



Universitat de Girona

ESCOLA POLITÈCNICA SUPERIOR

DESENVOLUPAMENT D'UN
PROTOTIP D'EINA D'AJUT AL
DIAGNÒSTIC PER EL CÀNCER
DE MAMA

Treball Final de Grau

Grau en Enginyeria Biomèdica

Autora:

Ursula Castellano Tallón

Tutor:

Robert Marti Marly

Juny 2023

Índex

Índex	1
1 INTRODUCCIÓ	3
2 CONCEPTES PREVIS	3
2.1 Càncer de mama	4
2.2 Intel·ligència artificial	6
2.2.1 Machine Learning	7
2.2.2 Deep Learning	7
2.2.3 Xarxes neuronals convolucionals	8
2.2.4 Models/Arquitectures	9
2.2.5 Mètriques	9
2.3 Programari	10
2.3.1 Python	10
2.3.2 Jupyter Notebook	11
2.3.3 Fast.ai	11
2.3.4 Hugging Face Spaces	12
2.3.5 MONAI Deploy	12
2.3.6 Anaconda	13
2.3.7 Entorns virtuals	13
2.3.8 Docker	14
3 ESTAT DE L'ART	14
4 HIPÒTESIS I OBJECTIUS	16
4.1 Pregunta de recerca	16
4.2 Hipòtesis	16
4.3 Objectiu	17
5 MATERIALS I MÈTODES	17
5.1 Bases de dades	17
5.1.1 Ecografia	17
5.1.2 Mamografia	17
5.2 Normativa i aspectes legals	18
5.3 Metodologia	18
5.3.1 Models	19
5.3.2 Deployment	20
6 RESULTATS	23

6.1	Models	23
6.1.1	CAD-ECO	24
6.1.2	CAD-MAMA	25
6.2	Deployment	27
6.2.1	Hugging Face Spaces	27
6.2.2	MONAI Deploy	29
7	DISCUSSIÓ	32
7.1	Limitacions	32
7.2	Contribucions als objectius de desenvolupament sostenible (ODS) de les Nacions Unides	33
8	CONCLUSIONS	33
	Referències	35
9	ANNEX A CODI	37

1 INTRODUCCIÓ

Al 2020, es va diagnosticar càncer de mama a 2.3 milions de dones arreu del món, i 685.000 van morir a causa de la malaltia. Segons la Societat Espanyola d'Oncologia Mèdica (SEOM) [21], al 2023 es diagnosticaran 35.001 nous casos de càncer de mama. La detecció precoç d'aquesta malaltia és clau per millorar les taxes de supervivència i oferir un tractament efectiu als pacients.

El diagnòstic del càncer de mama es basa en una combinació de diferents mètodes i proves mèdiques que permeten detectar i confirmar la presència de la malaltia. Els programes de cribratge estan dissenyats per a detectar de manera precoç possibles casos de càncer de mama en dones asimptomàtiques. L'objectiu és detectar la malaltia en etapes inicials que és quan els tractaments tenen una major probabilitat d'èxit. La prova d'imatge mèdica per el cribratge del càncer és la mamografia, a vegades es combina amb l'ecografia.

En els darrers anys, els avenços en intel·ligència artificial i aprenentatge profund han revolucionat el camp de la detecció del càncer de mama. La IA s'aplica a l'anàlisi de mamografies, i altres estudis, per identificar automàticament possibles irregularitats i ajudar als radiòlegs a prendre decisions.

L'objectiu principal d'aquest treball aprofitar les capacitats de la intel·ligència artificial per intentar millorar la precisió i l'eficiència en la detecció del càncer de mama. Per aconseguir-ho, seguirem tot un procés que va des de l'entrenament d'un model d'aprenentatge automàtic fins al desenvolupament d'una aplicació per a l'ajut del diagnòstic de la malaltia.

En primer lloc, entrenarem els models d'aprenentatge automàtic amb diferents conjunts de dades i utilitzant diferents eines d'intel·ligència artificial. Aquestes eines ens ajudaran a crear els models de manera ràpida i eficient.

A continuació, s'utilitzaran aquests models d'aprenentatge automàtic per al desenvolupament de les aplicacions. Ho farem de dues maneres diferents, utilitzant diferents eines dedicades al desplegament d'aplicacions.

En conclusió, aquest treball final de grau té com a objectiu desenvolupar una aplicació per a l'ajut del diagnòstic del càncer de mama, aprofitant les tècniques d'anàlisi d'imatge mèdica, presents en diverses eines d'intel·ligència artificial, per millorar la precisió i l'abast de la detecció de la malaltia.

2 CONCEPTES PREVIS

A continuació, es presenten una sèrie de descripcions detallades, amb l'objectiu de proporcionar al lector d'aquest treball la informació necessària per entendre el contingut present en cada un dels següents capítols.

2.1 Càncer de mama

Per poder entendre què és el càncer de mama, primer s'ha de conèixer l'anatomia de la mama. Tal i com podem veure a la Figura 1, la mama està composta de 10 a 20 lòbuls, els quals es divideixen en seccions més petites anomenades lobels. Els lòbuls són els que contenen les glàndules que s'encarreguen de la producció de llet durant la lactància. La llet passa del lòbul al mugró per uns conductes que s'anomenen ductes galactòfors. Trobem també teixit fibrós, greix i el múscul pectoral.




Figura 1: Anatomia de la mama femenina [21]

A més, les mames tenen vasos limfàtics que condueixen als ganglis limfàtics. Els ganglis limfàtics són els encarregats de protegir-nos de malalties, atrapant bacteries, cèl·lules tumorals i altres substàncies nocives. Cal recordar que el sistema limfàtic és similar al sistema sanguini, ens recorren tot el cos gràcies als vasos.

Així doncs, el càncer de mama és la proliferació incontrolada i accelerada de les cèl·lules de l'epiteli glandular, és a dir, les glàndules mamàries que s'encarreguen de produir llet. Són cèl·lules que han incrementat la seva capacitat reproductiva. Aquestes cèl·lules cancerígenes poden disseminar-se a través dels vasos limfàtics, o de la sang, i així arribar fins a altres òrgans del cos. Si aquest tipus de cèl·lules es dispersen poder arribar a adherir-se a altres teixits i créixer, formant el que coneixem com a metàstasi.

Segons la SEOM, Societat Espanyola d'Oncologia Mèdica, el càncer de mama és el càncer més freqüent en la dona espanyola tot i que pot aparèixer tant en homes com en dones. La realitat és que més del 99% dels casos són dones. L'estimació de nous casos de càncer de mama a Espanya al 2022 és de 34.750 [21]. Es calcula que 1 de cada 8 dones tindrà càncer de mama en algun moment de la seva vida.

La causa o les causes que fan que una persona tingui càncer de mama encara no estan clares, tot i que si s'han identificat nombrosos factors de risc associats. Aquests factors de risc són:

1. L'edat. Més edat, més risc.
2. Haver patit un càncer de mama invasiu.
3. Hiperplàsia atípica. És una acumulació de cèl·lules als ductes i lòbuls mamaris.
4. Pit amb molta densitat mamaria.
5. Factors reproductius. No haver estat embarassada mai, aparició de la menopausa tard, ..
6. Teràpia hormonal substitutiva. Prendre estrògens, progesterona, ..
7. Exposició a radiacions ionitzants.
8. Consum d'alcohol.
9. Obesitat.
10. Predisposició genètica. Antecedents familiars o mutacions genètiques.

El càncer de mama és un important problema de salut a Espanya, tant per la seva elevada incidència i mortalitat, com per els seus efectes físics, psicològics i econòmics. Tot i que hi han avenços diagnòstics i terapèutics, el seu pronòstic depèn de l'estat de la malaltia en el moment de la detecció. Per aquest motiu, els programes de cribratge (diagnòstic), la millora dels tractaments i l'estadi en el que es diagnostica la malaltia són factors que influeixen en la supervivència.

Per exemple, un càncer de mama en estadi I és un càncer en una etapa inicial, i un càncer de mama en estadi IV, és un càncer bastant avançat que s'ha estès per altres parts del cos. Si es diagnostica la malaltia en estadi I, la supervivència és més del 98%, mentre que si es diagnostica en un estadi IV, la supervivència és del 24%.

Les proves d'imatge són les que s'utilitzen per a l'estudi i el diagnòstic de patologies de la mama. Aquestes proves són:

- Mamografia: aquesta prova fa ús dels raigs X per a la detecció d'anomalies a la mama. No són fiables al 100%. Poden produir ombres sospitoses que poden ser diagnosticades com a malignes, quan no ho són, falsos positius, o es poden obviar lesions malignes, falsos negatius.
- Ecografia: aquesta prova utilitza els ultrasons per a produir una imatge. Moltes vegades aquesta tècnica complementa la mamografia, ja que es poden distingir lesions quístiques, són lesions plenes de líquid normalment no tumorals, de lesions solides, més sospitoses. L'ecografia també pot valorar l'estat dels ganglis limfàtics de l'axil· la, que és el primer lloc de disseminació del càncer de mama.
- Resonància magnètica nuclear (RMN): aquesta prova utilitza els camps magnètics per a obtenir imatges. És molt útil i necessària en dones amb un teixit mamari dens, dones amb mutació del gen BRCA o dones que porten pròtesis de silicona.




Figura 2: a. Ecografia [6] b. RM de mama [11] c. Mamografia

Es mostra un exemple visual d'aquests tipus d'imatges a la Figura 2.

La mamografia és la prova de cribatge més efectiva per a dones amb un risc mitjà. Els programes de cribatge mitjançant mamografia aconsegueixen una disminució en la mortalitat per càncer de mama. Actualment, totes les Comunitats Autònomes tenen programes de cribatge poblacional de càncer de mama.

Sempre que existeixi la sospita de càncer de mama, bé per una exploració física o bé per una mamografia de rutina o cribatge, s'inicia un estudi per a confirmar o rebutjar aquesta sospita. Les proves d'imatge orienten sobre el diagnòstic, però sempre es necessita d'una confirmació amb biòpsia.

2.2 Intel·ligència artificial

La intel·ligència artificial és un àrea d'estudi i desenvolupament de tecnologia que cerca crear sistemes capaços de realitzar tasques que normalment necessiten la intel·ligència humana com el reconeixement d'imatges.

A continuació, s'explicaran subconjunts de la IA per a la millor comprensió d'aquest treball.

