

การตรวจหาบริเวณนาข้าวจากภาพถ่ายภาคพื้นดิน



นายชญาน์ แหวนหล่อ

จุฬาลงกรณ์มหาวิทยาลัย

CHULALONGKORN UNIVERSITY

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต

สาขาวิชาวิศวกรรมคอมพิวเตอร์ ภาควิชาวิศวกรรมคอมพิวเตอร์

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

ปีการศึกษา 2556

ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

บทคัดย่อและแฟ้มข้อมูลฉบับเต็มของวิทยานิพนธ์ตั้งแต่ปีการศึกษา 2554 ที่ให้บริการในคลังปัญญาจุฬาฯ (CUIR)

เป็นแฟ้มข้อมูลของนิสิตเจ้าของวิทยานิพนธ์ ที่ส่งผ่านทางบัณฑิตวิทยาลัย

The abstract and full text of theses from the academic year 2011 in Chulalongkorn University Intellectual Repository (CUIR) are the thesis authors' files submitted through the University Graduate School.

RICE FIELD DETECTION FROM TERRESTRIAL IMAGES



Mr. Chaya Wanlor

จุฬาลงกรณ์มหาวิทยาลัย

CHULALONGKORN UNIVERSITY

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

Department of Computer Engineering

Faculty of Engineering

Chulalongkorn University

Academic Year 2013

Copyright of Chulalongkorn University

หัวข้อวิทยานิพนธ์

การตรวจหาบริเวณนาข้าวจากภาพถ่ายภาคพื้นดิน

โดย

นายชยุพันธ์ แหวนหล่อ

สาขาวิชา

วิศวกรรมคอมพิวเตอร์

อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก

ผู้ช่วยศาสตราจารย์ ดร.สีบสกุล พิภพมงคล

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้บัณฑิตวิทยานิพนธ์ฉบับนี้เป็นส่วน
หนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรบัณฑิต

..... คณบดีคณะวิศวกรรมศาสตร์
(ศาสตราจารย์ ดร.บัณฑิต เอื้ออาภรณ์)

คณะกรรมการสอบวิทยานิพนธ์

..... ประธานกรรมการ
(รองศาสตราจารย์ณรงค์ลักษณ์ โควาวิสารัช)

..... อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก
(ผู้ช่วยศาสตราจารย์ ดร.สีบสกุล พิภพมงคล)

..... กรรมการ
(ผู้ช่วยศาสตราจารย์ ดร.ธนรัตน์ ชลิตาพงศ์)

..... กรรมการ
(รองศาสตราจารย์ ดร.ไพศาล สันติธรรมนนท์)

..... กรรมการภายนอกมหาวิทยาลัย
(ดร.เดชาลิขิต กตัญญูทวีทิพย์)

ชญาน์ แหวนหล่อ : การตรวจหาบริเวณนาข้าวจากภาพถ่ายภาคพื้นดิน. (RICE FIELD DETECTION FROM TERRESTRIAL IMAGES) อ.ที่ปรึกษาวิทยานิพนธ์หลัก: ผศ. ดร. สืบสกุล พิภพมงคล, 100 หน้า.

ในงานวิจัยนี้ได้เสนอวิธีการตรวจหาบริเวณนาข้าวที่อยู่ในภาพโดยใช้เทคนิคการประมวลผลภาพดิจิทัลและข่ายงานประสาทเทียม วิธีการที่เสนอใช้กับภาพถ่ายภาคพื้นดินที่ถ่ายในประเทศไทย ในขั้นตอนวิธีของงานวิจัยนี้ในแต่ละภาพจะถูกแบ่งออกเป็นเซกเมนต์เท่าๆกัน จากนั้นในแต่ละเซกเมนต์จะถูกสกัดพีเจอร์แล้วป้อนเข้าในข่ายงานประสาทเทียม โดยพีเจอร์ประกอบด้วย พีเจอร์เชิงพื้นผิว เชิงสี และเชิงตำแหน่ง ข่ายงานประสาทเทียมจะจำแนกเซกเมนต์ทุกเซกเมนต์ในภาพว่าเซกเมนต์นั้นเป็นส่วนของนาข้าวหรือไม่ จากนั้นฮิวริสติกฟังก์ชันจะถูกนำมาใช้ในการตัดสินใจว่าเป็นภาพนาข้าวหรือไม่ โดยค่าฮิวริสติกจะชี้ว่าการเชื่อมต่อของแต่ละเซกเมนต์มีมากน้อยเพียงใด ภาพทดสอบ 600 ภาพถูกใช้ในการหาค่าฮิวริสติก เพื่อนำมาหาค่าขีดแบ่งที่เหมาะสม และภาพอีก 9,158 ภาพถูกนำมาทดสอบกับวิธีการที่เสนอ ผลลัพธ์ที่ได้มีค่าความถูกต้องสำหรับภาพนาข้าวเฉลี่ยร้อยละ 96.19 และค่าความถูกต้องสำหรับภาพที่ไม่ใช่ชาวนาเฉลี่ยร้อยละ 96.58

จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

ภาควิชา วิศวกรรมคอมพิวเตอร์

ลายมือชื่อนิสิต

สาขาวิชา วิศวกรรมคอมพิวเตอร์

ลายมือชื่อ อ.ที่ปรึกษาวิทยานิพนธ์หลัก

ปีการศึกษา 2556

5470156521 : MAJOR COMPUTER ENGINEERING

KEYWORDS: LAND USE / RICE FIELD / ARTIFICIAL NEURAL NETWORK / DIGITAL
IMAGE PROCESSING

CHAYA WANLOR: RICE FIELD DETECTION FROM TERRESTRIAL IMAGES.
ADVISOR: ASST. PROF.SUEBSKUL PHIPHOBMONGKOL, Ph.D., 100 pp.

This research presents a method to detect the rice field region in images by using digital image processing techniques and artificial neural network. The proposed method was applied to terrestrial images taken in Thailand. In the algorithm, each image was divided into segments. The features of each segment were extracted and fed to the artificial neural network. The features include texture, color, and position. Artificial neural network was then used to classify each segment to determine whether a segment was a region of a rice field or not. A heuristic function was then applied to the classified segments of the image to determine a heuristic value that represented how much these segments were connected. 600 images were processed to find the heuristic values. An appropriate threshold was then determined from heuristic value. Other 9,158 images were tested with the proposed method. The result showed an average of 96.19% accuracy for rice detection and an average of 96.58% accuracy for non-rice detection.



Department: Computer Engineering Student's Signature

Field of Study: Computer Engineering Advisor's Signature

Academic Year: 2013

กิตติกรรมประกาศ

วิทยานิพนธ์นี้เสร็จสมบูรณ์ได้เพราะได้รับความช่วยเหลือจาก ผศ.ดร.สีบสกุล พิภพมงคล ที่ได้สละเวลาในการแนะนำและเสนอแนะข้อคิดเห็นต่างๆมากมาย

ขอขอบคุณคณาจารย์ผู้ที่เป็นกรรมการในการสอบวิทยานิพนธ์ฉบับนี้ ที่ให้คำแนะนำและเสนอแนวทางในพัฒนางานวิจัย ตลอดจนแก้ไขปรับปรุงข้อบกพร่องต่างๆของวิทยานิพนธ์ฉบับนี้

ขอบคุณสมาชิกในห้องปฏิบัติการ CGCI ทุกคนที่ให้คำแนะนำและคอยช่วยเหลือในการพัฒนางานวิจัย

สุดท้ายขอขอบพระคุณทุกคนที่ให้การสนับสนุนและเป็นกำลังใจให้กับผู้วิจัยเสมอมา



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

สารบัญ

หน้า

บทคัดย่อภาษาไทย.....	ง
บทคัดย่อภาษาอังกฤษ.....	จ
กิตติกรรมประกาศ.....	ฉ
สารบัญ.....	ช
สารบัญตาราง.....	ฌ
สารบัญภาพ.....	ญ
บทที่ 1 บทนำ.....	1
1.1 ความเป็นมาและความสำคัญของปัญหา.....	1
1.2 วัตถุประสงค์ของการวิจัย.....	2
1.3 ขอบเขตของการวิจัย.....	2
1.4 ประโยชน์ที่คาดว่าจะได้รับ.....	3
1.5 วิธีดำเนินการวิจัย.....	3
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง.....	4
2.1 การเจริญเติบโตของข้าว.....	4
2.2 แบบจำลองสี RGB.....	6
2.3 การแปลงภาพสีเป็นภาพระดับเทา.....	7
2.4 การหาค่าดัชนีความเขียว (Greenness Index).....	8
2.5 เมทริกซ์ของการเกิดร่วมระดับเทา (Grey Level Co-occurrence Matrix).....	9
2.6 การหาพีเจอร์ทางสถิติ (Statistical Features).....	11
2.7 ข่ายงานประสาทเทียม.....	15
2.8 งานวิจัยที่เกี่ยวข้อง.....	17
บทที่ 3 แนวคิดและวิธีดำเนินงาน.....	19
3.1 การทำงานของระบบ.....	21
3.2 การเตรียมข้อมูลก่อนการประมวลผล.....	21
3.3 การตัดแยกเพื่อเอาค่าเอ็กเซสกรีน.....	22
3.4 การสกัดพีเจอร์.....	23
3.5 การจำแนกข้อมูลโดยใช้ข่ายงานประสาทเทียม.....	26

3.6	การยืนยันภาพนาข้าว.....	27
3.7	การทดสอบรูปภาพ.....	28
บทที่ 4 การทดลองและผลการทดลอง		29
4.1	ภาพที่ใช้ในการทดลอง	29
4.2	สภาพแวดล้อมในการทดลอง.....	29
4.3	การทดลองหาขนาดของเซกเมนต์ที่เหมาะสม.....	29
4.4	การทดลองแยกส่วนสีเขียวของพืช.....	31
4.5	การทดลองหาลักษณะเฉพาะของแต่ละพีเจอร์	33
4.6	การทดลองการเรียนรู้ของข่ายงานประสาทเทียม.....	45
4.7	การทดลองหาค่าฮิวริสติกที่เหมาะสม	50
4.8	การทดลองการจำแนกภาพ	53
บทที่ 5 สรุปผลการวิจัยและข้อเสนอแนะ		66
5.1	สรุปผลการวิจัย	66
5.2	ข้อเสนอแนะ.....	67
5.3	ประโยชน์ที่คาดว่าจะได้รับ	67
รายการอ้างอิง.....		68
ภาคผนวก.....		70
ภาคผนวก ก.....		71
ภาคผนวก ข.....		77
ภาคผนวก ค.....		82
ภาคผนวก ง.....		85
ภาคผนวก จ.....		87
ภาคผนวก ฉ.....		94
ประวัติผู้เขียนวิทยานิพนธ์		100

สารบัญตาราง

	หน้า
ตารางที่ 3.1 ตารางแสดงชื่อคุณสมบัติและสมการในการหาพีเจอร์เชิงพื้นผิวทั้งหมด	25
ตารางที่ 4.1 ผลการวัดความถูกต้องในการจำแนกภาพ	54
ตารางที่ 4.2 ผลการวัดความถูกต้องในการจำแนกภาพแบ่งตามจังหวัด	55
ตารางที่ 4.3 ผลการวัดความถูกต้องในการจำแนกภาพแบ่งตามระยะการเจริญเติบโต.....	57



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

สารบัญภาพ

หน้า

รูปที่ 1.1	รถสำรวจที่ใช้ในการเก็บภาพของ Google Street View [3]	2
รูปที่ 2.1	ภาพนาข้าวในระยะต้นกล้า.....	4
รูปที่ 2.2	ภาพนาข้าวในระยะแตกกอ	5
รูปที่ 2.3	ภาพนาข้าวในระยะการเจริญเติบโตด้านการสีพันธุ	5
รูปที่ 2.4	ภาพนาข้าวในระยะสุกแก่หรือเก็บเกี่ยว	6
รูปที่ 2.5	แบบจำลองสี RGB [6].....	7
รูปที่ 2.6	โครงสร้างลูกบาศก์ของแบบสี RGB [6].....	7
รูปที่ 2.7	จุดภาพที่สนใจในทิศทาง(θ) 0, 45, 90, 135 องศา โดยมีระยะห่าง d เท่ากับ 1	9
รูปที่ 2.8	ภาพตั้งต้นระดับเทาที่มีระดับเทา 4 ค่า	9
รูปที่ 2.9	กรอบงานของ GLCM ที่มีค่าระดับเทา 4 ระดับ	10
รูปที่ 2.10	ตารางบันทึกความถี่ของการเกิดการเปลี่ยนแปลงระดับเทาที่เกิดขึ้นทั้งหมด ($d=1, =0$).	10
รูปที่ 2.11	ตารางบันทึกความน่าจะเป็นของการเกิดการเปลี่ยนแปลงระดับเทาที่เกิดขึ้นทั้งหมด.....	10
รูปที่ 2.12	ตัวอย่างของโครงสร้างข่ายงานประสาทเทียม	15
รูปที่ 2.13	ขั้นตอนวิธีของการเรียนรู้ย้อนกลับ	16
รูปที่ 3.1	ตัวอย่างภาพที่ได้จาก Google Street View.....	19
รูปที่ 3.2	ตัวอย่างภาพที่ใช้ในงานวิจัย	20
รูปที่ 3.3	ผังงานแสดงขั้นตอนวิธีของวิธีการที่เสนอ.....	21
รูปที่ 3.4	ตัวอย่างการแบ่งรูปภาพด้วยขนาดที่แตกต่างกัน.....	22
รูปที่ 3.5	การนำภาพตั้งต้นมาแปลงเป็นภาพเอ็กเซสกรีน	23
รูปที่ 3.6	ส่วนติดต่อกับผู้ใช้งานของโปรแกรมที่ใช้สำหรับเก็บตัวอย่างในการฝึก	23
รูปที่ 3.7	ตำแหน่งของเชกเมนต์ของนาข้าวในแนวแกนตั้ง.....	24
รูปที่ 3.8	โครงสร้างของข่ายงานประสาทเทียมที่ใช้ในงานวิจัยนี้	26
รูปที่ 3.9	ตัวอย่างของฐานข้อมูลที่ใช้เก็บข้อมูลในการฝึกข่ายงานประสาทเทียม	26
รูปที่ 3.10	ตัวอย่างภาพแสดงความสัมพันธ์ระหว่างการเชื่อมต่อกันของเชกเมนต์กับค่าฮิสตริก	27
รูปที่ 3.11	ตัวอย่างส่วนติดต่อกับผู้ใช้งานของโปรแกรมที่ใช้สำหรับทดสอบรูปภาพ.....	28
รูปที่ 4.1	ภาพตั้งต้นที่มีการแบ่งขนาดของเชกเมนต์เท่ากับ 40x40 พิกเซล	30
รูปที่ 4.2	ภาพตั้งต้นที่มีการแบ่งขนาดของเชกเมนต์เท่ากับ 10x10 พิกเซล	30
รูปที่ 4.3	ภาพตั้งต้นที่มีการแบ่งขนาดของเชกเมนต์เท่ากับ 20x20 พิกเซล	31
รูปที่ 4.4	ตัวอย่างภาพที่นำมาแปลงให้เป็นภาพเอ็กเซสกรีน ที่เป็นค่าระดับเทา 256 ระดับ	33
รูปที่ 4.5	ตัวอย่างภาพที่ใช้ในการฝึกข่ายงานประสาทเทียม.....	34

รูปที่ 4.6 ตัวอย่าง(บางส่วน)ของเซกเมนต์ที่จะใช้เป็นตัวอย่งในการฝึก.....	35
รูปที่ 4.7 ไฟล์รูปแบบ CSV ที่ใช้เก็บตัวอย่างเพื่อที่จะใช้ในการฝึก	36
รูปที่ 4.8 ฮิสโตแกรมแสดงค่าพลังงานที่แตกต่างกัน	37
รูปที่ 4.9 ฮิสโตแกรมแสดงค่าสหสัมพันธ์ที่แตกต่างกัน.....	37
รูปที่ 4.10 ฮิสโตแกรมแสดงค่าความแปรปรวนที่แตกต่างกัน.....	38
รูปที่ 4.11 ฮิสโตแกรมแสดงค่าผกกลับของผลต่างโมเมนต์ที่แตกต่างกัน.....	38
รูปที่ 4.12 ฮิสโตแกรมแสดงค่าเอนโทรปีที่แตกต่างกัน.....	39
รูปที่ 4.13 ฮิสโตแกรมแสดงค่าการวัดสหสัมพันธ์ 1 ที่แตกต่างกัน	39
รูปที่ 4.14 ฮิสโตแกรมแสดงค่าการวัดสหสัมพันธ์ 2 ที่แตกต่างกัน	40
รูปที่ 4.15 ฮิสโตแกรมแสดงค่าผลรวมเฉลี่ยที่แตกต่างกัน	40
รูปที่ 4.16 ฮิสโตแกรมแสดงค่าผลรวมของเอนโทรปีที่แตกต่างกัน	41
รูปที่ 4.17 ฮิสโตแกรมแสดงค่าความแปรปรวนที่แตกต่างกัน.....	41
รูปที่ 4.18 ฮิสโตแกรมแสดงค่าผลต่างของค่าความแปรปรวนที่แตกต่างกัน	42
รูปที่ 4.19 ฮิสโตแกรมแสดงค่าความต่างที่แตกต่างกัน.....	42
รูปที่ 4.20 ฮิสโตแกรมแสดงค่าผลต่างของเอนโทรปีที่แตกต่างกัน.....	43
รูปที่ 4.21 ฮิสโตแกรมแสดงค่าความเอ็กเซสกรีนเฉลี่ยที่แตกต่างกัน.....	43
รูปที่ 4.22 ฮิสโตแกรมแสดงค่าตำแหน่งในแนวตั้งที่แตกต่างกัน.....	44
รูปที่ 4.23 ประสิทธิภาพในการเรียนรู้ของข่ายงานประสาทเทียมโดยใช้โนดซ่อน 7 โนด	45
รูปที่ 4.24 ประสิทธิภาพในการเรียนรู้ของข่ายงานประสาทเทียมโดยใช้โนดซ่อน 8 โนด	46
รูปที่ 4.25 ประสิทธิภาพในการเรียนรู้ของข่ายงานประสาทเทียมโดยใช้โนดซ่อน 9 โนด	46
รูปที่ 4.26 ประสิทธิภาพในการเรียนรู้ของข่ายงานประสาทเทียมโดยใช้โนดซ่อน 10 โนด	47
รูปที่ 4.27 ประสิทธิภาพในการเรียนรู้ของข่ายงานประสาทเทียมโดยใช้โนดซ่อน 11 โนด	47
รูปที่ 4.28 ประสิทธิภาพในการเรียนรู้ของข่ายงานประสาทเทียมโดยใช้โนดซ่อน 12 โนด	48
รูปที่ 4.29 ประสิทธิภาพในการเรียนรู้ของข่ายงานประสาทเทียมโดยใช้โนดซ่อน 13 โนด	48
รูปที่ 4.30 โครงสร้างของข่ายงานประสาทเทียมที่ใช้ในงานวิจัยนี้.....	49
รูปที่ 4.31 ภาพทดสอบที่ถูกประมวลผลแล้ว.....	50
รูปที่ 4.32 ภาพนาข้าวที่มีค่าฮิวริสติกเท่ากับ 322.00.....	51
รูปที่ 4.33 ภาพไมไ่ขนาค้าวที่มีค่าฮิวริสติกเท่ากับ 2.125	51
รูปที่ 4.34 กราฟแสดงความสัมพันธ์ระหว่างค่าฮิวริสติกกับค่าความแม่นยำในการจำแนกภาพ.....	52
รูปที่ 4.35 ภาพนาข้าวที่ผ่านการประมวลผลและแสดงค่าฮิวริสติก.....	53
รูปที่ 4.36 ภาพไมไ่ขนาค้าวที่ผ่านการประมวลผลและแสดงค่าฮิวริสติก	54
รูปที่ 4.37 ภาพทดสอบก่อนและหลังการประมวลผล	58
รูปที่ 4.38 ภาพทดสอบก่อนและหลังการประมวลผล	59

รูปที่ 4.39 ภาพทดสอบก่อนและหลังการประมวลผล	60
รูปที่ 4.40 ภาพทดสอบก่อนและหลังการประมวลผล	61
รูปที่ 4.41 ภาพทดสอบก่อนและหลังการประมวลผล	62
รูปที่ 4.42 ภาพทดสอบก่อนและหลังการประมวลผล	63
รูปที่ 4.43 ภาพทดสอบก่อนและหลังการประมวลผล	64
รูปที่ 4.44 ภาพทดสอบก่อนและหลังการประมวลผล	64
รูปที่ 4.45 ภาพทดสอบก่อนและหลังการประมวลผล	65
รูปที่ ก-1 ภาพผลการทดลองเพิ่มเติมพร้อมแสดงค่าฮิวริสติก	72
รูปที่ ก-2 ภาพผลการทดลองเพิ่มเติมพร้อมแสดงค่าฮิวริสติก	73
รูปที่ ก-3 ภาพผลการทดลองเพิ่มเติมพร้อมแสดงค่าฮิวริสติก	74
รูปที่ ก-4 ภาพผลการทดลองเพิ่มเติมพร้อมแสดงค่าฮิวริสติก	75
รูปที่ ก-5 ภาพผลการทดลองเพิ่มเติมพร้อมแสดงค่าฮิวริสติก	76
รูปที่ ข-1 ส่วนติดต่อผู้ใช้งานของโปรแกรมสำหรับเก็บตัวอย่างที่จะใช้ในการฝึก	78
รูปที่ ข-2 ส่วนที่ใช้กำหนดไคเร็กทอรีที่เก็บภาพ	78
รูปที่ ข-3 ตัวอย่างหน้าจอโปรแกรมเมื่อได้ทำการเลือกไคเร็กทอรีที่เก็บภาพแล้ว	79
รูปที่ ข-4 ส่วนของโปรแกรมเมื่อได้ทำการเลือกเซกเมนต์ที่สนใจ	79
รูปที่ ข-5 ส่วนของโปรแกรมที่ใช้ระบุค่าผลลัพธ์เป้าหมายของเซกเมนต์	80
รูปที่ ข-6 ส่วนของโปรแกรมที่เก็บค่าตัวอย่างที่จะใช้ในการฝึกทั้งหมด	80
รูปที่ ข-7 ส่วนของโปรแกรมที่ใช้ในการเลือกรูปถัดไปหรือก่อนหน้า	80
รูปที่ ข-8 ตัวอย่างของไฟล์ (CSV) ของข้อมูลที่จะใช้ในการฝึก	81
รูปที่ ค-1 ส่วนติดต่อผู้ใช้งานของโปรแกรม	83
รูปที่ ค-2 ไคอะล็กที่เก็บไฟล์ (CSV) สำหรับฝึกในข่ายงานประสาทเทียม	83
รูปที่ ค-3 หน้าต่างแจ้งเตือนเมื่อทำฝึกสำเร็จ	84
รูปที่ ค-4 ส่วนของโปรแกรมที่ใช้ระบุไคเร็กทอรีต้นทางและปลายทางของภาพที่ต้องการทดสอบ	84
รูปที่ ค-5 ส่วนของโปรแกรมที่แสดงภาพขณะประมวลผล	84
รูปที่ ง-1 กราฟแสดงเวลาในการประมวลผล	86
รูปที่ จ-1 ตัวอย่างไฟล์ภาพที่เก็บมาพร้อมระบุตำแหน่งพิกัด	88
รูปที่ จ-2 ตัวอย่างไฟล์ที่เก็บตำแหน่งของภาพที่ประมวลผลแล้ว และให้ผลลัพธ์ว่าเป็นภาพนาข้าว	88
รูปที่ จ-3 ภาพแสดงพิกัดที่มีนาข้าวของจังหวัดอ่างทอง	89
รูปที่ จ-4 ภาพแสดงพิกัดที่มีนาข้าวของจังหวัดพระนครศรีอยุธยา	89
รูปที่ จ-5 ภาพแสดงพิกัดที่มีนาข้าวของจังหวัดฉะเชิงเทรา	90
รูปที่ จ-6 ภาพแสดงพิกัดที่มีนาข้าวของจังหวัดชัยนาท	90
รูปที่ จ-7 ภาพแสดงพิกัดที่มีนาข้าวของจังหวัดเชียงราย	91

รูปที่ จ-8 ภาพแสดงพิกัดที่มีนาข้าวของจังหวัดชลบุรี	91
รูปที่ จ-9 ภาพแสดงพิกัดที่มีนาข้าวของจังหวัดนครปฐม.....	92
รูปที่ จ-10 ภาพแสดงพิกัดที่มีนาข้าวของจังหวัดปทุมธานี	92
รูปที่ จ-11 ภาพแสดงพิกัดที่มีนาข้าวของจังหวัดสุพรรณบุรี.....	93
รูปที่ จ-12 ภาพแสดงพิกัดที่มีนาข้าวของจังหวัดอุทัยธานี.....	93



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

บทที่ 1

บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา

ปัจจุบันประเทศไทยมีการใช้ประโยชน์ที่ดินหลายด้าน เช่น การใช้ที่ดินเพื่อสร้างอาคารและสิ่งปลูกสร้าง การใช้ที่ดินเป็นพื้นที่เกษตรกรรม การใช้ที่ดินเป็นพื้นที่ป่าไม้ เป็นต้น ซึ่งข้อมูลเหล่านี้จะเป็นข้อมูลสำคัญในการพัฒนาด้านต่างๆของประเทศ เช่น ด้านการวางแผนการกำหนดนโยบายในด้านการพัฒนาที่ดิน ด้านการประเมินว่าในแต่ละปีมีพื้นที่ทำการเกษตรมากน้อยเพียงใดโดยเอาข้อมูลที่สามารถตรวจสอบเชื่อมโยงกันฐานข้อมูลที่ดิน ด้านทรัพยากรมนุษย์ในการสำรวจอาคารและสิ่งปลูกสร้างต่างๆ เป็นต้น ดังนั้นจึงจำเป็นที่จะต้องมีการสำรวจการใช้ประโยชน์จากที่ดินอยู่เป็นประจำ เพื่อที่จะได้ข้อมูลที่ทันสมัยที่เป็นประโยชน์ในการบริหารหรือจัดการทรัพยากรในอนาคตต่อไป

วิธีการสำรวจการใช้ประโยชน์จากที่ดินที่นิยมใช้ในอดีตที่ผ่านมาจนถึงปัจจุบัน ได้แก่ การสำรวจข้อมูลด้วยการรับรู้ระยะไกล (Remote Sensing) ซึ่งใช้หลักการสะท้อนของคลื่นแม่เหล็กไฟฟ้าจากดวงอาทิตย์เคลื่อนที่ผ่านชั้นบรรยากาศ เกิดปฏิสัมพันธ์ของพลังงานตามรูปลักษณะบนพื้นผิวโลก แล้วเดินทางเข้าสู่ตัวรับสัญญาณที่ติดตั้งในดาวเทียม หรืออุปกรณ์ที่ติดตั้งไว้ เช่น เครื่องบิน ยานอวกาศ หรือดาวเทียม จากนั้นหลังจากเก็บข้อมูลแล้วก็จะนำข้อมูลที่ได้ไปวิเคราะห์ด้วยสายตาหรือวิธีการประมวลผลภาพดิจิทัล นอกจากนี้วิธีการนี้อาจมีการสำรวจด้วยการเดินสำรวจแล้วบันทึกข้อมูลตามที่มนุษย์มองเห็น หรือการใช้มนุษย์บันทึกข้อมูลบนยานพาหนะด้วย

