

## บทที่ 2

### แนวคิด ทฤษฎี เอกสารและวรรณกรรมที่เกี่ยวข้อง

การศึกษาการพยากรณ์ราคาหลักทรัพย์และดัชนีตลาดหลักทรัพย์โดยใช้แบบจำลอง  
โครงข่ายประสาทเทียมเปรียบเทียบกับวิธีอาร์มา

#### แนวคิดและทฤษฎี

1. โครงข่ายประสาทเทียม (Artificial Neural Network) หรือที่มักจะเรียกสั้น ๆ ว่า  
ข่ายงานประสาท (Neural Network หรือ Neural Net) คือแบบโครงสร้างทางคณิตศาสตร์ สำหรับ  
ประมวลผลสารสนเทศด้วยการคำนวณแบบคอนเนกชันนิสต์ (Connectionist) เพื่อจำลองการ  
ทำงานของ เครือข่ายประสาทในสมองมนุษย์ ด้วยวัตถุประสงค์ที่จะสร้างเครื่องมือซึ่งมี  
ความสามารถในการเรียนรู้การจดจำรูปแบบ (Pattern Recognition) และการอนุมานความรู้  
(Knowledge Deduction) เช่นเดียวกับความสามารถที่มีในสมองมนุษย์ แนวคิดเริ่มต้นของเทคนิคนี้  
ได้มาจากการศึกษาข่ายงานไฟฟ้าชีวภาพ (Bioelectric Network) ในสมอง ซึ่งประกอบด้วย เซลล์  
ประสาท หรือ “นิวรอน” (Neurons) และ จุดประสานประสาท (Synapses) แต่ละเซลล์ประสาท  
ประกอบด้วยปลายในการรับกระแสประสาท เรียกว่า “เดนไดรต์” (Dendrite) ซึ่งเป็นด้านข้อมูล  
ขาเข้า (Input) และปลายในการส่งกระแสประสาทเรียกว่า “แอกซอน” (Axon) ซึ่งเป็นเหมือนด้าน  
ข้อมูลขาออก (Output) ของเซลล์ เซลล์เหล่านี้ทำงานด้วยปฏิกิริยาไฟฟ้าเคมี เมื่อมีการกระตุ้นด้วย  
สิ่งเร้าภายนอกหรือกระตุ้นด้วยเซลล์ด้วยกัน กระแสประสาทจะวิ่งผ่านเดนไดรต์เข้าสู่นิวเคลียสซึ่ง  
จะเป็นตัวตัดสินใจว่าต้องกระตุ้นเซลล์อื่น ๆ ต่อหรือไม่ ถ้ากระแสประสาทแรงพอ นิวเคลียสก็จะ  
กระตุ้นเซลล์อื่น ๆ ต่อไปผ่านทางแอกซอนของมัน

#### โครงสร้าง

นักวิจัยส่วนใหญ่ในปัจจุบันเห็นตรงกันว่าข่ายงานประสาทเทียมมีโครงสร้างแตกต่าง  
จากข่ายงานในสมอง แต่ก็ยังเหมือนสมอง ในแง่ที่ว่าข่ายงานประสาทเทียม คือการรวมกลุ่มแบบ  
ขนานของหน่วยประมวลผลย่อย ๆ และการเชื่อมต่อนี้เป็นส่วนสำคัญที่ทำให้เกิดสติปัญญาของ  
ข่ายงาน เมื่อพิจารณาขนาดแล้วสมองมีขนาดใหญ่กว่าข่ายงานประสาทเทียมอย่างมาก รวมทั้งเซลล์  
ประสาทยังมีความซับซ้อนกว่าหน่วยย่อยของข่ายงาน อย่างไรก็ตามหน้าที่สำคัญของสมอง เช่น การ  
เรียนรู้ยังคงสามารถถูกจำลองขึ้นอย่างง่ายด้วยโครงข่ายประสาทนี้

## หลักการ

สำหรับในคอมพิวเตอร์โครงข่ายประสาทเทียมประกอบด้วยด้านข้อมูลขาเข้า (Input) และด้านข้อมูลขาออก (Output) เหมือนกัน โดยจำลองให้ ด้านข้อมูลนำเข้าแต่ละอันมีค่าถ่วงน้ำหนัก (Weight) เป็นตัวกำหนดน้ำหนักของข้อมูลขาเข้า(Input) โดยหน่วยประสาท แต่ละหน่วย จะมีค่าทำนอง (Threshold) เป็นตัวกำหนดว่าน้ำหนักรวมของข้อมูลนำเข้าต้องมากขนาดไหนจึงจะสามารถส่งออกข้อมูลไปยังโครงข่ายประสาทเทียมตัวอื่นได้ เมื่อนำโครงข่ายประสาทเทียมแต่ละหน่วยมาต่อกันให้ทำงานร่วมกันการทำงานนี้ในทางตรรกแล้วก็จะเหมือนกับปฏิกิริยาเคมีที่เกิดขึ้นในสมอง เพียงแต่ในคอมพิวเตอร์ทุกอย่างเป็นตัวเลขเท่านั้นเอง

## การทำงาน

การทำงานของโครงข่ายประสาทเทียมคือเมื่อมีข้อมูลขาเข้า (Input) เข้ามายังโครงข่าย ก็จะเอาข้อมูลขาเข้า (Input) มาคูณกับค่าถ่วงน้ำหนัก (Weight) ของแต่ละขา ผลที่ได้จากข้อมูลขาเข้า (Input) ทุก ๆ ขาของโครงข่ายประสาทเทียมจะเอามารวมกันแล้วก็เอามาเทียบกับค่าทำนอง (Threshold) ที่กำหนดไว้ ถ้าผลรวมมีค่ามากกว่าค่าทำนอง (Threshold) แล้ว โครงข่ายประสาทเทียม ก็จะส่งข้อมูลส่งออกยังข้อมูลขาเข้า (Input) ของโครงข่ายประสาทเทียม อื่น ๆ ที่เชื่อมกันในโครงข่าย ถ้าค่าน้อยกว่าค่าทำนอง (Threshold) ก็จะไม่เกิดส่งข้อมูลขาออก (Output)

