

การผสมผสานการเรียนรู้แบบเชิงตื้นและเชิงลึก  
สำหรับการจำแนกประเภทของกลิ่นโดยใช้อะแดปทีฟบูสติง

A HYBRID OF SHALLOW AND DEEP LEARNING  
FOR ODOR CLASSIFICATION BASED ON ADAPTIVE BOOSTING

บุญยวีร์ กรคนิยมชัย

BOONYAWEE GRODNIYOMCHAI

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร  
ปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการคอมพิวเตอร์  
ภาควิชาวิทยาการคอมพิวเตอร์ คณะวิทยาศาสตร์  
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

พ.ศ. 2563

KMITL-2020-SC-D-002-014

การผสมผสานการเรียนรู้แบบเชิงตื้นและเชิงลึก  
สำหรับการจำแนกประเภทของกลิ่นโดยใช้อะแดปทีฟบูสตีง

A HYBRID OF SHALLOW AND DEEP LEARNING  
FOR ODOR CLASSIFICATION BASED ON ADAPTIVE BOOSTING

บุญยวีร์ กรदनียมชัย

BOONYAWEE GRODNIYOMCHAI

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร  
ปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการคอมพิวเตอร์  
ภาควิชาวิทยาการคอมพิวเตอร์ คณะวิทยาศาสตร์  
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

พ.ศ. 2563

KMITL-2020-SC-D-002-014

A HYBRID OF SHALLOW AND DEEP LEARNING  
FOR ODOR CLASSIFICATION BASED ON ADAPTIVE BOOSTING

BOONYAWEE GRODNIYOMCHAI

A THESIS SUBMITTED IN PARTIAL FULFILLMENT OF THE REQUIREMENT FOR THE  
DEGREE OF MASTER OF SCIENCE IN COMPUTER SCIENCE  
DEPARTMENT OF COMPUTER SCIENCE  
FACULTY OF SCIENCE  
KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG  
2020  
KMITL-2020-SC-D-002-014

COPYRIGHT 2020

FACULTY OF SCIENCE

KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG



หัวข้อวิทยานิพนธ์	การผสมผสานการเรียนรู้แบบเชิงตั้งต้นและเชิงลึกสำหรับการ การจำแนกประเภทของกลิ่นโดยใช้อะแดปทีฟบูสตีง
ชื่อนักศึกษา	นายบุญยวีร์ กรदनิยมชัย
รหัสประจำตัว	59605070
ปริญญา	วิทยาศาสตรมหาบัณฑิต
ภาควิชา	วิทยาการคอมพิวเตอร์
พ.ศ.	2563
อาจารย์ที่ปรึกษาวิทยานิพนธ์	ผศ.ดร.สายชล ใจเย็น

### บทคัดย่อ

ในปัจจุบันปัญหากลิ่นเหม็นเป็นปัญหาอันดับต้น ๆ ของมลพิษทางอากาศ โดยเฉพาะอย่างยิ่งในบริเวณพื้นที่โรงงานอุตสาหกรรม แต่การที่จะให้มนุษย์เข้าไปสัมผัสรับรู้กลิ่นโดยตรงอาจจะก่อให้เกิดอันตรายต่อมนุษย์ได้ ดังนั้นผู้วิจัยจึงศึกษาและพัฒนาการเรียนรู้ของเครื่องเพื่อรู้จำกลิ่นและจำแนกประเภทของกลิ่นได้ โดยการผสมผสานการเรียนรู้แบบเชิงตั้งต้นและเชิงลึกสำหรับการจำแนกประเภทของกลิ่นซึ่งมีความสามารถในการรับรู้กลิ่นที่เหนือกว่าจุ่มมนุษย์ ในงานวิจัยนี้ได้ใช้ข้อมูลประเภทของกลิ่นจากสถานีจุ่มอิเล็กทรอนิกส์ทั้งหมด 3 ชุดข้อมูลสำหรับทำการทดลอง โดยชุดข้อมูลแต่ละชุดจะถูกแบ่งออกเป็นชุดข้อมูลฝึกสอนและชุดข้อมูลทดสอบเพื่อเลือกโมเดลการเรียนรู้ของเครื่องแล้วนำมารวมกันเป็นโมเดลการเรียนรู้แบบรวมกลุ่มโดยใช้วิธีอะแดปทีฟบูสตีงเพื่อเพิ่มประสิทธิภาพในการจำแนกประเภทของกลิ่นให้ดียิ่งขึ้น การทดลองถูกทำซ้ำทั้งหมด 10 ครั้งเพื่อหาค่าเฉลี่ยของความถูกต้องของโมเดลที่น่าเสนอ โมเดลการเรียนรู้แบบรวมกลุ่มของซัพพอร์ตเวกเตอร์แมชชีน โมเดลการเรียนรู้แบบรวมกลุ่มของต้นไม้ตัดสินใจ และโมเดลการเรียนรู้แบบรวมกลุ่มของโครงข่ายประสาทเทียมแบบลึกแล้วนำมาเปรียบเทียบกัน จากผลการทดลองจะเห็นว่าโมเดลที่น่าเสนอซึ่งเป็นโมเดลที่ผสมผสานการเรียนรู้แบบเชิงตั้งต้นและเชิงลึก ได้แก่ โมเดลโครงข่ายประสาทเทียมแบบลึก โมเดลซัพพอร์ตเวกเตอร์แมชชีน และโมเดลต้นไม้ตัดสินใจให้ผลค่าความแม่นยำเฉลี่ยที่ดีกว่าโมเดลอื่น

**คำสำคัญ :** การจำแนกประเภทของกลิ่น การเรียนรู้ของเครื่อง การเรียนรู้แบบรวมกลุ่มโครงข่ายประสาทเชิงลึก จุ่มอิเล็กทรอนิกส์

<b>Thesis Title</b>	A Hybrid of Shallow and Deep Learning for Odor Classification Based on Adaptive Boosting
<b>Student Name</b>	Mr. Boonyawee Grodhiyomchai
<b>Student ID</b>	59605070
<b>Degree</b>	Master of Science
<b>Department</b>	Computer Science
<b>Year</b>	2020
<b>Thesis Advisor</b>	Asst. Prof. Dr. Saichon Jaiyen

### **Abstract**

Nowadays, the bad odor is one of the top problems of air pollution especially in industrial areas. However, to let humans directly touch the odor may be harmful to humans. Therefore, the authors have studied and developed machine learning model in order to recognize the odor and to identify the type of odor by combining the shallow and deep learning for odor classification. In this research, three odor data sets from the electronic nose are used to conduct the experiments. Each dataset is divided into training and test set for selecting the machine learning models and combining them together to create the ensemble learning model by using the adaptive boosting method for boosting the efficiency in classification of odor types. The experiments are conducted 10 times. The average accuracies of the proposed model, the ensemble of the support vector machines, the ensemble of the decision trees and the ensemble of the deep neural networks are compared. From the experimental results, it can be seen that the proposed model, which is the combination of shallow and deep learning models including deep neural network model, support vector machine model and decision tree model, gives the better average accuracy than other models.

**Keywords :** Artificial Intelligence , Deep Neural Network , Electronic Nose , Ensemble Learning , Machine Learning , Odor Classification

## กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้จะไม่สำเร็จล่วงไปได้ หากปราศจาก ผศ.ดร.สายชล ใจเย็น อาจารย์ที่ปรึกษาวิทยานิพนธ์ที่ได้ช่วยให้คำแนะนำ ความรู้ในการทำวิทยานิพนธ์ และ ผศ.ดร.กุลสวัสดิ์ จิตขจรวานิช อาจารย์ประจำภาควิชาวิทยาการคอมพิวเตอร์ที่ได้ให้คำแนะนำในการเขียนภาษาอังกฤษสำหรับงานวิจัยเพื่อตีพิมพ์

ขอขอบคุณ รศ.ดร.อนุชิต จิตพัฒนกุล ผู้ทรงคุณวุฒิจากภายนอกสถาบันฯ ประธานกรรมการสอบ และ ผศ.ดร.อนันตพร ทรราชคุณาลัย อาจารย์บัณฑิตประจำภาควิชา กรรมการสอบวิทยานิพนธ์ที่ได้ให้คำแนะนำและชี้แนะจนวิทยานิพนธ์ฉบับนี้สำเร็จล่วง

ขอขอบคุณ ดร.ชัตติยา ชลาพัฒน์ อาจารย์ประจำวิทยาลัยนาโนเทคโนโลยี พระจอมเกล้าลาดกระบัง ที่ได้ให้การสนับสนุนชุดข้อมูลจากสถานีจุมูกอเล็กทรอนิกส์เพื่อใช้ในการจำแนกประเภทของกลิ่น และนักศึกษาระดับชั้นปริญญาตรีวิศวกรรมศาสตร์ วิทยาลัยนาโนเทคโนโลยี พระจอมเกล้าลาดกระบัง นายธนกร ศรีสุวรรณ และนายสุริยา ธรรมชาติ ที่ได้ทำการเก็บรวบรวมข้อมูลจากจุมูกอเล็กทรอนิกส์ในห้องปฏิบัติการเพื่อใช้เป็นส่วนหนึ่งในการทำวิทยานิพนธ์ฉบับนี้

ขอขอบคุณ ดร.เสฏฐนันท์ ทองสุวรรณ และนายนิพัทธ์ คล้ายโพธิ์ รุ่นพี่ระดับชั้นปริญญาเอกที่ได้ให้กำลังใจ คำปรึกษา และคำแนะนำในการทำวิทยานิพนธ์ฉบับนี้

ขอขอบพระคุณครอบครัวที่ได้ให้การสนับสนุนการศึกษาและให้กำลังใจในการสำเร็จการศึกษาในระดับชั้นปริญญาโท

บุญยวีร์ กรดนิยมชัย

# สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ก
บทคัดย่อภาษาอังกฤษ.....	ข
กิตติกรรมประกาศ.....	ค
สารบัญ.....	ง
สารบัญตาราง.....	ฉ
สารบัญรูป.....	ฎ
<b>บทที่ 1 บทนำ.....</b>	<b>1</b>
1.1 ความเป็นมาและความสำคัญของงานวิจัย.....	1
1.2 วัตถุประสงค์ของงานวิจัย.....	2
1.3 ขอบเขตของงานวิจัย.....	2
1.4 ประโยชน์ที่คาดว่าจะได้รับ.....	2
<b>บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง.....</b>	<b>3</b>
2.1 ทฤษฎีที่เกี่ยวข้อง.....	3
2.1.1 การเรียนรู้เชิงลึก.....	3
2.1.1.1 โครงข่ายประสาทเทียมแบบลึก.....	4
2.1.2 การเรียนรู้เชิงต้น.....	5
2.1.2.1 ซัพพอร์ตเวกเตอร์แมชชีน.....	5
2.1.2.2 ต้นไม้ตัดสินใจ.....	6
2.1.2.3 นาอูฟเบย์.....	6
2.1.2.4 วิธีการเพื่อนบ้านใกล้ที่สุด k ตัว.....	7
2.1.2.5 การถดถอยเชิงเส้น.....	7
2.1.2.6 การถดถอยโลจิสติกส์.....	7
2.1.3 การเรียนรู้แบบรวมกลุ่ม.....	8
2.1.3.1 อะแดปทีฟบูสตีง.....	8
2.1.3.2 แกรเดียนบูสตีง.....	9
2.1.3.3 เอกซ์ตรีมเกรเดียนบูสตีง.....	9
2.1.3.4 ป่าแบบสุ่ม.....	9
2.2 จมูกอิเล็กทรอนิกส์.....	10

## สารบัญ (ต่อ)

	หน้า
2.3 งานวิจัยที่เกี่ยวข้อง.....	10
2.3.1 Odour Identification Using Machine Learning Techniques.....	10
2.3.2 Detection of Tax Arrears Based on Ensemble Learning Model....	14
2.3.3 Mixture of Deep CNN-based Ensemble Model for Image Retrieval.....	17
<b>บทที่ 3 วิธีการดำเนินงานวิจัย.....</b>	<b>19</b>
3.1 ชุดข้อมูลที่ใช้ในการวิจัย.....	19
3.2 การเตรียมข้อมูลสำหรับใช้ในการวิจัย.....	22
3.3 การเพิ่มประสิทธิภาพโมเดลโดยใช้การเรียนรู้แบบรวมกลุ่มด้วย วิธีการอะแดปทีฟบูตสตรึง.....	26
3.3.1 การเลือกชุดข้อมูล.....	26
3.3.2 การเลือกโมเดลที่ใช้ในการวิจัย.....	26
3.3.3 การตั้งค่าโครงสร้างให้กับโมเดล.....	65
3.3.3.1 โครงข่ายประสาทเทียมแบบลึก.....	65
3.3.3.2 ซัพพอร์ตเวกเตอร์แมชชีน.....	67
3.3.3.3 ต้นไม้ตัดสินใจ.....	67
3.4 การวัดประสิทธิภาพของโมเดล.....	68
<b>บทที่ 4 ผลการวิจัยและการอภิปรายผล.....</b>	<b>70</b>
4.1 ผลการวิจัย.....	70
4.2 การอภิปรายผล.....	92
<b>บทที่ 5 สรุปผลการวิจัยและข้อเสนอแนะ.....</b>	<b>93</b>
5.1 สรุปผลการวิจัย.....	93
5.2 ข้อเสนอแนะ.....	93
เอกสารอ้างอิง.....	94
ภาคผนวก ก.....	97
ภาคผนวก ข.....	103
ประวัติผู้เขียน.....	110

# สารบัญตาราง

ตารางที่	หน้า
2.1 การคำนวณประสิทธิภาพของทดสอบความสามารถของเทคนิคการเรียนรู้ของเครื่อง เพื่อระบุอะซีโทน และโพรพานอล.....	11
2.2 คุณสมบัติของข้อมูลภาพ.....	15
2.3 ขนาดของชุดข้อมูล.....	17
2.4 การทดสอบความแม่นยำของโมเดลที่แตกต่างกับ 3 ชุดข้อมูล.....	17
2.5 จำนวนตัวอย่างข้อมูล.....	18
2.6 การจำแนกประเภทภาพความแม่นยำด้วยชุดข้อมูล CIFAR-10 และ CIFAR-100.....	18
3.1 เซ็นเซอร์จุ่มอิเล็กทรอนิกส์ที่ใช้ในการตรวจจับของชุดข้อมูลที่ 1.....	19
3.2 เซ็นเซอร์จุ่มอิเล็กทรอนิกส์ที่ใช้ในการตรวจจับของชุดข้อมูลที่ 2.....	20
3.3 เซ็นเซอร์จุ่มอิเล็กทรอนิกส์ที่ใช้ในการตรวจจับของชุดข้อมูลที่ 3.....	21
3.4 จำนวนชุดข้อมูลจากจุ่มอิเล็กทรอนิกส์.....	22
3.5 ตัวอย่างชุดข้อมูลจากจุ่มอิเล็กทรอนิกส์ของชุดข้อมูลที่ 1.....	23
3.6 ตัวอย่างชุดข้อมูลจากจุ่มอิเล็กทรอนิกส์ของชุดข้อมูลที่ 2.....	24
3.7 ตัวอย่างชุดข้อมูลจากจุ่มอิเล็กทรอนิกส์ของชุดข้อมูลที่ 3.....	25
3.8 ประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงต้นของชุดข้อมูลที่ 1.....	27
3.9 ระยะเวลาการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงต้นของชุดข้อมูลที่ 1.....	28
3.10 ประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้แบบรวมกลุ่ม ของชุดข้อมูลที่ 1.....	29
3.11 ระยะเวลาการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้แบบรวมกลุ่ม ของชุดข้อมูลที่ 1.....	30
3.12 ประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึก ในการปรับปรุงชั้นฮิดเดนที่ 1 ของชุดข้อมูลที่ 1.....	31
3.13 ระยะเวลาการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึก ในการปรับปรุงชั้นฮิดเดนที่ 1 ของชุดข้อมูลที่ 1.....	32
3.14 ประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึก ในการปรับปรุงชั้นฮิดเดนที่ 2 ของชุดข้อมูลที่ 1.....	33
3.15 ระยะเวลาการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึก ในการปรับปรุงชั้นฮิดเดนที่ 2 ของชุดข้อมูลที่ 1.....	34



## สารบัญตาราง (ต่อ)

ตารางที่	หน้า
3.32 ประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้แบบรวมกลุ่ม ของชุดข้อมูลที่ 3.....	51
3.33 ระยะเวลาการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้แบบรวมกลุ่ม ของชุดข้อมูลที่ 3.....	52
3.34 ประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึก ในการปรับปรุงชั้นฮิดเดนที่ 1 ของชุดข้อมูลที่ 3.....	53
3.35 ระยะเวลาการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึก ในการปรับปรุงชั้นฮิดเดนที่ 1 ของชุดข้อมูลที่ 3.....	54
3.36 ประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึก ในการปรับปรุงชั้นฮิดเดนที่ 2 ของชุดข้อมูลที่ 3.....	55
3.37 ระยะเวลาการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึก ในการปรับปรุงชั้นฮิดเดนที่ 2 ของชุดข้อมูลที่ 3.....	56
3.38 ประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึก ในการปรับปรุงชั้นฮิดเดนที่ 3 ของชุดข้อมูลที่ 3.....	57
3.39 ระยะเวลาการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึก ในการปรับปรุงชั้นฮิดเดนที่ 3 ของชุดข้อมูลที่ 3.....	58
3.40 ประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึก ในการปรับปรุงชั้นฮิดเดนที่ 4 ของชุดข้อมูลที่ 3.....	59
3.41 ระยะเวลาการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึก ในการปรับปรุงชั้นฮิดเดนที่ 4 ของชุดข้อมูลที่ 3.....	60
3.42 ค่าเฉลี่ยประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้ของเครื่อง.....	61
3.43 ระยะเวลาเฉลี่ยการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้ของเครื่อง.....	61
3.44 การกำหนดฟังก์ชันและพารามิเตอร์ให้กับโมเดล.....	68
4.1 ประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้แบบรวมกลุ่ม ที่เลือกมาใช้ทดลองของชุดข้อมูลที่ 1.....	70
4.2 ระยะเวลาการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้แบบรวมกลุ่ม ที่เลือกมาใช้ทดลองของชุดข้อมูลที่ 1.....	71
4.3 F1 Score การเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 1 ในการทดลองครั้งที่ 1.....	72
4.4 F1 Score การเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 1 ในการทดลองครั้งที่ 2.....	72



## สารบัญตาราง (ต่อ)

ตารางที่	หน้า
4.30 F1 Score การเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 3 ในการทดลองครั้งที่ 4.....	88
4.31 F1 Score การเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 3 ในการทดลองครั้งที่ 5.....	89
4.32 F1 Score การเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 3 ในการทดลองครั้งที่ 6.....	89
4.33 F1 Score การเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 3 ในการทดลองครั้งที่ 7.....	90
4.34 F1 Score การเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 3 ในการทดลองครั้งที่ 8.....	90
4.35 F1 Score การเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 3 ในการทดลองครั้งที่ 9.....	91
4.36 F1 Score การเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 3 ในการทดลองครั้งที่ 10.....	91
4.37 ค่าเฉลี่ยประสิทธิภาพการทำนายประเภทของกลิ้งด้วยโมเดลการเรียนรู้ แบบรวมกลุ่ม.....	92
4.38 ระยะเวลาเฉลี่ยการทำนายประเภทของกลิ้งด้วยโมเดลการเรียนรู้ แบบรวมกลุ่ม.....	92

## สารบัญรูป

รูปที่	หน้า
2.1 โครงสร้างโครงข่ายประสาทเทียมแบบลึก.....	4
2.2 โครงสร้างโครงข่ายประสาทเทียมแบบตื้น.....	5
2.3 โครงสร้างของต้นไม้ตัดสินใจ.....	6
2.4 แผนภาพโครงสร้างของโมเดลการเรียนรู้แบบรวมกลุ่ม.....	8
2.5 Confusion Matrix การจำแนกของอะซิทอนและโพรพานอลด้วยโมเดล ANFIS.....	12
2.6 Confusion Matrix การจำแนกของอะซิทอนและโพรพานอลด้วยโมเดล ANN.....	12
2.7 Confusion Matrix การจำแนกของอะซิทอนและโพรพานอลด้วย โมเดล Quadratic Gaussian.....	13
2.8 Confusion Matrix การจำแนกของอะซิทอนและโพรพานอลด้วย โมเดล Linear Gaussian.....	13
2.9 โครงสร้างของโมเดลการเรียนรู้แบบรวมกลุ่มในการตรวจสอบภาษี.....	14
3.1 แผนภาพโมเดลที่ใช้ในงานวิจัยนี้.....	62
3.2 โครงสร้างโมเดลโครงข่ายประสาทเทียมแบบลึกของชุดข้อมูลที่ 1.....	65
3.3 โครงสร้างโมเดลโครงข่ายประสาทเทียมแบบลึกของชุดข้อมูลที่ 2.....	66
3.4 โครงสร้างโมเดลโครงข่ายประสาทเทียมแบบลึกของชุดข้อมูลที่ 3.....	66

# บทที่ 1

## บทนำ

### 1.1 ความเป็นมาและความสำคัญของปัญหา

กลิ่นเป็นสิ่งเจือปนในอากาศโดยที่มนุษย์สามารถรับรู้ได้ด้วยอวัยวะรับกลิ่นที่เรียกว่า จมูก โดยสามารถรับรู้กลิ่นที่มีความแตกต่างกัน ได้แก่ ไม่มีกลิ่น กลิ่นหอม กลิ่นเหม็น และกลิ่นที่มีพิษ แต่ความสามารถในการจำแนกกลิ่นด้วยจมูกของมนุษย์นั้นมีข้อจำกัด และหากกลิ่นนั้นเป็นกลิ่นที่มีพิษจะก่อให้เกิดอันตรายต่อมนุษย์ได้ โดยข้อมูลในปี พ.ศ. 2559 2560 และ 2561 ของกรมควบคุมมลพิษ แสดงให้เห็นว่า ปัญหาที่ได้รับการร้องเรียนมากที่สุดคือ ปัญหากลิ่นเหม็น คิดเป็นร้อยละ 40 ในปี พ.ศ. 2559 ร้อยละ 46 ในปี พ.ศ. 2560 และร้อยละ 45 ในปี พ.ศ. 2561

ในปี พ.ศ. 2557 และ 2560 การนิคมอุตสาหกรรมแห่งประเทศไทย (กนอ.) ได้ตกลงร่วมมือกับ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง (สจล.) เพื่อศึกษาวิจัยและพัฒนาระบบเครือข่ายจมูกอิเล็กทรอนิกส์ สำหรับเฝ้าระวังและเตือนภัยกลิ่นและสารระเหย ในกลุ่มนิคมอุตสาหกรรมพื้นที่มาบตาพุด จังหวัดระยอง และได้ดำเนินการเก็บข้อมูลกลิ่นเพื่อพัฒนาระบบปัญญาประดิษฐ์สำหรับระบบรู้จำและแยกแยะประเภทของกลิ่น

การรู้จำกลิ่นได้นั้นต้องอาศัยจมูกอิเล็กทรอนิกส์ (Electronic nose) ที่มีความสามารถในการรับกลิ่นที่เสมือนจมูกมนุษย์ และมีประสิทธิภาพที่มากกว่าจมูกมนุษย์ โดยทำการเก็บรวบรวมข้อมูลสัญญาณกลิ่นที่ตรวจจับได้จากจมูกอิเล็กทรอนิกส์และใช้การเรียนรู้ของเครื่อง (Machine Learning) ซึ่งเป็นเทคนิคทางด้านปัญญาประดิษฐ์สำหรับจำแนกประเภทของกลิ่นโดยการนำชุดข้อมูลจากจมูกอิเล็กทรอนิกส์มาฝึกสอนโมเดล

งานวิจัยนี้ทำการเปรียบเทียบประสิทธิภาพการจำแนกประเภทของกลิ่นของโมเดลแบบดั้งเดิม และเลือกโมเดลที่มีประสิทธิภาพมาทำการเรียนรู้แบบรวมกลุ่ม (Ensemble Learning) ที่รวมโมเดลทั้งหมด 3 โมเดล ประกอบไปด้วย การเรียนรู้เชิงลึก (Deep Learning) ได้แก่ โครงข่ายประสาทเทียมแบบลึก (Deep Neural Network: DNN) และการเรียนรู้เชิงตื้น (Shallow Learning) ได้แก่ ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine: SVM) และต้นไม้ตัดสินใจ (Decision Tree) เข้าด้วยกัน เพื่อเพิ่มประสิทธิภาพในการทำนายประเภทให้ได้ดียิ่งขึ้น นอกจากนี้ยังใช้ชุดข้อมูลกลิ่นประเภทอื่น ๆ ที่มีขนาดชุดข้อมูลที่แตกต่างกัน เพื่อแสดงให้เห็นประสิทธิภาพของโมเดล

## 1.2 วัตถุประสงค์ของงานวิจัย

- 1) เพื่อสร้างโมเดลสำหรับจำแนกประเภทของกลืนจากจมูกอิเล็กทรอนิกส์
- 2) เพื่อศึกษาและเปรียบเทียบประสิทธิภาพในการจำแนกประเภทของกลืนจากการเรียนรู้ของเครื่อง
- 3) เพื่อพัฒนาโมเดลการเรียนรู้แบบรวมกลุ่ม (Ensemble Learning) จากการผสมผสานของการเรียนรู้เชิงตื้นและเชิงลึก

## 1.3 ขอบเขตของงานวิจัย

- 1) ใช้ชุดข้อมูลจากจมูกอิเล็กทรอนิกส์ ซึ่งเป็นค่าสัญญาณที่เซ็นเซอร์ตรวจจับกลืนที่มีความหลากหลายของคุณลักษณะ (Attribute) ประเภทของกลืน (Class) ที่แตกต่างกัน โดยมีชุดข้อมูลกลืนที่ใช้ในการวิจัยทั้งหมด 3 ชุดข้อมูล ประกอบไปด้วย ชุดข้อมูลกลืนของแอลกอฮอล์ ชุดข้อมูลกลืนของคุณภาพเนื้อ และชุดข้อมูลกลืนของเนื้อส่วนต่าง ๆ
- 2) เปรียบเทียบค่าความแม่นยำในการจำแนกประเภทของกลืนจากการเรียนรู้ของเครื่องแบบต่าง ๆ ด้วยวิธีการหาค่าความแม่นยำเฉลี่ย โดยดำเนินการทดลองทั้งหมด 10 ครั้งในแต่ละโมเดล
- 3) เปรียบเทียบเวลาที่ใช้ในการดำเนินงานของการจำแนกประเภทของกลืนของการเรียนรู้ของเครื่องแบบต่าง ๆ ด้วยวิธีการหาค่าเฉลี่ยระยะเวลาในการจำแนก โดยดำเนินการทดลองทั้งหมด 10 ครั้งในแต่ละโมเดล
- 4) งานวิจัยนี้มุ่งเน้นที่การประยุกต์ใช้การเรียนรู้แบบรวมกลุ่ม (Ensemble Learning) ด้วยวิธีการแบบอะแดปทีฟบูตสตรึง ซึ่งเป็นการผสมผสานการเรียนรู้เชิงตื้น (Shallow Learning) และการเรียนรู้เชิงลึก (Deep Learning)

## 1.4 ประโยชน์ที่คาดว่าจะได้รับ

- 1) สามารถจำแนกประเภทของกลืนด้วยโมเดลการเรียนรู้ของเครื่องได้อย่างแม่นยำ
- 2) สามารถนำโมเดลการเรียนรู้แบบรวมกลุ่มไปใช้กับประเภทของกลืนอื่น ๆ ได้
- 3) สามารถนำไปประยุกต์ใช้ในการแจ้งเตือนว่ามีกลืนที่แปลกปลอม หรือ เป็นอันตรายให้ผู้ที่เกี่ยวข้องได้รับทราบ

## บทที่ 2

# ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

ในบทนี้จะกล่าวถึงทฤษฎีที่เกี่ยวข้องได้แก่ การเรียนรู้เชิงลึก (Deep Learning) โครงข่ายประสาทเทียมแบบลึก (Deep Neural Network) การเรียนรู้เชิงตื้น (Shallow Learning) ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine) ต้นไม้ตัดสินใจ (Decision Tree) นาอิวเบย์ (Naïve Bayes) วิธีการเพื่อนบ้านที่ใกล้ที่สุด k ตัว (k-Nearest Neighbors) การถดถอยเชิงเส้น (Linear Regression) การถดถอยโลจิสติกส์ (Logistic Regression) การเรียนรู้แบบรวมกลุ่ม (Ensemble Learning) อะแดปทีฟบูสตีง (Adaptive Boosting) แกรเดียนบูสตีง (Gradient Boosting) เอกซ์ตรีมเกรเดียนบูสตีง (Extreme Gradient Boosting) ป่าแบบสุ่ม (Random Forest) จมูกอิเล็กทรอนิกส์ (Electronic Nose) และงานวิจัยที่เกี่ยวข้อง

### 2.1 ทฤษฎีที่เกี่ยวข้อง

#### 2.1.1 การเรียนรู้เชิงลึก (Deep Learning)


การเรียนรู้เชิงลึกเป็นส่วนหนึ่งของการเรียนรู้ของเครื่องที่ใช้การคำนวณแบบหลายชั้นโดยใช้โครงข่ายประสาทเทียม (Artificial Neural Networks) การเรียนรู้สามารถเป็นได้ทั้งการเรียนรู้แบบมีผู้สอน (Supervised Learning) การเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning) และการเรียนรู้แบบเสริมแรง (Reinforcement Learning) โดยทั่วไปของการเรียนรู้เชิงลึกคือ การเรียนรู้ที่ใช้การคำนวณแบบหลาย ๆ ชั้น ข้อมูลอินพุตในแต่ละชั้นได้มาจากผลลัพธ์จากการคำนวณของชั้นก่อนหน้า ทั้งนี้การเรียนรู้เชิงลึกพยายามเรียนรู้ลักษณะของข้อมูลในหลายระดับมากขึ้น นั่นคือ เมื่อมีจำนวนชั้นของการคำนวณมากขึ้น ลักษณะของข้อมูลในชั้นสูง ๆ ก็จะมีมีความซับซ้อนมากขึ้น

สถาปัตยกรรมการเรียนรู้เชิงลึก เช่น โครงข่ายประสาทเทียมแบบลึก (Deep Neural Network) โครงข่ายความเชื่อถือนแบบลึก (Deep Belief Network) โครงข่ายประสาทเทียมแบบวนซ้ำ (Recurrent Neural Network) และโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network) ที่ได้ถูกนำไปใช้กับสาขาต่าง ๆ เช่น คอมพิวเตอร์วิทัศน์ (Computer Vision) การรู้จำเสียง (Speech Recognition) การประมวลผลภาษาธรรมชาติ (Natural Language Processing) การกรองเครือข่ายทางสังคม (Social Network Filtering) เครื่องแปลภาษา (Machine Translation) ชีวสารสนเทศ (Bioinformatics) การออกแบบยา การวิเคราะห์ภาพทางการแพทย์ การตรวจสอบวัตถุ และโปรแกรมเกมกระดาน ซึ่งได้ผลลัพธ์ที่เทียบเท่าและในบางกรณีที่เหนือกว่าผู้เชี่ยวชาญที่เป็นมนุษย์ [4-5]

### 2.1.1.1 โครงข่ายประสาทเทียมเชิงลึก (Deep Neural Network: DNN)

โครงข่ายประสาทเทียมเชิงลึกเป็นโครงข่ายประสาทเทียม (Artificial Neural Network: ANN) ที่มีชั้นฮิดเดน (Hidden Layer) หลายชั้น ซึ่งอยู่ระหว่างชั้นอินพุต (Input Layer) และชั้นเอาต์พุต (Output Layer) โครงข่ายประสาทเทียมแบบลึกสามารถคำนวณทางคณิตศาสตร์เพื่อเปลี่ยนข้อมูลอินพุตให้เป็นผลลัพธ์ที่ต้องการได้ โดยโครงข่าย (network) จะมีการคำนวณแบบหลายชั้นเพื่อหาค่าความน่าจะเป็นของแต่ละผลลัพธ์ ตัวอย่างเช่น DNN ที่ได้รับการฝึกสอนให้จดจำสายพันธุ์สุนัขจะรับภาพที่กำหนดให้และคำนวณความน่าจะเป็นที่สุนัขภายในภาพจะเป็นสายพันธุ์ใด และให้ผลลัพธ์เป็นสายพันธุ์สุนัขที่มีความน่าจะเป็นมากที่สุด


โดยทั่วไปโครงข่ายประสาทเทียมเป็นเทคโนโลยีที่สร้างขึ้นเพื่อจำลองสมองของมนุษย์ โดยเฉพาะการจดจำรูปแบบ ผู้เชี่ยวชาญหลายคนกำหนดว่าโครงข่ายประสาทเทียมแบบลึกเป็นโครงข่ายที่มีชั้นฮิดเดนที่อยู่ระหว่างชั้นอินพุตและชั้นเอาต์พุตมากกว่าหนึ่งชั้น ซึ่งชั้นฮิดเดนแต่ละชั้นจะแทนลำดับชั้นของคุณลักษณะหนึ่ง การใช้งานที่สำคัญอย่างหนึ่งของโครงข่ายประสาทเทียมที่ซับซ้อนเหล่านี้คือ การจัดการกับข้อมูลที่ไม่มีโครงสร้าง ซึ่งการเรียนรู้เชิงลึกเหล่านี้เป็นรูปแบบหนึ่งของการเรียนรู้ของเครื่องที่มีโครงสร้างทั่วไปของโครงข่ายประสาทเทียมเชิงลึกดังรูปที่ 2.1 [6]



รูปที่ 2.1 โครงสร้างโครงข่ายประสาทเทียมแบบลึก

## 2.1.2 การเรียนรู้เชิงตื้น (Shallow Learning)

การเรียนรู้เชิงตื้น เป็นการเรียนรู้ของเครื่องที่มีการคำนวณเพียงแค่ชั้นเดียว เช่น โครงข่ายประสาทเทียม (Neural Network) ที่มีชั้นฮิดเดนเพียงชั้นเดียว ดังรูปที่ 2.2 [7]



รูปที่ 2.2 โครงสร้างโครงข่ายประสาทเทียมแบบตื้น

### 2.1.2.1 ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine)


ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine: SVM) เป็นโมเดลการเรียนรู้แบบมีผู้สอนที่ใช้สำหรับการจำแนกประเภท (classification) และการวิเคราะห์การถดถอย (regression) เมื่อได้รับตัวอย่างการฝึกสอนแต่ละตัว โมเดลจะทำนายว่าเป็นประเภทใดประเภทหนึ่งจากสองประเภท ซึ่งเราจะเรียกว่า การจำแนกประเภทแบบไบนารี

SVM เป็นโมเดลการจำแนกประเภทแบบเชิงเส้น และการเรียนรู้ของ SVM จะเป็นการหาเส้นแบ่ง (Hyperplane) ที่ดีที่สุดที่สามารถจำแนกเอาต์พุตเป็นสองกลุ่ม โดยปกติ Hyperplane ที่ได้จะอยู่กึ่งกลางระหว่างกลุ่มข้อมูลที่กำหนดให้

นอกเหนือจากการจำแนกประเภทแบบเชิงเส้น SVM ยังสามารถทำการจำแนกประเภทแบบไม่เชิงเส้นได้โดยการใช้ฟังก์ชันเคอร์เนล (Kernel Function) เพื่อแปลงข้อมูลไปยังมิติที่สูงขึ้นในปริภูมิคุณลักษณะ (Feature Space) ที่สามารถจำแนกข้อมูลแบบเชิงเส้นได้ [8-10]

### 2.1.2.2 ต้นไม้ตัดสินใจ (Decision Tree)

ต้นไม้ตัดสินใจ (Decision Tree) เป็นเทคนิคการเรียนรู้ของเครื่องแบบมีผู้สอนที่มีโครงสร้างเป็นต้นไม้ที่ใช้ในการตัดสินใจ ซึ่งประกอบไปด้วย โหนดภายในที่ใช้แทนการทดสอบคุณลักษณะ กิ่งที่ใช้แทนผลลัพธ์ของการทดสอบ และโหนดใบที่แทนประเภทของข้อมูล ดังแสดงในรูปที่ 2.3 ต้นไม้ตัดสินใจเป็นโมเดลที่ใช้กันมากที่สุด เนื่องจากมีความเสถียร แม่นยำ และใช้งานง่าย [11]



รูปที่ 2.3 โครงสร้างของต้นไม้ตัดสินใจ

### 2.1.2.3 นาอิวเบย์ (Naïve Bayes)

ตัวจำแนกนาอิวเบย์ (Naïve Bayes) เป็นโมเดลการจำแนกประเภทข้อมูลที่ใช้หลักความน่าจะเป็นซึ่งอยู่บนพื้นฐานของทฤษฎีของเบย์ (Bayes' Theorem) และสมมติฐาน ที่ให้การเกิดของเหตุการณ์ต่าง ๆ เป็นอิสระต่อกัน (Independence)

กำหนดให้  $P(h)$  คือความน่าจะเป็นที่จะเกิดเหตุการณ์  $h$  และ  $P(h|D)$  คือความน่าจะเป็นที่จะเกิดเหตุการณ์  $h$  เมื่อเกิดเหตุการณ์  $D$  จากตัวแปรที่กำหนดและแนวคิดทฤษฎีของเบย์ที่สามารถทำนายเหตุการณ์ที่พิจารณาได้จากการเกิดของเหตุการณ์ต่าง ๆ ได้ดังสมการ

$$P(h|D) = \frac{P(D|h) * P(h)}{P(D)} \quad (2.1)$$

นาอิวเบย์ได้รับการศึกษาอย่างกว้างขวางตั้งแต่ทศวรรษ 1960 และยังคงเป็นวิธีพื้นฐานสำหรับการจำแนกประเภท ตัวอย่างเช่น การจำแนกเอกสารเป็นประเภทใดประเภทหนึ่ง เช่น เป็นสแปมหรือไม่เป็นสแปม ถูกกฎหมายหรือไม่ถูกกฎหมาย กีฬาหรือการเมือง เป็นต้น นอกจากนี้ยังพบในแอปพลิเคชันการวินิจฉัยทางการแพทย์แบบอัตโนมัติ [12]

### 2.1.2.4 วิธีการเพื่อนบ้านที่ใกล้ที่สุด k ตัว (k-Nearest Neighbors)

วิธีการเพื่อนบ้านที่ใกล้ที่สุด k ตัว เป็นวิธีการสำหรับการแก้ปัญหาการจำแนกประเภท (classification) และการวิเคราะห์การถดถอย (regression) โดยการหาข้อมูลที่คล้ายคลึงกับข้อมูลที่สนใจจำนวน k ตัว และดูว่าข้อมูลที่คล้ายคลึงนั้นส่วนใหญ่เป็นประเภทใดก็จะให้คำตอบเป็นประเภทของข้อมูลที่มีจำนวนมากที่สุดใน k ตัวนั้น

โดยการหาระยะห่างระหว่างแต่ละตัวแปร (Attribute) จากจุดหนึ่งไปยังอีกจุดหนึ่งสามารถคำนวณได้จาก Euclidean Distance ดังสมการที่ 2.2

$$\sqrt{\sum_{i=1}^k (x_i - y_i)^2} \quad (2.2)$$

การจำแนกประเภทของ k-NN มีผลลัพธ์เป็นคลาส โดยมีค่าที่ไม่ต่อเนื่อง ข้อมูลจะถูกจัดประเภทตามคะแนนเสียงข้างมากของเพื่อนบ้าน ส่วนการวิเคราะห์การถดถอย ให้เอาต์พุตเป็นค่าสำหรับข้อมูล โดยเป็นการทำนายค่าต่อเนื่อง ค่านี้เป็นค่าเฉลี่ย (หรือค่ามัธยฐาน) ของค่าของเพื่อนบ้านที่ใกล้ที่สุด k ตัว [14-15]

### 2.1.2.5 การถดถอยเชิงเส้น (Linear Regression)

การถดถอยเชิงเส้น เป็นวิธีการทางสถิติอย่างหนึ่งที่ใช้ในการศึกษาความสัมพันธ์ระหว่างตัวแปรตั้งแต่ 2 ตัวขึ้นไป ได้แก่ ตัวแปรต้น (X) และตัวแปรตาม (Y) โดยเป็นความสัมพันธ์แบบเชิงเส้น (Linear) สามารถแบ่งได้เป็น 2 ประเภทคือ Simple Linear Regression ประกอบด้วยตัวแปรต้น 1 ตัว และตัวแปรตาม 1 ตัว เป็นการสร้างรูปแบบสมการคณิตศาสตร์ที่เป็นการพยากรณ์ค่าของตัวแปรตาม เช่น การพยากรณ์ผลการสอบปลายภาค เมื่อทราบผลการสอบกลางภาค และ Multiple Linear Regression ประกอบด้วยตัวแปรต้นตั้งแต่ 2 ตัวขึ้นไป และตัวแปรตาม 1 ตัว เป็นการหาขนาดของความสัมพันธ์และสร้างรูปแบบสมการทางคณิตศาสตร์ที่เป็นการพยากรณ์ค่าของตัวแปรตาม โดยใช้ตัวแปรอิสระที่ศึกษา เช่น ศึกษาความสัมพันธ์ระหว่างอายุ เพศ ปัญหาในการทำงาน ความขัดแย้งในครอบครัว กับความรู้สึกรู้สึกเจ็บปวดของผู้ป่วยในโรงพยาบาลแห่งหนึ่ง เป็นต้น [16]