2.2.1 Machine Learning

L'aprenentatge automàtic, també conegut com machine learning en anglès, és una branca de la intel·ligència artificial que es centra en el desenvolupament d'algorismes i models que permeten als ordinadors aprendre i prendre decisions basades en dades.

Es basa en la anàlisi de patrons i la construcció de models estadístics a partir de dades d'entrenament, en lloc de seguir instruccions específiques o haver sigut programades explícitament per l'ocasió.

Existeixen diferents categories en l'aprenentatge automàtic, sent les més comunes:

- **Aprenentatge supervisat:** s'entrena un model utilitzant les dades d'entrada juntament amb les corresponents etiquetes. L'objectiu és que es puguin fer prediccions amb l'ajuda d'aquestes dades d'entrada.
- **Aprenentatge no supervisat:** el model s'entrena utilitzant només dades d'entrada sense sortides etiquetades. L'objectiu és trobar patrons, estructures o agrupacions en les dades sense una guia.
- **Aprenentatge per reforç:** el model aprèn a prendre decisions òptimes en un entorn interactiu. Es basa en aprendre a través de la interacció continua amb l'entorn i la retroalimentació en forma de recompenses o càstigs.

L'aprenentatge automàtic s'utilitza en diverses àrees com el reconeixement de veu, la visió per computador, el processament de llenguatge natural, el diagnòstic mèdic i moltes altres. Permet a les màquines aprendre i adaptar-se a partir de dades, el que pot donar a lloc resultats precisos i automatitzar tasques complexes.

2.2.2 Deep Learning

L'aprenentatge profund, també conegut com Deep Learning en anglès, és una subbranca de l'aprenentatge automàtic (Machine Learning) que es centra en la construcció i entrenament de xarxes neuronals artificials profundes.

Aquestes xarxes neuronals artificials són models que estan inspirats en el funcionament del cervell humà. Estan formades per capes d'unitats que s'anomenen neurones, i cada neurona s'encarrega de fer càlculs i transmetre les senyals a través de les connexions.

La profunditat de les xarxes neuronals és la característica principal de l'aprenentatge profund, que vol dir que tenen diverses capes amagades entre la capa d'entrada i la capa de sortida. Aquesta estructura en capes permet a les xarxes neuronals aprendre i extreure automàticament característiques i representacions de major nivell a partir de les dades d'entrada, això és pot veure representat a la




Figura 3: Estructura de capes de les xarxes neuronals artificials [8]

Figura 3, on tenim les capes d'entrada (Input), les capes amagades (Hidden), i per últim, les capes de sortida (Output). Gràcies a aquesta estructura ha sigut capaç de predir l'entrada, imatge d'un gos.

L'aprenentatge profund ha evidenciat ser molt efectiu en tasques de reconeixement de patrons complexos, com el reconeixement d'imatges, el processament de llenguatge natural i la visió per computador. Al utilitzar grans conjunts de dades d'entrenament i poder computacional, les xarxes neuronals profundes poden aprendre a classificar i reconèixer patrons amb una capacitat i precisió de propagació impressionants.

Resumint, l'aprenentatge profund és una subcategoria de l'aprenentatge automàtic que es basa en xarxes neuronals artificials profundes. Permet a les màquines extreure i aprendre automàticament representacions i característiques de les dades, el que ens permet fer tasques de reconeixement de patrons complexos.

2.2.3 Xarxes neuronals convolucionals

Les xarxes neuronals convolucionals, o més conegudes com a CNN (Convolutional Neural Networks) són un tipus especialitzat d'arquitectura de xarxes neuronals profundes. Són estructures dissenyades per extreure característiques i realitzar tasques de processament d'imatges. Estan compostes per capes de convolució, activació, pooling i capes totalment connectades.

En les CNN, les capes de convolució apliquen filtres, també anomenats kernels, per extreure característiques locals de la imatge, mentre que les capes d'activació introdueixen no linealitat a la xarxa. Les capes de pooling redueixen les dimensions espacials de les característiques, disminuint la quantitat de paràmetres i la complexitat computacional. Per últim, les capes totalment connectades classifiquen les característiques extretes en categories específiques.

2.2.4 Models/Arquitectures

Existeixen diferents arquitectures de CNN conegudes, com LeNet, AlexNet, VGGNet, GooLeNet (Inception), ResNet i DenseNet, entre d'altres. La diferència entre aquestes arquitectures és la quantitat de capes, la distribució de les capes i la complexitat de la xarxa. Cada arquitectura té les seves pròpies característiques i s'utilitza en diferents situacions segons les necessitats del problema. A més, es tracten de models preentrenats.

Un model preentrenat, significa que ha sigut entrenat prèviament amb grans conjunts de dades, com ImageNet, que conté milions d'imatges i milers de categories diferents. Durant l'entrenament, les arquitectures, o els models, aprenen a extreure característiques importants per a la classificació d'objectes.

Aquestes arquitectures s'han desenvolupat per millorar el rendiment i la precisió de les CNN en tasques de classificació d'imatges, detecció d'objectes, segmentació semàntica i altres reptes relacionats amb el processament d'imatges.

2.2.5 Mètriques

En un context general, les mètriques són mesures o indicadors utilitzades per quantificar, avaluar o comparar diversos aspectes o característiques d'un sistema, procés, rendiment, resultat, etc.

En el context d'aquest treball, les mètriques són utilitzades per avaluar l'exercici i qualitat dels models i algorismes. Les utilitzarem per mesurar i comprendre el rendiment d'un model en funció de les dades d'entrada i les sortides, que en aquest cas seran prediccions generades.

Existeixen diferents tipus de mètriques depenen del problema i del tipus de dades que s'analitza. Les que utilitzarem seran:

- Matriu de confusió (Confusion Matrix): és una taula que s'utilitza per visualitzar la pràctica d'un model de classificació, podem veure un exemple a la Figura 4. És útil per veure com classifica les imatges en diferents categories. Aquestes categories són:
 - Vertaders positius (True Positive): clarrificades correctament com a positives
 - Vertaders negatius (True Negative): classificades correctament com a negatives
 - Falsos positius (False Positive): classificades incorrectament com a positives
 - Falsos negatius (False Negative): classificades incorrectament com a negatives
- Sensibilitat (Sensitivity): és la proporció de vertaders positius respecte del número total de positius. Es calcula amb la següent fórmula:

$$Sensibilitat = \frac{TP}{TP + FN} \quad (1)$$

		True Class	
		Positive	Negative
Predicted Class	Positive	TP	FP
	Negative	FN	TN

Figura 4: Matriu de confusió [18]

- Especificitat (Specificity): és la proporció de vertaders negatius respecte del número total de negatius. Es calcula amb la següent fórmula:

$$Especificitat = \frac{TN}{TN + FP} \quad (2)$$

- Precisió (Accuracy): és la capacitat d'un model per realitzar prediccions correctes en comparació amb el total de prediccions realitzades. Es calcula amb la següent fórmula:

$$Precisió = \frac{TP + TN}{TP + TN + FP + FN} \quad (3)$$

- Corba ROC (Receiver Operating Characteristic): és una representació gràfica de la sensibilitat davant de l'especificitat per a un sistema classificador binari.
- Àrea sota la corba (AUC, Area Under the Curve): es calcula a partir de la corba ROC i proporciona la mesura de la capacitat general de discriminació del model. Pren valors entre 0 i 1, on els valors propers a 1 indiquen un millor rendiment del model.

2.3 Programari

2.3.1 Python

Python [22] és un llenguatge de programació interpretat i d'alt nivell. És molt popular gràcies a la seva facilitat d'ús i la seva llegibilitat. Es destaca per tenir una sintaxi clara i llegible, això facilita l'escriptura i comprensió del codi.

Python és un llenguatge interpretat, el que significa que el codi font s'executa directament per un intèrpret sense la necessitat d'una compilació prèvia. Això fa més ràpid el procés de desenvolupament.

A més, té una biblioteca estàndard extensa que ocupa una ampla varietat d'àrees, des de la manipulació d'operacions matemàtiques fins a accés a bases de dades i desenvolupament web. Aquesta

biblioteca estàndard dona al programadors una gran quantitat d'eines i funcionalitats preparades per utilitzar-se.

Python s'utilitza en una gran varietat d'aplicacions, des de scripting i desenvolupament web, fins a anàlisis de dades i aprenentatge automàtic. La seva versatilitat i facilitat d'ús han ajudat al seu creixement i reconeixement continu.

2.3.2 Jupyter Notebook

Jupyter Notebook [12] és una aplicació web de codi obert que permet crear i compartir documents interactius que contenen codi, visualitzacions, text explicatiu i altres elements. És un eina molt utilitzada en investigació, educació i ciència de dades.

Els documents de Jupyter Notebook s'organitzen en cel·les, on cada cel·la pot contenir tant text com codi. Això permet unir explicacions de text amb fragments de codi executable en el mateix document. Els usuaris poden executar i modificar el codi en temps real, el que fa més fàcil l'experimentació, la anàlisis de dades i la generació de resultats.

Jupyter Notebook es caracteritza per suportar diferents llenguatges de programació, tot i que es va originar amb Python, es compatible amb altres llenguatges com són R, Julia, Scala, etc. També permet explorar i presentar les dades de forma més dinàmica i comprensible, facilita la creació de visualitzacions interactives com gràfics, taules i mapes.

Els notebooks de Jupyter es poden compartir fàcilment, ja sigui enviant l'arxiu del notebook o utilitzant serveis al núvol com GitHub. Això permet la col·laboració entre múltiples usuaris, qui poden veure, executar i modificar els notebooks de manera col·laborativa.

Jupyter Notebook s'executa en un navegador web i proporciona una arquitectura client-servidor per interactuar amb els notebooks.

2.3.3 Fast.ai

Fast.ai [10] és una biblioteca d'aprenentatge automàtic. Va ser desenvolupat amb l'objectiu d'accelerar l'aprenentatge automàtic, permetent als desenvolupadors crear models d'aprenentatge profund de manera ràpida i eficient.

Fast.ai es basa en Python i utilitza altres biblioteques populars d'aprenentatge automàtic, com PyTorch, per facilitar la implementació de models complexos d'aprenentatge profund. La biblioteca proporciona una interfície d'alt nivell que simplifica el procés de construcció, entrenament i desplegament de models, el que la fa accessible per usuaris amb diferents nivells d'experiència en aprenentatge automàtic.

