



กทปส

รายงานฉบับสมบูรณ์

โครงการขอรับการส่งเสริมและสนับสนุนจากเงินกองทุนวิจัยและพัฒนากิจการกระจายเสียง
กิจการโทรทัศน์ และกิจการโทรคมนาคม เพื่อประโยชน์สาธารณะ

โครงการคัดกรองมะเร็งต่อมไทรอยด์ด้วยภาพอัลตราซาวด์

Thyroid Nodules Assessment in Ultrasound Image Project

ผศ.ดร. ชฎาพร เกตุมณี และคณะ

ธันวาคม พ.ศ. ๒๕๖๗

กองทุนวิจัยและพัฒนากิจการกระจายเสียง กิจการโทรทัศน์ และกิจการโทรคมนาคม เพื่อประโยชน์สาธารณะ
(สำนักงาน กสทช.)

แบบ กทปส. ME-๐๐๓

รายงานฉบับสมบูรณ์

ทุนส่งเสริมและสนับสนุนการวิจัยและพัฒนา
สัญญารับทุนเลขที่ A๖๓-๑-(๒)-๐๑๘

โครงการคัดกรองมะเร็งต่อมไทรอยด์ด้วยภาพอัลตราซาวด์ Thyroid Nodules Assessment in Ultrasound Image Project

คณะนักวิจัย

๑. ผศ.ดร. ชฎาพร เกตุมณี	นักวิจัยหัวหน้าโครงการ
๒. ศ. ดร. แมททิว เอ็น เดลีย์	นักวิจัยร่วม
๓. รศ.นพ. จิตพงษ์ ส่งแสง	นักวิจัยร่วม
๔. นางสาวปวีณา นามเสนา	นักวิจัยร่วม
๕. นางสาวปิยะนุช อรุณรัถการ	นักวิจัยร่วม
๖. นางสาวจิตรลดา กุศล	นักวิจัยร่วม
๗. นายทรงพล กลั้ววงษ์	นักวิจัยร่วม
๘. นายราเมช มารีคุ	นักวิจัยร่วม
๙. นางสาวอภิญญา ชัยรัตน์	นักวิจัยร่วม
๑๐. นายชายชาญ พูลเพิ่ม	นักวิจัยร่วม
๑๑. นายวสันต์ ทิมทอง	นักวิจัยร่วม
๑๒. นายณัฐวัชร สัตย์อุดม	นักวิจัยร่วม
๑๓. นายชายชาญ พูลเพิ่ม	นักวิจัยร่วม

ได้รับทุนอุดหนุนจาก

กองทุนวิจัยและพัฒนาโครงการกระจายเสียง กิจกรรมโทรทัศน์ และกิจกรรมโทรคมนาคม เพื่อประโยชน์สาธารณะ
(สำนักงาน กสทช.)

ธันวาคม พ.ศ. ๒๕๖๗

แบบ กทปส. ME-๐๐๓

บทสรุปผู้บริหาร

โครงการคัดกรองมะเร็งต่อมไทรอยด์ด้วยภาพอัลตราซาวด์

ธันวาคม พ.ศ. ๒๕๖๗

ในการดำเนินโครงการวิจัยนี้ ทีมวิจัยได้วิจัยและพัฒนาระบบแพลตฟอร์มคัดกรองมะเร็งต่อมไทรอยด์ด้วยภาพอัลตราซาวด์ ซึ่งเป็นหนึ่งในระบบช่วยวินิจฉัย (Computer-aided Diagnosis) ที่มีความสำคัญอย่างยิ่งในบริบทด้านสาธารณสุขของประเทศไทย เนื่องจากในปัจจุบันมีการตรวจพบก้อนต่อมไทรอยด์เพิ่มขึ้นตามอายุโดยเฉพาะในผู้หญิง อีกทั้งยังมีปัญหาการขาดแคลนแพทย์ผู้เชี่ยวชาญด้านรังสีวิทยาในหลายพื้นที่ ส่งผลให้การวินิจฉัยต้องอาศัยระบบที่มีความแม่นยำสูงเพื่อช่วยลดภาระงานของแพทย์และเพิ่มโอกาสในการตรวจพบความผิดปกติในระยะเริ่มต้น การนำระบบนี้มาใช้ผ่านแพลตฟอร์มเว็บไซต์ช่วยให้เกิดการวินิจฉัยที่รวดเร็ว เข้าถึงได้ง่าย และสามารถขยายการใช้งานได้อย่างกว้างขวาง โดยเป็นเครื่องมืออัตโนมัติที่น่าเชื่อถือสำหรับแพทย์ ในการพัฒนาแพลตฟอร์มนี้ทีมวิจัยได้นำเครือข่ายประสาทเทียม "You Only Look Once" (YOLO) มาใช้เพื่อเพิ่มความแม่นยำและประสิทธิภาพในการตรวจหาก้อนต่อมไทรอยด์พร้อมกับการฝึกสอนเครือข่ายประสาทเทียม Weakly Supervised Data Augmentation Networks (WSDAN) ร่วมกับการเรียนรู้ด้วยชุดฝึกข้อมูล (Curriculum Learning) เพื่อช่วยให้โมเดล WSDAN สามารถเรียนรู้จากตัวอย่างที่ซับซ้อนมากขึ้นและจำแนกความแตกต่างระหว่างก้อนเนื้อชนิดดี (Benign) และชนิดร้าย (Malignant) ได้อย่างมีประสิทธิภาพ นอกจากนี้ โมเดล WSDAN ยังถูกพัฒนาด้วยการเสริมข้อมูล (Data Augmentation) โดยใช้ Attention Mechanism ร่วมกับภาพอัลตราซาวด์และภาพ Doppler เพื่อเพิ่มความสามารถในการจำแนกก้อนต่อมไทรอยด์ จากผลลัพธ์การทดลองฝึกสอนและทดสอบแพลตฟอร์มด้วยชุดข้อมูลจากโรงพยาบาลศิริราช ได้ผลความแม่นยำ (Precision) ที่ ๙๑% และ ๘๕% การตรวจจับผลที่ถูกต้อง (Recall) ๘๔% และ ๙๒% และคะแนน F1-score ๘๘% และ ๘๘% สำหรับก้อนเนื้อชนิดดีและชนิดร้ายตามลำดับ แต่เมื่อได้นำข้อมูลเข้ามาฝึกสอนและทดสอบโมเดลเพิ่มเติมในระดับหลายศูนย์การแพทย์ ได้แก่ ผลลัพธ์ดังกล่าวลดลงอย่างมีนัยสำคัญเนื่องจากข้อจำกัดด้านชุดข้อมูลที่ไม่เพียงพอ ซึ่งเป็นหนึ่งในแผนงานในอนาคตในการเก็บรวบรวมชุดข้อมูลที่มีความหลากหลายจากศูนย์การแพทย์ต่างๆ เพื่อเพิ่มความแม่นยำในการทำนายส่งผลให้แพลตฟอร์มสามารถถูกนำไปช่วยวินิจฉัยในหลายๆ พื้นที่นอกเหนือจากโรงพยาบาลศิริราช ในการดำเนินโครงการวิจัยนี้ทีมวิจัยได้วิจัยและพัฒนาแพลตฟอร์มคัดกรองมะเร็งต่อมไทรอยด์ด้วยภาพอัลตราซาวด์เสร็จสิ้นและนำระบบแพลตฟอร์มดังกล่าวไปใช้งานได้บรรลุตามวัตถุประสงค์ของโครงการ การขยายผลในอนาคตในวงกว้างด้วยความร่วมมือจากศูนย์การแพทย์ภาครัฐ หรือภาคเอกชน ในการใช้แพลตฟอร์มที่ทีมวิจัยพัฒนาขึ้นนี้นอกจากจะช่วยให้อินิจฉัยได้รวดเร็ว เข้าถึงได้ง่าย ยังเป็นประโยชน์ในการใช้งานด้านสาธารณสุขของประเทศไทยในการส่งเสริมการเข้าถึงบริการด้านสุขภาพของประชาชน นอกจากนี้ระบบที่พัฒนาขึ้นยังมีความสามารถทางด้านการแข่งขันกับซอฟต์แวร์จากต่างประเทศ ซึ่งช่วยลดการนำเข้าซอฟต์แวร์จากต่างประเทศ รวมถึงลดข้อกวดในการรั่วไหลของข้อมูลไปยังต่างประเทศ สำหรับการประยุกต์ใช้ข้อมูลที่มีความอ่อนไหวเช่นข้อมูลสุขภาพ

โครงการคัดกรองมะเร็งต่อมไทรอยด์ด้วยภาพอัลตราซาวด์

ผศ.ดร. ชฎาพร เกตุมณี

ธันวาคม พ.ศ. ๒๕๖๗

ในการดำเนินโครงการวิจัยนี้ทีมวิจัยได้ทำการวิจัยและพัฒนาระบบแพลตฟอร์มคัดกรองมะเร็งต่อมไทรอยด์ด้วยภาพอัลตราซาวด์ ซึ่งเป็นหนึ่งในระบบช่วยวินิจฉัย (Computer-aided diagnosis) ที่จำเป็นยิ่งเนื่องจากปัจจุบันนี้ก้อนต่อมไทรอยด์ถูกตรวจพบได้มากขึ้นตามอายุโดยเฉพาะผู้หญิง ก้อนต่อมไทรอยด์ที่ตรวจพบจำเป็นต้องได้รับการประเมินอย่างแม่นยำเพื่อระบุความเสี่ยงของการเป็นมะเร็งเพื่อการวางแผนการรักษาได้อย่างทันที่ การตรวจก้อนต่อมไทรอยด์เบื้องต้นด้วยเทคโนโลยีอัลตราซาวด์ถูกนำมาใช้เป็นเครื่องมือวินิจฉัยหลักเนื่องจากมีค่าใช้จ่ายที่ไม่สูงและเข้าถึงได้ง่าย โดยเฉพาะอย่างยิ่งการวิเคราะห์ภาพอัลตราซาวด์ด้วยเทคโนโลยีปัญญาประดิษฐ์ได้มีความก้าวหน้าเป็นอย่างมากในด้านการเรียนรู้เชิงลึก (Deep Learning) ดังนั้นในการพัฒนาแพลตฟอร์มนี้จึงได้มีการศึกษาและพัฒนาใช้เครือข่ายประสาทเทียมที่เรียกว่า You Only Look Once หรือโมเดล YOLO เพื่อเพิ่มความแม่นยำและประสิทธิภาพในการตรวจหาก้อนต่อมไทรอยด์ พร้อมกับการศึกษาและพัฒนาการผสมผสานการฝึกสอนเครือข่ายประสาทเทียมที่เรียกว่า Weakly Supervised Data Augmentation Networks หรือ โมเดล WSDAN ร่วมการเรียนรู้ด้วยชุดฝึกการเรียนรู้ (Curriculum Learning) เพื่อพัฒนาการประเมินก้อนต่อมไทรอยด์ด้วยภาพอัลตราซาวด์ นอกเหนือจากชุดฝึกการเรียนรู้ที่ถูกออกแบบขึ้นสำหรับฝึกสอนโมเดล WSDAN แล้วโมเดล WSDAN ยังได้รับการพัฒนาวิธีการสร้างข้อมูลเสริม (Data Augmentation) โดยอาศัยการขึ้นจาก Attention Mechanism โดยอัลกอริทึมดังกล่าวใช้ทั้งภาพอัลตราซาวด์และภาพ Doppler เพื่อเพิ่มความสามารถในการสร้างข้อมูลเสริมที่เหมาะสมส่งผลให้การจำแนกก้อนต่อมไทรอยด์ของโมเดลมีประสิทธิภาพสูงขึ้น ในขณะที่การเรียนรู้ด้วยชุดฝึกการเรียนรู้แบบลำดับขั้นช่วยให้โมเดลสามารถเรียนรู้จากตัวอย่างที่ซับซ้อนมากขึ้นเรื่อย ๆ ช่วยเพิ่มความสามารถในการแยกความแตกต่างระหว่างก้อนเนื้อชนิดดี (Benign) และก้อนเนื้อชนิดร้าย (Malignant) จากผลของการแสดงให้เห็นว่าการใช้โมเดล WSDAN สามารถทำนายได้อย่างมีประสิทธิภาพ โดยผลลัพธ์มีความแม่นยำ (Precision) ๙๑% และ ๘๕% การตรวจจับผลที่ถูกต้อง (Recall) ๘๔% และ ๙๒% และคะแนน F1-score ๘๗% และ ๘๘% สำหรับก้อนเนื้อชนิดดีและก้อนเนื้อร้ายตามลำดับ และมีความถูกต้องโดยรวม (Overall Accuracy) ๘๘% ซึ่งแสดงถึงประสิทธิภาพในการเพิ่มความแม่นยำในการวินิจฉัย นอกจากนี้ การนำระบบประเมินก้อนต่อมไทรอยด์นี้มาใช้ผ่านแพลตฟอร์มบนเว็บช่วยให้เกิดการวินิจฉัยที่รวดเร็ว เข้าถึงได้ และสามารถขยายการใช้งานได้อย่างกว้างขวาง โดยให้เครื่องมืออัตโนมัติที่เชื่อถือได้สำหรับแพทย์ ช่วยสนับสนุนการตัดสินใจ และส่งเสริมการตรวจหามะเร็งต่อมไทรอยด์ในระยะเริ่มต้น ในการดำเนินโครงการวิจัยนี้ทีมวิจัยได้วิจัยและพัฒนาระบบแพลตฟอร์มคัดกรองมะเร็งต่อมไทรอยด์ด้วยภาพอัลตราซาวด์เสร็จสิ้นและนำระบบแพลตฟอร์มดังกล่าวไปทดลองใช้งานได้บรรลุตามวัตถุประสงค์ของโครงการ

Thyroid Nodules Assessment in Ultrasound Image Project

Assis.Prof. Chadaporn Keatmanee

December 2024

In this research project, the research team developed a platform for thyroid cancer screening using ultrasound images, which is a critical computer-aided diagnosis (CAD) system. This development is particularly necessary as thyroid nodules are increasingly detected with age, especially in women. Thyroid nodules that are identified require accurate evaluation to assess the risk of malignancy and enable timely treatment planning. Ultrasound technology has been utilized as a primary diagnostic tool for thyroid nodule screening due to its affordability and accessibility. Particularly, advancements in artificial intelligence for ultrasound image analysis have significantly progressed in deep learning technology. Therefore, in the development of this platform, the research team studied and implemented the "You Only Look Once" (YOLO) neural network model to enhance the accuracy and efficiency of thyroid nodule detection. Alongside this, the team developed and integrated the Weakly Supervised Data Augmentation Network (WSDAN) with curriculum learning to improve thyroid nodule assessment using ultrasound images. In addition to the training datasets designed specifically for training the WSDAN model, WSDAN was further enhanced with attention-guided data augmentation, leveraging both traditional ultrasound and Doppler images. This improved the model's ability to generate suitable augmented data, thereby enhancing the efficiency of thyroid nodule classification. Meanwhile, curriculum learning allowed the model to learn progressively from increasingly complex examples, thereby improving its ability to distinguish between benign and malignant nodules. The results demonstrated the effectiveness of using the WSDAN model, achieving precision rates of 91% and 85%, recall rates of 84% and 92%, and F1-scores of 87% and 88% for benign and malignant nodules, respectively. The overall accuracy reached 88%, highlighting its potential to improve diagnostic precision. Moreover, deploying this thyroid nodule assessment system on a web-based platform facilitates rapid, accessible, and scalable diagnostics, providing automated and reliable tools for clinicians. This supports decision-making and promotes early detection of thyroid cancer. The research project successfully completed the development of the thyroid cancer screening platform using ultrasound images and achieved its objectives by implementing and testing the system effectively.

สารบัญ

บทสรุปผู้บริหาร	ก
สารบัญ.....	ง
สารบัญตาราง.....	ช
สารบัญภาพ	ซ
บทที่ ๑ บทนำ.....	12
๑.๑ ที่มาและความสำคัญของโครงการ	12
๑.๒ วัตถุประสงค์และขอบเขตของโครงการ	14
๑.๓ ประโยชน์ที่คาดว่าจะได้รับ.....	14
๑.๔ ผลผลิตสำคัญ.....	15
๑.๕ แผนปฏิบัติการโครงการ.....	16
บทที่ ๒ ทฤษฎี และงานวิจัยที่เกี่ยวข้อง	18
๒.๑ ทบทวนวรรณกรรม.....	18
๒.๒ การตรวจวินิจฉัยก้อนต่อมไทรอยด์	18
๒.๓ ระบบคอมพิวเตอร์ช่วยวินิจฉัยสำหรับประเมินก้อนต่อมไทรอยด์	23
๒.๔ การเรียนรู้เชิงลึก	24
๒.๔.๑ การพัฒนาโมเดลสำหรับตรวจจับก้อนต่อมไทรอยด์	27
๒.๔.๒ การพัฒนาโมเดลสำหรับจำแนกก้อนต่อมไทรอย์	29
๒.๕ ชุดฝึกการเรียนรู้	31
บทที่ ๓.....	32
ระเบียบวิธีวิจัย	32
๓.๑ ภาพรวมของระบบประเมินก้อนต่อมไทรอยด์ผ่านแพลตฟอร์มเว็บไซต์	32
๓.๒ ภาพรวมของระบบปัญญาประดิษฐ์.....	36
๓.๒.๑ การประมวลผลข้อมูลเบื้องต้น (Image preprocessing).....	39
๓.๒.๒ การตรวจจับและระบุตำแหน่งก้อนต่อมไทรอยด์ในภาพอัลตราซาวด์ (Thyroid nodule detection).....	41
๓.๒.๒.๑ Thyroid nodule detection ด้วยอัลกอริทึม YOLO.....	42

๓.๒.๒.๒ Thyroid nodule segmentation ด้วยอัลกอริทึม U-Net	50
๓.๒.๒.๓ Thyroid nodule segmentation ด้วยอัลกอริทึม GAN	57
๓.๒.๓ การจำแนกก้อนต่อมไทรอยด์ในภาพอัลตราซาวด์ (Thyroid nodule classification).....	59
๓.๒.๓.๑ การจำแนกก้อนต่อมไทรอยด์ในภาพอัลตราซาวด์ Pre-train Model	59
๓.๒.๓.๒ การจำแนกก้อนต่อมไทรอยด์ในภาพอัลตราซาวด์ WSDAN	69
๓.๒.๓.๓ การจำแนกก้อนต่อมไทรอยด์ในภาพอัลตราซาวด์ Enhanced – WSDAN	74
๓.๒.๓.๔ การจำแนกก้อนต่อมไทรอยด์ในภาพอัลตราซาวด์ ด้วยมาตรฐาน TI-RADS	78
๓.๒.๓.๕ การจำแนกก้อนต่อมไทรอยด์ในภาพอัลตราซาวด์ Multi-center	78
๓.๒.๓.๖ การจำแนกก้อนต่อมไทรอยด์ด้วยชุดฝึกการเรียนรู้ภาพอัลตราซาวด์	78
๓.๓ การออกแบบเซิร์ฟเวอร์ประมวลผลและเซิร์ฟเวอร์สำหรับจัดเก็บข้อมูล (Storage server และ Compute server)	79
บทที่ ๔ ผลการวิจัย และวิจารณ์ผล	84
๔.๑ ผลความแม่นยำของโมเดลคัดตรวจจับก้อนต่อมไทรอยด์ด้วยภาพอัลตราซาวด์	84
๔.๑.๑ Thyroid nodule detection ด้วยอัลกอริทึม YOLO	84
๔.๑.๒ Thyroid nodule detection ด้วยอัลกอริทึม GAN	88
๔.๒ ผลความแม่นยำของโมเดลคัดแยกก้อนต่อมไทรอยด์ด้วยภาพอัลตราซาวด์	91
๔.๒.๑ Thyroid nodule detection ด้วยอัลกอริทึม Pre-train models	91
๔.๑.๒ Thyroid nodule detection ด้วยอัลกอริทึม WSDAN	92
๔.๖ การติดตั้งและใช้งานระบบจริง	100
๔.๖.๑ การพัฒนาระบบประเมินก้อนต่อมไทรอยด์ด้วยภาพอัลตราซาวด์ผ่านแพลตฟอร์มเว็บ	100
๔.๗ วิจารณ์ผล	101
๔.๗.๑ Thyroid nodule detection ด้วยอัลกอริทึม Pre-train models	101
๔.๗.๒ Thyroid nodule detection ด้วยอัลกอริทึม GAN	101
๔.๗.๒ Thyroid nodule classification ด้วยอัลกอริทึม WSDAN	102
๔.๗.๔ ประสิทธิภาพในการรองรับภาระงาน	102
๔.๘ สรุปผลความแม่นยำของระบบ	103
๔.๙ การอบรมให้กับนักวิจัยและรังสีแพทย์เพื่อนำระบบไปใช้งานจริง	103

๔.๑๐ ผลงานตีพิมพ์ในการประชุมทางวิชาการระดับนานาชาติ	104
บทที่ ๕ สรุปผลการวิจัย และข้อเสนอแนะ	105
๕.๑ สรุปผลการวิจัย.....	105
๕.๒ ข้อเสนอแนะเชิงนโยบายต่อ กสทช. และหน่วยงานภาครัฐและเอกชนที่เกี่ยวข้อง	106
๕.๓ สรุปผลการดำเนินโครงการพัฒนาองค์ความรู้สื่อมวลชนด้านกิจการกระจายเสียงและกิจการโทรทัศน์	107
๕.๔ รายงานผลการดำเนินงานการใช้ประโยชน์จากการใช้งานจริง	107
๕.๕ รายงานสรุปผลในส่วนเป้าหมายที่อาจจะไม่สามารถบรรลุตามแผนงานที่วางไว้	109
๕.๖ รายงานผลการดำเนินการฉบับย่อสำหรับลงตีพิมพ์ในวารสารสำนักงาน กสทช.....	110
บรรณานุกรม.....	111
ภาคผนวก ก แบบประเมินความพึงพอใจ	116
ภาคผนวก ข.....	117
เอกสารตีพิมพ์ในวารสารวิชาการระดับนานาชาติ	117
ภาคผนวก ค.....	118
รายงานผลการดำเนินการฉบับย่อสำหรับลงตีพิมพ์ในวารสารสำนักงาน กสทช.....	118
ประวัตินักวิจัย	119

สารบัญตาราง

ตารางที่ ๑: การเรียนรู้เชิงลึกเพื่อตรวจจับประเภทก้อนต่อมไทรอยด์	27
ตารางที่ ๒: การเรียนรู้เชิงลึกเพื่อจำแนกประเภทก้อนต่อมไทรอยด์.....	29
ตารางที่ ๓ ผลการทดลองโมเดล U-Net.....	55
ตารางที่ ๔ แสดง Confusion Matrix	60
ตารางที่ ๕ แสดงผลลัพธ์การทำนาย.....	64
ตารางที่ ๖ แผนการพัฒนาระบบคอมพิวเตอร์ช่วยวินิจฉัยระบบประเมินก้อนต่อมไทรอยด์ด้วยภาพอัลตราซาวด์.....	83
ตารางที่ ๗ ผลการทดลองจากภาพทดสอบจำนวน ๓๒ ภาพ โดยแยกตามชนิดสัญลักษณ์.....	88
ตารางที่ ๘ แสดงผลการทดสอบ DeepLabV3+GAN.....	88
ตารางที่ ๙ แสดงผลการทดสอบ Model StableSeg GAN.....	90
ตารางที่ ๑๐แสดงผลการทดลองโมเดลเปรียบเทียบใน ๔ ชนิด.....	90
ตารางที่ ๑๑ แสดงโมเดลสำหรับแยกประเภทของก้อนเนื้อต่อมไทรอยด์	91
ตารางที่ ๑๒ แสดงการทำนายด้วย SOTA Model	91
ตารางที่ ๑๓ กรณีที่ไม่ได้เป็นก้อนต่อมไทรอยด์ชนิดดี (Benign).....	94
ตารางที่ ๑๔ กรณีที่เป็นก้อนต่อมไทรอยด์ชนิดร้าย (Malignant)	95
ตารางที่ ๑๕ ผลความแม่นยำ	97
ตารางที่ ๑๗: ความแม่นยำของระบบเมื่อเทียบกับเป้าหมาย.....	103
ตารางที่ ๑๘: สถานะการดำเนินการกิจกรรมที่สำคัญ	109

สารบัญภาพ

รูปที่ ๑: แนวทางการตรวจวินิจฉัยและรักษาโรคมะเร็งต่อมไทรอยด์.....	19
รูปที่ ๒: ตัวอย่างข้อมูลนิรนาม.....	22
รูปที่ ๓: คอมพิวเตอร์ช่วยวินิจฉัยก้อนต่อมไทรอยด์ด้วยภาพอัลตราซาวด์.....	23
รูปที่ ๔: คุณสมบัติของการเรียนรู้เชิงลึก	24
รูปที่ ๕ Single Neural Network.....	25
รูปที่ ๖: Convolutional Neural Network สำหรับประมวลผลข้อมูลทางการแพทย์	27
รูปที่ ๗: ภาพรวมของระบบออนไลน์คัดกรองมะเร็งต่อมไทรอยด์ด้วยภาพอัลตราซาวด์	32
รูปที่ ๘: แผนผังระบบประเมินก้อนต่อมไทรอยด์ผ่านแพลตฟอร์มเว็บไซต์	33
รูปที่ ๙: กระบวนการเก็บรวบรวมข้อมูลและปรับปรุงประสิทธิภาพการทำงานของโมเดล ปัญญาประดิษฐ์	34
รูปที่ ๑๐: หน้าหลักของระบบประเมินก้อนต่อมไทรอยด์ผ่านแพลตฟอร์มเว็บไซต์	35
รูปที่ ๑๑: การพัฒนาแพลตฟอร์มเว็บไซต์การวิเคราะห์ภาพทางการแพทย์ด้วยเทคโนโลยีคลาวด์....	36
รูปที่ ๑๒: การพัฒนาแพลตฟอร์มเว็บไซต์การวิเคราะห์ภาพทางการแพทย์ด้วยเทคโนโลยีคลาวด์....	36
รูปที่ ๑๓: ขั้นตอนการตรวจจับและทำนายโอกาสที่ก้อนเนื้อต่อมไทรอยด์จะเป็นก้อนเนื้อร้าย	37
รูปที่ ๑๔: การทำงานของโมเดลวิเคราะห์ก้อนต่อมไทรอยด์ด้วย CNN และโมเดลเหนี่ยวนำการเรียนรู้	37
รูปที่ ๑๕: ตัวอย่างการนำข้อมูลส่วนบุคคลออกจากรูปภาพอัลตราซาวด์	40
รูปที่ ๑๖: ตัวอย่างข้อมูลนิรนาม (ก) ภาพอัลตราซาวด์ (ข) ภาพอัลตราซาวด์ที่ปรากฏ caliper marks และ	40
รูปที่ ๑๗: ภาพแสดงตัวอย่างการกำหนด Region of Interest ของภาพ Doppler.....	40
รูปที่ ๑๘: ตัวอย่างการสร้าง Doppler mask (ก) กรอบสีขาวในภาพ Doppler ช่วยระบุตำแหน่งของ ก้อนเนื้อต่อมไทรอยด์ (ข) การระบุตำแหน่งบนภาพอัลตราซาวด์ (ค) Doppler mask.....	41
รูปที่ ๑๙: แสดงการออกแบบโมเดลทำนายขอบเขตของก้อนเนื้อต่อมไทรอยด์แยกกับโมเดลทำนาย ความผิดปกติของก้อนเนื้อต่อมไทรอยด์อย่างชัดเจน	41
รูปที่ ๒๐: แสดงการออกแบบโมเดลทำนายขอบเขตของก้อนเนื้อต่อมไทรอยด์ทำงานร่วมกับโมเดล ทำนายความผิดปกติของก้อนเนื้อต่อมไทรอยด์.....	42
รูปที่ ๒๑: แสดงกระบวนการสร้างโมเดลและการทำงานของ YOLO Detector.....	43
รูปที่ ๒๒: แสดงผลการตรวจหาตำแหน่งที่สนใจ (Region of Interest (ROI) ได้ถูกต้อง	43
รูปที่ ๒๓: แสดงความผิดพลาดในการตรวจหาตำแหน่งที่สนใจ (Region of Interest (ROI)	44

รูปที่ ๒๔: แสดงผลการค้นหาตำแหน่งบริเวณที่สนใจ (ROI) สามารถทำได้ถูกต้องทั้งหมด ในกรณีนี้ยังไม่ได้ทำการจับคู่ mark.....	45
รูปที่ ๒๕: ตัวอย่างการกำหนด Region of Interest ด้วย marks detection model	46
รูปที่ ๒๖: แสดงขั้นตอนการตรวจจับก้อนเนื้อต่อมไทรอยด์เพื่อกำหนด ROI (Namsena et al., ๒๐๒๓).....	46
รูปที่ ๒๗: ตัวอย่างภาพที่มีการดัดแปลงภาพก่อนเข้าฝึกทดลองให้กับโมเดลในแต่ละชุด batch	47
รูปที่ ๒๘: ตัวอย่างภาพเนื้องอกที่โปรแกรมตรวจจับได้ และขยายขอบเขตจากขนาดเนื้องอกเดิม ๔๐% และปรับให้เป็นขอบเขตแบบสี่เหลี่ยมจัตุรัส.....	48
รูปที่ ๒๙: ตัวอย่างภาพเนื้องอกที่ตัดเพื่อส่งต่อให้โปรแกรมคัดแยก.....	49
รูปที่ ๓๐: ตัวอย่างภาพเนื้องอกที่โปรแกรมตรวจจับได้ และขยายขอบเขตจากขนาดเนื้องอกเดิม ๒๐% และปรับให้เป็นขอบเขตแบบสี่เหลี่ยมจัตุรัส.....	49
รูปที่ ๓๑: ตัวอย่างภาพเนื้องอกที่ตัดเพื่อส่งต่อให้โปรแกรมคัดแยก.....	50
รูปที่ ๓๒: ตัวอย่างภาพผลลัพธ์ก่อน และหลังการลบเลือนสัญญาณ 51	51
รูปที่ ๓๓: ตัวอย่างภาพเนื้องอกที่หาได้จากโมเดล U-Net.....	52
รูปที่ ๓๔: ตัวอย่างการวาดตำแหน่งเนื้องอก	53
รูปที่ ๓๕: ตัวอย่างภาพเนื้องอกที่หาได้จากโมเดล U-Net.....	54
รูปที่ ๓๖: ตัวอย่างภาพไทรอยด์ที่มีก้อนเนื้อ และภาพหน้ากากก้อนเนื้อไทรอยด์ ที่ถูกนำมาตัดขอบที่ไม่จำเป็นออก	54
รูปที่ ๓๗: ตัวอย่างภาพที่มีการ Augmentation ในรูปแบบต่าง ๆ	55
รูปที่ ๓๘: โครงสร้างการทำงานของงานวิจัยที่ได้รับรางวัล MICCAI 2020 TN-SCUI Challenge....	56
รูปที่ ๓๙: โครงสร้างโมเดล DeepLabV	56
รูปที่ ๔๐: สถาปัตยกรรมโมเดล DeepLabV3+GAN.....	57
รูปที่ ๔๑: รูปภาพเปรียบเทียบการเรียนรู้ของ GAN.....	58
รูปที่ ๔๒: รูปภาพแสดงโครงสร้างของ PID Control ที่นำมาควบคุมการปรับสเกลค่า Loss เพื่อนำไปใช้ในปรับการเรียนรู้ของโมเดล Generator และ Discriminator.....	58
รูปที่ ๔๓: ภาพโมเดล StableSeg GAN	59
รูปที่ ๔๔: เทคนิค GradCAM และ Overlay Gradient Magnitude เพื่อเพิ่มความสามารถของโมเดลในการอธิบาย	61
รูปที่ ๔๕ แสดงผลลัพธ์การทำนาย	67
รูปที่ ๔๖: แสดงตัวอย่างข้อมูล Validation 8 ภาพในรูปแบบ RGBA	68
รูปที่ ๔๗: แสดงการเพิ่มเติมกระบวนการสำหรับเพิ่มรูปภาพ Mask ใน Alpha Channel.....	69

