



บันทึกข้อความ

ส่วนราชการ ภาควิชาวิศวกรรมไฟฟ้า คณะวิศวกรรมศาสตร์ มหาวิทยาลัยอุบลราชธานี โทร. 3329

ที่ ศธ 0529.8.6/พิเศษ

วันที่ 24 มกราคม 2554

เรื่อง ขออนุมัติค่าตอบแทนการตีพิมพ์ผลงานในวารสารวิชาการเรื่อง การจำแนกชิ้นงานที่ผลิตในโรงงานอุตสาหกรรมโดยใช้โครงข่ายประสาทเทียม

เรียน รองคณบดีฝ่ายวิจัยและบริการวิชาการ ผ่านหัวหน้าภาควิชาวิศวกรรมไฟฟ้า

อ้างถึงประกาศฉบับที่ 40/2550 ประกาศ ณ วันที่ 22 ตุลาคม 2550 คณะวิศวกรรมศาสตร์ เรื่อง “หลักเกณฑ์การจ่ายค่าตอบแทนการตีพิมพ์ผลงานวารสารวิชาการ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยอุบลราชธานี” ตามความทราบแล้วนั้น

เนื่องจากบทความทางวิชาการของ ดร.ศุภฤกษ์ จันทร์จรัสจิตต์ เรื่อง “การจำแนกชิ้นงานที่ผลิตในโรงงานอุตสาหกรรมโดยใช้โครงข่ายประสาทเทียม” ได้รับการตีพิมพ์ในวารสารวิชาการ วิศวกรรมศาสตร์ ม.อบ. ปีที่ 2 ฉบับที่ 1 หน้า 46-58 ดังนั้นภาควิชาวิศวกรรมไฟฟ้าและอิเล็กทรอนิกส์ จึงใคร่ขออนุมัติค่าตอบแทนการตีพิมพ์ผลงานในวารสารวิชาการในเรื่องดังกล่าว

จึงเรียนมาเพื่อโปรดพิจารณา

(ดร.ศุภฤกษ์ จันทร์จรัสจิตต์)

อาจารย์ประจำภาควิชาวิศวกรรมวิศวกรรมไฟฟ้าและอิเล็กทรอนิกส์

เรียน รองคณบดีฝ่ายวิจัย ๑

เพื่อ T. J. อ. อ. อ.

24 ม.ค. 54

แบบเสนอขอรับค่าตอบแทนในการตีพิมพ์วารสารวิชาการ

1. เอกสารประกอบการเสนอขอรับค่าตอบแทนในการตีพิมพ์วารสารวิชาการ

- X 1.1 แบบขอรับค่าตอบแทน
- 1.2 หนังสือขออนุมัติค่าตอบแทน เรียน รองคณบดีฝ่ายวิจัยและบริการวิชาการผ่านหัวหน้าภาควิชา
- 1.3 สำเนาบทความวิจัยที่ได้รับการตีพิมพ์ในวารสารวิชาการ
- 1.4 รายละเอียดวารสาร
- 1.5 เอกสารแสดงค่า Impact factor ของวารสารที่ตีพิมพ์

2. รายละเอียดข้อมูลประกอบเสนอขอรับค่าตอบแทนในการตีพิมพ์วารสารวิชาการ

- 2.1 ผู้เสนอขอรับค่าตอบแทน ชื่อ-สกุล นายศุภฤกษ์ จันทรจักรจิตต์
- 2.2 ชื่อบทความวิจัย (ภาษาไทย) การจำแนกชิ้นงานที่ผลิตในโรงงานอุตสาหกรรมโดยใช้โครงข่ายประสาทเทียม
(ภาษาอังกฤษ) Classification of Manufactured Objects Using Artificial Neural Network

2.3 รายละเอียดของวารสาร

ชื่อวารสาร วารสารวิชาการ วิศวกรรมศาสตร์ ม.อบ.

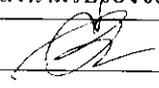
ปีที่ 2 ฉบับที่ 1

ปี 2552 หน้า-หน้า 46-58

2.5 สถานะในบทความวิจัยเป็น

- X ชื่อแรก (first author)
- X ผู้รับผิดชอบบทความ (corresponding author)
- ผู้มีส่วนร่วมในบทความ

การรับรองสัดส่วนผลงานทางวิชาการ กรุณากรอกข้อมูลตามแบบฟอร์มนี้ตามความเป็นจริง และรักษาไว้ซึ่งจรรยาบรรณ และขอรับรองว่า บทความนี้ไม่เป็นส่วนหนึ่งของวิทยานิพนธ์ของผู้เสนอขอรับค่าตอบแทน

ลำดับที่	ชื่อ-สกุล	สัดส่วนผลงานทางวิชาการ (%)	ลงนามรับรองข้อมูล
1	นายศุภฤกษ์ จันทรจักรจิตต์	60	
2	นายปิยะพงศ์ แสงมณี	40	
3			
4			
5			

หมายเหตุ: กรณีผู้เสนอขอรับค่าตอบแทนเป็นชื่อแรก หรือ ผู้รับผิดชอบบทความสามารถรับรองแทนผู้เขียนร่วมได้


.....
ผู้เสนอขอรับค่าตอบแทน

สารบัญ

บทความวิจัย	หน้า
▪ การกำจัดการบอนมอนอกไซด์ด้วยปฏิกิริยาซีฟต์อุณหภูมิต่ำและออกซิเจนแอสซีสต์วอเตอร์แก๊สซิฟต์โดยใช้ตัวเร่งปฏิกิริยาทองแดงออกไซด์บนตัวรองรับออกไซด์ผสมกัมพล สิริชัยประเสริฐ อาภาณี เหลืองนฤมิตชัย สงบทิพย์ พงศ์สถาปติ	1
▪ การสกัดสารสีจากเปลือกผลแก้วมังกร วิภาดา สอนราษฎร์ วิภาวี ขำวิจิตร วรินทร์ ยางเดิม ปรียากัทธ เชาว์ชาญ พัทธภรณ์ สารเสนา	9
▪ การศึกษาความเป็นไปได้ในการลงทุนในโรงบดหรือย่อยหินอุตสาหกรรมในจังหวัดอุบลราชธานี ธนารักษ์ พิทักษา สมบัติ สันธูเชาวน์	17
▪ การสำรวจการกำจัดขยะติดเชื้อของโรงพยาบาลชุมชนในเขตพื้นที่ภาคตะวันออกเฉียงเหนือตอนบน เจริญ ชูมมวล นลิน เพียรทอง กษิต์เดช สิบศิริ	26
▪ The Sensitivity Index and the Differential Evolution Technique Applications on the Determination of FACTS Placement Bongkoj Sookananta	35
▪ การจำแนกชิ้นงานที่ผลิตในโรงงานอุตสาหกรรมโดยใช้โครงข่ายประสาทเทียม ศุภฤกษ์ จันทรจักรจิตต์ ปิยะพงศ์ แสงมณี	46
บทความวิชาการ	
▪ การสำรวจการกำจัดแมลงในช่วงสารหอมมะลิ ในอุตสาหกรรมโรงสีข้าวของประเทศไทย : กรณีศึกษาโรงสีข้าวจังหวัดสุรินทร์ วิทยา อินทร์สอน สุขอังคณา ลี นลิน เพียรทอง สุริยา โชคสวัสดิ์ เจริญ ชูมมวล	53

บรรณาธิการ วารสารวิชาการ วิศวกรรมศาสตร์ ม.อบ.

ที่ปรึกษากองบรรณาธิการ

ศ.ดร.ประกอบ วิโรจนฤฎ

รศ.ดร.สถาพร โภคา

กองบรรณาธิการผู้ทรงคุณวุฒิ

ศ.ดร.วัลลภ สุระกำพลธร

ศ.ดร.บัณฑิต เอื้ออาภรณ์

ศ.ดร.สำเริง จักรใจ

ศ.ดร.ปราโมทย์ เดชะอำไพ

ศ.ดร.ปิยะสาร ประเสริฐธรรม

รศ.สันสนีย์ สุภาภา

Dr.Seah Tian Ho

ศ.ดร.สมชาย วงศ์วิเศษ

ศ.ธำรง เปรมปรีดี

ศ.ดร.ปริญญา จินดาประเสริฐ

รศ.ดร.วันเพ็ญ วิโรจนฤฎ

รศ.ดร.วรทัศน์ ขจิตวิษยานุกุล

รศ.ดร.วีระเชษฐ์ ชันเงิน

บรรณาธิการ

ผศ.ดร.ทวีศักดิ์ วังไพศาล

กองบรรณาธิการบริหาร

ผศ.ดร.กุลเชษฐ์ เพ็ชรทอง

ผศ.ดร.สุขอังคณา ลี

ผศ.ดร.ธนรัฐ ศรีวิระกุล

ดร.ศุภฤกษ์ จันทร์จรัสจิตต์

ผศ.ดร.กิตติศักดิ์ ชันติยวิชัย

ผศ.ดร.ปรีชา เกรียงกรกฎ

ดร.ฉัตรภูมิ วิรัตน์จันทร์

ดร.สุนนา สิริพัฒนานกุล

บรรณาธิการจัดการ

นายชิติกานต์ บุญแข็ง

นางสาวอรอนงค์ วงษ์ชมภู

การจำแนกชิ้นงานที่ผลิตในโรงงานอุตสาหกรรมโดยใช้โครงข่ายประสาทเทียม

Classification of Manufactured Objects Using Artificial Neural Network

ศุภฤกษ์ จันทร์จรัสจิตต์* ปิยะพงศ์ แสงมณี

คณะวิศวกรรมศาสตร์ มหาวิทยาลัยอุบลราชธานี อ.วารินชำราบ จ.อุบลราชธานี 34190

Suparerak Janjarasjitt* Piyapong Saengmanee

Faculty of Engineering, Ubon Ratchathani University, Warin Chamrab, Ubonratchathani 34190

Tel: 0-4535-3332 E-mail: ensupajit@ubu.ac.th

บทคัดย่อ

การจำแนกวัตถุอัตโนมัติมีบทบาทที่สำคัญอย่างยิ่งในปัจจุบัน ในช่วงเวลาที่ผ่านมาได้มีการสร้างและพัฒนาหลักการและเครื่องมือใหม่ๆ เพื่อช่วยในการจำแนกวัตถุขึ้นอย่างมากมาย โดยที่โครงข่ายประสาทเทียมเป็นเครื่องมือที่สำคัญอย่างหนึ่งที่นิยมถูกนำมาใช้ในกระบวนการรู้จำ งานวิจัยนี้มีวัตถุประสงค์เพื่อศึกษาเกี่ยวกับการจำแนกวัตถุอัตโนมัติเพื่องานอุตสาหกรรม โดยอาศัยการประมวลผลและวิเคราะห์ภาพดิจิทัล จากกระบวนการประมวลผลและวิเคราะห์ภาพดิจิทัล ค่าเฉพาะตัวของวัตถุแต่ละชิ้นจะถูกสกัดออกมาเพื่อใช้ในการจำแนก โดยในการศึกษานี้โครงข่ายประสาทเทียมแบบ feedforward backpropagation network ถูกนำมาใช้ วัตถุที่ใช้ในการศึกษานี้เป็นชิ้นงานจำนวนทั้งหมด 7 รูปแบบ ซึ่งเป็นชิ้นงานจริงที่ผลิตในโรงงานอุตสาหกรรม จากการทดลองพบว่า การจำแนกวัตถุโดยใช้โครงข่ายประสาทเทียมที่สร้างขึ้นสามารถจำแนกชิ้นงานทั้ง 7 รูปแบบออกมาได้อย่างสมบูรณ์

คำหลัก การจำแนกวัตถุ การประมวลผลภาพดิจิทัล การวิเคราะห์ภาพดิจิทัล โครงข่ายประสาทเทียม

Abstract

Object classification plays a significant role. There have been several computational approaches for object recognition and classification developed. Artificial neural network is one of the most common computational approaches that is used in pattern and object recognition. This study focuses on

examining an automatic object classification process based on digital image processing and analysis techniques for industrial and manufacturing purposes. The desired characteristics and features of objects are extracted using digital image processing and analysis techniques. Further, the feedforward backpropagation network is used in the object classification. There are 7 different objects obtained from a manufacture that are examined in this study. From the computational experiments using the 3-layer network, all objects can be perfectly classified.

Keywords: Object classification, digital image processing, digital image analysis, artificial neural network

1. บทนำ

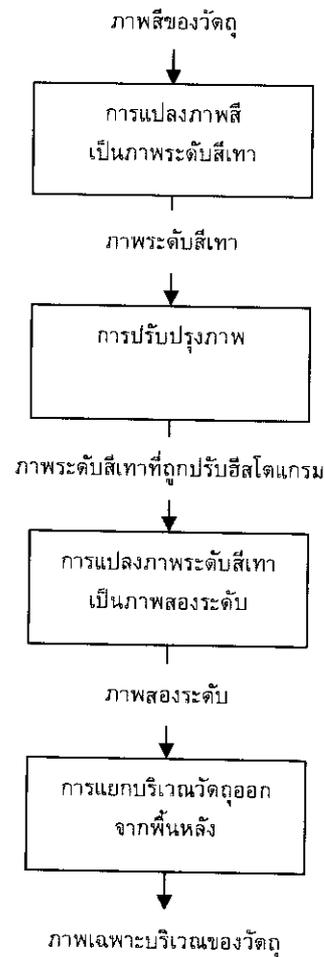
การประมวลผลและวิเคราะห์ภาพดิจิทัลเป็นเครื่องมือทางการคำนวณที่สำคัญอย่างหนึ่งในปัจจุบัน ซึ่งถูกนำไปประยุกต์ใช้ในงานต่างๆ อย่างหลากหลาย โดยรวมถึงการถูกนำไปประยุกต์ใช้ในการรู้จำและจำแนกวัตถุ สำหรับการรู้จำและจำแนกวัตถุสามารถแบ่งออกเป็น 2 ประเภทใหญ่ๆ คือ 1) แนวทางการใช้กระบวนการตัดสินใจ และ 2) แนวทางการใช้โครงสร้างของวัตถุ [1, 2] แนวทางแรกเกี่ยวข้องกับใช้คุณลักษณะและคุณสมบัติของวัตถุมาอธิบายถึงความเป็นตัวตนของวัตถุ เช่น ความยาว พื้นที่ เป็นต้น ในขณะที่แนวทางที่สองนั้นเกี่ยวข้องกับการใช้ข้อมูลเชิงสัญลักษณ์

