

การทำนายจำนวนรอบการปั่นผสมของใบพัดหลักในกระบวนการผสมเปียกโดยใช้โครงข่ายประสาท  
เทียมและสมการถดถอยประเภทซัพพอร์ตเวกเตอร์



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต  
สาขาวิชาวิศวกรรมอุตสาหการ ภาควิชาวิศวกรรมอุตสาหการ  
คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย  
ปีการศึกษา 2562  
ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

PREDICTION MODEL FOR IMPELLER REVOLUTION IN WET GRANULATION PROCEDURE  
USING ARTIFICIAL NEURAL NETWORK AND SUPPORT VECTOR REGRESSION



Mr. Boonyasith Chamnanthongpaivanh

จุฬาลงกรณ์มหาวิทยาลัย  
**CHULALONGKORN UNIVERSITY**

A Thesis Submitted in Partial Fulfillment of the Requirements  
for the Degree of Master of Engineering in Industrial Engineering

Department of Industrial Engineering

FACULTY OF ENGINEERING

Chulalongkorn University

Academic Year 2019

Copyright of Chulalongkorn University

หัวข้อวิทยานิพนธ์	การทำนายจำนวนรอบการปั่นผสมของใบพัดหลักใน กระบวนการผสมเปียกโดยใช้โครงข่ายประสาทเทียมและ สมการถดถอยประเภทซัพพอร์ตเวกเตอร์
โดย	นายบุญญสิทธิ์ ชำนาญทองไพวัลย์
สาขาวิชา	วิศวกรรมอุตสาหการ
อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก	ผู้ช่วยศาสตราจารย์ ดร.โอฬาร กิตติธีรพรชัย

---

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้บัณฑิตวิทยาลัยเป็นส่วนหนึ่ง  
ของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต

..... คณบดีคณะวิศวกรรมศาสตร์  
(รองศาสตราจารย์ ดร.ปวีณา เชาวลิทวงศ์)

คณะกรรมการสอบวิทยานิพนธ์

..... ประธานกรรมการ  
(รองศาสตราจารย์ ดร.วิภาวี ธรรมาภรณ์พิลาศ)

..... อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก  
(ผู้ช่วยศาสตราจารย์ ดร.โอฬาร กิตติธีรพรชัย)

..... กรรมการ  
(รองศาสตราจารย์ ดร.อังศุมาลิน เสนจันทร์ดีไชย)

..... กรรมการภายนอกมหาวิทยาลัย  
(รองศาสตราจารย์ ดร.เจริญชัย โขมพัตราภรณ์)

บุญญสิษฐ์ ชำนาญทองไพวัลท์ : การทำนายจำนวนรอบการปั่นผสมของใบพัดหลักในกระบวนการผสมเปียกโดยใช้โครงข่ายประสาทเทียมและสมการถดถอยประเภทซัพพอร์ตเวกเตอร์. ( PREDICTION MODEL FOR IMPELLER REVOLUTION IN WET GRANULATION PROCEDURE USING ARTIFICIAL NEURAL NETWORK AND SUPPORT VECTOR REGRESSION) อ.ที่ปรึกษาหลัก : ผศ. ดร.โอฬาร กิตติธีรพรชัย

วิธีการผสมเปียกเป็นวิธีที่ใช้กันมากในการผลิตยาเม็ดระดับอุตสาหกรรมเนื่องด้วยสามารถปรับปรุงคุณภาพการตอกอัดด้วยกระบวนการผสมเชิงกลระหว่างสารละลายยิดเกาะและผงส่วนประกอบยาในซามผสม หรือ การผสมเปียก การผสมเปียกเป็นกระบวนการที่ส่งผลกระทบต่อคุณภาพของยาเม็ดมากที่สุดอีกทั้งพารามิเตอร์ที่เกี่ยวข้องยังแตกต่างกันตามสูตรตำรับและเครื่องผสมเปียกตั้งเช่นโรงงานกรณีศึกษาซึ่งใช้ประสบการณ์และการลองผิดลองถูกในการประเมินเวลาการผสม งานวิทยานิพนธ์มีเป้าหมายเพื่อประยุกต์การใช้แนวคิดโครงข่ายประสาทเทียมและสมการถดถอยประเภทซัพพอร์ตเวกเตอร์ในการทำนายจำนวนรอบปั่นผสมของใบพัดหลัก หลังจากดำเนินการลดมิติของข้อมูลด้วยการวิเคราะห์องค์ประกอบหลักและสหสัมพันธ์แล้ว ข้อมูลองค์ประกอบหลักถูกแบ่งเพื่อทำการฝึกฝนและการทดสอบแบบจำลอง การวิเคราะห์แบบจำลองโครงข่ายประสาทเทียมพบว่าแบบจำลองแบบ 2 ชั้นช่อนดีกว่าแบบจำลองแบบ 1 ชั้นช่อนโดยฟังก์ชันถ่ายโอนประเภท Log-sigmoid หรือ Tan-sigmoid ให้ผลดีกว่า อย่างไรก็ตาม แบบจำลองสมการถดถอยประเภทซัพพอร์ตเวกเตอร์จะพยากรณ์ได้ดีกว่าแบบจำลองโครงข่ายประสาทเทียม โดยความแม่นยำในการพยากรณ์จะขึ้นอยู่กับชนิดของเคอร์เนลฟังก์ชัน (Kernel Function) อันได้แก่เคอร์เนลฟังก์ชันแบบเส้นตรง (Linear) แบบพหุคูณ (Polynomial) หรือแบบเกาส์เซียน (Gaussian) หลังจากการทดสอบความอ่อนไหวและความแม่นยำของแบบจำลองสมการถดถอยประเภทซัพพอร์ตเวกเตอร์ที่ใช้เคอร์เนลฟังก์ชันต่าง ๆ พบว่าแบบจำลองที่ใช้เคอร์เนลฟังก์ชันแบบเกาส์เซียนมีความเหมาะสมมากที่สุดในการพยากรณ์

สาขาวิชา วิศวกรรมอุตสาหกรรม  
ปีการศึกษา 2562

ลายมือชื่อนิสิต .....  
ลายมือชื่อ อ.ที่ปรึกษาหลัก .....

# # 6070237621 : MAJOR INDUSTRIAL ENGINEERING

KEYWORD: Wet mixing, Artificial Neural Network, Support Vector Regression

Boonyasith Chamnanthongpaivanh : PREDICTION MODEL FOR IMPELLER  
 REVOLUTION IN WET GRANULATION PROCEDURE USING ARTIFICIAL NEURAL  
 NETWORK AND SUPPORT VECTOR REGRESSION. Advisor: Asst. Prof. ORAN  
 KITTITHREERAPRONCHAI

As the most widely used procedure for tablet production on commercial-scale, wet granulation procedures can improve the compression properties through the mechanical combining of binder solution with tablet-powder excipients in a mixing bowl, called wet mixing step. As one of the critical steps, the wet mixing step can significantly affect the quality of tablets. The mixing parameters could vary across different machines and the formulation of tablets, similar to a case study factory. The factory has many wet mixing machines and relies on experience and trial-and-error to predict a mixing time. Therefore, this study aims to apply Artificial Neural Network (ANN) and Support Vector Regression (SVR) algorithms for predicting the number of impeller revolutions. After performing the dimension reduction with principal component analysis and correlation, the reduction data is grouped for training model parameters and validating model accuracy. The analysis of ANN models reveals that a model using 2-hidden layers dominates a model using a single hidden layer. Furthermore, a log-sigmoid and tan-sigmoid functions are superior than purelin transfer function. However, an SVR model has more potential for prediction compared to ANN models. Its accuracy highly depend on kernel functions including Linear kernel, Polynomial kernel, and Gaussian kernel. After the accuracy and sensitivity test, the SVR models with Gaussian kernel function is the most appropriate model for prediction.

Field of Study: Industrial Engineering

Student's Signature .....

Academic Year: 2019

Advisor's Signature .....

## กิตติกรรมประกาศ

การจัดทำวิทยานิพนธ์เล่มนี้ซึ่งเป็นไปได้อย่างลุล่วงนั้น จะเป็นไปไม่ได้เลยหากข้าพเจ้าไม่ได้รับการดูแลและความช่วยเหลือตลอดมาจากผู้ช่วยศาสตราจารย์ ดร.โอฬาร กิตติธีรพรชัย ผู้ซึ่งเป็นอาจารย์ที่ปรึกษาหลักของงานวิทยานิพนธ์นี้ ตั้งแต่การหาแนวคิดของวิทยานิพนธ์นี้ การเพิ่มพูนความรู้ต่าง ๆ ระหว่างการวิเคราะห์และจัดทำข้อมูลของข้าพเจ้า ตลอดจนการชี้แนะข้อบกพร่องต่าง ๆ ทำให้สามารถจัดทำวิทยานิพนธ์ได้จนเสร็จสมบูรณ์ นอกจากนี้ ข้าพเจ้าขอใช้โอกาสนี้กราบขอบพระคุณคณะกรรมการสอบวิทยานิพนธ์อันประกอบด้วย รองศาสตราจารย์ ดร.วิภาวี ธรรมมาภรณ์พิลาศ ผู้ซึ่งเป็นประธานกรรมการ รองศาสตราจารย์ ดร.อังศุมาลิน เสนจันทร์มิไชย ผู้ซึ่งเป็นกรรมการ และ รองศาสตราจารย์ ดร.เจริญชัย โขมพัตรภรณ์ ผู้ซึ่งเป็นกรรมการภายนอกมหาวิทยาลัย ที่สละเวลาอันมีค่าในการเข้าร่วมพิจารณา ตรวจสอบ และแนะนำเกี่ยวกับความสมบูรณ์กับความบกพร่องต่าง ๆ ภายในงานวิทยานิพนธ์ เพื่อให้งานวิทยานิพนธ์นี้มีความสมบูรณ์มากยิ่งขึ้น

อีกทั้งข้าพเจ้าขอขอบคุณอาจารย์ประจำภาควิชาวิศวกรรมอุตสาหการ คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัยทุกท่านเป็นอย่างยิ่ง ที่ได้ช่วยมอบความรู้ต่าง ๆ ให้แก่ข้าพเจ้า และเจ้าหน้าที่ประจำภาควิชาทุกท่านที่ช่วยประสานงานระหว่างการจัดทำวิทยานิพนธ์มาเป็นอย่างดี

ยิ่งไปกว่านั้น งานวิทยานิพนธ์นี้จะเกิดขึ้นไม่ได้เลยหากไม่ได้รับความร่วมมือเป็นอย่างดีจากบริษัทกรณีศึกษา ที่มอบข้อมูลอันมีค่าต่าง ๆ ให้แก่ข้าพเจ้าเพื่อนำมาใช้ในงานวิทยานิพนธ์นี้

สุดท้ายนี้ ขอกราบขอบพระคุณครอบครัวที่เป็นกำลังใจและเป็นแรงสนับสนุนข้าพเจ้า อีกทั้งนิสิตท่านอื่น ๆ รอบตัวข้าพเจ้าที่ให้คำปรึกษาและช่วยเหลือข้าพเจ้า ทำให้ข้าพเจ้าสามารถสำเร็จการศึกษาครั้งนี้ได้

จุฬาลงกรณ์มหาวิทยาลัย  
CHULALONGKORN UNIVERSITY

บุญญสิทธิ ชำนาญทองไพล์

## สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ค
บทคัดย่อภาษาอังกฤษ.....	ง
กิตติกรรมประกาศ.....	จ
สารบัญ.....	ฉ
สารบัญตาราง.....	ช
สารบัญรูป.....	ฅ
บทที่ 1 บทนำ .....	1
1.1 ยาเม็ดและกระบวนการผลิต .....	2
1.2 ที่มาและความสำคัญของปัญหา .....	4
1.3 วัตถุประสงค์ของวิทยานิพนธ์ .....	7
1.4 ขอบเขตของวิทยานิพนธ์ .....	8
1.5 ประโยชน์ของวิทยานิพนธ์.....	9
1.6 ผลที่คาดว่าจะได้รับ.....	9
1.7 ขั้นตอนดำเนินการจัดทำวิทยานิพนธ์.....	9
บทที่ 2 ทบทวนวรรณกรรมและงานวิจัยที่เกี่ยวข้อง .....	10
2.1 ยาเม็ดและกระบวนการผลิต .....	10
2.2 การผลิตยาเม็ดโดยการทำแกรนูลเปียก .....	13
2.3 ระบบโครงข่ายประสาทเทียม.....	17
2.4 แบบจำลองสมการถดถอยประเภทซัพพอร์ตเวกเตอร์.....	30
2.5 การวิเคราะห์องค์ประกอบหลัก.....	36
บทที่ 3 บริษัทกรณีศึกษา .....	41

3.1 สภาพทั่วไปของโรงงาน .....	41
3.2 โครงสร้างองค์กรและฝ่ายผลิต.....	42
3.3 ฝ่ายผลิตยาเม็ดและแคปซูล.....	44
บทที่ 4 ข้อมูลและการวิเคราะห์ห้องค์ประกอบหลัก.....	48
4.1 ข้อมูลที่ได้รับ.....	48
4.2 การวิเคราะห์ห้องค์ประกอบหลักเบื้องต้น .....	53
4.3 การวิเคราะห์ห้องค์ประกอบหลักหลังปรับปรุงข้อมูล.....	61
บทที่ 5 การพัฒนาแบบจำลอง .....	65
5.1 ข้อมูลเกี่ยวกับแบบจำลอง.....	65
5.2 แบบจำลอง ANN.....	69
5.3 แบบจำลอง SVR.....	97
5.4 การเปรียบเทียบแบบจำลอง.....	97
บทที่ 6 การทดสอบแบบจำลอง.....	104
6.1 แบบจำลอง ANN.....	105
6.2 แบบจำลอง SVR.....	120
6.3 การประเมินค่าทำนายจากแบบจำลอง .....	120
6.4 การเปรียบเทียบแบบจำลอง.....	122
6.5 การประยุกต์ใช้งานแบบจำลอง .....	125
บทที่ 7 สรุปผลการวิจัยและข้อเสนอแนะ .....	129
7.1 สรุปผลงานวิจัย.....	129
7.2 ข้อเสนอแนะ .....	131
บรรณานุกรม.....	132
ประวัติผู้เขียน.....	136



## สารบัญตาราง

	หน้า
ตารางที่ 1-1 การขึ้นทะเบียนตำรับยา แบ่งตามประเภทหมวดยา เมื่อปี พ.ศ. 2557.....	1
ตารางที่ 2-1 เปรียบเทียบการศึกษาทางเภสัชกรรมโดยใช้โปรแกรม ANN.....	29
ตารางที่ 4-1 ชุดข้อมูลนำเข้าและข้อมูลนำออกที่ได้รับ .....	50
ตารางที่ 4-2 ความแปรปรวนที่เกิดขึ้นในองค์ประกอบต่าง ๆ .....	54
ตารางที่ 4-3 ค่า loading ของข้อมูลนำเข้าที่เป็นส่วนประกอบในองค์ประกอบต่าง ๆ.....	55
ตารางที่ 4-4 แสดงค่าสัมประสิทธิ์สหสัมพันธ์และค่า p-value ของข้อมูลนำเข้าในกลุ่มข้อมูลที่ 1... 59	59
ตารางที่ 4-5 ค่าสัมประสิทธิ์สหสัมพันธ์และค่า p-value ของข้อมูลนำเข้าในกลุ่มข้อมูลที่ 2 .....	61
ตารางที่ 4-6 ความแปรปรวนที่เกิดขึ้นในองค์ประกอบต่าง ๆ หลังนำข้อมูลนำเข้าออกบางส่วน .....	62
ตารางที่ 4-7 ค่า loading ของข้อมูลนำเข้าที่เป็นส่วนประกอบในองค์ประกอบต่าง ๆ หลังปรับปรุงข้อมูล .....	62
ตารางที่ 5-1 ชุดข้อมูลที่ใช้สร้างและฝึกฝนแบบจำลอง .....	66
ตารางที่ 5-2 ข้อมูลที่ใช้ทดสอบความถูกต้องในการทำนายของแบบจำลอง .....	67
ตารางที่ 5-3 ค่าเฉลี่ยและส่วนเบี่ยงเบนมาตรฐานของค่า RMSE เมื่อใช้ฟังก์ชัน Logsig .....	72
ตารางที่ 5-4 ค่าเฉลี่ยและส่วนเบี่ยงเบนมาตรฐานของค่า RMSE เมื่อใช้ฟังก์ชัน Purelin.....	72
ตารางที่ 5-5 ค่าเฉลี่ยและส่วนเบี่ยงเบนมาตรฐานของค่า RMSE เมื่อใช้ฟังก์ชัน Tansig.....	73
ตารางที่ 5-6 ค่า p-value ที่ได้จากการทดสอบ ANOVA เปรียบเทียบค่าเฉลี่ย RMSE เมื่อใช้จำนวน RMSE เป็น 10 20 50 100 200 และ 500 ครั้ง.....	75
ตารางที่ 5-7 ค่า p-value ที่ได้จากการทดสอบ ANOVA เมื่อใช้ฟังก์ชันถ่ายโอนแตกต่างกัน .....	77
ตารางที่ 5-8 ค่า p-value ที่ได้จากการทดสอบ Tukey's Test เมื่อเปรียบเทียบระหว่างฟังก์ชันถ่ายโอน ณ จำนวนประสาทเทียมในชั้นซ่อนต่าง ๆ .....	77
ตารางที่ 5-9 ค่า p-value จากการทดสอบ ANOVA เมื่อใช้จำนวนประสาทเทียมแตกต่างกัน.....	79

ตารางที่ 5-10 ค่า p-value จากการทดสอบ Tukey's Test เมื่อเปรียบเทียบค่า RMSE ระหว่างแบบจำลองที่ใช้ฟังก์ชัน Logsig ณ จำนวนประสาทเทียมแตกต่างกัน .....	80
ตารางที่ 5-11 ค่าสถิติต่าง ๆ ของกลุ่มค่า RMSE ในแบบจำลอง ANN 2 ชั้นซ้อน.....	82
ตารางที่ 5-12 ช่วงความถี่ของค่าเฉลี่ยของ RMSE ของแบบจำลอง ANN 2 ชั้นซ้อนเมื่อใช้ฟังก์ชันถ่ายโอนแตกต่างกัน .....	83
ตารางที่ 5-13 ค่า p-value ที่ได้จากการทดสอบ two-tailed Paired T-test ระหว่างแบบจำลองที่ใช้ชุดฟังก์ชันถ่ายโอนแตกต่างกัน.....	86
ตารางที่ 5-14 ค่า p-value ที่ได้จากการทดสอบ One-tailed Paired T-test ระหว่างแบบจำลองที่ใช้ชุดฟังก์ชันถ่ายโอนอื่น ๆ กับแบบจำลองที่ใช้ชุดฟังก์ชัน Tansig-Tansig.....	88
ตารางที่ 5-15 ค่าเฉลี่ยของ RMSE จากแบบจำลองเมื่อใช้จำนวนประสาทเทียมในชั้นซ่อนที่ 1 แตกต่างกัน.....	89
ตารางที่ 5-16 ค่า p-value ที่ได้จากการทดสอบ ANOVA ระหว่างกลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลองที่ใช้จำนวนประสาทเทียมในชั้นซ่อนที่ 1 แตกต่างกัน .....	90
ตารางที่ 5-17 ค่า p-value จากการทดสอบ Tukey's Test เมื่อเปรียบเทียบค่า RMSE ระหว่างแบบจำลองที่ใช้ชุดฟังก์ชัน Logsig-Logsig ณ จำนวนประสาทเทียมในชั้นซ่อนที่ 1 แตกต่างกัน.....	91
ตารางที่ 5-18 ค่า p-value จากการทดสอบ Tukey's Test เมื่อเปรียบเทียบค่า RMSE ระหว่างแบบจำลองที่ใช้ชุดฟังก์ชัน Logsig-Tansig ณ จำนวนประสาทเทียมในชั้นซ่อนที่ 1 แตกต่างกัน.....	92
ตารางที่ 5-19 ค่า p-value จากการทดสอบ Tukey's Test เมื่อเปรียบเทียบค่า RMSE ระหว่างแบบจำลองที่ใช้ชุดฟังก์ชัน Tansig-Logsig ณ จำนวนประสาทเทียมในชั้นซ่อนที่ 1 แตกต่างกัน.....	93
ตารางที่ 5-20 ค่าเฉลี่ยของ RMSE จากแบบจำลองเมื่อใช้จำนวนประสาทเทียมในชั้นซ่อนที่ 2 แตกต่างกัน.....	95
ตารางที่ 5-21 ค่า p-value ที่ได้จากการทดสอบ ANOVA ระหว่างกลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลองที่ใช้จำนวนประสาทเทียมในชั้นซ่อนที่ 2 แตกต่างกัน .....	96
ตารางที่ 5-22 ค่า RMSE จากแบบจำลอง SVR.....	97
ตารางที่ 5-23 ช่วงของค่า RMSE จากแบบจำลองที่พัฒนาได้ทั้ง 3 ประเภท.....	98

ตารางที่ 5-24 ค่า p-value จากการทดสอบ Two-tailed T-test ระหว่างค่าเฉลี่ยของ RMSE จากแบบจำลอง ANN 2 ชั้นซ่อน และแบบจำลอง ANN 1 ชั้นซ่อน.....	99
ตารางที่ 5-25 ค่า p-value จากการทดสอบ Lower-tailed T-test ระหว่างค่าเฉลี่ยของ RMSE จากแบบจำลอง ANN 2 ชั้นซ่อน และแบบจำลอง ANN 1 ชั้นซ่อน.....	100
ตารางที่ 5-26 ค่า p-value จากการทดสอบ Two-tailed T-test ระหว่างค่า RMSE จากแบบจำลอง ANN 2 ชั้นซ่อน และแบบจำลอง SVR.....	102
ตารางที่ 5-27 ค่า p-value จากการทดสอบ One-tailed T-test ระหว่างค่า RMSE จากแบบจำลอง ANN 2 ชั้นซ่อน และแบบจำลอง SVR.....	103
ตารางที่ 6-1 ค่าสถิติของ RMSE ในแบบจำลอง ANN 2 ชั้นซ่อน.....	105
ตารางที่ 6-2 ช่วงความถี่ของค่าเฉลี่ยของ RMSE เมื่อใช้ชุดฟังก์ชันถ่ายโอนต่าง ๆ.....	106
ตารางที่ 6-3 ค่า p-value ที่ได้จากการทดสอบ Two-tailed Paired T-test ระหว่างแบบจำลอง ANN 2 ชั้นซ่อนที่ใช้ชุดฟังก์ชันถ่ายโอนแตกต่างกัน.....	109
ตารางที่ 6-4 ค่า p-value ที่ได้จากการทดสอบ One-tailed Paired T-test ระหว่างกลุ่มแบบจำลอง ANN 2 ชั้นซ่อน.....	111
ตารางที่ 6-5 ค่าเฉลี่ยของ RMSE จากแบบจำลอง ANN 2 ชั้นซ่อนเมื่อใช้จำนวนประสาทเทียมในชั้นซ่อนที่ 1 แตกต่างกัน.....	112
ตารางที่ 6-6 ค่า p-value ที่ได้จากการทดสอบ ANOVA ระหว่างกลุ่มค่าเฉลี่ยของ RMSE เมื่อใช้จำนวนประสาทเทียมในชั้นซ่อนที่ 1 แตกต่างกัน.....	113
ตารางที่ 6-7 ค่าเฉลี่ยของ RMSE จากแบบจำลอง ANN 2 ชั้นซ่อนเมื่อใช้จำนวนประสาทเทียมในชั้นซ่อนที่ 2 แตกต่างกัน.....	116
ตารางที่ 6-8 ค่า p-value ที่ได้จากการทดสอบ ANOVA ระหว่างกลุ่มค่าเฉลี่ยของ RMSE เมื่อใช้จำนวนประสาทเทียมในชั้นซ่อนที่ 2 แตกต่างกัน.....	117
ตารางที่ 6-9 RMSE จากแบบจำลอง SVR.....	120
ตารางที่ 6-10 การทดสอบความอ่อนไหวของแบบจำลอง ANN เมื่อปรับพารามิเตอร์ต่าง ๆ.....	121
ตารางที่ 6-11 การทดสอบความอ่อนไหวของแบบจำลอง SVR เมื่อใช้ Gaussian Kernel .....	121
ตารางที่ 6-12 การทดสอบความอ่อนไหวของแบบจำลอง SVR เมื่อใช้ Polynomial Kernel.....	121

ตารางที่ 6-13 การทดสอบความอ่อนไหวของแบบจำลอง SVR เมื่อใช้ Linear Kernel..... 121

ตารางที่ 6-14 ค่า p-value จากการทดสอบ Two-tailed T-test ระหว่างค่า RMSE จากแบบจำลอง ANN 2 ชั้นซ้อนกับแบบจำลอง SVR..... 123

ตารางที่ 6-15 ค่า p-value จากการทดสอบ One-tailed T-test ระหว่างค่า RMSE จากแบบจำลอง ANN 2 ชั้นซ้อนที่ใช้ฟังก์ชันถ่ายโอน Logsig-Logsig และแบบจำลอง SVR..... 124

ตารางที่ 6-16 ค่าจริงและค่าทำนายของชุดข้อมูลฝึกฝนจากแบบจำลอง SVR (Gaussian Kernel)125

ตารางที่ 6-17 ค่าจริงและค่าทำนายของชุดข้อมูลทดสอบจากแบบจำลอง SVR (Gaussian Kernel)  
..... 126



## สารบัญรูป

	หน้า
รูปที่ 1-1 ตัวอย่างโปรแกรม ANN .....	6
รูปที่ 1-2 ตัวอย่างเครื่องมือ SVR.....	6
รูปที่ 2-1 การผลิตยาเม็ดโดยการตอกตรง .....	11
รูปที่ 2-2 การผลิตยาเม็ดโดยการทำแกรนูลเปียก .....	12
รูปที่ 2-3 การผลิตยาเม็ดโดยการทำแกรนูลแห้ง .....	13
รูปที่ 2-4 เครื่องมือ Sigma-blade Mixer และ Planetary Mixer ตามลำดับ .....	14
รูปที่ 2-5 เครื่องมือ High Shear Mixer .....	15
รูปที่ 2-6 เครื่องมือ Fluidized Bed Mixer.....	15
รูปที่ 2-7 การทำงานของเซลล์ประสาท (Neuron) และประสาทเทียม (Artificial Neuron) .....	18
รูปที่ 2-8 การทำงานของประสาทเทียม.....	18
รูปที่ 2-9 กราฟเส้นของฟังก์ชันถ่ายโอนในแบบจำลอง ANN [(a) Logsig (b) Purelin (c) Tansig].	19
รูปที่ 2-10 หลักการเรียนรู้ของวิธี Error Back-propagation.....	22
รูปที่ 2-11 ระบบ ANN ประเภท MLP แบบ 4 ชั้น.....	23
รูปที่ 2-12 ระบบ ANN ประเภท GRNN.....	25
รูปที่ 2-13 รูปแบบการทำงานของ Elman Neural Network.....	26
รูปที่ 2-14 แสดงการเกิดแบบจำลอง SVR.....	31
รูปที่ 2-15 ตัวอย่างข้อมูลและกราฟแสดงข้อมูล .....	37
รูปที่ 2-16 ข้อมูลที่ถูกปรับค่าเฉลี่ย และกราฟของข้อมูลที่ถูกปรับค่าเฉลี่ยและเวกเตอร์เจาะจง.....	38
รูปที่ 2-17 ข้อมูลใหม่ที่ได้และกราฟของข้อมูลใหม่.....	39
รูปที่ 3-1 การรับรองต่าง ๆ ของบริษัทกรณีศึกษา .....	42

รูปที่ 3-2 โครงสร้างองค์กรของบริษัทกรณีศึกษา.....	43
รูปที่ 3-3 แผนผังองค์กรของหน่วยงานฝ่ายผลิตในบริษัทกรณีศึกษา.....	44
รูปที่ 3-4 ขั้นตอนการทำแกรนูลเปียก .....	45
รูปที่ 3-5 ระบบทำแกรนูลแบบเปียกแบบเดิม .....	46
รูปที่ 3-6 ระบบทำแกรนูลแบบเปียกแบบใหม่.....	46
รูปที่ 4-1 แผนผังขั้นตอนการวิเคราะห์ข้อมูลจากบริษัทกรณีศึกษา.....	54
รูปที่ 4-2 ข้อมูลนำเข้าที่เป็นส่วนประกอบขององค์ประกอบที่ 1 และ 2 .....	56
รูปที่ 4-3 สัมประสิทธิ์สหสัมพันธ์ของข้อมูลนำเข้าในกลุ่มข้อมูลที่ 1.....	58
รูปที่ 4-4 สัมประสิทธิ์สหสัมพันธ์ของข้อมูลนำเข้าในกลุ่มข้อมูลที่ 2.....	60
รูปที่ 4-5 ข้อมูลนำเข้าที่เป็นส่วนประกอบขององค์ประกอบที่ 1 และ 2 หลังการปรับปรุงข้อมูล .....	63
รูปที่ 5-1 แผนผังการพัฒนาและวิเคราะห์แบบจำลอง .....	68
รูปที่ 5-2 โครงสร้างของแบบจำลอง ANN ที่มีชั้นซ่อน 1 ชั้น .....	70
รูปที่ 5-3 โครงสร้างของแบบจำลอง ANN ที่มีชั้นซ่อน 2 ชั้น.....	70
รูปที่ 5-4 การกระจายของค่า RMSE เมื่อใช้ฟังก์ชัน Logsig และมีประสาทเทียม 1 5 และ 10 ตัว. 73	
รูปที่ 5-5 การกระจายของค่า RMSE เมื่อใช้ฟังก์ชัน Purelin และมีประสาทเทียม 1 5 และ 10 ตัว. 73	
รูปที่ 5-6 การกระจายของค่า RMSE เมื่อใช้ฟังก์ชัน Tansig และมีประสาทเทียม 1 5 และ 10 ตัว. 74	
รูปที่ 5-7 ค่าเฉลี่ยของ RMSE ของแบบจำลองเมื่อใช้จำนวนประสาทเทียมและฟังก์ชันถ่ายโอน แตกต่างกัน.....	76
รูปที่ 5-8 ค่า RMSE เมื่อใช้ฟังก์ชัน Logsig และจำนวนประสาทเทียมแตกต่างกัน .....	81
รูปที่ 5-9 การกระจายของค่าเฉลี่ยของ RMSE ของแบบจำลองที่ใช้ชุดฟังก์ชัน Logsig-Logsig.....	84
รูปที่ 5-10 การกระจายของค่าเฉลี่ยของ RMSE ของแบบจำลองที่ใช้ชุดฟังก์ชัน Logsig-Tansig .....	84
รูปที่ 5-11 การกระจายของค่าเฉลี่ยของ RMSE ของแบบจำลองที่ใช้ชุดฟังก์ชัน Tansig-Logsig .....	85
รูปที่ 5-12 การกระจายของค่าเฉลี่ยของ RMSE ของแบบจำลองที่ใช้ชุดฟังก์ชัน Tansig-Tansig.....	85

รูปที่ 5-13 ค่าเฉลี่ยของ RMSE จากแบบจำลองเมื่อใช้จำนวนประสาทเทียมในชั้นซ่อนที่ 1 แตกต่าง กัน.....	89
รูปที่ 5-14 ความแตกต่างของ RMSE ของแบบจำลองที่มีฟังก์ชันถ่ายโอน Logsig-Logsig เมื่อมี จำนวนประสาทเทียมในชั้นซ่อนที่ 1 แตกต่างกัน.....	92
รูปที่ 5-15 ความแตกต่างของ RMSE ของแบบจำลองที่มีฟังก์ชันถ่ายโอน Logsig-Tansig เมื่อใช้ จำนวนประสาทเทียมในชั้นซ่อนที่ 1 แตกต่างกัน.....	93
รูปที่ 5-16 ความแตกต่างของ RMSE ของแบบจำลองที่มีฟังก์ชันถ่ายโอน Tansig-Logsig เมื่อใช้ จำนวนประสาทเทียมในชั้นซ่อนที่ 1 แตกต่างกัน.....	94
รูปที่ 5-17 ค่าเฉลี่ยของ RMSE จากแบบจำลอง เมื่อใช้จำนวนประสาทเทียมในชั้นซ่อนที่ 2 แตกต่าง กัน.....	95
รูปที่ 5-18 ช่วงของค่า RMSE จากแบบจำลอง ANN 2 ชั้นซ่อน และแบบจำลอง SVR.....	101
รูปที่ 6-1 แผนผังการทดสอบและวิเคราะห์แบบจำลอง .....	104
รูปที่ 6-2 การกระจายของค่าเฉลี่ยของ RMSE ของแบบจำลอง ANN 2 ชั้นซ่อนที่ใช้ฟังก์ชัน Logsig- Logsig.....	107
รูปที่ 6-3 การกระจายของค่าเฉลี่ยของ RMSE ของแบบจำลอง ANN 2 ชั้นซ่อนที่ใช้ฟังก์ชัน Logsig- Tansig .....	107
รูปที่ 6-4 การกระจายของค่าเฉลี่ยของ RMSE ของแบบจำลอง ANN 2 ชั้นซ่อนที่ใช้ฟังก์ชัน Tansig- Logsig.....	108
รูปที่ 6-5 การกระจายของค่าเฉลี่ยของ RMSE ของแบบจำลอง ANN 2 ชั้นซ่อนที่ใช้ฟังก์ชัน Tansig- Tansig .....	108
รูปที่ 6-6 ค่าเฉลี่ยของ RMSE จากแบบจำลอง ANN 2 ชั้นซ่อนเมื่อใช้จำนวนประสาทเทียม ในชั้น ซ่อนที่ 1 แตกต่างกัน.....	112
รูปที่ 6-7 RMSE เมื่อใช้แบบจำลองที่มีฟังก์ชันถ่ายโอน Logsig-Logsig เมื่อใช้จำนวนประสาทเทียม ในชั้นซ่อนที่ 1 แตกต่างกัน .....	114
รูปที่ 6-8 RMSE เมื่อใช้แบบจำลองที่มีฟังก์ชันถ่ายโอน Tansig-Logsig เมื่อใช้จำนวนประสาทเทียม ในชั้นซ่อนที่ 1 แตกต่างกัน .....	115

รูปที่ 6-9 ค่าเฉลี่ยของ RMSE จากแบบจำลอง ANN 2 ชั้นซ่อนเมื่อใช้จำนวนประสาทเทียม ในชั้น  
ซ่อนที่ 2 แตกต่างกัน ..... 116

รูปที่ 6-10 RMSE เมื่อใช้แบบจำลองที่มีฟังก์ชันถ่ายโอน Logsig-Logsig เมื่อใช้จำนวนประสาทเทียม  
ในชั้นซ่อนที่ 2 แตกต่างกัน ..... 118

รูปที่ 6-11 RMSE เมื่อใช้แบบจำลองที่มีฟังก์ชันถ่ายโอน Tansig-Logsig เมื่อใช้จำนวนประสาทเทียม  
ในชั้นซ่อนที่ 2 แตกต่างกัน ..... 118

รูปที่ 6-12 ค่าจริงและค่าทำนายของชุดข้อมูลฝึกฝนจากแบบจำลอง SVR (Gaussian Kernel) .... 126

รูปที่ 6-13 ค่าจริงและค่าทำนายของชุดข้อมูลทดสอบจากแบบจำลอง SVR (Gaussian Kernel).. 127





## บทที่ 1

### บทนำ

อุตสาหกรรมยาในประเทศไทยเป็นหนึ่งในอุตสาหกรรมที่มีความสำคัญต่อเศรษฐกิจไทย นอกจากนี้อุตสาหกรรมยาในประเทศไทยยังมีศักยภาพสูงที่สุดในภูมิภาคเอเชียตะวันออกเฉียงใต้ ในปี พ.ศ. 2562 อุตสาหกรรมยาในประเทศไทยมีมูลค่ารวมอยู่ที่ 177,000 ล้านบาท แสดงให้เห็นได้ว่า อุตสาหกรรมยาเป็นอุตสาหกรรมที่มีความน่าสนใจในการลงทุนอีกอุตสาหกรรมหนึ่ง อันสังเกตได้จาก อัตราการเติบโตเฉลี่ยต่อปีของอุตสาหกรรมยาคือ 6.2% [1] และมีการขึ้นทะเบียนตำรับยาใหม่ ตลอดเวลา โดยข้อมูลจากสำนักงานคณะกรรมการอาหารและยาระบุสถิติการขึ้นทะเบียนตำรับยา แบ่งตามหมวดยาต่าง ๆ เมื่อปีพ.ศ. 2557 [2] ดังแสดงในตารางที่ 1-1

ตารางที่ 1-1 การขึ้นทะเบียนตำรับยา แบ่งตามประเภทหมวดยา เมื่อปี พ.ศ. 2557

หมวดยา	จำนวน	สัดส่วน
ยาเม็ด (Tablet)	344	50.22
ยาปราศจากเชื้อ (Sterile Product)	243	35.47
ยาแคปซูล (Capsule)	74	10.80
ยาน้ำ (Liquid)	16	2.34
ยาขี้ผึ้งหรือครีม (Ointment, Cream)	1	0.15
วัคซีน (Vaccine)	4	0.58
ยาอื่น ๆ (Miscellaneous)	4	0.59

จากข้อมูลการขึ้นทะเบียนตำรับยาในตารางที่ 1-1 พบว่ายาเม็ดเป็นประเภทยาที่มีการขึ้นทะเบียนตำรับมากที่สุด หรือ คิดเป็น 50.22% ของปริมาณตำรับยาทั้งหมดที่ได้รับการจดทะเบียนในปีพ.ศ. 2557 ข้อมูลดังกล่าวสอดคล้องกับลักษณะการผลิตและบริโภคของยาเม็ดเนื่องจากยาเม็ดสะดวกในการพกพาและบริหารยาได้ง่าย มีความคงตัวสูง และกระบวนการผลิตไม่ซับซ้อน [3] จาก

ลักษณะดังกล่าว ตำรับยาเม็ดจึงเป็นตำรับยาที่โรงงานผลิตยาให้ความสำคัญในการผลิตเป็นอันดับต้น ๆ ดังนั้นผู้วิจัยจึงมีความสนใจศึกษาเกี่ยวกับกระบวนการผลิตยาเม็ดดังที่จะกล่าวในส่วนต่อไป

### 1.1 ยาเม็ดและกระบวนการผลิต

ยาเม็ด (Tablet) คือยาในรูปแบบของแข็งที่ประกอบด้วยตัวยาสำคัญและส่วนประกอบอื่น ๆ ในเม็ดขนาดและน้ำหนักของยาเม็ดจะขึ้นอยู่กับปริมาณของตัวยาสำคัญและวิธีการบริหารยาเม็ด โดยทั่วไปการขึ้นรูปยาเม็ดสามารถทำได้ 2 วิธี ได้แก่

- วิธีการตอกอัด (Compression) เป็นการนำตัวยาสำคัญและส่วนประกอบอื่น ๆ มาผสมกันแล้วนำไปอัดแรงเพื่อทำให้ส่วนประกอบจับตัวกันแน่นเป็นเม็ด
- วิธีการหล่อพิมพ์ (Molding) เป็นการนำตัวยาสำคัญและส่วนประกอบอื่น ๆ มาผสมกันแล้วนำไปอัดฉีดลงในเบ้า ทำให้แห้งจนเป็นเม็ด

