



รายงานวิจัยฉบับสมบูรณ์

โครงการวิจัย “การประมาณค่าตำแหน่งกระดูกเชิงกรานบนภาพเอกซเรย์ชนิดฟิล์มธรรมดาอย่างแม่นยำ
ด้วยอัลกอริทึมจากการคำนวณเชิงเรขาคณิต”

Computational Geometry-Based Algorithms for Accurate Pelvic Localization in Plain
Film Images

ผู้ช่วยศาสตราจารย์ ดร. อธิตา อ่อนเอื้อน

หัวหน้าโครงการวิจัย

โครงการวิจัยประเภทงบเงินรายได้

คณะวิทยาการสารสนเทศ

ปีงบประมาณ พ.ศ. 2567

มหาวิทยาลัยบูรพา

สัญญาเลขที่ 3/2567

รายงานวิจัยฉบับสมบูรณ์

การประมาณค่าตำแหน่งกระดูกเชิงกรานบนภาพเอกซเรย์ชนิดฟิล์มธรรมดาอย่างแม่นยำด้วยอัลกอริทึม
จากการคำนวณเชิงเรขาคณิต

Computational Geometry-Based Algorithms for Accurate Pelvic Localization in Plain
Film Images

ผู้ช่วยศาสตราจารย์ ดร. อธิตา อ่อนเอื้อน

หัวหน้าโครงการวิจัย

คณะวิทยาการสารสนเทศ

มหาวิทยาลัยบูรพา

ตุลาคม พ.ศ. 2567

กิตติกรรมประกาศ

รายงานวิจัยฉบับนี้ได้รับทุนอุดหนุนการวิจัย ประเภทเงินรายได้ คณะวิทยาการสารสนเทศ ประจำปีงบประมาณ พ.ศ. 2567 เลขที่สัญญา 3/2567

ผู้วิจัยขอขอบคุณ คณะวิทยาการสารสนเทศ มหาวิทยาลัยบูรพา ที่ได้ให้โอกาสในการทำวิจัย รวมถึงเงินทุนเพื่อส่งเสริมและพัฒนาศักยภาพนักวิจัย มา ณ โอกาสนี้

อติดา อ่อนเอื้อน

ตุลาคม 2567

บทคัดย่อ

การวิจัยนี้มุ่งเน้นพัฒนาอัลกอริทึมเชิงเรขาคณิตเพื่อระบุตำแหน่งและขนาดของกระดูกในภาพเอ็กซเรย์ โดยมีวัตถุประสงค์เพื่อสนับสนุนกระบวนการวินิจฉัยและติดตามการรักษาทางการแพทย์ การคำนวณตำแหน่งกระดูกอย่างแม่นยำช่วยในการวิเคราะห์โครงสร้างร่างกายของผู้ป่วยและระบุการบาดเจ็บหรือข้อมูลทางการแพทย์อื่น ๆ ได้อย่างมีประสิทธิภาพ การศึกษาใช้สถิติจากชุดข้อมูลที่มีอยู่เพื่อเพิ่มความแม่นยำของอัลกอริทึม โดยใช้วิธีการ ASM (Active Shape Model) และโมเดลรูปร่างที่สามารถปรับขนาดและทิศทางให้สอดคล้องกับภาพ ผลการทดสอบพบว่าค่าดัชนีแจ้งการตัดสินใจสูงกว่า 0.85 ซึ่งแสดงถึงความแม่นยำของวิธีที่นำเสนอในการประมาณค่าตำแหน่งกระดูกเชิงกรานทั้งด้านซ้ายและขวาได้ดี ความสำเร็จนี้เป็นพื้นฐานสำคัญสำหรับการตรวจจับโครงสร้างอื่น ๆ เช่น กระดูกสันหลังส่วนล่างหรือกระดูกก้นกบ และมีศักยภาพในการนำไปประยุกต์ใช้ในวงการการแพทย์เพื่อเพิ่มประสิทธิภาพในการวินิจฉัย

คำสำคัญ: การระบุตำแหน่งกระดูก, ภาพเอกซเรย์, อัลกอริทึมทางเรขาคณิต, Active Shape Model (ASM), การวินิจฉัยทางการแพทย์, การวิเคราะห์ทางสถิติ, กระดูกเชิงกราน

Abstract

This study focuses on developing a geometric algorithm to identify the position and size of bones in X-ray images, aimed at supporting diagnostic and tracking processes in medical treatment. Accurate bone positioning assists in analyzing patients' anatomical structures and identifying injuries or other medical information effectively. The algorithm leverages statistical data from existing datasets to enhance accuracy and applies the Active Shape Model (ASM) method using an elliptical model, which adjusts in size and orientation to align with the X-ray images. Results show a Jaccard index above 0.85, indicating high accuracy in estimating the positions of the pelvis bones on both the left and right sides. This achievement forms a crucial foundation for detecting other structures, such as the lower spine or coccyx, and holds potential for applications in the medical field to improve diagnostic efficiency.

Keywords: bone localization, X-ray imaging, geometric algorithms, Active Shape Model (ASM), medical diagnosis, statistical analysis, pelvic bones

สารบัญ

หน้าที่

กิตติกรรมประกาศ	ก
บทคัดย่อ	ข
Abstract.....	ค
สารบัญ.....	ง
สารบัญภาพ.....	จ
บทที่ 1 บทนำ	1
1.1 ที่มาและความสำคัญ	1
1.2 วัตถุประสงค์ของงานวิจัย	1
1.3 ขอบเขตของการวิจัย	1
1.4 วิธีการดำเนินการวิจัย.....	2
1.5 แผนการดำเนินงาน	2
1.6 ประโยชน์ที่คาดว่าจะได้รับ	2
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง	3
2.1 การทบทวนวรรณกรรมเกี่ยวกับการระบุตำแหน่งของอุ้งเชิงกราน	3
2.2 ความสำคัญของกระดูกเชิงกรานในทางการแพทย์	6
2.3 Active Shape Model (ASM)	7
2.4 การใช้แบบจำลองรูปทรงวงรีในการตรวจจับกระดูกเชิงกราน	8
2.5 การเปลี่ยนรูป Affine Transformation.....	9
บทที่ 3 รายละเอียดผลการดำเนินงาน	11
3.1 การประมาณตำแหน่งกระดูกเชิงกรานเริ่มต้นด้วยข้อมูลทางสถิติจากชุดข้อมูล.....	11
3.2 การประมาณตำแหน่งกระดูกเชิงกรานด้วย Active Shape Model.....	12
3.3 การปรับโมเดลหาตำแหน่งกระดูกสันหลังด้วย Affine Transformations.....	13
3.4 วิธีการประเมินผล / สังเคราะห์ข้อมูล	15
3.5 การออกแบบระบบสนับสนุนการตัดสินใจสำหรับแพทย์	16
บทที่ 4 ผลการดำเนินโครงการ.....	18
4.1 ชุดข้อมูล BUU-LSPINE.....	18
4.2 ผลลัพธ์ของการประมาณตำแหน่งของกระดูกเชิงกราน	19
4.3 ผลลัพธ์การตรวจจับวัตถุ	21
4.4 ผลลัพธ์ระบบสนับสนุนการตัดสินใจสำหรับแพทย์	23
บทที่ 5 สรุปผลการดำเนินงานวิจัย.....	27
5.1 ข้อสรุปและอภิปรายผล.....	27
5.2 ข้อจำกัดและงานในอนาคต	27
5.3 บทความวิชาการที่ได้รับการตีพิมพ์	27
บรรณานุกรม.....	36
ประวัติผู้วิจัย.....	37

สารบัญภาพ

	หน้าที่
รูปที่ 1 ตำแหน่งของกระดูกเชิงกรานทั้งสองด้าน	6
รูปที่ 2 โมเดลประมาณตำแหน่งกระดูกเชิงกรานด้วยรูปทรงเรขาคณิตวงรี.....	9
รูปที่ 3 การประมาณตำแหน่งของกระดูกเชิงกรานด้วยข้อมูลทางสถิติ (ทางซ้าย).....	11
รูปที่ 4 การประมาณตำแหน่งของกระดูกเชิงกรานด้วยข้อมูลทางสถิติ (ทางขวา)	11
รูปที่ 5 กระบวนการตรวจจับกระดูกเชิงกราน ด้วย ASM.....	13
รูปที่ 6 การปรับตำแหน่งของโมเดล	14
รูปที่ 7 การปรับขนาด (Scaling Transformation) ของโมเดลวงรี (จุดสีแดง คือ landmarks ของโมเดลวงรี, จุดสีน้ำเงิน คือ landmark บนภาพ).....	14
รูปที่ 8 ผลลัพธ์ของการปรับโมเดลให้เข้ากับกระดูกเชิงกรานบนรูป	14
รูปที่ 9 กระบวนการทำงานของระบบสนับสนุนการตัดสินใจสำหรับแพทย์.....	17
รูปที่ 10 ชุดข้อมูล BUU-LSPINE: (ก) AP View, (ข) LA View	18
รูปที่ 11 ผลลัพธ์การประมาณตำแหน่งกระดูกเชิงกรานด้านซ้าย	20
รูปที่ 12 ผลลัพธ์การประมาณตำแหน่งกระดูกเชิงกรานด้านขวา.....	20
รูปที่ 13 ผลลัพธ์การประมาณตำแหน่งกระดูกเชิงกรานทั้งสองด้าน.....	20
รูปที่ 14 ดัชนีแฉกคาร์ตเมื่อเทียบกับโมเดลที่ประมาณค่าตำแหน่งกระดูกเชิงกราน	21
รูปที่ 15 สัญญาณรบกวนที่เกิดจากแสงรังสีขณะทำการถ่ายภาพเอกซเรย์	22
รูปที่ 16 สัญญาณรบกวนที่เกิดจากอุจจาระในลำไส้ บดบังกระดูกเชิงกราน	22
รูปที่ 17 สัญญาณรบกวนที่เกิดจาก Artifacts บนรูปภาพ (รูปไม้บรรทัด อักษรบนรูป ขอบของรูป).....	23
รูปที่ 18 หน้าตาของ Website ที่ออกแบบสำหรับระบบสนับสนุนการตัดสินใจของแพทย์ในการประมาณตำแหน่งของกระดูก เชิงกรานทั้งสองด้าน	23
รูปที่ 19 องค์ประกอบของเว็บไซต์สนับสนุนการตัดสินใจของแพทย์ (1).....	24
รูปที่ 20 องค์ประกอบของเว็บไซต์สนับสนุนการตัดสินใจของแพทย์ (2).....	24
รูปที่ 21 ตัวอย่างผลลัพธ์การประมาณตำแหน่งกระดูกเชิงกรานทั้งสองด้าน (1).....	25
รูปที่ 22 ตัวอย่างผลลัพธ์การประมาณตำแหน่งกระดูกเชิงกรานทั้งสองด้าน (2).....	25
รูปที่ 23 ตัวอย่างผลลัพธ์การประมาณตำแหน่งกระดูกเชิงกรานทั้งสองด้าน (3).....	26
รูปที่ 24 ตัวอย่างผลลัพธ์การประมาณตำแหน่งกระดูกเชิงกรานทั้งสองด้าน (4).....	26
รูปที่ 25 การส่งบทความไปยังวารสาร IEEE Access	28
รูปที่ 26 กำหนดการส่งบทความ	28
รูปที่ 27 อีเมลล์แจ้งสถานะบทความจากทางวารสาร IEEE Access	29
รูปที่ 28 อีเมลล์แจ้งสถานะการตอบรับ (Accepted) บทความ Q1 จากทางวารสาร IEEE Access.....	30

บทที่ 1

บทนำ

1.1 ที่มาและความสำคัญ

การประมาณค่าตำแหน่งกระดูกบนภาพเอกซเรย์เป็นกระบวนการที่มีความสำคัญในวงการการแพทย์ และการแพทย์ศาสตร์ การศึกษาและพัฒนาอย่างรอบคอบเป็นสิ่งจำเป็นในการพัฒนาระบบช่วยในการ วินิจฉัยและติดตามภาพถ่ายของกระดูกในการรักษา¹ โดยการคำนวณตำแหน่งของกระดูกจะช่วยให้การ วิเคราะห์โครงสร้างร่างกายของผู้ป่วย และที่สำคัญคือการระบุการบาดเจ็บหรือข้อมูลทางการแพทย์อื่น ๆ อย่างแม่นยำ

การวิจัยนี้มุ่งเน้นที่การพัฒนาอัลกอริทึมเชิงเรขาคณิต² ที่สามารถใช้ในการระบุตำแหน่งและขนาดของ กระดูกในภาพเอกซเรย์ซึ่งจะเป็นแหล่งข้อมูลที่สองสำหรับแพทย์ที่ช่วยในการตัดสินใจหรือวินิจฉัยโรคโดยมี สถิติและคณิตศาสตร์จากชุดข้อมูลในอดีตรองรับช่วยเพิ่มความแม่นยำและความถูกต้องในการวินิจฉัย การ แก้ไขปัญหานี้จะช่วยให้การลดความผิดพลาดในการวินิจฉัยและการรักษาผู้ป่วย และอาจมีประโยชน์ที่สำคัญ ในอุตสาหกรรมทางการแพทย์ทั่วโลก

