

Miokardo tekstūros klasterizavimas širdies MRT vaizduose: radiomikos ir klinikinių rodiklių sąsajos

Arina Peržu¹, Žygimantas Abramikas², Sigita Glaveckaitė²,
Giedrė Balčiūnaitė², Nomedą Rima Valevičienė³,
Darius Palionis³, Povilas Treigys¹, Jolita Bernatavičienė¹

¹ Vilniaus universitetas, Matematikos ir informatikos fakultetas, Vilnius
arina.tichonovskaja@mif.stud.vu.lt

² Vilniaus universitetas, Medicinos fakultetas, Klinikinės medicinos institutas,
Širdies ir kraujagyslių ligų klinika, Vilnius

³ Vilniaus universitetas, Vilniaus universiteto ligoninė Santaros klinikos, Vilnius

Santrauka. Širdies magnetinio rezonanso tomografija (MRT) leidžia įvertinti miokardo struktūrinius ir funkcinis pokyčius. Šiame tyrime nagrinėjama radiomikos pagrindu atliekama tekstūros analizė, skirta įvertinti miokardo pažeidimo lygį esant didelio laipsnio aortos vožtuvo stenozai. Iš 87 tiriamųjų MRT vaizdų išgauti tekstūros požymiai buvo agreguoti per visą širdies ciklą ir naudoti klasifikavimo bei klasterizavimo užduotims. Nustatyta, kad globali miokardo reprezentacija leidžia efektyviai atskirti sveiką ir pataloginį miokardą. Klasterinė analizė atskleidė skirtingus miokardo fenotipus, susijusius su reikšmingais globalios išilginės deformacijos (GLS) ir T1 rodiklių skirtumais, tuo tarpu ECV ir CVF reikšmingai nesiskyrė. Rezultatai rodo, kad radiomika gali suteikti papildomos informacijos apie miokardo būklę, nepriklausomai nuo tradicinių klinikinių rodiklių.

Raktiniai žodžiai: širdies MRT, radiomika, tekstūros analizė, aortos vožtuvo stenozė, klasterizavimas.

1 Įvadas

Tekstūros analizė vaizdų apdorojime yra svarbus metodas, leidžiantis kiekybiškai aprašyti objektų paviršiaus dėsninumus ir intensyvumo pasiskirstymą. Ji plačiai taikoma nuo medicininės diagnostikos iki objektų atpažinimo sistemų [1], kadangi leidžia sudėtingas vizualines struktūras paversti objektyviais skaitmeniniais rodikliais, tinkamais statistinei analizei ir automatizuotam sprendimų priėmimui.

Tekstūros dėsninumams aprašyti sukurta įvairių metodų. Plačiai taikomos pilkumo lygių gretinumo (angl. *Gray-Level Co-occurrence Matrix*, GLCM)


ir eilučių ilgių matricos (angl. *Gray-Level Run Length Matrix*, GLRLM), analizuojančios erdvinius pikselių ryšius [2]. Kiti metodai, pavyzdžiui, lokalieji dvejetainiai šablonai (angl. *Local Binary Patterns*, LBP), aprašo tekstūrą pagal lokalių elementų išsidėstymą [3]. Be to, naudojami modeliais pagrįsti (autoregresiniai, fraktaliniai) ir transformacijomis pagrįsti metodai (Furjė, bangelių, Gaboro), leidžiantys analizuoti tekstūrą dažnių srityje ir išgauti skirtingų mastelių bei orientacijų požymius [2, 4].