วิธีการสำรวจด้วยวิธีการรับรู้ระยะไกล สามารถทำได้อย่างรวดเร็ว เป็นการเก็บข้อมูลที่ได้ออกมาจำนวนมากในบริเวณกว้างก็จริง แต่จะให้รายละเอียดของวัตถุในภาพน้อยกว่าการสำรวจภาคพื้นดินเนื่องจากภาพที่ถ่ายอยู่ในระยะไกล มีขั้นตอนที่ยุ่งยากซับซ้อน ข้อมูลไม่ทันสมัยเพราะนานๆครั้งจึงจะสำรวจ ค่าใช้จ่ายสูง และเมื่อต้องการความละเอียดของภาพสูงและเก็บข้อมูลภาพบ่อยๆจะต้องเพิ่มค่าใช้จ่ายสูงตามด้วย การปรับปรุงข้อมูลให้ทันสมัยยังต้องพึ่งพาต่างประเทศอยู่นอกจากนั้นคุณภาพของภาพที่ได้ยังขึ้นอยู่กับสภาพอากาศ ณ ขณะนั้นด้วย ถ้ามีเมฆมากก็จะทำให้บดบังรายละเอียดต่างๆได้ แม้ที่ระดับพื้นดินจะมองเห็นชัดก็ตาม วิธีการเดินสำรวจสามารถเข้าถึงได้หลายพื้นที่ และสามารถเห็นรายละเอียดของภาพได้มากกว่าการสำรวจด้วยวิธีการรับรู้ระยะไกล แต่วิธีนี้ต้องใช้เวลามากเพราะทั้งการเดินและการบันทึกข้อมูลยังไม่เป็นอัตโนมัติ ดังนั้นถึงแม้หากใช้คนบันทึกข้อมูลบนยานพาหนะเพื่อให้สำรวจได้เร็วขึ้น ก็ยังคงไม่มีประสิทธิภาพเพราะรถต้องวิ่งด้วยความเร็วต่ำเพื่อให้ผู้บันทึกบันทึกข้อมูลได้ทัน

ในการใช้รถสำรวจวิ่งไปตามถนน เป็นสิ่งที่หน่วยงานบางหน่วยงานจัดทำอยู่เป็นประจำ ซึ่งจะมีการบันทึกภาพสิ่งแวดล้อมตามทางที่วิ่งไปด้วย หากมีการถ่ายภาพพื้นที่สองข้างทางไประหว่างสำรวจก็จะสามารถนำภาพที่ได้มาใช้ประโยชน์ในการระบุลักษณะการใช้ที่ดินได้ ในปัจจุบัน ประเทศไทยมีการใช้ที่ดินในการปลูกข้าวเป็นจำนวนมากสามารถดูได้จากการผลิตข้าวซึ่งผลิตได้ประมาณปีละ 32-38 ล้านตัน (สถิติระหว่างปี 2550-2554) มีพื้นที่เพาะปลูกประมาณ 60 ล้านไร่ [1] ซึ่งถือได้ว่าข้าวเป็นพืชเศรษฐกิจอันดับแรกของไทย ด้วยเหตุนี้ในงานวิจัยนี้จึงเสนอวิธีการตรวจหาบริเวณนาข้าว

ที่ใช้เทคนิคการประมวลผลภาพดิจิทัลและช่างงานประสาทเทียม โดยใช้ภาพถ่ายที่ได้จากการถ่ายภาพภาคพื้นดิน เช่น กล้องจากรถสำรวจ เป็นต้น ภาพที่ใช้ในงานวิจัยนี้ทั้งหมดจะใช้ภาพถ่ายจากรถสำรวจดังรูปที่ 1.1 ซึ่งเป็นรถสำรวจที่ใช้ในการเก็บภาพของ Google Street View [2]



รูปที่ 1.1 รถสำรวจที่ใช้ในการเก็บภาพของ Google Street View [3]

1.2 วัตถุประสงค์ของการวิจัย

งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาวิธีการตรวจหาบริเวณนาข้าวจากภาพถ่ายภาคพื้นดิน

1.3 ขอบเขตของการวิจัย

1. ภาพนาข้าวที่ตรวจจับเป็นภาพที่มีต้นข้าวที่โตพอสมควร (ในช่วงระยะการแตกกอจนถึงระยะเก็บเกี่ยว) ซึ่งจะมีส่วนของต้นข้าวเป็นส่วนใหญ่ครอบคลุมผิวดิน
2. ภาพนาข้าวที่ตรวจจับต้องเป็นภาพนาข้าวที่ยังไม่เก็บเกี่ยวหรือไม่เป็นภาพนาร้าง
3. ภาพที่ใช้เป็นภาพสีรูปแบบ RGB และเป็นภาพถ่ายภาคพื้นดิน โดยแกนของเลนส์อยู่ประมาณแนวราบ
4. ภาพที่จะนำมาทดสอบเป็นภาพถ่ายด้านข้างของถนน
5. ไม่มีวัตถุอื่นบดบังส่วนของนาข้าว เช่น รั้ว ต้นไม้อื่น สิ่งปลูกสร้าง เป็นต้น
6. ภาพถ่ายต้องเป็นภาพที่โฟกัสได้ชัดเจน ถ่ายในที่ที่มีแสงสว่างเพียงพอ และไม่มีรอยต่อ
7. ตรวจสอบความถูกต้องของผลลัพธ์โดยมนุษย์

1.4 ประโยชน์ที่คาดว่าจะได้รับ

1. สามารถนำวิธีการตรวจหาณาข้าวนี้ไปใช้เป็นทางเลือกในการตรวจหาการใช้ประโยชน์ที่ดินจากภาพถ่ายที่ได้จากการสำรวจภาคพื้นดินเป็นอีกทางเลือกหนึ่งนอกเหนือจากการสำรวจจากภาพถ่ายทางอากาศได้

2. สามารถให้ข้อมูลในการยืนยันหรือสนับสนุนข้อมูลที่ได้จากภาพถ่ายทางอากาศว่าบริเวณนั้นมีนาข้าว

3. เนื่องจากใช้ข้อมูลภาพถ่ายจากระยะที่สำรวจภาคพื้นดิน ซึ่งมีการสำรวจเป็นประจำอยู่แล้ว ช่วยให้แบ่งภาระต้นทุนค่าใช้จ่ายในการสำรวจได้ระหว่างหน่วยงานที่ใช้การสำรวจร่วมกัน

1.5 วิธีดำเนินการวิจัย

1. ศึกษาการเจริญเติบโตของข้าวในระยะต่างๆ
2. ศึกษาวิธีการสกัดพีเจอร์เชิงสี เชิงพื้นผิว และเชิงตำแหน่งของรูปภาพ
3. ออกแบบขั้นตอนวิธีในการการตรวจจับ
4. ทดสอบวิธีการที่เสนอ
5. วิเคราะห์ผลการทดลอง
6. สรุปผลและเรียบเรียงวิทยานิพนธ์

บทที่ 2

ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

2.1 การเจริญเติบโตของข้าว

ข้าวเป็นธัญพืชที่สำคัญของโลกโดยเป็นแหล่งพลังงานของประชากรโลก ตามรายงานขององค์การอาหารและเกษตรแห่งสหประชาชาติ (FAO) [4] ในช่วงระหว่างปี 2550-2554 ผลผลิตข้าวของโลกจะอยู่ในระหว่าง 612-723 ล้านตัน ซึ่งเป็นผลผลิตจากทวีปเอเชียประมาณ 598-653 ล้านตัน

ประเทศไทยสามารถผลิตข้าวได้ประมาณปีละ 32-38 ล้านตัน (สถิติระหว่างปี 2550-2554) จากข้าวนาปีประมาณ 25 ล้านตันและข้าวนาปรังประมาณ 10 ล้านตัน มีพื้นที่เพาะปลูกประมาณ 60 ล้านไร่ มีการส่งออกประมาณ 1ใน4หรือประมาณ 7-9 ล้านตัน โดยมีมูลค่าการส่งออกระหว่าง 119,215-203,219 ล้านบาทต่อปี (ข้อมูลระหว่างปี 2550-2554) [1]

การศึกษาทางการเจริญเติบโตหรือสรีรวิทยาของพืชที่มีความสำคัญทำให้ทราบถึงขั้นตอนของกระบวนการมีชีวิตของพืช และอิทธิพลของปัจจัยภายนอกที่ส่งผลต่อกระบวนการทำให้เกิดอาการผิดปกติหรือเจริญเติบโตไม่เต็มที่ ถ้าสามารถศึกษาและเข้าใจการตอบสนองของพืชดังกล่าวได้แล้ว ก็สามารถนำความรู้นั้นไปปรับปรุงแก้ไขให้พืชเจริญเติบโตในสภาพปกติและให้ผลผลิตตามเป้าหมายได้ ในที่นี้จะได้กล่าวถึงการเจริญเติบโตของข้าวพอสังเขปเท่านั้น การเจริญเติบโตของข้าว [5] โดยทั่วไปจะแบ่งออกเป็นระยะต่างๆ ซึ่งมีรายละเอียดดังนี้

2.1.1 ระยะต้นกล้า (Seedling Stage)

ระยะต้นกล้า เป็นระยะจากข้าวงอกจนกระทั่งถึงข้าวแตกกอ ใช้ระยะเวลาประมาณ 20 วัน (ขึ้นอยู่กับพันธุ์) สิ้นสุดระยะนี้ต้นข้าวจะมีใบประมาณ 5-6 ใบ ตัวอย่างภาพนาข้าวในระยะต้นกล้า แสดงดังรูปที่ 2.1



รูปที่ 2.1 ภาพนาข้าวในระยะต้นกล้า

2.1.2 ระยะแตกกอ (Tiller Stage)

ระยะแตกกอ นับจากข้าวเริ่มแตกกอดังกล่าวจนถึงข้าวเริ่มสร้างช่อดอกอ่อน ใช้เวลาประมาณ 30-50 หลังจากระยะต้นกล้าขึ้นอยู่กับการตอบสนองต่อช่วงแสงของพันธุ์ข้าว ตัวอย่างภาพนาข้าวในระยะต้นแตกกอแสดงดังรูปที่ 2.2



รูปที่ 2.2 ภาพนาข้าวในระยะแตกกอ

2.1.3 ระยะเจริญเติบโตด้านการสืบพันธุ์ (Reproductive Growth Stage)

ระยะเจริญเติบโตด้านการสืบพันธุ์ เริ่มจากข้าวเริ่มสร้างช่อดอกอ่อน ผ่านระยะตั้งท้อง จนถึงโผล่ช่อดอกและผสมเกสร โดยจะใช้ระยะเวลาช่วงนี้ประมาณ 30-35 วัน ตัวอย่างภาพนาข้าวในระยะเจริญเติบโตด้านการสืบพันธุ์แสดงดังรูปที่ 2.3



รูปที่ 2.3 ภาพนาข้าวในระยะการเจริญเติบโตด้านการสืบพันธุ์

2.1.4 ระยะเวลาสุกแก่หรือเก็บเกี่ยว (Harvest Maturity Stage)

ระยะสุกแก่หรือเก็บเกี่ยว จะมีการพัฒนาการของเมล็ด โดยจะเริ่มขึ้นภายหลังการผสมเกสร ซึ่งรังไข่ที่ได้รับการผสมจะเจริญเติบโต ในระยะแรกจะอยู่ในระยะน้ำนม เปลี่ยนเป็นแป้งอ่อน จนกระทั่งเมล็ดสุก เป็นแป้งแข็งเป็นระยะสุกแก่หรือเก็บเกี่ยว จะใช้เวลาการพัฒนาการของเมล็ดทั้งหมดประมาณ 25-30 วัน ตัวอย่างภาพนาข้าวในระยะสุกแก่หรือเก็บเกี่ยวแสดงดังรูปที่ 2.4




รูปที่ 2.4 ภาพนาข้าวในระยะสุกแก่หรือเก็บเกี่ยว

ดังนั้นเมื่อรวมระยะต่าง ๆ แล้ว ข้าวจะมีอายุในระหว่าง 110-120 วัน สำหรับข้าวไม่ไวแสง และประมาณ 120-140 วันสำหรับข้าวไวแสง

ในงานวิจัยนี้จะสามารถตรวจจับนาข้าวที่อยู่ในช่วงระยะการแตกกอ(Tiller Stage) จนถึงระยะสุกแก่หรือเก็บเกี่ยว(Harvest Maturity Stage)

2.2 แบบจำลองสี RGB

รูปแบบสี RGB (Red Green Blue) รูปแบบสี RGB เป็นระบบสีของแสงที่เกิดจากการหักเหของแสงสีขาวผ่านแท่งแก้วปริซึม ทำให้เกิดแถบสีรุ้ง (Spectrum) ซึ่งมี 7 สี ได้แก่ ม่วง คราม น้ำเงิน เขียว เหลือง แสด แดง โดยสามารถจัดเป็นพลังงานรูปแบบหนึ่งซึ่งอยู่ในช่วงที่ตาคนเรามองเห็นได้ และเมื่อศึกษาถี่กลงไปจะพบว่าสีทั้งหมดเกิดจากการผสมของสีหลัก 3 สี คือ สีแดง สีเขียว และสีน้ำเงิน ดังรูปที่ 2.5




รูปที่ 2.5 แบบจำลองสี RGB [6]

2.3 การแปลงภาพสีเป็นภาพระดับเทา

ระบบสี RGB แบ่งออกเป็น 3 ส่วน คือ สีแดง (Red) สีเขียว (Green) และสีน้ำเงิน (Blue) โดยแต่ละจุดของภาพสีเกิดจากการผสมกันระหว่าง 3 ส่วน ด้วยการโดยมีความเข้มของของแต่ละส่วนต่างกัน จะส่งผลให้เกิดสีต่างๆได้มากมาย ถ้านำภาพสีจากมาใช้ในการทำงานจะทำให้เกิดกระบวนการที่ยุ่งยากซับซ้อน ใช้เวลาประมวลผลนาน และอาจทำให้การทำงานผิดพลาดได้ เพื่อให้กระบวนการทำงานและการประมวลผลมีความรวดเร็วและง่ายขึ้น จึงต้องทำการเปลี่ยนภาพสีให้เป็นภาพระดับเทาที่มีระดับความเทาอยู่ระหว่าง 0 – 255 โดย 0 คือค่าที่มีความเข้มของแสงต่ำสุด 255 คือค่าที่มีความเข้มของแสงสูงสุด

จากรูปที่ 2.6 จะเห็นว่าองค์ประกอบของสีทั้งสามส่วนจะเริ่มต้นที่จุดเริ่มต้น(origin)เดียวกัน โดยสีน้ำเงินจะมีค่าเพิ่มขึ้นตามแนวของแกน B สีเขียวค่าจะเพิ่มขึ้นตามแนวของแกน G และ สีแดงค่าจะเพิ่มขึ้นตามแนวของแกน R ซึ่งการแปลงภาพสี RGB ไปเป็นภาพระดับเทาก็คือ การฉายจากจุดใดๆ ภายในลูกบาศก์ลงไปตั้งฉากกับแกนที่ลากจากจุด origin ไปยังจุดที่เป็นค่าสูงสุดของทั้งสามแกนรูปที่ 2.6



รูปที่ 2.6 โครงสร้างลูกบาศก์ของแบบสี RGB [6]

วิธีการแปลงเป็นภาพระดับเทานั้นจะหาได้จาก ผลรวมของค่าของความเข้มของแต่ละองค์ประกอบสี (สีแดง เขียวและน้ำเงิน) คูณกับน้ำหนักของ ตามมาตรฐานของ Rec.601(ITU-R

Recommendation BT.601) เมื่อคิดเป็นเปอร์เซ็นต์จะได้สีแดง 30 % สีเขียว 59 % และสีน้ำเงิน 11% สูตรการคำนวณดังสมการที่ 2.1

$$\text{Gray Level} = 0.3R + 0.59G + 0.11B \quad (2.1)$$

เมื่อค่า R,G,B คือ ค่าของในแต่ละองค์ประกอบของจุดภาพที่สนใจในระบบสี RGB

2.4 การหาค่าดัชนีความเขียว (Greenness Index)

การหาดัชนีความเขียวนำมาใช้ประโยชน์มากในการแยกส่วน (Segmentation) ส่วนที่เป็นสีเขียวของพืชในรูปภาพที่เกี่ยวกับทางด้านการเกษตร โดยมีผู้เสนอการหาดัชนีความเขียวรูปแบบต่างๆดังนี้

ค่า Excess green (ExG) ที่เสนอโดย Woebbecke [7] ดังสมการที่ 2.2

$$\text{ExG} = 2g - r - b \quad (2.2)$$

Color index of vegetation extraction (CIVE) ที่เสนอโดย Kataoka [8] ดังสมการที่ 2.3

$$\text{CIVE} = 0.441r - 0.811g + 0.385b + 18.78745 \quad (2.3)$$

Vegetative (Vegetative) ที่เสนอโดย Hague [9] ดังสมการที่ 2.4

$$\text{VEG} = g / r^a b^{(1-a)}, a = 0.667 \quad (2.4)$$

โดยที่

r, g, b คือ ค่าความเข้มที่ถูกนอมอลไลซ์ขององค์ประกอบสีแดง เขียว และน้ำเงินตามลำดับดังสมการ 2.5

$$g = \frac{g_n}{g_n + r_n + b_n}, r = \frac{r_n}{g_n + r_n + b_n}, b = \frac{b_n}{g_n + r_n + b_n} \quad (2.5)$$

r_n, g_n, b_n คือ ค่าความเข้มขององค์ประกอบสีแดง เขียว และน้ำเงิน ตามลำดับที่หารด้วยคือค่าความเข้มสูงสุดสูงสุดดังสมการ 2.6

$$g_n = \frac{G}{G_{\max}}, r_n = \frac{R}{R_{\max}}, b_n = \frac{B}{B_{\max}} \quad (2.6)$$

เมื่อ


$R_{\max}, G_{\max}, B_{\max}$ คือค่าความเข้มสูงสุดสูงสุดของ R G และ B ตามลำดับ ซึ่งมีค่าเท่ากับ 255

R G และ B คือ ค่าความเข้มขององค์ประกอบสีแดง เขียว และน้ำเงิน ตามลำดับ

ในงานวิจัยนี้จะใช้ค่า Excess Green ที่เสนอโดย Woebbecke [7] เนื่องจากสามารถใช้ได้ดี โดยไม่มีเงื่อนไขของความสว่างของแสงเข้ามาเกี่ยวข้อง

2.5 เมทริกซ์ของการเกิดร่วมระดับเทา (Grey Level Co-occurrence Matrix)

Gray-Level Co-occurrence (GLCM) เป็นวิธีการทางสถิติที่ใช้กันอย่างกว้างขวางในการจำแนกพื้นผิวโดยอาศัยหลักความสัมพันธ์ของการเปลี่ยนแปลงระดับสีเทาของพิกเซลที่อยู่ติดกันในภาพประกอบกันเป็นพื้นผิว ซึ่งสามารถคำนวณหาได้โดยอาศัยเมทริกซ์โดยการนับจำนวนคู่จุดภาพ (k,l) และ (m,n) ที่อยู่ติดใกล้กัน (Neighboring pixel) ที่มีระยะห่างระหว่างกันเท่ากับ d และทำมุมกันเท่ากับ θ โดยในที่นี้จะสนใจที่ค่าที่มุม $0, 45, 90, 135$ องศา โดยมีค่าระยะห่างระหว่างกันเท่ากับ 1 พิกเซล ($d=1$) ดังรูปที่ 2.7



รูปที่ 2.7 จุดภาพที่สนใจในทิศทาง(θ) $0, 45, 90, 135$ องศา โดยมีระยะห่าง d เท่ากับ 1

การคำนวณ GLCM จะใช้ตารางแสดงจำนวนครั้งที่เกิดขึ้นของการเปลี่ยนแปลงระหว่างจุดภาพ โดยใช้ค่าการเปลี่ยนแปลงระดับสีเทา (Gray Level) ที่เกิดในภาพมาแสดงผลในตารางตัวอย่างเช่น มีภาพระดับสีเทา 4 ระดับดังรูปที่ 2.8

0	0	1	1
0	0	1	1
0	2	2	2
2	2	3	3


รูปที่ 2.8 ภาพตั้งต้นระดับเทาที่มีระดับเทา 4 ค่า

เนื่องจากภาพตัวอย่างตั้งต้นมีระดับเทาเพียง 4 ค่า ดังนั้น กรอบงาน (Framework) ของ GLCM ที่เป็นไปได้ทั้งหมด $4 \times 4 = 16$ ค่าดังรูปที่ 2.9

0,0	0,1	0,2	0,3
1,0	1,1	1,2	1,3
2,0	2,1	2,2	2,3
3,0	3,1	3,2	3,3

รูปที่ 2.9 กรอบงานของ GLCM ที่มีค่าระดับเทา4ระดับ

เมื่อได้กรอบงานแล้ว ก็จะทำการบันทึกความถี่ของการเปลี่ยนแปลงค่าระดับเทาจากภาพตั้งต้น ในที่นี้แสดงการเปลี่ยนแปลงในทิศทาง 0 องศา โดยบันทึกลงในกรอบที่ได้สร้างขึ้นมาก่อนหน้านี้ ดังรูปที่ 2.10



รูปที่ 2.10 ตารางบันทึกความถี่ของการเกิดการเปลี่ยนแปลงระดับเทาที่เกิดขึ้นทั้งหมด (d=1, =0)

จากตารางความถี่ของการเกิดการเปลี่ยนแปลงระดับเทา จะต้องทำให้ข้อมูลอยู่ในรูปแบบมาตรฐาน (Normalization) โดยการหารในแต่ละสมาชิกด้วยจำนวนคู่ของการเปลี่ยนแปลงระดับเทาทั้งหมดที่เกิดขึ้น จะได้ค่าของความน่าจะเป็นที่เกิดขึ้น ดังรูปที่ 2.11

		0	1	2	3			0	1	2	3
	0	2	2	1	0	=	0	0.167	0.167	0.083	0
	1	0	2	0	0		1	0	0.167	0	0
1/12	2	0	0	3	1		2	0	0	0.25	0.083
	3	0	0	0	1		3	0	0	0	0.083

รูปที่ 2.11 ตารางบันทึกความน่าจะเป็นของการเกิดการเปลี่ยนแปลงระดับเทาที่เกิดขึ้นทั้งหมด

เมทริกซ์สุดท้ายที่ได้จะเรียกว่า Gray-Level Co-occurrence Matrix (GLCM) หรือ $p(i, j)$ ซึ่งคือค่าใน GLCM ที่ตำแหน่ง (i, j) เมทริกซ์ที่ได้นี้จะนำมาหาคุณสมบัติเฉพาะต่างๆทางสถิติต่อไป

2.6 การหาพีเจอร์ทางสถิติ (Statistical Features)

เมื่อได้ทำการหา Grey-Level Co-occurrence Matrix แล้ว ขั้นตอนต่อไปคือนำเมทริกซ์นี้ มาหาพีเจอร์ทางสถิติ (Statistical Features) ซึ่ง Haralick [10] ได้เสนอพีเจอร์ทางสถิติไว้ดังต่อไปนี้

ค่าโมเมนต์อันดับที่สองของมุม (Angular Second Moment, ASM)

ค่าโมเมนต์อันดับที่สองของมุม (Angular Second Moment, ASM) หรือ f_1 เป็นค่าที่แสดงผลรวมกำลังสองของค่าในอีลิเมนต์ต่างๆของเมทริกซ์ แสดงดังสมการที่ 2.7 ซึ่งค่านี้สามารถบอกได้ถึงลักษณะการเปลี่ยนโทนสีในแนวทางเดียวกันของภาพ (Homogeneity) โดยหากภาพประกอบด้วยจุดภาพที่มีโทนสีเหมือนกันแล้ว จะทำให้ความน่าจะเป็นที่มีค่าสูงไปรวมตัวกันในช่อง (i, j) ใน GLCM ทำให้ค่า $p(i, j)$ มีค่ามาก ส่งผลให้ค่า ASM มีค่ามากตามไปเช่นกัน ดังนั้นจึงเรียกค่า ASM ได้อีกอย่างหนึ่งว่าค่าพลังงาน (Energy)

$$f_1 = \sum_i \sum_j \{p(i, j)\}^2 \quad (2.7)$$

ค่าความต่าง(Contrast)

ค่าความต่าง(Contrast) หรือ f_2 เป็นค่าที่แสดงความต่างระดับสีของจุดภาพใกล้เคียงทั้งหมดในภาพ โดยกลุ่มภาพที่มีความต่างของระดับสีมากก็จะทำให้ค่าความต่างนี้มากขึ้นด้วย การหาค่าความต่าง แสดงดังสมการที่ 2.8

$$f_2 = \sum_{n=0}^{Ng-1} n^2 \left\{ \sum_{i=1}^{Ng} \sum_{j=1}^{Ng} p(i, j) \right\} \quad (2.8)$$

$$n = |i-j|$$

Ng คือ จำนวนของระดับเทาทั้งหมด

ค่าสหสัมพันธ์ (Correlation)

ค่าสหสัมพันธ์ (Correlation) หรือ f_3 เป็นการวิเคราะห์การขึ้นต่อกันแบบเชิงเส้น (Linear Dependency) ของระดับสีเทาระหว่างจุดภาพใกล้เคียงต่างๆ ในภาพ โดยภาพที่ประกอบด้วยวัตถุเดี่ยวๆ ที่ไม่อยู่ติดกันแล้วมักจะมีค่าสหสัมพันธ์ภายในวัตถุสูงกว่าในกรณีที่มีวัตถุที่อยู่ติดกัน แสดงดังสมการที่ 2.9

$$f_3 = \frac{\sum_{i=1}^{Ng-1} \sum_{j=1}^{Ng-1} (ij)p(i, j) - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (2.9)$$

μ_x คือ ค่าเฉลี่ยของ $p(i, j)$ ที่อยู่ในแถว i

μ_y คือ ค่าเฉลี่ยของ $p(i, j)$ ที่อยู่ในคอลัมน์ j

σ_x คือ ค่าเบี่ยงเบนมาตรฐานของ $p(i, j)$ ที่อยู่ในแถว i

σ_y คือ ค่าเบี่ยงเบนมาตรฐานของ $p(i, j)$ ที่อยู่ในคอลัมน์ j

N_g คือ จำนวนของระดับเทาทั้งหมด

ค่าเอนโทรปี (Entropy)

ค่าเอนโทรปี (Entropy) หรือ f_4 คือ ค่าวัดเชิงปริมาณความขรุขระของพื้นผิว (Texture Complexity) หากภาพมีพื้นผิวที่ขรุขระมากก็จะให้ค่าเอนโทรปีสูง แสดงดังสมการที่ 2.10

$$f_4 = -\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i, j) \log(p(i, j)) \quad (2.10)$$

N_g คือ จำนวนของระดับเทาทั้งหมด

คุณสมบัติของพื้นผิวอื่นๆที่เหลือต่อไปนี้เป็นสมการที่สืบทอดมาจากคุณสมบัติที่ได้กล่าวมาข้างต้น ได้แก่

ค่าความแปรปรวน (Variance)

ผลรวมกำลังสองของค่าความแปรปรวน หรือ f_5 (Variance) แสดงดังสมการที่ 2.11

$$f_5 = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (i - \mu)^2 p(i, j) \quad (2.11)$$

โดยที่

N_g คือ จำนวนของระดับเทาทั้งหมด

μ คือ ค่าเฉลี่ยของ $p(i, j)$

ค่าผั้กลับของผลต่างโมเมนต์ (Inverse Difference Moment)

ค่าผั้กลับของผลต่างโมเมนต์ (Inverse Difference Moment) หรือ f_6 แสดงดังสมการที่ 2.12

$$f_6 = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} \frac{1}{1 + (i - j)^2} p(i, j) \quad (2.12)$$

โดยที่

N_g คือ จำนวนของระดับเทาทั้งหมด

ค่าผลรวมเฉลี่ย (Sum Average)

ค่าผลรวมเฉลี่ย (Sum Average) หรือ f_7 แสดงดังสมการที่ 2.13

$$f_7 = \sum_{i=2}^{2N_g} i p_{x+y}(i) \quad (2.13)$$

โดยที่

N_g คือ จำนวนของระดับเทาทั้งหมด

$$p_{x+y}(k) = \sum_{i=1, i \neq k}^{N_g} \sum_{j=1}^{N_g} p(i, j), k = 2, 3, \dots, 2N_g$$

ค่าผลรวมของค่าความแปรปรวน (Sum Variance)

