

บทที่ 3

การศึกษานิวรอลเน็ตเวิร์กสำหรับระบบควบคุมกราฟฟิกแบบบีพีซีเอ็น

ความนำ

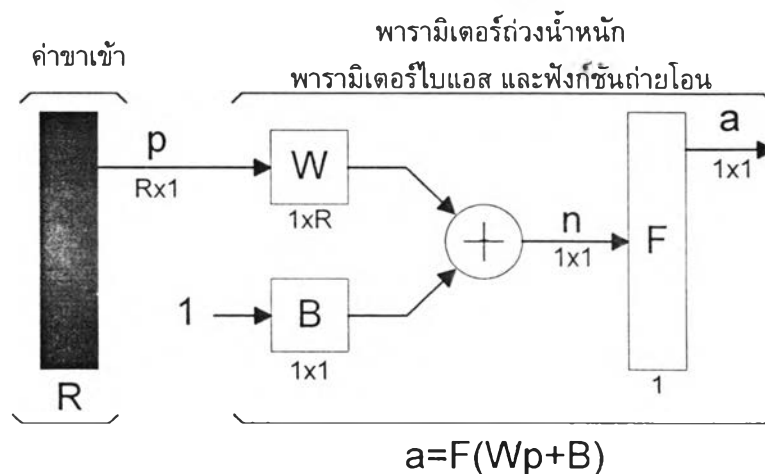
ในบทนี้จะกล่าวถึงการศึกษาการศึกษานิวรอลเน็ตเวิร์กแบบปรับพารามิเตอร์ถอยหลัง (Backpropagation Neural Network) ซึ่งจะถูกนำมาประยุกต์ในการทำนายค่ากราฟฟิก เพื่อใช้ในการควบคุมกราฟฟิกแบบบีพีซีเอ็น หัวข้อต่างๆที่จะนำเสนอมีดังนี้

- ลักษณะโดยทั่วไปของนิวรอลเน็ตเวิร์กแบบปรับพารามิเตอร์ถอยหลัง
- การกำหนดลักษณะที่เหมาะสมของนิวรอลเน็ตเวิร์กเพื่อการทำนายค่ากราฟฟิก
- ผลทดสอบจากการจำลองการทำงานในการควบคุมกราฟฟิกในระบบที่ศึกษา

3.1 ลักษณะโดยทั่วไปของนิวรอลเน็ตเวิร์กแบบปรับพารามิเตอร์ถอยหลัง

นิวรอลเน็ตเวิร์กเป็นอัลกอริทึมที่ได้ถูกนำมาประยุกต์ใช้ในการแก้ปัญหอย่างเป็นระบบเป็นครั้งแรกในช่วงปลายทศวรรษที่ 1950 และได้รับการพัฒนาอย่างกว้างขวางและต่อเนื่องตั้งแต่ช่วงประมาณปี 1970 จนกระทั่งปัจจุบัน ด้วยผลจากการพัฒนาทฤษฎีการเรียนรู้และโครงสร้างของโครงข่ายแบบใหม่ๆทำให้ นิวรอลเน็ตเวิร์กมีความสามารถในการแก้ปัญหาที่ซับซ้อนมากขึ้นและเรียนรู้ระบบได้อย่างมีประสิทธิภาพมากขึ้นด้วย

นิวรอลเน็ตเวิร์กประกอบขึ้นจากหน่วยพื้นฐานขนาดเล็กเรียกว่า 'นิวรอน' (Neuron) จำนวนหลายๆหน่วยมาต่อกันในลักษณะเป็นโครงข่าย ดังแสดงในรูปที่ 3.1

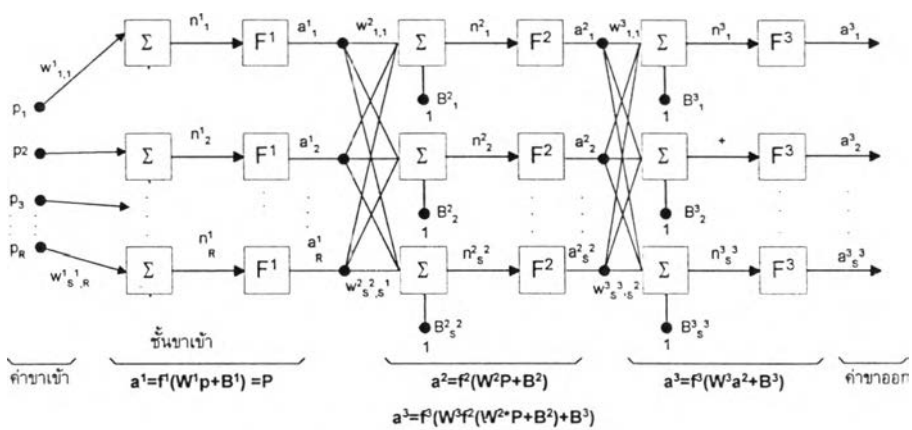


รูปที่ 3.1 นิวรอน

ส่วนประกอบที่สำคัญในนิวรอนได้แก่พารามิเตอร์ถ่วงน้ำหนัก (W - weight) พารามิเตอร์ไบแอส (B - bias) และฟังก์ชันถ่ายโอน (F- transfer function) ซึ่งการเลือกใช้ค่าพารามิเตอร์ต่างๆ และ ฟังก์ชันถ่ายโอน ขึ้นอยู่กับความเหมาะสมในการแก้ปัญหา ในการทำงานแต่ละนิวรอนจะสามารถให้ค่าขาออก (Output) ที่เหมาะสมจากค่าขาเข้า (Input) ได้โดยการปรับค่าของพารามิเตอร์ถ่วงน้ำหนัก (W - weight) และพารามิเตอร์ไบแอส (B - bias) ดังสมการที่ (3.1)

$$output = F(W * input + B) \tag{3.1}$$

การนำเอานิวรอนมาต่อกันเป็นโครงข่ายจะเพิ่มประสิทธิภาพการทำงานให้กับนิวรอนทำให้สามารถให้ค่าขาออกที่ซับซ้อนขึ้นตามที่ต้องการ และมีจำนวนพารามิเตอร์ที่สามารถปรับค่าได้เพิ่มขึ้น ดังรูปที่ 3.2 แสดงตัวอย่างนิวรอนซึ่งประกอบขึ้นเป็นนิวรอลเน็ตเวิร์ก (Cichocki, et. al, 1996)



รูปที่ 3.2 ตัวอย่างนิวรอลเน็ตเวิร์ก

จากรูปที่ 3.2 แสดงให้เห็นว่า ค่าขาเข้า (Input) จะถูกส่งผ่านมายังนิวรอลเน็ตเวิร์กชั้นขาเข้า (Input layer) ซึ่งทำหน้าที่ส่งผ่านค่าขาเข้าไปยังนิวรอลเน็ตเวิร์กชั้นที่อยู่ถัดเข้าไปซึ่งเรียกว่าชั้นซ่อนตัว (Hidden layer) โดยที่นิวรอลเน็ตเวิร์กชั้นขาเข้านี้ไม่ได้ทำหน้าที่ในการคำนวณแต่อย่างใด กล่าวคือ พารามิเตอร์ถ่วงน้ำหนักเป็นเมตริกซ์เอกลักษณ์ จำนวนนิวรอนมีค่าเท่ากับจำนวนสมาชิกในเวกเตอร์ขาเข้า ค่าของพารามิเตอร์ไบแอสทุกตัวมีค่าเป็นศูนย์ และฟังก์ชันถ่ายโอนเป็นฟังก์ชันเชิงเส้นดังสมการที่ (3.2)

$$f(x) = x \tag{3.2}$$

ดังนั้นในหนังสือด้านนิวรอลเน็ตเวิร์กบางเล่ม (Martin, et. al, 1996) จึงละเลยไม่กล่าวถึงนิวรอลเน็ตเวิร์กชั้นขาเข้า แต่จะแสดงชั้นซ่อนตัวที่ 1 เป็นชั้นนอกสุดของนิวรอลเน็ตเวิร์กนั้นแทน

นิวรอลเน็ตเวิร์กซึ่งอยู่ในชั้นถัดๆเข้าไปจะรับค่าจากค่าขาออกจากชั้นที่อยู่ก่อนหน้า และทำการคำนวณแล้วส่งผ่านไปจนกระทั่งได้ค่าขาออกที่ต้องการในที่สุด

กฎการเรียนรู้พื้นฐานของนิวรอลเน็ตเวิร์กที่สำคัญ คือการปรับค่าของพารามิเตอร์ถ่วงน้ำหนัก และพารามิเตอร์ไบแอสในลักษณะแบบถอยหลัง (Martin, et. al, 1996) ซึ่งสามารถทำได้โดยการเลือกค่าขาเข้าและค่าขาออกที่ถูกต้องจากค่าขาเข้านั้นๆเก็บเป็นชุดข้อมูลสำหรับสอน (Train set) ให้แก่นิวรอลเน็ตเวิร์ก เพื่อให้นิวรอลเน็ตเวิร์กประมาณความสัมพันธ์ระหว่างค่าขาเข้าและค่าขาออกได้อย่างถูกต้อง

กำหนดให้ค่าของฟังก์ชันจุดประสงค์ J (Objective function) เป็นเป้าหมายที่ต้องการจะทำให้มีค่าน้อยที่สุด คือผลรวมของกำลังสองของผลต่างระหว่างค่าจริง (y) และค่าประมาณที่ได้จากนิวรอลเน็ตเวิร์ก (\hat{y}) ซึ่งมีลักษณะเป็นผลรวมของค่ากำลังสองของความผิดพลาด (SSE - Sum Square Error)

$$J = SSE = \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (3.3)$$

การปรับค่าของพารามิเตอร์ถ่วงน้ำหนัก (W) และพารามิเตอร์ไบแอส (B) ไปยังตำแหน่งที่เกรเดียนของฟังก์ชันจุดประสงค์เทียบกับพารามิเตอร์นั้นมีค่าต่ำที่สุด สามารถทำได้ดังความสัมพันธ์ตามสมการที่ (3.4)

$$\begin{aligned} W_{new} &= W_{old} - \lambda \frac{\partial J}{\partial W_{old}} \\ B_{new} &= B_{old} - \lambda \frac{\partial J}{\partial B_{old}} \end{aligned} \quad (3.4)$$

โดยที่ λ คืออัตราการเรียนรู้ ซึ่งในบางอัลกอริทึมการเรียนรู้จะสามารถปรับค่าอัตราการเรียนรู้ระหว่างการเรียนรู้ได้ เพื่อให้ค่าของฟังก์ชันจุดประสงค์ลดต่ำลงได้เร็วขึ้น

การเลือกค่าเริ่มต้นของพารามิเตอร์ถ่วงน้ำหนักและพารามิเตอร์ไบแอส ในทางปฏิบัติจะใช้การสุ่มค่าเริ่มต้นของพารามิเตอร์ถ่วงน้ำหนักและพารามิเตอร์ไบแอสเป็นจำนวนจริงน้อยๆอยู่ในช่วงระหว่าง -1 ถึง +1

ในแต่ละรอบการคำนวณจะทำการคำนวณค่าประมาณที่ได้จากนิวรอลเน็ตเวิร์ก (\hat{y}) และนำมาคำนวณค่าฟังก์ชันจุดประสงค์ตามสมการที่ (3.3) ถ้าหากค่าของฟังก์ชันจุดประสงค์ยังคงมากกว่าค่าความผิดพลาดสูงสุดที่ยอมรับได้ จะทำการคำนวณปรับพารามิเตอร์ถ่วงน้ำหนักและพารามิเตอร์ไบแอสหนึ่งครั้ง โดยทำการปรับพารามิเตอร์ถ่วงน้ำหนักและพารามิเตอร์ไบแอสที่ชั้นส่งข้อมูลขาออกก่อน หลังจากนั้นจึงทำการปรับพารามิเตอร์ในชั้นถัดเข้ามาจนกระทั่งถึงชั้นส่งข้อมูลขาเข้า และนำค่าของพารามิเตอร์ถ่วงน้ำหนักและพารามิเตอร์ไบแอสชุดใหม่ไปเป็นค่าเริ่มต้นสำหรับการเรียนรู้ในวงรอบการทำงานรอบถัดไปในลักษณะ