2.3.4 Hugging Face Spaces

Hugging Face [7] és una plataforma web amb més de 120.000 models, 20.000 conjunts de dades i 50.000 aplicacions de demostració (Spaces). Tots ells són de codi obert i estan a l'abast del públic en una plataforma en línia. Qualsevol pot explorar, experimentar, col·laborar, compartir i construir en aquesta plataforma a través del Machine Learning.

Hugging Face Spaces és un subapartat de la plataforma, en el qual es permet als usuaris crear i compartir entorns interactius, aplicacions. Els usuaris poden crear aquests espais de treball virtuals, Spaces, on poden col·laborar, compartir idees i treballar en projectes en temps real aprofitant les capacitats de la plataforma, desenvolupament d'intel·ligència artificial i processament de llenguatge natural.

A més, Spaces ofereix als usuaris una interfície intuïtiva i amigable que es permet interactuar amb altres usuaris, fer preguntes, obtenir feedback i aprendre d'altres. També s'integra amb altres eines populars de la plataforma Hugging Face com són els models preentrenats.

En resum, Hugging Face Spaces és una plataforma en línia que permet als usuaris crear espais de treball col·laboratiu per a compartir idees, col·laborar en projectes i experimentar amb models.

2.3.5 MONAI Deploy

MONAI [19] (Medical Open Network for AI) és una biblioteca de codi obert i plataforma d'aprenentatge profund, Machine Learning, específicament dissenyada per al processament d'imatges mèdiques. Va ser desenvolupada per el Laboratori d'Imatges i Computació Biomèdica de l'Hospital d'Investigació St. Jude en col·laboració amb altres centres d'investigació i NVIDIA, l'empresa de software que dissenya unitats de processament de gràfics, interfícies de programació d'aplicacions per a la ciència de dades i computació d'alt rendiment.

MONAI està dissenyat per facilitar la investigació i el desenvolupament d'algorismes d'aprenentatge automàtic (Machine Learning) i d'aprenentatge profund (Deep Learning) en el camp de la investigació mèdica. Proporciona eines i funcionalitats que ajuden als investigadors i desenvolupadors a treballar amb dades mèdiques, entrenar models d'aprenentatge automàtic i avaluar el rendiment dels models.

MONAI Deploy [4] vol convertir-se en l'estàndard per desenvolupar, empaquetar, provar, desplegar i executar aplicacions mèdiques d'intel·ligència artificial (IA) en producció clínica. El que fa MONAI Deploy és crear un conjunt de passos intermedis en els que els investigadors i metges poden confiar en les tècniques i enfocaments utilitzats amb la IA.

Podem dir que MONAI Deploy és un eina que simplifica el procés de transformar models d'investigació en aplicacions pràctiques i accessibles. És una molt bona opció per a implementar solucions

d'intel·ligència artificial en l'àmbit mèdic.

2.3.6 Anaconda

Anaconda [2] és una plataforma de distribució de codi obert que s'utilitza principalment per al processament i anàlisi de dades. Esta dissenyada per facilitar la gestió de paquets, la creació d'entorns de desenvolupament i l'execució d'aplicacions en llenguatges de programació com són Python i R.

La principal avantatge és la seva capacitat per gestionar de manera eficient les dependències i configuracions de software necessàries per projectes de ciència de dades i anàlisi. A més, proporciona un administrador de paquets anomenat conda que facilita la instal·lació, actualització i eliminació de paquets i llibreries.

També inclou un conjunt de més de 1.500 paquets de codi obert com NumPy, Pandas, TensorFlow i SciPy, entre d'altres. Aquests paquets són molt utilitzats en aprenentatge automàtic (Machine Learning), visualització de dades, anàlisi estadístic i computació científica.

2.3.7 Entorns virtuals

Un entorn virtual, o virtual environment com es coneix en anglès, és una eina que s'utilitza per crear un entorn aïllat i independent en un sistema informàtic, on es poden instal·lar i gestionar diferents versions de paquets, biblioteques i dependències de software.

Quan es treballa en desenvolupament de software, a vegades es necessari treballar en múltiples projectes que poden requerir diferents versions de les mateixes biblioteques o dependències. En aquest moment es on es fan servir els entorns virtuals. Permeten crear un espai separat on es poden instal·lar i mantenir els paquets necessaris per un projecte específic sense interferir amb altres projectes o el sistema operatiu.

Al crear un entorn virtual, es crea una carpeta on hi ha una còpia aïllada de la versió de Python, o un altre llenguatge de programació, i les biblioteques i dependències que es necessiten. Això permet que cada projecte tingui el seu propi entorn aïllat amb la seva configuració específica. Es poden instal·lar, actualitzar o eliminar paquets sense afectar altres projectes.

Així doncs, un entorn virtual és un espai aïllat on es pot instal·lar i gestionar versions concretes de paquets i biblioteques per un projecte.

2.3.8 Docker

Docker [5] és una plataforma de codi obert per automatitzar el desplegament i l'administració d'aplicacions en entorns aïllats anomenats contenidors. Un contenidor és una unitat portàtil i lleugera que conté tot el necessari per executar una aplicació. Conté el codi, les biblioteques i les dependències.

La tecnologia de contenidors Dockers proporciona una forma sòlida i reproduïble d'empaquetar una aplicació i totes les seves dependències en una sola imatge. La imatge es pot executar en qualsevol entorn amb Docker instal·lat, el que permet que sigui fàcil de transferir.

Utilitzant Docker pots crear, distribuir i executar aplicacions de manera fàcil i ràpida, ja que les imatges dels contenidors són autònomes i no depenen de la configuració del sistema amb el que s'està executant.

En poques paraules, Docker és una tecnologia de contenidors que simplifica l'administració i desplegament d'aplicacions al oferir-nos un entorn portàtil i aïllat per a la seva execució. Això facilita la implementació ràpida i estable d'aplicacions en diferents entorns.

3 ESTAT DE L'ART

Els primers sistemes CAD (Computer Aided Detection) van aparèixer a la dècada de 1960 i el seu objectiu era ajudar a combatre els errors humans i optimitzar la cerca de càncers en imatges que presentaven un teixit mamari dens. Hi ha dos tipus de sistemes CAD, el de detecció i els de classificació.

La primera versió de CAD per mamografia va ser aprovada per l'Administració d'Aliments i Medicaments d'EE.UU. al 1998. La intenció original dels primers sistemes CAD era detectar càncers subtils que, d'un altra manera, els radiòlegs podrien haver passat per alt. Les primeres versions d'aquests sistemes CAD s'anomenen CAD tradicionals. El CAD tradicional es centra en la detecció d'anomalies com masses, asimetries, calcificacions i distorsions. Es va concebre com a segon lector en el context de la doble lectura, que representa un estàndard d'atenció en països europeus i ajuda a augmentar la detecció de càncer de mama.

Tot i que els CADs tradicionals van sorgir aviat, la seva fallida es va deure a algunes limitacions tècniques. Es basaven en recursos informàtics limitats, és a dir, unitats de processament central (CPU) més lentes i falta de processament paral·lel. Estaven entrenats amb conjunts de dades molt petits, ja que hi havia poca disponibilitat de mamografies digitals i utilitzaven exàmens amb mala qualitat d'imatge, utilitzaven pel·lícules digitalitzades. L'aplicació resultant no era tan robusta com podria haver sigut. La insuficient capacitat de processament informàtic també va impedir que funcionessin plenament per avaluar múltiples vistes monogràfiques o integrar estudis previs.

Referència	Base de dades	Resultats
Zhu et al. [27] (2016)	INBreast	AUC = 0.858
Kooi et al. [16] (2016)	Programa de cribratge als Països Baixos	AUC = 0.941
Teare et al. [24] (2017)	DDSM i ZMDS	AUC = 0.922
Al-masni et al. [17] (2017)	DDSM	AUC = 0.965
Kim et al. [14] (2017)	Multiinstitucional	AUC = 0.903-0.906
Geras et al. [9] (2018)	Pròpia	AUC = 0.688
Ribli et al. [23] (2018)	DDSM i INBreast	AUC = 0.95
Chougrad et al. [3] (2018)	DDSM, BCDR i INBreast	AUC = 0.98
Kim et al. [15] (2020)	Multiinstitucional	AUC = 0.959

Taula 1: Sistemes CAD. DDSM = Digital Database for Screening Mammography, ZMDS = Zebra Mammography Dataset, BCDR = Breast Cancer Digital Repository. AUC = Area Under the Curve

Els CADs tradicionals no estaven dissenyats per a la retroalimentació i l'aprenentatge continu, no milloraven el seu rendiment de forma independent. La limitació més important és que el CAD tradicional es basa en l'experiència humana com a estàndard de referència, que no sempre és la veritat absoluta.

Els sistemes CAD basats en aprenentatge profund (Deep Learning) ja no requereixen de tanta ajuda humana, aprenen a diferenciar les característiques que millor prediuen els resultats de forma independent i poden ser capaços d'identificar noves característiques no conegudes. La capacitat de retroalimentació i aprenentatge continu permet que el CAD millori amb el temps. Els algorismes de DL es poden entrenar per reconèixer patrons de dades d'imatge, correlacionar-los amb dades que sabem segur que són tumors i avaluar els riscos quan es reconeix un patró similar, és a dir, poder predir la probabilitat de càncer.

Aquest canvi en el disseny dels CAD es possible gràcies als avenços en tecnologia informàtica, ciència de dades i desenvolupament d'algorismes. La velocitat de processament i la memòria dels ordinadors han augmentat exponencialment, gràcies a les unitats de processament gràfic més ràpides i al processament paral·lel.

Els sistemes CAD en mamografia han evolucionat des de els seus inicis en la detecció de masses i microcalcificacions fins a sistemes més avançats que integren intel·ligència artificial i aprenentatge profund (Deep Learning). Aquests sistemes ajuden als radiòlegs en la detecció precoç i l'anàlisi de lesions mamàries, millorant la precisió i eficiència en el diagnòstic del càncer de mama. A la Taula 1 podem veure un resum dels sistemes CADs desenvolupats ens els darrers anys, les bases de dades utilitzades per al seu desenvolupament, totes de mamografies, i la seva precisió i rendiment.

Tots els sistemes CAD de la Taula 1, són sistemes detectors o classificadors de càncer de mama d'imatges de mamografia. Les següents bases de dades estan compostes de:

- INBreast – 410 imatges
- DDSM – més de 6.000 imatges
- ZMDS – 1.739 imatges
- BCDR – 600 imatges

Zhu et al. [27] van desenvolupar un classificador, utilitzant la base de dades de INBreast. Per l'entrenament del model classificador van fer servir l'arquitectura preentrenada Multiinstance.

