

บทที่ 4

ผลการวิจัยและอภิปรายผล

ในบทนี้จะนำเสนอผลการทดลอง การวิเคราะห์และการอภิปรายผลแบบจำลองการเรียนรู้ของเครื่องด้วยโปรแกรมภาษาไพธอน Google Colab โดยเทคนิควิธีโครงข่ายประสาทเทียม (Neural Network) ซึ่งได้ทำการทดลองเทคนิควิธีโครงข่ายประสาทเทียม 3 แบบคือ วิธีโครงข่ายประสาทเทียมแบบ 2 เลเยอร์,วิธีโครงข่ายประสาทเทียมแบบ VGG และวิธีโครงข่ายประสาทเทียมแบบ Resnet 50 ด้วยชุดข้อมูลวิดีโอ 2 ชุด ได้แก่ชุดข้อมูลการเรียนรู้วิดีโอปกติ และ ชุดข้อมูลวิดีโอเพิ่มการประมาณการทำทางด้วย MediaPipe ได้แบบจำลอง มาทั้งหมด 6 แบบจำลอง กำหนดชื่อแบบจำลองดังนี้


1. แบบจำลองโดยเทคนิควิธีโครงข่ายประสาทเทียมแบบ 2 เลเยอร์ รุ่นที่1 (2-layer Ver.1)
2. แบบจำลองโดยเทคนิควิธีโครงข่ายประสาทเทียมแบบ 2 เลเยอร์ รุ่นที่2 (2-layer Ver.2)
3. แบบจำลองโดยเทคนิควิธีโครงข่ายประสาทเทียมแบบ VGG รุ่นที่1 (VGG Ver.1)
4. แบบจำลองโดยเทคนิควิธีโครงข่ายประสาทเทียมแบบ VGG รุ่นที่2 (VGG Ver.2)
5. แบบจำลองโดยเทคนิควิธีโครงข่ายประสาทเทียมแบบ Resnet50 รุ่นที่1 (Resnet50 Ver.1)
6. แบบจำลองโดยเทคนิควิธีโครงข่ายประสาทเทียมแบบ Resnet50 รุ่นที่2 (Resnet50 Ver.2)

จากนั้นนำผลที่ได้มาประเมินประสิทธิภาพแบบจำลองจำแนกประเภทการล้ม 4 ประเภท และการเดิน โดยใช้ค่าความถูกต้อง (Accuracy), ค่าความแม่นยำ (Precision) ค่าเรียกคืน (Recall), ค่าเฉลี่ยของความแม่นยำและค่าเรียกคืน (F1-score) รวมถึงกราฟ ROC และค่า AUC

4.1 ผลการทดสอบประสิทธิภาพแบบจำลองโดยเทคนิควิธีโครงข่ายประสาทเทียมแบบ 2 เลเยอร์

4.1.1 Training Validation Loss และ Training Validation Accuracy ของ 2 เลเยอร์


จากการเทรนนิ่งข้อมูล 2 ชุดข้อมูล โดยมีชุดข้อมูลวิดีโอปกติและชุดข้อมูลที่เพิ่มการประมาณการทำทางด้วย MediaPipe ผลการทดสอบค่าความถูกต้อง (Accuracy) แสดงดังรูปที่ 4.1 และ 4.2



รูปที่ 4.1 แสดงกราฟบน Loss (Train vs Validation) และกราฟล่าง Accuracy

(Train vs Validation) 2-layer Ver.1

จากรูปที่ 4.1 แกน x แสดงการเรียนรู้ 1 รอบของข้อมูล (Epoch) และแกน y แสดงค่าความผิดพลาดของแบบจำลอง (Loss) กราฟสีน้ำเงิน คือค่า Train loss ลักษณะลดลงอย่างสม่ำเสมอ แสดงว่าแบบจำลอง เรียนรู้ข้อมูล train ได้ดีขึ้นเรื่อยๆ ในขณะที่กราฟสีส้ม คือค่า Validation loss ในช่วงแรก กราฟมีการแกว่งขึ้นๆลงๆมีความผันผวนสูง ไม่ลดลงตาม ค่า Train loss ลักษณะแบบนี้บ่งชี้ว่าข้อมูล Validation มีสัญญาณรบกวน (Noise) และแบบจำลองมีบางจุดเกิด Overfitting ส่วนกราฟล่างแสดงข้อมูลความถูกต้องระหว่าง train และ Validation สำหรับ Train accuracy กราฟเพิ่มขึ้นอย่างสม่ำเสมอจนเกือบถึง 90% สรุปได้ว่าแบบจำลองเรียนรู้ได้ดี ส่วน Validation accuracy มีแนวโน้มเพิ่มขึ้นในช่วงแรก แต่ในช่วงกลางยังมีความผันผวนสูง แต่ยังมีแนวโน้มเพิ่มขึ้น โดยรวมการที่ Validation Accuracy มีความผันผวน และมีค่าต่ำกว่า Train Accuracy อย่างมีนัยยะ สรุปได้ว่าแบบจำลองเกิด Overfitting ซึ่งหมายถึงการทำนายข้อมูลใหม่จะไม่ดี

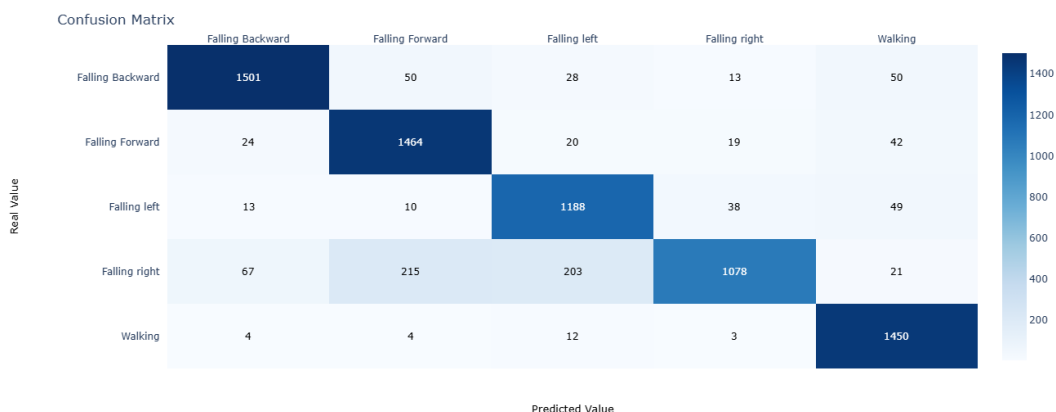


รูปที่ 4.2 แสดงกราฟบน Loss (Train vs Validation) และกราฟล่าง Accuracy (Train vs Validation) 2-layer Ver.2

จากรูปที่ 4.2 Train loss ลักษณะลดลงอย่างสม่ำเสมอจากประมาณ 1.5 ไปถึง 0.3 แสดงว่าแบบจำลองกำลังเรียนรู้ข้อมูล Training set ได้ดีขึ้นเรื่อย ๆ อย่างต่อเนื่อง รูปทรงการลดมีลักษณะ Smooth ซึ่งบ่งบอกว่าการ Optimizer ทำงานดี ส่วน Validation Loss เริ่มต้นใกล้เคียงกับ Train Loss (ประมาณ 1.5) หลังจากนั้น เกิดการผันผวนค่อนข้างสูง โดยเฉพาะช่วง Epoch 5–10 Validation Loss มีค่าสูงจนเกิน 2.0 แต่หลังจาก Epoch 12 ไป Validation Loss ลดลงชัดเจนและมีค่าน้อยกว่าช่วงแรก และในช่วง 14-18 Validation Loss กับ Train Loss เข้าใกล้กัน จะเห็นได้จากกราฟที่มีบางส่วนทับกัน ซึ่งแสดงให้เห็นว่า แบบจำลองสามารถทำนายข้อมูลที่ไม่เคย Train มาก่อนได้ถูกต้องมากขึ้น สำหรับค่าความแม่นยำ ในกราฟล่างนั้น Train Accuracy เพิ่มขึ้นต่อเนื่องจากประมาณ 38% ไปถึง 90% โดยสอดคล้องกับการลดลงของ Train Loss แสดงถึงความสามารถในการเรียนรู้และจดจำข้อมูล Training ได้ดี เมื่อเปรียบเทียบกับ Validation Accuracy ในช่วง Epoch 0–10 มีการแกว่งตัวค่อนข้างมาก เช่น ค่าความแม่นยำขึ้นไปถึงจาก 60% และลดลงมาเหลือ 45% แสดงถึงความไม่เสถียรของแบบจำลอง ในการทำนายข้อมูลที่ไม่เคยเห็นมาก่อน แต่ตั้งแต่ Epoch 13 เป็นต้นไป Validation Accuracy สูงขึ้นจนถึง 90% แสดงถึงความเสถียรที่มีมากขึ้น ช่วงปลายกราฟ Validation Accuracy มีแนวโน้มเพิ่มขึ้นอย่างคงที่จนมีค่าใกล้เคียง Train Accuracy ซึ่งหมายถึงว่าแบบจำลองมีความเข้าใจรูปแบบของชุดข้อมูล

4.1.2 Confusion Matrix ของ 2 เลเยอร์

Confusion Matrix นี้แสดงผลลัพธ์ของแบบจำลองในการจำแนกคลาส 5 ประเภท ดังนี้ Falling Backward, Falling Forward, Falling Left, Falling Right และ Walking โดยแกนแนวนอน คือค่าความจริง (Real/True Labels) แกน แนวอน คือค่าที่แบบจำลองทำนาย (Predicted Labels)



