


บทที่ 2

หลักการ เหตุผล และทฤษฎีที่เกี่ยวข้อง

2.1 ระบบยานยนต์

2.1.1 โครงสร้างของรถ

โครงสร้างระบบของรถที่จะทำการสร้างขึ้นเพื่องานวิจัยนี้ จะทำการวิเคราะห์แยกย่อย ออกเป็น 2 ส่วนหลักคือ 1.หน่วย เคลื่อนที่ (Mobile unit) 2.หน่วย สถานี (Stationary unit) โดย หน่วยสถานีจะแบ่งแยกย่อยได้อีก สองหน่วยคือ 1 หน่วยติดต่อ (Interface unit) และ 2 หน่วย คำนวณ (Computational unit) หรือ รวมเป็น 3 หน่วยย่อย ทำการจัดเรียงดังรูป 2.1 ซึ่งในแต่ละ หน่วยทั้ง 3 จะมีหน้าที่ การทำงานดังนี้คือ



รูป 2.1 โครงสร้างหน่วยต่างๆ ของระบบรถ และการเชื่อมต่อการประมวลผล ของแต่ละหน่วย

ก. หน่วย เคลื่อนที่ในหน่วยนี้จะประกอบไปด้วยการประมวลผลงาน 2 ลักษณะคือ 1.ทำการรับภาพจากกล้องและทำการออกอากาศ 2.ทำการรับสัญญาณควบคุมที่ส่งมาจากหน่วยติดต่อและทำการควบคุม ซึ่งในหน่วยนี้จะทำการติดตั้งบนตัวรถ

ข. หน่วยติดต่อในหน่วยนี้เป็นหน่วยย่อยในหน่วยสถานี กล่าวคือจะตั้งอยู่กับที่ หน้าที่ในหน่วยนี้คือทำการติดต่อ เชื่อมระหว่างหน่วยคำนวณ และหน่วยเคลื่อนที่ ในหน่วยนี้จะประกอบด้วย 3 อุปกรณ์หลักคือ โทรทัศน์ ตัวขับฮาร์ดแวร์ และ ตัวส่งสัญญาณควบคุมทางอากาศ ในส่วนของโทรทัศน์ใช้เพื่อรับสัญญาณที่ส่งออกมาจาก กล้องที่ทำการติดตั้งบนตัวรถ และ ส่งต่อไปยัง การ์ดจับภาพบนคอมพิวเตอร์ อีกประโยชน์ของโทรทัศน์ก็จะเป็นตัวช่วยเทียบภาพที่รับได้ดั้งเดิมที่ได้รับก่อนการประมวลผลกับภาพที่ประมวลผลแล้วในคอมพิวเตอร์ ในส่วนของตัวขับฮาร์ดแวร์ จะเป็นส่วนที่เชื่อมต่อกับช่องทาง รับส่ง (I/O port) และรับสัญญาณจากคอมพิวเตอร์ และแปลงสัญญาณเพื่อทำการขับเคลื่อนตัวส่งสัญญาณควบคุมทางอากาศต่อไป และสุดท้ายตัวส่งสัญญาณควบคุมทางอากาศจะทำการผสม (Modulate) และส่งสัญญาณที่เป็นแอนะล็อก ออกไปยังรถ

ค. หน่วยประมวลผลจะประกอบด้วยอุปกรณ์หลักเพียงอุปกรณ์เดียวคือคอมพิวเตอร์ส่วนบุคคลที่มี การ์ดจับภาพ ซึ่งในงานวิจัยนี้จะประยุกต์ใช้ การ์ดทีวีจูนเนอร์ (TV tuner) ที่มีราคาถูกกว่ามาใช้แทน ในหน่วยนี้จะประกอบไปด้วยการประมวลผล 3 ขั้นตอนคือ จับภาพจากสัญญาณโทรทัศน์ ที่ส่งต่อมาจาก โทรทัศน์ จากรูปแบบสัญญาณ แอนะล็อกสู่ภาพดิจิทัล แบบบิตแมพ (Bitmap format, BMP) ส่งต่อเพื่อทำการประมวลผลภาพเพื่อทำการลดขนาดและทำการแปลงข้อมูลที่จะนำไป ประมวลผลต่อให้แก่ ขบวนการตัดสินใจ และควบคุม ที่ใช้เครือข่ายประสาทเทียมเป็น ขั้นตอนวิธี (Algorithm) ต่อไป เมื่อทำการตัดสินใจแล้วจะส่งสัญญาณควบคุมออกทางช่องทาง รับส่ง ของคอมพิวเตอร์ สู่หน่วยติดต่อ กล่าวคือจะทำงานวนรอบแบบนี้ไปเรื่อยๆ


2.1.3 ปัญหาการติดตามเส้นทาง

ปัญหาการติดตามเส้นทางสำหรับยานยนต์ภาคพื้นดินนั้นหากกล่าวโดยย่อคือ การที่ยานยนต์สามารถเลี้ยวไปตาม เส้นทาง หรือแนวทางที่รู้แล้วในระนาบที่กำหนดให้ได้ ดังนั้นเพื่อความเข้าใจการติดตามเส้นทางที่ลึกซึ้งและตรงกัน จะกำหนดความต้องการของการติดตามเส้นทางใน 2 ลักษณะคือ 1.ยานยนต์ได้ติดตามและรวบรวมเอาแนวเส้นทางเข้าไว้ได้ 2.ยานยนต์มีทิศทางที่ที่เป็นแนวเดียวกับเส้นทางขณะยานยนต์กำลังติดตามเส้นทาง สรุปคือ ในข้อแรกเป็นการต้องการในเรื่องของตำแหน่ง แต่ข้อสอง เป็นความต้องการในด้านทิศทาง

ในที่นี้จะเสนอแนวทางที่จะใช้แก้ปัญหาการตามเส้นทางไว้ 2 วิธีด้วยกันในที่นี้จะกำหนดจุดเป้าหมาย (Target-point) T บนเส้นวิถีทาง R ที่การกระจัด D เป็นฟังก์ชันของความเร็วยานยนต์ ดังตัวอย่างเช่นพลขั้วจะมองหาจุดเป้าหมายไกลขึ้นเมื่อ ความเร็วสูงขึ้น แนวทางทั้ง 2 คือ [8]

