



ความสามารถในการพยากรณ์ของคุณลักษณะผลต่างแบบเศษส่วน

โดยใช้แบบจำลองซัพพอร์ตเวกเตอร์แมชชีน

The Predictability of Fractional Difference Feature using Support Vector Machines

ศิวิวัฒน์ ไทยรุ่งโรจน์¹ และชอุตพณ อู่อัสดี²

¹ สาขาวิศวกรรมการเงิน คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยหอการค้าไทย, dthairr@gmail.com

² สาขาการเงิน คณะบริหารธุรกิจ มหาวิทยาลัยหอการค้าไทย, tousawat@riped.org

บทคัดย่อ

การศึกษานี้มีวัตถุประสงค์เพื่อศึกษาความสามารถในการพยากรณ์ของคุณลักษณะผลต่างแบบเศษส่วน (Fractional Difference Feature) โดยใช้แบบจำลองซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machines) โดยใช้ข้อมูลราคาปิดรายวันดัชนีตลาดหลักทรัพย์แห่งประเทศไทยตั้งแต่วันที่ 1 มกราคม 2551 ถึง 31 ธันวาคม 2562 นำมาคำนวณเป็นอัตราผลตอบแทนรายวันและผลต่างแบบเศษส่วนเพื่อนำมาใช้เป็นคุณลักษณะ โดยตัวแบบจำลองนั้นจะใช้ในการพยากรณ์แนวโน้มล่วงหน้า 1, 5, 20, 60 วัน โดยผลการทดสอบความนิ่งของข้อมูล (Unit Root test) พบว่าอัตราผลตอบแทนรายวันมีความนิ่งและผลต่างแบบเศษส่วนมีความนิ่งที่ลำดับการทำผลต่างเท่ากับ 0.60

ผลการทดลองแสดงให้เห็นว่าค่าความแม่นยำเฉลี่ยจากการทำ 5-fold Cross-Validation ของอัตราผลตอบแทนรายวันมีค่าที่สูงกว่าผลต่างแบบเศษส่วนสำหรับการพยากรณ์แนวโน้มล่วงหน้า 1 วัน ซึ่งให้ค่าความแม่นยำที่ 53.21 เปอร์เซ็นต์ ส่วนผลต่างแบบเศษส่วนมีความแม่นยำในการพยากรณ์แนวโน้มล่วงหน้า 5, 20, 60 วันที่สูงกว่าโดยให้ความแม่นยำเฉลี่ยที่ 53.14 57.01 60.92 เปอร์เซ็นต์ตามลำดับ ผลการศึกษาแสดงให้เห็นว่าผลต่างแบบเศษส่วนนั้นสามารถเพิ่มความสามารถในการพยากรณ์ระยะยาวของแบบจำลองซัพพอร์ตเวกเตอร์แมชชีน

คำสำคัญ: ซัพพอร์ตเวกเตอร์แมชชีน, การเรียนรู้ของเครื่อง, ผลต่างแบบเศษส่วน

ABSTRACT

The objective of this study is to investigate the predictability of the fractional difference feature using support vector machines. Our sample is the close price of the Stock Exchange Thailand Index (SET Index) from 1 January 2008 to 31 December 2019. We calculate daily return and fractional difference of SET Index and use them as features. The model will use to predict the trend of SET Index for 1, 5, 20, 60 days. The results of unit root test shows that daily return is stationary and fractional difference stationary at $d = 0.60$

The experimental results show that average accuracy from 5-fold Cross-Validation of daily return is higher than fractional difference feature for 1-day trend prediction which gives average accuracy equal to 53.21%. Fractional difference feature has higher accuracy in trend prediction for 5, 20, 60 days which gives an average



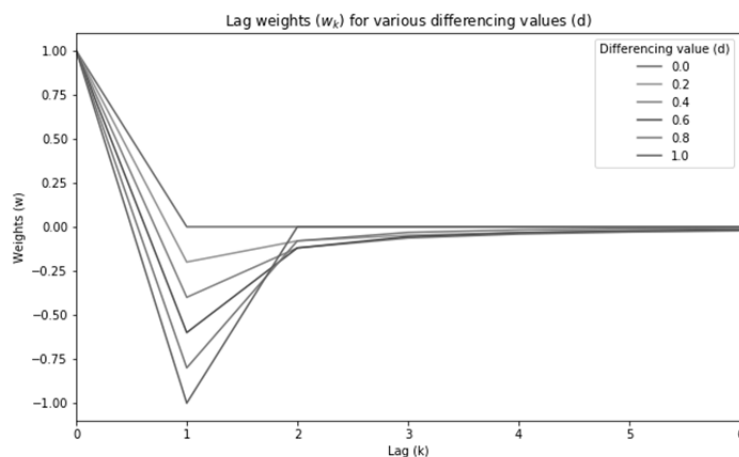
accuracy equal to 53.14% 57.01% 60.92% in order. The results demonstrate that fractional difference can improve the predictability of support vector machines for long-term prediction.

Keywords: Support Vector Machines, Machine Learning, Fractional Differencing

1. บทนำ

การวิเคราะห์อนุกรมเวลานั้นมักจะทำการศึกษานข้อมูลอนุกรมเวลาที่มีความนิ่ง (Stationary) และในกรณีที่ข้อมูลไม่มีความนิ่ง (Non-Stationary) ก่อนจะทำการศึกษาข้อมูลอนุกรมเวลานั้นจำเป็นต้องทำผลต่างเพื่อให้ข้อมูลอนุกรมเวลานั้นมีความนิ่งเสียก่อน โดยการวิเคราะห์อนุกรมเวลาโดยทั่วไปแล้วจะใช้แบบจำลองทางอนุกรมเวลา เช่น Auto Regressive Integrated Moving Average, Generalized Auto Regressive Conditional Heteroskedasticity (ภูมิฐาน รังคกุลนุวัฒน์, 2562) ซึ่งในปัจจุบันนั้นได้มีการประยุกต์ใช้การเรียนรู้ของเครื่องในการทำการวิเคราะห์ข้อมูลอนุกรมเวลาทางการเงิน เช่น การใช้แบบจำลองซัพพอร์ตเวกเตอร์แมชชีนในการพยากรณ์ทิศทางราคาหุ้น (Huang, 2005), (Rungruang, 2019) โดยผลการศึกษานั้นแสดงให้เห็นว่าแบบจำลองการเรียนรู้ของเครื่องนั้นสามารถที่นำมาใช้พยากรณ์ข้อมูลอนุกรมเวลาทางการเงินได้อย่างมีประสิทธิภาพ โดยในงานวิจัยที่ได้กล่าวไปนั้นได้ใช้การทำผลต่างเพื่อให้ข้อมูลอนุกรมเวลานั้นมีความนิ่งก่อนนำไปวิเคราะห์หรือพยากรณ์ ซึ่งการทำผลต่างนั้นจะใช้ข้อมูลในปัจจุบันและข้อมูลที่ห่างไป 1 ช่วงเวลาเท่านั้น (ในกรณีลำดับการทำผลต่างเท่ากับ 1) ซึ่งการทำผลต่างแบบนี้คือการทำผลต่างแบบจำนวนเต็ม (Integer Differentiation) โดยตัวอย่างของการทำผลต่างแบบจำนวนเต็ม ได้แก่ การหาผลต่าง, การหาอัตราการเปลี่ยนแปลง เป็นต้น ซึ่งการทำผลต่างแบบจำนวนเต็มนี้จะกำหนดให้ลำดับในการทำผลต่าง (d) เป็นจำนวนเต็มเท่านั้น ส่งผลทำให้ข้อมูลในอดีตที่ห่างไปมากกว่า 1 ช่วงเวลานั้นไม่ได้ถูกนำมาใช้ในการคำนวณผลต่าง ทำให้ความจำของข้อมูลหายไป (Prado, 2018) สามารถแสดงได้ดังรูปที่ 1

รูปที่ 1: แสดงน้ำหนักการคำนวณผลต่างในแต่ละลำดับการทำผลต่าง



ที่มา: Advance in Financial Machine Learning (Prado, 2018)

