



# Mašininio mokymosi ir funkcinių duomenų analizės metodų vystymas prostatos daugiafunkcinių MRT vaizdų analizėje

Doktorantas: Roman Surkant

Vadovas: Dr. Jolita Bernatavičienė

Mokslo kryptis: N009 Informatika

Studijų laikotarpis: 2022–2026 m.

Studijų metai: 2025/2026



# Tyrimo objektas, tikslas

- Tyrimo objektas: magnetinio rezonanso tomografijos dinaminio kontrasto sustiprinimo (MRI Dynamic Contrast Enhancement) vaizdų sekos
- Tyrimo tikslas: nustatyti vėžinės zonos aptikimo galimybes naudojantis mašininio mokymosi ir funkcinių duomenų analizės metodais.

# Tyrimo uždaviniai

- Atlikti mašininio mokymosi ir funkcinių duomenų analizės analitinę apžvalgą
- Identifikuoti mokslines problemas, aktualias šitam tyrimui
- Sukurti naują arba patobulinti esamus vėžio aptikimo prostatoje metodus, kuriuose taikoma MRI dinaminio kontrasto sustiprinimo vaizdų analizė

# Visų studijų planas ir jo vykdymo suvestinė

| Studijų metai          | Egzaminai |          |
|------------------------|-----------|----------|
|                        | Planas    | Įvykdyta |
| I (2022/2023)          | 2         | 2        |
| II (2023/2024)         | 2         | 2        |
| <b>III (2024/2025)</b> |           |          |
| IV (2025/2026)         |           |          |
| Iš viso:               | 4         | 4        |

Bendrųjų gebėjimų ugdymas (3 iš 3 ECTS):

- Vasaros mokykla „Vilnius University Multidisciplinary Doctoral Summer School“ (3 ECTS)
- Nuotolinis seminaras “GPU Programming: Why, When and How!”

| Studijų metai         | Dalyvavimas konferencijose |          |               |          | Publikacijos       |          |         |                    |          |            |
|-----------------------|----------------------------|----------|---------------|----------|--------------------|----------|---------|--------------------|----------|------------|
|                       | Tarptautinėse              |          | Nacionalinėse |          | Su citav. rodikliu |          |         | Be citav. rodiklio |          |            |
|                       | Planas                     | Įvykdyta | Planas        | Įvykdyta | Planas             | Įvykdyta | Būklė   | Planas             | Įvykdyta | Būklė      |
| I (2022/2023)         |                            |          |               | 1        |                    |          |         |                    |          |            |
| <b>II (2023/2024)</b> |                            | 1        | 1             | 1        |                    |          |         |                    | 1        | Publikuota |
| III (2024/2025)       | 1                          | 1        |               |          | 1                  | 1        | Įteikta |                    |          |            |
| IV (2025/2026)        | 1                          |          |               |          | 2                  |          | Vykdoma |                    |          |            |
| Iš viso:              | 2                          | 2        | 1             | 2        | 3                  | 0        |         | 0                  | 1        |            |

# Visų mokslinių tyrimų ir disertacijos rengimo etapai

|    |                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                              |                                                                                                               |                                                                                                                                                                                                                                                                                                |
|----|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| 2. | <p>Mokslinio tyrimo vykdymas:</p> <p><b>2.1. Tyrimo metodikos sudarymas:</b></p> <p>2.1.1. Tyrimo metodikos iškeltiems uždaviniams spręsti parinkimas;</p> <p>2.1.2. Teorinio ir empirinio tyrimų suplanavimas pagal pasirinktą metodiką.</p> <p><b>2.2. Teorinis tyrimas:</b></p> <p>2.2.1. Giliojo mokymosi metodų, naudojamų prostatos vėžio identifikavimui mpMRT vaizduose, tyrimas.</p> <p>2.2.2. Prostatos vėžio atpažinimo giliojo mokymosi metodo sukūrimas ir/ar testavimas.</p> <p><b>2.3. Empirinis tyrimas:</b></p> <p>2.3.1. Sudarytų metodų pritaikymas praktinių uždavinių sprendimui.</p> <p>2.3.2. Gautų duomenų analizė, rezultatų apibendrinimas, išvadų parengimas.</p> | <p>2024 m. spalio mėn. –<br/>2025 m. gegužės mėn.</p> <p>2025 m. birželio mėn. –<br/>2026 m. rugsėjo mėn.</p> | <p>Straipsnis pateiktas į TSP žurnalą (recenzuojama)</p> <p>Pratęsta eksperimentinė dalis (įtrauktos radiomikos)</p> <p>Modeliavime/tyrimuose pritaikytas mašininis mokymasis (gilieji neuroniniai tinklai)</p> <p>Pradėta nagrinėti nauja kryptis (FDA ir ML hibridinio modelio taikymas)</p> |
|----|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|


