

# การทำนายผลผลิตข้าวโดยวิธีชัพพอร์ทเวกเตอร์แมชชีน

รัชภูมิ ใจกล้า<sup>1</sup> พันธุ์ทิพย์ นนทรี<sup>1</sup> และ อรรถชัย จินตะเวช<sup>1</sup>

## บทคัดย่อ

**ประเด็น (Background):** การทำนายผลผลิตพืชจำเป็นต้องใช้แบบจำลองพืชและการทดลองจริง เพื่อการทดสอบความแม่นยำของแบบจำลอง ซึ่งในการทดลองในภาคสนามต้องใช้เวลานานและมีค่าใช้จ่ายสูง (สุนทร และ เมธี, 2535) เพื่อเป็นการประหยัดเวลาและค่าใช้จ่ายในการทำแบบจำลองพืช จึงได้เสนอวิธีการทำนายผลผลิตข้าวโดยวิธีชัพพอร์ทเวกเตอร์แมชชีน

**จุดประสงค์:** เพื่อพัฒนาแบบจำลองการทำนายผลผลิตข้าว โดยใช้ข้อมูลนำเข้าของ DSSAT 4.0 (Minimum Data Set) ในการเรียนรู้และการทดสอบแบบจำลองการทำนายผลผลิตข้าวโดยวิธีชัพพอร์ทเวกเตอร์แมชชีน

**วิธีการศึกษา:** พัฒนาแบบจำลองโดยใช้ข้อมูลที่ได้จากการคาดการณ์ผลผลิตข้าวจากการใช้โปรแกรม DSSAT 4.0 เป็นชุดข้อมูลสำหรับการเรียนรู้ (Learning) และสำหรับการทดสอบ โดยใช้โปรแกรม MATLAB ในการพัฒนาแบบจำลองการทำนายผลผลิตข้าวสำหรับการทำนายผลผลิตข้าวพันธุ์ กข23 ชุดดิน สุพรรณบุรี

**ผลการศึกษา:** จากการทำนายผลผลิตข้าวโดยวิธีชัพพอร์ทเวกเตอร์แมชชีน พบว่าแบบจำลองสามารถทำนายได้มีความใกล้เคียงกับผลที่ได้จากการคาดการณ์โดยโปรแกรม DSSAT 4.0

**สรุป:** แบบจำลองทำนายผลผลิตข้าวนี้สามารถทำนายได้สำหรับข้าวพันธุ์ กข23 ชุดดินสุพรรณบุรีเท่านั้น ซึ่งในอนาคตจะสามารถทำได้หลายพันธุ์และหลายชุดดิน โดยจะต้องมีการเรียนรู้และทดสอบสำหรับข้าวพันธุ์และชุดดินอื่นๆ อีกต่อไป

**คำสำคัญ:** การทำนายผลผลิตข้าว, ชัพพอร์ทเวกเตอร์แมชชีน

## บทนำ

ในเอกสารฉบับนี้ได้เสนอวิธีการทำนายผลโดยใช้วิธีการทำนายโดยการใช้ชัพพอร์ทเวกเตอร์แมชชีน สำหรับวิเคราะห์การถดถอย (Support Vector Regression: SVR) ซึ่งได้นำเอาผลที่ได้จากโปรแกรม DSSAT 4.0 ใช้เป็นชุดข้อมูลสำหรับการทดสอบการทำนายนี้ ในที่นี้ได้ทำการทดลองการทำนายผลผลิตข้าวพันธุ์ กข23 ชุดดิน สุพรรณบุรี ในปี 1963-1978 และข้อมูลอากาศของ สถานีทดลองเกษตรเขตชลประทาน นั่นก็หมายความว่าในการทำนายผลผลิตข้าว นั้น จะแยกแบบจำลองออกไปตาม พันธุ์ข้าวและชุดดิน ในเอกสารฉบับนี้ได้ทำการทดลอง 1 แบบจำลอง คือ ข้าวพันธุ์ กข23 ชุดดิน สุพรรณบุรี

