

เทคนิครีโมทเซนซิงสำหรับการศึกษาป่าชายเลน: การจำแนกพันธุ์ไม้ป่าชายเลนเขตร้อนด้วยภาพถ่าย
ประสาทคอนโวลูชัน และการสร้างแบบจำลองมวลชีวภาพของต้นไม้ป่าชายเลนเขตร้อนด้วยเครื่อง
สแกนเลเซอร์ภาคพื้นดิน



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรดุษฎีบัณฑิต
สาขาวิชาวิศวกรรมสำรวจ ภาควิชาวิศวกรรมสำรวจ
คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย
ปีการศึกษา 2561
ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

Remote sensing technique for mangrove studies: Tropical mangrove species
classification with convolutional neural network and tropical mangrove tree biomass
modelling with terrestrial laser scanner



A Dissertation Submitted in Partial Fulfillment of the Requirements
for the Degree of Doctor of Philosophy in Geomatic Engineering

Department of Survey Engineering

Faculty of Engineering

Chulalongkorn University

Academic Year 2018

Copyright of Chulalongkorn University

หัวข้อวิทยานิพนธ์

เทคนิครีโมทเซนซิงสำหรับการศึกษาป่าชายเลน: การ
จำแนกพันธุ์ไม้ป่าชายเลนเขตร้อนด้วยภาพถ่ายระยะทางไกล
ชั้น และการสร้างแบบจำลองมวลชีวภาพของต้นไม้ป่าชาย
เลนเขตร้อนด้วยเครื่องสแกนเลเซอร์ภาคพื้นดิน

โดย

นายกฤษฎาณ อินทร์ตัน

สาขาวิชา

วิศวกรรมสำรวจ

อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก

อาจารย์ ดร.ชัยโชค ไวกาษา

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้บัณฑิตวิทยาลัยเป็นส่วนหนึ่ง
ของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรดุษฎีบัณฑิต

..... คณบดีคณะวิศวกรรมศาสตร์
(ศาสตราจารย์ ดร.สุพจน์ เตชวรสินสกุล)

คณะกรรมการสอบวิทยานิพนธ์

..... ประธานกรรมการ
(รองศาสตราจารย์ ดร.อิทธิ ตรีสิริสัตยวงศ์)

..... อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก
(อาจารย์ ดร.ชัยโชค ไวกาษา)

..... กรรมการ
(อาจารย์ ดร.จงทิศ ฉายากุล)

..... กรรมการ
(อาจารย์ ดร.ธีทัต เจริญกาลัญญาตา)

..... กรรมการภายนอกมหาวิทยาลัย
(อาจารย์ ดร.ณกร วัฒนกิจ)

กฤษฎาณ อินทร์ตัน : เทคนิครีโมทเซนซิงสำหรับการศึกษาป่าชายเลน: การจำแนกพันธุ์ไม้ป่าชายเลน
เขตร้อนด้วยภาพถ่ายประสาทคอนโวลูชัน และการสร้างแบบจำลองมวลชีวภาพของต้นไม้ป่าชายเลนเขต
ร้อนด้วยเครื่องสแกนเลเซอร์ภาคพื้นดิน. (Remote sensing technique for mangrove studies:
Tropical mangrove species classification with convolutional neural network and
tropical mangrove tree biomass modelling with terrestrial laser scanner) อ.ที่ปรึกษา
หลัก : อ. ดร.ชัยโชค ไวกาษา

งานวิจัยนี้ได้ศึกษาป่าชายเลนในสองประเด็น ประเด็นแรกคือ งานวิจัยที่ใช้ภาพถ่ายจากดาวเทียม
รายละเอียดสูงในการจำแนกพันธุ์ไม้ป่าชายเลนแสดงให้เห็นว่า วิธีการสกัดคุณลักษณะจากภาพประสบผลสำเร็จ
เป็นอย่างดี อย่างไรก็ตาม วิธีการดังกล่าวยังจำเป็นต้องอาศัยการตัดสินใจจากมนุษย์ วัตถุประสงค์ของประเด็น
วิจัยนี้มีเป้าหมายที่จะนำภาพถ่ายประสาทคอนโวลูชันซึ่งเป็นวิธีการด้านการเรียนรู้เครื่องมาใช้จำแนกพันธุ์ไม้ป่าชาย
เลนเขตร้อนร่วมกับภาพถ่ายจากดาวเทียม Quickbird เพื่อปรับปรุงวิธีการจำแนกให้มีความถูกต้องมากยิ่งขึ้น
สถาปัตยกรรม Compressed Fully Convolution Network (CFCN) เป็นวิธีการนำเสนอที่ใช้ในงานวิจัยนี้
ปรับปรุงจากโครงข่ายอ้างอิง FCN-8s ให้มีจำนวนพารามิเตอร์ที่ลดน้อยลง มีความเหมาะสมกับทรัพยากร
ประมวลผลที่จำกัด และมีค่าทดสอบทั้ง 6 ค่าไม่น้อยไปกว่าโครงข่ายอ้างอิง ผลการจำแนกจาก CFCN จะนำไป
เปรียบเทียบกับวิธีการจำแนกแบบความน่าจะเป็นสูงสุด ผลการจำแนกพบว่า วิธี CFCN ให้ความถูกต้องการ
จำแนกโดยรวมร้อยละ 90.36 มีค่าสูงกว่าวิธีการจำแนกแบบความน่าจะเป็นสูงสุดที่มีค่าความถูกต้องการจำแนก
โดยรวมเพียง 66.02 ผลการจำแนกยืนยันถึงความเป็นไปได้ของการนำภาพถ่ายประสาทคอนโวลูชันมาประยุกต์
ร่วมกับข้อมูลการสำรวจระยะไกลเพื่อการจำแนกพันธุ์ไม้ป่าชายเลนเขตร้อน

ประเด็นงานวิจัยที่สอง ใช้เครื่องสแกนเลเซอร์ภาคพื้นดินเก็บข้อมูลทางกายภาพของต้นแสมทะเลโดย
ไม่ตัดต้นไม้ มีวัตถุประสงค์เพื่อประมาณค่ามวลชีวภาพเหนือพื้นดินด้วยแบบจำลองโครงสร้างเชิงปริมาตร และ
สร้างเป็นแบบจำลองอัลโลเมตรีด้วยฟังก์ชันยกกำลัง ผลที่ได้ถูกนำมาเปรียบเทียบกับผลจากแบบจำลองอ้างอิง
ด้วยค่าคลาดเคลื่อนกำลังสองเฉลี่ยรากที่สอง ค่าคลาดเคลื่อนมีค่าสูง (ร้อยละ 40 และ 35) เมื่อเปรียบเทียบ
ผลลัพธ์กับแบบจำลองอ้างอิงทั่วไป ในทางกลับกัน ค่าคลาดเคลื่อนมีค่าต่ำ (น้อยกว่าร้อยละ 20) เมื่อเปรียบเทียบ
ผลลัพธ์กับแบบจำลองที่สร้างขึ้นจากต้นแสมทะเลเช่นเดียวกับพื้นที่ศึกษา ผลการศึกษา แสดงให้เห็นว่า การสร้าง
แบบจำลองที่ระบุพันธุ์ไม้ให้ค่ามวลชีวภาพเหนือพื้นดินที่มีความถูกต้องมากกว่าไม่ระบุพันธุ์ไม้ วิธีการที่นำเสนอ
สามารถนำไปใช้ประยุกต์ให้เป็นวิธีการมาตรฐานสำหรับสร้างแบบจำลองอัลโลเมตรีของต้นแสมทะเลในพื้นที่อื่น
จากแนวคิดดังกล่าว ผู้วิจัยเสนอให้สร้างแบบจำลองแบบระบุพันธุ์ไม้กับพืชชายเลนสายพันธุ์อื่น เพื่อยืนยันผลการ
ทดลองในครั้งนี้

สาขาวิชา วิศวกรรมสำรวจ

ลายมือชื่อนิติ

ปีการศึกษา 2561

ลายมือชื่อ อ.ที่ปรึกษาหลัก

5871411021 : MAJOR GEOMATIC ENGINEERING

KEYWORD:

Kritchayan Intarat : Remote sensing technique for mangrove studies: Tropical mangrove species classification with convolutional neural network and tropical mangrove tree biomass modelling with terrestrial laser scanner. Advisor: Chaichoke Vaiphasa, Ph.D.

This research can be split into two topics. The first topic is the use of hi-resolution satellite images Quickbird in combination with convolutional neural network for classifying tropical mangroves at the species levels. The chosen network architecture is compressed fully convolution network (CFCN) that is based on the popular FCN-8s reference network. It was found that the compressed network performs as good as the reference network during the training session. This claim is supported by the six testing parameters. Additionally, the classification capability of the proposed network was tested against the popular maximum likelihood classifier (MLC). The proposed method gained 90.36% of total classification accuracy while the MLC method got only 66.02%. The outcome indicates that the proposed method can be used for classifying tropical mangrove at the operational level.

The second topic proposes the non-destructive method, a terrestrial laser scanner (TLS), to collect the tree structure and generate the allometric tree model. The result was compared to the four reference models using the RMSE. The largest error (i.e., 40% and 35%) was found when comparing the presented model to the two generic allometric models. On the other hand, the outcomes of the species-specific models were closer to the outcome of this study (i.e., the RMSE errors are less than 20%). The discrepancy between the proposed TLS model and the generic mangrove model recommended that a species-specific model is demanded more accurate results. It is supposed that the methodology presented in this study may be utilized as standard procedures for producing the *A. marina* allometric model in other areas.

Field of Study: Geomatic Engineering

Student's Signature

Academic Year: 2018

Advisor's Signature

กิตติกรรมประกาศ

ขอขอบพระคุณ อาจารย์ ดร.ชัยโชค ไวกาษา อาจารย์ที่ปรึกษาวิทยานิพนธ์ ที่ให้โอกาสความรู้ และมุมมองแนวคิดด้านงานวิจัย รวมถึงการใช้ชีวิต ความเป็นอยู่ในสังคม ซึ่งมีคุณค่าต่อผู้วิจัยอย่างมาก

ขอบพระคุณ พ่อ แม่ และครอบครัวที่คอยสนับสนุนในทุกด้าน และให้อิสระในการตัดสินใจทุกอย่าง ทำให้ได้เรียนรู้การใช้ชีวิตได้อย่างเต็มที่ ขอขอบคุณ คุณอารีวรรณ หัสดิน และครอบครัว ที่แนะนำให้มาเรียน และสนับสนุนดูแลเป็นอย่างดี

ขอบพระคุณ รศ.ดร.อิทธิ ตรีสิริสัตยวงศ์ ประธานคณะกรรมการสอบวิทยานิพนธ์ อ.ดร.ธีทัต เจริญกาลัญญาตา อ.ดร.ธงทิศ ฉายากุล กรรมการสอบ และ อ.ดร.ณกร วัฒนกิจ กรรมการภายนอกมหาวิทยาลัย ที่กรุณาให้คำแนะนำ พร้อมทั้งแนวคิดที่ทำให้วิทยานิพนธ์ฉบับนี้มีความสมบูรณ์ ขอขอบพระคุณอาจารย์ทุกท่านในภาควิชาวิศวกรรมสำรวจ ที่ให้ความรู้อันมีคุณค่า

ขอบพระคุณสาขาวิชาภูมิศาสตร์ คณะศิลปศาสตร์ มหาวิทยาลัยธรรมศาสตร์ ที่สนับสนุนเรื่องการเรียน ขอขอบคุณหัวหน้าและเจ้าหน้าที่สถานีพัฒนาทรัพยากรป่าชายเลนที่ 44 และ 15 ที่อนุเคราะห์เรือ และกำลัง สำหรับเก็บข้อมูลภาคสนาม บริษัทที่อปคอนอินสทรูเมนต์ (ไทยแลนด์) ที่ให้การสนับสนุนเครื่องสแกนเลเซอร์ภาคพื้นดิน มูลนิธิสิ่งแวดล้อมศึกษาเพื่อการพัฒนาอย่างยั่งยืน (ประเทศไทย) ที่ให้ใช้พื้นที่ศึกษาที่บางปู

ขอบคุณเพื่อน พี่ น้อง Ph.D. Survivor และชาววิศวกรรมสำรวจ ทุกท่านที่เป็นกำลังใจ และเกื้อกูลกันในทุกด้าน ขอขอบคุณ Datamind Lab ที่ส่งน้องแก้วมาช่วยสร้างสถาปัตยกรรมดี ๆ สำหรับทำงาน

ขอบคุณน้องโมบายล์ พิมรภัส ผดุงวัฒนะโชค (Mobile BNK48) ที่ทำให้รู้ว่า ความพยายามไม่เคยทรยศใคร

กฤชญาณ อินทร์ตัน

สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ค
บทคัดย่อภาษาอังกฤษ.....	ง
กิตติกรรมประกาศ.....	จ
สารบัญ.....	ฉ
สารบัญตาราง.....	ญ
สารบัญภาพ.....	ฎ
บทที่ 1 บทนำ.....	1
1.1 ความเป็นมา และความสำคัญของปัญหา.....	1
1.2 วัตถุประสงค์ของงานวิจัย.....	6
1.3 สมมติฐานของงานวิจัย.....	6
1.4 ขอบเขตของงานวิจัย.....	6
1.5 ประโยชน์ที่คาดว่าจะได้รับ.....	7
บทที่ 2 ทฤษฎี และงานวิจัยที่เกี่ยวข้อง.....	8
2.1 ช่ายประสาทเทียม (Artificial neural network).....	8
2.1.1 สถาปัตยกรรมของชั้นช่ายประสาทเทียม.....	8
2.1.2 ช่ายประสาทเทียมแบบป้อนไปข้างหน้า.....	11
2.1.3 การแพร่กระจายย้อนกลับ (Back propagation).....	14
2.2 ช่ายประสาทคอนโวลูชัน (Convolution neural network: CNN).....	16
2.2.1 ชั้นคอนโวลูชัน (Convolutional layer).....	17
2.2.2 ชั้นพูลลิง (Pooling layer).....	19
2.2.3 ชั้นเชื่อมต่อแบบเต็มรูปแบบ (Fully connected layer).....	19

2.2.4	ชั้นทรานโพสคอนโวลูชัน (Transposed convolutional layer).....	20
2.2.5	การแพร่กระจายย้อนกลับและการสอน (Back propagation and training).....	21
2.3	การวัดประสิทธิภาพ	22
2.3.1	ความถูกต้องโดยรวม (Overall accuracy).....	22
2.3.2	ความถูกต้องของผู้ใช้ (User's Accuracy).....	23
2.3.3	ความถูกต้องของผู้ผลิต.....	23
2.3.4	ค่าสถิติโคเฮนส์ แคปปา (Cohen's Kappa).....	23
2.3.5	ค่าสถิติการทดสอบ Z.....	24
2.4	มวลชีวภาพเหนือพื้นดิน.....	24
2.4.1	การประมาณค่ามวลชีวภาพเหนือพื้นดิน	25
2.4.2	การสร้างความสัมพันธ์อัลโลเมตรี.....	26
2.4.3	การแพร่ของค่าคลาดเคลื่อน.....	26
2.5	การวัดค่าคลาดเคลื่อนของผลลัพธ์.....	27
2.6	ข้อมูลภาพถ่ายจากดาวเทียมที่ใช้ในการศึกษา.....	27
2.7	เครื่องสแกนเลเซอร์ภาคพื้นดิน	29
บทที่ 3	เอกสารงานวิจัยที่เกี่ยวข้อง.....	32
3.1	งานวิจัยที่เกี่ยวข้องกับการจำแนกภาพถ่ายจากดาวเทียมด้วยข่ายประสาทคอนโวลูชัน.....	32
3.2	งานวิจัยที่เกี่ยวข้องด้านการประมาณค่ามวลชีวภาพเหนือพื้นดิน	38
บทที่ 4	วิธีการดำเนินงานวิจัย.....	44
4.1	วิธีการจำแนกพันธุ์ไม้ป่าชายเลนเขตร้อนด้วยข่ายประสาทคอนโวลูชัน.....	44
4.1.1	พื้นที่ศึกษา	44
4.1.2	ข้อมูลที่ใช้ในงานวิจัย.....	45
4.1.3	ระบบที่ใช้ในงานวิจัย	46
4.1.4	การเตรียมข้อมูลภาพ และข้อมูลอ้างอิง.....	47

4.1.5	การทำ Normalization	48
4.1.6	การแปลงข้อมูลภาพให้อยู่ในรูปแบบ Numpy array	48
4.1.7	การสอน และการทดสอบ.....	49
4.1.8	การทดสอบความถูกต้องของการจำแนก	52
4.2	วิธีการสร้างแบบจำลองมวลชีวภาพของต้นไม้ป่าชายเลนเขตร้อนด้วยเครื่องสแกนเลเซอร์ ภาคพื้นดิน.....	54
4.2.1	พื้นที่ศึกษา	54
4.2.2	อุปกรณ์ที่ใช้ในงานวิจัย.....	55
4.2.3	การเก็บข้อมูลด้วยเครื่องสแกนเลเซอร์ภาคพื้นดิน	55
4.2.4	การหาปริมาตรของลำต้น และการประมาณค่ามวลชีวภาพ.....	60
4.2.5	การสร้างแบบจำลองมวลชีวภาพเหนือพื้นดินของต้นแสมทะเล	61
4.2.6	การประมาณค่าคลาดเคลื่อน.....	62
4.2.7	การตรวจสอบความถูกต้องแบบจำลองมวลชีวภาพเหนือพื้นดินต้นแสมทะเล	63
บทที่ 5	ผลการดำเนินงานวิจัย	64
5.1	ผลการจำแนกพันธุ์ไม้ป่าชายเลนเขตร้อนด้วยข่ายประสาทคอนโวลูชัน	64
5.1.1	ผลการสอน CNN และการทดสอบความถูกต้องของวิธีการนำเสนอ	64
5.1.2	ผลการจำแนกพันธุ์ไม้ป่าชายเลนเขตร้อน และการเปรียบเทียบผลการจำแนก.....	66
5.2	ผลการสร้างแบบจำลองมวลชีวภาพของต้นไม้ป่าชายเลนเขตร้อนด้วยเครื่องสแกนเลเซอร์ ภาคพื้นดิน.....	69
5.2.1	ผลการประมาณค่ามวลชีวภาพเหนือพื้นดินต้นแสมทะเล.....	69
5.2.2	ผลการประมาณการแพร่ค่าคลาดเคลื่อน	71
5.2.3	แบบจำลองมวลชีวภาพเหนือพื้นดินของต้นแสมทะเล.....	72
5.2.4	การตรวจสอบความถูกต้องมวลชีวภาพเหนือพื้นดินของต้นแสมทะเล.....	73
บทที่ 6	อภิปราย และสรุปผล	78

6.1	อภิปรายผลการจำแนกพันธุ์ไม้ป่าชายเลนเขตร้อนด้วยข่ายประสาทคอนโวลูชัน	78
6.1.1	การนำเสนอวิธีการ CFCN โดยลดพารามิเตอร์ของโครงข่ายต้นแบบ (FCN-8s)	78
6.1.2	การจำแนกข้อมูลภาพถ่ายจากดาวเทียมรายละเอียดสูงในระดับสายพันธุ์ด้วยข่าย ประสาทคอนโวลูชัน	80
6.1.3	ความถูกต้องจากการจำแนก CFCN และการจำแนกแบบความน่าจะเป็นสูงสุด	81
6.2	สรุปผลการจำแนกพันธุ์ไม้ป่าชายเลนเขตร้อนด้วยข่ายประสาทคอนโวลูชัน	84
6.3	ข้อเสนอแนะในการจำแนกพันธุ์ไม้ป่าชายเลนเขตร้อนด้วยข่ายประสาทคอนโวลูชัน	85
6.4	อภิปรายผลการสร้างแบบจำลองมวลชีวภาพเหนือพื้นดินของต้นไม้ป่าชายเลนเขตร้อนด้วย เครื่องสแกนเลเซอร์ภาคพื้นดิน	85
6.4.1	แบบจำลองวิธีการเก็บข้อมูลต้นแสมทะเล และการคำนวณปริมาตรลำต้น	85
6.4.2	การสร้างแบบจำลองมวลชีวภาพเหนือพื้นดินต้นแสมทะเล	86
6.4.3	การเปรียบเทียบมวลชีวภาพเหนือพื้นดินกับแบบจำลองมวลชีวภาพเหนือพื้นดินอ้างอิง ด้วย RMSE	87
6.4.4	อุปกรณ์เครื่องสแกนเลเซอร์สำหรับการเก็บข้อมูลในพื้นที่ที่เข้าถึงลำบาก	88
6.5	สรุปผลการสร้างแบบจำลองมวลชีวภาพเหนือพื้นดินของต้นไม้ป่าชายเลนเขตร้อนด้วยเครื่อง สแกนเลเซอร์ภาคพื้นดิน	89
6.6	ข้อเสนอแนะสำหรับการสร้างแบบจำลองมวลชีวภาพเหนือพื้นดินของต้นไม้ป่าชายเลนเขตร้อนด้วยเครื่อง สแกนเลเซอร์ภาคพื้นดิน	89
	บรรณานุกรม	91
	ประวัติผู้เขียน	104

สารบัญตาราง

	หน้า
ตารางที่ 2-1 ตารางการวัดค่าคลาดเคลื่อน (Confusion matrix).....	22
ตารางที่ 2-2 รายละเอียดคุณสมบัติของดาวเทียม Quickbird ดัดแปลงจาก (Khorram et al., 2012)	28
ตารางที่ 4-1 รหัสค่าสีของคลาสที่ใช้ในการจำแนกพันธุ์ไม้ป่าชายเลน.....	48
ตารางที่ 4-2 รายละเอียดสถาปัตยกรรมโครงข่ายต้นแบบ (FCN-8s).....	50
ตารางที่ 4-3 รายละเอียดสถาปัตยกรรมของวิธีการนำเสนอ (CFCN).....	52
ตารางที่ 4-4 คุณสมบัติของเครื่องสแกนเลเซอร์ภาคพื้นดิน Topcon รุ่น GLS 2000	55
ตารางที่ 5-1 ผลการทดสอบโครงข่ายต้นแบบ (FCN-8s) และวิธีการนำเสนอ (CFCN).....	65
ตารางที่ 5-2 การทดสอบความแตกต่างประสิทธิภาพของโครงข่ายด้วยสถิติ Z แบบสองกลุ่ม	66
ตารางที่ 5-3 Confusion matrix ของการจำแนกด้วยวิธีการนำเสนอ (CFCN).....	67
ตารางที่ 5-4 Confusion matrix ของการจำแนกด้วยวิธีความน่าจะเป็นสูงสุด (MLC).....	67
ตารางที่ 5-5 ปริมาตรลำต้น และค่าประมาณมวลชีวภาพของต้นไม้ตัวอย่างจากจุดพิกัดสามมิติ.....	70
ตารางที่ 5-6 มวลชีวภาพเหนือพื้นดินของต้นแสมทะเลแยกตามลำต้น เรือนยอด และรวมค่า	71
ตารางที่ 5-7 การเปรียบเทียบมวลชีวภาพเหนือพื้นดินที่ประมาณค่าจากเครื่องสแกนเลเซอร์ ภาคพื้นดิน เปรียบเทียบกับค่ามวลชีวภาพที่ได้จากแบบจำลองอ้างอิง	74

สารบัญภาพ

	หน้า
ภาพที่ 2-1 ลักษณะโครงข่ายประสาทเทียมแบบชั้นเดียว	8
ภาพที่ 2-2 ลักษณะโครงข่ายประสาทเทียมแบบหลายชั้น	9
ภาพที่ 2-3 ลักษณะการรับข้อมูลเข้า และส่งออกของ Neuron.....	10
ภาพที่ 2-4 โครงข่ายประสาทเทียมแบบป้อนไปข้างหน้า	11
ภาพที่ 2-5 โครงสร้างของสถาปัตยกรรม CNN ทั่วไป (Hu et al., 2015b)	16
ภาพที่ 2-6 สถาปัตยกรรมโครงข่าย CNN AlexNet ซึ่งประกอบด้วย Convolution 5 ชั้น และ Fully connected 3 ชั้น ดัดแปลงจาก Cheng, Zhou, and Han (2016)	17
ภาพที่ 2-7 ตัวอย่างการทำ Convolution กับภาพขนาด $6 \times 6 \times 1$	18
ภาพที่ 2-8 การทำ Pooling แบบค่าสูงสุด	19
ภาพที่ 2-9 ตัวอย่างการทำคอนโวลูชัน และทรานโพสคอนโวลูชันกับภาพขนาด 4×4 จุดภาพ ดัดแปลงจาก (Dumoulin and Visin, 2016).....	20
ภาพที่ 2-10 ภาพถ่ายจากดาวเทียม Quickbird แบบหลายช่วงคลื่น.....	28
ภาพที่ 3-1 การทดสอบทางสถิติของการสะท้อนของช่วงคลื่นกับพันธุ์ <i>Rhizophora apiculata</i> (Vaiphasa et al., 2005).....	32
ภาพที่ 3-2 การใช้ CNNs ในการจำแนกข้อมูลภาพถ่ายจากดาวเทียม (Langkvist et al., 2016)....	35
ภาพที่ 3-3 การจำแนกแบบ Per-pixel ในการจำแนกภาพทางความหมาย โดยเพิ่มรายละเอียด จุดภาพหลังชั้น Fully connected (Long et al., 2015).....	37
ภาพที่ 3-4 วิธีการข้ามชั้นคอนโวลูชันแบบ FCN-32s FCN-16s และ FCN-8s ในการสกัดคุณลักษณะ ของข้อมูลภาพเพื่อจำแนก (Long et al., 2015).....	37
ภาพที่ 4-1 พื้นที่ศึกษาป่าชายเลนบริเวณแหลมตะลุมพุก อำเภอปากพนัง (ภาพผสมสีเท็จ 432 RGB)	44
ภาพที่ 4-2 ตัวอย่างข้อมูลภาพถ่ายจากดาวเทียม และข้อมูลอ้างอิงขนาด 512×512 จุดภาพ	47
ภาพที่ 4-3 ตัวอย่างการแปลงค่าจุดภาพ (a) และภาพอ้างอิง (b) ให้อยู่ในรูปแบบ Numpy array..	49

ภาพที่ 4-4 สถาปัตยกรรม CFCN ที่ใช้ในการจำแนกพันธุ์ไม้ป่าชายเลนเขตร้อน ประกอบด้วยส่วนคอนโวลูชัน และทรานส์โพสคอนโวลูชัน และปรับมิติของภาพแต่ละชั้นให้เหมาะสมกับทรัพยากรประมวลผล..... 51

ภาพที่ 4-5 ศูนย์ศึกษาธรรมชาติกองทัพบก (บางปู) เฉลิมพระเกียรติ 72 พรรชามหาราชินี 54

ภาพที่ 4-6 (a) พื้นที่เก็บข้อมูลต้นไม้ตัวอย่างตั้งอยู่บริเวณฝั่งคลองตรงข้ามสะพานแขวน (b) พื้นที่ศึกษาเป็นบริเวณที่ต้นเสมหะเลชันเจริญเติบโตรวมกันเป็นกลุ่ม และมีสภาพดินแห้ง สามารถเข้าไปเก็บข้อมูลได้ 56

ภาพที่ 4-7 (a) การตั้งเครื่องสแกนเลเซอร์ภาคพื้นดิน เพื่อเก็บข้อมูล Point cloud ต้องให้สามารถเก็บข้อมูลเข้าอ้างอิงได้ 2 สถานีเป็นอย่างน้อยต่อการสแกน 1 ครั้ง (b) สถานีเข้าอ้างอิง มีจำนวน 2 เป้า ต่อหนึ่งสถานี (ธนีสร อินทร์ตัน และชัยโชค ไวกาษา, 2561) 57

ภาพที่ 4-8 ข้อมูลจุดพิกัดสามมิติของตัวอย่าง BP05 ที่ได้จากสถานี TLS 1 (a) และ 2 (b) ตัวอย่างการเก็บข้อมูลในภาพที่ 6-4 มีสถานี TLS จำนวน 2 สถานี ตั้งอยู่สถานีละฝั่งของต้นไม้ตัวอย่าง และมีสถานีเป้าหมายอ้างอิงจำนวน 2 สถานี (สถานีละ 2 เป้า)..... 58

ภาพที่ 4-9 (a) การนำจุดพิกัดสามมิติ 2 ชุด มาประมวลผลเพื่อรวมข้อมูล (b) ผลจากการแปลงข้อมูลเป็นจุดพิกัดสามมิติเชิงเดี่ยว..... 59

ภาพที่ 4-10 (a) จุดพิกัดสามมิติเชิงเดี่ยวถูกนำมาลบข้อมูลที่ไม่งจำเป็นต่อการประมวลผล (b) ลบจุดพิกัดสามมิติออกจนเหลือแต่ลำต้นของต้นไม้ตัวอย่าง (c) ข้อมูลจุดพิกัดสามมิติที่พร้อมนำเข้าสู่กระบวนการวิเคราะห์ขั้นต่อไป (หน่วยเมตร)..... 60

ภาพที่ 4-11 บริเวณรูปทรง Frustum of paraboloid ที่ใช้คำนวณค่ามวลชีวภาพ..... 60

ภาพที่ 4-12 การวัดพารามิเตอร์ของท่อนไม้ (a) ตัดแบ่งต้นไม้ตัวอย่างออกเป็นท่อนให้มีความตรงตามแนวยาวมากที่สุด (b) การวัดความยาว และเส้นผ่านศูนย์กลาง ตัดแปลงจาก Intarat and Vaiphasa (2018)..... 61

ภาพที่ 5-1 ภาพแสดงผลการเปรียบเทียบค่าความสูญเสีย (Loss) ค่าความถูกต้อง (Accuracy) ค่าความเที่ยง (Precision) ค่าความระลึก (Recall) ค่าเอฟวัน (F1 score) และค่า IoU เฉลี่ย (Mean IoU) ของวิธีการนำเสนอ (CFCN, เส้นสีน้ำเงิน) และโครงข่ายต้นแบบ (FCN-8s, เส้นสีแดง)..... 65

ภาพที่ 5-2 a) ผลการจำแนกพันธุ์ไม้ป่าชายเลนเขตร้อนด้วยวิธีการนำเสนอ (CFCN) b) ผลการจำแนกพันธุ์ไม้ป่าชายเลนเขตร้อนด้วยวิธีความน่าจะเป็นสูงสุด (MLC)..... 68

- ภาพที่ 5-3 ความสัมพันธ์แบบยกกำลังระหว่างมวลชีวภาพเหนือพื้นดินและเส้นผ่านศูนย์กลางความสูงเพียงอกของต้นแสมทะเล 73
- ภาพที่ 5-4 แบบจำลองความสัมพันธ์แบบยกกำลังระหว่างมวลชีวภาพเหนือพื้นดิน และเส้นผ่านศูนย์กลางความสูงเพียงอกของต้นแสมทะเลที่ประมาณค่าจากเครื่องสแกนเลเซอร์ภาคพื้นดิน โดยแสดงค่าด้วยเส้นทึบสีแดง ส่วนเส้นประสีอื่นเป็นค่ามวลชีวภาพเหนือพื้นดินที่ได้จากแบบจำลองอ้างอิง โดยมีจุดประสงค์เพื่อนำมาเปรียบเทียบความถูกต้อง..... 76
- ภาพที่ 6-1 พื้นที่ต้นโกงกางใบเล็ก (พื้นที่สีเขียว) จุดสีแดง และจุดสีเหลือง เป็นจุดแสดงต้นโกงกางใบใหญ่ และต้นแสมขาวที่ขึ้นแทรกอยู่ในพื้นที่ 82
- ภาพที่ 6-2 ตัวอย่างพื้นที่ต้นแสมทะเล (Am) และต้นถั่วขาว (BP) แทนด้วยจุดสีฟ้า และสีน้ำเงินซึ่งเป็นจุดที่เข้าไปสำรวจภาคสนามเก็บข้อมูลในพื้นที่ศึกษา 83
- ภาพที่ 6-3 ตัวอย่างพื้นที่รอยต่อระหว่างเมืองกับต้นไม้ป่าชายเลน จุดสีชมพูแสดงถึงพื้นที่ต้นไม้พันธุ์ผสม (Mx) จุดสีเทาแสดงถึงพื้นที่เมือง (Ur)..... 83

บทที่ 1

บทนำ

1.1 ความเป็นมา และความสำคัญของปัญหา

ระบบนิเวศน์ป่าชายเลน เป็นระบบที่มีความสำคัญต่อพื้นที่ชายฝั่งทะเล เป็นส่วนที่ช่วยเชื่อมโยงความสัมพันธ์ระหว่างพื้นดิน และพื้นน้ำ (Heumann, 2011) เป็นแหล่งรวมของสังคมพืช สัตว์บก และสัตว์น้ำหลากหลายชนิด สามารถพบป่าชายเลนได้ทั่วไปในภูมิภาคที่มีภูมิอากาศแบบเขตร้อน หรือกึ่งเขตร้อน ระหว่างละติจูดที่ 30° เหนือ และ 30° ใต้ (Hamdan *et al.*, 2013) ป่าชายเลนมีความสำคัญทั้งทางด้านสิ่งแวดล้อม และทางด้านเศรษฐกิจ ให้คุณประโยชน์ต่อมนุษย์ ไม่ว่าจะเป็นการนำไม้จากป่าชายเลนมาใช้ประโยชน์ เช่น การใช้เป็นเชื้อเพลิง การนำมาปลูกสร้างสิ่งก่อสร้างต่าง ๆ รวมถึงเป็นอนุสรณ์ด้านการประมง อีกทั้งยังใช้ป่าชายเลนเป็นแหล่งในการหาปัจจัยเพื่อการดำรงชีพ ทั้งการจับสัตว์น้ำ และเก็บพืชที่ขึ้นในป่าชายเลน เพื่อใช้เป็นอาหาร และยา (Lee *et al.*, 2014; Sasmito *et al.*, 2016) นอกจากนี้ พื้นที่ป่าชายเลนยังเป็นแหล่งกักเก็บคาร์บอนที่สำคัญของโลก โดยเฉพาะ ต้นโกงกางใบเล็ก และใบใหญ่ (*Rhizophora apiculata* and *Rhizophora mucronata*) ซึ่งเป็นพืชที่มีความสามารถในการสังเคราะห์แสงสูง ช่วยให้สามารถกักเก็บก๊าซคาร์บอนไดออกไซด์ได้มากกว่าระบบนิเวศน์ของป่าประเภทอื่นประมาณ 3 - 4 เท่า (Donato *et al.*, 2011; Hamdan *et al.*, 2013; Murdiyarso *et al.*, 2015) รากของพืชในป่าชายเลนช่วยกรองสิ่งปนเปื้อน และสารพิษต่าง ๆ ไม่ให้ไหลลงสู่ทะเล ทั้งยังช่วยยึดดิน และเลนในพื้นที่ ส่งผลให้เกิดการสะสมของตะกอน เกิดการงอกของพื้นที่ป่าชายเลนเพิ่มขึ้น เมื่อปริมาณป่าชายเลนมีความหนาแน่นมากยิ่งขึ้น ส่งผลดีต่อการเป็นแนวป้องกันคลื่นกัดเซาะชายฝั่ง และลดความรุนแรงจากลมพายุนอกชายฝั่งที่พัดเข้ามา ช่วยป้องกันทรัพย์สินของผู้ที่อาศัยอยู่ตามแนวชายฝั่ง (Kuenzer *et al.*, 2011) อย่างไรก็ตาม ในช่วง 20 ปีที่ผ่านมา ป่าชายเลนได้ถูกคุกคามทั้งจากการเปลี่ยนแปลงทางธรรมชาติ และมนุษย์ (Ellison, 2015; Li *et al.*, 2015b) ส่งผลให้ป่าชายเลนในเกือบทุกภูมิภาคทั่วโลก ได้ลดจำนวนลงอย่างรวดเร็ว และอย่างต่อเนื่องมากกว่าร้อยละ 35 หากสถานการณ์ยังไม่มีการเปลี่ยนแปลง คาดว่าในอีกประมาณ 100 ปีข้างหน้า พันธุ์ไม้ป่าชายเลนอาจเกิดการสูญพันธุ์ และพื้นที่ชุ่มน้ำบริเวณชายฝั่งทะเลจะได้รับผลกระทบคิดเป็นร้อยละ 30 - 40 ของพื้นที่ทั้งหมด (Giri, 2016)

จากปัญหาที่เกิดขึ้น จึงได้มีความพยายามที่จะสงวน และฟื้นฟูป่าชายเลนอย่างเร่งด่วนในทั่วทุกภูมิภาคของโลก ซึ่งการมีข้อมูลเกี่ยวกับป่าชายเลนทั้งด้านพื้นที่ และความสมบูรณ์ที่มีความทันสมัย เป็นสิ่งสำคัญเพื่อช่วยในการบริหารจัดการพื้นที่ป่าชายเลน กำหนดนโยบายเกี่ยวกับป่าชายเลนให้มีความสอดคล้องกับสถานการณ์ปัจจุบัน และสามารถนำไปใช้เป็นข้อมูลในการตัดสินใจได้

อย่างทันท่วงที อย่างไรก็ตาม ระบบนิเวศน์ป่าชายเลน มีความหนาแน่นของพันธุ์ไม้สูง ทำให้วิธีการสำรวจภาคสนามแบบดั้งเดิมไม่เหมาะสมในการใช้งาน เนื่องจากการเดินทางเข้าถึงพื้นที่เป้าหมายเพื่อเก็บข้อมูลมีความยากลำบาก ใช้เวลาในการทำงานมากกว่าพื้นที่ทั่วไป และเสียค่าใช้จ่ายสูง (Kuenzer *et al.*, 2011) รีโมทเซนซิง (Remote sensing) ได้ถูกนำเข้ามาใช้เป็นเครื่องมือเพื่อศึกษาพื้นที่ป่าชายเลน และได้รับการยอมรับว่ามีประสิทธิภาพในการทำงาน ช่วยให้สามารถเก็บข้อมูลในพื้นที่ขนาดใหญ่ และมีความต่อเนื่องในการบันทึกข้อมูล หรือเหตุการณ์ที่เกิดขึ้นในพื้นที่ศึกษา นอกจากนี้ยังสามารถช่วยในการจัดทำแผนที่ที่มีความทันสมัย และลดเวลาในการทำงานลง รวมถึงมีค่าใช้จ่ายต่ำกว่าวิธีการสำรวจแบบดั้งเดิม (Hamdan *et al.*, 2013; Heenkenda *et al.*, 2014; Jia *et al.*, 2014; Kamal and Phinn, 2011; Kovacs *et al.*, 2010; Lee and Yeh, 2009) ประเด็นที่มักถูกยกมาใช้ในการงานวิจัยด้านป่าชายเลน มักเกี่ยวข้องกับเรื่องการจัดจำแนกพันธุ์ไม้ป่าชายเลน (Heenkenda *et al.*, 2014; Kamal and Phinn, 2011; Koedsin and Vaiphasa, 2013; Kovacs *et al.*, 2011; Vaiphasa *et al.*, 2005; Wang *et al.*, 2004; Watanakij and Vaiphasa, 2016; Zhang *et al.*, 2014) มวลชีวภาพของพื้นที่ศึกษา (Cao *et al.*, 2016; Hirata *et al.*, 2014; Jachowski *et al.*, 2013; Odipo *et al.*, 2016; Zhu *et al.*, 2015) และลักษณะโครงสร้างเชิงกายภาพของพันธุ์ไม้ป่าชายเลน (Feliciano *et al.*, 2014; Giri, 2016; Kuenzer *et al.*, 2011) เนื่องจากเป็นข้อมูลพื้นฐานสำคัญที่ใช้ในการบริหารจัดการพื้นที่ป่าชายเลน ซึ่งในงานวิจัยนี้ จะให้ความสนใจในสองประเด็น ได้แก่ การจัดจำแนกพันธุ์ไม้ป่าชายเลน และการเก็บข้อมูลทางกายภาพของต้นไม้ในป่าชายเลนเพื่อใช้ในการสร้างแบบจำลองมวลชีวภาพ

การจัดจำแนกพันธุ์ไม้ป่าชายเลนในอดีตนิยมใช้วิธีการจำแนกแบบกำกับดูแล และแบบไม่กำกับดูแล (Supervised and unsupervised classification) ซึ่งเป็นวิธีที่อาศัยคุณสมบัติเชิงคลื่นพื้นฐานที่มีประสิทธิภาพ เมื่อใช้วิเคราะห์ร่วมกับภาพถ่ายจากดาวเทียม นิยมใช้ตัวจำแนกที่เน้นการจำแนกแบบรายจุดภาพ (Pixel based classification) โดยอาศัยการวิเคราะห์ความแตกต่างที่ได้จากค่าการสะท้อนแสง (Bhattarai and Giri, 2011; Giri *et al.*, 2011; Green *et al.*, 1998; Myint *et al.*, 2014; Ramirez-Garcia *et al.*, 1998; Yu *et al.*, 2010) ต่อมา ได้มีการเน้นข้อมูลภาพด้วยการคำนวณหาค่าดัชนีพืชพรรณ (Vegetation index: VI) ให้พื้นที่พืชที่อาศัยคลอโรฟิลล์ในการสังเคราะห์แสง มีค่าที่โดดเด่น สามารถจำแนกออกจากพื้นที่ประเภทอื่น หรือการใช้วิธีเน้นค่าข้อมูลด้วยวิธีการวิเคราะห์องค์ประกอบหลัก (Principle component analysis: PCA) เพื่อสกัดค่าข้อมูลที่มีความสำคัญมาใช้ในการจำแนก (Otero *et al.*, 2016) เมื่อเทคโนโลยีด้านภาพถ่ายจากดาวเทียมได้รับการพัฒนาขีดความสามารถเพิ่มขึ้น และเข้าถึงได้สะดวกขึ้น ภาพถ่ายจากดาวเทียมรายละเอียดสูงได้ถูกนำมาใช้ในการวิจัยมากขึ้น (Hirata *et al.*, 2014; Jia *et al.*, 2014; Kamal *et al.*, 2015) วิธีการสกัดข้อมูลเนื้อภาพจากภาพถ่ายดาวเทียม (Texture extraction) ด้วยวิธีการ Gray level co-

occurrence matrix (GLCM) รวมถึงการจำแนกเชิงวัตถุ (Object based classification) นิยมนำมาใช้วิเคราะห์ภาพถ่ายจากดาวเทียมรายละเอียดสูง (Kamal *et al.*, 2015; Watanakij and Vaiphasa, 2016) ซึ่งได้มีการประยุกต์วิธีการเหล่านี้เข้าด้วยกันในงานวิจัยอีกหลายงานซึ่งสามารถหาข้อมูลเพิ่มเติมได้จาก Kuenzer *et al.* (2011) วิธีการจำแนกพันธุ์ไม้ป่าชายเลนได้รับการพัฒนาเรื่อยมาจนเข้าสู่ยุคของการใช้ Machine Learning เครื่องมือที่นิยมใช้ คือ การวิเคราะห์โครงข่ายประสาทเทียม (Analytical neural network: ANN) ซึ่งเป็นเครื่องมือที่สามารถใช้ในเรื่องของการจดจำรูปแบบ (Pattern recognition) โดยที่ผู้ใช้สามารถสอนให้เครื่องมือเรียนรู้ และปรับค่าในกระบวนการจำแนกได้อัตโนมัติ (Cheng and Han, 2016; Liu *et al.*, 2016; Mehdawi and Ahmad, 2012; Yu *et al.*, 2010) โครงข่ายประสาทเทียมประสบผลสำเร็จในการถูกนำมาประยุกต์กับการจำแนกพันธุ์ไม้ป่าชายเลน (Held *et al.*, 2003; Wang *et al.*, 2008; Yu *et al.*, 2010; Zhu *et al.*, 2015) โดยให้ผลการจำแนกที่มีความแม่นยำ และมีความถูกต้องสูงกว่าวิธีการจำแนกแบบทั่วไป อย่างไรก็ตาม การใช้วิธีโครงข่ายประสาทเทียมในบางงานวิจัย กลับได้ผลลัพธ์ที่มีความถูกต้องที่ต่ำกว่าวิธีการจำแนกแบบอื่น (Hu *et al.*, 2015b) จึงได้มีความพยายามในการสร้างเครื่องมือที่มีประสิทธิภาพในการจำแนกภาพถ่ายโดยเฉพาะ แนวคิดเรื่องการสร้างเครื่องมือการสกัดค่าจากเนื้อภพนี้มาจากกลุ่มนักวิจัยที่เกี่ยวข้องกับ Machine learning เริ่มจากแบบจำลองเพื่อจดจำลายมือ (Fukushima and Imagawa, 1993) และได้พัฒนาอัลกอริธึมโดย Lecun *et al.* (1998) จนเกิดเป็นสถาปัตยกรรม Convolution neural network (CNN) มีลักษณะคล้ายกับข่ายประสาทเทียมทั่วไป ประกอบด้วย Neuron ที่สามารถเรียนรู้ค่าน้ำหนัก และค่าความลำเอียง ซึ่ง CNN จะให้ข้อสรุปที่ชัดเจนว่า ข้อมูลที่นำเข้าไปในโครงข่ายคือ “ภาพ” ทำให้สามารถนำคุณสมบัติด้านภาพมาใช้วิเคราะห์ได้ ส่งผลให้ Forward function มีประสิทธิภาพเพิ่มขึ้นจากข่ายประสาทเทียมในการทำงาน และช่วยลดจำนวนของ Parameter ในโครงข่ายลง CNN ถูกนำมาใช้ในงานด้านการจำแนกภาพ การวิเคราะห์เชิงวัตถุ การตรวจหาตัวอักษร และการจดจำใบหน้า ซึ่งได้รับการยอมรับว่ามีประสิทธิภาพเหนือกว่าข่ายประสาทเทียม (Hu *et al.*, 2015b) จากความสามารถด้านการสกัดเนื้อภพ CNN ถูกนำมาใช้ในการจำแนกภาพถ่ายจากดาวเทียมแบบไฮเปอร์สเปกตรัล และแบบรายละเอียดสูง เน้นการจำแนกการใช้ประโยชน์ที่ดิน ซึ่งส่วนใหญ่จะทำในพื้นที่เขตเมือง (Hu *et al.*, 2015a; Hu *et al.*, 2015b; Langkvist *et al.*, 2016; Liang and Li, 2016; Yu *et al.*, 2017) ในพื้นที่ป่าชายเลนนั้น ยังไม่พบว่ามีผู้นำ CNN มาใช้จำแนกพันธุ์ไม้ จึงเป็นเรื่องที่น่าสนใจในการนำ CNN มาทดสอบการจำแนกพันธุ์ไม้ป่าชายเลน เนื่องจากในงานวิจัยที่ผ่านมา พบว่า การใช้วิธีสกัดพีเจอร์จากภาพถ่ายดาวเทียมรายละเอียดสูงประสบผลสำเร็จในการใช้จำแนกพันธุ์ไม้ป่าชายเลนที่มีลักษณะใกล้เคียงกันได้ อย่างเช่น ต้นโกงกางใบเล็ก และต้นโกงกางใบใหญ่ (Watanakij and Vaiphasa, 2016) และ CNN