ของการวนซ้ำ (Iteration) เมื่อได้ค่าของฟังก์ชันจุดประสงค์ต่ำกว่าค่าความผิดพลาดสูงสุดที่ยอมรับได้ แล้วจึงเก็บชุดของค่าพารามิเตอร์ถ่วงน้ำหนักและพารามิเตอร์ไบแอสนั้นไว้เพื่อใช้ประมาณค่าขาออกจากค่าขาเข้าที่ทราบค่าจริงต่อไป

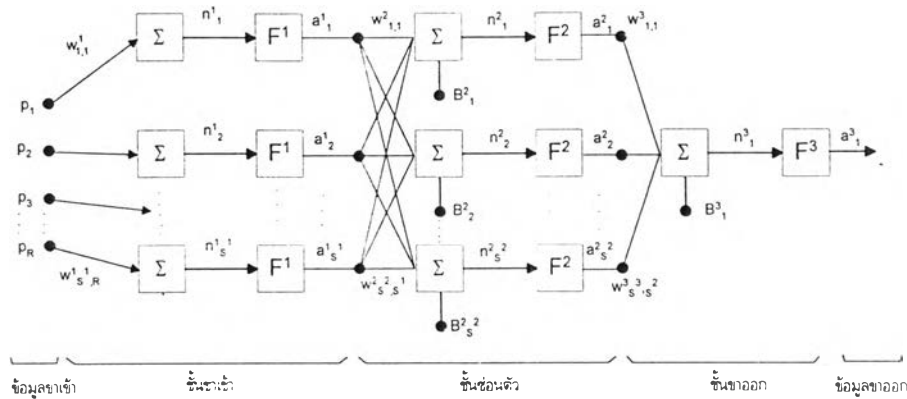
ในทางปฏิบัติแล้วการปรับพารามิเตอร์แบบถอยหลังด้วยวิธีพื้นฐานที่กล่าวมา จะเกิดปัญหาในการเข้าใกล้ค่าที่เป็นคำตอบซ้ำ และเมื่อพิจารณาในพื้นที่ผิวค่าผิดพลาด (Error surface) จะเกิดการแกว่งของกราฟเส้นทางการเดินของค่าฟังก์ชันจุดประสงค์เมื่อเข้าใกล้จุดที่เป็นคำตอบ จึงได้มีการพัฒนาทฤษฎีการเรียนรู้เพื่อแก้ไขปัญหาดังกล่าวขึ้น ที่สำคัญได้แก่ วิธีการใช้โมเมนตัม (Momentum), วิธีการเปลี่ยนแปลงอัตราการเรียนรู้, วิธีคอนจูเกตเกรเดียนต์ (Conjugate Gradient) และอัลกอริทึมของลีเวนเบิร์ก-มาร์ควาดท์ (Levenberg-Marquardt Algorithm) เป็นต้น ดังรายละเอียดตามเอกสารอ้างอิง (Martin, et. al, 1996)

3.2 การกำหนดลักษณะที่เหมาะสมของนิวรอลเน็ตเวิร์กเพื่อการทำนายกราฟฟิค

เมื่อพิจารณาสมการแสดงลักษณะเฉพาะของแหล่งกำเนิดกราฟฟิคทั้ง 3 แบบ ได้แก่ แหล่งกำเนิดกราฟฟิคแบบซีบีอาร์ วีบีอาร์ และเอบีอาร์ ดังสมการที่ (2.17), (2.22) และ (2.25) ตามลำดับ ลักษณะความสัมพันธ์ในเชิงเวลาระหว่างอัตราการส่งข้อมูล (หรือปริมาณเซลล์ข้อมูลที่เกิดขึ้นเมื่อพิจารณาในช่วงเวลาคงที่หนึ่งๆ) ณ เวลาต่างๆกันเมื่อพิจารณาแล้วมีความสัมพันธ์ต่อกันในลักษณะไม่เป็นเชิงเส้น นอกจากนี้ผลรวมของปริมาณข้อมูลหลายประเภทจำนวนหลายๆแหล่ง ยังส่งผลให้ความซับซ้อนระหว่างความสัมพันธ์ในเชิงเวลาของปริมาณข้อมูลที่เข้าสู่เอทีเอ็มสวิตช์มีมากขึ้นด้วย อย่างไรก็ตามในทางทฤษฎีแล้วการใช้ตัวทำนายค่าแบบนิวรอลเน็ตเวิร์กที่มีฟังก์ชันถ่ายโอนแบบไม่เชิงเส้นที่ผ่านการเรียนรู้จากชุดข้อมูลสำหรับสอนที่เหมาะสมและได้ค่าฟังก์ชันเป้าหมายที่ต่ำพอ ควรจะสามารถทำการประมาณค่าในอนาคตที่มีความซับซ้อนดังกล่าวได้ดีกว่าการประมาณด้วยอัลกอริทึมอาร์แอลเอสซึ่งเป็นอัลกอริทึมแบบเชิงเส้น (Pandit, et. al, 1983) ดังรายละเอียดที่จะได้แสดงต่อไป

3.2.1 โครงสร้างของนิวรอลเน็ตเวิร์ก

ในงานวิจัยนี้เลือกใช้นิวรอลเน็ตเวิร์กที่มีจำนวน 3 ชั้น ซึ่งในงานวิจัยอื่นๆเกี่ยวกับการทำนายข้อมูลอนุกรมเชิงเวลาด้วยนิวรอลเน็ตเวิร์ก (Tarraf, et. al, 1993), (Atsushi, et. al, 1990) ได้มีการศึกษาแล้วให้ผลในการทำนายที่น่าพอใจ นิวรอลเน็ตเวิร์กแบบ 3 ชั้นที่ใช้ในงานวิจัยนี้มีโครงสร้างเป็นดังรูปที่ 3.3



รูปที่ 3.3 โครงสร้างนิวรอลเน็ตเวิร์กที่ใช้ในงานวิจัยนี้

รูปแบบของนิวรอลเน็ตเวิร์กชั้นขาเข้าจะเป็นดังที่อธิบายในหัวข้อที่ 3.1 และฟังก์ชันถ่ายโอนที่ใช้ในการวิจัยนี้ใช้ฟังก์ชันถ่ายโอนในชั้นซ่อนตัวและชั้นขาออกของนิวรอลเน็ตเวิร์กเป็นฟังก์ชันไม่เชิงเส้นแบบลือกซิกมอยด์ ดังในสมการที่ (3.5)

$$f(x) = \frac{1}{1 + e^{-x}} \quad (3.5)$$

จำนวนนิวรอนในชั้นขาเข้าและจำนวนนิวรอนในชั้นขาออกขึ้นกับรูปแบบของการทำนายค่า ซึ่งในการควบคุมทราฟฟิกในงานวิจัยนี้ใช้รูปแบบการควบคุมแบบบีพีซีเอ็นเช่นเดียวกับในงานวิจัยของ Hu. ซึ่งทำนายค่า $Q(t)$ เพื่อใช้เป็นข้อมูลย้อนกลับไปยังส่วนควบคุมอัตราการส่งข้อมูลของแหล่งกำเนิดทราฟฟิกแบบเอบีอาร์ให้ปรับอัตราการส่งข้อมูลได้อย่างเหมาะสม ซึ่งการทำนายค่า $Q(t)$ ในงานวิจัยนี้สามารถอธิบายได้ดังนี้

การสอนนิวรอลเน็ตเวิร์ก

เกิดจากการตั้งสมมติฐานให้ค่า Q ในอนาคต f หน่วยเวลาขึ้นกับค่า Q ในอดีตตั้งแต่เวลาปัจจุบันย้อนไปจำนวน n ค่า ดังสมการที่ (3.6)

$$Q(t + f) = NN[Q(t), Q(t-1), Q(t-2), \dots, Q(t-n+1)] \quad (3.6)$$

แต่เนื่องจากค่าขาออกจากนิวรอลเน็ตเวิร์กที่ใส่ฟังก์ชันถ่ายโอนบางฟังก์ชันเช่น ฟังก์ชันลือกซิกมอยด์ ดังในสมการที่ (3.15) มีค่าขาออกอยู่ระหว่าง $(0,1)$ ซึ่งไม่ครอบคลุมค่าที่เป็นไปได้ของ $Q(t + f)$ ซึ่งมีค่าอยู่ในช่วง $[0,100]$ ตามความจุของบัฟเฟอร์ขาออกของเอทีเอ็มสวิตช์ ดังนั้นค่าขาออกจากนิวรอลเน็ตเวิร์กใน

ส่วนของชุดสำหรับการสอนจึงต้องทำให้เป็นค่าปกติ (Normalized) ด้วยค่าสูงสุดที่เป็นไปได้ (100 เซลล์) ก่อนที่จะนำไปแทนในด้านขวามือของสมการที่ (3.6) เพื่อสร้างชุดข้อมูลสำหรับการสอน ดังสมการที่ (3.7)

$$[Q(t + f) / 100] = NN[Q(t), Q(t - 1), Q(t - 2), \dots, Q(t - n + 1)] \quad (3.7)$$

สมการที่ (3.7) แสดงให้เห็นว่าชุดข้อมูลสอนนิรอลเน็ตเวิร์กทำได้โดยการป้อนค่าขาเข้าซึ่งประกอบด้วยค่า $Q(t), Q(t - 1), \dots, Q(t - n + 1)$ จำนวน n ตัว และกำหนดให้ค่าขาออกเป็นค่า $Q(t + f)$ ที่ถูกทำให้เป็นค่าปกติ

การทำนายด้วยนิรอลเน็ตเวิร์ก

นิรอลเน็ตเวิร์กที่ผ่านการเรียนรู้ความสัมพันธ์ในสมการที่ (3.7) จะถูกนำมาใช้ทำนายค่า $Q(t + f)$ (ซึ่งแทนด้วยสัญลักษณ์ $\hat{Q}(t + f)$) ในอนาคตที่ไม่ทราบค่า ด้วยข้อมูลจากค่า $Q(t), Q(t - 1), \dots, Q(t - n + 1)$ ซึ่งทราบค่า ณ เวลาปัจจุบัน t ดังสมการที่ (3.8)

$$[\hat{Q}(t + f) / 100] = NN[Q(t), Q(t - 1), Q(t - 2), \dots, Q(t - n + 1)] \quad (3.8)$$

หรือ
$$\hat{Q}(t + f) = 100 * NN[Q(t), Q(t - 1), Q(t - 2), \dots, Q(t - n + 1)] \quad (3.9)$$

สมการที่ (3.9) แสดงให้เห็นว่าค่า $\hat{Q}(t + f)$ สามารถทำนายได้จากการป้อนค่าจริงของ $Q(t), Q(t - 1), \dots, Q(t - n + 1)$ จำนวน n ตัวเข้าสู่นิรอลเน็ตเวิร์ก ซึ่งผ่านการเรียนรู้ที่เหมาะสม และนำค่าขาออกที่ได้จากนิรอลเน็ตเวิร์กมาคูณด้วยค่าที่ทำให้เป็นค่าปกติ ดังนั้นการทำนายค่าด้วยวิธีนี้ จำนวนนิรอนในชั้นขาเข้าของนิรอลเน็ตเวิร์กจะมีค่าเป็น n และ จำนวนนิรอนในชั้นขาออกจะมีจำนวนหนึ่งนิรอน ในส่วนจำนวนนิรอนของชั้นซ่อนตัวนั้นจะทำการจำลองการทำงานเพื่อหาค่าที่เหมาะสม ดังจะได้นำเสนอต่อไป

