

**УНИВЕРЗИТЕТ У БЕОГРАДУ**

Факултет организационих наука

**НАСТАВНО-НАУЧНОМ ВЕЋУ**

**Предмет:** Подобност теме и кандидата Николе Цветковић за израду докторске дисертације

Одлуком Наставно-научног већа Факултета организационих наука-Универзитета у Београду 05-01 бр. 3/38-5 од 30.03.2026. године именовани смо за чланове Комисије за преглед и одбрану приступног рада и оцену научне заснованости теме докторске дисертације кандидата **Николе Цветковић** под насловом:

**„Интегрални статистички модел за даљинско узорковање ”**

На основу материјала приложеног уз Захтев кандидата, Комисија подноси следећи

**ИЗВЕШТАЈ**

**1. Подаци о кандидату**

**1.1. Биографски подаци**

Никола Цветковић рођен је 24.12.1993. године у Београду. Прву економску школу, смер банкарски службеник, завршио је 2012. године као носилац Вукове дипломе. Исте године уписао је Факултет организационих наука, Универзитета у Београду, студијски програм Информациони системи и технологије. Положио је све испите предвиђене наставним планом и програмом и дипломирао у септембру 2016. године на Катедри за операциона истраживања и статистику под менторством професора др Александра Ђоковића, са просечном оценом 9.70 и стекао звање дипломирани инжењер организационих наука.

Школске 2016/17 године уписао је Мастер академске студије на Факултету организационих наука на студијском програму Пословна аналитика, модул Пословна статистика. Положио је све испите предвиђене наставним планом и програмом и одбранио завршни мастер рад у септембру 2018. године на Катедри за операциона истраживања и статистику са просечном оценом 9.80 и стекао звање мастер инжењер организационих наука.

Школске 2018/19 године уписао је Специјалистичке студије на Факултету организационих наука на студијском програму Менаџмент и информациони системи, модул Операциона истраживања и рачунарска статистика.

Школске 2019/20 године уписао је Докторске академске студије на Факултету организационих наука на студијском програму Информациони системи и квантитативни менаџмент, модул Операциона истраживања. Положио је све испите предвиђене наставним планом са просечном оценом 10. Тренутно ради на истраживању и писању докторске дисертације.

Никола Цветковић течно говори енглески језик, а поред тога служи се и немачким језиком. Два пута био је носилац стипендије коју додељује Фонд за младе таленте за стипендирање најбољих студената у Републици Србији. У току студирања био је члан студентског парламента Факултета организационих наука. Као члан фудбал секције факултета учествовао је на бројним домаћим и међународним турнирима и освојио велики број медаља. Познаје рад на рачунару, заједно са великим бројем програмских језика и статистичких пакета за обраду података попут SPSS, Python и R.

## 1.2. Стечено научноистраживачко искуство

У наставку ће бити приказане научноистраживачке активности кандидата.

Током досадашњег рада Никола Цветковић је објавио више радова у земљи и иностранству и учествовао на више међународних и домаћих скупова и конференција.

### **Радови објављени у научним часописима међународног значаја - M20**

1. **Cvetković N., Đoković A., Dobrota M., Radojičić M.** (2023) *New Methodology for Corn Stress Detection Using Remote Sensing and Vegetation Indices*. Sustainability.; 15(6):5487. <https://doi.org/10.3390/su15065487>. **M21**
2. Radojičić, M., Đoković, A., & **Cvetković, N.** (2021). *Extraordinary circumstances: Covid-19 – Italian Serie A scenario*. Proceedings of the Institution of Mechanical Engineers, Part P: Journal of Sports Engineering and Technology, DOI: 10.1177/17543371211019289, **M22**
3. Milovanović, A., **Cvetković, N.**, Šošević, U., Janković, S., & Pešić, M. (2024). *Synergies Between Land Use/Land Cover Mapping and Urban Morphology: A Review of Advances and Methodologies*. Land, 13(12), 2205, **M22**
4. Milovanović, A., Šošević, U., **Cvetković, N.**, Pešić, M., Janković, S., Krstić, V., Ristić Trajković, J., Milojević, M., Nikezić, A., Simić, D., & Djokić, V. (2025). *Mapping Digital Solutions for Multi-Scale Built Environment Observation: A Cluster-Based Systematic Review*. Smart Cities, 8(6), 196. <https://doi.org/10.3390/smartcities8060196> **M21a+**

### **Зборници међународних научних скупова - M30**

1. **Cvetković, N.**, Dragović, N. & Đoković, A.: *Field stress detection algorithm using remote sensing*. XVI International Symposium SymOrg 2018: Doing Business in the Digital Age: Challenges, Approaches and Solutions, Zlatibor 2018, pp.229-235, ISBN:978-86-7680-361-3, **M33**.
2. **Cvetković, N.**, Marinović M., & Milanović, N.: *Dynamics and clusters of the European Parliament Voting Results. How does the Europe vote?*. XVII International Symposium SymOrg 2020: Business and Artificial Intelligence, Belgrade 2020, pp.283-289, ISBN 978-86-7680-385-9, **M33**.
3. **Cvetković, N.**, & Đoković, A. (2022). *The Relationship between the Currencies of old and modern Times*. Book of Abstracts of XVIII International Symposium SymOrg 2022: Sustainable Business Management and Digital Transformation: Challenges and Opportunities in the Post - Covid Era, Belgrade 2022, pp.18-19, ISBN: 978-86-7680-411-5, **M34**.

4. Šošević, U., **Cvetković, N.**, Simić D. (2024). *Modern Tools for Digital Visualization of Built Environments*. In: M.Kostić Stanković, I. Mijatović, J. Krivokapić (Eds)., Unlocking the hidden potentials of organization through merging of humans and digitals: symposium proceedings / XIX International symposium SymOrg 2024, Zlatibor, June 12-15, 2024 (hybrid). Belgrade: University, Faculty of Organizational Sciences. pp. 104-110. ISBN-978-86-7680-464-1. **M33**.
5. **Cvetković, N.**, Marinović, M., & Spajić, N.:A.: *Development of a smart agriculture automation system based on Internet of Things and use of Raspberry Pi*. XVI International Symposium SymOrg 2018: Doing Business in the Digital Age: Challenges, Approaches and Solutions, Zlatibor 2018, pp.90-95, ISBN:978-86-7680-361-3, **M33**.

#### **Радови у часописима националног значаја – M50**

1. **Cvetković, N.**, Dobrota, M., Đoković, A. & Dragović, N.: *Field stress detection using remote sensing in agriculture*, INFO M, Fakultet organizacionih nauka, Beograd, Vol.69, ISSN:1451-4397, **M52**.