เขียนออกมาได้ดังนี้

**if (sum(input \* weight) > threshold) then output**

สิ่งสำคัญคือเราต้องทราบค่าถ่วงน้ำหนัก (Weight) และค่าทำนอง (Threshold) สำหรับสิ่งที่เราต้องการเพื่อให้คอมพิวเตอร์รู้จัก ซึ่งเป็นค่าที่ไม่แน่นอน แต่สามารถกำหนดให้คอมพิวเตอร์ปรับค่าเหล่านั้นได้โดยการสอนให้มันรู้จักรูปแบบของสิ่งที่เราต้องการให้มันรู้จัก เรียกว่า การแพร่กระจายแบบย้อนกลับ (Back Propagation) ซึ่งเป็นกระบวนการย้อนกลับของการรู้จักในการฝึกโครงข่ายประสาทเทียมแบบป้อนข้อมูลไปข้างหน้า (Feed-Forward Neural Networks) จะมีการใช้อัลกอริทึมแบบ การแพร่กระจายแบบย้อนกลับ (Back Propagation) เพื่อใช้ในการปรับปรุงน้ำหนักคะแนนของเครือข่าย (Network Weight) หลังจากใส่รูปแบบข้อมูลสำหรับฝึกให้แก่เครือข่ายในแต่ละครั้งแล้ว ด้านข้อมูลขาออก (Output) จากเครือข่ายจะถูกนำไปเปรียบเทียบกับผลที่คาดหวัง แล้วทำการคำนวณหาค่าความผิดพลาด ซึ่งค่าความผิดพลาดนี้จะถูกส่งกลับเข้าสู่เครือข่ายเพื่อใช้แก้ไขค่าน้ำหนักคะแนนต่อไป

## สถาปัตยกรรมของโครงข่าย (Network Architecture)

### โครงข่ายแบบป้อนไปข้างหน้า (Feed Forward Network)

ข้อมูลที่มีประมวลผลในวงจรข่ายจะถูกส่งไปในทิศทางเดียวจากจุดต่อด้านข้อมูลขาเข้า (Input Nodes) ส่งต่อมาเรื่อย ๆ จนถึงจุดต่อด้านขาออก (Output Nodes) โดยไม่มีการย้อนกลับของข้อมูล หรือแม้แต่จุดต่อ (Nodes) ในชั้น เดียวกันก็ไม่มี การเชื่อมต่อกัน

### โครงข่ายแบบป้อนกลับ (Feedback Network)

ข้อมูลที่มีประมวลผลในวงจรข่าย จะมีการป้อนกลับเข้าไปยังวงจรข่ายหลาย ๆ ครั้ง จนกระทั่งได้คำตอบออกมา บางทีเรียกว่าโครงข่ายแบบหมุนเวียนกลับ (Recurrent Network)

### ชั้นของโครงข่าย (Network Layer)

พื้นฐานสามัญที่สำคัญของโครงข่ายประสาทเทียม (Artificial Neural Network) ประกอบไปด้วย 3 ส่วน ได้แก่ ชั้นของหน่วยข้อมูลขาเข้า (Input Units) ที่ถูกเชื่อมต่อกับชั้นของหน่วยซ่อน (Hidden Units) ซึ่งเชื่อมต่อกับชั้นของหน่วยข้อมูลขาออก (Output Units)

- การทำงานของหน่วยข้อมูลขาเข้า (Input Units) จะทำหน้าที่แทนส่วนของข้อมูลดิบ ที่จะถูกป้อนเข้าสู่เครือข่าย
- การทำงานของแต่ละหน่วยซ่อน (Hidden Units) จะถูกกำหนดโดยการทำงานของหน่วยข้อมูลขาเข้า (Input Units) และค่าน้ำหนักบนความสัมพันธ์ระหว่างหน่วยข้อมูลขาเข้า (Input Units) และ หน่วยซ่อน (Hidden Units)
- พฤติกรรมการทำงานของหน่วยข้อมูลขาออก (Output Units) จะขึ้นอยู่กับการทำงานของหน่วยซ่อน (Hidden Units) และค่าน้ำหนักระหว่างหน่วยซ่อน (Hidden units) และหน่วยข้อมูลขาออก (Output Units)

ประเภทของเครือข่ายนี้เป็นที่น่าสนใจ เพราะเราสามารถกำหนดการแทนค่าให้แก่หน่วยข้อมูลขาเข้า (Input Units) ได้อย่างอิสระ ค่าน้ำหนักระหว่างหน่วยข้อมูลขาเข้า (Input Units) และ หน่วยซ่อน (Hidden Units) จะถูกกำหนดเมื่อหน่วยซ่อน (Hidden Units) กำลังทำงาน ฉะนั้นเวลาที่แก้ไขค่าน้ำหนักหน่วยซ่อน (Hidden Units) จะสามารถเลือกว่าอะไรคือค่าที่เราแทนเข้ามา

สถาปัตยกรรมของชั้น (Architecture of Layer) สามารถจำแนกสถาปัตยกรรมของชั้น (Layer) ออกเป็น 2 ประเภทคือ แบบชั้นเดียว (Single-Layer) และ แบบหลายชั้น (Multi-Layer)

- การรับรู้แบบชั้นเดียว (Single-Layer Perception) เครือข่ายประสาทที่ประกอบด้วยชั้นเพียงชั้นเดียว จำนวนโหนดการนำเข้าขึ้นอยู่กับจำนวนส่วนประกอบของข้อมูลนำเข้าและหน้าที่การกระตุ้น (Activation Function) ขึ้นอยู่กับลักษณะข้อมูลของข้อมูลขาออกเช่น

ถ้า ข้อมูลขาออกที่ต้องการเป็น “ใช่” หรือ “ไม่ใช่” เราจะต้องใช้ค่าสมการทำนบ (Threshold Function)

$$f(x) = \begin{cases} 1 & \text{if } x \geq T \\ 0 & \text{if } x < T \end{cases} \quad \mathbf{T=Threshold Level}$$

หรือถ้าข้อมูลขาออกเป็นค่าตัวเลขที่ต่อเนื่อง เราต้องใช้ฟังก์ชันแบบต่อเนื่อง (Continuous Function) เช่น Sigmoid Function

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

- การรับรู้แบบหลายชั้น (Multi-Layer Perception) เครือข่ายประสาทจะประกอบด้วยโครงข่ายหลายชั้นโดยในแต่ละชั้นจะประกอบด้วยโหนด (Nodes) หรือเปรียบได้กับตัวเซลล์ประสาท (Neural) ค่านำหนักของเส้นที่เชื่อมต่อระหว่างโหนดของแต่ละชั้น ค่า Bias Vector (b) และค่า Output Vector (a) โดย m เป็นตัวเลขบอกลำดับชั้นกำกับไว้ด้านบน เมื่อ p เป็น Input Vector การคำนวณค่าข้อมูลขาออกสำหรับเครือข่ายประสาทที่มี M ชั้นจะเป็นดังสมการ

$$\mathbf{a}^{m+1} = \mathbf{f}^{m+1}(\mathbf{W}^{m+1} \mathbf{a}^m + \mathbf{b}^{m+1})$$

