



UNIVERZITET U NIŠU  
PRIRODNO-MATEMATIČKI FAKULTET



**Jelena Lj. Pejić**

**METOD ZA GENERISANJE LINEARNOG  
RASPOREDA KORELISANIH ELEMENATA  
PRIMENOM VEŠTAČKE INTELIGENCIJE**

DOKTORSKA DISERTACIJA

Niš, 2025.





UNIVERSITY OF NIŠ  
FACULTY OF SCIENCES AND MATHEMATICS



**Jelena Lj. Pejić**

**METHOD FOR LINEAR LAYOUT  
GENERATION OF CORRELATED  
ELEMENTS USING ARTIFICIAL  
INTELLIGENCE**

DOCTORAL DISSERTATION

Niš, 2025.



## Подаци о докторској дисертацији

Ментор:

Марко Петковић, редовни професор, Природно-математички факултет, Универзитет у Нишу

Наслов:

Метод за генерисање линеарног распореда корелисаних елемената применом вештачке интелигенције

Резиме:

Циљ ове дисертације је формално дефинисање и решавање проблема линеарног распоређивања корелисаних елемената, који се јавља у бројним доменама. Као решење, предложен је метод заснован на конволуционим неуронским мрежама, који користи иновативан начин кодирања података путем вишеканалних бинарних низова. Овакав приступ омогућава ефикасно учење просторних односа и рад са прецизним димензијама и у случајевима када је количина података ограничена.

Развијен је скуп података за тестирање способности просторног резоновања. Експерименталним анализама утврђено је да предложени метод успешно учи основне просторне релације и надмашује постојеће приступе, нарочито у условима са малим бројем примера.

Метод је примењен у два домена: архитектури, где је коришћен за аутоматско генерисање распореда елемената у линеарним кухињама, и пчеларству, где је примењен на проблему предвиђања промене тежине кошнице на основу метеоролошких података. У оба случаја потврђена је његова применљивост и робусност.

Дисертација тиме доприноси формализацији важног практичног проблема, развоју генеричког метода за његово решавање, креирању евалуационих скупова података и демонстрацији широке применљивости у реалним окружењима.

Научна област:

Рачунарске науке

Научна  
дисциплина:

Вештачка интелигенција

Кључне речи:

Вештачка интелигенција, конволуционе неуронске мреже, просторно резонување, дизајнирање распореда, генерисање ентеријера, прецизно пчеларство, предикција тежине кошнице

УДК:

519.852: 004.8

CERIF  
класификација:

P 176 Вештачка интелигенција

Тип лиценце  
Креативне  
заједнице:

**CC BY-NC-ND**

## Data on Doctoral Dissertation

Doctoral  
Supervisor:

Marko Petković, full professor at Faculty of Sciences and Mathematics,  
University of Niš

Title:

Method for linear layout generation of correlated elements using artificial  
intelligence

Abstract:

The aim of this dissertation is to formally define and address the problem of linear arrangement of correlated elements, which appears across numerous domains. As a solution, a method based on convolutional neural networks is proposed, utilizing an innovative data encoding approach through multichannel binary sequences. This approach enables efficient learning of spatial relationships and precise dimensional reasoning, even under conditions of limited data availability.

A dataset was developed for evaluating the spatial reasoning capabilities of machine learning models. Experimental analyses demonstrated that the proposed method successfully learns fundamental spatial relations and outperforms existing approaches, particularly in scenarios with a small number of training examples.

The method was applied in two domains: architecture, where it was used for automatic generation of linear kitchen layouts, and beekeeping, where it was applied to the problem of predicting hive weight changes based on meteorological data. In both cases, its applicability and robustness were confirmed.

The dissertation thus contributes to the formalization of an important practical problem, the development of a generic method for its solution, the creation of evaluation datasets, and the demonstration of its broad applicability in real-world environments.

Scientific  
Field:

Computer science

Scientific  
Discipline:

Artificial Intelligence

Key Words:

Artificial intelligence, convolutional neural networks, spatial reasoning, layout design, interior design, precision beekeeping, hive weight prediction

UDC:

519.852: 004.8

CERIF  
Classification:

P 176 Artificial Intelligence

Creative  
Commons  
License Type:

**CC BY-NC-ND**



**ПРИРОДНО - МАТЕМАТИЧКИ ФАКУЛТЕТ  
НИШ**

**КЉУЧНА ДОКУМЕНТАЦИЈСКА ИНФОРМАЦИЈА**

|                                                                                                        |                                                                                                                                                                          |
|--------------------------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Редни број, <b>РБР:</b>                                                                                |                                                                                                                                                                          |
| Идентификациони број, <b>ИБР:</b>                                                                      |                                                                                                                                                                          |
| Тип документације, <b>ТД:</b>                                                                          | монографска                                                                                                                                                              |
| Тип записа, <b>ТЗ:</b>                                                                                 | текстуални / графички                                                                                                                                                    |
| Врста рада, <b>ВР:</b>                                                                                 | докторска дисертација                                                                                                                                                    |
| Аутор, <b>АУ:</b>                                                                                      | Јелена Љ. Пејић                                                                                                                                                          |
| Ментор, <b>МН:</b>                                                                                     | Марко Д. Петковић                                                                                                                                                        |
| Наслов рада, <b>НР:</b>                                                                                | Метод за генерисање линеарног распореда корелисаних елемената применом вештачке интелигенције                                                                            |
| Језик публикације, <b>ЈП:</b>                                                                          | српски                                                                                                                                                                   |
| Језик извода, <b>ЈИ:</b>                                                                               | српски/енглески                                                                                                                                                          |
| Земља публиковања, <b>ЗП:</b>                                                                          | Србија                                                                                                                                                                   |
| Уже географско подручје, <b>УГП:</b>                                                                   | Србија                                                                                                                                                                   |
| Година, <b>ГО:</b>                                                                                     | 2025.                                                                                                                                                                    |
| Издавач, <b>ИЗ:</b>                                                                                    | ауторски репринт                                                                                                                                                         |
| Место и адреса, <b>МА:</b>                                                                             | Ниш, Вишеградска 33.                                                                                                                                                     |
| Физички опис рада, <b>ФО:</b><br><small>(поглавља/страна/ цитата/табела/слика/графика/прилога)</small> | 6/114/145/31/39/0/1                                                                                                                                                      |
| Научна област, <b>НО:</b>                                                                              | Рачунарске науке                                                                                                                                                         |
| Научна дисциплина, <b>НД:</b>                                                                          | Вештачка интелигенција                                                                                                                                                   |
| Предметна одредница/Кључне речи, <b>ПО:</b>                                                            | Вештачка интелигенција, конволуционе неуронске мреже, просторно резоновање, дизајнирање распореда, генерисање ентеријера, прецизно пчеларство, предикција тежине кошнице |
| <b>УДК</b>                                                                                             | 519.852 : 004.8                                                                                                                                                          |
| Чува се, <b>ЧУ:</b>                                                                                    | библиотека                                                                                                                                                               |
| Важна напомена, <b>ВН:</b>                                                                             |                                                                                                                                                                          |

|                                   |                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                  |
|-----------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Извод, <b>ИЗ:</b>                 | <p>Циљ ове дисертације је формално дефинисање и решавање проблема линеарног распоређивања корелираних елемената, који се јавља у бројним доменама. Као решење, предложен је метод заснован на конволуционим неуронским мрежама, који користи иновативан начин кодирања података путем вишеканалних бинарних низова. Овакав приступ омогућава ефикасно учење просторних односа и рад са прецизним димензијама и у случајевима када је количина података ограничена.</p> <p>Развијен је скуп података за тестирање способности просторног резоновања. Експерименталним анализама утврђено је да предложени метод успешно учи основне просторне релације и надмашује постојеће приступе, нарочито у условима са малим бројем примера за тренирање.</p> <p>Метод је примењен у два домена: архитектури, где је коришћен за аутоматско генерисање распореда елемената у линеарним кухињама, и пчеларству, где је примењен на проблему предвиђања промене тежине кошнице на основу метеоролошких података. У оба случаја потврђена је његова применљивост и робусност.</p> <p>Дисертација тиме доприноси формализацији важног практичног проблема, развоју генеричког метода за његово решавање, креирању евалуационих скупова података и демонстрацији широке применљивости у реалним окружењима.</p> |
| Датум прихватања теме, <b>ДП:</b> | 23.09.2022                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                       |
| Датум одбране, <b>ДО:</b>         |                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                  |
| Чланови комисије, <b>КО:</b>      | <div>Председник:</div> <div>Члан:</div> <div>Члан, ментор:</div>                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                 |



**ПРИРОДНО - МАТЕМАТИЧКИ ФАКУЛТЕТ  
НИШ**

**KEY WORDS DOCUMENTATION**

|                                                                                              |                                                                                                                                                                                                                                                                                                                 |
|----------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Accession number, <b>ANO</b> :                                                               |                                                                                                                                                                                                                                                                                                                 |
| Identification number, <b>INO</b> :                                                          |                                                                                                                                                                                                                                                                                                                 |
| Document type, <b>DT</b> :                                                                   | monograph                                                                                                                                                                                                                                                                                                       |
| Type of record, <b>TR</b> :                                                                  | textual / graphic                                                                                                                                                                                                                                                                                               |
| Contents code, <b>CC</b> :                                                                   | doctoral dissertation                                                                                                                                                                                                                                                                                           |
| Author, <b>AU</b> :                                                                          | Jelena Lj. Pejić                                                                                                                                                                                                                                                                                                |
| Mentor, <b>MN</b> :                                                                          | Marko D. Petković                                                                                                                                                                                                                                                                                               |
| Title, <b>TI</b> :                                                                           | Method for linear layout generation of correlated elements using artificial intelligence                                                                                                                                                                                                                        |
| Language of text, <b>LT</b> :                                                                | Serbian                                                                                                                                                                                                                                                                                                         |
| Language of abstract, <b>LA</b> :                                                            | English                                                                                                                                                                                                                                                                                                         |
| Country of publication, <b>CP</b> :                                                          | Serbia                                                                                                                                                                                                                                                                                                          |
| Locality of publication, <b>LP</b> :                                                         | Serbia                                                                                                                                                                                                                                                                                                          |
| Publication year, <b>PY</b> :                                                                | 2025                                                                                                                                                                                                                                                                                                            |
| Publisher, <b>PB</b> :                                                                       | author's reprint                                                                                                                                                                                                                                                                                                |
| Publication place, <b>PP</b> :                                                               | Niš, Višegradska 33.                                                                                                                                                                                                                                                                                            |
| Physical description, <b>PD</b> :<br>(chapters/pages/ref./tables/pictures/graphs/appendixes) | 6/114/145/31/39/0/1                                                                                                                                                                                                                                                                                             |
| Scientific field, <b>SF</b> :                                                                | Computer Science                                                                                                                                                                                                                                                                                                |
| Scientific discipline, <b>SD</b> :                                                           | Artificial Intelligence                                                                                                                                                                                                                                                                                         |
| Subject/Key words, <b>S/KW</b> :                                                             | Artificial intelligence, convolutional neural networks, spatial reasoning, layout design, interior design, precision beekeeping, hive weight prediction Artificial intelligence, convolutional neural networks, spatial reasoning, layout design, interior design, precision beekeeping, hive weight prediction |
| <b>UC</b>                                                                                    | 519.852 : 004.8                                                                                                                                                                                                                                                                                                 |
| Holding data, <b>HD</b> :                                                                    | library                                                                                                                                                                                                                                                                                                         |
| Note, <b>N</b> :                                                                             |                                                                                                                                                                                                                                                                                                                 |

|                                                   |                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                      |
|---------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Abstract, <b>AB</b> :                             | <p>The aim of this dissertation is to formally define and address the problem of linear arrangement of correlated elements, which appears across numerous domains. As a solution, a method based on convolutional neural networks is proposed, utilizing an innovative data encoding approach through multichannel binary sequences. This approach enables efficient learning of spatial relationships and precise dimensional reasoning, even under conditions of limited data availability.</p> <p>A dataset was developed for evaluating the spatial reasoning capabilities of machine learning models. Experimental analyses demonstrated that the proposed method successfully learns fundamental spatial relations and outperforms existing approaches, particularly in scenarios with a small number of training examples.</p> <p>The method was applied in two domains: architecture, where it was used for automatic generation of linear kitchen layouts, and beekeeping, where it was applied to the problem of predicting hive weight changes based on meteorological data. In both cases, its applicability and robustness were confirmed.</p> <p>The dissertation thus contributes to the formalization of an important practical problem, the development of a generic method for its solution, the creation of evaluation datasets, and the demonstration of its broad applicability in real-world environments.</p> |
| Accepted by the Scientific Board on, <b>ASB</b> : | 23.09.2022                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                           |
| Defended on, <b>DE</b> :                          |                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                      |
| Defended Board, <b>DB</b> :                       |                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                      |
| President:                                        |                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                      |
| Member:                                           |                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                      |
| Member, Mentor:                                   |                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                                      |





*Disertaciju posvećujem:*

*roditeljima – koji su me naučili da sanjam,*

*bratu – sa kojim sam sanjala,*

*Dariji, Mariji, Mihajlu i Petru – sa kojima ostvarujem svoje snove.*



# Sadržaj

|                                                                                                               |           |
|---------------------------------------------------------------------------------------------------------------|-----------|
| <b>Predgovor</b>                                                                                              | <b>1</b>  |
| <b>1 Uvod</b>                                                                                                 | <b>5</b>  |
| 1.1 Raspored korelisanih elemenata . . . . .                                                                  | 5         |
| 1.2 Linearni raspored korelisanih elemenata . . . . .                                                         | 6         |
| 1.3 Značaj i izazovi generisanja rasporeda korelisanih elemenata . . . . .                                    | 6         |
| <b>2 Metodologija generisanja linearnog rasporeda korelisanih elemenata</b>                                   | <b>9</b>  |
| 2.1 Postojeći pristupi raspoređivanja korelisanih elemenata . . . . .                                         | 9         |
| 2.2 Formulacija problema . . . . .                                                                            | 10        |
| 2.3 LinLayCNN metod za generisanje linearnog rasporeda zasnovan na konvolucionim neuronskim mrežama . . . . . | 12        |
| 2.3.1 Opis metoda . . . . .                                                                                   | 12        |
| 2.3.2 Postupak generisanja kompletnog rasporeda . . . . .                                                     | 13        |
| 2.3.3 Arhitektura neuronske mreže . . . . .                                                                   | 14        |
| 2.3.4 Inovativna arhitektura ulaznog i izlaznog sloja . . . . .                                               | 14        |
| <b>3 Prostorno rezonovanje i LinSpaRes skup podataka</b>                                                      | <b>17</b> |
| 3.1 Problem prostornog rezonovanja . . . . .                                                                  | 17        |
| 3.2 Postojeći skupovi podataka za evaluaciju prostornog rezonovanja . . . .                                   | 18        |
| 3.3 LinSpaRes - skup linearnih rasporeda . . . . .                                                            | 18        |
| 3.3.1 Dizajniranje tipova rasporeda . . . . .                                                                 | 19        |
| 3.3.2 Generisanje tipova rasporeda . . . . .                                                                  | 22        |
| 3.4 Metod evaluacije . . . . .                                                                                | 23        |
| 3.4.1 Metrike podudaranja . . . . .                                                                           | 23        |
| 3.4.2 Metrike prostornih relacija . . . . .                                                                   | 24        |
| 3.4.3 Metrike na nivou rasporeda i skupa podataka . . . . .                                                   | 26        |
| 3.5 Raznovrsnost LinSpaRes skupa podataka . . . . .                                                           | 26        |
| <b>4 Analiza performansi i prostornog rezonovanja metoda</b>                                                  | <b>27</b> |
| 4.1 Struktura i analiza skrivenih slojeva konvolucione neuronske mreže . . .                                  | 27        |
| 4.2 Poređenje metoda sa postojećim pristupima . . . . .                                                       | 29        |
| 4.3 Skalabilnosti metoda . . . . .                                                                            | 30        |
| 4.4 Performanse metoda u 2D prostoru . . . . .                                                                | 31        |
| 4.5 Evaluacija sposobnosti prostornog rezonovanja metoda . . . . .                                            | 33        |

|          |                                                                                                         |           |
|----------|---------------------------------------------------------------------------------------------------------|-----------|
| 4.5.1    | Postavka eksperimenata . . . . .                                                                        | 33        |
| 4.5.2    | Evaluacija performansi na pojedinačnim tipovima prostornih relacija . . . . .                           | 33        |
| 4.5.2.1  | Topološke relacije . . . . .                                                                            | 33        |
| 4.5.2.2  | Direkzione relacije . . . . .                                                                           | 40        |
| 4.5.2.3  | Relacije udaljenosti . . . . .                                                                          | 41        |
| 4.5.2.4  | Iterativno dodavanje objekata . . . . .                                                                 | 42        |
| 4.5.3    | Diskusija . . . . .                                                                                     | 42        |
| 4.6      | Zaključak . . . . .                                                                                     | 44        |
| <b>5</b> | <b>Primena metoda na arhitektonskom problemu generisanja linearnog kuhinjskog rasporeda</b>             | <b>47</b> |
| 5.1      | Opšti problem raspoređivanja nameštaja . . . . .                                                        | 48        |
| 5.2      | Osnove organizacije kuhinjskog prostora . . . . .                                                       | 50        |
| 5.3      | LinKitLay - skup podataka sa linearnim kuhinjskim rasporedima . . . .                                   | 53        |
| 5.3.1    | Metod evaluacije . . . . .                                                                              | 56        |
| 5.4      | Metod za raspoređivanje kuhinjskih elemenata zasnovan na pravilima (engl. <i>rule-based</i> ) . . . . . | 57        |
| 5.4.1    | Opis metoda . . . . .                                                                                   | 57        |
| 5.4.2    | Softver . . . . .                                                                                       | 59        |
| 5.4.3    | Rezultati . . . . .                                                                                     | 61        |
| 5.5      | PKG metod zasnovan na sekvencijalnom nizu klasifikatora mašinskog učenja . . . . .                      | 61        |
| 5.5.1    | Opis metoda . . . . .                                                                                   | 61        |
| 5.5.2    | Rezultati . . . . .                                                                                     | 66        |
| 5.5.3    | Diskusija . . . . .                                                                                     | 73        |
| 5.6      | Metod LinlayCNN za generisanje linearnog kuhinjskog rasporeda . . .                                     | 74        |
| 5.6.1    | Opis metoda . . . . .                                                                                   | 74        |
| 5.6.1.1  | Formulacija problema . . . . .                                                                          | 74        |
| 5.6.1.2  | Transformacija ulaznih karakteristika i ciljnih vrednosti                                               | 74        |
| 5.6.1.3  | Iterativno generisanje rasporeda . . . . .                                                              | 75        |
| 5.6.2    | Rezultati . . . . .                                                                                     | 76        |
| 5.6.3    | Diskusija . . . . .                                                                                     | 77        |
| 5.7      | Zaključak . . . . .                                                                                     | 77        |
| <b>6</b> | <b>Primena metoda na poljoprivrednom problemu predviđanja promene težine košnice</b>                    | <b>79</b> |
| 6.1      | Značaj pčela i osnove pčelarstva . . . . .                                                              | 79        |
| 6.2      | Precizno pčelarstvo . . . . .                                                                           | 80        |
| 6.2.1    | Uređaji za precizno pčelarstvo . . . . .                                                                | 80        |
| 6.2.2    | Primena veštačke inteligencije . . . . .                                                                | 81        |
| 6.3      | Podaci u pčelarstvu: specifičnosti, ograničenja i izvori . . . . .                                      | 81        |
| 6.4      | Definicija problema i postojeći pristupi . . . . .                                                      | 83        |
| 6.5      | Metod LinLayCNN za predviđanje promena težine košnice . . . . .                                         | 84        |
| 6.5.1    | Opis metoda . . . . .                                                                                   | 84        |

|          |                                                                    |            |
|----------|--------------------------------------------------------------------|------------|
| 6.5.2    | Analogija prostornog i vremenskog domena . . . . .                 | 85         |
| 6.5.3    | Postavka eksperimenta . . . . .                                    | 86         |
| 6.5.3.1  | Skup podataka . . . . .                                            | 86         |
| 6.5.3.2  | Pretprocesiranje i priprema podataka . . . . .                     | 88         |
| 6.5.3.3  | Arhitektura modela i podešavanje hiperparametara . .               | 90         |
| 6.5.4    | Rezultati . . . . .                                                | 91         |
| 6.5.5    | Diskusija . . . . .                                                | 94         |
| 6.6      | Zaključak . . . . .                                                | 96         |
| <b>7</b> | <b>Zaključak</b>                                                   | <b>99</b>  |
|          | <b>Bibliografija</b>                                               | <b>101</b> |
| <b>A</b> | <b>Analiza promene težine košnica</b>                              | <b>113</b> |
| A.1      | Značenje promene težine košnice . . . . .                          | 113        |
| A.2      | Korelacija promena težine košnica na istoj mikrolokaciji . . . . . | 114        |
|          | <b>Biografija</b>                                                  | <b>117</b> |



# Predgovor

Linearno raspoređivanje elemenata predstavlja složen problem koji se javlja u različitim oblastima. Efikasno rešavanje ovog problema ima široku primenu - od svakodnevnih scenarija do tehničkih i industrijskih oblasti. Određeni problemi mogu se neposredno posmatrati kao problem linearnog raspoređivanja elemenata, često se javlja kao sastavni deo složenijih zadataka, a pojedini višedimenzionalni problemi u osnovi se svode upravo na njega.

Ipak, u dosadašnjoj literaturi, ovaj problem se najčešće posmatra posredno - u okviru specifičnih domena - bez njegovog jasnog izdvajanja i formalnog definisanja kao posebnog istraživačkog zadatka.

U ovoj disertaciji, problem linearnog raspoređivanja korelisanih elemenata prvi put je formalno definisan kao izdvojena kategorija problema. Time se omogućava generički pristup: svi problemi koji se mogu predstaviti kroz ovu definiciju mogu se rešavati jedinstvenim algoritmima, umesto da se za svaki domen razvija posebno rešenje. Pored toga, testiranjem na ovom zadatku može se steći dublje razumevanje osnovnih sposobnosti i ograničenja modela koji su razvijeni za rešavanje složenijih problema.

Za rešavanje problema generisanja linearnog rasporeda korelisanih elemenata razvijen je generički LinLayCNN metod baziran na konvolucionim neuronskim mrežama (engl. *Convolutional neural network*, CNN), imajući u vidu njihovu potvrđenu efikasnost u zadacima vizuelne obrade podataka. Pristup se odlikuje inovativnom arhitekturom ulaznog i izlaznog sloja, kojom se prostor predstavlja kroz višekanalne binarne nizove, što omogućava rad sa preciznim geometrijskim dimenzijama i učenje na ograničenim skupovima podataka.

Uobičajena praksa u istraživanjima jeste da se metode testiraju isključivo na ciljnim problemima za koje su razvijene, bez evaluacije njihovih sposobnosti na elementarnim zadacima. Čak i radovi koji pokušavaju da ocene opšte vizuelne sposobnosti modela koriste kompleksne zadatke, što može prikriti njihove osnovne slabosti. U ovoj disertaciji sistematski je kreiran LinSpaRes skup podataka za evaluaciju modela na elementarnim zadacima prostornog rezonovanja, sa ciljem da se omogući procena fundamentalnih prostornih sposobnosti - na primer, da li model zna šta je „levo” ili „desno”.

Na skupu podataka LinSpaRes sprovedena je analiza performansi standardnih CNN modela sa plitkom arhitekturom, kako bi se ispitala njihova sposobnost rešavanja osnovnih zadataka prostornog rezonovanja. Ovakva analiza dala je uvid u to koje prostorne relacije modeli uspešno savladavaju, gde nailaze na poteškoće i kako se njihova efikasnost menja u uslovima ograničene količine podataka - čime je delimično „razbije-

na” crna kutija (engl. *black box*) neuronskih mreža u kontekstu razumevanja prostora. Takođe, predloženi pristup kodiranja ulaza i izlaza kod LinlayCNN metoda pokazao se uspešnijim u poređenju sa postojećim pristupima.

Kako bi se pokazala opšta primenljivost metoda, testiran je na dva konkretna problema iz potpuno različitih oblasti: arhitekture i pčelarstva. U oblasti arhitekture razmatran je problem generisanja rasporeda linearnih kuhinja. Kako za ovaj problem ne postoje javno dostupni skupovi podataka, razvijen je novi skup podataka u saradnji sa stručnjacima iz različitih oblasti - LinKitLay. Na ovom skupu testirani su različiti pristupi, a metod LinLayCNN pokazao je najbolje performanse. U perceptualnim studijama, alat baziran na ovom metodu prepoznat je kao posebno koristan u praktičnoj primeni.

Potencijal veštačke inteligencije (engl. *Artificial Intelligence*, AI) u oblasti pčelarstva je izuzetan - naročito u kontekstu klimatskih promena, koje narušavaju ustaljene obrasce i čine tradicionalne pčelarske prakse sve manje pouzdanim. Glavni izazov u primeni veštačke inteligencije je nedostatak kvalitetnih skupova podataka, jer je potrebno podatke prikupljati dugoročno, na više lokacija i uz jasno beleženje konteksta (anotiranje). U okviru ove teze analizirani su dostupni skupovi podataka, identifikovane su njihove specifičnosti i izvršena je funkcionalna podela kako bi se omogućila njihova maksimalna iskoristivost u budućim istraživanjima. Definiše se i razmatra praktično značajan problem - predviđanje da li će težina košnice rasti u narednim danima. Predloženi LinLayCNN metod testiran je uz standardne algoritme i pokazao je konkurentne performanse, čak i pri ograničenoj količini podataka.

## Struktura disertacije

Disertacija obuhvata rezultate objavljenih naučnih radova. U nastavku je dat kratak pregled sadržaja pojedinačnih poglavlja.

Poglavlje 1: uvode se osnovni termini vezani za linearno raspoređivanje elemenata, definiše se sam problem i ukazuje se na ključne izazove u njegovom rešavanju.

Poglavlje 2: sadrži matematičku formulaciju problema linearnog raspoređivanja korelisanih elemenata. U poglavlju je opisan LinLayCNN metod zasnovan na konvolucionim neuronskim mrežama za rešavanje ovog problema.

Poglavlje 3: daje pregled problema prostornog rezonovanja. U poglavlju se definiše LinSpaRes skup podataka koji se sastoji od linearnih rasporeda elemenata i sadrži jasno definisane prostorne relacije. Definisane su i metrike za evaluaciju performansi.

Poglavlje 4: fokus je na analizi performansi i sposobnosti postornog rezonovanja predloženog metoda na LinSpaRes skupu podataka. Metod se upoređuje sa postojećim pristupima, uz analizu njegove skalabilnosti i potencijalnoj primeni u višedimenzionalnim prostorima.

Poglavlja 2, 3 i 4 zasnovana su na radu:

- Jelena Pejić, Marko Petković i Sandra Klinge. „Exploring spatial reasoning performances of CNN on linear layout dataset.” U: *Machine Learning: Science and Technology* 5.4 (2024.), str. 045056.

Poglavlje 5: prikazana je primena metoda na zadatku generisanja linearnog rasporeda kuhinjskih elemenata. Definisan je novi skup podataka - LinKitLay, razvijeni su i testirani različiti algoritmi, kao i alat za anotaciju i praktičnu primenu. Takođe su sprovedene perceptualne studije sa stručnjacima iz različitih oblasti.

Ovo poglavlje je zasnovano na radovima:

- Jelena Pejić i Petar Pejić. „Linear kitchen layout design via machine learning.” U: *AI EDAM* 36 (2022.), str. e9.
- Petar Pejić, Miodrag Mikić i Jelena Milovanović. „Automatic Rule-Based Kitchen Layout Design.” U: *PaKSoM 2019* (2019.), str. 199.

Poglavlje 6: ispituje se primenljivost metode u domenu pčelarstva, konkretno na problemu predikcije rasta težine košnice. Opisan je sam problem, analizirani su dostupni skupovi podataka, a performanse predloženog metoda upoređene su sa standardnim pristupima.

Poglavlje je zasnovano na radu:

- Jelena Pejić, Mihajlo Milovanović, Aca Božilov i Petar Pejić. „Impact of the precision beekeeping on the living environment”. U: *Facta Universitatis, Series: Working and Living Environmental Protection* (2022.), str. 049 – 061.

Koristim ovu priliku da se zahvalim mentoru, prof. dr Marku Petkoviću, koji me je svojom prijateljskom i profesionalnom podrškom zadržao na ovom putu. Takođe se zahvaljujem prof. dr Branimiru Todoroviću, koji me je uveo u svet mašinskog učenja, nastavniku Sveti Marinkoviću, koji me je uveo u svet matematike, kao i mojim dragim profesorkama i profesorima sa Departmana za Računarske nauke i kolegamicama i kolegama sa studija, zbog kojih je studiranje na Prirodno-matematičkom fakultetu bilo pravo uživanje.

Ova disertacija ne bi bila započeta da nije neizmerne podrške mojih roditelja i bratovog neprocenljivog prijateljstva. Bilo je posebno zadovoljstvo završiti je uz supruga, koji me neprestano inspiriše i pokazuje koliko vredim, i uz decu, koja su mi pokazala šta je najvrednije od svega.



# Glava 1

## Uvod

### 1.1 Raspored korelisanih elemenata

Raspoređivanje korelisanih elemenata je kompleksan zadatak koji se javlja u brojnim oblastima, od svakodnevnih aktivnosti do tehničkih i industrijskih primena [1]. Može se objasniti kao proces pozicioniranja različitih elemenata (mašina, opreme, nameštaja itd.) u skladu sa specifičnim kriterijumima i određenim ograničenjima. Kreiranje efikasnog rasporeda zahteva temeljno sagledavanje i precizno usklađivanje složenih i međuzavisnih odnosa između svih komponenti [2].

Termin „raspored korelisanih elemenata“ u ovoj disertaciji koristi se kao prevod široko korišćenog termina u engleskom jeziku *Layout design*, čiji bi bukvalni prevod bio „dizajniranje rasporeda“. Ovakvim prevodom naglašava se važnost međusobne zavisnosti i povezanosti elemenata unutar rasporeda. Termin „dizajn“ često se povezuje prvenstveno sa estetskim aspektima, dok funkcionalni i tehnički aspekti ponekad ostaju u senci ili se zanemaruju. Da bi dizajn bio uspešan, važno je da obuhvati i tehničke i funkcionalne zahteve, uz estetiku, kako bi se postigao optimalan rezultat. Među različitim dizajnerskim problemima, dizajniranje rasporeda tj. generisanje rasporeda korelisanih elemenata je posebno izazovan problem, pre svega zbog složenosti u identifikaciji skupa relevantnih dizajnerskih promenljivih koje definišu raspored [3]. Na primer, obrasci u prirodi kao što su formacije ptica u letu [4, 5], strukture ribljih jata [6], struktura saća [7] itd. mogu se posmatrati kao problemi dizajniranja rasporeda koji obuhvataju širok spektar dizajnerskih ciljeva [8]. Ovi prirodni obrasci i ritmovi već decenijama predstavljaju predmet istraživanja i služe kao izvor inspiracije za tehnološki razvoj, dizajn i unapređenje kvaliteta života [9].

Od grafičkih do mehaničkih sistema, zadatak raspoređivanja elemenata javlja se kao univerzalan izazov u različitim oblastima primene [10]. Na primer, planiranje rasporeda na čipovima je ključan korak u dizajnu integrisanih kola [11]. Raspoređivanje parking mesta igra ključnu ulogu u planiranju funkcionalnih i efikasnih urbanih sredina [12], automatsko kreiranje rasporeda nivoa u video igranju štedi novac i vreme [13], optimalan raspored sedenja je bio obavezan u vreme korona virusa [14, 15]. Rasporedi su ključni za efikasnu komunikaciju i usmeravanje vizuelne pažnje. Od novinskih članaka, preko časopisa, akademskih rukopisa, web sajtova, pa do raznih drugih dokumenata,

raspored vizuelnih elemenata igra ključnu ulogu u oblikovanju sadržaja i dobija najveću uredničku pažnju [16].

Planiranje rasporeda objekata, koji podrazumeva optimalno pozicioniranje elemenata u prostoru s ciljem postizanja maksimalne efikasnosti u korišćenju resursa tokom proizvodnje, ubraja se među najstarije zadatke industrijskog inženjerstva [17]. Odluke o rasporedu direktno utiče na nivoe proizvodnje, efikasnost [18], pa čak i na profitabilnost kompanije [19]. Takođe, ima ključnu ulogu u razvoju složenih elektromehaničkih proizvoda [20], povećanju proizvodnje energije [21], smanjenju troškova izgradnje [22] i smanjenju potrošnje resursa [23]. Problemi raspoređivanja prisutni su i u brojnim drugim kontekstima - od biblioteka i bolnica [24], preko dodele opreme i organizacije radionica, do planiranja novih proizvodnih postrojenja - i svi oni spadaju u domen dizajna rasporeda [25].

Generisanje efikasnog rasporeda elemenata ključno je za kreiranje virtuelnih okruženja [26], koja imaju značajnu primenu u industriji video igara, filmskoj industriji, pa čak i kod simulatora za obuku autonomnih vozila [27]. Sa porastom popularnosti virtuelne i proširene realnosti, robotike, sistema nadzora i pametnih kuća, raste i potreba za trodimenzionalnim modelima zatvorenih prostora (engl. *indoor environments*) [28], pri čemu zadaci raspoređivanja objekata - poput postavljanja nameštaja i uređaja unutar prostorija - postaju sve značajniji [29].

## 1.2 Linearni raspored korelisanih elemenata

Generisanje linearnih (jednodimenzionalnih (1D)) rasporeda bavi se postavljanjem elemenata u jednodimenzionalni prostor. Ova oblast obuhvata probleme poput planiranja rada jedne mašine [30], alokacije prostora u jednom redu (engl. *Single row facility layout*), pakovanja i sečenja materijala u jednoj dimenziji [31, 32, 33]. Linearni rasporedi, takođe, predstavljaju deo višedimenzionalnih rasporeda koji često zahtevaju poseban pristup. Na primer, kuhinje na jednom zidu ili police prepoznaju se kao specifični problemi u kreiranju unutrašnjih scena (engl. *indoor scenes*) [34, 27, 35]. S druge strane, predstavljanje objekata kroz osnovne geometrijske forme unutar jedne dimenzije pojednostavljuje prikaz i rešavanje složenih višedimenzionalnih problema [36, 37].

## 1.3 Značaj i izazovi generisanja rasporeda korelisanih elemenata

Generisanje rasporeda korelisanih elemenata predstavlja svakodnevni izazov u brojnim domenima - od arhitekture i dizajna, preko industrijskih procesa, do planiranja u logistici i planiranje izvršavanja zadataka u operativnim procesima. Automatizacija ovog procesa postaje sve važnija jer omogućava značajnu uštedu vremena i resursa. Uvođenjem metoda mašinskog učenja, naročito veštačkih neuronskih mreža, ostvaren je veliki napredak u rešavanju zadataka raspoređivanja elemenata, zahvaljujući sposobnosti modela da uče kompleksne relacije među objektima i efikasno generalizuju naučeno znanje na nove situacije [38, 39, 40]. Međutim, nedostatak kvalitetnih

označenih skupova podataka ograničava uspešnost modela u tehničkim domenima koji zahtevaju rad sa preciznim pozicijama i dimenzijama [41, 42, 43, 44]. Takođe, većina istraživanja se uglavnom bavi rešenjima specifičnim za određene oblasti, dok je generisanje linearnih rasporeda i pored velikog praktičnog značaja, retko bilo predmet direktnog proučavanja. U cilju adresiranja ovih izazova, u ovoj disertaciji predstavljen je generički metod za rešavanje različitih problema koji se mogu predstaviti kao problem linearnog raspoređivanja korelisanih elemenata, pri čemu su i dužine elemenata i njihove pozicije diskretne vrednosti. Baziran je na konvolucionoj neuronskoj mreži jer ova arhitektura pokreće većinu savremenih dostignuća u oblasti vizuelnog učenja, a njene sposobnosti za ekstrakciju karakteristika su široko prepoznate kao vrlo efikasni alati u razvoju modela [45, 46]. Poseban fokus je stavljen na 1D CNN arhitekture, koje su pokazale odlične rezultate u brojnim primenama [47]. Razvijeni metod može se efikasno trenirati i na malim skupovima podataka i primeniti u tehničkim oblastima gde su precizne dimenzije ključne. S obzirom na sve širu primenu problema raspoređivanja, ovakva generička rešenja mogu imati značajan doprinos i u naučnom i u industrijskom kontekstu.



## Glava 2

# Metodologija generisanja linearnog rasporeda korelisanih elemenata

U ovom poglavlju predstavljen je *Linear Layout CNN* (LinLayCNN) metod za generisanje linearnog rasporeda korelisanih elemenata, zasnovan na konvolucionim neuronskim mrežama. Cilj metoda je da omogući automatsko učenje prostornih relacija između objekata i obeležja u diskretnom jednodimenzionalnom prostoru i da generiše kvalitetne rasporede i u uslovima ograničene dostupnosti podataka. Definisana je opšta matematička formulacija problema generisanja linearnog rasporeda, pri čemu se LinLayCNN može primeniti na sve probleme koji se mogu predstaviti na taj način. Metod uključuje inovativnu arhitekturu ulaznog i izlaznog sloja, kojom se prostor zajedno sa obeležjima i objektima predstavlja kroz višekanalne binarne nizove. Na taj način postiže se precizno kodiranje relevantnih karakteristika i omogućava modelu da uči složene odnose između objekata i obeležja i na malom skupu podataka. Metod je koncipiran tako da se može koristiti kako za generisanje potpunog rasporeda od početka, tako i za dovršavanje delimičnih rasporeda, što ga čini fleksibilnim u različitim praktičnim primenama. Pored toga, iako je osnovna formulacija jednodimenzionalna, koncept se lako može proširiti i na višedimenzionalne rasporede kroz proširenje ulaznog prostora novim dimenzijama.