#### **Предавања по позиву на скуповима националног значаја – M60**

1. Radojičić, M., Đoković, A., Radovanović, S., **Cvetković, N.** (2019) *Zlatna kopačka – kritika trenutne metodologije*. In Proceedings of XLVI International Symposium on Operational Research - SYM-OP-IS 2019 (in press). September, 15th-18th, Kladovo, Serbia. **M63**.
2. **Cvetković, N.**, Đoković A, Marinović M (2023) *Uticaj faktora na otkazivanje rezervacija u hotelijerstvu*. In Proceedings of 50. International Symposium on Operational Research - SYM-OP-IS 2023 (in press). September, 18th-21st, Tara, Serbia. **M63**.
3. Janković, S., Pešić, M., Milovanović, A., **Cvetković, N.**, Šošević, U. (2024). *Conceptual Framework for Mapping of Urban Patterns in Spa Settlements in Serbia: SPATTERN Project*. In: Marić, J., Marković, J. (Eds). Third Scientific Conference Urban Security and Urban Development - Book of Abstracts. University of Belgrade - Faculty of Architecture and Faculty of Security. pp. 50-51. ISBN 978-86-80144-65-8 **M64**.

Следи списак положених предмета на докторским студијама са оценама и ЕСПБ бодовима:

Називи предмета	Оцена	ЕСПБ
Мултиваријациона анализа	10 (десет)	10
Нелинеарно програмирање	10 (десет)	10
Вишекритеријумска оптимизација и одлучивање	10 (десет)	10
Статистика у менаџменту	10 (десет)	10
Нови трендови у операционим истраживањима	10 (десет)	10
Примењена математичка анализа	10 (десет)	10
Комбинаторна оптимизација	10 (десет)	10
Наука о менаџменту	10 (десет)	10
Методологија научно-истраживачког рада	10 (десет)	10

Кандидат је дана 07.04.2026 године успешно одбранио приступни рад за израду докторске дисертације под називом „Интегрални статистички модел за даљинско узорковање”.

### 1.3. Оцена подобности кандидата за рад на предложеној теми

Узимајући у обзир резултате остварене током досадашњег образовања, резултате истраживања на тему рачунарске статистике, мултиваријационе анализе и даљинског узорковања који су публиковани на научно-стручним конференцијама и у часописима, а сходно томе и искуство у спровођењу наставних активности из ове области, закључује се да је Никола Цветковић у потпуности квалификован и припремљен да тему докторске дисертације самостално истражује и пружи научно-стручне доприносе у тој области.

## **2. Предмет и циљ истраживања**

Предмет истраживања ове докторске дисертације је развој, формализација и емпиријска валидација доменски преносивог интегралног статистичког модела за детекцију аномалија кроз анализу расподела у просторним подацима даљинског узорковања. Модел је заснован на интеграцији метода заснованих на језгру у Хилбертовом простору са репродукујућим језгром (RKHS), бутстрап калибрације прага одлуке и процедура вишеструког тестирања хипотеза са контролом стопе лажних открића.

Системи даљинског узорковања, у распону од UAV и сателитских платформи за снимање Земљине површине, преко медицинских система магнетне резонанце (MRI), до мрежа видео-надзорних камера, генеришу просторно организоване скупове мерења чија је кључна заједничка карактеристика да локална одступања од референтног нормалног стања не могу бити поуздано идентификована на нивоу агрегатних мера, већ искључиво на нивоу расподеле сигнала унутар локалних региона. Стрес вегетације у пољопривреди манифестује се кроз промену облика расподеле вегетативног индекса пре него кроз промену његове средње вредности. Лезије и тумори у медицинским MRI волуменима испољавају се кроз хетерогеност расподеле интензитета ткива. Аномална кретања у видео секвенцама надзорних камера одражавају се кроз промену расподеле вектора оптичког тока. Иако су домени технолошки потпуно различити, сва три случаја деле идентичну статистичку структуру: постоји просторни сигнал, референтно нормално стање, и аномалија која се манифестује кроз промену расподеле сигнала унутар локалних региона.

Ова заједничка структура представља полазну тачку за дефинисање предмета истраживања у ширем смислу, развоја јединственог статистичког модела способног да детектује одступања на нивоу расподела у просторним подацима независно од специфичности домена, уз формалне гаранције статистичке исправности и могућност преноса на нове домene без структурних измена методологије.

Непосредна мотивација за ово истраживање проистиче из претходног ауторовог рада о детекцији стреса кукуруза на основу UAV RGB снимака применом анализе расподеле вредности вегетативног индекса ExG (Cvetković et al., 2023). У том раду примењена је мера преклапања хистограма за квантификацију сличности између расподела унутар локалних региона поља. Резултати су потврдили потенцијал приступа заснованог на расподелама, али су истовремено идентификована два кључна методолошка ограничења: (1) мера преклапања хистограма је хеуристичка и нема формално статистичко утемељење, те не омогућава дефинисање теста са контролисаном грешком прве врсте; (2) приступ је специфичан за дати домен и не пружа принципијелни оквир за примену у другим доменима даљинског узорковања. Превазилажење ових ограничења директно мотивише развој формалног интегралног модела који је предмет овог истраживања.

Шири контекст мотивације произилази из анализе стања у области детекције аномалија у просторним подацима. Постојеће класе метода имају системска ограничења која се понављају без обзира на домен примене. Методе засноване на прагу и статистикама нижих редова редукују локални регион на један или два момента расподеле, чиме се губи информација о облику расподеле и пропуштају аномалије које се испољавају кроз промену облика, повећану мултимодалност или промену у реповима расподеле. Методе надгледане класификације захтевају означене примере аномалија, који су у пракси ретко доступни с обзиром на то да је појава аномалија по правилу спорадична и неравномерна по простору. Савремене методе дубоког учења постижу високу тачност у оквиру специфичних домена, али не обезбеђују формалну статистичку контролу грешке прве врсте нити омогућавају пренос на нове домene без поновног тренирања. Ниједан од наведених приступа не задовољава истовремено захтеве потпуности расподеле, непараметарске робусности, формалне контроле стопе лажних открића и доменске преносивости без структурних измена методологије.

Идентификована методолошка празнина огледа се у одсуству јединственог формалног статистичког модела који би: (а) третирао локалну расподелу сигнала унутар региона као примарну јединицу анализе, (б) примењивао теоријски утемељену меру растојања између расподела у простору вероватносних мера, (в) калибрисао праг одлуке без параметарских претпоставки о облику расподеле, (г) контролисао стопу лажних открића у условима симултаног тестирања великог броја региона, и (д) омогућавао пренос на нове домene искључивом заменом референтне расподеле, без измене математичке структуре модела.

Као одговор на идентификовану методолошку празнину, предлаже се интегрални статистички модел  $M = (\Pi, \Delta, A, \Theta)$ , у којем свака компонента директно операционализује један теоријски резултат из математичке статистике и теорије метода заснованих на језгру.

Компонента  $\Pi$  (подела домена) разлаже просторни домен на локалне регионе прилагођене карактеристикама домена: дводимензионалне регионе у UAV снимцима, тродимензионалне волуметријске регионе у MRI снимцима, или просторно-временске регионе у видео секвенцама. Сваки регион  $\Omega_i$  третира се као носилац локалне емпиријске мере расподеле  $\hat{P}_i$ , чиме се аналитички фокус премешта са нивоa појединачних мерења на ниво расподела.

Компонента  $\Delta$  (мера расподелног одступања) квантификује колико локална расподела сигнала унутар региона  $\Omega_i$  одступа од референтног нормалног стања  $P_{ref}$ . Примењује се  $MMD^2$  (Maximum Mean Discrepancy) мера, теоријски утемељена мера растојања између расподела у Хилбертовом простору са репродукујућим језгром. За скаларне сигнале, локална расподела се прво репрезентује путем оригиналне методе глатке хистограмске репрезентације (SoftHist), која представља дискретизовану апроксимацију репрезентације расподеле у RKHS простору.