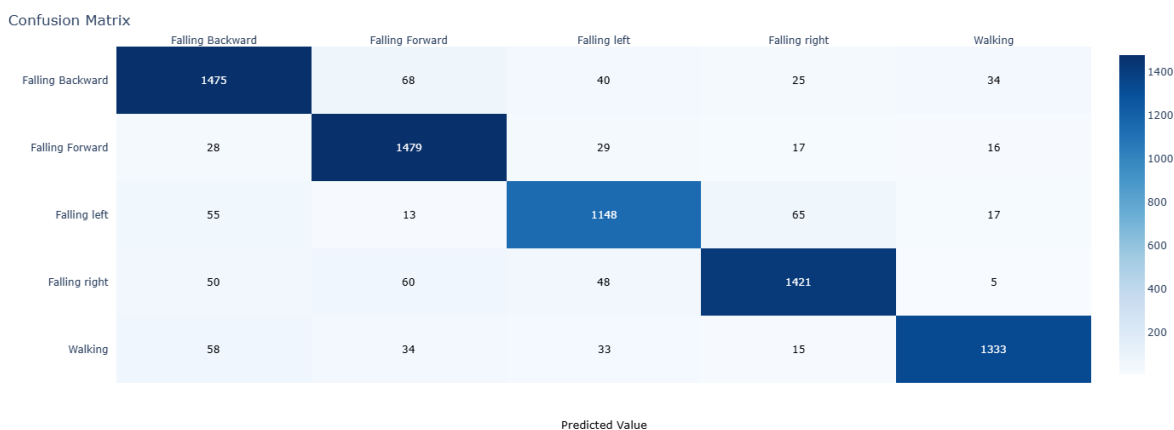
รูปที่ 4.3 แสดงตาราง Confusion Matrix ของ 2-layer Ver.1

จากรูปที่ 4.3 แบบจำลอง 2 เลเยอร์ ทำนายคลาส Falling Backward, Falling Forward และ Walking ได้อย่างแม่นยำ มีการทำนายผิดเป็นคลาสอื่นๆ น้อยกว่าคลาส Falling Left และ Falling Right โดยคลาส Falling Left มีการทำนายผิดเป็นคลาส Falling Right และ Walking ส่วน Falling Right มีการทำนายผิดเป็น Falling Forward และ Falling Left ค่อนข้างมาก เมื่อนำ Confusion Matrix ที่ได้มาหาค่าความแม่นยำ(Precision) ค่าเรียกคืน (Recall) และ F1-score จะได้ดังตารางที่ 4.1

ตารางที่ 4.1 รายงานการจำแนกประเภท (Classification Report) ของ 2-layer Ver.1

Class	Precision	Recall	F1-Score	Support
Falling Backward	0.9329	0.9141	0.9234	1642
Falling Forward	0.8399	0.9331	0.8841	1569
Falling Left	0.8187	0.9153	0.8643	1298
Falling Right	0.9366	0.6806	0.7883	1584
Walking	0.8995	0.9844	0.9400	1473
Accuracy			0.8830	7566
Macro Avg	0.8855	0.8855	0.8800	7566
Weighted Avg	0.8883	0.8830	0.8801	7566

จากตารางที่ 4.1 แสดงให้เห็นว่าแบบจำลองนี้ มีการทำนายถูกต้อง 88.3 %ของข้อมูลทั้งหมด โดยคลาส Walking มีค่าเรียกคืนสูงถึง 98.44 % ซึ่งหมายความว่า มีการทำนายคลาส Walking ได้เกือบทั้งหมด แต่ค่าความแม่นยำมีค่าเพียง 89.95 % ค่าความแม่นยำที่ต่ำเนื่องจากแบบจำลองมีการทำนายผิดจากการล้มประเภทต่างๆ เป็นการเดิน อาจต้องนำมาคำนึงถึงเรื่องความปลอดภัยต่อการนำไปใช้งาน ส่วนคลาส Falling Right แม้จะมีค่าความแม่นยำ สูงถึง 93.66 % แต่ก็มีค่าเรียกคืนต่ำที่สุด เมื่อเทียบกับคลาสทั้งหมดบ่งบอกว่าแบบจำลองนี้มีการทำนายคลาส Falling Right ผิดพลาดสูง ในส่วนของการทำนายคลาส Falling Forward และ Falling Left มีประสิทธิภาพในการทำนายอยู่ในระดับปานกลาง แต่อยู่ในเกณฑ์ที่สามารถใช้งานได้ จากข้อมูลในตารางคลาส Falling Backward เป็นคลาสที่แบบจำลองสามารถทำนายได้ดีที่สุดทั้งความแม่นยำและความครบถ้วนแบบจำลองจากชุดข้อมูลวิดีโอปกติ แม้จะมีค่าความแม่นยำและค่าเรียกคืนที่สูงกว่า 90 % แต่แบบจำลองยังไม่มี ความสมดุล เนื่องจากบางคลาสยังมีการทำนายได้ไม่ครบถ้วนเมื่อเทรนแบบจำลองด้วยชุดข้อมูลวิดีโอปกติพบว่าคลาส Falling Right มีค่าเรียกคืนต่ำที่สุดซึ่งอาจเกิดจากการที่แบบจำลองสับสนกับคลาส Falling Left จึงได้เพิ่มการประมาณการทำทางด้วย MediaPipe ในชุดข้อมูล ผลการเทรนแบบจำลองแสดงในรูปที่ 4.4 และตารางที่ 4.2



รูปที่ 4.4 แสดงตาราง Confusion Matrix ของ 2-layer Ver.2

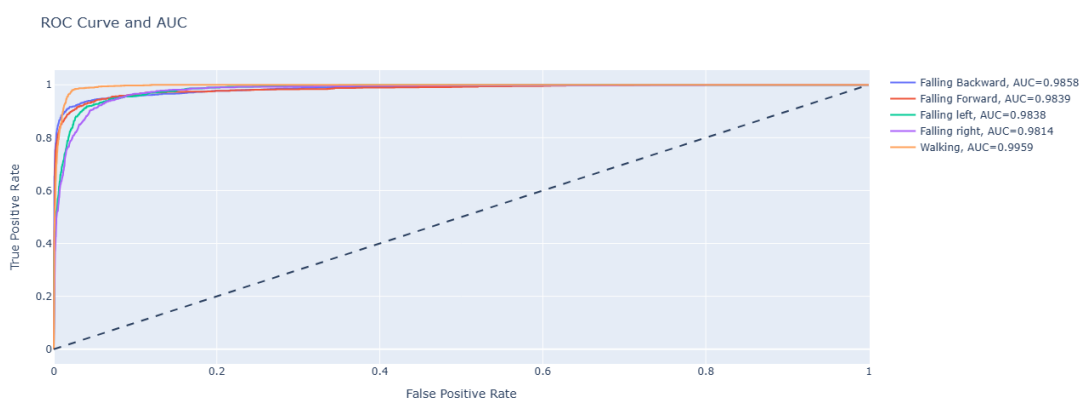
ตารางที่ 4.2 รายงานการจำแนกประเภท (Classification Report) ของ 2-layer Ver.2

Class	Precision	Recall	F1-Score	Support
Falling Backward	0.8854	0.8983	0.8918	1642
Falling Forward	0.8942	0.9426	0.9178	1569
Falling Left	0.8844	0.8844	0.8844	1298
Falling Right	0.9209	0.8971	0.9089	1584
Walking	0.9488	0.9050	0.9263	1473
Accuracy			0.9062	7566
Macro Avg	0.9067	0.9055	0.9058	7566
Weighted Avg	0.9068	0.9062	0.9062	7566


จากตารางที่ 4.2 แบบจำลองมีความถูกต้อง 90.62 % ซึ่งสูงกว่าการเทรนชุดข้อมูลวีดีโอปกติ 2 % ในแบบจำลองนี้ คลาส Falling Backward มีความแม่นยำ 88.54 % และมีค่าเรียกคืน 89.83 % และ F1-Score มี 89.18% ซึ่งถือว่ามีความสมดุล ในส่วนของ Falling Forward และคลาส Falling Left ที่แบบจำลองมีการทำนายได้อย่างแม่นยำมากขึ้น โดยคลาส Falling Forward มีความแม่นยำใกล้เคียงกับ Falling Backward ซึ่งอยู่ในเกณฑ์ที่ดี ส่วนคลาส Falling Left แม้จะมีความแม่นยำสูงขึ้นและมีความสมดุล สืบเนื่องจากค่าความแม่นยำ,ค่าเรียกคืนและ F1-Score ที่มีค่าเท่ากัน แต่ประสิทธิภาพการทำนายยังไม่สูงเท่าคลาสอื่น คลาส Falling Right มีความแม่นยำลดลงเมื่อเทียบกับแบบจำลองข้อมูลวีดีโอปกติ แต่ค่าเรียกคืนสูงขึ้นอย่างเห็นได้ชัด หมายความว่าแบบจำลองสามารถแยก คลาส Falling Right ได้อย่างครอบคลุมมากขึ้น ส่วนการแยกประเภทคลาส Walking แม้ค่าเรียกคืนจะลดลงจากแบบจำลองข้อมูลวีดีโอปกติ แต่ความแม่นยำมีค่าสูงขึ้นอย่างเห็นได้ชัด แบบจำลอง 2 เลเยอร์จากข้อมูลวีดีโอชุดข้อมูลวีดีโอเพิ่มการประมาณการทำทางด้วย MediaPipe มีความสมดุลดี