## ตรวจเอกสาร

เนื่องจากงานวิจัยนี้เป็นการประยุกต์ใช้ชัพพอร์ทเวกเตอร์แมชชีน เพื่อการประมาณค่าฟังก์ชันหรือเรียกอีกอย่างว่าการวิเคราะห์การถดถอย (Regression) เนื้อหาหลักของชัพพอร์ทเวกเตอร์แมชชีนจึงเกี่ยวกับการวิเคราะห์การ

<sup>1</sup> ศูนย์วิจัยเพื่อเพิ่มผลผลิตทางเกษตร คณะเกษตรศาสตร์ มหาวิทยาลัยเชียงใหม่

ถดถอย ส่วนทฤษฎีของซัพพอร์ตเวกเตอร์แมชชีนสำหรับการแบ่งกลุ่มจะกล่าวถึงให้รู้หลักการเบื้องต้นพอสังเขป ดังนั้น เนื้อหาในบทนี้จึงประกอบด้วย พื้นฐานที่เกี่ยวกับซัพพอร์ตเวกเตอร์แมชชีน ซัพพอร์ตเวกเตอร์แมชชีนสำหรับการแบ่งกลุ่ม และในส่วนตัวสุดท้ายจะกล่าวถึงซัพพอร์ตเวกเตอร์แมชชีนสำหรับการถดถอย

### พื้นฐานที่เกี่ยวกับซัพพอร์ตเวกเตอร์แมชชีน

ซัพพอร์ตเวกเตอร์แมชชีนเป็นเครื่องช่วยเรียนรู้ (Machine Learning Tasks) ที่มีพื้นฐานมาจากทฤษฎีการเรียนรู้จากสถิติ (Statistical Learning Theory) (T. Xu, X.N. Dong) เหมือนกับโครงข่ายประสาทเทียม (Artificial Neural Network: ANN) แต่โครงสร้างแตกต่างกัน นั่นคือ ซัพพอร์ตเวกเตอร์แมชชีนใช้หลักการลดความเสี่ยงเชิงโครงสร้างให้ต่ำสุด (Structural Risk Minimization: SRM) ในขณะที่โครงข่ายประสาทเทียมใช้หลักการลดความเสี่ยงเชิงทดลองให้ต่ำสุด (Empirical Risk Minimization: ERM) ซัพพอร์ตเวกเตอร์แมชชีนสามารถประยุกต์ใช้กับงาน 2 รูปแบบคือ การแบ่งกลุ่ม (Classification) และการวิเคราะห์การถดถอย (Regression) หรือการประมาณค่าฟังก์ชันสำหรับการทำนายผลผลิตข้าวเป็นการประยุกต์ใช้เพื่อประมาณค่าฟังก์ชัน

### ซัพพอร์ตเวกเตอร์แมชชีนสำหรับการถดถอย (Support Vector Regression: SVR)

โครงสร้างของซัพพอร์ตเวกเตอร์แมชชีนสำหรับการถดถอยแตกต่างจากโครงสร้างของซัพพอร์ตเวกเตอร์แมชชีนสำหรับการแบ่งกลุ่ม แต่อยู่บนหลักการของการใช้ซัพพอร์ตเวกเตอร์เพื่อเป็นตัวแทนของกลุ่มข้อมูลที่ใช้สำหรับสอนเช่นเดียวกัน

### หลักการหาระนาบเชิงเส้น


หลักการหาระนาบเชิงเส้นของซัพพอร์ตเวกเตอร์แมชชีนสำหรับการถดถอย เริ่มต้นที่การสอนซัพพอร์ตเวกเตอร์แมชชีนด้วยเซตข้อมูล  $\{x_i, y_i\}_{i=1}^l, x_i \in \mathcal{R}^n, y_i \in \mathcal{R}$  เมื่อ  $x_i$  คือเวกเตอร์ข้อมูลอินพุต  $y_i$  คือข้อมูลเอาต์พุต เพื่อหาฟังก์ชันเชิงเส้น  $f(x)$  ที่ใช้แทนสมการระนาบเกิน (Hyperplane) ของกลุ่มข้อมูลที่นำมาฝึกสอนทั้งหมดดังสมการ (1) เมื่อ  $w$  คือเวกเตอร์น้ำหนักและ  $b$  คือค่าไบอัส ดังนั้นเมื่อมีเวกเตอร์  $x$  ใดๆ ก็จะสามารถประมาณค่า  $y$  ได้โดยใช้สมการ (1) นั่นคือ  $f(x) = y'$  นั่นเอง

