

Academic article

การสกัดคุณลักษณะเอบีซีดีเพื่อประเมินความเสี่ยงโรคผิวหนังเมลาโนมา ด้วยการประมวลผลภาพ: การทบทวนวรรณกรรม ABCD Feature Extraction for Melanoma Screening Using Image Processing: A review

กวิน ชินพงศ์¹, อสมา ตั้งปรมัตถ์สกุล¹, ธัญรดา โพธิ์พระรส¹, ทศพร บุญชู¹
ปกรณ ล่องทอง¹, พร พันธุ์จันทา², พีรุตย์ เขียววิชัย^{1,*}

Kawin Chinpong¹, Asama Tungparamutsakul¹, Thanrada Popraros¹, Totsaporn Boonchu¹,
Pakorn Longthong¹, Phond Phunchongharn², Peerut Chienwichai^{1,*}

¹คณะแพทยศาสตร์และการสาธารณสุข วิทยาลัยวิทยาศาสตร์การแพทย์เจ้าฟ้าจุฬาภรณ์ ราชวิทยาลัยจุฬาภรณ์

²ภาควิชาวิศวกรรมคอมพิวเตอร์ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าธนบุรี

¹Faculty of Medicine and Public Health, HRH Princess Chulabhorn College of Medical Science, Chulabhorn Royal Academy

²Department of Computer Engineering, Faculty of Engineering, King Mongkut's University of Technology Thonburi

*Corresponding Author, email: peerut.chi@pccms.ac.th

Received: 4 July 2021; Revised: 29 September 2021; Accepted: 15 October 2021

บทคัดย่อ

มะเร็งเมลาโนมาเป็นมะเร็งผิวหนังที่พบไม่บ่อยนัก แต่เซลล์มะเร็งมีโอกาสรุกรายไปยังอวัยวะภายใน ส่งผลให้อัตราการเสียชีวิตสูง การวินิจฉัยมะเร็งเมลาโนมาในระยะต้นจะช่วยลดโอกาสการลุกลามและลดการเสียชีวิตของผู้ป่วยได้ แต่การวินิจฉัยมะเร็งในระยะต้นจำเป็นต้องอาศัยแพทย์ผู้เชี่ยวชาญ ซึ่งยังมีไม่เพียงพอในปัจจุบัน ดังนั้น การนำเทคโนโลยีที่ทันสมัยมาช่วยคัดกรองและวินิจฉัยมะเร็งเมลาโนมาจะช่วยลดอัตราการเสียชีวิตของผู้ป่วย และลดภาระงานของแพทย์ลงได้ การประมวลผลภาพเป็นสาขาหนึ่งของวิทยาศาสตร์ข้อมูลที่สามารถวิเคราะห์และแยกคุณลักษณะต่าง ๆ ของภาพ เช่น ขนาด สี ขอบเขต เป็นต้น โดยมีขั้นตอนการประมวลผลภาพ 5 ขั้นตอน ได้แก่ การเก็บข้อมูล การเตรียมข้อมูล การสกัดคุณลักษณะเฉพาะ การสร้างแบบจำลอง และการประเมินผล ขั้นตอนการสกัดคุณลักษณะของภาพมะเร็งผิวหนังเมลาโนมามักจะใช้วิธีการสกัดคุณลักษณะเอบีซีดี ซึ่งจะนำความไม่สมมาตร เส้นขอบ สี และเส้นผ่านศูนย์กลางของรอยโรคมาใช้ในการวิเคราะห์ เนื่องจากวิธีนี้ได้รับความนิยมและมีความแม่นยำสูง ในบทความวิชาการนี้ ได้สรุปขั้นตอนการประมวลผลภาพร่วมกับการสกัดคุณลักษณะเอบีซีดีเพื่อการวินิจฉัยมะเร็งผิวหนังเมลาโนมา โดยมีจุดประสงค์เพื่อให้ผู้อ่านเกิดความเข้าใจในกระบวนการดังกล่าว บทความนี้เป็นประโยชน์ต่อ

ผู้สนใจในการประยุกต์ใช้วิทยาศาสตร์ข้อมูลทางการแพทย์ และเพื่อเป็นแนวทางในการพัฒนานวัตกรรมที่ก่อให้เกิดประโยชน์กับผู้ป่วยและสังคมต่อไปในอนาคต

คำสำคัญ: มะเร็งเมลาโนมา การประมวลผลภาพ การสกัดคุณลักษณะ หลักเอบีซีดี

Abstract

Melanoma is an uncommon type of skin cancer. Once cancer cells spread to internal organs, the disease becomes deadly with high mortality rate. Early diagnosis can reduce disease progression as well as death rate from melanoma. For precise diagnosis of the disease at the early stage, specialized physicians are needed. Unfortunately, only a handful of these experts are available. Therefore, applying cutting-edge technologies to melanoma screening and diagnosis can help minimizing death of patients and reduces workloads of physicians. Image processing is a popular branch of data science for differentiating images using their features, i.e., size, color, margin. Image processing composes of 5 steps, including data acquisition, data preprocessing, feature extraction, modeling, and evaluation. During feature extraction, ABCD rule, which stands for asymmetry, border, color, and diameter, respectively, is widely applied due to its popularity and accuracy. In the current review, we aimed to elaborate image processing protocol for screening of melanoma with ABCD feature extraction. The detailed methods for performing feature extraction using ABCD rules are summarized. This review would be beneficial for scientists who interest in this field, and for future development of innovation to improve health of the patients and the public.

Keywords: Melanoma, Image Processing, Feature Extraction, ABCD rules

บทนำ (Introduction)

มะเร็งผิวหนังเมลาโนมา (Melanoma) คือ มะเร็งผิวหนังชนิดหนึ่งที่เกิดจากการแบ่งตัวมากเกินไปของเซลล์เม็ดสีในชั้นผิวหนัง มะเร็งผิวหนังเมลาโนมาพบได้ไม่บ่อยนัก คิดเป็นน้อยกว่าร้อยละ 5 ของมะเร็งผิวหนังทั้งหมด แต่มะเร็งชนิดนี้มีความรุนแรงสูง ก่อให้เกิดการเสียชีวิตมากถึงร้อยละ 75 ของผู้เสียชีวิตจากมะเร็งผิวหนังทั้งหมด¹ ผู้ป่วยส่วนใหญ่มักไม่ทราบว่าตนเองมีก้อนมะเร็ง ร้อยละ 33-59 ของผู้ป่วยมาพบแพทย์เมื่อ

มะเร็งมีพัฒนาไปในระยะที่รุนแรงแล้ว ส่งผลให้ผู้ป่วยมีค่ามัธยฐานการรอดชีพเพียง 3.71 ปี โดยอัตราการรอดชีพในระยะเวลา 5 ปีของผู้ป่วยลดลงอย่างมากเมื่อมะเร็งมีการพัฒนาเป็นระยะที่รุนแรง² การวินิจฉัยผู้ป่วยในระยะต้นจึงมีความสำคัญอย่างยิ่งต่อผลการรักษา ในขั้นตอนการวินิจฉัยมะเร็งผิวหนังเมลาโนมา แพทย์จะใช้กล้อง dermoscope ตรวจดูรอยโรคบนผิวหนัง ซึ่งกล้อง dermoscope นี้เป็นเครื่องมือที่ถูกพัฒนาขึ้นเพื่อดูลักษณะของรอยโรคและหา