Компонента  $A$  (агрегација) организује  $K$  локалних  $MMD^2$  скорова у просторну мапу одступања расподела, са придруженим глобалним детекционим скором  $D$ . Просторна мапа омогућава локализацију аномалних региона у домену, док глобални скор  $D$  пружа јединствену агрегатну меру за анализу стања целог система.



Компонента  $\Theta$  (статистичка одлука) калибрише праг одлуке  $\hat{\tau}$  бутстрап процедуром над референтним узорком, без параметарских претпоставки о облику нулте расподеле  $MMD^2$  статистике. За симултано тестирање  $K$  региона примењује се Бењамини-Хохберг процедура за контролу стопе лажних открића ( $FDR \leq \alpha$ ), са Бењамини-Јекутиели варијантом у случајевима просторне зависности. Скуп детектованих аномалија  $A$  има гарантовану контролу  $FDR$  под регуларним условима.

Кључна архитектонска карактеристика модела јесте прецизна раздвојеност доменски-специфичних и доменски-инваријантних компоненти. Сва специфичност домена улази искључиво кроз дефиницију референтне расподеле  $P_{ref}$  и параметар величине локалног региона  $P$ . Математичко језгро модела,  $MMD^2$  мера, бутстрап процедура и  $FDR$  корекција, остају непромењени без обзира на домен. Тиме се обезбеђује принципијелна преносивост модела између UAV пољопривредног, MRI медицинског и домена видео секвенци, без структурних измена методологије.

Циљеви докторске дисертације су вишеструки и хијерархијски организовани у складу са логиком истраживачког процеса.

Општи циљ истраживања јесте развој, формализација и свеобухватна емпиријска валидација интегралног статистичког модела  $M = (\Pi, \Delta, A, \Theta)$  са доказаним теоријским својствима конзистентности и статистичке моћи, применљивог у различитим доменима даљинског узорковања без структурних измена методологије.

Специфични циљеви истраживања обухватају:

- Систематски преглед и синтезу релевантне литературе из области статистичких метода за просторне податке, метода заснованих на језгру у простору вероватносних мера и детекције аномалија у доменима даљинског узорковања, уз идентификацију кључних ограничења постојећих приступа.
- Математичку формализацију интегралног модела  $M$  са теоријским доказима заснованим на теорији просторних случајних поља, статистичком тестирању заснованом на  $U$ -статистикама и теорији конзистентности бутстрап процедуре.
- Развој методе глатке хистограмске репрезентације расподеле (SoftHist) као оригиналног методолошког доприноса, са теоријским утемељењем у апроксимацији репрезентације расподеле у RKHS простору и анализом грешке дискретизације.
- Емпиријску валидацију модела на реалним UAV снимцима кукурузних парцела, укључујући квантитативну компаративну евалуацију у односу на референтне методе детекције аномалија и анализу осетљивости параметара модела.
- Примену модела на медицинском MRI домену кроз конкретизацију свих компоненти у тродимензионалној конфигурацији и емпиријску евалуацију на стандардним референтним скуповима података BraTS 2021 и WMH 2017.
- Примену модела на домену видео секвенци кроз конкретизацију просторно-временске конфигурације са CUSUM детектором и емпиријску евалуацију на скуповима UCF-Crime и UCSD Pedestrian.
- Систематску анализу доменског трансфера кроз компаративну евалуацију у односу на доменски специјализоване методе и верификацију хипотезе о принципијелној преносивости модела без структурних измена.

Почетна листа библиографских извора који ће се користити приликом израде докторске дисертације:

1. Adler, R. J., & Taylor, J. E. (2007). Random fields and geometry. New York, NY: Springer New York.

2. Adnan, M. M., Rahim, M. S. M., Rehman, A., Mehmood, Z., Saba, T., & Naqvi, R. A. (2021). Automatic image annotation based on deep learning models: a systematic review and future challenges. *IEEe Access*, 9, 50253-50264.
3. Alzubaidi, L., Bai, J., Al-Sabaawi, A., Santamaría, J., Albahri, A. S., Al-Dabbagh, B. S. N., ... & Gu, Y. (2023). A survey on deep learning tools dealing with data scarcity: definitions, challenges, solutions, tips, and applications. *Journal of Big Data*, 10(1), 46.
4. Arbia, G. (2006). *Spatial econometrics: statistical foundations and applications to regional convergence*. Berlin, Heidelberg: Springer Berlin Heidelberg.
5. Arcones, M. A., & Gine, E. (1992). On the bootstrap of U and V statistics. *The Annals of Statistics*, 655-674.
6. Ashburner, J., & Friston, K. J. (2005). Unified segmentation. *neuroimage*, 26(3), 839-851.
7. Audoin, B., Ranjeva, J. P., Duong, M. V. A., Ibarrola, D., Malikova, I., Confort-Gouny, S., ... & Cozzone, P. J. (2004). Voxel-based analysis of MTR images: A method to locate gray matter abnormalities in patients at the earliest stage of multiple sclerosis. *Journal of Magnetic Resonance Imaging: An Official Journal of the International Society for Magnetic Resonance in Medicine*, 20(5), 765-771.
8. Baid, U., Ghodasara, S., Mohan, S., Bilello, M., Calabrese, E., Colak, E., ... & Bakas, S. (2021). The rsna-asnr-miccai brats 2021 benchmark on brain tumor segmentation and radiogenomic classification. *arXiv preprint arXiv:2107.02314*.
9. Bannari, A., Morin, D., Bonn, F., & Huete, A. (1995). A review of vegetation indices. *Remote sensing reviews*, 13(1-2), 95-120.
10. Baringhaus, L., & Franz, C. (2004). On a new multivariate two-sample test. *Journal of multivariate analysis*, 88(1), 190-206.
11. Basu, S., Ramegowda, V., Kumar, A., & Pereira, A. (2016). Plant adaptation to drought stress. *F1000Research*, 5, F1000-Faculty.
12. Baur, C., Denner, S., Wiestler, B., Navab, N., & Albarqouni, S. (2021). Autoencoders for unsupervised anomaly segmentation in brain MR images: a comparative study. *Medical image analysis*, 69, 101952.
13. Benjamini, Y., & Hochberg, Y. (1995). Controlling the false discovery rate: a practical and powerful approach to multiple testing. *Journal of the Royal statistical society: series B (Methodological)*, 57(1), 289-300.
14. Benjamini, Y., & Yekutieli, D. (2001). The control of the false discovery rate in multiple testing under dependency. *Annals of statistics*, 1165-1188.
15. Berinet, A., & Thomas-Agnan, C. (2011). *Reproducing kernel Hilbert spaces in probability and statistics*. Springer Science & Business Media.
16. Billingsley, P. (2013). *Convergence of probability measures*. John Wiley & Sons.
17. Brown, M. A., & Semelka, R. C. (2011). *MRI: basic principles and applications*. John Wiley & Sons.
18. Budrys, T., Veikutis, V., Lukosevicius, S., Gleizniene, R., Monastyreckiene, E., & Kulakiene, I. (2018). Artifacts in magnetic resonance imaging: how it can really affect diagnostic image quality and confuse clinical diagnosis?. *Journal of Vibroengineering*, 20(2), 1202-1213.
19. Camps-Valls, G., Tuia, D., Gómez-Chova, L., Jiménez, S., & Malo, J. (2011). Remote sensing image processing.
20. Candiago, S., Remondino, F., De Giglio, M., Dubbini, M., & Gattelli, M. (2015). Evaluating multispectral images and vegetation indices for precision farming applications from UAV images. *Remote sensing*, 7(4), 4026-4047.
21. Carpenter, J., & Bithell, J. (2000). Bootstrap confidence intervals: when, which, what? A practical guide for medical statisticians. *Statistics in medicine*, 19(9), 1141-1164.
22. Carter, G. A. (1993). Responses of leaf spectral reflectance to plant stress. *American journal of botany*, 80(3), 239-243.

