

## บทที่ 6

### การสร้างแบบจำลองการทำนายปริมาณแฉ่งในหัวมันสำปะหลังสด

ปริมาณแฉ่งภายในหัวมันสำปะหลังสดเป็นตัวแปรหนึ่งที่มีความสำคัญอย่างมากในการซื้อขายมันสำปะหลังสด โดยค่าร้อยละของปริมาณแฉ่งในมันสำปะหลังสดจากการสุ่มตัวอย่างวัดด้วยเครื่องวัดปริมาณแฉ่ง จะถูกนำไปตีราคาในการซื้อขายที่จุดรับซื้อหน้าโรงงาน อีกทั้งปริมาณแฉ่งยังเป็นตัวแปรสำคัญในการคาดการณ์การผลิตแฉ่งมันสำปะหลังของโรงงานอุตสาหกรรม การพัฒนาแบบจำลองเพื่อทำนายปริมาณแฉ่งจึงมีความสำคัญอย่างมากต่อภาคการเกษตร และภาคอุตสาหกรรม

ในบทที่ 5 เป็นการศึกษาการใช้โครงข่ายประสาทเทียมในการทำนายน้ำหนักของหัวมันสำปะหลังสดภายในแปลงต่อหน่วยพื้นที่ ในบทนี้จะเป็นการศึกษาการใช้วิธีการเรียนรู้เชิงลึกโดยใช้แบบจำลองโครงข่ายประสาทเทียมสำหรับการทำนายปริมาณแฉ่งภายในหัวมันสำปะหลังสดภายในแปลงโดยใช้ค่าดัชนีพืชพรรณ NDVI แบบจำลองสำหรับการทำนายพัฒนาขึ้นด้วยการเขียนโปรแกรมภาษาไพธอน และการใช้ซอฟต์แวร์ MATLAB® R2018a เช่นเดียวกับการศึกษาที่ผ่านมา

#### 6.1 ผลการสร้างแบบจำลองด้วยการเขียนโปรแกรมภาษาไพธอน

ในการศึกษาการวิเคราะห์การถดถอยและสหสัมพันธ์ระหว่างดัชนีพืชพรรณกับปริมาณแฉ่งในหัวมันสำปะหลังสดในบทที่ 4 ผลการวิเคราะห์ค่าสหสัมพันธ์ไม่ได้อยู่ในระดับสูง เนื่องจากการวิเคราะห์ค่าสหสัมพันธ์เป็นการศึกษาแนวโน้มในแนวเส้นตรงเท่านั้น การศึกษานี้จึงใช้แบบจำลองการเรียนรู้เชิงลึกด้วยโครงข่ายประสาทเทียมเพื่อศึกษาความเป็นไปได้ในการทำนายปริมาณแฉ่งภายในหัวมันสำปะหลังสด

แบบจำลองในการศึกษานี้ถูกพัฒนาขึ้นเช่นเดียวกับแบบจำลองในบทที่ 5 โดยเป็นแบบจำลองโครงข่ายประสาทเทียมที่มีการปรับจำนวนชั้นซ่อนระหว่าง 1 ถึง 10 ชั้น ในแต่ละชั้นจะมีจำนวนโหนดเท่ากัน โดยมีการปรับจำนวนโหนดเป็น 8, 16, 32 และ 64 โหนดตามลำดับ การประมวลผลแบบจำลองมีรอบการประมวลผลสูงสุดที่ 1,500 Epochs และมีการประเมินผลแบบจำลองโดยใช้ค่า  $R^2$ , MSE และ RMSE ตามลำดับ โดยค่า RMSE มีหน่วยเป็น %

### 6.1.1 ผลการเปลี่ยนแปลงจำนวนโหนดของแบบจำลอง

การศึกษานี้เป็นการศึกษาผลของการเปลี่ยนแปลงจำนวนโหนดของแบบจำลองโครงข่ายประสาทเทียมแบบมีชั้นซ่อนเพียงชั้นเดียว เพื่อหาว่าจำนวนโหนดมีผลอย่างไรต่อค่าประสิทธิภาพในการทำนายของแบบจำลอง โดยประเมินจากค่า  $R^2$ , MSE และ RMSE ผลการประเมินประสิทธิภาพของแบบจำลองที่รอบการประมวลผล 500 1,000 และ 1,500 Epochs ด้วยข้อมูลชุดฝึกฝนและข้อมูลชุดทดสอบ แสดงได้ดังตารางที่ 6.1 และ ตารางที่ 6.2

ตารางที่ 6.1 ผลการศึกษาค่าดัชนี NDVI กับค่า  $R^2$  MSE และ RMSE กับการเปลี่ยนแปลงจำนวนโหนดของแบบจำลองสำหรับทำนายปริมาณน้ำด้วยข้อมูลชุดฝึกฝน

จำนวนโหนด	จำนวน Epochs	$R^2$	MSE	RMSE (%)
8	500	0.4008	4.9497	2.2248
	1,000	0.4098	5.1809	2.2762
	1,500	0.4090	5.0317	2.2431
16	500	0.4008	4.9615	2.2274
	1,000	0.4070	5.2209	2.2849
	1,500	0.4041	5.2320	2.2874
32	500	0.4014	5.0773	2.2533
	1,000	0.4050	4.8720	2.2073
	1,500	0.4097	5.2084	2.2822
64	500	0.4033	4.9272	2.2197
	1,000	0.4026	5.1435	2.2679
	1,500	0.4106	5.1514	2.2697