# Duomenys

Antrinės vaizdų sekos: T2w, DWI

- T2w, DWI turi 1 ašį: erdvės
- DCE turi 2 ašis: erdvės + laiko

Duomenų netikslumai:

- Radiologų segmentavimo klaidos
- Biopsijų prostatos pjūvio nekonkretiškumas
- MRT vaizdų nestandartizavimas
- Imties dydis: 20 pacientai




# Duomenys

Yra 5 duomenų šaltiniai:


1. Prostatos regiono kaukės
2. Vėžio regiono kaukės
3. Biopsijos kaukės ir tipas
4. DCE MRI
5. Prostatos zonų kaukės

Prostatos ir vėžio kaukės rankiniu būdu apibėžtos radiologų.


Biopsijos klasės: piktybinė („malignant“), nenustatyta („undetermined“), gerybinė („benign“)




(1) Prostatos regionas




(2) Vėžio regionas



(3) Biopsijos (priartinta)



(4) DCE MRI




Viskas kartu

Šio pusmečio moksliniai rezultatai:

# Skirtuminio žemėlapio analizė atsižvelgiant į biopsijos informaciją




- Skirtuminio žemėlapio („diffmap“) schema
- Iš DCE duomenų ir periferinių zonų kaukių gauname 2D vaizdą, reprezentuojantį didžiausią DCE signalo pokytį
- Prisitaiko prie kiekvieno paciento DCE dinamikos; pašalinama DCE laiko ašis



# Skirtuminio žemėlapio analizė atsižvelgiant į biopsijos informaciją



- Tikslas – vizualizuoti skirtuminio žemėlapio vokselių pasiskirstymus, palyginti juos su vokseliais priklausančiais biopsijų kaukėms
- Skirtuminio žemėlapio piktybinių vokselių reikšmės dažnai koncentruojasi aukščiau už nepiktybinių. Pasitaiko reikšmingų persidengimų
- Piktybinių biopsijų, persidengiančių su vėžio sritimis, vokseliai koncentruojasi prie viršutinės pasiskirtymo uodegos. Nepiktybinių biopsijų ir nepersidengiančios su vėžio kauke vokeliai – arčiau apatinės histogramos uodegos

Pacientas 003, pjūvis 15




# Radiominių požymių tiriamoji duomenų analizė


- Tikslas - sugeneruoti radiominių požymių vaizdus iš skirtuminių žemėlapių ir įvertinti kiekvienos radiomikos vėžio lokalizavimo tikslumą
- Pasirinkta radiominių požymių grupė – First Order Statistics
- Sugeneruojama 19 požymių (radiomikų) periferinėje zonoje




Energy



Uniformity



RootMeanSquared



InterquartileRange

# Radiominių požymių tiriamoji duomenų analizė





- Vėžio lokalizavimo tikslumo įvertinimas
- Metrikos (be slenksčio, nepriklausos nuo mastelio, jautrus klasių disbalansui):
  - Weighted Logloss
  - Kolmogorov-Smirnov statistika
  - Precision Recall AUC
- Pasirinkta 9 radiomikos tolimesnei analizei:  
10Percentile, 90Percentile, Energy, Maximum, Mean, Median, Minimum, RootMeanSquared, TotalEnergy