เช่น สตรีง เป็นต้น มานำเสนอวัตถุ

ความสามารถในการรู้จำและจำแนกวัตถุโดยใช้การประมวลผลและวิเคราะห์ภาพดิจิทัลนั้นเป็นประโยชน์อย่างสูงต่อการประยุกต์ใช้งานในหลายๆ ด้าน เช่น อุตสาหกรรม, การผลิต, การแพทย์, ความปลอดภัยและมั่นคง, และการขนส่ง เป็นต้น โดยเฉพาะอย่างยิ่งการรู้จำและจำแนกวัตถุโดยใช้การประมวลผลและวิเคราะห์ภาพนี้เป็นหัวใจสำคัญสำหรับแมชชีนวิชัน (machine vision) ซึ่งเป็นการประยุกต์ใช้งานคอมพิวเตอร์วิชันในงานอุตสาหกรรมและการผลิต โดยเครื่องมือดังกล่าวถูกนำไปใช้อย่างหลากหลายในงานอุตสาหกรรมและการผลิต นี้นำรวมถึงการถูกนำไปใช้ในการจำแนกประเภทของวัตถุที่ถูกผลิตขึ้นมาเพื่อนำส่งต่อไปในกระบวนการการผลิต, การตรวจสอบคุณภาพของวัตถุที่ถูกผลิตขึ้นมา, หรือแม้แต่การถูกนำไปใช้ในการควบคุมแขนกลอัตโนมัติในกระบวนการการผลิต เป็นต้น ข้อดีหลักของการรู้จำและจำแนกวัตถุโดยใช้การประมวลผลและวิเคราะห์ภาพดิจิทัล คือ การประยุกต์ใช้งานการรู้จำและจำแนกวัตถุนั้นเป็นกระบวนการอัตโนมัติ มีความถูกต้องและความแม่นยำสูง สามารถทำงานได้อย่างรวดเร็ว นอกจากนี้แล้วกระบวนการดังกล่าวสามารถดำเนินไปได้อย่างต่อเนื่องเนื่องจากการเป็นการทำงานของเครื่องจักร

ส่วนประกอบของกระบวนการในการจำแนกวัตถุอัตโนมัติสามารถแบ่งออกเป็น 2 ส่วนใหญ่ๆ คือ การประมวลผลและวิเคราะห์ภาพดิจิทัล และการตัดสินใจและจำแนกวัตถุ เป้าหมายของส่วนแรกคือเพื่อที่จะสกัดค่าเฉพาะตัวซึ่งคือคุณลักษณะและคุณสมบัติของวัตถุออกมาจากภาพดิจิทัล โดยที่ค่าเฉพาะตัวนั้นคือดัชนีที่บ่งบอกวัตถุซึ่งถูกนำไปใช้ในการตัดสินใจและจำแนกวัตถุต่อไป สำหรับส่วนที่สองนั้นเป็นการตัดสินใจและจำแนกวัตถุโดยนำค่าเฉพาะตัวต่างๆ ของวัตถุที่ได้มาจากในส่วนแรกมาพิจารณาดูตามกฎและเงื่อนไขที่สร้างขึ้นสำหรับจำแนกวัตถุ เครื่องมือทางการคำนวณหนึ่งที่เป็นเครื่องมือที่สำคัญและถูกนำมาประยุกต์ใช้อย่างหลากหลายในการรู้จำและจำแนกวัตถุหรือรูปแบบ คือ โครงข่ายประสาทเทียมซึ่งเป็นโครงข่ายที่ปรับตัวและเรียนรู้ด้วยตนเอง โครงข่ายประสาทเทียมเป็นแบบจำลองที่ประกอบด้วยเซลล์ประสาทของสมอง

งานวิจัยนี้เป็นการศึกษาการนำการประมวลผลและวิเคราะห์ภาพดิจิทัลร่วมกับโครงข่ายประสาทเทียมไป

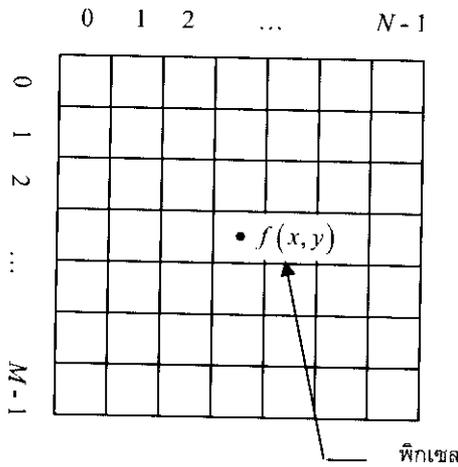


รูปที่ 1 กระบวนการการแยกบริเวณวัตถุออกจากพื้นหลังโดยใช้วิธีการประมวลผลภาพดิจิทัล

ประยุกต์ใช้เพื่อจำแนกวัตถุเพื่องานอุตสาหกรรม โดยที่วัตถุที่ใช้ในการศึกษานี้เป็นชิ้นงานจริงที่ผลิตอยู่ในโรงงานอุตสาหกรรม รูปแบบของชิ้นงานที่ใช้ในการศึกษามีอยู่ทั้งหมด 7 รูปแบบ กระบวนการจำแนกวัตถุที่ใช้ในการศึกษานี้เป็นแนวทางการใช้กระบวนการตัดสินใจจากการพิจารณาคูณลักษณะของชิ้นงานด้วยสายตาแล้วค่าเฉพาะตัวของชิ้นงานที่ถูกเลือกเพื่อใช้ในการจำแนกมีอยู่ทั้งหมด 5 ค่า ส่วนโครงข่ายประสาทเทียมที่ถูกนำมาใช้คือ feedforward backpropagation network (3-3-2 network) จากผลการทดลอง ชิ้นงานทั้ง 7 รูปแบบสามารถถูกจำแนกออกมาได้อย่างมีประสิทธิภาพและถูกต้องสมบูรณ์

2. หลักการและทฤษฎีพื้นฐาน

หลักการและทฤษฎีสำคัญที่เกี่ยวข้องในการศึกษานี้ประกอบด้วย 2 ส่วน คือ การประมวลผลและวิเคราะห์



รูปที่ 2 การนำเสนอภาพดิจิทัลโดยใช้ฟังก์ชัน $f(x, y)$

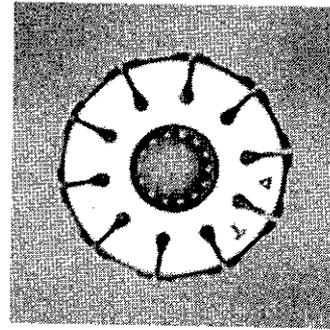
ภาพดิจิทัลเพื่อสกัดค่าคุณลักษณะและคุณสมบัติของวัตถุออกมา และโครงข่ายประสาทเทียมซึ่งถูกนำมาใช้ในการรู้จำและจำแนกวัตถุโดยอาศัยค่าคุณลักษณะและคุณสมบัติของวัตถุที่ได้มาจากการประมวลผลและวิเคราะห์ภาพดิจิทัล

2.1 การประมวลผลภาพดิจิทัล

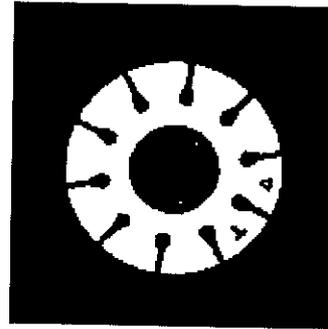
การประมวลผลภาพดิจิทัลเป็นการกระบวนกรทางการคำนวณที่กระทำต่อรูปภาพ โดยมีวัตถุประสงค์หลักคือเพื่อปรับปรุงคุณภาพของภาพเพื่อให้ได้ภาพใหม่ที่มีคุณสมบัติเหมาะสม เช่น รูปแบบของภาพ หรือความคมชัดของภาพ เป็นต้น สำหรับการรู้จำและจำแนกวัตถุโดยใช้ข้อมูลภาพดิจิทัล การประมวลผลภาพดิจิทัลจะถูกนำมาใช้ โดยเป้าหมายคือเพื่อที่จะแยกวัตถุที่อยู่ในภาพออกมา ก่อนที่คุณลักษณะและคุณสมบัติต่างๆ ของวัตถุจะถูกสกัดออกมาเพื่อนำไปใช้ในการรู้จำและการจำแนกต่อไป กระบวนการในการแยกบริเวณวัตถุออกมานั้นสามารถทำได้หลากหลายแนวทางโดยใช้วิธีการประมวลผลภาพดิจิทัลต่างๆ แนวทางหนึ่งในการแยกบริเวณวัตถุออกจากพื้นหลังถูกแสดงในรูปที่ 1 ซึ่งแผนผังที่แสดงในรูปที่ 1 เป็นแนวทางที่ใช้ในการศึกษานี้ด้วย

2.1.1 การนำเสนอภาพดิจิทัล

โดยทั่วไปแล้วภาพดิจิทัลจะถูกเขียนแสดงในรูปของฟังก์ชัน 2 มิติ $f(x, y)$ ซึ่งมีขนาดเท่ากับ $M \times N$ (M แถวและ N หลัก) [1, 2] ค่าฟังก์ชัน $f(x, y)$ แสดงค่าความเข้มแสงของภาพที่ตำแหน่งพิกัด (x, y) ซึ่งค่าของพิกัด (x, y) เป็นค่าแบบไม่ต่อเนื่อง



(ก)



(ข)

รูปที่ 3 (ก) ภาพระดับสีเทาของภาพชิ้นงานตัวอย่าง และ (ข) ภาพสองระดับของภาพชิ้นงานตัวอย่าง (ชิ้นงานรูปแบบที่ 2)

$$f(x, y) = \begin{bmatrix} f(0,0) & \dots & f(0, N-1) \\ f(1,0) & \dots & f(1, N-1) \\ \vdots & \ddots & \vdots \\ f(M-1,0) & \dots & f(M-1, N-1) \end{bmatrix} \quad (1)$$

ดังนั้นจะเห็นว่าภาพดิจิทัลประกอบด้วยค่าความเข้มแสงที่พิกัดต่างๆ ซึ่งส่วนประกอบของภาพดิจิทัลนี้ เรียกว่า พิกเซล (pixel) รูปที่ 2 แสดงการนำเสนอภาพดิจิทัลด้วยฟังก์ชัน $f(x, y)$

ค่าความเข้มแสงของภาพโทนสีเดี่ยวมักจะถูกเรียกว่าระดับสีเทา (gray level) ดังนั้นภาพโทนสีเดียวถูกเรียกว่าภาพระดับสีเทา (gray-scale image) ซึ่งจำนวนของระดับสีเทาทั้งหมดบ่งบอกถึงระดับความละเอียดของภาพ ถ้าภาพดิจิทัลมีระดับความละเอียดของภาพเท่ากับ 1 บิต (มี $2^1=2$ ระดับสี คือ สีขาวกับสีดำ) จะถูกเรียกว่าภาพสองระดับ (binary image) ตัวอย่างภาพระดับสีเทาของชิ้นงานตัวอย่างที่มีความละเอียดเท่ากับ 8 บิต ถูกแสดงในรูปที่ 3(ก)

สำหรับภาพสีนั้นจะเป็นการผสมรวมของภาพดิจิทัล $f(x, y)$ เข้าด้วยกัน โดยระบบ RGB ภาพสีจะ

ประกอบด้วยภาพดิจิทัลประกอบเข้าด้วยกัน 3 ภาพ ซึ่งแต่ละภาพเป็นฟังก์ชันของความเข้มแสงของสีแดง, สีเขียว และสีน้ำเงิน ดังนั้นภาพสีดิจิทัลคืออาร์เรย์ 3 มิติที่มีขนาดเท่ากับ $M \times N \times 3$ ของพิกเซลสี [1, 2] ภาพสีสามารถถูกแปลงเป็นภาพระดับสีเทาได้โดย

$$\text{gray level} = 0.2989R + 0.5870G + 0.1140B \quad (2)$$

เมื่อ R , G และ B คือค่าความเข้มแสงสีแดง, สีเขียว และสีน้ำเงินตามลำดับ

ส่วนการแปลงภาพระดับสีเทาไปเป็นภาพสองระดับนั้นสามารถทำได้ง่าย เพียงแค่เปรียบเทียบว่าค่าระดับสีเทาของพิกเซลนั้นมีค่ามากกว่า น้อยกว่า หรือเท่ากับกับค่าเกณฑ์ที่กำหนดไว้ (threshold) ค่าความเข้มแสง (P) ของภาพสองระดับที่แปลงมาจากภาพระดับสีเทามีค่าเท่ากับ

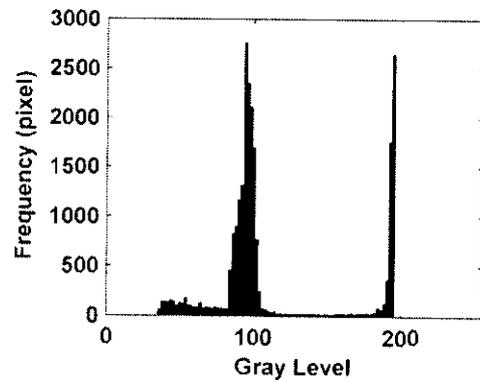
$$P(x, y) = \begin{cases} 1, & \text{if } I(x, y) \geq \tau \\ 0, & \text{if } I(x, y) < \tau \end{cases} \quad (3)$$

เมื่อ τ คือค่าเกณฑ์ที่จะแบ่งระดับสีออกเป็นสองระดับ และ B คือจำนวนบิตของภาพ (ความละเอียดของภาพ) สำหรับค่าเกณฑ์ τ ที่เหมาะสมนั้นขึ้นอยู่กับคุณลักษณะของแต่ละภาพ โดยวิธีการที่นิยมใช้ในการคำนวณหาค่าที่เหมาะสมสำหรับค่าเกณฑ์ τ วิธีหนึ่งนั้นคือ วิธีของ Otsu [3] ซึ่งวิธีการนี้ก็ถูกนำมาใช้ในการศึกษานี้ด้วยเช่นกัน ตัวอย่างภาพสองระดับของชิ้นงานตัวอย่างถูกแสดงในรูปที่ 3(ข)

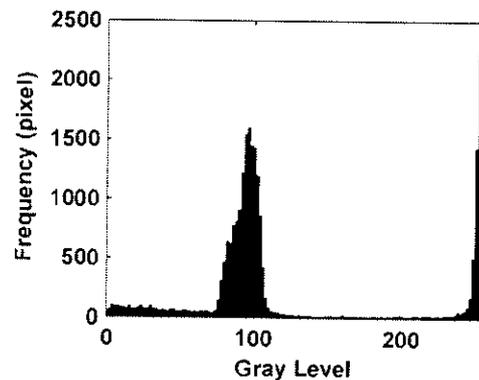
2.1.2 การปรับปรุงภาพ (Image Enhancement)

การปรับปรุงภาพเป็นขั้นตอนที่สำคัญในกระบวนการประมวลผลและวิเคราะห์ภาพดิจิทัล วัตถุประสงค์หลักในการปรับปรุงภาพ คือการประมวลผลภาพดิจิทัลเพื่อให้ภาพดิจิทัลที่ได้ออกมานั้นมีคุณลักษณะที่เหมาะสมกว่าภาพดิจิทัลต้นฉบับสำหรับแต่ละการประยุกต์ใช้งาน [1, 2] โดยวิธีการในการปรับปรุงภาพสามารถทำได้หลากหลายวิธี ตัวอย่างเช่น การแปลงความเข้มแสง (intensity transformation) การปรับฮิสโตแกรมให้เท่ากัน (histogram equalization) การกรองสัญญาณภาพ (filtering) เป็นต้น [1, 2]

การแปลงความเข้มแสงนั้นเป็นการปรับค่าความเข้มแสงหรือค่าระดับเทาของแต่ละพิกเซลในภาพดิจิทัล การแปลงความเข้มแสงเป็นการจัดการและปรับเปลี่ยนช่วงระดับของความเข้มแสงของภาพนั้นๆ [1, 2] ซึ่งโดยส่วนใหญ่จะเป็นการขยายช่วงระดับความเข้มแสงของ



(ก)



(ข)

รูปที่ 4 ฮิสโตแกรมของภาพระดับสีเทาของชิ้นงานตัวอย่าง (ก) ก่อนทำการแปลงความเข้มแสง และ (ข) หลังทำการแปลงความเข้มแสง