### 2.1.2.6 การถดถอยโลจิสติกส์ (Logistic Regression)

การถดถอยโลจิสติกส์ เป็นเทคนิคการวิเคราะห์สถิติเชิงคุณภาพ แบ่งได้เป็น 2 ประเภทคือ Binary Logistic Regression ใช้กับตัวแปรตามที่มีสองค่าที่เป็นไปได้ (0 กับ 1) เช่น กลุ่มที่มีเหตุการณ์กับกลุ่มที่ไม่มีเหตุการณ์ และ Multinomial Logistic Regression ใช้กับตัวแปร

ตามที่มีมากกว่า 2 กลุ่ม เช่น โรงพยาบาลมีมาตรฐานการให้บริการสูง ปานกลาง และต่ำ โดยมีเป้าหมายเพื่อทำนายโอกาสที่จะเกิดเหตุการณ์ที่สนใจ [17]

### 2.1.3 การเรียนรู้แบบรวมกลุ่ม (Ensemble Learning)

การเรียนรู้แบบรวมกลุ่ม (Ensemble learning) เป็นเทคนิคที่ใช้ในการพัฒนาโมเดลหลายแบบ เพื่อเพิ่มความแม่นยำในการทำนาย ในการเรียนรู้แบบรวมกลุ่มนั้นตัวจำแนกที่อ่อนแอหลายตัวจะถูก รวมเข้าด้วยกันเพื่อสร้างตัวจำแนกที่แข็งแกร่ง ชุดข้อมูลที่ใช้ในการฝึกสอนตัวจำแนกที่อ่อนแอแต่ละ ตัวนั้นถูกสร้างขึ้นจากชุดข้อมูลดั้งเดิมด้วยวิธีบูตสเตรป ตัวจำแนกที่อ่อนแอจะรวมกันเพื่อสร้าง ผลลัพธ์สุดท้าย โดยมีหลายวิธีในการรวมเอาต์พุตจากตัวจำแนกที่อ่อนแอ เช่น เทคนิค Bagging Boosting และ Stacking [18-19]



รูปที่ 2.4 แผนภาพโครงสร้างของการเรียนรู้แบบรวมกลุ่ม

จากรูปที่ 2.4 แผนภาพโครงสร้างของโมเดลการเรียนรู้แบบรวมกลุ่มเริ่มต้นจากการนำชุดข้อมูล แบ่งเป็นชุดข้อมูลย่อยตามจำนวนตัวจำแนก N ตัว และนำแต่ละชุดข้อมูลย่อยฝึกสอนตัวจำแนกต่าง ๆ และผสมผสานกันเป็นหนึ่งด้วยเทคนิคต่าง ๆ จึงจะได้ผลลัพธ์ออกมา

#### 2.1.3.1 อะแดปทีฟบูตติ้ง (Adaptive Boosting)

อะแดปทีฟบูตติ้ง หรือ AdaBoost เป็นเทคนิคที่ออกแบบมาเพื่อแก้ปัญหาความแม่นยำต่ำ โดยปรับเปลี่ยนผู้เรียนที่อ่อนแอ (weak learners) เป็นผู้เรียนที่แข็งแกร่ง (strong learners) โดยชุดข้อมูล ที่ใช้สำหรับการฝึกสอนจะได้รับการปรับความน่าจะเป็นอย่างต่อเนื่องเพื่อบังคับให้โมเดลมุ่งเน้นไปที่

กลุ่มตัวอย่างที่ไม่ได้จัดประเภท ในบางกรณีอาจทำให้เกิด overfitting มากกว่าอัลกอริทึมการเรียนรู้อื่น ๆ เนื่องจากอะแดปทีฟบูสตีงมีความอ่อนไหวต่อข้อมูลรบกวน (noisy data) และค่าผิดปกติ (outliers) โมเดลในขั้นสุดท้ายอาจกลายเป็นผู้เรียนที่แข็งแกร่งโดยรวมผู้เรียนที่อ่อนแอเข้าด้วยกัน [20-22]

### 2.1.3.2 แกรเดียนบูสตีง (Gradient Boosting)

แกรเดียนบูสตีง เป็นโมเดลที่มีพื้นฐานมาจากต้นไม้ตัดสินใจ ซึ่งใช้สำหรับการแก้ปัญหาการจำแนกประเภทและการถดถอย โดยแกรเดียนบูสตีงจะสร้างต้นไม้เป็นแบบต่อเนื่องกัน อินพุตแต่ละต้นจะเป็นเอาต์พุตของต้นก่อนหน้า โดยมีแนวคิดคือการรวมกลุ่มผู้เรียนที่อ่อนแอเพื่อสร้างผู้เรียนที่แข็งแกร่งในรูปแบบการทำซ้ำเพื่อลดค่าผิดพลาดที่เกิดจากต้นไม้ตัดสินใจก่อนหน้าด้วยอัลกอริทึม Gradient Descent ซึ่งเป็นอัลกอริทึมที่ใช้หาค่าพารามิเตอร์ (สัมประสิทธิ์) ของฟังก์ชันที่ทำให้ค่า cost function มีค่าน้อยที่สุด [23]

### 2.1.3.3 เอกซ์ตรีมแกรเดียนบูสตีง (Extreme Gradient Boosting)

เอกซ์ตรีมแกรเดียนบูสตีง หรือ XGBoost เป็นโมเดลที่มีพื้นฐานจากต้นไม้ตัดสินใจมาฝึกสอนต่อกันหลาย ๆ ต้น โดยที่แต่ละต้นไม้ตัดสินใจจะเรียนรู้จากข้อผิดพลาดของต้นก่อนหน้า ทำให้ความแม่นยำในการทำนายจะแม่นยำมากขึ้นเรื่อย ๆ เมื่อมีการเรียนรู้ของต้นไม้ต่อเนื่องกันจนมีความลึกมากพอ และโมเดลจะหยุดเรียนรู้เมื่อไม่เหลือรูปแบบของข้อผิดพลาดจากต้นไม้ก่อนหน้าให้เรียนรู้

โดยเอกซ์ตรีมแกรเดียนบูสตีงเป็นโมเดลที่ปรับปรุงเพิ่มเติมจากโมเดลแกรเดียนบูสตีงให้มีความสามารถเพิ่มมากขึ้น โดยมีส่วนที่ปรับปรุงเพิ่มขึ้นมาได้แก่ Regularization ช่วยลดการเกิด overfit ได้ Sparse Aware สามารถจัดการกับ missing value อัตโนมัติ Parallelization สามารถทำงานแบบขนานกับจำนวน core ของ CPU ได้ และ Cache Optimization ทำให้สามารถใช้ hardware ได้อย่างมีประสิทธิภาพ [24]

### 2.1.3.4 ป่าแบบสุ่ม (Random Forest)

ป่าแบบสุ่ม เป็นโมเดลที่มีพื้นฐานมาจากการนำต้นไม้ตัดสินใจมารวมกันเป็นการเรียนรู้แบบรวมกลุ่มที่มีต้นไม้ตัดสินใจจำนวนหลาย ๆ ต้น สำหรับการจำแนกประเภท และการถดถอย โดยมีจำนวนต้นไม้ตั้งแต่ 10 ต้น จนถึงมากกว่า 1,000 ต้น หลักการของป่าแบบสุ่มคือ การสุ่มข้อมูลจากชุดข้อมูลทั้งหมด ให้ได้ข้อมูลที่ไม่เหมือนกันออกมา  $n$  ชุด ตามจำนวนต้นไม้ และสร้างโมเดลต้นไม้

ตัดสินใจสำหรับแต่ละชุดข้อมูล จากนั้นทำการรวมผลทำการนายจากแต่ละโมเดล (bagging) เช่น วิธีการ voting ในกรณีการจำแนกประเภท หรือ หาค่าเฉลี่ยในกรณีการถดถอย [25-26]

## 2.2 จมูกอิเล็กทรอนิกส์ (Electronic Nose)

เนื่องจากความสามารถในการระบุประเภทของกลิ่นของมนุษย์นั้นไม่คงที่และมีข้อจำกัด จากปัจจัยกระตุ้นภายนอก ทั้งความอ่อนล้า อารมณ์ สภาพอากาศ หรือ อุณหภูมิ ตั้งแต่ปี พ.ศ. 2525 ได้มีการวิจัยเพื่อพัฒนาเทคโนโลยีที่เรียกว่า จมูกอิเล็กทรอนิกส์ ซึ่งสามารถตรวจจับและจดจำกลิ่นและรสชาติได้ ขั้นตอนของกระบวนการรู้จำนั้นคล้ายกับการดมกลิ่นของมนุษย์และทำหน้าที่เพื่อการระบุ การเปรียบเทียบ การหาปริมาณ และการใช้งานอื่น ๆ รวมถึงการจัดเก็บข้อมูล และการดึงข้อมูล

จมูกอิเล็กทรอนิกส์ เป็นอุปกรณ์ที่มีวัตถุประสงค์เพื่อตรวจจับกลิ่นหรือรสชาติ ในช่วงทศวรรษที่ผ่านมาเทคโนโลยีการตรวจจับทางอิเล็กทรอนิกส์ ได้รับการพัฒนาอย่างมากในทางเทคนิคและเชิงพาณิชย์ ซึ่งการตรวจจับทางอิเล็กทรอนิกส์ หมายถึง ความสามารถในการสร้างความรู้สึกของมนุษย์ โดยใช้อาร์เรย์เซ็นเซอร์และระบบการจดจำรูปแบบ จะช่วยลดข้อจำกัดของการจำแนกกลิ่นของผู้เชี่ยวชาญที่อาศัยประสาทสัมผัส โดยใช้การส่งสัญญาณที่แตกต่างกันของพอลิเมอร์แต่ละชนิดในจุ่มเทียม เพื่อใช้จดจำและจำแนกสารเคมีต่าง ๆ สามารถนำไปประยุกต์ใช้ได้อย่างกว้างขวาง โดยกลิ่นเป็นสารเคมีระเหย (Volatile chemical) ที่มีขนาดโมเลกุลไม่เกิน 300 ดาลตัน (Daltons) ซึ่งมนุษย์และสัตว์จะมีตัวตรวจจับสารเคมีของกลิ่น (olfactory) ที่ส่งสัญญาณไปยังสมองเพื่อประมวลผลว่าเป็นสัญญาณของกลิ่นใด ทั้งนี้การรับรู้กลิ่นเกี่ยวข้องกับปฏิกิริยาน้อยมากเนื่องจากระหว่างกระบวนการรับรู้กลิ่น โมเลกุลของกลิ่นไม่ได้มีการเปลี่ยนแปลง [27-28]

## 2.3 งานวิจัยที่เกี่ยวข้อง

### 2.3.1 Odour Identification Using Machine Learning Techniques

ในปี 2019 Ali M. Abdulshahed ได้ทำการทดสอบความสามารถของเทคนิคการเรียนรู้ของเครื่อง ได้แก่ Adaptive Neuro-Fuzzy Inference System (ANFIS) Artificial Neural Networks (ANNs) Quadratic Gaussian (QG) และ Linear Gaussian (LG) เพื่อระบุสารในอากาศ 2 ชนิดที่แตกต่างกัน ได้แก่ อะซีโตน และโพรพานอล ทำการทดสอบประสิทธิภาพโดยใช้ 4 เกณฑ์ ได้แก่ Root Mean Square Error (RMSE) Nash-Sutcliffe Efficiency Coefficient (NSE) Correlation Coefficient (R) และ Accuracy

โมเดล ANFIS เป็นการนำทฤษฎีฟuzzyลอจิกมาประยุกต์ร่วมกับ Neural Network โดยใช้โครงข่ายประสาทในส่วนของวิธีการ Back-Propagation เพื่อใช้ในการปรับปรุงพารามิเตอร์ส่วนของ antecedent และพารามิเตอร์ส่วนของ consequent ของฟuzzy ส่วนโมเดล ANN ใช้จำนวน 2 Input Layer 3 Hidden Layer ประกอบด้วย 10 เซลล์ประสาทในแต่ละ Hidden Layer และ 1 Output Layer โดยการเลือกจำนวนของเซลล์ประสาทใน Hidden Layer เป็นสิ่งสำคัญสำหรับการค้นหาโครงสร้างของโมเดล ANN ที่เหมาะสม การเพิ่มจำนวนเซลล์ประสาทใน Hidden Layer อาจช่วยปรับปรุงประสิทธิภาพของโครงข่ายประสาท

ตารางที่ 2.1 การคำนวณประสิทธิภาพของทดสอบความสามารถของเทคนิคการเรียนรู้ของเครื่องเพื่อระบุอะซีโทน และโพรพานอล

โมเดล	ดัชนีวัดประสิทธิภาพ			
	R	RMSE	NSE	Accuracy
ANFIS	0.92	0.18	0.86	96.6%
ANN	0.89	0.20	0.82	91.8%
Quadratic	0.55	0.42	0.25	82.0%
Linear	0.53	0.42	0.22	81.0%

จากผลการทดลองและค่าการประเมินในตารางที่ 2.1 จะเห็นชัดว่า โมเดล ANFIS มี RMSE ที่น้อยกว่า ค่า NSE 0.86 มีค่าที่สูงที่สุด ความแม่นยำ 96.6% ที่มากที่สุด และค่า R ที่มากที่สุดเมื่อเทียบกับ ANN, QG และ LG ส่วนโมเดล ANN สามารถแยกแยะสารในอากาศที่เป็นไปได้ และมีประสิทธิภาพที่ดีกว่าโมเดล QG และ LG จะสังเกตได้ว่าโมเดลที่ใช้ปัญญาประดิษฐ์มีประสิทธิภาพสูงกว่าโมเดลที่เป็นประเภท Gaussian เนื่องจาก Gaussian มีความไม่ซับซ้อนเมื่อเทียบกับโมเดลอื่น ๆ อย่างไรก็ตามโมเดล ANN ได้ทำปรับปรุงประสิทธิภาพในการจำแนกให้สูงกว่า 95% ด้วยการปรับจำนวนพารามิเตอร์ของโมเดล ANN ให้มาก โมเดล ANN ต้องมีการปรับปรุงเซลล์ประสาทใน Hidden Layer เพื่อให้ได้ประสิทธิภาพในการจำแนกที่ดี

จากรูปที่ 2.5 – 2.8 เป็น Confusion Matrix การจำแนกของอะซีโทนและโพรพานอลด้วยโมเดล ANFIS ANN QG และ LQ ตามลำดับ

Output Class	0	1628 58.5%	62 2.2%	96.3% 3.7%
	1	33 1.2%	1059 38.1%	97.0% 3.0%
		98.0% 2.0%	94.5% 5.5%	96.6% 3.4%
		0	1	
		Target Class		

รูปที่ 2.5 Confusion Matrix การจำแนกของอะซีโทนและโพรพานอลด้วยโมเดล ANFIS

Output Class	0	1618 58.2%	73 2.6%	95.7% 4.3%
	1	43 1.5%	1048 37.7%	80.9% 3.9%
		97.4% 2.6%	93.5% 6.5%	95.8% 4.2%
		0	1	
		Target Class		

รูปที่ 2.6 Confusion Matrix การจำแนกของอะซีโทนและโพรพานอลด้วยโมเดล ANN

Output Class	0	1470 52.8%	311 11.2%	82.5% 17.5%
	1	191 6.9%	810 29.1%	80.9% 19.1%
		88.5% 11.5%	72.3% 27.7%	82.0% 18.0%
		0	1	
		Target Class		

รูปที่ 2.7 Confusion Matrix การจำแนกของอะซีโทนและโพรพานอลด้วยโมเดล Quadratic Gaussian


Output Class	0	1492 53.6%	353 12.7%	80.9% 19.1%
	1	169 6.1%	768 27.6%	82.0% 18.0%
		89.8% 10.2%	68.5% 31.5%	81.2% 18.8%
		0	1	
		Target Class		

รูปที่ 2.8 Confusion Matrix การจำแนกของอะซีโทนและโพรพานอลด้วยโมเดล Linear Gaussian

ผลการวิจัยพบว่า โมเดล ANFIS อาจเป็นเครื่องมือที่ดีที่สุดสำหรับการจำแนก ซึ่งเป็นสิ่งที่ยากที่จะสำเร็จโดยใช้วิธีการทั่วไป โดยเฉพาะอย่างยิ่งสำหรับปัญหาที่ไม่สามารถแบ่งแยกได้สูง วิธีการที่นำเสนอมีความสามารถในการเรียนรู้อย่างรวดเร็วจากข้อมูลที่นำมาทดลองและความรู้ทางภาษาศาสตร์ และความสามารถในการให้เตรียมการอย่างง่าย โปร่งใส และมีประสิทธิภาพ [1]

### 2.3.2 Detection of Tax Arrears Based on Ensemble Learning Model

ในปี 2018 Anyan Su, Zhimin He, Junjian Su, Yan Zhou, Yun Fan และ Yuan Kong ได้พัฒนาโมเดลสำหรับการตรวจสอบการเก็บภาษีล่วงหน้า หรือการหลีกเลี่ยงการค้างภาษีขององค์กรในปีก่อนหน้า โดยผสมผสานโมเดลพื้นฐานด้วยโมเดลการเรียนรู้แบบรวมกลุ่ม ได้แก่ Multi-Layer Perceptron (MLP) k-Nearest Neighbor (KNN) Random Forest (RF) Extremely Randomized Trees (ET) Gradient Tree Boosting (GTB) และ Extreme Gradient Boosting (XGBoost) ดังรูปที่ 2.9 ซึ่งมีประสิทธิภาพกับข้อมูลภาษีที่ดี



รูปที่ 2.9 โครงสร้างของโมเดลการเรียนรู้แบบรวมกลุ่มในการตรวจสอบภาษี

คุณลักษณะของชุดข้อมูลภาษีถูกแบ่งออกเป็นสองส่วนดังแสดงในตาราง 2.2 คุณลักษณะแรกคือคุณลักษณะที่ไม่ใช่ตัวเลข ค่าของคุณลักษณะที่ไม่ใช่ตัวเลขแต่ละรายการจะถูกแทนที่ด้วยดัชนี (index) หลังจากเรียงลำดับตามจำนวนภาษี และการทำ Normalization ให้คุณลักษณะเป็น  $[0,1]$  ส่วนคุณลักษณะประเภทอื่น ๆ คือคุณลักษณะตัวเลข คุณลักษณะเชิงตัวเลขถูกทำให้เป็นมาตรฐานใน  $[0,1]$  ซึ่งสามารถปรับปรุงความเร็วของวิธีการ gradient descent เพื่อแก้ปัญหาที่ดีที่สุด โดยองค์กรแบ่งออกเป็นสามประเภท ได้แก่ องค์กรปกติ องค์กรที่ค้างชำระภาษีต่ำกว่า 5,000 หยวน และองค์กรที่ค้างชำระภาษีมากกว่า 5,000 หยวน

ตารางที่ 2.2 คุณลักษณะของข้อมูลภาษี

ประเภทของคุณลักษณะ	คุณลักษณะ
คุณลักษณะที่ไม่ใช่ตัวเลข	อุตสาหกรรม
	ภูมิภาค
	ประเภทการลงทะเบียน
	สถานะผู้เสียภาษี
	ระบบบัญชี
คุณลักษณะที่เป็นตัวเลข	ข้อมูลภาษี
	ทุนจดทะเบียน
	จำนวนเงินลงทุน
	กำไร
	ราคา
	รายได้ธุรกิจหลัก
	ต้นทุนธุรกิจหลัก
	กำไรสุทธิ
	รายได้จากการลงทุน
	ค่าใช้จ่ายในการจัดการ
	กำไรจากการดำเนินงาน
	ค่าใช้จ่ายที่ไม่ใช่ธุรกิจ
	รายได้ที่ไม่ใช่ธุรกิจ
	ค่าใช้จ่ายทางการเงิน
	สินทรัพย์ / สินทรัพย์ถาวร
	บัญชีลูกหนี้
	กองทุนสกุลเงิน
สินทรัพย์หมุนเวียน	

ในงานวิจัยนี้ใช้ back propagation เพื่อปรับพารามิเตอร์ของโครงข่ายประสาทเทียมของ MLP โมเดล k-NN กำหนดชื่อของตัวอย่างตามจำนวนตัวอย่าง k ที่ใกล้ที่สุด โดยค่าของพารามิเตอร์ k มีผลต่อประสิทธิภาพ ตัวเลือกที่ดีที่สุดของพารามิเตอร์ k ขึ้นอยู่กับชุดข้อมูล RF เป็นการเรียนรู้แบบกลุ่มควบคู่กันซึ่งประกอบด้วยตัวจำแนกพื้นฐานหลายตัว เมื่อทำการแยกโหนดระหว่างการสร้างต้นไม้ การแยกเป็นการแบ่งที่ดีที่สุดที่จุดย่อยของคุณลักษณะแบบสุ่ม และยังสามารถใช้กับโมเดล ET ด้วยเช่นกัน เมื่อสร้างต้นไม้อันดับแรกจะสร้างเกณฑ์บางอย่างแบบสุ่มจากนั้นเลือกเกณฑ์ที่ดีที่สุดเป็นกฎ

การแยก GTB เป็นหนึ่งในการเรียนรู้แบบรวมกลุ่มที่มีการ boosting โดยมีพื้นฐานมาจากต้นไม้ตัดสินใจ ซึ่งแตกต่างจาก RT ที่ขึ้นอยู่กับค่าเฉลี่ย ของตัวจำแนกพื้นฐาน สุดท้ายคือ XGBoost เป็นโมเดลที่สามารถเพิ่มขนาดที่ปรับขยายได้อย่างมาก เหมาะสำหรับข้อมูลขนาดใหญ่ที่มีการบีบอัดข้อมูล การรวมกลุ่มของโมเดลมีกลยุทธ์ที่แตกต่างกันออกไป ได้แก่

- 1) ค่าเฉลี่ย weight ที่คำนวณจากข้อมูลการฝึกสอน เนื่องจากข้อมูลภายในมี noise มาก weight จะมีการได้รับผลกระทบ
- 2) Stacking ซึ่งใช้ 2 ขั้นตอนในการฝึกสอนโมเดลแบบกลุ่ม
- 3) Voting เป็นวิธีการลงคะแนนโหวต hard-voting และ soft-voting

ในงานวิจัยนี้ใช้วิธีการปรับ soft-voting และค่า weight ความน่าจะเป็นของ input  $x$  ถูกจัดประเภทเป็น  $i^{th}$  class เขียนเป็นสมการได้ดังสมการที่ 2.3

$$p(y_i^*) = \sum_{j=1}^n p_j(x) * w_j \quad (i = 1 \dots m) \quad (2.3)$$

โดยที่  $p_j(x)$  คือ ความน่าจะเป็นของ  $x$  ที่จัดเป็น  $i^{th}$  class โดย base learner ( $j$ )  
 $w_j$  คือ weight ของ  $j^{th}$  base classifier  
 $m$  คือ จำนวน class  
 $n$  คือ จำนวนของ base classifier

ดังนั้น ชื่อ  $x$  เขียนเป็นสมการได้ดังสมการที่ 2.4

$$F^* = \operatorname{argmax}_i p(y_i^*) \quad (2.4)$$

พารามิเตอร์  $w_j$  มีผลกระทบอย่างมากต่อความแม่นยำ จึงต้องใช้ในการฝึกสอนล่วงหน้า (pre-training) เพื่อกำหนด weight

รูปแบบการเรียนรู้แบบกลุ่มที่เสนอเป็นการฝึกสอน 2 ขั้นตอน

- 1) ตัวจำแนกพื้นฐานทั้งหมดได้รับการฝึกสอนล่วงหน้าโดยการตรวจสอบความถูกต้องด้วย

วิธีการ k-fold

- 2) ใช้ตัวจำแนกพื้นฐานที่ฝึกในขั้นตอนที่ 1 เพื่อรับผลลัพธ์จากนั้นคำนวณความน่าจะเป็นของแต่ละคลาสด้วยสมการที่ (2.4)

งานวิจัยนี้ใช้ชุดข้อมูลภาษีจากตำบลหนานไ้ อำเภอฝอซาน มณฑลกว่างตุง สาธารณรัฐประชาชนจีน ในปี 2015 และ 2016 โดยทำการฝึกสอนโมเดลด้วยชุดข้อมูลของปี 2015 ด้วย 70,000

ตัวอย่างข้อมูล และตรวจจับการหลีกเลี่ยงภาษีด้วยชุดข้อมูลทดสอบ 50,000 ตัวอย่างของปี 2016 โดยใช้ชุดการฝึกและทดสอบ 3 ชุดที่มีขนาดแตกต่างกัน ดังแสดงในตารางที่ 2.3

ตารางที่ 2.3 ขนาดของชุดข้อมูล

ชุดข้อมูล	ชุดข้อมูลการฝึกสอน	ชุดข้อมูลการทดสอบ
ชุดข้อมูลที่ 1	10,000	10,000
ชุดข้อมูลที่ 2	40,000	30,000
ชุดข้อมูลที่ 3	70,000	50,000

ในการทดลองดำเนินการกับชุดข้อมูล 3 ชุด โดยชุดแรกมีความแม่นยำสูงในโมเดลที่นำเสนออยู่ที่ร้อยละ 87.4 ชุดข้อมูลชุดที่สองมีความแม่นยำสูงในโมเดลที่นำเสนอร้อยละ 89.3 แต่ชุดข้อมูลชุดที่สาม Random Forest กลับได้ความแม่นยำสูงสุดที่ร้อยละ 90.6 ซึ่งมากกว่าโมเดลที่นำเสนอร้อยละ 0.06% ดังแสดงในตารางที่ 2.4 [2]

ตารางที่ 2.4 การทดสอบความแม่นยำของโมเดลที่แตกต่างกับ 3 ชุดข้อมูล

โมเดล	ชุดข้อมูลที่ 1	ชุดข้อมูลที่ 2	ชุดข้อมูลที่ 3
โมเดลที่นำเสนอ	87.38%	89.32%	90.58%
Extreme Gradient Boosting (XGBoost)	85.32%	82.16%	82.57%
Random Forest (RF)	86.26%	87.11%	<b>90.64%</b>
Multi-Layer Perceptron (MLP)	71.08%	76.40%	80.60%
Gradient Tree Boosting (GTB)	83.74%	83.57%	82.54%
k-Nearest Neighbor (KNN)	81.30%	85.91%	89.72%
Extremely Randomized Trees (ET)	87.38%	89.14%	90.50%

### 2.3.3 Mixture of Deep CNN-based Ensemble Model for Image Retrieval

ในปี 2016 Hsin-Kai H., Chien-Fang C., Chien-Hao K., Yu-Chi W., Narisa N.Y. C. และ Pao-Chi C. ได้เสนอการดึงภาพโดยใช้โมเดล CNN สองโมเดล คือ AlexNet และ Network In Network (NIN) เพื่อรับคุณลักษณะภาพและคำนวณเวกเตอร์เฉลี่ยถ่วงน้ำหนัก โดยการรวมกลุ่มการเรียนรู้ทั้งหมดเพื่อเพิ่มประสิทธิภาพของโมเดล

โมเดลแบบการรวมกลุ่มใช้ชุดข้อมูลภาพสำหรับการประเมินการจำแนกภาพโดยใช้ความแม่นยำและค่าความแม่นยำเฉลี่ย (MAP) เป็นการวัดตามลำดับ การประเมินประสิทธิภาพในการทดลองนี้ได้ใช้

ชุดข้อมูล CIFAR-10 และ CIFAR-100 ประกอบด้วยชุดข้อมูลย่อยที่มีชื่อ 80 ล้านภาพเล็ก ๆ โดยมีจำนวนตัวอย่างข้อมูลดังตารางที่ 2.5

ตารางที่ 2.5 จำนวนตัวอย่างข้อมูล

ชุดข้อมูล	Class	ชุดฝึกสอน	ชุดทดสอบ
CIFAR-10	10	5,000	1,000
CIFAR-100	100	500	100

โมเดลแบบรวมของ AECNN ได้รวมสถาปัตยกรรม CNN 2 โมเดลที่โดดเด่นสำหรับการดำเนินการขนาดใหญ่ (เช่น การทำซ้ำ 20 ครั้ง) เพื่อให้ได้ผลการเรียนรู้ที่ดี โครงข่ายการเรียนรู้แบบลึกสองประเภท: AlexNet และ NIN ได้ผสมผสานรวมอยู่ในการคำนวณเพื่อให้ได้คุณลักษณะเวกเตอร์เฉลี่ยถ่วงน้ำหนัก ดังแสดงในตารางที่ 2.6

ตารางที่ 2.6 การจำแนกประเภทภาพความแม่นยำด้วยชุดข้อมูล CIFAR-10 และ CIFAR-100

โมเดล	ชุดข้อมูล	CIFAR-10	CIFAR-100
	Kuo	79.3%	44.0%
MCDNN	89.8%		
<b>โมเดล CNN</b>			
<b>Aggregate Ensemble CNN Model (AECNN)</b>	<b>90.2%</b>	<b>67.3%</b>	
Base : AlexNet	79.1%	44.0%	
20 AlexNet แบบรวมกลุ่ม	83.8%	50.0%	
Network In Network (NIN)	86.5%	57.7%	
20 NIN แบบรวมกลุ่ม	90.4%	66.7%	

จากตารางที่ 2.6 สังเกตว่า การสร้างโมเดล AECNN ที่โมเดลรวมสามารถให้ความแม่นยำในการจัดหมวดหมู่ที่สูงขึ้น โดยการจับประเภทภาพปกติให้ความแม่นยำสะสมร้อยละ 90.2 จากชุดข้อมูล CIFAR-10 และร้อยละ 67.3 ในชุดข้อมูล CIFAR-100 ซึ่งในชุดข้อมูล CIFAR-100 ได้ให้ผลลัพธ์ที่ดีกว่า AlexNet ที่มีความแม่นยำร้อยละ 79.1 ในชุดข้อมูลแรก และร้อยละ 44 ในชุดข้อมูลที่สอง ขณะเดียวกันเมื่อเปรียบเทียบกับ NIN ได้ผลร้อยละ 86.5 ในชุดข้อมูลแรก และร้อยละ 57.7 ในชุดข้อมูลที่สอง [3]

## บทที่ 3

### วิธีการดำเนินงานวิจัย

ในบทนี้จะกล่าวถึงการจำแนกประเภทของกลิ่นด้วยการผสมผสานการเรียนรู้เชิงต้น และการเรียนรู้เชิงลึก โดยใช้วิธีการอะแดปทีฟบูสติงเพื่อเพิ่มประสิทธิภาพการจำแนกของโมเดลให้ดียิ่งขึ้น

โดยมีขั้นตอนทั้งหมด 4 ขั้นตอน ประกอบไปด้วย ชุดข้อมูลที่ใช้ในการวิจัย การเตรียมข้อมูล การเพิ่มประสิทธิภาพโมเดลโดยการใช้การเรียนรู้แบบรวมกลุ่มด้วยวิธีการอะแดปทีฟบูสติง และการวัดประสิทธิภาพของโมเดล

#### 3.1 ชุดข้อมูลที่ใช้ในการวิจัย

ชุดข้อมูลที่ใช้ในการวิจัยเป็นข้อมูลค่าสัญญาณเซ็นเซอร์จากสถานีจุ่มกิโลกรัมอิเล็กทรอนิกส์ ซึ่งมีทั้งหมด 3 ชุดข้อมูล ประกอบไปด้วย กลิ่นของแอลกอฮอล์ กลิ่นของคุณภาพเนื้อ และกลิ่นของเนื้อส่วนต่าง ๆ โดยชุดข้อมูลที่ 1 ได้รับความร่วมมือจากวิทยาลัยนาโนเทคโนโลยี พระจอมเกล้าลาดกระบัง ในการรวบรวมเก็บข้อมูลในห้องปฏิบัติการโดยมีประเภทของกลิ่นเป็นแอลกอฮอล์ ประกอบไปด้วย ไม่มีกลิ่น (Odorless) กลิ่นเบียร์ (Beer) กลิ่นวิสกี้ (Whisky) และกลิ่นไวน์ (Wine) โดยมีคุณลักษณะของเซ็นเซอร์ที่สามารถตรวจวัดได้ตามตารางที่ 3.1

ตารางที่ 3.1 เซ็นเซอร์จุ่มกิโลกรัมอิเล็กทรอนิกส์ที่ใช้ในการตรวจจับของชุดข้อมูลที่ 1

เซ็นเซอร์	สารระเหยที่เซ็นเซอร์วัดได้
TGS826	เอทานอล แอมโมเนีย และไอโซบิวเทน
TGS832	คาร์บอนไดออกไซด์ (CFC) และเอทานอล
TGS2600	ไฮโดรเจน เอทานอล ไอโซบิวเทน คาร์บอนมอนอกไซด์ มีเทน
TGS2602	โทลูอีน ไฮโดรเจนซัลไฟด์ เอทานอล แอมโมเนีย ไฮโดรเจน
TGS2610	ไอโซบิวเทน มีเทน ไฮโดรเจน เอทานอล
TGS2444	แอมโมเนีย ไฮโดรเจนซัลไฟด์ เอทานอล
TGS4161	คาร์บอนไดออกไซด์

จากตารางที่ 3.1 เป็นเซ็นเซอร์จุ่มก๊อเล็กทรอนิกส์ที่ใช้ในการตรวจจับกลิ่นแอลกอฮอล์ ข้อมูลที่ใช้ในโครงข่ายจุ่มก๊อเล็กทรอนิกส์สำหรับการตรวจสอบกลิ่นและสารระเหยซึ่งเป็นกลิ่นที่ผิดปกติหรือเป็นอันตราย โดยมีเซ็นเซอร์ทั้งหมด 7 ตัวที่มีความสามารถในการตรวจจับที่แตกต่างกันออกไป อย่างไรก็ตามมีเพียงเซ็นเซอร์ TGS4161 ที่ไม่เกี่ยวข้องกับเซ็นเซอร์อื่น ๆ ซึ่งเป็นเซ็นเซอร์ที่ให้ข้อมูลเกี่ยวกับสภาพแวดล้อมทั่วไปในพื้นที่ โดยปกติแล้วจะมีก๊าซคาร์บอนไดออกไซด์อยู่ทุกหนทุกแห่ง

นอกจากนี้ยังได้ใช้ชุดข้อมูลจุ่มก๊อเล็กทรอนิกส์อื่น ๆ จาก Mendeley ซึ่งเป็นเว็บไซต์ที่รวบรวมชุดข้อมูลเพื่อเปิดให้นำไปใช้สำหรับการทดลองวิจัยต่าง ๆ ชุดข้อมูลที่ 2 เป็นข้อมูลกลิ่นคุณภาพเนื้อประกอบไปด้วย คุณภาพดีเยี่ยม (Excellent) ดี (Good) พอรับได้ (Acceptable) และเน่าเสีย (Spoiled) ซึ่งมีคุณลักษณะของเซ็นเซอร์ที่สามารถตรวจวัดได้ตามตารางที่ 3.2 โดยสามารถดาวน์โหลดชุดข้อมูลได้จาก <https://data.mendeley.com/datasets/mwmhh766fc/3>

ตารางที่ 3.2 เซ็นเซอร์จุ่มก๊อเล็กทรอนิกส์ที่ใช้ในการตรวจจับของชุดข้อมูลที่ 2

เซ็นเซอร์	สารระเหยที่เซ็นเซอร์วัดได้
MQ135	แอมโมเนีย ไนโตรเจนไดออกไซด์ แอลกอฮอล์ เบนซีน ควีน และคาร์บอนไดออกไซด์
MQ136	ไฮโดรเจนซัลไฟด์
MQ2	มีเทน บิวเทน และแอลพีจี
MQ3	แอลกอฮอล์ (เอทานอล)
MQ4	มีเทน และก๊าซธรรมชาติ (CNG)
MQ5	แอลพีจี และก๊าซธรรมชาติ
MQ6	แอลพีจี และบิวเทน
MQ8	ไฮโดรเจน
MQ9	คาร์บอนมอนอกไซด์ และก๊าซไวไฟ

จากตารางที่ 3.2 เป็นเซ็นเซอร์จุ่มก๊อเล็กทรอนิกส์ที่ใช้ในการตรวจจับกลิ่นคุณภาพเนื้อ โดยมีเซ็นเซอร์ทั้งหมด 9 ตัวที่มีความสามารถในการตรวจจับที่แตกต่างกันออกไป

และชุดข้อมูลที่ 3 เป็นข้อมูลกลิ่นเนื้อส่วนต่าง ๆ จากเว็บไซต์ Mendeley เช่นเดียวกับชุดข้อมูลที่ 2 ประกอบไปด้วย เนื้อส่วนซี่โครง (Beef ribs) เนื้อส่วนต้นขาหน้า (Beef shank) ออกไก่ (Chicken breast) น่องไก่ (Chicken drumsticks) หมูสามชั้น (Pork belly) และขาหมู (Pork legs) ซึ่งชุดข้อมูลมีคุณลักษณะของเซ็นเซอร์ที่สามารถตรวจวัดได้ตามตารางที่ 3.3 โดยสามารถดาวน์โหลดชุดข้อมูลได้จาก <https://data.mendeley.com/datasets/kcy29m3zzz/1>

ตารางที่ 3.3 เซ็นเซอร์จุ่มกิโลอิเล็กทรอนิกส์ที่ใช้ในการตรวจจับของชุดข้อมูลที่ 3

เซ็นเซอร์	สารระเหยที่เซ็นเซอร์วัดได้
TGS822	เอทานอล และตัวทำละลายอินทรีย์
TGS2612	มีเทน บิวเทน และโพรเพน
TGS2620	แอลกอฮอล์ และตัวทำละลายอินทรีย์
TGS832	คาร์บอนฟลูออไรด์คาร์บอน (CFC) และเอทานอล
TGS826	เอทานอล แอมโมเนีย และไอโซบิวเทน
TGS2603	ไตรเมทิลามีน และเมอร์แคปแทน
TGS2600	ไฮโดรเจน และเอทานอล
TGS813	มีเทน และบิวเทน

จากตารางที่ 3.3 เป็นเซ็นเซอร์จุ่มกิโลอิเล็กทรอนิกส์ที่ใช้ในการตรวจจับกลิ่นเนื้อส่วนต่าง ๆ โดยมีเซ็นเซอร์ทั้งหมด 8 ตัวที่มีความสามารถในการตรวจจับที่แตกต่างกันออกไป โดยเฉพาะเซ็นเซอร์ TGS2603 ที่มีความสามารถในการตรวจจับกลิ่นของอาหารได้เป็นอย่างดี เนื่องจากไตรเมทิลามีน (Trimethylamine) เป็นสารระเหยที่มีกลิ่นเหม็น ไม่มีสี ทำให้เกิดกลิ่นคาวปลา หรือกลิ่นปลาเน่า ส่วนเมอร์แคปแทน (Methyl Mercaptan) เป็นกลิ่นก๊าซหุงต้ม ซึ่งเป็นพิษเมื่อหายใจรับเข้าไป

จำนวนข้อมูลของทั้ง 3 ชุดข้อมูลที่นำมาใช้ในการทดลองได้สรุปไว้ดังตารางที่ 3.4

ตารางที่ 3.4 จำนวนชุดข้อมูลจากจุ่มกือเล็ทรอนิกส์

ชุดข้อมูล	คุณลักษณะ (Attribute)	ประเภทของกลืน (Class)	จำนวน	
			ตัวอย่าง (Instance)	รวม
ชุดข้อมูลที่ 1 กลืนของแอลกอฮอล์	7	ไม่มีกลิ่น (Odorless)	60	240
		เบียร์ (Beer)	60	
		วิสกี้ (Whisky)	60	
		ไวน์ (Wine)	60	
ชุดข้อมูลที่ 2 กลืนของคุณภาพเนื้อ	9	ดีเยี่ยม (Excellent)	250	1,000
		ดี (Good)	250	
		พอรับได้ (Acceptable)	250	
		เน่าเสีย (Spoiled)	250	
ชุดข้อมูลที่ 3 กลืนของ เนื้อส่วนต่าง ๆ	8	เนื้อส่วนซี่โครง (Beef ribs)	1,000	6,000
		เนื้อส่วนต้นขาหน้า (Beef shank)	1,000	
		อกไก่ (Chicken breast)	1,000	
		น่องไก่ (Chicken drumsticks)	1,000	
		หมูสามชั้น (Pork belly)	1,000	
		ขาหมู (Pork legs)	1,000	

จากตารางที่ 3.4 แสดงจำนวนชุดข้อมูลที่ใช้ในงานวิจัย โดยมีทั้งหมด 3 ชุดข้อมูล ซึ่งชุดข้อมูลที่ 1 กลืนของแอลกอฮอล์ประกอบไปด้วย 7 คุณลักษณะ 4 ประเภทของกลืน จำนวนตัวอย่างทั้งหมด 240 ตัวอย่าง ชุดข้อมูลที่ 2 กลืนของคุณภาพเนื้อ ประกอบไปด้วย 9 คุณลักษณะ 4 ประเภทของกลืน จำนวนตัวอย่างทั้งหมด 1,000 ตัวอย่าง และชุดข้อมูลที่ 3 กลืนของเนื้อส่วนต่าง ๆ ประกอบไปด้วย 8 คุณลักษณะ 6 ประเภทของกลืน จำนวนตัวอย่างทั้งหมด 6,000 ตัวอย่าง