3.2.2 การจำลองการทำงานเพื่อหาค่าพารามิเตอร์ของนิรอลเน็ตเวิร์กที่เหมาะสม

การเลือกใช้ค่าพารามิเตอร์ของนิรอลเน็ตเวิร์กเพื่อใช้ในงานวิจัยขั้นถัดไป สามารถทำได้โดยทำการจำลองการทำงานเพื่อเปรียบเทียบการเรียนรู้ของนิรอลเน็ตเวิร์กที่มีค่าพารามิเตอร์ต่างๆกัน ค่าพารามิเตอร์ที่สนใจศึกษาได้แก่


- จำนวนรอบการคำนวณ (Iteration) ต่อการลดลงของค่าฟังก์ชันจุดประสงค์
- ขนาดของชุดข้อมูลที่ใช้ทำการสอน (p)
- จำนวนชุดข้อมูลที่ใช้ทำการสอน (s)

- จำนวนนิรอนในชั้นซ้อนตัว (n)
- ช่วงเวลาในอนาคตที่ต้องการทำนาย (f)

ดังนั้นในหัวข้อนี้จะได้ทำการศึกษาในรายละเอียดถึงพารามิเตอร์ที่เกี่ยวข้องกับการทำนายค่าด้วยนิรอลเน็ตเวิร์ก โดยมีข้อกำหนดต่างๆลงไปเป็นกรณีย่อยๆ ตามลำดับดังนี้

- 1) เลือกค่าช่วงเวลาในอนาคตที่ต้องการทำนาย (f) มาหนึ่งค่า (ซึ่งค่า f จะเป็น 5, 10, 20, 40, 60, หรือ 80 หน่วยเวลา ซึ่งครอบคลุมช่วงเวลาที่ต้องการทำนายค่าในการศึกษาทั้งหมด)
- 2) ที่แต่ละค่า f เลือกจำนวนชุดข้อมูลสำหรับทำการสอนนิรอลเน็ตเวิร์ก (s) มาหนึ่งค่า (ซึ่งจะทำการจำลองการทำงานที่ค่า s เป็น 3,000 6,000 9,000 หรือ 12,000 ชุดข้อมูล)
- 3) ที่แต่ละค่า s เลือกค่าจำนวนข้อมูล $Q(t)$ ในอดีตที่นำมาทำนายค่า $Q(t+f)$ ในแต่ละชุดข้อมูลสำหรับทำการสอนนิรอลเน็ตเวิร์กมาหนึ่งค่า (p) (โดยจะทำการจำลองการทำงานที่ค่าต่างๆ ซึ่งสัมพันธ์กับค่า f ในกรณีต่างๆ ดังรายละเอียดในผลการจำลองการทำงาน)

การเลือกชุดข้อมูลสำหรับทำการสอนสามารถแสดงได้ดังรูปที่ 3.4



รูปที่ 3.4 การสร้างชุดข้อมูลสำหรับทำการสอน


ชุดข้อมูลสำหรับทำการสอนแต่ละชุดจะถูกเลือกมาจากปริมาณกราฟิกที่มีความต่อเนื่องกันโดยการเลื่อนบริเวณช่วงกราฟิกที่สร้างชุดข้อมูลไปที่ละหนึ่งหน่วยเวลา จนกระทั่งผลรวมของจำนวนชุดข้อมูลได้ s ชุดข้อมูลตามต้องการ

4) ที่แต่ละค่า p ทำการเปลี่ยนค่าจำนวนนิวรอนในชั้นซ่อนตัวของนิวรอลเน็ตเวิร์ก (n) เพื่อหาค่าผลรวมความผิดพลาดกำลังสองในการสอนนิวรอลเน็ตเวิร์ก (SSE) (โดยจะทำการจำลองการทำงานที่ค่า n ระหว่าง 2 ถึง 20 นิวรอนตามแต่กรณี)


- 5) ที่แต่ละค่า n ทำการคำนวณรอบ (iterate) จนกว่าค่า SSE ลดลงน้อยกว่า 1% ของค่า SSE สุดท้ายที่ได้จากการคำนวณรอบก่อน

ผลการจำลองการทำงานบางส่วนจะแยกนำเสนอในภาคผนวก และนำเสนอตัวอย่างผลการจำลองการทำงานบางส่วนในเนื้อหาส่วนนี้ดังนี้

ตัวอย่างผลการจำลองการทำงาน



รูปที่ 3.5 ความสัมพันธ์ระหว่างค่าผลรวมความผิดพลาดกำลังสอง (SSE) และจำนวนรอบการคำนวณที่ค่าพารามิเตอร์ $f=5$, $s=3000$, $p=4$, $n=2$




รูปที่ 3.6 ความสัมพันธ์ระหว่างค่าผลรวมความผิดพลาดกำลังสอง (SSE) และจำนวนรอบการคำนวณ ที่ค่าพารามิเตอร์ $f=5$, $s=3000$, $p=6$, $n=4$

ผลการจำลองการทำงานจากรูปที่ 3.5 และรูปที่ 3.6 แสดงให้เห็นว่า ที่จุดเริ่มต้นของการคำนวณ ครั้งแรกค่าของ SSE จะมีค่าสูงที่สุดและลดลงอย่างรวดเร็วในช่วงการคำนวณ 5000 รอบแรกโดยประมาณ และลดลงอย่างช้าจนกระทั่งเกือบคงที่ในที่สุด ซึ่งในบางกรณีที่จำลองการทำงานที่ค่าพารามิเตอร์อื่นๆ ค่า SSE อาจลดลงต่ำลงจนผ่านข้อกำหนดในการจำลองการทำงาน (ข้อที่ 5) ก่อนการคำนวณ 10,000 รอบ อย่างไรก็ตามเพื่อความสะดวกในงานวิจัยจึงได้ทำการคำนวณจนกระทั่งครบ 10,000 รอบในทุกกรณี


เนื่องจากการจำลองการทำงานนี้ ค่า SSE ที่ได้จากการคำนวณในแต่ละกรณีจะไม่สามารถเปรียบเทียบกันได้โดยตรงเนื่องจากค่า SSE แปรผันตรงอยู่กับจำนวนชุดข้อมูลสำหรับทำการสอนนิเวรอลเน็ตเวิร์ก (s) ดังนั้นเพื่อความสะดวกในการเปรียบเทียบผลการจำลองการทำงาน จึงได้ทำการคำนวณค่า SSE เป็นค่าเฉลี่ยความผิดพลาดกำลังสอง (MSE) ดังสมการที่ (3.10)

$$MSE = \frac{SSE}{s} \quad (3.10)$$

จากนั้นได้นำค่า MSE ในแต่ละกรณี (ที่ค่า f และ s เดียวกัน) มาเปรียบเทียบกันดังกราฟรูปที่ 3.7 และรูปที่ 3.8




รูปที่ 3.7 เปรียบเทียบค่าเฉลี่ยความผิดพลาดกำลังสอง (MSE) ที่จำนวนนิวรอนในชั้นซ่อนตัว (n) ต่างๆกัน ที่ค่าพารามิเตอร์ $f=5$, $s=3000$, $p=2-12$, $n=2-14$




รูปที่ 3.8 เปรียบเทียบค่าเฉลี่ยความผิดพลาดกำลังสอง (MSE) ที่จำนวนนิวรอนในชั้นซ่อนตัว (n) ต่างๆกัน ที่ค่าพารามิเตอร์ $f=5$, $s=6000$, $p=2-12$, $n=2-14$


เมื่อนำผลกราฟแสดงความสัมพันธ์ระหว่างค่าเฉลี่ยความผิดพลาดกำลังสอง (MSE) ที่ต่ำที่สุดที่แต่ละค่าจำนวนชุดข้อมูลสำหรับการสอนนิรอลเน็ตเวิร์ก (s) ที่ค่า f ต่างๆ มาแสดงรวมกันได้ผลดังนี้




รูปที่ 3.9 เปรียบเทียบค่าเฉลี่ยความผิดพลาดกำลังสอง (MSE) ที่มีค่าต่ำที่สุด ที่แต่ละจำนวนชุดข้อมูล สำหรับการสอนนิรอลเน็ตเวิร์ก (s) ที่ค่าพารามิเตอร์ $f=5$




รูปที่ 3.10 เปรียบเทียบค่าเฉลี่ยความผิดพลาดกำลังสอง (MSE) ที่มีค่าต่ำที่สุด ที่แต่ละจำนวนชุดข้อมูล สำหรับการสอนนิรอลเน็ตเวิร์ก (s) ที่ค่าพารามิเตอร์ $f=10$




รูปที่ 3.11 เปรียบเทียบค่าเฉลี่ยความผิดพลาดกำลังสอง (MSE) ที่มีค่าต่ำที่สุด ที่แต่ละจำนวนชุดข้อมูล สำหรับการสอนนิวรอลเน็ตเวิร์ก (s) ที่ค่าพารามิเตอร์ $f=20$



รูปที่ 3.12 เปรียบเทียบค่าเฉลี่ยความผิดพลาดกำลังสอง (MSE) ที่มีค่าต่ำที่สุด ที่แต่ละจำนวนชุดข้อมูล สำหรับการสอนนิวรอลเน็ตเวิร์ก (s) ที่ค่าพารามิเตอร์ $f=40$




รูปที่ 3.13 เปรียบเทียบค่าเฉลี่ยความผิดพลาดกำลังสอง (MSE) ที่มีค่าต่ำที่สุด ที่แต่ละจำนวนชุดข้อมูล สำหรับการสอนนิวรอลเน็ตเวิร์ก (s) ที่ค่าพารามิเตอร์ $f=60$



รูปที่ 3.14 เปรียบเทียบค่าเฉลี่ยความผิดพลาดกำลังสอง (MSE) ที่มีค่าต่ำที่สุด ที่แต่ละจำนวนชุดข้อมูล สำหรับการสอนนิวรอลเน็ตเวิร์ก (s) ที่ค่าพารามิเตอร์ $f=80$

จากรูปที่ 3.8 ถึงรูปที่ 3.13 แสดงให้เห็นถึงแนวโน้มการเปลี่ยนแปลงของค่า MSE ตลอดช่วงค่าช่วงเวลาในขนาดที่ต้องการทำนาย (f) ที่กำหนดในงานวิจัย ซึ่งสามารถนำไปกำหนดค่าพารามิเตอร์ที่ส่งผลให้ค่า MSE ในการสอนนิเวรอลเน็ตเวิร์กมีค่าต่ำ ดังนี้


- 1) ค่า MSE ที่ต่ำที่สุด (เมื่อเปรียบเทียบที่ค่า f เดียวกัน) จะเกิดขึ้น เมื่อค่า f มีค่าสูงขึ้นจะเกิดที่ค่า s ที่มีค่าสูงขึ้นอย่างเหมาะสมด้วย ทั้งนี้เนื่องจากเมื่อช่วงเวลาทำนายในขนาด (f) มีค่าสูงขึ้นนิเวรอลเน็ตเวิร์กต้องการปริมาณชุดข้อมูลในอดีต (s) มากขึ้น เพื่อให้สามารถรู้จำข้อมูลได้อย่างถูกต้อง ซึ่งจากผลการจำลองการทำงานค่า s ที่เหมาะสมมีค่าอยู่ในช่วง 6000-9000 ชุดข้อมูล
- 2) ค่า MSE ที่ต่ำที่สุด (เมื่อเปรียบเทียบที่ค่า f เดียวกัน) จะเกิดขึ้นที่ค่าของ p ค่าหนึ่งซึ่งสัมพันธ์กับค่า f และ ค่า p ที่ทำให้ค่า MSE ต่ำที่สุดจะมีค่าสูงขึ้นเมื่อ f มีค่าสูงขึ้นด้วย ซึ่งจากผลการจำลองการทำงานแสดงให้เห็นได้ว่าค่า p ที่เหมาะสมจะมีค่ามากกว่าค่า f ในช่วงที่เหมาะสมค่าหนึ่ง ซึ่งเมื่อคำนวณค่าอัตราส่วนระหว่าง $\frac{P}{f}$ ในกรณีที่ให้ค่า MSE ต่ำที่สุด จะได้ผลดังรูปที่ 3.14