## 2.1 Postojeći pristupi raspoređivanja korelisanih elemenata

Tradicionalni metodi rešavanja problema raspoređivanja elemenata oslanjaju se na pravila i iskustvo dizajnera [19]. Pojedini autori pristupaju problemu generisanja rasporeda koristeći optimizacione metode [48, 49, 50]. Međutim, primena optimizacionih metoda često nije dovoljno efikasna kod problema sa složenim ograničenjima koje je teško predstaviti kao optimizacione [3]. U poslednjih nekoliko godina, metodi mašinskog učenja, poput veštačkih neuronskih mreža, sve više se koriste u procesu raspoređivanja elemenata [51, 40, 39, 28]. Integracija veštačke inteligencije predstavlja važan korak napred u ovoj oblasti [38]. U nekim radovima koriste se rekurentne neuronske mreže

za planiranje prostora [52]. Duboko pojačano učenje (engl. *Deep Reinforcement Learning*) se, između ostalog, koristi za postavljanje čipova [53], generisanje rasporeda nameštaja i dizajn zgrada [54]. Tehnike za sintezu realističnog sadržaja napredovale su ubrzanim tempom poslednjih godina zahvaljujući generativnim suparničkim mrežama (engl. *Generative adversarial networks*), (GAN) [55, 55] i varijacionim autoenkoderima (engl. *Variational Autoencoder*, VAE) [56, 28, 16]. Transformeri (engl. *Transformers*) su postali popularni u zadacima automatskog dovršavanja dizajna korisničkih interfejsa, kao i za generisanje unutrašnjih scena [57, 10]. U referenci [58] se predlaže model raspoređivanja elemenata koji koristi arhitekturu isključivo zasnovanu na transformerima za implementaciju uslovnog probabilističkog modela za smanjenje šuma.

Većina modela za linearno raspoređivanje elemenata u dostupnoj literaturi razvijena je za rešavanje specifičnih problema. Na primer, u radu [59] autori primenjuju skup unapred definisanih pravila za rešavanje problema raspoređivanja elemenata u jednom ili više redova. Druga grupa autora koristi principe dizajna iz konkretne oblasti kao osnovu za definisanje funkcije gubitka u procesu optimizacije [60]. Na primer, u radu [61] raspored nameštaja se automatski generiše korišćenjem principa dizajna enterijera za konstruisanje funkcije gubitka, koja se zatim optimizuje metodom pohlepne minimizacije troškova (engl. *Greedy cost minimization*). Tokom poslednjih godina, uz sve veću količinu podataka, predložene su nove metode zasnovane na podacima (engl. *data-driven*). U radu [35] predstavljena je metoda zasnovana na podacima, posebno osmišljena za raspoređivanje objekata korišćenjem barijernih funkcija i stohastičke optimizacije. U radu [27], novi rasporedi kuhinja generišu se primenom sekvence uslovnih koraka uzorkovanja, pri čemu se koriste statistike naučene iz dostupnog skupa podataka.

Mnogi savremeni pristupi generisanju rasporeda oslanjaju se na konvolucione neuronske mreže. Na primer, pojedini autori koriste sposobnost CNN arhitekture za prostorno rezonovanje na nivou piksela za razvoj metoda zasnovanih na slikama, koji se primenjuju u sintezi unutrašnjih rasporeda, grafičkom dizajnu i modelovanju gradskih saobraćajnica [62, 63, 64, 55, 34]. Graf-konvolucione neuronske mreže (engl. *Graph convolutional neural network*, GCN) koriste se u nekim radovima za modelovanje i generisanje grafičkih rasporeda (engl. *graph-based layouts*), pri čemu se elementi i njihovi odnosi predstavljaju kao čvorovi i ivice u grafu. U nekim istraživanjima kombinuju se GCN sa modelima CNN zasnovanim na slikama za sintezu osnova (engl. *floor plans*) i unutrašnjih rasporeda [65, 66]. U radu [67] za generisanje osnova koriste se konvolucione mreže za prenos poruka (engl. *message-passing*).

## 2.2 Formulacija problema

Problem generisanja linearnog rasporeda se može neformalno definisati na jednostavan način: Dat je prostor dužine  $d$  (ceo broj),  $m$  celobrojnih vrednosti koje predstavljaju pozicije važnih obeležja u prostoru (na primer, položaj električne instalacije u generisanju kuhinjskog rasporeda) i  $n$  objekata koji imaju celobrojnu dužinu  $l$ . Cilj je postaviti sve objekte u jednodimenzionalni prostor tako da se zadovolje složeni odnosi između objekata i obeležja. Formalno, problem definišemo na sledeći način: Pretpostavimo da

je prostor  $S$  modelovan segmentom na jednodimenzionalnoj mreži, formiranoj tačkama sa celobrojnim koordinatama. To znači da su dužine i položaji svih objekata i obeležja celobrojne vrednosti. U tom smislu, pretpostavljamo da je skup  $S$  definisan kao:

$$S = [l, r] = \{l, l + 1, \dots, r\}. \quad (2.1)$$

U ostatku rada, za date cele brojeve  $i < j$ , segment  $[i, j]$  označava skup tačaka  $i \leq k \leq j$ . Nadalje, neka je  $l = left(S)$  i  $r = right(S)$ , gde označavamo levi, odnosno desni kraj segmenta  $S$ . Slično tome,  $slen(S) = r - l + 1$  označava ukupnu dužinu prostora  $S$ . Parametar  $max\_slen$  predstavlja maksimalnu moguću dužinu prostora  $S$ , odnosno, uvek pretpostavljamo da važi  $slen(S) \leq max\_slen$ .

Osim ako nije drugačije specificirano, pretpostavljamo da je  $left(S) = 0$  i  $right(S) = slen(S)$ , tj. da prostor počinje od indeksa 0.

Slično tome, uvodimo sledeće oznake za objekte i obeležja:

- Skup objekata označavamo sa  $\{O_1, O_2, \dots, O_n\}$ , a dužinu  $i$ -tog objekta  $O_i$  označavamo sa  $len(O_i)$ , za  $i = 1, 2, \dots, n$ . Takođe,  $min\_olen$  i  $max\_olen$  označavaju minimalnu i maksimalnu moguću dužinu objekta.
- Skup obeležja (engl. *Properties*) označavamo sa  $\{P_1, P_2, \dots, P_m\}$ , gde dodatno  $pos(P_j) \in S$  označava poziciju obeležja  $P_j$ , za  $j = 1, 2, \dots, m$ .

Odgovarajuće promenljive u problemu su željene pozicije objekata  $O_i$ . U tom smislu, za svako  $i = 1, 2, \dots, n$  označavamo sa:

- $left(O_i)$  - poziciju leve ivice objekta  $O_i$
- $right(O_i)$  - poziciju desne ivice objekta  $O_i$ ,
- $pos(O_i) = [left(O_i), right(O_i)] \subseteq S$ , segment prostora koji zauzima objekat  $O_i$ .

Cilj je generisati raspored svih objekata tako da budu zadovoljeni određeni uslovi (koji će biti detaljno opisani u nastavku). Ovi uslovi često uključuju relacije „levo-od“ i „desno-od“, definisane kao:

$$pt_1 is - left - to pt_2 \iff pos(pt_1) < pos(pt_2) \quad (2.2)$$

$$pt_1 is - left - to pt_2 \iff pos(pt_1) > pos(pt_2) \quad (2.3)$$

gde  $pt_1$  i  $pt_2$  mogu biti objekat  $O_i$  ili obeležje  $P_j$ .

Uzimajući sve ovo u obzir, potpuni raspored (tj. instanca problema) definiše se kao:


$$layout = (S, (pos(O_i))_{i=1}^n, (pos(P_j))_{j=1}^m). \quad (2.4)$$

## 2.3 LinLayCNN metod za generisanje linearnog rasporeda zasnovan na konvolucionim neuronskim mrežama

### 2.3.1 Opis metoda

Nedavne studije u oblasti automatskog generisanja rasporeda, poput rada [67], uglavnom se oslanjaju na metode koje zahtevaju veliku količinu podataka i bazirane su na transformer arhitekturama. Nasuprot tome, LinLayCNN metod razvijen u ovoj disertaciji zasnovan je na CNN-u i prilagođen scenarijima sa ograničenom količinom podataka. Metod je definisan kao generički, što znači da nije vezan za specifičan zadatak.

LinLayCNN omogućava raspoređivanje  $n$  jednodimenzionalnih objekata različitih dužina na pravolinijskom segmentu (jednodimenzionalnom prostoru) sa specifičnim obeležjima na različitim pozicijama. Složeni odnosi između objekata i obeležja uče se direktno iz podataka o postojećim rasporedima (engl. *data-driven approach*). LinLayCNN funkcioniše kao sekvencijalni model koji iterativno umeće objekte sve dok raspored ne bude kompletan (slika 2.1). Zahvaljujući ovom prisupu, može se koristiti kako za dovršavanje delimičnih rasporeda, tako i za generisanje rasporeda od početka. Dodatno, metod se može lako prilagoditi problemima u više dimenzija, predstavljanjem prostora putem višedimenzionalnih kanala.



Slika 2.1: Pregled LinLayCNN metoda za generisanje linearnog rasporeda korelisanih elemenata. U svakoj iteraciji postavlja se jedan objekat. Ulaz sa više kanala sadrži informacije o dužini prostora, pozicijama obeležja i postavljenih objekata kao i dužini objekta koji treba da bude postavljen u trenutnoj iteraciji. Dužina kanala i izlaznog sloja odgovara maksimalnoj dužini prostora. Svaki neuron izlaznog sigmoidalnog sloja predviđa verovatnoću da je određena tačka prostora zauzeta objektom koji se postavlja. Pozicija objekta određuje se na osnovu pokretnog prozora dužine objekta, kao položaj sa najvećom sumom izlaza neurona unutar prozora.

### 2.3.2 Postupak generisanja kompletnog rasporeda

Na osnovu skupa rasporeda iz konkretnog problema, LinLayCNN uči da generiše nove rasporede za zadate ulazne karakteristike. Budući da se rasporedi sastoje od jasno odvojenih objekata sa definisanim dužinama, pristup je iterativan – u svakoj iteraciji postavlja se po jedan objekat u prostor, sve dok raspored ne bude kompletiran (slika 2.1).

Ulaz za LinLayCNN u  $k$ -toj iteraciji sastoji se od delimično generisanog rasporeda do tog trenutka, koji uključuje prethodno postavljene objekte, prostorna obeležja, kao i dužinu objekta koji se u toj iteraciji postavlja. Formalnije, ulaz predstavlja odgovarajuće kodiranje sledećih elemenata:

$$S, (pred\_pos(O_i))_{i=1}^{k-1}, (pos(P_j))_{j=1}^m, len(O_k)$$

gde  $pred\_pos(O_i)$  označava segment prostora koji zauzima objekat  $O_i$  koji je već postavljen u  $i$ -toj iteraciji.

Ciljni izlaz predstavlja binarni vektor sa jedinicama na pozicijama  $pos(O_k)$  a problem je formulisan kao zadatak višelabelne klasifikacije (engl. *multi-label classification*) sa sigmoidalnim izlaznim slojem (engl. *sigmoidal layer*).

Pozicija objekta  $O_k$  određuje se pomeranjem prozora dužine  $len(O_k)$  preko sigmoidnog izlaznog sloja, pri čemu se za svaki položaj izračunava suma aktivacija neuron

unutar prozora. Položaj sa najvećom sumom predstavlja optimalnu lokaciju za postavljanje objekta.

### 2.3.3 Arhitektura neuronske mreže

Generisanje rasporeda zahteva razumevanje složenih prostornih odnosa između objekata i obeležja, zbog čega se ulaz u mrežu predstavlja kao 2D niz i kodira pomoću 1D CNN-a. Korišćene su konvolucione neuronske mreže jer su se pokazale pouzdanim u prepoznavanju i generisanju složenih vizuelnih obrazaca u mnogim vizuelnim domenima [34, 64]. Glavni gradivni blokovi mreže su konvolucionni slojevi i *max pooling* slojevi, nakon kojih slede potpuno povezani slojevi (engl. *dense layers*) i sigmoidalni sloj.

### 2.3.4 Inovativna arhitektura ulaznog i izlaznog sloja

Većina savremenih pristupa [68, 39, 58] predstavlja ulazne karakteristike (engl. *features*) kao niz realnih brojeva (engl. *float*), koji obično uključuju veličinu objekta ili druge specifične karakteristike objekta, dok izlaz predstavlja poziciju objekta izraženu kao realan broj. Pristupi za generisanje rasporeda zasnovani na CNN-u [34, 62] predstavljaaju karakteristike u prostoru piksela, ali ne pozicioniraju objekte sa precizno definisanim dimenzijama. Umesto toga, predviđa se lokacija objekta, a zatim određuju njegove dimenzije. U ovoj studiji uvodimo inovativan prostorni pristup za precizno predstavljanje objekata pomoću ulaza sa više kanala (slika 2.2). Ulazne karakteristike predstavljene su kao 2D niz i kodirane 1D CNN-om.

Pored toga, predlažemo inovativan prostorni pristup za izlazni sloj koristeći višelabelnu klasifikaciju. Ciljani izlaz je binarni vektor, gde su jedinicama označeni segmenti prostora koje zauzima objekat. Umesto predviđanja pozicije leve ivice objekta ( $left(O_k)$ ) ili centra objekta ( $O_k$ ) pomoću softmax izlaznog sloja kao u referencama [34, 62], za svaku tačku prostora model daje verovatnoću da je ta tačka zauzeta od strane objekta ( $O_k$ ), i koristi se sigmoidalni sloj. Time se omogućava aktivacija svih tačaka koje čine dužinu objekta, a ne samo jedne referentne tačke.

#### Ulaz sa više kanala

U svakoj iteraciji ulaz u model  $\{S, (pos(O_i))_{i=1}^{k-1}, (pos(P_j))_{j=1}^m, len(O_k)\}$  predstavljen je kao 1D binarni niz sa više kanala (slika 2.2). Veličina kanala je *max\_slen*. Bez gubitka opštosti, pretpostavljamo da je  $left(S) = 0$  (u opštem slučaju  $left(S)$  se oduzima od  $left(O_i), right(O_i), pos(P_j)$ ).

1D kanali su sledeći:

- Kanal dužine prostora: jedan kanal koji kodira dužinu prostora. Ako je dužina prostora *slen*, kanal je niz nula, popunjen jedinicama od početnog do krajnjeg indeksa  $[0, slen]$ .
- Kanali objekata: kanali koji kodiraju informacije o postavljenim objektima i objektima koji treba da budu postavljeni. Broj kanala za objekte je  $n * 2$  (gde je  $n$  maksimalni broj objekata). Svaki objekat ima dva kanala:

- Kanal postavljenog objekta (engl. *placed channel*): ako je objekat  $O_k$  u prostoru, kanal postavljenog objekta je niz nula popunjen jedinicama na pozicijama  $pos(O_k)$ . Ako objekat nije postavljen, kanal je niz nula.
- Kanal objekta koji treba da bude postavljen (engl. *to-be-placed channels*): za objekat koji treba da bude postavljen u trenutnoj iteraciji, ovo je niz nula popunjen jedinicama od početnog do krajnjeg indeksa  $[0, len(O_k)]$ . Za ostale objekte ovaj kanal je niz nula.
- Kanali obeležja: za obeležje  $P_j$ , kanal obeležja je niz nula sa jedinicom na indeksu  $pos(P_j)$ . Broj kanala obeležja je  $m$ , gde je  $m$  maksimalan broj obeležja.

Ukupan broj kanala je  $n_c = 1 + n * 2 + m$ . U zavisnosti od problema, maksimalna dužina prostora, maksimalan broj obeležja i maksimalan broj objekata su unapred definisani. Ulazne karakteristike su prikazane na Slici 2.2.

### Ulaz sa više kanala

|                                       |           |     |   |   |   |   |   |   |   |     |     |     |     |     |   |   |   |   |   |
|---------------------------------------|-----------|-----|---|---|---|---|---|---|---|-----|-----|-----|-----|-----|---|---|---|---|---|
| Dužina prostora                       | 1         | 1   | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1   | 1   | 1   | 1   | 1   | 1 | 1 | 0 | 0 | 0 |
| Obeležje 1                            | 0         | 0   | 0 | 0 | 0 | 1 | 0 | 0 | 0 | 0   | 0   | 0   | 0   | 0   | 0 | 0 | 0 | 0 | 0 |
| Obeležje 2                            | 0         | 0   | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1   | 0   | 0   | 0   | 0   | 0 | 0 | 0 | 0 | 0 |
| ⋮                                     |           |     |   |   |   |   |   |   |   |     |     |     |     |     |   |   |   |   |   |
| Obeležje m                            | 0         | 0   | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0   | 0   | 0   | 0   | 0   | 0 | 1 | 0 | 0 | 0 |
| Postavljeni elementi                  | Objekat 1 | 0   | 0 | 0 | 0 | 0 | 1 | 1 | 1 | 1   | 0   | 0   | 0   | 0   | 0 | 0 | 0 | 0 | 0 |
|                                       | Objekat 2 | 0   | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0   | 0   | 0   | 0   | 0   | 0 | 0 | 0 | 0 | 0 |
|                                       | ⋮         |     |   |   |   |   |   |   |   |     |     |     |     |     |   |   |   |   |   |
|                                       | Objekat n | 0   | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0   | 0   | 0   | 0   | 0   | 0 | 0 | 0 | 0 | 0 |
| Elementi koji se trenutno postavljaju | Objekat 1 | 0   | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0   | 0   | 0   | 0   | 0   | 0 | 0 | 0 | 0 | 0 |
|                                       | Objekat 2 | 1   | 1 | 1 | 1 | 1 | 0 | 0 | 0 | 0   | 0   | 0   | 0   | 0   | 0 | 0 | 0 | 0 | 0 |
|                                       | ⋮         |     |   |   |   |   |   |   |   |     |     |     |     |     |   |   |   |   |   |
|                                       | Objekat n | 0   | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0   | 0   | 0   | 0   | 0   | 0 | 0 | 0 | 0 | 0 |
| Izlazni sloj                          | 0.3       | 0.1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0.2 | 0.6 | 0.8 | 0.9 | 0.8 | 0 | 0 | 0 | 0 | 0 |

Slika 2.2: Ulazne karakteristike i izlaz iz neuronske mreže.

### Višelabelna klasifikacija

Konvolucioa neuronska mreža uči preslikavanje ulaznog niza u binarni vektor verovatnoća:

$$f_{\theta} : \mathbb{R}^{n_c \times \max\_slen} \rightarrow [0, 1]^{\max\_slen}$$

Izlaz iz mreže je vektor:

$$\mathbf{p}_{\theta} = [p_1, p_2, \dots, p_{\max\_slen}]$$

gde svaka komponenta  $p_i \in [0, 1]$  označava procenjenju verovatnoću da je pozicija  $i$  zauzeta objektom koji se trenutno postavlja. Treniranje modela vrši se minimizacijom

funkcije gubitka ukrštene entropije (engl. *cross-entropy loss*) između predikcije i ciljnog binarnog vektora.

## Glava 3

# Prostorno rezonovanje i LinSpaRes skup podataka

Prostorno rezonovanje jedna je od osnovnih komponenti prirodne inteligencije. Sposobnost prostornog rezonovanja omogućava razumevanje odnosa među objektima i njihovog položaja u prostoru, na osnovu kojih se gradi svaki složeniji zadatak, bilo da se odnosi na raspoređivanje, kretanje ili manipulaciju objekata u prostoru. Problem prostornog rezonovanja u ovom poglavlju formalizovan je kroz modularni pristup, pri čemu je predstavljen kao skup manjih, jasno definisanih i nezavisnih potproblema. Razvijen je skup podataka koji sadrži linearne rasporede elemenata, uz precizno definisane prostorne relacije među njima (npr. redosled i međusobne udaljenosti). Pored toga, uveden je i skup metrika posebno dizajniranih za evaluaciju performansi u prostornom rezonovanju, čime se obezbeđuje pouzdano i uporedivo merenje uspešnosti modela na elementarnim prostornim relacijama.

### 3.1 Problem prostornog rezonovanja

Prostorno rezonovanje predstavlja ključni aspekt ljudske inteligencije, utičući na širok spektar kognitivnih sposobnosti i praktičnih veština [69, 70]. Obuhvata sposobnost mentalne reprezentacije i manipulacije objektima i njihovim međusobnim odnosima (relacijama) u prostoru. Ova veština je od suštinskog značaja za modele mašinskog učenja kako bi mogli da razumeju i interpretiraju prostorne relacije između objekata, što je presudno za primene kao što su robotika, autonomna vožnja, analiza slika, kao i razumevanje i tumačenje prostornih odnosa na osnovu teksta [71, 72].

Uprkos značajnim naprecima u oblasti veštačke inteligencije, prostorno rezonovanje i dalje predstavlja veliki izazov za modele mašinskog učenja [73, 74]. Na primer, unapred trenirani vizuelno-jezički modeli, iako uspešni u složenim zadacima, često pokazuju slabosti u prostornom rezonovanju i lokalizaciji [75, 76]. Ovo ukazuje na potrebu za detaljnijim proučavanjem sposobnosti prostornog rezonovanja kod modela mašinskog učenja, s ciljem poboljšanja njihove tačnosti i robusnosti [77].

Ipak, većina postojećih istraživanja usmerena je na primarne vizuelne zadatke, bez eksplicitnog razmatranja prostornog rezonovanja, što naglašava potrebu za pažljivo

dizajniranim skupovima podataka koji bi omogućili evaluaciju tih sposobnosti [78]. Dizajniranje sintetičkih modela podataka je od velikog značaja kako bi se konačno shvatilo na koji način neuronske mreže uče [79]. Uprkos svojoj važnosti, postoji ozbiljan nedostatak skupova podataka koji su specifično namenjeni testiranju i unapređivanju sposobnosti prostornog rezonovanja kod modela mašinskog učenja. Postojeći skupovi podataka često obuhvataju obradu prirodnog jezika, fokusirani su na konkretne zadatke, kao što je rotacija objekata, zanemarujući druge aspekte prostornog rezonovanja [78], ili sadrže složene zadatke u kojima su višestruke prostorne relacije isprepletene [80]. Iako su ovi skupovi podataka korisni za zadatke visokog nivoa prostornog rezonovanja, nedostaje im granularnost potrebna za dijagnostikovanje specifičnih slabosti modela. Takođe, većina skupova podataka zasniva se na principima kognitivne nauke i forsira kvalitativne vizuelne relacije, dok tehničke oblasti imaju potrebu za preciznijim geometrijskim podacima [81, 80].

## 3.2 Postojeći skupovi podataka za evaluaciju prostornog rezonovanja

U domenu računarskog vida (engl. *Computer Vision*) kreirano je više skupova podataka za merenje sposobnosti prostornog rezonovanja. Postoje skupovi podataka za vizuelno odgovaranje na pitanja (engl. *Visual Question Answering (VQA)*), ali oni su u velikoj meri povezani sa obradom i razumevanjem prirodnog jezika, umesto da se fokusiraju isključivo na prostorno rezonovanje [82]. U radu [78], autori se posebno bave prostornim rezonovanjem i proučavaju kako neuronske mreže razumeju prostor. Kreirali su skup podataka koji se sastoji od IQ testova za prostorno rezonovanje. U radu [80], autori su osmislili SPARE3D skup podataka, zasnovan na principima kognitivne nauke i psihometrije, kako bi izmerili prostornu inteligenciju neuronskih mreža. Njihovi eksperimenti pokazuju da, iako su konvolucione mreže postigle nadljudske rezultate u mnogim vizuelnim zadacima, njihove performanse u prostornom rezonovanju na ovom skupu podataka su često niže od prosečnih ljudskih performansi, a ponekad čak i bližu nasumičnim pogodcima. U radu [74] predložen je metod koji značajno poboljšava rezultate na SPARE3D skupu podataka i istražuju se faktori koji utiču na osnovne performanse modela.

## 3.3 LinSpaRes - skup linearnih rasporeda

U ovom poglavlju opisan je proces sistematskog kreiranja *Linear Spatial Reasoning* (LinSpaRes) skupa podataka <sup>1</sup> koji sadrži rasporede u jednodimenzionalnom, diskretnom prostoru, i nalazi primenu u evaluaciji sposobnosti prostornog rezonovanja kod modela mašinskog učenja. Razmatramo najjednostavniju klasu problema: jednodimenzionalne rasporede, koji su donekle veštački, ali sadrže većinu karakteristika 2D i 3D problema. Analiziranje prostornog rezonovanja u kontekstu generisanja linear-

---

<sup>1</sup><https://github.com/LayoutGeneration/LinLayCNN.git>

nih rasporeda pruža jasan i pregledan okvir za razumevanje načina na koji neuronske mreže uče i predstavljaju prostorne relacije. Linearni rasporedi omogućavaju kontrolisanu složenost, što olakšava uvid u mehanizme prostornog rezonovanja, koje je potom moguće proširiti na složenije rasporede. LinSpaRes obuhvata primere koji prikazuju ključne prostorne relacije: topološke, direkcione, relacije udaljenosti i veličine. U cilju uvođenja različitih nivoa složenosti, primeri su kategorisani prema broju elemenata i vrstama prostornih relacija koje su uključene. Da bi se uklonile dodatne poteškoće i omogućilo modelima da se fokusiraju isključivo na prostorne relacije, većina rasporeda je formirana sa dva objekta i najviše jednim obeležjem. Dodavanje novih objekata ne doprinosi razumevanju prostornih sposobnosti modela, već njegovoj sposobnosti da istovremeno uzima u obzir odnose sa više objekata, što je tema za dalja istraživanja. Objekti nisu pod uticajem boja, osvetljenja ili tekstura kao na realističnim slikama, da bi se prostorno rezonovanje odvojilo od drugih ulaznih modaliteta.

LinSpaRes skup podataka je posebno osmišljen da precizno obrađuje geometrijske podatke, čime se obezbeđuje visoka tačnost u prostornoj reprezentaciji i analizi.

Skup podataka sadrži 9 tipova rasporeda, pri čemu svaki tip obuhvata 5000 primera. Rasporedi su opisani celobrojnim atributima:

$$layout = S, (pos(O_i))_{i=1}^n, (pos(P_j))_{j=1}^m \quad (3.1)$$

Za svaki tip rasporeda razvijen je algoritam za automatsko generisanje velikog broja primera (potpoglavlje 3.5).

### 3.3.1 Dizajniranje tipova rasporeda

U skupu podataka LinSpaRes fokusiramo se na sledeće prostorne relacije:

- **Topološke relacije** [83]:

- Susedstvo: objekti treba da budu jedan pored drugog,
- Preklapanje: objekti se ne smeju preklapati,
- Pripadnost: objekat mora biti unutar prostora; obeležje mora biti unutar objekta.

- **Direkcione relacije** [84]:

- s-leva/s-desna: objekat treba da bude sa leve ili desne strane drugog objekta ili obeležja.

- **Relacije udaljenosti:**

- Tačna udaljenost: postoji određeni prostor između objekata,
- Kvalitativne udaljenosti [85]:
  - što bliži/što dalji – dva objekta ili objekat i obeležje treba da budu što dalje, odnosno što bliže jedno drugom.

- **Relacije veličine:**[86, 87]:

- Kvalitativne:
  - duži/kraći.

Dizajnirano je 9 tipova rasporeda sa po 5000 primera, koji uključuju različite dizajnerske zahteve i različite vrednosti za parametre dizajna. U daljem tekstu sa, tip rasporeda (engl. *Layout type*, (LT))” označeni su podskupovi LinSpaRes skupa podataka koji sadrže primere koji pripadaju istom tipu rasporeda.

Dizajnerski zahtevi su prostorne relacije koje treba ispuniti između objekata i obeležja, a parametri dizajna su:

- maksimalna dužina prostora,
- minimalna i maksimalna dužina objekata,
- maksimalan broj objekata,
- maksimalan broj obeležja.

U cilju obezbeđivanja jasnoće i sažetosti, tipovi rasporeda sa sličnim dizajnerskim zahtevima su grupisani a za svaku kategoriju dat je objedinjeni opis:

- A. Tipovi rasporeda 1–2: Model treba iterativno da umeće  $n$  objekata jedan pored drugog, s leva na desno, pri čemu se poštuje zadato rastojanje između njih.
- B. Tipovi rasporeda 3–7: Objekat  $O_1$  je već postavljen u prostor. Zadatak modela je da postavi  $O_2$  u skladu sa zadatim dizajnerskim zahtevima.
- C. Tipovi rasporeda 8–9: Objekat  $O_1$  i obeležje  $P_1$  su već postavljeni. Model treba da nauči gde da postavi  $O_2$  kako bi zadovoljio zadate dizajnerske zahteve.

Detaljan opis svakog tipa rasporeda dat je u tabeli 3.1. U tabeli 3.2 za svaki tip rasporeda dajemo ilustracije podgrupa rasporeda formiranih na osnovu relativne pozicije  $O_2$ .

| Grupa rasporeda i tip rasporeda |     | Prostorne relacije |   |   |            |             |                 |          | Parametri dizajna |             |          |                 | Dizajnerski zahtevi                                                                                                                                    |
|---------------------------------|-----|--------------------|---|---|------------|-------------|-----------------|----------|-------------------|-------------|----------|-----------------|--------------------------------------------------------------------------------------------------------------------------------------------------------|
|                                 |     | Topološke          |   |   | Direkcione | Udaljenosti |                 | Veličine | Broj obj.         | Dužina obj. | Obeležja | Dužina prostora |                                                                                                                                                        |
|                                 |     |                    |   |   |            | Tačna       | Što-bliže-dalje |          |                   |             |          |                 |                                                                                                                                                        |
| A                               | LT1 | ✓                  | ✓ |   |            |             |                 |          | 10                | 10-60       | -        | 60-600          | 10 objekata poravnatih, počevši od leve ivice prostora                                                                                                 |
|                                 | LT2 |                    | ✓ |   | ✓          |             |                 |          | 5                 | 10-100      | -        | 50-600          | 5 objekata poravnatih sa rastućim razmakom od 10 tačaka                                                                                                |
| B                               | LT3 |                    | ✓ | ✓ |            |             |                 |          | 2                 | 10-300      | -        | 20-600          | $O_1$ i $O_2$ na različitim ivicama prostora                                                                                                           |
|                                 | LT4 |                    | ✓ | ✓ |            |             |                 | ✓        | 2                 | 10-300      | -        | 20-600          | $O_1$ nasumično pozicioniran; $O_2$ postavljen na levu ili desnu ivicu prostora gde može stati                                                         |
|                                 | LT5 |                    | ✓ | ✓ |            |             |                 | ✓        | 2                 | 10-150      | -        | 30-600          | $O_1$ nasumično pozicioniran; $O_2$ postavljen na levu ili desnu ivicu prostora tako da se maksimizira udaljenost između objekata                      |
|                                 | LT6 | ✓                  | ✓ | ✓ |            |             |                 | ✓        | 2                 | 10-150      | -        | 30-600          | $O_1$ nasumično pozicioniran; $O_2$ postavljen na levu ivicu $O_1$ ili desnu ivicu prostora, gde staje                                                 |
|                                 | LT7 | ✓                  | ✓ | ✓ |            |             |                 | ✓        | 2                 | 10-150      | -        | 30-600          | $O_1$ nasumično pozicioniran; $O_2$ postavljen na levu ili desnu ivicu $O_1$ , gde staje.                                                              |
| C                               | LT8 |                    | ✓ | ✓ |            |             |                 | ✓        | 2                 | 10-150      | 1        | 30-600          | $O_1$ i $P_1$ nasumično postavljeni; $O_2$ je što dalje od $O_1$ dok pokriva $P_1$                                                                     |
|                                 | LT9 |                    | ✓ | ✓ |            |             |                 | ✓        | 2                 | 10-150      | 1        | 30-600          | $O_1$ i $P_1$ nasumično postavljeni; $O_2$ postavljen što bliže $O_1$ dok pokriva $P_1$ . Ako ima prostora, $O_2$ i $P_1$ su sa suprotnih strana $O_1$ |

Tabela 3.1: Tabela prikazuje prostorne relacije i parametre dizajna povezane sa svakim tipom rasporeda (LT) uključenim u LinSpaRes skup podataka.





| Tip/podtip rasporeda | Primer                                                                            | Opis                                                                                                                                 |
|----------------------|-----------------------------------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------|
| LT1                  |  | 10 objekata postavljen jedan do drugog                                                                                               |
| LT2                  |  | 5 objekata je pozicionirano na odgovarajućim prostornim razmacima od 10, 20, 30 i 40 tačaka.                                         |
| LT3                  |  | O <sub>2</sub> je pozicioniran na ivici prostora nasuprot O <sub>1</sub>                                                             |
| LT4                  |  | O <sub>2</sub> je postavljen na ivici prostora gde ima dovoljno prostora za njega                                                    |
| LT5                  |  | O <sub>2</sub> je postavljen na ivici prostora koja je dalje od O <sub>1</sub>                                                       |
| LT6a                 |  | O <sub>2</sub> je postavljen na levoj ivici O <sub>1</sub>                                                                           |
| LT6b                 |  | O <sub>2</sub> je postavljen na desnoj ivici prostora.                                                                               |
| LT7                  |  | O <sub>2</sub> je postavljen na ivici O <sub>1</sub> gde ima prostora za njega                                                       |
| LT8a                 |  | O <sub>2</sub> nije postavljen ni na jednoj od ivica prostora.                                                                       |
| LT8b                 |  | O <sub>2</sub> je postavljen na ivici prostora                                                                                       |
| LT9a                 |  | O <sub>2</sub> je postavljen na ivici O <sub>1</sub> dalje od P <sub>1</sub>                                                         |
| LT9b                 |  | O <sub>2</sub> je postavljen na ivici O <sub>1</sub> bližoj P <sub>1</sub> , jer nema dovoljno prostora da bude postavljen na daljoj |
| LT9c                 |  | O <sub>2</sub> je susjed sa obeležjem P <sub>1</sub>                                                                                 |

Tabela 3.2: Vizuelne reprezentacije podtipova rasporeda formiranih na osnovu relativne pozicije  $O_2$

### 3.3.2 Generisanje tipova rasporeda

Za zadate dizajnerske zahteve, kao i minimalnu i maksimalnu dužinu objekata i prostora, ključni koraci za generisanje rasporeda su:

1. Nasumično generisati dužine objekata iz datog intervala  $[min\_olen, max\_olen]$ .
2. Nasumično generisati poziciju za  $O_1$ .
3. Na osnovu pozicije  $O_1$ , nasumično generisati dužinu prostora između  $O_1$  i  $O_2$  tako da zadovolji dizajnerske zahteve.
4. Nasumično generisati dužinu prostora između  $O_2$  i desne ivice prostora  $right(S)$  tako da zadovolji dizajnerske zahteve, a da ne premaši  $max\_slen$ .
5. U slučajevima kada u prostoru postoji obeležje, generisati njegovu poziciju tako da zadovolji dizajnerske zahteve.
6. Na 50% rasporeda primeniti simetričnu inverziju pozicija objekata i svojstava.

Generisanje rasporeda tipa 1 i 2 relativno je jednostavno i zato nije posebno opisano.

Minimalna dužina prostora je postavljena na 30, a maksimalna na 600. Eksperimentalnim putem utvrđeno je da su ove vrednosti optimalne za demonstraciju sposobnosti

prostornog rezonovanja: za veće vrednosti potrebno je više podataka za dostizanje istih performansi, dok manje vrednosti čine problem previše jednostavnim i dovode do preobučavanja (engl. *overfitting*).

U realnim problemima generisanja rasporeda, postoji više rasporeda koji zadovoljavaju iste prostorne relacije između objekata, a najbolji izbor zavisi od dizajnera i estetskih preferencija. LinSpaRes je dizajniran tako da za svaki primer rasporeda, data pozicija  $O_2$  bude jedina koja zadovoljava dizajnerske zahteve u odnosu na prisutne objekte i obeležja u prostoru.

## 3.4 Metod evaluacije

U literaturi su zastupljene različite perspektive za evaluaciju modela automatskog generisanja rasporeda [84]. U okviru ove disertacije koriste se dve perspektive za procenu kvaliteta generisanih rasporeda:

1. koliko se izlaz modela podudara sa referentnim rasporedom iz skupa podataka,
2. koliko je model uspešan u učenju prostornih relacija.

Teško je definisati jednu metriku koja u potpunosti pokriva oba aspekta. Stoga definišemo dva skupa metrika: *metrike podudaranja* i *metrike prostornih relacija*. Svaka od njih ima za cilj da predstavi jedan aspekt svake perspektive. Korišćene su standardne metrike iz literature, prilagođene jednodimenzionalnom prostoru, a dodatno su definisane i nove metrike.