Pastarojo meto mašininio ir giliojo mokymosi pasiekimai reikšmingai paspartino tekstūros analizę. Konvoliuciniai neuroniniai tinklai (angl. *Convolutional Neural Networks*, CNN) leidžia automatiškai išgauti požymius iš medicininių vaizdų [5], tačiau jų taikymą riboja didelių anotuočių duomenų rinkinių ir skaičiavimo išteklių poreikis. Šiai problemai spręsti taikomi duomenų papildymo metodai – nuo geometrinių transformacijų [6] iki generatyvinių modelių [7, 8], o rankiniu būdu suformuoti tekstūros požymiai (angl. *handcrafted features*), derinami su klasikiniais klasifikatoriais, išlieka aktualūs. Širdies MRT yra pagrindinis metodas vertinant miokardo struktūrą ir nustatant fibrozę, susijusią su blogesne paciento prognoze [9], todėl automatizuoti analizės metodai, tokie kaip tekstūros analizė, yra svarbūs siekiant sumažinti analizės laiką ir klaidų tikimybę klinikinėje praktikoje [10]. Ateityje vis didesnę reikšmę įgis daugiaryšiai pamatiniai modeliai (angl. *multimodal foundation models*), leidžiantys integruoti vaizdinius bei klinikiškus duomenis ir taip pagerinti tekstūros požymių interpretaciją [11].

Šiame tyrime tekstūros požymių išskyrimas taikomas širdies MRT vaizdams, siekiant nustatyti informatyviausius požymius tolesnei analizei. Šie požymiai naudojami kaip įvesties duomenys tiek klasifikavimo, tiek klasterizavimo užduotims. Klasifikavimo dalis skirta patologinėms būklėms atskirti, o klasterizavimo analizė tiria, ar tekstūros natūraliai grupuojasi pagal miokardo pažeidimo sunkumą. Be to, tyrime nagrinėjama, ar šios neprižiūrimo mokymosi grupės sutampa su nustatytais klinikiniais rodikliais. Pagrindinis šio tyrimo tikslas yra įvertinti ryšį tarp radiomikos tekstūra pagrįsto klasterizavimo ir miokardo pažeidimo laipsnio.

2 Metodologija ir duomenų imtis

Pilna tyrimo eiga matoma 1-ame paveikslėlyje.



1 pav. Širdies MRT tekstūros analizės darbo eiga [15].

2.1 Tyrimo duomenų imties aprašymas

Tyrimo duomenų rinkinį sudarė 87 tiriamieji: 74 pacientai, sergantys didelio laipsnio aortos vožtuvo stenozės sąlygota miokardo patologija, ir 13 sveikų kontrolinės grupės asmenų. Visiems tiriamiesiems atlikta širdies magnetinio rezonanso tomografija, kurios metu gauti 8–14 trumposios ašies pjūviai, segmentuoti į bazinį, vidurinį ir apikalinį regionus bei suskirstyti į 25 širdies ciklo fazes. Analizė buvo sutelkta į miokardą.

Daliai pacientų buvo prieinami klinikiniai rodikliai: h_CVF , m_Nat T1, m_ECV ir e_GLS , apibūdinantys atitinkamai fibrozę, audinio pažeidimą, ekstraląstelinio tūrio pokyčius ir miokardo funkciją. Šie rodikliai, parinkti bendradarbiaujant su kardiologais, naudoti klasterizavimo rezultatų interpretacijai. Visi klinikiniai duomenys buvo prieinami 49 pacientams.

Tekstūros analizė buvo atlikta skirtinguose miokardo regionuose bei širdies ciklo fazėse, siekiant įvertinti erdvinį ir laikinį kintamumą. MRT vaizdai buvo iš anksto apdoroti (konvertuoti į pilkumo skalę ir normalizuoti), o požymiai ištraukti iš trijų anatominių regionų (bazinio, vidurinio ir apikalinio) bei viso miokardo. Siekiant gauti bendrą charakteristiką, požymiai buvo agreguoti per visas 25 fazes, apskaičiuojant jų vidurkius.

Radiomikos požymių išgavimo procesas buvo automatizuotas naudojant „Python“ programavimo kalbą (v. 3.13.0). Požymių išgavimui naudotos „Scikit-image“ (LBP, HOG, GLCM), „PyRadiomics“ (GLRLM), „PyWavelets“ (bangelių transformacija) bei „NumPy“ (Furjė ir fraktalinė analizė) bibliotekos. Duomenų valdymui ir rezultatų agregavimui pasitelkta Pandas biblioteka.

