

การทำนายค่าความหนืดมุนนี้ของยางคอมพาวด์ด้วยระบบอนุมานตรรกศาสตร์คลุมเครือโครงข่าย
ประสาทเทียมแบบปรับตัวได้

ปาลิดา ทรัพย์ศิริโรจน์

TNI

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต

บัณฑิตวิทยาลัย สาขาเทคโนโลยีวิศวกรรม

สถาบันเทคโนโลยีไทย-ญี่ปุ่น

ปีการศึกษา 2563

MOONEY VISCOSITY PREDICTION OF RUBBER COMPOUNDS BASED ON ADAPTIVE
NEURO-FUZZY INFERENCE SYSTEM

Palida Sapsiroht

TNI

A Thesis Submitted in Partial Fulfillment of Requirements
for The Degree of Master of Engineering Program in Engineering Technology

Graduate School
Thai-Nichi Institute of Technology

Academic Year 2020

หัวข้อวิทยานิพนธ์

การหาค่าความเหนียวของยางคอมพาวด์ด้วยระบบ
อนุমানตรรกศาสตร์คลุมเครือโครงข่ายประสาทเทียมแบบ
ปรับตัวได้

โดย

ปาลิดา ทรัพย์ศิริโรจน์

สาขาวิชา

เทคโนโลยีวิศวกรรม

อาจารย์ที่ปรึกษาวิทยานิพนธ์

ดร. กันติชา กิตติพิรชล

บัณฑิตวิทยาลัย สถาบันเทคโนโลยีไทย-ญี่ปุ่น อนุมัติให้บัณฑิตวิทยาลัยนี้เป็น
ส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรบัณฑิต

.....คณบดีบัณฑิตวิทยาลัย

(รองศาสตราจารย์ ดร. พิชิต สุขเจริญพงษ์)

วันที่.....เดือน.....พ.ศ.....

คณะกรรมการสอบวิทยานิพนธ์

.....ประธานกรรมการ

(ดร. สรรพงค์ ทานอก)

.....กรรมการ

(รองศาสตราจารย์ ดร. วรากร ศรีเชวงทรัพย์)

.....กรรมการ

(ดร. วชิรินทร์ หนูทอง)

.....อาจารย์ที่ปรึกษาวิทยานิพนธ์

(ดร. กันติชา กิตติพิรชล)

ปาลิดา ทรัพย์สิริโรจน์ : การทำนายค่าความหนืดมูนนี้ของยางคอมพาวด์ด้วยระบบอนุมานตรรกศาสตร์คลุมเครือโครงข่ายประสาทเทียมแบบปรับตัวได้. อาจารย์ที่ปรึกษา : ดร. กันติชา กิตติพิรัชล, 74 หน้า.

ความหนืดมูนนี้เป็นพารามิเตอร์ที่สำคัญในอุตสาหกรรมยางคอมพาวด์ เนื่องจากเป็นหนึ่งในพารามิเตอร์ที่บ่งบอกถึงคุณภาพของกระบวนการผลิตและสมบัติของยางคอมพาวด์ได้ การทราบผลค่าความหนืดมูนนี้ของแบตช์ยางคอมพาวด์นั้นๆ ใช้เวลา 5 ชั่วโมง หลังจากกระบวนการผสมเสร็จสิ้นงานวิจัยนี้มีวัตถุประสงค์ออกแบบแบบจำลองทำนายค่าความหนืดมูนนี้ของยางคอมพาวด์ด้วยระบบอนุมานตรรกศาสตร์คลุมเครือโครงข่ายประสาทเทียมแบบปรับตัวได้ นำพารามิเตอร์ที่เครื่องผสมตรวจวัดในการผสมยางมากำหนดเป็นตัวแปรอินพุต ได้แก่ อุณหภูมิ กระแสไฟฟ้า และความดัน และนำชุดข้อมูลที่เกิดจากการผลิตจริงที่ผ่านการคัดเลือกและทำความสะอาดด้วยการตัดค่าผิดพลาดและออกนอกช่วงของข้อกำหนดทางด้านคุณภาพมาใช้เป็นฐานข้อมูล การออกแบบอัลกอริทึมที่ใช้ในการหาค่าพารามิเตอร์เริ่มต้นส่วนหน้าและส่วนหลัง การศึกษาโครงสร้างของแบบจำลองที่แตกต่างกัน ได้แก่ จำนวนอินพุต 1 2 และ 3 ตัวแปร จำนวนรอบการเรียนรู้ 100 500 และ 1000 รอบ และวิธีการดำเนินการ And And-Squared OR และ OR-Squared และการจำลองอัปเดตข้อมูลใหม่ในฐานข้อมูล จากผลการจำลองพบว่า ค่า RMSE ต่ำสุดของชุดข้อมูลทดสอบเท่ากับ 4.08 มาจากการใช้อัลกอริทึมเริ่มต้นค่าพารามิเตอร์จำนวนค่าอินพุต 3 ตัวแปร จำนวนรอบการเรียนรู้ 100 รอบ และการดำเนินการ OR ผลการจำลองแสดงให้เห็นว่า จำนวนรอบการเรียนรู้ที่น้อยบ่งบอกถึงความเร็วในการประมวลผลของแบบจำลอง จึงทำให้สามารถทำนายความหนืดมูนนี้ได้ทันทีเมื่อสิ้นสุดกระบวนการผสม ผลการอัปเดตฐานข้อมูลของแบบจำลองด้วยชุดข้อมูลใหม่ที่มีการใช้สูตรยางเดียวกับชุดข้อมูลที่เก็บในฐานข้อมูลมีประสิทธิภาพในการทำนายที่ดีกว่าชุดข้อมูลที่ใช้สูตรยางใหม่

PALIDA SAPSIROHT : MOONEY VISCOSITY PREDICTION OF RUBBER COMPOUNDS
 BASED ON ADAPTIVE NEURO-FUZZY INFERENCE SYSTEM. ADVISOR : DR. KANTICHA
 KITTIPEERACHON, 74 PP.

Mooney viscosity is an important parameter in rubber compound industry because it is one of the processing windows and key properties of rubber compound. The Mooney viscosity result of each batch rubber compound takes about 5 hours after the mixing process end. The objective of this research aims to design the Mooney viscosity prediction models based on Adaptive Neuro-Fuzzy Inference Systems (ANFIS).

The input variables are selected from the measured parameter of the mixer including the temperature, current, and pressure. The database is collected from the historical data of manufacturing and then cleansed by removing errors in process and out-of-spec values. Both premise and consequent parameters of rules are created using the parameter initialization algorithm. The number of inputs are 1, 2, and 3 variables. The epochs of learning are 100, 500, and 1000. The operation methods are AND, AND-Squared, OR, and OR-Squared. Model updates with new dataset have been simulated. The simulation results show that the minimum value of RMSE for data testing is about 4.08 which is obtained by using the parameter initialization algorithm with 3-inputs, 100 epochs, and OR operation method. The low number of epochs indicates that the processing of the model is fast. A Mooney viscosity can be predicted immediately at the end of mixing process. The model with new dataset using the same rubber formulation as the database provide shown the higher prediction performance than those using the new rubber formulation.

Graduate School

Field of Engineering of Technology

Academic Year 2020

Student's Signature.....

Advisor's Signature.....

กิตติกรรมประกาศ

งานวิจัยฉบับนี้สำเร็จลุล่วงได้ด้วยดีเนื่องจากได้รับความกรุณาอย่างสูงจากอาจารย์ที่ปรึกษา ดร. กันติชา กิตติพิรชล ที่กรุณาให้คำปรึกษาและคำแนะนำเกี่ยวกับงานวิจัย และแนะนำแนวทางในการแก้ไขปัญหาต่างๆ ด้วยความเอาใจใส่เป็นอย่างยิ่ง ขอกราบขอบพระคุณ ดร. สรรพงค์ ทานอก จากมหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ อาจารย์คณะวิศวกรรมศาสตร์ สถาบันเทคโนโลยีไทย-ญี่ปุ่น รวมถึงอาจารย์ทุกท่านที่ได้กล่าวนามที่ให้ความอนุเคราะห์ให้ความช่วยเหลือในด้านต่างๆ และคอยให้คำแนะนำที่เป็นประโยชน์กับงานวิจัย ทำให้งานวิจัยนี้สำเร็จลุล่วงไปได้ด้วยดี

ขอกราบขอบพระคุณทางสถาบันเทคโนโลยีไทย-ญี่ปุ่น ที่สนับสนุนทุนการศึกษา เพื่อการศึกษา วิทยานิพนธ์ในครั้งนี้

ขอขอบพระคุณ กลุ่มบริษัทอินโนเวชั่น และฝ่ายการผลิต การควบคุมคุณภาพ วิจัยและพัฒนา และเทคโนโลยีสารสนเทศ ที่ให้ความอนุเคราะห์ข้อมูล สนับสนุนเครื่องมือ และให้คำปรึกษาที่ใช้ในการดำเนินงานวิจัยครั้งนี้

สุดท้ายนี้ผู้วิจัยหวังเป็นอย่างยิ่งว่า งานวิจัยฉบับนี้จะเป็นประโยชน์ต่อผู้ศึกษาไม่มากนักน้อย ซึ่งขอกราบขอบพระคุณ ครอบครัว พี่ๆ ที่ทำงาน และเพื่อนๆ ทุกคนทั้งผู้ที่กล่าวนามและมิได้กล่าวนาม ที่คอยให้กำลังใจ ให้คำปรึกษาและสนับสนุนในการทำงาน จนดำเนินงานสำเร็จลุล่วงไปได้ด้วยดี

ปาลิดา ทรัพย์ศิริโรจน์

TNI

THAI - NICHI INSTITUTE OF TECHNOLOGY

สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ง
บทคัดย่อภาษาอังกฤษ.....	จ
กิตติกรรมประกาศ.....	ฉ
สารบัญ.....	ช
สารบัญตาราง.....	ฌ
สารบัญรูป.....	ญ
บทที่	
1 บทนำ.....	1
1.1 ที่มาและความสำคัญ.....	1
1.2 ความสำคัญของการวิจัย.....	4
1.3 วัตถุประสงค์ของการวิจัย.....	4
1.4 ขอบเขตของการวิจัย.....	4
1.5 ผลที่คาดว่าจะได้รับ.....	4
1.6 แผนงานและระยะเวลาดำเนินการ.....	5
2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง.....	6
2.1 หลักการพื้นฐาน.....	6
2.2 งานวิจัยที่เกี่ยวข้อง.....	30
3 วิธีการวิจัย.....	36
3.1 ตัวแปรที่มีอิทธิพลต่อค่าความหนืดมุนีของยางคอมพาวด์.....	38
3.2 การหาค่าพารามิเตอร์เริ่มต้น.....	38
3.3 การออกแบบระบบบอมนูมานตรรกศาสตร์คลุมเครือโครงข่ายปรับตัวได้.....	42
3.4 การอัปเดตฐานข้อมูลของแบบจำลอง.....	44

สารบัญ (ต่อ)

บทที่	หน้า
4 ผลการศึกษาและการอภิปรายผล.....	47
4.1 ผลของตัวแปรอินพุต.....	47
4.2 ผลของอัลกอริทึมการหาค่าพารามิเตอร์เริ่มต้น	49
4.3 ผลของเงื่อนไขในโครงสร้าง ANFIS.....	50
4.4 ผลของการอัปเดตฐานข้อมูลจากข้อมูลใหม่.....	52
5 สรุปผลและข้อเสนอแนะ.....	57
5.1 สรุปผล.....	57
5.2 ข้อเสนอแนะ	58
บรรณานุกรม	59
ภาคผนวก	62
ภาคผนวก ก. ผลการทดลองเงื่อนไขในโครงสร้าง ANFIS.....	63
ภาคผนวก ข. บทความการประชุมวิชาการ	66
ประวัติย่อผู้วิจัย.....	74

TNI

TAHITI - NICHI INSTITUTE OF TECHNOLOGY

สารบัญตาราง

ตาราง	หน้า
1.1 แผนงานและระยะเวลาในการดำเนินงาน.....	5
2.1 คุณสมบัติเด่นของยางแต่ละชนิด.....	7
2.2 อุณหภูมิและระยะเวลาในการหมุนของแกนหมุนที่ใช้ในการทดสอบยาง.....	10
2.3 ฟังก์ชันสมาชิกรูปแบบต่างๆ.....	15
2.4 การเปรียบเทียบความแม่นยำในการทำนายค่าความหนืดหมุนนี้แบบจำลองต่างๆ.....	32
2.5 รายงานการวิจัยที่เกี่ยวข้อง.....	34
3.1 การแบ่งชุดข้อมูลที่ใช้ในการทดสอบแบบจำลอง.....	38
3.2 เงื่อนไขการทดสอบประสิทธิภาพการทำนายเปรียบเทียบระหว่างอัลกอริทึมอัลกอริทึม การหาค่าพารามิเตอร์เริ่มต้นและค่าสุ่ม.....	42
3.3 วิธีการดำเนินการทางพีชคณิตของความคลุมเครือเซต.....	43
3.4 เงื่อนไขการทดสอบประสิทธิภาพการทำนายที่มีการตั้งเงื่อนไขของโครงสร้าง ANFIS ที่แตกต่างกัน.....	44
3.5 เงื่อนไขการทดสอบประสิทธิภาพการทำนายค่าความหนืดหมุนนี้ของแบบจำลองที่มี การอัปเดตและไม่อัปเดตฐานข้อมูล และการทำนายข้อมูลที่มาจากสูตรยางเก่า และใหม่.....	45
4.1 ค่า RMSE ของการทำนายค่าความหนืดหมุนนี้ที่มีจำนวนและตัวแปรอินพุตที่ใช้ในการจำลอง แตกต่างกัน ได้แก่ จำนวนอินพุต 1 2 และ 3 ตัวแปร และตัวแปรอินพุต เป็นอุณหภูมิ กระแสไฟฟ้า และความดัน.....	47
4.2 ค่า RMSE ของการทำนายค่าความหนืดหมุนนี้ของยางคอมพาวด์ที่เปรียบเทียบระหว่าง อัลกอริทึมการหาค่าพารามิเตอร์เริ่มต้นและค่าสุ่มที่แบ่งออกเป็น 5 ช่วง ได้แก่ 0 ถึง 1 1 ถึง 100 100 ถึง 1000 1000 ถึง 10000 และ 10000 ถึง 100000.....	50
4.3 ค่า RMSE การทำนายค่าความหนืดหมุนนี้ที่ทดสอบโดยชุดข้อมูลที่เป็นตัวแทนสูตรยางเก่า และสูตรใหม่ โดยเปรียบเทียบการอัปเดตและไม่อัปเดตฐานข้อมูลด้วยข้อมูลที่ใช้ ทดสอบในแต่ละครั้ง.....	54
ก.1 ค่า RMSE การทำนายค่าความหนืดหมุนนี้ของชุดข้อมูลสอนระบบที่มีเงื่อนไขที่ใช้ใน การจำลองแตกต่างกัน ได้แก่ ค่าอินพุต ประเภทของการตีความ ที่จำนวนรอบ การเรียนรู้.....	64

สารบัญตาราง (ต่อ)

ตาราง

หน้า

- ก.2 ค่า RMSE การทำนายค่าความหนืดมูนี้ของชุดข้อมูลทดสอบระบบ ที่มีเงื่อนไขที่ใช้
ในการจำลองแตกต่างกัน ได้แก่ ค่าอินพุต ประเภทของการตีความ ที่จำนวนรอบ
การเรียนรู้..... 65



สารบัญรูป

รูป	หน้า
1.1 ปริมาณการใช้ยางในการผลิตผลิตภัณฑ์ของประเทศต่างๆ ในปี พ.ศ.2561.....	2
1.2 เครื่องมูนีวีส์โคมิเตอร์ (Mooney Viscometer).....	3
1.3 การทำงานของแกนหมุนภายในห้องบรรจุยาง	3
2.1 กราฟความหนืดมูนีที่ได้จากเครื่องมูนีวีส์โคมิเตอร์	10
2.2 ระบบสายการผลิตยางพาวด์ที่นิยมใช้ในอุตสาหกรรม.....	11
2.3 เครื่องผสมภายในระบบปิด.....	12
2.4 เครื่องผสมระบบเปิดชนิดสองลูกกลิ้ง.....	12
2.5 การเปรียบเทียบระหว่างตรรกศาสตร์บูลีน และตรรกศาสตร์คลุมเครือ	13
2.6 โครงสร้างของการประมวลผลแบบตรรกศาสตร์คลุมเครือ.....	13
2.7 รูปแบบการอนุมานแบบตรรกศาสตร์คลุมเครือ.....	18
2.8 วิธีการจัดองค์ประกอบแบบค่าสูงสุด-ต่ำสุด.....	19
2.9 วิธีการจัดองค์ประกอบแบบค่าสูงสุด-ผลคูณ	20
2.10 The Tsukamoto Fuzzy Model.....	22
2.11 การแปลงค่าความคลุมเครือเป็นค่าจริงทั่วไปด้วยวิธีถ่วงน้ำหนัก.....	23
2.12 ความแตกต่างของเครือข่ายประสาทในสมองมนุษย์และโครงข่ายประสาทเทียม.....	24
2.13 โครงข่ายประสาทเทียมแบบชั้นเดียว.....	25
2.14 โครงข่ายประสาทเทียมแบบหลายชั้น	25
2.15 โครงสร้างของ ANFIS ที่มีจำนวนอินพุต 1 ตัวแปร	26
2.16 โครงสร้างของ ANFIS ที่มีจำนวนอินพุต 2 ตัวแปร	27
2.17 โครงสร้างของ ANFIS ที่มีจำนวนอินพุต 3 ตัวแปร	27
3.1 แบบจำลองระบบการทำนายค่าความหนืดมูนีของยางคอมพาวด์	37
3.2 กราฟเกาส์เซียนแต่ละตัวแปรอินพุต.....	39
3.3 เงื่อนไขการอัปเดตฐานข้อมูลของแบบจำลอง	45
4.1 การเปรียบเทียบระหว่างค่าจริงและค่าการทำนายความหนืดมูนีจากโครงสร้าง ANFIS ที่มีจำนวนอินพุต 1 ตัวแปร ได้แก่ อุณหภูมิ รูปที่ 4.1 (ก) กระแสไฟฟ้า รูปที่ 4.1 (ข) และความดัน รูปที่ 4.1 (ค).....	48

สารบัญรูป (ต่อ)

รูป	หน้า
4.2 การเปรียบเทียบระหว่างค่าจริงและค่าการทำนายความหนืดมูนนี้จากโครงสร้าง ANFIS ที่มีจำนวนอินพุต 2 ตัวแปร ได้แก่ อุณหภูมิและกระแสไฟฟ้า รูปที่ 4.2 (ก) อุณหภูมิและความดัน รูปที่ 4.2 (ข) กระแสไฟฟ้าและความดัน รูปที่ 4.3 (ค).....	48
4.3 การเปรียบเทียบระหว่างค่าจริงและค่าการทำนายความหนืดมูนนี้จากโครงสร้าง ANFIS ที่มีจำนวนอินพุต 3 ตัวแปร ได้แก่ อุณหภูมิ กระแสไฟฟ้า และความดัน	49
4.4 ค่า RMSE การทำนายค่าความหนืดมูนนี้ของชุดข้อมูลสอนระบบที่มีเงื่อนไขที่ใช้ในการจำลองแตกต่างกัน ได้แก่ ค่าอินพุต ประเภทของการตีความ ที่จำนวนรอบการเรียนรู้.....	51
4.5 ค่า RMSE การทำนายค่าความหนืดมูนนี้ของชุดข้อมูลทดสอบระบบที่มีเงื่อนไขที่ใช้ในการจำลองแตกต่างกัน ได้แก่ ค่าอินพุต ประเภทของการตีความ ที่จำนวนรอบการเรียนรู้.....	52
4.6 ค่า RMSE การทำนายค่าความหนืดมูนนี้ที่ทดสอบโดยชุดข้อมูลที่เป็นตัวแทนสูตรยางเก่าและสูตรใหม่ โดยเปรียบเทียบการอัปเดตและไม่อัปเดตฐานข้อมูลด้วยข้อมูลที่ใช้ทดสอบในแต่ละครั้ง	53
4.7 การเปรียบเทียบระหว่างความหนืดมูนนี้ค่าจริงและค่าทำนายของชุดข้อมูลที่เป็นตัวแทนของสูตรใหม่และสูตรยางเก่าอย่างละครั้ง และประสิทธิภาพการทำนายในเชิงความถูกต้องและความแม่นยำ	55

TNI


TAHITI - NICHI INSTITUTE OF TECHNOLOGY

บทที่ 1

บทนำ

1.1 ที่มาและความสำคัญ

ยาง (Rubber) เป็นวัตถุดิบหลักที่จำเป็นต้องใช้ในทุกกลุ่มอุตสาหกรรมการผลิต สามารถพบเจอในชีวิตประจำวัน เช่น ยางล้อรถยนต์ ถุงมือยาง ท่อยาง และอื่นๆ โดยวัตถุดิบยางแบ่งออกเป็น 2 ประเภท ได้แก่ ยางธรรมชาติ (Natural Rubber) และยางสังเคราะห์ (Synthetic Rubber) ซึ่งอุตสาหกรรมในประเทศไทยมีการนำยางไปผลิตเป็นผลิตภัณฑ์มากมาย ไม่ว่าจะเป็นอุตสาหกรรมยานยนต์ อุตสาหกรรมเครื่องใช้ไฟฟ้าและอิเล็กทรอนิกส์ อุตสาหกรรมรองเท้า และอุตสาหกรรมอื่นๆ เป็นต้น เนื่องด้วยคุณสมบัติที่ยืดหยุ่นสูงของยางที่ดีกว่าโลหะและเซรามิก จึงตอบสนองต่อความต้องการผลิตภัณฑ์ที่ต้องการความยืดหยุ่นในการใช้งาน จากรูปที่ 1.1 แสดงถึงปริมาณการใช้อยางในการผลิตผลิตภัณฑ์ของแต่ละประเทศในปี พ.ศ.2561 ซึ่งประเทศไทยอยู่ในลำดับที่ 5 ของโลก อย่างไรก็ตามการนำยางไปผลิตเป็นผลิตภัณฑ์จำเป็นต้องมีการใส่สารเติมแต่งต่างๆ เช่น สารกระตุ้น (Activator) สารตัวเร่ง (Accelerator) สารคงรูป (Crosslinking Agent) และสารตัวเติม (Filler) เพื่อให้ยางเกิดการคงรูป (Cure) และได้สมบัติที่เหมาะสมกับการใช้งานนั้นๆ โดยเรียกกยางที่ผ่านการผสมสารเคมีต่างๆ ว่ายางคอมพาวด์ (Rubber Compound) เป็นยางที่พร้อมที่นำไปขึ้นรูปเป็นผลิตภัณฑ์ แต่ก่อนนำไปขึ้นรูปเป็นผลิตภัณฑ์ได้ ยางคอมพาวด์จะต้องผ่านการตรวจสอบคุณภาพเบื้องต้น ได้แก่ ความถ่วงจำเพาะ (Specific Gravity) ความหนืดมูนี (Mooney Viscosity) และลักษณะการวัลคาไนซ์ (Cure Characteristics) เป็นการยืนยันว่าแบทช์ยางคอมพาวด์ผ่านข้อกำหนดด้านคุณภาพตามที่ต้องการ ยางและสารเติมแต่งต่างๆ เกิดการกระจายตัว (Distribution) และแตกตัว (Dispersion) อย่างสม่ำเสมอ จากนั้นจึงนำไปขึ้นรูปเป็นผลิตภัณฑ์ที่มีรูปร่างต่างๆ ตามต้องการ แล้วทำให้อยางคอมพาวด์เกิดการวัลคาไนซ์ (Vulcanization) หรือสุกตัว เพื่อให้เกิดการคงรูปผลิตภัณฑ์




