ 2

### ข้อเสนอแนะ

ในปัจจุบันได้มีผู้เสนอเครือข่ายนิวรอลชนิด Wavelet (Wavelet Network หรือ WN) (Zhang, 1992 ; Bakshi, 1993) ซึ่งมีคุณสมบัติที่น่าสนใจคือ

- 1) คุณสมบัติ Locality ของฟังก์ชันปมนิวรอลชนิด WN คุณสมบัตินี้ทำให้ปมนิวรอลสามารถเข้ารหัสความรู้ได้อย่างชัดเจน ปริภูมิของความรู้ (knowledge space) ทั้งหมดถูกแบ่งออกเป็นปริภูมีย่อยๆ WN จะกำหนดให้ปมนิวรอลชุดหนึ่งทำหน้าที่เข้ารหัสความรู้เฉพาะในปริภูมีย่อยๆ นั้น โดยไม่ขึ้นกับปมนิวรอลชุดอื่น ต่างจากปมนิวรอลชนิด BNN ปมนิวรอลทุกปมทำหน้าที่เข้ารหัสความรู้ทั้งหมดร่วมกัน
- 2) คุณสมบัติ Orthonormality ของฟังก์ชันปมนิวรอลชนิด WN คุณสมบัตินี้ทำให้ WN สามารถเรียนรู้โดยใช้จำนวนปมนิวรอลน้อยกว่า BNN สำหรับการเรียนรู้ความรู้ชุดหนึ่งๆ
- 3) คุณสมบัติ Multiresolution ของ WN คุณสมบัตินี้ทำให้ WN สามารถเรียนรู้ข้อมูลความรู้ได้ละเอียดมากขึ้น กล่าวคือในปริภูมีย่อยบางปริภูมิที่มีความหนาแน่นของข้อมูลสูง WN ก็ใช้จำนวนปมมากและเพียงพอสำหรับปริภูมินั้น และใช้จำนวนปมนิวรอลน้อยและเพียงพอสำหรับปริภูมิที่มีความหนาแน่นของข้อมูลความรู้น้อย

จากคุณสมบัติ 3 ข้อนี้สามารถปรับปรุงการชดเชยแบบปรับได้ในด้าน

- 1) คุณสมบัติ Locality ทำให้การปรับค่าน้ำหนักชั้นนอกสุดของ WN มีการปรับค่าน้ำหนักเพียงบางค่าเท่านั้น เนื่องจากปมนิวรอลของ WN มีการจัดแบ่งการเข้ารหัสอย่างชัดเจนและไม่ขึ้นแก่กัน จึงมีเพียงบางปมเท่านั้นที่ได้รับการกระตุ้นจากข้อมูลอินพุตเพื่อปรับค่าน้ำหนัก
- 2) คุณสมบัติ Orthonormality ทำให้ WN สามารถเรียนรู้โดยใช้จำนวนปมน้อยเมื่อเทียบกับ BNN สำหรับการเรียนรู้ข้อมูลความรู้ชุดหนึ่งๆ
- 3) คุณสมบัติ Multiresolution ช่วยเพิ่มความละเอียดของการประมาณค่าฟังก์ชันด้วย WN และลดค่าผิดพลาดเฉลี่ยของการเรียนรู้ให้ต่ำลง