รูปที่ 3.15 ค่า $\frac{P}{f}$ ซึ่งให้ค่า MSE ต่ำที่สุดที่ค่า f ต่างๆ ตลอดช่วงค่าที่ศึกษา


จากรูปที่ 3.14 แสดงให้เห็นว่าที่ค่า f มีค่าน้อยกว่า 10 หน่วยเวลาแล้วค่าของอัตราส่วน $\frac{P}{f}$ ที่ให้ค่า MSE ในการสอนนิเวรอลเน็ตเวิร์กมีค่าต่ำประมาณ 1.2-1.6 และเมื่อค่า f มีค่าระหว่าง 10-80 หน่วยเวลาแล้วค่าของอัตราส่วน $\frac{P}{f}$ ที่ให้ค่า MSE ในการสอนนิเวรอลเน็ตเวิร์กมีค่าต่ำมีค่าประมาณ

- 3) จำนวนนิรอนในชั้นซ่อนตัว (n) ที่ให้ค่า MSE ต่ำที่สุดจะมีแนวโน้มเพิ่มขึ้นเมื่อค่า f มีค่าเพิ่มขึ้นด้วย ทั้งนี้เนื่องจากเมื่อช่วงเวลาทำนายในอนาคต (f) มีค่าสูงขึ้น ความสัมพันธ์จากค่าที่ทราบในอดีตไปยังค่าที่ทำนายมีความซับซ้อนเพิ่มขึ้นด้วย กราฟรูปที่ 3.16 แสดงให้เห็นค่า n ที่ให้ค่า MSE ต่ำที่สุดที่ค่า f ต่างๆ ตลอดช่วงค่าที่ศึกษา



รูปที่ 3.16 ค่า n ซึ่งให้ค่า MSE ต่ำที่สุดที่ค่า f ต่างๆ ตลอดช่วงค่าที่ศึกษา

- 4) เมื่อค่า f มีค่าสูงขึ้น ค่า MSE ที่ต่ำที่สุดในแต่ละกรณีของค่า f จะมีค่าเพิ่มสูงขึ้นอย่างมาก ดังกราฟรูปที่ 3.16 แสดงให้เห็นถึงข้อจำกัดของประสิทธิภาพในการรู้จำของนิรอลเน็ตเวิร์กที่ลดลงอย่างรวดเร็วเมื่อช่วงเวลาที่ทำนายในอนาคตมีค่าสูงขึ้นถึงแม้จะเลือกใช้ค่าพารามิเตอร์อื่นๆ ที่ส่งผลให้ค่า MSE ลดลงต่ำที่สุดแล้วก็ตาม



รูปที่ 3.17 เปรียบเทียบค่าเฉลี่ยความผิดพลาดกำลังสอง (MSE) ที่มีค่าต่ำที่สุด ที่ค่าพารามิเตอร์ต่างๆ

ข้อสรุปที่ได้จากผลการจำลองการทำงานที่ผ่านมา นั้น แสดงให้เห็นถึงการเลือกใช้ค่าพารามิเตอร์ต่างๆ เพื่อให้การสอนนิรอลเน็ตเวิร์กให้ค่าความผิดพลาดในการรู้จำต่ำที่สุด อย่างไรก็ตามผลที่สำคัญที่สุดในการใช้งานตัวทำนายค่าด้วยนิรอลเน็ตเวิร์ก ก็คือความผิดพลาดในการทำนายเมื่อใช้งานจริงซึ่งจะส่งผลโดยตรงต่อสมรรถนะในการควบคุมทราฟฟิกระบบดังนำเสนอในหัวข้อต่อไป

3.3 การทดสอบนิรอลเน็ตเวิร์กที่ได้ค่าพารามิเตอร์จากการสอนกับชุดข้อมูลทราฟฟิกที่สุ่มจากระบบ (Test set) และเปรียบเทียบสมรรถนะในการทำนายค่ากับอัลกอริทึมอาร์แอลเอส

ในหัวข้อนี้ได้ทำการทดสอบนิรอลเน็ตเวิร์ก ซึ่งผ่านการสอนจากหัวข้อที่แล้ว ในกรณีค่าพารามิเตอร์ต่างๆ กัน เพื่อวิเคราะห์ถึงค่าความสัมพันธ์ระหว่างค่าเฉลี่ยความผิดพลาดกำลังสอง (MSE) ที่ได้จากการสอนนิรอลเน็ตเวิร์กด้วยชุดข้อมูลที่ได้จากระบบและค่าเฉลี่ยความผิดพลาดกำลังสองที่ได้จากการนำนิรอลเน็ตเวิร์กดังกล่าวไปทำนายค่าทราฟฟิกที่สุ่มตัวอย่างมาจากระบบ ซึ่งจะนำไปใช้ในการวิเคราะห์ผลเพื่อหาข้อสรุปในการหาค่าพารามิเตอร์ของนิรอลเน็ตเวิร์กที่เหมาะสมเพื่อนำไปใช้ควบคุมทราฟฟิกแบบบีพีซีเอ็นต่อไป นอกจากนี้จะทำการเปรียบเทียบผลดังกล่าวกับการทำนายค่าด้วยอัลกอริทึมอาร์แอลเอสที่ได้จากการจำลองการทำงานหัวข้อที่ 2.3 เพื่อเปรียบเทียบสมรรถนะในการทำนายค่า

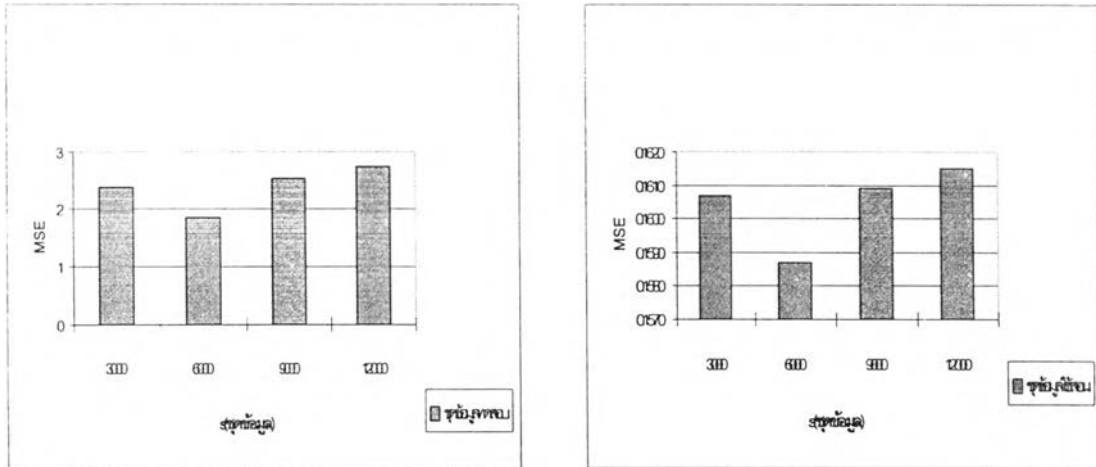
ในการจำลองการทำงานนี้ได้กำหนดให้สุ่มตัวอย่างทราฟฟิกที่มีความต่อเนื่องกัน 5,000 จุด จำนวน 5 ชุดมาเป็นชุดทดสอบตัวทำนายค่าแล้วคำนวณค่า MSE ออกมา เพื่อหลีกเลี่ยงกรณีที่นิรอลเน็ตเวิร์กอาจทำนายค่าได้ดีเฉพาะทราฟฟิกบางช่วง

ตารางที่ 3.1 ผลเปรียบเทียบค่า MSE ในการทำนายค่าของนิรอลเน็ตเวิร์กที่ได้จากการสุ่มชุดข้อมูล สำหรับทำการสอน ชุดข้อมูลจากการสุ่ม

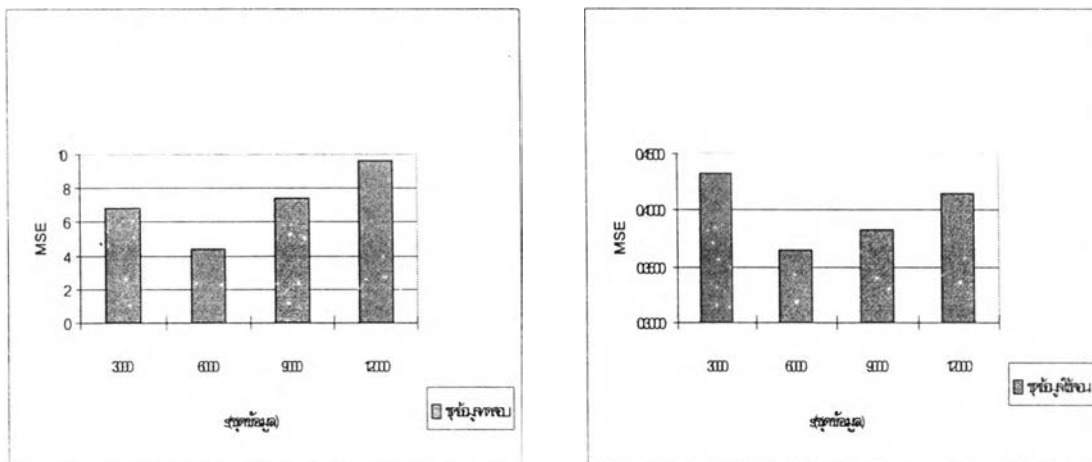
MSE / case	MSE, f=5	MSE, f=10	MSE, f=20	MSE, f=40	MSE, f=60	MSE, f=80
s=3000, train set	0.1607	0.4326	3.3524	8.4257	14.2032	36.8577
s=3000, test set	2.3866	6.8655	17.6958	35.6622	57.6226	85.6455
s=6000, train set	0.1587	0.3651	2.8955	8.0625	13.8757	35.9865
s=6000, test set	1.8546	4.3875	14.1159	29.2265	48.6358	82.6512
s=9000, train set	0.1609	0.3824	3.1565	7.8463	13.6969	34.7815
s=9000, test set	2.5390	7.4366	19.6523	25.3542	42.3555	75.1653
s=12000, train set	0.1615	0.4144	3.3155	8.6255	13.9265	35.7842
s=12000, test set	2.7366	9.6525	22.6654	32.6524	53.2657	79.6326

ผลจากตารางที่ 3.1 นำแยกแสดงผลเป็นกราฟเพื่อให้สะดวกในการวิเคราะห์ข้อมูลได้ดังนี้


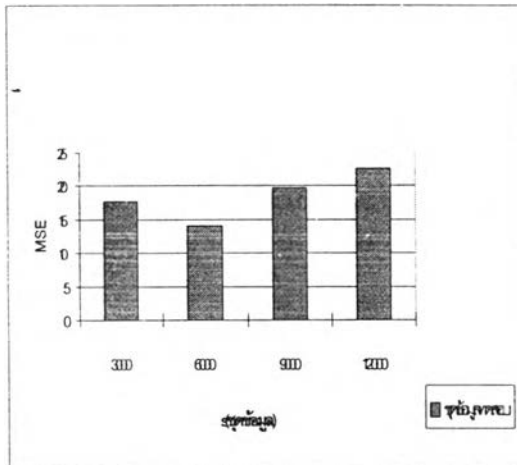
3.3.1 ค่า MSE ที่ได้จากการสอนนิเวรอลเน็ตเวิร์กและค่า MSE จากนิเวรอลเน็ตเวิร์กที่ทำนายชุดข้อมูลกราฟฟิคที่สุ่มจากระบบ





