



UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA



ESCOLA TÈCNICA
SUPERIOR ENGINYERIA
INDUSTRIAL VALÈNCIA

TREBALL FINAL DE GRAU EN ENGINYERIA BIOMÈDICA

**DISSENY D'UNA APROXIMACIÓ BASADA
EN RADIÒMICA PER A UNA
CLASSIFICACIÓ DE TUMORS DE PRÒSTATA
MITJANÇANT ANÀLISI DE TEXTURES EN
IMATGES DE RESSONÀNCIA MAGNÈTICA**

AUTOR: JOSE MANUEL JAÉN LORITES

TUTOR: DAVID MORATAL PÉREZ

COTUTORS: SILVIA RUÍZ ESPAÑA
TANIA PIÑEIRO VIDAL

Curs Acadèmic: 2019-20

AGRAÏMENTS

A David, pel seu suport incondicional, per totes les oportunitats, per confiar en mi i ajudar-me a millorar. Gràcies per no ser sols un professor o un tutor.

A Sílvia, per sempre tindre un minut per a dedicar-me, per ajudar-me a traure el millor de mi, i per fer-ho sempre amb un somriure. Gràcies per no ser sols una cotutora.

A ERESA - Grup ASCIRES, i de forma especial, a Tania, sense la qual aquest treball no haguera sigut possible, per la seua dedicació i pel seu compromís.

A la meua família, per ser un pilar no sols en aquesta etapa, sinó per haver-ho sigut durant tota la vida, i per continuar sent-ho.

A Maria per aportar-me la calma quan ha sigut necessària, per compartir no sols els bons moments, sinó també els roïns.

Als companys i amics que he trobat en aquesta meravellosa carrera, que heu aconseguit que quatre anys pareguen quatre dies. Aquest treball no simbolitza el fi d'una etapa, sinó el principi d'altra.

BioR.

Moltes gràcies a tots.

RESUMEN

Hoy en día, el cáncer es una de las principales causas de muerte a escala mundial. En hombres, uno de los cánceres más frecuentes es el de próstata. En 2018 hubo más de 1 millón de muertes por cáncer de próstata, y se espera que para 2040 esta cifra sea superior a los 2 millones. Uno de los aspectos clave a la hora de tratar el cáncer de próstata, es la detección temprana, gracias a la cual se puede no solo salvar vidas, sino mejorar la calidad de vida de los pacientes.

Para planear el tratamiento a seguir, se clasifica el tumor en función de sus características, con lo que se estima su malignidad. La clasificación PI-RADS v2, la cual se realiza a partir de imágenes de resonancia magnética (MRI), es una de las más usadas que no requieren procedimientos invasivos. Dicha clasificación va de 1 a 5, donde nos indica una muy baja o muy alta probabilidad de cáncer clínicamente significativo.

En este trabajo se pretende, a partir de MRI potenciadas en T2, en difusión (DWI), y mapas ADC, realizar un estudio con un enfoque radiómico con el fin de encontrar biomarcadores objetivos capaces de clasificar correctamente lesiones de próstata en PI-RADS 2 (clase 1), 3 (clase 2) y 4 y 5 (clase 3). Para ello, se estudian 97 casos, siendo 27 de clase 1, 37 de clase 2 y 33 de clase 3.

Tras obtener una segmentación de las lesiones, se extraen 3 características de texturas globales, y 40 por nivel de gris. Estos niveles de gris hacen referencia a la cuantización realizada previa a la extracción de características. Dado que se utilizan 5 niveles de gris (16, 32, 64, 128 y 256), se obtienen un total de 203 características de texturas. Este número se multiplica por las tres series de imágenes diferentes con las que se cuenta.

Debido a características de las muestras de la serie DWI, se estudia la existencia de diferencias en los valores, no relacionadas con la clasificación a estudiar, que pueden comprometer los resultados. Se demuestra que sí hay diferencias estadísticamente significativas en función del valor de b , parámetro de la serie DWI.

Debido a estos resultados, se realiza un estudio de las texturas, excluyendo la serie DWI. En este estudio se utilizan modelos basados en aprendizaje automático para realizar la clasificación de las lesiones de próstata. Se realiza posteriormente, debido al reducido número de muestras con un valor de b distinto en la serie DWI, un segundo estudio sin dichas muestras, con el objetivo de incluir la información que proporciona la serie DWI. Finalmente, se realiza un tercer estudio con todas las muestras, excluyendo aquellas variables de DWI en las que se ha encontrado que existen diferencias en función del valor de b .

Se obtienen resultados de $AUC > 0.7$ en los tres estudios, llegando a resultados de $AUC > 0.75$ en el tercer estudio. Se encuentra también que los modelos confunden en gran medida la clase 2, lo cual puede deberse a la subjetividad que presenta dicha clase. Con los resultados obtenidos, podemos afirmar que la metodología seguida puede proporcionar biomarcadores útiles para ayudar a la hora de clasificar lesiones de próstata.

Palabras clave: *cáncer; próstata; clasificador; aprendizaje supervisado; análisis de texturas; RADIOMICS; MRI, DWI, ADC.*

RESUM

Hui dia, el càncer és una de les principals causes de mort a escala mundial. En homes, un dels càncers més freqüents és el de pròstata. En 2018 va haver-hi més d'1 milió de morts per càncer de pròstata, i s'espera que per a 2040 aquesta xifra siga superior als 2 milions. Un dels aspectes clau a l'hora de tractar el càncer de pròstata, és la detecció primerenca, gràcies a la qual es pot no sols salvar vides, sinó millorar la qualitat de vida dels pacients.

Per a planejar el tractament a seguir, es classifica el tumor en funció de les seues característiques, amb el que s'estima la seua malignitat. La classificació PI-RADS v2, la qual es realitza a partir d'imatges de ressonància magnètica (MRI), és una de les més usades que no requereixen procediments invasius. Aquesta classificació va d'1 a 5, on ens indica una molt baixa o molt alta probabilitat de càncer clínicament significatiu.

En aquest treball es pretén, a partir de MRI potenciades en T2, en difusió (DWI), i mapes ADC, realitzar un estudi amb un enfocament radiòmic amb la finalitat de trobar biomarcadors objectius capaços de classificar correctament lesions de pròstata en PI-RADS 2 (classe 1), 3 (classe 2) i 4 i 5 (classe 3). Per a això, s'estudien 97 casos, sent 27 de classe 1, 37 de classe 2 i 33 de classe 3.

Després d'obtenir una segmentació de les lesions, s'extrauen 3 característiques de textures globals, i 40 per nivell de gris. Aquests nivells de gris fan referència a la quantització realitzada prèvia a l'extracció de característiques. Atés que s'utilitzen 5 nivells de gris (16, 32, 64, 128 i 256), s'obtenen un total de 203 característiques de textures. Aquest número es multiplica per les tres sèries d'imatges diferents amb les quals es compta.

A causa de característiques de les mostres de la sèrie DWI, s'estudia l'existència de diferències en els valors, no relacionades amb la classificació a estudiar, que poden comprometre els resultats. Es demostra que sí que hi ha diferències estadísticament significatives en funció del valor de b, paràmetre de la sèrie DWI.

A causa d'aquests resultats, es realitza un estudi de les textures, excloent la sèrie DWI. En aquest estudi s'utilitzen models basats en aprenentatge automàtic per a realitzar la classificació de les lesions de pròstata. Es realitza posteriorment, a causa del reduït nombre de mostres amb un valor de b diferent en la sèrie DWI, un segon estudi sense aquestes mostres, amb l'objectiu d'incloure la informació que proporciona la sèrie DWI. Finalment, es realitza un tercer estudi amb totes les mostres, excloent aquelles variables de DWI en les quals s'ha trobat que existeixen diferències en funció del valor de b.

S'obtenen resultats de $AUC > 0.7$ en els tres estudis, arribant a resultats de $AUC > 0.75$ en el tercer estudi. Es troba també que els models confonen en gran manera la classe 2, la qual cosa pot deure's a la subjectivitat que presenta aquesta classe. Amb els resultats obtinguts, podem afirmar que la metodologia seguida pot proporcionar biomarcadors útils per a ajudar a l'hora de classificar lesions de pròstata.

Paraules clau: càncer; pròstata; classificador; aprenentatge supervisat; anàlisi de textures; RADIOMICS; MRI, DWI, ADC.

ABSTRACT

Today, cancer is one of the leading causes of death worldwide. In men, one of the most common cancers is prostate cancer. In 2018 there were more than 1 million deaths from prostate cancer, and by 2040 this figure is expected to exceed 2 million. One of the key aspects of treating prostate cancer is early detection, which can not only save lives but also improve the quality of life of patients.

In order to plan the treatment to be followed, the tumor is classified according to its characteristics, thus estimating its malignancy. The PI-RADS v2 classification, which is made from magnetic resonance imaging (MRI), is one of the most used that does not require invasive procedures. This classification ranges from 1 to 5, where it indicates a very low or very high probability of clinically significant cancer.

This study aims to use T2-enhanced and diffusion enhanced (DWI) MRI and ADC maps to conduct a study using a radiomic approach to find objective biomarkers capable of correctly classifying prostate lesions in PI-RADS 2 (class 1), 3 (class 2) and 4 and 5 (class 3). To this end, 97 cases were studied, 27 of them in class 1, 37 in class 2 and 33 in class 3.

After obtaining a segmentation of the lesions, 3 characteristics of global textures are extracted, and 40 by grey level. These grey levels refer to the quantization carried out before the extraction of characteristics. Since 5 grey levels are used (16, 32, 64, 128 and 256), a total of 203 texture characteristics are obtained. This number is multiplied by the three different image series available.

Due to the characteristics of the DWI series samples, we study the existence of differences in the values, not related to the classification to be studied, which can compromise the results. It is demonstrated that there are statistically significant differences depending on the value of b , a parameter of the DWI series.

Due to these results, a study of the textures is carried out, excluding the DWI series. In this study, models based on automatic learning are used to classify prostate lesions. Due to the small number of samples with a different b -value in the DWI series, a second study without such samples is performed to include the information provided by the DWI series. Finally, a third study is carried out with all the samples, excluding those DWI variables in which it has been found that differences are depending on the value of b .

Results of $AUC > 0.7$ are obtained in the three studies, reaching results of $AUC > 0.75$ in the third study. It was also found that the models largely confuse class 2, which may be due to the subjectivity presented by this class. With the results obtained, we can affirm that the methodology followed can provide useful biomarkers to help in the classification of prostate lesions.

Keywords: *cancer; prostate; classifier; supervised learning; texture analysis; RADIOMICS; MRI, DWI, ADC.*

DISSENY D'UNA APROXIMACIÓ BASADA EN RADIÒMICA PER A UNA CLASSIFICACIÓ DE TUMORS DE PRÒSTATA MITJANÇANT ANÀLISI DE TEXTURES EN IMATGES DE RESSONÀNCIA MAGNÈTICA

DOCUMENTS CONTINGUTS EN EL TFG

- Memòria
- Pressupost

DISSENY D'UNA APROXIMACIÓ BASADA EN RADIÒMICA PER A UNA CLASSIFICACIÓ DE TUMORS DE PRÒSTATA MITJANÇANT ANÀLISI DE TEXTURES EN IMATGES DE RESSONÀNCIA MAGNÈTICA

DOCUMENT

MEMÒRIA

DISSENY D'UNA APROXIMACIÓ BASADA EN RADIÒMICA PER
A UNA CLASSIFICACIÓ DE TUMORS DE PRÒSTATA MITJANÇANT
ANÀLISI DE TEXTURES EN IMATGES DE RESSONÀNCIA
MAGNÈTICA

AUTOR: JOSE MANUEL JAÉN LORITES

TUTOR: DAVID MORATAL PÉREZ

Centre de Biomaterials i Enginyeria Tissular, Universitat Politècnica de València

COTUTORA: SILVIA RUÍZ ESPAÑA

Centre de Biomaterials i Enginyeria Tissular, Universitat Politècnica de València

COTUTORA: TANIA PIÑEIRO VIDAL

ERESA - Grup Biomèdic ASCIRES

CURS 2019 - 2020

ÍNDIX DE LA MEMÒRIA

1.	Motivació i objectius	1
2.	Introducció	2
2.1.	Càncer de pròstata	2
2.1.1.	Anatomia i fisiologia de la pròstata.....	2
2.1.2.	Patologies de la pròstata.....	3
2.1.3.	Càncer.....	3
2.1.4.	Càncer de pròstata	4
2.1.5.	Classificació del càncer de pròstata	5
2.2.	Imatge de Ressonància Magnètica.....	6
2.2.1.	Ressonància Magnètica.....	6
2.2.2.	La difusió molecular – Les imatges de RM potenciades en difusió.....	7
2.3.	Anàlisi de textures	8
2.3.1.	Adquisició en ressonància magnètica	8
2.3.2.	Definició de la Regió d'interés.....	9
2.3.3.	Preprocessat de la regió d'interés.....	9
2.3.4.	Extracció de característiques.....	10
2.3.5.	Selecció de característiques	13
2.3.6.	Classificació de textures	14
2.3.7.	Tècniques de remostreig.....	16
2.3.8.	Mètriques d'avaluació.....	18
3.	Materials	19
3.1.	Imatges.....	19
3.2.	Programes	20
4.	Metodologia	21
4.1.	Segmentació.....	21
4.2.	Preprocessat.....	21
4.3.	Extracció de característiques	22
4.4.	Estudi del valor de b a les seqüències DWI	23
4.5.	Selecció, classificació i avaluació de les textures. Estudi A.	24
4.6.	Selecció, classificació i avaluació de les textures. Estudi B.	25
4.7.	Selecció, classificació i avaluació de les textures. Estudi C.	25

DISSENY D'UNA APROXIMACIÓ BASADA EN RADIÒMICA PER A UNA CLASSIFICACIÓ DE TUMORS DE PRÒSTATA MITJANÇANT ANÀLISI DE TEXTURES EN IMATGES DE RESSONÀNCIA MAGNÈTICA

5.	Resultats.....	26
5.1.	Estudi del valor de b a les seqüències DWI	26
5.2.	Classificació de lesions de pròstata. Estudi A.....	27
5.2.1.	Nivell de gris 16	27
5.2.2.	Nivell de gris 32	29
5.2.3.	Nivell de gris 64	31
5.2.4.	Nivell de gris 128	33
5.2.5.	Nivell de gris 256	35
5.2.6.	Resum.....	37
5.3.	Classificació de lesions de pròstata. Estudi B.....	38
5.3.1.	Nivell de gris 16	38
5.3.2.	Nivell de gris 32	41
5.3.3.	Nivell de gris 64	43
5.3.4.	Nivell de gris 128	45
5.3.5.	Nivell de gris 256	47
5.3.6.	Resum.....	49
5.4.	Classificació de lesions de pròstata. Estudi C.....	51
5.4.1.	Nivell de gris 16	51
5.4.2.	Nivell de gris 32	53
5.4.3.	Nivell de gris 64	55
5.4.4.	Nivell de gris 128	57
5.4.5.	Nivell de gris 256	59
5.4.6.	Resum.....	61
6.	Discussió.....	63
6.1.	Estudi del valor de b a les seqüències DWI	63
6.2.	Classificació de lesions de pròstata. Estudi A.....	64
6.3.	Classificació de lesions de pròstata. Estudi B.....	65
6.4.	Classificació de lesions de pròstata. Estudi C.....	65
7.	Conclusió.....	67
8.	Línies futures	67
9.	Publicacions derivades d'aquest TFG	68
10.	Bibliografia	69

ÍNDIX D'IL·LUSTRACIONS

Figura 1. Detall gràfic de la pròstata i les seues zones. (Imatge realitzada per Mikael Häggström (Häggström, 2014)).....	2
Figura 2. Procés de l'anàlisi de textures per a classificació de IRM. (Recuperat de (Larroza et al., 2016))	8
Figura 3. Càlcul d'una matriu de co-ocurrències (c) a partir d'una imatge de 4x4 píxels (a) amb tres nivells de gris (b). En aquest exemple, la matriu es calcula en direcció horitzontal per a separació d'un píxel.....	11
Figura 4. Càlcul d'una matriu run-length (c) a partir d'una imatge de 4x4 píxels (a) amb tres nivells de gris (b). En aquest exemple se segueix una direcció horitzontal.	12
Figura 5. Càlcul d'una matriu GLSZM (c) a partir d'una imatge de 4x4 píxels (a) amb tres nivells de gris (b). En aquest exemple se segueix una direcció horitzontal.	12
Figura 6. Exemple del càlcul de la matriu NGTDM a partir d'una imatge de 5x5 píxels amb 4 nivells de gris i una distància $d=1$. En la matriu dels nivells de gris, la zona destacada es correspon amb els píxels a partir dels quals es pot calcular, donat que els píxels més propers de la vora no es poden calcular. (Recuperat de (Ortiz Ramón, 2019))	13
Figura 7. Exemple d'utilització de k-fold amb $k=3$. Es tracta d'un dataset de 12 mostres, amb una classificació binària (roig o blau), on cada subconjunt és de 4 mostres. (Recuperat de (Ortiz Ramón, 2019)).....	17
Figura 8. Exemple de matriu de confusió amb tres classes.....	18
Figura 9. Matriu de confusió general per a dues classes.	19
Figura 10. Segmentació d'una lesió de la pròstata. La segmentació es correspon al color roig.	21
Figura 11. Conjunt de textures que extrau la ferramenta de Vallières. (Recuperat de (Vallières et al., 2015))	23
Figura 12. Gràfica de perfils per model, amb la FS ReliefF i 16 nivells de gris. Estudi A.	28
Figura 13. Gràfica de perfils per model, amb la FS SVM-RFE i 16 nivells de gris. Estudi A..	28
Figura 14. Matriu de confusió del millor model per a nivell de gris 16. Estudi A.....	29
Figura 15. Gràfica de perfils per model, amb la FS ReliefF i 32 nivells de gris. Estudi A.	30
Figura 16. Gràfica de perfils per model, amb la FS SVM-RFE i 32 nivells de gris. Estudi A..	30
Figura 17. Matriu de confusió del millor model per a nivell de gris 32. Estudi A.....	31
Figura 18. Gràfica de perfils per model, amb la FS ReliefF i 64 nivells de gris. Estudi A.	32
Figura 19. Gràfica de perfils per model, amb la FS SVM-RFE i 64 nivells de gris. Estudi A..	32
Figura 20. Matriu de confusió del millor model per a nivell de gris 64. Estudi A.....	33
Figura 21. Gràfica de perfils per model, amb la FS ReliefF i 128 nivells de gris. Estudi A. ..	34

Figura 22. Gràfica de perfils per model, amb la FS SVM-RFE i 128 nivells de gris. Estudi A.	34
Figura 23. Matriu de confusió del millor model per a nivell de gris 128. Estudi A.....	35
Figura 24. Gràfica de perfils per model, amb la FS ReliefF i 256 nivells de gris. Estudi A. ..	36
Figura 25. Gràfica de perfils per model, amb la FS SVM-RFE i 256 nivells de gris. Estudi A.	36
Figura 26. Matriu de confusió del millor model per a nivell de gris 256. Estudi A.....	37
Figura 27. Gràfica de perfils per nivell de gris per al model amb millor resultat. Estudi A.	37
Figura 28. Gràfica de perfils per model, amb la FS ReliefF i 16 nivells de gris. Estudi B.	39
Figura 29. Gràfica de perfils per model, amb la FS SVM-RFE i 16 nivells de gris. Estudi B..	40
Figura 30. Matriu de confusió del millor model per a nivell de gris 16. Estudi B.....	40
Figura 31. Gràfica de perfils per model, amb la FS ReliefF i 32 nivells de gris. Estudi B.	41
Figura 32. Gràfica de perfils per model, amb la FS SVM-RFE i 32 nivells de gris. Estudi B..	42
Figura 33. Matriu de confusió del millor model per a nivell de gris 32. Estudi B.....	42
Figura 34. Gràfica de perfils per model, amb la FS ReliefF i 64 nivells de gris. Estudi B.	43
Figura 35. Gràfica de perfils per model, amb la FS SVM-RFE i 64 nivells de gris. Estudi B..	44
Figura 36. Matriu de confusió del millor model per a nivell de gris 64. Estudi B.....	44
Figura 37. Gràfica de perfils per model, amb la FS ReliefF i 128 nivells de gris. Estudi B. ..	45
Figura 38. Gràfica de perfils per model, amb la FS SVM-RFE i 128 nivells de gris. Estudi B.	46
Figura 39. Matriu de confusió del millor model per a nivell de gris 128. Estudi B.....	46
Figura 40. Gràfica de perfils per model, amb la FS ReliefF i 256 nivells de gris. Estudi B. ..	47
Figura 41. Gràfica de perfils per model, amb la FS SVM-RFE i 256 nivells de gris. Estudi B.	48
Figura 42. Matriu de confusió del millor model per a nivell de gris 256. Estudi B.....	48
Figura 43. Gràfica de perfils per nivell de gris per al model amb millor resultat. Estudi B.	49
Figura 44. Gràfica de perfils per model, amb la FS ReliefF i 16 nivells de gris. Estudi C.	52
Figura 45. Gràfica de perfils per model, amb la FS SVM-RFE i 16 nivells de gris. Estudi C..	52
Figura 46. Matriu de confusió del millor model per a nivell de gris 16. Estudi C.....	53
Figura 47. Gràfica de perfils per model, amb la FS ReliefF i 32 nivells de gris. Estudi C.	54
Figura 48. Gràfica de perfils per model, amb la FS SVM-RFE i 32 nivells de gris. Estudi C..	54
Figura 49. Matriu de confusió del millor model per a nivell de gris 32. Estudi C.....	55
Figura 50. Gràfica de perfils per model, amb la FS ReliefF i 64 nivells de gris. Estudi C.	56
Figura 51. Gràfica de perfils per model, amb la FS SVM-RFE i 64 nivells de gris. Estudi C..	56
Figura 52. Matriu de confusió del millor model per a nivell de gris 64. Estudi C.....	57

Figura 53. Gràfica de perfils per model, amb la FS ReliefF i 64 nivells de gris. Estudi C.	58
Figura 54. Gràfica de perfils per model, amb la FS SVM-RFE i 128 nivells de gris. Estudi C.	58
Figura 55. Matriu de confusió del millor model per a nivell de gris 128. Estudi C.....	59
Figura 56. Gràfica de perfils per model, amb la FS ReliefF i 64 nivells de gris. Estudi C.	60
Figura 57. Gràfica de perfils per model, amb la FS SVM-RFE i 256 nivells de gris. Estudi C.	60
Figura 58. Matriu de confusió del millor model per a nivell de gris 256. Estudi C.....	61
Figura 59. Gràfica de perfils per nivell de gris per al model amb millor resultat. Estudi C.	61

ÍNDIX DE TAULES

Taula 1. Classificació PI-RADS en funció de la senyal obtinguda.....	5
Taula 2. Relació dels paràmetres a potenciar i els temps de ressò i de recuperació.....	7
Taula 5. Classificació PI-RADS dels estudis.	20
Taula 6. Variables amb diferències estadísticament significatives segons el valor de b. Nivells de gris afectats.	26
Taula 7. Resultats Estudi A, Nivell de gris 16.....	27
Taula 8. Resultats Estudi A, Nivell de gris 32.....	29
Taula 9. Resultats Estudi A, Nivell de gris 64.....	31
Taula 10. Resultats Estudi A, Nivell de gris 128.....	33
Taula 11. Resultats Estudi A, Nivell de gris 256.....	35
Taula 12. Llista de les 25 variables més utilitzades per al millor resultat de l'Estudi A.	38
Taula 13. Resultats Estudi B, Nivell de gris 16.....	39
Taula 14. Resultats Estudi B, Nivell de gris 32.....	41
Taula 15. Resultats Estudi B, Nivell de gris 64.....	43
Taula 16. Resultats Estudi B, Nivell de gris 128.....	45
Taula 17. Resultats Estudi B, Nivell de gris 256.....	47
Taula 18. Llista de les 80 variables més utilitzades per al millor resultat de l'Estudi B.....	51
Taula 19. Resultats Estudi C, Nivell de gris 16.....	51
Taula 20. Resultats Estudi C, Nivell de gris 32.....	53
Taula 21. Resultats Estudi C, Nivell de gris 64.....	55
Taula 22. Resultats Estudi C, Nivell de gris 128.....	57
Taula 23. Resultats Estudi C, Nivell de gris 256.....	59
Taula 24. Llista de les 46 variables més utilitzades per al millor resultat de l'Estudi C.....	62

1. MOTIVACIÓ I OBJECTIUS

Hui dia, el càncer és una de les primeres causes de mort a escala mundial (World Health Organization, 2014). Concretament, en 2018 hi va haver més de 18 milions de casos, i s'estima que per a 2040 el número augmentarà un 63%. Quant al nombre de morts, el número va superar els 9.5 milions, i s'estima que en 2040 hi haurà més de 16 milions de defuncions, la qual cosa suposa un 70% més. Respecte al càncer de pròstata, s'estima que es passarà de 1.28 milions a 2.29 milions de casos (International Agency for Research on Cancer, 2019). A Espanya la situació es repeteix, on els tumors van ser la primera causa de mort en homes en 2018, igual que en els dos anys anteriors, on el càncer de pròstata és del qual més casos hi ha (Sociedad Española de Oncología Médica, 2019).

Un dels aspectes claus a l'hora d'aconseguir l'èxit en el tractament del càncer és la detecció primerenca. Un diagnòstic d'hora permet, no sols salvar vides als pacients, sinó evitar-los tractaments incòmodes en la mesura que siga possible, al costat dels costos econòmics que això comporta.

Per a dur a terme el diagnòstic del càncer de pròstata, han de realitzar-se proves incòmodes per al pacient, com poden ser el tacte rectal, o l'ecografia transrectal, entre altres. Posteriorment, es realitza una biòpsia per a confirmar el diagnòstic, i analitzar l'estadi en el qual es troba el tumor.

A causa de l'augment de casos previstos per al càncer de pròstata, i donada la seua importància, es fa necessari obtindre biomarcadors i proves diagnòstiques que siguen eficaces a l'hora de detectar i classificar el tumor, així com evitar, en la mesura que siga possible, la incomoditat al pacient, mitjançant tècniques no invasives.