รูปที่ 1.1 ปริมาณการใช้ยางในการผลิตผลิตภัณฑ์ของประเทศไทย ในปี พ.ศ.2561

ปัจจุบันในการผลิตยางพาวด์การกำหนดสภาวะการผสม จะเริ่มจากห้องปฏิบัติการทำการทดลองเพื่อออกสูตรยาง และหาสภาวะที่เหมาะสมในการตั้งเครื่องจักรผสมยาง เพื่อให้ได้ยางคอมพาวด์ตามที่ต้องการ เครื่องผสมที่ใช้ในอุตสาหกรรมก็มีขนาดแตกต่างกันไปตั้งแต่ 35 ลิตร จนถึง 250 ลิตร เครื่องผสมระบบปิดแบบอินเตอร์มิกซ์ (Intermix Internal Mixer) หรืออินเตอร์เมซซิง (Intermeshing) และแบบแทนเจนต์เชียล (Tangential) ซึ่งความหนืดของยาง หรือความหนืดมูนี (Mooney Viscosity) เป็นค่าที่บ่งบอกถึงคุณภาพของการผสมยาง และความสามารถในการไหลหรือการเปลี่ยนรูปของยาง การหาค่าความหนืดมูนีสามารถทำได้โดยการใช้เครื่องมือนิวส์โคมิเตอร์ (Mooney Viscometer) ดังแสดงในรูปที่ 1.2 โดยค่าความหนืดมูนีคำนวณมาจากแรงบิดของแกนหมุน (Rotor) ที่ต้านทานกับยางที่บรรจุอยู่เต็มภายในห้องใส่ยาง ซึ่งตรวจวัดโดยโหลดเซลล์ (load cell) ดังแสดงในรูปที่ 3 ซึ่งใช้ระยะเวลาในการทดสอบ 5 นาทีต่อตัวอย่าง ก่อนนำยางคอมพาวด์ไปทดสอบค่าความหนืดมูนีโดยเครื่องมือนิวส์โคมิเตอร์ ควรพักยางหลังจากสิ้นสุดกระบวนการผสมอย่างน้อย 4 ชั่วโมง [1] ทั้งนี้ เพื่อให้ได้ผลการทดสอบที่แม่นยำ ด้วยเหตุนี้ระบบประกันคุณภาพจึงมีมาตรฐานในการตรวจสอบยางคอมพาวด์แต่ละสูตรที่แตกต่างไปตามความต้องการหรือความเคร่งเครียดทางด้านคุณภาพของผู้นำไปขึ้นรูป ทำให้ระบบประกันคุณภาพส่งผลต่อต้นทุนสินค้าด้วย อย่างไรก็ตามหากสามารถทำนายค่าความหนืดมูนีได้ทันทีที่สิ้นสุดกระบวนการผสม จะช่วยเพิ่มประสิทธิภาพระบบการผลิต ระบบการจัดการและระบบประกันคุณภาพ และมีต้นทุนสินค้าที่เท่าเดิมหรือลดลง



รูปที่ 1.2 เครื่องมูนีวิสโคมิเตอร์ (Mooney Viscometer)



รูปที่ 1.3 การทำงานของแกนหมุนภายในห้องบรรจุยาง

ปัจจุบันมีงานวิจัยศึกษาเกี่ยวกับการหาค่าความหนืดมูนีขณะผสมยาง ซึ่งแสดงผลแบบออนไลน์ที่เครื่องผสมยาง โดยหาค่าความหนืดมูนีจากวิธีการและแบบจำลองทางคณิตศาสตร์ เช่น โครงข่ายประสาทเทียม (Neural Networks, NN) วิธีกำลังสองน้อยที่สุดบางส่วน (Partial Least Squares Regression, PLS) การถดถอยของกระบวนการเกาส์เซียน (Gaussian Process Regression, GPR) และการถดถอยตามการเรียนรู้ของเคอร์เนล (Kernel Learning-Based Regression, KLR) เป็นต้น

งานวิจัยฉบับนี้เป็นการศึกษาการทำนายค่าความหนืดมูนีของยางคอมพาวด์หลังจากสิ้นสุดกระบวนการผสมยางจากเครื่องผสมระบบปิดแบบอินเตอร์มิกซ์ โดยระบบตรรกศาสตร์คลุมเครือโครงข่ายประสาทเทียม (Neuro-Fuzzy System) จากนั้นนำข้อมูลที่ได้เพิ่มเติมในอนาคต จากการตรวจสอบโดยเครื่องมูนีวิสโคมิเตอร์ มาป้อนกลับเข้าสู่ระบบ ผ่านการคัดเลือกข้อมูลแล้วจึงนำไปให้ระบบเรียนรู้และประมวลผลใหม่ ทำให้สามารถทำนายค่าความหนืดมูนีของยางคอมพาวด์ได้แม่นยำยิ่งขึ้นต่อไป

1.2 ความสำคัญของการวิจัย

สามารถนำแบบจำลองไปใช้ในการทำนายค่าความหนืดมูนี้ของยางคอมพาวด์เมื่อสิ้นสุดกระบวนการผสมในอุตสาหกรรม ซึ่งสามารถช่วยเพิ่มประสิทธิภาพระบบการจัดการ และคุณภาพ

1.3 วัตถุประสงค์ของการวิจัย

เพื่อออกแบบแบบจำลองสำหรับทำนายค่าความหนืดมูนี้ของยางคอมพาวด์ระบบอนุमानตรรกศาสตร์คลุมเครือโครงข่ายประสาทเทียมแบบปรับตัวได้

1.4 ขอบเขตของการวิจัย

งานวิจัยนี้เป็นการศึกษาผลของตัวแปรที่วัดจากเครื่องผสมระบบปิดแบบอินเตอร์มิกซ์ ได้แก่ ค่าอุณหภูมิ ค่ากระแสไฟฟ้าไฟ และค่าความดันที่จุดสิ้นสุดกระบวนการผสม ซึ่งส่งผลต่อค่าความหนืดมูนี้ของยาง โดยเลือกสูตรยางคอมพาวด์ที่มีการผลิตมากใช้ในการศึกษา จากนั้นออกแบบแบบจำลองสำหรับทำนายด้วยระบบอนุमानตรรกศาสตร์คลุมเครือโครงข่ายประสาทเทียมที่สามารถปรับตัวได้ตามข้อมูลเปลี่ยนแปลง

1.5 ผลที่คาดว่าจะได้รับ

ได้แบบจำลองที่สามารถทำนายค่าความหนืดมูนี้ของยางคอมพาวด์เมื่อสิ้นสุดกระบวนการ

1.6 แผนงานและระยะเวลาดำเนินการ

ตารางที่ 1.1 แผนงานและระยะเวลาในการดำเนินงาน

[illegible]

บทที่ 2

ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

2.1 หลักการพื้นฐาน

2.1.1 ผลิตภัณฑ์ยาง

การทำผลิตภัณฑ์ยาง ประกอบด้วยขั้นตอนต่างๆ ดังนี้ ยางดิบ การออกสูตร การผสม การขึ้นรูปร่าง และการทำให้ยางคงรูป เป็นต้น

ยางดิบ แบ่งออกเป็น 2 ประเภทหลักๆ ได้แก่ ยางธรรมชาติ และยางสังเคราะห์ โดยยางธรรมชาติได้มาจากต้นยาง *Hevea Braziliensis* ให้ผลผลิตเป็นน้ำยางสดที่มีเนื้อยางอยู่ 25-40% ขึ้นกับพันธุ์ต้นยางและฤดูกาลกรีต โดยยางธรรมชาติที่อยู่ในรูปของยางแท่ง มาจากการนำน้ำยางสดมาจับตัวด้วยกรด แล้วนำไปผ่านกระบวนการให้ความร้อนเพื่อทำให้ยางแท่งได้เป็นยางธรรมชาติที่อยู่ในรูปที่เป็นแผ่นหรือเรียกว่า ยางแผ่นรมควัน (Ribbed Rubber Smoke Sheet, RSS) และยางแผ่นผึ่งแห้ง (Air Dried Sheet Rubber, ADS) และยางธรรมชาติที่อยู่ในรูปก้อน เรียกว่า ยางแท่ง (Block Rubber, TTR or STR) ยางธรรมชาติที่อยู่ในรูปของยางน้ำ จากการนำน้ำยางสดมาผ่านกระบวนการปั่นเหวี่ยงเพื่อกำจัดน้ำและส่วนที่ไม่ใช่เนื้อยางออกไปจนกระทั่งเนื้อยางอยู่ประมาณ 60 เปอร์เซ็นต์ แล้วจึงเติมสารเคมีที่ป้องกันการเน่าและเพิ่มเสถียรภาพของน้ำยาง ก็จะได้เป็นน้ำยางข้น (High Concentrated Latex, 60% NR) ในส่วนของยางสังเคราะห์ ได้มาจากการเกิดปฏิกิริยาพอลิเมอร์ไรเซชัน (Polymerization) ของโมโนเมอร์ (Monomer) โดยการสังเคราะห์ยางจากมอนอเมอร์ชนิดเดียว เรียกว่า โฮโมพอลิเมอร์ (Homopolymer) และการสังเคราะห์ยางที่ประกอบไปด้วยมอนอเมอร์มากกว่าชนิดเดียว เรียกว่า โคพอลิเมอร์ (Copolymer) แบ่งออกได้เป็น 8 ชนิด ได้แก่ ยางพอลิไอโซพรีนชนิดสังเคราะห์ (Isoprene Rubber, IR) ยางสไตรีนบิวทาไดอีน (Styrene-Butadiene Rubber, SBR) ยางไนไตรล์ (Nitrile Rubber, NBR) ยางคลอโรพรีน (Chloroprene Rubber, CR) ยางบิวไทล์ (Butyl Rubber, IIR) ยางบิวทาไดอีน (Butadiene Rubber, BR) ยางเอทิลีนโพรพิลีนไดอีน (Ethylene-Propylene Diene Rubber, EPDM) และยางซิลิโคน (Silicone Rubber, Q) ซึ่งยางแต่ละชนิดมีคุณสมบัติที่เด่นแตกต่างกันไปดังสรุปในตารางที่ 2.1

ตารางที่ 2.1 คุณสมบัติเด่นของยางแต่ละชนิด

ประเภทของยาง	ชนิดของยาง	คุณสมบัติเด่น
ยางธรรมชาติ	ยางพารา หรือยางธรรมชาติ (Natural Rubber, NR)	มีสมบัติทางกลที่ดี และมีความยืดหยุ่นสูง
ยางสังเคราะห์	ยางพอลิไอโซพรีนชนิดสังเคราะห์ (Isoprene Rubber, IR)	คล้ายยางธรรมชาติ แต่มีคุณภาพสม่ำเสมอ กว่า
	ยางสไตรีนบิวทาไดอีน (Styrene-Butadiene Rubber, SBR)	มีสมบัติทางกลที่ดี และคงทนต่อการเสียดสี ที่ดี
	ยางไนไตรล์ (Nitrile Rubber, NBR)	มีสมบัติทนน้ำมันปิโตรเลียมและตัวทำ ละลายไม่มีขั้วได้ดีเยี่ยม
	ยางคลอโรพรีน (Chloroprene Rubber, CR)	มีสมบัติทนต่อสภาวะอากาศได้ดี และทนวง ไฟในตัวเอง
	ยางบิวไทล์ (Butyl Rubber, IIR)	ทนต่อสภาวะอากาศได้ดี มีความเป็นฉนวน และมีสมบัติการซึมผ่านของก๊าซที่ต่ำ
	ยางบิวทาไดอีน (Butadiene Rubber, BR)	มีสมบัติคงทนการเสียดสีที่ดีเยี่ยม และ รองรับการใช้งานอุณหภูมิติดลบได้ดี
	ยางเอทิลีนโพรพิลีนไดอีน (Ethylene-Propylene Diene Rubber, EPDM)	มีสมบัติทนกรด ด่าง และสารเคมีได้ดี และ คงทนต่อสภาวะอากาศดีเยี่ยม
	ยางซิลิโคน (Silicone Rubber, Q)	รองรับอุณหภูมิการใช้งานช่วงกว้าง ตั้งแต่ -40 ถึง 280 องศาเซลเซียส

อย่างไรก็ตามยางดิบแต่ละชนิดจะมีขีดจำกัดในการใช้งาน จึงไม่สามารถตอบโจทย์ความต้องการคุณสมบัติได้ครบในผลิตภัณฑ์ยาง จึงจำเป็นต้องมีการทำคอมพาวด์ของยางโดยการการเติมยางดิบอีกชนิด หรือสารเคมีชนิดต่างๆ เพื่อให้ได้คุณสมบัติตามที่ต้องการ

การออกสูตรยางเป็นการกำหนดส่วนผสมของของสูตรยาง เพื่อให้มีสมบัติครบตามที่ต้องการในการนำไปผลิตเป็นผลิตภัณฑ์นั้นๆ โดยทั่วไปการออกสูตรยางมี 5 องค์ประกอบหลัก ได้แก่ ยางดิบ (Rubbers) ซึ่งเป็นองค์ประกอบหลัก สารตัวเติม (Fillers) เพื่อเพิ่มความแข็งแรงหรือช่วยลดต้นทุน สารทำให้ยางคงรูป (Vulcanizing Agents) ทำให้เกิดโครงสร้างร่างแหเชื่อมโยงระหว่างโมเลกุล

ของยาง สารตัวเร่ง (Accelerators) เพื่อช่วยลดเวลาในการคงรูปของยาง และสารกระตุ้น (Activators) เพื่อกระตุ้นการทำงานของสารตัวเร่ง ส่วนองค์ประกอบอื่นๆ ได้แก่ พลาสติไซเซอร์ (Plasticizers) เพื่อเพิ่มความนิ่มให้ยาง สารต้านการเสื่อมสภาพ (Age Resisters) ช่วยป้องกันการเสื่อมสภาพจากยางที่เกิดปฏิกิริยากับโอโซน สารช่วยในการขึ้นรูป (Processing Aids) และสารเติมแต่งอื่นๆ เช่น สารสี สารหน่วงการติดไฟ เป็นต้น

การผสมยาง หรือการทำคอมพาวด์เป็นขั้นตอนที่มีความสำคัญมากเนื่องจากส่งผลต่อการนำไปขึ้นรูป คุณสมบัติ และคุณภาพของผลิตภัณฑ์ จุดประสงค์ของการผสม คือ การทำให้สารเติมแต่งต่างๆ เกิดการกระจายตัว (Distributive) และแตกตัวได้ดี (Dispersive) เครื่องผสมก็มีความสำคัญช่วยให้แรงเฉือนทำให้ยางเกิดการเปลี่ยนแปลงรูปร่าง สารตัวเติมเกิดการแตกตัวออกจากกัน และกระจายตัวในเนื้อยาง โดยเครื่องผสมยางแบ่งออกเป็น 2 ประเภท ได้แก่ เครื่องผสมยางแบบไม่ต่อเนื่องหรือแบบแบทช์ (Batch Mixer) ซึ่งแบ่งได้เป็น 2 ระบบ คือ ระบบเปิด เครื่องผสมยางแบบ 2 ลูกกลิ้ง (Two-Roll Mill) และระบบปิด แบ่งตามลักษณะของโรเตอร์ ออกเป็น 4 แบบ ได้แก่ เครื่องผสมระบบปิดแบบบูรี่ (Banbury Internal Mixer) เครื่องผสมระบบปิดแบบอินเตอร์มิกซ์ (Intermix Internal Mixer) เครื่องผสมระบบปิดแบบที่ปรับระยะห่างระหว่างโรเตอร์ได้ (Variable Intermeshing Clearance Internal Mixer) และเครื่องผสมระบบปิดอื่นๆ เช่น เครื่องนวดยางหรือนีดเดอร์ (Kneader) เครื่องผสมยางแบบต่อเนื่อง (Continuous Mixer) ได้แก่ เครื่องผสมแบบเกลียวหนอนเดี่ยว (Single Screw) และเครื่องผสมแบบเกลียวหนอนคู่ (Twin Screw) เป็นต้น

ปัจจัยที่มีผลต่อคุณภาพของยางคอมพาวด์และประสิทธิภาพของการผสม ได้แก่

- ความเร็วรอบของแกนหมุน ส่งผลต่อความเครียดเฉือนและอัตราการเปลี่ยนรูป
- ประสิทธิภาพของการหล่อเย็น เนื่องจากในผสมจะเกิดความร้อนขึ้น หากสูงมาก

จะทำลายสมบัติของยางเพิ่มความเสี่ยงต่อการทำให้ยางตายและประสิทธิภาพของการบดยางลดลง แต่ถ้าหล่อเย็นมากเกินไป จะทำให้การผสมมีประสิทธิภาพไม่เพียงพอ ทำให้การกระจายของสารเติมแต่งในยางไม่ดี

- ความดันของแกนกด ทำหน้าที่กดให้ของผสมต่างๆ อยู่ในช่องบรรจุ ช่วยให้ฟองอากาศที่อยู่ในของผสมลดลงและลดการลื่นระหว่างยางกับพื้นผิวแกนหมุน
- ขนาดของแบทช์ โดยทั่วไป ปัจจัยการเติม (Fill Factor) ที่ประมาณ 70-80% หากมีขนาดของแบทช์ที่น้อยเกินไป จะไม่มีความดันกดวัสดุในเครื่องผสม ทำให้คอมพาวด์ไม่ผ่านบริเวณที่มีความเค้นเฉือนที่สูง แต่หากแบทช์มีขนาดใหญ่เกินไป แกนกดไม่สามารถเข้าไปในช่องบรรจุวัสดุ ทำให้สารเติมแต่งที่เป็นผงสะสมอยู่ที่ช่องเปิดของช่องบรรจุส่งผลต่อประสิทธิภาพการผสม

• ลำดับขั้นการผสม (Mixing Step) ลำดับการเติมแต่งต่างๆ ต้องเป็นขั้นตอนอย่างถูกต้อง ขั้นแรกควรเติมสารเติมแต่งเพื่อให้เกิดกระจายตัวในยางก่อน เนื่องจากยางที่อุณหภูมิต่ำ ยางยังมีความหนืดสูง เกิดการเนียนได้มาก จากนั้นเติมสารอื่นๆ และน้ำมัน สารที่ให้เติมสุดท้าย คือ สารตัวเร่งและกำมะถัน

การขึ้นรูป เครื่องมือที่ใช้ในการกำหนดรูปร่างของผลิตภัณฑ์ยาง มี 2 อย่าง ได้แก่ แม่พิมพ์ ซึ่งสามารถกำหนดรูปร่างผลิตภัณฑ์ได้ทั้ง 3 มิติ เช่น พื้นรองเท้า ยางล้อรถยนต์ และลูกบาสเก็ตบอล เป็นต้น และหัวอัดรีด สามารถกำหนดรูปร่างหน้าตัดของผลิตภัณฑ์ยางที่เป็นแบบเส้นยาง เช่น ยางปิดน้ำฝน ยางขอบประตูรถยนต์ และยางซิลิโคนต่างๆ เป็นต้น

การทำให้ยางคงรูป เป็นเปลี่ยนสถานะของยางคอมพาวด์ที่เป็นของไหล เป็นยางคงรูปที่มีสถานะเป็นของแข็ง ซึ่งเกิดจากการให้ความร้อนและการทำงานของสารทำให้ยางคงรูปทำให้โมเลกุลของยางเกิดพันธะเคมีเชื่อมโยงกันเป็นโครงสร้างร่างแห (Crosslink) ทำให้ยางเกิดการคงรูปเป็นผลิตภัณฑ์


จากขั้นตอนการผลิตทั้งหมดนี้ ในทางอุตสาหกรรมจะมีระบบประกันคุณภาพในทุกขั้นตอน สามารถสอบทวนได้ตลอดทุกขั้นตอนการผลิต ทั้งนี้เพื่อให้ได้ผลิตภัณฑ์ที่มีคุณภาพเป็นไปตามมาตรฐานที่กำหนด ซึ่งนิยมใช้สมบัติค่าความหนืดของยาง หรือค่าความหนืดมูนนี่ ในการดูคุณภาพแต่ละขั้นตอน เนื่องจากเป็นค่าบ่งบอกถึงความง่ายในการผสม และการนำไปขึ้นรูปเป็นผลิตภัณฑ์ ดังนั้นจึงนิยมใช้ตั้งแต่ขั้นตอนยางดิบ หาค่าความหนืดของยางเพื่อนำไปใช้ขั้นตอนการออกสูตร จึงช่วยในการเลือกสารเคมีและสารเติมแต่งที่เหมาะสมกับยางดิบ ขั้นตอนการผสม ช่วยในการเลือกเครื่องผสมและการใช้เทคนิคในการผสมเพื่อให้ได้ยางคอมพาวด์ที่มีคุณภาพที่สม่ำเสมอ ขั้นตอนการนำไปขึ้นรูป ช่วยในการเลือกเครื่องมือขึ้นรูปที่เหมาะสมกับความหนืดมูนนี่หรือพฤติกรรมการไหลของยางคอมพาวด์ เพื่อให้เกิดการคงรูปเป็นผลิตภัณฑ์ที่มีรูปร่างตามที่ต้องการ การตรวจสอบค่าความหนืดของยาง หรือค่าความหนืดมูนนี่ โดยเครื่องมือนี้วิสกิเมตรเป็นเครื่องวัดความหนืดของยางดิบ (Raw Rubber) และยางคอมพาวด์ ประกอบด้วยแกนหมุน (Rotor) ซึ่งหมุนอยู่ในช่องว่างระหว่างดาย 2 อัน คือ ดายบน (Upper Die) และดายล่าง (Lower Die) ด้วยความเร็วคงที่ อุณหภูมิและความดันที่กำหนด การหมุนของแกนหมุนทำให้เกิดแรงบิด (Torque) เนื่องจากแรงเฉือนระหว่างยางและแกนหมุนภายในห้องใส่ยาง ขับให้สปริงรูปตัวยูเกิดการเคลื่อนที่ โหลดเซลล์ตรวจวัดขนาดการเคลื่อนที่แสดงผลออกมาเป็นค่าความหนืดมูนนี่ Mooney Units (MU) หรือ Mooney Viscosity (MV) ลักษณะของแกนหมุนจะมีลักษณะเป็นร่อง เพื่อป้องกันการลื่นไถลของยางและแกนหมุน แกนหมุนที่ใช้วัดความหนืดของยางมีอยู่ 2 ขนาด คือ ขนาดใหญ่มีเส้นผ่าศูนย์กลาง 1.5 นิ้ว มีความหนา 0.2 นิ้ว และขนาดเล็กมีเส้นผ่าศูนย์กลาง 1.2 นิ้ว มีความหนา 0.2 นิ้ว ใช้กับยางที่มีความหนืดสูงมากกว่า 200 หน่วย ความเร็วรอบแกนหมุนโดยประมาณ 2 รอบต่อนาที (rpm) อุณหภูมิและเวลาที่ใช้ในการทดสอบความหนืดของยางด้วย

