

AVANTIX




Avancement Simulateur IQ

Simple shape dataset


Création d'une BDD avec 2 formes simples : rectangle + cercle

BDD me permettant de plus facilement rétro-ingénier le YOLOv8

Tous les tests ont été réalisés sur un YOLOv8 : nano, P3->P5, HP par défaut




Cas bord d'images



Bug yolo

Bug yolo encore ...
Il ne semble être
présent que pour
une orientation
donnée

Bug YOLO orientation





- Tous les bugs ont les coordonnées qui tournent dans le sens trigo mais ils existent des cas non bug qui tournent également dans le sens trigo
- Il y a plus de corrects que de bug pour l'orientation trigo
- Tous les bugs ont la première coordonné en BottomLeft (BL) ou BottomRight (BR)
- Possible que ça se résolve par HP tuning et/ou un apprentissage plus long avec un meilleur learning rate
- Vu des coquilles dans le framework sur conversion des coordonnées → J'ai fait remonter au lead dev

Non détection (ND) CW

Folder : cw_added

Génération d'une BDD avec des rectangles horizontaux, fins et longs.

Confirmation les CW ne sont pas détectés



ND CW

Ce qui a été testé :





- **HP reg_max** → pas d'influence sur les 3 valeurs testées : 16 (défaut), 1 et 256
- **Split des CW** → Fonctionne mais nécessite d'avoir 2 modèles
- **Bbox plus large** → Détection rognée → Solution retenue

ND CW : Solution par élargissement BBOX

Folders : cw_enlarged_8_pix

Essai élargissement de 8 pixels des BBOX des CW → Détection des CW mais fort rognage en largeur





Solution : Post traitement des BBOX fins et longs détectées afin de reconnaître si CW ou non







FMCW

Folder : `cw_&_fmcw`





Vérification du comportement de YOLO avec des FMCW → Analogue au CW





FMCW



FMCW



FMCW



Petits + gros objets

Folder : *all_scales_shapes_large_p3_p5** & *all_scales_shapes_nano_p2_p5**

Génération d'une très grande BDD en piochant dans toutes les configurations d'objets possibles afin de vérifier la robustesse de YOLO.

Toujours ayant au maximum 4 objets par image

YOLOv8 large + HP tuning + P3 → P5: Abandonné car trop long

YOLOv8 nano + HP tuning + P2 → P5

Grace aux 2 runs précédents, on remarque que même sur un problème aussi simple la version large surpasse la version nano

Large P3P5

epoch,	train/box_loss,	val/box_loss,
1,	0.93027,	0.83108,
2,	0.73255,	0.74052,
3,	0.67391,	0.67554,
4,	0.62643,	0.64015,
5,	0.60052,	0.64003,
6,	0.58303,	0.6067,
7,	0.56703,	0.6074,
8,	0.55627,	0.57276,

AVANTIX


Nano P2P5

epoch,	train/box_loss,	val/box_loss,
27,	0.60603,	0.77157,
28,	0.66423,	0.77055,
29,	0.66029,	0.77021,
30,	0.65811,	0.7696,
31,	0.65383,	0.7694,
32,	0.65235,	0.76885,
33,	0.65089,	0.76854,
34,	0.64713,	0.768,
35,	0.64219,	0.76745,

Petits + gros objets : HP tuning

Folder : all_scales_shapes_large_p3_p5 & all_scales_shapes_nano_p2_p5**

Après avoir étudié les HP de YOLO, j'ai lancé sur les HP que je considère pertinent et ce qu'on remarque c'est que le choix des HP non fixés n'a pas d'incidence sur les performances du modèle.




Petits + gros objets : Stats

Folder : *all_scales_shapes_large_p3_p5** & *all_scales_shapes_nano_p2_p5**

Plus petit objet détecté : 30 pixels (vs plus petit objet présent : 2 pixels)

Plus gros objet détecté : 233413 pixels (quasiment $512 \times 512 = 262144$ pixels)

Conclusion : Il ne faut pas compter sur la fft optimale pour détecter les signaux à très bas SNR optimal. D'ailleurs pour ces cas, même avec une méthode par seuil il ne serait pas possible de les différencier du bruit.




Gestion des coordonnées à l'extérieur de l'image

Folder : *all_shape_p2_p5_outside_coord*

Après avoir commenté les parties qui excluent les coordonnées à l'extérieur :


- L'apprentissage se passe sans bug
- On peut même voir des prédictions de coordonnées négatives (voir fig à gauche)
- Cependant pour certains gros objets, le modèle est réticent à avoir des coordonnées extrêmes (voir fig à droite)

image_20764.png | Seed: 25



```
tensor([[[[499.2072, 94.5485],  
         [498.4572, 90.8981],  
         [ 15.8099, 90.1791],  
         [ 15.8399, 91.6977]],  
        [[181.8497, 425.5780],  
         [ 1.5594, 424.5490],  
         [ 2.6489, 18.5386],  
         [182.9391, 19.5571]],  
        [[-3.2796, 229.1880],  
         [ -2.5327, 15.0097],  
         [ 12.9640, 15.4312]],  
        [[186.9572, 352.4566],  
         [186.0026, 338.7537],  
         [189.5321, 338.2771],  
         [187.9807, 351.9568]]], device='cuda:0')]
```

image_10545.png | Seed: 38



Modification de labelizer au vu des résultats sur simples shapes :

- Augmenter la hauteur des bboxes des CW et FMCW. Par défaut à 8 pixels
- Borne inférieure sur w et h. Par défaut à 4 pixels
- Coords tournent dans le sens CW
- Borner les coords à 1,05x la définition de l'image → Trouver barycentre (x,y) et réduire w & h en conservant l'angle