El present Treball Fi de Grau té com a objectiu general trobar biomarcadors basats en imatge que ens permeten diagnosticar el càncer de pròstata de forma no invasiva, mitjançant l'anàlisi de textures en imatges de RM i l'aplicació de tècniques d'aprenentatge automàtic. Es pretén utilitzar una aproximació radiòmica, fent ús de diferents algorismes de *Machine learning*, per a realitzar el diagnòstic. Per a assolir aquest objectiu general, ens plantejem els següents objectius específics:

- Fer un estudi amb les sèries d'imatges de RM T2, DWI i ADC. Donat que per a la sèrie DWI existeixen mostres amb dos valors de b diferents, estudiar la influència d'aquest paràmetre b sobre les textures. En cas de trobar diferències en les textures en funció d'aquest paràmetre, la sèrie DWI s'haurà de processar tenint en compte el valor de b de les diferents imatges.
- En cas que la sèrie DWI proporcione textures amb diferències estadísticament significatives en funció del paràmetre b , aquesta sèrie s'eliminarà, analitzant únicament les sèries T2 i ADC.
- Realitzar un segon estudi on s'inclouga la sèrie DWI, però es treballa tan sols amb un únic valor de b , per veure com aquesta nova sèrie pot afectar els resultats obtinguts.
- Realitzar un últim estudi amb totes les mostres, però utilitzant únicament aquelles variables de la sèrie DWI que no presenten diferències en funció del valor de b , per analitzar com aquest subconjunt de textures afecta els resultats obtinguts. D'aquesta forma es podrà avaluar, indirectament, el valor discriminatori que afegeix la sèrie DWI.

2. INTRODUCCIÓ

2.1. Càncer de pròstata

2.1.1. Anatomia i fisiologia de la pròstata

La pròstata és una glàndula del sistema reproductor masculí, la qual té una mida d'una nou en adults, aproximadament de 4 x 3 x 2 cm. Aquest òrgan se situa en la pelvis, en la part inferior de la bufeta urinària. A l'interior de la pròstata està la uretra, la qual prové de la bufeta, i es fusiona amb els dos conductes ejaculadors.

Inicialment, la pròstata és anatòmicament descrita amb cinc lòbuls distints per Lowsley en 1912. No obstant, aquesta divisió provenia d'anàlisis de pròstates de fetus de tan sols 3 mesos. Aquestes divisions no eren observables en pròstates d'adults, i van generar una important polèmica i confusió en la comunitat científica. Setanta anys més tard, McNeal descriu la pròstata humana amb la divisió d'aquesta en tres àrees principals, les quals si són diferenciables en adults. Aquestes àrees són la zona perifèrica, que rodeja la uretra distal, representa aproximadament el 70% de la massa de la pròstata, i és on s'originen un 70-80% dels càncers de pròstata; la zona central, que rodeja els conductes ejaculadors, és aproximadament el 20-25% de la massa de la pròstata, i és on s'originen el 2.5% dels càncers, els quals solen ser molt agressius; i finalment la zona de transició, la qual rodeja la uretra proximal, sent el 5% de la massa, i on s'originen el 10-20% dels càncers. Addicionalment, alguns autors reconeixen també la zona fibromuscular anterior com a part de la pròstata, encara que està formada sols per teixit muscular i fibrós. Podem observar aquestes parts a la Figura 1 (Aaron, Franco, & Hayward, 2016; Reeves, Everaerts, Murphy, & Costello, 2016; Young, O'Dowd, & Woodford, 2014).




Figura 1. Detall gràfic de la pròstata i les seues zones. (Imatge realitzada per Mikael Häggström (Häggström, 2014))

La funció principal de la pròstata, és generar el fluid en el qual romanen els espermatozoides. Aquesta glàndula conté cèl·lules secretores de substàncies tals com zinc, antígens específics de la pròstata (PSA), espermina, magnesi i altres enzims i substàncies. Amb la secreció d'aquestes substàncies, que ajuden a conformar el líquid seminal (aproximadament un 30% del semen), la pròstata té una funció destacada en la reproducció. Gràcies a les diferents substàncies,

els espermatozoides aconseguen la mobilitat necessària per arribar a l'òvul i produir la fecundació. A més, part de la pròstata es contrau de forma paral·lela al conducte deferent durant l'ejaculació (CuidatePlus, 2020; Guyton & Hall, 2011).

2.1.2. Patologies de la pròstata

Existeixen tres patologies principals associades a la pròstata. Aquestes són la hiperplàsia benigna de pròstata (HBP), la prostatitis, i el càncer de pròstata.

La HBP es defineix com una proliferació del múscul llis i cèl·lules epitelials en la zona de transició de la pròstata, que causa un engrossiment en la glàndula, i freqüentment relacionat amb símptomes del tracte urinari baix. Es tracta d'una malaltia comuna en els homes majors d'edat, on aproximadament el 50% dels homes majors de 60 anys han sigut diagnosticats amb aquesta patologia, i el 90% dels homes majors de 85 anys presenten símptomes. No es tracta d'una malaltia mortal, però els símptomes sí que poden reduir la qualitat de vida. Per a tractar aquesta malaltia, existeixen diverses opcions com són la medicació, teràpies mínimament invasives, operació quirúrgica o l'anomenada espera atenta, fins que siga necessari un major tractament (Priest, Garzotto, & Kaufman, 2012).

Respecte a la prostatitis, es tracta de la malaltia urològica més comuna en homes menors de 50 anys. La prostatitis és la inflamació de la pròstata, comunament causada per la infecció del bacteri *Escherichia coli*, encara que la malaltia està associada a diferents espècies originades a la flora intestinal, havent inclòs casos de prostatitis no relacionats amb bacteris. Es pot classificar en quatre categories diferents en funció del tipus d'infecció i/o inflamació. Alguns dels símptomes de la prostatitis són aquells relacionats amb les infeccions, com la febre o el malestar general. A més, altres símptomes poden ser aquells relacionats amb l'obstrucció uretral o la síndrome miccional irritativa. El tractament a realitzar és la utilització d'antibiòtics intravenosos, ja que es tracta d'una infecció greu (Touma & Nickel, 2011).

Respecte al càncer de pròstata, es desenvoluparà a continuació amb major detall.

2.1.3. Càncer

El càncer és una malaltia crònica de causa genètica, que consisteix fonamentalment en la proliferació clonal i descontrolada d'una població cel·lular transformada, sobre la que es va afegint de forma successiva una sèrie d'alteracions genòmiques. Aquestes alteracions determinaran les característiques de malignitat d'aquest clon, i són la base de la seua capacitat per a envair teixits adjacents i disseminar-se a distància, dos fenòmens coneguts com a invasió i metàstasi respectivament.

A causa de mutacions o causes externes, una cèl·lula pot començar a reproduir-se de forma anormal, provocant el que es coneix com a massa tumoral o tumor. Quan aquesta massa anormal de teixit, el creixement del qual excedeix i no està coordinat amb els teixits normals, continua creixent inclòs quan l'estímul inicial ha cessat, passa a nomenar-se una neoplàsia. Finalment, quan el creixement descontrolat d'aquest teixit comença a envair i afectar altres teixits, afectant inclòs a la funció d'òrgans, es tracta d'una neoplàsia maligna o càncer.

Segons Hanahan i Weinberg en (Hanahan & Weinberg, 2000), existeixen sis característiques que presenten els teixits cancerosos:

- El creixement i la divisió de les cèl·lules no tenen els senyals adequats
- Creixement continu i divisió fins i tot amb senyals contraris
- Evitar la mort cel·lular programada
- Nombre il·limitat de divisions cel·lulars
- Promoure la construcció de vasos sanguinis
- Invasió de teixits i formació de metàstasi

Pel que fa a les causes del càncer, existeixen una gran quantitat de factors que intervenen, on aproximadament el 90-95% dels casos són per culpa de causes relacionades amb l'ambient i l'estil de vida. Segons Anand *et al.*, el 30% de les morts per càncer són degudes al tabac, el 35% estan relacionades amb la dieta, i sobre el 20% són degudes a una infecció, sent la resta degudes a altres factors tals com la radiació, l'estrés i l'activitat física, entre altres (Anand et al., 2008).

2.1.4. Càncer de pròstata

El càncer de pròstata es tracta d'un dels principals problemes mèdics en la població masculina, la incidència del qual està relacionada amb l'edat dels pacients.

El 95% dels càncers de pròstata són adenocarcinomes, un tipus de càncer que s'origina en cèl·lules glandulars. El 70% dels casos solen ocórrer en la zona perifèrica, sent el 20% a la zona de transició, i el 10% restant a la zona central. El precursor d'aquest càncer és la neoplàsia prostàtica intraepitelial (Martínez-Amores Martínez, Durán Poveda, Sánchez Encinas, & Molina Villaverde, 2013; Swallow, Chowdhury, & Kirby, 2012).

Aquest càncer normalment roman asimptomàtic fins a etapes avançades. Els símptomes que pot presentar en aquestes etapes són similars als causats per la HBP, relacionats principalment amb el tracte urinari, encara que pot incloure dolor i sang amb l'orina (Miller, Hafez, Stewart, Montie, & Wei, 2003).

Pel que fa al diagnòstic, a causa de l'absència de símptomes, i la gravetat d'aquest càncer, és necessari recórrer a tècniques de prevenció i garbellat, fent anàlisis a aquelles persones susceptibles a tindre aquesta malaltia. Les proves diagnòstiques utilitzades són la mesura anormal de PSA, el tacte rectal o l'ecografia transrectal. No obstant, aquestes proves tan sols proporcionen resultats orientatius, sent necessària una biòpsia de pròstata per a confirmar l'existència o no del càncer. La detecció del càncer es tracta per tant d'un procés invasiu per al pacient i incòmode, al qual s'ha de sotmetre repetides voltes durant gran part de la seua vida, de forma preventiva, si es tracta d'un pacient de risc.

Respecte al tractament, difereix en funció de l'estadi en el qual s'encontre la malaltia, poden ser des de estadi I (més lleu) fins a estadi IV (més greu, involucra metàstasi). En els primers estadis, a causa de la reduïda velocitat de creixement, i als efectes secundaris de la resta de tractaments, molts pacients decideixen mantindre una vigilància activa, on no es realitza cap tractament, però van controlant el creixement del tumor, preparats per a quan siga necessària una intervenció. En pacients d'avançada edat, o esperança de vida reduïda, s'utilitza una espera vigilant, on no es realitza un seguiment de la malaltia, sinó tan sols es tracten alguns dels símptomes.

Quan el càncer avança, i comença a ser perillós per al pacient, el tractament a seguir passa per la prostatectomia radical, que consisteix en l'extirpació quirúrgica de la pròstata, o la radioteràpia radical, on es radia completament la pròstata. Aquests tractaments tenen com a conseqüència efectes secundaris tals com la incontinència urinària i la impotència sexual, o la rectitis. Existeixen altres tècniques utilitzades en els casos més greus, com la teràpia hormonal o la castració, que ajuden a controlar la malaltia (Martínez-Amores Martínez et al., 2013; Swallow et al., 2012).

2.1.5. Classificació del càncer de pròstata

Generalment, per a la classificació del càncer de pròstata s'utilitza la puntuació de Gleason, s'obté de l'observació de l'aparença microscòpica de l'arquitectura glandular de la pròstata, observada en la biòpsia. Consisteix a classificar els dos patrons d'imatge més comuns a la biòpsia, classificant la diferenciació de les cèl·lules observades amb una puntuació entre 1 i 5, sent 5 el cas més greu. Es fa la suma de la classificació dels dos patrons, i la mostra queda amb una puntuació total entre 2 i 10, sent aquesta la puntuació de Gleason (Lavery, Kirby, & Chowdhury, 2016).

Un altre sistema utilitzat per a la classificació és l'anomenat PI-RADS (sigles en anglés de Sistema de Dades i Informe en Imatge Prostàtica). Es tracta de la segona versió, publicada a un document amb el mateix nom, per un comitè format pel Col·legi Americà de Radiologia (ACR per les sigles en anglés), la Societat Europea d'Urologia Radiològica (ESUR per les sigles en anglés) i la fundació AdMeTech. En aquest document s'intenta fixar un llenguatge comú per a la pràctica clínica relacionada amb la classificació del càncer de pròstata.

PI-RADS v2 es basa en una escala de probabilitats de 5 punts, amb l'objectiu de detectar càncers clínicament significatius (CCS). En aquesta escala, un PI-RADS 1 ens indica una molt baixa probabilitat de CCS, mentre que un PI-RADS 5 ens indica una molt alta probabilitat de CCS. Per a l'assignació d'aquesta classificació, es fa ús d'imatges de ressonància magnètica en seqüència T2 o DWI, així com en imatge de ressonància magnètica amb contrast dinàmic. A la Taula 1 podem trobar mes detalls de la classificació (American College of Radiology, 2020; Torregrosa Andrés, Otero García, & Sineiro Galiñanes, 2017; Weinreb et al., 2016).

Puntuació PI-RADS v2	Zona perifèrica	Zona de transició
1	Hiperintensitat homogènia i uniforme	Senyal homogeni (normal)
2	Hipointensitat lineal o cuneïforme o hipointensitat lleugera de vores imprecises	Nòduls encapsulats heterogenis o hipointensos, ben delimitats
3	Senyal heterogeni o focus de baix senyal moderat i mal delimitat	Senyal heterogeni de vores mal definides
4	Tumoració moderadament hipointensa, homogènia, circumscrita, limitada a la pròstata, amb diàmetre < 1.5 cm	Focus de baix senyal moderat, mal delimitat, de diàmetre < 1.5 cm
5	Igual que 4, però diàmetre > 1.5 cm o extensió extracapsular	Igual que 4, però diàmetre > 1.5 cm o extensió extracapsular

Taula 1. Classificació PI-RADS en funció de la senyal obtinguda.

2.2. Imatge de Ressonància Magnètica

2.2.1. *Ressonància Magnètica*

La Ressonància Magnètica és un fenomen físic relacionat amb partícules com a protons, electrons, i nuclis atòmics amb un nombre imparell de protons i/o electrons. Aquestes partícules tenen la propietat d'absorbir selectivament energia de radiofreqüència quan són sotmeses a un camp magnètic.

Les imatges de Ressonància Magnètica (IRM) aprofiten la ressonància dels nuclis d'hidrogen. Concretament utilitzen l'alliberament de l'energia absorbida durant la ressonància, a partir d'ones de radiofreqüència, que són recollides per una antena receptora. Aquest fenomen d'alliberament es diu relaxació, i el senyal emés depèn tant de factors propis del teixit, com de factors externs, com per exemple la intensitat del camp magnètic. Això permet obtenir no sols imatges morfològiques, sinó amb elles també informació fisiològica, com pot ser la difusió, o informació bioquímica (Planas, 2003).

L'ús d'aquest fenomen físic fa de la IRM una tècnica molt utilitzada en l'àmbit clínic, ja que suposa una tècnica diagnòstica no invasiva, mitjançant radiació no ionitzant, i amb resultats de molt bona qualitat, amb una alta resolució.

Per a l'obtenció d'aquestes imatges, és necessari comptar amb tres elements principals:

- **Imant:** Pot ser de tipus permanent, resistiu o superconductiu. Els dos últims fan ús del corrent elèctric, sent el superconductiu el més usat, pel fet que permet aconseguir majors camps magnètics fàcilment quan se sotmet a baixes temperatures, on perd la seua resistència elèctrica. El disseny d'imant més utilitzat és en forma de solenoide, ja que aconseguix un camp magnètic molt homogeni en el seu interior. Comercialment s'utilitzen imants de potència d'1.5 o 3 T, encara que existeixen fins i tot de 7 T.
- **Bobines de gradients de camp magnètic:** Es tracta d'un parell de bobines recorregudes per corrents continus en sentit contrari, amb la intenció de crear, al llarg de l'eix, una variació uniforme del camp magnètic, és a dir, un gradient magnètic lineal. S'utilitzen 3 parells per a cobrir les tres direccions ortogonals espacials (x, y, z), de manera que gràcies a aquest gradient magnètic es té informació espacial dels vòxels calculats.
- **Bobines de radiofreqüència:** És l'encarregada d'emetre i rebre les ones de radiofreqüència, provocant així els estats d'excitació, i recollint la informació quan es produeix la relaxació.

És a partir d'aquests tres elements que s'obté la IRM, els quals actuen de la següent manera: els nuclis d'hidrogen presenten un moviment d'espín magnètic, de manera que giren sobre si mateixos. Això, al costat de la presència de càrregues lliures, genera un vector moment magnètic que, com el vector espín, s'alinea amb la direcció del camp magnètic. Aquesta orientació és alterada quan li apliquem un pols de radiofreqüència, passant d'un estat de menor energia ("UP") a un de major energia ("DOWN"). Quan finalitza el pols de radiofreqüència, els nuclis tornen a l'estat UP, alliberant l'energia absorbida en forma d'ona de radiofreqüència. Aquesta ona és detectada per l'antena, i enviada a l'ordinador per al seu processament.

Ara bé, la quantitat d'energia alliberada, així com el temps que tarden a tornar a l'estat inicial els nuclis, depenen del camp magnètic al qual estan sotmesos. Aquest camp magnètic està conformat pel camp creat per l'imant, el camp magnètic dels gradients, que codifiquen la informació espacial, i el camp magnètic bioquímic, d'ordre molt de menor als anteriors, però que ens permet conèixer l'estructura bioquímica al voltant dels nuclis d'hidrogen estudiats (Planas, 2003).

Estudiant el senyal de relaxació, podem obtindre informació sobre la densitat (D) dels nuclis d'H d'un vòxel, així com informació relativa al mitjà mitjançant els paràmetres T1, T2 i T2*. Concretament, dependrà dels temps de ressò (TE per les sigles en castellà) i dels temps de recuperació (TR) utilitzades en la seqüència *spin-echo*. En la Taula 2 podem observar la relació general entre els temps TE i TR, i els paràmetres que es potencien.

	TE curt	TE llarg
TR curt	Potenciem T1	Contrast mixte
TR llarg	Potenciem D	Potenciem T2

Taula 2. Relació dels paràmetres a potenciar i els temps de ressò i de recuperació.

Per a altres seqüències, la potenciació utilitza uns TR i TE diferents. T1 aporta informació sobre la facilitat d'alliberament d'energia del teixit, mentre que T2 informa sobre l'estructura bioquímica del mitjà. T2* té en compte a més factors que influeixen sobre l'asincronisme dels nuclis.

2.2.2. La difusió molecular – Les imatges de RM potenciades en difusió

A més, la IRM és també sensible a la difusió molecular. Aquesta difusió és un moviment de translació a l'atzar, conegut com a moviment Brownià. Això és pel fet que els moviments moleculars afecten tant a T1 com a T2. Cal tindre en compte que la difusió implica únicament moviments de translació i no inclou rotació o vibració, a més que aquesta no es veu afectada pel camp magnètic (Planas, 2003).

Per a entendre el moviment de difusió, podem imaginar una gran concentració de molècules en un punt donat, i aquestes al pas del temps anirien escampant-se, creant una il·lusió d'una esfera que creix de radi a mesura que passa el temps. La difusió pot ser isotròpica, on la difusió s'escampa uniformement, i anisotròpica, on presenta una direcció preferent a causa de l'anatomia del teixit.

Per a mesurar la difusió s'utilitza la tècnica STEJSKAL – TANNER, la qual proporciona una imatge potenciada en T2, però disminuïda en un factor que depèn de la difusió. La difusió que es detecta és en una direcció del gradient, per la qual cosa es mesura la difusió en aquesta direcció. La sensibilitat en la qual s'obté informació, és inversament proporcional al paràmetre b, que fa referència a l'amplitud i duració de l'aplicació d'aquest gradient. Per a obtindre les imatges potenciades en difusió (DWI per les seues sigles en anglés) isotròpica, on s'obté informació únicament de la magnitud de la difusió, s'han de combinar les DWI de les tres direccions espacials (x, y, z). La combinació pot ser amb la mitjana aritmètica, o amb la geomètrica, per exemple.

D'altra banda, es pot utilitzar el coeficient de difusió aparent (ADC), el qual conté informació quantitativa de la difusió en una direcció, obtenint-se combinant la imatge potenciada en difusió, i una de referència (no potenciada), amb el que s'aconsegueix que no hi haja informació emmascarada pel T2 (Manjón, 2020).

En la pròstata, a la regió perifèrica, la difusió és la seqüència predominant. Les lesions patològiques es mostren hiperintenses en DWI, i hipointenses en T2 i ADC.

2.3. Anàlisi de textures

La textura de les imatges es refereix a l'aparença, estructura i disposició de les parts d'un objecte dins de la imatge. Podem atribuir el concepte de textura en una imatge digital a la distribució de valors de nivell de gris entre els píxels d'una regió determinada d'interès en la imatge.

Així doncs, l'anàlisi de textures és, en principi, una tècnica per a avaluar la posició i intensitat de les característiques del senyal, és a dir, els píxels, i les seues intensitats de nivell de gris en les imatges digitals. Els trets de textura són, de fet, paràmetres matemàtics calculats a partir de la distribució dels píxels, que caracteritzen el tipus de textura i, per tant, l'estructura subjacent dels objectes mostrats en la imatge (Castellano, Bonilha, Li, & Cendes, 2004).

És ací on entra 'radiomics', o la 'radiòmica'. L'objectiu de la radiòmica és convertir les imatges en dades explotables, amb alta fidelitat i alt rendiment. Consisteix en l'extracció de característiques d'imatges quantitatives, amb la intenció de crear bases de dades a partir d'imatges radiològiques. S'espera que aquesta extracció de dades de característiques, i una anàlisi profunda d'aquests, revelen biomarcadors amb capacitat discriminatòria per a predir o pronosticar a partir de les imatges (Kumar et al., 2012).

El procés de l'anàlisi de textures, que fa ús de tècniques radiòmiques, consisteix en sis passos: adquisició de la IRM, definició de la regió d'interès (ROI), preprocessament de la ROI, extracció de les característiques de textura, selecció de característiques i classificació (Figura 2). Cap d'aquests passos és específic i els mètodes han de triar-se d'acord amb l'aplicació. La textura resultant pot veure's considerablement afectada depenent de la metodologia utilitzada al llarg del procés (Larroza, Bodí, & Moratal, 2016).

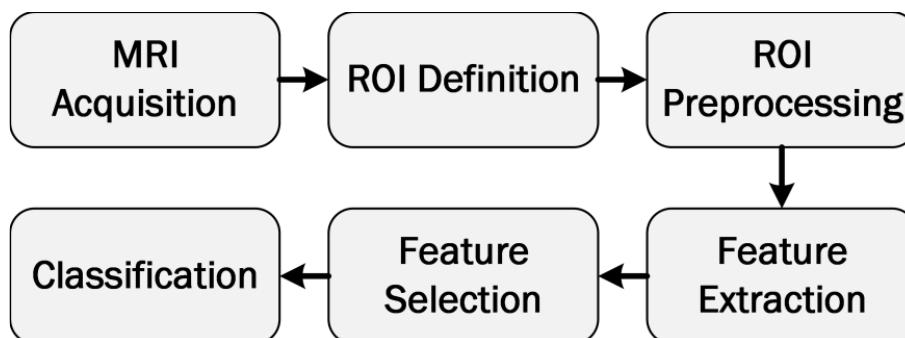


Figura 2. Procés de l'anàlisi de textures per a classificació de IRM. (Recuperat de (Larroza et al., 2016))

2.3.1. Adquisició en ressonància magnètica

Aquest primer pas correspon a l'adquisició de les IRM. L'anàlisi de textures és molt sensible a la metodologia utilitzada, així com als protocols utilitzats d'adquisició de les imatges. Això es deu a les variacions que poden existir en els camps magnètics de diferents màquines, hospitals o

protocols, que provoquen també variabilitat en la imatge. És per això que és important seleccionar aquests protocols de manera que assegurin la màxima precisió i reproductibilitat. Concretament, la utilització de diferents màquines, o fins i tot màquines d'un mateix proveïdor, pot proporcionar resultats diferents per a centres diferents.

A pesar que existeixen diferents seqüències de IRM, no és possible assegurar a priori que una seqüència donarà millors resultats que la resta (Larroza et al., 2016).

D'altra banda, a l'hora d'adquirir les imatges cal tindre en compte una sèrie de factors i consideracions per a assegurar la qualitat de les textures. Concretament, es recomana comptar amb una ràtio senyal soroll (SNR per les seues sigles en anglés) i una resolució espacial elevada. Tenint en compte la relació que tenen aquests paràmetres amb la intensitat de camp magnètic, podem intuir que un major camp magnètic proporcionarà millors resultats (Mayerhoefer, Szomolanyi, Jirak, Materka, & Trattng, 2009; Schad, 2004).

2.3.2. *Definició de la Regió d'interés*

La ROI, o el volum d'interés (VOI) quan parlem d'anàlisi en 3D, és el subconjunt de píxels o vòxels als quals se li realitzarà l'anàlisi de textures. És per això que és necessari que l'àrea de la regió siga el més fidel possible al contorn de la lesió.

Per a definir la ROI, és necessari dur a terme una segmentació, que pot ser manual o semiautomàtica. També existeixen algunes aproximacions que fan ús de figures geomètriques, així com de *'bounding box'* (definit com el rectangle més xicotet capaç d'albergar tot el teixit a estudi). No obstant això, els millors resultats són obtinguts mitjançant la delimitació completa del teixit, considerant-se la segmentació manual de la ROI la millor opció, ja que, encara que pot ser un procés tediós, s'assegura que no es perden detalls de la textura, o s'incloua teixit sa, que influísca en el resultat.

Quant a la grandària de la ROI, aquesta ha de ser prou gran per a poder extraure informació de les textures, i que siga estadísticament significativa. A més, es recomana que, en la mesura que siga possible, s'utilitzin ROIs de grandàries similars (Larroza et al., 2016).

2.3.3. *Preprocessat de la regió d'interés*

Com s'ha comentat en la secció 2.3.1, en l'anàlisi de textures influeixen els protocols d'adquisició d'imatges. És per això que es duen a terme tècniques de preprocessat amb la condició de minimitzar la influència d'aquests protocols. A més, en la suposició que l'estudi fora multicentre, aquest pas seria de vital importància per a minimitzar la possible variabilitat existent entre els centres.