4.1.3 กราฟ ROC และค่า AUC ของ 2 เลเยอร์

กราฟ ROC และค่า AUC ของแบบจำลอง 2 เลเยอร์จากข้อมูลทั้ง 2 ชุด แสดงดังรูปที่ 4.5 และ 4.6 ในรูปที่ 4.5 และ 4.6 จะเห็นว่ากราฟของแบบจำลองทั้ง 2 ชุดข้อมูลอยู่เหนือเส้นประทั้งหมด และมีค่าเข้าใกล้ 1 หมายถึงว่าแบบจำลองทั้ง 2 ชุดข้อมูลมีความสามารถในการแยกประเภทในแต่ละคลาสได้อย่างมีประสิทธิภาพ



รูปที่ 4.5 แสดงกราฟ ROC และค่า AUC ของ 2-layer Ver.1



รูปที่ 4.6 แสดงกราฟ ROC และค่า AUC ของ 2-layer Ver.2

ตารางที่ 4.3 แสดงการเปรียบเทียบของค่า AUC จากแบบจำลองทั้ง 2 ชุดข้อมูล (2-layer)

Class	AUC ของ 2-layer Ver.1	AUC ของ 2-layer Ver.2	การเปรียบเทียบ
Falling Backward	0.9858	0.9878	เพิ่มขึ้นเล็กน้อย
Falling Forward	0.9839	0.9913	เพิ่มขึ้นอย่างชัดเจน
Falling Left	0.9838	0.9871	เพิ่มขึ้นเล็กน้อย
Falling Right	0.9814	0.9884	เพิ่มขึ้นอย่างชัดเจน
Walking	0.9959	0.9905	ลดลงเล็กน้อย


จากการเปรียบเทียบค่า AUC ของ Falling Forward, Falling Right และ Falling Left ของชุดข้อมูล MediaPipe มีค่าสูงขึ้นอย่างเห็นได้ชัด แสดงว่าแบบจำลองมีการจำแนกคลาสเหล่านี้ได้ดีขึ้นเมื่อเทียบกับแบบจำลองชุดข้อมูลของวิดีโอปกติ แม้ว่าค่า AUC ของ Walking จะลดลง แต่ก็ยังมีค่าอยู่ในระดับที่สูงมาก และค่า AUC ทุกคลาสมีค่าสูงกว่า 0.98 บ่งบอกว่าแบบจำลองสามารถจำแนกได้ดีในทุกคลาส จากผลการทดลองแบบจำลองโดยเทคนิควิธีโครงข่ายประสาทเทียมแบบ 2 เลเยอร์ของชุดข้อมูลวิดีโอเพิ่มการประมาณการทำทางด้วย MediaPipe มีพัฒนาการที่ดีขึ้นในคลาส Falling ต่างๆ (Backward, Forward, Left, Right) ถึงแม้ว่าคลาส Walking มี AUC ลดลงเล็กน้อย แต่โดยรวมแบบจำลองโดยเทคนิควิธีโครงข่ายประสาทเทียมแบบ 2 เลเยอร์ ของชุดข้อมูลวิดีโอเพิ่มการประมาณการทำทางด้วย MediaPipe มีศักยภาพสูงกว่าเล็กน้อยในภาพรวมของการแยกหลายคลาส สรุปทั้งสองแบบจำลองมีความสามารถในการจำแนกพฤติกรรมการล้มและการเดินในระดับสูง โดยแบบจำลองโดยเทคนิควิธีโครงข่ายประสาทเทียมแบบ 2 เลเยอร์ ของชุดข้อมูลวิดีโอเพิ่มการประมาณการทำทางด้วย MediaPipe เหมาะกับการแยกคลาสล้มในภาพรวม ขณะที่แบบจำลองโดยเทคนิควิธีโครงข่ายประสาทเทียมแบบ 2 เลเยอร์ ของชุดข้อมูลวิดีโอปกติ โดดเด่นในด้านการจำแนก Walking

4.2 ผลการทดสอบประสิทธิภาพแบบจำลองโดยเทคนิควิธีโครงข่ายประสาทเทียมแบบ VGG


โมเดล CNN แบบ VGG16 ได้ปรับปรุงเพื่อลดความซับซ้อนและเหมาะกับข้อมูลที่เล็กกว่าเดิมเพิ่มประสิทธิภาพด้วย Global Average Pooling เพื่อลดความซับซ้อนของโมเดลและ Batch Normalization ช่วยเพิ่มความเร็วและเสถียรภาพในการเทรน

4.2.1 Training Validation Loss และ Training Validation Accuracy ของ VGG

ค่า loss และ Accuracy สำหรับการเทรนแบบฝึกจำลองด้วยชุดข้อมูลวีดีโอปกติ แสดงดังรูปที่ 4.7 จากกราฟบน Loss (Train vs Validation) ในช่วงแรก (Epoch 0-5) ค่า Loss ของ Validation มีความผันผวนสูงมาก โดยเฉพาะในช่วงต้น (epoch 2) ที่พุ่งขึ้นไปสูง ประมาณ 1.6 ก่อนที่จะปรับตัวลดลงอย่างรวดเร็วใน หลังจาก Epoch ที่ 5 เป็นต้นไป Validation Loss (เส้นสีส้ม) และ Train Loss (เส้นสีน้ำเงิน) ปรับลดลงอย่างต่อเนื่องและค่อนข้างเสถียรจนแทบไม่มีความแตกต่างกันมาก ซึ่งบ่งบอกว่าแบบจำลองเริ่มมีการ ทำนายผลลัพธ์ที่แม่นยำได้ทั้งบนข้อมูลที่ใช้ฝึก และบน ข้อมูลใหม่ ๆ ที่ไม่เคยผ่านการฝึกมาก่อน ได้ดีขึ้น และเกิดปัญหา Overfitting น้อยลงอย่างชัดเจน ส่วนกราฟล่าง Accuracy (Train vs Validation) ช่วงแรก (Epoch 0-5) ความแม่นยำมีการผันผวน ใน Validation Accuracy ที่ชัดเจน โดยเฉพาะ epoch ที่ 2 มีการลดลงอย่างมาก ซึ่งสัมพันธ์กับ Loss ที่เพิ่มขึ้น แต่หลังจาก epoch ที่ 5 เป็นต้นไป ความแม่นยำของ Train และ Validation มีการ ปรับตัวสูงขึ้น จนกราฟทั้งสองเส้นเข้าใกล้กัน และมี Accuracy สูงประมาณ 90% ขึ้นไป แสดงถึง ความเสถียรของแบบจำลอง




รูปที่ 4.7 แสดงกราฟบน Loss (Train vs Validation) และกราฟล่าง Accuracy (Train vs Validation) ของ VGG Ver.1



รูปที่ 4.8 แสดงกราฟบน Loss (Train vs Validation) และกราฟล่าง Accuracy (Train vs Validation) ของ VGG Ver.2

จากรูปที่ 4.8 กราฟบน Loss (Train vs Validation) ในช่วงเริ่มต้น (Epoch 0–5) Loss ของทั้ง Training และ Validation ลดลงอย่างรวดเร็ว แสดงให้เห็นว่าโมเดลเรียนรู้ได้เร็วแต่ Validation Loss ยังมีความผันผวนเล็กน้อย ช่วง Epoch 5–20 Training Loss ยังคงลดลงอย่างช้าๆ แต่คงที่มากขึ้นและสม่ำเสมอ ไม่มีเพิ่มขึ้นขึ้นอย่างผิดปกติ แสดงว่าการเรียนรู้ค่อนข้างเสถียรและดี ในขณะที่ Validation Loss ยังคงผันผวนตลอดช่วง มีลักษณะขึ้น-ลงสลับกันไปมา แสดงถึงการเรียนรู้ที่ยังไม่คงที่ หรือแบบจำลองอาจเรียนรู้ คุณลักษณะเฉพาะของชุดข้อมูลฝึกบางส่วนมากเกินไป ส่งผลให้ทำนายข้อมูลใหม่ (Validation) ได้ไม่ดีเท่าที่ควร ส่วนกราฟล่าง Accuracy (Train vs Validation) ช่วง Epoch 0–5 Accuracy ของทั้ง Training และ Validation มีแนวโน้มเพิ่มขึ้นอย่างรวดเร็วในช่วงต้น Validation Accuracy มีการผันผวนบ้างเล็กน้อย แต่ไม่รุนแรง ส่วนช่วง Epoch 5–20 Training Accuracy ค่อยๆ เพิ่มขึ้นอย่างต่อเนื่องและเสถียรมากขึ้นเรื่อย ๆ เข้าใกล้ค่า 90% โดย Validation Accuracy ยังคงผันผวนขึ้น-ลงเป็นระยะๆ มีลักษณะเช่นเดียวกับ Validation Loss ซึ่งสะท้อนถึงปัญหาในการการเรียนรู้ของแบบจำลองในบาง epoch แม้ Validation Accuracy จะมีความผันผวน แต่ Accuracy ในช่วงท้ายยังมีค่าสูงประมาณ 80%-90% ซึ่งถือว่าอยู่ในเกณฑ์ดีแต่ต้องมีการปรับปรุงเพื่อลดความไม่เสถียร