เครื่องวัดความหนืดมูนนี่ของยาง ตามมาตรฐาน ASTM D1646-2004 ซึ่งยางแต่ละชนิดก็มีการใช้อุณหภูมิและเวลาในการทดสอบที่แตกต่างกัน ดังที่แสดงในตารางที่ 2.2

ตารางที่ 2.2 อุณหภูมิและระยะเวลาในการหมุนของแกนหมุนที่ใช้ในการทดสอบยาง

ชนิดของยาง	อุณหภูมิ (องศาเซลเซียส)	ระยะเวลาในการหมุนของแกนหมุน (นาที)
ยางธรรมชาติ (NR) ยางครอโรพรีน (CR) ยางยางไนไตรล์ (NBR) ยางพอลิบูทาไดอิน (BR) ยางไอโซพรีน (IR) ยางสไตรีนบูทาไดอิน (SBR)	100 ± 0.5	4
ยางบิวไทล์ (IIR)	100 ± 0.5 125 ± 0.5 (ยางที่มีความหนืดมูนนี่สูงกว่า 60 หน่วย)	8
ยางยางเออีลีนโพรพิลีนไดอิน (EPDM)	125 ± 0.5	4


ค่าที่ได้จากการอ่านจากเครื่องมูนนี่วิสโคมิเตอร์จะอยู่ในรูปของสมการ $ML(100)1+4$ เท่ากับ ค่าที่อ่านได้ในหน่วยมูนนี่ (Mooney Unit) โดย ML หมายถึง แกนหมุนขนาดใหญ่ 100 หมายถึง อุณหภูมิที่ใช้ในการทดสอบ 100 องศาเซลเซียส ตัวเลข 1 หมายถึง เวลาที่ให้ความร้อน 1 นาที โดยที่ แกนหมุนยังไม่หมุน (Preheat Time) ตัวเลข 4 หมายถึง การหมุนแกนหมุนไป 4 นาที ด้วยความเร็วรอบประมาณ 2 รอบต่อนาที กราฟความหนืดมูนนี่แสดงในรูปที่ 2.1



รูปที่ 2.1 กราฟความหนืดมูนนี่ที่ได้จากเครื่องมูนนี่วิสโคมิเตอร์

ระบบสายการผลิตยางพาวด์ที่นิยมใช้ในอุตสาหกรรม แสดงดังรูปที่ 2.2 ประกอบด้วย ขั้นตอนการป้อนวัตถุดิบ ขั้นตอนการผสมโดยเริ่มจากเครื่องผสมภายในซึ่งทำให้เกิดการกระจายตัว และการแตกตัวของยางดิบและสารเคมี ใช้เวลาประมาณ 5 ถึง 10 นาที ขึ้นอยู่กับการออกสูตรยาง และเทคนิคการผสม จากนั้นเทยางคอมพาวด์ลงสู่เครื่องผสมสองลูกกลิ้งช่วย ซึ่งเพิ่มการแตกตัวที่ดี ใช้เวลาประมาณ 1 นาที นำไปผ่านเครื่องรีดแผ่น เครื่องหล่อเย็น แล้วบรรจุลงหีบห่อ เป็นต้น หลังจากเสร็จสิ้นกระบวนการผสมในแต่ละแบตช์ ระบบประกันคุณภาพทำการสุ่มเก็บตัวอย่างยางคอมพาวด์ ตามมาตรฐาน เพื่อนำไปตรวจสอบคุณภาพว่ายางคอมพาวด์มีการผสมที่ดีและผ่านเกณฑ์มาตรฐาน โดยหลักๆ จะตรวจสอบจาก 3 อย่าง ได้แก่


- การกระจายตัว โดยการนำยางคอมพาวด์ไปรีดให้มีความหนาตามมาตรฐาน แล้วนำไปส่องดูการกระจายตัวและความสม่ำเสมอในเนื้อยางคอมพาวด์โดยกล้องจุลทรรศน์ (Microscope) โดยความถี่ในการตรวจสอบ คือ ทุกแบตช์ยางคอมพาวด์
- ความถ่วงจำเพาะของยางคอมพาวด์ โดยเครื่องวัดความหนาแน่น และความถ่วงจำเพาะ (Densimeter) โดยความถี่ในการตรวจสอบ คือ ทุกแบตช์ยางคอมพาวด์
- ความหนืดมูนนี้ของยางคอมพาวด์ หลังจากเสร็จสิ้นกระบวนการผสมควรพักยางคอมพาวด์อย่างน้อย 4 ชั่วโมง ก่อนนำไปทดสอบ เนื่องจากการปล่อยให้ยางคลายความเครียด และอุณหภูมิลดลง ในการทดสอบหาค่าความหนืดมูนนี้จะต้องทำการทดสอบอย่างน้อย 3 ครั้ง นำมาหาค่าเฉลี่ยได้เป็นค่าความหนืดมูนนี้ของยางคอมพาวด์แบตช์นั้น ดังนั้นจึงใช้เวลานานในการตรวจสอบความถี่ในการตรวจสอบในนิยมนุ่ม 1 ใน 5 แบตช์ยางคอมพาวด์




รูปที่ 2.2 ระบบสายการผลิตยางพาวด์ที่นิยมใช้ในอุตสาหกรรม

การผสมยางโดยเครื่องผสมภายในซึ่งเป็นเครื่องผสมระบบปิด แสดงดังรูปที่ 2.3 มีประสิทธิภาพดีกว่าเครื่องผสมที่เป็นระบบเปิด ประกอบด้วยช่องบรรจุ (Chamber) และภายในช่องบรรจุมีแกนหมุน (Rotor) 2 อัน ซึ่งหมุนเข้าหากันเป็นตัวทำให้เกิดแรงเฉือน สามารถปรับความเร็วรอบ

ของแกนหมุนได้ มีจอภาพแสดงผลตลอดการทำงานของเครื่อง เช่น ค่าแรงบิด ค่ากระแสไฟฟ้า อุณหภูมิ ความดัน ความเร็วของแกนหมุน ระยะของแกนกด และอื่นๆ โดยจะทำการตรวจวัดและแสดงผลการเปลี่ยนแปลงของพารามิเตอร์ต่างๆ ในแต่ละวินาที ในส่วนของเครื่องผสมชนิดสองลูกกลิ้งระบบเปิด แสดงในรูปที่ 2.3 ประกอบด้วยลูกกลิ้ง 2 อัน วางขนานกัน สามารถปรับระยะห่างและความเร็วได้ มีระบบการหล่อเย็นจากการไหลเข้าออกของน้ำภายในลูกกลิ้ง



รูปที่ 2.3 เครื่องผสมภายในระบบปิด



รูปที่ 2.4 เครื่องผสมระบบเปิดชนิดสองลูกกลิ้ง


2.1.2 ระบบตรรกศาสตร์คลุมเครือโครงข่ายประสาทเทียม

ปัจจุบันประเทศไทยก้าวสู่อุตสาหกรรม 4.0 ที่ขับเคลื่อนด้วยความรู้และเทคโนโลยีขั้นสูงความคิดสร้างสรรค์ นวัตกรรม และการเชื่อมต่อเครือข่ายในรูปแบบ IoT (Internet of Things) เทคโนโลยีปัญญาประดิษฐ์ (Artificial Intelligence, AI) เริ่มเข้ามามีบทบาทและถูกนำมาใช้ในอุตสาหกรรมมากขึ้น เช่น อุตสาหกรรมการผลิต การแพทย์ การเกษตร งานก่อสร้าง ระบบการขนส่งสาธารณะ การเงิน การธนาคาร ประกันภัย และอื่น ๆ เป็นต้น เนื่องจากช่วยให้งานผลิตสำเร็จได้เร็วขึ้น การควบคุมคุณภาพ ประหยัดค่าใช้จ่าย และสามารถนำข้อมูลที่มีประโยชน์มาต่อยอดให้เกิดมูลค่าทางธุรกิจที่สูงขึ้นได้ มีข้อมูลที่เกิดขึ้นใหม่ทุกวันในแต่ละอุตสาหกรรมที่สามารถเกิดเป็นคลังข้อมูลขนาดใหญ่ (Big


Data) การทำงานร่วมกันระหว่างปัญญาประดิษฐ์และมนุษย์ในการนำคลังข้อมูลขนาดใหญ่มาใช้ให้เกิดประโยชน์ โดยผ่านการนำไปวิเคราะห์ และประมวลผลออกมา จะช่วยในการดึงศักยภาพได้อย่างมีประสิทธิภาพยิ่งขึ้น ระบบอนุมานตรรกศาสตร์คลุมเครือโครงข่ายปรับตัวได้ (Adaptive Neuro-Fuzzy Network Model, ANFIS) เป็นส่วนหนึ่งของปัญญาประดิษฐ์ มีกระบวนการทำงานเลียนแบบการคิด การหาเหตุผล การตัดสินใจ และการกระทำของมนุษย์ โดยมีการทำงาน 2 เครื่องมือ ได้แก่ ตรรกศาสตร์แบบคลุมเครือ (Fuzzy Logic) และโครงข่ายประสาทเทียม (Neural Networks, NN)

2.1.2.1 ตรรกศาสตร์แบบคลุมเครือ (Fuzzy Logic) [2]

เป็นเครื่องมือช่วยตัดสินใจภายใต้ความไม่แน่นอน (Uncertainty) ของข้อมูล ที่อาจเกิดจากปัจจัยบางอย่าง เช่น การมีข้อมูลไม่เพียงพอ ข้อมูลที่มาจากการประมาณการ และข้อมูลขาดความน่าเชื่อถือ เป็นต้น มีหลักเหตุผลที่คล้ายการเลียนแบบวิธีคิดที่ซับซ้อนของมนุษย์ จึงมีความยืดหยุ่นมากกว่าตรรกศาสตร์แบบดั้งเดิม หรือบูลีนลอจิก (Boolean Logic) ที่มีการตัดสินใจในรูปแบบเป็นจริงหรือเป็นเท็จ ในขณะที่ตรรกศาสตร์คลุมเครือเป็นส่วนที่เข้าไปขยายระหว่างจริงกับเท็จ โดยบอกเป็นระดับที่อยู่ในช่วง 0 ถึง 1 เป็น ดังแสดงในรูปที่ 2.5 และจากรูปที่ 2.6 แสดงถึงโครงสร้างการประมวลผลของตรรกศาสตร์คลุมเครือแบ่งออกเป็น 4 ส่วนสำคัญ ได้แก่



รูปที่ 2.5 การเปรียบเทียบระหว่างตรรกศาสตร์บูลีน และตรรกศาสตร์คลุมเครือ






รูปที่ 2.6 โครงสร้างของการประมวลผลแบบตรรกศาสตร์คลุมเครือ

1) ส่วนการแปลงข้อมูลให้เป็นความคลุมเครือ (Fuzzification)




เป็นการแปลงข้อมูลอินพุต (Input Data) ที่อยู่ในรูปของเซตแบบดั้งเดิม (Crisp Set) ที่มีค่าเป็น 0 และ 1 ให้อยู่ในรูปของความคลุมเครือหรือในรูปแบบความคลุมเครือเซต (Fuzzy Set) ที่มีดีกรีของความเป็นสมาชิก (Degree of Membership) มีค่าอยู่ระหว่าง 0 ถึง 1 ซึ่งบอกถึงความไม่แน่นอนของการมีค่าความเป็นสมาชิกเซต จากนั้นกำหนดระดับความเป็นสมาชิกในเซตให้อยู่ในรูปของฟังก์ชันสมาชิก (Membership Function) จากการการออกแบบ ใช้ความรู้ประสบการณ์ และความเชี่ยวชาญ กำหนดให้อยู่ในรูปของฟังก์ชันสมาชิกที่มีความสัมพันธ์ในทางคณิตศาสตร์ที่มีชนิดของฟังก์ชันความเป็นสมาชิกหลายรูปแบบตามแสดงในตารางที่ 2.3





ตารางที่ 2.3 ฟังก์ชันสมาชิกรูปแบบต่างๆ

ฟังก์ชัน	กราฟความสัมพันธ์	สมการความสัมพันธ์	จำนวนสมาชิก
สามเหลี่ยม (Triangular Membership Function)		$f(x; a, b, c) = \begin{cases} 0, & x \leq a \\ \frac{x-a}{b-a}, & a \leq x \leq b \\ \frac{c-x}{c-b}, & b \leq x \leq c \\ 0, & c \leq x \end{cases}$	มีพารามิเตอร์ 3 ค่า ได้แก่ a b และ c
สี่เหลี่ยมคางหมู (Trapezoidal Membership Function)		$f(x; a, b, c, d) = \begin{cases} 0, & x \leq a \\ \frac{x-a}{b-a}, & a \leq x \leq b \\ 1, & b \leq x \leq c \\ \frac{d-x}{d-c}, & c \leq x \leq d \\ 0, & d \leq x \end{cases}$	มีพารามิเตอร์ 4 ค่า ได้แก่ a b c และ d
เกาส์เซียน (Gaussian Membership Function)		$f(x; \sigma, c) = e^{\frac{-(x-c)^2}{2\sigma^2}}$	มีพารามิเตอร์ 2 ค่า ได้แก่ σ และ c

ตารางที่ 2.3 ฟังก์ชันสมาชิกรูปแบบต่างๆ (ต่อ)

ฟังก์ชัน	กราฟความสัมพันธ์	สมการความสัมพันธ์	จำนวนสมาชิก
ระฆังคว่ำ (Bell-Shaped Membership Function)		$f(x;a,b,c) = \frac{1}{1 + \left \frac{x-c}{a} \right ^{2b}}$	มีพารามิเตอร์ 3 ค่า ได้แก่ a b และ c
ตัวเอส (Smooth Membership Function)		$f(x;a,b) = \begin{cases} 0, x \leq a \\ 2\left(\frac{x-a}{b-a}\right)^2, a \leq x \leq \frac{a+b}{2} \\ 1-2\left(\frac{x-a}{b-a}\right)^2, \frac{a+b}{2} \leq x \leq b \\ 1, x \geq b \end{cases}$	มีพารามิเตอร์ 2 ค่า ได้แก่ a และ b
ตัวแซด (Z-Membership Function)		$f(x;a,b) = \begin{cases} 1, x \leq a \\ 1-2\left(\frac{x-a}{b-a}\right)^2, a \leq x \leq \frac{a+b}{2} \\ 1-2\left(\frac{x-a}{b-a}\right)^2, \frac{a+b}{2} \leq x \leq b \\ 0, x \geq b \end{cases}$	มีพารามิเตอร์ 2 ค่า ได้แก่ a และ b

ตารางที่ 2.3 ฟังก์ชันสมาชิกรูปแบบต่างๆ (ต่อ)


ฟังก์ชัน	กราฟความสัมพันธ์	สมการความสัมพันธ์	จำนวนสมาชิก
ตัวพาย (Π-Shaped Membership Function)		$f(x; \sigma, c) = \begin{cases} 0, & x \leq a \\ 2\left(\frac{x-a}{b-a}\right)^2, & a \leq x \leq \frac{a+b}{2} \\ 1-2\left(\frac{x-b}{b-a}\right)^2, & \frac{a+b}{2} \leq x \leq b \\ 1, & b \leq x \leq c \\ 1-2\left(\frac{x-c}{d-c}\right)^2, & c \leq x \leq \frac{c+d}{2} \\ 2\left(\frac{x-d}{d-c}\right)^2, & \frac{c+d}{2} \leq x \leq d \\ 0, & x \geq d \end{cases}$	มีพารามิเตอร์ 4 ค่า ได้แก่ a b c และ d
ซิกมอยด์ (Sigmoidal Membership Function)		$f(x; a, c) = \frac{1}{1 + e^{-a(x-c)}}$	มีพารามิเตอร์ 2 ค่า ได้แก่ a b และ c

2) ส่วนฐานความรู้ (Knowledge Base)

เป็นส่วนที่เก็บข้อมูลทั้งหมด แบ่งออกเป็น 2 ส่วน ได้แก่ ฐานกฎ (Rule Base) และฐานข้อมูล (Data Base) ฐานกฎ คือส่วนที่การกำหนดกฎหรือเงื่อนไขที่ใช้ในจำลองการตัดสินใจให้กับระบบจากความสัมพันธ์ ถ้า (If) และส่วนของ แล้ว (Then) เช่น ค่าเงื่อนไขใน If อินพุตทั้งหมดจะมีค่าระดับความคลุมเครือ และในส่วนของ Then จะถูกประเมินค่าด้วยค่าระดับความเป็นสมาชิก ทุกเงื่อนไขในส่วนของ If จะถูกประเมินพร้อมๆ กันแล้วเกิดการเชื่อมโยงกันของฐานข้อมูล เช่น And หรือ Or ในส่วนฐานข้อมูล เป็นการจัดเตรียมส่วนที่จำเป็นเพื่อที่จะใช้ในการกำหนดกฎและจัดการข้อมูลของตรรกศาสตร์คลุมเครือ

3) ส่วนของการอนุมานหรือตีความ (Inference Engine)

เป็นส่วนที่ทำหน้าอนุมานผลลัพธ์ที่มาจากการตัดสินใจของระบบพิจารณา ร่วมกับกฎการทำงานที่สอดคล้องกับเงื่อนไขดังกล่าว โดยมีกฎการอนุมานความคลุมเครือ 3 แบบ ได้แก่ รูปแบบ Mamdani รูปแบบ Takagi-Sugeno-Kang (TSK) และรูปแบบบวกมาตรฐาน (Standard Additive Model, SAM) ตามที่แสดงในรูปที่ 2.7



รูปที่ 2.7 รูปแบบการอนุมานแบบตรรกศาสตร์คลุมเครือ

- รูปแบบ Mamdani กำหนดให้ข้อมูลอินพุตได้ 2 ตัวแปร (x_1 และ x_2) และเอาต์พุต 1 ตัวแปร (y) มีกฎความคลุมเครือเป็น

$$\text{IF } x_1 \text{ is } A_{k1} \text{ and } x_2 \text{ is } A_{k2} \text{ THEN } y \text{ is } B_k \quad (2.1)$$

โดย $k = 1, 2, \dots, r$

เมื่อ A_{ki} เป็นพจน์ภาษาของข้อตั้ง (Consequence Linguistic Term) หรือเป็นฟังก์ชันความเป็นสมาชิกของข้อตั้ง (Antecedent Membership Function) ในกฎที่ $i = 1, 2, \dots, L$

B_k เป็นผลที่ตามมาของกฎนั้นๆ


ผลรวมเอาต์พุตหาได้ โดยใช้วิธีการจัดองค์ประกอบแบบค่าสูงสุด-ต่ำสุด (Max-Min Composition) และวิธีการจัดองค์ประกอบแบบค่าสูงสุด-ผลคูณ (Max-Product Composition)

วิธีการจัดองค์ประกอบแบบค่าสูงสุด-ต่ำสุด

$$\mu_{B_k}(y) = \max[\min(\mu_{A_{k1}}(\text{input}(i), \mu_{A_{k1}}(\text{input}(j)))] \quad (2.2)$$

โดย $k = 1, 2, \dots, r$

เมื่อ μ_{ki} คือ ฟังก์ชันความเป็นสมาชิกของข้อในกฎที่ $i = 1, 2, \dots, L$




รูปที่ 2.8 วิธีการจัดองค์ประกอบแบบค่าสูงสุด-ต่ำสุด

วิธีการจัดองค์ประกอบแบบค่าสูงสุด-ผลคูณ

$$\mu_{B_k}(y) = \max[\mu_{A_{k1}}(\text{input}(i)) \cdot \mu_{A_{k2}}(\text{input}(j))] \quad (3.3)$$

เมื่อ $k = 1, 2, \dots, r$



รูปที่ 2.9 วิธีการจัดองค์ประกอบแบบค่าสูงสุด-ผลคูณ

- รูปแบบ Takagi-Sugeno-Kang (TSK) จะอยู่ในรูป

กฎที่ 1 : IF (x_1 is A_{11}) AND (x_2 is A_{12}) AND ... AND (x_n is A_{1n})

THEN $y_1 = f_1(x_1, x_2, \dots, x_n) = b_{10} + b_{11}x_1 + \dots + b_{1n}x_n$

กฎที่ 2 : IF (x_1 is A_{21}) AND (x_2 is A_{22}) AND ... AND (x_n is A_{2n})

THEN $y_2 = f_2(x_1, x_2, \dots, x_n) = b_{20} + b_{21}x_1 + \dots + b_{2n}x_n$

กฎที่ L : IF (x_1 is A_{L1}) AND (x_2 is A_{L2}) AND ... AND (x_n is A_{Ln})

THEN $y_i = f_L(x_1, x_2, \dots, x_n) = b_{L0} + b_{L1}x_1 + \dots + b_{Ln}x_n$

เมื่อ x_j เป็นตัวประกอบที่ j ของตัวแปรอินพุต x โดย $j = 1, 2, \dots, n$

y เป็นตัวแปรเอาต์พุต

A_{ij} เป็นพจน์ภาษาของข้อตั้ง (Consequence Linguistic Term) หรือเป็นฟังก์ชัน

ความเป็นสมาชิกของข้อตั้ง (Antecedent Membership Function) ในกฎที่ $i = 1, 2, \dots, L$

f_i เป็นสมการเชิงเส้นของข้อตาม (Consequent Linear Function) ของกฎข้อที่ i ค่าเอาต์พุตของแต่ละกฎหาได้จากสมการ

$$y_i = b_{i0} + b_{i1}x_1 + \dots + b_{in}x_n \quad (2.4)$$

ค่าเอาต์พุตของระบบเป็นผลรวมจากเอาต์พุตจากกฎแต่ละข้อโดยใช้สมการ

$$y = \frac{\sum_{i=1}^L \alpha_i \cdot y_i}{\sum_{i=1}^L \alpha_i} \quad (2.5)$$

เมื่อ L คือ ค่าตั้งแต่ตำแหน่งที่ 1 ถึงตำแหน่งที่ i

y_i คือ ค่าความคลุมเครือของเอาต์พุตในเซตความคลุมเครือตำแหน่งที่ i

α_i คือ พื้นที่ใต้โค้งของความคลุมเครือตำแหน่งที่ i

• รูปแบบมาตรฐาน (Standard Additive Model, SAM) คล้ายกับระบบตรรกศาสตร์คลุมเครือของ Mamdani แต่ส่วนของข้อตามของกฎตรรกศาสตร์คลุมเครือจะแสดงในรูปความคลุมเครือเซตซึ่งมีฟังก์ชันสมาชิกแบบทางเดียว (Monotonic Membership Function) ตามที่แสดงในรูปที่ 2.10 ค่าเอาต์พุตทั้งหมดสามารถหาได้จากค่าเฉลี่ยน้ำหนักของเอาต์พุตจากแต่ละกฎจากสมการ


$$z = \frac{\sum_{i=1}^L w_i \cdot z_i}{\sum_{i=1}^L w_i} \quad (2.6)$$

เมื่อ L คือ ค่าตั้งแต่ตำแหน่งที่ 1 ถึงตำแหน่งที่ i

z_i คือ ค่าความคลุมเครือของเอาต์พุตในเซตความคลุมเครือตำแหน่งที่ i

w_i คือ พื้นที่ใต้โค้งของความคลุมเครือตำแหน่งที่ i

โดยค่าเอาต์พุตที่ได้เป็นข้อมูลทั่วไปแล้ว ไม่ต้องผ่านการแปลงให้เป็นข้อมูลทั่วไปก่อนส่งออก จึงเป็นรูปแบบที่รวดเร็วและประหยัดเวลามากขึ้น