ปัจจุบันกระบวนการขึ้นรูปแบบวิธีการตอกอัดเป็นวิธีการที่นิยมมากกว่าเนื่องจากวิธีนี้สามารถผลิตยาเม็ดที่มีปริมาณยามากได้ และสามารถควบคุมความแข็งของยาเม็ดได้อีกด้วย เพื่อให้การตอกอัดมีประสิทธิภาพสารประกอบที่ใช้ในการผลิตยาเม็ดต้องมีคุณสมบัติที่เหมาะสมเช่น การไหลเป็นไปอย่างอิสระ อนุภาคสามารถยึดเกาะกันเองได้ และคุณสมบัติหล่อลื่นในตัวเอง หากตัวยาสำคัญมีคุณสมบัติไม่เพียงพอในการตอกอัดเป็นเม็ดยา โรงงานผลิตจำเป็นต้องมีการพัฒนาสูตรตำรับยาและพัฒนาวิธีการผลิตยาเพื่อให้ได้คุณสมบัติของสารที่เหมาะสม [3]

การผลิตยาเม็ดโดยวิธีการตอกอัดที่ใช้ในอุตสาหกรรมยาเม็ดจะมีด้วยกัน 3 วิธี ประกอบด้วยวิธีการตอกตรง (Direct Compression) ซึ่งนำอนุภาคของมวลยาเม็ดมาทำการตอกอัดโดยตรงให้ได้เป็นยาเม็ด วิธีนี้เหมาะสมกับตำรับยาที่มีคุณสมบัติของอนุภาคเหมาะสมต่อการตอกอัดแล้ว การทำแกรนูลเปียก (Wet Granulation) เป็นวิธีที่นำอนุภาคของมวลยามาเติมสารละลายของสารยึดเกาะให้รวมกันแล้วอบแห้งให้เป็นแกรนูลเพื่อปรับคุณสมบัติให้เหมาะสมต่อการตอกอัด และ การทำแกรนูลแห้ง (Dry Granulation) เป็นวิธีที่นำอนุภาคของมวลยามาบีบอัดให้เป็นก้อนใหญ่ก่อนจะทำการแรงลดขนาดให้เป็นแกรนูลเพื่อปรับคุณสมบัติให้เหมาะสมต่อการตอกอัดเช่นเดียวกับการทำแกรนูลเปียก แต่วิธีนี้จะใช้กับอนุภาคของมวลยาที่ไม่ทนต่อสภาวะอุณหภูมิสูงหรือความชื้นสูง โดยวิธีที่มีการใช้มากที่สุดในการผลิตยาเม็ดคือการทำแกรนูลเปียก ผู้วิจัยจึงทำการทดลองโดยใช้ตำรับยาเม็ดที่ใช้วิธีการทำแกรนูลเปียกต่อไป

เพื่อให้ได้คุณภาพและคุณสมบัติการไหลที่ต้องการ การทำแกรนูลแห้งของยาแต่ละตำรับจำเป็นต้องมีการควบคุมปัจจัยในกระบวนการที่เหมาะสม เนื่องจากตัวยาสำคัญแต่ละชนิดมีคุณสมบัติทางเคมีและกายภาพที่แตกต่างกัน และอาจส่งผลกระทบต่อกระบวนการผลิต เช่น การกระจายขนาดอนุภาคผง (Particle Size Distribution) ความสามารถในการทำให้เปียกของผงยา (Wettability) ความเข้มข้นและความหนืดของสารน้ำที่ใช้ผสม (Binder Concentration and Viscosity) เป็นต้น โดยทั่วไปปัจจัยในกระบวนการที่จำเป็นต้องมีการควบคุมมีดังนี้ [4]

- อัตราการกระจายของสารน้ำ โดยสารน้ำจำเป็นต้องมีการกระจายเร็วเพื่อให้เกิดแกรนูลอย่างรวดเร็ว
- สัดส่วนตัวทำละลายที่ใช้ โดยมีผลต่ออัตราการรวมตัวของผงแห้งให้เกิดแกรนูล
- เวลาที่ใช้ในการผสม หากใช้เวลาน้อยหรือมากเกินไปจะทำให้แกรนูลมีความหนาแน่นไม่เหมาะสม
- ความเร็วของใบพาย Impeller ซึ่งส่งผลต่อความหนาแน่นของแกรนูลที่ได้
- ความเร็วของใบพัด Chopper ซึ่งส่งผลต่อรูปร่างและขนาดของแกรนูลที่ได้

## 1.2 ที่มาและความสำคัญของปัญหา


เนื่องด้วยกระบวนการผลิตผลิตภัณฑ์ยาด้วยวิธีการทำแกรนูลเปียกจะมีการปรับเปลี่ยนคุณสมบัติของส่วนประกอบของยาเม็ดให้เหมาะสมต่อการตอกอัดเป็นยาเม็ด ซึ่งขั้นตอนที่มีส่งผลกระทบต่อคุณสมบัติของส่วนประกอบของยาเม็ดมากที่สุดคือ ขั้นตอนการผสมเปียก (Wet Mixing) ในขั้นตอนดังกล่าวจะมีปัจจัยที่เกี่ยวข้องหลายส่วน ซึ่งสามารถแบ่งได้เป็น 2 ประเภทหลัก ๆ ได้แก่ ปัจจัยที่เกี่ยวข้องกับส่วนประกอบของผลิตภัณฑ์ยา (Critical Quality Attribute : CQA) และปัจจัยที่เกี่ยวข้องกับเครื่องมือ (Critical Process Parameter : CPP) หากปัจจัยที่กล่าวมาไม่เหมาะสม ก็จะส่งผลให้แกรนูลที่ได้มีคุณสมบัติไม่เหมาะสมที่จะนำไปทำการตอกอัดได้ ดังนั้นปัจจัยดังกล่าวต้องมีการควบคุมอย่างเหมาะสม อย่างไรก็ตาม ส่วนประกอบในผลิตภัณฑ์ยาเม็ดไม่สามารถเปลี่ยนแปลงไปจากสูตรตำรับที่ขึ้นทะเบียนได้ ทำให้ไม่สามารถปรับเปลี่ยนปัจจัยที่เกี่ยวข้องกับส่วนประกอบของผลิตภัณฑ์ยาได้ ดังนั้นปัจจัยที่สามารถทำการปรับเปลี่ยนเพื่อทำการควบคุมการผลิตได้ก็คือปัจจัยที่เกี่ยวข้องกับเครื่องมือ โดยปัจจัยที่สามารถทำการปรับเปลี่ยนในกระบวนการผลิตได้ง่ายและใช้กำหนดจุดยุติขั้นตอนการผสมเปียก คือเวลาที่ใช้ในการปั่นผสมเปียก (Wet Massing Time) ซึ่งเครื่องมือที่ใช้ในการผสมเปียกบางประเภทจะใช้ความเร็วในการปั่นผสม 2 ระดับต่อการผสม 1 รอบ ทำให้การนำเวลาที่ใช้ในการปั่นผสมเปียกเป็นตัวกำหนดจุดยุติขั้นตอนการผสมเปียกทำได้ยาก อย่างไรก็ตาม การใช้จำนวนรอบในการปั่นผสมของใบพัดหลัก (Number of Impeller Revolution) สามารถสะท้อนถึงเวลาที่ใช้ในการผสมเปียกได้เช่นเดียวกัน และสะท้อนถึงการปั่นผสมทั้งขั้นตอนได้ทั้งในเครื่องผสมเปียกทั้ง 2 ชนิดได้ ดังนั้น จำนวนรอบที่ใช้ในการปั่นผสมของใบพัดหลักจึงใช้เป็นจุดยุติขั้นตอนการผสมเปียกได้เช่นกัน

การหาจุดยุติของการผสมเปียกสำหรับผลิตภัณฑ์ยาใหม่มีความสำคัญต่อกระบวนการผสมเปียกอย่างมาก หากการกำหนดจุดยุติเกิดความผิดพลาด จะส่งผลให้เกิดความเสียหายต่อแกรนูลหรือผลิตภัณฑ์ยาสุดท้ายได้ เช่น แกรนูลไม่สามารถทำการตอกอัดเป็นยาเม็ดได้ หรือยาเม็ดที่ได้ไม่สามารถสภาพการจับตัวเป็นเม็ดได้ ซึ่งการกำหนดจุดยุติของการผสมเปียกในบริษัทกรณีศึกษาในปัจจุบันจะดำเนินการโดยการทดลองการผลิต (Production Trial) เพื่อหาจุดยุติที่เหมาะสม โดยมีเภสัชกรฝ่าย

ผลิตดำเนินการทดลองการผลิต อย่างไรก็ตาม การทดลองการผลิตจะมีค่าใช้จ่ายด้านวัตถุดิบ และใช้เวลาในการทดลองการผลิตระยะหนึ่ง ทำให้เกิดการสูญเสียโอกาสทางการค้า วิธีหนึ่งที่จะช่วยให้เกษตรกรหาจุดยุติที่เหมาะสมได้ คือ การสร้างแบบจำลองที่ช่วยทำนายจุดยุติโดยอาศัยข้อมูลการผสมเปียกของผลิตภัณฑ์ที่ดำเนินการผลิตในปัจจุบัน ซึ่งจะช่วยให้เกษตรกรสามารถคาดการณ์จุดยุติของการผสมเปียกได้ง่ายขึ้น อันทำให้จำนวนครั้งในการทดลองการผลิตลดลง ซึ่งเป็นการลดค่าใช้จ่ายและเวลาในการทดลองการผลิตในที่สุด


การทำนายเป็นการคาดคะเนผลลัพธ์ต่างๆ อย่างมีระบบ ตัวอย่างของแบบจำลองการทำนายที่นิยม ได้แก่ Linear Regression และ Response Surface Method เป็นต้น ในการประยุกต์ใช้การทำนายจำเป็นต้องเข้าใจถึงสมมุติฐานของแบบจำลองการทำนายซึ่งกล่าวถึงความสัมพันธ์ระหว่างตัวแปรต้นและตัวแปรตาม ในกรณีของการประยุกต์ใช้ การทำนายปัจจัยในกระบวนการผลิตระดับ Manufacturing Scale ซึ่งมีความสัมพันธ์ซับซ้อน เกษตรกรการผลิต หรือนักวิจัย อาจไม่สามารถกำหนดแบบจำลองหรือหาความสัมพันธ์ได้ ดังนั้นแนวคิดที่มีการประยุกต์ใช้และเป็นที่ยอมรับในปัจจุบันคือโครงข่ายประสาทเทียม (Artificial Neural Network : ANN) ซึ่งแบบจำลองเพื่อค้นหาคำตอบแบบโดยมีหลักการงานเลียนแบบการเรียนรู้ของเซลล์ประสาทในสมอง และสมการถดถอยประเภทซัพพอร์ตเวกเตอร์ (Support Vector Regression : SVR)

โครงสร้างของแบบจำลอง ANN ประกอบด้วยชั้นของข้อมูล 3 ส่วน คือชั้นข้อมูลนำเข้า (Input Layer) เป็นตัวแปรต่าง ๆ ที่สนใจศึกษาในการวิจัย ชั้นข้อมูลนำออก (Output Layer) เป็นตัวแปรผลลัพธ์ที่ต้องการในการวิจัย และชั้นข้อมูลแฝง (Hidden Layer) เป็นตัวแปรที่โปรแกรมสร้างขึ้นมาจากชุดข้อมูลนำเข้า เพื่อนำไปใช้ในการวิเคราะห์ชุดข้อมูลนำออกได้ แบบจำลองดังกล่าวมีข้อดีคือสามารถใช้ได้กับข้อมูลที่มีความสัมพันธ์ที่ซับซ้อนมาก ไม่จำเป็นต้องกำหนดสมมุติฐานความสัมพันธ์ระหว่างข้อมูลนำเข้าและข้อมูลนำออกแต่มีข้อจำกัดคือแบบจำลองไม่ได้คำนึงถึงหลักการคำนวณของข้อมูลที่ได้ จึงอธิบายความสัมพันธ์ที่ได้ไม่ชัดเจน [5]



รูปที่ 1-1 ตัวอย่างโปรแกรม ANN

SVR เป็นเครื่องมือที่ใช้ในการวิเคราะห์ความสัมพันธ์ระหว่างข้อมูลนำเข้าและข้อมูลนำออก คล้ายกับการสร้างสมการถดถอยทั่วไป แต่มีความแตกต่างในหลักการของเครื่องมืออยู่ โดยหลักการของเครื่องมือนี้คือการสร้างความสัมพันธ์โดยจะมีช่วงขอบเขตออกมาจากความสัมพันธ์ที่ได้ เรียกว่า ช่วงความเบี่ยงเบน (Deviation :  $\mathcal{E}$ ) ซึ่งข้อมูลที่อยู่ภายในช่วงความเบี่ยงเบน จะไม่นำมาคิดค่าความผิดพลาด (Error :  $\xi$ ) ในขณะที่ค่าความผิดพลาดจะเกิดจากข้อมูลที่อยู่ภายนอกช่วงขอบเขต ซึ่งเป้าหมายของเครื่องมือนี้คือการสร้างความสัมพันธ์ที่มีช่วงความเบี่ยงเบนให้แคบที่สุดในขณะเดียวกัน ก็ก่อให้เกิดความผิดพลาดน้อยที่สุด [6]



รูปที่ 1-2 ตัวอย่างเครื่องมือ SVR

จากการค้นคว้างานวิจัยเกี่ยวกับเกษตรกรรมในอดีต พบว่ามีการใช้โปรแกรม ANN ในงานวิจัยด้านต่าง ๆ เช่น การตรวจหาปริมาณตัวยาสำคัญ การตรวจสอบสถานะของสารระหว่างการผลิต [7-11] ในขณะที่มีการใช้โปรแกรม SVR ในงานวิจัยด้านต่าง ๆ เช่น การตรวจหาปริมาณยาที่ซึมผ่านผิวหนังมนุษย์ [12, 13] การตรวจหาปริมาณตัวยาสำคัญ [14] หรือการตรวจสอบคุณภาพของผลิตภัณฑ์ยา [15] แต่ยังไม่มีการวิจัยที่ใช้โปรแกรม ANN หรือโปรแกรม SVR มาช่วยการทำนายปัจจัยในกระบวนการผลิต ดังนั้น ผู้วิจัยจึงสนใจที่จะใช้โปรแกรม ANN และโปรแกรม SVR เพื่อทำนายปัจจัยที่ใช้เป็นจุดยุติในการผสมเปียกของผลิตภัณฑ์ยา โดยใช้ปัจจัยอื่น ๆ ในขั้นการผสมเปียกของผลิตภัณฑ์ยา

### 1.3 วัตถุประสงค์ของวิทยานิพนธ์

เพื่อพัฒนาแบบจำลองคอมพิวเตอร์ในการทำนายจำนวนรอบการปั่นผสมของใบพัดหลักในการผลิตผลิตภัณฑ์ยาเม็ด

#### 1.4 ขอบเขตของวิทยานิพนธ์

- ผลิตรถยนต์ที่ศึกษาเป็นตำรับยาเม็ดที่ผลิตโดยวิธีการผสมเปียก
- ขั้นตอนในวิธีการผสมเปียกที่ใช้ในการศึกษา จะเป็นขั้นตอนการผสมเปียก
- คุณภาพของสารตั้งต้นผลิตรถยนต์ที่ใช้เป็นข้อมูลนำเข้าในเครื่องมือ ประกอบด้วย
  - “ค่าการละลายน้ำของผงสาร”
  - “ค่าสัมประสิทธิ์การกระจายตัวของสารในชั้นน้ำและน้ำมัน”
  - “สัดส่วนน้ำหนักสารที่ใช้ในสูตรตำรับ”
- คุณภาพของสารละลายตัวยัดเกาะที่ใช้เป็นข้อมูลนำเข้าในเครื่องมือ ประกอบด้วย
  - “ค่าความหนืดของสารละลายตัวยัดเกาะ”
  - “ปริมาณของเหลวที่เติมในสารละลายตัวยัดเกาะ”
  - “สัดส่วนปริมาณของเหลวที่เติมในสารละลายตัวยัดเกาะเมื่อเทียบกับน้ำหนักของตำรับยา”
- ปัจจัยของเครื่องผลิตที่ใช้เป็นข้อมูลนำเข้าในเครื่องมือ ประกอบด้วย
  - “ความเร็วรอบในการปั่นผสมแบบเร็ว”
  - “ความเร็วรอบในการปั่นผสมแบบช้า”
- ข้อมูลนำออกที่นำมาพิจารณาในเครื่องมือ ประกอบด้วย
  - “จำนวนรอบการปั่นผสม”
- เครื่องมือที่ใช้ในการจัดทำวิทยานิพนธ์คือ โปรแกรม MATLAB® (R2017b, MathWorks®)
- แบบจำลองที่สร้างในวิทยานิพนธ์คือแบบจำลองโครงข่ายประสาทเทียม (Artificial Neural Network) และแบบจำลองสมการถดถอยประเภทซัพพอร์ตเวกเตอร์ (Support Vector Regression)



## 1.5 ประโยชน์ของวิทยานิพนธ์

มีเครื่องมือที่ใช้ทำนายจำนวนรอบการปั่นผสมเปียกของใบพัดหลักในการผลิตผลิตภัณฑ์ยาเม็ด

## 1.6 ผลที่คาดว่าจะได้รับ

- 1) เครื่องมือที่ใช้ทำนายมีประสิทธิภาพในการทำนายจำนวนรอบการปั่นผสมของใบพัดหลักในการผลิตผลิตภัณฑ์ยาเม็ดสูง
- 2) วัสดุดิบและจำนวนครั้งที่ใช้ในการทดลองการผลิตผลิตภัณฑ์ยาเม็ดโดยเฉลี่ยลดลงเมื่อเทียบกับการทดลองการผลิตผลิตภัณฑ์เมื่อไม่ใช่โปรแกรม

## 1.7 ขั้นตอนดำเนินการจัดทำวิทยานิพนธ์

- 1) ศึกษาการใช้งานต่าง ๆ ของโปรแกรมที่ใช้ช่วยทำนายคุณภาพด้านต่าง ๆ ของผลิตภัณฑ์ยา
- 2) ศึกษาหลักการทำงานของเครื่องมือที่จะใช้ในวิทยานิพนธ์
- 3) ศึกษากระบวนการผลิตผลิตภัณฑ์ยากระบวนการผสมเปียกในขั้นตอนผสมเปียก
- 4) รวบรวมข้อมูลการผลิตผลิตภัณฑ์ยาเม็ดในขั้นตอนการผสมเปียกในบริษัทกรณีศึกษา
- 5) คัดกรองข้อมูลการทดลองผลิตผลิตภัณฑ์ยาที่ได้จากขั้นตอนที่ 4)
- 6) นำข้อมูลที่ได้จากขั้นตอนที่ 5) บางส่วนไปใส่แบบจำลอง ANN และแบบจำลอง SVR เพื่อให้เข้าสู่กระบวนการเรียนรู้
- 7) นำแบบจำลอง ANN และแบบจำลอง SVR ที่ได้ไปทดสอบความสามารถในการทำนายโดยใช้ข้อมูลที่เหลือจากขั้นตอนที่ 6)
- 8) วิเคราะห์และสรุปผลการดำเนินวิทยานิพนธ์
- 9) จัดทำรูปเล่มวิทยานิพนธ์
- 10) นำเสนอและส่งวิทยานิพนธ์

## บทที่ 2

### ทบทวนวรรณกรรมและงานวิจัยที่เกี่ยวข้อง


ในบทนี้จะกล่าวถึงการคิดค้นวิจัยผลิตภัณฑ์ยาใหม่ออกสู่ท้องตลาด ยาเม็ดและกระบวนการผลิตยาเม็ด และอธิบายระบบ ANN กับการนำระบบไปใช้งานจริง

#### 2.1 ยาเม็ดและกระบวนการผลิต

ยาเม็ด (Tablet) คือยาในรูปแบบของแข็งที่ประกอบด้วยตัวยาสำคัญ และ/หรือ ส่วนประกอบอื่น ๆ โดยมีหลายรูปร่าง เช่น ทรงกลม รูปไข่ ทรงกระบอก ทรงสามเหลี่ยม เป็นต้น ขนาดและน้ำหนักของยาเม็ดขึ้นอยู่กับปริมาณของตัวยาสำคัญที่อยู่ในยาเม็ดและวิธีการบริหารยาเม็ด การผลิตยาเม็ดจะมีด้วยกัน 2 วิธี คือวิธีการตอกอัด (Compression) เป็นการให้แรงดันแก่สารภายในยาเม็ด ทำให้เกิดการบีบอัดจนได้เป็นยาเม็ดแข็ง และวิธีการหล่อพิมพ์ (Molding) เป็นการฉีดสารภายในยาเม็ดลงในเบ้าเพื่อขึ้นรูปยาเม็ด ซึ่งยาเม็ดส่วนใหญ่ถูกผลิตจากวิธีการตอกอัด เนื่องจากวิธีดังกล่าวสามารถควบคุมคุณสมบัติของยาเม็ดได้ง่าย เช่น ความแข็ง ความหนา เป็นต้น คุณสมบัติที่จำเป็นของสารที่จะผลิตโดยวิธีการตอกอัดมีด้วยกันหลายข้อ เช่น คุณสมบัติการไหลอย่างอิสระ คุณสมบัติการยึดเกาะของสาร และคุณสมบัติการหล่อลื่น ซึ่งตัวยาสำคัญส่วนใหญ่มีคุณสมบัติดังกล่าวไม่เพียงพอ จึงต้องมีการพัฒนาสูตรตำรับเพื่อปรับปรุงคุณสมบัติของสารผสมก่อนนำไปตอกอัด [3]


กระบวนการผลิตยาเม็ดจะแบ่งออกได้เป็น 3 ประเภท ตามการจัดการของผสมของตัวยาสำคัญกับส่วนประกอบอื่น ๆ ก่อนนำไปตอกอัด ได้แก่ การตอกตรง (Direct Compression) การทำแกรนูลเปียก (Wet Granulation) และการทำแกรนูลแห้ง (Dry Granulation) โดยแต่ละวิธีมีความแตกต่างกันดังนี้ [3]

**2.1.1 การตอกตรง** เป็นวิธีที่นำอนุภาคของมวลยาเม็ดมาทำการตอกอัดโดยไม่ปรับปรุงคุณสมบัติทางกายภาพของสาร เนื่องจากสารที่จะนำมาใช้ผลิตยาเม็ดมีคุณสมบัติที่เหมาะสมต่อกระบวนการตอกอัดแล้ว เช่น มีการไหลดี มีการยึดเกาะและสามารถถูกตอกอัดได้ดี เป็นต้น การผลิตยาเม็ดวิธีนี้เป็นการผลิตที่มีประสิทธิภาพมากที่สุดเนื่องจากมีขั้นตอนต่าง ๆ น้อย ทำให้ปริมาณสารที่สูญเสียระหว่างขั้นตอนน้อย อีกทั้งยังค่าใช้จ่ายส่วนของบุคลากรและเครื่องมือต่ำด้วย [3]




รูปที่ 2-1 การผลิตยาเม็ดโดยการตอกตรง

**2.1.2 การทำแกรนูลเปียก** เป็นวิธีที่ใช้ในการผลิตยาเม็ดโดยกระบวนการตอกอัดมากที่สุด เนื่องจากวิธีดังกล่าวมีประสิทธิภาพในการปรับปรุงสารที่มีคุณสมบัติในการถูกตอกอัดไม่เหมาะสม ให้เป็นแกรนูลที่มีคุณสมบัติในการถูกตอกอัดที่เหมาะสมได้ดี โดยการเติมสารละลายของสารยึดเกาะ ซึ่งสามารถเติมได้ทั้งในรูปของสารละลาย และการพ่นเป็นละอองฝอย อย่างไรก็ตาม ข้อจำกัดของวิธีนี้คือมีขั้นตอนการผลิตมาก ทำให้ใช้เวลาในการผลิตมาก รวมถึงการเพิ่มค่าใช้จ่ายในการผลิตด้วย [3]



รูปที่ 2-2 การผลิตยาเม็ดโดยการทำแกรนูลเปียก

2.1.3 การทำแกรนูลแห้ง เป็นวิธีที่ใช้ปรับปรุงสารในตำรับยาที่มีคุณสมบัติในการตอกอัดไม่เหมาะสม ให้เป็นแกรนูลที่มีคุณสมบัติในการตอกอัดเหมาะสมเช่นเดียวกับการทำแกรนูลเปียก แต่จะมีความแตกต่างกันที่สารในตำรับยาไม่สามารถทนต่อสภาวะอุณหภูมิสูงหรือความชื้นสูงได้ โดยจะมีการอัดอนุภาคของสารที่จะทำเป็นแกรนูลให้เป็นก้อน (Slug) หรือแผ่น (Compact) โดยใช้แรงตอกอัดก่อนแล้วจึงลดขนาด Slug หรือ Compact จนได้แกรนูล ดังนั้นสารในตำรับยาจะต้องมีคุณสมบัติการยึดเกาะได้บ้างเพื่อทำให้เกิดแกรนูลได้ วิธีนี้มีขั้นตอนน้อยกว่าการผลิตยาเม็ดโดยการทำแกรนูลเปียก แต่ยังคงมีขั้นตอนมากกว่าการผลิตยาเม็ดโดยการตอกตรง [3]



รูปที่ 2-3 การผลิตยาเม็ดโดยการทำแกรนูลแห้ง

## 2.2 การผลิตยาเม็ดโดยการทำแกรนูลเปียก

การผลิตยาเม็ดโดยการทำแกรนูลเปียก หรือ Wet Granulation เป็นวิธีผลิตยาเม็ดที่ใช้กันมากในปัจจุบัน เนื่องจากเป็นวิธีที่สามารถปรับปรุงคุณสมบัติการไหลและการตอกอัดของส่วนผสมภายในเม็ดยาก่อนทำการตอกอัดได้ดี อีกทั้งยังทำให้ยาเม็ดที่ได้มีปริมาณตัวยาสำคัญเท่ากันตลอดกระบวนการได้อย่างมีประสิทธิภาพ หลักการของวิธีนี้คือการเติมสารช่วยยึดเกาะ (Binder) ลงไปในส่วนผสมของตัวยาสำคัญและสารอื่น ๆ สารยึดเกาะอาจเติมในรูปแบบของสารน้ำ หรือผงแห้งแล้วเติมน้ำลงไปภายหลัง หลังจากผสมสารทั้งหมดแล้ว จะนำไปแรงเพื่อลดขนาดอนุภาค ได้สารอนุภาคเล็กซึ่งมีความชื้นที่เรียกว่าแกรนูลเปียก (Wet Granules) ซึ่งเรียกขั้นตอนนี้ว่าการแรงเปียก (Wet Sieving) แกรนูลเปียกที่ได้จะถูกนำไปอบแห้งเพื่อลดความชื้นของแกรนูล และนำไปแรงอีกครั้งผ่านกระบวนการแรงแห้ง (Dry Sieving) จนได้อนุภาคแห้งและเล็กที่มีคุณสมบัติการไหลและการยึดเกาะดีขึ้น เรียกว่า แกรนูลแห้ง (Dry Granules) [16]


เครื่องมือที่ใช้ในการผสมในกระบวนการ Wet Granulation ในปัจจุบันจะมีทั้งหมด 3 ประเภท คือ

**2.2.1 Low-shear Mixer** เป็นเครื่องมือที่ใช้ใบพายผสม (Impeller) กวนผงแห้งและสารน้ำผสมเข้าด้วยกัน โดยจะมีการเติมผงแห้งและสารน้ำเข้าด้วยกันก่อนทำการผสม ใบพายผสมของเครื่องมือประเภทนี้มีอัตราการผสมที่ต่ำเนื่องจากมีแรงเฉือนต่ำ ทำให้การผสมเพื่อทำแกรนูลมีประสิทธิภาพต่ำ อย่างไรก็ตาม ยังมีการใช้งานเครื่องมือประเภทนี้ในกรณีที่ต้องการผสมสารที่ไม่ต้องใช้แรงเฉือนในการผสมมาก ตัวอย่างของเครื่องมือประเภทนี้คือ Sigma-blade Mixer, Planetary Mixer เป็นต้น [16]




รูปที่ 2-4 เครื่องมือ Sigma-blade Mixer และ Planetary Mixer ตามลำดับ

**2.2.2 High-shear Mixer** เป็นเครื่องผสมที่มีใบพายผสม (Impeller) กวนผสมผงแห้งภายในให้เข้ากับสารน้ำ และมีใบตัด (Chopper) ที่เพิ่มแรงเฉือนภายในหม้อผสมเพื่อทำให้อ่อนสารที่มีขนาดใหญ่เกินไปในการผสมแตกออกให้ได้ก้อนสารที่มีขนาดเหมาะสม การเติมสารน้ำในเครื่องผสมประเภทนี้จะทำการเติมในระหว่างที่เครื่องมือทำการผสม โดยสามารถเติมสารน้ำได้ในรูปแบบของละอองฝอย หรือเทเป็นสายจากด้านบนของเครื่องมือ การเติมประเภทนี้ช่วยให้สารน้ำมีการกระจายอย่างทั่วถึงทุกอนุภาคผงแห้ง และทำแกรนูลได้มีประสิทธิภาพ เครื่องมือนี้จึงถูกใช้งานในการทำแกรนูลเปียกมากในปัจจุบัน [16]



รูปที่ 2-5 เครื่องมือ High Shear Mixer

2.2.3 Fluid Bed Mixer เป็นเครื่องผสมที่อาศัยการพ่นลมไปยังกลุ่มสารภายในเครื่อง เพื่อให้กลุ่มสารมีการไหลเวียนแบบของไหล ขณะเดียวกันก็มีการเติมสารน้ำเข้าไปภายในเพื่อผสมกับกลุ่มสารภายในอย่างสม่ำเสมอทำให้ได้แกรนูล เครื่องผสมประเภทนี้ยังสามารถปรับอุณหภูมิของลมที่พ่นภายในเครื่องมือ จึงสามารถทำการอบแกรนูลให้แห้งได้ภายในเวลาไม่นาน [16]



รูปที่ 2-6 เครื่องมือ Fluidized Bed Mixer

การทำ Wet Granulation ในการผลิตผลิตภัณฑ์ยาต้องมีการควบคุมปัจจัยต่าง ๆ ในกระบวนการผลิตให้เหมาะสม โดยปัจจัยต่าง ๆ จะถูกแบ่งออกเป็น 2 กลุ่ม คือ ปัจจัยที่เกี่ยวข้องกับส่วนประกอบของผลิตภัณฑ์ยา (Critical Quality Attribute : CQA) เกี่ยวข้องกับคุณสมบัติของสารในตำรับยา อาจเป็นคุณสมบัติของส่วนประกอบรูปแบบของแข็ง เช่น ค่าการละลายน้ำหรือการเปียกน้ำของผงสารในผลิตภัณฑ์ยา ขนาดอนุภาคหรือพื้นที่ผิวสัมผัสของอนุภาคผงสาร รวมถึงความสามารถในการไหลของผงสาร หรือคุณสมบัติของส่วนประกอบรูปแบบสารละลายตัวยัดเกาะ เช่น ความชื้นหนืด ความตึงผิว รวมทั้งปริมาณน้ำที่ใช้ในสารละลาย และปัจจัยที่เกี่ยวข้องกับเครื่องมือ (Critical Process Parameter : CPP) เป็นปัจจัยที่เกี่ยวข้องกับเครื่องมือปั่นผสม เช่น ความเร็วของใบพัดหลัก (Impeller) และใบปัดรอง (Chopper) หรือเวลาที่ใช้ในการปั่นผสม ซึ่งปัจจัยทั้งสองกลุ่มมีผลกระทบซึ่งกันและกันทำให้การเปลี่ยนแปลงปัจจัยใดก็ตามต้องพิจารณาผลลัพธ์ที่เกิดขึ้นกับปัจจัยอื่นหรือคุณสมบัติของแกรนูลที่ได้ เช่น [16]

- การเปลี่ยนแปลงขนาดอนุภาคหรือพื้นที่ผิวสัมผัสของอนุภาคผงสารจะเปลี่ยนแปลงการกระจายขนาดอนุภาคหรือความพรุนของแกรนูลที่ได้
- ค่าการละลายน้ำของผงสารในสูตรตำรับมีความเกี่ยวข้องกับปริมาณของของเหลวที่ใช้ในสารละลายตัวยัดเกาะ
- ความเร็วของใบพัดหลักสามารถส่งผลกระทบต่อรูพรุนและความสามารถในการตอกอัดของแกรนูลที่ได้
- ความเร็วของใบปัดรองที่ใช้ส่งผลกระทบต่อรูปร่างและขนาดของแกรนูลที่ได้

จากความสัมพันธ์ระหว่างกลุ่มปัจจัยที่ซับซ้อน ทำให้การทำ Wet Granulation ทำนายผลลัพธ์ที่เกิดขึ้นกับแกรนูลได้ยาก และจำเป็นต้องมีการควบคุมและกำหนดปัจจัยต่าง ๆ อย่างเหมาะสมด้วย [16]

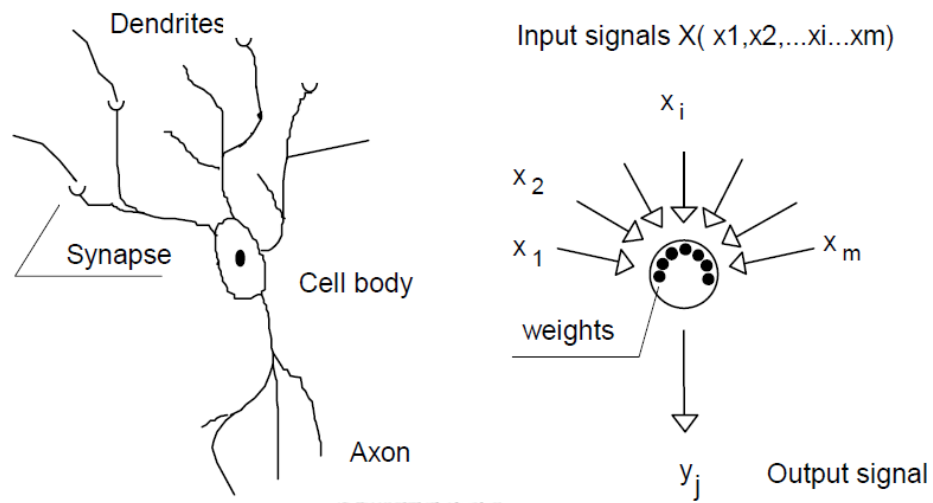


## 2.3 ระบบโครงข่ายประสาทเทียม

ระบบโครงข่ายประสาทเทียม หรือ Artificial Neural Network (ANN) เป็นระบบคอมพิวเตอร์ชนิดหนึ่งที่ใช้ในการทำนายชุดข้อมูลหนึ่งจากชุดข้อมูลอีกชุดหนึ่งคล้ายกับระบบคอมพิวเตอร์อื่น ๆ ซึ่งระบบ ANN ใช้ทำนายข้อมูลที่มีความสัมพันธ์ได้ทั้งแบบเป็นเส้นตรง (Linear Relationship) และแบบไม่เป็นเส้นตรง (Non-linear Relationship) แต่ระบบ ANN จะสามารถทำนายชุดข้อมูลที่มีความสัมพันธ์แบบไม่เป็นเส้นตรงได้มีประสิทธิภาพกว่าระบบคอมพิวเตอร์อื่น ๆ อย่างไรก็ตาม การทำงานของระบบโครงข่ายประสาทจะสนใจเฉพาะข้อมูลในระบบเท่านั้น โดยไม่อธิบายความสัมพันธ์ดังกล่าวออกมา จึงอาจเรียกว่าระบบ ANN มีการทำงานแบบ “Black box” [17]


### 2.3.1 แนวคิดและการทำงานของระบบโครงข่ายประสาทเทียม

แนวคิดการทำงานของระบบ ANN คือการเลียนแบบการทำงานของเครือข่ายเซลล์ประสาทในร่างกายมนุษย์ โดยการทำงานของเซลล์ประสาทหนึ่งเริ่มจากการรับสัญญาณประสาทจากหลาย ๆ แหล่ง เซลล์ประสาทจะประเมินความสำคัญของสัญญาณประสาทแต่ละแหล่งและส่งสัญญาณประสาทออกไปยังเซลล์ประสาทถัดไป ระบบ ANN ในคอมพิวเตอร์มีหลักการทำงานในแนวทางเดียวกันคือระบบจะรับสัญญาณนำเข้าจากหลาย ๆ แหล่ง ประเมินผลข้อมูลและส่งสัญญาณส่งออกไปยังส่วนถัดไป [17]



รูปที่ 2-7 การทำงานของเซลล์ประสาท (Neuron) และประสาทเทียม (Artificial Neuron)

ระบบ ANN จะประกอบด้วยหน่วยดำเนินการจำนวนหนึ่งที่เรียกว่า ประสาทเทียม (Artificial Neuron) ที่จะรับข้อมูลชุดหนึ่ง ประมวลผลและสร้างข้อมูลอีกชุดหนึ่ง โดยการทำงานจะเริ่มต้นเมื่อใส่ข้อมูลนำเข้า (Input Value :  $x_i$ ) เข้าไปในประสาทเทียม ประสาทเทียมจะนำข้อมูลไปประเมินความสำคัญของข้อมูลก่อน ความสำคัญมีชื่อเรียกเฉพาะว่า น้ำหนักเชื่อมโยง (Associate Weight :  $w_i$ ) น้ำหนักเชื่อมโยงที่ได้จะนำไปคูณกับข้อมูลนำเข้า แล้วจึงนำข้อมูลนำเข้าที่ดัดแปลงแล้วไปใส่ลงในฟังก์ชันได้เป็นข้อมูลนำออก (Output Value :  $y_k$ ) ข้อมูลนำออกที่ได้จากแต่ละประสาทเทียมจะถูกนำไปใช้ป้อนเป็นข้อมูลนำเข้าของประสาทเทียมลำดับถัดไปเรื่อย ๆ จนได้เป็นข้อมูลนำออกที่ต้องการในที่สุด [18]




รูปที่ 2-8 การทำงานของประสาทเทียม

จากเนื้อหาที่ได้อธิบายการทำงานของประสาทเทียม จะพบว่าประสาทเทียมเดียวจะมีการทำงานที่ค่อนข้างซับซ้อน เมื่อนำประสาทเทียมจำนวนหนึ่งมาทำงานประกอบกันแล้ว จะได้ระบบประสาทเทียมที่มีความสามารถในการทำงานที่ซับซ้อนได้เป็นอย่างดี อย่างไรก็ตาม ระบบประสาทเทียมยังสามารถแบ่งออกได้เป็นหลายประเภทตามลักษณะของระบบประสาทเทียมดังต่อไปนี้ [18]