ค่าผลรวมของค่าความแปรปรวน (Sum Variance) หรือ f_8 แสดงดังสมการที่ 2.14

$$f_8 = \sum_{i=2}^{2N_g} (i - f_9)^2 p_{x+y}(i) \quad (2.14)$$

โดยที่

N_g คือ จำนวนของระดับเทาทั้งหมด

$$p_{x+y}(k) = \sum_{i=1, i \neq k}^{N_g} \sum_{j=1}^{N_g} p(i, j), k = 2, 3, \dots, 2N_g$$

ค่าผลรวมของเอนโทรปี (Sum Entropy)

ค่าผลรวมของเอนโทรปี (Sum Entropy) หรือ f_9 แสดงดังสมการที่ 2.15

$$f_9 = - \sum_{i=2}^{2N_g} p_{x+y}(i) \log \{ p_{x+y}(i) \} \quad (2.15)$$

โดยที่

N_g คือ จำนวนของระดับเทาทั้งหมด

$$p_{x+y}(k) = \sum_{i=1, i \neq k}^{N_g} \sum_{j=1}^{N_g} p(i, j), k = 2, 3, \dots, 2N_g$$

ผลต่างของความแปรปรวน (Difference Variance)

ผลต่างของความแปรปรวน (Difference Variance) หรือ f_{10} แสดงดังสมการที่ 2.16

$$f_{10} = \text{Variance of } p_{x-y} \quad (2.16)$$

โดยที่

N_g คือ จำนวนของระดับเทาทั้งหมด

$$p_{x-y}(k) = \sum_{i=1, i \neq k}^{N_g} \sum_{j=1}^{N_g} p(i, j), k = 0, 1, \dots, N_g - 1$$

ผลต่างของเอนโทรปี (Difference Entropy)

ผลต่างของเอนโทรปี (Difference Entropy) หรือ f_{11} แสดงดังสมการที่ 2.17

$$f_{11} = -\sum_{i=0}^{Ng-1} p_{x-y}(i) \log\{p_{x-y}(i)\} \quad (2.17)$$

โดยที่

Ng คือ จำนวนของระดับเทาทั้งหมด

$$p_{x-y}(k) = \sum_{i=1-k}^{Ng} \sum_{j=1}^{Ng} p(i, j), k = 0, 1, \dots, Ng - 1$$

การวัดสหสัมพันธ์ (Information Measures of Correlation)

การวัดสหสัมพันธ์ (Information Measures of Correlation) หรือ f_{12} และ f_{13} แสดงดังสมการที่ 2.18 และ 2.19

$$f_{12} = \frac{HXY - HXY1}{\max\{HX, HY\}} \quad (2.18)$$

$$f_{13} = (1 - \exp[-2.0(HXY2 - HXY)])^{1/2} \quad (2.19)$$

โดยที่

HX = Entropy of p_x

HY = Entropy of p_y

$$HXY = -\sum_i \sum_j p(i, j) \log(p(i, j))$$

$$HXY1 = -\sum_i \sum_j p(i, j) \log\{p_x(i)p_y(j)\}$$


$$HXY2 = -\sum_i \sum_j p_x(i)p_y(j) \log\{p_x(i)p_y(j)\}$$

$p_x(i)$ คือ ค่าความน่าจะเป็นของเหตุการณ์ที่คำนวณได้จากผลรวมของ $p(i, j)$ ในทุกคอลัมน์ของแถว i

$p_y(j)$ คือค่าความน่าจะเป็นของเหตุการณ์ที่คำนวณได้จากผลรวมของ $p(i, j)$ ในทุกแถวของคอลัมน์ j

2.7 ข่ายงานประสาทเทียม

ข่ายงานประสาทเทียมเป็นการจำลองการทำงานบางส่วนของสมองมนุษย์ ที่เป็นเซลล์ประสาทเชื่อมโยงกันหลายๆ เซลล์ เมื่อเซลล์ได้รับสัญญาณไฟฟ้าเคมี เซลล์ก็จะถูกกระตุ้นและส่งสัญญาณไปยังเซลล์อื่นๆ ข่ายงานประสาทเทียมได้จำลองการทำงานเหล่านี้ โดยมีโนดที่เป็นข้อมูลเข้า (Input Node) โนดซ่อน (Hidden Node) และโนดที่เป็นข้อมูลออก (Output Node) ลักษณะของข่ายงานแสดงดังรูปที่ 2.12



รูปที่ 2.12 ตัวอย่างของโครงสร้างข่ายงานประสาทเทียม

ข่ายงานดังรูปที่ 2.12 จะประกอบไปด้วยชั้นนำเข้าซึ่งเป็นข้อมูลเข้า ชั้นซ่อน และชั้นนำออก โดยที่ชั้นซ่อนอาจจะมีมากกว่า 1 ชั้นก็ได้ เส้นเชื่อมที่เห็นดังรูปจะเชื่อมต่อกันเป็นชั้นๆ

การเรียนรู้แบบย้อนกลับเป็นวิธีการหนึ่งของข่ายงานประสาทเทียม ซึ่งกระบวนการเรียนรู้และปรับปรุงแก้ไขจะเป็นไปโดยอัตโนมัติ ถ้าข่ายงานให้คำตอบที่ผิด ค่าน้ำหนักก็จะถูกปรับจนกว่าค่าความผิดพลาดจะลดลง หรืออยู่ในเกณฑ์ที่ยอมรับได้ จากโครงสร้างของข่ายงานข้างต้น เมื่อข่ายงานได้รับข้อมูลนำเข้าก็จะคำนวณค่าน้ำหนักจากโนดข้อมูลเข้าไปยังแต่ละโนดของชั้นซ่อน และคำนวณน้ำหนักจากโนดในชั้นซ่อนไปยังโนดที่เป็นผลลัพธ์ เมื่อคำนวณค่าน้ำหนักถึงโนดที่เป็นชั้นนำออกแล้วก็จะได้ผลลัพธ์ ทำการเปรียบเทียบผลลัพธ์ที่ได้กับค่าจริงจะได้ค่าความต่างระหว่างผลลัพธ์ แล้วข่ายงานจะพยายามปรับค่าความผิดพลาดจากชั้นนำออกและแพร่ย้อนกลับไปยังชั้นซ่อนและชั้นนำเข้าต่อไป

ในการปรับค่าเวกเตอร์น้ำหนักโดยขั้นตอนวิธีแบบการเรียนรู้ย้อนกลับ (Backpropogation) นั้น มีการนิยามค่าผิดพลาดการฝึก หรือ $E(\vec{w})$ แล้วจากนั้นจะหาค่าเวกเตอร์น้ำหนักที่ให้ค่าผิดพลาดต่ำสุด นิยามค่าผิดพลาดดังสมการที่ 2.20

$$E(\vec{w}) = \frac{1}{2} \sum_{d \in D} \sum_{k \in \text{Outputs}} (t_{kd} - o_{kd})^2 \quad (2.20)$$

เมื่อ	outputs	คือ เซตของโนดนำออกในข่ายงาน
	t_{kd}	คือ ค่าผลลัพธ์เป้าหมาย
	o_{kd}	คือ ค่าผลลัพธ์ที่ได้จากข่ายงาน
	D	คือ จำนวนตัวอย่าง

ขั้นตอนวิธีสำหรับข่ายงานประสาทเทียมแบบการเรียนรู้ย้อนกลับ [11] แสดงดังรูปที่ 2.13

For each training example, Do

1. Input the training example to the network and compute the network outputs

2. For each output unit k

$$\delta_k \leftarrow o_k (1 - o_k) (t_k - o_k)$$

3. For each hidden unit h

$$\delta_h \leftarrow o_h (1 - o_h) \sum_{k \in \text{Outputs}} w_{h,k} \delta_k$$

4. Update each network weight $w_{i,j}$

$$w_{i,j} \leftarrow w_{i,j} + \Delta w_{i,j}$$

where

$$\Delta w_{i,j} = \eta \delta_j x_{i,j}$$

รูปที่ 2.13 ขั้นตอนวิธีของการเรียนรู้ย้อนกลับ

2.8 งานวิจัยที่เกี่ยวข้อง

งานวิจัยจำนวนมากในหลายปีที่ผ่านมาได้ใช้วิธีประมวลผลภาพโดยใช้ข้อมูลภาพถ่ายจากการรับรู้ระยะไกล (Remote Sensing) เช่น Strozzi และคณะ [12] ได้เสนอการตรวจหาการใช้ประโยชน์ที่ดิน และพื้นที่ป่าในทวีปยุโรปโดยใช้ ERS SAR Interferometry ซึ่งเป็นข้อมูลภาพที่ได้จากดาวเทียม โดยภาพที่ได้จะมีการสกัดพีเจอร้อออกมา 4 อย่างคือ ค่าการประมาณค่าของการเชื่อมโยงกัน (Estimation Of Coherence), ค่าความหนาแน่นการกระจัดกระจายกลับ (Backscattering Intensity), ค่าความแปรปรวนชั่วคราวของความหนาแน่นการกระจัดกระจายกลับ (Temporal Variability Of The Backscattering Intensity), และค่าพื้นผิวของความหนาแน่นการกระจัดกระจายกลับ (Texture of The Backscattering Intensity) จากนั้นแบ่งประเภทการใช้ประโยชน์ที่ดินด้วยวิธีการต่างๆ ได้แก่ การใช้ผังขีดแบ่ง (The Threshold Scheme) , การจัดหมวดหมู่หน้าจะเป็นสูงสุด (The Maximum-likelihood Classification) และ การจัดกลุ่มแบบคลุมเคลือ (Fuzzy Clustering Segmentation) ซึ่งงานวิจัยนี้ให้แบ่งประเภทของการใช้ประโยชน์ที่ดินได้ถูกต้อง 75 % ต่อมา Sarkar และคณะ [13] ได้ใช้ภาพ Mutispectral Image ซึ่งเป็นภาพถ่ายจากดาวเทียมโดยใช้แหล่งกำเนิดพลังงานที่ความยาวคลื่น (Wave Length) แตกต่างกัน ซึ่งจะมีพื้นผิว (Texture) ที่ต่างกัน จากนั้นนำพีเจอร้อที่แตกต่างกันนี้มาแบ่งประเภทการใช้ประโยชน์ที่ดินด้วยเขตข้อมูลสุ่มแบบมาคอฟ (Markov Random Field) นอกจากนี้ก็มีการใช้ประโยชน์จากภาพถ่ายการรับรู้ระยะไกลอย่างกว้างขวาง เช่น Jia และคณะ [14] ใช้ภาพถ่ายจากการรับรู้ระยะไกลในการตรวจหาไร่ข้าวโพด Xiaohe และคณะ [15] ใช้ภาพถ่ายจากการรับรู้ระยะไกลในการตรวจหาพื้นที่การเกษตร เป็นต้น

งานวิจัยที่ใช้เทคโนโลยีการประมวลผลภาพดิจิทัลมาใช้ในการเกษตร ก็มีการใช้อย่างกว้างขวางเช่น Woebbecke และคณะ [7] ได้เสนอวิธีการสกัดสีเขียวของพืชที่เรียกว่า Excess Green ที่ใช้รูปแบบสี RGB แปลงเป็นภาพระดับเทาด้วยสมการ $ExG = 2g-r-b$ โดยที่ r คือองค์ประกอบสีแดง g คือ องค์ประกอบสีเขียว และ b คือ องค์ประกอบสีน้ำเงิน ซึ่งการสกัดด้วยวิธีนี้จะใช้ได้ทั้งภาพที่มีแสงมากหรือแสงน้อยก็ได้ Hemming และ Rath [16] เสนอวิธีการระบุส่วนที่เป็นวัชพืชในรูปภาพโดยใช้วิธีการ morphological และคุณสมบัติทางสีในการหาพีเจอร้อ เพื่อใช้ในการจำแนกระหว่างพืชและวัชพืช Philipp และ Rath [17] ได้วิเคราะห์ความแตกต่างของพืชโดยใช้ Color space แบบต่างๆกัน ได้แก่ HIS HSV LAB และ $i_1i_2i_3$ ซึ่งสรุปว่า $i_1i_2i_3$ จะใช้ในการวิเคราะห์ความแตกต่างของพืชได้ดีที่สุด Sogaard และ Olsen [18] เสนอวิธีการหาแถวของพืชที่ปลูกเป็นแถวโดยสกัดค่าสีเอ็กเซสกรีน (Excess Green) แล้วหาแถวของพืชด้วยการหาจุดศูนย์ของแรงโน้มถ่วง (Centres of Gravity) ของแต่ละแถว Lee และคณะ [19] ได้ใช้หุ่นยนต์ในการควบคุมวัชพืชในแปลงมะเขือเทศ โดยหุ่นยนต์จะทำการกำจัดวัชพืชและพืชขนาดเล็กที่ไม่ใช่มะเขือเทศทิ้งไปโดยการแยกส่วน (Segment) ของภาพที่ใช้โมเดลภาพแบบ HSI ด้วยกฎของเบย์ในการสร้าง Color Lookup Table จากนั้นสกัดพีเจอร้อออกมา ซึ่งได้แก่ Length Ratio, Compactness, Elongation และ Ratio Of Length To Perimeter แล้วนำมาจำแนกประเภทด้วย Bayesian Classifier ต่อมา Burks และคณะ [20] ได้เสนอการจำแนกชนิดของวัชพืชโดยใช้ Color Co-Occurrence เพื่อแยกความต่างระหว่างวัชพืชที่มีขนาดและรูปร่างของใบที่แตกต่างกันโดยใช้ภาพสีรูปแบบ HSI ในการวิเคราะห์ Meyer และคณะ [21] ได้เสนอวิธีการ

จำแนกพืช พื้นดิน และส่วนที่เหลือของรูปภาพโดยใช้วิธีการตรวจจับการคลุมเครือของสี (Fuzzy color index) และการจัดกลุ่ม(Clustering) ซึ่งเป็นการเรียนรู้โดยไม่มีการสอน สำหรับการเรียนรู้โดยมีการสอน Guerrero และคณะ [22] ได้เสนอวิธีการแยกความแตกต่างระหว่างพืชกับวัชพืชจากภาพในไร่ข้าวโพดโดยใช้ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machines) Gee และคณะ [23] ได้เสนอวิธีการแยกความแตกต่างระหว่างพืชกับวัชพืชจากภาพการเกษตร โดยภาพของพืชเป็นพืชที่ปลูกแบบเป็นแถว และมีคุณสมบัติสมมาตร มีการใช้เทคนิคการแปลงฮัฟ (Hough Transform) ในการหาแถวของพืชที่ปลูกในแปลง ในปีถัดมา Bossu และคณะ [24] ได้ใช้ปรับปรุงวิธีดังกล่าวโดยใช้การแปลงเวฟเลต (Wavelet transform) เข้ามาช่วยเพื่อแยกความแตกต่างได้แม่นยำยิ่งขึ้น

ในงานวิจัยนี้จะใช้วิธีการหาค่าดัชนีความเขียว (Greenness Index) ในการตัดแยก (Segmentation) ภาพเพื่อสกัดเอาเฉพาะพื้นที่สีเขียวของพืช จากนั้นจะทำการสกัดฟีเจอร์ (Feature Extraction) ซึ่งได้แก่ฟีเจอร์เชิงสี ฟีเจอร์เชิงสี ฟีเจอร์เชิงตำแหน่ง และฟีเจอร์เชิงพื้นผิว นำมาฝึกในข่ายงานประสาทเทียมเพื่อแยกความแตกต่างระหว่างส่วนที่เป็นนาข้าวกับส่วนที่ไม่เป็นนาข้าว และใช้อัลกอริทึมฟังก์ชันในยืนยันภาพว่าเป็นภาพนาข้าวหรือไม่ โดยภาพที่ใช้จะเป็นใช้ภาพถ่ายภาคพื้นดิน

บทที่ 3

แนวคิดและวิธีดำเนินงาน

งานวิจัยนี้ได้เสนอวิธีการตรวจหาบริเวณนาข้าวจากภาพถ่ายภาคพื้นดินในประเทศไทย โดยใช้ภาพถ่ายจาก Google Street View [2] ด้วยการนำ Google Street View API [25] .ในการดึงรูปภาพแบบสุ่มจากจังหวัดที่มีการถ่ายภาพจากรถสำรวจแล้วในประเทศไทยโดยใช้ค่าพารามิเตอร์มาตรฐานซึ่งได้แก่ ค่า Field of View เท่ากับ 90 และ ค่า Pitch เท่ากับ 0 ภาพที่ได้จะเป็นภาพสี่ที่มีความละเอียด 640x600 pixels ดังรูปที่ 3.1 โดยภาพถ่ายจาก Google Street View จะมีการควบคุมปริมาณแสงในการสำรวจอยู่แล้ว ในงานวิจัยนี้จึงไม่ได้มีวิธีการจัดการเกี่ยวกับแสงเข้ามาเกี่ยวข้อง



รูปที่ 3.1 ตัวอย่างภาพที่ได้จาก Google Street View

งานวิจัยนี้จะตรวจสอบว่าภาพนี้เป็นภาพนาข้าวหรือไม่ วิธีการเสนอนี้จะไม่สามารถตรวจหา นาข้าวในระยะต้นกล้าได้ ดังรูปที่ 3.2 (ก) เนื่องจากวิธีการที่เสนอจะใช้พื้นฐานของการหาส่วนของสีเขียวและสีเหลืองของพืช ซึ่งในระยะต้นกล้ายังไม่มีการเจริญเติบโตในส่วนของใบพืชหรือมีแต่ยังไม่ มากพอที่จะสามารถตรวจหาได้ ภาพนาข้าวที่สามารถตรวจหาได้นั้นจะอยู่ในระยะต่างๆ ได้แก่

ระยะแตกกอ ดังรูปที่ 3.2 (ข) ระยะเจริญเติบโตทางด้านการสืบพันธุ์ดังรูปที่ 3.2 (ค) และระยะเก็บเกี่ยว ดังรูปที่ 3.2 (ง)



(ก)



(ข)



(ค)



(ง)



(จ)



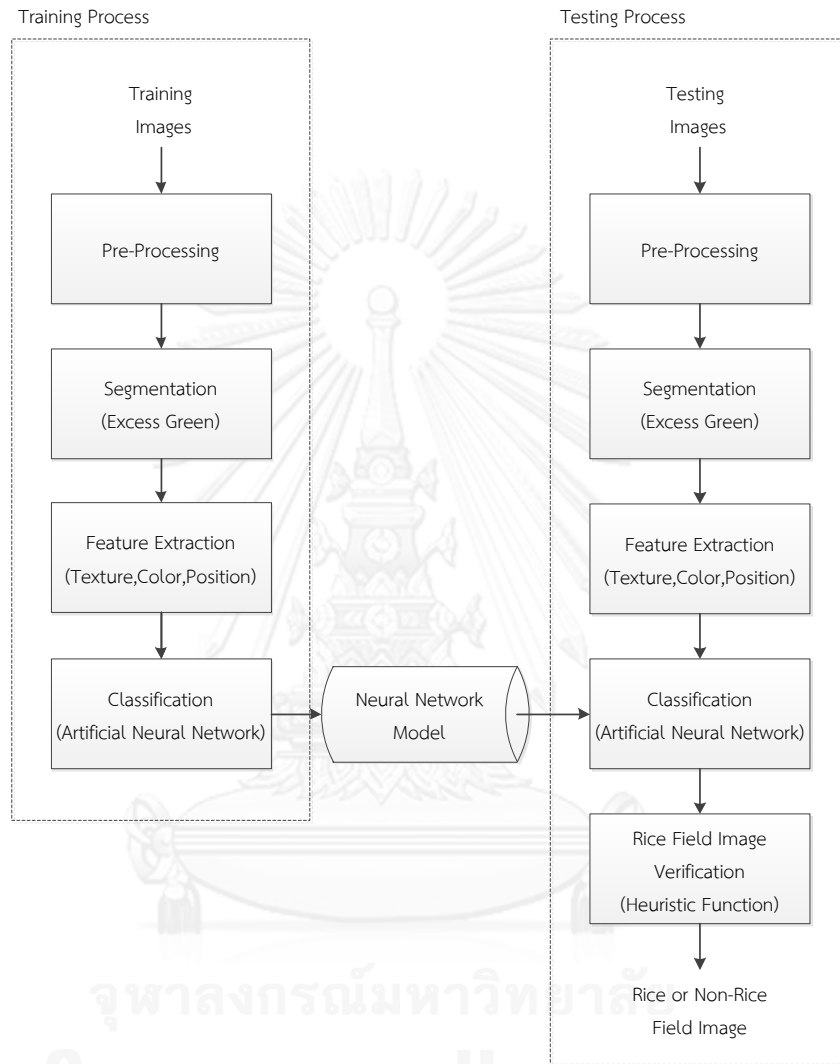
(ฉ)

รูปที่ 3.2 ตัวอย่างภาพที่ใช้ในงานวิจัย

(ก) - (ง) ภาพนาข้าวในระยะต่างๆ (จ) - (ฉ) ภาพไม้ไผ่ในนาข้าว

3.1 การทำงานของระบบ


ขั้นตอนวิธีในการตรวจหาบริเวณที่เป็นนาข้าวจากภาพถ่ายภาคพื้นดินสามารถแสดงได้ดังผังงานรูปที่ 3.3



รูปที่ 3.3 ผังงานแสดงขั้นตอนวิธีของวิธีการที่เสนอ

3.2 การเตรียมข้อมูลก่อนการประมวลผล

ในขั้นตอนนี้จะนำภาพตั้งต้นมาแบ่งเป็นเซกเมนต์(Segment) เพื่อที่จะใช้ในขั้นตอนอื่นๆ ถัดไป โดยเซกเมนต์นั้นต้องมีขนาดที่เหมาะสม ไม่มีขนาดเล็กหรือใหญ่จนเกินไป ถ้าภาพที่มีขนาดของเซกเมนต์ใหญ่เกินไปดังรูปที่ 3.4 (ก) ก็จะทำให้รายละเอียดของเซกเมนต์นั้นประกอบด้วยหลายวัตถุในเซกเมนต์นั้นๆ ซึ่งทำให้สูญเสียพื้นที่ที่สนใจ (นาข้าว) ไปจำนวนมาก แต่เมื่อเซกเมนต์มีขนาดเล็กจนเกินไปก็จะทำให้เซกเมนต์นั้นมีรายละเอียดของพื้นผิวไม่เพียงพอดังรูปที่ 3.4 (ข) การเลือกขนาดของเซกเมนต์ที่เหมาะสมจะกล่าวในบทที่ 4



(ก)

(ข)

รูปที่ 3.4 ตัวอย่างการแบ่งรูปภาพด้วยขนาดที่แตกต่างกัน

(ก) ภาพที่มีเซกเมนต์ขนาดใหญ่เกินไป (ข) ภาพที่มีเซกเมนต์ขนาดเล็กเกินไป

3.3 การตัดแยกเพื่อเอาค่าเอ็กเซสกรีน

ในขั้นตอนนี้จะนำภาพมาทำการตัดแยก (Segmentation) ส่วนสีเขียวจากภาพสีให้เป็นภาพภาพระดับเทา ด้วยการหาตรรกษณ์ความเขียว (Greenness Index) โดยใช้วิธีการของ Woebbeck [7] ในการหาค่าเอ็กเซสกรีน (Excess Green) ซึ่งเหมาะกับการใช้กับภาพถ่ายที่ถ่ายโดยไม่มีเงาของแสงเข้ามาเกี่ยวข้อง สมการการในหาค่าเอ็กเซสกรีน แสดงดังสมการที่ 3.1 และแปลงเป็นภาพระดับเทาตั้งใช้สมการที่ 3.2 จะได้ภาพระดับเทาที่มีค่า 256 ค่า


$$ExG = 2g - r - b \quad (3.1)$$

$$GrayLevel = 255 \times \frac{ExG - ExG_{min}}{ExG_{max} - ExG_{min}} \quad (3.2)$$

ภาพตั้งต้นก่อนการแปลงเป็นภาพเอ็กเซสกรีน แสดงดังรูปที่ 3.5 (ก) เมื่อผ่านการแปลงเป็นภาพเอ็กเซสกรีนแล้ว จะได้ภาพระดับเทาที่แสดงส่วนของสีเขียวดังรูปที่ 3.5 (ข) โดยถ้าบริเวณไหนที่มีค่าสีเขียวมากภาพระดับเทาก็จะแสดงบริเวณนั้นไปเป็นโทนสีขาว ส่วนบริเวณไหนที่มีมีส่วนของสีเขียวน้อยหรือไม่มีส่วนของสีเขียวเลย ภาพระดับเทาก็จะแสดงบริเวณนั้นเป็นโทนสีดำ



(ก)



(ข)

รูปที่ 3.5 การนำภาพตั้งต้นมาแปลงเป็นภาพเอ็กเซสกรีน
(ก) ภาพตั้งต้น (ข) ภาพที่ทำการแปลงเป็นภาพเอ็กเซสกรีน

3.4 การสกัดฟีเจอร์

ในขั้นตอนนี้จะนำแต่ละเซกเมนต์ของรูปภาพที่ได้ทำการแบ่งและตัดแยก (Segmentation) มาแล้ว นำมาสกัดฟีเจอร์ต่างๆ (Feature Extraction) ซึ่งประกอบด้วย ฟีเจอร์เชิงสี ฟีเจอร์เชิงตำแหน่ง และฟีเจอร์เชิงพื้นผิว โดยขั้นตอนนี้จะใช้โปรแกรมที่พัฒนาขึ้นเพื่อใช้ในการเก็บฟีเจอร์ของแต่ละเซกเมนต์เพื่อใช้ในการฝึก รายละเอียดการใช้โปรแกรมอยู่ในภาคผนวก ข โปรแกรมนี้จะแสดงฟีเจอร์ทั้งหมดของเซกเมนต์ที่ถูกเลือกดังรูปที่ 3.6

Name	Energy	Correlation	Sum of Variances	Inverse Difference Moment	Entropy	HXY1
*						

Energy: 0.440582
 Correlation: 204.11450, 248.1118
 Sum of Variances: 37665.825659
 Inverse Difference Moment: 0.855113
 Entropy: 1.673552
 HXY1: -0.663486
 HXY2: 0.903460
 Sum Average: 388.094737
 Sum Entropy: 1.577094
 Sum Variance: 149526.679348
 Difference Variance: 0.002768
 Contrast: 6.126316
 Difference Entropy: 0.667582
 Mean: ExG: 192.880000
 Y Index: 19
 X Index: 15

รูปที่ 3.6 ส่วนติดต่อกับผู้ใช้งานของโปรแกรมที่ใช้สำหรับเก็บตัวอย่างในการฝึก

3.4.1 การสกัดพีเจอร์เชิงสี

การสกัดพีเจอร์เชิงสีจะหาได้จากค่าเฉลี่ยของค่าเอ็กเซสกรีน ในเซกเมนต์นั้นๆ ซึ่งค่านี้จะบ่งบอกได้ว่าในเซกเมนต์นั้นมีความเขียวมากหรือน้อยเพียงใด โดยการหาค่าเฉลี่ยของค่าเอ็กเซสกรีนแสดงดังสมการที่ 3.3


$$\text{MeanExG} = \frac{\sum_{i=0}^{m-1} \sum_{j=0}^{n-1} \text{ExG}(i, j)}{mn} \quad (3.3)$$

เมื่อ

ExG	คือ ค่าเอ็กเซสกรีน ในแต่ละจุดภาพ
MeanExG	คือ ค่าเฉลี่ยของค่าเอ็กเซสกรีน ในเซกเมนต์
m	คือ ความยาวของเซกเมนต์
n	คือ ความกว้างของเซกเมนต์

3.4.2 การสกัดพีเจอร์เชิงตำแหน่ง

การสกัดพีเจอร์เชิงจะใช้ตำแหน่งของเซกเมนต์ในแนวตั้งเป็นพีเจอร์ เพื่อใช้เป็นตัวบอกว่าข้าวอยู่บริเวณใด เพราะตำแหน่งที่เป็นนาข้าวส่วนใหญ่จะอยู่บริเวณประมาณกลางภาพของแนวตั้งมากกว่าบริเวณขอบภาพของแนวตั้ง ตัวอย่างพีเจอร์เชิงตำแหน่งที่เป็นนาข้าวดังรูปที่ 3.7 จะอยู่ระหว่าง 15-19