Els treballs de Al-masni et al. [17] i Ribli et al. [23] proposen desenvolupar un sistema detector i classificador simultani. Tots dos van fer servir la mateixa base de dades de DDSM, però diferents models preentrenats. Els primers van utilitzar YOLO (You Only Look Once) i els altres Faster R-CNN.

La resta de treballs van proposar el desenvolupament d'un sistema CAD per a la detecció del càncer de mama. Mentre que Teare et al. [24], Al-masni et al. [17], Ribli et al. [23], Chougrad et al. [3] i Kim et al. [15] proposen utilitzar la mateixa base de dades per a l'entrenament del model, DDSM, Geras et al. [9], Kooi et al. [16] i Kim et al. [14] ho fan utilitzant bases de dades pròpies. Molts d'aquests treballs plantejen utilitzar bases de dades combinades, és a dir, utilitzar diferents bases de dades provinents de diferents centres o institucions. La majoria utilitza arquitectures similars com són ResNet, VGG (Visual Geometry Group) i Inception (Google).

4 HIPÒTESIS I OBJECTIUS

4.1 Pregunta de recerca

Una possible pregunta de recerca per aquest treball final podria ser la següent:

Podríem ser capaços de desenvolupar, amb els coneixements adquirits durant el Grau, un eina per a l'ajut al diagnòstic del càncer de mama?

4.2 Hipòtesis

La hipòtesis seria:

Els sistemes CAD per el diagnòstic de càncer de mama poden ajudar als radiòlegs a millorar el diagnòstic en proves de mamografia provinents de programes de cribratge.

4.3 Objectiu

Els objectius s'han formulat tenint en compte la pregunta de recerca i la hipòtesis plantejades anteriorment.

Per tant, l'objectiu principal del treball és el següent:

Desenvolupar un eina per a l'ajut al diagnòstic del càncer de mama des del començament, passant per totes les seves etapes. Des de la implementació dels algorismes fins al desplegament d'aquests. Veurem el procés de dues aplicacions diferents, una per a la classificació de lesions tumorals en imatges d'ecografia i l'altre per a la detecció del càncer de mama en imatges de mamografia.

5 MATERIALS I MÈTODES

5.1 Bases de dades

A continuació descriurem les dades que s'han utilitzat per desenvolupar aquest projecte:

5.1.1 Ecografia

Aquesta base de dades està formada per un total de 116 imatges d'ecografia. Totes les imatges són tumorals, és a dir, hi apareix un tumor. Es divideixen de la següent manera:

- 54 imatges CYST - Cist, benigne
- 31 imatges FA – Fibroadenoma, benigne
- 31 imatges IDC – Carcinoma Ductal Invasiu, maligne

Les dades van ser recollides a l'UDIAT [26] Centre Diagnòstic de l'Hospital Universitari Parc Taulí [25]. Es troben en una base de dades pública. Es va utilitzar un ecògraf de la marca SIEMENS per a l'adquisició d'aquestes imatges.

5.1.2 Mamografia

La base de dades que s'ha utilitzat en aquest treball consta de 2.767 imatges de mamografia que provenen d'un challenge de Kaggle [13]. Es divideixen de la següent manera:

- 2058 imatges - Casos normals

- 709 imatges - Casos amb càncer

Les dades estan extretes del challenge RSNA Screening Mammography Breast Cancer Detection [13]. La base de dades original es compona d'un total de 54.713 imatges de mamografia, però per aquest treball, s'ha utilitzat una petita part d'aquesta base de dades. Les dades provenen de dos hospitals diferents, però no s'especifica el lloc ni la marca dels mamògrafs que s'han usat. El que si que sabem és que al primer hospital hi ha 3 mamògrafs i al segon hospital hi ha 7 mamògrafs, són amb els que s'han realitzat les imatges.

Sabem també que d'un mateix pacient tindrem com a mínim 4 imatges, que són les que corresponen. En alguns casos, el numero d'imatges per pacient és superior, podem suposar que és per que s'han necessitat repetir algunes, o que hi ha diferents controls d'un mateix pacient.

5.2 Normativa i aspectes legals

Tenint en compte que es tracta de dades d'accés públic podem tenir la certesa que aquestes han passat per el corresponent comitè d'ètica.

Les bases de dades que s'utilitzen en aquest projecte estan a l'abast públic. En el punt anterior s'explica la procedència d'aquestes.

Al tractar-se de dades públiques han de complir amb la normativa de privacitat i protecció de dades, és per aquest motiu que les dades ja ens han arribat completament anonimitzades.

Aquestes bases de dades han sigut prèviament revisades i aprovades per els comitès d'ètica corresponents, garantint així que l'ús de les dades es realitzi de manera ètica i respectant els drets de privacitat dels pacients que han participat en la recollida d'aquestes dades.

5.3 Metodologia

En aquest apartat s'explicarà pas per pas la feina realitzada per el desenvolupament i compliment de l'objectiu d'aquest treball final de grau. L'objectiu s'ha especificat anteriorment però, tal i com s'observa a la Figura 5, podem veure un resum gràfic d'aquest.

Hem d'esmentar que tots els codis dels quals es parlaran en aquest apartat, es podran trobar a l'Annex d'aquest treball.

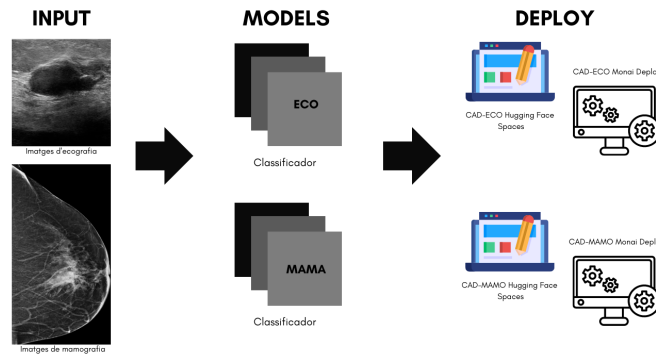


Figura 5: Diagrama de la metodologia proposada

5.3.1 Models

El primer pas va ser crear el model de classificació/predicció amb la base de dades corresponent a cada cas. Aquest model es va crear emprant Jupyter Notebook i Python.

Els models corresponen a: classificador per la base de dades d'ecografia i de detecció per a la base de dades de mamografia. Com l'objectiu principal no era crear un model predictiu/classificador, el que vàrem fer és un codi ben senzill, utilitzant la biblioteca fast.ai. Aquesta biblioteca ens va permetre crear dos models de manera ràpida i eficient fent ús de l'aprenentatge profund.

Com les dades són desbalancejades, és a dir, tenim moltes més imatges d'una classe que de l'altre, en el cas de les mamografies, i per les d'ecografia tenim poques imatges, el que vam fer servir va ser funcions de fast.ai les quals ens permeten fer un augment de dades, que és el que es coneix com a data augmentation en anglès. El que fa aquest augment de dades és generar més imatges a partir de les que ja tenim, és a dir, aplica modificacions per crear noves versions d'aquestes imatges. La finalitat és augmentar la quantitat i diversitat de les dades que el nostre model utilitzarà per l'entrenament.

S'han utilitzat diverses funcions facilitades per la biblioteca fast.ai per a realitzar l'entrenament dels nostres models. Hem fet servir arquitectures de xarxes neuronals prèviament entrenades, és a dir, preentrenades. L'arquitectura utilitzada ha sigut alexnet, que és la que ens ha donat millors resultats. Prèviament, n'havíem provat d'altres, com ResNet.

Una vegada ha estat entrenat el model, l'hem exportat en un tipus de fitxer anomenat .pkl. Un arxiu .pkl és un arxiu en Python que conté una representació serialitzada d'un objecte, el que permet guardar i recuperar objectes de Python de manera eficient. Aquest arxiu ens ajudarà a l'hora de crear les aplicacions en Hugging Face.

5.3.2 Deployment

El Deployment, o en català desplegament, és el procés d'implementar i posar en marxa una aplicació, servei o sistema en un entorn de producció. És l'etapa final del cicle de vida del desenvolupament de software, on el producte acabat va des de un entorn de desenvolupament a un entorn d'ús real.

L'objectiu és col·locar el model en un entorn, sense necessitat d'instal·lar llibreries, per a que sigui fàcil fer inferència, pensant en un usuari final. La inferència és el procés d'utilitzar un model entrenat per realitzar prediccions sobre noves dades d'entrada, aplicant els coneixements adquirits durant l'entrenament.

HUGGING FACE SPACES

Començarem explicant com es van desenvolupar les aplicacions a la plataforma web de Hugging Face. Només ho explicarem una vegada, tot i que hem fet dues aplicacions, una per les imatges d'ecografia i l'altre per les imatges de mamografia.

Per a la realització d'aquestes aplicacions, es va seguir el tutorial de Tanishq Abraham: Gradio + HuggingFace Spaces: A Tutorial [1].

Abans de fer cap cosa, ens vam assegurar que tenim un compte a la plataforma Hugging Face. Una vegada vàrem comprovar que tenim compte, o per defecte ens el vam fer, vam poder començar a crear un Space. S'ha de triar un nom per el repositori on hi haurà la nostra aplicació, un SDK que és el Software Development Kit, utilitzarem Gradio, i per últim, fer el nostre repositori públic, per a que altres usuaris puguin accedir-hi i provar-lo.

Superat el primer pas, vàrem clonar el nostre repositori d'Spaces en un directori local del nostre ordinador, això ens permet modificar més fàcilment els arxius que s'han d'incloure en aquest repositori. Una vegada clonat el repositori, ens vam descarregar els arxius .pkl que vàrem crear en el nostre notebook, on hi teníem el model classificador/detector. L'arxiu .pkl el vam copiar al directori. També va ser necessari crear un arxiu de Python i un arxiu de text. A l'arxiu de text s'han d'especificar totes les llibreries necessàries per executar el model que es troba a l'arxiu .pkl, mentre que a l'arxiu de Python s'han d'afegir les funcions necessàries per carregar el model, definir les entrades, sortides i la interfície de l'aplicació. Com a més a més, es van afegir unes imatges d'exemple per a que l'usuari pogués provar el funcionament de l'aplicació.

Realitzats tots els canvis necessaris al repositori, es van guardar totes les modificacions realitzades als diferents arxius i els vàrem carregar al repositori. S'ha de comprovar que no hi ha errors per a que l'Spaces construeixi l'aplicació i funcioni correctament.