L'objectiu principal d'aquest pas, és intentar aconseguir que totes les ROI estiguen en les mateixes condicions. Per a això, algunes de les tècniques utilitzades són les que segueixen, on algunes d'elles fins i tot milloren el poder discriminatori de les textures.

- Interpolació: Es tracta d'una opció a utilitzar sobretot quan les imatges tenen una resolució espacial baixa, on s'ha demostrat que millora els resultats en IRM. Per tant, es recomana utilitzar quan la resolució no és bona. Al seu torn, es requereix aquesta tècnica quan, treballant en volums, els vòxels no són isotròpics.

- Normalització: Pel fet que algunes de les característiques a extraure depenen de la mitjana i de la variància de la intensitat, la normalització de la ROI s'utilitza per a eliminar la influència negativa que aquests podrien ocasionar a causa dels protocols de l'adquisició. Concretament, per a IRM es recomana la normalització que proposen en Collewet *et al.* (Collewet, Strzelecki, & Mariette, 2004), on no es consideren els valors fora del rang $[\mu - 3\sigma, \mu + 3\sigma]$, sent μ la mitjana i σ la desviació estàndard. A més, en cas de ser necessari, previ a aquest pas, es pot realitzar una correcció d'inhomogeneïtat.
- Quantització de nivells de gris: La quantització fa referència a la reducció dels nivells de gris ($N_g = 2^{(n \text{ bits})}$) utilitzats per a representar la imatge. És a dir, si per a un píxel hi ha 4096 nivells de gris (12 bits) diferents, la quantització redueix aquest número. Aquesta quantització ajuda a millorar el SNR, encara que es perd una mica de poder discriminatori. Per això es recomana estudiar el nivell de gris òptim per a cada situació.

2.3.4. Extracció de característiques

Es tracta del pas principal, on una vegada preparada la ROI, s'extrauen les diferents característiques a partir d'aquesta. En la bibliografia podem trobar nombroses tècniques per a realitzar aquest pas, les quals es poden classificar en quatre grups (Castellano *et al.*, 2004; Materka, 2004):

- Mètodes estructurals: Es basen en primitives (microtextures) amb les quals intenten representar la macrotextura de la imatge. L'avantatge d'aquests mètodes és que permeten una bona descripció de la imatge. Una potent eina per a analitzar les textures estructurals és la morfologia matemàtica.
- Mètodes basats en models: Fan ús de models matemàtics, com poden ser models fractals o estocàstics, amb els quals intenten representar les textures, estimant els paràmetres a partir de la imatge. Es tracta d'un procés computacionalment costós.
- Mètodes de transformació: Fan ús de transformades, com la de Wavelet o la de Fourier, per a analitzar les textures de la imatge en un altre espai. Concretament, la més usada és la transformada de Wavelet.
- Mètodes estadístics: Es basen en les relacions entre els valors de gris en la imatge per a representar les textures, fent ús de propietats no deterministes. Existeix evidència que els estadístics de segon ordre poden ser les més importants (Materka, 2004).

Concretament, dins dels mètodes estadístics, podem diferenciar entre mètodes basats en l'histograma, que s'extrauen estadístics de primer ordre, i basats en matrius, obtenint estadístics d'ordre superior. Alguns exemples de matrius que s'utilitzen són:

- Matriu de co-ocurrències (Gray Level Co-occurrence Matrix o GLCM): Mètode de segon ordre que recull la quantitat de parells de píxels en una direcció donada, sent un dels més utilitzats per a extraure característiques (Materka, 2004). Es calcula definint una direcció (horitzontal, vertical o alguna de les dues diagonals) i una distància, i s'analitzen els parells de píxels separats per aquesta distància en aquesta direcció. Es compta el nombre de parells de píxels que tenen una distribució de nivells de gris, i s'emmagatzema aquest nombre en la matriu de co-ocurrències. Aquesta matriu té grandària $N \times N$, sent N el nombre de possibles valors de gris en la imatge, i per tant cada entrada es correspon a un parell de nivells de gris. Podem trobar un exemple a la Figura 3, on l'element (1, 2) de la matriu es correspon al nombre de parells de píxels que, donades la direcció horitzontal i la distància 1, tenen el primer un nivell de gris de 1 i el segon de 2. Cal destacar que per a aconseguir que siga rotacionalment invariant, és necessari calcular la mitjana d'aquesta matriu per a les quatre direccions (Haralick, Shanmugam, & Dinstein, 1973).




Figura 3. Càlcul d'una matriu de co-ocurrències (c) a partir d'una imatge de 4x4 píxels (a) amb tres nivells de gris (b). En aquest exemple, la matriu es calcula en direcció horitzontal per a separació d'un píxel.

- Run-length matrix (GLRLM): Mètode d'ordre estadístic superior a la GLCM. Es calcula buscant sèries de píxels d'un determinat nivell de gris en una orientació donada en la imatge. Es calcula la longitud d'aquestes sèries i queda recollit en la matriu. Aquesta matriu és de grandària $M \times N$, sent M el nombre de nivells de gris possibles, i N el nombre màxim de píxels en una sèrie. D'aquesta forma, podem trobar a la Figura 4 un exemple on l'element en (3, 2) de la matriu GLRLM es correspon al nombre de sèries de píxels que, per a una direcció donada, tenen un nivell de gris 3, i una grandària 2. De manera anàloga al mètode anterior, és necessari calcular la mitjana de la matriu per a les quatre direccions perquè siga rotacionalment invariant (Galloway, 1975).




Figura 4. Càlcul d'una matriu run-length (c) a partir d'una imatge de 4x4 píxels (a) amb tres nivells de gris (b). En aquest exemple se segueix una direcció horitzontal.

- Size zone matrix (GLSZM): Aquest mètode segueix el principi de la GLRLM. En aquest cas no es basa en sèries de píxels, sinó en àrees de píxels amb el mateix valor. En aquest cas no existeixen diverses direccions, per la qual cosa la matriu resultant depèn únicament de la imatge. Per tant, es tracta d'una matriu de grandària $M \times N$, sent M el nombre de possibles nivells de gris, i N la major grandària d'àrea oposat. Per tant, com podem observar a l'exemple de la Figura 5, l'element en (3, 5) de la matriu es correspon al nombre d'àrees de grandària 5, els píxels de la qual tenen un nivell de gris de 3 (Thibault et al., 2013).

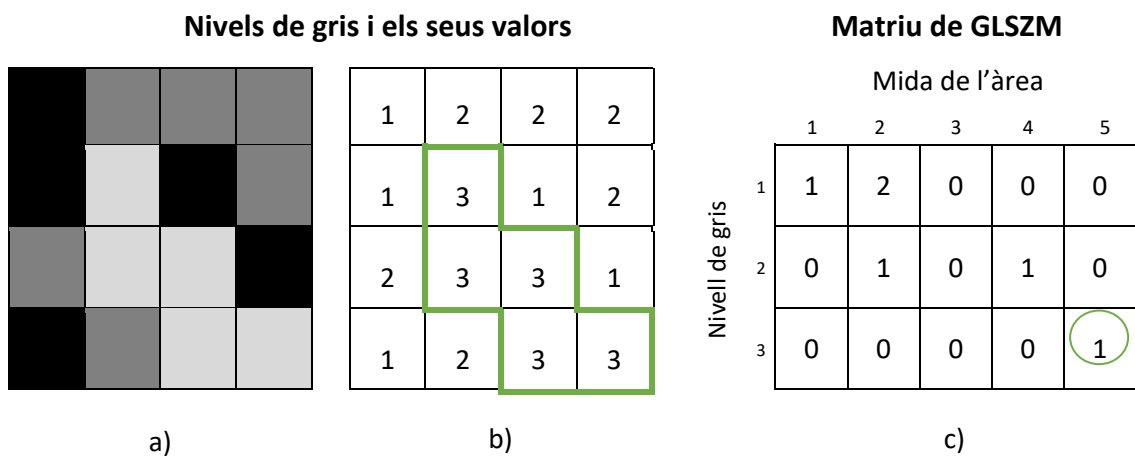


Figura 5. Càlcul d'una matriu GLSZM (c) a partir d'una imatge de 4x4 píxels (a) amb tres nivells de gris (b). En aquest exemple se segueix una direcció horitzontal.

- Neighbourhood gray-tone difference matrix (NGTDM): En aquest mètode, es construeix una matriu d'una sola columna on, donada una distància d , se suma la mitjana dels nivells de gris dels veïns de cadascun dels píxels que tinguen un nivell de gris donat. Amb la distància d definim quins píxels pertanyen al veïnat d'un píxel (k, l) , i es calcula la mitjana d'aquests veïns. Aquest valor se suma a la posició i de la matriu NGTDM, sent i el nivell de gris del píxel (k, l) . Podem observar un exemple de la elaboració d'aquesta matriu a la Figura 6 (Amadasun & King, 1989).




Figura 6. Exemple del càlcul de la matriu NGTDM a partir d'una imatge de 5x5 píxels amb 4 nivells de gris i una distància $d=1$. En la matriu dels nivells de gris, la zona destacada es correspon amb els píxels a partir dels quals es pot calcular, donat que els píxels més propers de la vora no es poden calcular. (Recuperat de (Ortiz Ramón, 2019))

2.3.5. Selecció de característiques

Els mètodes d'extracció de característiques permeten extraure un gran nombre d'aquestes. No obstant, no totes elles tenen el mateix nivell de poder discriminatori, i algunes d'elles poden inclòs ser redundants o contraproductes. A més a més, un nombre elevat dificulta la creació de models de classificació, cosa que empitjora quan el nombre de mostres disponibles és reduït. Concretament, el conjunt de dades ideal és aquell amb una proporció de mostres molt més elevada que de dimensionalitat, sent la dimensió del conjunt de dades el nombre de variables que hi ha.

És per això que cal reduir la dimensionalitat, fent ús de la selecció de característiques. Per a aquest pas, cal fer un estudi de quines variables són més importants a l'hora d'aconseguir una bona classificació, és a dir, veure quines tenen més poder discriminatori. Existeixen diversos mètodes per a realitzar aquest pas, que es poden agrupar en filtres, *wrappers* (embolcalls) i mètodes embeguts. En general, aquests mètodes creen un rànquing d'importància de les variables, ordenant-les de més a menys importants.

Els mètodes de filtre empren paràmetres estadístics amb els quals calculen el poder discriminatori de cada variable de forma individual. Després, fan una classificació d'acord al resultat d'aquest paràmetre, ordenant les variables de major a menor importància, és a dir, de major a menor poder discriminatori. No obstant, el principal problema d'aquests mètodes és que no tenen en compte la capacitat predictiva que poden tindre diverses variables com a conjunt. Alguns d'aquests mètodes són el mètode de Fisher, que calcula la puntuació de cada variable d'acord a la separació interclasse i la variància intraclasse (Gu, Li, & Han, 2012), o el mètode Informació Mútua (MI per les sigles en anglés), que calculen la puntuació a partir de la informació mútua entre la distribució dels valors d'una variable, i la pertinença d'aquesta a una classe en concret (Zaffalon & Hutter, 2002).

Un altre exemple de filtre és l'anomenat *Relief*, que tracta d'estimar la qualitat de les variables d'acord a com de bé els seus valors poden diferenciar entre mostres que són properes entre si. Per a fer això, tria una mostra aleatòria, i busca per a aquesta els dos veïns més propers, un de la mateixa classe, i altre d'una classe diferent. D'aquesta manera, dona major pes a les variables que millor separen entre classes, i que menys separen dins d'una classe. *Relief* és una ampliació d'aquest algoritme, més robust, i amb capacitat per a treballar amb més de dues classes (Robnik-Šikonja & Kononenko, 2003).

Els mètodes d'agrupament (*wrappers*) es diferencien dels filtres en el fet que aquests si tenen en compte la capacitat de predir d'una variable junt amb altres. Aquests mètodes solen donar millor resultats, però són més costosos computacionalment. Empren, en combinació amb un mètode de classificació, un algoritme de cerca a partir del qual seleccionen el subconjunt de variables que millor poder discriminatori ofereixen, on el mètode ideal seria provar tots els subconjunts de variables possibles. El problema pot sortir quan tenim un conjunt de dades d'alta dimensionalitat, ja que el nombre de combinacions augmenta en excés. Una solució és utilitzar algoritmes amb una estratègia de cerca.

Un dels mètodes de *wrapper* més utilitzats és l'algoritme SVM-RFE (Eliminació recursiva de característiques - Màquina de vectors de suport). Aquest algoritme calcula un rànquing de característiques mitjançant l'entrenament recursiu d'un SVM lineal. A cada iteració, elimina la característica que menys puntuació ha obtingut, i torna a repetir el pas amb el nou subconjunt de variables. Aquesta puntuació s'obté a partir del pes dels vectors emprats a l'algoritme SVM (Larrosa et al., 2016).

Finalment, els mètodes embeguts són similars als *wrappers* quant a l'ús d'un mètode de classificació, sols que els mètodes embeguts seleccionen el subconjunt de variables òptimes mentre construeixen el model de classificació. Generalment tenen els mateixos avantatges i desavantatges (Ortiz Ramón, 2019).

2.3.6. Classificació de textures

Donat que l'objectiu principal en l'anàlisi de textures, és la classificació d'aquestes textures, cal emprar mètodes de classificació que, a partir de les textures que hem extret, i posteriorment seleccionat, ens diguen de quin tipus de teixit es tracta.

Encara que aquest procés es pot realitzar amb mètodes estadístics simples, hui en dia existeixen nombroses tècniques i mètodes que han aconseguit molts bons resultats en nombroses tasques. Es tracta dels mètodes d'aprenentatge automàtic, els quals aconsegueixen classificar noves lesions o teixits, a partir de l'estructura interna del conjunt de dades donat, o a partir de les dades i la classificació d'un conjunt de lesions ja conegut.

En el primer cas, parlem de l'aprenentatge no supervisat, el qual s'empra quan tenim un conjunt de dades, però desconeguem la seua etiqueta associada, és a dir, la seua classificació. Aquests mètodes, els quals poden ser alguns com *k-means*, models de mixtures o DBSCAN, intenten classificar el conjunt de dades, a partir d'elles mateixes, mitjançant diverses tècniques, en funció del mètode emprat. En general aconsegueixen bons resultats, encara que normalment açò no es pot comprovar, ja que no se sap a priori l'etiqueta de les dades, i per tant tampoc hi ha forma de saber quin mètode és el millor.

El segon cas descrit, es tracta de l'aprenentatge supervisat. S'anomena supervisat, ja que si se sap a priori les etiquetes de les dades. Aquests mètodes són àmpliament utilitzats per a classificar una nova mostra de la qual es desconeix l'etiqueta. El procés d'aquests mètodes és entrenar un model estadístic a partir d'un conjunt de dades i la seua etiqueta. A l'entrenar aquest model, es crea una frontera de decisió amb la qual es decidirà l'etiqueta que li correspondria a una nova mostra.

En general, els mètodes d'aprenentatge supervisat, obtenen millors resultats que els de no supervisat, i tenen l'avantatge de què es poden avaluar, i comparar per veure quin dels distints

mètodes dona millors resultats per a un cas donat. És per això, i perquè es compta amb un conjunt de dades amb etiquetes com s'explicarà més avant, que en aquest treball s'han emprat aquests tipus de mètodes. A continuació es detallen alguns dels més rellevants:

2.3.6.1. *K-Nearest Neighbors (KNN)*

El classificador K veïns més propers, o KNN, utilitza una distància, generalment l'euclidiana, per a funcionar. En aquest model, les dades d'entrenament són representades en un espai on cada dimensió es correspon amb una variable del conjunt de dades amb les quals es compta. Posteriorment, es representa la nova mostra a classificar en el mateix espai, i es calcula la distància d'aquesta mostra amb la resta. S'agafen les k mostres més properes, és a dir, amb una distància menor, i la classe més repetida entre aquestes k mostres és la que se li assigna a la mostra a classificar.

Aquest model suposa que totes aquelles mostres amb uns valors similars entre si, pertanyen a la mateixa classe. Un dels principals inconvenients que té aquest mètode, és que no és capaç de diferenciar aquelles variables més importants d'aquelles que ho són menys, i per tant és molt sensible al soroll que poden crear variables innecessàries.

2.3.6.2. *Support Vector Machine (SVM)*

Les màquines de vectors de suport projecten les dades en un espai, i tracta d'encontrar un hiperplà que separe les classes, és a dir, definir una frontera de decisió a tot l'espai. Poden existir nombrosos hiperplans que aconseguen aquesta separació, però el SVM busca aquell òptim, on el marge entre les classes siga màxim. Una de les grans funcionalitats que té aquest mètode és la funció *kernel*, amb la qual transformen les dades a altre espai de major dimensionalitat, on la separabilitat de les classes a partir d'un hiperplà és més senzilla. Aquesta utilitat du associada un gran cost computacional en alguns casos, en funció del *kernel* utilitzat. Un dels més senzills és el *kernel* lineal.

Aquest mètode és utilitzat per a classificació binària. No obstant, existeixen tècniques per a adaptar aquest mètode a la classificació multiclasse. Una d'aquestes tècniques consisteix a construir $k(k-1)/2$ models, on k és el nombre de variables de les dades, i utilitzar la tècnica *one versus one* per a dissenyar una matriu de codificació. Es tracta del mètode *Error-Correcting Output Codes (ECOC)*, el qual redueix un problema de classificació multiclasse a un conjunt de classificacions binàries junt amb una funció de cost (Dietterich & Bakiri, 1995).

2.3.6.3. *Assemblats*

Els assemblats són tècniques utilitzades per a millorar l'eficàcia dels models, inclòs reduint en alguns casos l'overfitting. Es tracta d'una metodologia que aporta gran flexibilitat al classificador. La idea base és utilitzar diversos classificadors i ponderar la classificació que fan per a finalment obtindre la classificació global a partir de les classificacions individuals (Rokach, 2010).

Algunes de les tècniques més conegudes son *Bagging*, *Boosting* i *Random Subspace*.

2.3.6.4. *Random Forests (RF)*

Es tracta d'una de les tècniques de *bagging* més conegudes. Fa ús d'un conjunt d'arbres de classificació, un mètode de classificació jeràrquic. Concretament, entrena un conjunt d'arbres de decisió, cadascun amb un subconjunt de les variables del dataset, per a després obtindre la mitjana

d'ells. D'aquesta forma s'evita el gran sobre ajust que tendeixen a tindre aquests arbres, i es millora en gran mida la classificació (Opitz & Maclin, 1999; Rokach, 2010).

2.3.6.5. *Random Subspace amb KNN (KNNens)*

De forma similar a RF, aquest mètode utilitza un conjunt de models KNN, on cadascun fa ús d'un subconjunt de variables. Els diferents models són entrenats i finalment, per a classificar una nova mostra, es realitza la classificació en cada un dels diferents models entrenats i després es trau la mitjana de les puntuacions amb les quals classifiquen, per a fer la classificació final (MathWorks, 2020a).

2.3.6.6. *AdaBoost*

Adaptive Boosting o AdaBoost és un algoritme de classificació que, com el seu nom indica, es basa en la tècnica *Boosting*. Aquest algoritme entrena diferents models de forma seqüencial, ajustant la importància de cadascun d'ells en funció de l'error comés. Es tracta d'una tècnica similar a RF, que també utilitza arbres de decisió, però la principal diferència és que, per un costat utilitza totes les variables a tots els classificadors, i per altra, el procés d'entrenament no sol consisteix a entrenar els classificadors, sinó en actualitzar els pesos que se li donaran a cada classificació individual en funció de l'error comés, de forma que així unes classificacions tindran més importància que altres (Opitz & Maclin, 1999; Rokach, 2010).

2.3.6.7. *Naïve Bayes (NB)*

Es tracta d'un classificador probabilístic, el qual fa ús del teorema de Bayes. És un dels classificadors més senzills, el qual presenta un gran avantatge la qual és que pot tindre un gran rendiment amb poques mostres. Aquest classificador assumeix que totes les variables són mútuament independents, i encara que aquesta assumpció no es compleix, aconsegueix obtenir unes probabilitats a posteriori robustes. Aquestes probabilitats són del fet que la mostra siga d'una classe o d'altra.

2.3.6.8. *Discriminador lineal i quadràtic (DiscrLin i DiscrQua)*

Aquest model fa ús de les distribucions de mixtures gaussianes. Concretament, assumeix que totes les mostres d'una classe es poden modelar seguint aquestes distribucions. D'aquesta forma, per a predir una nova mostra utilitza una funció de cost que intenta minimitzar. Aquesta funció depèn dels valors de les variables de la nova mostra, així com de les distribucions obtingudes amb l'entrenament. La classe predita serà la d'aquella distribució a la qual la mostra més s'aproxime.

Les matrius de covariàncies de les distribucions al discriminador lineal no varien, sinó que tan sols varia la mitjana. En el discriminador quadràtic varien tant la mitjana com les matrius de covariància (MathWorks, 2020b).

2.3.7. *Tècniques de remostreig*

Els models supervisats, generalment són capaços de classificar correctament totes les mostres utilitzades per al seu entrenament. No obstant, no és això el que es busca, i no tindria sentit avaluar la classificació que ha realitzat un model d'una mostra que s'ha emprat per a entrenar-lo. Un cas que es pot donar quan s'ha entrenat un model, és l'anomenat *overfitting*, o sobre entrenament, el qual ocorre quan el model memoritza les dades, aconseguint ser molt precís a

l'hora de classificar les dades amb les quals s'ha entrenat, però no té prou flexibilitat a l'hora de classificar una nova mostra desconeguda per al model.

És necessari doncs, avaluar la capacitat de predicció d'un model amb dades no utilitzades per al seu entrenament. Per fer això, només cal separar un subconjunt de les dades de les quals es disposa, per a avaluar el rendiment del model. Aquesta tècnica s'anomena validació *hold-out*, perquè s'aparten unes poques mostres per a testejar (subconjunt *test*), sent tota la resta per a entrenar (subconjunt *train*). Amb aquesta tècnica, s'entrena el model només amb el subconjunt *train*, i s'avalua amb el subconjunt *test*.

Ara bé, en molts casos es pot donar que el nombre de mostres disponibles siga petit, i que al fer aquesta separació, el nombre de mostres amb el que s'entrena el model, és excessivament menut, inclòs podent ser no representatiu el subconjunt de dades respecte al total de la població. D'altra banda, amb aquesta partició, es pot incórrer en un error anomenat biaix. Aquest error ocorre quan la mostra que tenim no és completament representativa de la població, sinó només d'un conjunt d'aquesta, i es pot agreujar quan reduïm més el nombre de mostres per a entrenar. Aquest biaix pot produir que els resultats siguin falsos.

Si ajuntem el possible biaix, amb un conjunt de mostres petit, la separació dels dos subconjunts de les mostres pot paréixer inviable. Per sort, existeixen tècniques de remostreig capaces de resoldre aquests problemes.

Una de les tècniques més utilitzades quant es té un nombre de mostres reduït és l'anomenada *K-Fold Cross Validation*. Es tracta d'un tipus de validació creuada on es divideix la mostra en k subconjunts de forma aleatòria, de manera que tots tenen la mateixa mida i en cas de que siga estratificat, el mateix balanç de les classes. El procediment d'aquesta tècnica és repetir k voltes el procés de validació, obtenint d'aquesta forma k resultats distints, dels quals es calcula la mitjana per exemple. A cada volta que es repeteix, el subconjunt de test és un dels k , mentre que els altres $k-1$ conformen el subconjunt de *train*. D'aquesta forma, en cada iteració el model és entrenat i posteriorment avaluat amb uns subconjunts de dades distintes, de forma que s'evita en gran mesura el possible biaix, a l'utilitzar totes les dades tant per a entrenar com per a avaluar en algun moment. Podem trobar a la Figura 7 un exemple d'aquesta tècnica (Ortiz Ramón, 2019).




Figura 7. Exemple d'utilització de k -fold amb $k=3$. Es tracta d'un dataset de 12 mostres, amb una classificació binària (roig o blau), on cada subconjunt és de 4 mostres. (Recuperat de (Ortiz Ramón, 2019))

2.3.8. Mètriques d'avaluació

Finalment, cal avaluar els resultats obtinguts dels models utilitzats. Per a poder comparar entre ells objectivament, i poder triar quin és aparentment millor per al problema que ens ocupa, és necessari comptar amb mètriques d'avaluació objectives. D'aquesta forma podem conèixer també, de forma aproximada, la certesa amb la qual el nostre classificador actuarà enfront de noves mostres, i la fiabilitat que tindrà. Com hem comentat avanç, s'utilitza el subconjunt de test per a fer aquesta avaluació.

A continuació es detallen algunes de les mètriques comunament utilitzades:

- *Accuracy*: Es tracta del nombre de classificacions fetes correctament enfront del total de classificacions fetes. És a dir, la proporció d'encerts que s'ha aconseguit.

$$Accuracy = \frac{\text{classificacions acertades}}{\text{total de classificacions}}$$

- *Matriu de confusió*: Es tracta d'una matriu de mida $N \times N$, sent N el nombre de classes possibles de les dades. Aquesta matriu és útil per veure quines classes encerta més el model, i en quines es confon més, ja que enfronta el nombre de classes predites i el nombre de classes reals. Així doncs, per a un element de la matriu (i, j) , ens està indicant el nombre de voltes que ha classificat una mostra de classe i com a classe j . El resultat ideal seria que tots els valors estiguessen en la diagonal principal, sent la resta d'elements 0, ja que això significaria que ha encertat tots els casos.

Seguint aquesta nomenclatura, i donada una classe positiva p , tenim que els veritables positius (VP) són aquells que classifica correctament la classe positiva: $p = i = j$.

Els veritables negatius (VN) són aquells que classifica correctament les classes com a no positives: $p \neq i, p \neq j$.

Els falsos positius (FP) són aquells que classifica erròniament una classe com a positiva, quan no ho es: $p = j \neq i$.

Finalment, els falsos negatius (FN) són aquells que classifica erròniament una classe com a no positiva, quan si ho és: $p = i \neq j$.

En el cas de la Figura 8 tindríem, per a la classe 1 com a positiva: VP = 10, VN = 24, FP = 5 i FN = 5.

		Classes predites		
		1	2	3
Classes reals	1	10	3	2
	2	2	12	1
	3	3	2	9

Figura 8. Exemple de matriu de confusió amb tres classes.

