



ระบบการเรียนรู้ของเครื่องสำหรับการระบุลักษณะทางสัณฐานวิทยาแบบอัตโนมัติของอะแคนทามีบาด้วยภาพจากกล้องจุลทรรศน์

ศรีศุภางค์ ทิวสุวรรณ*

ภาควิชาวิศวกรรมคอมพิวเตอร์ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ นครนายก

ภัทธร บุปผัน

สาขาส่งเสริมสุขภาพ คณะกายภาพบำบัด มหาวิทยาลัยศรีนครินทรวิโรฒ นครนายก

* ผู้นิพนธ์ประสานงาน โทรศัพท์ 09 8552 3356 อีเมล: srisupang@g.swu.ac.th DOI: 10.14416/j.kmutnb.2022.09.014

รับเมื่อ 27 เมษายน 2564 แก้ไขเมื่อ 5 กรกฎาคม 2564 ตอรับเมื่อ 26 สิงหาคม 2564 เผยแพร่ออนไลน์ 19 กันยายน 2565

© 2023 King Mongkut's University of Technology North Bangkok. All Rights Reserved.

บทคัดย่อ

อะแคนทามีบา (*Acanthamoeba* spp.) เป็นอะมีบาที่ดำรงชีวิตเป็นอิสระในสิ่งแวดล้อม และเป็นโพรโตซัวชนิดฉวยโอกาสที่สามารถก่อให้เกิดผลกระทบต่อสุขภาพร่างกายของมนุษย์ เช่น โรคกระจกตาอักเสบ การตรวจสอบชนิดของสายพันธุ์จึงมีความจำเป็นอย่างยิ่งเพื่อให้สามารถทำการวินิจฉัยและรักษาโรคนั้นๆ ได้อย่างถูกต้อง หนึ่งในวิธีการพื้นฐานคือการระบุลักษณะทางสัณฐานวิทยาของผนังซิสต์ (Cyst) โดยสามารถจำแนกกลุ่มของอะแคนทามีบาออกเป็น 3 กลุ่ม อย่างไรก็ตาม กระบวนการนี้มีความจำเป็นที่ต้องอาศัยเวลาและผู้เชี่ยวชาญเฉพาะเพื่อให้เกิดความถูกต้องและแม่นยำมากที่สุด งานวิจัยนี้จึงนำเสนอระบบการเรียนรู้ของเครื่องเพื่อทำการระบุและจำแนกลักษณะทางสัณฐานวิทยาแบบอัตโนมัติของอะแคนทามีบาในระยะซิสต์ด้วยภาพจากกล้องจุลทรรศน์ เครื่องมือที่นำเสนอนี้มีความสามารถในการจำแนกกลุ่มอะแคนทามีบาได้โดยประกอบไปด้วย 3 กระบวนการหลัก คือ 1) กระบวนการก่อนการประมวลผลภาพ 2) กระบวนการสกัดคุณลักษณะเด่นของซิสต์ด้วยการผสมผสาน (Combined Descriptor) ในระดับคุณลักษณะทางรูปร่างด้วยวิธีการฮิสโทแกรมของทิศทางตามค่าเกรเดียนต์ (Histogram of Oriented Gradients; HOG) และคุณลักษณะเชิงพื้นผิวด้วยวิธีการโลคอลไบนารีแพตเทิร์น (Local Binary Pattern; LBP) หลังจากนั้น จะเข้าสู่การระบุลักษณะของซิสต์ที่เป็นกระบวนการสุดท้ายนั้น คือ 3) การคัดแยกกลุ่มของซิสต์ด้วยการเรียนรู้ของเครื่อง จากผลการทดลองพบว่า ตัวจำแนกชนิดซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine; SVM) นั้น ให้ค่าความถูกต้องเฉลี่ยสูงที่สุดเมื่อเปรียบเทียบกับตัวจำแนกชนิดอื่นๆ อีกทั้งระบบที่นำเสนอนี้ได้ประสิทธิภาพสูงที่สุดเมื่อทำการเปรียบเทียบประสิทธิภาพความถูกต้องกับวิธีการอื่นซึ่งคิดเป็นค่าความถูกต้องเฉลี่ยที่ 89.81%

คำสำคัญ: อะแคนทามีบา การระบุลักษณะทางสัณฐานวิทยา การเรียนรู้ของเครื่อง ฮิสโทแกรมของทิศทางตามค่าเกรเดียนต์ โลคอลไบนารีแพตเทิร์น

การอ้างอิงบทความ: ศรีศุภางค์ ทิวสุวรรณ และ ภัทธร บุปผัน, “ระบบการเรียนรู้ของเครื่องสำหรับการระบุลักษณะทางสัณฐานวิทยาแบบอัตโนมัติของอะแคนทามีบาด้วยภาพจากกล้องจุลทรรศน์,” วารสารวิชาการพระจอมเกล้าพระนครเหนือ, ปีที่ 33, ฉบับที่ 4, หน้า 1–11, เลขที่บทความ 234-134988, ต.ค.-ธ.ค. 2566.



Machine Learning-based System for Automatic Morphological Identification of *Acanthamoeba* spp. in Microscopic Images

Srisupang Thewsuwan*

Department of Computer Engineering, Faculty of Engineering, Srinakharinwirot University, Nakhon Nayok, Thailand

Pattakorn Buppan

Department of Health Promotion, Faculty of Physical Therapy, Srinakharinwirot University, Nakhon Nayok, Thailand

* Corresponding Author, Tel. 09 8552 3356, E-mail: srisupang@g.swu.ac.th DOI: 10.14416/j.kmutnb.2022.09.014

Received 27 2021; Revised 2 August 2021; Accepted 26 August 2021; Published online: 19 September 2022

© 2023 King Mongkut's University of Technology North Bangkok. All Rights Reserved.

Abstract

Acanthamoeba is free-living protozoa. They are the causative agents of granulomatous encephalitis and keratitis in humans. The simplified morphological identification was based on the shape of the inner and outer wall and the size of the cysts according to the standard criteria, which can be classified into group I, group II, and group III. Although morphology is isolated by the shape and the size of the cysts, it requires expert-skilled explicitly of health promoters. This paper proposes developing an automated machine learning-based system for morphological identification of *Acanthamoeba* spp. in microscopic images. The system can be separated into three processes, i.e. 1) image preprocessing process, 2) feature descriptors using Histogram of Gradient technique (HOG) as shaped-based approach, and Local Binary Pattern (LBP) as texture-based approach, and 3) SVM-based classification. The proposed approach is evaluated by using our dataset comparing with the state-of-the-art methods. The experimental results show that our proposed method can achieve highly accurate performance superior to the other methods with an accuracy of 89.81%.

Keywords: *Acanthamoeba* spp., Morphological Identification, Machine Learning, HOG, LBP


Please cite this article as: S. Thewsuwan and P. Buppan, "Machine learning-based system for automatic morphological identification of *Acanthamoeba* spp. in microscopic images," *The Journal of KMUTNB*, vol. 33, no. 4, pp. 1–11, ID. 234-134988, Oct.–Dec. 2023 (in Thai).