- 1) ลักษณะการเชื่อมต่อของประสาทเทียมในระบบ (Interconnection Pattern) ขึ้นอยู่กับจำนวนชั้นย่อย (Layer) และจำนวนประสาทเทียมในแต่ละชั้นย่อยของระบบประสาทเทียม
- 2) กระบวนการเรียนรู้เพื่อปรับปรุงน้ำหนักเชื่อมโยงระหว่างประสาทเทียม
- 3) ชนิดของฟังก์ชันถ่ายโอนที่ประสาทเทียมใช้ในการคำนวณข้อมูลนำออกออกมา เช่น

- ฟังก์ชัน Log-sigmoid (Logsig) ซึ่งมีสมการเป็น  $y = \frac{1}{1+e^{-x}}$
- ฟังก์ชันเส้นตรง (Purelin) ซึ่งมีสมการเป็น  $y = x$
- ฟังก์ชัน Tan-sigmoid (Tansig) ซึ่งมีสมการเป็น  $y = \frac{e^x - e^{-x}}{e^x + e^{-x}}$



รูปที่ 2-9 กราฟเส้นของฟังก์ชันถ่ายโอนในแบบจำลอง ANN [(a) Logsig (b) Purelin (c) Tansig]

### 2.3.2 การเรียนรู้ของประสาทเทียม

กระบวนการเรียนรู้ของประสาทเทียม เริ่มจากการสุ่มค่าน้ำหนักเชื่อมโยงให้กับข้อมูลนำเข้า แต่ละตัวก่อน และนำค่าน้ำหนักเชื่อมโยงที่ได้ไปอธิบายความสัมพันธ์ระหว่างข้อมูลนำเข้าและข้อมูลนำออก เมื่อระบบเปรียบเทียบข้อมูลนำออกที่ทำนายได้กับข้อมูลนำออกค่าจริง ระบบจะทราบความแตกต่างแล้ว ประสาทเทียมภายในระบบจะทำการปรับเปลี่ยนน้ำหนักเชื่อมโยงโดยใช้ความแตกต่างที่ได้ เพื่อให้ข้อมูลนำออกที่ระบบทำนายได้ใกล้เคียงกับข้อมูลนำออกค่าจริงมากขึ้น การปรับเปลี่ยนน้ำหนักเชื่อมโยงใหม่ซ้ำแต่ละครั้งจะเรียกว่า Iteration โดยประสาทเทียมจะทำเช่นนี้ซ้ำ ๆ จนกว่าข้อมูลนำออกที่ทำนายได้จะใกล้เคียงกับข้อมูลนำออกค่าจริงในระดับที่ยอมรับได้ [18]

เมื่อระบบ ANN เรียนรู้ความสัมพันธ์ระหว่างข้อมูลนำเข้าและข้อมูลนำออกเสร็จสิ้น จะมีการประเมินประสิทธิภาพในการทำนายของระบบ ANN โดยนำข้อมูลที่เตรียมไว้อีกชุดหนึ่งไปทดสอบว่าข้อมูลนำออกที่ได้จากระบบจะใกล้เคียงกับข้อมูลนำออกค่าจริงมากเท่าใด โดยค่าที่ใช้ประเมินคือค่า Sum of Squared Error (SSE) ดังสมการที่ (1) [18]

$$SSE = \frac{1}{N} \sum_{p=1}^N \sum_{i=1}^M (t_{pi} - o_{pi})^2 \quad (1)$$

โดย  $o_{pi}$  = ค่าข้อมูลนำออกที่ทำนายได้จากระบบตัวที่  $i$  จากตัวอย่างที่  $p$

$t_{pi}$  = ค่าข้อมูลนำออกค่าจริงตัวที่  $i$  จากตัวอย่างที่  $p$

$N$  = จำนวนตัวอย่างที่ใช้ทดสอบ

$M$  = จำนวนข้อมูลนำออกที่ได้

การปรับเปลี่ยนน้ำหนักเชื่อมโยงภายในระบบ ANN เพื่อให้ได้ค่า SSE น้อยที่สุดนั้นมักจะใช้วิธี Error Back-Propagation หลักการคือระบบจะนำความแตกต่างในการทำนายผลลัพธ์ไปปรับปรุงค่าน้ำหนักของข้อมูลเริ่มต้นที่ชั้น Output layer ก่อน แล้วจึงทำการปรับปรุงค่าน้ำหนักของข้อมูลในชั้นก่อนหน้าไปจนถึงชั้นบนสุดที่เป็นชั้นข้อมูลนำเข้า ซึ่งการปรับข้อมูลจะมีการคำนวณความผิดพลาด หรือ Error ระหว่างข้อมูล Output Value กับ Target Value ดังสมการที่ 2 [17]

$$\delta \varepsilon_i = y_i - t_i \quad (2)$$

โดย  $\delta \varepsilon_i$  = ค่า Error ของ Output value ตัวที่ i

$y_i$  = ค่า Output value ตัวที่ i


$t_i$  = ค่า Target value ตัวที่ i

เมื่อได้ค่า Error แล้ว ระบบจะนำข้อมูลไปปรับปรุงค่าน้ำหนักของข้อมูลใหม่ให้ข้อมูล Output value มีความใกล้เคียงค่า Target value มากขึ้นตามวิธี Gradient Descent Method ตามสมการที่ (3) [17]

$$\Delta w_{ji}^l = \eta \delta_j^l y_i^{l-1} + \mu \Delta w_{ji}^{l(\text{previous})} \quad (3)$$

โดยที่  $\eta$  = ค่า learning rate ของสมการ โดยจะมีค่าระหว่าง 0.1 ถึง 0.9

$\mu$  = ค่า momentum ของสมการ โดยจะมีค่าระหว่าง 0.1 ถึง 0.9



รูปที่ 2-10 หลักการเรียนรู้ของวิธี Error Back-propagation

### 2.3.3 ประเภทของระบบโครงข่ายประสาทเทียม


โดยทั่วไปแล้ว ระบบ ANN สามารถแบ่งออกเป็น 2 ประเภทตามการส่งถ่ายสัญญาณข้อมูลภายในระบบ คือ Static ANN และ Dynamic ANN [18]

- **Static ANN** เป็น ANN ประเภทที่ทำงานโดยการวิเคราะห์ข้อมูลที่ให้กับระบบทีละชุดโดยไม่นำข้อมูลที่ใส่ก่อนหน้ามาร่วมในการวิเคราะห์ โดย ANN ประเภทนี้มีด้วยกันอยู่หลายชนิด ได้แก่ [18]

- **Multilayer Perceptron (MLP)** เป็นระบบ ANN ที่มีการใช้งานมากที่สุดการวิจัยและพัฒนาเชิงประสาทกรรม โดย MLP ประกอบด้วยชั้นของประสาทเทียมหลายชั้น ซึ่งประสาทเทียมในชั้นที่ติดกันมีการเชื่อมโยงกันอย่างสมบูรณ์ ความสัมพันธ์ที่ประสาทเทียมแต่ละตัวใช้ (ยกเว้นประสาทเทียมของข้อมูลนำเข้า) เป็นความสัมพันธ์แบบ Non-linear Regression และความสัมพันธ์ระหว่างข้อมูลนำเข้าและข้อมูลส่งออกที่ได้จากทั้งระบบจะแสดงออกได้ดังสมการที่ (4) [18]

$$y_i = f_o \left[ \sum_{o=1}^{N_o} b_o + \sum_{h=1}^{N_h} w_{ho} \cdot f_h \left( b_o + \sum_{i=0}^{N_i} w_{ih} x_i \right) \right] \quad (4)$$

โดย  $x_i$  = ข้อมูลนำเข้าตัวที่  $i$   
 $y_i$  = ข้อมูลนำออกตัวที่  $i$   
 $w_{ih}$  = ค่าน้ำหนักเชื่อมโยงระหว่างข้อมูลนำเข้า-Hidden Unit  
 $w_{ho}$  = ค่าน้ำหนักเชื่อมโยงระหว่างข้อมูลนำออก Hidden Unit  
 $f_h$  และ  $f_o$  = ฟังก์ชันคำนวณของชั้น Hidden และข้อมูลนำออก ตามลำดับ  
 $b_h$  และ  $b_o$  = ค่า Bias ของ Hidden-Unit และข้อมูลนำออก ตามลำดับ



รูปที่ 2-11 ระบบ ANN ประเภท MLP แบบ 4 ชั้น

- **Generalized Regression Neural Network (GRNN)** เป็นระบบ ANN สามารถเรียนรู้ได้เร็วกว่า MLP โดยระบบจะวิเคราะห์ฟังก์ชันจากข้อมูลที่ได้โดยตรงจากวิธีการคาดคะเนฟังก์ชันทางสถิติ (Statistical Method of Function Approximation) ระบบนี้จะมีชั้นของประสาทเทียม 4 ชั้น ได้แก่ ชั้นข้อมูลนำเข้า, ชั้น Radial Layer, ชั้น Regression Layer และชั้นข้อมูลนำออก ชั้น Radial Layer เป็นชั้นประสาทเทียมที่รวมข้อมูลที่ให้ระบบเรียนรู้ ออกเป็นกลุ่ม ๆ ซึ่งวิธีแบ่งกลุ่มมีด้วยกันหลายวิธี เช่น sub-sampling, K-mean หรือ Kohonen เป็นต้น ส่วนชั้น Regression Layer ที่มีจำนวนประสาทเทียมมากกว่าชั้นข้อมูลนำออก 1 ตัวเสมอจะมีฟังก์ชันการทำงานแบบเส้นตรง ประสาทเทียมที่เพิ่มขึ้นมา 1 ตัวนั้นจะใช้คำนวณความหนาแน่นของความน่าจะเป็น (Probability Density) ในขณะที่ประสาทเทียมที่เหลือใน Regression Layer จะใช้คำนวณข้อมูลนำออกตามปกติ แล้วชั้นข้อมูลนำออกจะนำข้อมูลนำออกที่ได้ก่อนหน้าไปปรับด้วย Probability Density จนได้ออกมาเป็นข้อมูลนำออกสุดท้ายดังสมการที่ (5) [18]

$$\hat{y} = \frac{\sum_{i=1}^n y_i \exp(-D(x, x_i))}{\sum_{i=1}^n \exp(-D(x, x_i))} \quad (5)$$


โดย ค่า D หรือระยะห่างระหว่างตัวอย่างที่ใช้เรียนรู้กับจุดทำนาย คำนวณได้ใน

สมการที่ (6)

$$D(x, x_i) = \sum_{j=1}^p \left( \frac{x_j - x_{j,i}}{\sigma_j} \right)^2 \quad (6)$$

โดยที่  $\sigma$  = ส่วนเบี่ยงเบนมาตรฐาน





รูปที่ 2-12 ระบบ ANN ประเภท GRNN

- **Dynamic ANN** หรือ Recurrent ANN เป็นระบบ ANN ที่มีความสามารถในการเก็บข้อมูลชุดก่อนหน้าและนำไปประเมินร่วมกับข้อมูลชุดปัจจุบันเพื่อให้ได้ข้อมูลนำออกชุดใหม่ ซึ่งเป็นข้อดีของระบบนี้เมื่อเทียบกับ Static ANN โดย Dynamic ANN ที่มักใช้งานบ่อยที่สุดคือ Elman Neural Network (ENN) หรือ Simple Dynamic Neural Network เป็นระบบ ANN ที่มีประสาทเทียมความจำ (Memory Neuron) เพิ่มขึ้นมา กลุ่มประสาทเทียมความจำจะรับข้อมูลที่ได้จากชั้น Hidden Layer มาเก็บไว้และจะนำส่งข้อมูลที่เก็บไว้ให้กับชั้น Hidden Layer อีกครั้งเมื่อมีข้อมูลนำเข้าสู่ชุดใหม่เข้ามา เรียกกระบวนการนำส่งข้อมูลซ้ำประเภทนี้ว่า One-step Time Delay โดยข้อมูลนำออกสามารถทำนายได้ดังสมการที่ (7)

[18]

$$y_i = f_o \left[ \sum_{o=1}^{N_o} b_o + \sum_{h=1}^{N_h} w_{ho} \cdot f_h (b_o + \sum_{i=0}^{N_i} w_{ih} x_i + \sum_{j=0}^{N_h} w_{jh} a_h (k-1)) \right] \quad (7)$$

โดยที่  $x_i$  = ข้อมูลนำเข้าตัวที่  $i$

$y_i$  = ข้อมูลนำออกตัวที่  $i$

$w_{ih}, w_{jh}$  และ  $w_{ho}$  = ค่าน้ำหนักเชื่อมโยงระหว่างข้อมูลนำเข้า-Hidden Unit,


ข้อมูล Copied-Hidden Unit และ Hidden Unit-ข้อมูลนำ

ออก ตามลำดับ

$f_h$  และ  $f_o$  = ฟังก์ชันคำนวณของชั้น Hidden และข้อมูลนำออก

ตามลำดับ

$b_h$  และ  $b_o$  = ค่า Bias ของ Hidden Unit และข้อมูลนำออก ตามลำดับ



รูปที่ 2-13 รูปแบบการทำงานของ Elman Neural Network

#### 2.3.4 งานวิจัยที่เกี่ยวข้อง

ในช่วงเวลาที่ผ่านมา โปรแกรม ANN เริ่มถูกนำมาใช้ในการวิจัยทางเภสัชกรรมด้านต่าง ๆ โดยรูปแบบของโปรแกรม ANN ก็มีความแตกต่างกันไปตามลักษณะของงานวิจัย โดยมีรายละเอียดของงานวิจัยต่าง ๆ ดังนี้

ในปี 2010 ได้มีการวิจัยเกี่ยวกับการตรวจสอบปริมาณของตัวยาสสำคัญหลาย ๆ ชนิดพร้อมกันโดยไม่มีกระบวนการแยกตัวยาสสำคัญออกจากกัน การตรวจสอบปริมาณตัวยาสสำคัญใช้วิธี UV spectrophotometry ในช่วงความยาวคลื่นระหว่าง 220 – 300 นาโนเมตร ในการวิจัยนี้โปรแกรม

ANN ถูกนำมาใช้ในการตรวจสอบปริมาณตัวยาสำคัญโดยใช้กราฟของการดูดกลืนแสง (Absorbance) ชั้น Training มี Input value คือกราฟการดูดกลืนแสงที่ความยาวคลื่น 81 ค่า จำนวน 16 ตัวอย่าง แต่ละตัวอย่างแตกต่างกันตามความปริมาณตัวยาสำคัญทั้ง 4 ชนิด มี Hidden Layer เพียงชั้นเดียว และมี Output Value ทั้งหมด 4 ค่า คือปริมาณตัวยาสำคัญทั้ง 4 ชนิด ฟังก์ชันที่ใช้ใน Hidden Layer และ Output Layer คือฟังก์ชัน “tansig” และฟังก์ชัน “purelin” ตามลำดับ จากนั้นในชั้น Validation จึงใช้ค่าทางสถิติต่าง ๆ ช่วยประเมินความแม่นยำในการวัดค่า Output Value เช่น Standard Error of Prediction (SEP),  $R^2$  เป็นต้น ซึ่งผลลัพธ์ได้แสดงให้เห็นว่าโปรแกรม ANN มีประสิทธิภาพในการวัดค่าความเข้มข้นของตัวยาสำคัญทั้ง 4 ชนิดที่ผสมกันอยู่ได้จริง โดยมีค่า SEP ของตัวยาสำคัญทั้ง 4 ชนิด คือ 0.148, 0.308, 0.295 และ 0.323 และค่า  $R^2$  ของตัวยาสำคัญทั้ง 4 ชนิด คือ 0.984, 0.980, 0.987 และ 0.975 [7]

ในปี 2011 ได้มีงานวิจัยที่ใกล้เคียงกับงานวิจัยในปีก่อน โดยงานวิจัยเกี่ยวข้องกับการวัดปริมาณตัวยาสำคัญที่ผสมกันอยู่ 2 ชนิด โดยใช้วิธี UV spectrophotometry ในการตรวจสอบ เช่นเดียวกัน ซึ่งโปรแกรม ANN ถูกนำไปใช้ตรวจสอบปริมาณตัวยาสำคัญจากกราฟการดูดกลืนแสง เช่นเดียวกัน โดย Input Value คือกราฟการดูดกลืนแสงจำนวน 25 ตัวอย่าง แต่ละตัวอย่างแตกต่างกันตามปริมาณตัวยาสำคัญทั้ง 2 ชนิดและสารปนเปื้อน (Impurities) ของตัวยาสำคัญอีก 4 ชนิด โดยแต่ละชนิดมีความเข้มข้นแตกต่างกัน 5 ระดับ มี Hidden layer ชั้นเดียว และ Output value มีทั้งหมด 6 ค่าคือปริมาณสารที่ต้องกันทั้ง 6 ชนิด สิ่งที่เปรียบเทียบในการวิจัยนี้คือการใช้โมเดลระหว่าง Linear Model และ Nonlinear Model ซึ่งฟังก์ชันที่ใช้ในโมเดลทั้ง 2 ชนิด คือ Purelin-Purelin และ Tansig-Purelin ตามลำดับ โดยวัดความแม่นยำในการให้ค่า Output โดยใช้ค่าต่าง ๆ เช่น Root Mean Square Error of Prediction (RMSEP), Root Mean Square Error of Calibration (RMSEC) และ Root Mean Square Error of Cross Validation (RMSECV) วัดความแม่นยำในการวัดความเข้มข้นของสาร ซึ่งผลปรากฏว่าโปรแกรม ANN สามารถใช้ในการวัดปริมาณสารต่าง ๆ ได้ดีเนื่องจากมีค่าต่าง ๆ ข้างต้นต่ำ [8]

ในปี 2013 ได้มีงานวิจัยที่เกี่ยวข้องกับการนำ ANN ไปใช้ตรวจวัดปริมาณด้วยาสาคัญที่ผสมกัน โดยลักษณะโปรแกรมและการใช้ค่าเพื่อตรวจสอบความแม่นยำของการวัดปริมาณสารเหมือนกับการวิจัยก่อนหน้านี้ คือโปรแกรม ANN มีทั้งหมด 3 ชั้น คือ ชั้น Input Layer ซึ่งมี Input Value ทั้งหมด 25 ตัวอย่าง แต่ละตัวอย่างแตกต่างกันที่ปริมาณด้วยาสาคัญที่ใช้ 4 ชนิด, ชั้น Hidden Layer และ ชั้น Output Layer ที่ให้ Output Value 4 ค่า คือปริมาณด้วยาสาคัญ 4 ชนิด ซึ่งผลลัพธ์ที่ได้คือโปรแกรม ANN สามารถตรวจปริมาณด้วยาสาคัญได้ดีจากการประเมินค่า RMSEC และ RMSEP ที่ต่ำ [9]

ในปี 2015 ได้เริ่มมีงานวิจัยที่นำโปรแกรม ANN ไปใช้ในงานวิจัยแตกต่างออกไปจากแนวทางการวิจัยเดิมที่เกี่ยวข้องกับการวิเคราะห์ปริมาณสาร เป็นการวิจัยที่เกี่ยวข้องกับกระบวนการผลิตผลิตภัณฑ์ยาแทน โดยงานวิจัยนี้เกี่ยวกับการทำนายอุณหภูมิภายในเครื่องทำแกรนูลประเภท Fluidized Bed Granulator โดยใช้ Process Analytical Technology (PAT) ร่วมกับโปรแกรม ANN ซึ่งมีทั้งหมด 4 ชั้น คือ ชั้น Input Layer ซึ่งมี Input Value คือตำแหน่งภายในเครื่องทำแกรนูล, อัตราการพ่นของเหลวภายในเครื่อง และค่าอุณหภูมิที่ตั้งไว้, ชั้น Hidden Layer จำนวน 2 ชั้น และชั้น Output Layer คืออุณหภูมิภายในเครื่อง ณ ตำแหน่งต่าง ๆ ซึ่งข้อมูลที่ใช้ทั้งหมด 432 ชุด จะแบ่งออกเป็นชั้น Training จำนวน 70%, ชั้น Calibration จำนวน 15% และชั้น Validation จำนวน 15% โดยผลลัพธ์ออกมาได้ว่าโปรแกรม ANN สามารถทำนายอุณหภูมิภายในเครื่องมือ ณ จุดต่าง ๆ ได้แม่นยำมาก พิจารณาจากค่า  $R^2 = 0.994$  [10]

ในปี 2016 มีผู้วิจัยได้วิจัยเกี่ยวกับการนำโปรแกรม ANN ไปใช้ทำนายเกี่ยวกับกระบวนการผลิตผลิตภัณฑ์ยา โดยในงานวิจัยนี้เกี่ยวกับการทำนายขนาดอนุภาคของผงที่จะได้ออกมาจากการใช้เครื่องมือ Twin-screw Extruder รูปแบบ ANN ที่ใช้ในงานวิจัยนี้มี 4 ชั้น คือ Input Layer ที่มี Input Value 16 ชุด แต่ละชุดประกอบด้วยรูปแบบของสกรู อัตราส่วนของเหลวต่อของแข็ง ความเร็วของการหมุนสกรู อัตราการไหลของผง ชั้น Hidden Layer จำนวน 2 ชั้น และชั้น Output Layer ที่ให้ค่าขนาดอนุภาคออกมา 3 ค่า คือค่า d10, d50 และ d90 ความแตกต่างของงานวิจัยนี้จากงานวิจัยอื่น ๆ คืองานวิจัยนี้ได้มีการทดลองเปลี่ยนแปลงรูปแบบของโปรแกรม ANN เพื่อพิจารณาว่ารูปแบบ

ANN แบบใดที่มีความเหมาะสมที่สุดในการทำงานวิจัยชิ้นนี้ โดยมีการเปลี่ยนแปลงความสัมพันธ์ที่ Hidden Layer ว่าจะเป็นรูปแบบ Linear Model หรือ Nonlinear Model โดยใช้ค่า Root Mean Square Error (RMSE) ในพิจารณา และการพิจารณาความแม่นยำในการทำนายขนาดอนุภาค พิจารณาจากค่า  $R^2 = 0.99$  แสดงให้เห็นว่าการใช้โปรแกรม ANN ในการทำนายขนาดอนุภาคมีความแม่นยำมาก [11]

ตารางที่ 2-1 เปรียบเทียบการศึกษาทางเภสัชกรรมโดยใช้โปรแกรม ANN

ปี	การใช้งาน ANN	จำนวนชั้น ANN	การประยุกต์ เครื่องมือ ANN	การประเมิน ประสิทธิภาพ การทำนาย
2010	วิเคราะห์ปริมาณสารจากกราฟ UV Spectrophotometry	3	- ใช้ PCA เพื่อลดข้อมูล นำเข้าใน ANN	SEP, $R^2$
2011	วิเคราะห์ปริมาณสาร จากกราฟ UV Spectrophotometry	3	- ใช้การวิเคราะห์ SVR, GA ร่วมกับ ANN - เปรียบเทียบประเภท ฟังก์ชันของ ANN ที่ เหมาะสมในการทำนาย	RMSEC, RMSEP, RMSECV
2013	วิเคราะห์ปริมาณสาร จากกราฟ UV Spectrophotometry	3	- เปรียบเทียบวิธีวิเคราะห์ แบบ ANN กับแบบ PLS	RMSEC, RMSEP
2015	ทำนายอุณหภูมิภายในเครื่องอบแห้ง ประเภท Fluidized Bed	4	-	$R^2$
2016	ทำนายคุณภาพของแกรนูลจากเครื่อง Twin-Screw Extruder	4	- เปรียบเทียบประเภท ฟังก์ชัน, จำนวนประสาท เทียมของ ANN ที่เหมาะสม ในการทำนาย	$R^2$

## 2.4 แบบจำลองสมการถดถอยประเภทซัพพอร์ตเวกเตอร์

แบบจำลองสมการถดถอยประเภทซัพพอร์ตเวกเตอร์ เป็นรูปแบบหนึ่งของเครื่องจักรประเภทซัพพอร์ตเวกเตอร์ (Support Vector Machine : SVM) คือเครื่องมือเรียนรู้ที่ดำเนินการเพื่อการจำแนกข้อมูลออกเป็นกลุ่ม ๆ เครื่องมือนี้ถูกสร้างขึ้น ณ AT & T Bell Laboratories นำโดย Vapnik และคณะ โดยเครื่องมือนี้มีรูปแบบการใช้งานทั้งหมด 2 ส่วน คือ Support Vector Classification (SVC) ที่ใช้ในการจำแนกข้อมูลออกเป็นกลุ่ม ๆ และ Support Vector Regression (SVR) ที่ใช้ในการทำนายผลลัพธ์จากข้อมูลต่าง ๆ ในงานวิจัยนี้ผู้วิจัยจะนำเครื่องมือในส่วนของ SVR มาใช้ จึงขอกล่าวถึงรายละเอียดเกี่ยวกับ SVR ต่อไป [6]

### 2.4.1 หลักการของแบบจำลองสมการถดถอยประเภทซัพพอร์ตเวกเตอร์

การทำงานของ SVR จะเป็นการสร้างแบบจำลองโดยใช้ข้อมูลฝึกฝนจำนวนหนึ่งคือ  $(x, y) \subset \mathcal{X} \times \mathcal{Y}$  โดยที่  $\mathcal{X}$  คือขอบเขตรูปแบบของข้อมูลฝึกฝน โดยมีเป้าหมายคือการสร้างฟังก์ชัน  $f(x)$  ที่มีขอบเขตการเบี่ยงเบนจากค่า  $y_i$  ที่ต้องการมากที่สุดไม่เกินค่า  $\mathcal{E}$  สำหรับทุกชุดข้อมูลฝึกฝนในขณะที่ฟังก์ชันมีความแบนราบให้มากที่สุดเท่าที่เป็นไปได้ โดยรูปแบบ  $f(x)$  จะแสดงดังสมการที่ (8) [6]

$$f(x) = \langle \omega, x \rangle + b; \quad \omega \in \mathcal{X}, b \in \mathcal{Y} \quad (8)$$

โดยที่  $\langle \cdot, \cdot \rangle$  แสดงถึงการคูณแบบสเกลาร์ของเวกเตอร์ใน  $\mathcal{X}$  และความแบนราบของฟังก์ชันจะแสดงในรูปของค่า  $\omega$  หากค่า  $\omega$  น้อยจะบ่งบอกได้ว่ามีความแบนราบของฟังก์ชันที่มาก ดังนั้นเป้าหมายที่ต้องการในการสร้างฟังก์ชัน  $f(x)$  จะมีด้วยกันดังนี้ [6]

จุดประสงค์      ทำให้ค่า  $\frac{1}{2} \|\omega\|^2$  น้อยที่สุด

$$\text{สมการข้อจำกัด} \begin{cases} y_i - \langle \omega, x \rangle - b \leq \mathcal{E} \\ \langle \omega, x \rangle + b - y_i \leq \mathcal{E} \end{cases} \quad (9)$$

โดยที่  $\|\dots\|$  แสดงถึงขนาดความยาวของเวกเตอร์

การสร้างฟังก์ชัน  $f(x)$  จะมีความสมบูรณ์หากทุก  $(x_i, y_i)$  อยู่ภายใต้เงื่อนไขของสมการข้อจำกัด แต่โดยทั่วไปจะเกิดความไม่สมบูรณ์ในการสร้างฟังก์ชัน แบบจำลองนี้จึงเพิ่มตัวแปรขาด (Slack Variable) คือ  $\xi_i, \xi_i^*$  ขึ้นเพื่อแก้ปัญหาดังกล่าว จึงได้เงื่อนไขของฟังก์ชัน  $f(x)$  ใหม่ดังนี้ [6]


จุดประสงค์ ทำให้ค่า  $\frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*)$  น้อยที่สุด

$$\text{สมการข้อจำกัด} \begin{cases} y_i - \langle \omega, x \rangle - b \leq \varepsilon + \xi_i \\ \langle \omega, x \rangle + b - y_i \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases} \quad (10)$$

โดยที่ค่าคงที่  $C > 0$  จะขึ้นอยู่กับความแบนราบของฟังก์ชัน  $f$  และความแปรผันของค่าทำนายที่เกินกว่า  $\varepsilon$  ซึ่งแสดงในรูปของ  $|\xi|_\varepsilon$  โดยมีการคำนวณดังสมการที่ (11)

$$|\xi|_\varepsilon = \begin{cases} 0 & \text{ถ้า } |\xi| < \varepsilon \\ |\xi| - \varepsilon & \text{ถ้า } |\xi| \geq \varepsilon \end{cases} \quad (11)$$

รูปแบบของสมการต่าง ๆ สามารถแสดงได้ดังรูปที่ 2-14



รูปที่ 2-14 แสดงการเกิดแบบจำลอง SVR

จากเงื่อนไขต่าง ๆ ของฟังก์ชัน  $f(x)$  สามารถใช้วิธี Lagrange multipliers ในการแก้ปัญหาได้เป็นสมการที่ (12) [6]

$$L = \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) - \sum_{i=1}^n \alpha_i (\mathcal{E} + \xi_i - y_i + \langle \omega, x \rangle + b) - \sum_{i=1}^n \alpha_i^* (\mathcal{E} + \xi_i^* + y_i - \langle \omega, x \rangle - b) - \sum_{i=1}^n (\eta_i \xi_i + \eta_i^* \xi_i^*) \quad (12)$$

โดยตัวแปร Lagrange multipliers ที่มีคือ  $\alpha_i, \alpha_i^*, \eta_i, \eta_i^* \geq 0$  โดยการทำอนุพันธ์แยกส่วน (Partial Derivative) กับค่า L เทียบกับตัวแปรดั้งเดิม  $(\omega, b, \xi_i, \xi_i^*)$  จะได้สมการที่ (13) (14) และ (15) [6]

$$\frac{\partial L}{\partial b} = \sum_{i=1}^n (\alpha_i^* - \alpha_i) = 0 \quad (13)$$

$$\frac{\partial L}{\partial \omega} = \omega - \sum_{i=1}^n (\alpha_i^* - \alpha_i) x_i = 0 \quad (14)$$

$$\frac{\partial L}{\partial \xi_i^{(*)}} = C - \alpha_i^{(*)} - \eta_i^{(*)} = 0 \quad (15)$$

เมื่อนำสมการ (13) (14) และ (15) ที่ได้ข้างต้นไปแทนลงในสมการ (12) จะได้เงื่อนไขของฟังก์ชัน  $f(x)$  ดังนี้ [6]

จุดประสงค์ ทำให้ค่า  $\{-\frac{1}{2} \sum_{i,j=1}^n (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) \langle x_i, x_j \rangle - \mathcal{E} \sum_{i=1}^n (\alpha_i + \alpha_i^*) + \sum_{i=1}^n y_i (\alpha_i - \alpha_i^*)\}$  น้อยที่สุด

$$\text{สมการข้อจำกัด } \sum_{i=1}^n (\alpha_i - \alpha_i^*) = 0 \text{ และ } \alpha_i, \alpha_i^* \in [0, C] \quad (16)$$

จากสมการที่ (14) จะสามารถเขียนใหม่ได้เป็น  $\omega = \sum_{i=1}^n (\alpha_i^* - \alpha_i) x_i$  ซึ่งแทนในสมการที่ (8) ได้ดังนี้ [6]

$$f(x) = \sum_{i=1}^n (\alpha_i^* - \alpha_i) \langle x_i, x \rangle + b \quad (17)$$

จากสมการที่ (17) การคำนวณค่า b จะทำได้โดยเงื่อนไข Karush-Kuhn-Tucker (KKT condition) จะได้สมการใหม่ดังนี้ [6]



$$\begin{aligned}\alpha_i(\mathcal{E} + \xi_i - y_i + \langle \omega, x \rangle + b) &= 0 \\ \alpha_i^*(\mathcal{E} + \xi_i^* + y_i - \langle \omega, x \rangle - b) &= 0\end{aligned}\quad (18)$$

$$\begin{aligned}(C - \alpha_i)\xi_i &= 0 \\ (C - \alpha_i^*)\xi_i^* &= 0\end{aligned}\quad (19)$$

ความสัมพันธ์ที่ได้ทำให้สามารถสรุปได้ว่า

1) หากมีชุดข้อมูล  $(x_i, y_i)$  ใดที่ไม่อยู่ภายในช่วง  $\mathcal{E}$  จะทำให้  $\alpha_i^{(*)} = C$

2) เนื่องจากเป็นไปไม่ได้ที่จะเกิดค่า  $\alpha_i = 0$  หรือ  $\alpha_i^* = 0$  พร้อมกันในทั้งสองทิศทาง

จึงทำให้  $\alpha_i \alpha_i^* = 0$

3) เมื่อ  $\alpha_i^{(*)} \in (0, C)$  แล้ว จะทำให้  $\xi_i^{(*)} = 0$  (จากสมการที่ (18)) ดังนั้น จะได้ค่า

b ออกมาดังนี้

$$\begin{aligned}b &= y_i - \langle \omega, x_i \rangle - \mathcal{E} && \text{เมื่อ } \alpha_i \in (0, C) \\ b &= y_i - \langle \omega, x_i \rangle + \mathcal{E} && \text{เมื่อ } \alpha_i^* \in (0, C)\end{aligned}\quad (20)$$

จากสมการที่ (18) จะสังเกตได้ว่าหาก  $|f(x_i) - y_i| \geq \mathcal{E}$  แล้ว อาจจะทำให้ Lagrange multipliers ไม่เป็นศูนย์ได้ ในอีกนัยหนึ่ง หาก  $|f(x_i) - y_i| < \mathcal{E}$  จะทำให้ค่าในตัวประกอบที่สองของสมการที่ (18) ไม่เป็นศูนย์ ดังนั้นค่าของ  $\alpha_i, \alpha_i^*$  จะเป็นศูนย์ซึ่งตรงตามเงื่อนไข KKT จากที่กล่าวมาทั้งหมดแล้ว จึงสรุปได้ว่า  $\omega$  สามารถแสดงในรูปของ  $x_i$  ที่ไม่ได้อยู่ในช่วง  $\mathcal{E}$  โดยสัมพันธ์ภายใน  $\omega$  จะถูกเรียกว่า Support Vectors [6]

ในกรณีที่ความสัมพันธ์ของข้อมูลไม่เป็นแบบเส้นตรง เครื่องมือจะทำการเปลี่ยนแปลงรูปแบบข้อมูลฝึกฝน  $x_i$  ภายใต้อฟังก์ชัน  $\phi: X \rightarrow Z$  โดยที่  $Z$  คือรูปแบบข้อมูลที่เปลี่ยนแปลงแล้ว จะได้สมการใหม่คือ [6]

$$\omega = \sum_{i=1}^n (\alpha_i^* - \alpha_i) \phi(x_i) \quad (21)$$

จึงได้สมการของฟังก์ชันใหม่คือ

$$f(x) = \sum_{i=1}^n (\alpha_i^* - \alpha_i) k(x_i, x) + b \quad (22)$$

โดยที่  $\alpha_i, \alpha_i^*$  คือ Lagrange Multiplier และ  $k(x_i, x)$  คือ Kernel Function ที่แสดงถึงการคูณแบบสเกลาร์ของตัวแปรที่มีความสัมพันธ์แบบไม่เป็นเส้นตรง เพื่อให้ข้อมูลที่ซับซ้อนมากขึ้น และสร้างกราฟของฟังก์ชัน  $f(x)$  ได้อย่างมีประสิทธิภาพมากขึ้น [6]

$$k(x_i, x) = \varphi(x_i) \varphi(x) \quad (23)$$

โดยที่ Kernel Function ที่ใช้ใน SVR จะมีด้วยกัน 3 ประเภท คือ

- Linear Kernel ซึ่งมีความสัมพันธ์คือ  $k(x_i, x) = x_i^T x$
- Gaussian Kernel ซึ่งมีความสัมพันธ์คือ  $k(x_i, x) = e^{-\|x_i - x\|^2}$
- Polynomial Kernel ซึ่งมีความสัมพันธ์คือ  $k(x_i, x) = (1 + x_i^T x)^q$  เมื่อ  $q$  คืออันดับของพหุนาม

ค่า  $\alpha_i, \alpha_i^*$  จะพิจารณาจากการทำให้ค่าความเสี่ยงทั่วไป (Regularized Risk) ของฟังก์ชันต่ำที่สุด

$$R_{reg}[f] = \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n L_\varepsilon(y) \quad (24)$$

ตัวแปร  $\|\omega\|^2$  แสดงถึงความซับซ้อนของแบบจำลอง ในขณะที่ค่า  $C$  แสดงถึงความแบนราบของแบบจำลอง ในขณะที่ค่าของฟังก์ชันที่สูญเสียจากการออกนอกช่วง  $\mathcal{E}$  หรือค่า  $L_\varepsilon(y)$  จะคำนวณดังสมการ [6]

$$L_\varepsilon(y) = \begin{cases} 0 & \text{ถ้า } |f(x) - y| < \varepsilon \\ |f(x) - y| - \varepsilon & \text{ถ้า } |f(x) - y| \geq \varepsilon \end{cases} \quad (25)$$

#### 2.4.2 งานวิจัยที่เกี่ยวข้อง

ในกลุ่มงานวิจัยทางด้านเภสัชกรรม มีงานวิจัยบางส่วนได้นำแบบจำลอง SVR ไปใช้ในการช่วยทำนายค่าต่าง ๆ โดยงานวิจัยเริ่มแรกนั้นจะเกี่ยวข้องกับการทดสอบคุณสมบัติต่าง ๆ ของยา เช่น งานวิจัยของ Baba ที่เป็นการทำนายผลของตัวทำละลายต่อการซึมผ่านของสารในผิวหนังของมนุษย์ โดยใช้แบบจำลอง SVR ที่ใช้ Gaussian Kernel Function และเครื่องมือ Random Forest โดยพบว่าแบบจำลอง SVR สามารถทำนายผลลัพธ์ได้แม่นยำกว่าเครื่องมือ Random Forest และสามารถใช้ในการทำนายผลในการซึมผ่านของสารในผิวหนังของมนุษย์ได้ดี [12] ในขณะที่ยานวิจัยของ Shah จะสนใจการนำ SVR ไปทำนายความสามารถในการเสริมการซึมผ่านของตัวช่วยในผลิตภัณฑ์แผ่นแปะ โดยมีการใช้ Kernel Function ใน SVR ด้วยกัน 2 รูปแบบ คือแบบเส้นตรง (Linear Kernel Function) และแบบไม่เป็นเส้นตรงประเภท Radial Basis Function โดยผลลัพธ์ระบุว่า การใช้ Radial Basis Function ในแบบจำลอง SVR จะทำนายค่าความสามารถในการช่วยเสริมการซึมผ่านได้แม่นยำกว่าการใช้ Linear Kernel Function [13]

นอกจากนี้ แบบจำลอง SVR ยังถูกใช้ในการช่วยวิเคราะห์ปริมาณสารในทางเภสัชกรรมด้วย เช่น งานวิจัยของ Naguib ที่สนใจเกี่ยวกับการนำแบบจำลองต่าง ๆ ไปวิเคราะห์หาปริมาณของตัวยาสำคัญ Cefoperazone Sodium ที่มีสารไม่บริสุทธิ์ (Impurity) ปะปนอยู่ด้วย เมื่อเปรียบเทียบกับ การหาปริมาณสารโดยใช้วิธี High Performance Liquid Chromatography (HPLC) โดยมีการเปรียบเทียบการใช้แบบจำลอง SVR ที่ใช้ Linear Kernel Function กับการใช้แบบจำลอง Partial Least Square Regression (PLSR) โดยพบว่า การใช้แบบจำลอง SVR จะสามารถทำนายได้แม่นยำกว่าการใช้แบบจำลอง PLSR และสามารถหาปริมาณสารได้เทียบเท่าวิธี HPLC ด้วย [14]