Oznake koje se koriste za definisanje metrika uvedene su u poglavlju 2.2.

### 3.4.1 Metrike podudaranja

U nekim radovima [88, 89], smatra se da je važno definisati odgovarajuće metrike koje mere sličnost između generisanih i referentnih rasporeda. Stoga, za generisan i referentni raspored iz skupa podataka, za svaki objekat  $O_i$ , definišemo sledeće metrike:

$$true\_positives(O_i) = pred\_pos(O_i) \cap pos(O_i) \quad (3.2)$$

$$precision(O_i) = \frac{true\_positives(O_i)}{pred\_pos(O_i)} \quad (3.3)$$

$$recall(O_i) = \frac{true\_positives(O_i)}{len(O_i)} \quad (3.4)$$

$$F1(O_i) = \frac{precision(O_i) \cdot recall(O_i)}{precision(O_i) + recall(O_i)} \quad (3.5)$$

pri čemu su  $pos(O_i)$  i  $pred\_pos(O_i)$  segmenti prostora koje zauzima objekat  $O_i$  u referentnom rasporedu i rasporedu predviđenom od strane modela. Vrednosti ove F1 mere prikazane su u opsegu od 0 do 100 radi bolje preglednosti, što je dosledno primenjeno u celoj disertaciji.

### 3.4.2 Metrike prostornih relacija

Relacije objekta sa drugim elementima u prostoru kvantifikuju se metrikama koje se prema tipu elementa dele u tri grupe

1. metrike koje kvantifikuju relacije između dva objekta,
2. metrike koje kvantifikuju relacije između objekta i obeležja,
3. metrike koje kvantifikuju relacije između objekta i prostora.

#### Metrike koje kvantifikuju relacije između objekata

$$intersect\_area(O_i, O_j) = |pos(O_i) \cap pos(O_j)| \quad (3.6)$$

$$dist(O_i, O_j) = \max(left(O_j) - right(O_i), left(O_i) - right(O_j)) \quad (3.7)$$

$$distant(O_i, O_j) = \begin{cases} 1 & \text{if } dist(O_i, O_j) > 0 \\ 0 & \text{otherwise} \end{cases} \quad (3.8)$$

$$touching(O_i, O_j) = \begin{cases} 1 & \text{if } dist(O_i, O_j) = 0 \\ 0 & \text{otherwise} \end{cases} \quad (3.9)$$

$$intersecting(O_i, O_j) = \begin{cases} 1 & \text{if } dist(O_i, O_j) < 0 \\ 0 & \text{otherwise} \end{cases} \quad (3.10)$$

$$left(O_i, O_j) = \begin{cases} 1 & \text{if } left(O_j) - left(O_i) > 0 \\ 0 & \text{otherwise} \end{cases} \quad (3.11)$$

$$right(O_i, O_j) = \begin{cases} 1 & \text{if } left(O_j) - left(O_i) < 0 \\ 0 & \text{otherwise} \end{cases} \quad (3.12)$$

$$correct\_side(O_i, O_j) = \begin{cases} 1 & \text{if } pred\_left(O_i, O_j) = left(O_i, O_j) \\ 0 & \text{otherwise} \end{cases} \quad (3.13)$$

Metrike *left* i *right* koriste se samo u situacijama kada se objekti ne preklapaju, tj. kada je prostorni odnos „levo/desno“ jednoznačno definisan. Ovakva definicija pokazala se dovoljno informativnom za analizu prostornog rezonovanja na skupu LinSpaRes, naročito kada se koristi u kombinaciji sa ostalim metrikama.

Metrika *intersect\_area* (3.6) se zasniva na principima iz radova [55, 58, 90]. Po ugledu na metriku *Order Loss* iz [90], definisana je metrika *correct\_side* (3.13) koja proverava da li je metod postavio objekat na istu stranu drugog objekta kao u referentnom rasporedu.

### Metrike koje kvantifikuju relacije između objekta i obeležja

$$dist(O_i, P_j) = \max(pos(P_j) - right(O_i), left(O_i) - pos(P_j)) \quad (3.14)$$

$$inter\_dist(O_i, P_j) = -dist(O_i, P_j) \quad (3.15)$$

$$covering(O_i, P_j) = \begin{cases} 1 & \text{if } dist(O_i, P_j) \leq 0 \\ 0 & \text{otherwise} \end{cases} \quad (3.16)$$

$$side(O_i, P_j) = \text{sign}(pos(P_j) - left(O_i)) \quad (3.17)$$

$$correct\_side(O_i, P_j) = \begin{cases} 1 & \text{if } side(O_i, P_j) = pred\_side(O_i, P_j) \\ 0 & \text{otherwise} \end{cases} \quad (3.18)$$

### Metrike koje kvantifikuju relacije između objekta i prostora

Metrike su definisane pod pretpostavkom da prostor i pozicije objekta počinju od indeksa 0 (tj.  $left(S) = 0$  i  $right(S) = slen(S)$ ) pa su i prekoračenja objekta moguća samo u odnosu na desnu ivicu prostora.

$$dist\_left(O_i, S) = left(O_i) \quad (3.19)$$

$$dist\_right(O_i, S) = slen(S) - right(O_i) \quad (3.20)$$

$$violation(O_i, S) = right(O_i) - slen(S) \quad (3.21)$$

$$marginal(O_i, S) = \begin{cases} 1 & \text{if } dist\_right(O_i, S) = 0 \\ 0 & \text{otherwise} \end{cases} \quad (3.22)$$

$$inside(O_i, S) = \begin{cases} 1 & \text{if } dist\_right(O_i, S) > 0 \\ 0 & \text{otherwise} \end{cases} \quad (3.23)$$

$$outside(O_i, S) = \begin{cases} 1 & \text{if } dist\_right(O_i, S) < 0 \\ 0 & \text{otherwise} \end{cases} \quad (3.24)$$

Iako je metrika *Intersection over Union* (IoU) široko korišćena u literaturi [89, 88, 91], u ovoj tezi fokus je na metrikama koje potiču iz svih definisanih grupa, kako bi se omogućilo međusobno poređenje različitih aspekata na ujednačenoj skali (npr. razmaka i preseka između objekata). Pošto je za takvo poređenje potrebno da sve metrike budu izražene u istim jedinicama, IoU nije uključena u evaluaciju.

### 3.4.3 Metrike na nivou rasporeda i skupa podataka

F1 mera za raspored definiše se kao aritmetička sredina F1 mera izračunatih za svaki objekat u datom rasporedu:

$$F1_{layout} = \frac{\sum_{i=1}^n F1(O_i)}{n} \quad (3.25)$$

F1 mera na nivou celog skupa podataka definiše se kao aritmetička sredina F1 vrednosti svih rasporeda.

Metrika prostornih relacija za raspored definiše se kao aritmetička sredina vrednosti metrike za svaki par objekata  $O_i$  i  $O_{i-1}$  u rasporedu. Metrika na nivou celog skupa podataka definiše se kao aritmetička sredina metrika po rasporedima. Radi preglednosti prikaza rezultata, u ovoj disertaciji, vrednosti ove metrike su skalirane na interval od 0 do 100.

## 3.5 Raznovrsnost LinSpaRes skupa podataka

Mnogi faktori mogu uticati na performanse modela mašinskog učenja, među kojima je i raznovrsnost trening skupa (engl. *data diversity*) [92]. Veoma slični trening primeri dovode do redundancije u skupu podataka za treniranje, što dalje smanjuje efikasnost treniranja.

Kako bismo izmerili raznovrsnost podataka na LinSpaRes skupu podataka, računamo F1 meru za svaki par rasporeda  $j$  i  $k$  u svakom od 9 tipova rasporeda. F1 mera se računa kao što je opisano u potpoglavlju 3.4, pri čemu  $pred\_pos(O_i)$  i  $pos(O_i)$  predstavljaju segmente prostora koje objekat  $O_i$  zauzima u predviđenom i referentnom rasporedu. Vrednosti su date u tabeli 3.3.

|      | LT1   | LT2   | LT3   | LT4   | LT5   | LT6   | LT7   | LT8   | LT9   |
|------|-------|-------|-------|-------|-------|-------|-------|-------|-------|
| mean | 31.8  | 37.85 | 26.32 | 23.73 | 23.38 | 22.57 | 26.27 | 21.97 | 20.29 |
| std  | 17.62 | 19.70 | 25.78 | 24.77 | 23.78 | 22.23 | 21.85 | 24.01 | 21.07 |

Tabela 3.3: Tabela prikazuje raznovrsnost skupa podataka, pri čemu su date srednje vrednosti (engl. *mean*) i standardne devijacije (engl. *std*) F1 mere na svakom tipu rasporeda.

## Glava 4

# Analiza performansi i prostornog rezonovanja metoda

U ovom poglavlju vrši se eksperimentalna evaluacija metoda *LinLayCNN* na skupu podataka *LinSpaRes* (videti Poglavlje 3), sa ciljem da se kvantifikuju performanse i ispita sposobnost prostornog rezonovanja. Prikazuje se analiza arhitekture i hiperparametara, poređenje sa postojećim pristupima, ispitivanje skalabilnosti i ponašanja u 2D prostoru, kao i evaluacija učenja prostornih relacija. Zaključci sumiraju rezultate o performansama i sposobnosti prostornog rezonovanja metode.


### 4.1 Struktura i analiza skrivenih slojeva konvolucione neuronske mreže

U sprovedenim eksperimentima analizirano je kako različite konfiguracije unutrašnjih slojeva CNN-a utiču na performanse *LinLayCNN* metoda. Nedavna istraživanja [78] pokazuju da veća dimenzionalnost neuronskih mreža ne mora nužno da dovede do boljih rezultata u zadacima prostornog rezonovanja. Suprotno tome, u radu [74] istaknuto je da izbor strukture mreže zavisi pre svega od specifičnog cilja prostornog rezonovanja. Polazeći od ovih analiza, u okviru ovog poglavlja podešavani su različiti parametri: varirani su broj i tip konvolucionih slojeva, veličina filtera i kernela, raspored primene max pooling operacija (nakon svih ili samo određenih slojeva), kao i različiti brojevi potpuno povezanih slojeva neurona. Pored toga, testirane su različite veličine beča (engl. *batch sizes*), različite funkcije optimizacije i brojevi epoha.

Za testiranje je korišćen *LinSpaRes* skup podataka definisan u poglavlju 3. U tabeli 4.1 prikazane su performanse različitih arhitektura na LT1 tipu rasporeda. Koristi se F1 mera za različite veličine skupa podataka za treniranje i konfiguracije konvolucionih slojeva i filtera. Rezultati na LT1 služe kao reprezentativan primer, jer je raspodela performansi kod ovih arhitektura bila konzistentna sa rezultatima na drugim tipovima rasporeda. Za druge hiperparametre, optimalna konfiguracija uključuje 10 epoha, veličinu beča 32, Adam algoritam za optimizaciju sa stopom učenja od 0.01 i postavljanje max pooling sloja nakon poslednjeg konvolucionog sloja za sve tipove rasporeda.

| Broj slojeva | Broj filterapo sloju | Veličina trening skupa |           |           |           |           |
|--------------|----------------------|------------------------|-----------|-----------|-----------|-----------|
|              |                      | 100                    | 200       | 500       | 1000      | 4000      |
| 4            | 20,40,60,80          | 61                     | 68        | 74        | 84        | 84        |
| 4            | 20,20,20,20          | 71                     | 80        | 84        | <b>87</b> | <b>88</b> |
| 3            | 20,40,60             | 72                     | 78        | 80        | 84        | 84        |
| 3            | 20,20,20             | 70                     | 78        | 81        | 86        | 86        |
| 2            | 20,40                | 72                     | <b>81</b> | <b>86</b> | <b>87</b> | <b>88</b> |
| 2            | 20,20                | <b>75</b>              | 70        | <b>86</b> | 84        | 84        |

Tabela 4.1: Vrednosti F1 mere, za različite konfiguracije skrivenih slojeva, trenirane na skupovima različitih veličina. Podebljane su najveće vrednosti u koloni.



Slika 4.1: Arhitektura konvolucione neuronske mreže sa najboljim performansama na Lin-SpaRes skupu podataka.

Tabela 4.1 pokazuje da su najslabije performanse zabeležene kod arhitekture sa najvećim brojem slojeva i filtera, koja je dostigla performanse manjih arhitekture tek nakon obuke na 4000 primera. Arhitektura sa 4 sloja i manjim brojem kanala pokazala je konkurentne performanse na manjim skupovima za treniranje i nadmašila arhitekturu sa 3 sloja na većim skupovima podataka. S druge strane, arhitektura sa 2 sloja i kanalima 20 i 40 prikazana na slici 4.1 nadmašila je ostale modele na svim veličinama skupova podataka, osim na najmanjem skupu, gde je manja arhitektura sa kanalima 20 i 20 pokazala bolje performanse.

Rezultati ovog eksperimenta ukazuju na to da jednostavnije arhitekture - posebno modeli sa 2 sloja i odgovarajućim brojem kanala - pokazuju bolje performanse nezavisno od veličine skupa podataka. Složenije arhitekture, sa većim brojem slojeva i filtera, počinju da dostižu performanse manjih modela tek nakon što im se obez-

bedi značajno više podataka za treniranje. Ovakvi rezultati sugerišu da je pažljivo balansiranje između složenosti modela i veličine skupa podataka ključno za optimalne performanse na određenom problemu.

## 4.2 Poređenje metoda sa postojećim pristupima

Performanse predloženog sigmoidalnog izlaznog sloja LinLayCNN metoda upoređene su sa izlaznim slojevima korišćenim u prethodnim radovima, uključujući softmax sloj [34, 62] i regresioni sloj [90]. Ovakvo poređenje omogućava dublji uvid u sposobnost različitih arhitektura da rešavaju prostorne probleme sa različitim stepenima složenosti. Za testiranje je korišćen LinSpaRes skup podataka definisan u poglavlju 3.

Za svaki tip izlaznog sloja ponovljen je isti postupak evaluacije kroz sve varijante unutrašnjih slojeva kao u prethodnom potpoglavlju 4.1. Rezultati su pokazali da je, nezavisno od tipa izlaznog sloja, arhitektura sa dva skrivena sloja (prikazana na Slici 4.1) dosledno ostvarivala najbolje performanse, pa će dalja analiza biti zasnovana upravo na toj arhitekturi.

U tabeli 4.2 prikazane su vrednosti F1 mere za svaku konfiguraciju izlaznog sloja, za svaki tip rasporeda. Rezultati pokazuju da predloženi sigmoidalni izlazni sloj konzistentno nadmašuje softmax sloj na svim tipovima rasporeda, koji dostiže slične performanse samo pri treniranju na većem skupu podataka. Kod najzahtevnijih tipova rasporeda, kao što su LT9 i LT5, koji zahtevaju poređenje različitih dužina prostora, softmax izlazni sloj pokazuje loše performanse čak i pri treniranju na većim skupovima podataka.

U poređenju sa regresionim izlaznim slojem, LinLayCNN postiže bolje rezultate na svim tipovima rasporeda osim na LT1 i LT2. U ova dva slučaja, položaj objekta zavisi isključivo od desne ivice prethodno postavljenog objekta, bez dodatnih prostornih interakcija ili ograničenja. Zbog toga regresioni sloj postiže dobre rezultate, jednostavnim mapiranjem položaja objekta iz izlaznog sloja. Na LT3, gde postoje prostorne interakcije, regresioni izlazni sloj i dalje pruža zadovoljavajuće performanse, jer je potrebno samo da se objekat postavi na suprotnu stranu drugog objekta. Međutim, na složenijim tipovima rasporeda, poput LT5, gde je potrebno razumeti relativne veličine prostora, i LT8 i LT9, gde dolaze do izražaja dodatne prostorne relacije, sigmoidalni sloj značajno nadmašuje regresioni, koji pokazuje slabije rezultate čak i uz 4000 primera za treniranje.

| Izlazni sloj       | LT1       |           |           |           |           | LT2       |           |           |           |           | LT3       |           |           |           |           |
|--------------------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|
| <b>Sigmoidalni</b> | 72        | 81        | 86        | 87        | 88        | 82        | 88        | 92        | 93        | 94        | 79        | <b>92</b> | <b>97</b> | <b>98</b> | <b>99</b> |
| <b>Softmax</b>     | 56        | 63        | 75        | 81        | 89        | 73        | 79        | 85        | 89        | 93        | 77        | 86        | 89        | 92        | 94        |
| <b>Regresioni</b>  | <b>80</b> | <b>89</b> | <b>90</b> | <b>90</b> | <b>96</b> | <b>86</b> | <b>90</b> | <b>93</b> | <b>96</b> | <b>96</b> | <b>80</b> | 90        | 96        | 97        | 98        |

| Izlazni sloj       | LT4       |           |           |           |           | LT5       |           |           |           |           | LT6       |           |           |           |           |
|--------------------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|
| <b>Sigmoidalni</b> | <b>78</b> | <b>90</b> | <b>69</b> | <b>81</b> | <b>89</b> | <b>92</b> | <b>96</b> | <b>94</b> | <b>96</b> | <b>98</b> | <b>70</b> | <b>79</b> | <b>87</b> | <b>90</b> | <b>94</b> |
| <b>Softmax</b>     | 63        | 79        | 58        | 65        | 75        | 82        | 90        | 81        | 84        | 91        | 63        | 66        | 72        | 75        | 79        |
| <b>Regresioni</b>  | 59        | 65        | 44        | 55        | 68        | 76        | 85        | 71        | 80        | 85        | 39        | 41        | 49        | 57        | 64        |

| Izlazni sloj       | LT7       |           |           |           |           | LT8       |           |           |           |           | LT9       |           |           |           |           |
|--------------------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|-----------|
| <b>Sigmoidalni</b> | <b>69</b> | <b>79</b> | <b>90</b> | <b>93</b> | <b>96</b> | <b>74</b> | <b>83</b> | <b>90</b> | <b>93</b> | <b>96</b> | <b>45</b> | <b>51</b> | <b>66</b> | <b>74</b> | <b>85</b> |
| <b>Softmax</b>     | 55        | 63        | 75        | 80        | 85        | 65        | 73        | 82        | 88        | 91        | 41        | 46        | 53        | 60        | 71        |
| <b>Regresioni</b>  | 58        | 59        | 63        | 72        | 87        | 36        | 37        | 41        | 43        | 56        | 40        | 44        | 47        | 50        | 61        |

Tabela 4.2: Vrednosti F1 mere za različite konfiguracije izlaznog sloja na različitim tipovima rasporeda, pri čemu kolone predstavljaju veličine trening skupa: 100, 200, 500, 1000 i 4000 primera.

### 4.3 Skalabilnosti metoda

U ovom odeljku ocenjuje se skalabilnost LinLayCNN metoda ispitivanjem performansi pri povećanju broja objekata i povećanju dužine prostora. Cilj je da se utvrdi da li model zadržava konzistentne performanse u složenijim scenarijima. Za testiranje je korišćen LinSpaRes skup podataka definisan u poglavlju 3.

U postavci su varirane dužine prostora i broj objekata. Radi preglednosti, prikazani su rezultati arhitekture sa slike 4.1, budući da su alternativne arhitekture dosledno ostvarivale slabije performanse, uz zadržavanje istog relativnog odnosa u svim postavkama.

Analize su rađene na LT1 i LT9, koji pokrivaju čitav spektar složenosti - od jednostavnog dizajnerskog zahteva (LT1) do najsloženijih (LT9).

Tabela 4.3 prikazuje vrednosti F1 mere na LT1, za različite brojeve objekata unutar fiksne dužine prostora od 600 jedinica. Rezultati ukazuju na to da, kako se broj objekata povećava, potrebno je više primera za obuku da bi se održao isti nivo performansi koji je postignut sa manjim brojem objekata. Ovaj aspekt skalabilnosti naglašava važnost dodatnih podataka kako bi se održale performanse modela sa većem brojem objekata.

Tabela 4.4 prikazuje kako se performanse menjaju sa povećanjem dužine prostora, dok broj objekata varira između 10 i 20. Performanse modela ostaju stabilne uprkos povećanju dužine prostora, što ukazuje na sposobnost generalizacije na različite dimenzije prostora. Kao i u prethodnim analizama, veći broj objekata zahteva više primera za treniranje kako bi se održale optimalne performanse.

S druge strane, rezultati na LT9 za različite dužine prostora ukazuju na to da, kod složenijih rasporeda, povećanje dužine prostora zahteva i više trening primera kako bi se postigao isti nivo performansi (tabela 4.5). Na primer, za dužinu prostora od 3000, potrebno je 4000 trening primera da bi se postigle iste performanse metoda koje se postižu sa 1000 trening primera na prostoru dužine 600.

| Broj objekata | Veličina trening skupa |     |     |      |      |
|---------------|------------------------|-----|-----|------|------|
|               | 100                    | 200 | 500 | 1000 | 4000 |
| <b>3</b>      | 83                     | 89  | 93  | 95   | 97   |
| <b>5</b>      | 82                     | 88  | 92  | 93   | 94   |
| <b>10</b>     | 72                     | 77  | 79  | 84   | 87   |

Tabela 4.3: Vrednosti F1 mere na LT1, za različit broj objekata i veličine trening skupa

| Dužina prostora | Broj objekata          |     |     |      |      |                        |     |     |      |      |
|-----------------|------------------------|-----|-----|------|------|------------------------|-----|-----|------|------|
|                 | 10                     |     |     |      |      | 20                     |     |     |      |      |
|                 | Veličina trening skupa |     |     |      |      | Veličina trening skupa |     |     |      |      |
|                 | 100                    | 200 | 500 | 1000 | 4000 | 100                    | 200 | 500 | 1000 | 4000 |
| 600             | 72                     | 81  | 86  | 87   | 88   | 57                     | 65  | 68  | 73   | 74   |
| 1200            | 73                     | 75  | 79  | 85   | 89   | 55                     | 66  | 67  | 72   | 75   |
| 3000            | 69                     | 77  | 81  | 86   | 90   | 52                     | 63  | 65  | 73   | 76   |

Tabela 4.4: Vrednosti F1 mere na LT1, za različit broj objekata, dužine prostora i različite veličine trening skupa

| Dužina prostora | Veličina trening skupa |     |     |      |      |
|-----------------|------------------------|-----|-----|------|------|
|                 | 100                    | 200 | 500 | 1000 | 4000 |
| 600             | 45                     | 51  | 66  | 74   | 85   |
| 1200            | 40                     | 46  | 57  | 66   | 82   |
| 3000            | 39                     | 39  | 46  | 59   | 73   |

Tabela 4.5: Vrednosti F1 mere na LT9 za različite dužine prostora.

## 4.4 Performanse metoda u 2D prostoru

Za procenu performansi metoda u višedimenzionalnom prostoru, kreirani su skupovi koji obuhvataju dva tipa dvodimenzionalnih rasporeda: LT2D1 sa veličinom prostora  $50 \times 50$  i LT2D2 sa veličinom prostora  $80 \times 80$  (tabela 4.6). Kod oba tipa rasporeda, zahtev je da se jedan pravougaoni objekat pozicionira na donju-desnu ivicu drugog objekta. Za 2D prostore, metoda LinLayCNN je primenjena tako što je dodatna dimenzija uključena u prostor ulaznih karakteristika i izlazni sloj. Svaki piksel predstavlja koordinatu u 2D prostoru, gde vrednosti jedan označavaju pozicije koje zauzima objekat, a vrednosti nula ostale pozicije.

Primenom metodologije iz potpoglavlja 4.1 utvrđena je optimalna CNN arhitektura za ovaj zadatak i prikazana na slici 4.2. Uspešnost LinLayCNN metoda na 2D skupovima LT2D1 i LT2D2 izražena je putem F1 mere a rezultati su prikazani u tabeli 4.7.


Direktno poređenje sa rezultatima na LinSpaRes skupu podataka nije moguće, jer kod 2D tipova rasporeda postoji dodatna prostorna relacija - gore/dole. Ipak, kao referentna tačka korišćen je skup LT6, koji obuhvata sve linearne prostorne relacije prisutne u 2D rasporedima. Rezultati iz tabele 4.7 pokazuju da kada je površina prostora približno ista za oba skupa podataka (600 jedinica kod LT6 i  $80 \times 80$  kod LT2D2) performanse LinLayCNN-a u 2D prostoru dostižu nivo postignut u 1D prostoru tek sa 4000 trening primera. Međutim, za prostore manje površine ( $50 \times 50$  kod LT1D), performanse su ujednačene kod 1D i 2D rasporeda za sve veličine trening skupa. Ova analiza sugerise da povećanje prostorne dimenzionalnosti zahteva veći broj trening primera kako bi se za istu površinu prostora postigle jednake performanse metoda.

| Tip rasporeda | Prostorne relacije |             |              |             | Promenljive dizajna |                 |                 | Dizajnerski zahtevi                                                                      |
|---------------|--------------------|-------------|--------------|-------------|---------------------|-----------------|-----------------|------------------------------------------------------------------------------------------|
|               | Susedstvo          | Preklapanje | S leva/desna | Iznad/ispod | Broj objekata       | Dužina objekata | Dužina prostora |                                                                                          |
| LT2D1         | ✓                  | ✓           | ✓            | ✓           | 2                   | 10-40           | 50x50           | $O_1$ postavljen negde u prostoru, $O_2$ treba biti postavljen uz donji desni ugao $O_1$ |
| LT2D1         |                    |             |              |             |                     | 10-70           | 80x80           |                                                                                          |

Tabela 4.6: Tabela prikazuje karakteristike različitih tipova 2D rasporeda

| Tip rasporeda | Veličina trening skupa |     |     |      |      |
|---------------|------------------------|-----|-----|------|------|
|               | 100                    | 200 | 500 | 1000 | 4000 |
| LT2D1         | 74                     | 81  | 91  | 96   | 99   |
| LT2D2         | 72                     | 64  | 73  | 78   | 96   |
| LT6           | 69                     | 81  | 89  | 92   | 96   |

Tabela 4.7: Performanse LinLayCNN metoda na 1D i 2D skupovima rasporeda prikazane kroz F1 meru



Slika 4.2: Arhitektura konvolucione neuronske mreže sa najboljim performansama na skupu 2D rasporeda.

## 4.5 Evaluacija sposobnosti prostornog rezonovanja metoda

U ovom potpoglavlju analizirane su sposobnosti LinLayCNN metoda za učenje prostornih relacija. Analizirano je kako metod uči pojedinačne prostorne relacije i kako se njegove performanse menjaju u zavisnosti od veličine skupa podataka za treniranje.

### 4.5.1 Postavka eksperimenata

#### Skup podataka i metrike

LinLayCNN metod je evaluiran na LinSpaRes skupu podataka korišćenjem metrika definisanim u potpoglavlju 3.4. Radi preglednost, sve kategoričke metrike skalirane su na interval od 0 do 100. Trening i evaluacija metoda sprovedene su zasebno za svaki tip linearnog rasporeda (LT).

#### Veličine trening i test skupa

Kod ljudi, sticanje veština prostornog rezonovanja obično ne zahteva puno podataka za učenje [78]. Iz tog razloga, u eksperimentima je analizirano kako veličina skupa za treniranje utiče na performanse LinLayCNN. Shodno tome, u svakom eksperimentu, nasumično je izabrano 1000 primera za testiranje dok je metoda trenirana na podskupovima veličine 100, 200, 500, 1000 i 4000 primera. Ova procedura ponavlja se pet puta, a ukupna efikasnost metoda dobijena je kao prosečna vrednost metrika u svakom puštanju.

#### Implementacija

Svi eksperimenti su implementirani u programskom jeziku Python, korišćenjem Keras biblioteke za implementaciju neuronskih mreža.

### 4.5.2 Evaluacija performansi na pojedinačnim tipovima prostornih relacija

Najpre su pokazane performanse LinLayCNN metode na svakoj prostornoj relaciji pojedinačno. Zatim je analizirana uspešnost iterativnog pristupa dodavanja objekata. Na kraju je data detaljna analiza celokupnih rezultata.


#### 4.5.2.1 Topološke relacije

##### Relacija susedstva

Sposobnost LinLayCNN metoda da nauči relaciju susednosti analizirana je na rasporedima koji uključuju dizajnerske zahteve da objekat bude postavljen uz drugi objekat, obeležje ili ivicu prostora.

### a) Susjedstvo sa objektom


Na Slici 4.3 prikazano je da LinLayCNN postiže najviše vrednosti metrike *touching* na LT1, gde je zahtev isključivo postavljanje objekta uz desnu ivicu drugog objekta. Na LT6 i LT7, koji uključuju dodatne dizajnerske zahteve, vrednosti su niže. Najniže vrednosti uočene su na LT9, gde dodatna složenost u vidu uključivanja obeležja značajno otežava proces donošenja odluka.



Slika 4.3: Metrika *touching* na LT1, LT6a, LT7, LT9a i LT9b za različite veličine trening skupa.


Slika 4.4 ilustruje odnos između metrika *distant* i *intersecting* na test primerima na kojima LinLayCNN greši, i ne postavlja objekat tačno uz drugi objekat, kao u referentnom rasporedu. Kod trening skupa sa 100 primera, kroz sve tipove rasporeda, vrednosti ovih metrika su gotovo jednake, što ukazuje na to da su verovatnoće preklapanja ili udaljavanja objekata približno jednake. Na LT1, gde je jedini zahtev postavljanje objekata uz drugi objekat, odnos ostaje nepromenjen bez obzira na veličinu trening skupa, dok na LT6a, LT7 i LT9, kako broj trening primera raste, algoritam pokazuje sklonost ka udaljavanju objekata u odnosu na preklapanje, verovatno zbog dodatnih dizajnerskih zahteva kod ovih tipova rasporeda. Na LT6, kod polovine trening primera objekti treba da budu maksimalno udaljeni, što objašnjava izraženiju preferenciju ka udaljavanju objekata. LT7 je dizajniran tako da objekti uvek budu susedni, ali samo jedna strana pruža dovoljno prostora za postavljanje drugog objekta, što se može se tumačiti i kao zahtev za susjedstvo objekata uz istovremeno udaljavanje od najbliže ivice prostora. Ovakva postavka objašnjava zašto LT7, sa 4000 trening primera, favorizuje udaljavanje objekata u odnosu na preklapanje. Na LT9, dodatni zahtev za maksimiziranje udaljenosti objekta od obeležja rezultira češćim preklapanjem objekata kako bi zahtev bio zadovoljen.

Slika 4.5 prikazuje odnos metrika *intersection\_area* i  $\text{dist}(O_2, O_1)$ . Kod svih tipova rasporeda prosečna udaljenost između objekata veća je od njihove prosečne preklapljenosti, što je očekivano s obzirom na to da je udaljavanje dominantan zahtev kod većine primera. Na LT1, LT6 i LT7, sa 4000 trening primera, vrednosti obe metrike konvergi-




Slika 4.4: Odnos metrika *distant* i *intersecting* na LT1, LT6a, LT7 i LT9 za različite veličine trening skupa.

raju ka jedinici. Međutim, kod LT6 i LT7 učenje se odvija znatno sporije, metrike duže ostaju na višim vrednostima.




Slika 4.5: Odnos metrika *intersection\_area* i  $dist(O_2, O_1)$  na LT1, LT6, LT7 i LT9 za različite veličine trening skupa.

Na slici 4.6 prikazani su kutija dijagrami (engl. *boxplot*) za metriku  $dist(O_2, O_1)$ . Sa grafikona je očigledno da LT9 sadrži veliki broj autlajera (engl. *outlier*), što su verovatno primeri kod kojih LinLayCNN pogrešno odlučuje da ne postavi objekte jedan pored drugog. Ovo zapažanje dodatno potvrđuje i slika 4.7, na kojoj je F1 mera značajno niža na LT9. Medijana je blizu nule za sve rasporede sa 1000 primera, što ukazuje na to da, kada LinLayCNN ima za cilj da postavi objekte jedan do drugog, greške koje pravi nisu značajne.



Slika 4.6: Dijagrami za metriku  $dist(O_2, O_1)$  na LT6, LT7, LT9a i LT9b za različite veličine trening skupa.




Slika 4.7: F1 mera za sve tipove rasporeda za različite veličine trening skupa.

### b) Susjedstvo sa obeležjem

Na LT9c, LinLayCNN bi trebalo da postavi  $O_2$  uz obeležje. Slika 4.8 ilustruje da metod pravi veću grešku kada ih udalji, nego kada ih preklopi. Poređenjem slika 4.5 i 4.8 uočavaju se slični obrasci u odnosu između metrika  $intersection\_area$  i  $dist(O_2, O_1)$  koje mere preklapanje i udaljenost objekata, kao i između metrika  $inter-distance$  i  $dist(O_2, P_1)$ , koje mere udaljenost i preklapanje objekta i obeležja. Ovo ukazuje da metod koristi sličan osnovni mehanizam za učenje relacije susjedstva, bilo između objekata ili između objekta i obeležja.

### c) Susjedstvo sa ivicom prostora

Kod LT6, dizajnerski zadatak je postavljanje  $O_2$  na levu ivicu  $O_1$ , ukoliko postoji dovoljno prostora. Ukoliko to nije moguće, objekat se pozicionira uz desnu ivicu prostora. Tabela 4.8 prikazuje gotovo identične vrednosti metrika  $marginal$  i  $touching$  za



Slika 4.8: Metrike  $inter\_distance(O_2, P_1)$  i  $dist(O_2, P_1)$  na LT8a i LT9c

|                 |      |      |      |      |       |
|-----------------|------|------|------|------|-------|
| <b>Marginal</b> | 0.67 | 1.65 | 5.00 | 8.97 | 15.00 |
| <b>Touching</b> | 1.24 | 1.83 | 6.17 | 8.66 | 13.98 |

Tabela 4.8: Poređenje metrika  $marginal$  i  $touching$

sve veličine trening skupa, što implicira da se ivice prostora i objekata percipiraju na sličan način.

Na LT3, LT4 i LT5, već sa 500 trening primera, gotovo u 100 % test primera je  $O_2$  postavljen tačno na levu ivicu prostora, što ukazuje da metod na osnovu malog broja trening primera uči da precizno postavlja objekat na levu ivicu tj. početak prostora.

## Relacija preklapanja

Posebno su analizirane relacije preklapanja sa objektom i sa obeležjem.


### a) Preklapanje sa objektom

Kod rasporeda koji, pored zahteva za postavljanjem objekata jedan uz drugi, sadrže i dodatne uslove, LinLayCNN češće odlučuje da udalji objekte nego da ih preklopi (slika 4.4).

Kod LT3 i LT4 zadataka, visoke vrednosti F1 mere prikazane na slici 4.6, zajedno sa rezultatima sa slike 4.9, koji pokazuju da već sa samo 200 primera u trening skupu LinLayCNN u preko 95% slučajeva postavlja  $O_2$  na ispravnu stranu  $O_1$ , ukazuju da model uspešno prepoznaje deo prostora na kome se nalazi  $O_1$  i pravilno pozicionira objekat na drugu stranu.


### b) Preklapanje sa obeležjem

Na LT9 dizajnerski zahtev je minimizacija udaljenosti između objekata tako da se ne preklopi obeležje. Na LT9a i LT9b, sa 500 primera, LinLayCNN izbegava preklapanje



Slika 4.9: Metrika  $correct\_side(O_2, O_1)$  na LT3, LT4, LT5, LT6, LT7, LT8, LT9a, LT9b and LT9c za različite veličine trening skupa


obeležja u više od 90% slučajeva (slika 4.10). U slučaju LT9c, iako objekat pokriva obeležje u oko 50% primera, metod i dalje pravilno određuje stranu obeležja u više od 80% slučajeva, već sa 500 trening (slika 4.11). Ovo ukazuje da LinLayCNN ima izraženu tendenciju da izbegne preklapanje i da bira poziciju s dovoljno raspoloživog prostora za objekat. Ovakvo ponašanje sugerise da LinLayCNN u početnim fazama percipira obeležje u niskoj rezoluciji, identifikujući njegovu okvirnu lokaciju pre nego tačnu poziciju. Uočeno smanjenje mere  $inter\_distance$  (slika 10) i povećanje F1 mere (slika 4.7) sa većim brojem primera u trening skupu ukazuje na to da dodatni primeri poboljšavaju rezoluciju LinLayCNN metoda.



Slika 4.10: Metrika  $covering$  na LT8a i LT8b (sivi) i LT9a, LT9b i LT9c (crni stubovi)

## Relacija pripadnosti


Za ovu relaciju razmotrićemo slučajeve kada LinLayCNN uči da prostor sadrži objekat i kada uči da objekat sadrži obeležje.



Slika 4.11: Metrika  $correct\_side(O_2, P_1)$  na LT9a, LT9b i LT9c

#### a) Prostor sadrži objekat


Kod LT3, LT4, LT5 i LT6 jedan od dizajnerskih zahteva je postavljanje objekta uz desnu ivicu prostora. Sa slike 4.12 je jasno da LinLayCNN favorizuje postavljanje objekata unutar ili uz ivicu prostora, umesto izvan prostora. Sa porastom broja trening primera, metod sve uspešnije zadovoljava ovaj zahtev, povećavajući broj korektno pozicioniranih objekata. U slučajevima kada objekat nije postavljen tačno uz ivicu, rastojanje od ivice je u proseku veće kada se objekat nalazi unutar prostora, nego kada izlazi van njegovih granica (slika 4.13), što ukazuje na tendenciju ka postavljanju objekata unutar prostora.