ภาพ นั่นคือ การแปลงโดยยึดความแตกต่างของภาพ (contrast-stretching transformation) การกระทำดังกล่าวจะช่วยทำให้ความเข้มแสงในภาพมีความแตกต่างกันเพิ่มมากขึ้น ซึ่งช่วยทำให้ภาพมีความคมชัดเพิ่มมากขึ้น

การแปลงความเข้มแสงนั้นอาจจะเป็นการแปลงโดยใช้ฟังก์ชันที่เป็นเชิงเส้น หรือฟังก์ชันที่ไม่เป็นเชิงเส้น เช่น ฟังก์ชันลอการิทึม ฟังก์ชันสำหรับการแปลงโดยยึดความแตกต่างของภาพสามารถเขียนอยู่ในรูปต่อไปนี้ [1, 2]

$$P(x, y) = \frac{1}{1 + (\beta/I(x, y))^{\gamma}} \quad (4)$$

เมื่อ P คือค่าความเข้มแสงหลังจากการแปลงความเข้มแสง, I คือค่าความเข้มแสงของแต่ละพิกเซล, γ คือค่าความลาดชันของฟังก์ชันแปลงความเข้มแสง และ β คือเกณฑ์ค่าความเข้มแสง ค่าความเข้มแสง I ที่น้อยกว่า β จะถูกบีบเข้าไปอยู่ในช่วงระดับสีเทาที่มีด ต่ำ

ต้องการจะยึดความแตกต่างของภาพทุกระดับสีเทาออกให้เท่าๆ กันทั้งช่วง 2^b ระดับสีเทาสามารถทำได้โดยใช้ฟังก์ชัน

$$P(x, y) = (I(x, y) - I_{\min}) \left(\frac{2^b - 1}{I_{\max} - I_{\min}} \right) \quad (5)$$

เมื่อ I_{\max} และ I_{\min} คือค่าความเข้มแสงสูงสุดและค่าความเข้มแสงต่ำสุดของภาพต้นฉบับ

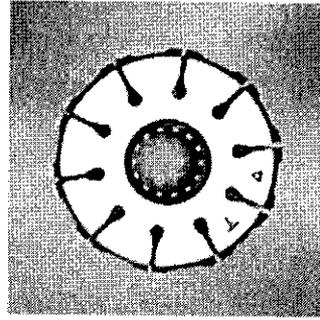
ตัวอย่างแสดงเปรียบเทียบผลที่ได้จากการแปลงความเข้มแสงโดยใช้สมการ (5) ถูกแสดงในรูปที่ 3(ก) และ (ข) โดยฮิสโตแกรมของภาพระดับสีเทาต้นฉบับของชิ้นงานตัวอย่างซึ่งถูกแสดงในรูปที่ 3(ก) ถูกแสดงในรูปที่ 4(ก) ในขณะที่รูปที่ 4(ข) แสดงฮิสโตแกรมของภาพหลังจากการแปลงความเข้มแสง นอกจากนี้ภาพชิ้นงานตัวอย่างหลังจากทำการแปลงความเข้มแสงแล้วถูกแสดงในรูปที่ 5

2.1.3 การแยกบริเวณวัตถุ (Image Segmentation)

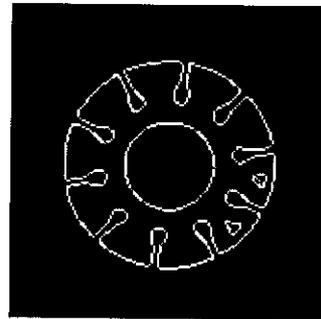
การแยกบริเวณของวัตถุออกจากพื้นหลังของภาพเป็นกระบวนการประมวลผลภาพดิจิทัล โดยจากอินพุตคือภาพดิจิทัลที่ถูกป้อนเข้าสู่กระบวนการ ข้อมูลและคุณลักษณะของวัตถุในภาพนั้นจะถูกสกัดออกมาจากภาพ ผลลัพธ์ที่ได้จากการแยกบริเวณวัตถุเป็นปัจจัยที่สำคัญอย่างยิ่งต่อผลกระบวนการวิเคราะห์ในลำดับต่อไปซึ่งส่งผลต่อความสำเร็จในการจำแนกวัตถุ

กระบวนการการแยกบริเวณของวัตถุออกจากพื้นหลังของภาพสองระดับนั้นขึ้นอยู่กับคุณสมบัติพื้นฐานของค่าความเข้มแสงของภาพ 2 คุณสมบัติคือ ความไม่ต่อเนื่อง (discontinuity) และความคล้ายคลึงกัน (similarity) แนวทางสำหรับการแยกบริเวณวัตถุโดยอาศัยคุณสมบัติแรก (ความไม่ต่อเนื่อง) นั้นคือการแบ่งภาพออกเป็นส่วนๆ โดยขึ้นอยู่กับเปลี่ยนแปลงอย่างทันทีทันใดของความเข้มแสง เช่น ขอบของวัตถุในภาพ เป็นต้น ส่วนแนวทางสำหรับการแยกบริเวณวัตถุโดยใช้ความคล้ายคลึงกันนั้นจะใช้การแบ่งภาพออกเป็นบริเวณต่างๆ ที่มีความคล้ายคลึงกันตามนิยามที่ต้องการ

การตรวจหาขอบเป็นกระบวนการสำหรับตรวจหาความไม่ต่อเนื่องของค่าความเข้มแสงโดยอาศัยหลักการอนุพันธ์ (derivative) ตัวเลือกหนึ่งสำหรับอนุพันธ์อันดับที่หนึ่งของการประมวลผลภาพคือเกรเดียนท์ (gradient) โดยเกรเดียนท์ของฟังก์ชัน 2 มิติมีนิยามดังนี้ [1, 2]



รูปที่ 5 ภาพระดับสีเทาของภาพชิ้นงานตัวอย่าง หลังทำการแปลงความเข้มแสง



รูปที่ 6 ภาพขอบของวัตถุภาพชิ้นงานตัวอย่าง

$$\nabla f = \begin{bmatrix} G_x \\ G_y \end{bmatrix} = \begin{bmatrix} \frac{\partial f}{\partial x} \\ \frac{\partial f}{\partial y} \end{bmatrix} \quad (6)$$

ค่าขนาดของเวกเตอร์นี้ คือ

$$|\nabla f| = (G_x^2 + G_y^2)^{1/2} \quad (7)$$

วิธีการสำหรับตรวจหาขอบมีอยู่หลากหลายวิธี เช่น วิธีของโซเบล (Sobel edge detector) และวิธีของพริวิต (Prewitt edge detector) เป็นต้น ซึ่งวิธีการต่างๆ เหล่านี้แตกต่างกันที่ใช้หน้ากากสำหรับทำการคำนวณอนุพันธ์แตกต่างกัน หน้ากากของ Sobel edge detector ในแนวนอนและแนวตั้ง คือ

-1	-2	-1
0	0	0
1	2	1

-1	0	1
-2	0	2
-1	0	1

ในขณะที่หน้ากากของ Prewitt edge detector ในแนวตั้งและแนวนอน คือ

-1	-1	-1
0	0	0
1	1	1

-1	0	1
-1	0	1
-1	0	1

สำหรับการแยกบริเวณวัตถุโดยใช้ความคล้ายคลึงกันนั้น จะเป็นการแบ่งภาพออกเป็นบริเวณต่างๆ ซึ่งโดยส่วนใหญ่จะแบ่งโดยใช้ค่าความเข้มแสงและมีค่าเกณฑ์ตัวหนึ่งสำหรับแบ่งแยกความคล้ายคลึงกัน ซึ่งหลักการนี้คล้ายกับกระบวนการแปลงภาพจากภาพระดับสีเทาเป็นภาพสองระดับ รูปที่ 6 แสดงภาพขอบของชิ้นงานตัวอย่างซึ่งแสดงในรูปที่ 3(ข)

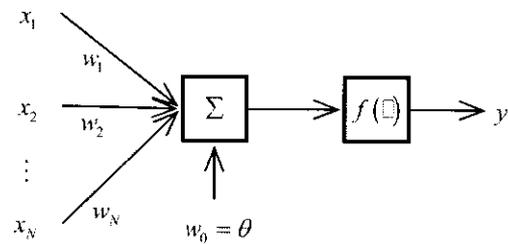
2.2 โครงข่ายประสาทเทียม

โครงข่ายประสาทเทียม (artificial neural network หรือที่เรียกอย่างสั้นๆ ว่า neural network) ถูกศึกษาและได้รับการพัฒนามาเริ่มตั้งแต่ช่วงปลายทศวรรษ 1950 โดย Rosenblatt ได้ประยุกต์ใช้เพอร์เซปตรอน (perceptron) แบบชั้นเดียวในการเรียนรู้เพื่อจำแนกรูปแบบ [5] ต่อมาโครงข่ายประสาทเทียมได้รับการพัฒนาให้เป็นระบบที่มีหลายชั้นขึ้น เนื่องจากเพอร์เซปตรอนแบบชั้นเดียวนั้นมีข้อจำกัด [6] แบบจำลองโครงข่ายประสาทเทียมใหม่ๆ ได้ถูกเสนอและถูกศึกษาอย่างต่อเนื่อง โดยโครงข่ายประสาทเทียมสามารถแบ่งออกเป็นได้หลายประเภทขึ้นอยู่กับเกณฑ์การพิจารณา เช่น วิธีการเรียนรู้ (supervised กับ unsupervised), สถาปัตยกรรมของโครงข่ายประสาทเทียม (feedforward กับ recurrent), ประเภทของผลลัพธ์ (binary กับ continuous), ประเภทของโหนด (uniform กับ hybrid) เป็นต้น [4]

เพอร์เซปตรอน (perceptron) เป็นการนำเสนอรูปแบบหนึ่งในความพยายามที่จะสร้างระบบอัจฉริยะและเรียนรู้ด้วยตนเอง โดยเพอร์เซปตรอนได้รับการพัฒนาปรับเปลี่ยนมาจากแบบจำลองเซลล์ประสาทของสมอง ที่เรียกว่านิวรอน ซึ่งถูกนำเสนอโดย McCulloch และ Pitts [7] รูปที่ 7 แสดงรูปแบบทั่วไปของเพอร์เซปตรอนแบบชั้นเดียว (single-layer perceptron) ที่มีไบอัส $w_0 = \theta$ จากเพอร์เซปตรอนแบบชั้นเดียวดังแสดงในรูปที่ 7 ผลลัพธ์ y สามารถคำนวณได้จาก

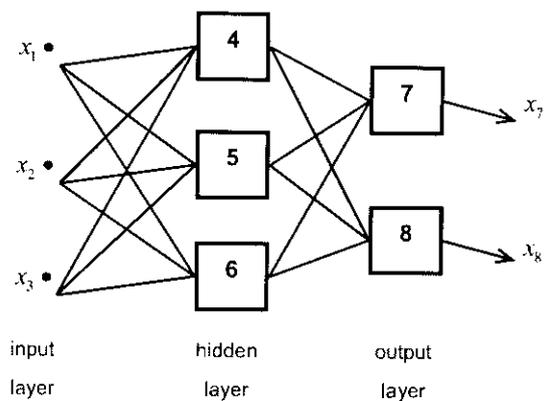
$$y = f\left(\sum_{i=1}^N w_i x_i + \theta\right) \quad (8)$$

หรือ



รูปที่ 7 เพอร์เซปตรอนแบบหนึ่งชั้นที่มีอินพุตเป็นเวกเตอร์

$$\mathbf{x} = (x_1 \ x_2 \ \dots \ x_N)^T \text{ ขนาด } N \times 1$$



รูปที่ 8 โครงข่ายประสาทเทียมแบบหลายชั้น (multilayer network หรือ 3-3-2 network)

$$y = f\left(\sum_{i=0}^N w_i x_i\right) \text{ และ } x_0 = 1 \quad (9)$$

ฟังก์ชัน $f(x)$ คือฟังก์ชันกระตุ้น (activation function หรือ transfer function) ซึ่งโดยปกติแล้วฟังก์ชันกระตุ้นนี้จะเป็นฟังก์ชันซิกนัม (sigmoid function) หรือฟังก์ชันขั้นบันได (step function) [4] ที่มีนิยามดังนี้ ตามลำดับ

$$\text{sgn}(x) = \begin{cases} 1, & \text{if } x > 0 \\ -1, & \text{otherwise} \end{cases} \quad (10)$$

และ

$$\text{step}(x) = \begin{cases} 1, & \text{if } x > 0 \\ 0, & \text{otherwise} \end{cases} \quad (11)$$

เพอร์เซปตรอนแบบชั้นเดียวนี้เป็นส่วนประกอบที่สำคัญสำหรับโครงข่ายประสาทเทียมและเป็นแบบจำลองของเซลล์ประสาท

โครงข่ายประสาทเทียมมักจะมีหลายชั้น เนื่องจากมีประสิทธิภาพสูงกว่า ชั้นต่างๆ ในโครงข่ายประสาทเทียมแบบหลายชั้น (multilayer network) สามารถแบ่งออกเป็น 3 ประเภท คือ ชั้นอินพุต (input layer), ชั้นซ่อน

(hidden layer) และชั้นเอาต์พุต (output layer) โดยที่ชั้นอินพุตและชั้นเอาต์พุตจะมีจำนวนคงที่ คือจำนวน 1 ชั้น ในขณะที่ชั้นซ่อนนั้นสามารถมีได้มากกว่าหนึ่งชั้น โครงข่ายประสาทเทียมแบบหลายชั้นถูกแสดงในรูปที่ 8 ชั้นอินพุตมีจำนวนโหนด (node) เป็นจำนวนคงที่ โดยจะมีจำนวนเท่ากับจำนวนของค่าเฉพาะตัวซึ่งเป็นค่าคุณลักษณะและคุณสมบัติของวัตถุที่ถูกนำมาใช้เป็นปัจจัยในการจำแนก แต่ละโหนดในชั้นอินพุตเป็นการรับค่าเฉพาะตัวของวัตถุ ส่วนโหนดในชั้นซ่อนและชั้นเอาต์พุตนั้นคือเพอร์เซ็ปตรอนแบบชั้นเดียว จำนวนโหนดในชั้นเอาต์พุตก็มีจำนวนคงที่ คือจะมีจำนวนโหนดเท่ากับจำนวนรูปแบบของวัตถุที่จะจำแนก ในขณะที่จำนวนโหนดในชั้นซ่อนนั้น มีจำนวนไม่คงที่ ขึ้นอยู่กับความซับซ้อนของโครงข่าย

จากโครงข่ายประสาทเทียมตัวอย่างที่แสดงในรูปที่ 8 จะเห็นว่าที่ชั้นอินพุตมี 3 โหนด ชั้นซ่อนมี 3 โหนด และชั้นเอาต์พุตมี 2 โหนด ซึ่งถูกเรียกว่า โครงข่ายแบบ 3-3-2 สำหรับโหนด j ใดๆ ที่ซึ่ง $j=4,5,6,7,8$ จะมีโครงสร้างภายในเป็นเพอร์เซ็ปตรอนแบบชั้นเดียวดังแสดงในรูปที่ 7 ผลลัพธ์ที่ได้จากโหนด j ใดๆ นั้นจะมีค่าเท่ากับ

$$y_j = f\left(\sum_{i=1}^{N_j} w_{i,j}x_i + b_j\right) \quad (12)$$

เมื่อ N_j คือจำนวนอินพุตทั้งหมดที่โหนด j นั้น, $w_{i,j}$ คือค่าน้ำหนักของอินพุตที่ i สำหรับโหนด j และ b_j คือค่าไบอัสที่โหนด j