2.2 Statistinė analizė ir požymių atranka

Statistinė analizė ir požymių atranka atlikta naudojant „R“ programinę įrangą (v. 4.4.2). Pirmiausia buvo taikyta vienmatė analizė: Stjudento t testas arba Mano–Vitnio U (angl. *Mann–Whitney U*) statistika, priklausomai nuo duomenų normalumo. Tolesnei analizei atrinkti požymiai, kurių $p < 0,01$. Požymių svarba vertinta naudojant atsitiktinių miškų (Gini indeksą), LASSO regresiją ir vienmatę analizę [12], o tarpusavio priklausomybei mažinti atlikta Spirmeno (angl. *Spearman*) koreliacijos analizė, pašalinant stipriai koreliuojančius požymius ($|p| > 0,8$).

Atrinktų požymių pažeisto geba atskirti pažeistą miokardą nuo sveiko buvo vertinama taikant kelis klasifikavimo metodus: atsitiktinių miškų, atra-

minių vektorių, k artimiausių kaimynų ir naiviojo Bajeso [2]. Modeliai buvo vertinami naudojant kryžminę validaciją ($k = 5$) pagal AUC ir subalansuotą tikslumą. Pacientų grupavimas atliktas taikant hierarchinį klasterizavimą, o optimalus klasterių skaičius nustatytas „alkūnės“ (angl. *elbow*) ir „silueto“ (angl. *silhouette*) metodais. Rezultatų vizualizavimui naudotas UMAP, o skirtumai tarp klasterių vertinti Kruskalo–Voliso (angl. *Kruskal–Wallis*) kriterijumi ($p < 0,01$). Klasterių klinikinė reikšmė įvertinta analizuojant jų sąsajas su miokardo rodikliais.

3 Tyrimo rezultatai

3.1 Bendros imties klasterizavimas

Klasifikavimo rezultatai buvo vertinti skirtinguose anatominuose regionuose ir širdies ciklo fazėse. Didžiausias gebėjimas atskirti sveiką ir patologinį miokardą pasiektas naudojant globalią miokardo struktūrą bei agreguojant požymius per 25 fazes, todėl ji pasirinkta tolesnei analizei. Atrinkti tekstūros požymiai ir jų interpretacija pateikiami 1 lentelėje.

1 lentelė. Analizuojamų radiomikos tekstūros požymių interpretacija.

Tekstūros požymis	Interpretacija (didesnės reikšmės)
Fourier energija (F_En)	Didesnis struktūrinis nelygumas
GLCM koreliacija (GLCM_Cor)	Tolygesnė miokardo tekstūra
GLRLM LRHGE	Stambesnės heterogeniškos audinio sritys
GLRLM sekų entropija (GLRLM_RE)	Didesnis tekstūros heterogeniškumas
GLRLM sekų ilgio nevienodumas (GLRLM_RLNUN)	Didesnė regionų dydžių variacija
LBP kontrastas (LBP_Con)	Didesni lokalūs intensyvumo skirtumai

Klasterinė analizė, atlikta naudojant informatyviausius tekstūros požymius iš globalios miokardo reprezentacijos, išskyrė penkis klasterius (vidutinis silueto rodiklis = 0,298). 1-ąjį klasterį sudarė beveik visi sveiki tiriamieji (12 sveikų asmenų ir 1 pacientas su patologija), o nuo 2-ojo iki 5-ojo klasterio grupavosi pacientai su miokardo patologija (atitinkamai $n = 3, 23, 23$ ir 25). Ketvirtame klasteryje buvo aptiktas vienas sveikas tiriamasis. Toks pasiskirstymas rodo, kad radiomikos pagrindu atlikta klasterinė analizė leidžia identifikuoti skirtingus miokardo tekstūros fenotipus be iš anksto apibrėžtų klasių, o ne tik atlikti griežtą binarinį sveiko ir patologinio miokardo atskyrimą.

Klinikinė analizė parodė statistiškai reikšmingus skirtumus tarp klasterių pagal e_GLS ir $m_Nat\ T1$ ($p < 0,05$), nors $T1$ skirtumai buvo mažiau ryškūs. Tuo tarpu reikšmingų skirtumų nenustatyta pagal m_ECV ($p = 0,604$) ir h_CVF ($p = 0,349$) metrikas.