Slika 4.12: Odnos metrika  $inside/outside/marginal$  na LT3, LT4, LT5 i LT6

#### b) Objekat sadrži obeležje

Na LT8, zahtev je postaviti  $O_1$  da pokrije obeležje tako da se maksimizuje udaljenost od  $O_2$ . Na LT8b, gde je obeležje pozicionirano blizu ivice prostora - što omogućava



Slika 4.13: Metrike *violation* i *dist\_right* na LT3, LT4, LT5 i LT6 za različite veličine trening skupa

da optimalna pozicija objekta bude upravo na ivici - LinLayCNN uspeva da pokrije obeležje u čak 99% slučajeva, sa samo 500 trening primera (slika 4.10).

Nasuprot tome, na LT8a, gde se obeležje nalazi približno u sredini prostora i mora biti pokriveno samo jednom tačkom objekta (tj. nalazi se na samoj ivici objekta sa unutrašnje strane), uspešnost LinLayCNN opada na oko 50%.

Međutim čak i kada ne dolazi do pokrivanja, LinLayCNN pravilno bira stranu drugog objekta na kojoj je obeležje (slika 4.9), a sa povećanjem trening skupa postavlja objekat sve bliže obeležju (slika 4.8). Ovo pokazuje da LinLayCNN prepoznaje okvirnu poziciju obeležja i teži da ga pokrije.

Tabela 4.9 pokazuje da LinLayCNN dosledno postavlja objekat  $O_2$  na stranu obeležja koja je udaljenija od  $O_1$ , ističući njegovu strategiju maksimizacije udaljenosti između objekata. U kombinaciji sa slabijom preciznošću u identifikaciji tačne lokacije obeležja, ova strategija često dovodi do toga da LinLayCNN ne pokrije obeležje da bi izbegao preklapanje sa objekatom ili doveo objekte bliže nego što je potrebno.

|                              |       |       |       |       |        |
|------------------------------|-------|-------|-------|-------|--------|
| Suprotne strane obeležja (%) | 97.85 | 99.24 | 99.69 | 99.93 | 100.00 |
|------------------------------|-------|-------|-------|-------|--------|

Tabela 4.9: Procenat test primera kod kojih su objekti postavljeni sa suprotnih strana obeležja

#### 4.5.2.2 Direkzione relacije

##### S-leva/s-desna

Na LT6, LinLayCNN treba da postavi objekat na levu ivicu drugog objekta ako ima mesta, u suprotnom na desnu ivicu prostora. Već sa 500 trening primera, uspešnost odabira ispravne strane je gotovo 100% (slika 4.9), što ukazuje na visoku uspešnost metoda na ovom zadatku. Za druge tipove rasporeda, odabir strane zavisi od drugih

| Veličina trening skupa | Redni broj objekta |       |       |       |
|------------------------|--------------------|-------|-------|-------|
|                        | 02                 | 03    | 04    | 05    |
| 100                    | 9.83               | 21.53 | 31.80 | 41.48 |
| 200                    | 10.18              | 20.48 | 30.50 | 40.39 |
| 500                    | 10.34              | 20.27 | 30.86 | 40.58 |
| 1000                   | 9.80               | 19.87 | 29.73 | 39.69 |
| 4000                   | 9.95               | 19.86 | 29.86 | 40.10 |

Tabela 4.10: Razmak između objekata na LT2

dizajnerskih zahteva, pa oni nisu analizirani radi procene sposobnosti LinLayCNN-a u orijentaciji levo-desno.

#### 4.5.2.3 Relacije udaljenosti

Analiziramo performanse modela u učenju relacije tačne udaljenosti, kao i relacija „što bliže” i „što dalje”, pri čemu posmatramo i odnose između samih objekata i odnose između objekta i obeležja.

#### Tačna udaljenost

Tip rasporeda LT2 sadrži dizajnerski zahtev da objekti budu postavljeni u tačno definisanom razmaku jedan od drugog. Konkretno, pet objekata treba biti postavljeno sa udaljenostima od 10, 20, 30 i 40 jedinica između njih, počev od leve ivice. Tabela 4.10 prikazuje prosečne udaljenosti svakog objekta od prethodnog. Iz tabele se vidi da je sa 200 trening primera greška manja od 1, što ukazuje na visoku uspešnost metoda na LT2.

#### Što dalje/što bliže

##### a) Što dalje od objekta

Kod LT5, zahtev je maksimizacija razdaljine između objekata, pri čemu uspešnost zavisi od tačne procene na kojoj strani - levoj ili desnoj - postoji više raspoloživog prostora u odnosu na postavljeni objekat. Slika 4.8 prikazuje najniži procenat tačno odabrane strane u poređenju s ostalim tipovima rasporeda, što ukazuje na to da LinLayCNN ima poteškoća u poređenju dužina prostora. Za LT8, zadatak je takođe maksimiziranje razdaljine između objekata, ali uz dodatno ograničenje pokrivanja obeležja. Prema podacima iz tabele 4.9, objekti su smešteni sa suprotnih strana obeležja u preko 99% slučajeva, dok na LT8a čak kod 50% primera obeležje nije pokriveno (slika 4.11). Ovo jasno pokazuje da je prioritet LinLayCNN razdvajanje objekata, čak i po cenu ne pokrivanja obeležja.

## b) Što dalje od obeležja

Analiziraćemo performanse na LT9, gde je zahtev postaviti objekat  $O_2$  što bliže objektu  $O_1$  a istovremeno što dalje od obeležja. Kod LT9a,  $O_2$  se postavlja uz ivicu  $O_1$  koja je udaljenija od obeležja. Ukoliko na toj strani nema dovoljno prostora, koristi se suprotna ivica - bliža obeležju (LT9b). U slučaju kada nema dovoljno prostora da se postavi ni uz jednu ivicu, smešta se neposredno pored obeležja (LT9c). Analiza slike 4.10 sugerise da zahtevi iz LT9b, koji se mogu tumačiti kao minimizacija udaljenosti od obeležja ali da objekti budu susedni, i LT9c - približavanje objekta obeležju - često dominiraju. Kao posledica toga, LinLayCNN često ne uspeva da ispuni zahtev udaljanja objekta od obeležja, te ih neretko smešta na istu stranu prostora, a u pojedinim slučajevima dolazi i do njihovog preklapanja.

## Što bliže

Na Slici 4.11 uočava se da kod LT9a i LT9b, već sa 500 trening primera, LinLayCNN ima tendenciju da bira stranu obeležja na kojoj se nalazi objekat  $O_1$ , što ukazuje na sklonost metoda ka njihovom približavanju. Analiza slike 4.10 ukazuje da metod često zanemaruje zahtev izbegavanja preklapanja sa obeležjem, favorizujući smanjenje razdaljine između objekata kao dominantan zahtev u odlučivanju. Relacija „što bliže“ obeležju analizirana je kroz potpoglavlje „Objekat sadrži obeležje”.


### 4.5.2.4 Iterativno dodavanje objekata

Za analizu performansi na ovom zadatku, evaluiramo LinLayCNN metod na tipovima rasporeda LT1 i LT2, gde su zadaci postavljanje 10 objekata jedan do drugog (LT1) i postavljanje pet objekata na razdaljinama 10,20,30,40 (LT2). Na Slici 4.14 prikazane su F1 mere za svaki objekat u rasporedu, u zavisnosti od veličine skupa za treniranje. Kao što je očekivano, F1 vrednost opada sa porastom rednog broja objekta - što je objekat udaljeniji od leve ivice, veći je broj potencijalnih početnih pozicija. Na Slici 4.15 prikazana je Gausova raspodela početnih pozicija svakog objekta. Srednja vrednost i standardna devijacija izračunate su na skupu podataka. Uprkos tome, analiza slike 4.3 pokazuje da LinLayCNN bolje savladava odnose susednosti na LT1 u poređenju s drugim tipovima rasporeda, jer greške nastale pri postavljanju prethodnog objekata ne utiču direktno na ispunjavanje zahteva postavljanja novog objekta uz njega.


Upoređićemo performanse metoda na LT1 i LT2 analizom prosečne F1 vrednosti za prvih pet objekata. Na osnovu slike 4.16, možemo zaključiti da nema značajnih razlika u performansama između rasporeda koji uključuju zahteve precizne udaljenosti i onih koji se fokusiraju na susednost.

### 4.5.3 Diskusija


Na osnovu analize rezultata možemo zaključiti da LinLayCNN prepoznaje sve prostorne relacije. Posmatrajući F1 mere na Slici 4.7, zaključujemo da, kada raspored uključuje više prostornih relacija i složenije interakcije između elemenata, potrebno je više trening primera kako bi se zadovoljili svi dizajnerski zahtevi.



Slika 4.14: F1 mera za svaki objekat iz skupa LT1, za različite veličine trening skupa




Slika 4.15: Gausova raspodela početnih pozicija objekata na LT1



Slika 4.16: Prosečna vrednost F1 mere za prvih pet objekata na LT1 i LT2

Na Slici 4.7 vidimo najbolje performanse i najbrže učenje kod LT2, LT3 i LT4, koji uključuju 2-3 prostorne relacije. LT7, sa 3 relacije i jednim obeležjem, zahteva više primera za treniranje, zatim slede LT4, LT5 i LT6, koji uključuju 4-5 prostornih relacija.

LT1, sa 10 objekata, ima niže performanse od LT2 zbog kumulativnih grešaka. LT9 pokazuje najslabije performanse; njegovi dizajnerski zahtevi su nekonzistentni, a odnos između objekta i obeležja menja se u zavisnosti od pozicije  $O_1$ . Na Slici 4.17 prikazana je aktivacija izlaznih neurona CNN-a za primer LT9c, gde je predikcija metoda LinLayCNN za poziciju  $O_2$  netačna. U ovom slučaju LinLayCNN predviđa da je  $O_2$  levo od obeležja. Međutim, slika 4.17 sugeriše da bi sa više primera za treniranje druga opcija za poziciju objekta mogla postati dominantna.



Slika 4.17: Ilustracija predikcije pozicije  $O_2$ . Gore: Tačan raspored iz LT9a. Dole: Heatmap koja prikazuje aktivacije izlaznih neurona

Slika 4.9 pokazuje najmanje vrednosti metrike *correct\_side* na LT5, gde je potrebno uporediti dve dužine prostora i postaviti objekat tamo gde ima više mesta, što ukazuje na to da LinLayCNN lakše poredi objekat sa prostorom nego što upoređje dva segmenta prostora.

Analiza susednosti pokazuje uniforman pristup unutar CNN mreže za kodiranje odnosa susednosti, bilo da se radi o interakcijama između objekata, objekta i obeležja, ili objekta i prostora.

Međutim, kod LT9c i LT8a, na osnovu analize preklapanja i pripadnosti, možemo zaključiti da LinLayCNN daje prednost dizajnerskim zahtevima koji uključuju objekte i prostor u odnosu na zahteve koji uključuju obeležje, naročito na manjim trening skupovima. Slika 4.9, koja pokazuje visoku stopu pravilnog odabira strane u većini rasporeda čak i uz nisku vrednost F1 mere (slika 4.7), dovodi nas do zaključka da LinLayCNN pri malom broju primera za treniranje percipira raspored u nižoj rezoluciji, prepoznajući područje umesto precizne pozicije elemenata.

Kako bi se iskoristile mogućnosti LinLayCNN-a u scenarijima sa malim skupovima za treniranje, preporučujemo korišćenje algoritama zasnovanih na pravilima za doradu generisanih rasporeda. To podrazumeva prilagođavanje rasporeda tako da se, na primer, kada su objekti ili objekat i obeležje na malim udaljenostima, oni prisilno postavljaju jedan pored drugog. Na ovaj način povećava se funkcionalnost rasporeda bez potrebe za obimnim skupovima podataka za treniranje.

## 4.6 Zaključak

Sprovedene analize pokazuju da jednostavnije arhitekture (posebno sa dva konvoluciona sloja) pokazuju superiornije performanse u odnosu na dublje mreže, koje dostižu

iste performanse tek sa većim brojem trening primera (4.1, 4.1). Predloženi sigmoidalni izlazni sloj konzistentno nadmašuje softmaks i regresioni izlaz (4.2). Regresioni izlaz daje bolje rezultate samo na najjednostavnijim problemima. U pogledu skalabilnosti, povećanje broja objekata i dimenzija prostora zahteva veće količine trening podataka da bi se održale iste performanse (4.3, 4.4, 4.5, 4.7).

Analiza rezultata pokazuje da LinLayCNN uspešno prepoznaje sve tipove prostornih relacija, ali pri manjem broju primera teži „grubljoj“ (niskorezolucijskoj) percepciji obeležja i prioritet daje zahtevima koji uključuju interakcije objekat–prostor u odnosu na objekt–obeležje (4.9, 4.7). Na osnovu rezultata, preporučuje se kombinovanje *LinLayCNN* sa pravilima u scenarijima sa malo podataka, kako bi se dodatno poboljšala tačnost bez povećanja složenosti modela. Ovakvi rezultati sugerišu da je pažljivo balansiranje između složenosti modela i veličine skupa podataka ključno za optimalne performanse na određenom problemu.



## Glava 5

# Primena metoda na arhitektonskom problemu generisanja linearnog kuhinjskog rasporeda

Problem generisanja kuhinjskih rasporeda predstavlja izazovan zadatak zbog složenosti koja spaja stroga funkcionalna pravila sa kreativnim aspektima dizajna. Ova jedinstvena kombinacija čini ga posebno interesantnim za istraživanje i testiranje algoritama mašinskog učenja, jer osim što moraju integrisati eksplicitna pravila, ovi algoritmi moraju biti sposobni da obuhvate i estetske principe i dizajnersku intuiciju u procesu odlučivanja.

U ovom poglavlju fokusiraćemo se na generisanje najjednostavnijeg kuhinjskog rasporeda – linearnih kuhinja. Rešavanje ovog osnovnog problema predstavlja ključni preduslov za dalje proširenje na složenije rasporede, budući da oni uključuju slična pravila, ali u više dimenzija. Analiza performansi algoritama na linearnim rasporedima pruža uvid u njihove mogućnosti i ograničenja, što je neophodno za njihovu primenu u generisanju kompleksnijih kuhinjskih konfiguracija.

Jedno od osnovnih ograničenja u primeni algoritama veštačke inteligencije u generisanju kuhinjskih rasporeda jeste nedostatak adekvatnih skupova podataka. Kreiranje kvalitetnog skupa podataka u ovoj oblasti izuzetno je zahtevno i skupo, jer zahteva objedinjavanje ekspertskog znanja dizajnera enterijera, praktičnih potreba krajnjih korisnika i tehničkog znanja proizvođača kuhinja.

Dodatni izazov predstavlja to što kuhinjski rasporedi zahtevaju rad sa preciznim dimenzijama, što otežava beleženje i pripremu podataka. Nedostatak intuitivnih i efikasnih alata dodatno komplikuje ovaj proces, a postavlja se i pitanje kako formalno definisati kuhinjski raspored i koje karakteristike su ključne za njegovu reprezentaciju.

Kako bismo definisali ključne karakteristike za reprezentaciju kuhinjskog rasporeda, sprovedi smo intervju sa stručnjacima iz oblasti dizajna enterijera i proizvodnje kuhinja. Na osnovu dobijenih informacija razvijen je alat za anotaciju, koji je omogućio sistematsko prikupljanje i obradu podataka. Korišćenjem ovog alata stručnjaci su kreirali LinKitLay skup podataka, koji obuhvata linearne kuhinjske rasporede različitih nivoa složenosti. Skup sadrži 900 trening i 100 test primera.

Na osnovu intervjua sa stručnjacima formulisana su pravila odlučivanja, koja su poslužila kao osnova za razvoj metoda za automatsko generisanje linearnih kuhinjskih rasporeda, zasnovanog na pravilima (engl. *rule-based method*). Validacija metoda na LinKitLay skupu podataka pokazala je dobre rezultate za jednostavnije rasporede, dok se ovaj deterministički pristup ispostavio neefikasnim za složenije konfiguracije.

Kako bismo prevazišli ova ograničenja, razvili smo algoritme zasnovane na mašinskom učenju. Prvo smo testirali tradicionalne algoritme, koji su pokazali značajno bolje rezultate od metoda zasnovanog na pravilima i koje su ispitanici ocenili kao praktično primenljive. Nakon toga, testirali smo LinLayCNN metod koji je pokazao najbolje performanse na ovom zadatku.

## 5.1 Opšti problem raspoređivanja nameštaja

Dizajn enterijera, koji obuhvata selekciju nameštaja, raspored elemenata i izbor materijala, predstavlja složen proces koji zahteva visok nivo stručnosti i kreativnosti profesionalnih dizajnera [50]. Raspoređivanje nameštaja je naročito izazovno jer zahteva usklađivanje različitih funkcionalnih i estetskih kriterijuma. Iskusni dizajneri se zato često oslanjaju na iterativni proces pokušaja i grešaka kako bi postigli optimalan balans između ovih komponenti [93].

S obzirom na sve širu upotrebu virtuelnih okruženja u arhitektonskoj vizualizaciji i industriji video igara, ručno dizajniranje enterijera virtuelnih scena postaje izuzetno skupo u pogledu vremena i resursa [50]. Ručna izrada ovakvih okruženja u velikim razmerama je nepraktična i teško izvodljiva [27]. Automatska i poluautomatska sinteza enterijera nudi velike prednosti dizajnerima enterijera jer im obezbeđuje brže i jednostavnije alate za korišćenje prilikom konsultacija sa klijentima i u generisanju predloženih rasporeda [94]. Predloženi su različiti pristupi za automatizaciju, uključujući zadovoljenje ograničenja, optimizaciju ručno definisanih principa dizajna enterijera, statističke pristupe primenjene na podatke o međusobnim odnosima objekata i odnosa sa korisnikom [65].

Međutim, dizajniranje rasporeda sa složenim ograničenjima i dalje je izazov zbog nejedinstvenih rešenja i poteškoća u integraciji ograničenja u konvencionalne metode zasnovane na optimizaciji [94]. Savremeni pristupi za rešavanje problema analize scena i modelovanja sve više se oslanjaju na podatke, koristeći metode mašinskog učenja [28].

### Specifičnosti generisanja kuhinjskih rasporeda

Kuhinja predstavlja prostor od velike važnosti za svaku porodicu. Zbog toga je važno da bude organizovana na najbolji mogući način, uz maksimalno iskorišćenje prostora i estetski izgled prilagođen ukusu korisnika. Da bi se ispunili ovi kriterijumi, vlasnici kuća se u većini slučajeva odlučuju za izradu kuhinja po meri. Ovo zahteva poštovanje mnogih pravila raspoređivanja elemenata kako bi se dobio funkcionalan prostor. Zbog toga su dizajneri enterijera često primorani da značajan deo vremena posvete rešavanju funkcionalnih izazova, što im ostavlja manje prostora za kreativne i estetske aspekte dizajna.

Mnoge smernice za dizajn enterijera smatraju kuhinju jednom od najkompleksnijih prostorija u celoj kući [95, 96]. Kuhinje zahtevaju rad sa nameštajem po meri, koji je specifično napravljen za datu prostoriju, ali mora da zadovolji unapred definisana pravila dizajna [97]. Na primer, dužina radnih površina izražava se kao kontinualna vrednost koja mora zadovoljiti određena ograničenja. Nasuprot tome, pojedini kuhinjski elementi, poput sudopere ili rerne, imaju unapred određene, diskretne dimenzije. Gradivni blokovi kuhinje moraju biti pažljivo koordinisani kako bi zadovoljili složena funkcionalna i estetska ograničenja (npr. elementi treba da se postave u nizu bez razmaka između njih [34], frižider treba da bude na početku radnog niza [98]). Planiranje kuhinje obuhvata pozicije vodovodnih, elektro, grejnih, ventilacionih i ponekad gasnih instalacija [99, 100].

Zbog toga dizajner kuhinje mora biti i analitičan i kreativan [101]. U nekim slučajevima, ne postoji jedinstven ispravan raspored kuhinje, a izbor prihvatljivog zavisi isključivo od kreativnosti dizajnera. Zbog kompleksnosti dizajna kuhinje, postojeća istraživanja u oblasti proceduralne sinteze unutrašnjih scena prepoznaju kuhinju kao specifičnu funkcionalnu grupu [34, 65, 27], ili se uopšte ne bave generisanjem rasporeda kuhinje [64, 62].

Poslednjih godina pristupi zasnovani na podacima i učenju dobijaju sve veću pažnju. Paralelno sa tim raste i broj skupova podataka o enterijerima [102]. Iako postoji interes za ovo polje, prema našim saznanjima, niko do sada nije kreirao skup podataka koji uključuje stvarne karakteristike kuhinjskog dizajna. Kako mašinsko učenje postaje sve prisutnije, postaje sve važnije prikupljati i anotirati podatke, naročito za najnovije arhitekture neuronskih mreža [103].

## Postojeći pristupi

Postoji širok spektar istraživačkih radova koji se bave tematikom konstrukcije virtuelnih zgrada [104]. Jedna grupa istraživanja fokusira se na generisanje zgrada [105, 106, 107, 108], dok druga istražuje automatsko generisanje enterijera [34, 109, 110].

Istraživanja koja se bave problemom automatskog raspoređivanja nameštaja primenjuju različite principe. Prva grupa autora koristi parametarske principe zasnovane na pravilima [109, 110, 111, 112, 113], dok druga primenjuje metode zasnovane na optimizaciji [61, 50]. Ovi autori formiraju funkciju cene u optimizaciji koristeći matematičke izraze koji predstavljaju estetska, ergonomska i funkcionalna pravila u profesionalnom dizajnu enterijera. Treća grupa istraživača koristi metode zasnovane na podacima, koje se oslanjaju na informacije iz postojećih rasporeda [27]. Ove metode izbegavaju potrebu za složenim pravilima, koja zavise od specifičnog znanja dizajnera. Kako mašinsko učenje postaje sve rašireniji pristup, nova istraživanja sve više primenjuju ove metode za automatsko kreiranje rasporeda nameštaja [34, 114, 62].

Pregledom literature došli smo do samo nekoliko radova koji se bave automatskim generisanjem rasporeda kuhinje [65, 34, 110, 111, 28], koji nude rešenja sa određenim ograničenjima. Duboke konvolucione mreže imaju poteškoća u generisanju kontinualnog rasporeda odvojenih sekcija kuhinjskih radnih površina [34]. Konvolucione operacije ne prepoznaju osnovne strukture u podacima koje igraju ključnu ulogu u razumevanju

scena, što može delimično objasniti zašto duboke konvolucione neuronske mreže, koje su bile uspešne u obradi prirodnih slika, nisu široko primenjene u analizi ili sintezi 3D unutrašnjih scena [28]. U radu [65] predstavljen je okvir za sintezu unutrašnjih scena koji kombinuje relacione grafičke prikaze višeg nivoa sa prostornim prioritetima neuronskih mreža. Ovakav pristup omogućava precizniji raspored nadstruktura, poput kuhinja ili ugradnih ormana. Iako metoda pruža kvalitetne rezultate slične drugim savremenim pristupima, izveštaji sugerišu da još uvek nije na nivou ljudskih sposobnosti u dizajnu scena, posebno u slučaju kuhinja.


Nedostatak specifičnih skupova podataka za kuhinjski dizajn, koji uključuju stvarne karakteristike, različite podtipove kuhinjskih elemenata i kontinualnu dužinu radnih površina, predstavlja veliku prepreku za razvoj automatskog generisanja kuhinjskih rasporeda.

## 5.2 Osnove organizacije kuhinjskog prostora

### Kuhinjski elementi

Tri glavna kuhinjska elementa su: element za kuvanje (engl. *Cooking*), element za skladištenje (engl. *Storage*) i element za pranje (engl. *Washing*). U daljem tekstu šporet, frižider i sudopera. Glavni elementi razdvojeni su radnim površinama [115, 116, 111].

U nastavku su definisana po tri tipa za svaki od glavnih kuhinjskih elemenata, na osnovu tržišno najzastupljenijih dimenzija (širina  $\times$  visina  $\times$  dubina), koji su prikazani na slici 5.1.



Slika 5.1: Tipovi glavnih kuhinjski elemenata

Tipovi frižidera i njihove dimenzije:

- F1:  $60 \times 90 \times 60$ ,
- F2:  $90 \times 180 \times 60$ ,
- F3: -  $120 \times 180 \times 60$ .

Tipovi sudopere i njihove dimenzije:


- S1:  $30 \times 90 \times 60$ ,
- S2:  $60 \times 90 \times 60$ ,
- S3:  $120 \times 90 \times 60$ .

Tipovi šporeta i njihove dimenzije:

- Š1:  $30 \times 2 \times 60$ ,
- Š2:  $60 \times 90 \times 60$ ,
- Š3:  $120 \times 180 \times 60$ .

## Tip kuhinje

Organizacija prostorije definiše mogući tip kuhinje. Prema obliku, kuhinjski rasporedi se mogu klasifikovati u šest osnovnih tipova (slika 5.2): Linearni (I-oblik), II-oblik, L-oblik, U-oblik, G-oblik i sa ostrvom [111].



Slika 5.2: Šest osnovnih tipova kuhinja

U ovom poglavlju bavićemo se linearnim kuhinjama, kod kojih su svi kuhinjski elementi postavljeni duž jednog zida (jedne dimenzije).


## Osnovna pravila raspoređivanja kuhinjskih elemenata

Ključni zahtev pri dizajniranju kuhinje jeste da glavni kuhinjski elementi budu organizovani tako da rad između njih bude što efikasniji, bez suvišnog hodanja ili prepreka.

Kuhinjski raspored zavisi od tri glavna faktora:

- pravila za bezbednu i udobnu upotrebu,
- postojećih infrastrukturnih elemenata,
- estetskog izgleda.

Još 1940-ih godina na Univerzitetu Illinois, razvijen je princip „Radnog trougla“ (engl. *Working Triangle*, WT), koji definiše pravila za međusobni položaj kuhinjskih elemenata koja se koriste i danas. Po WT principu tri glavna kuhinjska elementa treba da budu povezana zamišljenim linijama koje čine trougao (slika 5.3).



Slika 5.3: Princip radnog trougla


Ključne smernice WT pristupa su [117]:

- Razdaljina između radnih elemenata je 1.2m - 2.7m;
- Suma svih razdaljina je 4m - 7.9m;
- Prepreke, kao što su ormari, ne smeju da se ukrštaju sa trouglom za više od 30 cm;
- Ne bi trebalo da bude prolaza kroz trougao.

Važan faktor za dizajniranje rasporeda su postojeći infrastrukturni elementi prostora, na osnovu kojih se određuju pozicije nekih od kuhinjskih elemenata. Na primer:

- Vrata određuju poziciju frižidera.
- Vodovodne cevi i kanalizacija određuju poziciju sudopere.
- Cevi za ventilaciju određuju poziciju aspiratora i šporeta.

U linearnoj kuhinji, idealni raspored elemenata (od ulaza ka unutrašnjosti) je: frižider → sudopera → šporet, uz radne površine između elemenata (slika 5.4).



Slika 5.4: Idealna organizacija linearnog kuhinjskog rasporeda

Osnovna pravila raspoređivanja moguće je implementirati u slučaju dizajniranja i izgradnje nove zgrade. Implementacija prilikom renoviranja biće moguća samo ako

su pozicije infrastrukturni elementa usklađene sa principom radnog trougla. Ukoliko nisu, promena pozicija prozora i sistema cevi kako bi se uskladili sa principom radnog trougla može biti skupa i, u većini slučajeva, nemoguća. U tom slučaju, kreativnost dizajnera ima glavnu ulogu u dizajnu rasporeda kako bi se obezbedio siguran i udoban prostor u kuhinji.

## 5.3 LinKitLay - skup podataka sa linearnim kuhinjskim rasporedima

### Reprezentacija linearnog kuhinjskog rasporeda

S obzirom na to da kuhinjski elementi imaju standardizovane dimenzije u dubini i visini [111], te dimenzije su zanemarene prilikom definisanja reprezentacije rasporeda. Pošto su svi kuhinjski elementi raspoređeni duž jedne linije – duž zida – prostorni problem koji bi inače bio trodimenzionalan može se pojednostaviti na jednodimenzionalni. To znači da je za reprezentaciju rasporeda dovoljno opisati pozicije elemenata duž glavne ose kuhinje, dok su dubina i visina implicitno definisane njihovim standardnim vrednostima. Ovakav pristup omogućava efikasniju strukturu podataka i pojednostavljuje proces generisanja kuhinjskih rasporeda.

Kako bismo definisali ključne karakteristike za reprezentaciju kuhinjskog rasporeda, sprovedeno je istraživanje u formi intervjua, sa 43 stručnjaka u Srbiji. U okviru ovog istraživanja, intervjuisano je 9 dizajnera enterijera, 22 arhitekti i 12 proizvođača kuhinja. Na osnovu prikupljenih informacija, identifikovane su relevantne ulazne karakteristike koje utiču na donošenje odluka pri raspoređivanju kuhinjskih elemenata. Struktura rasporeda u potpunosti je određena podtipovima i pozicijama tri glavna kuhinjska elementa, dok se preostali prostor između njih popunjava radnim površinama (detaljnije opisano u potpoglavlju 5.2). Shodno tome svaki primer u skupu podataka sastoji se od šest diskretnih ulaznih karakteristika i od šest izlaznih parametara (ciljnih vrednosti).

#### Ulazne karakteristike (infrastrukturni elementi)

Ulazne karakteristike predstavljaju fiksne prostorne uslove (infrastrukturne elemente) koji direktno utiču na raspored kuhinjskih elemenata. Oni određuju fizičke granice unutar kojih se formira raspored. Ulazne karakteristike su:

1. dužina kuhinje,
2. pozicija ventilacije,
3. pozicija kanalizacionog odvoda,
4. pozicija prozora,
5. pozicija ulaza u kuhinju,

6. pozicija izlaza iz kuhinje.


Promena bilo kog ulaznog parametra može značajno uticati na raspored kuhinjskih elemenata.

### Izlazni parametri (ciljne vrednosti)

Ciljne vrednosti predstavljaju podtipove i pozicije tri glavna kuhinjska elementa:

1. tip sudopere,
2. pozicija sudopere,
3. tip šporeta,
4. pozicija šporeta,
5. tip frižidera,
6. pozicija frižidera.

Generisanje rasporeda kuhinje podrazumeva određivanje ciljnih vrednosti na osnovu definisanih ulaznih karakteristika (slika 5.5).



Slika 5.5: Ulazne karakteristike i ciljne vrednosti

### Kreiranje skupa podataka

Skup linearnih kuhinjskih rasporeda (engl. *Linear Kitchen Layouts*, LinKitLay) <sup>1</sup> kreiran je od strane pet dizajnera enterijera sa prosečnim iskustvom od 9,4 godine u dizajnu kuhinja i organizaciji rasporeda. LinKitLay sadrži 900 primera linearnih rasporeda kuhinja za treniranje i 100 primera za testiranje.

Skup podataka podeljen je u četiri podskupa koji simuliraju različite slučajeve projektovanja kuhinja:

---

<sup>1</sup><https://github.com/jelena6k/ProceduralKitchenGeneration>

**Podskup 1** – sadrži rasporede kuhinja različitih dužina, sa samo jednim ulaznim parametrom (pozicija ulaznih vrata). Ovaj podskup simulira projektovanje kuhinja u ranoj fazi izgradnje objekta, kada još nisu definisane tačne pozicije odvoda za sudoperu i ventilacije, pa je moguće generisati idealan raspored elemenata. Većina postojećih skupova podataka sadrži samo primere sa ovakvim karakteristikama.

**Podskup 2** – sadrži rasporede kuhinja različitih dužina, sa ulaznim parametrima postavljenim u idealnom redosledu: ulazna vrata na početku kuhinje, zatim odvod za sudoperu, ventilacija i izlaz na kraju. Simulira slučajeve projektovanja kuhinja u prostorima u kojima su infrastrukturni elementi postavljeni po WT principima.

**Podskup 3** – sadrži rasporede kuhinja različitih dužina, sa različitim ulaznim parametrima koji nisu u idealnom redosledu ali se ne preklapaju i nisu previše blizu (npr. pozicija odvoda za sudoperu i ventilacije nije bliža od 30 cm). Simulira slučajeve projektovanja kuhinja u prostorima u kojima WT principi nisu ispoštovani, pa nije moguće postići idealan raspored kuhinjskih elemenata.


**Podskup 4** – sadrži rasporede kuhinja različitih dužina, sa različitim ulaznim parametrima koji nisu u idealnom redosledu, preklapaju se ili su postavljeni vrlo blizu (npr. udaljenost između odvoda i ventilacije manja je od 30 cm), što onemogućava direkto povezivanje kuhinjskih elemenata sa odgovarajućim ulaznim parametrima. Ovakvi slučajevi odstupanja od WT principa predstavljaju poseban izazov u praksi.

Raspodela trening primera po podskupovima je približno uniformna, čime je obezbeđena ravnomerna zastupljenost različitih scenarija u procesu treniranja modela. Test skup sastoji se od 100 pažljivo odabranih primera. Raspodela primera po podskupovima podataka je sledeća:

- Podskup 1: 10 primera;
- Podskup 2: 20 primera;
- Podskup 3: 30 primera;
- Podskup 4: 40 primera.

## Alat za anotaciju

Za kreiranje linearnog rasporeda kuhinja, stručnjaci su koristili softver razvijen korišćenjem Unity razvojnog okruženja za video igre (engl. *Unity game engine*). Softver je namenjen kreiranju rasporeda kuhinja bilo kog oblika (slika 5.8), uz podršku za dimenzije zida od minimalnih 90 cm do maksimalnih 600 cm. Raspored kuhinje prikazan je iz perspektive „odozgo“. Pozicije ulaznih karakteristika korisnik može definisati ručno, koristeći klizalice, ili unosom tačnih dimenzija u centimetrima. Takođe postoji opcija da softver sam izgeneriše ulazne karakteristike. Nakon toga korisnik može ručno rasporediti kuhinjske elemente.



Slika 5.6: Alat za anotaciju

Softver koristi standardizovane dimenzije za sva tri glavna kuhinjska elementa (opisano u potpoglavlju 5.2). Radne površine koje popunjavaju prostor između glavnih elemenata imaju modularnu veličinu od 60 cm. Samo jedna radna površina može odstupati od ovog standarda, ali uz sledeća ograničenja:

- minimalna dozvoljena dužina: 30 cm,
- standardna dužina: 60 cm,
- maksimalna dozvoljena dužina: 90 cm.

### 5.3.1 Metod evaluacije

Kao metrike za merenje performansi na ovom skupu podataka predlažemo kvantitativnu metriku - *exact matching* i perceptualne metrike: *livability* i *applicability*.

Kvantitativne mere omogućavaju objektivnu evaluaciju modela upoređivanjem generisanih rezultata sa referentnim podacima. Međutim, u praksi, dizajn kuhinje nije proces strogo vođen pravilima, već i umetnička disciplina. U nekim slučajevima to dovodi do postojanja više ispravnih rasporeda za iste ulazne karakteristike kuhinje, u zavisnosti od ukusa i estetskih preferencija dizajnera. S druge strane, čak i kada generisani raspored nije u potpunosti prihvatljiv, često je dovoljna samo manja korekcija. Zbog toga, kao dodatne metrike predlažemo perceptualne metrike koje se određuju na osnovu procena stručnjaka i korisnika o kvalitetu i primenljivosti generisanih rasporeda.

#### Kvantitativne metrike:

- *Exact matching* – meri sličnost između generisanih i referentnih rasporeda iz skupa podataka, na nivou pojedinačnih elemenata i na nivou celog rasporeda.

Na nivou elementa - kuhinjski element se smatra tačno klasifikovanim samo ako je pozicioniran na identičnom mestu kao u referentnom rasporedu.

Na nivou rasporeda - raspored se smatra ispravno klasifikovanim samo ako su svi njegovi elementi pozicionirani na identičnom mestu kao u referentnom rasporedu. Ova metrika predstavlja varijaciju Intersection-over-Union (IOU) metrike – koja meri površinu preseka između predviđenog i referentnog rasporeda, koja je korišćena u [118].

### **Perceptualne metrike:**

- *Livability* – meri pogodnost za život. Učesnici procenjuju da li generisani rasporedi zadovoljavaju estetske, ergonomske i funkcionalne zahteve neophodne za ugodan boravak. Metrika je binarna, sa vrednostima 0 ili 1, u zavisnosti od toga da li je raspored pogodan za život (1) ili nije (0). Inspirisana je metodologijom opisanoj u [61].
- *Applicability* – meri stepen primenljivosti rasporeda u praksi dizajnera. Učesnici ocenjuju svaki generisani raspored na osnovu obima korekcija koje je potrebno napraviti da bi raspored bio primenljiv u njihovoj profesionalnoj praksi. Predlažemo skalu od 1 do 5, gde 1 označava raspored koji mora biti dizajniran iznova, dok 5 označava raspored koji ne zahteva nikakve korekcije. Eksperimentalni dizajn je inspirisan studijama [28, 119].

Metrike exact matching i livability imaju binarnu prirodu (tačno/netačno, useljiv/neuseljiv), pa su performanse na nivou celog skupa podataka izražene kroz tačnost (engl. *accuracy*), definisanu kao odnos broja ispravno klasifikovanih primera i ukupnog broja primera. U daljem tekstu, kada se ove metrike prikazuju na nivou celog skupa, pod tim se podrazumeva tačnost. Za metriku applicability, gde se ocena dodeljuje na skali od 0 do 5, rezultati su prikazani kao prosečna vrednost. U pojedinim slučajevima, kada u perceptualnim studijama učestvuje više ispitanika, određeni raspored je prihvatljiv za jednog stručnjaka, ali ne i za drugog, te konačni rezultat predstavlja prosečnu vrednost metrike po svim ispitanicima.

