



This is the **published version** of the bachelor thesis:

Bardeli Gámez, Marc; Sanchez Ramos, Carles, tut. Generación de características radiómicas 2D para el diagnóstico digital del cáncer de pulmón. 2025. (Enginyeria Informàtica)

This version is available at <https://ddd.uab.cat/record/317562>

under the terms of the  license

Generació de característiques radiòmiques 2D pel diagnòstic digital del càncer de pulmó

Marc Bardeli Gamez

30 de juny de 2025

Resum– El càncer de pulmó és un tipus de càncer molt comú i letal. Les característiques radiòmiques de tomografies computeritzades són útils per a la seva detecció precoç, però l'extracció de característiques és un procés lent i costós. Aquest treball es centra en buscar alternatives als mètodes d'extracció actuals buscant una millora en temps, cost i sense perdre la fiabilitat actual. Per fer-ho s'ha seguit una metodologia on es preprocesen les imatges amb els mètodes actuals per després ajuntar les imatges amb les seves característiques i passar-les com a entrada per a entrenar els models d'aprenentatge profund. Els resultats mostren una millora significativa en temps i eficiència computacional gràcies a una ràpida inferència, tot i que la qualitat de les característiques generades varia segons el cas. Malgrat algunes mancances en la generació de característiques, el sistema proposat representa un pas endavant cap a mètodes més eficients i accessibles.

Paraules clau– Càncer de Pulmó, característiques radiòmiques, tomografies computeritzades, detecció precoç, extracció de característiques, aprenentatge profund

Abstract– Lung cancer is a very common and lethal disease. Radiomic features extracted from computed tomography (CT) scans are useful for its early detection, but the feature extraction process is often slow and expensive. This project focuses on exploring alternatives to current extraction methods, aiming to improve processing time and cost without compromising reliability. The proposed methodology involves preprocessing images using current techniques, pairing them with their corresponding features, and feeding them into deep learning models for training. The results show significant improvements in time and computational efficiency due to fast inference, although the quality of the generated features varies depending on the case. Despite some shortcomings in feature generation, the proposed system represents a step forward toward more efficient and accessible methods.

Keywords– Lung cancer, radiomic features, computed tomography, early detection, feature extraction, deep learning

1 INTRODUCCIÓ - CONTEXT DEL TREBALL

EL càncer és una malaltia que per definició es dona quan un conjunt de cèl·lules del cos es multipliquen sense control i envaeixen teixits propers.

Actualment, el càncer de pulmó, és el tipus de càncer

més comú i letal entre les persones. Segons la World Health Organization (WHO), l'any 2022 més de 2.5 milions de persones van patir aquesta malaltia i de totes aquestes, 1.8 milions no van poder-la superar[1]. Malgrat tota la informació que es té sobre aquest tipus de càncer i la conscienciació que s'ha fet sobre els factors de risc que poden portar a desenvolupar-lo, no sempre es pot evitar. Per aquesta raó la detecció precoç de la malaltia és vital per a la supervivència de tota persona que tingui càncer de pulmó.

Tot càncer té unes fases, segons l'Associació Americana del càncer són tres, la Localitzada, la Regional i la Distant. Seguint el fil de l'associació, un estudi que va revisar dades

- E-mail de contacte: marcbardegamez@gmail.com
- Menció realitzada: Computació
- Treball tutoritzat per: Carles Sanchez Ramos (CVC)
- Curs 2024/25

de supervivència de l'any 2012 fins a l'any 2018 de persones que patien càncer de pulmó de cèl·lula no petita va donar uns percentatges. 65%, 37% i 9% de percentatges de supervivència respectivament per a cada fase[2]. Amb aquest nombre es pot observar la importància de detectar el càncer en la seva etapa més primerenca, detectar la malaltia en aquesta fase donaria al pacient més del 50% de possibilitats de sobreviure mentre que un cop el càncer ja ha arribat a la segona fase les probabilitats es redueixen dràsticament.

El següent factor a tenir en compte són els falsos negatius i falsos positius. El fet de fer un diagnòstic incorrecte pot posar en perill la vida del pacient directament, ja sigui no detectant un càncer que té o a l'inrevés.

Gràcies a l'anàlisi radiòmic de tomografies computeritzades (CT), aquests factors esmentats han millorat molt i han permès que es puguin aplicar tractaments adequats de forma més eficient que mai. Les dades tractades són de dos tipus principalment, o bé s'analitzen volums de tres dimensions que contenen el pulmó o concretament nòduls pulmonars que es coneixen com a VOI (Volume of interest) o també es poden analitzar talls d'aquests volums de tres dimensions en diferents direccions (Axial, Sagital i Coronal), aconseguint així imatges de dues dimensions que es poden analitzar amb més facilitat. Per a aquest projecte, s'utilitzaran aquests talls per a entrenar els models.

Per a exemplificar el que s'ha mencionat, un model que fa servir imatges de tres dimensions de CT és LungNet[5]. Es basa en una xarxa neuronal convolucional que analitza les imatges tridimensionals per obtenir informació de les característiques radiòmiques dels nòduls pulmonars. Aquest model, entrenat amb un gran volum de dades, aconsegueix uns resultats destacables: una exactitud del 96,81% en la classificació de cinc tipus de càncer de pulmó, amb una taxa global de falsos positius del 3,35%. En la subclassificació de fases inicials (1A, 1B, 2A, 2B), assoleix una precisió del 91,6% i una taxa de falsos positius del 7,25% [18]. Tot i aquests bons resultats, tenint en compte que es tracta de la salut dels pacients, encara no s'assoleix el màxim potencial possible, motiu pel qual cal seguir treballant alternatives com la millora de l'extracció de característiques radiòmiques.

Un altre projecte a destacar d'on sortien els principals objectius d'aquest projecte, seria el portat a terme per Guillermo Torres en la seva tesi[11]. En aquest estudi es tracten aspectes com la construcció d'un conjunt de dades mèdiques especialment rellevant per incloure diagnòstics confirmats per biòpsia, un element diferencial respecte als datasets públics d'ús comú, l'ús PyRadiomics[13] per extreure les característiques radiòmiques de les imatges i generar espais de representació i finalment s'analitzen diferents models i els resultats que generen aquests[11].

Amb això dit, queda marge de millora, sobretot en el temps d'extracció de característiques i el cost computacional. A més, cal destacar la forta influència que tenen els paràmetres d'adquisició dels diferents escàners de CT, ja que poden generar una variabilitat significativa en els resultats dels mètodes actuals. Aquesta dependència condiciona tant la qualitat de les característiques extretes, i es converteix en un factor clau a tenir en compte en el desenvolupament de sistemes robustos i generalitzables.