เป็นเครื่องมือที่มีประสิทธิภาพสูงในการสกัดเนื้อภาพระดับพิกเซลเพื่อการจำแนก ก็น่าที่จะสามารถนำมาใช้จำแนกพันธุ์ไม้ป่าชายเลน และให้ผลลัพธ์ที่ดีขึ้นกว่าเดิม

ในส่วนของข้อมูลลักษณะทางกายภาพของต้นไม้เพื่อนำมาสร้างสมการอัลโลเมตรีที่ใช้ประมาณค่ามวลชีวภาพ เช่น เส้นผ่านศูนย์กลางที่ความสูงเพียงอก (Diameter at breast height: DBH) และ ความสูงของต้นไม้ ซึ่งต้องใช้ข้อมูล Single tree ในการวิเคราะห์ ในยุคแรก จำเป็นต้องใช้กำลังคนเข้าไปสำรวจแบบต้นต่อต้น ทำให้ประสบปัญหาเช่นเดียวกับที่กล่าวมาในข้างต้น หลังจากนั้นได้มีการพัฒนาโดยการใช้อุปกรณ์ถ่ายภาพต้นไม้เพื่อจัดทำข้อมูล (Shlyakhter *et al.*, 2001) ต่อมา ได้นำเทคโนโลยีรีโมทเซนซิงมาใช้เพื่อเก็บข้อมูลทางกายภาพของต้นไม้ (Hackenberg *et al.*, 2015b; Hirata *et al.*, 2014) จนกระทั่งในช่วง 20 ปีที่ผ่านมา ได้มีการพัฒนาเทคโนโลยี Laser scanner (LS) หรือที่รู้จักกันในชื่อ Light detection and ranging (LiDAR) ซึ่งได้ถูกนำไปใช้อย่างแพร่หลายและประสบผลสำเร็จในงานวิจัยด้านการสำรวจต้นไม้ (Cao *et al.*, 2016; Forsman *et al.*, 2016; Lovell *et al.*, 2011; Olofsson and Holmgren, 2016) ประโยชน์ที่ได้จาก LS คือ ช่วยลดต้นทุนที่ใช้ในการเก็บข้อมูลภาคสนาม ความถูกต้องของข้อมูลที่ได้จาก LS มีความใกล้เคียงกับวิธีการลงเก็บข้อมูลแบบดั้งเดิม และเป็นวิธีการที่มีความเหมาะสมกับการเก็บข้อมูลส่วนประกอบต่าง ๆ ของต้นไม้ (Liang *et al.*, 2016) TLS มีลักษณะการทำงานคล้ายกับวิธี Optical point quadrat โดยใช้ลำแสงเลเซอร์ยิงไปยังวัตถุเป้าหมาย และสะท้อนกับเข้าสู่ตัวรับสัญญาณเพื่อหาสัดส่วนของสัญญาณที่สะท้อนกลับ และไม่สะท้อนกลับ เป็นวิธีการเก็บข้อมูลภาคพื้นดินแบบ Indirect method ที่ให้ผลการเก็บข้อมูลดีกว่าหลาย ๆ วิธี TLS นิยมใช้กับงานในพื้นที่ป่าไม้เพื่อประเมินค่ามวลชีวภาพ และปรับปรุงสมการอัลโลเมตรีของต้นไม้ สามารถสร้างแบบจำลอง 3 มิติที่มีค่าความถูกต้อง และรายละเอียดสูง

การประมาณค่ามวลชีวภาพของต้นไม้ นิยมใช้สมการอัลโลเมตรี ซึ่งมีความสัมพันธ์กับขนาด รูปร่าง ปริมาตร หรือเส้นผ่านศูนย์กลางลำต้น ซึ่งค่าเส้นผ่านศูนย์กลางลำต้นที่ความสูงเพียงอก (Diameter at breast height: DBH) เป็นค่าพารามิเตอร์ที่นิยมนำมาใช้ร่วมกับสมการ Komiyama *et al.* (2008) ได้นำ DBH ไปใช้สร้างสมการอัลโลเมตรีเพื่อหามวลชีวภาพของพันธุ์ไม้ป่าชายเลน และได้นำค่าความหนาแน่นจำเพาะของเนื้อไม้ (Wood specific density: WSD) มาใช้เป็นพารามิเตอร์เพื่อทำนายค่ามวลชีวภาพของพันธุ์ไม้ป่าชายเลนในประเทศไทย เช่นเดียวกับ Chave *et al.* (2014) และ Kenzo *et al.* (2009) ที่ได้ตรวจวัดค่า WSD เพื่อนำมาใช้ในการเปรียบเทียบปรับค่าของสมการอัลโลเมตรี แสดงให้เห็นว่า ค่า WSD มีความสัมพันธ์กับการคำนวณหามวลชีวภาพ อย่างไรก็ตาม ในการเก็บข้อมูลทางกายภาพ ยังใช้วิธีการตัดตัวอย่างเพื่อนำไปตรวจวัดค่าในห้องทดลอง Feliciano *et al.* (2014) มีความเห็นว่า วิธีการที่ใช้กันอยู่เดิมนั้นมีข้อจำกัด เช่น ต้องใช้เวลา และแรงงานเพื่อตัดตัวอย่างต้นไม้ส่งผลให้ต้นไม้ถูกทำลาย การนำ DBH มาเป็นตัวแปรเพื่อทำนายค่ามวล

ชีวภาพมีค่าคลาดเคลื่อนสูงถึงร้อยละ 10 – 15 สมการอัลโลเมตรีที่ใช้กับพื้นที่ป่าชายเลนทั่วไปได้รับการเก็บข้อมูลเพื่อสร้างสมการมาจากแหล่งเดียว และสมการที่ใช้ไม่ตรงกับสายพันธุ์ของต้นไม้ในป่าชายเลนที่ต้องการหาค่ามวลชีวภาพ จึงได้นำ TLS มาใช้เพื่อเก็บข้อมูลกายภาพของต้นไม้ในป่าชายเลน ร่วมกับข้อมูลตัวอย่างที่เก็บจากพื้นที่จริง เพื่อประเมินค่ามวลชีวภาพโดยไม่ต้องตัดต้นไม้ ที่อุทยานแห่งชาติเอเวอร์เกลด รัฐฟลอริดา เก็บข้อมูลทั้งหมด 3 สายพันธุ์ ได้แก่ *L. Racemosa* A. *Germinans* และ *R. Mangle* โดยหาค่าปริมาตรของลำต้น และรากของพันธุ์ไม้ป่าชายเลน เพื่อนำมาคำนวณร่วมกับค่า WSD และประสพผลสำเร็จในการประเมินค่ามวลชีวภาพของพันธุ์ไม้ป่าชายเลน และได้ข้อสรุปว่าสามารถใช้แทนวิธีการประเมินแบบดั้งเดิมได้ เช่นเดียวกับ Olagoke *et al.* (2016) ประสพผลสำเร็จในการประเมินค่ามวลชีวภาพของพันธุ์ไม้ป่าชายเลนที่มีเส้นผ่านศูนย์กลางลำต้นขนาดใหญ่กว่า 1 เมตร ในทวีปอเมริกาใต้ที่จังหวัดเฟรนช์เกียนาซึ่งอยู่ภายใต้การปกครองของประเทศฝรั่งเศส โดยเก็บข้อมูลด้วย TLS และนำมาคำนวณหาพารามิเตอร์สำหรับการประมาณค่ามวลชีวภาพ แสดงให้เห็นว่า TLS สามารถนำมาใช้ประยุกต์ด้านการเก็บข้อมูลทางกายภาพของพันธุ์ไม้ป่าชายเลนได้ จากรายงานวิจัยที่กล่าวมาข้างต้น ได้ใช้ป่าชายเลนในทวีปอเมริกาเป็นพื้นที่ศึกษา พันธุ์ไม้ป่าชายเลนที่นำมาใช้ในงานวิจัยมีรวมกันเพียงแค่ 3 สายพันธุ์เท่านั้น จึงเป็นเรื่องที่น่าสนใจในการนำ TLS มาทดสอบการเก็บข้อมูลทางกายภาพของต้นไม้ในป่าชายเลนในประเทศไทยซึ่งมีลักษณะเป็นสายพันธุ์ป่าชายเลนเขตร้อน (Tropical mangrove) และมีพันธุ์ไม้ป่าชายเลนที่หลากหลาย เนื่องจากยังไม่มีรายงานใด ๆ ด้านการใช้ TLS เพื่อเก็บข้อมูลทางกายภาพของพันธุ์ไม้ป่าชายเลนเขตร้อนในประเทศไทย รวมถึงการประเมินมวลชีวภาพจากการวิเคราะห์ข้อมูลที่ได้จาก TLS ดังนั้น เพื่อเป็นการยืนยันว่าแนวทางการประเมินมวลชีวภาพของ Feliciano *et al.* (2014) และ Olagoke *et al.* (2016) มีความเป็นไปได้ในการใช้สร้างแบบจำลองมวลชีวภาพของพันธุ์ไม้ป่าชายเลนเขตร้อนโดยไม่ต้องตัดต้นไม้ และใช้แทนการเก็บข้อมูลเพื่อประเมินมวลชีวภาพแบบดั้งเดิมได้

งานวิจัยครั้งนี้ เป็นการทดสอบเพื่อให้เป็นที่ประจักษ์ถึงความเป็นไปได้ในประเด็นที่สนใจ ดังที่ได้กล่าวมาในข้างต้น ได้แก่ การจำแนกพันธุ์ไม้ป่าชายเลนเขตร้อน และการเก็บข้อมูลทางกายภาพของต้นไม้ในป่าชายเลนเขตร้อนเพื่อใช้ในการสร้างแบบจำลองมวลชีวภาพ ในประเด็นการจำแนกพันธุ์ไม้ป่าชายเลน จะใช้วิธีการจำแนกแบบ Convolutional neural network ซึ่งเป็นเครื่องมือที่ใช้เพื่องานด้านการจำแนกข้อมูลจากเนื้อหาภาพ และจดจำข้อมูลภาพ เพื่อทดสอบศักยภาพในการจำแนกจะสามารถให้ผลลัพธ์ที่ดีกว่าวิธีการมาตรฐาน เช่น การจำแนกแบบความน่าจะเป็นสูงสุดได้หรือไม่ ในประเด็นการเก็บข้อมูลทางกายภาพของต้นไม้ป่าชายเลนเขตร้อน จะเก็บข้อมูลโดยใช้ TLS และนำข้อมูลที่ได้มาสร้างความสัมพันธ์กับมวลชีวภาพของต้นไม้ป่าชายเลนเขตร้อน เพื่อทดสอบว่าข้อมูล และแบบจำลองที่ได้จะมีศักยภาพสามารถคำนวณค่ามวลชีวภาพของพันธุ์ไม้ป่าชาย

เลนเซตร้อนโดยไม่ต้องตัดต้นไม้ได้อย่างมีนัยสำคัญหรือไม่ และเพื่อใช้เป็นแนวทางในการทำงานวิจัยต่อไป

1.2 วัตถุประสงค์ของงานวิจัย

1.2.1 จำแนกพันธุ์ไม้ป่าชายเลนเซตร้อนด้วยวิธีการถ่ายประสาทคอนโวลูชัน

1.2.2 ทดสอบวิธีการเก็บข้อมูลทางกายภาพของต้นไม้ในป่าชายเลนเซตร้อนด้วยเครื่องสแกนเลเซอร์ภาคพื้นดิน และสร้างแบบจำลองมวลชีวภาพของพันธุ์ไม้ป่าชายเลนเซตร้อน

1.3 สมมติฐานของงานวิจัย

1.3.1 การจำแนกพันธุ์ไม้ป่าชายเลนจากการวิเคราะห์เนื้อหาภาพด้วยวิธีการถ่ายประสาทคอนโวลูชัน (CNN) จะสามารถช่วยให้การจำแนกพันธุ์ไม้ที่โดดเด่น 5 ชนิดจากภาพถ่ายดาวเทียมรายละเอียดสูงมีความถูกต้องมากกว่าวิธีการจำแนกแบบความน่าจะเป็นสูงสุด

1.3.2 การเก็บข้อมูลกายภาพของต้นไม้ป่าชายเลนสามารถใช้ TLS เก็บข้อมูล และนำมาสร้างแบบจำลองมวลชีวภาพได้โดยไม่ต้องตัดต้นไม้

1.4 ขอบเขตของงานวิจัย

งานวิจัยเรื่องนี้ ให้ความสนใจเกี่ยวกับการศึกษาด้านป่าชายเลนอยู่สองประเด็น ได้แก่ การจำแนกพันธุ์ไม้ป่าชายเลนเซตร้อน และการสร้างแบบจำลองมวลชีวภาพเหนือพื้นดินของพันธุ์ไม้ป่าชายเลนเซตร้อนโดยไม่ต้องตัดต้นไม้ ดังนี้

1.4.1 การจำแนกพันธุ์ไม้ป่าชายเลนเซตร้อนด้วย CNN

จำแนกพันธุ์ไม้ป่าชายเลนโดยใช้วิธีการนำเสนอปรับปรุงจาก FCN-8s (Long *et al.*, 2015) ให้มีขนาดของโครงข่ายเล็กลงจากเดิม ให้ชื่อว่า Compressed fully convolution network (CFCN) มาสกัดเนื้อหา และจำแนกข้อมูลพันธุ์ไม้จากภาพถ่ายจากดาวเทียมรายละเอียดสูง ผลลัพธ์ที่ได้จากการจำแนกจะเปรียบเทียบกับผลลัพธ์จากการจำแนกด้วยวิธีความน่าจะเป็นสูงสุด (Maximum likelihood classification) ทดสอบความถูกต้องของการจำแนกด้วยเมตริกซ์ค่าคลาดเคลื่อน (Confusion matrix) และทดสอบความสอดคล้องของการจำแนกด้วยค่าสถิติโคเฮนส์ แคลปป์ จากนั้น ทดสอบความแตกต่างผลการจำแนกทั้งสองวิธีที่ระดับนัยสำคัญ 0.05 เพื่อยืนยันประสิทธิภาพของการจำแนก

พื้นที่ศึกษา: บริเวณป่าชายเลนแหลมตะลุมพุก อำเภอบางขัน จังหวัดนครศรีธรรมราช

1.4.2 การสร้างแบบจำลองมวลชีวภาพเหนือพื้นดินของพันธุ์ไม้ป่าชายเลนเขตร้อนโดยไม้ตัดต้นไม้

เก็บข้อมูลทางกายภาพของต้นแสมทะเลแบบไม้ตัดต้นไม้โดยใช้เครื่อง TLS และนำข้อมูล Point cloud มาคำนวณปริมาตรของลำต้น และเส้นผ่านศูนย์กลางเพียงอกที่มีขนาดไม่เกิน 30 เซนติเมตร ในส่วนของข้อมูลทางกายภาพอื่น ๆ จะใช้ข้อมูลทุติยภูมิจากงานวิจัยที่ได้รับการตีพิมพ์เผยแพร่ คำนวณปริมาตรของต้นไม้ด้วยวิธี Quantitative structure model (QSM) ร่วมกับความหนาแน่นจำเพาะของต้นไม้ และค่าปรับแก้เรือนยอด เพื่อให้ได้มาซึ่งมวลชีวภาพเหนือพื้นดินของต้นไม้แต่ละต้น

สร้างแบบจำลองมวลชีวภาพเหนือพื้นดินจากสมการอัลโลเมตรี และเปรียบเทียบความถูกต้องค่ามวลชีวภาพเหนือพื้นดินที่ได้จากแบบจำลองที่สร้างขึ้น กับแบบจำลองทั่วไปที่ได้จากการวัดค่าในห้องปฏิบัติการในรายงานของ Komiyama *et al.* (2008) Comley and McGuinness (2005) Laongmanee (2011) และ Patil *et al.* (2014) เพื่อทดสอบความแตกต่างของความสอดคล้องอย่างมีนัยสำคัญ

พื้นที่ศึกษา: ป่าชายเลน ศูนย์ศึกษาธรรมชาติกองทัพบก (บางปู) เฉลิมพระเกียรติ 72 พรรษา มหาราชินี ตำบลบางปู อำเภอเมือง จังหวัดสมุทรปราการ

1.5 ประโยชน์ที่คาดว่าจะได้รับ

1.5.1 ได้วิธีการจำแนกพันธุ์ไม้ป่าชายเลนในพื้นที่ศึกษาจากภาพถ่ายดาวเทียมรายละเอียดสูงที่มีความถูกต้องของการจำแนกพันธุ์ไม้ป่าชายเลนได้สูงขึ้น

1.5.2 สามารถนำวิธีการที่ได้ไปปรับใช้บริหารจัดการพื้นที่ป่าชายเลนและป่าไม้ที่มีลักษณะหนาแน่นชนิดอื่น ๆ ได้

1.5.3 ได้วิธีการประมาณค่ามวลชีวภาพเหนือพื้นดินของต้นแสมทะเลโดยไม่ต้องตัดต้นไม้

1.5.4 ได้สมการอัลโลเมตรีที่เหมาะสมกับต้นแสมทะเลในพื้นที่ศึกษา

บทที่ 2

ทฤษฎี และงานวิจัยที่เกี่ยวข้อง

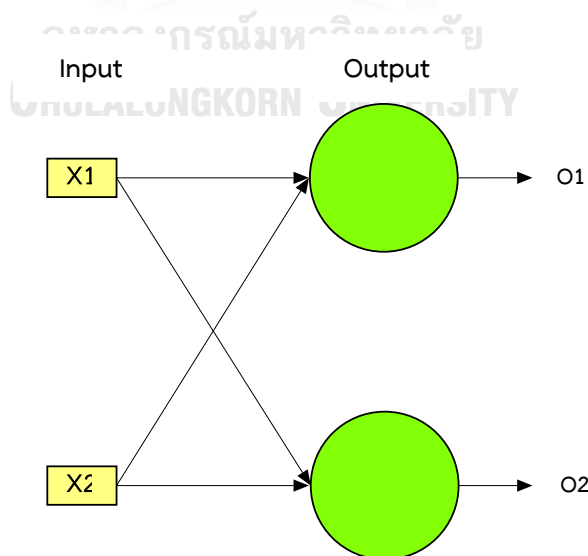
2.1 ข่ายประสาทเทียม (Artificial neural network)

ข่ายประสาทเทียมเป็นแบบจำลองทางคณิตศาสตร์ที่ได้รับการพัฒนาขึ้นให้มีการทำงานคล้ายกับสมองของมนุษย์ โดยสามารถเรียนรู้ข้อมูลที่มีอยู่แล้วจดจำ เพื่อใช้ในการทำนาย หรือการจำแนกผลลัพธ์ โดยข้อมูลที่เรียนรู้จะถูกจัดเก็บในรูปของค่าน้ำหนัก และสามารถปรับเปลี่ยนค่าน้ำหนักเมื่อได้รับข้อมูลเพิ่มเข้ามา คล้ายกับความรู้ที่สมองของคนได้เรียนรู้ และจดจำเพื่อนำไปใช้แก้ปัญหาเช่นเดียวกัน

2.1.1 สถาปัตยกรรมของชั้นข่ายประสาทเทียม

โครงข่ายประสาทเทียมแบ่งการเชื่อมต่อออกเป็นกลุ่มชั้น (Layer) ตามที่กล่าวในข้างต้น ประกอบด้วย ชั้นข้อมูลนำเข้า (Input layer) ชั้นแอบแฝง (Hidden layer) และชั้นข้อมูลส่งออก (Output layer) จำแนกประเภทของโครงข่ายประสาทเทียมตามจำนวนชั้นที่ประกอบภายในโครงข่ายได้ 2 ประเภท ได้แก่

1) โครงข่ายแบบชั้นเดียว (Single layer perceptron) เป็นโครงข่ายประสาทเทียมอย่างง่ายที่มีชั้นรับข้อมูลนำเข้ากับชั้นข้อมูลส่งออกเพียงเท่านั้น ข้อมูลจะถูกนำเข้าสู่ Neuron ชั้นแรก จากนั้นจะถูกส่งผ่านโครงข่ายเชื่อมไปยังชั้นข้อมูลส่งออกเพื่อคำนวณออกมาเป็นผลลัพธ์ผ่านฟังก์ชันการส่งออก ดังแสดงในภาพที่ 2-1



ภาพที่ 2-1 ลักษณะโครงข่ายประสาทเทียมแบบชั้นเดียว


จำนวนเพอร์เซปตรอนขึ้นอยู่กับจำนวนองค์ประกอบของข้อมูลนำเข้า และฟังก์ชันส่งออกขึ้นอยู่กับลักษณะของผลลัพธ์ ตัวอย่างเช่น ถ้าต้องการผลลัพธ์แบบสองค่า จะใช้ Threshold function (สมการที่ 2-1) โครงข่ายแบบชั้นเดียวมีความเหมาะสมในการคำนวณปัญหาที่ไม่ซับซ้อน

$$f(x) = \begin{cases} 0, & x < T \\ 1, & x \geq T \end{cases} \quad (2-1)$$

เมื่อ T คือ ระดับค่าขีดแบ่ง (Threshold)

ถ้าผลลัพธ์ที่ต้องการมีค่าเป็นตัวเลขที่มีความต่อเนื่อง ต้องนำ Continuous function มาคำนวณ เช่น Sigmoid function หรือ Hyperbolic tangent function เป็นต้น


2) โครงข่ายแบบหลายชั้น (Multi-layer perceptron หรือ Deep neural network) เป็นโครงข่ายที่มีชั้นแอบแฝงมากกว่าหนึ่งชั้นขึ้นไป โครงข่ายแบบนี้มีความเหมาะสมกับปัญหาประเภทที่มีความซับซ้อนมาก ต้องใช้โครงข่ายหลายชั้น และฟังก์ชันกระตุ้นส่งออกไม่เชิงเส้น (ญาติ ลิมปิยะภรณ์, 2556) ดังแสดงในภาพที่ 2-2 แต่ละชั้นจะประกอบด้วยเพอร์เซปตรอน ค่าน้ำหนักของเส้นที่เชื่อมต่อระหว่างเพอร์เซปตรอน ค่าความลำเอียง และค่าส่งออก



ภาพที่ 2-2 ลักษณะโครงข่ายประสาทเทียมแบบหลายชั้น

โครงข่ายประสาทเทียม จะใช้ Neuron หรือ Perceptron ซึ่งเป็นหน่วยย่อยที่สุดในโครงข่ายประสาทเทียมทำหน้าที่เหมือนเซลล์ประสาท (ภาพที่ 2-3) เพอร์เซปตรอนแต่ละตัวสามารถรับค่านำเข้าได้หลายค่า จากนั้น รวมค่าที่วิ่งเข้ามาทั้งหมดแบบเชิงเส้น และกระตุ้นด้วยฟังก์ชันที่

กำหนดก่อนส่งออกเป็นค่านำออกยังขั้นถัดไปซึ่งจะมีค่าแตกต่างกันไปตามฟังก์ชันกระตุ้นที่ใช้ ค่าที่ได้รับการกระตุ้น หรือส่งออกจะมีได้เพียงหนึ่งค่า



ภาพที่ 2-3 ลักษณะการรับข้อมูลเข้า และส่งออกของ Neuron

จากภาพที่ 2-3 กำหนดฟังก์ชันของ Neuron แทนด้วย $f(x)$ ซึ่งเป็นฟังก์ชันที่ใช้ในการกำหนดค่าส่งออก ดังแสดงในสมการที่ 6-2

$$t = f(x) = \begin{cases} 1, & \sum_{i=1}^m w_i x_i + b > 0 \\ 0, & \text{otherwise} \end{cases} \quad (2-2)$$

เมื่อ t คือ ข้อมูลส่งออก

x คือ ข้อมูลรับเข้า

w คือ เวกเตอร์ของน้ำหนัก

b คือ ค่าความลำเอียง

m คือ ขนาดของข้อมูลรับเข้า

จากสมการที่ 2-2 ค่าที่นำออกหลังจากได้รับการกระตุ้นจากฟังก์ชันการส่งออกแล้ว จะมีค่าเป็น 1 หรือ 0 ขึ้นอยู่กับว่าฟังก์ชันที่รับค่านำเข้าไปคำนวณออกมาแล้วมีผลลัพธ์ตามเกณฑ์ใด ค่าน้ำหนักของ Neuron จะถูกปรับอัตราการเรียนรู้ ตามสมการที่ 2-3 และ 2-4 เพื่อให้ได้มาซึ่งผลรวมเชิงเส้นถ่วงน้ำหนัก

$$w_i \leftarrow w_i + \Delta w_i \quad (2-3)$$


$$\Delta w_i = \alpha(t - o)x_i \quad (2-4)$$

- เมื่อ α คือ อัตราการเรียนรู้
 x คือ ข้อมูลรับเข้าตัวอย่าง
 o คือ ผลลัพธ์ที่ทำนายได้
 t คือ ผลลัพธ์เป้าหมาย
 $t - o$ คือ ค่าคลาดเคลื่อน

จากสมการที่ 2-4 อัตราการเรียนรู้ (Learning rate: α) มีลักษณะเป็นค่าคงที่บวกที่ส่งผลกระทบต่อค่าของเพอร์เซปตรอน ถ้าอัตราการเรียนรู้มีค่ามาก เพอร์เซปตรอนจะเรียนรู้ได้เร็ว แต่อาจเกิดปัญหา Overfitting เนื่องจากการปรับค่าน้ำหนักมีความหยวบเกินไป ในขณะที่อัตราการเรียนรู้ที่มีค่าน้อยจะทำให้การปรับน้ำหนักมีความละเอียด และถูกต้องซึ่งต้องแลกกับเวลาที่ใช้ในการคำนวณ

2.1.2 ข่ายประสาทเทียมแบบป้อนไปข้างหน้า

สถาปัตยกรรมของข่ายประสาทเทียมแบบป้อนไปข้างหน้า (Feedforward neural network) มีลักษณะโครงสร้างแบ่งออกเป็นลำดับชั้น การคำนวณ และส่งผ่านข้อมูลเป็นไปในทิศทางเดียว ในแต่ละลำดับชั้นจะมีเพอร์เซปตรอนที่มีเส้นเชื่อมโยงระหว่างชั้นก่อนหน้า และชั้นถัดไป ซึ่งข้อมูลของเพอร์เซปตรอนในชั้นก่อนหน้าจะเป็นข้อมูลรับเข้าของเพอร์เซปตรอนในชั้นถัดไป ดังแสดงในภาพที่ 2-4



ภาพที่ 2-4 โครงข่ายประสาทเทียมแบบป้อนไปข้างหน้า

จากภาพที่ 2-4 การคำนวณไปข้างหน้าจะคำนวณข้อมูลรับเข้าจากชั้นก่อนหน้าโดยการพิจารณาจากค่าน้ำหนัก และค่าความลำเอียง ตามสมการที่ 2-5 จากนั้น รวมผลการคำนวณที่ได้ และส่งออกด้วยฟังก์ชันกระตุ้น ตามสมการที่ 2-6

$$z_j^l = \sum_{k=1}^n w_{jk}^l a_k^{l-1} + b_j^l \quad (2-5)$$

$$a_j^l = g(z_j^l) \quad (2-6)$$

เมื่อ z_j^l คือ ผลการคำนวณตัวที่ j ในลำดับชั้น l
 n คือ จำนวนนิวรอนในลำดับชั้น $l - 1$
 a_k^{l-1} คือ ผลลัพธ์ของเพอร์เซปตรอนตัวที่ k ในลำดับชั้น $l - 1$
 w_{jk}^l คือ น้ำหนักของเพอร์เซปตรอนตัวที่ j ในลำดับชั้น l
 b_j^l คือ ค่าความลำเอียงตัวที่ j ในลำดับชั้น l
 a_j^l คือ ค่าส่งออกตัวที่ j ในลำดับชั้น l

1) ฟังก์ชันกระตุ้น (Activation function)

สมการที่ 2-6 การส่งออกข้อมูลจำเป็นต้องใช้ฟังก์ชันกระตุ้น $g(z_j^l)$ ซึ่งมีหลากหลายรูปแบบ โดยฟังก์ชันที่นำมาใช้ในการศึกษาครั้งนี้ ได้แก่

(ก) ฟังก์ชันเรคตีไฟด์เชิงเส้น (Rectified liner Unit: ReLU)

เป็นฟังก์ชันที่ให้ผลลัพธ์มีค่ามากกว่าหรือเท่ากับศูนย์เสมอ (สมการที่ 2-7) เป็นฟังก์ชันที่นิยมใช้กับการวิเคราะห์ภาพ เนื่องจากค่าจุดภาพของภาพถ่ายหลังจากนำเข้าสู่โครงข่ายแล้ว จะถูก Normalization ให้มีค่าอยู่ระหว่าง 0 - 255

$$f(z) = \begin{cases} 0 & \text{if } z < 0 \\ z & \text{if } z \geq 0 \end{cases} \quad (2-7)$$

เมื่อ z คือ ผลลัพธ์ในชั้นปัจจุบัน

(ข) ฟังก์ชันค่าสูงสุดอย่างอ่อน (Softmax function)

เป็นฟังก์ชันที่ให้ค่าผลลัพธ์อยู่ในช่วง 0 ถึง 1 ได้รับการพัฒนาจากฟังก์ชัน Binary logistic regression (ผลลัพธ์ส่งออกมีสองค่า) ให้มีค่าผลลัพธ์ส่งออกเป็นแบบ Multiple classes

และ Normalize ค่าความน่าจะเป็น (สมการที่ 2-8) โดยผลรวมของผลลัพธ์ทุกคลาสมีค่าเป็น 1 นิยมใช้กระตุ้นในชั้นแอบแฝงชั้นสุดท้ายก่อนนำออกค่าผลลัพธ์

$$f(z)_j = \frac{e^{z_j}}{\sum_{i=1}^k e^{z_i}} \quad (2-8)$$

เมื่อ	z	คือ	ผลลัพธ์
	e	คือ	ค่าคงตัวทางคณิตศาสตร์
	j	คือ	ลำดับของผลลัพธ์
	k	คือ	จำนวนชั้นของโครงข่ายที่ต้องการคำนวณ

2) ฟังก์ชันต้นทุน (Cost function)

เป็นฟังก์ชันของโครงข่ายประสาทเทียมที่แสดงถึงต้นทุนของโครงข่าย ซึ่งในการเรียนรู้ของโครงข่ายแต่ละครั้ง โครงข่ายจะปรับค่าน้ำหนักเพื่อให้ผลลัพธ์ของฟังก์ชันต้นทุนมีค่าลดลง ในการศึกษาได้ใช้ฟังก์ชันค่าครอสเอนโทรปีเพื่อให้มีความเหมาะสมกับลักษณะโครงข่ายที่มีผลลัพธ์เป็นแบบแบ่งประเภท (Multinomial cross entropy หรือ Categorical cross entropy) โดยเฉพาะเวกเตอร์ส่งออกมีการแจกแจงแบบความน่าจะเป็น ซึ่งฟังก์ชัน ครอสเอนโทรปีจะให้ค่าระยะทางระหว่างค่าการกระจายของผลลัพธ์จากโครงข่ายกับผลลัพธ์จริง (Plunkett and Elman, 1997) และใช้ควบคู่กับฟังก์ชันกระตุ้นสูงสุดอย่างอ่อน แสดงในสมการที่ 2-9

$$J = -\frac{1}{n} \sum_{i=1}^n y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i) \quad (2-9)$$

เมื่อ	J	คือ	ฟังก์ชันต้นทุน
	n	คือ	จำนวนข้อมูลทั้งหมด
	y_i	คือ	ผลลัพธ์จริงที่ต้องการของข้อมูลชุดที่ i
	\hat{y}_i	คือ	ผลลัพธ์ที่ทำนายได้ของข้อมูลชุดที่ i

3) การหาค่าเหมาะสมที่สุด (Optimization)

โครงข่ายประสาทเทียมจะใช้กระบวนการเรียนรู้เพื่อให้การทำนายผลลัพธ์มีความใกล้เคียงกับผลที่ต้องการมากที่สุดโดยการปรับค่าน้ำหนักของเส้นเชื่อมในโครงข่ายจากค่าอัตราการเปลี่ยนแปลงของฟังก์ชันต้นทุนเทียบค่าน้ำหนัก ส่งผลให้ฟังก์ชันต้นทุนมีค่าลดลง การปรับค่า

เหมาะสมที่สุด จะช่วยให้ค่าของฟังก์ชันต้นทุนไม่ตกอยู่ในช่วงค่า Local minima โดยวิธีการที่นำมาใช้ในการศึกษาครั้งนี้ คือ Stochastic gradient descent (SGD) ดังแสดงในสมการที่ 2-10

$$w_t = w_{t-1} - \alpha \frac{\partial J_t}{\partial w} \quad (2-10)$$

เมื่อ w คือ ค่าน้ำหนักที่ต้องการปรับค่า

α คือ อัตราการเรียนรู้

$\frac{\partial J_t}{\partial w}$ คือ อัตราการเปลี่ยนแปลงของฟังก์ชันต้นทุนเทียบกับค่าน้ำหนัก

จากวิธี SGD ในการทำงาน สามารถปรับความเร็วของค่าอัตราการเรียนรู้ ($\alpha \frac{\partial J_t}{\partial w}$) ตามความเหมาะสม (ปกติจะให้ค่าน้อย เพื่อให้การเรียนรู้ดำเนินไปอย่างช้า ๆ) ค่าที่ลู่เข้าสู่ Global minima จะช้ากว่าวิธีอื่น ๆ เช่น ADADELTA หรือ ADAGRAD (Zeiler, 2012) จึงมีการปรับค่าโดยใช้ โมเมนตัม (Momentum) มาช่วยให้การเรียนรู้มีค่าที่ดีขึ้น เพื่อหลีกเลี่ยงการติดอยู่ที่ Local optima (ธนภัทร์ คุ่มสุภา, 2559) ดังสมการที่ 2-11

$$v_t = \gamma v_{t-1} + \alpha \frac{\partial J_t}{\partial w} \quad (2-11)$$

$$w_t = w_{t-1} - v_t \quad (2-12)$$

เมื่อ v คือ ค่าความเร็วที่มีการปรับพร้อมกับค่าน้ำหนัก

γ คือ ค่าสัมประสิทธิ์โมเมนตัม

2.1.3 การแพร่กระจายย้อนกลับ (Back propagation)

หลังจากข้อมูลนำเข้าถูกป้อนเข้าสู่โครงข่ายประสาทเทียม และได้รับการคำนวณผลลัพธ์ผ่านฟังก์ชันกระตุ้น และคำนวณค่าความผิดพลาดของเพอร์เซปตรอนในลำดับสุดท้ายด้วยการคำนวณอัตราการเปลี่ยนแปลงของฟังก์ชันต้นทุนเทียบกับค่าผลลัพธ์ในชั้นใด ๆ ในการหาค่าความผิดพลาดของเพอร์เซปตรอน จะใช้วิธีการแพร่กระจายย้อนกลับคำนวณปรับค่าน้ำหนักของชั้นก่อนหน้า เพื่อให้ค่าน้ำหนักที่ถูกปรับในรอบต่อไปมีค่าที่ส่งผลให้ผลลัพธ์ที่ส่งออกมีความใกล้เคียงกับผลลัพธ์จริง และมีความผิดพลาดลดต่ำลง สามารถหาค่าความผิดพลาดดังแสดงในสมการที่ 2-13

$$\delta_j^l = \frac{\partial J}{\partial z_j^l} = \frac{\partial J}{\partial a_j^l} \frac{\partial a_j^l}{\partial z_j^l} = \frac{\partial J}{\partial a_j^l} g'(z_j^l) \quad (2-13)$$

เมื่อ δ_j^l คือ ค่าความผิดพลาดของเพอร์เซปตรอนตัวที่ j ในลำดับชั้นที่ l
 J คือ ฟังก์ชันต้นทุน
 a คือ ค่าผลลัพธ์ส่งออกในชั้นถัดไป
 z คือ ค่าผลรวมของโครงข่าย

การหาค่า $\frac{\partial J}{\partial a_j^l}$ ในลำดับชั้นก่อนหน้า ต้องคำนวณด้วยวิธีการแพร่กระจายย้อนกลับ โดยคำนวณเช่นเดียวกับการป้อนไปข้างหน้า แต่จะกลับทิศทางของการคำนวณดังแสดงในสมการที่ 2-14 ส่วนลำดับชั้นสุดท้ายนั้น สามารถคำนวณได้โดยตรงจากฟังก์ชันต้นทุน

$$\frac{\partial J}{\partial a_j^l} = \sum_{k=1}^m \frac{\partial J}{\partial z_k^{l+1}} \frac{\partial z_k^{l+1}}{\partial a_j^l} = \sum_{k=1}^m \delta_k^{l+1} w_{kj}^{l+1} \quad (2-14)$$

เมื่อ δ_k^{l+1} คือ ค่าความผิดพลาดของเพอร์เซปตรอนตัวที่ k ในลำดับชั้นที่ $l + 1$
 m คือ จำนวนเพอร์เซปตรอนในลำดับชั้นที่ $l + 1$
 w คือ ค่าน้ำหนัก

หลังจากคำนวณได้ค่าความผิดพลาดของลำดับชั้นแล้ว ให้นำไปเปรียบเทียบกับค่าน้ำหนัก และค่าความลำเอียง ดังสมการที่ 2-15 และ 2-16 เพื่อหาค่าที่เปลี่ยนไปเมื่อเทียบกับค่าความผิดพลาด แล้วปรับปรุงค่าน้ำหนักด้วยวิธี Stochastic gradient descent (Luus *et al.*, 2015) ตามสมการที่ 2-17

$$\frac{\partial J}{\partial w_{jk}^l} = \frac{\partial J}{\partial z_j^l} \frac{\partial z_j^l}{\partial w_{jk}^l} = \delta_j^l a_k^{l-1} \quad (2-15)$$

$$\frac{\partial J}{\partial b_j^l} = \frac{\partial J}{\partial z_j^l} \frac{\partial z_j^l}{\partial b_j^l} = \delta_j^l \quad (2-16)$$


$$w_{jk,t}^l = w_{jk,t-1}^l - \alpha a_{k,t}^{l-1} \delta_{j,t}^l \quad (2-17)$$

เมื่อ b คือ ค่าความลำเอียง (Bias)
 $w_{jk,t}^l$ คือ ค่าน้ำหนักที่ได้รับการปรับปรุง
 α คือ อัตราการเรียนรู้

จากนั้น ปรับปรุงค่าน้ำหนักให้มีความเหมาะสมในแต่ละรอบของการทำ Back propagation โดยทำซ้ำวิธีการเดียวกันไปเรื่อย ๆ ให้ครบทุกชั้นจนย้อนกลับไปถึงชั้นนำเข้าข้อมูลชั้นแรก จากนั้นคำนวณแบบ Feed forward เช่นเดียวกับตอนเริ่มการคำนวณ โดยทำซ้ำกระบวนการทั้งหมดจนค่าฟังก์ชันต้นทุนมีค่าลดลงตามค่าที่ได้กำหนดไว้


2.2 ข่ายประสาทคอนโวลูชัน (Convolution neural network: CNN)

CNN เป็นโครงข่ายประสาทเทียมประเภทหนึ่ง แต่มีความแตกต่างในเรื่องของสถาปัตยกรรมที่ให้ข้อสรุปที่ชัดเจนว่า ข้อมูลนำเข้าในโครงข่ายคือข้อมูลภาพ ทำให้สามารถใส่คุณสมบัติที่เกี่ยวกับภาพเพิ่มเข้าไปในสถาปัตยกรรมของโครงข่ายได้ เช่น การกรองค่า และการสกัดฟีเจอร์จากเนื้อภาพ (Convolutional layer) ส่งผลให้ Forward function มีประสิทธิภาพในการทำงาน และช่วยลดจำนวนพารามิเตอร์ภายในโครงข่ายลง ข้อมูลภาพที่นำเข้าโครงข่ายจะถูกแปลงให้อยู่ในรูปของ Array ได้ทั้งแบบสองมิติ และสามมิติ สถาปัตยกรรมของ CNN มีโครงสร้างหลัก ดังแสดงในภาพที่ 2-5



ภาพที่ 2-5 โครงสร้างของสถาปัตยกรรม CNN ทั้งหมด (Hu et al., 2015b)

จากภาพที่ 2-5 โครงข่ายจะทำหน้าที่รับข้อมูลนำเข้า เปลี่ยนให้อยู่ในรูปแบบอนุกรมของชั้นแอบแฝงโดยการสร้างชุดของเพอร์เซปตรอนที่เชื่อมต่อกับทุกเพอร์เซปตรอนทุกตัวในชั้นก่อนหน้า จากนั้นคำนวณ และปรับปรุงค่าน้ำหนักของทั้งโครงข่าย (ในโครงข่าย CNN คือ ค่าน้ำหนักคือค่าตัวกรอง) และส่งออกผลลัพธ์ในรูปแบบของเวกเตอร์ค่าคะแนนผ่านฟังก์ชันกระตุ้นในชั้นส่งออก โครงสร้างของสถาปัตยกรรม CNN สามารถปรับได้หลากหลายรูปแบบจากการนำชั้นต่าง ๆ มาเชื่อมต่อกัน เช่น AlexNet ในภาพที่ 2-6 เพื่อให้มีความเหมาะสมกับงานแต่ละประเภท



ภาพที่ 2-6 สถาปัตยกรรมโครงข่าย CNN AlexNet ซึ่งประกอบด้วย Convolution 5 ชั้น และ Fully connected 3 ชั้น ดัดแปลงจาก Cheng, Zhou, and Han (2016)

จากสถาปัตยกรรม CNN ในภาพที่ 2-5 และ 2-6 หากไม่นับรวมชั้นนำเข้า กับชั้นส่งออกผลลัพธ์แล้ว โครงข่าย CNN จะมีชั้นที่ใช้ในการคำนวณผลลัพธ์ในโครงข่ายจำนวน 3 ชั้น ได้แก่ ชั้น Convolutional ชั้น Pooling และชั้น Fully connected ดังนี้

2.2.1 ชั้นคอนโวลูชัน (Convolutional layer)

เป็นชั้นที่ทำหน้าที่สกัดฟีเจอร์ และคำนวณจำนวนเพอร์เซปตรอนที่เชื่อมกับข้อมูลภาพรับเข้าด้วยการ Dot Product กับค่าน้ำหนัก (ตัวกรอง) ดังแสดงในภาพที่ 2-7 ซึ่งค่าน้ำหนักนี้จะเป็นค่าที่ใช้ร่วมกันกับทุกการทำ Convolution ของข้อมูลรับเข้า ดังสมการที่ 2-18 และ 2-19

$$z_{ij}^l = \sum_{a=0}^{m-1} \sum_{b=0}^{m-1} w_{a,b}^l a_{i+a,j+b}^{l-1} + b^l \quad (2-18)$$

$$a_{ij}^l = g(z_{ij}^l) \quad (2-19)$$

เมื่อ z_{ij}^l คือ ผลลัพธ์จากการทำ Convolution ในลำดับชั้นที่ l
 a^{l-1} คือ ข้อมูลรับเข้าขนาด $N \times N$
 a_{ij}^l คือ ข้อมูลส่งออกตัวที่ ij ในลำดับชั้นที่ l
 w คือ ตัวกรองขนาด $m \times m$

37	0	152	147	84	0	689	773	634	712
235	162	255	238	206	11	816	818	887	916
184	159	154	255	233	40	861	1095	1056	874
0	11	124	253	255	107	648	842	790	698
38	109	247	240	169	0				
224	241	255	164	0	5				
x1	x0	x1							
x0	x1	x0	Convolutional kernel						
x1	x0	x1							

ภาพที่ 2-7 ตัวอย่างการทำ Convolution กับภาพขนาด $6 \times 6 \times 1$

จากภาพที่ 2-7 เป็นตัวอย่างการทำ Convolution โดยภาพนำเข้ามีขนาด $6 \times 6 \times 1$ ผลลัพธ์จะถูกส่งเข้าฟังก์ชันกระตุ้นเพื่อส่งออกผลลัพธ์ไปยังชั้นถัดไปเช่นเดียวกับโครงข่ายประสาทเทียม พารามิเตอร์ที่เกี่ยวข้องกับการคำนวณขนาดของผลลัพธ์ในชั้นถัดไป ได้แก่ จำนวนของตัวกรอง (Kernel size) ขนาดของตัวกรอง (Filter size) ขนาดการก้าวข้าม (Stride size) และจำนวนการเสริมเติม (Zero padding) สามารถคำนวณได้ตามสมการที่ 2-20 2-21 และ 2-22

$$W_{l+1} = \frac{(W_l - F + 2P)}{s} + 1 \quad (2-20)$$

$$H_{l+1} = \frac{(H_l - F + 2P)}{s} + 1 \quad (2-21)$$

$$D_{l+1} = K_l \quad (2-22)$$


เมื่อ W คือ ขนาดความกว้างของผลลัพธ์
 H คือ ขนาดความสูงของผลลัพธ์
 D คือ จำนวนชั้นของผลลัพธ์ (Channel)

K	คือ จำนวนของตัวกรอง
F	คือ ขนาดของตัวกรอง
S	คือ ขนาดการก้าวข้าม
P	คือ จำนวนการเสริมเติม
l	คือ ชั้นของโครงข่ายปัจจุบัน