## **5.4 Metod za raspoređivanje kuhinjskih elemenata zasnovan na pravilima (engl. *rule-based*)**

### **5.4.1 Opis metoda**

U ovom poglavlju razvijeni je metod za automatsko generisanje rasporeda kuhinje I-oblika zasnovan na pravilima. Dve ključne komponente metoda su: ulazne karakteristike (infrastrukturni elementi) i pravila odlučivanja sa pridruženim težinama. Pravila su zasnovana na ekspertizama prikupljenim kroz intervju sa stručnjacima, koji je korišćen i za definisanje ulaznih karakteristika i ciljnih vrednosti sistema (potpoglavlje 5.3). Na osnovu rezultata intervjua kreiran je algoritam zasnovan na if-else logici, koji integriše različita pravila, njihove težine i ulazne karakteristike kako bi generisao optimalan raspored kuhinjskih elemenata.

## Pravila odlučivanja

Pravila odlučivanja definišu način na koji se kuhinjski elementi raspoređuju u odnosu na ulazne karakteristike. Ključna pravila definisana kroz intervju sa stručnjacima:

- Razdaljina između sudopere i vodovodnih instalacija treba da bude minimalna.
- Razdaljina između šporeta i ventilacionog sistema treba da bude minimalna.
- Razdaljina između skladištenja i ulaznih vrata kuhinje treba da bude minimalna.
- Razdaljina između šporeta i prozora treba da bude minimalna.
- Razdaljina između šporeta i početka ili kraja kuhinje treba da bude minimalna.
- Razdaljina između frižidera i početka ili kraja kuhinje treba da bude minimalna.
- Šporet ne sme biti postavljen pored sudopere.
- Šporet ne sme biti postavljen pored frižidera.
- Sudopera ne sme biti postavljena pored frižidera.
- Sudopera treba da bude pozicionirana između šporeta i frižidera.

Svako pravilo ima pridruženu težinu, koja odražava njegovu važnost u procesu odlučivanja. Primeri pravila sa težinama:

- Najvažnije pravilo: Šporet ne sme biti pored sudopere (najveća težina),
- Manje važno pravilo: Prozori se preporučuju iznad šporeta (niža težina),
- Srednje važno pravilo: Frižider treba da bude blizu ulaza u kuhinju (srednja težina).

## Proces odlučivanja putem *if-else* strukture

Na osnovu ulaznih karakteristika, sistem koristi algoritam odlučivanja zasnovan na *if-else* logici, koji kombinuje pravila sa pridruženim težinama za generisanje i rangiranje mogućih rasporeda kuhinje. Ovaj algoritam je razvijen na osnovu intervjua sa stručnjacima. Stručnjaci su definisali relevantna pravila, njihove međusobne odnose i važnosti kroz pridružene težine. Prvo se generiše više potencijalnih rasporeda na osnovu različitih kombinacija pravila, a zatim se oni rangiraju prema zbiru težina primenjenih pravila.

Primer procesa odlučivanja:

1. Proveravaju se ulazne karakteristike (npr. lokacija vodovoda i ventilacije).
2. Primenjuju se pravila sa pridruženim težinama:

- Ako je lokacija vodovoda poznata, postavi sudoperu što bliže vodovodu.
  - Ako je pozicija ventilacije dostupna, postavi šporet uz ventilaciju.
  - Ako je moguća kolizija između šporeta i sudopere, primeni pravilo sa većom težinom (razdvoji ih).
3. Sistem rangira moguće rasporede na osnovu ukupnih težinskih vrednosti primenjenih pravila.
  4. Kao rezultat, generiše se raspored sa najvišim zbirom težina pravila.

### Određivanje težina pravila

Prvo su definisana pravila odlučivanja i razvijen algoritam zasnovan na if-else logici, koji kombinuje pravila i ulazne karakteristike za generisanje optimalnih rasporeda kuhinje. Ovaj algoritam je potom implementiran u alat za anotaciju opisan u potpoglavlju 5.3. Za svako pravilo uspostavljena je skala sa diskretnim vrednostima, koja omogućava kvantifikaciju njegove važnosti u procesu odlučivanja. U alatu, ova skala je implementirana kroz interaktivni klizač, omogućavajući korisnicima da intuitivno prilagode značaj svakog pravila, čime direktno utiču na proces generisanja kuhinjskih rasporeda (slika 5.7).

Težine pravila određene su empirijski kroz iterativni proces evaluacije. Stručnjaci su prvo definisali početne težine pravila unutar unapred određenog raspona vrednosti. Razvijeni softver zasnovan na rule-based metodu zatim generiše rasporede dobijene na osnovu tih težina, koji stručnjaci analiziraju. Tokom evaluacije, stručnjaci su ocenjivali usklađenost generisanih rasporeda sa pravilima dizajna, funkcionalnošću i dobrom praksom. Na osnovu rezultata analize, težine pravila su sukcesivno prilagođavane dok se nisu dobile vrednosti koje generišu rasporede najvišeg kvaliteta. Ovim iterativnim postupkom empirijski su određene optimalne težine za svako pravilo.


Nakon prikupljanja ocena stručnjaka, izračunata je prosečna težina za svako pravilo, a zatim su te vrednosti integrisane u algoritam. Na ovaj način, metod je podešen tako da koristi pravila sa težinama koje reflektuju kolektivno znanje i iskustvo stručnjaka.

### 5.4.2 Softver

Alat za anotaciju opisan u potpoglavlju 5.3, koji je prvobitno služio za određivanje težina pravila, nadograđen je u softver za automatsko generisanje kuhinjskih rasporeda integracijom rule-based metoda. Softver funkcioniše na sledeći način: kada korisnik unese ulazne karakteristike prostora, sistem na osnovu pravila generiše četiri najoptimalnija rasporeda, prikazana u dvodimenzionalnom pogledu odozgo (slika 5.8). Korisnik može da odabere jedno od ponuđenih rešenja ili, ukoliko želi da dodatno utiče na rezultat, ručno promeni težine parametara i tako prilagodi konačni raspored (slika 5.7). Ako nijedno od automatski predloženih rešenja ne zadovoljava zadate kriterijume, korisniku je omogućeno da pomoću opcije „Force” samostalno kreira novi raspored.

| Rule                           | Value | *D                                  |
|--------------------------------|-------|-------------------------------------|
| WASHING - WATER DISTANCE       | 6     | <input checked="" type="checkbox"/> |
| COOKING - VENTILATION DISTANCE | 4     | <input checked="" type="checkbox"/> |
| STORAGE - ENTRY DISTANCE       | 1     | <input checked="" type="checkbox"/> |
| COOKING - EXIT DISTANCE        | 1     | <input checked="" type="checkbox"/> |
| COOKING - WINDOW DISTANCE      | 3     | <input checked="" type="checkbox"/> |
| COOKING - EDGE DISTANCE        | 10    | <input type="checkbox"/>            |
| STORAGE - EDGE DISTANCE        | 15    | <input type="checkbox"/>            |
| COOKING - WASHING TOUCHING     | 50    | <input type="checkbox"/>            |
| COOKING - STORAGE TOUCHING     | 40    | <input checked="" type="checkbox"/> |
| WASHING - STORAGE TOUCHING     | 20    | <input checked="" type="checkbox"/> |
| LAYOUT : WASHING IN THE MIDDLE | 40    | <input type="checkbox"/>            |

Slika 5.7: Dodeljivanje težina pravilima



Slika 5.8: Softver za automatsko generisanje kuhinjskih rasporeda

### 5.4.3 Rezultati

Performanse razvijenog metoda testirane su na LinKitLay skupu podataka (poglavlje 5.3) kroz perceptualne studije, u kojima je učestvovalo pet stručnjaka. Za evaluaciju je korišćena livability metrika (poglavlje 5.3.1). Rezultati evaluacije prikazani su u tabeli 5.1.

| Podskup   | Broj primera | Livability (apsolutne vrednosti) | Livability (%) |
|-----------|--------------|----------------------------------|----------------|
| Podskup 1 | 10           | 10.0                             | 100.00         |
| Podskup 2 | 20           | 20.0                             | 100.00         |
| Podskup 3 | 30           | 20.6                             | 68.67          |
| Podskup 4 | 40           | 18.6                             | 46.50          |
| Ukupno    | 100          | 69.2                             | 69.20          |

Tabela 5.1: Evaluacija livability metrikom

U najjednostavnijim slučajevima (*Podskup 1* i *Podskup 2*), koji karakterišu mali broj ulaznih podataka i jednostavne infrastrukturne pozicije, ostvarena je vrednost livability metrike od 100%.

Međutim, u složenijim scenarijima:

- Kod *Podskupa 3*, koji obuhvata različite ulazne karakteristike bez idealnog rasporeda, livability opada na 68,67%.
- Kod *Podskupa 4*, koji sadrži preklapajuće infrastrukturne elemente i najkompleksnije rasporede, ostvarena je vrednost livability od svega 46,5%.

Ovi rezultati ukazuju na to da primena *if-else* logike sa težinskim pravilima omogućava kreiranje realističnih i funkcionalnih kuhinjskih rasporeda u jednostavnijim slučajevima. Međutim, za složenije rasporede sa kompleksnijim pozicijama ulaznih karakteristika, neophodan je razvoj naprednijih metoda.

## 5.5 PKG metod zasnovan na sekvencijalnom nizu klasifikatora mašinskog učenja

### 5.5.1 Opis metoda


U ovom poglavlju predlažemo Procedural Kitchen Generation (PKG) metod za automatsko generisanje linearnog rasporeda kuhinje, koji predstavlja sekvencijalnu liniju (engl. *pipeline*) klasifikatora mašinskog učenja (slika 5.9).

Ulazne karakteristike PKG metoda su: dužina kuhinje, položaj ventilacije, položaj odvoda sudopere, položaj prozora, položaj ulaznih vrata i položaj izlaznih vrata. Metod se fokusira na linearne kuhinje koje sadrže tri glavna elementa - sudoperu, šporet i frižider - dok se prostor između tih elemenata popunjava radnim površinama.

PKG metod je strukturiran kao sekvencijalna linija šest klasifikatora mašinskog učenja (slika 5.9), zasnovan na principima koji proizilaze iz realne prakse dizajna enterijera [116]. Klasifikatori su:

1. klasifikator tipa sudopere,
2. klasifikator pozicije sudopere,
3. klasifikator tipa šporeta,
4. klasifikator pozicije šporeta,
5. klasifikator tipa frižidera,
6. klasifikator pozicije frižidera.

Generisani rasporedi vizualizovani su u Unity razvojnom okruženju, koristeći unapred definisane stilove kuhinja. PKG metod je evaluiran kroz kvantitativne i perceptualne studije.



Slika 5.9: Koraci PKG metoda

## Formulacija problema mašinskog učenja

Na osnovu definicija iz potpoglavlja 5.2 i rezultata intervjua opisanih u potpoglavlju 5.3, zadatak generisanja kuhinjskog rasporeda formalno se postavlja kao problem predikcije šest diskretnih ciljnih vrednosti, na osnovu šest diskretnih ulaznih karakteristika (slika 5.5). Ciljne vrednosti predstavljaju tipovi i pozicije glavnih kuhinjskih elemenata (frižider, sudopera, šporet). Ulazni parametri opisuju infrastrukturne karakteristike prostora.

Shodno ovoj definiciji, PKG metod je koncipiran kao dvokomponentni sistem, pri čemu se rešavaju dva klasifikaciona zadatka:

- predikcija tipa glavnih kuhinjskih elemenata,
- predikcija pozicije glavnih kuhinjskih elemenata.

## Arhitektura metoda

### Predikcija tipa glavnih kuhinjskih elemenata

Predikcija tipa elemenata posmatra se kao nadgledani klasifikacioni problem. Za sva tri glavna kuhinjska elementa postoje tri klase tipova, koje su prikazane u tabeli 5.2. Koriste se standardizovani (modularni) tipovi i dimenzije, opisani u potpoglavlju 5.2

|            | Sudopera |     |     | Šporet |     |     | Frižider |     |     |
|------------|----------|-----|-----|--------|-----|-----|----------|-----|-----|
| Tip        | S1       | S2  | S3  | Š1     | Š2  | Š3  | F1       | F2  | F3  |
| Dužina (m) | 0.3      | 0.6 | 1.2 | 0.3    | 0.6 | 1.2 | 0.6      | 0.9 | 1.2 |


Tabela 5.2: Tipovi glavnih kuhinjskih elemenata i njihove dimenzije

Ukoliko tip šporeta pripada prvoj klasi, tada šporet i frižider čine jedan element. U tom slučaju, frižider pripada nultom podtipu i nije potrebno predviđanje podtipa frižidera.

### Predikcija pozicije glavnih kuhinjskih elemenata

Predikcija pozicije elemenata posmatra se kao nadgledani klasifikacioni problem. Dužina kuhinje ograničena je na opseg od 90 cm do 600 cm. U skladu sa principima modularnog dizajna, moguće početne pozicije glavnih kuhinjskih elemenata određene su u intervalima od 30 cm, računajući od jedne ili druge ivice kuhinje.

Na osnovu toga, pozicije elemenata podeljene su u 40 klasa. Prvih 20 klasa predstavljaju pozicije na 0 cm, 30 cm, 60 cm itd. od leve ivice kuhinje. Klase 21, 22...40 predstavljaju pozicije na 0 cm, 30 cm, 60 cm itd. od desne ivice. Na primer, kuhinja dužine 127 cm ima 10 mogućih početnih pozicija za kuhinjske elemente (slika 5.10).



Slika 5.10: Metodologija za određivanje početnih pozicija elemenata

## Predikcija kompletnog kuhinjskog rasporeda

Predloženi PKG metod sastoji se od šest sekvencijalno povezanih modula, prikazanih u tabeli 5.3.

| Modul | Predikcija         |
|-------|--------------------|
| 1     | Tip sudopere       |
| 2     | Pozicija sudopere  |
| 3     | Tip šporeta        |
| 4     | Pozicija šporeta   |
| 5     | Tip frižidera      |
| 6     | Pozicija frižidera |

Tabela 5.3: Predikcioni moduli u PKG metodu

Svaki modul rešava jedan od dva ključna zadatka: klasifikaciju tipa ili klasifikaciju pozicije glavnih kuhinjskih elemenata. U skladu sa ovom dekompozicijom, za svaki korak metoda treniran je poseban klasifikator. Struktura metoda prati sekvencijalnu liniju, gde izlaz jednog klasifikatora predstavlja dodatnu ulaznu karakteristiku za naredni klasifikator, čime se postiže progresivna integracija informacija.

Ulaz u metod čini šest ulaznih karakteristika (slika 5.5) čije vrednosti definiše korisnik. Prvi modul predviđa tip sudopere, nakon čega naredni modul koristi ovu informaciju, zajedno sa inicijalnim ulaznim karakteristikama, kako bi odredio poziciju sudopere. Sledeći modul proširuje ulazne karakteristike dodavanjem predikcija prethodnih modula i predviđa tip šporeta. Modul za određivanje pozicije šporeta uzima u obzir tip i poziciju sudopere, tip šporeta i početne ulazne karakteristike kako bi generisao odgovarajuću lokaciju šporeta. Ovaj sekvencijalni proces se nastavlja sve do poslednjeg modula, koji koristi ukupno 11 karakteristika.

Redosled predikcija u modelu zasnovan je na arhitektonskom procesu projektovanja kuhinja, gde se prvo definiše pozicija sudopere (pretežno određena pozicijom kanalizacionog odvoda), zatim pozicija šporeta (uglavnom zavisna od pozicije ventilacije), a na kraju se određuje pozicija frižidera. Sprovedeni eksperimenti pokazali su da promena ovog redosleda u proseku dovodi do smanjenja vrednosti exact matching kod metoda za 3%.

Tokom faze treniranja modela, ulazne karakteristike svakog modula uzimaju se iz odgovarajućih trening primera, pri čemu se svaki klasifikator trenira nezavisno (slika 5.5).

### Klasifikacioni modeli mašinskog učenja

Pretprocesiranje podataka, treniranje i evaluacija klasifikatora realizovani su korišćenjem programskog jezika Python 3.6 i biblioteke scikit-learn. U okviru PKG modela testirani su različiti klasifikatori nadgledanog učenja kako bi se identifikovao najbolji metod za svaki korak predikcije. Dajemo kratak opis korišćenih klasifikatora.

Klasifikator zasnovan na stablu odlučivanja (engl. *Decision Tree*) deli podatke u hijerarhijsku strukturu na osnovu kriterijuma optimizacije, pri čemu svaki čvor reprezentuje ulaznu karakteristiku, dok su listovi označeni klasama.

Ansambl metoda slučajnih šuma (engl. *Random Forest*) sastoji se od više nekorelisanih stabala odlučivanja, čime se smanjuje varijansa modela i poboljšava generalizacija. Ova metoda primenjuje slučajni izbor podskupa karakteristika pri konstrukciji svakog stabla, dok se konačna predikcija određuje agregacijom pojedinačnih rezultata.

*Adaptive Boosting (AdaBoost)* predstavlja tehniku iterativnog treniranja ansambla „slabih” klasifikatora, pri čemu se težinski koeficijenti dodeljuju uzorcima koji su teži za klasifikaciju.

Naivni Bajes (engl. *Naive Bayes*) je probabilistički klasifikator zasnovan na Bajesovoj teoremi, koji podrazumeva međusobnu nezavisnost ulaznih karakteristika, čime omogućava efikasno modelovanje čak i u slučaju ograničenih količina podataka.

Višeslojni perceptron (engl. *Multilayer Perceptron*, MLP) je neuronska mreža sa propagacijom unapred, koja koristi višeslojne nelinearne transformacije za rešavanje složenih klasifikacionih problema.

Mašina se vektorima podrške (engl. *Support Vector Machine*, SVM) koristi tehnike kernel trick transformacije kako bi mapirao podatke u višedimenzionalni prostor i pronašao optimalnu granicu odlučivanja između klasa.

L2 logistička regresija (engl. *L2 logistic regression*) modeluje verovatnoću pripadnosti klasi gađnjavajući visoke vrednosti težinskih koeficijenata korišćenjem L2 regularizacije. Za rešavanje višeklasnog problema, primenjen je algoritam jedan naspram svih (engl. *One-vs-All*), gde se više binarnih klasifikatora logističke regresije kombinuje u jedinstven klasifikacioni model.

Podešavanje hiperparametara realizovano je primenom metode pretrage mreže (engl. *grid search*) u kombinaciji sa ukrštenom validacijom (engl. *cross-validation*) na trening skupu. Optimalne vrednosti hiperparametara za svaki algoritam date su u tabeli 5.4.

| Klasifikator           | Hiperparametri                                                                    |
|------------------------|-----------------------------------------------------------------------------------|
| Decision Tree          | criterion='gini', max_features=n_features, max_depth=None                         |
| Random Forest          | criterion='gini', n_estimators=500, max_features= 'sqrt(n_features)', max_depth=6 |
| AdaBoost               | n_estimators=50, learning_rate=1.0                                                |
| Naivni Bayes           | priors=None                                                                       |
| MLP                    | max_iter=5000, hid._layer_size=(100,100,100), random_state=7, activation='tanh'   |
| SVM                    | C=1, gamma=0.1, kernel='linear'                                                   |
| L2 Logistic regression | solver='liblinear', max_iter=100                                                  |

Tabela 5.4: Optimalni hiperparametri za testirane klasifikatore

## 5.5.2 Rezultati

Metod je evaluiran na LinKitLay skupu linearnih kuhinjskih rasporeda (poglavlje 5.3), koji sadrži jasno definisane trening i test skupove. Da bi se poboljšala robustnost modela i povećala količina dostupnih podataka za učenje, primenjena je tehnika simetričnog proširenja skupa podataka. Svaki trening primer je generisan u obrnutom redosledu, što znači da je kompletan raspored reflektovan u odnosu na središnju osu kuhinje. Konkretno:

- Element koji se prvobitno nalazio na levoj ivici zida sada se postavlja na desnu ivicu, i obrnuto.
- Redosled elemenata unutar rasporeda je očuvan, ali njihove pozicije su transformisane tako da odgovaraju reflektovanom rasporedu.
- Infrastrukturni elementi, poput položaja odvoda sudopere i ventilacije, takođe su reflektovani kako bi odražavali novu strukturu rasporeda.

Najpre se sprovodi poređenje različitih klasifikatora mašinskog učenja za svaki korak PKG metoda. Klasifikator Random Forest pokazuje najbolje rezultate, pa se njegove performanse detaljnije analiziraju.

Dalje, opisan je softverski modul razvijen u Unity okruženju, koji omogućava 3D vizuelizaciju modela kuhinjskih rasporeda. Pomoću ovog softvera predstavljeno je 100 kuhinjskih rasporeda generisanih PKG modelom, koji su evaluirani kroz perceptualnu studiju sa stručnjacima.

Na kraju, dobijeni rezultati upoređeni su sa rule-based metodom zasnovanom na pravilima, pri čemu je PKG model ostvario poboljšanje po livability metrici od 8.2%.

### Izbor klasifikacionog modela

U fazi izbora modela, prethodno opisani klasifikatori testirani su za svaki korak PKG modela nezavisno. Prilikom treniranja, pretpostavlja se da su prethodni koraci

PKG sekvencijalne linije 100% tačni, pa su ulazne karakteristike za svaki klasifikator preuzete iz trening primera iz skupa podataka. Za evaluaciju performansi korišćena je exact matching metrika (poglavlje 5.3.1). Za izbor najboljeg klasifikatora u svakom koraku primenjena je tehnika cross-validation sa pet podela (*5-fold cross validation*) na trening skupu. Rezultati eksperimenta prikazani su u tabeli 5.5.

| Klasifikator           | Koraci PKG modela<br>testirani nezavisno |           |           |           |           |           |
|------------------------|------------------------------------------|-----------|-----------|-----------|-----------|-----------|
|                        | Pozicija                                 |           |           | Podtip    |           |           |
|                        | W                                        | C         | S         | W         | C         | S         |
| Decision tree          | 70                                       | 65        | 92        | <b>99</b> | <b>99</b> | <b>99</b> |
| Random forest          | <b>71</b>                                | <b>75</b> | <b>95</b> | <b>99</b> | <b>99</b> | <b>99</b> |
| AdaBoost               | 24                                       | 27        | 50        | 99        | 96        | 77        |
| Naive Bayes            | 16                                       | 19        | 21        | 91        | 77        | 81        |
| Multilayer perceptron  | 58                                       | 50        | 75        | 83        | 77        | 74        |
| SVM                    | 47                                       | 40        | 70        | 99        | 99        | 99        |
| L2 logistic regression | 41                                       | 34        | 65        | 92        | 95        | 95        |

Tabela 5.5: Performanse klasifikatora po koracima PKG modela izražene exact matching metrikom. Podebljane su najveće vrednosti u koloni.

Prema dostupnoj literaturi, ne postoje modeli koji koriste identične ulazne karakteristike kao PKG model, što onemogućava direktno poređenje ovog modela sa postojećim pristupima. Ipak, rezultati pokazuju da predloženi metod daje bolje performanse: uz pretpostavku da neprihvatljive pozicije imaju IoU nule, Random Forest postiže IoU od 80%. To je više od vrednosti prijavljenih u radu [118] za metode iz literature: [65] – 62%, [55] – 61% i [118] – 73%.

## Kvantitativna analiza

Random Forest klasifikator pokazao je superiorne performanse u svim zadacima predikcije, pa je, kao najuspešniji model, korišćen u svakom koraku PKG modela i evaluiran na test skupu, primenom exact matching metrike. Ulazne karakteristike test primera korišćene su kao ulazne karakteristike modela. Rezultati su prikazani u tabeli (5.6)

| Podskup | Koraci PKG modela |          |        |          |          |          | PKG model |
|---------|-------------------|----------|--------|----------|----------|----------|-----------|
|         | Sudopera          |          | Šporet |          | Frižider |          |           |
|         | Tip               | Pozicija | Tip    | Pozicija | Tip      | Pozicija |           |
| 1       | 100               | 100      | 100    | 100      | 100      | 100      | 100       |
| 2       | 100               | 100      | 100    | 100      | 100      | 100      | 100       |
| 3       | 100               | 80       | 100    | 70       | 100      | 64       | 50        |
| 4       | 100               | 65       | 100    | 60       | 100      | 88       | 55        |
| Ukupno  | 100               | 80       | 100    | 75       | 100      | 84       | 67        |

Tabela 5.6: Exact matching za pojedinačne korake i celokupni PKG model, na kompletnom test skupu i na svakom podskupu pojedinačno

### Analiza odluka Random Forest modela

Kako bi se detaljnije istražile odluke Random Forest modela, značaj ulaznih karakteristika izračunat je pomoću Gini značaja (engl. *Mean Decrease Gini*), prema jednačini (5.1):


$$\text{importance}(\text{feature}) = \frac{1}{N_T} \sum_T \frac{\sum_{\text{node} \in T: \text{feature}(\text{node}) = \text{feature}} \text{importance}(\text{node})}{\sum_{\text{node} \in T} \text{importance}(\text{node})} \quad (5.1)$$

gde je  $N_T$  broj stabala u Random Forest modelu,  $T$  skup svih stabala,  $\text{feature}(\text{node})$  karakteristika korišćena za deljenje u čvoru, dok se značaj čvora računa prema jednačini (5.2):

$$\text{importance}(\text{node}) = w(\text{node}) \text{ gini}(\text{node}) - w(\text{node}_{\text{left}}) \text{ gini}(\text{node}_{\text{left}}) - w(\text{node}_{\text{right}}) \text{ gini}(\text{node}_{\text{right}}) \quad (5.2)$$

pri čemu je  $w(\text{node})$  težinski broj uzoraka koji dostižu dati čvor, dok je  $\text{gini}(\text{node})$  Gini nečistoća za dati čvor.

Analiza značaja ulaznih karakteristika za svaki korak PKG modela pokazuje visok stepen podudarnosti između odluka donetih Random Forest klasifikatorom i onih koje donose stručnjaci (slika 5.11).



Slika 5.11: Značaj ulaznih karakteristika: 0 – dužina kuhinje, 1 – pozicija ventilacije, 2 – pozicija kanizacionog odvoda, 3 – pozicija prozora, 4 – pozicija ulaza, 5 – pozicija izlaza, 6 – tip sudopere, 7 – pozicija sudopere, 8 – tip šporeta, 9 – pozicija šporeta, 10 – tip frižidera.

Najvažnija karakteristika za predikciju tipa sudopere je dužina kuhinje, dok je za predikciju njene pozicije ključna pozicija odvoda sudopere. Tip šporeta najviše zavisi od dužine kuhinje i tipa elementa za pranje, dok njegova pozicija zavisi od položaja ventilacije, dužine kuhinje i pozicije sudopere. Tip frižidera uglavnom se određuje na osnovu dužine kuhinje, tipa sudopere i kuhinje, dok se njegova pozicija najčešće određuje prema pozicijama šporeta i sudopere.

Rezultati analize pokazuju da predikcija pozicije šporeta u značajnoj meri zavisi od prethodno predviđene pozicije sudopere. Ova zavisnost objašnjava zašto je tačnost predikcije pozicije šporeta konzistentno niža u odnosu na tačnost predikcije pozicije sudopere (tabela 5.6).

S druge strane, predikcija pozicije frižidera postiže najvišu tačnost, uprkos zavisnosti od predikcija šporeta i sudopere. Analiza trening skupa, kao i tipičnih kuhinjskih rasporeda, ukazuje na to da se frižideri najčešće pozicioniraju u uglovima kuhinje. Kao

rezultat toga, čak i kada model ne predvidi tačne pozicije sudopere i šporeta, odluka o postavljanju frižidera u odgovarajući ugao ostaje nepromenjena.

Dodatno, ukupna tačnost modela niža je od tačnosti pojedinačnih predikcija, što ukazuje na to da greške nisu nužno međusobno povezane. Drugim rečima, postoje primeri u kojima samo jedan korak predikcije odstupa od očekivanog rezultata, dok su ostali koraci tačni.

### Perceptualne studije

U praksi, dizajn kuhinje nije strogo definisan pravilima, već predstavlja umetnički proces. Zbog toga u pojedinim slučajevima može postojati više ispravnih rasporeda za iste ulazne karakteristike, u zavisnosti od ukusa dizajnera i estetskih preferencija. S druge strane, čak i kada generisani raspored nije u potpunosti prihvatljiv, često su potrebne samo minimalne korekcije kako bi bio upotrebljiv.

Iz tog razloga, sprovedena je perceptualna studija uz učešće 23 stručnjaka, podeljenih u četiri grupe u skladu sa njihovom profesijom:

- 8 dizajnera enterijera, sa prosekom od 8.2 godine iskustva,
- 5 arhitekata, sa prosekom od 9.5 godina iskustva,
- 3 dizajnera nivoa u video igrama, sa prosekom od 3.1 godine iskustva i
- 7 master studenata dizajna enterijera, bez radnog iskustva.

Kako bi se procenio ne samo kvalitet generisanih kuhinjskih rasporeda, već i primenljivost sistema za njihovo automatsko generisanje u različitim industrijama, razvijen je softver u okviru Unity okruženja (verzija 2019.3.4f1). Ovaj softver omogućava trodimenzionalnu vizuelizaciju generisanih kuhinjskih rasporeda (slika 5.12) uz pomoć koje su sprovedene perceptualne studije. Isti test skup korišćen u kvantitativnoj analizi PKG modela upotrebljen je i u perceptualnim studijama.



Slika 5.12: Prostorna reprezentacija kuhinje unutar Unity scene

## Kvantitativni rezultati perceptualne studije

Vizuelna 3D reprezentacija 100 kuhinjskih rasporeda generisanih od strane PKG modela evaluirana je kroz dve perceptualne studije - studiji procene funkcionalnosti prostora (engl. *Livability study*) i studiji primenljivosti (*Applicability study*).

U studiji procene funkcionalnosti prostora, učesnici su procenjivali da li je svaki generisani raspored pogodan za život ili ne (livability metrika opisana u potpoglavlju 5.3.1). Rezultati za svaki podskup test skupa, kao i za celokupan test skup, prikazani su u tabeli 5.7.

| Podskup       | exact matching | Livability   |
|---------------|----------------|--------------|
| 1             | 100            | 100          |
| 2             | 100            | 100          |
| 3             | 50             | 71.36        |
| 4             | 55             | 65.17        |
| <b>Ukupno</b> | <b>67</b>      | <b>77.47</b> |

Tabela 5.7: Performanse PKG metoda izmerene exact matching i livability metrikom

U drugoj studiji, isti skup učesnika ocenjuje svaki od generisanih rasporeda na osnovu njegove primenljivosti, koristeći applicability metriku opisanu u potpoglavlju 5.3.1). Srednje vrednosti za svaku grupu učesnika, kao i ukupni rezultati, prikazani su u tabeli 5.8.

| Učesnici                 | Applicability |
|--------------------------|---------------|
| Dizajneri enterijera     | 4.45          |
| Arhitekte                | 4.55          |
| Dizajneri nivoa u igrama | 4.81          |
| Studenti                 | 4.73          |
| <b>Ukupno</b>            | <b>4.6</b>    |

Tabela 5.8: Performanse PKG metoda izmerene applicability metrikom

Rezultati studije funkcionalnosti prostora pokazuju povećanje stope prihvatljivosti generisanih rasporeda u poređenju sa exact matching metrikom. Konkretno, za podskup 3 ostvareno je povećanje od 21,3%, dok je za podskup 4 povećanje iznosilo 10%. To znači da je u 10,4% slučajeva PKG model generisao raspored koji je ocenjen kao prihvatljiv, ali se razlikovao od rešenja u test skupu. Dodatno, studija primenljivost pokazala je da su generisani rasporedi zahtevali minimalne korekcije kako bi bili upotrebljivi u praksi.

## Kvalitativna analiza i povratne informacije učesnika

Pored kvantitativne evaluacije, učesnici su dali kvalitativne povratne informacije o PKG metodu i njegovoj potencijalnoj primeni u različitim oblastima. Većina ispitanika je istakla da softver za automatsko generisanje kuhinjskog rasporeda i predstavljanje

u 3D prostoru, može biti koristan u ubrzanju procesa dizajna kuhinje, uz mogućnost integracije u postojeće profesionalne softverske pakete. Svi učesnici, osim dizajnera nivoa u video igrama, izrazili su potrebu za integracijom PKG modela u specijalizovane 2D i 3D softverske alate, kao što su AutoCAD, 3D Max i SketchUp.

Dizajneri enterijera prepoznali su PKG metod kao alat koji može unaprediti komunikaciju sa klijentima i ubrzati proces izrade dizajna. Tradicionalni proces dizajniranja kuhinje podrazumeva kreiranje početne 3D vizualizacije na osnovu preferencija klijenta i dimenzija prostora. Klijenti potom vrše evaluaciju dizajna, što često rezultira višestrukim iteracijama pre konačnog odobrenja. Svaka promena zahteva dodatno 3D modelovanje, koje traje nekoliko sati, kao i dodatne sastanke za evaluaciju novih verzija. PKG model značajno skraćuje ovaj proces omogućavajući generisanje dizajna u realnom vremenu, čime se eliminiše potreba za višestrukim iteracijama i sastancima. Kao dodatno poboljšanje, dizajneri enterijera su predložili proširenje baze 3D modela u budućim verzijama softvera, sa mogućnostima uređivanja elemenata. Takođe, istaknuto je da trenutno ograničenje modela na samo jedan šporet, frižider i sudoperu smanjuje njegovu primenljivost za dizajn luksuznih enterijera.

Arhitekte su istakle da PKG model može imati praktičnu primenu u fazi projektovanja objekata, posebno pri izradi 2D osnova stanova. Model može olakšati i ubrzati ovaj proces, budući da se u toj fazi ne zahteva precizno definisan raspored kuhinje, već samo logična i funkcionalna prostorna organizacija. PKG model omogućava generisanje takvih predloga u kratkom vremenskom roku, što ga čini pogodnim alatom za arhitekte u ranim fazama projektovanja.


Dizajneri nivoa u video igrama su prepoznali primenu PKG modela u scenama sa velikim brojem enterijera, pri čemu su posebno naglasili značaj integracije modela u Unity okruženje. Međutim, istakli su da su, osim dužine kuhinje, sve ostale ulazne karakteristike nepotrebne za njihovu primenu, budući da 3D modeli enterijera u igrama ne moraju biti funkcionalni (npr. sudopera nije povezana sa odvodom, šporet nije povezan sa ventilacijom itd.). Za njih je ključna vizuelna verodostojnost prostora, kako bi enterijer izgledao realistično u kontekstu igre.

Master studenti arhitekture i dizajna enterijera identifikovali su PKG model kao potencijalno vredan edukativni alat. Zbog složenosti pravila koja se moraju poštovati pri dizajniranju kuhinja, PKG model im omogućava brzo generisanje primera i učenje kroz analizu konkretnih slučajeva. Takođe, istakli su da je u njihovim projektima stambenih enterijera dizajn i 3D modelovanje kuhinje jedan od najzahtevnijih zadataka, te da bi im razvijeni alat mogao značajno olakšati rad.

Ukupni rezultati perceptualnih studija sugerišu da PKG model može biti vredan alat za podršku u procesu dizajniranja kuhinjskih enterijera.

### **Poređenje sa rule-based metodom**

Performanse PKG metoda upoređene su sa rezultatima metoda zasnovanog na pravilima opisanog u poglavlju 5.4. Budući da oba istraživanja koriste isti test skup i primenjuju identičnu metodologiju perceptualnih studija, moguće je direktno uporediti njihovu efikasnost. Rezultati za pojedinačne podskupove, kao i za kompletan testni skup, prikazani su na slici 5.13.



Slika 5.13: Poređenje vrednosti livability metrike između PKG metoda i rule-based metoda, po podskupovima i na kompletnom test skupu

Rezultati pokazuju da kod podskupova 1 i 2 oba pristupa ostvaruju maksimalne performanse. Međutim, u podskupovima 3 i 4, PKG metod zasnovan na klasifikatoru Random Forest postiže bolje rezultate u odnosu na metod zasnovan na pravilima.

Ukupna tačnost PKG modela iznosi 77,4%, dok rule-based metod postiže tačnost od 69,2%

### 5.5.3 Diskusija

Rezultati ovog istraživanja pokazuju da mašinsko učenje može uspešno da identifikuje obrasce koji su ključni za rešavanje složenih zadataka, koji zahtevaju dizajnerske i inženjerske veštine. Analiza značaja ulaznih karakteristika ukazuje na to da model pri donošenju odluka koristi obrasce slične onima koje primenjuju stručnjaci.

PKG metod je ostvario 100% tačnost na podskupovima 1 i 2, dok na podskupovima 3 i 4 još uvek postoji prostor za poboljšanje tačnosti.

Poređenje performansi sa rule-based metodom pokazuje da PKG metod postiže jednake ili bolje rezultate. Razlika od 8,2% u korist PKG modela ukazuje na to da je model mašinskog učenja uspeo da prepozna složene obrasce koji ne mogu biti eksplicitno definisani pravilima dizajniranja kuhinje.