ก. แนวทางเลี้ยวบนพื้นฐานการหันหัวเข้าหา ในวิธีนี้จะเป็นการกำหนดเพียงแค่ทิศทาง เพื่อเติมความต้องการเอา 2 วัตถุประสงค์ คือ ทิศทางและตำแหน่งรวมกัน กล่าวคือ ตัวรถจะต้องพยายามทำให้มุมเลี้ยวที่จะต้องป้อนเข้า ψ เป็นศูนย์

ข. แนวทางเลี้ยวบนพื้นฐานของท่าทางรถ ในวิธีการนี้จะเป็นการเพิ่มความซับซ้อนมากขึ้นจากวิธีที่หนึ่งโดยจะมีการกำหนดความต้องการที่เป็นทั้งตำแหน่งและทิศทาง กล่าวคือที่จุดเป้าหมายนั้นจะมีการกำหนดค่าตามแนวแกนเคลื่อนที่ y เป็นศูนย์ รถจะต้องพยายามเลี้ยวเพื่อรักษาตัวเองให้ค่า ทั้ง y และ ψ มีค่าเป็นศูนย์




รูป 2.2 วิธีการติดตามเส้นทาง [Rivals I., Personnaz L และคณะ 1993]

2.2 ระบบเครือข่ายประสาทเทียม

2.2.1 การออกแบบระบบควบคุมเครือข่ายประสาทเทียม

ระบบเครือข่ายประสาทเทียมเป็นระบบที่ได้แนวคิดมาจากการทำงานจริงของสมองมนุษย์ ซึ่งในปัจจุบันและที่ผ่านมาได้มีการคิดค้นแบบทางคณิตศาสตร์ (Mathematical model) เพื่ออธิบายการทำงานของระบบประสาทมากมาย ระบบเครือข่ายประสาทเทียมเป็นระบบที่ประกอบไปด้วยหน่วยประสาท (Neuron) ที่เรียกว่า โหนด (Node) ซึ่งเป็นหน่วยการทำงานที่เทียบเคียงมาจากโซมา (Soma) ของประสาทจริง ทำการเชื่อมโยงประกอบกันเป็นเครือข่าย [5] รูป 2.3 การเปรียบเทียบระหว่างประสาทจริงและแบบจำลองทางคณิตศาสตร์ของหน่วยประสาท



รูป 2.3 การเปรียบเทียบระหว่างหน่วยประสาททางชีววิทยา และ ประสาทเทียม ภาพทางซ้ายมือ แสดงรูปจำลองของประสาททางชีววิทยา และ ขั้วมือแสดงรูปจำลองประสาทเทียม [Chin-Ten Lin, Geoge Lee, 1996]

ในส่วนประมวลผลของประสาทรุ่นนี้อาจจะแบ่งได้เป็น 2 ส่วนคือ ส่วนที่เป็นการรวม (Summation) ในขาเข้า $x_1, x_2, x_3, \dots, x_N$ ในส่วนนี้แต่ข้อมูลขาเข้าจะมีการปรับน้ำหนักด้วยการคูณค่าน้ำหนักเฉพาะตัวในแต่ละตัว $w_{i1}, w_{i2}, w_{i3}, \dots, w_{iN}$ ทำการหักลบด้วยค่าการกระตุ้น (Bias) θ_i ในส่วนของรวมอาจจะใช้สมการของการรวมอย่างใดอย่างหนึ่งต่อไปนี้

ฟังก์ชันแบบเอ็ม-พี (McCulloch-Pitts function, M-P function)

$$f_i = net_i = \sum_{j=1}^m w_{ij} x_j - \theta_i, \quad (2.1)$$

ฟังก์ชันแบบกำลังสอง (Quadratic function)

$$f_i = \sum_{j=1}^m w_{ij} x_j^2 - \theta_i, \quad (2.2)$$

ฟังก์ชันแบบทรงกลม (Spherical function)

$$f_i = \rho^{-2} \sum_{j=1}^m (x_j - w_{ij})^2 - \theta_i, \quad (2.3)$$

สำหรับการปรับเปลี่ยนน้ำหนักนั้นจะขึ้นอยู่กับวิธีการ และแนวคิดซึ่งส่วนนี้เองจะเป็นการแยกแบบจำลองเครือข่ายประสาทเทียมนี้ออกเป็นแบบต่างๆ ซึ่งจะทำการกล่าวต่อไปในภายหลัง และส่วนที่ เป็นการส่งสัญญาณออกมาจากประสาท y_i ฟังก์ชันกระตุ้น (Activation function) หรือจะเรียกว่าฟังก์ชันถ่ายเท (Transfer function) ก็ได้ ในส่วนของฟังก์ชันกระตุ้นนี้สามารถแบ่งออกเป็น

ฟังก์ชันบันได (Step function)

$$a(f) = \begin{cases} 1 & f > 1 \\ 0 & \text{otherwise,} \end{cases} \quad (2.4)$$

ฟังก์ชันฮาร์ดลิมิเตอร์ (Hard limiter หรือ Threshold function)

$$a(f) = \text{sgn}(f) = \begin{cases} 1 & f \geq 0 \\ -1 & f < 0 \end{cases} \quad (2.5)$$

ฟังก์ชันแบบเส้นตรง (Ram function)


$$a(f) = \begin{cases} 1 & f > 1 \\ f & 0 \leq f \leq 1 \\ 0 & f < 0, \end{cases} \quad (2.6)$$

ฟังก์ชันแบบซิกมอยด์ขั้วเดียว (Unipolar sigmoid)

$$a(f) = \frac{1}{1 + e^{-\lambda f}}, \quad (2.7)$$

ฟังก์ชันแบบซิกมอยด์สองขั้ว (Bipolar sigmoid)

$$a(f) = \frac{2}{1 + e^{-\lambda f}} - 1, \quad (2.8)$$




รูป 2.4 กราฟของฟังก์ชันกระตุ้นแบบต่างๆ ก.) ฟังก์ชันบันได ข.) ฮาร์ดลิมิต ค.) เส้นตรง ง.) ซิกมอยด์ขั้วเดียว และ จ.) ซิกมอยด์สองขั้ว [Chin-Ten Lin, Geoge Lee, 1996]

