

GOLF TRACER — คู่มือการเทรนโมเดลตรวจจับ

คู่มือการเทรนและเตรียมข้อมูล สำหรับทีมพัฒนา AI

ชุดข้อมูล 2 คลาส (club, golf_ball) · ที่มา สถานะ วิธีเทรน และกับดักที่เคยทำ
พลาดจริง

จัดทำโดยทีมพัฒนา Golf Tracer

YOLO (Ultralytics 8.4.106) · PyTorch 2.13.0 · ONNX opset 12 · imsz 960

ชุดข้อมูลต้นทาง: labelhub บนเครื่อง go-ai · สร้างด้วย build_dataset.py จาก labelhub.db

31 ก.ค. 2569 · v1.0 · ตัวเลขทุกตัวในเอกสารนี้วัดจากข้อมูลจริง ณ วันที่จัดทำ

บทคัดย่อ.

เอกสารนี้เป็นคู่มือส่งมอบงานเทรนโมเดลตรวจจับของ Golf Tracer ให้ทีมพัฒนา AI ทำต่อได้ด้วยตัวเอง ประกอบด้วยสี่ส่วน คือ (1) ของที่ส่งมอบและวิธีตรวจว่าครบจริง (2) ที่มาและตัวเลขจริงของชุดข้อมูล รวมถึงกติกการแบ่ง train/val/test ที่ต้องรักษาไว้ (3) ขั้นตอนการเทรนพร้อมคำสั่งที่ใช้ได้ทันที และตัวเลขพื้นฐานที่ต้องเอาชนะ (4) กับดักที่โครงการนี้เคยเสียเวลาไปกับมันจริง ๆ พร้อมวิธีเลี่ยง ข้อสรุปสำคัญสามข้อ ข้อแรก ชุดข้อมูลที่ส่งมอบผ่านการตรวจครบทุกข้อแล้ว 8,224 ภาพ ป้ายกำกับตรงกันหนึ่งต่อหนึ่ง และจำนวนกล่องตรงกับใบสรุปที่เครื่องมือสร้างชุดข้อมูลเขียนไว้ ข้อสอง ตัวเลขที่ต้องเอาชนะไม่ใช่ mAP แต่เป็น recall ของลูกกอล์ฟ ซึ่งปัจจุบันอยู่ที่ 0.665 ต่ำกว่าของหัวไม้ที่ 0.819 อย่างเห็นได้ชัด เพราะลูกที่โมเดลมองไม่เห็นคือรอยขาดของเส้นวิถี ข้อสาม มีกับดักหนึ่งที่พร้อมทำให้เสียเวลาเทรนทั้งชั่วโมงโดยไม่รู้ตัว คือคำสั่งต้นของ train.py ชี้ไปที่ไฟล์กำหนดชุดข้อมูลที่มีคลาสเดียว รายละเอียดอยู่ในหัวข้อที่ 6 และต้องอ่านก่อนเทรนครั้งแรก

คำสำคัญ — *object detection, YOLO, dataset preparation, train/val split, golf ball tracking*

สารบัญ

- 1 ของที่ส่งมอบ และวิธีตรวจว่าครบ
- 2 ชุดข้อมูล: ตัวเลขจริง
- 3 กติกการแบ่ง train / val / test ที่ต้องรักษาไว้
- 4 สถานะการ label ปัจจุบัน
- 5 โมเดลพื้นฐาน และตัวเลขที่ต้องเอาชนะ
- 6 ขั้นตอนการเทรน
- 7 การตรวจผลหลังเทรน
- 8 กับดักที่โครงการนี้เคยเสียเวลาไปกับมันจริง
- 9 การสร้างชุดข้อมูลใหม่
- 10 ข้อจำกัดของเอกสารและงานที่ยังไม่ได้ทำ

1. ของที่ส่งมอบ และวิธีตรวจว่าครบ

ทั้งหมดอยู่ที่ ~/Desktop/golf-tracer-training บนเครื่องนี้ ขนาดรวมประมาณ 3.3 กิกะไบต์ ไฟล์ภาพเป็นไฟล์จริงทั้งหมด ไม่ใช่ทางลัด (symlink) ประเด็นนี้สำคัญกว่าที่เห็น เพราะชุด

