

ปัญญาประดิษฐ์ล้ำยุค

Futuristic AI: Innovations, In-Depth Techniques, and Cross-Disciplinary Applications

Related Work Comparison & Troubleshooting Guide

ส่วนที่ 1: การเปรียบเทียบกับงานวิจัยอื่น (Related Work Comparison)

หนังสือเล่มนี้แนะนำเสนอวิธีการเรียนรู้เชิงลึก (Deep Learning) สำหรับ 6 กรณีศึกษา โดยมีการเปรียบเทียบกับงานวิจัยที่เกี่ยวข้องและระบบที่มีอยู่ในปัจจุบัน สรุปได้ดังนี้

1.1 สรุปการเปรียบเทียบวิธีที่นำเสนอกับวิธีอื่น ๆ (ภาพรวมทุกบท)

บท / งาน	วิธีที่นำเสนอ	วิธีเปรียบเทียบ	ผลลัพธ์ (งานนำเสนอ)	ผลลัพธ์ (งานอื่น)	สรุปข้อได้เปรียบ	อ้างอิง
Ch7 (UWB Breast)	Multi-DNN Deep Learning	UWB Signal Processing (TSAR, DMAS, DAS)	F1 = 96.98% Accuracy = 95%	ไม่รายงาน accuracy (qualitative only)	สูงกว่า (ไม่มีตัวเลขเปรียบเทียบ)	ตารางที่ 7.5
Ch7 (UWB vs CT)	Multi-DNN Deep Learning (UWB Signal)	CT Scan (Gold Standard)	100% (ส่วนใหญ่) 87% (กรณียาก)	CT Scan (Ground Truth)	เทียบเท่า CT Scan	ตารางที่ 7.4
Ch10 (Lung Tumor)	RNN (Classification) + RNN (Prediction)	Commercial RPM System (Varian Medical)	Error < 0.007% (คาบ); F1=100% (phase)	ราคาสูง ปรับแต่งไม่ได้	ดีกว่า RPM (ต้นทุนต่ำกว่า)	Table 10.4, 10.5

บท / งาน	วิธีที่นำเสนอ	วิธีเปรียบเทียบ	ผลลัพธ์ (งานนำเสนอ)	ผลลัพธ์ (งานอื่น)	สรุปข้อได้เปรียบ	อ้างอิง
Ch12 (UAV Altitude)	GRU (Gated Recurrent Unit)	LSTM (Long Short-Term Memory)	>97% accuracy MAE ลดลงทุก timestep	ซับซ้อนกว่า GRU ฝึกช้ากว่า	GRU เทียบเท่า/ดีกว่า LSTM (parameters น้อยกว่า)	Ch12 Summary
Ch4 (Multi-var Prediction)	Multi-point DNN (Deep Neural Network)	Multiple Regression (Linear Method)	Loss ลดลงสม่ำเสมอ ทุก epoch	Convergence ช้ากว่า ปรับ non-linear ไม่ได้	DNN ดีกว่าอย่างชัดเจน	รูปที่ 4.17

1.2 บทที่ 7 – การตรวจหาโลหะเรงเต้านมด้วย UWB + Deep Learning (ตารางที่ 7.5)

เปรียบเทียบวิธีการต่าง ๆ ในงานวิจัยทั่วโลก ที่ใช้สัญญาณ Ultra-Wideband (UWB) สำหรับตรวจหาโลหะเรงเต้านม โดยงานที่นำเสนอในหนังสือ (This work) เป็นงานวิจัยกลุ่มแรก ๆ ที่ใช้ Multi Deep-Learning Localization ร่วมกับสายอากาศแบบ Movable Multistate:

หัวข้อวิจัย	ประเภทสายอากาศ	วิธีถ่ายภาพ / Algorithm	ช่วงความถี่	วิธี DL / AI	ผลลัพธ์ที่รายงาน	ปี	อ้างอิง
Tissue Sensing (TSAR)	Balanced Antipodal Vivaldi	TSAR	1.0–13 GHz	ไม่ระบุ (Signal Processing)	- (ไม่รายงาน accuracy)	2004	[3]
Breast Detection	Tapered + Transmission Loaded	DMAS	2.0–8.0 GHz	ไม่ระบุ (DMAS Algorithm)	- (ไม่รายงาน accuracy)	2008	[4]