2.2.2 การเชื่อมต่อ

เครือข่ายประสาทเทียมประกอบด้วย หน่วยประสาทที่เรียกว่าโหนดจำนวนมากเชื่อมโยงเข้าด้วยกันในรูปแบบต่างๆ สำหรับรูปแบบการเชื่อมต่อเครือข่ายนั้นก็มีมากมายหลายรูปแบบ ดังที่

กล่าวมาในขั้นต้นสิ่งที่ทำให้ต้นแบบของเครือข่ายประสาทเทียมนั้นแตกต่างกัน คือลักษณะการเชื่อมต่อ และการเรียนรู้ที่จะนำไปแก้ไขน้ำหนัก โดยรวมแล้วอาจจะสรุปการเชื่อมต่อ ได้ดังรูป 2.5



รูป 2.5 การเชื่อมต่อพื้นฐานของระบบเครือข่าย ก.) การเชื่อมแบบเครือข่ายแบบป้อนไปข้างหน้าชั้นเดียว ข.) การเชื่อมต่อแบบโหนดเดียวแต่มีการป้อนกลับเข้าหาตัวเอง ค.) การเชื่อมต่อแบบวนกลับชั้นเดียว ง.) การเชื่อมต่อแบบป้อนไปข้างหน้าหลายชั้น จ.) การเชื่อมต่อแบบวนกลับหลายชั้น [Chin- Ten Lin, Geoge Lee, 1996]

2.2.3 การเรียนรู้


ระบบเครือข่ายประสาทเทียมนั้นเมื่อทำการสร้างเสร็จก็ยังไม่อาจจะนำมาใช้งานได้ทันทีแต่ต้องมีการเรียนรู้ในระยะหนึ่งก่อนจึงจะสามารถแก้ปัญหาได้หนึ่งในการจำแนกประเภท และขั้นตอนวิธีการแก้ปัญหา ของเครือข่ายประสาทเทียมคือ วิธีการเรียนรู้ สำหรับวิธีการเรียนรู้ของระบบเครือข่ายประสาทเทียมนั้นอาจจะแบ่งออกได้เป็น 3 ลักษณะคือ

ก. การเรียนรู้แบบมีผู้สอน (Supervised learning) การเรียนรู้แบบนี้ อาจจะเรียกอีกอย่างได้ว่า การเรียนรู้แบบ แก้ความผิดพลาด (Error-Correcting learning) การเรียนรู้แบบนี้ จำเป็นต้องมีข้อมูลตัวอย่างและการเรียนรู้แบบนี้จะพยายามสร้างผลลัพธ์ที่ได้ให้ตามเป้าหมายที่ได้รับหรือตามเป้าหมายที่กำหนด วิธีการเรียนรู้แบบนี้ใช้วิธีแบบแก้ความผิดพลาดที่ได้ให้ผลออกมา มีความแตกต่างกับเป้าหมายให้น้อยที่สุด

ข. การเรียนรู้แบบไม่มีผู้สอน (Unsupervised learning) การเรียนรู้แบบนี้มีคุณลักษณะที่ปรับตัวเองเพื่อเข้าหาข้อมูลขาเข้าและมีการจัดการข้อมูลด้วยตัวเอง กล่าวคือไม่ต้องการการป้อนข้อมูลกลับจากสิ่งแวดล้อมแต่จะค้นหาตัวเองจากข้อมูลที่ได้และจับข้อมูลออกมา

ค. การเรียนรู้แบบเสริมแรง (Reinforcement learning) เป็นการเรียนรู้แบบ บนสายงาน (On-Line Learning) ของข้อมูลเข้าออก ตลอดขบวนการหาคำตอบทดลอง และผิดพลาด (Trial

and Error) ระบบจะปรับเปลี่ยนน้ำหนักด้วยสัญญาณที่เพิ่มเข้ามาที่เรียกว่าสัญญาณเสริมแรง (Reinforcement Signal) [5]



รูป 2.6. กฎการเรียนรู้ของเครือข่ายประสาทเทียม ก.) การเรียนรู้แบบมีผู้สอน ข.) การเรียนรู้แบบเสริมแรง และ ค.) การเรียนรู้แบบไม่มีผู้สอน [Chin-Ten Lin, Geoge Lee, 1996]

2.2.4 การควบคุมด้วยเครือข่ายประสาทเทียม

การสร้างตัวควบคุมระบบเครือข่ายประสาทเทียมนั้นหากกล่าวให้ง่ายคือ การประมาณฟังก์ชันถ่ายเทในพลศาสตร์ของระบบ อย่างไรก็ตามไม่มีวิธีและข้อกำหนดที่แน่นอนเกี่ยวกับการออกแบบขนาดและลักษณะเครือข่าย แต่โดยทั่วไปแล้วในส่วนของโหนดเข้าจะมีขนาดเท่ากับข้อมูลที่คาดว่าจำเป็นสำหรับการประมาณพลศาสตร์ และมีโหนดขาออกที่มีจำนวนเท่ากับสัญญาณควบคุมที่ต้องการแต่การออกแบบอาจจะไม่เป็นไปตามนี้ได้ เพราะในระบบหนึ่ง และสภาพหนึ่งๆ การเรียนรู้ของระบบเครือข่ายอาจจะแตกต่างกันอย่างสิ้นเชิงก็เป็นได้ แต่นั่นไม่ได้หมายความว่าเครือข่ายประสาทเทียมทุกแบบจะใช้แก้ปัญหาได้ทุกปัญหาได้ดีในแต่ละประเภทของเครือข่าย

ประสาทเทียม ก็มีประเภทงานที่เหมาะสม ตัวอย่างเช่น MADALINE อาจจะเหมาะสมสำหรับงานจำพวกปัญหาการแยกจำพวก หรือ ปัญหาการจดจำที่เป็นรูปแบบ (Pattern recognition) แต่ในขณะเดียวกัน Self Organizing Map (SOM) ซึ่งเป็นเครือข่ายแบบไม่มีผู้สอน ก็เหมาะสำหรับงานจำพวก การควบคุมแบบป้อนกลับ (Feedback control) เช่นการรักษาสมดุลตุ้มกลับหัว (Inverted pendulum) ดังตัวอย่างเช่นปรากฏในเอกสารงานวิจัย Charles W. Anderson, 1989 [4] หรือ อีกตัวอย่างดังเช่นใช้การแสดงพลศาสตร์ของระบบดังปรากฏในเอกสารเชิงวิชาการ G. A. Barreto, A. F. R. Araujo, 2004 [2]

