



การคาดการณ์แนวโน้มหุ้นด้วยเทคนิคการรวมแบบจำลองโหวต
Forecasting Stock Trends using Vote Ensemble Technique

ศรียพอง สุภา

สาขาวิชาวิศวกรรมคอมพิวเตอร์ คณะเทคโนโลยีดิจิทัล
มหาวิทยาลัยราชภัฏเชียงราย
ปีการศึกษา 2566

(ลิขสิทธิ์ของมหาวิทยาลัยราชภัฏเชียงราย)
การคาดการณ์แนวโน้มด้วยเทคนิคการรวมแบบจำลองโหวต



การคาดการณ์แนวโน้มหุ้นด้วยเทคนิคการรวมแบบจำลองโหวต
Forecasting Stock Trends using Vote Ensemble Technique

ศรียอง สุภา

สาขาวิชาวิศวกรรมคอมพิวเตอร์ คณะเทคโนโลยีดิจิทัล
มหาวิทยาลัยราชภัฏเชียงราย
ปีการศึกษา 2566

บทคัดย่อ

ชื่องานวิจัย : การคาดการณ์แนวโน้มหุ้นด้วยเทคนิคการรวมแบบจำลองโหวต
ชื่อผู้วิจัย : นางสาวศรียพอง สุภา
สาขาวิชา : วิศวกรรมคอมพิวเตอร์
ปีการศึกษา : 2566
อาจารย์ที่ปรึกษา : ผศ.ดร.ธนาวุฒิ ธนวานิชย์

การลงทุนในตลาดหุ้นมีความซับซ้อน และเป็นสถานะที่ท้าทายสำหรับผู้ที่ไม่มีประสบการณ์ ไม่มีความรู้ ไม่มีความเข้าใจเรื่องการวิเคราะห์ปัจจัยพื้นฐานของหุ้น หรือการวิเคราะห์ข้อมูลโดยใช้ตัวชี้วัดในการวิเคราะห์หุ้น บทความนี้จึงนำเสนอการใช้การคาดการณ์แนวโน้มหุ้นด้วยเทคนิคการรวมแบบจำลองโหวต ในการพัฒนาแบบจำลองให้สามารถคาดการณ์แนวโน้มหุ้น เพื่อเพิ่มความแม่นยำในการคาดการณ์แนวโน้มหุ้น และเพิ่มโอกาสในการรับผลกำไรให้กับนักลงทุนในการลงทุนหุ้น โดยทดสอบข้อมูลราคาหุ้นของบริษัท Apple เป็นเวลา 5 ปีได้ผลความแม่นยำแบบ F1-Score ของแบบจำลองต้นไม่ตัดสินใจเฉลี่ยประมาณ 59.67% และผลความแม่นยำแบบ F1-Score ของโครงข่ายประสาทเทียมเฉลี่ยประมาณ 65.61% และเมื่อนำการวิเคราะห์ข้อมูลด้วยเทคนิค Internal Bar Strength แบบจำลองต้นไม่ตัดสินใจ และแบบจำลองโครงข่ายประสาทเทียม รวมกันด้วยเทคนิคการรวมแบบจำลองโหวต ได้แบบจำลองโหวตที่มีผลความแม่นยำแบบ F1-Score เฉลี่ยประมาณ 67.96% ซึ่งมีค่า F1-Score มากที่สุด ดังนั้น การคาดการณ์แนวโน้มหุ้นด้วยเทคนิคการรวมแบบจำลองโหวต ทำให้มีผลประสิทธิภาพความแม่นยำในการคาดการณ์แนวโน้มหุ้นเพิ่มขึ้น

กิตติกรรมประกาศ

การพัฒนาแบบจำลองการคาดการณ์แนวโน้มหุ้นด้วยเทคนิคการรวมแบบจำลองโหวต จะสำเร็จลุล่วงไปด้วยดีไม่ได้ หากไม่ได้รับความกรุณาจากบุคคลหลายท่าน ข้าพเจ้า ขอขอบคุณบุคคลสำคัญดังที่จะกล่าวถึง ดังต่อไปนี้เป็นอย่างยิ่งที่ช่วยให้คำแนะนำแก้ไขปัญหา ตลอดจนช่วยให้ข้าพเจ้าทำการพัฒนาแบบจำลองการคาดการณ์แนวโน้มหุ้นด้วยเทคนิคการรวมแบบจำลองโหวต สำเร็จลุล่วงไปได้ด้วยดี ซึ่งได้แก่ บิดามารดา ที่ให้การสนับสนุน ตลอดจน ผศ.ดร.ธนาวุฒิ ธนวานิชย์ อาจารย์ที่ปรึกษา ผศ.ดร.ภูมิพงษ์ ดวงตั้ง ผศ.ดร.กฤตกรณ์ ศรีวันนา ผศ.ดร.มยุร ไยบัวเทศ ผศ.กมล บุญล้อม และอาจารย์อริคม ศิริ ที่คอยสั่งสอนวิชาเพื่อนำไปใช้ในการทำงาน ให้คำปรึกษา และคำแนะนำ ในการคาดการณ์แนวโน้มหุ้นด้วยเทคนิคการรวมแบบจำลองโหวต ตั้งแต่เริ่มต้นจนเสร็จสิ้นกระบวนการทำงาน

สำหรับคุณงามความดีที่เกิดจากการพัฒนาแบบจำลองการคาดการณ์แนวโน้มหุ้นด้วยเทคนิคการรวมแบบจำลองโหวต ข้าพเจ้าขอมอบให้กับบิดามารดา ผู้ซึ่งเป็นที่รัก และเคารพยิ่ง ตลอดจนครูอาจารย์ที่เคารพทุกท่านที่ได้ประสิทธิ์ประสาท วิชาความรู้ และถ่ายทอดประสบการณ์ที่ดีต่อข้าพเจ้า ช่วยเหลือ และแนะนำสิ่งที่ดีให้กับข้าพเจ้า

ศรีฟอง สุภา

ตุลาคม 2566

สารบัญ

	หน้า
บทคัดย่อ	ก
กิตติกรรมประกาศ	ข
สารบัญ	ค
สารบัญตาราง	จ
สารบัญภาพ	ช
บทที่	
1 บทนำ	1
1.1 ที่มาและความสำคัญ	1
1.2 วัตถุประสงค์	1
1.3 ประโยชน์ที่คาดว่าจะได้รับ	2
1.4 ขอบเขตของการวิจัย	2
2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง	3
2.1 ตลาดหุ้น	3
2.2 การวิเคราะห์หุ้น	4
2.3 การเรียนรู้ของเครื่อง	9
2.4 การประเมินประสิทธิภาพแบบจำลอง	15
2.5 งานวิจัยที่เกี่ยวข้อง	18
3 วิธีดำเนินการวิจัย	19
3.1 การเตรียมข้อมูล	20
3.2 การแบ่งชุดข้อมูล	25
3.3 การสร้างแบบจำลอง	26
3.4 การประเมินผล	29

สารบัญ (ต่อ)

บทที่	หน้า
4 ผลการทดลอง	31
4.1 ประสิทธิภาพการคาดการณ์ราคาหุ้น ก่อนใช้แบบจำลองต้นไม้ตัดสินใจ และแบบจำลองโครงข่ายประสาทเทียม ร่วมกับเทคนิค Internal Bar Strength	31
4.2 ประสิทธิภาพการคาดการณ์ราคาหุ้น หลังใช้แบบจำลองต้นไม้ตัดสินใจ และแบบจำลองโครงข่ายประสาทเทียม ร่วมกับเทคนิค Internal Bar Strength	44
4.3 การพัฒนาประสิทธิภาพการคาดการณ์ราคาหุ้น โดยใช้แบบจำลองต้นไม้ตัดสินใจ และแบบจำลองโครงข่ายประสาทเทียม ร่วมกับเทคนิค Internal Bar Strength	46
5 สรุปผลการวิจัย	51
5.1 สรุปผลการทดลอง	51
5.2 อภิปรายผลการวิจัย	52
5.3 ข้อเสนอแนะการวิจัย	52
บรรณานุกรม	53
ภาคผนวก	54
ภาคผนวก ก	55
ประวัติผู้วิจัย	56

สารบัญตาราง (ต่อ)

ตารางที่	หน้า
3.1	ข้อมูลราคาหุ้นบริษัท Tesla จำนวน 5 วัน 21
3.2	ค่า EMA ย้อนหลัง 5 วัน จากข้อมูลราคาหุ้นบริษัท Tesla จำนวน 5 วัน 22
3.3	ค่า EMA ย้อนหลัง 20 วัน จากข้อมูลราคาหุ้นบริษัท Tesla จำนวน 5 วัน 22
3.4	ค่า EMA ย้อนหลัง 100 วัน จากข้อมูลราคาหุ้นบริษัท Tesla จำนวน 5 วัน 22
3.5	ตัวอย่างการแสดงค่าคุณลักษณะ 8 ข้อมูล 23
3.6	ข้อมูลราคาหุ้นบริษัท Tesla จำนวน 5 วัน 24
3.7	รายละเอียดชุดข้อมูลราคาหุ้น 25
4.1	ร้อยละของประสิทธิภาพความแม่นยำในการคาดการณ์แนวน้ำหุ้น และร้อยละของค่าความผิดพลาดในการคาดการณ์แนวน้ำหุ้น กับชุดข้อมูลราคาหุ้นบริษัท Apple ด้วยแบบจำลองต้นไม้ตัดสินใจ 32
4.2	ร้อยละของประสิทธิภาพความแม่นยำในการคาดการณ์แนวน้ำหุ้น และร้อยละของค่า ความผิดพลาดในการคาดการณ์แนวน้ำหุ้น กับชุดข้อมูลราคาหุ้นบริษัท Meta Platforms Inc ด้วยแบบจำลองต้นไม้ตัดสินใจ 32
4.3	ร้อยละของประสิทธิภาพความแม่นยำในการคาดการณ์แนวน้ำหุ้น และร้อยละของค่าความผิดพลาดในการคาดการณ์แนวน้ำหุ้น กับชุดข้อมูลราคาหุ้นบริษัท Tesla ด้วยแบบจำลองต้นไม้ตัดสินใจ 32
4.4	แบบจำลองโครงข่ายประสาทเทียมที่มี Hidden Node จำนวน 4 Node, Batch Size ขนาด 4 และ Epochs จำนวน 100 รอบ 300 รอบ และ 500 รอบ 34
4.5	แบบจำลองโครงข่ายประสาทเทียมที่มี Hidden Node จำนวน 4 Node, Batch Size ขนาด 16 และ Epochs จำนวน 100 รอบ 300 รอบ และ 500 รอบ 34
4.6	แบบจำลองโครงข่ายประสาทเทียมที่มี Hidden Node 4 จำนวน Node, Batch Size ขนาด 32 และ Epochs จำนวน 100 รอบ 300 รอบ และ 500 รอบ 35

สารบัญตาราง (ต่อ)

ตารางที่		หน้า
4.7	แบบจำลองโครงข่ายประสาทเทียมที่มี Hidden Node จำนวน 16 Node, Batch Size ขนาด 4 และ Epochs จำนวน 100 รอบ 300 รอบ และ 500 รอบ	36
4.8	แบบจำลองโครงข่ายประสาทเทียมที่มี Hidden Node จำนวน 16 Node, Batch Size ขนาด 16 และ Epochs จำนวน 100 รอบ 300 รอบ และ 500 รอบ	36
4.9	แบบจำลองโครงข่ายประสาทเทียมที่มี Hidden Node จำนวน 16 Node, Batch Size ขนาด 32 และ Epochs จำนวน 100 รอบ 300 รอบ และ 500 รอบ	36
4.10	แบบจำลองโครงข่ายประสาทเทียมที่มี Hidden Node จำนวน 32 Node, Batch Size ขนาด 4 และ Epochs จำนวน 100 รอบ 300 รอบ และ 500 รอบ	38
4.11	แบบจำลองโครงข่ายประสาทเทียมที่มี Hidden Node จำนวน 32 Node, Batch Size ขนาด 16 และ Epochs จำนวน 100 รอบ 300 รอบ และ 500 รอบ	38
4.12	แบบจำลองโครงข่ายประสาทเทียมที่มี Hidden Node จำนวน 32 Node, Batch Size ขนาด 32 และ Epochs จำนวน 100 รอบ 300 รอบ และ 500 รอบ	38
4.13	แบบจำลองโครงข่ายประสาทเทียมที่มี Hidden Node จำนวน 64 Node, Batch Size ขนาด 4 และ Epochs จำนวน 100 รอบ 300 รอบ และ 500 รอบ	39
4.14	แบบจำลองโครงข่ายประสาทเทียมที่มี Hidden Node จำนวน 64 Node, Batch Size ขนาด 16 และ Epochs จำนวน 100 รอบ 300 รอบ และ 500 รอบ	40
4.15	แบบจำลองโครงข่ายประสาทเทียมที่มี Hidden Node จำนวน 64 Node, Batch Size ขนาด 32 และ Epochs จำนวน 100 รอบ 300 รอบ และ 500 รอบ	40

สารบัญตาราง (ต่อ)

ตารางที่		หน้า
4.16	ผลประสิทธิภาพที่ดีที่สุดของการปรับจำนวน Hidden Node ขนาด Batch Size และจำนวน Epochs ในแบบจำลองโครงข่ายประสาทเทียม	41
4.17	ร้อยละของประสิทธิภาพความแม่นยำในการคาดการณ์แนวโน้มหุ้น และร้อยละของค่าความผิดพลาดในการคาดการณ์แนวโน้มหุ้น กับชุดข้อมูลราคาหุ้นบริษัท Apple ด้วยแบบจำลองโครงข่ายประสาทเทียม	42
4.18	ร้อยละของประสิทธิภาพความแม่นยำในการคาดการณ์แนวโน้มหุ้น และร้อยละของค่าความผิดพลาดในการคาดการณ์แนวโน้มหุ้น กับชุดข้อมูลราคาหุ้นบริษัท Meta Platforms Inc ด้วยแบบจำลองโครงข่ายประสาทเทียม	43
4.19	ร้อยละของประสิทธิภาพความแม่นยำในการคาดการณ์แนวโน้มหุ้น และร้อยละของค่าความผิดพลาดในการคาดการณ์แนวโน้มหุ้น กับชุดข้อมูลราคาหุ้นบริษัท Tesla ด้วยแบบจำลองโครงข่ายประสาทเทียม	43
4.20	ร้อยละของประสิทธิภาพความแม่นยำในการคาดการณ์แนวโน้มหุ้น และร้อยละของค่าความผิดพลาดในการคาดการณ์แนวโน้มหุ้น กับชุดข้อมูลราคาหุ้นบริษัท Apple ด้วยแบบจำลองโหนด	44
4.21	ร้อยละของประสิทธิภาพความแม่นยำในการคาดการณ์แนวโน้มหุ้น และร้อยละของค่าความผิดพลาดในการคาดการณ์แนวโน้มหุ้น กับชุดข้อมูลราคาหุ้นบริษัท Meta Platforms Inc ด้วยแบบจำลองโหนด	45
4.22	ร้อยละของประสิทธิภาพความแม่นยำในการคาดการณ์แนวโน้มหุ้น และร้อยละของค่าความผิดพลาดในการคาดการณ์แนวโน้มหุ้น กับชุดข้อมูลราคาหุ้นบริษัท Tesla ด้วยแบบจำลองโหนด	45
4.23	ร้อยละของประสิทธิภาพความแม่นยำในการคาดการณ์แนวโน้มหุ้น กับชุดข้อมูลราคาหุ้นบริษัท Apple ก่อนและหลังใช้แบบจำลองโหนด	46
4.24	ร้อยละของประสิทธิภาพความแม่นยำในการคาดการณ์แนวโน้มหุ้น กับชุดข้อมูลราคาหุ้นบริษัท Meta Platforms Inc ก่อนและหลังใช้แบบจำลองโหนด	47
4.25	ร้อยละของประสิทธิภาพความแม่นยำในการคาดการณ์แนวโน้มหุ้น กับชุดข้อมูลราคาหุ้นบริษัท Tesla ก่อนและหลังใช้แบบจำลองโหนด	49

สารบัญภาพ (ต่อ)

ภาพที่	หน้า	
2.1	รายละเอียดราคาในกราฟแท่งเทียน	5
2.2	กราฟแท่งเทียน และเส้นค่าเฉลี่ยเคลื่อนที่แบบเอ็กซ์โพเนนเชียล 5 วัน 20 วัน และ 100 วัน	6
2.3	กราฟแท่งเทียน และเส้น Moving Average Convergence Divergence (MACD)	7
2.4	กราฟแท่งเทียน และเส้นค่าความแข็งแกร่งของราคา (IBS)	8
2.5	โครงสร้างแบบจำลองต้นไม้ตัดสินใจ	10
2.6	แบบจำลองโครงข่ายประสาทในสมองมนุษย์	12
2.7	กระบวนการสร้างแบบจำลองโครงข่ายประสาทเทียม	13
2.8	กระบวนการทำงานของโครงข่ายประสาทเทียม	14
2.9	ส่วนประกอบ 4 ส่วนของ Confusion Matrix	15
3.1	ขั้นตอนการสร้างแบบจำลอง และประเมินผลแบบจำลอง	19
3.2	กระบวนการสร้างแบบจำลองต้นไม้ตัดสินใจ	26
3.3	แบบจำลองต้นไม้ตัดสินใจ	27
3.4	กระบวนการสร้างแบบจำลองโครงข่ายประสาทเทียม	28
3.5	กระบวนการทำงานของการสร้างแบบจำลองโหนด	29
4.1	ความแม่นยำของแบบจำลองโครงข่ายประสาทเทียมที่มี Hidden Node จำนวน 4 Node	35
4.2	ความแม่นยำของแบบจำลองโครงข่ายประสาทเทียมที่มี Hidden Node จำนวน 16 Node	37
4.3	ความแม่นยำของแบบจำลองโครงข่ายประสาทเทียมที่มี Hidden Node จำนวน 32 Node	39
4.4	ความแม่นยำของแบบจำลองโครงข่ายประสาทเทียมที่มี Hidden Node จำนวน 64 Node	41

สารบัญภาพ (ต่อ)

ภาพที่		หน้า
4.5	ร้อยละของความแม่นยำ ก่อนและหลังใช้แบบจำลองโหวต กับราคาหุ้นบริษัท Apple	47
4.6	ร้อยละของความแม่นยำ ก่อนและหลังใช้แบบจำลองโหวต กับราคาหุ้นบริษัท Meta Platforms Inc	48
4.7	ร้อยละของความแม่นยำ ก่อนและหลังใช้แบบจำลองโหวต กับราคาหุ้นบริษัท Tesla	49
ก.1	โค้ดการสร้างแบบจำลองโหวต	55

บทที่ 1

บทนำ

1.1 ที่มาและความสำคัญ

การลงทุนในตลาดหุ้นที่มีความผันผวนสูง เกิดจากปัจจัยหลายด้านที่มีผลกระทบต่อราคาหุ้น เช่น ด้านเศรษฐกิจ ด้านสังคม และด้านการเมือง เป็นต้น ทำให้เกิดนักวิเคราะห์ปัจจัยพื้นฐานหุ้น และนักวิเคราะห์ทางเทคนิค หรือ Technical Analysis ที่พัฒนาหลักการใช้เส้นกราฟราคา เพื่อทำนายแนวโน้มของราคาหุ้น โดยมีจุดเริ่มต้นในคริสต์ศตวรรษที่ 17 และ 18 มีการพัฒนาตัวชี้วัด หรือ Indicator เกิดขึ้นมากมาย เช่น ตัวชี้วัดแนวโน้มราคาหุ้น หรือ Moving Average Convergence Divergence ตัวชี้วัดค่าเฉลี่ยเคลื่อนที่แบบเอ็กซ์โพเนนเชียล หรือ Exponential Moving Average ตัวชี้วัดการแกว่งตัวของราคาหุ้น หรือ Relative Strength Index และตัวชี้วัดความแข็งแกร่งของราคาหุ้น หรือ Internal Bar Strength ซึ่งการมีตัวชี้วัดจำนวนมาก ทำให้นักลงทุนที่ขาดความรู้ และประสบการณ์ในการลงทุนในตลาดหุ้น ไม่สามารถวิเคราะห์แนวโน้มของราคาหุ้นด้วยการใช้ตัวชี้วัดที่มีอยู่มากมายให้เกิดประสิทธิภาพต่อการลงทุนในตลาดหุ้นได้

นักลงทุนที่ไม่สามารถใช้ตัวชี้วัดในการวิเคราะห์หุ้นที่มีความซับซ้อน ยากต่อการเข้าใจ และไม่สามารถนำไปใช้ให้เกิดประโยชน์ หรือใช้งานได้อย่างมีประสิทธิภาพต่อการลงทุนในตลาดหุ้น รวมถึงนักลงทุนที่ไม่มีองค์ความรู้ในหลากหลายด้าน เช่น ไม่สามารถวิเคราะห์กราฟราคาหุ้น หรือไม่สามารถวิเคราะห์ปัจจัยพื้นฐานของบริษัทที่จะทำการเลือกซื้อหุ้นได้อย่างเหมาะสม ส่งผลให้ผู้ลงทุนเกิดความเสียหาย และสูญเสียเงินลงทุนในตลาดหุ้น เพื่อช่วยลดความเสี่ยงในการสูญเสียเงินลงทุนในตลาดหุ้นของนักลงทุน ผู้วิจัยจึงศึกษาการเรียนรู้ของเครื่อง หรือ Machine Learning เช่นการสร้างแบบจำลองต้นไม้ตัดสินใจ การสร้างแบบจำลองโครงข่ายประสาทเทียม และวิธีการวิเคราะห์ข้อมูลจากตัวชี้วัดที่ใช้เทคนิคการวัดความแข็งแกร่งของราคาหุ้น และเทคนิคค่าเฉลี่ยเคลื่อนที่แบบเอ็กซ์โพเนนเชียล

ดังนั้น ในงานวิจัยเล่มนี้ ผู้วิจัยได้นำเทคนิคการรวมแบบจำลองโหวต ในการสร้างแบบจำลอง เพื่อนำมาใช้ในคาดการณ์แนวโน้มหุ้นให้มีประสิทธิภาพความแม่นยำสูง และเพื่อช่วยลดความเสี่ยงในการสูญเสียเงินลงทุนจากการตัดสินใจซื้อหุ้นผิดพลาดให้กับนักลงทุน และผู้ที่สนใจในการลงทุน

1.2 วัตถุประสงค์

เพื่อพัฒนาแบบจำลองที่มีประสิทธิภาพความแม่นยำในการคาดการณ์แนวโน้มหุ้น

1.3 ประโยชน์ที่คาดว่าจะได้รับ

ได้แบบจำลองที่มีประสิทธิภาพความแม่นยำในการคาดการณ์แนวโน้มหุ้น

1.4 ขอบเขตของการวิจัย

แบบจำลองสามารถคาดการณ์แนวโน้มหุ้นแบบรายวัน

บทที่ 2

ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

การศึกษาวิจัยเรื่อง “การคาดการณ์แนวโน้มหุ้นด้วยเทคนิคการรวมแบบจำลองโหวต” ผู้วิจัยได้ศึกษา ทฤษฎีและงานวิจัยที่เกี่ยวข้องเพื่อใช้ประกอบเป็นแนวทางในการ ทำวิจัยโดยแยก ออกเป็น 5 หัวข้อดังต่อไปนี้