4.2.2 Confusion Matrix ของเทคนิควิธีโครงข่ายประสาทเทียมแบบ VGG



รูปที่ 4.9 แสดงตาราง Confusion Matrix ของ VGG Ver.1

ผลการทำนายของแบบจำลองโดยใช้เทคนิควิธีโครงข่ายประสาทเทียมแบบ VGG มีรายละเอียดดังนี้

Falling Backward (ล้มไปด้านหลัง) ทำนายถูกต้อง 1190 ตัวอย่าง และทำนายผิดเป็นคลาส Falling Forward จำนวน 138 ตัวอย่าง คลาส Falling Left 101 ตัวอย่าง คลาส Falling Right 115 ตัวอย่าง และคลาส Walking 98 ตัวอย่าง จะเห็นได้ว่าการทำนายผิดพลาดกระจายไปยังทุกคลาส

Falling Forward (ล้มไปด้านหน้า) ทำนายถูกต้อง 1427 ตัวอย่าง และทำนายผิดเป็นคลาส Falling Backward จำนวน 17 ตัวอย่าง คลาส Falling Left จำนวน 25 ตัวอย่าง คลาส Falling Right จำนวน 57 ตัวอย่าง และคลาส Walking จำนวน 43 ตัวอย่าง แบบจำลองนี้มีความแม่นยำในการจำแนกคลาสที่สูง มีแยกประเภทคลาตเคลื่อนกับคลาส Falling Right และ Walking แต่ถือว่าน้อยมากเมื่อเทียบกับจำนวนถูกต้อง

Falling Left (ล้มไปทางซ้าย) ทำนายถูกต้อง 1165 ตัวอย่าง และทำนายผิดเป็นคลาส Falling Backward จำนวน 3 ตัวอย่าง คลาส Falling Forward จำนวน 2 ตัวอย่าง คลาส Falling Right จำนวน 47 ตัวอย่าง และคลาส Walking จำนวน 81 ตัวอย่าง สำหรับคลาสนี้แบบจำลองมีความแม่นยำดี มีข้อผิดพลาดน้อยในคลาสล้มไปด้านหลังและด้านหน้า แต่การแยกประเภทผิดเล็กน้อยกับคลาส Walking ซึ่งอาจสะท้อนถึงลักษณะการเคลื่อนไหวที่คล้ายกันในบางสถานการณ์

Falling Right (ล้มไปทางขวา) ทำนายถูกต้อง 1476 ตัวอย่าง และทำนายผิดเป็นคลาส Falling Backward จำนวน 14 ตัวอย่าง คลาส Falling Forward จำนวน 16 ตัวอย่าง คลาส Falling


Left จำนวน 61 ตัวอย่าง และคลาส Walking จำนวน 17 ตัวอย่าง การแยกประเภทที่เห็นชัดคือการทำนายผิดไปเป็นคลาส Falling Left อาจมีสาเหตุมาจากการล้มซ้าย-ขวามีลักษณะที่ใกล้เคียงกัน

Walking (การเดิน) ทำนายถูกต้อง 1469 ตัวอย่าง และทำนายผิดเป็นคลาส Falling Forward จำนวน 1 ตัวอย่าง และคลาส Falling Left จำนวน 3 ตัวอย่าง คลาสนี้แบบจำลองมีความแม่นยำสูงมากที่สุดเมื่อเทียบกับคลาสอื่นๆ

ตารางที่ 4.4 รายงานการจำแนกประเภท (Classification Report) ของ VGG Ver.1

Class	Precision	Recall	F1-Score	Support
Falling Backward	0.9722	0.7247	0.8304	1642
Falling Forward	0.9009	0.9095	0.9052	1569
Falling Left	0.8598	0.8975	0.8783	1298
Falling Right	0.8708	0.9318	0.9003	1584
Walking	0.8601	0.9973	0.9236	1473
Accuracy			0.8891	7566
Macro Avg	0.8928	0.8922	0.8875	7566
Weighted Avg	0.8951	0.8891	0.8869	7566

ประสิทธิภาพของแบบจำลองในการจำแนกแต่ละคลาสแสดงดังตารางที่ 4.4 แบบจำลองสามารถทำนายคลาส Falling Backward ได้แม่นยำที่สุด เนื่องจากค่า Precision สูงถึง 97.22 % แต่ถึงค่า Precision จะสูงแต่ค่า Recall มีค่าต่ำที่สุดจากคลาสทั้งหมด แสดงถึงการทำนายที่ยังครอบคลุมไม่หมด จึงต้องปรับปรุง recall ด้วยการเพิ่มข้อมูลให้หลากหลายเพื่อการทำนายที่ครอบคลุมขึ้น คลาส Falling Forward มีค่าเมตริกซ์ทั้ง 3 ค่าที่ใกล้เคียงกัน ถือว่าแบบจำลองทำนายข้อมูลคลาสนี้ได้ดีและสมดุล สำหรับคลาส Falling Left , Falling Right และ Walking ค่า Recall มีค่าสูงกว่า Precision ทั้ง 3 คลาส สะท้อนถึงการทำนายที่ครอบคลุม แต่มีข้อผิดพลาดที่ทำนายเป็นคลาสอื่น ๆ สรุปแบบจำลองนี้ต้องทำการปรับปรุงเพื่อเพิ่มค่า Recall ของคลาส Falling Backward และ Precision ของคลาส Falling Left , Falling Right และ Walking



รูปที่ 4.10 แสดงตาราง Confusion Matrix ของ VGG Ver.2

สำหรับแบบจำลองที่ใช้เทคนิควิธีโครงข่ายประสาทเทียมแบบ VGG กับชุดข้อมูลเพิ่มการประมาณการทำทางด้วย MediaPipe ผลการทำนายของแต่ละคลาสแสดงดังรูปที่ 4.10 ดังนี้

Falling Backward (ล้มไปด้านหลัง) ทำนายถูกต้อง 1280 ตัวอย่าง ทำนายผิดจำนวน 362 ตัวอย่าง ส่วนใหญ่ทำนายผิดเป็น Falling Left จำนวน 204 ตัวอย่าง และ Falling Right จำนวน 86 ตัวอย่าง แบบจำลองยังมีการทำนายคลาดเคลื่อนระหว่าง Falling Backward กับ Falling Left อย่างชัดเจน

Falling Forward (ล้มไปด้านหน้า) ทำนายถูกต้อง 1280 ตัวอย่าง ทำนายผิดจำนวน 354 ตัวอย่าง ส่วนใหญ่ทำนายผิดเป็น Falling Backward จำนวน 140 ตัวอย่าง และ Falling Left จำนวน 115 ตัวอย่าง แบบจำลองมีทำนายผิดมากกว่าคลาสอื่นๆ

Falling Left (ล้มไปทางซ้าย) ทำนายถูกต้อง 1260 ตัวอย่าง ทำนายผิดจำนวน 38 ตัวอย่าง ส่วนใหญ่ทำนายผิดเป็นคลาส Walking จำนวน 23 ตัวอย่าง โดยภาพรวมแสดงว่าแบบจำลองสามารถทำนายคลาส Falling Left ได้ดีเยี่ยม

Falling Right (ล้มไปทางขวา) ทำนายถูกต้อง 1191 ตัวอย่าง ทำนายผิดจำนวน 393 ตัวอย่าง ส่วนใหญ่ทำนายผิดเป็น Falling Backward จำนวน 104 ตัวอย่าง และ Falling Left จำนวน 247 ตัวอย่าง แบบจำลองนี้การทำนายคลาดเคลื่อนจากคลาส Falling Right เป็น Falling Left มากที่สุด

Walking (การเดิน) ทำนายถูกต้อง 1319 ตัวอย่าง ทำนายผิดจำนวน 154 ตัวอย่าง จาก 154 ตัวอย่างที่ทำนายผิด ส่วนใหญ่ทำนายผิดเป็นคลาส Falling Left จำนวน 133 ตัวอย่าง

ตารางที่ 4.5 รายงานการจำแนกประเภท (Classification Report) ของ VGG Ver.2


Class	Precision	Recall	F1-Score	Support
Falling Backward	0.8274	0.7795	0.8028	1642
Falling Forward	0.9325	0.7744	0.8461	1569
Falling Left	0.6432	0.9707	0.7737	1298
Falling Right	0.8816	0.7519	0.8116	1584
Walking	0.9381	0.8955	0.9163	1473
Accuracy			0.8280	7566
Macro Avg	0.8445	0.8344	0.8301	7566
Weighted Avg	0.8505	0.8280	0.8307	7566

จากตารางที่ 4.5 จะเห็นว่าคลาส Falling Backward, Falling Forward, Falling Right และ Walking ค่า Precision มีค่าสูงกว่าค่า Recall แสดงว่าแบบจำลองมีการทำนายทั้ง 4 คลาสได้ดี แต่ค่า Recall ต่ำหมายความว่ามีความผิดพลาดที่ถูกต้องทำนายผิด คลาส Falling Left มีค่า Precision ต่ำที่สุดจากคลาสทั้งหมด หมายถึงแบบจำลองมีการทำนายผิดพลาดจากคลาสอื่นเป็น Falling Left มากที่สุด ส่วนคลาส Falling Backward ค่า Precision อยู่ในเกณฑ์ดี แต่ยังไม่สูงมาก ถ้าเจอข้อมูลใหม่ที่เป็นคลาส Falling Backward มีโอกาสทำนายผิดพลาดสูงกว่าคลาสอื่น ๆ คลาสที่โดดเด่น คือ คลาส Walking มีค่า Precision สูงถึง 93.81 % แบบจำลองสามารถทำนายคลาส Walking ได้อย่างแม่นยำ