1. บทนำ

อะแคนทามีบา (*Acanthamoeba* spp.) เป็นอะมีบาที่ดำรงชีวิตเป็นอิสระในสิ่งแวดล้อมทั่วไป (Free-living Amoeba) เช่น แหล่งน้ำตามธรรมชาติ ดิน อากาศ และฝุ่นละออง ในประเทศไทยพบการมีอยู่ของอะแคนทามีบาในแหล่งน้ำสาธารณะถึงร้อยละ 36.7 [1]–[3] และมักจะเป็นสาเหตุที่ก่อให้เกิดโรคชนิดร้ายแรงในมนุษย์ เช่น โรคกระจกตาอักเสบจากอะแคนทามีบา (*Acanthamoeba* Keratitis) โดยร้อยละ 64 ของผู้ป่วยโรคนี้พบสาเหตุมาจากการใช้คอนแทคเลนส์ที่ไม่ถูกสุขอนามัยจึงก่อให้เกิดการปนเปื้อนของเชื้ออะแคนทามีบา อีกทั้งจากผลการสำรวจยังพบอุบัติการณ์การเป็นโรคกระจกตาอักเสบเพิ่มขึ้นในประเทศไทยจากการติดเชื้อชนิดนี้อีกด้วย [1], [4]

อะแคนทามีบาสามารถแบ่งวงจรการเจริญเติบโตออกเป็น 2 ระยะ คือ ระยะโทรโฟซอइट (Trophozoites) และระยะซิสต์ (Cysts) โดยระยะโทรโฟซอइटจะมีขนาดเส้นผ่านศูนย์กลาง 12–35 ไมโครเมตร มีส่วนยื่นคล้ายขาเทียมที่มีลักษณะคล้ายหนาม ส่วนระยะของซิสต์จะมีขนาดเส้นผ่านศูนย์กลาง 10–20 ไมโครเมตร มีผนังหุ้ม 2 ชั้น ได้แก่ ผนังชั้นนอก (Ectocyst) และผนังชั้นใน (Endocyst) การจัดจำแนกกลุ่มในระยะซิสต์จากขนาดและรูปร่างตามลักษณะทางสัณฐานวิทยา (Cyst Morphology) สามารถแบ่งออกเป็น 3 กลุ่ม ตามวิธีการของ Pussard และ Pons [5] ดังแสดงได้ดังรูปที่ 1 คือ ซิสต์กลุ่มที่ I จะมีขนาดใหญ่ ผนังชั้นนอกจะมีผิวเรียบหรือหยักเป็นรอยหย่นเล็กน้อย ผนังชั้นในมีลักษณะเป็นแฉกคล้ายรูปร่างดาว ซิสต์กลุ่มที่ II ผนังชั้นในจะมีรูปร่างหลายแบบ เช่น สามเหลี่ยม หลายเหลี่ยม แฉก กลม หรือรูปไข่ แต่มักจะเห็นแขนหรือแฉกไม่ชัดเจน และซิสต์กลุ่มที่ III จะมีลักษณะรูปร่างค่อนข้างกลม ผนังชั้นนอกเรียบและบางหรือเป็นคลื่นเล็กน้อย ผนังชั้นในนั้นมักเห็นเป็นลักษณะกลม [1]–[6]

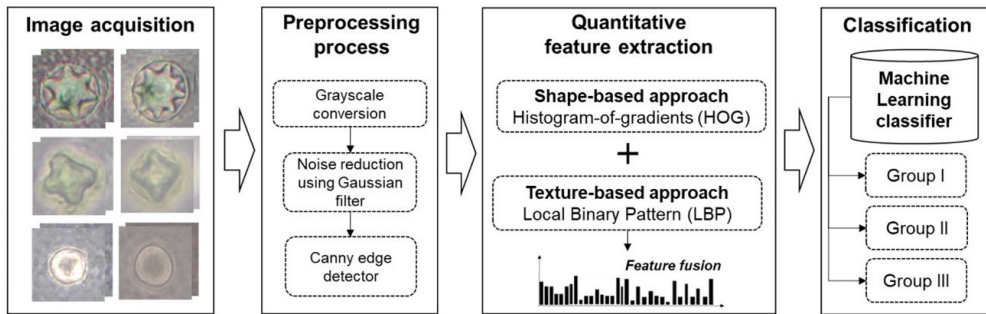
ปัจจุบันกระบวนการเพาะเลี้ยงเชื้อเป็นวิธีการที่ใช้ในการตรวจหาอะแคนทามีบาในห้องปฏิบัติการเพื่อการทดลองทางคลินิกและวินิจฉัยโรค โดยจะมีการระบุลักษณะทางสัณฐานวิทยาของอะแคนทามีบาในระยะซิสต์ ออกเป็น



รูปที่ 1 การจัดจำแนกกลุ่มอะแคนทามีบาตามขนาดและรูปร่างของซิสต์ตามหลักเกณฑ์ของ Pussard และ Pons [5]; Scale Bar = 10µm. (ec: Ectocyst, en: Endocyst)

กลุ่มๆ ด้วยตาเปล่าโดยภาพจากกล้องจุลทรรศน์ [1], [6], [7] อย่างไรก็ตาม วิธีการนี้มีความจำเป็นต้องใช้เวลา ทักษะ ความเชี่ยวชาญ เพื่อสังเกตความแตกต่างของรูปร่างและขนาดจากผนังซิสต์แต่ละกลุ่ม ผลลัพธ์ที่ได้จึงยังคงขึ้นอยู่กับประสบการณ์ของผู้ปฏิบัติงานแต่ละคน การจำแนกชนิดของอะแคนทามีบายังมีการใช้วิธีการอื่นร่วมด้วย ได้แก่ การวิเคราะห์ไอโซไซม์ (Isozyme Analysis) การจำแนกโดยการแยกไมโทคอนเดรียของเชื้อ (Mitochondrial-RFLP) และการหาลำดับเบสของ rRNA (Small Subunit rRNA Sequence) ด้วยเทคนิคปฏิกิริยาลูกโซ่พอลิเมอไรส (Polymerase Chain Reaction; PCR) [6]–[8] แต่อย่างไรก็ตาม การตรวจสอบด้วยเทคนิคเหล่านี้ค่อนข้างใช้งบประมาณที่สูง ผู้เชี่ยวชาญเฉพาะทาง และห้องปฏิบัติการที่มีเครื่องมือพร้อม ด้วยเหตุนี้ผู้วิจัยจึงมีแนวคิดในการมุ่งเน้นพัฒนาระบบวิเคราะห์ภาพอัตโนมัติจากกล้องจุลทรรศน์สำหรับการระบุลักษณะทางสัณฐานวิทยาของอะแคนทามีบาในระยะซิสต์ขึ้น