Učesnici perceptualnih studija ocenili su da se generisani rasporedi mogu primeniti u projektovanju enterijera, izradi 2D osnova i razvoju nivoa u video-igrama, uz napomenu da su u nekim slučajevima potrebne korekcije da bi raspored bio upotrebljiv.

Perceptualne studije su takođe potvrdile značaj razvoja metoda za automatizovano generisanje kuhinjskih rasporeda. Stručnjaci su ovakav alat prepoznali kao koristan u praksi, posebno u kontekstu ubrzavanja dizajnerskog procesa, unapređenja komunikacije sa klijentima i obrazovanja.

Rezultati eksperimenata pokazuju da PKG model ima potencijal da značajno pomogne dizajnerima u njihovoj praksi ali postoji potreba za unapređenjem generisanih rešenja. U skladu sa tim, u sledećem poglavlju predstavljamo LinLayCNN metod, koji generiše kvalitetnije kuhinjske rasporede i smanjuje potrebu za korekcijama.

## 5.6 Metod LinlayCNN za generisanje linearnog kuhinjskog rasporeda

U ovom poglavlju implementiramo metodu LinLayCNN za generisanje linearnih kuhinjskih rasporeda i upoređujemo njene performanse sa prethodnim metodama.


### 5.6.1 Opis metoda

#### 5.6.1.1 Formulacija problema

Zadatak generisanja kuhinjskog rasporeda, koji je prethodno definisan prilikom razvoja PKG metoda, i u ovom poglavlju ostaje postavljen kao problem predikcije šest diskretnih ciljnih vrednosti – tipova i pozicija glavnih kuhinjskih elemenata – na osnovu šest infrastrukturnih ulaznih karakteristika (slika 5.5). Pošto je PKG metod tačno predvideo tipove elemenata, ovde se fokusiramo na predikciju njihovih pozicija, uz pretpostavku da su tipovi unapred poznati. Ulazne karakteristike se posmatraju kao celobrojne vrednosti, izražene u centimetrima. U slučajevima kada su podaci dostupni u milimetrima ili sadrže decimale, vrši se zaokruživanje na najbliži ceo broj.

#### 5.6.1.2 Transformacija ulaznih karakteristika i ciljnih vrednosti


Ulazni niz karakteristika transformiše se u 2D format pogodan za obradu LinLayCNN metodom tako što se svaka karakteristika predstavlja kao zaseban jednodimenzionalni kanal širine jednake maksimalnoj dužini kuhinje. Na mestima gde se određena karakteristika pojavljuje, vrednost je postavljena na 1, dok je na ostalim pozicijama 0. Dužina kuhinje se predstavlja kanalom u kojem su jedinice postavljene od početne pozicije pa do tačke koja odgovara dužini kuhinje (slika 5.14). Kao i u PKG metodu (potpoglavlje 5.5), predikcija pozicija elemenata formulisana je kao klasifikacija u 40 diskretnih klasa. Svaka klasa pokriva interval od 30 cm duž kuhinje, računato od leve ili desne ivice.



Slika 5.14: Transformacija ulaznih karakteristika

### 5.6.1.3 Iterativno generisanje rasporeda

Generisanje rasporeda se vrši iterativnim postupkom, gde se u svakom koraku predviđa pozicija jednog glavnog kuhinjskog elementa. Za svaki element definišu se dva posebna ulazna kanala: *placed* i *to-be-placed*. Elementi čije su pozicije već određene u prethodnim koracima predstavljeni su kroz *placed* kanale – binarne vektore sa jedinicama na pozicijama gde su ti elementi postavljeni, čime se omogućava kontekstualno učenje na osnovu već generisanog dela rasporeda. Kanal *to-be-placed* označava element koji se u tom koraku pozicionira i popunjava se jedinicama u dužini koja odgovara njegovom tipu, počev od početne pozicije. Na taj način, modelu se eksplicitno pruža informacija o dimenziji elementa koji treba smestiti u prostor (slika 5.15).



Slika 5.15: Ilustrativni primer dva koraka u iterativnom generisanju kuhinjskog rasporeda. (1) Postavljanje šporeta, pod pretpostavkom da je sudopera već pozicionirana u prethodnom koraku, i (2) Postavljanje frižidera. Višekanalni ulaz predstavlja ulazne karakteristike, pri čemu širina odgovara maksimalnoj dužini kuhinje (smanjenoj radi preglednosti).

Postupak generisanja rasporeda obuhvata sledeće korake:

1. prvo se predviđa pozicija sudopere,
2. zatim se ta informacija koristi kao dodatni ulaz za predikciju pozicije šporeta,
3. na kraju, koristeći prethodno predviđene pozicije sudopere i šporeta, predviđa se pozicija frižidera.

Ovaj redosled predikcija odgovara načinu na koji dizajneri enterijera postavljaju elemente u realnim projektima (poglavlje 5.3).

Za razliku od PKG metoda, gde se u svakom koraku koristi i zasebno trenira drugačiji model mašinskog učenja, metoda LinLayCNN koristi isti model u svim koracima predikcije.

## 5.6.2 Rezultati

Metod je evaluiran na LinKitLay skupu podataka (poglavlje 5.3), metrikama opisanim u potpoglavlju 5.3.1.

Odrađene je perceptualna studija sa 8 ispitanika iz sledećih oblasti:

- 2 dizajnera enterijera, sa prosekom od 8 godine iskustva,
- 2 arhitekata, sa prosekom od 9.4 godina iskustva,
- 2 dizajnera nivoa u video igrima, sa prosekom od 3.1 godine iskustva,
- 2 master studenta dizajna enterijera, bez radnog iskustva.

Postupak perceptualne studije za LinLayCNN metod sproveden je na isti način kao i kod PKG metoda (potpoglavlje 5.5.2) - rasporedi generisani na osnovu ulaznih podataka iz test skupa vizualizovani su u razvojnom okruženju Unity i prosleđeni ispitanicima na analizu, a evaluacija je izvršena korišćenjem livability metrike.

Takođe, generisani rasporedi upoređeni su sa referentnim rasporedima iz test skupa exact matching metrikom. Vrednosti obe metrike na kompletnom test skupu i na svakom podskupu date su u tabeli 5.9.

| Podskup       | Exact matching | Livability  |
|---------------|----------------|-------------|
| 1             | 100            | 100         |
| 2             | 100            | 100         |
| 3             | 74             | 96.6        |
| 4             | 43             | 60          |
| <b>Ukupno</b> | <b>72</b>      | <b>82.8</b> |

Tabela 5.9: Performanse LinLayCNN metoda izmerene pomoću exact matching i livability metrike (%).

Performanse metoda su upoređene sa postojećim pristupima. Vrednosti exact matching metrike za PKG i LinLayCNN metod date su u tabeli 5.10, dok su u tabeli 5.11 prikazane vrednosti livability metrike za rule-based, PKG i LinLayCNN metod.

| Podskup       | PKG       | LinLayCNN |
|---------------|-----------|-----------|
| 1             | 100       | 100       |
| 2             | 100       | 100       |
| 3             | 50        | <b>74</b> |
| 4             | <b>55</b> | 43        |
| <b>Ukupno</b> | 67        | <b>72</b> |

Tabela 5.10: Performanse PKG i LinLayCNN metoda izmerene pomoću exact matching metrike (%). Podebljane su najveće vrednosti u vrsti.

| Podskup       | Rule-based | PKG       | LinLayCNN   |
|---------------|------------|-----------|-------------|
| 1             | 100        | 100       | 100         |
| 2             | 100        | 100       | 100         |
| 3             | 68.67      | 71.36     | <b>96.6</b> |
| 4             | 46.5       | <b>65</b> | 60          |
| <b>Ukupno</b> | 69.2       | 77.4      | <b>82.8</b> |

Tabela 5.11: Performanse rule-based, PKG i LinLayCNN metoda izmerene livability metrikom (%). Podebljane su najveće vrednosti u vrsti.

### 5.6.3 Diskusija

Rezultati prikazani u tabelama ukazuju na to da metoda LinLayCNN postiže superiorne rezultate u odnosu na PKG model, sa poboljšanjem od 5% prema exact matching metrici i 5.4% u perceptualnim studijama.

Detaljna analiza performansi po podskupovima otkriva zanimljive obrasce. Na četvrtom podskupu, koji obuhvata najkompleksnija pravila dizajna, LinLayCNN postiže 12% slabiji rezultat od PKG modela prema exact matching metrici. Nasuprot tome, na trećem podskupu, LinLayCNN značajno nadmašuje PKG model sa 24% boljim rezultatom. Ovakvo ponašanje modela može se objasniti rezultatima analize prostornog rezonovanja LinLayCNN metode, prikazanim u poglavlju 4, koji ukazuju na to da se sa povećanjem kompleksnosti rasporeda povećava i potreba za većim trening skupom kako bi se očuvale performanse metoda. U slučaju trećeg podskupa, očigledno je bilo dovoljno podataka za obuku, što je omogućilo LinLayCNN modelu da postigne bolje rezultate u odnosu na PKG model.

Rezultati perceptualnih studija pokazuju da LinLayCNN model na trećem i četvrtom podskupu ostvaruje poboljšanje od oko 20% kada se uporede exact matching i livability metrike, dok PKG model na istom zadatku beleži povećanje od svega 10%.

Ovakvi rezultati sugerišu da LinLayCNN model efikasnije uči strukturne obrasce kuhinjskih rasporeda i bolje generalizuje na nove primere, omogućavajući generisanje validnih i funkcionalnih rasporeda čak i kada se ne poklapaju u potpunosti sa referentnim podacima iz test skupa. Nasuprot tome, PKG model se u većoj meri oslanja na reprodukciju obrazaca iz trening skupa, što dovodi do manje fleksibilnosti i slabije generalizacije u realnim scenarijima.

## 5.7 Zaključak

U ovom poglavlju predloženi su metodi za automatsko generisanje linearnih kuhinjskih rasporeda. Rule-based metod koristi pravila definisana od strane stručnjaka dok PKG i LinLayCNN metod primenjuju modele mašinskog učenja za učenje složenih dizajnerskih ograničenja iz skupa podataka i generišu predloge rasporeda koji su upotrebljivi bez, ili uz minimalne, korekcije.

Pored toga, formiran je i javno objavljen skup podataka sa linearnim kuhinjskim

rasporedima - LinKitLay, kreiran od strane stručnjaka. Ovakav skup podataka može predstavljati značajan resurs za buduće pristupe zasnovane na podacima.

Metode su testirane na ovom skupu podataka pri čemu je LinLayCNN model ostvario najbolje rezultate prema svim evaluacionim metrikama. U okviru perceptualnih studija, 82 % generisanih rasporeda ocenjeni su kao direktno upotrebljivi, dok su preostali ocenjeni kao upotrebljivi uz minimalne korekcije, što potvrđuje visok nivo praktične primenljivosti metoda.

Pored evaluacije generisanih rasporeda u perceptualnim studijama, ispitanici su ocenjivali i upotrebljivost alata za automatsko generisanje kuhinjskih rasporeda, pri čemu su ga prepoznali kao koristan resurs sa značajnim potencijalom primene u dizajnu enterijera, arhitekturi, razvoju video-igara i obrazovanju.

Ovo poglavlje potvrđuje praktičnu upotrebljivost LinLayCNN metode, demonstrirajući njenu sposobnost da generiše linearne kuhinjske rasporede.

Iako LinLayCNN pokazuje visok nivo uspešnosti, postoji prostor za unapređenja. Zavisnost među koracima predikcije utiče na performanse metoda, pa treba isprobati i druge pristupe. Povećanje skupa podataka bi unapredilo performanse modela i omogućilo primenu kompleksnijih modela mašinskog učenja i generisanje kompletnog rasporeda u jednom prolazu. Takođe, istraživanja treba proširiti na druge tipove kuhinja (II-oblik, L-oblik). Metod je trenutno ograničen na jedan primerak svakog glavnog elementa, što takođe ostavlja prostor za unapređenje.

## Glava 6

# Primena metoda na poljoprivrednom problemu predviđanja promene težine košnice

U ovom poglavlju predstavljena je inovativa primena LinLayCNN metoda u novom domenu - za predikciju događaja u pčelarstvu. Metod koji je prvobitno razvijen za generisanje rasporeda objekata u linearnom prostoru, ovde se translira iz prostornog u vremenski domen, gde se „raspoređivanje objekata u prostoru“ zamenjuje „raspoređivanjem događaja u vremenu“. U osnovi oba problema nalazi se isti zadatak – prepoznavanje odnosa među elementima duž jedne dimenzije.

U poglavlju se prikazuju osnove pčelarstva i značaj pčela, uloga veštačke inteligencije u pčelarstvu kao i izazovi u prikupljanju podataka. Opisuje se primena LinLayCNN metode kojom se, na osnovu meteoroloških podataka, predviđa promena težine košnice u narednih sedam dana. Nakon toga sledi eksperimentalna analiza i zaključci.

### 6.1 Značaj pčela i osnove pčelarstva

Pčele su insekti od presudnog značaja za očuvanje biodiverziteta i prirodnih resursa, što direktno utiče na opstanak čitavog čovečanstva [120]. Među njima, medonosne pčele zauzimaju posebno mesto kao glavni prirodni posrednici u procesu prenosa polena s jednog cveta na drugi, čime omogućavaju oplodnju biljaka – kako samoniklih, tako i gajenih vrsta [121]. Poljoprivredna proizvodnja koja zavisi od oprašivanja životinjama se učetrostručila u poslednjih 50 godina.

Veza između ljudi i pčela datira još od pre više od 9000 godina. Tada su se hrabri pojedinci peli uz strme litice kako bi sakupili med iz gnezda divljih pčela, poput vrste *Apis dorsata*, koja nastanjuje litice i visoka stabla [122]. Vremenom su mnoge kulture razvile uzajamne odnose sa medonosnim pčelama, pružajući im sklonište u konstruisanim košnicama u zamenu za deo dragocenog meda. Prvi zapisi o pripitomljavanju pčela datiraju još iz 2400. godine p.n.e. [123]. Od tada, koristi koje ljudi imaju od pčela postaju sve značajnije, pa njihova uloga prevazilazi okvire ekologije i postaje neizostavna i u ekonomiji.

Savremeno pčelarstvo počiva na principima koji su definisani pre više od 200 godina. Da bi stekao uvid u stanje pčelinje zajednice, pčelar mora da bude fizički prisutan na pčelinjaku, da ručno otvori svaku košnicu i izvrši vizuelnu inspekciju svakog rama. U 80% slučajeva ne postoji potreba za intervencijom ali košnice moraju da se otvaraju radi provere stanja, pri čemu svako otvaranje dovodi do uznemiravanja pčela. Košnice je moguće pregledati isključivo danju, kada nema kiše i kada je temperatura između 15°C i 38°C. U proseku, jedan pčelar uspeva da pregleda oko 10 košnica dnevno, pa pregled velikih pčelinjaka sa preko 150 košnica predstavlja ozbiljan izazov. Svaka košnica se u proseku pregleda 15 puta godišnje, dok u međuvremenu pčelar nema nikakav uvid u stanje pčelinje zajednice, što onemogućava pravovremeno reagovanje koje je od suštinskog značaja za pravilan razvoj. Na osnovu zapažanja tokom inspekcije, pčelar mora odmah, na licu mesta, da donese odluke i preduzme dalje korake, što zahteva veliko znanje i iskustvo kako bi pčelarenje bilo pravilno, a potezi optimalni.


## 6.2 Precizno pčelarstvo

Ograničenja tradicionalnog pčelarstva, koje se oslanja na vizuelne procene i lično iskustvo pčelara, nameću potrebu za novim pristupom. Stalni pad broja pčela poslednjih godina, prisustvo bolesti poput varoe i sve izraženije klimatske nestabilnosti čine odluke zasnovane na analizi podataka (engl. *data-driven decisions*) sve značajnijim. Princip koji sve više dobija na značaju u industriji pčelarstva jeste precizno pčelarstvo (engl. *Precision Beekeeping, PB*), koje predstavlja podgranu precizne poljoprivrede. Precizno pčelarenje je termin koji je prvi put definisan u radu [124] kao „Strategija upravljanja pčelinjakom zasnovana na praćenju pojedinačnih pčelinjih društava sa ciljem minimizacije potrošnje resursa i maksimizacije produktivnosti pčela”. Jedan od glavnih ciljeva preciznog pčelarstva jeste razvoj alata za kontinuirano praćenje pčelinjih društava u realnom vremenu tokom njihovog životnog i proizvodnog ciklusa. Ti alati se zasnivaju na automatizovanim, informaciono-tehnološkim rešenjima koja ne izazivaju dodatni stres kod pčela i smanjuju nepotrebno trošenje resursa [125].

Primer primene preciznog pčelarenja: Vaga ispod košnice beleži postepeni pad težine tokom nedelje → sistem za precizno pčelarstvo obaveštava pčelara → pčelar proverava i otkriva da je košnica bez matice → rana intervencija spašava zajednicu.

### 6.2.1 Uređaji za precizno pčelarstvo

Većina komercijalno dostupnih uređaja za precizno pčelarstvo koristi kombinaciju različitih grupa senzora za prikupljanje podataka, uz dodatni sistem za analizu tih podataka. Komparativne analize pokazuju da su dominantni senzori koji se koriste za prikupljanje podataka senzori za temperaturu i vlažnost, zatim senzori za merenje težine, zvuk i vibracije, brojanje ulaska i izlaska pčela i senzori za praćenje sadržaja ramova (slika 6.1). Zastupljenost je izražena kao procenat košnica koje sadrže navedeni tip senzora.



Slika 6.1: Zastupljenost senzora u preciznom pčelarstvu (%)

Ovakva raspodela posledica je dostupnosti senzora i složenosti njihove integracije u funkcionalan uređaj.

### 6.2.2 Primena veštačke inteligencije

Veštačka inteligencija otvara novo poglavlje u upravljanju pčelinjim zajednicama. Integracijom AI u precizno pčelarstvo omogućeno je donošenje odluka zasnovanih na podacima, čime se unapređuje celokupno upravljanje pčelinjacima i povećava održivost proizvodnje [126, 127]. Korišćenjem AI tehnologija, pčelari mogu preći sa reaktivnog na proaktivno upravljanje pčelinjacima, što doprinosi boljem zdravlju zajednica i većoj efikasnosti pčelara.

AI pomaže u obradi i tumačenju podataka koji se kontinuirano prikupljaju iz košnice putem interneta inteligentnih uređaja (engl. *Internet Of Things*, IoT). Neki od primera korišćenja su: pametni nadzor košnice i analizu podataka [128], automatsko prepoznavanje stanja i aktivnosti pčelinjeg društva [129, 130], otkrivanje bolesti i štetočina [131] kao i za predikciju i donošenje odluka [132, 133].

Uprkos dostupnosti tehničkih resursa, tržišna primena sistema za podršku odlučivanju zasnovanih na veštačkoj inteligenciji i senzorima i dalje je niska [134]. Iako savremeni uređaji i senzori omogućavaju prikupljanje velikih količina podataka iz košnica, jedan od glavnih izazova je nedostatak kvalitetnih, anotiranih podataka za treniranje modela. Kako bi se u potpunosti iskoristili potencijali veštačke inteligencije u pčelarstvu neophodno je dugoročno prikupljanje velike količine podataka iz različitih okruženja, uz pažljivo vođenje kontekstualnih beleški. Tek tada će veštačka inteligencija moći da ostvari svoj puni potencijal u oblasti pčelarstva.

## 6.3 Podaci u pčelarstvu: specifičnosti, ograničenja i izvori

### Izazovi u prikupljanju i interpretaciji podataka

U radu sa podacima u oblasti pčelarstva javljaju se višestruki izazovi – od tehničkih (praznine, šum), preko bioloških (intervencije pčelara, retki događaji poput rojenja), do metodoloških (potreba za augmentacijom).

Pčele predstavljaju složen biološki sistem čije ponašanje zavisi od brojnih spoljašnjih i unutrašnjih faktora – od vremenskih uslova i dostupnosti paše, do dinamike same zajednice i načina pčelarenja. Promene u težini košnice, na primer, mogu biti posledica prirodnog unosa nektara, ali i intervencija pčelara poput dodavanja nastavka ili prihranjivanja šećernim sirupom, što često ostaje nezabeleženo i otežava pouzdanu interpretaciju podataka (detaljnije objašnjenje je dato u dodatku A.1). S obzirom na to da pčelinje zajednice prolaze kroz sezonski ciklus u kojem se tipični događaji javljaju u određenim fazama godine, kraći periodi posmatranja i ograničen broj košnica mogu dovesti do nedostatka važnih obrazaca, posebno onih retkih ili sezonski uslovljenih, poput gubitka matice ili pojave bolesti. Pouzdana analiza stoga zahteva dugoročno i prostorno raznovrsno prikupljanje podataka, uz obavezno preprocesiranje zbog šuma, praznina i nepravilnosti u sirovim merenjima nastalim usled tehničkih grešaka, prekida rada uređaja ili vremenskih uslova.

Zbog svega ovoga prikupljanje podataka u pčelarstvu je tehnički zahtevno, skupo i sporo, zbog čega su kvalitetno anotirani skupovi podataka u pčelarstvu retki. Nedostatak reprezentativnih i izbalansiranih skupova podataka otežava učenje modela, pa se često pribegava primeni različitih tehnika augmentacije kako bi se veštački povećao skup podataka i poboljšala robusnost modela [135, 136].

### **Sezonska i lokalna specifičnost podataka**

Ponašanje pčela zavisi od brojnih sezonskih i lokalnih faktora, koji uzrokuju da isti biološki procesi kod pčela ne nastupaju uvek u isto vreme svake godine, a u pojedinim sezonama ili na pojedinim lokacijama mogu potpuno izostati. Zbog toga se u podacima mogu javiti sezonske specifičnosti - karakteristične za određenu godinu ili sezonu, kao i lokalne specifičnosti - karakteristične za konkretnu geografsku oblast. Ove razlike mogu značajno uticati na modele trenirane na istorijskim podacima jer otežavaju da modeli pravilno generalizuju naučene obrasce. Razumevanje sezonskih i lokalnih specifičnosti je ključno za pravilno tumačenje obrazaca u ponašanju pčela i izbegavanje pogrešnih zaključaka pri modelovanju.

### **Postojeći skupovi podataka o težini košnice**

Za treniranje modela koji su predstavljeni u ovoj disertaciji potrebni su podaci o težini košnica, pa su u nastavku analizirani skupovi podataka koji sadrže podatke o težini.

U radu [137], korišćeni su podaci iz više od 500 košnica širom Italije, koje je prikupila kompanija 3Bee u saradnji sa pčelarima. Uz to su uključeni i meteorološki podaci iz Copernicus baze. Iako rad pokriva širok geografski opseg i vremenski period od nekoliko sezona, podaci nisu javno dostupni, već pripadaju privatnoj bazi komercijalnog sistema. Slično, rad [138] koristi podatke prikupljane putem 8 višesenzorskih sistema tokom 2.170 dana. Podaci uključuju temperaturu, vlažnost, zvuk, CO<sub>2</sub> i vibracije, ali nisu javno dostupni jer se odnose na interne eksperimente i implementacije. Jedan od retkih javno dostupnih skupova dolazi iz rada [139], u kojem su korišćeni podaci iz istraživačkog centra Carl Hayden Bee Research Center u Tusonu, Arizoni, SAD. Ovaj

skup sadrži merenja težine, unutrašnje temperature i vremenskih uslova prikupljenih iz 10 košnica. Prikupljanje je trajalo više meseci, a skup podataka je objavljen u skladu sa FAIR principima. Međutim, podaci su sakupljeni u periodu ekstremno visokih temperatura i promene težina su neznatne. Rad [134] koristi podatke iz projekta We4bee, u okviru kojeg su na tri košnice kontinuirano beleženi podaci o težini, temperaturi, vlažnosti i vremenskim uslovima tokom perioda od više meseci. Nažalost, ni ovi podaci nisu javno dostupni. *HOneyBee Online Studies* (HOBOS) skup podataka [129, 135] sadrži javno dostupne podatke prikupljene iz dve košnice na različitim lokacijama u Nemačkoj, u periodu od januara 2017. do aprila 2019. godiine. Za svaku košnicu dostupni su podaci o unutrašnjoj temperaturi, vlažnosti, težini i broju ulazaka/izlazaka pčela, pri čemu postoji period sa nedostajućim vrednostima, što zahteva dodatno preprocesiranje. Pored navedenih, postoje i drugi javno dostupni skupovi koji obuhvataju samo kratke vremenske periode (dane ili nedelje), zbog čega nisu od značajne koristi za većinu modela i primena.

## 6.4 Definicija problema i postojeći pristupi

Informacija o vremenu početka unosa nektara, koji ujedno označava početak medenja, ima veliku praktičnu vrednost za pčelare. Pravovremeno prepoznavanje ovih promena omogućava planiranje dodavanja nastavaka i ramova kako bi se izbeglo prenatrpavanje košnica, smanjio rizik od rojenja tokom perioda intenzivnog unosa i odredio optimalan trenutak za vrcanje meda.

Posebno je značajno precizno određivanje trenutka početka medenja biljaka za pčelare koji sele košnice, jer omogućava pravovremeno reagovanje i maksimalno iskorišćenje medonosnog potencijala terena. Kašnjenje u selidbi može dovesti do propuštanja najintenzivnije faze paše, dok preuranjena selidba nosi rizik gubitka prinosa koji bi bio ostvaren ostankom na prethodnoj lokaciji.

### Postojeći pristupi i njihova ograničenja

Za identifikaciju početka medenja koriste se različite vrste podataka. Najdirektniji pokazatelj predstavlja promena težine košnice [139]. Pristupi zasnovani na merenjima unutar košnice, kao što su temperatura i vlažnost [134] ili zvučni obrasci [140], mogu ukazivati na promene u aktivnostima pčelinjeg društva. Međutim, instalacija mernih uređaja zahteva dodatne troškove, fizičko prisustvo i logističku organizaciju, što značajno ograničava širu primenu ovakvih pristupa, naročito u uslovima selidbe košnica, gde pčelari često nemaju pristup internim podacima sa terena.

Zbog toga raste interesovanje za alternativna, komercijalno održiva rešenja zasnovana na eksternim, javno dostupnim izvorima podataka. Satelitski snimci su često u fokusu ovih pristupa jer omogućavaju prostorno širok obuhvat, ali njihova primena ima niz ograničenja: preciznost je narušena usled oblačnosti i magle, vremenska rezolucija nije dovoljna za detekciju kratkotrajnih fenoloških faza, a modeli zahtevaju terensku validaciju i obuku za različite biljne vrste, što smanjuje automatizaciju i povećava kompleksnost primene [141, 142, 143].

Meteorološki podaci predstavljaju posebno atraktivnu alternativu jer su besplatni, dostupni u realnom vremenu i pokrivaju većinu geografskih lokacija. Parametri poput temperature, padavina i vlažnosti direktno su povezani sa unosom nektara, što otvara mogućnost za razvoj modela koji bi, na osnovu vremenske prognoze, mogli da predviđaju verovatnoću početka medenja. U postojećim istraživanjima meteorološki podaci se gotovo uvek koriste u kombinaciji sa internim podacima iz košnice [134, 137, 138, 139].

Iako meteorološki podaci nude značajan potencijal, primena veštačke inteligencije u pčelarstvu ograničena je nedostatkom kvalitetnih skupova podataka, čije je prikupljanje sporo, skupo i tehnički zahtevno.

### Formulacija problema

Polazeći od navedenih ograničenja, postavlja se pitanje: da li je moguće razviti model koji, koristeći isključivo vremensku prognozu za naredne dane i ograničenu količinu podataka, može predvideti da li će na određenoj lokaciji doći do unosa nektara?

## 6.5 Metod LinLayCNN za predviđanje promena težine košnice


### 6.5.1 Opis metoda

Cilj metode je da, na osnovu vremenske prognoze, predvidi da li će u narednim danima doći do unosa nektara, tj. do porasta težine košnice.

Za razliku od prethodnih istraživanja, gde su korišćeni regresioni modeli za predikciju tačne vrednosti težine, ovde je primenjena binarna klasifikacija: za svaki dan se klasifikuje da li će težina rasti ili ne. Iako je metodološki jednostavniji, ovakav pristup pruža pčelarima izuzetno korisnu informaciju koja omogućava pravovremeno planiranje selidbe i bolje iskorišćavanje medonosnog potencijala terena.

### Arhitektura

Ulazna matrica je oblika  $m \times n$ , pri čemu  $m$  predstavlja broj meteoroloških karakteristika (npr. temperatura, vlažnost, padavine), a  $n$  broj dana za koje se vrši predikcija. Ova matrica se obrađuje pomoću 1D konvolucije duž vremenske dimenzije  $n$ , pri čemu kanali odgovaraju različitim meteorološkim karakteristikama. Izlazni sloj je sigmoidalni sloj dimenzije  $n$ , pri čemu svaki neuron daje procenu verovatnoće da će doći do porasta težine košnice upravo tog dana, u poređenju sa prethodnim (slika 6.2).



Slika 6.2: LinlayCNN metod za problem predviđanja promene težine košnice

## Ulazni podaci i način upotrebe

Za treniranje modela potrebni su meteorološki podaci i podaci o težini košnice, dok se u fazi primene koristi isključivo vremenska prognoza, čime se eliminiše potreba za dodatnom opremom na terenu. Dakle, težina košnice se ne koristi kao ulaz u model, već služi kao ciljna vrednost (engl. *target*) pri treniranju modela. Nakon treniranja, model se u realnim uslovima primenjuje tako što, za istu lokaciju, kao ulaz dobija vremensku prognozu za predstojeće dane i klasifikuje ih na one sa očekivanim porastom težine.

## Pretpostavke i uslovi primene

Za treniranje modela neophodno je prethodno prikupljanje podataka na konkretnoj lokaciji - barem godinu dana kontinuiranih merenja težine sa jedne ili više košnica. Nakon toga, model može da se koristi svake naredne sezone za istu lokaciju koristeći samo vremensku prognozu. Ova metoda počiva na pretpostavci da obrasci ponašanja pčelinjeg društva - u pogledu toga kada se dešava rast težine - ostaju relativno konzistentni iz godine u godinu na istoj mikrolokaciji, ukoliko su vremenski uslovi slični. Iako se apsolutna količina unetog nektara može razlikovati, pravac promene (rast, pad ili stagnacija) ima visok stepen ponovljivosti. Ova pretpostavka razmotrena je kroz analizu promena težine košnica na istoj mikrolokaciji, prikazanoj u dodatku A.2.

### 6.5.2 Analogija prostornog i vremenskog domena

Kao što LinLayCNN model u prostornim zadacima uči odnose i raspored objekata duž jedne dimenzije, ovde se isti princip prenosi na vremenski domen, gde se uče odnosi među događajima kroz vreme. Objekat dužine jedan dan predstavlja događaj rasta

težine, dok meteorološki podaci imaju ulogu obeležja, koja definišu kontekst u kojem se taj događaj može pojaviti. U ovom slučaju uvek se razmatra isti objekat fiksne dužine, pa nije potrebno dodavati dodatne kanale niti vršiti iterativno postavljanje kao u prostornim zadacima. Takođe, ne postoji unapred poznat broj objekata - umesto toga, model procenjuje koje su vremenske pozicije pogodne za pojavu događaja, što odgovara pronalaženju svih mogućih „ispravnih“ pozicija u prostoru.

Ova analogija omogućava da se znanja stečena analizom prostornog rezonovanja prenesu na vremenske sekvence. Na primer, saznanje da metod pri manjoj količini podataka funkcioniše sa nižom rezolucijom u ovom kontekstu znači približno predviđanje dana unosa, što može predstavljati korisnu informaciju u ranim fazama primene, kada sistem mora da funkcioniše u realnim uslovima pre nego što se prikupi dovoljan broj podataka za detaljno testiranje i kalibraciju.

### 6.5.3 Postavka eksperimenta


#### 6.5.3.1 Skup podataka

Za potrebe istraživanja korišćen je HOBOS skup podataka, koji je dostupan na platformi *Kaggle*<sup>1</sup>. HOBOS sadrži unutrašnja merenja iz dve košnice u Nemačkoj, sa lokacija Virzburg (nem. *Würzburg*) i Bad Švartau (nem. *Bad Schwanau*, u daljem tekstu: Schwartau), prikupljana u periodu od januara 2017. do aprila 2019. Obuhvata podatke o temperaturi, vlažnosti, težini i broju ulazaka/izlazaka pčela, ali bez podataka o spoljnim uslovima. Prisutni su diskontinuiteti i nedostajući podaci u određenim vremenskim intervalima, što zahteva dodatne korake pretprocesiranja. Kako bi se omogućila predikcija na osnovu meteoroloških uslova, ovim podacima su pridruženi javno dostupni meteorološki podaci (temperatura, vlažnost vazduha, padavine, vetar, oblačnost) za odgovarajuće lokacije, preuzeti sa servisa *opendata.dwd.de*. Opis skupa podataka dat je u Tabeli 6.1. Vremenske serije težina košnica date su na slici 6.3.


Tabela 6.1: Karakteristike HOBOS skupa podataka

| Karakteristika    | Opis                                                                                                  |
|-------------------|-------------------------------------------------------------------------------------------------------|
| Naziv skupa       | HOBOS                                                                                                 |
| Izvor             | Kaggle platforma                                                                                      |
| Lokacije merenja  | Košnice u Nemačkim gradovima Würzburg i Bad Schwanau                                                  |
| Broj košnica      | po jedna košnica na obe lokacije                                                                      |
| Period pokrivanja | Januar 2017 – April 2019                                                                              |
| Tipovi podataka   | Temperatura i vlažnost unutar košnice, težina košnice (merenja sa vage), broj ulazaka/izlazaka pčela. |
| Nedostaci         | Diskontinuiteti i praznine u određenim vremenskim intervalima                                         |

<sup>1</sup><https://www.kaggle.com/datasets/se18m502/bee-hive-metrics>



(a) Schwartau




(b) Wurzburg


Slika 6.3: Grafikon sirovih podataka o težini košnica

### Selekcija sezonski relevantnih podataka

Kako bi se poboljšala efikasnost učenja modela i izbeglo unošenje šuma, iz kompletnih vremenskih serija o težini košnica izdvojeni su isključivo dani koji pripadaju aktivnoj sezoni pčelarenja, definisanoj kao vremenski interval od 1. aprila do 31. oktobra. Ostatak podataka, koji obuhvata zimski i neaktivni period, izostavljen je iz dalje analize kako bi se model fokusirao na relevantne obrasce promena u težini košnica. Tokom zimskog perioda (otprilike od oktobra do aprila), pčele ulaze u fazu mirovanja u kojoj ne sakupljaju nektar, već preživljavaju koristeći zalihe meda koje su sakupile tokom godine. U tom periodu težina košnice uglavnom stagnira ili postepeno opada usled potrošnje resursa, dok vremenski uslovi nemaju jasan ili konzistentan uticaj na težinu. Zbog toga ti podaci ne sadrže koristan signal za učenje modela, već uglavnom unose šum, otežavajući modelu da prepozna obrasce koji su relevantni za predikciju promena težine tokom aktivne sezone. Na slici 6.4 prikazani su podaci iz vremenskih serija koji su korišćeni u eksperimentima.



(a) Podaci sa košnice na lokaciji Schwartau



(b) Podaci sa košnice na lokaciji Würzburg

Slika 6.4: Podaci sa košnica korišćeni u eksperimentima

### Podela skupova podataka po sezoni i lokaciji

Zbog sezonskih i lokalnih karakteristika, podaci su dodatno podeljeni na manje, logički povezane celine radi preciznije analize i evaluacije modela u različitim uslovima. Konkretno, podaci sa lokacije Schwartau su podeljeni na skup Schwartou2017 sa podacima iz sezone 2017 i skup Schwartou2018/2019 sa podacima iz sezone 2018 i 2019. Sa lokacije Würzburg koriste se samo podaci iz 2017 - formiran je skup Würzburg2017. Podaci sa Würzburg košnice su iskoristivi samo tokom sezone 2017, jer u narednim godinama nedostaju upravo u periodima intenzivne pčelinje aktivnosti (proleće – leto). Ova podela omogućava detaljno ispitivanje generalizacije modela kroz godine i lokacije, kao i sistematičnu upotrebu ovih podskupova u eksperimentalnoj analizi.

#### 6.5.3.2 Pretprocesiranje i priprema podataka

Zbog ograničenog broja dostupnih primera i specifičnosti podataka prikupljenih u realnim uslovima, faze pretprocesiranja i selekcije podataka predstavljaju ključne korake za uspešno treniranje modela.

## Imputacija nedostajućih vrednosti

Podaci o težini košnica često sadrže nedostajuće vrednosti, koje su mogle nastati usled vremenskih nepogoda, prekida napajanja, problema sa komunikacijom uređaja ili senzorima. Da bi se obezbedila konzistentnost vremenskih serija, izvršena je imputacija nedostajućih vrednosti korišćenjem algoritma višestruke imputacije zasnovane na povezanim jednačinama uz upotrebu metoda slučajnih šuma (engl. *Multiple Imputation by Chained Equations with Random Forests* (MICE Ranger)) kao u radu [134]. Ovaj algoritam omogućava višestruko dopunjavanje vrednosti na osnovu informacija iz drugih dana.