Per tant, partint d'aquesta base podem identificar les necessitats principals, una necessitat de major velocitat a l'ho-

ra de generar característiques radiòmiques amb una creació d'un model robust i eficient.

2 ESTAT DE L'ART

La detecció i classificació de càncer de pulmó és un tema que amb els anys ha anat guanyant popularitat, degut a l'alta mortalitat d'aquesta malaltia i a l'evolució de les tecnologies i el hardware d'aprenentatge profund s'ha posat molt èmfasi a fer-ne una detecció precoç.

Per abordar el problema que es pretén resoldre, és fonamental identificar d'on venim i cap a on volem avançar, tot observant nous models que puguin millorar els resultats obtinguts amb les metodologies actuals. Aquestes metodologies d'aprenentatge profund aplicades a la classificació i al diagnòstic digital solen seguir cinc etapes diferenciades: en primer lloc, la generació del conjunt de dades i del ground truth; en segon lloc, l'extracció de característiques; a continuació, la reducció de dimensionalitat; posteriorment, la selecció i entrenament del model, i finalment, la valoració i interpretabilitat dels resultats.

D'aquest conjunt d'etapes, aquest projecte es centra especialment en l'extracció de característiques, buscant el canvi i la millora respecte els mètodes actuals.

La generació de característiques radiòmiques a través de models generatius és un camp que no s'ha treballat, partint de què no hi ha models coneguts que facin aquesta tasca s'han explorat diferents opcions.

2.1 Extracció de característiques

L'extracció de característiques en dades mèdiques és un tema explorat i existeixen llibreries de molt fàcil ús per a dur a terme aquesta tasca, tot i això, no són perfectes, no n'hi ha gaires que puguin extreure característiques complexes i moltes vegades tenen una gran dependència als paràmetres d'adquisició dels escàners. Alguns d'aquests models són els següents:

- **MedPy:** És una llibreria que ha estat dissenyada per a l'extracció de característiques en imatges mèdiques. No inclou mètodes com el GLCM però es pot combinar amb llibreries que si el tenen. Té un cost computacional baix, funciona de forma ràpida[3].
- **TorchIO:** És una llibreria de PyTorch dissenyada per a processar imatges mèdiques de dues i tres dimensions. Inclou diverses eines per a analitzar les imatges però nativament no pot fer GLCM, tot i això, dona la possibilitat de combinar-se fàcilment amb altres llibreries que sí tenen aquestes funcions. Té un cost computacional mitjà, no és tan ràpida com MedPy però dona més opcions sobretot en les dimensions[4].
- **PyRadiomics:** És una llibreria que ha estat dissenyada per a l'extracció de característiques en imatges mèdiques. Inclou mètodes com el GLCM, entre d'altres, que dona la possibilitat d'extreure característiques de les imatges com pot ser la textura. Té un cost computacional alt en la majoria de casos degut a que l'extracció que fa pot ser molt exhaustiva i té un problema greu de dependència amb els paràmetres d'adquisició dels diferents escàners[13].

- **Scikit-Image:** És una llibreria de Python dissenyada per a processar imatges, tot i que no ha estat pensada per tractar amb imatges mèdiques permet calcular GLCM, entre altres característiques. Té un cost computacional mitjà i dona flexibilitat per la varietat de mètodes que té, és senzilla de combinar amb altres llibreries[14].

2.2 Generació de dades

Els models generatius s'utilitzen per a moltes tasques d'aprenentatge profund. Amb un bon entrenament permeten aconseguir resultats que llibreries tradicionals o bé no trobarien o trigarien molt, un dels problemes que tenen és que a aquests models els hi cal una revisió de resultats exhaustiva per evitar problemes del tipus overfitting. Alguns models que són adequats per a la tasca a fer són els següents:

- **DCGAN: (Deep Convolutional GAN):** Com el seu nom indica, és una xarxa neuronal adversarial generativa amb capes convolucionals profundes. Utilitza una Loss BCE i permet generar imatges, tot i que la qualitat no és la millor i pot perdre detalls, és el model més eficient dels que s'esmenten en la seva tasca[6].
- **StyleGAN:** Es una GAN avançada que permet generar imatges ultra realistes amb una loss de Wasserstein. Si bé la qualitat de les imatges generades és molt alta, el cost computacional també[12].
- **cGAN: (conditional GAN)** Variant dels GANs que permet generar imatges condicionades a una entrada addicional. Aquesta condició es passa tant al generador com al discriminador, permetent controlar la generació de dades. Utilitza habitualment una Loss BCE[16].
- **DDPM:(Denoising Diffusion Probabilistic Model)** Model que es basa en el procés de difusió probabilística. Permet generar imatges d'alta qualitat amb molt detall sempre i quan s'iteri i es doni el temps necessari[7].
- **AutoEncoder:** Model d'aprenentatge no supervisat format per dues parts: un codificador, i un decodificador. Fa servir típicament una Loss MSE i s'utilitza habitualment per reducció de dimensionalitat, detecció d'anomalies o extracció de característiques, també és computacionalment eficient[17].
- **VAE: (Variational Autoencoder)** Model generatiu que es basa en un autoencoder amb l'afegit d'un espai latent i utilitza la loss ELBO. No generen imatges amb tant detall com altres models però permeten una generació més acotada gràcies al fet que es pot condicionar aquesta generació amb les característiques requerides[8].

3 OBJECTIUS

L'objectiu principal d'aquest projecte es basa a buscar una alternativa als mètodes actuals, per tant, amb això en ment podem identificar les necessitats principals, una necessitat

Objectiu	Model	Loss	Descripció	Cost computacional
Extracció de features d'imatges mèdiques	PyRadiomics	No	Llibreria per extreure característiques d'imatges mèdiques com GLCM.	Alt
Tractament d'imatges mèdiques	MedPy	No	Llibreria que permet tractar amb imatges mèdiques de forma ràpida	Baix
Extracció de features d'imatges	Scikit-Image	No	Llibreria que permet l'extracció de GLCM	Mitjà
Extracció de features d'imatges	TorchIO	No	Llibreria de pyTorch que permet l'extracció de GLCM	Mitjà
Generació d'imatges	AutoEncoder	MSE	Permet generar imatges a partir d'unes features indicades	Alt
Generació d'imatges condicionada	cGAN (Conditional GAN)	BCE + Loss condicional	Model GAN que permet generar imatges condicionades	Alt
Generació d'imatges	DCGAN (Deep Convolutional GAN)	BCE	Model genèric de GAN que pot generar imatges sintètiques de pulmons	Alt
Generació d'imatges d'alta resolució	StyleGAN	Wasserstein Loss	Model que pot generar imatges ultra realistes	Molt alt
Generació d'imatges	DDPM (Denoising Diffusion Probabilistic Model)	ELBO	Model de tipus Diffusion que permet generar imatges d'alta qualitat	Molt alt
Generació d'imatges basat en les features	VAE (Variational Autoencoder)	ELBO	Permet generar imatges a partir d'unes features indicades	Molt alt

Taula 1. Comparativa de llibreries i models per al processament i generació d'imatges mèdiques.

de major velocitat a l'hora de generar característiques radiomiques a partir de la implementació d'un model capaç de generar-les de forma adequada i veloç. També seria necessari buscar una reducció en el cost computacional i a més cal implementar un mètode que sigui invariant als paràmetres d'adquisició dels escàners sense perdre fiabilitat.