- 2.1 ตลาดหุ้น
- 2.2 การวิเคราะห์หุ้น
- 2.3 การเรียนรู้ของเครื่อง
- 2.4 การประเมินประสิทธิภาพแบบจำลอง
- 2.5 งานวิจัยที่เกี่ยวข้อง

2.1 ตลาดหุ้น

หุ้น หรือ Stock คือตราสารทางการเงินที่บริษัทเปิดขายเพื่อระดมทุนจากผู้ลงทุนใน สาธารณะ ซึ่งผู้ถือหุ้นจะกลายเป็นเจ้าของบางส่วนของบริษัท และจะมีสิทธิพิเศษในการแบ่งปันผล กำไร สิทธิในทรัพย์สินของบริษัท และสิทธิในการมีส่วนร่วมในการตัดสินใจในทางธุรกิจ ข้อตกลงของ กิจการนั้น [1] โดยหุ้นจะแบ่งออกเป็น 2 ประเภทดังนี้

1. หุ้นสามัญ หรือ Common Stock คือตราสารทางการเงินที่บริษัทมหาชนออกให้เพื่อ ระดมทุนจากผู้ลงทุนในสาธารณะ โดยผู้ถือหุ้นสามัญมีสิทธิร่วมเป็นเจ้าของบริษัท มีสิทธิใน การแสดงความคิดเห็น และลงมติในที่ประชุมของผู้ถือหุ้นตามสัดส่วนของหุ้นที่ถือ ใน การมีส่วนร่วมตัดสินใจในเรื่องสำคัญที่เกี่ยวข้องกับกิจการ เช่น การเพิ่มทุน การจ่ายปัน ผล หรือการควบรวมกิจการ เป็นต้น
2. หุ้นบุริมสิทธิ หรือ Preferred Stock คือรูปแบบหนึ่งของตราสารทางการเงินที่ให้ผู้ถือ หุ้นมีส่วนร่วมเป็นเจ้าของกิจการเหมือนกับหุ้นสามัญ โดยผู้ถือหุ้นสามัญมีสิทธิในการ ออกเสียงลงมติในที่ประชุมผู้ถือหุ้น แต่ผู้ถือหุ้นบุริมสิทธิไม่มีสิทธิในลาลงมติในที่ประชุม ผู้ถือหุ้น และผู้ถือหุ้นบุริมสิทธิจะได้รับประโยชน์บางประการที่ไม่มีให้กับผู้ถือหุ้นสามัญ เช่น เมื่อกิจการมีกำไร ผู้ถือหุ้นบุริมสิทธิจะได้รับเงินปันผลในอัตราคงที่ที่กำหนด ล่วงหน้า และเมื่อบริษัทต้องปิดตัวหรือทำการขายทรัพย์สิน ผู้ถือหุ้นบุริมสิทธิจะได้รับ เงินคืนทุนก่อนผู้ถือหุ้นสามัญ

ตลาดหุ้น หรือ Stock Market คือศูนย์กลางการซื้อขายหลักทรัพย์ เช่นหุ้นสามัญ หุ้นบุริมสิทธิ และตราสารทางการเงินที่บริษัทได้ทำการจดทะเบียนในตลาดหลักทรัพย์ โดยตลาดหุ้นมีความสำคัญในเศรษฐกิจ เนื่องจากเป็นศูนย์รวมทรัพย์สิน และช่องทางในการระดมทุนสำหรับบริษัท ซึ่งการซื้อขายหุ้นในตลาดหุ้นเป็นที่รู้จักในวงการด้านการเงินที่มีการจดทะเบียน และการซื้อขายที่มีเป็นที่นิยมในปัจจุบันเกิดขึ้นในทศวรรษที่ 17 และต้นศตวรรษที่ 18

2.2 การวิเคราะห์หุ้น

การวิเคราะห์หุ้นเป็นกระบวนการทางการเงินที่นักลงทุนใช้เพื่อทำความเข้าใจ และวิเคราะห์เพื่อประเมินความคาดหวังในการลงทุนในหุ้นหรือหลักทรัพย์ทางการเงิน ที่มีการซื้อขายในตลาดหุ้น ซึ่งการวิเคราะห์มีหลายประเภท และมีหลายมุมมองที่แตกต่างกันตามวัตถุประสงค์ หรือมาตรการในการวิเคราะห์หุ้น

2.2.1 การวิเคราะห์พื้นฐาน

การวิเคราะห์พื้นฐาน หรือ Fundamental Analysis เป็นกระบวนการวิเคราะห์ทางการเงินที่ใช้ข้อมูลพื้นฐานของบริษัท หรือหลักทรัพย์เพื่อประเมินมูลค่า และความเหมาะสมในการลงทุน การวิเคราะห์พื้นฐานจะมุ่งเน้นดูที่ปัจจัยทางเศรษฐกิจ การเงิน และการจัดการของบริษัทเพื่อทำนายประสิทธิภาพของหลักทรัพย์ในอนาคต โดยการวิเคราะห์ปัจจัยหลัก 5 ปัจจัยดังนี้

1. การวิเคราะห์ทางเศรษฐกิจ คือการตรวจสอบสถานการณ์ทางเศรษฐกิจทั่วไป เช่น อัตราการเติบโตของ GDP อัตราดอกเบี้ย และค่าเงินสกุล
2. การวิเคราะห์การเงิน คือการศึกษารายงานการเงิน เพื่อดูสภาพคล่องทางการเงิน กำไรสุทธิ และการกระทำทางการเงินที่สำคัญ
3. การวิเคราะห์ตลาดและอุตสาหกรรม คือการตรวจสอบภาวะ และแนวโน้มของตลาดที่บริษัทดำเนินธุรกิจ รวมถึงการวิเคราะห์การแข่งขัน และโอกาสในอุตสาหกรรม
4. การวิเคราะห์การจัดการ คือการสำรวจความสามารถในการบริหารจัดการของทีมผู้บริหาร นโยบายการบริหาร และแผนยุทธศาสตร์ทางธุรกิจ
5. การวิเคราะห์การคาดการณ์ของตลาด คือการทำนายการคาดการณ์ของตลาดเกี่ยวกับผลประโยชน์ของบริษัทในอนาคต
6. การวิเคราะห์สิ่งแวดล้อม คือการพิจารณาปัจจัยทางสิ่งแวดล้อมที่อาจมีผลต่อกิจการ เช่น นโยบายกฎหมาย สิ่งแวดล้อม และเหตุการณ์ทางสังคม

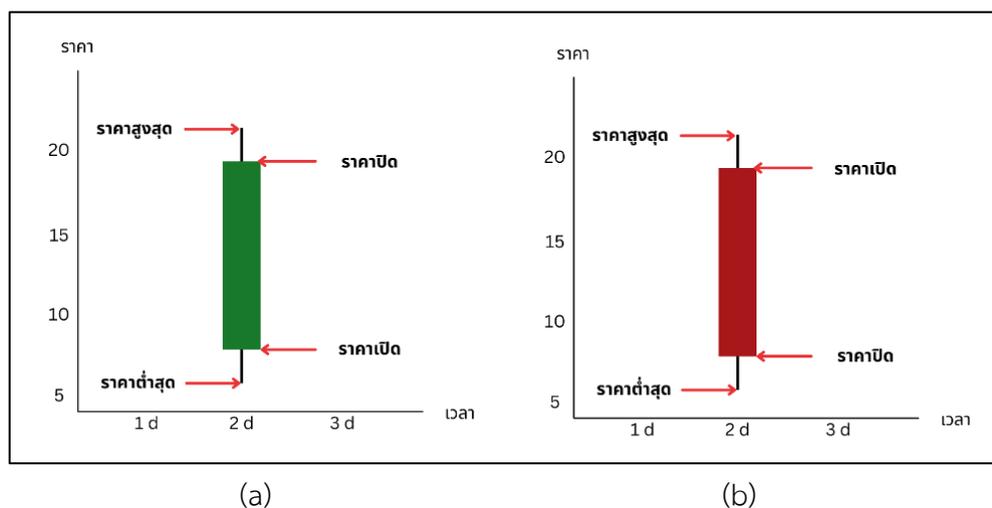
2.2.1 การวิเคราะห์ทางเทคนิค

การวิเคราะห์ทางเทคนิค หรือ Technical Analysis เป็นกระบวนการที่ใช้ข้อมูลราคา และปริมาณการซื้อขายของหลักทรัพย์เพื่อทำนายแนวโน้มในอนาคต โดยนักลงทุนจะวิเคราะห์จากใช้ตัวชี้วัด เพื่อช่วยในการตัดสินใจการลงทุน

ตัวชี้วัด หรือ Indicator หมายถึงข้อมูลหรือสัญญาณที่ถูกนำมาใช้เพื่อประเมินวิเคราะห์สภาพของตลาด หรือหลักทรัพย์ โดยตัวชี้วัดจะนำเข้ามาใช้ในกราฟหรือระบบการซื้อขาย เพื่อช่วยในการตัดสินใจการลงทุน

กราฟแท่งเทียน หรือ Candlestick Chart [2] เป็นรูปแบบหนึ่งของแผนภูมิทางเทคนิคที่ใช้แสดงข้อมูลการซื้อขายของหลักทรัพย์ สามารถแสดงแนวโน้ม ระดับราคาที่สำคัญ และสภาพตลาดได้อย่างชัดเจน ซึ่งในแต่ละแท่งเทียนจะแสดงราคาเปิดหรือ Open ราคาปิดหรือ Close ราคาสูงสุดหรือ High และราคาต่ำสุดหรือ Low ของหลักทรัพย์ในช่วงเวลาที่กำหนด โดยแท่งเทียนมีส่วนหลัก 3 ส่วนของดังนี้

1. ไส้เทียนด้านบน หรือ Upper Shadow คือจุดที่ไส้เทียนอยู่สูงสุดของแท่งเทียน แสดงราคาสูงสุดในช่วงเวลา
2. ไส้เทียนด้านล่าง หรือ Lower Shadow คือจุดที่ไส้เทียนอยู่ต่ำสุดของแท่งเทียน แสดงราคาต่ำสุดในช่วงเวลา
3. เนื้อเทียน หรือ Body คือส่วนที่อยู่ระหว่างราคาเปิดและราคาปิด



ภาพที่ 2.1 รายละเอียดราคาในกราฟแท่งเทียน

จากภาพที่ 2.1 เป็นการอธิบายรายละเอียดราคาในกราฟแท่งเทียน โดยสามารถแบ่งออกเป็น ลักษณะทั่วไปของแท่งเทียนดังนี้

1. ราคาเปิด หรือ Open คือราคาซื้อครั้งแรกที่เกิดขึ้นในช่วงเวลาเปิดที่กำหนด
2. ราคาปิด หรือ Close คือราคาซื้อสุดท้ายที่เกิดขึ้นในช่วงเวลาปิดที่กำหนด
3. ราคาสูงสุด หรือ High คือการเคลื่อนไหวของราคาหุ้นในจุดสูงสุดที่กำหนด
4. ราคาต่ำสุด หรือ Low คือการเคลื่อนไหวของราคาหุ้นในจุดต่ำสุดที่กำหนด

เมื่อราคาปิดมีค่ามากกว่าราคาเปิดเนื้อเทียนจะเป็นสีเขียว ดังภาพที่ 2.1 (a) และเมื่อราคาปิดมีค่าน้อยกว่าราคาเปิดเนื้อเทียนจะเป็นสีแดง ดังภาพที่ 2.1 (b) เมื่อถึงเวลาที่เวลากำหนดจะได้แท่งเทียนหนึ่งแท่ง โดยกราฟแท่งเทียนนิยมกำหนดช่วงเวลา 1 วัน 1 สัปดาห์ และ 1 เดือน

เส้นค่าเฉลี่ยเคลื่อนที่แบบเอ็กซ์โพเนนเชียล หรือ Exponential Moving Average (EMA) คือตัวชี้วัดทางเทคนิคที่ใช้ในการประมวลผลราคาหลักทรัพย์หรือตลาดหุ้น โดย EMA จะให้ความสำคัญกับข้อมูลราคาล่าสุดมากกว่าข้อมูลราคาในอดีต ซึ่งการให้น้ำหนักกับข้อมูลราคาล่าสุดทำให้ EMA มีการเปลี่ยนแปลงเร็วมากขึ้นตามการเคลื่อนที่ของราคา



ภาพที่ 2.2 กราฟแท่งเทียน และเส้นค่าเฉลี่ยเคลื่อนที่แบบเอ็กซ์โพเนนเชียล 5 วัน 20 วัน และ 100 วัน

จากภาพที่ 2.2 เป็นการแสดงตัวอย่างกราฟแท่งเทียนและเส้นค่าเฉลี่ยเคลื่อนที่แบบเอ็กซ์โพเนนเชียลย้อนหลัง 5 วัน 20 วัน และ 100 วัน ของค่าเงิน BTCUSDT โดยมีแกน Y เป็นข้อมูลราคา และแกน X เป็นวันที่ เริ่มต้นวันที่ 13 พฤศจิกายน 2022 จนถึงวันที่ 04 พฤศจิกายน 2023 ซึ่งเส้นสีฟ้า คือเส้น EMA100 หมายถึงค่า EMA ย้อนหลัง 100 วัน เส้นสีส้ม คือเส้น EMA20 หมายถึงค่า

EMA ย้อนหลัง 20 วัน และเส้นสีแดง คือเส้น EMA100 หมายถึงค่า EMA ย้อนหลัง 5 โดยมีสมการคำนวณค่าเฉลี่ยเคลื่อนที่ดังนี้

$$EMA_T = (\text{Alpha} \times \text{Close}_T) + ((1 - \text{Alpha}) \times EMA_{T-1}) \quad (2.1)$$

เมื่อ

- T คือ ระยะเวลาที่กำหนด
- EMA_T คือ ค่า Exponential Moving Average ของวันที่ T
- Alpha คือ ค่าส่วนเสริม คำนวณได้จากสมการ Smoothing Factor $\div (T + 1)$ โดยในกรณีทั่วไปจะให้ Smoothing Factor เท่ากับ 2 และ N คือ จำนวนวันที่ใช้ในการคำนวณ EMA
- Close_T คือ ข้อมูลราคาของหลักทรัพย์ของวันที่ T
- EMA_{T-1} คือ ค่า Exponential Moving Average ในวันก่อนหน้า T

เส้นแนวโน้ม เส้นแนวโน้ม หรือเส้น Moving Average Convergence Divergence (MACD) คือตัวชี้วัดทางเทคนิคที่ใช้ในการวิเคราะห์แนวโน้มของราคาหลักทรัพย์ และแรงส่งของราคาหุ้น โดย MACD เป็นการประยุกต์ใช้ค่าเส้นค่าเฉลี่ยเคลื่อนที่แบบเอ็กซ์โพเนนเชียลย้อนหลัง 3 ค่า คือ EMA ย้อนหลัง 9 วัน 12 วัน และ 26 วัน ในการนำมาวิเคราะห์ให้มีความซับซ้อนมากขึ้น



ภาพที่ 2.3 กราฟแท่งเทียน และเส้น Moving Average Convergence Divergence (MACD)

จากภาพที่ 2.3 เป็นการแสดงตัวอย่างกราฟแท่งเทียน และเส้น Moving Average Convergence Divergence (MACD) ของค่าเงิน BTCUSDT โดยมีแกน Y เป็นข้อมูลราคา และแกน X เป็นวันที่ เริ่มต้นวันที่ 13 พฤศจิกายน 2022 จนถึงวันที่ 04 พฤศจิกายน 2023 ซึ่งในภาพที่ 2.3 ดังล่างมีรูปสี่เหลี่ยมผืนผ้าสีส้ม คือตัวชี้วัดเส้นแนวโน้ม หรือเส้น Moving Average Convergence Divergence (MACD) โดยมีค่ากึ่งกลางเป็น 0 เส้นสีส้มเป็น Signal Line หรือค่าจากเส้นค่าเฉลี่ยเคลื่อนที่ 9 วัน เส้นสีน้ำเงินเป็น MACD Line หรือค่าส่วนต่างระหว่างค่า EMA ย้อนหลัง 12 วัน และ EMA ย้อนหลัง 26 วัน เส้น Histogram เป็นสีเขียวเมื่อเส้น Signal Line มีค่ามากกว่า MACD Line และเส้น Histogram เป็นสีแดงเมื่อเส้น Signal Line มีค่าน้อยกว่า MACD Line

การวัดความแข็งแกร่งของราคา หรือ Internal Bar Strength (IBS) คือตัวชี้วัดทางเทคนิคที่ใช้ในการวัดความแข็งแกร่งของราคาภายในช่วงเวลาที่กำหนด โดย Internal Bar Strength จะคำนวณจากข้อมูลราคาเปิด ราคาสูงสุด ราคาต่ำสุด และราคาปิดราคาในช่วงเวลาที่กำหนด



ภาพที่ 2.4 กราฟแท่งเทียน และเส้นค่าความแข็งแกร่งของราคา (IBS)

จากภาพที่ 2.4 เป็นการแสดงตัวอย่างกราฟแท่งเทียน และเส้นค่าความแข็งแกร่งของราคา ของค่าเงิน BTCUSDT โดยมีแกน Y เป็นข้อมูลราคา และแกน X เป็นวันที่ เริ่มต้นวันที่ 13

พฤศจิกายน 2022 จนถึงวันที่ 04 พฤศจิกายน 2023 ซึ่งในภาพที่ 2.4 ดังล่างมีรูปสี่เหลี่ยมผืนผ้าสีส้ม คือตัวชี้วัดค่าความแข็งแกร่งของราคา หรือ Internal Bar Strength (IBS) เป็นเส้นสีฟ้ามีค่าไม่ระหว่าง 0 ถึง 1 โดยสามารถคำนวณได้จากสมการ Internal Bar Strength ได้ดังนี้

$$IBS = \frac{\text{ราคาเปิด} - \text{ราคาต่ำสุด}}{\text{ราคาสูง} - \text{ราคาต่ำสุด}} \quad (2.2)$$

2.3 การเรียนรู้ของเครื่อง

การเรียนรู้ของเครื่อง หรือ Machine Learning คือกระบวนการที่ระบบคอมพิวเตอร์ได้รับข้อมูล และเรียนรู้จากข้อมูลนั้น เพื่อให้สามารถทำงานหรือตัดสินใจได้โดยไม่ต้องมีการโปรแกรมให้โดยตรง ซึ่งมีหลักการทำงานดังนี้

1. การเก็บข้อมูล หรือ Data Collection คือการเก็บข้อมูลจากหลากหลายแหล่ง เช่น ภาพ เสียง ข้อความ หรือข้อมูลตาราง โดยข้อมูลที่เก็บรวบรวมมาจะเป็นตัวอย่าง หรือรายละเอียดที่การเรียนรู้ของเครื่องจะใช้ในการเรียนรู้
2. การเตรียมข้อมูล หรือ Data Preprocessing คือข้อมูลที่ถูกรวบรวมซึ่งมักจะไม่สมบูรณ์ ดังนั้นจึงจำเป็นต้องมีการตรวจสอบ และเตรียมข้อมูลเพื่อให้ข้อมูลเหมาะสมในการนำมาใช้ในการเรียนรู้
3. การสร้างแบบจำลอง หรือ Model Building คือการเลือกโมเดลที่เหมาะสมกับปัญหา และการสร้างโมเดลเพื่อให้มีความสามารถในการทำนายหรือจัดกลุ่มข้อมูล
4. การฝึกแบบจำลอง หรือ Training Model คือการใช้ข้อมูลที่เป็นชุดตัวอย่างในการฝึกแบบจำลอง ซึ่งจะทำให้แบบจำลองปรับค่าพารามิเตอร์ที่เหมาะสม เพื่อให้มีความสามารถในการทำนายข้อมูล
5. การทดสอบและประเมิน หรือ Testing and Evaluation คือการใช้ทดสอบข้อมูลที่ไม่ได้ถูกใช้ในการฝึกจำลองเพื่อวัดประสิทธิภาพ และความแม่นยำของแบบจำลอง

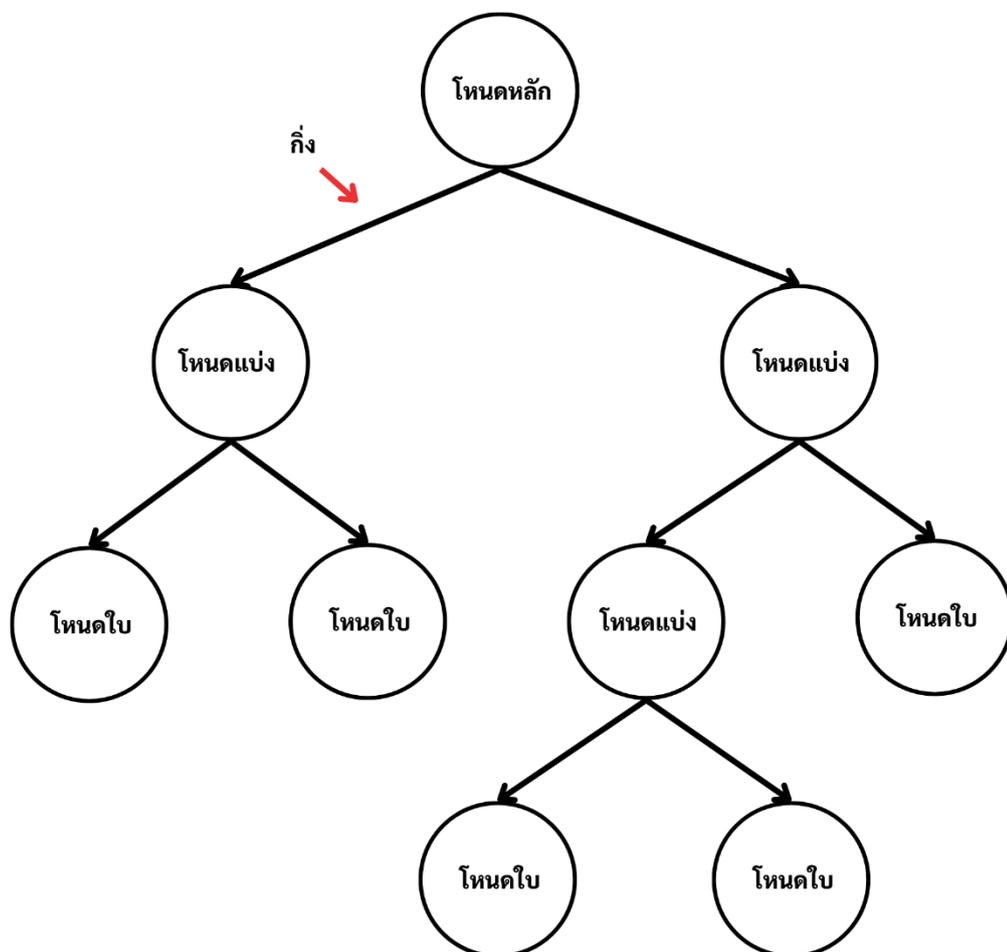
การเรียนรู้ของเครื่องได้รับความสนใจมากขึ้นในปัจจุบัน และมีการนำไปใช้ในหลายสาขา เช่น เศรษฐศาสตร์ การแพทย์ ภาษาศาสตร์ วิทยาศาสตร์ข้อมูล และการวิเคราะห์ข้อมูลที่มีปริมาณมาก โดยการเรียนรู้ของเครื่องสามารถแบ่งออกเป็น 2 ประเภทได้ดังนี้