ในงานวิจัยกลุ่มที่เกี่ยวข้องกับการผลิตผลิตภัณฑ์ยา แบบจำลอง SVR ก็มีการถูกใช้ในการทำนายค่าพารามิเตอร์ในการผลิต เช่นงานของ Clavud ที่สนใจการใช้แบบจำลองต่าง ๆ ไปทำนายปริมาณความชื้นของผลิตภัณฑ์ยาทำให้แห้งแบบเยือกแข็ง (Freeze-dried Product) โดยแบบจำลองที่ใช้ในงานวิจัยนี้มีหลายชนิดด้วยกัน คือแบบจำลองประเภท Partial Least Square, แบบจำลอง Decision Tree, แบบจำลอง Bayesian-Ridge, แบบจำลอง K-Nearest Neighbor และแบบจำลอง SVR ที่ใช้ Radial Basis Kernel Function โดยเปรียบเทียบกับการใช้วิธีวัดความชื้นแบบ Near-infrared (NIR) ซึ่งแบบจำลองประเภท SVR จะให้ความผันผวนในการทำนายต่ำที่สุดเมื่อเทียบกับแบบจำลองอื่น ๆ [15]


จากการค้นคว้างานวิจัยทางเภสัชกรรมที่ใช้แบบจำลอง SVR ผู้วิจัยเห็นว่าแบบจำลอง SVR สามารถนำมาใช้ในการทำนายความสัมพันธ์ที่ไม่เป็นเส้นตรงได้ดีเมื่อเทียบกับการใช้แบบจำลองประเภทอื่น ๆ ผู้วิจัยจึงสนใจที่จะนำแบบจำลอง SVR มาเปรียบเทียบในงานวิจัยนี้

## 2.5 การวิเคราะห์องค์ประกอบหลัก

การวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis: PCA) คือกระบวนการที่ใช้วิเคราะห์กลุ่มข้อมูลที่มีจำนวนชนิดของข้อมูลมาก โดยมีจุดมุ่งหมายคือการหาความคล้ายคลึงและความแตกต่างของข้อมูลแต่ละชนิด อีกทั้งกระบวนการนี้ยังสามารถนำข้อมูลที่ได้รับมาแปลงเป็นข้อมูลชุดใหม่ที่มีจำนวนชนิดของข้อมูลลดลงโดยไม่ทำให้รายละเอียดของข้อมูลลดลงมากเกินไป [19]

### 2.5.1 ขั้นตอนของการวิเคราะห์องค์ประกอบหลัก

การวิเคราะห์องค์ประกอบหลักจะต้องมีข้อมูลเดิมก่อน โดยมีตัวอย่างข้อมูลประกอบดังรูปที่



รูปที่ 2-15 ตัวอย่างข้อมูลและกราฟแสดงข้อมูล

จากนั้นจะมีขั้นตอนต่าง ๆ ทำการปรับปรุงข้อมูล ดังนี้

### 1) การปรับปรุงข้อมูลเบื้องต้น

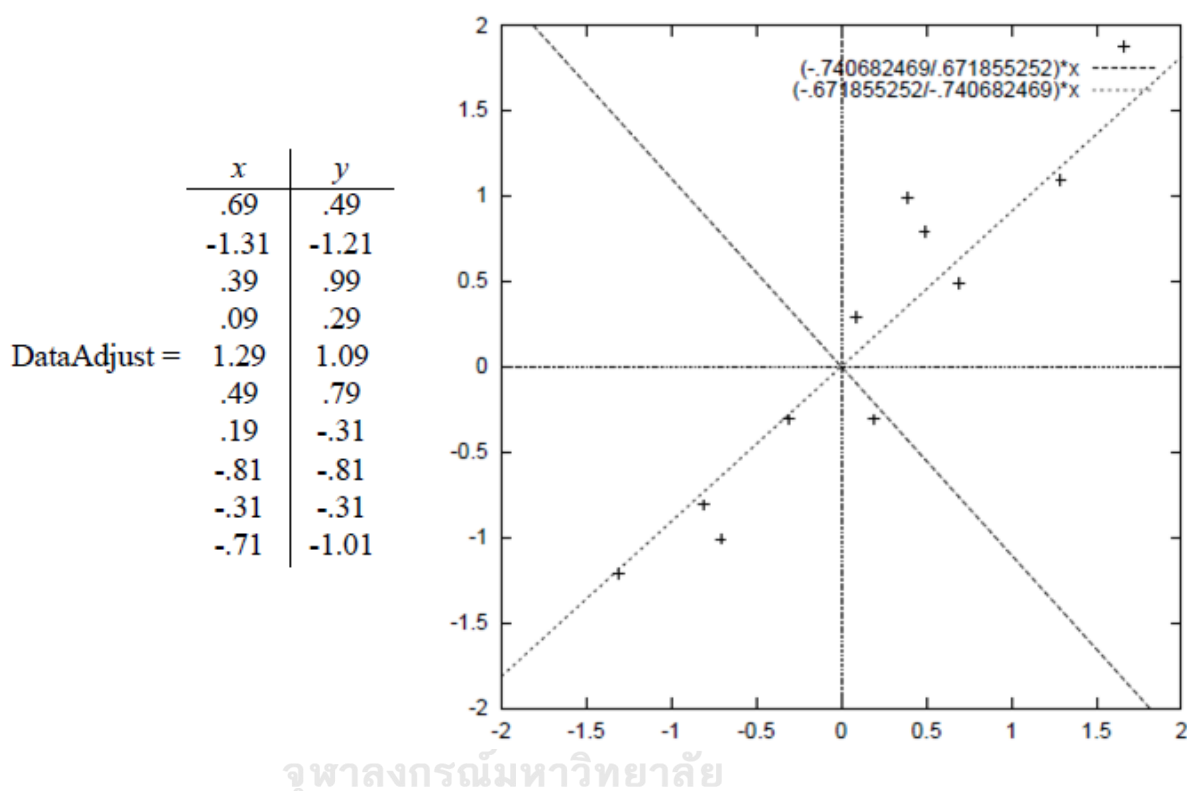
การปรับปรุงข้อมูลจะกระทำโดยทำการหาค่าเฉลี่ยของข้อมูลแต่ละชนิด จากนั้นจะนำข้อมูลแต่ละค่าไปลบด้วยค่าเฉลี่ยของข้อมูลชนิดนั้น ๆ และได้ออกมาเป็นข้อมูลชุดใหม่ แสดงในรูปของเมตริกซ์ เรียกว่า ข้อมูลที่ถูกปรับค่าเฉลี่ย (Mean-adjusted Data) [19]

### 2) การหาเมตริกซ์ความแปรปรวนร่วม

หลังจากได้เมตริกซ์ของข้อมูลที่ถูกปรับค่าเฉลี่ยแล้ว ขั้นตอนถัดไปจะเป็นการหาความแปรปรวนร่วม (Covariance) ระหว่างชนิดของข้อมูลแต่ละคู่ และแสดงผลลัพธ์ในรูปของเมตริกซ์ความแปรปรวนร่วม (Covariance Matrix) [19]

### 3) การหาเวกเตอร์เงาและค่าเงา

เมตริกซ์ความแปรปรวนร่วมในข้อ 2) จะถูกนำไปคำนวณหาเวกเตอร์เงา (Eigenvector) และค่าเงา (Eigenvalue) ของเมตริกซ์ความแปรปรวน ในขั้นตอนนี้หลักของเวกเตอร์เงาแต่ ละหลักจะถูกเรียกว่าองค์ประกอบ (Component) [19]



รูปที่ 2-16 ข้อมูลที่ถูกปรับค่าเฉลี่ย และกราฟของข้อมูลที่ถูกปรับค่าเฉลี่ยและเวกเตอร์เงา

### 4) เรียงลำดับองค์ประกอบ

จากขั้นตอนที่ 3) จะมีการเรียงลำดับหลักขององค์ประกอบขึ้นใหม่โดยพิจารณาจากค่าเงา โดยเรียงลำดับจากองค์ประกอบที่มีค่าเงาสูงที่สุดไปเรื่อย ๆ จนถึงองค์ประกอบที่มีค่าเงาต่ำที่สุด [19]

### 5) สร้างชุดข้อมูลใหม่

ข้อมูลใหม่จะถูกสร้างขึ้นโดยการคูณกันระหว่างเมตริกซ์ของข้อมูลชุดเดิม กับองค์ประกอบที่อยู่ภายในเวกเตอร์เจาะจง ดังสมการ


$$Final\ Data = RowFeatureVector \times RowDataAdjust \quad (23)$$

โดย Final Data คือ เมตริกซ์ของข้อมูลใหม่

RowFeatureVector คือ เวกเตอร์เจาะจงที่ถูกสลับเปลี่ยน (Transpose)

RowDataAdjust คือ เมตริกซ์ของข้อมูลที่ถูกปรับค่าเฉลี่ย

กราฟของข้อมูลใหม่ที่ได้จะมีการปรับเปลี่ยนแกนโดยแกน X คือองค์ประกอบที่ 1 หรือเวกเตอร์เจาะจงหลักที่มีค่าเจาะจงมากที่สุด และแกน Y คือองค์ประกอบที่ 2 หรือเวกเตอร์เจาะจงหลักที่มีค่าเจาะจงมากเป็นอันดับ 2 [19]



รูปที่ 2-17 ข้อมูลใหม่ที่ได้และกราฟของข้อมูลใหม่

## 2.5.2 งานวิจัยที่เกี่ยวข้อง

จากการศึกษางานวิจัยทางด้านเภสัชกรรม ผู้วิจัยพบว่ามี การนำเครื่องมือ PCA ไปใช้ในการวิเคราะห์ต่าง ๆ เช่นงานวิจัยของ Sun ที่ศึกษาผลของพารามิเตอร์ทางการผลิตต่อการละลายของผลิตภัณฑ์ยาเม็ดพาราเซตามอล โดยได้นำเครื่องมือ PCA ไปใช้วิเคราะห์ความแปรผันที่เกิดขึ้นจากปัจจัยต่าง ๆ ในงานวิจัย [20] อีกทั้งยังพบการใช้เครื่องมือ PCA ในการช่วยทำนายปริมาณยาที่ตรวจวัดได้จากการวิเคราะห์ด้วยในงานวิจัยของ Ioele ซึ่งมีการใช้เครื่องมือ Partial Least Square Method และแบบจำลอง Artificial Neural Network มาด้วย ซึ่งผลการวิจัยพบว่าการใช้แบบจำลอง ANN สามารถทำนายค่าได้แม่นยำกว่าการใช้เครื่องมือ PLS และหากใช้ PCA ควบคู่กับ ANN ก็จะทำให้การทำนายแม่นยำขึ้นและใช้เวลาในการเรียนรู้ลดลงด้วย [7]

จากที่กล่าวมานั้น ยังไม่มีการนำเครื่องมือ PCA มาใช้ในงานวิจัยด้านการผลิตผลิตภัณฑ์ยา อีกทั้งผู้วิจัยเห็นถึงโอกาสในการนำเครื่องมือ PCA มาใช้เพื่อปรับปรุงปัจจัยให้มีความเหมาะสมในการนำไปใช้มากขึ้น ผู้วิจัยจึงนำเครื่องมือ PCA มาใช้ในงานวิจัยนี้



## บทที่ 3

### บริษัทกรณศึกษา

ในบทนี้จะกล่าวถึงข้อมูลต่าง ๆ ของบริษัทกรณศึกษา เช่น โครงสร้างองค์กร แผนกต่าง ๆ รวมไปถึงการผลิตผลิตภัณฑ์ยาภายในบริษัท

#### 3.1 สภาพทั่วไปของโรงงาน

บริษัทกรณศึกษาเป็นบริษัทโรงงานขนาดเล็กที่ก่อตั้งในปี พ.ศ. 2524 เพื่อผลิตผลิตภัณฑ์ยาและเวชภัณฑ์ ในปัจจุบันบริษัทกรณศึกษามีอาคารโรงงานผลิตขนาด 3 ชั้น ครอบคลุมพื้นที่ 24,000 ตารางเมตร ซึ่งมีสายการผลิตที่ทันสมัยระดับโลก อีกทั้งยังมีหน่วยงานวิจัยและพัฒนาและหน่วยงานควบคุมและประกันคุณภาพอยู่ในอาคารด้วย

บริษัทกรณศึกษาเป็นบริษัทที่ดำเนินการด้านการผลิตยาและเวชภัณฑ์ที่มุ่งเน้นการพัฒนาสูตรตำรับและรับจ้างผลิตยาสามัญ โดยบริษัทมีการรับประกันคุณภาพในการผลิตระดับสูง เช่น PIC/S GMP, EU GMP เป็นต้น ทำให้ได้รับความไว้วางใจจากทั้งในประเทศและต่างประเทศ อาทิ เยอรมัน ญี่ปุ่น อิตาลี มาเลเซีย สิงคโปร์ ฟิลิปปินส์ และศรีลังกา ในปัจจุบันบริษัทได้ทำการผลิตยาและเวชภัณฑ์หลายรูปแบบ ตั้งแต่ยาเม็ดและแคปซูล ยาปราศจากเชื้อรูปแบบของเหลว ยาปราศจากเชื้อรูปแบบผง ครีมและซีฟิ่ง

บริษัทกรณศึกษามีการดำเนินการประกันคุณภาพเพื่อรับประกันคุณภาพของผลิตภัณฑ์ยาและเวชภัณฑ์ของบริษัทในระดับสูงสุด โดยหน่วยงานผลิตและหน่วยงานบริหารการดำเนินการได้รับการรับรองจากหน่วยงานมาตรฐานระดับโลกมากมาย ได้แก่


- มาตรฐาน PIC/S GMP ตั้งแต่ปีพ.ศ. 2552
- มาตรฐาน EU GMP
- มาตรฐาน ISO/IEC 17025
- มาตรฐาน ISO 9001:2008
- มาตรฐาน ISO 14001:2015
- มาตรฐาน OHSAS 18001:2007
- รางวัลหน่วยงานคุณภาพ จากสำนักงานคณะกรรมการอาหารและยา ตั้งแต่ปีพ.ศ. 2552
- มาตรฐานฮาลาล



รูปที่ 3-1 การรับรองต่าง ๆ ของบริษัทกรณีศึกษา

### 3.2 โครงสร้างองค์กรและฝ่ายผลิต

โครงสร้างองค์กรของบริษัทกรณีศึกษา มีผู้จัดการบริษัททำหน้าที่บริหารการดำเนินการต่าง ๆ โดยรวมของทุกหน่วยงานภายในบริษัท ซึ่งบริษัทมีหน่วยงานทั้งหมด 5 หน่วยงาน ได้แก่ หน่วยงานฝ่ายบริหาร หน่วยงานฝ่ายธุรกิจ หน่วยงานฝ่ายผลิต หน่วยงานฝ่ายประกันและควบคุมคุณภาพ และ หน่วยงานฝ่ายค้นคว้าวิจัยและพัฒนา




รูปที่ 3-2 โครงสร้างองค์กรของบริษัทกรณีศึกษา

หน่วยงานฝ่ายผลิตภายในบริษัทกรณีศึกษามีบทบาทหน้าที่ในการดำเนินการผลิตผลิตภัณฑ์ยาและเวชภัณฑ์ต่าง ๆ ซึ่งจะมีการแบ่งแผนกในหน่วยงานดังนี้

1) แผนกผลิตยาไม่ปราศจากเชื้อ (Non-sterile Production Line : PDN) เป็นแผนกที่เกี่ยวข้องกับการผลิตยาไม่ปราศจากเชื้อ โดยจะมีด้วยกันหลายฝ่าย เช่น ฝ่ายผลิตยาเม็ดและแคปซูล (Tablets and Capsules : TAC) ฝ่ายผลิตยาน้ำและครีม (Belcid, Cream and Solution : BCS) ฝ่ายผลิตยากลุ่มฮอร์โมน (Hormones : HOR) ฝ่ายผลิตผลิตภัณฑ์เสริมอาหาร (Foods and Supplements : FOS) ฝ่ายจัดหาตัวยาสำคัญ (Active Pharmaceutical Ingredient : API) ฝ่ายบรรจุภัณฑ์ (Central Packaging : CTP) และฝ่ายสนับสนุน (Supporting : SPT)

2) แผนกผลิตยาปราศจากเชื้อ (Sterile Production Line : PDS) เป็นแผนกที่เกี่ยวข้องกับการผลิตยาปราศจากเชื้อที่มีการจำกัดปริมาณเชื้อโรคภายในผลิตภัณฑ์ยา โดยจะมีด้วยกันหลายฝ่าย เช่น ฝ่ายผลิตยาปราศจากเชื้อทั่วไป (Sterile Production : STR) ฝ่ายผลิตยาต้านจุลชีพจำพวกเซฟาโลสปอริน (Cephalosporin Production : CEP) และฝ่ายผลิตยาต้านจุลชีพจำพวกคาร์บาพีเนม (Carbapenem Production : CPN)



รูปที่ 3-3 แผนผังองค์กรของหน่วยงานฝ่ายผลิตในบริษัทกรณีศึกษา


ในการทำงานร่วมกับบริษัทกรณีศึกษา ผู้วิจัยมีความสนใจเกี่ยวกับการผลิตยาเม็ด จึงขอกล่าวข้อมูลเกี่ยวกับแผนกผลิตยาไม่ปราศจากเชื้อ ฝ่ายผลิตยาเม็ดและแคปซูล (TAC) ต่อไป

### 3.3 ฝ่ายผลิตยาเม็ดและแคปซูล

ฝ่ายผลิตยาเม็ดและแคปซูล มีฝ่ายย่อยซึ่งแบ่งหน้าที่ตามสายการผลิตยาเม็ดและแคปซูลด้วยกัน 4 ฝ่ายย่อย ได้แก่ ฝ่ายทำแกรนูล (GRANULE) มีหน้าที่ผลิตแกรนูลจากผงของตัวยาสำคัญและสารเติมแต่ง เพื่อปรับปรุงคุณสมบัติให้เหมาะสมต่อการตอกอัด ฝ่ายตอกยาเม็ด (TABLETING) มีหน้าที่ผลิตยาเม็ดจากแกรนูลโดยวิธีการตอกอัด ฝ่ายเคลือบยาเม็ด (COATING) มีหน้าที่นำยาเม็ดบางชนิดไปเคลือบฟิล์มหรือเคลือบน้ำตาลเพื่อปรับเปลี่ยนคุณสมบัติของยาเม็ดให้เหมาะสมต่อการใช้งานมากขึ้น และฝ่ายบรรจุยาเม็ด (STRIP) มีหน้าที่นำยาเม็ดที่ผ่านกระบวนการผลิตเรียบร้อยแล้วไปบรรจุในบรรจุภัณฑ์ประเภทสตริป (Strip)

ฝ่ายทำแกรนูล (GRANULE) ในบริษัทกรณีศึกษาจะมีวิธีการทำแกรนูล 2 วิธีการ คือ การทำแกรนูลแบบเปียก (Wet Granulation) และการทำแกรนูลแบบแห้ง (Dry Granulation) เมื่อทำการสำรวจ พบว่าผลิตภัณฑ์ยาเม็ดของบริษัทกรณีศึกษาจะใช้วิธีการทำแกรนูลแบบเปียกในการทำแกรนูลเป็นส่วนใหญ่ จึงขอกล่าวการทำแกรนูลแบบเปียกต่อไป โดยขั้นตอนในการทำแกรนูลแบบเปียกจะมีด้วยกัน 4 ขั้นตอน คือ


- 1) **ขั้นตอนการผสมเปียก (Wet Mixing)** เป็นขั้นตอนที่ทำให้ผงยาและสารเติมแต่งจับตัวกันเป็นก้อน โดยอาศัยสารละลายของสารยึดเกาะ (Binding Solution)
- 2) **ขั้นตอนการร่อนเปียก (Wet Sieving)** เป็นขั้นตอนที่ทำให้ก้อนของสารผสมกลายเป็นมวลสารที่มีขนาดเล็กกลงโดยใช้เครื่องร่อน เรียกก้อนมวลสารเหล่านั้นว่า แกรนูลเปียก (Wet Granule)
- 3) **ขั้นตอนการทำให้แห้ง (Drying)** เป็นขั้นตอนที่กำจัดน้ำและความชื้นออกจากแกรนูลเปียก โดยใช้เครื่องอบประเภทต่าง ๆ แล้วแต่วิธีการทำให้แห้ง ขั้นตอนนี้จะกระทำจนกระทั่งได้แกรนูลที่มีความชื้นในระดับที่ต้องการ
- 4) **ขั้นตอนการร่อนแห้ง (Dry Sieving)** เป็นขั้นตอนที่นำแกรนูลที่ผ่านการกำจัดความชื้นมาแรงเพื่อลดขนาดทำให้ได้ขนาดแกรนูลที่ต้องการอีกครั้งโดยใช้เครื่องร่อน แกรนูลที่ผ่านขั้นตอนนี้แล้วจะเรียกว่า แกรนูลแห้ง (Dry Granule) ที่จะนำไปใช้ในกระบวนการอื่นต่อไป



รูปที่ 3-4 ขั้นตอนการทำแกรนูลเปียก


เนื่องด้วยเครื่องมือที่ใช้ในการทำแกรนูลแบบเปียกมีการเปลี่ยนแปลงและพัฒนาจากอดีตจนมาถึงปัจจุบัน ทำให้เครื่องมือที่ใช้ในปัจจุบันมีประสิทธิภาพมากขึ้น อันทำให้การทำแกรนูลแบบเปียกมีระยะเวลาที่ลดลงไปด้วย ดังนั้นบริษัทกรณีสึกษาจึงได้ทำการศึกษาและจัดซื้อเครื่องมือเพื่อเพิ่มประสิทธิภาพในการทำแกรนูลแบบเปียกเพื่อรองรับการขยายตัวของบริษัท ในปัจจุบันบริษัทกรณีสึกษามีกระบวนการทำแกรนูลแบบเปียกอยู่ด้วยกัน 2 ระบบ ได้แก่

1) ระบบทำแกรนูลแบบเปียกแบบเดิม ซึ่งบริษัทกรณีสึกษามีระบบนี้มาตั้งแต่จัดตั้งบริษัท ทำให้เครื่องมือที่ใช้ในระบบนี้ยังเป็นเครื่องมือรุ่นเดิม ระบบนี้จะมีระยะเวลาในการทำแกรนูลประมาณ 10 – 14 ชั่วโมง



รูปที่ 3-5 ระบบทำแกรนูลแบบเปียกแบบเดิม

2) ระบบทำแกรนูลแบบเปียกแบบใหม่ โดยเครื่องมือที่ใช้ในระบบนี้จะมีประสิทธิภาพมากกว่าเครื่องมือในระบบการทำแกรนูลแบบเปียกแบบเดิม อีกทั้งยังใช้ระยะเวลาในการทำแกรนูลน้อยกว่า (3 – 4 ชั่วโมง)



รูปที่ 3-6 ระบบทำแกรนูลแบบเปียกแบบใหม่

การเปรียบเทียบระบบทำแกรนูลแบบเปียกทั้ง 2 ระบบ จะเห็นได้ว่าระบบทำแกรนูลแบบเปียกแบบใหม่จะสามารถเพิ่มกำลังผลิตในการผลิตยาเม็ดได้มาก บริษัทกรณีศึกษาจึงมีความประสงค์ในการปรับเปลี่ยนการผลิตผลิตภัณฑ์ยาเม็ด จากการใช้ระบบทำแกรนูลแบบเปียกแบบเดิม เป็นการ ใช้ระบบทำแกรนูลแบบเปียกแบบใหม่ อย่างไรก็ตาม เนื่องด้วยเครื่องมือในการผลิตที่มีส่วนประกอบของเครื่องและพารามิเตอร์แตกต่างกัน จึงทำให้ไม่สามารถถ่ายโอนระบบการผลิตได้ในทันที อีกทั้งตำรับยาเม็ดของแต่ละผลิตภัณฑ์มีส่วนประกอบแตกต่างกันไปด้วย จึงทำให้พารามิเตอร์ในการผลิตมีความหลากหลายมากขึ้นด้วย จึงต้องมีการทดลองผลิตเพื่อหาพารามิเตอร์ที่เหมาะสมในการทำแกรนูลแบบเปียก ทำให้สูญเสียเวลาและค่าใช้จ่ายในการทดลอง ผู้วิจัยจึงสนใจในการนำระบบปัญญาประดิษฐ์มาทำนายค่าพารามิเตอร์ที่ต้องใช้ในการทำแกรนูลแบบเปียก โดยขั้นตอนในการทำแกรนูลแบบเปียกที่ผู้วิจัยสนใจคือขั้นตอนการผสมเปียก เนื่องจากเป็นขั้นตอนที่มีการควบคุมการผลิตยากและส่งผลกระทบต่อคุณภาพของแกรนูลที่ได้มากที่สุด

## บทที่ 4

### ข้อมูลและการวิเคราะห์ห้องค์ประกอบหลัก

หลังจากได้รับทราบปัญหาของบริษัทกรณีศึกษาแล้ว ทางผู้วิจัยได้ทำการติดต่อขอข้อมูลการผลิตจากฝ่ายผลิตยาเม็ดและแคปซูลจากบริษัทกรณีศึกษาเพื่อนำมาวิเคราะห์ก่อนนำข้อมูลไปใช้ต่อไป

#### 4.1 ข้อมูลที่ได้รับ

ข้อมูลที่ได้รับจากฝ่ายผลิตยาเม็ดและแคปซูลจากบริษัทกรณีศึกษา เป็นข้อมูลที่เกี่ยวข้องกับการทำแกรนูลแบบเปียกของตำรับผลิตภัณฑ์ยาเม็ดและแคปซูลที่บริษัทได้ดำเนินการจัดจำหน่าย โดยมีข้อมูลทั้งหมด 26 ชุดมาจากการทำแกรนูลแบบเปียกแบบเดิม จำนวน 17 ชุด และการทำแกรนูลแบบเปียกแบบใหม่ จำนวน 9 ชุด ข้อมูลแต่ละชุดประกอบด้วยข้อมูลนำเข้า (Input) จำนวน 10 ชนิด และข้อมูลนำออก (Output) จำนวน 1 ชนิด ข้อมูลนำเข้าจะแบ่งออกเป็น 3 กลุ่ม คือ

1) ข้อมูลที่เกี่ยวข้องกับส่วนประกอบที่เป็นผงในตำรับผลิตภัณฑ์ยาเม็ด จำนวน 5 ชนิด ได้แก่

- ค่าการละลายน้ำ (Water Solubility) ของผงสารที่มีปริมาณมากที่สุดในตำรับ (หน่วย มิลลิกรัมต่อมิลลิลิตร) โดยข้อมูลมาจากการสืบค้นของผู้วิจัย ซึ่งใช้คำย่อคือ “การละลายน้ำสารอันดับ 1”
- ค่าการละลายน้ำ (Water Solubility) ของผงสารที่มีปริมาณมากที่สุดในตำรับเป็นอันดับ 2 (หน่วย มิลลิกรัมต่อมิลลิลิตร) โดยข้อมูลมาจากการสืบค้นของผู้วิจัย ซึ่งใช้คำย่อคือ “การละลายน้ำสารอันดับ 2” ตามลำดับ
- ค่าสัมประสิทธิ์การกระจายตัวของสารในชั้นน้ำและน้ำมัน (Log P) ของผงสารที่มีปริมาณมากที่สุดในตำรับ โดยข้อมูลมาจากการสืบค้นของผู้วิจัย ซึ่งใช้คำย่อคือ “สัมประสิทธิ์น้ำ/น้ำมัน”
- สัดส่วนโดยน้ำหนักของผงสารที่มีปริมาณมากที่สุดในตำรับ โดยข้อมูลมาจากการคำนวณในตำรับ ซึ่งใช้คำย่อคือ “สัดส่วนสารอันดับ 1”



- สัดส่วนโดยน้ำหนักของผงสารที่มีปริมาณมากที่สุดเป็นอันดับ 2 โดยข้อมูลมาจากการคำนวณในตำรับ ซึ่งใช้คำย่อคือ “สัดส่วนสารอันดับ 2”

## 2) ข้อมูลที่เกี่ยวกับสารละลายตัวยัดเกาะที่ใช้ในตำรับ จำนวน 3 ชนิด ได้แก่

- ค่าความหนืด (Viscosity) ของสารละลายตัวยัดเกาะ (หน่วย เซนติพอยส์) โดยข้อมูลมาจากการสืบค้นของผู้วิจัย ซึ่งใช้คำย่อคือ “ความหนืด”]
- ปริมาตรของเหลวที่ใช้เมื่อเทียบกับน้ำหนักของตำรับยา (หน่วยลิตร) โดยได้รับข้อมูลจากตำรับ ซึ่งใช้คำย่อคือ “ปริมาตรของเหลว”
- และสัดส่วนปริมาตรของเหลวที่ใช้เมื่อเทียบกับน้ำหนักของตำรับยา โดยข้อมูลมาจากการคำนวณในตำรับ ซึ่งใช้คำย่อคือ “สัดส่วนของเหลว”

## 3) ข้อมูลพารามิเตอร์ของเครื่องมือที่ใช้ในการทำแกรนูลแบบเปียก จำนวน 2 ชนิด ได้แก่

- ความเร็วรอบในการปั่นผสมของใบพาย Impeller ขณะทำการปั่นผสมด้วยความเร็วสูง (หน่วย รอบต่อนาที) ซึ่งใช้คำย่อคือ “ความเร็วรอบปั่นเร็ว”
- ความเร็วรอบในการปั่นผสมของใบพาย Impeller ขณะทำการปั่นผสมด้วยความเร็วต่ำ (หน่วย รอบต่อนาที) ซึ่งใช้คำย่อคือ “ความเร็วรอบปั่นช้า”

ข้อมูลนำออกที่ใช้ในงานวิจัย คือ จำนวนรอบที่ใช้ในการปั่นผสม (Revolution) ของใบพาย Impeller (หน่วย รอบ) โดยค่าต่าง ๆ ของข้อมูลแสดงได้ดังตารางที่ 4-1

ตารางที่ 4-1 ชุดข้อมูลนำเข้าและข้อมูลนำเข้าออกที่ได้รับ

สูตรคำนวณที่	1	2	3	4	5	6	7	8	9	10
การละลายน้ำสารอันดับ 1	2.5	2.5	0.0037	0.0426	0.0426	195	195	195	195	195
สัมประสิทธิ์น้ำ/น้ำมัน	-1.56	-1.56	6.1	2.6	2.6	-5.03	-5.03	-5.03	-5.03	-5.03
สัดส่วนสารอันดับ 1	80.92	52.64	41.39	51.71	51.71	58.17	76.00	86.52	81.55	75.10
การละลายน้ำสารอันดับ 2	0	195	0	195	195	0	0	0	0.0141	0
สัดส่วนสารอันดับ 2	11.56	27.23	33.11	27.60	40.53	31.61	18.95	10.36	11.00	14.29
ปริมาตรของเหลว	7.00	5.40	12.40	4.53	6.50	33.60	1.30	15.60	7.20	17.00
สัดส่วนของเหลว	16.86	13.54	25.66	8.13	11.67	24.58	9.12	8.98	12.94	29.98
ความหนืด	45	50	50	$7 \times 10^7$	$3 \times 10^5$	$1 \times 10^3$	$8 \times 10^3$	700	70	$1 \times 10^3$
ความเร็วรอบการปั่นช้า	30.0	30.0	30.0	30.0	30.0	30.1	55.0	30.1	30.0	30.0
ความเร็วรอบการปั่นเร็ว	0	0	0	0	0	0	0	0	0	0
จำนวนรอบ Impeller	900	900	900	600	900	903	1,650	903	900	900

ตารางที่ 4-1 ชุดข้อมูลนำเข้าและข้อมูลนำออกที่ได้รับ (ต่อ)

สูตรตำรับที่	11	12	13	14	15	16	17	18
การละลายน้ำสารอันดับ 1	195	195	195	195	195	79	$1.89 \times 10^{-5}$	9.38
สัมประสิทธิ์อินทรีย์/น้ำมัน	-5.03	-5.03	-5.03	-5.03	-5.03	-0.77	1.7	0.4
สัดส่วนสารอันดับ 1	68.34	61.31	83.33	57.93	37.98	64.52	81.81	79.21
การละลายน้ำสารอันดับ 2	$4.14 \times 10^{-4}$	$2.37 \times 10^{-3}$	0	0.167	$1.4 \times 10^{-3}$	0.0265	0	195
สัดส่วนสารอันดับ 2	16.31	29.53	10.42	41.08	32.99	32.26	8.95	11.24
ปริมาตรของเหลว	2.90	20.00	21.00	24.00	25.00	17.50	26.00	28.00
สัดส่วนของเหลว	18.92	23.63	14.58	13.15	16.50	20.53	21.27	15.84
ความหนืด	20	2,800	20	200	9	8.5	80	2
ความเร็วรอบการปั่นช้า	55.0	30.1	30.1	30.1	30.1	30.1	30.1	73.0
ความเร็วรอบการปั่นเร็ว	0	0	0	0	0	0	0	145.0
จำนวนรอบ Impeller	1,650	451.5	903	903	903	903	903	798

ตารางที่ 4-1 ชุดข้อมูลนำเข้าและข้อมูลนำออกที่ได้รับ (ต่อ)


สูตรตำรับที่	19	20	21	22	23	24	25	26
การละลายน้ำสารอันดับ 1	9.38	195	195	195	195	195	195	$8.66 \times 10^{-5}$
สัมประสิทธิ์อินทรีย์/น้ำมัน	0.4	-5.03	-5.03	-5.03	-5.03	-5.03	-5.03	4.35
สัดส่วนสารอันดับ 1	79.21	61.31	73.79	80.53	88.46	35.92	40.15	54.05
การละลายน้ำสารอันดับ 2	195	$2.37 \times 10^{-3}$	0.0185	0.75	0	$1.4 \times 10^{-3}$	$1.4 \times 10^{-3}$	195
สัดส่วนสารอันดับ 2	11.24	29.53	13.39	10.10	10.73	31.20	34.87	30.27
ปริมาตรของเหลว	28.00	26.00	28.00	32.00	30.00	26.00	26.00	30.00
สัดส่วนของเหลว	15.84	15.36	15.63	16.23	7.15	16.22	16.22	16.22
ความหนืด	2	700	45	7	700	8	9	7.65
ความเร็วรอบการปั่นช้า	73.0	73.0	73.0	73.0	73.0	73.0	73.0	73.0
ความเร็วรอบการปั่นเร็ว	145.0	145.0	145.0	145.0	145.0	145.0	145.0	145.0
จำนวนรอบ Impeller	798	944	1,888	1,888	1,888	943	943	1,598

## 4.2 การวิเคราะห์องค์ประกอบหลักเบื้องต้น

หลังจากได้รับข้อมูลจากบริษัทการศึกษาแล้ว พบว่าจำนวนของข้อมูลนำเข้ามีจำนวนมาก เมื่อเทียบกับจำนวนของชุดข้อมูล ดังนั้นผู้วิจัยจึงต้องการลดข้อมูลนำเข้าก่อนที่จะนำชุดข้อมูลไปทำการสร้างแบบจำลองทำนายต่อไป โดยมีขั้นตอนการวิเคราะห์ดังนี้

- 1) การวิเคราะห์องค์ประกอบเบื้องต้น เพื่อให้เห็นแนวโน้มของความสัมพันธ์ระหว่างกลุ่มข้อมูลและทำการจัดกลุ่มข้อมูลที่มีความเกี่ยวข้องกัน
- 2) การวิเคราะห์สหสัมพันธ์ เพื่อวิเคราะห์ข้อมูลที่มีความสัมพันธ์กันมาก และทำการลดข้อมูลบางชนิดเพื่อลดความซ้ำซ้อนของกลุ่มข้อมูล
- 3) การวิเคราะห์องค์ประกอบซ้ำ โดยใช้กลุ่มข้อมูลที่ทำกรลดข้อมูลแล้ว เพื่อสังเกตว่าแนวโน้มของความสัมพันธ์ระหว่างกลุ่มข้อมูลมีการเปลี่ยนแปลงหรือไม่

แผนผังการวิเคราะห์ข้อมูลจะแสดงดังรูปที่ 4-1



รูปที่ 4-1 แผนผังขั้นตอนการวิเคราะห์ข้อมูลจากบริษัทกรณีศึกษา

การวิเคราะห์ข้อมูลจะกระทำในโปรแกรม R (รุ่น 1.0.153) [21] จะใช้การวิเคราะห์องค์ประกอบหลัก (Principle Component Analysis : PCA) เพื่อทำการค้นหาข้อมูลนำเข้าที่มีความสัมพันธ์กัน แล้วพิจารณาลดข้อมูลนำเข้าบางส่วน โดยมีผลลัพธ์ดังแสดงในตารางที่ 4-2


ตารางที่ 4-2 ความแปรปรวนที่เกิดขึ้นในองค์ประกอบต่าง ๆ

	องค์ประกอบที่ 1	องค์ประกอบที่ 2	องค์ประกอบที่ 3	องค์ประกอบที่ 4
ส่วนเบี่ยงเบนมาตรฐาน	1.7489	1.5475	1.3373	1.1411
อัตราส่วนของความแปรปรวน	0.3059	0.2395	0.1788	0.1302
อัตราส่วนของความแปรปรวนสะสม	0.3059	0.5454	0.7242	0.8544

ผลลัพธ์จากการวิเคราะห์องค์ประกอบแสดงให้เห็นว่าความแปรปรวนสะสมจะมีค่าเพิ่มขึ้นจนมากกว่า 80 เปอร์เซ็นต์ ภายในองค์ประกอบที่ 4 (85.44%) ผู้วิจัยจึงทำการวิเคราะห์ข้อมูลนำเข้าที่เป็นส่วนประกอบต่าง ๆ ภายในองค์ประกอบ 4 ลำดับแรกต่อไป โดยการพิจารณาส่วนประกอบต่าง ๆ ขององค์ประกอบทั้ง 4 องค์ประกอบจะได้ผลลัพธ์ดังตารางที่ 4-3 และรูปที่ 4-2

ตารางที่ 4-3 ค่า loading ของข้อมูลนำเข้าที่เป็นส่วนประกอบในองค์ประกอบต่าง ๆ

ข้อมูลนำเข้า	องค์ประกอบที่ 1	องค์ประกอบที่ 2	องค์ประกอบที่ 3	องค์ประกอบที่ 4
การละลายน้ำตาลอันดับ 1	0.465	0.188	-0.188	0.332
สัมประสิทธิ์น้ำ/น้ำมัน	-0.467	-0.203		-0.314
สัดส่วนสารอันดับ 1	0.257	0.141	0.576	-0.268
การละลายน้ำตาลอันดับ 2	-0.387	-0.333	0.209	
สัดส่วนสารอันดับ 2	-0.261		-0.580	0.269
ปริมาตรของเหลว	0.271	-0.396	-0.197	-0.218
สัดส่วนของเหลว			-0.399	-0.636
ความหนืด	-0.308		0.204	0.421
ความเร็วรอบการปั่นช้า	0.251	-0.533		0.117
ความเร็วรอบการปั่นเร็ว	0.225	-0.581		