รูปที่ 2.10 The Tsukamoto Fuzzy Model

4) ส่วนที่แปลงให้เป็นข้อมูลทั่วไปก่อนส่งออก (Defuzzification)


เป็นการแปลงค่าความคลุมเครือให้เป็นค่าจริงหรือข้อมูลทั่วไปก่อนส่งออก ไปเป็นข้อมูลเอาต์พุต (Output Data) ที่เป็นผลลัพธ์มนุษย์เข้าใจและนำไปใช้งานต่อไป โดยการทางคณิตศาสตร์ทำได้จากวิธีเฉลี่ยถ่วงน้ำหนัก (Weighted Average Method) หรือวิธีหาค่าพื้นที่กลาง (Centroid) ตามที่แสดงในรูปที่ 2.11 โดยการหาค่าจากพื้นที่ใต้กราฟของความคลุมเครือซึ่งเป็นผลที่ได้จากการอนุมาน ค่าที่ได้จะประมาณเทียบเคียงค่าจุดศูนย์ถ่วงโดยรวม (Central of Gravity, COG) เป็นวิธีการเฉลี่ยผลที่ได้จากการตีความหาเหตุผลที่นิยมใช้ในปัจจุบัน ค่าที่ได้จะคำนวณจุดศูนย์ถ่วงโดยรวมจะหาได้จากการประมาณค่าจากสมการ

$$COG = \frac{\sum_{i=1}^L \alpha_i \cdot w_i}{\sum_{i=1}^L \alpha_i} \quad (2.7)$$

เมื่อ N คือ ค่าตั้งแต่ตำแหน่งที่ 1 ถึงตำแหน่งที่ i

α_i คือ ค่าความคลุมเครือของเอาต์พุตในเซตความคลุมเครือตำแหน่งที่ i

w_i คือ พื้นที่ใต้กราฟความคลุมเครือตำแหน่งที่ i




รูปที่ 2.11 การแปลงค่าความคลุมเครือเป็นค่าจริงทั่วไปด้วยวิธีถ่วงน้ำหนัก

2.1.2.2 โครงข่ายประสาทเทียม (Artificial Neural Network : ANN)

เป็นแบบจำลองทางคณิตศาสตร์ มีรูปแบบโครงสร้างและการทำงานของ การประมวลผลเหมือนกับสมองของสิ่งมีชีวิตตามที่แสดงดังรูปที่ 2.12 ซึ่งเป็นเครื่องมือที่มีความสามารถในการเรียนรู้และการจดจำรูปแบบจากการที่โครงข่ายปรับเปลี่ยนตัวเองต่อการตอบสนองของอินพุต ตามกฎของการเรียนรู้ (Learning Rule) ที่มาจากการคิดค้นของมนุษย์ การประมวลผลต่างๆ เกิดขึ้นในหน่วยประมวลผลย่อย เรียกว่า นิวรอน หรือ เซลล์ประสาท (Neuron) เป็นการจำลองลักษณะการทำงานมาจากเซลล์การส่งสัญญาณระหว่างนิวรอนที่เชื่อมต่อกัน ภายในนิวรอนจะมีฟังก์ชันกำหนดสัญญาณส่งออกที่เรียกว่า ฟังก์ชันการแปลง (Transfer Function) ทำหน้าที่เปรียบเสมือนกระบวนการทำงานในเซลล์ สมองมนุษย์จึงเป็นเหมือนคอมพิวเตอร์ที่มีการปรับตัวได้ (Adaptive) ไม่เป็นเชิงเส้น (Nonlinear) และทำงานแบบขนาน (Parallel) ในการดูแลจัดการการทำงานร่วมกันของนิวรอนในสมอง การคำนวณเชิงนิวรอนจึงเป็นการคำนวณที่เลียนแบบมาจากการทำงานของสมองมนุษย์ โครงข่ายประสาทเทียมประกอบด้วย 5 องค์ประกอบ ดังนี้


- 1) ข้อมูลอินพุต เป็นข้อมูลที่เป็นตัวเลข หากเป็นข้อมูลเชิงคุณภาพ ต้องแปลงให้อยู่ในรูปเชิงปริมาณที่โครงข่ายประสาทเทียมยอมรับได้
- 2) ค่าน้ำหนัก (Weight) หรือค่าความรู้ (Knowledge) เป็นสิ่งที่ได้จากการเรียนรู้ของโครงข่ายประสาทเทียม โดยค่านี้จะถูกเก็บเป็นทักษะเพื่อใช้ในการจดจำข้อมูลอื่นๆ ที่อยู่ในรูปแบบเดียวกัน
- 3) ฟังก์ชันผลรวม (Summation Function) เป็นผลรวมของอินพุตและค่าน้ำหนัก

- 4) ฟังก์ชันการแปลง (Transfer Function) เป็นส่วนที่ทำหน้าที่รวมค่าเชิงตัวเลขจากเอาต์พุตของนิวรอน แล้วทำการตัดสินใจว่าจะส่งสัญญาณเอาต์พุตออกไปในรูปใด ฟังก์ชันการแปลงสามารถเป็นได้ทั้งแบบเชิงเส้นหรือไม่เป็นเชิงเส้น การเลือกใช้ฟังก์ชันการแปลงจะขึ้นอยู่กับลักษณะของระบบ ที่นำเอาโครงข่ายประสาทเทียมไปประยุกต์ใช้
- 5) ข้อมูลเอาต์พุต เป็นผลลัพธ์ที่เกิดขึ้นจริงจากกระบวนการเรียนรู้ของโครงข่ายประสาทเทียม




รูปที่ 2.12 ความแตกต่างของเครือข่ายประสาทในสมองมนุษย์และโครงข่ายประสาทเทียม

ลักษณะของโครงข่ายประสาทเทียมประกอบด้วยนิวรอนจำนวนมากเชื่อมต่อกัน ซึ่งการเชื่อมต่อแบ่งออกเป็นกลุ่มย่อย เรียกว่า ชั้น (Layer) ชั้นแรกเป็นชั้นอินพุต (Input Layer) ชั้นสุดท้ายเป็นชั้นเอาต์พุต (Output Layer) ส่วนชั้นที่อยู่ระหว่างชั้นอินพุตและชั้นเอาต์พุต เรียกว่า ชั้นซ่อน (Hidden Layer) ซึ่งโดยทั่วไปชั้นซ่อนอาจมีมากกว่า 1 ชั้นก็ได้ ดังนั้นจึงแบ่งประเภทตามโครงสร้างของโครงข่ายประสาทเทียมได้ 2 แบบ ได้แก่ โครงข่ายประสาทเทียมแบบชั้นเดียว (Single Layer) และโครงข่ายประสาทเทียมแบบหลายชั้น (Multi-Layer) ตามที่แสดงในรูปที่ 2.13 และ 2.14 ตามลำดับ



รูปที่ 2.13 โครงข่ายประสาทเทียมแบบชั้นเดียว



รูปที่ 2.14 โครงข่ายประสาทเทียมแบบหลายชั้น


การเรียนรู้ของโครงข่ายประสาทเทียมแบ่งออกเป็น 2 ประเภท ได้แก่

- 1) การเรียนรู้แบบมีผู้สอน (Supervised Learning) เป็นการฝึกสอนระบบจากการป้อนข้อมูลที่ต้องการสอน และผลลัพธ์ที่ต้องการให้โครงข่ายสร้าง โดยการทำงานของโครงข่ายจะกำหนดค่าผลลัพธ์ที่เป็นเป้าหมายให้กับอินพุตแต่ละตัว จากนั้นโครงข่ายจะนำค่าผิดพลาดระหว่างค่าเป้าหมายกับค่าผลลัพธ์ที่ได้มาใช้ในการปรับค่าน้ำหนัก เพื่อให้ผลลัพธ์ที่ใกล้เคียงกับเป้าหมายที่สุด การเรียนรู้แบบมีผู้สอนโครงข่าย มี 2 แบบ แบบแรก คือ การเรียนรู้แบบแพร่ย้อนกลับ (Back Propagation) มีขั้นตอนการแพร่เดินหน้า (Forward Propagation) ระบบทำการคำนวณผลรวมของอินพุต จากนั้นทำการแปลงค่าข้อมูลให้อยู่ในรูปของซิกมอยด์ฟังก์ชัน ทำให้ได้เป็นผลลัพธ์ของข้อมูลรับเข้าในหน่วยนั้นๆ จากนั้นขั้นตอนการแพร่ย้อนกลับ (Back Propagation) เป็นการคำนวณค่าความผิดพลาดจากการเปรียบเทียบผลลัพธ์ที่ได้จากการแพร่เดินหน้ากับค่าผลลัพธ์ที่แต่ละหน่วยประมวลผลส่งออกมา แล้วคำนวณค่าน้ำหนักที่เปลี่ยนของการเชื่อมโยง โดยเริ่มคำนวณจากชั้นส่งข้อมูลออกย้อนกลับไปยังชั้นรับอินพุต จากนั้นค่าน้ำหนักจะถูกปรับเปลี่ยนเพื่อให้ได้ผลลัพธ์ที่ใกล้เคียงกับค่าเป้าหมาย แบบที่สอง คือ การเรียนรู้แบบผสมผสาน (Hybrid) ซึ่งมาจากการประมาณ ใช้การเรียนรู้แบบแพร่ย้อนกลับร่วมกับอัลกอริทึมกำลังสองน้อยที่สุด (Least-Squares Algorithm) โดยการเรียนรู้แบบแพร่ย้อนกลับสำหรับพารามิเตอร์ที่เกี่ยวข้องกับฟังก์ชันการเป็นสมาชิกอินพุตและการประมาณค่ากำลังสองน้อยที่สุดสำหรับพารามิเตอร์ที่เกี่ยวข้องกับฟังก์ชันการเป็นสมาชิกเอาต์พุต


2) การเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning) เป็นการสอนโครงข่ายจากการป้อนข้อมูลเข้าเพียงอย่างเดียว ไม่มีการป้อนค่าผลลัพธ์เป้าหมายให้กับข้อมูลที่ป้อน เข้าในแต่ละตัว ทำให้การปรับน้ำหนักมาจากข้อมูลที่ป้อนเข้าระบบมาสอนเป็นตัวปรับค่า โดยค่าน้ำหนักจะปรับตามกลุ่มข้อมูลที่ป้อนเข้าที่มีรูปแบบคล้ายกัน

2.1.2.3 ระบบอนุมานตรรกศาสตร์คลุมเครือโครงข่ายประสาทเทียมแบบปรับตัวได้ (Adaptive Neuro-Fuzzy Inference Systems, ANFIS)


ตรรกศาสตร์คลุมเครือ และโครงข่ายประสาทเทียม ยังมีจุดด้อยของตนเอง เช่น ตรรกศาสตร์คลุมเครือ ไม่สามารถเรียนรู้ด้วยตัวเองได้ จึงไม่สามารถปรับเปลี่ยนโครงสร้างกฎ ตัวแปรต่างๆ และเข้าใจความจำเพาะของงานได้ทั้งหมด ขณะเดียวกันข้อด้อยของโครงข่ายประสาทเทียมคือ ไม่มีความสามารถทางด้านการตีความหาเหตุผลได้ว่าเพราะเหตุใดจึงมีข้อสรุปออกมาดังที่ปรากฏที่เอาต์พุตของโครงข่าย ดังนั้นเมื่อนำทั้ง 2 เครื่องมือมารวมกันเป็น ระบบอนุมานตรรกศาสตร์คลุมเครือโครงข่ายปรับตัวได้ (Adaptive Neuro-Fuzzy Inference Systems, ANFIS) จะช่วยทดแทนข้อด้อยของกันและกัน โดยโครงสร้างของ ANFIS ดังแสดงในรูปที่ 2.15 ที่แบ่งความเป็นสมาชิกออกเป็น 3 ระดับ มีจำนวนอินพุต 1 2 และ 3 ตัวแปร จึงมีรูปแบบกฎความคลุมเครือจำนวน 3 9 และ 27 ข้อตามลำดับ ค่าเอาต์พุตของแต่ละโหนดที่ชั้นนั้นๆ แสดงในรูป $O_{L,N}$ โดย L และ N คือ ลำดับของชั้นซ่อน และลำดับโหนดในชั้นที่ L ตามลำดับ การประมวลผลของ ANFIS แบ่งออกเป็น 2 ส่วน ได้แก่ ส่วนการเรียนรู้ไปข้างหน้า (Forward Pass) หรือส่วนที่ทำนายค่าเอาต์พุต (Predicted Pass) ที่มีการประมวลผลผ่านชั้นซ่อนจำนวน 5 ชั้น ดังนี้



รูปที่ 2.15 โครงสร้างของ ANFIS ที่มีจำนวนอินพุต 1 ตัวแปร



รูปที่ 2.16 โครงสร้างของ ANFIS ที่มีจำนวนอินพุต 2 ตัวแปร



รูปที่ 2.17 โครงสร้างของ ANFIS ที่มีจำนวนอินพุต 3 ตัวแปร

ขั้นที่ 1 เป็นการกำหนดระดับความเป็นสมาชิก (Membership Grade) ของตัวแปรอินพุตที่ต้องการใช้งานให้อยู่ในฟังก์ชันความเป็นสมาชิกที่มีรูปร่างสอดคล้องต่อกระบวนการคิดและสถานะของการนำไปใช้งาน หรือเป็นการสื่อถึงความคลุมเครือเซต สามารถเขียนอยู่ในรูปสมการได้เป็น

$$O_{1,N_1} = \mu_{level}(x_i) \quad (2.8)$$

โดย $N_1 = 1, 2, \dots, 3n$ และ $i = 1, 2, \dots, n$

เมื่อ x_i คือ ค่าอินพุตใดๆ

$\mu_{level}(x_i)$ คือ ค่าความเป็นสมาชิกของค่าอินพุตใดๆ

n คือ จำนวนของตัวแปรอินพุต

ขั้นที่ 2 การดำเนินการพื้นฐานทางลอจิกของความคลุมเครือเซต (Firing Strength) โดยทั่วไปแบ่งออกได้เป็น 2 ลักษณะด้วยกัน คือ การดำเนินการทางลอจิก และการดำเนินการทางพีชคณิต สามารถเขียนอยู่ในรูปสมการได้เป็น

$$O_{2,N_2} = Interpretation(\mu) \quad (2.9)$$

โดย $N_2 = 1, 2, \dots, 3^n$

เมื่อ $Interpretation(\mu)$ คือ วิธีการดำเนินการทางลอจิกของความคลุมเครือเซต

ขั้นที่ 3 การหาค่าเฉลี่ย (Normalization) ของเอาต์พุตที่มาจากการดำเนินการในแต่ละโหนดที่อยู่ในขั้นที่ 2 สามารถเขียนอยู่ในรูปสมการได้เป็น

$$O_{3,N_3} = \frac{O_{2,N_3}}{\sum_{N_2=1}^{3^n} O_{2,N_2}} \quad (2.10)$$

เมื่อ $N_3 = 1, 2, \dots, 3^n$

ขั้นที่ 4 กฎของความคลุมเครือ (Fuzzy Rules) ค่าเฉลี่ยจากเอาต์พุตในแต่ละโหนดของขั้นที่ 3 สามารถเขียนอยู่ในรูปสมการได้เป็น

$$O_{4,N_4} = O_{3,N_4} (p_{N_4} x_1 + q_{N_4} x_2 + \dots + s_{N_4} x_n + t_{N_4}) \quad (2.11)$$

ขั้นที่ 5 การแปลงค่าความคลุมเครือเป็นค่าปกติ (Defuzzification) จากการหาผลรวมค่าเอาต์พุตของโหนดที่อยู่ในขั้นที่ 4 จะได้ค่าเอาต์พุตหรือผลการทำนายค่าเอาต์พุตที่อื่น ๆ สามารถเขียนอยู่ในรูปสมการได้เป็น

$$O_{5,N_5} = \sum_{N_4=1}^{3^n} O_{4,N_4} \quad (2.12)$$

โดย $N_5 = 1$

ส่วนถัดมาเป็นส่วนการย้อนกลับ (Backward Pass) หรือส่วนของการเรียนรู้เพื่อปรับค่าพารามิเตอร์ส่วนหน้า และส่วนหลัง (Premise and Consequent Parameters) โดยใช้กฎลูกโซ่ (Chain Rule) สามารถเขียนอยู่ในรูปสมการ (2.13) และ (2.14) ตามลำดับ

$$\frac{\partial E}{\partial P_{pr,N_{pr}}} = \frac{\partial E}{\partial O_{5,N_5}} \frac{\partial O_{5,N_5}}{\partial O_{4,N_4}} \frac{\partial O_{4,N_4}}{\partial O_{3,N_3}} \frac{\partial O_{3,N_3}}{\partial O_{2,N_2}} \frac{\partial O_{2,N_2}}{\partial O_{1,N_1}} \frac{\partial O_{1,N_1}}{\partial P_{pr,N_{pr}}} \quad (2.13)$$

$$\frac{\partial E}{\partial P_{co,N_{co}}} = \frac{\partial E}{\partial O_{5,N_5}} \frac{\partial O_{5,N_5}}{\partial O_{4,N_4}} \frac{\partial O_{4,N_4}}{\partial P_{co,N_{co}}} \quad (2.14)$$

เมื่อ E คือ ค่าความคลาดเคลื่อนระหว่างค่าจริงและการทำนาย ซึ่งหาได้จากสมการ (2.15)

$$E = \frac{1}{2} (O_{5,N_5} - y)^2 \quad (2.15)$$

โดย $N_{pr} = 1, 2, \dots, 3n$ และ $N_{co} = 1, 2, \dots, 3^n$

เมื่อ P_{pr} และ P_{co} คือ ค่าพารามิเตอร์ส่วนหน้า และส่วนหลัง ตามลำดับ

N_{pr} และ N_{co} คือ ลำดับโหนดของพารามิเตอร์ส่วนหน้า และส่วนหลัง ตามลำดับ

y คือ ค่าความหึงหมู่นีจริงของชุดข้อมูลนั้นๆ

จากนั้นแทนค่าที่คำนวณได้จากสมการ (2.13) ถึง (2.15) เพื่ออัปเดตแต่ละค่าพารามิเตอร์ได้ดังสมการ

$$P(t'+1) = P(t') - \frac{\eta}{2D} \sum_{j=1}^D \frac{\partial E_j}{\partial P} \quad (2.16)$$

เมื่อ P คือ ค่าพารามิเตอร์ที่อยู่ในส่วนหน้า และส่วนหลัง

t' คือ ค่าพารามิเตอร์ปัจจุบัน

η คือ อัตราการเรียนรู้ของแต่ละค่าพารามิเตอร์

D คือ จำนวนชุดข้อมูลที่ใช้ในการสอน

การปรับค่าพารามิเตอร์ส่วนหน้าและส่วนหลัง ส่งผลต่อประสิทธิภาพการทำนายค่าเอาต์พุตเนื่องจากพารามิเตอร์ส่วนหน้าที่ใช้ในการคำนวณในชั้นที่ 1 หรือเป็นค่าพารามิเตอร์ที่อยู่ในฟังก์ชันรูปร่างต่างๆ ที่ใช้กำหนดความเป็นสมาชิกของค่าอินพุต มีจำนวนพารามิเตอร์ตามค่าคงที่ของฟังก์ชันนั้นๆ และพารามิเตอร์ส่วนหลังที่ใช้ในการคำนวณในชั้นที่ 4 หรือเป็นค่าพารามิเตอร์กฎของความคลุมเครือ มีจำนวนพารามิเตอร์เท่ากับจำนวนกฎ อย่างไรก็ตาม การปรับค่าอัตราการเรียนรู้ของแต่ละค่าพารามิเตอร์และจำนวนรอบการเรียนรู้ในส่วนของการเรียนรู้ที่ส่งผลต่อประสิทธิภาพในการทำนายเช่นกัน

2.2 งานวิจัยที่เกี่ยวข้อง

งานวิจัยที่เกี่ยวข้องกับการทำนายค่าความหนืดของยางคอมพาวด์ โดยมีการนำเสนอวิธีการและรูปแบบทางคณิตศาสตร์ เพื่อปรับปรุงแม่นยำให้เพิ่มขึ้น สามารถสรุปได้ดังนี้

การทำนายค่าความหนืดมูนีของยางคอมพาวด์โดยระบบอนุมานตรรกศาสตร์คลุมเครือโครงข่ายประสาทเทียมแบบปรับตัวได้ (Adaptive Neuro-Fuzzy Inference System, ANFIS) โดย S. Merikoski et al. [3] กำหนดข้อมูลอินพุตโดยพิจารณาปัจจัยที่ส่งผลต่อกระบวนการเป็นผลมยางคอมพาวด์ในเครื่องผสมภายใน ได้แก่ แรงบิดแกนหมุนของเครื่องผสม (Torque) และอุณหภูมิ (Temperature) แสดงให้อยู่ในรูปกราฟแสดงความสัมพันธ์ทั้ง 2 ตัวแปรที่ส่งผลต่อความหนืดมูนีพบว่า เมื่อเปรียบเทียบที่อุณหภูมิเท่ากัน ค่าความหนืดมูนีแปรผันตามแรงบิดที่เพิ่มขึ้น และกรณีที่แรงบิดเท่ากัน ค่าความหนืดมูนีแปรผันตามอุณหภูมิเช่นกัน

การทำนายค่าความหนืดมูนีของยางคอมพาวด์โดยวิธีการของเคอร์เนล มีการศึกษาโดย Y. Diancai et al. [4] นำเสนออัลกอริทึมการเรียนรู้เคอร์เนลแบบปรับตัว (Adaptive Kernel Learning (AKL) Algorithm) เนื่องจากเหมาะสำหรับการสร้างแบบจำลองกระบวนการที่มีหลายอินพุตที่มีพฤติกรรม

แบบไม่เป็นเชิงเส้น จากการนำไปทดสอบในโรงงานผลิตยางล้อรถยนต์ในประเทศจีน พบว่าประสิทธิภาพความแม่นยำมีค่า RMSE และ RE เท่ากับ 1.95 และ 4.48 ตามลำดับ จากนั้น H. Jin et al. [5] นำเสนอวิธีการการถดถอยเคอร์เนลคอร์เรนโทรปีแบบเชิงลึก (Ensemble Deep Correntropy Kernel Regression, EDCKR) ที่มาจากการรวมกัน 3 ส่วน ได้แก่ ส่วนที่รวบรวมการเรียนรู้ (Ensemble Learning) การเรียนรู้เชิงลึกของเครือข่าย (Deep Brief Network, DNN) และการถดถอยเคอร์เนลคอร์เรนโทรปี พบว่าประสิทธิภาพความแม่นยำมีค่า RRMSE เท่ากับ 4.55