หัวข้อวิจัย	ประเภทสายอากาศ	วิธีถ่ายภาพ / Algorithm	ช่วงความถี่	วิธี DL / AI	ผลลัพธ์ที่รายงาน	ปี	อ้างอิง
Breast Cancer Detection	Slotted Patch	Fixed Switching Matrix	3.5–15.0 GHz	ไม่ระบุ (Signal Processing)	- (ไม่รายงาน accuracy)	2010	[5]
Breast Cancer Detection	Corrugated Antipodal Vivaldi	Fixed Switching Matrix	1.0–4.0 GHz	ไม่ระบุ (Confocal Imaging)	- (ไม่รายงาน accuracy)	2012	[6]
Breast Tumor Detection	UWB Transceiver	DAS (Delay and Sum)	3.0–10.0 GHz	ไม่ระบุ (DAS Algorithm)	- (ไม่รายงาน accuracy)	2015	[15]
UWB Breast Imaging	CPW feed EBG Antenna	Fixed Switching Matrix	3.1–7.6 GHz	NN (Neural Network)	- (ไม่รายงาน accuracy)	2018	[16]
Breast Cancer Detection	CPW Feed Monopole	DMAS	4–8 GHz	ไม่ระบุ (DMAS Algorithm)	- (ไม่รายงาน accuracy)	2019	[18]
Breast Detection	Horn-like 3D UWB	Fixed Rotated Platform	2.0–4.0 GHz	ไม่ระบุ (Detection Only)	- (ไม่รายงาน accuracy)	2020	[19]
Breast Cancer Localization	Slide Slotted Vivaldi	IC-DAS	2.8–7.0 GHz	ไม่ระบุ (IC-DAS)	- (ไม่รายงาน accuracy)	2021	[21]
Breast Tumor Localization (งานที่นำเสนอ)	Side Slot Vivaldi 9Rx + 1Tx (Movable)	Multi Deep-Learning Localization	2.8–7.0 GHz	Multi-DNN (Deep Learning)	F1 = 96.98% Accuracy = 95% (Tumor Loc.)	2024	This work

* งานวิจัยในวรรณกรรมส่วนใหญ่ใช้ Signal Processing (TSAR, DMAS, DAS) โดยไม่รายงานค่า Accuracy/F1; งานที่นำเสนอเป็นกรณีแรก ๆ ที่ใช้ Multi-Deep-Learning และรายงานผลเชิงปริมาณ

1.3 บทที่ 7 – การเปรียบเทียบผลลัพธ์ DL กับ CT Scan (ตารางที่ 7.4)

ใช้ภาพ CT Scan เป็น Ground Truth เพื่อประเมินความถูกต้องของระบบตรวจหามะเร็งเต้านมด้วย UWB + Deep Learning (17 Class, 136 test samples):

กรณีทดสอบ	TP	FP	FN	Precision (%)	Recall / F1 (%)
Training – ตัวแทนทุก Class (CT vs DL)	8	0	0	100%	100% / 100%
Test – Class ตัวแทน (CT vs DL, Avg.)	8	0	0	100%	100% / 100%
Test – กรณียาก (deep position, TP=7)	7	1	2	87%	77% / 81.7%
Test – กรณีเฉลี่ย (TP=7)	7	1	1	87%	87% / 87%

* ผลลัพธ์ Precision/F1 = 100% ในกรณีส่วนใหญ่ แสดงให้เห็นว่าระบบ DL สามารถตรวจสอบตำแหน่งมะเร็งได้เทียบเท่า CT Scan

1.4 บทที่ 10 – การเปรียบเทียบกับระบบ RPM เชิงพาณิชย์ (Varian Medical Systems)