รูปที่ ๔๘ (A) ภาพอัลตราซาวด์ต้นแบบ (B) Rotation (C) Horizontal flip (D) Shear.....	70
รูปที่ ๔๙ (A) ภาพอัลตราซาวด์ต้นแบบ (B) Vertical flip (C) High degree of rotation.....	70
รูปที่ ๕๐ ตัวอย่างการสร้างชุดข้อมูลเสริมของ WSDAN	71
รูปที่ ๕๑: แสดงขั้นตอนการทำงานของโมเดลทำนายความผิดปกติของก้อนเนื้อต่อมไทรอยด์	72
รูปที่ ๕๒: แสดงตัวอย่างของผลการทำนายที่ได้จากโมเดลที่ออกแบบไป.....	74
รูปที่ ๕๓: แสดงขั้นตอนการทำงานของโมเดลทำนายความผิดปกติของก้อนเนื้อต่อมไทรอยด์อย่างละเอียด.....	74
รูปที่ ๕๔ แสดงกระบวนการจำแนกประเภทก้อนเนื้อของต่อมไทรอยด์แต่ละชุด.....	75
รูปที่ ๕๕ แผนภูมิแท่งแสดงจำนวนชุดภาพข้อมูลของก้อนต่อมไทรอยด์ที่เป็นก้อนเนื้อดีและร้าย	75
รูปที่ ๕๖ แผนภูมิแท่งแสดงจำนวนชุดภาพข้อมูลส่วนต่าง ๆ เพื่อใช้สำหรับการเรียนรู้ของโมเดล.....	76
รูปที่ ๕๗ ภาพแสดงตัวอย่างการทำ Image inpainting.....	76
รูปที่ ๕๘ ภาพแสดงตัวอย่างการกำหนด Region of Interest ด้วย marks detection model	77
รูปที่ ๕๙ ภาพแสดงตัวอย่างการกำหนด Region of Interest ของภาพ Doppler	77
รูปที่ ๖๐ ตัวอย่างการสร้างรูปภาพขึ้นมาใหม่ด้วยเทคนิคแบบต่าง ๆ	78
รูปที่ ๖๑: แผนผังของระบบเน็ตเวิร์คสำหรับเซิร์ฟเวอร์.....	79
รูปที่ ๖๒: แสดงตัวอย่างของ Storage server	79
รูปที่ ๖๓: แสดงตัวอย่างของ UPS	80
รูปที่ ๖๔: แสดงตัวอย่างของ GPU server	80
รูปที่ ๖๕: แผนผังของระบบ (System Integration Diagram)	82
รูปที่ ๖๖ แสดงตัวอย่างภาพอัลตราซาวด์และมาร์คที่ใช้สำหรับพัฒนาโมเดลตรวจจับก้อนต่อมไทรอยด์.....	84
รูปที่ ๖๗: แสดง loss ในการเทรนโมเดล.....	85
รูปที่ ๖๘: แผนภาพสรุปรวมผลการฝึกของโมเดล YOLOv5 รุ่นที่ ๕	86
รูปที่ ๖๙ ตัวอย่างรูปแบบสัญลักษณ์ที่ต้องการหาตำแหน่งทั้ง ๖ รูปแบบ.....	86
รูปที่ ๗๐: แผนภาพจำนวนรูปแบบสัญลักษณ์.....	87
รูปที่ ๗๑ ภาพค่า Loss ของตัว Generator เปรียบเทียบระหว่างการไม่ใส่ PID control.....	89
รูปที่ ๗๒ ตัวอย่างแสดงผลการทำนายของโมเดล.....	92
รูปที่ ๗๓ ตัวอย่างแสดงผลการทำนายของโมเดล.....	93
รูปที่ ๗๔ กราฟแสดงการพัฒนาโมเดลระหว่าง training และ validating	94
รูปที่ ๗๕ กราฟแสดงการพัฒนาโมเดลระหว่าง training และ validating	96
รูปที่ ๗๖ ตัวอย่างการประเมินก้อนเนื้อต่อมไทรอยด์ชนิดร้ายผ่านแพลตฟอร์มเว็บไซต์.....	101

รูปที่ ๗๗ : การฝึกอบรมการใช้งานระบบแพลตฟอร์มเว็บไซต์ประเมินก้อนต่อมไทรอยด์ด้วยภาพอัลตราซาวด์.....	103
---	-----

บทที่ ๑

บทนำ

๑.๑ ที่มาและความสำคัญของโครงการ

ก้อนต่อมไทรอยด์ (Thyroid nodules) สามารถตรวจพบได้ประมาณ ๑๙% ถึง ๖๘% จากการส่องตรวจกลุ่มประชากรด้วยวิธีอัลตราซาวด์ (ultrasound) นอกจากนี้มะเร็งต่อมไทรอยด์ (Thyroid cancer) ยังเป็นหนึ่งในมะเร็งต่อมไร้ท่อที่พบบ่อยที่สุดและพบว่ามีอัตราการเสี่ยงต่อการเป็นมะเร็งสูงขึ้นทั่วโลกในช่วง ๓๐ ปีที่ผ่านมา มะเร็งต่อมไทรอยด์ยังถูกจัดอันดับให้เป็นมะเร็งที่พบบ่อยที่สุดในผู้หญิงทั่วโลกเป็นอันดับห้า ในประเทศไทยพบว่ามีมะเร็งต่อมไทรอยด์ถูกจัดเป็นหนึ่งในสิบมะเร็งที่พบบ่อยที่สุดในผู้หญิงโดยมีโอกาสดำเนินชีวิตได้ในทุกช่วงอายุ จากการสำรวจพบว่าอายุเฉลี่ยในการเกิดมะเร็งของประชากรในประเทศที่กำลังพัฒนาหรือมีทรัพยากรที่จำกัด (Low Resource Countries: LRCs) เช่นประเทศไทย พบว่าประชากรที่ตรวจพบว่าเป็นมะเร็งจะมีอายุเฉลี่ยน้อยกว่าประเทศที่พัฒนาแล้วประมาณ ๑๐ ปี ดังนั้นการตรวจต่อมไทรอยด์เป็นประจำอาจช่วยป้องกันและรักษาผู้ป่วยในระยะแรกได้ซึ่งเป็นระยะที่มีโอกาสรักษาให้หายขาดได้ ด้วยเหตุนี้การตรวจก้อนต่อมไทรอยด์เบื้องต้นด้วยภาพอัลตราซาวด์จึงถูกนำมาใช้อย่างแพร่หลายเนื่องจากมีราคาค่อนข้างถูกเมื่อเทียบกับการตรวจด้วยภาพรังสีแบบอื่นๆ เช่น CT (Computerized Tomography Scan) และ MRI (Magnetic Resonance Imaging Scan) เป็นต้น นอกจากราคาที่ผู้ป่วยสามารถเข้าถึงบริการได้แล้วภาพอัลตราซาวด์ยังมีข้อดีอื่นๆอีกเช่น ปลอดภัย รังสี สดวก ไม่เกิดการระคายเคือง และมีประสิทธิภาพในการตรวจจับและแสดงผลก้อนไทรอยด์ที่สูง ดังนั้นการตรวจต่อมไทรอยด์ด้วยภาพอัลตราซาวด์จึงได้รับการแนะนำให้ถูกนำมาใช้เป็นการตรวจเบื้องต้นก่อนการตรวจชิ้นเนื้อ (Fine-needle aspiration: FNA) การตรวจต่อมไทรอยด์ทั่วไป รวมทั้งการตรวจสอบและวินิจฉัยเพื่อประเมินหลังการผ่าตัดรักษา ด้วยเหตุนี้จากตรวจหา มะเร็งต่อมไทรอยด์ด้วยวิธีอัลตราซาวด์จึงเป็นวิธีที่เหมาะสมสำหรับประชาชนในประเทศที่มีทรัพยากรจำกัดเช่น ประเทศไทย ในการตรวจต่อมไทรอยด์ด้วยวิธีอัลตราซาวด์แบบปกติจะได้ผลลัพธ์ออกมาเป็นภาพอัลตราซาวด์ (Conventional ultrasound imaging) ที่แสดงก้อนไทรอยด์ที่เป็นวัตถุสีดำที่แข็งกว่าเนื้อเยื่อปกติเพียงอย่างเดียว แต่ด้วยเทคโนโลยีที่ทันสมัยทำให้สามารถสร้างภาพเสริมที่มีความสามารถในการตรวจหาก้อนไทรอยด์รวมถึงเซลล์เม็ดเลือด ซึ่งเป็นภาพสีเรียกว่า ภาพ Doppler เป็นการแสดงผลที่อาศัยการเคลื่อนที่ของเซลล์เม็ดเลือดซึ่งส่งผลให้มีการเปลี่ยนแปลงการสะท้อนของคลื่นเสียง โดยปกติแล้วก้อนไทรอยด์ที่ไม่เป็นพิษ (Benign thyroid nodules) จะมีการไหลเวียนของหลอดเลือดเพียงเล็กน้อยหรือไม่มีเลย ซึ่งตรงกันข้ามกับก้อนไทรอยด์ที่เสี่ยงต่อการเป็นมะเร็ง (Malignant thyroid nodules) จะปรากฏการไหลเวียนของเลือดที่เพิ่มขึ้น ดังนั้นการนำภาพ Doppler มาใช้ส่งผลให้การตรวจสอบและวินิจฉัยมีความถูกต้องแม่นยำสูงขึ้น

ในด้านรังสีแพทย์ได้มีการตีพิมพ์ผลงานวิจัยเพื่อยืนยันว่าการใช้ภาพอัลตราซาวด์ร่วมกับภาพ Doppler มีผลให้แพทย์สามารถตรวจวินิจฉัยได้ถูกต้องและแม่นยำกว่าการใช้ภาพอัลตราซาวด์เพียงอย่างเดียว ดังนั้นการนำภาพทั้งสองมาใช้ร่วมกันเพื่อออกแบบ สร้าง และทดสอบโมเดลสำหรับการพัฒนาอัลกอริทึมคอมพิวเตอร์ช่วยวินิจฉัย (Computer aided diagnosis: CAD) ในการตรวจจับและจำแนกก้อนต่อมไทรอยด์ที่เป็นก้อนเนื้อมะเร็งออกจากก้อนเนื้อปกติควรมีประสิทธิภาพสูงขึ้นเช่นกัน นักรังสีวิทยาจึงวินิจฉัยก้อนต่อมไทรอยด์ตามลักษณะที่ปรากฏของ

ก่อนเนื้อในภาพอัลตราซาวด์ ซึ่งความถูกต้องและความรวดเร็วในการตรวจสอบและวินิจฉัยจะขึ้นอยู่กับความเชี่ยวชาญและประสบการณ์ของแพทย์ท่านนั้นๆ เพื่อแก้ปัญหาการขาดแคลนแพทย์เฉพาะทางโดยเฉพาะในโรงพยาบาลต่างจังหวัดหรือในพื้นที่ที่ห่างไกล การพัฒนาระบบคอมพิวเตอร์ช่วยวินิจฉัยสำหรับการจำแนกก้อนต่อมไทรอยด์อัตโนมัติจึงเป็นหนึ่งในทางเลือก การพัฒนาระบบคอมพิวเตอร์ช่วยวินิจฉัยมีองค์ประกอบพื้นฐานด้วยกันสามส่วนคือ การตรวจจับก้อนต่อมไทรอยด์ (Nodule detection) การแยกส่วนที่เป็นลักษณะเฉพาะที่สำคัญของก้อนต่อมไทรอยด์ (Imaging feature extraction) และการจำแนกก้อนต่อมไทรอยด์ระหว่างชนิดดีและชนิดร้าย (Classifier construction)

เนื่องจากก้อนต่อมไทรอยด์มีความแตกต่างกันในส่วนรูปร่าง ขนาด และลักษณะเฉพาะที่สำคัญ ดังนั้นการพัฒนาระบบด้วยคอมพิวเตอร์ช่วยวินิจฉัยแบบดั้งเดิมที่กล่าวไปข้างต้นอาจมีประสิทธิภาพไม่เพียงพอด้วยข้อจำกัดในการจำแนกความแตกต่างของก้อนเนื้อกับชิ้นส่วนโดยรอบในภาพอัลตราซาวด์ที่อาจก่อให้เกิดการตรวจจับและจำแนกที่ผิดพลาดได้เช่น เงาม กล้ามเนื้อ หรือหลอดเลือด เป็นต้น ในทางกลับกันโมเดลการเรียนรู้เชิงลึก (Deep Learning) ด้วยเครือข่ายประสาทเทียม Conventional Neural Networks หรือ CNNs ได้ถูกนำมาใช้อย่างแพร่หลายและมีประสิทธิภาพที่โดดเด่นกว่าวิธีทางด้านการประมวลผลภาพทั่วไป โดยเฉพาะด้านการตรวจจับการจำแนกประเภทของสิ่งของต่างๆภายในรูปภาพ หนึ่งในเทคโนโลยีด้านระบบคอมพิวเตอร์ช่วยวินิจฉัยที่ยังไม่ได้รับการพัฒนาคือแบบจำลองการเรียนรู้เชิงลึกเพื่อใช้ในการตรวจจับและจำแนกชนิดของก้อนต่อมไทรอยด์ระหว่างชนิดดีและร้ายด้วยการใช้ภาพอัลตราซาวด์ร่วมกับภาพ Doppler เนื่องจากผลงานวิจัยที่ใช้ภาพทั้งสองชนิดร่วมกันเผยว่ามีส่วนช่วยในการเพิ่มความถูกต้องในการวินิจฉัยของแพทย์ ดังนั้นการใช้ภาพทั้งสองประเภทเพื่อเป็นอินพุตป้อนให้กับโมเดลการเรียนรู้เชิงลึกด้วยเครือข่ายประสาทเทียม CNNs ควรส่งผลให้ประสิทธิภาพในการจำแนกชนิดของก้อนต่อมไทรอยด์ด้วยโมเดลที่สร้างขึ้นสูงขึ้นเช่นกัน นอกจากโมเดลการเรียนรู้เชิงลึกเพื่อการจำแนกก้อนต่อมไทรอยด์แบบอัตโนมัติที่ถูกพัฒนาขึ้นจะได้รับติดตั้งและใช้งานเป็นระบบหลักที่โรงพยาบาลศิริราชแล้ว เทคโนโลยีด้านการวิเคราะห์และวินิจฉัยภาพด้านการแพทย์ระบบทางไกล (Telegraph diagnosis technology) จะถูกพัฒนาขึ้นมาด้วยเช่นกันเพื่อรองรับการวินิจฉัยในพื้นที่ชนบทหรือในโรงพยาบาลหรือคลินิกที่ขาดแคลนรังสีแพทย์เพื่อลดการสูญเสียที่อาจจะเกิดขึ้นเนื่องจากการวินิจฉัยที่ล่าช้า

โครงการนี้เป็นส่วนหนึ่งของงานวิจัยที่ส่งเสริมเทคโนโลยีด้านการแพทย์และสาธารณสุขอัจฉริยะ (Smart health) ในการวิจัยและพัฒนาออกแบบ สร้างและทดสอบ (Prototype) ของระบบคอมพิวเตอร์ช่วยวินิจฉัยด้วยแบบจำลองการเรียนรู้เชิงลึกเพื่อใช้ในการตรวจจับและจำแนกชนิดของก้อนต่อมไทรอยด์ชนิดดีและร้ายด้วยการใช้ภาพอัลตราซาวด์ร่วมกับภาพ Doppler ให้มีประสิทธิภาพเท่ากับหรือใกล้เคียงกับการวินิจฉัยของรังสีแพทย์ โดยระบบแพลตฟอร์มจะถูกใช้และทดสอบด้วยทีมแพทย์จากโรงพยาบาลศิริราช เทคโนโลยีที่เสนอไปนี้จะมีส่วนช่วยในการเพิ่มความพร้อมของประเทศไทยในการปรับปรุงบริการด้านการแพทย์และสาธารณสุขและอาจมีส่วนช่วยเพิ่มอายุขัยของประชากร

๑.๒ วัตถุประสงค์และขอบเขตของโครงการ

๑. ออกแบบและสร้างแบบจำลองโมเดลตรวจจับและจำแนกก้อนต่อมไทรอยด์ด้วยภาพอัลตราซาวด์และภาพ Doppler
๒. สร้างและทดสอบโมเดลตรวจจับก้อนต่อมไทรอยด์
๓. สร้างและทดสอบโมเดลตรวจจับพร้อมกับการจำแนกชนิดก้อนต่อมไทรอยด์ (ก้อนเนื้อชนิดดีและร้าย)
๔. ออกแบบและใช้งานแพลตฟอร์มสำหรับจัดเก็บและประมวลผลการตรวจจับและจำแนกก้อนต่อมไทรอยด์บนคลาวด์ (Main server and storage server)
๕. การวิจัยตัวชี้วัดเบื้องต้นในการประมวลผลที่มีความผิดพลาดในการจำแนกก้อนต่อมไทรอยด์
๖. ออกแบบและพัฒนาการจัดเก็บและประมวลผลทางไกล (Web-based platform)
๗. ประเมินและทดสอบระบบสำหรับการใช้งานจริง

๑.๓ ประโยชน์ที่คาดว่าจะได้รับ

เป้าหมายในการดำเนินโครงการคือการนำนวัตกรรมที่พัฒนาขึ้นในประเทศมาช่วยในการทำงานด้านสาธารณสุขโดยเฉพาะระบบคอมพิวเตอร์ช่วยวินิจฉัยโดยมีรายละเอียดดังต่อไปนี้

๑. เพื่อสนับสนุนบริการทางการแพทย์และสาธารณสุขนอกจากนี้ยังเพิ่มโอกาสการเข้าถึงบริการสำหรับรังสีแพทย์สามารถใช้งานระบบประเมินก้อนต่อมไทรอยด์แบบทางไกลได้ โดยรังสีแพทย์ที่อยู่โรงพยาบาลในพื้นที่ชนบทหรือแพทย์ชุมชนสามารถเข้าใช้บริการได้ผ่านทางโทรศัพท์มือถือ (mobile application) และ/หรือคอมพิวเตอร์ (web browser) ซึ่งเป็นการเข้าถึงบริการได้ตลอดเวลา (๒๔/๗) ซึ่งการขยายโอกาสให้กับแพทย์หรือรังสีแพทย์สามารถเข้ามาใช้ระบบคอมพิวเตอร์ช่วยวินิจฉัยด้วยแบบจำลองการเรียนรู้เชิงลึกเพื่อใช้ในการตรวจจับและจำแนกชนิดของก้อนต่อมไทรอยด์ชนิดดีและชนิดร้ายด้วยการใช้ภาพอัลตราซาวด์ร่วมกับภาพ Doppler จะเป็นการขยายการเข้าถึงนวัตกรรมทางการแพทย์และสาธารณสุขไม่ให้อยู่จำกัดอยู่ในโรงพยาบาลรัฐใหญ่ๆหรือโรงพยาบาลเอกชน
๒. การลดการพึ่งพาการใช้ซอฟต์แวร์ที่พัฒนาจากต่างประเทศซึ่งอาจส่งผลให้เกิดความกังวลเรื่องความปลอดภัยของข้อมูลที่น่ามาใช้วิเคราะห์ การรักษาความปลอดภัยและอาจเสี่ยงต่อการรั่วไหลของข้อมูลส่วนบุคคลของคนไข้ได้ นอกจากนี้การพัฒนาระบบเฟรมเวิร์คช่วยวิเคราะห์ขึ้นมานี้ในประเทศควรจะส่งผลดีต่อระบบเศรษฐกิจรวมถึงการเพิ่มศักยภาพในการแข่งขันของประเทศไทยในด้านเทคโนโลยีเพื่อการดูแลสุขภาพด้วยปัญญาประดิษฐ์

๑.๔ ผลผลิตสำคัญ

ลำดับ	ชื่อผลผลิต	หน่วยวัด	ตัวชี้วัด (เชิงคุณภาพ/เชิงคุณภาพ)
๑	โมเดลการเรียนรู้เชิงลึก ได้แก่ - Detection model - Classification model	๒ โมเดล	นำโมเดลไปทำนายชุดข้อมูลทดสอบที่ได้รับจาก โรงพยาบาลศิริราช โดยมีค่า - Accuracy ไม่น้อยกว่า ๐.๗๕ (IoU ไม่น้อยกว่า ๐.๕) สำหรับ Detection model - Accuracy ไม่น้อยกว่า ๐.๗๕ (F1-Score) สำหรับ Classification model
๒	เฟรมเวิร์กระบบคอมพิวเตอร์ช่วย วินิจฉัยด้วยแบบจำลองการเรียนรู้ เชิงลึกเพื่อใช้ในการตรวจจับและ จำแนกชนิดของก้อนต่อมไทรอยด์ ชนิดดีและร้ายด้วยภาพ อัลตราซาวด์ร่วมกับภาพ Doppler ที่สามารถใช้ประเมินผล ได้ทั้งภายในและภายนอก โรงพยาบาลศิริราช (Web-based platform)	๑ ระบบ	ผลการประเมินความพึงพอใจในการใช้งานเฟรมเวิร์ก ระบบฯ โดยรังสีแพทย์ที่ร่วมโครงการไม่น้อยกว่าร้อยละ ๖๕%
๓	บทความทางวิชาการในวารสาร ระดับนานาชาติ	๕ ฉบับ	อยู่ในฐานข้อมูล Scopus

บทที่ ๒

ทฤษฎี และงานวิจัยที่เกี่ยวข้อง

๒.๑ ทบทวนวรรณกรรม


ระบบคอมพิวเตอร์ช่วยวินิจฉัยสำหรับประเมินก้อนต่อมไทรอยด์ใช้การผสมผสานระหว่างเทคนิคการตรวจจับก้อนต่อมไทรอยด์และการจำแนกก้อนต่อมไทรอยด์ออกเป็นชนิดดีและร้ายด้วยเทคโนโลยีการเรียนรู้เชิงลึก นอกจากนี้การสร้างชุดฝึกการสอนเพื่อเพิ่มประสิทธิภาพของการเรียนรู้สำหรับโมเดลการเรียนรู้เชิงลึกมีส่วนช่วยในการพัฒนาประสิทธิภาพในการทำนายผลที่ดียิ่งขึ้น ด้วยการวิเคราะห์ด้วยชุดฝึกการเรียนรู้ด้วยภาพอัลตราซาวด์และภาพ Doppler นอกจากนี้การใช้ระบบผ่านแพลตฟอร์มเว็บไซต์ยังช่วยเพิ่มความสะดวกสบาย ความสามารถในการขยายจำนวนผู้ใช้งานและการเข้าถึงแบบเรียลไทม์ ทำให้แพทย์มีเครื่องมือสนับสนุนที่น่าเชื่อถือสำหรับการวินิจฉัยและการตัดสินใจที่สำคัญ ระบบนี้จึงเป็นก้าวสำคัญในการพัฒนาวิธีการวินิจฉัยและตรวจหามะเร็งต่อมไทรอยด์ในระยะแรกได้อย่างมีประสิทธิภาพมากขึ้น

๒.๒ การตรวจวินิจฉัยก้อนต่อมไทรอยด์

มะเร็งต่อมไทรอยด์เป็นโรคมะเร็งที่พบบ่อยที่สุดของต่อมไทรอยด์และมีจำนวนเพิ่มขึ้นสูงเรื่อยๆ โดยก้อนต่อมไทรอยด์ (Thyroid nodules) สามารถตรวจพบได้ประมาณ ๑๙% ถึง ๖๘% จากการสุ่มตรวจกลุ่มประชากรด้วยวิธีอัลตราซาวด์ (ultrasound) นอกจากนี้มะเร็งต่อมไทรอยด์ (Thyroid cancer) ยังเป็นหนึ่งในมะเร็งต่อมไทรอยด์ที่พบบ่อยที่สุดและพบว่ามีอัตราการเสี่ยงต่อการเป็นมะเร็งสูงขึ้นทั่วโลกในช่วง ๓๐ ปีที่ผ่านมา (HaugenBryan et al., ๒๐๑๖) ในประเทศไทยมีผู้ป่วยมะเร็งต่อมไทรอยด์รายใหม่สูงขึ้นเรื่อยๆ และพบว่าในประเทศไทยพบว่ามีมะเร็งต่อมไทรอยด์ถูกจัดเป็นหนึ่งในสิบมะเร็งที่พบบ่อยที่สุดในผู้หญิงโดยมีโอกาสดังกล่าวเกิดขึ้นได้ในทุกช่วงอายุ (เบญจวรรณ สำราญ วานิช, ๒๐๑๙) จากการสำรวจพบว่านอกข้อจำกัดในด้านการให้บริการด้านการแพทย์และสาธารณสุขแล้ว อายุเฉลี่ยในการเกิดมะเร็งของประชากรในประเทศที่กำลังพัฒนาหรือมีทรัพยากรที่จำกัด (Low Resource Countries: LRCs) เช่นประเทศไทย พบว่าประชากรที่ตรวจพบว่าเป็นมะเร็งจะมีอายุเฉลี่ยน้อยกว่าประเทศที่พัฒนาแล้วประมาณ ๑๐ ปี (Shetty, M.K., ๒๐๑๑) ดังนั้นการตรวจต่อมไทรอยด์เป็นประจำอาจช่วยป้องกันและรักษาผู้ป่วยในระยะแรกได้ซึ่งเป็นระยะที่มีโอกาสรักษาให้หายขาดได้ ด้วยเหตุนี้การตรวจก้อนต่อมไทรอยด์เบื้องต้นด้วยภาพอัลตราซาวด์จึงถูกนำมาใช้อย่างแพร่หลายเนื่องจากมีราคาค่อนข้างถูกเมื่อเทียบกับการตรวจด้วยภาพรังสีแบบอื่นๆ เช่น CT (Computerized Tomography Scan) และ MRI (Magnetic Resonance Imaging Scan) เป็นต้น

แนวทางการตรวจวินิจฉัยและรักษาโรคมะเร็งต่อมไทรอยด์แสดงดังรูปที่ ๑ จะเริ่มจากซักประวัติผู้ป่วยและตรวจร่างกายพื้นฐานโรคก่อนที่ต่อมไทรอยด์มักไม่มีอาการ การตรวจพบมักจะเป็นการพบโดยบังเอิญทั้งจากตัวผู้ป่วยเอง จากแพทย์หรือการทำการตรวจทางรังสีด้วยวัตถุประสงค์อื่น อย่างไรก็ตามเมื่อตรวจพบว่ามีก้อนที่ต่อมไทรอยด์ควรเริ่มด้วยการซักประวัติและตรวจร่างกายเพื่อหาสาเหตุของก้อนและ เน้นประวัติและตรวจร่างกายที่ ชี้บ่งถึงมะเร็งไทรอยด์ ประวัติอื่นๆ ที่ควรซักถามเพื่อหาสาเหตุของก้อนได้แก่ ประวัติถิ่นที่อยู่ โรคไทรอยด์ก่อนหน้านี้นี้

ประวัติยาที่ใช้ร่วมด้วยซึ่งอาจมีผลต่อการทำงานของต่อมไทรอยด์ได้แก่ ยา Lithium, ไอโอดีน, Interferon, และ amiodarone เป็นต้น ตลอดจนควรสอบถามอาการที่บ่งชี้ถึงภาวะไทรอยด์เป็นพิษหรือภาวะพร่องฮอร์โมนไทรอยด์ ผู้ป่วยโรคก่อนที่ต่อมไทรอยด์ที่มีประวัติครอบครัวของโรคต่อไปนี้เสี่ยงต่อการเกิดมะเร็งไทรอยด์ได้แก่ โรค Multiple endocrine neoplasia ชนิดที่ ๒ (MEN 2) โรค Familial medullary thyroid carcinoma (MTC), familial papillary thyroid tumors, familial polyposis coli, Cowden disease, และ Gardner syndrome



รูปที่ ๑: แนวทางการตรวจวินิจฉัยและรักษาโรคมะเร็งต่อมไทรอยด์
(สมจินต์ จินดาวิจักษ์ณ์, ๒๐๑๕)

หากเกิดความผิดปกติหรือข้อสงสัยจากการซักประวัติและตรวจร่างกายคนไข้จะถูกแนะนำให้ตรวจก่อนต่อมไทรอยด์ด้วยเครื่องอัลตราซาวด์ชนิด Gray scale ที่มีหัวอ่านความถี่สูงโดยเฉพาะสูงกว่า ๗.๕ MHz มีความไวสูงเหมาะสำหรับการตรวจต่อมไทรอยด์วัตถุประสงค์การตรวจวิธีนี้เพื่อยืนยันว่ามีก้อนของต่อมไทรอยด์จริงและสามารถใช้บอกจำนวนก้อน เนื่องจากร้อยละ ๕๐ ของต่อมไทรอยด์ที่ตรวจร่างกายพบเป็นก้อนเดี่ยว เมื่อทำการ

ตรวจด้วยเครื่องอัลตราซาวด์จะพบก้อนอื่นๆ อีก นอกจากนี้เครื่องอัลตราซาวด์ใช้ในการบอก ตำแหน่ง ขนาด ขอบเขต ลักษณะเนื้อในก้อนหาปริมาณเลือดที่มาเลี้ยงด้วยการตรวจด้วย Doppler color flow และหาตำแหน่งที่เหมาะสมสำหรับการเจาะตรวจ การตรวจด้วยเครื่องอัลตราซาวด์มีความไวในการบ่งชี้ถึงความเสี่ยงต่อการเกิดมะเร็งได้ดี ซึ่งโครงการวิจัยคัดกรองมะเร็งต่อมไทรอยด์ด้วยภาพอัลตราซาวด์ได้ถูกคิดค้นเพื่อช่วยในการตรวจคัดกรองต่อมไทรอยด์ทั้งในเรื่องความถูกต้องและเวลาที่ใช้ในการวินิจฉัย ซึ่งสามารถใช้เป็นเครื่องมือในการช่วยให้รังสีแพทย์ทำงานได้อย่างมีประสิทธิภาพ


หากรังสีแพทย์วินิจฉัยว่าก้อนเนื้อที่ต่อมไทรอยด์มีความผิดปกติถึงขั้นเกิดอุบัติการณ์มะเร็งการตรวจระดับฮอร์โมนจะถูกแนะนำให้คนไข้ ซึ่งขั้นตอนที่เกิดขึ้นจากกระบวนการนี้และถัดไปจะอยู่นอกเหนือขอบเขตจากงานวิจัยนี้ โรคก้อนที่ต่อมไทรอยด์อาจจะสัมพันธ์กับการมีความผิดปกติของการทำงานของต่อมไทรอยด์ จากข้อมูลทางระบาดวิทยาในปี ค.ศ. ๒๐๐๐-๒๐๐๙ พบว่าผู้ป่วยโรคก้อนที่ต่อมไทรอยด์ที่มี TSH สูงจะมีสัดส่วนการเกิดมะเร็งต่อมไทรอยด์มากกว่า และเป็นรุนแรงกว่าผู้ที่โรคก้อนที่ต่อมไทรอยด์ที่มีระดับ TSH ปกติ ขณะเดียวกันผู้ป่วยที่มีค่า TSH ต่ำบ่งชี้ถึงภาวะไทรอยด์เป็นพิษ สามารถเกิดได้จากโรคไทรอยด์เป็นพิษชนิด Graves' disease ร่วมกับมีก้อนเดี่ยว ซึ่งอาจจะมีมะเร็งซ่อนอยู่ หรือเป็นโรคก้อนเดี่ยวที่ก้อน นั้นสร้างและหลั่งฮอร์โมนมากเกินไป (toxic adenoma) ทั้งสองภาวะนี้สามารถวินิจฉัยแยกโรคต่อไปด้วยการ ส่งตรวจทางรังสีนิวเคลียร์เพื่อดูความสามารถในการจับไอโอดีนรังสีของก้อนเทียบกับเนื้อต่อมไทรอยด์ใกล้เคียง (thyroid scintigraphy) จะพบเป็น hot nodule กรณี toxic adenoma ซึ่งโอกาสเป็นมะเร็งน้อยมากไม่จำเป็นต้องส่งตรวจทางเซลล์วิทยาต่อไป

หากรังสีแพทย์วินิจฉัยว่าก้อนเนื้อที่ต่อมไทรอยด์มีความผิดปกติถึงขั้นเกิดอุบัติการณ์มะเร็ง การตรวจทางเซลล์วิทยาด้วยเข็มขนาดเล็ก (Fine needle aspiration and biopsy, FNAB) การวินิจฉัยทางเซลล์วิทยาของไทรอยด์มีโอกาสผิดพลาดได้โดยเฉลี่ยร้อยละ 5 สาเหตุเกิดได้ทั้ง จากการเจาะเซลล์ไม่ตรงตำแหน่งที่เสี่ยงต่อมะเร็ง เช่นก้อนที่มีทั้งน้ำและเนื้อ ก้อนที่มีหลายก้อน หรือการเจาะ ก้อนขนาดใหญ่โดยพบว่าโอกาสผิดพลาดจะสูงขึ้นหากเจาะดูเซลล์ในก้อนที่มีขนาดมากกว่าหรือเท่ากับ ๔ เซนติเมตร พบว่าการตรวจโดยใช้เครื่องอัลตราซาวด์นำทางสามารถลดการอ่านผลผิดพลาดได้ ดังนั้นจึงแนะนำให้ใช้กรณีต่อไปนี้คลำก้อนได้ไม่ชัด ก้อนอยู่ด้านหลังของต่อมไทรอยด์ก้อนเป็นลักษณะน้ำ ปนเนื้อ ผู้ป่วยที่มีหลายก้อน ผู้ป่วยที่คอสั้น มีกล้ามเนื้อคอมาก ตลอดจนการเจาะต่อมน้ำเหลือง และการเจาะซ้ำในก้อนที่ไม่สามารถอ่านผลจากการเจาะครั้งก่อน ในการตรวจทางเซลล์วิทยาของต่อมน้ำเหลือง การส่งโปรตีนไทโรโกลบูลิน (Thyroglobulin) และแคลซิโตนิน (Calcitonin) จากน้ำเกลือล้างหัวเข็มที่ได้จากการเจาะต่อมน้ำเหลืองจะเพิ่มความไวในการวินิจฉัยโรคมะเร็งไทรอยด์แพร่กระจายมาที่ต่อมน้ำเหลืองได้