ตารางที่ 6.2 ผลการศึกษาค่าดัชนี NDVI กับค่า  $R^2$  MSE และ RMSE กับการเปลี่ยนแปลงจำนวน โหนดของแบบจำลองสำหรับทำนายปริมาณแบ่งด้วยข้อมูลชุดทดสอบ

จำนวนโหนด	จำนวน Epochs	$R^2$	MSE	RMSE (%)
8	500	0.3510	8.9323	2.9887
	1,000	0.3517	8.2306	2.8689
	1,500	0.3415	8.5769	2.9286
16	500	0.3534	8.7688	2.9612
	1,000	0.3416	8.7942	2.9655
	1,500	0.3615	6.3979	2.5294
32	500	0.3618	8.7360	2.9557
	1,000	0.3473	7.0308	2.6516
	1,500	0.3615	7.8318	2.7985
64	500	0.3681	7.7134	2.7773
	1,000	0.3457	7.1823	2.6800
	1,500	0.3457	7.1823	2.6800

จากตารางที่ 6.1 พบว่าการเพิ่มจำนวนโหนด และจำนวนรอบการประมวลผลส่งผลโดยตรงต่อประสิทธิภาพของแบบจำลองโดยแบบจำลองที่มี 64 โหนด ประมวลผลที่ 1,500 Epochs มีประสิทธิภาพสูงสุดที่มีค่า  $R^2$  เท่ากับ 0.4106 โดยค่า  $R^2$  มีแนวโน้มเพิ่มขึ้นตามความซับซ้อนของแบบจำลอง ขณะที่ค่าฟังก์ชันความสูญเสียของแบบจำลองมีค่าใกล้เคียงกัน และจากตารางที่ 6.2 พบว่าประสิทธิภาพของแบบจำลองโดยรวมมีค่าใกล้เคียงกันโดยมีค่า  $R^2$  ไม่เกิน 0.37 และมีค่า RMSE อยู่ในช่วง 2.60 – 3.00 % ซึ่งให้เห็นว่าแบบจำลองนี้ยังมีความผิดพลาดสูงในการทำนายปริมาณแบ่งในหัวมันสำปะหลังสด


ผลการศึกษาข้างต้นพบว่าจำนวนโหนดและจำนวนรอบการประมวลผลของแบบจำลองด้วยข้อมูลชุดฝึกฝนและข้อมูลชุดทดสอบมีประสิทธิภาพที่ใกล้เคียงกัน โดยข้อมูลชุดฝึกฝนมีประสิทธิภาพสูงกว่าข้อมูลชุดทดสอบ โดยเมื่อพิจารณาประสิทธิภาพของแบบจำลองโครงข่ายประสาทเทียมในการศึกษานี้มีความแม่นยำค่อนข้างต่ำและมีฟังก์ชันความสูญเสียสูง อาจเนื่องมาจากแบบจำลองยังมีความซับซ้อนที่ไม่เหมาะสมเพียงพอต่อชุดข้อมูลที่ใช้ในการศึกษา หรือแบบจำลองนี้มีความเหมาะสมกับข้อมูลต่ำเกินไป

เพื่อแก้ปัญหาความเหมาะสมกับข้อมูลต่ำเกินไป การเพิ่มจำนวนชั้นซ่อนของแบบจำลองโดยการเพิ่มจำนวนชั้นซ่อน อาจทำให้แบบจำลองมีความเหมาะสมกับชุดข้อมูลที่มีความสัมพันธ์แบบไม่เชิงเส้นได้ (กอบเกียรติ สระอุบล, 2565; เจริญ, 2566) การศึกษาในหัวข้อนี้เป็นหาแบบจำลองที่มีจำนวนโหนดและจำนวนรอบการประมวลผลสูงที่สุดกับชุดข้อมูล หัวข้อถัดไปเป็นการใช้แบบจำลองที่มีการกำหนดจำนวนโหนดที่ 64 โหนด และมีจำนวนรอบประมวลผลที่ 1,500 Epochs จากการศึกษา


### 6.1.2 ผลการเปลี่ยนแปลงจำนวนชั้นซ่อนของแบบจำลอง

การแก้ไขปัญหาความเหมาะสมกับข้อมูลต่ำเกินไปของแบบจำลองทำได้โดยการเพิ่มความซับซ้อนของแบบจำลอง ในการศึกษาจะเป็นการเพิ่มจำนวนชั้นซ่อนภายในโครงสร้างของโครงข่ายประสาทเทียมเพื่อหาว่าโครงสร้างของแบบจำลองที่มีความซับซ้อนเท่าใดมีความเหมาะสมมากที่สุดในการทำนายปริมาณแอมป์ในหัวมันสำปะหลังสด

การศึกษานี้เป็นการศึกษาผลของการเปลี่ยนแปลงจำนวนชั้นซ่อนของแบบจำลองโครงข่ายประสาทเทียมแบบหลายชั้นระหว่าง 1-10 ชั้นซ่อน เพื่อหาจำนวนชั้นซ่อนที่เหมาะสมต่อการทำนายปริมาณแอมป์ภายในหัวมันสำปะหลังสดที่มีการกำหนดจำนวนโหนดจากการศึกษาก่อนหน้าคือ 64 โหนดในแต่ละชั้นซ่อน โดยประเมินประสิทธิภาพในการทำนายของแบบจำลองด้วยค่า  $R^2$  และ MSE โดยผลการประเมินประสิทธิภาพของแบบจำลองที่รอบการประมวลผล 1,500 Epochs แสดงได้ดังรูปที่ 6.1 และ 6.2