3.2 Pacientų su patologija klasterizavimas ir klasterių stabilumo vertinimas


Atliekant klasterizavimą patologiją turintiems pacientams su visu medicininių metrikų rinkiniu, optimalus klasterių skaičius pagal tekstūros požymius buvo nustatytas remiantis „silueto“ (angl. *silhouette*) koeficientu. Jis leidžia įvertinti klasterių vidinį kompaktiškumą ir jų tarpusavio atsiskyrimą. Analizė parodė, kad 49 tiriamieji susigrupuoja pagal tekstūros požymius į keturis klasterius (vidutinis silueto koeficientas = 0,305), todėl šis klasterių skaičius buvo pasirinktas tolesnei analizei. Taip pat tirta, ar pacientai panašiai susigrupuoja pagal atrinktas medicinines metrikas. Nustatyta, kad naudojant keturis klasterius vidutinis silueto koeficientas siekė 0,218 – tai parodo silpną klasterių tarpusavio atsiskyrimą. Palyginus pacientų grupavimą su pradiniais rezultatais (gautais įtraukiant ir sveikus asmenis), nustatyta, kad tekstūros požymiais pagrįsti klasteriai išlieka stabilūs. Šį stabilumą patvirtina išorinės validacijos metrikos: koreguotasis Rando (angl. *Adjusted Rand*) indeksas ($ARI=0,456$), kuris patikimai įvertina struktūrinį panašumą koreguodamas rezultatą dėl atsitiktinio sutapimo tikimybės, bei normalizuotas tarpusavio informacijos indeksas ($NMI=0,600$), matuojantis informacinio turinio pasidalijimą tarp klasterių. Šių dviejų papildančių rodiklių derinys leidžia pagrįsti klasterizavimo rezultatų sutapimą [13, 14].

UMAP projekcijoje (žr. 2 pav.) dauguma pacientų sudarė pakankamai aiškiai atsiskiriančius tekstūros klasterius, tačiau keli taškai buvo išsidėstę klasterių ribose – tai galėtų signalizuoti apie pereinamosios miokardo struktūros būklę.

Siekiant įvertinti, ar medicininiai rodikliai skiriasi tarp tekstūros klasterių, buvo taikytas Kruskalo–Voliso (angl. *Kruskal–Wallis*) testas. Nustatyta, kad tarp klasterių statistiškai reikšmingai skiriasi tik e_GLS reikšmės ($p < 0,05$; $\varepsilon^2 = 0,325$). Post-hoc Dunno analizė parodė, kad statistiškai reikšmingi e_GLS skirtumai nustatyti tarp 1-ojo ir 2-ojo klasterių bei 1-ojo ir 3-iojo klasterių. Tuo tarpu kitų klasterių porų palyginimuose statistiškai reikšmingų skirtumų nenustatyta.

Klasterizavimas remiantis hierarchiniu metodu

Vizualizavimas: UMAP (n_neighbors = 10, min_dist = 0.01, Euklido atstumas)



2 pav. Radiomikos pagrindu gautų klasterių vizualizacija patologiją turinčių pacientų kohortoje (n=49).

Tyrimo metu vertinta, ar medicininių rodiklių pasiskirstymas tarp tekstūros klasterių skiriasi priklausomai nuo lyties. Analizuojamoje imtyje yra 20 vyrų ir 29 moterys. Vyrų pogrupyje statistiškai reikšmingų medicininių metrikų skirtumų tarp tekstūros klasterių nenustatyta. Tuo tarpu moterų pogrupyje nustatyti reikšmingi skirtumai pagal e_GLS rodiklį tarp 1-ojo ir 2-ojo klasterių bei tarp 1-ojo ir 3-iojo klasterių ($p < 0,05$). Taip pat nustatytas statistiškai reikšmingas skirtumas tarp 1-ojo ir 4-ojo klasterių pagal T1 rodiklį ($p < 0,05$).