## Selekcija ulaznih karakteristika

Za ulazne meteorološke karakteristike odabrani su minimalna i maksimalna dnevna temperatura, srednja dnevna vrednost relativne vlažnosti i količina padavina. Testiranjem različitih kombinacija pokazalo se da korišćenje samo navedena četiri parametra daje najbolje performanse metoda. Dodavanje dodatnih meteoroloških parametara nije dovelo do poboljšanja, a u pojedinim slučajevima čak je smanjilo tačnost modela. S druge strane, izostavljanje bilo kog od odabranih parametara rezultovalo je prosečnim padom tačnosti od oko 5%.

## Formiranje trening primera

Iz sirovih vremenskih serija o težini košnica izračunate su razlike u srednjim vrednostima težine između dva uzastopna dana, na osnovu kojih je definisana binarna oznaka: porast (klasa 1) ili izostanak porasta (klasa 0).

Metod je treniran da vrši predikciju promena težine u narednih sedam dana. Na osnovu uvida u pouzdanost vremenske prognoze i dostupnost podataka sa javnih meteoroloških servisa, procenjeno je da sedam dana predstavlja realističan maksimalni interval u kojem model može da donese pouzdane klasifikacione odluke.

Za treniranje metoda kreiran je skup primera primenom kliznog prozora dužine sedam dana nad vremenskom serijom ulaznih karakteristika. Svaki primer odgovara jednom intervalu od sedam uzastopnih dana i obuhvata:

- Ulazne karakteristike - meteorološki podaci za period od sedam uzastopnih dana, pri čemu se za svaki dan koristi vektor koji sadrži maksimalnu i minimalnu temperaturu, relativnu vlažnost i količinu padavina.
- Ciljne vrednosti - binarni vektor dužine sedam, gde svaka komponenta označava da li je tog dana zabeležen porast težine košnice u odnosu na prethodni dan.

Klizni prozor je pomeran za jedan dan, čime je iz jedne vremenske serije generisan veći broj preklapajućih primera. Na taj način je obezbeđen dovoljan broj uzoraka za treniranje modela uprkos ograničenoj veličini originalnog skupa podataka.

## Čišćenje skupa podataka

Zbog ograničene veličine skupa podataka i potrebe da se obezbedi visoka informativnost trening primera, izvršeno je dodatno filtriranje, koje obuhvata sledeće korake:

- Uklanjanje autlejera: eliminisani su svi primeri u kojima je u bilo kom danu zabeležena težina veća od 6 kg. Ove vrednosti se javljaju retko, a najčešće su rezultat grešaka u merenju, loše kalibracije vaga ili drugih tehničkih problema.
- Uklanjanje statičnih primera: uklonjeni su svi primeri kod kojih ni u jednom danu nije zabeležena promena težine veća od 0.5 kg. Ova odluka je motivisana ciljem da model uči obrasce koji vode ka značajnom unosu nektara, a ne da pasivno predviđa statična stanja. U kontekstu ograničenog broja primera za obuku, prisustvo velikog broja statičnih uzoraka može dovesti do toga da model nauči da predviđa ne-promenu kao dominantan ishod. Time se smanjuje njegova sposobnost da prepozna obrasce koji prethode stvarnom unosu nektara.


U Tabeli 6.2 prikazan je broj primera u definisanim skupovima nakon pretprocesiranja.

| Skup podataka       | Ukupno primera | Procenat pozitivnih primera(%) |
|---------------------|----------------|--------------------------------|
| Schwartou           | 190            | 67                             |
| Schwartou 2017      | 80             | 57                             |
| Schwartou 2018/2019 | 110            | 74                             |
| Wurzburg 2017       | 122            | 58                             |

Tabela 6.2: Skupovi podataka i bitne statistike nakon procesiranja

### 6.5.3.3 Arhitektura modela i podešavanje hiperparametara

Zbog ograničene veličine skupa podataka, hiperparametri su podešeni kros-validacijom na podacima sa obe lokacije. U oba slučaja, arhitektura označena na slici 6.5 pokazala se kao optimalna, što potvrđuje njenu robusnost. Model je treniran tokom 300 epoha, sa veličinom beča 32, korišćenjem Adam optimizacionog algoritma sa parametrom učenja `learning_rate=0.001`.



Slika 6.5: Korišćena arhitekrua CNN mreže

#### 6.5.4 Rezultati

Da bismo procenili efikasnost razvijenog LinLayCNN metoda, sproveli smo poređenje sa metodama koje se najčešće koriste u problemima binarne klasifikacije: Logistic Regression, SVM, Random Forest i MLP. Svi modeli su trenirani nad istim skupom karakteristika kao i LinLayCNN, s tim da su prostorni (sekvencijalni) podaci prethodno linearizovani. Za svaki dan u predikcionom horizontu treniran je poseban model binarne klasifikacije.

Modeli su trenirani i testirani na svim kombinacijama trening/test parova među skupovima Schwartau2017, Schwartau2018/2019 i Wurzburg2017, uključujući i objedinjene skupove označene znakom '+'. Rezultati se prikazuju u tabelama u vidu F1 mere, tačnosti (engl. *accuracy*) i površine ispod krive (engl. *Area Under the Curve* (AUC)) - koja meri sposobnost modela da razlikuje pozitivne i negativne primere (što bliže 1, to bolje).

U Tabeli 6.3 prikazujemo performanse modela testirane na podacima sa košnice na lokaciji Schwartou.

Tabela 6.3: Performanse modela prilikom testiranja na podacima sa lokacije Schwartou. Podebljane su najveće vrednosti u koloni.

(a) Trening skup: Schwartou2017 , Test skup: Schwartou2018/19

| Model                      | F1          | Accuracy    | AUC         |
|----------------------------|-------------|-------------|-------------|
| <b>Logistic Regression</b> | 0.80        | 0.70        | 0.68        |
| <b>Random Forest</b>       | 0.78        | 0.68        | 0.59        |
| <b>SVM</b>                 | <b>0.82</b> | <b>0.72</b> | 0.65        |
| <b>MLP</b>                 | 0.78        | 0.67        | 0.59        |
| <b>LinLayCNN</b>           | 0.81        | 0.71        | <b>0.69</b> |

(b) Trening skup: Wurzburg2017, Test skup: Schwartou2018/19

| Model                      | F1          | Accuracy    | AUC         |
|----------------------------|-------------|-------------|-------------|
| <b>Logistic Regression</b> | 0.70        | 0.61        | 0.64        |
| <b>Random Forest</b>       | 0.78        | 0.69        | 0.70        |
| <b>SVM</b>                 | <b>0.81</b> | <b>0.73</b> | <b>0.74</b> |
| <b>MLP</b>                 | 0.71        | 0.62        | 0.63        |
| <b>LinLayCNN</b>           | 0.80        | 0.71        | 0.67        |

(c) Trening skup: Schwartou2017 + Wurzburg2017, Test skup: Schwartou2018/19

| Model                      | F1          | Accuracy    | AUC         |
|----------------------------|-------------|-------------|-------------|
| <b>Logistic Regression</b> | 0.77        | 0.68        | 0.69        |
| <b>Random Forest</b>       | 0.78        | 0.69        | 0.70        |
| <b>SVM</b>                 | <b>0.84</b> | <b>0.76</b> | <b>0.75</b> |
| <b>MLP</b>                 | 0.75        | 0.65        | 0.60        |
| <b>LinLayCNN</b>           | 0.8         | 0.70        | 0.68        |

(d) Trening skup: Schwartou2018/19 , Test skup: Schwartou2017

| Model                      | F1          | Accuracy    | AUC         |
|----------------------------|-------------|-------------|-------------|
| <b>Logistic Regression</b> | 0.71        | 0.63        | 0.64        |
| <b>Random Forest</b>       | <b>0.73</b> | 0.62        | 0.65        |
| <b>SVM</b>                 | 0.72        | 0.59        | 0.63        |
| <b>MLP</b>                 | 0.70        | 0.59        | 0.58        |
| <b>LinLayCNN</b>           | 0.72        | <b>0.64</b> | <b>0.66</b> |

(e) Trening skup: Wurzburg2017, Test skup: Schwartou2017

| Model                      | F1          | Accuracy    | AUC         |
|----------------------------|-------------|-------------|-------------|
| <b>Logistic Regression</b> | 0.61        | 0.57        | 0.60        |
| <b>Random Forest</b>       | <b>0.72</b> | <b>0.65</b> | <b>0.67</b> |
| <b>SVM</b>                 | 0.69        | 0.62        | 0.62        |
| <b>MLP</b>                 | 0.63        | 0.61        | 0.65        |
| <b>LinLayCNN</b>           | 0.67        | 0.59        | 0.60        |

(f) Trening skup: Schwartou2018/19 + Wurzburg2017, Test skup: Schwartou2017

| Model                      | F1          | Accuracy    | AUC         |
|----------------------------|-------------|-------------|-------------|
| <b>Logistic Regression</b> | 0.71        | 0.62        | 0.65        |
| <b>Random Forest</b>       | <b>0.74</b> | <b>0.64</b> | <b>0.69</b> |
| <b>SVM</b>                 | <b>0.74</b> | 0.63        | <b>0.69</b> |
| <b>MLP</b>                 | 0.69        | <b>0.64</b> | 0.67        |
| <b>LinLayCNN</b>           | 0.71        | 0.63        | 0.66        |

Za treniranje modela je potrebno obezbediti celokupan sezonski ciklus, pa nije moguće testirati uspešnost modela treniranih na Wurzburg2017 na istoj košnici. U tabeli 6.4 su prikazani rezultati testiranja modela na Wourzburg2017, treniranih na podacima sa lokacije Schwartou.

Tabela 6.4: Performanse modela prilikom testiranja na podacima sa lokacije Wurzburg. Poređane su najveće vrednosti u koloni.

(a) Trening: skup: Schwartou2017

| Model                      | F1          | Accuracy    | AUC         |
|----------------------------|-------------|-------------|-------------|
| <b>Logistic Regression</b> | <b>0.68</b> | <b>0.58</b> | 0.57        |
| <b>Random Forest</b>       | 0.63        | 0.56        | <b>0.58</b> |
| <b>SVM</b>                 | 0.66        | <b>0.58</b> | <b>0.58</b> |
| <b>MLP</b>                 | <b>0.68</b> | <b>0.58</b> | 0.56        |
| <b>LinLayCNN</b>           | 0.65        | 0.57        | 0.56        |

(b) Trening skup: Schwartou2018/2019

| Model                      | F1          | Accuracy    | AUC         |
|----------------------------|-------------|-------------|-------------|
| <b>Logistic Regression</b> | 0.68        | 0.60        | 0.59        |
| <b>Random Forest</b>       | 0.71        | 0.61        | 0.61        |
| <b>SVM</b>                 | <b>0.73</b> | 0.61        | 0.62        |
| <b>MLP</b>                 | 0.71        | 0.62        | 0.61        |
| <b>LinLayCNN</b>           | 0.70        | <b>0.63</b> | <b>0.65</b> |

(c) Trening skup: Schwartou2017/2018/2019

| Model                      | F1          | Accuracy    | AUC         |
|----------------------------|-------------|-------------|-------------|
| <b>Logistic Regression</b> | 0.68        | 0.61        | 0.60        |
| <b>Random Forest</b>       | 0.68        | 0.58        | 0.61        |
| <b>SVM</b>                 | 0.69        | 0.59        | 0.61        |
| <b>MLP</b>                 | <b>0.70</b> | <b>0.63</b> | <b>0.62</b> |
| <b>LinLayCNN</b>           | 0.68        | 0.58        | 0.58        |

Radi jasnijeg uvida u ponašanje modela, u Tabeli 6.5 su prikazane vrednosti F1 mere najboljeg modela za svaku kombinaciju trening i test skupa.

Tabela 6.5: F1 mera najboljeg modela za različite kombinacije trening i test skupova. Skraćenice: Wur = Wurzburg, Sch=Schwartou, 17/18/19=godina.

| Trening/Test       | Wur17        | Sch17        | Sch18/19  | Sch17/18/19 |
|--------------------|--------------|--------------|-----------|-------------|
| <b>Wur</b>         | -            | 0.72(RF)     | 0.81(SVM) | 0.77(SVM)   |
| <b>Sch17</b>       | 0.68(LR,MLP) | -            | 0.82(SVM) | -           |
| <b>Sch18/19</b>    | 0.73(SVM)    | 0.73(RF)     | -         | -           |
| <b>Sch17/18/19</b> | 0.70(MLP)    | -            | -         | -           |
| <b>Wur+S17</b>     | -            | -            | 0.84(SVM) | -           |
| <b>Wur+S18/19</b>  | -            | 0.74(SVM,RF) | -         | -           |

Može se primetiti da performanse modela variraju sa različitim trening i test skupovima, pa u Tabeli 6.6 dajemo prosečne vrednosti metrika po svim test skupovima, za svaki model.

Tabela 6.6: Prosečne performanse modela po svim test skupovima, sa standardnim devijacijama, u opadajućem redosledu prema F1 meri.

| Model                      | F1              | Accuracy        | AUC             |
|----------------------------|-----------------|-----------------|-----------------|
| <b>SVM</b>                 | $0.74 \pm 0.06$ | $0.65 \pm 0.07$ | $0.65 \pm 0.06$ |
| <b>Random Forest</b>       | $0.73 \pm 0.05$ | $0.64 \pm 0.04$ | $0.64 \pm 0.05$ |
| <b>LinLayCNN</b>           | $0.73 \pm 0.06$ | $0.64 \pm 0.05$ | $0.64 \pm 0.04$ |
| <b>MLP</b>                 | $0.71 \pm 0.04$ | $0.62 \pm 0.03$ | $0.61 \pm 0.03$ |
| <b>Logistic Regression</b> | $0.70 \pm 0.05$ | $0.62 \pm 0.04$ | $0.63 \pm 0.04$ |

S obzirom na ograničenu tačnost vremenskih prognoza, naročito za dane koji su dalje u budućnosti, sproveden je eksperiment u kojem je na vrednosti minimalne i maksimalne temperature u test skupu dodat Gausov šum sa sredinom 0 i standardnim devijacijama po danima: 1, 2, 2, 3, 3, 4, 4. Rezultati pokazuju da su performanse svih modela umanjene za približno 2%. U Tabeli 6.7 date su performanse modela treniranog na Schwartou2017 i testiranog na Schwartou2018/2019, kao reprezentativan primer.

| Model                      | F1          | AUC         |
|----------------------------|-------------|-------------|
| <b>Logistic Regression</b> | 0.78        | 0.64        |
| <b>Random Forest</b>       | 0.75        | 0.54        |
| <b>SVM</b>                 | <b>0.80</b> | 0.61        |
| <b>MLP</b>                 | 0.77        | 0.59        |
| <b>LinLayCNN</b>           | 0.79        | <b>0.66</b> |

Tabela 6.7: Performanse modela sa dodatim šumom

Kao orijentaciono poređenje analiziran je rad [134], u kojem je korišćen vektorski autoregresivni model (VAR model) za predikciju težine u narednim danima na osnovu vremenskih uslova i internih parametara košnice. U dostupnoj literaturi nema radova koji se bave klasifikacijom rasta težine, pa je ovaj rad uzet kao najbliža referenca. Radi poređenja, regresione predikcije VAR modela transformisane su u binarnu formu (rast / ne-rast u odnosu na prethodni dan), nakon čega je izračunata F1 mera. Korišćenjem unakrsne validacije dobijene su vrednosti od 0.49% za lokaciju Schwartau i 0.63% za lokaciju Wurzburg.

### 6.5.5 Diskusija

Eksperimentalni rezultati pružaju uvid u performanse modela, ali istovremeno otkrivaju i sezonske i lokalne specifičnosti samih skupova podataka. Na primer, skup Schwartou2018/2019 pokazuje visok stepen opštosti, jer omogućava uspešnu generalizaciju i na druge lokacije i sezone. Testiranje na tom skupu daje najviše performanse

kod svih modela, pri čemu su rezultati gotovo identični bez obzira na to koji skup je korišćen za treniranje. Takođe, kad se ovaj skup koristi za treniranje, postižu se gotovo iste performanse pri testiranju na bilo kom drugom skupu.

Suprotno tome, rezultati vezani za Schwartou2017 ukazuju na prisustvo lokalno i sezonski specifičnih obrazaca, koji otežavaju prenos znanja na druge skupove. Naime, pri testiranju na ovom skupu, modeli postižu značajno niže rezultate nego pri testiranju na skupu Schwartou2018/2019, bez obzira na kom skupu su trenirane. Najniže performanse beleže se kada je model treniran na ovom skupu, a testiran na drugoj lokaciji, na skupu Wurzburg2017, iako podaci potiču iz iste godine. Čime se dodatno potvrđuje specifičnost obrasca prisutnog u sezoni 2017 na Schwartou lokaciji. Ovakva karakterizacija skupova – gde Schwartou2017 pokazuje lokalno-sezonske specifičnosti, a Schwartou2018/2019 opšte obrasce – doprinosi preciznijoj evaluaciji modela i jasnijem definisanju scenarija njihove optimalne primene.

Kada se za treniranje ili testiranje koristi skup Schwartou2018/2019, koji nosi pretežno opšte obrasce, najbolje performanse u odnosu na ostale modele ima SVM model. Pokazuje najbolje F1, Accuracy i AUC kada je treniran na skupu Wurzburg2017 i ubedljivo najbolje kada koristi kombinovani trening skup (Schwartou2017 + Wurzburg2017). Performanse modela rastu kada se dodaju podaci sa druge lokacije - za razliku od ostalih modela, kod kojih dolazi do pada performansi. Ovo ukazuje na izraženu sposobnost generalizacije, robusnost na varijacije u podacima i otpornost na šum.

Kada se za testiranje koristi skup Schwartou2017, koji je označen sezonski i lokalno specifičnim obrascima, Random Forest u odnosu na ostale modele daje najbolje rezultate. Ubedljivo najbolji rezultati postignuti su kada se za treniranje koriste podaci iz iste sezone ali sa druge lokacije, što ukazuje na to da je Random Forest model najposobniji za uočenje sezonskih obrazaca. Takođe, kada se u trening skup uključe i podaci sa iste lokacije ali iz druge sezone, performanse su gotovo izjednačene sa SVM-om, što ukazuje i na dobru sposobnost učenja lokalnih karakteristika kod Random Forest modela. Međutim, situacije u kojima Random Forest nadmašuje SVM (kada se trenira na jednoj lokaciji, a koristi na drugoj u istoj sezoni) retko se javljaju u praksi. S obzirom na to da SVM u svim drugim scenarijima ostvaruje bolje i stabilnije rezultate, predstavlja praktičniji izbor za realne uslove primene.

MLP u svim eksperimentima ostvaruje gotovo iste rezultate. Kada se trenira na Schwartou2017, koji sadrži lokalno specifične obrasce, a testira na Wurzburg2017, performanse MLP-a su najbolje u odnosu na ostale modele, koji u tom slučaju beleže značajan pad. Ovo ukazuje na to da se MLP pokazao kao najrobustniji u odnosu na lokalno specifične obrasce. Međutim, imajući u vidu da u svim ostalim scenarijima MLP beleži značajno slabije rezultate u odnosu na ostale modele, možemo zaključiti da MLP previše generalizuje i nije sposoban da nauči kompleksne ili specifične primere. Ukoliko je dostupna sezona sa izraženim lokalnim specifičnostima, a model se trenira na jednoj lokaciji i primenjuje na drugoj, MLP može biti dobar izbor.

Logistička regresija pokazuje obrasce ponašanja slične MLP-u, ali uz konzistentno niže performanse u svim scenarijima. Zbog toga neće biti detaljnije analizirana, niti se preporučuje za primenu u ovom kontekstu.

LinLayCNN model pokazuje obrasce ponašanja slične SVM modelu. Iako su njegove performanse u svim eksperimentima nešto slabije u odnosu na SVM, razlika je minimalna, što se vidi i u Tabeli 6.7. Rezultati iz poglavlja 3 ukazuju da se performanse LinLayCNN metode poboljšavaju sa većim skupom za treniranje, što je čini strateški pogodnijom od SVM-a u skalabilnim scenarijima i aplikacijama sa kontinualnim prikupljanjem podataka (npr. dugoročno IoT praćenje pčelinjih aktivnosti). U kontekstima sa ograničenom količinom podataka, ipak se prednost daje SVM modelu, zbog njegove stabilne generalizacije čak i uz manji broj primera.

## 6.6 Zaključak

U ovom poglavlju bavimo se problemom koji do sada nije bio adresiran u dostupnoj literaturi - predikcijom promena težine košnica isključivo na osnovu vremenske prognoze. Predloženi metod pruža osnovu za buduća istraživanja u ovom pravcu. Za razliku od pristupa u prethodnim radovima koji koriste regresione modele za predikciju konkretnih vrednosti težine, ovde je primenjena binarna klasifikacija, koja za svaki dan predviđa da li će doći do rasta težine. Takav pristup, iako jednostavniji, pčelarima pruža direktnu i korisnu informaciju za operativno planiranje - kao što je pravovremeno premeštanje košnica na lokacije sa većom verovatnoćom unosa.

U okviru eksperimentalne evaluacije, upoređeni su klasični modeli - SVM, Logistička regresija, Random Forest i MLP - sa metodom LinLayCNN, razvijenom u okviru ove disertacije. Ova metoda, prvobitno korišćena za generisanje rasporeda objekata u linearnom prostoru, u ovom poglavlju se primenjuje u vremenskom domenu. Na taj način demonstrirana je njena širina primene i efikasnost u rešavanju zadataka u oblasti preciznog pčelarstva.

U istraživanju je korišćen jedini javno dostupni skup podataka, koji obuhvata dve košnice sa različitih lokacija. Podaci su podeljeni na podskupove prema lokaciji i sezoni, čime su obuhvaćeni različiti uslovi pčelarenja. Iako je broj primera ograničen, ovakva podela omogućila je izvođenje različitih eksperimentalnih scenarija.

Rezultati eksperimenta pokazuju da LinLayCNN ostvaruje konkurentne performanse u poređenju sa tradicionalnim modelima, i to na vrlo malim skupovima odataka. Iako nije dosledno nadmašio sve klasične metode u svakom eksperimentu, njegova sposobnost da koristi dodatne podatke za postepeno poboljšanje performansi čini ga posebno pogodnim za primene u okruženjima gde se količina dostupnih podataka vremenom povećava, ili u situacijama kada su dostupne veće količine podataka.

Na osnovu dobijenih rezultata možemo izvesti nekoliko praktičnih preporuka za izbor modela u zavisnosti od raspoloživih podataka i scenarija primene. Kada se modeli treniraju na podacima sa jedne lokacije, a primenjuju na drugoj, poželjno je koristiti podatke koji ne sadrže lokalno specifične obrasce, jer takvi podaci omogućavaju bolju generalizaciju. U tim slučajevima, SVM se pokazuje kao najpouzdaniji model. U slučajevima sa izraženim sezonskim specifičnostima za lokaciju na kojoj se trenira, MLP pokazuje veću robusnost za korišćenje na drugim lokacijama.

S druge strane, kada je fokus na jednoj lokaciji, uključivanje većeg broja košnica može pomoći modelu da nauči opšte obrasce karakteristične za tu mikrolokaciju. Pre-

poručuje se SVM. Na osnovu istraživanja na prostornim zadacima, pokazano je da se performanse LinLayCNN modela značajno poboljšavaju sa većom količinom podataka za treniranje. Shodno tome, pri većim količinama podataka, LinLayCNN može biti bolji izbor, dok SVM ostaje pouzdan u scenarijima sa ograničenim resursima.

Kako bi se opravdala upotreba metoda koji generalizuje obrase na nivou lokacije, u dodatku A.2 analizirani su težinski podaci sa 10 košnica sa iste mikrolokacije. Uočen je zajednički sezonski trend, što omogućava treniranje modela na jednoj i primenu na drugim košnicama sa iste lokacije. Potvrda ovih nalaza na podacima iz više sezona bi dodatno ojačala zaključke, ali takvi podaci nisu javno dostupni.

Zbog ograničenosti dostupnih skupova podataka i složenosti problema, razvoj uspešnih metoda u ovom domenu zahteva pažljivu analizu i kvalitetno preprocesiranje podataka kao i uključivanje domenskog znanja radi pravilne interpretacije obrazaca. Rezultati eksperimenata pokazuju da sezone i lokalne razlike značajno utiču na performanse, što čini razumevanje ovih specifičnosti ključnim za pravilan izbor i obuku modela. Takođe, jako je bitno da izbor modela i priprema podataka budu prilagođeni konkretnom cilju primene. U ovom poglavlju evaluacija modela vršena je na osnovu performansi tokom cele sezone. Međutim, u praksi ciljevi primene mogu biti drugačiji - na primer, umesto opšte tačnosti tokom dužeg perioda, može biti ključna tačnost u određenom trenutku, poput detekcije početka medenja određene biljne vrste. U takvim slučajevima, drugačiji modeli i pristupi mogu pokazati bolje rezultate.

Buduća istraživanja trebalo bi da budu usmerena na sistematsko prikupljanje i pouzdano anotiranje podataka, kao i na evaluaciju modela u realnim uslovima korišćenja, uzimajući u obzir različite ciljeve primene i specifičnosti lokacije.



# Glava 7

## Zaključak

U ovoj disertaciji po prvi put je problem linearnog raspoređivanja korelisanih elemenata formalno definisan kao zasebna kategorija problema. Time je omogućeno njegovo rešavanje generičkim metodama koje se mogu primeniti u različitim domenima, umesto da se za svaki konkretan zadatak razvija poseban algoritam. Ovakav pristup značajno doprinosi efikasnosti, ponovnoj upotrebljivosti rešenja i bržoj primeni veštačke inteligencije u praksi.

Kao odgovor na definisani problem, predložen je metod LinLayCNN, zasnovan na konvolucionim neuronskim mrežama, koji koristi inovativan način kodiranja ulaznih informacija putem višekanalnih binarnih nizova. Time je omogućeno da se prostorne relacije u jednodimenzionalnom prostoru uče preciznije, čak i u uslovima ograničenih količina podataka.

Doprinos disertacije ogleda se i u razvoju posebnog skupa podataka - LinSpaRes - namenjenog evaluaciji sposobnosti modela na elementarnim zadacima prostornog rezonovanja. Ovaj skup omogućio je identifikaciju osnovnih slabosti i prednosti konvolucionih mreža u razumevanju prostornih odnosa, čime je delimično razbijena „crna kutija” u njihovom ponašanju. Na ovom skupu izvršeno je poređenje predloženog načina predstavljanja ulaznih karakteristika sa do sada korišćenim pristupima, pri čemu su pokazani superiorni rezultati - posebno u uslovima ograničenog broja primera za treniranje.

Metod je dodatno testiran u dva različita domena - arhitekturi i pčelarstvu - čime je potvrđena njegova fleksibilnost i široka primenljivost. U oblasti arhitekture, razmatran je zadatak generisanja linearnih kuhinjskih rasporeda. Kako za ovaj problem ne postoje javno dostupni skupovi podataka, u okviru istraživanja je u saradnji sa stručnjacima iz oblasti dizajna i arhitekture kreiran novi skup podataka, koji obuhvata realne primere linearnih kuhinja. Na ovom skupu, LinLayCNN je ostvario najbolje performanse u poređenju sa referentnim pristupima.

Pored toga, sprovedena je perceptualna studija primenljivosti, u kojoj su ispitani iz različitih oblasti ocenjivali alat za automatsko generisanje linearnih kuhinja baziran na predloženom metodu. Rezultati studije pokazali su da je alat ocenjen kao veoma koristan u praksi, dok su rasporedi generisani LinLayCNN metodom ocenjeni kao funkcionalni, bez ili uz minimalne korekcije.

U domenu pčelarstva, testiran je zadatak predikcije da li će doći do rasta težine

košnice u narednim danima. Problem je definisan tako da bude primenljiv u praksi, ali i dovoljno pojednostavljen da omogući učenje iz ograničenih i šumovitih skupova podataka. Uprkos izazovima vezanim za nehomogenost i količinu podataka, LinLayCNN je i u ovom domenu pokazao konkurentne rezultate, uporedive sa najefikasnijim standardnim metodama (npr. SVM), čime je dodatno potvrđena njegova robustnost u različitim uslovima.

Disertacija time daje doprinos u nekoliko pravaca: formalizaciji jednog važnog praktičnog problema, razvoju generičkog metoda zasnovanog na dubokom učenju, kreiranju evaluacionih skupova podataka i demonstraciji primenljivosti u različitim realnim okruženjima, uključujući i formulaciju i rešavanje novog, za praktične primene važnog problema u pčelarstvu.

# Bibliografija

- [1] T. Weiss i dr. “Fast and Scalable Position-Based Layout Synthesis”. U: *IEEE Transactions on Visualization and Computer Graphics* (2018.), str. 99–112. DOI: <https://doi.org/10.1109/TVCG.2018.2866436>.
- [2] H. Lee i dr. “Neural Design Network: Graphic Layout Generation with Constraints”. U: *Computer Vision–ECCV 2020:16th European Conference, Glasgow* (2020.), str. 491–506. DOI: <https://doi.org/10.48550/arXiv.1912.09421>.
- [3] Y. Zhang i W. Ye. “Deep learning-based inverse method for layout design”. U: *Structural and Multidisciplinary Optimization* (2019.), str. 527–536. DOI: <https://doi.org/10.48550/arXiv.1806.03182>.
- [4] Pete Seiler, Aniruddha Pant i Karl Hedrick. “Analysis of bird formations”. U: *Proceedings of the 41st IEEE Conference on Decision and Control, 2002*. Sv. 1. IEEE. 2002., str. 118–123.
- [5] Iztok Lebar Bajec i Frank H Heppner. “Organized flight in birds”. U: *Animal Behaviour* 78.4 (2009.), str. 777–789.
- [6] Intesaaf Ashraf i dr. “Simple phalanx pattern leads to energy saving in cohesive fish schooling”. U: *Proceedings of the National Academy of Sciences* 114.36 (2017.), str. 9599–9604.
- [7] Qiancheng Zhang i dr. “Bioinspired engineering of honeycomb structure—Using nature to inspire human innovation”. U: *Progress in Materials Science* 74 (2015.), str. 332–400.
- [8] Philip Ball. *Patterns in nature: why the natural world looks the way it does*. University of Chicago Press, 2016.
- [9] Horacio Serna i Daniel Barragán. “Patterns in nature: more than an inspiring design”. U: *Revista de la Academia Colombiana de Ciencias Exactas, Físicas y Naturales* 41.160 (2017.), str. 349–360.
- [10] Yang Li i dr. “Auto completion of user interface layout design using transformer-based tree decoders”. U: *arXiv preprint arXiv:2001.05308* (2020.).
- [11] Stephan Held, Stefan Hougardy i Jens Vygen. *Chip Design*. 2015.
- [12] Mehdi Nourinejad, Sina Bahrami i Matthew J Roorda. “Designing parking facilities for autonomous vehicles”. U: *Transportation Research Part B: Methodological* 109 (2018.), str. 110–127.

- [13] Andrew Pech i dr. “Game level layout generation using evolved cellular automata”. U: *Connection Science* 28.1 (2016.), str. 63–82.
- [14] Michael Barry i dr. “Optimal seat allocation under social distancing constraints”. U: *arXiv preprint arXiv:2105.05017* (2021.).
- [15] Danny Blom, Rudi Pendavingh i Frits CR Spijksma. “Filling a theatre in times of corona”. U: *arXiv preprint arXiv:2010.01981* (2020.).
- [16] Akshay Gadi Patil i dr. “Read: Recursive autoencoders for document layout generation”. U: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*. 2020., str. 544–545.
- [17] Salam Qaddoori Dawood Al-Zubaidi, Gualtiero Fantoni i Franco Failli. “Analysis of drivers for solving facility layout problems: A Literature review”. U: *Journal of industrial information integration* 21 (2021.), str. 100187.
- [18] Haifeng Zhang i dr. “Layout design for intelligent warehouse by evolution with fitness approximation”. U: *IEEE Access* 7 (2019.), str. 166310–166317.
- [19] Nagarjuna Reddy Gayam, K Shanmuganandam i D Vinodh. *WITHDRAWN: Layouts in production industries: A review*. 2020.
- [20] Xiaodong Yang i dr. “A review of cable layout design and assembly simulation in virtual environments”. U: *Virtual Reality & Intelligent Hardware* 1.6 (2019.), str. 543–557.
- [21] Aditya Dhoot i dr. “Optimizing wind farms layouts for maximum energy production using probabilistic inference: Benchmarking reveals superior computational efficiency and scalability”. U: *Energy* 223 (2021.), str. 120035.
- [22] Alaa Al Hawarneh, Salaheddine Bendak i Firas Ghanim. “Construction site layout planning problem: Past, present and future”. U: *Expert Systems with Applications* 168 (2021.), str. 114247.
- [23] Yaguang Wang, Yangjun Luo i Zhan Kang. “Integrated design optimization of structural topology and heat source layout”. U: *International Journal of Heat and Mass Transfer* 169 (2021.), str. 120943.
- [24] Sarvenaz Chaeibakhsh i dr. “Optimizing hospital room layout to reduce the risk of patient falls”. U: *arXiv preprint arXiv:2101.03210* (2021.).
- [25] Amir Sadrzadeh. “A genetic algorithm with the heuristic procedure to solve the multi-line layout problem”. U: *Computers & Industrial Engineering* 62.4 (2012.), str. 1055–1064.
- [26] Toby Rufinus. “Graph-based Terrain Generation”. Master rad. 2018.
- [27] Paul Henderson, Kartic Subr i Vittorio Ferrari. “Automatic generation of constrained furniture layouts”. U: *arXiv preprint arXiv:1711.10939* (2017.).
- [28] Manyi Li i dr. “Grains: Generative recursive autoencoders for indoor scenes”. U: *ACM Transactions on Graphics (TOG)* 38.2 (2019.), str. 1–16.

- [29] Andrew Luo i dr. “End-to-end optimization of scene layout”. U: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2020., str. 3754–3763.
- [30] Daniel Merkle i Martin Middendorf. “Ant colony optimization with global pheromone evaluation for scheduling a single machine”. U: *Applied Intelligence* 18 (2003.), str. 105–111.
- [31] Maxence Delorme, Manuel Iori i Silvano Martello. “Bin packing and cutting stock problems: Mathematical models and exact algorithms”. U: *European Journal of Operational Research* 255.1 (2016.), str. 1–20.
- [32] Donald M Simmons. “One-dimensional space allocation: an ordering algorithm”. U: *Operations Research* 17.5 (1969.), str. 812–826.
- [33] Jean-Claude Picard i Maurice Queyranne. “On the one-dimensional space allocation problem”. U: *Operations Research* 29.2 (1981.), str. 371–391.
- [34] Kai Wang i dr. “Deep convolutional priors for indoor scene synthesis”. U: *ACM Transactions on Graphics (TOG)* 37.4 (2018.), str. 1–14.
- [35] Lucas Majerowicz i dr. “Filling your shelves: Synthesizing diverse style-preserving artifact arrangements”. U: *IEEE transactions on visualization and computer graphics* 20.11 (2013.), str. 1507–1518.
- [36] Cheng Sun i dr. “Horizonnet: Learning room layout with 1d representation and pano stretch data augmentation”. U: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2019., str. 1047–1056.
- [37] GG Zabudsky i NS Veremchuk. “About One-Dimensional Space Allocation Problem with forbidden zones”. U: *Journal of Physics: Conference Series*. Sv. 1260. 8. IOP Publishing. 2019., str. 082006.
- [38] Mohammed Haroon Dupty i dr. “Constrained Layout Generation with Factor Graphs”. U: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2024., str. 12851–12860.
- [39] Elad Levi i dr. “Dlt: Conditioned layout generation with joint discrete-continuous diffusion layout transformer”. U: *Proceedings of the IEEE/CVF International Conference on Computer Vision*. 2023., str. 2106–2115.
- [40] Peter Burggraef, Johannes Wagner i Benjamin Heinbach. “Bibliometric study on the use of machine learning as resolution technique for facility layout problems”. U: *IEEE Access* 9 (2021.), str. 22569–22586.
- [41] Yang Liu i dr. “A survey of visual transformers”. U: *IEEE Transactions on Neural Networks and Learning Systems* (2023.).
- [42] Mohammad Mustafa Taye. “Understanding of machine learning with deep learning: architectures, workflow, applications and future directions”. U: *Computers* 12.5 (2023.), str. 91.