รูปที่ 3.18 การเปรียบเทียบค่า MSE ที่ได้จากการสอนนิเวรอลเน็ตเวิร์กและค่า MSE จาก การทำนายชุดข้อมูลกราฟฟิคที่สุ่มจากระบบ กรณี $f=5$





รูปที่ 3.19 การเปรียบเทียบค่า MSE ที่ได้จากการสอนนิเวรอลเน็ตเวิร์กและค่า MSE จาก การทำนายชุดข้อมูลกราฟฟิคที่สุ่มจากระบบ กรณี $f=10$





รูปที่ 3.20 การเปรียบเทียบค่า MSE ที่ได้จากการสอนนิเวรอลเน็ตเวิร์กและ
ค่า MSE จาก การทำนายชุดข้อมูลกราฟฟีกที่สุ่มจากระบบ กรณี $f=20$



รูปที่ 3.21 การเปรียบเทียบค่า MSE ที่ได้จากการสอนนิเวรอลเน็ตเวิร์กและ
ค่า MSE จาก การทำนายชุดข้อมูลกราฟฟีกที่สุ่มจากระบบ กรณี $f=40$



รูปที่ 3.22 การเปรียบเทียบค่า MSE ที่ได้จากการสอนนิเวรอลเน็ตเวิร์กและ
ค่า MSE จาก การทำนายชุดข้อมูลกราฟฟิคที่สุ่มจากระบบ กรณี $f=60$



รูปที่ 3.23 การเปรียบเทียบค่า MSE ที่ได้จากการสอนนิเวรอลเน็ตเวิร์กและ
ค่า MSE จาก การทำนายชุดข้อมูลกราฟฟิคที่สุ่มจากระบบ กรณี $f=80$

ผลจากกราฟรูปที่ 3.18 ถึงรูปที่ 3.23 แสดงให้เห็นว่า

- เมื่อนำนิเวรอลเน็ตเวิร์กมาทำนายชุดข้อมูลซึ่งสุ่มมาจากระบบ ค่า MSE ที่ได้จะมีค่าสูงขึ้นกว่ากรณีการสอนนิเวรอลเน็ตเวิร์ก เมื่อเปรียบเทียบที่ค่าพารามิเตอร์เดียวกัน
- เมื่อเปรียบเทียบกับค่า MSE ที่ค่า s ต่างกัน ในกรณีค่า f เดียวกันแล้ว ค่า MSE จากกรณีทั้งสองมีแนวโน้มในการเปลี่ยนแปลงที่สอดคล้องกัน กล่าวคือมีการเพิ่มขึ้นและลดลงในลักษณะที่แปรตามกัน แสดงให้เห็นว่าการสอนนิเวรอลเน็ตเวิร์กที่ได้ค่า MSE สูง จะมีความผิดพลาดในการทำนายค่าสูงด้วยเช่นกัน
- ค่าพารามิเตอร์ที่ให้ค่า MSE ในการสอนนิเวรอลเน็ตเวิร์กต่ำที่สุด จะให้ค่า MSE ในการทำนายค่าด้วยนิเวรอลเน็ตเวิร์กต่ำที่สุดด้วยเช่นกัน
- เมื่อเปรียบเทียบกับค่า MSE ที่ค่า s ต่างกัน ในกรณีค่า f เดียวกันแล้ว การเปลี่ยนแปลงค่า MSE ที่ได้จากการทำนายค่าชุดข้อมูลทดสอบมีการเปลี่ยนแปลงมากกว่าเมื่อเทียบกับการเปลี่ยนแปลงของค่า MSE ที่ได้จากการสอนนิเวรอลเน็ตเวิร์ก แสดงให้เห็นว่าค่า MSE ที่ต่างกันเพียงเล็กน้อยในการสอนนิเวรอลเน็ตเวิร์ก จะให้ค่าความผิดพลาดเมื่อนำไปใช้งานต่างกันอย่างมาก ซึ่งผลดังกล่าวนี้จะปรากฏชัดเจนยิ่งขึ้นเมื่อค่า f มีค่าสูงขึ้น

3.3.2 ค่า MSE จากนิเวรอลเน็ตเวิร์กและค่า MSE ที่ได้จากอัลกอริทึมอาร์แอลเอส เมื่อทำนาย


ชุดข้อมูลกราฟฟิกเดียวกันที่สุ่มจากระบบ

ในหัวข้อนี้ได้ทำการจำลองการทำงานเพื่อเปรียบเทียบความสามารถในการทำนายค่าของนิเวรอลเน็ตเวิร์กโดยใช้ค่าเงื่อนไขพารามิเตอร์จากการวิเคราะห์ผลท้ายหัวข้อที่ 3.3.2 และใช้อัลกอริทึมอาร์แอลเอสจากหัวข้อที่ 2.3 เพื่อเปรียบเทียบค่า MSE ที่ค่า f ต่างๆกัน ผลการจำลองการทำงานเป็นดังตารางที่ 3.2 และรูปที่ 3.24 ดังนี้

ตารางที่ 3.2 ผลเปรียบเทียบค่า MSE ในการทำนายค่าชุดข้อมูลจากการสุ่มของนิเวรอลเน็ตเวิร์กและอัลกอริทึมอาร์แอลเอส

MSE / f	f=5	f=10	f=15	f=20	f=25	f=30	f=35	f=40
MSE นิเวรอลเน็ตเวิร์ก	1.036	2.724	4.166	7.963	9.585	13.212	17.305	21.384
MSE อัลกอริทึมอาร์แอลเอส	5.632	7.653	9.4525	9.855	13.547	16.245	18.247	22.565

MSE / f	f=45	f=50	f=55	f=60	f=65	f=70	f=75	f=80
MSE นิเวรอลเน็ตเวิร์ก	25.684	28.651	33.457	37.884	42.385	46.308	53.985	58.668
MSE อัลกอริทึมอาร์แอลเอส	24.877	28.635	32.323	36.524	39.303	45.826	49.647	54.635




รูปที่ 3.24 การเปรียบเทียบค่า MSE จากนิวโรลเน็ตเวิร์กและค่า MSE ที่ได้จากอัลกอริทึมมาร์แอลเอส เมื่อทำนายค่าจากชุดข้อมูลกราฟฟิกเดียวกันที่สุ่มจากระบบที่ค่า f ระหว่าง 5 ถึง 80 หน่วยเวลา

จากผลการจำลองการทำงานในตารางที่ 3.2 เมื่อนำกรณีที่นิวโรลเน็ตเวิร์กทำนายค่าได้ใกล้เคียงที่สุดในผลการจำลองการทำงาน (กล่าวคือให้ค่า MSE ในการทำนายค่าต่ำที่สุด) มาเปรียบเทียบกับผลการทำนายค่าด้วยอัลกอริทึมมาร์แอลเอสซึ่งใช้ค่าพารามิเตอร์จากหัวข้อที่ 2.3 ได้ผลดังกราฟรูปที่ 3.24

ผลจากกราฟแสดงให้เห็นถึงความผิดพลาดในการทำนายด้วยอัลกอริทึมทั้งสอง ซึ่งมีค่าต่ำที่ค่าช่วงเวลาที่ทำนายในขนาดที่มีค่าน้อยๆ และความผิดพลาดในการทำนายจะสูงขึ้น เมื่อค่าช่วงเวลาที่ทำนายในขนาดที่มีค่าสูงขึ้น ผลดังกล่าวนี้เป็นลักษณะทั่วไปของการทำนายค่าด้วยอัลกอริทึมทางคณิตศาสตร์ซึ่งค่าความผิดพลาดจะสูงขึ้นเมื่อทำนายในช่วงเวลาในขนาดที่มากขึ้น

เมื่อพิจารณาในช่วงเวลาที่ทำนายในขนาดที่มีค่าเท่ากับหรือต่ำกว่า 40 หน่วยเวลา ค่า MSE ของการทำนายค่าด้วยนิวโรลเน็ตเวิร์กมีค่าต่ำกว่าค่า MSE ที่ได้จากอัลกอริทึมมาร์แอลเอส แต่เมื่อค่าช่วงเวลาที่ทำนายในขนาดเพิ่มสูงขึ้นกว่า 50 หน่วยเวลา ค่า MSE ของกรณีนิวโรลเน็ตเวิร์กจะมีค่าเพิ่มสูงขึ้นมากกว่ากรณีอัลกอริทึมมาร์แอลเอส แสดงให้เห็นว่าความผิดพลาดในการทำนายค่าด้วยนิวโรลเน็ตเวิร์กมีค่าต่ำกว่าอัลกอริทึมมาร์แอลเอสในช่วงเวลาที่ทำนายในขนาดที่มีค่าต่ำ และความผิดพลาดในการทำนายค่าสูงขึ้นอย่างรวดเร็วกว่าอัลกอริทึมมาร์แอลเอสเมื่อช่วงเวลาที่ทำนายในขนาดที่มีค่าเพิ่มสูงขึ้น

ผลการจำลองการทำงานจากกราฟรูปที่ 3.24 ในช่วงที่ f มีค่าระหว่าง 40 -55 หน่วยเวลา เป็นช่วงที่ค่า MSE ที่ได้จากอัลกอริทึมทั้งสองมีค่าใกล้เคียงกันมาก ดังนั้นเพื่อความละเอียดในการวิเคราะห์ผล จึงได้จำลองการทำงานโดยละเอียดเฉพาะในช่วงดังกล่าว ได้ผลดังกราฟรูปที่ 3.25



รูปที่ 3.25 การเปรียบเทียบค่า MSE จากนิเวศน์เวิร์กและค่า MSE ที่ได้จากอัลกอริทึมอาร์แอลเอส เมื่อทำนายชุดข้อมูลกราฟฟิคเดียวกันที่สุ่มจากระบบ ที่ ค่า $f = 40 - 55$ หน่วยเวลา

จุดที่ค่า MSE จากนิเวศน์เวิร์กเริ่มมีค่าสูงกว่าค่า MSE ที่ได้จากอัลกอริทึมอาร์แอลเอสอยู่ที่ค่า f ระหว่าง 43 ถึง 44 หน่วยเวลา ผลการจำลองการทำงานจากรูปที่ 3.25 แสดงให้เห็นว่าช่วงค่า f ที่นิเวศน์เวิร์กทำนายกราฟฟิคแล้วได้ค่าความผิดพลาดต่ำกว่าอัลกอริทึมอาร์แอลเอสคือที่ f มีค่าไม่เกิน 43 หน่วยเวลา

ในหัวข้อต่อไป จะนำอัลกอริทึมทำนายค่าที่ได้ศึกษาเป็นลำดับมาในหัวข้อต่างๆ มาเป็นตัวป้อนกลับสำหรับควบคุมกราฟฟิคแบบบีพีซีเอ็น เพื่อศึกษาการเปลี่ยนแปลงของค่าพารามิเตอร์ต่างๆในการควบคุมกราฟฟิคของระบบเอทีเอ็มที่กำหนดไว้ในหัวข้อที่ 2.5

3.4 การจำลองผลการทำนายเพื่อเปรียบเทียบสมรรถนะในการควบคุมกราฟฟิคแบบบีพีซีเอ็นด้วยนิเวศน์เวิร์กและอัลกอริทึมอาร์แอลเอส


ในหัวข้อนี้เป็นการศึกษานิเวศน์เวิร์กที่ต่อเนื่องจากหัวข้อที่ 3.3 โดยในหัวข้อนี้จะนำนิเวศน์เวิร์กจากหัวข้อดังกล่าวมาเป็นตัวทำนายค่าป้อนกลับเพื่อควบคุมกราฟฟิคในแบบบีพีซีเอ็น ศึกษาความสามารถในการควบคุมกราฟฟิคเมื่อค่าการประวิงในการแพร่กระจายในระบบมีค่าเพิ่มสูงขึ้น และเปรียบเทียบผลกับอัลกอริทึมอาร์แอลเอสในงานวิจัยของ Hu จากหัวข้อที่ 2.3