ข้อมูลฉบับบนเครื่อง go-ai เก็บภาพเป็นทางลัดชี้กลับไปโฟลเดอร์ labelhub/data/frames การคัดลอกแบบธรรมดาจะได้ทางลัดที่ชี้ไปที่ที่ไม่มีอยู่บนเครื่องนี้ 8,224 อัน และความผิดพลาดแบบนั้นจะไม่แสดงตัวตอนคัดลอก แต่จะแสดงตอนเทรนไปแล้ว การส่งมอบครั้งนี้จึงฉายทางลัดทุกอันให้เป็นไฟล์จริง และตรวจยืนยันว่าไม่มีทางลัดเหลืออยู่เลย

ตำแหน่ง	เนื้อหา	ขนาด
dataset/	ภาพและป้ายกำกับ 3 ชุด (train, val, test) พร้อม data.yaml และ summary.json	3.2 GB
models/yolo_birdiex_2c_1.pt	โมเดลพื้นฐานที่ใช้เป็นจุดเริ่มการ fine-tune และเป็นตัวเปรียบเทียบ (md5 a2eee2f...)	18 MB
models/yolo_birdiex_2c_20260728-004149.*	โมเดลที่เทรนล่าสุด ทั้ง .pt, .onnx และไฟล์ ตัวเลขผล .json	54 MB
labelhub/labelhub.db	ฐานข้อมูลการ label ใช้ตรวจสอบว่ากล่องแต่ละ กล่องใครวาด เมื่อไร และสร้างชุดข้อมูลใหม่ได้	2.1 MB
scripts/	เครื่องมือทั้งหมด: ตรวจสอบชุดข้อมูล, เทรน, สร้าง ชุดข้อมูลใหม่, ประเมินผลหลังเทรน	40 KB
docs/	เอกสารฉบับนี้	—

ตารางที่ 1 โครงสร้างของสิ่งที่ส่งมอบ

ก่อนเทรนทุกครั้ง ให้รัน `python3 scripts/verify_dataset.py` คำสั่งนี้ตรวจเช็คเรื่องที่เคยผิดพลาดมาแล้วจริงในโครงการนี้ และจะคืนค่าไม่เป็นศูนย์ถ้ามีข้อใดไม่ผ่าน ใช้เวลาไม่ถึงนาที ขณะที่ทางเลือกอีกทางคือรู้ตัวหลังเทรนไปหนึ่งชั่วโมง

2. ชุดข้อมูล: ตัวเลขจริง

ชุดข้อมูลนี้ชื่อ clean สร้างขึ้นโดยอ่านจากฐานข้อมูลการ label โดยตรง ไม่ได้อ่านจากไฟล์ที่ส่งออกไปก่อนหน้านี้ เหตุผลของการออกแบบเช่นนี้อยู่ในหัวข้อที่ 9 ซึ่งเป็นบทเรียนจากความผิดพลาดจริง สองคลาสคือ 0 = club (หัวไม้) และ 1 = golf_ball (ลูกกอล์ฟ) ลำดับนี้เปลี่ยนไม่ได้ เพราะเป็นลำดับเดียวกับที่โมเดลที่ใช้งานอยู่คาดหวัง คอลัมน์สุดท้าย "ลูกช่วงลอย" คือจำนวนกล่องลูกกอล์ฟที่อยู่ในเฟรมหลังจังหวะอิมแพกต์ของคลิปกั้น เป็นตัวเลขที่เครื่องมือสร้าง

ชุดข้อมูลนับเอาไว้อเอง ไม่ใช่ตัวเลขที่คำนวณย้อนหลังจากไฟล์ป้ายกำกับ เพราะการนับต้องรู้เฟรมอิมแพกต์ของแต่ละคลิปซึ่งอยู่ในฐานข้อมูล ความสำคัญของมันคือใช้เป็นเกณฑ์ว่าชุด val และ test วัด recall ของลูกได้จริงหรือไม่


ชุด	ภาพ	ป้ายกำกับ	กล่อง club	กล่อง golf_ball	ลูกช่วงลอย
train	6,727	6,727	4,717	3,629	627
val	791	791	490	525	120
test	706	706	91	283	219
รวม	8,224	8,224	5,298	4,437	966

ตารางที่ 2 จำนวนภาพและกล่องต่อชุด ตรวจสอบยืนยันแล้วตรงกับ summary.json ที่เครื่องมือสร้างชุดข้อมูลเขียนไว้