จากรูปแสดงให้เห็นว่าข้อมูลที่ห่างไปตั้งแต่ช่วงเวลาที่ 2 เป็นต้นไปนั้นไม่ได้ถูกนำมาคำนวณในการทำผลต่างจึงทำให้ความจำระยะยาวของข้อมูลอนุกรมเวลานั้นหายไป โดยจากการงานวิจัยพบว่าความจำระยะยาวของข้อมูลอนุกรมเวลานั้นส่งผลทำให้การพยากรณ์อนุกรมเวลานั้นมีความแม่นยำมากขึ้น (Bo Qian, 2004) ดังนั้นแล้วการที่ความจำ



ระยะเวลาของข้อมูลอนุกรมเวลาหายไปนั้นส่งผลทำให้ความสามารถในการพยากรณ์ของแบบจำลองการเรียนรู้ของเครื่องลดลง ได้เสนอให้ทำการแปลงข้อมูลที่ไม่มีความนิ่งให้มีความนิ่งโดยการทำผลต่างแบบเศษส่วน (Prado, 2018) ซึ่งสามารถกำหนดค่าให้ลำดับในการทำผลต่างเป็นจำนวนที่เป็นเศษส่วนได้โดยนำผลต่างแบบเศษส่วนนั้นมาใช้เป็นคุณลักษณะ (Feature) ของแบบจำลองการเรียนรู้ของเครื่อง ซึ่งแนวคิดการทำผลต่างแบบเศษส่วนนั้นได้มีการศึกษาและนำมาประยุกต์ในแบบจำลองการวิเคราะห์ข้อมูลอนุกรมเวลา เช่น งานวิจัยของ (Granger, 1980), (Hosking, 1985) และ (Karia, 2013) ซึ่งพบว่าการใช้การทำผลต่างแบบเศษส่วนช่วยทำให้แบบจำลองวิเคราะห์ข้อมูลอนุกรมเวลาสามารถวิเคราะห์ข้อมูลในระยะยาวได้อย่างมีประสิทธิภาพมากขึ้น โดยจากรูปที่ 1 แสดงให้เห็นว่าการกำหนดลำดับการทำผลต่างเป็นเศษส่วนนั้นจะนำข้อมูลที่หน่วงออกไปตั้งแต่ช่วงเวลา 2 มาคำนวณค่าผลต่างด้วยทำให้ข้อมูลผลต่างแบบเศษส่วนมีความจำของข้อมูลที่ยาวกว่าการทำผลต่างแบบจำนวนเต็มที่ใช้

2. วัตถุประสงค์การวิจัย

1. เพื่อเปรียบเทียบความสามารถในการพยากรณ์ของอัตราผลตอบแทนรายวันกับผลต่างแบบเศษส่วน
2. เพื่อศึกษาความสามารถในการพยากรณ์ของคุณลักษณะผลต่างแบบเศษส่วน
3. เพื่อศึกษาการเลือกใช้คุณลักษณะให้มีความเหมาะสมต่อการพยากรณ์อนุกรมเวลาโดยใช้การเรียนรู้ของเครื่อง

3. การดำเนินการวิจัย

3.1 ข้อมูลที่ใช้ในการศึกษา

ผู้ศึกษาเลือกใช้ข้อมูลดัชนีภูมิภาคโดยรวบรวมข้อมูลอนุกรมเวลาราคาปิดรายวันดัชนีของตลาดหลักทรัพย์แห่งประเทศไทย ตั้งแต่วันที่ 1 มกราคม พ.ศ.2551 ถึงวันที่ 31 ธันวาคม พ.ศ.2562 โดยมีความถี่ของข้อมูลเป็นข้อมูลรายวันรวบรวมข้อมูลจากเว็บไซต์ Investing

3.2 ขั้นตอนการศึกษา

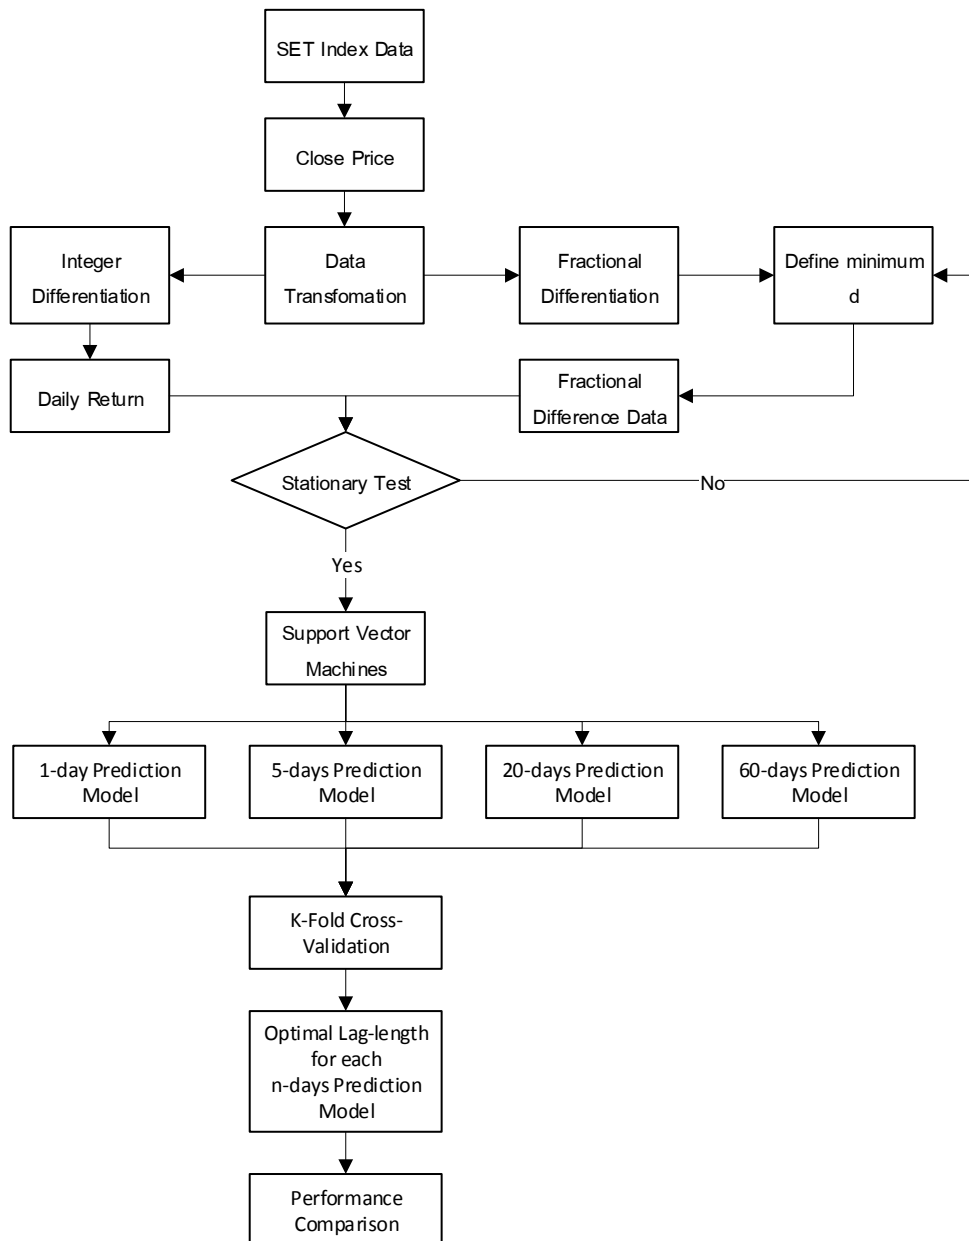
ในการศึกษาความสามารถในการพยากรณ์ของคุณลักษณะผลต่างแบบเศษส่วนในครั้งนี้ โดยใช้ข้อมูลดัชนีราคาหลักทรัพย์แห่งประเทศไทยในการศึกษา และใช้โปรแกรม Python ในการคำนวณ โดยมีขั้นตอนในการศึกษาโดยสังเขปดังต่อไปนี้