อย่างไรก็ตามเครือข่ายบางประเภทอาจจะใช้ได้หลายประเภทงานเช่นเครือข่ายประสาทแบบแพร่กลับ (Back propagation) อาจจะใช้ได้ในงานที่เป็นปัญหาการแยกจำพวก หรือ งาน

จำพวกทำนายค่าอนุกรมเวลา (Time series forecasting) ก็ได้ สำหรับการประมาณฟังก์ชันทั่วไป แล้วนั้น ฟังก์ชันส่วนมากสามารถประมาณด้วยเครือข่ายแบบแพร่กลับด้วยที่มีชั้นเครือข่ายเพียง 2 ชั้น โดยมีชั้นที่มี ฟังก์ชันกระตุ้นเป็น ลอจซิกมอยด์ และเส้นตรง ในอย่างละหนึ่งชั้น

ดังที่กล่าวไปแล้วในข้างต้นว่าไม่มีวิธีการตายตัวใดๆ ในการออกแบบตัวควบคุมที่สร้างจากระบบเครือข่ายประสาทเทียม หากจะกล่าวให้ง่ายขึ้นก็เปรียบได้ว่า ไม่ว่าสมองของสัตว์ใดๆ จะมีเซลล์ประสาทมากหรือน้อยก็สามารถตัดสินใจได้ แต่ประสิทธิภาพของการตัดสินใจ และความสามารถในการเข้าใจถึงลักษณะปัญหานั้นไม่เท่ากัน ลักษณะเช่นนี้ก็เป็นเช่นเดียวกันกับระบบเครือข่ายประสาทเทียม


และเนื่องจากความสำเร็จจากใช้ระบบควบคุมเครือข่ายประสาทเทียมแบบแพร่กลับตามเอกสารงานวิจัยของ Dean A. Pomerleau, (1992) [6] ซึ่งงานวิจัยนี้มีส่วนคล้ายกับงานวิจัยของผู้วิจัยที่สุดจึงเลือกใช้ระบบเครือข่ายประสาทเทียมแบบแพร่กลับมาปรับปรุงใช้ในงานวิจัยนี้ด้วย

2.2.5 ระบบเครือข่ายประสาทเทียมแบบแพร่กลับ

ระบบเครือข่ายประสาทเทียมที่เลือกมาใช้ในงานวิจัยนี้คือ ระบบประสาทแบบแพร่กลับซึ่งเป็นระบบประสาทแบบต้องมีผู้สอน กล่าวคือต้องมีการฝึกฝนในระดับหนึ่งก่อนจึงจะใช้งานได้ ระบบเครือข่ายประสาทเทียมแบบแพร่กลับนี้ เป็นระบบเครือข่ายประสาทเทียมป้อนไปข้างหน้าแบบหลายชั้น (Multilayer feed forward) ประเภทหนึ่ง ซึ่งจะไม่มีการนำสัญญาณที่ได้คำนวณออกมาจากระบบเครือข่ายป้อนกลับแต่จะใช้วิธีการสอนเพื่อทำการปรับแก้น้ำหนักแทน กล่าวคือจะทำการรับข้อมูลเข้ามาประมวลผล และส่งค่าออกไปเท่านั้น อีกนัยหนึ่งคือทำหน้าที่เสมือนตัวประมาณฟังก์ชันประเภทหนึ่ง ตัวอย่างเช่นหลังจากผ่านการสอนจากภาพ ตัวอย่างจำนวน 350 ภาพ ที่ทำการจับภาพจากเอกสารวิดิทัศน์ในรูปแบบเอกสาร AVI ซึ่งเป็นเอกสารวิดิทัศน์ที่นำภาพแบบบิตแมพนำมาเรียงต่อกัน ที่ความเร็ว 10 ภาพต่อวินาที หากเปรียบเทียบกับการสอนบนระบบจริงคือใช้เวลาทั้งสิ้น 35 วินาที นำมาแตกออกเป็นภาพตัวอย่าง และทำการลดขนาด ให้เหลือขนาด 32x30 และปรับภาพเป็น แบบโทนเทา (Grayscale) ขนาด 8 บิต และทำการคัดลอกข้อมูลลงใน เมทริกซ์ ซึ่งมีขนาด 32x30 เช่นเดียวกัน เมทริกซ์นี้ทำหน้าที่เสมือนไบต์แอเรย์ของภาพ (Byte array) คำนวณหาตำแหน่งกลางของถนนด้วยการนับตามตำแหน่งข้อมูลภาพในเมทริกซ์ ระบบถูกสอนจนกระทั่ง ค่าผิดพลาดการสอน (Training error) ต่ำกว่า ค่าเงื่อนไขที่กำหนดไว้จึงเสร็จสิ้นการสอนระบบเครือข่ายประสาทเทียม

เพื่อความเข้าใจในขั้นตอนการแก้ปัญหาในช่วงของการฝึกสอนของเครือข่ายประสาทเทียมแบบแพร่กลับสามารถอธิบายเป็นขั้นตอนได้คือ ให้ระบบเครือข่ายประสาทเทียมแบบแพร่กลับนี้มีทั้งหมด 3 ชั้นมีโครงสร้างดังรูป 2.7 ประกอบด้วย ชุดค่าข้อมูลขาเข้า x_j น้ำหนักของการเชื่อมต่อ

ระหว่างชั้นขาเข้ากับชั้นซ่อนเร้น v_{qj} ค่าสัญญาณออกจากชั้นซ่อนเร้น z_q น้ำหนักของการเชื่อมต่อระหว่างชั้นซ่อนเร้นชั้นข้อมูลขาออก w_{iq} และข้อมูลขาออก y_i