เมื่อ  $m = 0, 2, \dots, M-1$

$$\mathbf{a}^0 = \mathbf{p}$$

$$\mathbf{a} = \mathbf{a}^m$$

และ f เป็น Transfer Function

**แบบจำลองโครงข่ายประสาทเทียมที่ใช้ในการศึกษา**

โครงข่ายประสาทเทียมจะมีสถาปัตยกรรมหลักๆ ด้วยกันสองแบบคือ โครงข่ายแบบป้อนไปข้างหน้า (Feed Forward Network) และ โครงข่ายแบบป้อนกลับ (Feedback Network) แต่ทั้งสองแบบยังสามารถนำไปประยุกต์เข้ากับทฤษฎีอื่นๆ เพื่อใช้ประโยชน์ในการพยากรณ์ในรูปแบบที่แตกต่างกันไป ตามความเหมาะสมกับลักษณะข้อมูลและจำนวนของข้อมูลแบบต่างๆ ซึ่งการศึกษาครั้งนี้ใช้แบบจำลองที่ประกอบด้วยแบบจำลองทั้งหมด 11 รูปแบบด้วยกันคือ

1. Multi-layer perceptron (MLPs) โครงข่ายประสาทเทียมแบบ MLPs เป็นรูปแบบหนึ่งของโครงข่ายประสาทเทียมที่มีโครงสร้างเป็นแบบหลายๆชั้น ใช้สำหรับงานที่มีความซับซ้อนได้ผลเป็นอย่างดี โดยมีกระบวนการฝึกฝนเป็นแบบมีผู้สอน (Supervise) และใช้ขั้นตอนการส่งค่า

ย้อนกลับ (Backpropagation) สำหรับการฝึกฝนกระบวนการส่งค่าย้อนกลับ ประกอบด้วย 2 ส่วนย่อยคือ การส่งผ่านไปข้างหน้า (Forward Pass) การส่งผ่านย้อนกลับ (Backward Pass) สำหรับการส่งผ่านไปข้างหน้า ข้อมูลจะผ่านเข้าโครงข่ายประสาทเทียมที่ชั้นข้อมูลเข้า และจะส่งผ่าน จากอีกชั้นหนึ่งไปสู่อีกชั้นหนึ่งจนกระทั่งถึงชั้นข้อมูลออก ส่วนการส่งผ่านย้อนกลับค่าน้ำหนักการเชื่อมต่อจะถูกปรับเปลี่ยนให้สอดคล้อง กับกฎการแก้ข้อผิดพลาด (Error-Correction) คือผลต่างของผลตอบที่แท้จริง (Actual Response) กับผลตอบเป้าหมาย (Target Response) เกิดเป็นสัญญาณผิดพลาด (Error Signal) ซึ่งสัญญาณผิดพลาดนี้จะถูกส่งย้อนกลับเข้าสู่โครงข่ายประสาทเทียมในทิศทาง ตรงกันข้ามกับการเชื่อมต่อ และค่าน้ำหนักของการเชื่อมต่อจะถูกปรับจนกระทั่งผลตอบที่แท้จริงเข้าใกล้ผลตอบเป้าหมาย

สัญญาณที่มีโครงข่ายประสาทเทียมแบบ MLPs มี 2 ประเภทคือ Function Signal และ Error Signal 1.2.1 Function Signal เป็นสัญญาณเข้าที่มาจากโหนดในชั้นก่อนหน้า และจะส่งผ่านไปข้างหน้าจากโหนดหนึ่งไปสู่อีกโหนดหนึ่ง 1.2.2 Error Signal เป็นสัญญาณย้อนกลับที่เกิดขึ้นที่โหนดในชั้นข้อมูลออกของโครงข่ายประสาท เทียม และถูกส่งผ่านย้อนกลับจากชั้นหนึ่งไปสู่อีกชั้นหนึ่ง

หลักการทำงานของ MLPs คือในแต่ละชั้นของชั้นซ่อนตัว (Hidden Layer) จะมีฟังก์ชันสำหรับคำนวณเมื่อได้รับสัญญาณ (Output) จากโหนดในชั้นก่อนหน้านี้ เรียกว่า Activation Function โดยในแต่ละชั้นไม่จำเป็นต้องเป็นฟังก์ชันเดียวกันก็ได้ ชั้นซ่อนตัวนั้นมีหน้าที่สำคัญคือ จะพยายามแปลงข้อมูลที่เข้ามาในชั้น (Layer) นั้นๆ ให้สามารถแยกแยะความแตกต่างโดยใช้เส้นตรงเส้นเดียว (Linearly Separable) และก่อนที่ข้อมูลจะถูกส่งไปถึงชั้นข้อมูลออก (Output Layer) ในบางครั้งอาจจำเป็นต้องใช้ชั้นซ่อนตัวมากกว่า 1 ชั้นในการแปลงข้อมูลให้อยู่ในรูป Linearly Separable

ในการค้นหา Output ในปัญหาการจำแนกทำได้โดยการใส่ข้อมูล Input เข้าไปในโครงข่ายประสาทเทียมที่เราได้ทำการหาไว้แล้ว จากนั้นให้ทำการเปรียบเทียบค่าของ Output ใน Output Layer และให้ทำการเลือกค่าของ Output ที่มีค่าสูงกว่า (Neuron ที่มีค่าสูงกว่า) และทำการรับค่าของพยากรณ์ที่ตรงกับ Neuron ที่เลือก และให้นำค่าของ มาเปรียบเทียบกับค่าที่ยอมรับได้ หากค่าของ อยู่ในช่วงที่รับได้ (Error น้อยกว่า Error ที่เรากำหนด) ก็ให้ทำการรับข้อมูลชุดถัดไป แต่หากค่าของ มากกว่าค่าที่ยอมรับได้ ให้ทำการปรับค่าน้ำหนักและ Biased ตามขั้นตอนที่ได้กล่าวไว้ข้างต้น เมื่อทำการปรับน้ำหนักเรียบร้อยแล้ว ให้ทำการรับข้อมูลชุดถัดไปและทำตามขั้นตอนซ้ำอีกรอบ