ระบบวิเคราะห์ภาพจากกล้องจุลทรรศน์แบบอัตโนมัติได้ถูกพัฒนาขึ้นอย่างแพร่หลายในปัจจุบัน โดยมีแนวคิดจากการเปลี่ยนค่าพารามิเตอร์เชิงคุณภาพทางเซลล์วิทยาให้เป็นค่าเชิงปริมาณ และใช้อัลกอริทึมขั้นสูงช่วยประมวลผลและตัดสินใจ ซึ่งจะสามารถช่วยให้การประเมินทางพยาธิวิทยามีความแม่นยำและถูกต้องมากขึ้น Rodellar และคณะ [9] ได้นำเสนอการวิเคราะห์ลักษณะทางสัณฐานวิทยาของเม็ดเลือดเพื่อแยกชนิดที่ปกติและไม่ปกติ (Peripheral Blood Smear) โดยใช้การผสมผสานคุณลักษณะเด่นทางเรขาคณิตของเซลล์



รูปที่ 2 กระบวนการของระบบจำแนกกลุ่ม *Acanthamoeba* spp. ในระยะซิสต์แบบอัตโนมัติด้วยการเรียนรู้ของเครื่อง

เช่น พื้นที่ (Area) เส้นรอบวง (Perimeter) องค์ประกอบของสี (YCbCr) และคุณลักษณะเด่นเชิงพื้นผิวด้วยวิธี Grey Level Co-occurrence Matrix (GLCM) จากนั้นใช้วิธีการตัดแยกด้วยการเรียนรู้ของเครื่อง Mabrouk และคณะ [10] เสนอวิธีการวินิจฉัยโรคมะเร็งผิวหนังแบบอัตโนมัติด้วยการวิเคราะห์ลักษณะเชิงพื้นผิวจากภาพถ่ายด้วยเทคนิค GLCM และใช้ Multi-Layer Perceptron (MLP) ในการตัดแยกและวินิจฉัย ประสิทธิภาพของระบบพบค่าความถูกต้องอยู่ในระดับ 76% Abdeldaim และคณะ [11] นำเสนอระบบวิเคราะห์ภาพถ่ายสำหรับวินิจฉัยโรคมะเร็งเม็ดเลือดขาวชนิดเฉียบพลันโดยการสกัดลักษณะเด่นของสีเซลล์สำหรับการตรวจจับเม็ดเลือดขาว พร้อมทั้งผสมผสานคุณลักษณะเด่นเชิงรูปร่าง (Shape) ของเม็ดเลือด คุณลักษณะเด่นเชิงพื้นผิว (Texture) และสี (Color) และ K-NN ในการตัดแยกเซลล์มะเร็ง จากผลการทดลองพบว่า การผสมผสานคุณลักษณะเด่นของสีและเชิงพื้นผิวได้ค่าความถูกต้องที่สูงที่สุด และจำนวนขนาดเวกเตอร์ของคุณลักษณะเด่นจะแปรผันตรงต่อประสิทธิภาพความถูกต้องของระบบ Vijayalakshmi และคณะ [12] เสนอโมเดลการตรวจจับเชื้อมาลาเรียจากภาพถ่ายกล้องจุลทรรศน์ด้วยเทคนิคจากการเรียนรู้เชิงลึกรวมกับเทคนิคการเรียนรู้ของเครื่อง (VGG-SVM Model) ซึ่งมีประสิทธิภาพที่สูงกว่าการใช้เทคนิคพื้นฐานโครงข่ายประสาทแบบคอนโวลูชัน (CNN) อย่างไรก็ตาม ปัจจุบันการประยุกต์ใช้หลักการวิเคราะห์ภาพถ่ายสำหรับอะแคนทามีบา ยังมีความท้าทายอยู่มากด้วยลักษณะทางสัณฐานวิทยาของอะแคนทามีบา ระยะซิสต์ที่มีความคล้ายคลึงกันในแต่ละกลุ่ม ทำให้ต้องมี

การศึกษาเกณฑ์ของการสกัดข้อมูลลักษณะพิเศษที่เหมาะสม อีกทั้งจากการค้นคว้างานวิจัยที่เกี่ยวข้องพบว่า งานวิจัยนี้เป็นงานวิจัยแรกๆ ที่พัฒนาระบบวิเคราะห์ภาพอัตโนมัติสำหรับการระบุลักษณะทางสัณฐานวิทยาของอะแคนทามีบาอีกด้วย ดังนั้นในงานวิจัยนี้จึงนำเสนอระบบคอมพิวเตอร์เพื่อการจำแนกกลุ่มอะแคนทามีบาตามลักษณะทางสัณฐานวิทยาของผนังซิสต์แบบอัตโนมัติด้วยวิธีการเรียนรู้ของเครื่อง โดยมีวัตถุประสงค์เพื่อพัฒนาระบบการวิเคราะห์ภาพ ด้วยการประยุกต์ใช้เทคนิคการหาคุณลักษณะเด่นเชิงรูปร่างด้วยวิธีฮิสโทแกรมของทิศทางตามค่าเกรเดียนต์ (HOG) และเทคนิคการดึงลักษณะเด่นเชิงพื้นผิว (LBP) ของซิสต์เพื่อกำหนดคุณสมบัติเชิงปริมาณที่สามารถระบุลักษณะของตัวแปรทางเซลล์วิทยาของอะแคนทามีบา จากนั้นใช้กระบวนการการเรียนรู้ของเครื่องเข้ามาทำการตัดแยกกลุ่มของซิสต์ออกเป็นทั้งหมด 3 กลุ่ม ด้วยระบบอัตโนมัติตามหลักเกณฑ์ของ Pussard และ Pons [5] โดยผลการทดลองที่ได้รับจะสามารถนำไปใช้เพื่อเป็นแนวทางในการพัฒนาระบบให้สามารถช่วยเสริมการทำงานของผู้เชี่ยวชาญในห้องปฏิบัติการทางคลินิกต่อไปได้

2. วัสดุ อุปกรณ์และวิธีการวิจัย

กระบวนการทำงานของระบบการระบุกลุ่มของซิสต์ *Acanthamoeba* spp. แบบอัตโนมัติสามารถแบ่งการทำงานออกได้เป็น 3 กระบวนการดังแสดงในรูปที่ 2 คือ 1) กระบวนการก่อนการประมวลผลภาพ 2) กระบวนการสกัดคุณลักษณะเด่นของซิสต์ และ 3) การตัดแยกกลุ่มของซิสต์ด้วยการเรียนรู้ของเครื่อง