สัญญาณการเกิดมะเร็งผิวหนังชนิดต่าง ๆ³ หากแพทย์พบรอยโรคที่อาจเป็นมะเร็ง แพทย์จะทำการตัดชิ้นเนื้อบริเวณดังกล่าวเพื่อนำไปตรวจวินิจฉัยทางพยาธิวิทยาต่อไป ทั้งนี้การวินิจฉัยด้วยกล้อง dermoscope มีข้อดี กล่าวคือสามารถทำได้รวดเร็ว และไม่ทำให้ผิวหนังเสียหาย โดยมีความแม่นยำประมาณร้อยละ 75-84⁴ อย่างไรก็ตามความแม่นยำของการตรวจวินิจฉัยขึ้นอยู่กับทักษะ ประสบการณ์ และความชำนาญการของแพทย์แต่ละคน ซึ่งปัจจุบันประเทศไทยมีแพทย์ที่มีความเชี่ยวชาญเฉพาะทางโรคผิวหนังจำนวนไม่มากนัก ทำให้การให้บริการวินิจฉัยมะเร็งชนิดนี้ไม่ทั่วถึง โดยเฉพาะในพื้นที่ห่างไกล ดังนั้นหากมีการพัฒนาเทคโนโลยีและนวัตกรรมที่สามารถช่วยวินิจฉัยมะเร็งผิวหนังเมลาโนมาได้อย่างแม่นยำ จะสามารถแบ่งเบาภาระของแพทย์ผู้เชี่ยวชาญ และลดอัตราการเสียชีวิตของผู้ป่วยมะเร็งผิวหนังเมลาโนมาได้อย่างมีประสิทธิภาพ

เทคนิคการประมวลผลภาพ (Image processing) คือการนำเทคนิควิธีทางวิทยาศาสตร์ข้อมูลมาคำนวณและประมวลผลรูปภาพต่าง ๆ เพื่อให้ได้ข้อมูลตามที่ต้องการ เทคนิคการประมวลผลภาพถูกนำมาใช้ในการแพทย์อย่างแพร่หลาย รวมถึงนำมาใช้เพื่อการวินิจฉัยและประเมินระยะของมะเร็งผิวหนังเมลาโนมาด้วย¹⁻⁵ ในขั้นตอนการประมวลผลภาพ ข้อมูลรูปภาพจากกล้อง dermoscope จะถูกนำมาปรับเพื่อให้เหมาะสมกับการทำงานด้วยโปรแกรมคอมพิวเตอร์ จากนั้นจึงใช้การสร้างแบบจำลองในการวิเคราะห์ว่ารูปภาพดังกล่าวมีความเสี่ยงในการเป็นมะเร็งมากน้อยเพียงใด แบบจำลองที่นิยมนำมาใช้ในการประมวลผลภาพมะเร็งผิวหนังเมลาโนมา ได้แก่ แบบจำลองโครงข่ายประสาทแบบคอนโวลูชัน (Convolutional

neural network: CNN)⁶⁻⁸ แบบจำลอง Support vector machine^{9,10} เป็นต้น อีกหนึ่งวิธีที่ได้รับความนิยมในการใช้เพื่อศึกษา คือ การสกัดคุณลักษณะเฉพาะ (Feature extraction) ด้วยหลัก ABCD (ABCD rule) ร่วมกับการวิเคราะห์ด้วยแบบจำลอง Total dermoscopy score (TDS)¹¹⁻¹⁴ ซึ่งจะนำลักษณะของรอยโรคมาใช้ในการวิเคราะห์ ได้แก่ ความไม่สมมาตรของรอยโรค (Asymmetry: A) เส้นขอบของรอยโรค (Border: B) สีของรอยโรค (Color: C) และเส้นผ่านศูนย์กลางของรอยโรค (Diameter: D)^{11,12} การประมวลผลภาพมีอุปสรรคในการศึกษา ทั้งในแง่ของรายละเอียดเชิงเทคนิค ความแตกต่างของรูปภาพที่ใช้ในการวิเคราะห์ การระบุขอบเขตรอยโรค และความซับซ้อนในการศึกษา ทำให้ผู้ที่ไม่คุ้นชินกับงานด้านนี้อาจเกิดความลำบากในการศึกษาทำความเข้าใจได้ ดังนั้น หากมีคำอธิบายขั้นตอนการศึกษาการประมวลผลภาพเพื่อการคัดกรองและวินิจฉัยมะเร็งเมลาโนมา รวมถึงเปรียบเทียบผลของแต่ละวิธี จะช่วยให้ผู้ต้องการศึกษาสามารถเริ่มต้นการศึกษาได้ง่ายขึ้น

วัตถุประสงค์ของบทความทางวิชาการนี้ จะเป็นการสรุปขั้นตอนการคัดกรองมะเร็งเมลาโนมาด้วยเทคนิคการประมวลผลภาพด้วยการสกัดคุณลักษณะเฉพาะตามหลัก ABCD ร่วมกับการวิเคราะห์ด้วยแบบจำลอง Total dermoscopy score และเปรียบเทียบกับการใช้แบบจำลองโครงข่ายประสาทแบบคอนโวลูชัน บทความนี้มีประโยชน์สำหรับผู้ที่ต้องการเรียนรู้เทคนิคการประมวลผลภาพเพื่อนำมาประยุกต์ใช้กับข้อมูลทางการแพทย์ และยังมุ่งหวังให้เกิดการพัฒนาเทคโนโลยีและนวัตกรรมที่มีประโยชน์ต่อแพทย์และผู้ป่วยต่อไปในอนาคต

การประมวลผลภาพ (Image processing)


การประมวลผลภาพ (Image processing) คือ กระบวนการวิเคราะห์ข้อมูลรูปภาพในลักษณะของ ข้อมูลดิจิทัล โดยการวิเคราะห์จะประมวลผลผ่าน คอมพิวเตอร์ด้วยวิธีการคำนวณต่าง ๆ ที่ทำให้ได้ คุณสมบัติทั้งในเชิงคุณภาพและปริมาณ¹⁵ การ ประมวลผลภาพถูกนำมาประยุกต์ใช้กับรูปภาพ ทางทางการแพทย์อย่างหลากหลาย ทำให้บุคลากร ทางแพทย์สามารถวิเคราะห์รูปภาพจำนวนมากใน ระยะเวลาอันรวดเร็ว และเป็นการเพิ่มประสิทธิภาพ การวินิจฉัยได้ดียิ่งขึ้น เทคนิคการประมวลผลภาพถ่าย ผิวน้ำพบว่าสามารถแบ่งขั้นตอนดังแสดงในรูปที่ 1 ออกเป็น 5 ขั้นตอนหลัก ดังนี้

1. การเก็บข้อมูล (Data Acquisition)
2. การเตรียมข้อมูล (Data Preprocessing)
3. การสกัดคุณลักษณะเฉพาะ (Feature Extraction)
4. การสร้างแบบจำลอง (Modeling)
5. การประเมินผล (Evaluation)

การเก็บข้อมูล (Data Acquisition)

การเก็บข้อมูลรูปภาพมะเร็งผิวหนังเมลาโนมา ได้มาจากกล้อง dermoscope โดยต้องเลือกภาพที่ชัด ไม่มีสิ่งกีดขวาง เช่น ผม ขน เป็นต้น แต่ในปัจจุบัน มี ฐานข้อมูลสาธารณะที่เผยแพร่รูปของมะเร็งผิวหนัง ชนิดต่าง ๆ รวมถึงมะเร็งผิวหนังเมลาโนมาด้วย ได้แก่ ฐานข้อมูล PH2 และฐานข้อมูล International Skin Imaging Collaboration 2020 (ISIC2020) เป็นต้น

ฐานข้อมูล PH2¹⁶ ถูกสร้างขึ้นจากความร่วมมือ ระหว่างมหาวิทยาลัยปอร์โต มหาวิทยาลัยลิสบอน และโรงพยาบาลโรคผิวหนัง Pedro Hispano ประเทศ โปรตุเกส ฐานข้อมูล PH2 มีรูปถ่ายของมะเร็งผิวหนัง เมลาโนมาจากกล้อง dermoscope กว่า 200 รูป โดย รูปทั้งหมดจะเป็นภาพสี 8 บิต ระบบสี RGB (RGB color model) ความละเอียด 768 × 560 พิกเซล และภาพทั้งหมดได้รับการตรวจสอบและใส่คำอธิบาย จากแพทย์ผู้เชี่ยวชาญแล้ว ซึ่งฐานข้อมูล PH2 เปิดให้ บุคคลทั่วไปสามารถเข้าถึงได้ เพื่อประโยชน์ในการวิจัย และการเปรียบเทียบผลการทดลอง