จนกระทั่งถึงข้อมูลชุด สุดท้าย และเมื่อทำข้อมูลชุดสุดท้ายเสร็จจะนับเป็น 1 รอบของการคำนวณ (1 Epoch) จากนั้นจะทำการหาค่าผิดพลาดรวมเฉลี่ย จากค่าเฉลี่ยของ ที่ได้เก็บค่าเอาไว้ เพื่อใช้ในการตรวจสอบว่าค่า โดยเฉลี่ยในการจำแนกนั้น มีค่าน้อยกว่าค่าผิดพลาดที่ยอมรับได้หรือไม่ ถ้าใช่ แสดงว่าโครงข่ายประสาทเทียมที่สร้างขึ้นนั้นสามารถให้ผลลัพธ์ที่ถูกต้องของทุกๆข้อมูลแล้ว จึงทำการจบการเรียนรู้ได้ แต่ถ้าไม่ใช่ ให้กลับไปทำตามขั้นตอนแรก โดยเริ่มรับข้อมูลชุดที่ 1 ใหม่

2. Generalized feedforward networks มีลักษณะทั่วไปคล้ายกับ MLPs เช่นสามารถเชื่อมข้ามจากชั้นซ่อนหนึ่งไปอีกหนึ่งหรือหลายชั้นได้ ในทางทฤษฎี MLPs สามารถแก้ปัญหาต่าง ๆ ที่ Generalized feedforward networks สามารถแก้ได้แต่ในทางปฏิบัติ Generalized feedforward networks มักจะแก้ปัญหาได้อย่างมีประสิทธิภาพมากกว่า ตัวอย่างที่เห็นได้ชัดคือ MLPs จะต้องการจำนวนในการเรียนรู้ที่มากกว่า Generalized feedforward networks ร้อยครั้งขึ้นไปจึงจะให้ผลการพยากรณ์ที่ใกล้เคียงกับ Generalized feedforward networks

3. Modular feedforward networks เป็น MLPs แบบพิเศษแบบหนึ่งซึ่งโครงข่ายนี้จะประมวลผลข้อมูลขาเข้าโดยใช้ MLPs หลาย ๆ ชุดซึ่งขนานวางขนานกันแล้วรวมผลภายหลังอีกครั้ง. ซึ่งมีแนวโน้มที่จะสร้างโครงสร้างบางอย่างภายในแบบโครงสร้างของโครงข่ายเฉพาะที่ซึ่งจะเสริมสร้างความเชี่ยวชาญการทำงานในแต่ละแบบจำลองย่อย ตรงกันข้ามกับโครงข่ายแบบ MLPs โครงข่ายแบบ Modular feedforward networks จะไม่มีการเชื่อมต่อภายในระหว่างชั้นซ่อนแบบเต็ม ๆ ดังนั้นจำนวนของน้ำหนักน้อย ๆ ของแต่ละชั้นซ่อนจึงต้องมีโครงข่ายขนาดเดียวกันด้วย ทำให้มีแนวโน้มที่จะเพิ่มความเร็วเวลาในการสอนและลดจำนวนตัวอย่างที่ต้องการในการสอนลงได้ ทำให้ยากที่จะเข้าใจวิธีการที่ดีที่สุดในการออกแบบจำลองโครงสร้างของโครงข่ายเฉพาะที่ตามจำนวนข้อมูลและไม่มีการรับประกันใด ๆ ว่าแต่ละแบบจำลองจะสามารถทำการสอนโครงข่ายกับข้อมูลที่ซ้ำกันได้

4. Jordan and Elman networks จะขยายแบบจำลองแบบ MLPs ด้วยหน่วยบริบท (context unit) ซึ่งจะมีองค์ประกอบที่เป็นหน่วยประมวลผลหลาย ๆ หน่วย (PEs) ที่จะทำหน้าที่จดจำกิจกรรมที่ผ่าน ๆ มาของหน่วยบริบทเพื่อให้โครงข่ายที่มีความสามารถในการดึงข้อมูลปัจจุบันจากข้อมูลทั้งหมดได้ ในส่วนของโครงข่าย Elman จะมีหน้าที่คัดลอกกิจกรรมของชั้นซ่อนแรกจะไปยังหน่วยบริบทใน ขณะที่โครงข่าย Jordan จะคัดลอกผลการคำนวณของโครงข่ายเก็บข้อมูลขาออก จากนั้นโครงข่ายทั้งคู่ก็จะป้อนข้อมูลขาเข้าและผลจากชั้นซ่อนสุดท้ายไปยังหน่วยบริบท

5. Principal component analysis networks (PCAs) จะรวมการเรียนรู้แบบไม่ถูกควบคุม (unsupervised) และแบบถูกควบคุม (supervise) ไว้ในแบบโครงสร้างเดียวกัน การวิเคราะห์องค์ประกอบหลักเป็นแบบวิธีการเชิงเส้นแบบไม่ควบคุม (unsupervised) ซึ่งประกอบด้วยกลุ่มของข้อมูลที่มีลักษณะที่ไม่เหมือนกัน, ส่วนประกอบสำคัญอื่น ๆ และจากข้อมูลขาเข้า ส่วนแบบโครงข่าย MLPs จะดูแลการจำแนกข้อมูลแบบไม่เชิงเส้นออกจากองค์ประกอบเหล่านี้

6. Radial basis function (RBF) networks เป็นโครงข่ายลูกผสมแบบไม่เป็นเชิงเส้นซึ่งมีชั้นซ่อนเพียงชั้นเดียวเป็นองค์ประกอบในการประมวลผล ชั้นซ่อนนี้ใช้ฟังก์ชันแบบ Gaussian transfer แทนที่ฟังก์ชันมาตรฐานแบบ Sigmoid ถูกใช้งานโดยโครงข่าย MLPs จุดศูนย์กลางและความกว้างของ Gaussians กำหนดโดยกฎการเรียนรู้แบบไม่ควบคุม (unsupervised) และการเรียนรู้แบบควบคุม (supervised) จะนำไปใช้ในชั้น Output ซึ่งโครงข่ายเหล่านี้มักจะเรียนรู้เร็วกว่าโครงข่ายแบบ MLPs