- 1.) รวบรวมข้อมูลราคาปิดของดัชนีราคาหลักทรัพย์แห่งประเทศไทย
- 2.) แปลงข้อมูลราคาปิดดัชนีตลาดหลักทรัพย์แห่งประเทศไทยให้เป็นอัตราผลตอบแทนรายวันและผลต่างแบบเศษส่วน
- 3.) ทดสอบความนิ่งของอัตราผลตอบแทนรายวันและผลต่างแบบเศษส่วนด้วย Augmented Dickey Fuller Test
- 4.) กำหนดแบบจำลอง Support Vector Machines และใช้อัตราผลตอบแทนรายวันและผลต่างแบบเศษส่วนที่มีความนิ่งเป็นคุณลักษณะ เพื่อใช้ในการพยากรณ์แนวโน้มใน 1, 5, 20, 60 วันข้างหน้า



- 5.) ประเมินแบบจำลองด้วย K-Fold Validation โดยกำหนดค่า K เท่ากับ 5 เพื่อหาค่าความหน่วงที่เหมาะสมสำหรับการพยากรณ์ และหาค่าความแม่นยำของแบบจำลองเพื่อนำมาใช้ในการสรุปผลการศึกษา
- 6.) เปรียบเทียบแบบจำลองที่เหมาะสมของแต่ละคุณลักษณะ โดยใช้ค่าความแม่นยำเฉลี่ยที่ได้จากการทำ K-Fold Validation เพื่อสรุปผลการศึกษา

รูปที่ 2: ขั้นตอนการศึกษา





3.3 วิธีการเตรียมข้อมูล

ในการศึกษาค้างนี้จะใช้อัตราผลตอบแทนรายวันของดัชนีหลักทรัพย์แห่งประเทศไทย และผลต่างแบบเศษส่วน เพื่อใช้เป็นคุณลักษณะของแบบจำลองการเรียนรู้ของเครื่อง โดยมีรายละเอียดการคำนวณอัตราผลตอบแทนรายวันและการทำผลต่างแบบเศษส่วนดังนี้

1). อัตราผลตอบแทนรายวัน

ในการศึกษาค้างนี้จะคำนวณอัตราผลตอบแทนรายวันในรูปของลอการิทึม (Logarithmic Return) ซึ่งเป็นการนำข้อมูลราคาปิดรายวันดัชนีตลาดหลักทรัพย์แห่งประเทศไทย ณ เวลาที่ t หากการเปลี่ยนแปลงในรูปของลอการิทึมเทียบกับข้อมูลราคาปิดรายวันดัชนีตลาดหลักทรัพย์แห่งประเทศไทย ณ เวลาที่ $t-1$ โดยสามารถเขียนได้ตามสมการที่ 3.3.1

$$r_t = \ln \left(\frac{X_t}{X_{t-1}} \right) \quad (3.3.1)$$

โดยที่ r_t คือ อัตราผลตอบแทนรายวัน
 X_t คือ ราคาปิดรายวันดัชนีตลาดหลักทรัพย์แห่งประเทศไทย
 X_{t-1} คือ ราคาปิดรายวันดัชนีตลาดหลักทรัพย์แห่งประเทศไทยที่หน่วงไป 1 ช่วงเวลา

2). ผลต่างแบบเศษส่วน

ในการศึกษาค้างนี้ผู้ศึกษาได้เลือกใช้วิธีการทำผลต่างแบบเศษส่วนด้วยวิธี Fixed Width Window Fractional Differentiation (Prado, 2018) คือการคำนวณผลต่างแบบเศษส่วนโดยมีการกำหนดค่าน้ำหนักน้อยสุดค่านึง (ω_k) เพื่อใช้พิจารณาว่าจะใช้ข้อมูลในอดีตที่หน่วงไปทั้งหมดกี่ช่วงเวลาในการคำนวณผลต่างแบบเศษส่วน โดยค่าผลต่างแบบเศษส่วน ณ เวลาที่ t ใดๆนั้นจะสามารถคำนวณได้จากการนำค่าน้ำหนักในแต่ละช่วงเวลาคู่กับข้อมูลราคาปิด ณ ช่วงเวลานั้นๆและนำผลคูณแต่ละช่วงเวลามาหาผลบวกตั้งตั้งแต่ช่วงเวลาที่ t ถึงช่วงเวลาที่ $t - 1^*$ โดยสามารถเขียนสมการการคำนวณผลต่างแบบเศษส่วน การคำนวณค่าน้ำหนักในแต่ละช่วงเวลา และการกำหนดค่าน้ำหนักน้อยสุดได้ตามสมการที่ 3.3.2, 3.3.3 และ 3.3.4

$$\tilde{X}_t = \sum_{k=0}^{l^*} \omega_k X_{t-k} \quad (3.3.2)$$

$$\omega_k = -\omega_{k-1} \frac{d-k+1}{k} \quad (3.3.3)$$

$$\omega_k = \begin{cases} \omega_k & ; k \leq l^* \\ 0 & ; k > l^* \end{cases} \quad (3.3.4)$$

โดยที่ \tilde{X}_t คือ ค่าผลต่างแบบเศษส่วน
 X_t คือ ราคาปิดรายวันดัชนีตลาดหลักทรัพย์แห่งประเทศไทย
 ω_k คือ ค่าน้ำหนักในการคำนวณผลต่างแบบเศษส่วน
 d คือ ลำดับการทำผลต่างแบบเศษส่วน



- k คือ ค่าความหน่วงของช่วงเวลา
 I^* คือ ค่าความหน่วงของเวลาที่ค่าน้ำหนักในการคำนวณผลต่างแบบ
 เศษส่วนมีค่ามากกว่า 0.001

3.4 การทดสอบความนิ่งของข้อมูล

ในการทำผลต่างแบบเศษส่วนนั้นเพื่อให้สามารถระบุได้ว่าจะใช้ลำดับผลต่างเท่ากับเท่าไหรั้น ผู้ศึกษาจะใช้ Augmented Dickey Fuller Test ซึ่งเป็นวิธีการทดสอบความนิ่งของข้อมูลอนุกรมเวลาที่พัฒนามาจาก Dickey Fuller Test โดยเลือกค่าความหน่วงในการทดสอบโดยการใช้เกณฑ์ค่า Akaike Information Criterion น้อยที่สุดเพื่อทดสอบความนิ่งของข้อมูลและเลือกใช้ลำดับการทำผลต่างที่(d) น้อยที่สุดสำหรับการทำผลต่างแบบเศษส่วนที่ทำให้ผลการทดสอบ Augmented Dickey Fuller Test มีนัยสำคัญทางสถิติที่ระดับนัยสำคัญเท่ากับ 95% (Prado, 2018) โดยสามารถเขียนสมการทดสอบความนิ่งของข้อมูลด้วย Augmented Dickey Fuller ซึ่งมี 3 กรณี (ภูมิฐาน รังคกุลนุวัฒน์, 2556) ได้ดังนี้

- 1). กรณีข้อมูลไม่มีแนวโน้มและจุดตัดแกน

$$\Delta X_t = \gamma X_{t-1} + \sum_{i=1}^{p-1} c_i \Delta X_{t-i} + \varepsilon_i \quad (3.4.1)$$

- โดยที่ X_t, X_{t-1} คือ ค่าอนุกรมเวลา ณ เวลาที่ t และ t-1
 ΔX_t คือ ผลต่างลำดับที่ 1 ของอนุกรมเวลา ณ เวลาที่ t
 γ คือ ค่าสัมประสิทธิ์ของตัวแปร X_{t-1}
 c_i คือ ค่าสัมประสิทธิ์ของตัวแปร ΔX_{t-i}
 ε_i คือ ค่าตัวแปรสุ่มคลาดเคลื่อน

- 2). กรณีข้อมูลมีจุดตัดแกน

$$\Delta X_t = \beta_0 + \gamma X_{t-1} + \sum_{i=1}^{p-1} c_i \Delta X_{t-i} + \varepsilon_i \quad (3.4.2)$$

- โดยที่ X_t, X_{t-1} คือ ค่าอนุกรมเวลา ณ เวลาที่ t และ t-1
 ΔX_t คือ ผลต่างลำดับที่ 1 ของอนุกรมเวลา ณ เวลาที่ t
 β_0 คือ ค่าคงที่
 γ คือ ค่าสัมประสิทธิ์ของตัวแปร X_{t-1}
 c_i คือ ค่าสัมประสิทธิ์ของตัวแปร ΔX_{t-i}
 ε_i คือ ค่าตัวแปรสุ่มคลาดเคลื่อน