รูปที่ 3.7 ตำแหน่งของเซกเมนต์ของนาข้าวในแนวแกนตั้ง

3.4.3 การสกัดพีเจอร์เชิงพื้นผิว

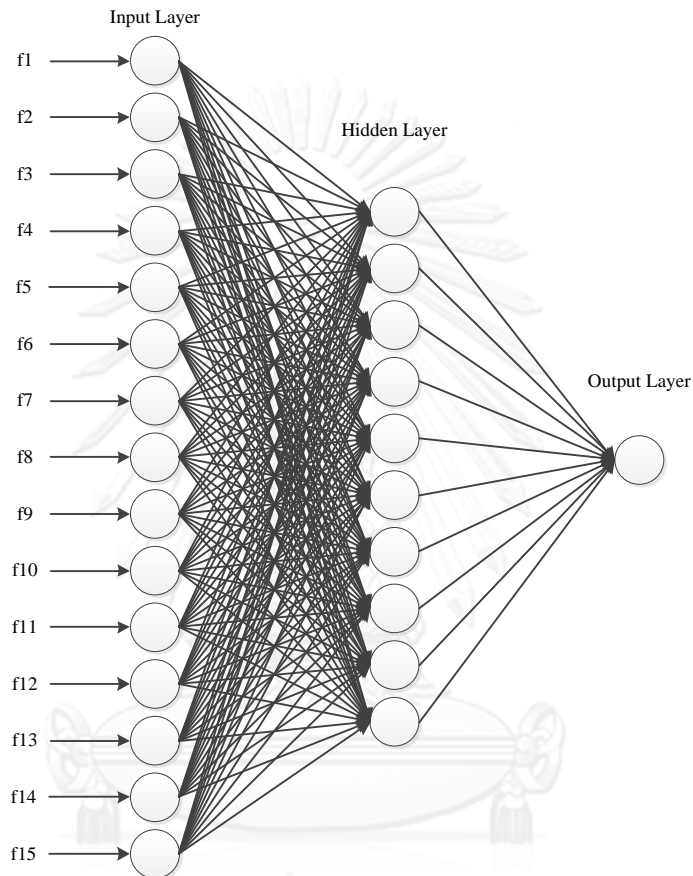
การสกัดพีเจอร์เชิงพื้นผิวนี้ ในแต่ละเซกเมนต์จะถูกนำมาคำนวณหาพีเจอร์เชิงพื้นผิว ซึ่งการหาพีเจอร์เชิงพื้นผิวจะใช้พีเจอร์ที่เสนอโดยของ Haralick [10] ซึ่งเป็นการหาพีเจอร์เชิงพื้นผิวของภาพที่นิยมใช้กันอย่างกว้างขวางประกอบด้วย 13 พีเจอร์ การคำนวณพีเจอร์ทั้ง 13 นี้แสดงดังตารางที่ 3.1

ตารางที่ 3.1 ตารางแสดงชื่อคุณสมบัติและสมการในการหาพีเจอร์เชิงพื้นผิวทั้งหมด

คุณสมบัติ	สมการ
Angular Second Moment	$f_1 = \sum_i \sum_j \{p(i, j)\}^2$
Contrast	$f_2 = \sum_{n=0}^{Ng-1} n^2 \left\{ \sum_{i=1}^{Ng} \sum_{j=1}^{Ng} p(i, j) \right\}; i-j =n$
Correlation	$f_3 = \frac{\sum_{i=1}^{Ng-1} \sum_{j=1}^{Ng-1} (ij)p(i, j) - \mu_x \mu_y}{\sigma_x \sigma_y}$
Variance	$f_4 = \sum_{i=1}^{Ng} \sum_{j=1}^{Ng} (i - \mu)^2 p(i, j)$
Inverse Difference Moment	$f_5 = \sum_{i=1}^{Ng} \sum_{j=1}^{Ng} \frac{1}{1 + (i - j)^2} p(i, j)$
Sum Average	$f_6 = \sum_{i=2}^{2Ng} i p_{x+y}(i)$
Sum Variance	$f_7 = \sum_{i=2}^{2Ng} (i - f_6)^2 p_{x+y}(i)$
Sum Entropy	$f_8 = -\sum_{i=2}^{2Ng} p_{x+y}(i) \log \{p_{x+y}(i)\}$
Entropy	$f_9 = -\sum_{i=1}^{Ng} \sum_{j=1}^{Ng} p(i, j) \log(p(i, j))$
Difference Variance	$f_{10} = \text{Variance of } p_{x-y}$
Difference Entropy	$f_{11} = -\sum_{i=0}^{Ng-1} p_{x-y}(i) \log \{p_{x-y}(i)\}$
Information Measures of Correlation 1	$f_{12} = \frac{HXY - HXY1}{\max \{HX, HY\}}$
Information Measures of Correlation 2	$f_{13} = (1 - \exp[-2.0(HXY2 - HXY)])^{1/2}$

3.5 การจำแนกข้อมูลโดยใช้ข่ายงานประสาทเทียม

การฝึกข้อมูลโดยใช้ข่ายงานประสาทเทียมจะใช้พีเจอร์ทั้งหมด 15 พีเจอร์ในแต่ละเซกเมนต์ที่ได้จากการเล็อกว่าเซกเมนต์ใดเป็นนาข้าวหรือไม่เป็นนาข้าว ดังนั้นข่ายงานประสาทเทียมจะประกอบด้วยโนดนำเข้า 15 โนดตามจำนวนของพีเจอร์ และมีโนดผลลัพธ์เพียง 1 โนด เพื่อแสดงผลลัพธ์ว่าเป็นเซกเมนต์ของนาข้าวหรือไม่ ดังรูปที่ 3.8



รูปที่ 3.8 โครงสร้างของข่ายงานประสาทเทียมที่ใช้ในงานวิจัยนี้

ข้อมูลตัวอย่างของเซกเมนต์ที่ถูกเลือกเพื่อที่จะใช้ในการฝึกในข่ายงานประสาทเทียมจะถูกเก็บไว้ในฐานข้อมูลของโปรแกรมที่ใช้เก็บตัวอย่างในการฝึก ดังรูปที่ 3.9

	Energy	Correlation	Sum of Variances	Inverse Difference Moment	Entropy	HXY1	HXY2
▶	0.542105	11976500.451164	26939.826573	0.909316	1.250774	-0.678164	0.872874
	0.142285	47532532.119634	31470.899854	0.871970	2.186176	-0.806097	0.973988
	0.154792	52121722.102784	32750.057639	0.940445	2.114307	-0.913944	0.985693
	0.278089	26560450.970106	36759.004679	0.767430	2.096736	-0.571436	0.909911
	0.211371	34673618.800267	34911.257457	0.844246	2.103997	-0.685444	0.944549
	0.068837	90109615.314598	38988.509769	0.719768	3.120051	-0.623662	0.970186
	0.098324	90619094.070978	50211.782638	0.739489	2.746754	-0.676767	0.970515
	0.163906	51062878.422580	44067.667283	0.847023	2.157698	-0.704284	0.951371
<	0.226929	34082476.637362	39241.530792	0.752798	1.951215	-0.604917	0.947993

รูปที่ 3.9 ตัวอย่างของฐานข้อมูลที่ใช้เก็บข้อมูลในการฝึกข่ายงานประสาทเทียม

3.6 การยืนยันภาพนาข้าว

เนื่องจากการจำแนกข้อมูลในขั้นตอนที่ใช้ข่ายงานประสาทเทียมจะมีการจำแนกข้อมูลผิดพลาดอยู่บ้าง เช่น จำแนกเซกเมนต์ที่ไม่ใช่ข้าวว่าเป็นนาข้าว ดังนั้นในขั้นตอนนี้จะเป็นการยืนยันว่าภาพนี้เป็นภาพนาข้าวหรือไม่ โดยใช้ฮิวริสติกฟังก์ชันเข้ามาช่วยในการดูว่าการเชื่อมต่อของเซกเมนต์ในภาพเป็นอย่างไร โดยฮิวริสติกฟังก์ชันแสดงดังสมการที่ 3.4


$$\text{Heuristic Value} = \frac{S}{C} \quad (3.4)$$

โดยที่

S คือ จำนวนเซกเมนต์ที่ถูกระบายทั้งหมด (เซกเมนต์ที่ถูกจำแนกเป็นนาข้าว)

C คือ จำนวนเซกเมนต์ที่มีการเชื่อมติดกันทั้งหมด

รูปที่ 3.10 แสดงตัวอย่างของภาพสองภาพที่ผ่านการจำแนกข้อมูลด้วยข่ายงานประสาทเทียม โดยรูปที่ 3.10 (ก) แสดงภาพที่มีการกระจายของเซกเมนต์ที่ถูกระบาย ซึ่งมีค่า S เท่ากับ 12 และค่า C เท่ากับ 9 ดังนั้นฮิวริสติกของรูปที่ 3.10 (ก) จะมีค่าเท่ากับ 1.33 ส่วนรูปที่ 3.10 (ข) แสดงภาพที่มีการเชื่อมต่อกันของเซกเมนต์ที่ถูกระบาย ซึ่งมีค่า S เท่ากับ 80 และมีค่า C เท่ากับ 1 ดังนั้นฮิวริสติกของรูปที่ 3.10 (ข) จะมีค่าเท่ากับ 80.00 ดังนั้นจะเห็นว่าภาพที่มีการกระจายของเซกเมนต์ที่ถูกระบายจะมีค่าฮิวริสติกต่ำ (มีโอกาสน่าเป็นภาพนาข้าวสูง) และภาพที่มีการเชื่อมต่อกันของเซกเมนต์ที่ถูกระบายจะมีค่าฮิวริสติกสูง (มีโอกาสเป็นภาพนาข้าวสูง) ซึ่งค่าฮิวริสติกนี้จะใช้เป็นตัวตัดสินว่าภาพที่นำมาทดสอบเป็นนาข้าวหรือไม่

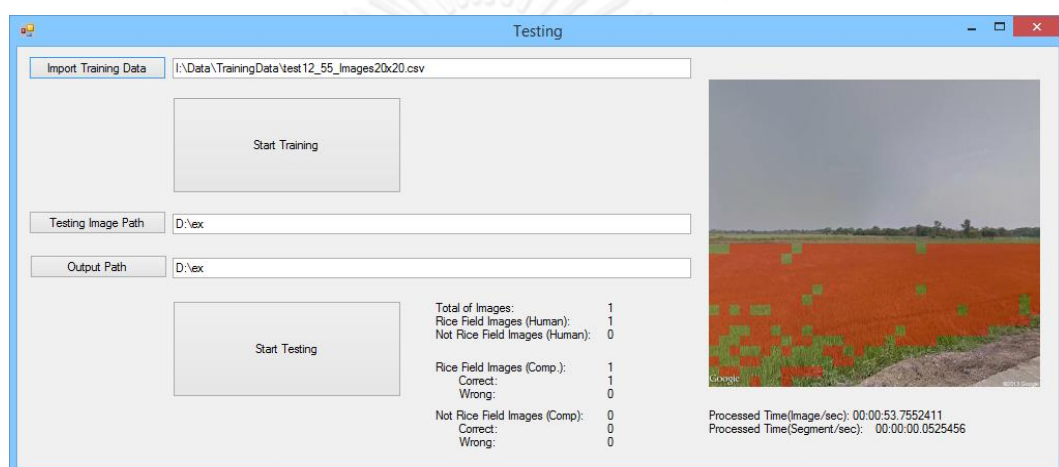


รูปที่ 3.10 ตัวอย่างภาพแสดงความสัมพันธ์ระหว่างการเชื่อมต่อกันของเซกเมนต์กับค่าฮิวริสติก

(ก) ภาพที่มีค่าฮิวริสติกต่ำ (ข) ภาพที่มีค่าฮิวริสติกสูง

3.7 การทดสอบรูปภาพ

การทดสอบรูปภาพจะใช้โปรแกรมที่พัฒนาขึ้นอีกโปรแกรมดังรูปที่ 3.11 เพื่อใช้ในการทดสอบภาพที่ยังไม่ทราบผลลัพธ์ โดยโปรแกรมนี้จะนำเข้าชุดข้อมูลตัวอย่างในการฝึกที่ได้จากโปรแกรมที่ใช้ในการเก็บตัวอย่างในการฝึก เพื่อใช้ในการปรับน้ำหนักของข่ายงานประสาทเทียมให้มีความผิดพลาดที่เหมาะสมที่สุดที่จะใช้ในการการทดสอบ และโปรแกรมนี้จะแสดงผลการทดสอบโดยการระบายส่วนที่เป็นส่วนของนาข้าวด้วยสีแดง พร้อมทั้งแสดงผลจำนวนของการตอบถูกหรือตอบผิดของภาพที่นำมาทดสอบ รายละเอียดการใช้โปรแกรมนี้สามารถดูที่ภาคผนวก ค



รูปที่ 3.11 ตัวอย่างส่วนติดต่อกับผู้ใช้งานของโปรแกรมที่ใช้สำหรับทดสอบรูปภาพ

บทที่ 4

การทดลองและผลการทดลอง

4.1 ภาพที่ใช้ในการทดลอง

4.1.1 ภาพที่ใช้ในการทดลองเป็นภาพที่ได้จาก Google Street View โดยใช้ Google Street View API เป็นเครื่องมือในการดึงภาพออกมา

4.1.2 ความละเอียดของภาพ 640 x 600 พิกเซล

4.1.3 รูปแบบของไฟล์ภาพคือ JPEG และเป็นภาพสีที่มีความลึก 24 บิต (RGB)

4.1.4 มุมของกล้องในการถ่ายภาพเป็นมุม 0 องศาจากแนวระดับ (มุมขนานกับแนวระดับ) โดยความสูงของกล้องที่ถูกติดตั้งมีระยะห่างจากพื้นดินประมาณ 2.5 เมตร

4.1.5 ภาพที่ถ่ายเป็นภาพด้านข้างของถนน

4.1.6 ใช้ภาพที่ถ่ายในประเทศไทย 10 จังหวัด ได้แก่ อ่างทอง พระนครศรีอยุธยา ฉะเชิงเทรา ชัยนาท เชียงราย ชลบุรี นครปฐม ปทุมธานี สุพรรณบุรี และ อุทัยธานี

4.2 สภาพแวดล้อมในการทดลอง

4.2.1 ฮาร์ดแวร์

หน่วยประมวลผล Intel Core i5-450M / 2.4 GHz (Dual-Core)

หน่วยความจำ 4.0 GB

4.2.2 ซอฟต์แวร์

Microsoft Windows 8.1 Professional

Microsoft Visual Studio C# 2013


EmguCV (Image processing library for .NET)

Google Street View API

4.3 การทดลองหาขนาดของเซกเมนต์ที่เหมาะสม


ในการหาทดลองการหาขนาดของเซกเมนต์ที่เหมาะสม ขนาดของเซกเมนต์มีความสำคัญในการจำแนกเซกเมนต์นั้นๆว่าเป็นเซกเมนต์ของนาข้าวหรือไม่ โดยเซกเมนต์นั้นต้องมีขนาดที่เหมาะสม ไม่มีขนาดเล็กหรือใหญ่จนเกินไป ถ้าภาพที่มีขนาดของเซกเมนต์ใหญ่เกินไปจะทำให้รายละเอียดของเซกเมนต์นั้นประกอบด้วยหลายวัตถุในเซกเมนต์นั้นๆ ซึ่งทำให้สูญเสียพื้นที่ที่สนใจไปจำนวนมาก แต่เมื่อเซกเมนต์มีขนาดเล็กจนเกินไปก็จะทำให้เซกเมนต์นั้นมีรายละเอียดของพื้นผิวไม่เพียงพอ เนื่องจากภาพที่ใช้ในงานวิจัยนี้มีขนาด 640x600 พิกเซล ดังนั้นตัวประกอบรวม (ขนาดของเซกเมนต์ที่เป็นไปได้) ของ 640 และ 600 คือ 1, 2, 4, 5, 8, 10, 20, 40 จากรูปที่ 4.1 ภาพนาข้าวที่มีขนาดของเซกเมนต์เท่ากับ 40x40 จะเห็นว่าส่วนในภาพจะมีการเสียพื้นที่นาข้าวไปเนื่องจากเซกเมนต์มี

ขนาดใหญ่จนเกินไป ทำให้กินพื้นที่จำนวนมาก เป็นผลให้เซกเมนต์บางส่วนมีส่วนคาบเกี่ยวกับวัตถุอื่นที่ไม่ใช่หน้าข้าว



รูปที่ 4.1 ภาพตั้งต้นที่มีการแบ่งขนาดของเซกเมนต์เท่ากับ 40x40 พิกเซล


เมื่อใช้เซกเมนต์ที่มีขนาด 10x10 พิกเซลดังรูปที่ 4.2 พบว่าจะมีเซกเมนต์ที่เป็นหน้าข้าวจำนวนมากในรูปภาพ ทำให้ใช้พื้นที่ในการตรวจหาหน้าข้าวได้มีประสิทธิภาพกว่าเซกเมนต์ขนาด 40x40 แต่จะเกิดความผิดพลาด (ในส่วนวงรีสีเหลืองของรูปที่ 4.2) เนื่องจากเซกเมนต์มีขนาดเล็กมากจนไม่สามารถเห็นลวดลาย (Texture) ได้เพียงพอ ทำให้พืชหรือวัตถุสีเขียวอื่นๆถูกจำแนกว่าเป็นหน้าข้าวได้ นอกจากนี้การที่เซกเมนต์มีขนาดเล็กจนเกินไปจะใช้เวลาในการประมวลผลมากขึ้นด้วย



รูปที่ 4.2 ภาพตั้งต้นที่มีการแบ่งขนาดของเซกเมนต์เท่ากับ 10x10 พิกเซล

เมื่อทดลองแบ่งเซกเมนต์ให้มีขนาด 20x20 ดังรูปที่ 4.3 พบว่าใช้เวลาในการประมวลผลน้อยกว่า และเกิดความผิดพลาด(จำแนกเซกเมนต์ที่ไม่ใช่นาข้าวว่าเป็นนาข้าว)น้อยกว่าเมื่อเทียบกับเซกเมนต์ขนาด 10x10 และพบว่าเซกเมนต์ขนาด 20x20 สูญเสียพื้นที่ที่เป็นนาข้าวน้อยกว่าเมื่อเทียบกับเซกเมนต์ขนาด 40x40

ดังนั้นเซกเมนต์ที่มีขนาดเหมาะสมที่จะใช้ในงานวิจัยนี้จะมีขนาด 20x20 พิกเซล




รูปที่ 4.3 ภาพตั้งต้นที่มีการแบ่งขนาดของเซกเมนต์เท่ากับ 20x20 พิกเซล

4.4 การทดลองแยกส่วนสีเขียวของพืช

การทดลองแยกส่วนของภาพที่เป็นพืชกระทำได้โดยการนำภาพของนาข้าวในระยะต่างๆ และภาพที่ไม่ใช่มาผ่านการแปลงให้เป็นภาพเอ็กเซสกรีน ที่เป็นภาพระดับเทา 256 ระดับ เพื่อดูผลว่าส่วนที่เป็นสีเขียวและสีเหลืองของภาพที่นำมาทดลองจะได้ผลออกมาอย่างไร ผลการทดลองคือวัตถุใดที่มีส่วนของสีเขียวหรือสีเหลืองในภาพตั้งต้นก็จะแสดงวัตถุนั้นในภาพเอ็กเซสกรีน ด้วยโทนสีขาว ส่วนวัตถุที่มีสีอื่นที่แสดงในภาพตั้งต้น ก็จะแสดงวัตถุนั้นในภาพเอ็กเซสกรีน ด้วยโทนสีดำ ดังรูปที่ 4.4



(ก)



(ข)



(ค)



(ง)



(จ)



(ฉ)



(ช)



(ซ)



ณ



ณ



ณ



ณ

รูปที่ 4.4 ตัวอย่างภาพที่นำมาแปลงให้เป็นภาพเอ็กเซสกรีน ที่เป็นค่าระดับเทา 256 ระดับ

(ก), (ค), (จ), (ช), (ณ), (ญ) ภาพตั้งต้น


(ข), (ง), (ฉ), (ซ), (ญ), (ฎ) ภาพที่ผ่านการแปลงเป็นภาพเอ็กเซสกรีน

4.5 การทดลองหาลักษณะเฉพาะของแต่ละพีเจอร์

การทดลองหาลักษณะเฉพาะของแต่ละพีเจอร์ ในการทดลองนี้จะต้องทำการเลือกรูปภาพที่จะใช้ในการเป็นตัวอย่างเพื่อที่จะใช้เป็นข้อมูลในการฝึกในข่ายงานประสาทเทียม โดยภาพที่เลือกมาฝึกในการทดลองนี้มีจำนวน 205 ภาพ ประกอบด้วยภาพที่เป็นนาข้าวในระยะต่างๆจำนวน 80 ภาพ ดังรูปที่ 4.5 (ก) และภาพที่ไม่ใช่ข้าวจำนวน 125 ภาพ ดังรูปที่ 4.5 (ข)



(ก)



(ข)

รูปที่ 4.5 ตัวอย่างภาพที่ใช้ในการฝึกข่ายงานประสาทเทียม

(ก) ภาพนาข้าว (ข) ไม่ใช่ภาพนาข้าว

เมื่อได้ภาพที่จะใช้เป็นข้อมูลในการฝึก ขั้นตอนต่อไปก็จะเป็นการเลือกเซกเมนต์โดยใช้โปรแกรมที่ใช้ในการเก็บตัวอย่างที่จะใช้ในการฝึก (รายละเอียดขั้นตอนการใช้งานสามารถดูได้ที่ภาคผนวก ข) เพื่อสกัดเอาพีเจอร์ทั้ง 15 พีเจอร์ของแต่ละเซกเมนต์ และระบุว่าตัวอย่างของเซกเมนต์ที่เลือกมานั้นเป็นส่วนของนาข้าวหรือเป็นเซกเมนต์ที่ไม่ใช่ชาข้าว โดยตัวอย่างของเซกเมนต์ที่เป็นนาข้าวที่เก็บไว้เพื่อใช้เป็นข้อมูลในการฝึกจะแสดงดังรูปที่ 4.6 (ก) และตัวอย่างของเซกเมนต์ที่ไม่เป็นนาข้าวจะแสดงดังรูปที่ 4.6 (ข)



(ก)



(ข)

รูปที่ 4.6 ตัวอย่าง(บางส่วน)ของเซกเมนต์ที่จะใช้เป็นตัวอย่างในการฝึก

(ก) ตัวอย่างนาข้าว (ข) ตัวอย่างไม่ใช่นาข้าว

ฟีเจอร์ทั้ง 15 ของแต่ละเซกเมนต์ที่เลือกมาใช้เป็นตัวอย่างในการฝึกจะถูกเก็บไว้ในฐานข้อมูลของโปรแกรม เพื่อสร้างไฟล์ที่ใช้ในการฝึกในรายงานประสาทเทียมต่อไป ตัวอย่างของไฟล์นามสกุล CSV ที่เก็บตัวอย่างทั้งหมดแสดงดังรูปที่ 4.7 ซึ่งจะแสดงฟีเจอร์ของแต่ละตัวอย่างทั้งหมด พร้อมทั้งการระบุว่าตัวอย่างนั้นเป็นเซกเมนต์ของนาข้าวหรือไม่

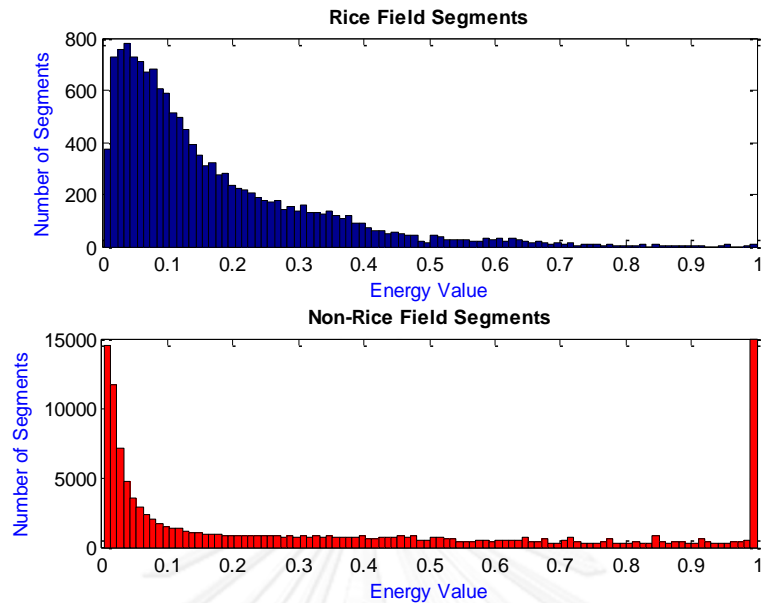
Name	Energy	Correlation	Inverse	Entropy	HXY1	HXY2	Sum Average	Sum Entropy	Sum Variance	Difference	Contrast	Difference	Mean ExG	Y Index	Class	
Ayutthaya00	0.055429	57314928	26455.63	0.628825	3.324564	-0.5474	0.958993	324.8184	2.860529	103898.5	0.001523	21.97105	1.427328	161.6075	20	1
Anghthong01	0.47151	8562.23	17.48412	0.966885	0.940949	-0.81318	0.857097	6.105263	0.940949	56.74327	0.003597	0.821053	0.182935	2.025	5	2
Chonburi010	0.011607	31134544	5458.84	0.334185	4.857264	-0.49882	0.980798	142.6053	4.185382	20271.76	0.000513	67.08421	2.477776	70.7425	18	2
Ayutthaya01	0.016981	1.93E+08	21435.54	0.559553	4.651749	-0.76894	0.998563	234.8105	4.354388	83158.1	0.001238	36.22632	1.69859	116.45	16	2
Uthaithani01	0.171537	32316036	26362.08	0.857974	2.314707	-0.76822	0.972273	323.3789	2.253841	103499.7	0.002862	11.7	0.57357	160.6775	18	1
Ayutthaya01	1	257	0.999969	1	0	0	0	2	0	4	0.003876	0	0	0	27	2
Chachoengs	0.97392	276.9538	1.084179	0.993684	0.083935	-0.35198	0.200703	2.036842	0.07891	3.947931	0.003815	0.031579	0.046086	0.02	23	2
Anghthong00	0.084986	840440.3	462.0574	0.49435	3.716189	-0.50551	0.959784	32.32368	3.295302	1626.55	0.000962	38.38684	1.987057	14.6025	27	2
Anghthong07	0.009294	82525812	6074.624	0.358253	5.100529	-0.73461	0.998711	135.5868	4.642513	22853.58	0.000489	53.93421	2.461501	66.81	18	2
Uthaithani01	0.006925	19939809	2613.486	0.166158	5.18248	-0.50559	0.985272	85.76842	4.370577	9195.708	0.000336	184.1947	2.695111	42.4175	24	2
Pathumthani	0.06097	290395	160.7629	0.49215	3.664531	-0.34937	0.888019	20.09211	3.045655	515.9125	0.000967	21.81316	1.779427	9.2025	20	2
Ayutthaya00	0.225997	29571.7	36.59459	0.825359	1.788095	-0.59167	0.885448	9.565789	1.710936	119.6549	0.00258	6.039474	0.744079	3.965	6	2
Uthaithani00	1	257	0.999969	1	0	0	0	2	0	4	0.003876	0	0	0	2	2
Anghthong01	0.030166	22571155	5720.685	0.470565	4.180199	-0.60643	0.988023	149.5105	3.844714	21964.86	0.000882	39.01579	2.056125	72.8425	22	2
Nakhonpathi	0.058286	24508014	11297.96	0.548699	3.360541	-0.5941	0.972227	207.8026	3.100816	43148.99	0.001255	62.61842	1.707161	103.295	17	2
Ayutthaya00	0.278587	35020.68	43.54197	0.876924	1.714735	-0.73674	0.930068	9.171053	1.714735	155.1122	0.002925	2.718421	0.574319	3.6975	12	2
Anghthong05	0.116593	8893821	5531.914	0.780322	2.724068	-0.71768	0.976686	146.9947	2.491721	21527.32	0.002354	21.25263	0.954246	72.5125	16	1
Ayutthaya01	0.149183	19998462	14125.53	0.870735	2.338658	-0.77711	0.975134	236.7658	2.28908	55533.25	0.002898	7.776316	0.648307	117.435	20	2
Pathumthani	1	257	0.999969	1	0	0	0	2	0	4	0.003876	0	0	0	25	2
Anghthong01	0.032119	5479445	1561.786	0.594014	3.858311	-0.61453	0.983861	77.38421	3.576369	5844.608	0.001215	12.63158	1.65098	37.6975	25	2
Chachoengs	0.042673	17105197	4910.162	0.568054	4.000156	-0.65782	0.990111	100.6921	3.672473	18899.04	0.001226	22.55526	1.705977	49.2925	14	2
Uthaithani00	0.095526	15152927	9081.516	0.66598	2.797325	-0.60644	0.955443	189.0632	2.560195	35417.58	0.001779	21.63684	1.172544	93.3025	22	2