Per arribar a l'objectiu proposat es treballaran els següents punts:

- **Revisió bibliogràfica:**

Estudi dels mètodes i models actuals que busquen característiques d'imatges mèdiques i altres que tenen la capacitat per generar imatges. Observació de projectes relacionats amb el problema a resoldre.

- **Selecció de model per a generar característiques radiomiques dels grups d'imatges:**

El GLCM és una tècnica útil per a processar imatges i fer un anàlisi de les textures. Malauradament, aquesta tècnica o similars són força costoses en termes de temps, per aquesta raó cal implementar o trobar un model que sigui capaç de maximitzar l'eficiència computacional sense perdre fiabilitat en els resultats. Les característiques radiomiques inicials serviràn de Ground Truth per a entrenaments de models posteriors i per a validar els resultats.

- **Implementació de models generadors de dades (Deep Learning GANS/VAE):**

Un cop extretes característiques radiomiques, s'entrenarà un model de tipus GAN o VAE per a generar dades. El propòsit d'aquest punt és principalment poder evitar el pas d'extreure característiques utilitzant llibreries com PyRadiomics que són molt costoses computacionalment i lentes, amb un model ben entrenat, en el moment en què arriben noves dades buscaria informació en el model i podria donar els resultats buscats.

Els models necessitaran un espai latent amb el qual treballar, aquest espai és una representació comprimida i estructurada de les característiques més rellevants de les imatges, on les dades es codifiquen en forma de vectors que capturen la seva essència de manera més eficient. Tenir una bona definició de l'espai a treballar permetrà generar unes dades més adequades, realistes i variades.

- **Validació dels resultats:**

Donat que el projecte tracta amb temes delicats com és la salut del pacient, cal una validació final dels resultats molt exhaustiva, amb l'objectiu d'obtenir la màxima informació per assegurar que la predicció feta és correcta. Per tal d'avaluar la fiabilitat del sistema, es duran a terme dos tipus de validació diferents: d'una banda, una validació centrada en la reproductibilitat, per comprovar que, sota les mateixes condicions d'entrada, el model ofereix resultats consistents, i de l'altra, una validació orientada a analitzar la capacitat de generalització del model, és a dir, com de bé és capaç de predir en dades no vistes durant l'entrenament. Per dur a terme aquestes validacions, s'utilitzaran diverses mètriques i representacions visuals per facilitar la interpretació dels resultats.

4 METODOLOGIA

Per poder començar a complir els objectius primer de tot s'ha d'entendre com funciona l'extracció de característiques, ja que és el punt de partida i quines alternatives es poden aplicar. Les dades a treballar són un punt important també, s'utilitzaran imatges mèdiques, concretament escàners tomogràfics que donen fitxer de 3 dimensions. Seguint la planificació original, s'ha resolt, en primer lloc, la feina relacionada amb les característiques radiomiques i s'ha seguit a buscar una bona definició de l'Espai Latent.

El diagrama de la figura 1 mostra un resum compacte i simple que mostra tots els passos seguits durant el projecte que inclouen la generació del GroundTruth utilitzant els mètodes actuals, la creació dels models entrenant a partir de les dades originals i el GroundTruth, i la generació de característiques a partir dels models i una validació final.

4.1 Extracció de característiques i generació del Ground Truth

Per tal d'alimentar els models generatius amb informació rellevant, s'ha dut a terme un procés d'extracció de característiques a partir d'imatges mèdiques 3D. Aquest procés consisteix a analitzar les regions d'interès (ROI) a partir de talls axials de la imatge 3D. S'han utilitzat diferents llibreries per a aquest propòsit, comparant-ne l'eficiència i la qualitat dels resultats, amb l'objectiu de construir un conjunt de dades fiable que serveixi com a Ground Truth i dades per entrenar models en fases posteriors del projecte.

4.1.1 PyRadiomics

Partint del codi base d'extracció de característiques radiomiques, s'ha atacat directament als objectius del projecte.

Un cop analitzat el funcionament dels mètodes de la llibreria, s'han provat diferents hiperparàmetres de les funcions de la llibreria PyRadiomics i s'ha paral·lelitzat l'extracció de característiques de cada slice per a utilitzar els recursos de forma òptima i eficient. Un cop extretes les característiques s'han desat en un fitxer i ajuntant-les amb el seu tall corresponent de cada imatge, permet tenir una bona base de dades per entrenar models generatius.

4.1.2 MedPy i SciKit-Image

De forma similar a PyRadiomics s'ha preparat un codi que combina la lectura ràpida d'imatges mèdiques de MedPy amb l'extracció de característiques GLCM que permet SciKit-Image.

El procediment imita al codi de PyRadiomics amb les diferències bàsiques de funcionament de les llibreries, s'itera sobre cada tall de la imatge 3D inicial i s'extreuen les característiques pertinents. En fer un seguit de proves ràpidament ha quedat clar que no és una opció viable per substituir a PyRadiomics tant per velocitat com per qualitat. Per exemplificar la diferència, en PyRadiomics s'ha pogut executar l'extracció en un minut mentre que amb MedPy i SciKit-Image ha tardat una hora i no ha pogut extreure les característiques amb tan alta qualitat.

4.2 Generació de característiques

Un cop extretes les característiques de les imatges mèdiques, el pas següent del projecte ha estat generar noves mostres sintètiques de característiques mitjançant models generatius.

S'han implementat i comparat diversos enfocaments de generació, començant per autoencoders simples i evolucionant cap a arquitectures més complexes com U-Net, Variational AutoEncoders (VAE) i models generatius adversatius condicionals (Conditional GAN).

A continuació es descriuen les diferents arquitectures i les seves pèrdues associades.

4.2.1 AutoEncoder (Simple i U-Net)

El primer model generatiu provat ha estat un autoencoder senzill, amb encoder i decoder sense gaire profunditat. Ha servit de base per a altres models més potents, tot i ser senzill té capacitat per aproximar-se a la generació desitjada.