รูปที่ 1 ขั้นตอนการประมวลผลภาพ

ฐานข้อมูล ISIC2020¹⁷ เป็นฐานข้อมูลรูปภาพมะเร็งผิวหนังเมลานوما จากความร่วมมือด้านวิชาการและด้านอุตสาหกรรมเพื่อลดอัตราการเสียชีวิตจากโรคมะเร็งชนิดนี้ ฐานข้อมูลนี้ประกอบด้วยรูปถ่ายมะเร็งผิวหนังเมลานوماจากกล้อง dermoscope มากกว่า 33,126 รูป ซึ่งผู้ที่สนใจสามารถนำรูปดังกล่าวไปใช้เพื่อจุดประสงค์ทางการศึกษา วิจัย และการพัฒนานวัตกรรมทางการแพทย์ได้ ทั้งนี้ ในปัจจุบันฐานข้อมูล ISIC2020 ถูกนำไปใช้ในการวิจัยและการพัฒนาระบบคัดกรองโรคมะเร็งผิวหนังเมลานوماอย่างต่อเนื่อง

การเตรียมข้อมูล (Data Preprocessing)

การเตรียมข้อมูลเป็นขั้นตอนที่ทำให้ข้อมูลอยู่ในรูปแบบที่เหมาะสมก่อนนำไปวิเคราะห์ในขั้นตอนถัดไป การเตรียมข้อมูลสำหรับการวิเคราะห์ภาพถ่ายมะเร็งผิวหนังเมลานوماสามารถสรุปเป็น 4 ขั้นตอน^{18,19} ดังนี้

1. การปรับปรุงรูปภาพ

(Image enhancement)

การปรับปรุงรูปภาพ คือ กระบวนการปรับปรุงข้อมูลภาพเพื่อเพิ่มประสิทธิภาพการวิเคราะห์ข้อมูล หลักการของการปรับปรุงภาพ คือ การแก้ไขบางคุณลักษณะให้เหมาะสมและจำเพาะกับงานมากขึ้น โดยยังคงลักษณะที่ต้องการไว้ได้ การปรับปรุงภาพมีหลายเทคนิค เช่น

- Image scaling คือการปรับขนาดภาพเพื่อให้มีขนาดความกว้างคงที่แต่มีขนาดความสูงแตกต่างกันเนื่องจากรูปภาพมะเร็งผิวหนังเมลานوماอาจถูกเก็บจากหลากหลายแหล่งที่มา ทำให้มีความหลากหลายทางขนาด


- Color Space Transformation คือ การปรับมาตรฐานหรือฐานข้อมูลสีของข้อมูลภาพให้เหมาะสม โดยมักจะปรับสีให้เป็นระบบสี Red Green Blue (RGB) ระบบ Hue Saturation Value (HSV) และระบบ Hue Lightness Saturation (HLS) ในบางกรณีหากต้องการให้ข้อมูลภาพมีความเข้มของสีที่แตกต่างกันอย่างชัดเจน อาจพิจารณาปรับรูปภาพให้อยู่ในระบบสีเทา (Grayscale)
- Contrast enhancement คือการปรับแต่งความเข้มของข้อมูลภาพ เพื่อให้ภาพมีความคมชัดขึ้น ซึ่งเทคนิคที่นิยมใช้มี 2 ประเภท ได้แก่ การปรับความเข้มของภาพโดยใช้ความสัมพันธ์เชิงเส้นตรง (Linear contrast enhancement) และการปรับความเข้มของภาพโดยใช้ความสัมพันธ์แบบไม่เป็นเส้นตรง (Non-linear contrast enhancement)

2. การคืนสภาพรูปภาพ

(Image restoration)

การคืนสภาพรูปภาพ คือ กระบวนการปรับปรุงข้อมูลภาพที่เกิดจากจุดรบกวน (Noise) และความพร่ามัว (Blur)

- จุดรบกวน (Noise) มักเกิดจากขณะเก็บรูปภาพมีแสงไม่เพียงพอ หรือเกิดจากการบีบอัดขนาดภาพ จุดรบกวนส่งผลให้ข้อมูลภาพมีรายละเอียดที่น้อยลง ดังแสดงในรูปที่ 2B การแก้ไขจุดรบกวนทำได้โดยใช้ตัวกรองแบบค่าเฉลี่ยเลขคณิต (Mean filters) หรือค่ากึ่งกลางเลขคณิต (Median filters) มาคำนวณค่าเฉลี่ยจากจุดภาพอื่นที่อยู่โดยรอบบริเวณที่สัญญาณหายไป เป็นต้น



รูปที่ 2 ภาพเปรียบเทียบรูปถ่ายปกติ (A.) รูปถ่ายที่มีจุดรบกวน (B.) และรูปถ่ายที่มีความพร่ามัว (C.)

- ความพร่ามัว (Blur) มักเกิดจากการเคลื่อนไหวของกล้อง dermoscope ขณะทำการถ่ายภาพ ดังแสดงในรูปที่ 2C การแก้ปัญหาความพร่ามัวสามารถทำได้หลายวิธี เช่น อัลกอริทึม Lucy-Richardson algorithm วิธี Inverse filter วิธี wiener filter เป็นต้น

3. การลบสิ่งรบกวน (Artifact removal)

ภาพถ่ายจากกล้อง dermoscope อาจมีสิ่งรบกวน (Artifact) แทรกอยู่ในภาพ เช่น ผม เส้นขน ฟองอากาศ เป็นต้น สิ่งรบกวนจะปิดบังรอยโรคบางส่วน ทำให้สีของรอยโรคเปลี่ยนไป หรือขอบเขตของรอยโรคไม่ชัดเจน ซึ่งจะส่งผลต่อการสร้างแบบจำลองในขั้นตอนต่อไปได้ ดังนั้น จึงจำเป็นต้องกำจัดสิ่งรบกวนนี้ออก การกำจัดสิ่งรบกวนอาจใช้ซอฟต์แวร์สำเร็จรูป เช่น DullRazor²⁰ ซึ่งเป็นที่นิยมในการประมวลผลภาพ

4. การหาขอบเขตของรอยโรค

(Lesion border detection)

การระบุขอบเขตสำหรับการสกัดคุณลักษณะเฉพาะ เริ่มจากการแปลงภาพสีระบบ RGB ที่ประกอบด้วย 3 ช่องสี ได้แก่ สีเขียว สีแดง และสีน้ำเงิน ให้เป็นภาพระบบสีเทาที่มีเพียง 1 ช่องสี จาก

งานวิจัยของ Wati และคณะ²¹ ได้เสนอสมการที่เหมาะสมกับการแปลงภาพสีระบบ RGB ในตำแหน่ง i, j ให้เป็นภาพระดับสีเทา (A_{gray}) คือ

$$A_{gray}[i, j] = 0.2999A_{red}[i, j] + 0.578A_{green}[i, j] + 0.11A_{blue}[i, j]$$

โดยกำหนดให้ A เป็นภาพที่เป็นระบบสี RGB ที่มีขนาดความกว้างเท่ากับ m พิกเซล และความยาวเท่ากับ n พิกเซล ที่สามารถแยกได้เป็น 3 ช่องสี คือ $A_{red}, A_{green}, A_{blue}$ โดยที่ $0 \leq i < m$ และ $0 \leq j < n$ จากนั้นจะเป็นการสร้างภาพขาว-ดำ (Binary image) ที่เกิดจากการเปรียบเทียบค่าระหว่าง $A_{gray}[i, j]$ ที่เป็นค่าความเข้มในแต่ละพิกเซล $[i, j]$ เทียบกับค่าแบ่งระดับ (Threshold: T) เพื่อแทนที่พิกเซล $[i, j]$ ที่ทำให้ $A_{gray}[i, j] \geq T$ ด้วยสีขาว (Foreground) และแทนที่พิกเซล $[i, j]$ ที่ทำให้ $A_{gray}[i, j] < T$ ด้วยสีดำ (Background)