รูป 2.7 ระบบเครือข่ายแบบป้อนไปข้างหน้าขนาด 3 ชั้น

พิจารณา คู่ข้อมูลเข้าและออก $\{x^{(k)}, d^{(k)}\}$, $k=1, 2, 3, \dots, p$ ซึ่ง $d^{(k)}$ คือค่าเป้าหมายที่ต้องการในการเขียนสมการต่อไปนี้จะด้วย k ออกเพื่อให้่ายต่อการเขียน เมื่อโหนดในชั้นซ่อนเร้นรับค่าชุดข้อมูล x จะมีค่ารับเข้าแต่ละโหนดคือ

$$net_q = \sum_{j=1}^m v_{qj} x_j \quad (2.9)$$

เมื่อ v_{qj} คือ ค่าน้ำหนักที่เชื่อมต่อระหว่างชั้นซ่อนเร้นและชั้นขาเข้า

x_j คือ ค่านำเข้าของชั้นของข้อมูลขาเข้า
และแต่ละโหนดจะส่งค่าสัญญาณออกมาเป็น

$$z_q = a(net_q) = a\left(\sum_{j=1}^m v_{qj} x_j\right) \quad (2.10)$$

เมื่อ $a(net)$ คือ ฟังก์ชันกระตุ้นที่เลือกใช้ในระบบเครือข่าย

และค่าข้อมูลเข้าในแต่ละโหนดของชั้นขาออกคือ

$$net_i = \sum_{q=1}^l w_{iq} z_q = \sum_{q=1}^l w_{iq} a\left(\sum_{j=1}^m v_{qj} x_j\right) \quad (2.11)$$

เมื่อ w_{iq} คือ ค่าน้ำหนักที่เชื่อมต่อระหว่างชั้นขาออกและชั้นซ่อนเร้น

และจะส่งค่าข้อมูลขาออกมาเป็น

$$y_i = a(net_i) = a\left(\sum_{q=1}^l w_{iq} z_q\right) = a\left(\sum_{q=1}^l w_{iq} a\left(\sum_{j=1}^m v_{qj} x_j\right)\right) \quad (2.12)$$

และทำการกำหนดฟังก์ชันต้นทุน (Cost function) แสดงเป็นสมการทางคณิตศาสตร์ ดังสมการ (2.13)

$$\begin{aligned} E(w) &= \frac{1}{2} \sum_{i=1}^n (d_i - y_i)^2 = \frac{1}{2} \sum_{i=1}^n [d_i - a(net_i)]^2 \\ &= \frac{1}{2} \sum_{i=1}^n \left[d_i - a\left(\sum_{q=1}^l w_{iq} z_q\right) \right] \end{aligned} \quad (2.13)$$

เมื่อ d_i คือ ค่าเป้าหมายที่ต้องการ

ในการเรียนรู้ระบบเครือข่ายประสาทเทียม แบบเพอร์เซปตรอนหลายชั้นนั้น (Multilayer perceptron) อาจกล่าวได้ว่าเป็นการปรับให้ค่าของฟังก์ชันต้นทุนนี้ลดลงให้น้อยที่สุด กล่าวคือ การทำให้ค่าเกรเดียนต์ของฟังก์ชันต้นทุนนี้มีลักษณะลาดลง หรือเรียกว่าวิธี เกรเดียนต์ลาดลง (Gradient descent method) สามารถแสดงดังสมการ

$$\Delta \tilde{w} = -\eta \nabla E[\tilde{w}] \quad (2.14)$$

ฉะนั้นระบบจะทำการเปลี่ยนน้ำหนักและการกระตุ้นเพื่อให้เข้าสู่ค่าที่ต้องการ พร้อมด้วยค่าคงที่การเรียนรู้ η ซึ่งเป็นค่ากำหนดขนาดขั้นการเปลี่ยนน้ำหนักว่ามากหรือน้อยเท่าใด ซึ่งค่าเริ่มต้นที่นิยมคือ 1 สำหรับงานใดๆ แต่อาจกำหนดให้มากหรือน้อยกว่านี้ได้ และเมื่อประยุกต์กับลูกโซ่ของอนุพันธ์ในสมการ 2.13 และ 2.14 จะสามารถแสดงได้คือ

$$\begin{aligned} \Delta w_{iq} &= -\eta \frac{\partial E}{\partial w_{iq}} \\ \Delta \theta_i &= -\eta \frac{\partial E}{\partial \theta_i} \end{aligned} \quad (2.15)$$

มีสัญญาณความผิดพลาด (Error signal) ที่ชั้นสัญญาณขาออก δ_{oi} คือ

$$\delta_{oi} = -\frac{\partial E}{\partial net_i} = -\left[\frac{\partial E}{\partial y_i}\right]\left[\frac{\partial y_i}{\partial net_i}\right] = [d_i - y_i][a'(net_i)] \quad (2.16)$$

เมื่อ net_i คือค่านำเข้าของโนดชั้นขาออก ซึ่งค่าข้อมูลเข้านี้เป็นข้อมูลขาออกของชั้นซ่อนเร้น
พิจารณาอนุพันธ์ของฟังก์ชันกระตุ้น

$$a'(net_i) = \frac{\partial a(net_i)}{\partial net_i} \quad (2.17)$$

เมื่อประยุกต์ใช้ กฎลูกโซ่กับการเปลี่ยนค่าของการเชื่อมต่อในชั้นขาออกและขาเข้า

$$\Delta v_{qj} = -\left[\frac{\partial E}{\partial v_{qj}}\right] = -\eta \left[\frac{\partial E}{\partial net_q}\right] \left[\frac{\partial net_q}{\partial v_{qj}}\right] \quad (2.18)$$

$$\Delta v_{qj} = -\eta \left[\frac{\partial E}{\partial z_q}\right] \left[\frac{\partial z_q}{\partial net_q}\right] \left[\frac{\partial net_q}{\partial v_{qj}}\right] \quad (2.19)$$

จากสมการ 2.13 สามารถแสดงได้ชัดเจนว่าพจน์ $[d_i - y_i]$, $i = 1, 2, \dots, n$ เป็นฟังก์ชันของ z_q จึงสามารถแสดงเป็นสมการ

$$\Delta v_{qj} = \eta \sum_{i=1}^n [(d_i - y_i) a'(net_i) w_{iq}] a'(net_q) x_j \quad (2.20)$$

สามารถเขียนใหม่ได้เป็น

$$\Delta v_{qj} = \eta \sum_{i=1}^n [d_{oi} w_{iq}] a'(net_q) x_j = \eta \delta_{hq} x_j \quad (2.21)$$