A partir de la base del codi anterior s'ha afegit profunditat al model posant més capes i afegint operacions entre capes, anomenada arquitectura U-Net. Un model molt similar a l'anterior però que mostra la potència afegida amb la generació de característiques aconseguida. L'arquitectura de l'autoencoder U-Net es basa en 4 capes amb 2 convolucions cadascuna per a l'Encoder i 4 capes simètriques per al Decoder, amb skip connections entre elles, i MaxPooling per a la compressió. Utilitza l'optimitzador Adam i la loss MSE.

$$\text{MSE}(\hat{x}, x) = \frac{1}{n} \sum_{i=1}^n (\hat{x}_i - x_i)^2 \quad (1)$$




Figura 1. Diagrama de la metodologia seguida pas a pas

4.2.2 Variational AutoEncoder

Seguint el camí marcat pels dos autoencoders anteriors el model és molt similar afegint una altra capa extra, la generació d'un espai latent. Gràcies a aquest espai el model té més capacitat de generalitzar.

L'arquitectura es basa en una estructura de tipus U-Net amb espai latent afegit de mida 16 i torna a usar l'optimitzador Adam. En aquest cas per a la loss s'utilitza una combinació entre MSE i KL Divergence més una suma de penalitzacions per a controlar l'espai latent.

$$\mathcal{L}_{VAE} = \text{MSE}(\hat{x}, x) + \beta \cdot D_{KL} + \text{Penalitzacions } \mu \text{ i } \log \text{var} \quad (2)$$

4.2.3 Conditional GAN

El Conditional GAN o model generacional adversariu condicional ha estat una prova des d'un punt de vista completament diferent a la resta de models. En aquest cas s'utilitza un generador que crea unes característiques i un discriminador que les avalua i indica si li semblen reals o falses.

El generador es basa en una arquitectura Encoder-Decoder amb dues convolucions per bloc i inclou skip connections. Tant el discriminador com el generador tenen 4 capes de convolucions, que s'encarreguen de les seves tasques respectivament, a més el generador inclou skip connections per a uns millors resultats. L'optimitzador d'aquest model també és l'Adam però amb l'afegit d'uns paràmetres de control de pesos. La loss per aquest model és una combinació entre BCE més una L1.

$$\mathcal{L}_G = \text{BCE}(D(x_{\text{fake}}), 1) + 100 \cdot \text{L1} \quad (3)$$

$$\mathcal{L}_1 = \|\hat{x} - x\|_1 = \sum_{i=1}^n |\hat{x}_i - x_i| \quad (4)$$

5 DATASET

Per a poder treballar amb les dades cal entendre d'on provenen i com tractar-les per a després poder generar aquestes característiques buscades a través de models generatius.

5.1 Origen i preparació de les dades

De forma concisa, les dades són tomografies computeritzades del tòrax, concretament d'un VOI (Volume of Interest) dels nòduls pulmonars, aquests volums són en 3D. Les imatges es van fer a l'hospital universitari Germans Trias i Pujol (HUGTiP) a Barcelona, Espanya, en uns escàners GE Medical Systems, Philips, and Siemens CT scanners.

El primer tractament que han rebut les dades ha estat la creació de talls en 2D convertint el volum 3D en un conjunt d'imatges com la que es pot observar en la figura 2. Posteriorment, s'han extret característiques de cada tall amb PyRadiomics, aquest procés ha trigat al voltant de dues hores i ha estat força costós computacionalment parlant, fet que demostra el problema que es vol solucionar. En acabar aquest procés s'ha observat que es tracta amb un total de 5865 talls d'entre 105 pacients, en què cada pacient té un nombre diferent de talls en el volum.




Figura 2. Imatge del tall central d'un nòdul (ID-123)

Un cop preparades les imatges i les característiques, per a poder entrenar els models generatius s'han fet tuples, s'ha ajuntat cada imatge amb les seves característiques i amb això és amb el que els 4 models han après a generar. Donat un volum 3D, cada model ha de generar les característiques que correspondrien a cada tall.

5.2 Característiques Utilitzades

De totes les característiques radiomiques disponibles se n'ha fet una selecció de 10 característiques de cinc tipus diferents [15]. Entre aquestes seleccionades s'han inclòs característiques que permeten analitzar aspectes com la forma i l'estructura general, així com característiques orientades a

estudiar la textura. També s'han considerat mesures relacionades amb la distribució de les intensitats i la uniformitat de les zones dins la imatge.

5.2.1 Característiques GLCM

Les característiques Gray Level Co-occurrence Matrix o GLCM analitza la relació entre parelles de píxels amb intensitats similars a una distància determinada.

- **original_glcmm_Contrast:** Mesura la diferència local d'intensitat. Valors alts indiquen molta variació entre píxels veïns.
- **original_glcmm_Correlation:** Indica com d'estadísticament relacionades estan les intensitats dels píxels (0 o 1). Un valor de 1 implica una correlació perfecta.
- **original_glcmm_DifferenceEntropy:** Mesura el desordre o la incertesa en les diferències d'intensitat. Més alt implica més complexitat o variabilitat.
- **original_glcmm_ClusterTendency:** Mesura d'agrupacions de voxels amb valors similars de nivell de gris. Un alt implica més agrupament.

5.2.2 Característiques GLSZM

Les característiques Gray Level Size Zone Matrix o GLSZM capturen zones de píxels connectats amb la mateixa intensitat.

- **original_glszm_GrayLevelVariance:** Mesura la variabilitat d'intensitat dels grisos dins les zones.
- **original_glszm_ZoneEntropy:** Avaluja la incertesa o complexitat de la distribució de zones de diferent mida i intensitat. Un valor més alt indica més heterogeneïtat en els patrons de textura.

5.2.3 Característiques GLRLM

Les característiques Gray Level Run Length Matrix o GLRLM quantifiquen les curses de nivell de gris, que es defineixen com la longitud (en nombre de píxels) de seqüències consecutives de píxels amb el mateix valor de gris.

- **original_glrlm_RunLengthNonUniformity:** Mesura la variabilitat de la longitud dels runs. Un alt valor implica menys uniformitat, més diversitat de longituds.

5.2.4 Característiques GLDM

Les característiques Gray Level Dependence Matrix o GLDM mesuren quants píxels depenen d'un píxel central amb una intensitat similar.

- **original_gldm_DependenceNonUniformity:** Mesura la similitud de dependència al llarg de la imatge. Valors alts indiquen una menor homogeneïtat.

5.2.5 Característiques NGTDM

Les característiques Neighboring Gray Tone Difference Matrix o NGTDM mesuren diferències entre un píxel i els seus veïns.

- **original_ngtddm_Strength:** Mesura de les primitives en una imatge. Un alt valor implica canvis d'intensitats marcats.
- **original_ngtddm_Busyness:** Mesura els canvis entre píxels veïns. Valors alts indiquen patrons molt canviants i complexos.