Podem apreciar com va quedar l'aplicació dedicada a la classificació de tumors en imatges d'ecografia a la Figura 6. Mentre que a la Figura 7, podem apreciar l'aplicació dedicada a la predicció del

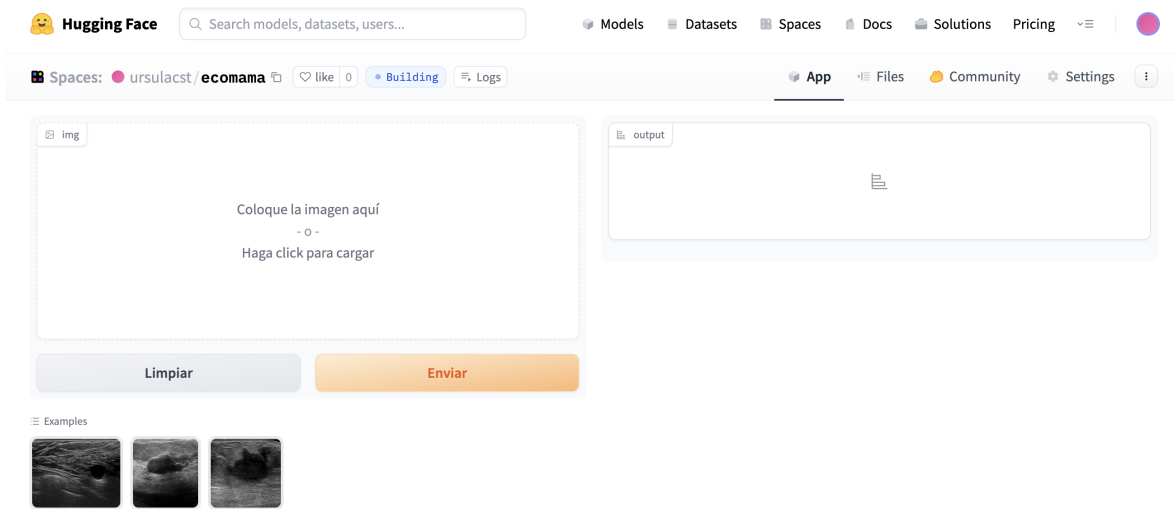


Figura 6: Hugging Face Spaces Ecografia

càncer de mama en mamografia. Com podem veure, totes dues tenen imatges d'exemple per a poder provar el funcionament dels models.

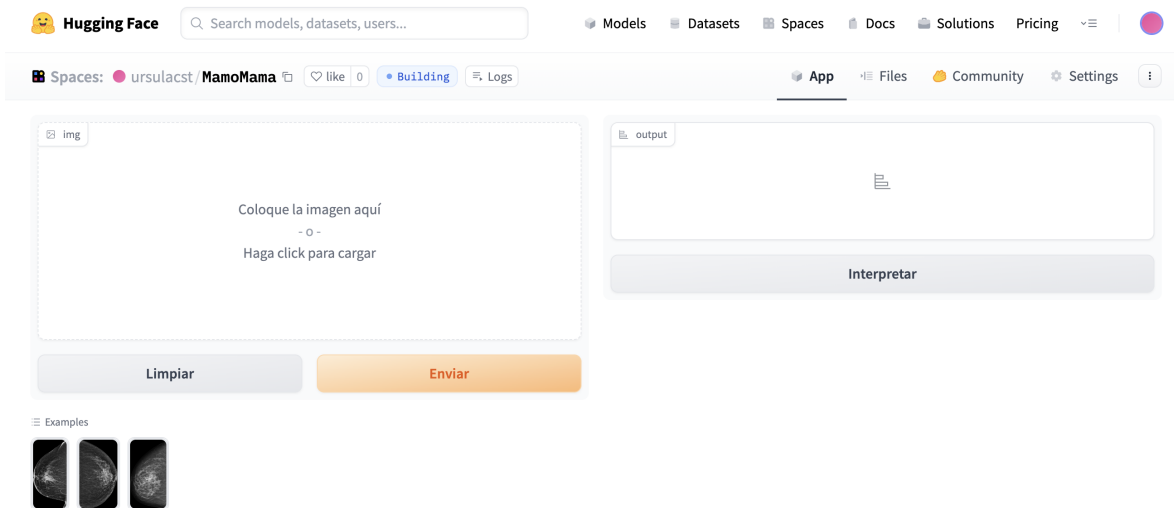


Figura 7: Hugging Face Spaces Mamografia

S'ha afegit el botó Interpretar, que el que fa és mostrar sobre la imatge diferents regions en colors. Aquestes regions, amb els colors, representen les regions en les quals el model s'ha basat per fer la predicció. Podem veure un exemple a la Figura 8.

MONAI DEPLOY

Passem doncs ara a explicar com es varen desenvolupar les aplicacions amb la llibreria MONAI Deploy. Tal i com hem fet amb Hugging Face, només explicarem el procés de creació una vegada tot i que hem desenvolupat dues aplicacions diferents.

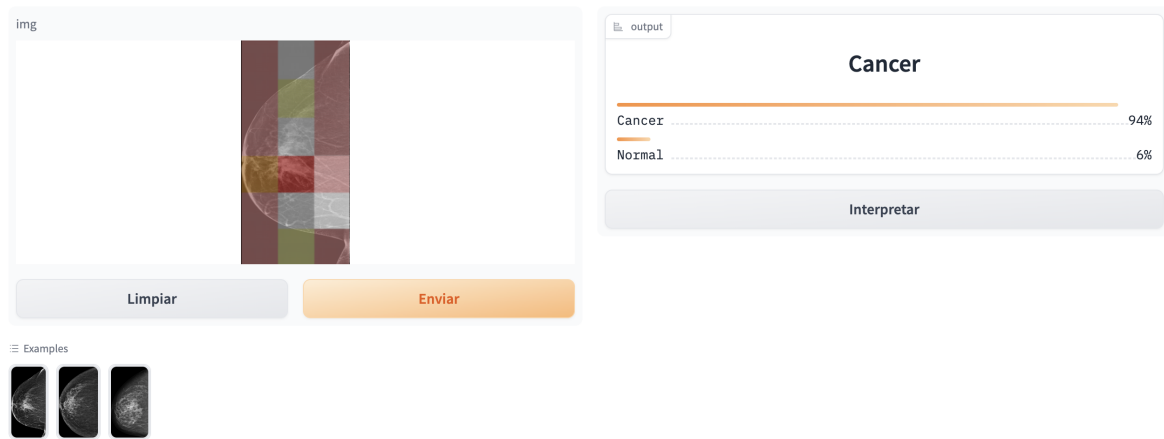


Figura 8: Imatge de mamografia després de prémer botó Interpretar

Per al desenvolupament de les aplicacions amb MONAI s'han seguit les indicacions de la documentació de MONAI Deploy App SDK(posar referencia), que es la llibreria que vàrem utilitzar.

El primer pas va ser comprovar que teníem Anaconda instal·lat, en cas de no ser així, es necessita instal·lar Anaconda. Segons la documentació de MONAI [20], per a poder desenvolupar una aplicació amb aquesta biblioteca, es necessària la creació d'un entorn virtual.

La diferencia entre Hugging Face i MONAI és la manera en la que hem exportat el model detector/classificador. No s'ha utilitzat l'arxiu .pkl, sinó que s'ha comprimit el classificador/detector en un arxiu zip, amb extensió .zip, ecoclassifier.zip i mamoclassifier.zip.

Una vegada que tenim el model comprimit el següent que hem de fer és definir els operadors a l'aplicació d'inferència. L'aplicació d'inferència és la que s'encarrega d'organitzar la seqüència d'operacions necessàries per a processar una imatge d'entrada i obtenir la predicció a partir del model entrenat. Així doncs, va ser necessari definir dos operadors, un que carrega una imatge d'entrada i la passa al següent operador (LoadPILOperator), i l'altre que processa la imatge amb el model comprimit i guarda la predicció en un arxiu JSON (ECOCClassifierOperator/MAMOCClassifierOperator). Per últim definim una classe App en la que connectarem els dos operadors per a poder-la fer servir.

Per comprovar que ho estem fent bé, s'executa l'aplicació localment i provem que ens retorna una sortida. Per poder executar l'aplicació hem d'aportar els següents arguments:

- Input: és la ruta a la carpeta on hi haurà les imatges d'entrada
- Output: és una carpeta on hi haurà els arxius JSON de sortida
- Model: és l'arxiu comprimit del nostre model detector/classificador

Quan s'ha comprovat que s'executa sense problemes i ens retorna una etiqueta amb el resultat, podem crear l'arxiu Python (.py). Aquest és el que contindrà tot el codi de l'aplicació que s'havia

desenvolupat fins ara, per a poder executar-lo més tard. En el nostre cas, `eco_classifier_monaideploy.py` i `mamo_classifier_monaydeploy.py`.

Tornem a executar l'aplicació, utilitzant l'arxiu Python i el model comprimit, per comprovar que ens mostra els resultat de la classificació/detecció, a més de guardar el resultat en un arxiu JSON a la carpeta Output.

Seguidament, utilitzant MONAI Application Packager, el que varem fer és empaquetar l'aplicació en una imatge Docker, el que ens facilitarà la seva distribució i execució en diferents entorns. S'ha de tenir en compte que aquesta imatge ocupa un 16GB, si no es té prou espai, es produirà un error durant l'execució del codi.

Arribats fins aquí, ja tenim les nostres aplicacions acabades. Podem executar-les des de el terminal per comprovar que funciona tot correctament.

La principal diferencia entre Hugging Face i MONAI és que fer-ho amb Hugging Face és molt més gràfic que MONAI, la interacció amb l'aplicació és més fàcil i accessible.

6 RESULTATS

En aquest capítol es mostraran els resultats obtinguts després d'haver seguit la metodologia descrita anteriorment. Començarem pels models.

6.1 Models

Tal i com hem mencionat anteriorment, hem desenvolupat dos models diferents utilitzant la llibreria `fast.ai` [10].

Tenim dos models classificadors, un d'imatges tumorals en ecografia de mama, que l'anomenarem CAD-ECO, i un model classificador/detector de càncer de mama en imatges de mamografia, que anomenarem CAD-MAMO.