ถ้าหาก generalized regression (GRNN) probabilistic (PNN) ถูกเลือก ทุกน้ำหนักของโครงข่ายจะสามารถวิเคราะห์การคำนวณ ในกรณีนี้จำนวนของกลุ่มศูนย์กลางจะถูกกำหนดจำนวนเท่ากับจำนวนข้อมูลตัวอย่าง และพวกมันจะถูกกำหนดให้มีการเปลี่ยนแปลงที่เหมือนกัน Radial basis function (RBF) networks จะเหมาะสมกับการพยากรณ์ข้อมูลที่มีจำนวนข้อมูลไม่มาก (น้อยกว่า 100 ข้อมูล) หรือข้อมูลที่เป็นกลุ่มก้อนไม่กระจัดกระจาย

7. Self-organizing feature maps (SOFMs) จะแปลงข้อมูลขาเข้าที่ไม่มีมิติไปเป็นข้อมูลแบบที่มีโครงสร้างแยกหนึ่งหรือสองมิติ และจะคำนวณโดยใช้การเรียนรู้แบบ Kohonen ซึ่งเป็นการเรียนรู้แบบไม่ควบคุม (unsupervised) ข้อมูลขาออกของ SOFMs สามารถใช้เป็นข้อมูลขาเข้าเพื่อจำแนกโครงข่ายประสาทแบบควบคุมเหมือนกับ MLPs ส่วนสำคัญของโครงข่ายนี้คือการแบ่งกลุ่มข้อมูลโดยที่ SOFMs จะช่วยลดช่องว่างของข้อมูลขาเข้าโดยแทนค่าจากกระบวนการสร้างหน่วย Self-organizing ดังนั้น โครงสร้างพื้นฐานของช่องว่างของข้อมูลจะถูกเก็บไว้ในหน่วยดังกล่าว

8. Time lagged recurrent networks (TLRNs) จะขยายโครงข่าย MLPs ด้วยโครงสร้างหน่วยความจำระยะสั้น ข้อมูลจริงที่มีโครงสร้างเวลาเช่นข้อมูลจะเปลี่ยนแปลงตามเวลาอย่างไร TLRNs มีลักษณะในการพยากรณ์แบบอนุกรมเวลาแบบไม่เชิงเส้น ระบุระบบและการจำแนกรูปแบบการแยกเป็นประเภทของข้อมูล

9. Fully recurrent networks คือโครงข่ายที่ป้อนกลับข้อมูลจากชั้นซ่อนกลับมาหาตัวมันเอง และบางส่วนของโครงข่ายจะเริ่มด้วยโครงข่ายป้อนกลับแบบเต็ม (Fully recurrent network) ที่บวกเอาโครงข่ายแบบ feed forward ที่กำจัดค่าป้อนกลับทิ้งไปด้วย ประสิทธิภาพของส่วนป้อนกลับจะเป็นไปตามสภาพของหน่วยความจำโครงข่ายเหล่านี้สามารถมีความลึกของหน่วยความจำได้

มากมายและทำให้พบความสัมพันธ์ทางเวลาอย่างรวดเร็วที่สุดแล้วข้อมูลจริงจะเก็บอยู่ใน โครงสร้าง เวลา Fully recurrent network จึงจัดเป็นวิธีการพยากรณ์แบบอนุกรมเวลา ไม่เป็นเชิงเส้น ระบบการหาเอกลักษณ์และการจำแนกรูปแบบชั่วคราว

10. The CANFIS (Co-Active Neuro-Fuzzy Inference System model) จะรวมเอาข้อมูลขาเข้าที่ปรับค่าด้วย Fuzzy logic เข้าด้วยกันโครงข่ายประสาทเทียมแบบ Modular neural network ในเวลารวดเร็วและด้วยฟังก์ชันแบบประมาณที่ซับซ้อนและแม่นยำ ด้วยระบบการอนุมานแบบ Fuzzy ยังสามารถระบุค่าของพวกมันตามกฎของกล่องดำของโครงข่ายประสาทเทียม

11. The Support Vector Machine (SVM) จะดำเนินการโดยใช้อัลกอริทึม Kernel Adatron Kernel Adatron maps โดยจะป้อนข้อมูลไปยังช่องว่างที่มีมิติที่สูงกว่า และจะแยกข้อมูลในชั้นเดียวกันเข้าสู่ลำดับของมัน โดยแยกข้อมูลขาเข้าให้เข้าใกล้รอยต่อของข้อมูล ดังนั้น Kernel Adatron จะมีประสิทธิภาพในการแยกชุดข้อมูลที่ซับซ้อน SVMs สามารถจึงเหมาะสำหรับการใช้สำหรับการจำแนกข้อมูล ไม่เหมาะสำหรับการประมาณการณ์หรือการพยากรณ์

## 2. วิธีอาร์มา (ARIMA)

การพยากรณ์ด้วยวิธี Box-Jenkins ซึ่งพัฒนาขึ้น โดย Box and Jenkins จะอาศัยวิธีอาร์มา (ARIMA: Autoregressive Integrated Moving Average) ที่เป็นข้อมูลอนุกรมเวลาตัวแปรเดียวในอดีตจนกระทั่งปัจจุบัน เพื่อพยากรณ์ข้อมูลในอนาคต โดยจะครอบคลุมผลลัพธ์ที่รวมเอาอนุกรมเวลาที่เป็นฤดูกาลรวมถึงกระบวนการหรือระบบที่ไม่นิ่งด้วย (Non-Stationary Process) ทั้งนี้กระบวนการวิเคราะห์ประกอบด้วย

### การบ่งชี้ (Identification)

เนื่องจากข้อมูลอนุกรมเวลาส่วนใหญ่จะมีลักษณะที่ไม่นิ่ง (Non-stationary) ในขณะที่ลักษณะของ Autoregressive (AR) และ Moving Average (MA) ของแบบวิธีอาร์มาเป็นข้อมูลอนุกรมเวลาที่มีลักษณะนิ่ง (Stationary) ดังนั้นจึงมีความจำเป็นอย่างยิ่งที่ในการวิเคราะห์ข้อมูลนั้น เราจะต้องทำข้อมูลดังกล่าวให้มีความนิ่งเสียก่อน ซึ่งข้อมูลอนุกรมเวลาที่มีลักษณะนิ่งจะต้อง (1) ค่าเฉลี่ย (2) ค่าความแปรปรวน และ (3) ค่าความแปรปรวนร่วมมีค่าคงที่ โดยการนำข้อมูลอนุกรมเวลา มาหารระดับผลต่าง (Difference) ถ้าสมมติให้สมการอย่างง่าย คือ