- 3). กรณีข้อมูลมีแนวโน้มและจุดตัดแกน

$$\Delta X_t = \beta_0 + \beta_1 t + \gamma X_{t-1} + \sum_{i=1}^{p-1} c_i \Delta X_{t-i} + \varepsilon_i \quad (3.4.3)$$



โดยที่	X_t, X_{t-1}	คือ ค่าอนุกรมเวลา ณ เวลาที่ t และ $t-1$
	ΔX_t	คือ ผลต่างลำดับที่ 1 ของอนุกรมเวลา ณ เวลาที่ t
	β_0	คือ ค่าคงที่
	β_1	คือ ค่าสัมประสิทธิ์ของแนวโน้มตามเวลา
	γ	คือ ค่าสัมประสิทธิ์ของตัวแปร X_{t-1}
	c_i	คือ ค่าสัมประสิทธิ์ของตัวแปร ΔX_{t-1}
	ε_i	คือ ค่าตัวแปรสุ่มคลาดเคลื่อน

ในการทดสอบความนิ่งของข้อมูลนั้นจะใช้สมการ 3.4.1, 3.4.2 และ 3.4.3 ในการวิเคราะห์สมการถดถอยตามลักษณะของข้อมูลอนุกรมเวลาว่ามีจุดตัดแกนหรือมีแนวโน้มตามเวลาหรือไม่ โดยในการที่จะทดสอบความนิ่งของข้อมูลอนุกรมเวลานั้นสามารถทำการทดสอบได้โดยการทดสอบสมมติฐานค่าสัมประสิทธิ์ γ ซึ่งสามารถตั้งสมมติฐานในการทดสอบความนิ่งของข้อมูลได้ตามสมการที่ 3.4.4 ถ้าหากการทดสอบสมมติฐานนั้นไม่ปฏิเสธสมมติฐานหลักหรือก็คือค่า γ เท่ากับ 0 จะสรุปการทดสอบว่าข้อมูลอนุกรมเวลานั้นไม่มีความนิ่ง และจะสรุปว่าข้อมูลอนุกรมเวลาที่มีความนิ่งเมื่อการทดสอบสมมติฐานนั้นปฏิเสธสมมติฐานหลักหรือก็คือค่า γ มีค่าน้อยกว่า 1 โดยในการศึกษาค้นคว้าครั้งนี้ผู้ศึกษาจะใช้สมการที่ 3.4.1 ในการทดสอบความนิ่งของอัตราผลตอบแทนรายวัน ใช้สมการที่ 3.4.2 ในการทดสอบความนิ่งของผลต่างแบบเศษส่วน และสมการที่ 3.4.3 ในการทดสอบความนิ่งของราคาปิดรายวันดัชนีตลาดหลักทรัพย์แห่งประเทศไทย

$$\begin{aligned} H_0 : \gamma &= 0 \\ H_1 : \gamma &< 0 \end{aligned} \quad (3.4.4)$$

3.5 แบบจำลองซัพพอร์ตเวกเตอร์แมชชีน

(ปริญา สวงวนสัจย์, 2562) แบบจำลองซัพพอร์ตเวกเตอร์แมชชีน เป็นแบบจำลองการเรียนรู้ของเครื่องแบบมีผู้สอนที่ใช้ในการแบ่งข้อมูลออกเป็นประเภทต่างๆตามที่ได้กำหนดเอาไว้ ซึ่งตัวแบบจำลองนั้นมีหลักการทำงานคือสร้างตัวจำแนกประเภท (Classifier) โดยตัวจำแนกประเภทของแบบจำลองซัพพอร์ตเวกเตอร์แมชชีน นั้นจะมีลักษณะเป็นระนาบเกิน (Hyperplane) ซึ่งในการหาระนาบเกินอาจจะมีปัญหา Overfitting ได้ดังนั้นแล้วเพื่อที่จะเลือกระนาบเกินที่มีความเหมาะสม (Optimal Hyperplane) จะใช้ระยะขอบที่มากที่สุด (Maximized Margin) ที่มากที่สุดเป็นเกณฑ์ในการเลือกระนาบเกินที่มีความเหมาะสม โดยปัญหาการหาระนาบเกินที่มีความเหมาะสมนั้นจะสามารถเขียนให้อยู่ในรูปปัญหาหาค่าสูงสุดได้ตามสมการที่ 3.5.1 ดังนี้

$$\begin{aligned} \max \quad & \gamma = \frac{2}{\|\mathbf{w}\|} \\ \text{subject to} \quad & y_i(\mathbf{w}^T \mathbf{x}_i + b) \geq 1 \end{aligned} \quad (3.5.1)$$

โดยที่	γ	คือ ระยะขอบ
	\mathbf{w}	คือ เวกเตอร์ปกติที่ตั้งฉากกับระนาบเกิน



x_i คือ เวกเตอร์คุณลักษณะ

y_i คือ ประเภทของข้อมูล

ซึ่งปัญหาการหาค่าสูงสุดของระยะขอบข้างต้นนั้นสามารถเขียนให้อยู่ในรูปของปัญหาการหาค่าต่ำสุดได้ตามสมการที่ 3.5.2 ได้ดังนี้

$$\begin{aligned} \min \quad & \gamma = \frac{1}{2} \mathbf{w}^T \mathbf{w} \\ \text{subject to} \quad & y_i (\mathbf{w}^T \mathbf{x}_i + b) \geq 1 \end{aligned} \quad (3.5.2)$$

ถ้าหากพบเจอปัญหาความไม่สมดุลของคลาสของข้อมูลที่นำมาใช้ในการสร้างแบบจำลองการเรียนรู้ของเครื่อง ซึ่งจะส่งผลทำให้ตัวจำแนกประเภทที่ได้นั้นไม่มีความสามารถในการแยกแยะคลาสของข้อมูลได้อย่างมีประสิทธิภาพ ดังนั้นเพื่อแก้ไขปัญหาดังกล่าวจึงได้มีการปรับแบบจำลองซัพพอร์ตเวกเตอร์แมชชีน (Lin, 2011) โดยให้ค่าพารามิเตอร์ C หรือค่าน้ำหนักของข้อมูลแต่ละประเภทยิ่งมีค่าไม่เท่ากัน โดยประเภทข้อมูลที่มีจำนวนมากจะมกำหนดให้มีค่า C ที่น้อยกว่าค่า C ของประเภทข้อมูลที่มีจำนวนน้อยเพื่อเป็นการทำให้ข้อมูลทั้งสองประเภทยิ่งมีความสมดุลกัน โดยแบบจำลองซัพพอร์ตเวกเตอร์แมชชีน นั้นจะถูกเขียนใหม่ให้อยู่รูปปัญหาการหาค่าต่ำสุดได้ตามสมการที่ 3.5.3 ดังนี้

$$\begin{aligned} \min \quad & \gamma = \frac{1}{2} \mathbf{w}^T \mathbf{w} + C^+ \sum_{y_i=1} \xi_i + C^- \sum_{y_i=-1} \xi_i \\ \text{subject to} \quad & y_i (\mathbf{w}^T \mathbf{x}_i + b) \geq 1 - \xi_i, \\ & \xi_i \geq 0, i = 1, \dots, l \end{aligned} \quad (3.5.3)$$

โดยที่	γ	คือ ระยะขอบ
	\mathbf{w}	คือ เวกเตอร์ปกติที่ตั้งฉากกับระนาบเกิน
	x_i	คือ เวกเตอร์คุณลักษณะ
	y_i	คือ ประเภทของข้อมูล
	C	คือ ค่าน้ำหนักของข้อมูลแต่ละประเภท
	ξ_i	คือ ตัวแปร Slack สำหรับวัดความผิดพลาดของการแบ่งประเภทของข้อมูล