Hem avaluat l'eficàcia d'aquests models amb matrius de confusió. Aquesta matriu s'ha generat després d'haver entrenat el model, amb les dades de validació, per tant no ha sigut necessari definir un `threshold`. També s'han calculat la precisió, l'especificitat i la sensibilitat de cada model. Les matrius

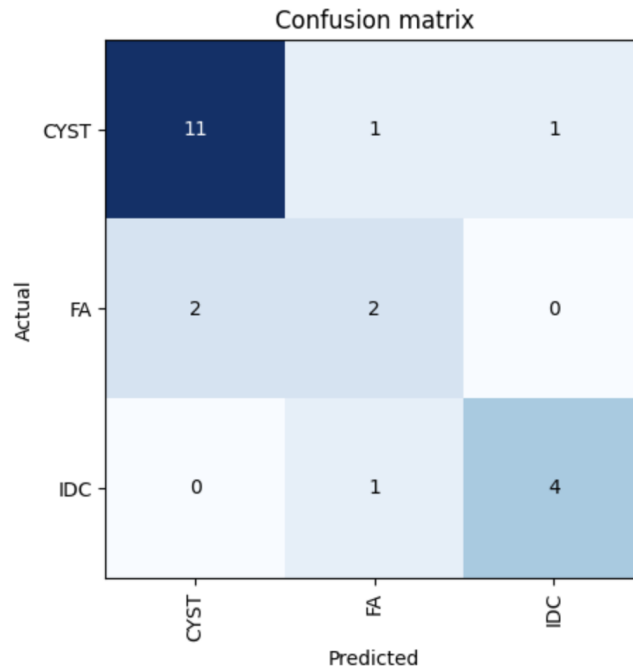


Figura 9: Matriu de confusió del model classificador

6.1.1 CAD-ECO

Comencem amb el model classificador. Podem apreciar la matriu de confusió resultant a la Figura 9. D'aquesta matriu podem extreure el valor de la precisió del model, que és del 77.27%. Per extreure els valors de l'especificitat i la sensibilitat, en aquest cas que es tracta de una matriu de confusió de 3 per 3, hem de calcular la matriu de confusió resultant, tal i com es mostra a la Figura 10.

		inferred class		
		A	B	C
true class	A	a	b	c
	B	d	e	f
	C	g	h	i

		inferred class	
		A	not-A
true class	A	a (TP)	b+c (FN)
	not-A	d+g (FP)	e+f+h+i (TN)

Figura 10: Càlcul de la matriu de confusió resultant d'una matriu 3x3

Una vegada hem fet la matriu d'observació, es pot veure a la Taula 2, podem calcular els valors de l'especificitat i la sensibilitat amb les mateixes formules. Per la classe CYST tenim una especificitat del 77.78% i una sensibilitat del 84.61%. Per la classe FA tenim una especificitat del 88.89% i una sensibilitat del 50%. I per la classe IDC tenim una especificitat del 94.11% i una sensibilitat del 80%.

Podem veure un exemple de classificació a la Figura 11. El valor de sobre indica l'etiqueta predita per el model, i el valor de sota és l'etiqueta real de la imatge.

Classe	TP	TN	FP	FN
CYST	11	7	2	2
FA	2	16	2	2
IDC	4	16	1	1

Taula 2: Matriu de confusió resultant




Figura 11: Exemple de classificació del model

6.1.2 CAD-MAMA

Vist el model classificador, podem passar a veure els resultats del model predictor de càncer de mama amb imatges de mamografia. Podem veure la matriu de confusió resultant a la Figura 12. En aquest cas no és tant complicat extreure els valors, ja que només tenim dos classes. Així doncs, podem extreure que el valor de la precisió d'aquest model és del 60.39%. A més, tenim una especificitat del 60.34% i una sensibilitat del 60.54%.

Podem veure un exemple de detecció a la Figura 13.

Tot i que tenim moltes menys imatges d'ecografia que de mamografia, els resultats obtinguts del model classificador són bastant millors que els resultats del model predictor.

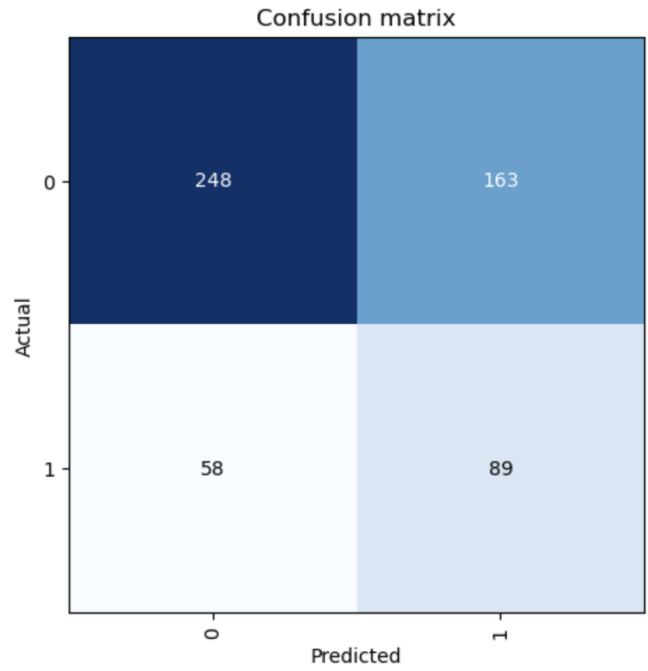


Figura 12: Matriu de confusió del model predictor




Figura 13: Exemple de detecció del model

L'objectiu principal d'aquest treball no és desenvolupar el millor model de classificació/predicció, sinó veure tot el procés de construcció d'una aplicació, per aquest motiu no vam dedicar més temps

en intentar millorar els resultats.

6.2 Deployment

En aquest apartat avaluarem els resultats obtinguts en els diferents escenaris d'experimentació, descrits en el capítol anterior.

6.2.1 Hugging Face Spaces

Per a la construcció de les aplicacions no tenim un mètode d'avaluació com a tal, sinó que veurem com han quedat i com funcionen les aplicacions. Començarem amb Hugging Face Spaces.

Al capítol anterior hem pogut veure com va quedar la interfície gràfica de les aplicacions creades amb la plataforma Hugging Face Spaces, en aquest veurem com funcionen.

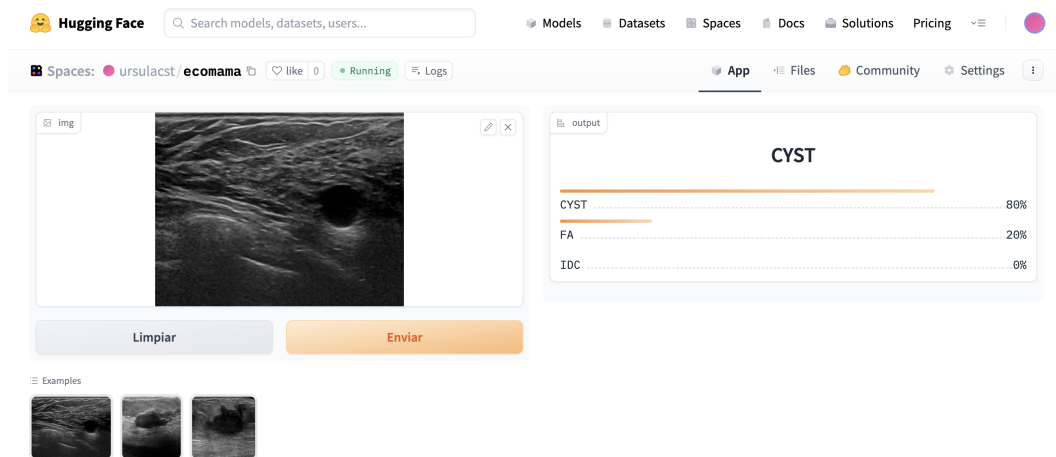


Figura 14: Hugging Face Spaces: CYST

Comencem amb l'aplicació per imatges d'ecografia. Com podem veure a la Figura 14, si triem una imatge d'exemple, ens retorna unes probabilitats. Aquestes probabilitats estan dividides en tres, ja que tenim tres classes diferents d'imatges. Les probabilitats es mostren en tant per cent. En aquest cas, hem triat una imatge que sabem que és un cist, així doncs, que classifica bé.

Provem amb un altre imatge. A la Figura 15 podem apreciar que classifica la imatge com a CYST, amb un 100% de probabilitat, però en realitat la imatge seleccionada correspon a un fibroadenoma, FA.

Passem ara a veure com ha quedat l'aplicació per imatges de mamografia. Com podem veure a la Figura 16, en aquest cas tenim només dues classes de probabilitats, ja que el model classifica entre càncer o no càncer. En aquest cas, hem triat una imatge normal, però etiquetada com a cas difícil, això vol dir que alguns radiòlegs la van classificar com a càncer quan en realitat no ho era, fals positiu.

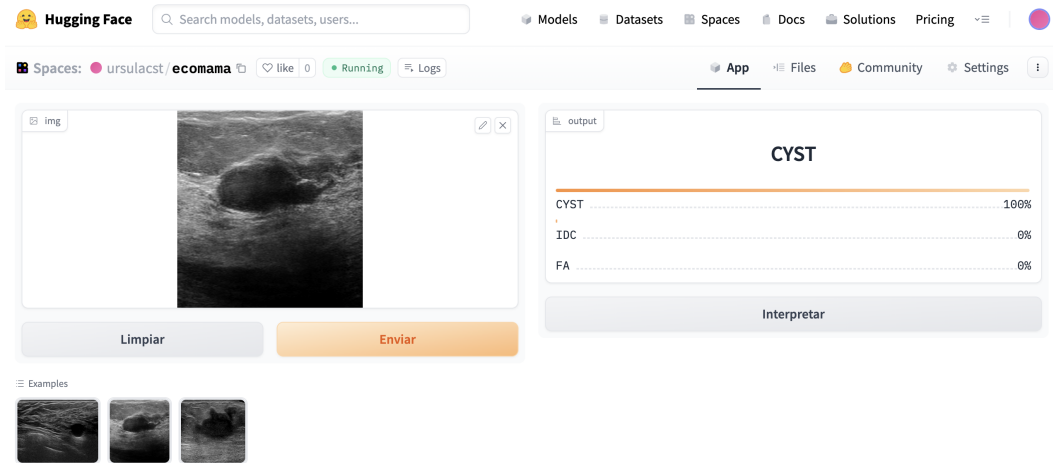


Figura 15: Hugging Face Spaces: FA

Podem veure que les probabilitats surten bastant ajustades, quasi 50%/50%, així que podem suposar que per la nostra aplicació també són casos difícils.