รูปที่ 6.1 ความสัมพันธ์ระหว่างการเปลี่ยนแปลงจำนวนชั้นซ่อนต่อค่า MSE



รูปที่ 6.2 ความสัมพันธ์ระหว่างการเปลี่ยนแปลงจำนวนชั้นซ่อนต่อค่า  $R^2$


จากรูปที่ 6.1 ค่า MSE ของแบบจำลองที่ข้อมูลชุดฝึกฝนมีแนวโน้มลดลงตามความซับซ้อนของแบบจำลองโดยแบบจำลองที่มีความซับซ้อนมากหรือมีจำนวนชั้นซ่อนมากจะส่งผลให้ค่า MSE มีค่าลดลง ขณะที่ข้อมูลชุดทดสอบพบว่าค่า MSE ของแบบจำลองมีแนวโน้มลดลงที่ 1 – 3 ชั้นซ่อนแรกก่อนที่จะเพิ่มขึ้นที่ชั้นซ่อนที่ 4 เป็นต้นไป และที่รูปที่ 6.2 ค่า  $R^2$  ของแบบจำลองมีแนวโน้มเพิ่มขึ้นที่ข้อมูลชุดฝึกฝนและข้อมูลชุดทดสอบ จากแนวโน้มพบว่าการฝึกฝนแบบจำลองที่ข้อมูลชุดฝึกฝนแบบจำลองยังมีความซับซ้อนมากจะทำให้มีความแม่นยำมากหรือมีค่า  $R^2$  มากขึ้น และมีค่าความผิดพลาดในการทำนาย MSE น้อยลง ขณะเดียวกันที่ข้อมูลชุดทดสอบค่า  $R^2$  จะเพิ่มขึ้นแต่ค่าความผิดพลาดอาจเพิ่มขึ้นตามไปด้วยส่งผลให้ค่า MSE มีค่าสูงขึ้น การที่แบบจำลองสามารถทำงานได้ที่ข้อมูลชุดฝึกฝนแต่มีความผิดพลาดมากในข้อมูลชุดทดสอบบ่งบอกถึงการเกิดความเหมาะสมกับข้อมูลมากเกินไป

### 6.1.3 ผลการเพิ่มประสิทธิภาพของแบบจำลอง

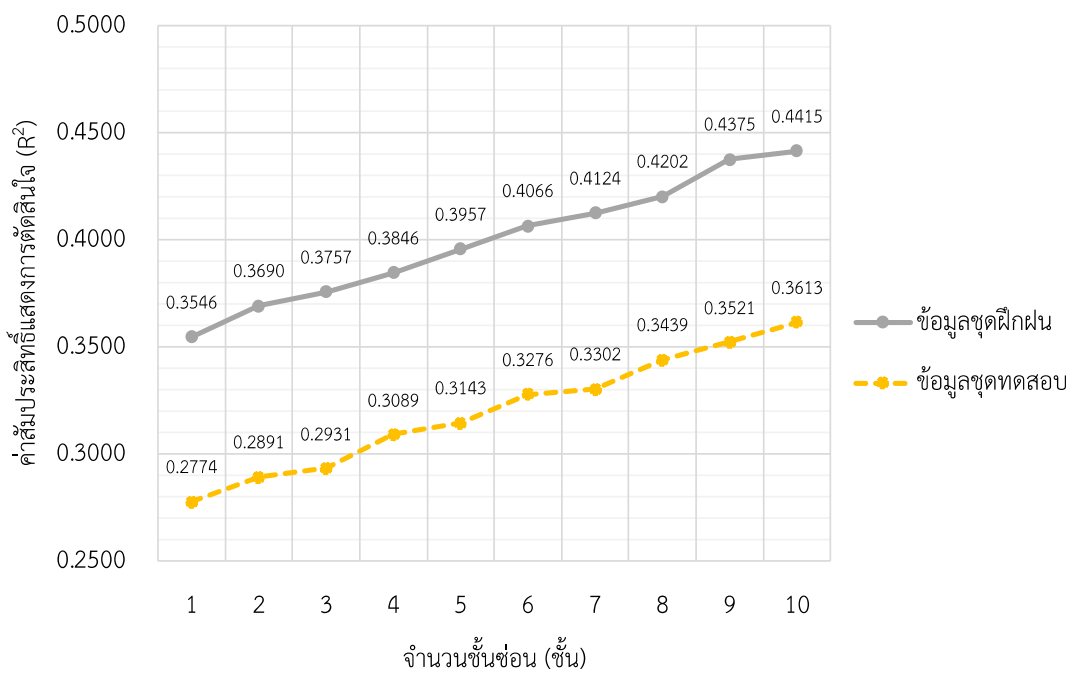
ในบทที่ 5 การแก้ปัญหาแบบจำลองมีความเหมาะสมกับข้อมูลชุดฝึกฝนมากเกินไปสามารถทำได้โดยการทำการเร็กคิวลาไรซ์เซชัน (ณัฐโชติ พรหมฤทธิ์ และสัจจาภรณ์ ไวจรรยา, 2564) โดยในงานวิจัยนี้เลือกใช้เทคนิคการวิเคราะห์สัญญาณตกท้ายที่ร้อยละ 20 การศึกษาในส่วนนี้เป็นการศึกษาเพื่อหาจำนวนชั้นซ่อนที่เหมาะสมที่สุดในการทำนายปริมาณแป้งในหัวมันสำปะหลังจากแบบจำลองโครงข่ายประสาทเทียมแบบหลายใช้ที่มีการใช้เทคนิคการวิเคราะห์สัญญาณตกท้าย ผลการวิเคราะห์แสดงได้ดังรูปที่ 6.3 สำหรับการประเมินด้วยค่า MSE และรูปที่ 6.4 สำหรับการประเมินด้วยค่า  $R^2$