2.3.1 การเรียนรู้แบบมีผู้สอน

การเรียนรู้แบบมีผู้สอน หรือ Supervised Learning คือแบบจำลองที่ถูกฝึกด้วยชุดข้อมูลที่มีคำตอบสำหรับการทำนาย ซึ่งแสดงถึงผลลัพธ์ที่ถูกต้องสำหรับข้อมูลนั้น โดยแบบจำลองจะ

ทำการเรียนรู้จากข้อมูล และคำตอบที่ให้แก่ และเมื่อหลังการฝึกแบบจำลองเสร็จสิ้นนี้ แบบจำลองจะสามารถทำนายผลลัพธ์สำหรับข้อมูลใหม่ที่ไม่เคยเห็นมาก่อน โดยการเรียนรู้แบบมีผู้สอนมีอัลกอริทึมหรือ algorithm ที่ใช้ในการสร้างแบบจำลองมากมายตัวอย่าง เช่น Decision Trees, Naive Bayes, Neural Networks, Linear Regression และ Artificial Neural Network

แบบจำลองต้นไม้ตัดสินใจ หรือ Decision Tree คือแบบจำลองที่มีโครงสร้างคล้ายกับต้นไม้ โดยมีรากอยู่ด้านบน และใบอยู่ด้านล่าง ซึ่งการใช้แบบจำลองนี้เหมือนกับการทำนายตามลำดับเงื่อนไขที่เชื่อมโยงกัน และช่วยในการทำนายผลลัพธ์ตามเงื่อนไขที่ถูกกำหนดไว้ล่วงหน้า ดังภาพที่ 2.5 [3]



ภาพที่ 2.5 โครงสร้างแบบจำลองต้นไม้ตัดสินใจ

จากภาพ 2.5 เป็นโครงสร้างแบบจำลองต้นไม้ตัดสินใจที่มีโครงสร้างคล้ายกับต้นไม้ โดยมีองค์ประกอบของแบบจำลองต้นไม้ตัดสินใจดังนี้

1. โหนดหลัก หรือ Root Node เป็นโหนดที่อยู่ทางด้านบนของต้นไม้ มีเพียงโหนดเดียว
2. โหนดแบ่ง หรือ Split Node เป็นโหนดที่ใช้เงื่อนไขเพื่อแบ่งข้อมูล
3. โหนดใบ หรือ Leaf Node เป็นโหนดที่ไม่มีการแบ่งเพิ่มเติม และใช้สำหรับการทำนาย
4. กิ่ง หรือ Branches เป็นการเชื่อมโหนดแบ่งกับโหนดใบ

แบบจำลองต้นไม้ตัดสินใจใช้สำหรับการทำ Classification Tree โดยวิธีการตัดสินใจใน Decision Node เป็นสิ่งสำคัญเพราะมีผลกระทบต่อความถูกต้องของแบบจำลอง ซึ่งการคำนวณหาค่า Gini Impurity หรือ Entropy เป็นการหาจุดที่ดีที่สุดในการแบ่งข้อมูล โดยการคำนวณหาค่า Gini Impurity หรือ Entropy สำหรับแต่ละโหนดที่ต้องการแบ่งข้อมูล จากนั้นให้เลือกการแบ่งที่ทำให้ Gini Impurity หรือ Entropy มีค่าน้อยที่สุด และทำซ้ำในขั้นตอนการคำนวณ กับการเลือกแบ่งจะเป็นการสร้างโครงสร้างต้นไม้ [4]

1. ความไม่บริสุทธิ์ของจินี หรือ Gini Impurity เป็นการวัดค่าความไม่บริสุทธิ์ (Impurity) ในแต่ละ Decision Node โดยการจำแนกจะแบ่งออกเป็นสองกลุ่มที่ควรเป็นกลุ่มข้อมูลที่ชัดเจน เช่น 0 และ 1 ซึ่งการที่ค่า Gini Impurity ต่ำจะทำให้การแบ่งข้อมูลออกมาได้ดี

$$\text{Gini}(X) = 1 - \sum_{i=1}^k P_i^2 \quad (2.3)$$

เมื่อ

- | | | |
|-------|-----|---|
| X | คือ | กลุ่มข้อมูลที่พิจารณา |
| K | คือ | จำนวนของคลาส หรือประเภทในกลุ่มข้อมูล |
| P_i | คือ | ความน่าจะเป็นของตัวอย่างที่ถูกจำแนกเป็นคลาส i |

2. เอ็นโทรปี หรือ Entropy เป็นเป็นตัวบ่งชี้ความไม่แน่นอนของกลุ่มข้อมูลที่ถูกแบ่งออกมาจาก Split Node ซึ่งการที่ค่า Entropy ต่ำจะทำให้การแบ่งข้อมูลออกมาได้ดี

$$\text{Entropy}(X) = - \sum_{i=1}^K P_i \cdot \log_2(P_i) \tag{2.4}$$

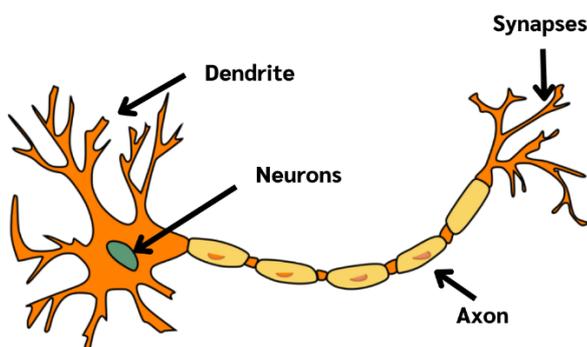
เมื่อ

- X คือ กลุ่มข้อมูลที่พิจารณา
- k คือ จำนวนของคลาส หรือประเภทในกลุ่มข้อมูล
- Pi คือ ความน่าจะเป็นของตัวอย่างที่ถูกจำแนกเป็นคลาส i

3. ประโยชน์ข้อมูล หรือ Information Gain เป็นชุดคำสั่งที่ช่วยในการจำแนกกลุ่มข้อมูล ซึ่งคุณลักษณะที่มี Information Gain สูงสุดจะได้เป็น Root Node เมื่อการคำนวณค่า Entropy ในแต่ละ Split Node แล้ว Information Gain มีค่ามากจะแสดงความสามารถในการแยกที่ดี

$$\text{Information Gain} = 1 - \text{Entropy} \tag{2.5}$$

แบบจำลองโครงข่ายประสาทเทียม หรือ Artificial Neural Network (ANN) เป็นแบบจำลองที่จำลองการทำงานของระบบประสาทเทียมในสมองมนุษย์ ถูกออกแบบให้ทำงานคล้ายกับประสาทของสมองมนุษย์เพื่อประมวลผลข้อมูลและเรียนรู้จากประสบการณ์ ซึ่งประกอบไปด้วย Neurons, Synapses, Dendrite และ Axon ดังภาพที่ 2.6 [5]



ภาพที่ 2.6 แบบจำลองโครงข่ายประสาทในสมองมนุษย์

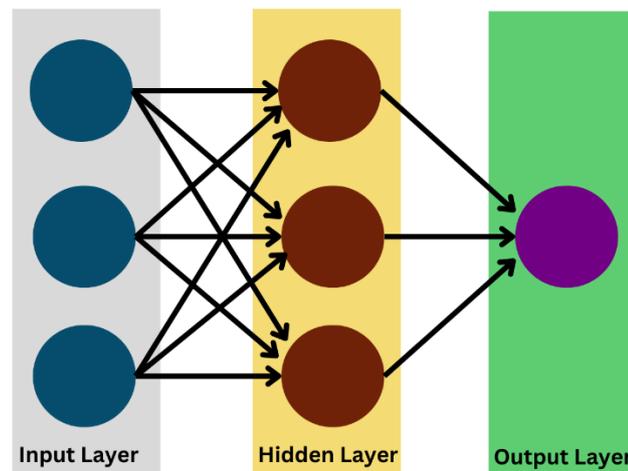
จากภาพที่ 2.6 คือระบบแบบจำลองโครงข่ายประสาทในสมองมนุษย์ประกอบด้วย 4 ส่วน ได้แก่

1. Neurons คือ เซลล์ประสาทที่มีการทำงานร่วมกับ Synapses

2. Synapses คือ จุดประสานประสาท
3. Dendrite คือ ปลายประสาทด้านที่รับกระแสประสาท
4. Axon คือ ส่วนที่เชื่อมระหว่าง Neurons และ Synapses

กระบวนการสร้างแบบจำลองโครงข่ายประสาทเทียม จะเป็นกระบวนการตามลำดับ

ขั้น ดังภาพที่ 2.7

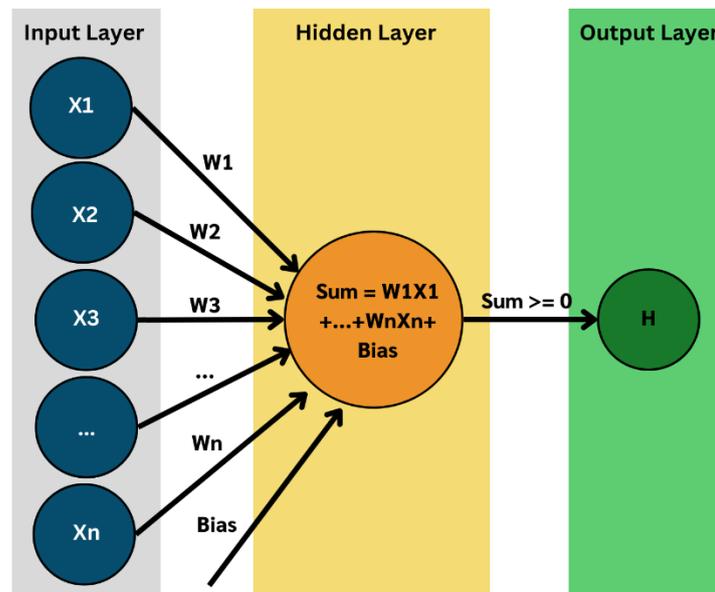


ภาพที่ 2.7 กระบวนการสร้างแบบจำลองโครงข่ายประสาทเทียม

จากภาพที่ 2.7 เป็นกระบวนการสร้างแบบจำลองโครงข่ายประสาทเทียม โดยมีลำดับขั้น 3 ขั้น ได้แก่

1. Input Layer คือ ชั้นการนำเข้าข้อมูล เป็นชั้นแรกของโครงข่ายประสาทเทียม โดยจำนวนโหนด หรือ Node ในชั้นนี้จะเข้าเท่ากับจำนวนคุณลักษณะ หรือ Features ของข้อมูลนำเข้า ซึ่งในภาพที่ 2.7 ในชั้น Input Layer มีจำนวนโหนด 3 โหนด
2. Hidden Layer คือ ชั้นที่มีโหนดอยู่ภายใน และทำหน้าที่ประมวลผลข้อมูลที่ได้จากชั้น Input Layer โดยความลึกของโครงข่ายนั้นจะขึ้นอยู่กับจำนวนโหนดในชั้น Hidden Layer ซึ่งในภาพที่ 2.7 ในชั้น Hidden Layer มีจำนวนโหนด 3 โหนด
3. Output Layer คือ ชั้นผลลัพธ์ของการประมวลผล โดยจำนวนโหนดในชั้นนี้จะขึ้นอยู่กับประเภทของการทำนาย ซึ่งในภาพที่ 2.7 ในชั้น Output Layer มีจำนวนโหนด 1 โหนด

หลักการทำงานโครงข่ายประสาทเทียมจะเริ่มจากการชั้น Input Layer มีการนำข้อมูลเข้าจากภาพนอกเรียกว่า Features โดยแต่ละ Feature จะมีน้ำหนักที่เป็นส่วนสำคัญในการทำนายผลลัพธ์ โดยน้ำหนักของแต่ละ Feature จะคูณกับค่านำเข้าและรวมกัน ดังภาพที่ 2.8



ภาพที่ 2.8 กระบวนการทำงานของโครงข่ายประสาทเทียม

จากภาพที่ 2.8 เป็นกระบวนการทำงานของโครงข่ายประสาทเทียม[6] ในชั้น Input Layer, Hidden Layer และ Output Layer โดยในชั้น Hidden Layer หาผลลัพธ์จากการคำนวณเมื่อผลลัพธ์มีค่ามากกว่า 0 มีจะส่งออกค่า 1 ไปยังชั้น Output Layer แต่ถ้าผลลัพธ์ค่าน้อยกว่า 0 จะส่งออกค่า 0 ไปยังชั้น Output Layer ในกรณีของปัญหาที่มีคำตอบของ Output เป็น 0 หรือ 1 หรือ binary classification แต่ถ้าในกรณีของปัญหาที่มีหลายหมวดหมู่ การใช้ Multi-layer Perceptron (MLP) จะมีการยืดหยุ่นมากขึ้น และในกรณีที่มี Output เป็น 0 และ 1 มีสมการคำนวณ ดังนี้

$$\text{Sum} = \sum_{i=1}^n (w_i \times x_i) + \text{Bias} \quad (2.6)$$

เมื่อ

- Sum คือ ตัวแปรแทนค่า เพื่อนำไปเปรียบเทียบกับค่า 0
- n คือ จำนวนโหนดที่นำเข้าจากชั้น Input Layer
- X คือ โหนดที่นำเข้าจากชั้น Input Layer

- W คือ ค่าพารามิเตอร์ที่ต้องปรับให้เหมาะสมกับปัญหา
- Bias คือ ค่าพารามิเตอร์ที่ต้องปรับให้เหมาะสมกับปัญหา
- H คือ ผลลัพธ์ที่ได้ มีค่าตั้งแต่ 0 ถึง 1

2.3.2 การเรียนรู้แบบไม่มีผู้สอน

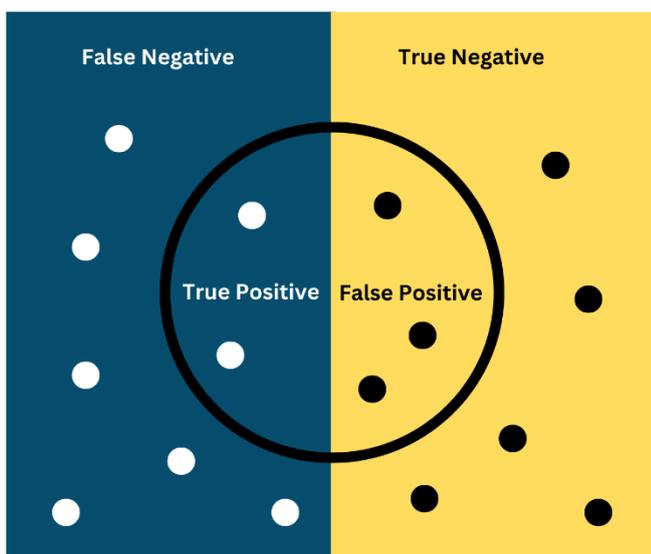
การเรียนรู้แบบไม่มีผู้สอน หรือ Unsupervised Learning คือแบบจำลองที่ต้องการจัดกลุ่ม หรือหาความสัมพันธ์ในข้อมูลโดยไม่มีคำตอบที่ระบุล่วงหน้าแบบ แบบจำลองที่ต้องการจัดการกับข้อมูลที่ไม่มีคำสอน ไม่มีคำตอบที่ระบุล่วงหน้า หรือบอกให้ทราบถึงลักษณะโครงสร้างในข้อมูลนั้น โดยมีวัตถุประสงค์เพื่อค้นหาลำดับ หรือจัดกลุ่มข้อมูลให้เป็นกลุ่มที่มีลักษณะคล้ายกัน

2.4 การประเมินประสิทธิภาพแบบจำลอง

การประเมินประสิทธิภาพของแบบจำลองเป็นขั้นตอนสำคัญที่ไม่ควรละเลยในกระบวนการสร้างแบบจำลองทางการเรียนรู้ของเครื่อง โดยการประเมินช่วยให้ทราบถึงทำงานของแบบจำลอง และมีประสิทธิภาพในการแก้ไขปัญหาหรือทำนายผลของแบบจำลอง ซึ่งการประเมินแบบจำลองสามารถทำได้หลายวิธี ควรเลือกให้เหมาะสมกับวัตถุประสงค์ของแบบจำลองข้อมูล

2.4.1 เมตริกซ์ความสับสน

เมตริกซ์ความสับสน หรือ Confusion Matrix เป็นเครื่องมือที่ใช้ในการประเมินประสิทธิภาพของระบบการจำแนกหรือการทำนาย โดยมีหน้าที่แสดงผลการทำนายของระบบในรูปแบบตารางที่แยกต่างหากตามกลุ่มของคลาสที่ต้องการทำนาย



ภาพที่ 2.9 ส่วนประกอบ 4 ส่วนของ Confusion Matrix

จากภาพที่ 2.9 เป็นภาพแสดงส่วนประกอบ 4 ส่วนของ Confusion Matrix โดยจุดสีขาว และจุดสีน้ำเงินแทนการทำนาย ซึ่งจะอยู่ในตำแหน่งการแบ่งเป็น 4 ส่วนดังนี้

1. True Positive (TP) คือ จำนวนของตัวอย่างที่ถูกทำนายเป็น Positive และความเป็นจริงเป็น Positive จึงเป็นผลลัพธ์ที่ถูกต้อง
2. True Negative (TN) คือ จำนวนของตัวอย่างที่ถูกทำนายเป็น Negative และความเป็นจริงเป็น Negative จึงเป็นผลลัพธ์ที่ถูกต้อง
3. False Positive (FP) คือ จำนวนของตัวอย่างที่ถูกทำนายเป็น Positive แต่ความเป็นจริงเป็น Negative จึงเป็นผลลัพธ์ที่ทำนายผิด
4. False Negative (FN) คือ จำนวนของตัวอย่างที่ถูกทำนายเป็น Negative แต่ความเป็นจริงเป็น Positive จึงเป็นผลลัพธ์ที่ทำนายผิด

ในการทำนายของแบบจำลองที่ดี ควรสามารถทำนายจำแนกกลุ่มได้อย่างถูกต้องในทุกกลุ่ม ซึ่งการคำนวณประสิทธิภาพแบบจำลองอื่น เช่น Accuracy, Precision, Recall และ F1-Score สามารถนำข้อมูลจาก Confusion Matrix ในการคำนวณประสิทธิภาพได้

2.4.2 ความแม่นยำ และความสามารถในการครอบคลุม

ความแม่นยำ และความสามารถในการครอบคลุม หรือ Precision and Recall ใช้ในการประเมินประสิทธิภาพของระบบจำแนกหรือการทำนาย โดยเฉพาะในงานที่เกี่ยวกับคลาสที่ไม่สมดุลกัน หรือกรณีที่จำนวนตัวอย่างในแต่ละคลาสมีความแตกต่างกัน

ความแม่นยำ หรือ Precision คืออัตราส่วนของการทำนาย Positive และทำนายถูกต้องจริงมากเพียงใด ซึ่งเป็นตัวชี้วัดที่เหมาะสมสำหรับประสิทธิภาพของระบบในกรณีที่สนใจในความแม่นยำของการทำนาย Positive โดยความหมายของแปรที่ใช้ในสมการที่ 2.7 ดังภาพที่ 2.9 และสามารถคำนวณได้ ดังนี้

$$\text{Precision} = \frac{\text{True Positive}}{\text{True Positive} + \text{False Positive}} \quad (2.7)$$

ความสามารถในการครอบคลุม หรือ Recall คืออัตราส่วนของการทำนาย Positive และทำนายถูกต้องจริงมากเพียงใด ซึ่งเป็นตัวชี้วัดที่เหมาะสมสำหรับประสิทธิภาพของระบบในกรณีที่สนใจในความสามารถของระบบในการครอบคลุมทุกกรณี Positive โดยความหมายตัวแปรที่ใช้ในสมการที่ 2.7 ดังภาพที่ 2.9 และสามารถคำนวณได้ ดังนี้

$$\text{Recall} = \frac{\text{True Positive}}{\text{True Positive} + \text{False Negative}} \quad (2.8)$$

2.4.3 ค่าเฉลี่ยแบบฮาร์โมนิกของความแม่นยำ และความสามารถในการครอบคลุม

ค่าเฉลี่ยแบบฮาร์โมนิกของความแม่นยำ และความสามารถในการครอบคลุม หรือ F1-Score คือค่าเฉลี่ย Precision และ Recall โดยสามารถคำนวณได้ ดังนี้

$$F1 - Score = 2 \frac{Precision \times Recall}{Precision + Recall} \quad (2.9)$$

เมื่อ

F1-Score คือ ค่าเฉลี่ยระหว่าง Precision และ Recall

Precision คือ ความแม่นยำในการทำนายผลให้ถูกต้อง

Recall คือ ความสามารถในการครอบคลุมในการทำนายผลกลุ่ม positive

F1-Score เป็นวิธีการวัดที่มีประโยชน์มากกว่า Accuracy ในกรณีที่ข้อมูลมีกลุ่มข้อมูลที่ไม่สมดุล เนื่องจาก F1-Score ให้ความสำคัญทั้งต่อ False Positive และ False Negative ร่วมด้วย โดยค่าที่ดีของ F1-Score จะมีค่าใกล้เคียงกับ 1 และมีค่าที่ไม่ดี เมื่อมีค่าใกล้เคียง 0