รูปที่ 4.7 ไฟล์รูปแบบ CSV ที่ใช้เก็บตัวอย่างเพื่อที่จะใช้ในการฝึก

เมื่อนำฟีเจอร์ของของแต่ละเซกเมนต์ที่ใช้เป็นตัวอย่างในการฝึก ซึ่งประกอบด้วยเซกเมนต์เป็นนาข้าวและไม่ใช่นาข้าวมาแสดงฮิสโตแกรมของจำนวนเซกเมนต์ที่เกิดขึ้นในแต่ละค่าของฟีเจอร์ผลที่ได้แสดงดังต่อไปนี้

4.5.1 ค่าโมเมนต์อันดับที่สองของมุม (Angular Second Moment, ASM) หรือ Energy

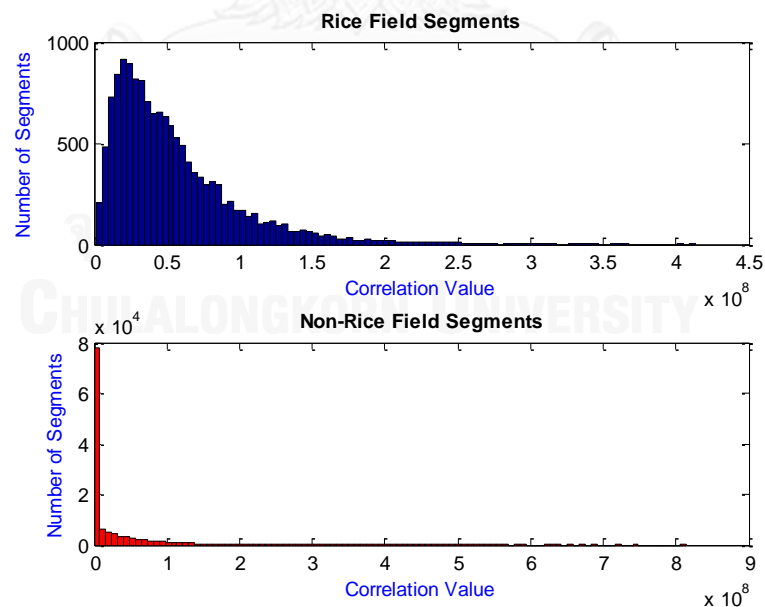
จากรูปที่ 4.8 ค่าโมเมนต์อันดับสองของมุมของเซกเมนต์ที่เป็นนาข้าว ค่าส่วนใหญ่จะอยู่ประมาณ 0 ถึง 0.1 ส่วนค่าโมเมนต์อันดับสองของมุมของเซกเมนต์ที่ไม่ใช่นาข้าวจะอยู่ที่ค่าต่ำสุดคือ 0 และค่าสูงสุดคือ 1 เป็นส่วนใหญ่



รูปที่ 4.8 ฮิสโตแกรมแสดงจำนวนเซกเมนต์ที่เป็นนาข้าวและไม่เป็นนาข้าว
ของค่าพลังงานที่แตกต่างกัน

4.5.2 ค่าสหสัมพันธ์ (Correlation)


จากรูปที่ 4.9 ค่าสหสัมพันธ์ของเซกเมนต์ที่เป็นนาข้าว ค่าส่วนใหญ่จะอยู่ประมาณ 0 ถึง 50,000,000 ส่วนค่าสหสัมพันธ์ของเซกเมนต์ที่ไม่ใช่ชาวนาข้าวจะอยู่ที่ค่าต่ำสุดคือ 0 เป็นส่วนใหญ่



รูปที่ 4.9 ฮิสโตแกรมแสดงจำนวนเซกเมนต์ที่เป็นนาข้าวและไม่เป็นนาข้าว
ของค่าสหสัมพันธ์ที่แตกต่างกัน

4.5.3 ค่าความแปรปรวน (Variance)

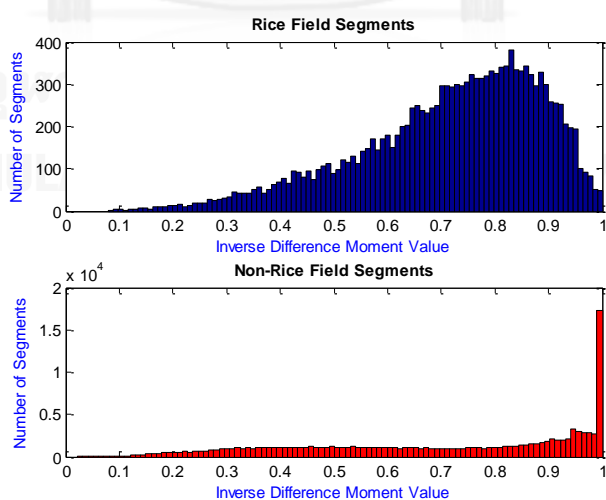
จากรูปที่ 4.10 ค่าความแปรปรวนของเซกเมนต์ที่เป็นนาข้าว ค่าส่วนใหญ่จะอยู่ประมาณ 25,000 ถึง 35,000 ส่วนค่าความแปรปรวนของเซกเมนต์ที่ไม่ใช่ชาวนาจะอยู่ที่ค่าต่ำสุดคือ 0 เป็นส่วนใหญ่



รูปที่ 4.10 ฮิสโตแกรมแสดงจำนวนเซกเมนต์ที่เป็นนาข้าวและไม่เป็นนาข้าว
ของค่าความแปรปรวนที่แตกต่างกัน

4.5.4 ค่าผั้กลับของผลต่างโมเมนต์ (Inverse Difference Moment)

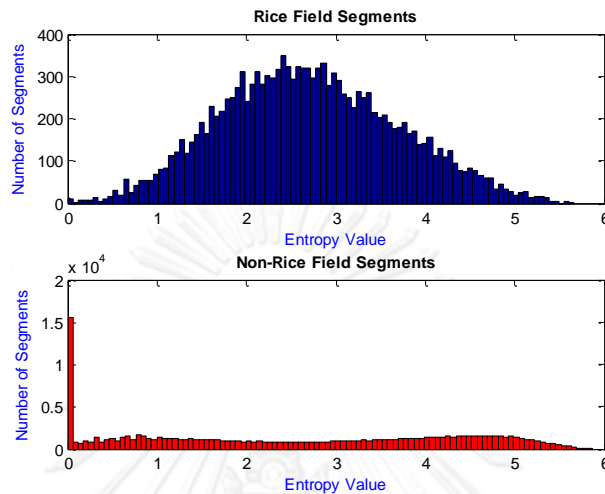
จากรูปที่ 4.11 ค่าผั้กลับของผลต่างโมเมนต์ของเซกเมนต์ที่เป็นนาข้าว ค่าส่วนใหญ่จะอยู่ประมาณ 0.7 ถึง 0.9 ส่วนค่าผั้กลับของผลต่างโมเมนต์ของเซกเมนต์ที่ไม่ใช่ชาวนาจะอยู่ที่ค่าสูงสุดคือ 1 เป็นส่วนใหญ่



รูปที่ 4.11 ฮิสโตแกรมแสดงจำนวนเซกเมนต์ที่เป็นนาข้าวและไม่เป็นนาข้าว
ของค่าผั้กลับของผลต่างโมเมนต์ที่แตกต่างกัน

4.5.5 ค่าเอนโทรปี (Entropy)

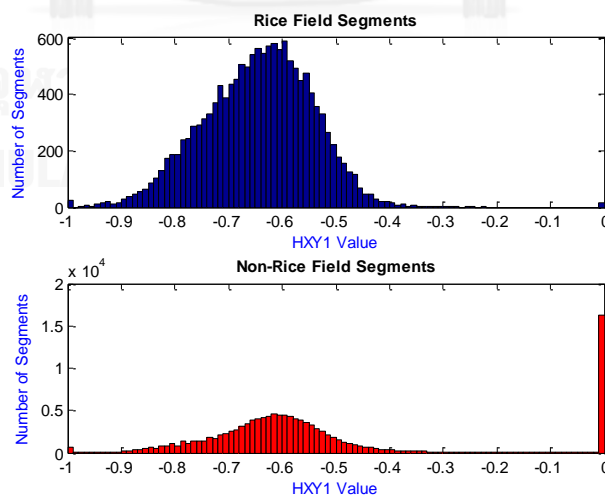
จากรูปที่ 4.12 ค่าเอนโทรปีของเซกเมนต์ที่เป็นนาข้าว ค่าส่วนใหญ่จะอยู่ประมาณ 2 ถึง 3 ส่วนค่าเอนโทรปีของเซกเมนต์ที่ไม่ใช่ชาวนาจะอยู่ที่ค่าต่ำสุดคือ 0 เป็นส่วนใหญ่



รูปที่ 4.12 ฮิสโตแกรมแสดงจำนวนเซกเมนต์ที่เป็นนาข้าวและไม่เป็นนาข้าวของค่าเอนโทรปีที่แตกต่างกัน

4.5.6 ค่าการวัดสหสัมพันธ์ของสหสัมพันธ์ 1 (Information Measures of Correlation 1: HXY1)

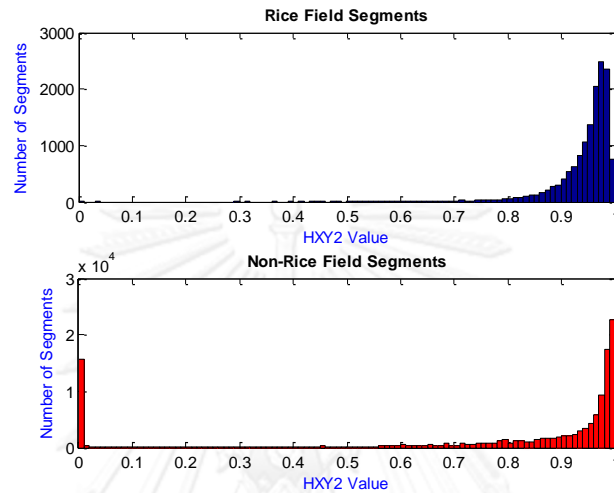
จากรูปที่ 4.13 ค่าการวัดสหสัมพันธ์ของสหสัมพันธ์ 1 ของเซกเมนต์ที่เป็นนาข้าว ค่าส่วนใหญ่จะอยู่ประมาณ -0.7 ถึง -0.6 ส่วนค่าการวัดสหสัมพันธ์ของสหสัมพันธ์ 1 ของเซกเมนต์ที่ไม่ใช่ชาวนาจะอยู่ที่ค่าสูงสุดคือ 0 เป็นส่วนใหญ่



รูปที่ 4.13 ฮิสโตแกรมแสดงจำนวนเซกเมนต์ที่เป็นนาข้าวและไม่เป็นนาข้าวของค่าการวัดสหสัมพันธ์ของสหสัมพันธ์ 1 ที่แตกต่างกัน

4.5.7 ค่าการวัดสหสัมพันธ์ของสหสัมพันธ์ 2 (Information Measures of Correlation 2: HXY2)

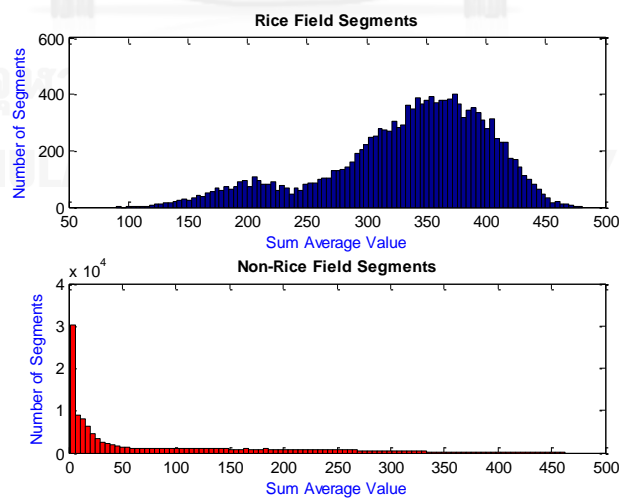
จากรูปที่ 4.14 ค่าการวัดสหสัมพันธ์ของสหสัมพันธ์ 2 ของเซกเมนต์ที่เป็นนาข้าว ค่าส่วนใหญ่จะอยู่ประมาณ 0.95 ถึง 0.98 ส่วนค่าการวัดสหสัมพันธ์ของสหสัมพันธ์ 2 ของเซกเมนต์ที่ไม่ใช่ชาวนาข้าวจะอยู่ที่ค่าต่ำสุด คือ 0 และค่าสูงสุดคือ 1 เป็นส่วนใหญ่



รูปที่ 4.14 ฮิสโตแกรมแสดงจำนวนเซกเมนต์ที่เป็นนาข้าวและไม่เป็นนาข้าวของค่าการวัดสหสัมพันธ์ของสหสัมพันธ์ 2 ที่แตกต่างกัน

4.5.8 ค่าผลรวมเฉลี่ย (Sum Average)

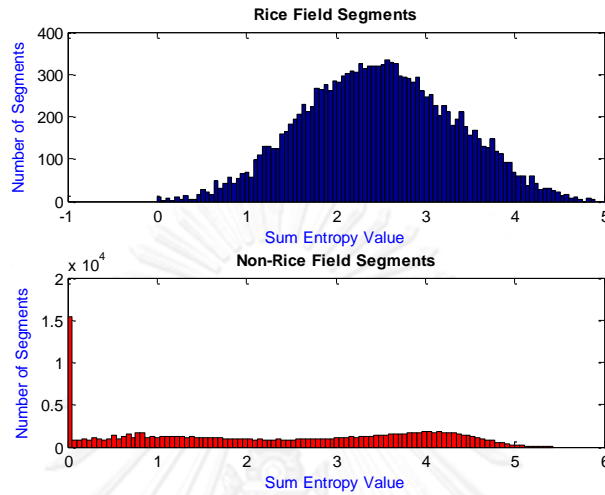
จากรูปที่ 4.15 ค่าผลรวมเฉลี่ยของเซกเมนต์ที่เป็นนาข้าว ค่าส่วนใหญ่จะอยู่ประมาณ 325 ถึง 375 ส่วนค่าผลรวมเฉลี่ยของเซกเมนต์ที่ไม่ใช่ชาวนาข้าวจะอยู่ที่ค่าต่ำสุด คือ 0 เป็นส่วนใหญ่



รูปที่ 4.15 ฮิสโตแกรมแสดงจำนวนเซกเมนต์ที่เป็นนาข้าวและไม่เป็นนาข้าวของค่าผลรวมเฉลี่ยที่ต่างกัน

4.5.9 ค่าผลรวมของเอนโทรปี (Sum Entropy)

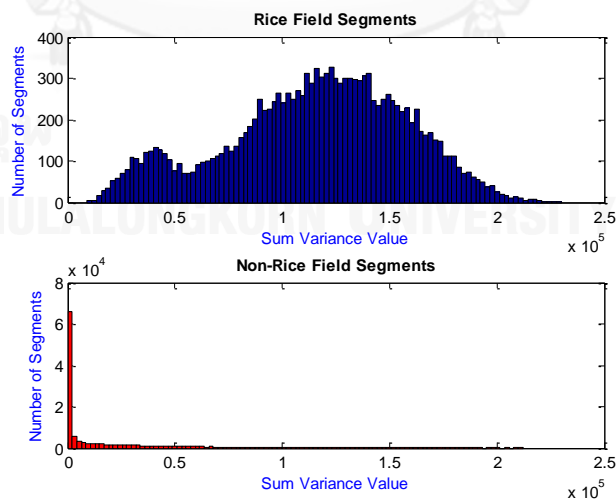
จากรูปที่ 4.16 ค่าผลรวมของเอนโทรปีของเซกเมนต์ที่เป็นนาข้าว ค่าส่วนใหญ่จะอยู่ประมาณ 2 ถึง 3 ส่วนค่าผลรวมของเอนโทรปีของเซกเมนต์ที่ไม่ใช่ข้าวจะอยู่ที่ค่าต่ำสุด คือ 0 เป็นส่วนใหญ่



รูปที่ 4.16 ฮิสโตแกรมแสดงจำนวนเซกเมนต์ที่เป็นนาข้าวและไม่เป็นนาข้าวของค่าผลรวมของเอนโทรปีที่แตกต่างกัน

4.5.10 ค่าผลรวมของค่าความแปรปรวน (Sum Variance)


จากรูปที่ 4.17 ค่าผลรวมของค่าความแปรปรวนของเซกเมนต์ที่เป็นนาข้าว ค่าส่วนใหญ่จะอยู่ประมาณ 10,000 ถึง 15,000 ส่วนค่าผลรวมของค่าความแปรปรวนของเซกเมนต์ที่ไม่ใช่ข้าวจะอยู่ที่ค่าต่ำสุด คือ 0 เป็นส่วนใหญ่



รูปที่ 4.17 ฮิสโตแกรมแสดงจำนวนเซกเมนต์ที่เป็นนาข้าวและไม่เป็นนาข้าวของค่าผลรวมของค่าความแปรปรวนที่ต่างกัน

4.5.11 ผลต่างของความแปรปรวน (Difference Variance)

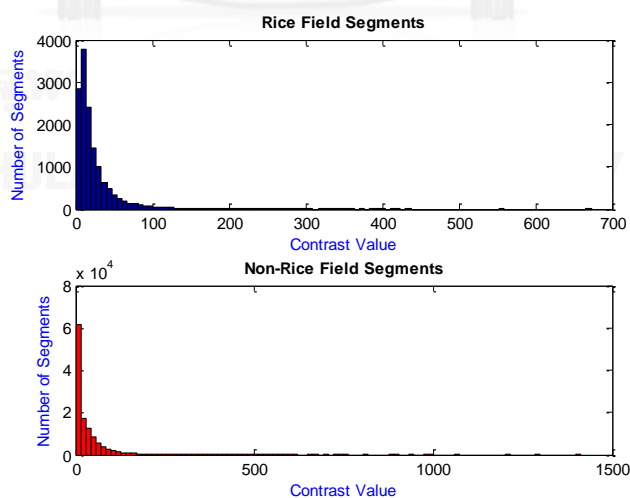
จากรูปที่ 4.18 ค่าผลต่างของค่าความแปรปรวนของเซกเมนต์ที่เป็นนาข้าว ค่าส่วนใหญ่จะอยู่ประมาณ 0.002 ถึง 0.003 ส่วนค่าผลต่างของค่าความแปรปรวนของเซกเมนต์ที่ไม่ใช่ชาวนาจะอยู่ที่ค่าสูงสุด คือ 0.0038 เป็นส่วนใหญ่



รูปที่ 4.18 ฮิสโตแกรมแสดงจำนวนเซกเมนต์ที่เป็นนาข้าวและไม่เป็นนาข้าวของค่าผลต่างของค่าความแปรปรวนที่แตกต่างกัน

4.5.12 ค่าความต่าง(Contrast)

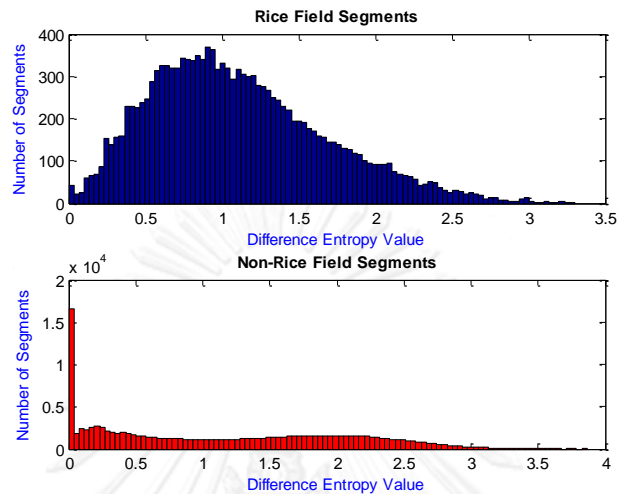
จากรูปที่ 4.19 ค่าความต่างของเซกเมนต์ที่เป็นนาข้าว ค่าส่วนใหญ่จะอยู่ประมาณ 0 ถึง 50 ส่วนค่าผลต่างของค่าความแปรปรวนของเซกเมนต์ที่ไม่ใช่ชาวนาจะอยู่ระหว่าง 0 ถึง 200 เป็นส่วนใหญ่ จะเห็นว่าค่าความต่างเป็นพีเจอร์ที่ไม่ดี เนื่องจากมีการซ้อนทับกันของทั้งสองฮิสโตแกรม



รูปที่ 4.19 ฮิสโตแกรมแสดงจำนวนเซกเมนต์ที่เป็นนาข้าวและไม่เป็นนาข้าวของค่าความต่างที่แตกต่างกัน

4.5.13 ค่าผลต่างของเอนโทรปี (Difference Entropy)

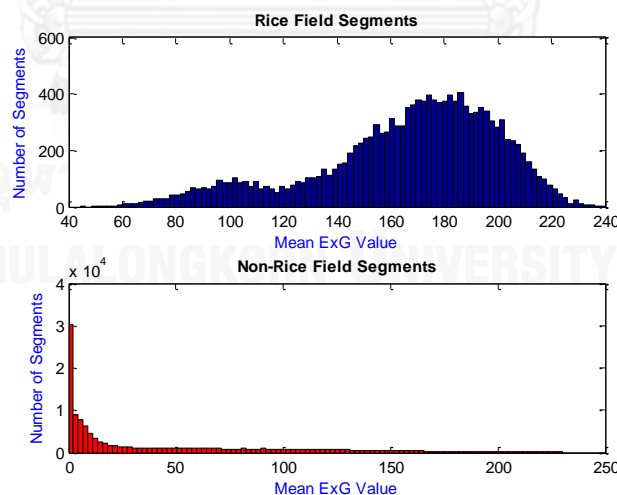
จากรูปที่ 4.20 ค่าผลต่างของเอนโทรปีของเซกเมนต์ที่เป็นนาข้าว ค่าส่วนใหญ่จะอยู่ประมาณ 0.5 ถึง 1 ส่วนค่าผลต่างของเอนโทรปีของเซกเมนต์ที่ไม่ใช่ชาวนาจะอยู่ที่ค่าต่ำสุด คือ 0 เป็นส่วนใหญ่



รูปที่ 4.20 ฮิสโตแกรมแสดงจำนวนเซกเมนต์ที่เป็นนาข้าวและไม่เป็นนาข้าวของค่าผลต่างของเอนโทรปีที่แตกต่างกัน

4.5.14 ค่าเอ็กเซสกรีนเฉลี่ย (Mean ExG)

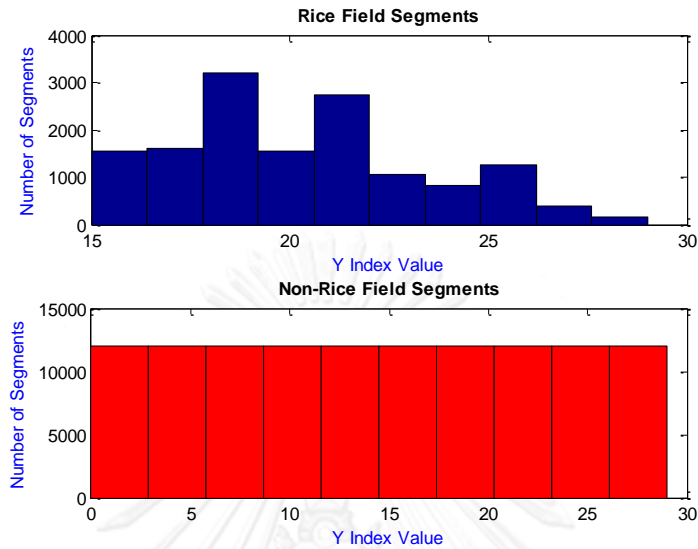
จากรูปที่ 4.21 ค่าเอ็กเซสกรีนเฉลี่ยของเซกเมนต์ที่เป็นนาข้าว ค่าส่วนใหญ่จะอยู่ประมาณ 160 ถึง 200 ส่วนค่าเอ็กเซสกรีนเฉลี่ยของเซกเมนต์ที่ไม่ใช่ชาวนาจะอยู่ที่ค่าต่ำสุด คือ 0 เป็นส่วนใหญ่



รูปที่ 4.21 ฮิสโตแกรมแสดงจำนวนเซกเมนต์ที่เป็นนาข้าวและไม่เป็นนาข้าวของค่าความเอ็กเซสกรีน เฉลี่ยที่แตกต่างกัน

4.5.15 ค่าตำแหน่งในแนวแกนตั้งของภาพ (Y Index)

จากรูปที่ 4.22 ค่าตำแหน่งในแนวดิ่งของเซกเมนต์ที่เป็นนาข้าว ค่าส่วนใหญ่จะอยู่ประมาณตำแหน่งที่ 15 ถึง 21 ส่วนค่าตำแหน่งในแนวดิ่งของเซกเมนต์ที่ไม่ใช่ชาวนาจะอยู่ทุกตำแหน่งเท่าๆกัน




รูปที่ 4.22 ฮิสโตแกรมแสดงจำนวนเซกเมนต์ที่เป็นนาข้าวและไม่เป็นนาข้าวของค่าตำแหน่งในแนวดิ่งที่แตกต่างกัน

4.6 การทดลองการเรียนรู้ของข่ายงานประสาทเทียม

ตัวอย่างที่จะใช้ในการฝึกข่ายงานประสาทเทียมจะประกอบด้วย 15 พีเจอร์ และผลลัพธ์เป้าหมายของแต่ละตัวอย่างคือใช่หรือไม่ใช่หน้าขาว (ใช่คือ 1 ไม่ใช่คือ 2) ดังนั้น โครงสร้างของข่ายงานประสาทเทียมในงานวิจัยนี้จะประกอบด้วย 15 โหนดนำเข้า และ 1 โหนดนำออก ส่วนจำนวนของโหนดซ่อนจะหาได้จากการทดลองต่อไปนี้


ตัวอย่าง (Sample) ที่จะใช้ในการฝึกข่ายงานประสาทเทียมมีทั้งหมด 134,311 ตัวอย่าง ซึ่งประกอบด้วยหน้าขาว 14,311 ตัวอย่าง และไม่ใช่หน้าขาว 120,000 ตัวอย่าง นำตัวอย่างทั้งหมดนี้แบ่งเป็นข้อมูลสำหรับการฝึก (Training) 94,017 ตัวอย่าง ตัวอย่างสำหรับการทดสอบเพื่อหา Mean Square Error (Mean Square Error Testing) 20,147 ตัวอย่าง และตัวอย่างสำหรับการตรวจสอบ (Validation) 20,147 ตัวอย่าง จากนั้นนำตัวอย่างทั้งหมดมาฝึกในข่ายงานประสาทเทียมด้วยโมดูลข่ายงานประสาทเทียมของโปรแกรม MATLAB ด้วยการใช้จำนวนโหนดซ่อนที่แตกต่างกัน จำนวนโหนดซ่อนที่เหมาะสมไม่ควรมีจำนวนมากหรือน้อยเกินไป โดยทั่วไปแล้วจะมีค่าอยู่ระหว่างจำนวนโหนดนำเข้ากับโหนดนำออก ดังนั้นในการทดลองนี้จะทดลองใช้โหนดนำเข้าตั้งแต่ 7 จนถึง 13 โหนด โดยจะแสดงความสัมพันธ์ระหว่างจำนวนรอบในการฝึก (Epoch) กับค่าความผิดพลาดจากการฝึกในแต่ละรอบ (Mean Squared Error) โดยค่าความผิดพลาดที่ได้จากการฝึกที่เหมาะสมที่สุดคือค่าที่จุดตัวอย่างที่ใช้ในการฝึกมีค่าความผิดพลาดที่ได้จากการฝึกลดลง แต่จุดตัวอย่างที่ใช้ในการตรวจสอบมีค่าความผิดพลาดที่ได้จากการฝึกเพิ่มขึ้น ซึ่งจะเกิดการเรียนรู้มากเกินไป (Overfitting) ทำให้ข้อมูลที่น่ามาทดสอบมีความคลาดเคลื่อนสูง ซึ่งผลการทดลองเป็นดังต่อไปนี้