จากแนวทางการตรวจวินิจฉัยและรักษาโรคมะเร็งต่อมไทรอยด์ (สมจินต์ จินดาวิจักขณ์, ๒๐๑๕) ได้แนะนำให้ไว้ว่าควรทำการตรวจอัลตราซาวด์ผู้ป่วยทุกรายที่มีปัญหาก้อนของต่อมไทรอยด์ทั้งที่คลำได้และคลำไม่ได้แต่ตรวจพบก้อนของต่อมไทรอยด์โดยบังเอิญเพราะพบว่าอัตราการเกิดของมะเร็งไม่ลดลงแม้ก้อนจะมีขนาดเล็กกว่า ๑๐ มิลลิเมตร ดังนั้นแม้ก้อนที่มีขนาดเล็กแต่ถ้ามีลักษณะทางอัลตราซาวด์ที่สงสัยว่าเป็นมะเร็งควรทำการเจาะตรวจทางเซลล์วิทยาต่อไป และในทางกลับกันหากก้อนที่มีขนาดเล็กกว่า ๑๐ มิลลิเมตร คลำไม่ได้และไม่มีลักษณะที่สงสัยว่าเป็นมะเร็งสามารถติดตามด้วยการทำอัลตราซาวด์โดยไม่ต้องส่งตรวจทางเซลล์วิทยา


การตรวจทางรังสีวิทยาอื่นๆ ได้แก่ การตรวจเอกซเรย์ปอด การตรวจด้วยเอกซเรย์คอมพิวเตอร์(CT scan) หรือการตรวจ ด้วยคลื่นแม่เหล็ก(MRI) ไม่แนะนำให้ทำการตรวจในผู้ป่วยทุกรายเนื่องจากความไวในการวินิจฉัย ทำนายการเกิดมะเร็งไม่ดีนัก ควรทำกรณีต้องการวินิจฉัยก่อนมีขนาดโตกดเบียดอวัยวะช่องอกใช้ในการวัดขนาด สำหรับการตรวจด้วยเอกซเรย์คอมพิวเตอร์มีข้อควรระวังในผู้ป่วยซึ่งมีก้อนของต่อมไทรอยด์ชนิดหลายก้อน และมีระดับ TSH ต่ำเพราะสารไอโอดีนที่บีบสีที่ฉีดเข้าไปอาจจะทำให้เกิดภาวะไทรอยด์เป็นพิษได้

(ก)



(ข)






รูปที่ ๒: ตัวอย่างข้อมูลนิรนาม

(ก) ภาพอัลตราซาวด์ (ข) ภาพอัลตราซาวด์ที่ปรากฏ caliper marks และ (ค) ภาพ Doppler

การประเมินก้อนต่อมไทรอยด์ที่ถูกพบอย่างเร่งด่วนและมีความถูกต้องแม่นยำสูงจึงมีความสำคัญอย่างยิ่งเพื่อตรวจวิเคราะห์หาความเป็นไปได้ที่ก้อนเนื้อนั้นจะสามารถพัฒนาเป็นมะเร็งได้มากน้อยเพียงใด เมื่อพิจารณาจากการศึกษาที่ผ่านมา มีเพียงส่วนน้อยที่ก้อนต่อมไทรอยด์อาจพัฒนาเป็นมะเร็งได้ และหากก้อนต่อมไทรอยด์ถูกตรวจพบเร็วจะส่งผลให้ได้รับการรักษาทันทั่วที่ลดโอกาสการเสียชีวิตของประชากรได้ การตรวจก้อนต่อมไทรอยด์ด้วยเทคโนโลยีภาพอัลตราซาวด์เป็นเครื่องมือวินิจฉัยที่ไม่เป็นอันตรายเนื่องจากปลอดภัยจากรังสีและราคาที่ไม่สูงมาก จากรูปที่ ๒ แสดงตัวอย่างข้อมูลนิรนามของภาพอัลตราซาวด์ที่ปรากฏและไม่ปรากฏ Caliper marks ในรูปที่ ๒ (ก) และ (ข) และ ข้อมูลนิรนามของภาพ Doppler แสดงดังรูปที่ ๓ (ค) ด้วยเทคโนโลยีที่ทันสมัยทำให้สามารถสร้างภาพเสริมที่มีความสามารถในการตรวจหาก้อนต่อมไทรอยด์รวมถึงเซลล์เม็ดเลือด ซึ่งจะถูกระบุว่าภาพ Doppler เป็นการแสดงผลที่อาศัยการเคลื่อนที่ของเซลล์เม็ดเลือดซึ่งส่งผลให้มีการเปลี่ยนแปลงการสะท้อนของคลื่นเสียง (Yamakoshi et al., ๒๐๑๖) โดยปกติแล้วก้อนต่อมไทรอยด์ที่ไม่เป็นพิษ (Benign thyroid nodules) จะมีการไหลเวียนของหลอดเลือดเพียงเล็กน้อยหรือไม่มีเลย ซึ่งตรงกันข้ามกับก้อนต่อมไทรอยด์ที่เสี่ยงต่อการเป็นมะเร็ง (Malignant thyroid nodules) จะปรากฏการไหลเวียนของเลือดที่เพิ่มขึ้น ดังนั้นการนำภาพ Doppler มาใช้ส่งผลให้การตรวจสอบและวินิจฉัยมีความถูกต้องแม่นยำสูงขึ้น (Moon et al., ๒๐๐๐; Ibrahim et al., ๒๐๑๖)

๒.๓ ระบบคอมพิวเตอร์ช่วยวินิจฉัยสำหรับประเมินก้อนต่อมไทรอยด์

ประเทศไทยเป็นหนึ่งในประเทศชั้นนำทางด้านบริการสุขภาพทั้งในทางคุณภาพและราคาที่เหมาะสม อย่างไรก็ตาม จำนวนบุคลากรทางการแพทย์ที่ผลิตได้ยังถือว่าไม่เพียงพอต่อจำนวนประชากร โดยเฉพาะอย่างยิ่งผู้เชี่ยวชาญในสาขาเฉพาะทาง รังสีแพทย์เป็นหนึ่งในศาสตร์ที่ต้องอาศัยความชำนาญในการอ่านและแปลผลภาพรังสีในแบบต่างๆ ซึ่งมีความสำคัญอย่างยิ่งต่อความเข้าใจในสภาวะของผู้ป่วย งานของรังสีแพทย์จึงมีบทบาทสำคัญทั้งในเชิงป้องกัน การวินิจฉัย รวมถึงการรักษาโรคในการทำงานบ่อยครั้งรังสีแพทย์ประเมินภาพทางการแพทย์ด้วยสายตา ซึ่งบางครั้งจำเป็นจะต้องอ่านและแปลผลภาพรังสีปริมาณมากในช่วงเวลาจำกัด หรือทำงานต่อเนื่องเป็นเวลานานรังสีแพทย์อาจเกิดความเมื่อยล้าทางสายตาและสมองซึ่งอาจส่งผลต่อการวิเคราะห์ความผิดปกติต่างๆ ที่อาจเกิดกับคนไข้ได้ การนำรังสีแพทย์มากกว่าหนึ่งท่านเพื่อช่วยในการตรวจวิเคราะห์อาจเพิ่มความถูกต้องแม่นยำในการวิเคราะห์ แต่จากสภาวะการปัจจุบันที่ขาดแคลนบุคลากรทางการแพทย์ในหลายพื้นที่จึงเป็นแนวคิดที่ยากจะนำไปปฏิบัติได้จริง ด้วยเหตุนี้เครื่องมือทางคอมพิวเตอร์จึงเป็นสิ่งที่เข้ามามีบทบาทสำคัญในการช่วยรังสีแพทย์ทำการวินิจฉัย และสามารถลดความผิดพลาดในการแปลผลได้อย่างมีนัยยะสำคัญ ตลอดจนขยายขีดความสามารถในการดำเนินการอีกด้วย นอกจากนี้ด้วยสาเหตุที่จำนวนของรังสีแพทย์ที่มีความเชี่ยวชาญไม่เพียงพอ อันอาจจะทำให้เกิดความล่าช้าในการเข้าถึงรังสีแพทย์ อาทิเช่น ในพื้นที่ห่างไกล โรงพยาบาลขนาดเล็ก เป็นต้น การใช้เครื่องมือเพื่อช่วยแปลผลภาพรังสี (Computer Aided Diagnosis: CAD) ประกอบกับผลทางคลินิกสามารถเข้ามามีส่วนช่วยแพทย์ในการวินิจฉัยเบื้องต้นได้




รูปที่ ๓: คอมพิวเตอร์ช่วยวินิจฉัยก้อนต่อมไทรอยด์ด้วยภาพอัลตราซาวด์

(S-Detect for Thyroid Samsung Medison Co., Choi et al., ๒๐๑๗)

จากรูปที่ ๓ แสดงเครื่องมือในการช่วยแปลผลก้อนต่อมไทรอยด์ด้วยภาพอัลตราซาวด์โดยส่วนใหญ่แล้วจะอิงอยู่กับเทคนิคในการพัฒนาโปรแกรมที่เรียกว่าปัญญาประดิษฐ์ (Artificial Intelligence: AI) ประกอบด้วยอัลกอริทึมสำหรับตรวจจับก้อนต่อมไทรอยด์และจำแนกก้อนต่อมไทรอยด์ ถูกนำมาใช้อย่างหลากหลายและมีแนวโน้มการนำไป

ประยุกต์ใช้อย่างมากในอนาคต โดยเฉพาะอย่างยิ่งการนำมาใช้กับภาพรังสีทางการแพทย์ (Medical Imaging) ซึ่งเป็นหนึ่งในสาขาที่จะได้รับผลกระทบอย่างมีนัยสำคัญจากความก้าวหน้าด้านการวิเคราะห์ภาพรังสีทางการแพทย์ เพื่อสนับสนุนการวินิจฉัยของแพทย์ ตัวอย่างเช่น การวิเคราะห์ความผิดปกติของก้อนต่อมไทรอยด์ด้วยภาพอัลตราซาวด์ การวิเคราะห์ชิ้นดของก้อนต่อมไทรอยด์ ดังแสดงในรูปที่ ๓ ที่ทำนายว่า Possibly Malignant ซึ่งมีส่วนทำให้การวินิจฉัยมีประสิทธิภาพและรวดเร็วมากขึ้นอาจช่วยป้องกันการเกิดมะเร็งต่อมไทรอยด์ได้ การตรวจพบสิ่งผิดปกติในระยะเริ่มต้นจะช่วยให้ผู้ป่วยมีโอกาสรับการรักษาได้ทันทั่วทั้งที่ก่อนที่จะโรครุนแรงหรือเป็นอันตรายถึงชีวิต

๒.๔ การเรียนรู้เชิงลึก




รูปที่ ๔: คุณสมบัติของการเรียนรู้เชิงลึก
(PTT Expresso (Express Solution), ๒๕๖๐)

Deep learning เริ่มเป็นที่รู้จักได้รับการยอมรับในประสิทธิภาพการประมวลผลชุดข้อมูลมหัต (Big data) ที่เรียกว่า Digit dataset เพื่อจำแนกประเภทของรูปภาพตัวเลข ๐ ถึง ๙ ที่เขียนด้วยมือ (LeCun, Bengio, and Hinton, ๒๐๑๓) และได้รับความนิยมเป็นอย่างมากในช่วงหลายปีที่ผ่านมา และมักจะถูกนำไปใช้ในการประมวลผลชุดข้อมูลในการจัดประเภทภาพ (Image classification), การทำนายทิศทางของตลาด (Market predictions), การจดจำคำพูดและใบหน้า (Automatic speech and face recognitions), การประมวลผลภาษาธรรมชาติ (Natural language processing), และงานด้านชีวสารสนเทศ (Bioinformatics) การเรียนรู้เชิงลึก (Deep learning) นั้น เป็นหนึ่งในเทคโนโลยีด้านปัญญาประดิษฐ์ (Artificial Intelligence) และถูกจัดอยู่ในหมวดหมู่ของการเรียนรู้ของเครื่อง (Machine Learning) แสดงดังรูปภาพที่ ๔

ปัญญาประดิษฐ์ คือโปรแกรมคอมพิวเตอร์ที่มีความสามารถในการเลียนแบบความฉลาดของมนุษย์ เรียนรู้ในด้านของกระบวนการคิด การกระทำ การให้เหตุผล การปรับตัว หรือการอนุมาน และการทำงานของสมอง หนึ่งในตัวอย่างของการนำเทคโนโลยีปัญญาประดิษฐ์มาประยุกต์ใช้ทางการแพทย์ได้แก่ ระบบคอมพิวเตอร์ช่วยวินิจฉัย Computer-Aided Diagnosis (CAD) ซึ่งเป็นระบบที่ใช้คอมพิวเตอร์เพื่อช่วยแพทย์ในการวินิจฉัยโรคหรือภาวะต่าง ๆ โดยการวิเคราะห์ข้อมูลทางการแพทย์ (Doi, ๒๐๐๗) เช่น การนำ CAD มาใช้กับภาพอัลตราซาวด์สำหรับวินิจฉัยก้อนเนื้ออกต่อมไทรอยด์เป็นการเพิ่มความแม่นยำในการประเมินลักษณะของก้อนเนื้ออก ไม่ว่าจะเป็นขนาด รูปร่าง ขอบเขต และลักษณะของเนื้อเยื่อ ซึ่งช่วยให้แพทย์สามารถตัดสินใจได้ดียิ่งขึ้นในการแยกระหว่างเนื้ออกชนิดดีและเนื้ออกชนิดร้าย ข้อดีของการใช้ CAD คือสามารถช่วยในการตรวจหาความผิดปกติที่อาจไม่สามารถมองเห็นได้ด้วยตาเปล่าและช่วยลดโอกาสในการวินิจฉัยผิดพลาดได้อย่างมาก (Wang และ Wei, ๒๐๒๑)

การเรียนรู้เชิงลึกเป็นส่วนหนึ่งของเทคโนโลยีด้านการเรียนรู้ของเครื่องที่สร้างมาเพื่อให้สอนคอมพิวเตอร์ได้เรียนรู้ด้วยตัวเอง และสามารถพัฒนาอัลกอริทึมที่สร้างขึ้นจากการป้อนข้อมูลมหัต การเรียนรู้เชิงลึกเป็นแนวคิดที่เลียนแบบการทำงานของระบบโครงข่ายประสาทของสมองมนุษย์ ใช้ในการเรียนรู้และแก้ไขปัญหา สามารถตัดสินใจได้ใกล้เคียงกับมนุษย์ ประกอบด้วย input layer, hidden layers และ output layer ทุก layer มีเซลล์ประสาท (Neuron) ที่เชื่อมโยงกันเป็นแบบโครงข่าย (Network) โดยเรียกว่า หรือโครงข่ายประสาทเทียม (Artificial Neural Network) ซึ่งเป็นแบบจำลองที่เกิดจากฟังก์ชันที่เรียกว่า Activation Function ที่นำผลรวมของเวกเตอร์ inputs $\{x_1, x_2, x_3\}$ กับ เวกเตอร์ weights $\{w_1, w_2, w_3\}$ มาคำนวณจนได้ output y ซึ่ง Activation Function ที่นำมาคำนวณสามารถแบ่งได้เป็นเชิงเส้นและไม่เชิงเส้น (KonjicAdmir, Jahić, และ Jahić, ๒๐๑๗) ตามแต่เลือกมาเพื่อความเหมาะสมกับการแก้ไขปัญหา แสดงดังรูปภาพที่ ๓



รูปที่ ๕ Single Neural Network

(Kushwaha, ๒๐๒๑)

การเรียนรู้ข้อมูลที่มีลักษณะแบบไม่สมดุลได้มีใช้โมเดลการเรียนรู้เชิงลึกมากมาย (Chen et al., ๒๐๑๘, Nikolas et al., ๒๐๑๘, Salman et al., ๒๐๑๘) แนวความคิดที่นำมาใช้แก้ปัญหาส่วนมากจะเกี่ยวกับการสุ่มโดยใช้หลักการทางคณิตศาสตร์เช่น การเรียนรู้ดีฟิเนียลที่มีประสิทธิภาพ (Jeatrakul et al., ๒๐๑๐) หรือจัดการกับเครือข่ายประสาทที่เสริมกันในฐานะเทคนิคการลดขนาดตัวอย่างและรวมกับการเติมข้อมูลแบบ SMOTE เพื่อสมดุลข้อมูล (Zhou et al., ๒๐๐๖) ศึกษาการเรียนรู้โดยการเรียนรู้สำหรับเครือข่ายประสาทความไวต่อพีเจอร์ในโครงข่ายประสาทเทียมที่มีความลึกและพารามิเตอร์ต้นทูนถูกปรับโครงข่ายมีประสิทธิภาพสูง หรือการทำการเรียงลำดับจำนวนของภาพฟอร์กราวด์และพื้นหลังเพื่อเรียนรู้เครือข่ายประสาทเชิงคอนโวลูชัน (CNN) สำหรับการจำแนกวัตถุ (Hand et al., ๒๐๑๘) เป็นต้น

Deep Neural Network (DNN) คือโครงข่ายประสาทเทียมเชิงลึก ที่มีการเพิ่มขึ้น Hidden layers เข้าไปจำนวนมาก เพื่อให้ระบบมีความสามารถในการแก้ปัญหาที่มีความซับซ้อนยิ่งขึ้น เช่น ระบบจดจำใบหน้า (Face recognition) แอปพลิเคชันแปลภาษาไทยเป็นภาษาอังกฤษ (Text translation) และ รถยนต์อัตโนมัติ (Autonomous car) เป็นต้น

Convolutional Neural Network (CNN) คือ โครงข่ายประสาท Convolution หนึ่งในอัลกอริทึมยอดนิยมของโครงข่ายประสาทเทียมเชิงลึก จะนิยมในงานการจัดประเภทภาพ (image classification) เป็นการทำให้คอมพิวเตอร์มีการเรียนรู้เพื่อเลียนแบบการมองของมนุษย์ ซึ่งมนุษย์จะมองภาพเป็นที่ย่อย ๆ ในการแยกคุณลักษณะ (feature) ของพื้นที่ภาพนั้น เช่น เส้นขอบ พื้นสี หรือจุดตัดภายในพื้นที่ภาพที่สนใจในบริเวณรอบ ๆ มาประกอบกัน (Keatmanee et al., ๒๐๒๐) อธิบายด้วยรูปภาพที่ 4 โดยขั้นตอนหลักการสร้างโมเดล CNN นั้น มีอยู่ประมาณ ๔ ขั้นตอน


๑. Convolution คือการหาลักษณะของ feature ภายในรูปภาพ เช่น ขอบ เส้น มาคำนวณกับตัวคำนวณที่เรียกว่า filter จนได้ feature maps

๒. Pooling คือการลดขนาดรูปภาพ แต่ยังคงรายละเอียดของภาพได้อย่างสมบูรณ์ สามารถใช้วิธีดิงได้ทั้งค่า max แล้วค่า mean

๓. Flatten คือการทำให้ค่ารูปภาพให้เป็น array ๑ มิติ เพื่อนำส่งคำนวณในขั้นตอนต่อไป

ซึ่งขั้นที่ ๑ -๓ เป็นการทำ Feature Extraction หรือการสกัดคุณลักษณะที่สำคัญที่มีผลต่อประสิทธิภาพการทำงานของโมเดล CNN

๔. Fully connected คือการสร้างโครงสร้างประสาทเทียม เพื่อสร้างแบบจำลองในการใช้หาค่า wight จากการคำนวณค่า feature เพื่อใช้ในการทำนายอายุกระดูกที่แสดงในรูปที่ ๖



รูปที่ ๖: Convolutional Neural Network สำหรับประมวลผลข้อมูลทางการแพทย์

๒.๔.๑ การพัฒนาโมเดลสำหรับตรวจจับก้อนต่อมไทรอยด์

การตรวจจับก้อนต่อมไทรอยด์ด้วยเทคนิคการเรียนรู้เชิงลึกได้รับความนิยมอย่างกว้างขวางในช่วงไม่กี่ปีที่ผ่านมา เนื่องจากความสามารถในการวิเคราะห์ภาพทางการแพทย์ที่ซับซ้อนได้อย่างแม่นยำ งานวิจัยส่วนใหญ่ใช้โมเดลเชิงลึก เช่น Convolutional Neural Networks (CNNs) เพื่อสกัดคุณลักษณะจากภาพอัลตราซาวด์ของต่อมไทรอยด์ (Feature extraction) โมเดลที่ได้รับการพัฒนามักถูกฝึกด้วยชุดข้อมูลขนาดใหญ่และอาศัยการประมวลผลภาพเบื้องต้น เช่น การปรับคอนทราสต์หรือการลบสัญญาณรบกวน นอกจากนี้ การปรับแต่งโมเดล เช่น การใช้ Transfer Learning หรือ Attention Mechanism ช่วยเพิ่มประสิทธิภาพในการตรวจจับ งานวิจัยหลายชิ้นรายงานความแม่นยำ (Accuracy) และค่าความไว (Sensitivity) ที่สูงเกิน 90% อย่างไรก็ตาม

ตารางที่ ๑: การเรียนรู้เชิงลึกเพื่อตรวจจับประเภทก้อนต่อมไทรอยด์

No.	Date of publication	Topic
๑	๒๐๑๘	ThyNet: A lightweight CNN for thyroid nodule segmentation (Sun et al., ๒๐๑๘) ➤ Utilized CNNs for feature extraction from thyroid ultrasound images. ➤ Demonstrated high accuracy in distinguishing malignant from benign nodules. ➤ Explored the impact of transfer learning in medical imaging.

No.	Date of publication	Topic
୨	୨୦୧୯	ThyNet: A lightweight CNN for thyroid nodule segmentation. (Park et al., ୨୦୧୯) ➤ A lightweight CNN model specifically designed for thyroid ultrasound images. ➤ Integrated multi-scale feature extraction for nodule localization. ➤ Achieved real-time processing for clinical settings.
୩	୨୦୧୯	Thyroid ultrasound image segmentation using U-Net (Huang et al., ୨୦୧୯) ➤ Employed U-Net architecture for precise thyroid gland segmentation. ➤ Improved segmentation in small nodules and irregular shapes.
୪	୨୦୨୦	Improved sensitivity in detecting small and low-contrast nodules (Li et al., ୨୦୨୦) ➤ Improved sensitivity in detecting small and low-contrast nodules. ➤ Reduced false positives by learning contextual features.
୫	୨୦୨୦	DenseNet for thyroid nodule classification in ultrasound images (Zhang et al., ୨୦୨୦) ➤ Optimized feature reuse to reduce model complexity. ➤ Achieved superior performance on small datasets.
୬	୨୦୨୧	Hybrid deep learning for thyroid segmentation (Luo et al., ୨୦୨୧) ➤ Combined ResNet for feature extraction and U-Net for segmentation. ➤ Enhanced robustness across diverse ultrasound image qualities.
୭	୨୦୨୧	Thyroid capsule-aware detection using attention mechanisms (Yang et al., ୨୦୨୧) ➤ Used capsule networks to retain spatial hierarchies in nodules. ➤ Incorporated attention modules for focusing on relevant regions.
୯	୨୦୨୨	Multi-scale thyroid nodule detection in ultrasound images (Wu et al., ୨୦୨୨)

No.	Date of publication	Topic
๙	๒๐๒๒	Ensemble learning for thyroid ultrasound image analysis." Computers in Biology and Medicine (Chen et al., ๒๐๒๒) ➤ Combined multiple CNN models for robust thyroid segmentation. ➤ Improved performance through ensemble averaging.

๒.๔.๒ การพัฒนาโมเดลสำหรับจำแนกก้อนต่อมไทรอยด์

จุดเด่นของเทคโนโลยีด้าน AI คือสามารถวิเคราะห์ภาพทางการแพทย์เพื่อหารูปแบบในการวิเคราะห์ได้อย่างอัตโนมัติ ใช้เวลาในการประมวลผลที่รวดเร็ว ตลอดจนเทคนิคโครงข่ายประสาทเทียมที่เรียกว่า CNN ซึ่งทำให้ความแม่นยำในการแปลผลมีพัฒนาการอย่างก้าวกระโดด ในบางผลการศึกษาพบว่าความแม่นยำสูงกว่าแพทย์ผู้เชี่ยวชาญที่มีประสบการณ์หลายปี อย่างไรก็ตามการนำเทคโนโลยีมาใช้ให้เกิดประโยชน์สูงสุดยังจำเป็นต้องพึ่งพาความชำนาญเฉพาะด้านของบุคลากรทางการแพทย์ในโดยอาศัยความรู้ความชำนาญและประสบการณ์ในการวิเคราะห์และวินิจฉัย ดังนั้นการพัฒนาเทคโนโลยีด้านปัญญาประดิษฐ์เพื่อใช้ด้านการแพทย์จะเป็นการทำงานแบบประสานประสานระหว่างทีมแพทย์และเทคนิคด้านปัญญาประดิษฐ์เพื่อพัฒนาผลิตภัณฑ์และบริการให้มีประสิทธิภาพสูงสุด ความท้าทายยังคงอยู่ที่การจัดการข้อมูลที่ไม่สมดุล (Data Imbalance) และความหลากหลายของภาพจากผู้ป่วยในพื้นที่ต่าง ๆ การวิจัยในอนาคตควรมุ่งเน้นการพัฒนาโมเดลที่ปรับตัวได้ดีในสถานการณ์ จากการทบทวนวรรณกรรมการนำเทคโนโลยีการเรียนรู้เชิงลึกด้วยเทคนิคโครงข่ายประสาทเทียมมาใช้เพื่อตรวจสอบและจำแนกประเภทของก้อนต่อมไทรอยด์แสดงตารางที่ ๒

ตารางที่ ๒: การเรียนรู้เชิงลึกเพื่อจำแนกประเภทก้อนต่อมไทรอยด์

No.	Date of publication	Topic
๑	๒๐๑๙	Lightweight Residual Network for The Classification of Thyroid Nodules (Nihila et al., ๒๐๑๙) ➤ It is a short paper with minimal data
๒	๒๐๑๙	Deep learning based classification of ultrasound images for thyroid nodules: a large scale of pilot study (Guan et al., ๒๐๑๙) ➤ A total of ๒,๘๓๖ thyroid ultrasound images from ๒,๒๓๕ patients were divided into a training dataset and a test dataset. Inception-v3 was trained and tested to crop the margin of the images of nodules and provide a differential diagnosis.

No.	Date of publication	Topic
෩	෨෦෧෪	Diagnosis of Thyroid Nodules: Performance of a Deep Learning Convolutional Neural Network Model vs. Radiologists (Park et al., ෨෦෧෪) ➤ Comparison between the proposed method with radiologists
෪	෨෦෧෪	Ultrasound image analysis using deep learning algorithm for the diagnosis of thyroid nodules (Song et al., ෨෦෧෪) ➤ Inception-v෩ model for training, ෧෩෪෪ (෧෦෦෦ benign, ෧෪෪ malignant)
෫	෨෦෧෪	Automated detection and classification of thyroid nodules in ultrasound images using clinical-knowledge-guided convolutional neural networks (Lui et al., ෨෦෧෪) ➤ The method combines deep learning and task-specific clinical knowledge. ➤ Model is evaluated and compared against the state-of-the-art CAD methods on two datasets. ➤ Model is evaluated and compared against experienced radiologists too.
෬	෨෦෧෪	Artificial Intelligence-Based Thyroid Nodule Classification Using Information from Spatial and Frequency Domains (Nguyen et al., ෨෦෧෪) ➤ Combine FFT as one input to CNN
෭	෨෦෧෪	A Deep-Learning Algorithm for Thyroid Malignancy Prediction From Whole Slide Cytopathology Images (Dov et al., ෨෦෧෪) ➤ Use CNN
෪	2017	Thyroid Nodule Classification in Ultrasound Images by Fine-Tuning Deep Convolutional Neural Network (Chi et al., ෨෦෧෭) ➤ Use GoogleLeNet as based model
෫.	2017	Classification of Thyroid Nodules in Ultrasound using Deep Model Based Transfer Learning and Hybrid features. (Liu et al, ෨෦෧෭) ➤ Use VGG

๒.๕ ชุดฝึกการเรียนรู้


มนุษย์ต้องใช้เวลาประมาณสองทศวรรษในการฝึกฝนให้มีความสามารถและประสบการณ์เต็มรูปแบบ เพื่อให้สามารถดำรงชีวิตในสังคมได้ การฝึกฝนโดยใช้ระบบการศึกษาและหลักสูตรที่มีการนำเสนอแนวคิดต่างๆ ในช่วงเวลาที่แตกต่างกัน โดยใช้แนวคิดที่มีการเรียนรู้ที่มีประสิทธิภาพและประสิทธิผลมาก่อนเพื่อช่วยในการเรียนรู้เรื่องใหม่ๆ ด้วยการเลือกตัวอย่างและลำดับการนำเสนอตัวอย่างนั้น ๆ เพื่อส่งเสริมระบบการเรียนรู้ ทฤษฎีที่ถูกออกแบบตามหลักการดังกล่าวข้างต้นช่วยในการฝึกฝนและเพิ่มความเร็วในการเรียนรู้ที่มีประสิทธิภาพ ดังนั้น แนวความคิดดังกล่าวมักถูกใช้งานอย่างสม่ำเสมอในการฝึกสัตว์และเรียกว่า "การพัฒนาทักษะการเรียนรู้" (Skinner, ๑๙๕๑; Peterson, ๒๐๐๓; Krueger & Dayan, ๒๐๐๙) เพื่อทดสอบสมมติฐานว่าหลักสูตรเพื่อการพัฒนาทักษะการเรียนรู้ (Curriculum Learning) (Benjio, Yoshua, et al., ๒๐๐๙) สามารถช่วยค้นหาจุดต่ำสุด (Local minima) ของรูปแบบกฎเกณฑ์การค้นหาคำตอบที่ดีที่สุดที่มีลักษณะที่ไม่เป็น Convex ดังเช่นการฝึกโมเดลการเรียนรู้เชิงลึก ซึ่งแสดงให้เห็นว่ามีความสามารถในการค้นหาคำตอบของจุดต่ำสุด (Local minima) ที่ดีในจุดต่ำสุด ซึ่งอาจจะไม่สามารถค้นเจอถ้าเลือกใช้การค้นหาคำตอบโดยการเริ่มต้นแบบสุ่ม (Initial Random) (Erhan et al., ๒๐๐๙)

บทที่ ๓

ระเบียบวิธีวิจัย

๓.๑ ภาพรวมของระบบประเมินก้อนต่อมไทรอยด์ผ่านแพลตฟอร์มเว็บไซต์


การพัฒนาแพลตฟอร์มเว็บไซต์เพื่อทดสอบการวิเคราะห์ภาพทางการแพทย์ด้วยปัญญาประดิษฐ์เริ่มต้นจากการสร้างโมเดลต้นแบบ คือ โมเดลตรวจจับและจำแนกประเภทของก้อนต่อมไทรอยด์ ซึ่งโมเดลจะถูกสร้างขึ้นด้วยอัลกอริทึมโครงข่ายประสาทเทียม CNN ซึ่งเป็นเทคนิคการเรียนรู้เชิงลึกที่โมเดลสามารถเรียนรู้ข้อมูลเมื่อมีการป้อนชุดข้อมูลใหม่ๆ ให้กับโมเดลเพื่อเพิ่มประสิทธิภาพในการวิเคราะห์ และด้วยเทคโนโลยีคลาวด์ที่ตอบโจทย์การศึกษาพัฒนาและทดสอบโมเดลที่รองรับระบบจัดเก็บข้อมูลและระบบประมวลผลออนไลน์ส่งผลให้การสร้างโมเดลมีความสะดวกมากยิ่งขึ้นแสดงภาพโดยรวมของระบบดังรูปที่ ๗



รูปที่ ๗: ภาพรวมของระบบออนไลน์คัดกรองมะเร็งต่อมไทรอยด์ด้วยภาพอัลตราซาวด์

ระบบประเมินก้อนต่อมไทรอยด์ด้วยภาพอัลตราซาวด์ถูกออกแบบมาให้ใช้งานผ่านเว็บแอปพลิเคชันแสดงดังรูปที่ ๘ โดยรังสีแพทย์จะเป็นผู้ส่งข้อมูลภาพอัลตราซาวด์ประกอบด้วยภาพอัลตราซาวด์ ภาพอัลตราซาวด์ ที่แสดงขอบเขตของก้อนเนื้อ (Caliper marks) และภาพ Doppler แสดงดังรูปที่ ๒ โดยรูปที่อัปโหลดขึ้นไปจะผ่านการตรวจสอบ คุณลักษณะ เพื่อให้แน่ใจว่าเป็นรูปที่เหมาะสมสำหรับระบบที่จะทำการประเมิน ซึ่งตอนนี้ระบบถูกออกแบบให้ผู้ใช้ ต้องอัปโหลดรูปภาพอย่างน้อย ๑ รูปคือ รูป (ก) และ/หรือ (ข) และ/หรือ (ค) เป็นรูปแสดงการไหลเวียนของเส้นเลือด บริเวณก้อนเนื้อต่อมไทรอยด์ ซึ่งบางครั้งรังสีแพทย์ไม่ได้ทำการสร้างไว้ รูปที่ผ่านการตรวจสอบจะถูก