2.4.4 ค่าผิดพลาดรูทมีนสแควร์

ค่าผิดพลาดรูทมีนสแควร์ หรือ Root Mean Square Error (RMSE) เป็นเครื่องมือทางสถิติที่ใช้ในการประเมินความคลาดเคลื่อนระหว่างค่าที่คำนวณโดยแบบจำลอง กับค่าความจริงในการประเมินแบบสถิติเชิงคำนวณ ซึ่งนิยมมาใช้ในการประเมินความแม่นยำของการทำนายหรือการแสดงผลของแบบจำลอง โดยสามารถคำนวณได้ ดังนี้

$$RMSE = \sqrt{\frac{1}{N} \times \sum (Predicted - Actual)^2} \quad (2.10)$$

เมื่อ

RMSE คือ ค่าความผิดพลาด

Predicted คือ ค่าจากการทำนาย

Actual คือ ค่าจากความจริง

N คือ จำนวนตัวอย่างในชุดการทดสอบ

2.5 งานวิจัยที่เกี่ยวข้อง

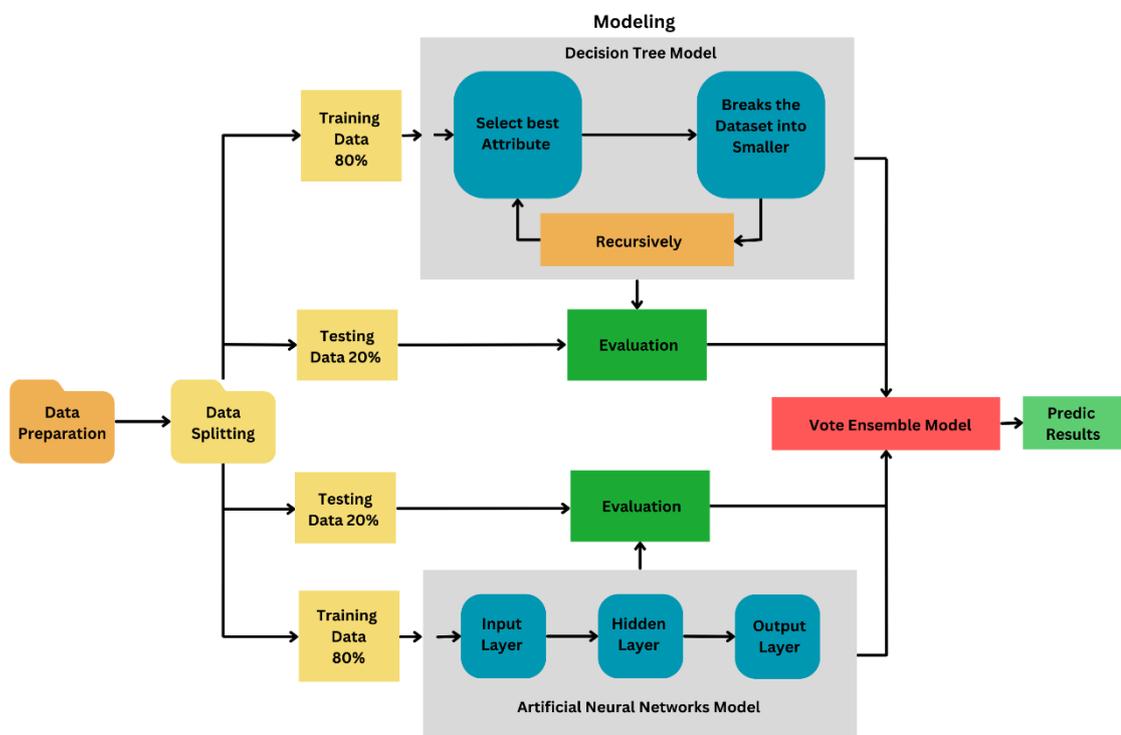
ชลรวี หาญลัยวง [7] เป็นสารนิพนธ์เรื่อง “การคาดการณ์ดัชนีราคาหุ้นตลาดหลักทรัพย์แห่งประเทศไทยโดยใช้มะชินเลิร์นนิ่งเทคนิค” เพื่อคาดการณ์การเปลี่ยนแปลงของดัชนีราคาหุ้นตลาดหลักทรัพย์แห่งประเทศไทย SET Index ในวันทำการถัดไป โดยใช้เทคนิค machine learning ซึ่งใช้ประโยชน์จากความสัมพันธ์ระยะสั้นระหว่างการเปลี่ยนแปลงของดัชนีราคาหุ้นตลาดหลักทรัพย์จากทั่วโลก global stock market indices อัตราแลกเปลี่ยน exchange rates และราคาสินค้าโภคภัณฑ์ commodities เพื่อทดสอบความแม่นยำ accuracy ของแต่ละโมเดล ในการศึกษาใช้ข้อมูลระหว่างวันที่ 2 สิงหาคม 2550 ถึงวันที่ 2 สิงหาคม 2561 โดยใช้เทคนิค Decision Tree, Artificial Neural Networks และ Support Vector Machine ซึ่ง Machine learning algorithm ที่สร้างโมเดลเพื่อคาดการณ์ได้ความแม่นยำมากที่สุดคือ Decision Tree ได้ความแม่นยำเฉลี่ยสูงที่สุดที่ 63.2% และมีส่วนเบี่ยงเบนมาตรฐาน standard deviation ต่ำที่สุด 4.24% และกอัลกอริทึมที่สามารถคาดการณ์ได้ความแม่นยำเฉลี่ยใกล้เคียงกัน คือ Artificial Neural Networks และ Support Vector Machine ตามลำดับ

วิศรุต แก้วมหา [8] เป็นสารนิพนธ์เรื่อง “การคาดการณ์ผลตอบแทนในอนาคตของตราสารทุนหุ้นสามัญโดยใช้แบบจำลองโครงข่ายประสาทเทียม และแบบจำลอง Random Forest” เพื่อคาดการณ์ผลตอบแทนในอนาคตของตราสารทุนหุ้นสามัญด้วยเทคนิค machine learning โดยการใช้แบบจำลอง โครงข่ายประสาทเทียม และแบบจำลอง Random Forest ซึ่งได้แบ่งการทดลองเป็นช่วงเวลาที่กำหนด ดังนี้ 1 วัน 1 เดือน และ 3 เดือน โดยตัววัดความแม่นยำที่ใช้ในการประเมินผลของ เช่น MAE, RMSE และ ตัววัดที่เรียกว่า Hit Rate ที่หมายถึงจำนวนการเทรดที่ประสบความสำเร็จหรือทำกำไรได้ในช่วงระยะเวลาหนึ่งที่ใช้กลยุทธ์การเทรด ทหารด้วยจำนวนการเทรดทั้งหมดในช่วงระยะเวลาเดียวกันจะแสดงข้อมูลเป็นเปอร์เซ็นต์ ซึ่งผลการทดลอง 1 วัน กับแบบจำลองคาดการณ์ผลตอบแทนของตราสารทุน พบว่า โมเดล ANN มี RMSE 2.57%, MAE 1.85%, Hit Rate 54.14% และ โมเดล RF มี RMSE 2.5%, MAE 1.8%, Hit Rate 53.21% ผลการทดลอง 1 เดือนกับแบบจำลองคาดการณ์ผลตอบแทนของตราสารทุน พบว่า โมเดล ANN มี RMSE 7.07%, MAE 4.94%, Hit Rate 78.43% และ โมเดล RF มี RMSE 6.37%, MAE 4.51%, Hit Rate 80.42% และ ผลการทดลอง 3 เดือนกับแบบจำลองคาดการณ์ผลตอบแทนของตราสารทุน พบว่า โมเดล ANN มี RMSE 7.85%, MAE 5.3%, Hit Rate 87.85% และ โมเดล RF มี RMSE 7.07%, MAE 4.85%, Hit Rate 88.96% จากผลการทดสอบแบบจำลองโครงข่ายประสาทเทียม และแบบจำลอง Random Forest จะมีความแม่นยำที่ใกล้เคียงกัน และจะแม่นยำมากขึ้นเมื่อมีการเรียนรู้กับระยะเวลาที่มากขึ้นตามลำดับ

บทที่ 3

วิธีดำเนินการวิจัย

วิธีการวิจัยในการศึกษานี้ได้นำเสนอการคาดการณ์แนวโน้มหุ้น ด้วยเทคนิคการรวมแบบจำลองโหวต เป็นการศึกษาโดยใช้รูปแบบการวิจัยหลายรูปแบบมาประยุกต์เข้าด้วยกัน ซึ่งในบทนี้จะกล่าวถึงการจัดเตรียมชุดข้อมูลราคาหุ้น การเตรียมข้อมูลสำหรับการประมวลผล การแบ่งชุดข้อมูล การสร้างแบบจำลอง การทดสอบแบบจำลอง และการรวมแบบจำลองโหวต



ภาพที่ 3.1 ขั้นตอนการสร้างแบบจำลอง และประเมินผลแบบจำลอง

จากภาพที่ 3.1 เป็นขั้นตอนการสร้างแบบจำลอง โดยเริ่มสร้างแบบจำลองจาก Data Preparation หรือการเตรียมข้อมูล และแบ่งข้อมูลที่ได้จากการเตรียมข้อมูลเป็น Training Data 80% นำไปสร้าง Decision Tree Model (DT) และ Artificial Neural Network Model (ANN) เป็น Test Data 20% นำไป Evaluation หรือประเมินแบบจำลอง ซึ่งขั้นตอนสุดท้าย คือการนำ DT และ ANN ร่วมกับเทคนิค Internal Bar Strength เป็น Vote Ensemble Model (VE)

3.1 การเตรียมข้อมูล

Data Preparation หรือการเตรียมข้อมูล เป็นกระบวนการที่นำเข้าข้อมูล เพื่อจัดรูปแบบข้อมูลให้เหมาะสมสำหรับการนำไปใช้ในการวิเคราะห์ หรือการฝึกแบบจำลอง

จากภาพที่ 3.1 Data Preparation ได้ดำเนินการศึกษาข้อมูลราคาหุ้นเป็นข้อมูลจริงจากฐานข้อมูล Finance ซึ่งเป็นฐานเก็บรวบรวมข้อมูลราคาหุ้น โดยได้นำข้อมูลหุ้นบริษัท Apple บริษัท Meta Platforms Inc และบริษัท Tesla ตั้งแต่วันที่ 01/01/2018 จนถึงวันที่ 31/12/2022 เพื่อเป็นต้นแบบในการวิเคราะห์ข้อมูลเพื่อหาความสัมพันธ์ของราคาหุ้น

ในการเตรียมข้อมูลสำหรับการสร้างแบบจำลอง การเลือกคุณลักษณะ หรือ Attribute ที่สำคัญต่อการฝึกแบบจำลอง และมีผลต่อการทำนาย จะช่วยลดความซับซ้อน และเพิ่มประสิทธิภาพให้กับแบบจำลอง ซึ่งการสร้างแบบจำลองจำเป็นต้องมีคุณลักษณะ และเป้าหมายการทำนายเพื่อปรับความสัมพันธ์ของข้อมูลให้สามารถทำนายในกรณีที่มีข้อมูลใหม่

3.1.1 คุณลักษณะ

คุณลักษณะ หรือ Attribute คือคุณลักษณะที่ใช้ในการฝึกแบบจำลอง ให้สามารถทำนาย หรือจัดกลุ่มข้อมูลได้ ซึ่งการเลือกคุณลักษณะที่สำคัญต่อการฝึกแบบจำลอง และมีผลต่อการทำนาย จะช่วยลดความซับซ้อนและเพิ่มประสิทธิภาพให้กับแบบจำลอง โดยงานวิจัยนี้มีวิธีการเลือกคัดเลือก Attribute ที่เกี่ยวข้อง เช่น ราคาเปิดของวัน ราคาปิดของวัน ราคาสูงสุดของวัน ราคาต่ำสุดของวัน ค่าเฉลี่ยเคลื่อนที่แบบเอ็กซ์โพเนนเชียลย้อนหลัง 5 วัน ค่าเฉลี่ยเคลื่อนที่แบบเอ็กซ์โพเนนเชียลย้อนหลัง 20 วัน และค่าเฉลี่ยเคลื่อนที่แบบเอ็กซ์โพเนนเชียลย้อนหลัง 100 วัน สามารถคำนวณได้ดังนี้

$$EMA_T = (\text{Alpha} \times \text{Close}_T) + ((1 - \text{Alpha}) \times EMA_{T-1})$$

เมื่อ

T	คือ	ระยะเวลาที่กำหนด
EMA _T	คือ	ค่า Exponential Moving Average ของวันที่ T
Alpha	คือ	ค่าส่วนเสริม คำนวณได้จากสมการ Smoothing Factor ÷ (T + 1) โดยในกรณีทั่วไปจะให้ Smoothing Factor เท่ากับ 2 และ N คือ จำนวนวันที่ใช้ในการคำนวณ EMA
Close _T	คือ	ข้อมูลราคาของหลักทรัพย์ของวันที่ T
EMA _{T-1}	คือ	ค่า Exponential Moving Average ในวันก่อนหน้า T

ตารางที่ 3.1 ข้อมูลราคาหุ้นบริษัท Tesla จำนวน 5 วัน

วันที่	ราคาเปิดของวัน (USD)
12 / 12 / 2022	167.91
13 / 12 / 2022	160.77
14 / 12 / 2022	156.57
15 / 12 / 2022	157.41
16 / 12 / 2022	150.06

ตัวอย่างการคำนวณหา EMA ย้อนหลัง 5 วันจากข้อมูลราคาหุ้นบริษัท Tesla จำนวน 5 วันจากข้อมูลในตารางที่ 3.1 โดยกำหนดค่าเริ่มต้น $EMA_1 = 167.91$ เท่ากับค่าแรกในชุดข้อมูล และ N เท่ากับ 5 โดยเริ่มจากการหาค่า Alpha ดังนี้

$$\text{Alpha} = \text{Smoothing Factor} \div (N+1)$$

$$\text{Alpha} = 2 \div (N+1)$$

$$\text{Alpha} = 2 \div (5+1)$$

$$\text{Alpha} = 0.3333$$

เมื่อค่า Alpha = 0.3333 หมายถึง การให้น้ำหนักข้อมูลปัจจุบัน 33.33% และมีการให้น้ำหนักกับข้อมูลในอดีต 66.67% เมื่อทราบค่า Alpha จึงสามารถหาค่า EMA ย้อนหลัง 5 วันได้จากสมการที่ 2.1 ดังนี้

- การคำนวณค่า Exponential Moving Average ลำดับที่ 1

$$EMA_2 = 0.3333 \times 160.77 + (1 - 0.3333) \times 167.91$$

$$EMA_2 = 165.53$$

- การคำนวณค่า Exponential Moving Average ลำดับที่ 2

$$EMA_3 = 0.3333 \times 156.57 + (1 - 0.3333) \times 165.53$$

$$EMA_3 = 159.37$$

- การคำนวณค่า Exponential Moving Average ลำดับที่ 3

$$EMA_4 = 0.3333 \times 157.41 + (1 - 0.3333) \times 159.37$$

$$EMA_4 = 156.85$$

- การคำนวณค่า Exponential Moving Average ลำดับที่ 4

$$EMA_5 = 0.3333 \times 150.06 + (1 - 0.3333) \times 156.85$$

$$EMA_5 = 154.96$$

เมื่อการคำนวณค่า EMA ลำดับที่ 4 จะได้ค่า EMA ย้อนหลัง 5 วัน แต่เมื่อมีข้อมูลราคามากกว่า 5 ข้อมูล สามารถคำนวณเพื่อหาค่า EMA จนจะถึงค่า T และ N เท่ากัน จึงเป็นการคำนวณเสร็จสิ้น

ตารางที่ 3.2 ค่า EMA ย้อนหลัง 5 วัน จากข้อมูลราคาหุ้นบริษัท Tesla จำนวน 5 วัน

วันที่	ราคาเปิดของวัน (USD)	ค่า EMA ย้อนหลัง 5 วัน (USD)
12 / 12 / 2022	167.91	0
13 / 12 / 2022	160.77	165.53
14 / 12 / 2022	156.57	159.37
15 / 12 / 2022	157.41	156.85
16 / 12 / 2022	150.06	154.96

ตารางที่ 3.3 ค่า EMA ย้อนหลัง 20 วัน จากข้อมูลราคาหุ้นบริษัท Tesla จำนวน 5 วัน

วันที่	ราคาเปิดของวัน (USD)	ค่า EMA ย้อนหลัง 20 วัน (USD)
12 / 12 / 2022	167.91	0
13 / 12 / 2022	160.77	167.23
14 / 12 / 2022	156.57	160.37
15 / 12 / 2022	157.41	156.65
16 / 12 / 2022	150.06	156.71

ตารางที่ 3.4 ค่า EMA ย้อนหลัง 100 วัน จากข้อมูลราคาหุ้นบริษัท Tesla จำนวน 5 วัน

วันที่	ราคาเปิดของวัน (USD)	ค่า EMA ย้อนหลัง 100 วัน (USD)
12 / 12 / 2022	167.91	0
13 / 12 / 2022	160.77	167.77
14 / 12 / 2022	156.57	160.69
15 / 12 / 2022	157.41	156.59
16 / 12 / 2022	150.06	157.26

จากตารางที่ 3.2, 3.3 และ 3.4 เป็นการแสดงตัวอย่างการคำนวณหาค่า EMA ย้อนหลัง 5 วัน 20 วัน และ 100 วันจะพบว่า EMA ย้อนหลัง 5 วัน จะมีการให้น้ำหนักกับข้อมูล

ปัจจุบัน ในขณะที่ค่า EMA ย้อนหลัง 20 วันและ 100 วันจะให้น้ำหนักกับข้อมูลในอดีตมากกว่าตามลำดับ ซึ่งการคำนวณค่า EMA ย้อนหลัง 5 วัน 20 วัน และ 100 วันเป็นการเตรียมข้อมูลสำหรับการเลือกคุณลักษณะในการฝึกแบบจำลอง โดยงานวิจัยมีการเลือกคุณลักษณะทั้งหมด 8 ข้อมูลดังนี้

1. คุณลักษณะลำดับที่ 1 คือ ค่าความห่างระหว่างค่า EMA ย้อนหลัง 100 วัน และค่า EMA ย้อนหลัง 20 วัน เป็นเปอร์เซ็นต์ เมื่อเทียบกับค่า EMA ย้อนหลัง 100 วัน
2. คุณลักษณะลำดับที่ 2 คือ ค่าความห่างระหว่างค่า EMA ย้อนหลัง 100 วัน และค่า EMA ย้อนหลัง 5 วัน เป็นเปอร์เซ็นต์ เมื่อเทียบกับค่า EMA ย้อนหลัง 100 วัน
3. คุณลักษณะลำดับที่ 3 คือ ค่าความห่างระหว่างค่า EMA ย้อนหลัง 20 วัน และค่า EMA ย้อนหลัง 5 วัน เป็นเปอร์เซ็นต์ เมื่อเทียบกับค่า EMA ย้อนหลัง 20 วัน
4. คุณลักษณะลำดับที่ 4 คือ ราคาปิดของวันเทียบกับราคาเปิดของวัน เมื่อราคาปิดมากกว่าราคาเปิดจะแทนค่า Attribute ลำดับที่ 4 เป็น 1 และเมื่อราคาปิดน้อยกว่าราคาเปิดจะแทนค่า Attribute ลำดับที่ 4 เป็น 0
5. คุณลักษณะ ลำดับที่ 5 คือ ค่าความห่างระหว่างราคาเปิดของวัน และค่า EMA ย้อนหลัง 100 วัน เป็นเปอร์เซ็นต์ เมื่อเทียบกับราคาปิดของวัน
6. คุณลักษณะ ลำดับที่ 6 คือ ค่าความห่างระหว่างราคาเปิดของวัน และค่า EMA ย้อนหลัง 20 วัน เป็นเปอร์เซ็นต์ เมื่อเทียบกับราคาปิดของวัน
7. คุณลักษณะ ลำดับที่ 7 คือ ค่าความห่างระหว่างราคาเปิดของวัน และค่า EMA ย้อนหลัง 5 วัน เป็นเปอร์เซ็นต์ เมื่อเทียบกับราคาปิดของวัน
8. คุณลักษณะ ลำดับที่ 8 คือ ค่าที่ได้จากการคำนวณ Internal Bar Strength ในสมการที่ 2.2

ตารางที่ 3.5 ตัวอย่างการแสดงค่าคุณลักษณะ 8 ข้อมูล

ราคา เปิด	EMA5	EMA20	EMA100	ลำดับ ที่ 1	ลำดับ ที่ 2	ลำดับ ที่ 3	ลำดับ ที่ 4	ลำดับ ที่ 5	ลำดับ ที่ 6	ลำดับ ที่ 7	ลำดับ ที่ 8
336.53	337.87	338.34	338.50	-0.04	-0.18	-0.14	0	-0.58	-0.53	-0.39	0.41
324.17	333.30	336.99	338.21	-0.36	-1.45	-1.09	0	-4.15	-3.80	-2.74	0.02
332.46	333.02	336.56	338.10	-0.45	-1.50	-1.05	1	-1.66	-1.21	-0.16	0.59
331.79	332.61	336.11	337.97	-0.55	-1.58	-1.04	0	-1.8	-1.28	-0.24	0.35
328.07	331.09	335.34	337.78	-0.72	-1.97	-1.26	1	-2.87	-0.16	-0.91	0.97

ข้อมูลคุณลักษณะ 8 ตัว ที่ได้จากการคำนวณ EMA ย้อนหลัง 5 วัน 20 วัน และ 100 วันและการหาค่าความห่างคิดเป็นเปอร์เซ็นต์ จากตารางที่ 3.5 จะมีข้อมูลราคาปิด ข้อมูล EMA ย้อนหลัง 5 วัน 20 วัน และ 100 วัน โดยในคอลัมน์ลำดับที่ 1 คือค่าความห่างระหว่างค่า EMA ย้อนหลัง 100 วัน และค่า EMA ย้อนหลัง 20 วัน เป็นเปอร์เซ็นต์ เมื่อเทียบกับค่า EMA ย้อนหลัง 100 วัน คอลัมน์ลำดับที่ 2 คือค่าความห่างระหว่างค่า EMA ย้อนหลัง 100 วัน และค่าEMA ย้อนหลัง 5 วัน เป็นเปอร์เซ็นต์ เมื่อเทียบกับค่า EMA ย้อนหลัง 100 วัน คอลัมน์ลำดับที่ 3 คือค่าความห่างระหว่างค่า EMA ย้อนหลัง 20 วัน และค่าEMA ย้อนหลัง 5 วัน เป็นเปอร์เซ็นต์ เมื่อเทียบกับค่า EMA ย้อนหลัง 20 วัน คอลัมน์ลำดับที่ 4 คือราคาปิดของวันเทียบกับราคาเปิดของวัน เมื่อราคาปิดมากกว่าราคาเปิดจะแทนค่า Attribute ลำดับที่ 4 เป็น 1 และเมื่อราคาปิดน้อยกว่าราคาเปิดจะแทนค่า Attribute ลำดับที่ 4 เป็น 0 คอลัมน์ลำดับที่ 5 คือค่าความห่างระหว่างราคาเปิดของวัน และค่า EMA ย้อนหลัง 100 วัน เป็นเปอร์เซ็นต์ เมื่อเทียบกับราคาปิดของวัน คอลัมน์ลำดับที่ 6 คือค่าความห่างระหว่างราคาเปิดของวัน และค่า EMA ย้อนหลัง 20 วัน เป็นเปอร์เซ็นต์ เมื่อเทียบกับราคาปิดของวัน คอลัมน์ลำดับที่ 7 คือค่าความห่างระหว่างราคาเปิดของวัน และค่าEMA ย้อนหลัง 5 วัน เป็นเปอร์เซ็นต์ เมื่อเทียบกับราคาปิดของวัน คอลัมน์ลำดับที่ 8 คือค่าที่ได้จากการคำนวณ Internal Bar Strength ในสมการที่ 2.2

