

Projecte fi de grau

Estudi: Grau en Enginyeria Informàtica

Títol: Desenvolupament d'una xarxa neuronal profunda per la ramaderia de precisió

Document: Memòria

Alumne: Virginia Ramón Ferrer

Tutor: Rafael Garcia Campos

Departament: Arquitectura i Tecnologia de Computadors

Àrea: ATC

Convocatòria (mes/any): Febrer 2022



PROJECTE FI DE GRAU

---

# Desenvolupament d'una xarxa neuronal profunda per la ramaderia de precisió

---

*Autor:*  
Virginia RAMÓN FERRER

Febrer 2022

Grau en Enginyeria Informàtica

*Tutor:*  
Rafael GARCIA CAMPOS



# Agraïments

Per començar vull agrair a la meva família, per donar-me tot el seu suport des de sempre en tot el que faig i demostrar-me l'orgullosos que estan de mi.

Al meu tutor Rafael Garcia, per mostrar-me una part de la informàtica que no havia descobert i confiar en mi des del primer moment, mostrant-me que puc arribar més lluny del que jo hauria pensat mai.

A VICOROB, i en especial als membres del CIRS, per ajudar-me sempre que ho he necessitat i rebre'm amb els braços oberts.

Als professors, companys i amics que m'han acompanyat al llarg de la carrera i han aportat el seu gra de sorra a que avui sigui qui soc.

De cor, gràcies.



# Índex

<b>1</b>	<b>Introducció</b>	<b>1</b>
<b>2</b>	<b>Viabilitat i requisits del sistema</b>	<b>3</b>
2.1	Viabilitat i requisits tecnològics . . . . .	3
2.2	Viabilitat i requisits econòmics . . . . .	4
2.3	Viabilitat temporal . . . . .	4
<b>3</b>	<b>Metodologia</b>	<b>5</b>
<b>4</b>	<b>Planificació</b>	<b>9</b>
<b>5</b>	<b>Marc de treball i conceptes previs</b>	<b>11</b>
5.1	Machine learning . . . . .	11
5.1.1	Deep learning . . . . .	12
5.2	Filtre de Kalman . . . . .	13
5.2.1	UKF . . . . .	15
<b>6</b>	<b>Estudi i decisions</b>	<b>17</b>
6.1	Processament de dades . . . . .	17
6.2	Detecció de persones i porcs . . . . .	19
6.3	Algorisme de seguiment . . . . .	20
<b>7</b>	<b>Anàlisi i disseny del sistema</b>	<b>23</b>
7.1	Processament de dades . . . . .	23
7.1.1	Dataset Universitat d'Edimburg (porcs) . . . . .	25
7.1.2	Dataset IRTA (porcs i persones) . . . . .	26
7.1.3	Dataset Open Images v4 (persones) . . . . .	28
7.2	Detecció de persones i porcs . . . . .	28
7.2.1	Quantificació del error del model . . . . .	30
7.2.2	Arquitectura de la YOLOv4 . . . . .	31
7.3	Disseny general del sistema . . . . .	32
<b>8</b>	<b>Implementació i proves</b>	<b>35</b>
8.1	Processament de dades . . . . .	35
8.1.1	Implementació . . . . .	35
8.1.1.1	Extracció de les dades del dataset de la Universitat d'Edimburg . . . . .	35
8.1.1.2	Extracció dels frames del dataset de l'IRTA . . . . .	36

8.1.1.3	Etiquetat de les dades del dataset de l'IRTA . . . . .	36
8.1.1.4	Extracció de persones del dataset de l'IRTA . . . . .	37
8.1.1.5	Processament de les dades d'Open Images v4 . . . . .	37
8.2	Detecció de persones i porcs . . . . .	38
8.2.1	Implementació . . . . .	38
8.2.1.1	Entrenament . . . . .	38
8.2.1.2	Predictió en imatges i seqüències de vídeo . . . . .	39
8.2.2	Proves . . . . .	40
8.3	Disseny general del sistema . . . . .	43
8.3.1	Implementació . . . . .	43
8.3.2	Proves . . . . .	45
<b>9</b>	<b>Resultats</b>	<b>49</b>
9.1	Detecció de persones i porcs . . . . .	49
9.2	Disseny general del sistema . . . . .	53
<b>10</b>	<b>Conclusions</b>	<b>59</b>
<b>11</b>	<b>Treball futur</b>	<b>61</b>
<b>Bibliografia</b>		<b>63</b>
<b>Appendices</b>		<b>67</b>
A.1	Manuals d'usuari . . . . .	69
A.1.1	Xarxa neuronal . . . . .	69
A.1.1.1	Entrenament de la xarxa amb datasets propis . . . . .	69
A.1.1.2	Comprovació mAP d'un model entrenat . . . . .	74
A.1.1.3	Predictió . . . . .	76
A.1.2	Ús del sistema de seguiment amb prediccions de la xarxa neuronal . . . . .	79
B.2	Codi Datasets . . . . .	83
B.2.1	extractFrameData.py . . . . .	83
B.2.2	Extract_frames.py . . . . .	89
B.2.3	breafing_datasets.py . . . . .	90
B.2.4	ExtractROIs.m . . . . .	92
B.2.5	ExtractROIs_people.m . . . . .	94
B.2.6	Object_Detection_DataPreprocessing.ipynb . . . . .	96
C.3	Codi YOLOv4 . . . . .	107
C.3.1	configs.py . . . . .	107
C.3.2	yolov4.py . . . . .	110
C.3.3	utils.py . . . . .	130
C.3.4	dataset.py . . . . .	152

C.3.5	train.py . . . . .	164
C.3.6	detection_demo.py . . . . .	172
C.3.7	evaluate_mApy . . . . .	175
C.3.8	mAPtest.py . . . . .	185
D.4	Codi UKF . . . . .	187
D.4.1	ukf.py . . . . .	187
D.4.2	tracker.py . . . . .	196
D.4.3	object_tracking.py . . . . .	208
D.4.4	common.py . . . . .	216
D.4.5	frame_detection.py . . . . .	217



# CAPÍTOL 1

## Introducció

---

L'arribada de les tecnologies de la informació i la comunicació a la ramaderia permet l'adquisició de dades directament a les granges, i el seu processament per a convertir-les en informació útil per a la presa de decisions sobre el maneig a realitzar. En aquest context, les granges actuals tendeixen a incrementar el nombre d'animals per treballador, al temps que el benestar animal és cada dia més rellevant.

La tecnologia a desenvolupar en aquest projecte permetrà supervisar un grup de porcs 24 hores al dia, 7 dies a la setmana, a partir d'una càmera zenithal que cobreix la zona on es troben els animals. Els animals, en funció de la seva edat, estat fisiològic, i altres factors, dediquen una sèrie d'hores més o menys determinades a descansar, menjar, beure, interactuar.... És el que s'anomena el seu "pressupost diari del temps". Quan un animal o un grup, es desvia significativament del seu "pressupost horari" pot ser indicatiu d'un problema.

Aquest projecte es basa en el treball fet per Bergamini et al. [1], on es vol fer un anàlisi del pressupost diari del temps de cada animal per a analitzar com es comporten. En el cas d'aquest projecte, ens centrarem en la detecció d'animals i persones per a posteriorment veure com afecta la presència de persones al comportament de cada porc, és a dir, l'efecte dels factors externs al comportament dels animals.

Es partirà d'una arquitectura CNN (Convolutional Neural Network) pre-entrenada per la detecció d'objectes, la YOLOv4, i es modificaran les darreres capes d'aquesta xarxa neuronal per detectar porcs i persones. Inicialment només es disposava d'una base de dades que contenia exclusivament porcs i una altra que contenia només persones. Posteriorment s'han obtingut imatges on hi ha la presència tant de porcs com a persones per a poder fer proves amb ambdues. Aquestes noves imatges no estaven etiquetades, per tant s'ha hagut d'extreure una petita mostra i etiquetar-la per a poder afegir-les als entrenaments i proves.

També s'ha desenvolupat un algorisme d'anàlisi d'imatge que interpreta les deteccions de la CNN, de forma que es mesura el moviment de cada animal al llarg del temps. Aquestes deteccions fetes per la CNN poden ser errònies, ja que els

porcs són animals que tendeixen a estar molt junts i la CNN pot detectar varis animals junts com a un sol porc o, si hi ha algun objecte al mig del porc i la càmera, detectar un sol porc com a varis animals. L'algorisme utilitzat per a mesurar el moviment, l'Unscented Kalman Filter, ens permet en part contrarestar aquest fenomen gràcies a la prediccó que pot fer quan no hi ha mesura.

Tot i que aquest PFG se centra en la detecció i seguiment del moviment dels porcs per qüestions de temps, també es vol entrenar la xarxa per a la detecció de persones per a deixar-la llesta per a utilitzar aquestes mesures i la detecció de presència de persones per a analitzar com afecta aquesta presència.

La implementació s'ha realitzat en Python i s'ha fet servir les llibreries Tensorflow i Keras per a la implementació de la xarxa neuronal.

Al capítol 2 s'explica la viabilitat i els requisits del sistema implementat. Seguidament, al capítol 3, s'explica tot el procés seguit al llarg del projecte. A continuació es mostra la planificació seguida, al capítol 4. Al capítol 5 s'introdueixen els conceptes previs necessaris per a entendre el funcionament del projecte. Al capítol 6 es presenta de forma més detallada l'estudi i les decisions d'aquest projecte. Seguidament, al capítol 7, es detalla l'anàlisi i el disseny del sistema, seguit de la implementació d'aquest i les proves realitzades, incloses al capítol 8. A continuació, al capítol 9, es mostren els resultats extrets de les proves realitzades. Finalment es presenten les conclusions extretes, al capítol 10, i el treball futur, al capítol 11.

## CAPÍTOL 2

# Viabilitat i requisits del sistema

---

Si es parla de viabilitat del projecte, hi ha tres possibles limitacions que impedeixen el correcte desenvolupament d'aquest: tecnològiques, temporals i econòmiques. Al llarg de l'estudi de viabilitat, també s'introduiran els requisits necessaris per a desenvolupar aquest sistema.

### 2.1 Viabilitat i requisits tecnològics.

Pel que respecta a la viabilitat tecnològica, aquest projecte és viable ja que les Xarxes Neuronals tenen la potència suficient per a fer-ho. En aquest sentit, les Xarxes Neuronals Convolucionals les quals estan molt avançades en l'aplicació en la visió per computador i molts de treballs anteriors com serien [2], [3] o [4] ho demostren. A Internet hi ha disponibles una gran quantitat d'implementacions d'aquest tipus de xarxes que són de lliure ús, per tant no s'han d'implementar de zero. Pel que fa al requisit de poder fer el seguiment dels animals i les persones, en el camp de la robòtica s'han fet ús i desenvolupat molts d'algorismes per a dur-ho a terme ja que sempre s'ha mostrat la necessitat de fer seguiment d'aquests. Alguns d'aquests algorismes, com seria el Filtre de Kalman, són també aplicables a les seqüències d'imatges, ja que seria com treballar en un món 2D. Al igual que amb la Xarxa Neuronal, també hi ha moltes implementacions d'aquest algorisme i les seves variacions disponibles a internet les quals són de lliure ús, per tant tampoc s'ha de implementar en la seva totalitat i només hi ha que modificar-los per a que compleixin els requisits. Tant la xarxa neuronal com l'algorisme de seguiment han de ser compatibles entre ells per a poder funcionar en conjunt. Algunes d'aquestes implementacions esmentades anteriorment són en Python, que és el llenguatge de programació elegit per a desenvolupar el projecte, per tant és factible el que es puguin combinar de forma senzilla.

Per a crear aquest sistema no només és necessari tenir la implementació si no també les dades per a poder fer proves. Pel que fa a les dades, hi ha disponibles grans quantitats de datasets de lliure ús d'imatges etiquetades de diferents objectes en xarxa, moltes de les quals contenen persones. També hi ha disponible

el dataset de porcs de la Universitat d'Edimburg [5] que només requereix citarlos per a poder fer-ne ús, per tant amb aquest ja es té coberta la part d'imatges de porcs.

Pel que fa al hardware necessari, l'única part que requereix d'una potència computacional fora dels límits d'un ordinador portàtil normal, del qual es disposa, és l'entrenament de la Xarxa Neuronal. Per a fer això, VICOROB té disponible un servidor que compta amb 376 GB de memòria RAM, 12 TB de memòria al disc dur i 2 GPUs de 24 GB de memòria cada una, per tant, es té capacitat computacional de sobra per a poder dur a terme el projecte i tenir una velocitat de processament suficient per a treballar còmodament. En aquest servidor es permet crear entorns de Conda [6], el que permet instal·lar i tenir disponible el compilador de Python i totes les llibreries necessàries per a la implementació.

## 2.2 Viabilitat i requisits econòmics

Pel que fa a les limitacions econòmiques, aquest projecte ha set desenvolupat en la seva totalitat amb recursos de lliure ús o credits de forma gratuïta, per tant la implementació i les dades no tenen cap cost. Pel que fa al hardware, s'ha fet ús d'un servidor de la universitat per a desenvolupar en la seva totalitat el projecte i s'ha utilitzat l'ordinador de la mateixa estudiant per accedir a aquest, per tant no ha suposat cap gast afegit i ha fet que aquest projecte no necessiti de cap despesa addicional al material ja disponible. Això ha fet que el projecte hagi set viable econòmicament.

## 2.3 Viabilitat temporal

Si es parla de limitacions temporals, a la introducció ja s'ha indicat que s'ha hagut de limitar l'abast del projecte per ajustar-lo al temps disponible, per tant s'ha centrat en la detecció dels porcs i les persones i en l'algorisme de seguiment d'aquests. S'ha organitzat des de un principi la planificació del desenvolupament d'aquest projecte per a tenir suficient temps per a treballar totes les parts amb cura.

## CAPÍTOL 3

# Metodologia

---

Aquest projecte va ser una proposta del tutor Rafael Garcia. Inicialment es va presentar la idea exposada al capítol 1 de crear un sistema per a analitzar com afecta la presència de persones al comportament dels porcs. Seguidament, es va analitzar el que suposava dissenyar i implementar aquest projecte en la seva totalitat i es va arribar a la conclusió de que en el temps que es tenia per a desenvolupar el Projecte Final de Grau no es podia fer en la seva totalitat, per tant es va arribar al consens de només implementar la part de detecció de porcs i persones i l'algorisme de seguiment d'aquests, deixant fora dels marges del projecte la part de quantificar aquests moviments i fer l'anàlisi del comportament.

Durant tot el desenvolupament del projecte hi ha hagut comunicació contínua entre l'estudiant i el tutor en forma de reunions presencials i en línia i amb missatges de correu electrònic on s'ha anat informant dels avenços del projecte, s'han resolt dubtes i s'han discutit diferents tòpics referents al treball a fer.

Per a implementar aquest projecte han fet falta conèixer un mínim de conceptes sobre Aprenentatge Automàtic i algorismes de seguiment, exposats al capítol 5, els quals l'estudiant no tenia ja que no entren en els coneixements donats al llarg de la carrera, per tant, al inici del projecte, ha fet falta un període d'aprenentatge on s'han estudiat els diferents conceptes.

Quan ja es tenien els conceptes clars, el següent pas va ser fer l'anàlisi de les dades que es tenien i/o es necessitaven per al correcte desenvolupament d'aquest. Inicialment es tenia un dataset de porcs aconseguit per l'Universitat d'Edinburgh [5] utilitzat a [7] per a fer l'anàlisi del pressupost diari del temps dels porcs. Aquesta publicació només fa l'anàlisi del comportament dels animals mirent quan estan menjant, beguent, moguent-se... En el cas d'aquest projecte, s'analitza com afecta la presència de persones al comportament dels porcs, mesurat en moviments, per tant, és necessari també tenir un dataset amb persones per a poder entrenar la detecció de persones i porcs. Per a fer això, s'ha utilitzat part del dataset de Google Open Images v4 [8], només fent ús d'imatges amb persones etiquetades. Al principi només s'anava a entrenar la detecció de porcs

i persones per separat ja que no es disposava d'un dataset que contingui's ambdós objectes a les seves imatges, però entrat en el desenvolupament d'aquest es va aconseguir un dataset proporcionat per l'IRTA [9] el qual conté seqüències d'imatges de persones interactuant en el mateix espai que els porcs, per tant va permetre poder fer entrenaments i proves amb ambdós junts. El problema amb aquest dataset és que no són imatges etiquetades, per tant l'alumne va haver d'emprar temps en etiquetar i processar algunes d'aquestes imatges per a poder fer-ne ús. Aquest fet fa que la quantitat d'imatges disponibles amb porcs i persones junts és més reduïda que de porcs i persones per separat. Les dades es varen repartir en tres datasets separats: entrenament, validació i testing.

Per a fer la detecció de persones i porcs es va haver d'elegir amb quin mètode fer-ho. Al analitzar les diferents opcions que es tenien, es va arribar a la conclusió de fer ús d'una Xarxa Neuronal Convolucional o CNN (concepte exposat a la secció 5.1.1), específicament un conjunt de CNNs específiques per a la detecció d'objectes anomenades Xarxes Neuronals Convolucionals basades en Regions o R-CNNs. Dintre d'aquest conjunt es va plantejar l'ús de dos R-CNNs diferents: Faster R-CNN [2] o YOLOv4 [3]. Després de fer proves amb ambdós i comparar diferents factors com a resultats i velocitat d'entrenament i detecció, es va arribar al consens de fer ús de la YOLOv4, ja que té un temps molt reduït de detecció, cosa que si en algun moment es vol extrapolar aquest sistema a un ús real, seria molt necessari. Quan es va tenir la xarxa elegida, es va començar a fer entrenaments amb les dades a partir dels pesos ja entrenats de la Darknet [10] i, a partir dels resultats obtinguts després de cada entrenament, es va anar refinant el dataset.

Per a fer el seguiment dels animals i les persones, des d'un principi el tutor va expressar la idea de fer ús d'un Filtre de Kalman (concepte exposat a la secció 5.2), ja que és un algorisme de seguiment àmpliament usat en el món de la robòtica que és relativament simple d'aplicar en visió per computador. Ja que el moviment que es té a les seqüències d'imatges no és lineal, es va haver d'elegir entre dos implementacions d'aquest aplicats a moviments no-lineals: Extended Kalman Filter o Unscented Kalman Filter (concepte exposat a la secció 5.2.1). Es va elegir finalment fer ús del Unscented Kalman Filter o UKF ja que els resultats són lleugerament millors que els de l'Extended Kalman Filter.

Quan ja es van tenir la Xarxa Neuronal i l'algorisme de seguiment elegits, es varen combinar, essent la sortida de la xarxa neuronal l'entrada de l'algorisme de seguiment (referir-se a 7 per a veure l'arquitectura d'aquest sistema). A mesura que s'anava entrenant la YOLOv4, s'anaven fent proves amb el UKF per veure com funcionaven en conjunt i anar refinant les dades i els paràmetres en

conseqüència.

Pel que fa a la memòria, al llarg del projecte s'ha anat fent un seguiment del procés i, quan ja es tenia implementat tot el sistema i només quedava refinjar dades i paràmetres, es va començar a redactar aquest document en paral·lel a aquest refinament per aaprofitar el temps que tarden els entrenaments i les proves.



# CAPÍTOL 4

## Planificació

---

Com s'ha explicat al capítol 3, la feina a fer s'ha dividit en quatre blocs principals ordenats cronològicament, com es pot veure a la figura 4.1:

### 1. Desenvolupament dataset

- Anàlisi i processament del dataset de porcs de la Universitat d'Edinburgh per a extreure les etiquetes de les imatges i posar les dades en el format necessari per a processar.
- Anàlisi i processament del dataset de Google Open Images v4 per a extreure algunes de les etiquetes de les imatges de persones i posar les dades en el format necessari per a processar.
- Anàlisi i processament del dataset de l'IRTA etiquetant algunes de les imatges proporcionades per a poder processar-les i fer-ne ús.
- Durant tot el desenvolupament del dataset s'han creat i refinat tres datasets, entrenament, validació i testing, per entrenar i fer proves. A mesura que s'ha desenvolupat el projecte, s'han anat afegint i modificant algunes de les dades per a aconseguir millors resultats.

### 2. Detecció de persones i porcs

- Per a poder desenvolupar la detecció, s'han hagut de conèixer alguns conceptes previs sobre l'Aprenentatge Automàtic, específicament sobre el Deep Learning.
- Investigació i elecció de la Xarxa Neuronal a utilitzar per fer la detecció, essent finalment l'elecció la YOLOv4.
- Cerca, anàlisi, modificació i refinament de la implementació de la YOLOv4 per a que sigui compatible amb el sistema sencer.
- Entrenament dels pesos de la YOLOv4 per a aconseguir millors resultats. A mesura que es va entrenant, es va refinant el dataset, com s'ha dit al apartat 1.
- Duta a terme de diferents proves per a veure el funcionament de la xarxa entrenada i analitzar si els resultats són els esperats i, si no ho eren, definir quins paràmetres del sistema hi havia que modificar i tornar a entrenar.

### 3. Algorisme de seguiment

- Per a poder desenvolupar la detecció, s'han hagut de conèixer alguns conceptes previs sobre els Filtres de Kalman.
- Investigació i elecció de la variant del Filtre de Kalman a usar, essent finalment el Unscented Kalman Filter per la seva aplicació a models no-lineals.
- Cerca, anàlisi, modificació i refinament de la implementació de l'UKF
- Duta a terme de diferents proves en combinació amb la Xarxa Neural entrenada per a veure el funcionament funcionament en conjunt i fer anàlisi dels resultats i, si calia, fer modificacions a la part que pertoqui.

### 4. Redacció de la memòria

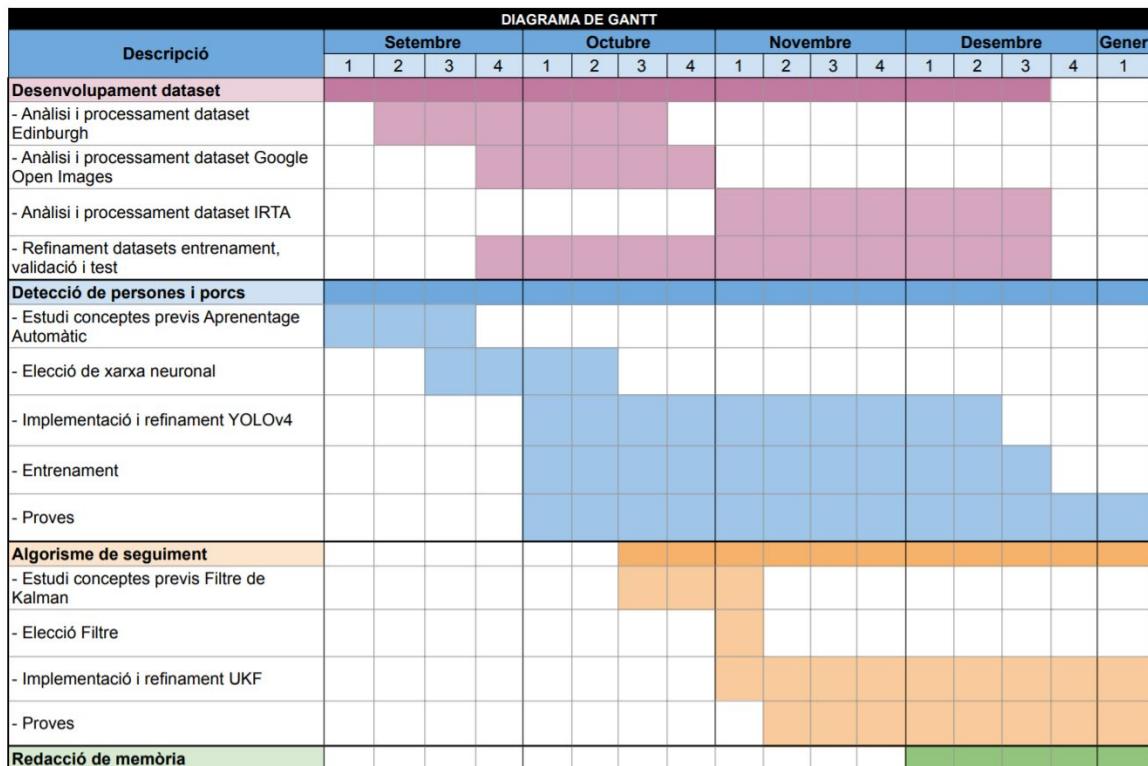


Figura 4.1: Diagrama de Gantt

## CAPÍTOL 5

# Marc de treball i conceptes previs

---

En aquest projecte només hi han col·laborat de forma directa la Virginia Ramón Ferrer (autora d'aquest document) amb l'assistència quan ha set necessària del tutor Rafael Garcia Campos.

Com ja s'ha esmentat prèviament, aquest projecte consisteix en fer ús d'una xarxa neuronal per a detectar la presència de persones i porcs en vídeo i, seguidament, seguir la trajectòria d'aquests amb un algorisme de tracking. Per a entendre els continguts d'aquest, s'han de conèixer una sèrie de conceptes previs, que s'introdueixen a continuació.

## 5.1 Machine learning

Segons [11], l'aprenentatge automàtic (més coneugut pel seu nom en anglès *Machine Learning*) es pot definir com a l'estudi sistemàtic d'algoritmes i sistemes que milloren el seu coneixement o rendiment amb l'experiència. Aquests algoritmes construeixen un model basat en dades de mostra, coneguts com a dades d'entrenament, per tal de fer prediccions o decisions sense estar programats explícitament per fer-ho.

A vegades hi ha tasques per a les quals és complicat programar algoritmes que indiquen a la màquina com executar tots els passos necessaris per resoldre el problema en qüestió, és a dir, sense que l'ordinador hagi d'aprendre. En aquests casos, sol ser més eficaç ajudar la màquina a desenvolupar el seu propi algorisme, fent així ús de tècniques de *Machine Learning* [12].

Segons la sortida que donen els algoritmes de *Machine Learning*, es poden classificar en diferents tipus, dels quals els principals són [12]:

1. **Aprendentatge supervisat:** S'anomenen així als algoritmes que generen una funció que relaciona cada entrada amb la sortida desitjada. Per a poder entrenar un algorisme supervisat, es necessiten dades que relacionen l'entrada amb la sortida, essent la sortida una classe, un valor... Aquest tipus de dades són conegudes com a dades "etiquetades".

2. **Aprenentatge no supervisat:** Al contrari que en el cas anterior, aquest tipus d'algorismes treballen amb dades "no etiquetades", és a dir, no es coneix la sortida desitjada, per tant, han de tenir la capacitat de trobar patrons en les dades per a ser capaç d'etiquetar-les.
3. **Aprenentatge semisupervisat:** Aquests algorismes són una combinació dels dos tipus anteriors, fent ús tant de dades "etiquetades" com "no etiquetades" per tal de fer una classificació adequada.
4. **Aprenentatge per reforç:** Al contrari que en els casos anteriors on per cada entrada es volia una sortida, els algorismes d'aquest tipus són capaços d'avaluar i generar polítiques de seqüències d'accions, restant importància a les accions singulars.

### 5.1.1 Deep learning

L'aprenentatge profund (més conegut pel seu nom en anglès *Deep Learning*) forma part d'un conjunt de mètodes d'aprenentatge automàtic basats en xarxes neuronals artificials. L'aprenentatge pot ser supervisat, semisupervisat o no supervisat.

Una xarxa neuronal artificial (més coneguda com a ANN per les seves sigles en anglès *Artificial Neural Network*) és un algorisme de machine learning basat en el sistema nerviós dels animals, específicament dels èssers humans. Com es pot veure a la figura 5.1, una xarxa neuronal és un algorisme format per capes que a la seva vegada estan formades per unitats computacionals, conegudes com a neurones, les quals contenen una o més entrades i sortides ponderades i una funció de transferència que connecta d'alguna forma aquestes entrades i sortides. Una xarxa neuronal sempre conté una capa d'entrada, una capa de sortida i una o més capes "amagades" que duen a terme tots els càlculs necessaris per transformar aquesta entrada en la sortida desitjada [13].

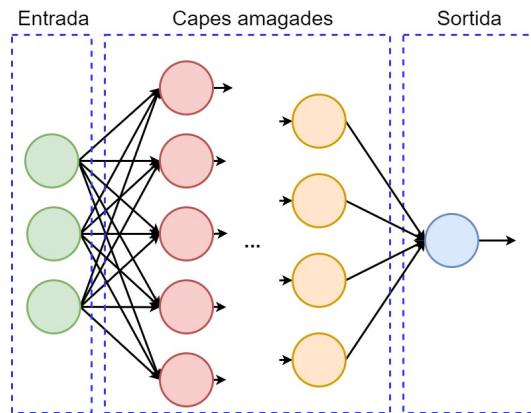


Figura 5.1: Arquitectura d'una xarxa neuronal artificial

Les xarxes neuronals poden ser classificades en diferents tipus segons el seu propòsit. Els tipus més comuns són:

1. **Xarxa neuronal directa:** Més coneguda pel seu acrònim anglès FNN (*Feedforward neuronal network*), les xarxes d'aquest tipus són les més simples, ja que les connexions entre nodes no formen cap cicle i la informació només es mou en direcció entrada a sortida.
2. **Xarxa neuronal convolucional:** Més coneguda pel seu acrònim anglès CNN (*Convolutional neural network*), és un tipus similar a la FNN, però fa ús de l'operació matemàtica coneguda com a "convolució", el que fa que aquesta classe de xarxa sigui molt utilitzada per al processament d'imatges. En aquest projecte es fa ús d'una CNN.
3. **Xarxes neuronals recurrents:** Més coneguda pel seu acrònim anglès RNN (*Recurrent neural network*), les connexions d'aquest tipus de xarxa poden formar cicles de realimentació entre neurones.

## 5.2 Filtre de Kalman

El Filtre de Kalman, normalment referit pel seu acrònim anglès KF (*Kalman Filter*), és un dels principals algorismes d'estimació. Aquest proporciona estimacions d'algunes variables desconegudes donades les mesures, o observacions, observades al llarg del temps. Els Filtres de Kalman han demostrat la seva utilitat en diverses aplicacions, també gràcies a que tenen una forma relativament simple i requereixen poca potència de càlcul [14].

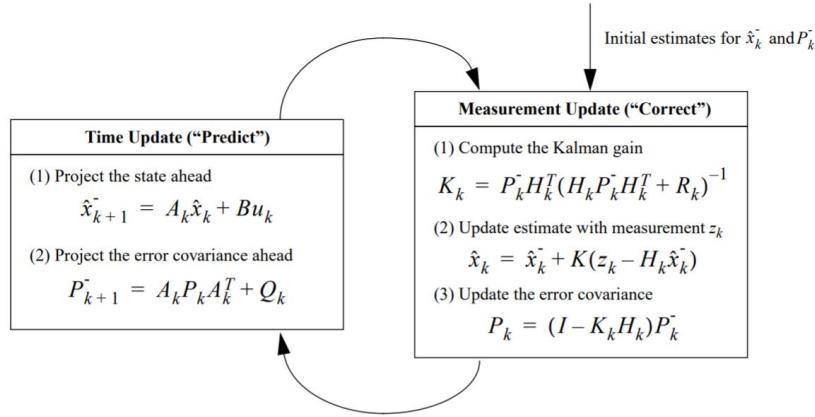


Figura 5.2: Operació del Filtre de Kalman [15]

Variable	Significat
$\hat{x}_k^-$	Projecció del estat
$A_k$	Matriu que descriu com l'estat evoluciona de k a k-1 sense controls o soroll
$\hat{x}_k$	Actualització del estat
$B$	Matriu que descriu com el control $u_k$ canvia l'estat de k a k-1
$u_k$	Vector d'entrada
$\hat{P}_k$	Projecció de la matriu de covariància
$P_k$	Matriu de covariància
$Q_k$	Matriu de covariància del soroll del sistema
$K_k$	Guany de Kalman
$H_k$	Matriu que descriu com mapejar l'estat $\hat{x}_k$ a una observació $z_k$
$R_k$	Matriu de covariància del soroll de la mesura
$z_k$	Mesura

Taula 5.1: Taula explicativa de les variables de la figura 5.2

Aquest algorisme és un algorisme iteratiu que es du a terme en dos fases: la predicció i l'actualització, quan es tenen mesures. Aquestes fases es poden observar clarament a la figura 5.2 [15], on cada bloc és una de les fases. Si observem el primer bloc "Time Update ("Predict")", és a dir, la predicció, veiem que l'algorisme projecta l'estat futur  $\hat{x}_{k+1}$  i la matriu  $P_k$ , que és la matriu de covariància del model. Seguidament, si es tenen mesures, a partir d'aquestes i de les projeccions fetes a la fase anterior es calcula el guany de Kalman  $K_k$ , s'actualitza l'estimació del estat  $\hat{x}_k$  amb la mesura  $z_k$  i l'error de covariància  $P_k$ . Per a conèixer que és cada variable, referir-se a la taula 5.1.

Normalment es refereix com a Filtre de Kalman al que és el Filtre de Kalman Lineal, és a dir, l'estimador òptim de l'estat ocult quan es té un sistema dinàmic

lineal. Per a sistemes no lineals, com el que es presenta en aquest projecte, hi ha modificacions d'aquest mateix com serien l'Extended Kalman Filter (EKF) o l'usat en aquest projecte, donats els seus millors resultats en comparació amb el EKF Unscented Kalman Filter (UKF). Aquestes modificacions aproximen els models no-lineals en models lineals.

### 5.2.1 UKF

L'UKF es basa en la intuïció de que és més fàcil aproximar una distribució gaussiana que no pas aproximar una funció o transformació no lineal arbitrària [16]. Aquest selecciona un nombre de mostres al voltant de la mitjana amb una tècnica de mostreig anomenada Unscented Transformation (UT) (Figura 5.3). Aleshores, els punts sigma es propaguen a través de la funció no lineal per a aconseguir un núvol de punts transformats, a partir de les quals es forma una nova estimació de mitjana i covariància.

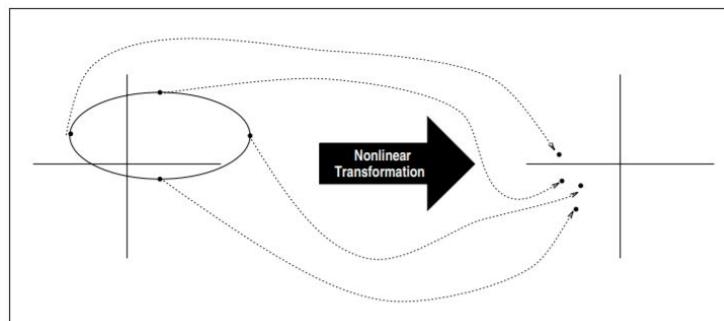


Figura 5.3: Exemple de l'UT [16]



# CAPÍTOL 6

## Estudi i decisions

---

En aquest capítol s'explica de forma detallada les decisions exposades al capítol 3 relacionades amb la implementació del sistema. En general, tot el sistema ha estat programat amb el llenguatge de programació Python [17], específicament en la seva versió 3.7 i programat, compilat i executat al servidor presentat al capítol 2.

### 6.1 Processament de dades

Pel que fa als datasets, tenim que, per a preprocessar-los per a poder fer-ne ús amb el sistema, s'ha fet ús de diferents scripts de Python. El dataset d'imatges de porcs de la Universitat d'Edimburg consta de videos de porcs amb etiquetes que estan guardades en fitxers en format JSON. Aquests han hagut de ser transformats al format que necessita el sistema, per tant, les seqüències de vídeo han hagut de ser dividides en frames per a poder entrenar la xarxa neuronal, ja que només processa imatges individuals, i les etiquetes que estaven en format JSON han hagut de ser convertides a format text (aquests formats estan explicats al capítol 7). Pel que fa al dataset de persones, s'ha fet ús d'un Python Notebook creat per l'usuari de Github "RockyXu66" [18] "Object\_Detection\_DataPreprocessing.ipynb", el qual permet descarregar, processar i guardar les etiquetes del dataset Open Images v4. S'ha modificat per a només descarregar algunes de les imatges de persones i les seves etiquetes. Si es parla del dataset de persones i porcs de l'IRTA, també s'ha hagut de dividir els frames de les seqüències de vídeo com al dataset dels porcs, però, en aquest cas, les etiquetes han hagut de ser registrades a mà. Per a fer-ho, s'ha creat un script de MATLAB [19] el qual permetia indicar sobre les imatges les regions d'interès de cada classe i registrar aquestes dades a un fitxer de text en el format requerit.

Pel que fa als scripts de Python, s'ha fet ús principalment de les següents llibreries externes:

1. NumPy
  - Versió: 1.18.5

- *Descripció:* NumPy [20] és una biblioteca que afegeix suport per a vectors i matrius grans i multidimensionals, juntament amb una gran col·lecció de funcions matemàtiques d'alt nivell per operar en aquestes.
- *Ús:* En el cas d'aquest projecte, numpy es fa servir per crear i modificar matrius que guarden les dades necessàries per al funcionament del sistema, com serien les etiquetes de les imatges o paràmetres.

## 2. CV2

- *Versió:* 4.1.1.26
- *Descripció:* OpenCV [21] (Open Source Computer Vision Library) és una biblioteca de funcions de programació dirigides principalment a la visió per ordinador en temps real.
- *Ús:* Aquesta biblioteca es fa servir per a processar les seqüències d'imatges dels datasets i fer totes les funcions adients: llegir les imatges, retallar-les, afegir text, guardar imatges a la memòria...

## 3. matplotlib

- *Versió:* 3.4.3
- *Descripció:* Matplotlib [22] és una biblioteca completa per crear visualitzacions estàtiques, animades i interactives
- *Ús:* S'usa per a mostrar per pantalla imatges i les seves etiquetes al processar les imatges de personnes al Python Notebook.

## 4. pandas

- *Versió:* 1.2.5
- *Descripció:* Pandas [23] és una eina d'anàlisi i manipulació de dades de codi obert.
- *Ús:* S'usa per a llegir els fitxers CSV que contenen les dades i les etiquetes de les imatges de les personnes.

## 5. scikit-image

- *Versió:* 0.17.2
- *Descripció:* scikit-image [24] és llibreria que conté una una col·lecció d'algorismes per al processament d'imatges.
- *Ús:* S'usa per a llegir les imatges de les personnes que són a internet per la seva URL.

A part, també es fa ús principalment de les següents llibreries i/o mòduls del mateix Python:

#### 1. os

- *Descripció*: os [25] és un mòdul que permet fer ús de manera versàtil funcionalitats depenents del sistema operatiu, com seria obrir o llegir fitxers, carpetes...
- *Ús*: Aquesta llibreria s'usa per a administrar fitxers, obrir, tancar, crear, llegir..., en aquest cas de text per a registrar i llegir les dades de les etiquetes.

#### 2. json

- *Descripció*: JSON és una llibreria que permet codificar i descodificar fitxers en format JSON (JavaScript Object Notation) [26].
- *Ús*: Aquesta llibreria s'usa per a llegir els fitxers d'etiquetes de les dades del dataset de porcs de la Universitat d'Edimburg.

#### 3. random

- *Descripció*: Random [27] implementa generadors de nombres pseudoaleatoris per a diverses distribucions.
- *Ús*: S'usa per a barrejar les imatges aleatoriament.

#### 4. shutil

- *Descripció*: Shutil [28] ofereix una sèrie d'operacions d'alt nivell sobre fitxers i col·leccions de fitxers, en particular, es proporcionen funcions que admeten la còpia i l'eliminació de fitxers.
- *Ús*: S'usa per a copiar fitxers d'un lloc a un altre, en aquest cas, copiar imatges d'una carpeta general a unes altres dividides per datasets.

## 6.2 Detecció de persones i porcs

Pel que fa la detecció de les persones i els porcs, es va elegir fer ús de la xarxa neuronal convolucional YOLOv4 [3]. Es va elegir aquesta xarxa per la seva velocitat de processament d'imatges, el que permetria fer-ne ús en temps real. Pel que fa a la implementació, la implementació original d'aquesta, anomenada "darknet" [10], té l'arquitectura programada amb C i els programes per fer-ne proves en Python. Aquesta implementació és complicada d'entendre i, quan es

va intentar analitzar per poder fer-ne ús, es va veure que no era còmoda de re-entrenar, per tant es va buscar una implementació d'aquesta que fos en Python en la seva totalitat. Després d'analitzar varíes opcions i fer algunes proves, es va decidir usar una implementació amb llicència d'ús MIT, per tant es pot usar lliurement mentre es doni crèdit al autor original del codi, implementada per l'usuari de Github "pythonlessons" [29]. Aquesta implementació està programada en la seva totalitat amb Python 3.7 i, a part d'algunes de les llibreries externes i llibreries i mòduls interns esmentades a la secció 6.1, fa ús principalment de la següent llibreria:

### 1. tensorflow-gpu

- *Versió:* 2.3.0rc0
- *Descripció:* Tensorflow és una biblioteca de programari obert per al aprenentatge automàtic [30], específicament per a construir i entrenar xarxes neuronals.
- *Ús:* Aquesta llibreria s'usa per a crear l'arquitectura, entrenar i fer ús de la Xarxa Neuronal YOLOv4.

## 6.3 Algorisme de seguiment

Per l'algorisme de seguiment, es va decidir usar l'Unscented Kalman Filter per la seva aplicació en models no-lineals i el seu millor funcionament que el seu antecesor, l'Extended Kalman Filter. Després de analitzar si era millor programar-lo des del principi o si buscar una implementació ja feta, es va decidir per la segona opció ja que es tenia un temps limitat per a dedicar-li. Després de buscar diferents implementacions, es va trobar la implementació del usuari de Github "sj23patel" [31], el qual també feia ús d'una xarxa neuronal YOLO per a fer la detecció de la posició d'objectes, però només s'ha agafat la part del UKF, afegint-hi posteriorment la xarxa YOLOv4 esmentada a la secció anterior. Aquesta implementació està programada en Python també en la seva versió 3.7 en la seva totalitat. A part d'algunes de les llibreries externes i llibreries i mòduls interns esmentades a les seccions anteriors, fa ús també de les llibreries externes:

### 1. sciPy

- *Versió:* 1.4.1
- *Descripció:* SciPy [32] proporciona algorismes per a l'optimització, integració, interpolació, problemes de valors propis, equacions algebraiques, equacions diferencials, estadístiques i moltes altres classes de problemes.

- *Ús:* Aquesta llibreria s'usa per algunes de les seves funcions matemàtiques per a desenvolupar l'algorisme UKF.

Pel que fa a les llibreries i mòduls del mateix Python, fa ús de:

### 1. **threading**

- *Descripció:* threading [33] és un modul que construeix una intereficie d'alt nivell a sobre del mòdul \_thread, el qual proporciona primitives a baix nivell per treballar amb múltiples threads.
- *Ús:* S'usa per paral·litzar alguns dels processos i bloquejar recursos que han de ser accedits un a la vegada.

### 2. **copy**

- *Descripció:* copy [34] aquesta llibreria proporciona operacions genèriques de còpia superficial i profundes d'objectes de Python, ja que les declaracions d'assignació d'aquest no copien objectes, sinó que creen enllaços entre un objectiu i un objecte.
- *Ús:* S'usa per fer còpies dels valors d'objectes, per no sobreescriure'l's al modificar aquests còpies.

### 3. **argparse**

- *Descripció:* argparse permet definir i administrar els arguments que un programa requereix.
- *Ús:* S'usa per definir els arguments que pot tenir un programa a l'hora de cridar-lo per línia de comandes.



## CAPÍTOL 7

# Anàlisi i disseny del sistema

En aquest capítol s'explica el disseny de cada part del sistema, específicament del processament de dades i la detecció de persones i porcs, i el disseny general del sistema, on també s'explica el funcionament del algorisme de seguiment. Al llarg del capítol hi ha diagrames, els quals estan codificats per colors: en blau allò dut a terme amb un programa de Python, en verd el dut a terme amb un programa de MATLAB i en vermell el dut a terme a mà.

## 7.1 Processament de dades

Com ja s'ha explicat a la secció 6.1 i es pot veure a la figura 7.1, es tenen tres datasets els quals han de ser processats per a poder fer-ne ús:

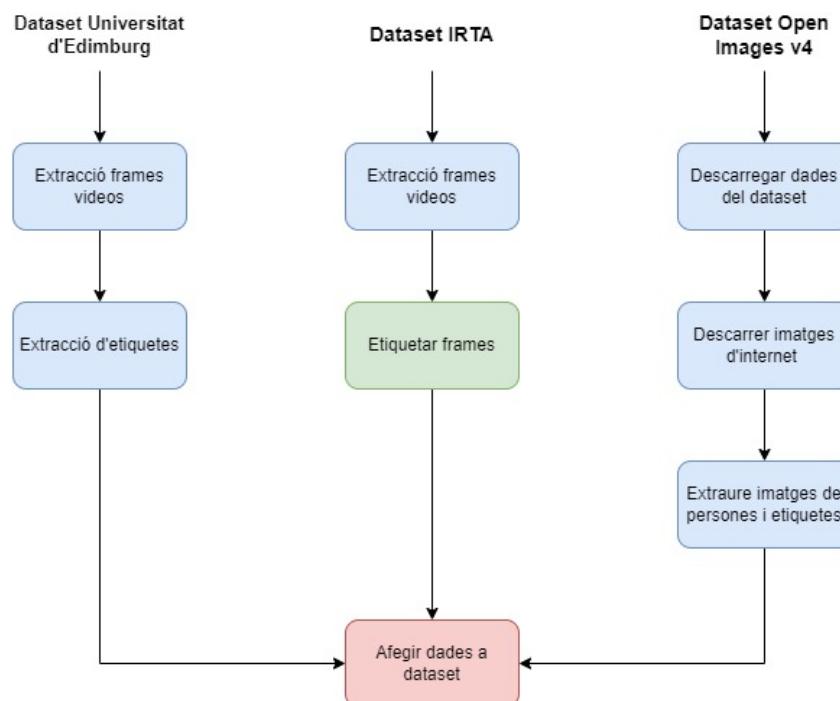


Figura 7.1: Diagrama del processament de dades

Aquests datasets han de ser convertits al format que es necessita per a entrenar i fer proves amb la xarxa neuronal. Aquest format, com es pot veure a la figura 7.2, consisteix en fitxers de text on cada línia correspon a una imatge etiquetada. Cada una d'aquestes conté el path absolut on la imatge està guardada a la màquina i, separat per espais, les coordenades i la classe de cada objecte etiquetat a la imatge. Aquestes etiquetes tenen el format [x\_min,y\_min,x\_max,y\_max,classe]. Com que només es treballa amb dos classes, s'ha arribat al consens de que la classe porcs serà l'indicador "0" i la classe persona serà l'indicador "1".

---

```

1 /home/virginia/TFG/PIGDATA2/frames_persona_cut/GH010013_zenital_Val_Pers_0.jpg
   ↳ 2,2,297,222,1
2 /home/virginia/TFG/PIGDATA2/frames_persona_cut/GH010013_zenital_Val_Pers_10.jpg
   ↳ 2,2,295,241,1
3 /home/virginia/TFG/PIGDATA2/frames/GH010013_zenital_Val_2010.jpg
   ↳ 609,757,1108,874,0 1089,820,1572,1015,0 1771,852,1921,948,0
   ↳ 1636,598,1921,822,0 1737,387,1921,621,0 1563,375,1774,489,0
   ↳ 1512,322,1774,394,0 1284,127,1377,261,0 1227,102,1285,163,0
   ↳ 1044,127,1261,244,0 993,204,1144,444,1

```

---

Figura 7.2: Exemple del format dels datasets

D'aquestes dades es generen tres datasets:

- *Entrenament*: Per entrenar la xarxa neuronal.
- *Validació*: Per a anar comprovant la correctesa els resultats generats per l'entrenament.
- *Testing*: Quan es té un resultat acceptable de validació, per comprovar que aquests resultats no són resultat del overfitting de la xarxa.

El dataset d'entrenament conté dades dels datasets de la Universitat d'Edimburg, de l'IRTA i del Open Images v4. Per la seva part, els datasets de validació i testing només contenen imatges de la Universitat d'Edimburg i de l'IRTA, ja que a la pràctica no ens interessa que la xarxa detecti coses com un vianant creuant el carrer, però sí que la xarxa tingui més dades per a conèixer el que és una persona, per tant, per validar i test amb les persones etiquetades de l'IRTA ja és suficient. A la taula de la figura 7.1 es pot observar quantes imatges de cada un dels datasets d'imatges s'utilitzen a cada dataset per a desenvolupar el model i a la figura 7.2 quantes etiquetes de persones i porcs hi ha de cada un dels datasets. Si s'analitzen aquestes dades, s'arriba a la conclusió de que s'ha

fet ús d'un 76% de les dades per a l'entrenament, un 13% per a la validació i un 11% per al testing.

		Dataset			Total
		Entrenament	Validació	Testing	
Imatges	Universitat d'Edimburg	4200	1395	1200	6795
	IRTA	2860	2595	1327	6792
	Open Images v4	8563	0	0	8563

Taula 7.1: Resum de les imatges usades dels datasets

			Dataset			Total etiquetes
			Entrenament	Validació	Testing	
Etiquetes	Universitat d'Edimburg	Porcs	33600	9600	9600	52800
		Porcs	8234	2639	979	11852
		Persones	2971	1439	1388	5798
		Persones	36563	0	0	36563
	Total etiquetes		81368	13678	11967	

Taula 7.2: Resum de les etiquetes usades dels datasets

### 7.1.1 Dataset Universitat d'Edimburg (porcs)

Aquest dataset conté seqüències de vídeo amb imatges com es mostren a la figura 7.3, de les quals algunes estan etiquetades en fitxers JSON (un per cada vídeo). Aquest fitxers JSON contenen informació del vídeo com en nom del fitxer, el seu path o la seva configuració, com es pot veure a la figura 7.4, i un registre de la posició de cada porc al llarg dels frames, com es pot veure a la figura 7.5, on per cada frame on el porc és visible es guarda la posició i mida de la bounding box del porc, si és ground truth, si aquest és visible i que està fent (ja que, com em dit abans, aquest dataset era usat per a analitzar el pressupost de temps diari dels animals). En el cas de l'ús que se'n fa en aquest projecte, només es necessita la informació de la bounding box a cada frame dels porcs.

D'aquest dataset s'extreuen frames separats entre si de les seqüències de vídeo etiquetades (per exemple els frames múltiples de 10), els quals es guarden a un repositori de la mateixa màquina, i es converteixen les seves etiquetes al format esmentat prèviament en aquest capítol (figura 7.2).



Figura 7.3: Exemple de fotogrames del dataset de la Universitat d'Edimburg

```

1 "videoFileName": "color(4).mp4",
2 "fullVideoFilePath":
   ↳ "test_pigs_11_11_19/2019-11-11--11:34:50/000028/color.mp4",
3 "stepSize": 0.1,
4 "config": {"stepSize": 0.1, "playbackRate": 0.4, "imageMimeType": "image/jpeg",
   ↳ "imageExtension": ".jpg", "framesZipFilename": "extracted-frames.zip",
   ↳ "consoleLog": false}

```

Figura 7.4: Informació del vídeo en fitxer JSON

```

1 {"frames": [{"frameNumber": 0, "bbox": {"x": 472, "y": 81, "width": 269, "height": 145},
   ↳ "isGroundTruth": true, "visible": true, "behaviour": "sleep"},
   ↳ {"frameNumber": 82, "bbox": {"x": 469, "y": 81, "width": 273, "height": 145},
   ↳ "isGroundTruth": true, "visible": true, "behaviour": "sleep"}, , , ...}], "id": "1"}

```

Figura 7.5: Dades de les bounding boxes en fitxer JSON

### 7.1.2 Dataset IRTA (porcs i persones)

Aquest dataset conté seqüències de vídeo amb imatges com es poden observar a la figura 7.6, les quals no estan etiquetades.



Figura 7.6: Exemple de fotogrames del dataset de l'IRTA

Al igual que amb el dataset anterior, també s'extreuen i es guarden alguns dels frames d'aquestes seqüències, però, pel que fa a les etiquetes, han de ser creades. Aquestes etiquetes es creen amb un programa de MATLAB i es guarden directament al format de la figura 7.2.

Com que la proporció de persones i porcs a cada imatge és desproporcionada, ja que per cada persona hi ha una gran quantitat de porcs, s'han extret retalls d'alguns dels frames de persones per a poder tenir més quantitat d'imatges de persones. Al igual que el procés d'etiquetat, això també s'ha fet amb un script de MATLAB. A la figura 7.7 es pot veure algunes de les imatges resultants d'aquest procés.



Figura 7.7: Exemple de fotogrames de persones dataset de l'IRTA

### 7.1.3 Dataset Open Images v4 (persones)

Open Images v4 és un dataset d'aproximadament 9 milions d'imatges que s'han anotat amb etiquetes a nivell d'imatge, quadres delimitadors d'objectes i relacions visuals. El conjunt d'entrenament de v4 conté 14,6 milions de caixes delimitadores per a 600 classes d'objectes en 1,74 milions d'imatges, el que el converteix en el conjunt de dades més gran existent amb anotacions d'ubicació d'objectes [8]. A la figura 7.8 es poden observar algunes de les imatges de persones d'aquest. D'aquestes imatges, en aquest projecte només s'han extret 8562 imatges aleatòries amb etiquetes de persones per afegir al dataset d'entrenament. Per a fer-ho, hi ha hagut que descarregar les dades del dataset (URL de les imatges i les seves etiquetes), les quals estan registrades en fitxers .CSV, descarregar aquestes imatges a un repositori de la màquina i transformar les etiquetes d'aquestes al format de la figura 7.2.



Figura 7.8: Exemple de fotogrames de persones del dataset de Open Images v4

## 7.2 Detecció de persones i porcs

Per a desenvolupar el model de xarxa neuronal per a la detecció de persones i porcs, l'arquitectura de la qual està explicada a la secció 7.2.2, s'ha dut a terme el procés de la figura 7.9. Inicialment es varen definir uns datasets d'entrenament i validació amb imatges del dataset d'Open Images v4 i la Universitat d'Edimburg. Seguidament es varen definir els paràmetres a entrar a la xarxa i es va entrenar. Amb la validació es va fer un anàlisi dels resultats d'aquest entrenaments. El resultat no era dolent, però la detecció de persones no era la esperada. Paral·lelament va arribar el dataset de l'IRTA, el qual va permetre tenir ambdues classes en el mateix espai, per tant es va poder prescindir de les imatges d'Open Images v4 a la validació. Es va repetir aquest procés de millorar el dataset, afegint o canviant dades i paràmetres, entrenar i analitzar resultats fins a aconseguir un resultat acceptable, per a poder començar a treballar en conjunt amb l'UKE.

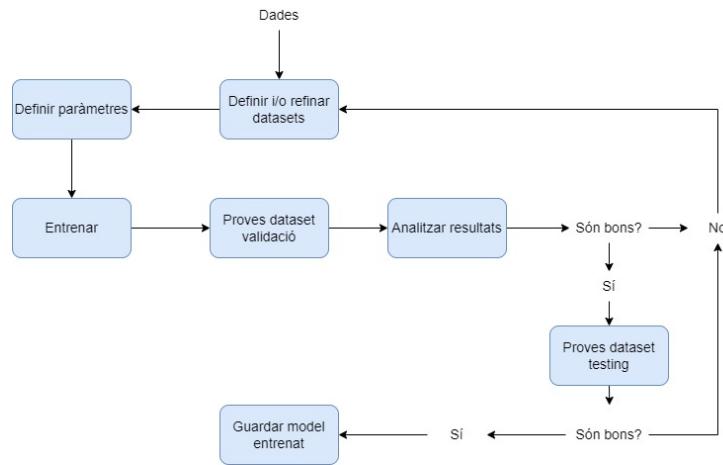


Figura 7.9: Diagrama del desenvolupament del model de la YOLOv4

A la figura 7.10 es poden observar com es mostren els resultats d'aquesta detecció: caixes blaves que indiquen la posició d'un objecte, amb el nom de la classe a la que pertany i la probabilitat amb la que ha identificat aquest objecte.

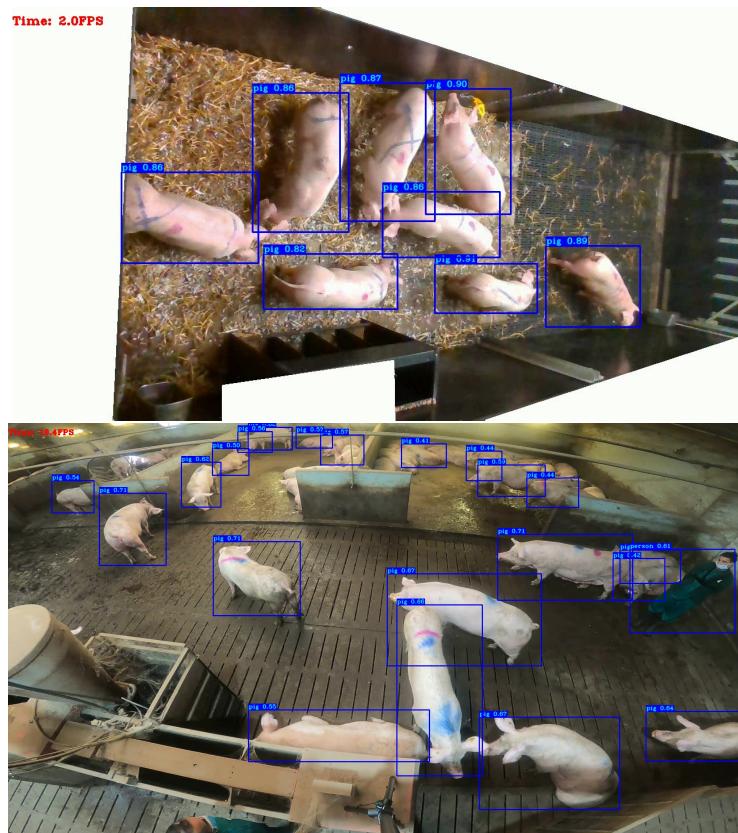


Figura 7.10: Exemple de resultats del model entrenat de la YOLOv4

### 7.2.1 Quantificació del error del model

Per quantificar l'error del model entrenat es fan ús de dos grups d'error o pèrdues:

1. *IoU*: Intersection over Union és una mètrica d'avaluació que s'utilitza per mesurar la precisió d'un detector d'objectes en un conjunt de dades concret [35]. Aquesta està basada en l'índex de Jaccard que és una mesura de semblança i diversitat entre conjunts de mostres finits, com es pot veure figura 7.11. IoU fa ús d'aquest mètode però amb les àrees de dos regions d'interés, com es pot veure a la figura 7.12.

$$J(A, B) = \frac{A \cap B}{A \cup B}$$

Figura 7.11: Càcul del index de Jaccard entre dos conjunts A i B

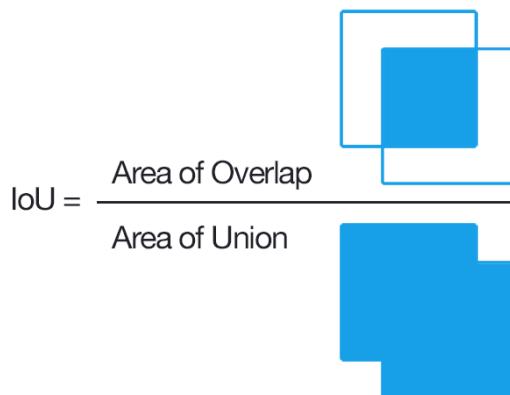


Figura 7.12: Càcul del IoU [35]

2. *Pèrdues del entrenament*:

- (a) *GIoU loss*: GIoU és una millora d'IoU, la qual inclou la forma i l'orientació de l'objecte a més de l'àrea de cobertura. [36] van proposar trobar la regió d'interès d'àrea més petita que pugui cobrir simultàniament l'àrea d'interès de la prediccio i l'àrea d'interès real, i utilitzar aquesta àrea com a denominador per substituir el denominador utilitzat originalment a l'IoU.
- (b) *Confidence loss*: Quantifica el segur que està la xarxa de la prediccio que fa de la regió d'interès. S'espera que la prediccio tingui una confiança d'1 quan hi ha objecte i de 0 quan no n'hi ha. Aquesta pèrdua quantifica quan dista la prediccio d'aquests valors esperats.

- (c) *Probability loss*: Quantifica el segur que està la xarxa de la predicción que fa de la classe de la regió d'interès. S'espera que la predicción tingui una probabilitat d'1 quan un objecte és d'una classe i de 0 de la resta de classes. Aquesta pèrdua quantifica quan dista la predicción d'aquests valors esperats.
  - (d) *Total loss*: Correspon a la suma dels tres errors esmentats anteriorment.
3. *mAP*: Average Precision (AP) o precisió mitjana és una mètrica d'avaluació per quantificar com de bona és la predicción de la xarxa en una classe comparant quantes prediccions correctes i incorrectes fa. Mean Average Precision (mAP) és el valor mitjà del AP d'un grup de classes.

### 7.2.2 Arquitectura de la YOLOv4

Com es pot observar a la figura 7.13, els models de detecció d'objectes es poden classificar en models d'una o dos etapes. Els models d'una etapa són capaços de detectar objectes sense necessitat d'un pas preliminar per a detectar regions d'interès a les imatges, a diferència dels models de dos etapes. Això fa que els models d'una etapa puguin treballar en temps real. En el cas d'aquest projecte es fa ús de la YOLOv4, model d'una etapa. Si s'observa una altra vegada la figura 7.13, es mostra que aquest tipus de model té una arquitectura en quatre parts:

1. *Input*: Poden ser imatges, piràmides d'imatges o pegats.
2. *Backbone*: És una xarxa neuronal profunda composta principalment per capes de convolució el objectiu principal de la qual és extreure les característiques essencials.
3. *Neck*: El rol principal d'aquest és recollir mapes de característiques de diferents etapes.
4. *Head*: És la predicción final, anomenada Dense Prediction, que es compon d'un vector que conté les coordenades del quadres delimitadors prevists o bounding boxes, la puntuació de confiança de la predicción i l'etiqueta.

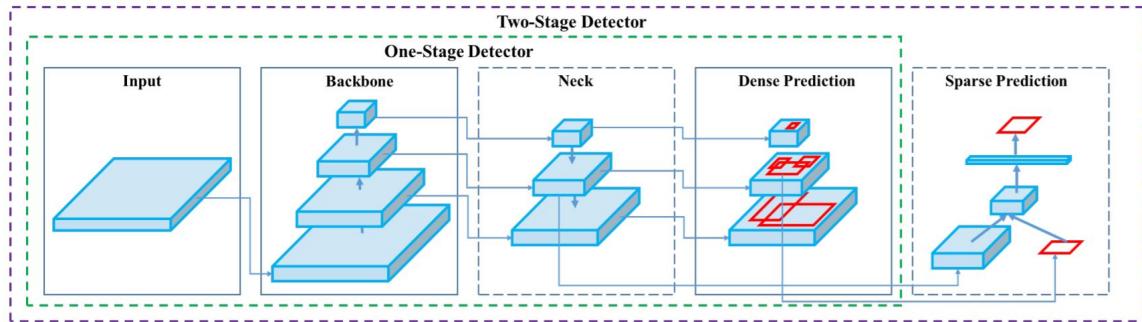


Figura 7.13: Object detector [3]

Si es parla específicament de la YOLOv4 utilitzada, aquestes quatre parts queden tal que:

1. *Input*: Imatges dels datasets de la secció 7.1
2. *Backbone*: S'utilitza la CSPDarknet53 [37] com a backbone.
3. *Neck*: En aquesta fase s'utilitza Path Aggregation Networks o PANet [38] concatenades amb mòduls de l'Spatial Pyramid Pooling o SPP [39].
4. *Head*: Per a la predicció es fa ús de la versió anterior d'aquesta xarxa, la YOLOv3.

### 7.3 Disseny general del sistema

Si es mira com funciona l'Unscented Kalman Filter en aquest projecte conseqüentment s'ha de parlar també de com s'ha acoblat la xarxa neuronal en aquest, per tant en aquesta secció es parlarà directament del funcionament general del sistema, és a dir, l'UKF en combinació amb la xarxa.

A la figura 7.14 es pot observar com funciona el sistema de dalt a avall:

1. Donada una seqüència de vídeo, per cada frame d'aquest es fa la detecció de persones i porcs amb el model entrenat de la YOLOv4.
2. Seguidament es comprova si el sistema tenia registrat algú track (s'entén per track el registre del moviment o trajectòria fet per un objecte) prèviament.
3. Si existeixen tracks:

- (a) Per cada ROI (Regions d'interès o Regions of Interest en anglès, és a dir, les deteccions resultants) detectada es dibuixa la ROI al frame i es calcula l'IoU entre la ROI i l'última ROI registrada a cada track.
  - (b) Quan ja es tenen tots els IoUs de totes les ROIs i els tracks, s'assigna cada ROI nova amb un dels tracks sense repetir-les fent ús del algorisme hongarès. Aquest algorisme és un algorisme d'optimització per a la resolució de problemes d'assignació amb cost mínim [40].
  - (c) Si hi ha més ROIs noves detectades que tracks o hi ha deteccions no assignades, es crea un nou track per cada una d'aquestes deteccions no assignades.
  - (d) Si hi ha més tracks que ROIs detectades o hi ha tracks no assignats, per cada un d'aquests es comprova si du més d'un nombre definit de frames sense tenir nova assignació de ROI. Si és així aquest track s'elimina de la llista, altrament s'agafa l'última ROI registrada d'aquest track i es traslada seguint la predicció que fa el filtre de Kalman del moviment que ha pogut fer l'objecte del frame anterior a aquest.
4. Si no existeixen tracks, es crea un track per cada ROI detectada.
  5. Finalment s'actualitza l'estat de cada track i es passa al següent frame.

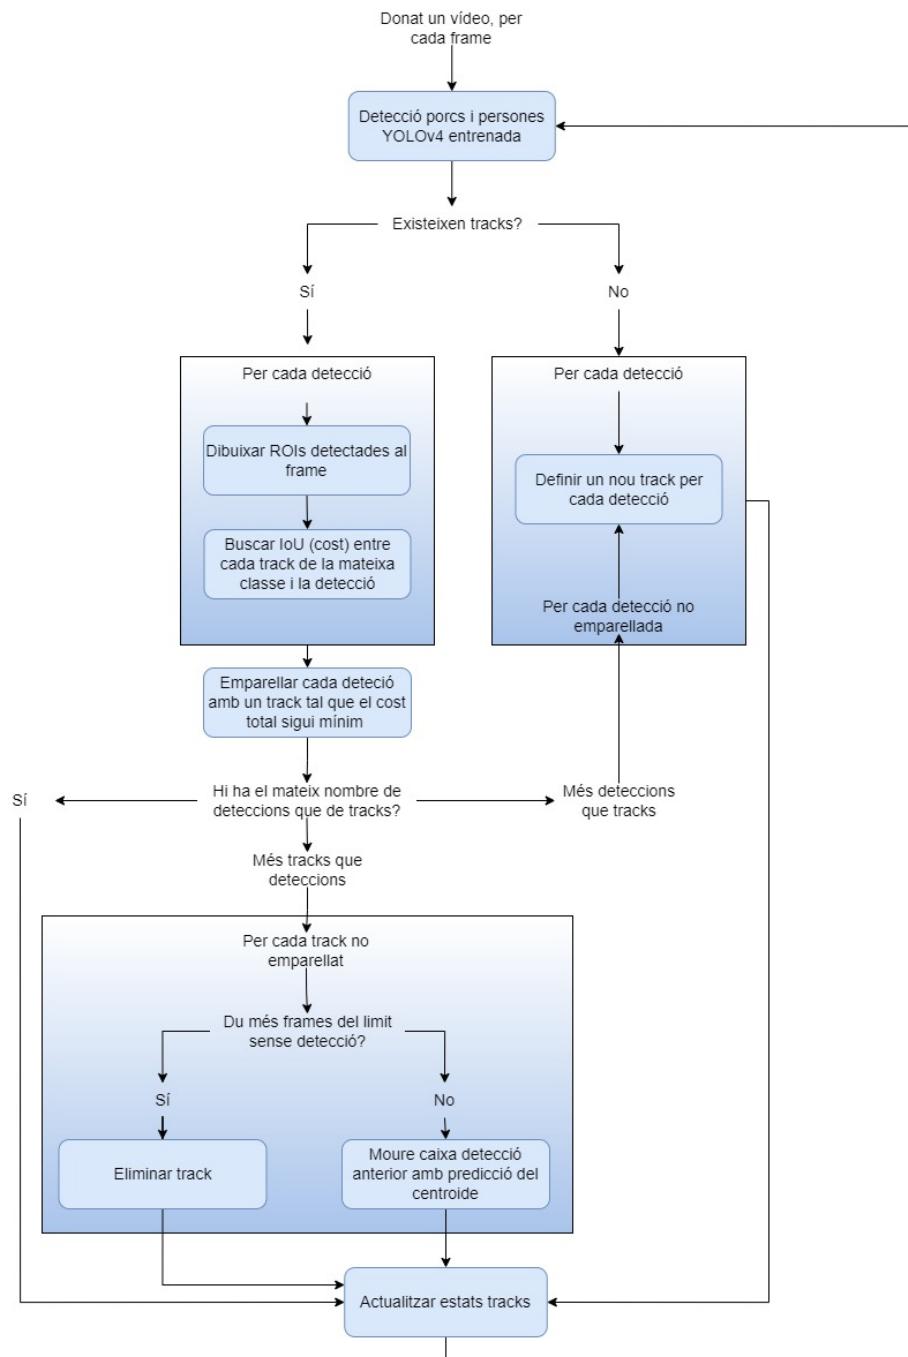


Figura 7.14: Diagrama del funcionament del sistema sencer

## CAPÍTOL 8

# Implementació i proves

---

En aquest apartat s'explicarà com s'ha implementat cada part del sistema i es presentarà com s'han dut a terme les proves de cada part. Els resultats finals d'aquestes proves es presentarà al capítol 9 de resultats.

## 8.1 Processament de dades

Si es torna a l'apartat 6.1, s'ha indicat com s'ha fet ús de cada dataset d'imatges de les que es disposava. En aquesta secció s'explicarà en detall com s'ha dut a terme el processament d'aquestes dades per a ser aptes per al seu ús en aquest projecte.

### 8.1.1 Implementació

#### 8.1.1.1 Extracció de les dades del dataset de la Universitat d'Edimburg

Per extraure els frames i les etiquetes del dataset de porcs de la Universitat d'Edimburg s'ha creat un programa de Python que fa ambdues coses (annex B.2.1). Aquest programa processa tot el repositori de vídeos etiquetats d'una vegada. Tant per extraure els frames com les etiquetes, aquest programa recorr tots els subrepositoris d'un repositori d'anotacions i vídeos, per cada qual du a terme:

- *Extracció de frames:* Llegeix el vídeo i, per cada frame, aplica una màscara a la imatge (figura 8.1), ja que només es vol que la xarxa processi una part de la imatge, i guarda el frame a un repositori existent amb el nom del video i el número de frame que és.
- *Extracció d'etiquetes:* Per cada fitxer .JSON d'etiquetes (un per cada video) llegeix el fitxer sencer i guarda a una taula per cada frame les dades de cada porc que apareix en ella. Per fer això llegeix el registre de cada animal i, per cada frame al que surt, afegeix les dades a la taula. Aquestes dades es guarden en el format esmentat al capítol anterior generant un fitxer tipus text per cada vídeo.



Figura 8.1: Processament frames Universitat d'Edimburg on: a) Frame, b) Màscara, c) Frame amb màscara aplicada

### 8.1.1.2 Extracció dels frames del dataset de l'IRTA

Com ja s'ha mencionat, s'han extret frames de les seqüències de vídeo dels datasets de l'IRTA per a poder entrenar la xarxa i fer proves. Per a fer això s'ha creat un programa de Python (annex B.2.2), el qual extrau frames d'una seqüència. Per a fer-ho, llegeix un vídeo ubicat a la màquina frame a frame, mantinguent un comptador general que du el seguiment del frame que s'està processant. Per cada frame, es comprova si aquest comptador indica que és un frame múltiple d'un valor (per no extreure frames molt seguits i evitar tenir la mateixa informació repetida), ja pot ser 10, 20, 30..., i, si ho és, guarda la imatge a un repositori existent amb el nom del video i el comptador en format .JPG.

### 8.1.1.3 Etiquetat de les dades del dataset de l'IRTA

Per a etiquetar els frames extrets de l'IRTA s'ha creat un codi de MATLAB (annex B.2.4) el qual du a terme els següents passos:

1. Llegir els fitxers que hi ha a un repositori entrat, per a tenir un registre de les imatges que hi ha.
2. Per a un grup d'aquestes imatges (ja que per a grans quantitats d'imatges és difícil etiquetar-les totes d'una):
  - (a) Mostrar la imatge per pantalla.
  - (b) Bucle que permet etiquetar tots els porcs a mà dibuixant un rectangle sobre la imatge per cada porc.
  - (c) Bucle que permet etiquetar totes les persones a mà dibuixant un rectangle sobre la imatge per cada persona.
  - (d) Guardar la informació de la imatge i les caixes creades per cada classe a un registre.
3. Guardar aquest registre de dades a un fitxer amb el format esmentat anteriorment.

### 8.1.1.4 Extracció de persones del dataset de l'IRTA

Per a extreure imatges de només persones, s'ha creat un codi de MATLAB (annex [B.2.5](#)) per a dur-ho a terme. Aquest codi té una estructura similar al anterior, ja que és una modificació d'aquest:

1. Llegir els fitxers que hi ha a un repositori entrat, per a tenir un registre de les imatges que hi ha.
2. Per a un grup d'aquestes imatges (ja que per a grans quantitats d'imatges és difícil etiquetar-les totes d'una):
  - (a) Mostrar la imatge per pantalla.
  - (b) Dibuixar una caixa al voltant de la persona a retallar.
  - (c) Retallar i guardar imatge a un repositori.
  - (d) Generar coordenades d'una regió d'interès, essent les mesures de la imatge menys dos pixels (ja que la xarxa treballa amb regions d'interès).
  - (e) Guardar la informació de la imatge i la caixa creada.
3. Guardar aquest registre de dades a un fitxer amb el format esmentat anteriorment.

### 8.1.1.5 Processament de les dades d'Open Images v4

Pel que fa al processament de les dades del Open Images v4, s'ha creat un Python Notebook (annex [B.2.6](#)) el qual du a terme els següents passos:

1. Descarrega i llegeix els fitxers .CSV que contenen les dades d'aquest dataset.
2. D'aquestes dades, s'extrauen totes les que contenen objectes etiquetats com a persona.
3. D'aquestes etiquetes es seleccionen un nombre n d'etiquetes aleatòries.
4. Es descarreguen a la màquina les imatges que contenen aquestes etiquetes i es divideixen en dos grups: per a entrenar i per a validar.
5. Per les imatges d'entrenament i validació:
  - (a) Extraure les dades de les imatges i les etiquetes.
  - (b) Guardar les dades a un fitxer amb el format necessari.

## 8.2 Detecció de persones i porcs

### 8.2.1 Implementació

Pel que fa a la detecció de persones, s'ha fet ús d'una implementació ja feta [29] en Python de la xarxa neuronal YOLOv4. Amb aquesta implementació s'ha entrenat i dut a terme proves per a comprovar els resultats d'aquest entrenament. Alguns d'aquests fitxers han estat modificats per a complir els requisits del sistema.

#### 8.2.1.1 Entrenament

L'entrenament de la xarxa s'ha fet amb un programa de Python "train.py" (annex C.3.5). Aquest programa fa ús d'un fitxer de Python que conté tots els paràmetres que s'usen a la configuració de la xarxa (annex C.3.1). Aquest programa consta de les següents etapes:

1. Carregar els pesos del model sobre el que es vol treballar, en aquest cas els pesos de la YOLOv4 Darknet [10].
2. Crear un fitxer de registre del procés d'entrenament, on per cada cicle d'entrenament es registra els valors del error.
3. Carregar els datasets d'entrenament i de validació.
4. Definir el nombre d'epochs (cicles d'entrenament) i la seva llargària.
5. Comprova si es vol entrenar des dels pesos de la Darknet, des d'un entrenament anterior o si es vol entrenar de zero i es crea la xarxa neuronal amb els pesos pertinents.
6. S'escull l'optimitzador a usar per a entrenar, en aquest cas l'optimitzador d'Adam, el qual és un mètode de descens de gradient estocàstic que es basa en l'estimació adaptativa de moments de primer i segon ordre. Segons [41] el mètode és "computacionalment eficient, té pocs requisits de memòria, invariant a la reescalada diagonal dels gradients i és molt adequat per a problemes que són grans en termes de dades/paràmetres".
7. Es defineix una funció "train\_step" la qual du a terme un cicle d'entrenament del model amb un dataset d'entrenament. Això ho du a terme fent prediccions en grups d'imatges i es guarda l'error o loss a un registre i es fa el gradient d'aquest per a, amb l'optimitzador, aplicar un canvi petit als pesos del model per a intentar reduir l'error. Seguidament es calculen els errors presentats a "Perdues del entrenament" a la secció 7.2.1, es mostren, es guarden a un registre i es retornen.

8. Es defineix una funció "validate\_step" la qual du a terme un cicle de validació del model comprovant els resultats de fer prediccions amb el model entrenat a un dataset de validació. Això ho fa seguint el mateix mètode de la funció "train\_step" però sense aplicar cap canvi al model. Finalment també es calculen els errors, es mostren, es guarden a un registre i es retornen.
9. Per cada cicle d'entrenament:
  - (a) Es fa un cicle d'entrenament amb la funció "train\_step" i es mostren els errors resultants.
  - (b) Si hi ha dataset de validació es fa una validació dels resultats amb la funció "validate\_step". Seguidament, donat els errors, es comprova si per paràmetres s'ha indicat si es volen guardar tots els models entrenats a cada cicle o el model amb menys error de validació. En el cas d'aquest projecte només es guarda el model amb menys error ja que guardar-los tots ocupa molta memòria.
10. Finalment, qual el model està entrenat, es comprova el valor del mAP per cada classe i en general per al model entrenat.

### 8.2.1.2 Predicció en imatges i seqüències de vídeo

Per a provar la predicció del model entrenat en imatges i seqüències de vídeo s'ha fet ús d'un programa de Python (annex C.3.6) el qual, donat una imatge o un vídeo emmagatzemat a la màquina, crea el model de la xarxa neuronal amb els pesos del entrenament i crida la funció "detect\_image" si rep una imatge o "detect\_video" si rep una seqüència de vídeo. Aquestes funcions generen una còpia del fitxer original de imatge que ara conté també les deteccions marcades i retorna el llistat de deteccions fets i les classes a les que pertanyen. A la figura 8.2 es poden veure dos exemples de resultats.

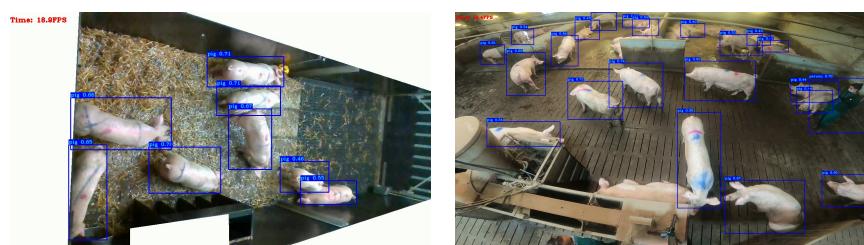


Figura 8.2: Processament frames Universitat d'Edimburg on: a) Frame, b) Màscara, c) Frame amb màscara aplicada

### 8.2.2 Proves

Per fer les proves s'ha fet ús d'un programa de Python que comprova el mAP de les prediccions d'un dataset entrat (annex C.3.7) i el programa per a la detecció presentat anteriorment. En les següents proves es farà ús dels següents termes:

- *Score threshold*: Aquest valor correspon a la probabilitat mínima de confiança de la predicció per a ser acceptada.
- *IoU threshold*: Aquest valor correspon al valor mínim que han de tenir dos regions d'interès d'IoU per a identificar-les com a una mateixa detecció, és a dir, un mateix objecte.

Aquestes proves han servit per a refinar els datasets i els paràmetres utilitzats a l'entrenament. A l'hora de modificar paràmetres d'una xarxa neuronal, prioritariament es modifiquen els següents:

1. *Learning Rate (LR)*: La tasa d'aprenentatge o Learning Rate defineix la mida del pas a cada iteració que fa l'entrenament mentre es mou cap a un mínim d'una funció de pèrdua.
2. *Mida del batch*: La mida del lot o batch és el nombre de mostres processades abans d'actualitzar el model durant l'entrenament.
3. *Nombre de capes i neurones de la xarxa neuronal*.

Com que en aquest projecte s'ha fet ús de la YOLOv4, la qual ja té aplicació en la detecció d'objectes i està demostrat que funciona bé per a aquest fi, s'ha decidit centrar-se en fer proves amb el LR i la mida del batch, deixant de costat fer modificacions de l'arquitectura.

Si es parla de la mida del batch, s'han fet diferents proves amb 1, 2, 4 i 6 mostres per cada iteració. Es va arribar a la conclusió de que 1 i 2 no era un bon nombre per al batch ja que el temps de processament de cada iteració resultarà en un temps molt alt per cada entrenament. Al provar 4 i 6 es va veure que ambdós podrien ser bones opcions com a batch size ja que reduïa el temps d'entrenament notablement i els resultats eren bons. Finalment es va decantar per 4, ja que 6 donava lleugerament pitjors resultats en algunes proves realitzades.

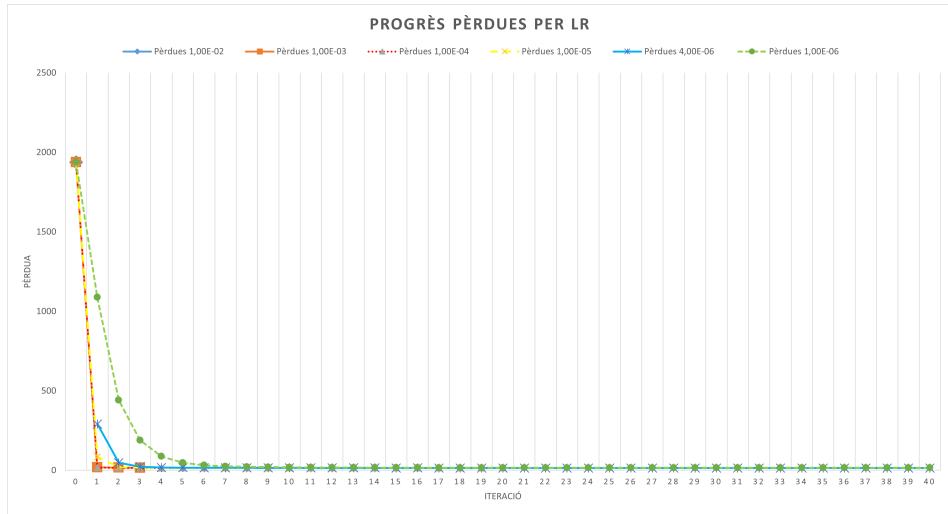


Figura 8.3: Gràfic de la comparació del progrés de la pèrdua total al llarg dels entrenaments amb diferents Learning Rates

Pel que fa al Learning Rate, s'han fet diferents entrenaments per a comparar com progressen els resultats comparant les pèrdues totals de cada iteració per a uns quants LRs amb valors entre  $1e-6$  a  $1e-2$ . Si s'observa la figura 8.3 i la taula 8.1 es pot veure que com, amb valors petits de LR com  $1e-6$  tarda bastants epochs en arribar al mínim, en comparació a  $4e-6$ , que tarda 6 epochs en comparació als 40 que tarda  $1e-6$  a arribar a valors al voltant del 15. Si es passa a  $1e-5$  s'arriba en 4 epochs i amb  $1e-4$  s'arriba en 2. Amb valors grans com  $1e-3$  o  $1e-2$  s'observa que en els primers epochs té error "nan" el que vol dir que hi ha hagut inconsistències numèriques, com seria dividir per 0 qualsevol valor, per tant es demostra que valors grans no són una bona elecció. Entre  $1e-4$  i  $1e-6$  es veu que més de la meitat de l'entrenament es queda al voltant dels 14 o els 15 i avança molt lentament.

Aquestes proves han servit per a definir els paràmetres a utilitzar a l'hora de fer les proves per als resultats finals.

		Learning Rate					
		1e-2	1e-3	1e-4	1e-5	4e-6	1e-6
Epoch	0	1938.35	1938.35	1938.35	1938.35	1938.35	1938.35
	1	nan	19.004	17.451	84.404	290.464	1109.10
	2	nan	16.881	15.465	21.109	47.421	454.646
	3	nan	16.065	15.272	16.492	22.974	187.491
	4	nan	nan	14.715	15.312	17.689	86.318
	5	nan	nan	15.099	14.913	16.359	47.679
	6	nan	nan	15.218	15.153	15.969	32.311
	7	nan	nan	15.532	14.681	15.678	25.756
	8	nan	nan	15.215	14.851	15.812	22.828
	9	nan	nan	15.729	14.789	15.400	21.129
	10	nan	nan	15.319	14.764	15.524	20.049
	11	nan	nan	16.078	14.790	15.269	19.348
	12	nan	nan	15.389	14.594	15.121	18.825
	13	nan	nan	15.655	14.742	15.084	18.508
	14	nan	nan	15.429	14.691	14.897	18.292
	15	nan	nan	15.706	14.746	14.833	17.997
	16	nan	nan	15.125	14.694	14.909	17.898
	17	nan	nan	15.268	14.755	14.738	17.832
	18	nan	nan	15.607	14.737	14.660	17.713
	19	nan	nan	15.951	14.689	14.771	17.674
	20	nan	nan	15.894	14.712	14.633	17.583
	21					14.621	15.975
	22					14.579	15.892
	23					14.688	15.790
	24					14.637	15.799
	25					14.654	15.740
	26					14.602	15.687
	27					14.566	15.636
	28					14.554	15.645
	29					14.537	15.589
	30					14.556	15.624
	31					14.597	15.619
	32					14.557	15.608
	33					14.542	15.571
	34					14.580	15.614
	35					14.567	15.606
	36					14.617	15.558
	37					14.575	15.598
	38					14.600	15.574
	39					14.545	15.539
	40					14.521	15.514

Taula 8.1: Progrés del loss de cada epoch dels diferents entrenaments donat el seu Learning Rate

## 8.3 Disseny general del sistema

### 8.3.1 Implementació

Pel que fa a la implementació general del sistema, formada per la detecció amb la YOLOv4 i l'algorisme UKF, s'explicarà com s'ha implementat el procés mostrat a la figura 7.14. Aquesta implementació és una modificació d'una implementació ja feta [31] programada en Python. En aquesta implementació s'ha modificat la detecció per fer-la amb la implementació explicada anteriorment, l'associació de ROIs i tracks s'ha canviat d'associació per distància dels centroides d'aquests (amb la Mean Squared Distance) a millor IoU, s'ha afegit la comprovació de que la ROI i el track tinguin la mateixa classe i que els tracks tinguin un registre de ROIs del objecte. Aquesta segueix els següents passos:

1. Inicialment, al fitxer "object\_tracking.py" (Annex D.4.3), es defineix el path de la seqüència de vídeo la qual analitzar, és a dir, fer la detecció i el seguiment, i el path on guardar la seqüència resultant.
2. Es crea el model de la YOLOv4 per a fer la detecció.
3. S'inicialitza el registre de tracks amb la classe "Tracker" definida al fitxer "tracker.py" (Annex D.4.2). Aquesta classe s'encarrega de definir cada registre i aplicar-ne l'UKF.
4. Per cada frame de la seqüència de vídeo:
  - (a) Es fa la detecció de porcs i persones fent ús de la funció "detect" definida al fitxer "frame\_detection.py" (Annex D.4.5):
    - Aquesta funció rep una imatge i una xarxa neuronal YOLOv4 i crida la funció "detect\_frame" definida al fitxer "utils.py" (Annex C.3.3) introduït anteriorment la qual fa la detecció de les ROIs de la imatge amb el model rebut i retorna un llistat de ROIs i la llista de classes.
    - Seguidament mostra el temps que ha tardat en fer la detecció i el nombre de deteccions resultant.
    - A continuació dibuixa sobre la imatge totes les ROIs i indica de quina classe és.
    - Finalment retorna la llista de centroides de les ROIs detectades i les mateixes ROIs.
  - (b) Seguidament es fa l'actualització dels tracks amb les noves ROIs. Aquesta actualització es fa amb una funció de la classe "Tracker" introduïda, "Update":

- Si no existeixen tracks, es crea un track nou per cada ROI detectada.
- Si existeixen tracks:
  - Per cada ROI i cada track es calcula l'IoU entre ells, específicament 1-IoU ja que l'algorisme d'associació, l'algorisme Hongarès, busca el menor valor de cost i l'IoU dona valor més gran quant més coincideixen.
  - Quan ja s'han associats les ROIs i els tracks es comprova si hi ha tracks sense assignació o si alguna de les assignacions té un valor d'IoU fora del rang acceptat i passen a ser no assignats.
  - En aquests tracks no assignats es comprova si duen més d'un nombre definit de frames sense detecció i, si és el cas, s'elimina el track del registre.
  - Es comprova si hi ha ROIs sense assignar i, si és el cas, es crea un nou track per cada un d'aquests.
  - S'actualitza el Filtre de Kalman de cada track, en aquest cas del UKF. En aquest projecte l'UKF està definit com a una classe "UKF" definida en el fitxer "ukf.py" (Annex D.4.1), la qual té definides les funcions "predict" i "update" que fan la predicción i l'actualització del filtre seguint les equacions explicades a la secció 5.2.1.
  - Per cada track es crida la funció "predict" la qual du a terme un "prediction step", que bàsicament consisteix en predir el moviment que l'objecte ha dut a terme en una quantitat de temps indicada des de l'última predicción. Inicialment propaga els punts sigma (les mostres) de la funció no lineal de moviment amb una funció "iterate\_x". A partir d'aquestes mostres es calcula l'estat "x\_out", que passa a ser l'estat "x", i la nova covariància "p\_out" a la qual se li afegeix el soroll del procés "q". Aquesta "p\_out" calculada passa a ser la nova "p".
  - Quan ja ha fet la predicción, crida a la funció "update" per dur a terme l'actualització del estat i aconseguir l'estimació real del estat "x" donada la mesura del centroide de la ROI assignada, si en té.
- Quan ja es té el nou estat "x" i conseqüentment la predicción del desplaçament fet des del frame anterior al actual, si el track actual no té mesura, és a dir, nova ROI, es desplaçarà l'última ROI

registrada d'aquest seguint la posició predicta pel filtre per a poder calcular l'IoU "correctament" al següent frame.

- (c) A continuació, per cada track, es dibuixa sobre el frame la línia del moviment fet l'últim nombre definit de frames de la seqüència (només per veure el moviment de cada objecte sense plenar tota la imatge de línies les quals no es distingeixen).
- (d) Finalment es guarda el frame amb totes les annotacions fets a la seqüència de vídeo resultant.

### 8.3.2 Proves

Pel que fa a les proves, s'ha fet ús del fitxer "object\_tracking.py". Aquest filtre no ha necessitat de moltes proves ja que inicialment ja funcionava i la part que més afecta als resultats que dona és la detecció explicada anteriorment, per tant quasi totes les proves han set de la detecció en si.

Algunes de les proves fets han set per a definir el valor de la matriu de covariància del soroll de la mesura "R" del fitxer "tracker.py" per a fer el filtre més "tranquil", ja que les prediccions d'aquests depenen molt de les deteccions de la xarxa i, com s'ha esmentat, aquestes encara són molt variables. Si s'observa la figura 8.4, es pot veure clarament l'efecte d'augmentar el valor d'aquesta matriu, ja que si es comparen les imatges a, b i c, en ordre de menor a major valor R, es pot veure com les trajectòries dels porcs i la persona observada són més lineals a mesura que es va augmentant aquest valor. Quant més gran és aquest valor, però, la predicció es retarda més, és a dir, prediu que està una mica més enrere del que realment està, per tant no es pot fer aquest valor tan gran com es vol.

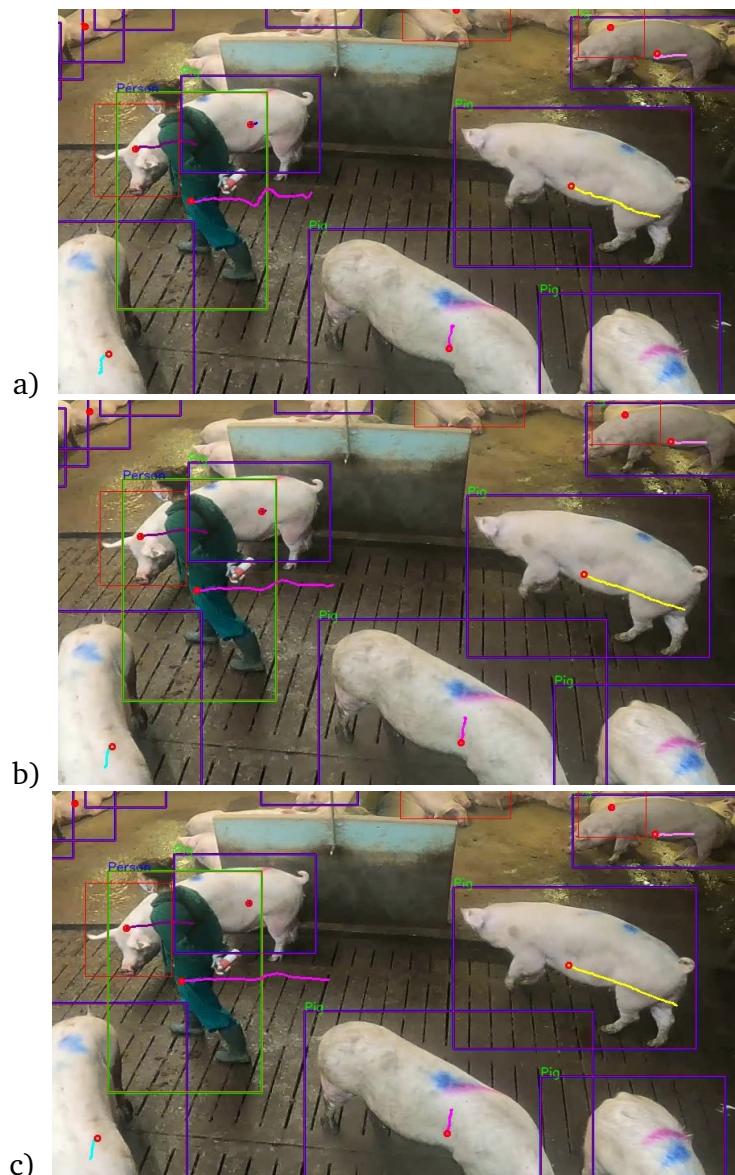


Figura 8.4: Comparació de la trajectòria predicta pel UKF per a tres valors de la matriu R: a) 0.1, b) 1.0 i c) 2.5.

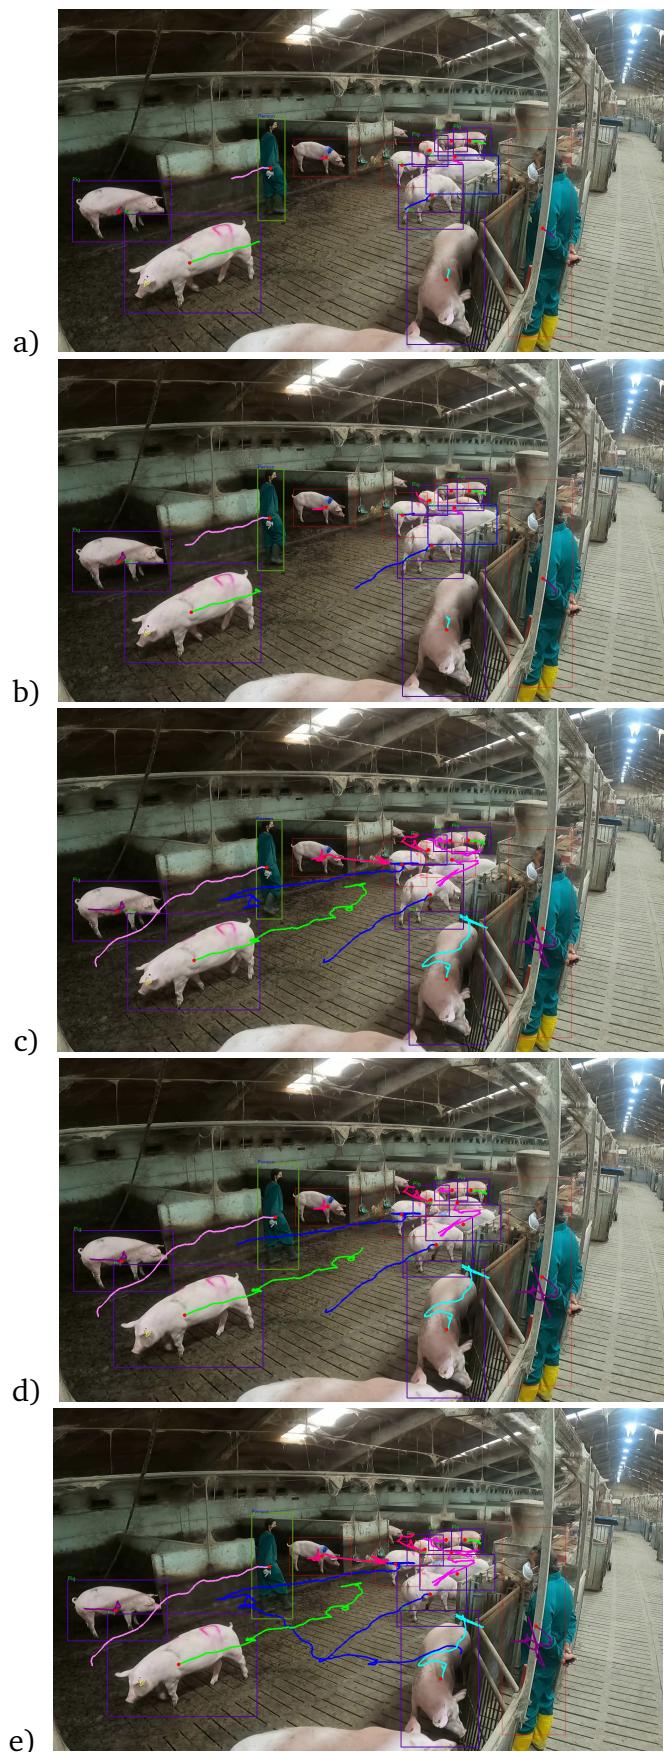


Figura 8.5: Visualització de llargària de trajectòries: a) 50, b) 100, c) 1000, d) 5000, e) Tota

A la vegada, s'ha definit un valor que restringeix la llargària de la trajectòria mostrada de cada objecte, en frames, ja que mostrar tota la trajectòria de cada objecte a la llarga fa que siguin indistingibles. S'han fet algunes proves comparant com es visualitzen les trajectòries per buscar un valor suficientment llarg per a poder seguir la trajectòria còmodament. A la figura 8.5 es pot observar la comparació de mostrar diferents llargàries de trajectòries. L'imatge a) mostra 50 frames de trajectòria, la b) 100, la c) 1000, la d) 5000 i la e) tota la trajectòria. En aquesta seqüència d'imatges en concret es pot veure com la c), la d) i la e) no són viables ja que no deixen visualitzar correctament totes les trajectòries, per tant, si es volen veure totes les trajectòries a la vegada tenint un nombre alt d'objectes i poder treure alguna conclusió, el millor valor és un valor entre 50 i 100.

A la secció 9.2 es presentaran els resultats finals de les proves i els errors més comuns donats. Aquestes proves s'han realitzat amb un valor d'R de 2.5 ja que dona trajectòries més llises i no retarda massa la trajectòria.

# CAPÍTOL 9

## Resultats

---

### 9.1 Detecció de persones i porcs

Com ja s'ha introduït en aquest document, es tenen dos datasets que contenen porcs, el de la Universitat d'Edimburg i el de l'IRTA, el primer dels quals es té una quantitat decent de dades etiquetades i amb un punt de vista de la càmera bastant beneficiós a l'hora de diferenciar els animals, mentre que el segon es caracteritza per ser dades menys controlades i marcades per la falta d'etiquetes. Aquesta diferència és visible al llarg dels resultats obtinguts.

La xarxa neuronal final ha set entrenada amb un LR de 5e-6, durant 50 epochs, amb un batch de 4. A la taula 9.1 es poden observar els resultats obtinguts a les diferents proves. Com es pot observar, es fa ús de tres score thresholds diferents i de quatre datasets:

- *Universitat d'Edimburg*: Dataset on només hi ha les imatges de validació i test del dataset de la Universitat d'Edimburg.
- *IRTA*: Dataset on només hi ha les imatges de validació i test del dataset de l'IRTA.
- *Dataset de validació*
- *Dataset de test*

Si es comparen els resultats entre els dos primers datasets en la classe porc, es veu que hi ha una diferència molt alta d'AP per a tots els score thresholds utilitzats, arribant a tenir una diferència de més del 30%. En ambdós casos l'AP es redueix notablement quan més gran es fa l'score threshold, passant del 92.55% al 26.32% al dataset de la Universitat d'Edimburg i del 59.56% al 14.21% al dataset del IRTA només amb una diferència de 0.2 de valor. Si es miren els resultats de les personnes de l'IRTA, es veu que són molt millors que els dels porcs, variant menys d'un 10% entre l'score threshold del 0.5 al 0.7, tinguent 96.56% i 86.77% respectivament. Això es dona perquè les personnes en aquest dataset duen sempre una indumentària similar, per tant ha pogut generalitzar-les millor que els porcs, els quals tenen marques pintades i tendeixen a estar molt junts. Si

es miren els datasets de validació i de test, es veu que els resultats són similars als del porc de la Universitat d'Edimburg, ja que una gran part de les mostres que es tenien venia d'aquest dataset, però l'AP es veu penalitzat per la presència d'imatges del IRTA pel que fa als porcs.

		Dataset										
		Universitat d'Edimburg		IRTA			Val			Test		
AP (en %)		Porc	Porc	Pers.	mAP	Porc	Pers.	mAP	Porc	Pers.	mAP	
Score thres.	0.5	92.55	59.56	96.56	78.06	87.31	96.87	92.09	87.57	96.25	91.91	
	0.6	68.76	37.74	93.07	65.40	61.76	93.33	77.54	66.37	92.80	79.58	
	0.7	26.32	14.21	86.77	50.49	21.20	86.73	53.96	28.17	86.82	57.49	

Taula 9.1: Resultats proves mAP als datasets en percentatges

Si es fa un anàlisi més exhaustiu dels resultats anteriors i es miren les deteccions que ha fet la xarxa a cada prova, com es pot veure a la figura 9.2, es reafirma el que ja s'havia dit anteriorment de que al model li costa més detectar els porcs del dataset del IRTA que del dataset de la Universitat d'Edimburg tot i que d'aquest últim també es veu que hi ha porcs que no ha detectat però proporcionalment molt menor. Si s'observen aquestes dades també es pot veure com en alguns casos també es detecten animals i persones que, en teoria, no hi son a les imatges, sobre tot en els porcs. En el cas de les imatges del IRTA, moltes d'aquestes deteccions en realitat no són deteccions errònies, si no que a l'hora d'etiquetar a mà aquestes dades, sobre tot en situacions on molts de porcs estan molt junts i és difícil diferenciar-los inclús amb la vista humana afectat també per la distància dels porcs i la càmera i la qualitat de les imatges, hi ha hagut regions no etiquetades **on realment sí que hi ha porcs o alguna persona**, com es pot veure exemplificat a la figura 9.1, on es compara les deteccions fetes (en blau les deteccions que coincideixen amb el ground truth i en verd les que no apareixen al ground truth de la imatge), amb el ground truth (en vermell les ROIs que no s'han detectat).

U. Edim. Porcs 0.5	U. Edim. Porcs 0.6	U. Edim. Porcs 0.6			
	GT	GT	GT	GT	GT
Pred	P	P	P	P	P
	N	N	N	N	N
17955	243	13334	144	5108	59
1245		5866		14092	

IRTA Porcs 0.5	IRTA Porcs 0.6	IRTA Porcs 0.7	IRTA Pers. 0.5	IRTA Pers. 0.6	IRTA Pers. 0.7
	GT	GT	GT	GT	GT
Pred	P	P	P	P	P
	N	N	N	N	N
2208	194	1376	50	514	0
1410		2242		3104	

Val. Porcs 0.5	Val. Porcs 0.6	Val. Porcs 0.7	Val. Pers. 0.5	Val. Pers. 0.6	Val. Pers. 0.7
	GT	GT	GT	GT	GT
Pred	P	P	P	P	P
	N	N	N	N	N
10759	199	7595	69	2599	13
1480		4644		9640	

Test Porcs 0.5	Test Porcs 0.6	Test Porcs 0.7	Test Pers. 0.5	Test Pers. 0.6	Test Pers. 0.7
	GT	GT	GT	GT	GT
Pred	P	P	P	P	P
	N	N	N	N	N
9404	238	7115	125	3023	46
1175		3464		7556	

Taula 9.2: Resultats deteccions en proves mAP

Com és lògic, el millor resultat dona amb el menor valor d'score threshold, 0.5, on, si s'observa els valors de mAP de validació i test, s'aconsegueix un mAP al voltant del 92%, específicament per als porcs tenim un valor d'un 87% i per a les persones del 96%. A mesura que es va augmentant el score threshold aquests valors disminueixen notòriament, sobre tot afectat pel AP de la predicció dels porcs. Si es miren ara els valors del AP dels porcs de la Universitat d'Edimburg i es comparen amb el de l'IRTA es veu que hi ha molt millor resultat al primer que al segon, on amb un score de 0.5 tenim més del 92% davant al 59% dels de l'IRTA. A mesura que augmenta el score threshold aquesta diferència es manté. Aquesta distància es dona per la diferència de quantitat de dades etiquetades a cada dataset, ja que del dataset de la Universitat d'Edimburg es disposa d'una quantitat notable de dades ja etiquetades per a treballar-hi, mentre que el dataset de l'IRTA s'ha hagut d'etiquetar a mà, cosa que ha reduït notablement la quantitat de dades que es tenen ja que no es disposava del suficient temps com per a generar una quantitat de dades equiparable a l'altre dataset.

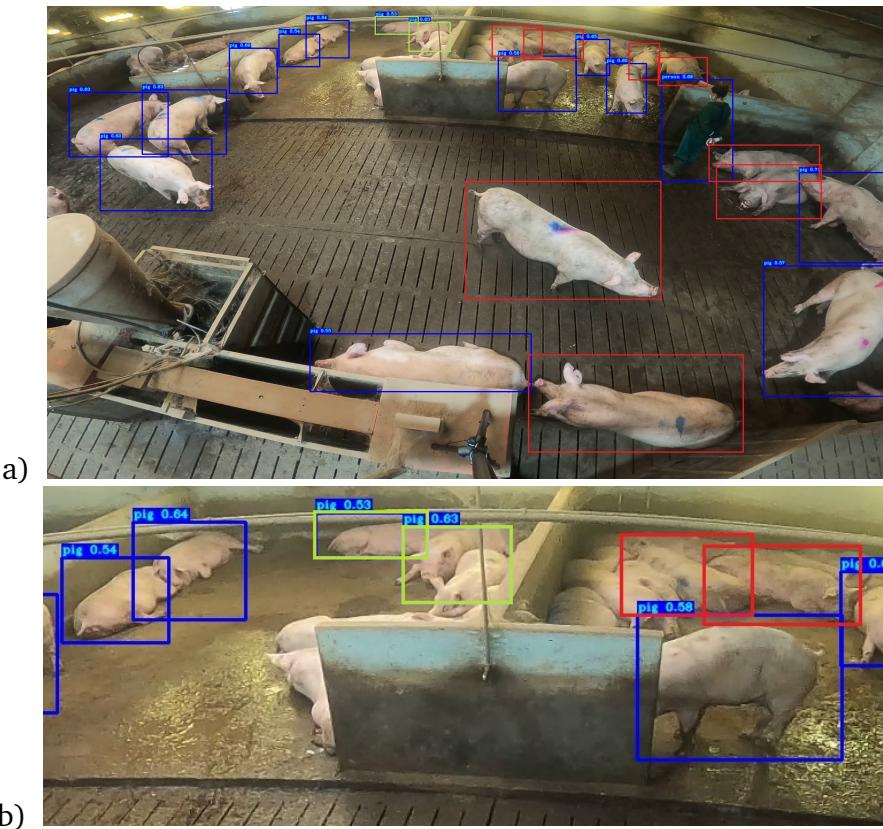


Figura 9.1: Comparació de les deteccions amb el ground truth (GT). En blau les deteccions, en vermell les ROIs del GT no detectades i el verd les deteccions que no són al GT.

Si es fa un ànalisi dels problemes més comuns en la detecció, es troba que els errors més comuns es donen a la figura 9.5:

- (a) La persona o un altre porc tapa a l'altre porc el suficient per a que la xarxa no ho detecti.
- (b) La persona passa pel davant d'un porc i la xarxa detecta un mateix porc com a dos regions d'interès separades.
- (c) Els porcs són animals que tendeixen a estar molt junts, per tant es dona repetidament la situació en que la xarxa confon dos porcs junts com a un mateix animal.

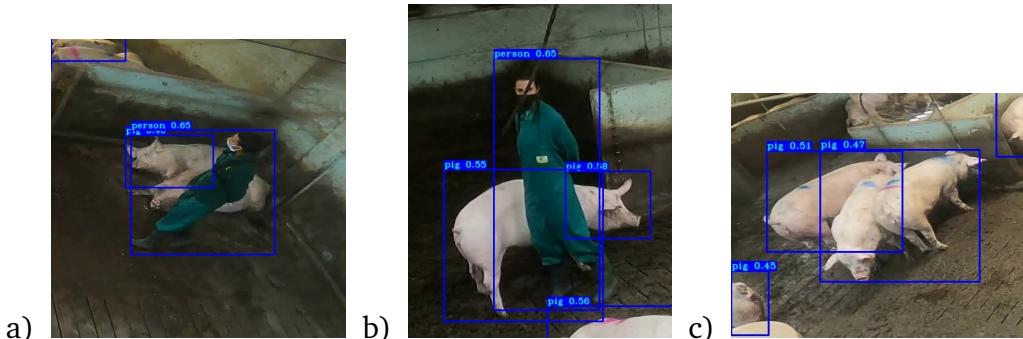


Figura 9.2: Exemples d'errors comuns a la detecció: a) Persona tapa el porc, b) Detecta un mateix porc com a dos al tenir un obstacle al mig, c) Detectar dos porcs propers com a un sol porc

## 9.2 Disseny general del sistema

Pel que fa als resultats del sistema general, la combinació de la detecció i el seguiment, no es pot fer un anàlisi quantitatiu dels resultats ja que no es té una mesura per fer-ho, per tant, es farà un anàlisi dels resultats qualitatiu, centrant-se en quins són els problemes principals d'aquest.

Si es torna a parlar dels dos datasets, els resultats obtinguts amb el dataset de la Universitat d'Edimburg són remarcables, aconseguint fer el seguiment de la majoria dels porcs durant seqüències de vídeo completes. A la figura 9.3 es poden observar dos trajectòries de porcs diferents al llarg de la seqüència de vídeo, marcats amb una línia groga i una línia rosa. L'error més donat en les proves d'aquest datasets s'ha donat quan un porc està molt aferrat a un altre, a sobre inclòs, impedint la detecció, seguit del intercanvi del seguiment de dos porcs que es creuen. A la figura 9.4 es pot veure com el porc verd, amb la trajectòria rosa, passa per davant del porc vermell, amb seguiment violeta, i a la imatge c) s'intercanvien els tracks, observant que a la imatge d) el porc verd ha passat a tenir el seguiment lila i el porc vermell el seguiment rosa.

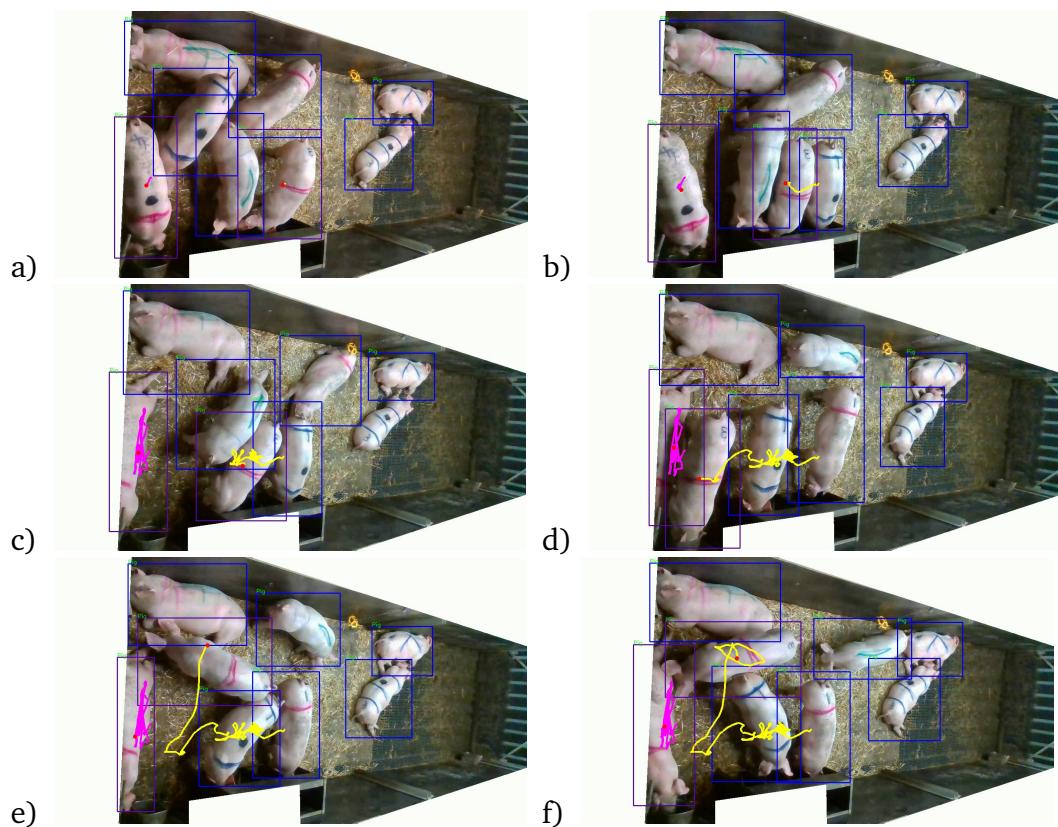


Figura 9.3: Exemple del seguiment de dos porcs.

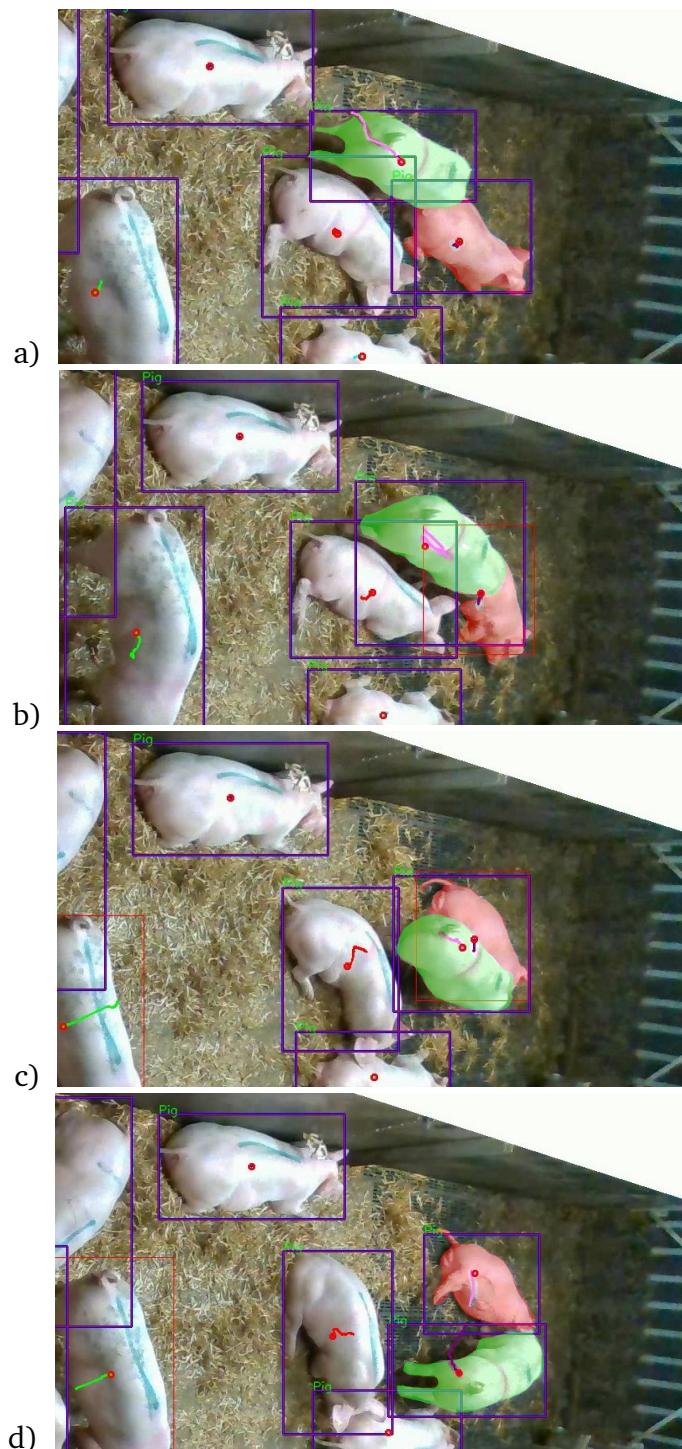


Figura 9.4: Exemple del intercanvi de seguiment entre dos porcs.

Com s'explica als resultats anteriors de la detecció, aquest filtre també serà sensible als errors de la detecció, sobre tot a l'error de la detecció d'un sol animal

com a dos porcs separats, ja que això fa que el filtre crei un altre track que, quan deixa d'haver un obstacle al davant i aquestes dues deteccions passa a ser una, aquest track seguirà existint i no tindrà detecció assignada o, si la té, serà errònia. A la figura 9.5 es pot observar com succeeix això, tenint en compte que les caixes blaves són deteccions de porcs, les verdes de persones i les vermelles la posició predicta d'un track la qual no té cap detecció assignada al frame:

- (a) Inicialment hi ha una persona caminant en direcció a un porc.
- (b) Es veu com la persona comença a tapar al porc i la detecció només capta la part frontal del cos del porc.
- (c) S'observa com la xarxa detecta el porc en dues parts ja que la persona obstaculitza la visió.
- (d) La persona segueix moguent-se i la xarxa només detecta la part trasera del porc, mentre que el track creat al cap segueix existint, però es mou seguint només la predicció, sense cap mesura.
- (e) Es pot veure com només es detecta un porc i el track es va desplaçant cap a la esquerra seguint el moviment que el filtre ha predit que l'objecte fa.

A la figura 9.5 també es pot observar el funcionament del filtre quan hi ha tracks els quals inicialment tenen detecció, seguidament estan algun frame sense detecció i finalment tornen a tenir detecció i recuperen l'objecte i la trajectòria:

- (a) Inicialment hi ha una persona caminant detectada per la xarxa, amb una línia rosa que indica la seva trajectòria.
- (b) Es veu com la xarxa no detecta la persona i el filtre, amb una caixa vermella, fa la predicció de la trajectòria que ha dut a terme i mou la ROI anterior consequentment i, per tant, la línia rosa mostra també aquesta trajectòria predicta.
- (c) La xarxa detecta la persona una altra vegada i el filtre la reassigna al track perdut anteriorment.

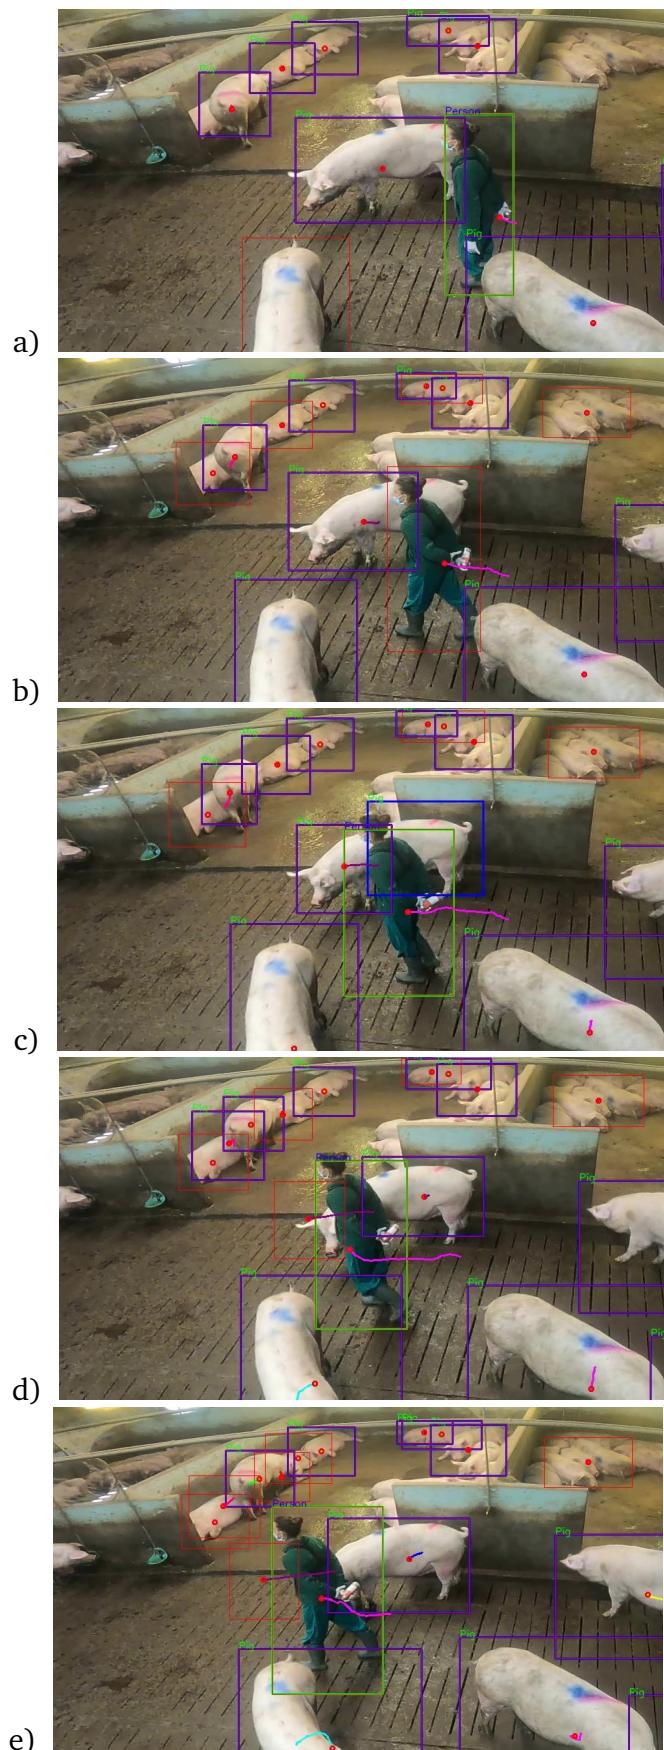


Figura 9.5: Exemple de l'efecte de l'error de detecció doble d'un porc en el seguiment.



## CAPÍTOL 10

# Conclusions

---

S'ha vist que a partir de les xarxes neuronals i d'algorismes de seguiment, en aquest cas el Filtre de Kalman en la seva variant Unsceded Kalman Filter, és possible dur a terme la detecció i el seguiment de persones i animals com són els porcs i extreure'n informació en temps reduït.

Analitzant els resultats presentats al capítol anterior, la primera conclusió que es treu és la importància que té un bon dataset per a obtenir bons resultats:

- Tenir una quantitat notable de dades.
- Les dades han d'estar ben etiquetades, ja que és la base de l'entrenament.
- En el cas d'aquest projecte, que el punt de vista de les imatges utilitzades sigui lòptic per a poder extreure'n la màxima quantitat d'informació, en aquest cas en pla zenital.

Un punt que hi ha que remarcar és la diferència notòria de treballar en situacions ideals en comparació a situacions reals. Com s'ha vist, el dataset de la Universitat d'Edimburg es podria entendre aquí com la situació quasi ideal, on el punt de vista és bo, el nombre d'objectes és reduït i les dades ja estan etiquetades. Moltes vegades s'assumeix que aquestes situacions ideals o quasi ideals es donaran sempre i això no és així. Al veure el funcionament del mateix sistema en un entorn real, com són les imatges de l'IRTA, es veu com un sistema que es creia que tenia un funcionament correcte ha de ser modificat per a que pugui funcionar en entorns reals.

Seguidament, es remarca la importància dels paràmetres usats en el desenvolupament de qualsevol algorisme, ja que, com s'ha pogut veure a la prova del Learning Rate, si algun valor és molt gran o molt petit, pot fer que no s'arribi mai al resultat desitjat.

Tot i que els resultats de la detecció estan lluny de ser perfectes, cosa que beneficiaria al sistema de seguiment, aquesta detecció és suficientment bona com per produir resultats de "tracking" acceptables. Des del principi d'aquest projecte es sabia que, per temps i recursos, arribats a aquest punt de la feina uns resultats

com els que es tenen amb un mAP al voltant del 60% per a score thresholds de 0.6 o 0.7 eren els esperats. Com a primer avenç en un projecte d'aquestes magnituds és un bon resultat i obre la porta a poder seguir avançant.

Pel que fa a la viabilitat de continuar amb el projecte, tal i com s'indicava a la introducció, al veure els resultats obtinguts es veu que, tot i que fa falta molt de treball i temps refinament tant dels algorismes com de les dades els quals comportarien la despesa d'una gran quantitat de temps, és una tasca que es podria arribar a dur a terme e implantar en un espai real, tot i que en aquest cas s'haurien d'analitzar factors externs com poden ser la instal·lació del hardware necessari per a dur-ho a terme en l'espai, la il·luminació... Tot i això, en la opinió del alumne, el benefici que aquest sistema podria aportar al benestar dels animals i al benefici econòmic dels ramaders és una bona motivació per a seguir fent feina en aquesta branca de treball.

## CAPÍTOL 11

# Treball futur

---

Com ja s'ha dit a la introducció d'aquest document, aquest projecte és part d'un projecte més gran que ha hagut de ser acotat per temps. Pel que fa al treball futur, analitzant els resultats obtinguts i veient on es vol arribar, farà falta dur a terme les següents tasques:

1. Augmentar les dades etiquetades per a poder entrenar millor la xarxa neuronal, ja que un dels majors problemes que hi ha ara és que les deteccions són encara precàries per a que sigui un sistema robust. Es podria seguir el mateix mètode d'etiquetar més imatges del dataset de l'IRTA o intentar aconseguir més dades de tercets.
2. Fer registres dels moviments quantificats per l'algorisme de seguiment i buscar una forma òptima d'emmagatzemar-les i que siguin de fàcil post-precessament.
3. Afegir una xarxa neuronal intermitja entre la YOLOv4 i l'UKF que agafi les deteccions de persones i detecti les parts de cos per a tenir dades més exactes de la relació entre la posició de la persona i el moviment dels animals. Es podria fer ús de la MoveNet o la PoseNet de Tensorflow, per exemple [42].
4. Quan s'hagin dut a terme les tasques anteriors, desenvolupar un algorisme que agafi les dades extretes dels moviments i la pose de les persones i els animals per a fer l'anàlisi de la variació del moviment dels animals quan hi ha persones a prop.



# Bibliografia

- [1] L. Bergamini, S. Pini, A. Simoni, R. Vezzani, S. Calderara, R. B. Eath, and R. B. Fisher, “Extracting accurate long-term behavior changes from a large pig dataset,” in *16th International Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications, VISIGRAPP 2021*. SciTePress, 2021, pp. 524–533. (Cited on page 1.)
- [2] S. Ren, K. He, R. B. Girshick, and J. Sun, “Faster R-CNN: towards real-time object detection with region proposal networks,” *CoRR*, vol. abs/1506.01497, 2015. [Online]. Available: <http://arxiv.org/abs/1506.01497> (Cited on pages 3 and 6.)
- [3] A. Bochkovskiy, C.-Y. Wang, and H.-Y. M. Liao, “Yolov4: Optimal speed and accuracy of object detection,” 2020. (Cited on pages 3, 6, 19 and 32.)
- [4] K. He, G. Gkioxari, P. Dollar, and R. Girshick, “Mask r-cnn,” in *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*, Oct 2017. (Cited on page 3.)
- [5] L. Bergamini, S. Pini, A. Simoni, R. Vezzani, S. Calderara, R. Eath, and R. Fisher. (2021) Edinburgh pig behavior video dataset. [Online]. Available: <https://homepages.inf.ed.ac.uk/rbf/PIGDATA/> (Cited on pages 4 and 5.)
- [6] Conda. (2017) Conda environments. [Online]. Available: <https://docs.conda.io/projects/conda/en/latest/user-guide/concepts/environments.html> (Cited on page 4.)
- [7] L. Bergamini, S. Pini, A. Simoni, R. Vezzani, S. Calderara, R. Eath, and R. Fisher, “Extracting accurate long-term behavior changes from a large pig dataset,” in *Proceedings of the 16th International Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications*, G. Farinella, P. Radeva, J. Braz, and K. Bouatouch, Eds., vol. 4. SciTePress, 2021, pp. 524–533, 16th International Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications, VISIGRAPP 2021 ; Conference date: 08-02-2021 Through 10-02-2021. (Cited on page 5.)
- [8] Google. (2018) Open images dataset v4. [Online]. Available: <https://storage.googleapis.com/openimages/web/index.html> (Cited on pages 5 and 28.)

- [9] IRTA. Institut de recerca i tecnologia agroalimentàries. [Online]. Available: <https://www.irta.cat/es/> (Cited on page 6.)
- [10] AlexeyAB. (2020) darknet. [Online]. Available: <https://github.com/AlexeyAB/darknet> (Cited on pages 6, 19 and 38.)
- [11] P. Flach, *Machine Learning: The Art and Science of Algorithms that Make Sense of Data*. Cambridge University Press, 2012. (Cited on page 11.)
- [12] E. Alpaydin, *Introduction to Machine Learning (4th Edition)*. MIT, 2020. (Cited on page 11.)
- [13] I. C. Education. (2020) Neural networks. [Online]. Available: <https://www.ibm.com/cloud/learn/neural-networks> (Cited on page 12.)
- [14] R. J. Meinhold and N. D. Singpurwalla, “Understanding the kalman filter,” *The American Statistician*, vol. 37, no. 2, pp. 123–127, 1983. (Cited on page 13.)
- [15] G. Welch, G. Bishop *et al.*, “An introduction to the kalman filter,” 1995. (Cited on page 14.)
- [16] S. J. Julier and J. K. Uhlmann, “New extension of the kalman filter to non-linear systems,” in *Signal processing, sensor fusion, and target recognition VI*, vol. 3068. International Society for Optics and Photonics, 1997, pp. 182–193. (Cited on page 15.)
- [17] Python Software Foundation. (2021) Python. [Online]. Available: <https://www.python.org> (Cited on page 17.)
- [18] RockyXu66. (2020) Faster rcnn for open images dataset keras. [Online]. Available: [https://github.com/RockyXu66/Faster\\_RCNN\\_for\\_Open\\_Images\\_Dataset\\_Keras](https://github.com/RockyXu66/Faster_RCNN_for_Open_Images_Dataset_Keras) (Cited on page 17.)
- [19] The MathWorks, Inc. (2021) Matlab. [Online]. Available: <https://es.mathworks.com> (Cited on page 17.)
- [20] C. R. Harris, K. J. Millman, S. J. van der Walt, R. Gommers, P. Virtanen, D. Cournapeau, E. Wieser, J. Taylor, S. Berg, N. J. Smith, R. Kern, M. Picus, S. Hoyer, M. H. van Kerkwijk, M. Brett, A. Haldane, J. F. del Río, M. Wiebe, P. Peterson, P. Gérard-Marchant, K. Sheppard, T. Reddy, W. Weckesser, H. Abbasi, C. Gohlke, and T. E. Oliphant, “Array programming with NumPy,” *Nature*, vol. 585, no. 7825, pp. 357–362, Sep. 2020. [Online]. Available: <https://doi.org/10.1038/s41586-020-2649-2> (Cited on page 18.)

- [21] OpenCV team. (2021) Opencv. [Online]. Available: <https://opencv.org> (Cited on page 18.)
- [22] The Matplotlib Development team. (2021) Matplotlib. [Online]. Available: <https://matplotlib.org> (Cited on page 18.)
- [23] NumFOCUS. (2021) Pandas. [Online]. Available: <https://pandas.pydata.org> (Cited on page 18.)
- [24] The scikit-image development team. (2021) scikit-image. [Online]. Available: <https://scikit-image.org> (Cited on page 18.)
- [25] Python Software Foundation. (2021) os. [Online]. Available: <https://docs.python.org/3.7/library/os.html?highlight=os#module-os> (Cited on page 19.)
- [26] ——. (2021) Json. [Online]. Available: <https://docs.python.org/3.7/library/json.html> (Cited on page 19.)
- [27] ——. (2021) random. [Online]. Available: <https://docs.python.org/3.7/library/random.html> (Cited on page 19.)
- [28] ——. (2021) shutil. [Online]. Available: <https://docs.python.org/3.7/library/shutil.html> (Cited on page 19.)
- [29] Pythonlessons. (2021) Tensorflow-2.x-yolov3. [Online]. Available: <https://github.com/pythonlessons/TensorFlow-2.x-YOLOv3> (Cited on pages 20 and 38.)
- [30] Google Brain. (2021) Tensorflow. [Online]. Available: <https://www.tensorflow.org> (Cited on page 20.)
- [31] sj23patel. Object\_tracking. [Online]. Available: <https://github.com/sj23patel/Object-Tracking> (Cited on pages 20 and 43.)
- [32] SciPy. Scipy. [Online]. Available: <https://scipy.org> (Cited on page 20.)
- [33] Python Software Foundation. threading. [Online]. Available: <https://docs.python.org/3.7/library/threading.html> (Cited on page 21.)
- [34] ——. copy. [Online]. Available: <https://docs.python.org/3.7/library/copy.html> (Cited on page 21.)
- [35] A. Rosebrock. (2016) Intersection over union (iou) for object detection. [Online]. Available: <https://www.pyimagesearch.com/2016/11/07/intersection-over-union-iou-for-object-detection/> (Cited on page 30.)

- [36] H. Rezatofighi, N. Tsoi, J. Gwak, A. Sadeghian, I. Reid, and S. Savarese, “Generalized intersection over union,” June 2019. (Cited on page 30.)
- [37] C.-Y. Wang, H.-Y. M. Liao, Y.-H. Wu, P.-Y. Chen, J.-W. Hsieh, and I.-H. Yeh, “CspNet: A new backbone that can enhance learning capability of cnn,” in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR) Workshops*, June 2020. (Cited on page 32.)
- [38] S. Liu, L. Qi, H. Qin, J. Shi, and J. Jia, “Path aggregation network for instance segmentation,” in *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2018, pp. 8759–8768. (Cited on page 32.)
- [39] K. He, X. Zhang, S. Ren, and J. Sun, “Spatial pyramid pooling in deep convolutional networks for visual recognition,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 37, no. 9, pp. 1904–1916, 2015. (Cited on page 32.)
- [40] H. W. Kuhn, “The hungarian method for the assignment problem,” *Naval research logistics quarterly*, vol. 2, no. 1-2, pp. 83–97, 1955. (Cited on page 33.)
- [41] D. P. Kingma and J. Ba, “Adam: A method for stochastic optimization,” *arXiv preprint arXiv:1412.6980*, 2014. (Cited on page 38.)
- [42] Tensorflow. Pose estimation. [Online]. Available: [https://www.tensorflow.org/lite/examples/pose\\_estimation/overview](https://www.tensorflow.org/lite/examples/pose_estimation/overview) (Cited on page 61.)
- [43] T. He, Z. Zhang, H. Zhang, Z. Zhang, J. Xie, and M. Li, “Bag of tricks for image classification with convolutional neural networks,” *CoRR*, vol. abs/1812.01187, 2018. [Online]. Available: <http://arxiv.org/abs/1812.01187> (Cited on page 71.)

# **Appendices**



## A.1 Manuals d'usuari

Els següents manuals expliquen com fer ús dels programes per a executar la xarxa neuronal i el sistema de seguiment. Aquest manuals parteixen de la condició de que totes les llibreries, paquets i/o mòduls indicats al capítol 6 estan instal·lats a la màquina que s'utilitza.

### A.1.1 Xarxa neuronal

#### A.1.1.1 Entrenament de la xarxa amb datasets pròpis

1. Inicialment hi ha que modificar el fitxer "configs.py" (Annex C.3.1):

- (a) Comentar les línies 24 i 25 i descomentar les línies 21 i 22 per a definir que es vol fer transfer learning dels pesos del model Darknet, tal com es mostra a la figura 1.

---

```

1 YOLO_CUSTOM_WEIGHTS      = False
2 YOLO_COCO_CLASSES        = "model_data/coco/coco.names"
3 #YOLO_CUSTOM_WEIGHTS    = True
4 #YOLO_COCO_CLASSES       = "/home/virginia/TFG/YOLOv4/TensorFlow-_
  ↵ 2.x-YOL0v3-master/data/annotation.names"

```

---

Figura 1: Mostra com han de quedar les línies 21-25 del "configs.py"

- (b) Seguidament s'han de configurar els paràmetres de l'entrenament d'aquest mateix fitxer, definits entre les línies 38 i 56. Aquests es poden modificar com sigui més convenient. Els paràmetres que s'han o es poden modificar són:

- *TRAIN\_YOLO\_TINY*: Defineix si es vol entrenar un model YOLOv4 Tiny o no. En aquest cas es deixa en False ja que no es treballa amb aquest model.
- *TRAIN\_SAVE\_BEST\_ONLY*: Defineix si es vol guardar només els pesos del model amb millor resultats en la validació o tots els models entrenats a cada epoch. Es deixa en "True" ja que només interessa el millor resultat i guardar-los tots suposaria un ús més elevat de memòria.
- *TRAIN\_SAVE\_CHECKPOINT*: Defineix si es volen guardar tots els millors pesos indicats anteriorment, és a dir, no sobreescriure els

pesos guardats anteriorment. Pel mateix motiu d'abans es deixa en "False".

- *TRAIN\_CLASSES*: Indica el path del fitxer on hi ha guardats els noms de les classes sobre les quals entrenar.
- *TRAIN\_ANNOT\_PATH*: Indica el path de les annotacions o etiquetes a fer ús per entrenar el model.
- *TRAIN\_CHECKPOINTS\_FOLDER*: Indica el repositori on guardar els pesos del model entrenat.
- *TRAIN\_MODEL\_NAME*: Indica amb quin nom es guarden els pesos del model entrenat a dintre de la carpeta indicada anteriorment.
- *TRAIN\_LOAD\_IMAGES\_TO\_RAM*: Indica si es vol carregar les imatges a la RAM. Això es fa per a processar les imatges més ràpidament a l'hora d'entrenar, tot i que tarda una mica més el carregar el dataset inicialment. Com que el servidor on s'entrena el model a aquest projecte té suficient RAM com per carregar totes les imatges, aquí està a "True", però dependrà de la capacitat de la que es disposi.
- *TRAIN\_BATCH\_SIZE*: Indica quantes imatges es processen a cada iteració de cada epoch. En aquest cas, com que hi ha un nombre considerable de imatges a processar s'ha elegit fer-ho de quatre en quatre després d'algunes proves, però aquest nombre és variable.
- *TRAIN\_DATA\_AUG*: Indica si es vol realitzar "Data Augmentation" que bàsicament és aplicar algunes transformacions a imatges ja existents del dataset per a tenir més dades que processar.
- *TRAIN\_TRANSFER*: Indica si es vol entrenar la xarxa des d'un altre model ja definit, com el Darknet en aquest cas, o si es vol entrenar de zero.
- *TRAIN\_FROM\_CHECKPOINT*: Indica si es vol començar a entrenar des d'un altre checkpoint, és a dir, un entrenament anterior. En el cas d'aquest projecte sempre s'ha treballat amb els pesos iniciais del Darknet, mai d'entrenaments anteriors.
- *TRAIN\_LR\_INIT*: Indica el learning rate que es vol tenir al llarg del entrenament.
- *TRAIN\_LR\_END*: Indica el learning rate inicials que es vol seguir als epochs de calentament o warm up. Els epochs de calentaments són epochs duts a terme al inici del entrenament per a pujar progressivament d'un learning rate petit (en aquest cas el

TRAIN\_LR\_END) a un learning rate més gran que es vol mantenir al llarg del entrenament (en aquest cas el TRAIN\_LR\_INIT). Això es fa ja que al inici del entrenament normalment els paràmetres usats tenen valors aleatoris que disten molt de la solució esperada i fer ús d'un learning rate gran pot fer que hi hagi instabilitat numèrica [43].

- *TRAIN\_WARMUP\_EPOCHS*: Indica quants d'epochs de calentament es volen fer.
- *TRAIN\_EPOCHS*: Indica quants d'epochs d'entrenament es volen fer.

A la figura 2 es mostra la configuració del últim entrenament dut a terme en aquest projecte.

---

```

1 # Train options
2 TRAIN_YOLO_TINY           = False
3 TRAIN_SAVE_BEST_ONLY      = True # saves only best model according
        ↳ validation loss (True recommended)
4 TRAIN_SAVE_CHECKPOINT     = False # saves all best validated
        ↳ checkpoints in training process (may require a lot disk space)
        ↳ (False recommended)
5 TRAIN_CLASSES              = "/home/virginia/TFG/YOLOv4/TensorFlow-2 \
        ↳ .x-YOLOv3-master/data/annotation.names"
6 TRAIN_ANNOT_PATH           = "/home/virginia/TFG/YOLOv4/TensorFlow-2 \
        ↳ .x-YOLOv3-master/data/PigPersv2/annotation_train.txt"
7 TRAIN_LOGDIR                = "log"
8 TRAIN_CHECKPOINTS_FOLDER    = "checkpoints/yolov4_PigPersv5"
9 TRAIN_MODEL_NAME             = f"YOLO_TYPE}_custom"
10 TRAIN_LOAD_IMAGES_TO_RAM    = True # With True faster training, but
        ↳ need more RAM
11 TRAIN_BATCH_SIZE            = 4
12 TRAIN_INPUT_SIZE            = 416
13 TRAIN_DATA_AUG              = True
14 TRAIN_TRANSFER               = True
15 TRAIN_FROM_CHECKPOINT       = False # "checkpoints/yolov3_custom"
16 TRAIN_LR_INIT                 = 5e-6
17 TRAIN_LR_END                  = 5e-7
18 TRAIN_WARMUP_EPOCHS          = 1
19 TRAIN_EPOCHS                   = 55

```

---

Figura 2: Mostra com ha de quedar la configuració de l'entrenament del "confs.py"

(c) Les últimes configuracions a fer en aquest fitxer són els paràmetres de validació o test, entre les línies 58 i 65 del fitxer. En aquest cas hi ha els següents paràmetres modificables:

- *TEST\_ANNOT\_PATH*: Equival al TRAIN\_ANNOT\_PATH però amb el fitxer de validació.
- *TEST\_BATCH\_SIZE*: Equival al TRAIN\_BATCH\_SIZE però per a la validació dels resultats.
- *TEST\_DATA\_AUG*: Equival al TRAIN\_DATA\_AUG però per a la validació dels resultats.
- *TEST\_SCORE\_THRESHOLD*: És el valor mínim de la confiança que té la xarxa en el resultat, és a dir, la probabilitat que té una regió d'interès de ser el que la xarxa ha predit, que s'accepta.
- *TEST\_IOU\_THRESHOLD*: És el valor mínim que han de tenir dos regions d'interès d'IoU per a acceptar-les com a una sola regió d'interès o objecte.

A la figura 3 es mostren aquests paràmetres.

---

```
1 # TEST options
2 TEST_ANNOT_PATH          = "/home/virginia/TFG/YOLOv4/TensorFlow-2\"
3   ↳ .x-YOLOv3-master/data/PigPersv2/annotation_val.txt"
4 TEST_BATCH_SIZE           = 4
5 TEST_INPUT_SIZE           = 416
6 TEST_DATA_AUG             = False
7 TEST_DECTECTED_IMAGE_PATH = ""
8 TEST_SCORE_THRESHOLD      = 0.7
9 TEST_IOU_THRESHOLD        = 0.5
```

---

Figura 3: Mostra com ha de quedar la configuració de la validació o test del "configs.py"

2. Seguidament s'ha de modificar la línia 42 del fitxer "train.py"(Annex C.3.5) i indicar el fitxer de text on es vol guardar el procés d'entrenament de la xarxa.

---

```
1 # Create register file for training process (Virginia Ramón)
2 file = open("loss_training_PigPersv5.txt", 'w')
```

---

Figura 4: Línia a modificar del fitxer "train.py"

3. Quan ja s'han fet les modificacions pertinentes, hi ha dos opcions per a executar el programa:

- Si es té algun programa o aplicació on es pugui compilar i executar un programa de Python directament, executar el fitxer "train.py".
- Si no es disposa de tal intereficie, obrir un terminal a la màquina, anar al repositori on hi ha guardats els fitxers de codi de la YOLOv4 i executar la comanta "*python train.py*".

4. Si tot va bé, es mostrerà per pantalla la informació del Tensorflow (figura 5), seguidament del progres de càrrega dels datasets (figura 6) i finalment el progrés de cada epoch (figura 7).

```
YOLOv4...
Num GPUs Available: 2
Register file created!
2021-12-27 12:50:26.486398: I tensorflow/core/common_runtime/gpu/gpu_device.cc:1716] Found device 0 with properties:
pciBusID: 0000:0b:00.0 name: Quadro RTX 6000 computeCapability: 7.5
coreClock: 1.77GHz coreCount: 72 deviceMemoryBandwidth: 625.94GiB/s
2021-12-27 12:50:26.487251: I tensorflow/core/common_runtime/gpu/gpu_device.cc:1716] Found device 1 with properties:
pciBusID: 0000:08:00.0 name: Quadro RTX 6000 computeCapability: 7.5
coreClock: 1.77GHz coreCount: 72 deviceMemoryBandwidth: 625.94GiB/s
2021-12-27 12:50:26.487273: I tensorflow/stream_executor/platform/default/dso_loader.cc:48] Successfully opened dynamic library libcudart.so.10.1
2021-12-27 12:50:26.487293: I tensorflow/stream_executor/platform/default/dso_loader.cc:48] Successfully opened dynamic library libcublas.so.10
2021-12-27 12:50:26.487306: I tensorflow/stream_executor/platform/default/dso_loader.cc:48] Successfully opened dynamic library libcufft.so.10
2021-12-27 12:50:26.487318: I tensorflow/stream_executor/platform/default/dso_loader.cc:48] Successfully opened dynamic library libcurand.so.10
2021-12-27 12:50:26.487330: I tensorflow/stream_executor/platform/default/dso_loader.cc:48] Successfully opened dynamic library libcusolver.so.10
2021-12-27 12:50:26.487342: I tensorflow/stream_executor/platform/default/dso_loader.cc:48] Successfully opened dynamic library libcusparse.so.10
2021-12-27 12:50:26.487354: I tensorflow/stream_executor/platform/default/dso_loader.cc:48] Successfully opened dynamic library libcudnn.so.7
2021-12-27 12:50:26.490584: I tensorflow/core/common_runtime/gpu/gpu_device.cc:1858] Adding visible gpu devices: 0, 1
2021-12-27 12:50:26.490623: I tensorflow/core/common_runtime/gpu/gpu_device.cc:1257] Device interconnect StreamExecutor with strength 1 edge matrix:
2021-12-27 12:50:26.490633: I tensorflow/core/common_runtime/gpu/gpu_device.cc:1263]           0  1
2021-12-27 12:50:26.490642: I tensorflow/core/common_runtime/gpu/gpu_device.cc:1276] 0:  N Y
2021-12-27 12:50:26.490648: I tensorflow/core/common_runtime/gpu/gpu_device.cc:1276] 1:  Y N
2021-12-27 12:50:26.493139: I tensorflow/core/common_runtime/gpu/gpu_device.cc:1402] Created TensorFlow device (/job:localhost/replica:0/task:0/device:GPU:0 with 22472 MB memory) -> physical GPU (device: 0, name: Quadro RTX 6000, pci bus id: 0000:0b:00.0, compute capability: 7.5)
2021-12-27 12:50:26.493988: I tensorflow/core/common_runtime/gpu/gpu_device.cc:1402] Created TensorFlow device (/job:localhost/replica:0/task:0/device:GPU:1 with 22472 MB memory) -> physical GPU (device: 1, name: Quadro RTX 6000, pci bus id: 0000:08:00.0, compute capability: 7.5)
Reading train dataset...
```

Figura 5: Sortida inicialització del Tensorflow

```
Reading train dataset...
100/15623
200/15623
300/15623
400/15623
500/15623
600/15623
700/15623
800/15623
900/15623
1000/15623
1100/15623
1200/15623
1300/15623
1400/15623
1500/15623
1600/15623
```

Figura 6: Sortida progrés de càrrega dels datasets

```

Creating Darknet model...
Loading model weights Darknet...
Creating YOLO model...
Loading darknet weights to model...
skipping conv2d_93
skipping conv2d_101
skipping conv2d_109
Start training!
2021-12-27 13:05:59.551056: I tensorflow/stream_executor/platform/default/dso_loader.cc:48] Successfully opened dynamic library libcudnn.so.7
2021-12-27 13:06:03.287446: I tensorflow/stream_executor/platform/default/dso_loader.cc:48] Successfully opened dynamic library libcublas.so.
10
epoch: 0 step:  2/3906, lr:0.000000, giou_loss: 23.31, conf_loss:1828.99, prob_loss: 28.38, total_loss:1880.68
epoch: 0 step:  3/3906, lr:0.000000, giou_loss: 12.04, conf_loss:1550.09, prob_loss: 14.21, total_loss:1576.35
epoch: 0 step:  4/3906, lr:0.000000, giou_loss: 9.61, conf_loss:1546.26, prob_loss: 13.52, total_loss:1569.39
epoch: 0 step:  5/3906, lr:0.000000, giou_loss: 12.98, conf_loss:1541.80, prob_loss: 16.72, total_loss:1571.58
epoch: 0 step:  6/3906, lr:0.000000, giou_loss: 17.53, conf_loss:1547.05, prob_loss: 23.13, total_loss:1587.71
epoch: 0 step:  7/3906, lr:0.000000, giou_loss: 22.06, conf_loss:1546.55, prob_loss: 26.17, total_loss:1594.78
epoch: 0 step:  8/3906, lr:0.000000, giou_loss: 15.68, conf_loss:1548.34, prob_loss: 20.57, total_loss:1584.59
epoch: 0 step:  9/3906, lr:0.000000, giou_loss: 20.56, conf_loss:1549.58, prob_loss: 23.88, total_loss:1593.94
epoch: 0 step:  10/3906, lr:0.000000, giou_loss: 10.82, conf_loss:1549.37, prob_loss: 13.68, total_loss:1573.87
epoch: 0 step:  11/3906, lr:0.000000, giou_loss: 16.56, conf_loss:1548.51, prob_loss: 20.32, total_loss:1585.39
epoch: 0 step:  12/3906, lr:0.000000, giou_loss: 24.33, conf_loss:1548.94, prob_loss: 28.63, total_loss:1601.89

```

Figura 7: Sortida del entrenament de la xarxa

### A.1.1.2 Comprovació mAP d'un model entrenat

1. Inicialment hi ha que modificar el fitxer "configs.py" (Annex C.3.1):

- (a) Comentar les línies 21 i 22 i descomentar les línies 24 i 25 per a definir que es vol fer ús del model entrenat, tal com es mostra a la figura 8. Substituir el paràmetre YOLO\_COCO\_CLASSES pel fitxer tipus text de les classes.

---

```

1 #YOLO_CUSTOM_WEIGHTS           = False
2 #YOLO_COCO_CLASSES             = "model_data/coco/coco.names"
3 YOLO_CUSTOM_WEIGHTS           = True
4 YOLO_COCO_CLASSES              = "/home/virginia/TFG/YOL0v4/TensorFlow-2 \
    ↳ .x-YOL0v3-master/data/annotation.names"

```

---

Figura 8: Mostra com han de quedar les línies 21-25 del "configs.py"

- (b) Cal indicar el dataset amb el que es vol fer la prova de mAP i els paràmetres de testing. Per fer això cal modificar les línies 58 a 65 del fitxer amb les dades que es volen. A la figura 9 es mostren aquests paràmetres.

---

```

1 # TEST options
2 TEST_ANNOT_PATH          = "/home/virginia/TFG/YOLOv4/TensorFlow-2 \
  ↳ .x-YOLOv3-master/data/PigPersv2/test.txt"
3 TEST_BATCH_SIZE           = 4
4 TEST_INPUT_SIZE           = 416
5 TEST_DATA_AUG              = False
6 TEST_DECTECTED_IMAGE_PATH = ""
7 TEST_SCORE_THRESHOLD       = 0.5
8 TEST_IOU_THRESHOLD         = 0.5

```

---

Figura 9: Mostra com ha de quedar la configuració de test del "configs.py"

- Quan ja s'han fet les modificacions pertinentes, hi ha dos opcions per a executar el programa:

- Si es té algun programa o aplicació on es pugui compilar i executar un programa de Python directament, executar el fitxer "mAP-test.py" (Annex C.3.8).
- Si no es disposa de tal intereficie, obrir un terminal a la màquina, anar al repositori on hi ha guardats els fitxers de codi de la YOLOv4 i executar la comanta "python mAPtest.py" (Annex C.3.8).

- Si tot va bé, es mostrerà per pantalla la informació del Tensorflow (figura 10), seguidament del progres de càrrega dels datasets (figura 11) i finalment el resultat dels APs i el mAP (figura 12).

```

2021-12-27 15:03:21.564650: I tensorflow/core/common_runtime/gpu/gpu_device.cc:1402] Created TensorFlow device (/job:localhost/replica:0
/task:0/device:GPU:0 with 22472 MB memory) -> physical GPU (device: 0, name: Quadro RTX 6000, pci bus id: 0000:3b:00.0, compute capabi
ty: 7.5)
2021-12-27 15:03:21.566061: I tensorflow/core/common_runtime/gpu/gpu_device.cc:1402] Created TensorFlow device (/job:localhost/replica:0
/task:0/device:GPU:1 with 22472 MB memory) -> physical GPU (device: 1, name: Quadro RTX 6000, pci bus id: 0000:d8:00.0, compute capabi
ty: 7.5)
2021-12-27 15:03:21.632100: I tensorflow/core/common_runtime/gpu/gpu_device.cc:1716] Found device 0 with properties:
pciBusID: 0000:3b:00.0 name: Quadro RTX 6000 computeCapability: 7.5
coreClock: 1.77GHz coreCount: 72 deviceMemorySize: 23.65GiB deviceMemoryBandwidth: 625.94GiB/s
2021-12-27 15:03:21.634164: I tensorflow/core/common_runtime/gpu/gpu_device.cc:1716] Found device 1 with properties:
pciBusID: 0000:d8:00.0 name: Quadro RTX 6000 computeCapability: 7.5
coreClock: 1.77GHz coreCount: 72 deviceMemorySize: 23.65GiB deviceMemoryBandwidth: 625.94GiB/s
2021-12-27 15:03:21.634216: I tensorflow/stream_executor/platform/default/dso_loader.cc:48] Successfully opened dynamic library libcudar
t.so.10.1
2021-12-27 15:03:21.634258: I tensorflow/stream_executor/platform/default/dso_loader.cc:48] Successfully opened dynamic library libcubla
s.so.10
2021-12-27 15:03:21.634286: I tensorflow/stream_executor/platform/default/dso_loader.cc:48] Successfully opened dynamic library libcufft
.so.10
2021-12-27 15:03:21.634314: I tensorflow/stream_executor/platform/default/dso_loader.cc:48] Successfully opened dynamic library libcuran
d.so.10
2021-12-27 15:03:21.634341: I tensorflow/stream_executor/platform/default/dso_loader.cc:48] Successfully opened dynamic library libcusol
ver.so.10
2021-12-27 15:03:21.634368: I tensorflow/stream_executor/platform/default/dso_loader.cc:48] Successfully opened dynamic library libcuspa
rse.so.10
2021-12-27 15:03:21.634396: I tensorflow/stream_executor/platform/default/dso_loader.cc:48] Successfully opened dynamic library libcudnn
.so.7
2021-12-27 15:03:21.641469: I tensorflow/core/common_runtime/gpu/gpu_device.cc:1858] Adding visible gpu devices: 0, 1

```

Figura 10: Sortida inicialització del Tensorflow

```
Reading test dataset...
100/2595
200/2595
300/2595
400/2595
500/2595
600/2595
700/2595
800/2595
```

Figura 11: Sortida progrés de càrrega dels datasets

```
2021-12-27 15:03:55.447675: I tensorflow/stream_executor/platform/default/dso_loader.cc:48] Successfully opened dynamic library libcudnn
.so.7
2021-12-27 15:03:56.916817: I tensorflow/stream_executor/platform/default/dso_loader.cc:48] Successfully opened dynamic library libcubla
s.so.10
96.866% = person AP
87.313% = pig AP
mAP = 92.069%, 17.26 FPS
```

Figura 12: Sortida del resultat dels APs i mAP

#### A.1.1.3 Predicció

Per a fer proves amb imatges i seqüències de vídeo hi ha que seguir els següents passos:

1. Inicialment hi ha que modificar el fitxer "configs.py" (Annex C.3.1), comentar les línies 21 i 22 i descomentar les línies 24 i 25 per a definir que es vol fer ús del model entrenat, tal com es mostra a la figura 13. Substituir el paràmetre YOLO\_COCO\_CLASSES pel fitxer tipus text de les classes.

---

```
1 #YOLO_CUSTOM_WEIGHTS           = False
2 #YOLO_COCO_CLASSES             = "model_data/coco/coco.names"
3 YOLO_CUSTOM_WEIGHTS           = True
4 YOLO_COCO_CLASSES              = "/home/virginia/TFG/YOLOv4/TensorFlow-2 \
↪ .x-YOL0v3-master/data/annotation.names"
```

---

Figura 13: Mostra com han de quedar les línies 21-25 del "configs.py"

2. Quan ja s'ha modificat el fitxer anterior, s'ha de modificar el fitxer "detection\_demo.py" (Annex C.3.6):
  - (a) Primer s'ha d'indicar si es vol fer la detecció sobre una imatge o una seqüència de vídeo modificant la línia 23 indicant "True" si es vol una imatge, "False" altrament.
  - (b) Si es vol usar una imatge, hi ha que modificar les línies:
    - Línia 30: Indicar el path de la imatge sobre la que fer la detecció.
    - Línia 31: Indicar el path de la imatge resultant de la detecció.

- *Línia 32:* Es poden modificar els paràmetres "show" que indica si es vol mostrar per pantalla la imatge resultant, "score\_threshold" el color del rectangle per a indicar les regions d'interés amb "rectangle\_colors".
- *Línia 43:* Indica el fitxer on guardar el resultat de la detecció.

A la figura 15 es mostra com ha de quedar el codi.

---

```

1 image_path    = "/home/virginia/TFG/PIGDATA/annotated/frames/2019_11_1_]
2   ↵ 1_000028_146.jpg"
3 _, data, classes = detect_image(yolo, image_path, image_out_path,
4   ↵ input_size=YOL0_INPUT_SIZE, show=False, score_threshold=0.5,
5   ↵ rectangle_colors=(255,0,0))
6
7 # Data to txt
8 datafile = []
9 fr = str(data[0])
10 bbxs = ""
11 for bb in data[1]:
12     pos = str(bb[0])+", "+str(bb[1])+", "+str(bb[2])+", "+str(bb[3])+", "
13     ↵ +str(bb[5])
14     bbxs= bbxs + " " + pos
15 datafile = fr+" "+bbxs+"\n"
16
17 file = open("./IMAGES/pred_img.txt", 'w')
18 file.write(datafile)
19 file.close()
20 print("Image detection ended")

```

---

Figura 14: Mostra com han de quedar les línies 30-46 del "detection\_demo.py"

(c) Si es vol usar una imatge, hi ha que modificar les línies:

- *Línia 49:* Indicar el path del video sobre el que fer la detecció.
- *Línia 50:* Indicar el path de la vídeo resultant de la detecció.
- *Línia 51:* Es poden modificar els paràmetres "show" que indica si es vol mostrar per pantalla la imatge resultant, "score\_threshold" el color del rectangle per a indicar les regions d'interés amb "rectangle\_colors".
- *Línia 63:* Indica el fitxer on guardar el resultat de la detecció.

A la figura 15 es mostra com ha de quedar el codi.

---

```
1 video_path    = "./IMAGES/GH010013_zenital_Test.mp4"
2 video_out_path = "./IMAGES/GH010013_zenital_Test_pred.mp4"
3 data, classes = detect_video(yolo, video_path, video_out_path,
4                                input_size=YOLO_INPUT_SIZE, show=False, score_threshold=0.5,
5                                rectangle_colors=(255,0,0))
6
7 # Data to txt
8 datafile = []
9 for frame in data:
10     fr = str(frame[1])
11     bbxs = ""
12     for bb in frame[2]:
13         pos = str(bb[0])+", "+str(bb[1])+", "+str(bb[2])+", "+str(bb[3]) +
14             ", "+str(bb[5])
15         bbxs= bbxs + " " + pos
16     datafile.append(fr+" "+bbxs)
17
18 file = open("./IMAGES/pred_video.txt", 'w')
19 for d in datafile:
20     file.write(d+"\n")
21 file.close()
22 print("Video detection ended")
```

---

Figura 15: Mostra com han de quedar les línies 49-67 del "detection\_demo.py"

3. Quan ja s'han fet les modificacions pertinents, hi ha dos opcions per a executar el programa:

- Si es té algun programa o aplicació on es pugui compilar i executar un programa de Python directament, executar el fitxer "detection\_demo.py".
- Si no es disposa de tal intereficie, obrir un terminal a la màquina, anar al repositori on hi ha guardats els fitxers de codi de la YOLOv4 i executar la comanta "*python detection\_demo.py*".

4. Si tot va bé, es mostrarà per pantalla la informació del Tensorflow (figura 16). Si és una imatge, seguidament es mostrarà un missatge de "image detection ended" si tot ha anat bé (figura 17). En canvi, si és un vídeo, es mostrarà el progrés de les deteccions (figura 18) i finalment un missatge de "Video detection ended" (figura 19).

```

2021-12-27 15:25:40.501095: I tensorflow/core/common_runtime/gpu/gpu_device.cc:1716] Found device 0 with properties:
pciBusId: 0000:3b:00.0 name: Quadro RTX 6000 computeCapability: 7.5
coreClock: 1.77GHz coreCount: 72 deviceMemorySize: 23.65GiB deviceMemoryBandwidth: 625.94GiB/s
2021-12-27 15:25:40.501191: I tensorflow/stream_executor/platform/default/dso_loader.cc:48] Successfully opened dynamic library libcudart.so.10.1
2021-12-27 15:25:40.501264: I tensorflow/stream_executor/platform/default/dso_loader.cc:48] Successfully opened dynamic library libcublas.so.10
2021-12-27 15:25:40.501311: I tensorflow/stream_executor/platform/default/dso_loader.cc:48] Successfully opened dynamic library libcufft.so.10
2021-12-27 15:25:40.501359: I tensorflow/stream_executor/platform/default/dso_loader.cc:48] Successfully opened dynamic library libcurand.so.10
2021-12-27 15:25:40.501404: I tensorflow/stream_executor/platform/default/dso_loader.cc:48] Successfully opened dynamic library libcusolver.so.10
2021-12-27 15:25:40.501449: I tensorflow/stream_executor/platform/default/dso_loader.cc:48] Successfully opened dynamic library libcusparse.so.10
2021-12-27 15:25:40.501496: I tensorflow/stream_executor/platform/default/dso_loader.cc:48] Successfully opened dynamic library libcudnn.so.7
2021-12-27 15:25:40.506917: I tensorflow/core/common_runtime/gpu/gpu_device.cc:1858] Adding visible gpu devices: 0
2021-12-27 15:25:40.507014: I tensorflow/stream_executor/platform/default/dso_loader.cc:48] Successfully opened dynamic library libcudart.so.10.1
2021-12-27 15:25:41.002886: I tensorflow/core/common_runtime/gpu/gpu_device.cc:1257] Device interconnect StreamExecutor with strength 1 edge matrix:
2021-12-27 15:25:41.002938: I tensorflow/core/common_runtime/gpu/gpu_device.cc:1263]      0
2021-12-27 15:25:41.002949: I tensorflow/core/common_runtime/gpu/gpu_device.cc:1276] 0: N
2021-12-27 15:25:41.004978: I tensorflow/core/common_runtime/gpu/gpu_device.cc:1402] Created TensorFlow device (/job:localhost/replica:0/task:0/device:GPU:0 with 22472 MB memory) -> physical GPU (device: 0, name: Quadro RTX 6000, pci bus id: 0000:3b:00.0, compute capability: 7.5)

```

Figura 16: Sortida inicialització del Tensorflow

```
Image detection ended
```

Figura 17: Missatge final detecció d'imatge

```

Time: 3653.96ms, Detection FPS: 0.3, total FPS: 0.3
Time: 1855.87ms, Detection FPS: 0.5, total FPS: 0.5
Time: 1254.87ms, Detection FPS: 0.8, total FPS: 0.8
Time: 954.92ms, Detection FPS: 1.0, total FPS: 1.0
Time: 774.68ms, Detection FPS: 1.3, total FPS: 1.3
Time: 654.34ms, Detection FPS: 1.5, total FPS: 1.5
Time: 568.39ms, Detection FPS: 1.8, total FPS: 1.7
Time: 503.93ms, Detection FPS: 2.0, total FPS: 1.9
Time: 453.80ms, Detection FPS: 2.2, total FPS: 2.1
Time: 413.11ms, Detection FPS: 2.4, total FPS: 2.4
Time: 380.90ms, Detection FPS: 2.6, total FPS: 2.6
Time: 353.48ms, Detection FPS: 2.8, total FPS: 2.7
Time: 330.78ms, Detection FPS: 3.0, total FPS: 2.9
Time: 310.54ms, Detection FPS: 3.2, total FPS: 3.1
Time: 293.13ms, Detection FPS: 3.4, total FPS: 3.3

```

Figura 18: Progrés de la detecció de vídeo

```

Time: 55.07ms, Detection FPS: 16.6, total FPS: 16.4
Time: 53.12ms, Detection FPS: 18.8, total FPS: 16.4
Time: 52.77ms, Detection FPS: 18.9, total FPS: 16.5
Time: 52.80ms, Detection FPS: 18.9, total FPS: 16.5
Video detection ended

```

Figura 19: Missatge final detecció de vídeo

### A.1.2 Ús del sistema de seguiment amb prediccions de la xarxa neuronal

Per a poder fer ús del sistema de seguiment amb les prediccions del model entrenat de la YOLOv4 hi ha que seguir els següents passos:

1. Inicialment hi ha que modificar les següents línies del fitxer "object\_tracking.py" (Annex D.4.3):
  - (a) Línia 63: Indicar en la captura de vídeo el path del fitxer de vídeo a fer el seguiment.

(b) Línia 65: Indicar el path on guardar el vídeo resultant d'aplicar la detecció i l'algorisme.

(c) Línia 78: Definir els paràmetres de la funció Tracker:

- 1r paràmetre: Defineix l'IoU mínim entre una detecció i l'última regió d'interès d'un dels seguiments per a tenir-lo en compte com a possible detecció a afegir a aquest seguiment.
- 2n paràmetre: Indica el nombre de frames que es manté un seguiment sense detecció abans de esborrar-lo de la llista.
- 3r paràmetre: Indica el nombre màxim de frames en que es pot mantenir un seguiment, indiferentment de si hi ha detecció o no.
- 4t paràmetre: Indica la identificació de cada objecte de seguiment.

A la figura 20 es mostra com ha de quedar el codi.

---

```
1 # Create opencv video capture object
2 cap = cv2.VideoCapture("../IMAGES/GH010020_Trim.mp4")
3 #Output path to save video result
4 output_path = "../IMAGES/GH010020_Trim_UKF.mp4"
5
6 cap.set(cv2.CAP_PROP_FRAME_WIDTH, 1920)
7 cap.set(cv2.CAP_PROP_FRAME_HEIGHT, 1080)
8
9 # by default VideoCapture returns float instead of int
10 width = int(cap.get(cv2.CAP_PROP_FRAME_WIDTH))
11 height = int(cap.get(cv2.CAP_PROP_FRAME_HEIGHT))
12 fps = int(cap.get(cv2.CAP_PROP_FPS))
13 codec = cv2.VideoWriter_fourcc(*'XVID')
14 out = cv2.VideoWriter(output_path, codec, fps, (width, height)) #
   ↳ output_path must be .mp4
15
16 # Create Object Tracker
17 tracker = Tracker(0.4, 80, 10000, 20)
```

---

Figura 20: Mostra com han de quedar les línies 62-78 del "object\_tracking.py"

2. Quan ja s'ha configurat el fitxer anterior, s'ha de configurar la detecció d'objectes amb el model entrenat de la YOLOv4. Inicialment hi ha que modificar el fitxer "configs.py" (Annex C.3.1), comentar les línies 21 i 22

i descomentar les línies 24 i 25 per a definir que es vol fer ús del model entrenat, tal com es mostra a la figura 21. Substituir el paràmetre YOLO\_COCO\_CLASSES pel fitxer tipus text de les classes.

---

```

1 #YOLO_CUSTOM_WEIGHTS      = False
2 #YOLO_COCO_CLASSES        = "model_data/coco/coco.names"
3 YOLO_CUSTOM_WEIGHTS      = True
4 YOLO_COCO_CLASSES         = "/home/virginia/TFG/YOLOv4/TensorFlow-2 \
→ .x-YOLOv3-master/data/annotation.names"

```

---

Figura 21: Mostra com han de quedar les línies 21-25 del "configs.py"

3. Seguidament hi ha que modificar la línia 21 del fitxer "frame\_detection.py" (Annex D.4.5) per a indicar els paràmetres de la funció de detecció d'objectes. Aquí es pot modificar el valor del "score\_threshold" del iou\_thresholdusat a cada detecció. A la figura 22 es mostra com ha de quedar el codi.

---

```

1     # Predict Bboxes
2     bboxes, classes = detect_frame(net, frame,
→   input_size=YOLO_INPUT_SIZE, show=False,
→   score_threshold=0.5, iou_threshold=0.5)

```

---

Figura 22: Mostra com han de quedar les línies 20-21 del "frame\_detection.py"

4. Quan ja s'han fet les modificacions pertinents, hi ha dos opcions per a executar el programa:

- Si es té algun programa o aplicació on es pugui compilar i executar un programa de Python directament, executar el fitxer "object\_tracking.py".
- Si no es disposa de tal intereficie, obrir un terminal a la màquina, anar al repositori on hi ha guardats els fitxers de codi de la YOLOv4 i executar la comanda "python object\_tracking.py".

5. Si tot va bé, es mostrarà per pantalla la informació del Tensorflow (figura 23). Si no hi ha errors, es mostrarà per pantalla l'anàlisi de frame a frame on es mostrarà el nombre de objectes de seguiment, la velocitat de detecció en FPS, el temps que ha tardat, el nombre de deteccions (BBXS), l'assignació de deteccions als objectes de seguiment i les deteccions que

no han pogut ser assignades i per tant creat un nou objecte de seguiment (figura 24) i finalment un missatge de "video ended"(figura 24).

```
2021-12-27 16:39:15.891338: I tensorflow/stream_executor/platform/default/dso_loader.cc:48] Successfully opened dynamic library libcusolver.so.10
2021-12-27 16:39:15.891365: I tensorflow/stream_executor/platform/default/dso_loader.cc:48] Successfully opened dynamic library libcusparse.so.10
2021-12-27 16:39:15.891394: I tensorflow/stream_executor/platform/default/dso_loader.cc:48] Successfully opened dynamic library libcudnn.so.7
2021-12-27 16:39:15.898551: I tensorflow/core/common_runtime/gpu/gpu_device.cc:1858] Adding visible gpu devices: 0, 1
2021-12-27 16:39:15.898622: I tensorflow/stream_executor/platform/default/dso_loader.cc:48] Successfully opened dynamic library libcudart.so.10.1
2021-12-27 16:39:16.818642: I tensorflow/core/common_runtime/gpu/gpu_device.cc:1257] Device interconnect StreamExecutor with strength 1 edge matrix:
2021-12-27 16:39:16.818691: I tensorflow/core/common_runtime/gpu/gpu_device.cc:1263]      0  1
2021-12-27 16:39:16.818701: I tensorflow/core/common_runtime/gpu/gpu_device.cc:1276] 0:  N Y
2021-12-27 16:39:16.818708: I tensorflow/core/common_runtime/gpu/gpu_device.cc:1276] 1:  Y N
2021-12-27 16:39:16.821914: I tensorflow/core/common_runtime/gpu/gpu_device.cc:1402] Created TensorFlow device (/job:localhost/replica:0/task:0/device:GPU:0 with 22472 MB memory) -> physical GPU (device: 0, name: Quadro RTX 6000, pci bus id: 0000:3b:00.0, compute capability: 7.5)
2021-12-27 16:39:16.823398: I tensorflow/core/common_runtime/gpu/gpu_device.cc:1402] Created TensorFlow device (/job:localhost/replica:0/task:0/device:GPU:1 with 22472 MB memory) -> physical GPU (device: 1, name: Quadro RTX 6000, pci bus id: 0000:d8:00.0, compute capability: 7.5)
```

Figura 23: Sortida inicialització del Tensorflow

```
NUM OF OBJECTS : 27
FPS : 14.728587330961854 Average_Time : 0.013579034805297853 BBXS : 17
Assignment after thresholding: [0, 8, 1, -1, -1, 10, 5, -1, 6, 7, 4, 15, 12, 9, 13, -1, 11, 2, -1, 16, -1, -1, 14, -1, 3, -1, -1]
Unassigned detects: []
NUM OF OBJECTS : 27
FPS : 14.33901063211514 Average_Time : 0.01394796371459961 BBXS : 18
Assignment after thresholding: [0, 8, 1, -1, -1, 12, 6, -1, 5, 7, 4, 15, -1, 9, 11, 13, 10, 3, 16, 17, -1, -1, 14, -1, 2, -1, -1]
Unassigned detects: []
NUM OF OBJECTS : 27
FPS : 14.7582309705334376 Average_Time : 0.013551759719848634 BBXS : 17
Assignment after thresholding: [0, 8, 1, -1, -1, 15, 7, -1, 5, 6, 4, -1, -1, 10, 11, 13, 9, 3, 14, 16, -1, -1, 12, -1, 2, -1, -1]
Unassigned detects: []
NUM OF OBJECTS : 27
```

Figura 24: Sortida del progrés del algorisme frame a frame

```
FPS : 14.84993237645426 Average_Time : 0.013468074798583985 BBXS : 7
Assignment after thresholding: [0, 1, -1, 3, -1, 4, 6, 5, 2]
Unassigned detects: []
NUM OF OBJECTS : 9
Video Ended
```

Figura 25: Missatge final del processament del algorisme

## B.2 Codi Datasets

### B.2.1 extractFrameData.py

```
1 import numpy as np
2 import cv2
3 import os
4 import json
5
6 # Define path for box information folder, video folder and
7 #   ↳ mask file
7 trackPath = '/home/virginia/TFG/PIGDATA/annotated'
8 maskPath = "/home/virginia/TFG/PIGDATA/mask.jpg"
9
10 Folders = [x[0] for x in os.walk(trackPath)]
11 Folders.pop(0)
12
13 # Partial path for images
14 partialPath = trackPath + "/frames"
15
16 frames = False
17
18 video = 1
19 for folder in Folders:
20     folderName = os.path.basename(folder)
21     # Extract subdirectories for box information
22     # Each subdirectory name in trackPath equals a
23     #   ↳ subdirecroty name in videoPath
23     subFolders = [x[0] for x in os.walk(folder)]
24     subFolders.pop(0)
25     #To select only first 30 folders
26     #subFolders = sorted(subFolders)
27     #subFolders = subFolders[0:29]
28     for f in subFolders:
29         print(f)
30         if frames:
31             #Read mask image
32             mask = cv2.bitwise_not(cv2.imread(maskPath,
33             ↳ cv2.IMREAD_COLOR))
33
34         # Indicates the frame number to save frame
```

```
35     idx = 0
36
37     # Extract folder name
38     subfolderName = os.path.basename(f)
39
40     print(str(video) + " -> " + subfolderName)
41     video += 1
42
43     # Create a VideoCapture object and read video
44     #   of folder
45     cap = cv2.VideoCapture(f+"/color.mp4")
46
47     # Check if camera opened successfully
48     if (cap.isOpened()== False):
49         print("Error opening video stream or file")
50
51     file_path = partialPath+'/'+folderName+'_'+subf_
52     # Read until video is completed
53     while(cap.isOpened()):
54         # Capture frame-by-frame
55         ret, frame = cap.read()
56         if ret == True:
57             # Add mask and frame (to erase the
58             #   outside of the image)
59             newFrame = cv2.add(frame, mask)
60             # Save new frame as single image
61             cv2.imwrite(file_path+str(idx)+".j"
62                         ↵ pg",
63                         ↵ newFrame)
64             idx += 1
65             # Break the loop
66             else:
67                 break
68
69             # When everything done, release the video
70             #   capture object
71             cap.release()
72         else:
73             # Extract info BBs
```

```

70         # track[0] --> frame rate (FPS) while
71             ↳ generating tracklets of a single video
72         # track[1] --> mean tracklet length
73         # track[2] --> video output resolution (should
74             ↳ be always 1280x720 pixels)
75         # track[3] --> N-dimensional (N = number of
76             ↳ tracklets) list. Each list entry contains
77             ↳ an M-dimensional (M = tracklet length)
78             ↳ array representing a single tracklet.
79             #           Each entry in the tracklet
80                 ↳ array has 6 values [frameID, bbox_X_min,
81                 ↳ bbox_Y_min, bbox_X_max, bbox_Y_max,
82                 ↳ tracklet_state],
83                 #           "tracklet_state" can have 3
84                 ↳ values: 0 = new tracklet, 1 = updated
85                 ↳ tracklet, 2 = wrong tracklet or no
86                 ↳ available detection

87
88
89
90
91
92
93
94
95

```

---

```

96         ap = False
97         count = 0
98         # For each tracklet saved
99         for t in track:
100             # If tracklet discontinued
101             while ap and t['frameNumber'] > count:
102                 file_path = partialPath+'/'+folderName+
103                 ↳ ame+'_'+subfolderName+"_"+str(c)
104                 ↳ ount*3)+"."+jpg"
105                 saved = False
106                 if data != []:
107                     for fr in data:
108                         if fr[0] == file_path:
109                             fr[2].append(str(last_)
110                             ↳ fr['bbox']['x']+","
111                             ↳ "+str(last_fr['bbox']
112                             ↳ 'x'])+","
113                             ↳ "+str(last_fr['bbox'][
114                             ↳ 'x']+last_fr['bbox'][
115                             ↳ 'widt'
116                             ↳ 'h'])+","
117                             ↳ "+str(last_fr['bbox'][
118                             ↳ 'y']+last_fr['bbox'][
119                             ↳ 'hei'
120                             ↳ 'ght'])+",0")
121                         saved = True
122                         break
123             if not saved:
124                 data.append([file_path,3*count]
125                 ↳ , [str(last_fr['bbox']['x'])]
126                 ↳ +","
127                 ↳ "+str(last_fr['bbox']['y'])
128                 ↳ '])+","
129                 ↳ "+str(last_fr['bbox'][
130                 ↳ 'x']+last_fr['bbox'][
131                 ↳ 'widt'
132                 ↳ 'h'])+","
133                 ↳ "+str(last_fr['bbox'][
134                 ↳ 'y']+last_fr['bbox'][
135                 ↳ 'hei'
136                 ↳ 'ght'])+",0"])
137             count+=1
138             # If tracklet actual
139             file_path = partialPath+'/'+folderName+
140             ↳ '_'+subfolderName+"_"+str(3*t['fram
141             ↳ eNumber']))+"."+jpg"
142             saved = False
143             if data != []:

```

```

117         for fr in data:
118             if fr[0] == file_path:
119                 fr[2].append(str(t['bbox'][
120                     'x'])+", "+str(t['bbox'][
121                     'y'])+", "+str(t['bbox'][
122                     'width'])+
123                     "], "+str(t['bbox'][
124                     'height'])+", 0")
125             saved = True
126             break
127         if not saved:
128             data.append([file_path, 3*t['frameN
129                     umber'], str(t['bbox'][
130                     'x'])+", "+
131                     "+str(t['bbox'][
132                     'y'])+", "+str(t[
133                     'bbox'][
134                     'x']+t['bbox'][
135                     'width'])+
136                     "], "+str(t['bbox'][
137                     'y']+t['bbox'][
138                     'height'])+", 0"))
139         last_fr = t
140         ap = True
141         count = t['frameNumber']+1
142         # If tracklet not finished
143         while 3*count<1800:
144             file_path =
145                 partialPath+'/'+folderName+'_'+subf
146                 olderName+"_"+str(count*3)+".jpg"
147             saved = False
148             if data != []:
149                 for fr in data:
150                     if fr[0] == file_path:
151                         fr[2].append(str(last_fr['
152                             bbox']['x'])+", "+str(la
153                             st_fr['bbox']['y'])+", "+
154                             +str(last_fr['bbox'][
155                             'x']+last_fr['bbox'][
156                             'width'])+
157                             ", "+str(last_fr['
158                             bbox']['y']+last_fr['bb
159                             ox']['height'])+", 0")
160                         saved = True
161                         break
162                     if not saved:

```

```
138                     data.append([file_path,3*count,[st_]
139                         ↪ r(last_fr['bbox']['x'])+", "+str_
140                         ↪ (last_fr['bbox']['y'])+", "+str(_
141                         ↪ last_fr['bbox']['x']+last_fr['b_'
142                         ↪ box']['width'])+", "+str(last_fr_
143                         ↪ ['bbox']['y']+last_fr['bbox']['_'
144                         ↪ height)])+", 0]]))
145             count+=1
146
147             # Define text to annotate in .txt file in
148             → format (file_path,x1,y1,x2,y2,class_name)
149             data.sort(key=lambda x: x[1])
150             #print(data)
151             #Write lines in annotation file
152             for d in data:
153                 text = d[0]
154                 for f in d[2]:
155                     text = text + " " + f
156                 file.write(text+"\n")
157             file.close()
```

### B.2.2 Extract\_frames.py

```
1 import numpy as np
2 import cv2
3
4 video = ("./")
5 # Create a VideoCapture object and read video of folder
6 cap = cv2.VideoCapture("./GH010008_Test.mp4")
7
8 # Check if camera opened successfully
9 if (cap.isOpened()== False):
10     print("Error opening video stream or file")
11
12 i = 0
13
14 # Read until video is completed
15 while(cap.isOpened()):
16     # Capture frame-by-frame
17     ret, frame = cap.read()
18     if ret == True:
19         if i%10 == 0:
20             # Save new frame as single image
21             cv2.imwrite("./frames_persona/GH010008_Test_Pe_"
22                         "rs_" +str(i)+ ".jpg",
23                         frame)
24         i += 1
25     # Break the loop
26     #else:
27     #    break
28
29 # When everything done, release the video capture object
30 cap.release()
```

### B.2.3 breafig\_datasets.py

```
1 import os
2 import sys
3 import cv2
4 import random
5 import numpy as np
6
7 # Check how many pigs and people are in a dataset
8 def load_annotations(annot_path):
9     count_pig = 0
10    count_pers = 0
11    final_annotations = []
12    with open(annot_path, 'r') as f:
13        txt = f.read().splitlines()
14        annotations = [line.strip() for line in txt if
15            len(line.strip().split()[1:]) != 0]
16    n = 1
17
18    for annotation in annotations:
19        # fully parse annotations
20        line = annotation.split(" ")
21        del line[0]
22
23        for l in line:
24            x = l.split(',')
25
26            if x[4] == '0':
27                count_pig+=1
28            else:
29                count_pers+=1
30
31    return count_pig, count_pers
32
33 count_pig, count_pers = load_annotations("./data/PigPersv2_"
34                                         "/annotation_train.txt")
35 print("Train")
36 print(count_pig)
37 print(count_pers)
```

```
37 count_pig, count_pers =
    ↳ load_annotations("./data/PigPersv2/annotation_val.txt")
38 print("Val")
39 print(count_pig)
40 print(count_pers)
41
42 count_pig, count_pers = load_annotations("./data/PigPersv2_"
    ↳ "/annotation_test.txt")
43 print("Test")
44 print(count_pig)
45 print(count_pers)
```

### B.2.4 ExtractROIs.m

```
1 clear all
2 close all
3
4 MyFolderInfo = dir('frames/GH010013_zenital_Train*');
5 i = 1;
6 rois = [] ;
7 global KEY_IS_PRESSED;
8 for f = 221:240
9     disp(f);
10    rois_img = [] ;
11    string = strcat('./frames/' ,MyFolderInfo(f).name);
12    I = imread(string); imshow(I);
13    KEY_IS_PRESSED = 0;
14    gcf;
15    % Select all pigs
16    set(gcf, 'KeyPressFcn', @myKeyPressFcn);
17    while ~KEY_IS_PRESSED
18        roi = drawrectangle();
19        if ~KEY_IS_PRESSED
20            disp("pig");
21            rois_img = [rois_img ;[roi.Position]];
22        end
23    end
24    rois_img2 = [] ;
25    disp("next");
26    KEY_IS_PRESSED = 0;
27    gcf;
28    % Select all people
29    set(gcf, 'KeyPressFcn', @myKeyPressFcn);
30    while ~KEY_IS_PRESSED
31        roi = drawrectangle();
32        if ~KEY_IS_PRESSED
33            disp("person");
34            rois_img2 = [rois_img2 ; [roi.Position]];
35        end
36    end
37    % Save data
38    rois_p.name = string;
39    rois_p.bboxes_pigs = rois_img;
```

```
40     rois_p.bboxes_pers = rois_img2;
41     rois = [rois rois_p];
42     i = i+1;
43 end
44
45 % Save BBxs data
46 fileID =
    ↳ fopen('annotations_GH010013_zenital_Train_221to240.txt','w');
47 for f = 1:size(rois,2)
    text = rois(f).name;
48    % Save pigs BBxs
49    for i = 1:size(rois(f).bboxes_pigs,1)
        text = strcat(text,
    ↳ ",int2str(rois(f).bboxes_pigs(i,1)),
    ↳ ",",int2str(rois(f).bboxes_pigs(i,2)),",",
    ↳ int2str(rois(f).bboxes_pigs(i,1)+rois(f).bboxes_pigs(i,3)),",
    ↳ int2str(rois(f).bboxes_pigs(i,2)+rois(f).bboxes_pigs(i,4)),",0");
        end
50    % Save people BBxs
51    for i = 1:size(rois(f).bboxes_pers,1)
        text = strcat(text,
    ↳ ",int2str(rois(f).bboxes_pers(i,1)),
    ↳ ",",int2str(rois(f).bboxes_pers(i,2)),",
    ↳ int2str(rois(f).bboxes_pers(i,1)+rois(f).bboxes_pers(i,3)),",
    ↳ int2str(rois(f).bboxes_pers(i,2)+rois(f).bboxes_pers(i,4)),",1");
        end
52    text = strcat(text,"\n");
53    fprintf(fileID,text);
54 end
55
56 function myKeyPressFcn(hObject, event)
57     global KEY_IS_PRESSED
58     KEY_IS_PRESSED = 1;
59     disp('key is pressed');
60 end
61
62
63
64
65 end
```

### B.2.5 ExtractROIs\_people.m

```
1 clear all
2 close all
3
4 MyFolderInfo = dir('frames_persona/GH010008_Val*');
5 i = 1;
6 rois = [] ;
7
8 for f = 401:543
9     disp(f);
10    rois_img = [] ;
11    % Define new name for image
12    string =
13        strcat('./frames_persona/' ,MyFolderInfo(f).name);
14    I = imread(string); imshow(I);
15
16    % Select person
17    roi = drawrectangle();
18
19    % Crop and save person image
20    I2 = imcrop(I,roi.Position);
21    string =
22        strcat('./frames_persona_cut/' ,MyFolderInfo(f).name);
23    imwrite(I2,string);
24    S = size(I2);
25    pos = [2 2 S(2)-2 S(1)-2];
26
27    % Save data
28    rois_img = [rois_img ;pos];
29    rois_p.name = string;
30    rois_p.bboxes_pigs = [];
31    rois_p.bboxes_pers = rois_img;
32    rois = [rois rois_p];
33    i = i+1;
34
35    % Save BBxs data
36    fileID = fopen('annotations_GH010008_Val_Pers_401to543.txt' ]
37        , 'w');
38    for f = 1:size(rois,2)
```

```
37     text = rois(f).name;
38     for i = 1:size(rois(f).bboxes_pers,1)
39         text = strcat(text,"
40             ",int2str(rois(f).bboxes_pers(i,1)),",",
41             int2str(rois(f).bboxes_pers(i,2)),",",
42             int2str(rois(f).bboxes_pers(i,1)+rois(f).bboxes_pers(i,3)),",",
43             int2str(rois(f).bboxes_pers(i,2)+rois(f).bboxes_pers(i,
44             ,4)),",1");
45     end
46     text = strcat(text,"\n");
47     fprintf(fileID,text);
48 end
49 fclose(fileID);
```

### B.2.6 Object\_Detection\_DataPreprocessing.ipynb

```
1 import cv2
2 from matplotlib import pyplot as plt
3 import numpy as np
4 import os
5 import pandas as pd
6 import random
7 from skimage import io
8 from shutil import copyfile
9 import sys
10 import time
11
12 '''
13 Load data from .csv file
14 train-images-boxable.csv file contains the image name and
15   ↳ image url
15 train-annotations-bbox.csv file contains the bounding box
16   ↳ info with the image id (name) and the image label name
16 class-descriptions-boxable.csv file contains the image
17   ↳ label name corresponding to its class name
17 Download link:
18
19 https://storage.googleapis.com/openimages/web/download.html
20   ↳ 1 ''
21
21 https://www.figure-eight.com/dataset/open-images-annotated
22   ↳ -with-bounding-boxes/
23 !wget https://storage.googleapis.com/openimages/2018_04/tr
24   ↳ ain/train-annotations-bbox.csv
24 !wget https://storage.googleapis.com/openimages/2018_04/tr
25   ↳ ain/train-images-boxable-with-rotation.csv
26
26 '''
27 The original code used "train-images-boxable.csv" but I
28   ↳ couldn't find it. So, I am using
29   ↳ "train-images-boxable-with-rotations.csv"
28 '''
29
```

```
30 !wget https://storage.googleapis.com/openimages/v5/class-d_]
   ↳ escriptions-boxable.csv
31
32 images_boxable_fname =
   ↳ 'train-images-boxable-with-rotation.csv'
33 annotations_bbox_fname = 'train-annotations-bbox.csv'
34 class_descriptions_fname = 'class-descriptions-boxable.csv'
35
36 images_boxable = pd.read_csv(images_boxable_fname)
37 images_boxable.head()
38
39 annotations_bbox = pd.read_csv(annotations_bbox_fname)
40 annotations_bbox.head()
41
42 '''
43 1. **XMin, XMax, YMin, YMax**: coordinates of the box, in
   ↳ normalized image coordinates.
44 2. **IsOccluded**: Indicates that the object is occluded
   ↳ by another object in the image.
45 3. **IsTruncated**: Indicates that the object extends
   ↳ beyond the boundary of the image.
46 4. **IsGroupOf**: Indicates that the box spans a group of
   ↳ objects (e.g., a bed of flowers or a crowd of people).
   ↳ We asked annotators to use this tag for cases with
   ↳ more than 5 instances which are heavily occluding each
   ↳ other and are physically touching.
47 5. **IsDepiction**: Indicates that the object is a
   ↳ depiction (e.g., a cartoon or drawing of the object,
   ↳ not a real physical instance).
48 6. **IsInside**: Indicates a picture taken from the inside
   ↳ of the object (e.g., a car interior or inside of a
   ↳ building).
49 '''
50
51 class_descriptions = pd.read_csv(class_descriptions_fname,
   ↳ header=None)
52 class_descriptions.head()
53
54 ### Plot Bounding box
55
56 def plot_bbox(img_id):
```



```
90 for img_id in random.sample(list(least_objects_img_ids),
91     ↴ 5):
92     plot_bbox(img_id)
93
94
95 For here, I just want to detect three classes, which
96     ↴ include person, mobile phone and car. We just extract
97     ↴ 1000 images for each class from the whole dataset.
98
99 # Find the label_name for 'Person', 'Mobile Phone' and
100    ↴ 'Car' classes
101 person_pd =
102     ↴ class_descriptions[class_descriptions[1]=='Person']
103
104 """
105 **Be careful that there might be several object in one
106     ↴ image. For example, there are three person and two
107     ↴ mobile phone in one image**
108 """
109
110 person_bbox = annotations_bbox[annotations_bbox['LabelName'
111     ↴ ]==label_name_person]
112
113 person_bbox = annotations_bbox[annotations_bbox['LabelName'
114     ↴ ]==label_name_person]
115 print('There are %d persons in the dataset'
116     ↴ %(len(person_bbox)))
117 person_img_id = person_bbox['ImageID']
118 person_img_id = np.unique(person_img_id)
```

```
119 print('There are %d images which contain persons' %
    ↪ (len(person_img_id)))
120
121 '''
122 We just randomly pick n images in here.
123 '''
124
125 # here I've chosen only 10 images for speed, change it to
    ↪ your liking
126 n = 50
127 subperson_img_id = random.sample(list(person_img_id), n)
128 subperson_pd = images_boxable.loc[images_boxable['ImageID']]
    ↪ .isin(subperson_img_id)]
129
130 subperson_pd.shape
131
132 subperson_pd.head()
133
134 subperson_dict = subperson_pd[['ImageID', 'OriginalURL']].
    ↪ set_index('ImageID')[["OriginalURL"]].to_dict()
135
136 mappings = [subperson_dict]
137
138 len(mappings)
139
140 len(mappings[0])
141
142 classes = ['Person']
143
144 ### Download images
145
146 We need to save the images with filename as image id with
    ↪ jpg extension
147
148 # download images
149 num = 1
150 for idx, obj_type in enumerate(classes):
151     n_issues = 0
152     # create the directory
153     if not os.path.exists(obj_type+"_mini"):
154         os.mkdir(obj_type+"_mini")
```

```
155     for img_id, url in mappings[idx].items():
156         try:
157             if num%50 == 0:
158                 print(num)
159             num += 1
160             img = io.imread(url)
161             saved_path = os.path.join(obj_type+"_mini",
162                                     img_id+".jpg")
163             io.imsave(saved_path, img)
164         except Exception as e:
165             n_issues += 1
166         print(f"Images Issues: {n_issues}")
167
168 !ls Person_mini | wc -l
169
170
171 (fname_path, xmin, xmax, ymin, ymax, class_name)
172
173 train: 0.8
174 validation: 0.2
175
176 # save images to train and test directory
177 train_path = 'train_mini'
178 test_path = 'test_mini'
179
180 !mkdir train_mini test_mini
181
182 random.seed(1)
183
184 for i in range(len(classes)):
185     all_imgs = os.listdir(classes[i] + "_mini")
186     all_imgs = [f for f in all_imgs if not
187                 f.startswith('.')]
188     random.shuffle(all_imgs)
189
190     limit = int(n*0.8)
191
192     train_imgs = all_imgs[:limit]
193     test_imgs = all_imgs[limit:]
```

```
194 # copy each classes' images to train directory
195 for j in range(len(train_imgs)):
196     original_path = os.path.join(classes[i]+"_mini",
197         → train_imgs[j])
198     new_path = os.path.join(train_path, train_imgs[j])
199     copyfile(original_path, new_path)
200
201 # copy each classes' images to test directory
202 for j in range(len(test_imgs)):
203     original_path = os.path.join(classes[i]+"_mini",
204         → test_imgs[j])
205     new_path = os.path.join(test_path, test_imgs[j])
206     copyfile(original_path, new_path)
207
208 !ls train_mini | wc -l
209
210 !ls test_mini | wc -l
211
212 """
213 The expected number of training images and validation
214     → images should be 24 and 6 respectively.
215
216 However, there might be some overlap images which appear
217     → in two or three classes simultaneously. For instance,
218     → an image might be a person walking on the street and
219     → there are several cars in the street
220 """
221
222 label_names = [label_name_person]
223
224 train_df = pd.DataFrame(columns=['FileName', 'XMin',
225     → 'XMax', 'YMin', 'YMax', 'ClassName'])
226
227 # Find boxes in each image and put them in a dataframe
228 train_imgs = os.listdir(train_path)
229 train_imgs = [name for name in train_imgs if not
230     → name.startswith('.')]
231
232 for i in range(len(train_imgs)):
233     sys.stdout.write('Parse train_imgs ' + str(i) + ' ;
234     → Number of boxes: ' + str(len(train_df)) + '\r')
```

```

226     sys.stdout.flush()
227     img_name = train_imgs[i]
228     img_id = img_name[0:16]
229     tmp_df = annotations_bbox[annotations_bbox['ImageID']==_
230         ↳ img_id]
231     for index, row in tmp_df.iterrows():
232         labelName = row['LabelName']
233         for i in range(len(label_names)):
234             if labelName == label_names[i]:
235                 train_df = train_df.append({'FileName':_
236                     ↳ img_name,
237                         'XMin': row['XM_'
238                             ↳ in'],
239                         'XMax': row['XM_'
240                             ↳ ax'],
241                         'YMin': row['YM_'
242                             ↳ in'],
243                         'YMax': row['YM_'
244                             ↳ ax'],
245                         'ClassName': cl_'
246                             ↳ asses[i]},_
247                             ↳ ignore_index=True_
248                             ↳ ue)
249
250     """
251
252     Let's test if they work fine by plotting the bounding box
253         ↳ for the above 5 images
254     """
255
256     train_img_ids = train_df["FileName"].head().str.split(".")
257         ↳ .str[0].unique()
258
259     for img_id in train_img_ids:
260         plot_bbox(img_id)
261
262     """
263
264     **This looks fine to me!!**

```

```
257  '''
258
259 test_df = pd.DataFrame(columns=['FileName', 'XMin', 'XMax',
260                         'YMin', 'YMax', 'ClassName'])
261
262 # find boxes in each image and put them in a dataframe
263 test_imgs = os.listdir(test_path)
264 test_imgs = [name for name in test_imgs if not
265             name.startswith('.')]
266
267 for i in range(len(test_imgs)):
268     sys.stdout.write('Parse test_imgs ' + str(i) + ';\n'
269                      ' Number of boxes: ' + str(len(test_df)) + '\r')
270     sys.stdout.flush()
271     img_name = test_imgs[i]
272     img_id = img_name[0:16]
273     tmp_df = annotations_bbox[annotations_bbox['ImageID']==_
274                               img_id]
275     for index, row in tmp_df.iterrows():
276         labelName = row['LabelName']
277         for i in range(len(label_names)):
278             if labelName == label_names[i]:
279                 test_df = test_df.append({'FileName':
280                                         img_name,
281                                         'XMin': row['XM_'
282                                         + 'in'],
283                                         'XMax': row['XM_'
284                                         + 'ax'],
285                                         'YMin': row['YM_'
286                                         + 'in'],
287                                         'YMax': row['YM_'
288                                         + 'ax'],
289                                         'ClassName': cl_
290                                         + asses[i]},
291                                         ignore_index=True,
292                                         + ue)
293
294 train_df.to_csv('train_mini.csv')
295 test_df.to_csv('test_mini.csv')
296
297 ### Write train.csv to annotation.txt
```

```
287
288 train_df = pd.read_csv('train_mini.csv')
289
290 # for training
291 with open("annotation_mini.txt", "w+") as f:
292     for idx, row in train_df.iterrows():
293         sys.stdout.write(str(idx) + '\r')
294         sys.stdout.flush()
295         img = cv2.imread('train_mini/' + row['FileName'])
296         height, width = img.shape[:2]
297         x1 = int(row['XMin'] * width)
298         x2 = int(row['XMax'] * width)
299         y1 = int(row['YMin'] * height)
300         y2 = int(row['YMax'] * height)
301
302         google_colab_file_path = '/home/virginia/TFG/Faster
303             → R-CNN/Faster_RCNN_for_Open_Images_Dataset_Keras-
304             → master/train_mini'
305         fileName = os.path.join(google_colab_file_path,
306             → row['FileName'])
307         className = row['ClassName']
308         f.write(fileName + ',' + str(x1) + ',' + str(y1) +
309             → ',' + str(x2) + ',' + str(y2) + ',' + className +
310             → '\n')
311
312 test_df = pd.read_csv('test_mini.csv')
313
314 # for test
315 with open("test_annotation_mini.txt", "w+") as f:
316     for idx, row in test_df.iterrows():
317         sys.stdout.write(str(idx) + '\r')
318         sys.stdout.flush()
319         img = cv2.imread('test_mini/' + row['FileName'])
320         height, width = img.shape[:2]
321         x1 = int(row['XMin'] * width)
322         x2 = int(row['XMax'] * width)
323         y1 = int(row['YMin'] * height)
324         y2 = int(row['YMax'] * height)
```

```
321     google_colab_file_path = '/home/virginia/TFG/Faster
      ↵   R-CNN/Faster_RCNN_for_Open_Images_Dataset_Keras-
      ↵   master/test_mini'
322     fileName = os.path.join(google_colab_file_path,
      ↵   row['FileName'])
323     className = row['ClassName']
324     f.write(fileName + ',' + str(x1) + ',' + str(y1) +
      ↵   ',' + str(x2) + ',' + str(y2) + ',' + className +
      ↵   '\n')
```

## C.3 Codi YOLOv4

### C.3.1 configs.py

```

1 #=====
2 #   =====
3 #   File name      : configs.py
4 #   Author         : PyLessons
5 #   Created date: 2020-08-18
6 #   Website        : https://pylessons.com/
7 #   GitHub          :
8 #   Description   : yolov3 configuration file
9 #
10 #   Modified by : Virginia Ramón
11 #=====
12 #
13 # YOLO options
14 YOLO_TYPE                  = "yolov4" # yolov4 or yolov3
15 YOLO_FRAMEWORK              = "tf" # "tf" or "trt"
16 YOLO_V3_WEIGHTS             = "model_data/yolov3.weights"
17 YOLO_V4_WEIGHTS             = "model_data/yolov4.weights"
18 YOLO_V3_TINY_WEIGHTS        =
19 #                         ↳ "model_data/yolov3-tiny.weights"
20 YOLO_V4_TINY_WEIGHTS        =
21 #                         ↳ "model_data/yolov4-tiny.weights"
22 YOLO_TRT_QUANTIZE_MODE      = "INT8" # INT8, FP16, FP32
23 #YOLO_CUSTOM_WEIGHTS        = False
24 #YOLO_COCO_CLASSES           = "model_data/coco/coco.names"
25 YOLO_CUSTOM_WEIGHTS         = True
26 YOLO_COCO_CLASSES            = "/home/virginia/TFG/YOLOv4/T
27 #                         ↳ ensorFlow-2.x-YOLOv3-master/data/annotation.names"
28 YOLO_STRIDES                 = [8, 16, 32]
29 YOLO_IOU_LOSS_THRESH         = 0.9
30 YOLO_ANCHOR_PER_SCALE        = 3
31 YOLO_MAX_BBOX_PER_SCALE      = 100
32 YOLO_INPUT_SIZE               = 416
33 if YOLO_TYPE                  == "yolov4":
```

```

31     YOLO_ANCHORS          = [[[12,   16], [19,    36],
32                               ↳ [40,    28]], ,
33                               [[[36,   75], [76,    55],
34                               ↳ [72,   146]], ,
35                               [[142, 110], [192,  243],
36                               ↳ [459,  401]]]
37
38 # Train options
39 TRAIN_YOLO_TINY           = False
40 TRAIN_SAVE_BEST_ONLY      = True # saves only best model
41                               ↳ according validation loss (True recommended)
42 TRAIN_SAVE_CHECKPOINT     = False # saves all best
43                               ↳ validated checkpoints in training process (may require
44                               ↳ a lot disk space) (False recommended)
45 TRAIN_CLASSES              = "/home/virginia/TFG/YOLOv4/T_"
46                               ↳ ensorFlow-2.x-YOLOv3-master/data/annotation.names"
47 TRAIN_ANNOT_PATH           =
48                               ↳ "/home/virginia/TFG/YOLOv4/TensorFlow-2.x-YOLOv3-maste_"
49                               ↳ r/data/PigPersv2/annotation_train.txt"
50 TRAIN_LOGDIR               = "log"
51 TRAIN_CHECKPOINTS_FOLDER   =
52                               ↳ "checkpoints/yolov4_PigPerse46"
53 TRAIN_MODEL_NAME            = f"{YOLO_TYPE}_custom"
54 TRAIN_LOAD_IMAGES_TO_RAM    = True # With True faster
55                               ↳ training, but need more RAM
56 TRAIN_BATCH_SIZE             = 4
57 TRAIN_INPUT_SIZE             = 416
58 TRAIN_DATA_AUG               = True
59 TRAIN_TRANSFER                = True
60 TRAIN_FROM_CHECKPOINT       = False #
61                               ↳ "checkpoints/yolov3_custom"
62 TRAIN_LR_INIT                 = 4e-6
63 TRAIN_LR_END                  = 4e-7
64 TRAIN_WARMUP_EPOCHS           = 1
65 TRAIN_EPOCHS                   = 40

```

```
57
58 # TEST options
59 TEST_ANNOT_PATH           =
  ↳ "/home/virginia/TFG/YOLOv4/TensorFlow-2.x-YOL0v3-maste_
  ↳ r/data/PigPersv2/annotation_val.txt"
60 TEST_BATCH_SIZE            = 4
61 TEST_INPUT_SIZE            = 416
62 TEST_DATA_AUG              = False
63 TEST_DECTECTED_IMAGE_PATH  = ""
64 TEST_SCORE_THRESHOLD       = 0.5
65 TEST_IOU_THRESHOLD         = 0.5
66
67 if TRAIN_YOLO_TINY:
68     YOLO_STRIDES             = [16, 32]
69     # YOLO_ANCHORS           =
      [[[[23, 27], [37, 58],
      ↳ [81, 82]], # this line can be uncommented for
      ↳ default coco weights
70     YOLO_ANCHORS             = [[[10, 14], [23, 27],
      ↳ [37, 58]],
71                               [[81, 82], [135, 169],
      ↳ [344, 319]]]
```

### C.3.2 yolov4.py

```

1 #=====
2 #=====#
3 #   File name    : yolov4.py
4 #   Author       : PyLessons
5 #   Created date: 2020-09-31
6 #   Website      : https://pylessons.com/
7 #   GitHub        :
8 #   Description  : main yolov3 & yolov4 functions
9 #
10 #=====
11 import numpy as np
12 import tensorflow as tf
13 from tensorflow.keras.layers import Conv2D, Input,
14     ↳ LeakyReLU, ZeroPadding2D, BatchNormalization, MaxPool2D
14 from tensorflow.keras.regularizers import l2
15 from yolov3.configs import *
16 import sys
17 sys.path.append("/home/virginia/TFG/YOLOv4/TensorFlow-2.x-")
18     ↳ YOLOv3-master/")
19 STRIDES          = np.array(YOLO_STRIDES)
20 ANCHORS          = (np.array(YOLO_ANCHORS).T/STRIDES).T
21
22 def read_class_names(class_file_name):
23     # loads class name from a file
24     names = {}
25     with open(class_file_name, 'r') as data:
26         for ID, name in enumerate(data):
27             names[ID] = name.strip('\n')
28     return names
29
30 class BatchNormalization(BatchNormalization):
31     # "Frozen state" and "inference mode" are two separate
32     ↳ concepts.
32     # `layer.trainable = False` is to freeze the layer, so
33     ↳ the layer will use

```

```

33     # stored moving `var` and `mean` in the "inference
34     # mode", and both `gama`
35     # and `beta` will not be updated !
36     def call(self, x, training=False):
37         if not training:
38             training = tf.constant(False)
39         training = tf.logical_and(training, self.trainable)
40         return super().call(x, training)
41
41     def convolutional(input_layer, filters_shape,
42                         downsample=False, activate=True, bn=True,
43                         activate_type='leaky'):
44         if downsample:
45             input_layer = ZeroPadding2D(((1, 0), (1,
46                                         0)))(input_layer)
47             padding = 'valid'
48             strides = 2
49         else:
50             strides = 1
51             padding = 'same'
52
50         conv = Conv2D(filters=filters_shape[-1], kernel_size =
51                         filters_shape[0], strides=strides,
52                         padding=padding, use_bias=not bn,
53                         kernel_regularizer=l2(0.0005),
54                         kernel_initializer=tf.random_normal_init_
55                         ializer(stddev=0.01),
56                         bias_initializer=tf.constant_initializer_
57                         ((0.))(input_layer)
58
58         if bn:
59             conv = BatchNormalization()(conv)
60         if activate == True:
61             if activate_type == "leaky":
62                 conv = LeakyReLU(alpha=0.1)(conv)
63             elif activate_type == "mish":
64                 conv = mish(conv)
65
62         return conv
63
64     def mish(x):
65         return x * tf.math.tanh(tf.math.softplus(x))

```

```
66
67 def residual_block(input_layer, input_channel,
68     ↳ filter_num1, filter_num2, activate_type='leaky'):
69     short_cut = input_layer
70     conv = convolutional(input_layer, filters_shape=(1, 1,
71         ↳ input_channel, filter_num1),
72         ↳ activate_type=activate_type)
73     conv = convolutional(conv      , filters_shape=(3, 3,
74         ↳ filter_num1,   filter_num2),
75         ↳ activate_type=activate_type)

76     residual_output = short_cut + conv
77     return residual_output

78
79 def upsample(input_layer):
80     return tf.image.resize(input_layer,
81         ↳ (input_layer.shape[1] * 2, input_layer.shape[2] *
82             2), method='nearest')

83
84 def route_group(input_layer, groups, group_id):
85     convs = tf.split(input_layer,
86         ↳ num_or_size_splits=groups, axis=-1)
87     return convs[group_id]

88
89 def darknet53(input_data):
90     input_data = convolutional(input_data, (3, 3, 3, 32))
91     input_data = convolutional(input_data, (3, 3, 32,
92         ↳ 64), downsample=True)

93     for i in range(1):
94         input_data = residual_block(input_data, 64, 32,
95             ↳ 64)

96     input_data = convolutional(input_data, (3, 3, 64,
97         ↳ 128), downsample=True)

98     for i in range(2):
99         input_data = residual_block(input_data, 128, 64,
100            ↳ 128)
```

```
94     input_data = convolutional(input_data, (3, 3, 128,
95         ↳ 256), downsample=True)
96
97     for i in range(8):
98         input_data = residual_block(input_data, 256, 128,
99             ↳ 256)
100
101    route_1 = input_data
102    input_data = convolutional(input_data, (3, 3, 256,
103        ↳ 512), downsample=True)
104
105    for i in range(8):
106        input_data = residual_block(input_data, 512, 256,
107            ↳ 512)
108
109    route_2 = input_data
110    input_data = convolutional(input_data, (3, 3, 512,
111        ↳ 1024), downsample=True)
112
113 def cspdarknet53(input_data):
114     input_data = convolutional(input_data, (3, 3, 3,
115         ↳ 32), activate_type="mish")
116     input_data = convolutional(input_data, (3, 3, 32,
117         ↳ 64), downsample=True, activate_type="mish")
118
119     route = input_data
120     route = convolutional(route, (1, 1, 64, 64),
121         ↳ activate_type="mish")
122     input_data = convolutional(input_data, (1, 1, 64, 64),
123         ↳ activate_type="mish")
124     for i in range(1):
125         input_data = residual_block(input_data, 64, 32,
126             ↳ 64, activate_type="mish")
127     input_data = convolutional(input_data, (1, 1, 64, 64),
128         ↳ activate_type="mish")
```

```
123
124     input_data = tf.concat([input_data, route], axis=-1)
125     input_data = convolutional(input_data, (1, 1, 128,
126         ↳ 64), activate_type="mish")
127     input_data = convolutional(input_data, (3, 3, 64,
128         ↳ 128), downsample=True, activate_type="mish")
129     route = input_data
130     route = convolutional(route, (1, 1, 128, 64),
131         ↳ activate_type="mish")
132     input_data = convolutional(input_data, (1, 1, 128,
133         ↳ 64), activate_type="mish")
134     for i in range(2):
135         input_data = residual_block(input_data, 64, 64,
136             ↳ 64, activate_type="mish")
137     input_data = convolutional(input_data, (1, 1, 64, 64),
138         ↳ activate_type="mish")
139     input_data = tf.concat([input_data, route], axis=-1)

140
141     input_data = convolutional(input_data, (1, 1, 128,
142         ↳ 128), activate_type="mish")
143     input_data = convolutional(input_data, (3, 3, 128,
144         ↳ 256), downsample=True, activate_type="mish")
145     route = input_data
146     route = convolutional(route, (1, 1, 256, 128),
147         ↳ activate_type="mish")
148     input_data = convolutional(input_data, (1, 1, 256,
149         ↳ 128), activate_type="mish")
150     for i in range(8):
151         input_data = residual_block(input_data, 128, 128,
152             ↳ 128, activate_type="mish")
153     input_data = convolutional(input_data, (1, 1, 128,
154         ↳ 128), activate_type="mish")
155     input_data = tf.concat([input_data, route], axis=-1)

156
157     input_data = convolutional(input_data, (1, 1, 256,
158         ↳ 256), activate_type="mish")
159     route_1 = input_data
160     input_data = convolutional(input_data, (3, 3, 256,
161         ↳ 512), downsample=True, activate_type="mish")
162     route = input_data
```

```
149     route = convolutional(route, (1, 1, 512, 256),
150         ↵ activate_type="mish")
151     input_data = convolutional(input_data, (1, 1, 512,
152         ↵ 256), activate_type="mish")
153     for i in range(8):
154         input_data = residual_block(input_data, 256, 256,
155             ↵ 256, activate_type="mish")
156     input_data = convolutional(input_data, (1, 1, 256,
157         ↵ 256), activate_type="mish")
158     input_data = tf.concat([input_data, route], axis=-1)
159
160     input_data = convolutional(input_data, (1, 1, 512,
161         ↵ 512), activate_type="mish")
162     route_2 = input_data
163     input_data = convolutional(input_data, (3, 3, 512,
164         ↵ 1024), downsample=True, activate_type="mish")
165     route = input_data
166     route = convolutional(route, (1, 1, 1024, 512),
167         ↵ activate_type="mish")
168     input_data = convolutional(input_data, (1, 1, 1024,
169         ↵ 512), activate_type="mish")
170     input_data = tf.concat([input_data, route], axis=-1)
171
172     input_data = convolutional(input_data, (1, 1, 1024,
173         ↵ 1024), activate_type="mish")
174     input_data = convolutional(input_data, (1, 1, 1024,
175         ↵ 512))
176     input_data = convolutional(input_data, (3, 3, 512,
177         ↵ 1024))
178     input_data = convolutional(input_data, (1, 1, 1024,
179         ↵ 512))
180
181     max_pooling_1 =
182         ↵ tf.keras.layers.MaxPool2D(pool_size=13,
183         ↵ padding='SAME', strides=1)(input_data)
```

```
173     max_pooling_2 = tf.keras.layers.MaxPool2D(pool_size=9,
174         ↵ padding='SAME', strides=1)(input_data)
175     max_pooling_3 = tf.keras.layers.MaxPool2D(pool_size=5,
176         ↵ padding='SAME', strides=1)(input_data)
177     input_data = tf.concat([max_pooling_1, max_pooling_2,
178         ↵ max_pooling_3, input_data], axis=-1)
179
180
181     input_data = convolutional(input_data, (1, 1, 2048,
182         ↵ 512))
183     input_data = convolutional(input_data, (3, 3, 512,
184         ↵ 1024))
185     input_data = convolutional(input_data, (1, 1, 1024,
186         ↵ 512))
187
188
189     return route_1, route_2, input_data
190
191
192 def darknet19_tiny(input_data):
193     input_data = convolutional(input_data, (3, 3, 3, 16))
194     input_data = MaxPool2D(2, 2, 'same')(input_data)
195     input_data = convolutional(input_data, (3, 3, 16, 32))
196     input_data = MaxPool2D(2, 2, 'same')(input_data)
197     input_data = convolutional(input_data, (3, 3, 32, 64))
198     input_data = MaxPool2D(2, 2, 'same')(input_data)
199     input_data = convolutional(input_data, (3, 3, 64, 128))
200     input_data = MaxPool2D(2, 2, 'same')(input_data)
201     input_data = convolutional(input_data, (3, 3, 128,
202         ↵ 256))
203
204     route_1 = input_data
205     input_data = MaxPool2D(2, 2, 'same')(input_data)
206     input_data = convolutional(input_data, (3, 3, 256,
207         ↵ 512))
208     input_data = MaxPool2D(2, 1, 'same')(input_data)
209     input_data = convolutional(input_data, (3, 3, 512,
210         ↵ 1024))
211
212
213     return route_1, input_data
214
215
216 def cspdarknet53_tiny(input_data): # not sure how this
217     ↵ should be called
218     input_data = convolutional(input_data, (3, 3, 3, 32),
219         ↵ downsample=True)
```

```
203     input_data = convolutional(input_data, (3, 3, 32, 64),  
204         ↳ downsample=True)  
205     input_data = convolutional(input_data, (3, 3, 64, 64))  
206  
207     route = input_data  
208     input_data = route_group(input_data, 2, 1)  
209     input_data = convolutional(input_data, (3, 3, 32, 32))  
210     route_1 = input_data  
211     input_data = convolutional(input_data, (3, 3, 32, 32))  
212     input_data = tf.concat([input_data, route_1], axis=-1)  
213     input_data = convolutional(input_data, (1, 1, 32, 64))  
214     input_data = tf.concat([route, input_data], axis=-1)  
215     input_data = MaxPool2D(2, 2, 'same')(input_data)  
216  
217     input_data = convolutional(input_data, (3, 3, 64, 128))  
218     route = input_data  
219     input_data = route_group(input_data, 2, 1)  
220     input_data = convolutional(input_data, (3, 3, 64, 64))  
221     route_1 = input_data  
222     input_data = convolutional(input_data, (3, 3, 64, 64))  
223     input_data = tf.concat([input_data, route_1], axis=-1)  
224     input_data = convolutional(input_data, (1, 1, 64, 128))  
225     input_data = tf.concat([route, input_data], axis=-1)  
226     input_data = MaxPool2D(2, 2, 'same')(input_data)  
227  
228     input_data = convolutional(input_data, (3, 3, 128,  
229         ↳ 256))  
230     route = input_data  
231     input_data = route_group(input_data, 2, 1)  
232     input_data = convolutional(input_data, (3, 3, 128,  
233         ↳ 128))  
234     route_1 = input_data  
235     input_data = convolutional(input_data, (3, 3, 128,  
236         ↳ 128))  
237     input_data = tf.concat([input_data, route_1], axis=-1)  
238     input_data = convolutional(input_data, (1, 1, 128,  
239         ↳ 256))  
240     route_1 = input_data  
241     input_data = tf.concat([route, input_data], axis=-1)  
242     input_data = MaxPool2D(2, 2, 'same')(input_data)
```

```

239     input_data = convolutional(input_data, (3, 3, 512,
240                                ↵ 512))
241
242     return route_1, input_data
243
244 def YOLOv3(input_layer, NUM_CLASS):
245     # After the input layer enters the Darknet-53 network,
246     # we get three branches
247     route_1, route_2, conv = darknet53(input_layer)
248     # See the orange module (DBL) in the figure above, a
249     # total of 5 Subconvolution operation
250     conv = convolutional(conv, (1, 1, 1024, 512))
251     conv = convolutional(conv, (3, 3, 512, 1024))
252     conv = convolutional(conv, (1, 1, 1024, 512))
253     conv = convolutional(conv, (3, 3, 512, 1024))
254     conv = convolutional(conv, (1, 1, 1024, 512))
255     conv_lbbox = convolutional(conv_lbbox_branch, (1, 1,
256                                ↵ 1024, 3*(NUM_CLASS + 5)), activate=False, bn=False)
257
258     conv = convolutional(conv, (1, 1, 512, 256))
259     # upsample here uses the nearest neighbor
260     # interpolation method, which has the advantage that
261     # the
262     # upsampling process does not need to learn, thereby
263     # reducing the network parameter
264     conv = upsample(conv)
265
266     conv = tf.concat([conv, route_2], axis=-1)
267     conv = convolutional(conv, (1, 1, 768, 256))
268     conv = convolutional(conv, (3, 3, 256, 512))
269     conv = convolutional(conv, (1, 1, 512, 256))
270     conv = convolutional(conv, (3, 3, 256, 512))
271     conv = convolutional(conv, (1, 1, 512, 256))
272     conv_mobj_branch = convolutional(conv, (3, 3, 256,
273                                ↵ 512))

```

```
270     # conv_mbbox is used to predict medium-sized objects,
271     # shape = [None, 26, 26, 255]
272     conv_mbbox = convolutional(conv_mobj_branch, (1, 1,
273         512, 3*(NUM_CLASS + 5)), activate=False, bn=False)
274
275     conv = convolutional(conv, (1, 1, 256, 128))
276     conv = upsample(conv)
277
278     conv = tf.concat([conv, route_1], axis=-1)
279     conv = convolutional(conv, (1, 1, 384, 128))
280     conv = convolutional(conv, (3, 3, 128, 256))
281     conv = convolutional(conv, (1, 1, 256, 128))
282     conv = convolutional(conv, (3, 3, 128, 256))
283     conv = convolutional(conv, (1, 1, 256, 128))
284     conv_sobj_branch = convolutional(conv, (3, 3, 128,
285         256))
286
287     # conv_sbbox is used to predict small size objects,
288     # shape = [None, 52, 52, 255]
289     conv_sbbox = convolutional(conv_sobj_branch, (1, 1,
290         256, 3*(NUM_CLASS +5)), activate=False, bn=False)
291
292     return [conv_sbbox, conv_mbbox, conv_lbbox]
```

```
293
294     def YOLOv4(input_layer, NUM_CLASS):
295         route_1, route_2, conv = cspdarknet53(input_layer)
296
297         route = conv
298         conv = convolutional(conv, (1, 1, 512, 256))
299         conv = upsample(conv)
300         route_2 = convolutional(route_2, (1, 1, 512, 256))
301         conv = tf.concat([route_2, conv], axis=-1)
302
303         conv = convolutional(conv, (1, 1, 512, 256))
304         conv = convolutional(conv, (3, 3, 256, 512))
305         conv = convolutional(conv, (1, 1, 512, 256))
306         conv = convolutional(conv, (3, 3, 256, 512))
307         conv = convolutional(conv, (1, 1, 512, 256))
```

```
306     conv = upsample(conv)
307     route_1 = convolutional(route_1, (1, 1, 256, 128))
308     conv = tf.concat([route_1, conv], axis=-1)
309
310     conv = convolutional(conv, (1, 1, 256, 128))
311     conv = convolutional(conv, (3, 3, 128, 256))
312     conv = convolutional(conv, (1, 1, 256, 128))
313     conv = convolutional(conv, (3, 3, 128, 256))
314     conv = convolutional(conv, (1, 1, 256, 128))
315
316     route_1 = conv
317     conv = convolutional(conv, (3, 3, 128, 256))
318     conv_sbbox = convolutional(conv, (1, 1, 256, 3 *
319         → (NUM_CLASS + 5)), activate=False, bn=False)
320
321     conv = convolutional(route_1, (3, 3, 128, 256),
322         → downsample=True)
323     conv = tf.concat([conv, route_2], axis=-1)
324
325     conv = convolutional(conv, (1, 1, 512, 256))
326     conv = convolutional(conv, (3, 3, 256, 512))
327     conv = convolutional(conv, (1, 1, 512, 256))
328     conv = convolutional(conv, (3, 3, 256, 512))
329     route_2 = conv
330     conv = convolutional(conv, (3, 3, 256, 512))
331     conv_mbbox = convolutional(conv, (1, 1, 512, 3 *
332         → (NUM_CLASS + 5)), activate=False, bn=False)
333
334     conv = convolutional(route_2, (3, 3, 256, 512),
335         → downsample=True)
336     conv = tf.concat([conv, route], axis=-1)
337
338     conv = convolutional(conv, (1, 1, 1024, 512))
339     conv = convolutional(conv, (3, 3, 512, 1024))
340     conv = convolutional(conv, (1, 1, 1024, 512))
341     conv = convolutional(conv, (3, 3, 512, 1024))
342     conv = convolutional(conv, (1, 1, 1024, 512))

343
344     conv = convolutional(conv, (3, 3, 512, 1024))
```

```
343     conv_lbbox = convolutional(conv, (1, 1, 1024, 3 *
344         ↳ (NUM_CLASS + 5)), activate=False, bn=False)
345
346     return [conv_sbbox, conv_mbbox, conv_lbbox]
347
348 def YOLOv3_tiny(input_layer, NUM_CLASS):
349     # After the input layer enters the Darknet-53 network,
350     # we get three branches
351     route_1, conv = darknet19_tiny(input_layer)
352
353     conv = convolutional(conv, (1, 1, 1024, 256))
354     conv_lbbox_branch = convolutional(conv, (3, 3, 256,
355         ↳ 512))
356
357     # conv_lbbox is used to predict large-sized objects ,
358     # Shape = [None, 26, 26, 255]
359     conv_lbbox = convolutional(conv_lbbox_branch, (1, 1,
360         ↳ 512, 3*(NUM_CLASS + 5)), activate=False, bn=False)
361
362     conv = convolutional(conv, (1, 1, 256, 128))
363     # upsample here uses the nearest neighbor
364     # interpolation method, which has the advantage that
365     # the
366     # upsampling process does not need to learn, thereby
367     # reducing the network parameter
368     conv = upsample(conv)
369
370     conv = tf.concat([conv, route_1], axis=-1)
371     conv_mobj_branch = convolutional(conv, (3, 3, 128,
372         ↳ 256))
373
374     # conv_mbbox is used to predict medium size objects,
375     # shape = [None, 13, 13, 255]
376     conv_mbbox = convolutional(conv_mobj_branch, (1, 1,
377         ↳ 256, 3 * (NUM_CLASS + 5)), activate=False,
378         ↳ bn=False)
379
380     return [conv_mbbox, conv_lbbox]
381
382 def YOLOv4_tiny(input_layer, NUM_CLASS):
383     route_1, conv = cspdarknet53_tiny(input_layer)
```

```
372     conv = convolutional(conv, (1, 1, 512, 256))
373
374     conv_lbbox_branch = convolutional(conv, (3, 3, 256,
375                                         ↳ 512))
375     conv_lbbox = convolutional(conv_lbbox_branch, (1, 1,
376                                         ↳ 512, 3 * (NUM_CLASS + 5)), activate=False,
377                                         ↳ bn=False)
378
379     conv = convolutional(conv, (1, 1, 256, 128))
380     conv = upsample(conv)
381     conv = tf.concat([conv, route_1], axis=-1)
382
383     conv_mobj_branch = convolutional(conv, (3, 3, 128,
384                                         ↳ 256))
385     conv_mbbox = convolutional(conv_mobj_branch, (1, 1,
386                                         ↳ 256, 3 * (NUM_CLASS + 5)), activate=False,
387                                         ↳ bn=False)
388
389     return [conv_mbbox, conv_lbbox]
390
391
392 def Create_Yolo(input_size=416, channels=3,
393                  ↳ training=False, CLASSES=YOLO_COCO_CLASSES):
394     NUM_CLASS = len(read_class_names(CLASSES))
395     input_layer = Input([input_size, input_size,
396                          ↳ channels])
397
398     if TRAIN_YOLO_TINY:
399         if YOLO_TYPE == "yolov4":
400             conv_tensors = YOL0v4_tiny(input_layer,
401                                         ↳ NUM_CLASS)
402         if YOLO_TYPE == "yolov3":
403             conv_tensors = YOL0v3_tiny(input_layer,
404                                         ↳ NUM_CLASS)
405     else:
406         if YOLO_TYPE == "yolov4":
407             conv_tensors = YOL0v4(input_layer, NUM_CLASS)
408         if YOLO_TYPE == "yolov3":
409             conv_tensors = YOL0v3(input_layer, NUM_CLASS)
410
411     output_tensors = []
412     for i, conv_tensor in enumerate(conv_tensors):
```

```
403     pred_tensor = decode(conv_tensor, NUM_CLASS, i)
404     if training: output_tensors.append(conv_tensor)
405     output_tensors.append(pred_tensor)
406
407     Yolo = tf.keras.Model(input_layer, output_tensors)
408     return Yolo
409
410
411 def decode(conv_output, NUM_CLASS, i=0):
412     # where i = 0, 1 or 2 to correspond to the three grid
413     # scales
414     conv_shape      = tf.shape(conv_output)
415     batch_size      = conv_shape[0]
416     output_size     = conv_shape[1]
417
418     conv_output = tf.reshape(conv_output, (batch_size,
419                                         output_size, 3, 5 + NUM_CLASS))
420
421     #conv_raw_dxdy = conv_output[:, :, :, :, 0:2] # offset
422     #    of center position
423     #conv_raw_dwdh = conv_output[:, :, :, :, 2:4] #
424     #    Prediction box length and width offset
425     #conv_raw_conf = conv_output[:, :, :, :, 4:5] #
426     #    confidence of the prediction box
427     #conv_raw_prob = conv_output[:, :, :, :, 5: ] #
428     #    category probability of the prediction box
429     conv_raw_dxdy, conv_raw_dwdh, conv_raw_conf,
430     #    conv_raw_prob = tf.split(conv_output, (2, 2, 1,
431     #    NUM_CLASS), axis=-1)
432
433     # next need Draw the grid. Where output_size is equal
434     #    to 13, 26 or 52
435     #y = tf.range(output_size, dtype=tf.int32)
436     #y = tf.expand_dims(y, -1)
437     #y = tf.tile(y, [1, output_size])
438     #x = tf.range(output_size,dtype=tf.int32)
439     #x = tf.expand_dims(x, 0)
440     #x = tf.tile(x, [output_size, 1])
441     xy_grid = tf.meshgrid(tf.range(output_size),
442                           tf.range(output_size))
```

```

433     xy_grid = tf.expand_dims(tf.stack(xy_grid, axis=-1),
434                               axis=2) # [gx, gy, 1, 2]
435     xy_grid = tf.tile(tf.expand_dims(xy_grid, axis=0),
436                        [batch_size, 1, 1, 3, 1])
437     xy_grid = tf.cast(xy_grid, tf.float32)
438
439     #xy_grid = tf.concat([x[:, :, tf.newaxis], y[:, :, tf.newaxis]], axis=-1)
440     #xy_grid = tf.tile(xy_grid[tf.newaxis, :, :, tf.newaxis, :], [batch_size, 1, 1, 3, 1])
441     #y_grid = tf.cast(xy_grid, tf.float32)
442
443     # Calculate the center position of the prediction box:
444     pred_xy = (tf.sigmoid(conv_raw_dxdy) + xy_grid) *
445               STRIDES[i]
446     # Calculate the length and width of the prediction box:
447     pred_wh = (tf.exp(conv_raw_dwdh) * ANCHORS[i]) *
448               STRIDES[i]
449
450     pred_xywh = tf.concat([pred_xy, pred_wh], axis=-1)
451     pred_conf = tf.sigmoid(conv_raw_conf) # object box
452     # calculates the predicted confidence
453     pred_prob = tf.sigmoid(conv_raw_prob) # calculating
454     # the predicted probability category box object
455
456     # calculating the predicted probability category box
457     # object
458     return tf.concat([pred_xywh, pred_conf, pred_prob],
459                     axis=-1)
460
461
462
463
464 def bbox_iou(boxes1, boxes2):
465     boxes1_area = boxes1[..., 2] * boxes1[..., 3]
466     boxes2_area = boxes2[..., 2] * boxes2[..., 3]
467
468     boxes1 = tf.concat([boxes1[..., :2] - boxes1[..., 2:],
469                         boxes1[..., :2] + boxes1[..., 2:],
470                         * 0.5], axis=-1)
471     boxes2 = tf.concat([boxes2[..., :2] - boxes2[..., 2:],
472                         boxes2[..., :2] + boxes2[..., 2:],
473                         * 0.5],
474                         axis=-1)

```

```
461             boxes2[..., :2] + boxes2[..., 2:]
462             ↳ * 0.5], axis=-1)
463
464     left_up = tf.maximum(boxes1[..., :2], boxes2[..., :2])
465     right_down = tf.minimum(boxes1[..., 2:], boxes2[...,
466     ↳ 2:])
467
468     inter_section = tf.maximum(right_down - left_up, 0.0)
469     inter_area = inter_section[..., 0] *
470     ↳ inter_section[..., 1]
471     union_area = boxes1_area + boxes2_area - inter_area
472
473     return 1.0 * inter_area / union_area
474
475 def bbox_giou(boxes1, boxes2):
476     boxes1 = tf.concat([boxes1[..., :2] - boxes1[..., 2:],
477     ↳ * 0.5,
478                 boxes1[..., :2] + boxes1[..., 2:]
479                 ↳ * 0.5], axis=-1)
480     boxes2 = tf.concat([boxes2[..., :2] - boxes2[..., 2:],
481     ↳ * 0.5,
482                 boxes2[..., :2] + boxes2[..., 2:]
483                 ↳ * 0.5], axis=-1)
484
485     boxes1_area = (boxes1[..., 2] - boxes1[..., 0]) *
486     ↳ (boxes1[..., 3] - boxes1[..., 1])
487     boxes2_area = (boxes2[..., 2] - boxes2[..., 0]) *
488     ↳ (boxes2[..., 3] - boxes2[..., 1])
489
490     left_up = tf.maximum(boxes1[..., :2], boxes2[..., :2])
491     right_down = tf.minimum(boxes1[..., 2:], boxes2[...,
492     ↳ 2:]])
```

```
488
489     inter_section = tf.maximum(right_down - left_up, 0.0)
490     inter_area = inter_section[..., 0] *
491         ↳ inter_section[..., 1]
492     union_area = boxes1_area + boxes2_area - inter_area
493
494 # Calculate the iou value between the two bounding
495     ↳ boxes
496     iou = inter_area / union_area
497
498 # Calculate the coordinates of the upper left corner
499     ↳ and the lower right corner of the smallest closed
500         ↳ convex surface
501     enclose_left_up = tf.minimum(boxes1[..., :2],
502         ↳ boxes2[..., :2])
503     enclose_right_down = tf.maximum(boxes1[..., 2:], 
504         ↳ boxes2[..., 2:])
505     enclose = tf.maximum(enclose_right_down -
506         ↳ enclose_left_up, 0.0)
507
508 # Calculate the area of the smallest closed convex
509     ↳ surface C
510     enclose_area = enclose[..., 0] * enclose[..., 1]
511
512 # Calculate the GIoU value according to the GioU
513     ↳ formula
514     giou = iou - 1.0 * (enclose_area - union_area) /
515         ↳ enclose_area
516
517     return giou
518
519 # testing (should be better than giou)
520 def bbox_ciou(boxes1, boxes2):
521     boxes1_coor = tf.concat([boxes1[..., :2] - boxes1[...,
522         ↳ 2:] * 0.5,
523             ↳ boxes1[..., :2] + boxes1[..., 2:]
524                 ↳ * 0.5], axis=-1)
525     boxes2_coor = tf.concat([boxes2[..., :2] - boxes2[...,
526         ↳ 2:] * 0.5,
527             ↳ boxes2[..., :2] + boxes2[..., 2:]
528                 ↳ * 0.5], axis=-1)
```



```

545     conv_raw_conf = conv[:, :, :, :, :, 4:5]
546     conv_raw_prob = conv[:, :, :, :, :, 5:]
547
548     pred_xywh      = pred[:, :, :, :, 0:4]
549     pred_conf      = pred[:, :, :, :, 4:5]
550
551     label_xywh     = label[:, :, :, :, 0:4]
552     respond_bbox   = label[:, :, :, :, 4:5]
553     label_prob     = label[:, :, :, :, 5:]
554
555     giou = tf.expand_dims(bbox_giou(pred_xywh,
556                               ↵ label_xywh), axis=-1)
556     input_size = tf.cast(input_size, tf.float32)
557
558     bbox_loss_scale = 2.0 - 1.0 * label_xywh[:, :, :, :, :,
559                               ↵ 2:3] * label_xywh[:, :, :, :, 3:4] / (input_size
560                               ↵ ** 2)
561     giou_loss = respond_bbox * bbox_loss_scale * (1 - giou)
562
563     iou = bbox_iou(pred_xywh[:, :, :, :, np.newaxis, :],
564                      ↵ bboxes[:, np.newaxis, np.newaxis, np.newaxis, :, :
565                      ↵ :])
566     # Find the value of IoU with the real box The largest
567     # prediction box
568     max_iou = tf.expand_dims(tf.reduce_max(iou, axis=-1),
569                               ↵ axis=-1)
570
571     # If the largest iou is less than the threshold, it is
572     # considered that the prediction box contains no
573     # objects, then the background box
574     respond_bgd = (1.0 - respond_bbox) * tf.cast(max_iou
575                               ↵ < YOLO_IOU_LOSS_THRESH, tf.float32)
576
577     conf_focal = tf.pow(respond_bbox - pred_conf, 2)
578
579     # Calculate the loss of confidence
580     # we hope that if the grid contains objects, then the
581     # network output prediction box has a confidence of
582     # 1 and 0 when there is no object.
583     conf_loss = conf_focal * (

```

```
573     respond_bbox * tf.nn.sigmoid_cross_entropy_with_
574         ↵ h_logits(labels=respond_bbox,
575             ↵ logits=conv_raw_conf)
576     +
577     respond_bgd * tf.nn.sigmoid_cross_entropy_with_
578         ↵ _logits(labels=respond_bbox,
579             ↵ logits=conv_raw_conf)
580 )
581
582 prob_loss = respond_bbox * tf.nn.sigmoid_cross_entropy_
583         ↵ _with_logits(labels=label_prob,
584             ↵ logits=conv_raw_prob)
585
586 giou_loss = tf.reduce_mean(tf.reduce_sum(giou_loss,
587         ↵ axis=[1,2,3,4]))
588 conf_loss = tf.reduce_mean(tf.reduce_sum(conf_loss,
589         ↵ axis=[1,2,3,4]))
590 prob_loss = tf.reduce_mean(tf.reduce_sum(prob_loss,
591         ↵ axis=[1,2,3,4]))
592
593 return giou_loss, conf_loss, prob_loss
```

### C.3.3 utils.py

```

1 #===== ]  

2 #=====  

3 # File name : utils.py  

4 # Author : PyLessons  

5 # Created date: 2020-09-27  

6 # Website : https://pylessons.com/  

7 # GitHub :  

8 # https://github.com/pythonlessons/TensorFlow-2.x-YOLOv3  

9 # Description : additional yolov3 and yolov4 functions  

10 # Modified by : Virginia Ramón  

11 #===== ]  

12 #=====  

13 from multiprocessing import Process, Queue, Pipe  

14 import cv2  

15 import time  

16 import random  

17 import colorsys  

18 import numpy as np  

19 import tensorflow as tf  

20 from yolov3.configs import *  

21 from yolov3.yolov4 import *  

22 from tensorflow.python.saved_model import tag_constants  

23 #Added by Virginia Ramon  

24 import json  

25 import sys  

26 sys.path.append("/home/virginia/TFG/YOLOv4/TensorFlow-2.x- ]  

27     YOLOv3-master/")  

28 def load_yolo_weights(model, weights_file):  

29     tf.keras.backend.clear_session() # used to reset layer  

30         names  

31     # load Darknet original weights to TensorFlow model  

32     if YOLO_TYPE == "yolov3":  

33         range1 = 75 if not TRAIN_YOLO_TINY else 13  

34         range2 = [58, 66, 74] if not TRAIN_YOLO_TINY else  

35             [9, 12]  

36     if YOLO_TYPE == "yolov4":  

37         range1 = 110 if not TRAIN_YOLO_TINY else 21

```

```

33         range2 = [93, 101, 109] if not TRAIN_YOLO_TINY
34             ↵ else [17, 20]
35
36     with open(weights_file, 'rb') as wf:
37         major, minor, revision, seen, _ = np.fromfile(wf,
38             ↵ dtype=np.int32, count=5)
39
40     j = 0
41     for i in range(range1):
42         if i > 0:
43             conv_layer_name = 'conv2d_%d' %i
44         else:
45             conv_layer_name = 'conv2d'
46
47         if j > 0:
48             bn_layer_name = 'batch_normalization_%d' %j
49         else:
50             bn_layer_name = 'batch_normalization'
51
52         conv_layer = model.get_layer(conv_layer_name)
53         filters = conv_layer.filters
54         k_size = conv_layer.kernel_size[0]
55         in_dim = conv_layer.input_shape[-1]
56
57         if i not in range2:
58             # darknet weights: [beta, gamma, mean,
59             ↵ variance]
60             bn_weights = np.fromfile(wf,
61             ↵ dtype=np.float32, count=4 * filters)
62             # tf weights: [gamma, beta, mean, variance]
63             bn_weights = bn_weights.reshape((4,
64             ↵ filters))[[1, 0, 2, 3]]
65             bn_layer = model.get_layer(bn_layer_name)
66             j += 1
67         else:
68             conv_bias = np.fromfile(wf,
69             ↵ dtype=np.float32, count=filters)
70
71         # darknet shape (out_dim, in_dim, height,
72         ↵ width)
73         conv_shape = (filters, in_dim, k_size, k_size)

```

```

67         conv_weights = np.fromfile(wf,
68             dtype=np.float32,
69             count=np.product(conv_shape))
70             # tf shape (height, width, in_dim, out_dim)
71             conv_weights = conv_weights.reshape(conv_shape [
72                 ).transpose([2, 3, 1,
73                 0])
74
75             if i not in range2:
76                 conv_layer.set_weights([conv_weights])
77                 bn_layer.set_weights(bn_weights)
78             else:
79                 conv_layer.set_weights([conv_weights,
80                     conv_bias])
81
82             assert len(wf.read()) == 0, 'failed to read all
83             data'
84
85     def Load_Yolo_model():
86         physical_devices =
87             tf.config.list_physical_devices('GPU')
88         for gpu_instance in physical_devices:
89             try: tf.config.experimental.set_memory_growth(gpu_ [
90                 instance,
91                 True)
92             except RuntimeError: pass
93
94         if YOLO_FRAMEWORK == "tf": # TensorFlow detection
95             if YOLO_TYPE == "yolov4":
96                 Darknet_weights = YOLO_V4_TINY_WEIGHTS if
97                     TRAIN_YOLO_TINY else YOLO_V4_WEIGHTS
98             if YOLO_TYPE == "yolov3":
99                 Darknet_weights = YOLO_V3_TINY_WEIGHTS if
100                     TRAIN_YOLO_TINY else YOLO_V3_WEIGHTS
101
102             if YOLO_CUSTOM_WEIGHTS == False:
103                 print("Loading Darknet_weights from:",
104                     Darknet_weights)
105             yolo = Create_Yolo(input_size=YOLO_INPUT_SIZE,
106                 CLASSES=YOLO_COCO_CLASSES)

```

```

94         load_yolo_weights(yolo, Darknet_weights) # use
95             → Darknet weights
96     else:
97         checkpoint = f"/home/virginia/TFG/YOLOv4/Tenso_
98             → rFlow-2.x-YOLOv3-master/checkpoints/yolov4_
99             → _PigPersv5/{TRAIN_MODEL_NAME}"
100    if TRAIN_YOLO_TINY:
101        checkpoint += "_Tiny"
102    print("Loading custom weights from:",
103          → checkpoint)
104    yolo = Create_Yolo(input_size=YOLO_INPUT_SIZE,
105                      → CLASSES=TRAIN_CLASSES)
106    yolo.load_weights(checkpoint) # use custom
107        → weights
108
109
110   def image_preprocess(image, target_size, gt_boxes=None):
111       ih, iw      = target_size
112       h, w, _     = image.shape
113
114       scale = min(iw/w, ih/h)
115       nw, nh  = int(scale * w), int(scale * h)
116       image_resized = cv2.resize(image, (nw, nh))
117
118       image_paded = np.full(shape=[ih, iw, 3],
119                           → fill_value=128.0)
120       dw, dh = (iw - nw) // 2, (ih-nh) // 2
121       image_paded[dh:nh+dh, dw:nw+dw, :] = image_resized
122       image_paded = image_paded / 255.
123
124   if gt_boxes is None:

```

```
124     return image_paded
125
126 else:
127     gt_boxes[:, [0, 2]] = gt_boxes[:, [0, 2]] * scale
128     ↪ + dw
129     gt_boxes[:, [1, 3]] = gt_boxes[:, [1, 3]] * scale
130     ↪ + dh
131     return image_paded, gt_boxes
132
133 def draw_bbox(image, bboxes, CLASSES=YOLO_COCO_CLASSES,
134   ↪ show_label=True, show_confidence = True,
135   ↪ Text_colors=(255,255,0), rectangle_colors='',
136   ↪ tracking=False):
137     NUM_CLASS = read_class_names(CLASSES)
138     num_classes = len(NUM_CLASS)
139     image_h, image_w, _ = image.shape
140     hsv_tuples = [(1.0 * x / num_classes, 1., 1.) for x in
141       ↪ range(num_classes)]
142     #print("hsv_tuples", hsv_tuples)
143     colors = list(map(lambda x: colorsys.hsv_to_rgb(*x),
144       ↪ hsv_tuples))
145     colors = list(map(lambda x: (int(x[0] * 255), int(x[1]
146       ↪ * 255), int(x[2] * 255)), colors))
147
148     random.seed(0)
149     random.shuffle(colors)
150     random.seed(None)
151
152     for i, bbox in enumerate(bboxes):
153         coor = np.array(bbox[:4], dtype=np.int32)
154         score = bbox[4]
155         class_ind = int(bbox[5])
156         bbox_color = rectangle_colors if rectangle_colors
157           ↪ != '' else colors[class_ind]
158         bbox_thick = int(0.6 * (image_h + image_w) / 1300)
159         if bbox_thick < 1: bbox_thick = 1
160         fontScale = 0.5 * bbox_thick
161         (x1, y1), (x2, y2) = (coor[0], coor[1]), (coor[2],
162           ↪ coor[3])
```

```
155     # put object rectangle
156     cv2.rectangle(image, (x1, y1), (x2, y2),
157                   ↵ bbox_color, bbox_thick*2)
158
159     if show_label:
160         # get text label
161         score_str = " {:.2f}".format(score) if
162             ↵ show_confidence else ""
163
164     try:
165         label = "{}".format(NUM_CLASS[class_ind])
166             ↵ + score_str
167     except KeyError:
168         print("You received KeyError, this might
169             ↵ be that you are trying to use yolo
170             ↵ original weights")
171         print("while using custom classes, if
172             ↵ using custom model in configs.py set
173             ↵ YOLO_CUSTOM_WEIGHTS = True")
174
175     # get text size
176     (text_width, text_height), baseline =
177         ↵ cv2.getTextSize(label,
178             ↵ cv2.FONT_HERSHEY_COMPLEX_SMALL,
```



```
173             # put filled text rectangle
174             cv2.rectangle(image, (x1, y1), (x1 +
175                                         → text_width, y1 - text_height - baseline),
176                                         → bbox_color, thickness=cv2.FILLED)
177
178             # put text above rectangle
179             cv2.putText(image, label, (x1, y1-4),
180                         → cv2.FONT_HERSHEY_COMPLEX_SMALL,
181                         → fontScale, Text_colors,
182                         → bbox_thick,
183                         → lineType=cv2.LINE_AA)
184
185         return image
186
187
188     def bboxes_iou(boxes1, boxes2):
189         boxes1 = np.array(boxes1)
190         boxes2 = np.array(boxes2)
191
192         boxes1_area = (boxes1[..., 2] - boxes1[..., 0]) *
193                     → (boxes1[..., 3] - boxes1[..., 1])
194         boxes2_area = (boxes2[..., 2] - boxes2[..., 0]) *
195                     → (boxes2[..., 3] - boxes2[..., 1])
196
197         left_up      = np.maximum(boxes1[..., :2],
198                               → boxes2[..., :2])
199         right_down   = np.minimum(boxes1[..., 2:],
200                               → boxes2[..., 2:])
201
202         inter_section = np.maximum(right_down - left_up, 0.0)
203         inter_area    = inter_section[..., 0] *
204                     → inter_section[..., 1]
205         union_area    = boxes1_area + boxes2_area - inter_area
206         ious          = np.maximum(1.0 * inter_area /
207                                   → union_area, np.finfo(np.float32).eps)
208
209     return ious
210
211
212     def nms(bboxes, iou_threshold, sigma=0.3, method='nms'):
213         """
```

```

203     :param bboxes: (xmin, ymin, xmax, ymax, score, class)
204
205     Note: soft-nms, https://arxiv.org/pdf/1704.04503.pdf
206         https://github.com/bharatsingh430/soft-nms
207     """
208
209     classes_in_img = list(set(bboxes[:, 5]))
210     best_bboxes = []
211
212     for cls in classes_in_img:
213         cls_mask = (bboxes[:, 5] == cls)
214         cls_bboxes = bboxes[cls_mask]
215         # Process 1: Determine whether the number of
216         # → bounding boxes is greater than 0
217         while len(cls_bboxes) > 0:
218             # Process 2: Select the bounding box with the
219             # → highest score according to score order A
220             max_ind = np.argmax(cls_bboxes[:, 4])
221             best_bbox = cls_bboxes[max_ind]
222             best_bboxes.append(best_bbox)
223             cls_bboxes = np.concatenate([cls_bboxes[::
224                 max_ind], cls_bboxes[max_ind + 1:]])
225             # Process 3: Calculate this bounding box A and
226             # Remain all iou of the bounding box and
227             # → remove those bounding boxes whose iou
228             # → value is higher than the threshold
229             iou = bboxes_iou(best_bbox[np.newaxis, :4],
230             # → cls_bboxes[:, :4])
231             weight = np.ones((len(iou),), dtype=np.float32)
232
233             assert method in ['nms', 'soft-nms']
234
235             if method == 'nms':
236                 iou_mask = iou > iou_threshold
237                 weight[iou_mask] = 0.0
238
239             if method == 'soft-nms':
240                 weight = np.exp(-(1.0 * iou ** 2 / sigma))
241
242                 cls_bboxes[:, 4] = cls_bboxes[:, 4] * weight
243                 score_mask = cls_bboxes[:, 4] > 0.
244                 cls_bboxes = cls_bboxes[score_mask]
```

```
238
239     return best_bboxes
240
241
242 def postprocess_boxes(pred_bbox, original_image,
243     ↪ input_size, score_threshold):
243     valid_scale=[0, np.inf]
244     pred_bbox = np.array(pred_bbox)
245
246     pred_xywh = pred_bbox[:, 0:4]
247     pred_conf = pred_bbox[:, 4]
248     pred_prob = pred_bbox[:, 5:]
249
250     # 1. (x, y, w, h) --> (xmin, ymin, xmax, ymax)
251     pred_coor = np.concatenate([pred_xywh[:, :2] -
252         ↪ pred_xywh[:, 2:] * 0.5,
253             pred_xywh[:, :2] +
254             ↪ pred_xywh[:, 2:] *
255             ↪ 0.5], axis=-1)
256
257     # 2. (xmin, ymin, xmax, ymax) -> (xmin_org, ymin_org,
258     ↪ xmax_org, ymax_org)
259     org_h, org_w = original_image.shape[:2]
260     resize_ratio = min(input_size / org_w, input_size /
261         ↪ org_h)
262
263     dw = (input_size - resize_ratio * org_w) / 2
264     dh = (input_size - resize_ratio * org_h) / 2
265
266     pred_coor[:, 0::2] = 1.0 * (pred_coor[:, 0::2] - dw) /
267         ↪ resize_ratio
268     pred_coor[:, 1::2] = 1.0 * (pred_coor[:, 1::2] - dh) /
269         ↪ resize_ratio
270
271     # 3. clip some boxes those are out of range
272     pred_coor = np.concatenate([np.maximum(pred_coor[:, :
273         ↪ :2], [0, 0]),
274             np.minimum(pred_coor[:, :
275         ↪ 2:], [org_w - 1, org_h
276             ↪ - 1])], axis=-1)
```

```
266     invalid_mask = np.logical_or((pred_coor[:, 0] >
267         → pred_coor[:, 2]), (pred_coor[:, 1] > pred_coor[:, 3]))
268     pred_coor[invalid_mask] = 0
269
270     # 4. discard some invalid boxes
271     bboxes_scale = np.sqrt(np.multiply.reduce(pred_coor[:, 2:4] - pred_coor[:, 0:2], axis=-1))
272     scale_mask = np.logical_and((valid_scale[0] < bboxes_scale), (bboxes_scale < valid_scale[1]))
273
274     # 5. discard boxes with low scores
275     classes = np.argmax(pred_prob, axis=-1)
276     scores = pred_conf *
277         → pred_prob[np.arange(len(pred_coor)), classes]
278     score_mask = scores > score_threshold
279     mask = np.logical_and(scale_mask, score_mask)
280     coors, scores, classes = pred_coor[mask],
281         → scores[mask], classes[mask]
282
283     return np.concatenate([coors, scores[:, np.newaxis],
284         → classes[:, np.newaxis]], axis=-1)
285
286
287 def detect_image(Yolo, image_path, output_path,
288     → input_size=416, show=False, CLASSES=YOLO_COCO_CLASSES,
289     → score_threshold=0.5, iou_threshold=0.45,
290     → rectangle_colors='r'):
291     original_image      = cv2.imread(image_path)
292     original_image      = cv2.cvtColor(original_image,
293         → cv2.COLOR_BGR2RGB)
294     original_image      = cv2.cvtColor(original_image,
295         → cv2.COLOR_BGR2RGB)
296
297     image_data = image_preprocess(np.copy(original_image),
298         → [input_size, input_size])
299     image_data = image_data[np.newaxis,
300         → ...].astype(np.float32)
301
302     if YOLO_FRAMEWORK == "tf":
303         pred_bbox = Yolo.predict(image_data)
```

```
293     elif YOLO_FRAMEWORK == "trt":
294         batched_input = tf.constant(image_data)
295         result = Yolo(batched_input)
296         pred_bbox = []
297         for key, value in result.items():
298             value = value.numpy()
299             pred_bbox.append(value)
300
301         pred_bbox = [tf.reshape(x, (-1, tf.shape(x)[-1])) for
302                     ↵ x in pred_bbox]
303         pred_bbox = tf.concat(pred_bbox, axis=0)
304
305         bboxes = postprocess_boxes(pred_bbox, original_image,
306                                    ↵ input_size, score_threshold)
306         bboxes = nms(bboxes, iou_threshold, method='nms')
307
308         image = draw_bbox(original_image, bboxes,
309                           ↵ CLASSES=CLASSES, rectangle_colors=rectangle_colors)
310         #--Added by Virginia Ramon--
311         data = [output_path, bboxes]
312
313         #print("Detections: "+ str(int(time.time())) +" "+
314             ↵ image_path)
315         #for b in bboxes:
316             # print(b)
317             #print(read_class_names(CLASSES))
318             #-----
319             #if output_path != '':
320                 cv2.imwrite(output_path, image)
321             #if show:
322                 # Show the image
323                 cv2.imshow("predicted image", image)
324                 # Load and hold the image
325                 cv2.waitKey(0)
326                 # To close the window after the required kill
327                 ↵ value was provided
328                 cv2.destroyAllWindows()
329
330         return image, data, read_class_names(CLASSES)
331
332         #--Added by Virginia Ramon--
```

```

328 def detect_frame(Yolo, original_image, input_size=416,
329     ↵ show=False, CLASSES=YOLO_COCO_CLASSES,
330     ↵ score_threshold=0.5, iou_threshold=0.45):
331     original_image      = cv2.cvtColor(original_image,
332         ↵ cv2.COLOR_BGR2RGB)
333     original_image      = cv2.cvtColor(original_image,
334         ↵ cv2.COLOR_BGR2RGB)
335
336     image_data = image_preprocess(np.copy(original_image),
337         ↵ [input_size, input_size])
338     image_data = image_data[np.newaxis,
339         ↵ ...].astype(np.float32)
340
341     if YOLO_FRAMEWORK == "tf":
342         pred_bbox = Yolo.predict(image_data)
343     elif YOLO_FRAMEWORK == "trt":
344         batched_input = tf.constant(image_data)
345         result = Yolo(batched_input)
346         pred_bbox = []
347         for key, value in result.items():
348             value = value.numpy()
349             pred_bbox.append(value)
350
351         pred_bbox = [tf.reshape(x, (-1, tf.shape(x)[-1])) for
352             ↵ x in pred_bbox]
353         pred_bbox = tf.concat(pred_bbox, axis=0)
354
355         bboxes = postprocess_boxes(pred_bbox, original_image,
356             ↵ input_size, score_threshold)
357         bboxes = nms(bboxes, iou_threshold, method='nms')
358
359         #image = draw_bbox(original_image, bboxes,
360             ↵ CLASSES=CLASSES, rectangle_colors=rectangle_colors)
361
362         return bboxes, read_class_names(CLASSES)
363     #-----
364
365 def Predict_bbox_mp(Frames_data, Predicted_data,
366     ↵ Processing_times):
367     gpus =
368         ↵ tf.config.experimental.list_physical_devices('GPU')

```

```

358 if len(gpus) > 0:
359     try: tf.config.experimental.set_memory_growth(gpus)
360         ↳ [0],
361         ↳ True)
362     except RuntimeError: print("RuntimeError in tf.con")
363         ↳ fig.experimental.list_physical_devices('GPU')"))
364 Yolo = Load_Yolo_model()
365 times = []
366 while True:
367     if Frames_data.qsize()>0:
368         image_data = Frames_data.get()
369         t1 = time.time()
370         Processing_times.put(time.time())
371
372         if YOLO_FRAMEWORK == "tf":
373             pred_bbox = Yolo.predict(image_data)
374         elif YOLO_FRAMEWORK == "trt":
375             batched_input = tf.constant(image_data)
376             result = Yolo(batched_input)
377             pred_bbox = []
378             for key, value in result.items():
379                 value = value.numpy()
380                 pred_bbox.append(value)
381
382             pred_bbox = [tf.reshape(x, (-1,
383             ↳ tf.shape(x)[-1])) for x in pred_bbox]
384             pred_bbox = tf.concat(pred_bbox, axis=0)
385
386             Predicted_data.put(pred_bbox)
387
388 def postprocess_mp(Predicted_data, original_frames,
389     ↳ Processed_frames, Processing_times, input_size,
390     ↳ CLASSES, score_threshold, iou_threshold,
391     ↳ rectangle_colors, realtime):
392     times = []
393     while True:
394         if Predicted_data.qsize()>0:
395             pred_bbox = Predicted_data.get()
396             if realtime:
397                 while original_frames.qsize() > 1:

```

```

392         original_image = original_frames.get()
393     else:
394         original_image = original_frames.get()
395
396     bboxes = postprocess_boxes(pred_bbox,
397         ↵ original_image, input_size,
398         ↵ score_threshold)
399     bboxes = nms(bboxes, iou_threshold,
400         ↵ method='nms')
401     image = draw_bbox(original_image, bboxes,
402         ↵ CLASSES=CLASSES,
403         ↵ rectangle_colors=rectangle_colors)
404     times.append(time.time()-Processing_times.get(
405         ↵ ))
406     times = times[-20:]
407
408     ms = sum(times)/len(times)*1000
409     fps = 1000 / ms
410     image = cv2.putText(image, "Time:
411         ↵ {:.1f}FPS".format(fps), (0, 30),
412         ↵ cv2.FONT_HERSHEY_COMPLEX_SMALL, 1, (0, 0,
413         ↵ 255), 2)
414     #print("Time: {:.2f}ms, Final FPS:
415         ↵ {:.1f}".format(ms, fps))
416
417     Processed_frames.put(image)
418
419 def Show_Image_mp(Processed_frames, show, Final_frames):
420     while True:
421         if Processed_frames.qsize()>0:
422             image = Processed_frames.get()
423             Final_frames.put(image)
424         if show:
425             cv2.imshow('output', image)
426             if cv2.waitKey(25) & 0xFF == ord("q"):
427                 cv2.destroyAllWindows()
428                 break
429
430 # detect from webcam

```

```
421 def detect_video_realtime_mp(video_path, output_path,
422     ↵ input_size=416, show=False, CLASSES=YOLO_COCO_CLASSES,
423     ↵ score_threshold=0.3, iou_threshold=0.45,
424     ↵ rectangle_colors='', realtime=False):
425     if realtime:
426         vid = cv2.VideoCapture(0)
427     else:
428         vid = cv2.VideoCapture(video_path)
429
430     # by default VideoCapture returns float instead of int
431     width = int(vid.get(cv2.CAP_PROP_FRAME_WIDTH))
432     height = int(vid.get(cv2.CAP_PROP_FRAME_HEIGHT))
433     fps = int(vid.get(cv2.CAP_PROP_FPS))
434     codec = cv2.VideoWriter_fourcc(*'XVID')
435     out = cv2.VideoWriter(output_path, codec, fps, (width,
436         ↵ height)) # output_path must be .mp4
437     no_of_frames = int(vid.get(cv2.CAP_PROP_FRAME_COUNT))
438
439     original_frames = Queue()
440     Frames_data = Queue()
441     Predicted_data = Queue()
442     Processed_frames = Queue()
443     Processing_times = Queue()
444     Final_frames = Queue()
445
446     p1 = Process(target=Predict_bbox_mp,
447         ↵ args=(Frames_data, Predicted_data,
448             ↵ Processing_times))
449     p2 = Process(target=postprocess_mp,
450         ↵ args=(Predicted_data, original_frames,
451             ↵ Processed_frames, Processing_times, input_size,
452             ↵ CLASSES, score_threshold, iou_threshold,
453             ↵ rectangle_colors, realtime))
454     p3 = Process(target>Show_Image_mp,
455         ↵ args=(Processed_frames, show, Final_frames))
456     p1.start()
457     p2.start()
458     p3.start()
459
460     while True:
461         ret, img = vid.read()
```

```
451     if not ret:
452         break
453
454     original_image = cv2.cvtColor(img,
455         ↪ cv2.COLOR_BGR2RGB)
455     original_image = cv2.cvtColor(original_image,
456         ↪ cv2.COLOR_BGR2RGB)
456     original_frames.put(original_image)
457
458     image_data =
459         ↪ image_preprocess(np.copy(original_image),
460             ↪ [input_size, input_size])
460     image_data = image_data[np.newaxis,
461         ↪ ...].astype(np.float32)
462     Frames_data.put(image_data)
463
464 while True:
465     if original_frames.qsize() == 0 and
466         ↪ Frames_data.qsize() == 0 and
467         ↪ Predicted_data.qsize() == 0 and
468         ↪ Processed_frames.qsize() == 0 and
469         ↪ Processing_times.qsize() == 0 and
470         ↪ Final_frames.qsize() == 0:
471         p1.terminate()
472         p2.terminate()
473         p3.terminate()
474         break
475     elif Final_frames.qsize()>0:
476         image = Final_frames.get()
477         if output_path != '': out.write(image)
478
479     cv2.destroyAllWindows()
480
481 def detect_video(Yolo, video_path, output_path,
482     ↪ input_size=416, show=False, CLASSES=YOLO_COCO_CLASSES,
483     ↪ score_threshold=0.5, iou_threshold=0.45,
484     ↪ rectangle_colors=''):
485     times, times_2 = [], []
486     vid = cv2.VideoCapture(video_path)
487     #--Added by Virginia Ramon--
488     data = []
```

```
479     frame = 0
480     #-----
481
482     # by default VideoCapture returns float instead of int
483     width = int(vid.get(cv2.CAP_PROP_FRAME_WIDTH))
484     height = int(vid.get(cv2.CAP_PROP_FRAME_HEIGHT))
485     fps = int(vid.get(cv2.CAP_PROP_FPS))
486     codec = cv2.VideoWriter_fourcc(*'XVID')
487     out = cv2.VideoWriter(output_path, codec, fps, (width,
488             ↴ height)) # output_path must be .mp4
489
490     while True:
491         _, img = vid.read()
492
493         try:
494             original_image = cv2.cvtColor(img,
495                 ↴ cv2.COLOR_BGR2RGB)
496             original_image = cv2.cvtColor(original_image,
497                 ↴ cv2.COLOR_BGR2RGB)
498         except:
499             break
500
501         image_data =
502             ↴ image_preprocess(np.copy(original_image),
503                 ↴ [input_size, input_size])
504         image_data = image_data[np.newaxis,
505             ↴ ...].astype(np.float32)
506
507         t1 = time.time()
508         if YOLO_FRAMEWORK == "tf":
509             pred_bbox = Yolo.predict(image_data)
510         elif YOLO_FRAMEWORK == "trt":
511             batched_input = tf.constant(image_data)
512             result = Yolo(batched_input)
513             pred_bbox = []
514             for key, value in result.items():
515                 value = value.numpy()
516                 pred_bbox.append(value)
517
518         t2 = time.time()
```

```

514     pred_bbox = [tf.reshape(x, (-1, tf.shape(x)[-1]))]
515         ↳ for x in pred_bbox]
516     pred_bbox = tf.concat(pred_bbox, axis=0)
517
518     bboxes = postprocess_boxes(pred_bbox,
519         ↳ original_image, input_size, score_threshold)
520     bboxes = nms(bboxes, iou_threshold, method='nms')
521
522     image = draw_bbox(original_image, bboxes,
523         ↳ CLASSES=CLASSES,
524         ↳ rectangle_colors=rectangle_colors)
525
526     t3 = time.time()
527     times.append(t2-t1)
528     times_2.append(t3-t1)
529
530     times = times[-20:]
531     times_2 = times_2[-20:]
532
533     ms = sum(times)/len(times)*1000
534     fps = 1000 / ms
535     fps2 = 1000 / (sum(times_2)/len(times_2)*1000)
536
537     image = cv2.putText(image, "Time:
538         ↳ {:.1f}FPS".format(fps), (0, 30),
539         ↳ cv2.FONT_HERSHEY_COMPLEX_SMALL, 1, (0, 0,
540         ↳ 255), 2)
541     #CreateXMLfile("XML_Detections",
542         ↳ str(int(time.time())), original_image, bboxes,
543         ↳ read_class_names(CLASSES))
544
545     #--Added by Virginia Ramon--
546     data.append([video_path, frame, bboxes])
547     frame += 1
548     #-----
549
550     print("Time: {:.2f}ms, Detection FPS: {:.1f},
551         ↳ total FPS: {:.1f}".format(ms, fps, fps2))
552     if output_path != '':
553         out.write(image)
554     if show:
555         cv2.imshow('output', image)

```

```
545         if cv2.waitKey(25) & 0xFF == ord("q"):
546             cv2.destroyAllWindows()
547             break
548
549     cv2.destroyAllWindows()
550     return data, read_class_names(CLASSES)
551
552 # detect from webcam
553 def detect_realtime(Yolo, output_path, input_size=416,
554     ↳ show=False, CLASSES=YOLO_COCO_CLASSES,
555     ↳ score_threshold=0.3, iou_threshold=0.45,
556     ↳ rectangle_colors='r'):
557     times = []
558     vid = cv2.VideoCapture(0)
559
560     # by default VideoCapture returns float instead of int
561     width = int(vid.get(cv2.CAP_PROP_FRAME_WIDTH))
562     height = int(vid.get(cv2.CAP_PROP_FRAME_HEIGHT))
563     fps = int(vid.get(cv2.CAP_PROP_FPS))
564     codec = cv2.VideoWriter_fourcc(*'XVID')
565     out = cv2.VideoWriter(output_path, codec, fps, (width,
566     ↳ height)) # output_path must be .mp4
567
568     while True:
569         _, frame = vid.read()
570
571         try:
572             original_frame = cv2.cvtColor(frame,
573                 ↳ cv2.COLOR_BGR2RGB)
574             original_frame = cv2.cvtColor(original_frame,
575                 ↳ cv2.COLOR_BGR2RGB)
576         except:
577             break
578         image_data =
579             ↳ image_preprocess(np.copy(original_frame),
580                 ↳ [input_size, input_size])
581         image_data = image_data[np.newaxis,
582             ↳ ...].astype(np.float32)
583
584         t1 = time.time()
585         if YOLO_FRAMEWORK == "tf":
```

```

577         pred_bbox = Yolo.predict(image_data)
578     elif YOLO_FRAMEWORK == "trt":
579         batched_input = tf.constant(image_data)
580         result = Yolo(batched_input)
581         pred_bbox = []
582         for key, value in result.items():
583             value = value.numpy()
584             pred_bbox.append(value)
585
586         t2 = time.time()
587
588         pred_bbox = [tf.reshape(x, (-1, tf.shape(x)[-1]))
589                     for x in pred_bbox]
590         pred_bbox = tf.concat(pred_bbox, axis=0)
591
592         bboxes = postprocess_boxes(pred_bbox,
593                                   original_frame, input_size, score_threshold)
594         bboxes = nms(bboxes, iou_threshold, method='nms')
595
596         times.append(t2-t1)
597         times = times[-20:]
598
599         ms = sum(times)/len(times)*1000
600         fps = 1000 / ms
601
602         print("Time: {:.2f}ms, {:.1f} FPS".format(ms, fps))
603
604         frame = draw_bbox(original_frame, bboxes,
605                           CLASSES=CLASSES,
606                           rectangle_colors=rectangle_colors)
607         # CreateXMLfile("XML_Detections",
608         #               str(int(time.time())), original_frame, bboxes,
609         #               read_class_names(CLASSES))
610         image = cv2.putText(frame, "Time:
611                             {:.1f}FPS".format(fps), (0, 30),
612                             cv2.FONT_HERSHEY_COMPLEX_SMALL,
613                             1, (0, 0, 255), 2)
614
615         if output_path != '':
616             out.write(frame)
617         if show:
618             cv2.imshow('output', frame)

```

```
610         if cv2.waitKey(25) & 0xFF == ord("q"):
611             cv2.destroyAllWindows()
612             break
613
614     cv2.destroyAllWindows()
```

### C.3.4 dataset.py

```
1 #=====
2 #
3 #     File name      : dataset.py
4 #     Author         : PyLessons
5 #     Created date: 2020-07-31
6 #     Website        : https://pylessons.com/
7 #     GitHub          :
8 #     Description   : functions used to prepare dataset for
9 #                      custom training
10 #=====
11 #
12 import os
13 import sys
14 import cv2
15 import random
16 import numpy as np
17 import tensorflow as tf
18 from yolov3.utils import read_class_names, image_preprocess
19 from yolov3.yolov3 import bbox_iou
20 from yolov3.configs import *
21
22
23 class Dataset(object):
24     # Dataset preprocess implementation
25     def __init__(self, dataset_type,
26                  TEST_INPUT_SIZE=TEST_INPUT_SIZE):
27         self.annot_path = TRAIN_ANNOT_PATH if
28             dataset_type == 'train' else TEST_ANNOT_PATH
29         self.input_sizes = TRAIN_INPUT_SIZE if
30             dataset_type == 'train' else TEST_INPUT_SIZE
31         self.batch_size = TRAIN_BATCH_SIZE if
32             dataset_type == 'train' else TEST_BATCH_SIZE
33         self.data_aug = TRAIN_DATA_AUG if
34             dataset_type == 'train' else TEST_DATA_AUG
```

```
31     self.train_yolo_tiny = TRAIN_YOLO_TINY
32     self.train_input_sizes = TRAIN_INPUT_SIZE
33     self.strides = np.array(YOLO_STRIDES)
34     self.classes = read_class_names(TRAIN_CLASSES)
35     self.num_classes = len(self.classes)
36     self.anchors =
37         ~ (np.array(YOLO_ANCHORS).T/self.strides).T
38     self.anchor_per_scale = YOLO_ANCHOR_PER_SCALE
39     self.max_bbox_per_scale = YOLO_MAX_BBOX_PER_SCALE
40
41     self.annotations =
42         ~ self.load_annotations(dataset_type)
43     self.num_samples = len(self.annotations)
44     self.num_batches = int(np.ceil(self.num_samples /
45         ~ self.batch_size))
46     self.batch_count = 0
47
48
49
50     def load_annotations(self, dataset_type):
51         final_annotations = []
52         with open(self.annot_path, 'r') as f:
53             txt = f.read().splitlines()
54             annotations = [line.strip() for line in txt if
55                 ~ len(line.strip().split()[1:]) != 0]
56         np.random.shuffle(annotations)
57         n = 1
58         # for annotation in annotations:
59         #     image_extension = '.jpg'
60         #     extension_index =
61         #         ~ annotation.find(image_extension)
62         #     image_path = annotation[:extension_index+len(
63         #         ~ (image_extension))]
64         #     line = annotation[extension_index+len(image_-
65         #         ~ extension):].split()
66         #     if not os.path.exists(image_path):
67         #         raise KeyError("%s does not exist ... "
68         #             ~ %image_path)
69         #     if TRAIN_LOAD_IMAGES_TO_RAM:
70         #         image = cv2.imread(image_path)
71         #     else:
72         #         image = ''
```

```
64      #     final_annotations.append([image_path, line,
65      #     ↵  image])
66      # return final_annotations
67      for annotation in annotations:
68          if n%100 == 0:
69              print(str(n) + '/' + str(len(annotations)),
70                  ↵  flush = True)
71              #sys.stdout.flush()
72          n += 1
73          # fully parse annotations
74          line = annotation.split()
75          image_path, index = "", 1
76          for i, one_line in enumerate(line):
77              if not
78                  ↵  one_line.replace(",","",).isnumeric():
79                  if image_path != "": image_path += " "
80                  image_path += one_line
81              else:
82                  index = i
83                  break
84          if not os.path.exists(image_path):
85              raise KeyError("%s does not exist ... "
86                  ↵  %image_path)
87          if TRAIN_LOAD_IMAGES_TO_RAM:
88              image = cv2.imread(image_path)
89          else:
90              image = ''
91          final_annotations.append([image_path,
92              ↵  line[index:], image])
93      return final_annotations
94
95
96
97      def __iter__(self):
98          return self
99
100
101      def Delete_bad_annotation(self, bad_annotation):
102          print(f'Deleting {bad_annotation} annotation line')
103          bad_image_path = bad_annotation[0]
104          bad_image_name = bad_annotation[0].split('/')[-1] #
105              ↵  can be used to delete bad image
106          bad_xml_path = bad_annotation[0][:-3]+'.xml' # can
107              ↵  be used to delete bad xml file
```

```
98
99      # remove bad annotation line from annotation file
100     with open(self.annot_path, "r+") as f:
101         d = f.readlines()
102         f.seek(0)
103         for i in d:
104             if bad_image_name not in i:
105                 f.write(i)
106         f.truncate()
107
108     def __next__(self):
109         with tf.device('/cpu:0'):
110             self.train_input_size =
111                 ↳ random.choice([self.train_input_sizes])
112             self.train_output_sizes =
113                 ↳ self.train_input_size // self.strides
114
115             batch_image = np.zeros((self.batch_size,
116                                     ↳ self.train_input_size,
117                                     ↳ self.train_input_size, 3),
118                                     ↳ dtype=np.float32)
119
120             if self.train_yolo_tiny:
121                 batch_label_mbbox =
122                     ↳ np.zeros((self.batch_size,
123                                 ↳ self.train_output_sizes[0],
124                                 ↳ self.train_output_sizes[0],
125                                 ↳ self.anchor_per_scale, 5 +
126                                 ↳ self.num_classes), dtype=np.float32)
127                 batch_label_lbbox =
128                     ↳ np.zeros((self.batch_size,
129                                 ↳ self.train_output_sizes[1],
130                                 ↳ self.train_output_sizes[1],
131                                 ↳ self.anchor_per_scale, 5 +
132                                 ↳ self.num_classes), dtype=np.float32)
133
134             else:
```

```
119         batch_label_sbbox =
120             np.zeros((self.batch_size,
121                     self.train_output_sizes[0],
122                     self.train_output_sizes[0],
123                     self.anchor_per_scale, 5 +
124                     self.num_classes), dtype=np.float32)
125         batch_label_mbbox =
126             np.zeros((self.batch_size,
127                     self.train_output_sizes[1],
128                     self.train_output_sizes[1],
129                     self.anchor_per_scale, 5 +
130                     self.num_classes), dtype=np.float32)
131         batch_label_lbbox =
132             np.zeros((self.batch_size,
133                     self.train_output_sizes[2],
134                     self.train_output_sizes[2],
135                     self.anchor_per_scale, 5 +
136                     self.num_classes), dtype=np.float32)
137
138         batch_sbboxes = np.zeros((self.batch_size,
139             self.max_bbox_per_scale, 4),
140             dtype=np.float32)
141
142         batch_mbboxes = np.zeros((self.batch_size,
143             self.max_bbox_per_scale, 4),
144             dtype=np.float32)
145         batch_lbboxes = np.zeros((self.batch_size,
146             self.max_bbox_per_scale, 4),
147             dtype=np.float32)
148
149         exceptions = False
150         num = 0
151         if self.batch_count < self.num_batchs:
152             while num < self.batch_size:
153                 index = self.batch_count *
154                     self.batch_size + num
155                 if index >= self.num_samples: index -=
156                     self.num_samples
157                 annotation = self.annotations[index]
158                 image, bboxes =
159                     self.parse_annotation(annotation)
```

```
136         try:
137             if self.train_yolo_tiny:
138                 label_mbbox, label_lbbox,
139                     ↳ mbboxes, lbboxes = self.pr_
140                     ↳ eprocess_true_boxes(bboxes)
141             else:
142                 label_sbbox, label_mbbox,
143                     ↳ label_lbbox, sbboxes,
144                     ↳ mbboxes, lbboxes = self.pr_
145                     ↳ eprocess_true_boxes(bboxes)
146             except IndexError:
147                 exceptions = True
148                 self.Delete_bad_annotation(annotation)
149                     ↳ ion)
150                 print("IndexError, something wrong
151                     ↳ with", annotation[0], "removed
152                     ↳ this line from annotation
153                     ↳ file")
154
155             batch_image[num, :, :, :] = image
156             batch_label_mbbox[num, :, :, :, :] =
157                 ↳ label_mbbox
158             batch_label_lbbox[num, :, :, :, :] =
159                 ↳ label_lbbox
160             batch_mbboxes[num, :, :] = mbboxes
161             batch_lbboxes[num, :, :] = lbboxes
162             if not self.train_yolo_tiny:
163                 batch_label_sbbox[num, :, :, :, :] =
164                     ↳ label_sbbox
165                 batch_sbboxes[num, :, :] = sbboxes
166
167             num += 1
168
169             if exceptions:
170                 print('\n')
171                 raise Exception("There were problems
172                     ↳ with dataset, I fixed them, now
173                     ↳ restart the training process.")
174             self.batch_count += 1
175             if not self.train_yolo_tiny:
```

```
162         batch_smaller_target =
163             ↳ batch_label_sbbox, batch_sbboxes
164         batch_medium_target = batch_label_mbbox,
165             ↳ batch_mbboxes
166         batch_larger_target = batch_label_lbbox,
167             ↳ batch_lbboxes
168
169     if self.train_yolo_tiny:
170         return batch_image,
171             ↳ (batch_medium_target,
172                 ↳ batch_larger_target)
173     return batch_image, (batch_smaller_target,
174             ↳ batch_medium_target,
175                 ↳ batch_larger_target)
176
177 else:
178     self.batch_count = 0
179     np.random.shuffle(self.annotations)
180     raise StopIteration
181
182 def random_horizontal_flip(self, image, bboxes):
183     if random.random() < 0.5:
184         _, w, _ = image.shape
185         image = image[:, ::-1, :]
186         bboxes[:, [0,2]] = w - bboxes[:, [2,0]]
187
188     return image, bboxes
189
190 def random_crop(self, image, bboxes):
191     if random.random() < 0.5:
192         h, w, _ = image.shape
193         max_bbox = np.concatenate([np.min(bboxes[:, 0:2], axis=0), np.max(bboxes[:, 2:4], axis=0)], axis=-1)
194
195         max_l_trans = max_bbox[0]
196         max_u_trans = max_bbox[1]
197         max_r_trans = w - max_bbox[2]
198         max_d_trans = h - max_bbox[3]
199
200         crop_xmin = max(0, int(max_bbox[0] -
201             random.uniform(0, max_l_trans)))
```

```
193         crop_ymin = max(0, int(max_bbox[1] -
194                         ↵ random.uniform(0, max_u_trans)))
195         crop_xmax = max(w, int(max_bbox[2] +
196                         ↵ random.uniform(0, max_r_trans)))
197         crop_ymax = max(h, int(max_bbox[3] +
198                         ↵ random.uniform(0, max_d_trans)))
199
200         image = image[crop_ymin : crop_ymax, crop_xmin
201                         ↵ : crop_xmax]
202
203         bboxes[:, [0, 2]] = bboxes[:, [0, 2]] -
204                         ↵ crop_xmin
205         bboxes[:, [1, 3]] = bboxes[:, [1, 3]] -
206                         ↵ crop_ymin
207
208         return image, bboxes
209
210
211
212
213
214
215
216
217
218
219
220
221
222
223
def random_translate(self, image, bboxes):
    if random.random() < 0.5:
        h, w, _ = image.shape
        max_bbox = np.concatenate([np.min(bboxes[:, 0:2], axis=0), np.max(bboxes[:, 2:4], axis=0)], axis=-1)

        max_l_trans = max_bbox[0]
        max_u_trans = max_bbox[1]
        max_r_trans = w - max_bbox[2]
        max_d_trans = h - max_bbox[3]

        tx = random.uniform(-(max_l_trans - 1),
                           (max_r_trans - 1))
        ty = random.uniform(-(max_u_trans - 1),
                           (max_d_trans - 1))

        M = np.array([[1, 0, tx], [0, 1, ty]])
        image = cv2.warpAffine(image, M, (w, h))

        bboxes[:, [0, 2]] = bboxes[:, [0, 2]] + tx
        bboxes[:, [1, 3]] = bboxes[:, [1, 3]] + ty

    return image, bboxes
```

```
224
225     def parse_annotation(self, annotation, mAP = 'False'):
226         if TRAIN_LOAD_IMAGES_TO_RAM:
227             image_path = annotation[0]
228             image = annotation[2]
229         else:
230             image_path = annotation[0]
231             image = cv2.imread(image_path)
232
233         bboxes = np.array([list(map(int, box.split(',')))  
    ↵   for box in annotation[1]])
234
235         if self.data_aug:
236             image, bboxes = self.random_horizontal_flip(np.  
    ↵   .copy(image),  
    ↵   np.copy(bboxes))
237             image, bboxes =  
    ↵   self.random_crop(np.copy(image),  
    ↵   np.copy(bboxes))
238             image, bboxes =  
    ↵   self.random_translate(np.copy(image),  
    ↵   np.copy(bboxes))
239
240         #image = cv2.cvtColor(image, cv2.COLOR_BGR2RGB)
241         if mAP == True:
242             return image, bboxes
243
244         image, bboxes = image_preprocess(np.copy(image),
245             ↵   [self.input_sizes, self.input_sizes],
246             ↵   np.copy(bboxes))
247         return image, bboxes
248
249
250     def preprocess_true_boxes(self, bboxes):
251         OUTPUT_LEVELS = len(self.strides)
252
253         label = [np.zeros((self.train_output_sizes[i],  
    ↵   self.train_output_sizes[i],  
    ↵   self.anchor_per_scale,  
    ↵   5 + self.num_classes)) for i in  
    ↵   range(OUTPUT_LEVELS)]
```

```

252         bboxes_xywh = [np.zeros((self.max_bbox_per_scale,
253             ↵ 4)) for _ in range(OUTPUT_LEVELS)]
254         bbox_count = np.zeros((OUTPUT_LEVELS,))
255
256     for bbox in bboxes:
257         bbox_coor = bbox[:4]
258         bbox_class_ind = bbox[4]
259
260         onehot = np.zeros(self.num_classes,
261             ↵ dtype=np.float)
262         onehot[bbox_class_ind] = 1.0
263         uniform_distribution =
264             ↵ np.full(self.num_classes, 1.0 /
265             ↵ self.num_classes)
266         deta = 0.01
267         smooth_onehot = onehot * (1 - deta) + deta *
268             ↵ uniform_distribution
269
270         bbox_xywh = np.concatenate([(bbox_coor[2:] +
271             ↵ bbox_coor[:2]) * 0.5, bbox_coor[2:] -
272             ↵ bbox_coor[:2]], axis=-1)
273         bbox_xywh_scaled = 1.0 * bbox_xywh[np.newaxis,
274             ↵ :] / self.strides[:, np.newaxis]
275
276         iou = []
277         exist_positive = False
278         for i in range(OUTPUT_LEVELS):#range(3):
279             anchors_xywh =
280                 ↵ np.zeros((self.anchor_per_scale, 4))
281             anchors_xywh[:, 0:2] =
282                 ↵ np.floor(bbox_xywh_scaled[i,
283                     ↵ 0:2]).astype(np.int32) + 0.5
284             anchors_xywh[:, 2:4] = self.anchors[i]
285
286             iou_scale = bbox_iou(bbox_xywh_scaled[i][n],
287                 ↵ p.newaxis, :),
288                 ↵ anchors_xywh)
289             iou.append(iou_scale)
290             iou_mask = iou_scale > 0.3
291
292             if np.any(iou_mask):

```



```
304         bbox_ind = int(bbox_count[best_detect] %  
305                         ↵ self.max_bbox_per_scale)  
306         bboxes_xywh[best_detect][bbox_ind, :4] =  
307                         ↵ bbox_xywh  
308         bbox_count[best_detect] += 1  
309  
310     if self.train_yolo_tiny:  
311         label_mbbox, label_lbbox = label  
312         mbboxes, lbboxes = bboxes_xywh  
313         return label_mbbox, label_lbbox, mbboxes,  
314                         ↵ lbboxes  
315  
316     label_sbbox, label_mbbox, label_lbbox = label  
317     sbboxes, mbboxes, lbboxes = bboxes_xywh  
318     return label_sbbox, label_mbbox, label_lbbox,  
319                         ↵ sbboxes, mbboxes, lbboxes  
320  
321     def __len__(self):  
322         return self.num_batchs
```

### C.3.5 train.py

```
1 #===== ]  
2 #=====  
3 # File name : train.py  
4 # Author : PyLessons  
5 # Created date: 2020-08-06  
6 # Website : https://pylessons.com/  
7 # GitHub :  
8 # Description : used to train custom object detector  
9 # Modified by : Virginia Ramón  
10 #===== ]  
11 #=====  
12 # Coments added by Virginia Ramon  
13 import os  
14 os.environ['CUDA_VISIBLE_DEVICES'] = '0,1'  
15 os.environ['TF_FORCE_GPU_ALLOW_GROWTH'] = 'true'  
16 from tensorflow.python.client import device_lib  
17 import shutil  
18 import numpy as np  
19 import tensorflow as tf  
20 config = tf.compat.v1.ConfigProto()  
21 config.gpu_options.allow_growth = True  
22 session = tf.compat.v1.Session(config=config)  
23 from yolov3.dataset import Dataset  
24 from yolov3.yolov4 import Create_Yolo, compute_loss  
25 from yolov3.utils import load_yolo_weights  
26 from yolov3.configs import *  
27 from evaluate_mAP import get_mAP  
28  
29  
30 # Define YOLO architecture  
31 if YOLO_TYPE == "yolov4":  
32     print("YOLOv4...")  
33     Darknet_weights = YOLO_V4_TINY_WEIGHTS if  
34         TRAIN_YOLO_TINY else YOLO_V4_WEIGHTS  
35 if YOLO_TYPE == "yolov3":  
36     print("YOLOv3...")
```

```
36     Darknet_weights = YOLO_V3_TINY_WEIGHTS if
37         ↳ TRAIN_YOLO_TINY else YOLO_V3_WEIGHTS
38 if TRAIN_YOLO_TINY: TRAIN_MODEL_NAME += "_Tiny"
39
40 print("Num GPUs Available: ",
41     ↳ len(tf.config.list_physical_devices('GPU')))
42 def main():
43     # Create register file for training process
44         ↳ (Virginia Ramón)
45     file = open("loss_training_PigPerse46.txt", 'w')
46     print("Register file created!")
47
48     global TRAIN_FROM_CHECKPOINT
49
50     #Allow memory growth in GPUs
51     gpus =
52         ↳ tf.config.experimental.list_physical_devices('GPU')
53     for gpu in gpus:
54         tf.config.experimental.set_memory_growth(gpu, True)
55
56     # Save training summary
57     if os.path.exists(TRAIN_LOGDIR):
58         ↳ shutil.rmtree(TRAIN_LOGDIR)
59     writer = tf.summary.create_file_writer(TRAIN_LOGDIR)
60
61     # Import train and validation datasets
62     print("Reading train dataset...")
63     trainset = Dataset('train')
64     print("Reading validation dataset...")
65     testset = Dataset('test')
66
67     # Define epochs and lengths
68     steps_per_epoch = len(trainset)
69     global_steps = tf.Variable(1, trainable=False,
70         ↳ dtype=tf.int64)
71     warmup_steps = TRAIN_WARMUP_EPOCHS * steps_per_epoch
72     total_steps = TRAIN_EPOCHS * steps_per_epoch
73
74     # Recreate YOLOv4 with Darknet weights
75     if TRAIN_TRANSFER:
76         print("Creating Darknet model...")
```

```

71     Darknet = Create_Yolo(input_size=YOLO_INPUT_SIZE,
72                           CLASSES=YOLO_COCO_CLASSES)
73     print("Loading model weights Darknet...")
74     load_yolo_weights(Darknet, Darknet_weights) # use
75                           darknet weights
76
77     # Create YOLOv4 to train
78     print("Creating YOLO model...")
79     yolo = Create_Yolo(input_size=YOLO_INPUT_SIZE,
80                          training=True, CLASSES=TRAIN_CLASSES)
81
82     if TRAIN_FROM_CHECKPOINT:
83         try:
84             print("Loading checkpoint weights...")
85             yolo.load_weights(f"./checkpoints/yolov4_PigPe_"
86                               rsv2/{TRAIN_MODEL_NAME}")
87         except ValueError:
88             print("Shapes are incompatible, transferring"
89                  " Darknet weights")
90             TRAIN_FROM_CHECKPOINT = False
91
92     if TRAIN_TRANSFER and not TRAIN_FROM_CHECKPOINT:
93         print("Loading darknet weights to model...")
94         for i, l in enumerate(Darknet.layers):
95             layer_weights = l.get_weights()
96             if layer_weights != []:
97                 try:
98                     yolo.layers[i].set_weights(layer_weights)
99                 except:
100                     print("skipping", yolo.layers[i].name)
101
102     # Choose the optimizer for the training
103     optimizer = tf.keras.optimizers.Adam()
104
105     # Training step: for each image in train dataset
106     #   compute gradient and apply to NN with LR
107     def train_step(image_data, target):
108         with tf.GradientTape() as tape:
109             pred_result = yolo(image_data, training=True)
110             giou_loss=conf_loss=prob_loss=0
111
112
113
114
115
116
117
118
119
120
121
122
123
124
125
126
127
128
129
130
131
132
133
134
135
136
137
138
139
140
141
142
143
144
145
146
147
148
149
150
151
152
153
154
155
156
157
158
159
160
161
162
163
164
165
166
167
168
169
170
171
172
173
174
175
176
177
178
179
180
181
182
183
184
185
186
187
188
189
190
191
192
193
194
195
196
197
198
199
200
201
202
203
204
205
206
207
208
209
210
211
212
213
214
215
216
217
218
219
220
221
222
223
224
225
226
227
228
229
230
231
232
233
234
235
236
237
238
239
240
241
242
243
244
245
246
247
248
249
250
251
252
253
254
255
256
257
258
259
260
261
262
263
264
265
266
267
268
269
270
271
272
273
274
275
276
277
278
279
280
281
282
283
284
285
286
287
288
289
290
291
292
293
294
295
296
297
298
299
300
301
302
303
304
305
306
307
308
309
310
311
312
313
314
315
316
317
318
319
320
321
322
323
324
325
326
327
328
329
330
331
332
333
334
335
336
337
338
339
340
341
342
343
344
345
346
347
348
349
350
351
352
353
354
355
356
357
358
359
360
361
362
363
364
365
366
367
368
369
370
371
372
373
374
375
376
377
378
379
380
381
382
383
384
385
386
387
388
389
390
391
392
393
394
395
396
397
398
399
400
401
402
403
404
405
406
407
408
409
410
411
412
413
414
415
416
417
418
419
420
421
422
423
424
425
426
427
428
429
430
431
432
433
434
435
436
437
438
439
440
441
442
443
444
445
446
447
448
449
450
451
452
453
454
455
456
457
458
459
460
461
462
463
464
465
466
467
468
469
470
471
472
473
474
475
476
477
478
479
480
481
482
483
484
485
486
487
488
489
490
491
492
493
494
495
496
497
498
499
500
501
502
503
504
505
506
507
508
509
510
511
512
513
514
515
516
517
518
519
520
521
522
523
524
525
526
527
528
529
530
531
532
533
534
535
536
537
538
539
540
541
542
543
544
545
546
547
548
549
550
551
552
553
554
555
556
557
558
559
559
560
561
562
563
564
565
566
567
568
569
569
570
571
572
573
574
575
576
577
578
579
579
580
581
582
583
584
585
586
587
588
589
589
590
591
592
593
594
595
596
597
598
599
599
600
601
602
603
604
605
606
607
608
609
609
610
611
612
613
614
615
616
617
618
619
619
620
621
622
623
624
625
626
627
628
629
629
630
631
632
633
634
635
636
637
638
639
639
640
641
642
643
644
645
646
647
648
649
649
650
651
652
653
654
655
656
657
658
659
659
660
661
662
663
664
665
666
667
668
669
669
670
671
672
673
674
675
676
677
678
679
679
680
681
682
683
684
685
686
687
688
689
689
690
691
692
693
694
695
696
697
698
699
699
700
701
702
703
704
705
706
707
708
709
709
710
711
712
713
714
715
716
717
718
719
719
720
721
722
723
724
725
726
727
728
729
729
730
731
732
733
734
735
736
737
738
739
739
740
741
742
743
744
745
746
747
747
748
749
749
750
751
752
753
754
755
756
757
758
759
759
760
761
762
763
764
765
766
767
768
769
769
770
771
772
773
774
775
776
777
778
779
779
780
781
782
783
784
785
786
787
787
788
789
789
790
791
792
793
794
795
796
797
797
798
799
799
800
801
802
803
804
805
806
807
808
809
809
810
811
812
813
814
815
816
817
817
818
819
819
820
821
822
823
824
825
826
827
827
828
829
829
830
831
832
833
834
835
836
837
837
838
839
839
840
841
842
843
844
845
846
846
847
848
848
849
849
850
851
852
853
854
855
856
856
857
858
858
859
859
860
861
862
863
864
865
866
866
867
868
868
869
869
870
871
872
873
874
875
876
876
877
878
878
879
879
880
881
882
883
884
885
886
886
887
888
888
889
889
890
891
892
893
894
895
895
896
897
897
898
898
899
899
900
901
902
903
904
905
905
906
907
907
908
908
909
909
910
911
912
913
913
914
914
915
915
916
916
917
917
918
918
919
919
920
920
921
921
922
922
923
923
924
924
925
925
926
926
927
927
928
928
929
929
930
930
931
931
932
932
933
933
934
934
935
935
936
936
937
937
938
938
939
939
940
940
941
941
942
942
943
943
944
944
945
945
946
946
947
947
948
948
949
949
950
950
951
951
952
952
953
953
954
954
955
955
956
956
957
957
958
958
959
959
960
960
961
961
962
962
963
963
964
964
965
965
966
966
967
967
968
968
969
969
970
970
971
971
972
972
973
973
974
974
975
975
976
976
977
977
978
978
979
979
980
980
981
981
982
982
983
983
984
984
985
985
986
986
987
987
988
988
989
989
990
990
991
991
992
992
993
993
994
994
995
995
996
996
997
997
998
998
999
999
1000
1000
1001
1001
1002
1002
1003
1003
1004
1004
1005
1005
1006
1006
1007
1007
1008
1008
1009
1009
1010
1010
1011
1011
1012
1012
1013
1013
1014
1014
1015
1015
1016
1016
1017
1017
1018
1018
1019
1019
1020
1020
1021
1021
1022
1022
1023
1023
1024
1024
1025
1025
1026
1026
1027
1027
1028
1028
1029
1029
1030
1030
1031
1031
1032
1032
1033
1033
1034
1034
1035
1035
1036
1036
1037
1037
1038
1038
1039
1039
1040
1040
1041
1041
1042
1042
1043
1043
1044
1044
1045
1045
1046
1046
1047
1047
1048
1048
1049
1049
1050
1050
1051
1051
1052
1052
1053
1053
1054
1054
1055
1055
1056
1056
1057
1057
1058
1058
1059
1059
1060
1060
1061
1061
1062
1062
1063
1063
1064
1064
1065
1065
1066
1066
1067
1067
1068
1068
1069
1069
1070
1070
1071
1071
1072
1072
1073
1073
1074
1074
1075
1075
1076
1076
1077
1077
1078
1078
1079
1079
1080
1080
1081
1081
1082
1082
1083
1083
1084
1084
1085
1085
1086
1086
1087
1087
1088
1088
1089
1089
1090
1090
1091
1091
1092
1092
1093
1093
1094
1094
1095
1095
1096
1096
1097
1097
1098
1098
1099
1099
1100
1100
1101
1101
1102
1102
1103
1103
1104
1104
1105
1105
1106
1106
1107
1107
1108
1108
1109
1109
1110
1110
1111
1111
1112
1112
1113
1113
1114
1114
1115
1115
1116
1116
1117
1117
1118
1118
1119
1119
1120
1120
1121
1121
1122
1122
1123
1123
1124
1124
1125
1125
1126
1126
1127
1127
1128
1128
1129
1129
1130
1130
1131
1131
1132
1132
1133
1133
1134
1134
1135
1135
1136
1136
1137
1137
1138
1138
1139
1139
1140
1140
1141
1141
1142
1142
1143
1143
1144
1144
1145
1145
1146
1146
1147
1147
1148
1148
1149
1149
1150
1150
1151
1151
1152
1152
1153
1153
1154
1154
1155
1155
1156
1156
1157
1157
1158
1158
1159
1159
1160
1160
1161
1161
1162
1162
1163
1163
1164
1164
1165
1165
1166
1166
1167
1167
1168
1168
1169
1169
1170
1170
1171
1171
1172
1172
1173
1173
1174
1174
1175
1175
1176
1176
1177
1177
1178
1178
1179
1179
1180
1180
1181
1181
1182
1182
1183
1183
1184
1184
1185
1185
1186
1186
1187
1187
1188
1188
1189
1189
1190
1190
1191
1191
1192
1192
1193
1193
1194
1194
1195
1195
1196
1196
1197
1197
1198
1198
1199
1199
1200
1200
1201
1201
1202
1202
1203
1203
1204
1204
1205
1205
1206
1206
1207
1207
1208
1208
1209
1209
1210
1210
1211
1211
1212
1212
1213
1213
1214
1214
1215
1215
1216
1216
1217
1217
1218
1218
1219
1219
1220
1220
1221
1221
1222
1222
1223
1223
1224
1224
1225
1225
1226
1226
1227
1227
1228
1228
1229
1229
1230
1230
1231
1231
1232
1232
1233
1233
1234
1234
1235
1235
1236
1236
1237
1237
1238
1238
1239
1239
1240
1240
1241
1241
1242
1242
1243
1243
1244
1244
1245
1245
1246
1246
1247
1247
1248
1248
1249
1249
1250
1250
1251
1251
1252
1252
1253
1253
1254
1254
1255
1255
1256
1256
1257
1257
1258
1258
1259
1259
1260
1260
1261
1261
1262
1262
1263
1263
1264
1264
1265
1265
1266
1266
1267
1267
1268
1268
1269
1269
1270
1270
1271
1271
1272
1272
1273
1273
1274
1274
1275
1275
1276
1276
1277
1277
1278
1278
1279
1279
1280
1280
1281
1281
1282
1282
1283
1283
1284
1284
1285
1285
1286
1286
1287
1287
1288
1288
1289
1289
1290
1290
1291
1291
1292
1292
1293
1293
1294
1294
1295
1295
1296
1296
1297
1297
1298
1298
1299
1299
1300
1300
1301
1301
1302
1302
1303
1303
1304
1304
1305
1305
1306
1306
1307
1307
1308
1308
1309
1309
1310
1310
1311
1311
1312
1312
1313
1313
1314
1314
1315
1315
1316
1316
1317
1317
1318
1318
1319
1319
1320
1320
1321
1321
1322
1322
1323
1323
1324
1324
1325
1325
1326
1326
1327
1327
1328
1328
1329
1329
1330
1330
1331
1331
1332
1332
1333
1333
1334
1334
1335
1335
1336
1336
1337
1337
1338
1338
1339
1339
1340
1340
1341
1341
1342
1342
1343
1343
1344
1344
1345
1345
1346
1346
1347
1347
1348
1348
1349
1349
1350
1350
1351
1351
1352
1352
1353
1353
1354
1354
1355
1355
1356
1356
1357
1357
1358
1358
1359
1359
1360
1360
1361
1361
1362
1362
1363
1363
1364
1364
1365
1365
1366
1366
1367
1367
1368
1368
1369
1369
1370
1370
1371
1371
1372
1372
1373
1373
1374
1374
1375
1375
1376
1376
1377
1377
1378
1378
1379
1379
1380
1380
1381
1381
1382
1382
1383
1383
1384
1384
1385
1385
1386
1386
1387
1387
1388
1388
1389
1389
1390
1390
1391
1391
1392
1392
1393
1393
1394
1394
1395
1395
1396
1396
1397
1397
1398
1398
1399
1399
1400
1400
1401
1401
1402
1402
1403
1403
1404
1404
1405
1405
1406
1406
1407
1407
1408
1408
1409
1409
1410
1410
1411
1411
1412
1412
1413
1413
1414
1414
1415
1415
1416
1416
1417
1417
1418
1418
1419
1419
1420
1420
1421
1421
1422
1422
1423
1423
1424
1424
1425
1425
1426
1426
1427
1427
1428
1428
1429
1429
1430
1430
1431
1431
1432
1432
1433
1433
1434
1434
1435
1435
1436
1436
1437
1437
1438
1438
1439
1439
1440
1440
1441
1441
1442
1442
1443
1443
1444
1444
1445
1445
1446
1446
1447
1447
1448
1448
1449
1449
1450
1450
1451
1451
1452
1452
1453
1453
1454
1454
1455
1455
1456
1456
1457
1457
1458
1458
1459
1459
1460
1460
1461
1461
1462
1462
1463
1463
1464
1464
1465
1465
1466
1466
1467
1467
1468
1468
1469
1469
1470
1470
1471
1471
1472
1472
1473
1473
1474
1474
1475
1475
1476
1476
1477
1477
1478
1478
1479
1479
1480
1480
1481
1481
1482
1482
1483
1483
1484
1484
1485
1485
1486
1486
1487
1487
1488
1488
1489
1489
1490
1490
1491
1491
1492
1492
1493
1493
1494
1494
1495
1495
1496
1496
1497
1497
1498
1498
1499
1499
1500
1500
1501
1501
1502
1502
1503
1503
1504
1504
1505
1505
1506
1506
1507
1507
1508
1508
1509
1509
1510
1510
1511
1511
1512
1512
1513
1513
1514
1514
1515
1515
1516
1516
1517
1517
1518
1518
1519
1519
1520
1520
1521
1521
1522
1522
1523
1523
1524
1524
1525
1525
1526
1526
1527
1527
1528
1528
1529
1529
1530
1530
1531
1531
1532
1532
1533
1533
1534
1534
1535
1535
1536
1536
1537
1537
1538
1538
1539
1539
1540
1540
1541
1541
1542
1542
1543
1543
1544
1544
1545
1545
1546
1546
1547
1547
1548
1548
1549
1549
1550
1550
1551
1551
1552
1552
1553
1553
1554
1554
1555
1555
1556
1556
1557
1557
1558
1558
1559
1559
1560
1560
1561
1561
1562
1562
1563
1563
1564
1564
1565
1565
1566
1566
1567
1567
1568
1568
1569
1569
1570
1570
1571
1571
1572
1572
1573
1573
1574
1574
1575
1575
1576
1576
1577
1577
1578
1578
1579
1579
1580
1580
1581
1581
1582
1582
1583
1583
1584
1584
1585
1585
1586
1586
1587
1587
1588
1588
1589
1589
1590
1590
1591
1591
1592
1592
1593
1593
1594
1594
1595
1595
1596
1596
1597
1597
1598
1598
1599
1599
1600
1600
1601
1601
1602
1602
1603
1603
1604
1604
1605
1605
1606
1606
1607
1607
1608
1608
1609
1609
1610
1610
1611
1611
1612
1612
1613
1613
1614
1614
1615
1615
1616
1616
1617
1617
1618
1618
1619
1619
1620
1620
1621
1621
1622
1622
1623
1623
1624
1624
1625
1625
1626
1626
1627
1627
1628
1628
1629
1629
1630
1630
1631
1631
1632
1632
1633
1633
1634
1634
1635
1635
1636
1636
1637
1637
1638
1638
1639
1639
1640
1640
1641
1641
1642
1642
1643
1643
1644
1644
1645
1645
1646
1646
1647
1647
1648
1648
1649
1649
1650
1650
1651
1651
1652
1652
1653
1653
1654
1654
1655
```

```

105      # optimizing process
106      grid = 3 if not TRAIN_YOLO_TINY else 2
107      for i in range(grid):
108          conv, pred = pred_result[i*2],
109              ↳ pred_result[i*2+1]
110          loss_items = compute_loss(pred, conv,
111              ↳ *target[i], i, CLASSES=TRAIN_CLASSES)
112          giou_loss += loss_items[0]
113          conf_loss += loss_items[1]
114          prob_loss += loss_items[2]
115
116          total_loss = giou_loss + conf_loss + prob_loss
117
118          gradients = tape.gradient(total_loss,
119              ↳ yolo.trainable_variables)
120          optimizer.apply_gradients(zip(gradients,
121              ↳ yolo.trainable_variables))
122
123          # update learning rate
124          # about warmup:
125          ↳ https://arxiv.org/pdf/1812.01187.pdf&usg=AJ
126          ↳ LkJrhglKOPDjNt6SHGbphTHyMcT0cuMJg
127          global_steps.assign_add(1)
128          if global_steps < warmup_steps:# and not
129              ↳ TRAIN_TRANSFER:
130                  lr = global_steps / warmup_steps *
131                      ↳ TRAIN_LR_INIT
132          else:
133              lr = TRAIN_LR_END + 0.5 * (TRAIN_LR_INIT -
134                  ↳ TRAIN_LR_END)*(
135                  (1 + tf.cos((global_steps -
136                      ↳ warmup_steps) / (total_steps -
137                      ↳ warmup_steps) * np.pi)))
138          optimizer.lr.assign(lr.numpy())
139
140          # writing summary data
141          with writer.as_default():
142              tf.summary.scalar("lr", optimizer.lr,
143                  ↳ step=global_steps)
144              tf.summary.scalar("loss/total_loss",
145                  ↳ total_loss, step=global_steps)

```

```

133             tf.summary.scalar("loss/giou_loss",
134                         → giou_loss, step=global_steps)
135             tf.summary.scalar("loss/conf_loss",
136                         → conf_loss, step=global_steps)
137             tf.summary.scalar("loss/prob_loss",
138                         → prob_loss, step=global_steps)
139             writer.flush()
140
141     return global_steps.numpy(), optimizer.lr.numpy(),
142           → giou_loss.numpy(), conf_loss.numpy(),
143           → prob_loss.numpy(), total_loss.numpy()
144
145     validate_writer =
146         → tf.summary.create_file_writer(TRAIN_LOGDIR)
147     def validate_step(image_data, target):
148         with tf.GradientTape() as tape:
149             pred_result = yolo(image_data, training=False)
150             giou_loss=conf_loss=prob_loss=0
151
152             # optimizing process
153             grid = 3 if not TRAIN_YOLO_TINY else 2
154             for i in range(grid):
155                 conv, pred = pred_result[i*2],
156                     → pred_result[i*2+1]
157                 loss_items = compute_loss(pred, conv,
158                               → *target[i], i, CLASSES=TRAIN_CLASSES)
159                 giou_loss += loss_items[0]
160                 conf_loss += loss_items[1]
161                 prob_loss += loss_items[2]
162
163             total_loss = giou_loss + conf_loss + prob_loss
164
165     return giou_loss.numpy(), conf_loss.numpy(),
166           → prob_loss.numpy(), total_loss.numpy()
167
168     mAP_model = Create_Yolo(input_size=YOLO_INPUT_SIZE,
169                             → CLASSES=TRAIN_CLASSES) # create second model to
170                             → measure mAP
171
172     print("Start training!")
173     with tf.device('/device:GPU:1'):

```

```
163     best_val_loss = 1000 # should be large at start
164     for epoch in range(TRAIN_EPOCHS):
165         for image_data, target in trainset:
166             results = train_step(image_data, target)
167             cur_step = results[0]//steps_per_epoch
168             print("epoch:{:2.0f} step:{:5.0f}/{},
169                   lr:{:.6f}, giou_loss:{:7.2f},
170                   conf_loss:{:7.2f}, prob_loss:{:7.2f},
171                   total_loss:{:7.2f}"
172                   .format(epoch, cur_step,
173                           steps_per_epoch, results[1],
174                           results[2], results[3],
175                           results[4], results[5]))
176
177     if len(testset) == 0:
178         print("configure TEST options to validate
179               model")
180         yolo.save_weights(os.path.join(TRAIN_CHECKPOINT,
181                                     POINTS_FOLDER,
182                                     TRAIN_MODEL_NAME))
183         continue
184
185     print("Validating results...")
186     count, giou_val, conf_val, prob_val, total_val
187     = 0., 0, 0, 0, 0
188     for image_data, target in testset:
189         results = validate_step(image_data, target)
190         count += 1
191         giou_val += results[0]
192         conf_val += results[1]
193         prob_val += results[2]
194         total_val += results[3]
195     # writing validate summary data
196     with validate_writer.as_default():
197         tf.summary.scalar("validate_loss/total_val",
198                           total_val/count,
199                           step=epoch)
200         tf.summary.scalar("validate_loss/giou_val",
201                           giou_val/count,
202                           step=epoch)
```

```

189         tf.summary.scalar("validate_loss/conf_val" ]
190             , conf_val/count,
191             step=epoch)
192         tf.summary.scalar("validate_loss/prob_val" ]
193             , prob_val/count,
194             step=epoch)
195         validate_writer.flush()
196         file.write(str(epoch)+"."+str(giou_val/count)+]
197             , "+str(conf_val/count)+"+str(prob_val/c]
198             ount)+"+str(total_val/count)+"\n")
199         file.flush()
200
201         print("\n\ngiou_val_loss:{:7.2f},
202             conf_val_loss:{:7.2f},
203             prob_val_loss:{:7.2f},
204             total_val_loss:{:7.2f}\n\n".
205                 format(giou_val/count, conf_val/count,
206                     prob_val/count, total_val/count))
207
208         if TRAIN_SAVE_CHECKPOINT and not
209             TRAIN_SAVE_BEST_ONLY:
210             save_directory =
211                 os.path.join(TRAIN_CHECKPOINTS_FOLDER,
212                     TRAIN_MODEL_NAME+"_val_loss_{:7.2f}".f]
213                     ormat(total_val/count))
214             yolo.save_weights(save_directory)
215             print("Weights saved checkpoint!")
216         if TRAIN_SAVE_BEST_ONLY and
217             best_val_loss>total_val/count:
218             save_directory =
219                 os.path.join(TRAIN_CHECKPOINTS_FOLDER,
220                     TRAIN_MODEL_NAME)
221             yolo.save_weights(save_directory)
222             best_val_loss = total_val/count
223             print("Weights saved best checkpoint!")
224         if not TRAIN_SAVE_BEST_ONLY and not
225             TRAIN_SAVE_CHECKPOINT:
226             save_directory =
227                 os.path.join(TRAIN_CHECKPOINTS_FOLDER,
228                     TRAIN_MODEL_NAME)
229             yolo.save_weights(save_directory)

```

```
210     print("Weights saved!")
211     file.close()
212     # measure mAP of trained custom model
213     try:
214         mAP_model.load_weights(save_directory) # use keras
215             ↵ weights
216         get_mAP(mAP_model, testset,
217             ↵ score_threshold=TEST_SCORE_THRESHOLD,
218             ↵ iou_threshold=TEST_IOU_THRESHOLD)
219     except UnboundLocalError:
220         print("You don't have saved model weights to
221             ↵ measure mAP, check TRAIN_SAVE_BEST_ONLY and
222             ↵ TRAIN_SAVE_CHECKPOINT lines in configs.py")
223
224 if __name__ == '__main__':
225     main()
```

### C.3.6 detection\_demo.py

```

1 #=====
2 #=====]
3 #
4 # File name : detection_demo.py
5 # Author : PyLessons
6 # Created date: 2020-09-27
7 # Website : https://pylessons.com/
8 # GitHub :
9 # Description : object detection image and video example
10 # Modified by : Virginia Ramón
11 #=====]
12 #
13 import os
14 os.environ['CUDA_VISIBLE_DEVICES'] = '0'
15 import cv2
16 import numpy as np
17 import tensorflow as tf
18 physical_devices = tf.config.list_physical_devices('GPU')
19 for gpu_instance in physical_devices:
20     tf.config.experimental.set_memory_growth(gpu_instance,
21         True)
22 from yolov3.utils import detect_image, detect_realtime,
23     detect_video, Load_Yolo_model, detect_video_realtime_mp
24 from yolov3.configs import *
25
26 # Define if want to detect image or video
27 img = False
28
29 # Load model
30 yolo = Load_Yolo_model()
31
32 # Image detection
33 if img:
34     image_path = "/home/virginia/TFG/PIGDATA2/frames/GH0_"
35         "10013_zenital_Val_2220.jpg"
36     image_out_path =
37         "./IMAGES/GH010013_zenital_Val_pred_05.jpg"

```

```
32     _, data, classes = detect_image(yolo, image_path,
33         ↳ image_out_path, input_size=YOLO_INPUT_SIZE,
34         ↳ show=False, score_threshold=0.5,
35         ↳ rectangle_colors=(255,0,0))
36
37
38
39
40
41
42
43
44
45
46
47
48
49
50
51
52
53
54
55
56
57
58
59
60
61
62
63
```

```
    # Data to txt
    datafile = []
    fr = str(data[0])
    bbxs = ""
    for bb in data[1]:
        pos = str(bb[0])+"," +str(bb[1])+"," +str(bb[2])+"," +
              ↳ +str(bb[3])+"," +str(bb[5]))
        bbxs= bbxs + " " + pos
    datafile = fr+" "+bbxs+"\n"

    file = open("./IMAGES/pred_img.txt", 'w')
    file.write(datafile)
    file.close()
    print("Image detection ended")

# Video detection
else:
    video_path    = "/home/virginia/TFG/PIGDATA/annotated/2_"
    ↳ 019_12_10/000078/color_mask.mp4"
    video_out_path = "./IMAGES/000078_color_mask_pred.mp4"
    data, classes = detect_video(yolo, video_path,
        ↳ video_out_path, input_size=YOLO_INPUT_SIZE,
        ↳ show=False, score_threshold=0.5,
        ↳ rectangle_colors=(255,0,0))

    # Data to txt
    datafile = []
    for frame in data:
        fr = str(frame[1])
        bbxs = ""
        for bb in frame[2]:
            pos = str(bb[0])+"," +str(bb[1])+"," +str(bb[2])+",
                  ↳ +"," +str(bb[3])+"," +str(bb[5]))
            bbxs= bbxs + " " + pos
        datafile.append(fr+" "+bbxs)

    file = open("./IMAGES/pred_video.txt", 'w')
```

```
64     for d in datafile:  
65         file.write(d+"\n")  
66     file.close()  
67     print("Video detection ended")
```

### C.3.7 evaluate\_mAP.py

```
1 #===== ]  
2 #  
3 #     File name    : evaluate_mAP.py  
4 #     Author       : PyLessons  
5 #     Created date: 2020-08-17  
6 #     Website      : https://pylessons.com/  
7 #     GitHub       :  
8 #         ↳ https://github.com/pythonlessons/TensorFlow-2.x-YOLOv3  
9 #     Description  : used to evaluate model mAP and FPS  
10 #  
11 import os  
12 os.environ['CUDA_VISIBLE_DEVICES'] = '0'  
13 import cv2  
14 import numpy as np  
15 import tensorflow as tf  
16 from tensorflow.python.saved_model import tag_constants  
17 from yolov3.dataset import Dataset  
18 from yolov3.yolov4 import Create_Yolo  
19 from yolov3.utils import load_yolo_weights, detect_image,  
20     ↳ image_preprocess, postprocess_boxes, nms,  
21     ↳ read_class_names  
22 from yolov3.configs import *  
23 import shutil  
24 import json  
25 import time  
26 gpus = tf.config.experimental.list_physical_devices('GPU')  
27 if len(gpus) > 0:  
28     try: tf.config.experimental.set_memory_growth(gpus[0],  
29             ↳ True)  
30     except RuntimeError: print("RuntimeError in tf.config. ]  
31     ↳ experimental.list_physical_devices('GPU'))  
32  
33 def voc_ap(rec, prec):  
34     """
```

```

33  --- Official matlab code VOC2012---
34  mrec=[0 ; rec ; 1];
35  mpre=[0 ; prec ; 0];
36  for i=numel(mpre)-1:-1:1
37      mpre(i)=max(mpre(i),mpre(i+1));
38  end
39  i=find(mrec(2:end)~=mrec(1:end-1))+1;
40  ap=sum((mrec(i)-mrec(i-1)).*mpre(i));
41  """
42  rec.insert(0, 0.0) # insert 0.0 at begining of list
43  rec.append(1.0) # insert 1.0 at end of list
44  mrec = rec[:]
45  prec.insert(0, 0.0) # insert 0.0 at begining of list
46  prec.append(0.0) # insert 0.0 at end of list
47  mpre = prec[:]
48  """
49  This part makes the precision monotonically decreasing
50  (goes from the end to the beginning)
51  matlab: for i=numel(mpre)-1:-1:1
52
53  → mpre(i)=max(mpre(i),mpre(i+1));
54  """
55  # matlab indexes start in 1 but python in 0, so I have
56  # to do:
57  # range(start=(len(mpre) - 2), end=0, step=-1)
58  # also the python function range excludes the end,
59  # resulting in:
60  # range(start=(len(mpre) - 2), end=-1, step=-1)
61  for i in range(len(mpre)-2, -1, -1):
62      mpre[i] = max(mpre[i], mpre[i+1])
63  """
64  This part creates a list of indexes where the recall
65  changes
66  matlab: i=find(mrec(2:end)~=mrec(1:end-1))+1;
67  """
68  i_list = []
69  for i in range(1, len(mrec)):
70      if mrec[i] != mrec[i-1]:
71          i_list.append(i) # if it was matlab would be i
72          → + 1
73  """

```

```

69     The Average Precision (AP) is the area under the curve
70         (numerical integration)
71         matlab: ap=sum((mrec(i)-mrec(i-1)).*mpre(i));
72         """
73         ap = 0.0
74         for i in i_list:
75             ap += ((mrec[i]-mrec[i-1])*mpre[i])
76         return ap, mrec, mpre
77
78
79 def get_mAP(Yolo, dataset, score_threshold=0.4,
80             iou_threshold=0.4, TEST_INPUT_SIZE=TEST_INPUT_SIZE):
81     MINOVERLAP = 0.5 # default value (defined in the
82                       PASCAL VOC2012 challenge)
83     NUM_CLASS = read_class_names(TRAIN_CLASSES)
84
85     ground_truth_dir_path = 'mAP/ground-truth'
86     if os.path.exists(ground_truth_dir_path):
87         shutil.rmtree(ground_truth_dir_path)
88
89     print(f'\nCalculating
90           mAP{int(iou_threshold*100)}...\n')
91
92     gt_counter_per_class = {}
93     for index in range(dataset.num_samples):
94         print(index)
95         ann_dataset = dataset.annotations[index]
96
97         original_image, bbox_data_gt =
98             dataset.parse_annotation(ann_dataset, True)
99
100        if len(bbox_data_gt) == 0:
101            bboxes_gt = []
102            classes_gt = []
103        else:
104            bboxes_gt, classes_gt = bbox_data_gt[:, :4],
105            bbox_data_gt[:, 4]

```

```

103     ground_truth_path =
104         → os.path.join(ground_truth_dir_path, str(index)
105             → + '.txt')
106     num_bbox_gt = len(bboxes_gt)
107
108     bounding_boxes = []
109     for i in range(num_bbox_gt):
110         class_name = NUM_CLASS[classes_gt[i]]
111         xmin, ymin, xmax, ymax = list(map(str,
112             → bboxes_gt[i]))
113         bbox = xmin + " " + ymin + " " + xmax + " "
114             → +ymax
115         bounding_boxes.append({"class_name":class_name,
116             → , "bbox":bbox,
117             → "used":False})
118
119         # count that object
120         if class_name in gt_counter_per_class:
121             gt_counter_per_class[class_name] += 1
122         else:
123             # if class didn't exist yet
124             gt_counter_per_class[class_name] = 1
125             bbox_mess = ' '.join([class_name, xmin, ymin,
126                 → xmax, ymax]) + '\n'
127             with open(f'{ground_truth_dir_path}/{str(index)}_g',
128                 → round_truth.json', 'w') as
129                 → outfile:
130                     json.dump(bounding_boxes, outfile)
131
132             gt_classes = list(gt_counter_per_class.keys())
133             # sort the classes alphabetically
134             gt_classes = sorted(gt_classes)
135             n_classes = len(gt_classes)
136
137             times = []
138             json_pred = [[] for i in range(n_classes)]
139             for index in range(dataset.num_samples):
140                 ann_dataset = dataset.annotations[index]
141
142                 image_name = ann_dataset[0].split('/')[-1]

```

```
134     original_image, bbox_data_gt =
135         ↵ dataset.parse_annotation(ann_dataset, True)
136
136     image = image_preprocess(np.copy(original_image),
137         ↵ [TEST_INPUT_SIZE, TEST_INPUT_SIZE])
137     image_data = image[np.newaxis,
138         ↵ ...].astype(np.float32)
138
139     t1 = time.time()
140     if YOLO_FRAMEWORK == "tf":
141         pred_bbox = Yolo.predict(image_data)
142     elif YOLO_FRAMEWORK == "trt":
143         batched_input = tf.constant(image_data)
144         result = Yolo(batched_input)
145         pred_bbox = []
146         for key, value in result.items():
147             value = value.numpy()
148             pred_bbox.append(value)
149
150     t2 = time.time()
151
152     times.append(t2-t1)
153
154     pred_bbox = [tf.reshape(x, (-1, tf.shape(x)[-1]))
155         ↵ for x in pred_bbox]
155     pred_bbox = tf.concat(pred_bbox, axis=0)
156
157     bboxes = postprocess_boxes(pred_bbox,
158         ↵ original_image, TEST_INPUT_SIZE,
159         ↵ score_threshold)
158     bboxes = nms(bboxes, iou_threshold, method='nms')
159
160     for bbox in bboxes:
161         coor = np.array(bbox[:4], dtype=np.int32)
162         score = bbox[4]
163         class_ind = int(bbox[5])
164         class_name = NUM_CLASS[class_ind]
165         score = '%.4f' % score
166         xmin, ymin, xmax, ymax = list(map(str, coor))
167         bbox = xmin + " " + ymin + " " + xmax + " "
168             ↵ +ymax
```

```
168     json_pred[gt_classes.index(class_name)].append([
169         {"confidence": str(score), "file_id":
170             str(index), "bbox": str(bbox)})]
171
172
173     for class_name in gt_classes:
174         json_pred[gt_classes.index(class_name)].sort(key=lambda x:float(x['confidence']),
175             reverse=True)
176         with open(f'{ground_truth_dir_path}/{class_name}_predictions.json', 'w') as
177             outfile:
178             json.dump(json_pred[gt_classes.index(class_name)], e),
179             outfile)
180
181     # Calculate the AP for each class
182     sum_AP = 0.0
183     ap_dictionary = {}
184     # open file to store the results
185     with open("mAP/results.txt", 'w') as results_file:
186         results_file.write("# AP and precision/recall per
187             class\n")
188         count_true_positives = {}
189         for class_index, class_name in
190             enumerate(gt_classes):
191             count_true_positives[class_name] = 0
192             # Load predictions of that class
193             predictions_file = f'{ground_truth_dir_path}/{class_name}_predictions.json'
194             predictions_data =
195                 json.load(open(predictions_file))
196
197             # Assign predictions to ground truth objects
198             nd = len(predictions_data)
199             tp = [0] * nd # creates an array of zeros of
200                 size nd
201             fp = [0] * nd
202             tp_count = 0
```

```

196
197     fp_count = 0
198
199     for idx, prediction in
200         ↳ enumerate(predictions_data):
201             file_id = prediction["file_id"]
202             # assign prediction to ground truth object
203             ↳ if any
204             # open ground-truth with that file_id
205             gt_file = f'{ground_truth_dir_path}/{str(f)}_ground_truth.json'
206             ground_truth_data =
207                 ↳ json.load(open(gt_file))
208             ovmax = -1
209             gt_match = -1
210             # load prediction bounding-box
211             bb = [ float(x) for x in
212                 ↳ prediction["bbox"].split() ] #
213                 ↳ bounding box of prediction
214             for obj in ground_truth_data:
215                 # look for a class_name match
216                 if obj["class_name"] == class_name:
217                     bbgt = [ float(x) for x in
218                         ↳ obj["bbox"].split() ] #
219                         ↳ bounding box of ground truth
220                     bi = [ max(bb[0],bbgt[0]),
221                         ↳ max(bb[1],bbgt[1]),
222                         ↳ min(bb[2],bbgt[2]),
223                         ↳ min(bb[3],bbgt[3]) ]
224                     iw = bi[2] - bi[0] + 1
225                     ih = bi[3] - bi[1] + 1
226                     if iw > 0 and ih > 0:
227                         # compute overlap (IoU) = area
228                             ↳ of intersection / area of
229                             ↳ union
230                         ua = (bb[2] - bb[0] + 1) *
231                             ↳ (bb[3] - bb[1] + 1) +
232                             ↳ (bbgt[2] - bbgt[0]
233                                 + 1) *
234                                 ↳ (bbgt[3] -
235                                     ↳ bbgt[1] +
236                                     ↳ 1) - iw *
237                                     ↳ ih

```

```

218                     ov = iw * ih / ua
219                     if ov > ovmax:
220                         ovmax = ov
221                         gt_match = obj
222
223             # assign prediction as true positive/don't
224             # care/false positive
224             if ovmax >= MINOVERLAP:# if ovmax >
225                 # minimum overlap
225                 if not bool(gt_match["used"]):
226                     # true positive
227                     tp[idx] = 1
228                     tp_count += 1
229                     gt_match["used"] = True
230                     count_true_positives[class_name]
231                     += 1
232             # update the ".json" file
232             with open(gt_file, 'w') as f:
233                 f.write(json.dumps(ground_truth,
234                                     indent=4))
234
235             else:
236                 # false positive (multiple
236                 # detection)
236                 fp[idx] = 1
237                 fp_count += 1
238
239             else:
240                 # false positive
241                 fp[idx] = 1
241                 fp_count += 1
242
243             # compute precision/recall
244             cumsum = 0
245
246             for idx, val in enumerate(fp):
247                 fp[idx] += cumsum
248                 cumsum += val
249             cumsum = 0
250             for idx, val in enumerate(tp):
251                 tp[idx] += cumsum
252                 cumsum += val
253             #print(tp)

```

```

254         rec = tp[:]
255         for idx, val in enumerate(tp):
256             rec[idx] = float(tp[idx]) /
257                         ↳ gt_counter_per_class[class_name]
258             #print(rec)
259             prec = tp[:]
260             for idx, val in enumerate(tp):
261                 prec[idx] = float(tp[idx]) / (fp[idx] +
262                         ↳ tp[idx])
263             #print(prec)
264
265             ap, mrec, mprec = voc_ap(rec, prec)
266             sum_AP += ap
267             text = "{0:.3f}%".format(ap*100) + " = " +
268                         ↳ class_name + " AP " #class_name + " AP =
269                         ↳ {0:.2f}%".format(ap*100)
270
271             rounded_prec = [ '%.3f' % elem for elem in prec
272                             ↳ ]
273             rounded_rec = [ '%.3f' % elem for elem in rec ]
274             # Write to results.txt
275             results_file.write(text + "\n Precision: " +
276                         ↳ str(rounded_prec) + "\n Recall    :" +
277                         ↳ str(rounded_rec) + "\n\n")
278
279             print(text)
280             print("{0:.1f}".format(tp_count) + " = " +
281                         ↳ class_name + " TP ")
282             print("{0:.1f}".format(fp_count) + " = " +
283                         ↳ class_name + " FP ")
284             ap_dictionary[class_name] = ap
285
286             results_file.write("\n# mAP of all classes\n")
287             mAP = sum_AP / n_classes
288
289             text = "mAP = {:.3f}%, {:.2f} FPS".format(mAP*100,
290                         ↳ fps)
291             results_file.write(text + "\n")
292             print(text)
293
294             return mAP*100

```

```
285
286 if __name__ == '__main__':
287     if YOLO_FRAMEWORK == "tf": # TensorFlow detection
288         if YOLO_TYPE == "yolov4":
289             Darknet_weights = YOLO_V4_TINY_WEIGHTS if
290                 ~ TRAIN_YOLO_TINY else YOLO_V4_WEIGHTS
291         if YOLO_TYPE == "yolov3":
292             Darknet_weights = YOLO_V3_TINY_WEIGHTS if
293                 ~ TRAIN_YOLO_TINY else YOLO_V3_WEIGHTS
294
295         if YOLO_CUSTOM_WEIGHTS == False:
296             yolo = Create_Yolo(input_size=YOLO_INPUT_SIZE,
297                 ~ CLASSES=YOLO_COCO_CLASSES)
298             load_yolo_weights(yolo, Darknet_weights) # use
299                 ~ Darknet weights
300         else:
301             yolo = Create_Yolo(input_size=YOLO_INPUT_SIZE,
302                 ~ CLASSES=TRAIN_CLASSES)
303             yolo.load_weights(f"./checkpoints/yolov4_PigPe_"
304                 ~ rsv5/{TRAIN_MODEL_NAME}") # use custom
305                 ~ weights
306
307         elif YOLO_FRAMEWORK == "trt": # TensorRT detection
308             saved_model_loaded = tf.saved_model.load(f"./check_"
309                 ~ points/{TRAIN_MODEL_NAME}",
310                 ~ tags=[tag_constants.SERVING])
311             signature_keys =
312                 ~ list(saved_model_loaded.signatures.keys())
313             yolo = saved_model_loaded.signatures['serving_defa_'
314                 ~ ult']
315
316             testset = Dataset('test',
317                 ~ TEST_INPUT_SIZE=YOLO_INPUT_SIZE)
318             get_mAP(yolo, testset, score_threshold=0.4,
319                 ~ iou_threshold=0.4, TEST_INPUT_SIZE=YOLO_INPUT_SIZE)
```

### C.3.8 mAPtest.py

```
1 import os
2 os.environ['CUDA_VISIBLE_DEVICES'] = '0,1'
3 os.environ['TF_FORCE_GPU_ALLOW_GROWTH'] = 'true'
4 from tensorflow.python.client import device_lib
5 #print(device_lib.list_local_devices())
6 import shutil
7 import numpy as np
8 import tensorflow as tf
9 #gpu_options = tf.compat.v1.GPUOptions(per_process_gpu_memory_fraction=0.9)
10 #sess = tf.compat.v1.Session(config=tf.compat.v1.ConfigProto()
11 #                             .gpu_options=gpu_options))
12 #from tensorflow.keras.utils import plot_model
13 config = tf.compat.v1.ConfigProto()
14 config.gpu_options.allow_growth = True
15 session = tf.compat.v1.Session(config=config)
16 from yolov3.dataset import Dataset
17 from yolov3.yolov4 import Create_Yolo, compute_loss
18 from yolov3.utils import load_yolo_weights
19 from yolov3.configs import *
20 from evaluate_mAP import get_mAP
21
22 #Allow memory growth in GPUs
23 gpus = tf.config.experimental.list_physical_devices('GPU')
24 for gpu in gpus:
25     tf.config.experimental.set_memory_growth(gpu, True)
26
27 print("Reading test dataset...")
28 testset = Dataset('test')
29
30 save_directory = os.path.join(TRAIN_CHECKPOINTS_FOLDER,
31                               TRAIN_MODEL_NAME)
32
33 print("Creating model...")
34 mAP_model = Create_Yolo(input_size=YOLO_INPUT_SIZE,
35                         CLASSES=TRAIN_CLASSES) # create second model to
36                         measure mAP
37
38 try:
```

```
35     mAP_model.load_weights(save_directory) # use keras
      ↵   weights
36     print("Calculating mAP...")
37     get_mAP(mAP_model, testset,
      ↵   score_threshold=TEST_SCORE_THRESHOLD,
      ↵   iou_threshold=TEST_IOU_THRESHOLD)
38 except UnboundLocalError:
39     print("You don't have saved model weights to
      ↵   measure mAP, check TRAIN_SAVE_BEST_ONLY and
      ↵   TRAIN_SAVE_CHECKPOINT lines in configs.py")
```

40

## D.4 Codi UKF

### D.4.1 ukf.py

```

1  """
2      File name      : ukf.py
3      Author         : Srinivas Ananthakrishnan
4      Python Version : 2.7
5  """
6
7 import numpy as np
8 import scipy.linalg
9 from copy import deepcopy
10 from threading import Lock
11
12
13 class UKFException(Exception):
14     """Raise for errors in the UKF, usually due to bad
15        inputs"""
16
17 class UKF:
18     def __init__(self, initial_state):#iterate_function):
19         """
20             Initializes the unscented kalman filter
21             :param num_states: int, the size of the state
22             :param process_noise: the process noise covariance
23             ← per unit time, should be num_states x num_states
24             :param initial_state: initial values for the
25             ← states, should be num_states x 1
26             :param initial_covar: initial covariance matrix,
27             ← should be num_states x num_states, typically large and
28             ← diagonal
29             :param alpha: UKF tuning parameter, determines
30             ← spread of sigma points, typically a small positive
31             ← value
32             :param k: UKF tuning parameter, typically 0 or 3 -
33             ← num_states
34             :param beta: UKF tuning parameter, beta = 2 is
35             ← ideal for gaussian distributions

```

---

```

28         :param iterate_function: function that predicts
29             ↵ the next state
30                     takes in a num_states x 1 state and a
31             ↵ float timestep
32                     returns a num_states x 1 state
33             """
34             num_states=6
35             self.n_dim = int(num_states)
36             #self.n_sig = 1 + num_states * 2
37             self.n_sig = 2 * num_states + 1
38             #self.q = process_noise
39             self.q = np.eye(6)
40             # ----- MODIFIED BY
41             ↵ VIRGINIA RAMÓN -----
42             self.q[0][0] = 0.01
43             self.q[1][1] = 0.01
44             self.q[2][2] = 0.01
45             self.q[3][3] = 0.01
46             self.q[4][4] = 0.01
47             self.q[5][5] = 0.01
48
49             #self.x = initial_state
50             self.x = np.array([initial_state[0],initial_state[
51                 ↵ 1],0.5,0.5,0.5,0.5])
52             self.p = 0.1*np.diag((1.0, 1.0, 1.0, 1.0, 1.0,
53                 ↵ 1.0))
54             self.beta = 2
55             self.alpha = 0.04
56             self.k = 0
57             #self.iterate = iterate_function
58             self.lastResult = np.array([[0],
59                 ↵ [255],[0],[0],[0],[0]])
60             self.lambd = pow(self.alpha, 2) * (self.n_dim +
61                 ↵ self.k) - self.n_dim
62
63             self.covar_weights = np.zeros(self.n_sig)
64             self.mean_weights = np.zeros(self.n_sig)
65
66             self.covar_weights[0] = (self.lambd / (self.n_dim
67                 ↵ + self.lambd)) + (1 - pow(self.alpha, 2) +
68                 ↵ self.beta)

```

```

60         self.mean_weights[0] = (self.lambd / (self.n_dim +
61                                     ↵ self.lambd))
62
63     for i in range(1, self.n_sig):
64         self.covar_weights[i] = 1 / (2*(self.n_dim +
65                                     ↵ self.lambd))
66         self.mean_weights[i] = 1 / (2*(self.n_dim +
67                                     ↵ self.lambd))
68
69     self.sigmas = self.__get_sigmas()
70
71     self.lock = Lock()
72
73 def iterate_x(self,x_in, timestep):
74     '''this function is based on the x_dot and can be
75     ↵ nonlinear as needed'''
76     ret = np.zeros(len(x_in))
77     ret[0] = x_in[0] + timestep * x_in[2] + timestep *
78             ↵ timestep * x_in[4]
79     ret[1] = x_in[1] + timestep * x_in[3] + timestep *
80             ↵ timestep * x_in[5]
81     ret[2] = x_in[2] + timestep * x_in[4]
82     ret[3] = x_in[3] + timestep * x_in[5]
83     ret[4] = x_in[4]
84     ret[5] = x_in[5]
85     return ret
86
87 def __get_sigmas(self):
88     """generates sigma points"""
89     ret = np.zeros((self.n_sig, self.n_dim))
90
91     tmp_mat = (self.n_dim + self.lambd)*self.p
92
93     # print spr_mat
94     spr_mat = scipy.linalg.sqrtm(tmp_mat)
95
96     ret[0] = self.x
97     for i in range(self.n_dim):
98         ret[i+1] = np.ravel(self.x) + spr_mat[i]
99         ret[i+1+self.n_dim] = np.ravel(self.x) -
100            ↵ spr_mat[i]

```

```
94         return ret.T
95
96
97     def update(self, states, data, flag, r_matrix):
98         """
99             performs a measurement update
100             :param states: list of indices (zero-indexed) of
101                 which states were measured, that is, which are being
102                 updated
103             :param data: list of the data corresponding to the
104                 values in states
105             :param r_matrix: error matrix for the data, again
106                 corresponding to the values in states
107             """
108
109         if not flag:
110             data = np.array([self.lastResult[states]])
111             #print('Not detected, data is: ', data)
112
113         self.lock.acquire()
114
115         num_states = len(states)
116
117         # create y, sigmas of just the states that are
118             # being updated
119         sigmas_split = np.split(self.sigmas, self.n_dim)
120         y = np.concatenate([sigmas_split[i] for i in
121             states])
122
123         # create y_mean, the mean of just the states that
124             # are being updated
125         x_split = np.split(self.x, self.n_dim)
126         y_mean = np.concatenate([x_split[i] for i in
127             states])
128
129         # differences in y from y mean
130         y_diff = deepcopy(y)
131         x_diff = deepcopy(self.sigmas)
132         for i in range(self.n_sig):
133             for j in range(num_states):
134                 y_diff[j][i] -= y_mean[j]
135             for j in range(self.n_dim):
```

```

127         x_diff[j][i] -= self.x[j]
128
129     # covariance of measurement
130     p_yy = np.zeros((num_states, num_states))
131     for i, val in enumerate(np.array_split(y_diff,
132                             self.n_sig, 1)):
133         p_yy += self.covar_weights[i] * val.dot(val.T)
134
135     # add measurement noise
136     p_yy += r_matrix
137
138     # covariance of measurement with states
139     p_xy = np.zeros((self.n_dim, num_states))
140     for i, val in enumerate(zip(np.array_split(y_diff,
141                             self.n_sig, 1), np.array_split(x_diff,
142                             self.n_sig, 1))):
143         p_xy += self.covar_weights[i] *
144             val[1].dot(val[0].T)
145
146     k = np.dot(p_xy, np.linalg.inv(p_yy))
147
148     y_actual = np.ravel(data)
149
150     self.x += np.dot(k, (y_actual - y_mean))
151     self.p -= np.dot(k, np.dot(p_yy, k.T))
152     self.sigmas = self.__get_sigmas()
153     self.lastResult = self.x
154     self.lock.release()
155
156     """
157     def update(self, data, flag, r_matrix):
158         """
159             performs a measurement update
160             :param states: list of indices (zero-indexed) of
161             which states were measured, that is, which are being
162             updated
163                 :param data: list of the data corresponding to the
164                 values in states
165                 :param r_matrix: error matrix for the data, again
166                 corresponding to the values in states
167             """

```

```
160
161     self.lock.acquire()
162     if not flag:
163         data = np.array([self.lastResult])
164         #num_states = len(states)
165
166         # create y, sigmas of just the states that are
167         # being updated
168         sigmas_split = np.split(self.sigmas, self.n_dim)
169         #y = np.concatenate([sigmas_split[i] for i in
170         #states])
171         y = sigmas_split
172
173         # create y_mean, the mean of just the states that
174         # are being updated
175         x_split = np.split(self.x, self.n_dim)
176         y_mean = x_split
177
178         # differences in y from y mean
179         y_diff = deepcopy(y)
180         x_diff = deepcopy(self.sigmas)
181         for i in range(self.n_sig):
182             for j in range(self.n_dim):
183                 y_diff[j][i] -= y_mean[j]
184             for j in range(self.n_dim):
185                 x_diff[j][i] -= self.x[j]
186
187         # covariance of measurement
188         p_yy = np.zeros(self.n_dim, self.n_dim)
189         for i, val in enumerate(np.array_split(y_diff,
190             self.n_sig, 1)):
191             p_yy += self.covar_weights[i] * val.dot(val.T)
192
193         # add measurement noise
194         p_yy += r_matrix
195
196         # covariance of measurement with states
197         p_xy = np.zeros((self.n_dim, self.n_dim))
198         for i, val in enumerate(zip(np.array_split(y_diff,
199             self.n_sig, 1), np.array_split(x_diff, self.n_sig,
200             1))):
```

```

195             p_xy += self.covar_weights[i] *
196             ↵ val[1].dot(val[0].T)
197
198             k = np.dot(p_xy, np.linalg.inv(p_yy))
199
200             y_actual = data
201
202             self.x += np.dot(k, (y_actual - y_mean))
203             self.p -= np.dot(k, np.dot(p_yy, k.T))
204             self.sigmas = self._get_sigmas()
205             print('r_matrix : ', r_matrix)
206
207             self.lock.release()
208             """
209
210     def predict(self, timestep):
211         """
212             performs a prediction step
213             :param timestep: float, amount of time since last
214             prediction
215             """
216
217             self.lock.acquire()
218             #print("x- shape: ",self.x.shape)
219             sigmas_out = np.array([self.iterate_x(x,timestep)
220             ↵ for x in self.sigmas.T]).T
221
222             x_out = np.zeros(self.n_dim)
223
224             # for each variable in X
225             for i in range(self.n_dim):
226                 # the mean of that variable is the sum of
227                 # the weighted values of that variable for
228                 # each iterated sigma point
229                 x_out[i] = sum((self.mean_weights[j] *
230                 ↵ sigmas_out[i][j] for j in
231                 ↵ range(self.n_sig)))
232
233             p_out = np.zeros((self.n_dim, self.n_dim))
234             # for each sigma point
235             for i in range(self.n_sig):
236                 # take the distance from the mean

```

```
230         # make it a covariance by multiplying by the
231         # transpose
232         # weight it using the calculated weighting
233         # and sum
234         diff = sigmas_out.T[i] - x_out
235         diff = np.atleast_2d(diff)
236         p_out += self.covar_weights[i] *
237             np.dot(diff.T, diff)
238
239         # add process noise
240         #p_out += timestep * self.q
241         p_out += self.q
242
243         self.sigmas = sigmas_out
244         self.x = x_out
245         self.p = p_out
246         self.lastResult = self.x
247         self.lock.release()
248
249     def get_state(self, index=-1):
250         """
251             returns the current state (n_dim x 1), or a
252             particular state variable (float)
253             :param index: optional, if provided, the index of
254             the returned variable
255             :return:
256             """
257             if index >= 0:
258                 return self.x[index]
259             else:
260                 return self.x
261
262     def get_covar(self):
263         """
264             :return: current state covariance (n_dim x n_dim)
265             """
266             return self.p
267
268     def set_state(self, value, index=-1):
269         """
```

```
266         Overrides the filter by setting one variable of
267         ↳ the state or the whole state
268             :param value: the value to put into the state (1 x
269             ↳ 1 or n_dim x 1)
270                 :param index: the index at which to override the
271                 ↳ state (-1 for whole state)
272                     """
273
274     with self.lock:
275         if index != -1:
276             self.x[index] = value
277         else:
278             self.x = value
279
280
281 def reset(self, state, covar):
282     """
283     Restarts the UKF at the given state and covariance
284     :param state: n_dim x 1
285     :param covar: n_dim x n_dim
286     """
287
288
289     with self.lock:
290         self.x = state
291         self.p = covar
```

### D.4.2 tracker.py

```
1 """
2     File name          : tracker.py
3     File Description   : Tracker Using Kalman Filter &
4     ↳ Hungarian Algorithm
5     Author            : Srinivas Ananthakrishnan
6     Date created      : 07/14/2017
7     Date last modified: 07/16/2017
8     Python Version    : 2.7
9
10 # Import python libraries
11 import numpy as np
12 from kalman_filter_backup import KalmanFilter
13 from common import dprint
14 from scipy.optimize import linear_sum_assignment
15 from ukf import UKF
16 import time
17 import cv2
18 class Track(object):
19     """Track class for every object to be tracked
20     Attributes:
21         None
22     """
23
24     def __init__(self, prediction, trackIdCount):
25         """Initialize variables used by Track class
26         Args:
27             prediction: predicted centroids of object to
28             ↳ be tracked
29             trackIdCount: identification of each track
30             ↳ object
31         Return:
32             None
33             """
34             self.track_id = trackIdCount # identification of
35             ↳ each track object
36             self.KF = UKF(prediction), self.iterate_x) # KF
37             ↳ instance to track this object
```

```

34         self.prediction = np.asarray(prediction) #  
35             ↳ predicted centroids (x,y)  
36         self.skipped_frames = 0 # number of frames  
37             ↳ skipped undetected  
38         self.trace = [] # trace path  
39             #-----ADDED BY VIRGINIA  
40             ↳ RAMÓN-----  
41     self.bbox = []  
42     self.obj_class = None  
43  
44  
45  
46  
47     class Tracker(object):  
48         """Tracker class that updates track vectors of object  
49             ↳ tracked  
50         Attributes:  
51             None  
52         """  
53  
54         def __init__(self, dist_thresh, max_frames_to_skip,  
55             ↳ max_trace_length,  
56                 trackIdCount):  
57             """Initialize variable used by Tracker class  
58             Args:  
59                 dist_thresh: distance threshold. When exceeds  
60                     ↳ the threshold,  
61                         track will be deleted and new  
62                     ↳ track is created  
63                         max_frames_to_skip: maximum allowed frames to  
64                     ↳ be skipped for  
65                         the track object undetected  
66                         max_trace_lenght: trace path history length  
67                         trackIdCount: identification of each track  
68             ↳ object  
69             Return:  
70                 None  
71             """  
72             self.dist_thresh = dist_thresh  
73             self.max_frames_to_skip = max_frames_to_skip  
74             self.max_trace_length = max_trace_length  
75             self.tracks = []  
76             self.trackIdCount = trackIdCount  
77             self.ls=[]

```

```
66         self.r = [2.5]
67     def Update(self, detections, bboxes, flag):
68         """Update tracks vector using following steps:
69             - Create tracks if no tracks vector found
70             - Calculate cost using sum of square distance
71                 between predicted vs detected centroids
72             - Using Hungarian Algorithm assign the correct
73                 detected measurements to predicted tracks
74
75         ↵ https://en.wikipedia.org/wiki/Hungarian_algorithm
76             - Identify tracks with no assignment, if any
77             - If tracks are not detected for long time,
78         ↵ remove them
79             - Now look for un_assigned detects
80             - Start new tracks
81             - Update KalmanFilter state, lastResults and
82         ↵ tracks trace
83         Args:
84             detections: detected centroids of object to be
85         ↵ tracked
86             bboxes: detected bounding boxes
87         Return:
88             None
89             *****
90             assignment = []
91
92             if flag==1:
93                 # Create tracks if no tracks vector found
94                 if (len(self.tracks) == 0):
95                     for i in range(len(detections)):
96                         #print('detections : ',detections)
97                         track = Track(detections[i],
98                             ↵ self.trackIdCount)
99                         # ----- ADDED BY
100                         ↵ VIRGINIA RAMÓN
101                         ↵ -----
102                         track.bbox.append(bboxes[i])
103                         track.obj_class = bboxes[i][4]
104                         self.trackIdCount += 1
105                         self.tracks.append(track)
```

```

100      # Calculate cost using sum of square distance
101      # between
102      # predicted vs detected centroids
103      N = len(self.tracks)
104      M = len(detections)
105      cost = np.zeros(shape=(N, M))    # Cost matrix
106      #print ('N: ',N)
107      #print('M: ',M)

108      for i in range(len(self.tracks)):
109          for j in range(len(detections)):
110              try:
111                  # diff1 = np.subtract(self.tracks[,
112                  # i].prediction[0] ,
113                  # detections[j][0])
114                  # diff2 = np.subtract(self.tracks[,
115                  # i].prediction[1] ,
116                  # detections[j][1])
117                  # diff=np.array([[diff1],[diff2]])
118                  # distance =
119                  # np.sqrt(diff[0][0]*diff[0][0] +
120                  #         # diff[1][0]
121                  #         # ]*diff[,
122                  #         # 1][0]))
123
124      # ----- ADDED BY
125      # VIRGINIA RAMÓN
126      #
127      # IoU: Get IoU of each BBox
128      # (1-IoU) because we use
129      # Hungarian Algorithm to assign
130      # weights
131      cost[i][j] =
132          1.0-bb_intersection_over_union(
133          (self.tracks[i].bbox[-1],
134          bboxes[j],
135          self.tracks[i].obj_class))
136
137      #print("differerce:
138      #     ",diff,"prediction: ",self.tr,
139      #     cks[i].prediction,"detections:
140      #     ",detections[j])

```

```
120             #print("cost: i: ",i," j: ",j,:  
121             ↵   ",cost[i][j])  
122         except:  
123             pass  
124  
125         # Using Hungarian Algorithm assign the correct  
126             ↵ detected measurements  
127         # to predicted tracks  
128         #print(cost)  
129         for _ in range(N):  
130             assignment.append(-1)  
131         row_ind, col_ind = linear_sum_assignment(cost)  
132         #print(row_ind,col_ind)  
133         for i in range(len(row_ind)):  
134             assignment[row_ind[i]] = col_ind[i]  
135         # Identify tracks with no assignment, if any  
136         un_assigned_tracks = []  
137         for i in range(len(assignment)):  
138             if (assignment[i] != -1):  
139                 # check for cost distance threshold.  
140                 # If cost is very high then un_assign  
141                 ↵ (delete) the track  
142                 if (cost[i][assignment[i]] >  
143                     ↵ self.dist_thresh):  
144                     assignment[i] = -1  
145                     un_assigned_tracks.append(i)  
146                     pass  
147             else:  
148                 self.tracks[i].skipped_frames += 1  
149             print ('Assignment after thresholding: ',  
150                   ↵ assignment)  
151             # If tracks are not detected for long time,  
152                 ↵ remove them  
153             del_tracks = []  
154             for i in range(len(self.tracks)):  
155                 if (self.tracks[i].skipped_frames >  
156                     ↵ self.max_frames_to_skip):  
157                     del_tracks.append(i)  
158             if len(del_tracks) > 0: # only when skipped  
159                 ↵ frame exceeds max  
160                 for id in del_tracks:
```

```

153             if id < len(self.tracks):
154                 del self.tracks[id]
155                 del assignment[id]
156             else:
157                 dprint("ERROR: id is greater than
158                     → length of tracks")
159
160     # Now look for un_assigned detects
161     un_assigned_detects = []
162     for i in range(len(detections)):
163         if i not in assignment:
164             un_assigned_detects.append(i)
165     print('Unassigned detects:
166           → ',un_assigned_detects)
167     # Start new tracks
168     if(len(un_assigned_detects) != 0):
169         for i in range(len(un_assigned_detects)):
170             track = Track(detections[un_assigned_d_]
171                           → ectests[i]],
172                           self.trackIdCount)
173             self.trackIdCount += 1
174             # ----- ADDED BY
175             → VIRGINIA RAMÓN
176             → -----
177             track.obj_class = bboxes[i][4]
178             track.bbox.append(bboxes[un_assigned_d_]
179                           → ectests[i]])
180             self.tracks.append(track)
181
182     # Update KalmanFilter state, lastResults and
183     → tracks trace
184     for i in range(len(assignment)):
185         #print('before only prediction: ',
186             → self.tracks[i].KF.x)
187         self.tracks[i].KF.predict(0.05)
188         #print('after only prediction: ',
189             → self.tracks[i].KF.x)
190         if(assignment[i] != -1):
191             self.tracks[i].skipped_frames = 0

```

```

183         self.tracks[i].KF.update([0],np.array([
184             [detections[assignment[i]][0]]]),1,
185             self.r)
186         self.tracks[i].KF.update([1],np.array([
187             [detections[assignment[i]][1]]]),1,
188             self.r)
189         self.tracks[i].prediction=self.tracks[
190             i].KF.x
191         #print("pre:
192             ",self.tracks[i].prediction)
193         #self.tracks[i].prediction[1]=self.tra
194             cks[i].KF.x[1];
195     else:
196         #print(self.tracks[i].KF.x)
197         self.tracks[i].KF.update([0],np.array([
198             np.array([0])),0,self.r)
199         self.tracks[i].KF.update([1],np.array([
200             np.array([0])),0,self.r)
201         self.tracks[i].prediction=self.tracks[
202             i].KF.x
203         #self.tracks[i].prediction =
204             self.tracks[i].KF.correct(
205                 #
206                 → np.array([[0], [0]]), 0)
207         #print('det
208             :',np.array([[detections[assignment[i]]
209                 [0]], [detections[assignment[i]][1]]]))
210         #print('i : ', assignment[i], 'updated
211             prediction :
212             ',self.tracks[i].prediction)
213         if(len(self.tracks[i].trace) >
214             self.max_trace_length):
215             for j in
216                 range(len(self.tracks[i].trace) -
217                     self.max_trace_length):
218                 del self.tracks[i].trace[j]
219
220
221         if self.tracks[i].prediction.shape[0] == 2:

```

```

204             self.tracks[i].prediction=np.insert(se_]
205                 ↵ lf.tracks[i].prediction,self.track_
206                 ↵ s[i].prediction.shape[0],0)
207             self.tracks[i].prediction=np.insert(se_]
208                 ↵ lf.tracks[i].prediction,self.track_
209                 ↵ s[i].prediction.shape[0],0)
210             self.tracks[i].prediction=np.insert(se_]
211                 ↵ lf.tracks[i].prediction,self.track_
212                 ↵ s[i].prediction.shape[0],0)
213             self.tracks[i].prediction=np.insert(se_]
214                 ↵ lf.tracks[i].prediction,self.track_
215                 ↵ s[i].prediction.shape[0],0)
216
217             self.tracks[i].trace.append(np.reshape(sel_]
218                 ↵ f.tracks[i].prediction,(6,1)))
219             #print('cc :
220                 ↵ ',self.tracks[i].prediction.shape)
221             self.tracks[i].KF.lastResult =
222                 ↵ self.tracks[i].prediction
223             self.ls = assignment
224             # ----- ADDED BY VIRGINIA
225                 ↵ RAMÓN -----
226             #print("Saving BBox...")
227             #print(len(self.tracks[i].trace))
228             if(assignment[i] != -1):
229                 #print("Not -1")
230                 self.tracks[i].bbox.append(bboxes[assi_
231                 ↵ gnment[i]])
232             else:
233                 bbox = []
234                 #print(len(self.tracks[i].trace))
235                 if (len(self.tracks[i].trace) > 1):
236
237                     # Get last centroid
238                     x1 = self.tracks[i].trace[-2][0][0]
239                     y1 = self.tracks[i].trace[-2][1][0]
240
241                     x2 = self.tracks[i].trace[-1][0][0]
242                     y2 = self.tracks[i].trace[-1][1][0]
243
244                     xd = x2-x1

```

```
232         yd = y2-y1
233         # Center bbox previous to new
234         # position
235         bbox = self.tracks[i].bbox[-1]
236
236         x1 = bbox[0]+xd if bbox[0]+xd > 0
237         # else 0
237         y1 = bbox[1]+yd if bbox[1]+yd > 0
238         # else 0
238         x2 = bbox[2]+xd if bbox[2]+xd > 0
239         # else 0
239         y2 = bbox[3]+yd if bbox[3]+yd > 0
240         # else 0
241
241         bbox = [x1,y1,x2,y2]
242     else:
243
244         bbox = self.tracks[i].bbox[-1]
245
246     self.tracks[i].bbox.append(bbox)
247
248
249 else:
250     assignment = self.ls
251     for i in range(len(assignment)):
252         #print('before only prediction: ',
253         #       self.tracks[i].KF.x)
253         self.tracks[i].KF.predict(0.08)
254         #print('after only prediction: ',
255         #       self.tracks[i].KF.x)
256
256         self.tracks[i].KF.update([0],np.array(np.a_
257         #       rray([0])),0,self.r)
257         self.tracks[i].KF.update([1],np.array(np.a_
258         #       rray([0])),0,self.r)
258         self.tracks[i].prediction=self.tracks[i].K_
259         #       F.x
259         #self.tracks[i].prediction =
260         #       self.tracks[i].KF.correct(
260         #       #
260         #       np.array([[0], [0]]), 0)
```

```

261      #print( 'det
262          ↵   :,np.array([[detections[assignment[i] ]
263          ↵   ][0]], [detections[assignment[i]][1]])))
264      #print('i : ', assignment[i], 'updated
265          ↵   prediction :
266          ↵   ',self.tracks[i].prediction)
267      if(len(self.tracks[i].trace) >
268          ↵   self.max_trace_length):
269          ↵   for j in
270              ↵   range(len(self.tracks[i].trace) -
271                  ↵   self.max_trace_length):
272                  ↵   del self.tracks[i].trace[j]
273
274
275
276
277
278
279
280
281
282

```

---

```
283         self.tracks[i].bbox.append(bboxes[assi_]
284             ↵ gnment[i]]))
285     else:
286         bbox = []
287         #print(len(self.tracks[i].trace))
288         if (len(self.tracks[i].trace) > 1):
289
290             # Get last centroid
291             x1 = self.tracks[i].trace[-2][0][0]
292             y1 = self.tracks[i].trace[-2][1][0]
293
294             x2 = self.tracks[i].trace[-1][0][0]
295             y2 = self.tracks[i].trace[-1][1][0]
296
297             xd = x2-x1
298             yd = y2-y1
299             # Center bbox previous to new
300                 ↵ position
301             bbox = self.tracks[i].bbox[-1]
302
303             x1 = bbox[0]+xd if bbox[0]+xd > 0
304                 ↵ else 0
305             y1 = bbox[1]+yd if bbox[1]+yd > 0
306                 ↵ else 0
307             x2 = bbox[2]+xd if bbox[2]+xd > 0
308                 ↵ else 0
309             y2 = bbox[3]+yd if bbox[3]+yd > 0
310                 ↵ else 0
311
312             bbox = [x1,y1,x2,y2]
313     else:
314
315         bbox = self.tracks[i].bbox[-1]
316
317         self.tracks[i].bbox.append(bbox)
318
319
320
321
322
323
324 # ----- ADDED BY VIRGINIA RAMÓN
325     ↵ -----
326
327 # Extracted from https://www.pyimagesearch.com/2016/11/07/
328     ↵ intersection-over-union-iou-for-object-detection/
```

```
316 def bb_intersection_over_union(boxA, boxB, obj_class):
317     # determine the (x, y)-coordinates of the intersection
318     # rectangle
319     xA = max(boxA[0], boxB[0])
320     yA = max(boxA[1], boxB[1])
321     xB = min(boxA[2], boxB[2])
322     yB = min(boxA[3], boxB[3])
323     # compute the area of intersection rectangle
324     interArea = max(0, xB - xA + 1) * max(0, yB - yA + 1)
325     # compute the area of both the prediction and
326     # ground-truth
327     # rectangles
328     boxAArea = (boxA[2] - boxA[0] + 1) * (boxA[3] -
329     # area and dividing it by the sum of prediction +
330     # ground-truth
331     # areas - the intersection area
332     iou = interArea / float(boxAArea + boxBArea -
333     # chwck if objects are the same class
334     if int(obj_class) != int(boxB[4]):
335         iou = -iou # to avoid being selected
336     # return the intersection over union value
337     return abs(iou)
```

### D.4.3 object\_tracking.py

```
1  """
2      File name          : object_tracking.py
3      File Description   : Multi Object Tracker Using Kalman
4      ↵ Filter           and Hungarian Algorithm
5      Author            : Srini Ananthakrishnan
6      Date created      : 07/14/2017
7      Date last modified: 07/16/2017
8      Python Version    : 2.7
9
10     Modified by        : Virginia Ramón
11     Data last modified: 19/12/2021
12 """
13
14 # Import python libraries
15 import sys
16 import cv2
17 import copy
18 import numpy as np
19 import time
20 from tracker import Tracker
21
22 # -----ADDED BY VIRGINIA
23     ↵ RAMÓN-----
23 from frame_detection import frame_detection as vid
24 sys.path.append("/home/virginia/TFG/YOLOv4/TensorFlow-2.x-"
25     ↵ YOLOv3-master/")
25 from yolov3.utils import Load_Yolo_model
26 from yolov3.configs import *
27 # -----
28     ↵ ---]
29 def main():
30     """Main function for multi object tracking
31     Usage:
32         $ python2.7 objectTracking.py
33     Pre-requisite:
34         - Python2.7
35         - Numpy
```

```
36      - SciPy
37      - OpenCV 3.0 for Python
38 Args:
39     None
40 Return:
41     None
42 """
43
44 """
45
46 options = {
47     'model': 'cfg/tiny-yolo-voc-1c.cfg',
48     'load': 4000,
49     'threshold': 0.15,
50     'gpu': 1.0
51 }
52
53 tfnet = TFNet(options)
54 """
55 # -----ADDED BY VIRGINIA
56 #-----RAMÓN-----
56 rg = 0
57 net = Load_Yolo_model()
58 # -----
59
60 # net = Detector(bytes("cfg/yolov3.cfg",
61 #   encoding="utf-8"), bytes("weights/yolov3.weights",
62 #   encoding="utf-8"), 0,
63 #       bytes("cfg/coco.data",
64 #   encoding="utf-8"))
65
66 # Create opencv video capture object
67 cap = cv2.VideoCapture("../IMAGES/GH010008_Val.mp4")
68 #Output path to save video result
69 output_path = "../IMAGES/GH010008_Val_UKF20000f.mp4"
70
71 # by default VideoCapture returns float instead of int
```

```
72     width = int(cap.get(cv2.CAP_PROP_FRAME_WIDTH))
73     height = int(cap.get(cv2.CAP_PROP_FRAME_HEIGHT))
74     fps = int(cap.get(cv2.CAP_PROP_FPS))
75     codec = cv2.VideoWriter_fourcc(*'XVID')
76     out = cv2.VideoWriter(output_path, codec, fps, (width,
77             ↳ height)) # output_path must be .mp4
78
79     # Create Object Tracker
80     tracker = Tracker(0.75, 80, 10000, 40)
81
82     # Variables initialization
83     skip_frame_count = 0
84     track_colors = [(255, 0, 0), (0, 255, 0), (0, 0, 255),
85             ↳ (255, 255, 0),
86                     (0, 255, 255), (255, 0, 255), (255,
87                         ↳ 127, 255),
88                     (127, 0, 255), (127, 0, 127)]
89     pause = False
90     frame_array=[]
91     first=0
92     # Frames of track shown
93     max_frames = 20000
94     # Infinite loop to process video frames
95     size=(1920,1080)
96     c=0
97
98     try:
99         while True:
100             # Capture frame-by-frame
101             ret, frame = cap.read()
102
103             # Make copy of original frame
104             orig_frame = copy.copy(frame)
105
106             # Skip initial frames that display logo
107             '''
108             if (skip_frame_count < 15):
109                 skip_frame_count += 1
110                 continue
111             '''
```

```
110         # Detect and return centeroids of the objects
111         # in the frame
112         centers, bbxs = vid.detect(ret,frame,net)
113
114     # If centroids are detected then track them
115     if (len(centers) > 0):
116         first=1
117         # Track object using Kalman Filter
118         tracker.Update(centers,bbxs,first)
119
120     # For identified object tracks draw
121     # tracking line
122     # Use various colors to indicate different
123     # track_id
124     print('NUM OF OBJECTS :
125         ',len(tracker.tracks))
126     if len(tracker.tracks) > 1:
127         rg = len(tracker.tracks)
128     else:
129         rg = len(tracker.tracks)
130     for i in range(rg):
131         if (len(tracker.tracks[i].trace) > 1):
132             # Check number of traces to show
133             if (len(tracker.tracks[i].trace) >
134                 max_frames):
135                 init_frames = max_frames
136             else:
137                 init_frames = len(tracker.trac
138                     ks[i].trace)

139
140         for j in range(len(tracker.tracks[
141             i].trace)-init_frames,len(trac
142             ker.tracks[i].trace)-1):
143             # Draw trace line
144             x1 = tracker.tracks[i].trace[j
145                 ][0][0]
146             y1 = tracker.tracks[i].trace[j
147                 ][1][0]
148             x2 = tracker.tracks[i].trace[j
149                 ]+1][0][0]
```

```

139             y2 = tracker.tracks[i].trace[j]
140                     ↵ +1][1][0]
141             clr =
142                     ↵ tracker.tracks[i].track_id
143                     ↵ % 9
144             cv2.line(frame, (int(x1),
145                     ↵ int(y1)), (int(x2),
146                     ↵ int(y2)),
147                         track_colors[clr], 4)
148
149             xb1 = int(tracker.tracks[i].bbox[-]
150                     ↵ 1][0])
151             yb1 = int(tracker.tracks[i].bbox[-]
152                     ↵ 1][1])
153             xb2 = int(tracker.tracks[i].bbox[-]
154                     ↵ 1][2])
155             yb2 = int(tracker.tracks[i].bbox[-]
156                     ↵ 1][3])
157             cv2.rectangle(frame, (xb1,yb1),
158                     ↵ (xb2,yb2), (0,0,255),1)
159             x = int(tracker.tracks[i].trace[-1]
160                     ↵ ][0][0])
161             y = int(tracker.tracks[i].trace[-1]
162                     ↵ ][1][0])
163             cv2.circle(frame, (x,y), 3,
164                     ↵ (0,0,255),4)
165
166             # Display the resulting tracking frame
167
168         elif first==1:
169             tracker.Update(centers,0)
170             print('NUM OF OBJECTSno : '
171                     ↵ ',len(tracker.tracks))'
172             if len(tracker.tracks) > 1:
173                 rg = len(tracker.tracks)
174             else:
175                 rg = len(tracker.tracks)
176             for i in range(rg):
177                 if (len(tracker.tracks[i].trace) > 1):
178                     print('NUM OF OBJECTSnononono : ',l
179                     ↵ en(tracker.tracks[i].trace),)

```

```

165     print('trace :
166         ', tracker.tracks[i].trace[len(
167             tracker.tracks[i].trace)-1],)
168
169     # Check number of traces to show
170     if (len(tracker.tracks[i].trace) >
171         max_frames):
172         init_frames = max_frames
173     else:
174         init_frames = len(tracker.trac
175             ks[i].trace)
176     for j in range(len(tracker.tracks[
177         i].trace)-init_frames, len(trac
178             ker.tracks[i].trace)-1):
179         # Draw trace line
180         x1 = tracker.tracks[i].trace[j]
181             [0][0]
182         y1 = tracker.tracks[i].trace[j]
183             [1][0]
184         x2 = tracker.tracks[i].trace[j]
185             +1][0][0]
186         y2 = tracker.tracks[i].trace[j]
187             +1][1][0]
188         clr =
189             tracker.tracks[i].track_id
190             % 9
191
192         cv2.line(frame, (int(x1),
193             int(y1)), (int(x2),
194             int(y2)),
195                 track_colors[clr], 4)
196         xb1 = int(tracker.tracks[i].bbox[-]
197             1][0])
198         yb1 = int(tracker.tracks[i].bbox[-]
199             1][1])
200         xb2 = int(tracker.tracks[i].bbox[-]
201             1][2])
202         yb2 = int(tracker.tracks[i].bbox[-]
203             1][3])
204         cv2.rectangle(frame, (xb1,yb1),
205             (xb2,yb2), (0,0,255),1)

```

```
186         x = int(tracker.tracks[i].trace[-1]
187             ↵     ][0][0])
188         y = int(tracker.tracks[i].trace[-1]
189             ↵     ][1][0])
190         cv2.circle(frame, (x,y), 3,
191             ↵     (0,0,255),4)
192
193
194     height, width, layers = frame.shape
195     size = (width,height)
196     frame_array.append(frame)
197     if output_path != '': out.write(frame)
198
199
200     '''
201
202     # Display the original frame
203     #cv2.imshow('Original', orig_frame)
204     if keyboard.is_pressed('q'):# 'q' key has been
205         → pressed, exit program.
206         break
207
208     # Slower the FPS
209     cv2.waitKey(50)
210
211
212     # Check for key strokes
213     k = cv2.waitKey(50) & 0xff
214     if k == 27: # 'esc' key has been pressed, exit
215         → program.
216         break
217     if k == 112: # 'p' has been pressed. this will
218         → pause/resume the code.
219         pause = not pause
220         if (pause is True):
221             print("Code is paused. Press 'p' to
222                 → resume...")
223             while (pause is True):
224                 # stay in this loop until
225                 key = cv2.waitKey(30) & 0xff
226                 if key == 112:
227                     pause = False
228                     print("Resume code...!!!")
229                     break
230
231         '''
232
233
234
235
236
237
238
239
```

```
220         key = cv2.waitKey(1) & 0xFF
221
222         # Exit
223         if key == ord('q'):
224             break
225
226         # Take screenshot
227         if key == ord('s'):
228             cv2.imwrite('frame_{}.jpg'.format(time.time(),
229                         () ,
230                         frame))
231
232         c+=1
233     except:
234         print('Video Ended')
235     # When everything done, release the capture
236     finally:
237         #out = cv2.VideoWriter('result2.mp4',cv2.VideoWriter(
238             # r_fourcc(*'MP4V'),
239             # int(cap.get(cv2.CAP_PROP_FPS)), size)
240             #print('11')
241             #for i in range(len(frame_array)):
242                 # writing to a image array
243                 #cv2.imshow('ff',frame_array[i])
244                 # writing to a image array
245                 #out.write(frame_array[i])
246             #out.release()
247
248             #out.release()
249             cap.release()
250             cv2.destroyAllWindows()
251
252
253 if __name__ == "__main__":
254     # execute main
255     main()
```

#### D.4.4 common.py

```
1  """
2      File name          : common.py
3      File Description   : Common debug functions
4      Author            : Srinivasan Ananthakrishnan
5      Date created      : 07/14/2017
6      Date last modified: 07/14/2017
7      Python Version    : 2.7
8  """
9
10
11 def dprint(*args, **kwargs):
12     """Debug print function using inbuilt print
13     Args:
14         args   : variable number of arguments
15         kwargs : variable number of keyword argument
16     Return:
17         None.
18     """
19     # print(*args, **kwargs)
20     pass
```

#### D.4.5 frame\_detection.py

```
32         cv2.putText(frame, 'Pig',
33                         ↳ (int(b[0]),int(b[1])),
34                         ↳ cv2.FONT_HERSHEY_SIMPLEX, 0.5, (0,
35                         ↳ 255, 0), 1, cv2.LINE_AA)
36     else:
37         cv2.rectangle(frame,
38                         ↳ (int(b[0]),int(b[1])),
39                         ↳ (int(b[2]),int(b[3])), (0,255,0),2)
40         cv2.putText(frame, 'Person',
41                         ↳ (int(b[0]),int(b[1])),
42                         ↳ cv2.FONT_HERSHEY_SIMPLEX, 0.5,
43                         ↳ (255,0,0), 1, cv2.LINE_AA)
44         x = int(b[0]+((b[2]-b[0])/2))
45         y = int(b[1]+((b[3]-b[1])/2))
46
47     # save centtroid and bbox
48     centroids.append((x,y))
49     bbx.append((b[0],b[1],b[2],b[3],b[5]))
50
51 return centroids, bbx
```