$$f(x) = \langle w \bullet x \rangle + b \quad (1)$$

ก่อนการสร้างระนาบเกิน สถาปัตยกรรมของซัพพอร์ตเวกเตอร์แมชชีนได้มีการออกแบบให้มีการแมปข้อมูลจากปริภูมิอินพุตไปอยู่ในปริภูมิที่สูงขึ้นเรียกว่าปริภูมิลักษณะเด่นด้วยฟังก์ชันเคอร์เนล เพื่อให้สามารถหาฟังก์ชันเชิงเส้นที่เหมาะสมสำหรับใช้แทนสมการระนาบเกินได้ ดังในภาพที่ 1 ซึ่งแสดงถึงความแตกต่างในการวิเคราะห์การถดถอยแบบไม่เชิงเส้นในปริภูมิอินพุตและการวิเคราะห์การถดถอยเชิงเส้นในปริภูมิลักษณะเด่น ทำให้เวกเตอร์ข้อมูลอินพุตเปลี่ยนไปเป็นข้อมูลที่มีมิติสูงขึ้นในปริภูมิลักษณะเด่น การแมปข้อมูลด้วยฟังก์ชันเคอร์เนลแสดงดังสมการ (2) เมื่อ  $\Phi$  คือฟังก์ชันการแมป (Mapping Function) นั่นคือ  $x_i \Rightarrow K(x_i, x_j)$  ทำให้สมการระนาบเกินที่ต้องการหาเปลี่ยนเป็นสมการ (3)

$$K(x_i, x_j) = \langle \Phi(x_i) \bullet \Phi(x_j) \rangle \quad (2)$$


$$f(x) = \langle w \bullet K(x_i, x_j) \rangle + b \quad (3)$$



ภาพที่ 1 การวิเคราะห์การถดถอยแบบไม่เชิงเส้นในปริภูมิอินพุต และ การวิเคราะห์การถดถอยเชิงเส้นในปริภูมิลักษณะเด่น