BT1.0.2

Paramètres :

nperseg = [128, 256, 512]

noverlap = nperseg / 2

nfft = 512

fc_rec = 2.5 GHz

fs_rec = [4, 20, 100, 500, 1e3, 4e3] MS/s

dt_rec = 513 * nperseg / (2*fs_rec)

sigma_noise = 1mV

sig_types = [['radar'], ['radar', 'cellular']]

snr_db_opt_radar : friend / no friend

snr_db_opt_com = 35 dB

snr_db_eff = -2 dB

100k enregistrements

DI (ns)	Sans Modulation	Modulations de Fréquence (MHz/μs)		Modulations de Phase Phase / Nombre de moments	
10-100	Oui	-	-	-	
100-1_000	Oui	-	-	-	
1_000-10_000	Oui	20	100	180°	7, 8
10_000-100_000	Oui	2	10	180°	7, 8, 13, 25, 33, 39
				60°	25, 30
				45°	8, 35, 70
100_000-1_000_000	Oui	10 ⁻³	1	180°	7, 8, 13, 25, 33, 39
				60°	25, 30
				45°	8, 35, 70
1_000_000-10_000_000	Non	0,001	0,1	-	
10_000_000-100_000_000	Non	0,0001	0,01	-	
100_000_000-inf	Non	0,00001	0,001	-	
CW	Oui	-	-	-	


Meta-formes d'ondes

4 classes

- Petits objets (< 20 pixels)
- NO-MOD + CW + P1 + Frank (qq fois douce chirp) + P4 + Biphase
- FMOD + FMCW + P2(ressemble au symbole %)
- P3 (double chirp)

HP tuning sur BT102

Comme pour les formes simples → aucun impact






Résultats BT102

- ND de signaux très peu énergétiques
- Détecte des signaux dans de l'interférence COM
- Cas de multi détection
- CW traversé par impulsions = ND des 2
- Chirp avec mauvais angle et multi détection en présence d'interférences
- Aucun FP si on ne considère pas les multi-détections
- ND de certains FMCW
- Cas complexe quasi parfait




Résultats BT102 : ND peu énergétique

rec_59082_fs_500.0MSps_nperseg_128.png | Seed: 0






Résultats BT102 : interférence COM

rec_69569_fs_20.0MSps_nperseg_128.png | Seed: 1




Résultats BT102 : multi-détection

rec_84355_fs_500.0MSps_nperseg_512.png | Seed: 2



Résultats BT102 : ND CW + impulsion




rec_45393_fs_500.0MSps_nperseg_512.png | Seed: 3



Lorsqu'une impulsion traverse un CW, le CW est souvent ND




Résultats BT102 : Chirp angle erroné + multi détection

rec_38203_fs_1000.0MSps_nperseg_512.png | Seed: 4






Résultats BT102 : FMCW ND

rec_16429_fs_4.0MSps_nperseg_256.png | Seed: 6



Résultats BT102 : Cas complexe quasi parfait

rec_58236_fs_500.0MSps_nperseg_256.png | Seed: 12




TODO

Résultats HE360 sur YOLOv8-0BB nano

Avant (14/02)



Aujourd'hui



Bug YOLOv8

Apprentissage instable : Bbox Loss qui diverge → A déboguer

Underfitting présent → Plus gros modèle après résolution du pb précédent

YOLOv9

<https://arxiv.org/pdf/2402.13616.pdf>

Résout le problème de la perte d'information dans les réseaux profonds en proposant le programmable gradient information (PGI) et le generalized ELAN (GELAN). Cela a permis d'obtenir un nouvel état de l'art des perfs sur MSCOCO.

Des branches sont ajoutées durant l'apprentissage uniquement ne pénalisant pas le temps d'inférence.

Table 1. Comparison of State-of-the-Art Real-Time Object Detectors

Model	size (pixels)	AP ^{val} ₅₀₋₉₅	AP ^{val} ₅₀	AP ^{val} ₇₅	params (M)	FLOPs (B)
YOLOv9-S	640	46.8	63.4	50.7	7.2	26.7
YOLOv9-M	640	51.4	68.1	56.1	20.1	76.8
YOLOv9-C	640	53.0	70.2	57.8	25.5	102.8
YOLOv9-E	640	55.6	72.8	60.6	58.1	192.5

Detection (COCO) Detection (Open Images V7) Segmentation (COCO) Classification (ImageNet) Pose (COCO) >


See [Detection Docs](#) for usage examples with these models trained on [COCO](#), which include 80 pre-trained classes.

Model	size (pixels)	mAP ^{val} ₅₀₋₉₅	Speed CPU ONNX (ms)	Speed A100 TensorRT (ms)	params (M)	FLOPs (B)
YOLOv8n	640	37.3	80.4	0.99	3.2	8.7
YOLOv8s	640	44.9	128.4	1.20	11.2	28.6
YOLOv8m	640	50.2	234.7	1.83	25.9	78.9
YOLOv8l	640	52.9	375.2	2.39	43.7	165.2
YOLOv8x	640	53.9	479.1	3.53	68.2	257.8

RT DETR

Overview

Real-Time Detection Transformer (RT-DETR), developed by Baidu, is a cutting-edge end-to-end object detector that provides real-time performance while maintaining high accuracy. It leverages the power of Vision Transformers (ViT) to efficiently process multiscale features by decoupling intra-scale interaction and cross-scale fusion. RT-DETR is highly adaptable, supporting flexible adjustment of inference speed using different decoder layers without retraining. The model excels on accelerated backends like CUDA with TensorRT, outperforming many other real-time object detectors.



Modèle intéressant pour faire
du temps-réel **mais n'a pas**
(pour le moment)
d'implémentation OBB

Est beaucoup moins considéré
car il nécessite un gros
préapprentissage or ce n'est
pas un frein pour notre cas
d'usage.

AVANTIX

MERCI