2.1 กระบวนการก่อนการประมวลผลภาพ

กระบวนการก่อนการประมวลผลภาพ (Image Preprocessing) เป็นการปรับปรุงข้อมูลรูปภาพให้มีความเหมาะสมสำหรับการวิเคราะห์และแยกคุณลักษณะเด่นของภาพ ดังแสดงกระบวนการทำงานในรูปที่ 2 โดยงานวิจัยชิ้นนี้ได้สามารถแบ่งกระบวนการปรับปรุงภาพออกได้ทั้งหมด 3 ขั้นตอน โดยขั้นตอนแรกคือ (i) การแปลงภาพเป็นระดับเทา: เมื่อรับภาพอินพุต ระบบจะทำการแปลงค่าความเข้มระดับสีชนิด (RGB) ให้อยู่ในระดับสีเทา (0-255), 1 Channel เพื่อลดความแปรปรวนของการแยกวัตถุกับพื้นหลังบนภาพ ขั้นตอนที่ (ii) การลดสิ่งเจือปนบนภาพ (Noise Reduction): เป็นการปรับปรุงภาพเพื่อลดสัญญาณรบกวน โดยใช้วิธีการกรองภาพโดยการใส่ตัวกรองสัญญาณเกาส์เซียน (Gaussian Filter) [13], [14] ซึ่งเป็นสัญญาณที่ลักษณะคล้ายระฆังคว่ำ ทำการลดสิ่งรบกวน เพื่อให้การประมวลผลภาพเป็นไปได้อย่างมีประสิทธิภาพ และขั้นตอนสุดท้าย (iii) การหาขอบของวัตถุบนภาพด้วยเทคนิค Canny [15] เนื่องจากสามารถตรวจจับเส้นขอบที่บางได้ดีกว่าเทคนิคอื่นโดยเป็นการหาขอบซีสต์ของอะแคนทามีบาในรูปภาพ เพื่อนำมาสกัดค่าคุณลักษณะเด่นในกระบวนการถัดไป

2.2 การดึงคุณลักษณะเด่น (Feature Extraction)

การดึงคุณลักษณะเด่น เป็นการสกัดและจัดเก็บข้อมูลของซีสต์ในภาพ เพื่อนำไปจำแนกกลุ่มของอะแคนทามีบา โดยในงานวิจัยนี้จะอาศัยคุณลักษณะที่สำคัญ 2 ประการคือ 1) คุณลักษณะเด่นเชิงรูปร่างของวัตถุ (Shaped-based Feature Extraction) และ 2) คุณลักษณะเด่นเชิงพื้นผิวของวัตถุ (Texture-based Feature Extraction) จากนั้นทำการผสมผสานของเวกเตอร์ของคุณลักษณะเด่นเพื่อการสร้างค่าคุณลักษณะเฉพาะของซีสต์อะแคนทามีบา

2.2.1 คุณลักษณะเด่นเชิงรูปร่างของวัตถุ

เป็นการสกัดคุณลักษณะเด่นรูปร่างของซีสต์อะแคนทามีบาในงานวิจัยชิ้นนี้ใช้เทคนิคฮิสโตแกรมของทิศทางตามค่าเกรเดียนต์ (Histogram of Oriented Gradient; HOG) [16] ที่มักจะนำมาประยุกต์ใช้ในการอธิบายรูปร่างของมนุษย์บน

ภาพ เช่น การจดจำใบหน้า การติดตามบุคคล ซึ่งภายในระบบที่นำเสนอ HOG จะทำการหาคุณสมบัติจำเพาะของเส้นขอบบนภาพอะแคนทามีบาในระยะซีสต์จากค่าความถี่ของทิศทางเกรเดียนต์ และค่าการกระจายตัวของความเข้มเกรเดียนต์ การดึงลักษณะของ HOG จะทำได้โดยการแบ่งภาพออกเป็น ส่วนย่อยขนาดเล็กเรียกว่า เซลล์ (Cells) โดยแต่ละเซลล์จะทำการรวมฮิสโตแกรมของทิศทางเกรเดียนต์ของขอบวัตถุ นั้นๆ อยู่ในเวกเตอร์ขนาด 1 มิติ (1-D) เพื่อแสดงถึงคุณลักษณะเด่นของซีสต์ในภาพนั้นๆ จากนั้นทำการนอร์มอลไลซ์ด้วยการคำนวณตัวชี้วัดของค่าความเข้มในพื้นที่ขนาดใหญ่เรียกว่า บล็อก (Blocks) ในงานวิจัยนี้ขนาดของเวกเตอร์คุณลักษณะเด่น HOG จะมีขนาดเท่ากับ 8,100 ต่อภาพ

2.2.2 คุณลักษณะเด่นเชิงพื้นผิวของวัตถุ

เป็นการสกัดคุณลักษณะเด่นเชิงพื้นผิวและลดทลายของซีสต์ด้วยวิธีการ Local Binary Pattern (LBP) [13] โดยตัวดำเนินการพื้นผิวแบบ LBP ทำหน้าที่เป็นตัวอธิบายลักษณะเด่นเฉพาะพื้นที่ (Local Descriptor) และนำมาใช้เพื่อเพิ่มความคมชัดของภาพ ซึ่งสามารถคำนวณได้จากการหาค่าความแตกต่างของค่าความเข้มสีของพิกเซลกลางที่สนใจและพิกเซลข้างเคียงเป็นเกณฑ์ในการสร้างรหัสไบนารี และจะถูกแปลงเป็นรหัส LBP ที่สามารถอธิบายถึงรูปแบบพื้นผิวของพิกเซลเหล่านั้น จากนั้นค่าของแต่ละพิกเซลจะถูกแสดงเป็นค่าฮิสโตแกรมเพื่อแสดงเป็นคุณลักษณะเด่นเชิงพื้นผิวของซีสต์โดยขนาดของเวกเตอร์คุณลักษณะเด่น LBP มีค่าเท่ากับ 256 ต่อภาพ

2.2.3 การผสมผสานของคุณลักษณะเด่นเชิงรูปร่างและเชิงพื้นผิวของวัตถุ

การผสมผสานคุณลักษณะเด่นด้วยวิธี HOG และ LBP มักจะนำมาประยุกต์ใช้ในงานทางด้านคอมพิวเตอร์วิทัศน์ เช่น ระบบการจดจำท่าทางของมือ [17] และการตรวจจับท่าทางมนุษย์ [18] เนื่องจากประสิทธิภาพของเทคนิคที่เน้นการหาลักษณะเด่นเฉพาะพื้นที่ (Local Descriptions) ของวัตถุและมีความคงทนต่อสภาวะแวดล้อมภายนอก ดังนั้นผู้วิจัยจึงนำวิธีการนี้มาประยุกต์ใช้สำหรับการระบุลักษณะทางสัญญาณวิทยาของอะแคนทามีบา ที่มุ่งเน้นสกัดหา

คุณลักษณะพิเศษเฉพาะพื้นที่จากเส้นขอบซีสต์ที่ปรากฏบนภาพ โดยนำคุณลักษณะทางรูปร่างและทางพื้นผิวมาผสมผสานกันเรียกว่า “Combined Descriptor” เพื่อสร้างเป็นเวกเตอร์ของค่าคุณลักษณะเด่นเฉพาะสำหรับอะแคนทาปีมา ดังนั้น ขนาดรวมของเวกเตอร์คุณลักษณะเด่น (HOG+LBP) มีค่าเท่ากับ 8,356 ต่อภาพ