การใช้อัลกอริทึมเชิงเรขาคณิตและใช้คณิตศาสตร์ในการคำนวณ จะช่วยลดความซับซ้อนของข้อมูล และเป็นการลดการใช้ทรัพยากร การใช้สถิติจากชุดข้อมูลที่มีอยู่จะช่วยให้อัลกอริทึมที่พัฒนาสามารถสะท้อน พฤติกรรมของข้อมูลจากประชากรจำนวนมากได้ เป็นการเพิ่มความน่าเชื่อถือของผลลัพธ์ของการประมาณค่า ตำแหน่งของกระดูกเชิงกรานและยังเพิ่มประสิทธิภาพในการวินิจฉัยของแพทย์ได้

ที่มาของการระบุตำแหน่งกระดูกเชิงกรานในงานวิจัยนี้จัดทำขึ้นเพื่อเป็นพื้นฐานสำหรับการพัฒนาการ ระบุตำแหน่งกระดูกสันหลังในขั้นตอนถัดไป ทั้งสองส่วนนี้มีความสำคัญอย่างยิ่งต่อโครงสร้างพื้นฐานของ ร่างกายมนุษย์ ในขณะที่งานวิจัยส่วนใหญ่มุ่งเน้นการตรวจจับกระดูกสันหลังโดยตรง งานวิจัยนี้เสนอวิธีการ ใหม่ที่ใช้การประมาณค่าตำแหน่งของกระดูกเชิงกรานเป็นจุดเริ่มต้น และนำตำแหน่งที่ได้มาใช้ในการระบุ ตำแหน่งของกระดูกสันหลังอย่างแม่นยำและเป็นระบบมากขึ้น

1.2 วัตถุประสงค์ของงานวิจัย

1. เพื่อพัฒนาอัลกอริทึมสำหรับการตรวจจับกระดูกเชิงกราน
2. เพื่อจัดทำระบบสนับสนุนการตัดสินใจสำหรับแพทย์

1.3 ขอบเขตของการวิจัย

1. การศึกษานี้มุ่งเน้นไปที่การนำโมเดลทางเรขาคณิต เข้ามาช่วยในการอธิบายและประมาณค่าตำแหน่ง ของกระดูกเชิงกราน
2. ขอบเขตของงานวิจัย คือ การตรวจจับบนภาพเอกซเรย์ชนิดฟิล์มธรรมดา (Plain radiograph) โดย มุมมองจากด้านหน้าไปด้านหลัง (Anteroposterior View) โดยเป็นภาพถ่ายที่ประกอบไปด้วย กระดูกสันหลังชนิดล้มบลาทั้ง 5 ข้อ และกระดูกเชิงกราน

3. พัฒนาระบบที่สามารถแนะนำข้อมูลสำหรับตำแหน่งของกระดูกเชิงกรานได้
4. ระยะเวลาในการดำเนินการ 1 ปี

1.4 วิธีการดำเนินการวิจัย

1. วิธีการวิจัยจะศึกษาวิธีการวิเคราะห์รูปภาพเชิงเรขาคณิตและนำมาปรับใช้ให้เข้ากับภาพเอกซเรย์
2. วิเคราะห์ข้อมูลเชิงสถิติจากชุดข้อมูลภาพเอกซเรย์ของผู้ป่วยที่มีขนาดของชุดข้อมูลใหญ่ เพื่อทำความเข้าใจคุณลักษณะของโครงสร้างกระดูกเชิงกรานของประชากรไทยในภาพรวม
3. ใช้ผลการวิเคราะห์คุณลักษณะของโครงสร้างกระดูกเชิงกรานที่ได้ ในการพัฒนา อัลกอริทึมในการตรวจจับตำแหน่งของกระดูกเชิงกรานบนภาพเอกซเรย์
4. นำอัลกอริทึมในการตรวจจับตำแหน่งที่ได้ไปพัฒนาระบบสนับสนุนการตัดสินใจของแพทย์

1.5 แผนการดำเนินงาน

ตารางแผนงานวิจัย

กิจกรรมหลัก	ระยะเวลา (เดือน)	ผู้รับผิดชอบ
1. การเก็บรวบรวมข้อมูล	1 – 2	คณะผู้วิจัย
2. การศึกษางานวิจัยที่เกี่ยวข้อง	1 – 2	คณะผู้วิจัย
3. การวิเคราะห์ชุดข้อมูลเชิงสถิติของประชากรไทย	2 – 3	คณะผู้วิจัย
4. การพัฒนาอัลกอริทึมสำหรับการตรวจจับกระดูกเชิงกราน	3 – 5	คณะผู้วิจัย
5. การวิเคราะห์ผลลัพธ์ในการตรวจจับเทียบกับวิธีการที่ทันสมัย	2 – 4	คณะผู้วิจัย
6. การประชุมกับผู้เชี่ยวชาญ	5 – 8	คณะผู้วิจัย
7. การจัดทำเอกสาร	9 – 10	คณะผู้วิจัย

1.6 ประโยชน์ที่คาดว่าจะได้รับ

วิธีการตรวจจับตำแหน่งของโครงสร้างกระดูกเชิงกรานซึ่งสามารถนำไปต่อยอดในการระบุองค์ประกอบอื่น ๆ ของร่างกายต่อไปได้ เช่น กระดูกสันหลังหรือซี่โครง ซึ่งยังเป็นวิธีที่ใช้พลังในการประมวลผลต่ำเนื่องจากจำลองโครงสร้างที่ซับซ้อนด้วยโมเดลทางเลขคณิต

บทที่ 2

ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

2.1 การทบทวนวรรณกรรมเกี่ยวกับการระบุตำแหน่งของอวัยวะเชิงกราน

การหาตำแหน่งอวัยวะเชิงกรานในบริบทของการประมวลผลภาพเป็นงานที่สำคัญสำหรับทางวิธีการทางคอมพิวเตอร์ที่จะช่วยพัฒนากระบวนการทางการแพทย์ ซึ่งโดยปกติแล้วจะเป็นภาพเอกซเรย์, การสแกน CT หรือภาพ MRI งานนี้มีความสำคัญสำหรับการวิเคราะห์และการวินิจฉัยในขั้นตอนถัดไป เช่น การตรวจจับภาวะต่างๆ เช่น กระดูกหักหรือกระดูกสันหลังเคลื่อน (spondylolisthesis) รวมทั้งการวางแผนการผ่าตัดและการประเมินการรักษา

การระบุตำแหน่งของวัตถุในภาพแบบดั้งเดิม (Traditional Image Localization) หมายถึง เทคนิคที่ใช้ในวิชาคอมพิวเตอร์วิชั่นเพื่อระบุและหาตำแหน่งของวัตถุภายในภาพ ก่อนยุคของการเรียนรู้เชิงลึก เทคนิคต่างๆ มักเน้นการดึงคุณลักษณะ (feature extraction) และการรู้จำลวดลาย (pattern recognition) โดยมักใช้คุณลักษณะที่ออกแบบเอง (hand-crafted features) และอัลกอริทึมคลาสสิก วิธีการระบุตำแหน่งของวัตถุแบบดั้งเดิมแม้จะมีความอ่อนไหวต่อสัญญาณรบกวน แต่ก็ยังไม่ได้รับความสนใจจากนักวิจัยที่จะเสนอวิธีการปรับปรุงพัฒนาวิธีการโดยมีวิธีการดั้งเดิมเหล่านี้เป็นรากฐาน

1. Edge Detection (Canny Edge Detector, Sobel Operator):

- a. Mishra, Satyam และคณะใช้ Canny Edge Detector เพื่อระบุขอบของวัตถุภายในภาพ ซึ่งเป็นขั้นตอนแรกในการตรวจจับรูปร่างและเค้าร่างของวัตถุ จากนั้นขอบของวัตถุจะได้รับ การวิเคราะห์และประมวลผลผ่านการดำเนินการทางรูปแบบ เช่น การกัดกร่อน (erosion) และการขยาย (dilation) เพื่อเพิ่มความแม่นยำในการตรวจจับวัตถุ เค้าร่างที่ได้จากการประมวลผลจะถูกใช้ในการคำนวณขนาดของวัตถุในเวลาจริง⁴
- b. C. Zhan, X และคณะใช้ Canny Edge Detector เพื่อระบุขอบของสองเฟรมที่ต่อเนื่องกัน ในวิดีโอ ขอบของเฟรมเหล่านี้จะถูกตรวจจับเพื่อวิเคราะห์ความแตกต่างระหว่างกัน โดยการ ใช้ Canny Edge Detector เพื่อจับการเปลี่ยนแปลงในภาพขอบ ซึ่งจะถูกใช้ในการระบุ ตำแหน่งของวัตถุที่เคลื่อนไหว ขั้นตอนการตรวจจับขอบนี้มีความสำคัญในการแยกพื้นที่ที่ เคลื่อนไหวออกจากพื้นที่ที่ไม่เคลื่อนไหว ช่วยเพิ่มความแม่นยำในการตรวจจับการเคลื่อนไหว โดยการเปรียบเทียบการเปลี่ยนแปลงของพิกเซลระหว่างเฟรมต่างๆ⁵
- c. Y. Yuan และคณะใช้ Sobel Operator เพื่อปรับปรุงประสิทธิภาพในการตรวจจับขอบ โดย ผู้เขียนได้เสนอการปรับปรุง Sobel Operator แบบดั้งเดิมโดยการเพิ่มทิศทางของเกรเดียนต์ ซึ่งช่วยในการตรวจจับขอบที่แม่นยำยิ่งขึ้น ผลลัพธ์จาก Sobel ที่ได้รับการปรับปรุงนี้จะถูกใช้ เป็นภาพพื้นฐาน (ground-truth image) ในการฝึกเครือข่ายแบบ HED-like ซึ่งทำการ เรียนรู้และปรับปรุงผลลัพธ์การตรวจจับขอบผ่านการเรียนรู้อย่างต่อเนื่อง ส่งผลให้ได้ภาพ

ขอบที่มีคุณภาพดีกว่า โดยที่อัลกอริทึม ISAHED นี้ช่วยเพิ่มประสิทธิภาพในการตรวจจับขอบ และเป็นการพัฒนาที่สำคัญในการเทคโนโลยีการตรวจจับขอบ⁶

2. Hough Transform:

- a. K. Zhao และคณะใช้ Hough Transform เพื่อปรับปรุงการตรวจจับเส้นโดยการผสมผสานกับการแสดงผลที่เรียนรู้เชิงลึก (deeply learned representations) โดยผู้เขียนใช้การพารามิเตอร์เส้นด้วยความชัน (slopes) และอคติ (biases) แล้วใช้การแปลง Hough เพื่อแปลงการแสดงผลเชิงลึกไปยังโดเมนพารามิเตอร์ ซึ่งช่วยในการตรวจจับเส้นได้อย่างมีประสิทธิภาพ โดยการรวบรวมคุณลักษณะตามเส้นที่เป็นไปได้ในแผนที่คุณลักษณะและแมปคุณลักษณะเหล่านั้นไปยังตำแหน่งที่เกี่ยวข้องในโดเมนพารามิเตอร์ การแปลง Hough ช่วยทำให้ปัญหาการตรวจจับเส้นในโดเมนเชิงพื้นที่ (spatial domain) กลายเป็นการหาจุดในโดเมนพารามิเตอร์ ซึ่งทำให้ขั้นตอนการประมวลผลต่อไป เช่น การกำจัดค่าซ้ำ (non-maximal suppression) มีประสิทธิภาพมากขึ้น นอกจากนี้ วิธีการนี้ยังช่วยในการสกัดคุณลักษณะของเส้นที่มีบริบท ซึ่งเป็นสิ่งสำคัญสำหรับการตรวจจับเส้นที่แม่นยำ⁷

3. Template Matching

- a. Biao Hou และคณะใช้การจับคู่เทมเพลต (template matching) เพื่อปรับปรุงความแม่นยำในการตรวจจับวัตถุ โดยการใชเทมเพลตเฉพาะสำหรับแต่ละประเภท (class-specific spatial templates) ซึ่งสร้างขึ้นจากสถิติของวัตถุในแต่ละประเภท และใช้ในระหว่างการทดสอบเพื่อให้เทมเพลตที่เชื่อถือได้ในการจับคู่กับวัตถุ เมื่อเครือข่าย RefinedNet ประมวลผลผลลัพธ์ที่ทำนายจาก SSD เทมเพลตเฉพาะประเภทจะช่วยเพิ่มความมั่นใจในวัตถุที่เป็นไปได้และลดการทำนายที่ผิดพลาดจากพื้นหลัง นอกจากนี้ เทมเพลตเหล่านี้ยังช่วยกรองผู้สมัครที่ไม่เกี่ยวข้องออกไป ลดอัตราการเตือนผิด (false alarm) ซึ่งการใช้การจับคู่เทมเพลตนี้ช่วยเพิ่มความแม่นยำในการตรวจจับวัตถุและยังรักษาความเร็วในการตรวจจับได้⁸
- b. Kiru Park และคณะใช้การจับคู่เทมเพลต (template matching) เพื่อการประเมินท่าทาง (pose estimation) ของวัตถุที่ถูกบัง (occluded objects) จากภาพความลึก (depth images) เฟรมเวิร์กที่เสนอชื่อว่า Multi-Task Template Matching (MTTM) ใช้การจับคู่เทมเพลตเพื่อหาวัตถุที่ตรงที่สุดจากภาพความลึก พร้อมทั้งทำนายหน้ากากการแบ่งส่วน (segmentation masks) และการแปลงท่าทางระหว่างเทมเพลตและวัตถุที่ตรวจจับในฉาก โดยใช้แผนที่คุณลักษณะของพื้นที่ของวัตถุ การเปรียบเทียบคุณลักษณะระหว่างเทมเพลตและคุณลักษณะที่ตัดมาจากฉากช่วยให้ผลลัพธ์การแบ่งส่วนเพิ่มความแข็งแกร่งในการประเมินท่าทางโดยการขจัดจุดที่ไม่เกี่ยวข้องกับวัตถุ ผลการทดลองแสดงให้เห็นว่า MTTM ช่วยให้ผลลัพธ์ในการแบ่งส่วนและการประเมินท่าทางของวัตถุที่ถูกบังดีกว่าวิธีพื้นฐานถึงแม้จะใช้แค่ภาพความลึก⁹