ข้อมูลนำเข้าในภาพที่ 2-7 (ขนาด $6 \times 6 \times 1$) มีจำนวนของตัวกรอง (K) 1 ตัว มีขนาด $3 \times 3 \times 1$ ($F = 3$) ขนาดการก้าวข้าม (S) คือ 1 ไม่มีการเสริมเติม 0 (P) ดังนั้น ความกว้าง และความสูงของผลลัพธ์ที่ได้ในชั้นถัดไป คือ $(6 - 3 + (2 \times 0)) / 1 + 1$ มีค่าเท่ากับ 4×4 และมีความลึกเท่ากับจำนวนของตัวกรอง คือ 1 ดังนั้น ขนาดของผลลัพธ์ที่ได้ในชั้นถัดไป คือ ภาพขนาด $4 \times 4 \times 1$ จะเห็นได้ว่า ข้อมูลในชั้นถัดไปจะมีขนาด และมีติลดลงจากชั้นก่อนหน้า

2.2.2 ชั้นพูลลิง (Pooling layer)

หลังจากได้ค่าพีเจอร์จากการทำ Convolution แล้ว ข้อมูลจะถูกนำเข้าสู่ชั้น Pooling ซึ่งมีหน้าที่ในการลดขนาดของรูปภาพลง โดยการสกัดเอาพีเจอร์ที่โดดเด่น ดังภาพที่ 2-8 วิธีการทำ Pooling มีหลายวิธี ซึ่งวิธีที่นิยมใช้ คือ ค่า Pooling แบบเฉลี่ย (Mean pooling) อย่างไรก็ตาม ในงานวิจัยนี้ ได้เลือกใช้วิธีค่า Pooling แบบสูงสุด (Max pooling) เนื่องจากวัตถุประสงค์ที่ต้องการสกัดค่าที่เด่นที่สุดของภาพออกมา



ภาพที่ 2-8 การทำ Pooling แบบค่าสูงสุด

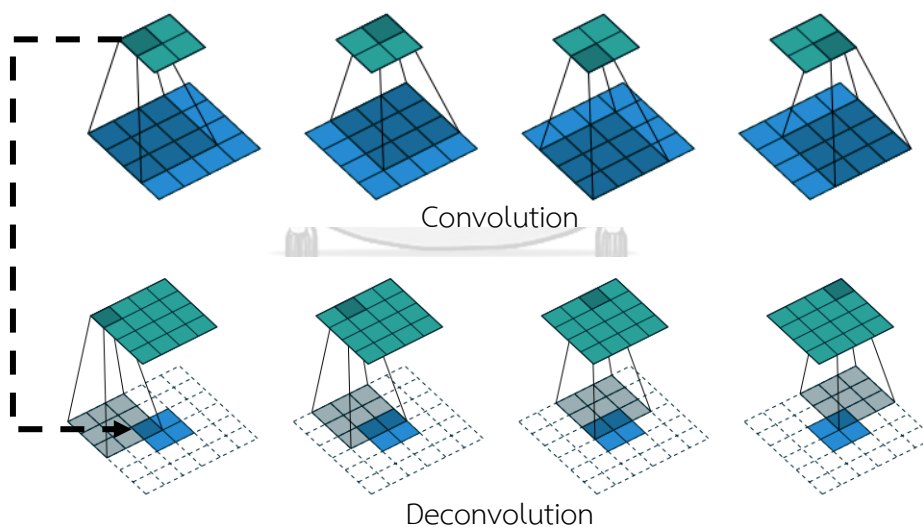
2.2.3 ชั้นเชื่อมโยงแบบเต็มรูปแบบ (Fully connected layer)

ชั้นสุดท้ายของโครงข่ายเป็นชั้นของการเชื่อมโยงแบบเต็มรูปแบบ (Fully connected layer) เปรียบเสมือนกับชั้นแอมพลิงในข่ายประสาทเทียมทั่วไป เป็นชั้นที่ประกอบด้วยชั้นของเพอร์

เซปตรอน โดยแต่ละตัวจะมีเส้นเชื่อมโยงกับทุกเพอร์เซปตรอนในชั้นก่อนหน้า และชั้นต่อไป การทำ Feed forward เดียวกับชั้นแอบแฝงในข่ายประสาทเทียมทำได้ด้วยวิธีการปกติ

2.2.4 ชั้นทรานโพสคอนโวลูชัน (Transposed convolutional layer)

ชั้นทรานโพสคอนโวลูชันใช้เพื่อจำแนกทางความหมายของภาพ ผลการจำแนกจะมีขนาดความละเอียดของจำนวนจุดภาพเท่ากับภาพที่ได้นำเข้าสู่โครงข่ายด้วยวิธีการเพิ่มความละเอียดของจุดภาพ (Upsampling) วิธีการนี้เป็นการปรับปรุงวิธีการจำแนกให้เป็นแบบ Dense prediction for per-pixel tasks ให้มีลักษณะแบบ Semantic segmentation (Dumoulin and Visin, 2016; Long *et al.*, 2015) ในบางงานวิจัย จะเรียกชั้นทรานโพสคอนโวลูชันว่า ดีคอนโวลูชัน หรือแฟรคชันนัลคอนโวลูชัน (Shi *et al.*, 2016) ลักษณะการทำงานของชั้นทรานโพสคอนโวลูชัน จะเป็นการสลับฟังก์ชันของ Forward pass และ Backward pass ของชั้นคอนโวลูชันส่งผลให้จำนวนจุดภาพหลังการประมวลผลมีจำนวนเพิ่มขึ้น ภาพที่ 2-9 เป็นตัวอย่างการแสดงกระบวนการคอนโวลูชัน และ ดีคอนโวลูชัน



ภาพที่ 2-9 ตัวอย่างการทำคอนโวลูชัน และทรานโพสคอนโวลูชันกับภาพขนาด 4×4 จุดภาพ
ดัดแปลงจาก (Dumoulin and Visin, 2016)

จากภาพที่ 2-9 ภาพที่นำเข้าสู่โครงข่ายมีขนาด 4×4 จุดภาพ ในการทำคอนโวลูชัน กำหนดให้ขนาดของตัวกรองมีขนาด 3×3 จำนวนการก้าวข้ามมีค่า 1 และการเสริมค่ามีค่า 0 ($f = 3$, $s = 1$ และ $p = 0$) ผลลัพธ์จากกระบวนการคอนโวลูชันมีขนาด 2×2 จุดภาพ เมื่อทำ

การทรานโพลคอนโวลูชัน จะปรับค่าพารามิเตอร์ โดย $f' = f, s' = s$, และ $p' = f - 1$ ค่าผลลัพธ์ที่ได้จะมีขนาดดังสมการที่ 2-23

$$o' = i' + (f - 1) \quad (2-23)$$

เมื่อ	o'	คือ	ผลลัพธ์ที่ได้จากการทรานโพลคอนโวลูชัน
	i'	คือ	ภาพนำเข้าสู่กระบวนการทรานโพลคอนโวลูชัน
	f	คือ	ขนาดของตัวกรอง

จากสมการที่ 2-23 และภาพที่ 2-9 ภาพผลลัพธ์ที่ได้จากกระบวนการการทรานโพลคอนโวลูชันจะมีขนาด 4×4 จุดภาพ $(2 + (3 - 1) = 4)$ เท่ากับขนาดของภาพที่ส่งเข้ากระบวนการคอนโวลูชันในตอนแรก

2.2.5 การแพร่กระจายย้อนกลับและการสอน (Back propagation and training)

กระบวนการแพร่กระจายย้อนกลับ และการสอนเป็นไปในลักษณะเดียวกับข่ายประสาทเทียมแบบทั่วไป โดยคำนวณอัตราการเปลี่ยนแปลงของฟังก์ชันต้นทุนเทียบค่าผลลัพธ์ในชั้นใด ๆ ตามสมการที่ 2-13 (ในหัวข้อ 2.1.3) การหาค่า $\frac{\partial J}{\partial a_{ij}^l}$ สามารถหาได้จากการแพร่กระจายย้อนกลับดังสมการที่ 2-24

จากนั้น คำนวณหาค่าความผิดพลาดเทียบกับน้ำหนัก และค่าความลำเอียงใด ๆ ในชั้นก่อนหน้า โดยคำนวณเทียบอัตราการเปลี่ยนแปลงกับค่าความผิดพลาดของในแต่ละระดับชั้น ดังสมการที่ 2-25 และ 2-26

$$\frac{\partial J}{\partial a_{ij}^l} = \sum_{a=0}^{m-1} \sum_{b=0}^{m-1} \frac{\partial J}{\partial z_{i-a,j-b}^{l+1}} \frac{\partial z_{i-a,j-b}^{l+1}}{\partial a_{ij}^l} \quad (2-24)$$

$$\frac{\partial J}{\partial w_{ab}^l} = \sum_{i=0}^{N-m} \sum_{j=0}^{N-m} \frac{\partial J}{\partial z_{ij}^l} \frac{\partial z_{ij}^l}{\partial w_{ab}^l} = \sum_{i=0}^{N-m} \sum_{j=0}^{N-m} \delta_{ij}^l a_{i+a,j+b}^{l-1} \quad (2-25)$$

$$\frac{\partial J}{\partial b^l} = \sum_{i=0}^{N-m} \sum_{j=0}^{N-m} \frac{\partial J}{\partial z_{ij}^l} \frac{\partial z_{ij}^l}{\partial b^l} = \sum_{i=0}^{N-m} \sum_{j=0}^{N-m} \delta_{ij}^l \quad (2-26)$$

เมื่อ	m	คือ	ขนาดของตัวกรองในชั้นคอนโวลูชัน
	N	คือ	ขนาดของข้อมูลที่รับเข้าในชั้นที่ N

2.3 การวัดประสิทธิภาพ

วัดประสิทธิภาพของการจำแนกด้วยเมตริกซ์ค่าคลาดเคลื่อน (Confusion matrix) เพื่อตรวจสอบความถูกต้องของผลการจำแนกโดยเปรียบเทียบระหว่างข้อมูลผลลัพธ์กับข้อมูลอ้างอิง (Congalton and Green, 2009) ดังตารางที่ 2-1

ตารางที่ 2-1 ตารางการวัดค่าคลาดเคลื่อน (Confusion matrix)

		คลาสอ้างอิง				
		1	2	3	k	n_{i+}
คลาสที่จำแนก	1	n_{11}	n_{12}	n_{13}	n_{1k}	n_{1+}
	2	n_{21}	n_{22}	n_{23}	n_{2k}	n_{2+}
	3	n_{31}	n_{32}	n_{33}	n_{3k}	n_{3+}
	k	n_{k1}	n_{k2}	n_{k3}	n_{kk}	n_{k+}
	n_{+i}	n_{+1}	n_{+2}	n_{+3}	n_{+k}	n

เมื่อ i คือ จำนวนแถว และหลัก

k คือ จำนวนชั้นการจำแนก

n_{kk} คือ จุดภาพที่จำแนกตรงกับชั้นข้อมูลอ้างอิง

n_{+i} คือ จำนวนจุดภาพทั้งหมดของข้อมูลอ้างอิงในชั้นข้อมูลที่ i ที่เป็นชั้นข้อมูลอ้างอิง

n_{i+} คือ จำนวนจุดภาพที่จำแนกเป็นชั้นข้อมูล i

n คือ จำนวนจุดภาพทั้งหมด

จากตารางที่ 2-1 ค่าข้อมูลคลาสใด ๆ ที่อยู่ในแถวจะแสดงถึงข้อมูลที่อยู่ในคลาสนั้นจริง (ข้อมูลจากการสำรวจภาคสนาม) ส่วนค่าข้อมูลในแต่ละสดมภ์ เป็นค่าที่จำแนกได้ในคลาสนั้น ๆ สามารถใช้เพื่อคำนวณความถูกต้องของการจำแนกในการศึกษาได้โดยสามารถแบ่งเป็นการหาค่าความถูกต้องแบบต่าง ๆ (Watanakij and Vaiphasa, 2016) ดังนี้

2.3.1 ความถูกต้องโดยรวม (Overall accuracy)

เป็นการวัดค่าความถูกต้องของผลลัพธ์ที่ได้จากการจำแนก กับข้อมูลภาคสนาม คำนวณจากผลรวมข้อมูลที่จำแนกได้คลาสนั้นตรงกับผลลัพธ์ที่ต้องการ ตามแนวทแยงของตาราง ดังสมการที่ 2-27

$$\text{Overall Accuracy} = \frac{\sum_{i=1}^5 n_{ii}}{n} \times 100 \quad (2-27)$$

2.3.2 ความถูกต้องของผู้ใช้ (User's Accuracy)

ใช้วัดค่าความน่าจะเป็นที่ผลลัพธ์จำแนกได้ตรงกับคลาสอ้างอิง เพื่อดูว่าการวิเคราะห์จำแนกมีความถูกต้องที่ค่าเท่าไร คำนวณจากผลลัพธ์ของคลาสนั้น ๆ ที่จำแนกได้ว่าเป็นคลาสดังกล่าว มีจำนวนเท่าไรหารกับผลลัพธ์ที่จำแนกเป็นคลาสนั้น ๆ ทั้งหมด ดังสมการที่ 2-28

$$\text{User's Accuracy} = \frac{n_{ii}}{n_{i+}} \times 100 \quad (2-28)$$

2.3.3 ความถูกต้องของผู้ผลิต

ใช้วัดค่าความน่าจะเป็นของคลาสอ้างอิงในพื้นที่ที่จำแนก ได้ถูกจำแนกเป็นคลาสดังกล่าวอย่างถูกต้องจำนวนเท่าใด เพื่อดูว่าแผนที่ที่ได้รับการวิเคราะห์มีความถูกต้องเท่าใด โดยคำนวณจากจุดภาพที่จำแนกที่ตรงกับจุดภาพอ้างอิงหารด้วยจำนวนจุดภาพอ้างอิงทั้งหมดในชั้นการจำแนกนั้น ตามสมการที่ 2-29

$$\text{Producer's Accuracy} = \frac{n_{ii}}{n_{+i}} \times 100 \quad (2-29)$$

2.3.4 ค่าสถิติโคเฮนส์ แคปปา (Cohen's Kappa)

ผลที่ได้จากการวิเคราะห์ สามารถจำแนกความถูกต้องได้สองกรณี คือ ความถูกต้องจากการจำแนกข้อมูลภาพจากดาวเทียม และความถูกต้องจากการตีความหมายข้อมูลภาคพื้นดิน ในการทดสอบว่า ความถูกต้องของข้อมูลทั้งสองกลุ่มมีความสอดคล้องกันหรือไม่ จำเป็นต้องวิเคราะห์โดยเลือกค่าสถิติที่เหมาะสมมาใช้เป็นเครื่องมือ Cohen's kappa coefficient เป็นค่าสถิติที่ใช้ทดสอบความสอดคล้อง (Consistency) ของข้อมูลสองกลุ่ม (เช่น ข้อมูลที่ได้จากการแปลตีความเปรียบเทียบกับข้อมูลที่ได้จากการสำรวจ) ในบางกรณีอาจใช้ในการเปรียบเทียบการประเมินค่าของข้อมูลชุดเดียวกันจากผู้ประเมินสองคน (Anthony and Joanne, 2005) ดังสมการที่ 2-30

$$K = \frac{P(O) - P(E)}{1 - P(E)} \quad (2-30)$$

เมื่อ $P(O)$ คือ ค่าความสอดคล้องของข้อมูลที่จำแนก

$P(E)$ คือ ค่าความสอดคล้องของข้อมูลที่อ้างอิง

ค่าโคเฮนส์ แคปปา สามารถแบ่งออกได้เป็นสามช่วง (Congalton and Green, 2009) ได้แก่ 1) มากกว่า 0.8 หมายถึงมีความสอดคล้องกันมาก 2) ระหว่าง 0.4 ถึง 0.8 หมายถึง มีความสอดคล้องกันปานกลาง และ 3) น้อยกว่า 0.4 มีความสอดคล้องกันต่ำ

2.3.5 ค่าสถิติการทดสอบ Z

ในกรณีที่ต้องการเปรียบเทียบผลการจำแนกที่วิเคราะห์ด้วยวิธีการที่ต่างกัน ต้องเปรียบเทียบความถูกต้องจากเมตริกซ์ค่าคลาดเคลื่อนของแต่ละการจำแนกว่าค่าความถูกต้องที่นำมาเปรียบเทียบกันนั้นมีความแตกต่างกันอย่างมีนัยสำคัญหรือไม่ (Watanakij and Vaiphasa, 2016) โดยนำค่าโคเฮนส์ แคปปามาทดสอบค่าสถิติ Z (Congalton and Green, 2009) ดังสมการที่ 2-31

$$Z = \frac{|\hat{K}_1 - \hat{K}_2|}{\sqrt{\hat{v}\hat{a}r(\hat{K}_1) - \hat{v}\hat{a}r(\hat{K}_2)}} \quad (2-31)$$

เมื่อ \hat{K}_1, \hat{K}_2 คือ ค่าประมาณแคปปาของเมตริกซ์ค่าคลาดเคลื่อน 1 และ 2
 $\hat{v}\hat{a}r(\hat{K}_1) - \hat{v}\hat{a}r(\hat{K}_2)$ คือ ค่าประมาณความแปรปรวนของแคปปา

จากสมการที่ 2-31 ค่าสถิติ Z เป็นค่ามาตรฐาน และมีการแจกแจงแบบปกติ กำหนดให้สมมติฐานหลัก $H_0: (K_1 - K_2) = 0$ (ค่าไม่แตกต่าง) และสมมติฐานรอง $H_1: (K_1 - K_2) \neq 0$ (ค่ามีความแตกต่าง) โดยที่ H_0 จะถูกปฏิเสธเมื่อ $Z \geq Z_{\alpha/2}$ เมื่อ $\alpha/2$ คือค่าระดับความเชื่อมั่นของการทดสอบค่าสถิติ Z แบบสองทาง และให้ห้องศาสีสระมีค่านันต์

2.4 มวลชีวภาพเหนือพื้นดิน

มวลชีวภาพเหนือพื้นดิน (Above ground biomass: AGB) เป็น 1 ใน 5 ตัวชี้วัดด้านระบบนิเวศน์วิทยาทะเลน้ำจืด (Terrestrial ecosystem) จากคณะกรรมการระหว่างรัฐบาลว่าด้วยการเปลี่ยนแปลงสภาพภูมิอากาศ (The intergovernmental on climate change: IPCC) ที่ใช้ประเมินถึงปริมาณคาร์บอนที่กักเก็บในอ่างคาร์บอน (Carbon pool) โดยให้มีสัดส่วนที่ร้อยละ 30 ของปริมาณการกักเก็บทั้งหมด (Kumar and Mutanga, 2017) โดยต้นไม้จะดูดซับก๊าซคาร์บอนไดออกไซด์จากบรรยากาศมาเก็บไว้ตามส่วนประกอบต่าง ๆ ของต้นไม้ผ่านกระบวนการสังเคราะห์ด้วยแสง (Vashum, 2012) ทำให้สามารถประมาณค่ามวลชีวภาพเหนือพื้นดินได้จากการวัดจากปริมาณน้ำหนักจากส่วนประกอบของลำต้นเหนือพื้นดิน ได้แก่ ลำต้น กิ่ง ก้าน ใบ และผล ในการประมาณค่ามวลชีวภาพ นิยมใช้วิธีการประเมินอยู่ 2 วิธี วิธีการแรกเป็นการเก็บตัวอย่างในพื้นที่ศึกษาเพื่อนำไปทดสอบในห้องปฏิบัติการ โดยตัดต้นไม้ที่ถูกสุ่มตัวอย่าง (Destructive sampling) ไป

ซึ่งนำหนักเพื่อหามวลชีวภาพ (Njana *et al.*, 2016b) ส่งผลให้ต้องสูญเสียต้นไม้บางส่วนในพื้นที่ศึกษา วิธีการที่สองเป็นการตรวจวัดมวลชีวภาพโดยไม่ตัดต้นไม้ตัวอย่าง (Non-destructive sampling) วิธีนี้ใช้การหาความสัมพันธ์ของมวลชีวภาพกับส่วนประกอบของต้นไม้ พารามิเตอร์ที่นิยมใช้ ได้แก่ เส้นผ่านศูนย์กลางเพียงอก (Diameter at breast height: DBH) และความสูงของต้นไม้ (Chave *et al.*, 2014; Kenzo *et al.*, 2009; Komiyama *et al.*, 2005; Ostadhashemi *et al.*, 2014; Patil *et al.*, 2014; Vashum, 2012) วิธีดังกล่าวจะใช้การวัดค่าพารามิเตอร์แล้วนำมาคำนวณทางสถิติเพื่อสร้างสมการอัลโลเมตรีแสดงความสัมพันธ์ และใช้เป็นตัวแทนในการคำนวณมวลชีวภาพ ซึ่งเป็นวิธีการที่เหมาะสมในการประมาณมวลชีวภาพในเขตป่าที่อนุรักษ์ เช่น พื้นที่ป่าชายเลน เป็นต้น

2.4.1 การประมาณค่ามวลชีวภาพเหนือพื้นดิน

จากงานวิจัยที่ผ่านมาของ Komiyama *et al.* (2005) พบว่า ชีวมวลเหนือพื้นดินของลำต้น หรือน้ำหนักของลำต้น (Trunk weight) เป็นฟังก์ชันของรูปร่างภายนอก และความหนาแน่นจำเพาะเนื้อไม้ โดยรูปร่างภายนอกของลำต้นสามารถประเมินได้จากความสัมพันธ์ระหว่างปริมาตรของลำต้น (Trunk volume: V_G) และกำลังสองของเส้นผ่านศูนย์กลางที่ความสูงเพียงอกคูณกับความสูงของต้นไม้ (D^2H) เช่นเดียวกับ Feliciano *et al.* (2014) ที่ประมาณค่าชีวมวลเหนือพื้นดินของลำต้นไม้ป่าชายเลนด้วยการวัดค่าปริมาตรของลำต้น แล้วนำมาคูณกับความหนาแน่นจำเพาะเนื้อไม้ (Feliciano *et al.*, 2014; Njana *et al.*, 2016b; Olagoke *et al.*, 2016) ดังสมการที่ 2-32 โดยเก็บค่าพารามิเตอร์ที่จำเป็นต้องใช้ในการคำนวณด้วยเครื่อง Terrestrial Laser Scanner แยกลำต้นเป็นส่วน ๆ และนำข้อมูลที่ได้นำมาคำนวณหาปริมาตรของลำต้นด้วยวิธี Smalian's formula ดังสมการที่ 2-33

$$AGB = V_e \times WSD \quad (2-32)$$

เมื่อ V_e คือ ค่าประมาณปริมาตรของลำต้น
 WSD คือ ค่าความหนาแน่นจำเพาะของเนื้อไม้

$$V = \frac{(A_T + A_B)}{2} \times h = \frac{\left(\frac{\pi D_T^2}{4} + \frac{\pi D_B^2}{4}\right)}{2} \times h \quad (2-33)$$

เมื่อ	V	คือ ปริมาตรส่วนของลำต้น
	A_T	คือ พื้นที่หน้าตัดขวางของลำต้นส่วนบน
	A_B	คือ พื้นที่หน้าตัดขวางของลำต้นส่วนล่าง
	h	คือ ความยาวของลำต้น
	D_T	คือ เส้นผ่านศูนย์กลางของลำต้นส่วนบน
	D_B	คือ เส้นผ่านศูนย์กลางของลำต้นส่วนล่าง

จากสมการที่ 2-33 จะได้ปริมาตรของลำต้นเพียงส่วนที่คำนวณ ในการจะหาปริมาตรของทั้งลำต้น ต้องนำปริมาตรทั้งหมดมารวมกันเป็นปริมาตรรวมของลำต้น จากนั้นคำนวณร่วมกับค่าความหนาแน่นจำเพาะของเนื้อไม้ เพื่อได้ค่ามวลชีวภาพของลำต้นของตัวอย่างทั้งหมด

2.4.2 การสร้างความสัมพันธ์อัลโลเมตรี

วิธีการศึกษามวลชีวภาพด้วยวิธีการอ้อม (Indirect method) วิธีที่นิยมใช้เป็นการหาความสัมพันธ์แบบอัลโลเมตรี (Allometric relationship) ซึ่งมีความสัมพันธ์แบบไม่เชิงเส้นยกกำลัง ตามสมการที่ 2-34 เรียกความสัมพันธ์แบบนี้ว่า Power law (Sileshi, 2014)

$$B_i = aX_i^b + \varepsilon_i \quad (2-34)$$

เมื่อ	B_i	คือ ค่ามวลชีวภาพเหนือดิน (mg)
	X_i	คือ ค่า DBH ตัวอย่างที่ i ของต้นไม้
	a, b	คือ ค่าคงที่
	ε_i	คือ ค่าคลาดเคลื่อนจากการเก็บตัวอย่างที่ i

จากการหาค่าความสัมพันธ์ จะมีค่า r^2 เป็นตัวที่ใช้ตรวจสอบว่าแบบจำลอง กับข้อมูลที่ ใช้สร้างความสัมพันธ์มีความสอดคล้องกันหรือไม่

2.4.3 การแปรของค่าคลาดเคลื่อน

เพื่อเป็นการลดความไม่แน่นอนของผลที่ได้จากการวิเคราะห์ การปรับแก้ค่าคลาดเคลื่อนของค่าประมาณมวลชีวภาพสามารถหาได้จากสมการการแปรของค่าคลาดเคลื่อน (Feliciano *et al.*, 2014) โดยคำนวณค่าคลาดเคลื่อนของมวลชีวภาพเหนือพื้นดินลำต้น ดังสมการที่ 2-35 และค่าคลาดเคลื่อนของมวลชีวภาพเหนือพื้นดินรวม ดังสมการที่ 2-36

$$\frac{\delta AGB_{stem}}{|AGB_{stem}|} = \sqrt{2 \left(\frac{\delta D}{D}\right)^2 + \left(\frac{\delta H}{H}\right)^2 + \left(\frac{\delta WSD}{WSD}\right)^2} \quad (2-35)$$

$$\delta AGB_{Total} = \sqrt{(\delta AGB_{stem})^2 + (\delta AGB_{canopy})^2} \quad (2-36)$$

เมื่อ δAGB_{stem} คือ ค่าคลาดเคลื่อนของมวลชีวภาพของลำต้น

δAGB_{canopy} คือ ค่าคลาดเคลื่อนของมวลชีวภาพของเรือนยอด

2.5 การวัดค่าคลาดเคลื่อนของผลลัพธ์

ค่าคลาดเคลื่อนของผลลัพธ์สามารถทำได้ด้วยการเปรียบเทียบค่าประมาณมวลชีวภาพจากเครื่อง TLS กับค่าประมาณมวลชีวภาพที่ได้จากสมการอัลโลเมตรีอ้างอิงด้วยค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ย (Olagoke *et al.*, 2016) หรือ Root mean square error: RMSE ดังสมการที่ 2-37


$$RMSE = \sqrt{\frac{\sum_{i=1}^n (AGB_{allometry} - AGB_{TLS})^2}{n}} \quad (2-37)$$

เมื่อ $AGB_{allometry}$ คือ ค่าประมาณมวลชีวภาพที่ได้จากสมการอัลโลเมตรีมาตรฐาน

AGB_{TLS} คือ ค่าประมาณมวลชีวภาพที่ได้จาก TLS

2.6 ข้อมูลภาพถ่ายจากดาวเทียมที่ใช้ในการศึกษา

ข้อมูลภาพถ่ายจากดาวเทียมที่ใช้ในการศึกษาครั้งนี้ จะใช้ข้อมูลจากภาพถ่ายจากดาวเทียมสำรวจทรัพยากรธรรมชาติ Quickbird ซึ่งเป็นภาพถ่ายจากดาวเทียมเชิงพานิชย์รายละเอียดเชิงพื้นที่สูง มีรายละเอียดในช่วงคลื่นเดี่ยว (Panchromatic mode) ที่ 0.61 เมตร และรายละเอียดในหลายช่วงคลื่น (Multispectral mode) ที่ 2.44 เมตร ภาพที่ 2-10 มีการโคจรกลับมายังพื้นที่เดิมทุก 3 - 6 วัน ดังรายละเอียดในตารางที่ 2-2



ภาพที่ 2-10 ภาพถ่ายจากดาวเทียม Quickbird แบบหลายช่วงคลื่น

ตารางที่ 2-2 รายละเอียดคุณสมบัติของดาวเทียม Quickbird ดัดแปลงจาก (Khorram *et al.*, 2012)

คุณสมบัติ	รายละเอียด
Sensor (Mission)	QuickBird
Organization	DigitalGlobe, USA
Operation period	2001 – Present
Swath Width (km)	16.5
Spatial resolution (m)	0.65 (PAN), 2.62 (MS)
Temporal resolution	2.5 – 5.6 วัน
Radiometric resolution	11 –bit
Spectral resolution (μm)	0.405 – 1.053 (PAN)
	0.450 – 0.520 (Blue)
	0.520 – 0.600 (Green)
	0.630 – 0.690 (Red)
Spectral bands	0.760 – 0.900 (Near IR)
	4 + PAN

ในตารางที่ 2-2 ช่วงคลื่น Panchromatic จะมีพิสัยกว้าง ครอบคลุมในทุกช่วงคลื่นของ Multispectral และยังมีรายละเอียดที่สูงกว่า ทำให้สามารถมองเห็นลักษณะเนื้อภาพของวัตถุในพื้นที่ศึกษาได้ชัดเจน แต่ก็มีสิ่งที่ต้องแลกกับรายละเอียดของภาพ (Trade off) คือ จะมีเพียงหนึ่งช่วงคลื่นเท่านั้น ในการทำงาน นิยมนำภาพ Panchromatic มาหลอมรวม (Image fusion) กับ ภาพ Multispectral ซึ่งจะช่วยให้การแปลภาพด้วยสายตาทำได้ละเอียด และง่ายขึ้นกว่าเดิม ในส่วนของการวิเคราะห์จำแนกภาพถ่ายดาวเทียมด้วยคอมพิวเตอร์ ไม่เป็นที่นิยม เนื่องจากการหลอมรวมภาพ ทำให้ค่าในแต่ละจุดภาพเปลี่ยนไปจากเดิม อย่างไรก็ตาม ได้มีการนำเทคนิคทางด้าน Deep learning มาช่วยในกระบวนการหลอมรวมภาพ (Zhong *et al.*, 2016) ทำให้ค่าของแต่ละจุดภาพ มีการเปลี่ยนแปลงน้อยลงกว่าวิธีปกติในระดับที่ยอมรับได้ทางสถิติ

2.7 เครื่องสแกนเลเซอร์ภาคพื้นดิน

เครื่องสแกนเลเซอร์ภาคพื้นดิน (Terrestrial laser scanner: TLS) เป็นอุปกรณ์เลเซอร์ที่ใช้ระบบ LiDAR สำหรับการวัดระยะทาง และมุมที่ให้ความแม่นยำผ่านกลไกการตรวจวัดลำแสงช่วงที่ตามองเห็น (Optical beam detection) เพื่อสร้าง Point cloud แบบสามมิติของพื้นผิววัตถุเป้าหมาย มีสองเทคนิคหลักที่ใช้ในการวัดค่าระยะทาง ได้แก่ Phase shift (PS) และ Time-of-flight (tof) ซึ่งในปัจจุบัน TLS ใช้เทคนิค tof เป็นมาตรฐาน โดยหลักการทำงานจะบันทึกสัญญาณ Backscatter ที่สะท้อนกลับมายังเครื่องรับซึ่งสามารถรับสัญญาณได้ทั้งแบบ One return และ Multi-return โดยแบบหลังจะให้ปริมาณจุดพิกัดสามมิติที่หนาแน่นเมื่อเทียบกับแบบแรก (Calders *et al.*, 2015) การสแกนในแต่ละครั้งสามารถเก็บค่าจุดพิกัดสามมิติจำนวนมาก ระยะเวลาที่ใช้ขึ้นอยู่กับโหมดการเก็บข้อมูล เครื่อง TLS มีผู้ผลิตออกสู่ตลาดหลายบริษัท เช่น Topcon FARO Leica system GeoSystem ฯลฯ สามารถวัดรายละเอียดได้มากที่สุดกว่า 1 ล้านจุดต่อวินาทีที่ระยะ 100 – 300 เมตร โดยมีความแม่นยำที่ระดับมิลลิเมตร และบูรณาการค่า RGB ที่ได้จากการถ่ายภาพเป้าหมายมาใส่ค่าให้กับจุดพิกัดสามมิติแต่ละจุด

ในการเก็บข้อมูลต้นไม้ด้วย TLS สำหรับการศึกษาด้านป่าไม้ Maas *et al.* (2008) ได้แนะนำถึงความต้องการขั้นต่ำของ TLS เชิงเทคนิค ไว้ดังนี้

- 1) ระยะทางต่ำสุดในการเก็บข้อมูลจาก TLS ถึงเป้าหมายจะต้องมีระยะทางไม่ต่ำกว่า 50 เมตร
- 2) จำนวนจุดการสแกนขั้นต่ำต้องไม่ต่ำกว่า 10,000 จุด ต่อ วินาที
- 3) ค่าขอบเขตการมองเห็น (Field of view) แบบ Hemisphere
- 4) ค่าความละเอียดของจุดต้องมีขนาดไม่เกิด 10 มิลลิเมตร

ในการวัดค่าพารามิเตอร์ของต้นไม้ (ส่วนประกอบของต้นไม้) Liang *et al.* (2016) ได้เสนอแบบจำลองสำหรับใช้ในการวัดค่าอยู่สองแบบจำลอง ได้แก่ แบบจำลอง Single tree และแบบจำลอง Individual tree

1) แบบจำลอง Single tree เป็นวิธีการเก็บข้อมูลส่วนประกอบของต้นไม้อย่างละเอียดในการเก็บข้อมูลแต่ละครั้ง จะวัดค่าต้นไม้ครั้งละต้น และวัดอย่างละเอียด ตั้งสถานีวัดอย่างน้อย 3 สถานีต่อต้น พร้อมเป่าสำหรับการ Register จุดพิกัดสามมิติ การวัดค่าจะตั้งความละเอียดของจุดพิกัดสามมิติให้สูงที่สุด วิธีการนี้ใช้เวลาในการวัดนาน แต่ให้ค่าความละเอียดของข้อมูลสูง

2) แบบจำลอง Individual tree เป็นวิธีการเก็บข้อมูลต้นไม้หลายต้นต่อการทำงานหนึ่งครั้ง วิธีการเก็บข้อมูลจะกำหนดพื้นที่สำหรับการเก็บตัวอย่าง (Plot) โดยมีรัศมีขนาดตั้งแต่ 20 ถึง 40 เมตร (Feliciano *et al.*, 2014; Liang *et al.*, 2018; Maas *et al.*, 2008; Olagoke *et al.*, 2016; Zhang *et al.*, 2019b) การเก็บข้อมูลจะตั้งกล้องที่จุดกึ่งกลางของพื้นที่เก็บตัวอย่าง 1 สถานี และตั้งบริเวณโดยรอบพื้นที่เก็บตัวอย่าง 4 สถานี พร้อมตั้งเป้าอ้างอิงสำหรับการ Register ข้อมูลจุดพิกัดสามมิติ จากนั้น สแกนข้อมูลต้นไม้ โดยหลังจากการ Register จุดพิกัดสามมิติแล้ว จะได้ข้อมูลต้นไม้ทั้งหมดในพื้นที่เก็บตัวอย่าง

การเก็บข้อมูลจุดพิกัดสามมิติจากพื้นที่ตัวอย่าง (Sample plot) สามารถทำได้ 3 วิธี (Liang *et al.*, 2016) ได้แก่

1) Single scan mode ตั้งเครื่องสแกนเลเซอร์ภาคพื้นดิน ไว้ตรงกลางของพื้นที่ตัวอย่าง แล้วดำเนินการสแกนแบบ Full field of view (เช่น 360×310 องศา) ข้อมูลที่ได้จากการสแกนจะถูกเก็บเป็น Single scan point cloud ปัญหาที่มักเกิดขึ้นจากการใช้วิธีนี้ คือ วัตถุที่กีดขวางการสแกน (Occlusion effect)

2) Multi-scan mode ดำเนินการสแกนหลายครั้งทั้งพื้นที่ด้านใน และด้านนอกของพื้นที่ตัวอย่าง เพื่อเป็นการเพิ่มปริมาณข้อมูลจุดพิกัดสามมิติ จากนั้น รวมข้อมูลจุดพิกัดสามมิติ โดยการ Register อ้างอิงจากค่าของเป้าหมายอ้างอิง (Referenced target) ที่ตั้งอยู่ด้านนอกพื้นที่ศึกษา ทำให้ได้ค่าข้อมูลที่แม่นยำ แต่ต้องแลกกับระยะเวลาที่ใช้ในการทำงาน

3) Multi-single scan mode เป็นการผสมวิธีทั้งสองวิธีข้างต้นเข้าด้วยกัน โดยการทำงานจะคล้ายกับ Multi-scan mode สแกนทั้งด้านใน และด้านนอกพื้นที่ตัวอย่าง แต่จะไม่ใช้เป้าหมายอ้างอิง โดยจะ Register ค่าอ้างอิงในระดับพีเจอร์ ในการเก็บข้อมูล จะสแกนข้อมูลต้นไม้ในพื้นที่อ้างอิง โดยในแต่ละการสแกน จะใช้ต้นไม้เป้าหมายเป็นเป้าหมายอ้างอิง ไปในตัว ซึ่งจะช่วยลดปัญหาวัตถุที่กีดขวาง และเวลาในการทำงาน แต่อาจประสบปัญหาในการรวมข้อมูลจุดพิกัดสามมิติเชิงเดี่ยว (Single point cloud) เนื่องจากค่าคลาดเคลื่อนจากสิ่งแวดล้อม และเป้าหมาย เช่น ลมที่เกิดขึ้นในพื้นที่ศึกษาที่ส่งผลต่อการเคลื่อนตัวของเป้าหมาย ต้องเก็บข้อมูลในช่วงเวลาที่เหมาะสม

ค่าคลาดเคลื่อนจากการวัดส่วนใหญ่เกิดจากการทำงานสนาม ได้แก่ สภาพอากาศ และ
สิ่งแวดล้อม คุณสมบัติของเป้าหมาย และเรขาคณิตที่คำนวณจากข้อมูลการสแกน ส่วนค่า
คลาดเคลื่อนที่เกิดจากตัว TLS มีค่าน้อยมาก ซึ่งในการทำงานจะไม่นำค่าคลาดเคลื่อนในส่วนนี้มาคิด
ในงานวิจัย (Feliciano *et al.*, 2014)



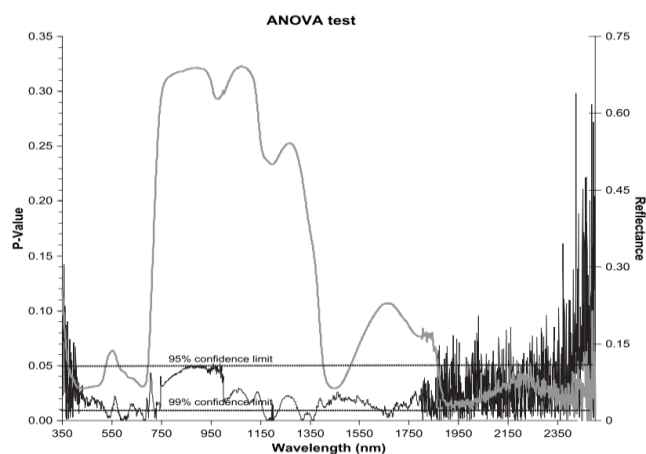
บทที่ 3

เอกสารงานวิจัยที่เกี่ยวข้อง

3.1 งานวิจัยที่เกี่ยวข้องกับการจำแนกภาพถ่ายจากดาวเทียมด้วยข่ายประสาทคอนโวลูชัน

ข้อมูลภาพถ่ายจากดาวเทียมเป็นที่นิยมนำมาใช้ในการประยุกต์กับงานด้านการจำแนกพื้นที่การใช้ประโยชน์ที่ดินโดยเฉพาะในด้านการจำแนกพื้นที่ป่า ซึ่งประสบผลสำเร็จเป็นอย่างดี จึงได้มีการพยายามในการต่อยอดการจำแนกลงไปในระดับของพันธุ์ไม้ ซึ่งงานวิจัยที่เกี่ยวข้องได้ใช้ภาพถ่ายจากดาวเทียมที่มีรายละเอียดของจุดภาพ จำนวนช่วงคลื่น และวิธีการจำแนกที่ต่างกันไปเพื่อพัฒนา และปรับปรุงวิธีการจำแนกอย่างต่อเนื่อง

ในงานวิจัยที่ใช้ภาพถ่ายจากดาวเทียมรายละเอียดปานกลาง ค่าการสะท้อนแสงเป็นข้อมูลที่สำคัญในการจำแนก ภาพถ่ายจากดาวเทียมที่มีจำนวนช่วงคลื่นหลายช่วงคลื่น เช่น ภาพถ่ายจากดาวเทียมแบบไฮเพอร์สเปกตรัล เป็นข้อมูลที่แสดงความแตกต่างของค่าการสะท้อนแสงของใบไม้ที่ต่างสายพันธุ์ โดย Vaiphasa *et al.* (2005) ได้พิสูจน์การนำข้อมูลดังกล่าวมาใช้ในการจำแนกพันธุ์ไม้ป่าชายเลนจำนวนทั้งสิ้น 16 พันธุ์ที่ป่าชายเลนอ่าวสวี จังหวัดชุมพร ประเทศไทย โดยเก็บใบไม้ของพันธุ์ไม้ป่าชายเลนแต่ละสายพันธุ์ในพื้นที่ศึกษาด้วยเครื่อง Spectroradiometer มาตรวจสอบค่าการสะท้อนของคลื่น ช่วงคลื่นที่ใช้ในการทดสอบมีจำนวนทั้งสิ้น 2,151 ช่วงคลื่น ทดสอบความแตกต่างจากการสะท้อนของช่วงคลื่นเพื่อจำแนกพันธุ์ไม้ป่าชายเลนด้วยค่าสถิติ ANOVA และ Jeffries-Matsushita distance (ภาพที่ 3-1)



ภาพที่ 3-1 การทดสอบทางสถิติของการสะท้อนของช่วงคลื่นกับพันธุ์ *Rhizophora apiculata* (Vaiphasa *et al.*, 2005)

จากภาพที่ 3-1 ผลการทดสอบพิสูจน์ได้ว่า มีช่วงคลื่นจำนวน 1,941 ช่วงคลื่นที่มีการสะท้อนแตกต่างกัน (P-value = 0.05) และมีช่วงคลื่นจำนวน 477 ช่วงคลื่นที่มีการสะท้อนแตกต่างกัน (P-value = 0.01) อย่างไรก็ตาม ยังมีบางสายพันธุ์ที่ไม่สามารถแยกออกจากกันได้ซึ่งเป็นพืชในตระกูล *Rhizophoraceae*

Zhang *et al.* (2014) ได้จำแนกพันธุ์ไม้ป่าชายเลน ร่วมกับการตรวจสอบสภาพความสมบูรณ์ของพันธุ์ไม้ป่าชายเลนที่เมืองมาซาทแลน ประเทศเม็กซิโก โดยใช้เครื่อง Spectroradiometer เก็บค่าการสะท้อนแสงจากใบของพันธุ์ไม้ป่าชายเลนที่โดดเด่นในพื้นที่ศึกษาจำนวน 3 สายพันธุ์ ได้แก่ *Rhizophora mangle* *Avicennia germinans* และ *Laguncularia racemosa* นำไปทดสอบการจำแนกพันธุ์ไม้ป่าชายเลน และสภาพความสมบูรณ์ในห้องทดลอง ผลการทดสอบพบว่า การใช้ค่าสะท้อนแสงแบบ Hyperspectral จำแนกพันธุ์ไม้ป่าชายเลน และความสมบูรณ์ให้ผลลัพธ์ที่มีความถูกต้องสูงมากกว่าร้อยละ 90 โดยมีความสอดคล้องกันจากค่าดัชนีแคปปาที่ 0.9 อย่างไรก็ตาม การจำแนกด้วยวิธีนี้เหมาะกับต้นไม้ป่าชายเลนที่มีความสมบูรณ์ดี การจำแนกต้นไม้มที่มีการเจริญเติบโตช้า ยังให้ค่าความถูกต้องเพียงร้อยละ 80 เท่านั้น

Koedsin and Vaiphasa (2013) นำภาพถ่ายจากดาวเทียม EO1-Hyperion มาใช้จำแนกพันธุ์ไม้ป่าชายเลนบริเวณแหลมตะลุมพุก อำเภอปากพนัง จังหวัดนครศรีธรรมราช โดยเลือกช่วงคลื่นที่มีความเหมาะสมในการนำมาจำแนกด้วยวิธี Genetic algorithm search ซึ่งให้ช่วงคลื่นที่เหมาะสมในการจำแนกจำนวน 7 ช่วงคลื่น ได้แก่ 498 nm 529 nm 569 nm 732 nm 773 nm 1,094 nm และ 2,163 nm จากนั้น นำช่วงคลื่นดังกล่าวมาจำแนกพันธุ์ไม้ป่าชายเลนจำนวน 5 สายพันธุ์โดดเด่นที่พบในพื้นที่ศึกษา โดยให้ความถูกต้องโดยรวมที่ร้อยละ 92 อย่างไรก็ตาม ยังพบปัญหาเกี่ยวกับการแยกแยะพืชตระกูล *Rhizophoraceae* ได้แก่ โกงกางใบเล็ก และโกงกางใบใหญ่ ออกจากกัน ซึ่งเป็นสิ่งที่ต้องศึกษาต่อยอดเพิ่มเข้าไป