2.3 การจำแนกกลุ่มของอะแคนทามีบา

การจำแนกประเภทกลุ่มของข้อมูลโดยวิธีการเรียนรู้ของเครื่อง เป็นขั้นตอนที่มีความสำคัญในการสร้างระบบวิเคราะห์อัตโนมัติโดยหลังจากทำการสกัดคุณลักษณะเด่นของภาพมาได้แล้ว จะนำลักษณะเด่นเหล่านั้น ผ่านตัวจำแนก (Classifier) เพื่อให้ระบบทำการทำนายข้อมูลประเภทกลุ่มของข้อมูลนั้นๆ งานวิจัยชิ้นนี้ได้เลือกวิธีการซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine; SVM) แบบหลายคลาส [19], [20] ชนิดการจำแนกประเภทแบบ One-vs-all (OVA) เป็นตัวจำแนกของระบบซึ่งเป็นหนึ่งในกระบวนการของการเรียนรู้ของเครื่องเข้ามาทำการคัดแยกกลุ่มของซีสต์อะแคนทามีบาด้วยระบบอัตโนมัติ

2.4 เกณฑ์ในการวัดประสิทธิภาพความถูกต้อง

ในการวัดประสิทธิภาพความถูกต้องและแม่นยำ งานวิจัยชิ้นนี้ใช้เกณฑ์การวัดด้วยค่าความถูกต้อง (Accuracy) ค่าความแม่นยำ (Precision) ค่าความระลึก (Recall) และค่าวัดประสิทธิภาพ (F1-measure) [19] โดยการวิเคราะห์จากเส้นทแยงมุมของเมทริกซ์ความสับสน (Confusion Matrix) และสามารถคำนวณได้โดยใช้สมการที่ (1)–(4) ดังนี้

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

$$Precision = \frac{TP}{(TP + FP)} \quad (2)$$

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

$$F1 - measure = \left(\frac{2 \times Precision \times Recall}{Precision + Recall} \right) \quad (4)$$

โดยที่

TP คือ จำนวนภาพที่ไม่เดลทำนายว่าจริงและถูกต้องตามข้อมูลจริง

TN คือ จำนวนภาพที่ไม่เดลทำนายว่าไม่จริงและถูกต้องตามข้อมูลจริง

FP คือ จำนวนภาพที่ไม่เดลทำนายว่าจริงและไม่ถูกต้องตามข้อมูลจริง

FN คือ จำนวนภาพที่ไม่เดลทำนายว่าไม่จริงและไม่ถูกต้องตามข้อมูลจริง

3. ผลการทดลอง


ผลการวิจัยของระบบการจำแนกกลุ่มของอะแคนทามีบาตามลักษณะทางสัญญาณวิทยาแบบอัตโนมัติด้วยวิธีการเรียนรู้ของเครื่อง เป็นดังนี้

3.1 ชุดภาพการทดลอง

งานวิจัยนี้ได้นำข้อมูลภาพของอะแคนทามีบาจากทีมวิจัย สาขาส่งเสริมสุขภาพ คณะกายภาพบำบัด มหาวิทยาลัยศรีนครินทรวิโรฒ องค์กรฯ นครนายก [1] โดยทำการเก็บภาพจากกล้องจุลทรรศน์ด้วยกำลังขยาย 400 เท่า ผู้วิจัยเตรียมชุดภาพข้อมูลโดยการระบุตำแหน่งของซีสต์ในภาพ ภาพทั้งหมด (N) ที่ใช้ในงานวิจัยนี้มีจำนวนทั้งสิ้น 1,800 ภาพ ขนาด 100 × 100 พิกเซล แบ่งเป็น ซีสต์กลุ่มที่ I, II และ III กลุ่มละ 600 ภาพ ดังแสดงตัวอย่างในรูปที่ 3

3.2 การเปรียบเทียบประสิทธิภาพของตัวจำแนกโดยใช้วิธีการดึงลักษณะเด่นที่นำเสนอ

ในการทดลองส่วนนี้แสดงให้เห็นถึงประสิทธิภาพความถูกต้องระหว่างการใช้วิธีการดึงลักษณะเด่นที่นำเสนอ (Combined Descriptor) และตัวจำแนกประเภทต่างๆ ทั้งหมด 7 วิธี มาเปรียบเทียบ ได้แก่ Logistic Regression (LR), Linear Discriminant Analysis (LDA), K-Nearest Neighbor (KNN), Decision Tree Classification (CART), Random Forest (RF), Naive Bayes (NB) และ Support Vector Machine (SVM) งานวิจัยนี้ ชุดข้อมูลที่ใช้ในการ



(ก) กลุ่ม I (ข) กลุ่ม II (ค) กลุ่ม III

รูปที่ 3 ตัวอย่างของภาพซีสต์ *Acanthamoeba* spp. แต่ละกลุ่มที่ใช้ในงานวิจัย โดยสามารถแบ่งออกตามลักษณะสัณฐานวิทยาได้เป็น 3 กลุ่ม (ก) กลุ่ม I (ข) กลุ่ม II และ (ค) กลุ่ม III

ทดลองจะมีขนาดเวกเตอร์ ($N \times \text{Features}$) โดย N คือ จำนวนภาพทั้งหมดที่ใช้ในการทดลอง และ Features คือ จำนวนเวกเตอร์ของคุณลักษณะเด่นที่นำเสนอ มีค่าเท่ากับ $1,800 \times 8,356$ และทำการสุ่มแบบไขว้กัน (k-fold Cross Validation) โดยกำหนดค่า $k = 10$ กลุ่ม หมายถึงการแบ่งข้อมูลออกเป็น 10 ส่วนเท่าๆ กัน เพื่อป้องกันปัญหาจากการเลือกข้อมูลที่ติและนำมาเป็นข้อมูลชุดทดสอบ จากนั้นนำข้อมูลแต่ละส่วนมาใช้เป็นข้อมูลฝึกที่ขนาด 70% (1,260 ภาพ) จากผลการทดลองในตารางที่ 1 พบว่า ตัวจำแนกชนิด SVM ให้ค่าความถูกต้องเฉลี่ยมากที่สุดคิดเป็น 89.29% ด้วยค่าพารามิเตอร์ที่มีประสิทธิภาพสูงสุดประกอบไปด้วย Kernel ชนิด radial basis function (rbf) ค่า Cost (C) เท่ากับ 10 และ Gamma เท่ากับ 0.01 ดังนั้น ในงานวิจัยนี้ตัวจำแนกชนิด SVM จึงถูกเลือกให้เป็นโมเดลหลักที่ใช้ในการจำแนกกลุ่มของซีสต์อะแคนทามีบา

ตารางที่ 1 การเปรียบเทียบประสิทธิภาพของตัวจำแนกแต่ละชนิดด้วยวิธีการดึงลักษณะเด่นที่นำเสนอ

ตัวจำแนก	ค่าความถูกต้องเฉลี่ย (Acc. %)
LR	86.83 ± 0.023
LDA	78.02 ± 0.026
KNN	70.24 ± 0.030
CART	65.95 ± 0.030
RF	86.83 ± 0.029
NB	79.13 ± 0.038
SVM	89.29 ± 0.017