### 3.2 การเตรียมข้อมูลสำหรับการวิจัย

ในการเตรียมข้อมูลสำหรับการวิจัยต้องมีการแบ่งจำนวนข้อมูลให้เท่ากันเพื่อให้เกิดความเท่าเทียมกันระหว่างประเภทของกลืนอื่น ๆ จึงทำการแบ่งข้อมูลจำนวนอย่างละ 60 250 และ 1,000 ตัวอย่าง (instance) ตามลำดับของชุดข้อมูลในแต่ละประเภทของกลืน เพื่อนำมาใช้เป็นชุดข้อมูลสำหรับฝึกสอน (Train) และทดสอบ (Test) โมเดล เพื่อให้โมเดลสามารถทำนายประเภทของกลืนได้

อย่างมีประสิทธิภาพ ชุดข้อมูลที่นำมาใช้จัดเก็บอยู่ในรูปแบบไฟล์ .CSV โดยกำหนดให้มีชื่อ (Label) ประเภทของกลิ่นสำหรับการฝึกสอนโมเดลเป็นตัวเลขเพื่อความเร็วในการอ่านข้อมูลของโมเดล

โดยมีตัวอย่างข้อมูลค่าสัญญาณเซ็นเซอร์จากสถานีจุ่มกิโลกรัมของชุดข้อมูลที่ 1 แสดงตามตารางที่ 3.5

ตารางที่ 3.5 ตัวอย่างชุดข้อมูลจากจุ่มกิโลกรัมของชุดข้อมูลที่ 1

ประเภท ของกลิ่น	ค่าที่เซ็นเซอร์วัดได้						
	TGS826	TGS832	TGS2600	TGS2602	TGS2610	TGS2444	TGS4161
ไม่มีกลิ่น (Odorless)	92	228	272	306	149	468	257
	81	215	231	284	143	412	265
	78	209	210	274	138	369	275
	76	206	200	267	135	335	284
เบียร์ (Beer)	111	211	206	256	134	204	239
	108	214	201	254	133	201	240
	104	208	192	250	131	192	242
	99	207	193	250	131	193	241
วิสกี้ (Whisky)	92	219	171	246	119	179	284
	91	219	171	246	117	181	284
	109	227	192	256	125	191	273
	112	229	193	259	126	195	273
ไวน์ (Wine)	123	222	233	264	139	205	225
	115	217	220	258	137	194	224
	105	210	215	255	135	184	227
	99	210	209	251	133	179	224

จากตารางที่ 3.5 แสดงตัวอย่าง 4 ข้อมูลจาก 60 ตัวอย่างในแต่ละประเภทของกลิ่น ซึ่งมีตัวอย่างทั้งหมด 240 ตัวอย่างที่ใช้เป็นชุดข้อมูลที่ 1 กลิ่นของแอลกอฮอล์ โดยตัวเลขแสดงถึงค่าสัญญาณตามความรุนแรงของกลิ่นที่เซ็นเซอร์สามารถตรวจวัดได้

ตัวอย่างข้อมูลค่าสัญญาณเซ็นเซอร์จากสถานีจุ่มกิโลกรัมของชุดข้อมูลที่ 2 ดังแสดงตามตารางที่ 3.6

ตารางที่ 3.6 ตัวอย่างชุดข้อมูลจากจุ่มกิโลกรัมของชุดข้อมูลที่ 2

ประเภทของกลิ่น	ค่าที่เซ็นเซอร์วัดได้								
	MQ135	MQ136	MQ2	MQ3	MQ4	MQ5	MQ6	MQ8	MQ9
ดีเยี่ยม (Excellent)	22.96	18.74	37.69	17.52	37.23	36.82	28.77	39.55	12.72
	13.13	4.17	6.53	13.79	25.42	28.34	28.27	34.31	9.85
	12.47	3.96	5.79	13.73	24.5	28.34	27.14	32.99	9.11
	10.33	3.31	4.33	12.93	20.48	25.74	26.69	32.63	8.49
ดี (Good)	9.93	3.22	4.25	12.38	20	22.92	35.16	32.45	8.49
	7.91	2.84	3.36	9.7	16.59	13.82	21.33	29.15	6.1
	6.65	2.57	2.86	8.04	13.12	5.16	12.35	26.07	6.26
	4.99	2.59	2.73	5.46	2.36	3.14	7.96	4.11	5.38
พอรับได้ (Acceptable)	4.82	2.06	2.73	5.25	1.73	3.06	7.93	3.92	4.55
	4.48	2.07	2.7	4.75	1.04	2.85	7.25	3.4	4.11
	4.73	2.07	2.7	4.67	1.03	2.79	6.94	3.25	4.01
	4.5	1.93	2.65	4.4	1	2.34	6.89	2.71	3.88
เน่าเสีย (Spoiled)	4.91	1.96	2.72	4.52	1.02	2.38	6.42	2.87	4.05
	4.88	2.71	2.65	4.56	1	2.28	6.07	2.76	6.39
	4.93	9.86	2.59	5.39	0.96	2.07	7.11	2.47	7.1
	5.24	12.63	2.62	5.91	0.95	2.67	5.41	3.94	8.1

จากตารางที่ 3.6 แสดงตัวอย่าง 4 ข้อมูลจาก 250 ตัวอย่างในแต่ละประเภทของกลิ่น ซึ่งมีตัวอย่างทั้งหมด 1,000 ตัวอย่างที่ใช้เป็นชุดข้อมูลที่ 2 กลิ่นของคุณภาพเนื้อ โดยตัวเลขแสดงถึงค่าสัญญาณตามความรุนแรงของกลิ่นที่เซ็นเซอร์สามารถตรวจวัดได้

ตัวอย่างข้อมูลค่าสัญญาณเซ็นเซอร์จากสถานีจุ่มกิโลกรัมของชุดข้อมูลที่ 3 ดังแสดงตามตารางที่ 3.7

ตารางที่ 3.7 ตัวอย่างชุดข้อมูลจากจุ่มกิโลกรัมของชุดข้อมูลที่ 3

ประเภท ของกลิ่น	ค่าที่เซ็นเซอร์วัดได้							
	TGS822	TGS2612	TGS2620	TGS832	TGS826	TGS2603	TGS2600	TGS813
เนื้อส่วนซี่โครง (Beef ribs)	2531.1	572.3	3089.8	620.6	3006.4	693.6	2917.9	534.4
	1465.7	368.4	2337.9	364.1	1884.4	583.7	1746.4	536.6
	1360.5	321.6	2187.8	352.3	1662	513.2	1641	535.1
	1406.6	318.2	2260.7	358.9	1653.6	524.4	1702.9	535.5
เนื้อส่วน ต้นขาหน้า (Beef shank)	1549.7	345.5	2503.5	396.1	1657.6	765	1865.2	537.3
	1445.6	322.8	2405.2	359.2	1825.6	600.5	1758.5	538.3
	1966.1	323.25	2785.1	475.6	2074.5	1078.3	2203.1	536.4
	1486.3	324	2410.5	365.1	1975.3	692.8	1761.7	533.6
อกไก่ (Chicken breast)	1523.6	283.3	2353.1	361.3	2197.3	858.4	1745.6	535.8
	1469.4	281.4	2355	355.3	2056.3	768.5	1750.3	540.7
	1432.8	284.1	2378	346.8	1853.4	660.7	1810.1	538.3
	1614.1	294.2	2301.3	387.1	2423	1063.5	1689.7	538.6
น่องไก่ (Chicken drumsticks)	1693.3	278.6	2535.3	404.6	2055.9	1026.5	1963.3	538.8
	1468.8	281.8	2305.1	359.6	2153.2	830.6	1686	539
	1602.3	273.7	2399.8	373.8	2121.7	902.0	1833.9	541.8
	1505.0	282.7	2344.5	363.7	2156.2	796.3	1737	540.3
หมูสามชั้น (Pork belly)	1701.7	360.9	2636.4	400.1	1656.5	858.7	2075.8	535.3
	1278.1	330.1	2319.9	333.7	1494.9	436.5	1685.8	534.7
	1426.1	297.7	2474.4	352.6	1455.9	518.2	1879.5	534.9
	1271.8	310.1	2348	323.2	1421	403.5	1733.2	537.9
ขาหมู (Pork legs)	1887.6	359.4	2725.1	443.8	1682.2	1054.7	2255.4	538.7
	1470.2	342	2448.6	346.1	1450.5	694.7	1943.4	534.8
	1878.8	334.1	2693.4	429.6	1971.8	1042.5	2134.7	534.9
	1418.8	332.4	2442.6	338.6	1529.3	532.5	1846.5	532.3

จากตารางที่ 3.7 แสดงตัวอย่าง 4 ข้อมูลจาก 1,000 ตัวอย่างในแต่ละประเภทของกลิ่น ซึ่งมีตัวอย่างทั้งหมด 6,000 ตัวอย่างที่ใช้เป็นชุดข้อมูลที่ 3 กลิ่นของเนื้อส่วนต่าง ๆ โดยตัวเลขแสดงถึงค่าสัญญาณตามความรุนแรงของกลิ่นที่เซ็นเซอร์สามารถตรวจวัดได้

### 3.3 การเพิ่มประสิทธิภาพโมเดลโดยใช้การเรียนรู้แบบรวมกลุ่มด้วยวิธีการอะแดปทีฟบูสตีง

การสร้างโมเดลประกอบไปด้วย 3 ขั้นตอนคือ การเลือกชุดข้อมูล การเลือกโมเดลที่ใช้ในการวิจัย และการตั้งค่าโครงสร้างให้กับโมเดล

#### 3.3.1 การเลือกชุดข้อมูล

ในการเลือกชุดข้อมูลเป็นชุดข้อมูลโดยทำการเลือกชุดข้อมูลจากข้อ 3.2 นำมาทำการแบ่งชุดข้อมูลสำหรับการฝึกสอนร้อยละ 70 และสำหรับการทดลองร้อยละ 30 ในแต่ละชุดข้อมูล

#### 3.3.2 การเลือกโมเดลที่ใช้ในการวิจัย

ในการคัดเลือกโมเดลเพื่อนำมาทดลองในงานวิจัยนี้ ผู้วิจัยได้ทำการทดลองเปรียบเทียบโมเดลการเรียนรู้ของเครื่องต่าง ๆ ได้แก่ โครงข่ายประสาทเทียมแบบลึก ซัพพอร์ตเวกเตอร์แมชชีน ต้นไม้ตัดสินใจ นาอ็พเบย์ วิธีการเพื่อนบ้านที่ใกล้ที่สุด  $k$  ตัว การถดถอยเชิงเส้น การถดถอยโลจิสติกส์ อะแดปทีฟบูสตีง แกรเดียนบูสตีง เอกซ์ตรีมเกรเดียนบูสตีง และป่าแบบสุ่ม เพื่อนำมาจำแนกประเภทของกลิ่นได้อย่างมีประสิทธิภาพและทำการทดลอง 10 ครั้งในแต่ละโมเดล โดยแบ่งตารางเพื่อแสดงประสิทธิภาพการทำนายและระยะเวลาที่ดำเนินการออกเป็นการเรียนรู้เชิงตั้ง การเรียนรู้แบบรวมกลุ่ม และการเรียนรู้เชิงลึก ซึ่งการเรียนรู้เชิงลึกต้องมีการปรับจูนพารามิเตอร์ ในแต่ละชุดข้อมูลเพื่อหาโมเดลที่มีความแม่นยำที่ดีที่สุด โดยชั้นฮิดเดนที่ 1 กำหนดจำนวนเซลล์ประสาท (neuron) เริ่มต้นที่  $2^n$  โดย  $n = 1, 2, 3, \dots$  เพิ่มจำนวน  $n$  ขึ้นไปเรื่อย ๆ จนมีค่าความแม่นยำคงที่หรือลดลง จึงหยุดการเพิ่มจำนวน  $n$  ในชั้นฮิดเดนที่ 1 จากนั้นเลือกจำนวนเซลล์ประสาทที่ให้ค่าความแม่นยำที่มากที่สุดของชั้นฮิดเดนที่ 1 นำมาเป็นอินพุตของชั้นฮิดเดนถัดไป โดยเพิ่มจำนวนเซลล์ประสาทเช่นเดียวกับชั้นฮิดเดนที่ 1 เมื่อค่าความแม่นยำคงที่หรือลดลง จึงหยุดการปรับจูนพารามิเตอร์ และเลือกโมเดลโครงข่ายประสาทเทียมแบบลึกด้วยเซลล์ประสาทที่ให้ค่าความแม่นยำที่ดีที่สุดนำมาใช้ในการวิจัย

โดยมีประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงตั้งของชุดข้อมูลที่ 1 ดังแสดงตามตารางที่ 3.8

ตารางที่ 3.8 ประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงต้นของชุดข้อมูลที่ 1

วิธี	ความแม่นยำของโมเดล (ร้อยละ)					
	Decision Tree	Naïve Bayes	SVM	k-NN	Linear Regression	Logistic Regression
1	98.61	98.61	100.00	98.61	77.03	100.00
2	100.00	98.61	98.61	100.00	76.06	97.22
3	98.61	100.00	98.61	98.61	66.60	100.00
4	97.22	98.61	98.61	97.22	73.75	100.00
5	94.44	100.00	97.22	98.61	72.64	98.61
6	95.83	95.83	100.00	98.61	69.23	98.61
7	98.61	95.83	100.00	98.61	67.62	94.44
8	95.83	97.22	98.61	100.00	66.06	100.00
9	100.00	98.61	100.00	98.61	68.75	100.00
10	100.00	100.00	100.00	100.00	58.60	98.61
MEAN	97.92	98.33	<b>99.17</b>	98.89	69.63	98.75
S.D.	1.99	1.58	0.97	<b>0.88</b>	5.48	1.79
MAX	100.00	100.00	<b>100.00</b>	100.00	77.03	100.00
MIN	94.44	95.83	<b>97.22</b>	97.22	58.60	94.44

จากตารางที่ 3.8 ผลการทดสอบประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงต้นของชุดข้อมูลที่ 1 แสดงให้เห็นว่าโมเดลที่มีประสิทธิภาพมากที่สุด คือ โมเดลซัพพอร์ตเวกเตอร์แมชชีนมีค่าความแม่นยำเฉลี่ยที่ร้อยละ 99.17 รองลงมาเป็นวิธีการเพื่อนบ้านที่ใกล้ที่สุด k ตัวมีค่าความแม่นยำเฉลี่ยที่ร้อยละ 98.89 ซึ่งทั้ง 2 โมเดลมีค่าความแม่นยำสูงสุดและต่ำสุดที่ร้อยละ 100 และ 97.22 ตามลำดับที่เท่ากัน แต่มีความแตกต่างกันที่ค่าความแม่นยำเฉลี่ยและค่าส่วนเบี่ยงเบนมาตรฐาน

นอกจากนี้ยังได้แสดงระยะเวลาดำเนินการในหน่วยวินาทีของแต่ละโมเดล ดังแสดงตามตารางที่ 3.9

ตารางที่ 3.9 ระยะเวลาการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงต้นของชุดข้อมูลที่ 1

วิธี	ระยะเวลาในการทำนายของโมเดล (วินาที)					
	Decision Tree	Naïve Bayes	SVM	k-NN	Linear Regression	Logistic Regression
1	1.83	1.50	2.15	1.63	1.38	2.26
2	1.50	1.51	1.94	1.59	0.98	1.97
3	1.55	1.52	1.95	1.54	0.96	2.18
4	1.64	1.50	1.85	1.52	0.93	2.49
5	1.49	1.42	1.94	1.60	1.04	2.15
6	1.46	1.28	1.87	1.56	0.91	2.03
7	1.55	1.52	1.82	1.52	0.93	2.01
8	1.49	1.44	1.97	1.55	0.95	2.09
9	1.47	1.46	1.49	1.45	0.96	2.13
10	1.49	1.56	1.85	1.57	0.97	2.00
MEAN	1.55	1.47	1.88	1.55	<b>1.00</b>	2.13
S.D.	0.11	0.08	0.17	<b>0.05</b>	0.14	0.16
MAX	1.83	1.56	2.15	1.63	<b>1.38</b>	2.49
MIN	1.46	1.28	1.49	1.45	<b>0.91</b>	1.97

จากตารางที่ 3.9 ระยะเวลาในการทำนายโมเดลการเรียนรู้เชิงต้นของชุดข้อมูลที่ 1 ในแต่ละโมเดลมีความแตกต่างกันไม่มากนัก โดยที่โมเดลการถดถอยเชิงเส้นสามารถทำระยะเวลาค่าเฉลี่ยได้เร็วสุดที่ 1.00 วินาที ใช้เวลาดำที่ต่ำสุด 0.91 วินาที และใช้เวลามากที่สุด 1.38 วินาที แต่ในขณะที่โมเดลวิธีการเพื่อนบ้านที่ใกล้ที่สุด k ตัวมีค่าส่วนเบี่ยงเบนมาตรฐาน 0.05 ซึ่งดีกว่าโมเดลการถดถอยเชิงเส้น

ประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 1 ดังแสดงตามตารางที่ 3.10

ตารางที่ 3.10 ประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 1

ครั้ง	ความแม่นยำของโมเดล (ร้อยละ)			
	Gradient Boosting	XGBoost	AdaBoost	Random Forest
1	100.00	98.61	98.61	100.00
2	97.22	100.00	97.22	100.00
3	98.61	100.00	98.61	97.22
4	97.22	97.22	98.61	94.44
5	100.00	100.00	98.61	100.00
6	98.61	98.61	98.61	100.00
7	98.61	98.61	98.61	97.22
8	97.22	100.00	100.00	98.61
9	98.61	98.61	98.61	100.00
10	95.83	94.44	100.00	98.61
MEAN	98.19	98.61	<b>98.75</b>	98.61
S.D.	1.32	1.73	<b>0.79</b>	1.85
MAX	100.00	100.00	<b>100.00</b>	100.00
MIN	95.83	94.44	<b>97.22</b>	94.44

จากตารางที่ 3.10 ผลการทดสอบประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 1 แสดงให้เห็นว่า โมเดลที่มีประสิทธิภาพมากที่สุด คือ โมเดลอะแดปทีฟบูสติงมีค่าความแม่นยำเฉลี่ยที่ร้อยละ 98.75 มีค่าส่วนเบี่ยงเบนมาตรฐานร้อยละ 0.79 ซึ่งน้อยที่สุดเมื่อเทียบกับโมเดลอื่น รองลงมาเป็นเอกซ์ตรีมเกรเดียนบูสติง และป่าแบบสุ่มมีค่าความแม่นยำเฉลี่ยเท่ากันที่ร้อยละ 98.61 ซึ่งทั้ง 2 โมเดลมีค่าความแม่นยำสูงสุดและต่ำสุดที่ร้อยละ 100 และ 94.44 ตามลำดับที่เท่ากัน และแสดงระยะเวลาดำเนินการในหน่วยวินาทีของแต่ละโมเดลดังแสดงตามตารางที่ 3.11

ตารางที่ 3.11 ระยะเวลาการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 1

ครั้ง	ระยะเวลาในการทำนายของโมเดล (วินาที)			
	Gradient Boosting	XGBoost	AdaBoost	Random Forest
1	1.86	2.19	0.71	1.79
2	1.84	1.79	0.66	1.81
3	1.81	1.76	0.69	1.78
4	1.80	1.77	0.75	1.75
5	1.87	1.80	0.68	1.75
6	1.78	1.78	0.59	1.79
7	1.82	1.76	0.58	1.79
8	1.88	1.75	0.59	1.81
9	1.97	1.79	0.56	1.76
10	1.84	1.80	0.60	1.79
MEAN	1.85	1.82	<b>0.64</b>	1.78
S.D.	0.05	0.13	0.07	<b>0.02</b>
MAX	1.97	2.19	<b>0.75</b>	1.81
MIN	1.78	1.75	<b>0.56</b>	1.75

จากตารางที่ 3.11 ระยะเวลาในการทำนายโมเดลการเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 1 โมเดลอะแดปทีฟบูสตีงสามารถทำระยะเวลาค่าเฉลี่ยได้เร็วสุดที่ 0.64 วินาที ใช้เวลาต่ำที่สุด 0.56 วินาที และใช้เวลามากที่สุด 0.75 วินาที ซึ่งใช้ระยะเวลาเร็วมากเมื่อเทียบกับโมเดลอื่น

ประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึก ซึ่งได้แก่ โมเดลโครงข่ายประสาทเทียมแบบลึก ของชุดข้อมูลที่ 1 ดังแสดงตามตารางที่ 3.12

ตารางที่ 3.12 ประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึกในการปรับ  
 ปรุงชั้นฮิดเดนที่ 1 ของชุดข้อมูลที่ 1

ครั้ง	ความแม่นยำของโมเดล (ร้อยละ)							
	Deep Neural Network (ปรับปรุงชั้นฮิดเดนที่ 1)							
	2	4	8	16	32	64	128	256
1	100.00	95.83	95.83	100.00	98.61	98.61	98.61	100.00
2	97.22	91.67	100.00	94.44	95.83	100.00	98.61	100.00
3	58.33	22.22	98.61	97.22	100.00	98.61	100.00	98.61
4	97.22	18.06	97.22	100.00	100.00	100.00	98.61	98.61
5	22.22	62.50	95.83	98.61	97.22	100.00	100.00	98.61
6	73.61	59.72	100.00	100.00	100.00	100.00	100.00	100.00
7	61.11	95.83	98.61	95.83	97.22	100.00	98.61	100.00
8	100.00	100.00	98.61	100.00	100.00	98.61	100.00	97.22
9	15.28	100.00	100.00	100.00	98.61	100.00	100.00	98.61
10	95.83	98.61	95.83	98.61	100.00	98.61	100.00	100.00
MEAN	72.08	74.44	98.05	98.47	98.75	<b>99.44</b>	99.44	99.17
S.D.	32.34	32.26	1.76	2.01	1.53	<b>0.72</b>	0.72	0.97
MAX	100.00	100.00	100.00	100.00	100.00	<b>100.00</b>	100.00	100.00
MIN	15.28	18.06	95.83	94.44	95.83	<b>98.61</b>	98.61	97.22

จากตารางที่ 3.12 แสดงประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึกของชุดข้อมูลที่ 1 ในการปรับปรุงชั้นฮิดเดนที่ 1 กำหนดจำนวนเซลล์ประสาท (neuron) เริ่มต้นที่  $2^n$  โดย  $n = 1, 2, 3, \dots$  เพิ่มจำนวน  $n$  ขึ้นไปเรื่อย ๆ จนมีค่าความแม่นยำคงที่หรือลดลง จึงหยุดการเพิ่มจำนวน  $n$  ในชั้นฮิดเดนที่ 1 จากนั้นเลือกจำนวนเซลล์ประสาทที่ให้ค่าความแม่นยำที่มากที่สุด โดยในชั้นฮิดเดนที่ 1 ที่มีจำนวนเซลล์ประสาท 64 เซลล์ ให้ค่าความแม่นยำเฉลี่ยที่มากที่สุดที่ร้อยละ 99.44 ส่วนเบี่ยงเบนมาตรฐานที่ร้อยละ 0.72 และแสดงระยะเวลาดำเนินการในหน่วยวินาทีของแต่ละโมเดลดังแสดงตามตารางที่ 3.13

ตารางที่ 3.13 ระยะเวลาการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึกในการปรับ  
ชั้นฮิดเดนที่ 1 ของชุดข้อมูลที่ 1

ครั้ง	ระยะเวลาในการทำนายของโมเดล (วินาที)							
	Deep Neural Network (ปรับจูนชั้นฮิดเดนที่ 1)							
	2	4	8	16	32	64	128	256
1	10.95	10.67	10.46	10.10	10.66	10.84	11.45	11.28
2	10.40	10.58	10.83	10.58	10.45	10.45	10.89	11.40
3	10.85	10.57	10.39	10.65	10.67	10.75	10.57	11.38
4	10.96	10.26	10.46	11.02	10.81	10.27	10.36	11.23
5	10.39	10.63	10.55	11.10	10.26	10.64	10.34	11.29
6	10.76	10.54	10.48	10.37	10.74	10.77	10.34	11.43
7	11.00	10.59	10.76	10.43	10.38	10.99	10.41	11.42
8	10.62	10.60	10.61	10.42	10.80	10.56	10.29	11.33
9	10.48	11.03	10.61	10.51	10.98	10.72	10.48	11.20
10	10.52	10.09	10.65	10.77	10.68	10.66	10.28	11.23
MEAN	10.69	<b>10.54</b>	10.58	10.60	10.64	10.67	<b>10.54</b>	11.32
S.D.	0.24	0.26	0.14	0.30	0.22	0.20	0.37	<b>0.09</b>
MAX	11.00	11.03	<b>10.83</b>	11.10	10.98	10.99	11.45	11.43
MIN	10.39	<b>10.09</b>	10.39	10.10	10.26	10.27	10.28	11.20

จากตารางที่ 3.13 ระยะเวลาในการทำนายโมเดลการเรียนรู้เชิงลึกของชุดข้อมูลที่ 1 โมเดลโครงข่ายประสาทเทียมแบบลึกชั้นฮิดเดนที่ 1 จำนวนเซลล์ประสาทที่ 64 ถึงแม้จะไม่ได้ระยะเวลาที่เร็วที่สุด แต่อยู่ในระยะเวลาที่รับได้เมื่อเทียบกับจำนวนเซลล์ประสาทอื่น ๆ

เมื่อได้ผลการทดลองในการปรับจูนชั้นฮิดเดนที่ 1 แล้ว จึงเลือกจำนวนเซลล์ประสาทที่ 64 มาปรับจูนในขั้นตอนต่อไปคือ ชั้นฮิดเดนที่ 2 โดยมีประสิทธิภาพการทำนายประเภทของกลิ่นของชุดข้อมูลที่ 1 ดังแสดงตามตารางที่ 3.14

ตารางที่ 3.14 ประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึกในการปรับ  
 ปรุงชั้นฮิดเดนที่ 2 ของชุดข้อมูลที่ 1

ครั้ง	ความแม่นยำของโมเดล (ร้อยละ)							
	Deep Neural Network (ปรับปรุงชั้นฮิดเดนที่ 2)							
	64-2	64-4	64-8	64-16	64-32	64-64	64-128	64-256
1	100.00	98.61	100.00	100.00	100.00	95.83	100.00	94.44
2	100.00	20.83	98.61	100.00	100.00	100.00	98.61	98.61
3	98.61	100.00	98.61	100.00	98.61	100.00	98.61	100.00
4	19.44	98.61	98.61	100.00	98.61	100.00	100.00	100.00
5	75.00	98.61	98.61	98.61	100.00	98.61	100.00	98.61
6	22.22	98.61	100.00	98.61	97.22	100.00	98.61	100.00
7	97.22	68.06	98.61	100.00	98.61	98.61	97.22	100.00
8	100.00	98.61	97.22	100.00	100.00	100.00	100.00	100.00
9	19.44	100.00	100.00	98.61	100.00	100.00	100.00	100.00
10	61.11	97.22	98.61	98.61	98.61	95.83	98.61	100.00
MEAN	69.30	87.92	98.89	<b>99.44</b>	99.17	98.89	99.17	99.17
S.D.	36.14	25.48	0.88	<b>0.72</b>	0.97	1.71	0.97	1.76
MAX	100.00	100.00	100.00	<b>100.00</b>	100.00	100.00	100.00	100.00
MIN	19.44	20.83	97.22	<b>98.61</b>	97.22	95.83	97.22	94.44

จากตารางที่ 3.14 แสดงประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึกของชุดข้อมูลที่ 1 ในการปรับปรุงชั้นฮิดเดนที่ 2 โดยชั้นฮิดเดนที่ 1 มีจำนวนเซลล์ประสาทเป็น 64 เซลล์ กำหนดจำนวนเซลล์ประสาท (neuron) ให้กับชั้นฮิดเดนที่ 2 เริ่มต้นที่  $2^n$  โดย  $n = 1, 2, 3, \dots$  เพิ่มจำนวน  $n$  ขึ้นไปเรื่อย ๆ จนมีค่าความแม่นยำคงที่หรือลดลง จึงหยุดการเพิ่มจำนวน  $n$  ในชั้นฮิดเดนที่ 2 จากนั้นเลือกจำนวนเซลล์ประสาทที่ให้ค่าความแม่นยำที่มากที่สุด โดยชั้นฮิดเดนที่ 1 จำนวนเซลล์ประสาท 64 เซลล์ และชั้นฮิดเดนที่ 2 จำนวนเซลล์ประสาท 16 เซลล์ ให้ค่าความแม่นยำเฉลี่ยที่มากที่สุดที่ร้อยละ 99.44 ส่วนเบี่ยงเบนมาตรฐานที่ร้อยละ 0.72 มีค่าความแม่นยำต่ำที่สุดอยู่ที่ร้อยละ 98.61 ซึ่งเมื่อเทียบกับจำนวนเซลล์ประสาท 64 เซลล์ในชั้นฮิดเดนที่ 1 จะมีค่าความแม่นยำที่เท่ากัน ดังนั้นจึงทำการทดสอบประสิทธิภาพต่อไป เพื่อให้แน่ใจว่าค่าความแม่นยำที่ได้มีความคงที่หรือลดลงในขั้นถัดไป และแสดงระยะเวลาดำเนินการในหน่วยวินาทีของแต่ละโมเดลดังแสดงตามตารางที่ 3.15

ตารางที่ 3.15 ระยะเวลาการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึกในการปรับ  
 ปรุงชั้นฮิดเดนที่ 2 ของชุดข้อมูลที่ 1

ครั้ง	ระยะเวลาในการทำนายของโมเดล (วินาที)							
	Deep Neural Network (ปรับปรุงชั้นฮิดเดนที่ 2)							
	64-2	64-4	64-8	64-16	64-32	64-64	64-128	64-256
1	10.78	10.82	12.83	12.49	12.53	12.60	12.94	13.53
2	10.86	11.21	11.84	12.39	12.33	12.36	12.58	13.32
3	11.58	11.18	12.34	12.88	12.58	12.48	13.02	13.55
4	11.34	11.24	12.41	12.62	12.49	12.35	12.79	13.61
5	11.31	11.45	12.40	12.55	12.17	12.48	12.81	13.34
6	11.41	11.13	12.01	12.20	12.51	12.52	12.59	13.41
7	11.45	10.82	12.50	12.21	12.60	12.51	12.83	13.48
8	10.83	11.64	12.44	12.23	12.59	12.35	12.93	13.42
9	10.40	10.61	12.11	12.42	12.09	12.19	12.82	13.42
10	11.25	11.18	11.96	12.23	12.25	12.44	12.75	13.32
MEAN	11.12	11.13	12.28	12.42	12.41	12.43	12.81	13.44
S.D.	0.38	0.31	0.30	0.22	0.19	0.12	0.14	0.10
MAX	11.58	11.64	12.83	12.88	12.60	12.60	13.02	13.61
MIN	10.40	10.61	11.84	12.20	12.09	12.19	12.58	13.32

จากตารางที่ 3.15 ระยะเวลาในการทำนายโมเดลการเรียนรู้เชิงลึกของชุดข้อมูลที่ 1 โมเดลโครงข่ายประสาทเทียมแบบลึกชั้นฮิดเดนที่ 1 จำนวนเซลล์ประสาท 64 เซลล์ และชั้นฮิดเดนที่ 2 จำนวนเซลล์ประสาท 16 เซลล์ ถึงแม้จะไม่ได้ระยะเวลาที่เร็วที่สุด แต่อยู่ในระยะเวลาที่รับได้เมื่อเทียบกับจำนวนเซลล์ประสาทอื่น ๆ

เมื่อได้ผลการทดลองในการปรับปรุงชั้นฮิดเดนที่ 2 แล้ว จึงเลือกชั้นฮิดเดนที่ 1 จำนวนเซลล์ประสาท 64 เซลล์ และชั้นฮิดเดนที่ 2 จำนวนเซลล์ประสาท 16 เซลล์ มาปรับปรุงในขั้นตอนต่อไปคือชั้นฮิดเดนที่ 3 โดยมีประสิทธิภาพการทำนายประเภทของกลิ่นของชุดข้อมูลที่ 1 ดังแสดงตามตารางที่ 3.16

ตารางที่ 3.16 ประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึกในการปรับ  
 ปรุงชั้นฮิดเดนที่ 3 ของชุดข้อมูลที่ 1

ครั้ง	ความแม่นยำของโมเดล (ร้อยละ)							
	Deep Neural Network (ปรับปรุงชั้นฮิดเดนที่ 3)							
	64-16- 2	64-16- 4	64-16- 8	64-16- 16	64-16- 32	64-16- 64	64-16- 128	64-16- 256
1	54.17	95.83	98.61	100.00	98.61	98.61	100.00	98.61
2	61.11	97.22	97.22	100.00	98.61	98.61	98.61	98.61
3	19.44	100.00	100.00	100.00	100.00	100.00	100.00	100.00
4	15.28	98.61	98.61	100.00	98.61	100.00	98.61	98.61
5	22.22	22.22	98.61	98.61	97.22	94.44	97.22	97.22
6	19.44	98.61	100.00	100.00	98.61	97.22	98.61	97.22
7	16.67	98.61	98.61	100.00	97.22	98.61	98.61	98.61
8	98.61	98.61	100.00	100.00	98.61	98.61	100.00	98.61
9	18.06	100.00	90.28	100.00	98.61	98.61	98.61	100.00
10	100.00	98.61	100.00	100.00	100.00	100.00	100.00	100.00
MEAN	42.50	90.83	98.19	<b>99.86</b>	98.61	98.47	99.03	98.75
S.D.	34.02	24.14	2.93	<b>0.44</b>	0.93	1.66	0.94	1.03
MAX	100.00	100.00	100.00	<b>100.00</b>	100.00	100.00	100.00	100.00
MIN	15.28	22.22	90.28	<b>98.61</b>	97.22	94.44	97.22	97.22

จากตารางที่ 3.16 แสดงประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึกของชุดข้อมูลที่ 1 ในการปรับปรุงชั้นฮิดเดนที่ 3 โดยชั้นฮิดเดนที่ 1 มีจำนวนเซลล์ประสาทเป็น 64 เซลล์ และชั้นฮิดเดนที่ 2 จำนวนเซลล์ประสาท 16 เซลล์ กำหนดจำนวนเซลล์ประสาท (neuron) ให้กับชั้นฮิดเดนที่ 3 เริ่มต้นที่  $2^n$  โดย  $n = 1, 2, 3, \dots$  เพิ่มจำนวน  $n$  ขึ้นไปเรื่อย ๆ จนมีค่าความแม่นยำคงที่หรือลดลง จึงหยุดการเพิ่มจำนวน  $n$  ในชั้นฮิดเดนที่ 3 จากนั้นเลือกจำนวนเซลล์ประสาทที่ให้ค่าความแม่นยำที่มากที่สุด โดยชั้นฮิดเดนที่ 1 จำนวนเซลล์ประสาท 64 เซลล์ ชั้นฮิดเดนที่ 2 จำนวนเซลล์ประสาท 16 เซลล์ และชั้นฮิดเดนที่ 3 จำนวนเซลล์ประสาท 16 เซลล์ ให้ค่าความแม่นยำเฉลี่ยที่มากที่สุดที่ร้อยละ 99.86 ส่วนเบี่ยงเบนมาตรฐานที่ร้อยละ 0.44 มีค่าความแม่นยำต่ำที่สุดอยู่ที่ร้อยละ 98.61 ซึ่งเป็นค่าที่ดีที่สุดเมื่อเทียบกับเซลล์ประสาทอื่น และแสดงระยะเวลาดำเนินการในหน่วยวินาทีของแต่ละโมเดลดังแสดงตามตารางที่ 3.17

ตารางที่ 3.17 ระยะเวลาการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึกในการปรับ  
 ปรุงชั้นฮิดเดนที่ 3 ของชุดข้อมูลที่ 1

ครั้ง	ระยะเวลาในการทำนายของโมเดล (วินาที)							
	Deep Neural Network (ปรับปรุงชั้นฮิดเดนที่ 3)							
	64-16- 2	64-16- 4	64-16- 8	64-16- 16	64-16- 32	64-16- 64	64-16- 128	64-16- 256
1	13.33	13.25	13.78	14.04	14.26	14.15	14.29	13.95
2	13.44	13.48	13.73	13.73	13.78	14.15	13.96	14.12
3	13.42	13.50	13.53	13.79	13.95	14.08	14.10	21.49
4	13.29	13.27	13.67	14.12	14.25	14.08	13.95	14.18
5	13.33	13.86	13.65	13.92	14.06	13.94	14.01	13.82
6	13.39	13.65	13.52	13.70	14.31	13.94	13.75	14.12
7	13.20	14.00	13.67	13.97	13.77	14.55	13.96	14.22
8	13.96	13.64	13.65	13.76	13.88	13.86	14.06	13.98
9	13.02	13.50	13.92	13.68	13.81	13.81	14.15	13.99
10	13.04	13.44	13.92	13.82	13.65	13.96	13.90	14.09
MEAN	<b>13.34</b>	13.56	13.70	13.85	13.97	14.05	14.01	14.80
S.D.	0.26	0.24	<b>0.14</b>	0.15	0.24	0.21	0.15	2.36
MAX	13.96	14.00	<b>13.92</b>	14.12	14.31	14.55	14.29	21.49
MIN	<b>13.02</b>	13.25	13.52	13.68	13.65	13.81	13.75	13.82

จากตารางที่ 3.17 ระยะเวลาในการทำนายโมเดลการเรียนรู้เชิงลึกของชุดข้อมูลที่ 1 โมเดลโครงข่ายประสาทเทียมแบบลึกชั้นฮิดเดนที่ 1 จำนวนเซลล์ประสาท 64 เซลล์ ชั้นฮิดเดนที่ 2 จำนวนเซลล์ประสาท 16 เซลล์ และชั้นฮิดเดนที่ 3 จำนวนเซลล์ประสาทที่ 16 ถึงแม้จะไม่ได้ระยะเวลาที่เร็วที่สุด แต่อยู่ในระยะเวลาที่รับได้เมื่อเทียบกับจำนวนเซลล์ประสาทอื่น ๆ

เมื่อได้ผลการทดลองในการปรับปรุงชั้นฮิดเดนที่ 3 แล้ว จึงเลือกชั้นฮิดเดนที่ 1 จำนวนเซลล์ประสาท 64 เซลล์ ชั้นฮิดเดนที่ 2 จำนวนเซลล์ประสาท 16 เซลล์ และชั้นฮิดเดนที่ 3 จำนวนเซลล์ประสาทที่ 16 มาปรับปรุงในขั้นตอนต่อไปคือ ชั้นฮิดเดนที่ 4 โดยมีประสิทธิภาพการทำนายประเภทของกลิ่นของชุดข้อมูลที่ 1 ดังแสดงตามตารางที่ 3.18

ตารางที่ 3.18 ประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึกในการปรับ  
 ปรุงชั้นฮิดเดนที่ 4 ของชุดข้อมูลที่ 1

ครั้ง	ความแม่นยำของโมเดล (ร้อยละ)							
	Deep Neural Network (ปรับปรุงชั้นฮิดเดนที่ 4)							
	64-16- 16-2	64-16- 16-4	64-16- 16-8	64-16- 16-16	64-16- 16-32	64-16- 16-64	64-16- 16-128	64-16- 16-256
1	19.44	19.44	100.00	94.44	100.00	97.22	97.22	98.61
2	18.06	98.61	98.61	100.00	100.00	98.61	100.00	98.61
3	98.61	97.22	98.61	100.00	98.61	100.00	100.00	97.22
4	18.06	97.67	97.22	98.61	100.00	100.00	98.61	100.00
5	100.00	80.56	98.61	98.61	98.61	100.00	100.00	100.00
6	100.00	100.00	98.61	100.00	98.61	100.00	100.00	98.61
7	72.22	70.83	100.00	97.22	97.22	100.00	98.61	100.00
8	98.61	100.00	100.00	100.00	98.61	98.61	98.61	100.00
9	22.22	100.00	100.00	97.22	100.00	97.22	97.22	100.00
10	97.22	94.44	98.61	97.22	98.61	97.22	100.00	97.22
MEAN	64.44	85.88	<b>99.03</b>	98.33	<b>99.03</b>	98.89	<b>99.03</b>	<b>99.03</b>
S.D.	39.59	25.32	<b>0.94</b>	1.83	<b>0.94</b>	1.28	1.14	1.14
MAX	100.00	100.00	<b>100.00</b>	100.00	<b>100.00</b>	100.00	<b>100.00</b>	<b>100.00</b>
MIN	18.06	19.44	<b>97.22</b>	94.44	<b>97.22</b>	97.22	<b>97.22</b>	<b>97.22</b>