4.2.3. กราฟ ROC และค่า AUC ของเทคนิควิธีโครงข่ายประสาทเทียมแบบ VGG

จากกราฟในรูปที่ 4.11 และ 4.12 จะเห็นว่าทุกคลาสอยู่เหนือเส้นประทั้งหมดและ ทุกคลาสมี AUC สูงมาก แบบจำลองมีประสิทธิภาพในการแยกแยะคลาสต่างๆ ดี แต่เมื่อนำแบบจำลองมาเปรียบเทียบกับ แบบจำลองที่ใช้เทคนิควิธีโครงข่ายประสาทเทียมแบบ VGG ของชุดข้อมูลวิดีโอ MediaPipe มีประสิทธิภาพดีน้อยกว่า แสดงรายละเอียดในตารางที่ 4.6

4.2.3 กราฟ ROC และค่า AUC ของ 2 เลเยอร์



รูปที่ 4.11 แสดงกราฟ ROC และค่า AUC ของ VGG Ver.1



รูปที่ 4.12 แสดงกราฟ ROC และค่า AUC ของ VGG Ver.2

ตารางที่ 4.6 แสดงการเปรียบเทียบของค่า AUC จากแบบจำลองทั้ง 2 ชุดข้อมูล (VGG)

Class	AUC ของ VGG Ver.1	AUC ของ VGG Ver.2	การเปรียบเทียบ
Falling Backward	0.9798	0.9658	ลดลงอย่างชัดเจน
Falling Forward	0.9841	0.9783	ลดลงอย่างชัดเจน
Falling Left	0.9862	0.9835	ลดลงเล็กน้อย
Falling Right	0.9860	0.9682	ลดลงอย่างชัดเจน
Walking	0.9986	0.9949	ลดลงเล็กน้อย

จากตารางที่ 4.6 แม้ทั้ง 2 แบบจำลองจะมีค่า AUC ที่ดีเยี่ยม ค่า AUC มากกว่า 0.96 ทุกคลาส แต่แบบจำลองโดยเทคนิควิธีโครงข่ายประสาทเทียมแบบ VGG ของชุดข้อมูลวีดีโอปกติแสดง


ผลลัพธ์ที่เสถียรและมีประสิทธิภาพในการแยกแยะที่ชัดเจนกว่ามาก มีแนวโน้มว่าแบบจำลองโดยเทคนิควิธีโครงข่ายประสาทเทียมแบบ VGG ของชุดข้อมูลวีดีโอเพิ่มการประมาณการทำทางด้วย MediaPipe จำแนกคลาส Falling Backward และ Falling Right ได้ดีกว่าแบบจำลองโดยเทคนิควิธีโครงข่ายประสาทเทียมแบบ VGG ของชุดข้อมูลวีดีโอปกติอย่างชัดเจน เนื่องจากค่า AUC ต่ำลงมากในทั้ง 2 คลาส สรุปได้ว่าแบบจำลองโดยเทคนิควิธีโครงข่ายประสาทเทียมแบบ VGG ของชุดข้อมูลวีดีโอปกติมีประสิทธิภาพสูงกว่าแบบจำลองโดยเทคนิควิธีโครงข่ายประสาทเทียมแบบ VGG ของชุดข้อมูลวีดีโอเพิ่มการประมาณการทำทางด้วย MediaPipe ในทุกคลาส

4.3 ผลการทดสอบประสิทธิภาพแบบจำลองโดยเทคนิควิธีโครงข่ายประสาทเทียมแบบ Resnet 50

แบบจำลองโดยเทคนิควิธีโครงข่ายประสาทเทียมแบบ Resnet 50 จะมีลักษณะของการทำการเรียนรู้แบบถ่ายโอนโดยใช้ Resnet 50 ซึ่งถูกเทรนล่วงหน้าจากชุดข้อมูลใหญ่ เช่น ImageNet เพื่อดึงคุณลักษณะพื้นฐานของภาพ ก่อนที่จะนำเวกเตอร์คุณลักษณะไปประมวลผลต่อด้วย Dense Layers ที่กำหนดขึ้นใหม่ เพื่อปรับแต่งการจำแนกประเภทให้ตรงกับชุดข้อมูลซึ่งมีทั้งหมด 5 ประเภท

4.3.1 Training Validation Loss และ Training Validation Accuracy ของ Resnet 50


ผลการฝึกแบบจำลองโดยเทคนิควิธีโครงข่ายประสาทเทียมแบบ Resnet 50 ของชุดข้อมูลวีดีโอปกติแสดงดังรูปที่ 4.13



รูปที่ 4.13 แสดงกราฟบน Loss (Train vs Validation) และกราฟล่าง Accuracy (Train vs Validation) ของ Resnet 50 Ver.1

จากรูปที่ 4.13 กราฟบนค่า Loss มีแนวโน้มลดลงต่อเนื่อง ทั้งชุด Train และ Validation แสดงว่าโมเดลกำลังเรียนรู้ได้ดี ในช่วง Epoch (0–5) ค่า Loss ของ Train และ Validation ลดลงพร้อมกันและใกล้เคียงกัน บ่งชี้ว่าแบบจำลองยังไม่ Overfit สำหรับช่วง Epoch 6–19 ค่า Loss ของ Validation ลดลงช้ากว่า Train เล็กน้อย โดยในช่วง Epoch 10–15 จะเห็นว่ามี การ "แกว่ง" (noise) แต่แนวโน้มโดยรวมของ Validation Loss ก็ยังลดลง ซึ่งเป็นสัญญาณที่ดี เนื่องจากไม่มีการเบี่ยงออก ระหว่าง Train และ Validation อย่างชัดเจน แบบจำลองยังไม่เกิด Overfitting

ในส่วนของค่า Accuracy ของทั้งชุด Train และ Validation เพิ่มขึ้นต่อเนื่อง แสดงว่าแบบจำลองสามารถเรียนรู้รูปแบบของข้อมูลได้ดีขึ้นเรื่อย ๆ ช่วง Epoch 0–3 Accuracy ของ Validation สูงกว่า Train เล็กน้อย บ่งบอกว่าแบบจำลองยังเรียนรู้ไม่ครบ แต่เริ่มมีแนวโน้มที่ดี ช่วง Epoch 4–10 จะเห็นว่า Accuracy ของ Train สูงกว่า Validation เล็กน้อย มีความแตกต่างเริ่มเกิดขึ้น แต่ไม่มากนัก แบบจำลองยังคงเรียนรู้ได้ดี และในช่วง Epoch 10–19 Accuracy ของ Train สูงกว่าชุด Validation อย่างสม่ำเสมอ แต่ต่างกันเล็กน้อย ประมาณ 0.03–0.05 แต่ Validation




รูปที่ 4.14 แสดงกราฟบน Loss (Train vs Validation) และกราฟล่าง Accuracy (Train vs Validation) ของ Resnet 50 Ver.2

Accuracy ยังเพิ่มขึ้นตลอด ไม่มีการลดลงอย่างรวดเร็ว แสดงว่า ไม่มี overfitting ชัดเจน สรุปแบบจำลองมีประสิทธิภาพและเรียนรู้ได้ดี สังเกตได้จากค่า Loss ที่ลดลง และค่า Accuracy ที่เพิ่มขึ้น สำหรับแบบจำลองโดยเทคนิควิธีโครงข่ายประสาทเทียมแบบ Resnet 50 ของชุดข้อมูลวีดีโอ เพิ่มการประมาณการทำทางด้วย MediaPipe ค่า Loss ของชุด Train และ Validation ลดลงต่อเนื่อง ตลอด 20 epoch แสดงในรูปที่ 4.14 กราฟบน ทั้งสองเส้นมีแนวโน้มลดลงแบบ เรียบและใกล้เคียงกันมาก ซึ่งบ่งบอกว่าแบบจำลองเรียนรู้ได้ดีและไม่มี Overfitting ไม่มีจุดที่ Validation Loss เพิ่มสูงแบบชัดเจน เป็นสัญญาณว่าแบบจำลองยังไม่เริ่มจำข้อมูลฝึกมากเกินไป ส่วนกราฟล่าง ค่า Accuracy ของทั้ง Train และ Validation เพิ่มขึ้นต่อเนื่อง และ เข้าใกล้กันมาก จนเกือบเท่ากัน ในช่วง Epoch 18–19 ความแตกต่างระหว่างกราฟ Train และ Validation Accuracy มีน้อยตลอด ช่วงการฝึก ค่า Accuracy สูงทำอยู่ประมาณ 76% – 77% ซึ่งถือว่า ค่อนข้างดี จากการวิเคราะห์ พบว่าแบบจำลองไม่มีอาการ Overfitting เพราะความแม่นยำของ Validation สูงเกือบเท่า Train และไม่มีอาการ Underfitting เพราะ Accuracy สูงขึ้นเรื่อย ๆ และไม่หยุดนิ่งเร็วเกินไป สรุปแบบจำลองมีประสิทธิภาพดี และเสถียร