3.3 การเปรียบเทียบประสิทธิภาพของวิธีการดึงลักษณะเด่นที่นำเสนอและวิธีการอื่นๆ

เพื่อให้สามารถวิเคราะห์ประสิทธิภาพของวิธีการดึงลักษณะเด่นที่ได้นำเสนอ การทดลองนี้ได้กำหนดการเปรียบเทียบระหว่างค่าคุณลักษณะเด่นที่นำเสนอและวิธีการดั้งเดิม โดยสามารถแบ่งการเปรียบเทียบในการทดลองได้เป็น วิธีการดึงลักษณะเด่นโดยการใช้รูปร่างของวัตถุ (Shape-based Feature) เช่น Hu Moment [14], HOG [16] วิธีการดึงลักษณะเด่นโดยการใช้ลักษณะเชิงพื้นผิววัตถุ (Texture-based Feature) เช่น วิธีการ LBP และ LBP^{u2} [13] และวิธีการที่นำเสนอคือการผสมผสานลักษณะเด่นเชิงรูปร่าง และลักษณะพื้นผิวระหว่างวิธีการ HOG และ LBP (Combined Descriptor: HOG+LBP) Hu moment คือการวิเคราะห์องค์ประกอบของเส้นเค้าโครงด้วยการคำนวณโมเมนต์ของภาพ เพื่อพิจารณาความเหมือนหรือต่างกัน ลักษณะรูปร่างที่มีความทนทานต่อการเลื่อน (Translation) สเกล (Scale) และการหมุน (Rotation) ของวัตถุในภาพ จากการทดลองจะได้ค่าขนาดเวกเตอร์เท่ากับ 7 ต่อภาพ วิธีการ HOG [16] ได้กำหนดเซลล์ของ HOG 1 บล็อก ไว้ที่ 6×6 เซลล์ เมื่อทำการหาค่า HOG ในภาพขนาด 100×100 พิกเซล จะให้ขนาดเวกเตอร์ของคุณลักษณะมีจำนวนทั้งหมด 8100 ต่อภาพ การดึงลักษณะเด่นเชิงพื้นผิวด้วยวิธีการพื้นฐาน LBP และวิธีการ LBP ชนิด Uniform Patterns Variant หรือ LBP^{u2} [13] โดยกำหนดพารามิเตอร์ $r = 3$ และ $p = 8$ เมื่อค่า r คือรัศมีระยะทางระหว่างพิกเซลตรงกลางและพิกเซลข้างเคียง

ค่า p คือ จำนวนพิกเซลข้างเคียง โดยอ้างอิงการกำหนดค่าพารามิเตอร์ตามงานวิจัย [13] จำนวนขนาดเวกเตอร์ที่ใช้ต่อภาพจะมีขนาด 256 และ 59 ตามลำดับ เทคนิค Grey Level Co-occurrence Matrix (GLCM) [21] คือการกำหนดค่าทางสถิติจากการวิเคราะห์โครงสร้างพื้นผิวภาพในทิศทางต่างๆ จำนวน 4 ทิศทาง คือ 0° , 45° , 90° และ 135° และระยะทางจำนวน 2 ระยะ คือ $d = 1$ และ 2 โดยค่าของคุณลักษณะทางสถิติที่เลือกใช้นั้นคือ ค่า Contrast, Entropy และ Autocorrelation จำนวนขนาดเวกเตอร์ที่ใช้ต่อภาพจะมีขนาด 24 เวกเตอร์ วิธีการสุดท้ายคือวิธีการที่นำเสนอ (HOG+LBP) หรือเรียกว่า Combined Descriptors ด้วยขนาดของเวกเตอร์ทั้งหมด 8,356 โดยการทดลองในขั้นตอนเหล่านี้ค่าของพารามิเตอร์ในแต่ละวิธีการจะเป็นไปตามคำแนะนำของงานวิจัยอ้างอิงอื่นๆ เพื่อให้เกิดประสิทธิภาพสูงสุด

ตารางที่ 2 ประสิทธิภาพของวิธีการที่นำเสนอโดยแสดงขนาดของเวกเตอร์และค่าความถูกต้องเมื่อเปรียบเทียบกับวิธีการที่ศึกษาและวิธีการอื่นๆ

วิธีการดึงคุณลักษณะเด่น	ขนาดของเวกเตอร์ (No. of Feature)	ค่าความถูกต้องเฉลี่ย (Acc: %)
Hu moment [16]	7	46.67
HOG [11]	8,100	85.00
LBP [13]	256	72.22
LBP ^{u2} [13]	59	71.85
GLCM [17]	24	58.52
(HOG+LBP)		
Combined descriptor	8,356	89.81

จากตารางที่ 2 แสดงค่าความถูกต้องเฉลี่ยของการจำแนกคุณลักษณะซิสต์ต่อแคนทามิบาออกเป็น 3 กลุ่ม จากการใช้ตัวจำแนก SVM ที่ผ่านการฝึกฝนจากการทดลองในหัวข้อ 3.2 ทำการประมวลผลในทุกๆ วิธีการเพื่อทำการเปรียบเทียบประสิทธิภาพจากผลการทดลองจะเห็นได้ว่าวิธีการที่นำเสนอ Combined Descriptors ได้ค่าความถูกต้องสูงที่สุดคิดเป็น 89.81% ตัวดึงค่าลักษณะเด่นเชิงรูปร่างเช่น Hu Moment

และ HOG นั้น มีค่าความถูกต้องคิดเป็น 46.67% และ 85.00% ตามลำดับ ซึ่ง HOG มีประสิทธิภาพที่ดีกว่า Hu moment อีกทั้งจำนวนขนาดของคุณลักษณะเด่นสามารถสกัดออกมาได้มากกว่า Hu Moment ในส่วนของวิธีการดึงลักษณะเด่นเชิงลักษณะพื้นผิวด้วยวิธีการ LBP และ LBP^{u2} จะเห็นได้ว่าค่าความถูกต้องเฉลี่ยนั้นอยู่ที่ 72.22% และ 71.85% ซึ่งไม่ได้มีความแตกต่างกันอย่างชัดเจน ค่าความถูกต้องของวิธีการ GLCM เฉลี่ยอยู่ที่ 58.52% ฉะนั้น ในลักษณะเด่นเชิงรูปร่าง วิธีการที่มีประสิทธิภาพที่สุดในการจำแนกซิสต์ของอะแคนทามิบา คือ HOG ในขณะที่ลักษณะเด่นเชิงลักษณะพื้นผิวคือวิธีการพื้นฐาน LBP ดังนั้น จากสมมติฐานเบื้องต้นที่ว่าหากทำการรวมคุณลักษณะเด่นเชิงรูปร่าง และเชิงพื้นผิวของซิสต์จากลักษณะทางสัณฐานวิทยาาระบบการจำแนกจะมีประสิทธิภาพที่ดี [11] จากค่าความถูกต้องของการจำแนกซิสต์ต่อแคนทามิบาในตารางที่ 2 นั้น แสดงให้เห็นว่าสมมติฐานที่กล่าวมาข้างต้นนั้นเป็นจริง เพราะมีการดึงหรือสกัดข้อมูลที่สำคัญและสามารถใช้เป็นตัวอธิบายเอกลักษณ์ของอะแคนทามิบาในระยะซิสต์แต่ละกลุ่มได้