จัดเก็บ ไว้ในระบบฐานข้อมูลที่ออกแบบไว้ (storage server) เพื่อนำไปใช้สำหรับการทำนายผล (Thyroid nodule assessment) และถูกจัดเตรียมไว้เพื่อสอนโมเดลปัญญาประดิษฐ์เพื่อให้มีประสิทธิภาพการทำนายที่ดียิ่งขึ้น (Retrain model) ทั้งในส่วนของโมเดล ตรวจจับขอบเขตของก้อนเนื้อต่อมไทรอยด์ (Thyroid nodule detection model) และโมเดลทำนายความน่าจะเป็นที่ก้อนเนื้อต่อมไทรอย์จะเป็นก้อนเนื้อชนิดร้าย (Thyroid nodule classification model)



รูปที่ ๘ แผนผังระบบประเมินก้อนต่อมไทรอยด์ผ่านแพลตฟอร์มเว็บไซต์

จากรูปที่ ๘ เส้นสีแดงจะเป็นขั้นตอนการประเมินความผิดปกติของก้อนเนื้อต่อมไทรอยด์ โดยเริ่มต้นรูปที่ ผู้จะส่งขึ้น ระบบจะถูกตรวจสอบความถูกต้อง เช่น รูปที่ส่งขึ้นระบบจะต้องมีอย่างน้อย ๑ รูป กรณีที่รูปที่ส่งขึ้นต้องมีสัญลักษณ์แสดงของเขตของก้อนเนื้อ (รูปที่ ๒ ข.) หลังจากนั้นรูปดังกล่าว จะถูกจัดเก็บ ไว้ในระบบ ฐานข้อมูลรูปภาพอัลตราซาวด์ที่แสดงขอบเขตของก้อนเนื้อจะถูกป้อนให้โมเดลปัญญาประดิษฐ์ที่ทำหน้าที่ตรวจจับ ขอบเขตของก้อนเนื้อต่อมไทรอยด์ เมื่อโมเดลสามารถทำนายพื้นที่ที่ต้องการตรวจสอบระบบจำทำการระบุขอบเขตในรูปอัลตราซาวด์ (รูปที่ ๒ ก.) แล้วส่งข้อมูลดังกล่าวให้โมเดลทำนายความผิดปกติของก้อนเนื้อต่อมไทรอยด์ซึ่ง แสดงผลลัพธ์ออกมาในรูปแบบของเปอร์เซ็นต์ความผิดปกติของก้อนเนื้อต่อมไทรอยด์

เส้นสีเหลืองแสดงการปรับปรุงประสิทธิภาพของโมเดลปัญญาประดิษฐ์ทั้งในส่วนของการทำนายขอบเขต และความ ผิดปกติของก้อนเนื้อต่อมไทรอยด์ โดยรูปภาพที่ถูกเก็บไว้ในระบบฐานข้อมูลเมื่อมีจำนวนที่มากเพียงพอ เช่น ๕๐ ชุดข้อมูลรูปภาพดังกล่าวจะถูกตรวจสอบความถูกต้อง และประเมินโดยรังสีแพทย์ที่มีความเชี่ยวชาญ เพื่อนำรูปดังกล่าวไปให้โมเดลปัญญาประดิษฐ์เรียนรู้เพื่อเพิ่มประสิทธิภาพให้ดียิ่งขึ้นแสดงดังรูปที่ ๙ การพัฒนาโมเดลเพื่อทดสอบการวิเคราะห์ภาพทางการแพทย์ด้วยปัญญาประดิษฐ์เริ่มต้นจากการสร้างโมเดลต้นแบบ คือ โมเดลตรวจจับและจำแนกประเภทของก้อนที่ต่อมไทรอยด์ ซึ่งโมเดลจะถูกสร้างขึ้นด้วยอัลกอริทึมโครงข่ายประสาทเทียม CNN ซึ่งเป็นเทคนิคการเรียนรู้เชิงลึกที่โมเดลสามารถเรียนรู้ข้อมูลอยู่ตลอดเวลาเมื่อมีการป้อนชุดข้อมูลใหม่ๆ ให้กับโมเดลเพื่อเพิ่มประสิทธิภาพในการวิเคราะห์



รูปที่ ๙: กระบวนการเก็บรวบรวมข้อมูลและปรับปรุงประสิทธิภาพการทำงานของโมเดลปัญญาประดิษฐ์
 หน้าหลักของแพลตฟอร์มเว็บไซต์ (<https://thyroid.aicenter.dynu.com/>) แสดงดังรูปที่ ๙ โดยรายละเอียด
 ของวิธีการใช้งานอย่างละเอียดแสดงในภาคผนวกที่ ๒ คู่มือการใช้งานระบบระบบประเมินก้อนต่อมไทรอยด์
 ระบบคัดกรองมะเร็งต่อมไทรอยด์ด้วยภาพอัลตราซาวด์ผ่านแพลตฟอร์มเว็บไซต์จะถูกออกแบบและตรวจสอบ
 ให้มีมาตรฐานความปลอดภัยเพื่อป้องกันการคุกคามด้วยเทคโนโลยีไซเบอร์ ตามพระราชบัญญัติมั่นคงไซเบอร์
 (Cyber Security Act) พ.ศ. ๒๕๖๒ เช่น Ransomware และ data breaches เป็นต้น โดยระบบเฟรมเวิร์คจะถูก
 ออกแบบเพื่อป้องกันการเกิดการคุกคามด้วยเทคโนโลยีและการสร้างกระบวนการตรวจสอบและป้องกันโดยผู้ดูแล
 ระบบ (Security Operation Functions) ดังนี้


๑. การใช้เทคโนโลยีในการสร้างความมั่นคงไซเบอร์พื้นฐาน (Perimeter based and Signature base)
 ได้แก่ firewall, web filter (Data Loss Prevention: DLP), URL filtering, IPS/IDS (Intrusion Prevention

System, Intrusion Detection System)-Blocking mode, Log monitoring, anti-virus และ anti-malware software เป็นต้น

๒. การออกแบบมาตรการป้องกันการคุกคามด้วยผู้ดูแลที่มีความรู้และผ่านการอบรมด้านความมั่นคงทางไซเบอร์ เช่น SIEM (Security Information and Event Management) เป็นต้น

๓. การจัดเก็บสำรองข้อมูลที่สำคัญ (Backup mechanism)

๔. การเข้ารหัสข้อมูลในการรับส่งระหว่างเครือข่ายสาธารณะ เช่น internet, DMS (Defense Message System), และ internal network



รูปที่ ๑๐: หน้าหลักของระบบประเมินก้อนต่อมไทรอยด์ผ่านแพลตฟอร์มเว็บไซต์


➤ การพัฒนาแพลตฟอร์มเว็บไซต์เพื่อรองรับการใช้งานผ่าน Web-based application

เป้าหมายของแพลตฟอร์มเว็บไซต์แสดงดังรูปที่ ๑๑ และ ๑๒ จำเป็นจะต้องมีคุณลักษณะที่สำคัญ ๕ ด้านได้แก่


๑. ความถูกต้องของข้อมูล เนื่องจากข้อมูลเป็นข้อมูลทางการแพทย์จึงจำเป็นต้องรักษาความถูกต้องและสอดคล้องของข้อมูลทั้งระบบ เราจึงเลือกใช้ระบบฐานข้อมูลที่มีความสามารถในการสำรองข้อมูลอัตโนมัติ
๒. รองรับการทำงานปริมาณมาก เนื่องจากเป้าหมายคือการขยายการทำงานไปสู่ระดับภูมิภาค โครงสร้างพื้นฐานของระบบจึงจำเป็นต้องเสถียรและตอบสนองการใช้งานของผู้ใช้งานจำนวนมากได้ในเวลาที่รวดเร็ว ซึ่งสามารถตอบสนองได้ด้วยเทคนิคการกระจายงาน (Load-balancing) โดยการใช้เทคโนโลยี web server application เข้ามาช่วยทั้งในแง่ของการกระจาย network request และการกระจายการคำนวณของ neural Network
๓. ความปลอดภัยของข้อมูล ถูกเข้ารหัสด้วยมาตรฐานความปลอดภัย SSL เพื่อป้องกันการรั่วไหลของข้อมูล

๔. ระบบเฟรมเวิร์คจะถูกพัฒนาให้สอดคล้องกับแนวทางการปฏิบัติตามพระราชบัญญัติมั่นคงไซเบอร์ (Cyber Security Act) พ.ศ. ๒๕๖๒

๖. การจัดการระบบเฟรมเวิร์คเพื่อรองรับการจัดการข้อมูลและสิทธิตามพระราชบัญญัติคุ้มครองข้อมูลส่วนบุคคล (Personal Data Protection Act) พ.ศ. ๒๕๖๒



รูปที่ ๑๑: การพัฒนาแพลตฟอร์มเว็บไซต์การวิเคราะห์ภาพทางการแพทย์ด้วยเทคโนโลยีคลาวด์
(Centralized service; main server and storage server)




รูปที่ ๑๒: การพัฒนาแพลตฟอร์มเว็บไซต์การวิเคราะห์ภาพทางการแพทย์ด้วยเทคโนโลยีคลาวด์
(Client applications)


๓.๒ ภาพรวมของระบบปัญญาประดิษฐ์

งานวิจัยนี้เป็นการประยุกต์ใช้งานการประมวลผลภาพร่วมกับการพัฒนาโมเดลปัญญาประดิษฐ์เพื่อใช้ในการทำนายโอกาสที่ก้อนเนื้อต่อมไทรอยด์ในภาพอัลตราซาวด์จะเป็นก้อนเนื้อชนิดร้ายหรือมะเร็งผ่านระบบแพลตฟอร์มเว็บไซต์ เพื่อความสะดวกในการเข้าใช้งาน และเพื่อปกป้องข้อมูลส่วนบุคคลภาพอัลตราซาวด์และ Doppler ที่ใช้ในการฝึกสอนโมเดลจะถูกเปลี่ยนให้เป็นข้อมูลนิรนามด้วยเทคนิคการประมวลผลภาพ ในงานวิจัยนี้ได้มีการฝึกสอนโมเดลการเรียนรู้เชิงลึกด้วยกันสองโมเดล โดยโมเดลแรกจะถูกนำมาฝึกสอนเพื่อใช้สำหรับตรวจจับ Caliper marks ในภาพอัลตราซาวด์เพื่อใช้ในการระบุตำแหน่งบริเวณก้อนเนื้อต่อมไทรอยด์ (Region of Interest, ROI) และบริเวณ

ดังกล่าวจะถูกนำมาใช้เพื่อทำนายโอกาสที่ก้อนเนื้อบริเวณนั้นจะเป็นมะเร็งหรือไม่ และในกรณีที่ภาพอัลตราซาวด์ที่ถูกป้อนให้กับโมเดลไม่ปรากฏ Caliper marks ภาพนี้จะถูกทำนายโดยโมเดลที่สองที่ทำหน้าที่ในการระบุตำแหน่ง ROI และทำนายโอกาสการเกิดมะเร็ง ด้วยการฝึกสอนโดยใช้ทั้งภาพอัลตราซาวด์และภาพ Doppler เพื่อช่วยชี้แนะให้โมเดลสกัดคุณลักษณะและสามารถกำหนดตำแหน่งบริเวณก้อนเนื้อต่อมไทรอยด์ได้ ซึ่งกระบวนการดำเนินงานวิจัยดังกล่าวแสดงในรูปที่ ๑๑



รูปที่ ๑๓: ขั้นตอนการตรวจจับและทำนายโอกาสที่ก้อนเนื้อต่อมไทรอยด์จะเป็นก้อนเนื้อร้าย



รูปที่ ๑๔: การทำงานของโมเดลวิเคราะห์ก้อนต่อมไทรอยด์ด้วย CNN และโมเดลเหนี่ยวนำการเรียนรู้

จากการทดสอบโมเดลเห็นว่าการเรียนรู้ที่ใช้เทคนิค CNN (Pre-training model) หลายๆโมเดลที่มีประสิทธิภาพเหมาะที่จะนำมาใช้ในการวิเคราะห์ภาพซึ่งความแม่นยำในการทำนายที่สูง รูปที่ ๑๒ คือแผนผังการทำงานของ Pre-training model based CNN สำหรับการวิเคราะห์ก้อนต่อมไทรอยด์ ที่ถูกพัฒนาขึ้นสำหรับข้อเสนอโครงการนี้

ขั้นตอนการดำเนินการของโครงการแสดงดังต่อไปนี้

๑. พัฒนาโมเดลต้นแบบสำหรับจำแนกก้อนเนื้อต่อมไทรอยด์ โดยแบ่งเป็นสองส่วน ดังนี้ ๑) การตรวจจับก้อนเนื้อต่อมไทรอยด์เพื่อใช้ในการแสดงผล ๒) การจำแนกก้อนเนื้อต่อมไทรอยด์ระหว่างก้อนเนื้อดีและก้อนเนื้อร้าย

๒. ดำเนินเอกสารเพื่อการขอเข้าใช้ข้อมูลภาพอัลตราซาวด์เพื่อนำมาพัฒนาโมเดลต้นแบบ

๓. พัฒนาโมเดลต้นแบบเพื่อตรวจจับและจำแนกก้อนเนื้อต่อมไทรอยด์ด้วยเทคนิคการเรียนรู้เชิงลึกโดยทีมงานที่ความประสบการณ์และความชำนาญทั้งด้านการวิเคราะห์ภาพรังสีและด้านวิทยาศาสตร์คอมพิวเตอร์จากมหาวิทยาลัยรามคำแหงและนักวิจัยจากศูนย์ปัญญาประดิษฐ์ AIT นอกจากนี้ในทุกขั้นตอนการพัฒนาโมเดลต้นแบบจะมีทีมรังสีแพทย์จากโรงพยาบาลศิริราชเป็นผู้ให้คำปรึกษาและประเมินการพัฒนาและออกแบบอย่างใกล้ชิดเพื่อให้ผู้ใช้ซึ่งเป็นรังสีแพทย์ยอมรับการทำงานของโมเดลต้นแบบ

๔. พัฒนาระบบจัดเก็บข้อมูลและประมวลผลออนไลน์ (A online storage and analysis platform) ที่ศูนย์ปัญญาประดิษฐ์ AIT นอกจากนี้ยังมีการสร้างซอฟต์แวร์เพื่อเตรียมข้อมูล (preprocessing) ก่อนส่งขึ้นไปเก็บและประมวลผลบนคลาวด์เพื่อลดการใช้แบนด์วิดท์ โดยผลการวิเคราะห์รวมถึงรูปภาพที่ใช้สำหรับวิเคราะห์ทั้งหมดจะถูกส่งผ่านโปรโตคอลที่มีความปลอดภัย (RESTful) เพื่อป้องกันความเสียหายของข้อมูล ทั้งนี้ระบบคลาวด์ที่สร้างขึ้นจะถูกนำมาใช้เพื่อพัฒนาโมเดลต้นแบบอย่างต่อเนื่อง (Retraining) ด้วยภาพชุดใหม่ที่ผ่านมาจากการประเมินจากรังสีแพทย์ในระบบจัดเก็บข้อมูลเพื่อเพิ่มชุดข้อมูลการเรียนรู้ให้กับโมเดลส่งผลให้โมเดลต้นแบบมีความถูกต้องแม่นยำมากขึ้น

๕. พัฒนาแพลตฟอร์มระบบคอมพิวเตอร์ช่วยวินิจฉัยด้วยแบบจำลองการเรียนรู้เชิงลึกเพื่อใช้ในการตรวจจับและจำแนกชนิดของก้อนต่อมไทรอยด์ระหว่างก้อนเนื้อดีและก้อนเนื้อร้ายด้วยการใช้ภาพอัลตราซาวด์ร่วมกับภาพ Doppler ให้สามารถใช้ประเมินผลได้อย่างมีประสิทธิภาพด้วยระบบคลาวด์ผ่านระบบ Web-based application

๖. ตรวจสอบเพื่อค้นหาลักษณะที่เป็นเอกลักษณ์ของก้อนต่อมไทรอยด์ที่เป็นเนื้อร้ายเพื่อนำมาใช้เป็นข้อมูลเพิ่มเติมให้โมเดลต้นแบบมีความฉลาดมากยิ่งขึ้นรวมทั้งการแสดงผลการวิเคราะห์ที่ส่งผลให้เกิดประโยชน์สูงสุดต่อรังสีแพทย์ในการวินิจฉัย โดยการปรึกษากับรังสีแพทย์ผู้มีความเชี่ยวชาญในการตรวจวิเคราะห์มะเร็งก้อนเนื้อต่อมไทรอยด์ที่ผู้ในทีมวิจัย (รังสีแพทย์จากโรงพยาบาลศิริราช) และจากโรงพยาบาลอื่นๆที่เข้าร่วมโครงการ

๗. พัฒนาเฟรมเวิร์คระบบคอมพิวเตอร์ช่วยวินิจฉัยด้วยแบบจำลองการเรียนรู้เชิงลึกเพื่อใช้ในการตรวจจับและจำแนกชนิดของก้อนต่อมไทรอยด์ระหว่างก้อนเนื้อดีและก้อนเนื้อร้ายด้วยการใช้ภาพอัลตราซาวด์ร่วมกับภาพ Doppler ให้สามารถใช้ประเมินผลระยะไกลผ่าน Web-based application

๘. ประเมินผลการใช้งานระบบเฟรมเวิร์คต้นแบบจริงด้วยแพทย์รังสี เพื่อประเมินการใช้งานจริงจากผู้ใช้งานและบันทึกผลการประเมินที่ได้เพื่อวิเคราะห์และปรับเปลี่ยนระบบให้มีประสิทธิภาพมากยิ่งขึ้น โดยองค์ความรู้ที่ได้

จากการสร้างโมเดลต้นแบบและผลลัพธ์ที่ได้จากการสร้างระบบเฟรมเวิร์กจะถูกนำไปเผยแพร่ตีพิมพ์ผ่านวารสารชั้นนำด้านปัญญาประดิษฐ์และรังสีวิทยา


๓.๒.๑ การประมวลผลข้อมูลเบื้องต้น (Image preprocessing)

➤ การลบข้อมูลส่วนบุคคลในภาพอัลตราซาวด์และ Doppler เพื่อสร้างข้อมูลนิรนาม (Anonymization) ด้วยเทคนิคการประมวล (Namsena et al., ๒๐๒๓) แสดงตัวอย่างดังรูปที่ ๑๕


ในการออกแบบแพลตฟอร์มเว็บไซต์สำหรับโมเดลตรวจจับและจำแนกมะเร็งต่อมไทรอยด์ด้วยภาพอัลตราซาวด์นี้ ระบบการจัดเก็บและจัดการข้อมูลจะถูกออกแบบให้สอดคล้องกับพระราชบัญญัติคุ้มครองข้อมูลส่วนบุคคล พ.ศ. ๒๕๖๒ (“ข้อมูลส่วนบุคคล” หมายความว่า ข้อมูลเกี่ยวกับบุคคลซึ่งทำให้สามารถระบุตัวบุคคลนั้นได้ ไม่ว่าทางตรงหรือทางอ้อม แต่ไม่รวมถึงข้อมูลของผู้ถึงแก่กรรมโดยเฉพาะ) โดยระบบจะถูกออกแบบเพื่อป้องกันการละเมิดสิทธิความเป็นส่วนตัวของข้อมูลส่วนบุคคล รวมถึงการดูแลข้อมูลหรือเปิดเผยส่วนบุคคลที่จัดเก็บไว้ในระบบให้เป็นไปตามกฎหมาย

ในการพัฒนาระบบข้อมูลจะถูกแบ่งออกเป็น ๒ ส่วนได้แก่

1. ข้อมูลภาพอัลตราซาวด์ที่ได้จากโรงพยาบาลเพื่อใช้ในการสร้างและทดสอบโมเดล รวมถึงข้อมูลที่ใช้เพื่อโหลดเข้าสู่ระบบเพื่อตรวจจับและทำนายก้อนต่อมไทรอยด์จะเป็นข้อมูลที่ไม่สามารถระบุตัวตนของเจ้าภาพได้ (data anonymization) ข้อมูลส่วนตัวหรือข้อมูลที่สามารถจะระบุตัวตนของเจ้าของภาพจะถูกลบออกไป ได้แก่ ชื่อ-นามสกุล บัตรประจำตัวประชาชน รหัสคนไข้ อายุ เพศ ที่อยู่ เบอร์โทรศัพท์ อีเมลล์ อาชีพ เป็นต้น ดังนั้นภาพอัลตราซาวด์ที่ใช้ในระบบเฟรมเวิร์กจะถูกจำแนกด้วยรหัสภาพ (ImageID) แทน
2. ข้อมูลผู้ใช้ (User) ซึ่งผู้ใช้เบื้องต้นในระบบเฟรมเวิร์กนี้จะเป็นรังสีแพทย์ ซึ่งการจะเข้าใช้งานระบบได้นั้นผู้ใช้งานจะต้องสมัคร (Register) เพื่อเข้าใช้ระบบ (Login) เพื่อป้องกันการใช้งานระบบจากผู้ที่ไม่เกี่ยวข้องและเพื่อเพิ่มประสิทธิภาพของผู้ใช้ในการตรวจสอบภาพย้อนหลัง ดังนั้นในส่วนนี้ข้อมูลของผู้ใช้ที่อยู่ในระบบจะถูกจัดเก็บและดูแลให้อยู่ภายในมาตรการคุ้มครองข้อมูลตามพระราชบัญญัติคุ้มครองข้อมูลส่วนบุคคล (Personal Data Protection Act) พ.ศ. ๒๕๖๒ ได้แก่
 - สิทธิได้รับการแจ้งให้ทราบ (Right to be informed)
 - สิทธิขอเข้าถึงข้อมูลส่วนบุคคล (Right of access)
 - สิทธิในการขอให้โอนข้อมูลส่วนบุคคล (Right to data portability)
 - สิทธิในการคัดค้านการเก็บรวบรวมใช้หรือเปิดเผยข้อมูลส่วนบุคคล (Right to object)
 - สิทธิในการขอให้ลบหรือทำลาย หรือทำให้ข้อมูลส่วนบุคคลเป็นข้อมูลที่ไม่สามารถระบุตัวบุคคล (Right to erasure)
 - สิทธิขอให้ระงับการใช้ข้อมูล (Right to restrict processing)
 - สิทธิในการขอแก้ไขข้อมูลส่วนบุคคล (Right of rectification)




รูปที่ ๑๕: ตัวอย่างการนำข้อมูลส่วนบุคคลออกจากรูปภาพอัลตราซาวด์




รูปที่ ๑๖: ตัวอย่างข้อมูลนิรนาม (ก) ภาพอัลตราซาวด์ (ข) ภาพอัลตราซาวด์ที่ปรากฏ caliper marks และ (ค) ภาพ Doppler

- การระบุตำแหน่งและแบ่งข้อมูลเฉพาะส่วนของภาพ Doppler เพื่อสร้าง Doppler mask ด้วยเทคนิคการประมวลผลภาพ ใช้ในการฝึกสอนโมเดลด้วยภาพอัลตราซาวด์และภาพ Doppler เพื่อช่วยชี้แนะให้โมเดลสกัดคุณลักษณะและสามารถกำหนดตำแหน่งบริเวณก้อนเนื้อต่อมไทรอยด์ได้แสดงดังรูปที่ ๑๗ และ ๑๘



รูปที่ ๑๗: ภาพแสดงตัวอย่างการกำหนด Region of Interest ของภาพ Doppler


จากกระบวนการสร้างภาพ Doppler ของรังสีแพทย์ทำให้สามารถทราบขอบเขตเบื้องต้นของก้อนเนื้อต่อมไทรอยด์ได้จากขอบสีเหลืองแสดงดังรูปที่ ๑๗ ภาพอินพุตที่ได้จึงเกิดจากการตรวจจับขอบและสร้างภาพขึ้นใหม่จากขอบเขตนั้นเพื่อใช้ป้อนให้เป็นอินพุตสำหรับโมเดลจำแนกประเภทของก้อนเนื้อต่อมไทรอยด์ ซึ่งภาพ Doppler ในบางชุดข้อมูลรังสีแพทย์จะไม่ได้สร้าง แต่อย่างไรก็ดีในกรณีที่ไม่มีภาพ Doppler ขอบเขตของภาพ Doppler จะช่วยสนับสนุนการเรียนรู้ของโมเดลให้มีประสิทธิภาพยิ่งขึ้น




รูปที่ ๑๘: ตัวอย่างการสร้าง Doppler mask (ก) กรอบสีขาวในภาพ Doppler ช่วยระบุตำแหน่งของก้อนเนื้อต่อมไทรอยด์ (ข) การระบุตำแหน่งบนภาพอัลตราซาวด์ (ค) Doppler mask

๓.๒.๒ การตรวจจับและระบุตำแหน่งก้อนต่อมไทรอยด์ในภาพอัลตราซาวด์ (Thyroid nodule detection)

ในการนี้การออกแบบโมเดลปัญญาประดิษฐ์เพื่อให้ในการตรวจจับขอบเขต (Thyroid nodule detection model) และความผิดปกติของก้อนเนื้อต่อมไทรอยด์ (Thyroid nodule classification model) ถูกออกแบบมาด้วยกัน ๒ ลักษณะแสดงดังรูปที่ ๑๙ และ ๒๐ โดยโมเดลทั้งสองรูปแบบจะมีความแตกต่างกันคือรูปที่ ๑๙ โมเดลตรวจจับขอบเขต จะทำการทำนายหาพื้นที่ที่ต้องสงสัยแล้วจึงส่งผ่านให้กับโมเดลทำนายความผิดปกติ ส่วนโมเดลรูปที่ ๒๐ โมเดล ปัญญาประดิษฐ์เพียงโมเดลเดียวสามารถทำนายได้ทั้งขอบเขตและความผิดปกติ ของก้อนต่อมไทรอยด์ซึ่ง ณ เวลานี้ผู้วิจัยยังไม่สามารถสรุปได้ว่าโมเดลใดให้ผลการทำนายที่มีประสิทธิภาพ สูงกว่ากัน ดังนั้นโมเดลทั้งสองรูปแบบจะถูกพัฒนาไปพร้อม ๆ กัน



รูปที่ ๑๙: แสดงการออกแบบโมเดลทำนายขอบเขตของก้อนเนื้อต่อมไทรอยด์แยกกับโมเดลทำนายความผิดปกติของก้อนเนื้อต่อมไทรอยด์อย่างชัดเจน



รูปที่ ๒๐: แสดงการออกแบบโมเดลทำนายขอบเขตของก้อนเนื้อต่อมไทรอยด์ทำงานร่วมกับโมเดลทำนายความผิดปกติของก้อนเนื้อต่อมไทรอยด์

๓.๒.๒.๑ Thyroid nodule detection ด้วยอัลกอริทึม YOLO


การค้นหาลำดับตำแหน่งของบริเวณที่สนใจ (region of thyroid nodules) ผู้วิจัยจะใช้ YOLO หรือ “You only look once” ในขั้นตอนนี้เพื่อให้ผลลัพธ์ที่ดีและแม่นยำผู้วิจัยได้ทำการทดลองหลากหลายรูปแบบและจะทำการเปรียบเทียบผลลัพธ์และเลือกใช้วิธีการที่ดีที่สุดในการทำงานนี้ ในการสร้างโมเดลผู้วิจัยใช้ภาพหลายภาพนำไปเข้ากระบวนการเทรนเพื่อให้ได้ weight ไฟล์แล้วจึงนำ weight ไฟล์ไปใช้ในการทำนายผลการค้นหาบริเวณที่สนใจรูปที่ ๒๑ แสดงกระบวนการสร้างโมเดลและการทำงาน YOLO Detector

➤ การทดสอบโมเดลเบื้องต้น: The ROI (Region of Interest) detector module


การค้นหาลำดับตำแหน่งของบริเวณที่สนใจ ROI จากภาพอัลตราซาวด์เพื่อส่งต่อไป ยัง classifier นั้น ผู้วิจัยได้ทำการทดลองเบื้องต้น ๒ การทดลอง ได้แก่ การทดลองที่ ๑: การทดลองค้นหาตำแหน่ง ของ ROI โดยการเทรน mark ทั้ง ๔ จุด และการทดลองที่ ๒: การทดลองค้นหาตำแหน่งของ ROI โดยการเทรน แต่ละ mark แยกจากกัน แล้วจับคู่แต่ละ mark ในภายหลัง

การทดลองที่ ๑



ผู้วิจัยได้ทำการทดลองค้นหาตำแหน่งที่จะใช้ในการวินิจฉัย โดยใช้ YOLO: Real-Time Object Detection ผู้วิจัยใช้ภาพอัลตราซาวด์ทั้งหมด ๓๒๐ ภาพจากทั้งสองประเภทได้แก่ benign และ malignant ผู้วิจัยใช้ภาพ ๒๘๘ ภาพในการเทรน และ validation test ทั้งหมด ๒๐ ภาพ ในการวัดค่า Accuracy ของโมเดลผู้วิจัยใช้ภาพในการตรวจสอบทั้งหมด ๑๒ ภาพจากทั้งสองประเภท



รูปที่ ๒๑: แสดงกระบวนการสร้างโมเดลและการทำงานของ YOLO Detector





รูปที่ ๒๒: แสดงผลการตรวจหาตำแหน่งที่สนใจ (Region of Interest (ROI) ได้ถูกต้อง



รูปที่ ๒๓: แสดงความผิดพลาดในการตรวจหาตำแหน่งที่สนใจ (Region of Interest (ROI)

การทดลองที่ ๒


ผู้วิจัยได้ทำการทดลองในการค้นหาตำแหน่งของ ROI โดยการค้นหาตำแหน่งของ mark แต่ละอัน โดย mark แต่ละอันจะมีคู่ที่อยู่ในทิศทางตรงกันข้าม เพื่อตีกรอบให้กับบริเวณที่สนใจ เพราะฉะนั้นหาก จำนวน mark มีมากกว่า ๔ จำเป็นต้องมีการจับคู่ mark เพื่อให้ได้พื้นที่ที่ต้องการ ผู้วิจัยใช้ภาพข้อมูลเทรนทั้งหมด ๓๒๑ ภาพ จากทั้ง benign และ malignant (เทรน ๓๒๗ ภาพ, validation test ๓๐ ภาพ) และใช้ภาพ ๒๐ ภาพ ในการวัดผล Accuracy




รูปที่ ๒๔: แสดงผลการค้นหาตำแหน่งบริเวณที่สนใจ (ROI) สามารถทำได้ถูกต้องทั้งหมด ในกรณีนี้ยังไม่ได้ทำการจับคู่ mark

➤ ROI segmentation with YOLO

ในการทดลองเบื้องต้นภาพอัลตราซาวด์จะถูกใช้เฉพาะบริเวณที่มีก้อนเนื้อปรากฏ ซึ่งโมเดลการตรวจจับก้อนเนื้อต่อมไทรอยด์ที่ถูกอธิบายใน section-thyroid nodule detection จะทำหน้าที่ตรวจจับมาร์ค เพื่อใช้สำหรับกำหนดขอบเขตก้อนเนื้อต่อมไทรอยด์ ROI (Region of Interest) โดยครอบคลุมบริเวณที่มีความสำคัญสำหรับการวิเคราะห์ก้อนเนื้อ เพื่อใช้เป็นภาพอินพุตที่มีขนาดความกว้างและความสูงเท่ากันให้กับโมเดลจำแนกประเภทก้อนเนื้อต่อมไทรอยด์ซึ่งรับข้อมูลเป็นทรงจตุรัสแสดงดังรูปที่ ๒๕



รูปที่ ๒๕: ตัวอย่างการกำหนด Region of Interest ด้วย marks detection model




รูปที่ ๒๖: แสดงขั้นตอนการตรวจจับก้อนเนื้อต่อมไทรอยด์เพื่อกำหนด ROI (Namsena et al., ๒๐๒๓)

➤ การเพิ่มข้อมูล (Data Augmentation)

โมเดลปัญญาประดิษฐ์เพื่อใช้สำหรับตรวจจับมาร์คที่แสดงตำแหน่งและขอบเขตของก้อนเนื้อต่อมไทรอยด์ (Thyroid Detection Model) เนื่องจากข้อมูลมหัต (big data) เป็นภาพจำนวน ๓๒๒ ภาพ (image) และข้อมูลตำแหน่งและลักษณะ ของสัญลักษณ์ (label) ซึ่งเป็นภาพต้นแบบการเรียนรู้ นั้น มีจำนวนที่น้อยเกินไป การฝึกของโมเดลอาจจะทำให้ การอ่านภาพในรูปแบบที่แตกต่างจะไม่แม่นยำเพียงพอ ดังนั้น ภาพจึงถูกดัดแปลงเพื่อให้เสมือนว่า เกิดภาพ ใหม่ ๆ เพิ่มขึ้น ซึ่งในงานวิจัยนี้มีการดัดแปลงภาพเป็นลักษณะต่าง ๆ โดยอ้างอิงความเป็นไปได้ที่จะมีลักษณะของภาพที่ เกิดขึ้นได้จริง ดังนี้