การทำนายค่าความหนืดมูนนี้ของยางคอมพาวด์โดยวิธีกำลังสองน้อยที่สุดบางส่วน (Partial Least Squares Regression, PLS) มีการศึกษาโดย K. Chen et al. [6] นำเสนอแบบจำลองการทำซ้ำของวิธีกำลังสองน้อยที่สุดบางส่วนแบบ Sliding-Window ช่วยปรับปรุงความแม่นยำในการทำนายแบบเรียลไทม์ของอัลกอริทึม PLS แบบดั้งเดิม โดยมีการอัปเดตข้อมูลออนไลน์และการติดตามตัวแปรที่เปลี่ยนแปลงตามเวลาเพื่อนำไปแก้ปัญหอัลกอริทึม PLS ส่วนที่บกพร่องได้ทันที พบว่าสามารถทำนายค่าความหนืดมูนนี้ได้แม่นยำที่ดีกว่าการใช้วิธีกำลังสองน้อยที่สุดบางส่วนแบบดั้งเดิม จากนั้น Z. Zhang et al. [7] ได้นำแบบจำลองไปพัฒนาเพื่อปรับปรุงให้ความแม่นยำที่ดีขึ้น จากข้อมูลสมบัติรีโอโลยี ซึ่งเป็นการศึกษาถึงพฤติกรรมเชิงกลของวัสดุในการตอบสนองต่อแรงที่มากระทำ โดยการตอบสนองที่เกิดขึ้นนั้นอยู่ในลักษณะการเสียรูปทรงและการไหล พารามิเตอร์ที่นำมาใช้เป็นข้อมูล ได้แก่ ค่าแรงบิดต่ำสุด (Minimum Torque, ML) ค่าแรงบิดสูงสุด (Maximum Torque, MH) ค่าแรงบิดที่ 30 เปอร์เซ็นต์ของเวลาการคงรูป (Time to Achieve 30% of the Maximum Cure-State, T30) และค่าแรงบิดที่ 60 เปอร์เซ็นต์ของเวลาการคงรูป (Time to Achieve 60% of the Maximum Cure-State, T60) ทำการปรับลดค่าที่ได้จากการวัด พบว่าวิธีการมีความแม่นยำกว่าแบบจำลอง PLS RPLS และการถดถอยของกระบวนการเกาส์เซียน (GPS) เนื่องจากสามารถคิดคำนวณครอบคลุมถึงพฤติกรรมการไหลของยางคอมพาวด์ที่เปลี่ยนแปลงไปตามเวลาแบบไม่เป็นเชิงเส้นได้ดีกว่า

การทำนายค่าความหนืดมูนนี้ของยางคอมพาวด์โดยการถดถอยของกระบวนการเกาส์เซียน (Gaussian Process Regression, GPR) มีการศึกษาโดย K. Yang et al. [8] นำเสนอแบบจำลอง Ensemble Just-in-Time Gaussian Process Regression Models, EJITGPR ที่ใช้วิธีการการถดถอยของกระบวนการเกาส์เซียนคู่ควบไปกับการเรียนรู้แบบครบวงจร (Ensemble Learning) และแบบทันเวลาพอดี (Just in Time Learning, JIT) พบว่าประสิทธิภาพความแม่นยำมีค่า RMSE และ R^2 เท่ากับ 3.4831 และ 0.9451 ตามลำดับ มีการนำไปใช้งานกับอุตสาหกรรมในกระบวนการผสมยางซึ่งสามารถทำนายค่าความหนืดมูนนี้ค่อนข้างแม่นยำและแสดงผลออนไลน์ได้ ทั้งนี้เนื่องแบบจำลองมีการคิดครอบคลุมถึงพฤติกรรมการไหลของยางคอมพาวด์ที่เปลี่ยนแปลงไปตามเวลาแบบไม่เป็นเชิงเส้นได้จากนั้นมีการพัฒนาต่อยอดโดย S. Zheng et al. [9] นำเสนอแบบจำลอง Multimodal Perturbation- (MP-) Based Ensemble Just-in-Time Learning Gaussian Process Regression, MP-EJITGPR โดยเพิ่มการเรียนรู้และ

กลไกรูปแบบของสิ่งนี้อาจทำให้เกิดความแปรปรวน เช่น การตรวจวัดความคล้ำยคลึงของการแปรปรวน และความแปรปรวนจากตัวแปรอินพุตที่อาจส่งผลต่อการทำนายค่าความหนืดมูนนี้ได้ พบว่าประสิทธิภาพความแม่นยำมีค่า RMSE และ R^2 เท่ากับ 2.9202 และ 0.9683 ตามลำดับ และได้มีการเปรียบเทียบความแม่นยำของแบบจำลองต่างๆ แสดงเป็นค่า RMSE RRMSE และ R^2 ตามที่แสดงในตารางที่ 2.4

ตารางที่ 2.4 การเปรียบเทียบความแม่นยำในการทำนายค่าความหนืดมูนนี้ในแบบจำลองต่างๆ

วิธีการ	เกณฑ์การเปรียบเทียบความแม่นยำ		
	RMSE	RRMSE (%)	R^2
Partial Least Squares Regression, PLS	7.3298	11.7026	0.8002
Gaussian Process Regression, GPR	4.2628	5.9354	0.9324
Gaussian Mixture Model- (GMM-) Based Ensemble GPR Models, GMMGPR	3.4606	4.8077	0.9555
JIT Learning GPR Using ED Similarity Measure, JITGPR (ED Similarity)	3.1561	4.2700	0.9630
JIT Learning GPR Using Cosine Similarity Measure, JITGPR (Cosine Similarity)	3.2053	4.3494	0.9618
JIT Learning GPR Using CWD Similarity Measure, JITGPR (CWD Similarity)	3.6552	5.2370	0.9503
JIT Learning GPR Using CC Similarity Measure, JITGPR (CC Similarity)	3.2029	4.3313	0.9618
Similarity Perturbation-Based EJITGPR with PLS Stacking for Combination, SP-EJITGPR (PLS Stacking)	3.9916	5.4067	0.9407
Similarity Perturbation-Based EJITGPR with GPR Stacking for Combination, SP-EJITGPR (GPR Stacking)	3.7792	5.0508	0.9469
Similarity Perturbation-Based EJITGPR with the Finite Mixture Mechanism for Combination, SP-EJITGPR (FMM)	3.0670	4.2073	0.9650

ตารางที่ 2.4 การเปรียบเทียบความแม่นยำในการทำนายค่าความหนืดมูนนี้ในแบบจำลองต่างๆ (ต่อ)

วิธีการ	เกณฑ์การเปรียบเทียบความแม่นยำ		
	RMSE	RRMSE (%)	R^2
Similarity Perturbation-Based EJITGPR with Simple Averaging Rule (SAR) for Combination, SP-EJITGPR (SAR)	4.3769	6.0332	0.9288
Multimodal Perturbation-Based EJITGPR with a Simple Averaging Rule for Combination, MP-EJITGPR (PLS Stacking)	4.1966	5.3943	0.9345
Multimodal Perturbation-Based EJITGPR with PLS Stacking for Combination, MP-EJITGPR (GPR Stacking)	3.7819	4.9735	0.9468
Multimodal Perturbation-Based Ensemble Just-in-Time Learning Gaussian Process Regression, MP-EJITGPR (FMM)	2.9202	3.9085	0.9683

งานวิจัยที่เกี่ยวข้องกับการประยุกต์ใช้ระบบตรรกศาสตร์คลุมเครือและโครงข่ายประสาทเทียมช่วยในการทำนายหรือจำลองผลลัพธ์ของงาน สามารถสรุปได้ดังนี้

S. Butdee and K. Tangchaidee [10] ศึกษาการใช้ระบบอนุมานตรรกศาสตร์คลุมเครือโครงข่ายประสาทเทียมแบบปรับตัวได้ในการทำนายความไม่แน่นอนของคุณภาพการคงรูปของชิ้นส่วนยางที่ขึ้นรูปจากกระบวนการกดอัด (Compression) โดยใช้เครื่องมือจากโปรแกรม MATLAB ในการประมวลผล กำหนดขอบเขตให้กับข้อมูลอินพุตโดยพิจารณาปัจจัยที่ส่งผลต่อกระบวนการคงรูปประกอบด้วย ความหนาแน่นของวัสดุ ประเภทของแม่พิมพ์ รูปร่างความซับซ้อนของชิ้นงาน อุณหภูมิ และเวลาการขึ้นรูป ใช้เป็นอินพุตไปประมวลผลโดยตรรกศาสตร์คลุมเครือในขั้นตอนแรก ได้ข้อมูลเอาต์พุตออกมาเป็นประสิทธิภาพ แหล่งที่มา และความผิดปกติของชิ้นงานยาง จากนั้นนำไปรวมกับข้อมูลมาตรฐานการคงรูปของยาง ได้แก่ เวลา ความดัน และอุณหภูมิ ใช้เป็นข้อมูลอินพุตเข้าไปในระบบอนุมานตรรกศาสตร์คลุมเครือโครงข่ายประสาทเทียมเพื่อประมวลผลออกเป็นข้อมูลเอาต์พุตที่บอกถึงประสิทธิภาพการคงรูปของชิ้นงานยาง จากการทดลองพบว่าสามารถทำนายคุณภาพชิ้นส่วนยางได้ดีภายใต้สถานการณ์และความไม่แน่นอน

G. Padmavathi et al. [11] ศึกษาการทำนายค่าความหนืดของยางบิวทาไดอีน และความหนืดของสารละลายพอลิบิวทาไดอีนที่มีความซับซ้อนมากและมีพฤติกรรมไม่เป็นเชิงเส้น โดยใช้โครงข่ายประสาทเทียม 2 แบบ ได้แก่ แบบแพร่ไปข้างหน้า (Feedforward Neural Network, FFNN) และแบบการถดถอยทั่วไป (Generalized Regression Neural Network, GRNN) พบว่าโครงข่ายประสาทเทียมแบบการถดถอยทั่วไปมีประสิทธิภาพดีกว่า ค่าความคลาดเคลื่อนกำลังสองเฉลี่ยของ FFNN และ GRNN ของความหนืดของสารละลายพอลิบิวทาไดอีนมีค่าเท่ากับ 8.6336 และ 0.3337 ตามลำดับ ความหนืดของยางบิวทาไดอีนที่ออกจากเครื่องปฏิกรณ์ (reactor) ในขั้นตอนแรกมีค่าเท่ากับ 0.6716 และ 0.3041 ตามลำดับ และความหนืดของยางบิวทาไดอีนกระบวนการขั้นสุดท้ายที่ออกจากเครื่องปฏิกรณ์มีค่าเท่ากับ 0.0252 และ 0.4091 ตามลำดับ

A. Moghadassi et al. [12] ศึกษาการทำนายความหนืดของสารประกอบ (The Viscosity of a Compound) โดยทำการเปรียบเทียบโครงข่ายประสาทเทียมที่มีการเรียนรู้แบบแพร่ย้อนกลับ (Back Propagation) 3 วิธีการ ได้แก่ แบบ Conjugate Gradient (SCG) แบบ Levenberg-Marquardt (LM) และแบบแพร่ย้อนกลับยืดหยุ่น (Resilient Back Propagation, RP) ชุดข้อมูลอินพุตที่ใช้ในการสอนให้ระบบ ได้แก่ น้ำ (Water) โทลูอีน (Toluene) อนิลีน (aniline) ที่ช่วงอุณหภูมิ -30 ถึง 200 องศาเซลเซียส พบว่า การเรียนรู้แบบแพร่ย้อนกลับวิธีการ SCG ซึ่งมี 19 เซลล์ประสาทที่ซ่อนในชั้นซ่อน (Hidden Layer) นั้นเหมาะสมที่สุด มีข้อผิดพลาดกำลังสองค่าเฉลี่ยต่ำสุด (MSE) ที่ 0.000381

ตารางที่ 2.5 รายงานการวิจัยที่เกี่ยวข้อง

ลำดับ	ปี	ผู้แต่ง	หัวข้องานวิจัย
1	2001	S. Merikoski et al. [3]	An Adaptive Neuro-Fuzzy Inference System as a Soft Sensor for Viscosity in Rubber Mixing Process
2	2009	Y. Diancai et al. [4]	Online Prediction of Mooney Viscosity in Industrial Rubber Mixing Process Via Adaptive Kernel Learning Method.
3	2020	H. Jin et al. [5]	Ensemble Just-In-Time Learning-Based Soft Sensor for Mooney Viscosity Prediction in an Industrial Rubber Mixing Process


ตารางที่ 2.5 รายงานการวิจัยที่เกี่ยวข้อง (ต่อ)

ลำดับ	ปี	ผู้แต่ง	หัวข้องานวิจัย
4	2009	K. Chen et al. [6]	Sliding-Window Recursive PLS Based Soft Sensing Model and Its Application to the Quality Control of Rubber Mixing Process
5	2012	Z. Zhang et al. [7]	A Novel Nonlinear Adaptive Mooney-Viscosity Model Based on DRPLS-GP Algorithm for Rubber Mixing Process
6	2016	K. Yang et al. [8]	Soft Sensor Development for Online Quality Prediction of Industrial Batch Rubber Mixing Process Using Ensemble Just-in-Time Gaussian Process Regression Models
7	2020	S. Zheng et al. [9]	Robust Soft Sensor with Deep Kernel Learning for Quality Prediction in Rubber Mixing Processes
8	2020	S. Butdee and K. Tangchaidee [10]	Neuro Fuzzy Based for Prediction Quality of a Rubber Curing Process on a Compression Machine Under Uncertainty Circumstances
9	2005	G. Padmavathi et al. [11]	Neural Modelling of Mooney Viscosity of Polybutadiene Rubber
10	2010	A. Moghadassi et al. [12]	Application of Artificial Neural Network for Prediction of Liquid Viscosity

บทที่ 3 วิธีการวิจัย

งานวิจัยนี้ทำการศึกษาและสร้างแบบจำลองทำนายค่าความหนืดมูนีของยางคอมพาวด์บนพื้นฐานระบบอนุมานตรรกศาสตร์คลุมเครือโครงข่ายปรับตัวได้ หรือ ANFIS ที่มีส่วนประกอบดังแสดงในรูปที่ 3.1 โดยเริ่มจากการศึกษาตัวแปรที่มีอิทธิพลต่อค่าความหนืดมูนีของยางคอมพาวด์เพื่อนำมากำหนดเป็นตัวแปรอินพุตและการคัดเลือกข้อมูลที่น่ามาใช้เป็นฐานข้อมูลของแบบจำลองการออกแบบอัลกอริทึมที่ใช้ในการหาค่าพารามิเตอร์เริ่มต้นส่วนหน้าและส่วนหลัง การศึกษาและออกแบบโครงสร้าง ANFIS และการออกแบบการอัปเดตฐานข้อมูลจากข้อมูลใหม่ เพื่อให้แบบจำลองสามารถปรับตัวเองได้ตามการเปลี่ยนแปลงในอนาคต และสามารถทำนายค่าความหนืดมูนีของยางคอมพาวด์ได้แม่นยำยิ่งขึ้น

TNI



รูปที่ 3.1 แบบจำลองระบบการทำนายค่าความหนืดมุนีของยางคอมพาวด์

3.1 ตัวแปรที่มีอิทธิพลต่อค่าความหนืดมูนี้ของยางคอมพาวด์

ศึกษายางคอมพาวด์ที่ผสมโดยเครื่องผสมระบบปิดแบบอินเตอร์มิกซ์ (Intermix Internal Mixer, INTERMIX, GK 250 E) ซึ่งพารามิเตอร์ที่เครื่องผสมตรวจวัดในการผสมยาง ได้แก่ อุณหภูมิ ความดันของแกนกด ระยะของแกนกด เวลา การหมุน และกระแสไฟฟ้า โดยในการศึกษาเลือกพารามิเตอร์ที่มีอิทธิพลต่อการเปลี่ยนแปลงค่าความหนืดมูนี้ของยางคอมพาวด์ ได้แก่ กระแสไฟฟ้า อุณหภูมิ และความดัน ณ จุดสิ้นสุดกระบวนการผสม เนื่องจากกระแสไฟฟ้าเป็นค่าที่สอดคล้องกับแรงบิดแกนหมุนของเครื่องผสมที่หมุนเข้าหากันเพื่อให้เกิดแรงเฉือนในการผสม อุณหภูมิและความดันซึ่งส่งผลต่อพฤติกรรมไหลของยาง จึงกำหนด 3 ตัวแปรนี้ ใช้ในการศึกษาตัวแปรอินพุตของแบบจำลองต่อประสิทธิภาพการทำนายค่าความหนืดมูนี้

การทดสอบค่าความหนืดมูนี้ของยางคอมพาวด์ นำยางคอมพาวด์ประมาณ 10 กรัม อุณหภูมิ 25 องศาเซลเซียส ไปทดสอบด้วยเครื่องมูนี้วิสโคมิเตอร์ ตามมาตรฐาน ASTM D1646-2004 จึงกำหนดเป็นข้อมูลเป้าหมาย หรือค่าจริง (Actual Value)

ข้อมูลที่ได้จากการผลิตในโรงงานผลิตยางคอมพาวด์ โดยใช้ข้อมูลจาก 13 สูตรยางคอมพาวด์ เออีเอสโพรพิลีนไดอินหรืออีพีดีเอ็ม จำนวน 2600 แบบที่มีค่าความหนืดมูนี้แตกต่างกัน จากนั้นแบ่งข้อมูลออกเป็น 3 ชุด ได้แก่ ชุดข้อมูลจำนวน 2000 ชุดที่มี 10 สูตรยางคอมพาวด์ ชุดข้อมูลจำนวน 400 ชุด ที่มี 2 สูตรยางคอมพาวด์ และชุดข้อมูลจำนวน 200 ชุดที่มี 10 สูตรยางคอมพาวด์ เป็นข้อมูลสำหรับสอนระบบอนุมานตรรกศาสตร์คลุมเครือโครงข่ายปรับตัวได้ (Training Data) หรือเป็นฐานข้อมูลของแบบจำลอง ข้อมูลที่ใช้ทดสอบแบบจำลอง (Testing Data) และข้อมูลที่ใช้ในการทดสอบอัปเดตฐานข้อมูลด้วยข้อมูลใหม่ ตามลำดับ ซึ่งสามารถแสดงได้ดังตารางที่ 3.1

ตารางที่ 3.1 การแบ่งชุดข้อมูลที่ใช้ในการทดสอบแบบจำลอง

การใช้ข้อมูล	จำนวนชุดข้อมูล
ฐานข้อมูล	2,000 ชุด
ชุดข้อมูลทดสอบ	400 ชุด
ชุดข้อมูลทดสอบการอัปเดต	200 ชุด


3.2 การหาค่าพารามิเตอร์เริ่มต้น

อัลกอริทึมการหาค่าพารามิเตอร์เริ่มต้น ประกอบด้วย 2 ส่วน ได้แก่ พารามิเตอร์ส่วนหน้า (Premise Parameters) และพารามิเตอร์ส่วนหลัง (Consequent Parameters) ซึ่งนำไปใช้ใน ขั้นที่ 2 และ 4 ตามลำดับ ของโครงสร้าง ANFIS เพื่อใช้ในการทำนายค่าความหนืดมูนี้ของยางคอมพาวด์

การคำนวณค่าพารามิเตอร์ส่วนหน้า งานวิจัยนี้เลือกฟังก์ชันความเป็นสมาชิกเกาส์เซียน (Gaussian Membership Function) เนื่องจากสอดคล้องกับพฤติกรรมค่าความหนืดมูนี่ที่เปลี่ยนแปลงไปตามตัวแปรอินพุต ซึ่งฟังก์ชันประกอบไปด้วย 2 พารามิเตอร์ ได้แก่ $\{c, \sigma\}$ ดังแสดงความสัมพันธ์ในสมการ (3.1) และในการศึกษานี้แบ่งฟังก์ชันความเป็นสมาชิกของแต่ละตัวแปรอินพุตออกเป็น 3 ระดับ ได้แก่ ต่ำ กลาง และสูง เพื่อให้ตัวแปรอินพุตมีระดับความเป็นสมาชิกที่คลุมเครือมากกว่าการมีระดับสูงหรือต่ำไปเลย ดังที่แสดงในรูปที่ 3.2

$$\mu = e^{\frac{-(x-c)^2}{2\sigma^2}} \quad (3.1)$$

เมื่อ c คือ ค่าศูนย์กลางหรือค่าเฉลี่ยของแต่ละฟังก์ชันความเป็นสมาชิก
 σ คือ การกระจายตัวหรือค่าเบี่ยงเบนมาตรฐานของแต่ละฟังก์ชันความเป็นสมาชิก



รูปที่ 3.2 กราฟเกาส์เซียนแต่ละตัวแปรอินพุต

การคำนวณค่าพารามิเตอร์ส่วนหน้าของฟังก์ชันความเป็นสมาชิกเกาส์เซียนของแต่ละตัวแปรอินพุต สามารถคำนวณได้จากสมการที่ (3.2) (3.3) (3.4) และ (3.5)

$$c_{low} = x_{min} + 5\% \quad (3.2)$$

$$c_{high} = x_{max} - 5\% \quad (3.3)$$

$$c_{medium} = \frac{c_{high} - c_{low}}{2} \quad (3.4)$$

$$\sigma = \sqrt{\frac{-(x-c)^2}{2\ln(\%OL)}} \quad (3.5)$$

เมื่อ c_{low} c_{medium} และ c_{high} คือ ค่าศูนย์กลางของฟังก์ชันความเป็นสมาชิกที่ระดับต่ำ กลาง และสูง ตามลำดับ

x_{min} และ x_{max} คือ ค่าต่ำสุด และสูงสุดของตัวแปรอินพุตในชุดข้อมูลสอนระบบ ตามลำดับ

%OL คือ ค่าเปอร์เซ็นต์การซ้อนทับกันของฟังก์ชันแต่ละระดับ หรือเป็นการสื่อถึงความคลุมเครือ ซึ่งฟังก์ชันแต่ละระดับไม่ควรมีส่วนทับกันน้อยเกินไป เพื่อไม่ให้ค่าความเป็นสมาชิกของตัวแปรอินพุตเป็น 0 หรือเกิดการกระจายลงในระดับฟังก์ชันความเป็นสมาชิกของตัวแปรอินพุตนั้นๆ

ชุดค่าพารามิเตอร์ส่วนหลังมีจำนวนค่าพารามิเตอร์ขึ้นกับจำนวนอินพุตของโครงสร้าง ANFIS โดยที่จำนวนอินพุต 1 ตัวแปรมี 2 ค่าพารามิเตอร์ ได้แก่ p และ t จำนวนอินพุต 2 ตัวแปรมี 3 ค่าพารามิเตอร์ ได้แก่ p q และ t และจำนวนอินพุต 3 ตัวแปรมีค่าพารามิเตอร์ ได้แก่ p q s และ t ในแต่ละตัวแปรจะมีจำนวนเท่ากับจำนวนกฎของแต่ละโครงสร้าง ANFIS ซึ่งแสดงความสัมพันธ์ในสมการที่ (3.6)

$$r = 3^n \quad (3.6)$$

เมื่อ r คือ จำนวนกฎของโครงสร้าง ANFIS ที่มีจำนวนอินพุตนั้นๆ

การหาค่า $p, q, \dots, s$ เริ่มจากการแบ่งกลุ่มชุดข้อมูลอินพุตที่มีเงื่อนไขตรงกับกฎ โดยอินพุตของแต่ละฟังก์ชันความเป็นสมาชิกของอินพุตนั้นๆ หาได้ดังนี้

$$\begin{aligned} R_{x_1, low} &= c_{x_1, low} - \sqrt{-2\sigma_{x_1}^2 \ln \varepsilon} \quad \text{to} \quad c_{x_1, low} + \sqrt{-2\sigma_{x_1}^2 \ln \varepsilon} \\ R_{x_1, medium} &= c_{x_1, medium} - \sqrt{-2\sigma_{x_1}^2 \ln \varepsilon} \quad \text{to} \quad c_{x_1, medium} + \sqrt{-2\sigma_{x_1}^2 \ln \varepsilon} \\ R_{x_1, high} &= c_{x_1, high} - \sqrt{-2\sigma_{x_1}^2 \ln \varepsilon} \quad \text{to} \quad c_{x_1, high} + \sqrt{-2\sigma_{x_1}^2 \ln \varepsilon} \\ R_{x_2, low} &= c_{x_2, low} - \sqrt{-2\sigma_{x_2}^2 \ln \varepsilon} \quad \text{to} \quad c_{x_2, low} + \sqrt{-2\sigma_{x_2}^2 \ln \varepsilon} \\ &\vdots \\ R_{x_i, low} &= c_{x_i, low} - \sqrt{-2\sigma_{x_i}^2 \ln \varepsilon} \quad \text{to} \quad c_{x_i, low} + \sqrt{-2\sigma_{x_i}^2 \ln \varepsilon} \\ R_{x_i, medium} &= c_{x_i, medium} - \sqrt{-2\sigma_{x_i}^2 \ln \varepsilon} \quad \text{to} \quad c_{x_i, medium} + \sqrt{-2\sigma_{x_i}^2 \ln \varepsilon} \\ R_{x_i, high} &= c_{x_i, high} - \sqrt{-2\sigma_{x_i}^2 \ln \varepsilon} \quad \text{to} \quad c_{x_i, high} + \sqrt{-2\sigma_{x_i}^2 \ln \varepsilon} \end{aligned}$$