งานวิจัยในบทที่ 10 เปรียบเทียบกล้อง Kinect v2 ที่พัฒนาร่วมกับ RNN/GRU กับระบบ Real-time Position Management (RPM) ของ Varian Medical Systems ซึ่งเป็นอุปกรณ์มาตรฐานทางการแพทย์สำหรับติดตามการเคลื่อนไหวของผนังทรวงอกในการรักษามะเร็งปอดด้วยรังสี:

รายการวัด	Kinect v2 (ระบบที่พัฒนา)	RPM (Varian Medical)	ค่าความผิดพลาด (%)	หมายเหตุ
คาบการหายใจ (ตัวอย่าง Index 0)	3.320 sec	3.320 sec	0.000%	ตรงกันสมบูรณ์

รายการวัด	Kinect v2 (ระบบที่พัฒนา)	RPM (Varian Medical)	ค่าความผิดพลาด (%)	หมายเหตุ
คาบการหายใจ (ตัวอย่าง Index 2)	4.074 sec	4.040 sec	0.034%	เกณฑ์ < ±2 mm
คาบการหายใจ (ตัวอย่าง Index 12)	4.280 sec	4.280 sec	0.000%	ตรงกันสมบูรณ์
คาบการหายใจ (ตัวอย่าง Index 14)	3.860 sec	3.800 sec	0.060%	ค่าสูงสุดในตัวอย่าง
ค่าเฉลี่ยความผิดพลาดคาบ (Mean)	—	—	< 0.007%	น้อยกว่าเกณฑ์ RPM มาก
ช่วงตรวจจับ (Kinect)	750–950 mm	N/A	—	ระยะที่เหมาะสม: 930 mm
Axis Motion Accuracy (CT/PET)	—	2.0 cm (±0.2 cm)	—	RPM Spec อ้างอิง (Varian 2019)

* ระบบ RPM ของ Varian Medical มีราคาสูงและเป็นเทคโนโลยีแบบปิด; ระบบที่พัฒนาขึ้นมีราคาถูกกว่า ปรับแต่งได้ และมีความแม่นยำเทียบเท่า

ส่วนที่ 2: Troubleshooting Guide – ปัญหาที่พบบ่อยในการพัฒนา Deep Learning

สรุปปัญหาที่พบบ่อยในการพัฒนาโครงข่ายประสาทเทียมเชิงลึก พร้อมสาเหตุ อาการ และวิธีแก้ไข จากเนื้อหาในหนังสือ:

ระดับความรุนแรง: **HIGH** = ส่งผลต่อประสิทธิภาพอย่างมาก | **MEDIUM** = ส่งผลปานกลาง | **LOW** = ส่งผลน้อย

#	ปัญหาที่พบ	สาเหตุหลัก	อาการ / Symptom	วิธีแก้ไข	บทอ้างอิงในหนังสือ	ระดับความรุนแรง
1	Gradient Vanishing (ความชันหายไป)	โครงข่ายมีหลายชั้นมากเกินไป ค่าเกรเดียนต์ลดลงเรื่อย ๆ จนเข้าใกล้ศูนย์	โมเดลเรียนรู้ช้ามาก / หยุดเรียนรู้ค่าความสูญเสียไม่ลดลงในชั้นแรก ๆ	กำหนดจำนวน Hidden Layers ให้เหมาะสม (3-5 ชั้น) ใช้ฟังก์ชัน ReLU/PReLU แทน Sigmoid/Tanh	Ch4 Neural Network (L40329-40342)	LOW
2	Exploding Gradients (ความชันระเบิด)	ค่าเกรเดียนต์เพิ่มขึ้นอย่างรวดเร็วจนมีค่ามหาศาล	ค่า loss กลายเป็น NaN / น้ำหนักกระเปิดออกไป ไม่ Converge	ใช้ Gradient Clipping จำกัดขนาดเกรเดียนต์ ลด Learning Rate ใช้ Batch Normalization	Ch4 Neural Network (L8436-8445)	LOW
3	Overfitting (โอเวอร์ฟิตติ้ง)	โมเดลซับซ้อนเกินไป จดจำข้อมูล training มากเกินไปจนทำนายข้อมูลใหม่ได้ไม่ดี	Train accuracy สูง แต่ Validation/Test accuracy ต่ำ มีช่องว่างกว้างระหว่างสองค่า	ใช้ Dropout (ปิด node สุ่ม), L1/L2 Regularization, เพิ่มข้อมูล Training (Data Augmentation), Early Stopping	Ch10 RNN (L70549), Ch11 Custom NN (L71253), Ch4 (L40399)	LOW
4	Underfitting (อันเดอร์ฟิตติ้ง)	โมเดลง่ายเกินไป หรือฝึกน้อยรอบ ไม่สามารถจับรูปแบบในข้อมูลได้	Train accuracy ต่ำ ค่าความสูญเสียไม่ลดลงมากพอ	เพิ่ม Hidden Layers/Nodes ใช้ Activation Function ที่เหมาะสม เพิ่มจำนวน Epoch เปลี่ยนสถาปัตยกรรมโครงข่าย	Ch4 Neural Network (L40338-40356)	LOW