4.3.2 Confusion Matrix ของ Resnet 50

ผลการทำนายของแบบจำลองโดยเทคนิควิธีโครงข่ายประสาทเทียมแบบ Resnet 50 ของชุดข้อมูลวีดีโอปกติแสดงในรูปที่ 4.15 มีรายละเอียดดังนี้



รูปที่ 4.15 แสดงตาราง Confusion Matrix ของ Resnet 50 Ver.1

Falling Backward (ล้มไปด้านหลัง) ทำนายถูกต้อง 1280 ตัวอย่าง และทำนายผิดเป็น คลาส Falling Left จำนวน 204 ตัวอย่าง และ คลาส Falling Right 101 รวมผิดทั้งหมด 362

ตัวอย่าง แบบจำลองมีแนวโน้มสับสนระหว่าง Falling Backward กับ Falling Left มากที่สุด สาเหตุอาจเกิดลักษณะท่าทางใกล้เคียงกันในมุมมองภาพ

Falling Forward (ล้มไปด้านหน้า) ทำนายถูกต้อง 1215 ตัวอย่าง และทำนายผิดเป็นคลาส Falling Backward จำนวน 140 ตัวอย่าง คลาส Falling Left จำนวน 115 ตัวอย่าง รวมผิดทั้งหมด 354 ตัวอย่าง แบบจำลองนี้สับสนระหว่างคลาส Falling Forward กับคลาส Falling Backward และคลาส Falling Left พอสมควร

Falling Left (ล้มไปทางซ้าย) ทำนายถูกต้อง 1260 ตัวอย่าง และทำนายผิดเป็นคลาส Falling Right จำนวน 9 ตัวอย่าง และคลาส Walking จำนวน 23 ตัวอย่าง สำหรับคลาสนี้แบบจำลองมีความสามารถแยกคลาส Falling Left ได้ดีมาก

Falling Right (ล้มไปทางขวา) ทำนายถูกต้อง 1191 ตัวอย่าง และทำนายผิดเป็นคลาส Falling Left จำนวน 247 ตัวอย่าง ซึ่งเป็นการทำนายผิดพลาดที่สูงที่สุดของคลาสนี้ มีแนวโน้มถูกทำนายผิดเป็นฝั่งซ้าย สะท้อนว่าแบบจำลองมีปัญหาแยกท่าล้มซ้าย-ขวา อาจเกิดจากลักษณะภาพที่คล้ายกัน


Walking (การเดิน) ทำนายถูกต้อง 1319 ตัวอย่าง และทำนายผิดเป็นคลาส Falling Left มากที่สุด จำนวน 133 ตัวอย่าง โดยรวมคลาส Walking แบบจำลองสามารถแยกได้ดี แต่ยังมีบางส่วนทำนายผิดเป็น Falling Left อาจเกิดจากภาพที่มีลักษณะเดินผิดปกติ หรือช่วง transition

ตารางที่ 4.7 รายงานการจำแนกประเภท (Classification Report) ของ Resnet 50 Ver.1

Class	Precision	Recall	F1-Score	Support
Falling Backward	0.8721	0.5773	0.6948	1642
Falling Forward	0.9450	0.6354	0.7599	1569
Falling Left	0.7259	0.8344	0.7763	1298
Falling Right	0.6366	0.9078	0.7484	1584
Walking	0.8243	0.9362	0.8767	1473
Accuracy			0.7725	7566
Macro Avg	0.8008	0.7782	0.7712	7566
Weighted Avg	0.8035	0.7725	0.7689	7566

จากตารางที่ 4.7 แบบจำลองทำนายได้ถูกต้องประมาณ 77.25% ของตัวอย่างทั้งหมด คลาส Falling Backward และ Falling Forward มีค่า Precision สูง แต่ Recall ต่ำมาก แบบจำลองทำนายทำนาย 2 คลาสนี้ได้แม่นยำ แต่ยังไม่ครอบคลุม เนื่องจากมีการทำนายพลาดเป็นคลาสอื่น ๆ ส่วนในคลาส Falling Left และ Falling Right สังเกตได้ว่ามีค่า Recall สูง บ่งบอกแบบจำลองสามารถจำแนก 2 คลาสนี้ได้อย่างครบถ้วน แต่มีค่า Precision ต่ำ ส่วนคลาส Walking แบบจำลองสามารถทำนายคลาสนี้ได้ดีที่สุด สังเกตได้จากค่า Precision, Recall และ F1-Score ที่สูง สรุปแบบจำลองสามารถจำแนกคลาส Walking ได้ดีเยี่ยม ต้องปรับปรุงในคลาส Falling Backward เนื่องจากแบบจำลองพลาดหลายเหตุการณ์ที่ควรตรวจจับได้ และคลาส Falling Right แบบจำลองมีแนวโน้มทำนายว่าเป็น Falling Right มากเกินไป ส่งผลให้มีค่า Precision ต่ำ

สำหรับชุดข้อมูลวิดีโอเพิ่มการประมาณการทำทางด้วย MediaPipe แสดงผลการทำนายของแบบจำลองในรูปที่ 4.16 มีรายละเอียดดังนี้



รูปที่ 4.16 แสดงตาราง Confusion Matrix ของ Resnet 50 Ver.2

Falling Backward (ล้มไปด้านหลัง) ทำนายถูกต้อง 975 ตัวอย่าง และทำนายผิดเป็นคลาส Falling Forward จำนวน 194 ตัวอย่าง คลาส Falling Right จำนวน 251 ตัวอย่าง รวมถึงคลาส Falling Left และคลาส Walking จำนวนคลาสนละ 111 ตัวอย่าง รวมผิดทั้งหมด 667 ตัวอย่าง แบบจำลองมีแนวโน้มสับสนระหว่าง Falling Right กับ Falling Forward มากที่สุด สาเหตุอาจเกิดลักษณะภาพหรือมุมมองอาจคล้ายกันในคลาสนเหล่านี้

Falling Forward (ล้มไปด้านหน้า) ทำนายถูกต้อง 1142 ตัวอย่าง และทำนายผิดเป็นคลาส Falling Backward จำนวน 80 ตัวอย่าง คลาส Falling Left จำนวน 66 ตัวอย่าง และคลาส Falling Right จำนวน 255 ตัวอย่าง รวมผิดทั้งหมด 427 ตัวอย่าง แบบจำลองนี้สับสนกับ Falling Right อย่างมีนัย คลาสนี้อาจมีท่าทางทิศทางการล้มที่แบบจำลองแยกยาก

Falling Left (ล้มไปทางซ้าย) ทำนายถูกต้อง 950 ตัวอย่าง มีการทำนายผิดเป็นคลาส Walking จำนวน 109 ตัวอย่าง ซึ่งสูงผิดปกติเมื่อเทียบกับคลาสนอื่น ๆ

Falling Right (ล้มไปทางขวา) ทำนายถูกต้อง 1329 ตัวอย่าง และทำนายผิดเป็นคลาส Falling Left จำนวน 122 ตัวอย่าง คลาส Falling Forward จำนวน 67 ตัวอย่าง และคลาส Falling Backward จำนวน 45 ตัวอย่าง คลาสนี้เป็นคลาสนที่แบบจำลองแยกได้ดีที่สุด

Walking (การเดิน) ทำนายถูกต้อง 1307 ตัวอย่าง และทำนายผิดเป็นคลาส Falling Forward จำนวน 92 ตัวอย่าง และทำนายผิดเป็นคลาส Falling Left จำนวน 69 ตัวอย่าง โดยรวม


คลาส Walking แบบจำลองสามารถแยกได้ดี แต่แบบจำลองอาจตีความการ "เดินเร็ว" หรือ "เดินผิดปกติ" ว่าเป็นการล้ม

ตารางที่ 4.8 รายงานการจำแนกประเภท (Classification Report) ของ Resnet 50 Ver.2


Class	Precision	Recall	F1-Score	Support
Falling Backward	0.8583	0.5938	0.7019	1642
Falling Forward	0.7133	0.7279	0.7205	1569
Falling Left	0.7208	0.7319	0.7263	1298
Falling Right	0.6861	0.8390	0.7549	1584
Walking	0.8304	0.8873	0.8579	1473
Accuracy			0.7538	7566
Macro Avg	0.7618	0.7560	0.7523	7566
Weighted Avg	0.7631	0.7538	0.7514	7566

จากตารางที่ 4.8 คลาส Falling Forward , Falling Left และ Walking มีความสมดุลทั้งค่า Precision, Recall และ F1- score บ่งบอกว่าแบบจำลองมีความสามารถในการจำแนกได้อย่างแม่นยำและครอบคลุม แม้ Falling Forward และ Falling Left จะมีค่าอยู่ในระดับปานกลาง ส่วนคลาส Falling Backward มีค่า Precision ค่อนข้างสูง แต่ค่า Recall ต่ำมาก แบบจำลองมีการทำนายคลาสนี้ผิดพลาดเยอะ คลาส Falling Right มีค่า Precision ต่ำ แต่ค่า Recall สูง แบบจำลองตรวจจับกรณีล้มทางขวาได้เกือบครบ แต่แบบจำลองมักทำนายว่าเป็น Falling Right แม้ไม่ใช่ ส่งผลให้ Precision ต่ำ สรุปคลาส Walking ยังเป็นคลาสที่แบบจำลองสามารถจำแนกได้ดีที่สุดในขณะที่คลาส Falling Backward ต้องมีการปรับปรุงเพื่อเพิ่มค่า Recall ส่วน Falling Forward และ Falling Left มีความสมดุลระหว่างค่า Precision และ Recall แต่อยู่ในระดับปานกลาง ยังต้องมีการปรับปรุงเพื่อเพิ่มค่า Precision และ Recall