- การเลื่อนภาพ (Translation)
- การเปลี่ยนเฉดสีของภาพ (color transform)
- การเปลี่ยนความเข้มของสีภาพ (brightness)
- การปรับขนาดของวัตถุ (scale)


สำหรับภาพที่มีการหมุน(rotation) นั้น ผู้วิจัยไม่ได้ใส่ไว้เพราะไม่มีภาพลักษณะนี้ปรากฏในภาพอัลตราซาวด์ปกติภาพที่มีการใช้วิธีดัดแปลงภาพนั้นจะทำเพียงภาพชุดฝึก (train set) จำนวน ๒๕๐ ภาพ ที่ใช้ในการฝึกเรียนรู้เท่านั้น สำหรับภาพชุดตรวจสอบ (validation set) จะไม่มีการดัดแปลงภาพแต่อย่างใด



รูปที่ ๒๗: ตัวอย่างภาพที่มีการดัดแปลงภาพก่อนเข้าฝึกทดลองให้กับโมเดลในแต่ละชุด batch

➤ การกำหนดขอบเขตของ ROI หลังจากหาตำแหน่งของสัญลักษณ์


หลังจากที่หาสัญลักษณ์ก่อนเนื้อได้แล้วจะนำมาคำนวณตำแหน่งของก้อนเนื้อต่อมไทรอยด์ด้วยการคำนวณหาพิกัดและขนาดของก้อนเนื้อต่อมไทรอยด์และตัดภาพออกมาส่งให้โปรแกรมคัดแยกชนิดของก้อนเนื้อโดยโปรแกรมจะตัดภาพก้อนเนื้อให้อยู่ตรงกลางของกรอบสี่เหลี่ยมจัตุรัสที่มีการขยายขอบเขตของเนื้อส่วนที่ปกติตามความต้องการของโปรแกรมคัดแยก ซึ่งบริเวณเนื้อส่วนที่ปกติ สามารถนำไปใช้ดูเปรียบเทียบกับลักษณะของ ก้อนเนื้อต่อมไทรอยด์ที่เป็นชนิดดีหรือร้ายได้




รูปที่ ๒๘: ตัวอย่างภาพเนื้องอกที่โปรแกรมตรวจจับได้ และขยายขอบเขตจากขนาดเนื้องอกเดิม ๔๐% และปรับให้เป็นขอบเขตแบบสี่เหลี่ยมจัตุรัส

➤ ตัดภาพเฉพาะส่วนก้อนเนื้องอก (Cropping image)

จากนั้นให้นำตำแหน่งสัญลักษณ์ที่จดจำไว้มาคำนวณตำแหน่งของก้อนเนื้อต่อมไทรอยด์ ด้วยการคำนวณหาพิกัดและขนาดของก้อนเนื้อต่อมไทรอยด์และตัดภาพออกมาส่งให้โปรแกรมคัดแยกชนิดของก้อนเนื้อโดยโปรแกรมจะตัดภาพก้อนเนื้อให้อยู่ตรงกลางของกรอบสี่เหลี่ยมจัตุรัสที่มีการขยายขอบเขตของเนื้อส่วนที่ปกติตามความต้องการของโปรแกรมคัดแยก ซึ่งบริเวณเนื้อส่วนที่ปกติ สามารถนำไปใช้ดูเปรียบเทียบกับลักษณะของก้อนเนื้อต่อมไทรอยด์ที่เป็นชนิดดีหรือร้ายได้ (สำหรับตำแหน่งภาพที่ถูกขยายแล้วเกินออกมา จะทำการขยายส่วนเกินนั้น ให้เป็นสีดำ)




รูปที่ ๒๙: ตัวอย่างภาพเนื้องอกที่ตัดเพื่อส่งต่อไปโปรแกรมคัดแยก



รูปที่ ๓๐: ตัวอย่างภาพเนื้องอกที่โปรแกรมตรวจจับได้ และขยายขอบเขตจากขนาดเนื้องอกเดิม ๒๐% และปรับให้เป็นขอบเขตแบบสี่เหลี่ยมจัตุรัส

➤ การลบเลือนตำแหน่งสัญลักษณ์ (Markers removal)


เมื่อได้ตำแหน่งของสัญลักษณ์แล้ว จะทำการลบเลือนตำแหน่งสัญลักษณ์ให้หายไป จนภาพเป็นเสมือนไม่มีตำแหน่งสัญลักษณ์มาก่อน โดยทีมผู้วิจัยได้ออกแบบโปรแกรมที่ใช้ในการลบเลือนสัญลักษณ์แบบอัตโนมัติขึ้น เพื่อให้โปรแกรมนี้เป็นขั้นตอนก่อนส่งไปให้โมเดลสำหรับแยกประเภทของก้อนเนื้อต่อมไทรอยด์




รูปที่ ๓๑: ตัวอย่างภาพเนื้องอกที่ตัดเพื่อส่งต่อให้โปรแกรมคัดแยก

๓.๒.๒.๒ Thyroid nodule segmentation ด้วยอัลกอริทึม U-Net

โมเดลปัญญาประดิษฐ์เพื่อใช้สำหรับตรวจจับก้อนเนื้อต่อมไทรอยด์ด้วยภาพที่ไม่มีสัญลักษณ์ (Thyroid Nodule Detection Model using ultrasound image without marks) เนื่องจากภาพอัลตราซาวด์ที่ได้รับมานั้น มีภาพบางส่วนที่เป็นภาพชนิดไม่มีสัญลักษณ์ ผู้วิจัยจึงได้นำอัลกอริทึมที่ชื่อว่า U-Net มาใช้ในการหาตำแหน่งของก้อนเนื้อที่ปรากฏในภาพ ซึ่งโมเดล U-Net นี้ ถูกนำมาใช้ในการแพทย์มากมาย โดยเฉพาะการหาตำแหน่งเนื้องอก หรือสิ่งผิดปกติต่าง



รูปที่ ๓๒: ตัวอย่างภาพผลลัพท์ก่อน และหลังการลบเลือนสัญญาณ




รูปที่ ๓๓: ตัวอย่างภาพเนื้องอกที่หาได้จากโมเดล U-Net

➤ วิธีการทดลอง

ผู้ทดลองได้นำเอาภาพต้นแบบ จำนวน ๓๒๒ ภาพ มาทำการวาดตำแหน่งเนื้องอก (Annotation) จากนั้นแบ่งออกเป็นภาพชุดฝึก (Train set) จำนวนร้อยละ ๙๐ หรือ ๒๙๐ ภาพ และ ภาพชุดตรวจสอบ (Validation set) จำนวนร้อยละ ๑๐ หรือ ๓๒ ภาพ มาฝึกหัดอ่านสัญลักษณ์ที่มีอยู่ในภาพด้วยโมเดล U-Net จำนวน ๑๐๐ รอบ โดยการทดสอบนี้ เพื่อตรวจสอบว่าโมเดล U-Net สามารถเรียนรู้ก่อนเนื้อได้จริง จึงยังไม่มีผลค่า Accuracy จากการฝึกนี้ ซึ่งผลการทดลองค่อนข้างมั่นใจได้ว่า สามารถหาค่อนเนื้อได้จริง แต่ยังคงไม่แม่นยำนัก เนื่องจากจำนวนภาพที่ใช้


เรียนโมเดลเพื่อทดสอบมีจำนวนน้อยเกินไป และจำนวนรอบการใช้ฝึกต่ำเกินไป ซึ่งผลตำแหน่งก้อนเนื้อเทียบกับภาพอัลตราซาวด์ เป็นดังรูปที่ ๓๔




รูปที่ ๓๔: ตัวอย่างการวาดตำแหน่งเนื้ออก

➤ การจัดทำชุดข้อมูลเพื่องานพัฒนาโมเดลตรวจจับก้อนเนื้อไทรอยด์

ในผลการดำเนินการส่วนนี้จะรายงานความคืบหน้าในการพัฒนาโมเดลตรวจจับก้อนเนื้อไทรอยด์ โดยจะใช้ชุดภาพจำนวน ๑๖๗๖ รูปภาพจากโรงพยาบาล และ ชุดภาพเพิ่มเติมจากชุดข้อมูลฟรีของ thyroid nodule ultrasound image dataset (DDTI public database <https://doi.org/10.1117/12.2073532>) อีก ๗๒๕ รูปภาพ โดยแบ่งภาพของโรงพยาบาลในประเทศไทยเป็นอัตราส่วนชุดฝึกร้อยละ ๙๐ และชุดทดสอบร้อยละ ๑๐ และนำชุดข้อมูลฟรีทั้งหมดเป็นข้อมูลชุดฝึก เพื่อเพิ่มการเรียนรู้ของข้อมูลมากขึ้น ดังนั้น ชุดข้อมูลจะแบ่งเป็นชุดฝึกทั้งหมด ๒๑๐๓ รูป และชุดทดสอบ ๑๔๙ รูป จากทั้งสองชุดข้อมูลดังกล่าว ได้นำชุดข้อมูลสำหรับฝึกโมเดลมาวางรูปร่างของก้อนเนื้อไทรอยด์โดยผู้ทดลองและนำชุดข้อมูลสำหรับทดสอบมาวางรูปร่างก้อนเนื้อโดยแพทย์รังสี เพื่อรับรองความถูกต้องว่าชุดทดสอบไม่ผลิตผลจากความไม่ชำนาญของผู้ทดลอง จากนั้นตำแหน่งก้อนเนื้อไทรอยด์ที่ถูกวงเอาไว้จะนำมาสร้างเป็นหน้ากากสำหรับภาพก้อนเนื้อเท่านั้น ชุดภาพทั้งหมดจะถูกนำมาตัดขอบที่ไม่จำเป็นออกเหมือนการดำเนินงานครึ่งเก่าและภาพหน้ากากก้อนเนื้อก็จะถูกตัดขอบด้วยตำแหน่งเหมือนภาพต้นฉบับ ดังรูป ๓๖




รูปที่ ๓๕: ตัวอย่างภาพเนื้องอกที่หาได้จากโมเดล U-Net



รูปที่ ๓๖: ตัวอย่างภาพไทรอยด์ที่มีก้อนเนื้อ และภาพหน้าากก้อนเนื้อไทรอยด์ ที่ถูกนำมาตัดขอบที่ไม่จำเป็นออก

เนื่องจากชุดภาพแต่ละโรงพยาบาลมีลักษณะไม่เหมือนกัน บางโรงพยาบาลมีสีที่เข้มสว่างแตกต่างกัน บางครั้งภาพอัลตราซาวด์มีสีที่ไม่ใช่แค่สีขาวดำ ดังนั้น ผู้ทดลองจึงนำภาพชุดฝึกมาทำ Data augmentation โดยอ้างอิงความเป็นไปได้ของความแตกต่างในเครื่องอัลตราซาวด์แต่ละยี่ห้อ ซึ่งการทำ Data augmentation มีการสุ่มการแปลงภาพดังต่อไปนี้

- ปรับสี RGB, ความสว่าง, ความสดใสของภาพ
- ปรับขนาดของภาพใหญ่ขึ้นหรือเล็กลง
- หมุนและเลื่อนภาพ



รูปที่ ๓๗: ตัวอย่างภาพที่มีการ Augmentation ในรูปแบบต่าง ๆ


จากนั้นจึงทำการทดลองเปรียบเทียบความถูกต้องของในค่าร้อยละของ IoU (Intersect of Union) ระหว่างภาพ Augmentation กับภาพที่ไม่มีการเปลี่ยนแปลง โดยใช้โมเดล U-Net256 พบว่า ค่า IoU ของชุดภาพที่มีการ Augmentation สูงกว่าชุดภาพที่ไม่มีการเปลี่ยนแปลงมากกว่าร้อยละ ๑๐ ผู้ทดลองจึงนำชุดข้อมูลฝึกไปทำ augmentation ก่อนฝึกทุกครั้ง แต่ชุดภาพทดลองจะไม่เปลี่ยน

ตารางที่ ๓ ผลการทดลองโมเดล U-Net


โมเดล	Non-Augmentation (IoU)	Augmentation (IoU)
U-Net256	๔๓.๒๓	๕๓.๖๘

จากผลการทดลองเบื้องต้น พบว่า โมเดล U-Net256 นั้น มีความแม่นยำที่ต่ำ ดังนั้นผู้ทดลองจึงหาโมเดลที่สามารถตรวจจับก้อนเนื้อได้ดีกว่าเดิม และพบว่ามีโมเดลที่ชื่อว่า DeepLab ซึ่งพัฒนาโดย Google สามารถตรวจสอบก้อนเนื้อไทรอยด์ในงานแข่ง MICCAI 2020 TN-SCUI challenge ซึ่งได้ที่หนึ่งในการแข่งนี้ โดยโครงสร้างโมเดลของงานวิจัยนั้นเป็นดังรูปที่ ๓๘

เนื่องจากงานวิจัยขั้นต้นได้ใช้โมเดล DeepLabV3+ ดังนั้น ผู้ทดลองจึงนำโมเดล DeepLabV3+ มาใช้เป็นโมเดลเริ่มต้นของการวิจัยในครั้งนี้ โดยทดลองฝึก DeepLabV3+ และตรวจสอบความแม่นยำของโมเดลเป็นพื้นฐานตั้งต้นของการทดลองนี้ โดยค่า IoU มีค่าถึงร้อยละ ๗๘.๙๗๒๕ และในการตรวจหาก้อนเนื้อในแต่ละภาพนั้นมีความเร็วในการประมวลผล ๑๕ ภาพต่อวินาที



รูปที่ ๓๘: โครงสร้างการทำงานของงานวิจัยที่ได้รับรางวัล MICCAI 2020 TN-SCUI Challenge




รูปที่ ๓๙: โครงสร้างโมเดล DeepLabV

๓.๒.๒.๓ Thyroid nodule segmentation ด้วยอัลกอริทึม GAN

จากการศึกษาค้นคว้าเพิ่มเติม พบว่ามีงานวิจัยหลายงานได้นำโมเดล GAN (Generative Adversarial Network) มาใช้ในงานวิจัยทั่วไปและทางการแพทย์ ซึ่งตัวโมเดล GAN แบ่งเป็นสองโมเดล คือ Generator หรือโมเดลที่ใช้ในการสร้างภาพ และ Discriminator หรือโมเดลที่ใช้ในการตรวจสอบว่าภาพนั้นถูกสร้างขึ้นมาหรือเป็นภาพจริง ซึ่งโมเดล Generator จะเรียนรู้จากผลของการตรวจสอบจาก Discriminator ว่าตัวเองสร้างภาพได้คล้ายคลึงกับภาพจริงมากน้อยแค่ไหน แล้วนำมาปรับปรุง ส่วน Discriminator จะเรียนจากภาพจริงกับภาพที่สร้างจาก Generator

ในทางการแพทย์นั้นโมเดล GAN ได้นำมาใช้ในการสร้างภาพจำลองทางการแพทย์เป็นส่วนใหญ่ และมีบางงานวิจัยนำมาใช้ในการตรวจหาอวัยวะของภาพเอ็กซเรย์หรือภาพซีทีสแกน ซึ่งแทบไม่มีงานวิจัยที่ใช้ GAN ในการตรวจภาพอัลตราซาวด์ แต่งานวิจัยทั้งหมดที่ใช้ GAN ในการตรวจจับ พบว่ามีผลลัพธ์ที่ดีขึ้นกว่าโมเดลดั้งเดิม ดังนั้นผู้วิจัยจึงนำ GAN มาดัดแปลงกับโมเดล DeepLabV3 เพื่อให้ผลการตรวจจับที่ได้จากโมเดล มีค่าความถูกต้องที่ดียิ่งขึ้น นอกจากนั้น ผู้วิจัยคาดหวังว่า จากการใช้โมเดล GAN จะทำให้โมเดลมีอิสระในทางความคิดด้านการตรวจจับเพื่อแก้ไขชุดภาพที่คนตรวจอาจวาดหน้ากากก่อนเนื้อได้ไม่ถูกต้อง


ในการวิจัยครั้งนี้ ผู้วิจัยจึงสร้าง GAN โดยนำ DeepLabV3 เป็นตัว Generator และสร้างโมเดล Discriminator จากโมเดล CNN พื้นฐาน จำนวน 5-8 เลเยอร์ ซึ่งมีหน้าที่ตรวจสอบว่าภาพที่ Generator สร้างขึ้นนั้น เป็นภาพหน้ากากที่ถูกต้องหรือไม่ โดยให้ Generator มีการเรียนรู้จากค่า Loss สองประเภทในอัตราส่วนที่เท่ากัน คือ Supervised Loss หรือค่า Loss ที่เกิดจากการตรวจสอบภาพหน้ากากที่สร้างขึ้นมา เทียบกับภาพหน้ากากต้นฉบับ และ Unsupervised Loss หรือ Loss ที่เกิดจากการตรวจสอบภาพหน้ากากโดย Discriminator



การทดสอบคือแยกทดลองฝึกและตรวจสอบจาก Discriminator ที่มีจำนวนเลเยอร์ที่แตกต่างกัน โดยเรียกโมเดลเหล่านี้ว่า DeepLabV3+GAN จากนั้นจึงนำโมเดลเพียงแค่ส่วนที่เป็น Generator ซึ่งก็คือ DeepLabV3+ มาทดสอบกับภาพชุดทดลอง จึงทำให้ความเร็วในการตรวจสอบผลมีความเร็วเท่าเดิม คือ ๑๕ ภาพต่อวินาที

➤ การปรับปรุงโมเดลเพื่อป้องกัน Mode Collapse ใน GAN


ในการป้องกันการเกิด Mode Collapse นั้น มีสามวิธีคือ การลดความซับซ้อนของ Discriminator, การทำให้เป็น Semi-Supervised และ การปรับความเร็วการเรียนรู้ของโมเดลทั้งสอง



รูปที่ ๔๑: รูปภาพเปรียบเทียบการเรียนรู้ของ GAN

แบบที่สเถียร (ซ้าย) กับแบบที่เป็น Mode Collapse (ขวา) ซึ่งถ้าโมเดล Discriminator เก่งเกินไป จะทำให้ loss ของ Generator สูงขึ้น และไม่เกิดการเรียนรู้

ในการลดความซับซ้อนของ Discriminator นั้น จะทำให้ความได้เปรียบจากการใช้โมเดล GAN ลดลง ซึ่งไม่ดีต่องานวิจัยสำหรับการทำให้เป็น Semi-Supervised นั้น ผู้วิจัยได้ใช้ไปแล้ว และยังไม่ช่วยลด Mode collapse ในกรณีเพิ่มความซับซ้อนของ Discriminator แต่ช่วยในการเพิ่มความเร็วการเรียนรู้ของ Generator ระดับหนึ่ง สำหรับการปรับความเร็วการเรียนรู้ของโมเดลของ Generator และ Discriminator นั้น น่าสนใจ โดยยืมพื้นฐานจาก ถ้า Generator เรียนได้ช้า Discriminator ควรต้องลดความเร็วการเรียนรู้หรือหยุดการเรียนรู้เพื่อรอให้ Generator ผลิตขึ้นเสียก่อน โดยอ้างอิงจากสมการการเรียนรู้ของ Machine Learning นั่นคือ การปรับค่าอัตราการเรียนรู้ หรือ ปรับสเกลค่า Loss เพื่อปรับสมดุลระหว่างความเร็วการเรียนรู้ของ Generator และ Discriminator โดยผู้วิจัย ได้นำทฤษฎีคอนโทรลมาประยุกต์ใช้กับงานวิจัยชิ้นนี้ โดยนำทฤษฎี Closed-loop control ตัวหนึ่ง ชื่อว่า PID control มาปรับสเกลค่า Loss ระหว่าง Generator และ Discriminator




รูปที่ ๔๒: รูปภาพแสดงโครงสร้างของ PID Control ที่นำมาควบคุมการปรับสเกลค่า Loss เพื่อนำไปใช้ใน ปรับการเรียนรู้ของโมเดล Generator และ Discriminator

หลังจากคำนวณไดนามิกส์ของอัตราการเรียนรู้ของโมเดล Generator และ Discriminator ได้เป็นสมการความถี่ดังนี้ โดยสมการดังกล่าว ตัวแปร จะถูกนำไปใส่ไว้ในโครงสร้างตามรูปที่ ๔๒ เพื่อคำนวณหาอัตราเร็วการเรียนรู้ด้วย PID control ต่อไป ซึ่งเป็นลักษณะของไดนามิกส์ ดังนั้น การเรียนรู้ในแต่ละครั้งของ Generator และ

Discriminator จะมีอัตราเร็วไม่เท่ากัน โดยจุดประสงค์ของการเรียนในรูปแบบนี้ คือเพื่อประคองให้โมเดลทั้งสองเข้าสู่ตำแหน่งขีดความสามารถของโมเดลสูงที่สุดเท่าที่ตัวโมเดลจะสามารถทำได้

$$\Phi(s) = \frac{2\gamma s}{4s^2 + 2s + 1} \mathcal{C}(s) = T_D(s)\mathcal{R}(s)$$

$$\Theta(s) = \frac{\gamma}{4s^2 + 2s + 1} \mathcal{R}(s)$$



รูปที่ ๔๓: ภาพโมเดล StableSeg GAN

หลังจากที่ปรับปรุงโครงสร้าง GAN ด้วยการใส่ PID control และผู้วิจัยได้ตั้งชื่อโมเดลใหม่ว่า StableSeg GAN พบว่า ตัวโมเดลใหม่สามารถรองรับความซับซ้อนของโมเดล Discriminator ได้ดียิ่งขึ้น ดังนั้น ผู้วิจัยจึงเปลี่ยนไปใช้ ResNet18 เป็น Discriminator ดังรูปที่ ๗๐ และทดสอบว่า โมเดลนี้ สามารถปรับให้มีค่าอัตราส่วนการเรียนรู้ของ Unsupervised Learning ได้มากขึ้นหรือไม่ ซึ่งผลการทดสอบเป็นไปตามตารางด้านล่าง

๓.๒.๓ การจำแนกก้อนต่อมไทรอยด์ในภาพอัลตราซาวด์ (Thyroid nodule classification)

การจำแนกก้อนต่อมไทรอยด์ในภาพอัลตราซาวด์เป็นกระบวนการที่ใช้เทคนิคการเรียนรู้การเรียนรู้เชิงลึก เพื่อแยกแยะประเภทของก้อน เช่น ก้อนต่อมไทรอยด์ชนิดร้าย (malignant) และชนิดดี (benign) โดยเริ่มจากการป้อนภาพอัลตราซาวด์เข้าสู่โมเดล เช่น CNNs เพื่อสกัดคุณลักษณะที่สำคัญ เช่น รูปร่าง ขอบเขต และพื้นผิวของก้อน จากนั้นโมเดลจะวิเคราะห์ลักษณะเหล่านี้เพื่อจัดประเภท โดยอาศัยข้อมูลที่ได้จากการฝึกโมเดลด้วยภาพที่มีการติดฉลาก (labeled data) ล่วงหน้า

๓.๒.๓.๑ การจำแนกก้อนต่อมไทรอยด์ในภาพอัลตราซาวด์ Pre-train Model

(องค์ความรู้ที่ได้จากการวิจัยและทดลองอยู่ระหว่างกระบวนการนำเสนอผ่านวารสารวิชาการระดับนานาชาติ ในหัวข้อ Diagnostic Performance of Artificial Intelligence for Interpreting Thyroid Cancer in Ultrasound images รายละเอียดเพิ่มเติมในภาคผนวก ข)

Pre-trained model หมายถึงโมเดลที่ถูกฝึกบนชุดข้อมูลขนาดใหญ่ เช่น ImageNet ในการจำแนกประเภทภาพทั่วไป ก่อนที่จะถูกนำมาปรับแต่งเพิ่มเติม (fine-tuning) เพื่อนำไปใช้กับปัญหาเฉพาะ เช่น การประเมินก้อนต่อมไทรอยด์ในภาพอัลตราซาวด์ โดยแนวคิดนี้มีความสำคัญในงานวิจัยด้านการประมวลผลภาพทางการแพทย์เพราะช่วยลดข้อจำกัดบางประการ ดังนี้

๑. ลดความต้องการข้อมูลจำนวนมาก

การฝึกโมเดลจากศูนย์ (training from scratch) ต้องใช้ข้อมูลขนาดใหญ่มากเพื่อให้โมเดลเรียนรู้ได้ดี ในกรณีของภาพอัลตราซาวด์ต่อมไทรอยด์ ข้อมูลมักมีจำนวนจำกัดและอาจมีข้อจำกัดด้านการเก็บข้อมูล (เช่น ความยากในการได้ข้อมูลจากผู้ป่วยจริง) การใช้ pre-trained model ช่วยให้โมเดลสามารถเริ่มต้นจากคุณลักษณะพื้นฐานที่เรียนรู้มาก่อนแล้ว

๒. ประหยัดทรัพยากรและเวลา

การเริ่มต้นฝึกโมเดลจากศูนย์ใช้เวลามากและต้องใช้ฮาร์ดแวร์ที่มีประสิทธิภาพสูง การใช้โมเดลที่ถูกฝึกมาก่อนช่วยลดเวลาและทรัพยากรในการประมวลผล เพราะสามารถปรับแต่งเฉพาะในขั้นตอนสุดท้าย (fine-tuning) เพื่อให้เหมาะกับข้อมูลภาพอัลตราซาวด์

๓. ปรับปรุงประสิทธิภาพในการจำแนกและประเมิน

Pre-trained models เช่น ResNet, VGG, หรือ EfficientNet สามารถดึงคุณลักษณะ (features) ที่มีความซับซ้อนจากภาพ เช่น รูปร่าง ขอบเขต และพื้นผิวของก้อนต่อมไทรอยด์ ได้อย่างมีประสิทธิภาพ ช่วยให้การจำแนกประเภทของก้อน (เช่น มะเร็งหรือไม่ใช่มะเร็ง) มีความแม่นยำสูง

➤ **ปรับปรุงชั้นทำนาย(prediction layer) โดยการแทนที่ชั้นทำนายสำหรับ ImageNet จำนวน ๑,๐๐๐ คลาสด้วยชั้นทำนายใหม่จำนวน ๒ คลาส**

ผลการทดลองด้วยชุดข้อมูล ๑,๒๓๙ ภาพ โดยแยกการทดสอบโมเดลออกแบบ ๒ ชุดข้อมูลได้ผลดังนี้

๑. ทดสอบด้วยชุดข้อมูลที่ได้ทำการสุ่มแยกออกมา จำนวน ๒๔๐ ภาพ โดยแบ่งเป็น Malignant ๑๒๐ ต่อ Benign ๑๒๐ ภาพ

ได้ความแม่นยำสูงสุด ๙๕%

Val:[loss=๐.๑๔๑๔ , acc=๙๕.๘๓%]


ตารางที่ ๔ แสดง Confusion Matrix

Actual\Predict	Benign	Malignant
Benign	117(TP)	3(FP)
Malignant	7(FN)	113(TN)

๒. ทดสอบด้วยชุดข้อมูลที่ถูกแยกไว้เพื่อเป็นข้อมูลทดสอบจำนวน ๖๐ ภาพ

๓. การเพิ่ม Model Explanation Method

- ความสามารถของโมเดลในการอธิบาย (Model Explanation) ด้วยเทคนิคสองแบบคือ GradCAM และ Overlay Gradient Magnitude ดังตัวอย่างที่แสดงในรูป



รูปที่ ๔๔: เทคนิค GradCAM และ Overlay Gradient Magnitude เพื่อเพิ่มความสามารถของโมเดลในการอธิบาย

จากภาพรูปซ้ายสุดจะเป็นรูปดั้งเดิม รูปตรงกลางจะเป็นรูปที่แสดง Gradient Magnitudes ซึ่งแสดงให้เห็นถึงขนาดของ Gradient ในบริเวณต่างๆ ในส่วนของรูปที่สามคือ GradCAM โดยบริเวณสีเขียวแสดงถึงบริเวณที่ Gradient เป็นบวกและสีแดงแสดงถึงบริเวณที่ Gradient มีค่าติดลบ อนึ่งความเป็นบวกติดลบของ Gradient ไม่สามารถแปลผลโดยตรงเป็น Benign หรือ Malignant ได้ แต่เป็นการแสดงบริเวณที่เกิดผลกระทบในการจำแนกสูง

๔. ทดลองทำนายผลด้วย Unlabeled Image(Blinded test images)

โดยในการทดลองนี้ทีมพัฒนาโมเดลจะไม่ทราบคำตอบในส่วนของการจำแนก ทีมวิจัยได้ทำการส่งผลทำนายให้กับทีมแพทย์ ได้ผลลัพธ์ในเชิงบรรยายว่า โมเดลสามารถจำแนกรูปภาพได้ในระดับดี โดยเฉพาะเมื่อเปรียบเทียบกับแพทย์จบใหม่ โดยการทำนายประกอบไปด้วยรูปภาพทั้งหมด ๘๐ ภาพ ได้ผลลัพธ์ดังตารางต่อไปนี้

no.	Class	Predicted	Confident
1	no_marker	Malignant	78.88
2	no_marker	Malignant	65.40
3	no_marker	Benign	58.95
4	no_marker	Malignant	59.80
5	no_marker	Benign	94.78
6	no_marker	Malignant	82.82


7	no_marker	Malignant	52.36
8	no_marker	Malignant	75.68
9	no_marker	Malignant	85.93
10	no_marker	Benign	68.12
11	no_marker	Malignant	50.78
12	no_marker	Malignant	79.12
13	no_marker	Benign	75.74
14	no_marker	Benign	81.67
15	no_marker	Benign	90.02
16	no_marker	Benign	95.94
17	no_marker	Benign	85.28
18	no_marker	Benign	99.53
19	no_marker	Benign	99.63
20	no_marker	Benign	63.20
21	no_marker	Benign	97.90
22	no_marker	Benign	91.74
23	no_marker	Malignant	65.92
24	no_marker	Benign	97.90
25	no_marker	Malignant	55.64
26	no_marker	Malignant	85.76
27	no_marker	Malignant	76.40
28	no_marker	Malignant	69.62
29	no_marker	Benign	54.12
30	no_marker	Malignant	70.43
31	no_marker	Benign	79.79
32	no_marker	Malignant	57.32
33	no_marker	Benign	83.76
34	no_marker	Malignant	63.08

35	no_marker	Benign	96.47
36	no_marker	Malignant	75.42
37	no_marker	Malignant	58.30
38	no_marker	Benign	92.29
39	no_marker	Malignant	62.63
40	no_marker	Benign	69.39
41	no_marker	Benign	98.43
42	no_marker	Benign	77.81
43	no_marker	Malignant	77.95
44	no_marker	Malignant	52.06
45	no_marker	Benign	57.97
46	no_marker	Malignant	68.69
47	no_marker	Malignant	62.11
48	no_marker	Malignant	71.44
49	no_marker	Benign	92.97
50	no_marker	Malignant	70.80
51	no_marker	Malignant	59.08
52	no_marker	Malignant	61.29
53	no_marker	Benign	55.06
54	no_marker	Benign	57.77
55	no_marker	Benign	63.04
56	no_marker	Malignant	59.83
57	no_marker	Malignant	61.48
58	no_marker	Malignant	84.16
59	no_marker	Benign	58.61
60	no_marker	Benign	63.19
61	marker	Benign	52.94
62	marker	Malignant	78.23



63	marker	Benign	95.79
64	marker	Malignant	59.91
65	marker	Benign	76.01
66	marker	Malignant	59.74
67	marker	Malignant	64.79
68	marker	Malignant	51.83
69	marker	Benign	70.22
70	marker	Malignant	80.54
71	marker	Benign	64.32
72	marker	Benign	96.95
73	marker	Benign	76.78
74	marker	Benign	86.20
75	marker	Benign	88.25
76	marker	Benign	80.44
77	marker	Benign	96.95
78	marker	Benign	92.14
79	marker	Malignant	69.99
80	marker	Benign	55.07

ตารางที่ ๕ แสดงผลลัพธ์การทำนาย



และตัวอย่างรูปผลลัพธ์แสดงดังต่อไปนี้






nodules_test_0001-0020_swu_c0015_1_p0186.png
Prediction: M
Prob: 0.70






nodules_test_0001-0020_siriraj_c0017_1_p0067.png
Prediction: B
Prob: 0.92





nodules_test_0001-0020_swu_c0011_1_p0172.png
Prediction: B
Prob: 0.97



nodules_test_0001-0020_siriraj_c0014_1_p0055.png
Prediction: B
Prob: 0.80




nodules_test_0001-0020_siriraj_c0016_1_p0063.png
Prediction: B
Prob: 0.88




nodules_test_0001-0020_siriraj_c0015_1_p0059.png
Prediction: B
Prob: 0.86




Overlaid Gradient Magnitudes




GradCAM




nodules_test_0001-0020_siriraj_c0013_1_p0051.png
Prediction: B
Prob: 0.77



Overlaid Gradient Magnitudes




GradCAM




nodules_test_0001-0020_siriraj_c0012_2_p0048.png
Prediction: M
Prob: 0.79




Overlaid Gradient Magnitudes




GradCAM




nodules_test_0001-0020_siriraj_c0012_1_p0047.png
Prediction: B
Prob: 0.64



Overlaid Gradient Magnitudes




GradCAM




nodules_test_0001-0020_swu_c0003_1_p0148.png
Prediction: B
Prob: 0.97




Overlaid Gradient Magnitudes



GradCAM






รูปที่ ๔๕ แสดงผลลัพธ์การทำนาย

- โมเดลการพัฒนาโมเดลการจำแนกก้อนเนื้อต่อมไทรอยด์ที่มีจำนวนชุดข้อมูลไม่ต่ำกว่า ๔๕๐ ชุด สำหรับโมเดลการจำแนกก้อนเนื้อต่อมไทรอยด์ ทีมวิจัยใช้ผลลัพธ์ที่ได้จากขั้นตอนตรวจจับก้อนเนื้อ เป็นข้อมูลเพิ่ม และทดลองเปรียบเทียบผลลัพธ์การจำแนกในสามแนวทางคือ