จากตารางที่ 3.18 แสดงประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึกของชุดข้อมูลที่ 1 ในการปรับปรุงชั้นฮิดเดนที่ 4 โดยชั้นฮิดเดนที่ 1 มีจำนวนเซลล์ประสาทเป็น 64 เซลล์ ชั้นฮิดเดนที่ 2 จำนวนเซลล์ประสาท 16 เซลล์ และชั้นฮิดเดนที่ 3 จำนวนเซลล์ประสาท 16 เซลล์ กำหนดจำนวนเซลล์ประสาท (neuron) ให้กับชั้นฮิดเดนที่ 4 เริ่มต้นที่  $2^n$  โดย  $n = 1, 2, 3, \dots$  เพิ่มจำนวน  $n$  ขึ้นไปเรื่อย ๆ จนมีค่าความแม่นยำคงที่หรือลดลง จึงหยุดการเพิ่มจำนวน  $n$  ในชั้นฮิดเดนที่ 4 จากนั้นเลือกจำนวนเซลล์ประสาทที่ให้ค่าความแม่นยำที่มากที่สุด โดยชั้นฮิดเดนที่ 1 จำนวนเซลล์ประสาท 64 เซลล์ ชั้นฮิดเดนที่ 2 จำนวนเซลล์ประสาท 16 เซลล์ ชั้นฮิดเดนที่ 3 จำนวนเซลล์ประสาท 16 เซลล์ และชั้นฮิดเดนที่ 4 ซึ่งมีทั้งหมด 4 แบบที่มีค่าความแม่นยำเฉลี่ยที่มากที่สุดเท่ากันที่ร้อยละ 99.03 ได้แก่ จำนวนเซลล์ประสาท 8 เซลล์ (64-16-16-8) จำนวนเซลล์ประสาท 32 เซลล์ (64-16-16-32) จำนวนเซลล์ประสาท 128 เซลล์ (64-16-16-128) และจำนวนเซลล์ประสาท 256 เซลล์ (64-16-

16-256) แต่กลับมีค่าความแม่นยำเฉลี่ยที่น้อยกว่าชั้นฮิดเดนที่ 3 ที่มีการปรับจูน จึงทำการหยุดการปรับจูน และแสดงระยะเวลาดำเนินการในหน่วยวินาทีของแต่ละโมเดลดังแสดงตามตารางที่ 3.19

ตารางที่ 3.19 ระยะเวลาการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึกในการปรับจูนชั้นฮิดเดนที่ 4 ของชุดข้อมูลที่ 1

ครั้ง	ระยะเวลาในการทำนายของโมเดล (วินาที)							
	Deep Neural Network (ปรับจูนชั้นฮิดเดนที่ 4)							
	64-16-16-2	64-16-16-4	64-16-16-8	64-16-16-16	64-16-16-32	64-16-16-64	64-16-16-128	64-16-16-256
1	14.31	13.39	13.61	14.03	13.58	13.91	14.96	13.87
2	13.93	13.28	14.04	13.77	13.58	13.69	14.06	13.79
3	13.69	13.64	13.70	13.95	13.81	13.58	13.84	13.70
4	13.83	13.60	13.50	13.73	13.86	13.80	14.20	13.94
5	13.70	13.60	13.94	13.45	13.54	13.63	13.64	14.01
6	13.63	13.69	13.70	13.94	13.71	13.41	13.75	14.25
7	14.27	13.36	14.23	13.62	13.77	13.39	13.93	14.04
8	13.25	13.36	13.99	13.79	14.10	13.93	13.99	14.06
9	13.57	13.49	13.88	13.81	13.97	13.93	13.97	14.23
10	13.65	13.86	13.82	13.65	13.55	13.98	14.40	13.80
MEAN	13.78	<b>13.53</b>	13.84	13.77	13.75	13.73	14.07	13.97
S.D.	0.32	0.18	0.22	<b>0.17</b>	0.19	0.22	0.38	0.18
MAX	14.31	<b>13.86</b>	14.23	14.03	14.10	13.98	14.96	14.25
MIN	<b>13.25</b>	13.28	13.50	13.45	13.54	13.39	13.64	13.70

จากตารางที่ 3.19 แสดงระยะเวลาในการทำนายโมเดลการเรียนรู้เชิงลึกของชุดข้อมูลที่ 1 โมเดลโครงข่ายประสาทเทียมแบบลึกชั้นฮิดเดนที่ 1 จำนวนเซลล์ประสาท 64 เซลล์ ชั้นฮิดเดนที่ 2 จำนวนเซลล์ประสาท 16 เซลล์ ชั้นฮิดเดนที่ 3 จำนวนเซลล์ประสาทที่ 16 เซลล์ และชั้นฮิดเดนที่ 4 จำนวนเซลล์ประสาทที่ 4 เซลล์ ใช้ระยะเวลาที่เร็วที่สุด

ดังนั้น โครงข่ายประสาทเทียมแบบลึกสำหรับชุดข้อมูลที่ 1 จึงเลือกใช้โมเดลที่มีชั้นฮิดเดนที่ 1 จำนวนเซลล์ประสาท 64 เซลล์ ชั้นฮิดเดนที่ 2 จำนวนเซลล์ประสาท 16 เซลล์ และชั้นฮิดเดนที่ 3 จำนวนเซลล์ประสาทที่ 16 เซลล์

จากนั้นทำการเปรียบเทียบประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิง  
ต้นของชุดข้อมูลที่ 2 ต่อไป ดังแสดงตามตารางที่ 3.20

ตารางที่ 3.20 ประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงต้นของ  
ชุดข้อมูลที่ 2

ครึ่ง	ความแม่นยำของโมเดล (ร้อยละ)					
	Decision Tree	Naïve Bayes	SVM	k-NN	Linear Regression	Logistic Regression
1	99.00	96.00	98.33	98.00	94.78	96.33
2	98.67	97.33	98.00	98.33	95.30	97.67
3	98.33	97.67	97.67	99.00	94.07	96.33
4	99.33	96.33	97.33	98.33	95.37	97.67
5	100.00	97.00	98.33	97.67	93.94	97.00
6	99.33	95.33	99.00	98.67	94.75	98.33
7	99.00	96.67	98.67	97.33	95.72	97.67
8	99.33	97.33	98.00	98.67	93.60	96.67
9	99.00	96.33	98.00	96.67	93.97	98.33
10	100.00	96.67	98.00	98.33	95.10	98.00
MEAN	<b>99.20</b>	96.67	98.13	98.10	94.66	97.40
S.D.	0.53	0.70	<b>0.48</b>	0.70	0.72	0.77
MAX	<b>100.00</b>	97.67	99.00	99.00	95.72	98.33
MIN	<b>98.33</b>	95.33	97.33	96.67	93.60	96.33

จากตารางที่ 3.20 ผลการทดสอบประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงต้นของชุดข้อมูลที่ 2 แสดงให้เห็นว่าโมเดลที่มีประสิทธิภาพมากที่สุดคือ โมเดลต้นไม้ตัดสินใจ มีค่าความแม่นยำเฉลี่ยที่ร้อยละ 99.20 รองลงมาเป็นซัพพอร์ตเวกเตอร์แมชชีน มีค่าความแม่นยำเฉลี่ยที่ร้อยละ 98.13

นอกจากนี้ยังได้แสดงระยะเวลาดำเนินการในหน่วยวินาทีของแต่ละโมเดล ดังแสดงตามตารางที่ 3.21

ตารางที่ 3.21 ระยะเวลาดำเนินการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงต้นของชุดข้อมูลที่ 2

ครั้ง	ระยะเวลาในการทำนายของโมเดล (วินาที)					
	Decision Tree	Naïve Bayes	SVM	k-NN	Linear Regression	Logistic Regression
1	2.19	1.54	1.75	1.63	0.97	1.46
2	1.90	1.58	1.69	1.60	0.96	1.38
3	1.71	1.55	1.71	1.68	1.07	1.40
4	1.73	1.53	1.70	1.61	0.95	1.42
5	1.74	1.59	1.79	1.60	1.10	1.44
6	1.80	1.62	1.79	1.61	1.08	1.43
7	1.76	1.58	1.68	1.64	1.10	1.43
8	1.78	1.58	1.68	1.61	1.03	1.40
9	1.67	1.56	1.77	1.62	1.19	1.36
10	1.71	1.56	1.73	1.63	1.08	1.41
MEAN	1.80	1.57	1.73	1.62	<b>1.05</b>	1.41
S.D.	0.15	0.03	0.04	<b>0.02</b>	0.08	0.03
MAX	2.19	1.62	1.79	1.68	1.19	<b>1.46</b>
MIN	1.67	1.53	1.68	1.60	<b>0.95</b>	1.36

จากตารางที่ 3.21 ระยะเวลาในการทำนายโมเดลการเรียนรู้เชิงต้นของชุดข้อมูลที่ 2 โดยที่โมเดลการถดถอยเชิงเส้นสามารถทำระยะเวลาค่าเฉลี่ยได้เร็วสุดที่ 1.05 วินาที ขณะที่โมเดลต้นไม้ตัดสินใจใช้เวลามากที่สุดที่ 1.80 วินาที

ประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 2 ดังแสดงตามตารางที่ 3.22

ตารางที่ 3.22 ประสิทธิภาพการทำนายประเภทของกลิ้งด้วยโมเดลการเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 2

ครั้ง	ความแม่นยำของโมเดล (ร้อยละ)			
	Gradient Boosting	XGBoost	AdaBoost	Random Forest
1	100.00	98.67	98.67	100.00
2	99.00	99.00	99.33	99.33
3	99.33	99.67	98.33	99.00
4	99.00	100.00	99.00	99.33
5	98.67	98.33	100.00	99.67
6	99.33	99.67	98.00	99.33
7	100.00	100.00	98.67	99.67
8	98.67	100.00	99.33	99.67
9	100.00	98.00	96.67	98.67
10	99.67	99.33	100.00	98.67
MEAN	<b>99.37</b>	99.27	98.80	99.33
S.D.	0.53	0.73	1.00	<b>0.44</b>
MAX	<b>100.00</b>	100.00	100.00	<b>100.00</b>
MIN	<b>98.67</b>	98.00	96.67	<b>98.67</b>

จากตารางที่ 3.22 ผลการทดสอบประสิทธิภาพการทำนายประเภทของกลิ้งด้วยโมเดลการเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 2 แสดงให้เห็นว่า โมเดลที่มีประสิทธิภาพมากที่สุด คือ โมเดลเกรเดียนบูสตี้ง มีค่าความแม่นยำเฉลี่ยที่ร้อยละ 99.37 มีค่าส่วนเบี่ยงเบนมาตรฐานร้อยละ 0.53 รองลงมาเป็นป่าแบบสุ่มมีค่าความแม่นยำเฉลี่ยเท่ากับที่ร้อยละ 99.33 ซึ่งทั้ง 2 โมเดลมีค่าความแม่นยำสูงสุดและต่ำสุดที่ร้อยละ 100 และ 98.67 ตามลำดับที่เท่ากัน แต่แตกต่างกันที่ส่วนเบี่ยงเบนมาตรฐาน และแสดงระยะเวลาดำเนินการในหน่วยวินาทีของแต่ละโมเดลดังแสดงตามตารางที่ 3.23

ตารางที่ 3.23 ระยะเวลาการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 2

ครั้ง	ระยะเวลาในการทำนายของโมเดล (วินาที)			
	Gradient Boosting	XGBoost	AdaBoost	Random Forest
1	2.54	2.53	0.70	1.65
2	1.90	1.91	0.71	1.54
3	1.86	1.85	0.70	1.93
4	1.88	1.84	0.70	1.89
5	1.86	1.98	0.74	1.95
6	1.82	1.85	0.75	1.90
7	1.86	1.82	0.73	1.94
8	1.83	1.83	0.72	1.85
9	1.82	1.83	0.71	1.93
10	1.81	2.09	0.73	1.92
MEAN	1.92	1.95	<b>0.72</b>	1.85
S.D.	0.22	0.22	<b>0.02</b>	0.14
MAX	2.54	2.53	<b>0.75</b>	1.95
MIN	1.81	1.82	<b>0.70</b>	1.54

จากตารางที่ 3.23 ระยะเวลาในการทำนายโมเดลการเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 2 โมเดลอะแดปทีฟบูสตีงสามารถทำระยะเวลาค่าเฉลี่ยได้เร็วสุดที่ 0.72 วินาที ส่วนเบี่ยงเบนมาตรฐาน 0.02 ใช้เวลาต่ำที่สุด 0.70 วินาที และใช้เวลามากที่สุด 0.75 วินาที ซึ่งใช้ระยะเวลาเร็วมากเมื่อเทียบกับโมเดลอื่น

ประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึก ซึ่งได้แก่ โมเดลโครงข่ายประสาทเทียมแบบลึก ของชุดข้อมูลที่ 2 ดังแสดงตามตารางที่ 3.24

ตารางที่ 3.24 ประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึกในการปรับ  
 ปรุงชั้นฮิดเดนที่ 1 ของชุดข้อมูลที่ 2

ครั้ง	ความแม่นยำของโมเดล (ร้อยละ)							
	Deep Neural Network (ปรับปรุงชั้นฮิดเดนที่ 1)							
	2	4	8	16	32	64	128	256
1	98.00	98.33	98.67	97.67	98.00	98.33	96.67	97.33
2	98.00	98.00	98.33	98.00	98.67	98.00	98.33	98.00
3	98.00	97.33	98.67	96.00	97.33	97.67	96.67	98.67
4	97.33	98.67	97.67	97.00	97.00	97.33	97.00	96.33
5	98.33	98.33	99.00	98.33	97.67	98.00	96.67	97.67
6	97.00	98.67	97.67	97.67	99.00	98.67	99.00	98.33
7	98.33	96.33	98.67	99.00	98.33	97.67	97.33	97.67
8	98.67	98.67	97.00	97.33	98.00	97.67	97.67	98.00
9	97.67	97.67	98.00	98.00	97.00	98.00	98.00	97.33
10	98.00	98.67	97.33	97.67	97.67	99.00	97.00	98.00
MEAN	97.93	98.07	<b>98.10</b>	97.67	97.87	98.03	97.43	97.73
S.D.	<b>0.49</b>	0.77	0.67	0.80	0.67	0.51	0.80	0.65
MAX	98.67	98.67	<b>99.00</b>	99.00	99.00	99.00	99.00	98.67
MIN	97.00	96.33	97.00	<b>96.00</b>	97.00	97.33	96.67	96.33

จากตารางที่ 3.24 แสดงประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึกของชุดข้อมูลที่ 2 ในการปรับปรุงชั้นฮิดเดนที่ 1 กำหนดจำนวนเซลล์ประสาท (neuron) เริ่มต้นที่  $2^n$  โดย  $n = 1, 2, 3, \dots$  เพิ่มจำนวน  $n$  ขึ้นไปเรื่อย ๆ จนมีค่าความแม่นยำคงที่หรือลดลง จึงหยุดการเพิ่มจำนวน  $n$  ในชั้นฮิดเดนที่ 1 จากนั้นเลือกจำนวนเซลล์ประสาทที่ให้ค่าความแม่นยำที่มากที่สุด โดยในชั้นฮิดเดนที่ 1 ที่มีจำนวนเซลล์ประสาท 8 เซลล์ ให้ค่าความแม่นยำเฉลี่ยที่มากที่สุดที่ร้อยละ 98.10 ส่วนเบี่ยงเบนมาตรฐานที่ร้อยละ 0.67 และแสดงระยะเวลาดำเนินการในหน่วยวินาทีของแต่ละโมเดล ดังแสดงตามตารางที่ 3.25

ตารางที่ 3.25 ระยะเวลาการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึกในการปรับ  
จูนชั้นฮิดเดนที่ 1 ของชุดข้อมูลที่ 2

ครั้ง	ระยะเวลาในการทำนายของโมเดล (วินาที)							
	Deep Neural Network (ปรับจูนชั้นฮิดเดนที่ 1)							
	2	4	8	16	32	64	128	256
1	33.24	34.46	33.47	34.51	34.06	34.04	34.63	34.85
2	34.35	34.44	32.96	33.84	33.72	34.90	34.43	34.38
3	34.04	33.59	33.31	34.30	34.52	33.82	33.60	35.38
4	34.04	34.69	33.87	33.42	34.44	34.00	33.79	34.38
5	34.40	34.74	34.21	34.17	33.24	33.89	34.25	35.20
6	34.02	34.59	33.80	34.42	33.61	33.73	34.38	34.96
7	33.97	34.58	33.74	33.99	34.21	33.55	33.46	34.89
8	34.04	35.04	34.08	33.87	34.06	34.72	33.25	34.32
9	34.38	34.43	34.22	33.57	35.52	33.82	33.78	35.57
10	34.63	33.77	33.88	33.91	35.37	34.46	34.68	34.55
MEAN	34.11	34.43	<b>33.75</b>	34.00	34.28	34.09	34.03	34.85
S.D.	0.38	0.46	0.40	<b>0.35</b>	0.73	0.45	0.51	0.44
MAX	34.63	35.04	<b>34.22</b>	34.51	35.52	34.90	34.68	35.57
MIN	<b>33.24</b>	33.59	32.96	33.42	<b>33.24</b>	33.55	33.25	34.32

จากตารางที่ 3.25 ระยะเวลาในการทำนายโมเดลการเรียนรู้เชิงลึกของชุดข้อมูลที่ 2 โมเดลโครงข่ายประสาทเทียมแบบลึกชั้นฮิดเดนที่ 1 จำนวนเซลล์ประสาทที่ 8 ซึ่งใช้ระยะเวลาที่เร็วที่สุด 33.75 วินาที เมื่อเทียบกับจำนวนเซลล์ประสาทอื่น ๆ

เมื่อได้ผลการทดลองในการปรับจูนชั้นฮิดเดนที่ 1 แล้ว จึงเลือกจำนวนเซลล์ประสาทที่ 8 มาปรับจูนในขั้นตอนต่อไปคือ ชั้นฮิดเดนที่ 2 โดยมีประสิทธิภาพการทำนายประเภทของกลิ่นของชุดข้อมูลที่ 2 ดังแสดงตามตารางที่ 3.26

ตารางที่ 3.26 ประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึกในการปรับ  
 ปรุงชั้นฮิดเดนที่ 2 ของชุดข้อมูลที่ 2

ครั้ง	ความแม่นยำของโมเดล (ร้อยละ)							
	Deep Neural Network (ปรับปรุงชั้นฮิดเดนที่ 2)							
	8-2	8-4	8-8	8-16	8-32	8-64	8-128	8-256
1	96.67	97.67	98.33	96.67	97.33	98.33	97.00	98.00
2	96.33	99.00	99.33	97.33	98.00	97.00	98.33	98.33
3	99.00	98.33	97.67	99.00	98.33	99.33	98.67	97.67
4	22.00	98.67	98.33	98.67	97.67	97.67	97.33	98.33
5	23.00	97.67	97.00	98.67	98.00	99.00	97.00	97.33
6	98.67	98.33	97.33	99.00	99.00	97.33	98.33	98.33
7	98.00	98.00	97.00	96.67	98.67	96.33	97.00	99.33
8	23.67	99.33	97.00	97.67	96.67	99.00	98.67	96.33
9	23.67	98.00	96.67	97.67	98.00	98.33	97.67	99.33
10	97.33	98.33	99.00	98.33	98.00	97.33	95.33	96.67
MEAN	67.83	<b>98.33</b>	97.77	97.97	97.97	97.97	97.53	97.97
S.D.	38.52	<b>0.54</b>	0.93	0.89	0.66	0.99	1.03	1.00
MAX	99.00	<b>99.33</b>	99.33	99.00	99.00	99.33	98.67	99.33
MIN	22.00	<b>97.67</b>	96.67	96.67	96.67	96.33	95.33	96.33

จากตารางที่ 3.26 แสดงประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึกของชุดข้อมูลที่ 2 ในการปรับปรุงชั้นฮิดเดนที่ 2 โดยชั้นฮิดเดนที่ 1 มีจำนวนเซลล์ประสาทเป็น 8 เซลล์ กำหนดจำนวนเซลล์ประสาท (neuron) ให้กับชั้นฮิดเดนที่ 2 เริ่มต้นที่  $2^n$  โดย  $n = 1, 2, 3, \dots$  เพิ่มจำนวน  $n$  ขึ้นไปเรื่อย ๆ จนมีค่าความแม่นยำคงที่หรือลดลง จึงหยุดการเพิ่มจำนวน  $n$  ในชั้นฮิดเดนที่ 2 จากนั้นเลือกจำนวนเซลล์ประสาทที่ให้ค่าความแม่นยำที่มากที่สุด โดยชั้นฮิดเดนที่ 1 จำนวนเซลล์ประสาท 8 เซลล์ และชั้นฮิดเดนที่ 2 จำนวนเซลล์ประสาท 4 เซลล์ ให้ค่าความแม่นยำเฉลี่ยที่มากที่สุดที่ร้อยละ 98.33 ส่วนเบี่ยงเบนมาตรฐานที่ร้อยละ 0.54 มีค่าความแม่นยำมากที่สุดอยู่ที่ร้อยละ 99.33 ความแม่นยำต่ำที่สุดอยู่ที่ร้อยละ 97.67 และแสดงระยะเวลาดำเนินการในหน่วยวินาทีของแต่ละโมเดลดังแสดงตามตารางที่ 3.27

ตารางที่ 3.27 ระยะเวลาการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึกในการปรับ  
 ปรุงชั้นฮิดเดนที่ 2 ของชุดข้อมูลที่ 2

ครั้ง	ระยะเวลาในการทำนายของโมเดล (วินาที)							
	Deep Neural Network (ปรับปรุงชั้นฮิดเดนที่ 2)							
	8-2	8-4	8-8	8-16	8-32	8-64	8-128	8-256
1	35.49	36.02	35.96	36.70	36.50	37.16	37.61	38.02
2	36.54	36.71	37.19	35.80	35.71	37.74	36.33	37.91
3	35.84	36.35	36.12	35.62	36.03	36.46	37.61	37.42
4	35.39	36.12	35.75	36.14	36.36	36.75	37.21	38.49
5	35.60	36.96	36.14	35.65	35.45	36.31	37.09	38.32
6	35.97	36.72	35.66	35.65	35.38	36.81	36.82	37.86
7	36.83	36.74	36.02	36.36	36.27	35.46	36.12	38.47
8	36.90	35.67	35.04	35.24	35.27	36.85	39.17	37.43
9	36.30	37.02	35.53	35.25	35.90	37.55	37.67	39.06
10	36.61	35.94	36.45	36.97	35.45	37.09	36.58	38.58
MEAN	36.15	36.43	35.99	35.94	<b>35.83</b>	36.82	37.22	38.16
S.D.	0.56	0.47	0.57	0.59	<b>0.45</b>	0.65	0.88	0.52
MAX	36.90	37.02	37.19	36.97	<b>36.50</b>	37.74	39.17	39.06
MIN	35.39	35.67	<b>35.04</b>	35.24	35.27	35.46	36.12	37.42

จากตารางที่ 3.27 ระยะเวลาในการทำนายโมเดลการเรียนรู้เชิงลึกของชุดข้อมูลที่ 2 โมเดลโครงข่ายประสาทเทียมแบบลึกชั้นฮิดเดนที่ 1 จำนวนเซลล์ประสาท 8 เซลล์ และชั้นฮิดเดนที่ 2 จำนวนเซลล์ประสาท 4 เซลล์ ถึงแม้จะไม่ได้ระยะเวลาที่เร็วที่สุด แต่อยู่ในระยะเวลาที่รับได้เมื่อเทียบกับจำนวนเซลล์ประสาทอื่น ๆ

เมื่อได้ผลการทดลองในการปรับปรุงชั้นฮิดเดนที่ 2 แล้ว จึงเลือกชั้นฮิดเดนที่ 1 จำนวนเซลล์ประสาท 8 เซลล์ และชั้นฮิดเดนที่ 2 จำนวนเซลล์ประสาท 4 เซลล์ มาปรับปรุงในขั้นตอนต่อไปคือ ชั้นฮิดเดนที่ 3 โดยมีประสิทธิภาพการทำนายประเภทของกลิ่นของชุดข้อมูลที่ 2 ดังแสดงตามตารางที่ 3.28

ตารางที่ 3.28 ประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึกในการปรับ  
 ปรุงชั้นฮิดเดนที่ 3 ของชุดข้อมูลที่ 2

ครั้ง	ความแม่นยำของโมเดล (ร้อยละ)							
	Deep Neural Network (ปรับปรุงชั้นฮิดเดนที่ 3)							
	8-4-2	8-4-4	8-4-8	8-4-16	8-4-32	8-4-64	8-4-128	8-4-256
1	97.67	97.67	76.33	96.67	95.33	98.33	98.33	98.67
2	97.33	73.67	98.33	99.00	97.67	98.33	98.00	96.33
3	23.33	70.33	97.00	98.00	73.33	97.67	98.00	98.00
4	97.67	97.00	96.67	98.00	98.67	96.67	95.33	98.67
5	22.33	97.00	74.33	98.00	97.67	98.00	98.00	98.33
6	94.00	98.00	98.67	97.67	96.67	99.00	98.33	95.00
7	97.00	98.00	97.33	99.00	97.00	98.67	97.67	96.33
8	98.67	97.33	97.00	98.33	95.00	98.00	97.67	97.67
9	97.00	97.67	98.00	97.33	97.67	99.00	98.00	97.67
10	73.00	96.67	97.00	73.33	98.00	98.33	98.00	98.67
MEAN	79.80	92.33	93.07	95.53	94.70	<b>98.20</b>	97.73	97.53
S.D.	30.97	10.75	9.38	7.83	7.60	<b>0.69</b>	0.87	1.25
MAX	98.67	98.00	98.67	99.00	98.67	<b>99.00</b>	98.33	98.67
MIN	22.33	70.33	74.33	73.33	73.33	<b>96.67</b>	95.33	95.00

จากตารางที่ 3.28 แสดงประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึกของชุดข้อมูลที่ 2 ในการปรับปรุงชั้นฮิดเดนที่ 3 โดยชั้นฮิดเดนที่ 1 มีจำนวนเซลล์ประสาทเป็น 8 เซลล์ และชั้นฮิดเดนที่ 2 จำนวนเซลล์ประสาท 16 เซลล์ กำหนดจำนวนเซลล์ประสาท (neuron) ให้กับชั้นฮิดเดนที่ 3 เริ่มต้นที่  $2^n$  โดย  $n = 1, 2, 3, \dots$  เพิ่มจำนวน  $n$  ขึ้นไปเรื่อย ๆ จนมีค่าความแม่นยำคงที่หรือลดลง จึงหยุดการเพิ่มจำนวน  $n$  ในชั้นฮิดเดนที่ 3 จากนั้นเลือกจำนวนเซลล์ประสาทที่ให้ค่าความแม่นยำที่มากที่สุด โดยชั้นฮิดเดนที่ 1 จำนวนเซลล์ประสาท 8 เซลล์ ชั้นฮิดเดนที่ 2 จำนวนเซลล์ประสาท 4 เซลล์ และชั้นฮิดเดนที่ 3 จำนวนเซลล์ประสาท 64 เซลล์ ให้ค่าความแม่นยำเฉลี่ยที่มากที่สุดที่ร้อยละ 98.20 แต่มีค่าความแม่นยำน้อยกว่าชั้นฮิดเดนที่ 2 จึงทำการหยุดการปรับปรุง และแสดงระยะเวลาดำเนินการในหน่วยวินาทีของแต่ละโมเดลดังแสดงตามตารางที่ 3.29

ตารางที่ 3.29 ระยะเวลาการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึกในการปรับ  
 ปรุงชั้นฮิดเดนที่ 3 ของชุดข้อมูลที่ 2

ครั้ง	ระยะเวลาในการทำนายของโมเดล (วินาที)							
	Deep Neural Network (ปรับปรุงชั้นฮิดเดนที่ 3)							
	8-4-2	8-4-4	8-4-8	8-4-16	8-4-32	8-4-64	8-4-128	8-4-256
1	39.75	39.89	38.62	39.73	38.60	39.85	40.39	40.04
2	38.77	38.95	39.01	39.49	39.38	38.46	40.10	39.86
3	38.94	38.71	39.23	39.21	39.52	39.10	39.73	40.79
4	39.31	38.47	38.26	39.18	38.85	38.97	39.41	40.12
5	38.12	38.94	38.75	39.04	40.27	38.88	40.30	40.01
6	39.04	39.57	38.74	39.18	38.70	38.89	39.15	40.81
7	38.34	38.31	39.28	39.02	38.92	39.08	39.82	41.39
8	39.10	38.62	37.89	38.99	38.56	39.60	39.74	40.22
9	39.01	39.67	39.19	39.37	40.12	39.87	39.76	40.39
10	38.60	38.65	39.78	38.75	39.50	38.77	40.01	39.51
MEAN	38.90	38.98	<b>38.88</b>	39.20	39.24	39.15	39.84	40.31
S.D.	0.47	0.55	0.55	<b>0.28</b>	0.62	0.47	0.38	0.55
MAX	39.75	39.89	39.78	<b>39.73</b>	40.27	39.87	40.39	41.39
MIN	38.12	38.31	<b>37.89</b>	38.75	38.56	38.46	39.15	39.51

จากตารางที่ 3.29 แสดงระยะเวลาในการทำนายโมเดลการเรียนรู้เชิงลึกของชุดข้อมูลที่ 2 โมเดลโครงข่ายประสาทเทียมแบบลึกชั้นฮิดเดนที่ 1 จำนวนเซลล์ประสาท 8 เซลล์ ชั้นฮิดเดนที่ 2 จำนวนเซลล์ประสาท 4 เซลล์ และชั้นฮิดเดนที่ 3 จำนวนเซลล์ประสาท 8 เซลล์ ใช้ระยะเวลาที่เร็วที่สุด 38.88 วินาที

ดังนั้น โครงข่ายประสาทเทียมแบบลึกสำหรับชุดข้อมูลที่ 2 จึงเลือกใช้โมเดลที่มีชั้นฮิดเดนที่ 1 จำนวนเซลล์ประสาท 8 เซลล์ และชั้นฮิดเดนที่ 2 จำนวนเซลล์ประสาท 4 เซลล์

จากนั้นทำการเปรียบเทียบประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงต้นของชุดข้อมูลที่ 3 ต่อไป ดังแสดงตามตารางที่ 3.30

ตารางที่ 3.30 ประสิทธิภาพการทำนายประเภทของกลืนด้วยโมเดลการเรียนรู้เชิงต้นของชุดข้อมูลที่ 3

วิธี	ความแม่นยำของโมเดล (ร้อยละ)					
	Decision Tree	Naïve Bayes	SVM	k-NN	Linear Regression	Logistic Regression
1	98.89	55.44	91.83	98.39	53.38	78.00
2	99.22	57.44	93.44	97.78	52.36	76.83
3	98.94	58.67	93.72	97.89	50.27	78.94
4	99.28	57.89	93.72	97.78	53.69	79.67
5	99.06	58.06	92.61	97.39	54.79	74.61
6	99.33	58.39	93.89	98.67	55.07	75.50
7	98.78	54.50	93.06	98.11	53.58	78.83
8	99.28	56.11	93.56	98.33	53.36	77.83
9	99.11	56.00	93.17	97.89	54.07	78.61
10	98.94	58.78	93.22	98.06	52.53	77.00
MEAN	<b>99.08</b>	57.13	93.22	98.03	53.31	77.58
S.D.	<b>0.19</b>	1.50	0.62	0.37	1.37	1.60
MAX	<b>99.33</b>	58.78	93.89	98.67	55.07	79.67
MIN	<b>98.78</b>	54.50	91.83	97.39	50.27	74.61

จากตารางที่ 3.30 ผลการทดสอบประสิทธิภาพการทำนายประเภทของกลืนด้วยโมเดลการเรียนรู้เชิงต้นของชุดข้อมูลที่ 3 แสดงให้เห็นว่าโมเดลที่มีประสิทธิภาพมากที่สุด คือ โมเดลซัพพอร์ตเวกเตอร์แมชชีนมีค่าความแม่นยำเฉลี่ยที่ร้อยละ 99.08 รองลงมาเป็นวิธีการเพื่อนบ้านที่ใกล้ที่สุด k ตัว มีค่าความแม่นยำเฉลี่ยที่ร้อยละ 98.03

นอกจากนี้ยังได้แสดงระยะเวลาดำเนินการในหน่วยวินาทีของแต่ละโมเดล ดังแสดงตามตารางที่ 3.31

ตารางที่ 3.31 ระยะเวลาการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงต้นของชุดข้อมูลที่ 3

วิธี	ระยะเวลาในการทำนายของโมเดล (วินาที)					
	Decision Tree	Naïve Bayes	SVM	k-NN	Linear Regression	Logistic Regression
1	1.69	1.52	9.10	1.78	0.98	1.85
2	1.70	1.51	10.37	1.79	0.94	1.83
3	1.67	1.51	10.85	1.91	0.93	1.80
4	1.90	1.52	10.53	1.72	0.92	1.79
5	1.77	1.53	11.94	1.69	0.89	1.83
6	1.49	1.52	9.84	1.64	0.97	1.88
7	1.71	1.54	10.40	1.68	0.89	1.81
8	1.49	1.49	12.41	1.68	0.93	1.79
9	1.72	1.47	10.74	1.67	0.91	1.85
10	1.68	1.48	12.86	1.66	0.90	1.87
MEAN	1.68	1.51	10.90	1.72	<b>0.93</b>	1.83
S.D.	0.12	<b>0.02</b>	1.17	0.08	0.03	0.03
MAX	1.90	1.54	12.86	1.91	<b>0.98</b>	1.88
MIN	1.49	1.47	9.10	1.64	<b>0.89</b>	1.79

จากตารางที่ 3.31 ระยะเวลาในการทำนายโมเดลการเรียนรู้เชิงต้นของชุดข้อมูลที่ 3 ในแต่ละโมเดลมีความแตกต่างกันไม่มากนัก โดยที่โมเดลการถดถอยเชิงเส้นสามารถทำระยะเวลาค่าเฉลี่ยได้เร็วสุดที่ 0.93 วินาที ใช้เวลาดำที่ต่ำที่สุด 0.89 วินาที และใช้เวลามากที่สุด 0.98 วินาที ในขณะที่ซัพพอร์ตเวกเตอร์แมชชีนใช้ระยะเวลาเฉลี่ยที่ 10.90 วินาที ซึ่งใช้เวลามากที่สุดเมื่อเทียบกับโมเดลอื่น ๆ

ประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 3 ดังแสดงตามตารางที่ 3.32

ตารางที่ 3.32 ประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 3

ครั้ง	ความแม่นยำของโมเดล (ร้อยละ)			
	Gradient Boosting	XGBoost	AdaBoost	Random Forest
1	99.83	99.22	99.72	99.50
2	99.67	99.61	99.78	99.83
3	99.44	99.56	99.67	100.00
4	99.83	99.39	99.78	99.72
5	99.67	99.11	100.00	99.50
6	99.50	99.39	99.72	99.78
7	99.50	99.11	100.00	99.83
8	99.78	99.50	99.61	99.50
9	99.17	99.00	99.67	99.83
10	99.83	99.50	99.72	99.83
MEAN	99.62	99.34	<b>99.77</b>	99.73
S.D.	0.22	0.21	<b>0.13</b>	0.17
MAX	99.83	99.61	<b>100.00</b>	100.00
MIN	99.17	99.00	<b>99.61</b>	99.50

จากตารางที่ 3.32 ผลการทดสอบประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 3 แสดงให้เห็นว่า โมเดลที่มีประสิทธิภาพมากที่สุดคือ โมเดลอะแดปทีฟบูสตีงมีความแม่นยำเฉลี่ยที่ร้อยละ 99.77 มีค่าส่วนเบี่ยงเบนมาตรฐานร้อยละ 0.13 ความแม่นยำที่น้อยที่สุดร้อยละ 99.61 ซึ่งมากที่สุดเมื่อเทียบกับโมเดลอื่น รองลงมาเป็นป่าแบบสุ่มมีความแม่นยำเฉลี่ยเท่ากับร้อยละ 99.73 ซึ่งใกล้เคียงกับอะแดปทีฟบูสตีง และแสดงระยะเวลาดำเนินการในหน่วยวินาทีของแต่ละโมเดลดังแสดงตามตารางที่ 3.33

ตารางที่ 3.33 ระยะเวลาการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 3

ครั้ง	ระยะเวลาในการทำนายของโมเดล (วินาที)			
	Gradient Boosting	XGBoost	AdaBoost	Random Forest
1	7.39	4.40	3.48	2.30
2	7.19	4.23	3.25	2.34
3	7.19	4.13	3.25	2.23
4	7.10	3.62	3.22	2.16
5	7.08	3.14	3.28	2.24
6	7.16	3.23	3.31	2.23
7	7.16	3.40	3.30	2.21
8	7.25	3.23	3.15	2.18
9	7.20	3.18	3.20	2.21
10	7.22	3.16	3.18	2.32
MEAN	7.19	3.57	3.26	<b>2.24</b>
S.D.	0.09	0.50	0.09	<b>0.06</b>
MAX	7.39	4.40	3.48	<b>2.34</b>
MIN	7.08	3.14	3.15	<b>2.16</b>

จากตารางที่ 3.33 ระยะเวลาในการทำนายโมเดลการเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 3 โดยโมเดลป่าแบบสุ่มทำระยะเวลาค่าเฉลี่ยได้เร็วสุด 2.24 วินาที รองลงมาเป็นโมเดลอะแดปทีฟบูสตีงสามารถทำระยะเวลาค่าเฉลี่ยได้เร็วสุดที่ 3.26 วินาที

ประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึก ซึ่งได้แก่ โมเดลโครงข่ายประสาทเทียมแบบลึก ของชุดข้อมูลที่ 3 ดังแสดงตามตารางที่ 3.34

ตารางที่ 3.34 ประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึกในการปรับ  
 ปรุงชั้นฮิดเดนที่ 1 ของชุดข้อมูลที่ 3

ครั้ ง	ความแม่นยำของโมเดล (ร้อยละ)							
	Deep Neural Network (ปรับปรุงชั้นฮิดเดนที่ 1)							
	2	4	8	16	32	64	128	256
1	15.83	86.11	50.78	94.11	96.61	89.61	16.94	17.17
2	15.00	88.11	88.67	94.39	96.78	96.39	15.67	17.06
3	15.44	16.22	15.56	95.50	94.22	95.28	95.72	17.22
4	15.00	15.17	15.89	94.72	89.11	93.06	16.94	16.94
5	15.28	16.00	77.83	95.33	92.89	95.61	17.61	14.94
6	49.72	15.89	15.89	91.94	94.61	95.22	17.11	16.50
7	16.06	16.11	49.78	90.78	95.11	93.11	16.28	16.50
8	15.06	53.22	79.72	96.72	87.72	90.61	17.22	16.61
9	15.44	16.06	15.72	93.00	84.22	91.44	17.44	16.22
10	15.78	52.67	85.89	92.00	93.28	95.00	16.72	16.39
MEAN	18.86	37.56	49.57	<b>93.85</b>	92.46	93.53	24.77	16.56
S.D.	10.85	30.18	31.85	1.87	4.12	2.34	24.94	<b>0.67</b>
MAX	49.72	88.11	88.67	96.72	<b>96.78</b>	96.39	95.72	17.22
MIN	15.00	15.17	15.56	<b>90.78</b>	84.22	89.61	15.67	14.94

จากตารางที่ 3.34 แสดงประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึก  
 ของชุดข้อมูลที่ 3 ในการปรับปรุงชั้นฮิดเดนที่ 1 กำหนดจำนวนเซลล์ประสาท (neuron) เริ่มต้นที่  $2^n$   
 โดย  $n = 1, 2, 3, \dots$  เพิ่มจำนวน  $n$  ขึ้นไปเรื่อย ๆ จนมีค่าความแม่นยำคงที่หรือลดลง จึงหยุดการเพิ่ม  
 จำนวน  $n$  ในชั้นฮิดเดนที่ 1 ที่มีจำนวนเซลล์ประสาท 16 เซลล์ มีค่าความแม่นยำเฉลี่ยที่มากที่สุดที่ร้อย  
 ละ 93.85 ส่วนเบี่ยงเบนมาตรฐานที่ร้อยละ 1.87 และแสดงระยะเวลาดำเนินการในหน่วยวินาทีของ  
 แต่ละโมเดลดังแสดงตามตารางที่ 3.35

ตารางที่ 3.35 ระยะเวลาการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึกในการปรับ  
 ปรุงชั้นฮิดเดนที่ 1 ของชุดข้อมูลที่ 3