#	ปัญหาที่พบ	สาเหตุหลัก	อาการ / Symptom	วิธีแก้ไข	บทอ้างอิงในหนังสือ	ระ
5	ข้อมูลไม่ได้ Normalize (Feature Scaling Issues)	Feature ที่มีช่วงค่าต่างกันมาก ทำให้โมเดลมีความลำเอียงไปตาม Feature ที่มีค่าสูง	โมเดลเรียนรู้ช้า หรือ Converge ผิดปกติ gradient ไม่สม่ำเสมอ	ทำ Normalization ทุก Feature ด้วย Min-Max Scaling [0,1] หรือ Z-score Standardization ก่อน training	Ch6 Microwave Ablation (L12120–12131) Ch12 GRU (L86669)	
6	Learning Rate ไม่เหมาะสม (Suboptimal Learning Rate)	Learning rate สูงเกินไป → Diverge; ต่ำเกินไป → Converge ช้ามาก	Loss กระโดดขึ้นลงแบบสุ่ม (rate สูง) หรือ Loss ลดลงช้ามาก (rate ต่ำ)	ใช้ Learning Rate ในช่วง 0.001–0.1 (ทดลองค่าต่าง ๆ) ใช้ Learning Rate Scheduler ปรับลดอัตโนมัติ	Ch6 ($\alpha=0.01$), Ch10 ($\alpha=0.1$) Ch7 (L51175, L57841)	
7	จำนวน Hidden Layers/Nodes ไม่เหมาะสม	น้อยเกินไป: Underfitting; มากเกินไป: Gradient Vanishing + หน่วยความจำมาก	ประสิทธิภาพไม่ดีทั้งคู่ ใช้ RAM สูง หรือ training ช้ามาก	เริ่มต้นที่ 3–5 Hidden Layers ใช้ Grid Search หรือ Bayesian Optimization เลือกจำนวน Node	Ch4 Neural Network (L40338–40369)	
8	เลือก Activation Function ผิดประเภท	Sigmoid/Tanh ใน Hidden Layers → Vanishing Gradient; Linear ใน Output Classification → ผิดพลาด	Vanishing gradient, output ไม่อยู่ในช่วงที่ถูกต้อง	Hidden Layers: ใช้ ReLU หรือ PReLU; Output (Classification): ใช้ Softmax; Output (Regression): ใช้ Linear	Ch2 Activation Functions (L11404–L11453) Ch10 (Softmax output, L70571)	
9	Batch Size ไม่เหมาะสม	Batch เล็กเกินไป: noisy gradient; Batch ใหญ่เกินไป: overfitting, RAM เต็ม	Loss ไม่ smooth (batch เล็ก) หรือ Generalization ต่ำ (batch ใหญ่)	ใช้ Mini-batch SGD (32–256 samples) ทดลองค่าต่าง ๆ พิจารณาตามขนาด dataset	Ch2 (Batch Size: L8371–L8383)	