๑. ฝึกสอนโมเดลด้วยข้อมูลรูปภาพพร้อมกับข้อมูลหน้ากากและทดสอบด้วยข้อมูลรูปภาพพร้อมกับข้อมูลหน้ากาก

๒. ฝึกสอนโมเดลด้วยข้อมูลรูปภาพร่วมกับข้อมูลหน้ากากและทดสอบด้วยข้อมูลรูปภาพเพียงอย่างเดียว
๓. ฝึกสอนโมเดลด้วยข้อมูลรูปภาพเพียงอย่างเดียวและทดสอบด้วยข้อมูลรูปภาพเพียงอย่างเดียว (Baseline model)

โดยทีมวิจัยได้ทำการใช้ Resnet50 เป็น Baseline model เพื่อเปรียบเทียบเนื่องจากความเรียบง่ายของโครงสร้าง โดยโมเดล Resnet50 จะถูกนำมาเพิ่ม Input Channel จากเดิมที่มี ๓ Input Channel ให้กลายเป็น 4 โดยข้อมูล หน้ากาก(Mask) จะถูกนำมารวมกับข้อมูลรูปภาพในรูปแบบของ Alpha Channel ในฟอร์แมตรูปภาพแบบ RGBA ดังตัวอย่างที่แสดงต่อไปนี้



รูปที่ ๔๖: แสดงตัวอย่างข้อมูล Validation 8 ภาพในรูปแบบ RGBA

โดยการที่วิธีการรวมข้อมูล mask เข้ากับ input data เราจะเรียกวิธีการนี้ว่า early fusion ซึ่งจะแตกต่างกับวิธีการ late fusion ที่โมเดลจะใช้ข้อมูลเสริมในการเรียนรู้ในชั้นที่ลึกลงไป หรือในบางครั้งใช้ข้อมูลเสริมในชั้นก่อนหน้าที่จะสร้างผลทำนายเพียงอย่างเดียว สำหรับสาเหตุที่ทีมวิจัยเลือกใช้วิธีการ early fusion เนื่องจากต้องการรักษาข้อมูลเชิงตำแหน่งไว้ กล่าวคือการซ้อนทับกับของ Mask และตำแหน่งของก้อนเนื้อจะต้องมีความถูกต้องเชิงตำแหน่ง ซึ่งสามารถทำได้ยากในกระบวนการเสริมข้อมูลแบบ late fusion

เราสามารถแสดงกระบวนการทำงานของการเพิ่มข้อมูล Mask ในกระบวนการฝึกสอนโมเดลได้ดังรูปที่ ๔๖

โมเดล 4-channel ResNet50


ในการสร้าง 4-channel ResNet50 นั้นทีมวิจัยได้นำเอา pretrained weight ของ ResNet50 ที่ถูกฝึกสอนด้วยฐานข้อมูล ImageNet เดิมมาเพิ่มชุดของ weight สำหรับ channel ที่เพิ่มเข้ามาจะถูกตั้งค่าเริ่มต้น (initial weight) เป็นแบบสุ่ม หลังจากนั้นจึงนำโมเดลที่ได้มาฝึกสอนเพิ่มเติมเพื่อให้ model ปรับ weight parameter ทั้งหมดอีกครั้ง

ข้อมูล

สำหรับข้อมูลที่ได้นำมาฝึกสอนโมเดลในครั้งนี้มีจำนวนทั้งหมด ๑,๑๔๗ รูปภาพโดยเป็นชุดข้อมูลเดียวกับที่ใช้ในการสร้างหน้ากากสำหรับตรวจจับก้อนเนื้อ โดยที่ทุกภาพจะมีคู่ Mask แบบ ๑-๑ เสมอ

กระบวนการฝึกสอน

สำหรับกระบวนการฝึกสอนจะใช้กับ train ด้วย hyperparameter และ Data Augmentation scheme แบบเดียวกับที่ใช้ในรายงานครั้งก่อน โดยประกอบไปด้วยกระบวนการ สลับภาพในแนวนอน, การหมุนภาพ, การปรับมุมมอง, การซูมและการตัด โดยทั้งหมดเป็นกระบวนการแบบสุ่ม และเพื่อให้สามารถทำการทดลองซ้ำได้ ทีมวิจัยจึงกำหนด random seed คงที่ไว้ที่ ๒๕๖๕ ในการฝึกสอนจะทำการฝึกโมเดลด้วยขนาด Batch Size ๑๖ และทำการฝึกที่ ๘๐ รอบ



รูปที่ ๔๗: แสดงการเพิ่มเติมกระบวนการสำหรับเพิ่มรูปภาพ Mask ใน Alpha Channel

๓.๒.๓.๒ การจำแนกก่อนต่อมไทรอยด์ในภาพอัลตราซาวด์ WSDAN

งานวิจัยนี้เลือกใช้อัลกอริทึมการเรียนรู้เชิงลึกประเภทโครงข่ายประสาท Convolution เรียกว่า Weakly Supervised Data Augmentation Networks (Hu, Huang, และ Lu, ๒๐๑๙) หรือ WSDAN ซึ่งนิยมใช้ในการแยกประเภทข้อมูลที่มีความแตกต่างกันเล็กน้อย (Fined grain classification) ทำให้ยากแก่การจำแนก เช่น การแยกสายพันธุ์ของนกนางนวล (Hu, Huang, และ Lu, ๒๐๑๙) การทำนายโอกาสการเกิดโรคสมองเสื่อม (Dementia) ด้วยคลื่นแม่เหล็ก หรือ MRI (Deng et al., ๒๐๒๐) เป็นต้น จุดเด่นของ WSDAN คือการใช้ความสามารถของการวิเคราะห์ข้อมูลในระดับ pixel เพื่อค้นหารูปแบบที่มีความสัมพันธ์เพื่อระบุตำแหน่งของก้อนเนื้องอกต่อมไทรอยด์พร้อมกับการทำนายประเภทของก้อนเนื้องอกต่อมไทรอยด์ได้อย่างแม่นยำ (Namsena et al., ๒๐๒๓) โมเดล WSDAN ถูกออกแบบด้วยอัลกอริทึมที่มีความสามารถในการสร้างชุดข้อมูลเสริม (Data Augmentation) ระหว่างฝึกการเรียนรู้โดยพิจารณาจาก Attention map ที่ได้จากการฝึกสอนในแต่ละรอบ ช่วยให้ข้อมูลเสริมที่ถูกสร้างเพิ่มขึ้นมานี้ไม่ได้มาจากการสุ่มและชุดข้อมูลดังกล่าวยังมีลักษณะคุณสมบัติที่สอดคล้องกับการวิเคราะห์ข้อมูลของรังสีแพทย์ในการวินิจฉัยโอกาสที่ก้อนเนื้องอกต่อมไทรอยด์จะเป็นก้อนเนื้อมะเร็งแสดงดังรูปที่ ๕๐ (D) และ (F) แสดง Attention map ที่ได้จาก Feature maps ที่ถูกสร้างขึ้นจากการเรียนรู้ของโมเดล

WSDAN ในส่วนของโครงข่ายประสาท Convolution layers ร่วมกับ Fully connected layers แสดงให้เห็นจำนวน pixel บนภาพอัลตราซาวด์ที่มีค่าการตอบสนองของโครงข่ายประสาทเทียมสูงโดยเฉพาะบริเวณที่โมเดลให้ความสนใจเป็นพิเศษ (พื้นที่สีแดงเข้ม) โดยสมการที่ใช้ในการสร้าง Attention map (A) แสดงในสมการที่ ๑


$$A(I) = f(I * W) \quad (๑)$$

เมื่อ A(I) คือ Attention map


f คือ ฟังก์ชันสร้าง Feature map

W คือ Weights และ Biases ของโครงข่ายประสาทเทียม

การที่โมเดล WSDAN สร้าง Attention map ช่วยเพิ่มความสามารถในการจำแนกประเภทของก้อนเนื้ออกต่อมไทรอยด์ได้ดียิ่งขึ้น ในงานวิจัยนี้โมเดล WSDAN ถูกฝึกสอนเพื่อจำแนกก้อนเนื้ออกต่อมไทรอยด์โดยแบ่งออกเป็นสองประเภทคือก้อนเนื้ออกชนิดดีหรือก้อนเนื้ออกชนิดร้าย เทคนิคการสุ่มเพิ่มจำนวนข้อมูลที่เรียกว่า Data augmentation ได้แก่เทคนิค image translation เช่น shear, rotation, zoom in และ horizontal flip จึงถูกนำมาใช้เพื่อเพิ่มปริมาณของข้อมูลให้เพียงพอต่อการสร้างชุดฝึกการเรียนรู้แสดงดังรูปที่ 8 ในงานวิจัยนี้จะไม่ใช่เทคนิคการสร้างชุดข้อมูลเพิ่มแบบสุ่ม เช่น vertical flip, high degree of rotation และ shear เพราะบางครั้งอัลกอริทึมแบบสุ่มดังกล่าวอาจสร้างข้อมูลที่ไม่สมเหตุสมผลสำหรับการวินิจฉัยก้อนเนื้ออกต่อมไทรอยด์แสดงดังรูปที่ ๘๘



รูปที่ ๔๘ (A) ภาพอัลตราซาวด์ต้นแบบ (B) Rotation (C) Horizontal flip (D) Shear



รูปที่ ๔๙ (A) ภาพอัลตราซาวด์ต้นแบบ (B) Vertical flip (C) High degree of rotation

นอกจากเทคนิค image transformation ที่แสดงในรูปที่ ๔๙ ยังมีการเพิ่มชุดข้อมูลสำหรับฝึกการเรียนรู้ด้วยทักษะความสามารถของโมเดล WSDAN ที่เรียกว่า Weakly supervised Data Augmentation ประกอบด้วย

$$A_k^* = \frac{A_k - \min(A_k)}{\max(A_k) - \min(A_k)}$$

Attention cropping และ Attention dropping mechanism โดยใช้สมการที่ ๒ ในการสร้าง Augmentation Map (A_k^*)


(๒)

และการสร้างภาพชุดข้อมูลเสริมด้วยเทคนิค Attention cropping แสดงดังสมการที่ ๓ ซึ่งเอาต์พุตที่ได้จะเป็นค่าที่มีการตอบสนองการเรียนรู้ของโครงข่ายประสาทเทียมที่สูงกว่าค่าที่กำหนดไว้ และสมการที่ ๔ แสดงสมการในการสร้างชุดข้อมูลเสริมด้วยเทคนิค Attention dropping

$$C_k(i, j) = \begin{cases} 1, A_k^*(i, j) > 0 \\ 0, \text{otherwise} \end{cases} \quad (๓)$$


$$D_k(i, j) = \begin{cases} 0, A_k^*(i, j) > 0 \\ 1, \text{otherwise} \end{cases} \quad (๔)$$

โมเดล WSDAN สร้างชุดข้อมูลเสริมโดยการสร้างชุดข้อมูลจากสิ่งที่โมเดล WSDAN ให้ความสนใจเป็นพิเศษส่งผลให้ข้อมูลที่ถูกสร้างเพิ่มขึ้นมานี้จะเป็นข้อมูลที่เกี่ยวข้องคุณลักษณะที่สำคัญที่ใช้สำหรับการวิเคราะห์ก้อนเนื้ออกต่อมไทรอยด์เพื่อจำแนกชนิดก้อนเนื้ออกระหว่างก้อนเนื้ออกชนิดดีหรือก้อนเนื้ออกชนิดร้าย ตัวอย่างการสร้างชุดข้อมูลเพิ่มของโมเดล WSDAN แสดงดังในรูปที่ ๕๐



(A) ภาพต้นแบบ (B) ก้อนเนื้องอกต่อมไทรอยด์ชนิดร้ายแสดงเนกรอบสเลียมทขาว (C) ภาพต้นแบบที่ถูกปรับขนาด (D) บริเวณที่โมเดล WSDAN ให้ความสนใจโดยสีแดงแสดงถึงการให้คะแนนความสนใจสูง (E) ชุดภาพที่ถูกสร้างขึ้นจากพื้นที่ที่โมเดล WSDAN ให้ความสนใจ (กรอบสี่เหลี่ยมสีแดง) และถูกปรับขนาดเพื่อป้อนให้โมเดล WSDAN เรียนรู้ต่อไป (Auto cropping mechanism) (F) บริเวณที่โมเดล WSDAN ให้ความสนใจโดย (G) ชุดภาพที่ถูกสร้างขึ้นจากการจากลบพื้นที่ในบริเวณโมเดล WSDAN ให้ความสนใจ (Auto dropping mechanism)

สำหรับโจทย์ในการออกแบบโมเดลแยกแยะที่มันงานได้ทำการศึกษาและวิเคราะห์โจทย์เพื่อคัดเลือกโมเดลเบื้องต้น และได้นำเสนอรูปแบบโครงสร้างดังแสดงในรูปที่ ๕๑



รูปที่ ๕๑: แสดงขั้นตอนการทำงานของโมเดลทำนายความผิดปกติของก้อนเนื้อต่อมไทรอยด์

ในส่วนของการฝึกสอนโมเดลนั้นอ้างอิงตามงานวิจัยแสดงรายละเอียดดังภาคผนวก ข และนำมาปรับใช้เพื่อให้เข้ากับลักษณะของข้อมูลที่จะนำมาฝึกสอน เนื่องจากลักษณะของโจทย์มีลักษณะที่เป็นการแยกแยะภาพในแบบละเอียด (Fine-grained classification problem) โมเดล Weakly Supervised Data Augmentation Network (WSDAN) นั้นสามารถที่จะเรียนรู้จุดสนใจของภาพโดยใช้เพียงแค่ข้อมูลในระดับ Label โดยมีความแม่นยำในการจำแนกภาพในแบบละเอียดอยู่ที่ ๘๙.๔%, ๙๓.๐% และ ๙๔.๕% เมื่อทดลองกับชุดข้อมูล CUB-200-2011, FGVC-Aircraft และ Stanford Cars ตามลำดับ อย่างไรก็ตามเนื่องจาก โจทย์ในงานวิจัยนี้ สามารถเข้าถึงข้อมูล Markers ที่ปรากฏบนภาพ Ultrasound ทางผู้วิจัยจึงเพิ่มส่วนของ Attention Mask Builder ซึ่งเปรียบเสมือนการให้ข้อมูลเสริมแก่โมเดลในบริเวณที่ควรจะให้ความสนใจเป็นพิเศษ จากภาพที่ ๕๕ โครงสร้างของเน็ตเวิร์กนั้น จะถูกเพิ่มส่วนของ Attention Mask Builder ซึ่งเป็นการนำข้อมูลพิเศษที่ได้จาก Localizer module มารระบุ บริเวณที่น่าสนใจเป็นพิเศษ เพื่อให้โมเดลสามารถเรียนรู้บริเวณได้ถูกต้อง ในขั้นตอนการทำ Inference นั้น Model จะใช้เพียง Cropped Image เพื่อช่วยเพิ่มความแม่นยำในการทำนาย และให้ผลลัพธ์ออกเป็นผลการทำนายพร้อมทั้งบริเวณที่มีความน่าสนใจเป็นพิเศษ

การออกแบบดังกล่าวอ้างอิงตามข้อสรุปการวิเคราะห์ดังนี้

- การแยกแยะมีลักษณะเป็น High-intraclass variance
- ดังนั้นโมเดลในแยกแยะจำเป็นต้องมีความสามารถในการค้นหาและจำแนกส่วนรายละเอียด (Discriminative Parts)

- ข้อมูลนำเข้ามีความเบ้ (Skew) ปานกลาง คือมีภาพที่จัดอยู่ในหมวด Malignant ต่อ Benign ในอัตราส่วน ๑: ๔

- ข้อมูลนำเข้ามีลักษณะเป็น Weakly-supervised กล่าวคือข้อมูลรูปภาพมีเพียงการระบุชนิดของภาพว่าเป็น Malignant หรือ Benign โมเดลจำเป็นต้องอาศัยความรู้ในการค้นหา Discriminative Parts

- ข้อมูลนำเข้ามีความไวต่อความต่างของสี (Contrast) เนื่องจากลักษณะของภาพ Ultrasound จะให้ข้อมูลที่เป็นการสะท้อนของคลื่น Ultrasound โดย ณ จุดที่มีการสะท้อนมากจะมี Pixel value มากและถูกแสดงเป็นสีขาวในขณะที่จุดที่มีการสะท้อนน้อยจะถูกแสดงเป็นสีมืด

- ข้อมูลนำเข้าอาจจะมีการแปรผันในลักษณะ Horizontal Flip
- ข้อมูลนำเข้าอาจจะมีหรืออาจไม่มี Mark Point Annotation ที่บริเวณก้อนเนื้อในภาพ

- ข้อมูลนำเข้าจะถูกนำมาประมวลผลเพื่อทำ Localization ตำแหน่งของก้อนเนื้อด้วยโมเดลจากของ ๒.๒.๒
- มีโอกาสที่ข้อมูลนำเข้าจะมีความผิดพลาดจาก Mis-labelled
- มีโอกาสที่ข้อมูลนำเข้าจะประกอบไปด้วยวัตถุแปลกปลอมส่งผลให้โมเดลพุ่งจุดสนใจไปยังวัตถุนั้น


จากข้อสรุปดังกล่าวที่ทีมงานวิจัยได้จัดหมวดหมู่ของปัญหาออกเป็น ๓ หมวดดังนี้

๑. ปัญหาที่เกิดจากชุดข้อมูลมีการกระจายแบบไม่ใช้โค้งปกติ แก้ปัญหาโดยการทำ Data Augmentation อิงชุดความรู้ที่ทีมงานวิจัยได้จากทีมแพทย์ได้แก่การเพิ่มปริมาณข้อมูลด้วยการสุ่มทำ Horizontal Flipping
๒. ปัญหาที่เกิดจากข้อมูลนำเข้ามีวัตถุวงกลมสะท้อนคลื่นที่ไม่ใช่เนื้อเยื่อปกติ แก้ปัญหาโดยตรวจสอบและคัดแยกข้อมูลนำเข้าโดยทดลองเปรียบเทียบกันระหว่างการใช้ข้อมูลประกอบไปด้วยภาพวัตถุวงกลมสะท้อนคลื่นในส่วน Training และในส่วน Validation data
๓. ปัญหาที่เกิดจากตัวโมเดลพุ่งความสนใจไปยังบริเวณที่ใกล้เคียงจากบริเวณต่อมไทรอยด์ เนื่องจาก ลักษณะของชุดข้อมูลภาพ Ultrasound ทำให้ค่าเฉลี่ยของสีในแต่ละชุดข้อมูล มีลักษณะใกล้เคียงกันดังนั้นจึงมี ความเป็นไปได้ที่จะสามารถทดลองปรับ Hyperparameter ในส่วนของ Cropping and Dropping Threshold เพื่อหาค่าที่ดีที่สุด นอกจากนี้ออกแบบโมเดลให้มีความสามารถในการแยกแยะส่วนต่าง ๆ ของวัตถุโดยใช้ความรู้ เพียงแค่ส่วน Label ของภาพ


รายละเอียด Model Design:

- ResNet34 based model
- Auto Augmentations: Horizontal Flipping, Random Cropping
- Model Discriminator: Weakly Supervised Data Augmentation Network for Fine-Grained Visual Classification (WSDAN)
- Optimizer: SGD

Preliminary Results: รูปแสดงตัวอย่างผลเบื้องต้นบางส่วนที่ได้จากการทำนาย



รูปที่ ๕๒: แสดงตัวอย่างของผลการทำนายที่ได้จากโมเดลที่ออกแบบไป




รูปที่ ๕๓: แสดงขั้นตอนการทำงานของโมเดลทำนายความผิดปกติของก้อนเนื้อต่อมไทรอยด์อย่างละเอียด

๓.๒.๓.๓ การจำแนกก้อนต่อมไทรอยด์ในภาพอัลตราซาวด์ Enhanced – WSDAN


(องค์ความรู้ที่ได้จากการวิจัยและทดลองอยู่ระหว่างกระบวนการนำเสนอผ่านวารสารวิชาการระดับนานาชาติ ในหัวข้อ Enhancing Weakly Supervised Data Augmentation Networks for Thyroid Nodule Assessment Using Traditional and Doppler Ultrasound Images รายละเอียดเพิ่มเติมในภาคผนวก ข)

ชุดข้อมูลภาพจำนวน ๑๕๐ ชุดได้ถูกรวบรวมโดยรังสีแพทย์ที่มีความเชี่ยวชาญในการวินิจฉัยไม่น้อยกว่า ๓ ปี และผลการจำแนกประเภทของก้อนเนื้อต่อมไทรอยด์ในชุดภาพข้อมูลเหล่านี้ได้ผ่านกระบวนการตรวจสอบอย่างละเอียดเพื่อให้มั่นใจว่าผลการจำแนกมีความถูกต้องสูงสุด เพื่อการเรียนรู้ที่มีประสิทธิภาพของโมเดลจำแนกก้อนเนื้อต่อมไทรอยด์ระหว่างก้อนเนื้อดีและก้อนเนื้อร้าย โดยกระบวนการจำแนกประเภทก้อนเนื้อของต่อมไทรอยด์แต่ละชุดภาพแสดงดังรูปที่ ๕๔




รูปที่ ๕๔ แสดงกระบวนการจำแนกประเภทก้อนเนื้อของต่อมไทรอยด์แต่ละชุด

ชุดภาพข้อมูลจำนวน ๑๕๐ ชุด จะถูกแบ่งออกเป็นชุดภาพข้อมูลสำหรับก้อนเนื้อดีจำนวน ๗๕ ชุดและก้อนเนื้อร้ายจำนวน ๗๕ ชุด แสดงดังรูปที่ ๕๕ เพื่อให้โมเดลจำแนกประเภทก้อนต่อมไทรอยด์มีโอกาสที่จะเรียนรู้ก้อนต่อมไทรอยด์ที่เป็นก้อนเนื้อร้ายและก้อนเนื้อดีในจำนวนที่เท่ากัน (Balanced dataset)



รูปที่ ๕๕ แผนภูมิแท่งแสดงจำนวนชุดภาพข้อมูลของก้อนต่อมไทรอยด์ที่เป็นก้อนเนื้อดีและร้าย

จากจำนวนชุดภาพข้อมูลจำนวน ๑๕๐ ชุดจะถูกแบ่งออกเป็น ๓ ส่วนเพื่อใช้ในการเรียนรู้ของโมเดลการเรียนรู้เชิงลึกได้แก่ training , validation , และ test set แผนภูมิแสดงดังรูปที่ ๕๖




รูปที่ ๕๖ แผนภูมิแท่งแสดงจำนวนชุดภาพข้อมูลส่วนต่าง ๆ เพื่อใช้สำหรับการเรียนรู้ของโมเดล
การประมวลผลชุดภาพข้อมูลเบื้องต้น (Data Preprocessing)

เนื่องจากชุดภาพข้อมูลที่ได้มาไม่สมบูรณ์แบบเพื่อให้การพัฒนาโมเดลมีความยืดหยุ่นการประมวลผลชุดภาพเบื้องต้นจึงจำเป็น โดยมีขั้นตอนต่าง ๆ ดังนี้

- Image inpainting (Conventional Ultrasound image)


เนื่องจากภาพที่ได้จากรังสีแพทย์ส่วนใหญ่จะเป็นภาพอัลตราซาวด์ที่มาพร้อมกับมาร์ค (marks) ที่ใช้แสดงขอบเขตของก้อนเนื้อต่อมไทรอยด์ ดังนั้นในการทดลองเบื้องต้นทีมงานจึงได้ทำการลบมาร์คที่บริเวณก้อนเนื้อต่อมไทรอยด์เพื่อสนับสนุนการเรียนรู้ของโมเดลให้พิจารณาเฉพาะคุณสมบัติของภาพ อัลตราซาวด์ที่ใช้ในการวิเคราะห์เพื่อจำแนกก้อนเนื้อต่อมไทรอยด์และหลีกเลี่ยงการจำคุณลักษณะของก้อนเนื้อด้วยมาร์ค



รูปที่ ๕๗ ภาพแสดงตัวอย่างการทำ Image inpainting

- Region of Interest (Conventional Ultrasound image)

ในการทดลองเบื้องต้นภาพอัลตราซาวด์จะถูกใช้เฉพาะบริเวณที่มีก้อนเนื้อปรากฏ ซึ่งโมเดลการตรวจจับก้อนเนื้อต่อมไทรอยด์ที่ถูกอธิบายใน section-thyroid nodule detection จะทำหน้าที่ตรวจจับมาร์ค เพื่อใช้สำหรับกำหนดขอบเขตก้อนเนื้อต่อมไทรอยด์ ROI (Region of Interest) โดยครอบคลุมบริเวณที่มีความสำคัญสำหรับการวิเคราะห์ก้อนเนื้อ เพื่อใช้เป็นภาพอินพุตที่มีขนาดความกว้างและความสูงเท่ากันให้กับโมเดลจำแนกประเภทก้อนเนื้อต่อมไทรอยด์ซึ่งรับข้อมูลเป็นทรงจัตุรัสแสดงดังรูปที่ ๕๘



รูปที่ ๕๘ ภาพแสดงตัวอย่างการกำหนด Region of Interest ด้วย marks detection model

- Region of Interest (Doppler)


จากกระบวนการสร้างภาพ Doppler ของรังสีแพทย์ทำให้สามารถทราบขอบเขตเบื้องต้นของก้อนเนื้อต่อมไทรอยด์ได้จากขอบสีเหลืองแสดงดังรูปที่ ๕๙ ภาพอินพุตที่ได้จึงเกิดจากการตรวจจับขอบและสร้างภาพขึ้นมาใหม่จากขอบเขตนั้นเพื่อใช้ป้อนให้เป็นอินพุตสำหรับโมเดลจำแนกประเภทของก้อนเนื้อต่อมไทรอยด์ ซึ่งภาพ Doppler ในบางชุดข้อมูลรังสีแพทย์จะไม่ได้สร้าง แต่อย่างไรก็ดีในกรณีที่ไม่มีภาพ Doppler ขอบเขตของภาพ Doppler จะช่วยสนับสนุนการเรียนรู้ของโมเดลให้มีประสิทธิภาพยิ่งขึ้น



รูปที่ ๕๙ ภาพแสดงตัวอย่างการกำหนด Region of Interest ของภาพ Doppler

การเพิ่มข้อมูล (Data Augmentation)

เนื่องจากจำนวนชุดข้อมูลที่มีน้อยสำหรับการเรียนรู้เชิงลึก รูปแบบจึงถูกปรับเปลี่ยนไปในรูปแบบต่าง ๆ เพื่อเพิ่มจำนวนรูปแบบการเรียนรู้ให้โมเดล ด้วยเทคนิคดังนี้ Rotation, horizontal flip, vertical flip และ Zoom



รูปที่ ๖๐ ตัวอย่างการสร้างรูปภาพขึ้นมาใหม่ด้วยเทคนิคแบบต่าง ๆ

๓.๒.๓.๔ การจำแนกก้อนต่อมไทรอยด์ในภาพอัลตราซาวด์ ด้วยมาตรฐาน TI-RADS

(องค์ความรู้ที่ได้จากการวิจัยและทดลองอยู่ระหว่างกระบวนการนำเสนอผ่านวารสารวิชาการระดับนานาชาติ ในหัวข้อ Explainable Automated TI-RADS Evaluation of Thyroid Nodules รายละเอียดเพิ่มเติมในภาคผนวก ข)


๓.๒.๓.๕ การจำแนกก้อนต่อมไทรอยด์ในภาพอัลตราซาวด์ Multi-center

(องค์ความรู้ที่ได้จากการวิจัยและทดลองอยู่ระหว่างกระบวนการนำเสนอผ่านวารสารวิชาการระดับนานาชาติ ในหัวข้อ Diagnostic Performance of Artificial Intelligence in Interpreting Thyroid Cancer on Ultrasound Images in the Multi-center Study รายละเอียดเพิ่มเติมในภาคผนวก ข)

๓.๒.๓.๖ การจำแนกก้อนต่อมไทรอยด์ด้วยชุดฝึกการเรียนรู้ภาพอัลตราซาวด์

(องค์ความรู้ที่ได้จากการวิจัยและทดลองอยู่ระหว่างกระบวนการนำเสนอผ่านวารสารวิชาการระดับนานาชาติ ในหัวข้อ Curriculum Learning for Assessing Thyroid Nodules Using Imbalanced Ultrasound Images รายละเอียดเพิ่มเติมในภาคผนวก ข)

๓.๓ การออกแบบเซิร์ฟเวอร์ประมวลผลและเซิร์ฟเวอร์สำหรับจัดเก็บข้อมูล (Storage server และ Compute server)



รูปที่ ๖๑: แผนผังของระบบเน็ตเวิร์คสำหรับเซิร์ฟเวอร์

๓.๓.๑ คุณสมบัติของเซิร์ฟเวอร์ประมวลผลและเซิร์ฟเวอร์สำหรับจัดเก็บข้อมูล

➤ SuperMicro SuperServer 2029P-C1RT 2U

- 1 x Intel Xeon Gold 5218 4/2P 16C/32T 2.3G 22M 10.4GT 125W
- 1 x 16GB DDR4-2666 2Rx8 ECC REG DIMM
- 2 x SSD 480GB SATA 6Gb/s 3D TLC 2.5" 7mm <2DWPD Rev.2
- 1 x Dual 1GbE LAN Intel i350, 1 x DVD Internal 5.25" 2 x 10GBase-T LAN ports with Intel X722 Onboard
- Broadcom 3108 SAS3 (12Gbps) controller; HW RAID 0, 1, 5, 6, 10, 50, 60 2Gb Cache
- 1200W Redundant Power Supplies Titanium Level (96%)



รูปที่ ๖๒: แสดงตัวอย่างของ Storage server

➤ APC SMT1500IC Kit

- APC Smart-UPS 1500VA LCD 230V with Smart connect3Y Extended Warranty NBD On-Site Upgrade



รูปที่ ๖๓: แสดงตัวอย่างของ UPS

➤ **SuperMicro GPU Server 7049GP-TRT / 4U Tower + Rack Mount Kit**

- 2 x Intel Xeon Gold 5218 4/2P 16C/32T 2.3G 22M 10.4GT 125W
- 64GB RAM (4 x 16GB DDR4-2666 2Rx8 ECC REG DIMM)
- 2 x SSD 960GB SATA 6Gb/s 3D TLC 2.5" 7mm <2DWPD Rev.2
- 4 x Nvidia RTX 2080ti 11GB GDDR6 1 x Quad-port GbE controller with 4x RJ45 ports
- Intel® X550 Dual Port 10GBase-T Onboard
- 2200W Redundant Power Supplies Titanium Level (96%)



รูปที่ ๖๔: แสดงตัวอย่างของ GPU server

๓.๓.๒ การออกแบบระบบจัดเก็บข้อมูลและประมวลผลออนไลน์ที่ศูนย์ปัญญาประดิษฐ์ สถาบันเทคโนโลยีแห่งเอเชีย ให้มีมาตรฐานความปลอดภัยเพื่อป้องกันการคุกคามด้วยเทคโนโลยีไซเบอร์ตามแนวทางพระราชบัญญัติมั่นคงไซเบอร์ (Cyber Security Act) พ.ศ. ๒๕๖๒

- ผู้ใช้หลักของระบบคือรังสีแพทย์ผู้ทำหน้าที่อัปโหลดรูปภาพที่ปราศจากข้อมูลของคนไข้เข้าสู่ระบบ ซึ่งภาพเหล่านั้นจะถูกเก็บไว้ในหน่วยความจำหลักของระบบเว็บไซต์ ผู้วิจัยได้


ออกแบบให้มีการเข้ารหัสข้อมูลรูปภาพ (encryption) ด้วยการเข้ารหัสโพลีเตอร์ที่ใช้จัดเก็บข้อมูลรูปภาพทั้งหมดในระบบเฟรมเวิร์ค ในที่นี้คือ Home directory