การใช้แบบจำลองซัพพอร์ตเวกเตอร์แมชชีนในกรณีที่ปัญหาการจำแนกข้อมูลนั้นไม่ได้อยู่ในรูปของเส้นตรงซึ่งส่งผลทำให้ไม่สามารถจำแนกข้อมูลได้อย่างมีประสิทธิภาพ ดังนั้นจึงต้องทำการแปลงปัญหาไม่เชิงเส้นให้เป็นปัญหาเชิงเส้นเสียก่อนด้วยการใช้กลวิธีเคอร์เนล (Kernel Trick) เพื่อทำการส่งข้อมูลที่อยู่ในปริภูมิไม่เชิงเส้นไปเป็นปริภูมิเชิงเส้น โดยในการศึกษาครั้งนี้ผู้ศึกษาเลือกใช้ฟังก์ชันเคอร์เนลเป็น Radial Basis Function โดยสามารถเขียนเป็นสมการได้ดังสมการที่ 3.5.4

$$K(\mathbf{x}_i, \mathbf{y}_j) = e^{-\gamma \|\mathbf{x}_i - \mathbf{y}_j\|^2}; \gamma > 0 \quad (3.5.4)$$



3.6 การกำหนดแบบจำลองซัพพอร์ตเวกเตอร์แมชชีน

การสร้างแบบจำลองการเรียนรู้ของเครื่องจำเป็นต้องมีคุณลักษณะหรือตัวแปรที่ใช้ในการแยกประเภทเพื่อบอกคุณลักษณะของข้อมูล เพื่อให้แบบจำลองการเรียนรู้ของเครื่องนั้นสามารถที่จะเรียนรู้ในการจำแนกประเภทของข้อมูลจากคุณลักษณะที่ได้ใช้ในแบบจำลองการเรียนรู้ของเครื่อง

ในการศึกษาครั้งนี้ผู้ศึกษาจะเลือกใช้คุณลักษณะที่นำมาใช้ในการสร้างแบบจำลองซัพพอร์ตเวกเตอร์แมชชีน ดังนี้ 1). อัตราผลตอบแทนรายวัน 2). ข้อมูลผลต่างแบบเศษส่วน โดยจะแบ่งแบบจำลองออกเป็นสองกลุ่มคือ 1). แบบจำลองที่ใช้คุณลักษณะอัตราผลตอบแทนรายวัน 2). แบบจำลองที่ใช้คุณลักษณะผลต่างแบบเศษส่วน เพื่อเปรียบเทียบความสามารถในการพยากรณ์แนวโน้มดัชนีราคาหลักทรัพย์แห่งประเทศไทยโดยใช้คุณลักษณะแต่ละประเภท โดยสามารถเขียนแบบจำลองการเรียนรู้ของเครื่องได้ดังนี้

1). แบบจำลองการเรียนรู้ของเครื่องที่ใช้คุณลักษณะอัตราผลตอบแทนรายวัน

$$D_{t+q} = f(r_t, \dots, r_{t-p}) ; q \in \{1, 5, 20, 60\} , p \in \{0, 1, 2, 3, 4, 5\} \quad (3.6.1)$$

โดยกำหนดฉลากของข้อมูล (Label Data) ที่จะพยากรณ์ด้วยผลต่างของราคาปิดรายวันดัชนีตลาดหลักทรัพย์แห่งประเทศไทย ณ วันที่ t และวันที่ $t+q$ โดยสามารถเขียนเป็นสมการได้ดังนี้

$$D_{t+q} = \begin{cases} 1 & ; X_t \leq X_{t+q} > 0 \\ -1 & ; X_t > X_{t+q} \leq 0 \end{cases} \quad (3.6.2)$$

โดยที่	r_t	คือ อัตราผลตอบแทนรายวัน
	X_t	คือ ราคาปิดรายวันดัชนีตลาดหลักทรัพย์แห่งประเทศไทย ณ เวลาที่ t
	X_{t+q}	คือ ราคาปิดรายวันดัชนีตลาดหลักทรัพย์แห่งประเทศไทย ณ เวลาที่ $t+q$
	p	คือ ค่าความหน่วง
	q	คือ ช่วงเวลาที่พยากรณ์แนวโน้มออกไปข้างหน้า
	D_{t+q}	คือ แนวโน้มของราคาปิดรายวันดัชนีตลาดหลักทรัพย์แห่งประเทศไทยในอีก q วันข้างหน้า

2). แบบจำลองการเรียนรู้ของเครื่องที่ใช้คุณลักษณะผลต่างแบบเศษส่วน

$$D_{t+q} = f(\bar{X}_t, \dots, \bar{X}_{t-p}) ; q \in \{1, 5, 20, 60\} , p \in \{0, 1, 2, 3, 4, 5\} \quad (3.6.3)$$

โดยกำหนดฉลากของข้อมูล (Label Data) ที่จะพยากรณ์ด้วยผลต่างของราคาปิดรายวันดัชนีตลาดหลักทรัพย์แห่งประเทศไทย ณ วันที่ t และวันที่ $t+q$ โดยสามารถเขียนเป็นสมการได้ดังนี้

$$D_{t+q} = \begin{cases} 1 & ; X_t \leq X_{t+q} > 0 \\ -1 & ; X_t > X_{t+q} \leq 0 \end{cases} \quad (3.6.4)$$



โดยที่	\tilde{X}_t	คือ ผลต่างแบบเศษส่วน
	X_t	คือ ราคาปิดรายวันดัชนีตลาดหลักทรัพย์แห่งประเทศไทย ณ เวลาที่ t
	X_{t+q}	คือ ราคาปิดรายวันดัชนีตลาดหลักทรัพย์แห่งประเทศไทย ณ เวลาที่ $t+q$
	p	คือ ค่าความหน่วง
	q	คือ ช่วงเวลาที่พยากรณ์แนวโน้มออกไปล่วงหน้า
	D_{t+q}	คือ แนวโน้มของราคาปิดรายวันดัชนีตลาดหลักทรัพย์แห่งประเทศไทยในอีก q วันข้างหน้า

โดยในแต่ละกลุ่มแบบจำลองนั้นจะกำหนดให้มีการนำข้อมูลย้อนหลังของคุณลักษณะนั้นๆ มาใช้เป็นคุณลักษณะในการสร้างแบบจำลอง โดยจะใช้ข้อมูลคุณลักษณะที่หน่วงไปตั้งแต่ 0 ถึง 5 ช่วงเวลาและจะทำการเลือกแบบจำลองที่ให้ความแม่นยำเฉลี่ยสูงที่สุดเป็นแบบจำลองที่ใช้ในการเปรียบเทียบระหว่างการใช้อัตราผลตอบแทนรายวันกับผลต่างแบบเศษส่วนมาเป็นคนลักษณะในการพยากรณ์แนวโน้มของราคาปิดรายวันดัชนีตลาดหลักทรัพย์แห่งประเทศไทย ในระยะเวลา 1, 5, 20, 60 วัน ซึ่งจะมีแบบจำลองทั้งหมด 48 แบบจำลองด้วยกันและจะมีแบบจำลองที่ดีที่สุดทั้งหมด 8 แบบจำลองตามคุณลักษณะที่ใช้และระยะเวลาที่พยากรณ์แนวโน้มของราคาปิดรายวันดัชนีตลาดหลักทรัพย์แห่งประเทศไทย ยกตัวอย่างเช่นในการพยากรณ์แนวโน้มในอีก 20 วันข้างหน้า โดยใช้อัตราผลตอบแทนรายวันเป็นคุณลักษณะจะมีแบบจำลองทั้งหมด 6 แบบจำลองด้วยกัน

โดยแต่ละแบบจำลองจะถูกประเมินแบบจำลองด้วยวิธี K-Fold Cross-Validation เพื่อหาค่าความแม่นยำเฉลี่ยและใช้ในการเลือกแบบจำลองที่มีค่าความหน่วง (p) เหมาะสมในการใช้อัตราผลตอบแทนรายวันเป็นคุณลักษณะสำหรับการพยากรณ์แนวโน้มในอีก 20 วันข้างหน้าเพื่อนำไปเปรียบเทียบค่าความแม่นยำกับแบบจำลองที่ใช้คุณลักษณะผลต่างแบบเศษส่วนสำหรับการพยากรณ์แนวโน้มในอีก 20 วันข้างหน้าต่อไป ในส่วนของรายละเอียดเกี่ยวกับ K-Fold Cross-Validation จะกล่าวถึงในหัวข้อถัดไป