จากรูปที่ 6.3 ความสัมพันธ์ระหว่างค่า MSE กับจำนวนชั้นซ่อนของแบบจำลองพบว่าหากแบบจำลองมีความซับซ้อนมากขึ้นค่า MSE จะมีค่าลดลงด้วย และจากรูปที่ 6.4 ความสัมพันธ์ระหว่างค่า  $R^2$  กับจำนวนชั้นซ่อนเป็นไปในทางเดียวกันคือ ยิ่งจำนวนชั้นซ่อนมากค่า  $R^2$  จะยิ่งมีค่ามากขึ้นไปด้วย

จากขอบเขตการกำหนดโครงสร้างของแบบจำลองในการศึกษานี้แบบจำลองโครงข่ายประสาทเทียมที่มีจำนวนชั้นซ่อน 10 ชั้นซ่อนมีประสิทธิภาพในการทำนายสูงสุด โดยมีค่า  $R^2$  เท่ากับ 0.4415 และ 0.3613 และมีค่า MSE เท่ากับ 2.6909 และ 4.0405 สำหรับข้อมูลชุดฝึกฝนและข้อมูลชุดทดสอบตามลำดับ



รูปที่ 6.3 ความสัมพันธ์ระหว่างการเปลี่ยนแปลงจำนวนชั้นซ้อนต่อค่า MSE



รูปที่ 6.4 ความสัมพันธ์ระหว่างการเปลี่ยนแปลงจำนวนชั้นซ้อนต่อค่า  $R^2$

#### 6.1.4 สรุปผลการศึกษา

การพัฒนาแบบจำลองโครงข่ายประสาทเทียมแบบหลายชั้นด้วยการเขียนโปรแกรมภาษาไพธอนในการศึกษานี้ แบบจำลองที่มีจำนวนชั้นซ่อน 10 ชั้นซ่อน มีความเหมาะสมมากที่สุดในการใช้ในการทำนายปริมาณแป้งในหัวมันสำปะหลังสดสำหรับการศึกษานี้ จากผลการศึกษาและเปรียบเทียบก่อนและภายหลังจากการใช้เทคนิคการวิเคราะห์สัญญาณตกหายแสดงดังตารางที่ 6.3 พบว่าที่ข้อมูลชุดฝึกฝนแบบจำลองมีความแม่นยำที่ 0.4911 และ 0.3613 ก่อนและหลังการปรับปรุงประสิทธิภาพตามลำดับ โดยสามารถแสดงค่าความผิดพลาดในการทำนายได้เท่ากับ 2.9833% และ 2.0101% ตามลำดับ ผลการศึกษานี้แสดงให้เห็นว่าแบบจำลองยังมีความแม่นยำที่ไม่เพียงพอต่อการทำนายปริมาณแป้งในหัวมันสำปะหลังสดจึงควรที่จะมีการปรับปรุงแบบจำลองโดยใช้แบบจำลองอื่นที่ใช้เทคนิคต่างกันออกไป

ตารางที่ 6.3 ผลการเปรียบเทียบค่า  $R^2$  MSE และ RMSE ของแบบจำลองสำหรับทำนายปริมาณแป้งก่อนและหลังการวิเคราะห์สัญญาณตกหาย

Regularization	ชุดข้อมูล	$R^2$	MSE	RMSE (%)
ไม่มี	ชุดฝึกฝน	0.4852	3.3740	1.8368
	ชุดทดสอบ	0.4911	8.9000	2.9833
Dropout=0.2	ชุดฝึกฝน	0.4415	2.6909	1.6404
	ชุดทดสอบ	0.3613	4.0405	2.0101

## 6.2 การสร้างแบบจำลองโดยใช้ซอฟต์แวร์ MATLAB

การศึกษานี้ใช้ข้อมูลดัชนีพืชพรรณ NDVI เป็นข้อมูลนำเข้า และใช้ข้อมูลปริมาณแป้งในมันสำปะหลังเป็นข้อมูลส่งออก โดยการศึกษานี้มีการกำหนดอัลกอริทึมที่ใช้ในการประมวลผล 3 ชนิด ได้แก่ SCG, LM และ BR เพื่อหาแบบจำลองที่มีความเหมาะสมกับการทำนายปริมาณแป้งมากที่สุดจึงมีการปรับปรุงจำนวนชั้นซ่อนของแบบจำลองระหว่าง 1 ถึง 10 ชั้นซ่อน และประเมินด้วยค่า  $R^2$  และค่าฟังก์ชันความสูญเสียได้แก่ MSE และ RMSE เพื่อหาแบบจำลองที่มีความเหมาะสมมากที่สุด

### 6.2.1 ผลการเปลี่ยนแปลงชนิดอัลกอริทึมของแบบจำลอง

เช่นเดียวกับการศึกษาในบทก่อนหน้าการศึกษานี้เป็นการประเมินประสิทธิภาพของแบบจำลองโครงข่ายประสาทเทียมที่มี 1 ชั้นซ่อน เพื่อหาว่าการเปลี่ยนแปลงชนิดของอัลกอริทึมในการประมวลผลส่งผลอย่างไรต่อประสิทธิภาพของแบบจำลอง ความถูกต้องแม่นยำในการประมวลผล



โดยใช้ค่า  $R^2$  และค่าฟังก์ชันความสูญเสีย ได้แก่ MSE และ RMSE ผลการประเมินประสิทธิภาพของแบบจำลองด้วยข้อมูลชุดฝึกฝนแสดงได้ดังตารางที่ 6.4