ภาพถ่ายจากดาวเทียมรายละเอียดปานกลางได้ถูกนำมาใช้งานร่วมกับภาพถ่ายดาวเทียมรายละเอียดสูง และข้อมูล LiDAR เพื่อปรับปรุงวิธีการจำแนกให้ผลลัพธ์ที่ได้จากการจำแนก Kamal *et al.* (2015) ได้เสนอประเด็นการจำแนกพื้นที่ป่าชายเลนตามองค์ประกอบ โดยใช้ภาพถ่ายจากดาวเทียมหลายดวง ประกอบด้วย Landsat TM ALOS AVNIR2 WorldView2 และ LiDAR โดยจำแนกด้วยวิธีการจำแนกเชิงวัตถุ แบ่งผลลัพธ์ออกเป็น 5 กลุ่ม โดยเลือกภาพถ่ายจากดาวเทียมที่มีความเหมาะสมในการจำแนกแต่ละกลุ่ม ได้แก่ การแบ่งพื้นที่ป่า และไม้ใช้ป่า ใช้ภาพถ่ายจากดาวเทียม Landsat TM การตรวจหาพื้นที่ป่าชายเลน และการแบ่งเขต ใช้ภาพถ่ายจากดาวเทียม ALOS และ AVNIR2 การจำแนกต้นไม้อื่นๆ และป่าชายเลนรายต้น และการจำแนกสายพันธุ์ ใช้ภาพถ่ายจากดาวเทียม WorldView2 และข้อมูล LiDAR ผลการจำแนกให้ความถูกต้องในทุกด้านที่มากกว่าร้อยละ

90 ผลการศึกษาพบว่า ภาพถ่ายดาวเทียมรายละเอียดสูง ขนาดวัตถุที่ใหญ่ และคลาสที่ไม่หลากหลาย ช่วยให้ผลการจำแนกมีค่าความถูกต้องสูงมากขึ้น

Jia *et al.* (2014) ได้จำแนกพันธุ์ไม้ป่าชายเลนที่เขตอนุรักษ์ป่าไม้โป ประเทศฮ่องกง โดยนำภาพถ่ายจากดาวเทียมรายละเอียดสูง SPOT 5 และภาพถ่ายจากดาวเทียมไฮเปอร์สเปกตรัล EO1 Hyperion มาใช้ร่วมกัน การจำแนกเริ่มจากการแบ่งเขต (Segmentation) ของพื้นที่ป่าชายเลนจากข้อมูลของภาพถ่ายจากดาวเทียมรายละเอียดสูง จากนั้น จำแนกสายพันธุ์ของป่าชายเลนด้วยภาพจากดาวเทียมไฮเปอร์สเปกตรัล ผลการจำแนก พบพันธุ์ไม้ป่าชายเลนที่โดดเด่นอยู่สองสายพันธุ์ ได้แก่ *Kandelia obovata* และ *Avicennia marina* โดยมีความถูกต้องในการจำแนก และความสอดคล้องของการจำแนกร้อยละ 88 และ 0.83 ตามลำดับ

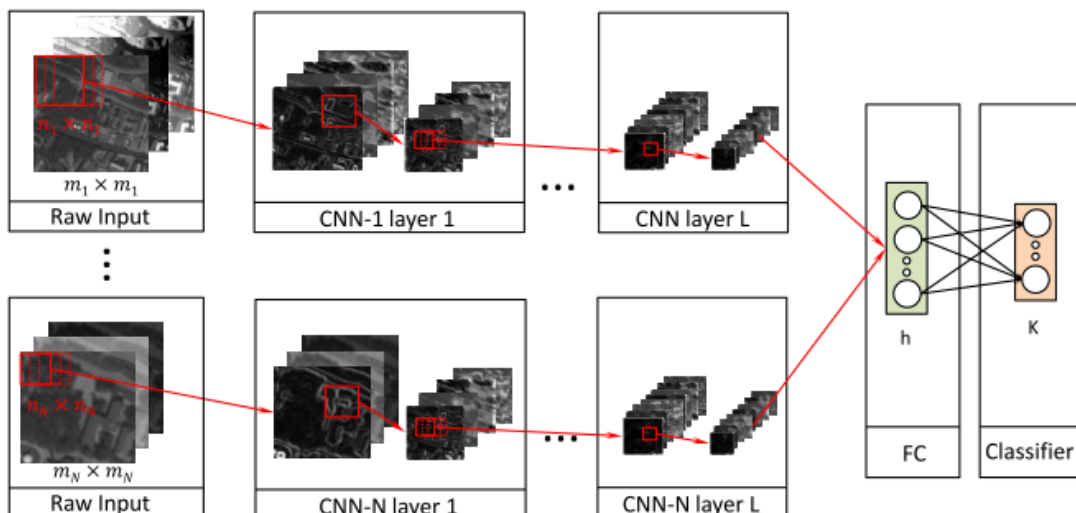
Watanakij and Vaiphasa (2016) นำปัญหาวิจัยที่ Koedsin and Vaiphasa (2013) ได้ทิ้งประเด็นเกี่ยวกับการแยกแยะพืชตระกูล *Rhizophoraceae* ออกจากกัน โดยในการศึกษาได้นำภาพถ่ายจากดาวเทียมรายละเอียดสูง Quickbird มาใช้จำแนกด้วยวิธีการสกัดเนื้อภาพ Gray level co-occurrence matrix ร่วมกับการวิเคราะห์องค์ประกอบหลัก และการจำแนกเชิงวัตถุ จำแนกร่วมกับข้อมูลพันธุ์ไม้ป่าชายเลนจากภาพถ่ายจากดาวเทียม EO1-Hyperion ผลลัพธ์ที่ได้จากการจำแนกสามารถแก้ปัญหาในเรื่องการจำแนกต้นโกงกางใบใหญ่ และโกงกางใบเล็กออกจากกัน ผลการจำแนกโดยรวมมีความถูกต้องเพิ่มขึ้นจากร้อยละ 92 เป็นร้อยละ 97 โดยผลลัพธ์การจำแนกต้นโกงกางใบใหญ่มีความถูกต้องเพิ่มขึ้นจากร้อยละ 68 เป็นร้อยละ 94 และต้นโกงกางใบเล็กมีความถูกต้องเพิ่มขึ้นจากร้อยละ 94 เป็นร้อยละ 95

ในงานวิจัยอีกส่วนหนึ่ง นิยมใช้ภาพถ่ายดาวเทียมรายละเอียดสูงมาจำแนกในระดับสายพันธุ์ โดยพัฒนาวิธีการจำแนกให้ได้ผลลัพธ์ที่มีความถูกต้องมากยิ่งขึ้น Heenkenda *et al.* (2014) ได้เปรียบเทียบความถูกต้องผลลัพธ์การจำแนกพันธุ์ไม้ป่าชายเลนระหว่างผลลัพธ์ที่ได้จากภาพถ่ายจากดาวเทียม WorldView 2 และภาพถ่ายทางอากาศสี ที่เมืองดาร์วิน ประเทศออสเตรเลีย เทคนิคการจำแนกเชิงวัตถุถูกนำมาใช้เพื่อแบ่งพื้นที่ป่าชายเลนออกจากพื้นที่ประเภทอื่น จากนั้นได้ใช้ Support vector machine จำแนกพันธุ์ไม้ป่าชายเลนจำนวน 5 สายพันธุ์ในพื้นที่ โดยมีความถูกต้องของการจำแนกอยู่ที่ร้อยละ 89 จำนวนช่วงคลื่นที่มีมาก และการนำช่วงคลื่น Panchromatic ช่วยเพิ่มประสิทธิภาพด้านการจำแนก ผลการเปรียบเทียบดัชนีแคปปาพบว่า ผลลัพธ์ที่ได้จากภาพถ่ายจากดาวเทียม WorldView 2 มีความสอดคล้องกับผลลัพธ์ที่ได้จากภาพถ่ายทางอากาศ

Otero *et al.* (2016) ได้นำวิธีการด้าน Machine learning มาใช้ในการจำแนกพื้นที่ป่าชายเลนร่วมกับภาพถ่ายจากดาวเทียม โดยจำแนกพื้นที่ป่าชายเลนเขตแห้งแล้งในพื้นที่ เมารีทาเนีย บริเวณชายฝั่งติดกับทะเลทรายสะฮารา โดยใช้ข้อมูลภาพถ่ายจากดาวเทียม Quickbird และ GeoEye วิเคราะห์ Principal component analysis เพื่อหลอมรวมข้อมูลให้มีความโดดเด่น

จากนั้นจำแนกด้วยวิธี Maximum likelihood และ Neural network ผลที่ได้พบว่า การจำแนกแบบ Maximum likelihood ให้ผลการจำแนกที่ดีที่สุด โดยมีค่าความถูกต้องสูงกว่าร้อยละ 87±2 ค่าคลาดเคลื่อนที่เกิดขึ้นในการจำแนกเป็นผลมาจากความแตกต่างของการสะท้อนระหว่างป่าชายเลนกับป่าบกทั่วไปที่มีค่าแตกต่างกันน้อย ทำให้เกิดความผิดพลาดในขั้นตอนดังกล่าว

ต่อมา ในงานของ Langkvist *et al.* (2016) ได้นำอัลกอริธึม Convolutional neural network ซึ่งเป็นอัลกอริธึมด้าน Machine learning ที่ใช้ในการประมวลผลด้าน Computer vision โดยนำข้อมูล City map ของประเทศสวีเดนทางตอนเหนือมาใช้ทดสอบ ประกอบด้วยช่วงคลื่นจำนวน 14 ช่วงคลื่น ร่วมกับ แบบจำลองพื้นผิวระดับสูง (Digital surface model: DSM) ภาพที่ใช้มีความละเอียด 0.5 เมตร แต่ละภาพมีขนาด 250 × 250 จุดภาพ เลือกภาพที่ช่วงคลื่นระหว่าง 400 – 1,040 นาโนเมตร จำนวน 5 ช่วงคลื่น สอนโครงข่ายด้วยวิธี Unsupervised learning K-means และออกแบบสถาปัตยกรรมแบบ Multiple CNN (CNNs) โดยทำคอนโวลูชันแบบขนาน (ภาพที่ 3-2) และรวมส่งข้อมูลเข้าชั้น Fully connected จากนั้นจำแนกด้วย Softmax classifier โดยปรับค่าน้ำหนักด้วย Stochastic gradient descent ผลลัพธ์ที่ได้จากการจำแนก ถูกทดสอบความถูกต้องด้วยตาราง Confusion matrix ผลการจำแนกพบว่า สถาปัตยกรรม Multiple CNN ให้ความถูกต้องการจำแนกที่ร้อยละ 94.49 มากกว่า Single CNN ที่ให้ความถูกต้องของการจำแนกที่ร้อยละ 90.02



ภาพที่ 3-2 การใช้ CNNs ในการจำแนกข้อมูลภาพถ่ายจากดาวเทียม (Langkvist *et al.*, 2016)


Luus *et al.* (2015) จำแนกการใช้ประโยชน์ที่ดินโดยนำชุดข้อมูลการใช้ประโยชน์ที่ดิน UC Merced ซึ่งเป็นภาพถ่ายทางอากาศที่มีความละเอียด 0.3408 เมตร แต่ละภาพมีขนาด 256 ×

256 จุดภาพ มีประเภทการใช้ที่ดินทั้งหมด 21 ประเภท มาใช้สอนให้กับ CNN พร้อมทดสอบการจำแนก ประเมินค่าคลาดเคลื่อนของผลลัพธ์ส่งออกเทียบกับผลลัพธ์เป้าหมายในแต่ละรอบด้วยค่า Log loss cost function และปรับค่าที่เหมาะสมด้วย Stochastic gradient descent ผลลัพธ์ที่ได้จากการจำแนกนำมาเปรียบเทียบกับวิธีการจำแนกแบบต่าง ๆ ที่ดำเนินการกับภาพถ่ายทางอากาศแบบหลายช่วงคลื่น ผลการจำแนกพบว่า CNN มีความแม่นยำในการจำแนกสูงที่สุดที่ร้อยละ 93.5 ตามด้วย Unsupervised feature learning (UFL) ที่มีความแม่นยำร้อยละ 90.20

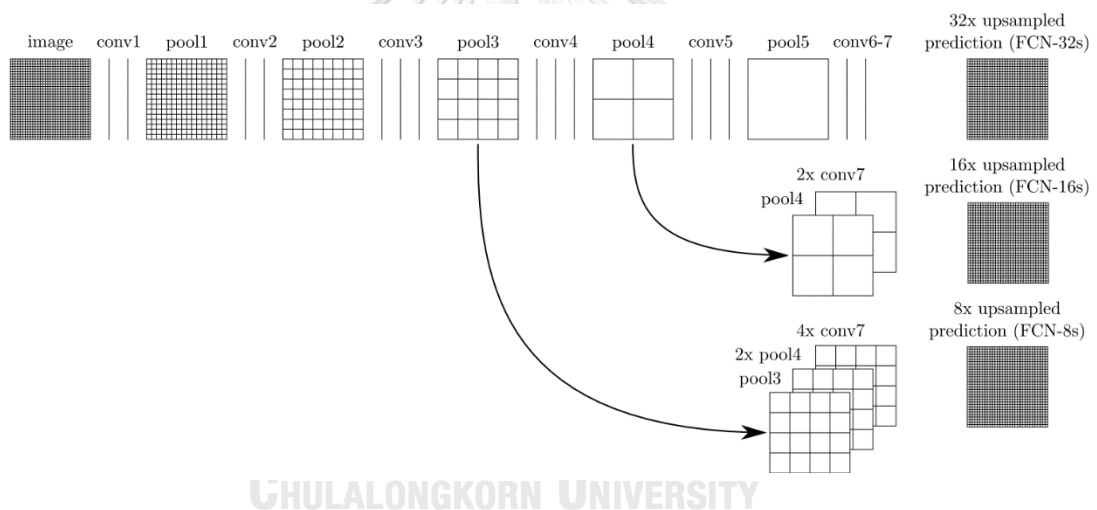
Cheng *et al.* (2016) พบปัญหาในการนำ CNN มาใช้จำแนกภาพถ่ายจากดาวเทียมรายละเอียดสูงในเรื่องความแปรปรวนของวัตถุในภาพที่ไม่ได้อยู่ในทิศทางเดียวกัน (Object rotation variation) ส่งผลให้การจำแนกข้อมูลเกิดความไม่ถูกต้อง จึงได้เสนอวิธีการแก้ปัญหาด้วยแบบจำลอง Rotation-invariant CNN (RICNN) โดยหมุนชั้นข้อมูลสำหรับการสอนโครงข่าย ภาพที่ใช้เป็นภาพถ่ายจากดาวเทียมรายละเอียดสูง ตัดภาพให้มีขนาด 227×227 จุดภาพ นำเข้าสู่โครงข่าย AlexNet ซึ่งประกอบด้วยชั้น Convolution จำนวน 5 ชั้น ตามด้วยชั้น Max pooling จำนวน 1 ชั้น จากนั้น นำเข้าสู่ชั้น Fully connected จำนวน 3 ชั้น จำแนกด้วยฟังก์ชัน Softmax และ Support vector machine (SVM) จากนั้น ปรับแต่งให้ผลลัพธ์มีความถูกต้องมากยิ่งขึ้น ผลที่ได้นำไปเปรียบเทียบกับผลที่ได้จากวิธีการจำแนกแบบอื่น ๆ 5 วิธี พบว่า ผลลัพธ์จากวิธีการ RICNN ที่จำแนกด้วยฟังก์ชัน Softmax ให้ค่าความถูกต้องของการจำแนกสูงที่สุดที่ร้อยละ 72.63 ดีกว่าผลลัพธ์จากวิธีอื่น ๆ รวมถึงการใช้ตัวจำแนก SVM ซึ่งให้ความถูกต้องของการจำแนกต่ำกว่าที่ร้อยละ 69.68

Nogueira *et al.* (2017) ทดสอบ CNN ได้แก่ Overfeat network AlexNet CaffeNet GoogleLeNet VGG₁₆ และ Patreonet เพื่อตรวจสอบโครงข่ายที่ให้ความถูกต้องกับงานด้าน Remote sensing ที่มีข้อมูลตัวอย่าง (Label) จำกัดด้วยวิธีการ 3 รูปแบบ ได้แก่ 1) ใช้ข้อมูลตัวอย่างมาสอนโครงข่ายเพียงอย่างเดียว 2) เพิ่มการปรับแต่งการจำแนกด้วยตัวจำแนกประเภทอื่น และ 3) ใช้ตัวสกัดข้อมูลเพียงอย่างเดียว โดยเปรียบเทียบข้อมูล Remote sensing จำนวน 3 ชุด ที่มีลักษณะพื้นที่ต่างกัน ผลปรากฏว่า การใช้โครงข่าย GoogleLeNet ร่วมกับการปรับแต่งด้วยตัวจำแนกอื่น ๆ (งานวิจัยนี้ใช้ Linear SVM) ให้ผลลัพธ์ที่มีความถูกต้องสูงที่สุดที่ร้อยละ 97.78 แสดงให้เห็นว่า CNN สามารถนำมาประยุกต์กับข้อมูล Remote sensing ในการจำแนกพื้นที่ได้ และเป็นโอกาสในการนำวิธีดังกล่าวมาปรับปรุงวิธีการจำแนกพื้นที่ไม่ป่าชายเลนให้มีความถูกต้องมากยิ่งขึ้น

CNN ได้ถูกพัฒนาเพื่อจำแนกภาพทางความหมาย ซึ่ง Long *et al.* (2015) ได้เสนอโครงข่ายคอนโวลูชันเชิงลึกแบบฟูลลี (Fully convolutional network: FCN) ซึ่งมีความแตกต่างจาก CNN แบบทั่วไปในขั้นสุดท้ายหลังชั้น Fully connected การจำแนก จะกระจายค่าผลลัพธ์ไปบนทุกจุดภาพด้วยวิธีการเพิ่มความละเอียดของจุดภาพ (Upsampling) ดังแสดงในภาพที่ 3-3



ภาพที่ 3-3 การจำแนกแบบ Per-pixel ในการจำแนกภาพทางความหมาย โดยเพิ่มรายละเอียดจุดภาพหลังชั้น Fully connected (Long *et al.*, 2015)



ภาพที่ 3-4 วิธีการข้ามชั้นคอนโวลูชันแบบ FCN-32s FCN-16s และ FCN-8s ในการสกัดคุณลักษณะของข้อมูลภาพเพื่อจำแนก (Long *et al.*, 2015)

จากภาพที่ 3-3 FCN ประกอบด้วยชั้นคอนโวลูชันจำนวน 7 ชั้น Long *et al.* (2015) ได้ทดสอบการจำแนกโดยการข้ามชั้นคอนโวลูชันของโครงข่ายไปยังชั้น Fully connected จำนวน 3 วิธี ได้แก่ FCN-32s เป็นการทำคอนโวลูชันครบทุกชั้น FCN-16s (เริ่มข้ามชั้นคอนโวลูชันที่ 5) และ FCN-8s (เริ่มข้ามชั้นคอนโวลูชันที่ 4) ดังภาพที่ 3-4 หลังจากทดสอบกับชุดข้อมูล PASCAL VOC ผลลัพธ์ที่ได้แสดงให้เห็นว่า FCN-8s มีประสิทธิภาพสูงกว่าวิธีการข้ามชั้นข้อมูลแบบอื่น โดยมีความถูกต้อง ร้อยละ 75.9

Saito *et al.* (2016) ได้นำ FCN มาใช้ในการจำแนกทางความหมายกับภาพถ่ายทางอากาศ โดยมุ่งไปที่การจำแนกถนน และอาคารในรัฐแมสซาชูเซตส์ออกจากกัน โดยข้อมูลการฝึกสอน มีขนาดจุดภาพ 64×64 จุดภาพ โดยผลการประเมินให้ค่าความถูกต้องที่ร้อยละ 76.20 เช่นเดียวกับ Muruganandham (2016) ที่ได้เปรียบเทียบ CNN จำนวน 3 โครงข่าย ได้แก่ FCN, FCN-8s, และ DeCNN โดยจำแนกข้อมูลถนนพื้นที่เดียวกับ Saito *et al.* (2016) ผลที่ได้จากการจำแนกพบว่า โครงข่าย FCN-8s ให้ค่าความถูกต้องในการจำแนกสูงที่สุดที่ร้อยละ 76.20 ตามด้วย FCN ให้ค่าความถูกต้องของการจำแนกที่ร้อยละ 74.20 และ DeCNN ให้ค่าความถูกต้องของการจำแนกที่ร้อยละ 65.70

อย่างไรก็ตาม การทำงานของ CNN ที่มีความลึกของโครงข่าย และจำนวนพารามิเตอร์ มาก ส่งผลต่อระยะเวลาในการสอน และไม่สามารถดำเนินการได้ในกรณีที่ทรัพยากรสำหรับการประมวลผลมีจำกัด Han *et al.* (2016) ได้พัฒนาวิธีการที่เรียกว่า Deep compression เพื่อเป็นการลดขนาดของแบบจำลองการเรียนรู้เชิงลึก โดยมีวิธีการ 3 ขั้นตอน ได้แก่ 1) Network pruning 2) trained quantization และ 3) Huffman coding ซึ่งการลดจำนวนของชั้นในสถาปัตยกรรมทำเพื่อปรับแต่งค่าน้ำหนักของ Pretrained network โดยเก็บเพียงค่าที่สำคัญต่อการทำนายผลไว้เท่านั้น แล้วตัดค่าที่ไม่สำคัญออกจากโครงข่ายเพื่อลดขนาดของโครงข่ายลง แต่ยังคงไว้ด้วยค่าน้ำหนักที่สำคัญต่อการประมวลผล จากนั้น สอนโครงข่ายเพื่อปรับแก้ค่าน้ำหนักที่มีค่าเป็น 0 โดยทำซ้ำจนค่าน้ำหนักที่เหลือในโครงข่ายมีค่าความถูกต้องสูง วิธี Deep compression สามารถลดจำนวนพารามิเตอร์ของโครงข่ายลงได้ 9 - 13 เท่า เพิ่มความเร็วในการสอนได้ 3 - 4 เท่า และไม่ส่งผลต่อประสิทธิภาพการทำงาน

3.2 งานวิจัยที่เกี่ยวข้องด้านการประมาณค่ามวลชีวภาพเหนือพื้นดิน

Komiyama *et al.* (2005) ได้เก็บตัวอย่างพันธุ์ไม้ป่าชายเลนที่จังหวัดพังงา ตราด สตูล และระนอง ในประเทศไทย และที่ ฮัลมาฮีรา ประเทศอินโดนีเซีย เพื่อนำข้อมูลมาสร้างสมการอัลโลเมตรีแบบทั่วไปในเขตภูมิอากาศเขตร้อน ได้ความสัมพันธ์ดังสมการที่ 3-1

$$W_{top} = 0.251\rho D^{2.46} \quad (3-1)$$

เมื่อ	W_{top}	คือ	ค่าประมาณมวลชีวภาพเหนือพื้นดิน
	ρ	คือ	ค่าความหนาแน่นจำเพาะของเนื้อไม้
	D	คือ	ค่าเส้นผ่านศูนย์กลางที่ความสูงเพียงอก

Komiyama *et al.* (2008) ได้รวบรวมการอัลโลเมตรีของพันธุ์ไม้ป่าชายเลนในประเทศไทย ซึ่งได้ให้ข้อมูลที่สำคัญในการประมาณค่ามวลชีวภาพเหนือพื้นดินของพันธุ์ไม้ป่าชายเลน ข้อเสนอแนะการใช้สมการอัลโลเมตรีแบบทั่วไป ซึ่งในงานดังกล่าว ได้เสนอสมการอัลโลเมตรีของต้นแสมทะเลที่ศึกษาโดย Comley and McGuinness (2005) ที่ได้ศึกษาเกี่ยวกับพันธุ์ไม้ป่าชายเลนที่ประเทศออสเตรเลีย และพบว่างานวิจัยที่เกี่ยวกับด้านป่าชายเลนมักเน้นไปที่ความหลากหลายทางสายพันธุ์ ในขณะที่มวลชีวภาพของต้นไม้ป่าชายเลนยังมีการศึกษาไม่มากนัก จึงได้เริ่มเก็บข้อมูลเพื่อหามวลชีวภาพเหนือพื้นดิน และใต้ดิน รวมถึงสร้างความสัมพันธ์อัลโลเมตรีของต้นไม้ป่าชายเลนจำนวน 4 พันธุ์ ได้แก่ ต้นแสมทะเล (*Avicennia marina*) ต้นพังกาหัวสุ่มดอกแดง (*Bruguiera exaristata*) ต้นโปรง (*Ceriops australis*) และ ต้นโกงกางทะเล (*Rhizophora stylosa*) ในการเลือกตัวอย่าง ต้นไม้จะเลือกต้นที่มีความสมบูรณ์ และสามารถเข้าถึงเพื่อขุด และถอนต้นไม้ได้ ต้นไม้ที่นำมาใช้เป็นตัวอย่างต้องมีความสูงไม่ต่ำกว่า 1.30 เมตร โดยมีตัวอย่างต้นแสมทะเล 11 ต้น ต้นพังกาหัวสุ่มดอกแดง 9 ต้น ต้นโปรง 12 ต้น และต้นโกงกางทะเล 6 ต้น แต่ละต้นจะวัดค่าเส้นผ่านศูนย์กลางความสูงเพียงอก (DBH) ซึ่งร้อยละ 70 ของต้นไม้ตัวอย่างมีเส้นผ่านศูนย์กลางเพียงอกมากกว่า 22 เซนติเมตรขึ้นไป ในกรณีของต้นแสมทะเล การหาน้ำหนักสด (Fresh weights) จะแบ่งส่วนของตัวอย่างออกเป็น ใบ ก้าน ลำต้น แยกซัง และนำเข้าสู่ห้องทดลองเพื่อหาน้ำหนักแห้ง (Dry weights) โดยการอบที่อุณหภูมิ 70 – 80 องศาเซลเซียส จนน้ำหนักมีความเสถียร ต่อมา หาค่าความสัมพันธ์เพื่อสร้างสมการอัลโลเมตรีระหว่างลอการิทึมของน้ำหนักแห้งกับลอการิทึมของเส้นผ่านศูนย์กลางความสูงเพียงอก จากการศึกษา พบว่า ความสัมพันธ์ระหว่างมวลชีวภาพเหนือพื้นดินกับเส้นผ่านศูนย์กลางเพียงอกของต้นแสมทะเลมีความสัมพันธ์กันอย่างมีนัยสำคัญที่ $r^2 = 0.82$ สามารถสร้างสมการอัลโลเมตรีของต้นแสมทะเลได้ดังสมการที่ 3-2

$$W_{top} = 0.308DBH^{2.11} \quad (3-2)$$

เมื่อ W_{top} คือ ค่าประมาณมวลชีวภาพเหนือพื้นดิน

DBH คือ ค่าเส้นผ่านศูนย์กลางที่ความสูงเพียงอก

Laongmanee (2011) ได้ศึกษาความเหมาะสมของจุดภาพ และดัชนีพีซพรอนที่นำไปใช้วิเคราะห์ดัชนีพื้นที่ใบ รวมถึงการทดสอบเทคนิคต่าง ๆ ที่นำมาใช้ในการประมาณค่ามวลชีวภาพในพื้นที่ป่าชายเลน ตัวอย่างต้นไม้ที่ใช้ในการวิเคราะห์มีขนาดเส้นผ่านศูนย์กลางความสูงเพียงอกต่ำกว่า 15 เซนติเมตร โดยผลการศึกษาที่ได้พบว่า รายละเอียดของจุดภาพจากภาพถ่ายดาวเทียมที่มีความเหมาะสมในการวิเคราะห์ดัชนีพื้นที่ใบ โดยดัชนีที่มีความเหมาะสมในการวิเคราะห์ ได้แก่ TCT-GVI

EVI และ NDVI โดยมีค่า $r^2 = 0.824$ 0.817 และ 0.800 ตามลำดับ ในส่วนการประมาณค่ามวลชีวภาพ ดัชนีที่ค่าสัมประสิทธิ์การตัดสินใจสูง ได้แก่ EVI NDVI และ TCT-GVI โดยมีค่า r^2 0.540 0.500 และ 0.460 ตามลำดับ นอกจากนี้ยังได้ปรับสมการอัลโลเมตรีแบบทั่วไปของ Komiyama *et al.* (2005) ให้มีความเหมาะสมกับต้นแสมทะเลในพื้นที่ศึกษา ดังสมการที่ 3-3

$$W_{top} = 0.251\rho D^{2.24} \quad (3-3)$$

เมื่อ W_{top} คือ ค่าประมาณมวลชีวภาพเหนือพื้นดิน
 ρ คือ ค่าความหนาแน่นจำเพาะของเนื้อไม้
 D คือ ค่าเส้นผ่านศูนย์กลางที่ความสูงเพียงอก

Patil *et al.* (2014) ได้ประมาณค่ามวลชีวภาพของต้นแสมทะเล ที่เมืองมุมไบ ประเทศอินเดีย โดยปรับปรุงแบบจำลองมวลชีวภาพเหนือพื้นดิน จากนั้น ประมาณค่าคาร์บอนในระดับภูมิภาค การประมาณค่ามวลชีวภาพจะใช้วิธีการสองวิธี ได้แก่ วิธีการประมาณค่ามวลชีวภาพโดยตรงด้วยการตรวจวัดค่าคาร์บอน ไฮโดรเจน และไนโตรเจน (CHN) ของต้นแสมทะเล และวิธีการประมาณค่าทางอ้อม จะใช้แบบจำลองมวลชีวภาพเหนือพื้นดินที่สร้างจากการเก็บข้อมูลจำนวนตัวอย่างทั้งหมด 110 ตัวอย่าง โดยมีตัวอย่างที่มีเส้นผ่านศูนย์กลางความสูงเพียงอกขนาดระหว่าง 14 – 21 เซนติเมตร จำนวน 75 ตัวอย่าง จากนั้น ประมาณค่าคาร์บอนในจุดพื้นที่ตัวอย่าง และสร้างแผนที่คาร์บอนจากการประมาณค่าด้วยวิธีการ Kriging แบบจำลองมวลชีวภาพเหนือพื้นดินที่ได้รับการปรับปรุง แสดงในสมการที่ 3-4 โดยมีค่า $r^2 = 0.94$

$$W_{top} = 0.3404DBH^{2.0273} \quad (3-4)$$

เมื่อ W_{top} คือ ค่าประมาณมวลชีวภาพเหนือพื้นดิน
 D คือ ค่าเส้นผ่านศูนย์กลางที่ความสูงเพียงอก

Njana *et al.* (2016b) ศึกษาเกี่ยวกับความหนาแน่นของต้นไม้ ซึ่งมีความสำคัญต่อการนำไปประยุกต์เพื่อประมาณค่ามวลชีวภาพของต้นไม้ โดยมีสมมติฐานว่า ถ้าใช้ค่าความหนาแน่นของต้นไม้ที่เหมาะสมกับพันธุ์ไม้แล้ว จะสามารถช่วยให้สมการอัลโลเมตรีมีความถูกต้องมากยิ่งขึ้น ในงานวิจัยได้เลือกพันธุ์ไม้ป่าชายเลนที่ใช้ในการศึกษาจำนวน 3 พันธุ์ ได้แก่ *Avicennia marina* (Forssk.) Vierh *Sonneratia alba* J. Smith และ *Rhizophora mucronata* Lam. จำนวน 120 ต้น ที่ประเทศแทนซาเนีย ในการดำเนินงาน ได้นำต้นไม้ 90 ต้น มาทดสอบเพื่อประมาณค่ามวล

ชีวภาพเหนือพื้นดิน จากนั้น คำนวณค่าปริมาตรของต้นไม้ และความหนาแน่นของต้นไม้ จากนั้น นำผลลัพธ์ที่ได้ไปพัฒนาแบบจำลองมวลชีวภาพของต้นไม้ เพื่อให้ค่าที่ได้จากการประมาณมีความถูกต้องมากยิ่งขึ้น โดยค่าความหนาแน่นของต้นไม้ที่เหมาะสมกับต้นเสมหะเล มีค่า 0.60 กรัมต่อลูกบาศก์เซนติเมตร เมื่อนำค่าความหนาแน่นต้นไม้รวมคำนวณในแบบจำลองมวลชีวภาพ พบว่า ค่ามวลชีวภาพที่ได้จากการประมาณค่ามีค่าใกล้เคียงกับค่าที่ได้จากการวัดจากห้องทดลอง

Calders *et al.* (2015) ได้ประมาณ ค่ามวลชีวภาพของต้นยูคาลิปตัสที่ ประเทศออสเตรเลียด้วยวิธีการที่ไม่ต้องตัดต้นไม้ เครื่องสแกนเลเซอร์ภาคพื้นดินได้ถูกใช้ในการเก็บข้อมูลทางกายภาพของต้นไม้ โดยเลือกต้นไม้ตัวอย่างทั้งหมด 65 ต้น ในงานวิจัยจะสกัดค่าการวัดต้นไม้แต่ละต้นจากค่า Point cloud และคำนวณค่าพารามิเตอร์ที่ต้องการ ได้แก่ เส้นผ่านศูนย์กลางที่ความสูงเพียงออก และความสูงจากข้อมูล Point cloud วิธีการที่ใช้เพื่อประมาณค่าเส้นผ่านศูนย์กลางที่ความสูงเพียงออกนั้นได้เลือกใช้วิธี Least square circular fitting ส่วนวิธีการประมาณค่าความสูงของต้นไม้ได้ใช้ความต่างระหว่างจุด Point cloud ที่สูงที่สุด และต่ำที่สุด จากนั้น ได้ประมาณค่าปริมาตรของลำต้นด้วยวิธีการ Quantitative structure model และนำค่าปริมาตรของลำต้นมาคำนวณร่วมกับค่าความหนาแน่นพื้นฐานเพื่อประมาณค่ามวลชีวภาพของต้นไม้ ค่าที่ได้ทั้งหมดได้ถูกนำมาคำนวณเพื่อสร้างสมการอัลโลเมตรี ค่ามวลชีวภาพที่ได้จากงานวิจัยถูกนำมาเปรียบเทียบกับค่ามวลชีวภาพที่ได้จากห้องปฏิบัติการ (ได้จากการตัดต้นไม้) พบว่า ค่ามวลชีวภาพที่ได้คำนวณจากข้อมูลเครื่องสแกนเลเซอร์ภาคพื้นดินมีค่าสูงกว่าค่ามวลชีวภาพเปรียบเทียบที่ร้อยละ 9.68 ซึ่งให้ผลดีกว่าค่ามวลชีวภาพที่ได้จากสมการอัลโลเมตรี ซึ่งมีค่าต่ำกว่าค่าเปรียบเทียบที่ร้อยละ 36.57 – 29.85

Hackenberg *et al.* (2015b) ได้ใช้เครื่องสแกนเลเซอร์ภาคพื้นดินเพื่อประเมินมวลชีวภาพของต้นไม้ 3 สายพันธุ์ ได้แก่ *Pinus massoniana* *Erythrophleum fordii* และ *Quercus petraea* โดยใช้ตัวอย่างจำนวน 36 ตัวอย่าง ซึ่งในการทำงานเป็นช่วงที่สภาพอากาศมีลมแรงส่งผลให้เกิด Point cloud ที่เป็นสัญญาณรบกวน ส่งผลให้ค่าที่ได้มีค่าคลาดเคลื่อนค่อนข้างสูง ถึงแม้จะลดสัญญาณรบกวนแล้วก็ตาม ผลที่ได้พบว่า ปริมาตรของลำต้นที่มีค่าคลาดเคลื่อนสูง เป็นสาเหตุหลักที่ส่งผลให้ค่าประมาณมวลชีวภาพมีค่าคลาดเคลื่อนสูงตาม ต้นไม้ที่มีเส้นผ่านศูนย์กลางลำต้นมากกว่า 10 เซนติเมตร มีแบบจำลองที่แม่นยำกว่าลำต้นที่เส้นผ่านศูนย์กลางต่ำกว่า โดยเฉพาะที่ต่ำกว่า 4 เซนติเมตรจะให้ค่าประมาณมวลชีวภาพที่สูงกว่าค่าที่ควรประมาณได้ จึงได้ปรับแก้โดยเพิ่มค่า Biomass expansion factor (BEF) เข้าไปในสมการ ส่งผลให้ค่าคลาดเคลื่อนลดลง โดย *Pinus massoniana* มีค่าคลาดเคลื่อนลดลงจากร้อยละ 33.84 เหลือร้อยละ 3.56 *Erythrophleum fordii* มีค่าคลาดเคลื่อนลดลงจากร้อยละ -17.24 เหลือร้อยละ -7.30 ในขณะที่ *Quercus petraea* มีค่าคลาดเคลื่อนต่ำอยู่แล้วที่ร้อยละ 2.75 เมื่อเพิ่ม BEF เข้าไป ส่งผลให้ค่าคลาดเคลื่อนมีค่าสูงขึ้นเป็นร้อยละ 3.82

Feliciano *et al.* (2014) ได้ศึกษาการประมาณค่ามวลชีวภาพของพันธุ์ไม้ป่าชายเลน ที่อุทยานแห่งชาติเอเวอร์เกลด รัฐฟลอริดา ประเทศสหรัฐอเมริกา เก็บข้อมูลกายภาพของต้นไม้ป่าชายเลนจำนวนทั้งหมด 25 ตัวอย่างจาก 3 พื้นที่ศึกษาด้วยเครื่องสแกนเลเซอร์ภาคพื้นดิน โดยแต่ละตัวอย่าง ได้สแกนแบบ Multiple scanning จากนั้น นำข้อมูล Point cloud มาคำนวณเพื่อหาปริมาตรของต้นไม้ และประมาณค่ามวลชีวภาพด้วยการนำค่าปริมาตรมาคูณกับค่าความหนาแน่นจำเพาะของเนื้อไม้ จากนั้น สร้างสมการอัลโลเมตรีด้วยสมการฟังก์ชันกำลัง โดยมวลชีวภาพเป็นฟังก์ชันของเส้นผ่านศูนย์กลางที่ความสูงเพียงอก แบ่งออกเป็นสองสมการคือสมการอัลโลเมตรีของพันธุ์ไม้ป่าชายเลนในพื้นที่ กับสมการอัลโลเมตรีเฉพาะของพันธุ์ *R. mangle* ซึ่งเป็นพันธุ์ไม้ป่าชายเลนที่โดดเด่นของพื้นที่ จากนั้น นำค่าที่ได้จากความสัมพันธ์ไปเปรียบเทียบกับค่าที่ได้จากสมการที่ได้จากการทบทวนเอกสาร ซึ่งพบว่ามีค่าใกล้เคียงกัน และค่าคลาดเคลื่อนจากการประมาณค่าชีวมวลอยู่ระหว่างร้อยละ 10.8 – 12.9

Olagoke *et al.* (2016) ได้ประเมินค่ามวลชีวภาพของพันธุ์ไม้ป่าชายเลนที่จังหวัดเฟรนช์เกียนา (ตั้งอยู่ที่ทวีปอเมริกาใต้ อยู่ใต้การปกครองของประเทศฝรั่งเศส) โดยเน้นไปที่ *A. Germinans* ที่สามารถมีขนาดเส้นผ่านศูนย์กลางความสูงเพียงอกใหญ่สุดถึง 125 เซนติเมตร โดยหาค่าปริมาตรของลำต้น และกิ่ง ของต้นไม้ ด้วยสมการรูปทรงเรขาคณิตที่มีความเหมาะสมกับส่วนของลำต้นแต่ละส่วน เพื่อประมาณค่ามวลชีวภาพ จากนั้น สร้างสมการอัลโลเมตรี โดยพารามิเตอร์ของสมการอัลโลเมตรีประกอบด้วย เส้นผ่านศูนย์กลางที่ความสูงเพียงอก และความสูงของต้นไม้ จากนั้น นำผลที่ได้มาทดสอบกับค่ามวลชีวภาพจากสมการอัลโลเมตรีมาตรฐาน ผลที่ได้จากการประมาณค่ามวลชีวภาพมีค่าคลาดเคลื่อนอยู่ระหว่างร้อยละ 6.7 – 16.7 ในขณะที่ค่าความสอดคล้องของแบบจำลองอัลโลเมตรีมีค่าอยู่ระหว่าง 0.96 – 0.99

Bienert *et al.* (2018) ได้นำเครื่องสแกนเลเซอร์เคลื่อนที่ (Mobile laser scanner; MLS) มาใช้เก็บข้อมูลจุดพิกัดสามมิติต้นไม้ ซึ่ง MLS เป็นเครื่องมือที่ใช้ทำงานได้รวดเร็ว และมีความแม่นยำในการเก็บข้อมูล ข้อมูลจาก MLS ได้ถูกนำมาเปรียบเทียบความแม่นยำกับ TLS โดยใช้แบบจำลองโครงสร้างเชิงปริมาณ (Quantitative structural model: QSM) เพื่อคำนวณปริมาตรจากจุดพิกัดสามมิติ ผลการเปรียบเทียบพบว่า การคำนวณความสูงของต้นไม้จากข้อมูล TLS และ QSM ให้ผลไม่แตกต่างกัน ในส่วนการประมาณค่า DBH ผลที่ได้จาก TLS มีความแม่นยำกว่า MLS โดย TLS มีค่าคลาดเคลื่อน 1.1 เซนติเมตร ส่วน MLS ให้ค่าคลาดเคลื่อนที่ 3.7 เซนติเมตร อย่างไรก็ตาม ในขั้นตอนการรวมจุดพิกัดสามมิติยังมีค่าคลาดเคลื่อนสูงเนื่องมาจากสัญญาณ GNSS ที่รับได้มีค่าอ่อน ต้องหาวิธีการมาแก้ไขในเรื่องของการรับสัญญาณ GNSS ให้มีความเสถียรมากยิ่งขึ้น

Owers *et al.* (2018) ได้นำแบบจำลองการประมาณค่าพื้นผิวสามมิติ (3-D surface reconstruction model) มาใช้หาปริมาตรของลำต้นแทนแบบจำลองโครงสร้างเชิงปริมาณ (Quantitative structural model: QSM) ที่วัดรูปทรงของลำต้นที่มีโอกาสเกิดความคลาดเคลื่อนจากการวัดถ้าเกิดต้นไม้ในพื้นที่ศึกษาที่มีความหนาแน่น และมีหลายสายพันธุ์ ในงานวิจัยได้นำ Poisson surface reconstruction model (Kazhdan *et al.*, 2006) เพื่อแก้ปัญหาดังกล่าว และคาดหวังว่าจะให้ผลลัพธ์ที่ดีกว่า QSM โดยได้ทดลองกับต้นไม้ป่าชายเลนที่ประเทศออสเตรเลีย อย่างไรก็ตาม ผลจากการศึกษาพบว่า ค่าปริมาตรของลำต้นที่ได้จากทั้งสองวิธีมีค่าไม่แตกต่างกันอย่างมีนัยสำคัญ แสดงให้เห็นว่า ถ้าพื้นที่ศึกษาไม่มีความซับซ้อนด้านสายพันธุ์ วิธี QSM สามารถนำมาใช้ในการคำนวณปริมาตรของลำต้น และให้ผลไม่ต่างจากวิธีการประมาณค่าพื้นผิวสามมิติ



บทที่ 4


วิธีการดำเนินงานวิจัย

งานวิจัยเรื่องนี้ แบ่งวิธีการดำเนินงานวิจัยออกเป็น 2 ส่วน ส่วนแรกเป็นวิธีการดำเนินงานวิจัยการจำแนกพันธุ์ไม้ป่าชายเลนเขตร้อนด้วยภาพถ่ายระยะทางคอนโวลูชัน แสดงในหัวข้อที่ 4.1 ส่วนที่สองเป็นวิธีการดำเนินงานวิจัยการสร้างแบบจำลองมวลชีวภาพของต้นไม้ป่าชายเลนเขตร้อนด้วย TLS แสดงในหัวข้อที่ 4.2

4.1 วิธีการจำแนกพันธุ์ไม้ป่าชายเลนเขตร้อนด้วยภาพถ่ายระยะทางคอนโวลูชัน

4.1.1 พื้นที่ศึกษา

พื้นที่ศึกษามีพิกัด ละติจูดที่ $8^{\circ} 22'$ ถึง $8^{\circ} 31'$ เหนือ และลองจิจูดที่ $100^{\circ} 06'$ ถึง $100^{\circ} 12'$ ตะวันออก ตั้งอยู่ในพื้นที่ป่าชายเลน บริเวณแหลมตะลุมพุก อำเภอปากพนัง จังหวัดนครศรีธรรมราช ดังแสดงในภาพที่ 4-1 ลักษณะของพื้นที่ทางด้านตะวันออกมีลักษณะเป็นชายหาดยาว วางตัวแนวเหนือ – ใต้ ถัดเข้ามาทางฝั่งตะวันตกเป็นสังคมของป่าชายเลน มีพื้นที่ประมาณ 56.8 ตารางกิโลเมตร พบพันธุ์ไม้ป่าชายเลนทั้งหมด 23 ชนิด 11 วงศ์ โดยมีพันธุ์ไม้เด่นในพื้นที่จำนวน 5 สายพันธุ์ ประกอบด้วย โกงกางใบเล็ก โกงกางใบใหญ่ ถั่วขาว แสมขาว และแสมทะเล (Koedsin and Vaiphasa, 2013)



ภาพที่ 4-1 พื้นที่ศึกษาป่าชายเลนบริเวณแหลมตะลุมพุก อำเภอปากพนัง (ภาพผสมสีเท็จ 432 RGB)

4.1.2 ข้อมูลที่ใช้ในงานวิจัย

1) ข้อมูลภาพถ่ายจากดาวเทียม

งานวิจัยนี้ได้ใช้ข้อมูลภาพถ่ายจากดาวเทียม Quickbird จากงานวิจัยของ Watanakij and Vaiphasa (2016) บันทึกภาพเมื่อวันที่ 13 ตุลาคม พ.ศ. 2552 ภาพถ่ายได้รับการปรับแก้เชิงคลื่น (Radiometric correction) ในระดับ 2A จำนวน 11 บิท ในการประมวลผลข้อมูลได้เลือกใช้ภาพทั้งสองระบบ โดยแปลงค่ากลับเป็นค่ารังสี (Spectral radiance) ด้วยแบบจำลอง MODTRAN-4 จากนั้น ปรับแก้ข้อมูลชั้นบรรยากาศ และแปลงไปเป็นค่าการสะท้อนด้วยแบบจำลอง Fast Line of Sight Atmospheric Analysis of Spectral Hypercube (FLAASH) ด้วยโปรแกรม ENVI 4.8 ข้อมูลได้รับการปรับแก้เชิงเรขาคณิตกับข้อมูลออร์โธรีจากสำนักงานเศรษฐกิจการเกษตร ด้วยวิธีภาพต่อภาพ กำหนดค่าคลาดเคลื่อนไม่เกิน 2 จุดภาพ โดยมีระบบพิกัดอ้างอิงแบบ World Geodetic System 1984 (WGS1984) และระบบพิกัดแบบ Universal Transverse Mercator (UTM) Zone 47 North