จากขั้นตอนการสร้างภาพขาว-ดำ ที่ได้อธิบายไว้ข้างต้น วิธีหนึ่งที่สามารถใช้หาค่าแบ่งระดับที่เหมาะสมได้คือ การใช้วิธีของ Otsu²² วิธีนี้จะเริ่มจากปรับแต่งภาพด้วยวิธีฮิสโตแกรมอีควอลไลเซชัน (Histogram equalization) โดยจะสร้างฮิสโตแกรมของความเข้ม

ของภาพระดับสีเทาให้มีโดเมนอยู่ในช่วง $[0,255]$ จากนั้น แต่ละค่าแบ่งระดับ $T \in [0,255]$ โดยจะมีการหาค่า T ที่ทำให้ค่าความแปรปรวนภายในคลาส (Within-class variance) มีค่าต่ำสุด ซึ่งค่าความแปรปรวนภายในคลาส สำหรับ 2 คลาส (Foreground และ Background) จะมีการแปรผันตามค่าผลรวมและค่าความแปรปรวนของความเข้ม ทั้ง 2 คลาส ภาพรวมของการเตรียมข้อมูลรูปภาพมะเร็งผิวหนังเมลาโนมา ถูกสรุปในรูปที่ 3

การสกัดคุณลักษณะเฉพาะ (Feature Extraction)


การสกัดคุณลักษณะเฉพาะจะนำผลลัพธ์ภาพหลังจากการใช้วิธีของ Otsu มาแยกคุณลักษณะ

ABCD เพื่อนำผลลัพธ์เหล่านั้นไปใช้งานในการสร้างแบบจำลองต่อไป การสกัดคุณลักษณะเฉพาะด้วยคุณลักษณะ ABCD นั้น มีวิธีการดังนี้

1. ความไม่สมมาตรของรอยโรค

(A: Asymmetry)

จากงานวิจัยของ Majumder และ Utah²³ ได้เสนอการหาความไม่สมมาตรของรอยโรคด้วยการปรับรูปตามแกน X (ได้ภาพ L_x) และแกน Y (ได้ภาพ L_y) โดยแกนพับจะพาดตามจุดศูนย์กลางของรอยโรค จากนั้นจะหาอัตราส่วนพื้นที่ที่ไม่ทับซ้อนกันจากการพับทั้ง 2 แกน ($A_{\Delta L_x}, A_{\Delta L_y}$) ต่อพื้นที่รอยโรค (A_L) ทั้งหมด ซึ่งสามารถเขียนเป็นสมการ



รูปที่ 3 กระบวนการเตรียมข้อมูลรูปภาพ สำหรับการประมวลผลภาพ ภาพต้นแบบ (A.) ภาพที่ผ่านการเปลี่ยนสีเป็นระบบสีเทา (B.) การหาขอบเขตของรอยโรคด้วยวิธีของ Otsu (C.-E.) และภาพที่ผ่านการกำหนดขอบเขตเรียบร้อยแล้ว (F.)

$$A_1 = \frac{A_{\Delta Lx}}{A_L}, \quad \text{และ} \quad A_2 = \frac{A_{\Delta Ly}}{A_L}$$

หลังจากนั้น จะมีการเปรียบเทียบค่า A_1 และ A_2 กับค่าแบ่งระดับ (T) เพื่อระบุจำนวนแกนที่ไม่สมมาตร โดยที่จะได้ $A_{area} = |A|$; $A = \{A_i | A_i \geq T\}$ และ ช่วงของค่า $A_{area} \in [0,2]$

นอกจากนี้ งานวิจัยของ Zghal และ Derbel²⁴ ได้ เสนอมุมมองของความไม่สม่ำเสมอของสี โดยเริ่มจาก การหาค่าฮิสโตแกรมแบบ Normalized ของแต่ละ ช่องสี C สำหรับภาพที่ L ที่เกิดจากการแบ่งตามแกน Y (แบ่งได้ภาพ ซ้าย-ขวา) ซึ่งเขียนในรูป $h_{L,c}(x)$, หลังจากนั้นจะใช้การหาระยะทางไคสแควร์ (Chi Square distance) ของฮิสโตแกรม $h_{L,c}(x)$ ซึ่งจะ เขียนได้ดังสมการ


$$A_{color} = \sum_{c \in \{R,G,B\}} \sum_{i=1}^n \frac{(h_{1,c}(i) - h_{2,c}(i))^2}{h_{1,c}(i) + h_{2,c}(i)}$$

2. เส้นขอบของรอยโรค (B: Border)

งานวิจัยของ Uddin และคณะ²⁵ ได้ใช้ค่า Compact index (CI) ที่เป็นค่าที่ใช้สำหรับระบุค่า ความกลมของภาพ โดยใช้การคำนวณอัตราส่วน ระหว่างกำลังสองของความยาวเส้นรอบรูป (P) ต่อ พื้นที่รอยโรค (A_L) ดังสมการ

$$B_{CI} = \frac{P^2}{4\pi A_L}$$

การหาระยะทางของแต่ละด้าน จะใช้ระยะทาง ยูคลิเดียน (Euclidean distance) ในการคำนวณ ระยะระหว่างจุดศูนย์กลางของรอยโรค (x_c, y_c) และ แต่ละจุดที่เป็นขอบของรอยโรค (x_i, y_i) ที่เป็นของ ส่วนย่อย (segment) ที่ $k \in [1,8]$ จะสามารถ คำนวณได้จาก



รูปที่ 4 การหาระยะจากจุดศูนย์กลางรอยโรค ตาม งานวิจัยของ Zghal และ Derbel²⁴

$$d_{k,i} = \sqrt{(x_c - x_i)^2 + (y_c - y_i)^2}$$

และหาค่าเฉลี่ยของแต่ละจุดที่เป็นขอบของรอยโรค ($\overline{d_k}$) โดยคำนวณจากสมการ

$$\overline{d_k} = \frac{1}{n} \sum_{i=1}^n d_{k,i}$$

ส่วนต่อมาจะทำการคำนวณค่าเบี่ยงเบนมาตรฐาน เทียบกับค่าเฉลี่ย $\overline{d_k}$ โดยในส่วนย่อยที่ k ที่มีจุด ทั้งหมด n จุด สามารถคำนวณได้จาก

$$s_k = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (d_{k,i} - \overline{d_k})^2}$$

หลังจากนี้ ค่าเบี่ยงเบนมาตรฐานจะถูก เปรียบเทียบกับค่าแบ่งระดับ ซึ่งในการศึกษานั้นมี กำหนดเป็น 30 โดยจะมีตัวแปร B_{score} ที่ระบุจำนวน ส่วนย่อยที่มีค่าเบี่ยงเบนมาตรฐานเกินค่าแบ่งระดับ ซึ่ง สามารถเขียนเป็นสมการได้ในรูป

$$B_{score} = |S| ; S = \{s_k | s_k > 30 \text{ and } k \in [1,8]\}$$

3. สีของรอยโรค (C: Color)

งานวิจัยของ Zghal และ Derbel²⁴ ได้จำแนกสีเป็น 6 สี ได้แก่ สีขาว (White) สีแดง (Red) สีน้ำตาลอ่อน (Light brown) สีน้ำตาลเข้ม (Dark brown) สีฟ้าเทา (Blue-gray) และสีดำ (Black) และแยกความเข้มของแต่ละสีเป็น 6 ระดับ เรียงตามความเข้มของสี โดยให้ระดับที่ 1 มีความเข้มสูงสุด และระดับที่ 6 มีความเข้มต่ำที่สุด และกำหนดค่ารหัสสี (RGB code) ดังตารางที่ 1

เนื่องจากค่า B_{CI} ที่ใช้อยู่นี้เป็นค่าที่มีความไวต่อจุดบกพร่อง Zghal และ Derbel²⁴ จึงได้เสนอการใช้หาระยะทางระหว่างจุดศูนย์กลางของรอยโรคกับขอบรอยโรคทั้ง 8 ด้าน โดยแต่ละด้านจะใช้มุม 45 องศาเทียบกับจุดศูนย์กลางของรอยโรค ดังแสดงใน รูปที่ 4