4.3.3 กราฟ ROC และค่า AUC ของ Resnet 50



รูปที่ 4.17 แสดงกราฟ ROC และค่า AUC ของ Resnet 50 Ver.1



รูปที่ 4.18 แสดงกราฟ ROC และค่า AUC ของ Resnet 50 Ver.2

จากกราฟในรูปที่ 4.17 กราฟแสดงว่าแบบจำลองโดยเทคนิควิธีโครงข่ายประสาทเทียมแบบ Resnet 50 ของชุดข้อมูลวีดีโอปกติ มีความสามารถในการจำแนกคลาสได้ดีเยี่ยม โดยทุกเส้น ROC โค้งชันขึ้นไปทางมุมซ้ายบนของกราฟ ซึ่งหมายถึงค่า TPR (True Positive Rate) สูงมาก ในขณะที่ FPR (False Positive Rate) ต่ำตลอดการจำแนก โดยเฉพาะคลาส Walking ที่ได้ AUC สูงสุดถึง 0.9897 แสดงว่าโมเดลสามารถจำแนก "การเดิน" ได้แม่นยำเกือบสมบูรณ์แบบ นอกจากนี้ Falling Forward (0.9630), Falling Left (0.9689), และ Falling Right (0.9579) อยู่ในระดับ AUC สูงมาก

(>0.95) ซึ่งบ่งชี้ว่าแบบจำลองสามารถแยกแยะท่าทางการล้มแต่ละทิศทางได้อย่างมีประสิทธิภาพ ส่วน Falling Backward ได้ AUC = 0.9395 ซึ่งยังถือว่าสูงและดีมาก แต่ต่ำที่สุดในชุดนี้ อาจสะท้อนว่าแบบจำลองยังมีข้อจำกัดบางประการในการแยกกรณีล้มไปด้านหลัง ส่วนภาพที่ 4.18 กราฟแสดงว่าแบบจำลองโดยเทคนิควิธีโครงข่ายประสาทเทียมแบบ Resnet 50 ของชุดข้อมูลวีดีโอเพิ่มการประมวลผลท่าทางด้วย MediaPipe กราฟ ROC แต่ละเส้นยังไม่โค้งไปทางซ้ายบนมากนักเมื่อเทียบกับชุดข้อมูลปกติ โดยค่า AUC ส่วนใหญ่จะต่ำกว่าทุกคลาส ตัวอย่างเช่น Falling Forward ได้เพียง 0.9313, ซึ่งต่ำกว่าแบบจำลองจากชุดข้อมูลปกติ ที่ได้ 0.9630 อย่างชัดเจน ส่วน Falling Left ได้ AUC เท่ากับ 0.9395 และ Falling Right อยู่ที่ 0.9512 ซึ่งแม้จะดูดีแต่ก็ยังต่ำกว่าแบบจำลองจากชุดข้อมูลปกติ คลาสที่แบบจำลองทำได้ดีที่สุที่สุดคือ Walking ที่ได้ AUC = 0.9839 ซึ่งยังสูงมากแต่น้อยกว่าแบบจำลองจากชุดข้อมูลปกติ นอกจากนี้คลาส Falling Backward ที่ได้ AUC = 0.9387 มีพฤติกรรมใกล้เคียงกันทั้งสองชุดข้อมูล แต่โดยรวมแล้ว ROC Curve ในแบบจำลองนี้ยังแสดงให้เห็นว่ามีการทำนายผิดมากกว่า โดยเฉพาะในช่วงค่า False Positive Rate ที่ยังไม่ต่ำเท่าที่ควร ตารางที่ 4.9 แสดงการเปรียบเทียบของค่า AUC จากแบบจำลองทั้ง 2 ชุดข้อมูล (Resnet 50)

Class	AUC ของ Resnet 50 Ver.1	AUC ของ Resnet 50 Ver.2	การเปรียบเทียบ
Falling Backward	0.9395	0.9387	ลดลงเล็กน้อย
Falling Forward	0.9630	0.9313	ลดลงอย่างชัดเจน
Falling Left	0.9689	0.9395	ลดลงอย่างชัดเจน
Falling Right	0.9579	0.9512	ลดลงเล็กน้อย
Walking	0.9897	0.9839	ลดลงเล็กน้อย

โดยสรุปจากตารางที่ 4.9 แล้ว แบบจำลองจากชุดข้อมูลปกติแสดงให้เห็นถึงประสิทธิภาพที่สูงกว่าในทุกคลาส เมื่อพิจารณาจากค่า AUC ทั้งในเชิงตัวเลขและในเชิงลักษณะกราฟเส้น ROC ที่แนบชิดกับมุมซ้ายบนมากกว่าอย่างชัดเจน การจำแนกประเภทที่โดดเด่นของแบบจำลองจากชุดข้อมูลปกติคือ คลาส Falling Forward และ Falling Left ซึ่งมีค่ามากกว่าแบบจำลองจากข้อมูล MediaPipe สะท้อนว่า แบบจำลองจากชุดข้อมูลปกติ มีความสามารถในการแยกแยะพฤติกรรมที่มี

ความซับซ้อนหรือมีลักษณะใกล้เคียงกันได้ดีขึ้น จึงเหมาะสำหรับใช้งานในระบบตรวจจับพฤติกรรม การล้มที่ต้องการความแม่นยำสูง

4.4 วิจัยและอภิปรายผลการวิจัย

แบบจำลองโดยเทคนิควิธีโครงข่ายประสาทเทียมแบบ 2 เลเยอร์ของชุดข้อมูลวิดีโอปกติมีค่าความแม่นยำ (Accuracy) เท่ากับ 88.30% ซึ่งอยู่ในระดับที่ดี อย่างไรก็ตาม เมื่อพิจารณาค่า Recall ในคลาส Falling Right พบว่ามีค่าต่ำเพียง 0.6806 สะท้อนว่าแบบจำลองมีแนวโน้มที่จะตรวจจับการล้มในทิศทางนี้ได้ไม่ครอบคลุม แม้ว่าค่าความแม่นยำในคลาสอื่น เช่น Walking จะอยู่ในระดับสูง (F1-score = 0.9835) ก็ตาม กราฟแสดงการฝึกของแบบจำลองแสดงให้เห็นว่า Accuracy ของชุดฝึกและชุดทดสอบเริ่มห่างกันมากขึ้น และ Validation Loss มีความผันผวน สะท้อนความเป็นไปได้ของการเกิด Overfitting ในช่วงหลังของการฝึก ทำให้แม้ผลรวมจะดูดี แต่เสถียรภาพของโมเดลยังไม่เหมาะกับการใช้งานจริง

แบบจำลองโดยเทคนิควิธีโครงข่ายประสาทเทียมแบบ 2 เลเยอร์ของชุดข้อมูลวิดีโอเพิ่มการประมวลผลทางด้วย MediaPipe เป็นแบบจำลองที่ให้ผลลัพธ์ที่ดีที่สุดในบรรดาทุกแบบจำลอง โดยมี Accuracy สูงถึง 90.62% และมีค่า F1-score รายคลาสสูงกว่า 0.90 ในเกือบทุกคลาส ไม่ว่าจะเป็น Falling Forward (0.9178), Falling Right (0.9089) และ Walking (0.9263) ซึ่งแสดงถึงความสมดุลและความครอบคลุมในการจำแนกพฤติกรรมแบบต่าง ๆ ได้อย่างแม่นยำ กราฟของแบบจำลองนี้ยังแสดงให้เห็นว่า Train และ Validation Accuracy มีแนวโน้มใกล้เคียงกันอย่างต่อเนื่อง และไม่มีอาการ Overfitting โดย Validation Loss ลดลงอย่างมั่นคง สะท้อนว่าแบบจำลองสามารถเรียนรู้ได้อย่างมีประสิทธิภาพและ generalize ได้ดีกับข้อมูลใหม่ จึงถือว่าเป็นแบบจำลองที่เหมาะสมที่สุดสำหรับการประยุกต์ใช้งานจริง

แบบจำลองโดยเทคนิควิธีโครงข่ายประสาทเทียมแบบ VGG ของชุดข้อมูลวิดีโอปกติมีค่า Accuracy อยู่ที่ 88.91% โดยค่าความแม่นยำในคลาส Falling Backward มีค่า Precision สูงถึง 0.9722 แต่มี Recall ต่ำเพียง 0.7247 แสดงว่าแบบจำลองสามารถทำนายได้แม่นยำเมื่อทำนายถูกต้อง แต่ยังพลาดการตรวจจับบางกรณี กราฟของแบบจำลองนี้แสดงการลดลงของ Loss อย่างต่อเนื่อง และความใกล้เคียงระหว่าง Train และ Validation Accuracy จึงไม่มีอาการ Overfitting

อย่างเด่นชัด อย่างไรก็ตาม การมี Recall ต่ำในบางคลาสโดยเฉพาะคลาสการล้ม อาจเป็นข้อจำกัดในการนำไปใช้จริงที่ต้องการความไวต่อเหตุการณ์ผิดปกติ