2) ข้อมูลภาคสนาม

ข้อมูลภาคสนามในงานวิจัยนี้ได้รับความอนุเคราะห์จากข้อมูลการสำรวจของ Koedsin and Vaiphasa (2013) ที่ได้เก็บข้อมูลในเดือนกุมภาพันธ์ และ มีนาคม พ.ศ. 2554 ซึ่งมีช่วงเวลาห่างจากวันที่บันทึกภาพถ่ายจากดาวเทียม Quickbird เป็นเวลา 17 เดือน จากงานวิจัยของ Koedsin and Vaiphasa (2013) และ Watanakij and Vaiphasa (2016) ที่ใช้ข้อมูลชุดเดียวกับงานวิจัยนี้พบว่า ช่วงเวลาดังกล่าว พื้นที่ป่าชายเลนไม่มีการเปลี่ยนแปลงอย่างชัดเจน โดยวิธีการเก็บข้อมูลได้วางแปลงขนาด 30 X 30 เมตร เก็บข้อมูลพิกัดโดยอ้างอิงพิกัดจากหมุดหลักฐานของกรมแผนที่ทหารเลขที่ 3367 ปรับแก้ค่าพิกัดโดยใช้หลักการ Differential GPS: DGPS) โดยมีค่าความถูกต้องทางตำแหน่งไม่เกิน 5 เมตร จากนั้น เก็บข้อมูลชนิดพันธุ์ไม้ภายในแปลง โดยเลือกเฉพาะต้นที่มีความสูงมากกว่า 2.5 เมตร ขั้นตอนการเก็บข้อมูล มีดังนี้

(ก) ถ่ายค่าพิกัดจากหมุดหลักฐานของกรมแผนที่ทหารเลขที่ 3367 ซึ่งตั้งอยู่ในสำนักงานโครงการชลประทานที่ 15 อำเภอบางบาล มาสู่หมุดชั่วคราวใกล้กับพื้นที่ศึกษา

(ข) ใช้ข้อมูลการเลือกแปลงตัวอย่างจากงานวิจัยของ ธันวา และคณะ (2552) ซึ่งเป็นข้อมูลภาพถ่ายจากดาวเทียม Aster ที่ผ่านการจำแนกแบบไม่ควบคุม K-means จำนวน 15 เขตแบ่ง ใช้วิธีการวางแผนเลือกแปลงตัวอย่างแบบการสุ่มตัวอย่างแบบแบ่งชั้น และใช้วิธี Line transect ในการเลือกแปลงตัวอย่างซึ่งเป็นวิธีที่มีความเหมาะสมกับสภาพป่าที่มีต้นไม้ขึ้นแน่นทึบ โดยมีการวางแปลงตัวอย่างครอบคลุม 15 เขตแบ่ง ประมาณ 500 แปลง

(ค) หลังจากการเลือกแปลงตัวอย่างแล้ว ได้ออกเรือสำรวจร่วมกับเจ้าหน้าที่จาก สถานีพัฒนาทรัพยากรป่าชายเลนที่ 44 เพื่อตรวจสอบแปลงตัวอย่างที่สามารถเข้าถึงได้ และ ครอบคลุมทุกเขตแบ่ง โดยคัดเลือกมาประมาณ 100 แปลง ใช้เครื่องรับสัญญาณระบบกำหนด ตำแหน่งบนพื้นผิวโลก โดยล่องเรือไปตามแนวคลอง และยึดค่าทิศเหนือ และค่าทิศตะวันออกที่อ่าน ได้จากเครื่องรับสัญญาณระบบกำหนดตำแหน่งบนพื้นผิวโลกเป็นหลัก เมื่อพบแนวทิศเหนือ หรือทิศ ตะวันออกของค่าพิกัดแปลงตัวอย่างแล้วหยุดเรือ แล้วใช้เข็มทิศในตัวเครื่องรับสัญญาณระบบกำหนด ตำแหน่งบนพื้นผิวโลกเล็งทิศทางที่จะเข้าสู่แปลงตัวอย่าง ใช้เชือกไนลอนยาว 30 เมตร วัดระยะทาง จากขอบแม่น้ำ (เริ่มวัดเมื่อห่างจากขอบพอประมาณ) สู่ตำแหน่งจุดกึ่งกลางแปลงตัวอย่าง

(ง) เมื่อพบตำแหน่งจุดกึ่งกลางแปลงตัวอย่างแล้ว วางแปลงขนาด 30×30 ตารางเมตร นับจำนวนแยกเป็นแต่ละสายพันธุ์ของต้นไม้ทุกต้นในแปลงที่มีสูงมากกว่า 2.5 เมตร

(จ) บันทึกค่าจุดกึ่งกลางแปลงตัวอย่าง ปรับแก้ความถูกต้องโดยใช้หลักการ DGPS ซึ่งใช้เครื่องรับสัญญาณระบบกำหนดตำแหน่งบนพื้นผิวโลกแบบพกพา จำนวน 2 เครื่อง เรียกว่า Pseudorange-based Difference GPS ซึ่งวิธีนี้ให้ความถูกต้องทางตำแหน่งไม่เกิน 5 เมตร

ได้ลงสำรวจภาคสนามเพิ่มเติมในเดือนธันวาคม พ.ศ. 2560 เพื่อเก็บข้อมูลในบริเวณ อื่นเพิ่ม และตรวจสอบข้อมูลภาคสนามที่มีอยู่เดิม กำหนดแปลงที่ต้องลงสำรวจเริ่มจากจำแนก ภาพถ่ายจากดาวเทียม Quickbird แบบไม่ควบคุม โดยใช้วิธีการจำแนกจัดกลุ่มโดยเรียงลำดับ (Sequential clustering classification หรือ K-means) จำนวน 15 เขตแบ่ง เลือกแปลงตัวอย่าง แบบการสุ่มตัวอย่างแบบแบ่งชั้นได้จำนวนแปลงสุ่ม จากนั้น เก็บตัวอย่างโดยใช้วิธีการเช่นเดียวกับ Koedsin and Vaiphasa (2013)

จุฬาลงกรณ์มหาวิทยาลัย

CHULALONGKORN UNIVERSITY

4.1.3 ระบบที่ใช้ในงานวิจัย

1) ทรัพยากรระบบประมวลผล

Intel® Xeon® E5 2660 ความเร็ว 2.2 GHz 64-bit หน่วยความจำขนาด 32 GB หน่วยประมวลผลกราฟฟิก NVIDIA GeForce GTX1080Ti หน่วยความจำกราฟฟิกขนาด 11 GB ใช้ระบบปฏิบัติการ Linux Ubuntu 14.6


2) ซอฟต์แวร์ที่ใช้ในการประมวลผล

(ก) การประมวลผลภาพถ่ายจากดาวเทียม Quickbird ทั้งในกระบวนการเตรียม ข้อมูล และสร้างข้อมูลนำเข้าสู่ CNN ได้ใช้ซอฟต์แวร์รหัสเปิด Quantum GIS เวอร์ชัน 2.18.11 ใน ส่วนการประมวลผล CNN ได้ใช้ซอฟต์แวร์รหัสเปิดภาษา Python โดยใช้ Library ด้าน Machine learning ได้แก่ TensorFlow

(ข) การประมวลผลทางสถิติ ใช้ซอฟต์แวร์ Matlab เวอร์ชัน 2018
(Chulalongkorn University License)










4.1.4 การเตรียมข้อมูลภาพ และข้อมูลอ้างอิง

ข้อมูลจากภาคสนามที่ทาง Watanakij and Vaiphasa (2016) ได้ Grow ค่าขึ้นให้มีขนาด 30×30 เมตร ยังมีขนาดเล็กเกินไป ในงานวิจัยนี้ ได้ใช้จุดสุ่มสำรวจในแต่ละกลุ่มแปลงที่สำรวจ มาสร้างเป็นภาพให้มีขนาด 512×512 จุดภาพ (ตัวอย่างในภาพที่ 4-2) ซึ่งเป็นขนาดที่ใหญ่ที่สุดเท่าที่ทรัพยากรที่ใช้ในการประมวลผลสำหรับงานวิจัยนี้สามารถประมวลได้ สร้างข้อมูลตัวอย่าง โดยแบ่งข้อมูลออกเป็นสองชุด ได้แก่ ข้อมูลภาพถ่ายจากดาวเทียม และข้อมูลอ้างอิงจากการสำรวคนนำมาสร้างเป็นภาพข้อมูลตัวอย่าง โดยแบ่งเป็นคลาสต่าง ๆ จำนวน 10 คลาส พร้อมแสดงค่าสีแบบ RGB ตามตารางที่ 4-1 ดังนี้



ภาพที่ 4-2 ตัวอย่างข้อมูลภาพถ่ายจากดาวเทียม และข้อมูลอ้างอิงขนาด 512×512 จุดภาพ

ตารางที่ 4-1 รหัสค่าสีของคลาสที่ใช้ในการจำแนกพันธุ์ไม้ป่าชายเลน

รหัสคลาส	คลาส	รหัสค่าสี			สี
		R	G	B	
Clsh	เมฆ เงา	255	255	255	
Ra	โกกางใบเล็ก	038	115	000	
Rm	โกกางใบใหญ่	252	053	018	
Aa	แสมขาว	255	255	115	
Am	แสมทะเล	000	038	115	
Bp	ถั่วขาว	190	255	232	
Mx	พันธุ์ผสม	255	115	223	
Wa	น้ำ	022	098	250	
Ur	เมือง	178	178	178	
Na	ไม่มีข้อมูล	000	000	000	

จากตารางที่ 4-1 นำคลาสที่กำหนดพร้อมค่าสีมาสร้างเป็นข้อมูลเชิงบรรยายในรูปแบบตาราง เชื่อมโยงกับข้อมูลอ้างอิงด้วยความสัมพันธ์แบบหนึ่งต่อหนึ่ง และนำไปใช้เชื่อมโยงกับผลลัพธ์ในขั้นตอนสุดท้ายเพื่อกำหนดค่าให้กับคลาสที่ได้จากการจำแนก

4.1.5 การทำ Normalization

ภาพถ่ายจากดาวเทียมที่นำเข้าสู่โครงข่ายจะเป็นภาพแบบ Multi-spectral มีจำนวนทั้งหมด 3 ช่วงคลื่น มีขนาด 11 บิต ในการส่งภาพเข้าสู่โครงข่าย ต้องปรับค่าสัญญาณแต่ละช่วงคลื่นให้อยู่ในรูปแบบ 8 บิต ซึ่งวัตถุประสงค์ของการทำ Normalization เพื่อลดขนาดของหน่วยความจำ สัญญาณภาพลงส่งผลให้การประมวลผลมีความเร็วเพิ่มขึ้น และช่วยให้ค่า Cost function มีการลู่เข้า Global optima ได้เร็วยิ่งขึ้น ในกรณีของภาพถ่ายจะ Normalize ค่าให้อยู่ในช่วง 0 – 255

4.1.6 การแปลงข้อมูลภาพให้อยู่ในรูปแบบ Numpy array

ข้อมูลภาพถ่าย และข้อมูลภาพอ้างอิงที่ใช้สำหรับการสอนโครงข่ายต้องถูกแปลงค่าให้อยู่ในรูปของเวกเตอร์ Numpy โดยสร้างเป็น Array ของตัวเลขขึ้นมา (ดังภาพที่ 4-3) เพื่อนำเข้า

ข้อมูลสุ่มกระจายในขั้นตอนการสอน แทนการนำเข้าข้อมูลแบบไฟล์ภาพที่ใช้เวลาในการนำเข้าข้อมูล การใช้ข้อมูลภาพในรูปแบบ Numpy array ช่วยลดเวลาในการเปิดไฟล์สำหรับการฝึกสอน

98	96	96	96	96	94	96	102	105	98	98	94	96	94	100	98	94	100
102	102	98	94	94	94	96	98	100	92	104	111	102	104	117	122	126	126
131	122	111	117	111	96	96	98	96	96	111	115	109	91	94	107	102	104
124	131	117	113	100	98	100	95	95	98	100	98	109	102	91	93	100	104
95	95	91	93	106	104	100	100	111	106	102	104	102	102	104	95	89	106
109	124	117	100	102	109	97	95	97	100	100	100	100	102	102	102	106	100
102	108	104	104	95	93	104	104	106	102	102	102	98	93	104	106	104	108
108	110	106	104	125	119	115	121	128	117	110	119	106	125	134	125	123	110
99	104	93	86	88	102	112	115	110	99	102	97	99	99	112	112	106	110
117	121	119	112	112	119	127	121	108	130	123	123	123	108	108	103	101	99
103	103	103	108	99	97	121	138	145	112	112	112	112	101	99	101	108	121
136	125	110	125	134	125	142	140	129	110	125	114	121	114	114	131	129	121
122	114	121	122	125	131	118	116	125	123	131	140	123	116	121	116	113	112
99	110	110	112	116	103	95	125	131	123	127	134	131	131	129	112	97	105
118	108	101	95	105	103	118	99	103	103	103	108	108	105	99	101	103	125
110	110	101	123	116	116	108	116	123	110	99	92	92	90	103	118	118	109
96	108	99	103	99	96	99	99	108	112	105	101	116	116	105	109	123	112
120	121	112	120	129	105	92	101	123	120	114	103	103	103	101	109	107	109
101	105	118	120	129	114	112	103	118	120	116	111	114	101	109	109	116	120
111	118	120	105	105	101	102	102	111	101	107	116	98	105	111	118	124	120
120	118	107	107	126	124	111	111	96	109	113	107	116	120	116	118	113	107
109	116	120	126	142	139	144	150	139	120	111	118	124	113	96	105	105	96
96	109	118	118	120	109	105	100	102	107	109	109	104	104	109	113	111	111
98	100	100	107	108	110	102	95	102	106	102	104	115	111	110	125	115	119
100	104	113	104	104	106	108	110	110	113	114	108	110	101	101	105	116	108
103	103	101	114	122	111	100	100	104	106	111	111	95	95	98	95	91	102
106	100	106	117	110	102	104	104	104	106	90	93	90	95	101	101	97	97
112	125	117	125	119	106	95	109	113	98	91	98	100	89	95	106	102	104
95	89	89	83	80	72	61	59										

a

b

ภาพที่ 4-3 ตัวอย่างการแปลงค่าจุดภาพ (a) และภาพอ้างอิง (b) ให้อยู่ในรูปแบบ Numpy array

4.1.7 การสอน และการทดสอบ

เป็นกระบวนการที่สำคัญที่ส่งผลต่อประสิทธิภาพของการทำงาน อย่างไรก็ตาม ยังไม่มีแบบจำลองที่ดีที่สุดสำหรับทุกงาน จำเป็นต้องทดสอบ (Trial and error) ในแต่ละงานเพื่อหาแบบจำลองที่มีประสิทธิภาพดีที่สุดในการทำงานได้กำหนดพารามิเตอร์ต่าง ๆ ดังนี้

1) ส่งภาพข้อมูลตัวอย่างเข้าไปในโครงข่าย

แบ่งข้อมูลออกเป็นสองชุด ได้แก่ ข้อมูลฝึกสอน และข้อมูลตรวจสอบ (Training and validation) จำนวน 454 ภาพ แต่ละภาพมีขนาด 512×512 จุดภาพ แบ่งเป็นสัดส่วน 80 / 20 ได้ข้อมูลสำหรับฝึกสอน 374 ภาพ และข้อมูลสำหรับตรวจสอบ 80 ภาพ ในงานวิจัยนี้ ได้ใช้ Transfer learning แบบจำลองน้ำหนักโครงข่าย (Weighted model) จาก Panboonyuen *et al.* (2019) เพื่อเป็นค่าน้ำหนักตั้งต้น (Hu *et al.*, 2015a; Wang *et al.*, 2017b; Zhou *et al.*, 2016) และช่วยให้ค่า loss function มีการลู่เข้าได้เร็วขึ้น

2) กำหนดไฮเปอร์พารามิเตอร์ที่ใช้ในการคำนวณสำหรับโครงข่าย

ไฮเปอร์พารามิเตอร์ที่ต้องกำหนดค่า ได้แก่ หน้าต่าง Convolution สำหรับใช้ในการกรองข้อมูลภาพขนาด 3×3 จำนวนการก้าวข้ามของหน้าต่าง (Stride) = 2 รุ่นการผลิตต่อรอบ (Batch size per epoch) = 4 และจำนวนรอบ (Epoch) = 10,000

3) สถาปัตยกรรมของโครงข่ายที่ใช้ประมวลผลจำแนกภาพ

ในงานวิจัยนี้ ได้นำเสนอวิธีการ Compressed fully convolution network (CFCN) ซึ่งปรับปรุงสถาปัตยกรรมของ FCN-8s (Long *et al.*, 2015) โดยปรับลดค่าพารามิเตอร์ในโครงข่าย (Network pruning) ให้มีความเหมาะสมกับทรัพยากรที่มีจำกัด และลดเวลาการสอนโครงข่ายลง (Han *et al.*, 2016) FCN-8s ใช้บล็อกคอนโวลูชันทั้งหมด 5 ชั้น โดยบล็อกที่หนึ่ง และสองแบ่งเป็นชั้นคอนโวลูชันจำนวน 2 ชั้น ในบล็อกที่ 3 – 5 แบ่งเป็นชั้นคอนโวลูชันจำนวน 3 ชั้น แต่ละบล็อกมีชั้นพูลลิงแบบสูงสุดเป็นชั้นสุดท้าย จากนั้น เชื่อมกับชั้นเชื่อมโยงเต็มรูปแบบจำนวน 2 ชั้น และทำนายผลลัพธ์ ก่อนทำทรานโพลคอนโวลูชันเพื่อปรับภาพให้มีขนาดเท่ากับตอนนำเข้าโครงข่าย รวมพารามิเตอร์ที่ใช้ในสถาปัตยกรรม FCN-8s จำนวนทั้งสิ้น 134,353,658 พารามิเตอร์

ตารางที่ 4-2 รายละเอียดสถาปัตยกรรมโครงข่ายต้นแบบ (FCN-8s)

Layer (type)	Output Shape	Parameter
Permute	(None, 512, 512, 3)	0
Convolution 1_1	(None, 512, 512, 64)	1,792
Convolution 1_2	(None, 512, 512, 64)	36,928
Max pooling 1	(None, 256, 256, 64)	0
Convolution 2_1	(None, 256, 256, 128)	73,856
Convolution 2_2	(None, 256, 256, 128)	147,584
Max pooling 2	(None, 128, 128, 128)	0
Convolution 3_1	(None, 128, 128, 256)	295,168
Convolution 3_2	(None, 128, 128, 256)	590,080
Convolution 3_3	(None, 128, 128, 256)	590,080
Max pooling 3	(None, 64, 64, 256)	0
Convolution 4_1	(None, 64, 64, 512)	1,180,160
Convolution 4_2	(None, 64, 64, 512)	2,359,808
Convolution 4_3	(None, 64, 64, 512)	2,359,808
Max pooling 4	(None, 32, 32, 512)	0
Convolution 5_1	(None, 32, 32, 512)	2,359,808
Convolution 5_2	(None, 32, 32, 512)	2,359,808
Convolution 5_3	(None, 32, 32, 512)	2,359,808
Max pooling 5	(None, 16, 16, 512)	0
Fully connected 6	(None, 16, 16, 4096)	102,764,544
Fully connected 7	(None, 16, 16, 4096)	16,781,312
Predicted score	(None, 16, 16, 10)	40,907


Deconvolution	(None, 514, 514, 10)	1,610
Cropping 2D	(None, 512, 512, 10)	0

Total params: 134,353,658

Trainable params: 134,353,658

Non-trainable params: 0

สถาปัตยกรรมของวิธีการนำเสนอ (CFCN) แบ่งออกเป็น 2 ส่วนหลัก ได้แก่ ส่วนคอนโวลูชัน และทรานโพสคอนโวลูชัน ส่วนคอนโวลูชัน (ภาพที่ 4-4) ประกอบด้วยกลุ่ม (Block) ของชั้นคอนโวลูชันจำนวน 2 กลุ่ม แต่ละกลุ่มมีชั้นคอนโวลูชันจำนวน 2 ชั้นต่อกันตามด้วยชั้นพูลลิงจำนวน 1 ชั้น เพื่อ Down sampling ข้อมูล ต่อด้วยการข้ามชั้นไปยังชั้นการเชื่อมโยงสูงสุดจำนวน 2 ชั้น ในส่วนทรานโพสคอนโวลูชันเป็นการทำนายผล และ Up sampling ข้อมูลเพื่อให้ผลลัพธ์สุดท้ายมีขนาดเท่ากับข้อมูลที่ส่งเข้าสู่โครงข่าย ประกอบด้วย ชั้นทรานโพสคอนโวลูชันจำนวน 1 ชั้น และชั้นจำแนกด้วยฟังก์ชัน Softmax จำนวน 1 ชั้น ในการปรับค่าพารามิเตอร์ของโครงข่ายให้มีค่าที่เหมาะสมใช้วิธี Stochastic gradient descent (Luus *et al.*, 2015) โดยปรับค่าการเรียนรู้ที่ 0.001 เพื่อให้ค่าการเรียนรู้มีการลู่เข้าสู่ค่า Global optima ที่ดีขึ้น และกำหนดค่าโมเมนตัมที่ 0.9 เพื่อช่วยป้องกันไม่ทำให้ค่าการเรียนรู้ลู่เข้าสู่ Local optima



ภาพที่ 4-4 สถาปัตยกรรม CFCN ที่ใช้ในการจำแนกพันธุ์ไม้ป่าชายเลนเขตร้อน ประกอบด้วยส่วนคอนโวลูชัน และทรานโพสคอนโวลูชัน และปรับมิติของภาพแต่ละชั้นให้เหมาะสมกับทรัพยากรประมวลผล

ตารางที่ 4-3 รายละเอียดสถาปัตยกรรมของวิธีการนำเสนอ (CFCN)

Layer (type)	Output Shape	Parameter
Permute	(None, 512, 512, 3)	0
Convolution 1_1	(None, 512, 512, 64)	1,792
Convolution 1_2	(None, 512, 512, 64)	36,928
Max pooling 1	(None, 256, 256, 64)	0
Convolution 2_1	(None, 256, 256, 128)	73,856
Convolution 2_2	(None, 256, 256, 128)	147,584
Max pooling 2	(None, 128, 128, 128)	0
Fully connected 6	(None, 128, 128, 1024)	6,423,552
Fully connected 7	(None, 128, 128, 1024)	1,049,600
Predicted score	(None, 128, 128, 10)	10,250
Deconvolution	(None, 514, 514, 10)	1,610
Cropping 2D	(None, 512, 512, 10)	0
Total params: 7,745,172		
Trainable params: 7,745,172		
Non-trainable params: 0		

จากภาพที่ 4-4 และตารางที่ 4-3 สถาปัตยกรรมที่ใช้ในงานวิจัยนี้ เมื่อใช้ข้อมูล และตั้งค่าพารามิเตอร์ตามข้อ 4.1.7 หน่วยความจำของ GPU สำหรับพารามิเตอร์ตามที่ตั้งค่านี้อาจใช้ไปจำนวน 10.72 GB (จากหน่วยความจำทั้งหมด 11.00 GB) ใช้เวลาในการสอนโครงข่าย 16 วัน และจำนวนพารามิเตอร์ของโครงข่ายมีทั้งสิ้น 7,745,172 พารามิเตอร์

4.1.8 การทดสอบความถูกต้องของการจำแนก

1) ทดสอบประสิทธิภาพการจำแนกของโครงข่ายจากวิธีการนำเสนอ (CFCN) ด้วยการสร้าง Confusion matrix เปรียบเทียบผลการทำนายด้วยการทดสอบ ค่าความถูกต้องของการจำแนก

ค่าในแต่ละแถวแทนจำนวนข้อมูลที่ถูกแปลเป็นคลาสนั้น และคือคลาสนั้นจริง ส่วนค่าในแต่ละสดมภ์แทนค่าจำนวนข้อมูลที่แปลเป็นคลาสนั้นว่าไปตกอยู่ในคลาสใดบ้าง (Panboonyuen *et al.*, 2019) แบ่งเป็นค่าต่าง ๆ ดังนี้

(ก) True positive (TP) คือจำนวนข้อมูลที่ทำนายได้ในคลาสนั้น และผลลัพธ์คือคลาสดังกล่าว

(ข) False positive (FP) คือจำนวนข้อมูลที่ทำนายได้ในคลาสนั้นแต่ผลลัพธ์คือคลาสนอื่น

(ค) True negative (TN) คือจำนวนข้อมูลที่ทำนายได้ในคลาสนอื่น และผลลัพธ์คือคลาสนอื่น

(ง) False negative (FN) คือ จำนวนข้อมูลที่ทำนายได้ในคลาสนอื่น แต่ผลลัพธ์คือคลาสนั้น

ค่า TP FP TN และ FN จะถูกนำมาคำนวณค่าความเที่ยง (Precision) ค่าความระลึก (Recall) ค่าเอฟวัน (F1 score) และค่า IoU เฉลี่ย (Mean IoU) ตามสมการที่ 4-1 ถึง 4-5 ดังนี้

$$Accuracy = \frac{TP+TN}{TP+FP+FN+TN} \quad (4-1)$$

$$Precision = \frac{TP}{TP+FN} \quad (4-2)$$

$$Recall = \frac{TP}{TP+FN} \quad (4-3)$$

$$F1 \text{ score} = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (4-4)$$

$$Mean \text{ IoU} = \frac{TP}{TP+FP+FN} \quad (4-5)$$

2) เปรียบเทียบความถูกต้องระหว่างวิธีการนำเสนอ กับการจำแนกแบบความน่าจะเป็นสูงสุดด้วยค่าอ้างอิงจากการสำรวจภาคสนาม โดยใช้ Confusion matrix เพื่อคำนวณค่าความถูกต้องรวม ความถูกต้องของผู้ใช้ และความถูกต้องของผู้ผลิต ตามสมการที่ 2-27 2-28 และ 2-29 ตามลำดับ

3) ทดสอบค่าความสอดคล้องของการจำแนกข้อมูลด้วยค่าสถิติโคเฮนส์ แคปปา ตามสมการที่ 2-30

4) ทดสอบค่าความแตกต่างของการจำแนกพันธุ์ไม้ป่าชายเลนด้วย CNN กับวิธีการมาตรฐานแบบกำกับดูแลแล้วผลที่ได้มีความแตกต่างกันอย่างมีนัยสำคัญหรือไม่ ตามสมการที่ 2-31

4.2 วิธีการสร้างแบบจำลองมวลชีวภาพของต้นไม้ป่าชายเลนเขตร้อนด้วยเครื่องสแกนเลเซอร์ภาคพื้นดิน

4.2.1 พื้นที่ศึกษา

ตั้งอยู่ที่ศูนย์ศึกษาธรรมชาติกองทัพบก (บางปู) เฉลิมพระเกียรติ 72 พรรษา มหาราชินี ตำบลบางปู อำเภอเมือง จังหวัดสมุทรปราการ อยู่ในชุมชนเมือง และอุตสาหกรรมบางปู โดยพื้นที่ดังกล่าวใช้เป็นสถานที่พักผ่อนให้แก่ทหาร และกองทุนสัตว์ป่าโลก (World Wildlife Fund: WWF) ประเทศไทย เป็นผู้จัดการโครงการรวมถึงการพัฒนาพื้นที่ ที่แต่ก่อนเป็นพื้นที่นาุ้งหึ่งร้างที่ถูกลักลอบเข้ามาใช้ประโยชน์อย่างไม่ถูกต้อง พันธุ์ไม้ป่าชายเลนเขตร้อนที่โดดเด่นในพื้นที่ศึกษา คือ ต้นแสมทะเล (*Avicennia marina* (Forsk.) Vierh) โดยมีช่วงอายุที่ต่างกันออกไป ลักษณะพื้นที่เป็นตะกอนปากแม่น้ำ ได้รับอิทธิพลโดยตรงจากน้ำขึ้น น้ำลงจากอ่าวไทย พื้นที่ได้รับการปรับปรุง ขุดลอกคลอง และพัฒนาเส้นทางศึกษาธรรมชาติ ทั้งสร้างสะพานไม้ และแนวถนนคอนกรีต โดยสภาพพื้นที่ปัจจุบันมีสภาพใกล้เคียงกับป่าชายเลนธรรมชาติ (Laongmanee, 2011) ดังภาพที่ 4-5 จุดสีแดงในภาพเป็นพื้นที่ที่จะใช้วางพื้นที่ตัวอย่าง



ภาพที่ 4-5 ศูนย์ศึกษาธรรมชาติกองทัพบก (บางปู) เฉลิมพระเกียรติ 72 พรรษามหาราชินี

4.2.2 อุปกรณ์ที่ใช้ในงานวิจัย

1) อุปกรณ์การเก็บข้อมูลจะใช้เครื่องสแกนเลเซอร์ภาคพื้นดิน (Terrestrial laser scanner: TLS) ใช้อุปกรณ์ของ Topcon รุ่น GLS2000 ได้รับความอนุเคราะห์จาก บริษัท ทีโอคอน อินสทรูเมนต์ (ไทยแลนด์) มีรายละเอียดคุณสมบัติเชิงเทคนิคที่ผ่านความต้องการขั้นต่ำในการทำงาน เก็บข้อมูลต้นไม้ในพื้นที่ป่า (Maas *et al.*, 2008) ดังตารางที่ 4-2

ตารางที่ 4-4 คุณสมบัติของเครื่องสแกนเลเซอร์ภาคพื้นดิน Topcon รุ่น GLS 2000

คุณสมบัติ	รายละเอียด
คลาสเลเซอร์	3R (ปลอดภัยต่อดวงตา)
ขอบเขตการมองเห็น (FOV)	แนวนอน (360°) แนวตั้ง (270°)
ระยะการเก็บข้อมูล	210 เมตร
ความละเอียดการสแกน	ขนาดจุด (4 มิลลิเมตร) ระยะห่างจุด (3.1 มิลลิเมตร)
อัตราการสแกน	120,000 จุดต่อวินาที
น้ำหนัก	10 กิโลกรัม
ช่วงคลื่น	Near Infrared (1,064 มิลลิเมตร)
อุปกรณ์พิเศษ	กล้องถ่ายภาพในตัว หน้าจอสัมผัส

2) ซอฟต์แวร์ Scan Master สำหรับในการประมวลผลข้อมูล Point cloud ได้รับความอนุเคราะห์จาก บริษัท ทีโอคอนอินสทรูเมนต์ (ไทยแลนด์) และซอฟต์แวร์รหัสเปิด Cloud compare สามารถดาวน์โหลดได้จาก <http://www.danielgm.net/cc/>

3) การประมวลผลทางสถิติใช้ซอฟต์แวร์ Matlab เวอร์ชัน 2018 (Chulalongkorn University License)

4.2.3 การเก็บข้อมูลด้วยเครื่องสแกนเลเซอร์ภาคพื้นดิน

เนื่องจากในงานวิจัยนี้เน้นการเก็บข้อมูลลำต้นของต้นไม้ป่าชายเลนเขตร้อน พันธุ์แสมทะเล (*Avicennia marina* (Forsk.) Veirh) จึงเลือกเก็บข้อมูลด้วยวิธี Individual tree modelling ใช้วิธีเก็บข้อมูลแบบ Multi - cam method เพื่อหลีกเลี่ยงการเกิดสิ่งกีดขวาง จุดพิกัดสามมิติที่ได้จากการเก็บข้อมูลจะถูกนำเข้าสู่การประมวลผลเพื่อรวมข้อมูลจุดพิกัดสามมิติให้เป็นข้อมูลแบบเชิงเดี่ยว ดังนี้

1) กำหนดพื้นที่เก็บตัวอย่างข้อมูลแบบเจาะจง

พื้นที่ที่ถูกเลือกต้องสามารถเดินทางเข้าถึงได้ พื้นดินเลนมีความแน่นในขณะที่น้ำลง สามารถตั้งเครื่องสแกนเลเซอร์ภาคพื้นดินได้ และลักษณะทางกายภาพของต้นไม้ไม่มีความใกล้เคียงกัน ซึ่งพื้นที่เก็บข้อมูลต้นไม้ในศูนย์ศึกษาระบบนิเวศวิทยาที่พบกบบางปูที่สามารถเดินทางเข้าถึงได้ พบอยู่บริเวณฝั่งคลองตรงข้ามสะพานแขวนบางปู (ภาพที่ 4-6) โดยบริเวณดังกล่าวเป็นพื้นที่ที่ต้นแสมทะเลเจริญเติบโต ขึ้นอยู่รวมกันเป็นกลุ่ม และมีพื้นดินที่แข็ง สามารถนำเครื่องสแกนเลเซอร์ภาคพื้นดินและเป้าอ้างอิง ไปตั้งสถานีเก็บข้อมูลเพื่อดำเนินงานวิจัย



ภาพที่ 4-6 (a) พื้นที่เก็บข้อมูลต้นไม้ตัวอย่างตั้งอยู่บริเวณฝั่งคลองตรงข้ามสะพานแขวน (b) พื้นที่ศึกษาเป็นบริเวณที่ต้นแสมทะเลขึ้นเจริญเติบโตรวมกันเป็นกลุ่ม และมีสภาพดินแข็งสามารถเข้าไปเก็บข้อมูลได้

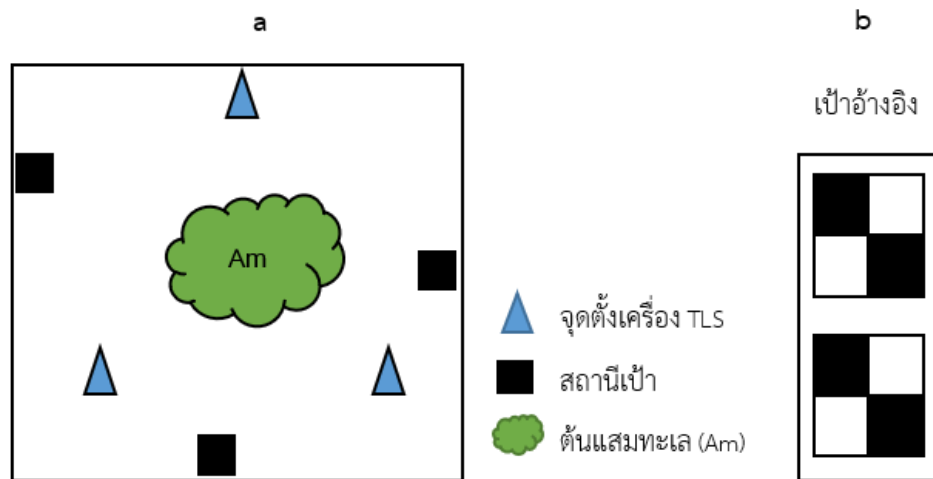
2) เลือกกลุ่มตัวอย่างในการเก็บข้อมูลแบบสุ่ม (Random sampling)

สุ่มเก็บข้อมูลกลุ่มตัวอย่างจำนวน 30 ต้น โดยกำหนดให้ต้นไม้ตัวอย่างมีรหัส BP01 – BP30 ดำเนินการวัดเส้นรอบวงของต้นไม้ตัวอย่างที่ความสูง 1.30 เมตร เพื่อคำนวณหาเส้นผ่านศูนย์กลางความสูงเพียงอก (Diameter at breast height) และเก็บข้อมูลจุดพิกัดสามมิติต้นไม้ตัวอย่างทุกต้นด้วยเครื่องสแกนเลเซอร์ภาคพื้นดิน

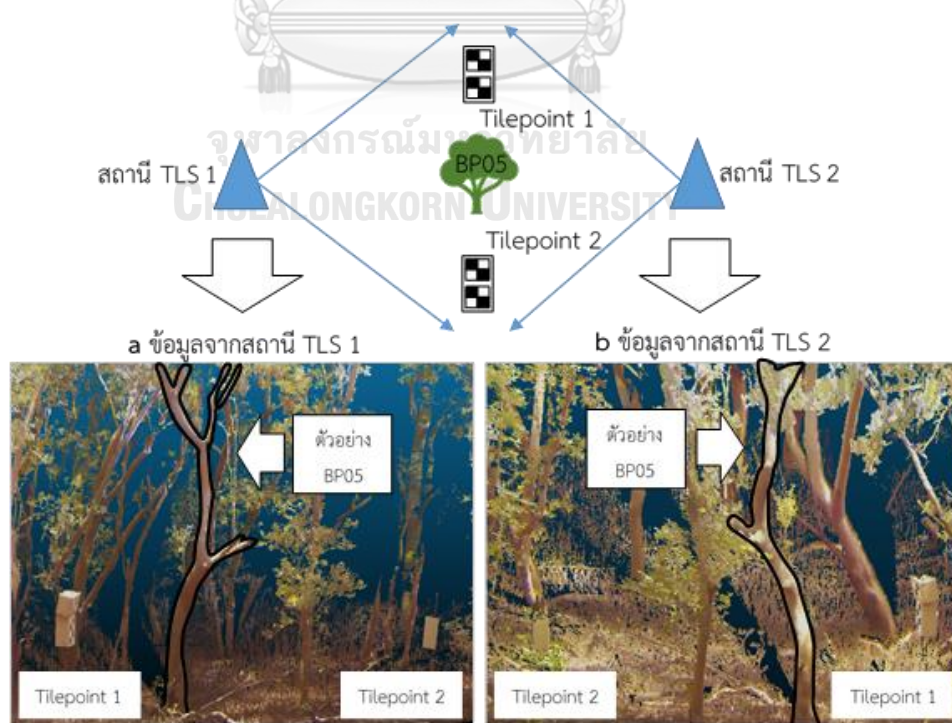
3) ตั้งสถานีเครื่องสแกนเลเซอร์ภาคพื้นดิน และเป้าอ้างอิง

สแกนตัวอย่างเพื่อเก็บข้อมูลจุดพิกัดสามมิติของต้นแสมทะเลแบบ Individual tree modeling ในแต่ละครั้งของการสแกน ต้องสามารถเก็บข้อมูลเป้าหมายอ้างอิงได้จำนวนอย่างน้อย 4 เป้าหมาย (ในงานวิจัยนี้ใช้เป้าหมายอ้างอิงจำนวน 2 สถานี โดยแต่ละสถานีมีเป้าหมายอ้างอิงจำนวน

2 เป้า) ได้แสดงตัวอย่างจุดพิกัดสามมิติของพื้นที่เก็บข้อมูลต้นไม้ตัวอย่างจากการเก็บข้อมูลในภาพที่ 4-7



ภาพที่ 4-7 (a) การตั้งเครื่องสแกนเลเซอร์ภาคพื้นดิน เพื่อเก็บข้อมูล Point cloud ต้องให้สามารถเก็บข้อมูลเป้าอ้างอิงได้ 2 สถานีเป็นอย่างน้อยต่อการสแกน 1 ครั้ง (b) สถานีเป้าอ้างอิงมีจำนวน 2 เป้า ต่อหนึ่งสถานี (ธนีสร อินทรรัตน์ และชัยโชค ไวกาษา, 2561)




ภาพที่ 4-8 ข้อมูลจุดพิกัดสามมิติของตัวอย่าง BP05 ที่ได้จากสถานี TLS 1 (a) และ 2 (b) ตัวอย่างการเก็บข้อมูลในภาพที่ 6-4 มีสถานี TLS จำนวน 2 สถานี ตั้งอยู่สถานีละฝั่งของต้นไม้ตัวอย่าง และมีสถานีเป้าหมายอ้างอิงจำนวน 2 สถานี (สถานีละ 2 เป้า)

ในการสแกนข้อมูลต้นไม้ จะหมุนเครื่องสแกนเลเซอร์ภาคพื้นดิน (ตั้งตัวอย่างในภาพที่ 4-8) ให้ครอบคลุมสถานีเป้าหมายอ้างอิง และต้นไม้ตัวอย่าง ภาพที่ 4-8a เป็นข้อมูลที่ได้จากสถานี TLS 1 และภาพที่ 4-8b เป็นข้อมูลที่ได้จากสถานี TLS 2

4) Register ข้อมูลจุดพิกัดสามมิติพหุ (Multiple pointcloud) ให้เป็นจุดพิกัดสามมิติเชิงเดี่ยว (Single pointcloud)

วิธีการ Register จะใช้เป้าหมายอ้างอิงในข้อมูลที่ได้จากการสแกนเพื่อ Merge ข้อมูลจุดพิกัดสามมิติ และคำนวณค่าคลาดเคลื่อนเฉลี่ยกำลังสอง (RMSE) ของระยะทางในแกน x y และ z ระหว่างเป้าหมายอ้างอิงแต่ละเป้า โดยค่า RMSE ไม่ควรเกิน 0.08 เมตร (Feliciano *et al.*, 2014) จากนั้น Merge ข้อมูลจุดพิกัดสามมิติทั้งหมดและแปลงให้อยู่ในรูปแบบข้อมูลจุดพิกัดสามมิติเชิงเดี่ยว ดังภาพที่ 4-9




ภาพที่ 4-9 (a) การนำจุดพิกัดสามมิติ 2 ชุด มาประมวลผลเพื่อรวมข้อมูล (b) ผลจากการแปลงข้อมูล เป็นจุดพิกัดสามมิติเชิงเดียว

จากภาพที่ 4-9a เป็นข้อมูลจุดพิกัดสามมิติที่ได้จากการสแกนด้วยเครื่องสแกน เลเซอร์ภาคพื้นดิน จำนวน 2 สถานี เมื่อนำมา register และรวมข้อมูลเพื่อแปลงข้อมูลให้เป็นจุดพิกัด สามมิติเชิงเดียว ชุดข้อมูลจุดพิกัดทั้ง 2 ชุด จะถูกรวมต่อกันอ้างอิงจากเป้าหมายอ้างอิง (ภาพที่ 4-9b) โดยงานวิจัยนี้ การ register ถูกกำหนดให้มีค่า RMSE ของระยะทางในแกน x y และ z ระหว่างคู่ของ เป้าอ้างอิงต่ำกว่า 0.01 เมตร หากค่า RMSE มีค่ามากกว่าค่าที่กำหนด จะต้องเก็บข้อมูลเพื่อ ประมวลผลใหม่

5) เลือกจุดพิกัดสามมิติสำหรับการประมวลผลข้อมูล

เนื่องจากจุดพิกัดอ้างอิงเชิงเดียวที่ได้จากการ register และ merge นั้น มีข้อมูลอื่น ๆ ที่ไม่ได้นำมาใช้ในการประมวลผลรวมอยู่ จำเป็นต้องลบออก ให้เหลือแต่ข้อมูลที่จำเป็น ดังแสดงใน ภาพที่ 4-10

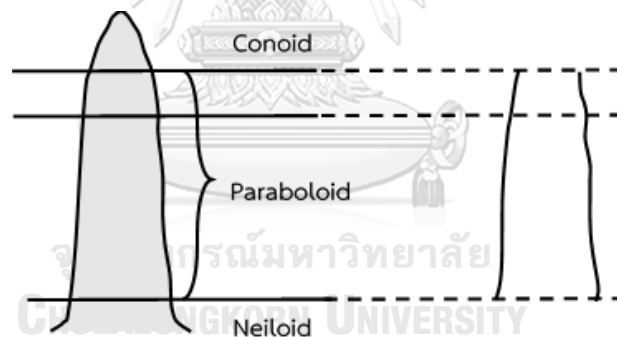


ภาพที่ 4-10 (a) จุดพิกัดสามมิติเชิงเดี่ยวถูกนำมาลบข้อมูลที่ไม่จำเป็นต่อการประมวลผล (b) ลบจุดพิกัดสามมิติออกจนเหลือแต่ลำต้นของต้นไม้ตัวอย่าง (c) ข้อมูลจุดพิกัดสามมิติที่พร้อมนำเข้าสู่กระบวนการวิเคราะห์ขั้นต่อไป (หน่วยเมตร)


จากภาพที่ 4-10a ข้อมูลจุดพิกัดสามมิติที่ไม่จำเป็นต่อการประมวลผลจะถูกลบออกให้เหลือแต่เพียงต้นไม้ตัวอย่าง จากนั้นลบจุดพิกัดสามมิติของต้นไม้ตัวอย่างในส่วนที่เป็นองค์ประกอบที่ไม่เกี่ยวข้องกับการวิเคราะห์ เช่น ใบ ก้านขนาดเล็ก (ภาพที่ 4-10b) ให้เหลือเพียงแค่ส่วนลำต้นของต้นไม้ตัวอย่าง (ภาพที่ 4-10c) เพื่อนำเข้าสู่กระบวนการในขั้นตอนต่อไป

4.2.4 การหาปริมาตรของลำต้น และการประมาณค่ามวลชีวภาพ

จุดพิกัดสามมิติเชิงเดี่ยวของต้นไม้ตัวอย่างที่ผ่านการประมวลผลเบื้องต้น จะถูกนำมาพิจารณาแยกลำต้น (Trunk) ออกเป็นท่อน (Stem) ตามบริเวณที่มีรูปร่างแบบ Frustum of paraboloid (Feliciano *et al.*, 2014) ดังภาพที่ 4-11 โดยแบ่งตามความโค้งงอของลำต้น (ถ้าลำต้นมีลักษณะตรง สามารถแยกตามส่วนให้มีความยาวมากขึ้น) ให้แต่ละท่อนมีความตรงตามแนวยาว ดังภาพที่ 4-12



ภาพที่ 4-11 บริเวณรูปร่าง Frustum of paraboloid ที่ใช้คำนวณค่ามวลชีวภาพ



ภาพที่ 4-12 การวัดพารามิเตอร์ของท่อนไม้ (a) ตัดแบ่งต้นไม้ตัวอย่างออกเป็นท่อนให้มีความตรงตามแนวยาวมากที่สุด (b) การวัดความยาว และเส้นผ่านศูนย์กลาง ตัดแปลงจาก Intarat and Vaiphasa (2018)