23. Chandola, V., Banerjee, A., & Kumar, V. (2009). Anomaly detection: A survey. *ACM computing surveys (CSUR)*, 41(3), 1-58.
24. Chen, M., Gao, C., & Ren, Z. (2016). A general decision theory for Huber's  $\epsilon$ -contamination model.
25. Chiles, J. P., & Delfiner, P. (2012). *Geostatistics: modeling spatial uncertainty*. John Wiley & Sons.
26. Chou, Y. M., Mason, R. L., & Young, J. C. (1999). Power comparisons for a Hotelling's  $T^2$  statistic. *Communications in Statistics-Simulation and Computation*, 28(4), 1031-1050.
27. Cohen, J. (2013). *Statistical power analysis for the behavioral sciences*. routledge.
28. Colomina, I., & Molina, P. (2014). Unmanned aerial systems for photogrammetry and remote sensing: A review. *ISPRS Journal of photogrammetry and remote sensing*, 92, 79-97.
29. Cover, T. M. (1999). *Elements of information theory*. John Wiley & Sons.
30. Cressie, N. (2015). *Statistics for spatial data*. John Wiley & Sons.
31. Csörgő, M. (2006). Glivenko-Cantelli type theorems for distance functions based on the modified empirical distribution function of M. Kac and for the empirical process with random sample size in general. In *Probability and Information Theory II* (pp. 149-164). Berlin, Heidelberg: Springer Berlin Heidelberg.
32. Cvetković, N., Đoković, A., Dobrota, M., & Radojičić, M. (2023). New Methodology for Corn Stress Detection Using Remote Sensing and Vegetation Indices. *Sustainability*, 15(6), 5487.
33. Davis, J., & Goadrich, M. (2006). The relationship between Precision-Recall and ROC curves. In *Proceedings of the 23rd international conference on Machine learning* (pp. 233-240).
34. Dehghani, A., Sarbishei, O., Glatard, T., & Shihab, E. (2019). A quantitative comparison of overlapping and non-overlapping sliding windows for human activity recognition using inertial sensors. *Sensors*, 19(22), 5026.
35. Dobrota, M. (2018) A Statistical Approach to Sensitivity Zone Definition in Remote Sensing Methods. Ph.D. Thesis, Faculty of Organizational Sciences, University of Belgrade, Belgrade, Serbia.
36. Drusch, M., Del Bello, U., Carlier, S., Colin, O., Fernandez, V., Gascon, F., ... & Bargellini, P. (2012). Sentinel-2: ESA's optical high-resolution mission for GMES operational services. *Remote sensing of Environment*, 120, 25-36.
37. "Duda, R. O., Hart, P. E., & Stork, D. G. (2000). *Pattern Classification* (2nd ed.).
38. New York, USA: John Wiley & Sons, Inc"
39. Farnebäck, G. (2003). Two-frame motion estimation based on polynomial expansion. In *Scandinavian conference on Image analysis* (pp. 363-370). Berlin, Heidelberg: Springer Berlin Heidelberg.
40. Fitzgerald, G., Rodriguez, D., & O'Leary, G. (2010). Measuring and predicting canopy nitrogen nutrition in wheat using a spectral index—The canopy chlorophyll content index (CCCI). *Field crops research*, 116(3), 318-324.
41. Fukumizu, K., Bach, F. R., & Jordan, M. I. (2004). Dimensionality reduction for supervised learning with reproducing kernel Hilbert spaces. *Journal of Machine Learning Research*, 5(Jan), 73-99.
42. Gagunashvili, N. D. (2010). Chi-square tests for comparing weighted histograms. *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, 614(2), 287-296.
43. Garreau, D., Jitkrittum, W., & Kanagawa, M. (2017). Large sample analysis of the median heuristic. *arXiv preprint arXiv:1707.07269*.
44. Genovese, C. R., Lazar, N. A., & Nichols, T. (2002). Thresholding of statistical maps in functional neuroimaging using the false discovery rate. *Neuroimage*, 15(4), 870-878.



45. Goldstein, M., & Uchida, S. (2016). A comparative evaluation of unsupervised anomaly detection algorithms for multivariate data. *PloS one*, 11(4), e0152173.
46. Gómez-Chova, L., Camps-Valls, G., Munoz-Mari, J., & Calpe, J. (2008). Semisupervised image classification with Laplacian support vector machines. *IEEE Geoscience and Remote Sensing Letters*, 5(3), 336-340.
47. Good, P. (2005). *Permutation, parametric and bootstrap tests of hypotheses*. New York, NY: Springer New York.
48. Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., & Moore, R. (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote sensing of Environment*, 202, 18-27.
49. Goutte, C., & Gaussier, E. (2005). A probabilistic interpretation of precision, recall and F-score, with implication for evaluation. In *European conference on information retrieval* (pp. 345-359). Berlin, Heidelberg: Springer Berlin Heidelberg.
50. Gretton, A., Borgwardt, K. M., Rasch, M. J., Schölkopf, B., & Smola, A. (2012). A kernel two-sample test. *The journal of machine learning research*, 13(1), 723-773.
51. Griffanti, L., Zamboni, G., Khan, A., Li, L., Bonifacio, G., Sundaresan, V., ... & Jenkinson, M. (2016). BIANCA (Brain Intensity AbNormality Classification Algorithm): A new tool for automated segmentation of white matter hyperintensities. *Neuroimage*, 141, 191-205.
52. Gupta, A., Karypis, G., & Kumar, V. (2002). Highly scalable parallel algorithms for sparse matrix factorization. *IEEE Transactions on Parallel and Distributed systems*, 8(5), 502-520.
53. Haering, N., Venetianer, P. L., & Lipton, A. (2008). The evolution of video surveillance: an overview. *Machine Vision and Applications*, 19(5), 279-290.
54. Hall, P. (2013). *The bootstrap and Edgeworth expansion*. Springer Science & Business Media.
55. Hanley, J. A., & McNeil, B. J. (1982). The meaning and use of the area under a receiver operating characteristic (ROC) curve. *Radiology*, 143(1), 29-36.
56. Hasheminasab, S. M., Zhou, T., & Habib, A. (2020). GNSS/INS-assisted structure from motion strategies for UAV-based imagery over mechanized agricultural fields. *Remote Sensing*, 12(3), 351.
57. Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The elements of statistical learning*.
58. Healy, J. D. (1987). A note on multivariate CUSUM procedures. *Technometrics*, 29(4), 409-412.
59. Horn, B. K., & Schunck, B. G. (1981). Determining optical flow. *Artificial intelligence*, 17(1-3), 185-203.
60. Huttenlocher, D. P., Klanderman, G. A., & Rucklidge, W. J. (2002). Comparing images using the Hausdorff distance. *IEEE Transactions on pattern analysis and machine intelligence*, 15(9), 850-863.
61. Isensee, F., Jaeger, P. F., Kohl, S. A., Petersen, J., & Maier-Hein, K. H. (2021). nnU-Net: a self-configuring method for deep learning-based biomedical image segmentation. *Nature methods*, 18(2), 203-211.
62. Jack Jr, C. R., Theodore, W. H., Cook, M., & McCarthy, G. (1995). MRI-based hippocampal volumetrics: data acquisition, normal ranges, and optimal protocol. *Magnetic resonance imaging*, 13(8), 1057-1064.
63. Jensen, J. R. (1996). *Introductory digital image processing: a remote sensing perspective*.
64. Jia, X., Zhao, M., Di, Y., Yang, Q., & Lee, J. (2017). Assessment of data suitability for machine prognosis using maximum mean discrepancy. *IEEE transactions on industrial electronics*, 65(7), 5872-5881.
65. Jiang, Z., Huete, A. R., Chen, J., Chen, Y., Li, J., Yan, G., & Zhang, X. (2006). Analysis of NDVI and scaled difference vegetation index retrievals of vegetation fraction. *Remote sensing of environment*, 101(3), 366-378.