แบบจำลองโดยเทคนิควิธีโครงข่ายประสาทเทียมแบบ VGG เลเยอร์ของชุดข้อมูลวีดีโอเพิ่มการประมาณการทำทางด้วย MediaPipe ให้ค่า Accuracy เท่ากับ 82.80% แม้จะมีจุดเด่นในคลาส Falling Left ที่มีค่า Recall สูงถึง 0.9707 แต่กลับมีค่า Precision ต่ำในคลาสเดียวกัน (0.6432) สะท้อนถึงแนวโน้มในการเกิด false positive หรือการแจ้งเตือนผิดพลาดได้บ่อย กราฟแสดงการเรียนรู้ของแบบจำลองนี้ค่อนข้างนิ่ง ทั้งในด้านของ Loss และ Accuracy แต่ Validation Accuracy ต่ำกว่าชุดฝึกค่อนข้างชัดเจน ทำให้มีความเสี่ยงของ Overfitting ในระดับหนึ่ง แม้ว่าเสถียรภาพของกราฟจะดี แต่เมื่อพิจารณาพร้อมกับประสิทธิภาพรายคลาสที่ไม่สมดุล จึงทำให้แบบจำลองนี้ยังไม่เหมาะกับการใช้งานจริง

แบบจำลองโดยเทคนิควิธีโครงข่ายประสาทเทียมแบบ Resnet50 ของชุดข้อมูลวีดีโอปกติมี Accuracy อยู่ที่ 77.25% โดยสามารถให้ผลดีในคลาส Falling Right (Recall = 0.9078) และ Walking (Recall = 0.9362) แต่ในคลาส Falling Forward และ Falling Backward ซึ่งเป็นคลาสสำคัญของการล้ม กลับมี Recall ต่ำกว่า 0.65 ซึ่งทำให้มีโอกาสพลาดเหตุการณ์สำคัญได้ง่าย กราฟการเรียนรู้ของแบบจำลองแสดงความเสถียรในเชิงเทคนิค โดยมีแนวโน้มของ Train และ Validation Loss ลดลงพร้อมกัน แต่ด้วยความแม่นยำโดยรวมที่ไม่สูงและความไม่สมดุลของประสิทธิภาพรายคลาส จึงไม่เหมาะสำหรับการใช้งานที่ต้องการความถูกต้องในทุกสถานการณ์

แบบจำลองโดยเทคนิควิธีโครงข่ายประสาทเทียมแบบ Resnet50 ของชุดข้อมูลวีดีโอเพิ่มการประมาณการทำทางด้วย MediaPipe ให้ค่า Accuracy ต่ำที่สุดเพียง 75.38% โดยมีประสิทธิภาพในคลาสการล้มทุกคลาสอยู่ในระดับต่ำ โดยเฉพาะ Falling Backward และ Falling Forward ที่มี F1-score ต่ำกว่า 0.75 กราฟการฝึกของแบบจำลองนี้ยังแสดงให้เห็นว่า ทั้ง Train และ Validation Accuracy มีค่าไม่สูง และค่า Loss ไม่มีแนวโน้มลดลงอย่างเด่นชัด แสดงว่าแบบจำลองอาจเรียนรู้ไม่เพียงพอหรือมีข้อจำกัดทางโครงสร้าง ส่งผลให้ไม่เหมาะกับการใช้งานจริงในระบบตรวจจับการล้มที่ต้องการความแม่นยำและความเสถียรในระดับสูง

4.5 ผลการทดสอบแบบจำลองกับข้อมูลนอกขอบเขตการฝึกสอนแบบจำลอง

จากการศึกษาแบบจำลองโดยเทคนิควิธีโครงข่ายประสาทเทียม เพื่อจำแนกการล้ม 4 แบบและการเดิน ต่อมาได้นำแบบจำลองทั้ง 6 แบบ มาทดสอบกับข้อมูลนอกช่วงของแบบจำลอง ซึ่งเป็นข้อมูลวิดีโอที่แบบจำลอง ยังไม่เคยเรียนรู้มาจำนวน 5 วิดีโอ ได้ผลการทดสอบดังตารางที่ 4.10

ตารางที่ 4.10 แสดงผลการทำนายของแบบจำลองทั้ง 6 แบบกับข้อมูลนอกขอบเขตการฝึกสอน

ชื่อวิดีโอ	จำนวนเฟรมทั้งหมด	จำนวนเฟรมที่ทำนายถูกคิดเป็นร้อยละ					
		2-layer Ver.1	2-layer Ver.2	VGG Ver.1	VGG Ver.2	Resnet50 Ver.1	Resnet50 Ver.2
Video_1	119	78.99	93.28	0.00	0.00	7.56	15.13
Video_2	122	45.08	19.33	15.97	14.29	63.87	63.87
Video_3	123	0.81	24.39	56.91	30.08	16.26	18.70
Video_4	365	0.00	0.00	9.59	0.00	89.32	89.32
Video_5	180	65.56	9.44	5.00	3.89	0.00	0.00
Video_6	450	42.00	4.00	24.89	20.67	29.78	44.22
Video_7	692	35.26	9.97	35.26	33.09	35.26	35.26
ค่าเฉลี่ยความถูกต้อง		38.24	22.92	21.09	14.57	34.58	38.07
ส่วนเบี่ยงเบนมาตรฐาน		29.83	32.14	19.83	13.90	31.99	30.79

จากตารางแสดงผลการทำนายของแบบจำลองทั้ง 6 แบบ ได้แก่ 2-layer Ver.1, 2-layer Ver.2, VGG Ver.1, VGG Ver.2, ResNet50 Ver.1 และ ResNet50 Ver.2 พบว่าแบบจำลองที่ให้ค่าความถูกต้องเฉลี่ยสูงที่สุดคือ 2-layer Ver.1 และ ResNet50 Ver.2 โดยมีค่าความถูกต้องเฉลี่ยเท่ากับ 38.24% และ 38.07% ตามลำดับ ซึ่งแสดงถึงความสามารถของแบบจำลองดังกล่าวในการจำแนกพฤติกรรมในวิดีโอได้ดีกว่าแบบจำลองอื่น ๆ ในชุดข้อมูลที่ใช้ทดลอง

ในขณะที่แบบจำลอง VGG Ver.2 แม้จะมีค่าความถูกต้องเฉลี่ยต่ำที่สุดที่ 14.57% แต่กลับมีส่วนเบี่ยงเบนมาตรฐานต่ำที่สุดที่ 13.90% ซึ่งบ่งชี้ว่าแบบจำลองมีความเสถียรในการทำนาย กล่าวคือประสิทธิภาพของแบบจำลองในแต่ละวิดีโอมีความแปรปรวนน้อย ต่างจาก 2-layer Ver.2 และ ResNet50 Ver.1 ที่มีส่วนเบี่ยงเบนมาตรฐานสูงถึง 32.14% และ 31.99% ตามลำดับ แสดงให้เห็นถึงความไม่สม่ำเสมอในการทำนายของแบบจำลองเหล่านี้ในบริบทของวิดีโอที่หลากหลาย

เมื่อพิจารณาแบบจำลองในภาพรวม ในชุดข้อมูลที่นำมาทดสอบ Video_1 ถึง Video_5 เป็นวิดีโอที่แสดงการล้มอย่างชัดเจน โดยแบบจำลอง 2-layer Ver.1 ทำนายได้ค่อนข้างแม่นยำ ในขณะที่ Video_6 และ Video_7 แสดงการนั่งจากนั้นล้มตัวลงนอน ซึ่งมีความใกล้เคียงกับการล้ม ด้วยแบบจำลองที่ถูกฝึกฝนมาให้แยกประเภทประเภทการล้มและการเดิน ทำให้แบบจำลองเรียนรู้การนั่งแล้วเอนตัวลงนอนเป็นการล้ม ซึ่งมีผลต่อการส่งการแจ้งเตือนทำให้เกิดความคลาดเคลื่อน และเกิดการแจ้งเตือนตลอดเวลา ถึงอย่างไรก็ตามใน Video_6 และ Video_7 แบบจำลอง Resnet50 Ver.2 มีการแยกแยะได้ดีกว่าเล็กน้อย แสดงถึงการพัฒนาโมเดลที่สามารถเพิ่มประสิทธิภาพได้อย่างมีนัยสำคัญ ส่วนแบบจำลอง VGG แม้จะมีประสิทธิภาพต่ำกว่าในด้านความแม่นยำ แต่ยังคงแสดงความสม่ำเสมอที่น่าสนใจในบางวิดีโอ เช่น Video_3 และ Video_7

จากผลการวิเคราะห์นี้สามารถสรุปได้ว่า แบบจำลอง 2-layer Ver.1 และ ResNet50 Ver.2 มีแนวโน้มที่เหมาะสมต่อการนำไปใช้งานจริงมากกว่าแบบจำลองอื่นในแง่ของความแม่นยำโดยรวม แต่หากพิจารณาร่วมกับค่าเบี่ยงเบนมาตรฐานด้วย จะพบว่าแบบจำลองทั้งหมดยังมีแนวโน้มการทำนายที่ไม่คงที่มากพอ จึงควรมีการพัฒนาเพิ่มเติม เช่น การเพิ่มข้อมูลฝึกสอน การเพิ่มข้อมูลเทียม การเพิ่มประเภทการจำแนกหรือการใช้เทคนิคการรวมแบบจำลองเพื่อรวมความสามารถของโมเดลหลายแบบเข้าด้วยกันในการประยุกต์ใช้งานแบบเรียลไทม์ต่อไป