3.7 การประเมินแบบจำลองการเรียนรู้ของเครื่อง

ในการประเมินผลหรือความสามารถของแบบจำลองการเรียนรู้ของเครื่องสามารถทำได้ด้วยการแบ่งข้อมูลทั้งหมดเป็นสองส่วน ได้แก่ ข้อมูลที่ใช้ฝึกสอนและข้อมูลที่ใช้สำหรับทดสอบ แต่ว่าการแบ่งข้อมูลในลักษณะนี้นั้นไม่ได้ใช้ข้อมูลทั้งหมดในการฝึกสอนและทดสอบและทำการแบ่งข้อมูลเพียงครั้งเดียว ซึ่งอาจจะส่งผลทำให้เกิดความไม่แม่นยำในการประเมินแบบจำลองได้

โดยการประเมินผลแบบจำลองการเรียนรู้ของเครื่องในการศึกษาครั้งนี้ ผู้ศึกษาเลือกใช้วิธี K-Fold Cross-Validation เป็นวิธีการประเมินแบบจำลองการเรียนรู้ของเครื่องที่แบ่งข้อมูลออกเป็น K ส่วนเท่ากันๆ และใช้ข้อมูลทุกส่วนในการเป็นข้อมูลที่ใช้ในการฝึกสอนและข้อมูลที่ใช้ในการทดสอบแบบจำลองเพื่อลดปัญหาความไม่แม่นยำในการประเมินแบบจำลอง โดยในการศึกษาครั้งนี้ผู้ศึกษาได้เลือกค่า K เท่ากับ 5 สำหรับการทำ K-Fold Cross-Validation และจะใช้การวัดผลแบบจำลองและประเมินแบบจำลองโดยใช้ค่าความแม่นยำ (Accuracy) ซึ่งก็คือค่าที่วัดอัตราความถูกต้องของการพยากรณ์ของแบบจำลองการเรียนรู้ของเครื่องเมื่อเทียบกับข้อมูลที่เกิดขึ้นจริง ในการ



พยากรณ์แนวโน้มดัชนีราคาตลาดหลักทรัพย์แห่งประเทศไทยในแต่ละครั้งการทำ Cross-Validation มาหาค่าเฉลี่ยความแม่นยำในการพยากรณ์แนวโน้มของดัชนีราคาตลาดหลักทรัพย์แห่งประเทศไทยของแต่ละแบบจำลอง และทำการเปรียบเทียบระหว่างแบบจำลองที่ใช้คุณลักษณะอัตราผลตอบแทนรายวันกับคุณลักษณะผลต่างแบบเศษส่วนในแต่ละระยะเวลาของการพยากรณ์ โดยการแบ่งข้อมูลที่ใช้ในการฝึกสอนและทดสอบแบบจำลอง ซึ่งการประเมินแบบจำลองซัพพอร์ตเวกเตอร์แมชชีนด้วยวิธี K-Fold Cross-Validation นั้นสามารถแสดงเป็นตารางได้ตามตารางที่ 3 ดังนี้

ตารางที่ 1: การประเมินแบบจำลองโดยใช้ 5-Fold Cross-Validation

Iteration	All Data					Performance
	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	
1 st	Test	Training	Training	Training	Training	ACC ₁
2 nd	Training	Test	Training	Training	Training	ACC ₂
3 rd	Training	Training	Test	Training	Training	ACC ₃
4 th	Training	Training	Training	Test	Training	ACC ₄
5 th	Training	Training	Training	Training	Test	ACC ₅

โดยค่าความแม่นยำและค่าความแม่นยำเฉลี่ยสามารถคำนวณได้ตามสมการที่ 3.6.1 และ 3.6.2 ตามลำดับดังนี้

$$Average\ ACC = \frac{\sum_{i=1}^k ACC_i}{k} \quad (3.7.1)$$

$$ACC = \frac{True\ positive + True\ negative}{Total\ prediction} \quad (3.7.2)$$

โดยที่	True Positive	คือ จำนวนครั้งที่แบบจำลองพยากรณ์ได้ถูกต้องสำหรับการพยากรณ์ว่าเป็นแนวโน้มขาขึ้น
	True Negative	คือ จำนวนครั้งที่แบบจำลองพยากรณ์ได้ถูกต้องสำหรับการพยากรณ์ว่าเป็นแนวโน้มขาลง
	Total Prediction	คือ จำนวนการพยากรณ์ทั้งหมด

4. ผลการวิจัย

การศึกษาความสามารถในการพยากรณ์ของผลต่างแบบเศษส่วนโดยใช้แบบจำลองซัพพอร์ตเวกเตอร์แมชชีน โดยใช้การทดสอบความนิ่งของข้อมูลด้วยวิธี Augmented Dickey Fuller Test และประเมินแบบจำลองซัพพอร์ตเวกเตอร์แมชชีนด้วยวิธี K-Fold Cross-Validation มีผลการศึกษาดังต่อไปนี้



4.1 ผลการทดสอบความนิ่งของข้อมูล

จากข้อมูลดัชนีหลักทรัพย์แห่งประเทศไทย ผู้ศึกษาได้นำมาหาค่าอัตราผลตอบแทนรายวันและนำมาหาค่าผลต่างแบบเศษส่วน โดยลำดับการทำผลต่างแบบเศษส่วนที่ทำให้ข้อมูลดัชนีหลักทรัพย์แห่งประเทศไทยนั้นมีความนิ่ง ผลการทดสอบ Augmented Dickey Fuller Test ของข้อมูลดัชนีหลักทรัพย์แห่งประเทศไทย อัตราผลตอบแทนผลต่างแบบเศษส่วน พบว่าดัชนีตลาดหลักทรัพย์แห่งประเทศไทยนั้นไม่มีความนิ่ง และอัตราผลตอบแทนและผลต่างแบบเศษส่วนนั้นมีความนิ่งที่ระดับนัยสำคัญ 95% สามารถสรุปผลการทำการทดสอบได้ดังตารางที่ 4 โดยลำดับการทำผลต่างแบบเศษส่วนนั้นหาได้จากการทดสอบ Augmented Dickey Fuller Test ในการทำผลต่างเศษส่วนในแต่ละลำดับการทำผลต่างแบบเศษส่วน พบว่าลำดับการทำผลต่างแบบเศษส่วนที่ทำให้ข้อมูลดัชนีหลักทรัพย์แห่งประเทศไทยมีความนิ่งมีค่าเท่ากับ 0.60 โดยตารางที่ 5 แสดงผลการทดสอบความนิ่งของข้อมูลด้วย Augmented Dickey Fuller Test ในแต่ละลำดับการทำผลต่างแบบเศษส่วนที่ระดับนัยสำคัญ 5%

ตารางที่ 2: ผลการทดสอบความนิ่งของข้อมูลด้วย Augmented Dickey Fuller Test

Variables	Lag Length	ADF Test Statistics	Test Critical Values	Result (at 95% confidence level)
SET Index	6.0	-1.7661	-3.41199	Non-Stationary
Daily Return	14.0	-12.8182	-1.94109	Stationary
Fractional Difference (d=0.60)	17.0	-2.8919	-2.86255	Stationary

ที่มา: จากการคำนวณ

ตารางที่ 3: ผลการทดสอบความนิ่งของข้อมูลในแต่ละลำดับการทำผลต่างแบบเศษส่วน โดยใช้ Augmented Dickey Fuller Test

Difference Order	Lag Length	ADF Test Statistics	Test Critical Value	Result (at 95% confidence level)
0.000	6.0	-1.0744	-2.8625	Non-Stationary
0.025	6.0	-1.0954	-2.8625	Non-Stationary
0.050	6.0	-1.1212	-2.8625	Non-Stationary
0.075	6.0	-1.1965	-2.8625	Non-Stationary
0.100	6.0	-1.2505	-2.8626	Non-Stationary
⋮	⋮	⋮	⋮	⋮
0.575	22.0	-2.7261	-2.8625	Non-Stationary
0.600	22.0	-2.8918	-2.8625	Stationary



0.625	22.0	-3.0219	-2.8625	Stationary
.
0.900	27.0	-4.9780	-2.8625	Stationary
0.925	27.0	-5.4366	-2.8625	Stationary
0.950	25.0	-6.5383	-2.8625	Stationary
0.975	13.0	-11.6569	-2.8625	Stationary
1.000	5.0	-23.0195	-2.8625	Stationary