- [43] Adrian El Baz i dr. “Lessons learned from the NeurIPS 2021 MetaDL challenge: Backbone fine-tuning without episodic meta-learning dominates for few-shot learning image classification”. U: *NeurIPS 2021 Competitions and Demonstrations Track*. PMLR. 2022., str. 80–96.
- [44] Ms Aayushi Bansal, Dr Rewa Sharma i Dr Mamta Kathuria. “A systematic review on data scarcity problem in deep learning: solution and applications”. U: *ACM Computing Surveys (Csur)* 54.10s (2022.), str. 1–29.
- [45] Pedro Celard i dr. “A survey on deep learning applied to medical images: from simple artificial neural networks to generative models”. U: *Neural Computing and Applications* 35.3 (2023.), str. 2291–2323.
- [46] Jose Galarza i Tamer Oraby. “Functional data learning using convolutional neural networks”. U: *Machine Learning: Science and Technology* 5.1 (2024.), str. 015030.
- [47] Serkan Kiranyaz i dr. “1D convolutional neural networks and applications: A survey”. U: *Mechanical systems and signal processing* 151 (2021.), str. 107398.
- [48] Yun-long Wang i dr. “Research on intelligent design method of ship multi-deck compartment layout based on improved taboo search genetic algorithm”. U: *Ocean Engineering* 225 (2021.), str. 108823.
- [49] Ruiqi Wang i dr. “A layout design method for an industrial park based on a novel arrangement algorithm—Consideration of pipe network and multiple hazard sources”. U: *Chemical Engineering Science* 227 (2020.), str. 115929.
- [50] Peter Kán i Hannes Kaufmann. “Automated interior design using a genetic algorithm”. U: *Proceedings of the 23rd ACM symposium on virtual reality software and technology*. 2017., str. 1–10.
- [51] Chao Qian, Ren Kai Tan i Wenjing Ye. “An adaptive artificial neural network-based generative design method for layout designs”. U: *International Journal of Heat and Mass Transfer* 184 (2022.), str. 122313.
- [52] Johannes Bayer, Syed Saqib Bukhari i Andreas Dengel. “Floor plan generation and auto completion based on recurrent neural networks”. U: *2017 14th IAPR International Conference on Document Analysis and Recognition (ICDAR)*. Sv. 2. IEEE. 2017., str. 49–50.
- [53] Azalia Mirhoseini i dr. “Chip placement with deep reinforcement learning”. U: *arXiv preprint arXiv:2004.10746* (2020.).
- [54] Imdat As, Siddharth Pal i Prithwish Basu. “Artificial intelligence in architecture: Generating conceptual design via deep learning”. U: *International Journal of Architectural Computing* 16.4 (2018.), str. 306–327.
- [55] Jianan Li i dr. “Layoutgan: Synthesizing graphic layouts with vector-wireframe adversarial networks”. U: *IEEE Transactions on Pattern Analysis and Machine Intelligence* 43.7 (2020.), str. 2388–2399.

- [56] Akash Abdu Jyothi i dr. “Layoutvae: Stochastic scene layout generation from a label set”. U: *Proceedings of the IEEE/CVF International Conference on Computer Vision*. 2019., str. 9895–9904.
- [57] Xinpeng Wang, Chandan Yeshwanth i Matthias Nießner. “Sceneformer: Indoor scene generation with transformers”. U: *2021 International Conference on 3D Vision (3DV)*. IEEE. 2021., str. 106–115.
- [58] Shang Chai, Liansheng Zhuang i Fengying Yan. “Layoutdm: Transformer-based diffusion model for layout generation”. U: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2023., str. 18349–18358.
- [59] Mohammad Komaki, Shaya Sheikh i Behnam Malakooti. “Rule based layout planning and its multiple objectives”. U: *Proceedings of the 2014 ICAM, International Conference on Advanced and Agile Manufacturing, Held at Oakland University, Rochester, MI*. Sv. 48309. 2014.
- [60] Miguel F Anjos i Manuel VC Vieira. “Mathematical optimization approaches for facility layout problems: The state-of-the-art and future research directions”. U: *European journal of operational research* 261.1 (2017.), str. 1–16.
- [61] Peter Kán i Hannes Kaufmann. “Automatic furniture arrangement using greedy cost minimization”. U: *2018 IEEE Conference on Virtual Reality and 3D User Interfaces (VR)*. IEEE. 2018., str. 491–498.
- [62] Daniel Ritchie, Kai Wang i Yu-an Lin. “Fast and flexible indoor scene synthesis via deep convolutional generative models”. U: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2019., str. 6182–6190.
- [63] Kira Kempinska i Roberto Murcio. “Modelling urban networks using Variational Autoencoders”. U: *Applied Network Science* 4.1 (2019.), str. 1–11.
- [64] Zaiwei Zhang i dr. “Deep generative modeling for scene synthesis via hybrid representations”. U: *ACM Transactions on Graphics (TOG)* 39.2 (2020.), str. 1–21.
- [65] Kai Wang i dr. “Planit: Planning and instantiating indoor scenes with relation graph and spatial prior networks”. U: *ACM Transactions on Graphics (TOG)* 38.4 (2019.), str. 1–15.
- [66] Ruizhen Hu i dr. “Graph2plan: Learning floorplan generation from layout graphs”. U: *ACM Transactions on Graphics (TOG)* 39.4 (2020.), str. 118–1.
- [67] Nelson Nauata i dr. “House-gan: Relational generative adversarial networks for graph-constrained house layout generation”. U: *Computer Vision–ECCV 2020: 16th European Conference, Glasgow, UK, August 23–28, 2020, Proceedings, Part I 16*. Springer. 2020., str. 162–177.
- [68] Julian Jorge Andrade Guerreiro i dr. “LayoutFlow: Flow Matching for Layout Generation”. U: *European Conference on Computer Vision*. Springer. 2025., str. 56–72. DOI: <https://doi.org/10.48550/arXiv.2403.18187>.

- [69] Danielle Harris. “Spatial reasoning in context: bridging cognitive and educational perspectives of spatial-mathematics relations”. U: *Frontiers in Education*. Sv. 8. Frontiers Media SA. 2023., str. 1302099.
- [70] Toru Ishikawa i Nora S Newcombe. *Why spatial is special in education, learning, and everyday activities*. 2021.
- [71] Mingliang Zhai i Xuezhi Xiang. “Geometry understanding from autonomous driving scenarios based on feature refinement”. U: *Neural Computing and Applications* 33.8 (2021.), str. 3209–3220.
- [72] Zhengxiang Shi, Qiang Zhang i Aldo Lipani. “Stepgame: A new benchmark for robust multi-hop spatial reasoning in texts”. U: *Proceedings of the AAAI conference on artificial intelligence*. Sv. 36. 10. 2022., str. 11321–11329.
- [73] Fangjun Li, David C Hogg i Anthony G Cohn. “Advancing spatial reasoning in large language models: An in-depth evaluation and enhancement using the stepgame benchmark”. U: *Proceedings of the AAAI Conference on Artificial Intelligence*. Sv. 38. 17. 2024., str. 18500–18507.
- [74] Siyuan Xiang i dr. “Self-supervised spatial reasoning on multi-view line drawings”. U: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2022., str. 12745–12754.
- [75] Amita Kamath, Jack Hessel i Kai-Wei Chang. “What’s” up” with vision-language models? Investigating their struggle with spatial reasoning”. U: *arXiv preprint arXiv:2310.19785* (2023.).
- [76] Kanchana Ranasinghe i dr. “Learning to localize objects improves spatial reasoning in visual-llms”. U: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2024., str. 12977–12987.
- [77] Behnam Nikparvar i Jean-Claude Thill. “Machine learning of spatial data”. U: *ISPRS International Journal of Geo-Information* 10.9 (2021.), str. 600.
- [78] Hyunjae Kim i dr. “Exploring the spatial reasoning ability of neural models in human IQ tests”. U: *Neural Networks* 140 (2021.), str. 27–38.
- [79] Umberto M Tomasini i dr. “How deep convolutional neural networks lose spatial information with training”. U: *Machine Learning: Science and Technology* 4.4 (2023.), str. 045026.
- [80] Wenyu Han i dr. “Spare3d: A dataset for spatial reasoning on three-view line drawings”. U: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2020., str. 14690–14699.
- [81] Manfred Kopisch. “Spatial relations in technical domains”. U: *Applied Intelligence* 5 (1995.), str. 351–366.
- [82] Fangyu Liu, Guy Emerson i Nigel Collier. “Visual spatial reasoning”. U: *Transactions of the Association for Computational Linguistics* 11 (2023.), str. 635–651.

- [83] Max J Egenhofer, Jayant Sharma, David M Mark i dr. "A critical comparison of the 4-intersection and 9-intersection models for spatial relations: formal analysis". U: *AUTOCARTO-CONFERENCE*-. ASPRS AMERICAN SOCIETY FOR PHOTOGRAMMETRY AND. 1993., str. 1–1.
- [84] S. Skiadapoulos. "Directional Relations". U: *Encyclopedia of GIS*. 2016., str. 1–7.
- [85] Daniel Hernández, Eliseo Clementini i Paolino Di Felice. "Qualitative distances". U: *Spatial Information Theory A Theoretical Basis for GIS: International Conference COSIT'95 Semmering, Austria, September 21–23, 1995 Proceedings 2*. Springer. 1995., str. 45–57.
- [86] A. Gerevini i J. Renz. "Combine Topological and Size Information for Spatial Reasoning". U: *Artificial Intelligence* 137.1-2 (2002.), str. 1–42.
- [87] Chaman L Sabharwal i Jennifer L Leopold. "A completeness of metrics for topological relations in 3d qualitative spatial reasoning". U: *Polibits* 52 (2015.), str. 5–15.
- [88] Diego Martin Arroyo, Janis Postels i Federico Tombari. "Variational transformer networks for layout generation". U: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2021., str. 13642–13652.
- [89] Xiang Kong i dr. "BlT: Bidirectional layout transformer for controllable layout generation". U: *European Conference on Computer Vision*. Springer. 2022., str. 474–490.
- [90] Jianan Li i dr. "Attribute-conditioned layout gan for automatic graphic design". U: *IEEE Transactions on Visualization and Computer Graphics* 27.10 (2020.), str. 4039–4048.
- [91] Kotaro Kikuchi i dr. "Constrained graphic layout generation via latent optimization". U: *Proceedings of the 29th ACM International Conference on Multimedia*. 2021., str. 88–96.
- [92] Zhiqiang Gong, Ping Zhong i Weidong Hu. "Diversity in machine learning". U: *Ieee Access* 7 (2019.), str. 64323–64350.
- [93] Paul Merrell i dr. "Interactive furniture layout using interior design guidelines". U: *ACM transactions on graphics (TOG)* 30.4 (2011.), str. 1–10.
- [94] Song-Hai Zhang i dr. "A survey of 3D indoor scene synthesis". U: *Journal of Computer Science and Technology* 34 (2019.), str. 594–608.
- [95] Lane Book Company. *Sunset ideas for remodeling your home*. Lane Pub. Co., 1958.
- [96] Jane Powell. *Bungalow Kitchens*. Gibbs Smith, 2009.
- [97] Maud Wilson i dr. "Patterns for kitchen cabinets". U: (1947.).
- [98] Charlotte Baden-Powell. *Architect's pocket book of kitchen design*. Routledge, 2006.

- [99] Dana J Hepler, Paul Ross Wallach i Donald Hepler. *Drafting and design for architecture & Construction*. Cengage Learning, 2012.
- [100] House, T. O. *Read This Before Hiring a Kitchen Designer*. Accessed: 2024-02-04. 2020. URL: <https://www.thisoldhouse.com/kitchens/21015837/read-this-before-hiring-a-kitchen-designer>.
- [101] Made, A. *What Makes a GREAT Kitchen Designer?* Accessed: 2024-02-04. 2020. URL: <https://www.teknikakitchensandbaths.com/what-makes-a-great-kitchen-designer/>.
- [102] Huan Fu i dr. “3d-front: 3d furnished rooms with layouts and semantics”. U: *Proceedings of the IEEE/CVF International Conference on Computer Vision*. 2021., str. 10933–10942.
- [103] Yuji Roh, Geon Heo i Steven Euijong Whang. “A survey on data collection for machine learning: a big data-ai integration perspective”. U: *IEEE Transactions on Knowledge and Data Engineering* 33.4 (2019.), str. 1328–1347.
- [104] Jonas Freiknecht i Wolfgang Effelsberg. “A survey on the procedural generation of virtual worlds”. U: *Multimodal Technologies and Interaction* 1.4 (2017.), str. 27.
- [105] Francisco Caio Maia Rodrigues, Joaquim Bento Cavalcante Neto i Creto Augusto Vidal. “Split grammar evolution for procedural modeling of virtual buildings”. U: *2015 XVII Symposium on Virtual and Augmented Reality*. IEEE. 2015., str. 75–83.
- [106] Claus Brenner. “Towards fully automatic generation of city models”. U: *International Archives of Photogrammetry and Remote Sensing* 33.B3/1; PART 3 (2000.), str. 84–92.
- [107] Marie Saldana i Christopher Johanson. “Procedural modeling for rapid-prototyping of multiple building phases”. U: *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 40 (2013.), str. 205–210.
- [108] Peter J Birch i dr. “Rapid procedural-modelling of architectural structures”. U: *Proceedings of the 2001 conference on Virtual reality, archeology, and cultural heritage*. 2001., str. 187–196.
- [109] Neil Katz. “Algorithmic modelling, parametric thinking”. U: *Distributed Intelligence In Design* (2011.).
- [110] Petar Pejić, Miodrag Mikić i Jelena Milovanović. “Automatic Rule-Based Kitchen Layout Design”. U: *PaKSoM 2019* (2019.), str. 199.
- [111] Petar Pejic i dr. “Parametric 3D modeling of I-shape kitchen”. U: *Journal of Industrial Design and Engineering Graphics* 14.1 (2019.), str. 155–158.
- [112] Carl Schultz, Mehul Bhatt i André Borrmann. “Bridging qualitative spatial constraints and feature-based parametric modelling: Expressing visibility and movement constraints”. U: *Advanced Engineering Informatics* 31 (2017.), str. 2–17.

- [113] V Stojakovic i dr. "Parametric modeling applied to the virtual reconstruction of the damaged sculpture of St John Nepomuk in Petrovaradin". U: eCAADe. 2017.
- [114] S. Chaillou. *AI & Architecture: Towards a New Approach*. s.l.: Harvard GSD, 2019.
- [115] Elizabeth M Ranney. "Handbook of Kitchen Design". U: *Technical Series Index No. C5. 32R* (1950.).
- [116] A. Wormer. *Designing your own kitchen*. Log Home Design, 2003.
- [117] Jason A Znoy. *Professional interior design: a career guide*. iUniverse, 2004.
- [118] Xinhan Di i Pengqian Yu. "Multi-agent reinforcement learning of 3d furniture layout simulation in indoor graphics scenes". U: *arXiv preprint arXiv:2102.09137* (2021.).
- [119] Siyuan Qi i dr. "Human-centric indoor scene synthesis using stochastic grammar". U: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2018., str. 5899–5908.
- [120] C Moreno. "Importance and health of honey bee (*Apis mellifera*): a review". U: *Scientific Writing and Presentations in English* (2016.), str. 1–15.
- [121] Hugo Hadjur, Doreid Ammar i Laurent Lefèvre. "Toward an intelligent and efficient beehive: A survey of precision beekeeping systems and services". U: *Computers and Electronics in Agriculture* 192 (2022.), str. 106604.
- [122] J. Zalewski i dr. *Bees Are Beneficial*. Tehn. izv. Delaware: Mid-Atlantic Apiculture Research i Extension Consortium, 2020.
- [123] E. Crane. *The World History of Beekeeping and Honey Hunting*. Routledge, 1999.
- [124] Aleksejs Zacepins, E Stalidzans i J Meitalovs. "Application of information technologies in precision apiculture". U: *Proceedings of the 13th International Conference on Precision Agriculture (ICPA 2012)*. Sv. 7. 2012.
- [125] W. Meikle i N. Holst. "Application of continuous monitoring of honeybee colonies". U: *Apidologie* 46.1 (2014.), str. 10–22.
- [126] Putri Kusuma Astuti i dr. "Buzzing with Intelligence: Current Issues in Apiculture and the Role of Artificial Intelligence (AI) to Tackle It". U: *Insects* 15.6 (2024.), str. 418.
- [127] Agatha Turyagyenda i dr. "IoT and Machine Learning Techniques for Precision Beekeeping: A Review". U: *AI* 6.2 (2025.), str. 26.
- [128] Aleksejs Zacepins i dr. "Remote detection of the swarming of honey bee colonies by single-point temperature monitoring". U: *Biosystems engineering* 148 (2016.), str. 76–80.
- [129] Padraig Davidson i dr. "Anomaly detection in beehives using deep recurrent autoencoders". U: *arXiv preprint arXiv:2003.04576* (2020.).

- [130] Michaela Sakova i dr. “Bee Hive Acoustic Monitoring and Processing Using Convolutional Neural Network and Machine Learning”. U: *2024 34th International Conference Radioelektronika (RADIOELEKTRONIKA)*. IEEE. 2024., str. 1–5.
- [131] Stefan Schurischuster i Martin Kampel. “Image-based classification of honeybees”. U: *2020 Tenth International Conference on Image Processing Theory, Tools and Applications (IPTA)*. IEEE. 2020., str. 1–6.
- [132] Berkant İsmail Yıldız, Kemal Eskioğlu i Kemal Karabağ. “Developing a machine learning prediction model for honey production”. U: *Mediterranean Agricultural Sciences* 37.2 (2024.), str. 105–110.
- [133] Nebojša Andrijević i dr. “IoT monitoring and prediction modeling of honeybee activity with alarm”. U: *Electronics* 11.5 (2022.), str. 783.
- [134] María C Robustillo, Carlos J Pérez i María I Parra. “Predicting internal conditions of beehives using precision beekeeping”. U: *biosystems engineering* 221 (2022.), str. 19–29.
- [135] Sid Ahmed Metidji, Jean-Charles Huet i Lamine Bougueroua. “Data preparation for prediction and anomaly detection in precision beekeeping”. U: *Procedia Computer Science* 246 (2024.), str. 4008–4017.
- [136] Simon Bilik i dr. “Machine learning and computer vision techniques in continuous beehive monitoring applications: A survey”. U: *Computers and Electronics in Agriculture* 217 (2024.), str. 108560.
- [137] Alessio Brini, Elisa Giovannini i Elia Smaniotto. “A machine learning approach to forecasting honey production with tree-based methods”. U: *arXiv preprint arXiv:2304.01215* (2023.).
- [138] Omar Anwar i dr. “Apis-Prime: A deep learning model to optimize beehive monitoring system for the task of daily weight estimation”. U: *Applied Soft Computing* 144 (2023.), str. 110546.
- [139] Vladimir A Kulyukin i dr. “Discrete Time Series Forecasting of Hive Weight, In-Hive Temperature, and Hive Entrance Traffic in Non-Invasive Monitoring of Managed Honey Bee Colonies: Part I”. U: *Sensors* 24.19 (2024.), str. 6433.
- [140] Alessandro Terenzi, Stefania Cecchi i Susanna Spinsante. “On the importance of the sound emitted by honey bee hives”. U: *Veterinary Sciences* 7.4 (2020.), str. 168.
- [141] Poonam Biswal i dr. “NDVI is the best parameter for yield prediction at the peak vegetative stage of potato (*Solanum tuberosum* L.)” U: *Climate Smart Agriculture* 2.2 (2025.), str. 100053.
- [142] Dan J Dixon i dr. “Satellite prediction of forest flowering phenology”. U: *Remote Sensing of Environment* 255 (2021.), str. 112197.
- [143] B Jolly i dr. *Detection of southern beech heavy flowering using Sentinel-2 imagery. Remote Sens* 14: 1–12. 2022.

- [144] WG Meikle, Milagra Weiss i AR Stilwell. “Monitoring colony phenology using within-day variability in continuous weight and temperature of honey bee hives”. U: *Apidologie* 47 (2016.), str. 1–14.
- [145] William G Meikle i dr. “Within-day variation in continuous hive weight data as a measure of honey bee colony activity”. U: *Apidologie* 39.6 (2008.), str. 694–707.



# Dodatak A

## Analiza promene težine košnica

### A.1 Značenje promene težine košnice

Promena težine košnice se koristi kao ključan indikator aktivnosti pčelinje zajednice. U kontekstu dnevnih merenja tokom sezone paše, promene težine se najčešće tumače na sledeći način:

- Porast težine najčešće ukazuje na unos nektara od strane pčela. U sezoni paše, ovo se koristi kao indirektan pokazatelj da su biljke u okruženju aktivne u lučenju nektara, odnosno da „mede“ [144, 134].
- Pad težine najčešće ukazuje na prekid u unosu, a može biti posledica završetka paše, nepovoljnih vremenskih uslova, smanjenja broja aktivnih pčela, rojenja, gubitka matice ili potrošnje zaliha [145].

Važno je napomenuti da postoje izuzeci koji mogu otežati interpretaciju podataka i dovesti do pogrešnih zaključaka ukoliko se podaci ne analiziraju u širem kontekstu. Neki od takvih izuzetaka uključuju:

- Apsorpciju vlage: porast težine može nastati usled povećane vlažnosti vazduha, pri čemu saće apsorbuje vlagu, naročito tokom noći ili u uslovima visoke vlažnosti vazduha.
- Veštačku prihranu: van sezone, porast težine može biti rezultat unošenja šećernog sirupa od strane pčelara, a ne prirodnog unosa nektara.
- Isparavanje vode iz nektara: manji pad težine tokom noći često je posledica procesa sazrevanja meda, kada pčele aktivno ventilacijom isparavaju višak vode iz nektara [138].
- Uticaj padavina i kondenzacije: vaga može registrovati porast težine usled direktnog izlaganja kiši ili kondenzacije, što ne odražava stvarnu promenu težine košnice.


- Netačnost mernog sistema: elektronske vage mogu biti podložne oscilacijama usled temperaturnih promena, mehaničkih smetnji ili nestabilnog terena, što može proizvesti lažne promene u težini.

Ipak, u većini praktičnih slučajeva, dnevne promene težine pouzdano odražavaju dinamiku unosa i koriste se u operativnim pčelarskim odlukama, kao što su selidba košnica, dodavanje nastavaka ili planiranje vrcanja [144].


## A.2 Korelacija promena težine košnica na istoj mikrolokaciji

U ovom potpoglavlju analizirani su obrasci ponašanja pčelinjih društava koja se nalaze na istoj mikrolokaciji, sa ciljem da se proverí da li dele slične obrasce promene težine ili postoje značajne razlike među njima. Kroz ovu analizu ispituje se da li je moguće obučiti jedan zajednički prediktivni model promene težine za celu lokaciju, umesto da se trenira poseban model za svaku košnicu pojedinačno.

Za analizu je korišćen skup podataka iz rada [139]. Skup sadrži vremenske serije težina za deset košnica postavljenih na istoj mikrolokaciji u Tusonu, u istom vremenskom periodu od juna do septembra. Košnice imaju različite genetske linije matice: u pet košnica matica je tipa Russian, dok su u preostalih pet matice tipa Wooten. Vremenske serije košnica sa istim maticama prikazane su na grafikonima na slici A.1.



(a) Wooten matica



(b) Russian matica

Slika A.1: Težine košnica sa Wooten i Russian maticom

Kako bi se kvantitativno procenila sličnost između vremenskih serija, korišćen je Pirsonov koeficijent korelacije (engl. *Pearson correlation coefficient*). Rezultati su predstavljeni u dve odvojene tabele (Tabela A.1 i Tabela A.2), od kojih svaka odgovara jednoj genetskoj liniji matica.

Tabela A.1: Pirsonov koeficijent korelacije između košnica sa Wooten maticom

|                | <b>mwh2129</b> | <b>mwh2130</b> | <b>mwh2137</b> | <b>mwh2146</b> | <b>mwh2123</b> |
|----------------|----------------|----------------|----------------|----------------|----------------|
| <b>mwh2129</b> | 1.000          | 0.949          | 0.870          | 0.938          | 0.374          |
| <b>mwh2130</b> | 0.949          | 1.000          | 0.949          | 0.983          | 0.370          |
| <b>mwh2137</b> | 0.870          | 0.949          | 1.000          | 0.975          | 0.333          |
| <b>mwh2146</b> | 0.938          | 0.983          | 0.975          | 1.000          | 0.318          |
| <b>mwh2123</b> | 0.374          | 0.370          | 0.333          | 0.318          | 1.000          |

Tabela A.2: Pirsonov koeficijent korelacije između košnica sa Russian maticom

|                | <b>mwh2059</b> | <b>mwh2120</b> | <b>mwh2141</b> | <b>mwh2142</b> | <b>mwh2158</b> |
|----------------|----------------|----------------|----------------|----------------|----------------|
| <b>mwh2059</b> | 1.000          | 0.228          | 0.207          | 0.516          | 0.737          |
| <b>mwh2120</b> | 0.228          | 1.000          | 0.994          | -0.648         | 0.109          |
| <b>mwh2141</b> | 0.207          | 0.994          | 1.000          | -0.667         | 0.093          |
| <b>mwh2142</b> | 0.516          | -0.648         | -0.667         | 1.000          | 0.535          |
| <b>mwh2158</b> | 0.737          | 0.109          | 0.093          | 0.535          | 1.000          |

Košnice sa Wooten maticama (mwh2129, mwh2130, mwh2137, mwh2146) pokazuju vrlo visok stepen međusobne korelacije (sve vrednosti iznad 0.87), što ukazuje na snažnu konzistentnost u obrascima promena težine tokom posmatranog perioda. Ove serije gotovo identično registruju promene težine tokom posmatranog perioda. Ovo potvrđuje pretpostavku da pčelinja društva sa istom genetskom osnovom, na istoj lokaciji i pod istim vremenskim uslovima, imaju visok stepen predvidivosti u pogledu dinamike unosa nektara. Jedina serija iz Wooten grupe koja se statistički izdvaja je mwh2123, čije korelacije sa ostalim serijama iz iste grupe ostaju niske (sve ispod 0.38). Ova odstupanja mogu ukazivati na specifično ponašanje konkretnog društva ili tehničku grešku u merenju.

Za razliku od Wooten grupe, košnice sa Russian maticama (mwh2059, mwh2120, mwh2141, mwh2142, mwh2158) pokazuju znatno niže i neujednačenije korelacije. Neki parovi imaju jaku pozitivnu korelaciju (npr. mwh2059 i mwh2158,  $r = 0.74$ ), dok su drugi u snažnoj negativnoj korelaciji (mwh2120 i mwh2142,  $r = -0.65$ ), ili gotovo bez povezanosti (mwh2141 i mwh2158,  $r = 0.09$ ). Ova raznolikost ukazuje na veću varijabilnost ponašanja pčelinjih društava unutar ove genetske linije, čak i pod istim spoljašnjim uslovima. Međutim, iako su košnice mwh2141 i mwh2120, formalno označene kao košnice sa Russian maticom, pokazuju izuzetno visoku korelaciju sa svim košnicama sa Wooten maticom, osim sa mwh2123, što je očekivano jer mwh2123 nije bila u visokoj korelaciji ni sa ostalim Wooten serijama. Korelacije sa mwh2129, mwh2130, mwh2137 i mwh2146 su sve iznad 0.92, neke čak i preko 0.97, što može ukazivati na: pogrešnu klasifikaciju – (možda su ove matice zapravo tipa Wooten) ili odstupanje unutar populacije (ova dva društva mogu imati sličniji stil unosa kao Wooten zbog okruženja, snage zajednice ili neke druge lokalne varijable). Ovakvi rezultati otvaraju pitanja o potencijalnim specifičnostima pojedinačnih društava i ukazuju na potrebu dodatnog kontekstualnog razumevanja podataka. Bilo bi korisno konsultovati autore skupa podataka kako bi se razjasnile moguće specifičnosti u okruženju, načinu evidentiranja podataka, kao i da bi se potvrdila tačnost klasifikacije matica po genetskoj liniji.

Rezultati ukazuju na postojanje konzistentnih obrazaca u promenama težine košnica na istoj mikrolokaciji, ali je za potvrdu opšte primenljivosti ovakvog zaključka neophodno sprovesti dodatna testiranja na različitim lokacijama i u dužim vremenskim intervalima.

# Biografija

Jelena Ljubiša Pejić (devojačko Milovanović) rođena je 2. septembra 1992. godine u Nišu, gde je završila prvi razred osnovne škole. Dalje obrazovanje nastavila je u Sokobanji, gde je završila Osnovnu školu „Mitropolit Mihailo“ i Srednju školu „Branislav Nušić“, postavši pritom prva učenica koja je istovremeno ponela titule sportiste i đaka generacije. Tokom školovanja posebno se isticala u matematici, osvajanjem nagrada na republičkim i regionalnim takmičenjima, a nagrađivana je i u disciplinama poput hemije i srpskog jezika.

Presudan trenutak u daljem obrazovanju bio je susret sa prezentacijom Departmana za Računarske nauke Prirodno-matematičkog fakulteta u Nišu, kojoj je prisustvovala kao jedan od najtalentovanijih đaka u regionu. Uprkos širokom spektru interesovanja, tada je donela odluku da svoje dalje školovanje nastavi upravo na ovom Departmanu. Osnovne studije završila je 2014. godine sa prosečnom ocenom 9,76/10, a master studije iz Razvoja softvera 2016. godine, sa prosečnom ocenom 10/10. 2015. godine proglašena je najboljom studentkinjom Prirodno-matematičkog fakulteta.

Njeno glavno opredeljenje tokom studija postaje veštačka inteligencija, oblast koja nalazi primenu gotovo svuda a za razvoj zahteva interdisciplinarno znanje - od matematike i programiranja do razumevanja različitih domena poput biomedicine, obrade prirodnog jezika pa čak i društvenih nauka.

Doktorske studije upisuje 2016. godine u Nišu, na Departmanu za Računarske nauke. Paralelno sa doktorskim studijama, kroz saradnju sa različitim IT kompanijama, radi na primeni veštačke inteligencije u rešavanju problema iz prakse. Nedugo po završetku master studija započela je i akademsku karijeru kao asistent na Prirodno-matematičkom fakultetu. Uporedo je radila i kao profesor u Gimnaziji „Bora Stanković“ u Nišu, čime je potvrdila da njena karijera podjednako pripada i veštačkoj, i prirodnoj inteligenciji.

U oblasti veštačke inteligencije učestvovala je u projektima iz domena obrade prirodnog jezika, sajber bezbednosti, biomedicine, analitike i segmentacije kupaca, kao i arhitekture i poljoprivrede. Godine 2020. osnovala je startup posvećen primeni veštačke inteligencije u pčelarstvu, koji je ubrzo prepoznat i nagrađivan u zemlji i inostranstvu. Među značajnijim priznanjima ističu se drugo mesto na Takmičenju za najbolju tehnološku inovaciju u Srbiji, više pobeda na regionalnim programima i takmičenjima, uključujući pobedu na *Tech Boost* programu u Sarajevu i *Green Innovation Award* u Podgorici, kao i potvrdu izvrsnosti na evropskom nivou (eng. *Seal of Excellence*) u okviru *Horizon* programa.

---

Svoj naučni rad predstavila je kroz publikacije u časopisima i na konferencijama. Radovi u časopisima:

- Mihajlo Milovanović, Jelena Pejić i Petar Pejić. „Advanced sensors for noninvasive bee colony inspection.”U: *Computers and Electronics in Agriculture* 231 (2025.), str. 109945. **(M21a+)**
- Jelena Pejić, Marko Petković i Sandra Klinge. „Exploring spatial reasoning performances of CNN on linear layout dataset.”U: *Machine Learning: Science and Technology* 5.4 (2024), str. 045056.**(M21a)**
- Jelena Pejić, Mihajlo Milovanović, Aca Božilov i Petar Pejić. „Impact of the precision beekeeping on the living environment.”U: *Facta Universitatis, Series: Working and Living Environmental Protection* (2022.), str. 049–061.**(M52)**
- Jelena Pejić i Petar Pejić. „Linear kitchen layout design via machine learning”.*AI EDAM* 36 (2022.), str. e9. **(M21)**

Radovi sa konferencija:

- Miljan Stevanović, Jelena Pejić i Petar Pejić. „Robotic Arm: Extension of Artistic Actions.”U: *Advances in Service and Industrial Robotics. RAAD 2025. Mechanisms and Machine Science* 190. Springer, 2025.**(M33)**
- Anđa Denić, Jelena Pejić i Aleksandar Trokičić. „Exploring Word2vec models for capturing the similarity of codon embeddings.”U: *The Third Serbian International Conference on Applied Artificial Intelligence (SICAAI)*, Kragujevac, Srbija, Maj 23-24, 2024. , str. 124. **(M34)**
- Mihajlo Milovanović, Jelena Pejić i Petar Pejić. „Development of Smart Beehive Frame for Multi-Parameter Monitoring.”U: *IEEE 33rd International Conference on Microelectronics (MIEL)*, Nis, Srbija, Oktobar 16-18, 2023. **(M33)**
- Petar Pejić, Jelena Pejić i Miodrag Mikić. „Augmented Reality Kitchen Design.”U *IETI Transactions on Engineering Research and Practice*, 4.2 (2020.), str. 41–49. **(M33)**
- Jelena Milovanović i Branimir Todorović. „Using Deep Neural Networks for Internal Banking Fraud Detection.”U: *The Seventh Conference on Information Theory and Complex Systems (TINKOS 2019)*, Beograd, Srbija, 2019. , str. 28.**(M64)**
- Jelena Milovanović, Miljan Stevanović, Petar Pejić. „Demystifying artists perception using Neural Style Transfer and Augmented Reality.”U: *AI and Arts, KI 2019 conference*, Kassel, Germany, September, 2019. **(M34)**
- Petar Pejić, Miodrag Mikić i Jelena Milovanović. „Automatic Rule-Based Kitchen Layout Design.”U: *PaKSoM 2019* (2019.), str. 199.**(M33)**

- 
- Jelena Milovanović i Branimir Todorović. „Semantic similarity detection in continuous vector space of words and phrases.” U: *The Fourth National Conference on Information Theory and Complex Systems (TINKOS 2016)*, Beograd, Srbija, Oktobar 27–28, 2016. (M64)

Koautor je udžbenika:

- Petar Pejić i Jelena Pejić. „Preduzetništvo i inovacije u softverskom inženjerstvu”, Metropolitan univerzitet Beograd, 2024.

Takođe, jedan je od podnosilaca međunarodnog i nacionalnog patenta:

- Petar Pejić, Jelena Pejić i Mihajlo Milovanović. „Frame with sensors for sampling honeycomb content based on the method of absorption spectroscopy.” Međunarodna patentna prijava PCT/RS2022/000017, Broj publikacije: WO/2023/113633, 2023. (M93)
- Petar Pejić, Jelena Pejić i Mihajlo Milovanović. „Ram sa senzorima za uzorkovanje sadržaja pčelinjeg saća zasnovan na metodi apsorpcione spektroskopije.” Prijavljen patent na nacionalnom nivou P-2021/1537, 2021. (M87)



**ИЗЈАВА О ИСТОВЕТНОСТИ ШТАМПАНОГ И ЕЛЕКТРОНСКОГ ОБЛИКА  
ДОКТОРСКЕ ДИСЕРТАЦИЈЕ**


Наслов дисертације:

**МЕТОД ЗА ГЕНЕРИСАЊЕ ЛИНЕАРНОГ РАСПОРЕДА КОРЕЛИСАНИХ  
ЕЛЕМЕНАТА ПРИМЕНОМ ВЕШТАЧКЕ ИНТЕЛИГЕНЦИЈЕ**

Изјављујем да је електронски облик моје докторске дисертације, коју сам предао/ла за уношење у **Дигитални репозиторијум Универзитета у Нишу**, истоветан штампаном облику.

У Нишу, 04.11.2025.

Потпис аутора дисертације:



---

Јелена Љ. Пејић



## ИЗЈАВА О АУТОРСТВУ

Изјављујем да је докторска дисертација, под насловом

### **МЕТОД ЗА ГЕНЕРИСАЊЕ ЛИНЕАРНОГ РАСПОРЕДА КОРЕЛИСАНИХ ЕЛЕМЕНАТА ПРИМЕНОМ ВЕШТАЧКЕ ИНТЕЛИГЕНЦИЈЕ**


која је одбрањена на Природно-математичком факултету Универзитета у Нишу:

- резултат сопственог истраживачког рада;
- да ову дисертацију, ни у целини, нити у деловима, нисам пријављивао/ла на другим факултетима, нити универзитетима;
- да нисам повредио/ла ауторска права, нити злоупотребио/ла интелектуалну својину других лица.

Дозвољавам да се објаве моји лични подаци, који су у вези са ауторством и добијањем академског звања доктора наука, као што су име и презиме, година и место рођења и датум одбране рада, и то у каталогу Библиотеке, Дигиталном репозиторијуму Универзитета у Нишу, као и у публикацијама Универзитета у Нишу.

У Нишу, 04.11.2025.

Потпис аутора дисертације:



---

Јелена Љ. Пејић



## ИЗЈАВА О КОРИШЋЕЊУ

Овлашћујем Универзитетску библиотеку „Никола Тесла“ да у Дигитални репозиторијум Универзитета у Нишу унесе моју докторску дисертацију, под насловом:

### МЕТОД ЗА ГЕНЕРИСАЊЕ ЛИНЕАРНОГ РАСПОРЕДА КОРЕЛИСАНИХ ЕЛЕМЕНАТА ПРИМЕНОМ ВЕШТАЧКЕ ИНТЕЛИГЕНЦИЈЕ

Дисертацију са свим прилозима предао/ла сам у електронском облику, погодном за трајно архивирање.

Моју докторску дисертацију, унету у Дигитални репозиторијум Универзитета у Нишу, могу користити сви који поштују одредбе садржане у одабраном типу лиценце Креативне заједнице (Creative Commons), за коју сам се одлучио/ла.

1. Ауторство (CC BY)

2. Ауторство – некомерцијално (CC BY-NC)

**3. Ауторство – некомерцијално – без прераде (CC BY-NC-ND)**

4. Ауторство – некомерцијално – делити под истим условима (CC BY-NC-SA)

5. Ауторство – без прераде (CC BY-ND)

6. Ауторство – делити под истим условима (CC BY-SA)

У Нишу, 04.11.2025.

Потпис аутора дисертације:



Јелена Љ. Пејић