จากภาพที่ 4-12 ท่อนไม้ตัวอย่างแต่ละท่อนจะถูกนำมาวัดเส้นผ่านศูนย์กลาง พื้นที่หน้าตัดส่วนบน เส้นผ่านศูนย์กลางพื้นที่หน้าตัดส่วนล่าง และความยาวของท่อนไม้ ด้วยกระบวนการวัดซ้ำ (Measure of repeatability) จำนวน 5 ครั้ง เพื่อพิจารณาค่าคลาดเคลื่อนจากการวัด และนำค่าที่ได้จากการวัดมาคำนวณหาปริมาตรของแต่ละท่อนไม้ตัวอย่างด้วยสมการสมาลีเยน (Smalian's formula) ตามสมการที่ 2-33

$$V = \frac{(A_T + A_B)}{2} \times h = \frac{\left(\frac{\pi D_T^2}{4} + \frac{\pi D_B^2}{4}\right)}{2} \times h \quad (2-33)$$

จากสมการที่ 2-33 ปริมาตรที่ได้จากการคำนวณจะถูกนำมาคูณกับความหนาแน่นจำเพาะของต้นแสมทะเล ซึ่งเป็นค่าคงที่มีค่า 0.60 กรัมต่อลูกบาศก์เซนติเมตร (Njana *et al.*, 2016b) เพื่อประมาณค่ามวลชีวภาพของท่อนไม้ตัวอย่างแต่ละท่อน และปรับแก้ค่ามวลชีวภาพเรือนยอด (Canopy correction) โดยการนำผลที่ได้มาคูณค่าการปรับเรือนยอดซึ่งเป็นค่าคงที่มีค่า 1.25 จากนั้น รวมค่ามวลชีวภาพของท่อนไม้ตัวอย่างทุกท่อน จะได้ค่ามวลชีวภาพลำต้นของต้นไม้ตัวอย่าง (Trunk biomass)

จุฬาลงกรณ์มหาวิทยาลัย

4.2.5 การสร้างแบบจำลองมวลชีวภาพเหนือพื้นดินของต้นแสมทะเล

นำค่ามวลชีวภาพที่ได้จากการประมาณค่ามาสร้างแบบจำลองอัลโลเมตรีด้วยความสัมพันธ์แบบยกกำลัง (Sileschi, 2014) ดังสมการที่ 2-34 เพื่อใช้หามวลชีวภาพของพันธุ์ไม้ป่าชายเลนเขตร้อน

$$B_i = aX_i^b + \varepsilon_i \quad (2-34)$$

มวลชีวภาพเหนือพื้นดินจะถูกนำมาหาความสัมพันธ์ตามสมการที่ 2-33 เพื่อหาเส้นกราฟที่เหมาะสมกับข้อมูล (Curve fitting) ด้วยวิธีการกำลังสองน้อยที่สุด และตรวจสอบความสอดคล้องของแบบจำลองอัลโลเมตรีที่ได้ด้วยค่าสถิติ r^2 ซึ่งมีช่วงอยู่ระหว่าง 0-1 โดยค่า r^2 ที่ค่าเข้าใกล้หนึ่งแสดงถึงความสอดคล้องของข้อมูลกับแบบจำลองมีสูง

$$R^2 = 1 - \frac{\sum_i (y_i - \hat{y}_i)^2}{\sum_i (y_i - \bar{y}_i)^2} \quad (4-1)$$

เมื่อ y_i คือ ค่ามวลชีวภาพเหนือพื้นดินจริงที่ได้จากการวัดข้อมูล

\hat{y}_i คือ ค่าประมาณมวลชีวภาพเหนือพื้นดิน

\bar{y}_i คือ ค่าเฉลี่ยมวลชีวภาพเหนือพื้นดิน

4.2.6 การประมาณค่าคลาดเคลื่อน

1) แหล่งของการเกิดค่าคลาดเคลื่อน

ในการวัดค่าพารามิเตอร์เพื่อนำมาประมาณค่ามวลชีวภาพในแต่ละขั้นตอนนั้น จะมีค่าคลาดเคลื่อนเกิดขึ้นรวมอยู่ ดังนี้

(ก) ค่าคลาดเคลื่อนจากอุปกรณ์ (TLS) ในการดำเนินงานวิจัยนี้ ได้ตั้งค่าความละเอียด (Resolution) ของการสแกน (ความห่างระหว่างจุดพิกัดสามมิติ) ที่ 6.3 มิลลิเมตร ต่อ 10 เมตร ส่งผลให้การวัดแต่ละครั้งมีค่าคลาดเคลื่อนอยู่ที่ $\frac{0.006}{\sqrt{3}}$ โดยที่ $\sqrt{3}$ คือ ค่าคลาดเคลื่อนมาตรฐานของอุปกรณ์ดิจิทัล ค่าคลาดเคลื่อนดังกล่าวจะมีค่าประมาณร้อยละ 0.3 ซึ่งเป็นค่าน้อยมากเมื่อเปรียบเทียบกับค่าคลาดเคลื่อนที่เกิดจากแหล่งอื่น จึงไม่นำค่าคลาดเคลื่อนจากอุปกรณ์มาใช้ในการประมาณการแพร่ค่าคลาดเคลื่อน

(ข) ค่าคลาดเคลื่อนจากการวัดพารามิเตอร์ ประกอบด้วยเส้นผ่านศูนย์กลางพื้นที่หน้าตัดส่วนบน และล่างของท่อนไม้ และความสูงของท่อนไม้ (หัวข้อ 4.2.4) ที่ใช้กระบวนการวัดซ้ำจำนวน 5 ครั้ง ได้ค่าคลาดเคลื่อนของเส้นผ่านศูนย์กลางท่อนไม้ระหว่างร้อยละ 0.67 – 0.98 และได้ค่าคลาดเคลื่อนของความยาวท่อนไม้ระหว่างร้อยละ 0.51 – 0.73

(ค) ค่าคลาดเคลื่อนจากค่าความหนาแน่นจำเพาะของเนื้อไม้ เป็นค่าที่ได้จากการทบทวนเอกสาร โดยค่าคลาดเคลื่อนจากความหนาแน่นจำเพาะเนื้อไม้ของต้นแสมทะเล มีค่าอยู่ที่ร้อยละ 8.33 (Njana *et al.*, 2016b)

(ง) ค่าคลาดเคลื่อนจากการปรับแก้เรือนยอด เป็นค่าที่ได้จากการทบทวนเอกสาร มีค่าร้อยละ 10 (Feliciano *et al.*, 2014)

2) การแพร่ของค่าคลาดเคลื่อน

(ก) การแพร่ค่าคลาดเคลื่อนมวลชีวภาพลำต้น เป็นการประมาณค่าคลาดเคลื่อนที่ได้จากการคำนวณมวลชีวภาพของลำต้น ประกอบด้วย เส้นผ่านศูนย์กลางพื้นที่หน้าตัดท่อนไม้ส่วนบน และล่าง ความสูงของท่อนไม้ (ได้จากการวัด) และความหนาแน่นจำเพาะของเนื้อไม้ (ร้อยละ 8.33) ดังสมการที่ 2-35

$$\frac{\delta AGB_{stem}}{|AGB_{stem}|} = \sqrt{2 \left(\frac{\delta D}{D}\right)^2 + \left(\frac{\delta H}{H}\right)^2 + \left(\frac{\delta WSD}{WSD}\right)^2} \quad (2-35)$$

(ข) การแพร่ค่าคลาดเคลื่อนมวลชีวภาพเหนือพื้นดิน ประมาณค่าโดยการนำค่าการแพร่ค่าคลาดเคลื่อนมาคำนวณร่วมกับค่าคลาดเคลื่อนจากการปรับแก้เรือนยอด (ร้อยละ 10) ดังสมการที่ 2-36

$$\delta AGB_{Total} = \sqrt{(\delta AGB_{stem})^2 + (\delta AGB_{canopy})^2} \quad (2-36)$$

4.2.7 การตรวจสอบความถูกต้องแบบจำลองมวลชีวภาพเหนือพื้นดินต้นแสมทะเล

โดยทั่วไป การตรวจสอบความถูกต้องจะนำผลการประมาณค่ามวลชีวภาพมาเปรียบเทียบกับค่ามวลชีวภาพที่วิเคราะห์จากต้นแสมทะเลในพื้นที่ศึกษาด้วยวิธีการแบบตัดต้นไม้ อย่างไรก็ตาม ไม่พบรายงาน หรืองานวิจัยที่เกี่ยวข้องกับการวัดค่ามวลชีวภาพในพื้นที่ศึกษามาก่อน งานวิจัยนี้ใช้แบบจำลองมวลชีวภาพเหนือพื้นดินอ้างอิงที่ได้จากการทบทวนเอกสารที่ได้จากการวิเคราะห์ตัวอย่างแบบตัดต้นไม้ และนำมาวิเคราะห์มวลชีวภาพในห้องทดลอง และเป็นสมการที่ได้รับ การยอมรับให้นำไปใช้ในการประมาณค่ามวลชีวภาพต้นแสมทะเล ได้แก่ แบบจำลองต้นไม้ป่าชายเลน ทั่วไปจาก Komiyama *et al.* (2008) แบบจำลองมวลชีวภาพต้นแสมทะเลจาก Comley and McGuinness (2005) Laongmanee (2011) และ Patil *et al.* (2014) จากนั้น เปรียบเทียบ ความถูกต้องโดยใช้ค่ารากที่สองของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (RMSE)

บทที่ 5

ผลการดำเนินงานวิจัย

งานวิจัยเรื่องนี้ แบ่งการรายงานผลการวิจัยออกเป็น 2 ส่วน ส่วนแรกเป็นผลการจำแนกพันธุ์ไม้ป่าชายเลนเขตร้อนด้วยข่ายประสาทคอนโวลูชัน แสดงในหัวข้อที่ 5.1 ส่วนที่สองเป็นผลการสร้างแบบจำลองมวลชีวภาพของต้นไม้ป่าชายเลนเขตร้อนด้วย TLS แสดงในหัวข้อที่ 5.2

5.1 ผลการจำแนกพันธุ์ไม้ป่าชายเลนเขตร้อนด้วยข่ายประสาทคอนโวลูชัน

ในงานวิจัยนี้ ได้รายงานผลการจำแนกพันธุ์ไม้ป่าชายเลนในพื้นที่แหลมตะลุมพุก อำเภอปากพนัง จังหวัดนครศรีธรรมราช ตามขั้นตอนการวิจัย โดยเริ่มจากผลที่ได้จากการฝึกสอนโครงข่าย CNN ซึ่งเป็นแบบจำลองของค่าน้ำหนักในชั้นทั้งหมดของโครงข่าย และตรวจสอบแบบจำลองโครงข่าย (Training and validation) วิธีการที่นำเสนอ (Proposed method) สำหรับสร้างแบบจำลองคือ CFCN ที่ปรับปรุงจาก FCN-8s (Long *et al.*, 2015) ใช้ข้อมูลภาพถ่ายจากดาวเทียม Quickbird ช่วงคลื่นตามมองเห็น (RGB) ผสมสีจริง (True-color composited) ที่มีขนาดรายละเอียดจุดภาพ 2.4 เมตร และข้อมูลอ้างอิงจากการลงสำรวจภาคสนามบริเวณพื้นที่ศึกษาในเดือนธันวาคม 2560 ร่วมกับข้อมูลที่ได้จากงานวิจัยของ Koedsin and Vaiphasa (2013) และ Watanakij and Vaiphasa (2016)

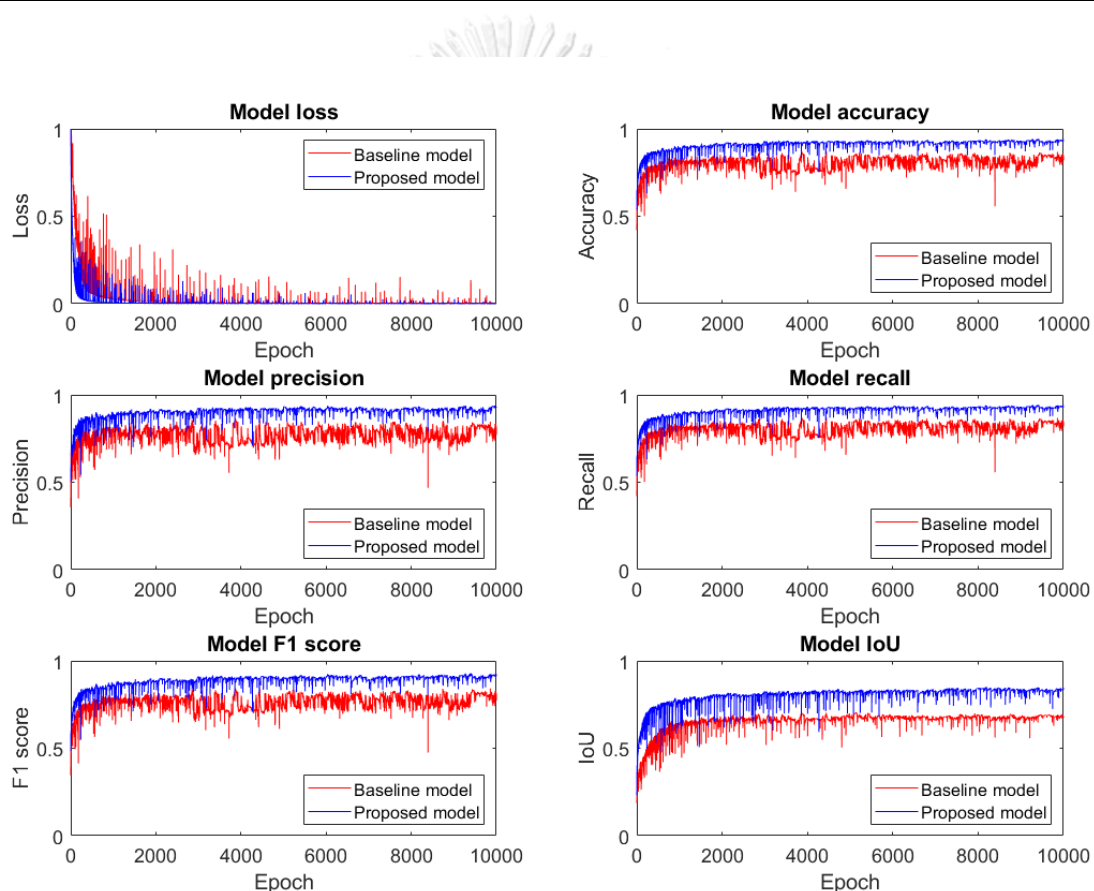
5.1.1 ผลการสอน CNN และการทดสอบความถูกต้องของวิธีการนำเสนอ

1) การทดสอบความถูกต้องของโครงข่ายนำเสนอ

สอนโครงข่ายทั้งสองโครงข่าย ได้แก่ CFCN (วิธีการนำเสนอ) และ FCN-8s (โครงข่ายต้นแบบ) การสอนโครงข่ายมีจำนวนรอบทั้งสิ้น 10,000 รอบ ค่าทดสอบที่ได้จากการสอนโครงข่ายจะให้ค่าความสูญเสีย (Loss) ค่าความถูกต้อง (Accuracy) ค่าความเที่ยง (Precision) ค่าความระลึก (Recall) ค่าเอฟวัน (F1 score) และค่า IoU เฉลี่ย (Mean IoU) แสดงค่าทดสอบการสอนที่ดีที่สุดในตารางที่ 5-1 และภาพการเปรียบเทียบผลลัพธ์จากทั้งสองแบบจำลองในภาพที่ 5-1 ดังนี้

ตารางที่ 5-1 ผลการทดสอบโครงข่ายต้นแบบ (FCN-8s) และวิธีการนำเสนอ (CFCN)

ค่าทดสอบ	โครงข่ายต้นแบบ (FCN-8s)	วิธีการนำเสนอ (CFCN)
Loss	0.0003	0.0000
Accuracy	0.8723	0.9425
Precision	0.8624	0.9378
Recall	0.8558	0.9374
F1 score	0.8494	0.9283
Mean IoU	0.7021	0.8506



ภาพที่ 5-1 ภาพแสดงผลการเปรียบเทียบค่าความสูญเสีย (Loss) ค่าความถูกต้อง (Accuracy) ค่าความเที่ยง (Precision) ค่าความระลึก (Recall) ค่าเอฟวัน (F1 score) และค่า IoU เฉลี่ย (Mean IoU) ของวิธีการนำเสนอ (CFCN, เส้นสีน้ำเงิน) และโครงข่ายต้นแบบ (FCN-8s, เส้นสีแดง)

จากตารางที่ 5-1 และภาพที่ 5-1 ผลการสอนวิธีการนำเสนอรอบที่ 9,412 ให้ผลลัพธ์การจำแนกที่ดีที่สุด โดยพิจารณาจากค่าความถูกต้องสูงสุด เมื่อเปรียบเทียบค่าทดสอบที่ดีที่สุดทุกค่า พบว่าผลการสอนโครงข่ายนำเสนอมีค่ามากกว่าผลการสอนโครงข่ายต้นแบบทุกค่า ผลลัพธ์ที่ได้แสดงให้เห็นว่าโครงข่ายที่ได้จากวิธีการนำเสนอ (CFCN) ให้ประสิทธิภาพในการใช้จำแนกพันธุ์ไม้ป่าชายเลนสูงกว่าโครงข่ายต้นแบบ (FCN-8s)

2) ผลการเปรียบเทียบความถูกต้องโครงข่ายของวิธีการนำเสนอกับโครงข่ายต้นแบบ

เนื่องจากผลการทดสอบสามารถหาความแปรปรวนของแต่ละกลุ่มข้อมูลได้ จึงเปรียบเทียบความแตกต่างด้วยค่าสถิติ Z แบบสองกลุ่มที่ระดับนัยสำคัญที่ 0.05 การทดสอบนี้ได้ตั้งสมมติฐาน H_0 : ประสิทธิภาพของวิธีการนำเสนอ และของโครงข่ายต้นแบบไม่แตกต่างกัน และ H_a : ประสิทธิภาพของวิธีการนำเสนอ และของโครงข่ายต้นแบบมีความแตกต่างกัน ดังแสดงในตารางที่ 5-2

ตารางที่ 5-2 การทดสอบความแตกต่างประสิทธิภาพของโครงข่ายด้วยสถิติ Z แบบสองกลุ่ม

ค่าทดสอบ	ค่าสถิติ Z	ค่าวิกฤต	ระดับนัยสำคัญ	P-value
Loss	-15.57			0.00***
Accuracy	88.68			0.00***
Precision	249.72			0.00***
Recall	226.53	-1.96 – 1.96	0.05	0.00***
F1 score	235.07			0.00***
Mean IoU	204.42			0.00***

จากตารางที่ 5-2 ได้ช่วงค่าวิกฤตสำหรับการทดสอบ -1.96 ถึง 1.96 ค่า Z ของค่าทดสอบที่คำนวณได้อยู่นอกช่วงค่าวิกฤต และ P-value เท่ากับ 0.00 ทำให้ต้องปฏิเสธ H_0 ผลการทดสอบค่าสถิติ Z พบว่า วิธีการนำเสนอ กับโครงข่ายต้นแบบให้ความถูกต้องของแบบจำลองที่แตกต่างกัน เป็นการยืนยันว่าวิธีการนำเสนอมีประสิทธิภาพในการใช้จำแนกพันธุ์ไม้ป่าชายเลนเขตร้อนสูงกว่าโครงข่ายต้นแบบ

5.1.2 ผลการจำแนกพันธุ์ไม้ป่าชายเลนเขตร้อน และการเปรียบเทียบผลการจำแนก

แบบจำลองที่ได้จากการสอนโครงข่ายใน 5.1.1 จะถูกใช้เป็นค่าน้ำหนักของโครงข่ายสำหรับการจำแนก นำภาพถ่ายจากดาวเทียมบริเวณพื้นที่ศึกษาเข้าสู่โครงข่ายด้วยวิธีการ Feed

forward จำนวน 1 รอบ เพื่อจำแนกพันธุ์ไม้ป่าชายเลนเขตร้อน ผลการจำแนกให้ความถูกต้องโดยรวมร้อยละ 90.36 โดยมีค่าความสอดคล้องการจำแนกที่คำนวณจากค่าดัชนีแคปทาที่ 0.80 แสดงในตารางที่ 5-3

ตารางที่ 5-3 Confusion matrix ของการจำแนกด้วยวิธีการนำเสนอ (CFCN)

	Field observation										PA	UA
	Ra	Rm	Aa	Am	Bp	Mx	Wa	Ur	Clsh	Total		
Ra	73	16	12	1	2	10	0	0	3	117	97.33	62.39
Rm	0	34	3	0	3	0	0	0	0	40	68.00	85.00
Aa	0	0	35	0	0	0	0	0	0	35	70.00	100.00
Am	0	0	0	49	12	0	0	0	0	61	98.00	80.33
Bp	1	0	0	0	36	0	0	0	0	37	67.93	97.30
Mx	1	0	0	0	0	26	0	12	0	39	70.27	66.67
Wa	0	0	0	0	0	1	49	1	0	51	100.00	96.08
Ur	0	0	0	0	0	0	0	38	0	38	74.51	100.00
Clsh	0	0	0	0	0	0	0	0	35	35	92.11	100.00
Total	75	50	50	50	53	37	49	51	38	453	OA = 90.36	


*Kappa index = 0.80

ตารางที่ 5-4 Confusion matrix ของการจำแนกด้วยวิธีความน่าจะเป็นสูงสุด (MLC)

	Field observation										PA	UA
	Ra	Rm	Aa	Am	Bp	Mx	Wa	Ur	Clsh	Total		
Ra	40	14	20	0	7	4	0	0	0	85	53.33	47.06
Rm	17	15	0	1	13	7	0	0	0	53	30.00	28.30
Aa	4	8	16	0	5	10	0	0	0	43	32.00	37.21
Am	4	1	0	47	6	3	0	0	0	61	94.00	77.05
Bp	5	11	7	0	21	3	0	0	0	47	39.62	44.68
Mx	5	1	3	1	1	8	0	2	0	21	21.62	38.10
Wa	0	0	0	0	0	1	47	2	0	50	95.92	94.00
Ur	0	0	0	0	0	0	0	43	1	44	84.31	97.73
Clsh	0	0	4	1	0	1	2	4	37	49	97.37	75.51
Total	75	50	50	50	53	37	49	51	38	453	OA = 66.02	

*Kappa index = 0.55

จากนั้น จำแนกพันธุ์ไม้ป่าชายเลนเขตร้อนด้วยวิธีความน่าจะเป็นสูงสุดเพื่อใช้ในการเปรียบเทียบผลการจำแนกที่ได้จากวิธีการนำเสนอ ผลการจำแนกให้ความถูกต้องโดยรวมร้อยละ 66.02 โดยมีค่าความสอดคล้องการจำแนกที่คำนวณจากค่าดัชนีแคปปาที่ 0.55 แสดงในตารางที่ 5-4 จากตารางที่ 5-3 และ 5-4 ความถูกต้องโดยรวมการจำแนกที่ได้จากวิธีการนำเสนอได้ถูกปรับปรุงให้มีค่าสูงกว่าวิธีความน่าจะเป็นสูงสุดจากร้อยละ 66.02 เป็นร้อยละ 90.36 เช่นเดียวกับค่าความถูกต้องผู้ผลิต และค่าความถูกต้องผู้ใช้ที่โดยรวมมีค่าเพิ่มขึ้นเมื่อใช้วิธีการนำเสนอในการจำแนก นอกจากนี้ ความสับสนระหว่างพันธุ์ไม้ที่โดดเด่นทั้ง 5 สายพันธุ์ ประกอบด้วย โกงกางใบเล็ก (Ra) โกงกางใบใหญ่ (Rm) แสมขาว (Aa) แสมทะเล (Am) และถั่วขาว (Bp) มีค่าลดลง (โปรดสังเกตบริเวณเน้นสีเทาอ่อนในตารางที่ 5-3 และ 5-4) อย่างไรก็ตาม ความถูกต้องของผู้ใช้กรณีพื้นที่เมือง (Ur) และเหมือง/เงา (Clsh) มีค่าความถูกต้องลดลง แผนที่ที่ได้จากการจำแนกด้วยวิธีการทั้งสองแสดงในภาพที่ 5-2 โดยข้อมูลแผนที่ได้นำพื้นที่ไม่ทราบค่าที่เป็นสีดำออกจากแผนที่เพื่อแสดงผลในส่วนที่เป็นพื้นที่จำแนกเท่านั้น



ภาพที่ 5-2 a) ผลการจำแนกพันธุ์ไม้ป่าชายเลนเขตร้อนด้วยวิธีการนำเสนอ (CFCN) b) ผลการจำแนกพันธุ์ไม้ป่าชายเลนเขตร้อนด้วยวิธีความน่าจะเป็นสูงสุด (MLC)

ทดสอบผลการจำแนกด้วยวิธีการนำเสนอ (ภาพที่ 5-2a) และวิธีความน่าจะเป็นสูงสุด (ภาพที่ 5-2b) ด้วยค่าสถิติ Z แบบสองกลุ่ม เพื่อเปรียบเทียบความแตกต่างของความถูกต้องในการจำแนกที่ระดับนัยสำคัญ 0.05 กำหนดให้สมมติฐาน H_0 : วิธีการนำเสนอ และวิธีความน่าจะเป็นสูงสุดมีความถูกต้องในการจำแนกไม่แตกต่างกัน และ H_a : วิธีการนำเสนอ และวิธีความน่าจะเป็นสูงสุดมีความถูกต้องในการจำแนกแตกต่างกัน ผลจากการทดสอบได้ค่า $Z = 7.65$ ซึ่งมีค่าอยู่นอกช่วงค่าวิกฤต (-1.96 ถึง 1.96) โดยมีค่า P-value = 0.00 ส่งผลให้ต้องปฏิเสธ H_0 ผลการทดสอบค่าสถิติ Z พบว่า วิธีการนำเสนอกับวิธีความน่าจะเป็นสูงสุดให้ค่าความถูกต้องในการจำแนกที่แตกต่างกัน เป็นการยืนยันว่า ผลการจำแนกจากวิธีนำเสนอให้ความถูกต้องในการจำแนกสูงกว่าวิธีความน่าจะเป็นสูงสุดอย่างมีนัยสำคัญสำหรับการจำแนกด้วยข้อมูลจากพื้นที่ศึกษา

5.2 ผลการสร้างแบบจำลองมวลชีวภาพของต้นไม้ป่าชายเลนเขตร้อนด้วยเครื่องสแกนเลเซอร์ภาคพื้นดิน

ในงานวิจัยนี้ ได้ใช้ตัวอย่างต้นไม้ป่าชายเลนเขตร้อนพันธุ์แสมทะเล (*Avicennia marina* (Forsk.) Vierh) จำนวน 30 ต้น (ใช้รหัส BP01 – BP30 แทนต้นไม้ตัวอย่าง) ที่ได้จากการสุ่มเป็นกลุ่มตัวอย่างเพื่อใช้ประมาณค่ามวลชีวภาพเหนือพื้นดิน โดยมีเส้นผ่านศูนย์กลางเพียงอกระหว่าง 11.90 ถึง 26.75 เซนติเมตร และมีความสูงอยู่ระหว่าง 6.13 ถึง 13.52 เมตร ผลลัพธ์ที่ได้จากการดำเนินงานมีดังนี้

5.2.1 ผลการประมาณค่ามวลชีวภาพเหนือพื้นดินต้นแสมทะเล

1) ผลการคำนวณปริมาตรของลำต้น

ค่าปริมาตรของต้นไม้ตัวอย่างรายต้นคำนวณจากค่าพารามิเตอร์ที่เก็บข้อมูลด้วยเครื่องสแกนเลเซอร์ภาคพื้นดิน โดยวัดส่วนลำต้นเริ่มจากบริเวณส่วนยอดของรากอากาศ ไปจนถึงกิ่งแรกของเรือนยอด (ภาพที่ 4-11) ผลลัพธ์ที่ได้ แสดงในตารางที่ 5-5 ปริมาตรของลำต้นมีค่าอยู่ระหว่าง 0.03 – 0.53 ลูกบาศก์เมตร โดยต้นไม้ตัวอย่างที่มีปริมาตรมากที่สุดคือ BP02 มีปริมาตรลำต้น 0.53 ลูกบาศก์เมตร ในขณะที่ต้นไม้ตัวอย่างที่มีปริมาตรน้อยที่สุดคือ BP08 มีปริมาตรลำต้น 0.03 ลูกบาศก์เมตร

2) ผลการประมาณค่ามวลชีวภาพลำต้น

นำปริมาตรของลำต้นที่ได้จากการคำนวณคูณกับความหนาแน่นจำเพาะเนื้อไม้ (600 กิโลกรัมต่อลูกบาศก์เมตร) แสดงในตารางที่ 5-5 ต้นไม้ตัวอย่างที่ BP02 มีมวลชีวภาพลำต้นมากที่สุด มีค่า 269.47 กิโลกรัม และ BP08 มีค่ามวลชีวภาพลำต้นน้อยที่สุด มีค่า 20.69 กิโลกรัม

3) ผลการประมาณค่ามวลชีวภาพเหนือพื้นดินรวม

นำค่ามวลชีวภาพลำต้นของต้นไม้ตัวอย่างมาปรับแก้ค่ามวลชีวภาพเรือนยอดด้วยการคูณกับค่าสัมประสิทธิ์การปรับแก้เรือนยอด (1.25) มวลชีวภาพเหนือพื้นดินของต้นไม้ตัวอย่างทั้งหมดแสดงในตารางที่ 5-5

ตารางที่ 5-5 ปริมาตรลำต้น และค่าประมาณมวลชีวภาพของต้นไม้ตัวอย่างจากจุดพิกัดสามมิติ

ต้นไม้ ตัวอย่าง	ความสูง (เมตร)	เส้นผ่าน ศูนย์กลางความ สูงเพียงอก (เซนติเมตร)	ปริมาตร (ลูกบาศก์ เมตร)	มวลชีวภาพ ลำต้น (กิโลกรัม)	มวลชีวภาพ เรือนยอด (กิโลกรัม)	มวลชีวภาพเหนือ พื้นดิน (กิโลกรัม)
BP01	10.70	18.81	0.14	86.95	21.74	108.69
BP02	10.50	26.57	0.53	269.47	67.37	336.84
BP03	11.41	20.24	0.21	128.53	32.13	160.66
BP04	11.55	14.03	0.06	34.16	8.54	42.70
BP05	13.52	20.62	0.29	130.87	32.72	163.59
BP06	7.73	14.80	0.09	55.90	13.97	69.87
BP07	11.31	19.86	0.20	117.69	29.42	147.11
BP08	6.13	11.90	0.03	20.69	5.17	25.86
BP09	7.14	13.30	0.07	34.47	8.62	43.09
BP10	6.88	12.42	0.06	28.60	7.15	35.75
BP11	10.74	24.67	0.45	214.67	53.67	268.33
BP12	10.66	25.31	0.48	223.72	55.93	279.64
BP13	10.33	15.97	0.13	60.05	15.01	75.06
BP14	10.10	24.11	0.41	198.79	49.70	248.49
BP15	10.55	20.96	0.28	134.01	33.50	167.51
BP16	10.98	19.19	0.22	95.12	23.78	118.89
BP17	11.23	26.50	0.54	260.35	65.09	325.44
BP18	11.04	23.78	0.40	191.95	47.99	239.93
BP19	10.65	23.91	0.40	192.18	48.05	240.23
BP20	9.91	16.40	0.14	65.03	16.26	81.29
BP21	10.84	20.04	0.26	124.00	31.00	154.99
BP22	10.33	26.75	0.44	263.50	65.87	329.37
BP23	10.32	16.55	0.14	66.70	16.67	83.37
BP24	11.84	17.69	0.18	84.55	21.14	105.69

ตารางที่ 5-5 ปริมาตรลำต้น และค่าประมาณมวลชีวภาพของต้นไม้ตัวอย่างจากจุดพิกัดสามมิติ (ต่อ)

ต้นไม้ ตัวอย่าง	ความสูง (เมตร)	เส้นผ่าน		ปริมาตร (ลูกบาศก์ เมตร)	มวลชีวภาพ ลำต้น (กิโลกรัม)	มวลชีวภาพ เรือนยอด (กิโลกรัม)	มวลชีวภาพเหนือ พื้นดิน (กิโลกรัม)
		ศูนย์กลางความ สูงเพียงอก (เซนติเมตร)	ศูนย์กลางความ สูงเพียงอก (เซนติเมตร)				
BP25	10.19		16.04	0.14	65.22	16.31	81.53
BP26	10.75		15.91	0.13	61.22	15.30	76.52
BP27	11.05		26.17	0.52	248.39	62.10	310.49
BP28	10.15		22.12	0.34	161.52	40.38	201.89
BP29	10.47		21.69	0.31	147.76	36.94	184.69
BP30	10.44		16.03	0.14	64.62	16.15	80.77

5.2.2 ผลการประมาณการแพร่ค่าคลาดเคลื่อน

ค่าคลาดเคลื่อนจากการวัด ประกอบด้วย ความสูง เส้นผ่านศูนย์กลาง และความหนาแน่นจำเพาะต้นไม้ มีค่าร้อยละ 0.63 0.80 และ 8.33 ตามลำดับ การแพร่ค่าคลาดเคลื่อนของมวลชีวภาพลำต้น มีค่าร้อยละ 8.44 เมื่อนำค่าคลาดเคลื่อนของการปรับแก้เรือนยอดแพร่รวมเข้าไปในการคำนวณ ส่งผลให้ค่าคลาดเคลื่อนรวมมีค่าร้อยละ 13.08

พิจารณาค่าคลาดเคลื่อนมวลชีวภาพแยกรายต้นแบ่งเป็นค่าคลาดเคลื่อนของมวลชีวภาพลำต้น มวลชีวภาพเรือนยอด และมวลชีวภาพเหนือพื้นดิน ผลลัพธ์แสดงในตารางที่ 5-6

ตารางที่ 5-6 มวลชีวภาพเหนือพื้นดินของต้นเสมหะทะเลแยกตามลำต้น เรือนยอด และรวมค่า

ต้นไม้ตัวอย่าง	มวลชีวภาพเหนือพื้นดินของต้นเสมหะทะเลแยกตามลำต้น เรือนยอด และรวมค่า		
	มวลชีวภาพลำต้น (กิโลกรัม)	มวลชีวภาพเรือนยอด (กิโลกรัม)	มวลชีวภาพเหนือพื้นดิน (กิโลกรัม)
BP01	86.95 ± 7.36	21.74 ± 2.17	108.69 ± 14.25
BP02	269.47 ± 23.04	67.37 ± 6.74	336.84 ± 44.33
BP03	128.53 ± 10.87	32.13 ± 3.21	160.66 ± 21.05
BP04	34.16 ± 2.89	8.54 ± 0.85	42.70 ± 5.59
BP05	130.87 ± 11.08	32.72 ± 3.27	163.59 ± 21.45
BP06	55.90 ± 4.70	13.97 ± 1.40	69.87 ± 9.13
BP07	117.69 ± 9.92	29.42 ± 2.94	147.11 ± 19.24
BP08	20.69 ± 1.75	5.17 ± 0.52	25.86 ± 3.39
BP09	34.47 ± 4.51	8.62 ± 1.13	43.09 ± 5.64
BP10	28.60 ± 3.74	7.15 ± 0.93	35.75 ± 4.67

ตารางที่ 5-6 มวลชีวภาพเหนือพื้นดินของต้นแสมทะเลแยกตามลำต้น เรือนยอด และรวมค่า (ต่อ)

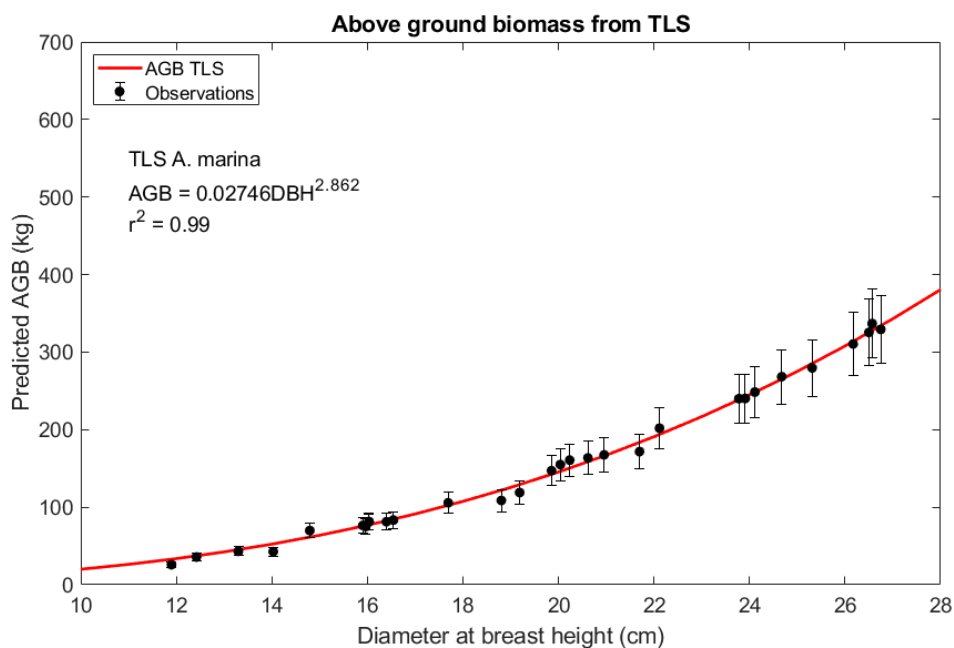
ต้นไม้ตัวอย่าง	มวลชีวภาพลำต้น (กิโลกรัม)	มวลชีวภาพเรือนยอด (กิโลกรัม)	มวลชีวภาพเหนือพื้นดิน (กิโลกรัม)
BP11	214.67 ± 28.05	53.67 ± 7.01	268.33 ± 35.06
BP12	223.72 ± 29.26	55.93 ± 7.31	279.64 ± 36.57
BP13	60.05 ± 7.86	15.01 ± 1.97	75.06 ± 9.83
BP14	198.79 ± 25.97	49.70 ± 6.49	248.49 ± 32.47
BP15	134.01 ± 17.54	33.50 ± 4.38	167.51 ± 21.92
BP16	95.12 ± 12.44	23.78 ± 3.11	118.89 ± 15.55
BP17	260.35 ± 34.07	65.09 ± 8.52	325.44 ± 42.59
BP18	191.95 ± 25.07	47.99 ± 6.27	239.93 ± 31.33
BP19	192.18 ± 25.12	48.05 ± 6.28	240.23 ± 31.40
BP20	65.03 ± 8.49	16.26 ± 2.12	81.29 ± 10.62
BP21	124.00 ± 16.22	31.00 ± 4.06	154.99 ± 20.28
BP22	263.50 ± 34.43	65.87 ± 8.61	329.37 ± 43.04
BP23	66.70 ± 8.74	16.67 ± 2.18	83.37 ± 10.92
BP24	84.55 ± 11.08	21.14 ± 2.77	105.69 ± 13.84
BP25	65.22 ± 8.53	16.31 ± 2.13	81.53 ± 10.67
BP26	61.22 ± 8.01	15.30 ± 2.00	76.52 ± 10.01
BP27	248.39 ± 32.48	62.10 ± 8.12	310.49 ± 40.59
BP28	161.52 ± 21.16	40.38 ± 5.29	201.89 ± 26.45
BP29	147.76 ± 17.96	36.94 ± 4.49	184.69 ± 22.45
BP30	64.62 ± 8.44	16.15 ± 2.11	80.77 ± 10.55

5.2.3 แบบจำลองมวลชีวภาพเหนือพื้นดินของต้นแสมทะเล

ผลจากการประมาณค่ามวลชีวภาพเหนือพื้นดิน และค่าเส้นผ่านศูนย์กลางความสูงเพียงอกที่ได้จากการวัดในภาคสนาม ถูกนำมาใช้สร้างแบบจำลองมวลชีวภาพเหนือพื้นดินของต้นแสมทะเล โดยใช้ความสัมพันธ์แบบยกกำลัง (Sileshi, 2014) ได้แบบจำลองดังสมการที่ 5-1 และได้แสดงความสัมพันธ์ระหว่างมวลชีวภาพเหนือพื้นดิน และเส้นผ่านศูนย์กลางความสูงเพียงอกของต้นแสมทะเล ในภาพที่ 5-3

$$AGB_{tls} = 0.0274DBH^{2.862} \quad (5-1)$$

เมื่อ AGB_{tls} คือ แบบจำลองมวลชีวภาพเหนือพื้นดินของต้นแสมทะเล
 DBH คือ เส้นผ่านศูนย์กลางความสูงเพียงอก



ภาพที่ 5-3 ความสัมพันธ์แบบยกกำลังระหว่างมวลชีวภาพเหนือพื้นดินและเส้นผ่านศูนย์กลางความสูงเพียงอกของต้นแสมทะเล

จากภาพที่ 5-3 แบบจำลองมวลชีวภาพเหนือพื้นดินของต้นแสมทะเลสามารถอธิบายความสัมพันธ์ระหว่างมวลชีวภาพเหนือพื้นดิน และเส้นผ่านความสูงเพียงอกได้ถึงร้อยละ 99 ($r^2 = 0.99$) และมี RMSE = 6.22 กิโลกรัม (ตารางที่ 5-7) จากผลลัพธ์สามารถกล่าวได้ว่า แบบจำลองนี้มีความเหมาะสมในการนำไปใช้ประมาณค่ามวลชีวภาพเหนือพื้นดินของต้นแสมทะเลด้วยเส้นผ่านศูนย์กลางความสูงเพียงอกในพื้นที่ศูนย์ศึกษาธรรมชาติกึ่งบก (บางปู) เฉลิมพระเกียรติ 72 พรรษา มหาราชินี

5.2.4 การตรวจสอบความถูกต้องมวลชีวภาพเหนือพื้นดินของต้นแสมทะเล

การประมาณค่ามวลชีวภาพเหนือพื้นดินในงานวิจัยนี้เป็นวิธีการการประมาณค่าแบบไม่ตัดต้นไม้ การเปรียบเทียบความถูกต้องจะเปรียบเทียบกับมวลชีวภาพเหนือพื้นดินที่ได้จากการตัดต้นไม้ในพื้นที่ไปวิเคราะห์ในห้องทดลอง อย่างไรก็ตาม จากการทบทวนเอกสารไม่พบค่ามวลชีวภาพในพื้นที่ศึกษา ดังนั้น การเปรียบเทียบความถูกต้องจะใช้แบบจำลองอ้างอิงที่ได้รับการตีพิมพ์และเป็น

ที่ยอมรับของ Komiyama *et al.* (2005) ในสมการที่ 3-1 Comley and McGuinness (2005) ในสมการที่ 3-2 Laongmanee (2011) ในสมการที่ 3-3 และ Patil *et al.* (2014) ในสมการที่ 3-4 โดยสมการเหล่านี้สร้างขึ้นจากวิธีการเก็บตัวอย่างแบบตัดต้นไม้ และนำมาวิเคราะห์มวลชีวภาพเหนือพื้นดินในห้องทดลอง

$$W_{top} = 0.251\rho D^{2.46} \quad (3-1)$$

$$W_{top} = 0.308DBH^{2.11} \quad (3-2)$$

$$W_{top} = 0.251\rho D^{2.24} \quad (3-3)$$

$$W_{top} = 0.3404DBH^{2.0273} \quad (3-4)$$

แทนค่าเส้นผ่านศูนย์กลางเพียงอกในแบบจำลองอ้างอิงทั้ง 4 สมการ จากนั้น นำมาเปรียบเทียบกับมวลชีวภาพเหนือพื้นดินที่ประมาณค่าจากเครื่องสแกนเลเซอร์ภาคพื้นดิน เพื่อหาค่า RMSE แสดงผลการประมาณค่ามวลชีวภาพเหนือพื้นดินในตารางที่ 5-7

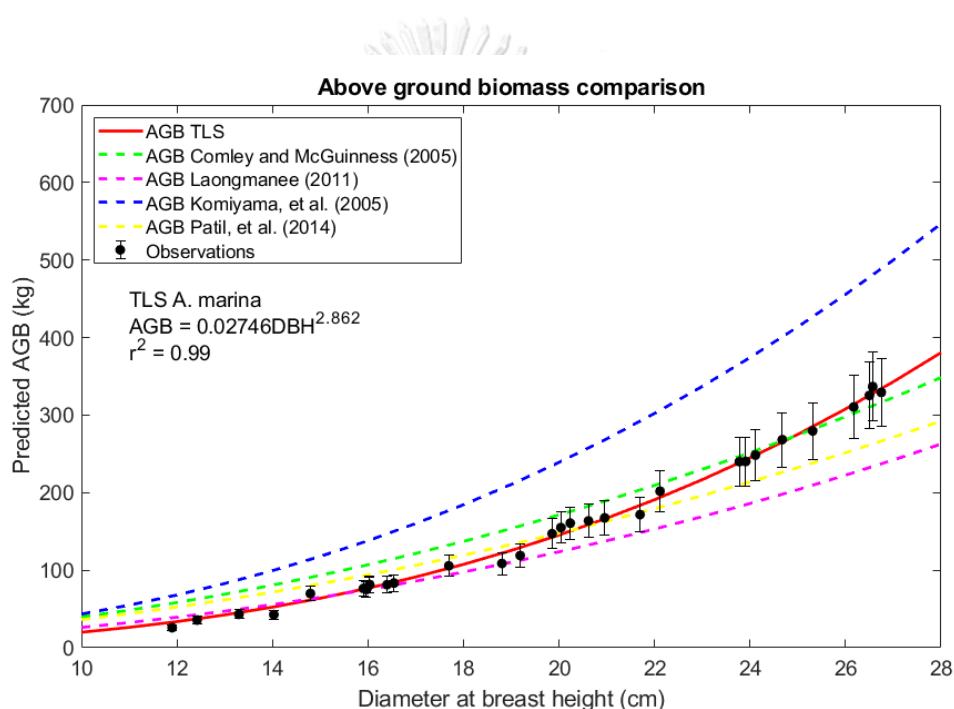
ตารางที่ 5-7 การเปรียบเทียบมวลชีวภาพเหนือพื้นดินที่ประมาณค่าจากเครื่องสแกนเลเซอร์ภาคพื้นดิน เปรียบเทียบกับค่ามวลชีวภาพที่ได้จากแบบจำลองอ้างอิง