รูปที่ 4-2 ข้อมูลนำเข้าที่เป็นส่วนประกอบขององค์ประกอบที่ 1 และ 2

จากรูปที่ 4-2 ซึ่งแสดงส่วนประกอบขององค์ประกอบที่ 1 และองค์ประกอบที่ 2 เมื่อสังเกตจากทิศทางและขนาดของลูกศรภายในรูป จะสังเกตเห็นแนวโน้มของความสัมพันธ์ระหว่างกลุ่มข้อมูลดังนี้

- “การละลายน้ำสารอันดับ 1”, “สัดส่วนสารอันดับ 1” มีทิศทางเดียวกัน ในขณะที่ “สัมประสิทธิ์น้ำ/น้ำมัน” “สัดส่วนสารอันดับ 2” “การละลายน้ำสารอันดับ 2” และ “ความหนืด” ก็มีทิศทางเดียวกัน บ่งบอกว่าข้อมูลกลุ่มที่มีทิศทางเดียวกันน่าจะมีความสัมพันธ์แบบแปรผันตรงกัน



- “การละลายน้ำสารอันดับ 1” “สกัดส่วนสารอันดับ 1” มีทิศทางตรงข้ามกับ “สัมประสิทธิ์น้ำ/น้ำมัน” “สกัดส่วนสารอันดับ 2” และ “การละลายน้ำสารอันดับ 2” บ่งบอกว่าข้อมูลทั้ง 2 กลุ่มน่าจะมีความสัมพันธ์แบบแปรผกผันกัน
- “ปริมาตรของเหลว” “ความเร็วรอบการปั่นเร็ว” และ “ความเร็วรอบการปั่นช้า” มีทิศทางเดียวกัน บ่งบอกให้เห็นว่าข้อมูลกลุ่มนี้น่าจะมีความสัมพันธ์แบบแปรผันตรง
- ลูกศรของข้อมูล “สกัดส่วนของเหลว” มีความยาวไม่มากนัก หากพิจารณาร่วมกับค่า Loading ของ “สกัดส่วนของเหลว” ในองค์ประกอบที่ 1 และ 2 ก็ไม่แสดงค่า Loading เช่นเดียวกัน บ่งบอกได้ว่าข้อมูลดังกล่าวไม่มีความเกี่ยวข้องกับข้อมูลอื่น ๆ

จากแนวโน้มทั้งหมดที่สังเกตได้ พบว่าข้อมูลจะถูกแบ่งออกเป็น 2 กลุ่มคือ


1. กลุ่มข้อมูล “การละลายน้ำสารอันดับ 1” “สกัดส่วนสารอันดับ 1” “สัมประสิทธิ์น้ำ/น้ำมัน” “สกัดส่วนสารอันดับ 2” “การละลายน้ำสารอันดับ 2” และ “ความหนืด” ซึ่งล้วนมีค่า Loading ในองค์ประกอบที่ 1 ชัดเจนกว่าองค์ประกอบที่ 2 ข้อมูลกลุ่มนี้จะถูกเรียกว่ากลุ่มข้อมูลที่ 1
2. กลุ่มข้อมูล “ปริมาตรของเหลว” “ความเร็วรอบการปั่นเร็ว” และ “ความเร็วรอบการปั่นช้า” ซึ่งมีค่า Loading ในองค์ประกอบที่ 2 ชัดเจนกว่าองค์ประกอบที่ 1 แต่ขณะเดียวกัน “การละลายน้ำสารอันดับ 2” ก็มีค่า Loading ในองค์ประกอบที่ 2 ใกล้เคียงกัน จึงถูกรวมเข้าในกลุ่มข้อมูลนี้ด้วย ข้อมูลกลุ่มนี้จะถูกเรียกว่ากลุ่มข้อมูลที่ 2

หลังจากการแบ่งกลุ่มข้อมูล จะพบว่าข้อมูล “สกัดส่วนของเหลว” ไม่มีค่า Loading ในองค์ประกอบที่ 1 และองค์ประกอบที่ 2 อีกทั้งในรูปที่ 4-2 ก็พบว่าความยาวของลูกศรที่แสดงข้อมูล “สกัดส่วนของเหลว” ก็มีความยาวไม่มากนัก บ่งบอกว่าข้อมูล “สกัดส่วนของเหลว” ไม่มีสำคัญในกลุ่มข้อมูลทั้งหมด ผู้วิจัยจึงพิจารณาตัดข้อมูล “สกัดส่วนของเหลว” ออกจากกลุ่มข้อมูล

จากการจัดเลือกกลุ่มข้อมูลดังกล่าว ผู้วิจัยจะนำกลุ่มข้อมูลเหล่านี้ไปวิเคราะห์เพิ่มเติมด้วยวิธีการวิเคราะห์สหสัมพันธ์ต่อไป

#### 4.2.1 กลุ่มข้อมูลที่ 1

การวิเคราะห์ภายในกลุ่มข้อมูลที่ 1 ประกอบด้วยข้อมูลนำเข้ากลุ่มที่เกี่ยวข้องกับส่วนประกอบในผลิตภัณฑ์ตำรับยาเม็ดทั้ง 5 ชนิด รวมถึงข้อมูลนำเข้า “ความหนืด” มาด้วย จะมีการหาสัมประสิทธิ์สหสัมพันธ์ (Correlation Coefficient : r) เพื่อพิจารณาความสัมพันธ์ระหว่างข้อมูลนำเข้าที่สนใจในกลุ่มข้อมูลที่ 1 โดยมีผลลัพธ์แสดงดังรูปที่ 4-3 และตารางที่ 4-4



รูปที่ 4-3 สัมประสิทธิ์สหสัมพันธ์ของข้อมูลนำเข้าในกลุ่มข้อมูลที่ 1

ตารางที่ 4-4 แสดงค่าสัมประสิทธิ์สหสัมพันธ์และค่า p-value ของข้อมูลนำเข้าในกลุ่มข้อมูลที่ 1

กลุ่มข้อมูลที่ 1	การละลายน้ำ สารอันดับ 1	สัมประสิทธิ์ น้ำ/น้ำมัน	สัดส่วนสาร อันดับ 1	การละลายน้ำ สารอันดับ 2	สัดส่วนสาร อันดับ 2	ความ หนืด
การละลายน้ำ สารอันดับ 1	-	-0.9170 ( $4.6 \times 10^{-11}$ )	0.1291 (0.53)	-0.7245 ( $2.9 \times 10^{-5}$ )	-0.1106 (0.59)	-0.2735 (0.18)
สัมประสิทธิ์น้ำ/ น้ำมัน	-0.9170 ( $4.6 \times 10^{-11}$ )	-	-0.2479 (0.22)	0.6317 ( $5.4 \times 10^{-4}$ )	0.2285 (0.23)	0.2973 (0.14)
สัดส่วนสาร อันดับ 1	0.1291 (0.53)	-0.2479 (0.22)	-	-0.1855 (0.36)	-0.8692 ( $8.4 \times 10^{-9}$ )	-0.1716 (0.40)
การละลายน้ำ สารอันดับ 2	-0.7245 ( $2.9 \times 10^{-5}$ )	0.6317 ( $5.4 \times 10^{-4}$ )	-0.1855 (0.36)	-	0.1938 (0.34)	0.3668 (0.065)
สัดส่วนสาร อันดับ 2	-0.1106 (0.59)	0.2285 (0.23)	-0.8692 ( $8.4 \times 10^{-9}$ )	0.1938 (0.34)	-	0.0945 (0.65)
ความหนืด	-0.2735 (0.18)	0.2973 (0.14)	-0.1716 (0.40)	0.3668 (0.065)	0.0945 (0.65)	-

จากการพิจารณาค่าสัมประสิทธิ์สหสัมพันธ์ระหว่างข้อมูลนำเข้าแต่ละชนิด พบว่าข้อมูลนำเข้า “การละลายน้ำสารอันดับ 1” มีความสัมพันธ์แบบแปรผกผันกับ “สัมประสิทธิ์น้ำ/น้ำมัน” ในระดับสูง สังเกตจากค่า  $r = -0.9170$  และมีค่า p-value คือ  $4.6 \times 10^{-11}$  แสดงให้เห็นว่า ค่าการละลายน้ำ (Water Solubility) ของสารต่าง ๆ จะมีความสัมพันธ์แบบแปรผกผันกับ ค่าสัมประสิทธิ์การกระจายตัวของสารในชั้นน้ำและน้ำมัน ( $\log P_{o/w}$ ) อย่างมีนัยสำคัญทางสถิติ [22, 23]

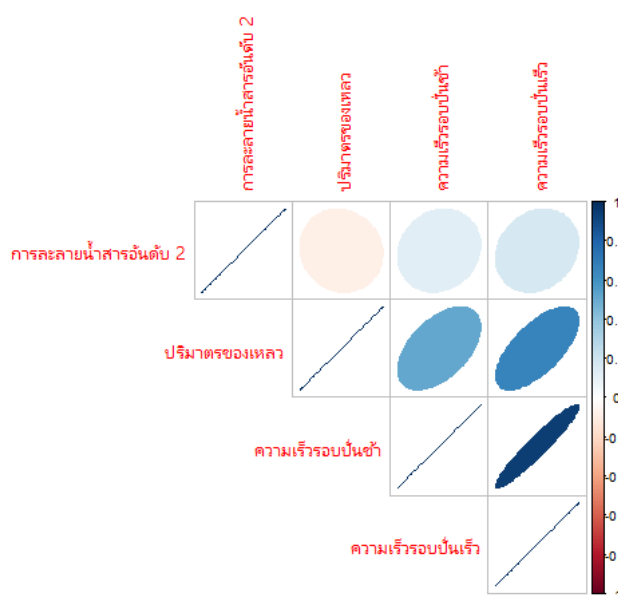
อีกทั้งยังพบความสัมพันธ์ระหว่างข้อมูลนำเข้า “สัดส่วนสารอันดับ 1” และ “สัดส่วนสารอันดับ 2” แบบแปรผกผันในระดับสูง สังเกตจากค่า  $r = -0.8692$  และค่า p-value คือ  $8.4 \times 10^{-9}$  ซึ่งสามารถอธิบายได้ว่า หากสารที่ใช้มากที่สุดในตำรับ อันดับ 1 มีปริมาณที่ถูกใช้ในตำรับมากขึ้น ก็จะทำให้สารที่ใช้มากที่สุดในตำรับ อันดับ 2 มีปริมาณที่ถูกใช้ในตำรับน้อยลงเช่นกันจึงทำให้ข้อมูลนำเข้าคู่ดังกล่าวมีความสัมพันธ์แบบแปรผกผันอย่างมีนัยสำคัญทางสถิติเช่นกัน

ขณะเดียวกันยังพบค่า  $r = -0.7245$  กับ  $p\text{-value} = 2.9 \times 10^{-5}$  ในคู่ของข้อมูลนำเข้า “การละลายน้ำสารอันดับ 1” กับ “การละลายน้ำสารอันดับ 2” และค่า  $r = 0.6317$  กับ  $p\text{-value} = 5.4 \times 10^{-4}$  ในคู่ของข้อมูลนำเข้า “สัมประสิทธิ์น้ำ/น้ำมัน” กับ “การละลายน้ำสารอันดับ 2” ซึ่งแสดงให้เห็นแนวโน้มที่จะมีความสัมพันธ์อย่างมีนัยสำคัญทางสถิติ แต่การสืบค้นเพิ่มเติมไม่พบว่ามีความสัมพันธ์กันจริง อีกทั้งในขณะที่คู่ของข้อมูลนำเข้าอื่น ๆ ไม่พบว่ามีค่า  $p\text{-value}$  ที่ต่ำกว่า 0.05 จึงไม่สามารถสรุปคู่ของข้อมูลอื่น ๆ ว่ามีความสัมพันธ์กันจริงหรือไม่

จากการพิจารณาข้อมูลสหสัมพันธ์ที่ได้ ผู้วิจัยจึงนำเอาข้อมูลนำเข้า “สัมประสิทธิ์น้ำ/น้ำมัน” และ “สัดส่วนสารอันดับ 2” ออกจากชุดข้อมูลนำเข้าเพื่อลดข้อมูลนำเข้าที่จำเป็น

#### 4.2.2 กลุ่มข้อมูลที่ 2

หลังจากวิเคราะห์กลุ่มข้อมูลที่ 1 เสร็จสิ้นแล้ว ผู้วิจัยได้ทำการวิเคราะห์ส่วนประกอบของกลุ่มข้อมูลที่ 2 ต่อไป โดยการหาสัมประสิทธิ์สหสัมพันธ์ เพื่อพิจารณาความสัมพันธ์ระหว่างกลุ่มข้อมูลนำเข้าในกลุ่มข้อมูลที่ 2 โดยมีผลลัพธ์แสดงดังรูปที่ 4-4 และตารางที่ 4-5



รูปที่ 4-4 สัมประสิทธิ์สหสัมพันธ์ของข้อมูลนำเข้าในกลุ่มข้อมูลที่ 2

ตารางที่ 4-5 ค่าสัมประสิทธิ์สหสัมพันธ์และค่า p-value ของข้อมูลนำเข้าในกลุ่มข้อมูลที่ 2

กลุ่มข้อมูลที่ 2	การละลายน้ำสารอันดับ 2	ปริมาตรของเหลว	ความเร็วรอบปั่นช้า	ความเร็วรอบปั่นเร็ว
การละลายน้ำสารอันดับ 2	-	-0.0808 (0.69)	0.1274 (0.54)	0.1776 (0.39)
ปริมาตรของเหลว	-0.0808 (0.69)	-	0.5144 (0.0072)	0.6651 ( $2.1 \times 10^{-4}$ )
ความเร็วรอบปั่นช้า	0.1274 (0.54)	0.5144 (0.0072)	-	0.9464 ( $2.8 \times 10^{-13}$ )
ความเร็วรอบปั่นเร็ว	0.1776 (0.39)	0.6651 ( $2.1 \times 10^{-4}$ )	0.9464 ( $2.8 \times 10^{-13}$ )	-

จากการตรวจสอบค่าสหสัมพันธ์ พบว่าข้อมูลนำเข้าที่มีความสัมพันธ์กันอย่างเห็นได้ชัดมีเพียงคู่ของข้อมูลนำเข้า “ความเร็วรอบปั่นช้า” และ “ความเร็วรอบปั่นเร็ว” ที่มีความสัมพันธ์แบบแปรผันตรง สังเกตได้จากค่า  $r = 0.9464$  อีกทั้งมีค่า p-value คือ  $2.8 \times 10^{-13}$  ซึ่งสอดคล้องกับหลักการตั้งความเร็วของเครื่องปั่นผสมเปียกที่มีความเร็วในการปั่นผสม 2 ระดับโดยที่ต้องเป็นสัดส่วนกัน อย่างไรก็ตาม ข้อมูลนำเข้าทั้ง 2 ชนิดที่กล่าวมาจะมีการถูกนำไปใช้ในแบบจำลองทำนายต่อไป จึงไม่สามารถทำการลดข้อมูลนำเข้าได้ ในขณะที่คู่ของข้อมูลนำเข้า “ความเร็วรอบปั่นช้า” กับ “ปริมาตรของเหลว” และคู่ของข้อมูลนำเข้า “ความเร็วรอบปั่นเร็ว” กับ “ปริมาตรของเหลว” มีแนวโน้มที่มีความสัมพันธ์แบบแปรผันตรง โดยมีค่า  $r$  คือ 0.5144 กับ 0.6651 และค่า p-value คือ 0.0072 และ  $2.1 \times 10^{-4}$  ตามลำดับ แต่เมื่อพิจารณาโดยละเอียดไม่สามารถหาสาเหตุของความสัมพันธ์ดังกล่าวได้ จึงไม่พิจารณาการลดข้อมูลนำเข้าใด ๆ ออก

### 4.3 การวิเคราะห์องค์ประกอบหลักหลังปรับปรุงข้อมูล

เมื่อปรับปรุงข้อมูลนำเข้าแล้ว ผู้วิจัยได้ทำการวิเคราะห์องค์ประกอบหลักอีกครั้งเพื่อพิจารณาการเปลี่ยนแปลงของความแปรปรวนในแต่ละองค์ประกอบ แสดงดังตารางที่ 4-6

ตารางที่ 4-6 ความแปรปรวนที่เกิดขึ้นในองค์ประกอบต่าง ๆ หลังนำข้อมูลนำเข้าออกบางส่วน

	องค์ประกอบที่ 1	องค์ประกอบที่ 2	องค์ประกอบที่ 3	องค์ประกอบที่ 4
ส่วนเบี่ยงเบนมาตรฐาน	1.6043	1.4105	0.9756	0.8676
อัตราส่วนของความแปรปรวน	0.3677	0.2842	0.1360	0.1075
อัตราส่วนของความแปรปรวนสะสม	0.3677	0.6519	0.7879	0.8954

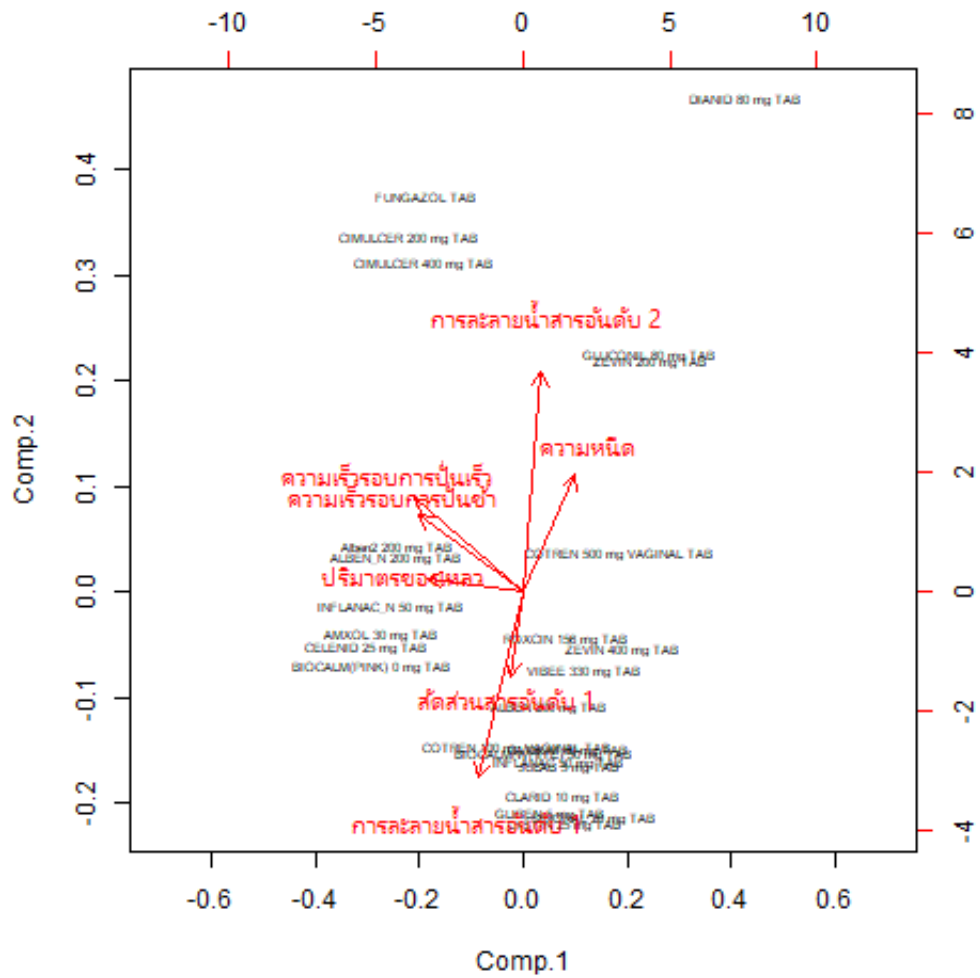
ข้อมูลในตารางแสดงให้เห็นว่าความแปรปรวนสะสมขององค์ประกอบ 4 อันดับแรกมีค่าลดลงเหลือ 73.36% เมื่อเปรียบเทียบกับความแปรปรวนสะสมก่อนปรับปรุงข้อมูล ผลลัพธ์ที่บ่งบอกว่าองค์ประกอบที่ได้ใหม่ยังคงใช้แทนองค์ประกอบเดิมได้ และสามารถนำข้อมูลนำเข้าที่ปรับปรุงแล้วมาอ้างอิงข้อมูลนำเข้าก่อนปรับปรุงได้ด้วย

หลังจากทำการวิเคราะห์ความแปรปรวนที่เปลี่ยนแปลงแล้ว ผู้วิจัยได้ทำการวิเคราะห์ส่วนประกอบในองค์ประกอบต่าง ๆ โดยได้ผลลัพธ์ดังตารางที่ 4-7 และรูปที่ 4-5 ดังนี้

ตารางที่ 4-7 ค่า loading ของข้อมูลนำเข้าที่เป็นส่วนประกอบในองค์ประกอบต่าง ๆ หลังปรับปรุง

ข้อมูล

ข้อมูลนำเข้า	องค์ประกอบที่ 1	องค์ประกอบที่ 2	องค์ประกอบที่ 3	องค์ประกอบที่ 4
การละลายน้ำสารอันดับ 1	-0.230	-0.538	0.286	-0.394
สัดส่วนสารอันดับ 1		-0.248	-0.921	-0.264
การละลายน้ำสารอันดับ 2		0.640	-0.190	0.120
ปริมาตรของเหลว	-0.499			0.165
ความหนืด	0.272	0.340	0.159	-0.820
ความเร็วรอบปั่นช้า	-0.544	0.222		-0.209
ความเร็วรอบปั่นเร็ว	-0.561	0.272		-0.131



รูปที่ 4-5 ข้อมูลนำเข้าที่เป็นส่วนประกอบขององค์ประกอบที่ 1 และ 2 หลังการปรับปรุงข้อมูล

จากรูปที่ 4-5 ซึ่งแสดงส่วนประกอบขององค์ประกอบที่ 1 และ 2 หลังการปรับปรุงข้อมูลแล้ว เมื่อสังเกตจากทิศทางและขนาดของลูกศรภายในรูป จะสังเกตเห็นแนวโน้มของความสัมพันธ์ระหว่างกลุ่มข้อมูลได้ดังนี้

- “การละลายน้ำสารอันดับ 1”, “สัดส่วนสารอันดับ 1” มีทิศทางเดียวกัน ในขณะที่ “การละลายน้ำสารอันดับ 2” “ความหนืด” ก็มีทิศทางเดียวกัน ซึ่งเป็นลักษณะเดียวกับข้อมูลก่อนการปรับปรุง
- “การละลายน้ำสารอันดับ 1” “สัดส่วนสารอันดับ 1” มีทิศทางตรงข้ามกับ “การละลายน้ำสารอันดับ 2” “ความหนืด” ซึ่งเป็นลักษณะเดียวกับข้อมูลก่อนการปรับปรุง
- “ปริมาตรของเหลว” “ความเร็วรอบการปั่นเร็ว” และ “ความเร็วรอบการปั่นช้า” มีทิศทางเดียวกัน ซึ่งเป็นลักษณะเดียวกับข้อมูลก่อนการปรับปรุง

จากแนวโน้มทั้งหมด ทิศทางของลูกศรยังไม่เปลี่ยนแปลงเมื่อเทียบกับก่อนปรับปรุงข้อมูล แสดงให้เห็นถึงความสัมพันธ์ของข้อมูลนำเข้าแต่ละชนิดที่ไม่เปลี่ยนแปลงจากเดิมหลังจากการปรับปรุงข้อมูลแล้ว ซึ่งสอดคล้องกับผลลัพธ์ในตารางที่ 4-7 ที่เห็นได้ว่าค่า Loading ของแต่ละข้อมูลมีแนวโน้มที่ไม่ได้เปลี่ยนแปลงจากเดิม

ด้วยการวิเคราะห์องค์ประกอบหลักและการวิเคราะห์สหสัมพันธ์เพื่อหาข้อมูลที่มีลักษณะใกล้เคียงกันและทำการปรับปรุงเพื่อลดข้อมูลบางชนิดออกนั้น สะท้อนให้เห็นว่าข้อมูลต่าง ๆ มีลักษณะที่เกี่ยวข้องกันดั้งเดิมและมีความซับซ้อนน้อยลงและผู้วิจัยจะนำกลุ่มข้อมูลที่ปรับปรุงแล้วไปทำการพัฒนาแบบจำลองต่อไป



## บทที่ 5

### การพัฒนาแบบจำลอง

หลังจากทำการวิเคราะห์ข้อมูลแล้ว ข้อมูลที่ได้จะถูกนำไปสร้างแบบจำลองที่ทำนายพารามิเตอร์จำนวนรอบในการปั่นผสมและทดสอบความถูกต้องในการทำนายของแบบจำลอง

#### 5.1 ข้อมูลเกี่ยวกับแบบจำลอง

ในขั้นตอนการสร้างแบบจำลอง ผู้วิจัยจะทำการแบ่งข้อมูลจำนวน 26 ชุด ซึ่งประกอบด้วยข้อมูลจากการทำแกรนูลเปียกแบบเดิม 17 ชุด และข้อมูลจากการทำแกรนูลเปียกแบบใหม่ 9 ชุด ออกเป็น 2 ส่วน คือ

- 1) ข้อมูลที่ใช้สร้างและฝึกฝนแบบจำลอง จำนวน 17 ชุด ซึ่งประกอบด้วยข้อมูลจากการทำแกรนูลเปียกแบบเดิม 11 ชุด และข้อมูลจากการทำแกรนูลเปียกแบบใหม่ 6 ชุด โดยมีชุดข้อมูลแสดงดังตารางที่ 5-1
- 2) ข้อมูลที่ใช้ทดสอบความถูกต้องในการทำนายของแบบจำลอง จำนวน 9 ชุด ซึ่งประกอบด้วยข้อมูลจากการทำแกรนูลเปียกแบบเดิม 6 ชุด และข้อมูลจากการทำแกรนูลเปียกแบบใหม่ 3 ชุด โดยมีชุดข้อมูลแสดงดังตารางที่ 5-2

ตารางที่ 5-1 ชุดข้อมูลที่ใช้สร้างและฝึกฝนแบบจำลอง

สูตรตำรับที่	1	2	3	4	5	6	7	8	9	10
การละลายน้ำสารอันดับ 1	2.5	2.5	0.0426	0.0426	195	195	195	195	195	195
สัดส่วนสารอันดับ 1	80.92	52.64	51.71	51.71	58.17	76.00	86.52	81.55	61.31	57.93
การละลายน้ำสารอันดับ 2	0	195	195	195	0	0	0	0.0141	0.00237	0.167
ปริมาตรของเหลว	7.00	5.40	4.53	6.50	33.60	1.30	15.60	7.20	20.00	24.00
ความหนืด	45	50	$7 \times 10^7$	$3 \times 10^5$	$1 \times 10^3$	$8 \times 10^3$	700	70	2800	200
ความเร็วรอบการปั่นช้า	30.0	30.0	30.0	30.0	30.1	55.0	30.1	30.0	30.1	30.1
ความเร็วรอบการปั่นเร็ว	0	0	0	0	0	0	0	0	0	0
จำนวนรอบ Impeller	900	900	600	900	903	1,650	903	900	451.5	903


  

สูตรตำรับที่	11	12	13	14	15	16	17
การละลายน้ำสารอันดับ 1	195	9.38	195	195	195	195	$8.66 \times 10^{-05}$
สัดส่วนสารอันดับ 1	37.98	79.21	61.31	80.53	88.46	35.92	54.05
การละลายน้ำสารอันดับ 2	0.0014	195	0.00237	0.75	0	0.0014	195
ปริมาตรของเหลว	25.00	28.00	26.00	32.00	30.00	26.00	30.00
ความหนืด	9	2	700	7	700	8	7.65
ความเร็วรอบการปั่นช้า	30.1	73	73	73	73	73	73
ความเร็วรอบการปั่นเร็ว	0	145	145	145	145	145	145
จำนวนรอบ Impeller	903	798	944	1888	1888	943	1598

ตารางที่ 5-2 ข้อมูลที่ใช้ทดสอบความถูกต้องในการทำนายของแบบจำลอง

สูตรตำรับที่	1	2	3	4	5	6	7	8	9
การละลายน้ำตาลอันดับ 1	0.0037	195	195	195	79	$1.89 \times 10^{-05}$	9.38	195	195
สัดส่วนสารอันดับ 1	41.39	75.10	68.34	83.33	64.52	81.81	69.57	73.79	40.15
การละลายน้ำตาลอันดับ 2	0	0	0.000414	0	0.0265	0	195	0.0185	0.0014
ปริมาตรของเหลว	12.40	17.00	2.90	21.00	17.50	26.00	33.30	28.00	26.00
ความหนืด	50	1000	20	20	8.5	80	850	45	9
ความเร็วรอบการปั่นช้า	30	30	55	30.1	30.1	30.1	73	73	73
ความเร็วรอบการปั่นเร็ว	0	0	0	0	0	0	145	145	145
จำนวนรอบ Impeller	900	900	1650	903	903	903	798	1888	943

โปรแกรมที่ใช้สร้างแบบจำลองคือโปรแกรม MATLAB รุ่น 9.3.0.713579 [24] ผู้วิจัยจะสร้างแบบจำลองจำนวน 2 ประเภท คือ แบบจำลองโครงข่ายประสาทเทียมหรือแบบจำลอง ANN และแบบจำลองสมการถดถอยประเภทซัพพอร์ตเวกเตอร์หรือแบบจำลอง SVR เพื่อเปรียบเทียบความถูกต้องในการทำนายของแบบจำลอง โดยมีแผนผังขั้นตอนการพัฒนาและวิเคราะห์แบบจำลอง ดังรูปที่ 5-1



รูปที่ 5-1 แผนผังการพัฒนาและวิเคราะห์แบบจำลอง

## 5.2 แบบจำลอง ANN

ในงานวิจัยนี้ ผู้วิจัยจะทำการกำหนดค่าปัจจัยต่าง ๆ ภายในแบบจำลอง ANN เพื่อหาแบบจำลองที่ทำนายค่าพารามิเตอร์ที่ต้องการได้ถูกต้องที่สุด โดยค่าปัจจัยที่มีการกำหนดจะมีดังต่อไปนี้

### 1) จำนวนชั้นของ ANN

การสร้างแบบจำลองโครงข่ายประสาทเทียมสามารถกำหนดจำนวนชั้นซ่อนของแบบจำลองได้ โดยจำนวนชั้นที่เพิ่มขึ้นจะทำให้การคำนวณภายในแบบจำลองมีความซับซ้อนขึ้นอันทำให้ความถูกต้องในการทำนายเพิ่มขึ้น ในงานวิจัยนี้จะมีการสร้างแบบจำลอง ANN 2 กลุ่มหลัก คือแบบจำลอง ANN 1 ชั้นซ่อน และแบบจำลอง ANN 2 ชั้นซ่อน


### 2) จำนวนประสาทเทียมในแต่ละชั้นของแบบจำลอง ANN

การสร้างแบบจำลอง ANN สามารถกำหนดจำนวนประสาทเทียมที่อยู่ภายในแต่ละชั้น ทำให้สามารถเพิ่มความซับซ้อนของการคำนวณภายในแบบจำลองได้ ในงานวิจัยนี้จะมีการกำหนดจำนวนประสาทเทียมในแต่ละชั้นตั้งแต่ 1 ถึง 10 ประสาทเทียม


### 3) ฟังก์ชันถ่ายโอน

ฟังก์ชันถ่ายโอนคือฟังก์ชันที่ใช้ในการปรับค่าของข้อมูลนำเข้าให้อยู่ในขอบเขตที่กำหนดไว้เพื่อลดความแปรผันของการทำนาย ฟังก์ชันถ่ายโอนภายในชั้นซ่อนของแบบจำลอง ANN ในงานวิจัยนี้จะถูกใช้จำนวน 3 ชนิด คือ ฟังก์ชัน Log-sigmoid (Logsig) ฟังก์ชันเส้นตรง (Purelin) และฟังก์ชัน Tan-sigmoid (Tansig)

ตัวอย่างของแบบจำลอง ANN ที่สร้างจากโปรแกรม จะแสดงดังรูปที่ 5-2 ซึ่งเป็นแบบจำลอง ANN ที่มีชั้นซ่อน 1 ชั้นและมีจำนวนประสาทเทียมในชั้นซ่อนด้วยกัน 10 ประสาทเทียมโดยมีฟังก์ชันถ่ายโอนคือ Tansig และรูปที่ 5-3 ซึ่งเป็นแบบจำลองที่มีชั้นซ่อน 2 ชั้นโดยมีจำนวนประสาทเทียมในชั้นซ่อนที่ 1 และชั้นซ่อนที่ 2 อย่างละ 5 ประสาทเทียมโดยมีฟังก์ชันถ่ายโอนในชั้นซ่อนที่ 1 และชั้นซ่อนที่ 2 คือ Logsig และ Purelin ตามลำดับ



รูปที่ 5-2 โครงสร้างของแบบจำลอง ANN ที่มีชั้นซ่อน 1 ชั้น



รูปที่ 5-3 โครงสร้างของแบบจำลอง ANN ที่มีชั้นซ่อน 2 ชั้น

แบบจำลอง ANN ทั้งหมดจะมีกระบวนการเรียนรู้แบบแพร่กระจายย้อนกลับของเลเวนเบิร์ก-มาควาดท์ (Levenberg-Maquardt's Back-Propagation) โดยกระบวนการเรียนรู้จะสิ้นสุดเมื่อ

- ค่า Performance Gradient มีค่าน้อยกว่า  $1.00 \times 10^{-7}$
- ค่า mu มีค่ามากกว่า  $1.00 \times 10^{10}$
- Validation Performance มากกว่า 6 ครั้ง
- Training Iteration ถึง 1000 ครั้ง

ความถูกต้องของการทำนายของแบบจำลอง ANN จะใช้ดัชนีชี้วัดคือรากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Square Error หรือ RMSE) ซึ่งเป็นค่าที่นิยมใช้ในการหาความเบี่ยงเบนของค่าที่ทำนายได้เมื่อเปรียบเทียบกับค่าจริง

### 5.2.1 แบบจำลอง ANN 1 ชั้นซ่อน

ในการพัฒนาแบบจำลอง ANN จะมีปัจจัยที่เกี่ยวข้องด้วยกันหลายปัจจัย ผู้วิจัยจึงทำการวิเคราะห์ปัจจัยที่เกี่ยวข้องที่ละปัจจัย

- จำนวนครั้งของการเรียนรู้และทำนาย

การทำงานของแบบจำลอง ANN จะมีการสุ่มค่าน้ำหนักก่อนการเรียนรู้ในการทำนาย จึงทำให้ค่าของข้อมูลนำออกแต่ละครั้งไม่เท่ากันซึ่งอาจมีความไม่สม่ำเสมอเกิดขึ้นได้ ผู้วิจัยจึงต้องหาความสม่ำเสมอของการทำนายก่อน โดยให้แบบจำลอง ANN เรียนรู้ข้อมูลนำเข้าและทำนายค่าของข้อมูลนำออกทั้งหมด 500 ครั้ง แล้วคำนวณ RMSE ของแบบจำลองทั้ง 500 ครั้ง นำค่า RMSE ที่ได้มาหาค่าเฉลี่ยและส่วนเบี่ยงเบนมาตรฐานของ RMSE ของแบบจำลอง โดยใช้ค่า RMSE จำนวน 10 20 50 100 200 และ 500 ครั้งมาคำนวณ โดยแสดงค่าดังตารางที่ 5-3 5-4 และ 5-5 และมีการแสดงการกระจายของค่า RMSE จากแบบจำลองจำนวน 10 20 50 100 200 และ 500 ครั้ง เมื่อใช้แบบจำลองที่มีฟังก์ชันต่าง ๆ และมีประสาทเทียม 1 5 และ 10 ตัวดังรูปที่ 5-4 5-5 และ 5-6

ตารางที่ 5-3 ค่าเฉลี่ยและส่วนเบี่ยงเบนมาตรฐานของค่า RMSE เมื่อใช้ฟังก์ชัน Logsig

จำนวนประสาท เทียมในชั้นซ่อน	ค่าเฉลี่ย $\pm$ ส่วนเบี่ยงเบนมาตรฐานของค่า RMSE					
	10 ครั้ง	20 ครั้ง	50 ครั้ง	100 ครั้ง	200 ครั้ง	500 ครั้ง
1	4.16 $\pm$ 1.25	4.18 $\pm$ 1.12	4.08 $\pm$ 1.00	4.02 $\pm$ 0.87	3.99 $\pm$ 0.99	3.98 $\pm$ 0.99
2	3.95 $\pm$ 0.59	4.02 $\pm$ 0.71	3.76 $\pm$ 0.93	3.91 $\pm$ 0.99	3.94 $\pm$ 0.97	3.93 $\pm$ 1.12
3	4.10 $\pm$ 1.20	3.96 $\pm$ 1.03	4.00 $\pm$ 1.05	3.89 $\pm$ 1.12	3.89 $\pm$ 1.13	4.02 $\pm$ 1.37
4	3.09 $\pm$ 1.34	3.73 $\pm$ 1.58	3.81 $\pm$ 1.56	3.94 $\pm$ 1.60	4.12 $\pm$ 1.62	4.10 $\pm$ 1.69
5	4.91 $\pm$ 1.90	4.64 $\pm$ 1.68	4.29 $\pm$ 2.06	4.07 $\pm$ 1.67	4.05 $\pm$ 1.54	4.12 $\pm$ 1.55
6	4.17 $\pm$ 1.00	4.10 $\pm$ 1.21	4.08 $\pm$ 1.20	4.32 $\pm$ 1.59	4.29 $\pm$ 1.60	4.25 $\pm$ 1.71
7	4.49 $\pm$ 1.17	4.43 $\pm$ 1.45	4.44 $\pm$ 1.48	4.38 $\pm$ 1.87	4.32 $\pm$ 1.74	4.37 $\pm$ 1.76
8	4.42 $\pm$ 1.18	4.15 $\pm$ 1.30	4.01 $\pm$ 1.29	4.06 $\pm$ 1.41	4.22 $\pm$ 1.63	4.30 $\pm$ 1.67
9	4.18 $\pm$ 1.77	3.99 $\pm$ 1.55	4.59 $\pm$ 2.24	4.61 $\pm$ 2.02	4.32 $\pm$ 1.90	4.29 $\pm$ 1.77
10	3.62 $\pm$ 0.95	3.96 $\pm$ 0.94	3.93 $\pm$ 1.22	4.16 $\pm$ 1.47	4.18 $\pm$ 1.65	4.28 $\pm$ 1.65


ตารางที่ 5-4 ค่าเฉลี่ยและส่วนเบี่ยงเบนมาตรฐานของค่า RMSE เมื่อใช้ฟังก์ชัน Purelin