4. Active Shape Model

- a. Daniela O. Medley และคณะใช้ Active Shape Model (ASM) เพื่อปรับปรุงการรับรู้และการหาตำแหน่งของวัตถุโดยการรวมความรู้เกี่ยวกับรูปร่างและลักษณะของวัตถุเข้าไปในโมเดล โดยใช้ ASM ในการทำสองงานหลัก: (1) การเปรียบเทียบประสิทธิภาพของคุณลักษณะต่างๆ เพื่อสกัด features จากภาพและ (2) การปรับปรุงประสิทธิภาพของการปรับขนาดของโมเดล (model fitting) โดยการใช้ framework ทางความน่าจะเป็นที่ทนทานต่อข้อมูลที่ผิดปกติ (outliers) โดยใช้ Generalized Expectation-Maximization ในการจัดการกับข้อมูลที่ผิดปกติและปรับปรุงกระบวนการพอดี้ของโมเดล การผสมผสาน ASM กับคุณลักษณะจากการเรียนรู้เชิงลึก (DL) ทำให้ได้ผลลัพธ์ที่มีประสิทธิภาพเทียบเท่ากับวิธีการ DL ที่ทันสมัย เช่น FCN, U-Net และ CNN Cascade ได้¹⁰
- b. Yea-Shuan Huang และคณะใช้ Active Shape Model (ASM) ในการปรับตำแหน่งของจุดสังเกตใบหน้า (facial landmarks) โดยมีสองขั้นตอนหลัก ในขั้นตอนแรกจะใช้ Adaboosting-based algorithm เพื่อค้นหาจุดสังเกตที่สำคัญ เช่น มุมตา คิ้ว และปาก จากนั้นนำมาใช้สร้าง global ASM เพื่อปรับตำแหน่งให้แม่นยำขึ้น ส่วนในขั้นตอนที่สอง ผลการตรวจจับจากขั้นตอนแรกจะเป็นตำแหน่งเริ่มต้นในการปรับปรุงจุดสังเกตอีกครั้งด้วย ASM เพื่อเพิ่มความแม่นยำ โดยวิธีนี้ช่วยให้การตรวจจับจุดสังเกตใบหน้าที่มีประสิทธิภาพและแม่นยำ แม้ในกรณีที่มีการแสดงออกทางสีหน้าแบบเกินจริง เช่น ความตกใจ การหัวเราะ หรือการขมวดคิ้ว ซึ่งสามารถทำให้ ASM แบบดั้งเดิมไม่สามารถทำงานได้ดีเท่าที่ควร¹¹
- c. Kim, Daehee และคณะใช้โมเดลรูปร่างแอคทีฟ (Active Shape Model, ASM) เป็นส่วนหนึ่งของ อัลกอริทึมการติดตาม เพื่อเสริมความสามารถในการตรวจจับและติดตามวัตถุในภาพวิดีโอการเฝ้าระวังในที่แสงน้อย โดย ASM ถูกใช้ในขั้นตอนที่สามของระบบที่นำเสนอ ซึ่งเป็นขั้นตอนหลังจากการใช้ อัลกอริทึมการพิกัดแบบพีระมิด และการสร้างภาพพาโนรามา โดย ASM ช่วยในการติดตามวัตถุโดยการใช้ข้อมูลรูปร่าง ซึ่งช่วยให้การติดตามมีความเสถียรแม้ในสภาพแวดล้อมที่มีขอบเขตที่ไม่ชัดเจนและมีเสียงรบกวนสูง ซึ่งเป็นลักษณะทั่วไปในภาพที่แสงน้อย งานวิจัยนี้แสดงให้เห็นว่า วิธีการติดตามที่ใช้ ASM ช่วยเพิ่มประสิทธิภาพในการดึงข้อมูลและติดตามวัตถุในภาพพาโนรามาได้ในเวลาจริง¹²

วิธีการดั้งเดิมเหล่านี้มักต้องปรับแต่งพารามิเตอร์ด้วยมือ และไม่สามารถรับมือกับข้อมูลที่ซับซ้อนหรือเปลี่ยนแปลงจากโลกจริงได้ดีเท่ากับวิธีที่ใช้การเรียนรู้เชิงลึกในปัจจุบัน ในขณะที่วิธีการสมัยใหม่ในการระบุตำแหน่งของวัตถุในภาพ (Modern Object Localization Methods) ใช้เทคนิคที่พัฒนาจากการเรียนรู้เชิงลึก (Deep Learning) ซึ่งสามารถประมวลผลข้อมูลที่ซับซ้อนได้ดีกว่าและมีความยืดหยุ่นสูงในการจัดการกับข้อมูลที่มีความหลากหลายและเปลี่ยนแปลง

ทั้งวิธีดั้งเดิมและสมัยใหม่มีข้อดีข้อเสียต่างกัน วิธีดั้งเดิมใช้ทรัพยากรต่ำและเข้าใจผลลัพธ์ง่าย แต่ไม่ทนทานต่อความหลากหลายของข้อมูล ส่วนวิธีสมัยใหม่ต้องการทรัพยากรสูงและข้อมูลมาก แต่ให้ผลลัพธ์แม่นยำและทนทานต่อความซับซ้อนของภาพ


จากการทบทวนวรรณกรรมพบว่า หากวัตถุที่ต้องการตรวจจับมีลักษณะที่ไม่ซับซ้อน วิธีการดั้งเดิมที่มีการใช้พลังงานในการประมวลผลต่ำสามารถนำมาใช้ได้อย่างมีประสิทธิภาพ แต่หากเป็นวัตถุที่มีลักษณะซับซ้อน การใช้วิธีสมัยใหม่จะช่วยให้ได้ผลลัพธ์ในการตรวจจับที่มีความแม่นยำมากยิ่งขึ้น แม้ว่าจะต้องใช้ทรัพยากรในการคำนวณที่สูงขึ้นก็ตาม

2.2 ความสำคัญของกระดูกเชิงกรานในทางการแพทย์

กระดูกเชิงกราน (Pelvis) ดังที่แสดงในรูปที่ 1 เป็นส่วนที่มีโครงสร้างทางกายวิภาคที่ซับซ้อนและสำคัญสำหรับการรองรับน้ำหนักและเป็นจุดเชื่อมต่อระหว่างกระดูกสันหลังกับขา โครงสร้างนี้ประกอบด้วยกระดูกหลายชิ้นที่รวมกัน ได้แก่ กระดูกสะโพก (hip bone), กระดูกกระเบนเหน็บ (sacrum) และกระดูกก้นกบ (coccyx) ซึ่งมีบทบาทสำคัญในการเคลื่อนไหวและความมั่นคงของร่างกาย¹³

โครงสร้างของกระดูกเชิงกรานและกระดูกสันหลังส่วนล่างมีความเกี่ยวข้องอย่างใกล้ชิด เนื่องจากกระดูกเชิงกรานทำหน้าที่รองรับกระดูกสันหลังและเชื่อมต่อไปยังกระดูกขา ทำให้สามารถรองรับน้ำหนักของร่างกายได้อย่างมีประสิทธิภาพและช่วยในการเคลื่อนไหวโดยไม่เกิดการบาดเจ็บ ในกระดูกสันหลังส่วนล่างหรือกระดูกสันหลังเอว (lumbar spine) จะมีกระดูกสันหลังส่วนที่ 4 และ 5 (L4-L5) ซึ่งเชื่อมต่อโดยตรงกับกระดูกเชิงกรานผ่านข้อต่อ sacroiliac (SI) ที่เชื่อมกระดูกสันหลังกับกระดูกเชิงกรานบริเวณกระดูกกระเบนเหน็บ (sacrum) ซึ่งเป็นฐานที่รองรับกระดูกสันหลังส่วนล่างทั้งหมด

ในทางการแพทย์ ข้อต่อ SI ที่เชื่อมระหว่างกระดูกสันหลังส่วนล่างและกระดูกเชิงกรานมีความสำคัญต่อการควบคุมการเคลื่อนไหวและการรับน้ำหนักในส่วนล่างของร่างกาย หากข้อต่อหรือโครงสร้างเหล่านี้เกิดความผิดปกติ เช่น กระดูกเชิงกรานบิดเบี้ยวหรือกระดูกสันหลังเอวเคลื่อน จะส่งผลต่อการเคลื่อนไหวและอาจทำให้เกิดความเจ็บปวดเรื้อรัง โดยเฉพาะในบริเวณหลังส่วนล่าง ดังนั้น การวิเคราะห์โครงสร้างและการเชื่อมต่อระหว่างกระดูกเชิงกรานและกระดูกสันหลังเอวจึงเป็นขั้นตอนสำคัญในการประเมินภาวะความผิดปกติที่เกี่ยวข้องกับการเคลื่อนไหว



รูปที่ 1 ตำแหน่งของกระดูกเชิงกรานทั้งสองด้าน

2.3 Active Shape Model (ASM)

Active Shape Model (ASM)¹⁴ เป็นเทคนิคที่ใช้ในการวิเคราะห์รูปร่าง (shape analysis) ในการประมวลผลภาพทางการแพทย์ โดยเฉพาะในงานที่ต้องการตรวจจับโครงสร้างเฉพาะ เช่น กระดูกในภาพเอกซเรย์ ใบหน้า หรืออวัยวะภายใน ASM ถูกพัฒนาขึ้นเพื่อให้สามารถระบุทรงของวัตถุที่มีความแปรผันทางรูปร่างและตำแหน่งได้อย่างยืดหยุ่นเหมาะกับการใช้ภาพถ่ายทางการแพทย์ของแต่ละคนที่มีโครงสร้างไม่เหมือนกัน แต่มีรูปร่างหลัก ๆ คล้ายกัน

ASM ทำงานโดยการสร้างแบบจำลองเชิงสถิติของรูปร่างซึ่งถูกฝึกฝนจากชุดข้อมูลตัวอย่างที่ประกอบด้วยตำแหน่งของจุดสังเกต (landmarks) บนวัตถุที่ศึกษา จากนั้นแบบจำลองจะสามารถปรับเปลี่ยนรูปร่างของตนเองได้เพื่อตรวจจับวัตถุในภาพใหม่ โดยจะพยายามหาตำแหน่งของจุดสังเกตที่ดีที่สุดที่ทำให้รูปร่างสอดคล้องกับวัตถุในภาพ ASM มีขั้นตอนหลักดังนี้:

1. การแทนรูปร่าง (Shape Representation)

รูปร่างจะถูกแทนด้วยชุดของ landmark ดังสมการที่ (6) $x = (x_1, x_2, \dots, x_n)$ ซึ่งแต่ละ x_i เป็นพิกัด 2 หรือ 3 มิติ landmark ต่าง ๆ บนวัตถุ

$$x = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix} \quad (6)$$

2. รูปร่างค่าเฉลี่ย (Mean Shape)

จากการแทนรูปร่างเป็นเมตริกทางคณิตศาสตร์ในข้อที่ 1 เราจะสามารถสร้างรูปร่างค่าเฉลี่ยจากการคำนวณจากการรูปร่างที่มีทั้งหมดในชุดข้อมูลสำหรับฝึกหัด โดยการหาค่าเฉลี่ยของจุด landmarks ที่ตรงกันในชุดข้อมูลดังสมการที่ (7)

$$\bar{x} = \frac{1}{M} \sum_{i=1}^M x_i \quad (7)$$

โดยที่ M คือจำนวนรูปร่างในการฝึก

จุด landmarks ถูกกำหนดในแต่ละภาพตัวอย่างเพื่อล้อมรอบวัตถุที่ต้องการศึกษา โดยตำแหน่งของจุดเหล่านี้จะแสดงถึงลักษณะเฉพาะของรูปร่าง ซึ่งอาจเป็นมุมหรือจุดที่มีการเปลี่ยนแปลงของโครงสร้าง เช่น ขอบของกระดูกสันหลัง จุดสังเกตเหล่านี้เป็นพื้นฐานในการสร้างแบบจำลองเชิงสถิติของรูปร่าง