เกณฑ์ที่เครื่องมือบังคับไว้: ชุด val และ test ต้องมีกล่องลูกกอล์ฟอย่างน้อย 60 กล่อง ถ้าน้อยกว่านั้น เครื่องมือจะปฏิเสธการสร้างชุดข้อมูล เพราะ recall ของลูกคือตัวเลขเดียวที่บอกว่าเส้นวิถีจะขาดหรือไม่ และวัดมันไม่ได้ถ้าชุดประเมินไม่มีลูก ปัจจุบัน val มี 525 กล่อง และ test มี 283 กล่อง ผ่านเกณฑ์ทั้งคู่

3. กติกาการแบ่ง train / val / test ที่ต้องรักษาไว้

การแบ่งชุดข้อมูลนี้ไม่ได้สุ่มเป็นภาพ ๆ แต่สุ่มเป็นคลิป และนี่คือจุดที่พลาดง่ายที่สุดในงานลักษณะนี้ เฟรมที่อยู่ติดกันในคลิปเดียวกันแทบจะเหมือนกัน ถ้าแบ่งแบบสุ่มรายภาพ เฟรมที่ 100 อาจไปอยู่ชุด train ขณะที่เฟรมที่ 101 ไปอยู่ชุด val ผลที่ได้คือตัวเลข val สวยงามแต่ไม่มี ความหมาย เพราะมันวัดการจำ ไม่ใช่การรู้จำแนก เครื่องมือจึงคำนวณค่าแฮชจากชื่อคลิป แล้วส่งทุกเฟรมของคลิปก้นไปอยู่ฝั่งเดียวกันทั้งหมด และเพราะเป็นการแฮชแบบคงที่ การรันซ้ำจะได้การแบ่งเดิมทุกครั้ง สำหรับข้อมูลชุดเก่าที่ชื่อไฟล์มีรหัสสุ่มนำหน้า เครื่องมือมีขั้นตอนถอดชื่อกลับไปหาหลุมต้นทางก่อน เพื่อให้เฟรมจากหลุมเดียวกันไม่กระจายข้ามชุด



ภาพ 1. ลำดับการสร้างชุดข้อมูลจากฐานข้อมูลการ label

ถ้าต้องสร้างชุดข้อมูลใหม่ ให้ใช้ `scripts/build_dataset.py` เท่านั้น อย่าเขียนสคริปต์แบ่งชุดขึ้นใหม่เอง กติกาสามข้อที่ต้องไม่หายไปคือ แบ่งเป็นคลิปไม่ใช่เป็นภาพ อ่านคลาสจากฐานข้อมูลไม่ใช่จากไฟล์ที่ส่งออกไว้ และมีเกณฑ์จำนวนลูกขึ้นต่ำในชุดประเมิน

4. สถานะการ label ปัจจุบัน

ความคืบหน้า 99.47 เปอร์เซนต์ จากทั้งหมด 11,803 เฟรม มีคนดูและบันทึกแล้ว 11,741 เฟรม เหลือ 62 เฟรม นิยามที่ฐานข้อมูลใช้ระบุไว้ชัด สถานะ `todo` หมายถึงยังไม่มีคนเห็นเฟรมนั้นเลย สถานะ `done` หมายถึงมีคนกดบันทึกแล้ว โดยนับรวมกรณีที่ตรวจแล้วไม่มีอะไรต้องวาด และนับรวมกรณีที่คนรับข้อเสนอของโมเดลด้วยการกดปุ่ม เพราะการยอมรับก็คือคำตอบของคนเช่นกัน ผู้ที่ลงแรง label เรียงตามจำนวนเฟรม คือ win 8,832 เฟรม, Tanupat Panyasantikul 1,912 เฟรม, admin 705 เฟรม และ siam 292 เฟรม

รายการ	จำนวน	หมายเหตุ
เฟรมที่บันทึกแล้ว	11,741 / 11,803	99.47 เปอร์เซนต์
เฟรมที่เหลือ	62	อยู่ในคลิปเดียว ดูหัวข้อที่ 9
คลิปทั้งหมด	50	ทำเส้นวิถีเสร็จแล้ว 49 คลิป
กล่องที่คนวาด	9,462	หัวไม้ 5,525 · ลูก 3,937
กล่องที่โมเดลเสนอและยังไม่มีคนยืนยัน	125	หัวไม้ 92 · ลูก 33
เฟรมที่ผ่านการรีวิวซ้ำ	108	คิดเป็น 0.9 เปอร์เซนต์ของที่บันทึกแล้ว