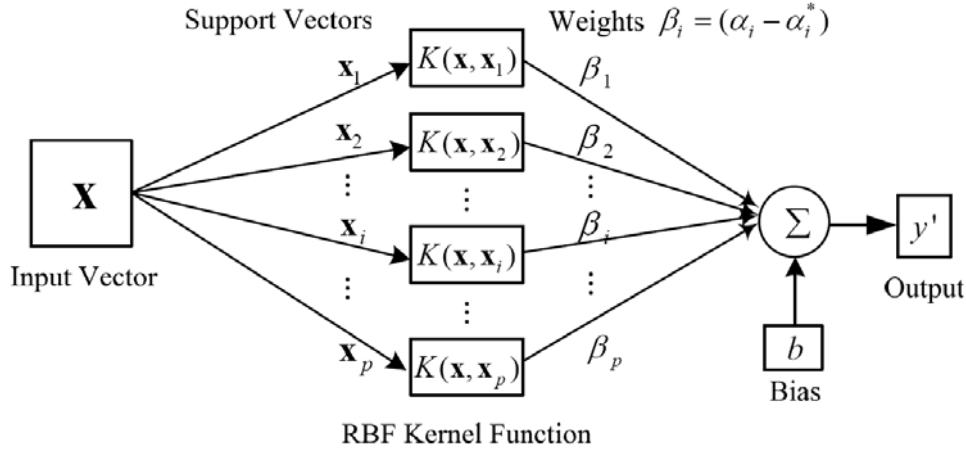
การสร้างระนาบเกิน  $f(x)$  เพื่อประมาณค่าให้ใกล้เคียงกับ  $y$  ที่สุดจะต้องหาค่า  $w$  และ  $b$  ที่เหมาะสมที่สุด การสร้างระนาบเกินสำหรับกรณีของซัพพอร์ตเวกเตอร์แมชชีนสำหรับการถดถอย จะพิจารณาค่าความคลาดเคลื่อนที่ยอมรับได้ ซึ่งอยู่ในรูปฟังก์ชันการสูญเสีย (Loss Function) และสำหรับกรณีการพยากรณ์ความต้องการไฟฟ้าเป็นการทำนายอนุกรมเวลา (Time Series Prediction) ซึ่งมีฟังก์ชันการสูญเสียให้เลือกใช้ 2 ชนิดคือ  $\epsilon$ -Insensitive และ Huber's Robust Loss Function (K.R. Muller) แต่ที่นิยมใช้มากกว่าคือ  $\epsilon$ -Insensitive ซึ่งมีความสัมพันธ์ดังสมการ (4) เมื่อ  $L(y_i, f(x))$  คือ ความคลาดเคลื่อนที่เกิดขึ้น (ความแตกต่างระหว่าง  $y_i$  และ  $f(x)$ ) โดยความหมายของสมการ(4) คือ ค่าความคลาดเคลื่อนที่น้อยกว่าหรือเท่ากับ  $\epsilon$  ให้ถือว่าเป็นศูนย์และเป็นค่าความคลาดเคลื่อนที่ผู้ใช้งานยินยอมให้เกิดขึ้นได้ เช่นในกรณีการประยุกต์ใช้เพื่อทำนายผลผลิตข้าวกำหนดให้  $\epsilon = 0.001$  ก็หมายความว่าผู้พยากรณ์ยอมรับผลการพยากรณ์ในสองหลักแรก และถือว่าการพยากรณ์ในหลักที่ 3 ไม่ค่อยมีความสำคัญและคลาดเคลื่อนได้เท่ากับ 0.001 นั้นเอง

$$L(y_i, f(x)) = \begin{cases} 0 & \text{for } |y_i - f(x)| \leq \epsilon \\ |y_i - f(x)| - \epsilon & \text{otherwise} \end{cases} \quad (4)$$



ภาพที่ 2 การหาระนาบเกินที่เหมาะสมที่สุดสำหรับใช้แทนกลุ่มข้อมูลและการกำหนดแนวขอบระนาบเกินด้วยฟังก์ชัน  $\epsilon$ -Insensitive

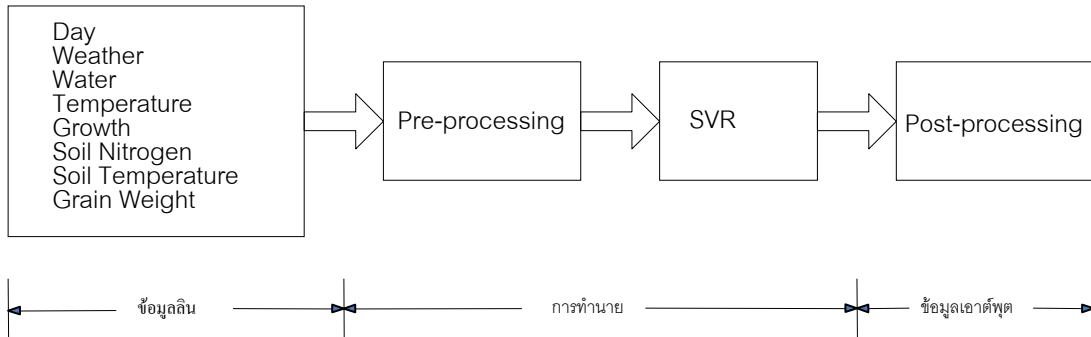
สถาปัตยกรรมของซัพพอร์ตเวกเตอร์แมชชีนสำหรับการถดถอยในกรณีนี้แสดงดังภาพที่ 3 เมื่อ  $y'$  คือค่าประมาณของ  $y$  ที่มีเวกเตอร์  $x$  เป็นลักษณะเด่น ซัพพอร์ตเวกเตอร์  $x_i$  เวกเตอร์น้ำหนัก  $\beta_i$  และ ค่าไบอัส ( $b$ ) ได้มาจากขั้นตอนการสอนซัพพอร์ตเวกเตอร์แมชชีน