เมื่อ $R_{x_r, \text{level}}$ คือ ช่วงกราฟของฟังก์ชันความเป็นสมาชิกในแต่ละระดับสำหรับอินพุตใดๆ
 ε คือ ค่าคงที่ 0.0001

กฎแต่ละข้อของโครงสร้าง ANFIS ที่มีจำนวนอินพุตนั้นๆ สามารถเขียนอยู่ในรูป

กฎที่ 1 IF x_1 is low and x_2 is low and ... and x_n is low

$$\text{THEN } O_{4,1} = O_{3,1} (p_{\text{low}}x_1 + q_{\text{low}}x_2 + \dots + s_{\text{low}}x_n + t_1)$$

กฎที่ 2 IF x_1 is low and x_2 is low and ... and x_n is medium

$$\text{THEN } O_{4,2} = O_{3,2} (p_{\text{low}}x_1 + q_{\text{low}}x_2 + \dots + s_{\text{medium}}x_n + t_2)$$

กฎที่ 3 IF x_1 is low and x_2 is low and ... and x_n is high

$$\text{THEN } O_{4,3} = O_{3,3} (p_{\text{low}}x_1 + q_{\text{low}}x_2 + \dots + s_{\text{high}}x_n + t_3)$$

กฎที่ 4 IF x_1 is medium and x_2 is low and ... and x_n is low

$$\text{THEN } O_{4,4} = O_{3,4} (p_{\text{medium}}x_1 + q_{\text{low}}x_2 + \dots + s_{\text{low}}x_n + t_4)$$

⋮

กฎที่ r IF x_1 is high and x_2 is high and ... and x_n is high

$$\text{THEN } O_{4,r} = O_{3,r} (p_{\text{high}}x_1 + q_{\text{high}}x_2 + \dots + s_{\text{high}}x_n + t_r)$$

จากนั้นหาค่าพารามิเตอร์ โดยการแก้สมการเชิงเส้นสมการที่ (3.7) ในแต่ละกฎ เพื่อหาค่า p สำหรับอินพุต 1 ตัวแปร q สำหรับอินพุต 2 ตัวแปร และ p q และ s สำหรับอินพุต 3 ตัวแปร

$$\begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_{D_r} \end{bmatrix}_{D_r \times 1} = \begin{bmatrix} x_{1,1} & x_{1,1} & \dots & x_{n,1} \\ x_{1,2} & x_{2,2} & \dots & x_{n,2} \\ \vdots & \vdots & & \vdots \\ x_{1,D_r} & x_{2,D_r} & \dots & x_{n,D_r} \end{bmatrix}_{D_r \times n} \begin{bmatrix} p \\ q \\ \vdots \\ s \end{bmatrix}_{n \times 1} \quad (3.7)$$

โดย D_r คือ จำนวนชุดข้อมูลที่ตรงตามกฎนั้นๆ

หาค่าพารามิเตอร์ t ของแต่ละกฎจากการแก้สมการที่ (3.8) แล้วหาค่าเฉลี่ย ด้วยสมการที่ (3.9)

$$\begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_{D_r} \end{bmatrix}_{D_r \times 1} = \begin{bmatrix} x_{1,1} & x_{1,1} & \cdots & x_{n,1} \\ x_{1,2} & x_{2,2} & \cdots & x_{n,2} \\ \vdots & \vdots & & \vdots \\ x_{1,D_r} & x_{2,D_r} & \cdots & x_{n,D_r} \end{bmatrix}_{D_r \times n} \begin{bmatrix} p \\ q \\ \vdots \\ s \end{bmatrix}_{n \times 1} + \begin{bmatrix} t_1 \\ t_2 \\ \vdots \\ t_{D_r} \end{bmatrix}_{D_r \times 1} \quad (3.8)$$

$$t = \frac{1}{D_r} \sum_{k=1}^{D_r} t_k \quad (3.9)$$

เงื่อนไขในการทดสอบประสิทธิภาพการทำนายค่าความหนืดมูนนี้ที่เปรียบเทียบระหว่างการใช้อัลกอริทึมการหาค่าพารามิเตอร์เริ่มต้นและค่าสุ่มที่แบ่งออกเป็น 5 ช่วง ได้แก่ 0 ถึง 1 1 ถึง 100 100 ถึง 1000 1000 ถึง 10000 และ 10000 ถึง 100000 ซึ่งสามารถเขียนแสดงได้ดังตารางที่ 3.2

ตารางที่ 3.2 เงื่อนไขการทดสอบประสิทธิภาพการทำนายเปรียบเทียบระหว่างอัลกอริทึมอัลกอริทึมการหาค่าพารามิเตอร์เริ่มต้นและค่าสุ่ม

ตัวแปรการทดสอบ	เงื่อนไขการปรับเปลี่ยน	ชุดข้อมูลทดสอบ
อัลกอริทึมการหาค่าพารามิเตอร์เริ่มต้น	-	
ค่าสุ่ม	0 ถึง 1	ชุดข้อมูลทดสอบ
	1 ถึง 100	
	100 ถึง 1000	
	1000 ถึง 10000	
	10000 ถึง 100000	

3.3 การออกแบบระบบอนุมานตรรกศาสตร์คลุมเครือโครงข่ายปรับตัวได้

การออกแบบเงื่อนไขหรือทิศทางการปรับเปลี่ยนตัวเลขในโครงสร้าง ANFIS ส่งต่อประสิทธิภาพการทำนายทั้งในแง่ความถูกต้องและความแม่นยำ โดยสามารถออกแบบโครงข่ายได้ 4 ส่วน ได้แก่ จำนวนและตัวแปรอินพุต ส่วนไปข้างหน้า วิธีการดำเนินการทางพีชคณิตของเซตความคลุมเครือ โดยจะอยู่ในชั้นที่ 1 และ 2 ของโครงข่าย ANFIS ส่วนไปข้างหน้า ตามลำดับ จำนวนรอบการเรียนรู้ และการอัปเดตค่าพารามิเตอร์ที่ผ่านการเรียนรู้แล้ว ซึ่งอยู่ในการคำนวณส่วนการเรียนรู้ของโครงข่าย ANFIS ในงานวิจัยนี้เลือกศึกษาการปรับเปลี่ยนเงื่อนไขและกำหนดค่าคงที่ ดังนี้

- จำนวนและตัวแปรอินพุต ได้แก่ จำนวนอินพุต 2 และ 3 ตัวแปร และมีตัวแปรเป็น อุณหภูมิ กระแสไฟฟ้า และความดัน
- วิธีการดำเนินการทางพีชคณิตของความคลุมเครือเซต เลือกศึกษาจำนวน 4 วิธีการ ซึ่งในแต่ละการดำเนินการมีสัญลักษณ์และความสัมพันธ์ทางคณิตศาสตร์ดังแสดงในตารางที่ 3.3
- จำนวนรอบการเรียนรู้ ได้แก่ 100 500 และ 1000 เนื่องจากจำนวนรอบส่งผลต่อความเร็วในการประมวลผลของแบบจำลองจึงกำหนดรอบให้อยู่ในระดับที่น้อยมาก น้อย และปานกลาง
- การอัปเดตค่าพารามิเตอร์ที่ผ่านการเรียนรู้แล้ว ในงานวิจัยนี้อัปเดตค่าพารามิเตอร์ส่วนหน้า และหลัง ได้แก่ σ และ t เท่านั้น เนื่องจากอัลกอริทึมการหาค่าพารามิเตอร์เริ่มต้นได้ออกแบบค่า c ให้ปรับตัวตามฐานข้อมูลและมีค่าที่แตกต่างกันแต่ละฟังก์ชันความเป็นสมาชิกของตัวแปรอินพุตนั้นๆ ในขณะที่ σ จะสามารถคำนวณได้ค่าเดียวและใช้เป็นตัวแทนในทุกฟังก์ชันความเป็นสมาชิกของตัวแปรอินพุตนั้นๆ และในส่วนของค่า t ซึ่งเป็นค่าเฉลี่ยของผลต่างที่ได้จากการแก้สมการเชิงเส้นของกฎนั้นๆ ซึ่งอาจไม่มีความแม่นยำพอ

ตารางที่ 3.3 วิธีการดำเนินการทางพีชคณิตของความคลุมเครือเซต

การดำเนินการ	สัญลักษณ์	เขียนอยู่ในรูปสมการได้เป็น
ผลคูณของระดับความเป็นสมาชิก	AND	$O_{2,N_2} = \mu(x_1) \cdot \mu(x_2) \cdot \dots \cdot \mu(x_n)$
ผลคูณของระดับความเป็นสมาชิกยกกำลังสอง	AND-Squared	$O_{2,N_2} = \mu^2(x_1) \cdot \mu^2(x_2) \cdot \dots \cdot \mu^2(x_n)$
ผลรวมของระดับความเป็นสมาชิก	OR	$O_{2,N_2} = \mu(x_1) + \mu(x_2) + \dots + \mu(x_n)$
ผลรวมของระดับความเป็นสมาชิกยกกำลังสอง	OR-Squared	$O_{2,N_2} = \mu^2(x_1) + \mu^2(x_2) + \dots + \mu^2(x_n)$

โดยเงื่อนไขในการทดสอบประสิทธิภาพการทำนายค่าความหนืดมูนี้ที่มีการตั้งเงื่อนไขในโครงสร้าง ANFIS ต่างๆ สามารถเขียนแสดงได้ดังตารางที่ 3.4

ตารางที่ 3.4 เงื่อนไขการทดสอบประสิทธิภาพการทำนายที่มีการตั้งเงื่อนไขของโครงสร้าง ANFIS ที่แตกต่างกัน


ตัวแปรการทดสอบ	เงื่อนไขการปรับเปลี่ยน	ชุดข้อมูลทดสอบ
ตัวแปรอินพุต	ค่าอินพุต 2 ตัวแปร	ฐานข้อมูล และชุดข้อมูลทดสอบ
	ค่าอินพุต 3 ตัวแปร	
จำนวนรอบการเรียนรู้	100	
	500	
	1,000	
วิธีการดำเนินการ	AND	
	AND-Squared	
	OR	
	OR-Squared	

3.4 การอัปเดตฐานข้อมูลของแบบจำลอง

การอัปเดตฐานข้อมูลของแบบจำลองเพื่อให้แบบจำลองเกิดการปรับตัว เรียนรู้ และสร้างค่าพารามิเตอร์ส่วนหน้าและส่วนหลังใหม่ตามข้อมูลที่เปลี่ยนแปลง โดยในการจำลองการทำนายค่าความหาค่าความผิดพลาดของชุดข้อมูลที่ใช้ในการทดสอบการอัปเดตฐานข้อมูลแบ่งออกเป็น 2 ส่วน ได้แก่ ส่วนการอัปเดตฐานข้อมูลของแบบจำลองด้วยข้อมูลที่เป็นตัวแทนของสูตรเก่าหรือเป็นสูตรของชุดข้อมูลในฐานข้อมูลของแบบจำลอง ซึ่งใช้จำนวน 50 ชุดต่อการทดสอบ และข้อมูลสูตรใหม่หรือเป็นสูตรที่ไม่มีชุดข้อมูลในฐานข้อมูลของแบบจำลอง ซึ่งใช้จำนวน 50 ชุดต่อการทดสอบ โดยในแต่ละสูตรจะทำการทดสอบ 4 ครั้ง เพื่อดูประสิทธิภาพการทำนายของแบบจำลองต่อข้อมูลที่เป็นสูตรเก่าและใหม่ จากนั้นทำการผสมข้อมูลระหว่างสูตรเก่าและใหม่อย่างละครึ่งรวมเป็นจำนวน 50 ชุดต่อการทดสอบ ทำการทดสอบได้ 8 ครั้ง โดยในแต่ละครั้งของการทดสอบ จะทำการเปรียบเทียบระหว่างค่า $RMSE_{model,current}$ ซึ่งเป็นตัวแทนบ่งบอกประสิทธิภาพการทำนายค่าความหาค่าความผิดพลาดของชุดข้อมูลที่ใช้ค่าพารามิเตอร์ส่วนหน้าและส่วนหลังที่สร้างจากฐานข้อมูลที่ยังไม่อัปเดต และ $RMSE_{model,new}$ ซึ่งเป็นตัวแทนบ่งบอกประสิทธิภาพการทำนายค่าความหาค่าความผิดพลาดของชุดข้อมูลที่ใช้ค่าพารามิเตอร์ส่วนหน้าและส่วนหลังที่สร้างจากฐานข้อมูลที่อัปเดตด้วยชุดข้อมูลที่นำมาทดสอบ โดยหลักการทดสอบสามารถแสดงดังรูปที่ 23 ทั้งนี้เพื่อดูการปรับตัวของแบบจำลองต่อความถูกต้องและความแม่นยำในการทำนายค่าความหาค่าความผิดพลาดของแบบจำลองต่อการนำไปใช้ในสูตรเก่าและใหม่ โดยเงื่อนไขในการทดสอบแบบจำลองทั้ง 2 ส่วน สามารถเขียนแสดงได้ดังตารางที่ 3.5

ตารางที่ 3.5 เงื่อนไขการทดสอบประสิทธิภาพการทำนายค่าความหนืดมูนี้ของแบบจำลองที่มีการอัปเดตและไม่อัปเดตฐานข้อมูล และการทำนายข้อมูลที่มาจากสูตรยางเก่าและใหม่

ตัวแปรการทดสอบ	เงื่อนไขการปรับเปลี่ยน	ชุดข้อมูลทดสอบ
สูตรยางเก่า	อัปเดต และไม่อัปเดตฐานข้อมูล	การทดสอบในแต่ละครั้งประกอบด้วย ชุดข้อมูลสำหรับทดสอบ 50 ชุด และชุดข้อมูลสำหรับทดสอบการอัปเดตจำนวน 50 ชุด
สูตรยางใหม่	อัปเดต และไม่อัปเดตฐานข้อมูล	
การทดสอบอัปเดตต่อเนื่อง	ชุดข้อมูลจำนวน 50 ชุด ต่อครั้งการทดสอบ	การทดสอบในแต่ละครั้งประกอบด้วย ชุดข้อมูลสำหรับทดสอบ 25 ชุด และชุดข้อมูลสำหรับทดสอบการอัปเดตจำนวน 25 ชุด



รูปที่ 3.3 เงื่อนไขการอัปเดตฐานข้อมูลของแบบจำลอง

การเปรียบเทียบประสิทธิภาพของแบบจำลอง โดยคำนวณค่ารากที่สองของค่าความคาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Square Error, RMSE) ตามสมการที่ (3.10)

$$\text{RMSE} = \sqrt{\frac{1}{D_k} \sum_{k=1}^{D_k} (O_{5,N_5} - y_k)^2} \quad (3.10)$$

เมื่อ D_k คือ จำนวนชุดข้อมูลที่ใช้เปรียบเทียบกับค่าการทำนาย
 y_k คือ ข้อมูลเป้าหมายของแต่ละชุดข้อมูล



บทที่ 4


ผลการศึกษาและการอภิปรายผล

4.1 ผลของตัวแปรอินพุต


จากการจำลองผลการทำนายจากชุดข้อมูลทดสอบ แสดงผลเปรียบเทียบระหว่างค่าจริงและค่าการทำนายของความหนืดมูนี ที่มีจำนวนอินพุต 1 2 และ 3 ตัวแปร แสดงดังรูปที่ 4.1 4.2 และ 4.3 ตามลำดับ พบว่า ค่า RMSE ของโครงสร้าง ANFIS ที่มีอินพุต ได้แก่ จำนวนอินพุต 1 ตัวแปร คือ อุณหภูมิ กระแสไฟฟ้า และความดัน จำนวนอินพุต 2 ตัวแปร คือ อุณหภูมิและกระแสไฟฟ้า อุณหภูมิและความดัน กระแสไฟฟ้าและความดัน และอินพุต 3 ตัวแปร คือ อุณหภูมิ กระแสไฟฟ้า และความดัน แสดงดังตารางที่ 12 จะเห็นว่า โครงสร้าง ANFIS ที่มีอินพุต 3 ตัวแปรจะมีค่า RMSE น้อยกว่าและมีประสิทธิภาพในการทำนายที่ดีกว่าอินพุต 1 และ 2 ตัวแปร อย่างไรก็ตามโครงสร้าง ANFIS ที่มีอินพุต 2 ตัวแปร คือ อุณหภูมิและกระแสไฟฟ้า มีประสิทธิภาพการทำนายใกล้เคียงกับอินพุต 3 ตัวแปรเช่นกัน จึงทำให้อินพุตทั้ง 2 แบบมีประสิทธิภาพการทำนายที่ดี และมีช่องว่างระหว่างค่าจริงและค่าทำนายที่น้อยเมื่อเทียบกับอินพุตรูปแบบอื่นๆ อย่างไรก็ตาม เมื่อพิจารณาการใช้อุณหภูมิและความดันในการทำนาย พบว่ามีค่าความแปรปรวนของการทำนายระหว่างค่าจริงกับค่าการทำนายที่น้อยกว่า จึงเป็นอีกทางเลือกสำหรับผู้ที่ต้องการความแปรปรวนในการทำนายที่น้อยเมื่อนำไปใช้งาน

ตารางที่ 4.1 ค่า RMSE ของการทำนายค่าความหนืดมูนีที่มีจำนวนและตัวแปรอินพุตที่ใช้ในการจำลองแตกต่างกัน ได้แก่ จำนวนอินพุต 1 2 และ 3 ตัวแปร และตัวแปรอินพุต เป็นอุณหภูมิ กระแสไฟฟ้า และความดัน


จำนวนอินพุต	ตัวแปรอินพุต	ค่า RMSE
1	อุณหภูมิ	22.85
	กระแสไฟฟ้า	442.37
	ความดัน	14.68
2	อุณหภูมิและกระแสไฟฟ้า	6.71
	อุณหภูมิและความดัน	8.04
	กระแสไฟฟ้าและความดัน	9.39
3	อุณหภูมิ กระแสไฟฟ้า และความดัน	6.26




รูปที่ 4.1 การเปรียบเทียบระหว่างค่าจริงและค่าการทำนายความหยาบนี้จากโครงสร้าง ANFIS ที่มีจำนวนอินพุต 1 ตัวแปร ได้แก่ อุณหภูมิ รูปที่ 4.1 (ก) กระแสไฟฟ้า รูปที่ 4.1 (ข) และความดัน รูปที่ 4.1 (ค)



รูปที่ 4.2 การเปรียบเทียบระหว่างค่าจริงและค่าการทำนายความหยาบนี้จากโครงสร้าง ANFIS ที่มีจำนวนอินพุต 2 ตัวแปร ได้แก่ อุณหภูมิและกระแสไฟฟ้า รูปที่ 4.2 (ก) อุณหภูมิและความดัน รูปที่ 4.2 (ข) กระแสไฟฟ้าและความดัน รูปที่ 4.3 (ค)



รูปที่ 4.2 การเปรียบเทียบระหว่างค่าจริงและค่าการทำนายความหนืดปูนซีเมนต์จากโครงสร้าง ANFIS ที่มีจำนวนอินพุต 2 ตัวแปร ได้แก่ อุณหภูมิและกระแสไฟฟ้า รูปที่ 4.2 (ก) อุณหภูมิและความดัน รูปที่ 4.2 (ข) กระแสไฟฟ้าและความดัน รูปที่ 4.3 (ค) (ต่อ)



รูปที่ 4.3 การเปรียบเทียบระหว่างค่าจริงและค่าการทำนายความหนืดปูนซีเมนต์จากโครงสร้าง ANFIS ที่มีจำนวนอินพุต 3 ตัวแปร ได้แก่ อุณหภูมิ กระแสไฟฟ้า และความดัน

4.2 ผลของอัลกอริทึมการหาค่าพารามิเตอร์เริ่มต้น

จากผลการทดลองในหัวข้อก่อนหน้านี้ กำหนดค่าตัวแปรที่ให้ผลลัพธ์ที่ดีมาใช้ในการทดลอง ในหัวข้อนี้ การทดสอบแสดงประสิทธิภาพด้วยค่า RMSE ที่ได้จากการใช้พารามิเตอร์เริ่มต้นที่แตกต่างกัน โดยผลการจำลองที่แสดงในตารางที่ 4.2 แสดงให้เห็นว่า อัลกอริทึมการหาค่าพารามิเตอร์เริ่มต้นสามารถให้ประสิทธิภาพการทำนายที่ดีเมื่อเปรียบเทียบกับค่าสุ่ม เนื่องจากมีค่า RMSE ที่น้อย และยังสามารถปรับตัวให้เข้ากับฐานข้อมูลได้ อีกทั้งอินพุต 3 ตัวแปรของโครงสร้าง ANFIS ให้ประสิทธิภาพการทำนายที่ดีกว่าอินพุต 2 ตัวแปร ซึ่งสอดคล้องกับผลการจำลองก่อนหน้านี้ การสุ่มเลขในช่วง 0 ถึง 1 (ทั้งอินพุต 2 และ 3 ตัวแปร) และ 1-100 (อินพุต 3 ตัวแปร) พบว่าแบบจำลองไม่สามารถคำนวณได้ ซึ่งแสดงได้ว่า ตัวเลขบางตัวไม่สามารถที่จะนำไปใช้ได้ เนื่องจากแบบจำลองไม่สามารถประมวลผลการทำนายได้ ยิ่งไปกว่านั้นตัวเลขสุ่มในช่วงที่เหลือแสดงผลการทำนายที่มีค่า RMSE สูงกว่าค่าที่ได้จากการใช้อัลกอริทึมการหาค่าพารามิเตอร์เริ่มต้น

โดยทั่วไป ค่าพารามิเตอร์ส่วนหน้าและส่วนหลังของระบบตรรกศาสตร์คลุมเครือมาจากประสบการณ์หรือความชำนาญของผู้ปฏิบัติงาน ดังนั้นอัลกอริทึมการหาค่าพารามิเตอร์เริ่มต้นจะช่วยเพิ่มประสิทธิภาพของการทำนาย และเหมาะสมกับแบบจำลองการทำนายค่าความเหน็ดมุนนี้ของยางคอมพาวด์นี้ด้วย โดยจะสร้างค่าพารามิเตอร์จำเพาะที่เหมาะสมสำหรับแบบจำลอง จึงมีความสามารถในการนำไปใช้ที่ดี สามารถอัปเดตได้อัตโนมัติเมื่อฐานข้อมูลเกิดการเปลี่ยนแปลงหรือมีข้อมูลใหม่ และกำจัดตัวแปรที่ไม่จำกัดที่ส่งผลต่อความไม่แน่นอนและความอคติของผู้ปฏิบัติงาน