จากการแสดงผลทดสอบประสิทธิภาพการจำแนกกลุ่มอะแคนทามิบาในตารางที่ 3 โดยใช้การวิเคราะห์จากเส้นทแยงมุมของเมทริกซ์สับสน มีชุดข้อมูลที่ใช้ในการทดสอบนั้นคิดเป็นสัดส่วน 30% (540 ภาพ) โดยจำนวนภาพในกลุ่มที่ I, II และ III มีจำนวน 184, 168 และ 188 ภาพตามลำดับ พบค่าความถูกต้องเฉลี่ยของระบบคิดเป็น 89.81% เมื่อทำการวิเคราะห์แยกในแต่ละกลุ่มพบว่าค่าประสิทธิภาพของการทำนายซิสต์กลุ่ม III มีค่ามากที่สุด คิดเป็น 94.21% ค่าความระลึกลับ 95.21% และค่าความแม่นยำเท่ากับ 93.23% เมื่อเทียบกับซิสต์กลุ่มที่ I และ II ทั้งนี้เมื่อพิจารณาลักษณะสัณฐานวิทยาของซิสต์กลุ่มที่ III ที่มีรูปทรงค่อนข้างกลมผนังชั้นนอกเรียบและผนังชั้นในนั้นมักเห็นเป็นลักษณะกลมจะเห็นได้ว่าวิธีการที่นำเสนอมีประสิทธิภาพตามเกณฑ์ของการคิดแยกด้วยตาเปล่า เมื่ออ้างอิงตามหลักการของ Pussard และ Pons [5] ในขณะเดียวกันซิสต์กลุ่มที่ II มีประสิทธิภาพน้อยที่สุดคิดเป็น 83.24% ค่าความระลึกลับที่ 79.76% และค่าความแม่นยำที่ 87.01% ซึ่งเมื่อพิจารณา

ตารางที่ 3 ผลการทดสอบประสิทธิภาพของการจำแนกกลุ่มอะแคนทามีบาด้วยการวิเคราะห์จากเส้นทแยงมุมของเมทริกซ์สลับสน โดยแสดงจำนวนภาพ (หน่วย: ภาพ) ที่ทำนายได้ถูกต้อง และร้อยละของค่าความแม่นยำ ค่าความความระลึก และค่าวัดประสิทธิภาพ

	ชุดข้อมูลทดสอบ (ภาพ)	ชุดข้อมูลทดสอบ (ภาพ)			รวม	ค่าความแม่นยำ Precision (%)	ค่าความระลึก Recall (%)	ค่าประสิทธิภาพ F1-measure (%)
		กลุ่ม I	กลุ่ม II	กลุ่ม III				
ชุดข้อมูลจริง (ภาพ)	กลุ่ม I	172	11	1	184	88.66	93.48	91.01
	กลุ่ม II	22	134	12	168	87.01	79.76	83.23
	กลุ่ม III	0	9	179	188	93.23	95.21	94.21
	รวม	194	154	192	ค่าความถูกต้องเฉลี่ย (%) 89.81			

แยกการทำนายภาพแต่ละกลุ่ม พบว่า วิธีการที่นำเสนอไม่มีข้อจำกัดเมื่อลักษณะทางสัณฐานวิทยาของซิสต์กลุ่ม II มีลักษณะที่ไม่ชัดเจน เช่น มีรอยหยัก คลื่นของผนังชั้นนอกที่เป็นลักษณะรูปทรงของซิสต์กลุ่มที่ I และในทางกลับกัน หากลักษณะของซิสต์ค่อนข้างกลม แต่อาจมีรอยหยักแยกเป็นแฉก ระบบจะทำการทำนายว่าเป็นซิสต์กลุ่มที่ III ดังนั้นการสกัดคุณลักษณะเด่นที่เฉพาะเจาะจงมากขึ้น และการกำหนดเกณฑ์คุณสมบัติเชิงปริมาณของซิสต์แต่ละกลุ่มยังคงต้องมีการพัฒนาต่อไป อีกทั้งกระบวนการปรับแต่งภาพก่อนการประมวลผลยังเป็นปัจจัยที่ส่งผลให้เกิดความถูกต้องในการจำแนกกลุ่มเพิ่มขึ้นได้อีกด้วย

จากการทดลองทั้งหมดทำให้สามารถสรุปผลได้ว่าการจำแนกลักษณะทางสัณฐานวิทยาของซิสต์อะแคนทามีบาในกลุ่มที่ I, II และ III ตามหลักการของ Pussard และ Pons [5] การดึงลักษณะเด่นของซิสต์ในเชิงรูปร่างและเชิงพื้นผิวนั้นมีความจำเป็นสำหรับการพัฒนาระบบจำแนกอัตโนมัติ ทั้งนี้ความผิดพลาดที่เกิดขึ้นพบมากที่สุดโนซิสต์กลุ่มที่ II ที่มีลักษณะทางกายภาพคล้ายคลึงระหว่างกลุ่มที่ I และ II จากค่าทดสอบประสิทธิภาพในตารางที่ 3

4. สรุป

งานวิจัยนี้นำเสนอการพัฒนากระบวนการคอมพิวเตอร์เพื่อการระบุลักษณะทางสัณฐานวิทยาของ *Acanthamoeba* spp. ระยะซิสต์แบบอัตโนมัติด้วยภาพจากกล้องจุลทรรศน์ โดยมีการใช้หลักการของการเรียนรู้ของเครื่องในการ

ออกแบบระบบอัตโนมัติเพื่อให้ระบบมีความสามารถ และมีประสิทธิภาพในการจำแนกและระบุกลุ่มอะแคนทามีบาได้ ซึ่งระบบจะประกอบไปด้วย 3 กระบวนการหลัก คือ 1) กระบวนการก่อนการประมวลผลภาพ 2) กระบวนการสกัดคุณลักษณะเด่นของซิสต์ด้วยการผสมผสานในระดับคุณลักษณะทางรูปร่างด้วยวิธีการ HOG และคุณลักษณะเชิงพื้นผิวด้วยวิธีการ LBP (Combined Descriptor) หลังจากนั้นค่าของคุณลักษณะเด่นเหล่านี้จะถูกนำมาจำแนก คัดแยกกลุ่มอะแคนทามีบาในกระบวนการสุดท้ายนั้นคือ 3) การคัดแยกกลุ่มของซิสต์ด้วยการเรียนรู้ของเครื่อง ในงานวิจัยชิ้นนี้พบว่าตัวจำแนกชนิด SVM นั้นให้ค่าความถูกต้องเฉลี่ยสูงที่สุดเมื่อเปรียบเทียบกับตัวจำแนกชนิดอื่นๆ จากการทดลองพบว่า ระบบที่นำเสนอนี้มีประสิทธิภาพสูงที่สุดเมื่อทำการเปรียบเทียบประสิทธิภาพความถูกต้องและความแม่นยำกับวิธีการดั้งเดิมของการดึงลักษณะเด่นอื่นๆ จึงทำให้สามารถสรุปผลการทดลองได้ว่า ระบบการเรียนรู้ของเครื่องแบบอัตโนมัตินี้มีประสิทธิภาพสำหรับระบุลักษณะทางสัณฐานวิทยาของอะแคนทามีบาด้วยภาพจากกล้องจุลทรรศน์ และยังสามารถนำไปใช้เพื่อเป็นแนวทางในการพัฒนาระบบให้สามารถช่วยเสริมการทำงานของผู้เชี่ยวชาญในห้องปฏิบัติการทางคลินิกต่อไปได้