จำนวนประสาท เทียมในชั้นซ่อน	ค่าเฉลี่ย $\pm$ ส่วนเบี่ยงเบนมาตรฐานของค่า RMSE					
	10 ครั้ง	20 ครั้ง	50 ครั้ง	100 ครั้ง	200 ครั้ง	500 ครั้ง
1	4.96 $\pm$ 2.24	7.84 $\pm$ 10.59	6.67 $\pm$ 8.36	6.82 $\pm$ 9.32	6.36 $\pm$ 8.96	6.29 $\pm$ 9.57
2	11.04 $\pm$ 15.09	14.86 $\pm$ 31.13	9.63 $\pm$ 20.92	7.67 $\pm$ 15.24	7.40 $\pm$ 12.78	7.28 $\pm$ 10.72
3	13.84 $\pm$ 15.63	9.11 $\pm$ 12.03	9.04 $\pm$ 11.28	8.30 $\pm$ 10.81	7.39 $\pm$ 9.12	7.86 $\pm$ 18.93
4	17.41 $\pm$ 23.02	13.14 $\pm$ 17.29	11.57 $\pm$ 15.12	10.64 $\pm$ 14.48	9.40 $\pm$ 12.57	9.80 $\pm$ 15.71
5	5.24 $\pm$ 1.95	7.64 $\pm$ 6.32	8.13 $\pm$ 7.62	8.96 $\pm$ 8.34	9.18 $\pm$ 11.42	9.88 $\pm$ 13.13
6	7.04 $\pm$ 2.46	6.14 $\pm$ 2.36	7.48 $\pm$ 9.47	11.79 $\pm$ 20.18	16.17 $\pm$ 46.56	13.43 $\pm$ 32.94
7	12.47 $\pm$ 15.73	11.96 $\pm$ 17.43	12.62 $\pm$ 23.85	15.60 $\pm$ 26.07	16.07 $\pm$ 39.62	14.19 $\pm$ 28.82
8	4.69 $\pm$ 1.27	6.66 $\pm$ 5.29	9.31 $\pm$ 9.95	21.64 $\pm$ 81.87	16.33 $\pm$ 58.83	16.18 $\pm$ 47.34
9	8.76 $\pm$ 14.21	14.99 $\pm$ 25.17	11.85 $\pm$ 19.05	13.07 $\pm$ 16.28	14.75 $\pm$ 24.32	17.25 $\pm$ 30.23
10	11.63 $\pm$ 9.33	14.47 $\pm$ 14.42	13.87 $\pm$ 14.06	14.70 $\pm$ 16.28	16.58 $\pm$ 25.65	18.81 $\pm$ 33.46




ตารางที่ 5-5 ค่าเฉลี่ยและส่วนเบี่ยงเบนมาตรฐานของค่า RMSE เมื่อใช้ฟังก์ชัน Tansig


จำนวนประสาท เทียมในชั้นซ่อน	ค่าเฉลี่ย $\pm$ ส่วนเบี่ยงเบนมาตรฐานของค่า RMSE					
	10 ครั้ง	20 ครั้ง	50 ครั้ง	100 ครั้ง	200 ครั้ง	500 ครั้ง
1	$3.87 \pm 0.67$	$4.53 \pm 2.99$	$4.25 \pm 2.07$	$4.15 \pm 1.64$	$4.05 \pm 1.33$	$4.05 \pm 1.22$
2	$4.58 \pm 1.05$	$4.27 \pm 1.72$	$4.16 \pm 1.58$	$3.99 \pm 1.38$	$4.02 \pm 1.28$	$4.07 \pm 1.51$
3	$3.92 \pm 1.10$	$3.96 \pm 0.95$	$3.89 \pm 1.12$	$4.07 \pm 1.36$	$3.96 \pm 1.36$	$4.03 \pm 1.48$
4	$3.91 \pm 1.51$	$4.64 \pm 2.83$	$4.17 \pm 2.11$	$4.14 \pm 1.95$	$4.12 \pm 1.75$	$4.22 \pm 1.82$
5	$4.45 \pm 2.18$	$4.47 \pm 2.36$	$4.22 \pm 1.98$	$4.28 \pm 1.73$	$4.30 \pm 1.77$	$4.28 \pm 1.90$
6	$3.84 \pm 1.41$	$3.81 \pm 1.22$	$3.99 \pm 1.34$	$4.31 \pm 1.56$	$4.41 \pm 1.89$	$4.36 \pm 1.91$
7	$5.21 \pm 2.96$	$4.49 \pm 2.34$	$4.25 \pm 1.94$	$4.16 \pm 1.81$	$4.33 \pm 1.80$	$4.26 \pm 1.77$
8	$4.52 \pm 1.86$	$3.99 \pm 1.67$	$4.07 \pm 1.56$	$4.12 \pm 1.61$	$4.18 \pm 1.70$	$4.18 \pm 1.88$
9	$5.23 \pm 1.94$	$4.53 \pm 1.84$	$4.33 \pm 1.72$	$4.25 \pm 1.70$	$4.17 \pm 1.75$	$4.22 \pm 1.80$
10	$4.90 \pm 2.94$	$4.44 \pm 2.31$	$4.50 \pm 2.50$	$4.50 \pm 2.36$	$4.28 \pm 2.11$	$4.29 \pm 2.07$



รูปที่ 5-4 การกระจายของค่า RMSE เมื่อใช้ฟังก์ชัน Logsig และมีประสาทเทียม 1 5 และ 10 ตัว



รูปที่ 5-5 การกระจายของค่า RMSE เมื่อใช้ฟังก์ชัน Purelin และมีประสาทเทียม 1 5 และ 10 ตัว



รูปที่ 5-6 การกระจายของค่า RMSE เมื่อใช้ฟังก์ชัน Tansig และมีประสาทเทียม 1 5 และ 10 ตัว

ผลลัพธ์จากตารางที่ 5-3 5-4 และ 5-5 เมื่อค่าเฉลี่ยของ RMSE ที่ได้จากการนำค่า RMSE จากการพัฒนาแบบจำลองจำนวน 10 20 50 100 200 และ 500 ครั้งแรกมาคำนวณและเปรียบเทียบ จำนวนประสาทเทียมในชั้นซ่อนและฟังก์ชันถ่ายโอนที่ใช้เหมือนกัน พบว่าค่าเฉลี่ยของ RMSE ไม่ได้เปลี่ยนแปลงไปมากนัก อีกทั้งรูปที่ 5-4 5-5 และ 5-6 ก็แสดงการกระจายของค่า RMSE เมื่อใช้จำนวนประสาทเทียม 10 20 50 100 200 และ 500 ครั้ง ที่มีช่วงกระจายไม่แตกต่างกัน ผลลัพธ์ทั้งสองรูปแบบแสดงให้เห็นถึงแนวโน้มที่ค่าเฉลี่ยของ RMSE จากการคำนวณจำนวน 10 20 50 100 200 และ 500 ครั้งแรกจะไม่แตกต่างกัน ทำให้ผู้วิจัยตั้งสมมติฐานเพื่อยืนยันแนวคิดดังกล่าว ดังนี้

$H_0$ : ค่าเฉลี่ยของ RMSE เมื่อคำนวณจากค่า RMSE จำนวน 10 20 50 100 200 และ 500 ครั้งไม่แตกต่างกัน

$H_1$ : มีค่าเฉลี่ยของ RMSE เมื่อคำนวณจากค่า RMSE จำนวน 10 20 50 100 200 และ 500 ครั้งอย่างน้อย 1 คู่ที่แตกต่างกัน

การวิเคราะห์สมมติฐานจะใช้การวิเคราะห์ความแปรปรวน (Analysis of Variance: ANOVA) ที่ระดับนัยสำคัญทางสถิติ  $\alpha = 0.05$  โดยจะทำการวิเคราะห์เปรียบเทียบภายในแบบจำลอง ที่มีจำนวนประสาทเทียมในชั้นซ่อนและฟังก์ชันถ่ายโอนเหมือนกัน โดยมีค่า p-value แสดงดังตารางที่ 5-6


ตารางที่ 5-6 ค่า p-value ที่ได้จากการทดสอบ ANOVA เปรียบเทียบค่าเฉลี่ย RMSE เมื่อใช้จำนวน RMSE เป็น 10 20 50 100 200 และ 500 ครั้ง

ฟังก์ชันถ่ายโอน	จำนวนประสาทเทียมในชั้นซ่อน									
	1	2	3	4	5	6	7	8	9	10
Logsig	0.90	0.92	0.81	0.27	0.36	0.96	1.00	0.68	0.52	0.48
Purelin	0.96	0.16	0.84	0.49	0.66	0.51	0.96	0.70	0.49	0.61
Tansig	0.62	0.80	0.97	0.86	1.00	0.46	0.64	0.98	0.53	0.85

ผลลัพธ์จากตารางที่ 5-6 พบว่า p-value ทุกกรณีมีค่าไม่น้อยกว่าค่าระดับนัยสำคัญทางสถิติที่  $\alpha = 0.05$  แสดงว่าแบบจำลองทุกแบบไม่สามารถปฏิเสธ  $H_0$  หรือก็คือ “ค่าเฉลี่ยของ RMSE เมื่อคำนวณจากค่า RMSE จำนวน 10 20 50 100 200 และ 500 ครั้งไม่แตกต่างกัน” ไม่ว่าจะใช้จำนวนประสาทเทียมในชั้นซ่อนหรือฟังก์ชันถ่ายโอนใด จากผลลัพธ์ที่ได้ แสดงว่าแบบจำลองมีความสม่ำเสมอในการทำนาย ซึ่งผู้วิจัยจะใช้ข้อมูล RMSE 100 ครั้งแรกของแบบจำลองเพื่อนำไปใช้วิเคราะห์ปัจจัยอื่น ๆ ต่อไป

- ฟังก์ชันถ่ายโอนที่ใช้

ในขั้นตอนนี้ ผู้วิจัยจะพิจารณาผลของฟังก์ชันถ่ายโอนที่ใช้ต่อค่า RMSE จากแบบจำลองเมื่อใช้จำนวนประสาทเทียมในแบบจำลองเท่ากัน โดยนำค่าเฉลี่ยของ RMSE จำนวน 100 ครั้งจากแบบจำลองที่ใช้ฟังก์ชันถ่ายโอน 3 ชนิด ได้แก่ Logsig, Purelin และ Tansig เมื่อใช้จำนวนประสาทเทียม 1 – 10 ตัว มาสร้างกราฟเส้น ได้ดังรูปที่ 5-7



รูปที่ 5-7 ค่าเฉลี่ยของ RMSE ของแบบจำลองเมื่อใช้จำนวนประสาทเทียมและฟังก์ชันถ่ายโอน  
แตกต่างกัน

จากรูปที่ 5-7 พบแนวโน้มที่การใช้ฟังก์ชันถ่ายโอน Purelin ในแบบจำลอง ANN จะทำให้ค่าเฉลี่ยของ RMSE แตกต่างกันในทุกจำนวนประสาทเทียมที่ใช้ ผู้วิจัยจึงตั้งสมมติฐานเพื่อยืนยันแนวโน้มที่พบ ดังนี้

$H_0$ : ค่าเฉลี่ยของ RMSE ระหว่างแบบจำลองที่ใช้ฟังก์ชันถ่ายโอนทั้ง 3 ชนิดไม่แตกต่างกัน

$H_1$ : มีค่าเฉลี่ยของ RMSE ระหว่างแบบจำลองที่ใช้ฟังก์ชันถ่ายโอนทั้ง 3 ชนิดอย่างน้อย 1 คู่ที่แตกต่างกัน

การทดสอบสมมติฐานจะใช้การวิเคราะห์ความแปรปรวน (ANOVA) ที่ระดับนัยสำคัญทางสถิติ  $\alpha = 0.05$  โดยจะเปรียบเทียบค่า RMSE จากแบบจำลองที่ใช้จำนวนประสาทเทียมเท่ากัน (ตั้งแต่ 1 – 10 ตัว) โดยมีค่า p-value จากการทดสอบสมมติฐานดังตารางที่ 5-7 ดังนี้

ตารางที่ 5-7 ค่า p-value ที่ได้จากการทดสอบ ANOVA เมื่อใช้ฟังก์ชันถ่ายโอนแตกต่างกัน

จำนวนประสาทเทียมในชั้นซ่อน (ตัว)	1	2	3	4	5	6	7	8	9	10
p-value	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.01	0.00	0.00

ผลลัพธ์จากตารางที่ 5-7 แสดงให้เห็นว่า p-value ที่ได้จากการทดสอบสมมติฐานน้อยกว่าค่าระดับนัยสำคัญทางสถิติที่  $\alpha = 0.05$  ในทุกกรณี (พบความแตกต่างของค่า RMSE จากแบบจำลองที่ใช้จำนวนประสาทเทียมเท่ากันแต่ใช้ฟังก์ชันถ่ายโอนแตกต่างกัน) ผู้วิจัยจึงปฏิเสธ  $H_0$  แสดงว่า “มีค่าเฉลี่ยของกลุ่ม RMSE ระหว่างแบบจำลองที่ใช้ฟังก์ชันถ่ายโอนทั้ง 3 ชนิดอย่างน้อย 1 คู่ที่แตกต่างกัน” ขั้นตอนถัดมาจึงเป็นการหาว่าฟังก์ชันถ่ายโอนใดที่ทำให้ค่า RMSE ที่ได้แตกต่างออกไป ผู้วิจัยจึงทำการทดสอบ Tukey’s Honestly Significant Different Post Hoc Test หรือ Tukey’s Test โดยใช้สมมติฐาน  $H_0, H_1$  เดิมที่ระดับนัยสำคัญทางสถิติ  $\alpha = 0.05$  โดยได้ค่า p-value ดังตารางที่ 5-8

ตารางที่ 5-8 ค่า p-value ที่ได้จากการทดสอบ Tukey’s Test เมื่อเปรียบเทียบระหว่างฟังก์ชันถ่ายโอน ณ จำนวนประสาทเทียมในชั้นซ่อนต่าง ๆ

จำนวนประสาทเทียมในชั้นซ่อน		1	2	3	4	5	6	7	8	9	10
คู่ฟังก์ชันถ่ายโอนที่เปรียบเทียบ	Logsig - Purelin	0.00	0.01	0.00	0.00	0.00	0.00	0.00	0.02	0.00	0.00
	Logsig - Tansig	0.99	1.00	0.98	0.98	0.95	1.00	0.99	1.00	0.98	0.96
	Purelin - Tansig	0.00	0.01	0.00	0.00	0.00	0.00	0.00	0.02	0.00	0.00

ผลลัพธ์จากตารางที่ 5-8 มีด้วยกัน 2 ลักษณะ ดังนี้

- ค่า p-value ที่ได้จากการเปรียบเทียบแบบจำลองที่ใช้ฟังก์ชัน Purelin กับแบบจำลองที่ใช้ฟังก์ชันอื่น ๆ (Logsig หรือ Tansig) มีค่าน้อยกว่าค่าระดับนัยสำคัญทางสถิติที่  $\alpha = 0.05$  ในทุกกรณี (ไม่ขึ้นกับจำนวนประสาทเทียมที่ใช้) ทำให้เกิดการปฏิเสธ  $H_0$  แสดงว่าแบบจำลองที่ใช้ฟังก์ชัน Purelin จะให้ค่า RMSE แตกต่างจากแบบจำลองที่ใช้ฟังก์ชัน Logsig และ Tansig
- ค่า p-value ที่ได้จากการเปรียบเทียบแบบจำลองที่ใช้ฟังก์ชัน Logsig กับแบบจำลองที่ใช้ฟังก์ชัน Tansig มีค่าไม่น้อยกว่าค่าระดับนัยสำคัญทางสถิติที่  $\alpha = 0.05$  ในทุกกรณี (ไม่ขึ้นกับจำนวนประสาทเทียมที่ใช้) ทำให้ไม่ปฏิเสธ  $H_0$  แสดงว่าค่า RMSE จากแบบจำลองที่ใช้ฟังก์ชัน Logsig กับแบบจำลองที่ใช้ฟังก์ชัน Tansig ไม่แตกต่างกัน

ผลลัพธ์จากตารางที่ 5-8 สอดคล้องกับผลลัพธ์ในรูปแบบที่ 5-7 ที่แสดงให้เห็นว่าแบบจำลองที่ใช้ฟังก์ชันถ่ายโอน Purelin ให้ค่า RMSE สูงกว่าแบบจำลองที่ใช้ฟังก์ชัน Logsig หรือ Tansig เป็นการบ่งบอกถึงความสัมพันธ์ภายในกลุ่มข้อมูลนำเข้า-ข้อมูลนำออกที่ไม่เป็นเส้นตรง จึงทำให้การใช้ฟังก์ชัน Purelin ไม่เหมาะสมในกรณีนี้

จากข้อมูลที่ได้ จึงสรุปได้ว่าการใช้ฟังก์ชันถ่ายโอน Purelin ไม่เหมาะสมต่อการทำนายผลข้อมูลนำออกในงานวิจัย ผู้วิจัยจึงพิจารณาไม่นำฟังก์ชันถ่ายโอน Purelin มาใช้ต่อไปและจะใช้ฟังก์ชันถ่ายโอน Logsig และ Tansig ในแบบจำลองเพื่อพิจารณาผลด้านอื่น ๆ ต่อไป

- จำนวนประสาทเทียมที่ใช้

ในขั้นตอนนี้ ผู้วิจัยจะพิจารณาผลของจำนวนประสาทเทียมที่ใช้ต่อค่า RMSE จากแบบจำลองที่ใช้ฟังก์ชัน Logsig และ Tansig ซึ่งการสังเกตผลจากในรูปที่ 5-7 พบแนวโน้มที่การใช้จำนวนประสาทเทียมที่แตกต่างกันจะทำให้ค่าเฉลี่ยของ RMSE แตกต่างกัน ทั้งในแบบจำลองที่ใช้ฟังก์ชันถ่ายโอน Logsig และ Tansig ผู้วิจัยจึงตั้งสมมติฐานเพื่อการทดสอบแนวโน้มที่พบ ดังนี้

$H_0$ : ค่าเฉลี่ยของกลุ่ม RMSE ระหว่างแบบจำลองที่ใช้จำนวนประสาทเทียม 1 – 10 ตัว ไม่แตกต่างกัน

$H_1$ : มีค่าเฉลี่ยของกลุ่ม RMSE ระหว่างแบบจำลองที่ใช้จำนวนประสาทเทียม 1 – 10 ตัวอย่างน้อย 1 คู่ที่แตกต่างกัน

การทดสอบสมมติฐานจะใช้วิธีการวิเคราะห์ความแปรปรวน (ANOVA) ที่ระดับนัยสำคัญทางสถิติ  $\alpha = 0.05$  โดยมีผลลัพธ์แสดงดังตารางที่ 5-9

ตารางที่ 5-9 ค่า p-value จากการทดสอบ ANOVA เมื่อใช้จำนวนประสาทเทียมแตกต่างกัน


ANOVA	p-value
Logsig	0.01
Tansig	0.72

ผลลัพธ์จากตารางที่ 5-9 มีด้วยกัน 2 ลักษณะ ดังนี้

- ค่า p-value ที่ได้จากการทดสอบแบบจำลองที่ใช้ฟังก์ชัน Logsig น้อยกว่าค่าระดับนัยสำคัญทางสถิติที่  $\alpha = 0.05$  ทำให้เกิดการปฏิเสธ  $H_0$  แสดงว่า “มีค่าเฉลี่ยของกลุ่ม RMSE ระหว่างแบบจำลองที่ใช้ฟังก์ชัน Logsig และจำนวนประสาทเทียม 1 – 10 ตัวอย่างน้อย 1 คู่ที่แตกต่างกัน”







รูปที่ 5-8 ค่า RMSE เมื่อใช้ฟังก์ชัน Logsig และจำนวนประสาทเทียมแตกต่างกัน

ผลลัพธ์จากตารางที่ 5-10 แสดงให้เห็นถึงความแตกต่างของค่า RMSE ของแบบจำลองที่ใช้จำนวนประสาทเทียม 9 ตัวเมื่อเปรียบเทียบกับค่า RMSE ที่ได้จากแบบจำลองที่ใช้จำนวนประสาทเทียม 2 – 4 ตัว ซึ่งสอดคล้องกับผลลัพธ์ในรูปที่ 5-8 อย่างไรก็ตาม ไม่พบแนวโน้มความแตกต่างในกรณีอื่น ๆ เลย จากผลลัพธ์ดังกล่าวจึงไม่สามารถระบุผลของจำนวนประสาทเทียมต่อค่า RMSE จากแบบจำลองที่ใช้ฟังก์ชัน Logsig ได้แน่ชัด และสรุปว่าจำนวนประสาทเทียมไม่มีผลต่อค่า RMSE จากแบบจำลองที่ใช้ฟังก์ชัน Logsig ดังนั้น จำนวนประสาทเทียมที่เหมาะสมสำหรับแบบจำลองโครงข่ายประสาทเทียมที่มีชั้นซ่อน 1 ชั้น ได้แก่ 1 – 10 ตัว

จากการพัฒนาแบบจำลอง ANN 1 ชั้นซ่อน จะสรุปได้ว่าฟังก์ชันที่ทำให้การทำนายของแบบจำลองมีความเหมาะสม คือฟังก์ชัน Logsig และ Tansig ในขณะที่การเลือกใช้จำนวนประสาทเทียมตั้งแต่ 1 – 10 ตัว ให้ค่าเฉลี่ยของ RMSE ไม่แตกต่างกัน ซึ่งผู้วิจัยจะนำข้อสรุปที่ได้ไปใช้ในการพัฒนาแบบจำลอง ANN 2 ชั้นซ่อนต่อไป

### 5.2.2 แบบจำลอง ANN 2 ชั้นซ่อน

การสร้างแบบจำลอง ANN 2 ชั้นซ่อนจะมีขั้นตอนเหมือนกับการสร้างแบบจำลอง ANN 1 ชั้นซ่อน คือให้ข้อมูลแก่แบบจำลองและเรียนรู้ทั้งหมด 100 ครั้ง แล้วหาค่า RMSE ของการเรียนรู้ทั้ง 100 ครั้ง ทำเป็นค่าเฉลี่ยของ RMSE โดยมีปัจจัยที่เกี่ยวข้องในแบบจำลองทั้งหมด 3 ปัจจัย ได้แก่

- 1) ชนิดของฟังก์ชันถ่ายโอนที่ใช้ในชั้นซ่อนแต่ละชั้น คือ Logsig หรือ Tansig
- 2) จำนวนประสาทเทียมในชั้นซ่อนที่ 1 โดยมีจำนวนประสาทเทียมตั้งแต่ 1 – 10 ตัว
- 3) จำนวนประสาทเทียมในชั้นซ่อนที่ 2 โดยมีจำนวนประสาทเทียมตั้งแต่ 1 – 10 ตัว

- ฟังก์ชันถ่ายโอนที่ใช้

เมื่อจำแนกแบบจำลอง ANN จากฟังก์ชันถ่ายโอนที่ใช้ในชั้นซ่อนทั้ง 2 ชั้น จะทำให้มีแบบจำลอง ANN ทั้งหมด 4 ประเภท คือแบบจำลองที่ใช้ชุดฟังก์ชันถ่ายโอน “Logsig-Logsig”, “Logsig-Tansig”, “Tansig-Logsig” และ “Tansig-Tansig” โดยแต่ละประเภทมีจำนวนประสาทเทียมในชั้นซ่อนคือ 1 – 10 ประสาทเทียม ทำให้แบบจำลอง ANN แต่ละประเภทมีชุดของจำนวนประสาทเทียมตั้งแต่  $1 \times 1$  ประสาทเทียม จนถึง  $10 \times 10$  ประสาทเทียม เป็น 100 ชุด จึงมีค่าเฉลี่ยของ RMSE ในแบบจำลองแต่ละประเภททั้งหมด 100 ค่า ซึ่งมีการหาค่าต่าง ๆ ทางสถิติของชุดค่าเฉลี่ย RMSE ดังตารางที่ 5-11


ตารางที่ 5-11 ค่าสถิติต่าง ๆ ของกลุ่มค่า RMSE ในแบบจำลอง ANN 2 ชั้นซ่อน

ฟังก์ชันถ่ายโอนในแต่ละชั้นซ่อน		ช่วงระยะ	เปอร์เซ็นต์ไทล์ ที่ 10	มัธยฐาน	เปอร์เซ็นต์ไทล์ ที่ 90
ชั้นที่ 1	ชั้นที่ 2				
Logsig	Logsig	3.56 – 4.35	3.70	3.87	4.02
	Tansig	3.56 – 4.26	3.72	3.88	4.11
Tansig	Logsig	3.50 – 4.34	3.67	3.88	4.06
	Tansig	3.55 – 4.60	3.75	3.91	4.17


เมื่อนำกลุ่มค่าเฉลี่ยของ RMSE ของแบบจำลอง ANN 2 ชั้นซ่อนแต่ใช้ฟังก์ชันถ่ายโอนแตกต่างกันมาเปรียบเทียบโดยการนับช่วงความถี่ของค่าเฉลี่ยของ RMSE แสดงดังตารางที่ 5-12 และนำไปทำกราฟฮิสโตแกรมแสดงการกระจายของค่าเฉลี่ยของ RMSE ดังรูปที่ 5-9 5-10 5-11 และ 5-12

ตารางที่ 5-12 ช่วงความถี่ของค่าเฉลี่ยของ RMSE ของแบบจำลอง ANN 2 ชั้นซ่อนเมื่อใช้ฟังก์ชันถ่ายโอนแตกต่างกัน


ช่วงระยะ	ความถี่ของค่าเฉลี่ยของ RMSE			
	Logsig-Logsig	Logsig – Tansig	Tansig-Logsig	Tansig-Tansig
3.40 – 3.49	0	0	1	0
3.50 – 3.59	2	2	3	1
3.60 – 3.69	8	6	9	5
3.70 – 3.79	15	17	17	19
3.80 – 3.89	34	29	25	23
3.90 – 3.99	27	23	28	19
4.00 – 4.09	10	10	11	17
4.10 – 4.19	1	10	5	12
4.20 – 4.29	2	3	0	1
4.30 – 4.39	1	0	1	2
4.40 – 4.49	0	0	0	0
4.50 – 4.59	0	0	0	1




รูปที่ 5-9 การกระจายของค่าเฉลี่ยของ RMSE ของแบบจำลองที่ใช้ชุดฟังก์ชัน Logsig-Logsig



รูปที่ 5-10 การกระจายของค่าเฉลี่ยของ RMSE ของแบบจำลองที่ใช้ชุดฟังก์ชัน Logsig-Tansig



รูปที่ 5-11 การกระจายของค่าเฉลี่ยของ RMSE ของแบบจำลองที่ใช้ชุดฟังก์ชัน Tansig-Logsig



รูปที่ 5-12 การกระจายของค่าเฉลี่ยของ RMSE ของแบบจำลองที่ใช้ชุดฟังก์ชัน Tansig-Tansig

ผลลัพธ์จากรูปที่ 5-9 5-10 5-11 และ 5-12 พบว่าค่าเฉลี่ยของ RMSE ส่วนใหญ่มีการกระจายอยู่ในช่วง 3.6 – 4.2 อย่างไรก็ตาม พบว่าแบบจำลองที่ใช้ชุดฟังก์ชัน Tansig-Tansig มีการกระจายของค่า RMSE ที่แตกต่างออกไปจากแบบจำลองอื่น ๆ จึงมีความเป็นไปได้ที่แบบจำลองที่ใช้ชุดฟังก์ชันถ่ายโอนแตกต่างกันจะทำให้การกระจายของกลุ่มค่าเฉลี่ยของ RMSE แตกต่างกันได้ด้วย เพื่อพิสูจน์ความเป็นไปได้อย่างกล่าว ผู้วิจัยจึงตั้งสมมติฐานเพื่อการทดสอบดังนี้

$H_0$ : กลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลองที่ใช้ชุดฟังก์ชันถ่ายโอนแตกต่างกันแต่มีจำนวนประชากรเทียบในแต่ละชั้นซ้อนเท่ากัน จะไม่แตกต่างกัน

$H_1$ : กลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลองที่ใช้ชุดฟังก์ชันถ่ายโอนแตกต่างกันแต่มีจำนวนประชากรเทียบในแต่ละชั้นซ้อนเท่ากัน จะแตกต่างกัน

การทดสอบสมมติฐานจะใช้วิธี Two-tailed Paired T-test ที่ระดับนัยสำคัญทางสถิติ  $\alpha = 0.05$  โดยมีผลลัพธ์แสดงดังตารางที่ 5-13

ตารางที่ 5-13 ค่า p-value ที่ได้จากการทดสอบ two-tailed Paired T-test ระหว่างแบบจำลองที่ใช้ชุดฟังก์ชันถ่ายโอนแตกต่างกัน

ชุดฟังก์ชัน	Logsig-Logsig	Logsig-Tansig	Tansig-Logsig	Tansig-Tansig
Logsig-Logsig	/	0.12	0.94	0.00
Logsig-Tansig	/	/	0.12	0.05
Tansig-Logsig	/	/	/	0.00
Tansig-Tansig	/	/	/	/

ผลลัพธ์จากตารางที่ 5-13 มีด้วยกัน 2 ลักษณะ ดังนี้

- ค่า p-value ที่ได้จากการเปรียบเทียบแบบจำลองที่ใช้ชุดฟังก์ชัน Tansig-Tansig กับแบบจำลองที่ใช้ชุดฟังก์ชันอื่น ๆ มีค่าน้อยกว่าระดับนัยสำคัญทางสถิติ  $\alpha = 0.05$  ทุกกรณี (0.1202, 0.1205 และ 0.0018 ตามลำดับ) นำไปสู่การปฏิเสธ  $H_0$  ในกรณีที่ใช้แบบจำลองที่ใช้ชุดฟังก์ชัน Tansig-Tansig แสดงว่า “กลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลองที่ใช้ชุดฟังก์ชันถ่ายโอน Tansig-Tansig แต่มีจำนวนประสาทเทียมในแต่ละชั้นซ่อนเท่ากัน จะแตกต่างจากแบบจำลองที่ใช้ชุดฟังก์ชันถ่ายโอนอื่น ๆ”
- ค่า p-value ที่ได้จากการเปรียบเทียบแบบจำลองที่ใช้ชุดฟังก์ชันถ่ายโอนที่ไม่ใช่ Tansig-Tansig มีค่าน้อยกว่าระดับนัยสำคัญทางสถิติ  $\alpha = 0.05$  ทำให้ไม่สามารถปฏิเสธ  $H_0$  ได้ แสดงว่า “กลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลองที่ใช้ชุดฟังก์ชันถ่ายโอนที่ไม่ใช่ Tansig-Tansig แต่มีจำนวนประสาทเทียมในแต่ละชั้นซ่อนเท่ากัน จะไม่แตกต่างกัน”

จุฬาลงกรณ์มหาวิทยาลัย

จากข้อสรุปที่ได้ บ่งบอกว่าการใช้ชุดฟังก์ชันถ่ายโอน Tansig-Tansig ในแบบจำลองจะทำให้กลุ่มค่าเฉลี่ยของ RMSE แตกต่างจากแบบจำลองที่ใช้ชุดฟังก์ชันถ่ายโอนอื่น ๆ เมื่อพิจารณาเพิ่มเติมมีความเป็นไปได้ว่ากลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลองที่ใช้ชุดฟังก์ชันถ่ายโอน Tansig-Tansig จะมากกว่ากลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลองที่ใช้ชุดฟังก์ชันถ่ายโอนอื่น ๆ ผู้วิจัยจึงตั้งสมมติฐานเพื่อทดสอบความเป็นไปได้นี้ดังต่อไปนี้

$H_0$ : กลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลองที่ใช้ชุดฟังก์ชัน Tansig-Tansig แต่มีจำนวนประสาทเทียมในชั้นซ่อนแต่ละชั้นเท่ากันจะไม่มากกว่ากลุ่มค่าเฉลี่ยจากแบบจำลองที่ใช้ชุดฟังก์ชันอื่น ๆ

$H_1$ : กลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลองที่ใช้ชุดฟังก์ชัน Tansig-Tansig แต่มีจำนวนประสาทเทียมในชั้นซ่อนแต่ละชั้นเท่ากันจะมากกว่ากลุ่มค่าเฉลี่ยจากแบบจำลองที่ใช้ชุดฟังก์ชันอื่น ๆ

การทดสอบสมมติฐานจะใช้วิธีการ One-tailed Paired T-test ที่ระดับนัยสำคัญทางสถิติ  $\alpha = 0.05$  โดยมีผลลัพธ์แสดงดังตารางที่ 5-14

ตารางที่ 5-14 ค่า p-value ที่ได้จากการทดสอบ One-tailed Paired T-test ระหว่างแบบจำลองที่ใช้ชุดฟังก์ชันถ่ายโอนอื่น ๆ กับแบบจำลองที่ใช้ชุดฟังก์ชัน Tansig-Tansig

ฟังก์ชันถ่ายโอนในแต่ละชั้นซ่อน		ค่า p-value
ชั้นที่ 1	ชั้นที่ 2	
Logsig	Logsig	0.00
Logsig	Tansig	0.02
Tansig	Logsig	0.00

ผลลัพธ์จากตารางที่ 5-14 พบว่าค่า p-value น้อยกว่าระดับนัยสำคัญทางสถิติ  $\alpha = 0.05$  ทุกกรณี นำมาสู่การปฏิเสธ  $H_0$  แสดงว่า “กลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลองที่ใช้ชุดฟังก์ชัน Tansig-Tansig แต่ใช้จำนวนประสาทเทียมในชั้นซ่อนแต่ละชั้นเท่ากันจะมากกว่ากลุ่มค่าเฉลี่ยจากแบบจำลอง ANN 2 ชั้นซ่อนเมื่อใช้ชุดฟังก์ชันอื่น ๆ” จึงได้ข้อสรุปว่าแบบจำลองที่ใช้ชุดฟังก์ชัน Tansig-Tansig จะมีความแม่นยำในการทำนายน้อยกว่าแบบจำลองที่ใช้ชุดฟังก์ชันอื่น ๆ ในขั้นตอนถัดไปผู้วิจัยจึงไม่นำแบบจำลองที่ใช้ชุดฟังก์ชัน Tansig-Tansig มาพิจารณาต่อไป

ในส่วนของปัจจัยด้านจำนวนประสาทเทียมที่ใช้ในชั้นซ่อนที่ 1 และชั้นซ่อนที่ 2 ผู้วิจัยจะนำกลุ่มของแบบจำลอง ANN ที่ใช้ฟังก์ชันถ่ายโอนเดียวกัน และมีจำนวนประสาทเทียมในชั้นใดชั้นหนึ่งเท่ากัน มาทำการหาค่าเฉลี่ยของค่าเฉลี่ย RMSE แล้วแสดงในรูปของกราฟเส้นเพื่อพิจารณาแนวโน้มต่าง ๆ ที่อาจเกิดขึ้น




- จำนวนประสาทเทียมในชั้นซ่อนที่ 1

การพิจารณาผลของจำนวนประสาทเทียมที่ใช้ในชั้นซ่อนที่ 1 ที่มีต่อกลุ่มค่าเฉลี่ย RMSE จากแบบจำลองจะกระทำโดยการหาค่าเฉลี่ยของกลุ่ม RMSE เมื่อใช้จำนวนประสาทเทียมในชั้นซ่อนที่ 1 ตั้งแต่ 1 – 10 ตัว ได้ผลลัพธ์ดังตารางที่ 5-15 ซึ่งสามารถสร้างกราฟเส้นได้ดังรูปที่ 5-13

ตารางที่ 5-15 ค่าเฉลี่ยของ RMSE จากแบบจำลองเมื่อใช้จำนวนประสาทเทียมในชั้นซ่อนที่ 1 แตกต่างกัน

ฟังก์ชันถ่ายโอนในชั้นซ่อน		จำนวนประสาทเทียมในชั้นซ่อนที่ 1									
ชั้นที่ 1	ชั้นที่ 2	1	2	3	4	5	6	7	8	9	10
Logsig	Logsig	4.07	3.78	3.90	3.85	3.80	3.88	3.82	3.89	3.85	3.90
Logsig	Tansig	4.03	3.83	3.84	3.86	3.83	4.02	3.88	3.96	3.91	3.81
Tansig	Logsig	4.10	3.87	3.92	3.84	3.83	3.91	3.77	3.87	3.87	3.76



รูปที่ 5-13 ค่าเฉลี่ยของ RMSE จากแบบจำลองเมื่อใช้จำนวนประสาทเทียมในชั้นซ่อนที่ 1 แตกต่าง  
กัน

ผลลัพธ์จากรูปที่ 5-13 พบความเป็นไปได้ที่แบบจำลองที่ใช้ประสาทเทียมในชั้นซ่อนที่ 1 จำนวน 1 ตัวจะให้ค่าเฉลี่ยของ RMSE แตกต่างจากแบบจำลองที่ใช้จำนวนประสาทเทียม 2 – 10 ตัว จากแบบจำลองที่ใช้ชุดฟังก์ชันถ่ายโอนทั้ง 3 รูปแบบ นอกจากนี้ ยังมีความเป็นไปได้ที่แบบจำลองที่ใช้ชุดฟังก์ชัน Logsig-Tansig จะมีค่าเฉลี่ยของ RMSE จากแบบจำลองที่ใช้จำนวนประสาทเทียม 6 ตัว แตกต่างจากแบบจำลองอื่น ๆ ด้วย ผู้วิจัยจึงตั้งสมมติฐานเพื่อทดสอบความเป็นไปได้ทั้งหมด ดังนี้

$H_0$ : กลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลองที่ใช้จำนวนประสาทเทียมในชั้นซ่อนที่ 1 แตกต่างกันจะไม่แตกต่างกัน

$H_1$ : มีกลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลองที่ใช้จำนวนประสาทเทียมในชั้นซ่อนที่ 1 แตกต่างกันอย่างน้อย 1 คู่ที่แตกต่างกัน

การทดสอบสมมติฐานจะกระทำโดยการทดสอบ ANOVA ที่ระดับนัยสำคัญทางสถิติ  $\alpha = 0.05$  ในแบบจำลองที่มีชุดฟังก์ชันถ่ายโอนเดียวกัน โดยมีผลลัพธ์แสดงดังตารางที่ 5-16


**ตารางที่ 5-16** ค่า p-value ที่ได้จากการทดสอบ ANOVA ระหว่างกลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลองที่ใช้จำนวนประสาทเทียมในชั้นซ่อนที่ 1 แตกต่างกัน

ฟังก์ชันถ่ายโอนในแต่ละชั้นซ่อน		ค่า p-value
ชั้นที่ 1	ชั้นที่ 2	
Logsig	Logsig	0.00
Logsig	Tansig	0.00
Tansig	Logsig	0.00









รูปที่ 5-16 ความแตกต่างของ RMSE ของแบบจำลองที่มีฟังก์ชันถ่ายโอน Tansig-Logsig เมื่อใช้จำนวนประสาทเทียมในชั้นซ่อนที่ 1 แตกต่างกัน


ผลลัพธ์จากรูปที่ 5-14 5-15 5-16 และตารางที่ 5-17 5-18 และ 5-19 แสดงให้เห็นว่าการใช้จำนวนประสาทเทียม 1 ตัวในชั้นซ่อนที่ 1 ของแบบจำลองมักจะทำให้ค่าเฉลี่ยของ RMSE มากกว่าค่าเฉลี่ยของ RMSE จากแบบจำลองที่มีจำนวนประสาทเทียมในชั้นซ่อนที่ 1 ตั้งแต่ 2 – 10 ตัวขึ้นไปอย่างมีนัยสำคัญทางสถิติ ในขณะที่แบบจำลองที่ใช้จำนวนประสาทเทียมตั้งแต่ 2 – 10 ตัว จะให้ค่าเฉลี่ยของ RMSE ใกล้เคียงกัน บ่งบอกได้ว่าการใช้จำนวนประสาทเทียมเพียง 1 ตัวชั้นซ่อนที่ 1 ทำให้แบบจำลองสร้างหน่วยประมวลผลที่น้อยจนทำให้ทำนายความสัมพันธ์ระหว่างข้อมูลที่ซับซ้อนเกินไปได้ไม่ถูกต้องเท่าที่ควร