ที่มา: จากการคำนวณ

4.2 ผลการพยากรณ์โดยแบบจำลองซัพพอร์ตเวกเตอร์แมชชีน

หลังจากการทดสอบความนิ่งของข้อมูลด้วย Augmented Dickey Fuller Test ผู้ศึกษาได้นำข้อมูลที่มีความนิ่งได้แก่ อัตราผลตอบแทนรายวัน และผลต่างแบบเศษส่วนมาใช้เป็นคุณลักษณะของแบบจำลองซัพพอร์ตเวกเตอร์แมชชีน โดยได้เปรียบเทียบความสามารถในการพยากรณ์ด้วยค่าความแม่นยำเฉลี่ยในการพยากรณ์ (Accuracy) ที่ได้จากการประเมินแบบจำลองซัพพอร์ตเวกเตอร์แมชชีนด้วย 5-Fold Cross-Validation ของแบบจำลองที่เหมาะสมในแต่ละระยะของการพยากรณ์แนวโน้ม โดยจากการศึกษาได้ผลการศึกษาดังตารางที่ 4 และ 5 ซึ่งผลการศึกษาแสดงให้เห็นว่าอัตราผลตอบแทนนั้นมีความแม่นยำเฉลี่ยในการพยากรณ์ที่สูงกว่าในการพยากรณ์ระยะสั้น (1 วัน) ที่สูงกว่าผลต่างแบบเศษส่วนแต่ความแม่นยำนั้นสูงกว่า 50% เพียงเล็กน้อยเท่านั้น ส่วนผลต่างแบบเศษส่วนนั้นมีความแม่นยำในการพยากรณ์ระยะยาว (5, 20, 60 วัน) ที่สูงกว่าซึ่งแสดงให้เห็นว่าการใช้ผลต่างแบบเศษส่วนนั้นสามารถเพิ่มความสามารถในการพยากรณ์ในระยะยาวของแบบจำลองซัพพอร์ตเวกเตอร์แมชชีนได้

ตารางที่ 4: ค่าความแม่นยำในการพยากรณ์ของทุกแบบจำลอง

Lag Length	1-day Pred.		5-day Pred.		20-day Pred.		60-day Pred.	
	Return	FD	Return	FD	Return	FD	Return	FD
0	51.21%	48.06%	50.79%	49.30%	52.17%	54.64%	51.35%	54.66%
1	53.21%	48.89%	51.73%	52.07%	50.32%	55.89%	50.19%	58.87%
2	50.69%	48.58%	51.04%	53.14%	49.94%	56.10%	49.84%	59.68%
3	52.41%	47.92%	48.92%	52.41%	50.15%	56.90%	50.40%	60.21%
4	52.14%	50.27%	50.38%	51.76%	51.19%	57.01%	50.75%	60.92%
5	51.07%	51.17%	51.66%	51.76%	50.95%	56.66%	50.65%	60.85%

ที่มา: จากการคำนวณ

หมายเหตุ: FD คือ Fractional Difference



ตารางที่ 5: ผลการประเมินแบบจำลองซัพพอร์ตเวกเตอร์แมชชีนที่เหมาะสมด้วยค่าความแม่นยำเฉลี่ยจากการประเมินแบบจำลองด้วย 5-Fold Cross-Validation

Features	n-day Prediction	Lag Length	Average Accuracy
Return	1	1	53.21%
	5	1	51.73%
	20	0	52.17%
	60	0	51.35%
Fractional Difference	1	5	51.17%
	5	2	53.14%
	20	4	57.01%
	60	4	60.92%

ที่มา: จากการคำนวณ

5. การอภิปรายผล

ในการศึกษาครั้งนี้มีจุดประสงค์เพื่อศึกษาความสามารถในการพยากรณ์ของผลต่างแบบเศษส่วน โดยเปรียบเทียบกับความสามารถในการพยากรณ์ของอัตราผลตอบแทนรายวัน โดยใช้แบบจำลองซัพพอร์ตเวกเตอร์แมชชีนในการพยากรณ์ จากผลการศึกษาผู้ศึกษาสามารถอภิปรายผลการศึกษาความสามารถในการพยากรณ์ของคุณลักษณะผลต่างแบบเศษส่วนได้ดังนี้

1). ความสามารถในการพยากรณ์ของข้อมูลที่ทำผลต่างแบบจำนวนเต็มหรืออัตราผลตอบแทนมีผลการศึกษาที่สอดคล้องกับ (Granger, 1980) และ (Hosking, 1985) ในเรื่องของการทำผลต่างแบบจำนวนเต็มนั้นเพียงพอต่อการพยากรณ์ข้อมูลอนุกรมเวลาในระยะสั้น โดยจากการศึกษาครั้งนี้แสดงให้เห็นว่าการพยากรณ์แนวโน้มของราคาปิดรายวันดัชนีตลาดหลักทรัพย์แห่งประเทศไทย คุณลักษณะอัตราผลตอบแทนรายวันนั้นมีความแม่นยำเฉลี่ยในการพยากรณ์แนวโน้ม 1 วันข้างหน้าที่สูงกว่าการใช้คุณลักษณะผลต่างแบบเศษส่วน เนื่องจากการทำผลต่างแบบจำนวนเต็มนั้นสะท้อนถึงความจำระยะสั้นของข้อมูลอนุกรมเวลา แต่ถึงแม้อัตราผลตอบแทนนั้นจะให้ค่าความแม่นยำในการพยากรณ์ที่มากกว่าแต่ค่าความแม่นยำนั้นมีค่าเพียง 53.21% ซึ่งสูงกว่าการเดาสุ่มเพียงเล็กน้อยเท่านั้น โดยอาจจะเป็นผลมาจากในระยะสั้นนั้นดัชนีตลาดหลักทรัพย์นั้นมีปัจจัยต่างเข้ามากระทบมากมายในแต่ละวันส่งผลทำให้เกิดความผันผวนในระยะสั้นจึงทำให้การพยากรณ์ในระยะสั้นนั้นเป็นไปได้ยาก หรือการใช้อัตราผลตอบแทนเพียงอย่างเดียวไม่เพียงพอต่อการพยากรณ์

2). ความสามารถในการพยากรณ์ของคุณลักษณะผลต่างแบบเศษส่วนนั้นมีผลการศึกษาที่สอดคล้องกับ (Granger, 1980), (Hosking, 1985) และ (Karia, 2013) คุณลักษณะผลต่างแบบเศษส่วนนั้นสะท้อนถึงความจำระยะยาวของข้อมูลอนุกรมเวลาทำให้สามารถพยากรณ์ข้อมูลอนุกรมเวลาในระยะยาวได้อย่างแม่นยำมากขึ้นแต่ไม่ได้ช่วยเพิ่มประสิทธิภาพในการพยากรณ์ระยะสั้น โดยการศึกษาในครั้งนี้ได้แสดงให้เห็นว่าคุณลักษณะผลต่างแบบเศษส่วนนั้นมีความสามารถในการพยากรณ์ในระยะยาวที่สูงกว่าคุณลักษณะอัตราผลตอบแทนรายวัน โดยมีค่าความแม่นยำเฉลี่ยที่



สูงกว่าอย่างชัดเจนในการพยากรณ์แนวโน้มตั้ง 20 และ 60 วันล่วงหน้าโดยให้ค่าความแม่นยำเฉลี่ยสูงสุดที่ 60.92% แต่ความสามารถในการพยากรณ์ระยะสั้นนั้นคือยกว่าการใช้คุณลักษณะอัตราผลตอบแทนรายวัน โดยพบว่าลำดับการทำผลต่างแบบเศษส่วนที่น้อยที่สุดที่ทำให้ข้อมูลราคาปิดดัชนีตลาดหลักทรัพย์แห่งประเทศไทยมีความนิ่งนั้นมีค่าเท่ากับ 0.6