ตารางที่ 6.4 การประเมินประสิทธิภาพของแบบจำลองโครงข่ายประสาทเทียมด้วยข้อมูลชุดฝึกฝน

อัลกอริทึม	จำนวน Iterations	$R^2$	MSE	RMSE (%)
Levenberg-Marquardt (LM)	10	0.6939	1.5354	1.2391
Scaled conjugate gradient (SCG)	26	0.6856	1.6633	1.2897
Bayesian regularization (BR)	31	0.6834	1.4772	1.2154

จากตารางที่ 6.4 แสดงจำนวนรอบในการวนซ้ำสำหรับประมวลผลที่ทำให้แบบจำลองมีประสิทธิภาพสูงสุด เมื่อพิจารณาที่ความเร็วในการประมวลผล LM มีประสิทธิภาพสูงสุดที่ 10 Iterations ขณะที่ BR มีจำนวนรอบการวนซ้ำมากที่สุดที่ 31 Iterations เมื่อพิจารณาค่า  $R^2$  ของแบบจำลองที่ข้อมูลชุดฝึกฝนแบบจำลองที่ใช้อัลกอริทึม LM มีค่า  $R^2$  สูงสุดที่ 0.6939 มีค่า MSE เท่ากับ 1.5345 และมีค่า RMSE เท่ากับ 1.2391% ตามลำดับ

การพิจารณาประสิทธิภาพของแบบจำลองจำเป็นต้องมีการพิจารณาที่ข้อมูลชุดทดสอบด้วย เพื่อให้มั่นใจว่าแบบจำลองสามารถทำงานได้ดีบนข้อมูลชุดที่ไม่เคยใช้ในการฝึกฝนมาก่อนหรือไม่ ตารางที่ 6.5 แสดงผลการประเมินประสิทธิภาพของแบบจำลองด้วยข้อมูลชุดฝึกฝน ชุดตรวจสอบ และชุดทดสอบ

ตารางที่ 6.5 การประเมินประสิทธิภาพของแบบจำลองโครงข่ายประสาทเทียมในแต่ละชุดข้อมูล


ชุดข้อมูล	อัลกอริทึม	$R^2$	MSE	RMSE (%)
ชุดฝึกฝน	SCG	0.6856	1.6633	1.2897
	LM	0.6939	1.5354	1.2391
	BR	0.6834	1.4772	1.2154
ชุดทดสอบ	SCG	0.5998	1.9694	1.4033
	LM	0.5068	2.7743	1.6656
	BR	0.6069	2.6801	1.6371
ชุดตรวจสอบ	SCG	0.6298	1.0395	1.0195
	LM	0.7048	0.9224	0.9604

จากตารางที่ 6.5 พบว่าที่ข้อมูลชุดตรวจสอบ แบบจำลองที่ใช้อัลกอริทึม LM มีค่า  $R^2$  สูงที่สุดที่ 0.7048 และมีค่ามากกว่า SCG ขณะที่ค่า MSE ของแบบจำลองพบว่า SCG มีค่าสูงกว่าเล็กน้อยที่ 1.0395 ขณะที่ข้อมูลชุดทดสอบแบบจำลองที่ใช้อัลกอริทึม LM มีประสิทธิภาพต่ำที่สุดโดยมีค่า  $R^2$  เท่ากับ 0.5068 และ MSE สูงที่สุดที่ 2.7743 ขณะที่อัลกอริทึม BR ให้ประสิทธิภาพสูงที่สุดที่  $R^2$  เท่ากับ 0.6069 และ MSE เท่ากับ 2.6801 อย่างไรก็ตามผลการศึกษานี้แบบจำลองมีความแม่นยำไม่สูงนัก และมีค่าความผิดพลาดค่อนข้างสูงเมื่อพิจารณาจากขอบเขตในการศึกษา การปรับปรุงแบบจำลองให้มีประสิทธิภาพสูงขึ้นอาจทำได้โดยการเพิ่มความซับซ้อนให้แก่แบบจำลอง การศึกษาต่อไปเป็นการศึกษาประสิทธิภาพของแบบจำลองที่มีการปรับจำนวนชั้นซ่อนระหว่าง 1-10 ชั้นซ่อน

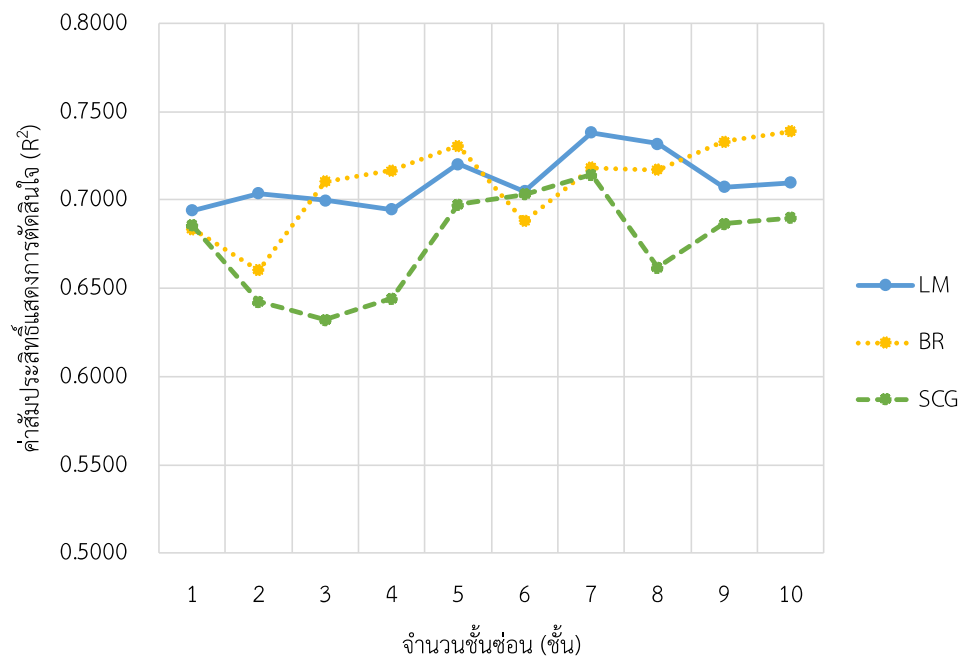
### 6.2.2 ผลการเปลี่ยนแปลงจำนวนชั้นซ่อนของแบบจำลอง