3. Principle Component Analysis (PCA)

ในโมเดล Active Shape Models (ASM) การวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis หรือ PCA) เป็นเทคนิคหลักที่ใช้สำหรับการสร้างแบบจำลองและอธิบายความแปรผันของรูปร่างในชุดข้อมูลแต่ละรูปร่าง โดย PCA ช่วยให้ ASM สามารถแทนความหลากหลายของรูปร่างที่ซับซ้อนได้อย่างกระชับและมีประสิทธิภาพ เนื่องจากหากรูปร่างค่าเฉลี่ยมีหลาย landmark อาจส่งผลให้มิติของข้อมูลเยอะไปด้วย PCA จะช่วยในการหาทิศทางที่ข้อมูลมีการเปลี่ยนแปลงมากที่สุดนำมาเป็นแกนหลักในการปรับรูปร่าง ซึ่งจะช่วยในการลดมิติของข้อมูลได้

4. การเปลี่ยนแปลงรูปร่าง (Shape Variation)

หลังจากที่ได้รูปร่างค่าเฉลี่ยจากข้อที่สองแล้ว รูปร่างที่ได้มาอาจไม่ fit พอดีกับรูปร่างที่ใด ๆ ได้ ดังนั้นตัวโมเดลจะมีความความยืดหยุ่นสามารถปรับจุด landmark ให้ออกจากรูปร่างค่าเฉลี่ยได้ด้วยค่าเบี่ยงเบนมาตรฐานของรูปร่างใด ๆ กับรูปร่างค่าเฉลี่ยดังที่แสดงในสมการที่ (8)

$$\Delta x_i = x_i - \bar{x} \quad (8)$$

โดยที่

- x_i คือ รูปร่างที่ i
- $\bar{x}$ คือ รูปร่างค่าเฉลี่ย

แบบจำลองจะสามารถแสดงการเปลี่ยนแปลงของรูปร่างออกจากรูปร่างค่าเฉลี่ยได้ภายในขอบเขตที่กำหนดจากข้อมูลชุดข้อมูลที่ใช้ในการสร้างโมเดล

5. การจับคู่รูปร่างกับภาพใหม่ (Shape Matching to New Image)

เมื่อ ASM ถูกนำไปใช้ในภาพใหม่ แบบจำลองจะถูกปรับให้เข้ากับรูปร่างของวัตถุในภาพโดยพยายามจับคู่กับจุด landmarks ตามที่ถูกฝึกมา ขั้นตอนนี้จะอาศัยการปรับตำแหน่งของจุด landmarks ให้สอดคล้องกับขอบเขตและรายละเอียดของรูปร่างในภาพใหม่ และปรับรูปร่างของแบบจำลองตามค่าเฉลี่ยและค่าความแปรผันที่ถูกกำหนดไว้ในขั้นตอนการฝึก


2.4 การใช้แบบจำลองรูปร่างวงรีในการตรวจจับกระดูกเชิงกราน

ลักษณะของกระดูกเชิงกรานที่ปรากฏในภาพเอกซเรย์จะมีแนวของเส้นโครงเป็นองค์ประกอบของวงรีอย่าง que แสดงในรูปที่ 2 ในการศึกษาครั้งนี้เราจึงสร้างรูปร่างค่าเฉลี่ยเป็นโมเดลวงรี เป็นการแทนที่ตำแหน่งของการตรวจเชิงกราน ทั้งชายและขาได้ โดยสมการของวงรีอย่าง que แสดงในสมการที่ (9) แทนรูปร่างค่าเฉลี่ยของกระดูกเชิงกราน

$$\frac{(x - h)^2}{a^2} + \frac{(y - h)^2}{b^2} = 1 \quad (9)$$

โดยที่

- (h, k) คือ จุดศูนย์กลางของวงกลม
- a คือ กึ่งแกนหลัก (ครึ่งหนึ่งของความยาวเส้นผ่านศูนย์กลางของแกนหลัก)
- b คือ กึ่งแกนรอง (ครึ่งหนึ่งของความยาวเส้นผ่านศูนย์กลางของแกนรอง)
- $a \geq b > 0$ คือ a มีค่ามากกว่าหรือเท่ากับ b และทั้งคู่ต้องมีค่ามากกว่า 0



รูปที่ 2 โมเดลประมาณตำแหน่งกระดูกเชิงกรานด้วยรูปทรงเรขาคณิตวงรี

ด้วยวิธีการแทนที่โมเดลด้วยสมการวงรีจะทำให้เราสามารถลดความซับซ้อนของรูปร่างค่าเฉลี่ยได้

2.5 การเปลี่ยนรูป Affine Transformation

Affine Transformation เป็นเทคนิคในการเปลี่ยนรูปแบบของข้อมูลภาพที่ใช้ในการประมวลผลภาพและการวิเคราะห์เชิงภาพ เทคนิคนี้ช่วยในการปรับเปลี่ยนขนาด การหมุน การย้าย และการบิดเบือนของภาพ โดยการรักษาสัดส่วนของรูปทรงและความสัมพันธ์ระหว่างจุดในภาพ การเปลี่ยนรูป Affine Transformation จะถูกกำหนดโดยการใช้แมทริกซ์การแปลง (transformation matrix) ซึ่งรวมถึงการแปล (translation), การขยายหรือหด (scaling), การหมุน (rotation), และการบิดเบือน (shearing)³ Affine Transformation สามารถเขียนในรูปของสมการ (10):

$$\begin{bmatrix} x' \\ y' \\ 1 \end{bmatrix} = \begin{bmatrix} a & b & tx \\ c & d & ty \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x \\ y \\ 1 \end{bmatrix} \quad (10)$$

โดยที่ (x, y) เป็นพิกัดจุดในภาพต้นฉบับ และ (x', y') เป็นพิกัดของจุดหลังการแปลง a, b, c, d

เป็นค่าของแมทริกซ์การแปลง และ tx, ty คือค่าการแปลในทิศทาง x และ y ตามลำดับ

Affine Transformation มีการปรับเปลี่ยนภาพที่สำคัญอยู่ 4 ชนิด ดังต่อไปนี้:

1. **การปรับขนาด (Scaling):** การปรับขนาดจะทำให้โมเดลวงรีมีความยืดหยุ่น โดยสามารถปรับขนาดได้ตามแกน x หรือแกน y ตามความต้องการ
2. **การหมุน (Rotation):** การหมุนจะทำให้สามารถปรับโมเดลวงรี ให้เรียงตัวหมุนไปตามองศาที่เหมาะสมกับมุมของกระดูกเชิงกรานได้
3. **การแปล (Translation):** การกำหนดจุดศูนย์กลางของโมเดลวงรีมีความสำคัญอย่างมาก แม้ข้อมูลค่าเฉลี่ยจะทำให้กับหนดจุดศูนย์กลางเริ่มต้นได้ใกล้เคียงแล้วก็ตาม การจะปรับให้ตรงกับตำแหน่งของกระดูกเชิงกรานสามารถทำได้โดยการใช้การแปลตำแหน่งของโมเดลได้


การปรับขนาดของรูปร่างด้วยการใช้ Affine Transformation จะถูกนำเข้ามาใช้เพื่อปรับขนาดของโมเดลเพื่อให้มีลักษณะสอดคล้องกับวัตถุที่ต้องการตรวจจับ ซึ่งในที่นี้คือ กระดูกเชิงกราน

บทที่ 3


รายละเอียดผลการดำเนินงาน

3.1 การประมาณตำแหน่งกระดูกเชิงกรานเริ่มต้นด้วยข้อมูลทางสถิติจากชุดข้อมูล

ตำแหน่งเริ่มต้นในการหาตำแหน่งของกระดูกเชิงกรานสามารถทำได้โดยการขีดเส้นรอบกระดูกเชิงกรานในภาพเอกซเรย์ เพื่อประเมินตำแหน่งคร่าว ๆ ของกระดูกในแต่ละภาพ ก่อนที่จะรวบรวมข้อมูลตำแหน่งกระดูกเชิงกรานจากชุดข้อมูลทั้งหมด เพื่อนำมาสร้างเป็น probability map ซึ่งแสดงความน่าจะเป็นของตำแหน่งกระดูกเชิงกรานเริ่มต้น หลังจากนั้น เมื่อได้ตำแหน่งคร่าว ๆ จาก probability map นี้ ระบบจะสามารถนำไปใช้ในการปรับตำแหน่งให้แม่นยำยิ่งขึ้นในขั้นตอนถัดไป ดังที่แสดงในรูปที่ 3 และ รูปที่ 4



รูปที่ 3 การประมาณตำแหน่งของกระดูกเชิงกรานด้วยข้อมูลทางสถิติ (ทางซ้าย)



รูปที่ 4 การประมาณตำแหน่งของกระดูกเชิงกรานด้วยข้อมูลทางสถิติ (ทางขวา)

วิธีการที่เรานำเสนอใช้การประมาณตำแหน่งจุดศูนย์กลางและขนาดความยาวของแกนหลักและแกนรองของโมเดลวงรีจากข้อมูลทางสถิติแบบอัตโนมัติ ทำให้สามารถประมาณรูปร่างค่าเฉลี่ยวงรีคร่าว ๆ ได้ แต่เพื่อให้โมเดลวงรีมีความ fit เข้ากับกระดูกเชิงกรานใด ๆ เรายังเสนอวิธีการใช้ Affine transformation เพื่อปรับรูปร่างโดยใช้หลักการปรับโมเดลของ ASM เข้ามาผนวกต่อไป


3.2 การประมาณตำแหน่งกระดูกเชิงกรานด้วย Active Shape Model

ขั้นตอนเริ่มต้นของกระบวนการนี้คือการนำเข้าภาพเอกซเรย์ของผู้ป่วยดังที่แสดงในรูปที่ 5 ซึ่งเป็นภาพที่มีข้อมูลที่ต้องการสำหรับการวิเคราะห์ตำแหน่งของกระดูกเชิงกราน จากนั้นระบบจะใช้ข้อมูลทางสถิติ เช่น โครงสร้างมาตรฐานหรือข้อมูลเฉลี่ยจากกลุ่มตัวอย่างที่เกี่ยวข้อง เพื่อประมาณตำแหน่งเริ่มต้นของกระดูกเชิงกรานในภาพ ขั้นตอนนี้ช่วยให้การคำนวณในขั้นต่อไปมีความรวดเร็วและมีประสิทธิภาพมากขึ้น โดยที่จุดเริ่มต้นจะมีความใกล้เคียงกับตำแหน่งจริงมากที่สุด

เมื่อได้ตำแหน่งเริ่มต้นที่คาดคะเนไว้ ระบบจะใช้อัลกอริทึม ASM เข้ามาช่วยในกระบวนการปรับตำแหน่งให้แม่นยำขึ้น ASM เป็นอัลกอริทึมที่สามารถตรวจจับรูปร่างและขอบเขตของวัตถุในภาพได้อย่างแม่นยำ โดยพยายามปรับจุดตำแหน่งให้ตรงกับขอบเขตของกระดูกเชิงกรานจริงในภาพเอกซเรย์ ซึ่งช่วยให้ระบบสามารถระบุตำแหน่งของกระดูกเชิงกรานได้อย่างถูกต้องแม่นยำ

สุดท้าย เมื่อกระบวนการปรับตำแหน่งเสร็จสิ้น ระบบจะได้ตำแหน่งที่แม่นยำของกระดูกเชิงกราน ซึ่งตำแหน่งนี้สามารถนำไปใช้ในการวิเคราะห์หรือวินิจฉัยต่อไป ขั้นตอนนี้สิ้นสุดลงเมื่อได้ตำแหน่งที่ต้องการแล้ว ทำให้ระบบพร้อมสำหรับกระบวนการในขั้นถัดไปตามที่ผู้ใช้ต้องการ

1. นำเข้าภาพเอกซเรย์: ขั้นตอนแรกเริ่มจากการนำเข้าภาพเอกซเรย์ของผู้ป่วย เพื่อให้ระบบสามารถประมวลผลข้อมูลภาพนี้
2. ประมาณตำแหน่งกระดูกเชิงกรานเริ่มต้นจากข้อมูลสถิติ: ระบบจะใช้ข้อมูลทางสถิติ เช่น ข้อมูลโครงสร้างร่างกายมาตรฐาน ในการคาดคะเนตำแหน่งเริ่มต้นของกระดูกเชิงกราน
3. ใช้ ASM ปรับตำแหน่งให้ตรงกับกระดูกเชิงกราน: อัลกอริทึม Active Shape Model (ASM) จะถูกนำมาใช้เพื่อปรับจุดตำแหน่งให้แม่นยำ ตรงกับขอบเขตของกระดูกเชิงกรานในภาพ
4. ได้ตำแหน่งกระดูกเชิงกรานที่แม่นยำ: หลังจากผ่านการปรับโดย ASM ระบบจะได้ตำแหน่งที่แน่นอนของกระดูกเชิงกราน ซึ่งสามารถนำไปใช้งานต่อไปในด้านการวิเคราะห์หรือวินิจฉัย
5. สิ้นสุด: กระบวนการสิ้นสุดลงเมื่อได้ตำแหน่งกระดูกเชิงกรานที่แม่นยำ