$$Y_t = Y_{t-1} + \varepsilon_t$$

ผลต่างอันดับที่ 1 (First Difference)

$$Y'_t = Y_t - Y_{t-1} + \varepsilon_t$$

หรือ

$$Y'_t = \Delta Y_t + \varepsilon_t$$



ผลต่างอันดับที่ 2 (Second-Order Difference)

$$Y_t'' = Y_t' - Y_{t-1}' + \varepsilon_t$$

หรือ 
$$Y_t'' = \Delta Y_t' + \varepsilon_t$$

### ระบบอัตถดถอย (Autoregressive Processes)

ระบบอัตถดถอย AR(p) คือ ระบบ AR แสดงให้เห็นว่าข้อมูลอนุกรมเวลาขึ้นอยู่กับข้อมูลความล่าช้าในอดีตอันดับ p ซึ่งสามารถนำมาเขียนในรูปสมการได้ดังนี้

$$Y_t = \delta_0 + \delta_1 Y_{t-1} + \delta_2 Y_{t-2} + \dots + \delta_p Y_{t-p} + e_t$$

โดยที่  $\delta_0$  = ค่าคงที่  
 $\delta_1, \delta_2, \dots, \delta_p$  = ค่าสัมประสิทธิ์ของตัวแปรล่าช้า  
 $Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}$  = ตัวแปรล่าช้าของ Y  
 $e_t$  = ค่าความคลาดเคลื่อน

### ระบบเฉลี่ยเคลื่อนที่ (Moving Average Processes)

ระบบเฉลี่ยเคลื่อนที่ MA (q) คือ ระบบ MA แสดงให้เห็นว่าข้อมูลอนุกรมเวลาขึ้นอยู่กับความคลาดเคลื่อนในปัจจุบันและความคลาดเคลื่อนของความล่าช้าอันดับ q ซึ่งสามารถนำมาเขียนในรูปสมการได้ดังนี้

$$Y_t = \phi_0 + e_t - \phi_1 e_{t-1} - \phi_2 e_{t-2} + \dots + \phi_q e_{t-q}$$

โดยที่  $\phi_0$  = ค่าคงที่  
 $\phi_1, \phi_2, \dots, \phi_p$  = ค่าสัมประสิทธิ์ของตัวแปรล่าช้า  
 $e_{t-1}, e_{t-2}, \dots, e_{t-q}$  = ตัวแปรล่าช้าของค่าความคลาดเคลื่อน  
 $e_t$  = ค่าความคลาดเคลื่อน

เมื่อนำความสัมพันธ์ระหว่าง AR และ MA มารวมกัน ก็จะได้รูปแบบระบบใหม่ที่เรียกว่า

ARMA ซึ่งในกรณีที่ข้อมูลมีลักษณะนิ่ง (Stationary) รูปแบบของแบบจำลอง ARIMA(p,d,q) จะมีรูปแบบเป็น ARIMA(p,0,q) ซึ่งเหมือน ARMA(p,q) โดยสามารถเขียนในรูปแบบจำลองได้ดังนี้

$$Y_t = \delta_0 + \delta_1 Y_{t-1} + \delta_2 Y_{t-2} + \dots + \delta_p Y_{t-p} + e_t - \phi_1 e_{t-1} - \phi_2 e_{t-2} + \dots + \phi_q e_{t-q}$$

ในกรณีที่ข้อมูลไม่นิ่ง (Non-Stationary) รูปแบบของแบบจำลอง ARIMA (p,d,q) จะมีลักษณะดังนี้

$$\Delta^d Y_t = \delta_0 + \delta_1 \Delta^d Y_{t-1} + \delta_2 \Delta^d Y_{t-2} + \dots + \delta_p \Delta^d Y_{t-p} + e_t - \phi_1 e_{t-1} - \phi_2 e_{t-2} + \dots + \phi_q e_{t-q}$$

โดยที่  $\Delta^d$  = อันดับผลต่างของข้อมูล

ทั้งนี้ เราสามารถนำแบบจำลองดังกล่าวมาใช้ในการประมาณการ เพื่อหาแบบจำลองที่เหมาะสมที่สุดสำหรับการพยากรณ์ โดยมีเกณฑ์ในการเลือกแบบจำลองดังนี้

(1การพิจารณาค่า Akaike's Information Criterion (AIC) มีสูตรดังนี้

$$AIC = \log \hat{\sigma}^2 + 2 \frac{p+q}{T}$$

โดยที่  $\hat{\sigma}^2$  = ค่าประมาณของความแปรปรวนของ  $e_t$

(2การพิจารณาค่า Schwartz's Bayesian Information Criterion (BIC หรือ SBC) มีสูตรดังนี้

$$BIC = \log \hat{\sigma}^2 + 2 \frac{p+q}{T} \log T$$

ทั้งสองเกณฑ์จะพิจารณาแบบจำลองที่ให้ค่า AIC หรือ BIC ต่ำสุด ในกรณีที่เกณฑ์ทั้งสองให้ผลที่แตกต่างกันให้เลือกใช้ BIC ก่อน เพราะ BIC มีคุณสมบัติว่า BIC จะเลือกแบบจำลองที่ถูกต้องเกือบแน่นอน ถ้า  $T \rightarrow \infty$  โดยกำหนดว่าแบบจำลองที่ถูกต้องอยู่ในรูปแบบของ ARMA(p,q) สำหรับค่า p และ q มีขนาดเล็ก

**เกณฑ์การพิจารณาค่าพยากรณ์ที่เหมาะสม**

ในการพิจารณาแบบจำลองที่เหมาะสมในการพยากรณ์นั้น เราสามารถพิจารณาความแตกต่างระหว่างค่าที่แท้จริงกับค่าพยากรณ์ หรือที่เราเรียกว่า “ค่าความคลาดเคลื่อน (Residuals)” ซึ่งมีรูปแบบสมการดังนี้

$$e_t = Y_t - \hat{Y}_t$$

โดยที่  $e_t$  = ความคลาดเคลื่อนจากการพยากรณ์ในช่วงเวลา t

$Y_t$  = ค่าของข้อมูลจริงในช่วงเวลา t

$\hat{Y}_t$  = ค่าที่พยากรณ์ในช่วงเวลา t

### 3. เปรียบเทียบข้อมูลทางสถิติ

1. ค่าเฉลี่ยความคลาดเคลื่อนที่แท้จริง (Mean Absolute Deviation: MAD) ซึ่งสามารถใช้วัดความแม่นยำของค่าพยากรณ์ โดยการเฉลี่ยค่าความผิดพลาดของค่าพยากรณ์ ซึ่งจะมีประโยชน์มากสำหรับการวิเคราะห์ที่ต้องการวัดความผิดพลาดในหน่วยเดียวกันกับข้อมูลอนุกรมเวลาเดิม มีรูปแบบสมการในการพิจารณาดังนี้

$$MAD = \frac{1}{n} \sum_{t=1}^n |Y_t - \hat{Y}_t|; \text{เมื่อ } n \text{ เป็นจำนวนคาบเวลา } t \text{ ทั้งหมด}$$