ค่าความผิดพลาดจากการฝึกโดยใช้โหนดซ่อนจำนวน 7 โหนด จะได้ค่าที่เหมาะสมที่สุดคือ 0.027467 โดยใช้การฝึก 121 รอบดังรูปที่ 4.23




รูปที่ 4.23 ประสิทธิภาพในการเรียนรู้ของข่ายงานประสาทเทียมโดยใช้โหนดซ่อน 7 โหนด

เมื่อใช้จำนวนโนดซ่อนจำนวน 8 โหนด จะได้ค่าความผิดพลาดจากการฝึกที่เหมาะสมที่สุดคือ 0.033002 โดยใช้การฝึก 90 รอบ ดังรูปที่ 4.24




รูปที่ 4.24 ประสิทธิภาพในการเรียนรู้ของข่ายงานประสาทเทียมโดยใช้โนดซ่อน 8 โหนด

เมื่อใช้จำนวนโนดซ่อนจำนวน 9 โหนด จะได้ค่าความผิดพลาดจากการฝึกที่เหมาะสมที่สุดคือ 0.028918 โดยใช้การฝึก 87 รอบ ดังรูปที่ 4.25



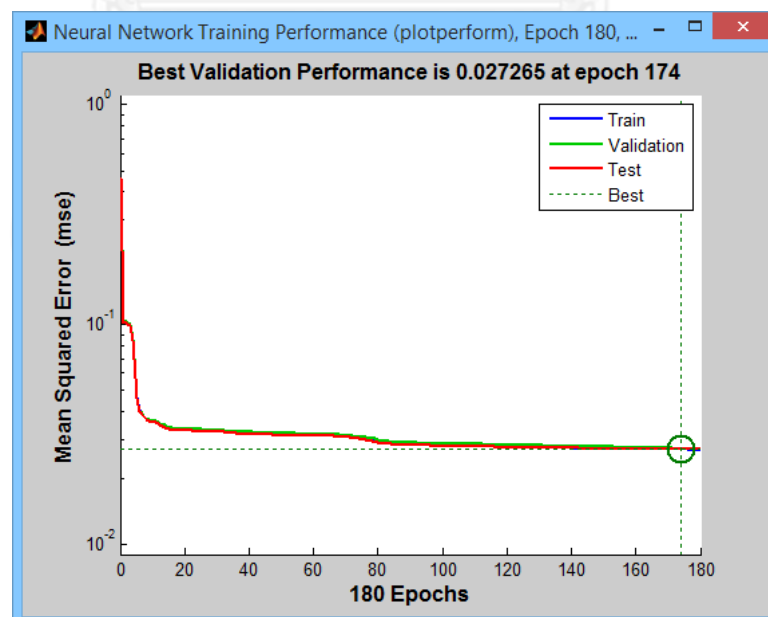
รูปที่ 4.25 ประสิทธิภาพในการเรียนรู้ของข่ายงานประสาทเทียมโดยใช้โนดซ่อน 9 โหนด

เมื่อใช้จำนวนโนดซ่อนจำนวน 10 โนด จะได้ค่าความผิดพลาดจากการฝึกที่เหมาะสมที่สุดคือ 0.026292 โดยใช้การฝึก 122 รอบ ดังรูปที่ 4.26



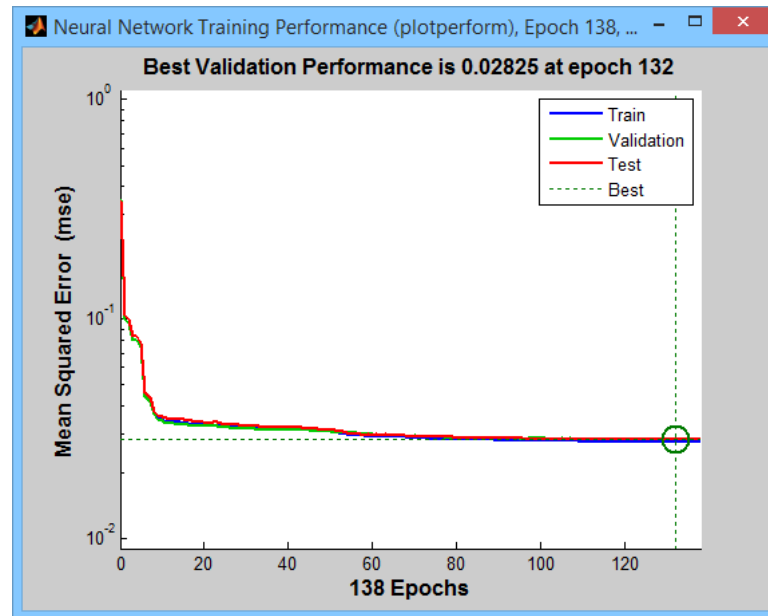
รูปที่ 4.26 ประสิทธิภาพในการเรียนรู้ของข่ายงานประสาทเทียมโดยใช้โนดซ่อน 10 โนด

เมื่อใช้จำนวนโนดซ่อนจำนวน 11 โนด จะได้ค่าความผิดพลาดจากการฝึกที่เหมาะสมที่สุดคือ 0.027265 โดยใช้การฝึก 174 รอบ ดังรูปที่ 4.27



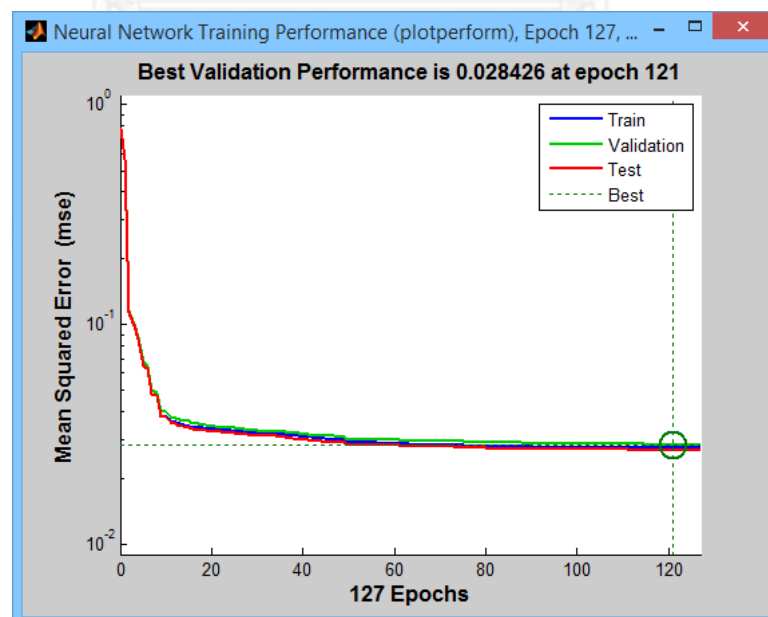
รูปที่ 4.27 ประสิทธิภาพในการเรียนรู้ของข่ายงานประสาทเทียมโดยใช้โนดซ่อน 11 โนด

เมื่อใช้จำนวนโนดซ่อนจำนวน 12 โนด จะได้ค่าความผิดพลาดจากการฝึกที่เหมาะสมที่สุดคือ 0.02825 โดยใช้การฝึก 132 รอบ ดังรูปที่ 4.28




รูปที่ 4.28 ประสิทธิภาพในการเรียนรู้ของข่ายงานประสาทเทียมโดยใช้โนดซ่อน 12 โนด

เมื่อใช้จำนวนโนดซ่อนจำนวน 13 โนด จะได้ค่าความผิดพลาดจากการฝึกที่เหมาะสมที่สุดคือ 0.028426 โดยใช้การฝึก 121 รอบ ดังรูปที่ 4.29



รูปที่ 4.29 ประสิทธิภาพในการเรียนรู้ของข่ายงานประสาทเทียมโดยใช้โนดซ่อน 13 โนด

จากการทดลองพบว่าจำนวนโนดซ่อนที่เหมาะสมที่สุดที่ใช้ในงานวิจัยนี้คือ 10 โนด (ค่าความผิดพลาดจากการฝึกคือ 0.026292) ดังนั้นโครงสร้างของข่ายงานประสาทเทียมที่ใช้ในงานวิจัยนี้จะประกอบด้วย 15 โนดนำเข้า 10 โนดซ่อน และ 1 โนดนำออก ดังรูปที่ 4.30



รูปที่ 4.30 โครงสร้างของข่ายงานประสาทเทียมที่ใช้ในงานวิจัยนี้

4.7 การทดลองหาค่าอิทธิพลที่เหมาะสม

เมื่อภาพทดสอบผ่านช่างงานประสาทเทียมที่ได้รับการฝึกแล้ว ในภาพที่เป็นนาข้าวบริเวณของเซกเมนต์ที่เป็นนาข้าวจะถูกระบาย (Label) เป็นสีแดงดังรูปที่ 4.31 (ก) ส่วนภาพที่ไม่ใช่ นาข้าว แต่มีเซกเมนต์ในภาพบางส่วนคล้ายส่วนของนาข้าวก็อาจเกิดความผิดพลาด (Fault) ขึ้น และถูกระบายได้เช่นกัน ดังรูปที่ 4.31 (ข)



(ก)

(ข)

รูปที่ 4.31 ภาพทดสอบที่ถูกประมวลผลแล้ว

(ก) ภาพนาข้าว (ข) ไม่ใช่ภาพนาข้าว

จากการนำภาพมาทดสอบพบว่าภาพที่เป็นนาข้าวจะมีส่วนที่ถูกระบายติดต่อกันเป็นผืนใหญ่ ส่วนภาพที่ไม่ใช่ นาข้าวและมีข้อผิดพลาดเกิดขึ้น (มีส่วนที่ไม่ใช่ส่วนของนาข้าวถูกระบายสีแดง) จะกระจายกันเป็นจุดๆซึ่งไม่ติดกัน ดังนั้นในขั้นตอนที่จะตัดสินใจว่าภาพนี้เป็นนาข้าวหรือไม่จะใช้อิทธิพลฟังก์ชันเข้ามาช่วยในการวิเคราะห์ว่าส่วนที่ถูกระบายมีการเชื่อมต่อกันมากเท่าใด โดยค่าอิทธิพลนิยามได้โดยการนำค่าของจำนวนเซกเมนต์ที่ถูกระบายทั้งหมด (เซกเมนต์ที่ถูกระบายเป็นนาข้าว)หารด้วยจำนวนเซกเมนต์ที่มีการเชื่อมติดกันทั้งหมด ภาพที่เป็นนาข้าวจะมีค่าอิทธิพลสูง ดังรูปที่ 4.32 โดยมีจำนวนเซกเมนต์ที่ถูกระบายทั้งหมดเท่ากับ 322 และมีจำนวนเซกเมนต์ที่มีการเชื่อมติดกันทั้งหมดเท่ากับ 1 ดังนั้น รูปที่ 4.32 มีค่าอิทธิพลเท่ากับ 322.00




รูปที่ 4.32 ภาพนาข้าวที่มีค่าฮิวริสติกเท่ากับ 322.00

ภาพที่ไม่ใช่ภาพนาข้าวจะมีค่าฮิวริสติกต่ำ ดังรูปที่ 4.33 โดยมีจำนวนเซกเมนต์ที่ถูกระบายทั้งหมดเท่ากับ 17 และมีจำนวนเซกเมนต์ที่มีการเชื่อมติดกันทั้งหมดเท่ากับ 8 ดังนั้น รูปที่ 4.33 มีค่าฮิวริสติกเท่ากับ 2.125




รูปที่ 4.33 ภาพไม่ใช่นาข้าวที่มีค่าฮิวริสติกเท่ากับ 2.125

ค่าฮิวริสติกจะเป็นตัวตัดสินว่าภาพที่นำมาทดสอบเป็นนาข้าวหรือไม่ โดยจะต้องเลือกค่าฮิวริสติกที่เหมาะสมเพื่อจะได้ค่าความแม่นยำในการจำแนกภาพสูงที่สุด โดยการหาค่าฮิวริสติกที่เหมาะสมนั้น จะทำการทดลองโดยนำภาพทดสอบจำนวน 600 ภาพ มาหาค่าฮิวริสติกที่ดีที่สุด จากรูปที่ 4.34 (ก) แสดงผลความแม่นยำในการจำแนกภาพที่เป็นนาข้าวและภาพที่เป็นนาข้าวโดยใช้ค่าฮิวริสติกต่างๆ จากรูปที่ 4.34 (ข) จะพบว่าค่าฮิวริสติกที่ให้ความแม่นยำในการจำแนกสูงที่สุดคือค่าฮิวริสติกเท่ากับ 9.67 ซึ่งมีค่าความแม่นยำในการจำแนกภาพที่เป็นนาข้าวและภาพที่ไม่ใช่ข้าวเท่ากับ 94.92%



(ก)



(ข)

รูปที่ 4.34 กราฟแสดงความสัมพันธ์ระหว่างค่าฮิวริสติกกับค่าความแม่นยำในการจำแนกภาพ

(ก) กราฟสเกลจริง (ข) กราฟสเกลขยาย

4.8 การทดลองการจำแนกภาพ

การทดลองการจำแนกภาพคือผลลัพธ์สุดท้ายของงานวิจัยนี้ ซึ่งก็คือการหาว่าภาพที่นำมาทดสอบนี้เป็นภาพนาข้าวหรือไม่ โดยการทดลองจะใช้ภาพทดสอบทั้งหมด 9,189 ภาพ ใช้ข่ายงานประสาทเทียมที่ประกอบด้วย 15 โหนดนำเข้า 10 โหนดซ่อน 1 โหนดนำออก ตัวอย่างของภาพผลลัพธ์ของภาพนาข้าวพร้อมแสดงค่าฮิวริสติก แสดงดังรูปที่ 4.35



รูปที่ 4.35 ภาพนาข้าวที่ผ่านการประมวลผลและแสดงค่าฮิวริสติก

ตัวอย่างของภาพผลลัพธ์ของภาพไมใช่नाข้าวพร้อมแสดงค่าฮิวริสติก แสดงดังรูปที่ 4.36



รูปที่ 4.36 ภาพไมใช่นาข้าวที่ผ่านการประมวลผลและแสดงค่าฮิวริสติก

เมื่อใช้ค่าฮิวริสติกเท่ากับ 9.67 มาใช้ในการจำแนกภาพ กำหนดให้ภาพไมใช่นาข้าวเป็นตัวอย่างบวกและภาพนาข้าวเป็นตัวอย่างลบ ผลลัพธ์การจำแนกภาพจะได้ค่าความผิดพลาดเชิงบวกเฉลี่ยร้อยละ 3.42 และค่าผิดพลาดความพลาดเชิงลบเฉลี่ยร้อยละ 3.81 ดังตารางที่ 4.1

ตารางที่ 4.1 ผลการวัดความถูกต้องในการจำแนกภาพ

ชนิดภาพภาพ	จำนวนภาพ	ตอบถูก	ตอบผิด
ไม่ใช่ภาพนาข้าว	8,186	7,906	280
		96.58%	3.42%
ภาพนาข้าว	972	935	37
		96.19 %	3.81%

เมื่อแบ่งการจำแนกข้อมูลรูปภาพตามจังหวัด โดยจำแนกข้อมูลรูปภาพด้วยผู้วิจัยเองตามลักษณะของภาพที่มีนาข้าวโดยไม่ได้ลงสำรวจภาคสนามจริง เปรียบเทียบกับผลที่ได้จากวิธีการที่นำเสนอ ผลที่ได้แสดงดังตารางที่ 4.2

ตารางที่ 4.2 ผลการวัดความถูกต้องในการจำแนกภาพแบ่งตามจังหวัด

จังหวัด	ชนิดภาพภาพ	จำนวนภาพ	ตอบถูก	ตอบผิด
อ่างทอง	ไม่ใช่ภาพนาข้าว	1,627	1,602	25
			98.46%	1.54%
	ภาพนาข้าว	84	81	3
			96.43%	3.57%
อยุธยา	ไม่ใช่ภาพนาข้าว	1,141	1,067	74
			93.50%	6.50%
	ภาพนาข้าว	193	186	7
			96.37%	3.63%
ฉะเชิงเทรา	ไม่ใช่ภาพนาข้าว	983	966	17
			98.27%	1.73%
	ภาพนาข้าว	14	13	1
			92.86%	7.14%
ชัยนาท	ไม่ใช่ภาพนาข้าว	493	468	25
			94.93%	5.07%
	ภาพนาข้าว	90	86	4
			95.60%	4.40%
เชียงราย	ไม่ใช่ภาพนาข้าว	577	569	8

จังหวัด	ชนิดภาพภาพ	จำนวนภาพ	ตอบถูก	ตอบผิด
	ภาพนาข้าว	31	98.61%	1.39%
			28	3
			90.32%	9.68%
ชลบุรี	ไม่ใช่ภาพนาข้าว	589	556	33
			94.40%	5.60%
			ภาพนาข้าว	13
			84.62%	15.38
นครปฐม	ไม่ใช่ภาพนาข้าว	695	674	21
			96.98%	3.02%
			ภาพนาข้าว	54
			98.15%	1.85%
ปทุมธานี	ไม่ใช่ภาพนาข้าว	563	528	35
			93.78%	6.22%
			ภาพนาข้าว	50
			92.00%	8.00%
สุพรรณบุรี	ไม่ใช่ภาพนาข้าว	551	530	21
			96.19%	3.81%
			ภาพนาข้าว	106
			95.28%	4.72%
อุทัยธานี	ไม่ใช่ภาพนาข้าว	967	946	21
			97.83%	2.17%
			ภาพนาข้าว	337
			97.92%	2.08%

เมื่อแบ่งการจำแนกข้อมูลรูปภาพตามระยะการเจริญเติบโตของข้าว โดยจำแนกข้อมูลรูปภาพด้วยผู้วิจัยเองตามลักษณะของนาข้าวโดยไม่ได้ลงสำรวจภาคสนามจริง เปรียบเทียบกับผลที่ได้จากวิธีการที่นำเสนอ ผลที่ได้แสดงดังตารางที่ 4.3

ตารางที่ 4.3 ผลการวัดความถูกต้องในการจำแนกภาพแบ่งตามระยะการเจริญเติบโต

ระยะของข้าว	จำนวนภาพ	ตอบถูก	ตอบผิด
ระยะแตกกอ	677	655	22
		96.75%	3.25%
ระยะเจริญเติบโต ด้านการสีพันธุ์	212	201	11
		94.81%	5.19%
ระยะเก็บเกี่ยว	83	79	4
		95.18%	4.82%

ตัวอย่างของภาพนาข้าวระยะต้นกล้าที่นำมาทดสอบดังรูปที่ 4.37 (ก),(ค),(จ) และภาพของผลลัพธ์พร้อมค่าฮิสตริก แสดงดังรูปที่ 4.37 (ข),(ง),(ฉ) จะเห็นว่าภาพนาข้าวในระยะนี้จะไม่สามารถตรวจจับได้



(ก)



(ข)



(ค)



(ง)



(จ)



(ฉ)

รูปที่ 4.37 ภาพทดสอบก่อนและหลังการประมวลผล

(ก),(ค),(จ) ภาพก่อนประมวลผล (ข),(ง),(ฉ) ภาพหลังประมวลผล


ตัวอย่างของภาพนาข้าวระยะแตกกอที่นำมาทดสอบดังรูปที่ 4.38 (ก),(ค),(จ) และภาพของ ผลลัพธ์พร้อมค่าฮิวริสติก แสดงดังรูปที่ 4.38 (ข),(ง),(ฉ)




(ก)



(ข)



(ค)



(ง)



(จ)



(ฉ)

รูปที่ 4.38 ภาพทดสอบก่อนและหลังการประมวผล
(ก),(ค),(จ) ภาพก่อนประมวผล (ข),(ง),(ฉ) ภาพหลังประมวผล

ตัวอย่างของภาพนาข้าวระยะเจริญเติบโตด้านการสีพันธุ์ที่นำมาทดสอบดังรูปที่ 4.39
(ก),(ค),(จ) และภาพของผลลัพธ์พร้อมค่าฮิวริสติก แสดงดังรูปที่ 4.39 (ข),(ง),(ฉ)




(ก)



(ข)



(ค)



(ง)



(จ)




(ฉ)

รูปที่ 4.39 ภาพทดสอบก่อนและหลังการประมวลผล
(ก),(ค),(จ) ภาพก่อนประมวลผล (ข),(ง),(ฉ) ภาพหลังประมวลผล

ตัวอย่างของภาพนาข้าวระยะระยะเก็บเกี่ยวที่นำมาทดสอบดังรูปที่ 4.40 (ก),(ค),(จ) และภาพของผลลัพธ์พร้อมค่าฮิวริสติก แสดงดังรูปที่ 4.40 (ข),(ง),(ฉ)



(ก)



(ข)



(ค)



(ง)



(จ)



(ฉ)

รูปที่ 4.40 ภาพทดสอบก่อนและหลังการประมวลผล
(ก),(ค),(จ) ภาพก่อนประมวลผล (ข),(ง),(ฉ) ภาพหลังประมวลผล

4.8.1 ความผิดพลาดเชิงบวก

ความผิดพลาดเชิงบวกในงานวิจัยนี้จะหมายถึงการที่โปรแกรมตอบว่าภาพนั้นเป็นภาพนาข้าว โดยที่ความจริงแล้วภาพนั้นไม่ใช่นาข้าว โดยสาเหตุของความผิดพลาดที่เกิดขึ้นจะเกิดจากภาพต่างๆ ต่อไปนี้

4.8.1.1 ความผิดพลาดเชิงบวกที่เกิดจากพืชหรือวัชพืชที่มีความคล้ายส่วนของนาข้าว

ตัวอย่างภาพที่มีความผิดพลาดเชิงบวกโดยมีส่วนของพืชมีความคล้ายกับส่วนของนาข้าว นำมาทดสอบดังรูปที่ 4.41 (ก),(ค),(จ) และภาพของผลลัพธ์พร้อมค่าฮิวริสติก แสดงดังรูปที่ 4.41 (ข),(ง),(ฉ) จะเห็นว่าภาพเหล่านี้เป็นภาพที่ไม่ใช่ข้าวที่มีค่าฮิวริสติกมากกว่า 9.67



(ก)



(ข)



(ค)



(ง)



(จ)



(ฉ)

รูปที่ 4.41 ภาพทดสอบก่อนและหลังการประมวลผล
(ก),(ค),(จ) ภาพก่อนประมวลผล (ข),(ง),(ฉ) ภาพหลังประมวลผล

4.8.1.2 ความผิดพลาดเชิงบวกที่เกิดจากสนามหญ้าที่มนุษย์สร้างขึ้น

ตัวอย่างภาพที่มีความผิดพลาดเชิงบวกโดยมีส่วนของสิ่งที่มนุษย์สร้างขึ้นที่มีความคล้ายกับส่วนของนาข้าวนำมาทดสอบดังรูปที่ 4 42 (ก),(ค),(จ) และภาพของผลลัพธ์พร้อมค่าอิวิริสติก แสดงดังรูปที่ 4 42 (ข),(ง),(ฉ) จะเห็นว่าภาพเหล่านี้เป็นภาพที่ไม่ใช่ข้าวที่มีค่าอิวิริสติกมากกว่า 9.67



(ก)



(ข)



(ค)



(ง)



(จ)



(ฉ)

รูปที่ 4 42 ภาพทดสอบก่อนและหลังการประมวลผล
(ก),(ค),(จ) ภาพก่อนประมวลผล (ข),(ง),(ฉ) ภาพหลังประมวลผล

4.8.2 ความผิดพลาดเชิงลบ

ความผิดพลาดเชิงลบในงานวิจัยนี้จะหมายถึงการที่โปรแกรมตอบว่าภาพนั้นไม่ใช่ภาพนาข้าว โดยที่ความจริงแล้วภาพนั้นเป็นนาข้าว โดยสาเหตุของความผิดพลาดที่เกิดขึ้นจะเกิดจากภาพต่างๆ ต่อไปนี้

4.8.2.1 ความผิดพลาดเชิงลบที่เกิดจากนาข้าวที่มีการล้มของต้นข้าว

ตัวอย่างของความผิดพลาดเชิงลบที่เกิดจากการล้มของต้นข้าว แสดงดังรูปที่ 4.43 โดยส่วนใหญ่จะเกิดขึ้นกับนาข้าวในระยะเก็บเกี่ยว จะเห็นว่าภาพนี้เป็นภาพที่นาข้าวที่มีค่าฮิวริสติกน้อยกว่า 9.67



(ก)

(ข)

รูปที่ 4.43 ภาพทดสอบก่อนและหลังการประมวผล

(ก) ภาพก่อนประมวผล (ข) ภาพหลังประมวผล

4.8.2.2 ความผิดพลาดเชิงลบที่เกิดจากนาข้าวอยู่ในระยะต้นกล้า

ตัวอย่างความผิดพลาดเชิงลบที่เกิดจากนาข้าวอยู่ในระยะต้นกล้า แสดงดังรูปที่ 4.44 จะเห็นว่าภาพนี้เป็นภาพที่นาข้าวที่มีค่าฮิวริสติกน้อยกว่า 9.67แสดงดังรูปที่



(ก)

(ข)

รูปที่ 4.44 ภาพทดสอบก่อนและหลังการประมวผล

(ก) ภาพก่อนประมวผล (ข) ภาพหลังประมวผล

4.8.2.3 ความผิดพลาดเชิงลบที่เกิดจากนาข้าวที่อยู่ระยะห่างไกลจนเกินไป

ตัวอย่างความผิดพลาดเชิงลบที่เกิดจากนาข้าวอยู่ระยะห่างไกลจนเกินไป จนทำให้เห็นพื้นที่ของนาข้าวน้อย แสดงดังรูปที่ 4.45




(ก)

(ข)

รูปที่ 4.45 ภาพทดสอบก่อนและหลังการประมวลผล

(ก) ภาพก่อนประมวลผล (ข) ภาพหลังประมวลผล



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

บทที่ 5

สรุปผลการวิจัยและข้อเสนอแนะ

5.1 สรุปผลการวิจัย

งานวิจัยนี้ได้เสนอวิธีการตรวจหาบริเวณนาข้าวจากภาพถ่ายภาคพื้นดินในประเทศไทย โดยใช้ภาพถ่ายจาก Google Street View ที่มีขนาด 640x600 พิกเซล แล้วแบ่งภาพหลักออกเป็น เซกเมนต์เท่าๆกัน จากนั้นแปลงภาพสีเป็นภาพเอ็ทเชสกรีน เพื่อใช้ในการสกัดพีเจอร์หลักซึ่งได้แก่ พีเจอร์เชิงสี่ พีเจอร์เชิงตำแหน่ง และพีเจอร์เชิงพื้นผิว เมื่อได้พีเจอร์ทั้งหมดแล้วก็จะนำมาฝึกใน ข่ายงานประสาทเทียมเพื่อให้เรียนรู้ว่าเซกเมนต์ใดคือนาข้าวหรือไม่ใช่ข้าว แล้วใช้ค่าฮิวริสติกใน ขั้นตอนสุดท้ายในการยืนยันภาพนั้นว่าเป็นภาพนาข้าวหรือไม่