เช่นเดียวกับการศึกษาก่อนหน้าเรื่องการปรับปรุงจำนวนชั้นซ่อนเพื่อเพิ่มประสิทธิภาพของแบบจำลองการศึกษาในส่วนนี้จึงเป็นการประเมินประสิทธิภาพของแบบจำลองที่มีการปรับปรุงจำนวนชั้นซ่อนระหว่าง 1 ถึง 10 ชั้นซ่อน ผลการประเมินประสิทธิภาพของแบบจำลองหลังการปรับปรุงจำนวนชั้นซ่อนของแบบจำลองด้วยข้อมูลชุดฝึกฝนแสดงได้ดังรูปที่ 6.5 และรูปที่ 6.6 สำหรับข้อมูลชุดทดสอบแสดงได้ดังรูปที่ 6.7 และรูปที่ 6.8


สำหรับข้อมูลชุดฝึกฝนแบบจำลองที่ใช้อัลกอริทึม LM มีแนวโน้มของค่า MSE ต่ำกว่าอัลกอริทึม BR และ SCG โดยแบบจำลองอัลกอริทึม LM ที่มีจำนวนชั้นซ่อนจำนวน 8 ชั้นซ่อนมีค่า MSE ต่ำที่สุดแสดงดังรูปที่ 6.5 สำหรับค่า  $R^2$  ของแบบจำลองพบว่าอัลกอริทึม LM มีแนวโน้มที่มีค่า  $R^2$  สูงกว่าอัลกอริทึมอื่นโดยมีค่าสูงที่สุดที่ 7 ชั้นซ่อนแสดงดังรูปที่ 6.6 สำหรับข้อมูลชุดทดสอบอัลกอริทึม LM ยังคงมีประสิทธิภาพสูงกว่าอัลกอริทึมอื่นโดยมีแนวโน้มที่ค่า MSE จะลดลงเมื่อจำนวนชั้นซ่อนมากขึ้นดังรูปที่ 6.7 และมีค่า  $R^2$  เพิ่มขึ้นเมื่อเพิ่มจำนวนชั้นซ่อนดังรูปที่ 6.8 อย่างไรก็ตามแบบจำลองยังมีค่าประสิทธิภาพใกล้เคียงกันมากในบางชั้นซ่อนจึงทำให้ไม่อาจตัดสินได้ว่าแบบจำลองที่มีโครงสร้างแบบใดมีความเหมาะสมที่สุด การพิจารณาจากชุดข้อมูลทั้งหมดจึงเป็นหนึ่งในแนวทางการประเมินประสิทธิภาพของแบบจำลองโดยภาพรวมรูปที่ 6.9 แสดงผลการประเมินความแม่นยำของแบบจำลอง ( $R^2$ ) ที่ชุดข้อมูลทั้งหมด




รูปที่ 6.5 การประเมินประสิทธิภาพของแบบจำลองด้วยข้อมูลชุดฝึกฝนด้วยค่า MSE




รูปที่ 6.6 การประเมินประสิทธิภาพของแบบจำลองด้วยข้อมูลชุดฝึกฝนด้วยค่า  $R^2$



รูปที่ 6.7 การประเมินประสิทธิภาพของแบบจำลองด้วยข้อมูลชุดทดสอบด้วยค่า MSE



รูปที่ 6.8 การประเมินประสิทธิภาพของแบบจำลองด้วยข้อมูลชุดทดสอบด้วยค่า R<sup>2</sup>




รูปที่ 6.9 การประเมินประสิทธิภาพของแบบจำลองด้วยข้อมูลทั้งหมดด้วยค่า  $R^2$

จากรูปที่ 6.9 พบว่าแบบจำลองที่มีจำนวนชั้นซ้อนที่ 10 ชั้นซ้อนโดยภาพรวมมีแนวโน้มที่ให้ค่า  $R^2$  สูงสุด โดยอัลกอริทึม BR ให้ค่า  $R^2$  มากที่สุดที่ 0.7242 ใกล้เคียงกับอัลกอริทึม LM ที่ 0.7217 ทั้งนี้หากพิจารณาการเพิ่มขึ้นของจำนวนชั้นซ้อนจะพบว่ายิ่งแบบจำลองมีความซับซ้อนมาก ความแม่นยำของแบบจำลองจะยิ่งเพิ่มขึ้นมาก แต่อย่างไรก็ตามหากพิจารณาการขอบเขตการศึกษาแบบจำลองนี้ยังมีความแม่นยำที่ค่อนข้างต่ำและมีความผิดพลาดในการทำนายผลค่อนข้างสูง โดย  $R^2$  มีค่าต่ำกว่า 0.80 และ MSE มีค่าสูงกว่า 0.01 ตารางที่ 6.6 แสดงผลการประเมินประสิทธิภาพของแบบจำลองด้วยข้อมูลชุดทดสอบเทียบกับข้อมูลทั้งหมดที่ 10 ชั้นซ้อน