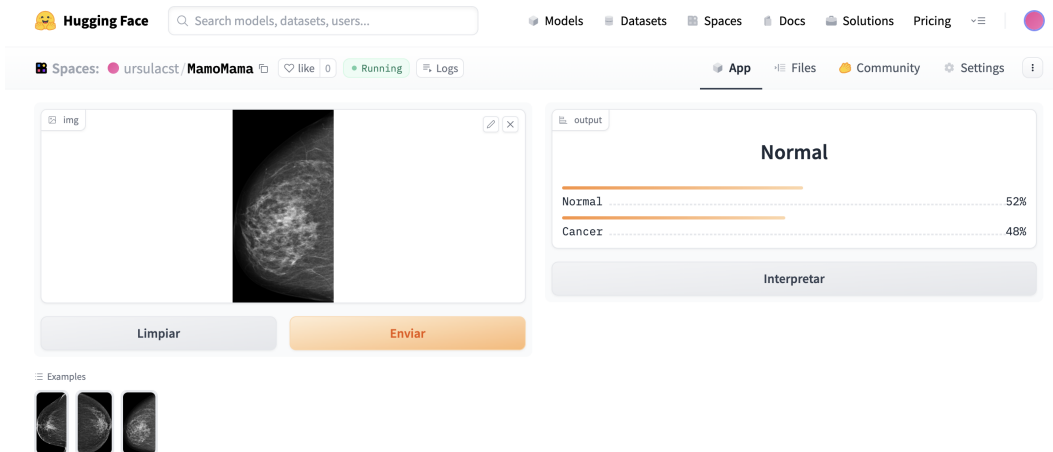


Figura 16: Hugging Face Spaces: Normal

Si provem amb un imatge de càncer, com podem veure a la Figura 17, sembla que l'aplicació classifica bé la imatge.

Els models no són perfectes, així que ja ens esperàvem que les nostres aplicacions fallèssin en alguns casos la classificació d'imatges, sobretot quan són imatges semblants. Tot i això, estem contents amb els resultats obtinguts, ja que hem aconseguit desenvolupar dues aplicacions senzilles, que classifiquen, i que són bastant intuïtives i fàcils d'utilitzar.

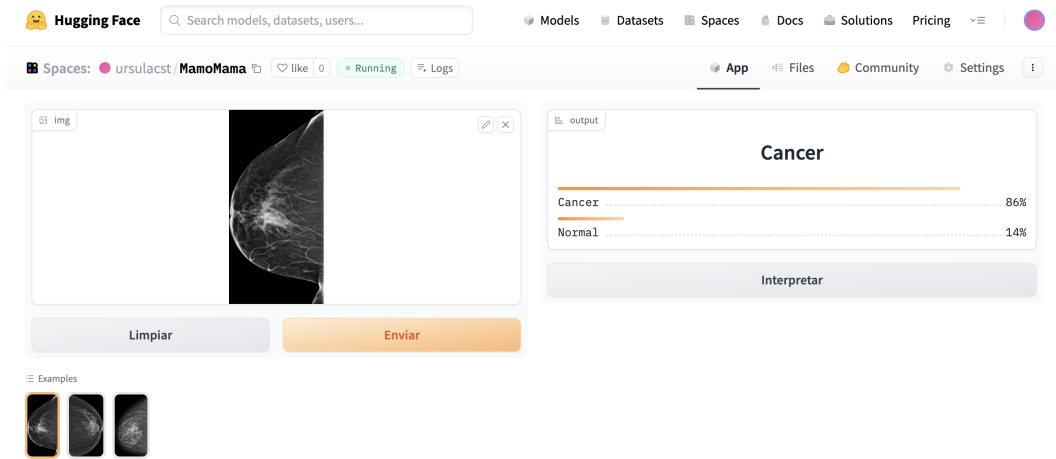


Figura 17: Hugging Face Spaces: Càncer

6.2.2 MONAI Deploy

Passem ara a veure el funcionament de les aplicacions creades amb la llibreria MONAI Deploy. L'objectiu de les aplicacions desenvolupades amb MONAI no és la interfície gràfica, sinó que les podem executar en qualsevol entorn, a més, de retornar un resultat en format fitxer. Com no tenim una interfície gràfica, les executarem a través del terminal.

```
(mednist) ursula@mariecurie:~/projecte$ cd input
(mednist) ursula@mariecurie:~/projecte/input$ ls
000124.png
```

Figura 18: Contingut de la carpeta input

Com no tenim una interfície gràfica que puguem mostrar, mostrarem com s'executa l'aplicació des de el terminal.




Figura 19: Imatge present a la carpeta input

Comencem amb l'aplicació eco_app, que és el classificador d'imatges d'ecografia. Primerament,

com podem observar a la Figura 18, dins la carpeta input tenim una imatge. Aquesta imatge és la que volem passar-li a la aplicació per a que la classifiqui. La imatge correspon a una imatge d'un tumor benigne CYST. Podem veure la imatge a la Figura 19.

Executem l'aplicació amb la següent comanda: `monai-deploy run eco_app:latest input output`. On input és una carpeta on es troba la imatge a classificar, output és un carpeta on es generarà un arxiu JSON amb l'etiqueta i `eco_app` és l'aplicació. Podem veure el resultat de l'execució a la Figura 20.

```
(mednist) ursula@mariecurie:~/projecte$ monai-deploy run eco_app:latest input output
Checking dependencies...
--> Verifying if "docker" is installed...

--> Verifying if "eco_app:latest" is available...

Checking for MAP "eco_app:latest" locally
"eco_app:latest" found.

Reading MONAI App Package manifest...
Successfully copied 2.05kB to /tmp/tmpx9e0v7pa/app.json
Successfully copied 2.05kB to /tmp/tmpx9e0v7pa/pkg.json
--> Verifying if "nvidia-docker" is installed...

Going to initiate execution of operator LoadPILOperator
Executing operator LoadPILOperator (Process ID: 1, Operator ID: a1b5dcc9-65c7-4845-9c92-6b56ba67ba39)
Done performing execution of operator LoadPILOperator

Going to initiate execution of operator ECOClassifierOperator
Executing operator ECOClassifierOperator (Process ID: 1, Operator ID: 921fee8d-1db2-4fa3-82f8-324eb9286208)
/root/.local/lib/python3.8/site-packages/monai/utils/deprecate_utils.py:107: FutureWarning: <class 'monai.transforms.utility.array.AddChannel'>: Class 'AddChannel' has been deprecated since version 0.8. please use MetaTensor data type and monai.transforms.EnsureChannelFirst instead.
  warn_deprecated(obj, msg, warning_category)
/root/.local/lib/python3.8/site-packages/monai/utils/type_conversion.py:138: UserWarning: The given NumPy array is not writeable, and PyTorch does not support non-writeable tensors. This means you can write to the underlying (supposedly non-writeable) NumPy array using the tensor. You may want to copy the array to protect its data or make it writeable before converting it to a tensor. This type of warning will be suppressed for the rest of this program. (Triggered internally at /opt/pytorch/pytorch/torch/csrc/utils/tensor_numpy.cpp:175.)
  tensor = torch.as_tensor(tensor, **kwargs)
CYST
Done performing execution of operator ECOClassifierOperator
```

Figura 20: Execució de l'aplicació eco_app

Tal com hem dit abans, la imatge pertany a una imatge d'un tumor benigne, CYST, i la nostra aplicació el classifica com a tumor benigne, CYST. Així doncs, la classifica correctament. A la Figura 21, podem observar que se'n ha generat l'arxiu JSON a la carpeta output.

```
(mednist) ursula@mariecurie:~/projecte/output$ ls
output.json
```

Figura 21: Contingut de la carpeta output

```
(mednist) ursula@mariecurie:~/projecte/input$ ls
44709_650076091_L.png
```

Figura 22: Contingut de la carpeta input

Seguim amb l'aplicació mammo_app, que és el model predictor de càncer en imatges de mamografia. Com hem fet anteriorment, a la Figura 22 podem observar que dins la carpeta input tenim una imatge

per classificar. Aquesta imatge correspon a una imatge amb càncer. Podem veure la imatge a la Figura 23.




Figura 23: Imatge present a la carpeta input

L'aplicació l'executem amb la comanda: `monai-deploy run mammo_app:latest input output`. Podem veure el resultat d'aquesta execució a la Figura 24. Comprovem que aquesta aplicació també falla al predir, ens diu que és una imatge normal quan sabem que no ho és, és una imatge de Càncer. Tal i com ha passat abans, també s'ha generat un arxiu JSON a la carpeta output.

Torna a passar el mateix, els models no són perfectes, però no és la perfecció el que volíem aconseguir. Podríem haver posat exemples en que l'aplicació classifiqués correctament, però no seria realista. Els models també s'equivoquen encara que estiguin utilitzant la intel·ligència artificial.

L'objectiu és desenvolupar un eina capaç d'ajudar al diagnòstic de càncer de mama, i considerem que s'ha complert, tot i que amb les aplicacions desenvolupades amb MONAI podríem anar un pas més enllà i crear una interfície gràfica, ja que no és gaire pràctic manipular i executar les aplicacions des de el terminal.


```
(mednist) ursula@mariecurie:~/projecte$ monai-deploy run mammo_app:latest input output
Checking dependencies...
--> Verifying if "docker" is installed...

--> Verifying if "mammo_app:latest" is available...

Checking for MAP "mammo_app:latest" locally
"mammo_app:latest" found.

Reading MONAI App Package manifest...
Successfully copied 2.05kB to /tmp/tmpvtl1qo1_/app.json
Successfully copied 2.05kB to /tmp/tmpvtl1qo1_/pkg.json
--> Verifying if "nvidia-docker" is installed...

Going to initiate execution of operator LoadPILOperator
Executing operator LoadPILOperator (Process ID: 1, Operator ID: 2b4a7294-008d-45a3-87d2-1bee03458bee)
Done performing execution of operator LoadPILOperator

Going to initiate execution of operator MAMOClassifierOperator
Executing operator MAMOClassifierOperator (Process ID: 1, Operator ID: ca1e3a3d-2832-442f-a834-1fa0775e8b09)
/root/.local/lib/python3.8/site-packages/monai/transforms/utility/array.py:107: FutureWarning: <class 'monai.transforms.utility.array.AddChannel'>: Class 'AddChannel' has been deprecated since version 0.8. please use MetaTensor data type and monai.transforms.EnsureChannelFirst instead.
  warn_deprecated(obj, msg, warning_category)
/root/.local/lib/python3.8/site-packages/monai/transforms/utility/array.py:138: UserWarning: The given NumPy array is not writeable, and PyTorch does not support non-writeable tensors. This means you can write to the underlying (supposedly non-writeable) NumPy array using the tensor. You may want to copy the array to protect its data or make it writeable before converting it to a tensor. This type of warning will be suppressed for the rest of this program. (Triggered internally at /opt/pytorch/pytorch/torch/csrc/utils/tensor_numpy.cpp:175.)
  tensor = torch.as_tensor(tensor, **kwargs)
Normal
Done performing execution of operator MAMOClassifierOperator
```

Figura 24: Execució de l'aplicació mammo_app

7 DISCUSSIÓ

7.1 Limitacions

Malgrat que els resultats del projecte són satisfactoris tenint en compte que s'han assolit els objectius inicials, ja comptàvem amb algunes limitacions inicials, a més de les que han anat sorgint durant el desenvolupament del projecte.