ตารางที่ 3 สถานะการ label ณ 31 ก.ค. 2569 อ่านจาก labelhub.db

ข้อควรระวังสำหรับการวางแผนงานต่อ อัตราการรีวิวซ้ำอยู่ที่ 0.9 เปอร์เซนต์ หมายความว่าป้ายกำกับเกือบทั้งหมดผ่านสายตาคนเพียงคนเดียวแล้วเข้าสู่การเทรน ถ้าจะยกระดับคุณภาพโมเดล การสุ่มรีวิวซ้ำน่าจะให้ผลตอบแทนสูงกว่าการเพิ่มจำนวนเฟรมใหม่

5. โมเดลพื้นฐาน และตัวเลขที่ต้องเอาชนะ

โมเดลที่เทรนล่าสุดคือ `yolo_birdiex_2c_20260728-004149` เทรนที่ขนาดภาพ 960 พิกเซล 120 รอบ ส่งออกเป็น ONNX opset 12 ตัวเลขทั้งหมดด้านล่างมาจากไฟล์ผลที่ระบบเขียนไว้

เอง ไม่ใช่การประมาณ ตัวเลขที่ควรใช้ตัดสินคือ recall ของลูกกอล์ฟ ไม่ใช่ mAP เหตุผลตรงไปตรงมา ลูกที่โมเดลมองไม่เห็นในเฟรมหนึ่งคือรอยขาดหนึ่งจุดบนเส้นวิถีที่ผู้ใช้เห็น ขณะที่ precision ที่ลดลงเล็กน้อยมักถูกตัวติดตามกรองออกได้ ปัจจุบันช่องว่างระหว่าง recall ของหัวไม้ที่ 0.819 กับของลูกที่ 0.665 คือประมาณ 15 จุด และเป็นเป้าหมายที่ชัดที่สุดของการเทรนต่อไป

ตัวชี้วัด	ค่า	อ่านอย่างไร
mAP50	0.7956	ค่ารวม ใช้ดูภาพกว้าง แต่ไม่ใช่ตัวตัดสินสำหรับงานนี้
mAP50-95	0.4680	เข้มงวดกว่า สะท้อนความแม่นยำของขอบกล่อง
recall หัวไม้	0.8191	หาหัวไม้เจอ 82 เปอร์เซ็นต์ของที่มีจริง
precision หัวไม้	0.9525	ที่ทายว่าเป็นหัวไม้ ถูก 95 เปอร์เซ็นต์
recall ลูกกอล์ฟ	0.6648	จุดอ่อนที่แท้จริง — ดูคำอธิบายด้านล่าง
precision ลูกกอล์ฟ	0.8924	ที่ทายว่าเป็นลูก ถูก 89 เปอร์เซ็นต์

ตารางที่ 4 ผลการวัดของโมเดลล่าสุด บนชุด val เดียวกับที่ใช้เปรียบเทียบ

ทิศทางที่มีเหตุผลรองรับ กรณีที่โมเดลพลาดคือลูกเบลจากการเคลื่อนที่เร็วที่ 60 เฟรมต่อวินาที ลูกสีขาวบนท้องฟ้าที่มีเมฆ และลูกที่อยู่ไกลจนเล็กลงมาก การเพิ่มข้อมูลที่เจาะสามกรณีนี้ให้ผลมากกว่าการเพิ่มเฟรมทั่วไปในจำนวนเท่ากัน

6. ขั้นตอนการเทรน

การเทรนไม่ได้เริ่มจากศูนย์ แต่ fine-tune ต่อจากโมเดลที่ใช้งานอยู่ เหตุผลคือชุดข้อมูลที่มีป้ายกำกับยังเล็ก หน้าที่ของมันคือสอนกรณีโมเดลปัจจุบันพลาด ไม่ใช่สอนใหม่ว่าลูกกอล์ฟหน้าตาเป็นอย่างไร คำสั่งเดียวที่ต้องใช้ และควรใช้แทนการเรียก train.py ตรง ๆ คือ