6 EXPERIMENTS I RESULTATS

Un cop les dades han estat preparades i els models pensats i programats per a la tasca a fer s'han executat els experiments i observat els resultats.

Per tal d'analitzar el rendiment dels models, s'han plantejat dues situacions diferenciades pel que fa a la distribució de les dades d'entrenament. Això ha permès estudiar tant la generació de característiques per a casos completament nous com la capacitat de generalització quan determinades zones de les imatges no han estat vistes durant l'entrenament.

Els experiments s'han executat en un entorn controlat, aprofitant recursos computacionals amb GPU i un conjunt de llibreries especialitzades. Per avaluar objectivament els resultats, s'han utilitzat mètriques de similitud i qualitat com l'SSIM i la similitud cosinus, així com el seguiment de les funcions de pèrdua pròpies de cada arquitectura.

Les següents subseccions detallen cadascun d'aquests elements, des de la preparació de les dades fins als resultats obtinguts per cada escenari proposat.

6.1 Partició de dades

Abans de començar amb tot l'entrenament dels models s'han pensat dos casos per a poder veure el comportament dels models sota condicions diferents. En ambdós casos s'han utilitzat al voltant de 105 nòduls d'escàners de pacients diferents, els casos són els següents:

Generalització: Tots els nòduls han format part de l'entrenament però s'han tret percentatges de dades de zones concretes. En totes les dades s'ha tret un 5% d'imatges de la part superior, un altre 5% de la part inferior i un 10% del centre fent un train/test de 80/20.

Reproductibilitat: S'ha entrenat amb nòduls sencers i les seves característiques seguint un train/test de 80/20 en el que s'han apartat també nòduls sencers amb tots els seus talls i característiques per a fer el test.

6.2 Entorn de desenvolupament

Els experiments s'han desenvolupat utilitzant un ordinador portàtil amb les següents especificacions tècniques: processador AMD Ryzen 7 5800H amb gràfics integrats Radeon, amb una freqüència base de 3,20 GHz. El sistema disposa de 16 GB de memòria RAM, i compta amb dues unitats gràfiques: una GPU dedicada NVIDIA GeForce RTX 3070 Laptop amb 8 GB, i una GPU integrada AMD Radeon amb

496 MB. L'emmagatzematge intern consisteix en una unitat d'estat sòlid (SSD) d'1 TB.

El codi ha estat desenvolupat en Python, utilitzant diverses llibreries especialitzades per al tractament d'imatges mèdiques, l'extracció de característiques i la implementació de models de deep learning. Les versions utilitzades de les principals llibreries han estat: PyRadiomics 3.10.0 per a l'extracció de característiques radiòmiques, Scikit-learn 1.6.1 per a funcionalitats de machine learning, Torch 2.5.1 amb suport per CUDA 12.1 per a la construcció i entrenament dels models neuronals, NumPy 1.24.2 per al càlcul numèric, MedPy 0.5.2 per al processament d'imatges mèdiques, Matplotlib 3.7.1 per a la visualització de resultats, i SimpleITK 2.4.1 per a la manipulació i lectura d'imatges mèdiques en format NIFTI.

6.3 Mètriques utilitzades

Per tal d'avaluar la qualitat de les imatges generades i la seva similitud amb les imatges reals, s'han emprat dues mètriques principals: SSIM i la similitud cosinus.

- **SSIM (Structural Similarity Index Measure):** Aquesta mètrica compara dues imatges tenint en compte la luminància, el contrast i l'estructura, proporcionant un valor entre -1 i 1 que indica el grau de similitud estructural. És especialment útil per avaluar la qualitat perceptiva de les imatges generades. Un valor de 1 indica una similitud estructural igual.

$$\text{SSIM}(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (5)$$

- **Similitud cosinus:** Aquesta mètrica mesura l'angle cosinus entre dos vectors com poden ser imatges vectoritzades, i s'utilitza per quantificar la similitud entre elles. Un valor de 1 indica vectors idèntics, mentre que 0 indica similitud nul·la.

$$\text{Sim}_{\cos}(x, y) = \frac{x \cdot y}{\|x\| \|y\|} = \frac{\sum_{i=1}^n x_i y_i}{\sqrt{\sum_{i=1}^n x_i^2} \sqrt{\sum_{i=1}^n y_i^2}} \quad (6)$$

Aquestes dues mètriques proporcionen una visió complementària: mentre que SSIM s'enfoca en aspectes perceptius i estructurals, la similitud cosinus s'aplica a l'espai vectorial per mesurar la proximitat entre representacions numèriques de les imatges. A més també s'han utilitzat les loss individuals de cada model per a poder fer una avaluació del model més completa, aquestes loss es poden veure en les figures 6 i 7 de l'apèndix on estan juntament amb les altres mètriques.

6.4 Resultats obtinguts

Els resultats obtinguts per a tots els experiments han estat en general bons per algunes característiques concretes, i no tan bons per altres en ambdós casos de la generació. Cal remarcar que cada model s'ha entrenat amb unes variables concretes que s'han mantingut entre experiments. Les diferències més habituals han estat en el batch size, de 128 en l'AutoEncoder simple i el U-Net, de 64 en el VAE, i de 32 en el cGAN, el learning rate també ha estat de 1e-3 per a tots els models menys el cGAN i el cGAN ha utilitzat un paràmetre extra en l'optimitzador Adam.

6.4.1 Experiment 1 - Extracció de característiques

Abans de començar amb els experiments de desenvolupament de models generatius, es va fer un apropament al problema més bàsic. Aquest experiment ha analitzat la capacitat d'extracció de característiques radiòmiques de MedPy amb scikit-Image comparat amb PyRadiomics, el mètode actual.

Les proves han consistit en extreure algunes característiques GLCM i comparar-les tant numèricament, com visualment amb les de PyRadiomics. Sense gaires dificultats s'ha pogut observar que l'ús de MedPy i scikit-Image no són un bon substitut per al mètode actual, ja que per extreure una sola característica es triga més d'una hora mentre que amb PyRadiomics uns dos minuts, també perquè la qualitat numèrica es pitjor fet que al visualitzar-ho es diferencial.

6.4.2 Experiment 2 - Generalització

La intenció dels experiments d'aquest cas és analitzar la capacitat de generalització dels models quan certes zones de les imatges no han estat utilitzades durant l'entrenament. Els resultats mostren que, tot i l'eliminació d'un 20% de les dades (5% superior, 5% inferior i 10% central), els tres models han tingut una capacitat de reconstrucció acceptable mantenint valors força competitiu tant de similitud cosinus com, en molts casos, de SSIM. En general, es manté una loss baixa amb les consideracions especials del VAE ja que introdueix unes penalitzacions que fan variar la loss com es veu en la figura 6 de l'apèndix.