และในชั้นต่อมาจะมีสัญญาณความผิดพลาดคือ

$$\delta_{hq} = -\frac{\partial E}{\partial net_q} = -\left[\frac{\partial E}{\partial z_q}\right] \left[\frac{\partial z_q}{\partial net_q}\right] = a'(net_q) \sum_{i=1}^n \delta_{oi} w_{iq} \quad (2.22)$$

ขบวนการเรียนรู้แบบนี้อาจเรียกอีกแบบว่า กฎการเรียนรู้เดลต้าทั่วไป (Generalized delta learning rule) สำหรับการปรับเปลี่ยนน้ำหนักสำหรับชั้นใด ๆ คือ

$$\Delta w_{ij} = \eta \delta_i x_j = \eta \delta_{output-i} \cdot x_{input-j} \quad (2.23)$$

จะเห็นได้ว่าการปรับเปลี่ยนน้ำหนักแบบนำค่าสัญญาณความผิดพลาดจากชั้นก่อนๆ มาเป็นส่วนหนึ่งในการปรับน้ำหนัก นี่เองที่เป็นที่มาของชื่อ แพร่กลับ [1]

2.2.6 ตัวแปรที่มีผลต่อการเรียนรู้ของเครือข่ายประสาทเทียมแบบแพร่กลับ

การที่จะให้การเรียนรู้ที่เกิดขึ้นในระบบเครือข่ายประสาทเทียมนั้นดีหรือไม่ ประกอบไปด้วยปัจจัยต่างๆ ประกอบเข้าด้วยกัน และไม่มีสูตรหรือสมการ เพื่อหาคำตอบว่าปัจจัยใดจะเด่นชัดที่สุดในการออกแบบเครือข่ายประสาทเทียมหนึ่งๆ ปัจจัยที่เป็นตัวแปรที่มีผลต่อการเรียนรู้ระบบเครือข่ายประสาทเทียมแบบแพร่กลับประกอบไปด้วย

ก.) น้ำหนักเริ่มต้น (Initial weights) น้ำหนักเริ่มต้นของเครือข่ายประสาทแบบเครือข่ายป้อนไปข้างหน้าแบบหลายชั้น มีผลกระทบอย่างยิ่งต่อการหาคำตอบสุดท้ายของระบบเครือข่ายประสาทเทียม โดยทั่วไปแล้วจะให้ค่าเริ่มเป็นค่าสุ่มในวงแคบ (Small random) การกำหนดให้น้ำหนักของระบบเท่ากัน ไม่สามารถทำการสอนให้มีความเหมาะสมต่อการแก้ปัญหาได้ และค่าเริ่มต้นไม่สามารถทำให้กว้างเกินไปได้ เพราะอาจจะเป็นผลให้ฟังก์ชันซิกมอยด์เกิดการอิ่มตัวตั้งแต่เริ่มสอน และจะเป็นผลให้การเรียนรู้ของระบบหยุดที่ โลคอลมินิมา (Local minima) หรือ อาจจะทำให้เกิดเส้นเรียบแบบ บริเวณใกล้กับจุดเริ่มต้น วิธีหนึ่งในการเลือกค่าเริ่มต้นที่ดีสำหรับระบบคือ ให้เลือกในช่วง $[-3\sqrt{k_i}, 3\sqrt{k_i}]$ โดยที่ k_i คือจำนวนของข้อมูลที่เชื่อมต่อเข้ากับหน่วยประมวลผลนั้นๆ ซึ่งเป็นคำแนะนำจากเอกสารอ้างอิงของ Wessles, L.F.A., Barnard, E [18]

ข.) ค่าคงที่การเรียนรู้ (Learning constant) อีกปัจจัยหนึ่งที่มีผลกระทบอย่างมากต่อประสิทธิภาพการหาคำตอบของวิธีการเรียนรู้แบบแพร่กลับอย่างเด่นชัด คือค่าคงที่การเรียนรู้ η ไม่มีค่าคงที่การเรียนรู้ใดที่เหมาะสมต่อการเรียนรู้ในปัญหาที่ต่างกัน และค่าคงที่การเรียนรู้นั้น โดยปรกติแล้วจะทำการเลือกจากการทดลองโดยเฉพาะในแต่ละปัญหานั้นๆ ค่าคงที่การเรียนรู้มากๆ สามารถทำให้ปัญหาหาคำตอบได้เร็วแต่ก็อาจจะเป็นผลให้มีการปรับแก้ค่าน้ำหนักที่แกว่งหรือเคลื่อนไปจากค่าที่ต้องการ ในขณะที่เดียวกันค่าคงที่การเรียนรู้ที่น้อยมากๆ อาจจะทำให้เกิดปัญหาการเรียนรู้ที่ลู่เข้าช้า หรือ จะเกิดการหยุดที่โลคอลมินิมาได้โดยง่าย ค่าคงที่การเรียนรู้ในช่วงจาก 0.001 ถึง 10 เป็นค่าที่ใช้ในการแก้ปัญหาแบบแพร่กลับแล้วประสบความสำเร็จจำนวนมาก อนึ่งปัญหาอื่นๆ นั้นอาจจะมีค่าคงที่การเรียนรู้ที่ดีสำหรับการเรียนรู้ในช่วงต้น แต่ค่านี้ อาจจะเป็นค่าที่ไม่ดีนักในช่วงปลายๆ ของการเรียนรู้ ดังนั้น วิธีการที่มีประสิทธิภาพอย่างหนึ่งในการเรียนรู้คือการใช้ค่าการเรียนรู้แบบปรับค่าได้ เช่นวิธีการหยั่งรู้ (Intuitive method) ซึ่งเป็นวิธีการตรวจหาค่าของฟังก์ชันต้นทุนว่ามีการเพิ่มหรือลดลงจากการเปลี่ยนค่าน้ำหนัก หากค่าในฟังก์ชันต้นทุนไม่มีการลดลง อาจหมายความว่าเกิดการแกว่งของการเรียนรู้ซึ่งจะต้องพยายามทำการลดค่าคงที่การเรียนรู้ลง หากค่ามีการลดลงน้อยๆ ในหลายขั้นของการคำนวณแสดงว่าอาจมีการเปลี่ยนแปลงที่น้อยมากเกินไปซึ่งจะต้องพยายามเพิ่มค่าการเรียนรู้ หรืออาจจะใช้วิธีซึ่งให้อัตราการเปลี่ยนแปลงของค่าคงที่การเรียนรู้แปรผกผันกับอัตราการเปลี่ยนแปลงสัญญาณความผิดพลาด กล่าวคือ ให้ค่าคงที่การเรียนรู้เพิ่มขึ้น