ค่าสีดังกล่าวจะมีการเปรียบเทียบความห่างโดยใช้ระยะทางยูคลิเดียน ซึ่งสมการระยะทางระหว่างสีแดง (R) สีเขียว (G) และสีน้ำเงิน (B) ของภาพ ณ พิกัด (i, j) และค่าที่ 1 ของสีอ้างอิง ลำดับที่ k (r_k, g_k, b_k) โดยที่จะเป็นตามสมการ

$$C_{k,(i,j)} = \sqrt{(r_k - r_{ij})^2 + (g_k - g_{ij})^2 + (b_k - b_{ij})^2}$$

ตารางที่ 1 ค่ารหัสสี RGB สำหรับสีทั้ง 6 โดย

สี	ระดับที่ 1	ระดับที่ 2	ระดับที่ 3	ระดับที่ 4	ระดับที่ 5	ระดับที่ 6
สีขาว	(1,1,1)	(0.96,0.96,0.96)	(0.92,0.92,0.92)	(0.88,0.88,0.88)	(0.84,0.84,0.84)	(0.8,0.8,0.8)
สีแดง	(0.78,0.59,0.39)	(1,0.20,0.20)	(0.78,0,0)	(0.78,0.2,0.2)	(0.59,0,0)	(0.59,0.2,0.2)
สีน้ำตาลอ่อน	(0.78,0.59,0.39)	(0.78,0.39,0)	(0.78,0.39,0.12)	(0.59,0.39,0.2)	(0.59,0.39,0)	(0.59,0.2,0)
สีน้ำตาลเข้ม	(0.59,0.39,0.39)	(0.49,0.29,0.29)	(0.39,0.2,0.2)	(0.39,0.2,0)	(0.39,0,0)	(0.2,0,0)
สีฟ้าเทา	(0.59,0.49,0.59)	(0.49,0.49,0.59)	(0.39,0.39,0.49)	(0.39,0.49,0.59)	(0.2,0.39,0.59)	(0,0.39,0.59)
สีดำ	(0,0,0)	(0.04,0.04,0.04)	(0.08,0.08,0.08)	(0.12,0.12,0.12)	(0.16,0.16,0.16)	(0.2,0.2,0.2)

ต่อมา คำนวณค่าแบ่งระดับ C_k ที่เป็นค่าเฉลี่ยของค่า $C_{k,(i,j)}$ ในแต่ละช่อง ซึ่งคำนวณจาก

$$C_k = \frac{\sum_{i,j=1}^n C_{k,(i,j)}}{n}$$

จากนั้นจะนำค่ามาเปรียบเทียบกับค่าแบ่งระดับ T_k ที่เกิดจากการหาค่าระยะทางยูคลิเดียน (Euclidean distance) ระหว่างค่าสูงสุดและค่าต่ำสุดของสีอ้างอิงลำดับที่ k โดยที่ภาพจะถูกกล่าวถึงเป็นสีที่ k ก็ต่อเมื่อ $C_k \leq T_k$ และจำนวนสีที่มีในรอยโรคสามารถสรุปได้ด้วยตัวแปร $C = |\{C_k; C_k \leq T_k; k \in [1,6]\}|$ หรือมีจำนวนสี $C \in [1,6]$

4. เส้นผ่านศูนย์กลางของรอยโรค

(D: Diameter)

Zghal และ Derbel²⁴ คำนวณเส้นผ่านศูนย์กลางของรอยโรคจะใช้การวัดขนาดของเส้นผ่านศูนย์กลางในช่วงที่กว้างที่สุด (major axis) ซึ่งการหาเส้นผ่านศูนย์กลางนี้จะใช้การวัดทุกจุดที่เป็นขอบของรอยโรค แล้วหาจุด (x_1, y_1) และ (x_2, y_2) ที่ทำให้ค่าระยะทางยูคลิเดียนมากที่สุด ซึ่งจะได้ค่า $d_{majoraxis}$ หลังจากนั้น จะทำการแปลงเป็นค่าความยาวที่เป็นหน่วยพิกเซล ให้เป็นหน่วยมิลลิเมตร แล้วเปรียบเทียบค่าโดยใช้ค่าแบ่งระดับ เท่ากับ 6 มิลลิเมตร ซึ่งแสดงได้

ดังสมการ

$$D = \begin{cases} 1; (d_{majoraxis} * 25.4)/dpi \geq 6 \\ 0; otherwise \end{cases}$$

ค่า dots per inch (dpi) จะมีค่าตั้งแต่ 72 ถึง 300 ซึ่ง Thanh และคณะ¹² ได้ทำการศึกษาในลักษณะใกล้เคียงกัน โดยวัดขนาดของรอยโรคที่มีขนาดกว้างที่สุด และกำหนดให้รอยโรคที่มีเส้นผ่านศูนย์กลางรอยโรคที่มากกว่า 6 มิลลิเมตรมีโอกาสที่จะเป็นมะเร็ง

โดยสรุปแล้ว จะมีตัวแปรจำนวนแกนที่ไม่สมมาตร (A_{area}) ความไม่สม่ำเสมอของสี (A_{color}) Compactness index (B_{CI}) จำนวนส่วนของขอบที่ไม่เรียบเนียน (B_{score}) จำนวนสีที่มีในรอยโรค (C) ความยาวเส้นผ่านศูนย์กลางเทียบกับค่าแบ่งระดับที่ 6 มิลลิเมตร (D) ที่สามารถนำมาใช้เป็นข้อมูลป้อนเข้า (input) สำหรับแบบจำลองที่จะเกิดขึ้นในส่วนถัดไปได้

การสร้างแบบจำลอง (Modeling)

แบบจำลอง (Model) เป็นเหมือนโครงสร้างของกระบวนการคำนวณ เพื่อทำนายว่ารอยโรคนั้นเป็นมะเร็งผิวหนังหรือไม่ ซึ่งวิธีในการสร้างแบบจำลองที่ได้รับความนิยมในการทำนายรอยโรคของมะเร็งผิวหนังมีหลายวิธี ได้แก่ วิธี Total Dermoscopy Score (TDS) และวิธี Convolutional Neuron Network (CNN)

1. แบบจำลอง Total Dermoscopy Score (TDS)

เป็นค่าที่แสดงให้เห็นว่ารอยโรคนั้นเป็นมะเร็งผิวหนังหรือไม่ โดยนำค่า ABCD ที่ได้จากการสกัดคุณลักษณะเฉพาะไปใช้ ดังสมการ

$$TDS = 1.3A + 0.1B + 0.5C + 0.5D$$

โดยค่า A คือ จำนวนแกนที่ไม่สมมาตร (มีค่าเป็น 0-2) B คือ จำนวนส่วนของขอบรอยโรคที่มีความไม่เรียบเนียน (มีค่าเป็น 0-8) C คือ จำนวนสีที่อยู่บนรอยโรค (มีค่าเป็น 1-6) และ D คือ ความยาวเส้นผ่านศูนย์กลาง ถ้ามีความยาวเส้นผ่านศูนย์กลางตั้งแต่ 6 มิลลิเมตรขึ้นไป D จะมีค่าเป็น 1 แต่ถ้าน้อยกว่า 6 มิลลิเมตร D จะมีค่าเป็น 0

หากค่า TDS มีค่าน้อยกว่า 4.75 จะทำนายว่ารอยโรคนั้นไม่เป็นอันตราย หากค่า TDS มีค่าตั้งแต่ 4.75-5.45 จะทำนายว่ารอยโรคอาจเป็นมะเร็งผิวหนังได้ และหากค่า TDS มีค่ามากกว่า 5.45 จะทำนายว่ารอยโรคนั้นเป็นมะเร็งผิวหนังเมลาโนมา