Analitzant els resultats globals de la taula 2, l'AE U-Net és el model que ha obtingut els valors més alts en 5 de les 10 característiques radiòmiques, destacant la seva capacitat de preservar l'estructura. Això es reflecteix en la seva mitjana global de 0.5563 ± 0.2704 en SSIM i 0.8907 ± 0.0827 en cosinus. El VAE ha mostrat un comportament similar amb la mitjana global més alta de 0.6026 ± 0.2001 en SSIM i 0.8969 ± 0.0795 en cosinus amb un millor rendiment en les altres 5 de les 10 característiques, especialment en aquelles relacionades amb l'entropia i la no uniformitat, aspectes on la seva naturalesa probabilística aporta més flexibilitat davant de la incertesa. Finalment, el cGAN, tot i presentar valors globals inferiors 0.5033 ± 0.2113 en SSIM i 0.8173 ± 0.1214 en cosinus, ofereix en alguns casos una qualitat visual notable que les mètriques clàssiques no capten del tot com es el cas de la característica Busyness en la figura 3.

Observant la taula 2 i enllaçant amb el paràgraf anterior, l'AE U-Net ofereix alguns dels valors més alts, destacant especialment en característiques com ClusterTendency (SSIM = 0.9089, Cosine = 0.9703), GrayLevelVariance (SSIM = 0.9053, Cosine = 0.9696) i Strength (SSIM = 0.8745, Cosine = 0.9765).

Pel que fa al VAE, tot i tenir una arquitectura amb enfoc probabilístic que habitualment resulta en reconstruccions més difuses, ha aconseguit resultats notables en algunes mètriques específiques. En concret, supera l'AE U-Net en característiques com DifferenceEntropy (SSIM = 0.3207 vs. 0.1529) i DependenceNonUniformity (SSIM = 0.4941 vs. 0.2771), fet que suggereix una major flexibilitat del model en entorns amb incertesa o variabilitat local, característica pròpia dels autoencoders variacionals.

D'altra banda, el model cGAN presenta de manera general resultats numèrics més baixos, sobretot en mètriques




Figura 3. Gràfiques Generalització (corresponen al tall central d'un nòdul ID-123)

Mètrica	AE U-Net		VAE		cGAN	
	SSIM	Cosine	SSIM	Cosine	SSIM	Cosine
Contrast	0.8722 ± 0.0331	0.9621 ± 0.0269	0.8121 ± 0.1139	0.9422 ± 0.0261	0.7524 ± 0.1257	0.8968 ± 0.0356
Correlation	0.3642 ± 0.1066	0.8951 ± 0.0295	0.4241 ± 0.1068	0.9023 ± 0.0249	0.2611 ± 0.0816	0.8095 ± 0.0531
DifferenceEntropy	0.1529 ± 0.0427	0.8530 ± 0.0513	0.3207 ± 0.0720	0.8710 ± 0.0407	0.1974 ± 0.0551	0.7837 ± 0.0428
ClusterTendency	0.9089 ± 0.0679	0.9703 ± 0.0180	0.8976 ± 0.0687	0.9677 ± 0.0197	0.8152 ± 0.1113	0.9090 ± 0.0326
GrayLevelVariance	0.9053 ± 0.0590	0.9696 ± 0.0173	0.8724 ± 0.0950	0.9683 ± 0.0154	0.7953 ± 0.1023	0.9126 ± 0.0270
RunLengthNU	0.3316 ± 0.1049	0.8137 ± 0.0432	0.4263 ± 0.0828	0.8257 ± 0.0524	0.3952 ± 0.0810	0.7429 ± 0.0612
ZoneEntropy	0.4504 ± 0.1048	0.9403 ± 0.0254	0.5361 ± 0.0918	0.9455 ± 0.0248	0.4740 ± 0.0722	0.9152 ± 0.0346
DependenceNU	0.2771 ± 0.1134	0.8018 ± 0.0456	0.4941 ± 0.1063	0.8489 ± 0.0440	0.3932 ± 0.0631	0.7532 ± 0.0513
Strength	0.8745 ± 0.0572	0.9765 ± 0.0106	0.8507 ± 0.0676	0.9751 ± 0.0101	0.7552 ± 0.0663	0.9376 ± 0.0126
Busyness	0.4256 ± 0.1318	0.7241 ± 0.0727	0.3916 ± 0.1079	0.7220 ± 0.0707	0.1936 ± 0.0719	0.5124 ± 0.1071
Mitjana global	0.5563 ± 0.2704	0.8907 ± 0.0827	0.6026 ± 0.2001	0.8969 ± 0.0795	0.5033 ± 0.2113	0.8173 ± 0.1214

TAULA 2. TAULA DE VALORS DE L'EXPERIMENT DE GENERALITZACIÓ.

sensibles a la textura i al soroll com Busyness (SSIM = 0.1936, Cosine = 0.5124) i DifferenceEntropy (SSIM = 0.1974). Tot i això, no es pot descartar la seva utilitat, ja que en alguns casos visuals concrets, com es mostra a la Figura 3, el cGAN aconsegueix reconstruccions visiblement coherents, especialment en detalls puntuals que poden no ser reflectits per les mètriques objectives. Aquest contrast entre qualitat perceptiva i resultats numèrics apunta al fet que el model pot aprendre a reconstruir patrons complexos de manera convincent, tot i que no sempre millora segons les mètriques clàssiques.

Aquests resultats numèrics es poden visualitzar en format imatge a la Figura 3, on es mostren comparacions entre les imatges originals (primera fila) i les generades pels diferents models.

6.4.3 Experiment 3 - Reproductibilitat

La intenció dels experiments d'aquest cas és veure la capacitat de generació de zero que té cada model. Els resultats mostren que els tres models (AE U-Net, VAE i cGAN) tenen rendiments diversos en les mètriques SSIM i similitud cosinus depenent de la característica analitzada. En general, es manté una loss baixa amb les consideracions especials del VAE que fan variar la loss com es veu en la figura 7 de

l'apèndix.

En aquest experiment, com es pot observar a la Taula 3, l'AE U-Net destaca amb els millors resultats globals en 9 de les 10 característiques analitzades segons el SSIM i amb una mitjana global de 0.6408 ± 0.2265 en SSIM i 0.9069 ± 0.0732 en cosinus, mostrant un gran compromís entre estructura i intensitat. El VAE, amb una mitjana de 0.5692 ± 0.2320 en SSIM i 0.8887 ± 0.0862 en cosinus, ofereix una qualitat intermèdia, amb un millor rendiment en 1 característica. El cGAN, en canvi, és el model amb pitjor rendiment global de 0.5150 ± 0.2104 en SSIM i 0.8196 ± 0.1217 en cosinus, mostrant dificultats especials per a generar detalladament les característiques, tot i que, en alguns casos com el de la característica Busyness en la Figura 4, és capaç de produir de forma similar a l'original visualment.