2. ค่าเฉลี่ยความผิดพลาดกำลังสอง (Mean Square Error: MSE) ใช้สำหรับหาค่าความแตกต่างระหว่างค่าพยากรณ์และค่าจริงเป็นวิธีการวัดความถูกต้องแม่นยำในการพยากรณ์และกำจัดทิศทางการพยากรณ์ (ไม่คิดทิศทางบวกหรือลบ) ซึ่งสามารถคำนวณได้จากการนำ MSE มาหารากที่สอง ซึ่งมีรูปแบบสมการในการพิจารณาดังนี้

$$MSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2}; \text{เมื่อ } n \text{ เป็นจำนวนคาบเวลา } t \text{ ทั้งหมด}$$

3. ร้อยละของค่าเฉลี่ยความผิดพลาด (Mean Absolute Percentage Error: MAPE) ซึ่งสามารถหาได้จากนำค่าความผิดพลาดที่แท้จริงในแต่ละช่วงเวลาหารด้วยข้อมูลจริงในช่วงเวลานั้น และเฉลี่ยความผิดพลาดที่แท้จริงให้อยู่ในรูปร้อยละ เพื่อใช้สำหรับการเปรียบเทียบความแม่นยำสำหรับชุดข้อมูลที่อยู่ในช่วงแตกต่างกัน ซึ่งมีรูปแบบสมการในการพิจารณาดังนี้

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right|; \text{เมื่อ } n \text{ เป็นจำนวนคาบเวลา } t \text{ ทั้งหมด}$$

ทั้งนี้ จะต้องพิจารณาว่าค่าพยากรณ์ใดที่ให้ค่าสถิติต่างๆ ดังกล่าวที่กล่าวมาข้างต้นนั้นต้องมีค่าต่ำสุด เพื่อให้ค่าความแม่นยำในการพยากรณ์สูงสุด และต้องใช้ในการเปรียบเทียบทั้งสามแบบเพื่อเปรียบเทียบทั้งนี้หากใช้เพียง MAD บางครั้งได้ค่าต่ำมากแต่อาจเกิดจากการหักล้างกันของข้อมูลทำให้ได้ค่า MAD ที่ต่ำจำเป็นต้อง MSE ประกอบเพื่อทำให้ค่าความผิดพลาดเป็นค่าสมบูรณ์ก่อน ส่วน MAPE จะใช้ปรับให้ค่าเฉลี่ยความผิดพลาดของการพยากรณ์ของแต่ละดัชนี แต่ละหลักทรัพย์อยู่ในรูปร้อยละ เหมือนกันก่อนจึงจะสามารถเปรียบเทียบความแม่นยำระหว่างกันได้

### วรรณกรรมที่เกี่ยวข้อง

จิตติ ตันเสนีย์ (2549) ศึกษาเรื่องการเปรียบเทียบความแม่นยำในการพยากรณ์ราคาหลักทรัพย์ระหว่างแบบจำลองโครงข่ายประสาทเทียมกับแบบจำลองอาร์มาและการ์ชเอ็ม มีวัตถุประสงค์เพื่อหาแบบจำลองโครงข่ายประสาทเทียมที่เหมาะสมที่สุดสำหรับการพยากรณ์ราคาหลักทรัพย์ และเปรียบเทียบความแม่นยำ โดยใช้ดัชนี SET50 และราคาหลักทรัพย์ของบริษัท PTT TPI และ BBL ซึ่งผลการศึกษาพบว่าแบบจำลองอาร์มาและการ์ชเอ็ม มีความแม่นยำกว่าแบบจำลองโครงข่ายประสาทเทียม สาเหตุเนื่องมาจาก มีข้อบกพร่องในการสร้างแบบจำลองที่ใช้จำนวนนำเข้าและจำนวนนิวรอลในชั้นซ่อน (Hidden Layer) มากเกินไป นอกจากนี้ยังเลือกแบบจำลองสำหรับการใช้พยากรณ์โดยพิจารณาจากค่า MSE ซึ่งอาจเกิดปัญหา Over Fitting ขึ้นได้

ศุภเชษฐ์ กันนัม (2547) ศึกษาเรื่องการประยุกต์ใช้โครงข่ายประสาทเทียมเพื่อพัฒนารูปแบบการพยากรณ์ยอดขายจักรยานยนต์ภายในประเทศไทย ผ่านการวิเคราะห์ความสัมพันธ์ของตัวแปรอิสระที่คาดว่าจะมีผลต่อความต้องการรถจักรยานยนต์ภายในประเทศ 11 ปัจจัย ซึ่งตัวแปรเหล่านี้เป็นดัชนีชี้วัดสถานะทางเศรษฐกิจของประเทศอันประกอบไปด้วย อัตราแลกเปลี่ยนเงินตราต่างประเทศ ราคาทองคำ มูลค่าสินค้าส่งออก มูลค่าสินค้านำเข้า ค่าใช้จ่ายภาครัฐ อัตราค่าจ้างขั้นต่ำ อัตราเงินเฟ้อ อัตราการว่างงาน ราคาน้ำมันเบนซิน และผลิตภัณฑ์มวลรวมภายในประเทศ ในการพยากรณ์โดยวิธีโครงข่ายประสาทเทียมผ่านโปรแกรม Neurosolution 4.21 ค่าอัตราการเรียนรู้ในชั้นอินเดน เท่ากับ 1 ค่าอัตราการเรียนรู้ในชั้นเอาท์พุทเท่ากับ 0.1 ค่าโมเมนตัม เท่ากับ 0.7 จำนวนรอบในการเรียนรู้ 5000 รอบ เมื่อเปรียบเทียบค่าความคลาดเคลื่อนยกกำลังสอง (Mean Square Error) ของการพยากรณ์โดยวิธีปัจจุบันกับการพยากรณ์โดยวิธีโครงข่ายประสาทเทียมพบว่า การพยากรณ์โดยวิธีโครงข่ายประสาทเทียมมีความแม่นยำกว่าการพยากรณ์โดยวิธีปัจจุบัน และมีความเหมาะสมที่จะนำมาใช้ในการวางแผนการผลิต