สำหรับฟังก์ชันกระตุ้นในแต่ละชั้นของโครงข่ายประสาทเทียมอาจจะเป็นฟังก์ชันที่ต่างกัน โดยอาจจะเป็นฟังก์ชันไฮเพอร์บอลิกแทนเจนต์ (hyperbolic tangent), ฟังก์ชันลอจิสติก (logistic function) หรือฟังก์ชันเชิงเส้น (linear function) [4] ซึ่งมีนิยามดังนี้ตามลำดับ

$$f(x) = \tanh(x/2) = \frac{1-e^{-x}}{1+e^{-x}}, \quad (13)$$

$$f(x) = \frac{1}{1+e^{-x}}, \quad (14)$$

และ

$$f(x) = x \quad (15)$$

กระบวนการเรียนรู้ของโครงข่ายประสาทเทียมสามารถทำได้โดยการสอนโครงข่ายประสาทเทียมเพื่อให้

โครงข่ายดังกล่าวได้ทำการปรับตัวให้สอดคล้องกับอินพุตที่ป้อนเข้าสู่โครงข่าย ซึ่งการปรับตัวของโครงข่ายประสาทเทียมนั้นคือการปรับเปลี่ยนค่าน้ำหนัก $w_{i,j}$ และค่าไบอัส b_j ที่เหมาะสมเพื่อให้โครงข่ายประสาทเทียมสามารถจำแนกรูปแบบต่างๆ ได้ตามที่ต้องการ กระบวนการเรียนรู้ของโครงข่ายประสาทเทียมวิธีหนึ่งที่น่าง่ายและเป็นที่ยอมรับคือวิธีที่เรียกว่า backpropagation กระบวนการสอนโครงข่ายประสาทเทียม ประกอบด้วยขั้นตอนต่างๆ ดังต่อไปนี้

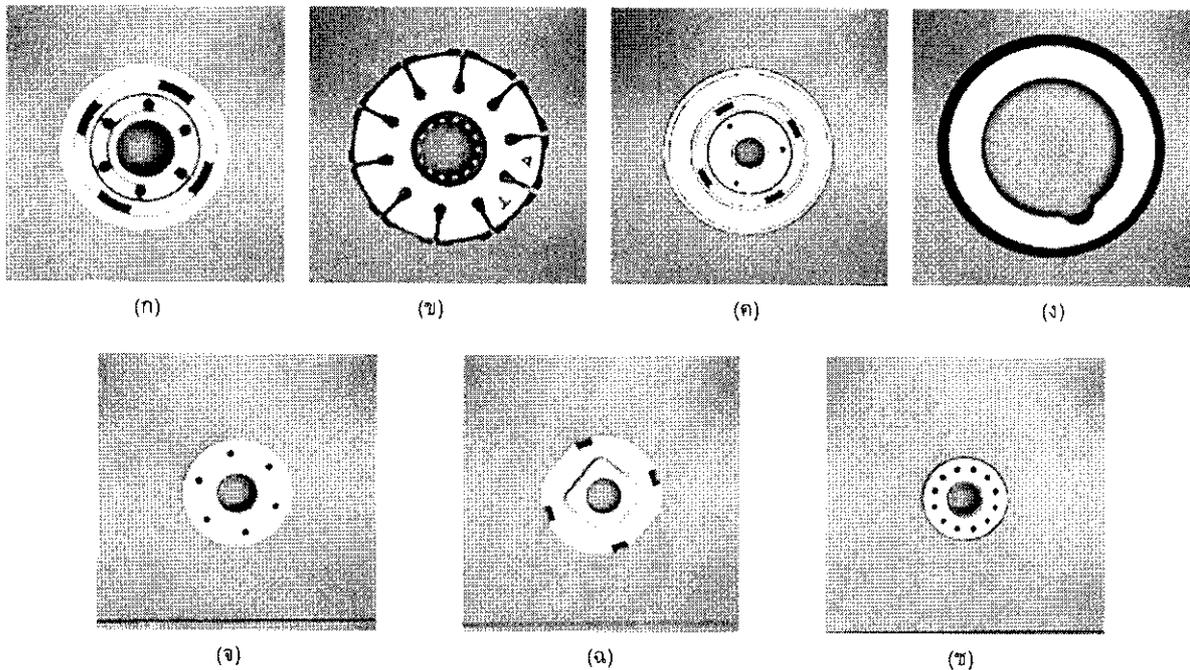
- 1) กำหนดค่าเริ่มต้นของค่าน้ำหนัก $w_{i,j}$ และค่าไบอัส b_j ทั้งหมด ซึ่งการกำหนดค่าเริ่มต้นนี้สามารถทำได้โดยการสุ่มค่า โดยค่าที่ถูกสุ่มขึ้นมา นั้นจะมีค่าอยู่ระหว่าง $[-1,1]$
- 2) ทำการป้อนข้อมูลอินพุต x ที่จะใช้ในกระบวนการสอนโครงข่ายประสาทเทียมเข้าสู่โครงข่าย
- 3) คำนวณหาค่าผิดพลาด
- 4) ทำการปรับค่าน้ำหนัก $w_{i,j}$ และค่าไบอัส b_j
- 5) ทำซ้ำขั้นตอน 2), 3) และ 4) จนกว่าค่าผิดพลาดต่ำกว่าเกณฑ์ที่กำหนดไว้ หรือจนกว่าเป็นไปตามเงื่อนไขในการหยุดกระบวนการสอนอื่นที่กำหนดไว้

3. ระเบียบวิธีวิจัย

แนวทางในการศึกษา รวมถึงองค์ประกอบและขอบเขตต่างๆ ของการศึกษาในงานวิจัยนี้มีดังนี้

3.1 วัตถุ ภาพดิจิทัล และอุปกรณ์บันทึกภาพ

วัตถุที่ใช้ในการทดลองในงานวิจัยนี้เป็นชิ้นงานจริงที่ผลิตในโรงงานอุตสาหกรรมซึ่งเป็นชิ้นส่วนของโช๊คที่เป็นวัตถุแข็งเกร็ง โดยมีจำนวนทั้งหมด 7 รูปแบบ: ชิ้นงาน O_1, O_2, \dots, O_7 ดังแสดงในรูปที่ 9(ก)-(ข) ตามลำดับ นอกจากนี้แล้วชิ้นงานทั้ง 7 รูปแบบนั้น มีจำนวนรูปแบบละ 3 ชิ้น รวมตัวอย่างในการทดลองมีชิ้นงานจำนวนทั้งสิ้น 21 ชิ้น รูปภาพของวัตถุถูกบันทึกด้วยกล้องดิจิทัลแบบเว็บแคม ยี่ห้อ Logitech รุ่น QuickCam Pro for Notebooks ภาพดิจิทัลของวัตถุที่ใช้ในการทดลองเป็นภาพที่มีขนาดเท่ากับ 320x240 พิกเซล ซึ่งภาพดิจิทัลจะถูกบันทึกโดยอัตโนมัติเมื่อชิ้นงานเดินทางมาถึงตำแหน่งของการถ่ายภาพ ระยะห่างระหว่างกล้อง



รูปที่ 9 ภาพตัวอย่างชั้นงาน (ก) ชั้นงาน O_1 , (ข) ชั้นงาน O_2 , (ค) ชั้นงาน O_3 , (ง) ชั้นงาน O_4 , (จ) ชั้นงาน O_5 , (ฉ) ชั้นงาน O_6 และ (ช) ชั้นงาน O_7

ดิจิทัลแบบเว็บแคมและพื้นที่วางชิ้นงานเท่ากับ 12 ซม.

3.2 วิธีการ

จากกระบวนการประมวลผลภาพดิจิทัลที่แสดงในแผนผังในรูปที่ 1 ข้อมูลและคุณลักษณะของวัตถุจะถูกนำไปประมวลผลและวิเคราะห์ต่อไปเพื่อที่จะจำแนกประเภทของชิ้นงานออกมา แผนผังแสดงกระบวนการจำแนกชิ้นงานที่ถูกใช้ในการศึกษานี้ถูกแสดงอยู่ในรูปที่ 10

3.2.1 ค่าเฉพาะตัวของชิ้นงาน

จากการพิจารณารูปร่างและลักษณะของชิ้นงานทั้ง 7 รูปแบบที่จะถูกจำแนกในการศึกษานี้ พบว่าชิ้นงานทั้ง 7 รูปแบบนี้มีคุณลักษณะและคุณสมบัติที่สามารถจะนำมาใช้เป็นปัจจัยในการจำแนกวัตถุได้อย่างชัดเจน โดยในการศึกษานี้ค่าเฉพาะตัวของชิ้นงานซึ่งจะถูกนำมาใช้ในการจำแนกวัตถุประกอบด้วย 5 ค่า ดังนี้

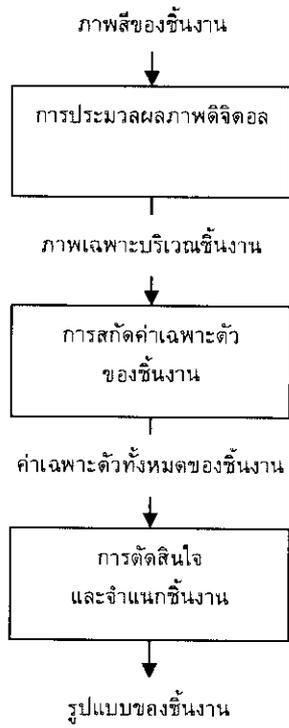
- พื้นที่ทั้งหมดของชิ้นงาน (x_1) คือจำนวนพิกเซลทั้งหมดของวัตถุ (แสดงในรูปที่ 11(ก))
- พื้นที่ของรูชิ้นงาน (x_2) คือจำนวนพิกเซลทั้งหมดของรูกลางชิ้นงาน (แสดงในรูปที่ 11(ข))
- ค่าเฉลี่ยของด้านทั้งสี่ของกรอบสี่เหลี่ยมที่เล็กที่สุดที่สามารถล้อมรอบชิ้นงานได้พอดี (x_3) คือ

ค่าเฉลี่ยของความสูงและความกว้างของกรอบสี่เหลี่ยมที่เล็กที่สุดที่สามารถล้อมรอบชิ้นงานได้ (แสดงในรูปที่ 11(ค))

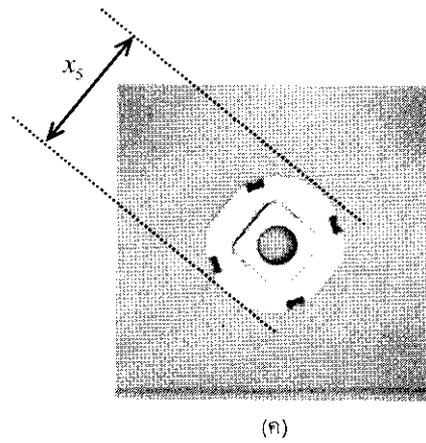
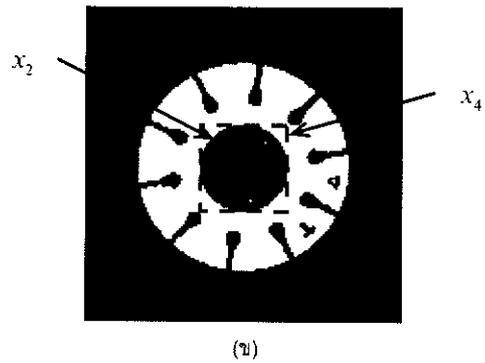
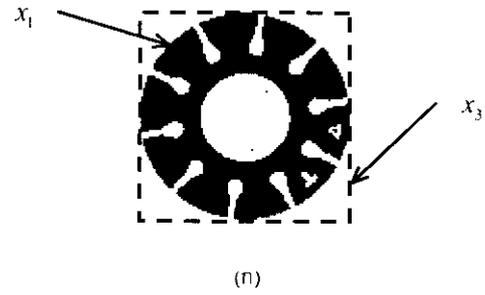
- ค่าเฉลี่ยของด้านทั้งสี่ของกรอบสี่เหลี่ยมที่เล็กที่สุดที่สามารถล้อมรอบรูชิ้นงานได้พอดี (x_4) คือค่าเฉลี่ยของความสูงและความกว้างของกรอบสี่เหลี่ยมที่เล็กที่สุดที่สามารถล้อมรอบรูกลางชิ้นงานได้ (แสดงในรูปที่ 11(ง))
- ค่าความยาวสูงสุดของชิ้นงาน (x_5) คือความยาวของบริเวณที่กว้างที่สุดของชิ้นงาน (แสดงในรูปที่ 11(จ))

3.2.2 โครงข่ายประสาทเทียมสำหรับจำแนกวัตถุ

โครงข่ายประสาทเทียมที่ใช้ในการจำแนกชิ้นงานในการศึกษานี้ คือโครงข่ายแบบ feedforward ที่มี 3 ชั้น โดยมีโครงสร้างเป็นแบบ 5-7-7 นั่นคือในชั้นอินพุตมี 5 โหนดซึ่งเท่ากับจำนวนค่าเฉพาะตัวที่ใช้ในการจำแนก, ชั้นซ่อนมี 7 โหนด และชั้นเอาต์พุตมี 7 โหนดซึ่งเท่ากับจำนวนของรูปแบบของชิ้นงาน นอกจากนี้ฟังก์ชันกระตุ้นที่ใช้ในชั้นซ่อนและชั้นเอาต์พุต คือฟังก์ชันไฮเพอร์บอลิกแทนเจนต์และฟังก์ชันเชิงเส้น ตามลำดับ สำหรับกระบวนการการเรียนรู้ของโครงข่ายประสาทเทียมที่ใช้ใน



รูปที่ 10 กระบวนการการจำแนกวัตถุโดยใช้วิธีการประมวลผลภาพดิจิทัล



รูปที่ 11 ค่าเฉพาะตัวของชิ้นงานที่ใช้ในการจำแนกวัตถุ

การศึกษานี้ คือวิธีการเรียนรู้แบบ backpropagation

3.3 กรอบการทดลอง

การทดลองสำหรับการจำแนกวัตถุอัตโนมัติในการศึกษานี้แบ่งออกเป็น 2 ขั้นตอน คือ 1) การทดลองเบื้องต้นเพื่อเก็บค่าคุณลักษณะและคุณสมบัติของชิ้นงานทั้ง 7 รูปแบบสำหรับการสร้างและการเรียนรู้ของโครงข่ายประสาทเทียม และ 2) การประเมินผลประสิทธิภาพในการจำแนกวัตถุของโครงข่ายประสาทเทียม

3.3.1 การทดลองสำหรับการสร้างและการเรียนรู้ของโครงข่ายประสาทเทียม

เป้าหมายหลักของขั้นตอนแรกนี้ คือเพื่อที่จะสอนให้โครงข่ายประสาทเทียมที่ออกแบบไว้ได้ปรับตัว ซึ่งจะส่งผลให้โครงข่ายประสาทเทียมมีความสามารถในการตัดสินใจจำแนกวัตถุซึ่งในที่นี้คือชิ้นงานทั้ง 7 รูปแบบได้อย่างถูกต้อง การทดลองในขั้นตอนแรกประกอบด้วย 2 ส่วน ดังนี้