ตัวอย่าง	เส้นผ่าน ศูนย์กลาง ความสูง เพียงอก (เซนติเมตร)	มวลชีวภาพเหนือพื้นดิน (กิโลกรัม)					
		แบบจำลอง TLS	Comley and McGuinness (2005)	Laongmanee (2011)	Patil <i>et al.</i> (2014)	Komiyama <i>et al.</i> (2005)	
							TLS
BP01	18.81	108.69	121.81	150.41	107.70	130.41	205.37
BP02	26.57	336.84	327.50	311.85	233.55	262.78	480.56
BP03	20.24	160.66	150.26	175.58	126.92	151.32	245.98
BP04	14.03	42.70	52.67	81.07	55.88	72.01	99.90
BP05	20.62	163.59	158.52	182.65	132.35	157.17	257.56
BP06	14.80	69.87	61.32	90.68	62.93	80.20	113.84
BP07	19.86	147.11	142.30	168.68	121.63	145.60	234.74
BP08	11.90	25.86	32.88	57.27	38.64	51.58	66.63
BP09	13.30	43.09	45.20	72.42	49.57	64.62	87.60
BP10	12.42	35.75	37.17	62.69	42.53	56.26	74.04

ตารางที่ 5-7 การเปรียบเทียบมวลชีวภาพเหนือพื้นดินที่ประมาณค่าจากเครื่องสแกนเลเซอร์
ภาคพื้นดิน เปรียบเทียบกับค่ามวลชีวภาพที่ได้จากแบบจำลองอ้างอิง (ต่อ)

ตัวอย่าง	เส้นผ่าน ศูนย์กลาง ความสูง เพียงอก (เซนติเมตร)	มวลชีวภาพเหนือพื้นดิน (กิโลกรัม)					
		TLS	แบบจำลอง ลอง TLS	Comley and McGuinness (2005)	Laongmanee (2011)	Patil <i>et al.</i> (2014)	Komiyama <i>et al.</i> (2005)
		BP11	24.67	268.33	265.03	266.79	197.90
BP12	25.31	279.64	285.08	281.54	209.53	238.19	426.55
BP13	15.97	75.06	76.28	106.51	74.66	93.61	137.35
BP14	24.11	248.49	248.11	254.13	187.94	215.87	378.55
BP15	20.96	167.51	166.07	189.02	137.26	162.43	268.07
BP16	19.19	118.89	129.04	156.94	112.67	135.86	215.81
BP17	26.50	325.44	325.11	310.17	232.22	261.42	477.54
BP18	23.78	239.93	238.40	246.76	182.16	209.85	365.78
BP19	23.91	240.23	242.21	249.66	184.43	212.22	370.79
BP20	16.40	81.29	82.33	112.69	79.26	98.82	146.67
BP21	20.04	154.99	146.13	172.01	124.19	148.36	240.16
BP22	26.75	329.37	333.93	316.35	237.13	266.42	488.65
BP23	16.55	83.37	84.45	114.81	80.85	100.61	149.90
BP24	17.69	105.69	102.31	132.25	93.95	115.25	176.77
BP25	16.04	81.53	77.23	107.49	75.39	94.44	138.81
BP26	15.91	76.52	75.42	105.63	74.00	92.87	136.02
BP27	26.17	310.49	313.66	302.08	225.79	254.86	463.04
BP28	22.12	201.89	193.75	211.78	154.87	181.18	306.06
BP29	21.69	184.69	183.46	203.42	148.39	174.31	292.02
BP30	16.03	80.77	77.12	107.38	75.30	94.34	138.64
RMSE (กิโลกรัม)			6.22	23.51	45.19	29.91	100.83
(ร้อยละ)			3.91	13.30	35.12	19.72	39.88

จากตารางที่ 5-7 มวลชีวภาพเหนือพื้นดินจากเครื่องสแกนเลเซอร์ภาคพื้นดิน เมื่อเปรียบเทียบกับแบบจำลองอ้างอิง พบว่า มีค่าใกล้เคียงกับแบบจำลองอ้างอิงของ Comley and McGuinness (2005) มากที่สุด มีค่า RMSE เท่ากับ 23.51 กิโลกรัม (ร้อยละ 13.30) ตามด้วยแบบจำลองของ Patil *et al.* (2014) ที่ให้ค่า RMSE ใกล้เคียงกัน โดยมีค่า 29.91 กิโลกรัม (ร้อยละ 19.72) เมื่อเปรียบเทียบกับแบบจำลองอ้างอิงของ Laongmanee (2011) พบว่า มีค่า RMSE เท่ากับ 45.19 กิโลกรัม (ร้อยละ 35.12) และเมื่อเปรียบเทียบกับแบบจำลองอ้างอิงของ Komiyama *et al.* (2005) พบว่า มีค่า RMSE เท่ากับ 100.83 กิโลกรัม (ร้อยละ 39.88) ได้แสดงผลการเปรียบเทียบแบบจำลองมวลชีวภาพเหนือพื้นดินในรูปแบบแผนภูมิดังภาพที่ 5-4



ภาพที่ 5-4 แบบจำลองความสัมพันธ์แบบยกกำลังระหว่างมวลชีวภาพเหนือพื้นดิน และเส้นผ่านศูนย์กลางความสูงเพียงอกของต้นแสมทะเลที่ประมาณค่าจากเครื่องสแกนเลเซอร์ภาคพื้นดิน โดยแสดงค่าด้วยเส้นทึบสีแดง ส่วนเส้นประสีอื่นเป็นค่ามวลชีวภาพเหนือพื้นดินที่ได้จากแบบจำลองอ้างอิงโดยมีจุดประสงค์เพื่อนำมาเปรียบเทียบความถูกต้อง

จากตารางที่ 5-7 และภาพที่ 5-4 เมื่อพิจารณาค่ามวลชีวภาพเหนือพื้นดินตามต้นไม้ตัวอย่าง พบว่า มวลชีวภาพเหนือพื้นดินจากเครื่องสแกนเลเซอร์ภาคพื้นดิน ที่เส้นผ่านศูนย์กลางเพียงอก มีค่าต่ำกว่า 15 เซนติเมตร มีค่าใกล้เคียงกับมวลชีวภาพเหนือพื้นดินที่ได้จากแบบจำลองอ้างอิงของ Laongmanee (2011) แสดงเป็นเส้นประสีชมพูในภาพที่ 5-4 มวลชีวภาพเหนือพื้นดินจาก

เครื่องสแกนเลเซอร์ภาคพื้นดิน ที่เส้นผ่านศูนย์กลางความสูงเพียงอกมีค่าประมาณ 15 - 21 เซนติเมตร มีค่าใกล้เคียงกับมวลชีวภาพเหนือพื้นดินที่ได้จากแบบจำลองอ้างอิงของ Patil *et al.* (2014) แสดงเป็นเส้นประสีเหลืองในภาพที่ 5-4 ส่วนมวลชีวภาพเหนือพื้นดินจากเครื่องสแกนเลเซอร์ภาคพื้นดิน ที่เส้นผ่านศูนย์กลางเพียงอก มีค่าสูงกว่า 21 เซนติเมตร ขึ้นไป มีค่าใกล้เคียงกับมวลชีวภาพเหนือพื้นดินที่ได้จากแบบจำลองอ้างอิงของ Comley and McGuinness (2005) แสดงเป็นเส้นประสีเขียวในภาพที่ 5-4



บทที่ 6

อภิปราย และสรุปผล

งานวิจัยเรื่องนี้ แบ่งการอภิปราย และสรุปผลการวิจัยออกเป็น 2 ส่วน ส่วนแรกเป็นการอภิปรายผล และสรุปผลการจำแนกพันธุ์ไม้ป่าชายเลนเขตร้อนด้วยข่ายประสาทคอนโวลูชัน แสดงในหัวข้อที่ 6.1 - 6.3 ตามลำดับ ส่วนที่สองเป็นอภิปรายผล และสรุปผลการสร้างแบบจำลองมวลชีวภาพเหนือพื้นดินของต้นไม้ป่าชายเลนเขตร้อนด้วยเครื่องสแกนเลเซอร์ภาคพื้นดิน แสดงในหัวข้อที่ 6.4 - 6.6 ตามลำดับ

6.1 อภิปรายผลการจำแนกพันธุ์ไม้ป่าชายเลนเขตร้อนด้วยข่ายประสาทคอนโวลูชัน

ผลการใช้วิธีการนำเสนอ (CFCN) จำแนกพันธุ์ไม้ป่าชายเลนเขตร้อนแสดงให้เห็นถึงความถูกต้องการจำแนกโดยรวมของสถาปัตยกรรมข่ายประสาทคอนโวลูชันที่มีสูงกว่าวิธีความน่าจะเป็นสูงสุดสำหรับการใช้จำแนกในพื้นที่ศึกษา โดยวิธีการนำเสนอมีความถูกต้องโดยรวมร้อยละ 90.36 และค่าโคเฮนส์ แคปอาร์ร้อยละ 0.80 ส่วนวิธีความน่าจะเป็นสูงสุดมีความถูกต้องโดยรวมร้อยละ 66.02 และค่าโคเฮนส์ แคปอาร์ร้อยละ 0.55 ตามลำดับ การเปรียบเทียบความถูกต้องการจำแนกของทั้งสองวิธีด้วยค่าสถิติ Z ช่วยยืนยันว่าวิธีการนำเสนอให้ค่าความถูกต้องสูงกว่าที่ระดับนัยสำคัญ 0.05 ตรงตามวัตถุประสงค์ของงานวิจัยที่ต้องการใช้ข่ายประสาทคอนโวลูชันจำแนกพันธุ์ไม้ป่าชายเลนเขตร้อนเพื่อปรับปรุงวิธีการจำแนกให้มีความถูกต้องมากขึ้น

6.1.1 การนำเสนอวิธีการ CFCN โดยลดพารามิเตอร์ของโครงข่ายต้นแบบ (FCN-8s)

ข่ายประสาทเชิงลึกได้รับความนิยมในการนำมาใช้วิเคราะห์ข้อมูลด้าน Computer vision เป็นจำนวนมาก และได้ถูกพัฒนาเป็นสถาปัตยกรรมโครงข่ายหลากหลายแบบ ซึ่งสถาปัตยกรรมที่ช่วยจำแนกข้อมูลภาพแบบ Semantic segmentation ได้ดีมีจำนวนมากในโครงข่ายที่ลึกมาก เช่น AlexNet Caffemodel (Krizhevsky *et al.*, 2012) หรือ Fully convolution network (Long *et al.*, 2015) ส่งผลให้ต้องใช้ทรัพยากรสำหรับประมวลผลสูง และใช้ระยะเวลาที่นานสำหรับการสอน (Han *et al.*, 2016) สถาปัตยกรรมที่มีประสิทธิภาพสูงส่วนใหญ่ถูกออกแบบมาเพื่อใช้สำหรับการแข่งขัน Large Scale Visual Recognition Challenge (ILSVRC) ข้อมูลที่ใช้เป็นข้อมูล ImageNet ซึ่งมีความซับซ้อนในการจำแนก เช่น การมีพีเจอร์ที่หลากหลาย หรือมีสีของพีเจอร์ที่แตกต่างกันจำนวนมากในภาพหนึ่งภาพ ทำให้ผู้แข่งขันต้องออกแบบสถาปัตยกรรมเพื่อให้สามารถจำแนกข้อมูลที่มีความซับซ้อนได้ เมื่อพิจารณาข้อมูลภาพถ่ายจากดาวเทียม เป็น

ข้อมูลภาพที่มีคุณลักษณะไม่ซับซ้อนเท่ากับข้อมูลภาพของ ImageNet Cloud Sources ที่ใช้สำหรับการแข่งขัน สถาปัตยกรรมที่มีโครงข่ายลึกมากเป็นสิ่งที่เกินความจำเป็นสำหรับการทำงานลักษณะนี้ (Zhang *et al.*, 2018) นอกจากนี้ การที่มีพารามิเตอร์จำนวนมากอาจทำให้การสอนโครงข่ายประสบปัญหา Overfitting ได้ (Krizhevsky *et al.*, 2012) ดังนั้น ในการจำแนกข้อมูลภาพรีโมทเซนซิง นิยมใช้โครงข่ายที่มีสถาปัตยกรรมที่ไม่ลึกมาก มีจำนวนชั้นในโครงข่ายประมาณ 5 – 8 ชั้น (Basaed *et al.*, 2016; Ghamisi *et al.*, 2016; Langkvist *et al.*, 2016) สามารถให้ค่าความถูกต้องของการจำแนกสูงกว่าร้อยละ 90 ขึ้นไป

การสอนชุดข้อมูลด้วยโครงข่ายต้นแบบ (FCN-8s) มีพารามิเตอร์ที่ใช้ในการคำนวณโครงข่ายทั้งสิ้น 134,353,658 พารามิเตอร์ (ตารางที่ 4-2) ซึ่งพารามิเตอร์ที่มีจำนวนมากเกินไปส่งผลให้กระบวนการแพร่กระจายย้อนกลับ (Back propagation) ต้องทำงานหนัก และใช้เวลานานกว่าที่จะปรับพารามิเตอร์ทุกค่าเสร็จสิ้นก่อนเริ่มกระบวนการป้อนไปข้างหน้า (Feed forward) ในรอบถัดไป วิธีการที่นำเสนอ (CFCN) ในงานวิจัยนี้ได้ใช้สถาปัตยกรรม FCN-8s เป็นต้นแบบ และได้ปรับปรุงโครงข่ายโดยการลดจำนวนพารามิเตอร์ของโครงข่ายลง (Han *et al.*, 2016) ทำให้สามารถดำเนินการสอนโครงข่ายภายใต้ทรัพยากรที่มีจำกัด (หน่วยความจำ GPU ขนาด 11 GB) จำนวนพารามิเตอร์หลังทำการลดจำนวนชั้นในโครงข่ายลงแล้วมีทั้งสิ้น 7,745,172 พารามิเตอร์ (ตารางที่ 4-3) ลดลงจากโครงข่ายต้นแบบ 17.35 เท่า ส่งผลต่อเวลาที่ใช้ในการสอนโครงข่ายจำนวน 10,000 รอบที่ลดลงจากเดิม 912 ชั่วโมง เหลือ 384 ชั่วโมง คิดเป็น 2.38 เท่า สามารถดำเนินการสอนภายใต้ทรัพยากรประมวผลที่มีอย่างจำกัด และการที่จำนวนพารามิเตอร์ลดน้อยลงทำให้โอกาสการเกิด Overfitting มีต่ำกว่าการใช้พารามิเตอร์จำนวนมาก (Krizhevsky *et al.*, 2012; Nogueira *et al.*, 2017) ส่งผลให้การเรียนรู้ของวิธีการนำเสนอมีประสิทธิภาพสูงกว่าโครงข่ายต้นแบบดังผลลัพธ์ในภาพที่ 5-1

โครงข่ายของวิธีการนำเสนอใช้ข้อมูลการสอน และปรับโครงข่ายที่ได้จากการสำรวจภายในพื้นที่ศึกษา จึงมีความเหมาะสมเฉพาะภายในพื้นที่ เช่นเดียวกับงานด้านรีโมทเซนซิงอื่น ๆ ที่ใช้เฉพาะข้อมูลตัวอย่างในพื้นที่ศึกษามาสอนโครงข่าย (Langkvist *et al.*, 2016; Maggiori *et al.*, 2017; Zhao and Du, 2016) การประยุกต์วิธีการนำเสนอกับพื้นที่อื่นจะใช้ในรูปแบบของโครงข่ายตั้งต้นเพื่อส่งผ่านการเรียนรู้ (Hu *et al.*, 2015a; Wang *et al.*, 2017b; Zhou *et al.*, 2016) ร่วมกับการเก็บข้อมูลในพื้นที่เพิ่มเติม วิธีการดังกล่าวช่วยให้ค่าการสูญเสียของการสอนลู่เข้าได้เร็วยิ่งขึ้น

6.1.2 การจำแนกข้อมูลภาพถ่ายจากดาวเทียมรายละเอียดสูงในระดับสายพันธุ์ด้วยข่ายประสาทคอนโวลูชัน

ลักษณะพีเจอร์เชิงพื้นที่ในภาพถ่ายจากดาวเทียมมีหลากหลายรูปแบบ ทำให้การจำแนกด้วยวิธีเชิงจุดภาพมีความคลาดเคลื่อน เนื่องจากไม่สามารถที่จะเรียนรู้ลักษณะรูปแบบเชิงพื้นที่ของพีเจอร์เหล่านั้นได้ สถาปัตยกรรม CNN ได้ถูกนำมาใช้เพื่อแก้ปัญหาความหลากหลายของรูปแบบเชิงพื้นที่ และช่วยสกัดพีเจอร์ระดับสูงจากภาพ ความสามารถของ CNN มีความโดดเด่นด้านการรู้จำเชิงพื้นที่ (Spatial recognition) เช่น เนื้อภาพ รูปทรงเรขาคณิต และความสัมพันธ์เชิงบริบท (Wang *et al.*, 2017a) ซึ่งเป็นลักษณะที่มีอยู่ในพีเจอร์ระดับสูง (High level feature) พีเจอร์ประเภทนี้จะมีลักษณะรูปแบบที่มีความโดดเด่นจากพื้นหลังของภาพซึ่ง CNN สามารถแยกแยะได้อย่างมีประสิทธิภาพ เช่น หลังคาบ้าน ทางน้ำ หรือถนน ที่มนุษย์สามารถมองเห็นได้ด้วยตา พีเจอร์ระดับสูงมักจะวางตัวอยู่เหนือพีเจอร์ระดับต่ำ (Low level feature) ที่มีลักษณะดังเช่น พื้นที่แคบระหว่างอาคาร และถนน ลักษณะของทางน้ำที่แคบ หรือพีเจอร์ที่มีลักษณะเป็นจุด โดยพีเจอร์ระดับต่ำถูกจำแนกได้ดีด้วยวิธีการจำแนกแบบจุดภาพ (Li *et al.*, 2015a) นอกจากนี้ CNN ยังสามารถตรวจหารูปแบบเชิงพื้นที่ (Spatial pattern) ที่ซ่อนอยู่ในข้อมูลภาพถ่ายจากดาวเทียม (Zhang *et al.*, 2019a)

การจำแนกด้วย CNN พบปัญหาความไม่แน่นอนด้านขอบเขตของพีเจอร์ (Boundary uncertainty) ถึงแม้ว่า CNN จะมีการเรียนรู้พีเจอร์ระดับต่ำในช่วงขั้นแรกของสถาปัตยกรรม และเรียนรู้พีเจอร์ระดับสูงในขั้นท้าย (Nogueira *et al.*, 2017) แต่ CNN มักจำแนกพีเจอร์ระดับต่ำรวมไปอยู่กับพีเจอร์ระดับสูงที่ตรวจพบได้ชัดเจนกว่า เช่น พวกช่องว่างแคบ ๆ ระหว่างพีเจอร์ระดับสูง (Li *et al.*, 2015a) เป็นปัญหาเดียวกันกับที่พบในงานวิจัยนี้ CNN ได้จำแนกเส้นทางน้ำ หรือคลองในบางบริเวณของพื้นที่ศึกษารวมเป็นพีเจอร์ที่เป็นตันไม้ที่เห็นได้ชัดเจนกว่า (เรือนยอดของต้นไม้ทั้งสองฝั่งของเส้นทางน้ำมีขนาดใหญ่ แผ่ขยายปกคลุม) เป็นผลมาจากการลดขนาดของข้อมูลภาพในขั้นคอนโวลูชัน และพูลลิง อย่างไรก็ตาม การจำแนกพีเจอร์รูปแบบนี้ส่งผลดีต่อพื้นที่ศึกษาที่พันธุ์ไม้ป่าชายเลนเขตร้อนเจริญเติบโตปะปนกันทำให้เกิดความสับสนเชิงคลื่น (Spectral mixing) ซึ่งเป็นปัญหาที่พบในการจำแนกเชิงจุดภาพ (Hu *et al.*, 2015a; Hu *et al.*, 2015b) พันธุ์ไม้ป่าชายเลนเขตร้อนในพื้นที่ศึกษามีลักษณะการเจริญเติบโตอยู่รวมกันเป็นกลุ่มเนื่องจากพื้นที่ส่วนใหญ่เป็นป่าที่ได้รับการปลูกมานานหลายสิบปี เช่น พื้นที่ปลูกต้นโกงกางใบเล็กจะมีแต่ต้นโกงกางใบเล็กขึ้นอยู่ ลำต้นสูงใหญ่คลุมพื้นที่ และมีพันธุ์ไม้อื่นที่ลอยมาเจริญเติบโตในพื้นที่ เช่น ต้นโกงกางใบใหญ่ และต้นแสมขาว แต่ก็ไม่สามารถเจริญเติบโตได้ทันต้นโกงกางใบเล็กซึ่งเป็นเจ้าของพื้นที่ จะมีเพียงตามแนวคลองเท่านั้น ที่ต้นโกงกางใบใหญ่ และต้นแสมขาวมีโอกาสเจริญเติบโตสูงใหญ่ แต่ก็มีเพียงจำนวนน้อย ลักษณะการเจริญเติบโตของต้นโกงกางใบใหญ่ และต้นแสมขาวเช่นนี้ เป็นลักษณะของพีเจอร์ระดับต่ำ CNN จะ

จำแนกพีเจอร์เหล่านี้รวมไปเป็นต้นโงกวางใบเล็ก ซึ่งเป็นพีเจอร์ระดับสูง หลักการจำแนกเช่นนี้สอดคล้องกับวิธีการเก็บข้อมูลภาคสนามที่เลือกพันธุ์ไม้ที่โดดเด่น (มีจำนวนมากที่สุดในแปลงตัวอย่าง) เป็นพันธุ์ไม้ของแปลงตัวอย่างดังกล่าว (Koedsin and Vaiphasa, 2013; Watanakij and Vaiphasa, 2016)

จากปัญหาที่พบแสดงให้เห็นว่า CNN ยังมีข้อด้อยในเรื่องของการแบ่งขอบเขตเชิงพื้นที่ (Spatial partition) เมื่อใช้ทำงานด้านรีโมทเซนซิง Zhang *et al.* (2019a) ได้เสนอวิธีการแก้ปัญหาโดยนำวิธี Pixel-based multi-layer perceptron (MLP) มาบูรณาการร่วมกับ CNN เพื่อแก้ปัญหาความราบเรียบที่มีมากเกินไป (Over-smoothness) จากการจำแนกด้วย CNN เพียงวิธีการเดียว ทำให้ตรวจพบพีเจอร์ระดับต่ำได้อย่างมีประสิทธิภาพ และช่วยปรับปรุงให้ผลการจำแนกให้มีความถูกต้องมากยิ่งขึ้น วิธีการดังกล่าว เป็นวิธีที่น่าสนใจสำหรับนำมาใช้ปรับปรุง และแก้ไขข้อจำกัดที่เกิดจาก CNN

6.1.3 ความถูกต้องจากการจำแนก CFCN และการจำแนกแบบความน่าจะเป็นสูงสุด

การตรวจสอบผลความถูกต้องจากการจำแนกโดยรวมแสดงให้เห็นถึงประสิทธิภาพการจำแนกคลาสพันธุ์ไม้ป่าชายเลนเขตร้อนของวิธีการนำเสนอ (CFCN) มีสูงกว่าวิธีการจำแนกแบบความน่าจะเป็นสูงสุดอย่างมีนัยสำคัญ เมื่อเปรียบเทียบวิธีการจำแนกทั้งสอง การจำแนกแบบความน่าจะเป็นสูงสุดเป็นวิธีการจำแนกข้อมูลรายจุดภาพ (Pixel based classification) ซึ่งเป็นวิธีจำแนกที่ได้รับการยอมรับ และให้เป็นวิธีการสำหรับอ้างอิง (Benchmark) ให้แก่การจำแนกแบบอื่น ๆ ที่ได้รับการพัฒนา ลักษณะของข้อมูลที่น่ามาใช้กับการจำแนกแบบความน่าจะเป็นสูงสุดมีลักษณะการกระจายแบบปกติ (Normal distribution) อย่างไรก็ตาม ยังมีข้อจำกัดในการจำแนกข้อมูลที่มีค่าการสะท้อนแสงในแต่ละจุดภาพที่ใกล้เคียงกันมาก เช่น ข้อมูลการสะท้อนของใบของต้นโงกวางใบเล็ก และโงกวางใบใหญ่ที่มีลักษณะโครงสร้างของใบที่แตกต่างกัน แต่กลับให้ค่าการสะท้อนที่ใกล้เคียงกันมาก ส่งผลให้เกิดความสับสนในผลการจำแนก (Koedsin and Vaiphasa, 2013)

งานวิจัยนี้ได้เสนอวิธีการจำแนก CFCN ซึ่งเป็นสถาปัตยกรรม CNN แบบหนึ่งพัฒนาจาก FCN-8s (Long *et al.*, 2015) ที่นิยมใช้งานด้านการจำแนกเชิงความหมาย (Semantic segmentation) มีลักษณะคล้ายกับวิธีการจำแนกเชิงวัตถุ (Object based classification) ที่ใช้จำแนกกับงานด้าน Remote sensing ในงานวิจัยด้านการจำแนกพันธุ์ไม้ป่าชายเลนของ Watanakij and Vaiphasa (2016) ได้นำวิธีการจำแนกเชิงวัตถุร่วมกับวิธีการจำแนกแบบความน่าจะเป็นสูงสุดแยกแยะพันธุ์ไม้โงกวางใบเล็ก และโงกวางใบใหญ่ออกจากกัน และประสบผลสำเร็จเป็นอย่างดี เช่นเดียวกับงานวิจัยชิ้นนี้ที่ต้องการเห็นความแตกต่างของผลลัพธ์ที่ได้จาก CNN เมื่อเปรียบเทียบกับ MLC ซึ่งเป็นผลลัพธ์อ้างอิง เมื่อพิจารณาจากความถูกต้องรวมของการจำแนกแสดงให้เห็นว่า CNN

เป็นการจำแนกแบบไม่มีพารามิเตอร์ (Non-parametric classification) ข้อมูลที่ใช้ในการจำแนกไม่จำเป็นต้องมีลักษณะการกระจายแบบปกติ ส่งผลให้ผลการจำแนกที่ได้มีความถูกต้องโดยรวมสูงกว่า MLC (สำหรับการจำแนกในพื้นที่ศึกษาเท่านั้น)

นอกจากผลการจำแนกรวมในงานของ Watanakij and Vaiphasa (2016) ที่มีค่าสูงขึ้นแล้ว การจำแนกเชิงวัตถุยังช่วยปรับปรุงความถูกต้องผู้ผลิต (Producer's accuracy) ได้สูงขึ้น เมื่อเปรียบเทียบกับผลความถูกต้องผู้ผลิตจากงานของ Koedsin and Vaiphasa (2013) เป็นผลมาจากความสามารถด้านการวิเคราะห์เนื้อหาของวิธีที่นำมาใช้สามารถแยกแยะต้นโกงกางใบใหญ่ออกจากต้นโกงกางใบเล็กได้ การจำแนกด้วย CNN ใช้การพิจารณาเนื้อหาของภาพเพื่อการจำแนก ซึ่งเป็นวิธีการเดียวกับวิธีการจำแนกเชิงวัตถุ มากไปกว่านั้น CNN ได้ใช้การพิจารณาลักษณะเรขาคณิต และความสัมพันธ์เชิงบริบทของพิกเซลในการจำแนก จึงเป็นวิธีการที่น่าจะสามารถจำแนกพันธุ์ไม้ที่มีค่าการสะท้อนของจุดภาพที่มีค่าใกล้เคียงกัน แต่มีลักษณะโครงสร้างของใบที่แตกต่างกันให้แยกออกจากกันได้

อย่างไรก็ตาม เมื่อพิจารณาค่าความถูกต้องผู้ผลิต (PA) และค่าความถูกต้องผู้ใช้ (UA) ของการจำแนกด้วย CNN ในตารางที่ 5-3 พบว่า ในคลาสของต้นโกงกางใบเล็ก (Ra) มีค่า PA สูงถึงร้อยละ 97.33 ในขณะที่ UA มีค่าเพียงร้อยละ 62.39 ที่เป็นเช่นนี้เนื่องจาก CNN ได้จำแนกคลาอื่น เช่น ต้นโกงกางใบใหญ่ (Rm) และต้นแสมขาว (Aa) ที่ขึ้นอยู่บริเวณเดียวกันรวมไปเป็นต้นโกงกางใบเล็ก (Congalton and Green, 2009) แสดงในภาพที่ 6-1




ภาพที่ 6-1 พื้นที่ต้นโกงกางใบเล็ก (พื้นที่สีเขียว) จุดสีแดง และจุดสีเหลือง เป็นจุดแสดงต้นโกงกางใบใหญ่ และต้นแสมขาวที่ขึ้นแทรกอยู่ในพื้นที่

จากภาพที่ 6-1 พื้นที่ตัวอย่างในภาพเป็นบริเวณที่ได้รับการส่งเสริมให้ปลูกต้นโกงกางใบเล็กเพื่อการอนุรักษ์ จึงมีต้นโกงกางใบเล็กขึ้นอยู่อย่างหนาแน่น ต้นไม้พันธุ์อื่น เช่น ต้นโกงกางใบใหญ่ และต้นแสมขาว (จุดสีแดง และจุดสีเหลืองในภาพที่ 6-1 ได้จากการสำรวจภาคสนาม) เป็นต้นไม้ที่เมล็ดพันธุ์ลอยตามน้ำจากที่อื่นมาเจริญเติบโตในพื้นที่เป็นกลุ่มเล็ก หรือเป็นต้นแทรกอยู่ตามต้นโกงกางใบเล็ก CNN จะมองต้นโกงกางใบใหญ่ และต้นแสมทะเลเป็นพิกเซลระดับต่ำ เมื่อผ่าน

กระบวนการคอนโวลูชัน CNN จะรวมพีเจอร์เหล่านี้ไปอยู่ในคลาสของต้นไม้กิ่งก้านใบเล็กที่ CNN มองว่าเป็นพีเจอร์ระดับสูง (Giri *et al.*, 2014) ส่งผลให้เกิดความราบเรียบมากเกินไป และการแบ่งขอบเขตเชิงพื้นที่ (Zhang *et al.*, 2019a) ในผลการจำแนก ค่า PA ของต้นไม้กิ่งก้านใบใหญ่ และต้นแสมทะเล (ตารางที่ 5-3) มีค่าต่ำ (ร้อยละ 68.00 และร้อยละ 70.00 ตามลำดับ)

ปัญหาความราบเรียบมากเกินไปยังพบในการจำแนกคลาสต้นแสมทะเล (Am) กับต้นถั่วขาว (Bp) ดังแสดงในภาพที่ 6-2 และบริเวณรอยต่อระหว่างคลาสของเมือง กับคลาสของต้นไม้ป่าชายเลน ดังแสดงในภาพที่ 6-3



ภาพที่ 6-2 ตัวอย่างพื้นที่ต้นแสมทะเล (Am) และต้นถั่วขาว (BP) แทนด้วยจุดสีฟ้า และสีน้ำเงินซึ่งเป็นจุดที่เข้าไปสำรวจภาคสนามเก็บข้อมูลในพื้นที่ศึกษา



ภาพที่ 6-3 ตัวอย่างพื้นที่รอยต่อระหว่างเมืองกับต้นไม้ป่าชายเลน จุดสีชมพูแสดงถึงพื้นที่ต้นไม้พันธุ์ผสม (Mx) จุดสีเทาแสดงถึงพื้นที่เมือง (Ur)

จากภาพที่ 6-2 ต้นแสมทะเล และต้นถั่วขาวเป็นต้นไม้ที่ขึ้นอยู่บริเวณที่ดอน หรือใกล้ฝั่ง โดยต้นถั่วขาวมักจะพบอยู่บริเวณริมคลองที่มีอยู่ระหว่างพื้นที่ของต้นแสมทะเล จากลักษณะที่พบ

เช่นนี้ส่งผลให้กระบวนการคอนโวลูชันจำแนกคลาสต้นแก้วขาวคลาดเคลื่อนไปเป็นต้นแสมทะเล ส่งผลให้ค่า PA ของต้นแก้วขาวมีค่าต่ำเพียงร้อยละ 67.93 (ตารางที่ 5-3)

ในส่วนของพื้นที่รอยต่อ (Transition zone) ที่คั่นระหว่างคลาสเมืองกับคลาสต้นไม้ป่าชายเลนเขตร้อนที่แสดงในภาพที่ 6-3 ค่า พื้นที่รอยต่อจัดอยู่ในคลาสต้นไม้พันธุ์ผสม เนื่องจากมีต้นหมายในพื้นที่หลากหลายสายพันธุ์ ไม่มีสายพันธุ์ใดที่มีความโดดเด่น เมื่อพิจารณา PA และ UA ของคลาสต้นไม้พันธุ์ผสมพบว่ามีค่าต่ำทั้งคู่ที่ร้อยละ 70.27 และ 66.67 ตามลำดับ เป็นผลมาจากความเป็นพื้นที่รอยต่อที่ระหว่างสองคลาสที่ทำให้ฝั่งหนึ่งของคลาสถูกจำแนกผสมรวมไปกับพีเจอร์ที่เด่นกว่า (ในภาพที่ 6-3 พีเจอร์ที่เด่นกว่าคือคลาสต้นโกงกางใบเล็กแทนด้วยพื้นที่สีเขียว) และถูกคลาสที่มีพีเจอร์ระดับต่ำกว่าจำแนกมาผสมรวม (จากภาพที่ 6-3 พีเจอร์ระดับต่ำกว่าคือคลาสเมืองแทนด้วยสีเทา) ซึ่งเป็นผลมาจากการคอนโวลูชันที่ก่อให้เกิดความคลาดเคลื่อนของผลการจำแนกเช่นกัน

อย่างไรก็ตาม งานวิจัยนี้ต้องการทดสอบประสิทธิภาพการจำแนกของ CNN จึงไม่ได้กันคลาสเมือง และเขม/เงา ออกจากกระบวนการจำแนก เช่น งานวิจัยของ Koedsin and Vaiphasa (2013) และ Watanakij and Vaiphasa (2016) ที่กันเฉพาะพื้นที่พันธุ์ไม้ป่าชายเลนมาวิเคราะห์จำแนก ผลการตรวจสอบความถูกต้องไม่ได้รวมคลาสอื่นที่นอกเหนือจากพันธุ์ไม้ป่าชายเลน ความถูกต้องโดยรวม ความถูกต้องผู้ผลิต และความถูกต้องผู้ใช้ที่ได้จากการจำแนกจึงมีค่าสูงกว่างานวิจัยนี้

6.2 สรุปผลการจำแนกพันธุ์ไม้ป่าชายเลนเขตร้อนด้วยข่ายประสาทคอนโวลูชัน

ข่ายประสาทคอนโวลูชัน เป็นอัลกอริธึมที่มีความสามารถด้านการรู้จำรูปแบบของพีเจอร์ ที่จำลองจากการมองเห็นของมนุษย์ การใช้ข่ายประสาทคอนโวลูชันในการจำแนกพันธุ์ไม้ป่าชายเลนเขตร้อนเป็นการช่วยปรับปรุงวิธีการจำแนกทางรีโมทเซนซิงให้มีประสิทธิภาพในการทำงานมากยิ่งขึ้น งานวิจัยนี้ได้ใช้ Compressed fully convolution network (CFCN) ซึ่งเป็นวิธีการนำเสนอที่ปรับปรุงจากสถาปัตยกรรม FCN-8s ให้มีจำนวนชั้นในโครงข่ายลดลงจนมีความเหมาะสมกับทรัพยากรประมวลผลสำหรับงานวิจัยที่จำกัด การปรับลดโครงข่ายของวิธีการนำเสนอนอกจากจะไม่ทำให้ประสิทธิภาพของการจำแนกลดลงแล้ว ยังป้องกันการเกิดปัญหา Overfitting ในกระบวนการจำแนก และลดเวลาในการสอนโครงข่ายลง ช่วยให้การดำเนินงานมีความรวดเร็วขึ้น และมีความเหมาะสมในการนำไปใช้จำแนกพันธุ์ไม้ป่าชายเลนในพื้นที่ศึกษา ผลจากการจำแนกพบว่า ข่ายประสาทคอนโวลูชันมีประสิทธิภาพในการจำแนกพันธุ์ไม้ป่าชายเลนเขตร้อน สามารถช่วยแก้ปัญหาการผสมรวมของช่วงคลื่นที่เกิดจากการจำแนกแบบจุดภาพ ผลการตรวจสอบความถูกต้องการจำแนกแสดงให้เห็นว่า วิธีการจำแนกด้วยข่ายประสาทคอนโวลูชันให้ความถูกต้องโดยรวมการจำแนกสูงกว่าวิธีการจำแนกแบบความน่าจะเป็นสูงสุดอย่างมีนัยสำคัญ เมื่อจำแนกด้วยข้อมูลที่ได้จากพื้นที่ศึกษา

อย่างไรก็ตาม ในกระบวนการทำงาน ยังต้องปรับปรุงโครงข่ายให้มีความสามารถด้านการแบ่งขอบเขตเชิงพื้นที่เพิ่มขึ้น เพื่อแก้ปัญหาความไม่แน่นอนด้านขอบเขตของพีเจอร์ที่จำแนก ในส่วนของการนำวิธีการนำเสนอไปใช้จำแนกพันธุ์ไม้ป่าชายเลนในพื้นที่อื่น สามารถนำค่าน้ำหนักของโครงข่ายไปใช้เป็นค่าน้ำหนักตั้งต้นเพื่อส่งผ่านการเรียนรู้ ร่วมกับการเก็บข้อมูลในพื้นที่เพิ่มเติมเพื่อช่วยลดเวลาการสอนโครงข่าย และช่วยให้กระบวนการปรับแต่งโครงข่ายมีประสิทธิภาพมากยิ่งขึ้น

6.3 ข้อเสนอแนะในการจำแนกพันธุ์ไม้ป่าชายเลนเขตร้อนด้วยข่ายประสาทคอนโวลูชัน

6.3.1 ควรค้นพื้นที่อื่นที่ไม่ใช่พันธุ์ไม้ป่าชายเลนออกจากพื้นที่ศึกษา และจำแนกเฉพาะพันธุ์ไม้ป่าชายเลน

6.3.2 ควรนำข้อมูลภาพถ่ายจากดาวเทียมที่มีรายละเอียดสูงกว่าในงานวิจัยนี้ หรือภาพถ่ายจากดาวเทียมที่ผ่านการ Pan-sharpening ที่สามารถมองเห็นพีเจอร์ของแต่ละคลาสได้ชัดเจนกว่ามาใช้สำหรับการจำแนก

6.3.3 ควรทดลองนำสถาปัตยกรรมข่ายประสาทคอนโวลูชันประเภทอื่น หรือปรับปรุงสถาปัตยกรรมให้มีประสิทธิภาพเพิ่มขึ้น มาทดสอบจำแนกพันธุ์ไม้ป่าชายเลน

6.3.4 ควรทดลองนำวิธีการนำเสนอไปใช้จำแนกพันธุ์ไม้ป่าชายเลนในพื้นที่อื่น โดยใช้ค่าน้ำหนักของโครงข่ายเป็นค่าตั้งต้นสำหรับการส่งผ่านการเรียนรู้ และต้องทำการเก็บข้อมูลในพื้นที่ดังกล่าวเพื่อนำมาสอนโครงข่ายเพิ่มเติม

6.4 อภิปรายผลการสร้างแบบจำลองมวลชีวภาพเหนือพื้นดินของต้นไม้ป่าชายเลนเขตร้อนด้วยเครื่องสแกนเลเซอร์ภาคพื้นดิน

ผลที่ได้จากการวิจัย แสดงให้เห็นถึงความสามารถของเครื่องสแกนเลเซอร์ภาคพื้นดิน ในด้านการเก็บข้อมูลจุดพิกัดสามมิติของโครงสร้างต้นไม้ ข้อมูลที่ได้สามารถนำมาสร้างแบบจำลองมวลชีวภาพเหนือพื้นดินของต้นแสมทะเล โดยมีค่า R-squared 0.99 และค่า RMSE = 7.86 กิโลกรัม (ร้อยละ 6.70) แสดงถึงแบบจำลองมวลชีวภาพเหนือพื้นดินที่สร้างจากข้อมูลจุดพิกัดสามมิติสามารถอธิบายค่าสังเกต และใช้ทำนายค่ามวลชีวภาพเหนือพื้นดินได้อย่างมีประสิทธิภาพ ตรงตามวัตถุประสงค์ของงานวิจัย

6.4.1 แบบจำลองวิธีการเก็บข้อมูลต้นแสมทะเล และการคำนวณปริมาตรลำต้น

แบบจำลองวิธีการเก็บข้อมูลที่ใช้มีอยู่สองวิธี ได้แก่ แบบจำลอง Single tree และแบบจำลอง Individual tree (Liang *et al.*, 2016) วิธีการแรกจะให้ข้อมูลจุดพิกัดสามมิติที่มีจำนวนมาก และความหนาแน่นสูง โดยเก็บข้อมูลต้นไม้ครั้งละหนึ่งต้น มีทิศทางการสแกนอย่างน้อย 3

ทิศทาง ซึ่งวิธีนี้เป็นวิธีที่เหมาะสมสำหรับการศึกษาที่ต้องการรายละเอียดของส่วนประกอบของต้นไม้ อย่างไรก็ตาม วิธีการดังกล่าวเป็นวิธีที่ใช้เวลานานในการเก็บข้อมูลต้นไม้แต่ละต้น ส่วนวิธีการหลังเป็นวิธีที่ใช้สำหรับการเก็บข้อมูลต้นไม้ครั้งละมาก ๆ ในพื้นที่เก็บตัวอย่างข้อมูล ในแต่ละการเก็บข้อมูลจะต้องตั้งสถานี TLS อย่างน้อย 5 สถานี วิธีนี้ช่วยลดระยะเวลาในการเก็บข้อมูลต้นไม้ครั้งละจำนวนมาก โดยปัญหาที่เกิดขึ้นจากวิธีการนี้จะเป็นการที่ต้นไม้ถูกบดบัง (Occlusion) ซึ่งเป็นปัญหาที่พบในการทำวิจัยครั้งนี้ด้วยเช่นกัน การแก้ปัญหาดังกล่าวจะเพิ่มจุดตั้งกล้องโดยพิจารณาจากหน่วยงานเพื่อเพิ่มทิศทางในการเก็บข้อมูล และเพิ่มจำนวน และความหนาแน่นของจุดพิกัดสามมิติ ส่งผลให้ปัญหาการถูกบดบังลดน้อยลง

วิธีการคำนวณปริมาตรลำต้นนิยมใช้แบบจำลองโครงสร้างเชิงปริมาณ (Quantitative structural model: QSM) (Calders *et al.*, 2015; Feliciano *et al.*, 2014; Olagoke *et al.*, 2016) โดยแบ่งลำต้นเป็นท่อนให้มีความตรงที่สุด วัตถุประสงค์ของลำต้นที่ได้จากการเก็บข้อมูลพิกัดสามมิติและคำนวณออกมาเป็นปริมาตร จากนั้น นำค่าปริมาตรที่ได้ทั้งหมดมารวมกันเพื่อคำนวณเป็นปริมาตรรวมของลำต้นดังกล่าว Owers *et al.* (2018) ได้เสนอแบบจำลองพื้นผิวสามมิติ (3-D surface structural model) มาใช้แทน QSM โดยคาดหวังว่าวิธีดังกล่าวจะมีความเหมาะสมกับพื้นที่ที่ต้นไม้มีความหนาแน่น และมีหลากหลายสายพันธุ์ และสามารถคำนวณปริมาตรของลำต้นได้แม่นยำขึ้น อย่างไรก็ตาม ผลลัพธ์ที่ได้ปรากฏว่า ปริมาตรที่คำนวณได้จากแบบจำลองทั้งสองวิธีไม่แตกต่างกันอย่างมีนัยสำคัญทางสถิติ ในงานวิจัยนี้ได้เลือกใช้วิธี QSM เพื่อคำนวณค่าปริมาตรของลำต้น เนื่องจากลักษณะพื้นที่ศึกษามีต้นไม้หนาแน่น แต่มีสายพันธุ์เพียงสายพันธุ์เดียว คือ ต้นเสมหะเล การเก็บข้อมูลต้นไม้จึงมีความซับซ้อนน้อยกว่าในพื้นที่ศึกษาของ Owers *et al.* (2018) ดังนั้น การใช้ QSM ในการคำนวณปริมาตรของลำต้นจึงมีความเพียงพอสำหรับงานวิจัยนี้

6.4.2 การสร้างแบบจำลองมวลชีวภาพเหนือพื้นดินต้นเสมหะเล

การสร้างแบบจำลองมวลชีวภาพเหนือพื้นดินใช้ต้นไม้ตัวอย่างจำนวน 30 ต้น โดยขนาดเส้นผ่านศูนย์กลางความสูงเพียงอกมีค่าอยู่ระหว่าง 11.90 – 26.75 เซนติเมตร มาสร้างแบบจำลองโดยใช้ฟังก์ชันแบบยกกำลังซึ่งเป็นที่นิยมใช้อธิบายความสัมพันธ์แบบไม่เชิงเส้นระหว่างมวลชีวภาพเหนือพื้นดินกับส่วนประกอบของต้นไม้ (Chave *et al.*, 2005; Comley and McGuinness, 2005; Feliciano *et al.*, 2014; Komiyama *et al.*, 2005; Maan *et al.*, 2015; Njana *et al.*, 2016b; Olagoke *et al.*, 2016; Patil *et al.*, 2014) งานวิจัยนี้ได้เลือกเส้นผ่านศูนย์กลางความสูงเพียงอกเพียงหนึ่งพารามิเตอร์มาใช้เป็นตัวแปรเพื่อทำนายค่ามวลชีวภาพเหนือพื้นดินของต้นเสมหะเล เนื่องจากการสแกนข้อมูลด้วยเครื่องสแกนเลเซอร์ภาคพื้นดินเก็บข้อมูลบริเวณลำต้นเท่านั้น ในส่วนของเรือนยอดได้ปรับแก้โดยใช้ค่าปรับแก้เรือนยอด (Komiyama *et al.*, 2005) เพื่อประมาณค่ามวล