ครั้ง	ระยะเวลาในการทำนายของโมเดล (วินาที)							
	Deep Neural Network (ปรับปรุงชั้นฮิดเดนที่ 1)							
	2	4	8	16	32	64	128	256
1	177.42	172.56	201.98	201.33	204.94	176.83	179.69	218.56
2	175.60	180.47	201.81	198.83	204.77	180.41	189.82	224.60
3	179.32	178.63	201.58	210.51	206.80	185.88	192.86	209.43
4	177.94	172.66	201.25	210.77	200.77	182.40	178.71	213.89
5	179.18	178.59	200.77	198.99	207.80	178.96	176.47	210.70
6	175.17	174.25	199.57	207.33	199.07	178.61	206.19	209.75
7	179.89	175.69	202.34	205.13	200.64	187.98	207.58	211.38
8	173.09	173.45	202.27	202.52	210.61	190.39	207.75	211.26
9	180.31	178.28	201.09	211.87	211.00	184.78	210.97	212.93
10	175.01	176.10	202.04	206.23	206.94	192.23	206.40	211.42
MEAN	<b>177.29</b>	176.07	201.47	205.35	205.33	183.85	195.64	213.39
S.D.	2.45	2.82	<b>0.84</b>	4.83	4.13	5.27	13.75	4.73
MAX	<b>180.31</b>	180.47	202.34	211.87	211.00	192.23	210.97	224.60
MIN	173.09	<b>172.56</b>	199.57	198.83	199.07	176.83	176.47	209.43

จากตารางที่ 3.35 ระยะเวลาในการทำนายโมเดลการเรียนรู้เชิงลึกของชุดข้อมูลที่ 3 โมเดลโครงข่ายประสาทเทียมแบบลึกชั้นฮิดเดนที่ 1 จำนวนเซลล์ประสาทที่ 16 ถึงแม้จะไม่ได้ระยะเวลาที่เร็วที่สุด แต่อยู่ในระยะเวลาที่รับได้เมื่อเทียบกับจำนวนเซลล์ประสาทอื่น ๆ

เมื่อได้ผลการทดลองในการปรับปรุงชั้นฮิดเดนที่ 1 แล้ว จึงเลือกจำนวนเซลล์ประสาทที่ 16 มาปรับปรุงในขั้นตอนต่อไปคือ ชั้นฮิดเดนที่ 2 โดยมีประสิทธิภาพการทำนายประเภทของกลิ่นของชุดข้อมูลที่ 3 ดังแสดงตามตารางที่ 3.36

ตารางที่ 3.36 ประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึกในการปรับ  
 ปรุงชั้นฮิดเดนที่ 2 ของชุดข้อมูลที่ 3

ครั้ง	ความแม่นยำของโมเดล (ร้อยละ)							
	Deep Neural Network (ปรับปรุงชั้นฮิดเดนที่ 2)							
	16-2	16-4	16-8	16-16	16-32	16-64	16-128	16-256
1	16.06	95.00	94.56	96.94	98.44	98.17	98.83	97.17
2	15.72	88.06	86.44	97.17	99.72	98.67	99.06	97.89
3	15.50	15.56	97.17	97.56	99.61	99.33	95.44	99.22
4	48.00	82.11	92.61	96.17	99.72	98.89	99.06	95.44
5	62.44	91.72	85.78	93.17	97.89	99.11	98.61	99.22
6	15.61	85.78	89.33	97.00	95.39	94.22	86.39	97.83
7	14.94	15.94	93.39	95.28	96.67	98.28	99.78	99.67
8	84.28	81.50	95.72	95.83	99.33	98.56	99.06	99.17
9	85.56	84.06	94.78	98.72	99.00	98.39	94.28	93.94
10	72.22	15.89	91.67	95.17	98.17	98.28	99.22	95.39
MEAN	43.03	65.56	92.15	96.30	<b>98.39</b>	98.19	96.97	97.49
S.D.	30.80	34.59	3.86	1.54	<b>1.44</b>	1.45	4.13	1.98
MAX	85.56	95.00	97.17	98.72	99.72	99.33	<b>99.78</b>	99.67
MIN	14.94	15.56	85.78	93.17	<b>95.39</b>	94.22	86.39	93.94

จากตารางที่ 3.36 แสดงประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึกของชุดข้อมูลที่ 3 ในการปรับปรุงชั้นฮิดเดนที่ 2 โดยชั้นฮิดเดนที่ 1 มีจำนวนเซลล์ประสาทเป็น 16 เซลล์ กำหนดจำนวนเซลล์ประสาท (neuron) ให้กับชั้นฮิดเดนที่ 2 เริ่มต้นที่  $2^n$  โดย  $n = 1, 2, 3, \dots$  เพิ่มจำนวน  $n$  ขึ้นไปเรื่อย ๆ จนมีค่าความแม่นยำคงที่หรือลดลง จึงหยุดการเพิ่มจำนวน  $n$  ในชั้นฮิดเดนที่ 2 จากนั้นเลือกจำนวนเซลล์ประสาทที่ให้ค่าความแม่นยำที่มากที่สุด โดยชั้นฮิดเดนที่ 1 จำนวนเซลล์ประสาท 16 เซลล์ และชั้นฮิดเดนที่ 2 จำนวนเซลล์ประสาท 32 เซลล์ ให้ค่าความแม่นยำเฉลี่ยที่มากที่สุดที่ร้อยละ 98.39 ส่วนเบี่ยงเบนมาตรฐานที่ร้อยละ 1.44 มีค่าความแม่นยำต่ำที่สุดอยู่ที่ร้อยละ 95.39 และแสดงระยะเวลาดำเนินการในหน่วยวินาทีของแต่ละโมเดลดังแสดงตามตารางที่ 3.37

ตารางที่ 3.37 ระยะเวลาการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึกในการปรับ  
 ปรุงชั้นฮิดเดนที่ 2 ของชุดข้อมูลที่ 3

ครั้ง	ระยะเวลาในการทำนายของโมเดล (วินาที)							
	Deep Neural Network (ปรับปรุงชั้นฮิดเดนที่ 2)							
	16-2	16-4	16-8	16-16	16-32	16-64	16-128	16-256
1	226.63	222.37	224.90	225.20	229.38	175.65	215.73	228.82
2	223.53	224.91	223.34	225.71	224.01	178.76	208.92	221.66
3	220.97	222.80	227.01	225.30	226.61	176.37	213.34	228.71
4	228.11	224.15	226.53	223.09	224.23	173.23	225.88	228.04
5	227.94	227.58	227.56	224.85	225.06	171.78	238.49	227.67
6	234.43	222.66	221.55	224.10	182.17	210.35	219.19	223.04
7	229.90	222.70	225.18	224.10	175.84	210.01	218.30	226.35
8	227.82	224.04	221.11	224.23	184.24	207.98	232.70	232.83
9	232.96	223.82	223.31	223.41	191.13	207.52	234.58	228.03
10	226.51	226.51	228.87	224.59	210.80	206.32	224.28	229.58
MEAN	227.88	224.15	224.94	224.46	207.35	<b>191.80</b>	223.14	227.47
S.D.	3.99	1.74	2.59	<b>0.84</b>	21.52	17.67	9.77	3.19
MAX	234.43	227.58	228.87	225.71	229.38	<b>210.35</b>	238.49	232.83
MIN	220.97	222.37	221.11	223.09	175.84	<b>171.78</b>	208.92	221.66

จากตารางที่ 3.37 ระยะเวลาในการทำนายโมเดลการเรียนรู้เชิงลึกของชุดข้อมูลที่ 3 โมเดลโครงข่ายประสาทเทียมแบบลึกชั้นฮิดเดนที่ 1 จำนวนเซลล์ประสาท 16 เซลล์ และชั้นฮิดเดนที่ 2 จำนวนเซลล์ประสาท 32 เซลล์ ถึงแม้จะไม่ได้ระยะเวลาที่เร็วที่สุด แต่อยู่ในระยะเวลาที่รับได้เมื่อเทียบกับจำนวนเซลล์ประสาทอื่น ๆ

เมื่อได้ผลการทดลองในการปรับปรุงชั้นฮิดเดนที่ 2 แล้ว จึงเลือกชั้นฮิดเดนที่ 1 จำนวนเซลล์ประสาท 16 เซลล์ และชั้นฮิดเดนที่ 2 จำนวนเซลล์ประสาท 32 เซลล์ มาปรับปรุงในขั้นตอนต่อไปคือ ชั้นฮิดเดนที่ 3 โดยมีประสิทธิภาพการทำนายประเภทของกลิ่นของชุดข้อมูลที่ 3 ดังแสดงตามตารางที่ 3.38

ตารางที่ 3.38 ประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึกในการปรับ  
 ปรุงชั้นฮิดเดนที่ 3 ของชุดข้อมูลที่ 3

ครั้ง	ความแม่นยำของโมเดล (ร้อยละ)							
	Deep Neural Network (ปรับปรุงชั้นฮิดเดนที่ 3)							
	16-32- 2	16-32- 4	16-32- 8	16-32- 16	16-32- 32	16-32- 64	16-32- 128	16-32- 256
1	69.72	96.70	97.67	98.00	98.44	99.33	98.56	99.22
2	15.67	98.06	98.89	97.06	98.28	98.72	97.94	99.00
3	52.11	98.94	99.33	98.61	98.94	99.39	89.44	98.11
4	93.33	97.44	99.06	99.56	98.89	96.67	99.28	99.00
5	15.17	97.83	98.50	97.22	99.33	98.22	98.06	98.89
6	50.56	88.06	94.50	98.06	97.22	97.50	99.39	97.11
7	15.67	97.56	99.06	97.17	96.17	98.22	94.78	92.72
8	94.28	15.11	97.78	98.44	95.67	98.22	99.94	98.89
9	16.39	15.50	96.28	98.17	99.72	99.72	97.50	97.44
10	93.83	98.83	98.67	98.78	99.33	98.28	90.94	99.78
MEAN	51.67	80.40	97.97	98.11	98.20	<b>98.43</b>	96.58	98.02
S.D.	34.68	34.45	1.52	<b>0.80</b>	1.39	0.92	3.67	2.03
MAX	94.28	98.94	99.33	99.56	99.72	99.72	<b>99.94</b>	99.78
MIN	15.17	15.11	94.50	<b>97.06</b>	95.67	96.67	89.44	92.72

จากตารางที่ 3.38 แสดงประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึกของชุดข้อมูลที่ 3 ในการปรับปรุงชั้นฮิดเดนที่ 3 โดยชั้นฮิดเดนที่ 1 มีจำนวนเซลล์ประสาทเป็น 16 เซลล์ และชั้นฮิดเดนที่ 2 จำนวนเซลล์ประสาท 32 เซลล์ กำหนดจำนวนเซลล์ประสาท (neuron) ให้กับชั้นฮิดเดนที่ 3 เริ่มต้นที่  $2^n$  โดย  $n = 1, 2, 3, \dots$  เพิ่มจำนวน  $n$  ขึ้นไปเรื่อย ๆ จนมีค่าความแม่นยำคงที่หรือลดลง จึงหยุดการเพิ่มจำนวน  $n$  ในชั้นฮิดเดนที่ 3 จากนั้นเลือกจำนวนเซลล์ประสาทที่ให้ค่าความแม่นยำที่มากที่สุด โดยชั้นฮิดเดนที่ 1 จำนวนเซลล์ประสาท 16 เซลล์ ชั้นฮิดเดนที่ 2 จำนวนเซลล์ประสาท 32 เซลล์ และชั้นฮิดเดนที่ 3 จำนวนเซลล์ประสาท 64 เซลล์ ให้ค่าความแม่นยำเฉลี่ยที่มากที่สุดที่ร้อยละ 98.43 ส่วนเบี่ยงเบนมาตรฐานที่ร้อยละ 0.92 มีค่าความแม่นยำต่ำที่สุดอยู่ที่ร้อยละ 96.67 ซึ่งเป็นค่าความแม่นยำเฉลี่ยที่ดีที่สุดเมื่อเทียบกับเซลล์ประสาทอื่น และแสดงระยะเวลาดำเนินการในหน่วยวินาทีของแต่ละโมเดลดังแสดงตามตารางที่ 3.39

ตารางที่ 3.39 ระยะเวลาการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึกในการปรับ  
จูนชั้นฮิดเดนที่ 3 ของชุดข้อมูลที่ 3

ครั้ง	ระยะเวลาในการทำนายของโมเดล (วินาที)							
	Deep Neural Network (ปรับจูนชั้นฮิดเดนที่ 3)							
	16-32- 2	16-32- 4	16-32- 8	16-32- 16	16-32- 32	16-32- 64	16-32- 128	16-32- 256
1	241.85	236.80	199.50	199.40	196.84	198.94	208.72	243.84
2	232.59	241.74	193.86	202.59	197.26	203.70	202.27	231.78
3	249.86	236.63	197.02	197.64	195.31	197.91	202.85	237.58
4	235.49	235.98	194.17	197.37	195.99	199.66	202.93	228.88
5	234.38	240.13	199.15	202.06	202.22	202.19	206.05	236.93
6	238.71	233.48	197.71	196.65	205.24	196.75	200.34	238.73
7	240.20	237.26	197.06	195.47	200.34	201.13	199.56	266.71
8	256.67	238.84	198.39	196.35	197.13	207.77	202.61	270.00
9	251.38	237.33	203.57	195.84	198.67	199.57	203.62	268.12
10	249.64	238.24	196.28	206.50	197.29	199.91	200.07	267.65
MEAN	243.08	237.64	<b>197.67</b>	198.99	198.63	200.75	202.90	249.02
S.D.	8.27	<b>2.28</b>	2.80	3.62	3.10	3.18	2.80	16.92
MAX	256.67	241.74	<b>203.57</b>	206.50	205.24	207.77	208.72	270.00
MIN	232.59	233.48	<b>193.86</b>	195.47	195.31	196.75	199.56	228.88

จากตารางที่ 3.39 ระยะเวลาในการทำนายโมเดลการเรียนรู้เชิงลึกของชุดข้อมูลที่ 3 โมเดลโครงข่ายประสาทเทียมแบบลึกชั้นฮิดเดนที่ 1 จำนวนเซลล์ประสาท 16 เซลล์ ชั้นฮิดเดนที่ 2 จำนวนเซลล์ประสาท 32 เซลล์ และชั้นฮิดเดนที่ 3 จำนวนเซลล์ประสาทที่ 64 ถึงแม้จะไม่ได้ระยะเวลาที่เร็วที่สุด แต่อยู่ในระยะเวลาที่รับได้เมื่อเทียบกับจำนวนเซลล์ประสาทอื่น ๆ

เมื่อได้ผลการทดลองในการปรับจูนชั้นฮิดเดนที่ 3 แล้ว จึงเลือกชั้นฮิดเดนที่ 1 จำนวนเซลล์ประสาท 16 เซลล์ ชั้นฮิดเดนที่ 2 จำนวนเซลล์ประสาท 32 เซลล์ และชั้นฮิดเดนที่ 3 จำนวนเซลล์ประสาทที่ 64 มาปรับจูนในขั้นตอนต่อไปคือ ชั้นฮิดเดนที่ 4 โดยมีประสิทธิภาพการทำนายประเภทของกลิ่นของชุดข้อมูลที่ 3 ดังแสดงตามตารางที่ 3.40

ตารางที่ 3.40 ประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึกในการปรับ  
 ปรุงชั้นฮิดเดนที่ 4 ของชุดข้อมูลที่ 3

ครั้ง	ความแม่นยำของโมเดล (ร้อยละ)							
	Deep Neural Network (ปรับปรุงชั้นฮิดเดนที่ 4)							
	16-32- 64-2	16-32- 64-4	16-32- 64-8	16-32- 64-16	16-32- 64-32	16-32- 64-64	16-32- 64-128	16-32- 64-256
1	15.67	98.78	98.39	97.12	97.33	99.39	98.44	96.78
2	15.56	96.89	97.06	98.22	96.50	95.78	97.78	99.33
3	16.33	98.06	89.61	96.83	98.89	97.00	96.06	98.06
4	77.17	97.11	97.39	98.72	98.78	95.89	99.17	97.22
5	16.17	98.61	92.89	98.67	99.17	98.83	99.56	89.94
6	15.22	97.39	97.22	98.44	99.06	98.72	98.56	98.00
7	92.83	98.61	99.56	99.00	99.28	99.00	98.06	91.67
8	16.17	16.28	98.61	97.11	99.00	99.44	98.17	93.00
9	16.28	97.28	99.06	96.22	94.44	99.28	98.89	94.78
10	15.72	66.50	94.72	96.78	97.11	97.50	95.83	84.06
MEAN	29.71	86.55	96.45	97.71	97.96	<b>98.08</b>	98.05	94.28
S.D.	29.37	26.59	3.15	<b>1.00</b>	1.59	1.43	1.23	4.72
MAX	92.83	98.78	99.56	99.00	99.28	99.44	<b>99.56</b>	99.33
MIN	15.22	16.28	89.61	<b>96.22</b>	94.44	95.78	95.83	84.06

จากตารางที่ 3.40 แสดงประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึกของชุดข้อมูลที่ 3 ในการปรับปรุงชั้นฮิดเดนที่ 4 โดยชั้นฮิดเดนที่ 1 มีจำนวนเซลล์ประสาทเป็น 16 เซลล์ ชั้นฮิดเดนที่ 2 จำนวนเซลล์ประสาท 32 เซลล์ และชั้นฮิดเดนที่ 3 จำนวนเซลล์ประสาท 64 เซลล์ กำหนดจำนวนเซลล์ประสาท (neuron) ให้กับชั้นฮิดเดนที่ 4 เริ่มต้นที่  $2^n$  โดย  $n = 1, 2, 3, \dots$  เพิ่มจำนวน  $n$  ขึ้นไปเรื่อย ๆ จนมีค่าความแม่นยำคงที่หรือลดลง จึงหยุดการเพิ่มจำนวน  $n$  ในชั้นฮิดเดนที่ 4 จากนั้นเลือกจำนวนเซลล์ประสาทที่ให้ค่าความแม่นยำที่มากที่สุด โดยชั้นฮิดเดนที่ 1 จำนวนเซลล์ประสาท 16 เซลล์ ชั้นฮิดเดนที่ 2 จำนวนเซลล์ประสาท 32 เซลล์ ชั้นฮิดเดนที่ 3 จำนวนเซลล์ประสาท 64 เซลล์ และชั้นฮิดเดนที่ 4 จำนวนเซลล์ประสาท 64 เซลล์ ให้ค่าความแม่นยำเฉลี่ยที่ร้อยละ 98.08 แต่กลับมีค่าความแม่นยำเฉลี่ยที่น้อยกว่า ชั้นฮิดเดนที่ 3 ที่มีการปรับปรุง จึงทำการหยุดการปรับปรุงและแสดงระยะเวลาดำเนินการในหน่วยวินาทีของแต่ละโมเดลดังแสดงตามตารางที่ 3.41

ตารางที่ 3.41 ระยะเวลาการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงลึกในการปรับ  
 ปรุงชั้นฮิดเดนที่ 4 ของชุดข้อมูลที่ 3

ครั้ง	ระยะเวลาในการทำนายของโมเดล (วินาที)							
	Deep Neural Network (ปรับปรุงชั้นฮิดเดนที่ 4)							
	16-32- 64-2	16-32- 64-4	16-32- 64-8	16-32- 64-16	16-32- 64-32	16-32- 64-64	16-32- 64-128	16-32- 64-256
1	215.91	247.93	219.20	219.42	211.00	213.37	216.12	229.60
2	239.39	243.41	231.79	244.72	222.39	207.41	213.45	225.53
3	215.72	239.82	217.07	221.35	212.35	214.57	217.48	249.38
4	220.30	227.75	245.26	247.02	209.60	224.64	216.48	227.66
5	219.23	226.31	246.31	243.11	212.28	212.21	229.15	226.44
6	220.64	225.74	217.76	217.52	211.32	209.48	226.41	247.36
7	216.55	223.85	221.06	219.78	215.52	209.57	221.90	224.67
8	215.25	229.49	217.74	219.56	213.49	209.52	219.58	241.70
9	215.78	225.71	247.10	211.06	220.67	208.34	220.20	223.13
10	216.41	235.21	251.68	211.93	216.58	220.91	219.70	231.84
MEAN	219.52	232.52	231.50	225.55	214.52	<b>213.00</b>	220.05	232.73
S.D.	7.26	8.53	14.55	13.83	<b>4.25</b>	5.68	4.78	9.76
MAX	239.39	247.93	251.68	247.02	<b>222.39</b>	224.64	229.15	249.38
MIN	215.25	223.85	217.07	211.06	209.60	<b>207.41</b>	213.45	223.13

จากตารางที่ 3.41 แสดงระยะเวลาในการทำนายโมเดลการเรียนรู้เชิงลึกของชุดข้อมูลที่ 3 โมเดลโครงข่ายประสาทเทียมแบบลึกชั้นฮิดเดนที่ 1 จำนวนเซลล์ประสาท 16 เซลล์ ชั้นฮิดเดนที่ 2 จำนวนเซลล์ประสาท 32 เซลล์ ชั้นฮิดเดนที่ 3 จำนวนเซลล์ประสาทที่ 64 เซลล์ และชั้นฮิดเดนที่ 4 จำนวนเซลล์ประสาทที่ 64 เซลล์ ใช้ระยะเวลาที่เร็วที่สุด 213 วินาที เมื่อเทียบกับจำนวนเซลล์ประสาทอื่น ๆ

ดังนั้น โครงข่ายประสาทเทียมแบบลึกสำหรับชุดข้อมูลที่ 3 จึงเลือกใช้โมเดลที่มีชั้นฮิดเดนที่ 1 จำนวนเซลล์ประสาท 16 เซลล์ ชั้นฮิดเดนที่ 2 จำนวนเซลล์ประสาท 32 เซลล์ และชั้นฮิดเดนที่ 3 จำนวนเซลล์ประสาทที่ 64 เซลล์

จากนั้นทำสรุปการเปรียบเทียบประสิทธิภาพและระยะเวลาเฉลี่ยการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้เชิงต้น การเรียนรู้แบบรวมกลุ่ม และการเรียนรู้เชิงลึกด้วยชุดข้อมูลทั้งหมด 3 ชุด ดังแสดงตามตารางที่ 3.42 – 3.43

ตารางที่ 3.42 ค่าเฉลี่ยประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้ของเครื่อง

โมเดล	ชุดข้อมูลที่ 1	ชุดข้อมูลที่ 2	ชุดข้อมูลที่ 3
Decision Tree	97.92%	<b>99.20%</b>	<b>99.08%</b>
Navies Bayes	98.33%	96.67%	57.13%
Support Vector Machine	<b>99.17%</b>	98.13%	93.22%
k-Nearest Neighbors	98.89%	98.10%	98.03%
Linear Regression	69.63%	94.66%	53.31%
Logistic Regression	98.75%	97.40%	77.58%
Gradient Boosting Machine	98.19%	<b>99.37%</b>	99.62%
Extreme Gradient Boosting	98.61%	99.27%	99.34%
Adaptive Boosting	<b>98.75%</b>	98.80%	<b>99.77%</b>
Random Forest	98.61%	99.33%	99.73%
Deep Neural Network	<b>99.86%</b>	<b>98.33%</b>	<b>98.43%</b>

ตารางที่ 3.43 ระยะเวลาเฉลี่ยการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้ของเครื่อง

โมเดล	ชุดข้อมูลที่ 1	ชุดข้อมูลที่ 2	ชุดข้อมูลที่ 3
Decision Tree	1.55	1.80	1.68
Navies Bayes	1.47	1.57	1.51
Support Vector Machine	1.88	1.73	10.90
k-Nearest Neighbors	1.55	1.62	1.72
Linear Regression	<b>1.00</b>	<b>1.05</b>	<b>0.93</b>
Logistic Regression	2.13	1.41	1.83
Gradient Boosting Machine	1.85	1.92	7.19
Extreme Gradient Boosting	1.82	1.95	3.57
Adaptive Boosting	<b>0.64</b>	<b>0.72</b>	<b>3.26</b>
Random Forest	1.78	1.85	2.24
Deep Neural Network	<b>13.85</b>	<b>36.43</b>	<b>200.75</b>


จากตารางที่ 3.42 ได้สรุปประสิทธิภาพในการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้ของเครื่องจากการทดลองในแต่ละโมเดลทั้งหมด 10 ครั้ง โดยมีค่าความแม่นยำเฉลี่ยดังนี้

- 1) การเรียนรู้เชิงต้น ได้แก่ โมเดลต้นไม้ตัดสินใจมีความแม่นยำเฉลี่ยสูงสุดร้อยละ 99.20 และ 99.08 ในชุดข้อมูลที่ 2 และชุดข้อมูลที่ 3 ตามลำดับ
- 2) การเรียนรู้เชิงลึก ได้แก่ โมเดลโครงข่ายประสาทเทียมแบบลึกมีความแม่นยำเฉลี่ยร้อยละ 99.86 และ 98.33 ในชุดข้อมูลที่ 1-3 ตามลำดับ
- 3) การเรียนรู้แบบรวมกลุ่ม ได้แก่ โมเดลอะแดปทีฟบูสตีงมีความแม่นยำเฉลี่ยสูงสุดร้อยละ 98.75 และ 99.77 ในชุดข้อมูลที่ 1 และชุดข้อมูล 3 ตามลำดับ และโมเดลเกรเดียนบูสตีงมีความแม่นยำเฉลี่ยสูงสุดร้อยละ 99.37 ในชุดข้อมูลที่ 2

และจากตารางที่ 3.43 ได้สรุประยะเวลาดำเนินการในการทำนายประเภทของกลิ่น โดยมีระยะเวลาเฉลี่ยหน่วยเป็นวินาทีดังนี้

- 1) การเรียนรู้เชิงต้น ได้แก่ โมเดลการถดถอยเชิงเส้นใช้ระยะเวลาเฉลี่ยเร็วที่สุดคือ 1.00 1.05 และ 0.93 วินาที ในชุดข้อมูลที่ 1-3 ตามลำดับ
- 2) การเรียนรู้เชิงลึก ได้แก่ โมเดลโครงข่ายประสาทเทียมแบบลึกใช้ระยะเวลาเฉลี่ยเร็วที่สุดคือ 13.85 36.43 และ 200.75 วินาที ในชุดข้อมูลที่ 1-3 ตามลำดับ
- 3) การเรียนรู้แบบรวมกลุ่ม ได้แก่ โมเดลอะแดปทีฟบูสตีงใช้ระยะเวลาเฉลี่ยเร็วที่สุดคือ 0.64 0.72 และ 3.26 วินาที ในชุดข้อมูลที่ 1-3 ตามลำดับ

ผู้วิจัยจึงเลือกโมเดลดังกล่าว โดยทำให้เกิดการผสมผสานโมเดลกันด้วยวิธีการเรียนรู้แบบกลุ่มระหว่างการเรียนรู้เชิงต้น (Shallow Learning) ได้แก่ โมเดลซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine) และต้นไม้ตัดสินใจ (Decision Tree) และการเรียนรู้เชิงลึก (Deep Learning) ได้แก่ โครงข่ายประสาทเทียมแบบลึก (Deep Neural Network) โดยใช้วิธีการอะแดปทีฟบูสตีงเพื่อเพิ่มประสิทธิภาพการจำแนกของโมเดลให้ดียิ่งขึ้น ดังแสดงตามรูปที่ 3.1



รูปที่ 3.1 แผนภาพโมเดลที่ใช้ในงานวิจัยนี้

จากรูปที่ 3.1 แผนภาพโมเดลที่นำเสนอ โดยการใช้การเรียนรู้แบบรวมกลุ่ม ซึ่งประกอบไปด้วย โมเดลโครงข่ายประสาทเทียมแบบลึก ซัพพอร์ตเวกเตอร์แมชชีน และต้นไม้ตัดสินใจ และใช้ชุดข้อมูลที่มีการแบ่งตามข้อ 3.2

โดยขั้นตอนการทำงานของโมเดลการเรียนรู้ร่วมกันของโมเดลโครงข่ายประสาทเทียมแบบลึก ซัพพอร์ตเวกเตอร์แมชชีน และต้นไม้ตัดสินใจ ด้วยวิธีการอะแดปทีฟบูสตีง โดยได้อธิบายไว้ใน อัลกอริทึมที่ 1

### อัลกอริทึมที่ 1: อัลกอริทึม AdaBoost DNN-SVM-DTree

1. ตั้งค่าน้ำหนักเริ่มต้นของแต่ละตัวอย่างเป็น  $\frac{1}{m}$

$$D_1(i) = \frac{1}{m} \text{ โดยที่ } i = 1, 2, \dots, m \quad (3.1)$$

2. กำหนดให้  $T$  เป็นจำนวนรอบในการบูสตีง (boosting)
3. ทำซ้ำตั้งแต่  $t = 1$  ถึง  $T$  (FOR Loop)
4. ฝึกสอนโมเดลโครงข่ายประสาทเทียมแบบลึก หรือ  $C_1$  ด้วยชุดฝึกสอนเดิม
5. ใช้  $C_1$  กับตัวอย่างทั้งหมดในต้นฉบับชุดฝึกสอน  $D$
6. คำนวณค่า weighted error ด้วย

$$\varepsilon_t = \frac{1}{N} \left[ \sum_{i=1}^m D_1(i) \cdot \delta(h_t(x_i) \neq y_i) \right] \quad (3.2)$$

7. ถ้า  $\varepsilon_t > 0.5$  แล้ว (IF Loop)
8. เริ่มต้นค่าถ่วงน้ำหนักสำหรับตัวอย่าง  $m$  ทั้งหมดใหม่ด้วยสมการ 3.1
9. กลับไปที่ขั้นตอนที่ 4
10. สิ้นสุดถ้า (End IF)
11. คำนวณค่า weight สำหรับตัวจำแนกที่อ่อนแอ  $\alpha_t = \frac{1}{2} \ln \left( \frac{1-\varepsilon_t}{\varepsilon_t} \right)$  (3.3)
12. ปรับน้ำหนักของตัวอย่างและน้ำหนักของตัวจำแนกปัจจุบันโดยใช้อัลกอริทึม AdaBoost

$$D_{t+1}(i) = \frac{D_t(i)}{Z_t} \times \begin{cases} e^{-\alpha_t}, & h_t(x_i) = y_i \\ e^{\alpha_t}, & h_t(x_i) \neq y_i \end{cases} \quad (3.4)$$

$$= \frac{D_t(i) \exp(-\alpha_t y_i h_t(x_i))}{Z_t} \quad (3.5)$$

13. ทำซ้ำขั้นตอนที่ 4 ถึง 12 โดยเปลี่ยนตัวจำแนก  $C_2$  เป็นโมเดลซัพพอร์ตเวกเตอร์แมชชีน
14. ทำซ้ำขั้นตอนที่ 4 ถึง 12 โดยเปลี่ยนตัวจำแนก  $C_3$  เป็นโมเดลการตัดสินใจต้นไม้
15. สิ้นสุด (End FOR)
16.  $C^*(x) = \underset{y}{\operatorname{argmax}} \sum_{j=1}^T \alpha_j \delta(C_j(x) = y)$  (3.6)

จากอัลกอริทึมที่ 1 เป็นการอธิบายขั้นตอนการทำงานของโมเดลการผสมผสานการเรียนรู้เชิงต้น และเชิงลึกสำหรับการจำแนกประเภทของกลิ่นโดยใช้วิธีการแบบอะแดปทีฟบูสตีง

โดยกำหนดให้  $\alpha$  เป็นค่าถ่วงน้ำหนักสำหรับตัวจำแนกที่อ่อนแอ  
 $\varepsilon$  เป็นค่าผิดพลาดถ่วงน้ำหนัก (weighted error)  
 $\delta$  เป็นฟังก์ชัน  
 และ  $y_i$  เป็นประเภทของกลิ่นที่ทำนาย

เริ่มต้นจากการกำหนดค่า weight ของตัวอย่าง  $m$  ทั้งหมด กำหนดจำนวนรอบในการทำซ้ำ ตั้งแต่ 1 ถึง  $T$  รอบ สร้างชุดข้อมูลสำหรับการฝึกสอน แล้วฝึกสอนโมเดลโครงข่ายประสาทเทียมแบบ ลึก (DNN) หรือ  $C_1$  พร้อมตัวอย่างทั้งหมดในชุดฝึกสอนเดิม เลือกผู้เรียนอ่อนแอที่มี weighted error ต่ำที่สุด โดยคำนวณได้จากสมการที่ 3.2 โดยที่ส่วน  $\delta(h_t(x_i) \neq y_i)$  ถ้าค่าจากตัวจำแนกไม่เท่ากับค่าจริงจะมีค่าเป็น 1 ถ้าค่าจากตัวจำแนกเท่ากับค่าจริงจะมีค่าเป็น 0 แต่ถ้า  $\varepsilon_t > 0.5$  ให้เริ่มต้นค่าถ่วงน้ำหนักสำหรับตัวอย่าง  $m$  ทั้งหมดใหม่ด้วยสมการ 3.1 จากนั้นคำนวณค่า weight สำหรับตัวจำแนกที่อ่อนแอด้วยสมการที่ 3.3 ทำการปรับน้ำหนักของตัวอย่างและน้ำหนักของตัวจำแนกปัจจุบันด้วยสมการที่ 3.4 ซึ่งถ้าโมเดลทำนายจะถูกคูณด้วย  $e^{-\alpha\varepsilon}$  ซึ่งจะมีค่ามากกว่า 1 ทำให้ค่า weight เพิ่มขึ้น แต่ถ้าโมเดลทำนายผิดจะถูกคูณด้วย  $e^{\alpha\varepsilon}$  ซึ่งจะมีค่าน้อยกว่า 1 ทำให้ค่า weight ลดลง และจะได้เป็นสมการที่ 3.5

โดยที่  $Z_t$  เป็นการทำให้ Normalization Factor ดังสมการที่ 3.7


$$\sum_{i=1}^m D_t(i) \exp(-\alpha_t y_i h_t(x_i)) \quad (3.7)$$

จากสมการที่ 3.7 โดยการนำเอาค่า weight ที่คำนวณได้ใหม่มาบวกกันทั้งหมด และไปเป็นตัวหารของ weight ในแต่ละข้อมูล เพื่อให้ผลรวมของ weight ในรอบถัดไปมีค่าเท่ากับ 1 จากนั้นเปลี่ยนตัวจำแนก  $C_2$  เป็นโมเดลซัพพอร์ตเวกเตอร์แมชชีน (SVM) โดยการทำให้ซ้ำขั้นตอนที่ 4 ถึง 12 และเปลี่ยนตัวจำแนก  $C_3$  เป็นโมเดลตัดสินใจต้นไม้ โดยการทำให้ซ้ำขั้นตอนที่ 4 ถึง 12 และในขั้นตอนสุดท้ายจึงเป็นผลลัพธ์การทำนายประเภทของกลิ่นดังสมการที่ 3.6 จากการทำให้ Voting โดยนำค่าน้ำหนักของตัวจำแนกในแต่ละคลาสมาบวกกัน แล้วเลือกคลาสที่มีผลรวมของค่าน้ำหนักมากที่สุดเป็นคำตอบ

### 3.3.3 การตั้งค่าโครงสร้างให้กับโมเดล


#### 3.3.3.1 โครงข่ายประสาทเทียมแบบลึก

ในการเลือกจำนวนเซลล์ประสาท (neuron) แต่ละชั้นมีหลักเกณฑ์ในการเลือกคือ ชั้นอินพุต (Input Layer) จะมีจำนวนเท่ากับข้อมูลที่ป้อนเข้าไปคือ เท่ากับจำนวนเซ็นเซอร์จุ่มกือเล็กทรอนิกส์ที่ใช้ ชั้นฮิดเดน (Hidden Layer) จะมีจำนวนชั้นและจำนวนเซลล์ประสาทจากการปรับพารามิเตอร์ในข้อ 3.3.2 และชั้นเอาต์พุต (Output Layer) จะมีจำนวนเท่ากับผลลัพธ์ที่ต้องการคือ ประเภทของกลิ่นที่นำมาใช้ทดลอง




รูปที่ 3.2 โครงสร้างโมเดลโครงข่ายประสาทเทียมแบบลึกของชุดข้อมูลที่ 1

จากรูปที่ 3.2 โครงสร้างโมเดลโครงข่ายประสาทเทียมแบบลึกของชุดข้อมูลที่ 1 ประกอบด้วย ชั้นอินพุต (Input Layer) มี 7 เซลล์ประสาท ชั้นฮิดเดน (Hidden Layer) มี 3 ชั้น ซึ่งประกอบไปด้วย ชั้นฮิดเดนที่ 1 จำนวนเซลล์ประสาท 64 เซลล์ ชั้นฮิดเดนที่ 2 จำนวนเซลล์ประสาท 16 เซลล์ และชั้นฮิดเดนที่ 3 เซลล์ประสาทที่ 16 เซลล์ และชั้นเอาต์พุต (Output Layer) มี 4 เซลล์ประสาท



รูปที่ 3.3 โครงสร้างโมเดลโครงข่ายประสาทเทียมแบบลึกของชุดข้อมูลที่ 2

จากรูปที่ 3.3 โครงสร้างโมเดลโครงข่ายประสาทเทียมแบบลึกของชุดข้อมูลที่ 2 ประกอบด้วย ชั้นอินพุต (Input Layer) มี 9 เซลล์ประสาท ชั้นฮิดเดน (Hidden Layer) มี 2 ชั้น ซึ่งประกอบไปด้วย ชั้นฮิดเดนที่ 1 จำนวนเซลล์ประสาท 8 เซลล์ และชั้นฮิดเดนที่ 2 จำนวนเซลล์ประสาท 4 เซลล์ และ ชั้นเอาต์พุต (Output Layer) มี 4 เซลล์ประสาท



รูปที่ 3.4 โครงสร้างโมเดลโครงข่ายประสาทเทียมแบบลึกของชุดข้อมูลที่ 3

จากรูปที่ 3.4 โครงสร้างโมเดลโครงข่ายประสาทเทียมแบบลึกของชุดข้อมูลที่ 3 ประกอบด้วย ชั้นอินพุต (Input Layer) มี 8 เซลล์ประสาท ชั้นฮิดเดน (Hidden Layer) มี 3 ชั้น ซึ่งประกอบไปด้วย ชั้นฮิดเดนที่ 1 จำนวนเซลล์ประสาท 16 เซลล์ ชั้นฮิดเดนที่ 2 จำนวนเซลล์ประสาท 32 เซลล์ และชั้นฮิดเดนที่ 3 เซลล์ประสาทที่ 64 เซลล์ และชั้นเอาต์พุต (Output Layer) มี 6 เซลล์ประสาท

โดยกำหนดให้ฟังก์ชันการเปิดใช้งาน (activation function) ของชั้นฮิดเดนคือ ฟังก์ชัน Rectified Linear Unit (ReLU) ฟังก์ชันการเปิดใช้งาน (activation function) ของชั้นเอาต์พุตคือ softmax อัลกอริทึมเพิ่มประสิทธิภาพสำหรับการปรับน้ำหนัก (optimizer algorithm) เป็น Adam optimizer โดยมีอัตราการเรียนรู้เริ่มต้น (initial learning rate) เท่ากับ 0.001 และฟังก์ชันการสูญเสีย (loss function) เป็น sparse categorical cross entropy ขนาดของ batch ถูกตั้งค่าเป็น 20 และจำนวนของรอบ (epoch) เป็น 1,000

### 3.3.3.2 ซัพพอร์ตเวกเตอร์แมชชีน

การกำหนดพารามิเตอร์สำหรับโมเดลซัพพอร์ตเวกเตอร์แมชชีน กำหนดให้ฟังก์ชันเคอร์เนล (kernel function) ถูกตั้งค่าเป็นเคอร์เนลเชิงเส้น (linear kernel) และจำนวนตัวจำแนกเป็น 3 โดยที่เคอร์เนลเชิงเส้นเป็นฟังก์ชันที่ใช้เพื่อแบ่งข้อมูลเชิงเส้น

### 3.3.3.3 ต้นไม้ตัดสินใจ

การกำหนดพารามิเตอร์สำหรับโมเดลต้นไม้ตัดสินใจ กำหนดให้จำนวนตัวจำแนก (number of classifiers) ถูกตั้งค่าเป็น 3 สถานะสุ่ม (random state) ถูกตั้งค่าเป็นศูนย์ ค่าความลึกสูงสุด (max depth) เป็น 7 9 และ 8 ตามลำดับชุดข้อมูล และตั้งค่าอัตราการเรียนรู้ (learning rate) เป็น 1

โดยสรุปการกำหนดฟังก์ชันและพารามิเตอร์ดังแสดงตามตารางที่ 3.43

ตารางที่ 3.44 การกำหนดฟังก์ชันและพารามิเตอร์ให้กับโมเดล

โมเดลการเรียนรู้แบบรวมกลุ่ม	ฟังก์ชันและพารามิเตอร์	ชุดข้อมูล		
		1	2	3
Decision Tree	จำนวน estimators	3	3	3
	Max depth	7	9	8
	learning rate	1	1	1
Support Vector Machine	จำนวน estimators	3	3	3
	kernel	linear	linear	linear
Deep Neural Network	Estimators	3	3	3
	Epochs	1,000	1,000	1,000
	Batch size	20	20	20
	Input Layer (Activation = ReLU)	7	9	8
	Hidden Layer (Activation = ReLU)	64-16-16	8-4	16-32-64
	Output Layer Activation = softmax	4	4	6
AdaBoost DNN-SVM-DTree	Iterations	3	3	3