ในส่วนแรกข้อมูลภาพดิจิทัลของชิ้นงานทั้ง 7 รูปแบบจะถูกทำการบันทึก โดยในการทดลองขั้นตอนนี้ชิ้นงานทั้ง 7 รูปแบบ รูปแบบละ 3 ชิ้นถูกนำมาวางบน

ฐานอย่างสุ่ม โดยไม่มีการกำหนดตำแหน่งการวางไว้ล่วงหน้าเพื่อทำการบันทึกภาพดิจิทัล ชิ้นงานแต่ละชิ้น จะได้รับการบันทึกภาพดิจิทัลทั้งหมด 4 ครั้ง โดยแต่ละครั้งที่ทำการบันทึกภาพดิจิทัลของแต่ละชิ้นงานนั้นจะไม่ซ้ำตำแหน่งเดิม รวมข้อมูลภาพดิจิทัลของชิ้นงานทั้งหมดจะมีจำนวนเท่ากับ 84 ภาพ หลังจากนั้นค่าเฉพาะตัวทั้ง 5 ค่าซึ่งเป็นองค์ประกอบที่ใช้ในการพิจารณาจำแนกวัตถุของภาพดิจิทัลทั้ง 84 ภาพ จะถูกสกัดออกมา ในส่วนที่สองค่าเฉพาะตัวทั้ง 5 ค่าของภาพดิจิทัลของแต่ละชิ้นงานจะถูกป้อนเข้าสู่โครงข่ายประสาทเทียมต่อไป

ตารางที่ 1 ค่าเฉลี่ยและค่าเบี่ยงเบนมาตรฐานของค่าเฉพาะตัวของวัตถุที่ใช้ในการเรียนรู้ของโครงข่ายประสาทเทียม

ค่าเฉพาะตัว	O_1	O_2	O_3	O_4	O_5	O_6	O_7
x_1	25127.50	28683.5	25440.33	36873.42	10569.17	12046.25	6187.08
(พิทเชล)	± 1076.81	± 716.06	± 1229.39	± 1121.04	± 710.97	± 409.35	± 251.80
x_2	3291.75	5605.00	977.67	18400.08	1592.75	1514.25	1293.92
(พิทเชล)	± 163.74	± 270.64	± 59.98	± 653.58	± 120.93	± 87.84	± 137.41
x_3	179.42	203.58	180.92	217.00	117.42	129.92	89.25
(พิทเชล)	± 3.65	± 2.47	± 4.78	± 3.30	± 3.20	± 3.06	± 2.05
x_4	65.08	84.75	35.92	155.42	45.92	44.17	41.42
(พิทเชล)	± 1.68	± 2.18	± 1.68	± 3.50	± 2.78	± 1.34	± 1.88
x_5	180.50	201.25	181.08	218.00	117.33	128.33	89.75
(พิทเชล)	± 3.87	± 2.53	± 3.94	± 3.62	± 3.75	± 2.64	± 1.86

3.3.2 การจำแนกวัตถุของโครงข่ายประสาทเทียม

ในทำนองเดียวกันกับในขั้นตอนแรก ในขั้นตอนที่สองนี้ประกอบด้วย 2 ส่วนเช่นเดียวกัน โดยในส่วนแรก ข้อมูลภาพดิจิทัลของชิ้นงานทั้ง 7 รูปแบบจะถูกทำการบันทึกเพิ่มเติม แต่ในส่วนที่สองนั้นโครงข่ายประสาทเทียมที่ได้จากในขั้นตอนแรกจะถูกนำมาใช้เพื่อจำแนกชิ้นงานจากข้อมูลภาพดิจิทัลที่ทำการบันทึกมาใหม่

ในการเก็บบันทึกข้อมูลภาพดิจิทัล ชิ้นงานจากจำนวนรูปแบบละ 3 ชิ้นจะถูกสุ่มเลือกออกมาเพื่อนำไปวางบนฐานอย่างสุ่มโดยไม่มีกำหนดตำแหน่งการวางไว้ล่วงหน้าเพื่อทำการบันทึกภาพดิจิทัล สำหรับชิ้นงานทั้ง 7 รูปแบบจะถูกทำการบันทึกภาพดิจิทัล รูปแบบละ 27 ครั้ง รวมข้อมูลภาพดิจิทัลของชิ้นงานทั้งหมดที่ใช้ในการทดลองจำแนกวัตถุมีจำนวนเท่ากับ 189 ภาพ

3.3.3 การประเมินประสิทธิภาพการจำแนกวัตถุของโครงข่ายประสาทเทียม

ประสิทธิภาพการจำแนกวัตถุจะถูกประเมินด้วยค่า 3 ค่า ดังนี้ 1) ความแม่นยำในการจำแนกวัตถุ (α) 2) ค่า sensitivity (S_c) และ 3) ค่า specificity (S_p) โดยค่าทั้งสามนี้สามารถคำนวณได้จาก

$$\alpha = \frac{TP}{N} \times 100\% \quad (16)$$

$$S_c = \frac{TP}{TP + FN} \times 100\% \quad (17)$$

$$S_p = \frac{TN}{TN + FP} \times 100\% \quad (18)$$

เมื่อ N คือจำนวนของชิ้นงานทั้งหมดที่ถูกจำแนก โดยในการทดลองนี้ $N=189$ และ TP , TN , FN และ FP หมายถึง จำนวนที่จำแนกได้ถูกต้องว่าเป็นชิ้นงาน

รูปแบบนั้น, จำนวนที่จำแนกได้อย่างถูกต้องว่าไม่ใช่ชิ้นงานรูปแบบนั้น, จำนวนที่จำแนกผิดพลาดโดยไม่ได้จำแนกชิ้นงานรูปแบบที่กำลังพิจารณาอยู่ว่าเป็นชิ้นงานรูปแบบนั้น (false negative) และจำนวนที่จำแนกผิดพลาดโดยจำแนกชิ้นงานรูปแบบอื่นว่าเป็นชิ้นงานรูปแบบที่กำลังพิจารณาอยู่ (false positive) ตามลำดับ

4. ผลการทดลอง

จากการทดลองทั้ง 2 ขั้นตอนดังที่ได้กล่าวไว้ข้างต้น ทำให้ได้ผลการทดลองเป็นดังนี้

4.1 ค่าเฉพาะตัวของวัตถุ

จากการคำนวณค่าเฉพาะตัวทั้ง 5 ค่าของวัตถุซึ่งประกอบด้วย พื้นที่ทั้งหมดของชิ้นงาน (x_1) พื้นที่ของรูชิ้นงาน (x_2) ค่าเฉลี่ยของด้านทั้งสี่ของกรอบสี่เหลี่ยมที่เล็กที่สุดที่สามารถล้อมรอบชิ้นงานได้พอดี (x_3) ค่าเฉลี่ยของด้านทั้งสี่ของกรอบสี่เหลี่ยมที่เล็กที่สุดที่สามารถล้อมรอบรูชิ้นงานได้พอดี (x_4) และค่าความยาวสูงสุดของชิ้นงาน (x_5) ในการทดลองในขั้นตอนแรกเพื่อที่จะนำไปใช้ในการเรียนรู้ของโครงข่ายประสาทเทียม ค่าเฉลี่ยและค่าเบี่ยงเบนมาตรฐาน (ค่าเฉลี่ย \pm ค่าเบี่ยงเบนมาตรฐาน) ของค่าเฉพาะตัวทั้ง 5 ค่าของชิ้นงานทั้ง 7 รูปแบบ ถูกสรุปไว้ในตารางที่ 1

จากตารางที่ 1 แสดงให้เห็นว่าคุณลักษณะและคุณสมบัติของชิ้นงานทั้ง 7 รูปแบบมีความแตกต่างกันอยู่พอสมควร ซึ่งจากความแตกต่างดังกล่าวทำให้เห็นได้ว่าชิ้นงานทั้ง 7 รูปแบบนั้นสามารถที่จะถูกจำแนกออกมาได้

$$\mathbf{b}_h = \begin{bmatrix} 17.7498 \\ 0.2858 \\ -0.3768 \\ -7.4373 \\ 5.8512 \\ -3.2602 \\ 7.0569 \end{bmatrix}, \mathbf{b}_o = \begin{bmatrix} 0.0001 \\ 0 \\ -0.0002 \\ 0.5000 \\ -0.2150 \\ 0.2148 \\ 0.5002 \end{bmatrix}, \mathbf{W}_h = \begin{bmatrix} 0.0025 & -0.0042 & -0.2251 & 0.5528 & -0.2911 \\ -0.0070 & -0.0101 & 0.0827 & 0.1078 & 0.5491 \\ 0.0021 & -0.0033 & -0.3750 & 0.3204 & 0.0845 \\ 0.0005 & 0.0094 & -0.1964 & -0.0728 & -0.0202 \\ 0.0010 & -0.0020 & -0.1003 & 0.2620 & -0.1046 \\ 0.0001 & -0.0051 & -0.0533 & 0.7797 & -0.1013 \\ -0.0002 & 0.0039 & 0.1850 & -0.4215 & -0.1711 \end{bmatrix}$$

$$\mathbf{W}_o = \begin{bmatrix} -0.110 & 0.0055 & 0.5056 & -0.5001 & 0.0110 & 0.4999 & 0.5000 \\ 0 & 0 & 0 & 0.5000 & 0 & 0 & -0.5000 \\ -0.0002 & 0 & -0.0002 & 0.0001 & 0.0004 & -0.5002 & -0.5001 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0.5000 \\ 0.9557 & -0.4988 & -0.4847 & -0.0001 & -0.7573 & 0.0183 & 0.0162 \\ -0.9443 & -0.0069 & -0.0207 & 0 & 0.7455 & -0.0180 & -0.0160 \\ -0.0003 & 0.5003 & 0 & 0 & 0.0004 & 0 & 0 \end{bmatrix}$$

รูปที่ 12 ค่าน้ำหนักและค่าไบอัสของโครงข่ายประสาทเทียม

ตารางที่ 2 ค่าเฉลี่ยและค่าเบี่ยงเบนมาตรฐานของค่าเฉพาะตัวของชั้นงานที่ใช้ในการจำแนกวัตถุ

ค่าเฉพาะตัว	O_1	O_2	O_3	O_4	O_5	O_6	O_7
x_1 (พิกเซล)	24799.30 ± 1041.99	28401.37 ± 977.06	24724.70 ± 1492.81	36699.33 ± 1051.11	10267.48 ± 593.85	11986.93 ± 537.70	6207.33 ± 309.45
x_2 (พิกเซล)	3282.26 ± 179.23	5626.44 ± 205.76	1003.67 ± 78.41	18496.41 ± 716.34	1572.67 ± 100.86	1549.81 ± 121.68	1231.56 ± 145.08
x_3 (พิกเซล)	178.19 ± 3.85	203.07 ± 3.41	179.15 ± 5.88	216.63 ± 3.18	115.37 ± 3.00	129.52 ± 3.49	89.59 ± 2.22
x_4 (พิกเซล)	65.30 ± 1.77	85.04 ± 1.58	37.00 ± 2.57	155.89 ± 4.09	45.26 ± 1.63	44.78 ± 1.72	40.19 ± 2.20
x_5 (พิกเซล)	179.48 ± 4.08	201.11 ± 3.32	179.15 ± 5.45	217.67 ± 3.29	115.89 ± 3.40	128.52 ± 3.26	90.22 ± 2.75

โดยใช้ค่าเฉพาะตัวทั้ง 5 ค่านี้

4.2 คุณลักษณะของโครงข่ายประสาทเทียมสำหรับจำแนกวัตถุ

เมื่อนำข้อมูลค่าเฉพาะตัวทั้ง 5 ค่าของชั้นงานทั้งหมดซึ่งถูกสรุปไว้ในตารางที่ 1 มาป้อนเข้าสู่โครงข่ายประสาทเทียมที่ออกแบบไว้ เพื่อที่จะให้โครงข่ายประสาทเทียมดังกล่าวได้ปรับตัวและเรียนรู้ค่าเฉพาะตัวทั้ง 5 ค่าของชั้นงานทั้งหมด เมื่อกระบวนการเรียนรู้ของโครงข่ายประสาทเทียมสิ้นสุดลงทำให้โครงสร้างของโครงข่ายประสาทเทียมมีคุณลักษณะดังแสดงในรูปที่ 12 เมื่อ

$$\mathbf{b}_h = [b_6 \ b_7 \ b_8 \ b_9 \ b_{10} \ b_{11} \ b_{12}]^T,$$

$$\mathbf{b}_o = [b_{13} \ b_{14} \ b_{15} \ b_{16} \ b_{17} \ b_{18} \ b_{19}]^T,$$

$$\mathbf{W}_h = \begin{bmatrix} w_{1,6} & w_{1,7} & \dots & w_{1,12} \\ \vdots & \vdots & \ddots & \vdots \\ w_{5,6} & w_{5,7} & \dots & w_{5,12} \end{bmatrix},$$

$$\mathbf{W}_o = \begin{bmatrix} w_{6,13} & w_{6,14} & \dots & w_{6,19} \\ \vdots & \vdots & \ddots & \vdots \\ w_{12,13} & w_{12,14} & \dots & w_{12,19} \end{bmatrix}$$

4.3 ประสิทธิภาพในการจำแนกวัตถุ

ตารางที่ 2 แสดงค่าเฉลี่ยและค่าเบี่ยงเบนมาตรฐานของค่าเฉพาะตัวทั้ง 5 ค่าของชั้นงานทั้งหมดที่จะถูกทำการจำแนกโดยใช้โครงข่ายประสาทเทียม เมื่อนำโครงข่ายประสาทเทียมที่ผ่านกระบวนการเรียนรู้แล้วไปใช้ในการจำแนกวัตถุจากข้อมูลภาพดิจิทัลของชั้นงานทั้ง

ตารางที่ 3 ผลการจำแนกวัตถุของโครงข่ายประสาทเทียม

ชั้นงาน	TP	TN	FN	FP
O_1	27	162	0	0
O_2	27	162	0	0
O_3	27	162	0	0
O_4	27	162	0	0
O_5	27	162	0	0
O_6	27	162	0	0
O_7	27	162	0	0

7 รูปแบบ จำนวน 189 ภาพ ทำให้ได้ผลการจำแนกวัตถุ (ค่า TP, TN, FN และ FP) สรุปได้ดังแสดงในตารางที่ 3

จากผลการจำแนกดังกล่าวทำให้ได้ค่าแม่นยำของชั้นงานทั้ง 7 รูปแบบมีค่าเท่ากับ 100% ค่า sensitivity สำหรับการจำแนกชั้นงานทั้ง 7 รูปแบบมีค่าเท่ากับ 100% และค่า specificity สำหรับการจำแนกชั้นงานทั้ง 7 รูปแบบมีค่าเท่ากับ 100% เช่นเดียวกัน โดยประสิทธิภาพในการจำแนกวัตถุของโครงข่ายประสาทเทียมที่ออกแบบไว้นั้นถูกสรุปในตารางที่ 4 ด้วย