Pereinant prie klinikinės interpretacijos h_CVF normos ribos yra 0,1–4,0 %, o didesnės reikšmės rodo didesnį miokardo fibrozės paplitimą. e_GLS norma laikoma $\leq -20,0$ %, o mažiau neigiamos reikšmės siejamos su funkcijos sutrikimu. Orientacinės m_Nat T1 normos yra apie $956,0 \pm 59,0$ ms (vyrams $978,0 \pm 67,0$, moterims $931,0 \pm 38,0$), o m_ECV – apie $24,0 \pm 3,0$ % (vyrams $26,0 \pm 3,0$, moterims $22,0 \pm 1,0$, didesnės reikšmės atspindi padidėjusią ekstraląstelinio tūrio frakciją).

Kaip matyti 2 lentelėje, tekstūros pagrindu identifikuoti klasteriai atspindi skirtingus miokardo funkcijos ir struktūrinių pokyčių profilius. Didžiausi skirtumai nustatyti pagal e_GLS , tuo tarpu h_CVF visose grupėse išlieka padidėjęs, o m_Nat T1 ir m_ECV variacija tarp klasterių yra santykinai mažesnė.

2 lentelė. Klinikinių rodiklių pasiskirstymas tekstūros klasteriuose pagal lytį.

Klas- teris	Grupė	e_GLS	m_Nat T1 (ms)	m_ECV (%)	h_CVF (%)
1	Bendra	-20,5 ± 1,8	936,0 ± 22,0	23,0 ± 1,5	11,8 ± 6,5
2	Bendra	-13,9 ± 3,1	980,0 ± 23,0	24,2 ± 1,5	10,1 ± 5,3
3	Bendra	-15,6 ± 2,9	958,0 ± 21,5	22,6 ± 1,1	13,6 ± 8,0
4	Bendra	-19,5 ± 4,0	967,0 ± 24,0	23,9 ± 1,6	13,0 ± 8,0
1	Vyrai	-20,3 ± 1,8	962,0 ± 20,0	23,1 ± 3,0	11,2 ± 5,6
2	Vyrai	-13,9 ± 1,8	995,0 ± 15,0	24,2 ± 1,4	8,3 ± 1,8
3	Vyrai	-17,4 ± 3,5	948,0 ± 30,5	21,5 ± 1,2	16,9 ± 7,0
4	Vyrai	-19,5 ± 2,4	956,0 ± 11,0	24,1 ± 0,7	16,3 ± 12,1
1	Moterys	-20,7 ± 1,7	929,0 ± 19,0	23,0 ± 1,2	12,0 ± 8,8
2	Moterys	-13,4 ± 3,7	968,0 ± 15,5	23,5 ± 2,1	16,2 ± 9,4
3	Moterys	-14,0 ± 1,1	966,0 ± 10,0	24,0 ± 1,6	13,6 ± 6,0
4	Moterys	-17,8 ± 2,9	1012,0 ± 31,0	22,5 ± 2,7	13,0 ± 2,5

* Lentelėje pateikiamos reikšmės: mediana ± absoliutinis medianinis nuokrypis


** Spalvų žymėjimas: žalia – reikšmės normos intervale, žydra – nedidelis nuokrypis nuo normos, mėlyna – didelis nuokrypis nuo normos.

1-asis klasteris pasižymi palankiausiu profiliu: e_GLS artimas normai (-20,5), m_Nat T1 ir m_ECV yra normos ribose, tačiau h_CVF padidėjęs ($\approx 11,8\%$) – tai rodo išsaugotą funkciją esant ankstyviems struktūriniais pokyčiams. 2-asis klasteris išsiskiria ryškiausiu funkcinio sutrikimu (e_GLS = -13,9) ir padidėjusiu m_Nat T1 (≈ 980 ms), leidžiančiu įtarti pažengusius pokyčius. 3-asis klasteris atspindi tarpinį fenotipą (e_GLS = -15,6), kai funkcijos sutrikimas jau ryškus, tačiau m_Nat T1 ir m_ECV pokyčiai mažiau išreikšti. 4-asis klasteris pasižymi santykinai išsaugota funkcija e_GLS tačiau didesnėmis m_Nat T1, m_ECV ir h_CVF reikšmėmis – tai rodo struktūrinių pokyčių dominavimą.