ภาพที่ 3 สถาปัตยกรรมของซัพพอร์ตเวกเตอร์แมชชีนสำหรับการถดถอย

**วิธีการ**

ขั้นตอนในการทำการทำนายนี้ได้แบ่งออกเป็น 3 ส่วน คือ ส่วนของข้อมูลอินพุต (Input data) การทำนาย (Prediction) และส่วนของข้อมูลเอาต์พุต (Output data) ดังแสดงในภาพที่ 4



ภาพที่ 4 ขั้นตอนการทำนายผลผลิตของข้าว

**ข้อมูลอินพุต** คือ ข้อมูลผลผลิตของข้าวและปัจจัยในอดีตที่เกี่ยวข้อง โดยข้อมูลผลผลิตของข้าวในอดีตและปัจจุบันมีหน่วยกิโลกรัมต่อไร่ (kg/rai) ส่วนปัจจัยที่เกี่ยวข้องประกอบด้วย ข้อมูล ข้าวพันธุ์ กข. 23 ข้อมูลชุดดินสุพรรณบุรี วันที่จะทำการทำนาย สภาพอากาศ ปริมาณน้ำในดิน อุณหภูมิสะสม ปริมาณไนโตรเจน อุณหภูมิในดิน และข้อมูลผลผลิตของข้าวในวันที่ผ่านมา

**การทำนาย** งานวิจัยนี้ใช้ซัพพอร์ตเวกเตอร์แมชชีนสำหรับการถดถอย (Support Vector Regression: SVR) ในการพยากรณ์ และทำการเปรียบเทียบกับการพยากรณ์โดยใช้โครงข่ายประสาท (Neural Network: NN) ซัพพอร์ตเวกเตอร์แมชชีนสำหรับการถดถอยจะใช้ฟังก์ชันการสูญเสียแบบ  $\epsilon - Insensitive$  Loss Function และเลือกทดลองใช้ฟังก์ชันเคอร์เนล คือ ฟังก์ชันเรเดียลเบซิช (RBF Kernel Function) ในขั้นตอนการทำนายนี้จะมีการประมวลผลเบื้องต้น (Pre-Processing) เพื่อทำให้ข้อมูลสำหรับที่จะนำไปประมวลผลมีขนาดเล็กลง อยู่ในช่วงตั้งแต่

-1 ถึง +1 ทำให้เหมาะต่อการคำนวณ และเมื่อมีการประมวลผลเบื้องต้น จะต้องมีการประมวลผลตอนหลัง (Post-Processing) เพื่อแปลงข้อมูลที่มีขนาดน้อยๆ กลับมาเป็นข้อมูลจริง

**ข้อมูลเอาต์พุต** เป็นข้อมูลของผลผลิตที่ได้จากการทำนายในขั้นตอนนี้สิ่งสำคัญอีกประการคือ การหาค่าผิดพลาดจากการทำนาย งานวิจัยนี้ประเมินประสิทธิภาพอัลกอริทึมการพยากรณ์ คือ การหาค่าความผิดพลาดสัมบูรณ์เฉลี่ย (Mean Absolute Error: MAE)


#### การออกแบบการทดลองและการแสดงประสิทธิภาพของการทำนาย

##### การออกแบบการทดลอง


งานวิจัยนี้แบ่งข้อมูลออกเป็นสองส่วน คือ ชุดข้อมูลที่ใช้สำหรับการสอน(Training Set) หรือเรียนรู้ (Learning) และชุดข้อมูลที่ใช้สำหรับทดสอบประสิทธิภาพของระบบ (Test Set) การแบ่งข้อมูลออกเป็นสองส่วนนี้ เพื่อจะหาแบบจำลองที่ดีที่สุดสำหรับการทำนายโดยข้อมูลสำหรับสอนเป็นข้อมูลตั้งแต่ปี 1963 ถึงปี 1977 ระยะเวลา 15 ปี จำนวน  $10 \times 1375$  แซมเปิล (Samples) ส่วนข้อมูลสำหรับทดสอบเป็นข้อมูลปี 1978 จำนวน  $10 \times 87$  แซมเปิล