5. กิตติกรรมประกาศ

งานวิจัยนี้ได้รับทุนอุดหนุนการวิจัยจากเงินรายได้ คณะวิศวกรรมศาสตร์ ประจำปีงบประมาณ 2562

มหาวิทยาลัยศรีนครินทรวิโรฒ สัญญาเลขที่ 537/2562 ขอขอบพระคุณ นายไกรวิทย์ รูปโฉม นางสาวชฎาภรณ์ เกื้อกุล และ นางสาวบุษกร ศุภกิจอำนวย ภาควิชา วิศวกรรมศาสตร์คอมพิวเตอร์ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ สำหรับการเตรียมข้อมูลที่เกี่ยวข้องเพื่อการตีพิมพ์ผลงานวิจัยฉบับนี้

เอกสารอ้างอิง

- [1] P. Buppan, C. Meeboon, T. Klamsiri, W. Promyuttana, W. Koamornsap, R. Kosuwin, and P. Srimee, "Survey of *Acanthamoeba* spp. in water samples from the public park of Thailand," *Journal of Research Unit on Science, Technology and Environment for Learning*, vol. 9, no. 1, pp. 36–45, 2018 (in Thai).
- [2] C. Suwancharoen and W. Srichoom, "Survey of *Acanthamoeba* in natural water sources in communities around the university of Phayao, Phayao province, Thailand," *Journal of Public Health*, vol. 47, no. 3, pp. 255–263, 2017 (in Thai).
- [3] C. Siripanth, "Amphizoic amoebae: Pathogenic free-living protozoa; Review of the literature and review of cases in Thailand," *Journal of the Medical Association of Thailand*, vol. 88, no. 5, pp. 1–7, 2005 (in Thai).
- [4] C. Bunsuwansakul, T. Mahboob, K. Hounkong, S. Laohaprapanon, S. Chitapornpan, S. Jawjit, A. Yasiri, S. Barusrux, K. Bunluepuech, N. Sawangjaroen, C. C. Salibay, C. Kaewjai, M. L. Pereira, and V. Nissapatorn, "Acanthamoeba in Southeast Asia - overview and challenges," *The Korean Journal of Parasitology*, vol. 57, no. 4, pp. 341–357, 2019.
- [5] M. Pussard and R. Pons, "Morphologies de la paroi kystique et taxonomie du genre *Acanthamoeba* (Protozoa, Amoebida)," *Protistologica*, vol. 13, no. 4, pp. 557–598, 1977.
- [6] N. Ruangrunsi and C. Palanuvej, "Acanthamoeba spp. infection's health and risk watch," Public Health Science, College of Public Health Sciences, Chulalongkorn University, Bangkok, 2011.
- [7] J. L. Duarte, C. Furst, D. R. Klisiowicz, G. Klassen, and A. O. Costa, "Morphological, genotypic, and physiological characterization of *Acanthamoeba* isolates from keratitis patients and the domestic environment in Vitoria, Espirito Santo, Brazil," *Experimental Parasitology*, vol. 135, no. 1, pp. 9–14, 2013.
- [8] G. C. Booton, G. S. Visvesvara, T. J. Byers, D. J. Kelly, P. A. Fuerst, "Identification and distribution of *Acanthamoeba* species genotypes associated with nonkeratitis infections," *Journal of Clinical Microbiology*, vol. 43, no. 4, pp. 1689–1693, 2005.
- [9] J. Rodellar, S. Alférez, A. Acevedo, A. Molina, and A. Merino, "Image processing and machine learning in the morphological analysis of blood cells," *International Journal of Laboratory Hematology*, vol. 40, pp. 46–53, 2018.
- [10] M. S. Mabrouk, M. A. Sheha, and A. Sharawy, "Automatic detection of melanoma skin cancer using texture analysis," *International Journal of Computer Applications*, vol. 42, no. 20, pp. 22–26, 2012.
- [11] A. M. Abdeldaim, A. T. Sahlol, M. Elhoseny, and A. E. Hassanien, "Computer-aided acute lymphoblastic leukemia diagnosis system based on image analysis," *Advances in Soft Computing and Machine Learning in Image*

- Processing*, vol. 730, Springer, Cham, 2018.
- [12] A. Vijayalakshmi and B. Rajesh Kanna, "Deep learning approach to detect malaria from microscopic images," *Multimedia Tools and Applications*, vol. 79, no. 21–22, pp. 15297–15317, 2019.
- [13] T. Ojala, M. Pietikainen, and T. Maenpaa, "Multiresolution gray-scale and rotation invariant texture classification with local binary patterns," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 24, no. 7, pp. 971–987, 2002.
- [14] M. K. Hu, "Visual pattern recognition by moment invariants," *RE Transactions on Information Theory*, vol. IT-8, no. 2, pp. 179–187, 1962.
- [15] J. Canny, "A computational approach to edge detection," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. PAMI-8, no. 6, pp. 679–698, 1986.
- [16] N. Dalal and B. Triggs, "Histograms of oriented gradients for human detection," *IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)*, 2005, pp. 886–893.
- [17] H. Lahiani and M. Neji, "Hand gesture recognition method based on HOG-LBP features for mobile devices," *Procedia Computer Science*, vol. 126, pp. 254–263, 2018.
- [18] X. Wang, T. X. Han, and S. Yan, "An HOG-LBP human detector with partial occlusion handling," in *2009 IEEE 12th International Conference on Computer Vision*, 2009, pp. 32–39.
- [19] M. Sokolova and G. Lapalme, "A systematic analysis of performance measures for classification tasks," *Information Processing & Management*, vol. 45, pp. 427–437, 2009.
- [20] T. S. Furey, N. Cristianini, N. Duffy, D. W. Bednarski, M. Schummer, and D. Hausler, "Support vector machine classification and validation of cancer tissue samples using microarray expression data," *Bioinformatics*, vol. 16, no. 10, pp. 906–914, 2000.
- [21] S. Öztürk and B. Akdemir, "Application of feature extraction and classification methods for histopathological image using GLCM, LBP, LBGLCM, GLRLM and SFTA," *Procedia Computer Science*, vol. 132, pp. 40–46, 2018.