- ระบบปฏิบัติการที่ใช้ในการควบคุมการทำงานของเซิร์ฟเวอร์คือระบบปฏิบัติการ Ubuntu ซึ่งใช้ eCryptfs สำหรับการเข้ารหัสข้อมูล เมื่อผู้ใช้ login เข้าระบบ home directory ของผู้ใช้จะถูกเข้ารหัสโดยอัตโนมัติด้วยรหัสผ่าน (password) ของผู้ใช้ ซึ่งการเข้ารหัสและถอดรหัสโพลีเตอร์ของผู้ใช้จะถูกจัดการโดยระบบปฏิบัติการเป็นหลัก
- ในการออกแบบฐานข้อมูลของเว็บไซต์ที่ทีมผู้วิจัยใช้ Postgres DBMS ซึ่งซอฟต์แวร์จัดการระบบฐานข้อมูล มีกลไกในการเข้ารหัสและถอดรหัสที่มีมาตรฐาน (encrypt/decrypt for data-at-rest) นอกเหนือจากนี้ยังมีระบบความปลอดภัยในระดับ Transport Layer Security (TLS) ที่ได้รับการยอมรับในระดับอุตสาหกรรม และยังรองรับระบบ authorization ที่มีมาตรฐาน PostgreSQL ยังรองรับการเข้ารหัสในหลายระดับและมีความยืดหยุ่นในการรองรับการออกแบบเพื่อให้มีมาตรฐานความปลอดภัยสูง ทั้งในส่วน of ข้อมูล (Database sever) ผู้ดูแลระบบฐานข้อมูล (Administrators) และการสื่อสารข้อมูลในเครือข่าย (Networks)
- สำหรับการออกแบบระบบ Retraining model ซึ่งเป็นการฝึกโมเดลในระบบเฟรมเวิร์ค โดยใช้รูปที่รังสีแพทย์อัลโพลิตขึ้นระบบและได้รับการตรวจสอบความถูกต้องแล้ว ด้วย AutoMR ซึ่งระบบจะสามารถเข้าถึงข้อมูล ที่เก็บไว้ในฐานข้อมูลของเว็บไซต์ดังกล่าวด้วยระดับการเข้าถึงแบบ read only access permission โดยผู้ดูแลระบบฐานข้อมูลจะเป็นผู้กำหนดสิทธิในการเข้าถึงข้อมูลเพื่อความปลอดภัยของระบบเฟรมเวิร์ค
- การออกแบบระบบสำรองข้อมูลเพื่อป้องกันข้อมูลสูญหายหรือเสียหายเมื่อมีความผิดปกติเกิดขึ้นที่ระบบฐานข้อมูลหลักของเซิร์ฟเวอร์หลัก ทีมผู้วิจัยออกแบบให้มีการสำรองข้อมูลอย่างสม่ำเสมอ (periodically scheduled scripts) ซึ่งระบบฐานข้อมูลสำรองจะถูกเก็บไว้ด้วยเทคโนโลยี mirroring (RAID 1) ซึ่งจะใช้อุปกรณ์ QNAP TS-251+, 2 bay)
- ระบบ Anti-virus ถูกรองรับด้วยระบบปฏิบัติการ Ubuntu ซึ่งมีกลไกในการรักษาความปลอดภัยจาก malware
- ระบบ Firewall การเข้าถึงเซิร์ฟเวอร์จะทำผ่านพอร์ตที่มีความปลอดภัย (ระบบ firewall โรงพยาบาลศิริราช)

- ระบบ Logging ในส่วนของเว็บไซต์จะถูกจัดการด้วย application log ส่วนของการรีเทรนมอเดลจะถูกจัดการด้วยระบบ AutoMR

๓.๓.๓ สรุปผลการพัฒนาระบบจัดเก็บข้อมูลและประมวลผลออนไลน์

- ราคาของ Computer Graphic Unit (GPU) ปรับตัวสูงขึ้นมาก โดยราคา ณ ปัจจุบันมีราคาสูงกว่าใบประเมินราคาที่ยื่นขอตอนเสนอโครงการประมาณ ๑๕๐,๐๐๐ บาท ซึ่งมีปัจจัยเนื่องมาจากความต้องการใช้อุปกรณ์เพิ่มขึ้นสูงในช่วงการเกิดโรคระบาด Covid19 และปัจจัยเสริมอื่นๆ ดังนั้นทางทีมผู้วิจัยได้เขียนบันทึกข้อความเสนอผู้อำนวยการกองทุนพัฒนาและวิจัยฯ เพื่อชะลอการสั่งซื้ออุปกรณ์ออกไปก่อนดังเอกสารแนบ
- แผนการพัฒนาระบบคอมพิวเตอร์ช่วยวินิจฉัยด้วยแบบจำลองการเรียนรู้เชิงลึกเพื่อใช้ในการตรวจจับและจำแนกชนิดของก้อนต่อมไทรอยด์ระหว่างก้อนเนื้อดีและก้อนเนื้อร้ายด้วยการใช้ภาพอัลตราซาวด์ร่วมกับภาพ Doppler



รูปที่ ๖๕: แผนผังของระบบ (System Integration Diagram)

จากแผนผังการพัฒนาระบบคอมพิวเตอร์ช่วยวินิจฉัยด้วยแบบจำลองการเรียนรู้เชิงลึกสามารถสรุปแผนการพัฒนาดังนี้

ตารางที่ ๖ แผนการพัฒนาระบบคอมพิวเตอร์ช่วยวินิจฉัยระบบประเมินก้อนต่อมไทรอยด์ด้วยภาพอัลตราซาวด์

ลำดับที่	หัวข้อ	ผู้รับผิดชอบ	หมายเหตุ
๑	การพัฒนา UI/UX ของระบบฯ - Logo, icons - Themes - Layout - User flows	Logsig	เสร็จสิ้น
๒	การพัฒนา Web application - Interface - Database	Nextmed	เสร็จสิ้น
๓	โมเดลการเรียนรู้เชิงลึก - Thyroid nodule detection - Thyroid nodule classification	ศูนย์ปัญญาประดิษฐ์ AIT	เสร็จสิ้น
๔	Preprocessing process - Patient information removal	ศูนย์ปัญญาประดิษฐ์ AIT	เสร็จสิ้น

บทที่ ๔

ผลการวิจัย และวิจารณ์ผล

ในบทนี้จะอธิบายผลการประเมินความแม่นยำของโมเดลตรวจจับและจำแนกก้อนเนื้อต่อมไทรอยด์ตามวิธีการทดลองที่ได้กล่าวไปในบทที่ ๓


๔.๑ ผลความแม่นยำของโมเดลคัดตรวจจับก้อนต่อมไทรอยด์ด้วยภาพอัลตราซาวด์

๔.๑.๑ Thyroid nodule detection ด้วยอัลกอริทึม YOLO


ผลการทดลองที่ ๑

ผู้วิจัยได้ทำการทดลองค้นหาตำแหน่งที่จะใช้ในการวินิจฉัย โดยใช้ YOLO: Real-Time Object Detection ผู้วิจัยใช้ภาพอัลตราซาวด์ทั้งหมด ๓๒๐ ภาพจากทั้งสองประเภทได้แก่ benign และ malignant ผู้วิจัยใช้ภาพ ๒๘๘ ภาพในการเทรน และ validation test ทั้งหมด ๒๐ ภาพ ในการวัดค่า Accuracy ของโมเดลผู้วิจัยใช้ภาพในการตรวจสอบทั้งหมด ๑๒ ภาพจากทั้งสองประเภท

โมเดลปัญญาประดิษฐ์เพื่อใช้สำหรับตรวจจับมาร์คที่แสดงตำแหน่งและขอบเขตของก้อนเนื้อต่อมไทรอยด์ (Thyroid Detection Model) ภาพที่ใช้สำหรับการพัฒนาโมเดลจะเป็นภาพอัลตราซาวด์ที่มีมาร์คแสดงตำแหน่งและขอบเขตของก้อนเนื้อต่อมไทรอยด์จำนวน ๓๐๐ ภาพ แสดงตัวอย่างดังรูปที่ ๖๕




รูปที่ ๖๖ แสดงตัวอย่างภาพอัลตราซาวด์และมาร์คที่ใช้สำหรับพัฒนาโมเดลตรวจจับก้อนต่อมไทรอยด์



รูปที่ ๖๗: แสดง loss ในการเทรนโมเดล

ผลการทดลองที่ ๒

โมเดล yolo รุ่นที่ ๕ จึงถูกเลือกใช้ในงานวิจัยนี้ และผู้วิจัยได้เลือกใช้โมเดล ขนาดเล็กที่สุด (โมเดล yolov5) เพราะความเร็วในการหาที่รวดเร็วกว่าโมเดลที่มีขนาดใหญ่ ในการทดลองหาสัญลักษณ์ได้นำเอาภาพจำนวน ๓๒๒ ภาพมาแบ่งออกเป็นภาพชุดฝึก (Train set) จำนวนร้อยละ ๙๐ หรือ ๒๙๐ ภาพ และภาพชุดตรวจสอบ (Validation set) จำนวนร้อยละ ๑๐ หรือ ๓๒ ภาพ มาฝึกหัดอ่านสัญลักษณ์ที่มีอยู่ในภาพด้วยโมเดล Yolov5s จำนวน ๑๐๐๐ รอบ จนค่าน้ำหนัก ตัวแปร (weights) เข้าสู่จุดเสถียร โดยการฝึกโมเดลแต่ละรอบนั้นมีการวัดผลด้วยการนำภาพชุดตรวจสอบมาทดลองหลังการฝึกเพื่อ ตรวจสอบการเรียนรู้ว่าเกิด over-fitting หรือ under-fitting หรือไม่ ซึ่งผลการทดลองแสดงผลดังภาพด้านล่าง




รูปที่ ๖๘: แผนภาพสรุปรวมผลการฝึกของโมเดล YOLOv รุ่นที่ ๕

โดยภาพชุดด้านบน คือ ผลลัพธ์จากข้อมูลชุดฝึก และภาพชุดด้านล่าง เป็นผลลัพธ์จากข้อมูลชุดตรวจสอบ อ้างอิงกับการฝึกของโมเดลในแต่ละรอบ เรียงจากซ้ายไปขวา ค่า Loss ของตำแหน่งและขนาดสัญลักษณ์, ค่า Loss ของการตรวจสอบ Sensitivity ของวัตถุ, ค่า Loss ของการตรวจจับชนิดของสัญลักษณ์, อัตราส่วน Accuracy ของตำแหน่งสัญลักษณ์, อัตราส่วน Accuracy ในการตรวจจับชนิดของสัญลักษณ์

สัญลักษณ์ที่ใช้ในการตรวจสอบ มีทั้งหมด ๖ รูปแบบ ซึ่งมีจำนวนไม่เท่ากันในแต่ละรูปแบบ โดยขึ้นอยู่กับ จำนวนของก้อนเนื้อในภาพอัลตราซาวด์ โดยรูปแบบที่ ๑ และ ๒ จะมีจำนวนมากที่สุด สัญลักษณ์ตัวอย่างที่ใช้ ในการตรวจสอบ เป็นดังภาพด้านล่าง



รูปที่ ๖๙ ตัวอย่างรูปแบบสัญลักษณ์ที่ต้องการหาตำแหน่งทั้ง ๖ รูปแบบ



รูปที่ ๗: แผนภาพจำนวนรูปแบบสัญลักษณ์

(ซ้ายบน) แผนภาพแสดงความถี่ของตำแหน่งในการเกิดสัญลักษณ์ (ซ้ายล่าง) แผนภาพแสดงความถี่ของขนาดของสัญลักษณ์ (ขวาล่าง)

ผลการทดลองที่ ๓

หลังจากฝึกโมเดลเป็นจำนวน ๑๐๐๐ รอบ และนำมาตรวจสอบในชุดข้อมูลตรวจสอบ ได้ค่า Loss ดังนี้

- box_loss (ตำแหน่งและขนาดของสัญลักษณ์)=๐.๐๐๔๙๐๖
- cls_loss (การจำแนกชนิดของสัญลักษณ์)=๐.๐๐๐๒๒๐๑
- obj_loss (การตรวจสอบความถูกต้องของวัตถุ)=๐.๐๐๔๗๓๘

โดยค่า Accuracy ตำแหน่งและขนาดสัญลักษณ์มีค่าร้อยละ ๖๘.๘๔ ค่า Sensitivity ของสัญลักษณ์ร้อยละ ๙๓.๒๓ และค่า mAP@๐.๕ เป็นร้อยละ ๘๑.๖๘ และค่า mAP@๐.๕:๐.๙๕ เป็นร้อยละ ๖๓.๖๙ ผลการทดสอบของภาพโดยแยกตามสัญลักษณ์ เป็นดังตาราง

ตารางที่ ๗ ผลการทดลองจากภาพทดสอบจำนวน ๓๒ ภาพ โดยแยกตามชนิดสัญลักษณ์

ชนิดสัญลักษณ์	จำนวนสัญลักษณ์	Accuracy (ร้อยละ)	Sensitivity (ร้อยละ)	MAP@๐.๕ (ร้อยละ)	MAP@๐.๕:๐.๙๕ (ร้อยละ)
ทั้งหมด	๑๓๖	๖๘.๘๔	๙๓.๒๓	๘๑.๖๘	๖๓.๖๙
Marker1	๖๔	๘๗.๙	๑๐๐	๙๙.๗	๘๐.๒
Marker2	๖๔	๘๗.๗	๑๐๐	๙๘.๗	๗๙.๘
Marker3	๔	๕๗.๖	๑๐๐	๗๔.๕	๕๔.๖
Marker4	๔	๔๒.๑	๗๒.๙	๕๓.๗	๔๐.๒
Marker5	๐	N/A	N/A	N/A	N/A
Marker6	๐	N/A	N/A	N/A	N/A

๔.๑.๒ Thyroid nodule detection ด้วยอัลกอริทึม GAN

ผลการทดลองที่ ๑


การทดสอบคือแยกทดลองฝึกและตรวจสอบจาก Discriminator ที่มีจำนวนเลเยอร์ที่ต่างกัน โดยเรียกโมเดลเหล่านี้ว่า DeepLabV3+GAN จากนั้นจึงนำโมเดลเพียงแค่ส่วนที่เป็น Generator ซึ่งก็คือ DeepLabV3+ มาทดสอบกับภาพชุดทดลอง จึงทำให้ความเร็วในการตรวจสอบผลมีความเร็วเท่าเดิม คือ ๑๕ ภาพต่อวินาที โดยผลการทดสอบเป็นดังตารางที่ ๘

ตารางที่ ๘ แสดงผลการทดสอบ DeepLabV3+GAN

DeepLabV3+GAN	5 Layers	6 Layers	7 Layers	8 Layers
IoU	๗๘.๕๕	๗๘.๖๖	๗๙.๐๐	๗๙.๐๓
Accuracy	๙๔.๖๕	๙๔.๕๒	๙๔.๗๕	๙๖.๑๔
Sensitivity	๘๙.๓๕	๘๙.๔๘	๘๘.๗๕	๘๘.๕๑
Specification	๙๕.๒๑	๙๕.๓๕	๙๕.๖๑	๙๖.๕๓
Precision	๘๕.๕๕	๘๕.๕๕	๘๕.๖๓	๘๘.๕๐
Disc	๘๖.๒๐	๘๖.๒๓	๘๖.๑๖	๘๖.๕๓

ผลการทดลองที่ ๒

ในการลดความซับซ้อนของ Discriminator นั้น จะทำให้ความได้เปรียบจากการใช้โมเดล GAN ลดลง ซึ่งไม่ต้องการวิจัยสำหรับการทำให้เป็น Semi-Supervised นั้น ผู้วิจัยได้ใช้ไปแล้ว และยังไม่ช่วยลด Mode collapse ในกรณีเพิ่มความซับซ้อนของ Discriminator แต่ช่วยในการเพิ่มความเร็วการเรียนรู้ของ Generator ระดับหนึ่ง



รูปที่ ๗๑ ภาพค่า Loss ของตัว Generator เปรียบเทียบระหว่างการไม่ใส่ PID control

(ภาพบน) และ Loss ของ Generator ที่มีการใส่ PID control จะเห็นได้ว่าค่า Loss ของโมเดลที่ใส่ PID control ไม่สูงขึ้นชนิดที่แสดงสถานะของ Mode collapse เมื่อเทียบกับภาพบนที่เกิด Mode collapse

ตารางที่ ๙ แสดงผลการทดสอบ Model StableSeg GAN

StableSeg GAN	ร้อยละ ๑๐๐ Unsupervised	ร้อยละ ๙๐ Unsupervised	ร้อยละ ๕๐ Unsupervised	ร้อยละ ๑๐ Unsupervised
IoU	ไม่เกิดการเรียนรู้	๘๑.๙๗	๘๐.๐๓	๗๘.๓๒
Accuracy		๙๗.๑๔	๙๖.๖๔	๙๖.๐๕
Sensitivity		๙๑.๐๘	๘๙.๐๑	๘๘.๔๕
Specification		๙๗.๘๖	๙๗.๕๓	๙๗.๓๐
Precision		๘๘.๒๑	๘๗.๕๐	๘๘.๕๑
Disc		๘๘.๘๑	๘๗.๙๓	๘๖.๔๔

ผลการทดลองที่ ๓

ผลการทดลองโมเดลเปรียบเทียบในแต่ละชนิด สำหรับผลการทดลองโมเดลแต่ละชนิด ผู้วิจัยได้ทำการทดลองโมเดลต่างๆ ดังต่อไปนี้

- DeepLabV3+
- DeepLabV3+GAN (ย่อว่า DL+GAN)
- StableSeg GAN (8 layers) (ย่อว่า SSSGAN8L)
- StableSeg GAN (ResNet18) (ย่อว่า SSSGAN)

ซึ่งผลการทดลองเป็นดังตารางด้านล่าง

ตารางที่ ๑๐แสดงผลการทดลองโมเดลเปรียบเทียบใน ๔ ชนิด

โมเดล	IoU	Acc	Sen	Spec	Prec	Disc
DeepLabV3+	๗๘.๙๗	๙๖.๑๔	๘๙.๐๘	๙๗.๑๖	๘๗.๒๑	๘๖.๘๑
DL+GAN	๗๙.๐๓	๙๖.๑๔	๘๘.๕๑	๙๗.๕๓	๘๘.๕๐	๘๖.๙๓
SSSGAN8L	๘๐.๖๑	๙๖.๖๔	๙๐.๓๕	๙๗.๖+	๘๗.๙๓	๘๘.๔๔
SSSGAN	๘๑.๙๗	๙๗.๑๔	๙๑.๐๘	๙๗.๘๖	๘๘.๒๑	๘๘.๘๑

๔.๒ ผลความแม่นยำของโมเดลคัดแยกก้อนต่อมไทรอยด์ด้วยภาพอัลตราซาวด์

๔.๒.๑ Thyroid nodule detection ด้วยอัลกอริทึม Pre-train models

ผลการทดลองที่ ๑

โมเดลสำหรับแยกประเภทของก้อนเนื้อต่อมไทรอยด์ (Thyroid Classification Model) การทดลองเพื่อเปรียบเทียบความแตกต่างระหว่างข้อมูล Training แบบมี Marker และแบบ NoMarker

Model	f1-score	accuracy	Data
VGG16_BN	0.746	75.000	CroppedNoMarker
InceptionV3	0.741	77.083	CroppedNoMarker
ResNet50	0.682	70.833	CroppedNoMarker
DenseNet161	0.810	81.250	CroppedNoMarker
VGG16_BN	0.742	77.038	Cropped
InceptionV3	0.832	83.333	Cropped
ResNet50	0.892	89.583	Cropped
DenseNet161	0.874	87.500	Cropped

ตารางที่ ๑๑ แสดงโมเดลสำหรับแยกประเภทของก้อนเนื้อต่อมไทรอยด์

ผลการทดลองที่ ๒

การทดลองเพื่อเปรียบเทียบ Baseline model ที่เหมาะสมกับการใช้การทำนายด้วย SOTA Model เพื่อสร้าง baseline ของ classification performance

Model	f1-score	accuracy(%)	Data
VGG16_BN	0.742	77.038	Cropped
InceptionV3	0.832	83.333	Cropped
ResNet50	0.892	89.583	Cropped
DenseNet161	0.874	87.500	Cropped
DenseNet121	0.894	89.500	Cropped
VGG16_BN	0.746	75.000	CroppedNoMarker
InceptionV3	0.741	77.083	CroppedNoMarker
ResNet50	0.682	70.833	CroppedNoMarker
DenseNet161	0.810	81.250	CroppedNoMarker
DenseNet121	0.820	82.250	CroppedNoMarker

ตารางที่ ๑๒ แสดงการทำนายด้วย SOTA Model

๔.๑.๒ Thyroid nodule detection ด้วยอัลกอริทึม WSDAN

ผลการทดลองที่ ๑


กระบวนการเทรนจะแบ่งชุดข้อมูลออกเป็น

๑. การทดลองเพื่อใช้ระบบค้นหาบริเวณที่สนใจผ่านกระบวนการ Auto-cropping


การทดลองนี้แสดงการฝึกสอนโมเดลการทำนายแบบ Weakly-supervised ด้วย Image-level label เพียงอย่างเดียวเท่านั้น โดยเลือกเอาบางตัวอย่างที่น่าสนใจมาแสดงตามรูปต่อไปนี้โดยรูปจะประกอบไปด้วย

- รูปภาพตั้งต้น
- รูปภาพในบริเวณที่มีโมเดลให้ความสนใจ
- รูปภาพที่โมเดลทำการตัดเพื่อขยาย

Malignant กรณีที่มี Marker



Malignant กรณีที่ไม่มี Marker



(ก.)


(ข.)

(ค.)


รูปที่ ๓๒ ตัวอย่างแสดงผลการทำนายของโมเดล

(ก) รูปต้นแบบ (ข) บริเวณที่โมเดลให้ความสนใจ (สีน้ำเงินคราม) (ค) บริเวณที่โมเดลให้ความสนใจสูงสุด

Benign กรณีที่มี Marker



Benign กรณีที่ไม่มี Marker



รูปที่ ๗๓ ตัวอย่างแสดงผลการทำนายของโมเดล


(ก) รูปต้นแบบ (ข) บริเวณที่โมเดลให้ความสนใจ (สีน้ำเงินคราม) (ค) บริเวณที่โมเดลให้ความสนใจสูงสุด

๒. การทดลองเพื่อใช้ระบบจำแนก Benign/Malignant แบบ Auto-cropping

Acc




Crop-Drop
tag: Acc/Crop-Drop



(ข)

Loss



(ค)

รูปที่ ๗๔ กราฟแสดงการพัฒนาโมเดลระหว่าง training และ validating

(ก.) ความถูกต้องแม่นยำในการจำแนกก้อนเนื้อ (ข.) ความถูกต้องแม่นยำในการระบุพื้นที่
ผิดปกติ (ค.) ความผิดพลาดในการจำแนกก้อนเนื้อ

ผลการทดลองแสดงได้ดังตารางดังนี้

ตารางที่ ๑๓ กรณีที่ไม่ได้เป็นก้อนต่อมไทรอยด์ชนิดดี (Benign)


Case 1	[0.855 0.145]	pred:Benign	true:Benign
Case 2	[0.834 0.166]	pred:Benign	true:Benign
Case 3	[0.754 0.246]	pred:Benign	true:Benign
Case 4	[0.715 0.285]	pred:Benign	true:Benign

Case 5	[0.420 0.580]	pred:Malign	true:Benign	
Case 6	[0.656 0.344]	pred:Benign	true:Benign	
Case 7	[0.467 0.533]	pred:Malign	true:Benign	*
Case 8	[0.871 0.129]	pred:Benign	true:Benign	
Case 9	[0.400 0.600]	pred:Malign	true:Benign	

ตารางที่ ๑๔ กรณีที่เป็นก้อนต่อมไทรอยด์ชนิดร้าย (Malignant)

Case 77	[0.277 0.723]	pred:Malign	true:Malign	
Case 78	[0.231 0.769]	pred:Malign	true:Malign	
Case 79	[0.468 0.532]	pred:Malign	true:Malign	*
Case 80	[0.268 0.732]	pred:Malign	true:Malign	
Case 81	[0.200 0.800]	pred:Malign	true:Malign	
Case 82	[0.468 0.532]	pred:Malign	true:Malign	*
Case 83	[0.318 0.682]	pred:Malign	true:Malign	
Case 84	[0.232 0.768]	pred:Malign	true:Malign	
Case 85	[0.164 0.836]	pred:Malign	true:Malign	
Case 86	[0.146 0.854]	pred:Malign	true:Malign	
Case 87	[0.460 0.540]	pred:Malign	true:Malign	*


๓. การทดลองเพื่อใช้ระบบจำแนก Benign/Malignant แบบ Guided-cropping โดยการใช้ Mask Builder รวมกับข้อมูลที่ได้จากจุด Mark Point



Crop-Drop
tag: Acc/Crop-Drop



Loss



รูปที่ ๗๕ กราฟแสดงการพัฒนาโมเดลระหว่าง training และ validating

(ก.) ความถูกต้องแม่นยำในการจำแนกก้อนเนื้อ (ข.) ความถูกต้องแม่นยำในการระบุพื้นที่ผิดปกติ (ค.) ความผิดพลาดในการจำแนกก้อนเนื้อ

ผลการทดลองแสดงได้ดังตารางดังนี้

กรณีที่ไม่ได้เป็นก้อนเนื้อร้าย (Benign)

Case 1	[0.097 0.903]	pred:Malign	true:Benign
Case 2	[0.997 0.003]	pred:Benign	true:Benign
Case 3	[0.988 0.012]	pred:Benign	true:Benign
Case 4	[0.155 0.845]	pred:Malign	true:Malign
Case 5	[0.999 0.001]	pred:Benign	true:Benign
Case 6	[0.651 0.349]	pred:Benign	true:Malign
Case 7	[0.042 0.958]	pred:Malign	true:Malign
Case 8	[1.000 0.000]	pred:Benign	true:Benign
Case 9	[0.740 0.260]	pred:Benign	true:Malign

กรณีที่เป็นก้อนเนื้อร้าย (Malignant)

Case 77	[0.995 0.005]	pred:Benign	true:Benign	
Case 78	[1.000 0.000]	pred:Benign	true:Benign	
Case 79	[0.999 0.001]	pred:Benign	true:Benign	
Case 80	[1.000 0.000]	pred:Benign	true:Benign	
Case 81	[0.506 0.494]	pred:Benign	true:Malign	*
Case 82	[0.991 0.009]	pred:Benign	true:Benign	
Case 83	[1.000 0.000]	pred:Benign	true:Benign	
Case 84	[0.128 0.872]	pred:Malign	true:Malign	
Case 85	[0.136 0.864]	pred:Malign	true:Benign	
Case 86	[1.000 0.000]	pred:Benign	true:Benign	
Case 87	[0.110 0.890]	pred:Malign	true:Malign	

*แสดงถึงกรณีที่โมเดลยังไม่สามารถจำแนกได้อย่างชัดเจน

- การวัดความแม่นยำเปรียบเทียบกับกรณีที่มีจุด mask เพื่อกำหนดบริเวณที่เป็นจุดสนใจเปรียบเทียบกับกรณีที่ใช้การสุมเพื่อค้นหาจุดสนใจ

ผลการทดลองที่ ๒

สำหรับข้อมูลที่ได้นำมาฝึกสอนโมเดลในครั้งนี้มีจำนวนทั้งหมด ๑,๑๔๗ รูปภาพโดยเป็นชุดข้อมูลเดียวกับที่ใช้ในการสร้างหน้ากาสำหรับตรวจจับก้อนเนื้อ โดยที่ทุกภาพจะมีคู่ Mask แบบ ๑-๑ เสมอ

กระบวนการฝึกสอน


สำหรับกระบวนการฝึกสอนจะใช้กับ train ด้วย hyperparamater และ Data Augmentation scheme แบบเดียวกับที่ใช้ในรายงานครั้งก่อน โดยประกอบไปด้วยกระบวนการสลับภาพในแนวนอน, การหมุนภาพ, การปรับมุมมอง, การซูมและการตัด โดยทั้งหมดเป็นกระบวนการแบบสุ่ม และเพื่อให้สามารถทำการทดลองซ้ำได้ ทีมวิจัยจึงกำหนด random seed คงที่ไว้ที่ ๒๕๖๕ ในการฝึกสอนจะทำการฝึกโมเดลด้วยขนาด Batch Size ๑๖ และทำการฝึกที่ ๘๐ รอบ


ผลลัพธ์ สำหรับผลลัพธ์ที่ได้สำหรับการเปรียบเทียบแนวทางการใช้ mask แสดงได้ดังตารางด้านล่างนี้


ตารางที่ ๑๕ ผลความแม่นยำ

แนวทางที่ 1	ความแม่นยำ: 73.58%
แนวทางที่ 2	ความแม่นยำ: 62.26%
แนวทางที่ 3	ความแม่นยำ: 64.15%

ผลลัพธ์ในรูปแบบของตาราง Confusion Matrix








๔.๖ การติดตั้งและใช้งานระบบจริง

๔.๖.๑ การพัฒนาระบบประเมินก้อนต่อมไทรอยด์ด้วยภาพอัลตราซาวด์ผ่านแพลตฟอร์มเว็บ

การประเมินโอกาสที่ก้อนเนื้อต่อมไทรอยด์จะเป็นก้อนเนื้อมะเร็งด้วยภาพอัลตราซาวด์ (Thyroid cancer prediction via web interface) ผู้ใช้สามารถอัปโหลดรูปภาพดังที่ได้อธิบายไว้ผ่านระบบแพลตฟอร์มเว็บไซต์เพื่อให้ระบบสามารถประมวลผลออนไลน์ได้แสดงดังรูปที่ ๗๖



รูปที่ ๗๖ ตัวอย่างการประเมินก้อนเนื้อต่อมไทรอยด์ชนิดร้ายผ่านแพลตฟอร์มเว็บไซต์

๔.๗ วิจัยผลลัพธ์

๔.๗.๑ Thyroid nodule detection ด้วยอัลกอริทึม Pre-train models

จากตารางที่ ๘ จะเห็นได้ชัดเลยว่าโมเดลที่ถูกเทรนด้วยข้อมูลที่มี Marker มีความแม่นยำสูงกว่าแบบ NoMarker โดยเฉลี่ย จากตารางที่ ๙ จากผลการทดลองโดยการหาค่าเฉลี่ย f1-score และ accuracy จะเห็นได้ว่า ResNet50 และ DenseNet121 จะได้ผลลัพธ์ที่อยู่ในกลุ่มแม่นยำสูงสุด แต่เมื่อเปรียบเทียบขนาดของโมเดลที่ทีมงานเลือกที่จะใช้ DenseNet121 เป็น Base model จะสังเกตได้ว่า DenseNet 121 ให้ผลเบื้องต้นที่มีความแม่นยำสูงกว่า DenseNet161 ที่มีจำนวนพารามิเตอร์สูงกว่า โดยทีมวิจัยได้ตั้งสมมติฐานว่าโมเดล DenseNet161 เกิดภาวะ Overfitting ขึ้นเนื่องจากโมเดลมีขนาดใหญ่เมื่อเทียบสัดส่วนกับปริมาณข้อมูลที่ใช้ในการฝึกสอน

๔.๗.๒ Thyroid nodule detection ด้วยอัลกอริทึม GAN

การทดลองที่ ๑

จากตารางที่ ๘ ทำให้ทราบว่ายิ่งมีจำนวนเลเยอร์สูงยิ่งขึ้น จะทำให้มีความแม่นยำมากขึ้น ดังนั้น ผู้ทดลองจึงลองขยายเลเยอร์เพิ่มเป็น ๙ เลเยอร์ แต่พบว่าโมเดลไม่ได้เรียนรู้ได้มากขึ้นไปกว่าเดิม ไม่เพียงเท่านั้น ค่าความแม่นยำยังลดลงอีกด้วย ซึ่งผู้ทดลองได้ตรวจสอบค่า Loss จาก Discriminator แล้วพบว่า ค่า Loss สูงขึ้นเรื่อยๆ ซึ่งทำให้ Generator ไม่สามารถเรียนรู้ว่าผิดพลาดที่ตรงไหน เหตุการณ์นี้เกิดขึ้นบ่อยครั้ง ในการฝึกให้กับโมเดล GAN ซึ่งจะเกิดเมื่อ Discriminator เก่งเกินไปหรือเรียนรู้เร็วกว่า Generator มากเกินไป

การทดลองที่ ๒

จากตารางที่ ๙ ทำให้ทราบว่า การใช้ GAN ในโครงสร้างโมเดลที่มีอัตราส่วนการเรียนรู้จาก Discriminator มากขึ้น ทำให้ความสามารถของโมเดลมีความความแม่นยำสูงขึ้น แต่ถ้าไม่มีการใช้ Supervised Loss เลย จะทำให้โมเดลไม่สามารถเรียนรู้ได้ ดังนั้น จึงควรมี Supervised Loss ในอัตราส่วนหนึ่ง