ตารางที่ 6.6 การประเมินประสิทธิภาพของแบบจำลองด้วยข้อมูลชุดทดสอบกับข้อมูลทั้งหมด

ชุดข้อมูล	อัลกอริทึม	R <sup>2</sup>	MSE	RMSE (%)
ชุดทดสอบ	SCG	0.7885	0.8847	0.9406
	LM	0.6066	2.1783	1.4759
	BR	0.7594	1.2335	1.1106
ข้อมูลทั้งหมด	SCG	0.6970	1.5123	1.2298
	LM	0.7217	1.4642	1.2100
	BR	0.7242	1.3101	1.1446

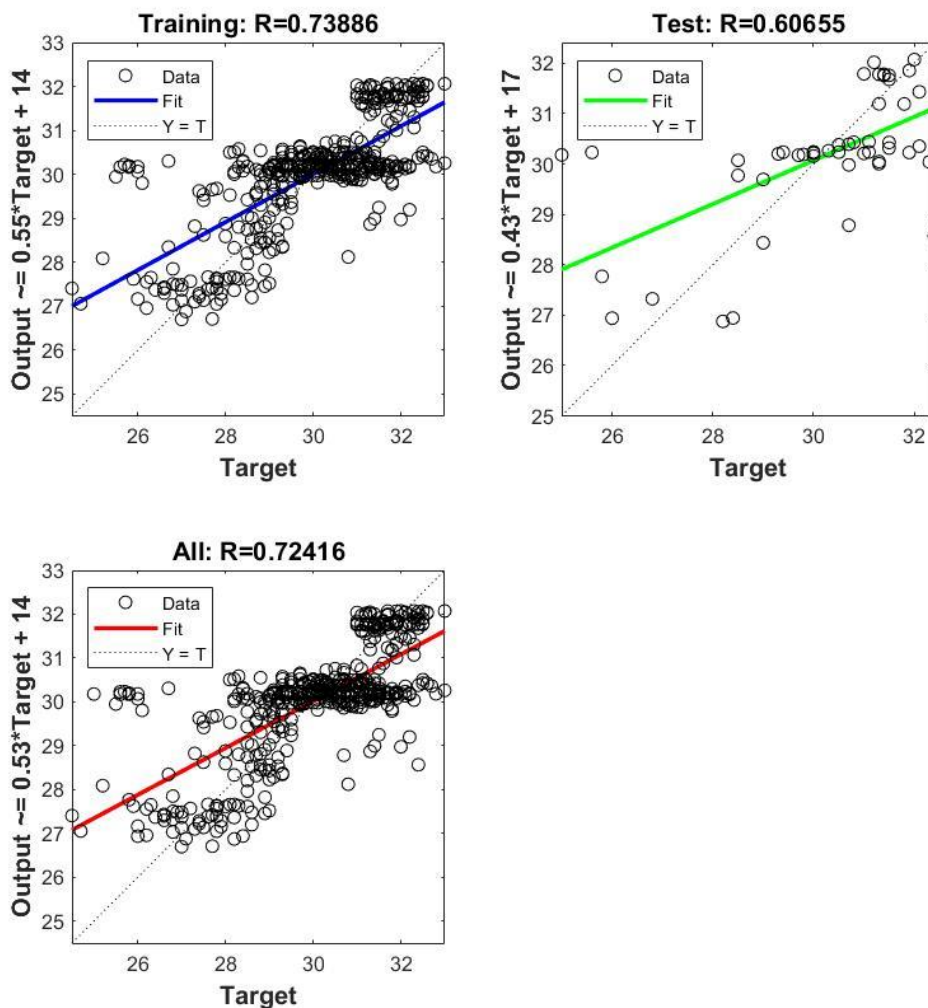
การผลการศึกษาในตารางที่ 6.6 ที่สุดเมื่อพิจารณาจากการใช้ข้อมูลชุดทดสอบแบบจำลองที่ใช้อัลกอริทึม SCG มีประสิทธิภาพสูงที่สุด กล่าวคือมีค่า R<sup>2</sup> สูงที่สุดเท่ากับ 0.7885 มีค่า MSE ต่ำสุดที่ข้อมูลทั้งหมดเท่ากับ 0.8847 และมีค่า RMSE ต่ำที่สุดที่ 0.9406% ในขณะที่อัลกอริทึม BR มีประสิทธิภาพดีที่สุดเมื่อพิจารณาจากการใช้ข้อมูลทั้งหมดโดยมีค่า R<sup>2</sup> สูงที่สุดที่ข้อมูลทั้งหมดเท่ากับ 0.7242 มีค่า MSE ต่ำสุดที่ข้อมูลทั้งหมดเท่ากับ 1.3101 และมีค่า RMSE ต่ำที่สุดที่ 1.1446% ในรูปที่ 6.10 รูปที่ 6.11 และรูปที่ 6.12 แสดงค่า MSE ค่า Error และ Fit regression ระหว่างการฝึกฝนแบบจำลองอัลกอริทึม BR ตามลำดับ