### 3.4 การวัดประสิทธิภาพของโมเดล

การวัดประสิทธิภาพการทำนายประเภทของกลืนของโมเดล ในงานวิจัยนี้ได้ทำการเปรียบเทียบการทดลองกับโมเดลโครงข่ายประสาทเทียมแบบลึก (Deep Neural Network) ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine) ต้นไม้ตัดสินใจ (Decision Tree) การเรียนรู้แบบรวมกลุ่มต่าง ๆ ได้แก่ การเรียนรู้แบบรวมกลุ่มของโครงข่ายประสาทเทียมแบบลึก (Ensemble Learning of Deep Neural Network) การเรียนรู้แบบรวมกลุ่มของซัพพอร์ตเวกเตอร์แมชชีน (Ensemble Learning of Support Vector Machine) การเรียนรู้แบบรวมกลุ่มของต้นไม้ตัดสินใจ (Ensemble Learning of Decision Tree) และการเรียนรู้แบบรวมกลุ่มของโครงข่ายประสาทเทียมแบบลึก ซัพพอร์ตเวกเตอร์แมชชีน และต้นไม้ตัดสินใจ (Ensemble Learning of DNN-SVM-DTree) โดยทำการทดลองทั้งหมด 10 ครั้งในแต่ละโมเดล และใช้วิธีการเปรียบเทียบค่าความแม่นยำเฉลี่ย (Average accuracy) และค่า  $F_1$  score

โดยที่  $F_1$  score เป็นการหาเฉลี่ยระหว่างค่า Precision และ Recall ดังสมการที่ 3.8 [29]

$$F_1 \text{ score} = 2 \cdot \frac{\text{precision} \times \text{recall}}{\text{precision} + \text{recall}} \quad (3.8)$$

จากสมการที่ 3.8 Precision คือ ความแม่นยำที่สนใจส่วนที่ทำนาย ดังสมการที่ 3.9 และ Recall คือ ความแม่นยำที่สนใจในความเป็นจริง ดังสมการที่ 3.10

$$\text{Precision} = \frac{TP}{TP+FP} \quad (3.9)$$

$$\text{Recall} = \frac{TP}{TP+FN} \quad (3.10)$$

จากสมการที่ 3.9 – 3.10 โดยที่

True Positive (TP) คือ จำนวนที่ทำนายตรงกับข้อมูลจริงในคลาสบวก

True Negative (TN) คือ จำนวนที่ทำนายตรงกับข้อมูลจริงในคลาสลบ

False Positive (FP) คือ จำนวนที่ทำนายผิดเป็นคลาสบวก

False Negative (FN) คือ จำนวนที่ทำนายผิดเป็นคลาสลบ

## บทที่ 4

### ผลการวิจัยและการอภิปรายผล

ในการทำวิจัยนี้ได้นำเสนอการผสมผสานการเรียนรู้เชิงต้นและการเรียนรู้เชิงลึกสำหรับการจำแนกประเภทของกลิ่นด้วยวิธีการอะแดปทีฟบูสตีงจากกระบวนการที่ได้กล่าวในบทที่ 3 โดยได้แสดงผลการทดลองด้วยชุดข้อมูลที่ 1-3 ดังนี้

#### 4.1 ผลการวิจัย

ผลการทดลองในงานวิจัยนี้ได้ทำการทดลองเพื่อเปรียบเทียบประสิทธิภาพการจำแนกประเภทของกลิ่นในแต่ละการเรียนรู้แบบรวมกลุ่ม มีผลการทดลองด้วยชุดข้อมูลที่ 1 ดังแสดงตามตารางที่ 4.1

ตารางที่ 4.1 ประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้แบบรวมกลุ่มที่เลือกมาใช้ทดลองของชุดข้อมูลที่ 1

ครั้ง	โมเดลการเรียนรู้แบบรวมกลุ่ม (ร้อยละ)			
	โมเดลที่นำเสนอ	DNN	SVM	DTree
1	100.00	100.00	98.61	97.22
2	100.00	95.83	97.22	98.61
3	100.00	100.00	97.22	98.61
4	100.00	100.00	98.61	98.61
5	100.00	100.00	100.00	98.61
6	98.61	100.00	97.22	97.22
7	100.00	100.00	97.22	98.61
8	100.00	100.00	97.22	98.61
9	100.00	100.00	98.61	98.61
10	100.00	98.61	100.00	100.00
MEAN	99.86	99.44	98.19	98.47
S.D.	0.44	1.34	1.14	0.79
MAX	100.00	100.00	100.00	100.00
MIN	98.61	95.83	97.22	97.22

จากตารางที่ 4.1 ทำการทดสอบด้วยชุดข้อมูลที่ 1 โดยโมเดลที่นำเสนอมีความแม่นยำเฉลี่ยมากที่สุดคือ ร้อยละ 99.86 ส่วนเบี่ยงเบนมาตรฐาน 0.44 ค่าความแม่นยำที่สูงสุดร้อยละ 100.00 และค่าความแม่นยำที่ต่ำสุดร้อยละ 98.61 รองลงมาคือ โมเดลการเรียนรู้แบบรวมกลุ่มของโครงข่ายประสาทเทียมแบบลึกมีความแม่นยำเฉลี่ยร้อยละ 99.44 ส่วนเบี่ยงเบนมาตรฐาน 1.34 ค่าความแม่นยำที่สูงสุดร้อยละ 100.00 และค่าความแม่นยำที่ต่ำสุดร้อยละ 95.83 ซึ่งเมื่อเปรียบเทียบกับโมเดลที่นำเสนอแล้วนั้นมีค่าส่วนเบี่ยงเบนมาตรฐานแตกต่างกัน 0.90

ตารางที่ 4.2 ระยะเวลาการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้แบบรวมกลุ่มที่เลือกมาใช้ทดลองของชุดข้อมูลที่ 1

ครั้ง	ระยะเวลาในการทำนายของการเรียนรู้แบบรวมกลุ่ม (วินาที)			
	โมเดลที่นำเสนอ	DNN	SVM	DTree
1	41.89	40.13	0.65	1.01
2	42.14	39.79	0.71	0.93
3	42.42	39.69	0.65	0.97
4	42.13	40.92	0.64	0.95
5	42.69	41.01	0.67	0.96
6	41.74	37.70	0.65	0.96
7	42.34	41.14	0.64	1.00
8	42.51	40.78	0.65	0.96
9	42.11	41.22	0.65	0.94
10	41.63	40.72	0.65	0.94
MEAN	42.16	40.31	<b>0.66</b>	0.96
S.D.	0.34	1.07	<b>0.02</b>	0.03
MAX	42.69	41.22	<b>0.71</b>	1.01
MIN	41.63	37.70	<b>0.64</b>	0.93

จากตารางที่ 4.2 โมเดลที่นำเสนอใช้ระยะเวลาเฉลี่ยในการทำนายประเภทกลิ่นของชุดข้อมูลที่ 1 เป็นเวลา 42.16 วินาที ซึ่งใช้เวลานานที่สุดเมื่อเทียบกับโมเดลอื่นอย่างต้นไม้ตัดสินใจที่ใช้เวลาเฉลี่ยเร็วที่สุดคือ 0.66 วินาที

นอกจากการเปรียบเทียบค่าความแม่นยำเฉลี่ยและระยะเวลาที่ใช้ในการดำเนินการด้วยชุดข้อมูลที่ 1 แล้ว ยังทำการเปรียบเทียบค่า  $F_1$  Score ในการทดลองแต่ละโมเดลทั้งหมด 10 ครั้ง ดังแสดงตามตารางที่ 4.3 - 4.12

ตารางที่ 4.3  $F_1$  Score การเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 1 ในการทดลองครั้งที่ 1

ประเภทของกลืน	$F_1$ Score ครั้งที่ 1			
	โมเดลที่นำเสนอ	DNN	SVM	DTree
ไม่มีกลืน	1.00	1.00	0.98	0.98
เปียร์	1.00	1.00	0.97	1.00
วิสกี	1.00	1.00	1.00	0.97
ไวน์	1.00	1.00	1.00	1.00

จากตารางที่ 4.3 เป็นการเปรียบเทียบค่า  $F_1$  Score ของชุดข้อมูลที่ 1 ในการทดลองครั้งที่ 1 โดยโมเดลที่นำเสนอและโมเดลการเรียนรู้แบบรวมกลุ่มของโครงข่ายประสาทเทียมแบบลึกมีค่า  $F_1$  Score เป็น 1.00 ทุกประเภทของกลืน ซึ่งหมายความว่าสามารถทำนายทุกประเภทของกลืนได้ถูกต้องกับความ เป็นจริง นอกจากนี้โมเดลอื่นยังมีค่า  $F_1$  Score เป็น 1.00 ที่ประเภทของกลืนไวน์ทุกโมเดล ซึ่งหมายความว่าทุกโมเดลสามารถทำนายประเภทของกลืนไวน์ได้ถูกต้องกับความ เป็นจริง

ตารางที่ 4.4  $F_1$  Score การเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 1 ในการทดลองครั้งที่ 2

ประเภทของกลืน	$F_1$ Score ครั้งที่ 2			
	โมเดลที่นำเสนอ	DNN	SVM	DTree
ไม่มีกลืน	1.00	0.93	0.92	0.92
เปียร์	1.00	1.00	0.97	0.97
วิสกี	1.00	0.94	0.94	0.95
ไวน์	1.00	1.00	1.00	1.00

จากตารางที่ 4.4 เป็นการเปรียบเทียบค่า  $F_1$  Score ของชุดข้อมูลที่ 1 ในการทดลองครั้งที่ 2 โดยโมเดลที่นำเสนอ มีค่า  $F_1$  Score เป็น 1.00 ทุกประเภทของกลืน ซึ่งหมายความว่าสามารถทำนายทุกประเภทของกลืนได้ถูกต้องกับความ เป็นจริง ส่วนโมเดลอื่นมีค่า  $F_1$  Score เป็น 1.00 ที่ประเภทของกลืนไวน์ ซึ่งหมายความว่าทุกโมเดลสามารถทำนายประเภทของกลืนไวน์ได้ถูกต้องกับความ เป็นจริง

ตารางที่ 4.5  $F_1$  Score การเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 1 ในการทดลองครั้งที่ 3

ประเภทของกลืน	$F_1$ Score ครั้งที่ 3			
	โมเดลที่ นำเสนอ	DNN	SVM	DTree
ไม่มีกลืน	1.00	0.91	0.97	0.95
เปียร์	1.00	1.00	1.00	0.97
วิสกี	1.00	0.93	0.97	0.97
ไวน์	1.00	1.00	1.00	1.00

จากตารางที่ 4.5 เป็นการเปรียบเทียบค่า  $F_1$  Score ของชุดข้อมูลที่ 1 ในการทดลองครั้งที่ 3 โดยโมเดลที่นำเสนอ มีค่า  $F_1$  Score เป็น 1.00 ทุกประเภทของกลืน ส่วนโมเดลอื่นมีค่า  $F_1$  Score เป็น 1.00 ที่ประเภทของกลืนไวน์ทุกโมเดล และที่ประเภทของกลืนเปียร์ในโมเดลการเรียนรู้แบบรวมกลุ่มของโครงข่ายประสาทเทียมแบบลึก และโมเดลการเรียนรู้แบบรวมกลุ่มของซัพพอร์ตเวกเตอร์แมชชีน ซึ่งหมายความว่าโมเดลสามารถทำนายประเภทของกลืนเปียร์และไวน์ได้ถูกต้องกับความเป็นจริง

ตารางที่ 4.6  $F_1$  Score การเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 1 ในการทดลองครั้งที่ 4

ประเภทของกลืน	$F_1$ Score ครั้งที่ 4			
	โมเดลที่ นำเสนอ	DNN	SVM	DTree
ไม่มีกลืน	1.00	1.00	1.00	0.95
เปียร์	1.00	1.00	1.00	0.97
วิสกี	1.00	1.00	1.00	0.98
ไวน์	1.00	1.00	1.00	1.00

จากตารางที่ 4.6 เป็นการเปรียบเทียบค่า  $F_1$  Score ของชุดข้อมูลที่ 1 ในการทดลองครั้งที่ 4 โดยโมเดลที่นำเสนอ โมเดลการเรียนรู้แบบรวมกลุ่มของโครงข่ายประสาทเทียมแบบลึก และโมเดลการเรียนรู้แบบรวมกลุ่มของซัพพอร์ตเวกเตอร์แมชชีนมีค่า  $F_1$  Score เป็น 1.00 ทุกประเภทของกลืน ซึ่งหมายความว่าสามารถทำนายทุกประเภทของกลืนได้ถูกต้องกับความเป็นจริง ส่วนโมเดลการเรียนรู้แบบรวมกลุ่มของต้นไม้ตัดสินใจมีค่า  $F_1$  Score เป็น 1.00 ที่ประเภทของกลืนไวน์เท่านั้นที่สามารถทำนายประเภทของกลืนไวน์ได้ถูกต้องกับความเป็นจริง

ตารางที่ 4.7  $F_1$  Score การเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 1 ในการทดลองครั้งที่ 5

ประเภทของกลืน	$F_1$ Score ครั้งที่ 5			
	โมเดลที่ นำเสนอ	DNN	SVM	DTree
ไม่มีกลืน	1.00	1.00	0.94	0.98
เปียร์	1.00	1.00	0.97	0.97
วิสกี	1.00	1.00	0.97	1.00
ไวน์	1.00	1.00	1.00	1.00

จากตารางที่ 4.7 เป็นการเปรียบเทียบค่า  $F_1$  Score ของชุดข้อมูลที่ 1 ในการทดลองครั้งที่ 5 โดยโมเดลที่นำเสนอ และโมเดลการเรียนรู้แบบรวมกลุ่มของโครงข่ายประสาทเทียมแบบลึกมีค่า  $F_1$  Score เป็น 1.00 ทุกประเภทของกลืน ซึ่งหมายความว่าสามารถทำนายทุกประเภทของกลืนได้ถูกต้องกับความเป็นจริง ส่วนโมเดลการเรียนรู้แบบรวมกลุ่มของซัพพอร์ตเวกเตอร์แมชชีนมีค่า  $F_1$  Score เป็น 1.00 ที่ประเภทของกลืนไวน์เท่านั้นที่สามารถทำนายประเภทของกลืนไวน์ได้ถูกต้องกับความเป็นจริง และโมเดลการเรียนรู้แบบรวมกลุ่มของต้นไม้ตัดสินใจมีค่า  $F_1$  Score เป็น 1.00 ที่ประเภทของกลืนวิสกีและไวน์ที่สามารถทำนายประเภทของกลืนวิสกีและไวน์ได้ถูกต้องกับความเป็นจริง

ตารางที่ 4.8  $F_1$  Score การเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 1 ในการทดลองครั้งที่ 6

ประเภทของกลืน	$F_1$ Score ครั้งที่ 6			
	โมเดลที่ นำเสนอ	DNN	SVM	DTree
ไม่มีกลืน	0.96	0.97	0.95	0.94
เปียร์	1.00	1.00	0.94	0.97
วิสกี	0.97	0.97	1.00	0.98
ไวน์	1.00	1.00	1.00	1.00

จากตารางที่ 4.8 เป็นการเปรียบเทียบค่า  $F_1$  Score ของชุดข้อมูลที่ 1 ในการทดลองครั้งที่ 6 โดยโมเดลที่นำเสนอ และโมเดลการเรียนรู้แบบรวมกลุ่มของโครงข่ายประสาทเทียมแบบลึกมีค่า  $F_1$  Score เป็น 1.00 ประเภทของกลืนเปียร์และไวน์เท่านั้น ซึ่งหมายความว่าสามารถทำนายประเภทของกลืนเปียร์และไวน์ได้ถูกต้องกับความเป็นจริง ส่วนโมเดลการเรียนรู้แบบรวมกลุ่มของซัพพอร์ตเวกเตอร์แมชชีนมีค่า  $F_1$  Score เป็น 1.00 ที่ประเภทของกลืนวิสกีและไวน์เท่านั้นที่สามารถทำนายประเภทของกลืนวิสกีและไวน์ได้ถูกต้องกับความเป็นจริง และโมเดลการเรียนรู้แบบรวมกลุ่มของต้นไม้ตัดสินใจมี

ค่า  $F_1$  Score เป็น 1.00 ที่ประเภทของกลิ่นไวน์เท่านั้นที่สามารถทำนายประเภทของกลิ่นไวน์ได้ถูกต้องกับความเป็นจริง

ตารางที่ 4.9  $F_1$  Score การเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 1 ในการทดลองครั้งที่ 7

ประเภทของกลิ่น	$F_1$ Score ครั้งที่ 7			
	โมเดลที่นำเสนอ	DNN	SVM	DTree
ไม่มีกลิ่น	0.97	1.00	0.98	0.91
เปียร์	1.00	1.00	0.97	1.00
วิสกี	0.97	1.00	1.00	0.89
ไวน์	1.00	1.00	1.00	1.00

จากตารางที่ 4.9 เป็นการเปรียบเทียบค่า  $F_1$  Score ของชุดข้อมูลที่ 1 ในการทดลองครั้งที่ 7 โดยโมเดลที่นำเสนอ และโมเดลการเรียนรู้แบบรวมกลุ่มของต้นไม้ตัดสินใจมีค่า  $F_1$  Score เป็น 1.00 ประเภทของกลิ่นเปียร์และไวน์เท่านั้น ซึ่งหมายความว่าสามารถทำนายประเภทของกลิ่นเปียร์และไวน์ได้ถูกต้องกับความเป็นจริง ส่วนโมเดลการเรียนรู้แบบรวมกลุ่มของโครงข่ายประสาทเทียมแบบลึกมีค่า  $F_1$  Score เป็น 1.00 ทุกประเภทของกลิ่น ซึ่งหมายความว่าสามารถทำนายทุกประเภทของกลิ่นได้ถูกต้องกับความเป็นจริง และโมเดลการเรียนรู้แบบรวมกลุ่มของซัพพอร์ตเวกเตอร์แมชชีนมีค่า  $F_1$  Score เป็น 1.00 ที่ประเภทของกลิ่นวิสกีและไวน์เท่านั้นที่สามารถทำนายประเภทของกลิ่นวิสกีและไวน์ได้ถูกต้องกับความเป็นจริง

ตารางที่ 4.10  $F_1$  Score การเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 1 ในการทดลองครั้งที่ 8

ประเภทของกลิ่น	$F_1$ Score ครั้งที่ 8			
	โมเดลที่นำเสนอ	DNN	SVM	DTree
ไม่มีกลิ่น	1.00	1.00	0.94	0.97
เปียร์	1.00	1.00	1.00	0.97
วิสกี	1.00	1.00	0.94	1.00
ไวน์	1.00	1.00	1.00	1.00

จากตารางที่ 4.10 เป็นการเปรียบเทียบค่า  $F_1$  Score ของชุดข้อมูลที่ 1 ในการทดลองครั้งที่ 8 โดยโมเดลที่นำเสนอ และโมเดลการเรียนรู้แบบรวมกลุ่มของโครงข่ายประสาทเทียมแบบลึกมีค่า  $F_1$

Score เป็น 1.00 ทุกประเภทของกลิ้ง ซึ่งหมายความว่าสามารถทำนายทุกประเภทของกลิ้งได้ถูกต้อง กับการเป็นจริง ส่วนโมเดลการเรียนรู้แบบรวมกลุ่มของซัพพอร์ตเวกเตอร์แมชชีนมีค่า  $F_1$  Score เป็น 1.00 ประเภทของกลิ้งเปียร์และไวน์ ซึ่งหมายความว่าสามารถทำนายประเภทของกลิ้งเปียร์และไวน์ ได้ถูกต้องกับการเป็นจริง และโมเดลการเรียนรู้แบบรวมกลุ่มของต้นไม้ตัดสินใจมีค่า  $F_1$  Score เป็น 1.00 ที่ประเภทของกลิ้งวิสกีและไวน์เท่านั้นที่สามารถทำนายประเภทของกลิ้งวิสกีและไวน์ได้ถูกต้อง กับการเป็นจริง

ตารางที่ 4.11  $F_1$  Score การเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 1 ในการทดลองครั้งที่ 9

ประเภทของกลิ้ง	$F_1$ Score ครั้งที่ 9			
	โมเดลที่ นำเสนอ	DNN	SVM	DTree
ไม่มีกลิ้ง	1.00	0.97	0.98	0.96
เปียร์	1.00	1.00	0.73	1.00
วิสกี	1.00	0.97	0.97	0.94
ไวน์	1.00	1.00	0.56	1.00

จากตารางที่ 4.11 เป็นการเปรียบเทียบค่า  $F_1$  Score ของชุดข้อมูลที่ 1 ในการทดลองครั้งที่ 9 โดยโมเดลที่นำเสนอมีค่า  $F_1$  Score เป็น 1.00 ทุกประเภทของกลิ้ง ซึ่งหมายความว่าสามารถทำนายทุกประเภทของกลิ้งได้ถูกต้องกับการเป็นจริง ส่วนโมเดลการเรียนรู้แบบรวมกลุ่มของโครงข่ายประสาทเทียมแบบลึก และโมเดลการเรียนรู้แบบรวมกลุ่มของต้นไม้ตัดสินใจมีค่า  $F_1$  Score เป็น 1.00 ที่ประเภทของกลิ้งเปียร์และไวน์เท่านั้นที่สามารถทำนายประเภทของกลิ้งเปียร์และไวน์ได้ถูกต้อง กับการเป็นจริง

ตารางที่ 4.12  $F_1$  Score การเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 1 ในการทดลองครั้งที่ 10

ประเภทของกลิ้ง	$F_1$ Score ครั้งที่ 10			
	โมเดลที่ นำเสนอ	DNN	SVM	DTree
ไม่มีกลิ้ง	0.97	1.00	0.96	1.00
เปียร์	1.00	1.00	1.00	1.00
วิสกี	0.97	1.00	0.97	1.00
ไวน์	1.00	1.00	1.00	1.00

จากตารางที่ 4.12 เป็นการเปรียบเทียบค่า  $F_1$  Score ของชุดข้อมูลที่ 1 ในการทดลองครั้งที่ 10 โดยโมเดลที่นำเสนอ และโมเดลการเรียนรู้แบบรวมกลุ่มของซัพพอร์ตเวกเตอร์แมชชีนมีค่า  $F_1$  Score เป็น 1.00 ประเภทของกลิ่นเปียร์และไวน์ ซึ่งหมายความว่าสามารถทำนายประเภทของกลิ่นเปียร์และไวน์ได้ถูกต้องกับความเป็นจริง ส่วนโมเดลการเรียนรู้แบบรวมกลุ่มของโครงข่ายประสาทเทียมแบบลึก และโมเดลการเรียนรู้แบบรวมกลุ่มของต้นไม้ตัดสินใจมีค่า  $F_1$  Score เป็น 1.00 ทุกประเภทของกลิ่น ซึ่งหมายความว่าสามารถทำนายทุกประเภทของกลิ่นได้ถูกต้องกับความเป็นจริง

จากนั้นทำการเปรียบเทียบประสิทธิภาพการจำแนกประเภทของกลิ่นในแต่ละการเรียนรู้แบบรวมกลุ่ม โดยมีผลการทดลองด้วยชุดข้อมูลที่ 2 ดังแสดงตามตารางที่ 4.13

ตารางที่ 4.13 ประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้แบบรวมกลุ่มที่เลือกมาใช้ทดลองของชุดข้อมูลที่ 2

ครั้ง	โมเดลการเรียนรู้แบบรวมกลุ่ม (ร้อยละ)			
	โมเดลที่นำเสนอ	DNN	SVM	DTree
1	98.33	98.67	97.00	97.67
2	98.00	98.00	97.33	97.33
3	98.33	99.00	98.00	98.33
4	98.33	98.00	97.67	97.33
5	98.33	96.33	96.67	97.33
6	98.33	97.33	97.00	98.00
7	98.00	98.67	96.67	98.67
8	99.00	98.33	97.33	98.33
9	98.67	99.67	97.33	97.67
10	98.00	98.00	97.00	98.33
MEAN	<b>98.33</b>	98.20	97.20	97.90
S.D.	<b>0.31</b>	0.92	0.42	0.50
MAX	99.00	<b>99.67</b>	98.00	98.67
MIN	<b>98.00</b>	96.33	96.67	97.33

จากตารางที่ 4.13 ทำการทดสอบด้วยชุดข้อมูลที่ 2 โดยโมเดลที่นำเสนอมีความแม่นยำเฉลี่ยมากที่สุดคือ ร้อยละ 98.33 ส่วนเบี่ยงเบนมาตรฐาน 0.31 ค่าความแม่นยำที่สูงสุดร้อยละ 99.00 และ

ค่าความแม่นยำที่ต่ำสุดร้อยละ 98.00 รองลงมาคือ โมเดลการเรียนรู้แบบรวมกลุ่มของโครงข่ายประสาทเทียมแบบลึกมีค่าความแม่นยำเฉลี่ยร้อยละ 98.20 ส่วนเบี่ยงเบนมาตรฐาน 0.92 ค่าความแม่นยำที่สูงสุดร้อยละ 99.67 และค่าความแม่นยำที่ต่ำสุดร้อยละ 96.33 ซึ่งเมื่อเปรียบเทียบกับโมเดลที่นำเสนอแล้วนั้นมีค่าส่วนเบี่ยงเบนมาตรฐานแตกต่างกัน 0.61

ตารางที่ 4.14 ระยะเวลาการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้แบบรวมกลุ่มที่เลือกมาใช้ทดลองของชุดข้อมูลที่ 2

ครั้ง	ระยะเวลาในการทำนายของการเรียนรู้แบบรวมกลุ่ม (วินาที)			
	โมเดลที่นำเสนอ	DNN	SVM	DTree
1	121.53	121.25	0.82	0.68
2	121.73	118.57	0.78	1.07
3	122.11	124.07	0.78	0.66
4	125.33	123.81	0.77	0.68
5	124.71	116.76	0.76	0.68
6	122.26	120.05	0.79	0.70
7	121.47	121.33	0.76	0.72
8	123.51	119.74	0.77	0.73
9	121.56	118.50	0.76	0.67
10	121.87	119.56	0.78	0.67
MEAN	122.61	120.36	0.78	<b>0.73</b>
S.D.	1.41	2.31	<b>0.02</b>	0.12
MAX	125.33	124.07	<b>0.82</b>	1.07
MIN	121.47	116.76	0.76	<b>0.66</b>

จากตารางที่ 4.14 โมเดลที่นำเสนอใช้ระยะเวลาเฉลี่ยในการทำนายการจำแนกประเภทกลิ่นของชุดข้อมูลที่ 2 เป็นเวลา 122.61 วินาที ซึ่งใช้เวลานานที่สุดเมื่อเทียบกับโมเดลอื่นอย่างต้นไม้ตัดสินใจที่ใช้เวลาเฉลี่ยเร็วที่สุดคือ 0.73 วินาที

นอกจากการเปรียบเทียบค่าความแม่นยำเฉลี่ยและระยะเวลาที่ใช้ในการทำนายด้วยชุดข้อมูลที่ 2 แล้ว ยังทำการเปรียบเทียบค่า  $F_1$  Score ในการทดลองแต่ละโมเดลทั้งหมด 10 ครั้ง ดังแสดงตามตารางที่ 4.15 - 4.24

ตารางที่ 4.15  $F_1$  Score การเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 2 ในการทดลองครั้งที่ 1

ประเภทของกลืน	$F_1$ Score ครั้งที่ 1			
	โมเดลที่นำเสนอ	DNN	SVM	DTree
ดีเยี่ยม	0.98	1.00	0.99	0.98
ดี	0.97	0.99	0.97	0.97
พอรับได้	0.99	0.97	0.95	0.98
น่าเสีย	0.99	0.99	0.97	0.98

จากตารางที่ 4.15 เป็นการเปรียบเทียบค่า  $F_1$  Score ของชุดข้อมูลที่ 2 ในการทดลองครั้งที่ 1 โดยโมเดลที่นำเสนอมีค่า  $F_1$  Score เป็น 0.99 ประเภทของกลืนพอรับได้และน่าเสีย ซึ่งหมายความว่าสามารถทำนายประเภทของกลืนพอรับได้และน่าเสียได้ใกล้เคียงถูกต้องกับความเป็นจริง ส่วนโมเดลการเรียนรู้แบบรวมกลุ่มของโครงข่ายประสาทเทียมแบบลึกมีค่า  $F_1$  Score เป็น 1.00 ประเภทของกลืนดีเยี่ยมเท่านั้น ซึ่งหมายความว่าสามารถทำนายประเภทของกลืนดีเยี่ยมได้ถูกต้องกับความเป็นจริง และมีค่า  $F_1$  Score เป็น 0.99 ที่ประเภทของกลืนดีและน่าเสียเท่านั้นที่สามารถทำนายประเภทของกลืนดีและน่าเสียได้ใกล้เคียงถูกต้องกับความเป็นจริง

ตารางที่ 4.16  $F_1$  Score การเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 2 ในการทดลองครั้งที่ 2

ประเภทของกลืน	$F_1$ Score ครั้งที่ 2			
	โมเดลที่นำเสนอ	DNN	SVM	DTree
ดีเยี่ยม	0.98	0.98	0.97	0.98
ดี	0.96	0.97	0.97	0.98
พอรับได้	0.98	0.98	0.97	0.96
น่าเสีย	0.99	0.98	0.98	0.97

จากตารางที่ 4.16 เป็นการเปรียบเทียบค่า  $F_1$  Score ของชุดข้อมูลที่ 2 ในการทดลองครั้งที่ 2 โดยโมเดลที่นำเสนอ มีค่า  $F_1$  Score เป็น 0.99 ประเภทของกลืนน่าเสีย และมีค่า  $F_1$  Score เป็น 0.98 ประเภทของกลืนดีเยี่ยม และพอรับได้ ซึ่งหมายความว่าสามารถทำนายประเภทของกลืนดีเยี่ยม พอรับได้ และน่าเสียได้ใกล้เคียงถูกต้องกับความเป็นจริง และโมเดลการเรียนรู้แบบรวมกลุ่มของโครงข่ายประสาทเทียมแบบลึกมีค่า  $F_1$  Score เป็น 0.98 ประเภทของกลืนดีเยี่ยม พอรับได้ และน่าเสีย ซึ่งหมายความว่าสามารถทำนายประเภทของกลืนดีเยี่ยม พอรับได้ และน่าเสีย ได้ใกล้เคียง

ถูกต้องกับความเป็นจริง ส่วนโมเดลการเรียนรู้แบบรวมกลุ่มของต้นไม้ตัดสินใจมีค่า  $F_1$  Score เป็น 0.98 ประเภทของกลิ่นดีเยี่ยมและดีเท่านั้น ซึ่งหมายความว่าสามารถทำนายประเภทของกลิ่นดีเยี่ยมและดีได้ใกล้เคียงถูกต้องกับความเป็นจริง

ตารางที่ 4.17  $F_1$  Score การเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 2 ในการทดลองครั้งที่ 3

ประเภทของกลิ่น	$F_1$ Score ครั้งที่ 3			
	โมเดลที่นำเสนอ	DNN	SVM	DTree
ดีเยี่ยม	0.99	<b>0.99</b>	<b>0.99</b>	<b>0.99</b>
ดี	0.98	<b>0.99</b>	<b>0.99</b>	<b>0.99</b>
พอรับได้	0.98	<b>0.99</b>	0.97	0.97
น่าเสียด	<b>0.99</b>	<b>0.99</b>	0.97	0.97

จากตารางที่ 4.17 เป็นการเปรียบเทียบค่า  $F_1$  Score ของชุดข้อมูลที่ 2 ในการทดลองครั้งที่ 3 โดยโมเดลที่นำเสนอ มีค่า  $F_1$  Score เป็น 0.99 ที่ประเภทของกลิ่นดีเยี่ยมและน่าเสียดเท่านั้น ซึ่งหมายความว่าสามารถทำนายประเภทของกลิ่นดีเยี่ยมและน่าเสียดได้ใกล้เคียงถูกต้องกับความเป็นจริง ส่วนโมเดลการเรียนรู้แบบรวมกลุ่มของโครงข่ายประสาทเทียมแบบลึกมีค่า  $F_1$  Score เป็น 0.99 ทุกประเภทของกลิ่น ซึ่งหมายความว่าสามารถทำนายทุกประเภทของกลิ่นได้ใกล้เคียงถูกต้องกับความเป็นจริง ส่วนโมเดลการเรียนรู้แบบรวมกลุ่มของซัพพอร์ตเวกเตอร์แมชชีน และโมเดลการเรียนรู้แบบรวมกลุ่มของต้นไม้ตัดสินใจมีค่า  $F_1$  Score เป็น 0.99 ที่ประเภทของกลิ่นดีเยี่ยมและดีเท่านั้น ซึ่งหมายความว่าสามารถทำนายประเภทของกลิ่นดีเยี่ยมและดีได้ใกล้เคียงถูกต้องกับความเป็นจริง

ตารางที่ 4.18  $F_1$  Score การเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 2 ในการทดลองครั้งที่ 4

ประเภทของกลิ่น	$F_1$ Score ครั้งที่ 4			
	โมเดลที่นำเสนอ	DNN	SVM	DTree
ดีเยี่ยม	0.98	0.98	0.99	<b>1.00</b>
ดี	0.98	0.97	0.98	<b>0.99</b>
พอรับได้	<b>0.99</b>	0.98	0.96	0.94
น่าเสียด	<b>0.99</b>	<b>0.99</b>	0.97	0.97

จากตารางที่ 4.18 เป็นการเปรียบเทียบค่า  $F_1$  Score ของชุดข้อมูลที่ 2 ในการทดลองครั้งที่ 4 โดยโมเดลที่นำเสนอ มีค่า  $F_1$  Score เป็น 0.99 ประเภทของกลืนพอร์ไบ้และเนาเสีย ซึ่งหมายความว่าสามารถทำนายประเภทของกลืนพอร์ไบ้และเนาเสียได้ใกล้เคียงถูกต้องกับความเป็นจริง ส่วนโมเดลการเรียนรู้แบบรวมกลุ่มของโครงข่ายประสาทเทียมแบบลึกมีค่า  $F_1$  Score เป็น 0.99 ที่ประเภทของกลืนเนาเสีย ซึ่งหมายความว่าสามารถทำนายประเภทของกลืนเนาเสียได้ใกล้เคียงถูกต้องกับความเป็นจริง ส่วนโมเดลการเรียนรู้แบบรวมกลุ่มของซัพพอร์ตเวกเตอร์แมชชีนมีค่า  $F_1$  Score เป็น 0.99 ประเภทของกลืนดีเยี่ยมเท่านั้น ซึ่งหมายความว่าสามารถทำนายประเภทของกลืนดีเยี่ยมได้ใกล้เคียงถูกต้องกับความเป็นจริง และโมเดลการเรียนรู้แบบรวมกลุ่มของต้นไม้ตัดสินใจมีค่า  $F_1$  Score เป็น 1.00 ที่ประเภทของกลืนดีเยี่ยมเท่านั้น ซึ่งหมายความว่าสามารถทำนายประเภทของกลืนดีเยี่ยมได้ถูกต้องกับความเป็นจริง

ตารางที่ 4.19  $F_1$  Score การเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 2 ในการทดลองครั้งที่ 5

ประเภทของกลืน	$F_1$ Score ครั้งที่ 5			
	โมเดลที่นำเสนอ	DNN	SVM	DTree
ดีเยี่ยม	0.98	0.96	0.99	<b>1.00</b>
ดี	0.98	0.94	0.96	<b>1.00</b>
พอร์ไบ้	<b>0.99</b>	0.97	0.95	0.95
เนาเสีย	<b>0.99</b>	0.98	0.97	0.95

จากตารางที่ 4.19 เป็นการเปรียบเทียบค่า  $F_1$  Score ของชุดข้อมูลที่ 2 ในการทดลองครั้งที่ 5 โดยโมเดลที่นำเสนอ มีค่า  $F_1$  Score เป็น 0.99 ที่ประเภทของกลืนพอร์ไบ้และเนาเสีย ซึ่งหมายความว่าสามารถทำนายประเภทของกลืนพอร์ไบ้และเนาเสียได้ใกล้เคียงถูกต้องกับความเป็นจริง ส่วนโมเดลการเรียนรู้แบบรวมกลุ่มของซัพพอร์ตเวกเตอร์แมชชีนมีค่า  $F_1$  Score เป็น 0.99 ที่ประเภทของกลืนดีเยี่ยมเท่านั้น ซึ่งหมายความว่าสามารถทำนายประเภทของกลืนดีเยี่ยมได้ใกล้เคียงถูกต้องกับความเป็นจริง และโมเดลการเรียนรู้แบบรวมกลุ่มของต้นไม้ตัดสินใจมีค่า  $F_1$  Score เป็น 1.00 ประเภทของกลืนดีเยี่ยมและดีเท่านั้น ซึ่งหมายความว่าสามารถทำนายประเภทของกลืนดีเยี่ยมและดีได้ถูกต้องกับความเป็นจริง

ตารางที่ 4.20  $F_1$  Score การเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 2 ในการทดลองครั้งที่ 6

ประเภทของกลิ่น	$F_1$ Score ครั้งที่ 6			
	โมเดลที่นำเสนอ	DNN	SVM	DTree
ดีเยี่ยม	0.98	0.97	0.98	<b>1.00</b>
ดี	0.98	0.97	0.97	<b>1.00</b>
พอรับได้	<b>0.99</b>	0.98	0.96	0.97
น่าเสีย	<b>0.99</b>	0.97	0.97	0.96

จากตารางที่ 4.20 เป็นการเปรียบเทียบค่า  $F_1$  Score ของชุดข้อมูลที่ 2 ในการทดลองครั้งที่ 6 โดยโมเดลที่นำเสนอ มีค่า  $F_1$  Score เป็น 0.99 ที่ประเภทของกลิ่นพอรับได้และน่าเสีย ซึ่งหมายความว่าสามารถทำนายประเภทของกลิ่นพอรับได้และน่าเสียได้ใกล้เคียงถูกต้องกับความเป็นจริง และโมเดลการเรียนรู้แบบรวมกลุ่มของต้นไม้ตัดสินใจมีค่า  $F_1$  Score เป็น 1.00 ประเภทของกลิ่นดีเยี่ยมและดีเท่านั้น ซึ่งหมายความว่าสามารถทำนายประเภทของกลิ่นดีเยี่ยมและดีได้ถูกต้องกับความเป็นจริง

ตารางที่ 4.21  $F_1$  Score การเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 2 ในการทดลองครั้งที่ 7

ประเภทของกลิ่น	$F_1$ Score ครั้งที่ 7			
	โมเดลที่นำเสนอ	DNN	SVM	DTree
ดีเยี่ยม	0.99	0.99	0.97	<b>1.00</b>
ดี	0.99	0.99	0.96	<b>1.00</b>
พอรับได้	0.97	<b>0.99</b>	0.96	0.97
น่าเสีย	0.97	<b>0.99</b>	0.97	0.97

จากตารางที่ 4.21 เป็นการเปรียบเทียบค่า  $F_1$  Score ของชุดข้อมูลที่ 2 ในการทดลองครั้งที่ 7 โดยโมเดลที่นำเสนอ มีค่า  $F_1$  Score เป็น 0.99 ประเภทของกลิ่นดีเยี่ยมและดีเท่านั้น ซึ่งหมายความว่าสามารถทำนายประเภทของกลิ่นดีเยี่ยมและดีได้ใกล้เคียงถูกต้องกับความเป็นจริง ส่วนโมเดลการเรียนรู้แบบรวมกลุ่มของโครงข่ายประสาทเทียมแบบลึกมีค่า  $F_1$  Score เป็น 0.99 ทุกประเภทของกลิ่น ซึ่งหมายความว่าสามารถทำนายทุกประเภทของกลิ่นได้ใกล้เคียงถูกต้องกับความเป็นจริง ส่วนโมเดลการเรียนรู้แบบรวมกลุ่มของต้นไม้ตัดสินใจมีค่า  $F_1$  Score เป็น 1.00 ที่ประเภทของกลิ่นดีเยี่ยมและดีเท่านั้น ซึ่งหมายความว่าสามารถทำนายประเภทของกลิ่นดีเยี่ยมและดีได้ถูกต้องกับความเป็นจริง

ตารางที่ 4.22  $F_1$  Score การเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 2 ในการทดลองครั้งที่ 8

ประเภทของกลืน	$F_1$ Score ครั้งที่ 8			
	โมเดลที่นำเสนอ	DNN	SVM	DTree
ดีเยี่ยม	0.99	0.99	0.99	0.99
ดี	0.98	0.99	0.97	0.99
พอรับได้	0.99	0.97	0.96	0.97
น่าเสีย	0.99	0.98	0.98	0.98

จากตารางที่ 4.22 เป็นการเปรียบเทียบค่า  $F_1$  Score ของชุดข้อมูลที่ 2 ในการทดลองครั้งที่ 8 โดยโมเดลที่นำเสนอ มีค่า  $F_1$  Score เป็น 0.99 ที่ประเภทของกลืนดีเยี่ยม พอรับได้ และน่าเสีย ซึ่งหมายความว่าสามารถทำนายประเภทของกลืนดีเยี่ยม พอรับได้ และน่าเสียได้ใกล้เคียงถูกต้องกับความเป็นจริง ส่วนโมเดลการเรียนรู้แบบรวมกลุ่มของโครงข่ายประสาทเทียมแบบลึก และโมเดลการเรียนรู้แบบรวมกลุ่มของต้นไม้ตัดสินใจมีค่า  $F_1$  Score เป็น 0.99 ประเภทของกลืนดีเยี่ยมและดี ซึ่งหมายความว่าสามารถทำนายประเภทของกลืนดีเยี่ยมและดีได้ใกล้เคียงถูกต้องกับความเป็นจริง