Quan tenim una classificació binària, com podem observar a la Figura 9, es correspon a una matriu de 2x2, on en (1, 1) tenim els VP, en (1, 2) els FN, en (2, 1) els FP i en (2, 2) els VN, sent l'etiqueta positiva la 1.

		Classes predites	
		1	2
Classes reals	1	VP	FN
	2	FP	VN

Figura 9. Matriu de confusió general per a dues classes.

- Especificitat i sensibilitat: L'especificitat ens indica, donada una classe positiva, com de bé el model és capaç d'encertar que una mostra no pertany a la classe positiva. Per contra, la sensibilitat ens indica com de bé un model és capaç d'encertar que una mostra si pertany a la classe positiva. Aquests paràmetres també s'anomenen raó de verdaters negatius (VPN) i raó de verdaters positius (VPR) respectivament.

$$VPR = \frac{VP}{VP + FN} , \quad NPR = \frac{VN}{VN + FP}$$

- Precisió: Es tracta d'una mètrica similar a les dues anteriors, la qual es pot entendre com la confiança amb la qual el model classifica la classe positiva, és a dir, amb quina confiança es pot assegurar que, quan el model prediu una classe com a la positiva, aquesta realment ho siga. També es coneix com a valor predictiu positiu (VPP, o PPV per les sigles en anglés).

$$VPP = \frac{VP}{VP + FP}$$

- F1 Score: Es tracta d'una mètrica que compara les anteriors. Concretament, és la mitjana harmònica de la sensibilitat i la precisió.

- Corba ROC (*Receiver Operating Characteristic*): Aquesta corba ROC enfronta la VPR front a la raó de falsos positius (FPR = 1 - NPR), de forma que com més a prop passa de la part superior esquerra, ens indica que el model té una major capacitat per a no cometre errors de tipus 1 o 2, és a dir, de caure en un FP o FN respectivament.

D'aquesta corba s'obté també un *paràmetre anomenat AUC (Area Under Curve)*, que representa l'àrea sota la corba ROC. Es tracta d'un valor numèric que representa a la corba, ja que un valor d'1 es correspondria a la corba ideal que passa pel cantó superior esquerre. Aquest valor es pot interpretar com la probabilitat d'encertar correctament la classificació d'una mostra aleatòria. Es tracta d'una de les mètriques més utilitzades en estudis similars a aquest.

3. MATERIALS

3.1. Imatges

Es compta amb 97 estudis de ressonància magnètica multiparamètrica de pròstata, dels quals s'analitzaran les sèries T2, difusió i ADC, les quals estan corregistrades. Es tracta d'imatges

proporcionades per Eresa, part del grup ASCIRES, amb el consentiment previ dels pacients, informat per escrit. Aquests estudis han sigut informats per radiòlegs experts, els quals han classificat la gravetat de les lesions seguint la classificació de referència PI-RADS. A la Taula 3 podem comprovar les mostres de cada classe.

		Classificació PI-RADS			
		2	3	4	5
Nombre d'estudis		27	37	26	7

Taula 3. Classificació PI-RADS dels estudis.

Donada la variabilitat que pot haver-hi amb estudis de diferents protocols, les imatges proporcionades per a aquest estudi provenen del mateix equip, i són realitzades seguint les mateixes pautes. Són obtingudes amb una màquina SIGNA Architect de 3T, de la marca General Electric Healthcare, amb una seqüència Spin Echo amb temps de repetició/temps de ressò (TR/TE) de 8360/126.336 ms, potenciant T2. La matriu d'adquisició és de 512x512, sent la mida de píxel de 0.391x0.391 mm² i la grossor de pla de 3 mm. Cal destacar que si hi ha una variació amb les pautes respecte a les sèries de DWI, ja que dels 97 casos, 7 d'ells s'han obtingut amb un valor de b de 1500 s/mm², mentre que la resta amb un valor de b de 800 s/mm².

Els fitxers s'enc entren en format DICOM, estàndard utilitzat per a les imatges mèdiques, i el qual compta amb la imatge junt amb una capçalera amb informació.

En relació amb els pacients, es tracta d'homes amb una edat mitjana de 65.97 ± 7.07 anys.

3.2. Programes

Aquest treball s'ha dut a terme amb MATLAB (R2019b), un entorn de desenvolupament integrat (IDE) que compta amb llenguatge propi. Es tracta d'un llenguatge científic, orientat principalment a càlculs amb matrius, i incorpora nombroses prestacions per a camps tals com l'estadística, l'aprenentatge automàtic, anàlisi de dades, així com diverses funcions gràfiques.

S'han utilitzat a més, altres programes, així com diversos paquets creats per la comunitat d'usuaris:

- *Radiomics*: Es tracta d'un paquet de funcions, creat per *Vallières et al.*, enfocat al càlcul de textures, tant per a imatges com per a volums. A partir d'una sèrie d'imatges, i la seua segmentació, aquest paquet retorna una taula amb 43 textures diferents, per a cada quantització realitzada (Vallières, Freeman, Skamene, & El Naqa, 2015).
- *Feature Selection with SVM-RFE*: Es tracta d'un paquet que incorpora el codi per a realitzar l'algoritme SVM-RFE, compartit per Ke Yan (Yan, 2020).
- *Mango*: Programa de visualització d'imatges DICOM.
- *AW Server*, de GE Healthcare: Es tracta del programa utilitzat per a realitzar les segmentacions.

4. METODOLOGIA

En aquest apartat es detallen els passos seguits per a la realització d'aquest treball. Podem dividir el treball realitzat en la segmentació de les imatges, el preprocessat dels diferents fitxers, l'extracció de les característiques de les imatges, i els estudis fets a partir d'aquestes. S'han realitzat un total de quatre estudis, sent el primer en relació al valor de b de la sèrie DWI, i la resta en relació amb la classificació de lesions de pròstata.

4.1. Segmentació

El primer pas a realitzar, una volta es compta amb les imatges, és obtindre la segmentació de la lesió. Aquesta segmentació s'ha fet manualment, a partir de les lesions definides pels radiòlegs, amb la seqüència T2, utilitzant el programa AW Server, de GE Healthcare. La màscara obtinguda s'aplica també a les sèries DWI i ADC, les quals estan corregistrades amb la sèrie T2. Podem veure un exemple de segmentació a la Figura 10.




Figura 10. Segmentació d'una lesió de la pròstata. La segmentació es correspon al color roig.

4.2. Preprocessat

Com s'ha indicat avanç, en aquest treball s'ha utilitzat la ferramenta *Radiomics*, creada per Vallières. Aquesta ferramenta necessita que les imatges i la segmentació estiguen en un format concret. A més a més, necessita un conjunt de paràmetres que s'obtenen de la capçalera DICOM de les imatges.

Per tant, en primer lloc, és necessari preparar els arxius '.mat'. Són arxius de MATLAB, on s'emmagatzemen distintes variables. En aquest cas, la ferramenta necessita que cada un dels casos estiga en un arxiu d'aquest tipus, el qual ha de contindre el volum d'imatges, la segmentació, com a una màscara en forma de volum, amb les mateixes dimensions que el volum d'imatges. La ferramenta necessita que a l'arxiu estiga també la resolució de la imatge, els plans segmentats, el tipus de lesió, la identificació del pacient, i la data de l'estudi. Es prepara per tant un codi a MATLAB que, a partir de les distintes imatges DICOM i la seua segmentació, cree i guardi a una carpeta tots aquests fitxers '.mat'. A més, donat que es pretén utilitzar 3 sèries d'imatges distintes (T2, DWI i ADC), el codi guarda els fitxers creats en carpetes distintes en funció de la sèrie de la qual es tracte.

La ferramenta de Vallières inclou el preprocessat necessari per a l'anàlisi de textures, el qual realitza automàticament a les imatges. Una de les opcions que permet la ferramenta, és la d'assignar el conjunt de nombres de nivell de gris resultants tres aplicar la quantització, que en aquest treball s'han indicat els nombres 16, 32, 64, 128 i 256.

Altra opció que inclou és l'aplicació d'un interpolat. Donada la alta resolució de les imatges amb les quals es compta, s'ha decidit no utilitzar aquesta opció.

La ferramenta compta també amb una normalització de les imatges. Aquesta normalització correspon a la mencionada a la introducció, on per a imatges de RM s'exclouen els valors fora del rang $[\mu - 3\sigma, \mu + 3\sigma]$, tal com recomanen en *Collewet et al.* (Collewet et al., 2004).

Addicionalment, la ferramenta compta amb el paràmetre R, el qual està relacionat amb un filtratge de Wavelet, el qual en aquest treball s'ha deixat com a $R=1$, i per tant no s'aplica cap filtratge a la imatge.

4.3. Extracció de característiques

A la ferramenta només cal indicar-li la carpeta on s'entren els arxius '.mat' creats, un per cada pacient, i aquesta et retorna una taula amb totes les textures, junt amb la identificació del pacient i la seua lesió, entre altres. Les textures extretes es detallen a la Figura 11.

Donat que les 3 textures globals no depenen dels nivells de gris, resta un total de 40 textures que si ho fan. Per tant, l'eina ens tornarà un total de 203 textures en el nostre cas, 3 globals, i 5 voltes les 40 restants, una volta per a cada nombre de nivells de gris.

Finalment, la ferramenta guardarà un arxiu '.mat' i un arxiu '.csv', en els quals estarà la taula amb totes les textures, per a tots els casos que hi havia en les carpetes que s'han indicat al principi. Aquest pas es repeteix per a les tres sèries d'imatges, ADC, T2 i DWI.

El següent pas és ajuntar les dades de les diferents sèries en una única taula de dades, i separar aquesta per als diferents nivells de gris. El resultat per tant és passar de 3 taules (una per sèrie) a 5 (una per nivell de gris).

DISSENY D'UNA APROXIMACIÓ BASADA EN RADIÒMICA PER A UNA CLASSIFICACIÓ DE TUMORS DE PRÒSTATA MITJANÇANT ANÀLISI DE TEXTURES EN IMATGES DE RESSONÀNCIA MAGNÈTICA

Texture type	Reference(s)	Texture name
<i>Global</i>	—	Variance Skewness Kurtosis
GLCM ^a	(Haralick <i>et al</i> 1973)	Energy Contrast Correlation Homogeneity Variance Sum Average Entropy
GLRLM ^b	(Galloway 1975)	Short Run Emphasis (SRE) Long Run Emphasis (LRE) Gray-Level Non-uniformity (GLN) Run-Length Non-uniformity (RLN) Run Percentage (RP)
	(Chu <i>et al</i> 1990)	Low Gray-Level Run Emphasis (LGRE) High Gray-Level Run Emphasis (HGRE)
	(Dasarathy and Holder 1991)	Short Run Low Gray-Level Emphasis (SRLGE) Short Run High Gray-Level Emphasis (SRHGE) Long Run Low Gray-Level Emphasis (LRLGE) Long Run High Gray-Level Emphasis (LRHGE)
	(Thibault <i>et al</i> 2009)	Gray-Level Variance (GLV) Run-Length Variance (RLV)
	(Galloway 1975, Thibault <i>et al</i> 2009)	Small Zone Emphasis (SZE) Large Zone Emphasis (LZE) Gray-Level Non-uniformity (GLN) Zone-Size Non-uniformity (ZSN) Zone Percentage (ZP)
GLSZM ^c	(Chu <i>et al</i> 1990, Thibault <i>et al</i> 2009)	Low Gray-Level Zone Emphasis (LGZE) High Gray-Level Zone Emphasis (HGZE)
	(Dasarathy and Holder 1991, Thibault <i>et al</i> 2009)	Small Zone Low Gray-Level Emphasis (SZLGE) Small Zone High Gray-Level Emphasis (SZHGE) Large Zone Low Gray-Level Emphasis (LZLGE) Large Zone High Gray-Level Emphasis (LZHGE)
	(Thibault <i>et al</i> 2009)	Gray-Level Variance (GLV) Zone-Size Variance (ZSV)
	(Amadasun and King 1989)	Coarseness Contrast Busyness Complexity Strength

Figura 11. Conjunt de textures que extrau la ferramenta de Vallières. (Recuperat de (Vallières et al., 2015))

4.4. Estudi del valor de b a les seqüències DWI

Pel fet que en el conjunt de dades inicial, en la sèrie DWI, hi ha imatges obtingudes amb un valor de b diferent, cal fer un estudi per a veure si hi ha diferències estadísticament significatives entre aquelles mostres amb $b=800 \text{ s/mm}^2$, i aquelles amb $b=1500 \text{ s/mm}^2$.

Aquest estudi és necessari donat que, la presència d'alteracions en les dades produïdes per causes no relacionades amb les classes que es pretén classificar, pot produir errors i confondre als models, impeding una correcta classificació, i per tant, tindre un rendiment inferior. Cal assegurar-se per tant, que no existeixen diferències entre les característiques d'imatges amb nivells de b distints, les quals puguen interferir en l'entrenament dels models, i la classificació de les lesions.

Per a fer aquesta anàlisi, donada la desproporció de les mostres (90 vs 7), s'utilitza la prova estadística Mann-Whitney. Es tracta d'una prova estadística no paramètrica que permet comparar conjunts de dades de diferent mida. Aquesta prova s'utilitza per a comprovar si la mediana dels dos

conjunts de dades és igual, sent aquesta la hipòtesi nul·la, enfront de que no ho siga, que és la hipòtesi alternativa. Es tracta a més d'una de les proves amb millor rendiment quan es tracta de conjunts de dades amb mides diferents (Fagerland & Sandvik, 2009).

Aquesta prova s'aplica al conjunt de dades de la sèrie DWI, que conté les textures dels diferents nombres de nivell de gris, el que suma un total de 203 variables. Donat el gran nombre de variables, s'ha d'aplicar una correcció per tal d'evitar errors de tipus 1 quant a la significança de la prova. En aquest cas, s'utilitza la correcció de Holm-Bonferroni, una correcció del valor p obtingut de la prova estadística, basada en la correcció de Bonferroni, però modificada per a ser menys conservadora, adaptant-se als resultats d'una forma més precisa. Per a aquesta correcció, es fa ús del codi creat per Groppe (Groppe, 2020).

S'entrarà en major detall en els resultats i es comentaran en els apartats corresponents, però cal mencionar que s'obtenen 48 variables que presenten diferències en funció del valor b amb un nivell de significança del 0.05.

Donat aquest resultat, es decideix no utilitzar la sèrie DWI en un primer moment. Per tant, el procediment comentat prèviament d'ajuntar les taules de dades, passa a ser ajuntar les dues taules de dades restants (T2 i ADC), i separar-les en 5 (una per nivell de gris). Cada una de les 5 taules conté per tant 86 variables (dues voltes les 40+3 que s'obtenen amb l'eina per nivell de gris, una per sèrie).

4.5. Selecció, classificació i avaluació de les textures. Estudi A.

Una volta es tenen les taules de dades separades per nivell de gris, es procedeix al següent pas. Es tracta d'analitzar, per a cada taula, és a dir, per a cada nivell de gris, quin és el conjunt de variables que, junt amb un model, aconseguen fer una millor classificació.

L'estudi a realitzar és un estudi multiclasse, on s'agrupen els casos PI-RADS 4 i 5, per a tindre les classes 1 (PI-RADS 2, 27 pacients), 2 (PI-RADS 3, 37 pacients) i 3 (PI-RADS 4 i 5, 26+7 pacients).

Donada l'alta dimensionalitat que es té, i per evitar problemes de sobre ajust en els models, es varia de forma recursiva el nombre de variables amb les quals s'entrenen els diferents models. És a dir, existeix un bucle en el qual, començant amb una, a cada iteració, s'agafa una variable més que en la iteració anterior. L'ordre en què aquestes variables es van afegint no és aleatori, sinó que resulta d'aplicar les tècniques de selecció de característiques *ReliefF* i SVM-RFE, amb les que s'obté un rànquing d'importància. D'aquesta manera, per a cada tècnica de selecció de característiques, s'obtenen el mateix nombre de combinacions que variables hi ha, sent l'última combinació que es prova tot el conjunt de variables. Es tracta d'una forma d'obtindre el nombre òptim de variables per a cada classificador, a la vegada que s'intenta reduir la dimensionalitat.

Es realitza també una anàlisi de la variabilitat dels resultats, repetint el procés d'entrenament 10 voltes. A més, donat el reduït nombre de mostres del qual es disposa, s'utilitza la tècnica de remostreig *K-Fold Cross Validation*, amb 5 particions aleatòries.

Per tant, el procediment complet consisteix en, donat un nivell de gris, un model a entrenar, un nombre de variables, i una tècnica de selecció de característiques, repetir 10 voltes la tècnica de *K-Fold*. Posteriorment s'avalua el rendiment del model, i es calcula la mitjana i la desviació típica de les mètriques obtingudes a l'avaluar el model durant les 10 · 5 iteracions.

Aquest procés es repeteix per a cada nombre de variables, per a cada tècnica de selecció de variables, per a cada model, i per a cada nivell de gris.

Els models utilitzats són: KNN amb 3 veïns, SVM amb *kernel* lineal, discriminador lineal i quadràtic, *Random Forest*, un assemblat de KNN i AdaBoost.

Donat que es tracta d'un problema de classificació multiclasse, es realitza una breu recerca bibliogràfica, i es troba que existeixen adaptacions de les mètriques d'avaluació descrites a la introducció. En aquest treball es fa ús de la mitjana dels valors d'AUC per a cada una de les classes com a positiva. S'extrauen també la sensibilitat i especificitat per a cada una de les diferents classes, i l'*accuracy* (Domingos & Provost, 2003; Fawcett, 2006; Sokolova & Lapalme, 2009).

Dels resultats s'extrau també la matriu de confusió, a partir de la qual podem observar el comportament del model, així com quines classes confon més. Es tracta d'una forma eficaç de veure que podem esperar del model.

4.6. Selecció, classificació i avaluació de les textures. Estudi B.

Donada la perduda de informació que es té a l'eliminar una sèrie d'imatges completa, així com el reduït nombre de mostres amb un valor de b de 1500 s/mm², es decideix fer també un segon estudi per observar la importància de la sèrie de DWI. En aquest segon estudi, s'inclou la sèrie DWI, i per a evitar el problema dels valors de b diferents, s'exclouen de l'estudi aquelles mostres amb b igual a 1500 s/mm².

Quant al procediment de l'estudi, se segueixen les mateixes pautes que a l'estudi A, amb la diferència que en aquest cas el nombre de variables es major (un total de 129 per nivell de gris estudiat), donat que s'inclouen les 43 variables pertanyents a la sèrie DWI. D'altra banda, amb la reducció de mostres, en aquest segon estudi es compta amb 25 mostres classe 1 (PI-RADS 2), 35 mostres classe 2 (PI-RADS 3), i 30 mostres classe 3 (PI-RADS 4 i 5).

4.7. Selecció, classificació i avaluació de les textures. Estudi C.

En vista dels resultats dels estudis A i B, es realitza un tercer estudi en relació amb la informació que proporciona la sèrie DWI. En aquest cas no s'elimina cap mostra, com si es fa a l'Estudi B. La diferència respecte als anteriors casos és que ara no es tenen en compte aquelles variables que presenten diferències estadísticament significatives en funció del valor de b de la sèrie DWI.

Per tant, en aquest tercer estudi, s'inclouen les 97 mostres de les quals es disposa, però en funció del nivell de gris a estudiar, s'eliminaran certes variables. Les variables a eliminar en funció del nivell de gris són aquelles descrites a la Taula 4, del total de 129 variables de les quals es disposa per cada nivell de gris.

5. RESULTATS

5.1. Estudi del valor de b a les seqüències DWI

El resultat d'aquest estudi, és que, per a un nivell de significança del 0.05, existeixen 48 variables amb diferències estadísticament significatives en funció del valor de b (800 o 1500 s/mm²). De les 48 que hi ha, es poden agrupar en 16 variables, extretes amb diferents nivells de gris, com es mostra a la Taula 4.

<i>Nivells de gris</i>	<i>256</i>	<i>128</i>	<i>64</i>	<i>32</i>	<i>16</i>
<i>Complexity_NGTD</i>	•	•	•	•	•
<i>Contrast_NGTD</i>	•	•	•	•	•
<i>Energy_GLCM</i>	•	•	•	•	
<i>Entropy_GLCM</i>	•	•	•	•	
<i>Contrast_GLCM</i>	•	•	•		
<i>Dissimilarity_GLCM</i>	•	•	•		
<i>Homogeneity_GLCM</i>	•	•	•		
<i>SZE_GLSZM</i>	•	•	•		
<i>ZP_GLSZM</i>	•	•	•		
<i>ZSN_GLSZM</i>	•	•	•		
<i>LZE_GLSZM</i>	•	•			
<i>RLE_GLRLM</i>	•	•			
<i>RLN_GLRLM</i>	•	•			
<i>RP_GLRLM</i>	•	•			
<i>SRE_GLRLM</i>	•	•			
<i>GLV_GLRLM/ GLV_GLSZM</i>	•				

Taula 4. Variables amb diferències estadísticament significatives segons el valor de b. Nivells de gris afectats.

5.2. Classificació de lesions de pròstata. Estudi A

A continuació es detallen els resultats obtinguts per a cada nivell de gris a l'Estudi A. Es mostraran els resultats de l'AUC mig ($\mu \pm \sigma$), junt amb el nombre de variables òptim per a cada cas. Per a cada taula, s'indicarà amb color blau el millor resultat, i amb taronja si el resultat és el millor de l'estudi.

Es mostrarà també una gràfica dels perfils dels models, on es podrà observar l'evolució del rendiment dels models en funció del nombre de variables amb les quals treballen, així com la matriu de confusió i les variables més utilitzades per al millor model de cada nivell de gris.

A la llegenda de les gràfiques de perfils, els elements es troben ordenats en funció del millor resultat obtingut.

5.2.1. Nivell de gris 16

A la Taula 5 es detallen els resultats més destacats per a aquest estudi i aquest nivell de gris.

Models	SVM-RFE		ReliefF	
	AUC ($\mu \pm \sigma$)	Nº de variables	AUC ($\mu \pm \sigma$)	Nº de variables
AdaBoost	0.6882 \pm 0.0858	76	0.6790 \pm 0.0815	83
DiscrLin	0.6445 \pm 0.0917	9	0.6073 \pm 0.0670	1
DiscrQua	0.5933 \pm 0.0901	16	0.5956 \pm 0.0786	1
KNN	0.6687 \pm 0.0856	45	0.6627 \pm 0.0798	83
KNNens	0.6579 \pm 0.0744	75	0.6516 \pm 0.0780	76
NB	0.6455 \pm 0.0937	78	0.6437 \pm 0.1080	86
RF	0.6998 \pm 0.0861	83	0.6872 \pm 0.0871	54
SVM	0.6901 \pm 0.1063	15	0.6232 \pm 0.0921	15

Taula 5. Resultats Estudi A, Nivell de gris 16.

A la Figura 12 es mostren, per a aquest estudi i aquest nivell de gris, els perfils per model amb ReliefF com a mètode de selecció de variables.




Figura 12. Gràfica de perfils per model, amb la FS ReliefF i 16 nivells de gris. Estudi A.

A la Figura 13 es mostren, per a aquest estudi i aquest nivell de gris, els perfils per model amb SVM-RFE com a mètode de selecció de variables.




Figura 13. Gràfica de perfils per model, amb la FS SVM-RFE i 16 nivells de gris. Estudi A.

El millor resultat per a 16 nivells de gris s'obté amb *Random Forest* i les 83 millors característiques segons SVM-RFE, podent trobar la seua matriu de confusió a la Figura 14. Per a aquest model s'ha obtés un AUC de 0.6998 ± 0.0861 . Si ens fixem en la matriu de confusió, podem observar que els valors de sensibilitat son 0.4074, 0.5405 i 0.5758 per a cada classe com a positiva, sent la mitjana 0.5079 ± 0.0725 . D'altra banda, els d'especificitat son 0.8000, 0.7167 i 0.7500 per a cada classe com a positiva, sent la mitjana 0.7556 ± 0.0419 . L'*accuracy* per tant es de 0.5155.




Figura 14. Matriu de confusió del millor model per a nivell de gris 16. Estudi A.

5.2.2. Nivell de gris 32

A la Taula 6 es detallen els resultats més destacats per a aquest estudi i aquest nivell de gris.

Models	SVM-RFE		ReliefF	
	AUC ($\mu \pm \sigma$)	Nº de variables	AUC ($\mu \pm \sigma$)	Nº de variables
AdaBoost	0.6858 \pm 0.0829	72	0.6760 \pm 0.0731	85
DiscrLin	0.6675 \pm 0.0937	18	0.6427 \pm 0.0903	18
DiscrQua	0.5983 \pm 0.1140	34	0.5755 \pm 0.0948	46
KNN	0.6509 \pm 0.0895	84	0.6372 \pm 0.0782	70
KNNens	0.6465 \pm 0.0888	69	0.6354 \pm 0.0932	83
NB	0.6555 \pm 0.0879	82	0.6560 \pm 0.0848	63
RF	0.7039 \pm 0.0942	84	0.7034 \pm 0.0954	84
SVM	0.6905 \pm 0.0932	23	0.6457 \pm 0.0806	19

Taula 6. Resultats Estudi A, Nivell de gris 32.

A la Figura 15 es mostren, per a aquest estudi i aquest nivell de gris, els perfils per model amb ReliefF com a mètode de selecció de variables.