- จำนวนประสาทเทียมในชั้นซ่อนที่ 2

การพิจารณาผลของจำนวนประสาทเทียมที่ใช้ในชั้นซ่อนที่ 2 ที่มีต่อกลุ่มค่าเฉลี่ย RMSE จากแบบจำลองจะกระทำโดยการหาค่าเฉลี่ยของกลุ่ม RMSE เมื่อใช้จำนวนประสาทเทียมในชั้นซ่อนที่ 2 ตั้งแต่ 1 – 10 ตัว ได้ผลลัพธ์ดังตารางที่ 5-20 ซึ่งสามารถสร้างกราฟเส้นได้ดังรูปที่ 5-17

ตารางที่ 5-20 ค่าเฉลี่ยของ RMSE จากแบบจำลองเมื่อใช้จำนวนประสาทเทียมในชั้นซ่อนที่ 2 แตกต่างกัน

ฟังก์ชันถ่ายโอนในชั้นซ่อน		จำนวนประสาทเทียมในชั้นซ่อนที่ 2									
ชั้นที่ 1	ชั้นที่ 2	1	2	3	4	5	6	7	8	9	10
Logsig	Logsig	3.94	3.91	3.80	3.80	3.89	3.89	3.91	3.87	3.85	3.87
Logsig	Tansig	4.01	3.92	3.87	3.88	3.85	3.87	3.89	3.92	3.86	3.91
Tansig	Logsig	4.00	3.88	3.86	3.82	3.90	3.86	3.90	3.86	3.81	3.87



รูปที่ 5-17 ค่าเฉลี่ยของ RMSE จากแบบจำลอง เมื่อใช้จำนวนประสาทเทียมในชั้นซ่อนที่ 2 แตกต่างกัน

ผลลัพธ์จากรูปที่ 5-17 ไม่พบว่าการใช้จำนวนประสาทเทียมในชั้นซ่อนที่ 2 แตกต่างกันในแบบจำลองจะทำให้ค่าเฉลี่ยของ RMSE แตกต่างกันอย่างใด ในแบบจำลองที่ใช้ชุดฟังก์ชันถ่ายโอนทั้ง 3 รูปแบบ อย่างไรก็ตาม เพื่อยืนยันแนวคิดดังกล่าว ผู้วิจัยจึงตั้งสมมติฐานเพื่อทดสอบดังนี้

$H_0$ : กลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลองที่ใช้จำนวนประสาทเทียมในชั้นซ่อนที่ 2 แตกต่างกันจะไม่แตกต่างกัน

$H_1$ : มีกลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลองที่ใช้จำนวนประสาทเทียมในชั้นซ่อนที่ 2 แตกต่างกันอย่างน้อย 1 คู่ที่แตกต่างกัน

การทดสอบสมมติฐานจะกระทำโดยการทดสอบ ANOVA ที่ระดับนัยสำคัญทางสถิติ  $\alpha = 0.05$  ในแบบจำลองที่มีชุดฟังก์ชันถ่ายโอนเดียวกัน โดยมีผลลัพธ์แสดงดังตารางที่ 5-21

ตารางที่ 5-21 ค่า p-value ที่ได้จากการทดสอบ ANOVA ระหว่างกลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลองที่ใช้จำนวนประสาทเทียมในชั้นซ่อนที่ 2 แตกต่างกัน

คู่ฟังก์ชันถ่ายโอน	p-value
Logsig-Logsig	0.33
Logsig-Tansig	0.50
Tansig-Logsig	0.34

ผลลัพธ์จากตารางที่ 5-21 ระบุว่า p-value ที่ได้จากแบบจำลองที่ใช้ชุดฟังก์ชันถ่ายโอนใด ๆ ก็ตามมีค่าไม่น้อยกว่าค่าระดับนัยสำคัญทางสถิติที่  $\alpha = 0.05$  จึงไม่ปฏิเสธ  $H_0$  หรือแปลว่า “กลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลองที่ใช้จำนวนประสาทเทียมในชั้นซ่อนที่ 2 แตกต่างกันจะไม่แตกต่างกัน” ทุกแบบจำลอง อาจเป็นเพราะข้อมูลที่ได้จากประสาทเทียมในชั้นซ่อนที่ 1 ได้รับการปรับปรุงมาแล้วในระดับหนึ่ง จึงทำให้ชั้นซ่อนที่ 2 ปรับปรุงข้อมูลได้โดยไม่ขึ้นกับจำนวนประสาทเทียมในชั้นซ่อนที่ 2 จึงสามารถสรุปได้ว่าจำนวนประสาทเทียมที่เหมาะสมสำหรับชั้นซ่อนที่ 2 ของแบบจำลองโครงข่ายประสาทเทียม 2 ชั้นซ่อน คือ 1 – 10 ตัว



จากผลลัพธ์ทั้งหมดในการพัฒนาแบบจำลอง ANN ได้ข้อสรุปดังนี้

- สำหรับแบบจำลอง ANN 1 ชั้นซ่อน แบบจำลองที่มีประสิทธิภาพในการทำนาย ได้แก่ แบบจำลองที่ใช้ฟังก์ชันถ่ายโอน Logsig และ Tansig โดยจำนวนประสาทเทียมในชั้นซ่อนไม่มีผลต่อการทำนายแต่อย่างใด
- สำหรับแบบจำลอง ANN 2 ชั้นซ่อน แบบจำลองที่มีประสิทธิภาพในการทำนาย ได้แก่ แบบจำลองที่ใช้ชุดฟังก์ชันถ่ายโอน “Logsig-Logsig” “Logsig-Tansig” และ “Tansig-Logsig” โดยจำนวนประสาทเทียมในชั้นซ่อนที่ 1 ที่เหมาะสมคือ 2 – 10 ตัว ในขณะที่จำนวนประสาทเทียมในชั้นซ่อนที่ 2 ที่เหมาะสมคือ 1 – 10 ตัว

### 5.3 แบบจำลอง SVR

แบบจำลอง SVR ที่สร้างขึ้นโดยใช้ข้อมูลนำเข้าและข้อมูลนำออกชุดเดียวกับข้อมูลที่ใช้พัฒนาแบบจำลอง ANN โดยปัจจัยที่เกี่ยวข้องในแบบจำลองจะมีเพียงปัจจัยเดียว คือ Kernel Function ที่ใช้ในแบบจำลอง โดยมีทั้งหมด 3 ชนิด คือ Linear, Gaussian และ Polynomial เนื่องจากแบบจำลอง SVR มีวิธีการคำนวณที่ตายตัว จึงทำให้แบบจำลองมีการทำนายผลลัพธ์ได้ค่าเดียวและทำให้การทดสอบความถูกต้องของแบบจำลองจะได้ค่า RMSE จากแบบจำลองเพียงค่าเดียว โดยค่า RMSE จากแบบจำลองทั้ง 3 ประเภทจะแสดงดังตารางที่ 5-22

ตารางที่ 5-22 ค่า RMSE จากแบบจำลอง SVR

Kernel Function	Linear	Gaussian	Polynomial
RMSE	3.34	3.12	0.75

### 5.4 การเปรียบเทียบแบบจำลอง

จากการพัฒนาแบบจำลองในขั้นตอนที่ผ่านมา จะพบว่าแบบจำลองที่ได้ทั้ง 3 กลุ่ม คือ แบบจำลอง ANN 1 ชั้นซ่อน แบบจำลอง ANN 2 ชั้นซ่อน และแบบจำลอง SVR จะมีช่วงของค่า RMSE ซึ่งแสดงได้ดังตารางที่ 5-23

ตารางที่ 5-23 ช่วงของค่า RMSE จากแบบจำลองที่พัฒนาได้ทั้ง 3 ประเภท

ประเภทแบบจำลอง	ANN		SVR
	ชั้นซ่อน 1 ชั้น	ชั้นซ่อน 2 ชั้น	
ค่า RMSE	3.89 – 4.61	3.50 – 4.60	0.75 – 3.34

ผลลัพธ์จากตารางที่ 5-23 บ่งบอกถึงแนวโน้มต่าง ๆ ของค่า RMSE ที่เกี่ยวข้องกับประเภทของแบบจำลอง โดยพบว่าแบบจำลอง ANN 1 ชั้นซ่อน จะมีช่วงของค่า RMSE สูงกว่าแบบจำลอง ANN 2 ชั้นซ่อน ในขณะที่แบบจำลอง ANN 2 ชั้นซ่อนก็มีช่วงของค่า RMSE สูงกว่าแบบจำลอง SVR ดังนั้น จึงมีการคำนวณทางสถิติเพื่อทำการทดสอบแนวโน้มต่าง ๆ ที่เกิดขึ้น

#### 5.4.1 การเปรียบเทียบแบบจำลอง ANN 1 ชั้นซ่อน และแบบจำลอง ANN 2 ชั้นซ่อน

จากการพบแนวโน้มที่แบบจำลอง ANN 2 ชั้นซ่อนให้ค่าเฉลี่ยของ RMSE ต่ำกว่าแบบจำลอง ANN 1 ชั้นซ่อน ผู้วิจัยจึงตั้งสมมติฐานเพื่อทำการทดสอบแนวโน้มที่สังเกตได้ดังนี้

$H_0$ : กลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลอง ANN 2 ชั้นซ่อนไม่แตกต่างจากกลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลอง ANN 1 ชั้นซ่อน

$H_1$ : กลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลอง ANN 2 ชั้นซ่อนแตกต่างจากกลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลอง ANN 1 ชั้นซ่อน

การทดสอบสมมติฐานกระทำโดยการทดสอบ Two-tailed T-test ที่ระดับนัยสำคัญทางสถิติ  $\alpha = 0.05$  โดยจะทำการเปรียบเทียบแบบจำลอง ANN ทั้ง 2 ประเภทในทุกฟังก์ชันถ่ายโอนที่เกิดขึ้น โดย p-value ที่ได้จากการทดสอบจะแสดงดังตารางที่ 5-24

ตารางที่ 5-24 ค่า p-value จากการทดสอบ Two-tailed T-test ระหว่างค่าเฉลี่ยของ RMSE จากแบบจำลอง ANN 2 ชั้นซ่อน และแบบจำลอง ANN 1 ชั้นซ่อน

แบบจำลอง ANN 2 ชั้นซ่อน		แบบจำลอง ANN 1 ชั้นซ่อน	
ฟังก์ชันถ่ายโอนในแต่ละชั้นซ่อน		ฟังก์ชันถ่ายโอน	
ชั้นที่ 1	ชั้นที่ 2	Logsig	Tansig
Logsig	Logsig	0.00	0.00
	Tansig	0.00	0.00
Tansig	Logsig	0.00	0.00
	Tansig	0.00	0.00

ผลลัพธ์ในตารางที่ 5-24 แสดงให้เห็นว่า p-value ที่ได้จากการวิเคราะห์ทุกกรณีมีค่าน้อยกว่าค่าระดับนัยสำคัญทางสถิติที่  $\alpha = 0.05$  ทุกกรณี ซึ่งบ่งบอกการปฏิเสธ  $H_0$  แสดงว่า “กลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลอง ANN 2 ชั้นซ่อนแตกต่างจากกลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลอง ANN 1 ชั้นซ่อน” ทุกกรณีของฟังก์ชันถ่ายโอนที่เกิดขึ้น ขั้นตอนถัดไปจึงเป็นการหาว่าแบบจำลองประเภทใดที่มีกลุ่มค่าเฉลี่ยของ RMSE น้อยกว่า ซึ่งบ่งบอกถึงความสามารถในการทำนายที่มีความแม่นยำกว่า โดยมีการตั้งสมมติฐานเพื่อการทดสอบดังนี้

$H_0$ : กลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลอง ANN 2 ชั้นซ่อนมีค่าไม่น้อยกว่ากลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลอง ANN 1 ชั้นซ่อน

$H_1$ : กลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลอง ANN 2 ชั้นซ่อนมีค่าน้อยกว่ากลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลอง ANN 1 ชั้นซ่อน

การวิเคราะห์สมมติฐานกระทำโดยการทดสอบ Lower-tailed T-test ที่ระดับนัยสำคัญทางสถิติ  $\alpha = 0.05$  โดยจะทำการเปรียบเทียบแบบจำลองทั้ง 2 ประเภทในทุกฟังก์ชันถ่ายโอนที่เกิดขึ้น โดย p-value ที่ได้จากการทดสอบจะแสดงดังตารางที่ 5-25


ตารางที่ 5-25 ค่า p-value จากการทดสอบ Lower-tailed T-test ระหว่างค่าเฉลี่ยของ RMSE จากแบบจำลอง ANN 2 ชั้นซ่อน และแบบจำลอง ANN 1 ชั้นซ่อน

แบบจำลอง ANN 2 ชั้นซ่อน		แบบจำลอง ANN 1 ชั้นซ่อน	
ฟังก์ชันถ่ายโอนในแต่ละชั้นซ่อน		ฟังก์ชันถ่ายโอน	
ชั้นที่ 1	ชั้นที่ 2	Logsig	Tansig
Logsig	Logsig	0.00	0.00
	Tansig	0.00	0.00
Tansig	Logsig	0.00	0.00
	Tansig	0.00	0.00

ผลลัพธ์ในตารางที่ 5-25 แสดงให้เห็นว่า p-value ที่ได้จากการวิเคราะห์ทุกกรณีมีค่าน้อยกว่าค่าระดับนัยสำคัญทางสถิติที่  $\alpha = 0.05$  ทุกกรณี บ่งบอกการปฏิเสธ  $H_0$  แสดงว่า “กลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลอง ANN 2 ชั้นซ่อนน้อยกว่ากลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลอง ANN 1 ชั้นซ่อน” ทุกกรณีของฟังก์ชันถ่ายโอนที่เกิดขึ้น ผลลัพธ์ที่ได้ทำให้เห็นว่าการเพิ่มชั้นซ่อนช่วยเพิ่มประสิทธิภาพในการทำนายค่าของแบบจำลอง ANN ทำให้แบบจำลอง ANN 2 ชั้นซ่อน มีประสิทธิภาพในการทำนายมากกว่าแบบจำลอง ANN 1 ชั้นซ่อน โดยไม่ขึ้นกับประเภทของฟังก์ชันถ่ายโอนที่ใช้ ดังนั้นผู้วิจัยจึงไม่นำแบบจำลอง ANN 1 ชั้นซ่อนมาร่วมพิจารณาในขั้นตอนการทดสอบแบบจำลองต่อไป

#### 5.4.2 การเปรียบเทียบแบบจำลอง ANN 2 ชั้นซ่อน และแบบจำลอง SVR

เมื่อนำผลลัพธ์จากตารางที่ 5-25 มาเปรียบเทียบค่า RMSE จากแบบจำลอง ANN 2 ชั้นซ่อน และแบบจำลอง SVR จะได้ผลลัพธ์ดังรูปที่ 5-18



รูปที่ 5-18 ช่วงของค่า RMSE จากแบบจำลอง ANN 2 ชั้นซ่อน และแบบจำลอง SVR

จากรูปที่ 5-18 แสดงให้เห็นถึงแนวโน้มที่ค่า RMSE ที่ได้จากแบบจำลอง SVR จะมีค่าน้อยกว่า RMSE ที่ได้จากแบบจำลอง ANN ผู้วิจัยจึงตั้งสมมติฐานเพื่อทดสอบแนวโน้มดังนี้

$H_0$ : กลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลอง ANN ไม่แตกต่างจาก RMSE จากแบบจำลอง SVR

$H_1$ : กลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลอง ANN แตกต่างจาก RMSE จากแบบจำลองสมการ SVR

การทดสอบสมมติฐานจะกระทำโดยการทดสอบ Two-tailed T-test ที่ระดับนัยสำคัญทางสถิติ  $\alpha = 0.05$  โดยจะทำการเปรียบเทียบแบบจำลองทั้ง 2 ประเภทในทุกฟังก์ชันที่เกิดขึ้น โดยมีค่า p-value แสดงดังตารางที่ 5-26

ตารางที่ 5-26 ค่า p-value จากการทดสอบ Two-tailed T-test ระหว่างค่า RMSE จากแบบจำลอง ANN 2 ชั้นซ่อน และแบบจำลอง SVR

แบบจำลอง ANN (ฟังก์ชันถ่ายโอนที่ใช้)	แบบจำลอง SVR (Kernel Function ที่ใช้)		
	Linear	Gaussian	Polynomial
Logsig-Logsig	0.00	0.00	0.00
Logsig-Tansig	0.00	0.00	0.00
Tansig-Logsig	0.00	0.00	0.00

ผลลัพธ์จากตารางที่ 5-26 พบว่าค่า p-value จากการเปรียบเทียบทุกกรณีมีค่าน้อยกว่าระดับนัยสำคัญทางสถิติที่  $\alpha = 0.05$  จึงเกิดการปฏิเสธ  $H_0$  นั่นคือ “กลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลอง ANN แตกต่างจาก RMSE จากแบบจำลอง SVR” ในทุกกรณีของแบบจำลองทั้ง 2 ประเภท ขั้นตอนถัดไปจึงเป็นการหาว่าแบบจำลองประเภทใดที่มีกลุ่มค่าเฉลี่ยของ RMSE น้อยกว่า ซึ่งบ่งบอกถึงความสามารถในการทำนายที่มีความแม่นยำกว่า โดยมีการตั้งสมมติฐานเพื่อการทดสอบดังนี้

$H_0$ : กลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลอง ANN ไม่มากกว่า RMSE จากแบบจำลอง SVR

$H_1$ : กลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลอง ANN มากกว่า RMSE จากแบบจำลอง SVR

การทดสอบ One-tailed T-test จะถูกใช้ในการทดสอบสมมติฐานที่ระดับนัยสำคัญทางสถิติ  $\alpha = 0.05$  โดยจะทำการเปรียบเทียบแบบจำลองทั้ง 2 ประเภทในทุกฟังก์ชันที่เกิดขึ้น โดยมีค่า p-value แสดงดังตารางที่ 5-27

ตารางที่ 5-27 ค่า p-value จากการทดสอบ One-tailed T-test ระหว่างค่า RMSE จากแบบจำลอง ANN 2 ชั้นซ่อน และแบบจำลอง SVR

แบบจำลอง ANN (ฟังก์ชันถ่ายโอนที่ใช้)	แบบจำลอง SVR (Kernel Function ที่ใช้)		
	Linear	Gaussian	Polynomial
Logsig-Logsig	0.00	0.00	0.00
Logsig-Tansig	0.00	0.00	0.00
Tansig-Logsig	0.00	0.00	0.00


ผลลัพธ์จากตารางที่ 5-27 พบว่าค่า p-value จากการเปรียบเทียบทุกกรณีมีค่าน้อยกว่าระดับนัยสำคัญทางสถิติ  $\alpha = 0.05$  จึงเกิดการปฏิเสธ  $H_0$  แสดงให้เห็นว่า “กลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลอง ANN มากกว่า RMSE จากแบบจำลอง SVR” ทุกกรณีที่เปรียบเทียบ แสดงให้เห็นว่าแบบจำลอง SVR สามารถใช้ในการทำนายได้ดีกว่าแบบจำลอง ANN

จากการพัฒนาแบบจำลองในบทนี้ พบว่าแบบจำลอง ANN จะมีความสามารถในการทำนายเพิ่มขึ้นหากมีการเพิ่มจำนวนชั้นซ่อน ในขณะที่ฟังก์ชันถ่ายโอนที่เหมาะสมต่อข้อมูลที่มีความสัมพันธ์ที่ซับซ้อน คือฟังก์ชัน Logsig และ Tansig ในส่วนของจำนวนของประสาทเทียม พบว่าชั้นซ่อนที่ 1 ควรจะมีจำนวนประสาทเทียมตั้งแต่ 2 ตัวขึ้นไปเพื่อสร้างแบบจำลองที่มีความซับซ้อนได้ ขณะที่ชั้นซ่อนที่ 2 ยังไม่ส่งผลต่อการทำนายเท่าที่ควร ขณะเดียวกัน แบบจำลอง SVR จะมีประสิทธิภาพในการทำนายที่เหนือกว่าแบบจำลอง ANN อย่างไรก็ตาม จะมีการนำแบบจำลองที่ได้จากการพัฒนาแบบจำลองไปทำการทดสอบกับข้อมูลอีกชุดหนึ่งเพื่อพิจารณาว่าจะมีแนวโน้มของการทำนายเปลี่ยนแปลงหรือไม่ในบทถัดไป

## บทที่ 6

### การทดสอบแบบจำลอง

หลังจากการพัฒนาและวิเคราะห์แบบจำลองเสร็จสิ้นแล้ว ผู้วิจัยนำแบบจำลองทั้งสองประเภทที่มีความสามารถในการทำนายได้ดีไปทดสอบกับชุดข้อมูลที่ใช้ทดสอบความถูกต้องเพื่อหาความสามารถในการทำนายของแบบจำลองในชุดข้อมูลใหม่ โดยมีแผนผังขั้นตอนการทดสอบและวิเคราะห์แบบจำลองดังรูปที่ 6-1



รูปที่ 6-1 แผนผังการทดสอบและวิเคราะห์แบบจำลอง



## 6.1 แบบจำลอง ANN

การทดสอบความถูกต้องในการทำนายของแบบจำลอง ANN ที่ได้จากบทที่ 5 จะกระทำโดยการใช้ชุดข้อมูลทดสอบที่มีข้อมูล 9 ชุด ให้แบบจำลอง ANN แต่ละแบบเรียนรู้และทำนายค่า RMSE จำนวน 100 ครั้ง แล้วจึงหาค่าเฉลี่ยของ RMSE ของแบบจำลอง ANN แต่ละแบบ ผลลัพธ์ที่ได้จะแสดงดังตารางที่ 6-1

ตารางที่ 6-1 ค่าสถิติของ RMSE ในแบบจำลอง ANN 2 ชั้นซ่อน


ฟังก์ชันถ่ายโอน		ช่วงระยะ	เปอร์เซ็นต์ที่ 10	มัธยฐาน	เปอร์เซ็นต์ที่ 90
ชั้นซ่อนที่ 1	ชั้นซ่อนที่ 2				
Logsig	Logsig	3.66 – 5.33	3.79	4.04	4.36
Logsig	Tansig	3.70 – 5.30	3.90	4.17	4.66
Tansig	Logsig	3.72 – 5.01	3.82	4.02	4.38
Tansig	Tansig	3.70 – 5.66	3.95	4.20	4.57

### 6.1.1 ฟังก์ชันถ่ายโอนที่ใช้


การเปรียบเทียบความแตกต่างของค่าเฉลี่ยของ RMSE ของแบบจำลองที่ใช้ฟังก์ชันถ่ายโอนแตกต่างกัน จะกระทำโดยการนับช่วงความถี่ของค่าเฉลี่ยของ RMSE จากแบบจำลองที่ใช้ฟังก์ชันถ่ายโอนแตกต่างกัน มาแสดงดังตารางที่ 6-2 และนำไปทำกราฟฮิสโตแกรม ได้ดังรูปที่ 6-2 6-3 6-4 และ 6-5

ตารางที่ 6-2 ช่วงความถี่ของค่าเฉลี่ยของ RMSE เมื่อใช้ชุดฟังก์ชันถ่ายโอนต่าง ๆ


ช่วงระยะ	ความถี่ของค่าเฉลี่ยของ RMSE			
	Logsig-Logsig	Logsig-Tansig	Tansig-Logsig	Tansig-Tansig
3.60 – 3.69	2	1	0	0
3.70 – 3.79	9	3	6	1
3.80 – 3.89	12	6	16	3
3.90 – 3.99	19	16	24	14
4.00 – 4.09	19	15	17	21
4.10 – 4.19	13	14	16	11
4.20 – 4.29	14	11	8	14
4.30 – 4.39	6	12	4	11
4.40 – 4.49	0	6	5	14
4.50 – 4.59	1	4	0	2
4.60 – 4.69	1	6	0	2
4.70 – 4.79	1	0	1	1
4.80 – 4.89	0	1	2	3
4.90 – 4.99	1	0	0	0
5.0 ขึ้นไป	2	5	1	3




รูปที่ 6-2 การกระจายของค่าเฉลี่ยของ RMSE ของแบบจำลอง ANN 2 ชั้นซ่อนที่ใช้ฟังก์ชัน Logsig-  
Logsig



รูปที่ 6-3 การกระจายของค่าเฉลี่ยของ RMSE ของแบบจำลอง ANN 2 ชั้นซ่อนที่ใช้ฟังก์ชัน Logsig-  
Tansig



รูปที่ 6-4 การกระจายของค่าเฉลี่ยของ RMSE ของแบบจำลอง ANN 2 ชั้นซ่อนที่ใช้ฟังก์ชัน Tansig-Logsig



รูปที่ 6-5 การกระจายของค่าเฉลี่ยของ RMSE ของแบบจำลอง ANN 2 ชั้นซ่อนที่ใช้ฟังก์ชัน Tansig-Tansig

ผลลัพธ์จากกราฟฮิสโตแกรม พบแนวโน้มที่การใช้ชุดฟังก์ชันถ่ายโอนแตกต่างกันส่งผลให้ได้กลุ่มค่าเฉลี่ยของ RMSE แตกต่างกัน โดยแบบจำลองที่ใช้ชุดฟังก์ชัน Logsig-Logsig และ Tansig-Logsig น่าจะมีช่วงค่าเฉลี่ยของ RMSE ที่น้อยกว่าแบบจำลองที่ใช้ชุดฟังก์ชันถ่ายโอน Logsig-Tansig และ Tansig-Tansig เมื่อเปรียบเทียบจากแบบจำลองที่มีจำนวนประสาทเทียมในชั้นซ่อนแต่ละชั้นเท่ากัน ผู้วิจัยจึงตั้งสมมติฐานในการทดสอบดังนี้

$H_0$ : กลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลอง ANN 2 ชั้นซ่อนเมื่อใช้ชุดฟังก์ชันถ่ายโอนแตกต่างกันแต่ใช้จำนวนประสาทเทียมในชั้นซ่อนแต่ละชั้นเท่ากันจะแตกต่างกัน

$H_1$ : กลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลอง ANN 2 ชั้นซ่อนเมื่อใช้ชุดฟังก์ชันแตกต่างกันแต่ใช้จำนวนประสาทเทียมในชั้นซ่อนแต่ละชั้นเท่ากันจะแตกต่างกัน

การทดสอบสมมติฐานโดยการทดสอบ Two-tailed Paired T-test ที่ระดับนัยสำคัญทางสถิติ  $\alpha = 0.05$  ระหว่างแบบจำลองที่ใช้ชุดฟังก์ชันถ่ายโอนแตกต่างกัน โดยมีผลลัพธ์ดังตารางที่ 6-3

ตารางที่ 6-3 ค่า p-value ที่ได้จากการทดสอบ Two-tailed Paired T-test ระหว่างแบบจำลอง ANN 2 ชั้นซ่อนที่ใช้ชุดฟังก์ชันถ่ายโอนแตกต่างกัน

ชุดฟังก์ชันถ่ายโอน (ชั้นซ่อนที่ 1 - ชั้นซ่อนที่ 2)		ค่า p-value
แบบจำลองที่ 1	แบบจำลองที่ 2	
Logsig-Logsig	Logsig-Tansig	0.00
Logsig-Logsig	Tansig-Logsig	0.35
Logsig-Logsig	Tansig-Tansig	0.00
Logsig-Tansig	Tansig-Logsig	0.00
Logsig-Tansig	Tansig-Tansig	0.29
Tansig-Logsig	Tansig-Tansig	0.00

ผลลัพธ์จากตารางที่ 6-3 มีด้วยกัน 2 ลักษณะ ดังนี้

- ค่า p-value ที่ได้จากการเปรียบเทียบระหว่างแบบจำลอง “Logsig-Logsig” กับแบบจำลอง “Tansig-Logsig” และ ระหว่างแบบจำลอง “Logsig-Tansig” กับแบบจำลอง “Tansig-Tansig” มีค่าไม่น้อยกว่าระดับนัยสำคัญทางสถิติ  $\alpha = 0.05$  นำไปสู่การไม่ปฏิเสธ  $H_0$  ได้ แสดงว่าไม่พบความแตกต่างของค่าเฉลี่ยของ RMSE ระหว่างแบบจำลองคู่ดังที่กล่าวมาข้างต้น
- ค่า p-value ที่ได้จากการเปรียบเทียบระหว่างแบบจำลองคู่ นอกเหนือจากลักษณะแรกนั้น มีค่าน้อยกว่าระดับนัยสำคัญทางสถิติ  $\alpha = 0.05$  นำไปสู่การปฏิเสธ  $H_0$  แสดงว่ามีความแตกต่างระหว่างค่าเฉลี่ยของ RMSE ระหว่างกลุ่มแบบจำลอง “Logsig-Logsig” “Tansig-Logsig” กับกลุ่มแบบจำลอง “Logsig-Tansig” “Tansig-Tansig”

จากผลลัพธ์ข้างต้น ผู้วิจัยต้องการศึกษาต่อว่าแบบจำลองกลุ่มที่จำแนกได้นั้นให้ค่าเฉลี่ยของ RMSE แตกต่างกันอย่างใด โดยจากการสังเกตรูปที่ 6-2 6-3 6-4 และ 6-5 พบว่ากลุ่มแบบจำลอง “Logsig-Logsig” “Tansig-Logsig” มีแนวโน้มที่จะให้ค่าเฉลี่ยของ RMSE ต่ำกว่ากลุ่มแบบจำลอง “Logsig-Tansig” “Tansig-Tansig” เมื่อเปรียบเทียบจากแบบจำลองที่มีจำนวนประสาทเทียมในชั้นซ่อนแต่ละชั้นเท่ากัน จึงตั้งสมมติฐานเพื่อการทดสอบ ดังนี้

$H_0$ : กลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลองที่ใช้ชุดฟังก์ชันถ่ายโอน Logsig-Logsig หรือ Tansig-Logsig จะมีค่าน้อยกว่ากลุ่มค่าเฉลี่ยจากแบบจำลองที่ใช้ชุดฟังก์ชันถ่ายโอน Logsig-Tansig หรือ Tansig-Tansig

$H_1$ : กลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลองที่ใช้ชุดฟังก์ชันถ่ายโอน Logsig – Logsig หรือ Tansig-Logsig จะมีค่าน้อยกว่ากลุ่มค่าเฉลี่ยจากแบบจำลองที่ใช้ชุดฟังก์ชันถ่ายโอน Logsig-Tansig หรือ Tansig-Tansig

การทดสอบสมมติฐานจะกระทำโดยวิธี One-tailed Paired T-test ที่ระดับนัยสำคัญทางสถิติ  $\alpha = 0.05$  โดยมีผลลัพธ์ดังตารางที่ 6-4

ตารางที่ 6-4 ค่า p-value ที่ได้จากการทดสอบ One-tailed Paired T-test ระหว่างกลุ่มแบบจำลอง ANN 2 ชั้นซ้อน

แบบจำลองที่ 1	แบบจำลองที่ 2	ค่า p-value
Logsig-Logsig	Logsig-Tansig	0.00
	Tansig-Tansig	0.00
Tansig-Logsig	Logsig-Tansig	0.00
	Tansig-Tansig	0.00


ผลลัพธ์จากตารางที่ 6-4 แสดงให้เห็นว่าการเปรียบเทียบทุกกรณีให้ค่า p-value น้อยกว่าระดับนัยสำคัญทางสถิติ  $\alpha = 0.05$  เป็นการยืนยันการปฏิเสธ  $H_0$  แปลว่า “กลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลองที่ใช้ชุดฟังก์ชันถ่ายโอน Logsig-Logsig หรือ Tansig-Logsig จะมีค่าน้อยกว่ากลุ่มค่าเฉลี่ยจากแบบจำลองที่ใช้ชุดฟังก์ชันถ่ายโอน Logsig-Tansig หรือ Tansig-Tansig” โดยเฉพาะแบบจำลองที่ใช้ชุดฟังก์ชัน Tansig-Tansig ที่มีความแตกต่างออกไปอย่างชัดเจนซึ่งเป็นแนวโน้มเดียวกับสิ่งที่เกิดขึ้นในขั้นตอนการพัฒนาแบบจำลอง จากผลลัพธ์ดังกล่าว ผู้วิจัยจึงพิจารณาเลือกแบบจำลอง ANN ที่ใช้ชุดฟังก์ชันถ่ายโอน Logsig-Logsig กับ Tansig-Logsig มาพิจารณาปัจจัยอื่น ๆ ในขั้นตอนถัดไป

### 6.1.2 จำนวนประสาทเทียมในชั้นซ่อนที่ 1

การพิจารณาผลของจำนวนประสาทเทียมในชั้นซ่อนที่ 1 ในแบบจำลอง ANN ในขั้นตอนการทดสอบ จะมีค่าเฉลี่ยของค่าเฉลี่ยของ RMSE เมื่อใช้จำนวนประสาทเทียมแตกต่างกัน แสดงดังตารางที่ 6-5 และรูปที่ 6-6

ตารางที่ 6-5 ค่าเฉลี่ยของ RMSE จากแบบจำลอง ANN 2 ชั้นซ่อนเมื่อใช้จำนวนประสาทเทียมในชั้นซ่อนที่ 1 แตกต่างกัน

คู่ฟังก์ชันถ่ายโอน	จำนวนประสาทเทียมในชั้นซ่อนที่ 1									
	1	2	3	4	5	6	7	8	9	10
Logsig-Logsig	4.56	3.99	4.08	4.03	3.95	4.10	3.97	4.09	4.03	4.06
Tansig-Logsig	4.50	4.08	4.05	4.04	3.99	4.10	3.94	4.04	4.03	3.95



รูปที่ 6-6 ค่าเฉลี่ยของ RMSE จากแบบจำลอง ANN 2 ชั้นซ่อนเมื่อใช้จำนวนประสาทเทียมในชั้นซ่อนที่ 1 แตกต่างกัน



ผลลัพธ์ข้างต้นแสดงให้เห็นถึงแนวโน้มของความแตกต่างของค่าเฉลี่ยของ RMSE เมื่อใช้จำนวนประสาทเทียมในชั้นซ่อนที่ 1 แตกต่างกันในทุกชุดฟังก์ชันถ่ายโอนที่ใช้ ผู้วิจัยจึงตั้งสมมติฐานเพื่อการทดสอบแนวโน้ม ดังนี้

$H_0$ : กลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลอง ANN 2 ชั้นซ่อนที่ใช้จำนวนประสาทเทียมในชั้นซ่อนที่ 1 แตกต่างกันจะไม่แตกต่างกัน

$H_1$ : มีกลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลอง ANN 2 ชั้นซ่อนที่ใช้จำนวนประสาทเทียมในชั้นซ่อนที่ 1 อย่างน้อย 1 คู่ที่แตกต่างกัน


การทดสอบสมมติฐานจะกระทำโดยการทดสอบ ANOVA ที่ระดับนัยสำคัญทางสถิติ  $\alpha = 0.05$  โดยมีผลลัพธ์แสดงดังตารางที่ 6-6

ตารางที่ 6-6 ค่า p-value ที่ได้จากการทดสอบ ANOVA ระหว่างกลุ่มค่าเฉลี่ยของ RMSE เมื่อใช้จำนวนประสาทเทียมในชั้นซ่อนที่ 1 แตกต่างกัน


คู่ฟังก์ชันถ่ายโอน	p-value
Logsig-Logsig	0.00
Tansig-Logsig	0.00

แสดงให้เห็นว่า p-value ที่ได้จากแบบจำลองทุกกรณีมีค่าน้อยกว่าค่าระดับนัยสำคัญทางสถิติที่  $\alpha = 0.05$  ทำให้ผู้วิจัยปฏิเสธ  $H_0$  หรือสรุปได้ว่า “มีกลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลอง ANN 2 ชั้นซ่อนที่ใช้จำนวนประสาทเทียมในชั้นซ่อนที่ 1 อย่างน้อย 1 คู่ที่แตกต่างกัน” ในทุกชุดฟังก์ชันถ่ายโอนที่ใช้

จากการปฏิเสธ  $H_0$  ผู้วิจัยต้องการหาว่าการใช้จำนวนประสาทเทียมเท่าไรทำให้เกิดความแตกต่างดังกล่าว จึงใช้วิธีการทดสอบ Tukey's Test เพื่อหาจำนวนประสาทเทียมในชั้นซ่อนที่ 1 ที่ทำให้เกิดค่าเฉลี่ยของ RMSE แตกต่างออกไปโดยใช้สมมติฐาน  $H_0, H_1$  เดิมที่ระดับนัยสำคัญทางสถิติ  $\alpha = 0.05$  โดยมีผลลัพธ์แสดงดังรูปที่ 6-7 และ 6-8



รูปที่ 6-7 RMSE เมื่อใช้แบบจำลองที่มีฟังก์ชันถ่ายโอน Logsig-Logsig เมื่อใช้จำนวนประสาทเทียมในชั้นซ่อนที่ 1 แตกต่างกัน



รูปที่ 6-8 RMSE เมื่อใช้แบบจำลองที่มีฟังก์ชันถ่ายโอน Tansig-Logsig เมื่อใช้จำนวนประสาทเทียมในชั้นซ่อนที่ 1 แตกต่างกัน


ผลลัพธ์จากรูปที่ 6-7 6-8 พบว่าการใช้จำนวนประสาทเทียม 1 จำนวนจะทำให้ค่าเฉลี่ยของ RMSE มากกว่าการใช้จำนวนประสาทเทียมอื่น ๆ ในขณะที่จะไม่พบความแตกต่างของค่าเฉลี่ยของ RMSE จากแบบจำลองที่ใช้จำนวนประสาทเทียมตั้งแต่ 2 – 10 ตัว ซึ่งเป็นผลลัพธ์ที่สอดคล้องกับขั้นตอนการพัฒนาแบบจำลอง

### 6.1.3 จำนวนประสาทเทียมในชั้นซ่อนที่ 2

การพิจารณาผลของจำนวนประสาทเทียมที่ใช้ในชั้นซ่อนที่ 2 ที่มีต่อกลุ่ม RMSE ในขั้นตอนการทดสอบแบบจำลอง สามารถคำนวณค่าเฉลี่ยของกลุ่ม RMSE เมื่อใช้จำนวนประสาทเทียมในชั้นซ่อนที่ 2 ต่าง ๆ ได้ดังตารางที่ 6-7 และรูปที่ 6-9

ตารางที่ 6-7 ค่าเฉลี่ยของ RMSE จากแบบจำลอง ANN 2 ชั้นซ่อนเมื่อใช้จำนวนประสาทเทียมในชั้นซ่อนที่ 2 แตกต่างกัน