รูปที่ 6.10 ค่า MSE ของแบบจำลองที่ใช้อัลกอริทึม BR



รูปที่ 6.11 ความต่างระหว่างค่าข้อมูลจริงและค่าจากการทำนายของแบบจำลอง




รูปที่ 6.12 การถดถอยของแบบจำลองในข้อมูลชุดต่าง ๆ

### 6.3 ผลการทำนายปริมาณแบ่งจากแบบจำลอง

การศึกษาพบว่าการใช้ซอฟต์แวร์ MATLAB® R2018a ในการทำนายปริมาณแบ่งนี้เป็นการหาแบบจำลองที่มีความเหมาะสมที่สุดในการทำนายปริมาณแบ่งจากค่าดัชนีพืชพรรณ โดยพิจารณาจากค่า  $R^2$  รูปที่ 6.13 เป็นการเปรียบเทียบเทียบค่าน้ำหนักของปริมาณแบ่งในหัวมันสำปะหลังจากการเก็บในแปลงตัวอย่างกับค่าปริมาณแบ่งจากการทำนายด้วยแบบจำลองโครงข่ายประสาทเทียมแบบหลายชั้นซ่อนที่มี 10 ชั้นซ่อนของ 3 อัลกอริทึม





รูปที่ 6.13 การเปรียบเทียบค่าปริมาณน้ำในหัวมันสำปะหลังสดจากข้อมูลจริงภายในแปลงกับข้อมูลจากการทำนายโดยการใช้อัลกอริทึม SCG LM และ BR

#### 6.4 สรุปผลการวิจัย

การศึกษาในบทนี้เช่นเดียวกับบทก่อนหน้าคือเป็นการศึกษาการใช้ค่าดัชนีพืชพรรณ NDVI ในการทำนายปริมาณน้ำในหัวมันสำปะหลังสดภายในแปลง (%) โดยใช้แบบจำลองโครงข่ายประสาทเทียมแบบหลายชั้นที่พัฒนาขึ้นจากการเขียนโปรแกรมภาษาไพธอน และซอฟต์แวร์ MATLAB © R2018a การประเมินประสิทธิภาพของแบบจำลองใช้ค่า MSE และค่า  $R^2$  คำนวณหาค่า RMSE เพื่อแปลงออกมาเป็นค่าความคลาดเคลื่อนในหน่วย (%) ชุดข้อมูลในการศึกษาถูกแบ่งออกเป็นข้อมูลชุดฝึกฝน ข้อมูลชุดทดสอบ และข้อมูลชุดตรวจสอบ โดยจะพิจารณาจากแนวโน้มของข้อมูลชุดฝึกฝน และข้อมูลชุดทดสอบ

ในการพิจารณาความเหมาะสมของแบบจำลองจะพิจารณาจากค่า MSE และ  $R^2$  โดยกำหนดขอบเขตที่ค่า MSE ไม่สูงกว่า 0.01 หรือมีความคลาดเคลื่อนในหน่วยพื้นที่ RMSE เท่ากับ 0.1 % และมีค่า  $R^2$  ไม่ต่ำกว่า 0.80 จากขอบเขตดังกล่าวไม่มีแบบจำลองใดในการศึกษานี้ให้ประสิทธิภาพสูงถึงเกณฑ์ที่กำหนด เนื่องจากการศึกษาก่อนหน้านี้ในบทที่ 4 พบว่าข้อมูลปริมาณน้ำในหัวมันสำปะหลังมีค่าสหสัมพันธ์กับค่าดัชนีพืชพรรณที่ใช้ในการทำนายอยู่ในเกณฑ์ปานกลางถึงต่ำ โดยแบบจำลองที่มีประสิทธิภาพสูงที่สุดคือแบบจำลองที่พัฒนาบนซอฟต์แวร์ MATLAB โดยใช้อัลกอริทึม BR ที่มีการ

กำหนดจำนวนชั้นซ้อนที่ 10 ชั้นซ้อน ความคาดเคลื่อนในการทำนายมีค่าเท่ากับ 1.1446% ขณะที่แบบจำลองที่พัฒนาจากการเขียนโปรแกรมภาษาไพธอนมีค่าความคาดเคลื่อนเท่ากับ 1.6371%

การศึกษาเรื่องการทำนายปริมาณแป้งในหัวมันสำปะหลังสดนี้เป็นก้าวแรกในการประเมินปริมาณแป้งโดยใช้ภาพถ่ายจากอากาศยานไร้คนขับสำหรับการทำนายปริมาณผลผลิตใต้ดินด้วยเทคโนโลยีการประมวลผลภาพถ่ายแบบหลายช่วงคลื่นในการสกัดค่าดัชนีพืชพรรณที่ใช้ในการบ่งบอกสุขภาพของพืชจากการสะท้อนแสงของใบ อย่างไรก็ตามการเปลี่ยนแปลงปริมาณแป้งในหัวมันสำปะหลังสดใต้ดินยังมีปัจจัยทางสภาพแวดล้อมที่เกี่ยวข้อง อาทิ ความชื้น ปริมาณธาตุอาหาร และศัตรูพืช ปัจจัยเหล่านี้เองเป็นหนึ่งในสาเหตุที่ทำให้แบบจำลองมีประสิทธิภาพไม่สูงมากนักและยังมีความผิดพลาดอยู่อีกมาก การพัฒนาแบบจำลองในการทำนายในการศึกษาหน้าควรมีการเก็บข้อมูลปัจจัยที่หลากหลายร่วมกับการเก็บข้อมูลในสภาพแวดล้อมที่แตกต่างออกไปเพื่อให้ได้แบบจำลองการเรียนรู้เชิงลึกที่มีประสิทธิภาพสูงเหมาะแก่การใช้งานในทุกสภาพแวดล้อมต่อไป