Analizuojant klasterius pagal lytį, bendros tendencijos išlieka. Vyrams 2-asis klasteris siejasi su ryškiausiais T1 pokyčiais (≈ 995 ms), o moterims 4-asis klasteris išsiskiria didžiausiomis T1 reikšmėmis (≈ 1012 ms), kartu išlaikant santykinai geresnę funkciją. 1-asis klasteris abiejose grupėse išlieka palankiausias.

Apibendrinant, klasteriai atspindi skirtingus miokardo fibrozės fenotipus: nuo išsaugotos funkcijos (1 klasteris) iki funkcijos sutrikimo dominuo-

jamų (2 ir 3 klasteriai) bei struktūrinių pokyčių dominavimo (4-asis klasteris). Visuose klasteriuose nustatytas padidėjęs h_CVF rodo, kad fibrozės požymiai būdingi visoms grupėms, o pagrindiniai skirtumai susiję su funkcinių ir struktūrinių pakitimų santykiu. Šią interpretaciją papildė nuokrypių nuo normos analizė (3 pav.), rodanti, kad didžiausi skirtumai tarp klasterių stebimi e_GLS ir h_CVF rodikliuose: 2-ajame klasteryje dominuoja funkcinis nuokrypis, o 3–4 klasteriuose – struktūriniai pokyčiai.



3 pav. Medianinis nuokrypis nuo normos, pateikiama mediana ir absoliutinis medianos nuokrypis.

4 Išvados

Šio tyrimo rezultatai rodo, kad radiomikos pagrindu išgauti tekstūros požymiai atskleidžia miokardo struktūros ir funkcijos pokyčius, kurie ne visada aiškiai matomi taikant tradicinius klinikinius rodiklius. Nustatytos tendencijos leidžia manyti, kad šie požymiai gali būti naudojami sveikam ir patologiniam miokardui atskirti bei skirtingiems miokardo pažeidimo fenotipams identifikuoti.

Klasterinė analizė parodė, kad didžiausi skirtumai tarp klasterių siejasi su e_GLS ir m_Nat T1 rodikliais – tai rodo tekstūros analizės jautrumą tiek funkciniais, tiek ankstyviems struktūriniams pokyčiams. Tuo tarpu reikšmingų skirtumų pagal m_ECV ir h_CVF nenustatyta. Tai gali rodyti, jog šie globalūs rodikliai ne visuomet atspindi smulkesnę miokardo heterogeniškumo struktūrą, kurią geba užfiksuoti radiomikos metodai. Tačiau, ribotas sutapimas tarp tekstūros požymių ir klinikiniais rodikliais pagrįsto grupavimo leidžia teigti, kad radiomika suteikia papildomos, iš dalies nepriklausomos informacijos apie miokardo būklę.

Vis dėlto gauti rezultatai turėtų būti vertinami atsargiai dėl ribotos imties ir nepilnų klinikinių duomenų daliai pacientų. Siekiant padaryti patikimesnes ir apibendrinamas išvadas, būtina atlikti tolesnius tyrimus su didesne pacientų imtimi bei integruoti radiomikos požymius su klinikiniais ir kitais duomenimis.

Padėkos

Šio tyrimo finansavimą skyrė Lietuvos mokslo taryba pagal Lietuvos Respublikos švietimo, mokslo ir sporto ministerijos programą „Universitetų ekselencijos iniciatyvos“ (priemonė Nr. 12 -001-01-01-01 „Mokslo ir studijų aplinkos gerinimas“), projektas Nr. S-A-UEI-23-11. Tyrimas patvirtintas biomedicininų tyrimų etikos komiteto (leidimo Nr. 2025/5-1665-1119, išduotas 2025 m. gegužės 12 d.).