- `bash scripts/train.sh` — เทรน 60 รอบจากโมเดลพื้นฐาน โดยตรวจชุดข้อมูลให้ก่อนเสมอ
- `bash scripts/train.sh --epochs 120` — ตัวเลือกทุกตัวของ train.py ส่งผ่านได้ตามปกติ
- `python3 scripts/verify_dataset.py` — ตรวจชุดข้อมูลอย่างเดียว ไม่เทรน

ตัวเลือก	ค่าตั้งต้น	เหตุผล
--epochs	60	ปรับได้ รอบล่าสุดที่ให้ผลดีที่สุดใช้ 120
--imgsz	960	ต้องตรงกับที่แอปใช้ตอนอนุมาน ถ้าไม่ตรงผลจะเพี้ยน
--batch	8	เหมาะกับหน่วยความจำของเครื่อง Mac Studio
--device	mps	เร่งความเร็วด้วย GPU ของ Apple Silicon
--patience	8	หยุดเองเมื่อไม่ดีขึ้น 8 รอบติดกัน
--opset	12	รุ่นของ ONNX ที่ฝั่งแอปรองรับ
--cache	ram	อ่านภาพเข้าหน่วยความจำ เร็วขึ้นชัดเจน

ตารางที่ 5 ค่าตั้งต้นของการเทรน จาก train.py

อ่านก่อนเทรนครั้งแรก ค่าตั้งต้นของตัวเลือก --data ใน train.py ชี้ไปที่ data/datasets/current/data.yaml ซึ่งเป็นไฟล์ที่ประกาศไว้เพียงคลาสเดียว การรัน python train.py เปล่า ๆ จึงเป็นการเทรนโมเดลสองคลาสด้วยพื้นที่ป้ายกำกับคลาสเดียว ผลคือกล่องลูกกอล์ฟทั้งหมดถูกย้ายไปเป็นคลาส 0 คือหัวไม้ โดยไม่มีข้อความเตือนใด ๆ ความผิดพลาดนี้เกิดขึ้นจริงแล้วหนึ่งครั้ง สคริปต์ scripts/train.sh มีอยู่เพื่อเรื่องนี้เรื่องเดียว คือส่ง --data ให้ชัดเจนทุกครั้ง

7. การตรวจผลหลังเทรน

ไม่มีการเลื่อนโมเดลขึ้นใช้งานอัตโนมัติ ทุกรอบการเทรนจะพิมพ์ตัวเลข val ของโมเดลใหม่ข้างตัวเลขของโมเดลพื้นฐานบนชุดแบ่งเดียวกัน แล้วให้คนตัดสินว่าดีขึ้นจริงหรือไม่ การออกแบบเช่นนี้ตั้งใจไว้ตั้งแต่ต้น นอกจากตัวเลข val ยังมีการตรวจอีกสองชั้นที่ควรรันทุกครั้ง

- scripts/eval_clips.py — ลองโมเดลกับคลิปที่ไม่เคยอยู่ในชุดเทรน ค่าตั้งต้นคือหลุม H2G1, H4G1, H4G2 และ H8G1 ตัวเลข val ดีขึ้นแต่คลิปจริงแย่ง เป็นสัญญาณที่ต้องหยุดพิจารณา
- scripts/score_labels.py — ให้คะแนนโมเดลกับเฟรมที่คนวาดไว้ เทียบกันระหว่างโมเดลเก่ากับใหม่
- scripts/after_train.sh — รอให้การเทรนจบแล้วรันทั้งสองอย่างข้างบนให้เอง พร้อมสรุปตัวเลขไว้ในไฟล์เดียว

เกณฑ์การตัดสินใจที่แนะนำ ให้ดู recall ของลูกกอล์ฟเป็นหลัก และดูผลจากคลิปที่ไม่เคยเห็นเป็นตัวยืนยัน อย่าตัดสินจาก mAP อย่างเดียว และอย่าตัดสินจากส่วนต่างที่เล็กกว่าความผันผวนของชุดประเมิน รายละเอียดเรื่องนี้อยู่ในหัวข้อถัดไป

8. กับดักที่โครงการนี้เคยเสียเวลาไปกับมันจริง

หัวข้อนี้ไม่ใช่ทฤษฎี ทุกข้อคือเหตุการณ์ที่เกิดขึ้นแล้ว หรือเป็นสภาพที่ยังค้างอยู่ในระบบและพร้อมจะทำให้พลาดซ้ำ