5. สรุปและอภิปรายผลการทดลอง

ในการศึกษานี้ การจำแนกวัตถุอัตโนมัติโดยใช้การประมวลผลและวิเคราะห์ภาพดิจิทัลร่วมกับโครงข่ายประสาทเทียมถูกนำมาประยุกต์ใช้ในการจำแนกชั้นงานทางอุตสาหกรรม โดยในการทดลองเป็นการจำแนกชั้นงานทั้งหมด 7 รูปแบบ คุณลักษณะและคุณสมบัติของชั้นงานถูกสกัดออกมาและนำไปใช้ในการจำแนกคือค่าเฉพาะตัว 5 ค่า คือ พื้นที่ทั้งหมดของชั้นงาน (x_1) พื้นที่ของรูชั้นงาน (x_2) ค่าเฉลี่ยของด้านทั้งสี่ของกรอบสี่เหลี่ยมที่เล็กที่สุดที่สามารถล้อมรอบชั้นงานได้พอดี (x_3) ค่าเฉลี่ยของด้านทั้งสี่ของกรอบสี่เหลี่ยมที่เล็กที่สุดที่สามารถล้อมรอบรูชั้นงานได้พอดี (x_4) และค่าความยาวสูงสุดของชั้นงาน (x_5) จากผลการทดลองพบว่าชั้นงานทั้งหมดสามารถถูกจำแนกออกมาได้อย่างถูกต้องสมบูรณ์โดยไม่มีข้อผิดพลาด นอกจากนี้ค่าเฉพาะตัวทั้ง 5 ค่าที่ถูกนำมาใช้ในการศึกษานี้แล้ว ยังมีคุณลักษณะและคุณสมบัติอื่นๆ ของชั้นงานทั้ง 7 รูปแบบที่สามารถถูกนำมาใช้ในการจำแนกได้อีก

จากการศึกษานี้สามารถนำไปใช้ในการศึกษาวิจัย

ตารางที่ 4 ประสิทธิภาพในการจำแนกวัตถุของโครงข่ายประสาทเทียม

ชั้นงาน	α	S_c	S_p
O_1	100%	100%	100%
O_2	100%	100%	100%
O_3	100%	100%	100%
O_4	100%	100%	100%
O_5	100%	100%	100%
O_6	100%	100%	100%
O_7	100%	100%	100%

อื่นๆ ต่อไปในอนาคต ซึ่งรวมถึงการเพิ่มจำนวนรูปแบบของชั้นงานในการจำแนก โดยถ้าหากมีการเพิ่มจำนวนรูปแบบของชั้นงานขึ้นหรือมีการปรับเปลี่ยนรูปแบบของชั้นงานนั้น คุณลักษณะและคุณสมบัติของชั้นงานที่จะถูกนำไปใช้ในการจำแนกอาจจะต้องมีการปรับเปลี่ยนด้วยเช่นกัน ซึ่งจะต้องปรับเปลี่ยนให้สอดคล้องและเหมาะสมกับรูปแบบของชั้นงานทั้งหมด การจำแนกวัตถุอัตโนมัติยังคงสามารถถูกนำไปใช้ร่วมกับในกระบวนการผลิต โดยทำการต่อพ่วงเข้ากับระบบควบคุมในกระบวนการผลิต นอกจากนี้แล้วกระบวนการจำแนกวัตถุอัตโนมัติที่ถูกศึกษาในงานวิจัยนี้สามารถถูกขยายกระบวนการไปจนถึงการตรวจสอบคุณภาพของชั้นงานอีกด้วย

กิตติกรรมประกาศ

การศึกษานางานวิจัยนี้ได้รับความอนุเคราะห์จากบริษัท ไทยไฟน์ซินเตอร์ จำกัด ที่ได้มอบชั้นงานทั้งหมดเพื่อใช้ในการศึกษา

เอกสารอ้างอิง

- [1] Gonzalez, R.C. and Woods, R.E. 2002. Digital Image Processing, Prentice Hall, New Jersey, U.S.A.
- [2] Gonzalez, R.C., Woods, R.E. and Eddins, S.L. 2004. Digital Image Processing Using Matlab, Prentice Hall, New Jersey, U.S.A.
- [3] Otsu, N. 1979. A threshold selection method from gray-level histograms. IEEE Trans. Sys., Man. Cyber., 9: 62-66.
- [4] Jang, J.-S. R., Sun, C.-T. and Mizutani, E. 1997.

Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence, Prentice Hall, New Jersey, U.S.A.

- [5] Rosenblatt, F. 1962. Principles of Neurodynamics: Perceptrons and the Theory of Brain Learning, Spartan, New York, U.S.A.
- [6] Minsky, M. and Papert, S. 1969. Perceptrons, MIT Press, Massachusetts, U.S.A.
- [7] McCulloch, W.S. and Pitts, W. 1943. A logical calculus of the ideas imminent in neural nets. Bulletin of Math. Biophys., 5: 115-137.





บันทึกข้อความ

ส่วนราชการ ภาควิชาวิศวกรรมไฟฟ้า คณะวิศวกรรมศาสตร์ มหาวิทยาลัยอุบลราชธานี โทร. 3329

ที่ ศช 0529.8.6/พิเศษ

วันที่ 24 มกราคม 2554

เรื่อง ขออนุมัติค่าตอบแทนการตีพิมพ์ผลงานในวารสารวิชาการเรื่อง Classification of the Epileptic EEGs Using the Wavelet-Based Scale Variance Feature

เรียน รองคณบดีฝ่ายวิจัยและบริการวิชาการ ผ่านหัวหน้าภาควิชาวิศวกรรมไฟฟ้า

อ้างถึงประกาศฉบับที่ 40/2550 ประกาศ ณ วันที่ 22 ตุลาคม 2550 คณะวิศวกรรมศาสตร์ เรื่อง “หลักเกณฑ์การจ่ายค่าตอบแทนการตีพิมพ์ผลงานวารสารวิชาการ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยอุบลราชธานี” ตามความทราบแล้วนั้น

เนื่องจากบทความทางวิชาการของ ดร.ศุภฤกษ์ จันทรจักรสัตตต์ เรื่อง “Classification of the Epileptic EEGs Using the Wavelet-Based Scale Variance Feature” ได้รับการตีพิมพ์ในวารสารวิชาการระดับนานาชาติ International Journal of Applied Biomedical Engineering; 3:19-25 ดังนั้นภาควิชาวิศวกรรมไฟฟ้า และอิเล็กทรอนิกส์ จึงใคร่ขออนุมัติค่าตอบแทนการตีพิมพ์ผลงานในวารสารวิชาการในเรื่องดังกล่าว

จึงเรียนมาเพื่อโปรดพิจารณา

(ดร.ศุภฤกษ์ จันทรจักรสัตตต์)

อาจารย์ประจำภาควิชาวิศวกรรมไฟฟ้าและอิเล็กทรอนิกส์

รับทราบคณบดีฝ่ายวิจัยฯ

เพื่อโปรดพิจารณา

24 ม.ค. 54

IJABME Manuscript Submission Guide

General

The **International Journal on Applied Biomedical Engineering (IJABME)** is published *bi-annually* by ThaiBME Society. Contributed papers must be original that advance the state-of-the art and applications of Biomedical Engineering. Both theoretical contributions (including new techniques, concepts, and analyses) and practical contributions (including system experiments and prototypes, and new applications) are encouraged. The submitted manuscript must have been copyrighted, published, or submitted or accepted for publication elsewhere, except in a conference proceedings. The manuscript text should not contain any commercial references, such as company names, university names, trademarks, commercial acronyms, or part numbers. Not accepted material will not be returned.

Submission Due

Authors should document their work in relation to the open literature. The following limits on length (A4 size) should be observed.

- **End of March**, for January-June issue.
- **End of September**, for July-December issue.

Length

Authors should document their work in relation to the open literature. The following limits on length (A4 size) should be observed.

- 1) **Regular papers**, should be at least 6 pages and up to 12 pages in length, including figures and illustrations.
- 2) **Correspondences**, less than 3 pages in length, including figures and illustrations.

Styles for Manuscript

- 1) The manuscript must be in English.
- 2) Provide a carefully worded abstract of 150 to 300 words for regular papers and less than 150 words for correspondences. If the manuscript is not submitted via the website, Name, address, and telephone number of author(s) should be organised on a separate cover page.
- 3) The style for organization of a paper can be found in the manuscript template file.

Form and Submissions

- 1) The manuscripts itself
- 2) Cover Page: should include
 - Paper title
 - Paper category (regular paper or correspondence)
 - Full name of all authors
 - Name and address of the key author whom proofs and other correspondence can be sent
 - Keywords (duplicate from the paper)
 - Abstract (duplicate from the paper)
 - Date of submission

Notes:

1. Authors are encouraged to submit their paper in electronic form via the IJABME website. The first sent manuscripts must be in the form of *pdf* files. In any case of difficulty, the manuscript could be also attached to standard emails and sent directly to the editor.
2. Authors who are not convenient to submit paper in electronic form, hard copy formatted is also appreciated. Authors are to send four copies of the manuscript.
3. The accepted and/or revised manuscript must be resubmitted for IJABME publishing. Text files are appreciated. The manuscript will be reformatted upon IJABME style.
4. Original illustrations (could be also good resolution image files) must be ready for immediately submission upon acceptance of the manuscript. In the case of regular papers, also be prepared to provide a brief technical biography and photograph of each author.

Where to Submit

Electronic version of the manuscript must be submitted online via IJABME website; <http://www.ijabme.org>.

Review Process

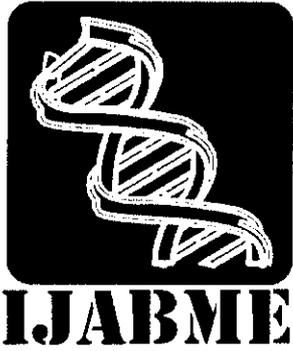
The review process usually takes 3 weeks to 3 months. The author is then notified the decision of the editor based on the reviewers' recommendations. Authors may be asked to revise the manuscript if it is not accepted or rejected in its original form. The un-accepted manuscript will not be returned to authors.

Page Charges

After the manuscript has been reviewed and accepted for its publication, the author's company or institution will be asked to pay a charge of 1,000 THB (or 33 USD) per printed page to cover part of the cost of publication. ThaiBME members will receive full reduction on page charge. Printing of colour pages are specially requested and fully paid by the authors. Page charges can be exempted upon request.

Copyright

It is the policy of the ThaiBME to own the copyright to the published contributions on behalf of the interests of ThaiBME, its authors, and their employers, and to facilitate the appropriate reuse of this material by others. To comply with the Copyright Law, authors are required to sign a copyright transfer form before publication. This form, a copy of which appears in this journal, returns to authors and their employers full rights to reuse their material for their own purposes.



International Journal of Applied Biomedical Engineering

Vol. 3, No. 1, January - June 2010

I
J
A
B
M
E

Editorial Board	1
Message from the Editor-in-chief	11

REGULAR PAPERS

Biological Inspiration for Mechanical Design and Control of Autonomous Walking Robots Towards Life-Like Robots P. Manoonpong, F. Wörgötter and F. Pasemann	1
Wheelchair Control Based on Bioimpedance H. Yunfei, P. Phukpattaranont, B. Wongkittisuksa and S. Terintanun	13
Classification of the Epileptic EEGs Using the Wavelet-Based Scale Variance Feature S. Janjarasjit	19
Discrete Wavelet Transform-based Baseline Wandering Removal for High Resolution Electrocardiogram C. Bunluechokchai and T. Leelodomwong	28
Header Format for Selective Mapping Technique on Wavelet based ECG Compression Y. Chompusri, K. Dehan and S. Jimmai	36
Pattern Recognition in Brain FMRI for Agnosia P. Pongpanitanont, W. Sittiprapaporn and W. Charoensri	39
Fine Exudate Detection using Morphological Reconstruction Enhancement A. Sopharak, B. Uyyanonvara, S. Barman, S. Vongkittirux, and N. Wongkamchan	45
Medical Consult-Based System for Diagnosis on WiMAX Technology K.Noimanee, S.Noimanee, P.Khunjia and P.Keawfoongsoe	51

Manuscript Submission Guideline

Classification of the Epileptic EEGs Using the Wavelet-Based Scale Variance Feature

Suparek Janjarasjitt, Member

ABSTRACT

The detection and classification of epileptic seizures are an important component for the analysis and diagnosis of epilepsy. In this study, the wavelet transform is used as a primary computational tool for extracting characteristics of the epileptic EEG signals at various scales (resolutions). The wavelet-based scale variance defined as log-variance of wavelet coefficients of the epileptic EEG signal is used as a feature vector for the classification. The k -means clustering is then used to classify the epileptic EEG data from the corresponding wavelet-based scale variance features. The computational results show that the excellent classifications between the epileptic EEG data during seizure activity and non-seizure period can be achieved.

Keywords: Electroencephalogram; Epilepsy; Seizure; Wavelet transform; k -means clustering

1. INTRODUCTION

Epilepsy is a common brain disorder in which clusters of neurons signal abnormally [1]. More than 50 million individuals worldwide, about 1% of the world's population are affected by epilepsy [2]. In epilepsy, the normal pattern of neuronal activity becomes disturbed, causing strange sensations, emotions, and behavior, or sometimes convulsions, muscle spasms, and loss of consciousness [1]. There are many possible causes of epilepsy. Anything that disturbs the normal pattern of neuron activity ranging from illness to brain damage to abnormal brain development can lead to seizures [1]. Epileptic seizures are manifestations of epilepsy [3].

Electroencephalogram (EEG) which provides insight information representing the brain's electrical activity is the most utilized signal to assess and detect abnormalities in the electrical activity of the brain, and is a crucial component for the diagnosis of epilepsy [1]. Even though the brain's electrical activity and the unusual pattern of EEG during the epileptic seizure may differ significantly from the brain's electrical activity during non-seizure period, the de-

tection of epileptic seizures is however challenging for a number of reasons.

There have been several techniques, derived from a variety of concepts and theories such as linear analysis, nonlinear analysis and chaos, and artificial neural networks, proposed and used for the detection and classification of epileptic seizures. Spectral analysis is the simplest technique used to examine the characteristics of the EEG signal in frequency and time-frequency domains [3]. The frequency contents of the EEG signal change before and during seizures. Nonlinear analysis techniques such as correlation dimension and Lyapunov exponent have been widely used in EEG analysis including seizure detection [4-6]. Further, most of seizure prediction methods employ nonlinear analysis techniques [3]. In general, the complexity of the dynamics of the neuronal system of the brain is lost during seizures.

Recently, artificial neural networks techniques have played a significant role in classification and pattern recognition including the detection and classification of epileptic seizures [7]. Wavelet is a powerful and efficient computational tool for time-scale analysis which has been applied to various applications. For the seizure detection and classification, wavelet is used as an ideal bandpass filter [8] and also used to extract the features and characteristics of the epileptic EEG signals at different scales or resolutions [3].

In this study, the epileptic EEG signals obtained from different physiological and pathological brain states, and recorded from different regions of the brain are analyzed and then classified. The wavelet transform is used as a primary computational tool for extracting the characteristics of the epileptic EEG signals at various scales. The wavelet-based scale variance that is defined as log-variance of wavelet coefficients of the EEG signals is used as a feature for the classification of the epileptic EEG data. The k -means clustering that is the unsupervised classification method is used for the classification of the epileptic EEG data.

From the computational experiments, the exceptional performance of the classifications of the epileptic EEG data using the simple k -means clustering of the wavelet-based scale variance features is illustrated. The epileptic EEG data recorded during seizure activity can be classified and separated from the epileptic EEG data recorded during seizure-free interval using the wavelet-based scale variance feature. In addition, the results show that the re-

Manuscript received on June 1, 2010; revised on September 30, 2010

Suparek Janjarasjitt is with the Department of Electrical and Electronic Engineering, Ubon Ratchathani University, Warin-chamrab, Ubon Ratchathani 34190 Thailand.