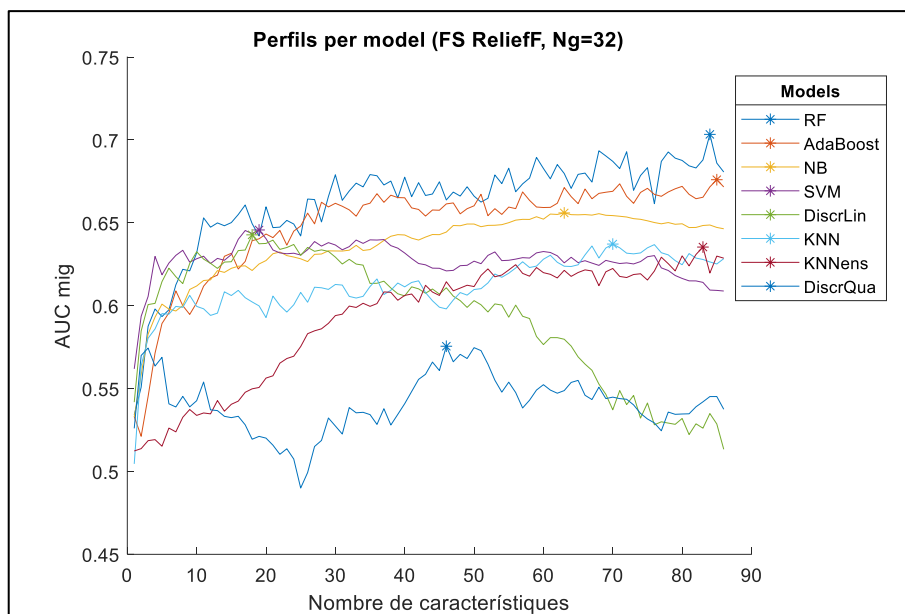


Figura 15. Gràfica de perfils per model, amb la FS ReliefF i 32 nivells de gris. Estudi A.

A la Figura 16 es mostren, per a aquest estudi i aquest nivell de gris, els perfils per model amb SVM-RFE com a mètode de selecció de variables.




Figura 16. Gràfica de perfils per model, amb la FS SVM-RFE i 32 nivells de gris. Estudi A.

El millor resultat per a 32 nivells de gris s'obté amb *Random Forest* i les 84 millors característiques segons SVM-RFE, podent trobar la seua matriu de confusió a la Figura 17. Per a aquest model s'ha obtingut un AUC de 0.7039 ± 0.0942 . Si ens fixem en la matriu de confusió, podem observar que els valors de sensibilitat són 0.4444, 0.5135 i 0.5758 per a cada classe com a positiva, sent la mitjana 0.5112 ± 0.0657 . D'altra banda, els d'especificitat són 0.8000, 0.7167 i 0.7500 per a cada classe com a positiva, sent la mitjana 0.7556 ± 0.0419 . L'*accuracy* per tant és de 0.5155.

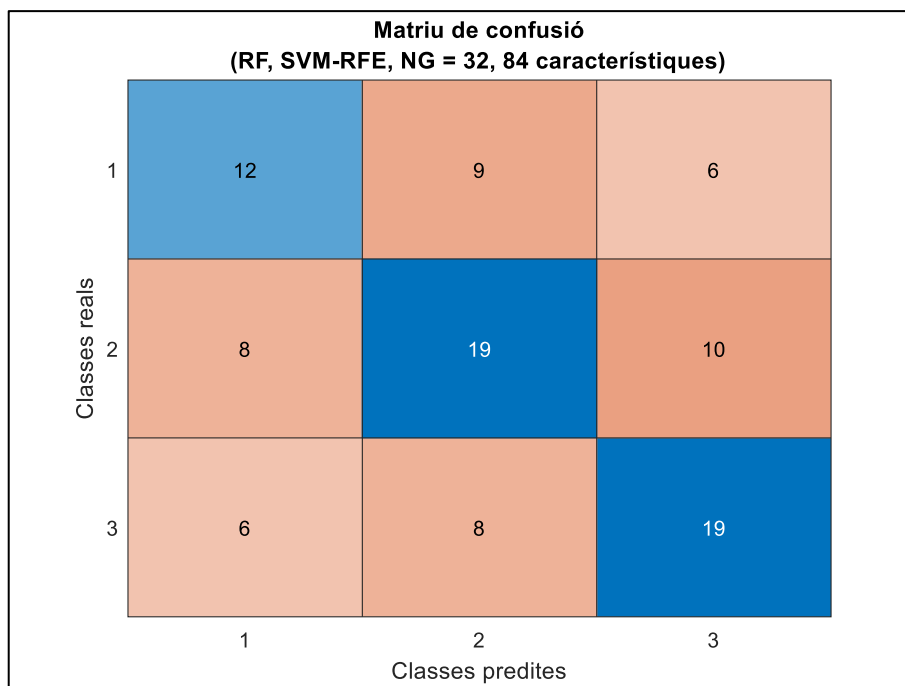


Figura 17. Matriu de confusió del millor model per a nivell de gris 32. Estudi A.

5.2.3. Nivell de gris 64

A la Taula 7 es detallen els resultats més destacats per a aquest estudi i aquest nivell de gris.

Models	SVM-RFE		ReliefF	
	AUC ($\mu \pm \sigma$)	Nº de variables	AUC ($\mu \pm \sigma$)	Nº de variables
AdaBoost	0.6826 \pm 0.0801	77	0.6792 \pm 0.0908	65
DiscrLin	0.6520 \pm 0.0869	4	0.6406 \pm 0.0993	14
DiscrQua	0.5895 \pm 0.0841	82	0.5896 \pm 0.0784	3
KNN	0.6645 \pm 0.0717	66	0.6649 \pm 0.0933	79
KNNens	0.5969 \pm 0.1024	85	0.5996 \pm 0.0987	86
NB	0.6440 \pm 0.0784	86	0.6520 \pm 0.0880	65
RF	0.6945 \pm 0.0807	84	0.6959 \pm 0.0876	60
SVM	0.6898 \pm 0.0958	19	0.6615 \pm 0.0768	14

Taula 7. Resultats Estudi A, Nivell de gris 64.

A la Figura 18 es mostren, per a aquest estudi i aquest nivell de gris, els perfils per model amb ReliefF com a mètode de selecció de variables.




Figura 18. Gràfica de perfils per model, amb la FS ReliefF i 64 nivells de gris. Estudi A.

A la Figura 19 es mostren, per a aquest estudi i aquest nivell de gris, els perfils per model amb SVM-RFE com a mètode de selecció de variables.




Figura 19. Gràfica de perfils per model, amb la FS SVM-RFE i 64 nivells de gris. Estudi A.

El millor resultat per a 64 nivells de gris s'obté amb *Random Forest* i les 60 millors característiques segons ReliefF, podent trobar la seua matriu de confusió a la Figura 20. Per a aquest model s'ha obtingut un AUC de 0.6959 ± 0.0876 . Si ens fixem en la matriu de confusió, podem observar que els valors de sensibilitat són 0.4444, 0.5405 i 0.5758 per a cada classe com a positiva, sent la mitjana 0.5202 ± 0.0680 . D'altra banda, els d'especificitat són 0.8000, 0.7333 i 0.7500 per a cada classe com a positiva, sent la mitjana 0.7611 ± 0.0347 . L'*accuracy* per tant es de 0.5258.




Figura 20. Matriu de confusió del millor model per a nivell de gris 64. Estudi A.

5.2.4. Nivell de gris 128

A la Taula 8 es detallen els resultats més destacats per a aquest estudi i aquest nivell de gris.

Models	SVM-RFE		ReliefF	
	AUC ($\mu \pm \sigma$)	Nº de variables	AUC ($\mu \pm \sigma$)	Nº de variables
AdaBoost	0.6937 \pm 0.0665	72	0.6792 \pm 0.0801	70
DiscrLin	0.6506 \pm 0.0839	13	0.6590 \pm 0.0975	19
DiscrQua	0.5909 \pm 0.1181	4	0.5890 \pm 0.0852	48
KNN	0.6383 \pm 0.0956	75	0.6527 \pm 0.0952	78
KNNens	0.5371 \pm 0.0957	71	0.5615 \pm 0.0849	30
NB	0.6536 \pm 0.0908	80	0.6463 \pm 0.0823	86
RF	0.6769 \pm 0.1017	77	0.6850 \pm 0.0919	71
SVM	0.7128 \pm 0.0876	25	0.6951 \pm 0.0762	25

Taula 8. Resultats Estudi A, Nivell de gris 128.

A la Figura 21 es mostren, per a aquest estudi i aquest nivell de gris, els perfils per model amb ReliefF com a mètode de selecció de variables.

DISSENY D'UNA APROXIMACIÓ BASADA EN RADIÒMICA PER A UNA CLASSIFICACIÓ DE TUMORS DE PRÒSTATA MITJANÇANT ANÀLISI DE TEXTURES EN IMATGES DE RESSONÀNCIA MAGNÈTICA




Figura 21. Gràfica de perfils per model, amb la FS ReliefF i 128 nivells de gris. Estudi A.

A la Figura 22 es mostren, per a aquest estudi i aquest nivell de gris, els perfils per model amb SVM-RFE com a mètode de selecció de variables.




Figura 22. Gràfica de perfils per model, amb la FS SVM-RFE i 128 nivells de gris. Estudi A.

El millor resultat per a 128 nivells de gris s'obté amb SVM i les 25 millors característiques segons SVM-RFE, podent trobar la seua matriu de confusió a la Figura 23. Per a aquest model s'ha obtingut un AUC de 0.7128 ± 0.0876 . Si ens fixem en la matriu de confusió, podem observar que els valors de sensibilitat són 0.5185, 0.5263 i 0.5625 per a cada classe com a positiva, sent la mitjana 0.5358 ± 0.0235 . D'altra banda, els d'especificitat són 0.8143, 0.7119 i 0.7692 per a cada classe com a positiva, sent la mitjana 0.7651 ± 0.0513 . L'*accuracy* per tant es de 0.5361.




Figura 23. Matriu de confusió del millor model per a nivell de gris 128. Estudi A.

5.2.5. Nivell de gris 256

A la Taula 9 es detallen els resultats més destacats per a aquest estudi i aquest nivell de gris.

Models	SVM-RFE		ReliefF	
	AUC ($\mu \pm \sigma$)	Nº de variables	AUC ($\mu \pm \sigma$)	Nº de variables
AdaBoost	0.6258 \pm 0.0820	79	0.6296 \pm 0.0846	86
DiscrLin	0.6314 \pm 0.1024	11	0.6649 \pm 0.1157	12
DiscrQua	0.5889 \pm 0.0959	34	0.5775 \pm 0.0915	3
KNN	0.6002 \pm 0.0877	52	0.6047 \pm 0.0856	31
KNNens	0.5391 \pm 0.0787	80	0.5526 \pm 0.0962	28
NB	0.6004 \pm 0.0944	85	0.6202 \pm 0.0888	11
RF	0.6471 \pm 0.0845	86	0.6289 \pm 0.0926	50
SVM	0.6647 \pm 0.0867	27	0.6845 \pm 0.0879	37

Taula 9. Resultats Estudi A, Nivell de gris 256.

A la Figura 24 es mostren, per a aquest estudi i aquest nivell de gris, els perfils per model amb ReliefF com a mètode de selecció de variables.




Figura 24. Gràfica de perfils per model, amb la FS ReliefF i 256 nivells de gris. Estudi A.

A la Figura 25 es mostren, per a aquest estudi i aquest nivell de gris, els perfils per model amb SVM-RFE com a mètode de selecció de variables.




Figura 25. Gràfica de perfils per model, amb la FS SVM-RFE i 256 nivells de gris. Estudi A.

El millor resultat per a 256 nivells de gris s'obté amb SVM i les 37 millors característiques segons ReliefF, podent trobar la seua matriu de confusió a la Figura 26. Per a aquest model s'ha obtingut un AUC de 0.6845 ± 0.0879 . Si ens fixem en la matriu de confusió, podem observar que els valors de sensibilitat són 0.4815, 0.5135 i 0.5152 per a cada classe com a positiva, sent la mitjana 0.5034 ± 0.0190 . D'altra banda, els d'especificitat són 0.8000, 0.6833 i 0.7656 per a cada classe com a positiva, sent la mitjana 0.7497 ± 0.0600 . L'*accuracy* per tant es de 0.5052.

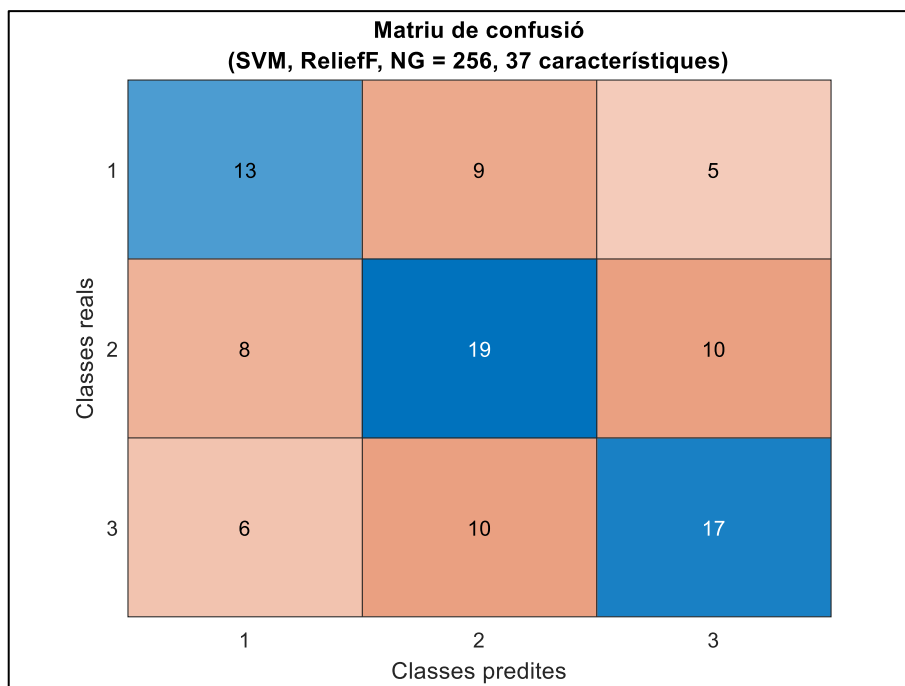


Figura 26. Matriu de confusió del millor model per a nivell de gris 256. Estudi A.

5.2.6. Resum

El millor resultat d'aquest Estudi A s'ha obtingut a l'utilitzar les 25 millors característiques amb 128 nivells de gris segons SVM-RFE, entrenant el model SVM. S'ha obtingut un AUC de 0.7128 ± 0.0876 , sent la sensibilitat mitja 0.5358 ± 0.0235 , la especificitat mitja 0.7651 ± 0.0513 i l'*accuracy* 0.5361.

La Figura 27 es correspon al rendiment d'aquest model als diferents nivells de gris estudiats.




Figura 27. Gràfica de perfils per nivell de gris per al model amb millor resultat. Estudi A.

Les 25 variables més utilitzades, junt amb la freqüència relativa (voltes gastada/total gastades) amb la que s'han gastat s'inclouen en la Taula 10.

Variable	Freqüència relativa	Variable	Freqüència relativa
LRE_GLRLM_ADC	0.0368	Strength_NGTDM_ADC	0.0264
LZE_GLSZM_ADC	0.0368	Variance_GLCM_ADC	0.0216
LZLGE_GLSZM_ADC	0.0368	SRE_GLRLM_ADC	0.0200
RP_GLRLM_ADC	0.0336	Dissimilarity_GLCM_ADC	0.0176
Homogeneity_GLCM_ADC	0.0328	GLN_GLRLM_ADC	0.0176
SZE_GLSZM_ADC	0.0328	RLN_GLRLM_ADC	0.0176
ZP_GLSZM_ADC	0.0328	GLN_GLSZM_ADC	0.0176
LRLGE_GLRLM_ADC	0.032	Contrast_NGTDM_ADC	0.0168
ZSN_GLSZM_ADC	0.0296	Complexity_NGTDM_ADC	0.0152
LZHGE_GLSZM_ADC	0.0296	Correlation_GLCM_T2	0.0144
Homogeneity_GLCM_T2	0.0264	Dissimilarity_GLCM_T2	0.0144
Correlation_GLCM_ADC	0.0264	AutoCorrelation_GLCM_T2	0.0144
Coarseness_NGTDM_ADC	0.0264		

Taula 10. Llista de les 25 variables més utilitzades per al millor resultat de l'Estudi A.

5.3. Classificació de lesions de pròstata. Estudi B

Es mostren a continuació els resultats de l'Estudi B, de forma anàloga a com s'han mostrat els de l'Estudi A.

5.3.1. *Nivell de gris 16*

A la Taula 11 es detallen els resultats més destacats per a aquest estudi i aquest nivell de gris.

DISSENY D'UNA APROXIMACIÓ BASADA EN RADIOÌMICA PER A UNA CLASSIFICACIÓ DE TUMORS DE PRÒSTATA MITJANÇANT ANÀLISI DE TEXTURES EN IMATGES DE RESSONÀNCIA MAGNÈTICA

Models	SVM-RFE		ReliefF	
	AUC ($\mu \pm \sigma$)	Nº de variables	AUC ($\mu \pm \sigma$)	Nº de variables
AdaBoost	0.7134 \pm 0.0835	129	0.7168 \pm 0.0965	108
DiscrLin	0.6178 \pm 0.0988	2	0.6543 \pm 0.0904	11
DiscrQua	0.6535 \pm 0.1047	48	0.6026 \pm 0.1080	32
KNN	0.6873 \pm 0.0921	105	0.6821 \pm 0.1060	124
KNNens	0.6942 \pm 0.0791	108	0.6888 \pm 0.0929	118
NB	0.7304 \pm 0.1131	121	0.7335 \pm 0.0883	128
RF	0.7215 \pm 0.0822	129	0.7143 \pm 0.0897	94
SVM	0.6554 \pm 0.1063	125	0.6675 \pm 0.1075	13

Taula 11. Resultats Estudi B, Nivell de gris 16.

A la Figura 28 es mostren, per a aquest estudi i aquest nivell de gris, els perfils per model amb ReliefF com a mètode de selecció de variables.




Figura 28. Gràfica de perfils per model, amb la FS ReliefF i 16 nivells de gris. Estudi B.

A la Figura 29 es mostren, per a aquest estudi i aquest nivell de gris, els perfils per model amb SVM-RFE com a mètode de selecció de variables.




Figura 29. Gràfica de perfils per model, amb la FS SVM-RFE i 16 nivells de gris. Estudi B.

El millor resultat per a 16 nivells de gris s'obté amb Naïve Bayes i les 128 millors característiques segons ReliefF, podent trobar la seua matriu de confusió a la Figura 30. Per a aquest model s'ha obtingut un AUC de 0.7335 ± 0.0883 . Si ens fixem en la matriu de confusió, podem observar que els valors de sensibilitat són 0.5000, 0.5833 i 0.6333 per a cada classe com a positiva, sent la mitjana 0.5722 ± 0.0673 . D'altra banda, els d'especificitat són 0.7879, 0.7222 i 0.8500 per a cada classe com a positiva, sent la mitjana 0.7867 ± 0.0639 . L'accuracy per tant és de 0.5778.




Figura 30. Matriu de confusió del millor model per a nivell de gris 16. Estudi B.

5.3.2. Nivell de gris 32

A la Taula 12 es detallen els resultats més destacats per a aquest estudi i aquest nivell de gris.

Models	SVM-RFE		Relieff	
	AUC ($\mu \pm \sigma$)	Nº de variables	AUC ($\mu \pm \sigma$)	Nº de variables
AdaBoost	0.7314 \pm 0.0778	118	0.7289 \pm 0.0854	93
DiscrLin	0.6766 \pm 0.1026	10	0.6663 \pm 0.0932	17
DiscrQua	0.6249 \pm 0.1189	70	0.6291 \pm 0.1175	57
KNN	0.7164 \pm 0.0933	100	0.7163 \pm 0.0750	109
KNNens	0.6964 \pm 0.0798	122	0.7058 \pm 0.0870	88
NB	0.7308 \pm 0.0953	127	0.7292 \pm 0.0597	106
RF	0.7347 \pm 0.0856	91	0.7394 \pm 0.0965	52
SVM	0.7025 \pm 0.0947	88	0.6899 \pm 0.0957	71

Taula 12. Resultats Estudi B, Nivell de gris 32.

A la Figura 31 es mostren, per a aquest estudi i aquest nivell de gris, els perfils per model amb Relieff com a mètode de selecció de variables.




Figura 31. Gràfica de perfils per model, amb la FS Relieff i 32 nivells de gris. Estudi B.

A la Figura 32 es mostren, per a aquest estudi i aquest nivell de gris, els perfils per model amb SVM-RFE com a mètode de selecció de variables.




Figura 32. Gràfica de perfils per model, amb la FS SVM-RFE i 32 nivells de gris. Estudi B.

El millor resultat per a 32 nivells de gris s'obté amb *Random Forest* i les 52 millors característiques segons ReliefF, podent trobar la seua matriu de confusió a la Figura 33. Per a aquest model s'ha obtingut un AUC de 0.7394 ± 0.0965 . Si ens fixem en la matriu de confusió, podem observar que els valors de sensibilitat són 0.4400, 0.5714 i 0.6667 per a cada classe com a positiva, sent la mitjana 0.5594 ± 0.1138 . D'altra banda, els d'especificitat són 0.8462, 0.7091 i 0.7833 per a cada classe com a positiva, sent la mitjana 0.7795 ± 0.0686 . L'*accuracy* per tant és de 0.5667.




Figura 33. Matriu de confusió del millor model per a nivell de gris 32. Estudi B.

5.3.3. Nivell de gris 64

A la Taula 13 es detallen els resultats més destacats per a aquest estudi i aquest nivell de gris.

Models	SVM-RFE		Relieff	
	AUC ($\mu \pm \sigma$)	Nº de variables	AUC ($\mu \pm \sigma$)	Nº de variables
AdaBoost	0.7066 \pm 0.0746	114	0.7050 \pm 0.0792	111
DiscrLin	0.6670 \pm 0.1030	9	0.6569 \pm 0.1042	31
DiscrQua	0.6525 \pm 0.0983	10	0.6519 \pm 0.0987	62
KNN	0.7163 \pm 0.0835	126	0.7008 \pm 0.0945	126
KNNens	0.5918 \pm 0.0894	129	0.6075 \pm 0.0957	125
NB	0.7442 \pm 0.0880	120	0.7373 \pm 0.0800	126
RF	0.7133 \pm 0.0976	85	0.7208 \pm 0.0734	115
SVM	0.6653 \pm 0.1018	13	0.6625 \pm 0.1020	41

Taula 13. Resultats Estudi B, Nivell de gris 64.

A la Figura 34 es mostren, per a aquest estudi i aquest nivell de gris, els perfils per model amb Relieff com a mètode de selecció de variables.




Figura 34. Gràfica de perfils per model, amb la FS ReliefF i 64 nivells de gris. Estudi B.

A la Figura 35 es mostren, per a aquest estudi i aquest nivell de gris, els perfils per model amb SVM-RFE com a mètode de selecció de variables.




Figura 35. Gràfica de perfils per model, amb la FS SVM-RFE i 64 nivells de gris. Estudi B.

El millor resultat per a 64 nivells de gris s'obté amb Naïve Bayes i les 120 millors característiques segons SVM-RFE, podent trobar la seua matriu de confusió a la Figura 36. Per a aquest model s'ha obtingut un AUC de 0.7442 ± 0.0880 . Si ens fixem en la matriu de confusió, podem observar que els valors de sensibilitat són 0.5600, 0.5556 i 0.5862 per a cada classe com a positiva, sent la mitjana 0.5673 ± 0.0165 . D'altra banda, els d'especificitat són 0.7846, 0.7222 i 0.8361 per a cada classe com a positiva, sent la mitjana 0.7810 ± 0.0570 . L'accuracy per tant és de 0.5667.




Figura 36. Matriu de confusió del millor model per a nivell de gris 64. Estudi B.

5.3.4. Nivell de gris 128

A la Taula 14 es detallen els resultats més destacats per a aquest estudi i aquest nivell de gris.

Models	SVM-RFE		ReliefF	
	AUC ($\mu \pm \sigma$)	Nº de variables	AUC ($\mu \pm \sigma$)	Nº de variables
AdaBoost	0.7194 \pm 0.0923	121	0.7093 \pm 0.1021	126
DiscrLin	0.6403 \pm 0.0810	25	0.6796 \pm 0.0825	13
DiscrQua	0.6279 \pm 0.0887	5	0.6551 \pm 0.0913	81
KNN	0.6849 \pm 0.0934	111	0.6933 \pm 0.0866	126
KNNens	0.5620 \pm 0.0888	120	0.5825 \pm 0.0788	90
NB	0.7167 \pm 0.0822	129	0.7229 \pm 0.0830	100
RF	0.7062 \pm 0.0945	101	0.7029 \pm 0.0627	92
SVM	0.7084 \pm 0.0811	127	0.7255 \pm 0.0925	33

Taula 14. Resultats Estudi B, Nivell de gris 128.

A la Figura 37 es mostren, per a aquest estudi i aquest nivell de gris, els perfils per model amb ReliefF com a mètode de selecció de variables.




Figura 37. Gràfica de perfils per model, amb la FS ReliefF i 128 nivells de gris. Estudi B.

A la Figura 38 es mostren, per a aquest estudi i aquest nivell de gris, els perfils per model amb SVM-RFE com a mètode de selecció de variables.




Figura 38. Gràfica de perfils per model, amb la FS SVM-RFE i 128 nivells de gris. Estudi B.

El millor resultat per a 128 nivells de gris s'obté amb SVM i les 33 millors característiques segons ReliefF, podent trobar la seua matriu de confusió a la Figura 39. Per a aquest model s'ha obtingut un AUC de 0.7255 ± 0.0925 . Si ens fixem en la matriu de confusió, podem observar que els valors de sensibilitat són 0.4800, 0.5714 i 0.6000 per a cada classe com a positiva, sent la mitjana 0.5505 ± 0.0627 . D'altra banda, els d'especificitat són 0.8154, 0.7273 i 0.7833 per a cada classe com a positiva, sent la mitjana 0.7753 ± 0.0446 . L'*accuracy* per tant és de 0.5556.




Figura 39. Matriu de confusió del millor model per a nivell de gris 128. Estudi B.

5.3.5. Nivell de gris 256

A la Taula 15 es detallen els resultats més destacats per a aquest estudi i aquest nivell de gris.

Models	SVM-RFE		Relieff	
	AUC ($\mu \pm \sigma$)	Nº de variables	AUC ($\mu \pm \sigma$)	Nº de variables
AdaBoost	0.7134 \pm 0.0855	76	0.7351 \pm 0.0868	77
DiscrLin	0.6556 \pm 0.0843	20	0.6800 \pm 0.0962	18
DiscrQua	0.6454 \pm 0.1113	11	0.6628 \pm 0.0997	64
KNN	0.6671 \pm 0.0953	70	0.6744 \pm 0.0947	61
KNNens	0.6069 \pm 0.0939	41	0.5800 \pm 0.0987	77
NB	0.6992 \pm 0.0980	101	0.7098 \pm 0.0947	87
RF	0.7025 \pm 0.0891	87	0.7021 \pm 0.0937	95
SVM	0.7029 \pm 0.1110	78	0.7312 \pm 0.0905	70

Taula 15. Resultats Estudi B, Nivell de gris 256.