เรื่อง	สภาพปัจจุบัน	สิ่งที่ต้องทำ
ไฟล์กำหนดชุดข้อมูลที่มีคลาสเดียว ทำให้ลูกกลายเป็นหัวไม้	ยังอยู่ในระบบ และเป็นค่าตั้งต้นของ train.py เคยทำให้เทรนเสียเปล่าไปหนึ่งชั่วโมง โดยชุด val ของรอบนั้นมีกล่องหัวไม้ 47 กล่องและไม่มีลูกเลย	ส่ง --data ให้ชัดเจนทุกครั้ง หรือใช้ scripts/train.sh และควรแก้ค่าตั้งต้นในต้นทางให้ไม่ชี้ไปที่ไฟล์นั้น
ชุดข้อมูล merged ที่ใช้เทรนโมเดลที่ส่งมอบ มีชุด val เพียง 53 ภาพจาก 2 คลิป	ยังเป็นอย่างนั้น ส่วนต่างที่รายงานในรอบล่าสุดอยู่ระดับ 0.0004 ถึง 0.008 ซึ่งเล็กกว่าความผันผวนที่ชุดขนาดนี้ให้ได้	ใช้ชุด clean ที่ส่งมอบครั้งนั้นแทน ซึ่งมี val 791 ภาพ และอย่าสรุปผลจากส่วนต่างระดับพันส่วน
คลิปซ้ำในฐานข้อมูล H8G1 อยู่ฝั่ง train และ H8G1 copy อยู่ฝั่ง val จำนวนเฟรมเท่ากันคือ 273	ตรวจแล้วว่ายังไม่หลุดเข้าไปในชุด clean หรือ merged จึงยังไม่กระทบโมเดลที่มีอยู่	ลบคลิปที่ซ้ำออกจากฐานข้อมูลก่อนสร้างชุดข้อมูลใหม่ ไม่เช่นนั้นการแบ่งครั้งถัดไปจะทำให้คลิปเดียวกันอยู่ทั้งสองฝั่ง และตัวเลข val จะวัดการจำ
เฟรม 62 เฟรมที่ยังไม่ label อยู่ในคลิป H8G1 copy ทั้งหมด	เป็นงานที่ไม่ควรทำ เพราะเป็นสำเนา	ลบสำเนาออก แล้วความคืบหน้าจะเป็น 100 เปอร์เซนต์ทันทีโดยไม่ต้อง label เพิ่ม
คลิป h6g1_3 และ h6g1_3 copy อยู่ฝั่ง train ทั้งคู่ จำนวนเฟรมเท่ากันคือ 350	ไม่ทำให้ข้อมูลรั่วข้ามชุด แต่ทำให้คลิปนั้นมีน้ำหนักเป็นสองเท่าในการเทรน	ลบสำเนาออกเช่นกัน
อัตราการรีวิวซ้ำ 0.9 เปอร์เซนต์	ป้ายกำกับเกือบทั้งหมดผ่านสายตาคนเดียว	สุ่มรีวิวซ้ำอย่างน้อยในชุด val และ test ซึ่งเป็นชุดที่ความผิดพลาดหนึ่งจุดกระทบตัวเลขมากที่สุด

ตารางที่ 6 กับดักที่ตรวจพบ พร้อมสถานะและวิธีเลี่ยง

สาระร่วมของทุกข้อข้างบน ความผิดพลาดของชุดข้อมูลไม่ส่งเสียงเตือน มันไม่ทำให้โปรแกรมพัง แต่ทำให้ตัวเลขดูดีขึ้นหรือแย่ลงโดยไม่มีเหตุผลที่แท้จริง นี่คือเหตุผลที่ verify_dataset.py ถูกเขียนขึ้น และควรรันก่อนเทรนทุกครั้ง

9. การสร้างชุดข้อมูลใหม่

เมื่อมีการ label เพิ่ม หรือแก้ป้ายกำกับเดิม ต้องสร้างชุดข้อมูลใหม่ ไม่ใช่แก้ไฟล์ในโฟลเดอร์ dataset โดยตรง เพราะโฟลเดอร์นั้นเป็นผลลัพธ์ ไม่ใช่แหล่งข้อมูล แหล่งข้อมูลจริงคือ labelhub.db ขั้นตอนคือรัน scripts/build_dataset.py ซึ่งจะอ่านฐานข้อมูล คัดเฉพาะเฟรมที่มีคนยืนยันแล้ว แบ่งชุดตามคลิป ตรวจสอบจำนวนลูกในชุดประเมิน แล้วเขียนโฟลเดอร์ชุดข้อมูลใหม่พร้อมใบสรุป