ตารางที่ 4.23  $F_1$  Score การเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 2 ในการทดลองครั้งที่ 9

ประเภทของกลืน	$F_1$ Score ครั้งที่ 9			
	โมเดลที่นำเสนอ	DNN	SVM	DTree
ดีเยี่ยม	0.98	0.99	0.99	0.99
ดี	0.97	0.99	0.95	0.98
พอรับได้	0.99	1.00	0.96	0.96
น่าเสีย	1.00	1.00	0.99	0.97

จากตารางที่ 4.23 เป็นการเปรียบเทียบค่า  $F_1$  Score ของชุดข้อมูลที่ 2 ในการทดลองครั้งที่ 9 โดยโมเดลที่นำเสนอ มีค่า  $F_1$  Score เป็น 1.00 ที่ประเภทของกลืนน่าเสียเท่านั้น ซึ่งหมายความว่าสามารถทำนายประเภทของกลืนน่าเสียได้ถูกต้องกับความเป็นจริง และโมเดลการเรียนรู้แบบรวมกลุ่มของโครงข่ายประสาทเทียมแบบลึกมีค่า  $F_1$  Score เป็น 1.00 ประเภทของกลืนพอรับได้และน่าเสีย ซึ่งหมายความว่าสามารถทำนายประเภทของกลืนพอรับได้และน่าเสียได้ถูกต้องกับความเป็นจริง

ตารางที่ 4.24  $F_1$  Score การเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 2 ในการทดลองครั้งที่ 10

ประเภทของกลิ่น	$F_1$ Score ครั้งที่ 10			
	โมเดลที่นำเสนอ	DNN	SVM	DTree
ดีเยี่ยม	0.98	0.98	0.99	<b>1.00</b>
ดี	0.98	0.97	0.97	<b>0.99</b>
พอรับได้	0.98	<b>0.99</b>	0.95	0.97
น่าเสีย	<b>0.98</b>	<b>0.98</b>	0.96	0.97

จากตารางที่ 4.24 เป็นการเปรียบเทียบค่า  $F_1$  Score ของชุดข้อมูลที่ 2 ในการทดลองครั้งที่ 10 โดยโมเดลที่นำเสนอ มีค่า  $F_1$  Score เป็น 0.98 ทุกประเภทของกลิ่น ซึ่งหมายความว่าสามารถทำนายทุกประเภทของกลิ่นได้ใกล้เคียงถูกต้องกับความเป็นจริง และโมเดลการเรียนรู้แบบรวมกลุ่มของต้นไม้ตัดสินใจมีค่า  $F_1$  Score เป็น 1.00 ที่ประเภทของกลิ่นดีเยี่ยมเท่านั้น ซึ่งหมายความว่าสามารถทำนายประเภทของกลิ่นดีเยี่ยมได้ถูกต้องกับความเป็นจริง

จากนั้นทำการเปรียบเทียบประสิทธิภาพการจำแนกประเภทของกลิ่นในแต่ละการเรียนรู้แบบรวมกลุ่ม โดยมีผลการทดลองด้วยชุดข้อมูลที่ 3 ดังแสดงตามตารางที่ 4.25

ตารางที่ 4.25 ประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้แบบรวมกลุ่มที่เลือกมาใช้ทดลองของชุดข้อมูลที่ 3

ครั้ง	โมเดลการเรียนรู้แบบรวมกลุ่ม (ร้อยละ)			
	โมเดลที่นำเสนอ	DNN	SVM	DTree
1	99.17	98.50	89.17	99.17
2	98.89	98.83	90.22	98.89
3	99.44	96.28	88.94	99.00
4	99.67	97.50	89.06	99.06
5	99.67	97.00	89.94	98.67
6	98.89	98.44	90.17	99.00
7	99.00	98.50	88.50	98.83
8	99.56	98.11	89.22	98.78
9	99.06	99.06	88.67	98.89
10	98.83	99.22	89.22	99.22
MEAN	<b>99.22</b>	98.14	89.31	98.95
S.D.	0.34	0.94	0.60	<b>0.17</b>
MAX	<b>99.67</b>	99.22	90.22	99.22
MIN	<b>98.83</b>	96.28	88.50	98.67

จากตารางที่ 4.25 ทำการทดสอบด้วยชุดข้อมูลที่ 3 โดยโมเดลที่นำเสนอมีค่าความแม่นยำเฉลี่ยมากที่สุดคือ ร้อยละ 99.22 ส่วนเบี่ยงเบนมาตรฐาน 0.34 ค่าความแม่นยำที่สูงสุดร้อยละ 99.67 และค่าความแม่นยำที่ต่ำสุดร้อยละ 98.83 รองลงมาคือ โมเดลการเรียนรู้แบบรวมกลุ่มของต้นไม้ตัดสินใจมีค่าความแม่นยำเฉลี่ยร้อยละ 98.95 ส่วนเบี่ยงเบนมาตรฐาน 0.17 ค่าความแม่นยำที่สูงสุดร้อยละ 99.22 และค่าความแม่นยำที่ต่ำสุดร้อยละ 98.67 ซึ่งเมื่อเปรียบเทียบกับโมเดลที่นำเสนอแล้วนั้นมีค่าส่วนเบี่ยงเบนมาตรฐานแตกต่างกัน 0.17

ตารางที่ 4.26 ระยะเวลาการทำนายประเภทของกลืนด้วยโมเดลการเรียนรู้แบบรวมกลุ่มที่เลือกมาใช้ทดลองของชุดข้อมูลที่ 3

ครั้ง	ระยะเวลาในการทำนายของการเรียนรู้แบบรวมกลุ่ม (วินาที)			
	โมเดลที่นำเสนอ	DNN	SVM	DTree
1	756.18	737.31	6.59	0.76
2	756.28	727.42	6.39	0.76
3	742.02	720.49	6.22	1.14
4	753.76	683.10	6.20	1.12
5	747.41	704.42	6.36	1.13
6	753.06	724.92	6.61	0.84
7	726.05	734.14	6.50	0.82
8	747.45	648.79	6.55	0.70
9	759.14	760.87	6.46	1.13
10	748.67	782.34	6.36	1.11
MEAN	749.00	722.38	6.42	<b>0.95</b>
S.D.	9.59	37.64	<b>0.14</b>	0.19
MAX	759.14	782.34	6.61	<b>1.14</b>
MIN	726.05	648.79	6.20	<b>0.70</b>

จากตารางที่ 4.26 โมเดลที่นำเสนอใช้ระยะเวลาเฉลี่ยในการดำเนินการการจำแนกประเภทกลืนของชุดข้อมูลที่ 3 เป็นเวลา 749.00 วินาที ซึ่งใช้เวลานานที่สุดเมื่อเทียบกับโมเดลอื่นอย่างต้นไม้ตัดสินใจที่ใช้เวลาเฉลี่ยเร็วที่สุดคือ 0.95 วินาที

นอกจากการเปรียบเทียบค่าความแม่นยำเฉลี่ยและระยะเวลาที่ใช้ในการดำเนินการด้วยชุดข้อมูลที่ 3 แล้ว ยังทำการเปรียบเทียบค่า  $F_1$  Score ในการทดลองแต่ละโมเดลทั้งหมด 10 ครั้ง ดังแสดงตามตารางที่ 4.27 - 4.36

ตารางที่ 4.27  $F_1$  Score การเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 3 ในการทดลองครั้งที่ 1

ประเภทของกลิ่น	$F_1$ Score ครั้งที่ 1			
	โมเดลที่ นำเสนอ	DNN	SVM	DTree
เนื้อส่วนซีโครง	1.00	1.00	1.00	1.00
เนื้อส่วนต้นขาหน้า	0.99	0.98	0.96	0.99
อกไก่	0.99	0.97	0.86	0.99
น่องไก่	0.99	0.97	0.87	0.99
หมูสามชั้น	0.99	0.99	0.85	0.99
ขาหมู	0.99	0.99	0.81	0.99

จากตารางที่ 4.27 เป็นการเปรียบเทียบค่า  $F_1$  Score ของชุดข้อมูลที่ 3 ในการทดลองครั้งที่ 1 โดยโมเดลที่นำเสนอและโมเดลการเรียนรู้แบบรวมกลุ่มของตนไม่ตัดสินใจ มีค่า  $F_1$  Score เป็น 1.00 ประเภทของกลิ่นเนื้อส่วนซีโครงเท่านั้น และมีค่า  $F_1$  Score เป็น 0.99 ที่ประเภทของกลิ่นอื่น ๆ ซึ่งหมายความว่าสามารถทำนายทุกประเภทของกลิ่นได้ใกล้เคียงถูกต้องกับความเป็นจริง

ตารางที่ 4.28  $F_1$  Score การเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 3 ในการทดลองครั้งที่ 2

ประเภทของกลิ่น	$F_1$ Score ครั้งที่ 2			
	โมเดลที่ นำเสนอ	DNN	SVM	DTree
เนื้อส่วนซีโครง	1.00	1.00	1.00	1.00
เนื้อส่วนต้นขาหน้า	0.99	1.00	0.95	0.99
อกไก่	0.98	0.97	0.89	0.99
น่องไก่	0.97	0.97	0.90	0.98
หมูสามชั้น	0.99	1.00	0.85	0.98
ขาหมู	1.00	1.00	0.82	0.98

จากตารางที่ 4.28 เป็นการเปรียบเทียบค่า  $F_1$  Score ของชุดข้อมูลที่ 3 ในการทดลองครั้งที่ 2 โดยโมเดลที่นำเสนอมีค่า  $F_1$  Score เป็น 1.00 ประเภทของกลิ่นเนื้อส่วนซีโครงและขาหมูเท่านั้นซึ่งหมายความว่าสามารถทำนายประเภทของกลิ่นเนื้อส่วนซีโครงและขาหมูได้ใกล้เคียงถูกต้องกับความเป็นจริง ในขณะที่โมเดลการเรียนรู้แบบรวมกลุ่มของโครงข่ายประสาทเทียมแบบลึกสามารถทำนายประเภทของกลิ่นถูกต้องกับความเป็นจริงได้มากกว่า

ตารางที่ 4.29  $F_1$  Score การเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 3 ในการทดลองครั้งที่ 3

ประเภทของกลืน	$F_1$ Score ครั้งที่ 3			
	โมเดลที่ นำเสนอ	DNN	SVM	DTree
เนื้อส่วนซีโครง	1.00	1.00	1.00	1.00
เนื้อส่วนต้นขาหน้า	0.99	0.98	0.96	1.00
อกไก่	0.99	0.91	0.87	0.99
น่องไก่	0.99	0.93	0.88	0.99
หมูสามชั้น	1.00	0.98	0.84	0.98
ขาหมู	1.00	0.98	0.79	0.98

จากตารางที่ 4.29 เป็นการเปรียบเทียบค่า  $F_1$  Score ของชุดข้อมูลที่ 3 ในการทดลองครั้งที่ 3 โดยโมเดลที่นำเสนอมีค่า  $F_1$  Score เป็น 1.00 จำนวนมากที่สุด โดยที่ประเภทของกลืนเนื้อส่วนซีโครง หมูสามชั้น และขาหมูเท่านั้น ซึ่งหมายความว่าสามารถทำนายประเภทของกลืนเนื้อส่วนซีโครง หมูสามชั้น และขาหมูได้ถูกต้องกับความเป็นจริง

ตารางที่ 4.30  $F_1$  Score การเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 3 ในการทดลองครั้งที่ 4

ประเภทของกลืน	$F_1$ Score ครั้งที่ 4			
	โมเดลที่ นำเสนอ	DNN	SVM	DTree
เนื้อส่วนซีโครง	1.00	1.00	1.00	1.00
เนื้อส่วนต้นขาหน้า	0.99	0.99	0.94	0.99
อกไก่	1.00	0.93	0.85	0.99
น่องไก่	1.00	0.93	0.86	0.99
หมูสามชั้น	0.99	0.99	0.87	0.98
ขาหมู	1.00	0.99	0.82	1.00

จากตารางที่ 4.30 เป็นการเปรียบเทียบค่า  $F_1$  Score ของชุดข้อมูลที่ 3 ในการทดลองครั้งที่ 4 โดยโมเดลที่นำเสนอมีค่า  $F_1$  Score เป็น 1.00 จำนวนมากที่สุด โดยที่ประเภทของกลืนเนื้อส่วนซีโครง อกไก่ น่องไก่ และขาหมู ซึ่งสามารถทำนายประเภทของกลืนเนื้อส่วนซีโครงอกไก่ น่องไก่ และขาหมูได้ถูกต้องกับความเป็นจริง

ตารางที่ 4.31  $F_1$  Score การเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 3 ในการทดลองครั้งที่ 5

ประเภทของกลืน	$F_1$ Score ครั้งที่ 5			
	โมเดลที่ นำเสนอ	DNN	SVM	DTree
เนื้อส่วนซีโครง	1.00	0.99	1.00	1.00
เนื้อส่วนต้นขาหน้า	0.99	0.98	0.96	0.99
อกไก่	1.00	0.93	0.87	0.98
น่องไก่	1.00	0.94	0.88	0.98
หมูสามชั้น	0.99	0.99	0.85	0.98
ขาหมู	1.00	0.99	0.84	0.99

จากตารางที่ 4.31 เป็นการเปรียบเทียบค่า  $F_1$  Score ของชุดข้อมูลที่ 3 ในการทดลองครั้งที่ 5 โดยโมเดลที่นำเสนอมีค่า  $F_1$  Score เป็น 1.00 จำนวนมากที่สุด โดยที่ประเภทของกลืนเนื้อส่วนซีโครง อกไก่ น่องไก่ และขาหมูเท่านั้น ซึ่งสามารถทำนายประเภทของกลืนเนื้อส่วนซีโครงอกไก่ น่องไก่ และขาหมูได้ถูกต้องกับความเป็นจริง

ตารางที่ 4.32  $F_1$  Score การเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 3 ในการทดลองครั้งที่ 6

ประเภทของกลืน	$F_1$ Score ครั้งที่ 6			
	โมเดลที่ นำเสนอ	DNN	SVM	DTree
เนื้อส่วนซีโครง	1.00	0.99	1.00	1.00
เนื้อส่วนต้นขาหน้า	0.99	0.99	0.96	0.99
อกไก่	0.98	0.97	0.87	0.99
น่องไก่	0.98	0.98	0.87	0.99
หมูสามชั้น	0.99	0.99	0.87	0.98
ขาหมู	0.99	0.99	0.83	0.98

จากตารางที่ 4.32 เป็นการเปรียบเทียบค่า  $F_1$  Score ของชุดข้อมูลที่ 3 ในการทดลองครั้งที่ 6 โดยโมเดลที่นำเสนอ โมเดลการเรียนรู้แบบรวมกลุ่มของซัพพอร์ตเวกเตอร์แมชชีน และโมเดลการเรียนรู้แบบรวมกลุ่มของต้นไม้ตัดสินใจ มีค่า  $F_1$  Score เป็น 1.00 ประเภทของกลืนเนื้อส่วนซีโครงเท่านั้น ซึ่งสามารถทำนายประเภทของกลืนเนื้อส่วนซีโครงได้ถูกต้องกับความเป็นจริง

ตารางที่ 4.33  $F_1$  Score การเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 3 ในการทดลองครั้งที่ 7

ประเภทของกลืน	$F_1$ Score ครั้งที่ 7			
	โมเดลที่ นำเสนอ	DNN	SVM	DTree
เนื้อส่วนซีโครง	1.00	1.00	1.00	1.00
เนื้อส่วนต้นขาหน้า	0.99	1.00	0.95	0.98
อกไก่	0.98	0.96	0.87	0.99
น่องไก่	0.98	0.96	0.88	0.99
หมูสามชั้น	1.00	1.00	0.82	0.99
ขาหมู	0.99	1.00	0.80	0.98

จากตารางที่ 4.33 เป็นการเปรียบเทียบค่า  $F_1$  Score ของชุดข้อมูลที่ 3 ในการทดลองครั้งที่ 7 โดยโมเดลที่นำเสนอมีค่า  $F_1$  Score เป็น 1.00 ประเภทของกลืนเนื้อส่วนซีโครงและหมูสามชั้นเท่านั้น ซึ่งหมายความว่าสามารถทำนายทุกประเภทของกลืนเนื้อส่วนซีโครงและหมูสามชั้นได้ใกล้เคียงถูกต้องกับความเป็นจริง ในขณะที่โมเดลการเรียนรู้แบบรวมกลุ่มของโครงข่ายประสาทเทียมแบบลึกสามารถทำนายทุกประเภทของกลืนถูกต้องกับความเป็นจริงได้มากกว่า

ตารางที่ 4.34  $F_1$  Score การเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 3 ในการทดลองครั้งที่ 8

ประเภทของกลืน	$F_1$ Score ครั้งที่ 8			
	โมเดลที่ นำเสนอ	DNN	SVM	DTree
เนื้อส่วนซีโครง	1.00	1.00	1.00	1.00
เนื้อส่วนต้นขาหน้า	1.00	0.98	0.96	1.00
อกไก่	0.99	0.97	0.87	0.98
น่องไก่	1.00	0.97	0.86	0.97
หมูสามชั้น	0.99	0.98	0.85	0.98
ขาหมู	0.99	0.98	0.81	1.00

จากตารางที่ 4.34 เป็นการเปรียบเทียบค่า  $F_1$  Score ของชุดข้อมูลที่ 3 ในการทดลองครั้งที่ 8 โดยโมเดลที่นำเสนอ มีค่า  $F_1$  Score เป็น 1.00 ที่ประเภทของกลืนเนื้อส่วนซีโครง เนื้อส่วนต้นขาหน้า และน่องไก่เท่านั้น ซึ่งหมายความว่าสามารถทำนายประเภทของกลืนเนื้อส่วนซีโครง เนื้อส่วนต้นขาหน้า และน่องไก่ได้ถูกต้องกับความเป็นจริง

ตารางที่ 4.35  $F_1$  Score การเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 3 ในการทดลองครั้งที่ 9

ประเภทของกลืน	$F_1$ Score ครั้งที่ 9			
	โมเดลที่ นำเสนอ	DNN	SVM	DTree
เนื้อส่วนซีโครง	1.00	1.00	1.00	1.00
เนื้อส่วนต้นขาหน้า	1.00	0.99	0.95	0.99
อกไก่	0.98	0.98	0.88	0.99
น่องไก่	0.97	0.98	0.88	0.99
หมูสามชั้น	1.00	0.99	0.82	0.98
ขาหมู	1.00	1.00	0.79	0.98

จากตารางที่ 4.35 เป็นการเปรียบเทียบค่า  $F_1$  Score ของชุดข้อมูลที่ 3 ในการทดลองครั้งที่ 9 โดยโมเดลที่นำเสนอ มีค่า  $F_1$  Score เป็น 1.00 ที่ประเภทของกลืนเนื้อส่วนซีโครง เนื้อส่วนต้นขาหน้า หมูสามชั้น และขาหมูเท่านั้น ซึ่งหมายความว่าสามารถทำนายประเภทของกลืนเนื้อส่วนซีโครง เนื้อส่วนต้นขาหน้า หมูสามชั้น และขาหมูได้ถูกต้องกับความเป็นจริง

ตารางที่ 4.36  $F_1$  Score การเรียนรู้แบบรวมกลุ่มของชุดข้อมูลที่ 3 ในการทดลองครั้งที่ 10

ประเภทของกลืน	$F_1$ Score ครั้งที่ 10			
	โมเดลที่ นำเสนอ	DNN	SVM	DTree
เนื้อส่วนซีโครง	1.00	1.00	1.00	1.00
เนื้อส่วนต้นขาหน้า	0.99	0.99	0.93	0.99
อกไก่	0.97	0.99	0.87	0.99
น่องไก่	0.97	0.99	0.88	0.99
หมูสามชั้น	1.00	1.00	0.84	0.99
ขาหมู	1.00	0.99	0.83	1.00

จากตารางที่ 4.36 เป็นการเปรียบเทียบค่า  $F_1$  Score ของชุดข้อมูลที่ 3 ในการทดลองครั้งที่ 10 โดยโมเดลที่นำเสนอ มีค่า  $F_1$  Score เป็น 1.00 ที่ประเภทของกลืนเนื้อส่วนซีโครง หมูสามชั้น และขาหมูเท่านั้น ซึ่งหมายความว่าสามารถทำนายประเภทของกลืนเนื้อส่วนซีโครง หมูสามชั้น และขาหมูได้ถูกต้องกับความเป็นจริง

## 4.2 การอภิปรายผล

ในการอภิปรายผลการวิจัยการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้แบบรวมกลุ่มจากผลการวิจัยข้อ 4.1 ซึ่งได้อภิปรายดังนี้

ตารางที่ 4.37 ค่าเฉลี่ยประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้แบบรวมกลุ่ม

การเรียนรู้แบบรวมกลุ่ม	ชุดข้อมูล		
	ชุดข้อมูลที่ 1	ชุดข้อมูลที่ 2	ชุดข้อมูลที่ 3
โมเดลที่นำเสนอ	99.86%	98.33%	99.22%
Deep Neural Network	99.44%	98.20%	98.14%
Support Vector Machine	98.19%	97.20%	89.31%
Decision Tree	98.47%	97.90%	98.95%

จากตารางที่ 4.37 แสดงค่าเฉลี่ยประสิทธิภาพการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้แบบรวมกลุ่มที่ใช้ในการเปรียบเทียบ โดยโมเดลที่นำเสนอมีค่าเฉลี่ยของประสิทธิภาพในการทำนายสูงสุดทั้ง 3 ชุดข้อมูล โดยชุดข้อมูลที่ 1 ได้ความแม่นยำร้อยละ 99.86 ชุดข้อมูลที่ 2 ได้ความแม่นยำร้อยละ 98.33 และชุดข้อมูลที่ 3 ได้ความแม่นยำร้อยละ 99.22

ตารางที่ 4.38 ระยะเวลาเฉลี่ยการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้แบบรวมกลุ่ม

การเรียนรู้แบบรวมกลุ่ม	ชุดข้อมูล		
	ชุดข้อมูลที่ 1	ชุดข้อมูลที่ 2	ชุดข้อมูลที่ 3
โมเดลที่นำเสนอ	42.16	122.61	749.00
Deep Neural Network	40.31	120.36	722.38
Support Vector Machine	0.66	0.78	6.42
Decision Tree	0.96	0.73	0.95

จากตารางที่ 4.38 แสดงระยะเวลาเฉลี่ยการทำนายประเภทของกลิ่นด้วยโมเดลการเรียนรู้แบบรวมกลุ่มที่ใช้ในการเปรียบเทียบ โดยโมเดลที่นำเสนอมีระยะเวลาค่าเฉลี่ยของชุดข้อมูลที่ 1 ใช้เวลา 42.16 วินาที ชุดข้อมูลที่ 2 ใช้เวลา 122.61 วินาที และชุดข้อมูลที่ 3 ใช้เวลา 749.00 วินาที ซึ่งเมื่อเทียบกับโมเดลการเรียนรู้แบบรวมกลุ่มที่นำมาเปรียบเทียบแล้วใช้ระยะเวลาที่นานที่สุด

## บทที่ 5

# สรุปผลการวิจัยและข้อเสนอแนะ

### 5.1 สรุปผลการวิจัย

งานวิจัยนี้ได้ทำการสร้างการผสมผสานระหว่างการเรียนรู้เชิงลึก ได้แก่ โครงข่ายประสาทเทียมแบบลึก และการเรียนรู้เชิงต้น ได้แก่ ซัพพอร์ตเวกเตอร์แมชชีน และต้นไม้ตัดสินใจ จากการศึกษาเปรียบเทียบทดลองการเรียนรู้ของเครื่องแบบปกติเพื่อหาโมเดลที่มีประสิทธิภาพสำหรับการจำแนกประเภทของกลิ่นโดยใช้วิธีการอะแดปทีฟบูตสตรึง ซึ่งเป็นวิธีการหนึ่งในการเรียนรู้แบบรวมกลุ่ม ด้วยชุดข้อมูลค่าสัญญาณตัวเลขของเซ็นเซอร์จากจุ่มกือเล็กทรอนิกส์ โดยจุ่มกือเล็กทรอนิกส์เป็นเซ็นเซอร์ที่มีความสามารถในการรับรู้กลิ่นได้ดีกว่าจุ่มกือของมนุษย์และสามารถตรวจจับกลิ่นที่แตกต่างกัน

ในการจำแนกประเภทของกลิ่นด้วยการเรียนรู้ของเครื่องต้องทำการฝึกสอนและทดสอบด้วยโมเดลการเรียนรู้ของเครื่องแบบต่าง ๆ จากชุดข้อมูลทั้งหมด 3 ชุด กลิ่นของแอลกอฮอล์ ซึ่งเป็นชุดข้อมูลจากห้องปฏิบัติการของวิทยาลัยนาโนเทคโนโลยี พระจอมเกล้าลาดกระบัง กลิ่นของคุณภาพเนื้อและกลิ่นของเนื้อส่วนต่าง ๆ ซึ่งเป็นชุดข้อมูลจากเว็บไซต์ Mendeley ทำการทดลองทั้งหมด 10 ครั้ง และโมเดลที่มีการผสมผสานการเรียนรู้ที่นำเสนอสามารถให้ความแม่นยำที่ดีที่สุด โดยชุดข้อมูลที่ 1 ได้รับความแม่นยำเฉลี่ยร้อยละ 99.86 ใช้ระยะเวลาดำเนินการ 42.16 วินาที ชุดข้อมูลที่ 2 ได้รับความแม่นยำเฉลี่ยร้อยละ 98.33 ใช้ระยะเวลาดำเนินการ 122.61 วินาที และชุดข้อมูลที่ 3 ได้รับความแม่นยำเฉลี่ยร้อยละ 99.22 ใช้ระยะเวลาดำเนินการ 749.00 วินาที รองลงมาเป็นโมเดลโครงข่ายประสาทเทียมแบบลึก ชุดข้อมูลที่ 1 ได้รับความแม่นยำเฉลี่ยร้อยละ 99.44 ใช้ระยะเวลาดำเนินการ 40.31 วินาที ชุดข้อมูลที่ 2 ได้รับความแม่นยำเฉลี่ยร้อยละ 98.20 ใช้ระยะเวลาดำเนินการ 120.36 วินาที และโมเดลต้นไม้ตัดสินใจ ชุดข้อมูลที่ 3 ได้รับความแม่นยำเฉลี่ยร้อยละ 98.95 ใช้ระยะเวลาดำเนินการ 0.95 วินาที ดังนั้นโมเดลที่เกิดจากการผสมผสานการเรียนรู้ของเครื่องทำให้ได้ประสิทธิภาพในการจำแนกประเภทของกลิ่นได้ดีที่สุด

### 5.2 ข้อเสนอแนะ

งานวิจัยนี้มีประเภทของกลิ่น (Class) ที่ไม่มาก รวมไปถึงปัจจัยอื่น ๆ ในคุณลักษณะ (Attribute) ของชุดข้อมูล เช่น ทิศทาง ความเร็วลมพัดผ่าน อุณหภูมิ และความชื้นของเซ็นเซอร์จุ่มกือเล็กทรอนิกส์ บริเวณที่ตั้งสถานี ไม่ได้มีการนำมาใช้ฝึกสอนโมเดลการเรียนรู้ของเครื่อง เพื่อให้โมเดลสามารถทำนายทิศทางแหล่งที่มาของกลิ่นที่แม่นยำได้มากกว่าการทำนายประเภทของกลิ่นอย่างเดียว

## เอกสารอ้างอิง

- [1] Ali M. A., “Odour Identification Using Machine Learning Techniques,” International Conference on Technical Sciences (ICST2019), pp. 239–244, 2019.
- [2] Anyan Su, Zhimin He, Junjian Su, Yan Zhou, Yun Fan and Yuan Kong, “Detection of Tax Arrears Based on Ensemble Learning Model,” 2018 International Conference on Wavelet Analysis and Pattern Recognition (ICWAPR), pp. 270–274, 2018.
- [3] Hsin-Kai Huang, Chien-Fang Chiu, Chien-Hao Kuo, Yu-Chi Wu, Narisa N.Y. Chu and Pao-Chi Chang, “Mixture of Deep CNN-based Ensemble Model for Image Retrieval,” 2016 IEEE 5th Global Conference on Consumer Electronics, 2016.
- [4] Wikipedia. (2020). Deep learning. January 20, 2020, from Wikipedia Web site: [https://en.wikipedia.org/wiki/Deep\\_learning](https://en.wikipedia.org/wiki/Deep_learning)
- [5] วิกิพีเดีย สารานุกรมเสรี. (2017). การเรียนรู้เชิงลึก. January 20, 2020, from Wikipedia Web site: <https://th.wikipedia.org/wiki/การเรียนรู้เชิงลึก>
- [6] Techopedia. Deep Neural Network. May 10, 2019, from techopedia Web site: <https://www.techopedia.com/definition/32902/deep-neural-network>
- [7] Doug Hawkins. (2018). What is shallow knowledge?. May 28, 2019, from Quora Web site: <https://www.quora.com/What-is-shallow-knowledge>
- [8] kokzard. (2016). อัลกอริทึม Support Vector Machine (SVM). May 10, 2019, from blogspot Web site: <http://kokzard.blogspot.com/2011/10/jfjkdshfkjsldf.html>
- [9] Wikipedia. (2017). Support-vector machine. May 20, 2019, from Wikipedia Web site: [https://en.wikipedia.org/wiki/Support-vector\\_machine](https://en.wikipedia.org/wiki/Support-vector_machine)
- [10] chaiyanan. (2018). ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine: SVM). May 10, 2019, from blogspot Web site: <https://knowledge.snru.ac.th/ซัพพอร์ตเวกเตอร์แมชชีน/>
- [11] Rajesh S. Brid. (2018). Decision Trees – A simple way to visualize a decision. May 10, 2019, from medium Web site: <https://medium.com/greyatom/decision-trees-a-simple-way-to-visualize-a-decision-dc506a403aeb>
- [12] ดร.นพมาศ ปักเข็ม. การเรียนรู้แบบเบย์ (Bayesian Learning). December 25, 2019, from [mis.csit.sci.tsu.ac.th](http://mis.csit.sci.tsu.ac.th) Web site:

<https://mis.csit.sci.tsu.ac.th/noppamas/download/DataMining/DataMiningCh7V1.pdf>

- [13] วิกีพีเดีย สารานุกรมเสรี. (2019). ขั้นตอนวิธีการค้นหาเพื่อนบ้านใกล้สุด k ตัว. January 20, 2020, from Wikipedia Web site: [https://th.wikipedia.org/wiki/ขั้นตอนวิธีการค้นหาเพื่อนบ้านใกล้สุด\\_k\\_ตัว](https://th.wikipedia.org/wiki/ขั้นตอนวิธีการค้นหาเพื่อนบ้านใกล้สุด_k_ตัว)
- [14] Wikipedia. (2020). k-nearest neighbors algorithm. January 28, 2020, from Wikipedia Web site: [https://en.wikipedia.org/wiki/K-nearest\\_neighbors\\_algorithm](https://en.wikipedia.org/wiki/K-nearest_neighbors_algorithm)
- [15] Nuttavut Thongjor. (2017). [Machine Learning#2] รู้จักการจำแนกประเภทข้อมูลด้วย k-Nearest Neighbors. January 12, 2020, from Babel Coder Web site: <https://www.babelcoder.com/blog/posts/k-nearest-neighbors>
- [16] CORALINE CO. LTD. (2017). สถิติเบื้องต้นง่ายๆ ที่จะช่วยให้คุณเข้าใจการวิเคราะห์มากขึ้น (ตอนที่ 2). January 13, 2020, from medium Web site: [https://medium.com/@info\\_46914/สถิติเบื้องต้นง่ายๆ-ที่จะช่วยให้คุณเข้าใจการวิเคราะห์มากขึ้น-ตอนที่-2-1f94b6664ede](https://medium.com/@info_46914/สถิติเบื้องต้นง่ายๆ-ที่จะช่วยให้คุณเข้าใจการวิเคราะห์มากขึ้น-ตอนที่-2-1f94b6664ede)
- [17] Wikipedia. (2020). Logistic regression. January 25, 2020, from Wikipedia Web site: [https://en.wikipedia.org/wiki/Logistic\\_regression](https://en.wikipedia.org/wiki/Logistic_regression)
- [18] Jinde Shubham. (2018). Ensemble Learning — Bagging and Boosting. June 8, 2019, from becominghuman.ai Web site: <https://becominghuman.ai/ensemble-learning-bagging-and-boosting-d20f38be9b1e>
- [19] SeattleDataGuy. (2017). Boosting and Bagging: How To Develop A Robust Machine Learning Algorithm. June 8, 2019, from HACKERNOON Web site: <https://hackernoon.com/how-to-develop-a-robust-algorithm-c38e08f32201>
- [20] Wikipedia. (2019). AdaBoost. May 15, 2019, from Wikipedia Web site: <https://en.wikipedia.org/wiki/AdaBoost>
- [21] SauceCat. (2017). Boosting algorithm: AdaBoost. June 8, 2019, from towardsdatascience Web site: <https://towardsdatascience.com/boosting-algorithm-adaboost-b6737a9ee60c>
- [22] Avinash Navlani. (2018). AdaBoost Classifier in Python. June 8, 2019, from DataCamp Web site: <https://www.datacamp.com/community/tutorials/adaboost-classifier-python>
- [23] Wikipedia. (2020). Gradient boosting. January 27, 2020, from Wikipedia Web site: [https://en.wikipedia.org/wiki/Gradient\\_boosting](https://en.wikipedia.org/wiki/Gradient_boosting)

- [24] Nut Chukamphaeng. (2018). ทำไมใครๆก็ใช้ XGBoost กันจัง. January 27, 2020, from Wikipedia Web site: <https://medium.com/@nutorbitx/ทำไมใครๆก็ใช้-xgboost-กัน-จัง-a775b53cc1eb>
- [25] Wikipedia. (2020). Random forest. January 25, 2020, from Wikipedia Web site: [https://en.wikipedia.org/wiki/Random\\_forest](https://en.wikipedia.org/wiki/Random_forest)
- [26] Witchapong Daroontham. (2018). เจาะลึก Random Forest !!!— Part 2 of “รู้จัก Decision Tree, Random Forest, และ XGBoost!!!”. January 22, 2020, from medium Web site: <https://medium.com/@witchapongdaroontham/เจาะลึก-random-forest-part-2-of-รู้จัก-decision-tree-random-forest-และ-xgboost-79b9f41a1c1c>
- [27] เทียนชัย จำรัสสกุล. (2017). จมูกอิเล็กทรอนิกส์ (ELECTRONIC NOSE). May 25, 2019, from Ministry of Science and Technology Web site: <https://www.mhesi.go.th/main/th/116-knowledge/work-of-most/nstda/1681-electronic-nose>
- [28] Wikipedia. (2019). Electronic nose. May 25, 2019, from Wikipedia Web site: [https://en.wikipedia.org/wiki/Electronic\\_nose](https://en.wikipedia.org/wiki/Electronic_nose)
- [29] ดร. เอกสิทธิ์ พัทธวงศ์ศักดิ์ดา. (2015). ตัววัดประสิทธิภาพของโมเดล Classification. February 28, 2020, from Data Mining Trend Web site: [http://dataminingtrend.com/2014/classifier\\_evaluation\\_metrics/](http://dataminingtrend.com/2014/classifier_evaluation_metrics/)

ภาคผนวก ก  
งานวิจัยที่ตีพิมพ์ 1



# 5<sup>th</sup> iceast 2019

*Luang Prabang, Lao PDR*

2-5 July 2019  
[www.iceast2019.org](http://www.iceast2019.org)



# A Deep Learning Model for Odor Classification Using Deep Neural Network

Boonyawee Grodnyomchai

Department of Computer Science, Faculty of Science, King Mongkut's Institute of Technology Ladkrabang, Bangkok, Thailand  
boonyawee\_4449@hotmail.com

Kulsawasd Jitkajornwanich, Ph.D.

Department of Computer Science, Faculty of Science, King Mongkut's Institute of Technology Ladkrabang, Bangkok, Thailand  
kulsawasd.ji@kmitl.ac.th

Khattiya Chalapat, Ph.D.

College of Nanotechnology, King Mongkut's Institute of Technology Ladkrabang, Bangkok, Thailand  
kchalapat@gmail.com

Saichon Jaiyen, Ph.D.

Department of Computer Science, Faculty of Science, King Mongkut's Institute of Technology Ladkrabang, Bangkok, Thailand  
saichon.ja@kmitl.ac.th

**Abstract**— The odor is an environment that surrounds us. However, to identify the odor by using the human nose in order to prove the odor is very dangerous. Therefore, the artificial intelligent (AI) system should be built based on machine learning in order to achieve more accurate results. This research adopts the Deep Neural Network (DNN) model to identify some types of odor including odorless, beer odor, whisky odor, and wine odor. Each contains 60 instances that are obtained from seven sensors of the electronic nose. The experiments are conducted, and the results are compared to the comparative machine learning methods including Multilayer Perceptron (MLP), Decision Tree and Naïve Bayes (NB). From the experimental results, it can signify that the proposed deep learning model can achieve the best average accuracy.

**Keywords**— *deep neural network; classification, electronic nose; artificial intelligence; machine learning; odor classification*

## I. INTRODUCTION

The odor classification problem using machine learning techniques is a challenging problem. To use a human nose for identification of the smell is very dangerous. To overcome this problem, the artificially intelligent system should be applied to identify the dangerous odor to reduce the risk of human life and health. Currently, many machine learning kinds of research have concentrated on data analytics for business. So, this research focuses on applying machine learning to protect human life and health.

Chomtip P. and Piyorot K. applied the Neural Network model for Chemical substance classification from electronic noses by modifying the number of hidden neurons in the hidden layer to get different performance in the same model [1]. Francesca Arcelli F. and et al. used the Naïve Bayes model in the Data Class Code smell with 95.4% accuracy and God Class Code smell with an accuracy of 95.4% [2]. Salahedin

S. and Leili E. adopt the neural network, Multilayer Perceptron with the back-propagation algorithm, to detect and extract the smoke smell by adjusting the weights and bias values to obtain the best accuracy [3]. Khalid A. and et al. developed the classification algorithm by using machine learning to design a smell detection system for using in the industry [4]. Pei-Feng Qi and et al. used the Convolutional Neural Network (CNN) for smell classification from the electronic nose sensors and converting the sensor data to a gray image to achieve the better performance with 95.7% accuracy and compared to Support Vector Machine (SVM) that give the accuracy of 92.9% [5]. Bipan T. and et al. modified the Back-Propagation algorithm for Multilayer Perceptron to improve the accuracy of the electronic nose for the classification of black tea [6]. Nakarin M. and Pomsiri M. collected 7 datasets which contained 27 design indicators and 7 bad smells and used the Random Forest to identify and obtained the accuracy of 94.53 % while Naïve Bayes gives the average accuracy of 78.38% [7]. Chomtip P. and Natt S. applied two methods: Rule-base method and Neural network for checking the type of beer. The structure of the model consists of 25 input neurons in the input layer, 28 hidden neurons in the hidden layer and 10 output neurons in the output layer and produce the accuracy of 87.5% [8]. Mizanur R. used an electronic nose instead of a human nose or animal nose to identify the quality of food and fruits. They conducted experiments and found that the appropriated models for classifying data from the electronic nose are a k-nearest neighbor (k-NN), support vector machine (SVM), radial basis function (RBF), and generalized regression neural networks (GRNNs) [9].

The electronic noses are the nose that can smell by electronic sensors. However, they cannot recognize the types of smell. Therefore, the artificial intelligence system based on machine learning techniques should be integrated with the electronic nose in order to make

them recognize the types of smell. In this research, we adopt the deep learning model to recognize the types of odors in order to build an artificially intelligent system that can smell.

## II. METHODOLOGY

### A. Deep Neural Network (DNN)

Deep Neural Network (DNN) is an artificial neural network that is built to simulate the human brain function. Deep Neural Network consisting of an input layer, an output layer, and there is more than one hidden layer between the input layer and the output layer in order to process the complex features. An important part of this neural network is to deal with labeled and unstructured data. There are many deep architectures based on deep learning principles including Deep Neural Networks (DNN), Convolutional Neural Networks (CNN) that are popular with computer vision, Deep Belief Networks (DBN) and Recurrent Neural Network (RNN), which are used in Speech recognition Natural language processing, and bioinformatics. Deep Neural Network architecture used in this paper is shown in Figure 1.

### B. Proposed Method

In this research, we adopt a Deep Neural Network to identify some types of odor. The learning process of the proposed model begins with splitting the training set and the test set with the test size of 0.3 and training the model according to architecture in Figure 1. The proposed Deep Neural Network architecture consists of 7 input neurons in the input layer, 4 output neurons in the output layer and 5 hidden layers. The first hidden layer consists of 128 neurons. The second hidden layer consists of 64 neurons. The third hidden consists of 32 neurons. The fourth hidden layer consists of 16 neurons. The last hidden layer consists of 8 neurons as shown in Figure 1.