ตารางที่ 4.2 ค่า RMSE ของการทำนายค่าความเหน็ดมุนนี้ของยางคอมพาวด์ที่เปรียบเทียบระหว่างอัลกอริทึมการหาค่าพารามิเตอร์เริ่มต้นและค่าสุ่มที่แบ่งออกเป็น 5 ช่วง ได้แก่ 0 ถึง 1 1 ถึง 100 100 ถึง 1000 1000 ถึง 10000 และ 10000 ถึง 100000

การหาค่าพารามิเตอร์เริ่มต้น	ช่วงตัวเลข	ค่า RMSE	
		ค่าอินพุต 2 ตัวแปร	ค่าอินพุต 3 ตัวแปร
อัลกอริทึมการหาค่าพารามิเตอร์เริ่มต้น	-	8.56	5.59
ค่าสุ่ม	0 ถึง 1	หาค่าไม่ได้	หาค่าไม่ได้
	1 ถึง 100	67.96	หาค่าไม่ได้
	100 ถึง 1000	391.98	51,791.57
	1000 ถึง 10000	3,863.56	450,928.80
	10000 ถึง 100000	52,932.84	479,437.46


4.3 ผลของเงื่อนไขในโครงสร้าง ANFIS

การจำลองการทำนายค่าความเหน็ดมุนนี้ แบ่งออกเป็น 2 ส่วน ได้แก่ ชุดข้อมูลที่ใช้ในการสอนระบบ และชุดข้อมูลทดสอบแบบจำลอง ผลการทดสอบแสดงดังรูปที่ 4.4 และ 4.5 พบว่า


- ค่า RMSE ที่ต่ำสุด มาจากการใช้อินพุต 3 ตัวแปร ได้แก่ อุณหภูมิ ความดัน และกระแสไฟฟ้าไฟ โดยชุดข้อมูลทดสอบ มีค่าเท่ากับ 4.08 มาจากการใช้จำนวนรอบการเรียนรู้ 100 รอบ การดำเนินการวิธีผลรวมของความเป็นสมาชิกฟังก์ชัน ในขณะที่ชุดข้อมูลที่ใช้ในการสอน มีค่า RMSE เท่ากับ 13.45 มาจากการใช้จำนวนรอบการเรียนรู้ 500 รอบการเรียนรู้ การดำเนินการวิธีผลคูณของฟังก์ชันความเป็นสมาชิกกำลังสอง

- โครงสร้าง ANFIS ที่มีอินพุต 3 ตัวแปรให้ประสิทธิภาพที่ดีในแง่ความถูกต้องของการทำนาย ซึ่งสอดคล้องกับผลการจำลองก่อนหน้านี้

- จำนวนรอบการเรียนรู้ไม่ได้ส่งผลอย่างมีนัยสำคัญต่อแบบจำลอง โดยจำนวนรอบการเรียนรู้ที่น้อยของแบบจำลองถือเป็นข้อดีต่อการประมวลผลของแบบจำลอง
- ผลของวิธีการดำเนินการต่อประสิทธิภาพการทำนายของแบบจำลอง พบว่าขึ้นอยู่กับจำนวนของอินพุต ตัวแปรอินพุต และจำนวนรอบการเรียนรู้



รูปที่ 4.4 ค่า RMSE การทำนายค่าความหนืดมูนี้ของชุดข้อมูลสอนระบบที่มีเงื่อนไขที่ใช้ในการจำลองแตกต่างกัน ได้แก่ ค่าอินพุต ประเภทของการตีความ ที่จำนวนรอบการเรียนรู้




รูปที่ 4.5 ค่า RMSE การทำนายค่าความหนืดมุนนี้ของชุดข้อมูลทดสอบระบบที่มีเงื่อนไขที่ใช้ในการจำลองแตกต่างกัน ได้แก่ ค่าอินพุต ประเภทของการตีความ ที่จำนวนรอบการเรียนรู้

4.4 ผลของการอัปเดตฐานข้อมูลจากข้อมูลใหม่

การจำลองการทำนายค่าความหนืดมุนนี้ของ ส่วนการอัปเดตฐานข้อมูลของแบบจำลองด้วยข้อมูลที่เป็นตัวแทนของสูตรยางเก่า และข้อมูลสูตรใหม่ แสดงดังรูปที่ 4.6 พบว่า ค่า RMSE ของการทำนายค่าความหนืดมุนนี้ของแบบจำลองที่มีการอัปเดตฐานข้อมูลด้วยข้อมูลที่ใช้ทดสอบในแต่ละครั้งมีค่าที่มากกว่าการไม่อัปเดตฐานข้อมูล ซึ่งบ่งบอกได้ถึงความสามารถในการปรับตัวของแบบจำลองเมื่อฐานข้อมูลมีการเปลี่ยนแปลงไป นำข้อมูลไปสร้างค่าพารามิเตอร์ส่วนหน้าและส่วนหลังใหม่ เพื่อสามารถทำนายได้ดียิ่งขึ้นในอนาคตที่มีการรับค่าอินพุตต่างที่ใกล้เคียงกับข้อมูลที่อัปเดตฐานข้อมูลลง

ไปใหม่ อย่างไรก็ตามแบบจำลองสามารถทำนายชุดข้อมูลที่มาจากยาสตรเก่าได้ประสิทธิภาพที่ดีกว่าสูตรใหม่



รูปที่ 4.6 ค่า RMSE การทำนายค่าความหนืดมูนี้ที่ทดสอบโดยชุดข้อมูลที่เป็นตัวแทนสูตรยางเก่าและสูตรใหม่ โดยเปรียบเทียบการอัปเดตและไม่อัปเดตฐานข้อมูลด้วยข้อมูลที่ใช้ทดสอบในแต่ละครั้ง


จากนั้นทำการจำลองการอัปเดตฐานข้อมูลด้วยข้อมูลทดสอบที่มีในแต่ละครั้งที่ประกอบด้วยชุดข้อมูลที่เป็นตัวแทนของสูตรใหม่และสูตรยางเก่าอย่างละครึ่ง เพื่อเปรียบเทียบประสิทธิภาพการทำนายทั้งในเชิงความถูกต้องและความแม่นยำ ซึ่งผลการทดลองแสดงในตารางที่ 4.3 และรูปที่ 4.7 พบว่า

- การทำนายค่าความหนืดมูนี้ของแบบจำลองที่มีการอัปเดตฐานข้อมูลด้วยข้อมูลที่ใช้ทดสอบในแต่ละครั้ง มีจำนวน 6 ครั้งที่มีค่า RMSE มีค่าที่น้อยกว่าการไม่อัปเดตฐานข้อมูลซึ่งสอดคล้องกับผลก่อนหน้า โดยชุดข้อมูลของ 6 ครั้งนี้จะถูกนำมาอัปเดตฐานข้อมูลหรือเก็บลงในฐานข้อมูลของแบบจำลอง เพื่อให้แบบจำลองเกิดการปรับตัว เรียนรู้ และสร้างค่าพารามิเตอร์ส่วนหน้าและส่วนหลังใหม่ที่เหมาะสมกับฐานข้อมูลที่อัปเดตใหม่ อย่างไรก็ตามมีจำนวน 2 ครั้งที่มีค่า RMSE มากขึ้นเมื่อทำการอัปเดตข้อมูลในฐานข้อมูล ได้แก่ ครั้งที่ 5 และ 7 ซึ่งจะไม่ทำการอัปเดตฐานข้อมูลชุดข้อมูลทั้ง 2 ครั้งนี้ลงในฐานข้อมูลของแบบจำลอง


- ผลการเปรียบเทียบค่าจริงและค่าการทำนายของชุดข้อมูลทดสอบที่เป็นตัวแทนสูตรยางเก่ามีประสิทธิภาพที่ดีกว่าสูตรใหม่อย่างมีนัยสำคัญ เนื่องจากค่าการทำนายมีค่าเข้าใกล้กับค่าจริงมากกว่า และการเปลี่ยนแปลงไปในทิศทางเดียวกับค่าจริง

ตารางที่ 4.3 ค่า RMSE การทำนายค่าความหนืดมูนี้ที่ทดสอบโดยชุดข้อมูลที่เป็นตัวแทนสูตรยางเก่าและสูตรใหม่ โดยเปรียบเทียบการอัปเดตและไม่อัปเดตฐานข้อมูลด้วยข้อมูลที่ใช้ทดสอบในแต่ละครั้ง

การจำลองครั้งที่	จำนวนข้อมูลในฐานข้อมูล	ค่า RMSE	การอัปเดตฐานข้อมูล
1	2000	18.60	อัปเดตฐานข้อมูล
	2050	17.60	
2	2050	15.72	อัปเดตฐานข้อมูล
	2100	15.39	
3	2100	17.22	อัปเดตฐานข้อมูล
	2150	17.19	
4	2150	17.34	อัปเดตฐานข้อมูล
	2200	16.65	
5	2200	14.63	ไม่อัปเดตฐานข้อมูล
	2250	14.97	
6	2200	15.93	อัปเดตฐานข้อมูล
	2250	15.36	
7	2250	17.45	ไม่อัปเดตฐานข้อมูล
	2300	17.59	
8	2250	19.13	อัปเดตฐานข้อมูล
	2300	18.75	



รูปที่ 4.7 การเปรียบเทียบระหว่างความเหน็ดเหนื่อยที่ค่าจริงและค่าทำนายของชุดข้อมูลที่เป็นตัวแทนของสูตรใหม่และสูตรยางเก่าอย่างละครั้ง และประสิทธิภาพการทำนายในเชิงความถูกต้องและความแม่นยำ



รูปที่ 4.7 การเปรียบเทียบระหว่างความเหน็ดเหนื่อยที่ค่าจริงและค่าทำนายของชุดข้อมูลที่เป็นตัวแทนของสูตรใหม่และสูตรยางเก่าอย่างละครั้ง และประสิทธิภาพการทำนายในเชิงความถูกต้องและความแม่นยำ (ต่อ)

บทที่ 5

สรุปผลและข้อเสนอแนะ

5.1 สรุปผล

ค่าความหนีตมุนนี้เป็นค่าที่บ่งบอกคุณภาพของยางคอมพาวด์ ใช้เวลาการทดสอบมากกว่า 4 ชั่วโมงต่อแบบท์ จากการศึกษาการทำนายค่าความหนีตมุนนี้ของยางคอมพาวด์ และออกแบบแบบจำลองทำนายค่าความหนีตมุนนี้ของยางคอมพาวด์ ประกอบด้วย 3 ส่วน ได้แก่ ฐานข้อมูล การเริ่มต้นพารามิเตอร์ และการทำนาย จากผลการจำลองการทำนายของแบบจำลอง พบว่า ฐานข้อมูลส่งผลต่อประสิทธิภาพการทำนาย และการประมวลผลของแบบจำลอง อัลกอริทึมการเริ่มต้นพารามิเตอร์สามารถปรับตัว และสร้างชุดพารามิเตอร์ส่วนหน้า และส่วนหลัง ได้ตามฐานข้อมูลที่มีการอัปเดตหรือเปลี่ยนไป โดยไม่ขึ้นกับความไม่แน่นอนของผู้ปฏิบัติงานหรือวิธีการสุ่ม ตัวแปรอินพุตที่เปลี่ยนแปลงก็ส่งผลต่อประสิทธิภาพการทำนายทั้งในด้านความถูกต้อง และความแม่นยำ อย่างไรก็ตาม การใช้ตัวแปรอินพุตค่ากระแสไฟฟ้าให้ประสิทธิภาพที่ต่ำสุด แต่เมื่อนำไปใช้ร่วมกับตัวแปรอินพุตอื่นๆ ในการทำนาย สามารถให้ประสิทธิภาพการทำนายที่ดีขึ้น เนื่องจากมีค่าการทำนายใกล้เคียงกับค่าจริงมากกว่าการใช้ตัวแปรร่วมที่ไม่มีค่ากระแสไฟฟ้า ในทางตรงกันข้ามจะพบว่าบางชุดข้อมูลมีค่าความแตกต่างค่อนข้างมากกว่า ซึ่งในการนำไปใช้งานจริง ขึ้นอยู่กับการพิจารณาและวิธีการจัดการกรณีที่พบการทำนายที่มีความผิดพลาดสูง ตัวแปรกระแสไฟฟ้าเหมาะกับการต้องการความแม่นยำสูง แต่ยอมรับความผิดพลาดที่มากได้เช่นกัน กรณีที่ไม่มีตัวแปรกระแสไฟฟ้าเหมาะกับการต้องการความแม่นยำปานกลาง และยอมรับข้อผิดพลาดได้เล็กน้อย ผลของจำนวนรอบการเรียนรู้ที่น้อย บ่งบอกถึงความเร็วในการประมวลผลของแบบจำลอง ผลของวิธีการดำเนินการขึ้นอยู่กับจำนวนตัวแปรอินพุต และจำนวนรอบการเรียนรู้ การอัปเดตฐานข้อมูลของแบบจำลองเพื่อให้เกิดการปรับตัวและสร้างค่าพารามิเตอร์ส่วนหน้าและส่วนหลังได้ตามข้อมูลที่เปลี่ยนแปลงไป โดยข้อมูลอินพุตที่มีรูปแบบเหมือนหรือใกล้เคียงกับฐานข้อมูลของแบบจำลองมีประสิทธิภาพในการทำนายที่มีความถูกต้องและแม่นยำใกล้เคียงกับค่าจริงมากกว่ารูปแบบอินพุตที่ไม่มีข้อมูลในฐานข้อมูลของแบบจำลอง

งานวิจัยนี้นำเสนอแบบจำลองการทำนายค่าความหนีตมุนนี้ของยางคอมพาวด์ทันทีที่เสร็จสิ้นกระบวนการผสม สามารถเป็นประโยชน์ต่อโรงงานผลิตยางคอมพาวด์ที่มีการบันทึกค่าการเปลี่ยนแปลงต่างๆ ในกระบวนการผสม เนื่องจากช่วยเพิ่มประสิทธิภาพด้านการจัดการในโรงงาน และระบบการประกันคุณภาพ ส่งผลให้ต้นทุนการผลิตลดลง อีกทั้งแบบจำลองยังสามารถปรับตัวไปตามข้อมูลที่เปลี่ยนแปลงไปในอนาคตได้

5.2 ข้อเสนอแนะ

1) ปัญหาความแปรปรวนที่สูงของการทำนายเมื่อใช้ค่ากระแสไฟเป็นอินพุต อาจมาจากค่าความแตกต่างของข้อมูลจริงที่มีค่าตั้ง 40 จนถึง 760 ซึ่งมีช่วงข้อมูลที่กว้างกว่าตัวแปรอีก 2 ตัว ในการปรับปรุงประสิทธิภาพจากการคำนวณให้อยู่ในรูปกำลังไฟฟ้า (Power Consumption) เพื่อลดความแตกต่างของช่วงข้อมูล

2) แบบจำลองนี้เน้นการนำไปใช้ในการทำนายค่าความหนืดมูนี้ของยางในหลายๆ สูตร จึงมีประสิทธิภาพความแม่นยำที่ไม่สูงมาก อย่างไรก็ตาม การปรับปรุงประสิทธิภาพโดยการแบ่งแยกแบบจำลองที่มีฐานข้อมูลใกล้เคียงกับสภาวะที่จะนำไปใช้ทำนายจริง อาจช่วยเพิ่มประสิทธิภาพการทำนายได้ดียิ่งขึ้น



TNIT

บรรณานุกรม

TNI

บรรณานุกรม

- [1] P. M. Visakh et al., *Advances in Elastomers II (Advanced Structured Materials)*, New Jersey : Pearson Prentice Hall, 2013.
- [2] พรจิต ประทุมสุวรรณ, *การควบคุมแบบฟัซซีลอจิก*, กรุงเทพฯ : ซีเอ็ดดูเคชั่น, 2562.
- [3] S. Merikoski et al., "An adaptive neuro-fuzzy inference system as a soft sensor for viscosity in rubber mixing process," *Advances in Neural Networks and Applications Journal*, vol. 34, no. 3, pp. 287-291, May-June 2001.
- [4] Y. Diancai et al., "Online prediction of Mooney viscosity in industrial rubber mixing process via adaptive kernel learning method," *Proceedings of the 48th IEEE Conference on Decision and Control, CDC 2009*, Shanghai, China, December 16-18, 2009, pp. 404-409.
- [5] H. Jin et al., "Ensemble just-in-time learning-based soft sensor for mooney viscosity prediction in an industrial rubber mixing process," *Advances in Polymer Technology Journal*, vol. 39, no. 1, pp. 1-14, March-May 2020.
- [6] K. Chen et al., "Sliding-window recursive PLS based soft sensing model and its application to the quality control of rubber mixing process," *International Conference on Intelligence Computation and Applications 2009*, ISICA 2009, Huangshi, China, October 23-25, 2009, pp. 16-24.
- [7] Z. Zhang et al., "A novel nonlinear adaptive mooney-viscosity model based on DRPLS-GP algorithm for rubber mixing process," *Chemometrics and Intelligent Laboratory Systems Journal*, vol. 112, no. 2, pp. 17-23, April 2012.
- [8] K. Yang et al., "Soft sensor development for online quality prediction of industrial batch rubber mixing process using ensemble just-in-time gaussian process regression models," *Chemometrics and Intelligent Laboratory Systems Journal*, vol. 155, no. 1, pp. 170-182, March 2016.
- [9] S. Zheng et al., "Robust soft sensor with deep kernel learning for quality prediction in rubber mixing processes," *Sensors 2020 Journal*, vol. 20, no. 3, pp. 694-703, January 2020.

- [10] S. Butdee and K. Tangchaidee, "Neuro fuzzy based for prediction quality of a rubber curing process on a compression machine under uncertainty circumstances," *Materials Today*, vol. 26, no. 3, pp. 2,953-2,960, November 2020.
- [11] G. Padmavathi et al., "Neural modelling of mooney viscosity of polybutadiene rubber," *Computers & Chemical Engineering Journal*, vol. 29, no. 7, pp. 1,677-1,685, June 2005.
- [12] A. Moghadassi et al., "Application of artificial neural network for prediction of liquid viscosity," *Indian Chemical Engineer Journal*, vol. 52, no. 1, pp. 37-48, April 2010.



ภาคผนวก

TNI

ภาคผนวก ก.

ผลการทดลองเงื่อนไขในโครงสร้าง ANFIS

TNI

ตารางที่ ก.1 ค่า RMSE การทำนายค่าความหนาแน่นของชุดข้อมูลสอนระบบที่มีเงื่อนไขที่ใช้ในการจำลองแตกต่างกัน ได้แก่ ค่าอินพุต ประเภทของการตีความ ที่จำนวนรอบการเรียนรู้

จำนวนรอบการเรียนรู้	จำนวนอินพุต	ตัวแปรอินพุต	ค่า RMSE ของชุดข้อมูลสอนระบบ			
			AND	AND-Squared	OR	OR-Squared
100	2	อุณหภูมิ และกระแสน้ำ	8.04	5.00	4.26	4.18
		อุณหภูมิ และความดัน	6.71	5.70	5.81	5.86
		กระแสน้ำ และความดัน	9.39	8.74	8.03	8.02
	3	อุณหภูมิ ความดัน และกระแสน้ำ	6.27	5.01	4.08	4.45
500	2	อุณหภูมิ และกระแสน้ำ	6.70	4.96	4.54	4.20
		อุณหภูมิ และความดัน	7.57	5.82	5.84	5.94
		กระแสน้ำ และความดัน	9.55	7.68	7.99	7.98
	3	อุณหภูมิ ความดัน และกระแสน้ำ	5.50	5.36	5.12	4.90
1000	2	อุณหภูมิ และกระแสน้ำ	6.16	5.06	4.71	4.28
		อุณหภูมิ และความดัน	8.56	5.95	5.87	5.98
		กระแสน้ำ และความดัน	8.97	7.27	7.97	7.95
	3	อุณหภูมิ ความดัน และกระแสน้ำ	5.59	7.82	4.88	5.91

ตารางที่ ก.2 ค่า RMSE การทำนายค่าความหนาแน่นของชุดข้อมูลทดสอบระบบ ที่มีเงื่อนไขที่ใช้ในการจำลองแตกต่างกัน ได้แก่ ค่าอินพุต ประเภทของการตีความ ที่จำนวนรอบการเรียนรู้

จำนวนรอบการเรียนรู้	จำนวนอินพุต	ตัวแปรอินพุต	ค่า RMSE ของชุดข้อมูลสอนระบบ			
			AND	AND-Squared	OR	OR-Squared
100	2	อุณหภูมิ และกระแส	14.79	14.80	15.27	15.31
		อุณหภูมิ และความดัน	17.50	17.52	17.52	17.52
		กระแส และความดัน	15.83	15.74	16.40	16.36
	3	อุณหภูมิ ความดัน และกระแส	14.34	14.25	15.06	14.80
500	2	อุณหภูมิ และกระแส	14.58	13.99	14.80	14.98
		อุณหภูมิ และความดัน	17.47	17.44	17.51	17.51
		กระแส และความดัน	15.56	15.51	16.21	16.20
	3	อุณหภูมิ ความดัน และกระแส	13.72	13.45	14.64	14.62
1000	2	อุณหภูมิ และกระแส	14.58	13.54	14.68	14.78
		อุณหภูมิ และความดัน	17.47	17.42	17.51	17.49
		กระแส และความดัน	15.60	15.36	16.07	16.07
	3	อุณหภูมิ ความดัน และกระแส	13.46	14.06	14.58	14.43

ภาคผนวก ข.
บทความการประชุมวิชาการ

TNI

Comparative Study of Mooney Viscosity Prediction Models for Rubber Compounds based on ANFIS with Different Architectures

Palida Sapsiroht
Faculty of Engineering
Thai Nichi Institute of Technology
Bangkok, Thailand
sa.palida_sl@tni.ac.th

Kanticha Kittipeerachon
Computer Engineering, Robotics and Technology Laboratory
Thai Nichi Institute of Technology
Bangkok, Thailand
kanticha@tni.ac.th

Abstract— Mooney viscosity is an important parameter in rubber compound industry because it is one of the processing windows and key properties of a rubber compound. As dynamic behaviors of rubber compounds are nonlinear and rubber product manufacturing process affects dynamic behaviors, an exact model for predicting Mooney viscosity has not been found. This paper presents the prediction models based on Adaptive Neuro-Fuzzy Inference Systems (ANFIS) for rubber compounds with different architectures and the effects of changes of certain parameters in each model on prediction performance. The database is collected from the historical data of manufacturing and then cleansed by removing errors in process and out-of-spec values. Both premise and consequent parameters of rules are created using the parameter initialization algorithm. The effects of different numbers of inputs and epochs, different input variables, and different interpretation methods are investigated. The simulation results show that the minimum value of RMSE for data testing is obtained by using the parameters initialization algorithm with 100 epochs, 3 inputs and OR interpretation method. Moreover, the lower number of epochs indicates the faster processing of the model. It is expected that the Mooney viscosity can be predicted and shown immediately at the end of mixing process.