3.1.2 เป้าหมายการทำนาย

เป้าหมายการทำนาย หรือ Target คือผลลัพธ์ที่ต้องการให้แบบจำลองทำนาย หรือ จำแนก โดยกระบวนการเรียนรู้แบบจำลองจะใช้คุณลักษณะ เพื่อทำนาย Target

การเลือก Target ในการวิจัยต้องการทราบผลลัพธ์ให้แบบจำลองทำนายหุ้นสองแบบ คือราคาปิดของหุ้นวันปัจจุบันมากกว่าราคาปิดของหุ้นวันที่ผ่านมาจะแทนค่า Target เป็น 1 และราคาปิดของหุ้นวันปัจจุบันน้อยกว่าราคาปิดของหุ้นวันที่ผ่านมาจะแทนค่า Target เป็น 0

ตารางที่ 3.6 ข้อมูลราคาหุ้นบริษัท Tesla จำนวน 5 วัน

วันที่	ราคาเปิดของวัน (USD)	ราคาปิดของวัน (USD)	Target
12 / 12 / 2022	176.11	167.91	0
13 / 12 / 2022	174.83	160.77	0
14 / 12 / 2022	159.35	156.57	0
15 / 12 / 2022	153.46	157.41	1
16 / 12 / 2022	159.73	150.06	0

จากตารางที่ 3.6 เป็นการแสดงตัวอย่างการเลือก Target โดยใช้ข้อมูลราคาหุ้นบริษัท Tesla จำนวน 5 วันเพื่อแสดงการเลือก Target โดยในตารางที่ 3.6 มีข้อมูลวันที่ของราคาเปิดของวันและราคาปิดของวัน เมื่อราคาปิดของหุ้นวันปัจจุบันมากกว่าราคาปิดของหุ้นวันที่ผ่านมาจะแทนค่า Target ของวันปัจจุบันเป็น 1 นั้นหมายถึงแนวโน้มหุ้นมีการขึ้น และราคาปิดของหุ้นวันปัจจุบันน้อยกว่าราคาปิดของหุ้นวันที่ผ่านมาจะแทนค่า Target ของวันปัจจุบันเป็น 0 นั้นหมายถึงแนวโน้มหุ้นมีการลง

3.2 การแบ่งชุดข้อมูล

การแบ่งชุดข้อมูล หรือ Data Splitting เป็นกระบวนการที่สำคัญในการเตรียมข้อมูลสำหรับการฝึก และทดสอบแบบจำลอง เป้าหมายของการแบ่งชุดข้อมูล คือการแยกข้อมูลออกเป็นส่วนย่อยดังนี้ภาพที่ 3.1 เพื่อให้มีชุดข้อมูลสำหรับการฝึก หรือ Training Data และชุดข้อมูลสำหรับการทดสอบ หรือ Testing Data เพื่อประเมินประสิทธิภาพของแบบจำลอง หรือ Evaluation โดยมีข้อมูลราคาจากหุ้นบริษัท Apple บริษัท Meta Platforms Inc และบริษัท Tesla โดยแบ่งสัดส่วนชุดข้อมูลสำหรับการฝึก 80% และชุดข้อมูลสำหรับการทดสอบ 20%

ตารางที่ 3.7 รายละเอียดชุดข้อมูลราคาหุ้น

ชื่อบริษัท	ชื่อหุ้น	จำนวนตัวอย่าง (วันที่)
Apple	APPL	01/01/2018 – 31/12/2022
Meta Platforms Inc	META	01/01/2018 – 31/12/2022
Tesla	TSLA	01/01/2018 – 31/12/2022

จากตารางที่ 3.7 คือรายละเอียดชุดข้อมูลของบริษัท หุ้นบริษัท Apple บริษัท Meta Platforms Inc และบริษัท Tesla โดยมีการระบุชื่อหุ้น และระยะเวลาข้อมูลราคาหุ้นในการนำมาฝึกแบบจำลองตั้งแต่วันที่ 01/01/2018 จนถึงวันที่ 31/12/2022

3.3.1 ชุดข้อมูลสำหรับฝึก

ชุดข้อมูลสำหรับฝึก หรือ Training Set เป็นชุดข้อมูลที่ใช้ในกระบวนการสร้าง หรือฝึกแบบจำลอง โดยนำชุดข้อมูลให้แบบจำลองเรียนรู้ ชุดข้อมูลฝึกมีข้อมูลราคาหุ้น APPL 1,000 วัน META 1,000 วัน และ TSLA 1,000 วัน

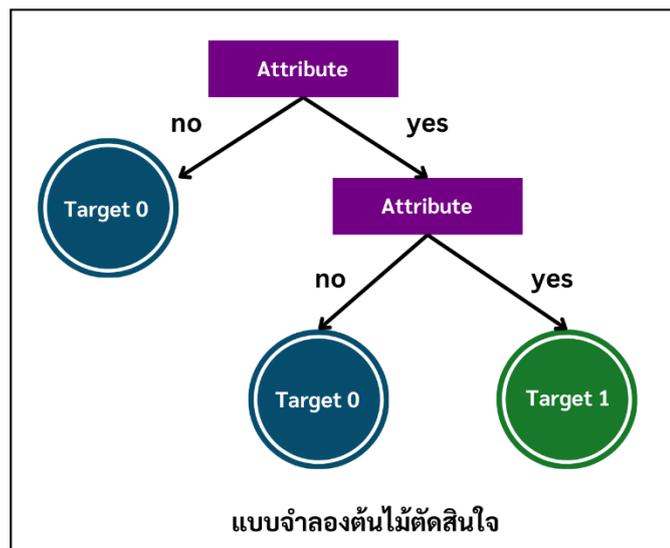
3.3.2 ชุดข้อมูลสำหรับทดสอบ

ชุดข้อมูลสำหรับทดสอบ หรือ Testing Set เป็นเป็นชุดข้อมูลที่ใช้ในการทดสอบประสิทธิภาพของแบบจำลองหลังจาก แบบจำลองถูกฝึกเสร็จสิ้น ชุดข้อมูลนี้ไม่ได้ใช้ในกระบวนการฝึกแบบจำลองที่เป็นความลับของแบบจำลอง ชุดข้อมูลทดสอบมีข้อมูลราคาหุ้น APPL 250 วัน META 250 วัน และ TSLA 250 วัน

3.3 การสร้างแบบจำลอง

การสร้างแบบจำลอง หรือ Modeling เป็นกระบวนการที่ทำให้แบบจำลองเรียนรู้และปรับค่าพารามิเตอร์ เพื่อให้แบบจำลองสามารถทำงานได้อย่างถูกต้อง และมีประสิทธิภาพในการคาดการณ์ราคาหุ้นที่มีความแม่นยำ

3.3.1 แบบจำลองต้นไม้ตัดสินใจ

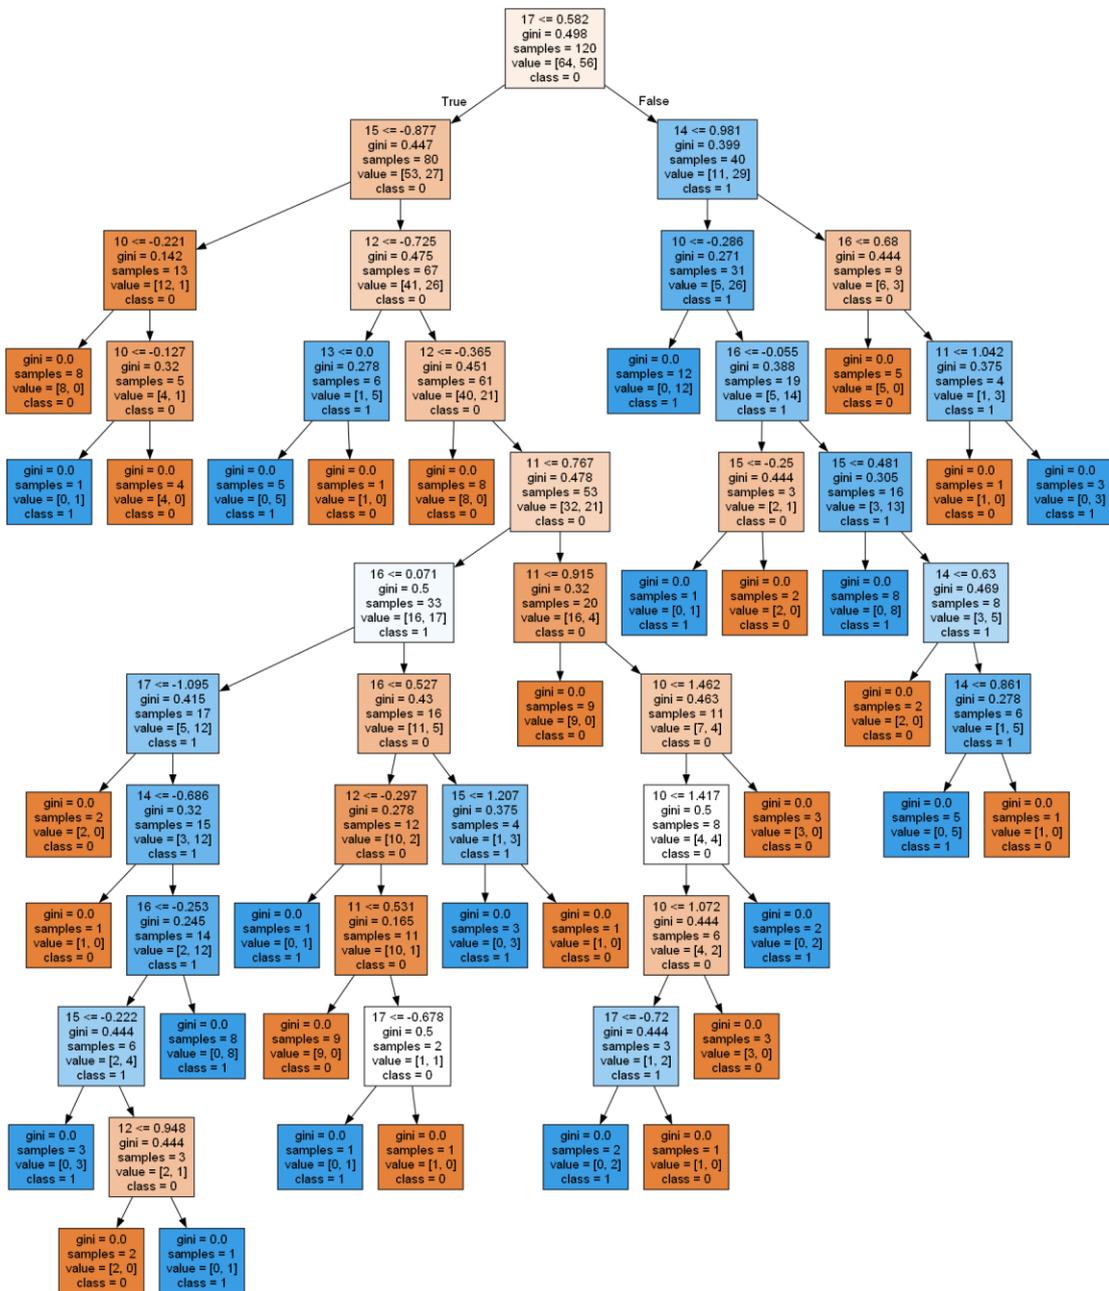


ภาพที่ 3.2 กระบวนการสร้างแบบจำลองต้นไม้ตัดสินใจ

จากภาพที่ 3.2 เป็นกระบวนการสร้างแบบจำลองต้นไม้ตัดสินใจ ประกอบไปด้วยคุณลักษณะ เป้าหมายการทำนายที่ต้องการให้แบบจำลองทำนาย และกิ่งของแบบจำลองต้นไม้ตัดสินใจ

1. Attribute หรือคุณลักษณะ คือข้อมูลคุณลักษณะที่ใช้ในการฝึกแบบจำลอง จากภาพที่ 3.2 เรียกว่า Split Node เป็นโหนดที่ใช้เงื่อนไขเพื่อแบ่งข้อมูล เช่น yes หรือ no แต่เมื่อเป็นโหนดที่อยู่ทางด้านบนของต้นไม้ตัดสินใจเพียงโหนดเดียวเรียกว่า Root Node

- Target หรือเป้าหมายการทำนาย คือข้อมูลที่ต้องการให้แบบจำลองทำนาย เป็น 0 แทนการทำนายสำหรับแนวโน้มหุ่นขึ้น และ 1 แทนการทำนายสำหรับแนวโน้มหุ่นลง โดยจะตำแหน่งที่ Target อยู่เรียกว่า Leaf Node เป็นโหนดที่ไม่มีการแบ่งเพิ่มเติม และใช้สำหรับการทำนาย
- กิ่ง หรือ Branches เป็นการเชื่อม Split Node และ Leaf Node

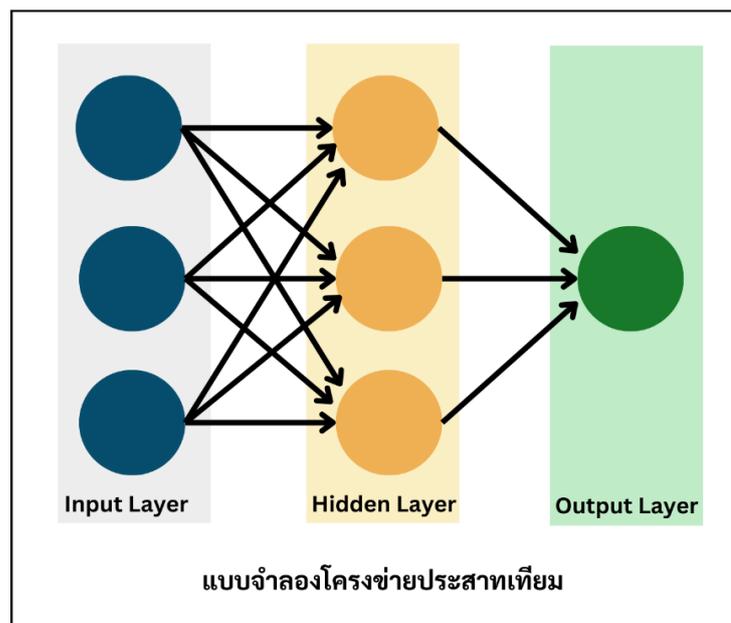


ภาพที่ 3.3 แบบจำลองต้นไม้ตัดสินใจ

จากภาพที่ 3.3 เป็นแบบจำลองต้นไม้ตัดสินใจ ที่มีการคำนวณหาค่า Gini Impurity ดัง สมการที่ 2.3 โดยมี Root Node อยู่บนสุดของแบบจำลอง และมีการแตก Branches เป็น Split Node และ Leaf Node เป็น class 0 แนวโน้มหั่นลง และ class 1 แนวโน้มหั่นขึ้น ซึ่งมีค่า gini หรือ Gini Impurity จะบ่งบอกถึงความบริสุทธิ์ของ Node โดย gini เป็น 0 หมายถึงข้อมูลทุกรายการใน Node นั้นอยู่ใน class เดียวกัน ส่วน gini เป็น 0.5 หมายถึงข้อมูลใน Node มี 2 class ที่เท่ากัน

ค่า samples จากภาพที่ 3.3 คือจำนวนรายการข้อมูลที่เข้ากันได้กับ Node โดยเมื่อมีการตัดสินใจจะมีการเคลื่อนลงตามความลึกของต้นไม้ ซึ่ง samples ของ Node ในแต่ละชั้นจะมีแนวโน้มที่ลดลงตามลำดับ และ value บอกถึงจำนวน class ทั้งหมดที่มี แบ่งเป็นจำนวนที่อยู่ใน class 0 และ class 1

3.3.2 แบบจำลองโครงข่ายประสาทเทียม



ภาพที่ 3.4 กระบวนการสร้างแบบจำลองโครงข่ายประสาทเทียม

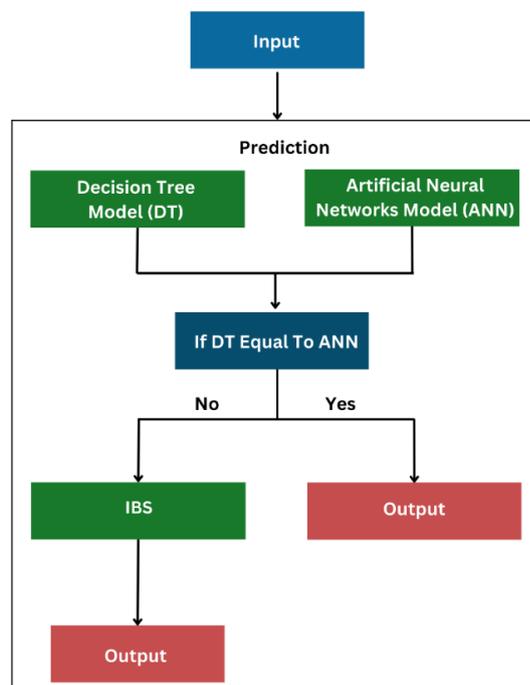
จากภาพที่ 3.4 เป็นกระบวนการสร้างแบบจำลองโครงข่ายประสาทเทียม ประกอบไปด้วย Input Layer, Hidden Layer และ Output Layer

1. Input Layer หรือชั้นข้อมูลนำเข้า คือชั้นแรกเป็นชั้นที่รับข้อมูลนำเข้า โดยชั้น Input Layer จะมีโหนดตามจำนวน Attribute ที่มีการนำเข้า เช่นในหัวข้อคุณลักษณะ 3.1.1 โดยแต่ละโหนดในชั้น Input Layer จะรับค่าข้อมูลนำเข้าหนึ่งค่า และส่งข้อมูลไปยังชั้นซ่อน

2. Hidden Layer หรือชั้นซ่อน คือชั้นที่ใช้ในการประมวลผลข้อมูล และเรียนรู้รูปแบบหรือความสัมพันธ์ระหว่างข้อมูล Input Layer และข้อมูล Output Layer โดยในชั้น Hidden Layer สามารถกำหนดโหนดภายใน Hidden Layer ได้ การในชั้น Hidden Layer จะมีการประมวลผลข้อมูล โดยการคำนวณจากสมการที่ 2.6
3. Output Layer หรือชั้นข้อมูลออก คือชั้นที่ใช้ในการแสดงผลลัพธ์ หรือการทำนายข้อมูลขาออก เป็น 0 และ 1

การกำหนดพารามิเตอร์ แบบจำลองโครงข่ายประสาทเทียม สามารถแบ่งเป็น Input Layer จำนวน 8 โหนด Hidden Layer จำนวน 64 โหนด และ Output Layer 1 โหนด ที่มีค่าตั้งแต่ 0 ถึง 1 เป็นการกำหนดพารามิเตอร์ที่ดีที่สุดสำหรับการคาดการณ์แนวโน้มหุ้นในงานวิจัยนี้

3.3.3 การรวมแบบจำลองโหนด



ภาพที่ 3.5 กระบวนการทำงานของการสร้างแบบจำลองโหนด

แบบจำลองการโหวต หรือ Vote Ensemble Model (VE) เป็นการคาดการณ์แนวโน้มหุ้นของแบบจำลองต้นไม้ตัดสินใจ และแบบจำลองโครงข่ายประสาทเทียม ร่วมเทคนิค Internal Bar Strength ทำงานร่วมกันเพื่อให้ได้ผลการคาดการณ์แนวโน้มหุ้นที่แม่นยำ

จากภาพที่ 3.5 เป็นการแสดงกระบวนการทำงานของการสร้างแบบจำลองโหวต โดยมีกระบวนการทำงาน ดังนี้

1. Input หรือการนำข้อมูลที่ได้จากการเตรียมข้อมูลในหัวข้อการเตรียมข้อมูล 3.1 นำข้อมูลเข้า Decision Tree Model (DT) และ Artificial Neural Networks Model (ANN) เพื่อการ Prediction โดยมีผลการ Prediction เป็น 0 คือแนวโน้มหุ้นลง และ 1 คือแนวโน้มหุ้นขึ้น
2. เมื่อผลการทำนายของแบบจำลอง DT และ ANN ตรงกัน เช่น DT ทำนาย 0 และ ANN ทำนาย 0 จะเข้าเงื่อนไข Yes และส่งผลการทำนาย 0 ไปยัง Output แต่เมื่อผลการทำนายของแบบจำลอง DT และ ANN ไม่ตรงกัน เช่น DT ทำนาย 0 และ ANN ทำนาย 1 จะเข้าเงื่อนไข No และทำการเช็คค่า IBS ที่มีค่าเท่ากับ 0.69 ดังนั้นจึงให้นำหนักผลการทำนายกับค่า IBS ที่มีผลการทำนายใกล้เคียงกับแบบจำลอง ANN และส่งผลการทำนาย 1 ไปยัง Output

3.4 การประเมินผล

การประเมินผล หรือ Evaluation จากภาพที่ 3.1 เป็นขั้นตอนสำคัญในกระบวนการสร้างและพัฒนาประสิทธิภาพแบบจำลอง เนื่องจากมีความสำคัญที่จะทราบว่าแบบจำลองทำงานอย่างไรบนข้อมูลที่ไม่เคยเห็นมาก่อน และมีประสิทธิภาพเพียงใดในการทำนายข้อมูลใหม่

เมื่อสร้างแบบจำลองจากชุดข้อมูลการฝึก จะนำแบบจำลองที่ได้มาทดสอบ กับชุดข้อมูลทดสอบ เพื่อประเมินผลประสิทธิภาพด้วย ค่าความถูกต้อง F1-Score และค่าความผิดพลาด Root Mean Square Error (RMSE)

บทที่ 4

ผลการทดลอง

การศึกษา การคาดการณ์แนวโน้มหุ้นด้วยแบบจำลองต้นไม้ตัดสินใจ และแบบจำลองโครงข่ายประสาทเทียม ร่วมกับเทคนิค Internal Bar Strength ผู้ศึกษาได้ดำเนินการวิเคราะห์ข้อมูล โดยนำเสนอเป็น 3 ตอนดังนี้

- 4.1 ประสิทธิภาพการคาดการณ์แนวโน้มหุ้น ก่อนใช้แบบจำลองต้นไม้ตัดสินใจ และแบบจำลองโครงข่ายประสาทเทียม ร่วมกับเทคนิค Internal Bar Strength
- 4.2 ประสิทธิภาพการคาดการณ์แนวโน้มหุ้น หลังใช้แบบจำลองต้นไม้ตัดสินใจ และแบบจำลองโครงข่ายประสาทเทียม ร่วมกับเทคนิค Internal Bar Strength
- 4.3 การพัฒนาประสิทธิภาพการคาดการณ์แนวโน้มหุ้น โดยใช้แบบจำลองต้นไม้ตัดสินใจ และแบบจำลองโครงข่ายประสาทเทียม ร่วมกับเทคนิค Internal Bar Strength โดยมีรายละเอียดดังนี้

4.1 ประสิทธิภาพการคาดการณ์แนวโน้มหุ้น ก่อนใช้แบบจำลองต้นไม้ตัดสินใจ และแบบจำลองโครงข่ายประสาทเทียม ร่วมกับเทคนิค Internal Bar Strength