E-mail address: cnsupajt@ubu.ac.th

gion of the brain where the epileptic EEG data were recorded, i.e., within the epileptogenic zone and far-away from the seizure origin, has an influence on the classification.

2. BACKGROUND

2.1 Wavelet Transforms

Wavelets have been introduced by Grossmann and Morlet [9] for the representation of a function in $L_2(\mathcal{R})$. The continuous wavelet transform of a function $f \in L_2(\mathcal{R})$ is defined as [10]

$$Wf(a, b) = \langle f, \psi_{a,b} \rangle \\ = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} f(t) \psi^* \left(\frac{t-b}{a} \right) dt \quad (1)$$

where ψ is a fix function called mother wavelet. A family of wavelets, $\psi_{a,b}$, is normalized dilations and translations of the mother wavelet ψ [11, 12]:

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi \left(\frac{t-b}{a} \right), \quad a > 0, b \in \mathcal{R}. \quad (2)$$

The mother wavelet ψ is well localized both in time and frequency [13]. For a large scale a , the wavelet $\psi_{a,b}$ becomes a stretched version of the mother wavelet corresponding to low frequency content, while for a small scale a , the wavelet $\psi_{a,b}$ becomes a contracted wavelet corresponding to high frequency content. The continuous wavelet transform is invertible if the mother wavelet ψ satisfies the admissibility condition [14]:

$$C_{\psi} = \int_{-\infty}^{+\infty} \frac{\|\hat{\psi}(\omega)\|^2}{\|\omega\|^2} d\omega < +\infty \quad (3)$$

where $\hat{\psi}(\omega)$ is the Fourier transform of the mother wavelet. To guarantee that the integral of the condition in (3) is finite, it is required that $\hat{\psi}(0) = 0$ [14]. The function f can then be reconstructed by

$$f(t) = \frac{1}{C_{\psi}} \int_0^{+\infty} \frac{da}{a^2} \int_{-\infty}^{+\infty} Wf(a, b) \psi_{a,b}(t) db. \quad (4)$$

Of particular interest is the discretization of the dilation and translation parameters, a and b , on a dyadic grid, that is $a = 2^m$ and $b = n2^m$ where $m, n \in \mathbb{Z}$. Accordingly, a family of dyadic wavelets is given by [10]

$$\psi_{m,n} = \frac{1}{\sqrt{2^m}} \psi(2^{-m}t - n). \quad (5)$$

It is possible to construct a collection of dyadic wavelets $\psi_{m,n}$ that is orthonormal, i.e., $\langle \psi_{m,n}, \psi_{k,l} \rangle = \delta_{m,k} \delta_{n,l}$ [10]. Consequently, the discrete wavelet transform of the function f is defined by

$$d_{m,n} = \langle f, \psi_{m,n} \rangle \\ = \frac{1}{\sqrt{2^m}} \int_{-\infty}^{+\infty} f(t) \psi^*(2^{-m}t - n) dt \quad (6)$$

where $d_{m,n}$ are called wavelet coefficients, and $d_{m,n}^2$ represent an estimate of the energy of the function f in the vicinity of $t = 2^m n$. In addition, the wavelets $\psi_{m,n}$ associate to the scale 2^m or the resolution 2^{-m} . From a signal processing point of view, a dyadic orthonormal wavelet is an octave band filter. Therefore, the wavelet transform can be interpreted as a constant- Q filtering with a set of octave-band filters which is followed by sampling at the respective Nyquist frequencies [10]. It is also clear that the details or resolution can be added to the signal by adding higher octave bands [10].

Moreover, the partial sum of wavelet coefficients, i.e., $\sum_{n=-\infty}^{+\infty} d_{m,n} \psi_{m,n} = \sum_{n=-\infty}^{+\infty} \langle f, \psi_{m,n} \rangle \psi_{m,n}$, can be interpreted as the difference between two approximations of f at the resolution 2^{-m+1} and 2^{-m} [14]. Multiresolution approximations compute the approximation of signals at various resolutions 2^{-m} with orthogonal projections on different spaces $\mathbf{V}_m \subset \mathbf{V}_{m-1}$ such that $\mathbf{V}_m \in \mathbf{V}_{m-1}$ where $\mathbf{V}_m \in L_2(\mathcal{R})$ [14].

2.2 The k -means Clustering Algorithm

Clustering is the unsupervised classification of patterns such as feature vectors into groups (clusters) [15]. The k -means is the simplest and most commonly used clustering algorithm that employs a squared error criterion [16]. The squared error criterion is the most intuitive criterion function in partitional clustering techniques. The squared error criterion tends to work well with isolated and compact clusters [15].

The squared error for a clustering \mathcal{L} of a pattern set \mathcal{H} that contains K clusters is [15]

$$\varepsilon^2(\mathcal{H}, \mathcal{L}) = \sum_{j=1}^K \sum_{i=1}^{n_j} \|\mathbf{x}_i^j - \mathbf{c}_j\|^2 \quad (7)$$

where \mathbf{x}_i^j is the i th patterns belonging to the j th cluster and \mathbf{c}_j is the geometric centroid of the j th cluster. The steps of the squared error clustering method are as follows [15]:

1. Choose an initial partition of the patterns for K clusters.
2. Assign each pattern to the closest cluster center.
3. Compute the new cluster centers as the centroids of the clusters.
4. Repeat steps 2-3 until convergence is achieved, i.e., there is no change of the cluster membership.
5. Combine and split clusters based on some heuristic information.

Similarly, the k -means starts with a random initial partition and keeps reassigning the patterns to clusters based on the similarity between the pattern and the cluster centers until a convergence criterion is met, e.g. there is no reassignment of any pattern from one cluster to another, or the squared error ceases to decrease significantly after some number of iterations [15]. The computational complexity of the k -means algorithm is linear to the number of patterns n , i.e.,

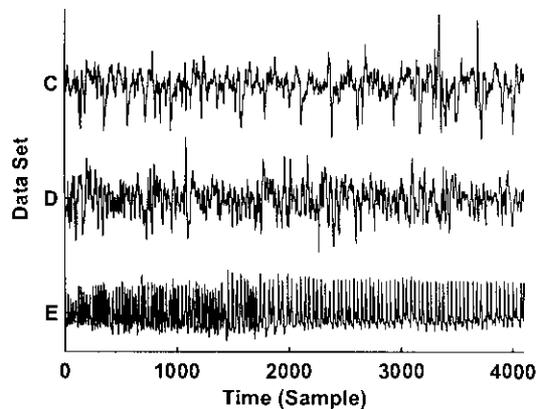


Fig.1: Examples of EEG time series of the data sets C, D, and E.

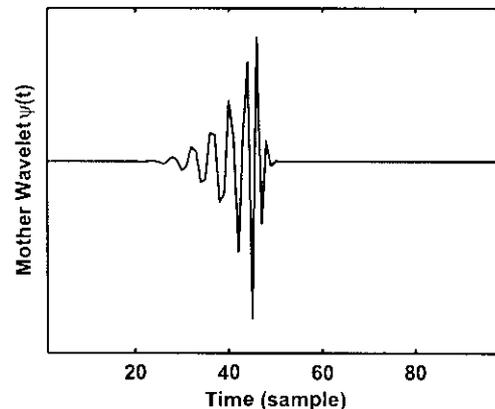


Fig.2: The mother wavelet of the 25th-order Daubechies wavelet family.

$O(n)$. A primary disadvantage of the k -means algorithm is that it is sensitive to the selection of the initial partition and may converge to a local minimum of the criterion function value if the initial partition is not properly chosen [15].

The steps of the k -means clustering algorithm are as follows [15]:

1. Initialize K cluster centers by randomly choosing K patterns.
2. Assign each pattern to the closest cluster center.
3. Compute the cluster centers using the current cluster membership.
4. If a convergence criterion is not met, go to step 2. Typically, the convergence criteria are: no or minimal reassignment of patterns to new cluster centers, or minimal decrease in squared error.

3. METHODS

3.1 EEG Data

There are 3 sets of EEG data, referred to as sets C, D and E, examined in this study. The EEG data are obtained from the Department of Epileptology, University of Bonn (available online at <http://www.epileptologie-bonn.de>) where the EEG data originated from the study presented in [17]. The EEG data were recorded using intracranial electrodes from five epilepsy patients. Further, the EEG data of the set C were recorded from the hippocampal formation of the opposite hemisphere of the brain from where the seizure was thought to have originated. The EEG data of the sets D and E were recorded from within the epileptogenic zone. The EEG data of the sets C and D correspond to EEG data during non-seizure period while the EEG data in the set E were recorded during seizure activity.

Each EEG data set contains 100 epochs of a single-channel EEG signal that were selected to be free of artifacts such as muscle activity and eye movements. The length of each epoch is 4.097 samples (about

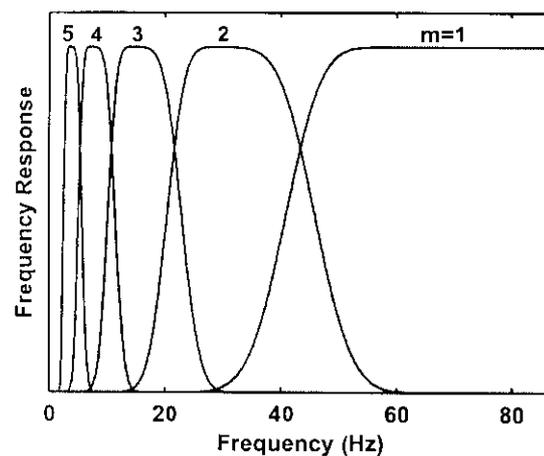


Fig.3: The associated octave bands of the 25th-order Daubechies wavelets at the scales $2^1, 2^2, \dots, 2^5$.

23.6s). In addition, the epochs of the EEG signal satisfied the weak stationarity criterion given in [17]. The sampling rate of the EEG data is 173.61 Hz. The bandpass filter of the acquisition system has the spectral bandwidth between 0.50 Hz and 85 Hz [17]. Examples of the EEG signal for each data set are illustrated in Fig. 1.

3.2 The Wavelet-Based Scale Variance

The wavelet-based scale variance that is used as the feature vector for the classification of the epileptic EEG signals is composed of 3 steps as follows. First, the wavelet coefficients $d_{m,n}$ of the signal is determined by applying the wavelet decomposition. The variance of the wavelet coefficients of each scale 2^m is then calculated: $v_m = \text{var}(d_{m,n})$ for all n . Finally, take log (base 2) of the variance of wavelet coefficients of each scale 2^m . The feature vector of the wavelet-based scale variance of the signal \mathbf{v} can be written

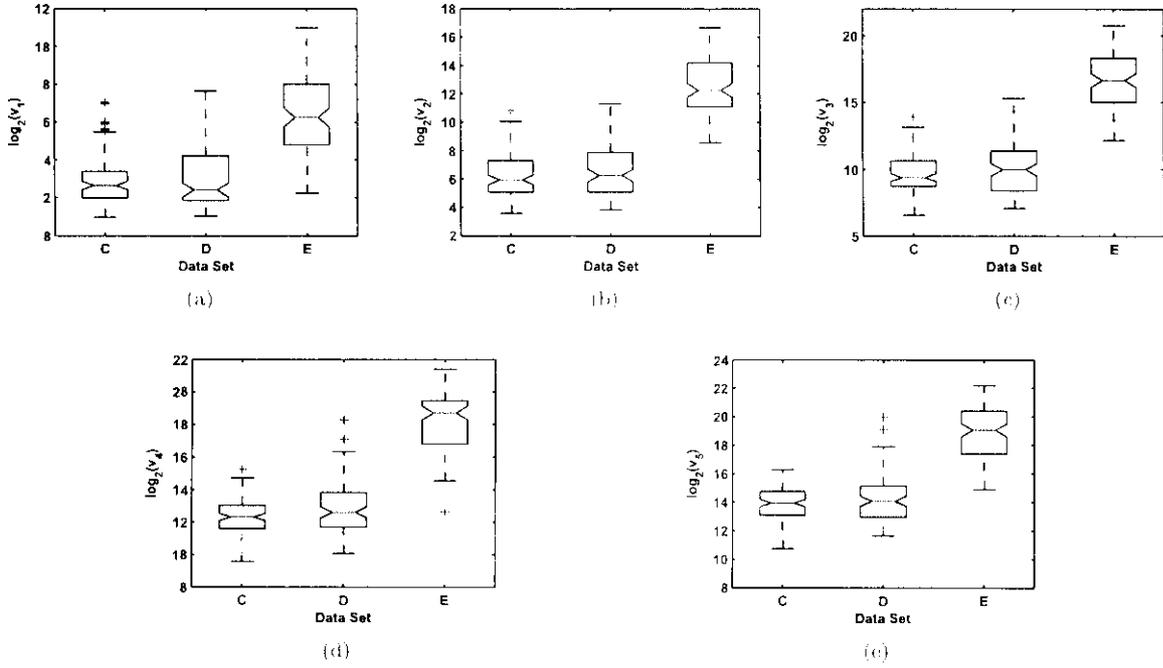


Fig. 4: The box plot of the wavelet-based scale variance of the epileptic EEG data of the sets C, D and E at the scale: (a) 2^1 , (b) 2^2 , (c) 2^3 , (d) 2^4 and (e) 2^5 .

as

$$\mathbf{v}_d = \begin{bmatrix} \log_2(v_i) \\ \log_2(v_{i+1}) \\ \vdots \\ \log_2(v_j) \end{bmatrix} \quad (8)$$

where the scales $\{2^m; m = i, i+1, \dots, j\}$ are the scale that is used in the classification.

3.3 Analytic Framework

In this study, the 25th-order Daubechies wavelet family is used in the wavelet decomposition where the mother wavelet is illustrated in Fig. 2. The EEG data are decomposed into 5 scales, i.e., $2^1, 2^2, \dots, 2^5$ which correspond to the levels $m = 1, 2, \dots, 5$ where the associated octave bands of the 25th-order Daubechies wavelets at the scales $2^1, 2^2, \dots, 2^5$ are, respectively, 85-43.42, 43.42-21.71, 21.71-10.86, 10.86-5.43 and 5.43-2.72 Hz. Further, the magnitude of the frequency response of the corresponding octave band filters is depicted in Fig. 3. The patterns used for the classification of the epileptic EEG data are the feature vector of the wavelet-based scale variance at only the scales $2^2, 2^3, \dots, 2^5$ (corresponding to the levels $m = 2, 3, \dots, 5$) which provide the best outcomes of the classification for these EEG data sets.

In classification, the k -means clustering is employed to classify the feature vectors of the wavelet-based scale variance of the EEG signals. Specifically, the classification of the epileptic EEG signals performed in this study is divided into three tasks as

follow:

- Task 1: the classification between the EEG data of the set C and of the set E.
- Task 2: the classification between the EEG data of the set D and of the set E.
- Task 3: the classification between the EEG data of the sets C and D and of the set E.

3.4 Evaluation of Performance of the Classification

In addition to the accuracy of the classification of the EEG data, the performance of the classification of the EEG data is evaluated by determining two parameters, i.e., the sensitivity (the true positive ratio) and the specificity (the true negative ratio). The sensitivity and the specificity are given by, respectively,

$$S_e = \frac{TP}{TP + FN} \times 100\% \quad (9)$$

$$S_p = \frac{TN}{TN + FP} \times 100\% \quad (10)$$

where TP , FN , TN , and FP denote the number of the true positives, the number of the false negatives, the number of true negative, and the number of the false positives, respectively.