La primera estaria relacionada amb la quantitat de dades de les que disposàvem. En referència a la base de dades d'ecografia, la quantitat de dades present era insuficient per a poder entrenar un bon model classificador. Igual que a la base de dades de mamografia, vam veure que les dades estaven poc balancejades, ja que teníem molts casos normals en vers als casos de càncer. Això va suposar un problema a l'hora d'entrenar el model de predicció.

En relació amb la limitació anterior ens hem trobat que les mètriques resultants, com la precisió, no han estat gaire satisfactòries, tot i haver aconseguit un 77% de precisió, en el cas del model classificador.

Un altre de les limitacions amb la que ens hem trobat ha estat treballar amb un ordinador amb un sistema operatiu diferent a l'habitual, això ha suposat haver de dedicar temps a aprendre el funcionament d'aquest.

A part del sistema operatiu també se'ns han presentat limitacions a l'hora d'utilitzar la llibreria MONAI, començant per la memòria necessària per crear la imatge docker de l'aplicació. A més de tots els problemes previs per executar el codi, ja que MONAI havia fet canvis al codi font i no havia modificat algunes de les seves funcions que han estat utilitzades en aquest treball, això va comportar errors difícils de identificar, als quals vam haver de dedicar molt de temps per poder resoldre'ls i seguir amb el desenvolupament del projecte.

A més del sistema operatiu, també se'ns han presentat limitacions a l'hora de fer servir la llibreria MONAI Deploy, començant per que vam haver d'entrenar un model, ja que la llibreria no accepta models entrenat amb altres llibreries que no siguin les que utilitza MONAI. També varem tenir problemes a l'hora d'executar el codi, ja que els desenvolupadors de MONAI havien fer modificacions al codi font però no havien modificat les funcions corresponents, això ens va comportar errors difícils d'identificar. Va haver de dedicar molt de temps i esforç a resoldre errors, tant així que fins i tot vam contactar amb els desenvolupadors de la llibreria, per veure si ens podien donar una mà per intentar solucionar-los.

Tot el temps emprat en resoldre errors ens ha limitat la possibilitat de poder trobar maneres de construir una interfície gràfica, per a que les aplicacions siguin molt més visuals i fàcils de fer-ne ús.

7.2 Contribucions als objectius de desenvolupament sostenible (ODS) de les Nacions Unides

Després de revisar les ODS, l'objectiu que més s'ajusta amb la temàtica d'aquest TFG és l'objectiu 3 Salut i benestar, que garanteix una vida saludable i promou el benestar per tots en totes les edats.

Garantir una vida saludable implica assegurar que les persones tinguin accés a serveis de salut preventius i de diagnòstic primerenc per detectar i tractar malalties de manera oportuna. En el cas específic del càncer de mama, la detecció precoç a través de proves mèdiques regulades és essencial per augmentar les possibilitats de cura i reduir la mortalitat associada a aquesta malaltia.

A més promoure el benestar implica oferir a les persones l'accés a tractaments efectius, i de qualitat per al càncer de mama. Això inclou l'accés a teràpies mèdiques, cirurgies, radioteràpia, quimioteràpia i teràpies dirigides, així com a serveis de suport integral, com ara el suport emocional i la rehabilitació.

8 CONCLUSIONS

Una vegada hem finalitzat el projecte, podem afirmar que l'objectiu que ens havíem plantejat a l'inici del projecte, que és: Desenvolupar un sistema CAD per l'ajut del diagnòstic del càncer de mama. S'ha assolit de manera satisfactòria.

Hem aconseguit veure tot el procés de construcció d'una aplicació per a l'ajut al diagnòstic, des de l'entrenament d'un model amb les dades desitjades fins a la utilització d'aquest per el desenvolupament d'una aplicació, en aquest cas de dues maneres diferents. Una amb Hugging Face Spaces i l'altre mitjançant la llibreria MONAI.

El resultat obtingut amb Hugging Face Space és una aplicació que passant-li una entrada, en aquest cas una imatge mèdica, retorna una sortida que correspon a una etiqueta que classifica, en el cas de les ecografies, o diagnòstica, en el cas de les mamografies.

En relació amb els resultats obtinguts amb la llibreria MONAI, el que tenim és que guardem una imatge en una carpeta que la utilitzarà com a entrada i retorna un arxiu Json amb la predicció en cas de les mamografies o amb la classificació en el cas de les ecografies.

Malgrat que s'ha assolit l'objectiu del projecte, creiem que es podrien realitzar millores en aquest si disposéssim de més temps. Aquestes millores serien:

- Crear una interfície gràfica per a l'aplicació desenvolupada amb la llibreria MONAI ja que aquesta s'executa localment des d'un terminal.
- També podríem arribar a retornar un pdf amb el diagnòstic a partir d'una imatge mèdica d'entrada.
- Millorar els models de predicció i classificació perquè siguin més precisos.

Tot i les millores que es podrien fer estem satisfets amb el treball desenvolupat en aquest projecte i amb els resultats obtinguts.

Referències

- [1] Tanishq Abraham. *Gradio + HuggingFace Spaces: A Tutorial*. URL: https://www.tanishq.ai/blog/gradio_hf_spaces_tutorial.
- [2] Anaconda. URL: <https://www.anaconda.com/>.
- [3] Hiba Chougrad, Hamid Zouaki i Omar Alheyane. “Deep Convolutional Neural Networks for breast cancer screening”. A: *Computer Methods and Programs in Biomedicine* 157 (2018), pàg. 19-30.
- [4] MONAI Deploy. URL: <https://monai.io/deploy.html>.
- [5] Docker. URL: <https://www.docker.com/>.
- [6] AR Ecografia. *Ecografía de mama*. URL: http://www.ar-ecografia.com/eco_mama.php.
- [7] Hugging Face. URL: <https://huggingface.co/>.
- [8] Estefanía Freire i Sarahí Silva. *Redes neuronales*. 2019. URL: <https://bootcampai.medium.com/redes-neuronales-13349dd1a5bb>.
- [9] Krzysztof J. Geras et al. “High-Resolution Breast Cancer Screening with Multi-View Deep Convolutional Neural Networks”. A: *arXiv* ().
- [10] Jeremy Howard. *fast.ai*. URL: <https://www.fast.ai/>.
- [11] Diagnostico especializado por imagen. *Resonancia magnética de mama*. URL: <https://www.deidiagnostico.com/resonancia-magnetica-de-mama/>.
- [12] Jupyter. URL: <https://jupyter.org/>.
- [13] Kaggle. *RSNA Screening Mammography Breast Cancer Detection*. 2022-23. URL: <https://www.kaggle.com/competitions/rsna-breast-cancer-detection>.
- [14] Eun-Kyung Kim et al. “Applying Data-driven Imaging Biomarker in Mammography for Breast Cancer Screening: Preliminary Study”. A: *Scientific Reports* 8.1 (2018), pàg. 2762.
- [15] Hyo-Eun Kim et al. “Changes in cancer detection and false-positive recall in mammography using artificial intelligence: a retrospective, multireader study”. A: *The Lancet Digital Health* 2.3 (2020), e138-e148.
- [16] Thijs Kooi et al. “Large scale deep learning for computer aided detection of mammographic lesions”. A: *Medical Image Analysis* 35 (2017), pàg. 303-312.
- [17] Mohammed A. Al-masni et al. “Simultaneous detection and classification of breast masses in digital mammograms via a deep learning YOLO-based CAD system”. A: *Computer Methods and Programs in Biomedicine* 157 (2018), pàg. 85-94.
- [18] Joydwip Mohajon. *Confusion Matrix for Your Multi-Class Machine Learning Model*. URL: <https://towardsdatascience.com/confusion-matrix-for-your-multi-class-machine-learning-model-ff9aa3bf7826>.

- [19] MONAI. URL: <https://monai.io/>.
- [20] MONAI. *MONAI Deploy App SDK*. URL: <https://docs.monai.io/projects/monai-deploy-app-sdk/en/latest/>.
- [21] Sociedad Española de Oncología Médica. *Cáncer de mama*. URL: <https://seom.org/info-sobre-el-cancer/cancer-de-mama?start=2>.
- [22] Python. URL: <https://www.python.org/>.
- [23] Dezsó Ribli et al. “Detecting and classifying lesions in mammograms with Deep Learning”. A: *Scientific Reports* 8.1 (2018), pàg. 4165.
- [24] Philip Teare et al. “Malignancy Detection on Mammography Using Dual Deep Convolutional Neural Networks and Genetically Discovered False Color Input Enhancement”. A: *Journal of Digital Imaging* 30.4 (2017), pàg. 499-505.
- [25] Parc Taulí Hospital Universitari. URL: <http://www.tauli.cat/tauli/>.
- [26] Parc Taulí Hospital Universitari. *UDIAT Centre Diagnòstic*. URL: <https://www.tauli.cat/udiat/>.
- [27] Wentao Zhu et al. “Deep Multi-instance Networks with Sparse Label Assignment for Whole Mammogram Classification”. A: *bioRxiv website* (2016).

9 ANNEX A CODI

Donat que la part experimental d'aquest projecte a portat al desenvolupament de programari, notebooks en aquest cas, s'ha inclòs un repositori GitHub per a que qui vulgui consultar el programari pugui fer-ho.

El repositori GitHub és d'accés públic i conté el document ReadMe amb l'explicació de cada cosa.

L'enllaç és el següent: <https://github.com/ursulacst/ProjecteFinal>