สำหรับการทดลองเพื่อหาค่าที่เหมาะสมต่างๆเพื่อใช้ในวิธีการที่เสนอนั้น พบว่าการเลือกใช้ เซกเมนต์ที่มีขนาดเหมาะสมที่สุดในงานวิจัยนี้คือ 20x20 pixels ข่ายงานประสาทเทียมที่ใช้จะ ประกอบด้วยโนดนำเข้า 15 โนด โนดซ่อน 10 โนด และโนดนำออก 1 โนด ค่าฮิวริสติกที่เหมาะสมคือ 9.67

ภาพที่ใช้เป็นตัวอย่างในการฝึกทั้งหมด 205 ภาพ โดยเก็บเอาตัวอย่างของเซกเมนต์เพื่อเป็น ตัวอย่างในการฝึกจำนวน 134,311 ตัวอย่าง ประกอบด้วยนาข้าว 14,311 ตัวอย่าง ไม่ใช่ข้าว 120,000 ตัวอย่าง และใช้ภาพในการทดสอบจำนวน 9,158 ภาพ ประกอบด้วยภาพไม่ใช่ข้าว 8186 ภาพ และภาพนาข้าว 972 ภาพ ผลการทดลองจะได้ค่าความถูกต้องของภาพไม่ใช่ข้าวเฉลี่ย ร้อยละ 96.58 หรือมีค่าความผิดพลาดเชิงบวกเฉลี่ยร้อยละ 3.42 และได้ค่าความถูกต้องของภาพนา ข้าวเฉลี่ยร้อยละ 96.19 หรือมีค่าความผิดพลาดเชิงลบเฉลี่ยร้อยละ 3.81

ความผิดพลาดเชิงบวกเกิดขึ้นกับภาพที่มีส่วนของพืชบางชนิดคล้ายกับส่วนของนาข้าว เช่น สนามหญ้า เป็นต้น ความผิดพลาดเชิงลบเกิดจากภาพนาข้าวที่มีการล้มของต้นข้าว ภาพนาข้าวที่อยู่ใน ระยะไกลในภาพจนทำให้ตรวจไม่พบหรือพบน้อยมาก ทำให้ค่าฮิวริสติกต่ำ และภาพนาข้าวที่อยู่ใน ระยะต้นกล้า เนื่องจากข้าวในระยะนี้ยังมีการเจริญเติบโตของใบยังไม่เพียงพอที่วิธีการที่เสนอนี้จะ ตรวจหาได้

วิธีการที่เสนอนี้จะใช้ได้ดีกับนาข้าวระยะต่างๆดังนี้คือ ระยะแตกกอ ระยะเจริญเติบโตด้าน การสืบพันธุ์ และระยะเก็บเกี่ยว ส่วนนาข้าวระยะต้นกล้า นาไร่ที่ยังไม่มีการปลูกหรือนาที่มีการเก็บ เกียวแล้ว ไม่สามารถนำมาใช้ได้ เนื่องจากวิธีการที่เสนอเหมาะสมกับภาพนาข้าวที่มีส่วนของสีเขียว และสีเหลืองที่ค่อนข้างชัดเจน

5.2 ข้อเสนอแนะ

จากการทดลองวิธีการที่เสนอนี้พบว่ายังมีสิ่งสมควรปรับปรุงได้ เพื่อให้วิธีการที่เสนอทำงานได้ดียิ่งขึ้นดังต่อไปนี้

1. วิธีการที่เสนอยังใช้เวลาในการประมวลผลช้า (สมรรถนะในการประมวลผล ภาคผนวก ง) ในส่วนของการหาพีเจอร์เชิงพื้นผิว ดังนั้นหากจะเพิ่มสมรรถนะในการคำนวณอาจปรับปรุงวิธีการดังต่อไปนี้

- 1.1. ใช้ GPU ช่วยประมวลผล
- 1.2. ตัดพีเจอร์ที่ไม่จำเป็นออก
- 1.3. ตัดส่วนที่เป็นบริเวณท้องฟ้าในรูปภาพก่อนทำการประมวลผล

2. ความผิดพลาดที่เกิดจากข่างานประสาทเทียม เกิดจากข้อมูลที่ใช้ในการฝึกยังไม่มีความหลากหลายเพียงพอ ดังนั้นควรเก็บข้อมูลในการฝึกให้มีความหลากหลายโดยเฉพาะข้อมูลตัวอย่างของส่วนที่เป็นสีเขียวที่มีลักษณะคล้ายนาข้าว ซึ่งในการทดลองนี้ยังแยกได้บางครั้งเท่านั้น

3. ค่าความถูกต้องในการจำแนกภาพของวิธีการที่นำเสนอ ค่าที่ได้อาจได้ไม่แน่นอนขึ้นอยู่กับ การเก็บข้อมูลเพื่อใช้ในการฝึกของผู้ใช้งาน ซึ่งแต่ละคนจะเก็บข้อมูลได้แตกต่างกัน

4. การใช้ฮิวริสติกในการตัดสินใจว่าภาพนั้นเป็นภาพนาข้าวหรือไม่ อาจทำการนอร์มอลไลซ์ ด้วยขนาดของพื้นที่นาข้าว เพื่อให้จำแนกพื้นที่ของนาข้าวที่มีขนาดแตกต่างกันได้

5. ใช้ภาพถ่ายที่ผ่านเลนส์ NIR (Near Infrared) ซึ่งจะสามารถเห็นส่วนของพืชได้ชัดเจนกว่า

5.3 ประโยชน์ที่คาดว่าจะได้รับ

สามารถนำวิธีการตรวจหาบริเวณนาข้าวนี้ไปใช้เป็นทางเลือกในการตรวจหาการใช้ประโยชน์ที่ดินจากภาพถ่ายที่ได้จากการสำรวจภาคพื้นดินเป็นอีกทางเลือกหนึ่งนอกเหนือจากการสำรวจจากภาพถ่ายทางอากาศได้ (ภาคผนวก จ ตัวอย่างการนำข้อมูลที่ได้จากงานวิจัยนี้ไปใช้ประโยชน์)

รายการอ้างอิง


- [1] สำนักงานเศรษฐกิจการเกษตร. สถิติการเกษตรของประเทศไทย. [Online]; Available from: http://www.oae.go.th/main.php?filename=journal_all.
- [2] Google Maps. Street View. [Online]; Available from: <https://www.google.com/maps/views/streetview?gl=th>.
- [3] Google Maps. About Street View. [Online]; Available from: <https://www.google.com/intl/en/maps/about/behind-the-scenes/streetview/>.
- [4] Food and Agriculture Organization of The United Nations. Top Production. [Online]; Available from: <http://faostat.fao.org/site/339/default.aspx>.
- [5] ประวิตร โสภโณตร และคณะ. พืชเศรษฐกิจ. [Online]; Available from: <http://www.natres.psu.ac.th/Department/PlantScience/510-211/>.
- [6] Gonzalez, R.C. and Woods, R.E., Digital Image Processing. Second Edition. United States of America: Prentice-Hall, 2002.
- [7] Woebbecke, D.M., et al., Color indices for weed identification under various soil, residue, and lighting conditions. Transactions of the American Society of Agricultural Engineers, 1995. 38(1): p. 259-269.
- [8] Kataoka, T., et al. Crop growth estimation system using machine vision. in Advanced Intelligent Mechatronics. 2003.
- [9] Hague, T., Tillett, N.D., and Wheeler, H., Automated Crop and Weed Monitoring in Widely Spaced Cereals. Precision Agriculture, 2006. 7(1): p. 21-32.
- [10] Haralick, R.M., Shanmugam, K., and Dinstein, I.H., Textural Features for Image Classification. Systems, Man and Cybernetics, IEEE Transactions on, 1973. SMC-3(6): p. 610-621.
- [11] Mitchell, T.M., Machine Learning. United States of America: McGraw-Hill, 1997.
- [12] Strozzi, T., et al., Landuse mapping with ERS SAR interferometry. Geoscience and Remote Sensing, IEEE Transactions on, 2000. 38(2): p. 766-775.
- [13] Sarkar, A., et al., A MRF model-based segmentation approach to classification for multispectral imagery. Geoscience and Remote Sensing, IEEE Transactions on, 2002. 40(5): p. 1102-1113.
- [14] Liu, J., et al. Recognition of corn acreage in Jilin province based on mixed pixels decomposition. in Agro-Geoinformatics (Agro-Geoinformatics), 2012 First International Conference on. 2012.

- [15] Gu, X., Dong, Y., and Wang, K. Mapping farmland organic matter using HSI image and its effects of land-use types. in Agro-Geoinformatics (Agro-Geoinformatics), 2012 First International Conference on. 2012.
- [16] Hemming, J. and Rath, T., PA—Precision Agriculture: Computer-Vision-based Weed Identification under Field Conditions using Controlled Lighting. Journal of Agricultural Engineering Research, 2001. 78(3): p. 233-243.
- [17] Philipp, I. and Rath, T., Improving plant discrimination in image processing by use of different colour space transformations. Computers and Electronics in Agriculture, 2002. 35(1): p. 1-15.
- [18] Søggaard, H.T. and Olsen, H.J., Determination of crop rows by image analysis without segmentation. Computers and Electronics in Agriculture, 2003. 38(2): p. 141-158.
- [19] Lee, W.S., Slaughter, D.C., and Giles, D.K., Robotic Weed Control System for Tomatoes. Precision Agriculture, 1999. 1(1): p. 95-113.
- [20] Burks, T.F., Shearer, S.A., and Payne, F.A., Classification of weed species using color texture features and discriminant analysis. Transactions of the American Society of Agricultural Engineers, 2000. 43(2): p. 441-448.
- [21] Meyer, G.E., et al., Intensified fuzzy clusters for classifying plant, soil, and residue regions of interest from color images. Computers and Electronics in Agriculture, 2004. 42(3): p. 161-180.
- [22] Guerrero, J.M., et al., Support Vector Machines for crop/weeds identification in maize fields. Expert Systems with Applications, 2012. 39(12): p. 11149-11155.
- [23] Gée, C., et al., Crop/weed discrimination in perspective agronomic images. Computers and Electronics in Agriculture, 2008. 60(1): p. 49-59.
- [24] Bossu, J., et al., Wavelet transform to discriminate between crop and weed in perspective agronomic images. Computers and Electronics in Agriculture, 2009. 65(1): p. 133-143.
- [25] Google Developers. Google Street View Image API. [Online]; Available from: <https://developers.google.com/maps/documentation/streetview/>.



ภาคผนวก


จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY



ภาคผนวก ก
ภาพผลการทดลองเพิ่มเติม

จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

ตัวอย่างของภาพผลการทดลองเพิ่มเติมพร้อมแสดงค่าฮิสทริกของภาพที่ไม่ใช่หน้าต่างแสดง
 ดังรูปที่ ก-1




รูปที่ ก-1 ภาพผลการทดลองเพิ่มเติมพร้อมแสดงค่าฮิสทริก

ตัวอย่างของภาพผลการทดลองเพิ่มเติมพร้อมแสดงค่าฮิสทริกของภาพที่ไม่ใช่หน้าต่างแสดง
 ดังรูปที่ ก-2




รูปที่ ก-2 ภาพผลการทดลองเพิ่มเติมพร้อมแสดงค่าฮิสทริก

ตัวอย่างของภาพผลการทดลองเพิ่มเติมพร้อมแสดงค่าฮิสโตแกรมของภาพนาข้าว(ระยะแตกกอ)
แสดงดังรูปที่ ก-3




รูปที่ ก-3 ภาพผลการทดลองเพิ่มเติมพร้อมแสดงค่าฮิสโตแกรม

ตัวอย่างของภาพผลการทดลองเพิ่มเติมพร้อมแสดงค่าฮิวริสติกของภาพนาข้าว(ระยะ
เจริญเติบโตด้านการสีพันธุ)แสดงดังรูปที่ ก-4




รูปที่ ก-4 ภาพผลการทดลองเพิ่มเติมพร้อมแสดงค่าฮิวริสติก

ตัวอย่างของภาพผลการทดลองเพิ่มเติมพร้อมแสดงค่าฮิสทริกของภาพนาข้าว(ระยะเก็บเกี่ยว)แสดงดังรูปที่ ก-5



รูปที่ ก-5 ภาพผลการทดลองเพิ่มเติมพร้อมแสดงค่าฮิสทริก



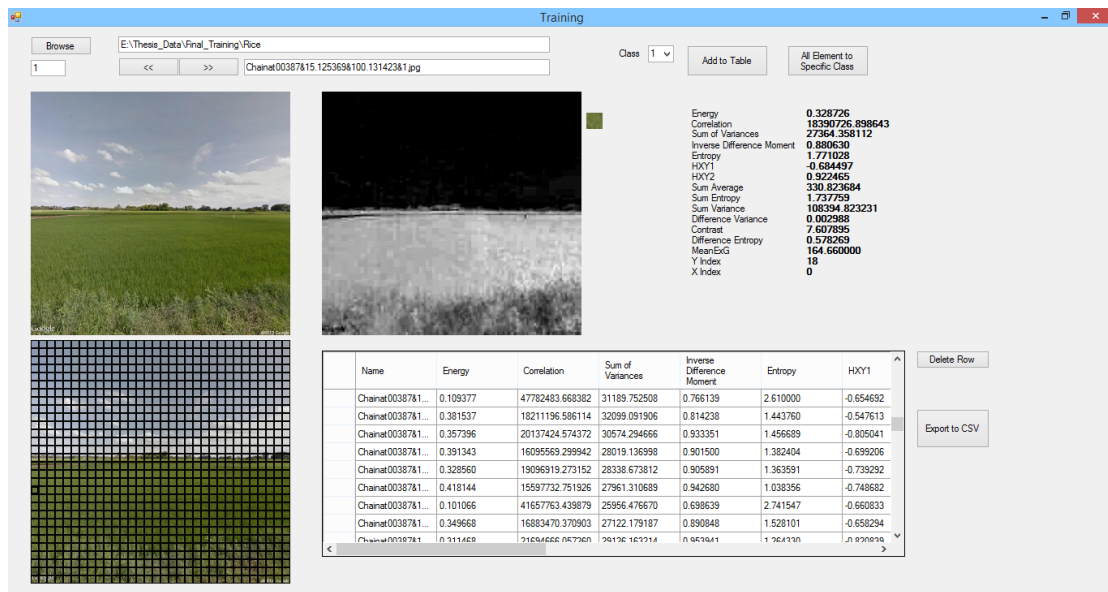
ภาคผนวก ข

โปรแกรมใช้สำหรับเก็บตัวอย่างที่จะใช้ในการฝึก

จุฬาลงกรณ์มหาวิทยาลัย

CHULALONGKORN UNIVERSITY

โปรแกรมใช้สำหรับเก็บตัวอย่างของเซกเมนต์ที่จะใช้ในการฝึก พัฒนาด้วย Microsoft Visual C# 2013 และใช้ Emgu CV เป็นไลบรารีในการประมวลผลภาพ โดยโปรแกรมนี้อาจจะแบ่งเซกเมนต์ของรูปของเป็นขนาดที่เหมาะสมตามที่ได้กำหนดไว้ (20x20 พิกเซล) แสดงภาพที่ผ่านการแปลงเป็นภาพเอ็กเซสกรีน แสดงพีเจอร์ของเซกเมนต์ที่เลือก และจัดเก็บตัวอย่างที่ต้องการใช้ในการฝึกไว้ในฐานข้อมูลได้ ส่วนติดต่อการใช้งานกับผู้ใช้แสดงดังรูปที่ ข-1




รูปที่ ข-1 ส่วนติดต่อผู้ใช้ของโปรแกรมสำหรับเก็บตัวอย่างที่จะใช้ในการฝึก

รายละเอียดการใช้งานแสดงดังต่อไปนี้

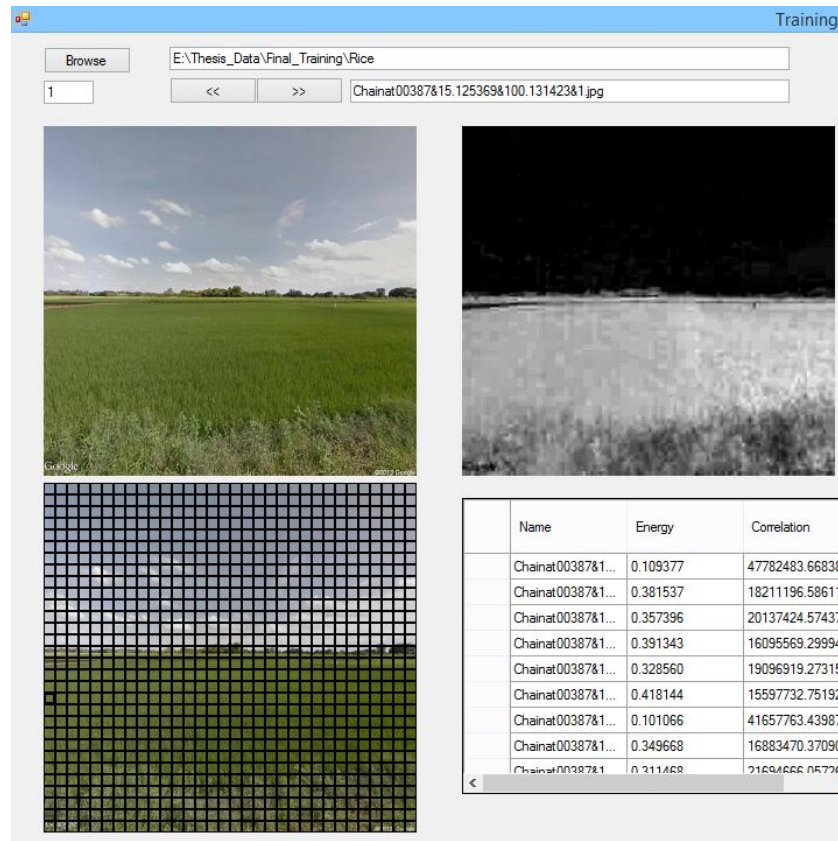
1. เมื่อเริ่มต้นเข้าสู่โปรแกรม ให้ทำการเลือกไดเรกทอรีที่เก็บภาพที่ต้องการจะใช้ในการฝึกดัง

รูปที่ ข-2



รูปที่ ข-2 ส่วนที่ใช้กำหนดไดเรกทอรีที่เก็บภาพ

2. เมื่อเลือกไดเรกทอรีที่ต้องการแล้ว โปรแกรมจะแสดงภาพแรกของไดเรกทอรีที่ได้เลือกมา โดยจะแสดงภาพต้นฉบับ ภาพที่ผ่านการแปลงเป็นภาพเอ็กเซสกรีน และภาพที่ทำการแบ่งเป็นเซกเมนต์เพื่อที่จะได้เลือกเซกเมนต์ที่ต้องการดังรูปที่ ข-3



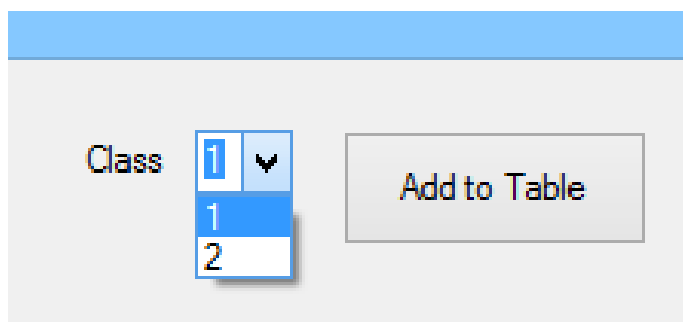
รูปที่ ข-3 ตัวอย่างหน้าจอโปรแกรมเมื่อได้ทำการเลือกไดเรกทอรีที่เก็บภาพแล้ว

3. เมื่อได้ทำการแบ่งเซกเมนต์แล้ว ขั้นตอนต่อไปจะเป็นการเลือกเซกเมนต์ที่ต้องการจะเก็บ โดยเซกเมนต์ที่ได้ทำการเลือกจะแสดงข้อมูลรายละเอียดของพีเจอร์ทั้งหมด ดังรูปที่ ข-4

Energy	0.328726
Correlation	18390726.898643
Sum of Variances	27364.358112
Inverse Difference Moment	0.880630
Entropy	1.771028
HXY1	-0.684497
HXY2	0.922465
Sum Average	330.823684
Sum Entropy	1.737759
Sum Variance	108394.823231
Difference Variance	0.002988
Contrast	7.607895
Difference Entropy	0.578269
MeanExG	164.660000
Y Index	18
X Index	0

รูปที่ ข-4 ส่วนของโปรแกรมเมื่อได้ทำการเลือกเซกเมนต์ที่สนใจ

4. เมื่อได้ตัวอย่างของเซกเมนต์ที่ต้องการแล้ว ขั้นตอนต่อไปคือการจัดเก็บตัวอย่างนั้นโดยต้องกำหนดค่าผลลัพธ์เป้าหมายของตัวอย่างนั้นว่าเป็นนาข้าวหรือไม่ โดยเลือกจาก Drop down list ดังรูปที่ ข-5 โดยที่ถ้าตัวอย่างเซกเมนต์นั้นเป็นนาข้าวให้เลือก Class 1 ถ้าไม่ใช่นาข้าวให้เลือก Class 2




รูปที่ ข-5 ส่วนของโปรแกรมที่ใช้ระบุค่าผลลัพธ์เป้าหมายของเซกเมนต์

5. เมื่อกำหนดค่าผลลัพธ์เป้าหมายแล้ว ให้ทำการเพิ่มตัวอย่างนั้นลงในตารางโดยการเลือกปุ่ม Add to Table ตัวอย่างที่เลือกจะถูกเก็บไว้ในตารางดังรูปที่ ข-6

Name	Energy	Correlation	Sum of Variances	Inverse Difference Moment	Entropy	HXY1
Chainat00387&1...	0.109377	47782483.668382	31189.752508	0.766139	2.610000	-0.654692
Chainat00387&1...	0.381537	18211196.586114	32099.091906	0.814238	1.443760	-0.547613
Chainat00387&1...	0.357396	20137424.574372	30574.294666	0.933351	1.456689	-0.805041
Chainat00387&1...	0.391343	16095569.299942	28019.136998	0.901500	1.382404	-0.699206
Chainat00387&1...	0.328560	19096919.273152	28338.673812	0.905891	1.363591	-0.739292
Chainat00387&1...	0.418144	15597732.751926	27961.310689	0.942680	1.038356	-0.749682
Chainat00387&1...	0.101066	41657763.439879	25956.476670	0.698639	2.741547	-0.660833
Chainat00387&1...	0.349668	16883470.370903	27122.179187	0.890848	1.528101	-0.658294
Chainat00387&1...	0.211468	21694666.057260	29126.163214	0.951941	1.264330	-0.820636

รูปที่ ข-6 ส่วนของโปรแกรมที่เก็บค่าตัวอย่างที่จะใช้ในการฝึกทั้งหมด

6. เมื่อได้ตัวอย่างที่ต้องการครบแล้ว ต้องการเปลี่ยนภาพถัดไปหรือย้อนกลับไปภาพก่อนหน้านี้สามารถเลือกปุ่ม ดังรูปที่ ข-7 ซึ่งจะแสดงชื่อไฟล์ปัจจุบันที่กำลังเลือกอยู่ด้วย



รูปที่ ข-7 ส่วนของโปรแกรมที่ใช้ในการเลือกรูปถัดไปหรือก่อนหน้า


7. เมื่อได้ตัวอย่างของเซกเมนต์ในแต่ละภาพครบทุกภาพแล้ว ขั้นตอนสุดท้ายจะเป็นการนำข้อมูลออก (Export) เพื่อใช้เป็นข้อมูลตัวอย่างที่ใช้สำหรับฝึกในโปรแกรมสำหรับทดสอบรูปภาพต่อไป

โดยเลือกที่ปุ่ม Export เพื่อบันทึกข้อมูลเป็นไฟล์นามสกุล CSV (Comma-Separated Values) ตัวอย่างไฟล์ข้อมูลตัวอย่างที่ใช้ในการฝึกที่ได้แสดงดังรูปที่ ข-8

Name	Energy	Correlation	Sum of Variance	Inverse Diagonal	Entropy	HXY1	HXY2	Sum Average	Sum Entropy	Sum Variance	Difference Contrast	Difference Contrast	Mean ExG	Y Index	Class	
Ayutthaya00	0.055429	57314928	26455.63	0.628825	3.324564	-0.5474	0.958993	324.8184	2.860529	103898.5	0.001523	21.97105	1.427328	161.6075	20	1
Anghthong01	0.47151	8562.23	17.48412	0.966885	0.940949	-0.81318	0.857097	6.105263	0.940949	56.74327	0.003597	0.821053	0.182935	2.025	5	2
Chonburi010	0.011607	31134544	5458.84	0.334185	4.857264	-0.49882	0.980798	142.6053	4.185382	20271.76	0.000513	67.08421	2.477776	70.7425	18	2
Ayutthaya01	0.016981	1.93E+08	21435.54	0.559553	4.651749	-0.76894	0.998563	234.8105	4.354388	83158.1	0.001238	36.22632	1.69859	116.45	16	2
Uthaihani01	0.171537	32316036	26362.08	0.857974	2.314707	-0.76822	0.972273	323.3789	2.253841	103499.7	0.002862	11.7	0.57357	160.6775	18	1
Ayutthaya01	1	257	0.999969	1	0	0	0	2	0	4	0.003876	0	0	0	27	2
Chachoengs	0.97392	276.9538	1.084179	0.993684	0.083935	-0.35198	0.200703	2.036842	0.07891	3.947931	0.003815	0.031579	0.046086	0.02	23	2
Anghthong00	0.084986	840440.3	462.0574	0.49435	3.716189	-0.50551	0.959784	32.32368	3.295302	1626.55	0.000962	38.38684	1.987057	14.6025	27	2
Anghthong00	0.009294	82525812	6074.624	0.358253	5.100529	-0.73461	0.998711	135.5868	4.642513	22853.58	0.000489	53.93421	2.461501	66.81	18	2
Uthaihani01	0.006925	19939809	2613.486	0.166158	5.18248	-0.50559	0.985272	85.76842	4.370577	9195.708	0.000336	184.1947	2.695111	42.4175	24	2
Pathumthani	0.06097	290395	160.7629	0.49215	3.664531	-0.34937	0.888019	20.09211	3.045655	515.9125	0.000967	21.81316	1.779427	9.2025	20	2
Ayutthaya00	0.225997	29571.7	36.59459	0.825359	1.788095	-0.59167	0.885448	9.565789	1.710936	119.6549	0.00258	6.039474	0.744079	3.965	6	2
Uthaihani00	1	257	0.999969	1	0	0	0	2	0	4	0.003876	0	0	0	2	2
Anghthong1	0.030166	22571155	5720.685	0.470565	4.180199	-0.60643	0.988023	149.5105	3.844714	21964.86	0.000882	39.01579	2.056125	72.8425	22	2
Nakhonpath	0.058296	24508014	11297.96	0.548699	3.360541	-0.5941	0.972227	207.8026	3.100816	43148.99	0.001255	62.61842	1.707161	103.295	17	2
Ayutthaya00	0.278587	35020.68	43.54197	0.876924	1.714735	-0.73674	0.930068	9.171053	1.714735	155.1122	0.002925	2.718421	0.574319	3.6975	12	2
Anghthong00	0.116593	8893821	5531.914	0.780322	2.724068	-0.71768	0.976686	146.9947	2.491721	21527.32	0.002354	21.25263	0.954246	72.5125	16	1
Ayutthaya01	0.149183	19998462	14125.53	0.870735	2.338658	-0.77711	0.975134	236.7658	2.28908	55533.25	0.002898	7.776316	0.648307	117.435	20	2
Pathumthani	1	257	0.999969	1	0	0	0	2	0	4	0.003876	0	0	0	25	2
Anghthong1	0.032119	5479445	1561.786	0.594014	3.858311	-0.61453	0.983861	77.38421	3.576369	5844.608	0.001215	12.63158	1.65098	37.6975	25	2
Chachoengs	0.042673	17105197	4910.162	0.568054	4.000156	-0.65782	0.990111	100.6921	3.672473	18899.04	0.001226	22.55526	1.705977	49.2925	14	2
Uthaihani00	0.095526	15152927	9081.516	0.66598	2.797325	-0.60644	0.955443	189.0632	2.560195	35417.58	0.001779	21.63684	1.172544	93.3025	22	2