#### ผลการศึกษา

ในการทดสอบการทำนายผลผลิตข้าวกับชุดข้อมูลในปี 1978 นั้น ผลผลิตข้าวหลังการเก็บเกี่ยวที่ได้จากการทำนายมีความใกล้เคียงกับผลผลิตข้าวหลังการเก็บเกี่ยวที่ได้ในปี 1978 คือ ผลที่ได้จากการทำนายมีปริมาณน้อยกว่าผลผลิตที่ได้ในปี 1978 ไป 109.12 (kg/rai) และค่า MAE เท่ากับ 651.76 ดังภาพที่ 5 ส่วนผลที่ได้จากการทดสอบแบบ 10% cross validation นั้นได้ภาพที่ 6 ซึ่งค่า MAE เท่ากับ 240.24 ซึ่งค่าพารามิเตอร์ที่ใช้ในการเรียนรู้ คือ  $\varepsilon = 0.82$ ,  $C = 0.002$  และ  $\sigma = 15$



ภาพที่ 5 ผลที่ได้จากการทดสอบกับข้อมูลปี 1978



ภาพที่ 6 ผลที่ได้จากการทดสอบแบบ 10% cross validation

#### สรุป

ผลการทำนายผลผลิตข้าวนั้นประกอบไปด้วยชุดข้อมูลสำหรับการเรียนรู้ ประกอบไปด้วย ข้อมูลวัน ข้อมูลอากาศ ข้อมูลน้ำในดิน ข้อมูลอุณหภูมิสะสม ข้อมูลอุณหภูมิในดิน ข้อมูลไนโตรเจนในดินและ ข้อมูลผลผลิตข้าว ซึ่ง

เป็นข้อมูลในปี 1963 – 1977 ผลที่ได้คือการหาค่า MAE โดยการทำให้ 10% cross validation ได้ 240.24 และผลการทดสอบกับข้อมูลที่ไม่เคยเห็นมาก่อน (Blind Test Set) เท่ากับ 651.76

ซึ่งในแบบจำลองนี้ สามารถทำนายได้เฉพาะชั่วโมง กข. 23 และชุดดินสุพรรณบุรี เท่านั้น เนื่องจากในการทำการเรียนรู้ (Learning) ให้กับแบบจำลองนั้นทำเฉพาะชั่วโมง กข.23 และชุดดินสุพรรณบุรีเท่านั้น ดังนั้นถ้าหากต้องการให้แบบจำลองนี้สามารถทำนายชั่วโมงหลายพันธุและหลายชุดดินก็จำเป็นที่จะต้องมีส่วนข้อมูลที่จะสอนให้กับแบบจำลองที่หลากหลายขึ้น

### เอกสารอ้างอิง

สุนทร บุรณะวิริยะกุล และ เมธี เอกะสิงห์. 2535. การทดสอบแบบจำลอง CERES-Rice สำหรับผลผลิตข้าวในสภาพของเชียงใหม่. คณะเกษตรศาสตร์: มหาวิทยาลัยเชียงใหม่

T. Xu, R. He, P. Wang and D. Xu, "Input Dimension Reduction for Load Forecasting Based on Support Vector Machines," *Proceedings of the 2004 IEEE International Conference on Electric Utility deregulation, Restructuring and Power Technologies*, pp.510-514, Hong Kong, Apr.2004.

X.N. Dong, W. Qiang and L. Jin-Chao, "Short Term Load Forecasting Model Using Support Vector Machine Based on Artificial Neural Network," *Proceedings of Fourth International Conference on Machine Learning and Cybernetics*, pp.4260-4265, Guangzhou, Aug.2005.

K.R. Muller, A.J. Smola, G. Ratsch, B. Scholkopf, J. Kohlmorgen and V. Vapnik, "Predicting Time Series with Support Vector Machine," *Proceedings of ICANN'97, Springer LNCS 1327*, pp.999-1004, 1997.