Keywords—Mooney viscosity, ANFIS, rubber compounds, prediction model, fuzzy

I. INTRODUCTION

Rubber is a material used in everyday life and industries such as tires, auto parts, gloves, tubes, soles, etc. The manufacturing process of rubber product is divided into 5 stages consisting of formulation design, mixing, forming, vulcanization and finishing as shown in Fig. 1. Mixing is an important step which dictate the properties of final product. To achieve superior properties of product, the raw rubber must be well mixed with all chemicals obtaining good dispersion and distribution of the mixture. Therefore, the rubber mixing process is separated into 2 steps. Firstly, both filler and activator are mixed with raw rubber. The product of the first-step is generally called a masterbatch. Then, it is mixed with accelerators and curatives. The resulting product is known as rubber compounds [1]. However, before producing a second-step, the quality of a masterbatch such as dispersion of chemicals in rubber, specific gravity, and Mooney viscosity must pass the quality standard. Thus, measurements of these properties are necessary. The testing time of both dispersion and specific gravity are about 2 minutes, while the Mooney viscosity testing time is about 5 minutes but the sample test will be ready to measure after the mixing process ends for around 4 hours owing to both chemical and physical mechanisms. Hence, the efficiency of the compound's Mooney viscosity measurement will be




Fig. 1. The manufacturing process of rubber product.

improved if the Mooney viscosity can be known immediately after the end of the mixing process.

The manufacturing processes usually create a lot of new data which utilize along with the prediction model to address business problem and improve process capability [2-4]. Many research works have presented Mooney viscosity prediction models which can be applied in the rubber compound factory based on the Adaptive Neuro-Fuzzy Inference System (ANFIS), Kernel Learning-based Regression (KLR), Partial Least Squares regression (PLS), and Gaussian Process Regression (GPR). [5] proposed an ANFIS with 2 inputs, which are temperature and torque, and found that the inputs affect the Mooney viscosity. An Adaptive Kernel Learning (AKL) algorithm is used in [6] because it is suitable for Mooney viscosity's behavior which is non-linear. Furthermore, KL algorithm is also developed in [7] to make the prediction performance better by using the Ensemble Deep Correntropy Kernel Regression (EDCKR) which includes the ensemble learning, deep brief network and kernel regression. [8] proposed the sliding-window recursive PLS based soft sensing model. The algorithm can be adapted to follow the processing variables and the prediction performance is better than the traditional PLS. Besides, [9] demonstrated that the material rheology factor improves the prediction performance. The Ensemble Just-In-Time Gaussian Process Regression (EJITGPR) models are studied in [10]. Moreover, [11] developed the algorithm by adding the learning pattern of disturbance and found that the prediction performance is improved.

This paper presents a Mooney viscosity prediction model of rubber compound based on ANFIS. The influences of parameters measured at the end of the mixing process and the ANFIS structures with different numbers of inputs, epochs of learning, and interpretation methods are studies.

II. ADAPTIVE NEURO-FUZZY INFERENCE SYSTEM (ANFIS)

A. Input Selection

In the rubber compound industry, several parameters are measured in the mixing process, i.e. temperature, current, pressure, and rotor speed. In this research, input variables selected from the measured parameters at the end of mixing

process are temperature, current, and pressure since these parameters relate to the behavior of rubber's Mooney viscosity, whereas rotor speed is predetermined according to rubber formulation.

B. ANFIS Architectures

The architectures of ANFIS for two input variables and three input variables are studied in this research as shown in Fig. 2. The architectures are divided into 5 layers. There are 3 levels of membership functions (low, medium and high) for each input variable for both architectures, 9 rules for 2-input and 27 rules for 3-input architecture. The output of the node in each respective layer is represented by $O_{L,N}$ where L and N are the layer number and the node number, respectively. A forward pass for finding the output of each layer can be described as follows:

Layer 1 creates degree of the membership function of the input variable as

$$O_{1,N_1} = \mu_{level}(x_i) \quad (1)$$

where x_i is the input variable, $\mu_{level}(x_i)$ is a degree of a membership function in each level of input variable, $N_1 = 1, 2, \dots, 3n$, $i = 1, 2, \dots, n$, and n is the number of input variables.

Layer 2 generates the firing strength of fuzzy rules as obtained by

$$O_{2,N_2} = \text{Interpretation}(\mu) \quad (2)$$

where $\text{Interpretation}(\mu)$ is the interpretation method of the rule's antecedent part, and $N_2 = 1, 2, \dots, 3^n$.

Layer 3 normalizes the output from Layer 2 as given by

$$O_{3,N_3} = \frac{O_{2,N_2}}{\sum_{N_2=1}^{3^n} O_{2,N_2}} \quad (3)$$

where $N_3 = 1, 2, \dots, 3^n$.

Layer 4 calculates the output of each rule as given by

$$O_{4,N_4} = O_{3,N_3} (p_{N_4} x_1 + q_{N_4} x_2 + \dots + s_{N_4} x_n + t_{N_4}) \quad (4)$$

where $N_4 = 1, 2, \dots, 3^n$, and p_{N_4} , q_{N_4} , $\dots$, t_{N_4} are the consequent parameters of the rule's consequent part.

Layer 5 finds the sum of all outputs from Layer 4 to obtain the Mooney viscosity value as

$$O_{5,N_5} = \sum_{N_4=1}^{3^n} O_{4,N_4} \quad (5)$$

where $N_5 = 1$.




Fig. 2. ANFIS architectures: (a) for two inputs, and (b) for three inputs

A backward pass for updating both premise and consequent parameters is derived by using the chain rule as

$$\frac{\partial E}{\partial P_{pr,N_{pr}}} = \frac{\partial E}{\partial O_{5,N_5}} \frac{\partial O_{5,N_5}}{\partial O_{4,N_4}} \frac{\partial O_{4,N_4}}{\partial O_{3,N_3}} \frac{\partial O_{4,N_4}}{\partial O_{2,N_2}} \frac{\partial O_{4,N_4}}{\partial O_{1,N_1}} \frac{\partial O_{4,N_4}}{\partial P_{pr,N_{pr}}} \quad (6)$$

for the premise parameter and

$$\frac{\partial E}{\partial P_{co,N_{co}}} = \frac{\partial E}{\partial O_{5,N_5}} \frac{\partial O_{5,N_5}}{\partial O_{4,N_4}} \frac{\partial O_{4,N_4}}{\partial P_{co,N_{co}}} \quad (7)$$

for the consequent parameter, where E is the squared error defined by

$$E = \frac{1}{2} (O_{5,N_5} - y)^2 \quad (8)$$

where P_{pr} is the premise parameter, P_{co} is the consequent parameter, $N_{pr} = 1, 2, \dots, 3n$ and $N_{co} = 1, 2, \dots, 3^n$, and y is the actual value of Mooney viscosity.

Substituting (1) to (5) and (8) into (6) and (7), the updated value of each parameter is obtained as

$$P(t+1) = P(t) - \frac{\eta}{2D} \sum_{j=1}^D \frac{\partial E_j}{\partial P} \quad (9)$$

where P is the value of parameter, t' represents the previous value of the parameter, η is the learning rate, and D is the number of input patterns.

III. MOONEY VISCOSITY PREDICTION MODEL DESIGN

The Mooney viscosity prediction model consists of 3 parts: the data preparation, the parameters initialization, and the ANFIS design, as shown in Fig. 3.

A. Data Preparation

The dataset is collected from 12 compounds formulations, 2400 batches which cover several Mooney viscosity's patterns. The collected data is then cleansed for later use by removing errors in process and out-of-spec values.

B. Parameter Initialization

This section presents algorithms for initializing two-parameter sets of the ANFIS architecture. The first set is the premise parameters of a membership function. In this work, the Gaussian function expressed as

$$\mu = e^{-\frac{(x-c)^2}{2\sigma^2}} \quad (10)$$

where c and σ are center and width of the function curve, respectively as shown in Fig. 4 is used for all membership functions since this function corresponds to the Mooney viscosity behavior when the input variable changes.

For this function, the premise parameters, which are c and σ can be calculated as

$$c_{low} = x_{min} + 5\% \quad (11)$$

$$c_{high} = x_{max} - 5\% \quad (12)$$

$$c_{med} = \frac{c_{high} - c_{low}}{2} \quad (13)$$

$$\sigma = \sqrt{\frac{-(x-c)^2}{2 \ln(\%OL)}} \quad (14)$$

where c_{low} , c_{high} and c_{medium} are the c parameter of low, high, and medium levels of membership function, respectively. x_{min} and x_{max} are the minimum and maximum values of each input variable, respectively. %OL is the percent of overlap between the adjacent membership function curves.

The second parameter set is the consequent parameters that are used in the rule's consequent part in Layer 4 of ANFIS. There are 3 consequent parameters which are p , q , and t for 2-input architecture, and 4 parameters p , q , s and t for 3-input architecture. The number of each of consequent parameters in each ANFIS




Fig. 3. The mooney viscosity prediction model framework.




Fig. 4. Gaussian function curve for each input variable.

architecture is equal to the number of rules as given by

$$r = 3^n \quad (15)$$

where r is the number of rules. The input datasets of database are grouped into rules by level of membership function. The ranges of low, medium and high levels for each input variable can be expressed as

$$R_{x_i,low} = c_{x_i,low} - \sqrt{-2\sigma_{x_i}^2 \ln \varepsilon} \text{ to } c_{x_i,low} + \sqrt{-2\sigma_{x_i}^2 \ln \varepsilon} \quad (16)$$

$$R_{x_i,med} = c_{x_i,med} - \sqrt{-2\sigma_{x_i}^2 \ln \varepsilon} \text{ to } c_{x_i,med} + \sqrt{-2\sigma_{x_i}^2 \ln \varepsilon} \quad (17)$$

$$R_{x_i,high} = c_{x_i,high} - \sqrt{-2\sigma_{x_i}^2 \ln \varepsilon} \text{ to } c_{x_i,high} + \sqrt{-2\sigma_{x_i}^2 \ln \varepsilon} \quad (18)$$

where $R_{x_i,level}$ is range of the membership function in each level, and ε is a constant that should be sufficiently small. The first two and three variables of consequent parameters for 2-input and 3-input architectures, respectively in each rule can then be calculated by solving the following linear equation for p and q (2-input) or for p , q and s (3-input)

$$\begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_{D_r} \end{bmatrix}_{D_r \times 1} = \begin{bmatrix} x_{1,1} & x_{2,1} & \cdots & x_{n,1} \\ x_{1,2} & x_{2,2} & \cdots & x_{n,2} \\ \vdots & \vdots & \ddots & \vdots \\ x_{1,D_r} & x_{2,D_r} & \cdots & x_{n,D_r} \end{bmatrix}_{D_r \times n} \begin{bmatrix} p \\ q \\ \vdots \\ s \end{bmatrix}_{n \times 1} \quad (19)$$

where D_r is the number of datasets that matched the rule. The parameter t in each rule can be found by

$$t = \frac{1}{D_r} \sum_{k=1}^{D_r} t_k \quad (20)$$

which is the average value of t in each rule that obtained by solving the following equation for t .

$$\begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_{D_r} \end{bmatrix}_{D_r \times 1} = \begin{bmatrix} x_{1,1} & x_{2,1} & \cdots & x_{n,1} \\ x_{1,2} & x_{2,2} & \cdots & x_{n,2} \\ \vdots & \vdots & \ddots & \vdots \\ x_{1,D_r} & x_{2,D_r} & \cdots & x_{n,D_r} \end{bmatrix}_{D_r \times n} \begin{bmatrix} p \\ q \\ \vdots \\ s \end{bmatrix}_{n \times 1} + \begin{bmatrix} t_1 \\ t_2 \\ \vdots \\ t_{D_r} \end{bmatrix}_{D_r \times 1} \quad (21)$$

C. ANFIS Design

In this section, several parameters including input variable, epoch of learning, and interpretation method in the ANFIS architectures are varied to observe their effects on the prediction performance. First, the input variables for the 2-input architecture model are classified into temperature and current (T/C), temperature and pressure (T/P), and current and pressure (C/P). Second, epochs of learning in the backward pass for updating both premise and consequent parameters are varied as 100, 500, and 1000. Lastly, the interpretation methods used in Layer 2 are AND-squared, OR, and OR-squared as given by (21), (22), (23) and (24), respectively.

$$O_{2,N_2} = \mu(x_1) \cdot \mu(x_2) \cdots \mu(x_n) \quad (22)$$

$$O_{2,N_2} = \mu^2(x_1) \cdot \mu^2(x_2) \cdots \mu^2(x_n) \quad (23)$$

$$O_{2,N_2} = \mu(x_1) + \mu(x_2) + \cdots + \mu(x_n) \quad (24)$$

$$O_{2,N_2} = \mu^2(x_1) + \mu^2(x_2) + \cdots + \mu^2(x_n) \quad (25)$$

IV. SIMULATION RESULTS AND DISCUSSIONS

The dataset is divided into 2 parts. The first 80% of total data (10 formulas) is used for training, and the remaining 20% (2 formulas) is used for testing the model. The performance of the model is evaluated by the Root Mean Squared Error (RMSE) given by

$$RMSE = \sqrt{\frac{1}{D} \sum_{k=1}^D (O_{5,N_5} - y_k)^2} \quad (26)$$

A. Effects of Input Variables

The results of the actual values and predicted values of Mooney viscosity are shown in Fig. 5. The RMSE values of

testing data for 2-input models including temperature and current (T/C), temperature and pressure (T/P), current and pressure (C/P), and 3-input model consisting of temperature, current, and pressure (T/C/P) are 6.71, 8.04, 9.39, and 6.26, respectively. Among all four patterns of input variables, the T/C/P model provides the best performance in term of RMSE. Similarly, the performance of the T/C model is comparable to that of the T/C/P model. Both patterns of input variables yield the lower RMSE values than the rest patterns of input variables and give only a small gap between the predicted values and the actual values. Instead of using the T/C/P model, the T/C model can be used to decrease model's complexity without a significantly large amount of RMSE difference. Nevertheless, the T/P model which generates the predicted values with small variations compared to the values generated by other models can be an alternative model to reduce model's complexity when its RMSE value can be acceptable.




Fig. 5. Simulation results comparing the actual values and the predicted values of Mooney viscosity: (a) for 2 input variables: temperature and current (T/C), (b) for 2 input variables: temperature and pressure (T/P), (c) for 2 input variables: current and pressure (C/P), and (d) for 3 input variables: temperature, current, and pressure (T/C/P).

B. Effects of Initial Values of Premise and Consequent Parameters

According to the results from the previous section, the T/C and T/C/P models are used in this section. The prediction performances of the models using the proposed algorithm for initializing premise and consequent parameters are compared with the models using random numbers which are divided into 5 ranges, i.e. 0-1, 1-100, 100-1000, 1000-10000, and 10000-100000.

From TABLE I, it can be seen that using the parameter initialization algorithm gives low-numerical values of RMSE. In addition, the T/C/P model shows better performances than the T/C model. N/A value of RMSE in TABLE I indicates that the values of initial parameters obtained are inappropriate to use due to leading to an undefined numerical expression.

TABLE I. MOONEY VISCOSITY'S RMSE VALUES OF MODELS USING THE PROPOSED ALGORITHM AND RANDOM NUMBERS FROM 0 TO 100000 FOR PARAMETER INITIALIZATION.

Parameter initialization	Range of number	RMSE	
		2-input	3-input
Algorithm	-	8.56	5.59
Random	0-1	N/A	N/A
	1-100	67.96	N/A
	100-1000	391.98	51,791.57
	1000-10000	3,863.56	450,928.80
	10000-100000	52,932.84	479,437.46

C. Effects of Interpretation Methods, the Number of Input Variables, and the Number of Epochs

The results are divided into two parts as follows: RMSE values of the testing data and RMSE values of the training data. From Fig. 6 it was observed that

- The minimum value of RMSE of both testing and training data are obtained from the model composed of 3 input variables. For the testing data, the minimum value is 4.08 which is obtained by the model with 100 epochs of learning through OR interpretation method, while the minimum value for training data is 13.45 and derived by the model with 500 epochs of learning through AND-Squared interpretation method.
- The T/C/P models give pretty better performances than other models in term of prediction accuracy which correspond to the results in the previous sections.
- The number of epochs does not greatly affect the model performance. Decreasing the number of epochs is beneficial to model processing.
- Regarding interpretation methods, the prediction performances of each interpretation method depend on the number of input variables and the number of epochs.




Fig. 6. Mooney viscosity's RMSE values of testing data and training data for models with different input variables, and different interpretation methods: (a) for 100 epochs, (b) for 500 epochs, and (c) for 1000 epochs.

V. CONCLUSION

Mooney viscosity is a key quality of rubber compounds, but the testing time is more than 4 hours. The several Mooney viscosity prediction models have been presented. They are divided into three parts including databases, parameter initialization, and prediction. From numerous simulations, it was found that database selection influences the prediction performance and model processing. The parameter initialization algorithm is able to adapt and generate both premise and consequent parameters when database is changed or updated without worker bias and random manner. The input variables also affect the prediction performance whether it is precision, or accuracy. The smaller number of epochs indicates the faster processing. The effect of the interpretation methods depends on the number of input variables and epochs. The model design presented in this study should be useful for a rubber compound manufacturer that records parameters throughout the mixing process. It will help to improve efficiency in manufacturing management and quality assurance while manufacturing cost is reduced.

ACKNOWLEDGMENTS

The authors gratefully acknowledge both financial support and data information from Innovation Group (Thailand) Ltd. as well as the courtesy of the IT department for collecting information to conduct this study.

REFERENCES

- [1] P. M. Visakh, S. Thomas, A. K. Chandra, and A. P. Mathew, Eds. *Advances in Elastomers II* (Advanced Structured Materials). Springer-Verlag Berlin Heidelberg, 2013, pp. X, 428.
- [2] A. Moghadassi, F. Parvizian, and S. M. Hosseini, "Application of Artificial Neural Network for Prediction of Liquid Viscosity," *Indian Chemical Engineer*, vol. 52, no. 1, pp. 37-48, 2010, doi: 10.1080/00194501003759688.
- [3] G. Padmavathi, M. G. Mandan, S. P. Mitra, and K. K. Chaudhuri, "Neural modelling of Mooney viscosity of polybutadiene rubber," *Computers & Chemical Engineering*, vol. 29, no. 7, pp. 1677-1685, 2005, doi: 10.1016/j.compchemeng.2005.02.028.
- [4] S. Butdee and K. Tangchaidee, "Neuro fuzzy based for prediction quality of a rubber curing process on a compression machine under uncertainty circumstances," *Materials Today: Proceedings*, vol. 26, pp. 2953-2960, 2020, doi: 10.1016/j.matpr.2020.02.610.
- [5] S. Merikoski, M. Laurikkala, and H. Koivisto, "An adaptive neuro-fuzzy inference system as a soft sensor for viscosity in rubber mixing process," in *Advances in neural networks and applications*, USA, N. E. Mastorakis, Ed., 2001: World Scientific and Engineering Academy and Society, pp. 287-291.
- [6] Y. Diancai, L. Yi, F. Yugang, and W. Haiqing, "Online prediction of Mooney viscosity in industrial rubber mixing process via adaptive kernel learning method," in *Proceedings of the 48th IEEE Conference on Decision and Control (CDC) held jointly with 2009 28th Chinese Control Conference*, Shanghai, China, 2009: IEEE, doi: 10.1109/CDC.2009.5400936.
- [7] H. Jin *et al.*, "Ensemble Just-In-Time Learning-Based Soft Sensor for Mooney Viscosity Prediction in an Industrial Rubber Mixing Process," *Advances in Polymer Technology*, vol. 2020, pp. 1-14, 2020, doi: 10.1155/2020/6575326.
- [8] K. Chen, M. He, and D. Zhang, "Sliding-Window Recursive PLS Based Soft Sensing Model and Its Application to the Quality Control of Rubber Mixing Process," presented at the Computational Intelligence and Intelligent Systems, 2009.
- [9] Z. Zhang, K. Song, T.-P. Tong, and F. Wu, "A novel nonlinear adaptive Mooney-viscosity model based on DRPLS-GP algorithm for rubber mixing process," *Chemometrics and Intelligent Laboratory Systems*, vol. 112, pp. 17-23, 2012, doi: 10.1016/j.chemolab.2011.12.001.
- [10] K. Yang, H. Jin, X. Chen, J. Dai, L. Wang, and D. Zhang, "Soft sensor development for online quality prediction of industrial batch rubber mixing process using ensemble just-in-time Gaussian process regression models," *Chemometrics and Intelligent Laboratory Systems*, vol. 155, pp. 170-182, 2016, doi: 10.1016/j.chemolab.2016.04.009.
- [11] S. Zheng, K. Liu, Y. Xu, H. Chen, X. Zhang, and Y. Liu, "Robust Soft Sensor with Deep Kernel Learning for Quality Prediction in Rubber Mixing Processes," *Sensors (Basel)*, vol. 20, no. 3, Jan 27 2020, doi: 10.3390/s20030695.



RSNC2019
The 10th Rajamangala Surin National Conference

มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี

ขอมอบเกียรติบัตรนี้ให้ไว้เพื่อแสดงว่า
วราชนนธ์ ชมจิตร และ ดอน แก้วดก

ได้นำเสนอผลงานวิจัยกลุ่ม วิศวกรรมศาสตร์และเทคโนโลยี ภาค บรรยาย
เรื่อง การออกแบบเงื่อนไขการฉีดขึ้นรูปโดยการใส่โปรแกรมจำลอง กระบวนการร่วมกับการทดลอง
เพื่อศึกษาตัวแปรที่มีอิทธิพลต่อคุณสมบัติเชิงกลของ PP

ในการประชุมวิชาการและนำเสนอผลงานวิจัยระดับชาติ ราชชมงคลธัญบุรี ครั้งที่ 10
"วิจัยและนวัตกรรม นำสู่การพัฒนาอย่างยั่งยืน"
ระหว่างวันที่ 19-20 กันยายน 2562
ณ มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี วิทยาเขตสุรินทร์
ให้ไว้ ณ วันที่ 20 กันยายน 2562

(ผู้ช่วยศาสตราจารย์ ดร. สำนวนี เสาวกุล)
รองอธิการบดีประจำวิทยาเขตสุรินทร์



(ผู้ช่วยศาสตราจารย์ ดร. วิโรจน์ ลิ้มไขแสง)
อธิการบดีมหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี



ประวัติย่อผู้วิจัย



ชื่อ – สกุล

นางสาวปาลิดา ทรัพย์ศิริโรจน์

วัน – เดือน – ปี เกิด

30 มิถุนายน 2539

ที่อยู่ปัจจุบัน

99/251 คอนโดยูแอตห้วยหมากสเตชัน

แขวงห้วยหมาก เขตบางกะปิ

กรุงเทพมหานคร 10240

โทรศัพท์มือถือ : 066-164-5391

E-mail : sa.palida_st@tni.ac.th

ประวัติการศึกษา

พ.ศ. 2563

วิศวกรรมศาสตรมหาบัณฑิต สาขาเทคโนโลยีวิศวกรรม

สถาบันเทคโนโลยีไทย-ญี่ปุ่น

พ.ศ. 2561

วิศวกรรมศาสตรบัณฑิต สาขาวิศวกรรมพอลิเมอร์

มหาวิทยาลัยเทคโนโลยีสุรนารี

ประวัติการทำงาน

พ.ศ. 2561 – ปัจจุบัน

Business Assistant & Technical Sales

บริษัท เคมี อินโนเวชั่น จำกัด