รูปที่ 5 กระบวนการตรวจจับกระดูกเชิงกราน ด้วย ASM

3.3 การปรับโมเดลหาตำแหน่งกระดูกสันหลังด้วย Affine Transformations


หลังจากที่ได้ตำแหน่งเบื้องต้นจากข้อมูลทางสถิติ จะเห็นว่าทั้งตำแหน่งและขนาดของโมเดลยังไม่ตรงกับตำแหน่งจริงของกระดูกเชิงกรานในภาพเอกซเรย์ ดังที่แสดงในรูปที่ 6 และรูปที่ 7 ดังนั้น จึงจำเป็นต้องใช้ ASM และ Affine Transformation เพื่อปรับโมเดลให้สอดคล้องกับภาพนั้น ๆ

Translation Adjust เป็นขั้นตอนที่สำคัญในการปรับตำแหน่งของโมเดลให้ตรงกับรูปภาพที่ต้องการวิเคราะห์ด้วยการตรวจสอบบริเวณขอบของวัตถุโดยรอบว่าตรงไหนที่มีขอบชัดเจนและโมเดลจะเลื่อนตำแหน่งให้ตรงกับขอบนั้น โดยเฉพาะในบริบทของการตรวจจับรูปร่างหรือโครงสร้าง เช่น กระดูกเชิงกรานในภาพเอกซเรย์ การปรับตำแหน่งด้วยการแปล (translation) ช่วยให้เรามั่นใจได้ว่าโมเดลที่สร้างขึ้นสามารถตั้งอยู่ในตำแหน่งที่ถูกต้องบนภาพได้อย่างแม่นยำ




รูปที่ 6 การปรับตำแหน่งของโมเดล

Scaling Adjust เป็นกระบวนการที่สำคัญในการปรับขนาดของโมเดลให้เข้ากับรูปร่างที่ต้องการวิเคราะห์ด้วยการประเมินจากขอบของวัตถุว่า ใหญ่กว่า หรือเล็กกว่าขนาดของโมเดลปัจจุบันก่อนจะปรับขนาดของโมเดลให้เหมาะสมกับขอบของวัตถุ โดยเฉพาะในบริบทของการตรวจจับและวิเคราะห์โครงสร้างทางกายภาพ เช่น กระดูกเชิงกรานในภาพเอกซเรย์ การปรับขนาดช่วยให้โมเดลสามารถแสดงรูปร่างที่ถูกต้องและเหมาะสมกับขนาดจริงในภาพได้




รูปที่ 7 การปรับขนาด (Scaling Transformation) ของโมเดลวงรี (จุดสีแดง คือ landmarks ของโมเดลวงรี, จุดสีน้ำเงิน คือ landmark บนภาพ)



รูปที่ 8 ผลลัพธ์ของการปรับโมเดลให้เข้ากับกระดูกเชิงกรานบนรูป

3.4 วิธีการประเมินผล / สังเคราะห์ข้อมูล

งานวิจัยนี้มีจุดมุ่งหมายในการประเมินความแม่นยำของการตรวจจับตำแหน่งกระดูกเชิงกรานจากภาพเอกซเรย์ โดยใช้อัลกอริทึมที่พัฒนาขึ้นเฉพาะ และเปรียบเทียบผลลัพธ์ที่ได้กับผลเฉลยในชุดข้อมูลมาตรฐาน เพื่อประเมินความเหมือนของภาพไบนารีที่อธิบายตำแหน่งกระดูกเชิงกรานอย่างแม่นยำ งานวิจัยจะใช้ดัชนีแจคการ์ด (Jaccard Index)³ ซึ่งคำนวณจากสมการที่ (1):



$$\text{Jaccard index } j(A, B) = \frac{A \cap B}{A \cup B} \quad (1)$$

โดยที่ A และ B แทนตำแหน่งกระดูกเชิงกรานที่ได้จากการตรวจจับและจากผลเฉลยตามลำดับ ดัชนีแจคการ์ดจะช่วยให้สามารถวัดความแม่นยำของตำแหน่งกระดูกที่ตรวจจับได้เทียบกับผลเฉลยได้อย่างมีประสิทธิภาพ

ในการประเมินประสิทธิภาพของอัลกอริทึมเพิ่มเติม จะใช้คอนฟิวชันเมทริกซ์ (Confusion Matrix) ซึ่งช่วยให้สามารถวิเคราะห์ค่าต่าง ๆ เช่น ความแม่นยำ (Accuracy), ความถูกต้อง (Precision), ความอ่อนไหว (Sensitivity) และความจำเพาะ (Specificity) ของอัลกอริทึมที่ใช้ในการตรวจจับ

ตารางที่ 1 คอนฟิวชันเมทริกซ์

	Positive	Negative
Predicted Positive	TP: True Positives	FP: False Negatives
Predicted Negative	FN: False Negatives	TN: True Negatives

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (2)$$

$$Precision = \frac{TP}{TP + FP} \quad (3)$$

$$Sensitivity = \frac{TP}{TP + FN} \quad (4)$$

$$Specificity = \frac{TN}{TN + FP} \quad (5)$$

Accuracy คือสัดส่วนของการทำนายที่ถูกต้องทั้งหมดเมื่อเทียบกับจำนวนตัวอย่างในชุดข้อมูลทั้งหมด แสดงในสมการที่ (1), Precision แสดงถึงความแม่นยำของการทำนายผลบวกว่ามีความถูกต้องเพียงใดแสดงในสมการที่ (2), Sensitivity หรือ Recall บ่งบอกว่าโมเดลสามารถทำนายตัวอย่างที่เป็นบวกจริงได้ครบถ้วนแค่ไหนแสดงในสมการที่ (3) และ Specificity คือความสามารถของโมเดลในการทำนายผลลบได้ถูกต้อง โดยทั้งสี่ตัวชี้วัดนี้ช่วยประเมินความสามารถของโมเดลในมิติต่าง ๆ ตามลักษณะของปัญหาการจำแนกประเภทแสดงในสมการที่ (4) จากการใช้วิธีการวัดที่กล่าวมาจะสามารถประเมินผลลัพธ์ของอัลกอริทึม ที่พัฒนาเทียบกับวิธีการที่ทันสมัยในปัจจุบัน (State of the art) ได้

3.5 การออกแบบระบบสนับสนุนการตัดสินใจสำหรับแพทย์

ระบบการตัดสินใจของแพทย์ที่ออกแบบมีขั้นตอนการทำงานดังที่แสดงในรูปที่ 9 โดยแบ่งออกเป็น 5 ขั้นตอน

1. เริ่มต้นการทำงานจากหน้าเว็บไซต์ให้ user upload รูปภาพเอกซเรย์ชนิด L-Spine ที่มีส่วนประกอบของกระดูกเชิงกรานอยู่ด้วย
2. ระบบจะส่งภาพเข้าไปยังระบบ backend ที่สร้างด้วยการใช้ python ภาพที่รับมาจะถูกประเมินตำแหน่งของกระดูกเชิงกรานด้วยโมเดลวงรี
3. หลังจากได้โมเดลวงรีแล้วระบบจะปรับปรุงขนาดและตำแหน่งของโมเดลวงรีด้วย ASM และ Affine transformations ให้เข้ากับขอบของกระดูกเชิงกรานของรูปที่ได้ upload มา
4. ต่อมาระบบจะ fine-tune ขอบของโมเดลให้เข้ากับขอบของกระดูกเชิงกรานด้วยการประมาณค่าด้วย Polynomial
5. สุดท้ายระบบจะส่ง ตำแหน่ง และ รูปภาพผลลัพธ์ที่ได้ไปยังเว็บไซต์เป็นการตรวจจับแบบอัตโนมัติ



รูปที่ 9 กระบวนการทำงานของระบบสนับสนุนการตัดสินใจสำหรับแพทย์

บทที่ 4

ผลการดำเนินโครงการ


4.1 ชุดข้อมูล BUU-LSPINE

ชุดข้อมูลที่ใช้ในโครงการวิจัยนี้มีชื่อว่า “BUU-LSPINE”¹⁵ เป็นภาพ X-ray ชนิด CT Scan บริเวณกระดูกสันหลังส่วนล่าง (Lumbar Spine) ซึ่งประกอบด้วยมุมมองด้านหน้า (AP) และด้านข้าง (LA) ดังที่แสดงในรูปที่ 10 ซึ่งถูกตีพิมพ์ชื่อ “BUU-LSPINE: A Thai Open Lumbar Spine Dataset for Spondylolisthesis Detection” แสดงถึงผลงานวิจัยก่อนหน้านี้ของเรา ชุดข้อมูลนี้ประกอบด้วยภาพถ่ายรังสีของกระดูกสันหลังส่วนล่างจากผู้ป่วยจำนวน 5,308 ราย โดยได้รับการระบุข้อมูลสำคัญโดยแพทย์เป็นประเภทหลัก 3 ประเภท ได้แก่ พิกัดของกระดูกสันหลัง การเกิดโรคกระดูกสันหลังเคลื่อน (Spondylolisthesis) และกระดูกสันหลังที่มีข้อต่อกับกระดูกเชิงกราน (LSTV) ตามรายละเอียดในตารางที่ 1 และตารางที่ 2 สำหรับข้อมูลเพิ่มเติมและการเข้าถึงชุดข้อมูลนี้ สามารถศึกษาได้จากเอกสารที่เราเผยแพร่¹⁵

จากชุดข้อมูล BUU-LSPINE ที่มีภาพด้านหน้า 5,308 ภาพ การศึกษานี้ได้คัดภาพที่มีองค์ประกอบของกระดูกเชิงกรานครบมา 2,500 ภาพและดำเนินการแบ่งชุดข้อมูลสำหรับเทรนนิ่งและเทสด้วยอัตราส่วน 80:20 เป็นเทรนนิ่งเซตจำนวน 2,000 ภาพ และเทสตั้งเซตจำนวน 500 ภาพ



(ก) AP View



(ข) LA View

รูปที่ 10 ชุดข้อมูล BUU-LSPINE: (ก) AP View, (ข) LA View

ตารางที่ 1 จำนวนข้อมูลในชุดข้อมูล BUU-LSPINE


เนื้อหา	จำนวนทั้งหมด	เพศหญิง	เพศชาย
All Patients	5308	3316	1992
Spondylolisthesis Patients	889	616	273
Anterolisthesis	657	503	154
Retrolisthesis	300	142	158
Left Laterolisthesis	86	65	21
Right Laterolisthesis	95	64	31
LSTV Patients	172	123	49
Sacralization	152	113	39
Lumbarization	20	10	10

ตารางที่ 2 คุณลักษณะของ BUU-LSPINE


เนื้อหา	คำอธิบาย
ประเภทไฟล์	รูปภาพ: JPG, ผลเฉลย: CSV
Ground truths	Lumbar coordinates, Spondylolisthesis, LSTV
ความสูงของภาพ (pixels)	AP: 1,434 - 3,408, LA: 1,752 - 3,408
ความกว้างของภาพ (pixels)	AP: 860 - 3,408, LA: 868 - 3,408
Pixel Spacing (mm)	0.125 - 0.175
ขนาดชุดข้อมูล (gigabytes)	15.7

4.2 ผลลัพธ์ของการประมาณตำแหน่งของกระดูกเชิงกราน


ผลลัพธ์จากการประมาณตำแหน่งกระดูกเชิงกราน คือ โมเดลวงรี (วงกลมสีแดงในรูปที่ 11, รูปที่ 12, และรูปที่ 13) ผลลัพธ์จากการปรับตำแหน่งและขนาดของวงรี ทำให้โมเดลมีความยืดหยุ่นปรับรูปร่างให้เข้ากับกระดูกเชิงกรานของผู้ป่วยแต่ละคน ซึ่งผลลัพธ์ที่ได้นั้น ยังสามารถเป็นรากฐานในการหาตำแหน่งของกระดูกสันหลังส่วนล่าง หรือองค์ประกอบอื่น ๆ ได้อีกด้วย



รูปที่ 11 ผลลัพธ์การประมาณตำแหน่งกระดูกเชิงกรานด้านซ้าย



รูปที่ 12 ผลลัพธ์การประมาณตำแหน่งกระดูกเชิงกรานด้านขวา




รูปที่ 13 ผลลัพธ์การประมาณตำแหน่งกระดูกเชิงกรานทั้งสองด้าน

4.3 ผลลัพธ์การตรวจจับวัตถุ

การตรวจจับตำแหน่งของกระดูกเชิงกรานทั้งสองด้าน โดยใช้ดัชนีแจ็กการ์ดในการประเมินประสิทธิภาพของแบบจำลองดังที่แสดงในรูปที่ 14 แสดงผลลัพธ์ที่ค่อนข้างแม่นยำ โดยกระดูกเชิงกรานทางด้านซ้ายมีค่าอยู่ที่ 0.8594 และทางด้านขวาอยู่ที่ 0.8597 ซึ่งค่าเหล่านี้บ่งบอกถึงความคล้ายคลึงกันระหว่างตำแหน่งที่คาดการณ์กับตำแหน่งจริง โดยที่ค่าดัชนีแจ็กการ์ดที่ใกล้เคียงกับ 1 แสดงถึงความแม่นยำที่สูงขึ้น ค่าดัชนีแจ็กการ์ดที่ได้อยู่ที่ประมาณ 0.86 แสดงให้เห็นช่องว่างที่สามารถพัฒนาเพิ่มเติมได้ ดังที่แสดงในตารางที่ 3 ส่วนค่าความแม่นยำของการตรวจจับเทียบระหว่างพื้นที่วัตถุที่ตรวจจับได้ กับวัตถุโครงของกระดูกเชิงกราน ได้ว่ามีค่า Precision ของกระดูกเชิงกรานด้านซ้าย อยู่ที่ 92.59% และของกระดูกเชิงกรานทางด้านขวาอยู่ที่ 92.68% ส่วนค่า Recall ที่ได้อยู่ที่ 92.69% ของทั้งด้านซ้ายและขวา ดังที่แสดงในตารางที่ 3