คู่ฟังก์ชันถ่ายโอน	จำนวนประสาทเทียมในชั้นซ่อนที่ 2									
	1	2	3	4	5	6	7	8	9	10
Logsig-Logsig	3.84	3.91	3.89	3.96	4.08	4.20	4.23	4.23	4.23	4.30
Tansig-Logsig	3.91	3.89	3.93	4.01	4.06	4.11	4.21	4.19	4.20	4.20



รูปที่ 6-9 ค่าเฉลี่ยของ RMSE จากแบบจำลอง ANN 2 ชั้นซ่อนเมื่อใช้จำนวนประสาทเทียมในชั้นซ่อนที่ 2 แตกต่างกัน

จากการพิจารณาเบื้องต้น จะเห็นถึงแนวโน้มของความแตกต่างของค่าเฉลี่ยของ RMSE เมื่อใช้จำนวนประสาทเทียมในชั้นซ่อนที่ 2 แตกต่างกันในทุกชุดฟังก์ชันถ่ายโอนที่ใช้ ผู้วิจัยจึงตั้งสมมติฐานเพื่อทดสอบแนวโน้มที่เห็น ดังนี้

$H_0$ : กลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลอง ANN 2 ชั้นซ่อนที่ใช้จำนวนประสาทเทียมในชั้นซ่อนที่ 2 แตกต่างกันจะไม่แตกต่างกัน

$H_1$ : มีกลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลอง ANN 2 ชั้นซ่อนที่ใช้จำนวนประสาทเทียมในชั้นซ่อนที่ 2 อย่างน้อย 1 คู่ที่แตกต่างกัน


การทดสอบสมมติฐานจะกระทำโดยการทดสอบ ANOVA ที่ระดับนัยสำคัญทางสถิติ  $\alpha = 0.05$  โดยมีผลลัพธ์แสดงดังตารางที่ 6-8

ตารางที่ 6-8 ค่า p-value ที่ได้จากการทดสอบ ANOVA ระหว่างกลุ่มค่าเฉลี่ยของ RMSE เมื่อใช้จำนวนประสาทเทียมในชั้นซ่อนที่ 2 แตกต่างกัน


คู่ฟังก์ชันถ่ายโอน	p-value
Logsig-Logsig	0.00
Tansig-Logsig	0.00

ผลลัพธ์จากตารางที่ 6-8 พบว่า p-value ที่ได้จากแบบจำลองทุกกรณีมีค่าน้อยกว่าค่าระดับนัยสำคัญทางสถิติที่  $\alpha = 0.05$  ทำให้เกิดการปฏิเสธ  $H_0$  หรือสรุปได้ว่า “มีกลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลอง ANN 2 ชั้นซ่อนที่ใช้จำนวนประสาทเทียมในชั้นซ่อนที่ 2 อย่างน้อย 1 คู่ที่แตกต่างกัน” ในทุกชุดฟังก์ชันถ่ายโอนที่ใช้

จากการปฏิเสธ  $H_0$  ผู้วิจัยต้องการหาว่าการใช้จำนวนประสาทเทียมเท่าไรทำให้เกิดความแตกต่างดังกล่าว จึงใช้วิธีการทดสอบ Tukey's Test เพื่อหาจำนวนประสาทเทียมในชั้นซ่อนที่ 2 ที่ทำให้เกิดค่าเฉลี่ยของ RMSE แตกต่างออกไปโดยใช้สมมติฐาน  $H_0, H_1$  เดิมที่ระดับนัยสำคัญทางสถิติ  $\alpha = 0.05$  โดยมีผลลัพธ์แสดงดังรูปที่ 6-10 และ 6-11



รูปที่ 6-10 RMSE เมื่อใช้แบบจำลองที่มีฟังก์ชันถ่ายโอน Logsig-Logsig เมื่อใช้จำนวนประสาทเทียม  
ในชั้นซ่อนที่ 2 แตกต่างกัน



รูปที่ 6-11 RMSE เมื่อใช้แบบจำลองที่มีฟังก์ชันถ่ายโอน Tansig-Logsig เมื่อใช้จำนวนประสาทเทียม  
ในชั้นซ่อนที่ 2 แตกต่างกัน

ผลลัพธ์จากรูปที่ 6-10 และ 6-11 แสดงให้เห็นแนวโน้มของการเพิ่มของช่วงค่าเฉลี่ยของ RMSE เมื่อเพิ่มจำนวนประสาทเทียมในชั้นซ่อนที่ 2 ซึ่งหากเปรียบเทียบแต่ละรูปจะพบว่า

- จากรูปที่ 6-10 ที่เป็นการเปรียบเทียบแบบจำลอง ANN ที่ใช้ชุดฟังก์ชันถ่ายโอน Logsig-Logsig พบว่าการใช้จำนวนประสาทเทียมในชั้นซ่อนที่ 2 จำนวน 10 หน่วย ทำให้กลุ่มค่าเฉลี่ยของ RMSE มากกว่ากลุ่มค่าเฉลี่ยของ RMSE จากการใช้จำนวนประสาทเทียม 1 – 4 ตัว ในขณะที่ไม่พบความแตกต่างระหว่างกลุ่มค่าเฉลี่ยของ RMSE จากคู่ของจำนวนประสาทเทียมอื่น ๆ
- จากรูปที่ 6-11 ที่เป็นการเปรียบเทียบแบบจำลอง ANN ที่ใช้ชุดฟังก์ชันถ่ายโอน Tansig-Logsig พบว่าการใช้จำนวนประสาทเทียมในชั้นซ่อนที่ 2 จำนวน 7 หน่วย ทำให้กลุ่มค่าเฉลี่ยของ RMSE แตกต่างจากการใช้จำนวนประสาทเทียม 2 ตัวอย่างมีนัยสำคัญทางสถิติ ในขณะที่ไม่พบความแตกต่างระหว่างกลุ่มค่าเฉลี่ยของ RMSE จากคู่ของจำนวนประสาทเทียมอื่น ๆ

ผลลัพธ์ดังกล่าวแสดงให้เห็นว่าการใช้จำนวนประสาทเทียมในชั้นซ่อนที่ 2 จำนวนน้อย (1 – 5 ตัว) จะทำให้แบบจำลอง ANN ทำนายได้ดีกว่าการใช้จำนวนประสาทเทียมในชั้นซ่อนที่ 2 จำนวนมาก (6 – 10 ตัว) เนื่องจากการเพิ่มจำนวนประสาทเทียมในชั้นซ่อนที่ 2 มากเกินไป ในขณะที่มีข้อมูลในการพัฒนาแบบจำลองจำกัด จะทำให้เพิ่มความแปรผันในข้อมูลในชั้นซ่อนที่ 2 ทำให้การทำนายข้อมูลนำออกมีความแม่นยำน้อยลง

ผลลัพธ์จากการทดสอบแบบจำลอง ANN 2 ชั้นซ่อน ทำให้ได้ข้อสรุปว่าแบบจำลองที่ให้ค่าเฉลี่ยของ RMSE ต่ำ ซึ่งเกี่ยวข้องกับความแม่นยำในการทำนายที่สูง จะต้องมีปัจจัยที่เหมาะสม ได้แก่ การใช้ชุดฟังก์ชันถ่ายโอน Logsig – Logsig หรือ Tansig – Logsig ในขณะที่จำนวนประสาทเทียมในชั้นซ่อนที่ 1 ควรใช้จำนวนประสาทเทียมตั้งแต่ 2 – 10 ตัว ในขณะที่จำนวนประสาทเทียมในชั้นซ่อนที่ 2 ที่ใช้ควรมีจำนวน 1 – 5 ตัว ซึ่งผู้วิจัยจะนำแบบจำลองที่มีปัจจัยดังกล่าวไปใช้ในการวิเคราะห์ร่วมกับแบบจำลอง SVR ต่อไป

## 6.2 แบบจำลอง SVR

ในขั้นตอนการทดสอบแบบจำลอง SVR การใช้ชุดข้อมูลทดสอบเพื่อทำนายค่าจะได้ผลลัพธ์เป็นค่า RMSE จากแบบจำลองที่ใช้ Kernel Function ทั้ง 3 ประเภทแสดงดังตารางที่ 6-9

ตารางที่ 6-9 RMSE จากแบบจำลอง SVR

Kernel Function	Linear	Gaussian	Polynomial
RMSE	3.58	3.26	4.01

ผลลัพธ์จากตารางที่ 6-9 พบว่าแบบจำลองจะให้ค่า RMSE ในขั้นตอนทดสอบสูงกว่าเล็กน้อยเมื่อเปรียบเทียบกับขั้นตอนการพัฒนา ยกเว้นแบบจำลองที่ใช้ Kernel Function ประเภท Polynomial ที่ให้ค่า RMSE เพิ่มขึ้นอย่างเห็นได้ชัด (4.0066 เมื่อเปรียบเทียบกับ 0.7546) อาจเป็นไปได้ว่าแบบจำลองที่ใช้ Kernel Function ประเภท Polynomial จะเกิด Overfitting กับข้อมูลนำเข้าที่ใช้ในชุดการพัฒนาแบบจำลอง และทำให้การทำนายค่าจากข้อมูลนำเข้าที่ใช้ในการทดสอบแบบจำลองไม่ถูกต้องเท่าที่ควร

## 6.3 การประเมินค่าทำนายจากแบบจำลอง

นอกจากการประเมินความแม่นยำในการทำนายของแบบจำลอง ANN และ SVR แล้ว ผู้วิจัยได้ทำการทดสอบความอ่อนไหวของแบบจำลอง (Sensitivity Analysis) ระหว่างค่าพารามิเตอร์ต่างๆ กับข้อมูลนำออกของแบบจำลองแต่ละประเภท โดยใช้แบบจำลอง ANN และ SVR ที่มีค่า RMSE จากการทำนายข้อมูลนำออกในการทดสอบใกล้เคียงกัน (RMSE ของแบบจำลอง ANN และ SVR คือ 3.2597 และ 3.26 ตามลำดับ) และมีการเปลี่ยนแปลงค่าของพารามิเตอร์ต่างๆ จากนั้นหาค่าเฉลี่ยของการเปลี่ยนแปลงค่าของข้อมูลนำออกหลังจากการเปลี่ยนแปลงพารามิเตอร์แล้ว ซึ่งได้ผลลัพธ์จากแบบจำลอง ANN และ SVR ดังตารางที่ 6-10 6-11 6-12 และ 6-13



ตารางที่ 6-10 การทดสอบความอ่อนไหวของแบบจำลอง ANN เมื่อปรับพารามิเตอร์ต่าง ๆ

พารามิเตอร์ของแบบจำลอง ANN	การเปลี่ยนแปลงของพารามิเตอร์			
	ลดลง 50%	ลดลง 10%	เพิ่มขึ้น 10%	เพิ่มขึ้น 50%
Minimum performance Gradient	0%	0%	0%	0%
Minimum mu	0%	0%	0%	0%
Mu decrease factor	0%	0%	0%	0%
Mu increase factor	0%	0%	0%	0%
Maximum mu	0%	0%	0%	0%
Maximum validation failure	0%	0%	0%	0%

ตารางที่ 6-11 การทดสอบความอ่อนไหวของแบบจำลอง SVR เมื่อใช้ Gaussian Kernel

พารามิเตอร์	Kernel Scale			
	1 (default)	2	3	4
% ที่เปลี่ยนแปลง	0%	-2.47%	-3.07%	-3.16%

ตารางที่ 6-12 การทดสอบความอ่อนไหวของแบบจำลอง SVR เมื่อใช้ Polynomial Kernel

พารามิเตอร์	Polynomial Order				
	1	2	3 (default)	4	5
% ที่เปลี่ยนแปลง	27.63%	26.53%	0%	-32.37%	-24.26%

ตารางที่ 6-13 การทดสอบความอ่อนไหวของแบบจำลอง SVR เมื่อใช้ Linear Kernel

พารามิเตอร์	Epsilon				
	0.1	0.2	0.3 (default)	0.4	0.5
% ที่เปลี่ยนแปลง	0.39%	0.53%	0%	0.11%	0.36%

ผลลัพธ์จากตารางที่ 6-10 6-11 6-12 และ 6-13 บ่งบอกให้เห็นว่าทั้งแบบจำลอง ANN และแบบจำลอง SVR มีความอ่อนไหวต่อค่าพารามิเตอร์ภายในแบบจำลองที่ค่อนข้างต่ำ สังเกตได้จากค่า %การเปลี่ยนแปลงของข้อมูลนำออกที่มีค่าน้อย ยกเว้นแบบจำลอง SVR ที่ใช้ Kernel function คือ Polynomial Kernel ที่จะมีความอ่อนไหวต่ออันดับของพหุนาม (Polynomial Order) มาก สังเกตได้จาก %การเปลี่ยนแปลงที่มีค่ามากในตารางที่ 6-14 ซึ่งยืนยันแนวโน้มของการเกิด Overfitting ดังนั้น แบบจำลอง SVR ที่ใช้ Polynomial Kernel ที่มีความอ่อนไหวมากจะไม่ถูกนำไปใช้ในการทำนายข้อมูลนำออก

#### 6.4 การเปรียบเทียบแบบจำลอง

การพิจารณาค่า RMSE ระหว่างแบบจำลอง ANN และแบบจำลอง SVR โดยจะใช้กลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลอง ANN ที่มีจำนวนประสาทเทียมในชั้นซ่อนที่ 2 คือ 1 – 5 หน่วย (เนื่องจากทดสอบแล้วว่าจำนวนประสาทเทียมในชั้นซ่อนที่ 1 ไม่มีผลต่อค่า RMSE) มาเปรียบเทียบกับค่า RMSE จากแบบจำลอง SVR ที่ใช้ Kernel Function ประเภท Linear กับ Gaussian ว่ามีความแตกต่างกันหรือไม่ โดยจะมีการตั้งสมมติฐานเพื่อทดสอบ ดังนี้

$H_0$ : กลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลอง ANN ไม่แตกต่างจาก RMSE จากแบบจำลอง SVR

$H_1$ : กลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลอง ANN แตกต่างจาก RMSE จากแบบจำลอง SVR

การทดสอบสมมติฐานจะกระทำโดย Two-tailed T-test ที่ระดับนัยสำคัญทางสถิติ  $\alpha = 0.05$  โดยมีผลลัพธ์แสดงดังตารางที่ 6-14

ตารางที่ 6-14 ค่า p-value จากการทดสอบ Two-tailed T-test ระหว่างค่า RMSE จากแบบจำลอง ANN 2 ชั้นซ้อนกับแบบจำลอง SVR

แบบจำลอง ANN		แบบจำลอง SVR	
ชุดฟังก์ชันถ่ายโอน	ประสาทเทียมในชั้นซ้อนที่ 2	Linear	Gaussian
Logsig-Logsig	1	0.00	0.00
	2	0.00	0.00
	3	0.00	0.00
	4	0.00	0.00
	5	0.00	0.00
Tansig-Logsig	1	0.00	0.00
	2	0.00	0.00
	3	0.00	0.00
	4	0.00	0.00
	5	0.00	0.00

ผลลัพธ์จากตารางที่ 6-14 พบว่าค่า p-value จากการเปรียบเทียบแบบจำลองทุกกรณีมีค่าน้อยกว่าค่าระดับนัยสำคัญทางสถิติที่  $\alpha = 0.05$  ทำให้เกิดการปฏิเสธ  $H_0$  และสรุปว่า “กลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลอง ANN แตกต่างจาก RMSE จากแบบจำลอง SVR” ทุกกรณี ผลลัพธ์ข้างต้นทำให้ผู้วิจัยทำการทดสอบต่อไปว่าแบบจำลองประเภทใดมีค่า RMSE น้อยกว่าอีกแบบจำลอง โดยจากการสังเกตค่า RMSE พบว่าแบบจำลอง SVR น่าจะมีค่า RMSE น้อยกว่าแบบจำลอง ANN ผู้วิจัยจึงตั้งสมมติฐานเพื่อทดสอบข้อสังเกตที่ได้ ดังนี้

$H_0$ : กลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลอง ANN ไม่มากกว่า RMSE จากแบบจำลอง SVR

$H_1$ : กลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลอง ANN มากกว่า RMSE จากแบบจำลอง SVR

การทดสอบสมมติฐานจะกระทำโดยการทดสอบ One-tailed T-test ที่ระดับนัยสำคัญทางสถิติ  $\alpha = 0.05$  โดยมีผลลัพธ์แสดงดังตารางที่ 6-15

ตารางที่ 6-15 ค่า p-value จากการทดสอบ One-tailed T-test ระหว่างค่า RMSE จากแบบจำลอง ANN 2 ชั้นซ่อนที่ใช้ฟังก์ชันถ่ายโอน Logsig-Logsig และแบบจำลอง SVR

แบบจำลอง ANN		แบบจำลอง SVR	
ชุดฟังก์ชันถ่ายโอน	ประสาทเทียมในชั้นซ่อนที่ 2	Linear	Gaussian
Logsig-Logsig	1	0.00	0.00
	2	0.00	0.00
	3	0.00	0.00
	4	0.00	0.00
	5	0.00	0.00
Tansig-Logsig	1	0.00	0.00
	2	0.00	0.00
	3	0.00	0.00
	4	0.00	0.00
	5	0.00	0.00

ผลลัพธ์จากตารางที่ 6-15 ระบุว่าค่า p-value ที่ได้ทุกกรณีมีค่าน้อยกว่าค่าระดับนัยสำคัญทางสถิติที่  $\alpha = 0.05$  ทำให้เกิดการปฏิเสธ  $H_0$  และสรุปว่า “กลุ่มค่าเฉลี่ยของ RMSE จากแบบจำลอง ANN มากกว่า RMSE จากแบบจำลอง SVR” ทุกกรณี บ่งชี้ได้ว่าแบบจำลอง SVR มีข้อได้เปรียบกว่าแบบจำลอง ANN ในการทำนายค่า โดยสาเหตุเกิดจากการที่มีจำนวนข้อมูลที่ใช้ในการพัฒนาแบบจำลองอย่างจำกัด ทำให้แบบจำลอง SVR สามารถทำนายได้แม่นยำกว่าแบบจำลอง ANN [25]


เมื่อเปรียบเทียบแบบจำลอง SVR ทั้งสองประเภทที่เหลือ พบว่าแบบจำลองที่ใช้ Kernel Function ประเภท Gaussian จะมีค่า RMSE ต่ำกว่าแบบจำลองที่ใช้ Kernel Function ประเภท Linear ทั้งขณะพัฒนาแบบจำลองและทดสอบแบบจำลอง เนื่องจากความสัมพันธ์ระหว่างข้อมูลไม่เป็นแบบเส้นตรงจึงทำให้การใช้ Kernel Function ประเภท Linear จะทำนายได้แม่นยำน้อยกว่า ดังนั้น Kernel Function ประเภท Gaussian จึงถูกนำมาใช้ในแบบจำลอง SVR

## 6.5 การประยุกต์ใช้งานแบบจำลอง

เมื่อนำแบบจำลอง SVR ที่ใช้ Kernel function ประเภท Gaussian มาทำนายค่าของข้อมูลนำออกในชุดข้อมูลที่ใช้ฝึกฝนและทดสอบแบบจำลอง จะได้ค่าทำนายของข้อมูลนำออกเมื่อเปรียบเทียบกับค่าจริงของข้อมูลนำออกของชุดข้อมูลที่ใช้ฝึกฝนแบบจำลอง กับชุดข้อมูลที่ใช้ทดสอบแบบจำลองได้ดังตารางที่ 6-16 และ 6-17 กับรูปที่ 6-12 และ 6-13

ตารางที่ 6-16 ค่าจริงและค่าทำนายของชุดข้อมูลฝึกฝนจากแบบจำลอง SVR (Gaussian Kernel)


ข้อมูลนำออกที่	ค่าจริง	ค่าทำนาย	ข้อมูลนำออกที่	ค่าจริง	ค่าทำนาย
1	900	915.54	10	903	887.55
2	900	915.22	11	903	918.48
3	600	800.81	12	798	915.83
4	900	915.22	13	944	959.48
5	903	918.44	14	1,888	1,220.20
6	1,650	1,098.43	15	1,888	1,224.99
7	903	918.54	16	943	951.31
8	900	915.20	17	1,598	1,093.48
9	451.5	862.72			



รูปที่ 6-12 ค่าจริงและค่าทำนายของชุดข้อมูลฝึกฝนจากแบบจำลอง SVR (Gaussian Kernel)

ตารางที่ 6-17 ค่าจริงและค่าทำนายของชุดข้อมูลทดสอบจากแบบจำลอง SVR (Gaussian Kernel)

ข้อมูลนำออกที่	ค่าจริง	ค่าทำนาย
1	900	954.01
2	900	884.36
3	1,650	1,067.77
4	903	923.55
5	903	929.69
6	903	952.11
7	798	925.12
8	1,888	1,118.73
9	943	948.04



รูปที่ 6-13 ค่าจริงและค่าทำนายของชุดข้อมูลทดสอบจากแบบจำลอง SVR (Gaussian Kernel)

ผลลัพธ์ที่ได้จากตารางที่ 6-16 กับ 6-17 และรูปที่ 6-12 กับ 6-13 แสดงให้เห็นการทำนายของข้อมูลนำออกที่ได้จากแบบจำลอง SVR ที่ใช้ Gaussian Kernel ซึ่งพบว่าแบบจำลองจะมีการทำนายใกล้เคียงความเป็นจริงเมื่อค่าของข้อมูลนำออกอยู่ในช่วง 800 – 1,000 และจะมีความแม่นยำในการทำนายลดลงเมื่อค่าของข้อมูลนำออกอยู่ภายนอกช่วง 800 – 1,000 เนื่องจากการมีจำนวนข้อมูลที่มีค่าของข้อมูลนำออกภายนอกช่วง 800 – 1,000 น้อย ทำให้แบบจำลองได้รับการฝึกฝนแบบจำลองในช่วงดังกล่าวไม่เพียงพอ นำไปสู่การทำนายที่ไม่แม่นยำดังกล่าว อย่างไรก็ตาม การคำนวณค่า Mean Absolute Percentage Error (MAPE) จากการทำนายชุดข้อมูลฝึกฝน และชุดข้อมูลทดสอบ อยู่ที่ 17.12% และ 12.32% ตามลำดับแสดงให้เห็นว่าแบบจำลองยังคงมีประสิทธิภาพในการทำนายดี

จากการพัฒนาและทดสอบแบบจำลองที่ผ่านมาด้วยข้อมูลที่ได้รับจากบริษัทกรณีศึกษา แบบจำลองสมการ SVR สามารถใช้ในการทำนายค่าของข้อมูลนำออกได้แม่นยำกว่าการใช้แบบจำลอง ANN ทั้งในขั้นตอนการพัฒนาแบบจำลองและการทดสอบแบบจำลอง โดยการใช้ความสัมพันธ์แบบ Gaussian จะทำนายได้แม่นยำที่สุด ดังนั้น แบบจำลอง SVR ที่ใช้ความสัมพันธ์แบบ Gaussian จะถูกนำไปประยุกต์ใช้ในบริษัทกรณีศึกษาเพื่อช่วยในการเลือกค่าพารามิเตอร์ในการผลิตต่อไป





## บทที่ 7

### สรุปผลการวิจัยและข้อเสนอแนะ

ในบทนี้จะกล่าวถึงข้อสรุปในงานวิจัย ตั้งแต่การวิเคราะห์และคัดเลือกข้อมูลที่ใช้ในงานวิจัย การวิเคราะห์ความแม่นยำของแบบจำลองที่พัฒนาได้ทั้งสองแบบ การทดสอบใช้งานแบบจำลอง และ ข้อเสนอแนะในการดำเนินงานวิจัย

#### 7.1 สรุปผลงานวิจัย

ในการผลิตผลิตภัณฑ์ยา จำเป็นต้องมีกระบวนการคิดค้นและพัฒนาการผลิตผลิตภัณฑ์โดยมีขนาดการผลิตทั้งหมด 3 แบบ คือ ขนาดการผลิตเพื่อการวิจัย (Laboratory Production Scale) ขนาดการผลิตขั้นกลาง (Pilot Production Scale) ที่เพิ่มปริมาณผลิตภัณฑ์ยาที่ผลิตเป็น 10 เท่า โดยประมาณ และขนาดการผลิตเพื่อการค้า (Commercial Production Scale) โดยขนาดการผลิตขั้นกลางมีเพื่อให้ผู้ดำเนินการผลิตสามารถวิเคราะห์แนวโน้มเหตุการณ์ที่จะเกิดขึ้นเมื่อเพิ่มขนาดการผลิต ทำให้ผู้ดำเนินการผลิตสามารถวิเคราะห์และปรับปรุงกระบวนการผลิตให้มีความเหมาะสมได้ อย่างไรก็ตาม บริษัทกรณีศึกษาไม่มีการดำเนินการทดลองผลิตในขนาดการผลิตขั้นกลาง ทำให้บริษัทกรณีศึกษามีขนาดการผลิตในการพัฒนาการผลิตผลิตภัณฑ์เพียง 2 แบบ คือขนาดการผลิตเพื่อการวิจัย และขนาดการผลิตเพื่อการค้า โดยผู้ดำเนินการผลิตจำเป็นต้องคาดเดาปัจจัยต่าง ๆ ที่ใช้ในขนาดการผลิตเพื่อการค้า อันเป็นเหตุให้เกิดความเสี่ยงต่อการผลิตที่ผิดพลาดนำไปสู่การสูญเสียโอกาสทางการค้า วัตถุดิบและต้นทุนการวิจัย ผู้วิจัยจึงมีแนวคิดที่จะใช้โปรแกรมแบบจำลองในการช่วยผู้ดำเนินการผลิตในการคาดเดาปัจจัยที่ใช้ในการผลิตเพื่อการค้า ทำให้ลดวัตถุดิบและต้นทุนการวิจัยที่ใช้ในบริษัทกรณีศึกษาและลดการสูญเสียโอกาสทางการค้า

งานวิจัยนี้ผู้วิจัยเริ่มต้นด้วยการรวบรวมข้อมูลที่ใช้ในการผลิตเพื่อการค้าซึ่งประกอบด้วยข้อมูลจากบริษัทกรณีศึกษาจำนวน 7 ข้อมูล ได้แก่ “สัดส่วนสารอันดับ 1” “สัดส่วนสารอันดับ 2” “ปริมาตรของเหลว” “สัดส่วนของเหลว” “ความเร็วรอบปั่นเร็ว” “ความเร็วรอบปั่นช้า” และ “จำนวนรอบของใบพาย Impeller” กับข้อมูลที่สืบค้นโดยผู้วิจัยจำนวน 4 ข้อมูล ได้แก่ “การละลาย

น้ำสารอันดับ 1” “การละลายน้ำสารอันดับ 2” “สัมประสิทธิ์น้ำ/น้ำมัน” และ “ความหนืด” รวมทั้งหมด 11 ข้อมูล ข้อมูลนำออกในงานวิจัยนี้คือ “จำนวนรอบของใบพาย Impeller” ในขณะที่ข้อมูลอีก 10 ข้อมูลที่เหลือเป็นข้อมูลนำเข้า โดยผู้วิจัยทำการวิเคราะห์หาความสัมพันธ์ระหว่างข้อมูลนำเข้า โดยใช้วิธีการวิเคราะห์องค์ประกอบหลักเพื่อค้นหาข้อมูลนำเข้าที่มีความสัมพันธ์กันมากแล้วทำการลดข้อมูลนำเข้าเพื่อลดข้อมูลนำเข้าที่ซ้ำซ้อนกัน ทำให้สามารถลดข้อมูลนำเข้าที่เกี่ยวข้องจาก 10 ข้อมูลเหลือ 7 ข้อมูล โดยพิจารณาคัดเลือก “สัดส่วนสารอันดับ 2” “สัดส่วนของเหลว” และ “สัมประสิทธิ์น้ำ/น้ำมัน” โดยมีความแปรปรวนขององค์ประกอบต่าง ๆ หลังจากลดข้อมูลนำเข้า ลดลงเหลือ 73.36% แสดงให้เห็นว่ากลุ่มข้อมูลนำเข้าหลังลดข้อมูลสามารถอ้างอิงกลุ่มข้อมูลนำเข้าก่อนลดข้อมูลได้และข้อมูลหลังการลดข้อมูลนำเข้าจะถูกนำไปพัฒนาแบบจำลองต่อไป โดยมีการพัฒนาแบบจำลอง 2 รูปแบบ คือแบบจำลอง ANN และแบบจำลอง SVR

ในการพัฒนาและทดสอบแบบจำลอง ANN นั้น พบว่ามีปัจจัยที่สามารถกำหนดได้หลายปัจจัย ซึ่งการวิเคราะห์ระบุว่าการใช้ฟังก์ชันถ่ายโอนประเภท Purelin ในแบบจำลองไม่เหมาะสมต่อการทำนายในงานวิจัยนี้ เนื่องจากค่า RMSE ที่ได้มีค่าสูงกว่าแบบจำลองที่ใช้ฟังก์ชันถ่ายโอนประเภท Tansig และ Logsig ในส่วนของจำนวนชั้นซ่อน พบว่าการใช้ชั้นซ่อนในแบบจำลอง ANN 2 ชั้นซ่อนสามารถทำการทำนายได้ถูกต้องกว่าการใช้ชั้นซ่อนเพียง 1 ชั้น นอกจากนั้นจำนวนประสาทเทียมในชั้นซ่อนแต่ละชั้นก็มีผลต่อความถูกต้องในการทำนายด้วย หากจำนวนประสาทเทียมมีมาก จะทำให้มีความแปรผันจากจำนวนประสาทเทียมที่มากเกินไป ทำให้ความสามารถในการทำนายลดลง ในขณะที่หากจำนวนประสาทเทียมมีน้อย จะทำให้ไม่สามารถประมวลผลปัจจัยต่าง ๆ ได้ละเอียดเพียงพอทำให้ความสามารถในการทำนายลดลงเช่นกัน

การพัฒนาและทดสอบแบบจำลอง SVR จะมีปัจจัยที่เกี่ยวข้องเพียงปัจจัยเดียวคือ Kernel Function ที่ใช้ในแบบจำลอง ซึ่งพบว่าการใช้ความสัมพันธ์ Kernel Function ประเภท Polynomial จะเกิดเหตุการณ์ Overfitting ในขณะที่ไม่เกิดเหตุการณ์ดังกล่าวกับแบบจำลองที่ใช้ Kernel Function ประเภท Linear และ Gaussian อย่างไรก็ตาม เนื่องจากความสัมพันธ์ระหว่างข้อมูลที่ใช้ในแบบจำลองไม่ได้เป็นแบบเส้นตรง ทำให้การใช้ Kernel Function ประเภท Linear ในแบบจำลอง

SVR ไม่เหมาะสมนัก ทำให้สรุปว่าแบบจำลอง SVR ควรใช้ Kernel Function ประเภท Gaussian ในการทำนายค่า

เมื่อทำการเปรียบเทียบความถูกต้องในการทำนายระหว่างแบบจำลองทั้งสองประเภท พบว่าแบบจำลอง SVR สามารถทำนายค่าได้ดีกว่าแบบจำลอง ANN อย่างมีนัยสำคัญทางสถิติ เนื่องจากจำนวนชุดข้อมูลที่ใช้ในการพัฒนาและทดสอบแบบจำลองมีจำกัด ดังนั้นแบบจำลอง SVR จะถูกนำมาทดสอบประสิทธิภาพในการทำนาย ซึ่งผู้วิจัยเลือกใช้แบบจำลอง SVR ที่ใช้ Kernel function ประเภท Gaussian มาทดสอบประสิทธิภาพ ซึ่งแสดงในรูปแบบของ MAPE โดยมีค่า MAPE จากการทำนายข้อมูลนำออกจากชุดข้อมูลฝึกฝน และชุดข้อมูลทดสอบอยู่ที่ 17.12% และ 12.32% บ่งบอกว่าแบบจำลองมีประสิทธิภาพในการทำนายในระดับดี แบบจำลองดังกล่าวจะถูกนำไปประยุกต์ใช้เพื่อช่วยจำกัดขอบเขตของค่าพารามิเตอร์ที่ใช้ในการผลิตต่อไป

## 7.2 ข้อเสนอแนะ

ในงานวิจัยนี้ มีข้อจำกัดด้วยกันหลายประการ เช่น

- ข้อมูลที่ได้จากการผลิตผลิตภัณฑ์มาจากเครื่องมือปั้นผสมหลายรูปแบบ ทำให้ค่าของข้อมูลที่ใช้ในแบบจำลองไม่สามารถเปรียบเทียบกันได้แน่นอน
- ข้อมูลบางชนิดจากสารที่ใช้ในการผลิตถูกสืบค้นมาจากแหล่งข้อมูลอิเล็กทรอนิกส์ อาจไม่ตรงกับข้อมูลจากสารที่ใช้ในการผลิตจริง ซึ่งแบบจำลองสามารถถูกพัฒนาขึ้นมาใหม่ได้อีกครั้งหากมีการตรวจหาข้อมูลในสารที่ใช้ในการผลิตจริงในอนาคต
- จำนวนชุดข้อมูลที่ใช้ในการพัฒนาและทดสอบแบบจำลองที่มีอย่างจำกัด หากมีการเพิ่มชุดข้อมูลในอนาคต จะทำให้สามารถพัฒนาแบบจำลองให้มีประสิทธิภาพในการทำนายเพิ่มมากขึ้นได้
- แบบจำลองที่พัฒนาจากข้อมูลที่มาจากรุ่นปั้นผสมจากบริษัทกรณีศึกษา หากนำแบบจำลองไปใช้กับเครื่องมือปั้นผสมจากบริษัทอื่น ๆ อาจใช้เครื่องมือปั้นผสมคนละรูปแบบกัน ทำให้แบบจำลองมีประสิทธิภาพในการทำนายต่ำ

### บรรณานุกรม

1. กรุงเทพธุรกิจ. อุตสาหกรรมยาเติบโตเฉลี่ย 6.2% ต่อปี. 2020 [May 25, 2020]; Available from: <https://www.bangkokbiznews.com/news/detail/861818>.
2. รายการยาสามัญ (NG) ที่อนุมัติขึ้นทะเบียน ปี พ.ศ. 2557.
3. Allen, L.V., in *Remington: The Science and Practice of Pharmacy*. 2013, Pharmaceutical Press: Philadelphia. p. 947 - 976.
4. Faure, A., P. York, and R.C. Rowe, *Process control and scale-up of pharmaceutical wet granulation processes: a review*. *Eur J Pharm Biopharm*, 2001. **52**(3): p. 269-77.
5. Bertolaccini, L., et al., *An overview of the use of artificial neural networks in lung cancer research*. *J Thorac Dis*, 2017. **9**(4): p. 924-931.
6. Basak, D.P., S.; Patranabis, D.C., *Support Vector Regression*. *Neural Information Processing*, 2007. **11**: p. 203 - 224.
7. Ioele, G., et al., *Artificial neural network combined with principal component analysis for resolution of complex pharmaceutical formulations*. *Chem Pharm Bull (Tokyo)*, 2011. **59**(1): p. 35-40.
8. Naguib, I.A. and H.W. Darwish, *Support vector regression and artificial neural network models for stability indicating analysis of mebeverine hydrochloride and sulphiride mixtures in pharmaceutical preparation: a comparative study*. *Spectrochim Acta A Mol Biomol Spectrosc*, 2012. **86**: p. 515-26.
9. Elkhoudary, M.M., R.A. Abdel Salam, and G.M. Hadad, *Comparative artificial neural network and partial least squares models for analysis of Metronidazole, Diloxanide, Spiramycin and Cliquinol in pharmaceutical preparations*. *Spectrochim Acta A Mol Biomol Spectrosc*, 2014. **130**: p. 222-9.
10. Korteby, Y., et al., *Implementation of an artificial neural network as a PAT tool for the prediction of temperature distribution within a pharmaceutical fluidized bed granulator*. *Eur J Pharm Sci*, 2016. **88**: p. 219-32.
11. Shirazian, S., et al., *Artificial neural network modelling of continuous wet granulation using a twin-screw extruder*. *Int J Pharm*, 2017. **521**(1-2): p. 102-109.

12. Baba, H., et al., *Modeling and Prediction of Solvent Effect on Human Skin Permeability using Support Vector Regression and Random Forest*. Pharm Res, 2015. **32**(11): p. 3604-17.
13. Shah, A., et al., *Support vector regression to estimate the permeability enhancement of potential transdermal enhancers*. J Pharm Pharmacol, 2016. **68**(2): p. 170-84.
14. Naguib, I.A., et al., *Determination of Cefoperazone Sodium in Presence of Related Impurities by Linear Support Vector Regression and Partial Least Squares Chemometric Models*. J Anal Methods Chem, 2015. **2015**: p. 593892.
15. Clavaud, M., et al., *Global regression model for moisture content determination using near-infrared spectroscopy*. Eur J Pharm Biopharm, 2017. **119**: p. 343-352.
16. Pandey, P. and S. Badawy, *A quality by design approach to scale-up of high-shear wet granulation process*. Drug Dev Ind Pharm, 2016. **42**(2): p. 175-89.
17. Zupan, J., *Introduction to Artificial Neural Network (ANN) Methods: What They Are and How to Use Them*. Acta Chimica Slovenica, 1994: p. 327-352.
18. Ibric, S., et al., *Artificial neural networks in evaluation and optimization of modified release solid dosage forms*. Pharmaceutics, 2012. **4**(4): p. 531-50.
19. Smith, L.I., *A tutorial on Principal Component Analysis*. 2002.
20. Sun, F., et al., *Latent variable modeling to analyze the effects of process parameters on the dissolution of paracetamol tablet*. Bioengineered, 2017. **8**(1): p. 61-70.
21. R Development Core Team, *R: A language and environment for statistical computing*. 2017, R Foundation for Statistical Computing: Vienna, Austria.
22. Banerjee, S.Y., S.H.; Valvani, S.C., *Water Solubility and Octanol/Water Partition Coefficients of Organics. Limitations of the Solubility-Partition Coefficient Correlation*. Environ Sci Technol, 1980. **14**(10): p. 1227-1229.
23. van Gestel, C.A., K. Otermann, and J.H. Canton, *Relation between water solubility, octanol/water partition coefficients, and bioconcentration of organic chemicals in fish: a review*. Regul Toxicol Pharmacol, 1985. **5**(4): p. 422-31.
24. *MATLAB*. 2017, The MathWorks Incorporation: Natick, Massachusetts.

25. Golkarnarenji, G., et al., *Production of Low Cost Carbon-Fiber through Energy Optimization of Stabilization Process*. *Materials (Basel)*, 2018. **11**(3).





จุฬาลงกรณ์มหาวิทยาลัย  
**CHULALONGKORN UNIVERSITY**

## ประวัติผู้เขียน

ชื่อ-สกุล	บุญญสิษฐ์ ชำนาญทองไพวัลท์
วัน เดือน ปี เกิด	16 กรกฎาคม 2535
สถานที่เกิด	กรุงเทพมหานคร
วุฒิการศึกษา	ประถมศึกษาและมัธยมศึกษา : อัสสัมชัญสมุทรปราการ ปริญญาตรี : คณะเภสัชศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย
ที่อยู่ปัจจุบัน	69/794 สุขุมวิท 48 แขวงคลองเตย เขตพระโขนง กรุงเทพมหานคร 10110



จุฬาลงกรณ์มหาวิทยาลัย  
CHULALONGKORN UNIVERSITY