การจำลองการทำงานหัวข้อนี้ใช้ค่าพารามิเตอร์ของระบบที่ศึกษาเช่นเดียวกับในหัวข้อที่ 2.5 กล่าวคือ

- ค่าความเข้มกราฟฟิคมีค่าประมาณ 1.0
- ค่าตัดสินใจของการค้ำคั่งกำหนดไว้ที่ 70 เซลล์ของระดับค่าบัพเฟอร์ในเอทีเอ็มสวิตช์ที่ 100 เซลล์
- บัพเฟอร์ของแหล่งกำเนิดกราฟฟิคแบบเอบีอาร์มีขนาด 3000 เซลล์

- การประวิงในการแพร่กระจายทั้งวงรอบระบบ (D_p) มีค่าตั้งแต่ 2 ถึง 40 หน่วยเวลา ซึ่งอัลกอริทึมทำนายค่าจะต้องทำนายค่าล่วงหน้าในช่วงเวลาสองเท่าของค่าดังกล่าว


ผลการจำลองการทำงานเป็นดังนี้



รูปที่ 3.26 การประวิงในการส่งข้อมูลจากแหล่งกำเนิดกราฟฟิกแบบมีการรับรอง และการประวิงในการแพร่กระจาย


การประวิงในการส่งข้อมูล (D_t) ของกราฟฟิกที่ส่งจากแหล่งกำเนิดกราฟฟิกแบบมีการรับรอง จะมีแนวโน้มลดลง เมื่อค่าการประวิงในการแพร่กระจาย (D_p) มีค่าเพิ่มสูงขึ้น ซึ่งเป็นลักษณะเช่นเดียวกับที่พบในการควบคุมกราฟฟิกแบบบีพีซีเอ็น และการควบคุมแบบบีพีซีเอ็นด้วยอัลกอริทึมอาร์แอลเอส

เมื่อพิจารณาค่าการประวิงในการส่งข้อมูลในเชิงเปรียบเทียบกันระหว่างแต่ละวิธีการควบคุม วิธีการควบคุมแบบบีพีซีเอ็นมีค่าการประวิงในการส่งข้อมูลสูงที่สุดตลอดช่วงการประวิงในการแพร่กระจายที่ศึกษา และเมื่อเปรียบเทียบระหว่างกรณีของนีวอลเน็ตเวิร์กและอัลกอริทึมอาร์แอลเอสจะพบว่าในช่วงค่าการประวิงในการแพร่กระจายมีค่าต่ำกว่า 24 หน่วยเวลา การใช้อัลกอริทึมอาร์แอลเอสจะทำให้ค่าการประวิงในการส่งข้อมูลมีค่าสูงกว่านีวอลเน็ตเวิร์ก แต่เมื่อค่าการประวิงในการแพร่กระจายมีค่าสูงเกินกว่า 24 หน่วยเวลา การควบคุมแบบบีพีซีเอ็นด้วยนีวอลเน็ตเวิร์กจะทำให้ค่าการประวิงในการส่งข้อมูลมีค่าสูงกว่าการควบคุมแบบบีพีซีเอ็นด้วยอัลกอริทึมอาร์แอลเอส




รูปที่ 3.27 อัตราส่วนการสูญเสียจากแหล่งกำเนิดกราฟฟิกแบบมีการรับรองและการประวิงในการแพร่กระจาย

จากรูปที่ 3.27 อัตราส่วนการสูญเสียจากแหล่งกำเนิดกราฟฟิกแบบมีการรับรองเมื่อควบคุมแบบบีอีซีเอ็นจะมีค่าสูงตลอดช่วงการประวิงในการแพร่กระจายที่ศึกษา การควบคุมแบบบีอีซีเอ็นด้วยนิวรอลเนตเวิร์กจะส่งผลให้ค่าอัตราส่วนการสูญเสียมีค่าลดลงต่ำที่สุดในช่วงที่การประวิงในการแพร่กระจายมีค่าต่ำ แต่เมื่อค่าการประวิงในการแพร่กระจายมีค่าสูงกว่า 24 หน่วยเวลา ค่าอัตราส่วนการสูญเสียในการนี้ควบคุมแบบบีอีซีเอ็นนิวรอลเนตเวิร์ก จะมีค่าสูงขึ้นกว่าการควบคุมแบบบีอีซีเอ็นด้วยอัลกอริทึมอาร์แอลเอส อย่างไรก็ตาม การควบคุมแบบบีอีซีเอ็นด้วยอัลกอริทึมทั้งสองแบบยังคงให้ค่าอัตราส่วนการสูญเสียที่ต่ำกว่าการควบคุมแบบบีอีซีเอ็น



รูปที่ 3.28 การประวิงในการส่งข้อมูลจากแหล่งกำเนิดกราฟฟิกแบบเอบีอาร์และการประวิงในการแพร่กระจาย

จากรูปที่ 3.28 ผลกราฟแสดงให้เห็นว่าการควบคุมแบบบีพีซีเอ็นทำให้ค่าการประวิงในการส่งข้อมูลจากแหล่งกำเนิดกราฟฟิกแบบเอบีอาร์ลดต่ำลงกว่าการควบคุมแบบบีพีซีเอ็น กรณีของการควบคุมแบบบีพีซีเอ็นนิรอลเน็ตเวิร์กมีค่าการประวิงในการส่งข้อมูลสูงกว่ากรณีการควบคุมแบบบีพีซีเอ็นด้วยอัลกอริทึมอาร์แอลเอสตลอดช่วงการจำลองการทำงาน โดยมีค่าใกล้เคียงกันในช่วงที่การประวิงในการแพร่กระจายมีค่าต่ำ และมีค่าแตกต่างกันมากขึ้นเมื่อค่าการประวิงในการแพร่กระจายมีค่าสูงขึ้น

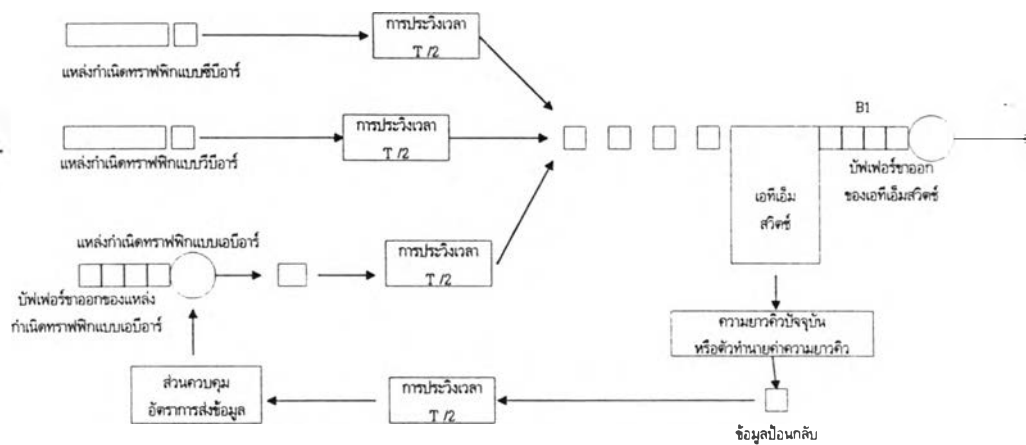


รูปที่ 3.29 อัตราส่วนการสูญเสียจากแหล่งกำเนิดกราฟฟิกแบบเอบีอาร์และการประวิงในการแพร่กระจาย

จากรูปที่ 3.29 อัตราส่วนการสูญเสียจากแหล่งกำเนิดกราฟฟิกแบบเอบีอาร์จะมีค่าลดลงตลอดช่วงค่าการประวิงในการแพร่กระจายที่ศึกษาเมื่อใช้การควบคุมแบบบีพีซีเอ็น และการควบคุมแบบบีพีซีเอ็นด้วยนิรอลเน็ตเวิร์กให้ค่าอัตราส่วนการสูญเสียต่ำที่สุดในช่วงการประวิงในการแพร่กระจายมีค่าต่ำกว่า 22 หน่วยเวลา เมื่อค่าการประวิงในการแพร่กระจายเท่ากับหรือสูงขึ้นไปกว่า 22 หน่วยเวลา การควบคุมแบบบีพีซีเอ็นด้วยอัลกอริทึมอาร์แอลเอสจะให้ค่าอัตราส่วนการสูญเสียจากแหล่งกำเนิดกราฟฟิกแบบเอบีอาร์ต่ำที่สุดไปจนตลอดช่วงค่าการประวิงในการแพร่กระจายที่ศึกษา

3.5 วิเคราะห์ผลการจำลองการทำงานในการควบคุมกราฟฟิกแบบบีพีซีเอ็นด้วยนิรอลเน็ตเวิร์ก

ในการควบคุมกราฟฟิกในระบบที่ศึกษานี้ พารามิเตอร์สำคัญที่พิจารณาได้แก่ค่าการประวิงในการส่งข้อมูลและอัตราส่วนการสูญเสียของข้อมูล (Gillian, et al., 1990) ซึ่งในทางทฤษฎีแล้วพารามิเตอร์ทั้งสองนี้จะมีลักษณะแปรผันสวนทางกันกล่าวคือ ถ้าระบบมีค่าการประวิงในการส่งข้อมูลต่ำก็ก็สามารถส่งข้อมูลไปยังปลายทางได้อย่างรวดเร็ว แต่ข้อมูลก็จะเกิดการสูญเสียมากจึงมีอัตราส่วนการสูญเสียมากด้วย ในทางกลับกันถ้าหากรบบควบคุมให้การส่งข้อมูลไปยังปลายทางช้าลง การประวิงในการส่งข้อมูลก็จะมีค่าสูงขึ้นแต่อัตราส่วนการสูญเสียจะลดต่ำลงด้วย



รูปที่ 3.30 แบบจำลองโครงข่ายเอทีเอ็มในงานวิจัย (อ้างอิงบทที่ 2 หน้าที 23)

เมื่อพิจารณากระบวนการส่งข้อมูลแบบเอทีเอ็มที่ศึกษาจากรูปที่ 3.30 ระบบถูกออกแบบให้เกิดความคับคั่งและการสูญเสียข้อมูลในบัฟเฟอร์ขาออกของเอทีเอ็มสวิตช์เท่านั้น และการประวิงในการแพร่กระจายเกิดจากการประวิงที่อยู่ระหว่างแหล่งกำเนิดข้อมูลต่างๆและเอทีเอ็มสวิตช์

3.5.1 ทราฟฟิกจากแหล่งกำเนิดตราฟิสิกแบบมีการรับรอง

เมื่อพิจารณาความสัมพันธ์ระหว่างการประวิงในการส่งข้อมูลจากแหล่งกำเนิดตราฟิสิกแบบมีการรับรองและการประวิงในการแพร่กระจายจากรูปที่ 3.26 พบว่าเมื่อการประวิงในการแพร่กระจายมีค่าสูงขึ้น ค่าการประวิงในการแพร่กระจายของตราฟิสิกแบบมีการรับรองจะมีค่าลดลงเนื่องจาก ค่าการประวิงในการแพร่กระจายของตราฟิสิกแบบมีการรับรองเกิดจากเวลาที่ข้อมูลรอที่จะถูกส่งออกจากบัฟเฟอร์ขาออกของเอทีเอ็มสวิตช์เท่านั้น เมื่อค่าการประวิงในการแพร่กระจายของข้อมูลมีค่าสูงขึ้น ความสามารถในการควบคุมตราฟิสิกแบบเอบีอาร์ของระบบควบคุมจะด้อยลง ส่งผลให้ระบบไม่สามารถรักษาปริมาณเซลล์ข้อมูลในบัฟเฟอร์ขาออกของเอทีเอ็มสวิตช์ไว้ที่ค่าเป้าหมายได้ตามปกติ ดังนั้นกลไกการควบคุมการทำงานจึงต้องทำงานบ่อยครั้งขึ้นตามไปด้วย ทำให้ปริมาณข้อมูลที่เข้าสู่เอทีเอ็มสวิตช์โดยเฉลี่ยมีค่าลดลง จึงส่งผลสุดท้ายให้การประวิงในการส่งข้อมูลของตราฟิสิกแบบมีการรับรองลดลงด้วย