66. Johnston, M. G., & Faulkner, C. (2021). A bootstrap approach is a superior statistical method for the comparison of non-normal data with differing variances. *The New Phytologist*, 230(1), 23-26.
67. Khorram, S., Van der Wiele, C. F., Koch, F. H., Nelson, S. A., & Potts, M. D. (2016). Principles of applied remote sensing (pp. 21-31). Berlin/Heidelberg: Springer International Publishing.
68. Kiran, B. R., Thomas, D. M., & Parakkal, R. (2018). An overview of deep learning based methods for unsupervised and semi-supervised anomaly detection in videos. *Journal of imaging*, 4(2), 36.
69. Kristoffersen Wiberg, M., Aspelin, P., Sylvan, M., & Bone, B. (2003). Comparison of lesion size estimated by dynamic MR imaging, mammography and histopathology in breast neoplasms. *European radiology*, 13(6), 1207-1212.
70. Kuijf, H. J., Biesbroek, J. M., De Bresser, J., Heinen, R., Andermatt, S., Bento, M., ... & Biessels, G. J. (2019). Standardized assessment of automatic segmentation of white matter hyperintensities and results of the WMH segmentation challenge. *IEEE transactions on medical imaging*, 38(11), 2556-2568.
71. Kullback, S., & Leibler, R. A. (1951). On information and sufficiency. *The annals of mathematical statistics*, 22(1), 79-86.
72. Künsch, H. R. (1989). The jackknife and the bootstrap for general stationary observations. *The annals of Statistics*, 1217-1241.
73. Lahiri, S. N. (2013). Resampling methods for dependent data. Springer Science & Business Media.
74. Lehmann, E. L., & Romano, J. P. (2005). Testing statistical hypotheses. New York, NY: Springer New York.
75. Liakos, K. G., Busato, P., Moshou, D., Pearson, S., & Bochtis, D. (2018). Machine learning in agriculture: A review. *Sensors*, 18(8), 2674.
76. Liang, P., Shi, L., Chen, N., Luo, Y., Wang, X., Liu, K., ... & Li, K. (2015). Construction of brain atlases based on a multi-center MRI dataset of 2020 Chinese adults. *Scientific reports*, 5(1), 18216.
77. Lillesand, T. M., Kiefer, R. W., & Chipman, J. W. (2015). Remote Sensing and Image Interpretation (7th ed.). John Wiley & Sons.
78. Lindgren, F., Rue, H., & Lindström, J. (2011). An explicit link between Gaussian fields and Gaussian Markov random fields: the stochastic partial differential equation approach. *Journal of the Royal Statistical Society Series B: Statistical Methodology*, 73(4), 423-498.
79. Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., ... & Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. *Medical image analysis*, 42, 60-88.
80. Liu, W., & Röckner, M. (2015). Stochastic partial differential equations: an introduction (Vol. 10, pp. 978-3). Cham: Springer.
81. Lu, B., Dao, P. D., Liu, J., He, Y., & Shang, J. (2020). Recent advances of hyperspectral imaging technology and applications in agriculture. *Remote sensing*, 12(16), 2659.
82. Lucas, B. D., & Kanade, T. (1981). An iterative image registration technique with an application to stereo vision. In *IJCAI'81: 7th international joint conference on Artificial intelligence* (Vol. 2, pp. 674-679).
83. Mahlein, A. K., Rumpf, T., Welke, P., Dehne, H. W., Plümer, L., Steiner, U., & Oerke, E. C. (2013). Development of spectral indices for detecting and identifying plant diseases. *Remote sensing of environment*, 128, 21-30.
84. Matheron, G. (1984). The selectivity of the distributions and “the second principle of geostatistics”. In *Geostatistics for Natural Resources Characterization: Part 1* (pp. 421-433). Dordrecht: Springer Netherlands.