A la Figura 40 es mostren, per a aquest estudi i aquest nivell de gris, els perfils per model amb Relieff com a mètode de selecció de variables.




Figura 40. Gràfica de perfils per model, amb la FS Relieff i 256 nivells de gris. Estudi B.

A la Figura 41 es mostren, per a aquest estudi i aquest nivell de gris, els perfils per model amb SVM-RFE com a mètode de selecció de variables.




Figura 41. Gràfica de perfils per model, amb la FS SVM-RFE i 256 nivells de gris. Estudi B.

El millor resultat per a 256 nivells de gris s'obté amb AdaBoost i les 77 millors característiques segons ReliefF , podent trobar la seua matriu de confusió a la Figura 42. Per a aquest model s'ha obtés un AUC de 0.7351 ± 0.0868 . Si ens fixem en la matriu de confusió, podem observar que els valors de sensibilitat son 0.3846, 0.5882 i 0.6333 per a cada classe com a positiva, sent la mitjana 0.5354 ± 0.1325 . D'altra banda, els d'especificitat son 0.8594, 0.6429 i 0.8000 per a cada classe com a positiva, sent la mitjana 0.7674 ± 0.1119 . L'accuracy per tant es de 0.5444.




Figura 42. Matriu de confusió del millor model per a nivell de gris 256. Estudi B.

5.3.6. Resum

El millor resultat d'aquest Estudi B s'ha obtingut a l'utilitzar les 120 millors característiques amb 64 nivells de gris segons SVM-RFE, entrenant el model Naïve Bayes. S'ha obtingut un AUC de 0.7442 ± 0.0880 , sent la sensibilitat mitja 0.5673 ± 0.0165 , la especificitat mitja 0.7810 ± 0.0570 i l'*accuracy* 0.5667.

La Figura 43 es correspon al rendiment d'aquest model als diferents nivells de gris estudiats.




Figura 43. Gràfica de perfils per nivell de gris per al model amb millor resultat. Estudi B.

A la Taula 16 una llista de les 80 variables més utilitzades, junt amb la seua freqüència relativa.

Variable	Freqüència relativa	Variable	Freqüència relativa
Energy_GLCM_T2	0.0083	RLN_GLRLM_DWI	0.0083
Contrast_GLCM_T2	0.0083	RP_GLRLM_DWI	0.0083
Entropy_GLCM_T2	0.0083	HGRE_GLRLM_DWI	0.0083
Homogeneity_GLCM_T2	0.0083	LRHGE_GLRLM_DWI	0.0083
Correlation_GLCM_T2	0.0083	RLV_GLRLM_DWI	0.0083
SumAverage_GLCM_T2	0.0083	SZE_GLSZM_DWI	0.0083
Variance_GLCM_T2	0.0083	LZE_GLSZM_DWI	0.0083
Dissimilarity_GLCM_T2	0.0083	ZSN_GLSZM_DWI	0.0083
AutoCorrelation_GLCM_T2	0.0083	ZP_GLSZM_DWI	0.0083

DISSENY D'UNA APROXIMACIÓ BASADA EN RADIOÈMICA PER A UNA CLASSIFICACIÓ DE TUMORS DE PRÒSTATA MITJANÇANT ANÀLISI DE TEXTURES EN IMATGES DE RESSONÀNCIA MAGNÈTICA

SRE_GLRLM_T2	0.0083	LGZE_GLSZM_DWI	0.0083
LRE_GLRLM_T2	0.0083	HGZE_GLSZM_DWI	0.0083
GLN_GLRLM_T2	0.0083	SZHGE_GLSZM_DWI	0.0083
RLN_GLRLM_T2	0.0083	GLV_GLSZM_DWI	0.0083
RP_GLRLM_T2	0.0083	ZSV_GLSZM_DWI	0.0083
SRLGE_GLRLM_T2	0.0083	Coarseness_NGTDM_DWI	0.0083
LRHGE_GLRLM_T2	0.0083	Contrast_NGTDM_DWI	0.0083
RLV_GLRLM_T2	0.0083	Strength_NGTDM_DWI	0.0083
SZE_GLSZM_T2	0.0083	Energy_GLCM_ADC	0.0083
LZE_GLSZM_T2	0.0083	Entropy_GLCM_ADC	0.0083
GLN_GLSZM_T2	0.0083	Homogeneity_GLCM_ADC	0.0083
ZSN_GLSZM_T2	0.0083	Correlation_GLCM_ADC	0.0083
ZP_GLSZM_T2	0.0083	Dissimilarity_GLCM_ADC	0.0083
LGZE_GLSZM_T2	0.0083	SRE_GLRLM_ADC	0.0083
SZHGE_GLSZM_T2	0.0083	LRE_GLRLM_ADC	0.0083
LZHGE_GLSZM_T2	0.0083	RLN_GLRLM_ADC	0.0083
GLV_GLSZM_T2	0.0083	RP_GLRLM_ADC	0.0083
ZSV_GLSZM_T2	0.0083	SRLGE_GLRLM_ADC	0.0083
Coarseness_NGTDM_T2	0.0083	SZE_GLSZM_ADC	0.0083
Contrast_NGTDM_T2	0.0083	LZE_GLSZM_ADC	0.0083
Complexity_NGTDM_T2	0.0083	GLN_GLSZM_ADC	0.0083
Strength_NGTDM_T2	0.0083	ZSN_GLSZM_ADC	0.0083
Energy_GLCM_DWI	0.0083	ZP_GLSZM_ADC	0.0083
Contrast_GLCM_DWI	0.0083	LZLGE_GLSZM_ADC	0.0083
Homogeneity_GLCM_DWI	0.0083	GLV_GLSZM_ADC	0.0083

Correlation_GLCM_DWI	0.0083	ZSV_GLSZM_ADC	0.0083
SumAverage_GLCM_DWI	0.0083	Coarseness_NGTDMA_ADC	0.0083
Dissimilarity_GLCM_DWI	0.0083	Complexity_NGTDMA_ADC	0.0083
AutoCorrelation_GLCM_DWI	0.0083	Strength_NGTDMA_ADC	0.0083
SRE_GLRLM_DWI	0.0083	Variance_GT_DWI	0.0082
LRE_GLRLM_DWI	0.0083	HGRE_GLRLM_T2	0.0082

Taula 16. Llista de les 80 variables més utilitzades per al millor resultat de l'Estudi B.

5.4. Classificació de lesions de pròstata. Estudi C

Es mostren a continuació els resultats de l'Estudi C, de forma anàloga a com s'han mostrat els de l'Estudi A i l'Estudi B.

5.4.1. Nivell de gris 16

A la Taula 17 es detallen els resultats més destacats per a aquest estudi i aquest nivell de gris.

Models	SVM-RFE		ReliefF	
	AUC ($\mu \pm \sigma$)	Nº de variables	AUC ($\mu \pm \sigma$)	Nº de variables
AdaBoost	0.7245 \pm 0.0971	101	0.7336 \pm 0.0811	86
DiscrLin	0.6359 \pm 0.0990	8	0.6508 \pm 0.0968	9
DiscrQua	0.6287 \pm 0.0916	41	0.6075 \pm 0.1038	15
KNN	0.7176 \pm 0.0880	109	0.7078 \pm 0.0768	107
KNNens	0.6973 \pm 0.0866	112	0.6857 \pm 0.0894	120
NB	0.6857 \pm 0.1002	122	0.6922 \pm 0.0841	122
RF	0.7114 \pm 0.0898	117	0.7179 \pm 0.0799	69
SVM	0.6615 \pm 0.0860	31	0.6545 \pm 0.0963	9

Taula 17. Resultats Estudi C, Nivell de gris 16.

A la Figura 44 es mostren, per a aquest estudi i aquest nivell de gris, els perfils per model amb ReliefF com a mètode de selecció de variables.

DISSENY D'UNA APROXIMACIÓ BASADA EN RADIOMICA PER A UNA CLASSIFICACIÓ DE TUMORS DE PRÒSTATA MITJANÇANT ANÀLISI DE TEXTURES EN IMATGES DE RESSONÀNCIA MAGNÈTICA




Figura 44. Gràfica de perfils per model, amb la FS ReliefF i 16 nivells de gris. Estudi C.

A la Figura 45 es mostren, per a aquest estudi i aquest nivell de gris, els perfils per model amb SVM-RFE com a mètode de selecció de variables.




Figura 45. Gràfica de perfils per model, amb la FS SVM-RFE i 16 nivells de gris. Estudi C.

El millor resultat per a 16 nivells de gris s'obté amb AdaBoost i les 86 millors característiques segons ReliefF, podent trobar la seua matriu de confusió a la Figura 46. Per a aquest model s'ha obtingut un AUC de 0.7336 ± 0.0811 . Si ens fixem en la matriu de confusió, podem observar que els valors de sensibilitat són 0.4074, 0.5676 i 0.5758 per a cada classe com a positiva, sent la mitjana 0.5169 ± 0.0949 . D'altra banda, els d'especificitat són 0.8000, 0.6833 i 0.7969 per a cada classe com a positiva, sent la mitjana 0.7601 ± 0.0665 . L'*accuracy* per tant es de 0.5258.

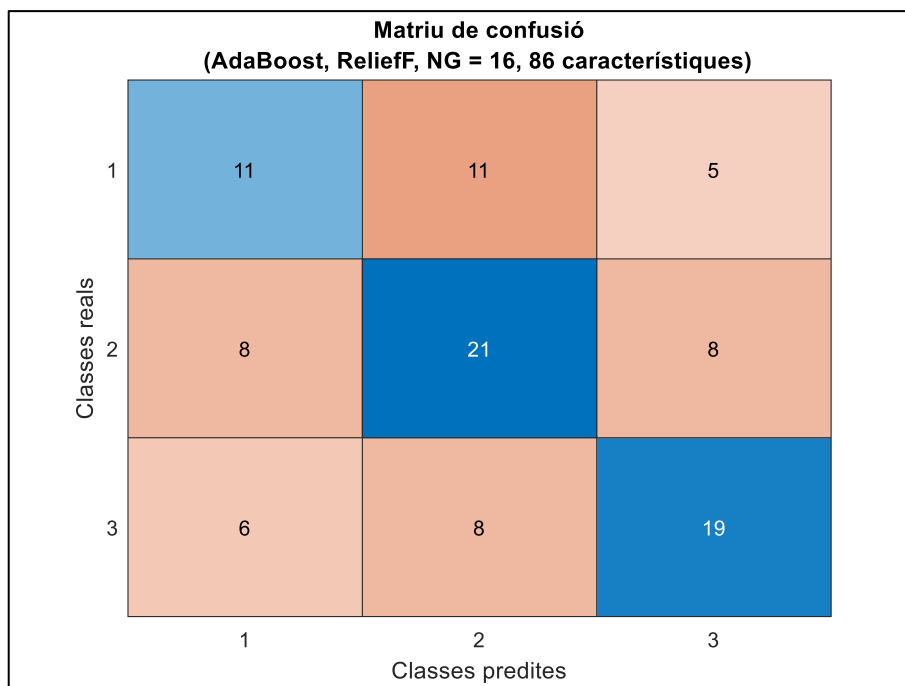


Figura 46. Matriu de confusió del millor model per a nivell de gris 16. Estudi C.

5.4.2. Nivell de gris 32

A la Taula 18 es detallen els resultats més destacats per a aquest estudi i aquest nivell de gris.

Models	SVM-RFE		ReliefF	
	AUC ($\mu \pm \sigma$)	Nº de variables	AUC ($\mu \pm \sigma$)	Nº de variables
AdaBoost	0.7376 \pm 0.0877	116	0.7383 \pm 0.0846	58
DiscrLin	0.6457 \pm 0.1013	18	0.6476 \pm 0.1039	28
DiscrQua	0.5919 \pm 0.0977	52	0.5956 \pm 0.0811	64
KNN	0.7152 \pm 0.0959	119	0.7162 \pm 0.0773	110
KNNens	0.6949 \pm 0.0854	125	0.6858 \pm 0.0963	124
NB	0.6952 \pm 0.0785	120	0.6924 \pm 0.0893	124
RF	0.7228 \pm 0.0832	122	0.7422 \pm 0.0818	110
SVM	0.6982 \pm 0.0852	18	0.6632 \pm 0.0866	81

Taula 18. Resultats Estudi C, Nivell de gris 32.

A la Figura 47 es mostren, per a aquest estudi i aquest nivell de gris, els perfils per model amb ReliefF com a mètode de selecció de variables.




Figura 47. Gràfica de perfils per model, amb la FS ReliefF i 32 nivells de gris. Estudi C.

A la Figura 48 es mostren, per a aquest estudi i aquest nivell de gris, els perfils per model amb SVM-RFE com a mètode de selecció de variables.




Figura 48. Gràfica de perfils per model, amb la FS SVM-RFE i 32 nivells de gris. Estudi C.

El millor resultat per a 16 nivells de gris s'obté amb *Random Forest* i les 110 millors característiques segons ReliefF, podent trobar la seua matriu de confusió a la Figura 49. Per a aquest model s'ha obtingut un AUC de 0.7422 ± 0.0818 . Si ens fixem en la matriu de confusió, podem observar que els valors de sensibilitat són 0.4074, 0.5946 i 0.6364 per a cada classe com a positiva, sent la mitjana 0.5461 ± 0.1220 . D'altra banda, els d'especificitat són 0.8143, 0.7000 i 0.8125 per a cada classe com a positiva, sent la mitjana 0.7756 ± 0.0655 . L'*accuracy* per tant es de 0.5567.

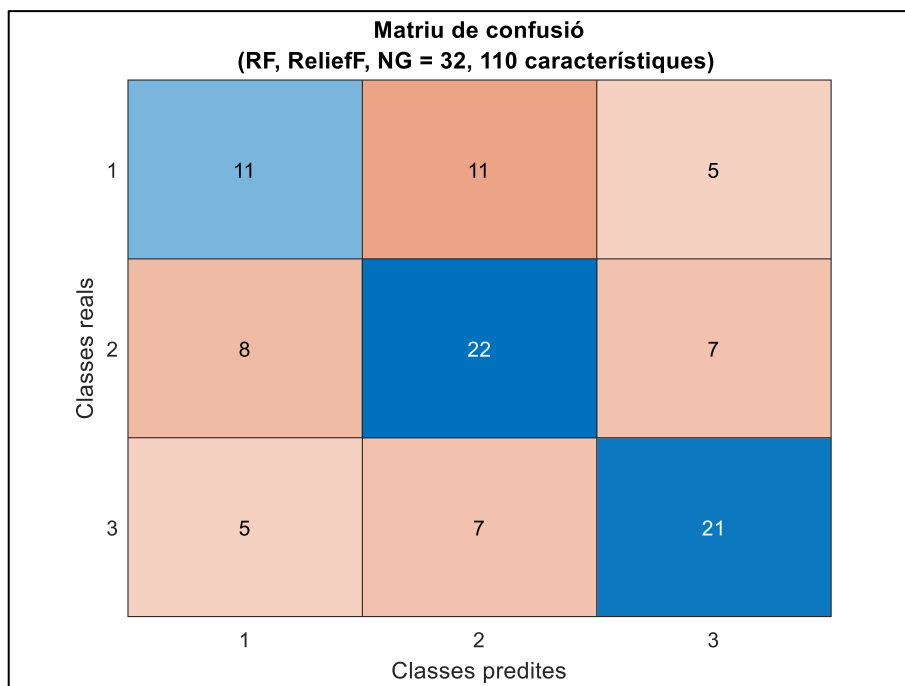


Figura 49. Matriu de confusió del millor model per a nivell de gris 32. Estudi C.

5.4.3. Nivell de gris 64

A la Taula 19 es detallen els resultats més destacats per a aquest estudi i aquest nivell de gris.

Models	SVM-RFE		ReliefF	
	AUC ($\mu \pm \sigma$)	Nº de variables	AUC ($\mu \pm \sigma$)	Nº de variables
AdaBoost	0.6830 \pm 0.0795	102	0.6813 \pm 0.0854	60
DiscrLin	0.6539 \pm 0.0859	17	0.6576 \pm 0.0885	16
DiscrQua	0.6428 \pm 0.0995	118	0.6440 \pm 0.0883	118
KNN	0.7249 \pm 0.0871	84	0.7147 \pm 0.0731	116
KNNens	0.6007 \pm 0.0748	117	0.5837 \pm 0.0826	117
NB	0.6698 \pm 0.1162	117	0.6754 \pm 0.0959	110
RF	0.7093 \pm 0.0715	117	0.7094 \pm 0.0706	103
SVM	0.6631 \pm 0.1099	108	0.6623 \pm 0.0995	116

Taula 19. Resultats Estudi C, Nivell de gris 64.

A la Figura 50 es mostren, per a aquest estudi i aquest nivell de gris, els perfils per model amb ReliefF com a mètode de selecció de variables.

DISSENY D'UNA APROXIMACIÓ BASADA EN RADIÒMICA PER A UNA CLASSIFICACIÓ DE TUMORS DE PRÒSTATA MITJANÇANT ANÀLISI DE TEXTURES EN IMATGES DE RESSONÀNCIA MAGNÈTICA




Figura 50. Gràfica de perfils per model, amb la FS ReliefF i 64 nivells de gris. Estudi C.

A la Figura 51 es mostren, per a aquest estudi i aquest nivell de gris, els perfils per model amb SVM-RFE com a mètode de selecció de variables.




Figura 51. Gràfica de perfils per model, amb la FS SVM-RFE i 64 nivells de gris. Estudi C.

El millor resultat per a 16 nivells de gris s'obté amb KNN i les 84 millors característiques segons SVM-RFE, podent trobar la seua matriu de confusió a la Figura 52. Per a aquest model s'ha obtingut un AUC de 0.7249 ± 0.0871 . Si ens fixem en la matriu de confusió, podem observar que els valors de sensibilitat són 0.6429, 0.5405 i 0.5000 per a cada classe com a positiva, sent la mitjana 0.5611 ± 0.0737 . D'altra banda, els d'especificitat són 0.7264, 0.7333 i 0.8769 per a cada classe com a positiva, sent la mitjana 0.7789 ± 0.0850 . L'accuracy per tant es de 0.5567.




Figura 52. Matriu de confusió del millor model per a nivell de gris 64. Estudi C.

5.4.4. Nivell de gris 128

A la Taula 20 es detallen els resultats més destacats per a aquest estudi i aquest nivell de gris.

Models	SVM-RFE		ReliefF	
	AUC ($\mu \pm \sigma$)	Nº de variables	AUC ($\mu \pm \sigma$)	Nº de variables
AdaBoost	0.6979 \pm 0.0860	106	0.6924 \pm 0.0852	108
DiscrLin	0.6482 \pm 0.0928	18	0.6616 \pm 0.0982	34
DiscrQua	0.6302 \pm 0.1024	111	0.6325 \pm 0.0944	55
KNN	0.6461 \pm 0.1011	78	0.6463 \pm 0.0990	49
KNNens	0.5792 \pm 0.1025	69	0.6022 \pm 0.0782	74
NB	0.6955 \pm 0.1007	114	0.7058 \pm 0.0896	110
RF	0.7124 \pm 0.0735	95	0.7064 \pm 0.0805	112
SVM	0.6803 \pm 0.0711	114	0.7130 \pm 0.1018	69

Taula 20. Resultats Estudi C, Nivell de gris 128.

A la Figura 53 es mostren, per a aquest estudi i aquest nivell de gris, els perfils per model amb ReliefF com a mètode de selecció de variables.

DISSENY D'UNA APROXIMACIÓ BASADA EN RADIOMICA PER A UNA CLASSIFICACIÓ DE TUMORS DE PRÒSTATA MITJANÇANT ANÀLISI DE TEXTURES EN IMATGES DE RESSONÀNCIA MAGNÈTICA




Figura 53. Gràfica de perfils per model, amb la FS ReliefF i 64 nivells de gris. Estudi C.

A la Figura 54 es mostren, per a aquest estudi i aquest nivell de gris, els perfils per model amb SVM-RFE com a mètode de selecció de variables.




Figura 54. Gràfica de perfils per model, amb la FS SVM-RFE i 128 nivells de gris. Estudi C.

El millor resultat per a 16 nivells de gris s'obté amb SVM i les 69 millors característiques segons ReliefF, podent trobar la seua matriu de confusió a la Figura 55. Per a aquest model s'ha obtés un AUC de 0.7130 ± 0.1018 . Si ens fixem en la matriu de confusió, podem observar que els valors de sensibilitat son 0.5714, 0.5405 i 0.5313 per a cada classe com a positiva, sent la mitjana 0.5477 ± 0.0210 . D'altra banda, els d'especificitat son 0.7826, 0.7167 i 0.8154 per a cada classe com a positiva, sent la mitjana 0.7716 ± 0.0503 . L'accuracy per tant es de 0.5464.




Figura 55. Matriu de confusió del millor model per a nivell de gris 128. Estudi C.

5.4.5. Nivell de gris 256

A la Taula 21 es detallen els resultats més destacats per a aquest estudi i aquest nivell de gris.

Models	SVM-RFE		ReliefF	
	AUC ($\mu \pm \sigma$)	Nº de variables	AUC ($\mu \pm \sigma$)	Nº de variables
AdaBoost	0.7127 \pm 0.0714	102	0.7428 \pm 0.0780	67
DiscrLin	0.6479 \pm 0.0781	7	0.7057 \pm 0.1022	31
DiscrQua	0.6426 \pm 0.0895	13	0.6596 \pm 0.0997	60
KNN	0.6507 \pm 0.0865	104	0.6758 \pm 0.0863	78
KNNens	0.6159 \pm 0.0935	94	0.6146 \pm 0.0802	109
NB	0.6867 \pm 0.0864	108	0.6877 \pm 0.0945	78
RF	0.6841 \pm 0.0838	101	0.7108 \pm 0.0914	79
SVM	0.6855 \pm 0.0795	57	0.7503 \pm 0.0692	46

Taula 21. Resultats Estudi C, Nivell de gris 256.

A la Figura 56 es mostren, per a aquest estudi i aquest nivell de gris, els perfils per model amb ReliefF com a mètode de selecció de variables.

DISSENY D'UNA APROXIMACIÓ BASADA EN RADIOMICA PER A UNA CLASSIFICACIÓ DE TUMORS DE PRÒSTATA MITJANÇANT ANÀLISI DE TEXTURES EN IMATGES DE RESSONÀNCIA MAGNÈTICA




Figura 56. Gràfica de perfils per model, amb la FS ReliefF i 64 nivells de gris. Estudi C.

A la Figura 57 es mostren, per a aquest estudi i aquest nivell de gris, els perfils per model amb SVM-RFE com a mètode de selecció de variables.




Figura 57. Gràfica de perfils per model, amb la FS SVM-RFE i 256 nivells de gris. Estudi C.

El millor resultat per a 16 nivells de gris s'obté amb SVM i les 46 millors característiques segons ReliefF, podent trobar la seua matriu de confusió a la Figura 58. Per a aquest model s'ha obtingut un AUC de 0.7503 ± 0.0692 . Si ens fixem en la matriu de confusió, podem observar que els valors de sensibilitat són 0.5556, 0.5135 i 0.5758 per a cada classe com a positiva, sent la mitjana 0.5483 ± 0.0318 . D'altra banda, els d'especificitat són 0.8143, 0.6833 i 0.8125 per a cada classe com a positiva, sent la mitjana 0.7700 ± 0.0751 . L'*accuracy* per tant es de 0.5464.




Figura 58. Matriu de confusió del millor model per a nivell de gris 256. Estudi C.

5.4.6. Resum

El millor resultat d'aquest Estudi C s'ha obtingut a l'utilitzar les 46 millors característiques amb 256 nivells de gris segons ReliefF, entrenant el model SVM. S'ha obtingut un AUC de 0.7503 ± 0.0692 , sent la sensibilitat mitja 0.5483 ± 0.0318 , la especificitat mitja 0.7700 ± 0.0751 i l'*accuracy* 0.5464.

La Figura 59 es correspon al rendiment d'aquest model als diferents nivells de gris estudiats.




Figura 59. Gràfica de perfils per nivell de gris per al model amb millor resultat. Estudi C.

A la Taula 22 una llista de les 80 variables més utilitzades, junt amb la seua freqüència relativa.

DISSENY D'UNA APROXIMACIÓ BASADA EN RADIÒMICA PER A UNA CLASSIFICACIÓ DE TUMORS DE PRÒSTATA MITJANÇANT ANÀLISI DE TEXTURES EN IMATGES DE RESSONÀNCIA MAGNÈTICA

Variable	Frecuencia relativa	Variable	Frecuencia relativa
SRLGE_GLRLM_DWI	0.0213	RLN_GLRLM_ADC	0.0170
SumAverage_GLCM_T2	0.0209	Strength_NGTDMS_ADC	0.0170
LGZE_GLSZM_DWI	0.0204	LGZE_GLSZM_T2	0.0165
ZP_GLSZM_ADC	0.0204	Dissimilarity_GLCM_T2	0.0161
Contrast_NGTDMS_ADC	0.0204	LRLGE_GLRLM_T2	0.0161
SZLGE_GLSZM_DWI	0.0200	AutoCorrelation_GLCM_DWI	0.0161
LRE_GLRLM_ADC	0.0200	LZHGE_GLSZM_ADC	0.0161
LZE_GLSZM_ADC	0.0200	HGRE_GLRLM_DWI	0.0157
LZLGE_GLSZM_DWI	0.0196	SRHGE_GLRLM_DWI	0.0157
Complexity_NGTDMS_ADC	0.0191	LRHGE_GLRLM_DWI	0.0157
GLN_GLRLM_ADC	0.0187	HGZE_GLSZM_DWI	0.0157
Busyness_NGTDMS_ADC	0.0187	Correlation_GLCM_ADC	0.0157
SRHGE_GLRLM_T2	0.0183	SZLGE_GLSZM_T2	0.0152
LGRE_GLRLM_DWI	0.0183	SZHGE_GLSZM_DWI	0.0152
SRE_GLRLM_ADC	0.0183	SumAverage_GLCM_DWI	0.0143
RP_GLRLM_ADC	0.0183	LRLGE_GLRLM_DWI	0.0143
SZE_GLSZM_ADC	0.0183	Complexity_NGTDMS_T2	0.0139
GLN_GLSZM_ADC	0.0183	SZHGE_GLSZM_T2	0.0135
LZLGE_GLSZM_T2	0.0178	Energy_GLCM_ADC	0.0135
LZHGE_GLSZM_DWI	0.0174	LGRE_GLRLM_T2	0.0130
ZSN_GLSZM_ADC	0.0174	LZHGE_GLSZM_T2	0.0130
Contrast_GLCM_ADC	0.0170	Coarseness_NGTDMS_ADC	0.0130
Homogeneity_GLCM_ADC	0.0170	Dissimilarity_GLCM_ADC	0.0126

Taula 22. Llista de les 46 variables més utilitzades per al millor resultat de l'Estudi C.