ความท้าทายในการระบุขอบของกระดูกเชิงกรานเกิดจากความคลุมเครือของขอบวัตถุ รวมถึงความคล้ายคลึงของสีระหว่างพื้นหลังและวัตถุ ทำให้การตรวจจับขอบเขตของกระดูกเชิงกรานโดยไม่ให้โมเดลตรวจจับเกินขอบเขตของวัตถุจริง จำเป็นต้องอาศัยการประมาณตำแหน่งของขอบในบริเวณที่ไม่ชัดเจน ในงานวิจัยนี้ ได้นำวิธีการประมาณตำแหน่งด้วยวงรีมาใช้ เพื่อให้โมเดลสามารถพิตเข้ากับขอบของกระดูกเชิงกรานได้อย่างเหมาะสม วิธีนี้ช่วยให้สามารถประมาณตำแหน่งของกระดูกเชิงกรานได้ทั้งในบริเวณที่มีขอบชัดเจนและบริเวณที่ขอบไม่ชัดเจน ดังที่แสดงในรูปที่ 14



รูปที่ 14 ดัชนีแจ็กการ์ดเมื่อเทียบกับโมเดลที่ประมาณค่าตำแหน่งกระดูกเชิงกราน

ตารางที่ 3 ดัชนีแจ็กการ์ดและคอนฟิวชันเมทริกซ์ที่ได้ในการตรวจจับกระดูกเชิงกราน (ผลการวัดจาก Testing sets จำนวน 500 ภาพ)

วัตถุที่ตรวจจับ	Jaccard's index	Precision	Recall
กระดูกเชิงกรานทางด้านซ้าย	0.8594	0.9259	0.9269
กระดูกเชิงกรานทางด้านขวา	0.8597	0.9268	0.9269

ผลลัพธ์ที่ได้จากการตรวจจับกระดูกเชิงกราน อาจได้รับผลกระทบจากสัญญาณรบกวนบนรูปภาพ ทำให้ไม่สามารถตรวจจับได้อย่างเต็มประสิทธิภาพ ดังต่อไปนี้


- แสงเงาจากการถ่ายภาพรังสีทำให้เกิดเงาบริเวณรอบของกระดูกเชิงกราน ซึ่งส่งผลกระทบต่อตรวจจับของโมเดล ดังที่แสดงในรูปที่ 15
- อุจจาระของผู้ป่วยหากผู้ป่วยไม่ได้งดอาหารมาก่อนภาพที่ได้ อาจจะมีสีดำของก้อนอุจจาระดังที่แสดงรูปที่ 16
- Artifacts บนรูปภาพที่มีเพื่อให้ข้อมูลกับผู้ดูฟิล์มเอกซเรย์ บางครั้งจกตกอยู่บริเวณกระดูกเชิงกรานทำให้ส่งผลกระทบต่อตรวจจับของโมเดล อย่างที่แสดงในรูปที่ 17



รูปที่ 15 สัญญาณรบกวนที่เกิดจากเงาแสงรังสีขณะทำการถ่ายภาพเอกซเรย์




รูปที่ 16 สัญญาณรบกวนที่เกิดจากอุจจาระในลำไส้ บดบังกระดูกเชิงกราน



รูปที่ 17 สัญญาณรบกวนที่เกิดจาก Artifacts บนรูปภาพ (รูปไม่บรรทัด อักษรบนรูป ขอบของรูป)

4.4 ผลลัพธ์ระบบสนับสนุนการตัดสินใจสำหรับแพทย์

ผลลัพธ์การจัดทำระบบสนับสนุนการตัดสินใจสำหรับแพทย์ในการประมาณค่าตำแหน่งกระดูกเชิงกรานแสดงไว้ในรูปที่ 18 ซึ่งหน้าเว็บของระบบประกอบไปด้วย 4 ส่วนหลัก ๆ ตามรูปที่ 19 และรูปที่ 20 โดยที่ ส่วนที่ 1 คือ ส่วนที่ผู้ใช้ระบบทำการ upload ภาพเอกซเรย์เข้ามา ส่วนที่ 2 คือ ส่วนที่แสดงรูปตั้งต้นที่ผู้ใช้งาน upload ส่วนที่ 3 คือ ส่วนที่แสดงผลของการประมาณค่าตำแหน่งกระดูกเชิงกรานที่ได้ และส่วนที่ 4 คือ ส่วนที่แสดงพิกัดของกระดูกเชิงกรานที่ได้จากทั้งชายและขวาของผู้ป่วย



รูปที่ 18 หน้าตาของ Website ที่ออกแบบสำหรับระบบสนับสนุนการตัดสินใจของแพทย์ในการประมาณตำแหน่งของกระดูกเชิงกรานทั้งสองด้าน

Pelvic Prediction

Utilizing machine learning for early risk assessment and informed treatment decisions in healthcare.

1 Upload Input Image:

Browse... No file selected.

2 Input Image:

3 Prediction: BBox

Bounding Box Details:

รูปที่ 19 องค์ประกอบของเว็บไซต์สนับสนุนการตัดสินใจของแพทย์ (1)

Upload Input Image:

Browse... No file selected.

Input Image:


Prediction: BBox

4 Bounding Box Details:


Lumbar	BBox Position [[row_min, col_min],[row_max, col_max]]	Detection Score
Left Pelvic		
Right Pelvic		

รูปที่ 20 องค์ประกอบของเว็บไซต์สนับสนุนการตัดสินใจของแพทย์ (2)


ผลลัพธ์ของระบบสนับสนุนการตัดสินใจของแพทย์ในการประมาณตำแหน่งของกระดูกเชิงกรานแสดงไว้ในรูปที่ 21 ถึงรูปที่ 24 จะเห็นว่าผลลัพธ์ที่ได้ คือ การตรวจจบบัวตูดที่เป็นตำแหน่งของกระดูกเชิงกรานทั้งด้านซ้ายและขวาของผู้ป่วย




รูปที่ 21 ตัวอย่างผลลัพธ์การประมาณตำแหน่งกระดูกเชิงกรานทั้งสองด้าน (1)



รูปที่ 22 ตัวอย่างผลลัพธ์การประมาณตำแหน่งกระดูกเชิงกรานทั้งสองด้าน (2)



รูปที่ 23 ตัวอย่างผลลัพธ์การประมาณตำแหน่งกระดุกเชิงกรานทั้งสองด้าน (3)



รูปที่ 24 ตัวอย่างผลลัพธ์การประมาณตำแหน่งกระดุกเชิงกรานทั้งสองด้าน (4)

บทที่ 5

สรุปผลการดำเนินงานวิจัย

5.1 ข้อสรุปและอภิปรายผล

ผลการตรวจจับตำแหน่งกระดูกเชิงกรานทั้งด้านซ้ายและด้านขวาโดยใช้วิธีการ ASM แสดงให้เห็นว่ามีค่าดัชนีแฉกคาร์ตสูงกว่า 0.85 ซึ่งบ่งบอกถึงความแม่นยำของวิธีการที่เสนอในการประมาณตำแหน่งของกระดูกเชิงกรานได้อย่างมีประสิทธิภาพ โดยการใช้โมเดลรูปร่างที่มีการปรับขนาดและตำแหน่งให้สอดคล้องกับภาพ สิ่งสำคัญคือการกำหนดค่าตำแหน่งและขนาดของโมเดลเริ่มต้นโดยอ้างอิงสถิติจากชุดข้อมูลก่อนที่จะปรับขนาดและทิศทางให้เข้ากับภาพ

วิธีการนี้ช่วยให้ได้ตำแหน่งและขนาดของกระดูกเชิงกรานอย่างแม่นยำ ซึ่งเป็นรากฐานสำคัญในการค้นหาตำแหน่งของวัตถุอื่น ๆ เช่น กระดูกสันหลังส่วนล่างหรือกระดูกก้นกบในขั้นตอนถัดไป

5.2 ข้อจำกัดและงานในอนาคต

วิธีการที่ประมาณตำแหน่งของกระดูกเชิงกรานด้วยโมเดลทางเรขาคณิต โดยดูจากขอบของข้อกระดูก ทำให้อาจพบปัญหาเมื่อเจอกับภาพที่มีขอบของข้อกระดูกที่ไม่ชัดเจน เช่น โดนสัญญาณรบกวนด้วย ก้อนอุจจาระ เงาของการถ่ายภาพรังสีหรือ Artifacts ข้อมูลของฟิล์ม

งานในอนาคตอาจศึกษาเพิ่มเติมถึงการจัดการกับสัญญาณเบื้องต้นเหล่านี้ ก่อนทำการประมาณตำแหน่งของกระดูกเชิงกราน

5.3 บทความวิชาการที่ได้รับการตีพิมพ์

1. บทความวิจัยเรื่อง “An invariant geometric feature for inter-subject lumbar curve alignment to detect spondylolisthesis” กำลังอยู่ในขั้นตอนการพิจารณาโดยผู้ทรงคุณวุฒิ หลังจากที่ได้ส่งไปยังวารสาร IEEE Access เมื่อวันที่ 27 ตุลาคม 2567 ดังแสดงในรูปที่ 25 โดยวันที่ส่งบทความปรากฏในรูปที่ 26 สถานะปัจจุบันของบทความคือ “อยู่ในกระบวนการพิจารณาโดยผู้ทรงคุณวุฒิ” ซึ่งได้รับยืนยันจากอีเมลแจ้งเตือนจากทีมบรรณาธิการของวารสาร ดังแสดงในรูปที่ 27 (Updated: 16 ธันวาคม 2567) บทความวิจัยเรื่อง “An invariant geometric feature for inter-subject lumbar curve alignment to detect spondylolisthesis” ได้รับกายอมรับ (Accepted) เมื่อวันที่ 16 ธันวาคม 2567 แล้วอย่างที่แสดงให้รูปที่ 28

For consideration in *IEEE Access*
Page 1 of 20




Regular Manuscript

An invariant geometric feature for inter-subject lumbar curve alignment to detect spondylolisthesis

Submission ID	9da8ed45-e9a5-421e-b988-769830da7f04
Manuscript ID	draft-9da8ed45-e9a5-421e-b988-769830da7f04
Submission Version	Initial Submission
PDF Generation	27 Aug 2024 04:19:55 EST by Atypon ReX

Authors

Mr. PODCHARA KLINWICHIT

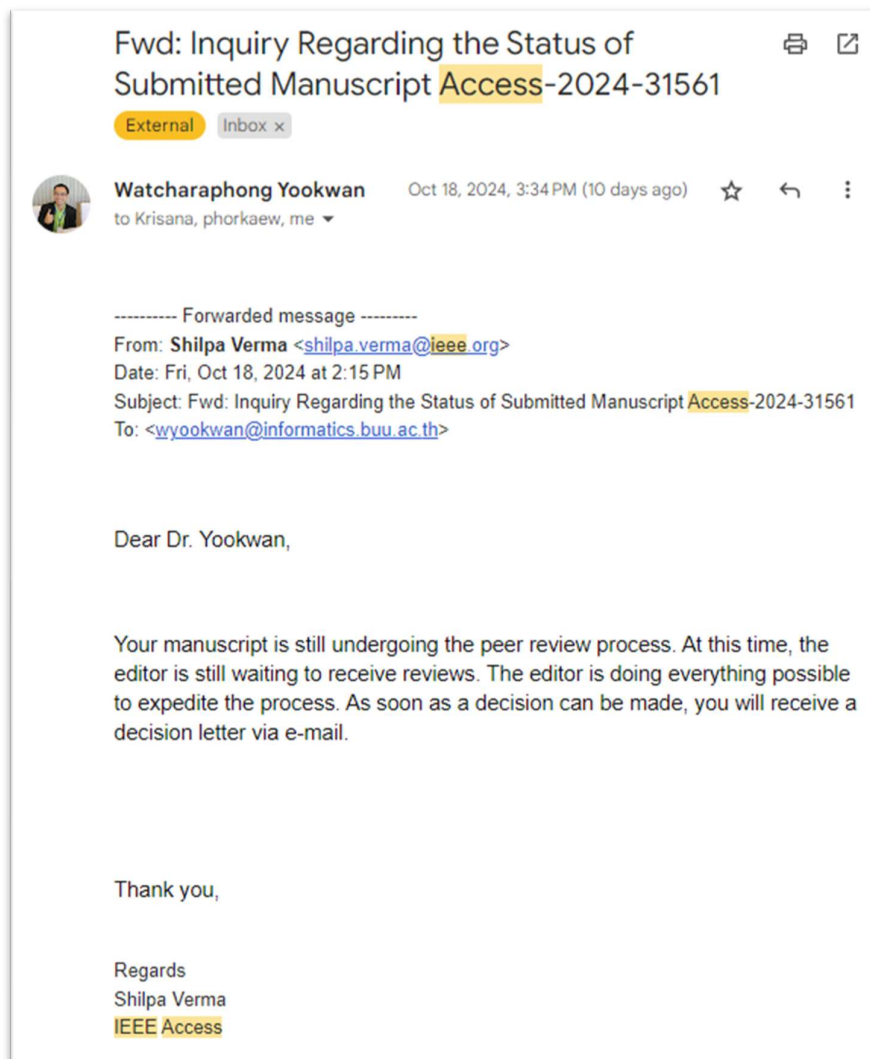
Affiliations

- Faculty of Informatics, Burapha University, Chonburi 20131, Thailand

รูปที่ 25 การส่งบทความไปยังวารสาร IEEE Access

History	Submitted On	27 August 2024 by Krisana Chinnasarn
		Show this version history
	Submission Started	13 August 2024 by Krisana Chinnasarn
	Journal Contacts	Pandey, Dr. Shefali - Administrator shefali.pandey@ieee.org