การทดลองที่ ๓

จากผลการทดลองในตารางที่ ๑๐ พบว่า StableSeg GAN ที่ใช้ ResNet18 เป็น Discriminator ได้ผลลัพธ์ที่สูงกว่า DeepLabV3+ ถึงร้อยละ ๓ ซึ่งทำให้สามารถสรุปได้ว่า ถ้าใช้ GAN ที่มี Discriminator ที่มีความซับซ้อนสูงจะทำให้ดึงศักยภาพของตัวโมเดลได้สูงขึ้นกว่าเดิม โดยต้องมีการสร้างตัวแปรควบคุมสมดุลการเรียนรู้ระหว่าง Generator และ Discriminator ซึ่งในครั้งนี้นำ PID control มาปรับสมดุลการเรียนรู้ดังกล่าว

๔.๗.๒ Thyroid nodule classification ด้วยอัลกอริทึม WSDAN

จากการผลการทดลองโมเดลมีความสามารถจำแนกได้ที่ระดับ ๘๒% โดยการใช้แนวทางแบบ Weakly-Supervised ช่วยเพิ่มความสามารถในการจำแนกภาพของโมเดล รวมไปถึงสามารถที่จะกำหนดบริเวณที่ contribute ให้กับการทำนายได้อีกด้วย นอกจากนี้แนวทางพัฒนาแบบ Weakly-Supervised นั้นยังช่วยสามารถ trace-back เพื่อค้นหาบริเวณที่ทำให้โมเดลตัดสินใจทำนายได้อีกด้วย อนึ่ง ข้อสังเกตในการฝึกสอนโมเดลนั้น ยังมีประเด็นต้องสงสัยในเรื่องของการที่โมเดลมีการรู้จำรูปแบบเฉพาะตัวของ Markers ที่แสดงผลบนภาพหรือไม่ สำหรับในข้อนี้สามารถที่จะแก้ไขได้โดยการเพิ่มจำนวน Data ให้ตกลงไปอยู่ในทั้งสองคลาสอย่างสมดุลและทดลองเปรียบเทียบความสามารถในการจำแนกทั้งสองแบบ

๔.๗.๔ ประสิทธิภาพในการรองรับภาระงาน

จากการทดสอบใช้งานจริงที่มิววิจัยพบว่าระบบแพลตฟอร์มเว็บไซต์ประเมินก้อนต่อมไทรอยด์ด้วยภาพอัลตราซาวด์แสดงให้เห็นถึงความสามารถในการรับ request เมื่อมีการส่ง request พร้อม ๆ กัน แต่เพื่อเตรียมพื้นที่ไว้รองรับการใช้บริการแบบหลายๆศูนย์การแพทย์จำเป็นต้องเพิ่มประสิทธิภาพในการประมวลเพื่อป้องกันการเกิดคอขวดเมื่อมีการ request พร้อมกันจากหลายแหล่ง ดังนั้นในการใช้งานจริงอาจต้องพิจารณาหน่วยประมวลผลกราฟิกที่มีประสิทธิภาพมากขึ้น เพื่อให้รองรับการใช้งานในกรณีที่มีการสัญจรของคนในปริมาณหนาแน่น

๔.๘ สรุปผลความแม่นยำของระบบ


สรุปผลความแม่นยำของระบบเมื่อเทียบกับเป้าหมายที่กำหนดไว้มีรายละเอียดดังแสดงในตารางที่ ๕๓

ตารางที่ ๑๖: ความแม่นยำของระบบเมื่อเทียบกับเป้าหมาย

ระบบ	เป้าหมาย	ความแม่นยำที่ได้
ตรวจจับก้อนต่อมไทรอยด์	ความแม่นยำ ๗๕%	๐.๗๙ (IoU = ๐.๖๕)
แยกประเภทก้อนต่อมไทรอยด์	ความแม่นยำ ๗๕%	๐.๘๗ (F1-Score)

๔.๙ การอบรมให้กับนักวิจัยและรังสีแพทย์เพื่อนำระบบไปใช้งานจริง

ทีมวิจัยได้ฝึกอบรมให้กับผู้เกี่ยวข้องทั้งของสถาบันเทคโนโลยีแห่งเอเชีย มหาวิทยาลัยรามคำแหง และนักรังสีแพทย์หรือนักวิจัยที่สนใจ ดังแสดงในรูปที่ ๗๗ โดยแบบการประเมินและคู่มือการใช้งานระบบแสดงรายละเอียดเพิ่มเติมใน ภาคผนวก ก



รูปที่ ๗๗ : การฝึกอบรมการใช้งานระบบแพลตฟอร์มเว็บไซต์ประเมินก้อนต่อมไทรอยด์ด้วยภาพอัลตราซาวด์

๔.๑๐ ผลงานตีพิมพ์ในการประชุมทางวิชาการระดับนานาชาติ

ตารางการตีพิมพ์และรายละเอียดเพิ่มเติมแสดงในภาคผนวก ข

บทที่ ๕

สรุปผลการวิจัย และข้อเสนอแนะ

๕.๑ สรุปผลการวิจัย

ในการดำเนินโครงการวิจัยนี้ทีมวิจัยได้พัฒนาแพลตฟอร์มคัดกรองมะเร็งต่อมไทรอยด์ด้วยภาพอัลตราซาวด์ ซึ่งเป็นระบบช่วยวินิจฉัย (Computer-aided Diagnosis) ที่เน้นความแม่นยำและการใช้งานที่เข้าถึงได้ง่าย เพื่อตอบสนองความต้องการในการประเมินก้อนต่อมไทรอยด์ซึ่งพบได้บ่อยในผู้สูงอายุและผู้หญิง ระบบนี้พัฒนาขึ้นโดยใช้โมเดลการเรียนรู้เชิงลึก เช่น YOLO สำหรับตรวจหาก้อนต่อมไทรอยด์ และ WSDAN (Weakly Supervised Data Augmentation Networks) เพื่อจำแนกก้อนต่อมไทรอยด์เป็นชนิดดี (Benign) และชนิดร้าย (Malignant)

การพัฒนาโมเดล WSDAN ได้รวม Attention Mechanism และ Curriculum Learning เพื่อปรับปรุงประสิทธิภาพในการเรียนรู้ โดยใช้ภาพอัลตราซาวด์และ Doppler ในการสร้างข้อมูลเสริม (Data Augmentation) ให้เหมาะสม ผลการทดลองแสดงให้เห็นว่าโมเดล WSDAN มีค่าความแม่นยำ (Precision) ๙๑% สำหรับก้อนชนิดดีและ ๘๕% สำหรับก้อนชนิดร้าย พร้อมคะแนน F1-score ๘๗% และ ๘๘% ตามลำดับ และความถูกต้องโดยรวม (Overall Accuracy) ๘๘%

แพลตฟอร์มดังกล่าวถูกออกแบบให้ทำงานบนเว็บแอปพลิเคชัน เพื่อสนับสนุนการวินิจฉัยที่รวดเร็วและขยายการใช้งานได้กว้างขวาง ระบบนี้ช่วยลดภาระงานของแพทย์ พร้อมทั้งเพิ่มประสิทธิภาพในการตรวจหามะเร็งต่อมไทรอยด์ในระยะเริ่มต้น โดยการพัฒนาแบบเสร็จสิ้นตามเป้าหมายของโครงการและนำไปทดลองใช้งานได้สำเร็จ ในการดำเนินโครงการวิจัยนี้ทีมวิจัยได้วิจัยและพัฒนาแพลตฟอร์มประเมินก้อนต่อมไทรอยด์ด้วยภาพอัลตราซาวด์เสร็จสิ้นและนำระบบแพลตฟอร์มดังกล่าวไปติดตั้งและใช้งานได้บรรลุตามวัตถุประสงค์ของโครงการ

๕.๒ ข้อเสนอแนะเชิงนโยบายต่อ กสทช. และหน่วยงานภาครัฐและเอกชนที่เกี่ยวข้อง

การดำเนินงานเพื่อเพิ่มทรัพยากรสำหรับจัดเก็บและประมวลผลข้อมูลเป็นปัจจัยสำคัญในการขยายขีดความสามารถของระบบให้รองรับการใช้งานในหลายศูนย์การแพทย์ที่มีข้อมูลที่หลากหลาย การจัดเก็บและประมวลผลข้อมูลที่มีปริมาณมากจำเป็นต้องพิจารณาโครงสร้างพื้นฐาน เช่น การเพิ่มพื้นที่จัดเก็บข้อมูลแบบกระจาย (Distributed Storage) และการใช้บริการประมวลผลแบบคลาวด์ (Cloud Computing) เพื่อช่วยรองรับการประมวลผลข้อมูลขนาดใหญ่และลดภาระการจัดการทรัพยากรในศูนย์การแพทย์แต่ละแห่ง นอกจากนี้ การเพิ่มประสิทธิภาพของระบบให้สามารถรองรับการทำงานร่วมกับศูนย์การแพทย์หลายแห่งที่มีชุดข้อมูลและลักษณะข้อมูลที่แตกต่างกันเป็นความท้าทายอย่างยิ่ง การประยุกต์ใช้เทคนิค Federated Learning หรือการเรียนรู้แบบกระจายตัว (Distributed Learning) อาจเป็นทางเลือกหนึ่งในการช่วยให้โมเดลสามารถเรียนรู้ข้อมูลจากหลายศูนย์การแพทย์โดยไม่ต้องย้ายข้อมูลออกจากแต่ละศูนย์ ซึ่งจะช่วยลดความเสี่ยงในการละเมิดความเป็นส่วนตัวของข้อมูลและเพิ่มความปลอดภัยในกระบวนการเรียนรู้ จากผลการทดลองพบว่าความสามารถในการทำนายของโมเดลลดลงอย่างมีนัยสำคัญเมื่อใช้งานกับข้อมูลจากศูนย์การแพทย์ต่าง ๆ ที่มีความหลากหลายในรูปแบบภาพและคุณภาพข้อมูล เพื่อแก้ปัญหานี้ ทีมวิจัยอาจพิจารณาพัฒนาโมเดลที่สามารถปรับตัวให้เข้ากับข้อมูลของแต่ละศูนย์ได้ เช่น การใช้ Domain Adaptation หรือ Domain Generalization เพื่อเพิ่มความยืดหยุ่นและลดผลกระทบจากความแตกต่างของข้อมูลระหว่างศูนย์ ในส่วนของการทำนายลักษณะของก้อนต่อมไทรอยด์ มาตรฐาน TI-RADS (Thyroid Imaging Reporting and Data System) ได้รับการพิสูจน์ว่าเหมาะสมกับการตอบสนองการใช้งานของแพทย์มากกว่าการแบ่งประเภทก้อนออกเป็นชนิดดีหรือชนิดร้ายเท่านั้น การใช้ TI-RADS ช่วยเพิ่มความละเอียดในการวินิจฉัย โดยแบ่งระดับความเสี่ยงของก้อนออกเป็นหลายระดับ ซึ่งทำให้แพทย์สามารถประเมินและตัดสินใจเกี่ยวกับการรักษาได้อย่างเหมาะสม ดังนั้น ทีมวิจัยอาจพิจารณาปรับปรุงระบบให้รองรับการทำนายตามมาตรฐาน TI-RADS โดยใช้โมเดลที่สามารถระบุระดับความเสี่ยงในแต่ละระดับได้อย่างแม่นยำ การพัฒนาโมเดลที่ให้ผลลัพธ์ในลักษณะนี้อาจช่วยเพิ่มความมั่นใจในผลการวินิจฉัยของแพทย์ รวมถึงช่วยสนับสนุนการตัดสินใจเกี่ยวกับการดูแลและรักษาผู้ป่วยต่อมไทรอยด์ได้อย่างมีประสิทธิภาพ

๕.๓ สรุปผลการดำเนินโครงการพัฒนาองค์ความรู้สื่อมวลชนด้านกิจการกระจายเสียงและกิจการโทรทัศน์

ระบบคอมพิวเตอร์ช่วยวินิจฉัย (Computer-Aided Diagnosis หรือ CAD) เป็นเทคโนโลยีที่มีผลกระทบเชิงบวกอย่างมากต่อสังคม โดยเฉพาะในด้านการแพทย์และสุขภาพของประชาชน ระบบนี้ช่วยให้การวินิจฉัยโรคมีความแม่นยำและรวดเร็วมากยิ่งขึ้น โดยใช้เทคนิคปัญญาประดิษฐ์ หนึ่งในข้อดีสำคัญของระบบคอมพิวเตอร์ช่วยวินิจฉัยคือความสามารถในการตรวจจับโรคในระยะเริ่มต้น ซึ่งช่วยเพิ่มโอกาสในการรักษาและลดอัตราการเสียชีวิต ตัวอย่างเช่น การตรวจจับมะเร็งเต้านมหรือมะเร็งต่อมไทรอยด์จากภาพถ่ายทางการแพทย์ด้วยระบบ CAD สามารถเพิ่มความแม่นยำในการระบุชนิดของเนื้องอก และลดความผิดพลาดที่อาจเกิดจากการวินิจฉัยด้วยสายตามนุษย์ นอกจากนี้ ระบบยังช่วยลดระยะเวลาในการตรวจและวินิจฉัย ทำให้ผู้ป่วยได้รับการดูแลที่รวดเร็วขึ้น ระบบคอมพิวเตอร์ช่วยวินิจฉัยยังช่วยลดภาระงานของแพทย์ โดยการคัดกรองข้อมูลเบื้องต้นและแจ้งเตือนความผิดปกติในข้อมูลที่อาจตรวจไม่พบด้วยสายตา อีกทั้งยังสามารถช่วยในการตรวจสอบซ้ำเพื่อยืนยันผลวินิจฉัย ซึ่งมีความสำคัญอย่างยิ่งในกรณีที่ต้องการความแม่นยำสูง เช่น การตรวจวินิจฉัยโรคทางสมองหรือโรคหัวใจ นอกจากนี้ เทคโนโลยี CAD ยังช่วยเพิ่มการเข้าถึงการดูแลสุขภาพในพื้นที่ห่างไกล ซึ่งอาจขาดแคลนแพทย์ผู้เชี่ยวชาญ ระบบสามารถทำงานผ่านแพลตฟอร์มออนไลน์ ช่วยให้แพทย์ในพื้นที่ได้รับข้อมูลสำคัญในการวินิจฉัย หรือส่งข้อมูลไปยังผู้เชี่ยวชาญในเมืองใหญ่เพื่อขอคำแนะนำเพิ่มเติม ในเชิงสังคม ระบบคอมพิวเตอร์ช่วยวินิจฉัยยังช่วยลดค่าใช้จ่ายทางการแพทย์ในระยะยาว โดยการลดความจำเป็นในการตรวจเพิ่มเติมหรือการรักษาที่ไม่จำเป็น ซึ่งเป็นผลจากการวินิจฉัยที่แม่นยำมากขึ้น และยังช่วยเพิ่มความมั่นใจให้กับผู้ป่วย เนื่องจากผลวินิจฉัยมักได้รับการสนับสนุนด้วยข้อมูลเชิงลึกที่ผ่านการประมวลผลจาก AI โดยรวมแล้ว ระบบคอมพิวเตอร์ช่วยวินิจฉัยไม่เพียงแต่เพิ่มประสิทธิภาพและความแม่นยำในการวินิจฉัยโรค แต่ยังช่วยเสริมสร้างคุณภาพชีวิตของประชาชน เพิ่มโอกาสในการเข้าถึงบริการสุขภาพ และลดภาระของระบบสาธารณสุขในภาพรวม

๕.๔ รายงานผลการดำเนินงานการใช้ประโยชน์จากการใช้งานจริง

ทีมวิจัยได้นำระบบประเมินก่อนต่อมไทรอยด์ด้วยภาพอัลตราซาวด์ผ่านแพลตฟอร์มเว็บไซต์ไปใช้งานจริงโดยรังสีแพทย์ จำนวน 8 คน เพื่อประเมินประสิทธิภาพและความเหมาะสมของระบบในบริบทการใช้งานจริง การประเมินนี้ครอบคลุมในด้านต่าง ๆ ได้แก่ ความแม่นยำของการทำนาย (Prediction Accuracy) การใช้งานของเว็บไซต์ (Web Experience) และความสะดวกในการใช้งานโดยรวม (Ease of Use) ผลรวมของการประเมินจากทั้งสามด้านอยู่ที่ ๘๐% ซึ่งถือว่าอยู่ในระดับที่ดีสำหรับการนำระบบไปใช้งานในระยะแรก ผู้ใช้งานแสดงความพึงพอใจในด้านความแม่นยำของโมเดลและความง่ายในการใช้งานเป็นพิเศษ แต่ยังคงมีข้อเสนอแนะในเรื่องของประสบการณ์การใช้

งานเว็บไซต์ เช่น การปรับปรุงความเร็วในการประมวลผล และการเพิ่มฟีเจอร์การใช้งานเพิ่มเติม ทีมวิจัยจะนำข้อมูลจากการประเมินนี้ไปปรับปรุงระบบให้เหมาะสมยิ่งขึ้นในระยะถัดไป

ด้านความแม่นยำของการทำนาย (Model Prediction Accuracy) ผู้ใช้งานประเมินผลลัพธ์ของโมเดลที่ใช้วิเคราะห์ภาพอัลตราซาวด์ในการตรวจจับและจำแนกชนิดของก้อนต่อมไทรอยด์ โดยเฉพาะการแยกความแตกต่างระหว่างก้อนชนิดดี (Benign) และชนิดร้าย (Malignant) โดยรวมแล้วผู้ใช้งานพึงพอใจในประสิทธิภาพของโมเดลในระดับดี อย่างไรก็ตาม มีข้อเสนอแนะให้ปรับปรุงโมเดลให้สามารถรองรับการจำแนกที่หลากหลายมากขึ้น เช่น การวิเคราะห์ตามเกณฑ์ TI-RADS เพื่อเพิ่มความเหมาะสมในการใช้งานกับผู้ป่วยแต่ละราย

ด้านประสบการณ์การใช้งานเว็บไซต์ (Web Experience) ผู้ใช้งานรายงานว่าระบบมีส่วนติดต่อผู้ใช้งานที่ชัดเจนและเข้าใจง่าย โดยเฉพาะการแสดงผลภาพอัลตราซาวด์พร้อมคำทำนายจากโมเดล และการจัดเรียงข้อมูลในรูปแบบที่ช่วยสนับสนุนการวินิจฉัย เช่น การแสดงค่าเปอร์เซ็นต์ความผิดปกติ (Percentage of abnormality) อย่างไรก็ตาม มีผู้ใช้งานบางรายให้ข้อเสนอแนะเกี่ยวกับความเร็วในการประมวลผล โดยเฉพาะในกรณีที่ต้องอัปโหลดไฟล์ขนาดใหญ่ ซึ่งอาจส่งผลกระทบต่อความสับสนในการใช้งานในกรณีที่อินเทอร์เน็ตมีความเร็วต่ำ

ด้านความสะดวกในการใช้งาน (Ease of Use) ผู้ใช้งานส่วนใหญ่ให้ความเห็นว่าระบบใช้งานง่าย แม้กระทั่งผู้ที่มีประสบการณ์ใช้งานระบบคอมพิวเตอร์น้อย การออกแบบที่คำนึงถึงผู้ใช้ (User-Centered Design) เช่น การจัดหมวดหมู่เมนูอย่างชัดเจน และการให้คำแนะนำในทุกขั้นตอนผ่านข้อความช่วยเหลือ ทำให้ลดข้อผิดพลาดในการใช้งาน อย่างไรก็ตาม มีข้อเสนอแนะให้เพิ่มฟีเจอร์ในการแปลผลการวิเคราะห์เป็นรายงานที่สามารถดาวน์โหลดได้โดยตรง เพื่อช่วยลดขั้นตอนการทำงานของผู้ใช้งาน

๕.๕ รายงานสรุปผลในส่วนเป้าหมายที่อาจจะไม่สามารถบรรลุตามแผนงานที่วางไว้

ทีมวิจัยได้ดำเนินการวิจัยและพัฒนาบรรลุตามแผนงานที่วางไว้ทั้งหมด ดังแสดงในตารางที่ ๑๗

ตารางที่ ๑๗: สถานะการดำเนินการกิจกรรมที่สำคัญ

ลำดับ	กิจกรรมที่สำคัญ	สถานะ การดำเนินการ	รายละเอียดการดำเนินการ
๑	แพลตฟอร์มระบบคอมพิวเตอร์ช่วยวินิจฉัยด้วยแบบจำลองการเรียนรู้เชิงลึกเพื่อใช้ในการตรวจจับและจำแนกชนิดของก้อนต่อมไทรอยด์ชนิดดีและร้ายด้วยภาพอัลตราซาวด์ร่วมกับภาพ Doppler ที่สามารถใช้ประเมินผลผ่าน (Web-based platform)	เสร็จสิ้น	ทีมวิจัยได้ออกแบบและพัฒนาระบบดึงข้อมูลอัตลักษณ์ก้อนต่อมไทรอยด์เสร็จสิ้น ซึ่งมีรายละเอียดดังต่อไปนี้ - โมเดลตรวจจำก้อนต่อมไทรอยด์ - โมเดลจำแนกก้อนประเภทต่อมไทรอยด์ - แพลตฟอร์มระบบคอมพิวเตอร์ช่วยวินิจฉัย - Servers ได้แก่ web application (interface และ database), computational server และ storage server
๒	บทความทางวิชาการในวารสารระดับนานาชาติ (บรรจุในฐานข้อมูล Scopus)	เสร็จสิ้น	รายละเอียดแสดงในภาคผนวก ข
๓	โปรแกรมสำหรับประมวลผลภาพอัลตราซาวด์เบื้องต้น	เสร็จสิ้น	- โปรแกรมตัดข้อมูลส่วนบุคคล - โปรแกรมสร้าง Doppler mask

๕.๖ รายงานผลการดำเนินการฉบย่อสำหรับลงตีพิมพ์ในวารสารสำนักงาน กสทช.

รายงานผลการดำเนินการฉบย่อสำหรับลงตีพิมพ์ในวารสารสำนักงาน กสทช. ได้แนบไว้เอกสาร
ภาคผนวก ค

บรรณานุกรม

เบญจวรรณ สำราญ วานิช. (๒๐๑๙). ภาวะ แทรกซ้อน หลัง การ ผ่าตัด รักษา มะเร็ง ต่อ ม ไทรอยด์ ชนิด well-differentiated ใน กลุ่ม งาน โสต ศ อ นาสิก โรง พยาบาล มหาราช นครราชสีมา. Thai cancer journal-วารสาร โรค มะเร็ง, ๓๙(๓), ๙๓-๑๐๒.

สมจินต์ จินดาวิจักขณ์, วิษณุ ปานจันทร์, อาคม ชัยวีระวัฒน์ และ วีรวุฒิ อิ่มสำราญ. (๒๐๑๕). แนวทางการตรวจวินิจฉัยและรักษาโรคมะเร็งต่อมไทรอยด์ สถาบันมะเร็งแห่งชาติ กรมการแพทย์ กระทรวงสาธารณสุข, ISBN: ๙๗๘-๙๗๔-๔๒๒-๗๘๙-๘.

Arunrukthavon, P., Songsaeng, D., Keatmanee, C., Klabwong, S., Ekpanyapong, M., & Dailey, M. N. (๒๐๒๑). Diagnostic Performance of Artificial Intelligence for Interpreting Thyroid Cancer in Ultrasound images. International Journal of Knowledge and Systems Science (IJKSS), ๑๓(๑), ๑-๑๓.

Bengio, Y., Louradour, J., Collobert, R., Weston, J. (๒๐๑๙). Curriculum learning. In Proceedings of the ๒๖th annual international conference on machine learning, pp. ๔๑-๔๘.

Brown, P. et al. (๒๐๒๑). "AI-powered thyroid nodule analysis: Benefits of scalability and real-time diagnostics." Clinical Endocrinology Reviews, ๓๖(๔), ๒๑๕-๒๒๘.

Buda, M., Maki, A., Mazurowski, M. A. (๒๐๑๘). A systematic study of the class imbalance problem in convolutional neural networks. Neural Networks, ๑๐๖, ๑๗๑-๑๘๑.

Chawla, N. V., Japkowicz, N., Kolcz, A. (๒๐๐๔). Editorial: Special issue on learning from imbalanced data sets. ACM SIGKDD Explorations Newsletter, ๖(๑), ๑-๖.

Chammas, M. C., Gerhard, R., Oliveira, I. R. S. D., Widman, A., Barros, N. D., Durazzo, M., ... & Cerri, G. G. (๒๐๐๕). Thyroid nodules: evaluation with power Doppler and duplex Doppler ultrasound. Otolaryngology—Head and Neck Surgery, ๑๓๒(๖), ๘๗๔-๘๘๒.

Chen, L., Wu, Z., & Qian, Y. (๒๐๒๒). Ensemble learning for thyroid ultrasound image analysis. Computers in Biology and Medicine, ๑๔๔, ๑๐๕๓๔๑.

Choi, Y. J., Baek, J. H., Park, H. S., Shim, W. H., Kim, T. Y., Shong, Y. K., & Lee, J. H. (2017). A computer-aided diagnosis system using artificial intelligence for the diagnosis and characterization of thyroid nodules on ultrasound: initial clinical assessment. *Thyroid*, 27(4), 446-452.

Chi, J., Walia, E., Babyn, P., Wang, J., Groot, G., & Eramian, M. (2017). Thyroid nodule classification in ultrasound images by fine-tuning deep convolutional neural network. *Journal of digital imaging*, 30(4), 409-420.

Dov, D., Kovalsky, S. Z., Cohen, J., Range, D. E., Henao, R., & Carin, L. (2018). A Deep-Learning Algorithm for Thyroid Malignancy Prediction From Whole Slide Cytopathology Images. *arXiv preprint arXiv:1808.02788*.

Gharib, H., Papini, E., Garber, J. R., et al. (2016). AACE/ACE/AME Task Force on Thyroid Nodules: American Association of Clinical Endocrinologists, American College of Endocrinology, and Associazione Medici Endocrinologi Medical Guidelines for Clinical Practice for the Diagnosis and Management of Thyroid Nodules—Update. *Endocrine Practice*, 22(5), 522-538.

Guan, Q., Wang, Y., Du, J., Qin, Y., Lu, H., Xiang, J., & Wang, F. (2018). Deep learning based classification of ultrasound images for thyroid nodules: a large scale of pilot study. *Annals of translational medicine*, 7(7).

Haugen, B. R., Alexander, E. K., Bible, K. C., Doherty, G. M., Mandel, S. J., Nikiforov, Y. E., ... & Schuff, K. G. (2015). 2015 American Thyroid Association management guidelines for adult patients with thyroid nodules and differentiated thyroid cancer: the American Thyroid Association guidelines task force on thyroid nodules and differentiated thyroid cancer. *Thyroid*, 25(6), 6-35.

Hu, Tao, Honggang Qi, Qingming Huang, and Yan Lu. (2018) "See better before looking closer: Weakly supervised data augmentation network for fine-grained visual classification." *arXiv preprint arXiv:1808.05440*.

Huang, X., Gao, Y., & Li, Y. (2018). Thyroid ultrasound image segmentation using U-Net. *Biomedical Signal Processing and Control*, 41, 848-850.

Jocher G, Stoken A, Borovec J, Jocher G, Stoken A, Borovec J, Kwon Y, Xie T, Fang J, Wong C, Abhiram V, Zhiqiang Wang Z, Fati C, Skalski P, Hogan A, Strobel M, Jain M. ultralytics/yolov5: v7.0 - YOLOv5 SOTA Realtime Instance Segmentation, Zenodo, Nov (2020). Available online: <https://doi.org/10.5281/zenodo.5456942>

Kunapinun, A., Songsaeng, D., Buathong, S., Dailey, M. N., Keatmanee, C., & Ekpanyapong, M. (2020). Explainable Automated TI-RADS Evaluation of Thyroid Nodules. *Sensors*, 20(16), 4688.

LeCun, Y., Bengio, Y., Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.

Li, Z., Zhang, Y., & Wang, X. (2020). Attention-based deep learning for thyroid nodule detection. *Scientific Reports*, 10(1), 1-12.

Litjens, G., Kooi, T., Bejnordi, B. E., et al. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42, 60-88.

Liu, T., Guo, Q., Lian, C., Ren, X., Liang, S., Yu, J., ... & Shen, D. (2018). Automated detection and classification of thyroid nodules in ultrasound images using clinical-knowledge-guided convolutional neural networks. *Medical image analysis*, 45, 100-111.

Liu, T., Xie, S., Yu, J., Niu, L., & Sun, W. (2018, March). Classification of thyroid nodules in ultrasound images using deep model based transfer learning and hybrid features. In *2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)* (pp. 888-892). IEEE.

Luo, H., Chen, R., & Zhang, Y. (2020). Hybrid deep learning for thyroid segmentation. *Medical Image Analysis*, 61, 101888.

Namsena, P., Songsaeng, D., Keatmanee, C., Klabwong, S., Kunapinun, A., Soodchuen, S., ... & Dailey, M. N. (2020). Diagnostic performance of artificial intelligence in

interpreting thyroid nodules on ultrasound images: a multicenter retrospective study. *Quantitative Imaging in Medicine and Surgery*, ෧෧(෫), ෩෦෦-෦෦.

Ma, J., Wu, F., Jiang, T., Zhu, J., & Kong, D. (෨෦෧෭). Automatic detection of thyroid nodules in ultrasound images via convolutional neural networks. *Medical Physics*, ෪෪(෫), ෧෧෦෪-෧෧෦෭.

Nguyen, D. T., Pham, T. D., Batchuluun, G., Yoon, H. S., & Park, K. R. (෨෦෧෮). Artificial Intelligence-Based Thyroid Nodule Classification Using Information from Spatial and Frequency Domains. *Journal of clinical medicine*, ෭(෧෧), ෧෮෦෦.

Nikhila, P., Nathan, S., Ataide, E. J. G., Illanes, A., Friebe, D., & Abbineni, S. (෨෦෧෮). Lightweight Residual Network for The Classification of Thyroid Nodules. *arXiv preprint arXiv:෧෮෧෧.෦෪෦෦෦෦*.

Park, V. Y., Han, K., Seong, Y. K., Park, M. H., Kim, E. K., Moon, H. J., ... & Kwak, J. Y. (෨෦෧෮). Diagnosis of thyroid nodules: performance of a Deep Learning convolutional neural network Model vs. Radiologists. *Scientific reports*, ෮(෧), ෧-෮.

R. Ibrahim, K. Rahmat, F. Fadzli, F. I. Rozalli, C. J. Westerhout, K. Alli, A. Vijayananthan, and F. (෨෦෧෭) Moosa. Evaluation of solid breast lesions with power doppler: value of penetrating vessels as a predictor of malignancy. *Singapore Med J*, ෫෮(෧෧):෧෦෦෦-෧෦෦෦.

Shi, Y., Han, W. (෨෦෧෮). AI in thyroid ultrasound: current status and future perspectives. *Gland Surgery*, ෮(෧), ෦෦෦෦-෦෦෦෦.

Shorten, C., Khoshgoftaar, T. M. (෨෦෧෮). A survey on image data augmentation for deep learning. *Journal of Big Data*, ෫(෧), ෦෦.

Song, J., Chai, Y. J., Masuoka, H., Park, S. W., Kim, S. J., Choi, J. Y., ... & Yi, K. H. (෨෦෧෮). Ultrasound image analysis using deep learning algorithm for the diagnosis of thyroid nodules. *Medicine*, ෯෭(෧෫).

Sun, J., Liu, Y., Li, W., & Zhou, H. (෨෦෧෮). ThyNet: A lightweight CNN for thyroid nodule segmentation. *IEEE Transactions on Medical Imaging*, ෩෭(෧෧), ෧෦෦෦෦෦-෧෦෦෦෦෦.

W. K. Moon, J.-G. Im, D.-Y. Noh, and M. C. Han. (2000) Nonpalpable breast lesions: Evaluation with power doppler us and a microbubble contrast agent initial experience. Radiology, 295(1):240-246.

World Health Organization (WHO). (2020). "Digital health interventions for enhanced healthcare delivery.

Wu, T., Zhao, X., & Liu, H. (2022). Multi-scale thyroid nodule detection in ultrasound images. Expert Systems with Applications, 184, 116006.

Y. Yamakoshi, T. Nakajima, T. Kasahara, M. Yamazaki, R. Koda, and N. Sunaguchi. (2016) Shear wave imaging of in vivo breast tissue by color doppler shear wave elastography. IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control, 63(1):1-9.

Yang, G., Chen, L., & Zhou, X. (2021). Thyroid capsule-aware detection using attention mechanisms. Journal of Medical Imaging, 4(1), 040501.

Zhang, Y., Wang, Z., & Hu, Q. (2020). DenseNet for thyroid nodule classification in ultrasound images. Ultrasound in Medicine & Biology, 46(2), 444-454.

ภาคผนวก ก
ตัวอย่างแบบประเมินความพึงพอใจและคู่มือ

ภาคผนวก ข
เอกสารตีพิมพ์ในวารสารวิชาการระดับนานาชาติ

ภาคผนวก ค

รายงานผลการดำเนินการฉบับย่อสำหรับลงตีพิมพ์ในวารสารสำนักงาน กสทช.

ประวัตินักวิจัย



กองทุนวิจัยและพัฒนากิจการกระจายเสียง กิจการโทรทัศน์ และกิจการโทรคมนาคม เพื่อประโยชน์สาธารณะ
(สำนักงาน กสทช.)