Seguint el que s'ha mencionat, el model AE U-Net ha obtingut els millors resultats en la majoria de característiques, tant en termes de SSIM com de cosine similarity, indicant una alta fidelitat estructural i una gran similitud entre algunes de les característiques generades i les originals. Per exemple, en característiques com ClusterTendency (SSIM = 0.9412, Cosine = 0.9803), GrayLevelVariance (SSIM = 0.9358, Cosine = 0.9814) i Strength (SSIM = 0.8910, Cosine = 0.9821).

El VAE ha mostrat un rendiment intermig. Encara que




Figura 4. Gràfiques Reproductibilitat(corresponen al tall central d'un nòdul ID-123)

Mètrica	AE U-Net		VAE		cGAN	
	SSIM	Cosine	SSIM	Cosine	SSIM	Cosine
Contrast	0.9208 ± 0.0427	0.9758 ± 0.0171	0.8179 ± 0.1090	0.9398 ± 0.0264	0.7644 ± 0.0990	0.9061 ± 0.0310
Correlation	0.3337 ± 0.0835	0.8950 ± 0.0320	0.3767 ± 0.0943	0.9012 ± 0.0281	0.2743 ± 0.0577	0.8324 ± 0.0474
DifferenceEntropy	0.2823 ± 0.0563	0.8607 ± 0.0347	0.1700 ± 0.0510	0.8468 ± 0.0410	0.2087 ± 0.0468	0.7644 ± 0.0404
ClusterTendency	0.9412 ± 0.0426	0.9803 ± 0.0169	0.8851 ± 0.0713	0.9658 ± 0.0191	0.8006 ± 0.0976	0.9148 ± 0.0294
GrayLevelVariance	0.9358 ± 0.0397	0.9814 ± 0.0140	0.8422 ± 0.0941	0.9636 ± 0.0148	0.7880 ± 0.0990	0.9190 ± 0.0295
RunLengthNU	0.5005 ± 0.0787	0.8429 ± 0.0357	0.4185 ± 0.0870	0.8224 ± 0.0365	0.4128 ± 0.0631	0.7574 ± 0.0395
ZoneEntropy	0.5990 ± 0.0713	0.9460 ± 0.0172	0.5854 ± 0.0628	0.9457 ± 0.0185	0.4680 ± 0.0695	0.8851 ± 0.0422
DependenceNU	0.4925 ± 0.0750	0.8418 ± 0.0362	0.4180 ± 0.0845	0.8238 ± 0.0355	0.4269 ± 0.0619	0.7617 ± 0.0418
Strength	0.8910 ± 0.0447	0.9821 ± 0.0075	0.8466 ± 0.0682	0.9758 ± 0.0082	0.7637 ± 0.0698	0.9467 ± 0.0114
Busyness	0.5114 ± 0.1302	0.7630 ± 0.0556	0.3319 ± 0.1212	0.7023 ± 0.0715	0.2430 ± 0.0990	0.5085 ± 0.0781
Mitjana global	0.6408 ± 0.2265	0.9069 ± 0.0732	0.5692 ± 0.2320	0.8887 ± 0.0862	0.5150 ± 0.2104	0.8196 ± 0.1217

TAULA 3. TAULA DE VALORS DE L'EXPERIMENT DE REPRODUCTIBILITAT.

la seva SSIM i és notablement inferior a la de l'AE U-Net, especialment en característiques com DifferenceEntropy (SSIM = 0.1700, Cosine = 0.8468) i Busyness (SSIM = 0.3319, Cosine = 0.7023). En el que a similitud Cosine respecta, els canvis no es noten tant però segueixen un comportament similar a la SSIM sent generalment inferiors que en l'AE U-Net.

Finalment, el model cGAN és el que presenta els pitjors resultats globals, especialment pel que fa a la SSIM, amb valors força baixos en característiques com Busyness (SSIM = 0.2430, Cosine = 0.5085) o Correlation (SSIM = 0.2743, Cosine = 0.8324), fet que indica una pèrdua important de la forma original de les característiques. Els valors de cosine, tot i ser generalment més alts que la SSIM, són també els més baixos entre els tres models.

Aquests resultats numèrics es poden visualitzar en format imatge a la Figura 4, on es mostren comparacions entre les imatges originals (primera fila) i les generades pels diferents models.

7 CONCLUSIONS

Amb els resultats observats fins al moment es pot concloure que els models generatius poden arribar a ser una molt bona

opció per a substituir la llibreria PyRadiomics en l'extracció d'algunes característiques.

Els models generatius han complert amb els requisits de reducció de temps i de reducció de cost computacional de forma molt satisfactòria, ja que un cop entrenat el model amb una inferència d'uns cinc segons ja s'obtenen resultats i no consumeix recursos. També han mostrat que l'espai latent que generen no depèn del conjunt de train i amb els dos experiments s'ha mantingut estable.

Si bé com s'ha mencionat es compleixen bé els requisits, els resultats de la generació de dades estan dividits, per una banda, hi ha característiques molt realistes, n'hi ha d'altres que no ho són tant. Això és un problema perquè implica que per aquestes característiques s'hauria de continuar utilitzant PyRadiomics.

En analitzar la diferència entre els experiments de generalització i reproductibilitat, es veu clarament que el model AE U-Net és el que ha mantingut un millor compromís entre estructura i intensitat en ambdós casos, però amb un avantatge especialment marcat en reproductibilitat, on ha aconseguit valors més alts tant en SSIM com en similitud cosinus. Això indica que té una gran capacitat per generar dades des de zero de manera consistent amb les característiques originals.

El VAE ha mostrat un rendiment més equilibrat entre ge-

neralització i reproductibilitat en termes d'intensitat (cosinus), però amb una pèrdua d'estructura (SSIM) més notable, especialment en reproductibilitat. En generalització ha ofert una millor resposta en característiques relacionades amb entropia i variabilitat, aprofitant la seva naturalesa probabilística per adaptar-se millor a zones amb incertesa.

El cGAN ha estat el model amb el pitjor rendiment global en ambdós experiments pel que fa a mètriques quantitatives, però cal destacar que tant en generalització com en Reproductibilitat ha estat capaç de generar detalls puntuals amb coherència visual, encara que no sempre valorats per les mètriques.

Tractant amb dades mèdiques, la precisió en la generació és de vital importància per aquesta raó els resultats obtinguts tenen marge de millora i obren la porta a futures investigacions.