รูปที่ 26 กำหนดการส่งบทความ



รูปที่ 27 อีเมลแจ้งสถานะบทความจากทางวารสาร IEEE Access

16-Dec-2024

Dear Dr. Chinnasarn:

Your manuscript entitled "An invariant geometric feature for inter-subject lumbar curve alignment to detect spondylolisthesis" has been accepted for publication in IEEE Access. The comments of the reviewers who evaluated your manuscript are included at the foot of this letter. We ask that you make minor changes to your manuscript based on those comments, before uploading final files.

Please be advised that you are **not permitted** to add or remove authors or references post-acceptance, regardless of the reviewers' request(s). **Any request to add an author post-acceptance will be denied.** However, we encourage you to check the formatting of your references to ensure that they are accurate in terms of bibliographic details as well as consistent with [IEEE style](#). Additionally, please take this opportunity to improve the English grammar and check spelling, as the article is only lightly edited before publication.

You can submit your final files through the [IEEE Author Portal](#).

All files intended for publication need to be submitted during this step, even if some files are unchanged from the initial submission. If you do not submit all files during this step, it can delay the publication of your article, or result in certain files not being published. **Please be advised that once you submit final files the article will be considered published and cannot be withdrawn.**

To assist you with preparing your final files, attached please find a Final Files Checklist.

Once you have completed the submission of your final files, the **accepted version** of your article will be posted Early Access on IEEE Xplore within 2-3 business days. Within 7-10 business days the corresponding author will receive your page proofs, at which point you can make **minor** edits as necessary. Once the corresponding author approves the proofs, the final version will replace the Early Access version on IEEE Xplore.

For more information on what to expect after you submit final files, please visit our [Post Acceptance Guide](#).

After you submit final files you will automatically be directed to the Electronic Copyright Form. Once the copyright information is completed, within a few business days you will receive an email from Copyright Clearance Center (CCC) to settle your APC balance of \$1,995 USD plus applicable local taxes by check, credit card, or wire transfer. **Please note that once you submit final files your article is considered published, and you are responsible for covering the cost of the APC.** If you need assistance with the payment process, please contact CCC Customer Service at IEEEsupport@copyright.com.

Thank you for your fine contribution. On behalf of the Editors of IEEE Access, we look forward to your continued contributions to IEEE Access.

Sincerely,

Prof. Gustavo Callico
Associate Editor, IEEE Access

รูปที่ 28 อีเมลล์แจ้งสถานการณ์ตอบรับ (Accepted) บทความ Q1 จากทางวารสาร IEEE Access

- บทความวิจัยเรื่อง "Spondylolisthesis Identification in Lumbar Spine Using Centroid Distance Error" ซึ่งได้รับการตีพิมพ์ใน InCIT 2024: The 8th International Conference on Information Technology @Faculty of Informatics, Burapha University, Chonburi, Thailand And @Kanazawa (Japan) 14th - 15th November 2024 ดังที่แสดงในรูปต่อไปนี้

Spondylolisthesis Identification in Lumbar Spine Using Centroid Distance Error

1st Jiranun Sangrueng
Faculty of Informatics
Burapha University
Chon Buri, Thailand
67910094@go.buu.ac.th

2nd Watcharaphong Yookwan
Faculty of Informatics
Burapha University
Chon Buri, Thailand
wyookwan@informatics.buu.ac.th

3rd Suwanna Rasmequan
Faculty of Informatics
Burapha University
Chon Buri, Thailand
rsuwanna@informatics.buu.ac.th

4th Annupan Rodtook
Faculty of Science
Ramkhamheang University
Bangkok, Thailand
annupan@ru.ac.th

5th Athita Onuean
Faculty of Informatics
Burapha University
Chon Buri, Thailand
athitha@go.buu.ac.th

6th Krisana Chinnasarn
Faculty of Informatics
Burapha University
Chon Buri, Thailand
krisana@buu.ac.th

7th Thanin Methiyothin
Master of Science
University of Science and Technology
(UST) & Korea Institute of Science and
Technology Information (KISTI)
Daejeon, Korea(south)
thanin@kisti.re.kr

Abstract— Spondylolisthesis is a spinal disorder characterized by the anterior displacement of one vertebra over the one beneath it, predominantly affecting the lumbar region. Accurate and timely diagnosis is crucial for effective treatment and patient care. This study proposes an automated method for identifying spondylolisthesis by employing a deep learning approach using SSD for lumbar vertebrae detection. After detecting the vertebrae, the centroids of each vertebra are calculated from their respective bounding boxes, and a linear model is fitted through these centroids to assess vertebral alignment. The centroid distance error, defined as the deviation of each centroid from the fitted line, is utilized to evaluate misalignment indicative of spondylolisthesis. The proposed method was evaluated on a dataset of lumbar spine images, in diagnosing spondylolisthesis based on centroid distance errors. This automated framework demonstrates significant advantages over traditional diagnostic methods, including increased efficiency, consistency, and scalability. The findings highlight the potential of integrating advanced image processing techniques and machine learning models into clinical practice, paving the way for improved diagnostic accuracy and patient outcomes in spinal disorders. Future work will focus on expanding the dataset and exploring the integration of clinical parameters to enhance the model's predictive capabilities. +

Keywords— Lumbar Spine, Centroid Distance Error, Spondylolisthesis

I. INTRODUCTION

Spondylolisthesis is a spinal disorder characterized by the anterior displacement of one vertebra relative to the one below it, commonly affecting the lumbar region [1]. This condition can result in severe complications, including nerve impingement, chronic pain, and restricted mobility, all of which can significantly affect a patient's quality of life. Early diagnosis is essential to prevent further progression and mitigate the symptoms. Typically, the diagnosis is conducted through visual analysis of radiological images, including X-rays, CT scans, or MRI scans, followed by manual

measurements of vertebral displacement [2]. While effective, this traditional method suffers from several drawbacks, such as inter-observer variability, the time required for manual inspection, and the potential for human error, leading to inconsistent or inaccurate diagnoses.

In recent years, advances in artificial intelligence (AI) and computer vision have provided opportunities to automate and enhance diagnostic processes, reducing the burden on clinicians and improving diagnostic accuracy. In this paper, we propose an automated approach for detecting and quantifying spondylolisthesis using deep learning techniques, specifically focusing on lumbar spine images. The proposed method integrates the Single Shot Multibox Detector (SSD), a cutting-edge object detection model, to accurately detect and localize individual vertebrae in spinal imaging datasets [3]. The efficiency and accuracy of SSD make it well-suited for real-time applications, as it can effectively handle variations in image quality, orientation, and patient anatomy.

Once SSD detects the vertebrae, the centroids of each vertebra are computed from the bounding boxes. These centroids are crucial for assessing the alignment of the vertebral column. To evaluate the spinal alignment, a best-fit linear regression line is calculated, passing through the centroids of all detected vertebrae. This line serves as the reference for an ideal, healthy spine where no significant misalignment is present. The characteristic of spondylolisthesis, is quantified by calculating the centroid distance error. This metric measures the perpendicular distance from each vertebral centroid to the fitted line. An elevated centroid distance error indicates a deviation from normal spinal alignment, with larger errors signifying greater vertebral displacement and, consequently, a higher likelihood of spondylolisthesis.

Our proposed approach offers several advantages over traditional diagnostic approaches. First, by automating the vertebral detection and measurement process, it eliminates the

subjectivity and variability introduced by manual methods. Second, the use of deep learning allows for rapid and scalable analysis, which is particularly valuable in clinical settings where large volumes of imaging data need to be processed quickly and accurately. Lastly, the centroid distance error provides a quantifiable measure of vertebral displacement, allowing clinicians to objectively assess the severity of spondylolisthesis and monitor its progression over time.

In summary, the proposed method aims to provide a reliable, efficient, and automated solution for spondylolisthesis detection. By leveraging state-of-the-art deep learning models like SSD, combined with robust centroid analysis, this approach holds the potential to significantly improve the diagnostic workflow in spinal healthcare, reducing both the time required for analysis and the risk of diagnostic errors.




Fig.1 Conceptual of Proposed Framework

The objective of this research is to improve accuracy and reduce computational time in spondylolisthesis identification. Our proposed method provides an efficient and automate, Spondylolisthesis detection that can help in preliminary medical analysis.

II. BACKGROUND

Spondylolisthesis is a condition where one vertebra slips forward over the adjacent vertebra, leading to various degrees of spinal instability. This condition primarily affects the lumbar spine and can result in significant pain, neurological deficits, and diminished quality of life [1]. The early detection and accurate assessment of spondylolisthesis are crucial for effective management and treatment strategies, which may range from conservative approaches to surgical interventions [2].

A. Pathophysiology of Spondylolisthesis

Spondylolisthesis can result from multiple factors, including degenerative changes, traumatic injuries, congenital anomalies, or pathological conditions [4]. It is classified into several grades based on the degree of slip, with Grade I indicating a minimal shift and Grade IV representing near-total slippage. The pathophysiological implications of spondylolisthesis can lead to nerve root compression, spinal stenosis, and altered biomechanics of the spine, necessitating timely intervention as shown in Fig. 2.




Fig.2 Pathophysiology of Spondylolisthesis

In Fig. 2, in X-ray imaging, spondylolisthesis can be visualized as a misalignment in the vertebrae. Radiological examination is typically the first-line diagnostic tool used to confirm the presence of this condition, with lateral (side view) and anteroposterior (front-to-back view) X-rays being the most common views taken.

B. Traditional Diagnostic Approaches

Normally, the diagnosis of spondylolisthesis relies on radiological assessments. X-rays are often the first imaging modality employed to visualize vertebral alignment [1]. However, the interpretation of these images is subjective and can vary significantly between practitioners. Advanced imaging techniques, such as MRI and CT scans, provide better anatomical detail and allow for the assessment of soft tissue structures; however, these methods are more expensive and less accessible [5].

III. PROPOSED METHOD

This section outlines the proposed methodology for the automated identification of spondylolisthesis in the lumbar spine. Fig. 3 demonstrates the approach leverages state-of-the-art deep learning techniques, specifically the SSD architecture, for the detection of lumbar vertebrae. Subsequently, we calculate the centroids of these vertebrae and assess their alignment using centroid distance error as a diagnostic metric. The methodology is structured into the following key components: dataset preparation, lumbar vertebrae detection using SSD, centroid calculation, linear fitting of centroids, and distance error calculation.




Fig.3 Proposed Method

A. Dataset

For this study, we utilize a dataset comprising labeled medical images of the lumbar spine, which include X-rays images. Klinwicht et. al. [6] introduced an Open Dataset contains Lumbar X-Ray images with Spondylolisthesis cases entitled "BUU-LSPINE". The dataset consists of plain film images from 3,600 patients, annotated with vertebral positions, spondylolisthesis diagnoses, and ground truth labels for lumbosacral transitional vertebrae (LSTV). The dataset is then split into to 80 percent training set (2,880 images) and 20 percent testing set (720 images) to avoid overfit problem.

B. Lumbar Vertebrae Detection Using SSD

Using the Single Shot MultiBox Detector (SSD300) from PyTorch for lumbar vertebrae detection in X-ray images involves training the model to locate and classify the lumbar vertebrae (L1 to L5) by predicting bounding boxes around each vertebra. The SSD300 model processes the entire X-ray image in a single pass, leveraging convolutional feature maps to detect vertebrae at various scales, ensuring accuracy across different vertebra sizes. By minimizing localization and confidence losses during training, SSD300 efficiently learns to differentiate between lumbar vertebrae and background structures. Once trained, SSD300 can rapidly detect and classify vertebrae in new images. Once the dataset is prepared, the SSD model is trained to detect vertebrae. SSD employs a unified neural network architecture that directly predicts bounding boxes and class probabilities from full images in a single pass. The architecture comprises multiple convolutional layers followed by regression layers, which produce both the bounding box coordinates and the associated confidence scores. During training, the model is optimized using an annotated dataset, with the loss function typically combining object detection and localization components to minimize errors in vertebra localization and classification. A validation set is incorporated to evaluate performance and mitigate overfitting. Following training, the model is deployed

for inference on previously unseen medical images, where it outputs bounding boxes around detected vertebrae along with confidence scores. A confidence threshold is applied to exclude detections with low confidence, ensuring robust identification of vertebral structures. The parameter set is shown in Table I.