#	ปัญหาที่พบ	สาเหตุหลัก	อาการ / Symptom	วิธีแก้ไข	บทอ้างอิงในหนังสือ	ระ
10	ข้อมูลไม่สมดุล (Class Imbalance) และ Vanishing Gradient ใน RNN	RNN มี time steps มากเกินไป ทำให้ Gradient Vanishing; Class ไม่สมดุลทำให้ bias	โมเดล RNN ทำนายเฉพาะ majority class; Training หยุดก่อนเวลา	ใช้ LSTM/GRU แทน Vanilla RNN; กำหนด Time Steps ประมาณ 3 ช่วง; ใช้ Class Weights หรือ Oversampling	Ch12 LSTM/GRU (L82743–82756) Ch10 RNN (L67215–67232)	

2.2 Quick Reference: การเลือกฟังก์ชันกระตุ้น (Activation Function Selection Guide)

จากเนื้อหาในหนังสือ (บทที่ 2 และกรณีศึกษาต่าง ๆ) แนะนำการเลือกใช้ Activation Function ดังนี้:

Activation Function	เหมาะสำหรับ	ข้อดี	ข้อเสีย/ข้อควรระวัง	ตัวอย่างในหนังสือ
ReLU (Rectified Linear Unit)	Hidden Layers ทั่วไป	ลด computation ไม่เกิด saturation สำหรับ $z > 0$	อาจเกิด 'Dead ReLU' (node ส่งออก 0 ตลอด) ถ้า Learning Rate สูง	ใช้ใน Ch6, Ch7, Ch8, Ch10
PReLU (Parametric ReLU)	Hidden Layers ที่ต้องการยืดหยุ่น	แก้ปัญหา Dead ReLU ด้วยค่า slope ที่ปรับได้	มี parameter เพิ่มเติมที่ต้อง train	แนะนำใน Ch4 Neural Network
Sigmoid	Output Layer (Binary Classification)	ส่งออกค่า $[0,1]$ เหมาะกับ Binary Output	Vanishing gradient ใน Hidden Layers ไม่ควรใช้	ไม่แนะนำใน Hidden Layers
Tanh (Hyperbolic Tangent)	Hidden Layers (ข้อมูล Centered)	ส่งออก $[-1,1]$ center ที่ 0 ดีกว่า Sigmoid	Vanishing gradient ยังคงมีอยู่ใน Deep networks	ใช้ใน Sequential data
Softmax	Output Layer (Multi-class Classification)	ส่งออกเป็น Probability distribution รวม = 1.0	ไม่เหมาะกับ Regression หรือ Hidden Layers	ใช้ใน Ch10 (10 phase output) Ch7 (17 class output)
Linear / None	Output Layer (Regression)	ส่งออกค่าต่อเนื่อง ไม่จำกัดช่วง	ไม่เหมาะกับ Classification	ใช้ใน Ch6 (temperature prediction) Ch12 (altitude prediction)

2.3 Quick Reference: ค่า Hyperparameter ที่ใช้ในกรณีศึกษาจริง

สรุปค่า Hyperparameter ที่ใช้จริงในแต่ละกรณีศึกษา เพื่อใช้เป็นจุดเริ่มต้น (Starting Point):

บท	งาน	สถาปัตยกรรม	Learning Rate	Epoch	Hidden Layers	Normalization	ผลลัพธ์
Ch6	Temperature Prediction (Microwave Ablation)	DNN Regression	0.01	5,000	300	Min-Max	MSE 99.98%
Ch7	Breast Cancer Detection (UWB + DL)	Multi-point DNN	0.01	5,000	—	Z-score	F1 96.98%
Ch8	Gesture Recognition (UWB Human Activity)	Custom Multi-DNN	0.01	5,000	—	Min-Max	F1 98% (Train)
Ch10	Lung Tumor Prediction (RNN + Kinect)	RNN (Class+Predict)	0.1	1,000	—	Min-Max	F1 100% (phase)
Ch12	UAV Altitude Prediction (GRU)	GRU (3 timesteps)	—	—	3 timesteps	Min-Max	>97% accuracy
Ch14	Underground Detection (Custom NN + GPR)	Custom NN + GPR	—	—	—	—	92.80% overall

รองศาสตราจารย์ ดร.ภัทรพงษ์ ผาสุขกิจ | สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง (KMITL) | www.pattarapong.com