เมื่อมีอัตราการเปลี่ยนแปลงสัญญาณผิดพลาดน้อยกว่าศูนย์อย่างสม่ำเสมอ และ ให้ค่าคงที่การเรียนรู้ลดลง เมื่ออัตราการเปลี่ยนแปลงสัญญาณผิดพลาดมากกว่าศูนย์ และหากอัตราการเปลี่ยนแปลงสัญญาณผิดพลาดคงที่ ให้ใช้ค่าเดิมต่อไป หรืออาจจะใช้วิธีที่เรียกว่า เดลต้า-บาร์-เดลต้า (Deta-Bar-Delta) มีวิธีการเปลี่ยนค่าดังนี้

$$\Delta \eta(t+1) = \begin{cases} +a & \text{if } \bar{\lambda}(t-1)\lambda(t) > 0 \\ -b\eta(t) & \text{if } \bar{\lambda}(t-1)\lambda(t) < 0 \\ 0 & \text{Otherwise} \end{cases} \quad (2.24)$$

ซึ่ง

$$\lambda(t) = \frac{\partial E}{\partial w_{ij}} \text{ และ } \bar{\lambda}(t) = (1-c)\lambda(t) + c\bar{\lambda}(t-1), c \in [0, 1]$$

ค.) ฟังก์ชันต้นทุน ที่กล่าวมาข้างต้นนั้นอยู่ในรูปแบบกำลังสอง (Quadratic) แต่อย่างไรก็ตาม รูปแบบของฟังก์ชันต้นทุนนี้ไม่ใช่รูปแบบเดียวที่สามารถใช้งานได้ กล่าวคือในส่วนของการกำลังสองของสัญญาณผิดพลาด $(d_i - a(net_i))^2$ สามารถแทนที่ด้วยสมการในรูปแบบอื่นๆได้ กล่าวได้ว่าเราสามารถทำการเปลี่ยนแปลงการปรับเปลี่ยนค่าน้ำหนักโดยการปรับเพียงแค่ส่วนต่างสัญญาณผิดพลาดนี้โดยที่ส่วนอื่นๆคงเดิม โดยส่วนมากแล้วฟังก์ชันต้นทุนที่ใช้ในออร์มแบบ L_p (L_p Norm, $1 \leq p < \infty$) เป็นที่นิยมใช้โดยทั่วไปเนื่องจากมีข้อดีเนื่องจากความง่ายทางคณิตศาสตร์ซึ่งอยู่ในรูป

$$E = \frac{1}{p} \sum_i (d_i - y_i)^p \quad (2.25)$$

กล่าวคือ สมการรูปแบบกำลังสองถือเป็นออร์มแบบ L_2 ซึ่งเป็นรูปแบบที่ใช้กันอย่างกว้างขวางเพราะความเรียบง่ายของสมการ ให้พิจารณาออร์มแบบ L_∞ หรือเรียกว่า นอร์มแบบเชบิเชฟ (Chebyshev norm) ซึ่งนอร์มแบบเชบิเชฟ นี้มีรูปแบบคือ

$$E^\infty = \sup_i |d_i - y_i| \quad (2.26)$$

โดยที่ฟังก์ชัน $\sup$ ให้มีหน้าที่เลือกเอาส่วนประกอบที่มากที่สุดของเวกเตอร์ ซึ่งเป็นนัยว่าส่วนของเวกเตอร์ที่มากที่สุดเท่านั้นที่จะนำมาทำการวัด สำหรับส่วนประกอบอื่นๆจะนำมาคำนวณ จากการที่กำหนดฟังก์ชันราคาแบบนี้จะทำให้สามารถกำหนดสมการของสัญญาณผิดพลาด δ_{oi} ของชั้นนอกสุดได้เป็น

$$\delta_{oi} = -\frac{\partial E^\infty}{\partial net_i} = \begin{cases} 0 & \text{if } i \neq i^* \\ a'(net_{i^*}) \operatorname{sgn}(d_{i^*} - y_{i^*}) & \text{if } i = i^* \end{cases} \quad (2.27)$$

โดยที่ i^* เป็นดัชนีของส่วนประกอบที่มากที่สุดของเวกเตอร์ผลลัพธ์สัญญาณแบบนี้บ่งชี้ว่าการแพร่กลับของสัญญาณผิดพลาดจะมีมาจากเพียงโหนดที่มีการกระตุ้นมากที่สุดเพียงโหนดเดียวเท่านั้น

ง.) โมเมนตัม (Momentum) เนื่องจากในการเรียนรู้แบบแพร่กลับนี้เป็นการเรียนรู้แบบปรับค่าความผิดพลาดไปเรื่อยๆจนเข้าสู่ช่วงที่เหมาะสม หรือยอมรับได้ จึงนำมาใช้งาน สามารถอธิบายในทางคณิตศาสตร์ว่าเป็นการเคลื่อนหาค่าตำแหน่งที่ต่ำที่สุดของพื้นผิวค่าความผิดพลาด หรือที่เรียกว่า คำตอบสุดท้าย (Ultimate solution) แต่อย่างไรก็ตาม ในปัญหาหนึ่งๆอาจจะมีช่วงที่พื้นผิวค่าความผิดพลาดลดลงสูงต่ำสลับกันไปในลักษณะหุบเขา ซึ่งไม่สามารถทราบล่วงหน้าได้เลยว่าส่วนของพื้นผิวจะมีลักษณะใด หากว่าขบวนการสอนระบบเครือข่ายไปหยุดในตำแหน่งที่ไม่ใช่ตำแหน่งต่ำสุดในพื้นที่ผิว หรือโลคอลมินิมาแล้ว คำตอบที่ได้จะไม่ใช่ว่าคำตอบสุดท้ายที่ต้องการ และการสอนในแบบแพร่กลับนี้มีการเคลื่อนที่มีแนวโน้มว่าสามารถติดที่บริเวณโลคอลมินิมาได้ และเพื่อทำการแก้ปัญหาดังกล่าว ในการสอนระบบเครือข่ายสามารถนำส่วนของสมการโมเมนตัมเข้ามารวมด้วยเมื่อมีการเปลี่ยนน้ำหนักภายในระบบเครือข่าย โดยสมการปรับแก้ น้ำหนักที่รวมโมเมนตัมคือ

$$\Delta w(t) = -\eta \nabla E(t) + \alpha \Delta w(t-1) \quad (2.28)$$

โดยที่ $\alpha \in [0, 1]$ ซึ่งเป็นตัวแปรที่เรียกว่าค่าคงที่โมเมนตัม ค่าที่นิยมใช้คือ 0.9