ประสิทธิภาพการคาดการณ์แนวโน้มหุ้น ก่อนใช้แบบจำลองต้นไม้ตัดสินใจ และแบบจำลองโครงข่ายประสาทเทียม ร่วมกับเทคนิค Internal Bar Strength เมื่อนำข้อมูลราคาหุ้นบริษัท Apple หุ้นบริษัท Meta Platforms Inc และหุ้นบริษัท Tesla ตั้งแต่วันที่ 01/01/2018 จนถึงวันที่ 31/12/2022 เป็นเวลา 5 ปี เพื่อฝึกแบบจำลองต้นไม้ตัดสินใจ และแบบจำลองโครงข่ายประสาทเทียม

4.1.1 แบบจำลองต้นไม้ตัดสินใจ

ประสิทธิภาพการคาดการณ์แนวโน้มหุ้น เมื่อประเมินผลการคาดการณ์ด้วยแบบจำลองต้นไม้ตัดสินใจ โดยใช้ชุดข้อมูลราคาหุ้นบริษัท Apple หุ้นบริษัท Meta Platforms Inc และหุ้นบริษัท Tesla ตั้งแต่วันที่ 01/01/2018 จนถึงวันที่ 31/12/2022 เป็นเวลา 5 ปี ได้ผลประสิทธิภาพ ดังตารางที่ 4.1, 4.2 และ 4.3

ตารางที่ 4.1 ร้อยละของประสิทธิภาพความแม่นยำในการคาดการณ์แนวโน้มหุ้น และร้อยละของค่าความผิดพลาดในการคาดการณ์แนวโน้มหุ้น กับชุดข้อมูลราคาหุ้นบริษัท Apple ด้วยแบบจำลองต้นไม้ตัดสินใจ

ปี	F1-Score (%)	RMSE (%)
2022	52.00	69.28
2021	60.78	62.62
2020	52.94	68.60
2019	66.67	57.74
2018	66.00	58.31

ตารางที่ 4.2 ร้อยละของประสิทธิภาพความแม่นยำในการคาดการณ์แนวโน้มหุ้น และร้อยละของค่าความผิดพลาดในการคาดการณ์แนวโน้มหุ้น กับชุดข้อมูลราคาหุ้นบริษัท Meta Platforms Inc ด้วยแบบจำลองต้นไม้ตัดสินใจ

ปี	F1-Score (%)	RMSE (%)
2022	64.00	60.00
2021	60.78	62.62
2020	64.71	59.41
2019	68.63	56.01
2018	54.00	67.82

ตารางที่ 4.3 ร้อยละของประสิทธิภาพความแม่นยำในการคาดการณ์แนวโน้มหุ้น และร้อยละของค่าความผิดพลาดในการคาดการณ์แนวโน้มหุ้น กับชุดข้อมูลราคาหุ้นบริษัท Tesla ด้วยแบบจำลองต้นไม้ตัดสินใจ

ปี	F1-Score (%)	RMSE (%)
2022	68.00	56.57
2021	64.71	59.41
2020	54.90	67.16
2019	62.75	61.04
2018	66.00	58.31

ร้อยละของประสิทธิภาพความแม่นยำในการคาดการณ์แนวโน้มหุ้น และร้อยละของค่าความผิดพลาดในการคาดการณ์แนวโน้มหุ้น กับชุดข้อมูลราคาหุ้น บริษัท Apple บริษัท Meta Platforms Inc และบริษัท Tesla ด้วยแบบจำลองต้นไม้ตัดสินใจ จากตารางที่ 4.1, 4.2 และ 4.3 พบว่าประสิทธิภาพการทำนายหุ้นด้วยแบบจำลองต้นไม้ตัดสินใจ ในชุดข้อมูลราคาหุ้นบริษัท Apple มีค่าความแม่นยำแบบ F1-Score จากสมการที่ 2.9 เฉลี่ยประมาณ 59.67% และมีค่า RMSE จากสมการที่ 2.10 เฉลี่ยประมาณ 63.31% ประสิทธิภาพการทำนายหุ้นด้วยแบบจำลองต้นไม้ตัดสินใจ ในชุดข้อมูลราคาหุ้นบริษัท Meta Platforms Inc มีค่าความแม่นยำแบบ F1-Score เฉลี่ยประมาณ 62.42% และมีค่า RMSE เฉลี่ยประมาณ 61.17% และประสิทธิภาพการทำนายแบบจำลองต้นไม้ตัดสินใจ ในชุดข้อมูลราคาหุ้นบริษัท Tesla มีค่าความแม่นยำแบบ F1-Score เฉลี่ยประมาณ 63.27% และมีค่า RMSE เฉลี่ยประมาณ 60.49% โดยค่า RMSE หรือค่าความผิดพลาดในการทำนายจะมีค่าที่สูงขึ้น เมื่อค่าความแม่นยำลดลง และค่า RMSE หรือค่าความผิดพลาดในการทำนายจะมีค่าลดลง เมื่อค่าความแม่นยำเพิ่มขึ้น ซึ่งในการทดสอบประสิทธิภาพความแม่นยำในการคาดการณ์ราคาหุ้นด้วยแบบจำลองต้นไม้ตัดสินใจ กับชุดข้อมูลราคาหุ้นบริษัท Meta Platforms Inc มีค่าความแม่นยำในการทำนายมากที่สุด เฉลี่ยอยู่ที่ความแม่นยำแบบ F1-Score 63.27%

4.1.2 แบบจำลองโครงข่ายประสาทเทียม

ประสิทธิภาพการคาดการณ์แนวโน้มหุ้น เมื่อประเมินผลการคาดการณ์ด้วยแบบจำลองโครงข่ายประสาทเทียม โดยใช้ชุดข้อมูลราคาหุ้นบริษัท Tesla หุ้น ตั้งแต่วันที่ 01/01/2022 จนถึงวันที่ 31/12/2022 เป็นเวลา 1 ปี ในการทดสอบปรับค่าพารามิเตอร์ เช่น จำนวน Hidden Node ขนาด Batch Size และจำนวนรอบ Epochs ของแบบจำลองโครงข่ายประสาทเทียม เพื่อให้ได้ประสิทธิภาพในการคาดการณ์ราคาหุ้นที่แม่นยำมากที่สุด

1. โหนดที่ซ่อนอยู่ (Hidden Node) ที่อยู่ในชั้นโหนดภายใน (Hidden Layer) มีหน้าที่ประมวลผลข้อมูลที่ได้รับจากชั้นนำเข้าข้อมูล (Input Layer) และส่งผลลัพธ์ให้ชั้นผลลัพธ์ของการประมวลผล (Output Layer) โดยแบบจำลองโครงข่ายประสาทเทียมที่มี Hidden Node จำนวนมากจะทำให้โครงข่ายมีความซับซ้อนที่มาก และเมื่อมี Hidden Node จำนวนน้อยจะทำให้โครงข่ายมีความซับซ้อนที่น้อย ซึ่งการทดสอบจะปรับจำนวน Hidden Node จะใช้ Hidden Node จำนวน 4, 16, 32 และ 64
2. ขนาดกลุ่ม (Batch Size) คือจำนวนตัวอย่างที่ใช้ในแต่ละรอบการอัปเดตน้ำหนักของโครงข่าย โดยแบบจำลองโครงข่ายประสาทเทียมที่มีขนาด Batch Size ใหญ่

จะทำให้การอัปเดตน้ำหนักเป็นที่ละกลุ่มตัวอย่าง ทำให้ลดเวลาในการคำนวณ และเมื่อมีขนาด Batch Size เล็กจะทำให้การอัปเดตน้ำหนักเป็นที่ละตัวอย่าง ทำให้เพิ่มเวลาในการคำนวณ ซึ่งการทดสอบจะปรับขนาด Batch Size 4, 16 และ 32

3. รอบการฝึก (Epochs) คือจำนวนรอบที่โครงข่ายได้ทำการฝึกชุดข้อมูลในแบบจำลองโครงข่ายประสาทเทียม โดย Epochs ที่มีค่าน้อยจะใช้เวลาในการฝึกที่น้อย ทำให้โครงข่ายไม่สามารถเรียนรู้รูปแบบทั้งหมดที่มีในชุดข้อมูล และ Epochs ที่มีค่ามากจะใช้เวลาในการฝึกที่มาก ทำให้โครงข่ายสามารถเรียนรู้รูปแบบทั้งหมดที่มีในชุดข้อมูล ซึ่งการทดสอบจะปรับค่า Epochs เป็นจำนวน 100, 300 และ 500 รอบ

ตารางที่ 4.4 แบบจำลองโครงข่ายประสาทเทียมที่มี Hidden Node จำนวน 4 Node, Batch Size ขนาด 4 และ Epochs จำนวน 100 รอบ 300 รอบ และ 500 รอบ

Hidden Node	Batch Size	Epochs	Training Time (s)	F1-Score (%)	RMSE (%)
4	4	100	10.20	63.58	48.15
4	4	300	27.29	63.32	47.70
4	4	500	46.17	68.40	47.24

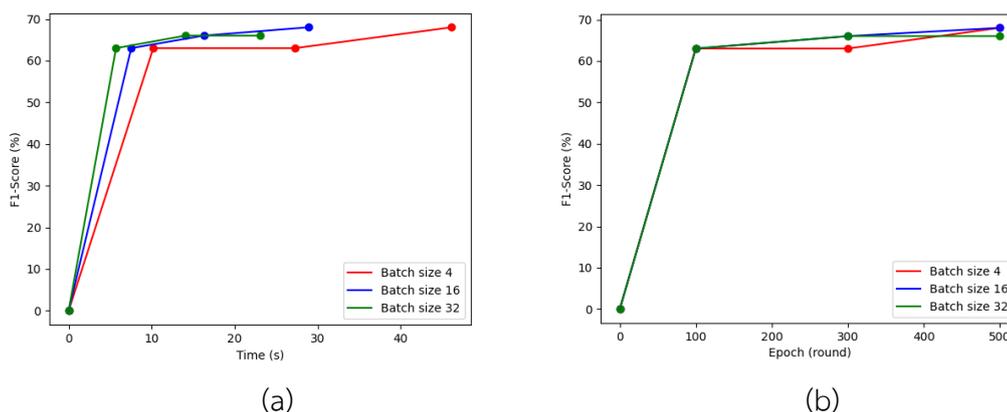
ตารางที่ 4.5 แบบจำลองโครงข่ายประสาทเทียมที่มี Hidden Node จำนวน 4 Node, Batch Size ขนาด 16 และ Epochs จำนวน 100 รอบ 300 รอบ และ 500 รอบ

Hidden Node	Batch Size	Epochs	Training Time (s)	F1-Score (%)	RMSE (%)
4	16	100	7.55	63.55	49.93
4	16	300	16.28	66.81	45.7
4	16	500	28.89	68.22	46.10

ตารางที่ 4.6 แบบจำลองโครงข่ายประสาทเทียมที่มี Hidden Node 4 จำนวน Node, Batch Size ขนาด 32 และ Epochs จำนวน 100 รอบ 300 รอบ และ 500 รอบ

Hidden Node	Batch Size	Epochs	Training Time (s)	F1-Score (%)	RMSE (%)
4	32	100	5.71	63.27	46.35
4	32	300	14.07	66.36	48.90
4	32	500	23.07	66.47	48.45

จากตารางที่ 4.4, 4.5 และ 4.6 เป็นผลประสิทธิภาพแบบจำลองโครงข่ายประสาทเทียมที่มี Hidden Node จำนวน 4 Node ทดสอบกับ Batch Size ขนาด 4, 16 และ 32 และทดสอบกับ Epochs จำนวน 100 รอบ 300 รอบ และ 500 รอบ แสดงข้อมูลในรูปแบบตาราง พบว่า เวลา Training Time ลดลงเมื่อขนาด Batch Size ใหญ่และเวลา Training Time เพิ่มขึ้นเมื่อจำนวนรอบ Epochs มากขึ้น ซึ่งเวลาที่เพิ่มขึ้นของ Training Time ทำให้ค่าความแม่นยำแบบ F1-Score เพิ่มขึ้น และค่า RMSE มีค่าลดลง โดยข้อมูลตัวหนังสือสีแดงในตารางที่ 4.5 เป็นผลประสิทธิภาพที่ดีที่สุดของแบบจำลองโครงข่ายประสาทเทียมที่มี Hidden Node จำนวน 4 Node มีค่า F1-Score 68% ค่า RMSE 46% และเวลา Training Time 28.89 วินาทีเมื่อ Batch Size ขนาด 16 และ Epochs จำนวน 500 รอบ



ภาพที่ 4.1 ความแม่นยำของแบบจำลองโครงข่ายประสาทเทียมที่มี Hidden Node จำนวน 4 Node

จากภาพที่ 4.1 เป็นผลประสิทธิภาพแบบจำลองโครงข่ายประสาทเทียมที่มี Hidden Node จำนวน 4 Node ทดสอบกับ Batch Size ขนาด 4, 16 และ 32 และทดสอบกับ Epochs

จำนวน 100 รอบ 300 รอบ และ 500 รอบ แสดงในรูปแบบกราฟเส้น โดยภาพ (a) เป็นกราฟเส้นแสดงผลร้อยละของความแม่นยำแบบ F1-Score ในแกน Y และ Time ในแกน X และภาพ (b) เป็นกราฟเส้นแสดงผลร้อยละของความแม่นยำแบบ F1-Score ในแกน Y และจำนวน Epoch ในแกน X โดยเส้นสีส้มแทน Batch Size ขนาด 4 สีน้ำเงินแทน Batch Size ขนาด 16 และสีเขียวแทน Batch Size ขนาด 32

ตารางที่ 4.7 แบบจำลองโครงข่ายประสาทเทียมที่มี Hidden Node จำนวน 16 Node, Batch Size ขนาด 4 และ Epochs จำนวน 100 รอบ 300 รอบ และ 500 รอบ

Hidden Node	Batch Size	Epochs	Training Time (s)	F1-Score (%)	RMSE (%)
16	4	100	12.80	66.23	47.85
16	4	300	38.23	68.55	47.62
16	4	500	46.76	68.29	47.67

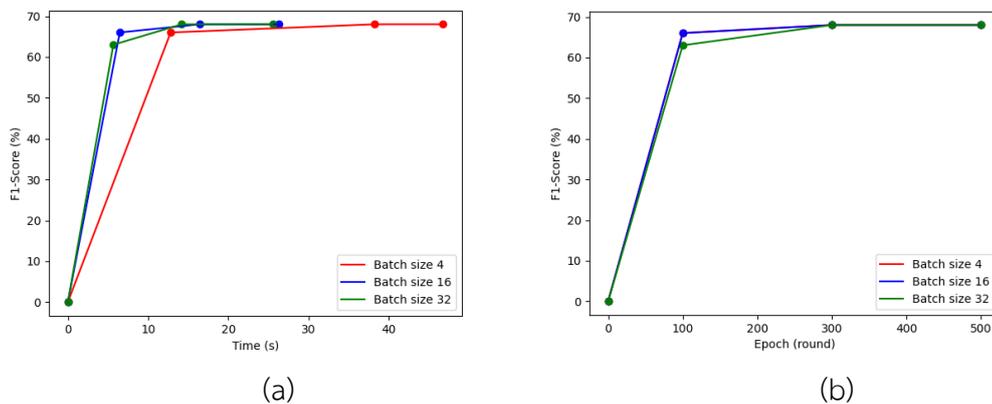
ตารางที่ 4.8 แบบจำลองโครงข่ายประสาทเทียมที่มี Hidden Node จำนวน 16 Node, Batch Size ขนาด 16 และ Epochs จำนวน 100 รอบ 300 รอบ และ 500 รอบ

Hidden Node	Batch Size	Epochs	Training Time (s)	F1-Score (%)	RMSE (%)
16	16	100	6.47	66.21	46.74
16	16	300	16.39	68.36	45.82
16	16	500	26.26	68.78	46.63

ตารางที่ 4.9 แบบจำลองโครงข่ายประสาทเทียมที่มี Hidden Node จำนวน 16 Node, Batch Size ขนาด 32 และ Epochs จำนวน 100 รอบ 300 รอบ และ 500 รอบ

Hidden Node	Batch Size	Epochs	Training Time (s)	F1-Score (%)	RMSE (%)
16	32	100	5.67	63.23	47.54
16	32	300	14.20	68.64	46.53
16	32	500	25.50	68.00	47.76

จากตารางที่ 4.7, 4.8 และ 4.9 เป็นผลประสิทธิภาพแบบจำลองโครงข่ายประสาทเทียมที่มี Hidden Node จำนวน 16 Node ทดสอบกับ Batch Size ขนาด 4, 16 และ 32 และทดสอบกับ Epochs จำนวน 100 รอบ 300 รอบ และ 500 รอบ แสดงข้อมูลในรูปแบบตาราง พบว่า เวลา Training Time ลดลงเมื่อขนาด Batch Size ใหญ่และเวลา Training Time เพิ่มขึ้นเมื่อจำนวนรอบ Epochs มากขึ้น ซึ่งเวลาที่เพิ่มขึ้นของ Training Time ทำให้ค่าความแม่นยำแบบ F1-Score เพิ่มขึ้น และค่า RMSE มีค่าลดลง โดยข้อมูลตัวหนังสือสีแดงในตารางที่ 4.8 เป็นผลประสิทธิภาพที่ดีที่สุดของแบบจำลองโครงข่ายประสาทเทียมที่มี Hidden Node จำนวน 16 Node มีค่า F1-Score 68% ค่า RMSE 45% และเวลา Training Time 16.39 วินาทีเมื่อ Batch Size ขนาด 16 และ Epochs จำนวน 300 รอบ



ภาพที่ 4.2 ความแม่นยำของแบบจำลองโครงข่ายประสาทเทียมที่มี Hidden Node จำนวน 16 Node

จากภาพที่ 4.2 เป็นผลประสิทธิภาพแบบจำลองโครงข่ายประสาทเทียมที่มี Hidden Node จำนวน 16 Node ทดสอบกับ Batch Size ขนาด 4, 16 และ 32 และทดสอบกับ Epochs จำนวน 100 รอบ 300 รอบ และ 500 รอบ แสดงในรูปแบบกราฟเส้น โดยภาพ (a) เป็นกราฟเส้นแสดงผลร้อยละของความแม่นยำแบบ F1-Score ในแกน Y และ Time ในแกน X และภาพ (b) เป็นกราฟเส้นแสดงผลร้อยละของความแม่นยำแบบ F1-Score ในแกน Y และจำนวน Epoch ในแกน X โดยเส้นสีส้มแทน Batch Size ขนาด 4 สีน้ำเงินแทน Batch Size ขนาด 16 และสีเขียวแทน Batch Size ขนาด 32

ตารางที่ 4.10 แบบจำลองโครงข่ายประสาทเทียมที่มี Hidden Node จำนวน 32 Node, Batch Size ขนาด 4 และ Epochs จำนวน 100 รอบ 300 รอบ และ 500 รอบ

Hidden Node	Batch Size	Epochs	Training Time (s)	F1-Score (%)	RMSE (%)
32	4	100	14.50	68.10	45.60
32	4	300	33.01	71.32	47.60
32	4	500	53.42	71.00	46.64

ตารางที่ 4.11 แบบจำลองโครงข่ายประสาทเทียมที่มี Hidden Node จำนวน 32 Node, Batch Size ขนาด 16 และ Epochs จำนวน 100 รอบ 300 รอบ และ 500 รอบ

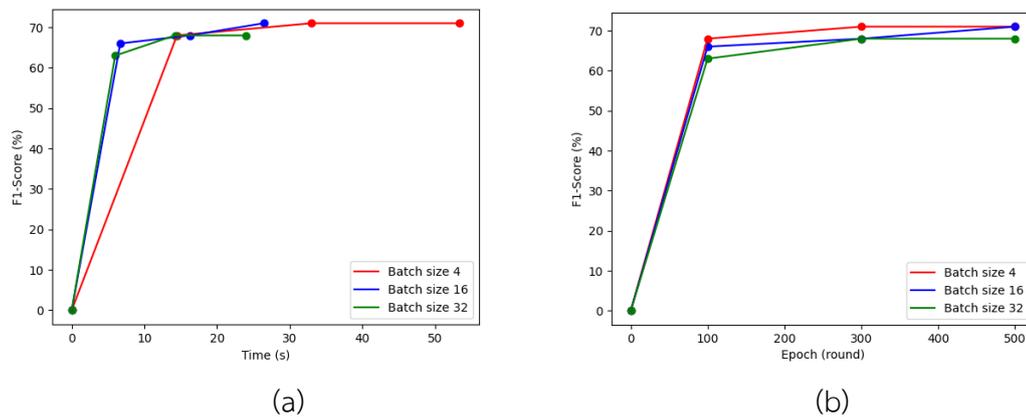
Hidden Node	Batch Size	Epochs	Training Time (s)	F1-Score (%)	RMSE (%)
32	16	100	6.68	66.95	47.21
32	16	300	16.24	68.57	46.85
32	16	500	26.42	71.47	45.32

ตารางที่ 4.12 แบบจำลองโครงข่ายประสาทเทียมที่มี Hidden Node จำนวน 32 Node, Batch Size ขนาด 32 และ Epochs จำนวน 100 รอบ 300 รอบ และ 500 รอบ

Hidden Node	Batch Size	Epochs	Training Time (s)	F1-Score (%)	RMSE (%)
32	32	100	5.99	63.85	47.79
32	32	300	14.23	68.64	47.20
32	32	500	23.96	68.35	47.71

จากตารางที่ 4.10, 4.11 และ 4.12 เป็นผลประสิทธิภาพแบบจำลองโครงข่ายประสาทเทียมที่มี Hidden Node จำนวน 32 Node ทดสอบกับ Batch Size ขนาด 4, 16 และ 32 และทดสอบกับ Epochs จำนวน 100 รอบ 300 รอบ และ 500 รอบ แสดงข้อมูลในรูปแบบตารางพบว่าเวลา Training Time ลดลงเมื่อขนาด Batch Size ใหญ่และเวลา Training Time เพิ่มขึ้นเมื่อจำนวนรอบ Epochs มากขึ้น ซึ่งเวลาที่เพิ่มขึ้นของ Training Time ทำให้ค่าความแม่นยำแบบ F1-Score เพิ่มขึ้น และค่า RMSE มีค่าลดลง โดยข้อมูลตัวหนังสือสีแดงในตารางที่ 4.11 เป็นผล

ประสิทธิภาพที่ดีที่สุดของแบบจำลองโครงข่ายประสาทเทียมที่มี Hidden Node จำนวน 32 Node มีค่า F1-Score 71% ค่า RMSE 45% และเวลา Training Time 26.42 วินาทีเมื่อ Batch Size ขนาด 16 และ Epochs จำนวน 500 รอบ



ภาพที่ 4.3 ความแม่นยำของแบบจำลองโครงข่ายประสาทเทียมที่มี Hidden Node จำนวน 32 Node