De cara a treballs futurs es podrien validar les extraccions fetes amb professionals del sector i entrenar models de predicció amb aquestes característiques per a poder observar el comportament en casos reals. A més, seria interessant avaluar la usabilitat de les característiques generades utilitzant-les en un sistema end-to-end de diagnòstic digital, com el descrit a la tesi de Guillermo [11], i comprovar si s'assoleixen resultats comparables als que s'obtenen amb les GLCM calculades amb PyRadiomics. També es podria explorar una evolució a models 3D que processin directament la VOI, un procés que, tot i ser computacionalment més exigent, permetria generar GLCM 3D de manera eficient.

AGRAÏMENTS

Voldria expressar el meu sincer agraïment al meu tutor, Carles Sanchez Ramos, per la seva orientació, paciència i suport durant tot el procés d'aquest treball.

A la meua família i amics, gràcies per ser-hi sempre, pel vostre suport incondicional i per animar-me en els moments difícils.

Finalment, gràcies a totes les persones que, d'una manera o altra, han contribuït a fer possible aquest projecte.

REFERÈNCIES

- [1] World Health Organization, "Lung cancer." [Online]. Available: <https://www.who.int/es/news-room/fact-sheets/detail/lung-cancer>
- [2] American Cancer Society, "Tasas de supervivencia del cáncer de pulmón." [Online]. Available: <https://www.cancer.org/es/cancer/tipos/cancer-de-pulmon/deteccion-diagnostico-clasificacion-por-etapas/tasas-de-supervivencia.html>
- [3] Python Package Index (PyPI), "MedPy." [Accessed: Feb. 24, 2025]. [Online]. Available: <https://pypi.org/project/MedPy/>
- [4] Pérez-García, F., Sparks, R., and Ourselin, S., "TorchIO: A Python library for medical imaging." [Accessed: Feb. 24, 2025]. [Online]. Available: <https://torchio.readthedocs.io/>
- [5] Stergioc, "LungNet: Semantic Segmentation of Pathological Lung Tissue with Dilated Fully Convolutional Networks," 2018. [Online]. Available: <https://github.com/stergioc/LungNet/tree/master>
- [6] PyTorch, "DCGAN Tutorial." [Accessed: Feb. 17, 2025]. [Online]. Available: https://pytorch.org/tutorials/beginner/dcgan_faces_tutorial.html
- [7] Ho, J., Jain, A., and Abbeel, P., "Denoising Diffusion Probabilistic Models," 2020. [Online]. Available: <https://arxiv.org/abs/2006.11239>
- [8] MathWorks, "Train a Variational Autoencoder (VAE) to Generate Images." [Online]. Available: <https://es.mathworks.com/help/deeplearning/ug/train-a-variational-autoencoder-vae-to-generate-images.html>
- [9] "Deep Learning Innovations in the Detection of Lung Cancer: Advances, Trends, and Open Challenges," 2025. [Online]. Available: <https://link.springer.com/article/10.1007/s12559-025-10408-2>
- [10] "Deep learning-based algorithm for lung cancer detection on chest radiographs using the segmentation method," 2021. [Online]. Available: <https://www.nature.com/articles/s41598-021-04667-w>
- [11] Torres, G. E., "Evaluation of the Reproducibility of Radiomic Intelligent Systems for Early Detection of Lung Cancer," Tesi doctoral, Universitat Autònoma de Barcelona, 2024.
- [12] NVIDIA Labs, "StyleGAN." [Accessed: Feb. 26, 2025]. Available: <https://github.com/NVLabs/stylegan>
- [13] Python Package Index (PyPI), "PyRadiomics." [Accessed: Mar. 10, 2025]. Available: <https://pypi.org/project/pyradiomics/>
- [14] Scikit-Image. [Accessed: Mar. 21, 2025]. Available: <https://scikit-image.org/>
- [15] PyRadiomics features. [Accessed: Mar. 15, 2025]. Available: <https://pyradiomics.readthedocs.io/en/latest/features.html>
- [16] MathWorks, "Train Conditional Generative Adversarial Network (cGAN)." [Accessed: Mar. 03, 2025]. Available: <https://www.mathworks.com/help/deeplearning/ug/train-conditional-generative-adversarial-network.html>
- [17] Isola, P., Zhu, J.-Y., Zhou, T., and Efros, A. A., "Image-to-Image Translation with Conditional Adversarial Networks," arXiv:2003.05991, 2020. [Accessed: Mar. 04, 2025]. Available: <https://arxiv.org/abs/2003.05991>
- [18] Choudhary, G., Srivastava, R., and Kumar, V., "LungNet: A hybrid CNN model for lung cancer classification using CT images," [Accessed: Mar. 02, 2025]. Available: <https://www.sciencedirect.com/science/article/abs/pii/S0010482521000000>

APÈNDIX

A.1 Secció d'Apèndix - Planificació

Un cop esmentats els objectius del projecte, per a poder-los complir es seguirà una planificació que consisteix en els següents tres punts principals:

- **Revisió bibliogràfica:** Estudi dels mètodes i models actuals que busquen característiques d'imatges mèdiques i altres que tenen la capacitat per generar imatges. Observació de projectes relacionats amb el problema a resoldre. En el que respecta a planificació, aquesta part correspon a la fase inicial del projecte i es finalitzarà la primera amb una duració aproximada d'una mica menys d'un mes. A mesura que avanci el projecte es seguirà tenint en compte per si apareix un nou mètode d'última hora.
- **Creació del model:** Implementació de diferents models buscant sempre el que més convingui, es provaran diferents opcions tant per la generació de característiques com per les GANS, es faran proves de forma individual i combinant un model de cada tipus. L'Espai Latent es definirà en aquesta part on es buscarà acotar-lo per a uns millors resultats. En el que respecta a planificació, aquesta part correspon a la fase mitjana del projecte i se li dedicarà bona part del temps del projecte, aproximadament amb una duració d'un mes i mig.
- **Validació dels resultats:** Anàlisi exhaustiva dels resultats obtinguts, donada la naturalesa del projecte, com s'ha mencionat als objectius, és molt important analitzar bé els resultats i donar les conclusions corresponents per poder saber les aplicacions que es podran donar al projecte. En el que respecta a planificació, aquesta part correspon a la fase mitjana i final del projecte, com en el punt anterior, se li dedicarà gran part del temps del projecte, aproximadament amb una duració d'un mes i mig.

Per finalitzar la planificació del projecte, en últim lloc s'acabarà de redactar la memòria del projecte que s'ha anat fent des del principi i donar els retocs finals.




Figura 5. Timetable

A.2 Secció d'Apèndix - Imatges




Figura 6. Taula de gràfiques amb loss, SSIM i Cosinus - Generalització




Figura 7. Taula de gràfiques amb loss, SSIM i Cosinus - Reproductibilitat