รูปที่ ข-8 ตัวอย่างของไฟล์ (CSV) ของข้อมูลที่จะใช้ในการฝึก

จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

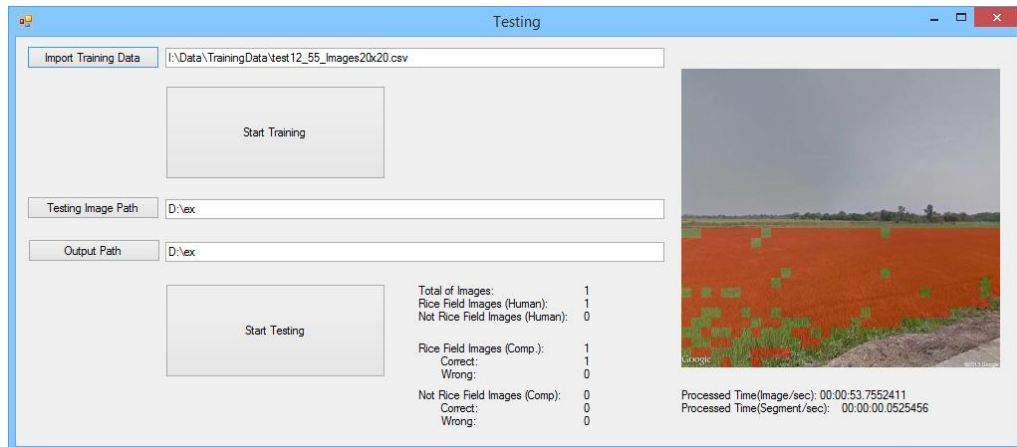


ภาคผนวก ค

โปรแกรมสำหรับใช้ฝึกข่างานประสาทเทียมและใช้ทดสอบรูปภาพ

จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY


เมื่อได้ข้อมูลตัวอย่างที่จะใช้ในการฝึกแล้ว ขั้นตอนต่อไปจะเป็นการนำข้อมูลมาฝึกในข่ายงานประสาทเทียม โดยใช้โปรแกรมที่พัฒนาขึ้นสำหรับฝึกข่ายงานประสาทเทียมและใช้ทดสอบรูปภาพ ส่วนติดต่อการใช้งานกับผู้ใช้แสดงดังรูปที่ ค-1



รูปที่ ค-1 ส่วนติดต่อผู้ใช้งานของโปรแกรม

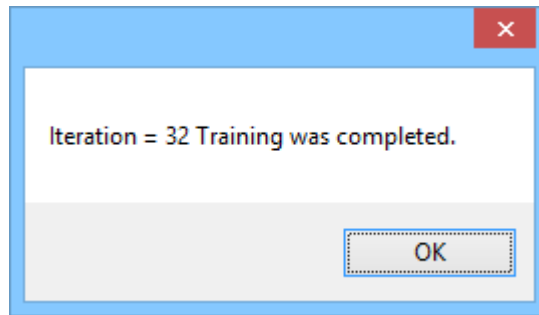
รายละเอียดการใช้งานแสดงดังต่อไปนี้

1. นำเข้าข้อมูลตัวอย่างของเซกเมนต์ที่จะใช้ในการฝึก (ไฟล์ .csv) จากโปรแกรมในภาคผนวก ข โดยเลือกที่ปุ่ม Import Training Data แล้วเลือกไฟล์ที่เก็บตัวอย่างของข้อมูลในการฝึกดังรูปที่ ค-2



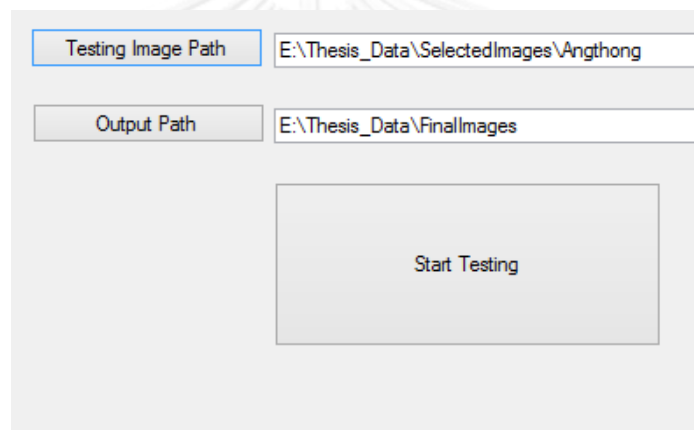
รูปที่ ค-2 ไดอะล็อกที่เก็บไฟล์ (CSV) สำหรับฝึกในข่ายงานประสาทเทียม

2. เริ่มต้นการฝึกข่ายงานประสาทเทียมโดยเลือกปุ่ม Start Training จากนั้นให้รอโปรแกรมจนกระทั่งโปรแกรมทำการฝึกจนเสร็จจะขึ้นหน้าต่างแสดงจำนวนรอบในการฝึกดังรูปที่ ค-3




รูปที่ ค-3 หน้าต่างแจ้งเตือนเมื่อทำฝึกสำเร็จ

3. เมื่อได้ทำการฝึกข่ายงานประสาทเทียมแล้ว ขั้นตอนต่อไปจะเป็นการทดสอบรูปภาพ โดยต้องทำการระบุไดเรกทอรีของภาพที่ต้องการทดสอบ และระบุไดเรกทอรีปลายทางที่จะเก็บภาพทดสอบที่ได้ทำการประมวลผลแล้วดังรูปที่ ค-4




รูปที่ ค-4 ส่วนของโปรแกรมที่ใช้ระบุไดเรกทอรีต้นทางและปลายทางของภาพที่ต้องการทดสอบ

4. ขั้นตอนสุดท้ายคือการเริ่มทดสอบรูปภาพโดยเลือกที่ปุ่ม Start Testing โดยโปรแกรมจะแสดงภาพที่กำลังประมวลผลแบบเรียลไทม์ และแสดงรายละเอียดการจำแนกภาพดังรูปที่ ค-5



รูปที่ ค-5 ส่วนของโปรแกรมที่แสดงภาพขณะประมวลผล



ภาคผนวก ง

สมรรถนะในการประมวลผลของวิธีการที่เสนอ

จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

เครื่องมือที่ใช้ในการประมวลผลประกอบด้วยส่วนของชุดข้อมูลภาพนำเข้า (Input Images) ชุดคำสั่ง (Software) และส่วนของฮาร์ดแวร์ (Hardware) โดยรายละเอียดของเครื่องมือที่ใช้ในการประมวลผลจะแสดงดังต่อไปนี้

ภาพที่ใช้ในการประมวลผล

- ใช้ภาพถ่ายจากกรถสำรวจของ Google Street View โดยใช้ Google Street View API เป็นเครื่องมือในการดึงภาพออกมาใช้

- ความละเอียดของภาพ 640x600 พิกเซล
- รูปแบบของไฟล์ภาพคือ JPEG และเป็นภาพสีที่มีความลึก 24 บิต (RGB)


ซอฟต์แวร์

- Microsoft Windows 8.1 Professional
- Microsoft Visual Studio C# 2013
- EmguCV (Image processing library for .NET)
- Google Street View API (Tool for accessing an image from Google Street View)


ฮาร์ดแวร์

- หน่วยประมวลผล Intel Core i5-450M / 2.4 GHz (Dual-Core)
- หน่วยความจำ 4.0 GB

การประมวลผลโดยใช้ภาพทดสอบจำนวน 600 ภาพ โดยใช้สภาพแวดล้อมตามข้างต้นในการประมวลผลภาพ สมรรถนะในการประมวลผลแสดงได้ดังรูปที่ ง-1 ค่าเฉลี่ยในการประมวลผลจะอยู่ที่ประมาณ 52 วินาทีต่อ 1 ภาพ



รูปที่ ง-1 กราฟแสดงเวลาในการประมวลผล



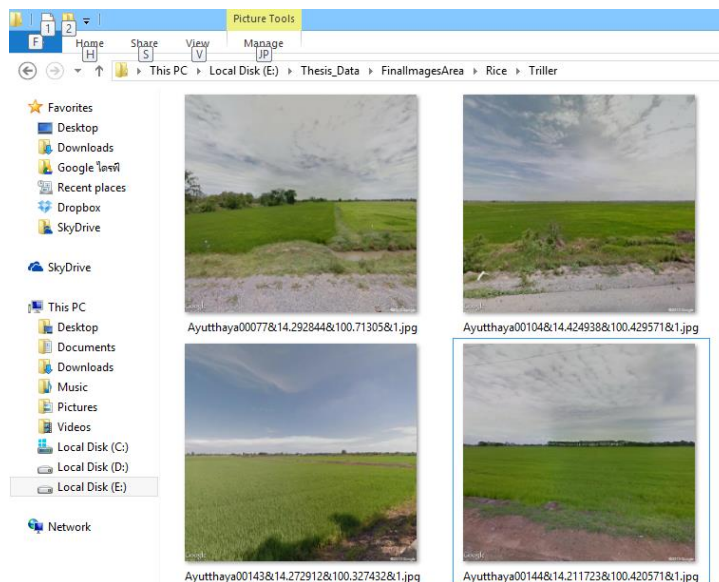
ภาคผนวก จ

ตัวอย่างการนำข้อมูลที่ได้จากวิธีการที่เสนอไปใช้ประโยชน์

จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

เนื่องจากการเก็บรูปภาพจะมีการเก็บข้อมูลพิกัด (ละติจูด ลองจิจูด) มาด้วย ดังรูปที่ จ-1 โดยภาพในตัวอย่างที่เก็บมาจะมีการบันทึกข้อมูลในชื่อไฟล์ของภาพ ประกอบด้วย ชื่อจังหวัด หมายเลขภาพ ค่าละติจูด และลองจิจูด คั่นด้วยเครื่องหมาย & ตัวอย่างเช่น

“Ayutthaya00005&14.413142&100.736717&1.jpg”



รูปที่ จ-1 ตัวอย่างไฟล์ภาพที่เก็บมาพร้อมระบุตำแหน่งพิกัด


ดังนั้นเมื่อนำรูปภาพไปประมวลผลด้วยวิธีการที่เสนอแล้วจะได้ผลลัพธ์ว่าภาพนี้เป็นภาพนาข้าวหรือไม่ สามารถนำข้อมูลเหล่านี้มาใช้ประโยชน์ในการระบุพิกัดการใช้ประโยชน์ที่ดินในการทำนาข้าวได้ ในตัวอย่างนี้จะใช้ชุดข้อมูลภาพที่ผ่านการประมวลผลแล้วนำมาระบุพิกัดโดยเก็บในรูปแบบไฟล์นามสกุล CSV ที่เก็บค่าพารามิเตอร์ต่างๆของภาพที่เป็นนาข้าว ประกอบด้วย ชื่อภาพ ละติจูด ลองจิจูด และค่าฮิวริสติกของภาพนั้น ตัวอย่างของไฟล์นามสกุล CSV ที่ใช้ในการระบุพิกัดการใช้ประโยชน์ที่ดินในการทำนาข้าวดังรูปที่ จ-2

	A	B	C	D	E	F
1	Angthong00114	14.6494	100.4005	10.42857		
2	Angthong01503	14.69851	100.3346	10.5		
3	Angthong00053	14.53724	100.4627	11.6		
4	Angthong00941	14.69904	100.3345	12.4		
5	Angthong00190	14.73594	100.2461	14.6		
6	Angthong00005	14.62666	100.3037	15.14286		
7	Angthong00327	14.65258	100.4313	15.33333		
8	Angthong00894	14.70299	100.2913	16.2		
9	Angthong01496	14.64641	100.4206	16.25		
10	Angthong00674	14.70619	100.2599	16.66667		
11	Angthong00524	14.59364	100.31	16.71428		
12	Angthong01214	14.68131	100.3398	18.28572		

รูปที่ จ-2 ตัวอย่างไฟล์ที่เก็บตำแหน่งของภาพที่ประมวลผลแล้ว และให้ผลลัพธ์ว่าเป็นภาพนาข้าว


เมื่อนำไฟล์ดังกล่าวมานำเข้าข้อมูล (Import) ใน Maps Engine ที่พัฒนาโดย Google ผลที่ได้จะแสดงดังต่อไปนี้

ตัวอย่างการแสดงผลการใช้ประโยชน์ที่ดินในการทำนาข้าวของจังหวัดอ่างทอง แสดงดังรูปที่ จ-3




รูปที่ จ-3 ภาพแสดงพิกัดที่มีนาข้าวของจังหวัดอ่างทอง

ตัวอย่างการแสดงผลการใช้ประโยชน์ที่ดินในการทำนาข้าวของจังหวัดพระนครศรีอยุธยา แสดงดังรูปที่ จ-4




รูปที่ จ-4 ภาพแสดงพิกัดที่มีนาข้าวของจังหวัดพระนครศรีอยุธยา

ตัวอย่างการแสดงผลการค้นหาใช้ประโยชน์ที่ดินในการทำนาข้าวของจังหวัดฉะเชิงเทรา แสดงดังรูปที่ จ-5




รูปที่ จ-5 ภาพแสดงพิกัดที่มีนาข้าวของจังหวัดฉะเชิงเทรา

ตัวอย่างการแสดงผลการค้นหาใช้ประโยชน์ที่ดินในการทำนาข้าวของจังหวัดชัยนาท แสดงดังรูปที่ จ-6




รูปที่ จ-6 ภาพแสดงพิกัดที่มีนาข้าวของจังหวัดชัยนาท

ตัวอย่างการแสดงพิภดการใช้ประโยชน์ที่ดินในการทำนาข้าวของจังหวัดเชียงราย แสดงดังรูปที่ จ-7




รูปที่ จ-7 ภาพแสดงพิภดที่มีนาข้าวของจังหวัดเชียงราย

ตัวอย่างการแสดงพิภดการใช้ประโยชน์ที่ดินในการทำนาข้าวของจังหวัดชลบุรี แสดงดังรูปที่ จ-8




รูปที่ จ-8 ภาพแสดงพิภดที่มีนาข้าวของจังหวัดชลบุรี

ตัวอย่างการแสดงผลการค้นหาใช้ประโยชน์ที่ดินในการทำนาข้าวของจังหวัดนครปฐม แสดงดังรูปที่ จ-9




รูปที่ จ-9 ภาพแสดงพิกัดที่มีนาข้าวของจังหวัดนครปฐม

ตัวอย่างการแสดงผลการค้นหาใช้ประโยชน์ที่ดินในการทำนาข้าวของจังหวัดปทุมธานี แสดงดังรูปที่ จ-10




รูปที่ จ-10 ภาพแสดงพิกัดที่มีนาข้าวของจังหวัดปทุมธานี

ตัวอย่างการแสดงผลการค้นหาใช้ประโยชน์ที่ดินในการทำนาข้าวของจังหวัดสุพรรณบุรี แสดงดังรูปที่ จ-11



รูปที่ จ-11 ภาพแสดงพิกัดที่มีนาข้าวของจังหวัดสุพรรณบุรี

ตัวอย่างการแสดงผลการค้นหาใช้ประโยชน์ที่ดินในการทำนาข้าวของจังหวัดอุทัยธานี แสดงดังรูปที่ จ-12



รูปที่ จ-12 ภาพแสดงพิกัดที่มีนาข้าวของจังหวัดอุทัยธานี



ภาคผนวก ฉ

บทความที่เสนอในงานประชุมวิชาการ

จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

บทความเรื่อง “Rice Field Detection from Terrestrial Images” เสนอในงานประชุมวิชาการ 2014 International Workshop on Advanced Image Technology (IWAIT2014), The Sukosol Hotel, Bangkok, Thailand จัดระหว่างวันที่ 6-8 มกราคม พ.ศ. 2557 บทความนี้ตีพิมพ์ไว้ใน Proceeding of 2014 International Workshop on Advanced Image Technology หน้า 197-200



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

Rice Field Detection from Terrestrial Images

Chaya Wanlor

Department of Computer Engineering
Chulalongkorn University
Pathumwan, Bangkok 10330, Thailand
Chaya.W@student.chula.ac.th

Suebskul Phiphobmongkol

Department of Computer Engineering
Chulalongkorn University
Pathumwan, Bangkok 10330, Thailand
Suebskul.p@chula.ac.th

Abstract— This paper presents a method to detect the rice field region in images by using digital image processing techniques and artificial neural network. The proposed method was applied to terrestrial images taken in Thailand. In the method, each image was divided into segments. The features of each segment were extracted and fed to the artificial neural network. The features include texture, color, and position. Artificial neural network was then used to classify each segment to determine whether a segment was a region of a rice field or not. A heuristic function was then applied to the classified segments of the image to determine a value that represented how much these segments were connected. Two hundred images were processed to find the heuristic values, an appropriate threshold was then determined. Other six hundred images were tested with the proposed method. The result showed about 99% accuracy for rice detection and about 96% accuracy for non-rice detection.

Keywords— Land use; Rice Field; Artificial Neural Network; Digital Image Processing.

I. INTRODUCTION


Rice is one of most important economic crops in Thailand. There are about 9.6 million hectares of rice fields in Thailand. There are two methods which are normally applied to the land use survey. The first method is Remote Sensing. In this method, images were taken from satellites or airplanes. Then, the land-use mapping is done by digital image processing. Images from this method may not be acquired frequently due to the high cost of survey. This method is suitable for the non-frequent survey. The second method is human visual inspection. This method required inspectors to go to the fields and can take a longer survey time.

Nowadays, many organization use survey vehicles to collect images and other data. The images were taken automatically from cameras installed on a vehicle roof. This paper will use image data from this survey method to detect rice field in Thailand

Many of field crop land use detection techniques have been proposed. Most methods were applied to satellite or aerial images. Sarkar et al. [1] used Markov Random Field (MRF) to classify tonal and textural features by extracting them from multispectral images. Jia et al. [2] applied mixed-pixel decomposition model to classify the EOS-MODIS NDVI time series data from satellite images. Xiaohe et al. [3] applied multiple linear regressions to predict model of organic matter in HJ-1A HSI image. There are methods that used terrestrial

images as inputs. Guerrero et al. [4] proposed a method based on greenness identification to extract features and used Support Vector Machines to classify masked and unmasked plants. Gée et al. [5] proposed a method that detected crop rows in images using double Hough transform (DHT). The method could discriminate between crops and weeds by a region-based segmentation method using a blob coloring analysis.

This paper proposed a method for rice field detection which was applied to terrestrial images of 640x600 resolution. In the method, each image was divided into small segments. The features of each segment, which include texture, color, and position, were classified by Artificial Neural Network (ANN). Rice fields can be in many stages. Figure 1 shows various stages of rice fields.



II. OBJECTIVE

The objective of this research is to develop an automatic rice field detection method to be applied to terrestrial images taken in Thailand.

III. THE PROPOSED METHOD

The proposed method consists of five phases. The first phase is the pre-processing phase which is used to divide an image into segments. The second phase is the green crop segmentation. The third phase is the feature extraction. The fourth phase is classification. The last phase is rice field image verification. The process of proposed method is shown in Figure 2.





Fig. 2 Flow chart of the proposed method

A. Pre-Processing Phase

In this phase, images were divided into small segments. A larger segment contains too much information while a smaller segment contains fewer information of the rice field. In the latter case, ambiguity occurs between rice field segments and other green plants segment. Figure 3 shows segmented images of two different sizes, 80x80 and 20x20, respectively. In this paper, a segment size of 20x20 were used due to its good result and can divide 640x600 evenly.



(a) Location 14.133413, 100.461559 (b) Location 14.133413, 100.461559

Fig. 3 Examples of two segment sizes [6]

(a) 80x80 pixels (b) 20x20 pixels

B. Green Crop Segmentation Phase


In this phase, Excess Green index (ExG) of Woebbecke et al. [7] was used. This technique is suitable for images captured under different lighting conditions. The equations are shown below. In equation (1), g , r , and b represent green, red, and blue intensity of a pixel, respectively.

$$ExG = 2g - r - b \quad (1)$$

Each ExG is quantized to 256 gray levels as follows.

$$GrayLevel = 255 \times \frac{ExG - ExG_{min}}{ExG_{max} - ExG_{min}} \quad (2)$$

A sample RGB image is shown in Figure 4(a). The image after applying excess green index and quantized to 256 gray levels is shown in Figure 4(b)



(a) Location 14.160046, 100.37487 (b) Location 14.160046, 100.37487

Fig. 4 RGB images with Green Crop Segmentation [6]

(a) Original RGB image (b) Green Crop Segmentation image

C. Feature Extraction Phase

In this phase, there are three main features: Color, Texture, and Position

- Color Feature

Color feature has only one feature, f_1 , whose value is an average of the excess green values in a segment.

$$f_1 : \text{Mean of Excess Green}$$

- Textural Feature

Textural feature has 13 features, f_2 - f_{14} . To calculate these features, Gray Level Co-occurrence Matrix [8] must be used. Gray Level Co-occurrence Matrix is one of the simplest approaches for describing texture. It uses statistical moments of the intensity histogram of an image or region. In 1973, Haralick [9] introduced statistical features which are generated by calculating from co-occurrence matrices. The process used a direction parameter and a distance parameter. In this paper, direction parameter value is set to 0° and the distance parameter value is set to 1. These features are listed as follows,

$$f_2 : \text{Angular Second Moment}$$

$$f_3 : \text{Contrast}$$

$$f_4 : \text{Correlation}$$

$$f_5 : \text{Sum of Squares or Variance}$$

$$f_6 : \text{Inverse Difference Moment}$$


$$f_7 : \text{Sum Average}$$

- f_8 : Sum Variance
- f_9 : Sum Entropy
- f_{10} : Entropy
- f_{11} : Difference Variance
- f_{12} : Difference Entropy
- f_{13} : Information Measures of Correlation 1
- f_{14} : Information Measures of Correlation 2

- Position Feature

The Position feature has only one feature, f_{15} . This feature is the vertical index of a segment in an image. For example, in Figure 5, the vertical index varies from 0 to 6.

f_{15} : Vertical segment index



Location 14.133413, 100.461559

Fig. 5 Vertical Index [6]

D. Classification Phase

In this phase, all 15 features were fed to ANN. And ANN model was constructed by 3 layers including 15 input nodes, 10 hidden nodes, and 1 output node. The Binary Classification of the ANN is shown in Figure 6





Fig. 6. The Binary Classification of the ANN

The training algorithm that was used is Back-propagation algorithm. Figure 7 shows the result after the classification process with 55 training images, including various rice fields and non-rice field images. A non-rice field image result is shown in Figure 7(a), and a rice field image result shown in Figure 7(b)



(a) Location 14.151245, 100.50010 (b) Location 14.24153, 100.78509

Fig. 7 Resulting Image after Classification Process [6]

(a) Non-Rice Field Image

(b) Rice Field Image

E. Rice Field Image Verification Phase

In this phase, a heuristic function was applied to the classified segments of an image to determine a value that represented how much these segments were connected. The heuristic function is defined as follows


$$\text{Heuristic Value} = \frac{S}{C} \quad (3)$$

where

S : The total number of labeled segments (segments classified as rice).

C : The total number of connected labeled segments.

Figure 8 shows examples of two images after classification process. In Figure 8 (a), labeled segments are scattered while in Figure 8 (b), labeled segments are connected. The heuristic value in Figure 8 (a) is 1.33 while the heuristic value in Figure 8 (b) is 80.



(a) (b)

Fig. 8 Example of a Connected Labeled Segment in an Image


(a) Scattered Segments (b) Connected Segments

IV. EXPERIMENTAL RESULTS

Applying the proposed method to testing images with 20 training images. The testing images contain tiller stage and reproductive growth stage. The experiment was not tried with the harvest maturity stage due to the lack of images at the time

2014 International Workshop on Advanced Image Technology

of the experiment. The seedling stage was not tried because the proposed method does not suit the seedling stage due to small portion of green leaves in an image. The result images are shown in Figure 9.



Two hundred images were processed to find heuristic values. An appropriate threshold was then determined from the heuristic values. The threshold was used for deciding which image is a rice field image or not. In this paper threshold value is 11.00. The classification results of other six hundred images were shown in Table 1.

TABLE I. RESULT ON TESTING IMAGES

	Total	True	False
Non-Rice Field Images	406	393 96.8%	13 3.2%
Rice Field Images	194	193 99.5%	1 0.5%

V. DISCUSSION AND CONCLUSION

For the 194 rice field images, there was only one image that the program detected as non-rice. In this case, the rice had light brown dry-like color. The stalk fell down to the ground. This situation make the features more like dry grass. For the 406 non-rice field images, there were 13 images that the program detected as rice. Actually, the plants in all 13 images were lawn grass in front of buildings.

In summary, this research applied rice field detection method by using terrestrial images taken from various places and time from Google Street View [6]. The result showed about 99% accuracy for rice detection of tiller stage to reproductive growth stage and about 96% accuracy for non-rice detection. The proposed method does not suit the seedling stage due to small portion of green leaves in an image. The method was not tested with the harvest maturity stage due to the lack of images at the time of the experiment. It is planned to be tested in the near future.

REFERENCES

- [1] A. Sarkar, M.K. Biswas, B. Kartikeyan, V. Kumar, K.L. Majumder, and D.K. Pal, "A MRF model-based segmentation approach to classification for multispectral imagery," *IEEE Trans. Geosci. and Remote Sens.*, vol.40, no.5, pp.1102-1113, May. 2002
- [2] L. Jia, W. Limin, H. Yan, Y. Fugang, L. Dandan, and W. Xiaolong, "Recognition of corn acreage in Jilin province based on mixed pixels decomposition," *2012 First International Conference. Agro-GeoInformatics.*, pp.1-5, Aug. 2012
- [3] G. Xiaohu, D. Yansheng, and W. Kun, "Mapping farmland organic matter using HSI image and its effects of land-use types," *2012 First International Conference. Agro-GeoInformatics.*, pp.1-4, Aug. 2012
- [4] J.M. Guerrero, G. Pajares, M. Montalvo, J. Romeo, and M. Guijarro, "Support vector machines for crop/weeds identification in maize fields," *Expert Systems with Applications*, vol.39, no.12, pp.11149-11155, Sep. 2012
- [5] Ch. Gée, J. Bossu, G. Jones, and F. Truchetet, "Crop/weed discrimination in perspective agronomic images," *Computers and Electronics in Agriculture*, vol.60, no.1, pp.49-59, Jan. 2008
- [6] Google, Street View, <http://maps.google.co.th/help/maps/streetview/>, accessed Sep 7th 2013.
- [7] D.M. Woebbecke, G.E. Meyer, K.V. Bargen, and D.A. Mortensen, "Color indices for weed identification under various soil, residue, and lightning conditions", *Trans. Am. Soc. Agric. Eng.*, vol.38, no.1, pp. 259-269, 1995
- [8] R.C. Gonzalez, and R.E. Woods, *Digital Image Processing*, 3rd ed. Prentice Hall, 2008
- [9] R.M. Haralick, K. Shanmugam, and I. Dinstein, "Textural features for image classification," *IEEE Trans. Systems, Man, and Cybernetics*, vol. 3, no.6, pp.610-621, 1973

ประวัติผู้เขียนวิทยานิพนธ์

นายชญาน์ แหวนหล่อ เกิดวันที่ 7 สิงหาคม พ.ศ. 2531 ที่จังหวัดร้อยเอ็ด สำเร็จการศึกษา
ระดับปริญญาตรีวิศวกรรมศาสตรบัณฑิต ภาควิชาวิศวกรรมคอมพิวเตอร์ คณะวิศวกรรมศาสตร์
มหาวิทยาลัยขอนแก่น หลังจากนั้นได้เข้าศึกษาต่อในหลักสูตรวิศวกรรมศาสตรมหาบัณฑิต สาขา
วิศวกรรมคอมพิวเตอร์ คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย ในปีการศึกษา 2554



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY