

Josep Bello Curto

# Detecció de danys a pales d'aerogeneradors amb deep learning

Enginyeria Informàtica

Treball de Fi de Grau

Dirigit pels

Dr. Domènec Savi Puig Valls

Dr. Mohamed Abdelnasser Mohamed Mahmoud



UNIVERSITAT ROVIRA I VIRGILI

Tarragona, 2022

**Índex**

<b>Resum</b>	<b>iv</b>
<b>Resumen</b>	<b>iv</b>
<b>Abstract</b>	<b>iv</b>
<b>1 Introducció</b>	<b>1</b>
<b>2 Antecedents</b>	<b>9</b>
<b>3 Metodologia</b>	<b>13</b>
3.1 Recopilació de dades . . . . .	13
3.2 Etiquetat de les imatges . . . . .	13
3.3 Models provats . . . . .	14
3.4 Model base . . . . .	14
3.5 Augmentació de dades . . . . .	15
3.6 Balanceig de dades . . . . .	15
<b>4 Resultats experimentals</b>	<b>16</b>
4.1 Xarxa petita . . . . .	16
4.1.1 Comparativa models xarxa petita . . . . .	20
4.2 Xarxa gran . . . . .	24
4.2.1 Comparativa models xarxa gran . . . . .	27
<b>5 Conclusions</b>	<b>30</b>
<b>Referències</b>	<b>31</b>

## List of code snippets

## Índex de figures

1	Fotografia d'una inspecció feta des de terra. . . . .	1
2	Fotografia d'una inspecció amb dron. Font: EbreDrone . . . . .	2
3	Canon 5D amb teleobjectiu. Font: Canon . . . . .	2
4	Parts d'una pala d'aerogenerador [4] . . . . .	3
5	Aerogenerador parat per fer una inspecció amb càmera. . . . .	3
6	Aerogenerador parat per fer una inspecció amb dron. Font: EbreDrone . . . . .	4
7	Exemple pitting. Font: EbreDrone . . . . .	5
8	Exemple erosió amb dany a les fibres. Font: EbreDrone . . . . .	6
9	Exemple erosió sense dany a les fibres. Font: EbreDrone . . . . .	6
10	Exemple impacte de llamp. Font: EbreDrone . . . . .	7
11	Exemple gel coat desgastat. Font: EbreDrone . . . . .	7
12	Exemple plàstics danyats. Font: EbreDrone . . . . .	8
13	Exemple esqueda. Font: EbreDrone . . . . .	8
14	Matriu de confusió amb múltiples classes [3] . . . . .	9
15	Interpretació de matriu de confusió amb múltiples classes [3] . . . . .	10
16	Representació gràfica precisió i recall [7] . . . . .	10
17	Representació gràfica IoU [8] . . . . .	11
18	Efecte IoU als resultats [8] . . . . .	11
19	Exemple curva precisió-recall . . . . .	12
20	Distribució de la quantitat de danys per imatge . . . . .	13
21	Distribució de les etiquetes . . . . .	14
22	Tamany de les etiquetes dels danys al dataset d'entrenament . . . . .	14
23	Imatges de validació etiquetades a mà . . . . .	16
24	Matriu de confusió base xarxa petita . . . . .	17
25	Prediccions base xarxa petita . . . . .	17
26	Matriu de confusió xarxa petita equilibrada i augmentada . . . . .	19
27	Prediccions xarxa petita equilibrada i augmentada . . . . .	20
28	Comparativa mAP 0.5:0.95 xarxa petita . . . . .	20
29	Comparativa mAP 0.5 xarxa petita . . . . .	21
30	Comparativa precisió xarxa petita . . . . .	21
31	Comparativa recall xarxa petita . . . . .	21
32	Comparativa box loss xarxa petita . . . . .	22
33	Comparativa cls loss xarxa petita . . . . .	22
34	Comparativa obj loss xarxa petita . . . . .	22
35	Matriu de confusió xarxa gran base . . . . .	24
36	Prediccions base xarxa gran . . . . .	25
37	Matriu de confusió xarxa gran equilibrada i augmentada . . . . .	26
38	Prediccions xarxa gran equilibrada i augmentada . . . . .	26
39	Comparativa mAP 0.5:0.95 xarxa large . . . . .	27
40	Comparativa mAP 0.5 xarxa large . . . . .	27
41	Comparativa precisió xarxa gran . . . . .	27
42	Comparativa recall xarxa gran . . . . .	28
43	Comparativa box loss xarxa gran . . . . .	28
44	Comparativa cls loss xarxa gran . . . . .	28

45	Comparativa obj loss xarxa gran . . . . .	29
----	---	----

## Índex de taules

1	Matriu de confusió . . . . .	9
2	Mètriques base xarxa petita . . . . .	16
3	Mètriques xarxa petita equilibrada i augmentada . . . . .	19
4	Mètriques base xarxa gran . . . . .	24
5	Mètriques xarxa gran equilibrada i augmentada . . . . .	25

## **Resum**

S'estima que aproximadament el 20-25% del cost de l'energia és causat pel manteniment de les infraestructures. Aquest treball té com a objectiu agilitzar aquesta tasca als parcs eòlics on es fan inspeccions amb dron amb l'ús de deep learning per l'anàlisi de les imatges. I, en última instància, reduir el cost i/o temps de les inspeccions.

## **Resumen**

Se estima que aproximadamente el 20-25 % del coste de la energía es causado por el mantenimiento de las infraestructuras. Este trabajo tiene como objetivo agilizar dicha tarea en parques eólicos donde se hacen inspecciones con dron con el uso de deep learning para analizar las imágenes. I, en última instancia, reducir el coste y/o tiempo de las inspecciones.

## **Abstract**

It is estimated that approximately 20-25% of the levelized cost of energy is caused by infrastructure maintenance. This project aims to speed up that process in wind turbines, where inspections are done with drones with the usage of deep learning to analyze the images. And ultimately, reduce the cost and/or time of the inspections.

## 1 Introducció

Reduir els costos de l'energia està sent un dels grans objectius dels últims temps, ja que hem arribat a superar els 300 € el MWh durant diversos dies.

S'estima que aproximadament el 20-25% del 'Levelized Cost of Energy' (LCoE) és per culpa del manteniment i operacions en el cas del sector eòlic, en comparació al 15% per al carbó, 10% per al gas, i 5% per l'energia nuclear. Durant els últims anys el sector ha estat evolucionant per tal de reduir aquesta xifra automatitzant processos, introduint l'ús de l'intel·ligència artificial [5] i afegint nous tipus de sensors, entre d'altres.

Tot i això, hem de tenir en compte que el cost de les inspeccions és considerablement inferior al cost de la reparació. En el millor dels casos la reparació implicarà que una persona amb coneixements de treballs verticals pugi a reparar la màquina, mentre que en el pitjor dels casos implicarà que s'hagi de baixar la pala per substituir-la o reparar-la a terra.

La introducció dels drons a les inspeccions ha permès reduir els costos, ja que es fan molt més ràpid, entre 20 i 40 minuts per inspecció, mentre que amb els mètodes tradicionals es tarda entre 1 i 3 hores, augmentar la qualitat, **Figura 1** i **Figura 2**, ja que s'utilitzen càmeres amb augments òptics i es poden situar amb millor perspectiva que els mètodes tradicionals, una millor qualitat, per tant, més facilitat d'identificar els danys a les fotografies i una quantitat de dades major, unes 150 fotografies per aerogenerador.



**Figura 1:** Fotografia d'una inspecció feta des de terra.



**Figura 2:** Fotografia d'una inspecció amb dron. Font: EbreDrone

Amb els mètodes tradicionals ja és una tasca tediosa, i llarga, el fet d'identificar els danys a les fotografies, ja que primer s'han de separar per aerogenerador, pala i cara, i després anar fotografia per fotografia fent una inspecció manual.


Aquesta tasca augmenta considerablement en tenir més imatges com és el cas del dron, és per això que diverses empreses estan investigant i invertint en aquesta via, entre elles EbreDrone, empresa col·laboradora en aquest treball fi de grau.

Tradicionalment les inspeccions es fan amb càmeres DSLR professionals i teleobjectius.



**Figura 3:** Canon 5D amb teleobjectiu. Font: Canon

No és l'objectiu d'aquest treball explicar els diversos tipus de pales i la seva composició, però per norma general podem dir que un aerogenerador té tres pales i cadascuna té el que s'anomena el vora d'atac, amb el que 'talla' l'aire, la vora de sortida, la balva de succió i la balva de pressió. **Figura 4**



**Figura 4:** Parts d'una pala d'aerogenerador [4]

Per les inspeccions amb càmera se sol parar l'aerogenerador de tal forma que cadascuna de les pales davant del màstil, **Figura 5**, de l'aerogenerador per fer les fotografies i l'aerogenerador té la funcionalitat de girar les pales sobre elles mateixes i així es poden veure les 4 parts de la pala des de el mateix punt.



**Figura 5:** Aerogenerador parat per fer una inspecció amb càmera.

Això significa que per cada aerogenerador s'han de fer 3 parades de la màquina, durant les quals no està produint i a més per passar d'una pala a l'altra no es fica l'aerogenerador en funcionament, sinó que es trau el fre i és depèn del vent, per tant, en cas que no hi hagi vent és impossible inspeccionar en aquest mètode.

D'altra banda, les inspeccions amb dron, les utilitzades per aquest treball, es solen fer amb drons industrials.

Per fer la inspecció amb el dron habitualment es para l'aerogenerador amb una pala cap a dalt, **Figura 6**, d'aquesta forma es pot inspeccionar la que queda totalment vertical i les dues balves superiors de les altres dues pales.



**Figura 6:** Aerogenerador parat per fer una inspecció amb dron. Font: EbreDrone

D'aquesta forma és molt més ràpid fer l'inspecció, ja que l'aerogenerador només s'ha de parar dos cops i no cal que quedi perfecte, ja que el dron es pot moure amb total llibertat.

Els tipus de danys que pot tenir una pala són molt diversos, però principalment els podem separar en 7 tipus.

- Pitting
- Erosió amb danys a les fibres
- Erosió sense danys a les fibres
- Impacte de llamp
- Gel coat desgastat
- Plàstics danyats
- Esquerda

El Pitting es troba a les balves i es dona quan l'aigua entra a la pala a causa d'un error a la fabricació d'aquesta.



**Figura 7:** Exemple pitting. Font: EbreDrone

Les erosions es causen pel fregament de l'aire amb la pala durant molt de temps. Se solen donar a les vores d'atac i sortida.



**Figura 8:** Exemple erosió amb dany a les fibres. Font: EbreDrone



**Figura 9:** Exemple erosió sense dany a les fibres. Font: EbreDrone

L'impacte de llamp es dona a la punta de la pala, ja que hi ha un para llamps i se sol veure tota aquella secció cremada, però cal parar especial atenció als voltants perquè a causa de l'impacte poden aparèixer esquerdes.




**Figura 10:** Exemple impacte de llamp. Font: EbreDrone

Gel coat es un tipus de dany que no es dona a totes les pales, però si a moltes, es dona quan les pales tenen una cinta prop de la vora d'atac generalment i aquesta s'arrenca.



**Figura 11:** Exemple gel coat desgastat. Font: EbreDrone

Al punt d'unió de la pala amb la góndola de l'aerogenerador hi ha un plàstic que a causa del vent es pot doblegar.



**Figura 12:** Exemple plàstics danyats. Font: EbreDrone

Finalment, les esquerdes són el tipus de danys menys comuns, però que poden ser més greus, se solen donar a les vores d'atac i sortida i són més crítiques quan més prop estan de l'arrel de la pala, més pròximes a la góndola.



**Figura 13:** Exemple esqueda. Font: EbreDrone

## 2 Antecedents

Primer cal definir totes les diverses mètriques que utilitzarem durant el treball per comparar les diverses xarxes entrenades.

Primer, cal separar totes les dades etiquetades en, com a mínim, 2 sub-datasets, un per entrenament i un per obtenir les mètriques que definirem a continuació durant l'entrenament i refinar els paràmetres de la xarxa.

En xarxes neuronals es defineixen vertader positiu, true positive en anglès (tp), vertader negatiu, true negative en anglès (tn), fals positiu, fals positive en anglès (fp) i fals negatiu, fals negative (fn) en anglès de la següent forma:

Per dues classes, per exemple, hi ha gos a la imatge o no:

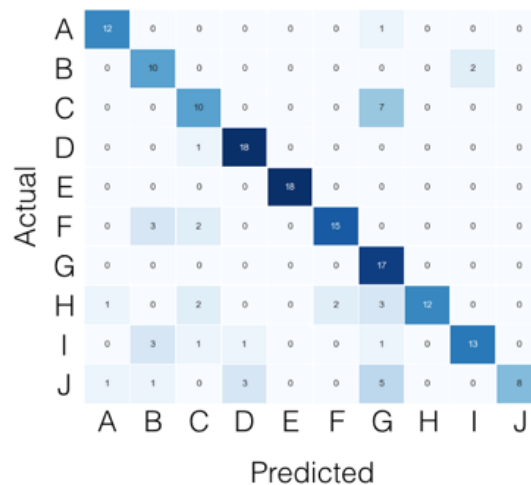
- TP: Aquelles fotografies classificades i etiquetades com que hi ha gos.
- TN: Aquelles fotografies classificades i etiquetades com que no hi ha gos.
- FP: Aquelles fotografies classificades com que hi ha gos, però no n'hi ha.
- FN: Aquelles fotografies classificades com que no hi ha gos, però sí que n'hi ha

Aquests 4 termes els podem ficar a una matriu de la següent forma, anomenarem a aquesta matriu, la matriu de confusió.

		Classe etiquetada	
		Hi ha gos	No hi ha gos
Classe predita	Hi ha gos	<i>TP</i>	<i>FP</i>
	No hi ha gos	<i>FN</i>	<i>TN</i>

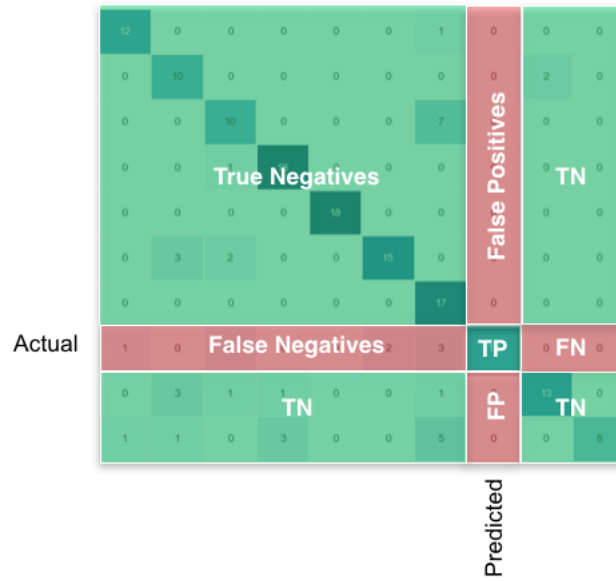
**Taula 1:** Matriu de confusió

I, en el cas d'un problema amb més de dues classes, utilitzarem el mètode d'un contra la resta. On si tenim les classes, A, B, C ... J aquesta seria la matriu de confusió.



**Figura 14:** Matriu de confusió amb múltiples classes [3]

I aquesta la seva interpretació.



**Figura 15:** Interpretació de matriu de confusió amb múltiples classes [3]


A partir d'aquests termes es defineixen la precisió i reclam, o recall en anglès, també anomenat sensibilitat.

La precisió és la fracció de casos veritablement positius entre els casos predits com a positius.

$$Precision = \frac{tp}{tp + fp} \tag{1}$$

I el recall és la fracció de casos positius detectats entre tots els casos positius.

$$Recall = \frac{tp}{tp + fn} \tag{2}$$



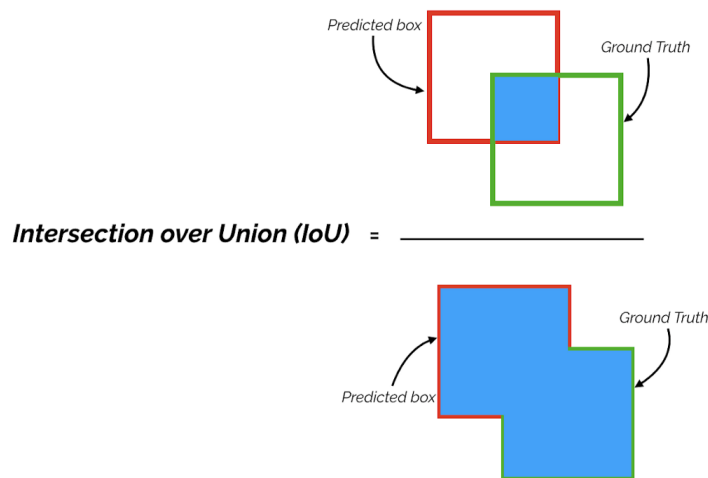
**Figura 16:** Representació gràfica precisió i recall [7]

Però per als models on no només volem detectar si una imatge és d'un gat o no, sinó que el volem localitzar a la imatge, fer el que es coneix com a detecció d'objectes, cal definir algunes mètriques més.

Primer, cal definir una mètrica que ens permeti dir veure com d'igual és una detecció respecte a l'etiquetat. Aquesta mètrica és l'anomenat Intersection Over Union (IoU) o índex de Jaccard, que es defineix de la següent forma:

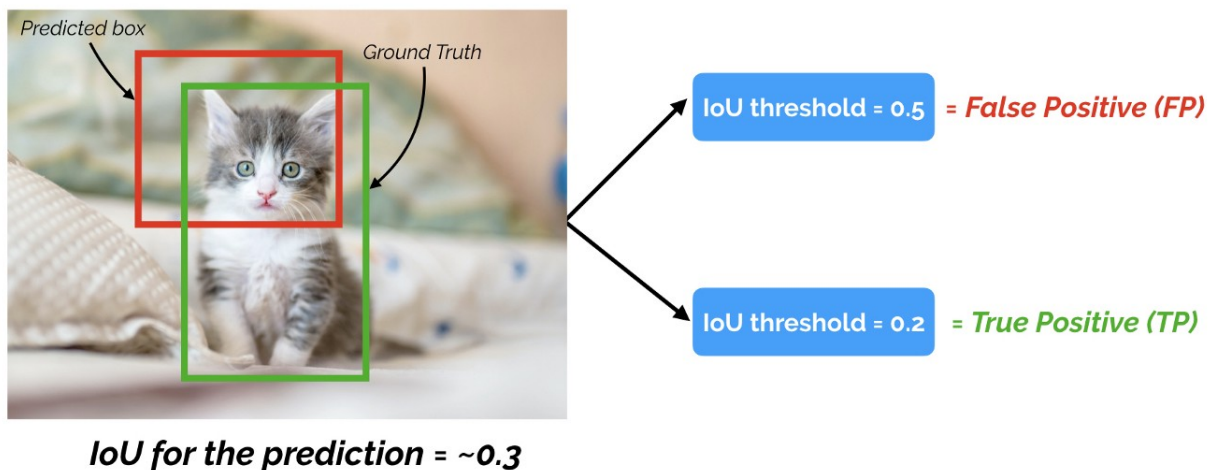
$$IoU = \frac{Area_{Overlap}}{Area_{Union}} \quad (3)$$

Gràficament, ho podem representar de la següent forma:



**Figura 17:** Representació gràfica IoU [8]


Per als models que fan detecció d'objectes la precisió i recall estan calculades per un valor concret de IoU, i, per tant, aquest valor tindrà un impacte directe en els resultats com es pot veure a la següent figura, on si fem aquest threshold a 0,5 ens donarà un fals positiu mentre que si el fem a 0,2 tindrem un vertader positiu.



**Figura 18:** Efecte IoU als resultats [8]

A partir de la IoU es deriva la precisió mitjana, average precision o AP en anglès i la seva mitjana, la mean average precision o mAP.

Per als sistemes on tenim un rang en les deteccions hem de tenir en compte l'ordre d'aquestes. Això es fa calculant la precisió, equació 1, i el recall, equació 2, per a tots els rangs i fer el que es coneix com a la curva precisió-recall, representar la precisió  $p(r)$  en funció del recall  $r$  de la següent forma.



**Figura 19:** Exemple curva precisió-recall

I definim l'average precision com a l'àrea per sota d'aquesta línia. Definit de la següent forma. [6]

$$AP = \int_0^1 p(r) dr \quad (4)$$

A la pràctica l'integral és substituïda per una suma finita per cada element detectat. [6]

$$AP = \sum_{k=1}^n P(k) \Delta r(k) \quad (5)$$

On  $k$  es el rang d'elements detectats,  $n$  la quantitat d'elements,  $P(k)$  la precisió per un valor de tall  $k$  de la llista i  $\Delta r(k)$  el canvi del recall del element  $k - 1$  i  $k$ . [6]

I definim també la seva mitjana, mean average precision o mAP de la següent forma, per un nombre  $Q$  de classes. [6]

$$mAP = \frac{\sum_{q=1}^Q AP(q)}{Q} \quad (6)$$

Finalment, també cal definir 3 funcions de perduda, que ens ajudaran a entendre el funcionament de la xarxa.

Box loss és defineix com la perduda a les caixes, object loss es defineix com la seguretat de la presència d'un objecte i cls loss com a la pèrdua a la classificació.


## 3 Metodologia

### 3.1 Recopilació de dades

En deep learning el més important són les dades, els models d'avui dia són molt eficients per tasques com visió per computador, NLP, reconeixement de senyals, etcètera, però necessiten una gran quantitat i qualitat de dades.

En aquest cas no hi ha cap dataset públic que s'adapti a les necessitats que tenia EbreDrone a causa de la seva metodologia explicada a la introducció, per tant, el dataset utilitzat en aquest projecte és privat i propietat de l'empresa.

A continuació és mostra la distribució d'etiquetes per imatge.



**Figura 20:** Distribució de la quantitat de danys per imatge

Aquest dataset inclou totes les imatges en danys, i un petit percentatge, un 1% aproximadament, sense danys, de les inspeccions fetes per EbreDrone desde l'any 2019 fins al 2021 a un parc eòlic. Totes les imatges han sigut capturades amb un drone.


### 3.2 Etiquetat de les imatges

L'etiquetatge d'aquest dataset va començar prèviament a l'inici d'aquest projecte per Pau Jornet, cofundador d'EbreDrone, ja que inicialment van fer proves amb diversos col·laboradors.

Les primeres imatges, van ser classificades utilitzant la plataforma que te Google Cloud per aquesta tasca, però després de no tenir resultats satisfactoris es va deixar el projecte fins aquest treball.

La resta de dataset ha sigut etiquetat fent servir una eina open source.

A continuació es pot veure com la distribució dels danys no és equitativa, sinó que segueix la distribució real que se sol trobar als danys d'un parc.




**Figura 21:** Distribució de les etiquetes

### 3.3 Models provats

Prèviament a aquest projecte es van provar plataformes basades en el cloud per fer aquest model, però després de no obtenir resultats satisfactoris es va deixar el projecte. Per aquest treball inicialment vaig realitzar proves amb l'API de detecció d'objectes de Tensorflow 2 [1], i YOLOv5 [2] entre d'altres.

Un motiu important per l'elecció de la xarxa es el reduït tamany dels danys com es pot veure a continuació.



**Figura 22:** Tamany de les etiquetes dels danys al dataset d'entrenament

Per aquest treball s'han fet experiments amb dos xarxes de la mateixa arquitectura, però de dimensions diferents. I per cada tamany s'han fet dos entrenaments. Un amb els hiperparàmetres base i un altre amb augmentació i balanceig de dades a mesura.

### 3.4 Model base

Abans de fer cap modificació als paràmetres d'entrenament s'ha realitzat un entrenament amb els predeterminats per establir una línia base.

### 3.5 Augmentació de dades

És una pràctica habitual, i més quan els datasets són petits com en aquest cas, fer augmentació de dades, és a dir, mentre estem entrenant a la xarxa tenir una certa probabilitat que les imatges que s'ensenyen en una època d'entrenament estiguin alterades d'alguna forma, com ara fent zoom, fent una translació, afegint soroll, rotant la imatge, etcètera.

### 3.6 Balanceig de dades

Una altra tècnica utilitzada quan tenim datasets amb dades desequilibrades, com és el cas, és fer que el dataset d'entrenament en lloc de tenir la mateixa probabilitat que surti una imatge de la classe que més etiquetes que de la classe que menys etiquetes té. Es pot fer una probabilitat ponderada.

## 4 Resultats experimentals

La metodologia proposada ha sigut l'utilitzada per fer diversos experiments. Per evaluar els resultats dels entrenaments utilitzarem les mètriques descrites al segon capítol, partint dels models base i després amb els models equilibrats i amb augmentació pensada per al problema. Com s'ha explicat anteriorment s'han realitzat dos experiments, un amb la xarxa més petita, i una altra amb una de les més grans. Tots els entrenaments s'han dut a terme sobre una NVIDIA Quadro RTX 4000 Max-Q. Per tots els experiments s'ha fet servir el mateix dataset de validació i aquestes són algunes de les imatges d'aquest, etiquetades per una persona i les que s'usaran durant aquest capítol per fer comparacions després.



**Figura 23:** Imatges de validació etiquetades a mà

### 4.1 Xarxa petita

Per als experiments amb aquesta xarxa s'ha entrenat durant 1000 èpoques i les millors mètriques són les següents.

Època	mAP 0.5:0.95	mAP 0.5	Precisió	Recall	Box loss	Cls loss	Obj loss
162	0.17	0.45	0.51	0.51	0.0568	0.0191	0.0327

**Taula 2:** Mètriques base xarxa petita




Figura 24: Matriu de confusió base xarxa petita

Com es pot observar, la classe que pitjor classifica és la d'esquerdes a causa que és la classe amb menys etiquetes [Figura 21](#), mentre que aquelles amb més etiquetes les classifica considerablement millor.

Durant l'entrenament podem veure com van evolucionant la precisió, recall i mAP 0.5:0.95 fins a arribar a estabilitzar-se a l'ordre dels valors de la [Taula 2](#). Per aquest model aquestes són les prediccions sobre imatges de validació [Figura 23](#)



Figura 25: Prediccions base xarxa petita


Com podem observar, en general estan bé, però si mirem al detall, no té un elevat

grau de confiança amb les prediccions i sobretot falla en les esquerdes, com ja hem vist a [Figura 24](#)

Si passem a la xarxa amb augmentació personalitzada i equilibrada tenim les següents mètriques.

Època	mAP 0.5:0.95	mAP 0.5	Precisió	Recall	Box loss	Cls loss	Obj loss
849	0.17	0.43	0.61	0.42	0.0579	0.0170	0.0342

**Taula 3:** Mètriques xarxa petita equilibrada i augmentada



**Figura 26:** Matriu de confusió xarxa petita equilibrada i augmentada

Com es pot observar segueix la tendència de la xarxa base, classifica pitjor les imatges amb menys etiquetes, a continuació es mostren les imatges de validació per aquesta xarxa.



**Figura 27:** Prediccions xarxa petita equilibrada i augmentada

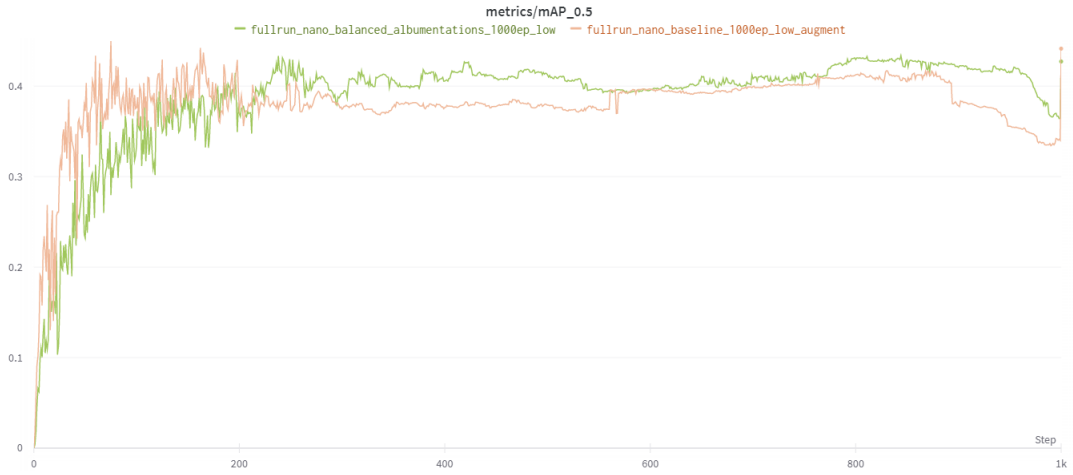
Com en l'anterior, en general estan bé, una mica millor en alguns casos, tot i tenir unes mètriques similars a la xarxa base, com es pot veure en les imatges de validació tendeix a estar més segur de les prediccions i detecta alguna esquerda que abans no, tot i que en norma general va pitjor per aquesta classe.

#### 4.1.1 Comparativa models xarxa petita

A partir de les mètriques de la millor època podem observar com aparentment la xarxa base té un millor funcionament que la xarxa amb augmentació dissenyada per aquest problema i equilibrant la xarxa, encara que per fer una comparativa més acurada del que està passant cal mirar a l'evolució d'aquestes mètriques durant l'entrenament, especialment a box loss, cls loss i obj loss per al dataset de train i de validació i veure així quan tenim overfit.



**Figura 28:** Comparativa mAP 0.5:0.95 xarxa petita



**Figura 29:** Comparativa mAP 0.5 xarxa petita



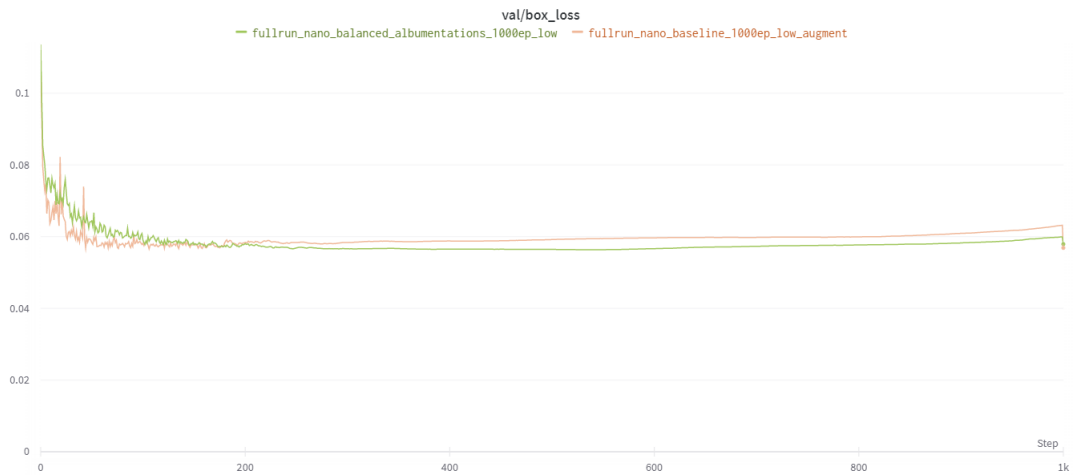
**Figura 30:** Comparativa precisió xarxa petita




**Figura 31:** Comparativa recall xarxa petita

Com podem veure en aquestes mètriques les dues xarxes pareixen tenir un comportament similar durant tot l'entrenament, però de cara al final podem veure com


la xarxa balancejada i amb augmentació a mesura per al problema obté uns resultats lleugerament millors. Però l'efecte de les augmentacions i el balanceig sí que es veu clarament a les següents loss mètriques al dataset de validació.



**Figura 32:** Comparativa box loss xarxa petita



**Figura 33:** Comparativa cls loss xarxa petita



**Figura 34:** Comparativa obj loss xarxa petita

A aquestes últimes tres mètriques es pot veure clarament l'efecte de balancejar la xarxa i fer una augmentació a mesura, observem una clara tendència on les mètriques d'aquesta segona xarxa són millors.

## 4.2 Xarxa gran

Com s'ha explicat anteriorment s'han realitzat experiments amb dues xarxes per veure com afecta els resultats tenir una xarxa amb més valors.


A part de la xarxa petita també s'han fet experiments amb una gran.

A causa de tenir més paràmetres l'entrenament és més costós, és per això que s'han fet entrenaments de 300 èpoques en lloc de 1000, tot i que tardaven el mateix, entre 8 i 9 hores cadascun.

Per al model base les millors mètriques són les següents.

Època	mAP 0.5:0.95	mAP 0.5	Precisió	Recall	Box loss	Cls loss	Obj loss
129	0.21	0.48	0.57	0.51	0.0549	0.0081	0.0231

**Taula 4:** Mètriques base xarxa gran



**Figura 35:** Matriu de confusió xarxa gran base

Es pot observar que segueix la tendència dels experiments anteriors, la classe amb menys etiquetes, esquerra, és la pitjor classificada, mentre que aquelles amb més etiquetes o més senzilles de detectar funcionen millor.

I aquestes són les prediccions de les imatges de la [Figura 23](#)






Figura 37: Matriu de confusió xarxa gran equilibrada i augmentada

I les prediccions per les etiquetes Figura 23 són




Figura 38: Prediccions xarxa gran equilibrada i augmentada


Com es pot observar classifica correctament el llamp de baix a la dreta i el spoiled plastic del centre, cosa que no feia la xarxa balancejada i equilibrada amb el model nano, però no detecta el spoiled plastic de dalt a l'esquerra que si detecta la xarxa base.

### 4.2.1 Comparativa models xarxa gran


Igual que amb la xarxa petita, les mètriques de la millor època només donen una petita imatge del que està passant, és per això que cal veure com evolucionen les mètriques durant l'entrenament.




**Figura 39:** Comparativa mAP 0.5:0.95 xarxa large



**Figura 40:** Comparativa mAP 0.5 xarxa large




**Figura 41:** Comparativa precisió xarxa gran

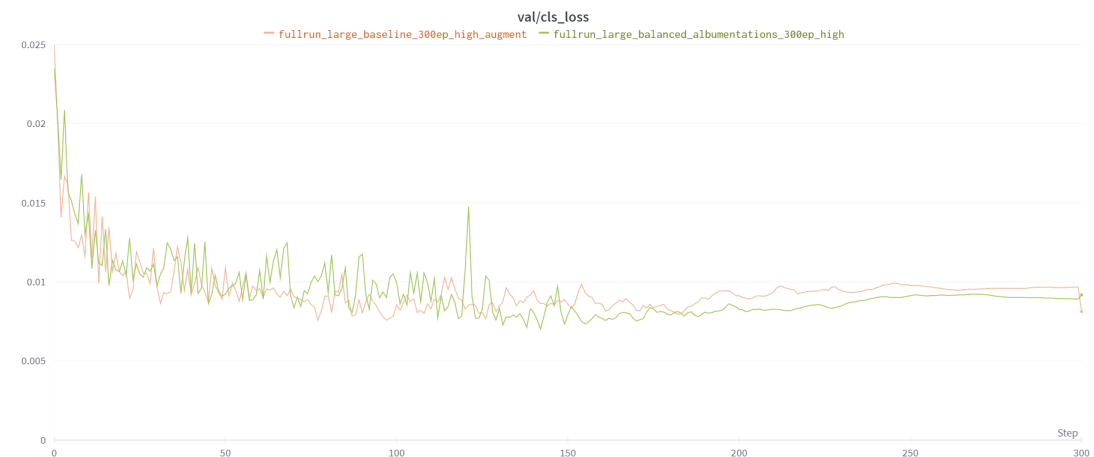


**Figura 42:** Comparativa recall xarxa gran


Igual que en la xarxa nano podem veure que les dues versions de la xarxa tenen un comportament similar, durant les primeres èpoques és millor la xarxa base, però de cara al final la xarxa balancejada i augmentada és lleugerament superior.



**Figura 43:** Comparativa box loss xarxa gran



**Figura 44:** Comparativa cls loss xarxa gran



**Figura 45:** Comparativa obj loss xarxa gran

Amb les mètriques de perduda podem veure com clarament la xarxa balancejada i augmentada tarda més en tenir overfit i és considerablement inferior.

## 5 Conclusions

Finalment, podem concloure que per un dataset petit i extremadament desequilibrat com es pot veure a la [Figura 21](#), no s'ha observat millora en les mètriques de la millor època tot i retardar l'overfit com podem veure a la [Subsubsecció 4.1.1](#) i [Subsubsecció 4.2.1](#).

També podem concloure que sí que hi ha una, petita, millora amb la xarxa gran respecte a la petita, tot i que això ve a canvi de tardar un temps considerablement superior en l'entrenament, en 8 hores s'han pogut entrenar 1000 èpoques en la xarxa nano però 300 en la gran. I també es veu incrementat considerablement el temps d'inferència per la xarxa large, per una mateixa CPU amb les mateixes optimitzacions es tarden 2500 ms per la large i 200 ms per la nano.

Això és especialment crític si es vol executar en temps real, doncs necessitaríem processar en 40 ms si volem processar un vídeo a 25 fps.

Aquestes diferències al temps d'inferència són causades per la diferència del tamany de la xarxa.

Per millorar els resultats obtinguts a aquest treball es recomana obtenir més dades, sobretot de les classes amb menys instàncies, tot i ser complicat, ja que aquestes classes minoritàries també ho són a la realitat.

Finalment cal destacar que els models derivats d'aquest treball estan sent utilitzats per EbreDrone per tal de reduir el temps de realització dels informes i està sent millorada per obtenir millor rendiment.

## Referències

- [1] HUANG, Jonathan ; RATHOD, Vivek ; SUN, Chen ; ZHU, Menglong ; KORATTIKARRA, Anoop ; FATHI, Alireza ; FISCHER, Ian ; WOJNA, Zbigniew ; SONG, Yang ; GUADARRAMA, Sergio ; MURPHY, Kevin: *Speed/accuracy trade-offs for modern convolutional object detectors*. 2016. – URL <https://arxiv.org/abs/1611.10012>
- [2] JOCHER, Glenn ; CHAURASIA, Ayush ; STOKEN, Alex ; BOROVEC, Jirka ; NANOCODE012 ; KWON, Yonghye ; TAOXIE ; FANG, Jiacong ; IMYHXY ; MICHAEL, Kalen ; LORNA ; V, Abhiram ; MONTES, Diego ; NADAR, Jebastin ; LAUGHING ; TKIANAI ; YXNONG ; SKALSKI, Piotr ; WANG, Zhiqiang ; HOGAN, Adam ; FATI, Cristi ; MAMMANA, Lorenzo ; ALEXWANG1900 ; PATEL, Deep ; YIWEI, Ding ; YOU, Felix ; HAJEK, Jan ; DIACONU, Laurentiu ; MINH, Mai T.: *ultralytics/yolov5: v6.1 - TensorRT, TensorFlow Edge TPU and OpenVINO Export and Inference*. Februar 2022. – URL <https://doi.org/10.5281/zenodo.6222936>
- [3] LUCIDV01D: *Scikit-learn: How to obtain True Positive, True Negative, False Positive and False Negative*. 2017. – URL <https://stackoverflow.com/questions/31324218/scikit-learn-how-to-obtain-true-positive-true-negative-false-positive-and-fal/43331484#43331484>
- [4] OTERO, Alejandro D. ; PONTA, Fernando L. ; LAGO, Lucas I.: Structural Analysis of Complex Wind Turbine Blades: Flexo- Torsional Vibrational Modes. In: CARRIVEAU, Rupp (Hrsg.): *Advances in Wind Power*. Rijeka : IntechOpen, 2012, Kap. 5. – URL <https://doi.org/10.5772/51142>
- [5] SHIHAVUDDIN, ASM ; CHEN, Xiao ; FEDOROV, Vladimir ; NYMARK CHRISTENSEN, Anders ; ANDRE BROGAARD RIIS, Nicolai ; BRANNER, Kim ; BJORHOLM DAHL, Anders ; REINHOLD PAULSEN, Rasmus: Wind Turbine Surface Damage Detection by Deep Learning Aided Drone Inspection Analysis. In: *Energies* 12 (2019), Nr. 4. – URL <https://www.mdpi.com/1996-1073/12/4/676>. – ISSN 1996-1073
- [6] WIKIPEDIA: *Evaluation measures (information retrieval)* — *Wikipedia, The Free Encyclopedia*. [http://en.wikipedia.org/w/index.php?title=Evaluation%20measures%20\(information%20retrieval\)&oldid=1077036698](http://en.wikipedia.org/w/index.php?title=Evaluation%20measures%20(information%20retrieval)&oldid=1077036698). 2022
- [7] WIKIPEDIA: *Precision and recall* — *Wikipedia, The Free Encyclopedia*. <http://en.wikipedia.org/w/index.php?title=Precision%20and%20recall&oldid=1089762876>. 2022
- [8] YOHANANDAN, Shivy: *mAP (mean Average Precision) might confuse you!* 2020. – URL <https://towardsdatascience.com/map-mean-average-precision-might-confuse-you-5956f1bfa9e2>