- ตัวเครื่องมือจะไม่เขียนทับของเดิมถ้าระบุ --out เป็นชื่ออื่น และมีโหมด --dry-run ให้ดูผลก่อน
- หลังสร้างเสร็จ ต้องแก้บรรทัด path: ใน data.yaml ให้ชี้ที่เครื่องที่จะเทรน เพราะ Ultralytics อ้างอิงตำแหน่งของ train, val และ test จากบรรทัดนี้
- จากนั้นรัน verify_dataset.py ทับอีกครั้งก่อนเทรน

ข้อควรรู้เรื่องรูปภาพ ชุดข้อมูลบนเครื่องต้นทางเก็บภาพเป็นทางลัดเพื่อไม่ให้เปลืองเนื้อที่ ถ้าจะย้ายชุดข้อมูลข้ามเครื่องอีกครั้ง ต้องคลายทางลัดให้เป็นไฟล์จริง เช่นด้วย tar --dereference หรือ rsync -L มิฉะนั้นจะได้ทางลัดที่ชี้ไปในที่ไม่มีอยู่ และจะรู้ตัวตอนเทรนไปแล้ว

10. ข้อจำกัดของเอกสารและงานที่ยังไม่ได้ทำ

เพื่อให้ผู้อ่านประเมินความน่าเชื่อถือของแต่ละส่วนได้เอง ส่วนนี้ระบุสิ่งที่ยังไม่ได้ตรวจและสิ่งที่ยังไม่ได้ทำ

- ยังไม่ได้ทดลองเทรนบนเครื่องนี้ ชุดข้อมูลผ่านการตรวจความครบถ้วนแล้ว แต่การเทรนจริงยังไม่ได้รัน จึงยังไม่ยืนยันว่าเครื่องนี้มีสภาพแวดล้อมครบ ต้องมี Ultralytics 8.4.106 และ PyTorch 2.13.0 ตามที่เครื่องต้นทางใช้
- ตัวเลขผลของโมเดลทั้งหมดคัดลอกมาจากไฟล์ที่ระบบเขียนไว้ ไม่ได้รันวัดซ้ำเพื่อยืนยัน
- ยังไม่ได้ลบคลิปซ้ำในฐานข้อมูล เพราะเป็นการแก้ข้อมูลบนเครื่องที่ให้บริการอยู่ ต้องได้รับการยืนยันก่อน
- ยังไม่ได้แก้ค่าตั้งต้น --data ใน train.py ที่ต้นทาง เอกสารนี้จึงใช้วิธีห่อด้วย train.sh แทน ซึ่งแก้ที่ปลายทางไม่ใช่ที่ต้นเหตุ

- จำนวนกล่องที่โมเดลเสนอและยังไม่มีคนยืนยัน 125 กล่อง ยังไม่ได้ตรวจว่าถูกนับรวมเข้าชุดข้อมูลหรือไม่ในทุกกรณี

ข้อแนะนำลำดับงานถัดไป หนึ่ง ลบคลิปซ้ำสองคลิปปอกจากฐานข้อมูล สอง แก้ค่าตั้งต้นของ `--data` ที่ต้นทางให้ไม่ชี้ไปที่ไฟล์คลาสเดียว สาม สร้างชุดข้อมูลใหม่แล้วเทรนเทียบกับตัวเลขในหัวข้อที่ 5 โดยดู recall ของลูกกอล์ฟเป็นตัวตัดสิน

เอกสารอ้างอิง

- [1] ชุดข้อมูลต้นทาง: labelhub บนเครื่อง go-ai .
/Users/siammacstudio/labelhub/data/datasets/clean
- [2] ฐานข้อมูลการ label: labelhub.db · ตาราง clips, frames, boxes, jobs, landings
- [3] เครื่องมือสร้างชุดข้อมูล: build_dataset.py · เกณฑ์ MIN_BALLS_PER_EVAL_SPLIT = 60
- [4] เครื่องมือเทรน: train.py · Ultralytics 8.4.106 · PyTorch 2.13.0 · imgsz 960 · ONNX opset 12
- [5] ผลการวัดของโมเดล: models/yolo_birdiex_2c_20260728-004149.json