การสกัดคุณลักษณะ ABCD ร่วมกับแบบจำลอง TDS เป็นการนำลักษณะของรอยโรคมาใช้ในการคัดแยกชนิดของรอยโรค ซึ่งจะคล้ายกับวิธีที่แพทย์จำแนกรอยโรคตามปกติ²⁶ วิธีดังกล่าวมีความน่าเชื่อถือสูง ดังจะเห็นได้จากงานวิจัยต่าง ๆ ที่มักมีความถูกต้องมากกว่าร้อยละ 90^{12,13,24} แต่อย่างไรก็ตาม การวิเคราะห์ด้วยเทคนิคนี้ จำเป็นต้องมีการเตรียมข้อมูลเป็นอย่างดี ต้องมีการสกัดคุณลักษณะเฉพาะทั้ง 4 ของรอยโรคอย่างถูกต้องและแม่นยำ เพื่อให้ได้ผลที่ถูกต้อง ซึ่งจะใช้เวลาค่อนข้างมากหากมีข้อมูลจำนวนมาก¹² นอกจากนี้ เทคนิคนี้ใช้คุณลักษณะของรอยโรคเพียง 4 คุณลักษณะในการคำนวณ ซึ่งอาจจะมองข้ามคุณลักษณะบางอย่างของรอยโรคไปได้ ในระยะหลังจึงมีการใช้เทคนิค Convolutional Neuron Network (CNN) เข้ามาช่วยในการวิเคราะห์เพิ่มมากขึ้น

2. แบบจำลองโครงข่ายประสาทแบบคอนโวลูชัน (Convolutional neural network: CNN)


เป็นโครงข่ายที่ทำหน้าที่คล้ายกับการทำงานของสมองของสิ่งมีชีวิตในการวิเคราะห์รูปภาพของมะเร็งผิวหนังเมลาโนมาดังแสดงในรูปที่ 5 โดยจะมีการแบ่งชั้น (Layer) ในการวิเคราะห์^{27,28} ดังนี้

- Input layer เป็นชั้นที่ทำการรับรูปภาพของรอยโรคที่มีการสงสัยหรือต้องการวินิจฉัยเบื้องต้นว่าเป็นรอยโรคมะเร็งผิวหนัง
- Convolutional layer เป็นชั้นที่ทำการดึงลักษณะต่าง ๆ จากรูปของรอยโรคให้อยู่ในลักษณะของฟังก์ชันลักษณะ (Feature map)
- Pooling layer เป็นชั้นที่จะลดขนาดของฟังก์ชันลักษณะจาก Convolutional layer ลงและเลือกลักษณะที่ชัดเจนของภาพออกมา เพราะถ้าหากฟังก์ชันลักษณะมีขนาดใหญ่เกินไป จะใช้เวลาในการคำนวณนาน

- Fully Connected layer เป็นชั้นที่เกิดการวิเคราะห์ว่าแต่ละภาพเป็นรอยโรคมะเร็งผิวหนังเมลาโนมาหรือไม่ ในชั้นนี้จะมีการคำนวณทางคณิตศาสตร์โดยอาศัยค่าถ่วงน้ำหนักของแต่ละคุณลักษณะเฉพาะของแต่ละรูป

- Output layer เป็นชั้นที่แสดงผลลัพธ์ เพื่อระบุประเภทของรอยโรค

การใช้ CNN เพื่อการคัดกรองภาพมะเร็งผิวหนังเมลาโนมา ไม่จำเป็นต้องอาศัยหลัก ABCD แต่จำเป็นต้องระบุชนิดของภาพก่อนว่าเป็นภาพมะเร็งหรือภาพปกติ จากนั้นแบบจำลองจะระบุลักษณะที่สำคัญของรอยโรคเอง โดยแบบจำลอง CNN ได้รับความนิยมมากขึ้นเนื่องจากสามารถวิเคราะห์รูปภาพที่มีความซับซ้อนได้ดี ซึ่งเหมาะกับการวิเคราะห์รูปภาพมะเร็งผิวหนังเมลาโนมา ที่มีรอยโรคคล้ายกับรอยโรคอื่นที่ไม่เป็นอันตราย เช่น ไฟ แผลเป็น เป็นต้น ในการวิเคราะห์ด้วย CNN แบบจำลองจะ ใช้ทุกคุณลักษณะของรูปภาพในการวิเคราะห์ ดังนั้น จึงมีโอกาที่แบบจำลอง จะประเมิน



รูปที่ 5 ภาพแสดงการทำงานของ Convolutional Neuron Network

คุณลักษณะอื่น ๆ นอกจาก ABCD ด้วย การใช้ CNN ให้มีประสิทธิภาพนั้น จำเป็นต้องมีฐานข้อมูลภาพจำนวนมากเพียงพอ ไม่เช่นนั้นอาจทำให้แบบจำลองที่ได้ มีค่าความถูกต้องเกินความเป็นจริงได้ (Overfit) นอกจากนี้ การที่จำเป็นต้องใช้ฐานข้อมูลรูปภาพขนาดใหญ่ ก็จะทำให้ต้องใช้เวลาในการประมวลผลนานด้วยเช่นกัน

การประเมินผล (Evaluation)

เป็นขั้นตอนการประเมินความถูกต้องของแบบจำลอง วิธีการประเมินผลแบบจำลองมีหลายวิธีตามลักษณะของข้อมูล และความเหมาะสมของแบบจำลอง การประเมินผลที่ได้รับว่านิยมคือการใช้ Confusion matrix^{6,12} ซึ่งจะใช้ความไว (Sensitivity) ความจำเพาะ (Specificity) และความถูกต้อง (Accuracy) ในการประเมินความเหมาะสมของแบบจำลอง

จากตารางที่ 2 ความไว เป็นสัดส่วนของผลบวกจริงต่อผลบวกทั้งหมดจากแบบจำลอง แบบจำลองที่มีความไวสูง แสดงว่ามีโอกาสที่จะทำนายภาพมะเร็งผิวหนังเมลานوماได้อย่างถูกต้อง

ความจำเพาะ เป็นสัดส่วนของผลลบจริงต่อผลลบทั้งหมดจากแบบจำลอง แบบจำลองที่มีความจำเพาะสูง แสดงว่ามีโอกาสที่จะแยกภาพที่ไม่เป็นมะเร็ง ออกจากภาพมะเร็งได้อย่างถูกต้อง

ความถูกต้อง เป็นสัดส่วนของผลรวมผลบวกจริงและผลลบจริง ต่อผลตรวจทั้งหมด ค่าความถูกต้องบ่งบอกถึงความสามารถโดยรวมของแบบจำลองในการตรวจสอบการคัดแยกมะเร็งผิวหนังเมลานوما ซึ่งแบบจำลองที่ดีควรมีค่าความไว ความจำเพาะ และความถูกต้องสูง

การพัฒนาแบบจำลองตรวจคัดกรองมะเร็งผิวหนังเมลานوماด้วยการสกัดคุณลักษณะ ABCD ร่วมกับแบบจำลอง TDS และการใช้แบบจำลอง CNN ให้ค่าความไว ความจำเพาะ และความถูกต้องที่แตกต่างกัน ดังสรุปได้ในตารางที่ 3 ซึ่งอาจจะเกิดจากจำนวนรูปภาพที่ใช้ในการประมวลผลที่ไม่เท่ากัน รูปแบบการเตรียมข้อมูลที่แตกต่างกัน เป็นต้น แต่ทั้งนี้ ค่าทั้งหมดมีแนวโน้มเพิ่มมากขึ้นเมื่อจำนวนรูปที่ใช้ในการประมวลผลมีมากขึ้น

ตารางที่ 2 Confusion matrix

	ภาพมะเร็งผิวหนัง เมลานوما	ภาพที่ไม่ใช่มะเร็งผิวหนัง เมลานوما	
ผลบวกจากแบบจำลอง	ผลบวกจริง (True positive: TP)	ผลลบจริง (False negative: FN)	ความไว (TP / TP+FN)
	ผลบวกจริง (False positive: FP)	ผลลบจริง (True negative: TN)	ความจำเพาะ (TN / TN+FP)
ผลลบจากแบบจำลอง	ความแม่นยำ (TP / TP+FP)	ค่าทำนายผลลบ (TN / FN+TN)	ความถูกต้อง (TP+TN / TP+TN+FP+FN)