6. DISCUSSIÓ

6.1. Estudi del valor de b a les seqüències DWI

En relació amb la importància del valor de b a les seqüències de DWI, existeixen diversos estudis que entren en major profunditat en com es comporten les textures en funció del valor b (Becker, Wagner, Wurnig, & Boss, 2017; Zhang et al., 2019). Concretament, a Becker *et al.* (Becker et al., 2017) realitzen un estudi de la influència d'aquest valor per a diferents òrgans del cos, on troben que sí que hi ha relació entre b i les textures obtingudes. A més, troben que aquesta relació també depèn de l'òrgan a estudi. També existeixen algunes textures que semblen mostrar una relació general en tots els òrgans. No obstant, no s'inclou la pròstata en aquest estudi.

Algunes de les textures amb relació global amb el valor de b, es comparteixen amb els resultats obtinguts en el nostre estudi, com per exemple RLN_GLRLM i RP_GLRLM. A més, donada la naturalesa de les característiques, és a dir, són fórmules matemàtiques aplicades a una matriu de dades, existeixen algunes característiques amb una relació matemàtica que implica que la significança estadística d'una d'elles estiga present amb l'altra. És el cas de l'entropia i l'energia a la GLCM:

$$\text{energia} = \sum_{i=1} \sum_{j=1} [p(i,j)]^2 \qquad \text{entropia} = - \sum_{i=1} \sum_{j=1} p(i,j) \log_2(p(i,j))$$

On $p(i, j)$ és el valor en l'element (i, j) de la matriu GLCM. Es pot veure que hi ha una relació inversament proporcional, és a dir, el creixement d'una implica el decreixement de l'altra.

Per altre costat, podem veure com a mesura que reduïm els nivells de gris, l'efecte del valor b es redueix. A més, aquesta relació és diferent en funció de la matriu que utilitzem. Podem observar que en la matriu NGTDM aquest efecte no té influència, com si la té en les altres. A més, l'efecte que té sobre les variables que provenen de les mateixes matrius és similar, en el sentit que apareixen diferències fins a cert nivell de gris per a una matriu donada.

Al reduir els nivells de gris, estem simplificant la informació, així com reduint la SNR de la imatge. Si tenim en compte això, ens podem adonar que, donada la relació del valor de b amb la informació que ens aporta la sèrie DWI, una forma de reduir la variabilitat que podem tindre en un subconjunt de dades amb dos valors de b diferents podria ser treballar amb nivells de gris baixos. Aquesta seria una mesura una mica radical, donat que estaríem perdent molta informació perquè no s'utilitzaria de part de la informació de la qual es disposa. No obstant, pot ser una solució efectiva en el cas de no poder utilitzar altra mesura més coherent, per les circumstàncies de l'estudi.

Concretament, caldria avaluar les textures en les quals es va a treballar, ja que una variable provinent de la matriu NGTDM, donats els resultats d'aquest estudi, no podríem afirmar que hi haja un nivell de gris amb el qual puguem treballar. D'altra banda, a la matriu GLRLM per exemple, sembla que les diferències sols es donen a partir del nivell de gris 128, i per tant els nivells de gris més baixos sí que, a priori, semblen que es podrien aprofitar.

Cal remarcar que l'estudi realitzat sobre aquests valors en aquest treball ha sigut un estudi preliminar, i caldria profunditzar més en el tema.

6.2. Classificació de lesions de pròstata. Estudi A

Com es pot observar als resultats d'aquest estudi, els millors resultats s'han aconseguit amb els models SVM, RF i AdaBoost per a tots els nivells de gris, sent els pitjors obtinguts per KNNens per a 128 i 256 nivells de gris, mentre que a nivells més baixos, és DiscrQua el que dona els pitjors resultats. Podem observar també que els perfils dels models són similars amb els distints nivells de gris, és a dir, tenen un comportament paregut. No obstant, sí que podem observar que alguns d'ells són més sensibles al nivell de gris que altres.

També podem observar, com és lògic, que la importància de la tècnica de selecció de característiques utilitzada, és menor com major és el nombre de variables que es tenen en compte. Aquest fenomen es deu al fet que quan utilitzem un gran nombre de variables, la probabilitat de que la o les variables que no s'han inclòs, tinguen un gran poder discriminatori, és molt menuda.

Una altra de les coses que destaquen és la relació entre els models, el nivell de gris, i la FS utilitzada. Analitzant el que ha sigut el model que ha proporcionat el millor resultat, el SVM, podem observar que a nivells de gris baixos, quan s'utilitza la tècnica *ReliefF*, els resultats obtinguts no són bons, mentre que al nivell de gris més gran, el resultat obtingut amb *ReliefF* és millor que l'obtingut amb SVM-RFE. Cal destacar que SVM és més sensible a la tècnica de FS utilitzada que la resta, junt amb DiscrLin, pel fet que en la majoria dels casos els millors resultats s'obtenen amb poques variables, mentre que en la resta de casos pareix que com més variables millor.

Aquesta relació que es manté a tots els nivells entre el model utilitzat i el nombre óptim de variables, es pot deure principalment al funcionament intern dels classificadors. NB és un dels classificadors més robust front a un gran nombre de variables, i els models basats en tècniques d'assemblatge, a causa dels algorismes interns, poden evitar el possible sobre ajust existent, el qual pot afectar en major mesura a les tècniques SVM i DiscrLin.

Si analitzem la desviació típica dels resultats, podem veure que en general oscil·la entre 0.1 i 0.07. Això ens indica que els resultats obtinguts tenen prou variabilitat, i per tant, com els millors resultats obtinguts són similars, no podem afirmar de forma contundent que el model amb millor resultat siga el model per a utilitzar en la pràctica clínica. El que sí que podem afirmar, és que, donats els resultats d'aquest Estudi A, el model a utilitzar seria o RF, o AdaBoost, o SVM.

Podem veure també que, vists els perfils dels distints nivells de gris, així com els AUC mostrats a les taules, els resultats obtinguts amb un nivell de gris de 256, no es poden comparar amb la resta, ja que s'han obtingut valors inferiors. Pel que fa a la resta, pareix que en general tots els nivells ofereixen una informació similar, encara que per a cada model es donen situacions diferents.

En línies generals, pareix que RF i AdaBoost són els millors classificadors, independentment de la tècnica de selecció de variables utilitzada. No obstant, el classificador SVM destaca per sobre la resta quan s'utilitza amb les textures sotmeses a una quantització de 128 nivells de gris, i amb les 25 variables més importants segons SVM-RFE. Aquesta combinació és la que dona el millor resultat.

Quant a les variables utilitzades per al millor resultat, podem veure que la majoria són relatives a la sèrie d'imatges ADC. Aquest resultat es pot relacionar amb la utilitat que tenen els mapes ADC per a molts oncòlegs a l'hora de diagnosticar i avaluar tumors. És per això que resulta

interessant dur a terme un estudi que incloga la sèrie d'imatges DWI, donada la relació que té amb els mapes ADC.

6.3. Classificació de lesions de pròstata. Estudi B

En aquest segon estudi es manté que els millors models són SVM, AdaBoost i RF, i s'inclou un nou model a la llista, el qual seria el que ens proporcione el millor resultat, que és NB. En general, s'obtenen millors resultats per a tots els nivells de gris, sent el millor resultat entre un 4 i un 8 per cent superior. Aquesta millora general dels resultats reforça la idea que la sèrie DWI tenia informació discriminatòria, amb la qual es pot dur millor a terme la tasca de classificar les diferents mostres.

El comportament dels models és similar al cas anterior, sent novament els models DiscrQua i KNNens els que pitjors resultats ofereixen en la majoria de nivells de gris.

En relació a la variabilitat dels resultats, es tenen uns valors similars a l'Estudi A, i per tant novament no podem afirmar que un estudi siga millor que altre pels resultats obtinguts. No obstant, sí que podem afirmar que els models més robustos per a aquest problema, donats els resultats, són AdaBoost, RF i NB, junt amb SVM quan es tenen nivells de gris alts.

Novament, podem observar tendències creixents en diferents models en funció del nombre de característiques usades. L'exemple més clar és NB, amb la qual cosa es podria explicar la millora que ha tingut el valor d'AUC respecte a l'anterior estudi, pel fet que ara té més informació.

Respecte a les variables utilitzades pels models destacats, exceptuant algun cas del model SVM que sols utilitza 33 variables (es correspon al millor resultat de l'Estudi A), en general els models pareix que fan ús de la gran majoria de la informació de la qual disposen. Si bé és veritat que a partir d'unes 60 variables, els resultats obtinguts són similars, els millors resultats quasi sempre es troben passant les 100 variables. Podria ser una casualitat, i que el nombre òptim fora menor, però per a saber això necessitaríem un estudi amb un nombre de mostres major.

A més, cal tindre en compte que, en general, s'aconsella que els models utilitzen el menor nombre de textures possibles. Això és pel fet que a menys variables utilitzades, és més probable que es pugui aplicar a altres estudis, ja que serà menys complex. És per això que, donada la similitud dels resultats a un nombre distint de variables, s'aconsella aprofundir en el cas per a seleccionar, en la mesura que siga possible, aquella configuració que utilitzi menys variables, sempre que els resultats siguin suficientment satisfactoris.

6.4. Classificació de lesions de pròstata. Estudi C

Amb la realització d'aquest tercer estudi, podem comprovar diverses coses. Per un costat, tenim la xicoteta millora aconseguida només amb la introducció d'unes poques mostres més en alguns casos, encara que la pèrdua d'informació provoca que la mitjana dels resultats siga pitjor. Seria interessant observar que passaria amb l'augment del nombre de mostres, i comprovar si la tendència a millorar es manté.

D'altra banda, aquest estudi es pot comparar directament amb l'Estudi A, la diferència dels quals passa per la introducció de nova informació. Per tant, podem observar un augment del rendiment dels models en funció d'aquesta nova informació. Queda per tant comprovada la importància que té la sèrie DWI pel que fa a la classificació estudiada a aquest treball.

Si observem la matriu de confusió del millor model, podem comprovar com es produeix una bona distinció entre la classe 1, PI-RADS 2, i la classe 3, PI-RADS 4 i 5. En la pràctica clínica, aquesta classificació es podria comparar en cert grau en la classificació binària de la malignitat del tumor, i seria una bona notícia la potència discriminadora que s'obté. No obstant, sí que hi ha prou confusió entre la classe 2 i la resta.

Aquesta confusió es pot entendre si tenim en compte que PI-RADS 3 és una classificació clínica intermèdia, moltes vegades relacionada amb el dubte que pot tindre el radiòleg a l'hora de classificar una mostra. Existeixen diversos estudis respecte a la relació entre PI-RADS, i l'existència o no de càncer, així com la relació amb el risc associat a la lesió, una volta feta la biòpsia (prova concloent). En aquests estudis ((Kuru et al., 2013; Nimhurchu et al., 2016; Thompson et al., 2014)) podem observar com la classificació PI-RADS 3 és la que més incertesa proporciona. Per tant, no és d'estranyar que aquesta classificació siga la que més dificultats aporta, ja que la seua classificació va associada al dubte, i per tant, pot presentar una gran variabilitat.

Quant als resultats que més destaquen, continuen sent AdaBoost i RF, junt amb SVM per a nivells de gris alts. En aquest tercer estudi, destaca també KNN, superant el rendiment de NB en els nivells de gris baixos, i obtenint el millor resultat per al nivell de gris 64. Per tant KNN s'ha vist afavorit en aquest tercer estudi.

Novament, a causa de la variabilitat que presenten els resultats, no podem afirmar que un d'ells siga millor que la resta, però si podem comprovar com alguns d'ells destaquen sobre la resta.

7. CONCLUSIÓ

L'objectiu d'aquest treball era trobar biomarcadors basats en IRM capaços de classificar lesions en l'estàndard PI-RADS per a un òptim diagnòstic del càncer en pròstata. S'han aconseguit resultats satisfactoris, els quals es poden utilitzar com a una eina d'ajuda al diagnòstic. A més, en vista del millor resultat de l'Estudi C, si observem la matriu de confusió, podem pensar que la classificació PI-RADS pot tindre una major aproximació a la realitat si s'utilitzen biomarcadors per a la seua classificació, ja que aquests proporcionarien una informació purament objectiva en funció de les imatges. Es tractaria per tant d'una millora a l'hora de detectar i avaluar el càncer de pròstata, a més que es tracta d'una prova senzilla i el més important, no invasiva per al pacient.

En vista dels resultats, podem afirmar que s'han superat els objectius plantejats per a aquest treball en relació amb la recerca de biomarcadors, amb diferents models com són AdaBoost, Random Forest i SVM, que han demostrat obtindre en general els millors resultats.

A més, aquest estudi s'ha complementat amb un estudi relacionat amb la importància de la sèrie DWI per a la correcta discriminació de les diferents classes, millorant els resultats obtinguts quan s'han inclòs al conjunt de dades les diverses variables associades a aquesta sèrie.

8. LÍNIES FUTURES

Existeixen estudis relacionats amb l'eficàcia del valor de b a la sèrie DWI per a l'obtenció de biomarcadors. En aquest estudi, la majoria de les mostres (>90%) tenien un valor de b de 800 s/mm², sent la resta amb un valor de 1500 s/mm². Seria interessant realitzar un estudi similar a aquest però amb mostres únicament amb un valor de b de 1500 s/mm².

D'altra banda, s'ha observat que, amb unes poques mostres més, eliminant part de la informació, s'han obtingut alguns resultats millors. Per tant, caldria comprovar si efectivament un nombre de mostres superior pot proporcionar una millora dels resultats obtinguts.

També caldria revisar si hi ha informació discriminatòria a diferents nivells de gris que, si s'utilitzara de forma conjunta, proporciona un major rendiment. Es tractaria d'un conjunt de dades amb una gran quantitat d'informació, amb moltes variables, i caldria novament un gran nombre de mostres per a poder dur-lo a terme.

En relació als biomarcadors, seria necessari continuar aquest estudi amb la preparació d'una aplicació capaç de, a partir d'una imatge i la segmentació, proporcionar una classificació de la mostra. És a dir, caldria crear l'eina d'ajuda al diagnòstic clínic que faça servir els biomarcadors trobats, de forma que tinga utilitat per al personal sanitari corresponent.

9. PUBLICACIONS DERIVADES D'AQUEST TFG

Multiclass classification of prostate tumors following an MR image analysis-based radiomics approach

Jose Manuel Jaén-Lorites
Center for Biomaterials and Tissue Engineering, Universitat Politècnica de València, Valencia, Spain
josemanueljaenlorites@gmail.com

Tania Piñeiro-Vidal
ASCIREs-Grupo Biomédico, Valencia, Spain
tpineirov@ascires.com

Silvia Ruiz-España
Center for Biomaterials and Tissue Engineering, Universitat Politècnica de València, Valencia, Spain
silruies@upv.es

José Manuel Santabàrbara
ASCIREs-Grupo Biomédico, Valencia, Spain
jmsantabarbara@eres.com

David Moratal
Center for Biomaterials and Tissue Engineering, Universitat Politècnica de València, Valencia, Spain
dmoratal@eln.upv.es

Abstract— Prostate cancer is one of the most common cancers in men. Its early detection allows us to find the most appropriate treatment. In addition, it is important to know the cause of the cancer. However, the test performed are often invasive, resulting in a biopsy. A non-invasive alternative is the magnetic resonance imaging (MRI)-based PI-RADS v2 classification. This classification, however, has a certain degree of subjectivity. The aim of this work is to find objective biomarkers that allow the PI-RADS classification of prostate lesions using a radiomics approach on multiparametric MRI. T2-enhanced MRI series, diffusion-enhanced series and ADC maps are used, together with a segmentation of the lesion. A total of 90 subjects have been analyzed: 25 subjects with PI-RADS 2, 35 subjects with PI-RADS 3 and 30 subjects with PI-RADS 4 and 5. A total of 203 textures per MRI series have been extracted using five different statistical methods, which assess 609 different texture features. Two feature selection methods and eight multiclass predictive models have been evaluated. This is a multiclass study in which results of AUC > 0.7 are obtained in 20 different cases. The best AUC result is 0.7442 ± 0.0886, achieved with the Naive Bayes model.

Keywords— cancer; prostate; classifier; multiclass; supervised learning; texture analysis; RADIOMICS; MRI; DWI; ADC.

I. INTRODUCTION

Today, cancer is one of the leading causes of death worldwide [1]. In men, one of the most common cancers is prostate cancer. In 2018, there were more than 1 million prostate cancer deaths, and this number is expected to rise to more than 2 million by 2040 [2]. It is a slow-growing kind of cancer, although it does not show symptoms until advanced stages. In addition, symptoms may be confused with those caused by benign prostatic hyperplasia [3].

One of the key aspects of treating prostate cancer is its early detection. Early diagnosis not only increases life expectancy but also improves the future quality of the life of patients as much as possible. In addition, early detection

reduces health and economic costs. Because of this, the population at risk is routinely tested in a preventive way.

In order to plan the treatment to be followed, the tumor is classified according to its characteristics, thus estimating its malignancy. Prior to this, the patient is subjected to a set of invasive tests that end in a biopsy. From this biopsy, the Gleason score is used to classify [4]. A less invasive alternative is the PI-RADS v2 classification, which is performed using magnetic resonance imaging (MRI). This rating ranges from 1 to 5, indicating a very low or very high probability of clinically significant cancer, as defined by the American College of Radiology (ACR) [5]-[7].

Radiomics analyses in cancer studies have proven to be very useful, providing a great deal of information useful for the diagnosis [8], [9]. These methods involve extracting features from regions of the image and then analyzing them to create models and tools to aid in clinical decision making. These methods can be of different types, with statistical methods being one of the most widely used [10], [11]. To do this, the gray-level patterns and pixel interrelationships in the image are quantified to obtain statistical information from the image.

The aim of this work is to find quantitative biomarkers capable of correctly classifying prostate lesions in PI-RADS 2 (class 1), 3 (class 2) and 4 and 5 (class 3), using a combination of different MRI-sequences and a radiomics approach.

II. MATERIALS AND METHODS

A. Patients

A total of 90 MRI studies have been used, provided by ERESA - ASCIREs Group, with the prior written informed consent of the patients. The average age of the patients is 66.31 ± 7.02 years old. Of these, 23 correspond to class 1, 35 to class 2 and 30 to class 3. These MRI studies include T2-weighted images, diffusion-weighted images (DWI), and apparent diffusion coefficient (ADC) maps.

XXXX-XX-XXXXX-XXXXX-XXXX-XXXX.00 @20XX IEEE

J.M. Jaén-Lorites, T. Piñeiro-Vidal, S. Ruiz-España, J.M. Santabàrbara, & D. Moratal, “Multiclass classification of prostate tumors following a radiomics approach-based MR image analysis” in The 20th IEEE International Conference on Bioinformatics and BioEngineering (BIBE), 2020. Enviat el 15 de juny de 2020.

Evaluation of the performance of DWI textures in a radiomics approach for classifying prostate cancer

Jose Manuel Jaén-Lorites, Center for Biomaterials and Tissue Engineering, Universitat Politècnica de València, Valencia, Spain. josemanueljaenlorites@gmail.com

Tania Piñeiro-Vidal, ASCIREs-Grupo Biomédico, Valencia, Spain. tpineirov@ascires.com

Silvia Ruiz-España, Center for Biomaterials and Tissue Engineering, Universitat Politècnica de València, Valencia, Spain. silruies@upv.es

Irene Del Canto, Center for Biomaterials and Tissue Engineering, Universitat Politècnica de València, Valencia, Spain. irene.delcanto@gmail.com

Jose Manuel Santabàrbara, ASCIREs-Grupo Biomédico, Valencia, Spain. jmsantabarbara@eres.com

David Moratal, Center for Biomaterials and Tissue Engineering, Universitat Politècnica de València, Valencia, Spain. dmoratal@eln.upv.es

Introduction

In prostate cancer, one of the key aspects is early detection. One of the non-invasive procedures to classify prostate cancer is to make use of the PI-RADS classification from mpMRI. Radiomics is a technique that extracts statistical information from the image, and with it classifies tumours. However, the MRI series to be used is questionable. In this study we intend to analyse the performance offered by the DWI series textures, obtained with two different b-values, when performing a PI-RADS classification.

Subjects/Methods

A total of 907 patients participated with a b value of 500/1500 s/mm² with PI-RADS 2, 35/2 with PI-RADS 3 and 24/3 with PI-RADS 4 and 5. The T2 MRI, DWI and ADC series were used. These series are co-registered, and a segmentation of the prostate lesion is made in each patient.

To carry out the study, a classification study is first performed with the T2 and ADC series. A radiomic approach is used in which a quantification of the grey levels of the images (16, 32, 64, 128 and 256) is used as a previous step to the extraction of textures. A total of 203 textures are extracted per series. As indicated in Larroza *et al.* [1], the optimal grey level number is searched for, so they are studied separately. In addition, the optimal number of variables is also searched. To carry out the study, two methods of feature selection and eight multi-class predictive models are used. Finally, the mean AUC obtained is calculated for a multiclass extension.

Subsequently, a second study is carried out, the same as the previous one, but including the DWI series. Since there are different values of b, as a previous step to the second study, the differences of the textures extracted as a function of the parameter b are analysed with the Mann-Whitney test. Those textures that present differences with a significance level of 0.05 are excluded from the study.

Discussion

We can see in Table 1 the best results of each study, where the AUC obtained, the model used, the number of grey level and the number of variables and the FS method are indicated.

J.M. Jaén-Lorites, T. Piñeiro-Vidal, S. Ruiz-España, I. Del Canto J.M. Santabàrbara, & D. Moratal, “Evaluation of the performance of DWI textures in a radiomics approach for classifying prostate cancer” in The 37th ESMRMB Annual Scientific Meeting, 2020. Enviat el 15 de juny de 2020.