จากภาพที่ 4.3 เป็นผลประสิทธิภาพแบบจำลองโครงข่ายประสาทเทียมที่มี Hidden Node จำนวน 32 Node ทดสอบกับ Batch Size ขนาด 4, 16 และ 32 และทดสอบกับ Epochs จำนวน 100 รอบ 300 รอบ และ 500 รอบ แสดงในรูปแบบกราฟเส้น โดยภาพ (a) เป็นกราฟเส้นแสดงผลร้อยละของความแม่นยำแบบ F1-Score ในแกน Y และ Time ในแกน X และภาพ (b) คือกราฟเส้นแสดงผลร้อยละของความแม่นยำแบบ F1-Score ในแกน Y และจำนวน Epoch ในแกน X โดยเส้นสีส้มแทน Batch Size ขนาด 4 สีน้ำเงินแทน Batch Size ขนาด 16 และสีเขียวแทน Batch Size ขนาด 32

ตารางที่ 4.13 แบบจำลองโครงข่ายประสาทเทียมที่มี Hidden Node จำนวน 64 Node, Batch Size ขนาด 4 และ Epochs จำนวน 100 รอบ 300 รอบ และ 500 รอบ

Hidden Node	Batch Size	Epochs	Training Time (s)	F1-Score (%)	RMSE (%)
64	4	100	15.33	71.62	45.95
64	4	300	38.04	71.20	47.85
64	4	500	55.79	71.03	48.10

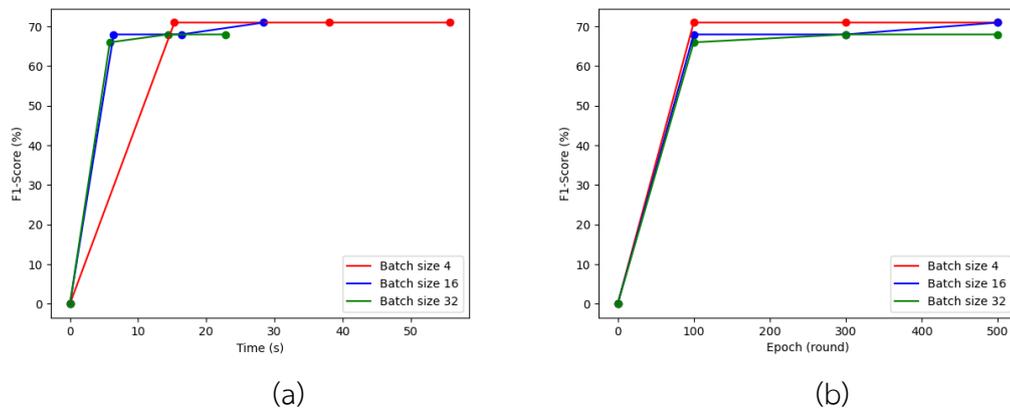
ตารางที่ 4.14 แบบจำลองโครงข่ายประสาทเทียมที่มี Hidden Node จำนวน 64 Node, Batch Size ขนาด 16 และ Epochs จำนวน 100 รอบ 300 รอบ และ 500 รอบ

Hidden Node	Batch Size	Epochs	Training Time (s)	F1-Score (%)	RMSE (%)
64	16	100	6.42	68.23	47.10
64	16	300	16.37	68.65	47.26
64	16	500	28.43	71.33	46.03

ตารางที่ 4.15 แบบจำลองโครงข่ายประสาทเทียมที่มี Hidden Node จำนวน 64 Node, Batch Size ขนาด 32 และ Epochs จำนวน 100 รอบ 300 รอบ และ 500 รอบ

Hidden Node	Batch Size	Epochs	Training Time (s)	F1-Score (%)	RMSE (%)
64	32	100	5.85	66.78	46.70
64	32	300	14.39	68.32	47.54
64	32	500	22.79	68.16	48.71

จากตารางที่ 4.13, 4.14 และ 4.15 เป็นผลประสิทธิภาพแบบจำลองโครงข่ายประสาทเทียมที่มี Hidden Node จำนวน 64 Node ทดสอบกับ Batch Size ขนาด 4, 16 และ 32 และทดสอบกับ Epochs จำนวน 100 รอบ 300 รอบ และ 500 รอบ แสดงข้อมูลในรูปแบบตารางพบว่าเวลา Training Time ลดลงเมื่อขนาด Batch Size ใหญ่และเวลา Training Time เพิ่มขึ้นเมื่อจำนวนรอบ Epochs มากขึ้น ซึ่งเวลาที่เพิ่มขึ้นของ Training Time ทำให้ค่าความแม่นยำแบบ F1-Score เพิ่มขึ้น และค่า RMSE มีค่าลดลง โดยข้อมูลตัวหนังสือสีแดงในตารางที่ 4.13 เป็นผลประสิทธิภาพที่ดีที่สุดของแบบจำลองโครงข่ายประสาทเทียมที่มี Hidden Node จำนวน 32 Node มีค่า F1-Score 71% ค่า RMSE 45% และเวลา Training Time 15.33 วินาทีเมื่อ Batch Size ขนาด 16 และ Epochs จำนวน 500 รอบ



ภาพที่ 4.4 ความแม่นยำของแบบจำลองโครงข่ายประสาทเทียมที่มี Hidden Node จำนวน 64 Node

จากภาพที่ 4.4 เป็นผลประสิทธิภาพแบบจำลองโครงข่ายประสาทเทียมที่มี Hidden Node จำนวน 64 Node ทดสอบกับ Batch Size ขนาด 4, 16 และ 32 และทดสอบกับ Epochs จำนวน 100 รอบ 300 รอบ และ 500 รอบ แสดงในภาพแบบกราฟเส้น โดยภาพ (a) เป็นกราฟเส้นแสดงผลร้อยละของความแม่นยำแบบ F1-Score ในแกน Y และ Time ในแกน X และภาพ (b) เป็นกราฟเส้นแสดงผลร้อยละของความแม่นยำแบบ F1-Score ในแกน Y และจำนวน Epoch ในแกน X โดยเส้นสีส้มแทน Batch Size ขนาด 4 สีน้ำเงินแทน Batch Size ขนาด 16 และสีเขียวแทน Batch Size ขนาด 32

ตารางที่ 4.16 ผลประสิทธิภาพที่ดีที่สุดของการปรับจำนวน Hidden Node ขนาด Batch Size และจำนวน Epochs ในแบบจำลองโครงข่ายประสาทเทียม

Hidden Node	Batch Size	Epochs	Training Time (s)	F1-Score (%)	RMSE (%)
4	16	500	28.89	68.22	46.10
16	16	300	16.39	68.36	45.82
32	16	500	26.42	71.47	45.32
64	4	100	15.33	71.62	45.95

จากตารางที่ 4.16 พบว่าการปรับจำนวน Hidden Node มากขึ้นทำให้เวลา Training Time เพิ่มขึ้น และมีค่าความแม่นยำแบบ F1-Score เพิ่มขึ้น การปรับขนาด Batch Size ใหญ่ขึ้นทำให้เวลา Training Time และค่า F1-Score ลดลง และการปรับจำนวนรอบ Epochs มากขึ้นทำให้เวลา Training Time และค่า F1-Score เพิ่มขึ้น ดังนั้นจาก ตารางที่ 4.5, 4.8, 4.11 และ 4.11 ได้มีการปรับพารามิเตอร์ของแบบจำลองโครงข่ายประสาทเทียมให้ได้ผลประสิทธิภาพที่ดีที่สุดในแต่ละตาราง นำมาคัดเลือกค่าพารามิเตอร์ที่ได้ผลประสิทธิภาพที่ดีที่สุดคือ Hidden Node จำนวน 64, Batch Size ขนาด 4 และ Epochs จำนวน 100 รอบจะได้ค่า F1-Score ที่ดีที่สุด 71% ค่า RMSE 45% และเวลา Training Time 15.33 วินาที เป็นเวลาที่ดีที่สุดเมื่อเทียบกับเวลา Training Time ที่มีค่า F1-Score ที่ดีที่สุด ดังนั้นการปรับค่าพารามิเตอร์ของแบบจำลองโครงข่ายประสาทเทียมที่ได้ผลประสิทธิภาพดีที่สุดในการคาดการณ์ราคาหุ้นจะมี Hidden Node จำนวน 64, Batch Size ขนาด 4 และ Epochs จำนวน 100

ประสิทธิภาพการคาดการณ์ราคาหุ้น เมื่อประเมินผลการคาดการณ์ด้วยแบบจำลองโครงข่ายประสาทเทียมที่มีการปรับพารามิเตอร์ Hidden Node จำนวน 64, Batch Size ขนาด 4 และ Epochs จำนวน 100 โดยใช้ชุดข้อมูลราคาหุ้นบริษัท APPL หุ้นบริษัท Meta Platforms Inc และหุ้นบริษัท Tesla ตั้งแต่วันที่ 01/01/2018 จนถึงวันที่ 31/12/2022 เป็นเวลา 5 ปี ได้ผลประสิทธิภาพ ดังตารางที่ 4.17, 4.18 และ 4.19

ตารางที่ 4.17 ร้อยละของประสิทธิภาพความแม่นยำในการคาดการณ์แนวโน้มหุ้น และร้อยละของความผิดพลาดในการคาดการณ์แนวโน้มหุ้น กับชุดข้อมูลราคาหุ้นบริษัท Apple ด้วยแบบจำลองโครงข่ายประสาทเทียม

ปี	F1-Score (%)	RMSE (%)
2022	60.00	63.25
2021	64.71	59.41
2020	64.71	59.41
2019	66.67	57.74
2018	72.00	52.92

ตารางที่ 4.18 ร้อยละของประสิทธิภาพความแม่นยำในการคาดการณ์แนวโน้มหุ้น และร้อยละของค่าความผิดพลาดในการคาดการณ์แนวโน้มหุ้น กับชุดข้อมูลราคาหุ้นบริษัท Meta Platforms Inc ด้วยแบบจำลองโครงข่ายประสาทเทียม

ปี	F1-Score (%)	RMSE (%)
2022	60.00	63.25
2021	65.67	57.74
2020	70.59	54.23
2019	74.51	50.49
2018	53.00	67.82

ตารางที่ 4.19 ร้อยละของประสิทธิภาพความแม่นยำในการคาดการณ์แนวโน้มหุ้น และร้อยละของค่าความผิดพลาดในการคาดการณ์แนวโน้มหุ้น กับชุดข้อมูลราคาหุ้นบริษัท Tesla ด้วยแบบจำลองโครงข่ายประสาทเทียม

ปี	F1-Score (%)	RMSE (%)
2022	74.00	48.99
2021	67.63	56.01
2020	77.43	46.44
2019	56.86	65.68
2018	74.00	50.99

ร้อยละของประสิทธิภาพความแม่นยำในการคาดการณ์แนวโน้มหุ้น และร้อยละของค่าความผิดพลาดในการคาดการณ์แนวโน้มหุ้น กับชุดข้อมูลราคาหุ้น บริษัท Apple บริษัท Meta Platforms Inc และบริษัท Tesla ด้วยแบบจำลองโครงข่ายประสาทเทียม จากตารางที่ 4.17, 4.18 และ 4.19 พบว่าประสิทธิภาพการทำนายหุ้นด้วยแบบจำลองโครงข่ายประสาทเทียม ในชุดข้อมูลราคาหุ้นบริษัท Apple มีค่าความแม่นยำแบบ F1-Score จากสมการที่ 2.9 เฉลี่ยประมาณ 65.61% และมีค่า RMSE จากสมการที่ 2.10 เฉลี่ยประมาณ 58.54% ประสิทธิภาพการทำนายหุ้นด้วยแบบจำลองโครงข่ายประสาทเทียม ในชุดข้อมูลราคาหุ้นบริษัท Meta Platforms Inc มีค่าความแม่นยำแบบ F1-Score เฉลี่ยประมาณ 64.75% และมีค่า RMSE เฉลี่ยประมาณ 58.70% และประสิทธิภาพการทำนายแบบจำลองโครงข่ายประสาทเทียม ในชุดข้อมูลราคาหุ้นบริษัท Tesla มีค่าความแม่นยำแบบ F1-Score เฉลี่ยประมาณ 69.98% และมีค่า RMSE เฉลี่ยประมาณ 53.62% โดยค่า RMSE หรือค่าความผิดพลาดในการทำนายจะมีค่าที่สูงขึ้น เมื่อค่าความแม่นยำลดลง และค่า

RMSE หรือค่าความผิดพลาดในการทำนายจะมีค่าลดลง เมื่อค่าความแม่นยำเพิ่มขึ้น ซึ่งในการทดสอบประสิทธิภาพความแม่นยำในการคาดการณ์ราคาหุ้นด้วยแบบจำลองโครงข่ายประสาทเทียม กับชุดข้อมูลราคาหุ้นบริษัท Tesla มีค่า F1-Score ในการทำนายมากที่สุด เฉลี่ยอยู่ที่ความแม่นยำแบบ F1-Score 69.98%

4.2 ประสิทธิภาพการคาดการณ์แนวโน้มหุ้น หลังใช้แบบจำลองต้นไม้ตัดสินใจ และแบบจำลองโครงข่ายประสาทเทียม ร่วมกับเทคนิค Internal Bar Strength

ประสิทธิภาพการคาดการณ์แนวโน้มหุ้น หลังใช้แบบจำลองต้นไม้ตัดสินใจ และแบบจำลองโครงข่ายประสาทเทียม ร่วมกับเทคนิค Internal Bar Strength เมื่อนำข้อมูลราคาหุ้นบริษัท Apple หุ้นบริษัท Meta Platforms Inc และหุ้นบริษัท Tesla ตั้งแต่วันที่ 01/01/2018 จนถึงวันที่ 31/12/2022 เป็นเวลา 5 ปี เพื่อฝึกแบบจำลองต้นไม้ตัดสินใจ และแบบจำลองโครงข่ายประสาทเทียม ร่วมกับเทคนิค Internal Bar Strength

4.2.1 การรวมแบบจำลองโหวต

ประสิทธิภาพการคาดการณ์แนวโน้มหุ้น เมื่อประเมินผลการคาดการณ์ด้วยการรวมแบบจำลองโหวต (VE) เป็นการทำงานของแบบจำลองต้นไม้ตัดสินใจ และแบบจำลองโครงข่ายประสาทเทียม ร่วมกับเทคนิค Internal Bar Strength โดยใช้ชุดข้อมูลราคาหุ้นบริษัท Apple หุ้นบริษัท Meta Platforms Inc และหุ้นบริษัท Tesla ตั้งแต่วันที่ 01/01/2018 จนถึงวันที่ 31/12/2022 เป็นเวลา 5 ปี ได้ผลประสิทธิภาพ ดังตารางที่ 4.20, 4.21 และ 4.22

ตารางที่ 4.20 ร้อยละของประสิทธิภาพความแม่นยำในการคาดการณ์แนวโน้มหุ้น และร้อยละของค่าความผิดพลาดในการคาดการณ์แนวโน้มหุ้น กับชุดข้อมูลราคาหุ้นบริษัท Apple ด้วยแบบจำลองโหวต

ปี	F1-Score (%)	RMSE (%)
2022	60.00	63.25
2021	76.47	48.51
2020	64.71	59.41
2019	68.63	56.01
2018	70.00	54.77

ตารางที่ 4.21 ร้อยละของประสิทธิภาพความแม่นยำในการคาดการณ์แนวโน้มหุ้น และร้อยละของค่าความผิดพลาดในการคาดการณ์แนวโน้มหุ้น กับชุดข้อมูลราคาหุ้นบริษัท Meta Platforms Inc ด้วยแบบจำลองโหวต

ปี	F1-Score (%)	RMSE (%)
2022	60.00	63.25
2021	62.75	61.04
2020	70.59	54.23
2019	75.51	50.49
2018	56.00	66.33

ตารางที่ 4.22 ร้อยละของประสิทธิภาพความแม่นยำในการคาดการณ์แนวโน้มหุ้น และร้อยละของค่าความผิดพลาดในการคาดการณ์แนวโน้มหุ้น กับชุดข้อมูลราคาหุ้นบริษัท Tesla ด้วยแบบจำลองโหวต

ปี	F1-Score (%)	RMSE (%)
2022	74.00	50.99
2021	70.59	54.23
2020	71.59	54.23
2019	58.82	64.17
2018	78.00	46.90

ร้อยละของประสิทธิภาพความแม่นยำในการคาดการณ์แนวโน้มหุ้น และร้อยละของค่าความผิดพลาดในการคาดการณ์แนวโน้มหุ้น กับชุดข้อมูลราคาหุ้น บริษัท Apple บริษัท Meta Platforms Inc และบริษัท Tesla ด้วยแบบจำลอง VE จากตารางที่ 4.20, 4.21 และ 4.22 พบว่าประสิทธิภาพการทำนายหุ้น VE ในชุดข้อมูลราคาหุ้นบริษัท Apple มีค่าความแม่นยำแบบ F1-Score เฉลี่ยประมาณ 67.96% และมีค่า RMSE เฉลี่ยประมาณ 56.39% ประสิทธิภาพการทำนายหุ้นด้วยแบบจำลองโหวต ในชุดข้อมูลราคาหุ้นบริษัท Meta Platforms Inc มีค่าความแม่นยำแบบ F1-Score เฉลี่ยประมาณ 64.97% และมีค่า RMSE เฉลี่ยประมาณ 59.06% และประสิทธิภาพการทำนายแบบจำลอง VE ในชุดข้อมูลราคาหุ้นบริษัท Tesla มีค่าความแม่นยำแบบ F1-Score เฉลี่ยประมาณ 70.60% และมีค่า RMSE เฉลี่ยประมาณ 54.10% โดยค่า RMSE หรือค่าความผิดพลาดในการทำนายจะมีค่าที่สูงขึ้น เมื่อค่าความแม่นยำลดลง และค่า RMSE หรือค่าความผิดพลาดในการทำนายจะมีค่าลดลง เมื่อค่าความแม่นยำเพิ่มขึ้น ซึ่งในการทดสอบประสิทธิภาพความแม่นยำในการคาดการณ์ราคา

หุ้นด้วยแบบจำลอง VE กับชุดข้อมูลราคาหุ้นบริษัท Apple มีค่าความแม่นยำในการทำนายมากที่สุด โดยมีค่าความแม่นยำแบบ F1-Score เฉลี่ยประมาณ 67.96%

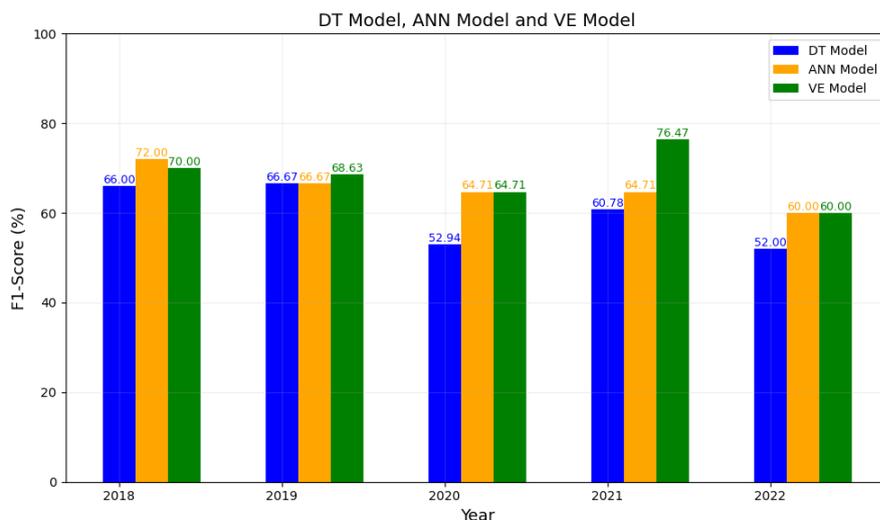
4.3 การพัฒนาประสิทธิภาพการคาดการณ์แนวโน้มหุ้น โดยใช้แบบจำลองต้นไม้ตัดสินใจ และแบบจำลองโครงข่ายประสาทเทียมร่วมกับเทคนิค Internal Bar Strength

การพัฒนาประสิทธิภาพการคาดการณ์แนวโน้มหุ้นก่อนและหลังใช้แบบจำลองต้นไม้ตัดสินใจ และแบบจำลองโครงข่ายประสาทเทียม ร่วมกับเทคนิค Internal Bar Strength หรือก่อนและหลังใช้แบบจำลองโหวต (VE) ดังหัวข้อการรวมแบบจำลองโหวตที่ 3.5 ในภาพที่ 3.5 พัฒนาประสิทธิภาพการคาดการณ์แนวโน้มหุ้น โดยการนำข้อมูลราคาหุ้นบริษัท Apple หุ้นบริษัท Meta Platforms Inc และหุ้นบริษัท Tesla ตั้งแต่วันที่ 01/01/2018 จนถึงวันที่ 31/12/2022 เป็นเวลา 5 ปี เพื่อฝึกแบบจำลองต้นไม้ตัดสินใจ และแบบจำลองโครงข่ายประสาทเทียม ร่วมกับเทคนิค Internal Bar Strength แสดงผลประสิทธิภาพดังตารางที่ 4.23, 4.24 และ 4.25

ตารางที่ 4.23 ร้อยละของประสิทธิภาพความแม่นยำในการคาดการณ์แนวโน้มหุ้น กับชุดข้อมูลราคาหุ้นบริษัท Apple ก่อนและหลังใช้แบบจำลองโหวต

ปี	ผลการทำนายก่อนใช้ VE		ผลการทำนายหลังใช้ VE F1-Score (%)	F1-Score เพิ่มขึ้นจาก DT (%)	F1-Score เพิ่มขึ้นจาก ANN (%)
	F1-Score DT (%)	F1-Score ANN (%)			
2022	52.00	60.00	60.00	8.00	0.00
2021	60.78	64.71	76.47	15.69	11.76
2020	52.94	64.71	64.71	11.77	0.00
2019	66.67	66.67	68.63	1.96	1.96
2018	66.00	72.00	70.00	4.00	-2.00

จากตารางที่ 4.23 พบว่าผลการทำนายราคาหุ้นบริษัท Apple หลังใช้แบบจำลอง VE เปรียบเทียบผลการทำนายก่อนใช้ VE กับค่า F1-Score แบบจำลอง DT มีค่า F1-Score เพิ่มขึ้นจาก DT สูงสุดมีค่า F1-Score 15.69% ต่ำสุดมีค่า F1-Score 1.96% และมีค่า F1-Score เพิ่มขึ้นเฉลี่ยประมาณ 8.28% และผลการทำนายหลังใช้แบบจำลอง VE เปรียบเทียบผลการทำนายก่อนใช้แบบจำลอง VE กับค่า F1-Score แบบจำลอง ANN มีค่า F1-Score เพิ่มขึ้นจาก ANN สูงสุดมีค่า F1-Score 11.76% ต่ำสุดมีค่า F1-Score -2.00% และมีค่า F1-Score เพิ่มขึ้นเฉลี่ยประมาณ 2.34%