ตารางที่ 3 สรุปงานวิจัยที่ใช้การประมวลผลภาพเพื่อคัดกรองมะเร็งผิวหนังเมลาโนมาด้วยแบบจำลอง TDS และ CNN

คณะผู้วิจัย	จำนวนรูปภาพ	แบบจำลอง	ความไว	ความจำเพาะ	ความถูกต้อง
Thanh และคณะ ¹²	> 2,000 รูป	TDS	96.1%	96.8%	96.6%
Amoabedini และคณะ ¹³	206 รูป	TDS	94.85%	99.23%	90.83%
Zghal และ Derbel ²⁴	200 รูป	TDS	87.5%	92.46%	90.83%
Isasi และคณะ ¹⁴	30 รูป	TDS	*	*	85%
Zhang และคณะ ⁶	28,000 รูป	CNN	> 80%	> 80%	> 80%
Sagar และ Dheeba ²⁹	3,600 รูป	CNN	77%	94%	93.5%
Li และ Shen ⁸	2,000 รูป	CNN	49.0%	96.1%	85.7%
Nasiri และคณะ ³⁰	1,796 รูป	CNN	73%	78%	75%
Haenssle และคณะ ⁷	300 รูป	CNN	95%	80%	*

* หมายถึง บทความไม่ได้ระบุไว้

บทสรุป (Conclusion)

เทคนิคการประมวลผลภาพ เป็นวิธีการทางวิทยาศาสตร์ข้อมูลที่มีประโยชน์มากในการคัดกรองและวินิจฉัยมะเร็งผิวหนังเมลาโนมา การประมวลผลภาพสามารถทำได้หลายวิธี โดยแต่ละวิธีมีข้อดีและข้อเสียแตกต่างกันไป ในการทบทวนวรรณกรรมชิ้นนี้ ได้ยกตัวอย่างเทคนิคการประมวลผลภาพ 2 วิธีที่ได้รับความนิยมในการศึกษาวิจัยเพื่อพัฒนาการตรวจวินิจฉัยมะเร็งผิวหนังเมลาโนมา ได้แก่ การสกัดคุณลักษณะ ABCD ร่วมกับแบบจำลอง TDS และแบบจำลอง CNN การสกัดคุณลักษณะ ABCD ร่วมกับแบบจำลอง TDS ให้ค่าความไว ความจำเพาะ และความถูกต้องที่ค่อนข้างสูง แต่ในขั้นตอนการเตรียมข้อมูล ผู้วิจัยจำเป็นต้องมีการปรับแต่งข้อมูลจำนวนมาก แตกต่างจากแบบจำลอง CNN ที่มีการเตรียมข้อมูลน้อยกว่า แต่จำเป็นต้องใช้ข้อมูลรูปภาพจำนวนมาก จึงจะได้ค่าความไว ความจำเพาะ และความถูกต้องที่สูง การเลือกใช้เทคนิคใดในการประมวลผลภาพ

ผู้วิจัยจึงจำเป็นต้องพิจารณาจากหลายองค์ประกอบ เช่น จำนวนข้อมูลที่มีผู้วิจัยมี ความพร้อมของอุปกรณ์ต่าง ๆ เป็นต้น ทั้งนี้ เพื่อให้ผู้วิจัยสามารถพัฒนาแบบจำลองที่มีประสิทธิภาพ และสามารถนำไปใช้เพื่อประโยชน์ของผู้ป่วยและแพทย์ต่อไปในอนาคต

กิตติกรรมประกาศ (Acknowledgements)

คณะผู้จัดทำขอขอบคุณ ผู้ช่วยศาสตราจารย์ ดร.รจนกร พูลมานะอุสาทะกุล คุณประภาศรี สิริ และคุณกมลพร สุขสมพีช สำหรับความช่วยเหลือในการเตรียมข้อมูล

เอกสารอ้างอิง

1. Jain S, Jagtap V, Pise N. Computer Aided Melanoma Skin Cancer Detection Using Image Processing. *Procedia Comput Sci.* 2015;48:735-740. doi:10.1016/j.procs.2015.04.209
2. Chang JWC, Guo J, Hung CY, et al. Sunrise in melanoma management: Time to focus on

- melanoma burden in Asia. *Asia Pac J Clin Oncol*. 2017;13(6):423-427.
doi:[10.1111/ajco.12670](https://doi.org/10.1111/ajco.12670)
3. Holmes GA, Vassantachart JM, Limone BA, Zumwalt M, Hirokane J, Jacob SE. Using Dermoscopy to Identify Melanoma and Improve Diagnostic Discrimination. *Fed Pract*. 2018;35(Suppl 4):S39-S45.
 4. Argenziano G, Soyer HP, Chimenti S, et al. Dermoscopy of pigmented skin lesions: results of a consensus meeting via the Internet. *J Am Acad Dermatol*. 2003;48(5):679-693.
doi:[10.1067/mjd.2003.281](https://doi.org/10.1067/mjd.2003.281)
 5. Vijayalakshmi M M. Melanoma Skin Cancer Detection using Image Processing and Machine Learning. *Int J Trend Sci Res Dev*. 2019;3(4):780-784. doi:[10.31142/ijtsrd23936](https://doi.org/10.31142/ijtsrd23936)
 6. Zhang N, Cai YX, Wang YY, Tian YT, Wang XL, Badami B. Skin cancer diagnosis based on optimized convolutional neural network. *Artif Intell Med*. 2020;102:101756.
doi:[10.1016/j.artmed.2019.101756](https://doi.org/10.1016/j.artmed.2019.101756)
 7. Haenssle HA, Fink C, Schneiderbauer R, et al. Man against machine: diagnostic performance of a deep learning convolutional neural network for dermoscopic melanoma recognition in comparison to 58 dermatologists. *Ann Oncol Off J Eur Soc Med Oncol*. 2018;29(8):1836-1842.
doi:[10.1093/annonc/mdy166](https://doi.org/10.1093/annonc/mdy166)
 8. Li Y, Shen L. Skin Lesion Analysis towards Melanoma Detection Using Deep Learning Network. *Sensors*. 2018;18(2):E556.
doi:[10.3390/s18020556](https://doi.org/10.3390/s18020556)
 9. Seeja R D, Suresh A. Deep Learning Based Skin Lesion Segmentation and Classification of Melanoma Using Support Vector Machine (SVM). *Asian Pac J Cancer Prev APJCP*. 2019;20(5):1555-1561.
doi:[10.31557/APJCP.2019.20.5.1555](https://doi.org/10.31557/APJCP.2019.20.5.1555)
 10. Rehman A, Khan MA, Mehmood Z, Saba T, Sardaraz M, Rashid M. Microscopic melanoma detection and classification: A framework of pixel-based fusion and multilevel features reduction. *Microsc Res Tech*. 2020;83(4):410-423. doi:[10.1002/jemt.23429](https://doi.org/10.1002/jemt.23429)
 11. Daniel Jensen J, Elewski BE. The ABCDEF Rule: Combining the “ABCDE Rule” and the “Ugly Duckling Sign” in an Effort to Improve Patient Self-Screening Examinations. *J Clin Aesthetic Dermatol*. 2015;8(2):15.
 12. Thanh DNH, Prasath VBS, Hieu LM, Hien NN. Melanoma Skin Cancer Detection Method Based on Adaptive Principal Curvature, Colour Normalisation and Feature Extraction with the ABCD Rule. *J Digit Imaging*. 2020;33(3):574-585.
doi:[10.1007/s10278-019-00316-x](https://doi.org/10.1007/s10278-019-00316-x)
 13. Amoabedini A, Farsani MS, Saberhari H, Aminian E. Employing the Local Radon Transform for Melanoma Segmentation in Dermoscopic Images. *J Med Signals Sens*. 2018;8(3):184-194.
doi:[10.4103/jmss.JMSS_40_17](https://doi.org/10.4103/jmss.JMSS_40_17)
 14. Isasi AG, Zapirain BG, Zorrilla AM. Melanomas non-invasive diagnosis application based on the ABCD rule and pattern recognition image processing algorithms. *Comput Biol Med*. 2011;41(9):742-755.
doi:[10.1016/j.combiomed.2011.06.010](https://doi.org/10.1016/j.combiomed.2011.06.010)