| Radiomic                    | Weighted log loss | KS Statistic | PR-AUC |
|-----------------------------|-------------------|--------------|--------|
| 10Percentile                | 0,606             | 0,474        | 0,266  |
| 90Percentile                | 0,557             | 0,546        | 0,292  |
| Energy                      | 0,611             | 0,506        | 0,286  |
| Entropy                     | 0,673             | 0,246        | 0,110  |
| InterquartileRange          | 0,680             | 0,295        | 0,133  |
| Kurtosis                    | 0,716             | 0,102        | 0,045  |
| Maximum                     | 0,556             | 0,550        | 0,294  |
| Mean                        | 0,574             | 0,524        | 0,291  |
| MeanAbsoluteDeviation       | 0,659             | 0,321        | 0,157  |
| Median                      | 0,577             | 0,519        | 0,287  |
| Minimum                     | 0,615             | 0,457        | 0,254  |
| Range                       | 0,652             | 0,342        | 0,166  |
| RobustMeanAbsoluteDeviation | 0,669             | 0,304        | 0,148  |
| RootMeanSquared             | 0,573             | 0,526        | 0,292  |
| Skewness                    | 0,720             | 0,100        | 0,046  |
| StandardDeviation           | 0,656             | 0,328        | 0,159  |
| TotalEnergy                 | 0,611             | 0,506        | 0,286  |
| Uniformity                  | 0,763             | 0,214        | 0,036  |
| Variance                    | 0,773             | 0,334        | 0,154  |

# Radiominių požymių panaudojimas semantiniam segmentavimui

- Tikslas – panaudoti radiominius žemėlapius segmentavimo modelio treniravimui, įvertinti modelio vėžio segmentavimo tikslumą
- U-net architektūra (2D), kiekviena iš 9 radiomikų kaip atskiras įvesties kanalas
- Pasiektas Dice įvertis: 0.69
- Sekantys žingsniai: įvesties duomenų normalizavimas, kitos „loss“ funkcijos panaudojimas, 3D modelio architektūros pasirinkimas vietoje 2D, radiominių žemėlapių generavimas naudojant „wavelet“, „Laplacian of Gaussian“ ir kitu duomenų aprodjimo metodų, panaudojimas kitu MRT vaizdo sekų (T2W, DWI)

Faktinė vėžio kaukė  
Modelio prognozė



# Hibridinis modelis, jungiantis Funkcinę Duomenų Analizę ir giliuosius neuroninius tinklus

- Tikslas – sukurti naują neuroninio tinklo architektūrą, kuri naudoja laiko-signalų funkcijas kaip įvestį ir atlieka semantinį segmentavimą. Toks modelis bus pritaikytas DCE duomenims vėžio aptikimui.
  - Buvo atlikta pradinė literatūros apžvalga apie neuroninių tinklų ir funkcinės duomenų analizės kombinuotą taikymą. Buvo išnagrinėti keli straipsniai, derinantys FDA ir ML, tačiau semantinio segmentavimo pritaikymų nebuvo rasta
- 
- Oviedo de La Fuente, Manuel, et al. "3D Point Cloud Semantic Segmentation Through Functional Data Analysis." *Journal of Agricultural, Biological and Environmental Statistics* 29.4 (2024): 723-744.
  - Thind, Barinder, Kevin Multani, and Jiguo Cao. "Deep learning with functional inputs." *Journal of Computational and Graphical Statistics* 32.1 (2023): 171-180.
  - Zhao, Wei, et al. "Functional Data Analysis as the Feature Representation for the Classification Problem in one or two dimensional spaces." *2024 International Joint Conference on Neural Networks (IJCNN)*. IEEE, 2024.

# Kito pusmečio darbo planas

- Publikuoti skirtuminio žemėlapiu mokslinį straipsnį žurnale su citavimo rodikliu
- Atlikti radiominių požymių segmentavimo modeliavimo eksperimentus, paruošti mokslinį straipsnį
- Atlikti Funkcinės Duomenų Analizės ir neuroninių tinklų hibridinių modelių literatūros apžvalgą, sukurti hibridinį segmentavimo modelį, patikrinti jo veikimą ant MRT dinaminio kontrasto duomenų, paruošti straipsnį