จากผลการเปรียบเทียบการควบคุมตราฟิสิกทั้งสามวิธี พบว่าที่ค่าการประวิงในการแพร่กระจายตั้งแต่ 24 หน่วยเวลาลงมา (รูปที่ 3.26) ซึ่งเป็นช่วงที่นิวโรลเน็ตเวิร์กมีความผิดพลาดในการทำนายค่าต่ำกว่า อัลกอริทึมอาร์แอลเอส (เมื่อพิจารณารูปที่ 3.24 และรูปที่ 3.25 ประกอบ) ค่าการประวิงในการส่งข้อมูลในการณีการควบคุมแบบบีพีซีเอ็นด้วยนิวโรลเน็ตเวิร์กจะมีค่าต่ำกว่ากรณีของการควบคุมแบบบีพีซีเอ็นด้วยอัลกอริทึมอาร์แอลเอสในช่วง 0.89-0.99 เทียบกับการควบคุมแบบบีพีซีเอ็นด้วยอัลกอริทึมอาร์แอลเอสดังตารางที่ 3.3

ตารางที่ 3.3 อัตราส่วนการประวิงในการส่งข้อมูลของกราฟฟิกแบบมีการรับรองเทียบกับกรณีของการควบคุมกราฟฟิกแบบบีบีซีเอ็นด้วยอัลกอริทึมอาร์แอลเอสที่ค่าการประวิงในการแพร่กระจายต่างๆ

	การประวิงในการแพร่กระจาย (Dp) (หน่วยเวลา)																			
	2	4	6	8	10	12	14	16	18	20	22	24	26	28	30	32	34	36	38	40
บีบีซีเอ็น*	1.044	1.045	1.035	1.044	1.048	1.031	1.067	1.068	1.078	1.052	1.071	1.042	1.065	1.047	1.035	1.088	1.088	1.092	1.115	1.108
นิวรอลเนตเวิร์ก*	0.897	0.902	0.906	0.906	0.942	0.942	0.971	0.971	0.977	0.953	0.999	0.966	1.026	1.008	1.002	1.033	1.035	1.021	1.032	1.046

บีบีซีเอ็น* หมายถึง อัตราส่วนการประวิงในการส่งข้อมูลของกราฟฟิกแบบมีการรับรอง ในกรณีการควบคุมกราฟฟิกแบบบีบีซีเอ็นเทียบกับกรณีการควบคุมกราฟฟิกแบบบีบีซีเอ็นด้วยอัลกอริทึมอาร์แอลเอส

นิวรอลเนตเวิร์ก* หมายถึง อัตราส่วนการประวิงในการส่งข้อมูลของกราฟฟิกแบบมีการรับรอง ในกรณีการควบคุมกราฟฟิกแบบบีบีซีเอ็นด้วยนิวรอลเนตเวิร์กเทียบกับกรณีการควบคุมกราฟฟิกแบบบีบีซีเอ็นด้วยอัลกอริทึมอาร์แอลเอส

เมื่อค่าการประวิงในการแพร่กระจายสูงขึ้นกว่า 24 หน่วยเวลา ค่าความผิดพลาดในการทำนายค่าของนิเวศเน็ตเวิร์กจะเพิ่มสูงขึ้นกว่าอัลกอริทึมอาร์แอลเอส จึงทำให้ค่าการประวิงในการส่งข้อมูลมีค่าสูงขึ้นกว่าการณของอัลกอริทึมอาร์แอลเอสเมื่อเปรียบเทียบกันที่ค่าการประวิงในการแพร่กระจายค่าเดียวกัน ผลการจำลองการทำงานนี้ชี้ให้เห็นว่าเราสามารถควบคุมให้ค่าการประวิงในการส่งข้อมูลของกราฟฟิกแบบรับรองผลลดลงได้เมื่อการควบคุมกราฟฟิกแบบบีพีซีเอ็นถูกป้อนกลับด้วยค่าที่แม่นยำขึ้นด้วยการทำนายค่าจากนิเวศเน็ตเวิร์ก

เมื่อพิจารณาความสัมพันธ์ระหว่างอัตราส่วนการสูญเสียของกราฟฟิกจากแหล่งกำเนิดกราฟฟิกแบบมีการรับรองและการประวิงในการแพร่กระจาย จากผลกราฟในรูปที่ 3.27 พบว่าอัตราส่วนการสูญเสียจะมีค่าเพิ่มสูงขึ้นเมื่อการประวิงในการแพร่กระจายสูงขึ้น ซึ่งในงานวิจัยของ Hu และผลการจำลองการทำงานที่ผ่านมาให้ผลที่สอดคล้องกันเนื่องจากเมื่อค่าการประวิงในการแพร่กระจายสูงขึ้น ค่าความผิดพลาดในการควบคุมกราฟฟิกให้อยู่ที่ค่าเป้าหมายจะมีค่าสูงขึ้นด้วย (สมการที่ (2.10) และสมการที่ (2.11)) อัตราส่วนการสูญเสียจึงมีค่าเพิ่มสูงขึ้นด้วยเนื่องจากโอกาสที่ข้อมูลจะล้นบัฟเฟอร์ขาออกของเอทีเอ็มสวิตช์มีสูงขึ้น

เมื่อนำค่าอัตราส่วนการสูญเสียจากกราฟรูปที่ 3.27 มาแสดงค่าในรูปตารางโดยเทียบอัตราส่วนการสูญเสียกับการณการควบคุมกราฟฟิกแบบบีพีวีเอ็นด้วยอัลกอริทึมอาร์แอลเอส ได้ดังตารางที่ 3.4

ตารางที่ 3.4 อัตราส่วนการสูญเสียของกราฟฟิกแบบมีการรับรองเทียบกับกรณีของการควบคุมกราฟฟิกแบบบีบีซีเอ็นด้วยอัลกอริทึมอาร์แอลเอสที่ค่าการประวิงในการแพร่กระจายต่างๆ

	การประวิงในการแพร่กระจาย (Dp) (หน่วยเวลา)																			
	2	4	6	8	10	12	14	16	18	20	22	24	26	28	30	32	34	36	38	40
บีบีซีเอ็น*	3.575	2.696	3.490	3.833	3.140	4.682	4.507	4.608	5.132	3.771	4.504	3.499	4.837	5.595	4.652	3.488	4.791	4.640	3.454	3.526
นิวรอลเน็ตเวิร์ก*	0.373	0.389	0.448	0.521	0.557	0.828	0.880	0.920	0.913	0.863	0.977	1.006	1.066	1.201	1.258	1.135	1.312	1.264	1.479	1.221

บีบีซีเอ็น* หมายถึง อัตราส่วนการสูญเสียของกราฟฟิกแบบมีการรับรองของกรณีการควบคุมกราฟฟิกแบบบีบีซีเอ็นเทียบกับกรณีการควบคุมกราฟฟิกแบบบีบีซีเอ็นด้วยอัลกอริทึมอาร์แอลเอส


นิวรอลเน็ตเวิร์ก* หมายถึง อัตราส่วนการสูญเสียของกราฟฟิกแบบมีการรับรองของกรณีการควบคุมกราฟฟิกแบบบีบีซีเอ็นด้วยนิวรอลเน็ตเวิร์กเทียบกับกรณีการควบคุมกราฟฟิกแบบบีบีซีเอ็นด้วยอัลกอริทึมอาร์แอลเอส

ผลจากตารางที่ 3.4 แสดงให้เห็นว่าในช่วงที่ค่าการประวิงในการแพร่กระจายมีค่าตั้งแต่ 22 หน่วยเวลาลงมา ค่าอัตราส่วนการสูญเสียในช่วงดังกล่าวของการควบคุมทราฟฟิกแบบบีพีซีเอ็นด้วยนิวรอลเน็ตเวิร์กจะมีค่าต่ำกว่าการควบคุมทราฟฟิกแบบบีพีซีเอ็นด้วยอัลกอริทึมอาร์แอลเอส โดยในช่วงที่การประวิงมีค่าต่ำกว่า 8 หน่วยเวลา ค่าอัตราส่วนการสูญเสียในกรณีของการควบคุมทราฟฟิกแบบบีพีซีเอ็นด้วยนิวรอลเน็ตเวิร์กจะลดลงเหลือต่ำกว่า 50 % ของการควบคุมทราฟฟิกแบบบีพีซีเอ็นด้วยอัลกอริทึมอาร์แอลเอส ในขณะที่อัตราส่วนการสูญเสียจากการควบคุมแบบบีพีซีเอ็นทั้งสองแบบมีค่าต่ำกว่าการควบคุมแบบบีพีซีเอ็นประมาณ 3-4 เท่าตลอดช่วงค่าการประวิงในการแพร่กระจายที่ศึกษา

3.5.2 ทราฟฟิกจากแหล่งกำเนิดทราฟฟิกแบบเอบีอาร์

พิจารณารูปที่ 3.30 ซึ่งแสดงแบบจำลองของระบบที่ศึกษา จะเห็นได้ว่าการประวิงในการส่งข้อมูลของทราฟฟิกแบบเอบีอาร์ขึ้นกับปริมาณข้อมูลภายในบัฟเฟอร์ของแหล่งกำเนิดทราฟฟิกแบบเอบีอาร์เองและปริมาณข้อมูลในบัฟเฟอร์ขาออกของเอทีเอ็มสวิตช์ ซึ่งแตกต่างจากค่าการประวิงในการส่งข้อมูลแหล่งกำเนิดทราฟฟิกแบบมีการรับรองซึ่งขึ้นกับปริมาณข้อมูลในบัฟเฟอร์ขาออกของเอทีเอ็มสวิตช์เพียงอย่างเดียว

เมื่อการประวิงในการแพร่กระจายมีค่าสูงขึ้นส่งผลให้ความผิดพลาดในการควบคุมทราฟฟิกมีค่าสูงขึ้น จึงทำให้กลไกการควบคุมทราฟฟิกทำงานบ่อยครั้งขึ้นเพื่อลดโอกาสการเกิดการสูญเสียข้อมูลที่บัฟเฟอร์ขาออกของเอทีเอ็มสวิตช์ ดังนั้นปริมาณทราฟฟิกแบบเอบีอาร์ที่สะสมอยู่ในบัฟเฟอร์ของแหล่งกำเนิดทราฟฟิกแบบเอบีอาร์มีค่าสูงขึ้นเมื่อการประวิงในการแพร่กระจายของข้อมูลมีค่าสูงขึ้น ซึ่งผลการจำลองการทำงานในรูปที่ 3.31 แสดงให้เห็นความสัมพันธ์ระหว่างปริมาณข้อมูลเฉลี่ยภายในบัฟเฟอร์ของแหล่งกำเนิดทราฟฟิกแบบเอบีอาร์และการประวิงในการแพร่กระจาย



รูปที่ 3.31 ความสัมพันธ์ระหว่างปริมาณข้อมูลเฉลี่ยภายในบัฟเฟอร์ของแหล่งกำเนิดทราฟฟิกแบบเอบีอาร์และการประวิงในการแพร่กระจาย