ประภาพรรณ ปั้นโอ (2546) ศึกษาเรื่องต้นแบบการพยากรณ์ราคาหุ้นในตลาดหลักทรัพย์ ด้วยวิธีของโครงข่ายนิวรอล โดยมุ่งที่การปรับปรุงวิธีการสอนโครงข่ายนิวรอลให้เกิดการเรียนรู้เพื่อให้เกิดความถูกต้องของผลการพยากรณ์ที่มากขึ้นในทั้งสองด้านด้วยกันคือ ความถูกต้องของค่าพยากรณ์ได้จริง และความถูกต้องของทิศทางการขึ้นลงของค่าเหล่านั้น การสอนโครงข่ายนิวรอลทำโดยการป้อนอินพุทจำนวนมากเข้าสู่โครงข่ายเพื่อให้เกิดการเรียนรู้ โดยพยายามลดขนาดของค่ามัธยฐานของความผิดพลาดที่เกิดขึ้นยกกำลังสอง (Mean Squared Error) จากผลต่างระหว่างค่าคาดหวังกับค่าที่พยากรณ์ได้จริงระหว่างการสอนในแต่ละรอบ วิธีการที่ใช้ในการหาขนาดความคลาดเคลื่อน เพื่อจะนำไปปรับเปลี่ยนค่าน้ำหนักเรียกว่า Two-Step Continuous Fluctuation Direction (TSCFD) ซึ่งแนวทางการแก้ปัญหาที่น่าเสนอนี้จะถูกทดสอบประสิทธิภาพ

โดยใช้แบบจำลองนี้ไปพยากรณ์ค่าของชุดข้อมูลทดสอบที่อยู่ในรูปแบบของอนุกรมเวลา จาก 3 แหล่งคือข้อมูลราคาปีคองหุ้น 2 ตัวคือ AHOLD และ IBM และข้อมูลที่ได้จำลองขึ้นมาจาก Mackey-Glass Equation ผลของการทดลองที่ได้จากการเลือกใช้รูปแบบการสอนโครงข่ายแบบ TSCFD เพื่อพยากรณ์ข้อมูลในอีก 1 จุดข้างหน้าสำหรับโครงข่ายแบบ 20-2-1 ให้ผลของ Tolerance 1%, Tolerance 5% และ POCDF สำหรับข้อมูลทั้ง 3 แหล่งเฉลี่ยแล้วประมาณ 75%, 90% และ 80% ตามลำดับ

คมสัน สุริยะ (2548) ศึกษาการพยากรณ์ราคาน้ำมันดิบด้วยแบบจำลอง Neural Network การศึกษาได้สร้างแบบจำลองเพื่อพยากรณ์ราคาน้ำมันดิบ โดยใช้กฎการปรับค่าน้ำหนักแบบย้อนกลับ (Back propagation) ใช้ราคาน้ำมันดิบ Brent รายวันเป็นข้อมูลนำเข้าในการสร้างแบบจำลอง เมื่อสร้างแบบจำลองแล้วจะใช้แบบจำลองนั้นพยากรณ์ไปข้างหน้าทีละ 1 วัน เป็นจำนวน 34 วัน และนำค่าที่พยากรณ์ได้มาวัดความแม่นยำโดยเปรียบเทียบกับค่าที่เกิดขึ้นจริงด้วยวิธี Mean Absolute Percentage Error (MAPE) ในการหาแบบจำลอง Neural Network ที่ดีที่สุด การศึกษานี้ได้ใช้วิธีการกำหนดจำนวนข้อมูลนำเข้าไว้ให้มีจำนวน 10 ค่า และทำการเปลี่ยนจำนวนนิวรอลในชั้นซ่อน (Hidden Layer) เพื่อหาจำนวนนิวรอลที่จะให้ค่า MAPE ที่ต่ำที่สุดโดยใช้หลักการหาค่าต่ำสุดแบบ Quadratic Interpolation ผลการศึกษาพบว่าแบบจำลองซึ่งมีจำนวนข้อมูลนำเข้า 10 ค่าและมีจำนวนนิวรอลในชั้นซ่อน (hidden layer) จำนวน 200 นิวรอล มีความสามารถในการพยากรณ์ราคาน้ำมัน Brent รายวันได้ดีที่สุด โดยมี MAPE ต่ำกว่าแบบจำลองอื่นๆ (ประมาณ 1.8%)

วัลลภา อุนวิจิตร(2539) ศึกษาการพยากรณ์ราคาน้ำมันดิบด้วยแบบจำลอง Neural Networks โดยใช้กฎการปรับค่าน้ำหนักแบบ Back propagation โดยใช้ข้อมูลราคาน้ำมันดิบรายวันจากแหล่งโอมานเป็นข้อมูลนำเข้า ทำการพยากรณ์ไปข้างหน้า 1 วัน ในการกำหนดจำนวนข้อมูลนำเข้าและจำนวนข้อมูลนำเข้าและจำนวนนิวรอลในชั้นซ่อน (Hidden Layer) ที่เหมาะสมทำโดยทำการทดลองสร้างแบบจำลองที่มีจำนวนข้อมูลนำเข้าต่างกัน 6 การทดลอง (ใช้ข้อมูลนำเข้าจำนวน 20, 40, 80, 160, 320 และ 460 ค่า) และกำหนดจำนวนนิวรอลในชั้นซ่อนเริ่มต้นเท่ากับ  $\sqrt{mn}$  นิวรอล เมื่อ  $m =$  จำนวนนิวรอลของชั้นข้อมูลนำเข้า และ  $n =$  จำนวน นิวรอลของชั้นแสดงผลลัพธ์ ค่าพยากรณ์ที่ได้มาของการพยากรณ์ ผลการศึกษาพบว่าแบบจำลองที่มีจำนวนข้อมูลนำเข้าจำนวน 160 ค่ามีความสามารถในการพยากรณ์ราคาน้ำมันดิบรายวันได้ดีที่สุด โดยมี MAPE ต่ำกว่าแบบจำลองอื่นๆ