ชีวภาพเหนือพื้นดินในส่วนของเรือนยอด ค่ามวลชีวภาพเหนือพื้นดินของต้นแสมทะเลที่ประมาณค่าจากข้อมูลเครื่องสแกนเลเซอร์ภาคพื้นดินในงานวิจัยนี้ มีความสอดคล้องกับเส้นผ่านศูนย์กลางความสูงเพียงอก เมื่อเส้นผ่านศูนย์กลางความสูงเพียงอกมีค่าเพิ่มขึ้น ค่ามวลชีวภาพเหนือพื้นดินของต้นแสมทะเลจะมีค่าเพิ่มขึ้นเช่นเดียวกัน เป็นไปตามความสัมพันธ์ที่ได้จากแบบจำลองมวลชีวภาพเหนือพื้นดินของต้นแสมทะเล

6.4.3 การเปรียบเทียบมวลชีวภาพเหนือพื้นดินกับแบบจำลองมวลชีวภาพเหนือพื้นดินอ้างอิงด้วย RMSE

แบบจำลองมวลชีวภาพเหนือพื้นดินที่ใช้เพื่อเป็นแบบจำลองอ้างอิงประกอบด้วยแบบจำลองมวลชีวภาพเหนือพื้นดินของต้นแสมทะเลของ Comley and McGuinness (2005) และ Patil *et al.* (2014) มวลชีวภาพเหนือพื้นดินของต้นแสมทะเลในพื้นที่ศึกษาของ Laongmanee (2011) และแบบจำลองมวลชีวภาพเหนือพื้นดินของต้นไม้ป่าชายเลนทั่วไปของ Komiyama *et al.* (2005) เมื่อนำผลลัพธ์ค่ามวลชีวภาพเหนือพื้นดินที่ได้จากการประมาณค่ามาเปรียบเทียบกับแบบจำลองมวลชีวภาพเหนือพื้นดิน พบว่า ค่ามวลชีวภาพเหนือพื้นดินของงานวิจัยนี้มีค่าใกล้เคียงกับแบบจำลองมวลชีวภาพเหนือพื้นดินของ Comley and McGuinness (2005) มากที่สุด โดยมีค่า RMSE 23.51 กิโลกรัม คิดเป็นร้อยละ 13.30 รองลงมาเป็นแบบจำลองมวลชีวภาพเหนือพื้นดินของ Patil *et al.* (2014) มีค่า RMSE 29.91 กิโลกรัม คิดเป็นร้อยละ 19.72 (ตารางที่ 5-6) อย่างไรก็ตามเมื่อเปรียบเทียบกับแบบจำลองมวลชีวภาพของ Laongmanee (2011) RMSE มีค่า 45.19 กิโลกรัม คิดเป็นร้อยละ 35.12 สุดท้ายเมื่อเปรียบเทียบกับแบบจำลองของ Komiyama *et al.* (2005) ที่สร้างจากต้นไม้ป่าชายเลนหลายพันธุ์ผสมกัน RMSE มีค่า 100.83 กิโลกรัม คิดเป็นร้อยละ 39.88 เมื่อพิจารณาการเปรียบเทียบผลการประมาณมวลชีวภาพเหนือพื้นดินในของงานวิจัยที่ผ่านมา ในงานวิจัยของ Chave *et al.* (2005) เปรียบเทียบค่า RMSE อยู่ระหว่างร้อยละ 12.50 - 19.50 ซึ่งค่าที่ได้ขึ้นอยู่กับจำนวนพารามิเตอร์ที่เลือกเข้าสู่แบบจำลองมวลชีวภาพเหนือพื้นดิน Hackenberg *et al.* (2015a) และ Calders *et al.* (2015) เปรียบเทียบค่า RMSE ได้ประมาณร้อยละ 17.00 - 20.00 เมื่อพิจารณากับค่า RMSE ที่ได้จากการเปรียบเทียบแบบจำลองมวลชีวภาพเหนือพื้นดินของงานวิจัยนี้ พบว่า ค่า RMSE ที่เปรียบเทียบกับแบบจำลองมวลชีวภาพเหนือพื้นดินต้นแสมทะเลของ Comley and McGuinness (2005) และ Patil *et al.* (2014) มีค่าใกล้เคียงกับค่า RMSE ที่ได้เปรียบเทียบกับงานวิจัยที่ผ่านมา

อย่างไรก็ตาม เมื่ออนุมาน (Extrapolation) ค่าเส้นผ่านศูนย์กลางความสูงเพียงอกให้มีค่ามากกว่า 30 เซนติเมตรขึ้นไปจะมีค่าคลาดเคลื่อนเพิ่มสูงขึ้นห่างจากแบบจำลองอ้างอิงที่มีค่าใกล้เคียงจากการเปรียบเทียบ RMSE เนื่องจากพารามิเตอร์ที่ใช้ในการประมาณค่ามวลชีวภาพเหนือพื้นดินจาก

เครื่องสแกนเลเซอร์ภาคพื้นดินมีเพียงหนึ่งค่าคือเส้นผ่านศูนย์กลางความสูงเพียงอก และขนาดที่ใช้มีค่าอยู่ระหว่าง 11.90 – 26.75 เซนติเมตร ส่งผลให้ค่ามวลชีวภาพเหนือพื้นดินที่ประมาณได้จากแบบจำลองมีความแม่นยำในขอบเขตขนาดเส้นผ่านศูนย์กลางความสูงเพียงอกที่ใช้เป็นตัวอย่างเท่านั้น

แบบจำลองจากงานวิจัยนี้ เลือกใช้เส้นผ่านศูนย์กลางความสูงเพียงอกเป็นพารามิเตอร์สำหรับการทำนายผลซึ่งสอดคล้องกับงานวิจัยส่วนใหญ่ (Comley and McGuinness, 2005; Feliciano *et al.*, 2014; Njana *et al.*, 2016a; Patil *et al.*, 2014) อย่างไรก็ตาม แบบจำลองมวลชีวภาพเหนือพื้นดินจากบางงานวิจัยได้ใช้พารามิเตอร์จำนวนมากกว่าหนึ่งตัว เช่น ความสูงของต้นไม้และความหนาแน่นจำเพาะของเนื้อไม้ (Komiyama *et al.*, 2005; Laongmanee, 2011) ที่สามารถช่วยเพิ่มความถูกต้องของค่าประมาณมวลชีวภาพเหนือพื้นดิน ซึ่งงานวิจัยนี้ ไม่ได้นำพารามิเตอร์ตัวอื่น เช่น ความสูงของต้นไม้ มาร่วมใช้สร้างแบบจำลองเนื่องจากข้อจำกัดในการเก็บข้อมูลที่อาจส่งผลให้ความสูงของต้นไม้มีค่าคลาดเคลื่อนสูง ส่งผลต่อผลการประเมินมวลชีวภาพเหนือพื้นดินจากแบบจำลอง (Chave *et al.*, 2014; Liang *et al.*, 2016)

6.4.4 อุปกรณ์เครื่องสแกนเลเซอร์สำหรับการเก็บข้อมูลในพื้นที่ที่เข้าถึงลำบาก

ข้อจำกัดอีกประการหนึ่งของการสแกนเก็บข้อมูลต้นไม้ด้วย TLS เกิดจากความยากลำบากในการเข้าถึงพื้นที่ ลักษณะของพื้นที่ซึ่งเป็นโคลน และน้ำหนักของเครื่องสแกนเลเซอร์ภาคพื้นดิน จึงได้มีการทดลองนำเครื่องสแกนเลเซอร์ประเภทที่สามารถติดตั้งบนยานพาหนะ หรือผู้ใช้งานสามารถนำติดตัวเข้าไปในพื้นที่เก็บข้อมูล ได้แก่ Mobile laser scanner (MLS) และ Personal laser scanner (PLS) (นิยมเรียกอุปกรณ์ทั้งสองชนิดนี้เป็น MLS) มาใช้ในการเก็บข้อมูลจุดพิกัดสามมิติของต้นไม้ (Feliciano *et al.*, 2014; Liang *et al.*, 2016) ซึ่งอุปกรณ์ดังกล่าวได้มีการนำมาใช้งานเพื่อทดแทนการใช้งาน TLS Bauwens *et al.* (2016) ได้แก้ปัญหาเรื่องการเข้าไปเก็บข้อมูลในพื้นที่ที่เข้าถึงลำบากโดยใช้ MLS ทดสอบเก็บข้อมูลต้นไม้แทน TLS ผลลัพธ์ที่ได้มีความถูกต้องอยู่ในระดับที่น่าพอใจ อย่างไรก็ตาม อุปกรณ์ดังกล่าวยังมีค่าคลาดเคลื่อนที่เกิดขึ้นในขั้นตอนการประมาณค่า DBH โดยมีค่าคลาดเคลื่อนที่ 3.7 เซนติเมตร และมีค่าคลาดเคลื่อนเกิดขึ้นสูงในขั้นตอนของการรวมจุดพิกัดสามมิติ (Bienert *et al.*, 2018) เป็นผลมาจากสัญญาณของ GNSS ที่เครื่อง MLS ใช้นั้นมีค่าอ่อน (พื้นที่เก็บข้อมูลมีต้นไม้ที่หนาแน่น โดยเฉพาะในพื้นที่ป่าชายเลนที่เรือนยอดของต้นไม้หนาแน่นมาก ส่งผลต่อการรับสัญญาณของ GNSS) ถ้าหากมีการพัฒนาวิธีการรับสัญญาณ GNSS ให้มีคุณภาพดีขึ้น จะสามารถช่วยแก้ปัญหาด้านข้อจำกัดด้านการเข้าถึงพื้นที่ที่เกิดขึ้นได้ โดยข้อมูลที่ได้จากการทำงานด้วย MLS สามารถนำมาใช้ทดแทนข้อมูลจุดพิกัดสามมิติจาก TLS

6.5 สรุปผลการสร้างแบบจำลองมวลชีวภาพเหนือพื้นดินของต้นไม้ป่าชายเลนเขตร้อนด้วยเครื่องสแกนเลเซอร์ภาคพื้นดิน

การประมาณค่ามวลชีวภาพเหนือพื้นดินของต้นไม้นิยมใช้วิธีการประเมินอยู่ 2 วิธี คือ วิธีการตัดต้นไม้เพื่อนำมาประมาณค่าในห้องทดลอง และการใช้แบบจำลองมวลชีวภาพเหนือพื้นดินเพื่อประมาณค่าจากส่วนประกอบของต้นไม้ ในการประมาณค่ามวลชีวภาพเหนือพื้นดินของต้นไม้ในเขตอนุรักษ์ซึ่งในงานวิจัยนี้ทำการประมาณค่ามวลชีวภาพของต้นแสมทะเล ไม่สามารถตัดต้นไม้เพื่อนำไปประมาณค่าในห้องทดลอง หรือสร้างแบบจำลองมวลชีวภาพเหนือพื้นดิน วิธีการสร้างแบบจำลองมวลชีวภาพเหนือพื้นดินของต้นไม้ป่าชายเลนเขตร้อนด้วยเครื่องสแกนเลเซอร์ภาคพื้นดินจึงเป็นทางเลือกที่มีความเหมาะสมต่อการนำมาใช้สร้างแบบจำลองมวลชีวภาพเหนือพื้นดินของต้นแสมทะเล ผลการประมาณค่ามวลชีวภาพเหนือพื้นดินของต้นแสมทะเลด้วยเครื่องสแกนเลเซอร์ภาคพื้นดินให้ค่ามวลชีวภาพเหนือพื้นดินที่มีค่าใกล้เคียงกับค่าที่ได้จากแบบจำลองอ้างอิงที่นำมาใช้เปรียบเทียบ และแบบจำลองที่ได้จากงานวิจัยนี้สามารถนำมาใช้เป็นแบบจำลองมวลชีวภาพเหนือพื้นดินต้นแสมทะเลสำหรับพื้นที่อนุรักษ์พันธุ์ไม้ป่าชายเลนบางปูได้

อย่างไรก็ตาม ในการสร้างแบบจำลองใช้ค่าเส้นผ่านศูนย์กลางความสูงเพียงอกเป็นพารามิเตอร์สำหรับการทำนายเพียงค่าเดียวเท่านั้น ถ้าหากต้องการประมาณค่ามวลชีวภาพเหนือพื้นดินต้นแสมทะเลที่มีขนาดใหญ่มาก ต้องเก็บข้อมูลต้นแสมทะเลขนาดใหญ่เพิ่มเติมเพื่อนำมาปรับแก้แบบจำลองให้สามารถใช้ประมาณค่ามวลชีวภาพต้นแสมทะเลที่มีขนาดใหญ่ได้ และ ควรมีการทดสอบนำค่าพารามิเตอร์อื่น เช่น ความสูงของต้นไม้ มาใช้เป็นพารามิเตอร์ร่วมกับเส้นผ่านศูนย์กลางความสูงเพียงอกในการสร้างแบบจำลองมวลชีวภาพเหนือพื้นดินของต้นแสมทะเล นอกจากนี้ การนำเครื่องสแกนเลเซอร์มือถือมาใช้แทนเครื่องสแกนเลเซอร์ภาคพื้นดิน คาดว่าจะสามารถช่วยแก้ปัญหาด้านข้อจำกัดที่เกิดขึ้นในการทำงาน

6.6 ข้อเสนอแนะสำหรับการสร้างแบบจำลองมวลชีวภาพเหนือพื้นดินของต้นไม้ป่าชายเลนเขตร้อนด้วยเครื่องสแกนเลเซอร์ภาคพื้นดิน

6.6.1 ควรเพิ่มพารามิเตอร์สำหรับการทำนาย เช่น ค่าความสูง เข้าไปในการสร้างแบบจำลองเพื่อทดสอบความถูกต้องเพิ่มเติมสำหรับการประมาณค่ามวลชีวภาพเหนือพื้นดินต้นแสมทะเล

6.6.2 ควรทดลองใช้สมการรูปแบบอื่นนอกจากสมการแบบยกกำลัง หรือทดลองสร้างสมการรูปแบบอื่นเพื่อประมาณค่ามวลชีวภาพเหนือพื้นดินในแต่ละส่วนของต้นไม้ป่าชายเลนเขตร้อน

6.6.3 ควรนำวิธีการนี้ไปทดลองใช้กับต้นไม้ปาชายเลนเขตร้อนพันธุ์อื่น ๆ ที่พบในพื้นที่
ศึกษา เพื่อต่อยอดไปถึงการประเมินปริมาณคาร์บอนทั้งหมดที่กักเก็บได้ในพื้นที่



บรรณานุกรม

- Anthony, J. V., & Joanne, M. G. (2005). Understanding Interobserver Agreement: The Kappa Statistics. *Family Medicine*, 37(5), 3.
- Basaeed, E., Bhaskar, H., & Al-Mualla, M. (2016). Supervised remote sensing image segmentation using boosted convolutional neural networks. *Knowledge-Based Systems*, 99, 19-27. doi:10.1016/j.knosys.2016.01.028
- Bauwens, S., Bartholomeus, H., Calders, K., & Lejeune, P. (2016). Forest Inventory with Terrestrial LiDAR: A Comparison of Static and Hand-Held Mobile Laser Scanning. *Forests*, 7(6). doi:10.3390/f7060127
- Bhattarai, B., & Giri, C. (2011). Assessment of mangrove forests in the Pacific region using Landsat imagery. *Journal of Applied Remote Sensing*, 5. doi:10.1117/1.3563584
- Bienert, A., Georgi, L., Kunz, M., Maas, H. G., & von Oheimb, G. (2018). Comparison and Combination of Mobile and Terrestrial Laser Scanning for Natural Forest Inventories. *Forests*, 9(7). doi:10.3390/f9070395
- Calders, K., Newnham, G., Burt, A., Murphy, S., Raunonen, P., Herold, M., & Kaasalainen, M. (2015). Nondestructive estimates of above-ground biomass using terrestrial laser scanning. *Methods in Ecology and Evolution*, 6(2), 198-208. doi:10.1111/2041-210x.12301
- Cao, L., Coops, N. C., Innes, J. L., Sheppard, S. R. J., Fu, L. Y., Ruan, H. H., & She, G. H. (2016). Estimation of forest biomass dynamics in subtropical forests using multi-temporal airborne LiDAR data. *Remote Sensing of Environment*, 178, 158-171. doi:10.1016/j.rse.2016.03.012
- Chave, J., Andalo, C., Brown, S., Cairns, M. A., Chambers, J. Q., Eamus, D., & Yamakura, T. (2005). Tree allometry and improved estimation of carbon stocks and balance in tropical forests. *Oecologia*, 145(1), 87-99. doi:10.1007/s00442-005-0100-x
- Chave, J., Rejou-Mechain, M., Burquez, A., Chidumayo, E., Colgan, M. S., Delitti, W. B., & Vieilledent, G. (2014). Improved allometric models to estimate the aboveground biomass of tropical trees. *Global Change Biology*, 20(10), 3177-3190. doi:10.1111/gcb.12629

- Cheng, G., & Han, J. (2016). A survey on object detection in optical remote sensing images. *Isprs Journal of Photogrammetry and Remote Sensing*, 117, 11-28. doi:<http://dx.doi.org/10.1016/j.isprsjprs.2016.03.014>
- Cheng, G., Zhou, P. C., & Han, J. W. (2016). Learning Rotation-Invariant Convolutional Neural Networks for Object Detection in VHR Optical Remote Sensing Images. *Ieee Transactions on Geoscience and Remote Sensing*, 54(12), 7405-7415. doi:10.1109/tgrs.2016.2601622
- Comley, B. W. T., & McGuinness, K. A. (2005). Above- and below-ground biomass, and allometry, of four common northern Australian mangroves. *Australian Journal of Botany*, 53(5), 431-436. doi:10.1071/bt04162
- Congalton, R. G., & Green, K. (2009). *Assessing the accuracy of remotely sensed data. [electronic resource] : principles and practices*: Boca Raton : CRC Press/Taylor & Francis, c2009. 2nd ed.
- Donato, D. C., Kauffman, J. B., Murdiyarso, D., Kurnianto, S., Stidham, M., & Kanninen, M. (2011). Mangroves among the most carbon-rich forests in the tropics. *Nature Geoscience*, 4(5), 293-297. doi:10.1038/ngeo1123
- Dumoulin, V., & Visin, F. (2016). A guide to convolution arithmetic for deep learning.
- Ellison, J. C. (2015). Vulnerability assessment of mangroves to climate change and sea-level rise impacts. *Wetlands Ecology and Management*, 23(2), 115-137. doi:10.1007/s11273-014-9397-8
- Feliciano, E. A., Wdowinski, S., & Potts, M. D. (2014). Assessing Mangrove Above-Ground Biomass and Structure using Terrestrial Laser Scanning: A Case Study in the Everglades National Park. *Wetlands*, 34(5), 955-968. doi:10.1007/s13157-014-0558-6
- Forsman, M., Holmgren, J., & Olofsson, K. (2016). Tree Stem Diameter Estimation from Mobile Laser Scanning Using Line-Wise Intensity-Based Clustering. *Forests*, 7(9). doi:10.3390/f7090206
- Fukushima, K., & Imagawa, T. (1993). RECOGNITION AND SEGMENTATION OF CONNECTED CHARACTERS WITH SELECTIVE ATTENTION. *Neural Networks*, 6(1), 33-41. doi:10.1016/s0893-6080(05)80071-1

- Ghamisi, P., Chen, Y. S., & Zhu, X. X. (2016). A Self-Improving Convolution Neural Network for the Classification of Hyperspectral Data. *IEEE Geoscience and Remote Sensing Letters*, 13(10), 1537-1541. doi:10.1109/lgrs.2016.2595108
- Giri, C. (2016). Observation and Monitoring of Mangrove Forests Using Remote Sensing: Opportunities and Challenges. *Remote Sensing*, 8(9). doi:10.3390/rs8090783
- Giri, C., Ochieng, E., Tieszen, L. L., Zhu, Z., Singh, A., Loveland, T., & Duke, N. (2011). Status and distribution of mangrove forests of the world using earth observation satellite data. *Global Ecology and Biogeography*, 20(1), 154-159. doi:10.1111/j.1466-8238.2010.00584.x
- Giri, S., Mukhopadhyay, A., Hazra, S., Mukherjee, S., Roy, D., Ghosh, S., . . . Mitra, D. (2014). A study on abundance and distribution of mangrove species in Indian Sundarban using remote sensing technique. *Journal of Coastal Conservation*, 18(4), 359-367. doi:10.1007/s11852-014-0322-3
- Green, E. P., Mumby, P. J., Edwards, A. J., Clark, C. D., & Ellis, A. C. (1998). The assessment of mangrove areas using high resolution multispectral airborne imagery. *Journal of Coastal Research*, 14(2), 433-443.
- Hackenberg, J., Spiecker, H., Calders, K., Disney, M., & Raunonen, P. (2015a). SimpleTree-An Efficient Open Source Tool to Build Tree Models from TLS Clouds. *Forests*, 6(11), 4245-4294. doi:10.3390/f6114245
- Hackenberg, J., Wassenberg, M., Spiecker, H., & Sun, D. J. (2015b). Non Destructive Method for Biomass Prediction Combining TLS Derived Tree Volume and Wood Density. *Forests*, 6(4), 1274-1300. doi:10.3390/f6041274
- Hamdan, O., Khairunnisa, M. R., Ammar, A. A., Hasmadi, I. M., & Aziz, H. K. (2013). MANGROVE CARBON STOCK ASSESSMENT BY OPTICAL SATELLITE IMAGERY. *Penilaian stok karbon hutan paya laut menggunakan imej satelit optik.*, 25(4), 554-565.
- Han, S., Mao, H., & Dally, W. (2016). *Deep Compression: Compressing Deep Neural Networks with Pruning, Trained Quantization and Huffman Coding.*
- Heenkenda, M. K., Joyce, K. E., Maier, S. W., & Bartolo, R. (2014). Mangrove Species Identification: Comparing WorldView-2 with Aerial Photographs. *Remote Sensing*, 6(7), 6064-6088. doi:10.3390/rs6076064

- Held, A., Ticehurst, C., Lymburner, L., & Williams, N. (2003). High resolution mapping of tropical mangrove ecosystems using hyperspectral and radar remote sensing. *International Journal of Remote Sensing*, 24(13), 2739-2759. doi:10.1080/0143116031000066323
- Heumann, B. W. (2011). Satellite remote sensing of mangrove forests: Recent advances and future opportunities. *Progress in Physical Geography*, 35(1), 87-108. doi:10.1177/0309133310385371
- Hirata, Y., Tabuchi, R., Patanaponpaiboon, P., Pongparn, S., Yoneda, R., & Fujioka, Y. (2014). Estimation of aboveground biomass in mangrove forests using high-resolution satellite data. *Journal of Forest Research*, 19(1), 34-41. doi:10.1007/s10310-013-0402-5
- Hu, F., Xia, G. S., Hu, J. W., & Zhang, L. P. (2015a). Transferring Deep Convolutional Neural Networks for the Scene Classification of High-Resolution Remote Sensing Imagery. *Remote Sensing*, 7(11), 14680-14707. doi:10.3390/rs71114680
- Hu, W., Huang, Y. Y., Wei, L., Zhang, F., & Li, H. C. (2015b). Deep Convolutional Neural Networks for Hyperspectral Image Classification. *Journal of Sensors*. doi:10.1155/2015/258619
- Intarat, T., & Vaiphasa, C. (2018). *Application of Laser Scan Technique for Individual Tree Above Ground Biomass Estimation: an Experiment Study of Avicennia marina*. Paper presented at the The International Technical Conference on Circuits/Systems, Computers and Communications (ITC-CSCC), Thailand.
- Jachowski, N. R. A., Quak, M. S. Y., Friess, D. A., Duangnamon, D., Webb, E. L., & Ziegler, A. D. (2013). Mangrove biomass estimation in Southwest Thailand using machine learning. *Applied Geography*, 45, 311-321. doi:10.1016/j.apgeog.2013.09.024
- Jia, M. M., Zhang, Y. Z., Wang, Z. M., Song, K. S., & Ren, C. Y. (2014). Mapping the distribution of mangrove species in the Core Zone of Mai Po Marshes Nature Reserve, Hong Kong, using hyperspectral data and high-resolution data. *International Journal of Applied Earth Observation and Geoinformation*, 33, 226-231. doi:10.1016/j.jag.2014.06.006
- Kamal, M., & Phinn, S. (2011). Hyperspectral Data for Mangrove Species Mapping: A Comparison of Pixel-Based and Object-Based Approach. *Remote Sensing*, 3(10),

2222-2242. doi:10.3390/rs3102222

- Kamal, M., Phinn, S., & Johansen, K. (2015). Object-Based Approach for Multi-Scale Mangrove Composition Mapping Using Multi-Resolution Image Datasets. *Remote Sensing*, 7(4), 4753-4783. doi:10.3390/rs70404753
- Kazhdan, M., Bolitho, M., & Hoppe, H. (2006). *Poisson surface reconstruction*. Paper presented at the Proceedings of the fourth Eurographics symposium on Geometry processing, Cagliari, Sardinia, Italy.
- Kenzo, T., Ichie, T., Hattori, D., Itioka, T., Handa, C., Ohkubo, T., . . . Ninomiya, I. (2009). Development of allometric relationships for accurate estimation of above- and below-ground biomass in tropical secondary forests in Sarawak, Malaysia. *Journal of Tropical Ecology*, 25, 371-386. doi:10.1017/s0266467409006129
- Khorram, S., Koch, F. H., Wiele, C. F. v. d., & Nelson, S. A. C. (2012). *Remote Sensing*. New York: Springer.
- Koedsin, W., & Vaiphasa, C. (2013). Discrimination of Tropical Mangroves at the Species Level with EO-1 Hyperion Data. *Remote Sensing*, 5(7), 3562-3582. doi:10.3390/rs5073562
- Komiyama, A., Ong, J. E., & Pongpan, S. (2008). Allometry, biomass, and productivity of mangrove forests: A review. *Aquatic Botany*, 89(2), 128-137. doi:10.1016/j.aquabot.2007.12.006
- Komiyama, A., Pongpan, S., & Kato, S. (2005). Common allometric equations for estimating the tree weight of mangroves. *Journal of Tropical Ecology*, 21, 471-477. doi:10.1017/s0266467405002476
- Kovacs, J. M., de Santiago, F. F., Bastien, J., & Lafrance, P. (2010). An Assessment of Mangroves in Guinea, West Africa, Using a Field and Remote Sensing Based Approach. *Wetlands*, 30(4), 773-782. doi:10.1007/s13157-010-0065-3
- Kovacs, J. M., Liu, Y. L., Zhang, C. H., Flores-Verdugo, F., & de Santiago, F. F. (2011). A field based statistical approach for validating a remotely sensed mangrove forest classification scheme. *Wetlands Ecology and Management*, 19(5), 409-421. doi:10.1007/s11273-011-9225-3
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). *Imagenet classification with deep convolutional neural networks*. Paper presented at the Advances in neural

information processing systems.

- Kuenzer, C., Bluemel, A., Gebhardt, S., Quoc, T. V., & Dech, S. (2011). Remote Sensing of Mangrove Ecosystems: A Review. *Remote Sensing*, 3(5), 878-928. doi:10.3390/rs3050878
- Kumar, L., & Mutanga, O. (2017). Remote Sensing of Above-Ground Biomass. *Remote Sensing*, 9(9). doi:10.3390/rs9090935
- Langkvist, M., Kiselev, A., Alirezaie, M., & Loutfi, A. (2016). Classification and Segmentation of Satellite Orthoimagery Using Convolutional Neural Networks. *Remote Sensing*, 8(4). doi:10.3390/rs8040329
- Laongmanee, W. (2011). *Remote sensing techniques for biomass estimation of mangrove plantation* (Ph.D.), Chulalongkorn University, Bangkok. Available from EBSCOhost cat05085a database.
- Lecun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324. doi:10.1109/5.726791
- Lee, S. Y., Primavera, J. H., Dahdouh-Guebas, F., McKee, K., Bosire, J. O., Cannicci, S., . . . Record, S. (2014). Ecological role and services of tropical mangrove ecosystems: a reassessment. *Global Ecology and Biogeography*, 23(7), 726-743. doi:10.1111/geb.12155
- Lee, T. M., & Yeh, H. C. (2009). Applying remote sensing techniques to monitor shifting wetland vegetation: A case study of Danshui River estuary mangrove communities, Taiwan. *Ecological Engineering*, 35(4), 487-496. doi:10.1016/j.ecoleng.2008.01.007
- Li, H., Lu, H., Lin, Z., Shen, X., & Price, B. (2015a). *LCNN: Low-level Feature Embedded CNN for Salient Object Detection*.
- Li, S. S., Meng, X. W., Ge, Z. M., & Zhang, L. Q. (2015b). Evaluation of the threat from sea-level rise to the mangrove ecosystems in Tieshangang Bay, southern China. *Ocean & Coastal Management*, 109, 1-8. doi:10.1016/j.ocecoaman.2015.02.006
- Liang, H. M., & Li, Q. (2016). Hyperspectral Imagery Classification Using Sparse Representations of Convolutional Neural Network Features. *Remote Sensing*, 8(2). doi:10.3390/rs8020099

- Liang, X., Kankare, V., Hyypä, J., Wang, Y., Kukko, A., Haggrén, H., . . . Vastaranta, M. (2016). Terrestrial laser scanning in forest inventories. *Isprs Journal of Photogrammetry and Remote Sensing*, 115, 63-77. doi:<http://dx.doi.org/10.1016/j.isprsjprs.2016.01.006>
- Liang, X. L., Hyypä, J., Kaartinen, H., Lehtomaki, M., Pyorala, J., Pfeifer, N., . . . Wang, Y. S. (2018). International benchmarking of terrestrial laser scanning approaches for forest inventories. *Isprs Journal of Photogrammetry and Remote Sensing*, 144, 137-179. doi:10.1016/j.isprsjprs.2018.06.021
- Liu, W., Wang, Z., Liu, X., Zeng, N., Liu, Y., & Alsaadi, F. E. (2016). A survey of deep neural network architectures and their applications. *Neurocomputing*. doi:<http://dx.doi.org/10.1016/j.neucom.2016.12.038>
- Long, J., Shelhamer, E., & Darrell, T. (2015, 7-12 June 2015). *Fully Convolutional Networks for Semantic Segmentation*. Paper presented at the The Conference on Computer Vision and Pattern Recognition (CVPR), Boston, MA, USA.
- Lovell, J. L., Jupp, D. L. B., Newnham, G. J., & Culvenor, D. S. (2011). Measuring tree stem diameters using intensity profiles from ground-based scanning lidar from a fixed viewpoint. *Isprs Journal of Photogrammetry and Remote Sensing*, 66(1), 46-55. doi:10.1016/j.isprsjprs.2010.08.006
- Luus, F. P. S., Salmon, B. P., van den Bergh, F., & Maharaj, B. T. J. (2015). Multiview Deep Learning for Land-Use Classification. *IEEE Geoscience and Remote Sensing Letters*, 12(12), 2448-2452. doi:10.1109/lgrs.2015.2483680
- Maan, G. S., Singh, C. K., Singh, M. K., & Nagarajan, B. (2015). Tree species biomass and carbon stock measurement using ground based-LiDAR. *Geocarto International*, 30(3), 293-310. doi:10.1080/10106049.2014.925003
- Maas, H. G., Bienert, A., Scheller, S., & Keane, E. (2008). Automatic forest inventory parameter determination from terrestrial laser scanner data. *International Journal of Remote Sensing*, 29(5), 1579-1593. doi:10.1080/01431160701736406
- Maggiori, E., Tarabalka, Y., Charpiat, G., & Alliez, P. (2017). Convolutional Neural Networks for Large-Scale Remote-Sensing Image Classification. *IEEE Transactions on Geoscience and Remote Sensing*, 55(2), 645-657. doi:10.1109/tgrs.2016.2612821

- Mehdawi, A. A., & Ahmad, B. b. (2012). *Classification of Forest Change by Integration of Remote Sensing Data with Neural Network Techniques*. Paper presented at the 2012 International Conference on System Engineering and Technology, Bandung, Indonesia.
- Murdiyarso, D., Purbopuspito, J., Kauffman, J. B., Warren, M. W., Sasmito, S. D., Donato, D. C., . . . Kurnianto, S. (2015). The potential of Indonesian mangrove forests for global climate change mitigation. *Nature Climate Change*, *5*(12), 1089-1092. doi:10.1038/nclimate2734
- Muruganandham, S. (2016). Semantic Segmentation of Satellite Images using Deep Learning.
- Myint, S. W., Franklin, J., Buenemann, M., Kim, W. K., & Gini, C. P. (2014). Examining Change Detection Approaches for Tropical Mangrove Monitoring. *Photogrammetric Engineering and Remote Sensing*, *80*(10), 983-993.
- Njana, M. A., Bollandasås, O. M., Eid, T., Zahabu, E., & Malimbwi, R. E. (2016a). Above- and belowground tree biomass models for three mangrove species in Tanzania: a nonlinear mixed effects modelling approach. *Annals of Forest Science*, *73*(2), 353-369. doi:10.1007/s13595-015-0524-3
- Njana, M. A., Meilby, H., Eid, T., Zahabu, E., & Malimbwi, R. E. (2016b). Importance of tree basic density in biomass estimation and associated uncertainties: a case of three mangrove species in Tanzania. *Annals of Forest Science*, *73*(4), 1073-1087. doi:10.1007/s13595-016-0583-0
- Nogueira, K., Penatti, O. A. B., & dos Santos, J. A. (2017). Towards better exploiting convolutional neural networks for remote sensing scene classification. *Pattern Recognition*, *61*, 539-556. doi:10.1016/j.patcog.2016.07.001
- Odipo, V. O., Nickless, A., Berger, C., Baade, J., Urbazaev, M., Walther, C., & Schnullius, C. (2016). Assessment of Aboveground Woody Biomass Dynamics Using Terrestrial Laser Scanner and L-Band ALOS PALSAR Data in South African Savanna. *Forests*, *7*(12). doi:10.3390/f7120294
- Olagoke, A., Proisy, C., Feret, J. B., Blanchard, E., Fromard, F., Mehlig, U., . . . Berger, U. (2016). Extended biomass allometric equations for large mangrove trees from terrestrial LiDAR data. *Trees-Structure and Function*, *30*(3), 935-947.

doi:10.1007/s00468-015-1334-9

- Olofsson, K., & Holmgren, J. (2016). Single Tree Stem Profile Detection Using Terrestrial Laser Scanner Data, Flatness Saliency Features and Curvature Properties. *Forests*, 7(9). doi:10.3390/f7090207
- Ostadhashemi, R., Shahraji, T. R., Roehle, H., & Limaei, S. M. (2014). Estimation of biomass and carbon storage of tree plantations in northern Iran. *Journal of Forest Science*, 60(9), 363-371.
- Otero, V., Quisthoudt, K., Koedam, N., & Dahdouh-Guebas, F. (2016). Mangroves at Their Limits: Detection and Area Estimation of Mangroves along the Sahara Desert Coast. *Remote Sensing*, 8(6). doi:10.3390/rs8060512
- Owers, C. J., Rogers, K., & Woodroffe, C. D. (2018). Terrestrial laser scanning to quantify above-ground biomass of structurally complex coastal wetland vegetation. *Estuarine Coastal and Shelf Science*, 204, 164-176. doi:10.1016/j.ecss.2018.02.027
- Panboonyuen, T., Jitkajornwanich, K., Lawawirojwong, S., Srestasathiern, P., & Vateekul, P. (2019). Semantic segmentation on remotely sensed images using an enhanced global convolutional network with channel attention and domain specific transfer learning. *Remote Sensing*, 11(1). doi:10.3390/rs11010083
- Patil, V., Singh, A., Naik, N., & Unnikrishnan, S. (2014). Estimation of Carbon Stocks in *Avicennia marina* Stand Using Allometry, CHN Analysis, and GIS Methods. *Wetlands*, 34(2), 379-391. doi:10.1007/s13157-013-0505-y
- Plunkett, K., & Elman, J. (1997). *Exercises in Rethinking Innateness: A Handbook for Connectionist Simulation*. Cambridge, MA: MIT Press.
- Ramirez-Garcia, P., Lopez-Blanco, J., & Ocana, D. (1998). Mangrove vegetation assessment in the Santiago river mouth, Mexico, by means of supervised classification using Landsat TM imagery. *Forest Ecology and Management*, 105(1-3), 217-229. doi:10.1016/s0378-1127(97)00289-2
- Saito, S., Yamashita, T., & Aoki, Y. (2016). Multiple Object Extraction from Aerial imagery with Convolutional Neural Networks. *Journal of Imaging Science and Technology*, 60(1). doi:10.2352/J.ImagingSci.Technol.2016.60.1.010402
- Sasmito, S. D., Murdiyarso, D., Friess, D. A., & Kurnianto, S. (2016). Can mangroves keep

- pace with contemporary sea level rise? A global data review. *Wetlands Ecology and Management*, 24(2), 263-278. doi:10.1007/s11273-015-9466-7
- Shi, W., Caballero, J., Theis, L., Huszar, F., Aitken, A., Ledig, C., & Wang, Z. (2016). Is the deconvolution layer the same as a convolutional layer? In.
- Shlyakhter, I., Rozenoer, M., Dorsey, J., & Teller, S. (2001). Reconstructing 3D tree models from instrumented photographs. *IEEE Computer Graphics and Applications*, 21(3), 53-61. doi:10.1109/38.920627
- Sileshi, G. W. (2014). A critical review of forest biomass estimation models, common mistakes and corrective measures. *Forest Ecology and Management*, 329, 237-254. doi:10.1016/j.foreco.2014.06.026
- Vaiphasa, C., Ongsomwang, S., Vaiphasa, T., & Skidmore, A. K. (2005). Tropical mangrove species discrimination using hyperspectral data: A laboratory study. *Estuarine, Coastal and Shelf Science*, 65, 371-379. doi:10.1016
- Vashum, K. (2012). *Methods to Estimate Above-Ground Biomass and Carbon Stock in Natural Forests - A Review* (Vol. 02).
- Wang, H. Z., Wang, Y., Zhang, Q., Xiang, S. M., & Pan, C. H. (2017a). Gated Convolutional Neural Network for Semantic Segmentation in High-Resolution Images. *Remote Sensing*, 9(5). doi:10.3390/rs9050446
- Wang, J., Luo, C., Huang, H. Q., Zhao, H. Z., & Wang, S. Q. (2017b). Transferring Pre-Trained Deep CNNs for Remote Scene Classification with General Features Learned from Linear PCA Network. *Remote Sensing*, 9(3). doi:10.3390/rs9030225
- Wang, L., Silvan-Cardenas, J. L., & Sousa, W. P. (2008). Neural network classification of mangrove species from multi-seasonal ikonos imagery. *Photogrammetric Engineering and Remote Sensing*, 74(7), 921-927.
- Wang, L., Sousa, W. P., Gong, P., & Biging, G. S. (2004). Comparison of IKONOS and QuickBird images for mapping mangrove species on the Caribbean coast of Panama. *Remote Sensing of Environment*, 91(3-4), 432-440. doi:10.1016/j.rse.2004.04.005
- Watanakij, N., & Vaiphasa, C. (2016). Improving the accuracy of mangrove species discrimination using object based and high spatial resolution imagery: A case study in Pak Phanang, Thailand. *International Journal of Geoinformatics*, 12(3),

41-49.

- Yu, S., Jia, S., & Xu, C. (2017). Convolutional neural networks for hyperspectral image classification. *Neurocomputing*, 219, 88-98. doi:<http://dx.doi.org/10.1016/j.neucom.2016.09.010>
- Yu, X., Shao, H. B., Liu, X. H., & Zhao, D. Z. (2010). Applying Neural Network Classification to Obtain Mangrove Landscape Characteristics for Monitoring the Travel Environment Quality on the Beihai Coast of Guangxi, P. R. China. *Clean-Soil Air Water*, 38(3), 289-295. doi:10.1002/clen.200900195
- Zeiler, M. (2012). ADADELTA: An Adaptive Learning Rate Method. *CoRR*, *abs/1212.5701*. doi:citeulike-article-id:13321452
- Zhang, C., Sargent, I., Pan, X., Li, H., Gardiner, A., Hare, J., & Atkinson, P. M. (2019a). Joint Deep Learning for land cover and land use classification. *Remote Sensing of Environment*, 221, 173-187. doi:<https://doi.org/10.1016/j.rse.2018.11.014>
- Zhang, C. H., Kovacs, J. M., Liu, Y. L., Flores-Verdugo, F., & Flores-de-Santiago, F. (2014). Separating Mangrove Species and Conditions Using Laboratory Hyperspectral Data: A Case Study of a Degraded Mangrove Forest of the Mexican Pacific. *Remote Sensing*, 6(12), 11673-11688. doi:10.3390/rs61211673
- Zhang, C. M., Liu, J. P., Yu, F., Wan, S. J., Han, Y. J., Wang, J., & Wang, G. (2018). Segmentation model based on convolutional neural networks for extracting vegetation from Gaofen-2 images. *Journal of Applied Remote Sensing*, 12(4). doi:10.1117/1.Jrs.12.042804
- Zhang, W. M., Wan, P., Wang, T. J., Cai, S. S., Chen, Y. M., Jin, X. L., & Yan, G. J. (2019b). A Novel Approach for the Detection of Standing Tree Stems from Plot-Level Terrestrial Laser Scanning Data. *Remote Sensing*, 11(2). doi:10.3390/rs11020211
- Zhao, W., & Du, S. (2016). Learning multiscale and deep representations for classifying remotely sensed imagery. *Isprs Journal of Photogrammetry and Remote Sensing*, 113, 155-165. doi:<http://dx.doi.org/10.1016/j.isprsjprs.2016.01.004>
- Zhong, J. Y., Yang, B., Huang, G. Y., Zhong, F., & Chen, Z. Z. (2016). Remote Sensing Image Fusion with Convolutional Neural Network. *Sensing and Imaging*, 17. doi:10.1007/s11220-016-0135-6
- Zhou, P. C., Cheng, G., Liu, Z. B., Bu, S. H., & Hu, X. T. (2016). Weakly supervised target

- detection in remote sensing images based on transferred deep features and negative bootstrapping. *Multidimensional Systems and Signal Processing*, 27(4), 925-944. doi:10.1007/s11045-015-0370-3
- Zhu, Y. H., Liu, K., Liu, L., Wang, S. G., & Liu, H. X. (2015). Retrieval of Mangrove Aboveground Biomass at the Individual Species Level with WorldView-2 Images. *Remote Sensing*, 7(9), 12192-12214. doi:10.3390/rs70912192
- ศุภโชค แสงสว่าง. (2559). การประยุกต์ใช้โครงข่ายประสาทเทียมกับงานด้านการเกษตร. วารสารวิชาการพระจอมเกล้าพระนครเหนือ, 26(2), 12.
- ธนภัทร คุ่มสุภา. (2559). การจำแนกข้อความภาษาไทยโดยใช้นิวรอลเน็ตเวิร์กคอนโวลูชันระดับตัวอักษร. (วิทยาศาสตร์มหาบัณฑิต), จุฬาลงกรณ์มหาวิทยาลัย, กรุงเทพฯ.
- ธนสร อินทร์ตัน และ ชัยโชค ไวกาษา. (2561). การทดลองประมาณค่ามวลชีวภาพเหนือพื้นดินของต้นแสมทะเลเบื้องต้นด้วยเครื่องสแกนเลเซอร์ภาคพื้นดิน. *Thai Journal of Science and Technology*, 7(3), 307-318.
- ธันวา สัจจาพิทักษ์วงศ์, บรรเจิด พละการ, และ ชัยโชค ไวกาษา. (2009). การใช้ค่าดัชนีพืชพรรณที่ได้จากเทคนิคการสำรวจระยะไกลแบบไฮเปอร์สเปกตรัลเพื่อศึกษาตัวแปรทางชีววิทยาของป่าชายเลน: 2552.
- ญาใจ ลีมีปิยะภรณ์. (2556). การทำเหมืองข้อมูล. กรุงเทพฯ: ภาควิชาวิศวกรรมคอมพิวเตอร์ จุฬาลงกรณ์มหาวิทยาลัย.
- อรนงค์ บุเกตุ, & พุชชดี. (2556). แบบจำลองการพยากรณ์ปริมาณอ้อยของภาคตะวันออกเฉียงเหนือ โดยการใช้โครงข่ายประสาทเทียม. วารสารวิทยาศาสตร์ มข., 41(1), 13.



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

ประวัติผู้เขียน

ชื่อ-สกุล	นายฤชญาณ อินทร์ตัน
วัน เดือน ปี เกิด	6 พฤศจิกายน 2524
สถานที่เกิด	จังหวัดชลบุรี
วุฒิการศึกษา	2546 วิทยาศาสตร์บัณฑิต (ภูมิศาสตร์) มหาวิทยาลัยบูรพา 2550 วิทยาศาสตรมหาบัณฑิต (เทคโนโลยีภูมิศาสตร์) มหาวิทยาลัย บูรพา
ที่อยู่ปัจจุบัน	5/6 ถนนวชิรปราการ ต.บางปลาสร้อย อ.เมือง จ.ชลบุรี 20000
ผลงานตีพิมพ์	Intarat, T. & Vaiphasa, C. (2018). Application of Laser Scan Technique for Individual Tree Above Ground Biomass Estimation: an Experiment Study of Avicennia marina. In proceedings the International Technical Conference on Circuits/Systems, Computers and Communications (ITC-CSCC). Thailand: ITC-CSCC. Intarat, T. & Vaiphasa, C. (2018). Preliminary experiment on above-ground biomass estimation of Avicennia marina using terrestrial laser scanning technique. Thai Journal of Sciences and Technology 7(3). (in Thai)