85. Menze, B. H., Jakab, A., Bauer, S., Kalpathy-Cramer, J., Farahani, K., Kirby, J., ... & Van Leemput, K. (2014). The multimodal brain tumor image segmentation benchmark (BRATS). *IEEE transactions on medical imaging*, 34(10), 1993-2024.
86. Moso, J. C., Cormier, S., de Runz, C., Fouchal, H., & Wandeto, J. M. (2021). Anomaly detection on data streams for smart agriculture. *Agriculture*, 11(11), 1083.
87. Muandet, K., Fukumizu, K., Sriperumbudur, B., & Schölkopf, B. (2017). Kernel mean embedding of distributions: A review and beyond. *Foundations and Trends® in Machine Learning*, 10(1-2), 1-141.
88. Murray, M. P., Drought, A. B., & Kory, R. C. (1964). Walking patterns of normal men. *JBJS*, 46(2), 335-360.
89. Muzik, O., Chugani, D. C., Juhász, C., Shen, C., & Chugani, H. T. (2000). Statistical parametric mapping: assessment of application in children. *Neuroimage*, 12(5), 538-549.
90. Nagaraja, N., Forder, J. R., Warach, S., & Merino, J. G. (2020). Reversible diffusion-weighted imaging lesions in acute ischemic stroke: a systematic review. *Neurology*, 94(13), 571-587.
91. Nex, F., & Remondino, F. (2014). UAV for 3D mapping applications: A review. *Applied geomatics*, 6(1), 1-15.
92. Nguyen, X., Wainwright, M. J., & Jordan, M. I. (2010). Estimating divergence functionals and the likelihood ratio by convex risk minimization. *IEEE Transactions on Information Theory*, 56(11), 5847-5861.
93. Nichols, T., & Hayasaka, S. (2003). Controlling the familywise error rate in functional neuroimaging: a comparative review. *Statistical methods in medical research*, 12(5), 419-446.
94. Oliver, M. A., & Webster, R. (2015). Basic steps in geostatistics: the variogram and kriging (Vol. 106). Cham, Switzerland: Springer International Publishing.
95. Openshaw, S. (1984). The modifiable areal unit problem. *Concepts and techniques in modern geography*.
96. Pang, G., Shen, C., Cao, L., & Hengel, A. V. D. (2021). Deep learning for anomaly detection: A review. *ACM computing surveys (CSUR)*, 54(2), 1-38.
97. Qian, Q., Wang, Y., Zhang, T., & Qin, Y. (2023). Maximum mean square discrepancy: a new discrepancy representation metric for mechanical fault transfer diagnosis. *Knowledge-Based Systems*, 276, 110748.
98. Richards, J. A. (2022). *Remote Sensing Digital Image Analysis: An Introduction* (6th ed.). Springer.
99. Ridgway, G. R., Omar, R., Ourselin, S., Hill, D. L., Warren, J. D., & Fox, N. C. (2009). Issues with threshold masking in voxel-based morphometry of atrophied brains. *Neuroimage*, 44(1), 99-111.
100. Ronneberger, O., Fischer, P., & Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. In *International Conference on Medical image computing and computer-assisted intervention* (pp. 234-241). Cham: Springer international publishing.
101. Rouse, W. (1973). Monitoring vegetation system in the great plain with ERTS. In *3rd ERTS symposium, NASA Washington DC, 1973* (Vol. 1, pp. 309-317).
102. Rue, H., & Held, L. (2005). *Gaussian Markov random fields: theory and applications*. Chapman and Hall/CRC.
103. Sabih, M., & Vishwakarma, D. K. (2022). Crowd anomaly detection with LSTMs using optical features and domain knowledge for improved inferring. *The visual computer*, 38(5), 1719-1730.
104. Sarkar, S. K. (2007). Stepup procedures controlling generalized FWER and generalized FDR.

105. Schmidt, P., Gaser, C., Arsic, M., Buck, D., Förchler, A., Berthele, A., ... & Mührlau, M. (2012). An automated tool for detection of FLAIR-hyperintense white-matter lesions in multiple sclerosis. *Neuroimage*, 59(4), 3774-3783.
106. Schölkopf, B., & Smola, A. J. (2002). *Learning with kernels: support vector machines, regularization, optimization, and beyond*. MIT press.
107. Scott, D. W. (2015). *Multivariate density estimation*.
108. Serai, S. D. (2022). Basics of magnetic resonance imaging and quantitative parameters T1, T2, T2\*, T1rho and diffusion-weighted imaging. *Pediatric radiology*, 52(2), 217-227.
109. Shamir, R. R., Duchin, Y., Kim, J., Sapiro, G., & Harel, N. (2019). Continuous dice coefficient: a method for evaluating probabilistic segmentations. *arXiv preprint arXiv:1906.11031*.
110. Sheykhou, M., Mahdianpari, M., Ghanbari, H., Mohammadimanesh, F., Ghamisi, P., & Homayouni, S. (2020). Support vector machine versus random forest for remote sensing image classification: A meta-analysis and systematic review. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 6308-6325.
111. Silverman, B. W. (2018). *Density estimation for statistics and data analysis*. Routledge.
112. Smola, A., Gretton, A., Song, L., & Schölkopf, B. (2007, October). A Hilbert space embedding for distributions. In *International conference on algorithmic learning theory* (pp. 13-31). Berlin, Heidelberg: Springer Berlin Heidelberg.
113. Sommerfeld, M., & Munk, A. (2018). Inference for empirical Wasserstein distances on finite spaces. *Journal of the Royal Statistical Society Series B: Statistical Methodology*, 80(1), 219-238.
114. Sriperumbudur, B. K., Gretton, A., Fukumizu, K., Schölkopf, B., & Lanckriet, G. R. (2010). Hilbert space embeddings and metrics on probability measures. *The Journal of Machine Learning Research*, 11, 1517-1561.
115. Stein, M. L. (1999). *Interpolation of spatial data: some theory for kriging*. Springer Science & Business Media.
116. Steinwart, I., & Scovel, C. (2012). Mercer's theorem on general domains: On the interaction between measures, kernels, and RKHSs. *Constructive Approximation*, 35(3), 363-417.
117. Sultani, W., Chen, C., & Shah, M. (2018). Real-world anomaly detection in surveillance videos. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 6479-6488).
118. Swain, M. J., & Ballard, D. H. (1991). Color indexing. *International journal of computer vision*, 7(1), 11-32.
119. Székely, G. J., & Rizzo, M. L. (2004). Testing for equal distributions in high dimension. *InterStat*, 5(16.10), 1249-1272.
120. Székely, G. J., & Rizzo, M. L. (2013). Energy statistics: A class of statistics based on distances. *Journal of statistical planning and inference*, 143(8), 1249-1272.
121. Teed, Z., & Deng, J. (2020). Raft: Recurrent all-pairs field transforms for optical flow. In *European conference on computer vision* (pp. 402-419). Cham: Springer International Publishing.
122. Thaller, B. (2013). *The dirac equation*. Springer Science & Business Media.
123. Toth, C., & Józkó, G. (2016). Remote sensing platforms and sensors: A survey. *ISPRS Journal of Photogrammetry and Remote Sensing*, 115, 22-36.
124. Tucker, C. J. (1979). Red and photographic infrared linear combinations for monitoring vegetation. *Remote sensing of Environment*, 8(2), 127-150.
125. Tustison, N. J., Avants, B. B., Cook, P. A., Zheng, Y., Egan, A., Yushkevich, P. A., & Gee, J. C. (2010). N4ITK: improved N3 bias correction. *IEEE transactions on medical imaging*, 29(6), 1310-1320.
126. Villani, C. (2009). *Optimal transport: old and new* (Vol. 338, p. 23). Berlin: springer.



127. Vuković N., Bulajić M. (2014) Osnove statistike. Beograd: Fakultet organizacionih nauka, 270 p.
128. Wackernagel, H. (2003). Multivariate geostatistics: an introduction with applications. Springer Science & Business Media.
129. Wang, S., Cao, J., & Philip, S. Y. (2020). Deep learning for spatio-temporal data mining: A survey. IEEE transactions on knowledge and data engineering, 34(8), 3681-3700.
130. Wilcoxon, F. (1945). Individual comparisons by ranking methods. Biometrics bulletin, 1(6), 80-83.
131. Woebbecke, D. M., Meyer, G. E., Von Bargen, K., & Mortensen, D. A. (1995). Color indices for weed identification under various soil, residue, and lighting conditions. Transactions of the ASAE, 38(1), 259-269.
132. Wulder, M. A., Loveland, T. R., Roy, D. P., Crawford, C. J., Masek, J. G., Woodcock, C. E., ... & Zhu, Z. (2019). Current status of Landsat program, science, and applications. Remote sensing of environment, 225, 127-147.
133. Xue, J., & Su, B. (2017). Significant remote sensing vegetation indices: A review of developments and applications. Journal of sensors, 2017(1), 1353691.
134. Yacoub, R., & Axman, D. (2020, November). Probabilistic extension of precision, recall, and f1 score for more thorough evaluation of classification models. In Proceedings of the first workshop on evaluation and comparison of NLP systems (pp. 79-91).
135. Zarco-Tejada, P. J., González-Dugo, V., & Berni, J. A. (2012). Fluorescence, temperature and narrow-band indices acquired from a UAV platform for water stress detection using a micro-hyperspectral imager and a thermal camera. Remote sensing of environment, 117, 322-337.
136. Zhang, C., & Kovacs, J. M. (2012). The application of small unmanned aerial systems for precision agriculture: a review. Precision agriculture, 13(6), 693-712.
137. Zijdenbos, A. P., Dawant, B. M., Margolin, R. A., & Palmer, A. C. (1994). Morphometric analysis of white matter lesions in MR images: method and validation. IEEE transactions on medical imaging, 13(4), 716-724.