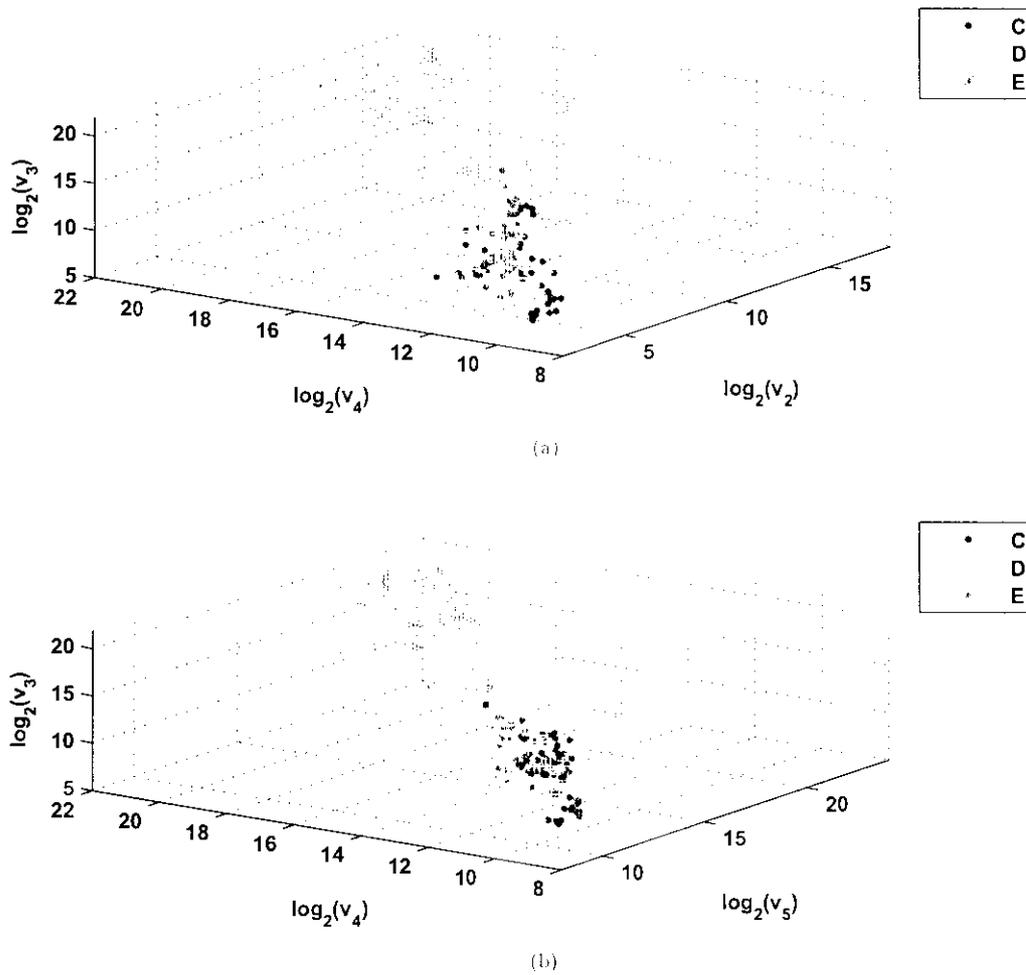


Fig. 5: The wavelet-based scale variance of the epileptic EEG data of the sets *C*, *D* and *E* at the scales: (a) 2^2 , 2^3 and 2^4 and (b) 2^3 , 2^4 and 2^5 .

Table 1: The Wavelet-Based Scale Variance of the EEG Data

Scale	Set <i>C</i>	Set <i>D</i>	Set <i>E</i>
2^1	3.0103 ± 1.4025	3.0077 ± 1.4430	6.3764 ± 2.0805
2^2	6.2433 ± 1.6252	6.5470 ± 1.7452	12.4581 ± 1.9467
2^3	9.5599 ± 1.5252	10.0714 ± 1.8045	16.7245 ± 2.0125
2^4	12.2154 ± 1.2330	12.8257 ± 1.5669	18.2717 ± 1.7967
2^5	13.7775 ± 1.2381	14.1975 ± 1.5345	18.8500 ± 1.8052

4. RESULTS

4.1 The Wavelet-Based Scale Variance of the Epileptic EEGs

The wavelet-based scale variance features of the EEG data of the sets *C*, *D* and *E* at the scales

2^1 , 2^2 , 2^3 , 2^4 and 2^5 (corresponding to the levels $m = 1, 2, \dots, 5$) are compared in box plots shown in Fig. 4(a)-Fig. 4(e), respectively. The mean and standard deviation values of the wavelet-based scale variance features of the EEG data of the sets *C*, *D* and *E* at the scales 2^1 , 2^2 , 2^3 , 2^4 and 2^5 are summarized in Table 1. Obviously, the wavelet-based scale variance feature of the EEG data of the set *E* tends to be higher than that of the EEG data of the set *D*, and the wavelet-based scale variance feature of the EEG data of the set *D* tends to be higher than that of the EEG data of the set *C*. Further, the wavelet-based scale variance feature of the EEG data of the set *E* is significantly higher than that of the EEG data of the sets *C* and *D* with p -value much less than 0.0001 ($p \ll 0.0001$) at all scales $2^1, 2^2, \dots, 2^5$. There is however not a statistically significant difference between the wavelet-based scale variance features of the EEG data of the sets *C* and *D* at all scales $2^1, 2^2, \dots, 2^5$.

Furthermore, the wavelet-based scale variance features of the EEG data of the sets *C*, *D* and *E* at the

Table 2: Classification Results of Task 1

	No. of Correct Classification	No. of False Classification
Set <i>C</i>	99	1
Set <i>E</i>	99	1

Table 3: Classification Results of Task 2

	No. of Correct Classification	No. of False Classification
Set <i>D</i>	95	5
Set <i>E</i>	99	1

Table 4: Classification Results of Task 3

	No. of Correct Classification	No. of False Classification
Sets <i>C</i> and <i>D</i>	194	6
Set <i>E</i>	99	1

scales 2^2 , 2^3 , 2^4 and 2^5 (corresponding to the levels $m = 2, 3, 4$ and 5) that are the feature vectors used in the classification of the EEG data are illustrated in 3-D plots. Fig. 5(a) exhibits the formation of the wavelet-based scale variance features of the EEG data of the sets *C*, *D* and *E* at the scales 2^2 , 2^3 and 2^4 while Fig. 5(b) exhibits the formation the wavelet-based scale variance features of the EEG data of the sets *C*, *D* and *E* at the scales 2^3 , 2^4 and 2^5 . It is shown that the wavelet-based scale variance feature of the EEG data of the set *E* (plotted in the "*" mark) is well-grouped and aligned on one side of the plots, while the wavelet-based scale variance features of the EEG data of the sets *C* and *D* (plotted in the "o" and "+" marks, respectively) are mixed together and aligned on the opposite side of the plots. Visually, the wavelet-based scale variance features therefore show a promising result for the classification of the EEG data.

4.2 The Classification of the Epileptic EEGs

The wavelet-based scale variance features of the EEG data of the sets *C*, *D* and *E* at the scales 2^2 , 2^3 , 2^4 and 2^5 as shown in Fig. 5(a) and Fig. 5(b) are used as the feature vectors for the classification of the epileptic EEG data using *k*-means clustering. The outcomes of the classification of the epileptic EEG data of Task 1, Task 2, and Task 3 are, respectively, summarized in Table 2, Table 3, and Table 4. The accuracy of the classification of the epileptic EEG data for the set *C* in Task 1 is 99.00%, while the accuracy of the classification of the epileptic EEG data for the set *D* in Task 2 is 95.00%. Also, the classification of the epileptic EEG data for the set *E* is 99.00% accurate in all three tasks, i.e., Task 1, Task 2 and Task 3.

Table 5: Sensitivity and Specificity of the Classification

Task	Sensitivity (S_e)	Specificity (S_p)
1	99.00%	99.00%
2	95.19%	98.96%
3	94.29%	99.49%

Accordingly, from the perspective of the epilepsy detection and classification, the sensitivity (S_e) and the specificity (S_p) of Task 1, Task 2, and Task 3 are 99.00% and 99.00%, 95.19% and 98.96%, 94.29% and 99.49%, respectively, as also illustrated in Table 5.

In general, the performance of the classification between the epileptic EEG data in the sets *C* and *E* is better than the performance of the classification between the epileptic EEG data in the sets *D* and *E*. Therefore, this implies that the feature of the epileptic EEG signals in the set *D*, the wavelet-based scale variance feature, is different from the feature of the epileptic EEG signals in the set *C* even though the EEG data of both sets, *C* and *D*, correspond to the epileptic EEG data during non-seizure period. Further, the epileptic EEG signals in the set *D* are slightly more similar to the ones in the set *E* where the EEG data of both sets, *D* and *E*, were recorded from within the epileptogenic zone.

5. DISCUSSION

In this study, the wavelet decomposition is used to extract the characteristics of the epileptic EEG data that are recorded during seizure activity and seizure-free interval, and also obtained from within the epileptogenic zone and faraway from the corresponding seizure origin at various scales or resolutions. The log-variance of wavelet coefficients of the epileptic EEG data is used as the element of the pattern that is used in the classification of the epileptic EEG data. Further, a set of the log-variance of wavelet coefficients of the epileptic EEG data at various scales, the wavelet-based scale variance feature, is used as the pattern for the classification of the epileptic EEG data.

From the computational results, it is shown that there is a significant difference between the wavelet-based scale variance of the epileptic EEG data of the set *E* which correspond to the EEG data recorded during seizures and of the epileptic EEG data of the sets *C* and *D* which correspond to the EEG data during non-seizure period. As a result, the epileptic EEG data during seizure activity can be excellently classified even the unsupervised method, the *k*-means clustering, is employed for the classification of the epileptic EEG data and there are no prior knowledge and training required. The seizure activity can then be decently detected using the wavelet-based scale variance feature.

The classification results also suggest that the region of the brain where the epileptic EEG data were recorded has an influence on the the analysis and diagnosis of epilepsy because it is shown that the wavelet-based scale variance features of the epileptic EEG data that are obtained from different regions of the brain, i.e., within the epileptogenic zone and faraway from the corresponding seizure origin, are slightly different from each other. Therefore, the position of the EEG data acquisition plays a role in the classification of the epileptic EEG data that can lead to a different performance of the classification.

Furthermore, the wavelet-based scale variance approach is applied to examine the characteristics of the EEG signal of an epilepsy patient that manifests the generalized tonic-clonic seizure [18]. From the study, it is shown that the epileptic EEG signal exhibits different characteristics of the wavelet-based scale variance corresponding to various physiological and pathological states of the brain. The physiological and pathological states of the brain can be characterized using the wavelet-based scale variance [18].

References

- [1] Seizure and Epilepsy: Hope through Research National Institute of Neurological Disorders and Stroke (NINDS), Bethesda, MD, 2004 [Online]. Available: http://www.ninds.nih.gov/disorders/epilepsy/detail_epilepsy.htm
- [2] B. Litt and J. Echauz, "Prediction of epileptic seizures," *Lancet Neurology*, vol. 1, pp. 22–30, 2002.
- [3] A. Subasi, "Epileptic seizure detection using dynamic wavelet network," *Expert Systems with Applications*, vol. 29, pp. 343–355, 2005.
- [4] K. Lehnertz and C. Elger, "Spatio-temporal dynamics of the primary epileptogenic area in temporal lobe epilepsy characterized by neuronal complexity loss," *Electroenceph. Clin. Neurophysiol.*, vol. 95, pp. 108–117, 1995.
- [5] L. D. Iasemidis, J. C. Sackellares, H. P. Zaveri, and W. J. Williams, "Phase space topography and the Lyapunov exponent of electrocorticograms in partial seizures," *Brain Topogr.*, vol. 2, pp. 187–201, 1990.
- [6] N. Paivinen et al., "Epileptic seizure Detection: a nonlinear viewpoint," *Computer Methods and Programs in Biomedicine*, vol. 79, pp. 151–159, 2005.
- [7] R. Schuyler, A. White, K. Staley, and K. J. Cios, "Epileptic seizure detection," *IEEE Eng. Med. Biol. Mag.*, pp. 74–81, Mar/April 2007.
- [8] H. Adeli, S. Ghosh-Dastidar, and N. Dadmehr, "A wavelet-chaos methodology for analysis of EEGs and EEG subbands to detect seizure and epilepsy," *IEEE Trans. Biomed. Eng.*, vol. 54, pp. 205–211, 2007.
- [9] A. Grossman and J. Morlet, "Decomposition of Hardy functions into square integrable wavelets of constant shape," *SIAM J. Math.*, vol. 15, pp. 723–736, 1984.
- [10] M. Vetterli and C. Herley, "Wavelets and filter banks: theory and design," *IEEE Trans. Signal Processing*, vol. 40, pp. 2207–2232, 1992.
- [11] I. Daubechies, "Orthonormal bases of compactly supported wavelets," *Commun. Pure Appl. Math.*, vol. XLI, pp. 909–996, 1988.
- [12] S. G. Mallat, "A theory for multiresolution signal decomposition: the wavelet representation," *IEEE Trans. Pattern Analysis and Machine Intelligence*, vol. 11, pp. 674–693, 1989.
- [13] A. Cohen and J. Kovacevic, "Wavelets: the mathematical background," *Proceeding of the IEEE*, vol. 84, pp. 514–522, 1996.
- [14] S. Mallat, *A Wavelet Tour of Signal Processing*. San Diego: Academic Press, 1998.
- [15] A. K. Jain, "Data clustering: a review," *ACM Computing Surveys*, vol. 31, pp. 264–323, 1999.
- [16] J. McQueen, "Some methods for classification and analysis of multivariate observations," in *Proc. of the Fifth Berkeley Symposium on Mathematical Statistics and Probability*, 1967, pp. 281–297.
- [17] R. G. Andrzejak et al., "Indications of nonlinear deterministic and finite-dimensional structures in time series of brain electrical activity: dependence on recording region and brain state," *Phys. Rev. E*, vol. 64, pp. (061907)1–8, 2001.
- [18] S. Janjarasjitt, "Examination of the generalized tonic-clonic seizure using the wavelet-based scale variance," in *The 3rd International Symposium on Biomedical Engineering*, Bangkok, Thailand, 2008, pp. 6.

Suparek Janjarasjitt received his M.S. in 2002 and Ph.D. in 2006 in Systems and Control Engineering from Case Western Reserve University, Cleveland, OH, U.S.A. He has been a faculty member of the Department of Electrical and Electronic Engineering, Ubonratchathani University, Thailand since he received his B.Eng. (Hons.) in Electrical Engineering in 1998. Also, he currently holds an adjunct assistant professor position at the Department of Electrical Engineering and Computer Sciences, Case Western Reserve University, Cleveland, OH, U.S.A.

His research interests include the development of advanced computational tools and techniques, and the use of complex systems analysis techniques in various applications including biology and medicine, for a deeper understanding of the characteristics and behaviors of underlying biological and physiological systems corresponding to different states or conditions, namely health and disease. His current research projects are supported by various sources of funding including the Thailand Research Fund (TRF), the Commission on Higher Education (CHE), the Ministry of Education, Thailand, the Coordinating Center for Thai Government Science and Technology Scholarship Student (CSTST), the National Science and Technology Development Agency (NSTDA), and Ubon Ratchathani University.