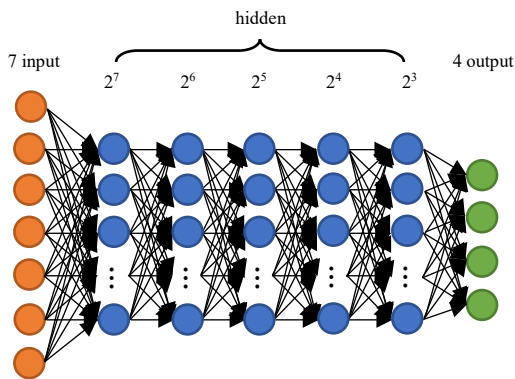


Figure 1. The deep neural network diagram that we propose.

## III. EXPERIMENTAL RESULTS

### A. Dataset

The dataset contains 4 types of odors that are collected from the electronic nose. These types of

odors include odorless, beer odor, whisky odor, and wine odor. Each type of odor contains 60 instances with 7 attributes measured from 7 sensors of an electronic nose. The sensor name of the electronic nose includes TGS826, TGS832, TGS2600, TGS2602, TGS2610, TGS2444 and TGS4161.

TABLE I. SENSOR DETAILS.

Sensor Name	Target Gas
TGS826	Ammonia
TGS832	Chlorofluorocarbon (CFC) or Halocarbon gases
TGS2600	Air contaminants
TGS2602	Air Quality / VOC Sensor (Hydrogen sulfide, Ethanol)
TGS2610	LP Gas (butane, Propane)
TGS2444	Ammonia
TGS4161	Carbon dioxide

### B. Experimental Results

In the experiments, the Deep Neural Network model consists of 5 hidden layers and each layer consists of 128, 64, 32, 16, and 8 neurons respectively. The learning rate is set as 0.001 and the number of epochs is set as 1,000. The MLP architecture consists of 1 hidden layer with 512 neurons and the learning rate is set as 0.0001. Decision Tree and Naïve Bayes. The experiments are conducted 10 times. When we consider only the maximum accuracy selected from 10 experiments, we found that all machine learning models can achieve the best accuracy of 100% as shown in Figure 2-5. Figure 2 shows the confusion matrix of DNN model with the highest accuracy of 100%, Figure 3 shows the confusion matrix of MLP model with the highest accuracy 100%, Figure 4 shows the confusion matrix of decision tree model with the highest accuracy of 100%, and Figure 5 shows the confusion matrix of the Naïve Bayes model that can produce the highest accuracy of 100%.

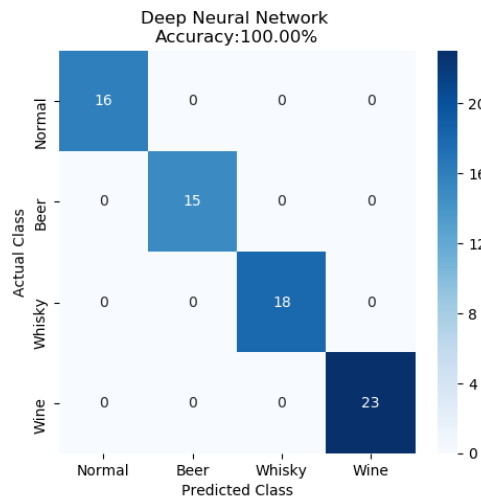


Figure 2. The confusion matrix and the accurate prediction of the Deep Neural Network model

TABLE II. EXAMPLES OF INSTANCES IN DATASET.

Class	Attributes						
	TGS826	TGS832	TGS2600	TGS2602	TGS2610	TGS2444	TGS4161
Odorless	66	178	153	220	121	180	320
	65	176	152	220	122	177	317
	64	177	151	219	121	173	316
Beer	104	208	192	250	131	192	242
	99	207	193	250	131	193	241
	98	206	190	248	131	190	240
Whisky	131	238	220	272	133	215	269
	134	239	220	272	132	218	271
	135	240	224	274	132	220	271
Wine	105	210	215	255	135	184	227
	99	210	209	251	133	179	224
	93	206	207	251	134	176	225

Table II shows an example of the dataset used for classification. The values in each attribute come from each sensor of the electronic nose in Table I.

All values in all conclusion matrix are calculated from the test set.

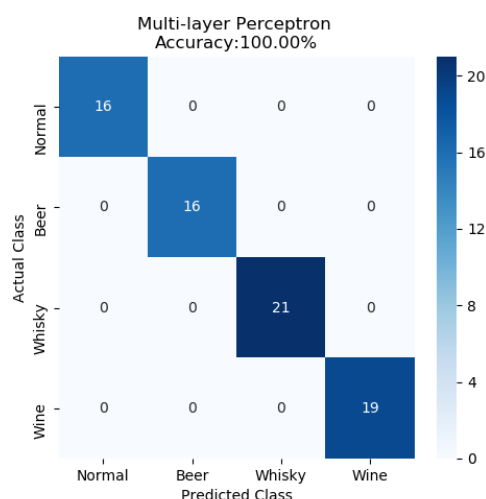


Figure 3. The confusion matrix and the accurate prediction of Multilayer Perceptron model.

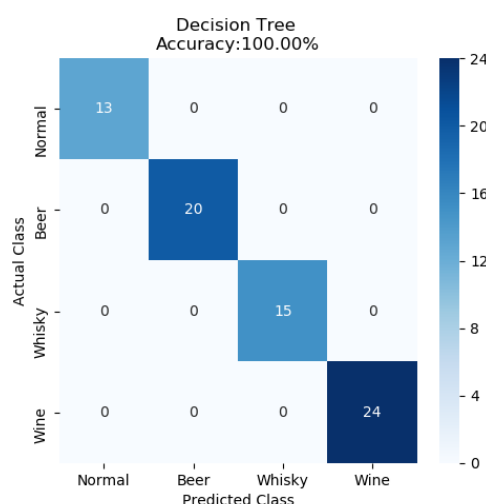


Figure 4. The confusion matrix and the accurate prediction of Decision Tree model.

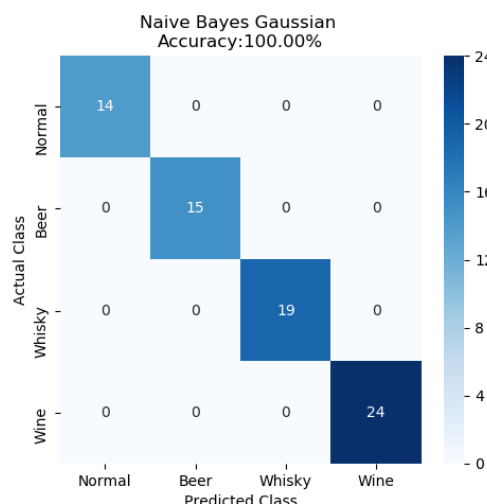


Figure 5. The confusion matrix and the accurate prediction of Naive Bayes model.

Although the DNN model, MLP model, Decision Tree model, and Naïve Bayes model can give the highest accuracy results up to 100%, but when the accuracies of 10 times are average, the proposed DNN model can achieve the best average accuracy as shown in Table I. From the experimental results in Table I, the average accuracy of DNN is 99.26%, which is the highest accuracy comparing to other models. In addition, DNN has a standard deviation of 0.64% that is less than other models. From the performance comparison, Deep Neural Network gives more accurate predictions than Multilayer Perceptron, Decision Tree and Naïve Bayes.

TABLE III. THE COMPARISON OF PERFORMANCE PREDICTIONS OF ODORS WITH VARIOUS MODELS.

Model	Mean	S.D.	Max	Min
<b>DNN</b>	<b>99.26%</b>	<b>0.64%</b>	100.00%	<b>98.77%</b>
<b>MLP</b>	99.01%	1.27%	100.00%	96.30%
<b>Tree</b>	97.90%	1.65%	100.00%	95.06%
<b>NB</b>	95.43%	2.54%	100.00%	92.59%

#### IV. CONCLUSION

In this paper, Deep Neural Network is applied for odor classification from an electronic nose that is like a human nose in order to protect human life and health from the dangerous order. The dataset used in the experiments consists of 240 instances with 7 attributes collecting from an electronic nose. The experiments are conducted 10 times and the results are average to evaluate the performance of the proposed model. From the experimental results, the proposed Deep Neural Network model can achieve the highest average accuracy when compared to other comparative models. Therefore, Deep Neural Network can be applied for detecting the odor from an electronic nose in order to recognize the types of odor.

#### ACKNOWLEDGMENT

This research has been funded by the Industrial Estate Authority of Thailand (IEAT) for the development of the odor and VOCs monitoring system with an electronic-nose network. We also thank B.Eng. students, Thanakorn Srisuwan and Suriya Thammachat, from the College of Nanotechnology KMITL for assisting the data collection from the electronic nose.

#### REFERENCES

- [1] Chomtip Pornpanomchai and Piyorot Khongchuay, "Chemical substance classification by electronic noses," 2009 2nd IEEE International Conference on Computer Science and Information Technology, pp. 68–72, 2009.
- [2] Francesca Arcelli Fontana, Marco Zanoni, Alessandro Marino, and Mika V. Mäntylä, "Code Smell Detection: Towards a Machine Learning-Based Approach," 2013 IEEE International Conference on Software Maintenance, pp. 396–399, 2013.
- [3] Salahedin Sadeghifard and Leili Esmailani, "A New Embedded E-Nose System to Identify Smell of Smoke," 2012 7th International Conference on System of Systems Engineering (SoSE), 2012.
- [4] Khalid Alkharabsheh, Jose A. Taboada, Yania Crespo, and Tareq Alzu'bi, "Improving Design Smell Detection for Adoption in Industry," 2018 8th International Conference on Computer Science and Information Technology (CSIT), pp. 213–218, 2018.
- [5] Pei-Feng Qi, Qing-Hao Meng, and Ming Zeng, "A CNN-based simplified data processing method for electronic noses," 2017 ISOCs/IEEE International Symposium on Olfaction and Electronic Nose (ISOEN), 2017.
- [6] Bipan Tudu, Bikram Know, Nabarun Bhattacharyya, and Rajib Bandyopadhyay, "Comparison of Multivariate Normalization Techniques as Applied to Electronic Nose Based Pattern Classification for Black Tea," 2008 3rd International Conference on Sensing Technology, pp. 254–258, 2008.
- [7] Nakarin Maneerat and Pomsiri Muenchaisri, "Bad-smell prediction from software design model using machine learning techniques," 2011 Eighth International Joint Conference on Computer Science and Software Engineering (JCSSE), pp. 331–336, 2011.
- [8] Chomtip Pornpanomchai and Natt Suthamsmai, "Beer classification by electronic nose," 2008 International Conference on Wavelet Analysis and Pattern Recognition, pp. 333–338, 2008.
- [9] Md. Mizanur Rahman, Chalie Charoenlarnopparut, and Prapun Suksompong, "Classification and pattern recognition algorithms applied to E-Nose," 2015 2nd International Conference on Electrical Information and Communication Technologies (EICT), pp. 44–48, 2015.

ภาคผนวก ข  
งานวิจัยที่ตีพิมพ์ 2



# PROCEEDINGS

9TH IEEE INTERNATIONAL CONFERENCE ON CONTROL SYSTEM,  
COMPUTING AND ENGINEERING (ICCSCE 2019)

PARK ROYAL Penang Resort Batu Ferringhi, Penang Malaysia

29 Nov 2019 – 1 Dec 2019

## Secretariat:

Mohd Nasir Taib  
Zakaria Hussain  
Saiful Zaimy Yahaya  
Norhazimi Hamzah  
Rozan Boudville  
Ramli Adnan  
Siti Noraini Sulaiman  
Nooritawati Md. Tahir  
Muhammad Khusairi Osman  
Abdul Rahim Ahmad  
Khairul Azman Ahmad

## CONTACT INFORMATION:

ICCSCE 2019 SECRETARIAT  
C/O: SAIFUL ZAIMY YAHAYA  
FACULTY OF ELECTRICAL ENGINEERING  
UNIVERSITI TEKNOLOGI MARA  
13500 PERMATANG PAUH  
PULAU PINANG  
MALAYSIA



**SECRETARIAT AT:**  
FACULTY OF ELECTRICAL ENGINEERING,  
UITM SHAH ALAM

FACULTY OF ELECTRICAL ENGINEERING,  
UITM PULAU PINANG

**ORGANIZER:**  
IEEE Control System Society  
Chapter Malaysia

**EMAIL:**  
szaimy79@gmail.com  
adnanramli@yahoo.com  
**TEL:** 603-55435012  
**FAX:** 603-55435077

# A Hybrid of Shallow and Deep Learning for Odor Classification Based on Adaptive Boosting

Boonyawee Grodnyiomchai

Department of Computer Science, Faculty of Science,  
King Mongkut's Institute of Technology Ladkrabang,  
Bangkok, Thailand 10520  
boonyawee\_4449@hotmail.com

Kulsawasd Jitkajornwanich

Department of Computer Science, Faculty of Science,  
King Mongkut's Institute of Technology Ladkrabang,  
Bangkok, Thailand 10520  
kulsawasd.ji@kmitl.ac.th

Khattiya Chalapat

College of Nanotechnology, King Mongkut's Institute of  
Technology Ladkrabang, Bangkok, Thailand 10520  
kchalapat@gmail.com

Saichon Jaiyen

Department of Computer Science, Faculty of Science,  
King Mongkut's Institute of Technology Ladkrabang,  
Bangkok, Thailand 10520  
saichon.ja@kmitl.ac.th

**Abstract**— An electronic nose is very useful for identifying an odor that is harmful to humans. To get the most accurate odor predictions from an electronic nose, we combined the models of traditional machine learning and deep learning, including deep neural network (DNN), support vector machine (SVM) and decision tree, to make a new hybrid model that adopts the AdaBoost algorithm to adjust the weights of weak classifiers to build a strong classifier using odor data. Experimental results from our model were compared with other models, including a single deep neural network, an ensemble of SVM models and an ensemble of decision trees. Our model achieved an averaged accuracy of 99.58%, which is better than other models, and the standard deviation, 0.67%, is also less than other models.

**Keywords**— ensemble learning; deep neural network; odor classification, electronic nose; artificial intelligence; machine learning

## I. INTRODUCTION

Detecting odors with an electronic nose is a challenging problem, especially when the odor are dangerous to human. However, we need to develop machine learning algorithms, that can detect odors with high accuracy. Many machine learning algorithms have been applied to detect odors from electronic nose signals. However, these algorithms used shallow machine learning and were appropriate for only a few types of odor. If we need to detect a large range of odors, deep learning algorithms should be applied.

Gültekin and Uğur adopted ensemble learning for preventing the overfitting with small data sets. A new dynamic ensemble algorithm was described and it was able to achieve the 77.3% accuracy [1]. Ozaki and Hono used an ensemble method with SVM classifiers to improve texture classification, using a Bagging technique as the voting method. Accuracies of their method were compared to the single SVM (86.8%), SVM with cross-validation (86.0%) and a k-NN classifier (84.7%) found to be the best [2]. Gan and Xiao used an improved AdaBoosting algorithm, using the cloud model concept, called Cloud-AdaBoosting, and applied similar training set filling techniques, through the exact calculation of each test sample associated with the neural network. The prediction error between Cloud-AdaBoosting and AdaBoosting are similar, within 0.02% [3]. Li et al. used

a multi-model ensemble to predict the concentration of PM2.5 using wavelet theory and a neural network, called wavelet neural network. They compared its performance with a BP neural network, RBF neural network, Elman neural network and TS fuzzy neural network. They showed that the prediction accuracy for PM2.5 by using wavelet neural network was better than other models [4]. Chen et al. applied the ensemble method to develop algorithms to predict precise traffic flow under abnormal conditions. They used four different model structures in ensemble and compared them to support vector regression, random forests and gradient boosting regression trees (GBRT). The model they used was the combination of GBRT and Lasso [5]. Li et al. presented a multi-view based AdaBoost classifier ensemble framework (MV-ACE) to predict the class of gene expression data sets. They applied a random view generation technique to control different perspectives, with AdaBoost to adjust the training set. In addition, they explored the possible combination of views through the optimization process. By using 12 cancer gene combinations for classification, their model worked well with the cancer gene expression profiles of a variety of cancer genes and achieved better performance than other ensemble classifiers [6]. Su et al. created a model to determine whether there is a tax hold in advance or avoid tax arrears in the organization by using a Multi-Layer Perceptron Model (MLP), k-Nearest Neighbor (KNN), Random Forest (RF), Extremely Randomized Trees (ET), Gradient Tree Boosting (GTB) and Extreme Gradient Boosting (XGBoost). The experiment were performed on three datasets, with the first dataset having high accuracy in the proposed model of 87.4%, the second dataset having high accuracy in the model presented of 89.3%, but the third dataset returning a Random Forest with a maximum accuracy of 90.6%, which is 0.06% more than the proposed model [7]. Zhang et al. designed a new method of vehicle manufacturer recognition (VMR), that combined clear visual detection and their Autoencoder Pre-trained Deep Neural Network (AP-DNN) together. AP-DNN is an autoencoder for unsupervised pre-training, reducing the length of time for weight and bias adjustment due to the complexity of the deep neural network. They tested 2,000 images of vehicles for 10 different types of manufacturers and achieved a VMR rate of 97.9% [8]. Zhou et al. handled challenging problems by tracking objects in complex areas

with a variety of views. Using a combination of deep learning architecture and an on-line AdaBoost framework, DNN classifiers were updated on-line to completely separate targets from the background, which was improved on other models [9]. Shahin et al. Developed an effective automated framework by using an ensemble that combined the ResNet-50 architecture and Inception V3 together to classify seven types of skin lesions and achieved an accuracy up to 89.9% higher than Standalone ResNet-50 and Standalone Inception V3 methods [10]. Rijal et al. developed the PM2.5 concentrations predicted from the 1,460 images dataset by combining three CNN models, VGG-16, Inception-v3, and ResNet50 being used as base learners and constructed 5-layer feed forward neural network at Built to use as a meta learner in the ensemble. The method that uses forward-forward neural network can combine predictions from basic learners and get more accurate predictions than CNN for each model used. With Root Mean Square Error (RMSE) of 49.4%, the method works better than VGG-16, Inception-v3, ResNet50, Mean Arithmetic, Geometric Mean, and Linear Regression models [11]. Huang et al. proposed the image retrieval using two CNN models, namely AlexNet and Network In Network (NIN), in order to obtain image properties and weighted average vector calculations. Features for pulling images together are all learning sets. Normal image classification gives a cumulative accuracy of 90.2% from the CIFAR-10 dataset and 67.3% in the CIFAR-100 dataset. CIFAR-100 is better guaranteed than the AlexNet model that has 79.1% in first dataset and 44% in the second dataset. In the same, compared with NIN model that received 86.5% in first dataset and 57.7% in second dataset [12].

Recent researches that we studied, to get better predictive performance of the model, require Ensemble Learning technique to adjust weights and errors, repeating and recalculating until a good accuracy is reached.

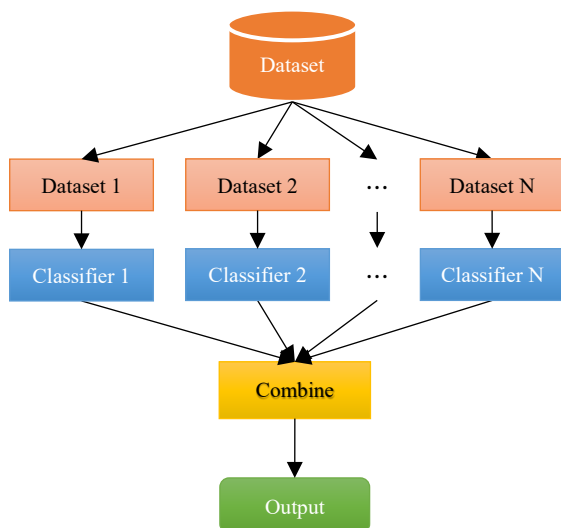


Fig. 1. Ensemble learning diagram

Ensemble learning [13] is a technique used to develop a model based on multiple models to enhance the prediction accuracy. In ensemble learning, many weak classifiers are combined to create a strong classifier. The dataset used to train each weak classifier is generated from the original dataset by bootstrapping. Eventually, outputs from weak classifiers are combined to produce a final output. There are several methods for combining the outputs from weak

classifiers such as Bagging, Boosting, Voting and Stacking techniques.

Here, we used Boosting to increase the efficiency of sequential learning technique.

Adaptive Boosting [14-17], also known as AdaBoost, is a boosting technique designed to solve low-precision problems by changing weak learners into strong learners, which has the basic structure from the decision tree model. But, the dataset used for training has been continuously adapted to force the model to focus on samples that are not classified. In some cases, it may cause overfitting than other learning algorithms, because AdaBoost is sensitive to noisy data and outliers. Each learner may be weak, if each one slightly is better than random guessing. The final model can be becomes a strong learner, combining the weak learners.

We combined shallow and deep machine learning models, using Deep Neural Network (DNN), Support Vector Machine (SVM) and Decision Trees together to enhance the prediction accuracy of odor classification from electronic nose signals.

## II. METHODOLOGY

### A. Dataset

The dataset used in this study was collected from an electronic nose with 7 sensors. The odor dataset contained 60 instances with 7 attributes. There were 4 types of odors including odorless, beer, wine and whisky odor.

The seven sensors are described and detailed in Table I.

TABLE I. SENSOR DETAILS

Sensor name	Sensor can measure	
	Volatile substances	Concentration (ppm)
TGS826	Ethanol, Ammonia and Isobutane	30 – 300
TGS832	Chlorofluorocarbon (CFC) or Halocarbon gases and Ethanol	10 – 3000
TGS2600	Hydrogen, Ethanol, Isobutane, Carbon Monoxide and Methane	1 – 100
TGS2602	Toluene, Hydrogen sulfide, Ethanol, Ammonia and Hydrogen	1 – 30
TGS2610	Isobutane, Methane, Hydrogen and Ethanol	300 – 10000
TGS2444	Ammonia, Hydrogen sulfide and Ethanol	10 – 300
TGS4161	Carbon dioxide	500 – 50000

From Table I, it can be seen that the sensor is used for detecting alcohol odor. It is the data used in the electronic nose network for odor and volatile substances monitoring, which is the abnormal or dangerous odor. But there is only a TGS4161 sensor that is not relevant to other sensors. It is a sensor that provides data about general environmental conditions in the area which normally has carbon dioxide everywhere.

Table II show an example of 60 instances from each odor that we used as a dataset, where the number represents the digital output value, according to the severity of the odor that the sensor can detect.

TABLE II. AN EXAMPLE OF INSTANCES IN DATASET

Class	Attributes						
	TGS826	TGS832	TGS2600	TGS2602	TGS2610	TGS2444	TGS4161
Odorless	92	228	272	306	149	468	257
	81	215	231	284	143	412	265
	78	209	210	274	138	369	275
	76	206	200	267	135	335	284
	75	202	191	263	134	312	291
Beer	111	211	206	256	134	204	239
	108	214	201	254	133	201	240
	104	208	192	250	131	192	242
	99	207	193	250	131	193	241
	98	206	190	248	131	190	240
Whisky	92	219	171	246	119	179	284
	91	219	171	246	117	181	284
	109	227	192	256	125	191	273
	112	229	193	259	126	195	273
	122	231	202	262	126	201	274
Wine	123	222	233	264	139	205	225
	115	217	220	258	137	194	224
	105	210	215	255	135	184	227
	99	210	209	251	133	179	224
	93	206	207	251	134	176	225

### B. Our Hybrid Method

In our study, a comparison of machine learning models that classify the types of odor. From the experiment of the efficiency, average accuracy of each model 10 times. Found that the most efficient models are Deep Neural Network (DNN), Support Vector Machine (SVM) and Decision Tree. We developed a hybrid classifier, which combined shallow machine learning and deep learning models. We studied the performance of the combination of a deep learning model which is a Deep Neural Network and two shallow models which are Support Vector Machine and Decision Tree models. In addition, we adopted the AdaBoost algorithm to combine these classifiers to generate the final output. The proposed model is demonstrated in Figure 2 and the details of the proposed method can be described in Algorithm 1, where  $\alpha$  is defined as the weight for weak classifier,  $\delta$  is defined as the function,  $\varepsilon$  is defined as the weighted error and  $y_j$  is defined as the output class.

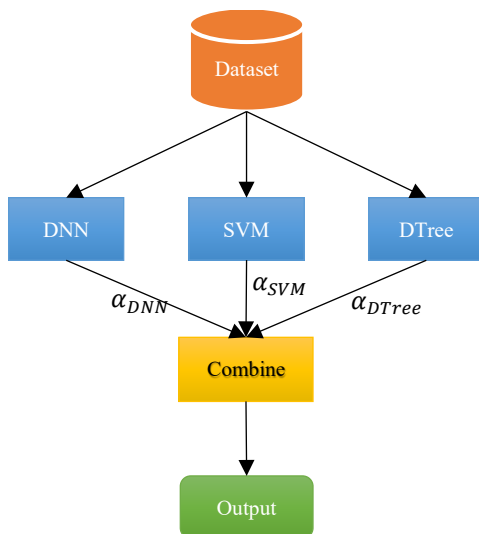


Fig. 2. The proposed model which is the combination of deep neural network, support vector machine and decision tree.

### Algorithm 1: DNN-SVM-Tree AdaBoost Algorithm

1. Set the initial weight of each sample as  $\frac{1}{N}$ .
2. Let  $k$  be the number of boosting rounds.
3. **for**  $i = 1$  to  $k$  **do**
4. Train a base classifier  $C_i$  on  $D$   
Train Deep Neural Network model (DNN) or  $C_1$  with all samples in the original training set
5. Apply  $C_1$  to all examples in the original training set,  $D$ .
6.  $\varepsilon_i = \frac{1}{N} \left[ \sum_j w_j \cdot \delta \left( C_i(x_j) \neq y_j \right) \right]$  (2)  
{ Calculate the weighted error. }
7. **if**  $\varepsilon_i > 0.5$  **then**
8.  $w = \left\{ w_j = \frac{1}{N} \mid j = 1, 2, \dots, N \right\}$ . (3)  
{ Reset the weights for all  $N$  examples. }
9. Go back to Step 4.
10. **end if**
11.  $\alpha_i = \frac{1}{2} \ln \frac{1-\varepsilon_i}{\varepsilon_i}$ . (4)
12. Adjust the weights of samples and the weight of the current classifier using AdaBoost algorithm.
13. Repeat step 4 until 12 by changing the based classifier  $C_2$  to Support Vector Machine (SVM) model.
14. Repeat step 4 until 12 by changing the based classifier  $C_3$  to Decision Tree model.
15. **end for**
16.  $C^*(x) = \underset{y}{\operatorname{argmax}} \sum_{j=1}^T \alpha_j \delta(C_j(x) = y)$ . (5)  
{ Final Prediction }

## III. RESULTS

### A. Experimental Setup

In the dataset, we have divided them to 70% of training data and 30% of test set data. Our ensemble of the Deep Neural Network consisted of 7 input layers, 5 hidden layers (each hidden layer consisted of 128, 64, 32, 16 and 8 nodes) and 4 output layers. The activation function of the hidden layers was the Rectified Linear Unit (ReLU) function. The activation function of the output layers was softmax. The optimizer algorithm for adjusting weights was an Adam optimizer with an initial learning rate of 0.001 and the loss function was set as sparse categorical cross entropy. The batch size was set to 15 and the number of epochs set as 1000. For the ensemble of the Support Vector Machine, the kernel function was set as linear kernel and the number of classifiers as 600. Linear Kernel is a function that uses linear to divide data. For the ensemble of Decision Tree models, the number of classifiers was set to 600, random state was set to zero, max depth was set to 2 and learning rate was set to 1. The number of classifier selected is shown to be the most efficient for the model.

### B. Experimental Results

Our hybrid model of shallow and deep learning model was compared to a Deep Neural Network, an ensemble of SVM models and an ensemble of Decision Tree models using the same dataset, 10 times per model. From Table III, the average accuracy of our model was the highest at 99.58%

with standard deviation 0.67%, i.e. our model produced more consistent results. Further, our hybrid model produced better results on all metrics.

TABLE III. PERFORMANCE PREDICTIONS OF ODORS WITH VARIOUS MODELS

Round	Ensemble Model			
	Our Hybrid Model	DNN	SVM	Tree
1	100.00%	100.00%	98.61%	98.61%
2	100.00%	97.22%	95.83%	95.83%
3	100.00%	95.83%	98.61%	97.22%
4	100.00%	100.00%	100.00%	97.22%
5	100.00%	100.00%	97.22%	98.61%
6	98.61%	98.61%	97.22%	97.22%
7	98.61%	100.00%	98.61%	94.44%
8	100.00%	100.00%	97.22%	98.61%
9	100.00%	98.61%	83.33%	97.22%
10	98.61%	100.00%	98.61%	100.00%
Mean	<b>99.58%</b>	99.03%	96.53%	97.50%
S.D.	<b>0.67%</b>	1.47%	4.78%	1.58%
Max	100.00%	100.0%	100.00%	100.00%
Min	<b>98.61%</b>	95.83%	83.33%	94.44%

Table IV-XIII compares the  $F_1$  scores in each round.

 TABLE IV. COMPARISON OF PERFORMANCE PREDICTIONS OF  $F_1$  SCORE WITH VARIOUS MODELS IN ROUND 1.

Class	F <sub>1</sub> Score Round 1			
	Proposed Model	DNN	SVM	Tree
Odorless	1.00	1.00	0.98	0.98
Beer	1.00	1.00	0.97	1.00
Whisky	1.00	1.00	1.00	0.97
Wine	1.00	1.00	1.00	1.00

 TABLE V. COMPARISON OF PERFORMANCE PREDICTIONS OF  $F_1$  SCORE WITH VARIOUS MODELS IN ROUND 2.

Class	F <sub>1</sub> Score Round 2			
	Proposed Model	DNN	SVM	Tree
Odorless	1.00	0.93	0.92	0.92
Beer	1.00	1.00	0.97	0.97
Whisky	1.00	0.94	0.94	0.95
Wine	1.00	1.00	1.00	1.00

 TABLE VI. COMPARISON OF PERFORMANCE PREDICTIONS OF  $F_1$  SCORE WITH VARIOUS MODELS IN ROUND 3.

Class	F <sub>1</sub> Score Round 3			
	Proposed Model	DNN	SVM	Tree
Odorless	1.00	0.91	0.97	0.95
Beer	1.00	1.00	1.00	0.97
Whisky	1.00	0.93	0.97	0.97
Wine	1.00	1.00	1.00	1.00

 TABLE VII. COMPARISON OF PERFORMANCE PREDICTIONS OF  $F_1$  SCORE WITH VARIOUS MODELS IN ROUND 4.

Class	F <sub>1</sub> Score Round 4			
	Proposed Model	DNN	SVM	Tree
Odorless	1.00	1.00	1.00	0.95
Beer	1.00	1.00	1.00	0.97
Whisky	1.00	1.00	1.00	0.98
Wine	1.00	1.00	1.00	1.00

 TABLE VIII. COMPARISON OF PERFORMANCE PREDICTIONS OF  $F_1$  SCORE WITH VARIOUS MODELS IN ROUND 5.

Class	F <sub>1</sub> Score Round 5			
	Proposed Model	DNN	SVM	Tree
Odorless	1.00	1.00	0.94	0.98
Beer	1.00	1.00	0.97	0.97
Whisky	1.00	1.00	0.97	1.00
Wine	1.00	1.00	1.00	1.00

 TABLE IX. COMPARISON OF PERFORMANCE PREDICTIONS OF  $F_1$  SCORE WITH VARIOUS MODELS IN ROUND 6.

Class	F <sub>1</sub> Score Round 6			
	Proposed Model	DNN	SVM	Tree
Odorless	0.96	0.97	0.95	0.94
Beer	1.00	1.00	0.94	0.97
Whisky	0.97	0.97	1.00	0.98
Wine	1.00	1.00	1.00	1.00

 TABLE X. COMPARISON OF PERFORMANCE PREDICTIONS OF  $F_1$  SCORE WITH VARIOUS MODELS IN ROUND 7.

Class	F <sub>1</sub> Score Round 7			
	Proposed Model	DNN	SVM	Tree
Odorless	0.97	1.00	0.98	0.91
Beer	1.00	1.00	0.97	1.00
Whisky	0.97	1.00	1.00	0.89
Wine	1.00	1.00	1.00	1.00

 TABLE XI. COMPARISON OF PERFORMANCE PREDICTIONS OF  $F_1$  SCORE WITH VARIOUS MODELS IN ROUND 8.

Class	F <sub>1</sub> Score Round 8			
	Proposed Model	DNN	SVM	Tree
Odorless	1.00	1.00	0.94	0.97
Beer	1.00	1.00	1.00	0.97
Whisky	1.00	1.00	0.94	1.00
Wine	1.00	1.00	1.00	1.00

 TABLE XII. COMPARISON OF PERFORMANCE PREDICTIONS OF  $F_1$  SCORE WITH VARIOUS MODELS IN ROUND 9.

Class	F <sub>1</sub> Score Round 9			
	Proposed Model	DNN	SVM	Tree
Odorless	1.00	0.97	0.98	0.96
Beer	1.00	1.00	0.73	1.00
Whisky	1.00	0.97	0.97	0.94
Wine	1.00	1.00	0.56	1.00

 TABLE XIII. COMPARISON OF PERFORMANCE PREDICTIONS OF  $F_1$  SCORE WITH VARIOUS MODELS IN ROUND 10.

Class	F <sub>1</sub> Score Round 10			
	Proposed Model	DNN	SVM	Tree
Odorless	0.97	1.00	0.96	1.00
Beer	1.00	1.00	1.00	1.00
Whisky	0.97	1.00	0.97	1.00
Wine	1.00	1.00	1.00	1.00

$F_1$  score is the average value of precision and recall measuring the ability of the model.

$$F_1 \text{ score} = 2 \cdot \frac{\text{precision} \times \text{recall}}{\text{precision} + \text{recall}} \quad (6)$$

From the experiments, it is observed that the  $F_1$  score in the proposed model has many values of 1.00. This means that it gives better predictability than ensemble model that we compared.

#### IV. CONCLUSION

In this paper, we described the hybrid model of shallow and deep learning models in order to enhance the prediction accuracy. The dataset used was collected from the electronic nose with 7 sensors. We performed the experiments 10 times and then compared the performance of the proposed model to other models. Our model with a hybrid of Deep Neural Network, Support Vector Machine and Decision Tree achieved an accuracy of 99.58% with standard deviation 0.67% compared to other models. Also, the  $F_1$  score in our hybrid proposed has many values of 1.00. This means that it gives better predictability than other models.

In our experiment, if there is the dataset of the type of odor and the number of sensors more than, this will help to increase the efficiency of odor and volatile substances monitoring even more.

#### ACKNOWLEDGMENT

This research has been funded by the Industrial Estate Authority of Thailand (IEAT) for the development of the odor and VOCs monitoring system with an electronic-nose network. We also thank Bachelor of Engineering students, Thanakorn Srisuwan and Suriya Thammachat, from the College of Nanotechnology KMITL for assisting in data collection from the electronic nose. And we also thank Mr. John Morris from KMITL Research and Innovation Services (KRIS) for consulting in writing this research.

#### REFERENCES

- [1] Tunç Gültekin and Aybars Uğur, "An Iterative Dynamic Ensemble Weighting Approach for Deep Learning Applications," *2017 International Artificial Intelligence and Data Processing Symposium (IDAP)*, pp. 1–4, 2017.
- [2] Srisupang Thewsuan Nanto Ozaki and Keiichi Horio, "SVM Ensemble Approaches for Improving Texture Classification Performance Based on Complex Network Model with Spatial Information," *2018 International Workshop on Advanced Image Technology (IWAIT)*, pp. 1–3, 2018.
- [3] Zhigang Gan and Nanfeng Xiao, "An Improved Adaptive Boosting Algorithm for Neural Network Ensemble Based on Multi-dimensional Cloud Model," *2009 Second International Symposium on Knowledge Acquisition and Modeling*, pp. 170–173, 2009.
- [4] Tao Li, Xiang Li, Lina Wang, Yongjun Ren, Tingyu Zhang and Meichen Yu, "Multi-model Ensemble Forecast Method of PM<sub>2.5</sub> Concentration Based on Wavelet Neural Networks," *2018 1st International Cognitive Cities Conference (IC3)*, pp. 81–86, 2018.
- [5] Xiqun (Michael) Chen, Shuaichao Zhang and Li Li, "Multi-model ensemble for short-term traffic flow prediction under normal and abnormal conditions," *IET Intelligent Transport Systems*, 13(2), pp. 260–268, 2018.
- [6] Le Li, Zhiwen Yu, Jiming Liu, Jane You, Hau-San Wong and Guoqiang Han, "Multi-view Based AdaBoost Classifier Ensemble for Class Prediction from Gene Expression Profiles," *2014 22nd International Conference on Pattern Recognition*, pp. 178–183, 2014.
- [7] Anyan Su, Zhimin He, Junjian Su, Yan Zhou, Yun Fan and Yuan Kong, "Detection of Tax Arrears Based on Ensemble Learning Model," *2018 International Conference on Wavelet Analysis and Pattern Recognition (ICWAPR)*, pp. 270–274, 2018.
- [8] Jiang Zhang, Yao Zhao, Fuqiang Zhou and Ming Chi, "Visual saliency-based vehicle manufacturer recognition using autoencoder pre-training deep neural networks," *2017 IEEE International Conference on Imaging Systems and Techniques (IST)*, pp. 1–6, 2017.
- [9] Xiangzeng Zhou, Lei Xie, Peng Zhang and Yanning Zhang, "An Ensemble of Deep Neural Networks for Object Tracking," *2014 IEEE International Conference on Image Processing (ICIP)*, pp. 843–847, 2014.
- [10] Ahmed H. Shahin, Ahmed Kamal and Mustafa A. Elattar, "Deep Ensemble Learning for Skin Lesion Classification from Dermoscopic Images," *2018 9th Cairo International Biomedical Engineering Conference (CIBEC)*, pp. 150–153, 2018.
- [11] Nabin Rijal, Ravi Teja Gutta, Tingting Cao, Jerry Lin, Qirong Bo and Jing Zhang, "Ensemble of Deep Neural Networks for Estimating Particulate Matter from Images," *2018 3rd IEEE International Conference on Image, Vision and Computing*, pp. 733–738, 2018.
- [12] Hsin-Kai Huang, Chien-Fang Chiu, Chien-Hao Kuo, Yu-Chi Wu, Narisa N.Y. Chu and Pao-Chi Chang, "Mixture of Deep CNN-based Ensemble Model for Image Retrieval," *2016 IEEE 5th Global Conference on Consumer Electronics*, 2016.
- [13] Giuseppe Bonaccorso. (2017). *Machine Learning Algorithm*. Birmingham: Packt. pp. 167–171.
- [14] Jinde Shubham. (2018). *Ensemble Learning — Bagging and Boosting*. June 8, 2019, from becominghuman.ai Web site: <https://becominghuman.ai/ensemble-learning-bagging-and-boosting-d20f38be9b1e>
- [15] SauceCat. (2017). *Boosting algorithm: AdaBoost*. June 8, 2019, from towardsdatascience Web site: <https://towardsdatascience.com/boosting-algorithm-adaboost-b6737a9e60c>
- [16] Avinash Navlani (2018). *AdaBoost Classifier in Python*. June 8, 2019, from DataCamp Web site: <https://www.datacamp.com/community/tutorials/adaboost-classifier-python>
- [17] SeattleDataGuy (2017). *Boosting and Bagging: How To Develop A Robust Machine Learning Algorithm*. June 8, 2019, from HACKERNOON Web site: <https://hackernoon.com/how-to-develop-a-robust-algorithm-c38e08f32201>

## ประวัติผู้เขียน

ชื่อ	นายบุญยวีร์ กรดนิยมชัย
วัน เดือน ปีเกิด	8 ตุลาคม 2536
ที่อยู่ปัจจุบัน	27 ซอยแก้วเงินทอง 41 แขวงคลองซั๊กพระ เขตตลิ่งชัน กรุงเทพมหานคร 10170
ประวัติการศึกษา	(2558) วิทยาศาสตรบัณฑิต สาขาวิทยาการคอมพิวเตอร์ เกรดเฉลี่ย 2.72 (สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง) (2562) วิทยาศาสตรมหาบัณฑิต สาขาวิทยาการคอมพิวเตอร์ เกรดเฉลี่ย 3.56 (สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง)
ผลงานทางวิชาการ	1. B. Grodnyomchai, K. Chalapat, K. Jitkajornwanich and S. Jaiyen, "A Deep Learning Model for Odor Classification Using Deep Neural Network," <i>2019 5th International Conference on Engineering, Applied Sciences and Technology (ICEAST)</i> , Luang Prabang, Laos, 2-5 July 2019, pp. 545-548. 2. B. Grodnyomchai, K. Chalapat, K. Jitkajornwanich and S. Jaiyen, "A Hybrid of Shallow and Deep Learning for Odor Classification Based on Adaptive Boosting," <i>2019 9th IEEE International Conference on Control System, Computing and Engineering (ICEAST)</i> , Penang, Malaysia, 29-30 November 2019, pp. 55-59.