ผลการจำลองการทำงานในรูปที่ 3.31 แสดงให้เห็นว่าปริมาณกราฟฟิกสะสมภายในบัฟเฟอร์ของเอทีเอ็มสวิตช์ที่เพิ่มขึ้น ส่งผลให้การประวิงในการส่งข้อมูลของกราฟฟิกแบบเอบีอาร์มีค่าเพิ่มขึ้นเมื่อการประวิงในการแพร่กระจายของข้อมูลมีค่าสูงขึ้น อย่างไรก็ตามผลที่เกิดขึ้นเป็นลักษณะสมบัติร่วมของระบบและกลไกการควบคุมแบบป้อนกลับที่ศึกษาซึ่งพบในการควบคุมกราฟฟิกทั้งสามวิธี ถึงแม้ว่าการควบคุมกราฟฟิกแบบบีพีซีเอ็นด้วยนิวโรลเนตเวิร์กจะให้ค่าการประวิงในการส่งข้อมูลสูงขึ้นกว่าการควบคุมกราฟฟิกแบบบีพีซีเอ็นด้วยอัลกอริทึมอาร์แอลเอสประมาณ 5%-22% ตลอดช่วงการประวิงในการแพร่กระจายที่ศึกษา ผลที่ได้ก็ยังต่ำกว่าการควบคุมกราฟฟิกแบบบีพีซีเอ็นซึ่งมีค่าการประวิงในการส่งข้อมูลสูงขึ้นกว่าการควบคุมกราฟฟิกแบบบีพีซีเอ็นด้วยอัลกอริทึมอาร์แอลเอสประมาณ 27%-127% ดังตารางเปรียบเทียบอัตราค่าการประวิงในการส่งข้อมูลของกราฟฟิกแบบเอบีอาร์เป็นจำนวนเท่าเทียบกับกรณีของการควบคุมกราฟฟิกแบบบีพีซีเอ็นด้วยอัลกอริทึมอาร์แอลเอส ในตารางที่ 3.5 ซึ่งเป็นข้อมูลเดียวกับข้อมูลในกราฟรูปที่ 3.28

ตารางที่ 3.5 อัตราส่วนการประวิงในการส่งข้อมูลของกราฟฟิกแบบเอบีอาร์เทียบกับกรณีของการควบคุมกราฟฟิกแบบบีพีซีเอ็นด้วยอัลกอริทึมอาร์แอลเอสที่ค่าการประวิงในการแพร่กระจายต่างๆ

	การประวิงในการแพร่กระจาย (Dp) (หน่วยเวลา)																			
	2	4	6	8	10	12	14	16	18	20	22	24	26	28	30	32	34	36	38	40
บีพีซีเอ็น*	1.275	1.262	1.250	1.239	1.277	1.225	1.235	1.297	1.353	1.472	1.382	1.455	1.482	1.527	1.691	1.644	1.817	1.841	2.164	2.270
นิวรอลเน็ตเวิร์ก*	1.050	1.048	1.023	1.022	1.027	1.020	1.039	1.032	1.078	1.094	1.073	1.109	1.120	1.109	1.127	1.127	1.133	1.151	1.209	1.223

บีพีซีเอ็น* หมายถึง อัตราส่วนการประวิงในการส่งข้อมูลของกราฟฟิกแบบเอบีอาร์ ในกรณีการควบคุมกราฟฟิกแบบบีพีซีเอ็นเทียบกับกรณีการควบคุมกราฟฟิกแบบบีพีซีเอ็นด้วยอัลกอริทึมอาร์แอลเอส

นิวรอลเน็ตเวิร์ก* หมายถึง อัตราส่วนการประวิงในการส่งข้อมูลของกราฟฟิกแบบเอบีอาร์ ในกรณีการควบคุมกราฟฟิกแบบบีพีซีเอ็นด้วยนิวรอลเน็ตเวิร์กเทียบกับกรณีการควบคุมกราฟฟิกแบบบีพีซีเอ็นด้วยอัลกอริทึมอาร์แอลเอส

ต่อมาเมื่อพิจารณาความสัมพันธ์ระหว่างอัตราส่วนการสูญเสียของข้อมูลจากแหล่งกำเนิดกราฟฟิกแบบเวบีอาร์และการประวิงในการแพร่กระจาย จากผลการจำลองการทำงานในรูปที่ 3.29 แสดงให้เห็นว่าเมื่อการประวิงในการแพร่กระจายสูงขึ้น อัตราส่วนการสูญเสียของข้อมูลจากแหล่งกำเนิดกราฟฟิกแบบเวบีอาร์จะมีค่าสูงขึ้น ซึ่งอธิบายได้ด้วยเหตุผลเดียวกับการอธิบายความสัมพันธ์ระหว่างอัตราส่วนการสูญเสียของข้อมูลจากแหล่งกำเนิดกราฟฟิกแบบรับรองผลและการประวิงในการแพร่กระจาย

เมื่อนำค่าอัตราส่วนการสูญเสียของข้อมูลจากแหล่งกำเนิดกราฟฟิกแบบเวบีอาร์และการประวิงในการแพร่กระจาย จากรูปที่ 3.29 มาแสดงผลเปรียบเทียบเป็นเปอร์เซ็นต์กับกรณีของการควบคุมกราฟฟิกแบบบีทีซีเอ็นด้วยอัลกอริทึมอาร์แอลเอส ได้ผลดังตารางที่ 3.6

ตารางที่ 3.6 อัตราส่วนการสูญเสียของกราฟฟิกแบบเอบีอาร์เทียบกับกรณีของการควบคุมกราฟฟิกแบบบีพีซีเอ็นด้วยอัลกอริทึมอาร์แอลเอสที่ค่าการประวิงในการแพร่กระจายต่างๆ

	การประวิงในการแพร่กระจาย (Dp) (หน่วยเวลา)																			
	2	4	6	8	10	12	14	16	18	20	22	24	26	28	30	32	34	36	38	40
บีพีซีเอ็น*	1.930	2.511	2.694	2.469	2.579	1.601	1.878	2.048	2.272	2.464	2.364	2.422	2.638	2.738	3.517	3.632	3.755	3.569	3.111	3.076
นิวรอลเน็ตเวิร์ก*	0.183	0.275	0.315	0.615	0.774	0.758	0.777	0.821	0.855	0.926	1.039	1.028	1.070	1.071	1.084	1.126	1.147	1.137	1.188	1.170

บีพีซีเอ็น* หมายถึง อัตราส่วนการสูญเสียของกราฟฟิกแบบเอบีอาร์ ในกรณีการควบคุมกราฟฟิกแบบบีพีซีเอ็นเทียบกับกรณีการควบคุมกราฟฟิกแบบบีพีซีเอ็นด้วยอัลกอริทึมอาร์แอลเอส

นิวรอลเน็ตเวิร์ก* หมายถึง อัตราส่วนการสูญเสียของกราฟฟิกแบบเอบีอาร์ ในกรณีการควบคุมกราฟฟิกแบบบีพีซีเอ็นด้วยนิวรอลเน็ตเวิร์กเทียบกับกรณีการควบคุมกราฟฟิกแบบบีพีซีเอ็นด้วยอัลกอริทึมอาร์แอลเอส

ตารางที่ 3.6 แสดงให้เห็นว่าอัตราส่วนการสูญเสียข้อมูลจากแหล่งกำเนิดกราฟฟิกแบบเอบีอาร์เมื่อควบคุมกราฟฟิกแบบบีพีซีเอ็นด้วยด้วยนิรอลเน็ตเวิร์กมีค่าต่ำกว่าการควบคุมกราฟฟิกแบบบีพีซีเอ็นด้วยอัลกอริทึมอาร์แอลเอสในช่วงที่การประวิงในการแพร่กระจายมีค่าต่ำกว่า 20 หน่วยเวลาหรือเป็นช่วงโดยประมาณที่นิรอลเน็ตเวิร์กทำนายค่ากราฟฟิกได้แม่นยำกว่าอัลกอริทึมอาร์แอลเอส การลดลงของอัตราส่วนการสูญเสียของข้อมูลจากแหล่งกำเนิดกราฟฟิกแบบเอบีอาร์จะลดลงต่ำกว่า 50 % ของอัลกอริทึมอาร์แอลเอสที่ค่าการประวิงในการแพร่กระจายต่ำกว่า 8 หน่วยเวลา ในขณะที่การควบคุมกราฟฟิกแบบบีพีซีเอ็นมีอัตราส่วนการสูญเสียของข้อมูลสูงถึง 1.9-3.7 เท่าเมื่อเทียบกับการควบคุมกราฟฟิกแบบบีพีซีเอ็นด้วยอัลกอริทึมอาร์แอลเอสในช่วงค่าการประวิงในการส่งข้อมูลที่ศึกษา

3.6 สรุปผลการควบคุมกราฟฟิกแบบบีพีซีเอ็นด้วยนิรอลเน็ตเวิร์ก

จากการศึกษาในหัวข้อที่ 3.1 -3.5 สามารถสรุปผลได้ว่า การนำนิรอลเน็ตเวิร์กมาทำนายค่ากราฟฟิกในอนาคตแล้วนำค่าป้อนกลับเข้าสู่ระบบควบคุมแบบบีพีซีเอ็นให้ผลในการควบคุมกราฟฟิกในระบบที่ทำการศึกษาดังนั้น เมื่อใช้นิรอลเน็ตเวิร์กที่มีฟังก์ชันถ่ายโอนในชั้นขาเข้า ชั้นซ่อนตัว และชั้นขาออกเป็นฟังก์ชันเชิงเส้น ล้อคซิกมอยด์ และล้อคซิกมอยด์ตามลำดับ โดยในการสอนนิรอลเน็ตเวิร์กนั้นต้องมีค่าพารามิเตอร์บางค่าที่สำคัญอยู่ในช่วงที่เหมาะสมเพื่อให้การทำนายค่าให้ค่าความผิดพลาดต่ำที่สุดกล่าว

ในช่วงที่การประวิงในการแพร่กระจายมีค่าต่ำกว่า 20 หน่วยเวลา ซึ่งอยู่ในช่วงที่นิรอลเน็ตเวิร์กสามารถทำนายค่าได้แม่นยำกว่าอัลกอริทึมอาร์แอลเอสและให้ผลในการควบคุมกราฟฟิกที่ดีขึ้นด้วยนั้น นิรอลเน็ตเวิร์กให้ผลที่ดีกว่าเมื่อเทียบกับการควบคุมกราฟฟิกด้วยอัลกอริทึมอาร์แอลเอสดังนี้

- 1) การประวิงในการส่งข้อมูลของกราฟฟิกแบบรับรองผลต่ำกว่าอัลกอริทึมอาร์แอลเอส โดยมีค่าเป็น 89%-95% ของค่าดังกล่าวที่ได้จากอัลกอริทึมอาร์แอลเอส
- 2) อัตราส่วนการสูญเสียในการส่งข้อมูลของกราฟฟิกแบบรับรองผลต่ำกว่าอัลกอริทึมอาร์แอลเอส โดยมีค่าเป็น 37%-86% ของค่าดังกล่าวที่ได้จากอัลกอริทึมอาร์แอลเอส
- 3) อัตราส่วนการสูญเสียในการส่งข้อมูลของกราฟฟิกแบบเอบีอาร์ต่ำกว่าอัลกอริทึมอาร์แอลเอส โดยมีค่าเป็น 18%-92% ของค่าดังกล่าวที่ได้จากอัลกอริทึมอาร์แอลเอส

อย่างไรก็ตามในช่วงการประวิงในการแพร่กระจายมีค่าต่ำกว่า 20 หน่วยเวลา การควบคุมกราฟฟิกแบบบีพีซีเอ็นด้วยนิรอลเน็ตเวิร์กส่งผลให้การประวิงเวลาในการส่งข้อมูลของแหล่งกำเนิดกราฟฟิกแบบเอบีอาร์เพิ่มขึ้นเล็กน้อยในช่วง 5%-9% เมื่อเทียบกับอัลกอริทึมอาร์แอลเอส แต่ยังคงมีค่าต่ำกว่าการควบคุมแบบบีพีซีเอ็นที่มีค่าการประวิงเวลาในการส่งข้อมูลของแหล่งกำเนิดกราฟฟิกแบบเอบีอาร์เพิ่มขึ้นในช่วง 27%-47% เมื่อเทียบกับอัลกอริทึมอาร์แอลเอส