### 3. Полазне хипотезе

Као главна хипотеза која ће бити тестирана у докторској дисертацији се издваја:

- Могуће је развити интегрални статистички модел даљинског узорковања интеграцијом статистичких метода, са циљем унапређења тачности детекције, робусности модела и интерпретабилности резултата.

Посебне хипотезе у истраживању које проистичу из главне истраживачке хипотезе су:

- ПХ1 - Примена интегралног статистичког модела омогућава смањење грешке класификације у односу на стандардне методе узорковања.
- ПХ2 - Предложени статистички модел може се применити на различите домене при чему постиже перформансе упоредиве са доменски специјализованим методама.
- ПХ3 - Комбиновање више статистичких приступа у јединствен систем омогућава бољу детекцију образаца у даљински прикупљеним подацима.
- ПХ4 - Предложени модел омогућава ефикасније коришћење ограничених узорака података прикупљених даљинским узорковањем.

### 4. Научне методе истраживања

Методологија истраживања која ће бити примењена у овом раду заснована је на комбинацији математичко-статистичких, аналитичко-дедуктивних и емпиријских метода, које заједно



омогућавају изградњу и верификацију интегралног статистичког модела за детекцију аномалија у просторним подацима.

Као полазна основа биће коришћена систематска анализа постојеће литературе из области даљинског узорковања, статистичке теорије расподела, метода детекције аномалија и примена различитим доменима. На основу идентификованих ограничења постојећих приступа, биће примењена метода научног моделирања за конструкцију оригиналног модела  $M = (\Pi, \Delta, A, \Theta)$ , који integriше поделу простора, мерење одступања расподела, агрегацију у просторну мапу аномалија и калибрацију прага одлуке заснованог на бутстрап процедури.

Аналитичко-дедуктивна метода биће примењена при формализацији теоријских основа модела, извођењу особина *Maximum Mean Discrepancy* ( $MMD^2$ ) мере у Хилбертовом простору са репродуктивним језгром, доказивању димензионалне независности конвергенције и формализацији SoftHist уградње расподела. На исти начин биће изведена и процедура контроле стопе лажних открића (FDR) применом *Benjamini-Hochberg* и *Benjamini-Yekutieli* корекција за вишеструко тестирање хипотеза над  $K$  просторних региона.

Статистичке методе чине централни инструментариј истраживања: бутстрап калибрација прага детекције  $\hat{\tau}$  из референтног узорка здравих пиксела, непараметарска процена дистрибуција кроз SoftHist методу, ROC анализа са мером AUC за вредновање дискриминационе моћи модела, те F1 мера за процену баланса између прецизности и одзива. Анализом осетљивости параметара  $\sigma$  и  $B$  биће верификована робусност модела у односу на избор параметара модела.

Компаративна метода биће примењена за упоређивање предложеног модела са референтним методама детекције аномалија на идентичним скуповима података, чиме ће бити омогућена објективна квантитативна евалуација научног доприноса.

Емпиријска метода биће реализована кроз анализу и примену модела на реалним скуповима података из три различита домена. У домену прецизне пољопривреде, модел ће бити примењен на RGB ортофото мозаицима снимљеним UAV платформом над усевима кукуруза у условима природне стресне инфекције, уз коришћење унапред аотираних скупова података у оквиру две протоколарне конфигурације. У домену медицинског снимања, модел ће бити примењен на MRI скуповима података ради детекције структурних аномалија у тродимензионалним просторним сигнаlima. У домену анализе видео секвенци, модел ће бити прилагођен и примењен на временско-просторним подацима ради детекције аномалија у динамичким сценама.

Резултати истраживања биће представљени путем текстуалног излагања и описа, табеларно, путем слика и дијаграма. Процеси синтезе, апстракције и генерализације биће примењени за извођење закључака о применљивости модела ван UAV домена, у медицинском снимању (MRI) и анализи видео сигнала, чиме ће бити потврђена општост предложеног приступа.

## 5. Очекивани научни допринос

Најзначајнији допринос ове докторске дисертације биће развој оригиналног интегралног статистичког модела  $M = (\Pi, \Delta, A, \Theta)$  за детекцију аномалија у просторним подацима даљинског узорковања, заснованог на строгим статистичким принципима и верификованог на реалним скуповима података из више домена примене.

Очекивани научни доприноси овог рада су следећи:

- Формализација и теоријско утемељење оригиналне методе уградње расподела (SoftHist) у Хилбертов простор са репродуктивним језгром, са доказаним особинама конвергенције.
- Развој статистичке процедуре за просторно локализовану детекцију аномалија засноване на MMD<sup>2</sup> мери одступања расподела, независне од димензионалности улазног сигнала.
- Интеграција бутстрап калибрације прага и контроле стопе лажних открића (FDR) у јединствен оквир за вишеструко просторно тестирање хипотеза.
- Верификација примене предложеног модела у три различита домена, прецизна пољопривреда, медицинско снимање и анализа видео секвенци, чиме се потврђује општост приступа.

Очекивани стручни доприноси овог рада огледају се у следећем:

- Систематизација постојећих метода детекције аномалија у просторним сигнаlima уз критичку анализу њихових ограничења у условима несиметричног и ограниченог узорковања.
- Развој поновљивог и параметарски једноставног алата за детекцију аномалија који не захтева претходну обуку на обележеним подацима, чиме се смањује зависност од скупих анонотација.
- Дефинисање протоколарних конфигурација за прикупљање референтних података и евалуацију модела у реалним условима примене.

Друштвени доприноси резултата истраживања односе се на следеће:

- Резултати истраживања могу непосредно да се примене у системима за праћење стања усева, чиме се доприноси раном откривању болести и смањењу губитака у пољопривредној производњи.
- Општост предложеног модела омогућава његову примену у медицинској дијагностици и видео надзору, чиме се шири круг потенцијалних корисника резултата.
- Јавна доступност методологије и евалуационих протокола омогућава другим истраживачима репродуковање и надоградњу резултата у сродним областима.