10. BIBLIOGRAFIA

- Aaron, L., Franco, O. E., & Hayward, S. W. (2016). Review of Prostate Anatomy and Embryology and the Etiology of Benign Prostatic Hyperplasia. *Urologic Clinics of North America*, 43(3), 279–288. <https://doi.org/10.1016/j.ucl.2016.04.012>
- Amadasun, M., & King, R. (1989). Textural features corresponding to textural properties. *IEEE Transactions on Systems, Man, and Cybernetics*, 19(5), 1264–1274. <https://doi.org/10.1109/21.44046>
- American College of Radiology. (2020). PI-RADS | American College of Radiology. Retrieved May 17, 2020, from <https://www.acr.org/Clinical-Resources/Reporting-and-Data-Systems/PI-RADS>
- Anand, P., Kunnumakara, A. B., Sundaram, C., Harikumar, K. B., Tharakan, S. T., Lai, O. S., ... Aggarwal, B. B. (2008). Cancer is a Preventable Disease that Requires Major Lifestyle Changes. *Pharmaceutical Research*, 25(9), 2097–2116. <https://doi.org/10.1007/s11095-008-9661-9>
- Becker, A. S., Wagner, M. W., Wurnig, M. C., & Boss, A. (2017). Diffusion-weighted imaging of the abdomen: Impact of b-values on texture analysis features. *NMR in Biomedicine*, 30(1), 1–11. <https://doi.org/10.1002/nbm.3669>
- Castellano, G., Bonilha, L., Li, L. M., & Cendes, F. (2004). Texture analysis of medical images. *Clinical Radiology*, 59(12), 1061–1069. <https://doi.org/10.1016/j.crad.2004.07.008>
- Collewet, G., Strzelecki, M., & Mariette, F. (2004). Influence of MRI acquisition protocols and image intensity normalization methods on texture classification. *Magnetic Resonance Imaging*, 22(1), 81–91. <https://doi.org/10.1016/j.mri.2003.09.001>
- CuidatePlus. (2020). Próstata | CuidatePlus. Retrieved May 16, 2020, from <https://cuidateplus.marca.com/sexualidad/diccionario/prostata.html>
- Dietterich, T. G., & Bakiri, G. (1995). Solving Multiclass Learning Problems via Error-Correcting Output Codes. *Journal of Artificial Intelligence Research*, 2, 263–286. <https://doi.org/10.1613/jair.105>
- Domingos, P., & Provost, F. (2003). Tree Induction for Probability-Based Ranking. *Machine Learning*, 52(3), 199–215. <https://doi.org/10.1023/A:1024099825458>
- Fagerland, M. W., & Sandvik, L. (2009). Performance of five two-sample location tests for skewed distributions with unequal variances. *Contemporary Clinical Trials*, 30(5), 490–496. <https://doi.org/10.1016/j.cct.2009.06.007>
- Fawcett, T. (2006). An introduction to ROC analysis. *Pattern Recognition Letters*, 27(8), 861–874. <https://doi.org/10.1016/j.patrec.2005.10.010>
- Galloway, M. M. (1975). Texture analysis using gray level run lengths. *Computer Graphics and Image Processing*, 4(2), 172–179. [https://doi.org/10.1016/S0146-664X\(75\)80008-6](https://doi.org/10.1016/S0146-664X(75)80008-6)
- Groppe, D. (2020). Bonferroni-Holm Correction for Multiple Comparisons - File Exchange - MATLAB Central. Retrieved May 23, 2020, from <https://es.mathworks.com/matlabcentral/fileexchange/28303-bonferroni-holm-correction-for-multiple-comparisons>
- Gu, Q., Li, Z., & Han, J. (2012). Generalized Fisher Score for Feature Selection. *Proceedings of the 27th Conference on Uncertainty in Artificial Intelligence, UAI 2011*, 266–273. Retrieved from <http://arxiv.org/abs/1202.3725>
- Guyton, A., & Hall, J. (2011). *Guyton y Hall Tratado de Fisiología Médica*. ELSEVIER España S.L. <https://doi.org/10.1093/jhered/est132>

- Häggström, M. (2014). Medical gallery of Mikael Häggström 2014. *WikiJournal of Medicine*. <https://doi.org/10.15347/wjm/2014.008>
- Hanahan, D., & Weinberg, R. A. (2000, January 7). The hallmarks of cancer. *Cell*. Elsevier. [https://doi.org/10.1016/S0092-8674\(00\)81683-9](https://doi.org/10.1016/S0092-8674(00)81683-9)
- Haralick, R. M., Shanmugam, K., & Dinstein, I. (1973). Textural Features for Image Classification. *IEEE Transactions on Systems, Man, and Cybernetics*, *SMC-3*(6), 610–621. <https://doi.org/10.1109/TSMC.1973.4309314>
- International Agency for Research on Cancer. (2019). Cancer Tomorrow. *World Health Organization (WHO)*. Retrieved from <https://gco.iarc.fr/tomorrow/home>
- Kumar, V., Gu, Y., Basu, S., Berglund, A., Eschrich, S. A., Schabath, M. B., ... Gillies, R. J. (2012). Radiomics: the process and the challenges. *Magnetic Resonance Imaging*, *30*(9), 1234–1248. <https://doi.org/10.1016/j.mri.2012.06.010>
- Kuru, T. H., Roethke, M. C., Rieker, P., Roth, W., Fenchel, M., Hohenfellner, M., ... Hadaschik, B. A. (2013). Histology core-specific evaluation of the European Society of Urogenital Radiology (ESUR) standardised scoring system of multiparametric magnetic resonance imaging (mpMRI) of the prostate. *BJU International*, *112*(8), 1080–1087. <https://doi.org/10.1111/bju.12259>
- Larroza, A., Bodí, V., & Moratal, D. (2016). Texture Analysis in Magnetic Resonance Imaging: Review and Considerations for Future Applications. In *Assessment of Cellular and Organ Function and Dysfunction using Direct and Derived MRI Methodologies* (p. 13). InTech. <https://doi.org/10.5772/64641>
- Lavery, A., Kirby, R. S., & Chowdhury, S. (2016). Prostate cancer. *Medicine (United Kingdom)*, *44*(1), 47–51. <https://doi.org/10.1016/j.mpmed.2015.10.001>
- Manjón, J. V. (2020). Análisis funcional: Difusión. Transparencias de la asignatura Análisis de señales e imágenes biomédicas. Universitat Politècnica de València.
- Martínez-Amores Martínez, B., Durán Poveda, M., Sánchez Encinas, M., & Molina Villaverde, R. (2013). Actualización en cáncer de próstata. *Medicine - Programa de Formación Médica Continuada Acreditado*, *11*(26), 1578–1587. [https://doi.org/10.1016/S0304-5412\(13\)70509-2](https://doi.org/10.1016/S0304-5412(13)70509-2)
- Materka, A. (2004). Texture analysis methodologies for magnetic resonance imaging. *Dialogues in Clinical Neuroscience*, *6*(2), 243–250.
- MathWorks. (2020a). Ensemble Algorithms - MATLAB & Simulink - MathWorks India. Retrieved May 28, 2020, from <https://in.mathworks.com/help/stats/ensemble-algorithms.html#btbbds9>
- MathWorks. (2020b). Fit discriminant analysis classifier - MATLAB fitcdiscr - MathWorks India. Retrieved May 28, 2020, from <https://in.mathworks.com/help/stats/fitcdiscr.html#bvjg9sk>
- Mayerhoefer, M. E., Szomolanyi, P., Jirak, D., Materka, A., & Trattnig, S. (2009). Effects of MRI acquisition parameter variations and protocol heterogeneity on the results of texture analysis and pattern discrimination: An application-oriented study. *Medical Physics*, *36*(4), 1236–1243. <https://doi.org/10.1118/1.3081408>
- Miller, D. C., Hafez, K. S., Stewart, A., Montie, J. E., & Wei, J. T. (2003). Prostate carcinoma presentation, diagnosis, and staging. *Cancer*, *98*(6), 1169–1178. <https://doi.org/10.1002/cncr.11635>
- Nimhurchu, E., O'Kelly, F., Murphy, I. G., Lavelle, L. P., Collins, C. D., Lennon, G., ... McMahon, C. J. (2016). Predictive value of PI-RADS classification in MRI-directed transrectal ultrasound guided prostate biopsy. *Clinical Radiology*, *71*(4), 375–380. <https://doi.org/10.1016/j.crad.2016.01.001>

- Opitz, D., & Maclin, R. (1999). Popular Ensemble Methods: An Empirical Study. *Journal of Artificial Intelligence Research*, 11, 169–198. <https://doi.org/10.1613/jair.614>
- Ortiz Ramón, R. (2019). *Radiomics for diagnosis and assessing brain diseases: an approach based on texture analysis on magnetic resonance imaging*. Universitat Politècnica de València, Valencia (Spain). <https://doi.org/10.4995/Thesis/10251/119118>
- Planas, J. G. (2003). Introducción Biofísica a la Resonancia Magnética en Neuroimagen. V:03-2, V:03-2. Retrieved from <https://www.vetcomunicaciones.com.ar/uploadsarchivos/libro.gili.pdf>
- Priest, R., Garzotto, M., & Kaufman, J. (2012). Benign Prostatic Hyperplasia: A Brief Overview of Pathogenesis, Diagnosis, and Therapy. *Techniques in Vascular and Interventional Radiology*, 15(4), 261–264. <https://doi.org/10.1053/j.tvir.2012.10.001>
- Reeves, F., Everaerts, W., Murphy, D. G., & Costello, A. (2016). *The Surgical Anatomy of the Prostate. Prostate Cancer: Science and Clinical Practice: Second Edition* (Second Edi). Elsevier Ltd. <https://doi.org/10.1016/B978-0-12-800077-9.00029-3>
- Robnik-Šikonja, M., & Kononenko, I. (2003). Theoretical and Empirical Analysis of Relief and RRelief. *Machine Learning*, 53(1–2), 23–69. <https://doi.org/10.1023/A:1025667309714>
- Rokach, L. (2010). Ensemble-based classifiers. *Artificial Intelligence Review*, 33(1–2), 1–39. <https://doi.org/10.1007/s10462-009-9124-7>
- Schad, L. R. (2004). Problems in texture analysis with magnetic resonance imaging. *Dialogues in Clinical Neuroscience*, 6(2), 235–242.
- Sociedad Española de Oncología Médica. (2019). El cáncer en cifras - SEOM: Sociedad Española de Oncología Médica © 2019. Retrieved May 7, 2020, from <https://seom.org/publicaciones/el-cancer-en-espanyacom>
- Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information Processing & Management*, 45(4), 427–437. <https://doi.org/10.1016/j.ipm.2009.03.002>
- Swallow, T., Chowdhury, S., & Kirby, R. S. (2012). Cancer of the prostate gland. *Medicine*, 40(1), 10–13. <https://doi.org/10.1016/j.mpmed.2011.09.002>
- Thibault, G., Fertil, B., Navarro, C., Pereira, S., Cau, P., Levy, N., ... Mari, J.-L. (2013). Shape and texture indexes application to cell nuclei classification. *International Journal of Pattern Recognition and Artificial Intelligence*, 27(01), 1357002. <https://doi.org/10.1142/S0218001413570024>
- Thompson, J. E., Moses, D., Shnier, R., Brenner, P., Delprado, W., Ponsky, L., ... Stricker, P. D. (2014). Multiparametric magnetic resonance imaging guided diagnostic biopsy detects significant prostate cancer and could reduce unnecessary biopsies and over detection: A prospective study. *Journal of Urology*, 192(1), 67–74. <https://doi.org/10.1016/j.juro.2014.01.014>
- Torregrosa Andrés, A., Otero García, M., & Sineiro Galiñanes, M. (2017). Resonancia magnética de próstata: lectura con el sistema PI-RADS V2. *Radiología*, 59(2), 128–138. <https://doi.org/10.1016/j.rx.2016.10.005>
- Touma, N. J., & Nickel, J. C. (2011). Prostatitis and Chronic Pelvic Pain Syndrome in Men. *Medical Clinics of North America*, 95(1), 75–86. <https://doi.org/10.1016/j.mcna.2010.08.019>
- Vallières, M., Freeman, C. R., Skamene, S. R., & El Naqa, I. (2015). A radiomics model from joint FDG-PET and MRI texture features for the prediction of lung metastases in soft-tissue sarcomas of the extremities. *Physics in Medicine and Biology*, 60(14), 5471–5496. <https://doi.org/10.1088/0031-9155/60/14/5471>

DISSENY D'UNA APROXIMACIÓ BASADA EN RADIÒMICA PER A UNA CLASSIFICACIÓ DE TUMORS DE PRÒSTATA MITJANÇANT ANÀLISI DE TEXTURES EN IMATGES DE RESSONÀNCIA MAGNÈTICA

- Weinreb, J. C., Barentsz, J. O., Choyke, P. L., Cornud, F., Haider, M. A., Macura, K. J., ... Verma, S. (2016). PI-RADS Prostate Imaging - Reporting and Data System: 2015, Version 2. *European Urology*. <https://doi.org/10.1016/j.eururo.2015.08.052>
- World Health Organization. (2014). OMS | Datos y cifras sobre el cáncer. Retrieved May 7, 2020, from <https://www.who.int/cancer/about/facts/es/>
- Yan, K. (2020). Feature selection with SVM-RFE - File Exchange - MATLAB Central. Retrieved May 20, 2020, from <https://es.mathworks.com/matlabcentral/fileexchange/50701-feature-selection-with-svm-rfe>
- Young, B., O'Dowd, G., & Woodford, P. (2014). *Wheater : histología funcional : texto y atlas en color. Wheater. Histología funcional : Texto y Atlas en color.*
- Zaffalon, M., & Hutter, M. (2002). Robust Feature Selection by Mutual Information Distributions. Retrieved from <http://arxiv.org/abs/1408.1487>
- Zhang, J., Qiu, Q., Duan, J., Gong, G., Jiang, Q., Sun, G., & Yin, Y. (2019). Variability of radiomic features extracted from multi-b-value diffusion-weighted images in hepatocellular carcinoma. *Translational Cancer Research*, 8(1), 130–140. <https://doi.org/10.21037/tcr.2019.01.14>

DISSENY D'UNA APROXIMACIÓ BASADA EN RADIÒMICA PER A UNA CLASSIFICACIÓ DE TUMORS DE PRÒSTATA MITJANÇANT ANÀLISI DE TEXTURES EN IMATGES DE RESSONÀNCIA MAGNÈTICA

DISSENY D'UNA APROXIMACIÓ BASADA EN RADIÒMICA PER A UNA CLASSIFICACIÓ DE TUMORS DE PRÒSTATA MITJANÇANT ANÀLISI DE TEXTURES EN IMATGES DE RESSONÀNCIA MAGNÈTICA

DOCUMENT

PRESSUPOST

DISSENY D'UNA APROXIMACIÓ BASADA EN RADIÒMICA PER
A UNA CLASSIFICACIÓ DE TUMORS DE PRÒSTATA
MITJANÇANT ANÀLISI DE TEXTURES EN IMATGES DE
RESSONÀNCIA MAGNÈTICA

AUTOR: JOSE MANUEL JAÉN LORITES

TUTOR: DAVID MORATAL PÉREZ

Centre de Biomaterials i Enginyeria Tissular, Universitat Politècnica de València

COTUTORA: SILVIA RUÍZ ESPAÑA

Centro de Biomaterials i Enginyeria Tissular, Universitat Politècnica de València

COTUTORA: TANIA PIÑEIRO VIDAL

ERESA - Grup Biomèdic ASCIRES

CURS 2019 - 2020

ÍNDIX DELS PRESSUPOSTOS

1. Introducció	1
2. Quadre de mà d'obra	2
3. Quadre de materials.....	2
4. Quadre de preus unitaris.....	3
5. Quadre de preus descompostos	4
6. Quadre de preus parcials	5
7. Pressupost d'execució per contrata.....	7

1. INTRODUCCIÓ

En aquest document del TFG es presenta una valoració econòmica del treball realitzat. Es detallen a continuació algunes de les consideracions que s'han tingut en compte per a elaborar aquest pressupost.

La mà d'obra necessària per a dur a terme aquest projecte ha sigut un enginyer biomèdic junior (estudiant), que és qui realitza la major part del treball, dos enginyers en qualitat de consultors, que han sigut el tutor i cotutor, un enginyer sènior, també cotutor i encarregat de les segmentacions, i un radiòleg expert. Per al càlcul del cost per hora de cadascun d'aquestes persones, s'ha considerat un salari brut anual de 20 000 € per a l'enginyer biomèdic junior, 50 000 i 40 000 € per als consultors respectivament, 30 000 € per a l'enginyer sènior, i 70 000 € per al radiòleg. El cost per a l'empresa es correspon al salari brut percebut mes una sèrie de conceptes de seguretat social que es desglossen, segons el Ministeri de Treball, Migracions i Seguretat Social, de la següent forma: un 23.6 % com a cotització de contingències comunes, un 5.5 % com a cotització per aturament, un 1 % com a cotització per accidents i malalties professionals, un 0.6 % com a formació professional i un 0.2 % com a cotització a FOGASA (Fons de Garantia Salarial), que resulta en un augment total del 30.9 % respecte al salari brut percebut. En el quadre de mà d'obra queda registrat el preu per hora, que és el resultat de dividir el resultat de salari brut mes els conceptes mencionats entre 1792 h de treball que es calcula es realitzen a l'any. Aquest nombre resulta considerant una jornada laboral de 8 h, i descomptant als dies de l'any els caps de setmana, 15 dies festius i 30 dies de vacances.

Respecte als costos dels materials, s'ha tingut en compte que la vida útil d'un ordinador són 5 anys, i per tant, la dels programes associats també. El preu de l'ordinador és de 550 €, la llicència del programa Matlab són 2000 €, i la llicència de M. Office Hogar y Empresas són 299 € (en realitat el cost d'aquestes dues llicències ha estat 0, donat que són proporcionades per la UPV, encara que en aquest pressupost s'inclouen per a mostrar el cost com si no es comptara amb la llicència). Donat que aquest treball s'ha dut a terme durant 6 mesos, això fa un factor d'amortització de 6/60, el que ve a ser 0.1. Aquests materials s'han aplicat una única volta al capítol 3, com a una única unitat, fent referència al total utilitzat. Quant al programa AW Server, es tracta d'una eina professional cedida per part del grup Ascires, segons els quals té un cost associat de 50 000 € anuals per a ells. En aquest cas si s'ha calculat el preu per hora, fent servir el càlcul de 1792 h de treball.

Per a obtindre el pressupost per contrata del projecte, s'ha incrementat el pressupost d'execució material (suma de pressupostos parcials) en un 13 % en concepte de despeses generals, i en un 6 % per al benefici industrial. Seguidament, a aquest pressupost incrementat, se li ha aplicat el tipus d'IVA corresponent segons l'Agència Tributària per obtindre el pressupost per contrata. Per al present TFG, deu aplicar-se el tipus d'IVA general, que correspon a un 21%.

2. QUADRE DE MÀ D'OBRA

Num.	Codi	Denominació de la mà d'obra	Preu	Hores	Total
1	MO.RAD	Radiòleg	51,170	20,000 h	1.023,40
2	MO.TUT	Tutor de l'alumne encarregat de supervisar el treball	36,550	15,000 h	548,29
3	MO.COT	Cotutor de l'alumne encarregat de supervisar el treball	29,240	15,000 h	438,60
4	MO.INS	Enginyer sènior	21,930	60,000 h	1.315,80
5	MO.ING	Enginyer biomèdic	14,620	385,500 h	5.636,01
Total mà d'obra:					8.962,10

3. QUADRE DE MATERIALS

Num.	Codi	Denominació del material	Preu	Quantitat	Total
1	MA.MAT	Matlab 2020a	200,000	1,000 u	200,00
2	MA.PC	Ordinador portàtil HP 15S-FQ1125NS Intel Core i5-1035G1/8GB RAM/512GB SSD/15.6"	55,000	1,000 u	55,00
3	MA.MO19	Microsoft Office Home 2019	29,900	1,000 u	29,90
4	MA.AWS	Programa utilitzat per a segmentar	27,900	55,000 h	1.534,50
Total materials:					1.819,40

4. QUADRE DE PREUS UNITARIS

Nº	Designació	Import	
		En xifra (Euros)	En lletra (Euros)
	1 Planificació i avaluació del projecte		
1.1	u Reunio inicial	120,62	CENT VINT EUROS AMB SEIXANTA-DOS CÈNTIMS
1.2	u Reunions periòdiques de avaluació	120,62	CENT VINT EUROS AMB SEIXANTA-DOS CÈNTIMS
	2 Segmentacions		
2.1	u Aprenentatge	365,50	TRES-CENTS SEIXANTA-CINC EUROS AMB CINQUANTA CÈNTIMS
2.2	u Segmentació	767,55	SET-CENTS SEIXANTA-SET EUROS AMB CINQUANTA-CINC CÈNTIMS
2.3	u Segmentacions	2.740,65	DOS MIL SET-CENTS QUARANTA EUROS AMB SEIXANTA-CINC CÈNTIMS
	3 Programació del software		
3.1	u Instal·lació dels diferents programes necessaris	321,45	TRES-CENTS VINT-I-U EUROS AMB QUARANTA-CINC CÈNTIMS
3.2	h Programació mòdul preparació de fitxers	14,62	CATORZE EUROS AMB SEIXANTA-DOS CÈNTIMS
3.3	h Programació mòdul extracció de característiques	14,62	CATORZE EUROS AMB SEIXANTA-DOS CÈNTIMS
3.4	h Programació mòdul anàlisi de característiques	14,62	CATORZE EUROS AMB SEIXANTA-DOS CÈNTIMS
3.5	u Avaluacions del codi	43,86	QUARANTA-TRES EUROS AMB VUITANTA-SIS CÈNTIMS
	4 Obtenció i anàlisi dels resultats		
4.1	h Estudi A	14,62	CATORZE EUROS AMB SEIXANTA-DOS CÈNTIMS
4.2	h Estudi B	14,62	CATORZE EUROS AMB SEIXANTA-DOS CÈNTIMS
4.3	h Estudi C	14,62	CATORZE EUROS AMB SEIXANTA-DOS CÈNTIMS
	5 Redacció i defensa del TFG		
5.1	u Redacció del projecte	1.315,80	MIL TRES-CENTS QUINZE EUROS AMB VUITANTA CÈNTIMS
5.2	u Revisió i correcció del TFG	314,33	TRES-CENTS CATORZE EUROS AMB TRENTA-TRES CÈNTIMS
5.3	u Preparació de la defensa	438,60	QUATRE-CENTS TRENTA-VUIT EUROS AMB SEIXANTA CÈNTIMS

5. QUADRE DE PREUS DESCOMPOSTOS

Nº	Codi	Ud	Descripció		Total
1 Planificació i avaluació del projecte					
1.1		u	Reunio inicial		
	MO.ING	1,500 h	Enginyer biomèdic	14,620	21,93
	MO.TUT	1,500 h	Tutor	36,550	54,83
	MO.COT	1,500 h	Cotutor	29,240	43,86
			Preu total per u .		120,62
1.2		u	Reunions periòdiques de avaluació		
	MO.ING	1,500 h	Enginyer biomèdic	14,620	21,93
	MO.COT	1,500 h	Cotutor	29,240	43,86
	MO.TUT	1,500 h	Tutor	36,550	54,83
			Preu total per u .		120,62
2 Segmentacions					
2.1		u	Aprentatge		
	MO.INS	5,000 h	Enginyer sènior	21,930	109,65
	MO.RAD	5,000 h	Radiòleg	51,170	255,85
			Preu total per u .		365,50
2.2		u	Segmentació		
	MO.RAD	15,000 h	Radiòleg	51,170	767,55
			Preu total per u .		767,55
2.3		u	Segmentacions		
	MO.INS	55,000 h	Enginyer sènior	21,930	1.206,15
	MA.AWS	55,000 h	AW Server GE	27,900	1.534,50
			Preu total per u .		2.740,65
3 Programació del software					
3.1		u	Instal·lació dels diferents programes necessaris		
	MO.ING	2,500 h	Enginyer biomèdic	14,620	36,55
	MA.MO19	1,000 u	Microsoft Office Home 2019	29,900	29,90
	MA.PC	1,000 u	Ordinador portàtil HP 15S-FQ1125NS Intel Core i5-1035G1/8GB RAM/512GB SSD/15.6"	55,000	55,00
	MA.MAT	1,000 u	Matlab 2020a	200,000	200,00
			Preu total per u .		321,45
3.2		h	Programació mòdul preparació de fitxers		
	MO.ING	1,000 h	Enginyer biomèdic	14,620	14,62
			Preu total per h .		14,62
3.3		h	Programació mòdul extracció de característiques		
	MO.ING	1,000 h	Enginyer biomèdic	14,620	14,62
			Preu total per h .		14,62
3.4		h	Programació mòdul anàlisi de característiques		
	MO.ING	1,000 h	Enginyer biomèdic	14,620	14,62
			Preu total per h .		14,62

DISSENY D'UNA APROXIMACIÓ BASADA EN RADIÒMICA PER A UNA CLASSIFICACIÓ DE TUMORS DE PRÒSTATA MITJANÇANT ANÀLISI DE TEXTURES EN IMATGES DE RESSONÀNCIA MAGNÈTICA

3.5	u	Avaluacions del codi				
MO.ING		3,000 h	Enginyer biomèdic	14,620	43,86	
			Preu total per u .		43,86	
4 Obtenció i anàlisi dels resultats						
4.1	h	Estudi A				
MO.ING		1,000 h	Enginyer biomèdic	14,620	14,62	
			Preu total per h .		14,62	
4.2	h	Estudi B				
MO.ING		1,000 h	Enginyer biomèdic	14,620	14,62	
			Preu total per h .		14,62	
4.3	h	Estudi C				
MO.ING		1,000 h	Enginyer biomèdic	14,620	14,62	
			Preu total per h .		14,62	
5 Redacció i defensa del TFG						
5.1	u	Redacció del projecte				
MO.ING		90,000 h	Enginyer biomèdic	14,620	1.315,80	
			Preu total per u .		1.315,80	
5.2	u	Revisió i correcció del TFG				
MO.ING		8,000 h	Enginyer biomèdic	14,620	116,96	
MO.TUT		3,000 h	Tutor	36,550	109,65	
MO.COT		3,000 h	Cotutor	29,240	87,72	
			Preu total per u .		314,33	
5.3	u	Preparació de la defensa				
MO.ING		30,000 h	Enginyer biomèdic	14,620	438,60	
			Preu total per u .		438,60	

6. QUADRE DE PREUS PARCIALS

Capítol nº 1 Planificació i avaluació del projecte

Nº	U	Descripció	Amidament	Preu	Import
1.1.	U	Reunio inicial			
			Total u :	1,000	120,62
1.2.	U	Reunions periòdiques de avaluació			
			Total u :	7,000	120,62
Parcial nº 1 Planificació i avaluació del projecte :					964,96

Capítol nº 2 Segmentacions

Nº	U	Descripció	Amidament	Preu	Import
2.1.	U	Aprenentatge			
			Total u :	1,000	365,50
2.2.	U	Segmentació			
			Total u :	1,000	767,55
2.3.	U	Segmentacions			
			Total u :	1,000	2.740,65

Parcial nº 2 Segmentacions : 3.873,70

Capítol nº 3 Programació del software

Nº	U	Descripció	Amidament	Preu	Import
3.1.	U	Instal·lació dels diferents programes necessaris			
		Total u :	1,000	321,45	321,45
3.2.	H	Programació mòdul preparació de fitxers			
		Total h :	15,000	14,62	219,30
3.3.	H	Programació mòdul extracció de característiques			
		Total h :	10,000	14,62	146,20
3.4.	H	Programació mòdul anàlisi de característiques			
		Total h :	100,000	14,62	1.462,00
3.5.	U	Avaluacions del codi			
		Total u :	6,000	43,86	263,16
Parcial nº 3 Programació del software :					2.412,11

Capítol nº 4 Obtenció i anàlisi dels resultats

Nº	U	Descripció	Amidament	Preu	Import
4.1.	H	Estudi A			
		Total h :	30,000	14,62	438,60
4.2.	H	Estudi B			
		Total h :	35,000	14,62	511,70
4.3.	H	Estudi C			
		Total h :	35,000	14,62	511,70
Parcial nº 4 Obtenció i anàlisi dels resultats :					1.462,00

Capítol nº 5 Redacció i defensa del TFG

Nº	U	Descripció	Amidament	Preu	Import
5.1.	U	Redacció del projecte			
		Total u :	1,000	1.315,80	1.315,80
5.2.	U	Revisió i correcció del TFG			
		Total u :	1,000	314,33	314,33
5.3.	U	Preparació de la defensa			
		Total u :	1,000	438,60	438,60
Parcial nº 5 Redacció i defensa del TFG :					2.068,73

7. PRESSUPOST D'EXECUCIÓ PER CONTRATA

Capítol	Import
Capítol 1 Planificació i avaluació del projecte	964,96
Capítol 2 Segmentacions	3.873,70
Capítol 3 Programació del software	2.412,11
Capítol 4 Obtenció i anàlisi dels resultats	1.462,00
Capítol 5 Redacció i defensa del TFG	2.068,73
Pressupost d'execució material	10.781,50
13% de despeses generals	1.401,60
6% de benefici industrial	646,89
Suma	12.829,99
21% IVA	2.694,30
Pressupost d'execució per contracta	15.524,29

Puja el pressupost d'execució per contracta a l'expressada quantitat de **QUINZE MIL CINCCENTS VINT-I-QUATRE EUROS AMB VINT-I-NOU CÈNTIMS**.