3). ความสามารถในการพยากรณ์แนวโน้มของดัชนีราคาหลักทรัพย์แห่งประเทศไทย ในการใช้แบบจำลองซัพพอร์ตเวกเตอร์แมชชีน โดยมีอัตราผลตอบแทนรายวันเป็นคุณลักษณะของแบบจำลอง มีผลการศึกษาที่ขัดแย้งกับ (Rungruang, 2019) ซึ่งจากผลการศึกษาในครั้งนี้แสดงให้เห็นว่าการใช้อัตราผลตอบแทนรายวันเพียงอย่างเดียวนั้นไม่ได้ให้ความแม่นยำที่สูงมากนัก โดยให้ค่าความแม่นยำสูงสุดเพียงแค่ 53.21% เท่านั้น

6. สรุปผลการศึกษา

จากการศึกษาพบว่าอัตราผลตอบแทนรายวันนั้นมีความสามารถในการพยากรณ์ที่สูงกว่าการใช้ผลต่างแบบเศษส่วนในการพยากรณ์แนวโน้มล่วงหน้าเป็นระยะเวลา 1 วัน โดยให้ค่าความแม่นยำเท่ากับ 53.21% แต่การใช้ผลต่างแบบเศษส่วนเป็นคุณลักษณะในแบบจำลองซัพพอร์ตเวกเตอร์แมชชีนนั้นมีความสามารถในการพยากรณ์แนวโน้มล่วงหน้า 5, 20, 60 วัน สูงกว่าการใช้อัตราผลรายวันเป็นคุณลักษณะ โดยให้ค่าความแม่นยำเท่ากับ 53.14, 57.01, 60.92 เปอร์เซ็นต์ตามลำดับ เนื่องจากผลต่างแบบเศษส่วนนั้นสะท้อนถึงความจำของข้อมูลอนุกรมเวลาที่ยาวกว่าอัตราผลตอบแทนรายวันส่งผลทำให้การพยากรณ์ในระยะยาวมีประสิทธิภาพมากขึ้น แต่ถึงแม้การใช้ผลต่างแบบเศษส่วนนั้นจะช่วยทำให้การพยากรณ์ในระยะยาวนั้นมีประสิทธิภาพมากขึ้นแต่การใช้ข้อมูลดัชนีเพียงอย่างเดียวนั้นยังไม่เพียงพอต่อการพยากรณ์ให้มีความแม่นยำที่สูง โดยเฉพาะอย่างยิ่งในการพยากรณ์ในระยะสั้น

7. ข้อเสนอแนะ

7.1 ข้อเสนอแนะในการนำไปใช้

จากผลการศึกษาในครั้งนี้แสดงให้เห็นถึงความสามารถในการพยากรณ์ของคุณลักษณะผลต่างแบบเศษส่วนในแบบจำลองการเรียนรู้ของเครื่อง ซึ่งมีความสามารถในการพยากรณ์แนวโน้มของราคาปิดรายวันดัชนีตลาดหลักทรัพย์แห่งประเทศไทยในระยะยาวที่สูงกว่าการใช้คุณลักษณะผลต่างแบบจำนวนเต็ม (อัตราผลตอบแทน) ดังนั้นแล้วในการพยากรณ์แนวโน้มควรพิจารณาถึงระยะเวลาที่จะทำการพยากรณ์ออกไปล่วงหน้าโดยการพยากรณ์ระยะสั้นการใช้อัตราผลตอบแทนจะมีความเหมาะสมกว่าการใช้ผลต่างแบบเศษส่วน แต่ถ้าหากการพยากรณ์นั้นเป็นการพยากรณ์ในระยะยาวผู้พยากรณ์ควรพิจารณาใช้ผลต่างแบบเศษส่วนในการทำข้อมูลอนุกรมเวลานั้นมีความนิ่งและใช้ผลต่างแบบเศษส่วนนั้นเป็นคุณลักษณะของแบบจำลองการเรียนรู้ของเครื่อง

7.2 ข้อเสนอแนะในการศึกษาค้างถัดไป

โดยการศึกษาครั้งนี้ได้ศึกษาประยุกต์ใช้การทำผลต่างแบบเศษส่วนในข้อมูลอนุกรมเวลาราคาปิดรายวันดัชนีตลาดหลักทรัพย์แห่งประเทศไทยเท่านั้น ดังนั้นในการศึกษาค้างต่อไปผู้ศึกษาแนะนำให้ประยุกต์การใช้การทำผลต่างแบบเศษส่วนในข้อมูลอนุกรมเวลาอื่นๆ เช่น ข้อมูลเศรษฐกิจมหภาค ข้อมูลทางการเงินต่างๆ เพื่อพัฒนาให้แบบจำลองมีความสามารถในการพยากรณ์ที่สูงมากยิ่งขึ้น และในการศึกษาค้างนี้ก็ได้ศึกษาโดยใช้แบบจำลองซัพพอร์ตเวกเตอร์แมชชีนในการแก้ปัญหาการจำแนกประเภทของข้อมูล ดังนั้นแล้วในการศึกษาค้างถัดไปอาจจะศึกษา



การใช้ผลต่างแบบเศษส่วนกับแบบจำลองการเรียนรู้ของเครื่องที่ใช้ในการแก้ปัญหา Regression เช่น Support Vector Regression เป็นต้น นอกจากนั้นในการศึกษาค้นคว้าครั้งนี้พิจารณาแค่ค่าความหน่วงสูงสุดของคุณลักษณะที่ใช้เท่ากับ 5 ดังนั้นแล้วในการศึกษาค้นคว้าครั้งต่อไปอาจจะพิจารณาถึงขอบเขตของค่าความหน่วงที่มากขึ้น

กิตติกรรมประกาศ

การศึกษาค้นคว้าอิสระเรื่องนี้สำเร็จลุล่วงได้ด้วยความกรุณาจากบุคคลที่ให้ความอนุเคราะห์ ดร. ธฤตพน อุสวัตต์ อาจารย์ที่ปรึกษาการศึกษาค้นคว้าอิสระ ที่ได้กรุณาให้คำปรึกษาแนะนำแนวทางอันเป็นประโยชน์ในการศึกษาค้นคว้าอิสระ รวมทั้งการตรวจตราแก้ไขเนื้อหาตลอดระยะเวลาที่ได้ทำการศึกษาค้นคว้าจนสำเร็จลุล่วงไปด้วยดี ผู้ศึกษาจึงขอกราบขอบพระคุณเป็นอย่างสูง

เอกสารอ้างอิง

- ปริญญา สงวนศักดิ์. (2562). Artificial Intelligence with Machine Learning, AI สร้างได้ด้วยแมชชีนเลิร์นนิ่ง, พิมพ์ครั้งที่ 1.
- ภูมิฐาน รังคกุลนุวัฒน์. (2556). การวิเคราะห์อนุกรมเวลาสำหรับเศรษฐศาสตร์และธุรกิจ, พิมพ์ครั้งที่ 1. สำนักพิมพ์แห่งจุฬาลงกรณ์มหาวิทยาลัย.
- Bergmeir, C.; Hyndman, R. J.; & Koo, B. (2018). A note on the validity of cross-validation for evaluating autoregressive time series prediction. *Computational Statistics & Data Analysis*. 70-83.
- Granger, C. W. J.; & Joyeux R. (1980). An Introduction to Long-Memory Time Series Models and Fractional Differencing. *Journal of Time Series Analysis*. 15-29
- Hosking, J. R. M. (1985). Fractional Differencing Modeling in Hydrology. *Journal of the American Water Resource Association*. 677-682.
- Huang, W.; Nakamori, Y.; & Wang, S. Y. (2005). Forecasting stock market movement direction with support vector machine. *Computers & Operations Research*. 2513-2522.
- Karia, A. A. (2013). Fractionally integrated ARMA for crude palm oil prices prediction: case of potentially overdifference. *Journal of Applied Statistics*. 2735-2748
- Lin, C. J.; & Chang, C. C. (2011). LIBSVM: A Library for Support Vector Machines. *ACM Transactions on Intelligent Systems and Technology*.
- Pedregosa, F.; et al. (2011). Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*. 2825-2830.
- Prado, Marcos L. D. (2018). *Advance in Financial Machine Learning*. 1st ed. Wiley.
- Qian, B.; & Rasheed, K. (2004). Hurst Exponent and Financial Market Predictability. *Proceeds of the Financial Engineering and Application*. 203-209.
- Rungruang, C.; et al. (2019). Prediction the Direction of SET50 Index Using Support Vector Machines. *Thai Journal of Mathematics*, 153-165.