15. Dildar M, Akram S, Irfan M, et al. Skin Cancer Detection: A Review Using Deep Learning Techniques. *Int J Environ Res Public Health*. 2021;18(10):5479. doi:[10.3390/ijerph18105479](https://doi.org/10.3390/ijerph18105479)
16. Mendonca T, Ferreira PM, Marçal ARS, et al. PH2: A Public Database for the Analysis of Dermoscopic Images. In: Celebi ME, Mendonca T, Marques JS, eds. *Dermoscopy Image Analysis*. Melanoma Skin Cancer Detection. CRC Press; 2017.
17. International Skin Imaging Collaboration. SIIM-ISIC 2020 Challenge Dataset. Published online 2020. doi:[10.34970/2020-DS01](https://doi.org/10.34970/2020-DS01)
18. Vocaturo E, Zumpano E, Veltri P. Image pre-processing in computer vision systems for melanoma detection. In: *2018 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*. ; 2018:2117-2124. doi:[10.1109/BIBM.2018.8621507](https://doi.org/10.1109/BIBM.2018.8621507)
19. Hoshyar AN, Al-Jumaily A, Hoshyar AN. The Beneficial Techniques in Preprocessing Step of Skin Cancer Detection System Comparing. *Procedia Comput Sci*. 2014;42:25-31. doi:[10.1016/j.procs.2014.11.029](https://doi.org/10.1016/j.procs.2014.11.029)
20. Lee T, Ng V, Gallagher R, Coldman A, McLean D. DullRazor: a software approach to hair removal from images. *Comput Biol Med*. 1997;27(6):533-543. doi:[10.1016/s0010-4825\(97\)00020-6](https://doi.org/10.1016/s0010-4825(97)00020-6)
21. Wati M, Havaluddin, Puspitasari N, Budiman E, Rahim R. First-order Feature Extraction Methods for Image Texture and Melanoma Skin Cancer Detection. *J Phys: Conf Ser*. 2019;1230(1):012013. doi:[10.1088/1742-6596/1230/1/012013](https://doi.org/10.1088/1742-6596/1230/1/012013)
22. Bangare SL, Dubal A, Bangare PS, Patil ST. Reviewing Otsu's Method For Image Thresholding. *Int J Appl Eng Res*. 2015;10(9):21777-21783. doi:[10.37622/IJAER/10.9.2015.21777-21783](https://doi.org/10.37622/IJAER/10.9.2015.21777-21783)
23. Majumder S, Ullah MA. Feature extraction from dermoscopy images for melanoma diagnosis. *SN Appl Sci*. 2019;1(7):753. doi:[10.1007/s42452-019-0786-8](https://doi.org/10.1007/s42452-019-0786-8)
24. Zghal NS, Derbel N. Melanoma Skin Cancer Detection based on Image Processing. *Curr Med Imaging Rev*. 2020;16(1):50-58. doi:[10.2174/1573405614666180911120546](https://doi.org/10.2174/1573405614666180911120546)
25. Uddin MK, Azad I, Bhuiyan A. Image Processing for Skin Cancer Features Extraction. *Int J Sci Eng Res*. 2013;4(2):1-6.
26. Rigel DS, Russak J, Friedman R. The evolution of melanoma diagnosis: 25 years beyond the ABCDs. *CA Cancer J Clin*. 2010;60(5):301-316. doi:[10.3322/caac.20074](https://doi.org/10.3322/caac.20074)
27. Fu'adah YN, Pratiwi NC, Pramudito MA, Ibrahim N. Convolutional Neural Network (CNN) for Automatic Skin Cancer Classification System. *IOP Conf Ser: Mater Sci Eng*. 2020;982:012005. doi:[10.1088/1757-899X/982/1/012005](https://doi.org/10.1088/1757-899X/982/1/012005)
28. Naranjo-Torres J, Mora M, Hernández-García R, Barrientos RJ, Fredes C, Valenzuela A. A Review of Convolutional Neural Network Applied to Fruit Image Processing. *Appl Sci*. 2020;10(10):3443. doi:[10.3390/app10103443](https://doi.org/10.3390/app10103443)
29. Sagar A, Jacob D. *Convolutional Neural Networks for Classifying Melanoma Images*. Cancer Biology; 2020. doi:[10.1101/2020.05.22.110973](https://doi.org/10.1101/2020.05.22.110973)

30. Nasiri S, Helsper J, Jung M, Fathi M. DePicT Melanoma Deep-CLASS: a deep convolutional neural networks approach to classify skin lesion images. *BMC Bioinformatics*. 2020;21(Suppl 2):84. doi:10.1186/s12859-020-3351-y

Chinpong K, Tungparamutsakul A, Poparros T, Boonchu T, Longthong P, Phunchongharn P, Chienwichai P. ABCD Feature Extraction for Melanoma Screening Using Image Processing: A review. *J Chulabhorn Royal Acad*. 2021;3(4):230-45. <https://he02.tci-thaijo.org/index.php/jcra/article/view/251950>

สัญญาอนุญาต ไฟล์ข้อมูลเสริม และ ลิขสิทธิ์

บทความเผยแพร่ในรูปแบบของบทความแบบเปิดและสามารถเข้าถึงได้อย่างเสรี (open-access) ภายใต้เงื่อนไขของสัญญาอนุญาตครีเอทีฟคอมมอนส์สากล ในรูปแบบที่ ต้องอ้างอิงแหล่งที่มา ห้ามใช้เพื่อการค้า และห้ามแก้ไขดัดแปลง เวอร์ชัน 4.0 (CC BY NC ND 4.0) ท่านสามารถแจกจ่ายและนำบทความไปใช้ประโยชน์เพื่อการศึกษาได้ แต่ต้องระบุการอ้างอิงถึงบทความนี้จากเว็บไซต์วารสารวิชาการราชวิทยาลัยจุฬาภรณ์ โดยการระบุข้อมูลบทความและลิงก์ URL บนเอกสารอ้างอิงของท่าน ท่านไม่สามารถนำบทความไปใช้เพื่อการพาณิชย์ใด ๆ ได้เว้นแต่ได้รับอนุญาตจากบรรณาธิการวารสารวิชาการราชวิทยาลัยจุฬาภรณ์ และกรณีการนำบทความไปเรียบเรียงใหม่ เปลี่ยนแปลงเนื้อหา หรือเสริมเติมแต่งเนื้อหาของบทความนี้ ท่านไม่สามารถนำบทความที่ปรับแต่งไปเผยแพร่ได้ในทุกกรณี

หากมีวัสดุเอกสารข้อมูลวิจัยเสริมเพิ่มเติมใด ๆ ที่ใช้อ้างอิงในบทความ ท่านสามารถเข้าถึงได้บนหน้าเว็บไซต์ของวารสาร

บทความนี้เป็นลิขสิทธิ์ของราชวิทยาลัยจุฬาภรณ์ (Chulabhorn Royal Academy) พ.ศ.2564

การอ้างอิง

กวิน ชินพงศ์, อสมมา ตั้งปรมัตถ์สกุล, ธัญรดา โพธิ์พระรส, ทศพร บุญชู, ปกรณ์ ล่องทอง, พร พันธุ์จันทาญ, พิรุทย์ เขียววิชัย. การสกัดคุณลักษณะเอชิตีเพื่อประเมินความเสี่ยงโรคผิวหนังเมลาโนมาด้วยการประมวลผลภาพ: การทบทวนวรรณกรรม. *วารสารวิชาการราชวิทยาลัยจุฬาภรณ์*. 2564;3(4):230-45. <https://he02.tci-thaijo.org/index.php/jcra/article/view/251950>

Online Access

<https://he02.tci-thaijo.org/index.php/jcra/article/view/251950>