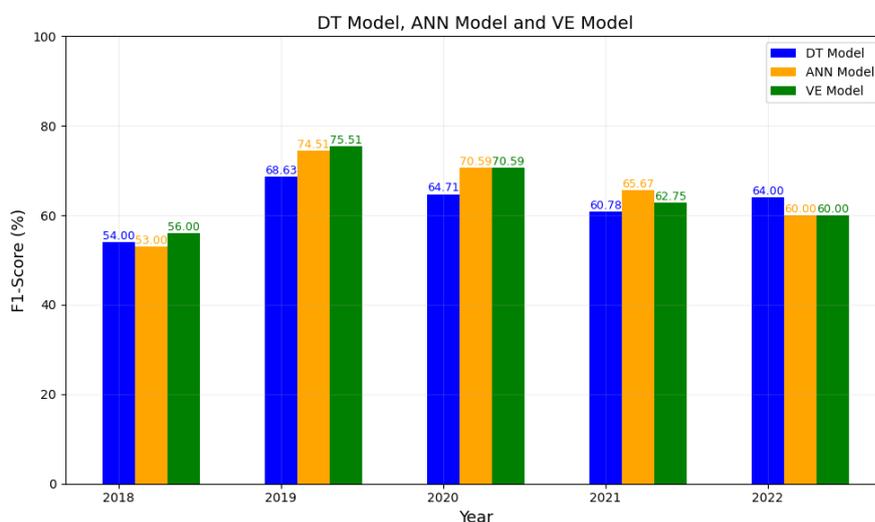
ภาพที่ 4.5 ร้อยละของความแม่นยำ ก่อนและหลังใช้แบบจำลองโหวต กับราคาหุ้นบริษัท Apple

จากภาพที่ 4.5 เป็นกราฟแท่งแสดงข้อมูลประสิทธิภาพความแม่นยำในการคาดการณ์แนวโน้มหุ้น ก่อนและหลังใช้แบบจำลอง VE ด้วยข้อมูลราคาบริษัท Apple ตั้งแต่ปี 2018 จนถึงปี 2022 เป็นเวลา 5 ปี โดยค่าความแม่นยำแบบ F1-Score ในแกน Y และนับเวลาเป็น Year ในแกน X โดยที่ในแท่งกราฟสีน้ำเงิน คือค่า F1-Score ของ DT Model หรือแบบจำลองต้นไม้ตัดสินใจ แท่งกราฟสีส้ม คือค่า F1-Score ของ ANN Model หรือแบบจำลองโครงข่ายประสาทเทียม และแท่งกราฟสีน้ำเขียว คือค่า F1-Score ของ VE Model หรือแบบจำลอง VE ซึ่งหลังใช้แบบจำลอง VE มีค่า F1-Score เพิ่มขึ้นมากกว่าก่อนใช้แบบจำลอง VE จำนวน 2 ปี คือปี 2021 และปี 2019

ตารางที่ 4.24 ร้อยละของประสิทธิภาพความแม่นยำในการคาดการณ์แนวโน้มหุ้น กับชุดข้อมูลราคาหุ้นบริษัท Meta Platforms Inc ก่อนและหลังใช้แบบจำลองโหวต

ปี	ผลการทำนายก่อนใช้ VE		ผลการทำนายหลังใช้ VE F1-Score (%)	F1-Score เพิ่มขึ้นจาก DT (%)	F1-Score เพิ่มขึ้นจาก ANN (%)
	F1-Score DT (%)	F1-Score ANN (%)			
2022	64.00	60.00	60.00	-4.00	0.00
2021	60.78	65.67	62.75	1.97	-2.92
2020	64.71	70.59	70.59	5.88	0.00
2019	68.63	74.51	75.51	6.88	1.00
2018	54.00	53.00	56.00	2.00	3.00

จากตารางที่ 4.24 พบว่าผลการทำนายแนวโน้มหุ้นบริษัท Meta Platforms Inc หลังใช้แบบจำลอง VE เปรียบเทียบผลการทำนายก่อนใช้ VE กับค่า F1-Score แบบจำลอง DT มีค่า F1-Score เพิ่มขึ้นจากแบบจำลอง DT สูงสุดมีค่า F1-Score 6.88% ต่ำสุดมีค่า F1-Score -4.00% และมีค่า F1-Score เพิ่มขึ้นเฉลี่ยประมาณ 2.54% และผลการทำนายหลังใช้แบบจำลอง VE เปรียบเทียบผลการทำนายก่อนใช้แบบจำลอง VE กับค่า F1-Score แบบจำลอง ANN มีค่า F1-Score เพิ่มขึ้นจากแบบจำลอง ANN สูงสุดมีค่า F1-Score 3.00% ต่ำสุดมีค่า F1-Score -2.92% และมีค่า F1-Score เพิ่มขึ้นเฉลี่ยประมาณ 0.21%



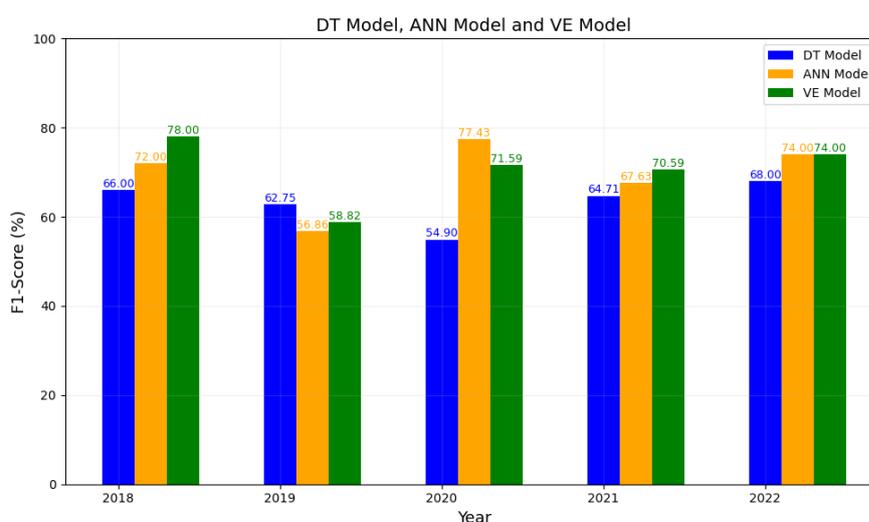
ภาพที่ 4.6 ร้อยละของความแม่นยำ ก่อนและหลังใช้แบบจำลองโหวต กับราคาหุ้นบริษัท Meta Platforms Inc

จากภาพที่ 4.6 เป็นกราฟแท่งแสดงข้อมูลประสิทธิภาพความแม่นยำในการคาดการณ์แนวโน้มหุ้น ก่อนและหลังใช้แบบจำลอง VE ด้วยข้อมูลราคาหุ้นบริษัท Meta Platforms Inc ตั้งแต่ปี 2018 จนถึงปี 2022 เป็นเวลา 5 ปี โดยค่าความแม่นยำแบบ F1-Score ในแกน Y และนับเวลาเป็น Year ในแกน X โดยที่ในแท่งกราฟสีน้ำเงิน คือค่า F1-Score ของ DT Model หรือแบบจำลองต้นไม้ตัดสินใจ แท่งกราฟสีส้ม คือค่า F1-Score ของ ANN Model หรือแบบจำลองโครงข่ายประสาทเทียม และแท่งกราฟสีน้ำเขียว คือค่า F1-Score ของ VE Model หรือแบบจำลอง VE ซึ่งหลังใช้แบบจำลองโหวตมีค่า F1-Score เพิ่มขึ้นมากกว่าก่อนใช้แบบจำลอง VE จำนวน 2 ปี คือปี 2019 และปี 2018

ตารางที่ 4.25 ร้อยละของประสิทธิภาพความแม่นยำในการคาดการณ์แนวโน้มหุ้น กับชุดข้อมูลราคาหุ้นบริษัท Tesla ก่อนและหลังใช้แบบจำลองโหวต

ปี	ผลการทำนายก่อนใช้ VE		ผลการทำนายหลังใช้ VE F1-Score (%)	F1-Score เพิ่มขึ้นจาก DT (%)	F1-Score เพิ่มขึ้นจาก ANN (%)
	F1-Score DT (%)	F1-Score ANN (%)			
2022	68.00	74.00	74.00	6.00	-2.00
2021	64.71	67.63	70.59	5.88	2.96
2020	54.90	77.43	71.59	16.69	-5.84
2019	62.75	56.86	58.82	-3.93	1.96
2018	66.00	74.00	78.00	12.00	4.00

จากตารางที่ 4.25 พบว่าผลการทำนายแนวโน้มหุ้นบริษัท Tesla หลังใช้แบบจำลอง VE เปรียบเทียบผลการทำนายก่อนใช้แบบจำลอง VE กับค่า F1-Score แบบจำลอง DT มีค่า F1-Score เพิ่มขึ้นจากแบบจำลอง DT สูงสุดมีค่า F1-Score 16.69% ต่ำสุดมีค่า F1-Score -3.93% และมีค่า F1-Score เพิ่มขึ้นเฉลี่ยประมาณ 7.32% และผลการทำนายหลังใช้แบบจำลอง VE เปรียบเทียบผลการทำนายก่อนใช้แบบจำลอง VE กับค่า F1-Score แบบจำลอง ANN มีค่า F1-Score เพิ่มขึ้นจากแบบจำลอง ANN สูงสุดมีค่า F1-Score 4.00% ต่ำสุดมีค่า F1-Score -5.84% และมีค่า F1-Score เพิ่มขึ้นเฉลี่ยประมาณ 0.22%



ภาพที่ 4.7 ร้อยละของความแม่นยำ ก่อนและหลังใช้แบบจำลองโหวต กับราคาหุ้นบริษัท Tesla

จากภาพที่ 4.7 เป็นกราฟแท่งแสดงข้อมูลประสิทธิภาพความแม่นยำในการคาดการณ์แนวโน้มหุ้น ก่อนและหลังใช้แบบจำลอง VE ด้วยข้อมูลราคาหุ้นบริษัท Tesla ตั้งแต่ปี 2018 จนถึงปี 2022 เป็นเวลา 5 ปี โดยค่าความแม่นยำแบบ F1-Score ในแกน Y และนับเวลาเป็น Year ในแกน X โดยที่ในแท่งกราฟสีน้ำเงิน คือค่า F1-Score ของ DT Model หรือแบบจำลองต้นไม้ตัดสินใจ แท่งกราฟสีส้ม คือค่า F1-Score ของ ANN Model หรือแบบจำลองโครงข่ายประสาทเทียม และแท่งกราฟสีน้ำเขียว คือค่า F1-Score ของ VE Model หรือแบบจำลอง VE ซึ่งหลังใช้แบบจำลอง VE มีค่า F1-Score เพิ่มขึ้นมากกว่าก่อนใช้แบบจำลอง VE จำนวน 2 ปี คือปี 2021 และปี 2018

บทที่ 5

สรุปผลการวิจัย

การศึกษาครั้งนี้ ผู้ศึกษาพบปัญหาการวิเคราะห์หุ้นด้วยตัวชี้วัดที่มีอยู่มากมายนั้น มีความซับซ้อน และยากต่อการเข้าใจสำหรับนักลงทุนที่ไม่เชี่ยวชาญในการลงทุนหุ้น จึงแก้ปัญหาโดยใช้การวิเคราะห์ข้อมูลด้วยเทคนิค Internal Bar Strength ร่วมกับแบบจำลองต้นไม้ตัดสินใจ และแบบจำลองโครงข่ายประสาทเทียม เพื่อสร้างแบบจำลองที่มีประสิทธิภาพแม่นยำในการคาดการณ์แนวโน้มหุ้นได้ โดยทดสอบจากข้อมูลราคาหุ้นบริษัท Apple เป็นเวลาปี 5 ได้ผลความแม่นยำแบบ F1-Score ของแบบจำลองต้นไม้ตัดสินใจมีค่า F1-Score เฉลี่ยประมาณ 59.68% ในขณะที่แบบจำลองโครงข่ายประสาทเทียมมีค่า F1-Score เฉลี่ยประมาณ 65.62% และการคาดการณ์แนวโน้มหุ้นด้วยเทคนิคการรวมแบบจำลองโหวต มีค่า F1-Score เฉลี่ยประมาณ 67.96 % โดยมีค่า F1-Score มากกว่าแบบจำลองต้นไม้ตัดสินใจเฉลี่ยประมาณ 8.28% และมีค่า F1-Score มากกว่าแบบจำลองโครงข่ายประสาทเทียมเฉลี่ยประมาณ 2.34% จึงสรุปได้ว่าการคาดการณ์แนวโน้มหุ้นด้วยเทคนิคการรวมแบบจำลองโหวต ทำให้ประสิทธิภาพความแม่นยำในการคาดการณ์ราคาหุ้นเพิ่มขึ้น

5.1 สรุปผลการทดลอง

1. ผลความแม่นยำก่อนใช้แบบจำลองต้นไม้ตัดสินใจ และแบบจำลองโครงข่ายประสาทเทียม ร่วมกับเทคนิค Internal Bar Strength มีค่าความแม่นยำจากแบบจำลองต้นไม้ตัดสินใจในการคาดการณ์ราคาหุ้นของบริษัท Apple มีค่า F1-Score เฉลี่ยประมาณ 5 ปี 59.68% และแบบจำลองโครงข่ายประสาทเทียมมีค่า F1-Score เฉลี่ยประมาณ 5 ปี 65.62%

2. ผลความแม่นยำหลังใช้แบบจำลองต้นไม้ตัดสินใจ และแบบจำลองโครงข่ายประสาทเทียม ร่วมกับเทคนิค Internal Bar Strength ในการคาดการณ์ราคาหุ้นของบริษัท Apple มีค่า F1-Score เฉลี่ยประมาณ 5 ปี 67.96%

3. ผลความแม่นยำก่อนใช้แบบจำลองต้นไม้ตัดสินใจ และแบบจำลองโครงข่ายประสาทเทียม ร่วมกับเทคนิค Internal Bar Strength เมื่อเปรียบเทียบกับหลังใช้ พบว่ามีค่า F1-Score มากกว่าแบบจำลองต้นไม้ตัดสินใจมีค่า F1-Score เฉลี่ยประมาณ 8.28% และมากกว่าแบบจำลองโครงข่ายประสาทเทียมมีค่า F1-Score เฉลี่ยประมาณ 2.34%

5.2 อภิปรายผลการวิจัย

1. จากผลการวิจัยพบว่าแบบจำลองต้นไม้ตัดสินใจ และแบบจำลองโครงข่ายประสาทเทียม ร่วมกับการวิเคราะห์ข้อมูลด้วยเทคนิค Internal Bar Strength หรือแบบจำลอง VE มีความแม่นยำ แบบ F1-Score มากที่สุด ทั้งนี้อาจเพราะว่าการวิเคราะห์ข้อมูลด้วยเทคนิค Internal Bar Strength มีค่าความแข็งแกร่งของราคา ซึ่งสอดคล้องกับ ผล F1-Score ของแบบจำลอง VE โดยเทคนิค Internal Bar Strength เป็นตัวชี้วัดความแข็งแกร่งของราคา ทำให้ทราบความแข็งแกร่งของราคาในแต่ละวัน ที่ส่งผลต่อการคาดการณ์แนวโน้มของแบบจำลองต้นไม้ตัดสินใจ และแบบจำลองโครงข่ายประสาทเทียมร่วมกับการวิเคราะห์ทางเทคนิค Internal Bar Strength

2. จากผลการวิจัยพบว่าแบบจำลองต้นไม้ตัดสินใจ และแบบจำลองโครงข่ายประสาทเทียม ร่วมกับการวิเคราะห์ข้อมูลด้วยเทคนิค Internal Bar Strength มีค่าความแม่นยำแบบ F1-Score มากที่สุด สอดคล้องกับผล F1-Score ของการวิเคราะห์ข้อมูลด้วยเทคนิค Internal Bar Strength

3. จากผลการวิจัยพบว่าแบบจำลองต้นไม้ตัดสินใจ และแบบจำลองโครงข่ายประสาทเทียม ร่วมกับการวิเคราะห์ข้อมูลด้วยเทคนิค Internal Bar Strength มีค่าความแม่นยำแบบ F1-Score มากที่สุด ทั้งนี้อาจเป็นเพราะว่า การวิเคราะห์ข้อมูลด้วยเทคนิค Internal Bar Strength เป็นตัวชี้วัดความแข็งแกร่งของราคา ทำให้ทราบความแข็งแกร่งของราคาในแต่ละวันที่ส่งผลต่อผลการคาดการณ์แนวโน้มของแบบจำลองต้นไม้ตัดสินใจ และแบบจำลองโครงข่ายประสาทเทียม ร่วมกับการวิเคราะห์ข้อมูลด้วยเทคนิค Internal Bar Strength

5.3 ข้อเสนอแนะการวิจัย

5.3.1 ข้อเสนอแนะในการนำผลการวิจัยไปใช้

การใช้เครื่องมือในการทำนายหุ้นของการวิจัยเล่มนี้ จำเป็นต้องการมีโปรแกรมสำหรับรันโค้ดภาษา Python

5.3.2 ข้อเสนอแนะในการทำวิจัยครั้งต่อไป

1. พัฒนาแบบจำลองการคาดการณ์แนวโน้มหุ้นให้เป็นแอปพลิเคชัน เพื่อให้สามารถใช้งานได้สะดวกมากขึ้น
2. พัฒนาปรับปรุง เทคนิค วิธีการ และแนวคิดสำหรับเพิ่มประสิทธิภาพของแบบจำลองการนำนายแนวโน้มหุ้น เช่น เพิ่มการวิเคราะห์ปัจจัยทางเทคนิค และการวิเคราะห์ปัจจัยพื้นฐานให้เหมาะสมกับแบบจำลอง

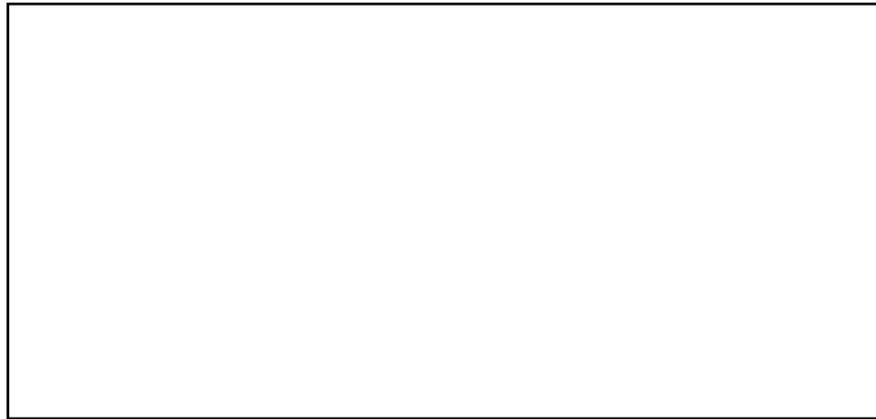
บรรณานุกรม

- [1] The Stock Exchange of Thailand. (2558). หุ้นคืออะไร. [ออนไลน์]. ได้จาก:
https://member.set.or.th/education/th/begin/stock_content01.pdf/
 [สืบค้นเมื่อ วันที่ 5 ตุลาคม 2566].
- [2] Koi Nopnok. (2665). Candlestick คืออะไร. [ออนไลน์]. ได้จาก:
<https://www.vlearn.world/knowledge/view/400/Financial-investment/>
 [สืบค้นเมื่อ วันที่ 5 ตุลาคม 2566].
- [3] Pasith Thanapatpisarn. (2665). Decision Tree โมเดลต้นไม้. [ออนไลน์]. ได้จาก:
<https://datascihaeng.medium.com/decision-tree-part01-47ef24539fba/>
 [สืบค้นเมื่อ วันที่ 5 ตุลาคม 2566].
- [4] Chaiyaphop Jamjumrat. (2665). รู้จักกับ Decision Tree มันคือต้นไม้อะไร ทำงานอย่างไร. [ออนไลน์]. ได้จาก:
<https://www.borntodev.com/2022/09/15/รู้จักกับ-decision-tree/>
 [สืบค้นเมื่อ วันที่ 5 ตุลาคม 2566].
- [5] วิกิพีเดีย สารานุกรมเสรี. (2566). โครงข่ายประสาทเทียม. [ออนไลน์]. ได้จาก:
<https://th.wikipedia.org/wiki/โครงข่ายประสาทเทียม/>
 [สืบค้นเมื่อ วันที่ 5 ตุลาคม 2566].
- [6] Phyblas. (2665). โครงข่ายประสาทเทียมเบื้องต้น. [ออนไลน์]. ได้จาก:
<https://phyblas.hinaboshi.com/umaki01/> [สืบค้นเมื่อ วันที่ 5 ตุลาคม 2566].
- [7] ชลรวี หาญล้ำวง. (2662). การคาดการณ์ดัชนีราคาหุ้นตลาดหลักทรัพย์แห่งประเทศไทย โดยใช้มะชินเลิร์นนิ่งเทคนิค(วิทยานิพนธ์ปริญญาโทบริหารธุรกิจ). นครปฐม. มหาวิทยาลัยมหิดล. สืบค้นจาก <https://archive.cm.mahidol.ac.th/bitstream/>
- [8] วิศรุต แก้วมหา. (2664). การคาดการณ์ผลตอบแทนในอนาคตของตราสารทุนสามัญ โดยการใ้แบบจำลองโครงข่ายประสาทเทียม และแบบจำลอง Random Forest (วิทยานิพนธ์ปริญญาโทบริหารธุรกิจ). นครปฐม. มหาวิทยาลัยมหิดล. สืบค้นจาก <https://archive.cm.mahidol.ac.th/bitstream/>

ภาคผนวก

ภาคผนวก ก

โค้ดการสร้างแบบจำลองโหนด



ภาพที่ ก.1 โค้ดการสร้างแบบจำลองโหนด

จากภาพที่ ก.1 เป็นโค้ดสำหรับการสร้างแบบจำลองโหนด โดยประกอบไปด้วย โค้ดการสร้างแบบจำลองต้นไม้ตัดสินใจ การสร้างแบบจำลองโครงข่ายประสาทเทียม และการสร้างการรวมแบบจำลองโหนด บันทึกโค้ดภาษา Python อยู่ในรูปแบบของ SD การ์ด เป็นจำนวน 1 โฟลเดอร์ ชื่อ VE Model

ประวัติผู้วิจัย

ชื่อ-นามสกุล	นางสาวศรียอง สุภา	
วัน เดือน ปี เกิด	07 ตุลาคม 2541	
ที่อยู่ปัจจุบัน	บ้านเลขที่ 531 หมู่ 5 ตำบล เวียงพางคำ อำเภอ แม่สาย จังหวัด เชียงราย รหัสไปรษณีย์ 57130	
เบอร์	097-0566-918	
ประวัติการศึกษา	พ.ศ. 2561	มัธยมศึกษาปีที่ 6 โรงเรียนแม่สายประสิทธิ์ศาสตร์
	พ.ศ. 2555	ประถมศึกษาปีที่ 6 โรงเรียนเทศบาล 1 (วัดพรหมวิหาร)