อย่างไรก็ตามการมีส่วนของโมเมนตัมอาจจะทำให้เกิดการส่ายในการเดินทางของวิธีการสอนแบบตัวอย่างต่อตัวอย่าง (Pattern by pattern) ซึ่งเป็นวิธีการสอนในงานวิจัยนี้บ้าง กล่าวคืออาจจะพบการแกว่งในกราฟค่าความผิดพลาดแต่อย่างไรก็ตาม การมีส่วนของโมเมนตัมจะช่วยให้แน่ใจได้ว่า การสอนจะไม่หยุดที่ส่วนที่เป็นโลคอลมินิมา

จ.) ตัวอย่างของการสอน (Training Samples) ในการสอนระบบเครือข่ายหนึ่งจำเป็นอย่างยั้งที่ต้องมีจำนวนตัวอย่างของการสอนมากเพียงพอต่อจำนวนข้อมูลขาเข้าของระบบเครือข่าย รวมไปถึงจะต้องมีการกระจายข้อมูลที่ดีพอสำหรับการสอน และข้อมูลที่นำมาสอนจำเป็นอย่างยั้งที่ต้องสื่อถึงสิ่งที่ต้องการ และข้อมูลที่นำมาสอนนั้นบรรจุเอาสาระสำคัญ (Feature) เอาไว้อีกประการหนึ่งคือลำดับของการใช้ตัวอย่างการสอน ในกรณีของการสอนที่มีลำดับคล้ายๆ กันเรื่อยๆ อาจจะทำให้ระบบเครือข่ายเกิดการลื่น การลื่น ตัวอย่างเช่นหากมีลำดับการสอนให้เลี้ยวซ้ายต่อเนื่องยาวนาน อาจจะทำให้ระบบเครือข่ายเกิดการแก้ไขให้เลี้ยวซ้ายได้เพียงอย่างเดียว ดังนั้นในงานวิจัยนี้จะทำการสอนโดยใช้วิธี สุ่มตัวอย่างของการสอนแบบตัวอย่างต่อตัวอย่างเป็นหลัก

2.3 การประมวลผลภาพ

เนื่องจากในงานวิจัยนี้จะใช้ภาพที่รับจากกล้องเพื่อให้ส่วนของประสาทเทียมตัดสินใจ แต่อย่างไรก็ตามการรับภาพที่เป็นภาพที่มีจำนวนสีจริง เป็นการรับภาระแก่การคำนวณมากเกินไป ดังนั้นในงานวิจัยนี้จึงเลือกใช้ภาพที่มีลักษณะเป็นโทนเทาขนาด 8 บิต ส่งผลให้จำนวนของข้อมูลขาเข้าลดลง 3 เท่า เมื่อเปรียบเทียบกับการใช้ค่าความเข้มข้น (Intensity) ของแสงสีแดง เขียว และน้ำเงิน

อนึ่งความมุ่งหมายในงานวิจัยนี้คือเพื่อให้ระบบเครือข่ายประสาทเทียมสามารถทำการตัดสินใจบังคับเลี้ยวได้ถูกต้อง ดังนั้นการใช้ภาพโทนเทาเป็นข้อมูลเข้าย่อมเพียงพอต่อการตัดสินใจ อย่างไรก็ตามถึงแม้ว่าจะสามารถลดข้อมูลลงได้ 3 เท่า แต่การนำภาพที่ได้จากการจับภาพผ่านอุปกรณ์จับภาพเข้ามาประมวลผลโดยตรง ก็อาจจะส่งผลให้มีการคำนวณที่มากเกินไปจนจำเป็นจะต้องมีการลดขนาดภาพที่จะใช้ในการคำนวณลงไปด้วย

2.3.1. การแปลงภาพสีสู่ภาพโทนเทา

ในการแปลงภาพสีไปสู่ภาพโทนเทาจะใช้ วิธีคำนวณส่วนประกอบความเข้มข้นมาตรฐาน (Standard intensity components) มีวิธีการคือทำการคัดลอกส่วนของหน่วยความจำที่ทำการบรรจุเอาข้อมูลภาพสี จากนั้นจึง นำข้อมูลความเข้มข้นของสีแม่ทั้ง 3 คือ แดง เขียว และน้ำเงินเข้ามาคำนวณหาค่าความเข้มข้นของภาพโทนเทาโดยใช้สมการค่าเฉลี่ยมาตรฐานสหพันธ์โทรคมนาคมนานาชาติ (International Telecommunications Union, ITU) [15] มีสมการดังสมการ 2.29

$$I_{Gray} = [(222 \times IR) + (707 \times IG) + (71 \times IB)] \quad (2.29)$$

เมื่อ I_{Gray} คือ ค่าความเข้มข้นของโทนเทา

IR คือ ค่าความเข้มข้นของสีแดง

IG คือ ค่าความเข้มข้นของสีเขียว

IB คือ ค่าความเข้มข้นของสีน้ำเงิน

2.3.2 การลดขนาดภาพ

จะใช้วิธีการหาอัตราค่าการเปลี่ยนแปลงของขนาด ในทางด้านแนวตั้งและแนวนอนของภาพ และจากนั้นจึงทำการประมาณในช่วง (Interpolate) โดยจะทำจากแนวแกนบนไปหาแนวแกนตั้ง สำหรับค่าความเข้มข้นในแต่ละจุดจะหาจากการหาค่ากลางของความเข้มข้นของจุดที่อยู่ใกล้ที่สุด 4 จุด สำหรับรายละเอียดสามารถติดตามได้ในส่วนของซอร์สโค้ดในภาคผนวก