Literatūra

- [1] Ghalati, M. K., Nunes, A., Ferreira, H., Serranho, P., & Bernardes, R. (2021). Texture analysis and its applications in biomedical imaging: A survey. *IEEE Reviews in Biomedical Engineering*, 15, 222-246.
- [2] Bėbas, E., Borowska, M., Derlatka, M., Oczeretko, E., Hładuński, M., Szumowski, P., & Mojsak, M. (2021). Machine-learning-based classification of the histological subtype of non-small-cell lung cancer using MRI texture analysis. *Biomedical Signal Processing and Control*, 66, 102446.
- [3] Materka, A. (2004). Texture analysis methodologies for magnetic resonance imaging. *Dialogues in clinical neuroscience*, 6(2), 243-250.
- [4] Li, Q., Zhang, W., Wu, Z., Dai, Y., & Liu, Y. (2024). An efficient multi-level 2D DWT architecture for parallel tile block processing with integrated quantization modules. *Electronics*, 13(23), 4668.
- [5] Goyal, V., & Sharma, S. (2023). Texture classification for visual data using transfer learning. *Multimedia Tools and Applications*, 82(16), 24841-24864.
- [6] Liu, D., Yan, Z., Chang, Q., Axel, L., & Metaxas, D. N. (2021, September). Refined deep layer aggregation for multi-disease, multi-view & multi-center cardiac mr segmentation. In *International Workshop on Statistical Atlases and Computational Models of the Heart* (pp. 315-322). Cham: Springer International Publishing.
- [7] Al Khalil, Y., Amirrajab, S., Lorenz, C., Weese, J., Pluim, J., & Breeuwer, M. (2023). Reducing segmentation failures in cardiac MRI via late feature fusion and GAN-based augmentation. *Computers in Biology and Medicine*, 161, 106973.
- [8] Lustermaans, D. R., Amirrajab, S., Veta, M., Breeuwer, M., & Scannell, C. M. (2022). Optimized automated cardiac MR scar quantification with GAN-based data augmentation. *Computer methods and programs in biomedicine*, 226, 107116.
- [9] Balčiūnaitė, G., Besusparis, J., Palionis, D., Žurauskas, E., Skorniakov, V., Janušauskas, V., ... & Glaveckaitė, S. (2022). Exploring myocardial fibrosis in severe aortic stenosis: echo,

CMR and histology data from FIB-AS study. *The International Journal of Cardiovascular Imaging*, 38(7), 1555-1568.

- [10] Sauer, S. T., Christner, S. A., Lois, A. M., Woznicki, P., Curtaz, C., Kunz, A. S., ... & Grunz, J. P. (2024). Deep learning k-space-to-image reconstruction facilitates high spatial resolution and scan time reduction in diffusion-weighted imaging breast MRI. *Journal of Magnetic Resonance Imaging*, 60(3), 1190-1200.
- [11] Zhang, Y., Hager, P., Liu, C., Shit, S., Chen, C., Rueckert, D., & Pan, J. (2025). Towards cardiac MRI foundation models: Comprehensive visual-tabular representations for whole-heart assessment and beyond. *Medical Image Analysis*, 103756.
- [12] Abellana, D. P. M., & Lao, D. M. (2023). A new univariate feature selection algorithm based on the best-worst multi-attribute decision-making method. *Decision Analytics Journal*, 7, 100240.
- [13] Shilpa, S., Shailaja, K. P., & Nischitha, S. G. (2025). External clustering validation using ARI, NMI and FMI. In *ITM Web of Conferences* (Vol. 79, p. 01004). EDP Sciences.
- [14] Li, A., Meng, Y., & Wang, P. (2024). Similarity-based three-way clustering by using dimensionality reduction. *Mathematics*, 12(13), 1951
- [15] Peržu, A., Abramikas, Ž., Glaveckaitė, S., Balčiūnaitė, G., Valevičienė, N. R., Palionis, D., Treigys, P., & Bernatavičienė, J. (2026). Characterization of myocardial structural heterogeneity using radiomic texture features and clinical biomarkers [Accepted for publication]. *The 13th Open International Conference on Electrical, Electronic and Information Sciences (eStream 2026)*.