Table I. Parameter Setup

Parameter	Value/Range
Model Architecture	SSD
Batch Size	16
Learning Rate	0.001
Optimizer	Adam
Epochs	100
Confidence Threshold	0.7
IoU Threshold	0.45
Validation Dataset	10-fold cross validation
Loss Function	Cross-Entropy + IoU Loss
Non-Max Suppression	Enabled (NMS threshold: 0.45)
GPU Usage	NVIDIA GPUs with CUDA support RTX 3080
Evaluation Metrics	Precision, Recall, F1-score

The result from the localization is presented in the bounding box for each vertebrae. In Fig. 4, the vertebrae of lumbar spine are located.




Fig.4 Bounding box of each Lumbar Vertebrae

C. Centroid Calculation

After the lumbar vertebrae have been detected, we calculate the centroid for each vertebra. Bounding Box Analysis: For each detected bounding box, the centroid is

computed using the coordinates of the bounding box corners. The centroid (x_c, y_c) of a bounding box defined by $(x_{min}, y_{min}, x_{max}, y_{max})$ can be calculated using the Eq. (1).

$$x_c = \frac{x_{min} + x_{max}}{2}, y_c = \frac{y_{min} + y_{max}}{2} \quad (1)$$

Centroid Collection: Store the centroids of all detected vertebrae for further analysis. This data will serve as the basis for assessing vertebral alignment.

D. Linear Fitting of Centroids

To evaluate the alignment of the lumbar vertebrae, a linear regression line is fitted through the calculated centroid. The centroids are subjected to linear regression analysis to determine the best-fit line that represents the ideal alignment of vertebrae in a healthy spine. The linear equation can be expressed in the form of Eq. (2).

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \varepsilon \quad (2)$$

Where m is the slope and b is the y-intercept. In Fig. 5, the fitted line is visualized alongside the centroids on a graph, providing a clear representation of vertebral alignment.




Fig.5 Regression Line from Vertebra centroid

E. Distance Error Calculation

The final step involves quantifying the alignment of each vertebra relative to the fitted line by calculating the centroid distance error. For each centroid, the perpendicular distance d_i from the centroid (x_c, y_c) to the line can be calculated using the Eq. (3) derived from the point-to-line distance.

$$d_i = \frac{|Ax_{c_i} + By_{c_i} + C|}{\sqrt{A^2 + B^2}} \quad (3)$$

where A , B , and C are coefficients derived from the linear equation of the fitted line. Algorithm I show the process in determination of spondylolisthesis detection

Algorithm I. Spondylolisthesis detection

Algorithm:	Spondylolisthesis Detection
Input:	Centroid C_n of vertebrae from Localization Process
1:	INITIALIZE list of centroid C_n
2:	FOR EACH vertebra centroid in the image
3:	ALIGN adjacency centroid C_i
4:	END FOR
5:	COMPUTE regression line $L = \beta_0 + \beta_1 C_1 + \beta_2 C_2 + \dots + \beta_n C_n$
6:	IF $\sim(L \perp X_{axis})$:
7:	Mark vertebra as Spondylolisthesis
8:	ELSE:
9:	FOR EACH centroid C_i
10:	COMPUTE error E_i between C_i and L
11:	END FOR
12:	COMPUTE $Thresh_{reg}$ using Standard Deviation σ^2 of E_n
13:	IF $E_i > Thresh_{reg}$:
14:	Mark vertebra as Spondylolisthesis
15:	ELSE
16:	Mark vertebra as Normal
17:	END IF
18:	END IF
Output:	Detection results for each vertebra

The calculated distances provide a quantitative measure of vertebral misalignment. Larger distances indicate a greater degree of displacement, which may suggest the presence of spondylolisthesis as illustrated in Fig. 6.




Fig. 6 Distance Error and Angle Error

In Fig. 7, the error from the regression line is demonstrated. If the error is between the red line, the vertebrae is determined as Normal. On the other hand, the data with an error above and below the red line is decided as Abnormal or Spondylolisthesis.




Fig.7 Scatter plot of error value from the regression and centroid of each vertebrae.

IV. RESULT AND DISCUSSION

In this section, we present the results of the proposed method for identifying spondylolisthesis in the lumbar spine. The proposed approach demonstrated impressive detection capabilities, achieving a precision of 0.88, recall of 0.89, F1 score of 0.85. This performance indicates a high level of accuracy in identifying Spondylolisthesis. This approach established a threshold for diagnosing, demonstrating an accuracy. The advantages of the proposed automated framework in terms of efficiency, consistency, and scalability.

In addition, the results illustrate the potential of the automated method to enhance clinical diagnostics. By providing an objective measure of vertebral alignment, the centroid distance error facilitates more accurate diagnoses and timely interventions, addressing the limitations of subjective manual assessments. Furthermore, the proposed method can be seamlessly integrated into clinical workflows, allowing for rapid analysis of large datasets. The following table summarizes the performance metrics of the proposed method applying in various dataset.

Table II. Performance Evaluation

Metric	Dataset		
	Klinwichit et. al. [6]	Cai et. al. [7]	Fraivan et. al. [8]
Precision	0.88	0.81	0.79
Recall	0.89	0.83	0.77
F1-Score	0.85	0.86	0.78

Table II emphasizes the performance of the proposed approach in detecting Spondylolisthesis, demonstrating that the proposed method significantly reduces diagnostic errors and enhances efficiency in identifying spondylolisthesis. While the results are promising, it is important to note the limitations of the study, including the dataset size and generalizability to other spinal disorders. Future research should focus on refining the model further and exploring its application across diverse patient populations and imaging modalities to validate its clinical effectiveness.

V. CONCLUSION AND FUTURE WORK

This study presents an innovative automated method for identifying spondylolisthesis in the lumbar spine, leveraging deep learning techniques with the SSD architecture for precise lumbar vertebrae detection and centroid distance error for assessing vertebral alignment. The results demonstrate that our method significantly enhances diagnostic accuracy and efficiency compared to traditional manual inspection techniques, achieving a high Precision and consistent identification of vertebral centroids. By establishing a robust framework for measuring centroid distance errors, we can objectively quantify misalignments indicative of spondylolisthesis, facilitating timely and accurate diagnoses that are essential for effective patient management.

Despite the promising outcomes, this research acknowledges several limitations, including the dependency on the dataset's size and diversity, as well as potential challenges in generalizing the model to other spinal conditions. Future work will focus on several key areas to further improve and validate the proposed method. First, we aim to expand the dataset by incorporating a broader range of imaging modalities and patient demographics, which will enhance the model's robustness and applicability in diverse clinical settings. Additionally, exploring advanced techniques such as transfer learning and ensemble methods could improve the model's performance and accuracy further.

Moreover, future research will investigate the integration of clinical parameters, such as patient history and physical examination findings, to enhance the predictive capabilities of the model. This multi-faceted approach may lead to the development of a comprehensive diagnostic tool that combines automated image analysis with clinical insights. Lastly, we intend to conduct clinical trials to evaluate the method's effectiveness in real-world settings, which will provide valuable feedback for refining the algorithm and its clinical implementation.

VI. ACKNOWLEDGEMENT

The authors gratefully acknowledge the financial support from the Faculty of Informatics at Burapha University. This research was funded by the Korea Institute of Oriental Medicine, grant numbers KSN1823130 and KSN1922110.

REFERENCES

- [1] C. L. García-Ramos, J. Valenzuela-González, V. B. Baeza-Álvarez, L. M. Rosales-Olivarez, A. Alpizar-Aguirre, and A. Reyes-Sánchez, "Degenerative spondylolisthesis I: General principles," *Acta ortopédica mexicana*, vol. 34, no. 5, pp. 324-328, 2021.
- [2] C. Vanti, S. Ferrari, A. A. Guccione, and P. Pillastri, "Lumbar spondylolisthesis: State of the art on assessment and conservative treatment," *Archives of Physiotherapy*, vol. 11, pp. 1-15, 2021.
- [3] M. G. Ragab, S. J. Abdulkader, A. Muneer, A. Alqushaibi, E. H. Sumiea, R. Qureshi, and H. Alhussian, "A Comprehensive Systematic Review of YOLO for Medical Object Detection (2018 to 2023)," *IEEE Access*, 2024.
- [4] M. Mazurek, B. Kulesza, N. Gołębiewska, B. Tyzo, K. Kura, and D. Szczepanek, "Factors predisposing to the formation of degenerative spondylolisthesis—A narrative review," *Medicina*, vol. 59, no. 8, p. 1430, 2023.
- [5] M. C. Florkow, K. Willemsen, V. V. Mascarenhas, E. H. Oei, M. van Stralen, and P. R. Seevinck, "Magnetic resonance imaging versus computed tomography for three-dimensional bone imaging of musculoskeletal pathologies: A review," *Journal of Magnetic Resonance Imaging*, vol. 56, no. 1, pp. 11-34, 2022.
- [6] P. Klinwichit, W. Yookwan, S. Limchareon, K. Chinnasam, J. S. Jang, and A. Onuean, "BUU-LSPINE: A Thai open lumbar spine dataset for spondylolisthesis detection," *Applied Sciences*, vol. 13, no. 15, p. 8646, 2023.
- [7] M. Fraivan, Z. Audat, L. Fraivan, and T. Manasreh, "Using deep transfer learning to detect scoliosis and spondylolisthesis from X-ray images," *PLoS ONE*, vol. 17, p. e0267851, 2022.
- [8] Y. Cai, S. Leung, J. Warrington, S. Pandey, O. Shmuelovich, and S. Li, "Direct spondylolisthesis identification and measurement in MR/CT using detectors trained by articulated parameterized spine model," in *Proceedings of SPIE 10133, Medical Imaging 2017: Image Processing*, vol. 1013319, 2017.

บรรณานุกรม

- 1 Sutton, R. T. *et al.* An overview of clinical decision support systems: benefits, risks, and strategies for success. *NPJ digital medicine* **3**, 17 (2020).
- 2 Preparata, F. P. & Shamos, M. I. *Computational geometry: an introduction*. (Springer Science & Business Media, 2012).
- 3 Bebis, G., Georgiopoulos, M., da Vitoria Lobo, N. & Shah, M. Learning affine transformations. *Pattern recognition* **32**, 1783-1799 (1999).
- 4 Mishra, S. & Thanh, L. T. in *International Conference on AI and Mobile Services*. 91-101 (Springer).
- 5 Zhan, C., Duan, X., Xu, S., Song, Z. & Luo, M. in *Fourth international conference on image and graphics (ICIG 2007)*. 519-523 (IEEE).
- 6 Yuan, Y., Chen, W., Tang, J. & Yang, J. in *2024 IEEE 14th International Conference on CYBER Technology in Automation, Control, and Intelligent Systems (CYBER)*. 83-88 (IEEE).
- 7 Zhao, K., Han, Q., Zhang, C.-B., Xu, J. & Cheng, M.-M. Deep hough transform for semantic line detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence* **44**, 4793-4806 (2021).
- 8 Hou, B., Ren, Z., Zhao, W., Wu, Q. & Jiao, L. Object detection in high-resolution panchromatic images using deep models and spatial template matching. *IEEE Transactions on Geoscience and Remote Sensing* **58**, 956-970 (2019).
- 9 Park, K., Patten, T., Prankl, J. & Vincze, M. in *2019 International Conference on Robotics and Automation (ICRA)*. 7207-7213 (IEEE).
- 10 Medley, D. O., Santiago, C. & Nascimento, J. C. Deep active shape model for robust object fitting. *IEEE Transactions on Image Processing* **29**, 2380-2394 (2019).
- 11 Huang, Y.-S., Hsu, T.-C. & Cheng, F.-H. in *2010 Third International Symposium on Electronic Commerce and Security*. 381-386 (IEEE).
- 12 Kim, D., Maik, V., Lee, D., Shin, J. & Paik, J. in *Computational Science-ICCS 2006: 6th International Conference, Reading, UK, May 28-31, 2006, Proceedings, Part IV* 6. 922-929 (Springer).
- 13 Drake, R. L., Vogl, A. W. & Mitchell, A. W. M. *Gray's Anatomy for Students*. (Elsevier, 2023).
- 14 Cootes, T. F., Taylor, C. J., Cooper, D. H. & Graham, J. Active shape models-their training and application. *Computer vision and image understanding* **61**, 38-59 (1995).
- 15 Klinwichit, P. *et al.* BUU-LSPINE: A thai open lumbar spine dataset for spondylolisthesis detection. *Applied Sciences* **13**, 8646 (2023).