## 6. План истраживања и структура рада

План истраживања докторске дисертације приказан је у следећој табели:

	Фаза	Задатак	Методe, технике, стандарди
1.	Анализа постојећег стања и досадашњих резултата истраживања	<ul style="list-style-type: none"><li>• Претраживање и систематизација научне литературе из области детекције аномалија, даљинског узорковања и статистичког моделирања просторних сигнала</li><li>• Анализа постојећих метода и</li></ul>	<ul style="list-style-type: none"><li>• Претраживање научне и стручне литературе</li><li>• Претраживање индексних база података</li><li>• Компаративна анализа</li></ul>

		<p>идентификација њихових ограничења у условима несиметричног узорковања</p> <ul style="list-style-type: none"> <li>• Дефинисање истраживачких хипотеза и оквира евалуације</li> </ul>	
2.	Развој интегралног статистичког модела $M = (\Pi, \Delta, A, \Theta)$	<ul style="list-style-type: none"> <li>• Формализација методе просторне поделе (<math>\Pi</math>)</li> <li>• Развој SoftHist методе уградње расподела и <math>MMD^2</math> мере дивергенције (<math>\Delta</math>)</li> <li>• Дефинисање поступка агрегације у просторну мапу аномалија (<math>A</math>)</li> <li>• Развој bootstrap процедуре за калибрацију прага и интеграција BH/BY FDR контроле (<math>\Theta</math>)</li> </ul>	<ul style="list-style-type: none"> <li>• Аналитичко-дедуктивна метода</li> <li>• Математичко-статистичко моделирање</li> <li>• Теорија репродуктивних Хилбертових простора (RKHS)</li> <li>• Непараметарска статистика</li> <li>• Бутстрап методе</li> </ul>
3.	Примена модела и емпиријска верификација у домену прецизне пољопривреде	<ul style="list-style-type: none"> <li>• Примена модела на RGB UAV снимцима парцела кукуруза</li> <li>• Евалуација перформанси у оквиру две протоколарне конфигурације</li> <li>• Компаративна анализа са референтним методама детекције аномалија</li> </ul>	<ul style="list-style-type: none"> <li>• Емпиријска метода ROC анализа, AUC, F1 мера</li> <li>• Статистичке методе евалуације</li> <li>• Анализа осетљивости параметара</li> </ul>
4.	Генерализација и примена модела у другим доменима	<ul style="list-style-type: none"> <li>• Прилагођавање и примена модела на MRI скуповима података за детекцију структурних аномалија</li> <li>• Прилагођавање и примена модела на видео секвенцама за детекцију аномалија у динамичким сценама</li> </ul>	<ul style="list-style-type: none"> <li>• Емпиријска метода</li> <li>• Методе тродимензионалне просторне анализе</li> <li>• Методе временско-просторне анализе сигнала</li> <li>• Статистичке методе верификације и валидације</li> </ul>

		<ul style="list-style-type: none"> <li>Анализа резултата и поређење перформанси преко свих домена</li> </ul>	
5.	Анализа резултата и закључак	<ul style="list-style-type: none"> <li>Синтеза резултата истраживања и верификација хипотеза</li> <li>Оцена научних доприноса и ограничења предложеног модела</li> <li>Дефинисање праваца будућег истраживања</li> </ul>	<ul style="list-style-type: none"> <li>Анализа и синтеза</li> <li>Индуктивно-дедуктивно закључивање</li> </ul>

Оквирно, структуру докторске дисертације сачињаваће следећа поглавља:

## 1. Увод

- 1.1 Предмет и циљ истраживања
- 1.2 Полазне хипотезе
- 1.3 Методе истраживања
- 1.4 Очекивани резултати, научни и стручни допринос

## 2. Даљинско узорковање и детекција просторних аномалија

- 2.1 Системи даљинског узорковања и релевантни домени примене
- 2.2 Дефиниција и таксономија просторних аномалија
- 2.3 Преглед метода детекције аномалија
- 2.4 Критичка анализа и идентификација методолошких празнина

## 3. Статистички инструментаријум за анализу просторних података

- 3.1 Теорија просторних случајних поља
- 3.2 Језгрена репрезентација расподела и RKHS
- 3.3 MMD - дефиниција, процена и тестирање
- 3.4 Бутстрап процедура и калибрација прага одлуке
- 3.5 Вишеструко тестирање хипотеза и контрола стопе лажних открића

## 4. Интегрални статистички модел $M = (P, \Delta, A, \theta)$

- 4.1 Формална дефиниција и архитектура модела
- 4.2 Компонента  $P$  - просторна декомпозиција домена
- 4.3 Компонента  $\Delta$  - одступање расподела и  $MMD^2$
- 4.4 Компонента  $A$  - агрегација у просторну мапу аномалија
- 4.5 Компонента  $\theta$  - калибрација прага и FDR контрола
- 4.6 Теоријска својства модела и референтне методе за евалуацију

## 5. Емпиријска студија - UAV пољопривредни домен

- 5.1 Опис проблема и скупа података
- 5.2 Конкретизација модела  $M$  за UAV домен

- 5.3 Експериментална поставка и методологија евалуације
- 5.4 Резултати и статистичка анализа
- 5.5 Анализа осетљивости параметара
- 5.6 Интерпретација и дискусија резултата

## **6. Емпиријска студија - Медицинска слика**

- 6.1 Опис проблема и референтних скупова података
- 6.2 Конкретизација модела  $M$  за MRI домен
- 6.3 Експериментална поставка и методологија евалуације
- 6.4 Резултати и компаративна анализа

## **7. Емпиријска студија - Видео секвенце**

- 7.1 Опис проблема и референтних скупова података
- 7.2 Конкретизација модела  $M$  за видео домен
- 7.3 Експериментална поставка и методологија евалуације
- 7.4 Резултати и компаративна анализа

## **8. Научни и стручни доприноси**

## **9. Закључак и даљи правци истраживања**

## **10. Литература**





## 7. Закључак и предлог

Из изложеног се може закључити да кандидат Никола Цветковић испуњава све услове предвиђене Законом о високом образовању за одобрење израде докторске дисертације под насловом „**Интегрални статистички модел даљинског узорковања**”.

Никола Цветковић поседује знања из области статистике, даљинског узорковања и мултиваријационе анализе података, неопходна за успешан рад на докторској дисертацији.

Тема припада ужој научној области Рачунарска статистика, мултидисциплинарна је и актуелна. Добијени резултати могу допринети унапређењу метода аутоматске детекције аномалија у просторним подацима, са практичном применом у прецизној пољопривреди, медицинском снимању, анализи видео секвенци и другим доменима.

На основу свега наведеног, комисија предлаже Наставно-научном већу да прихвати предложену тему и одобри израду пријављене докторске дисертације. За ментора докторске дисертације предлаже се др Александар Ђоковић, ванредни професор Факултета организационих наука, Универзитета у Београду.

### ЧЛАНОВИ КОМИСИЈЕ:

---

др Александар Ђоковић, ванредни професор  
Факултет организационих наука  
Универзитет у Београду

---

др Сандро Радовановић, доцент  
Факултет организационих наука  
Универзитет у Београду

---

др Милан Радојичић, доцент  
Факултет организационих наука  
Универзитет у Београду

---

др Ана Старчевић, ванредни професор  
Медицински факултет  
Универзитет у Београду

---

др Свјетлана Јанковић-Шоја, ванредни професор  
Пољопривредни факултет  
Универзитет у Београду

Београд, 14.04.2026.