

**“VICTOR BABEȘ” UNIVERSITY OF MEDICINE  
AND PHARMACY FROM TIMIȘOARA  
FACULTY OF MEDICINE  
DEPARTMENT XV – ORTHOPAEDICS-TRAUMATOLOGY II**

**BOTNARI ALEXEI**



# **PhD THESIS**

**Deep Learning for AI-Assisted Diagnosis of Knee  
Pathology in MRI Imaging: Advanced  
Segmentation, Classification,  
and Detection Models**

**A B S T R A C T**

Scientific Coordinator  
**PROF. UNIV. DR. JENEL MARIAN PĂTRAȘCU**

**Timișoara  
2025**



## ABSTRACT

Knee injuries are among the most common musculoskeletal disorders, significantly impacting healthcare costs and patient morbidity. The knee's complex structure—comprising ligaments, menisci, cartilage, and bones—makes it particularly vulnerable, especially among athletes and individuals engaged in physically demanding activities. Common injuries such as anterior cruciate ligament (ACL) tears, meniscal damage, and cartilage lesions can lead to severe complications, including osteoarthritis (OA) and chronic instability, if not diagnosed and treated promptly.

Magnetic Resonance Imaging (MRI) has become the gold standard for knee injury diagnosis, offering high-resolution, non-invasive visualization of soft tissues. However, its accuracy is dependent on radiologist expertise, leading to inter-observer variability and diagnostic inconsistencies. Moreover, the large volume of MRI data makes manual interpretation time-consuming, underscoring the need for automated solutions.

Artificial intelligence (AI), particularly deep learning (DL), has emerged as a promising tool in medical imaging, enhancing accuracy and efficiency in knee MRI analysis. Convolutional neural networks (CNNs) have demonstrated superior performance in identifying complex patterns within medical images, surpassing traditional diagnostic methods. By leveraging large datasets, deep learning models can autonomously detect and classify abnormalities with high precision, potentially revolutionizing knee injury diagnosis.

Knee injuries pose a significant public health challenge, particularly in sports. In the U.S., approximately 200,000 ACL injuries occur annually, with meniscal injuries affecting 12–14% of the general population. Cartilage injuries impact nearly 900,000 individuals each year, with over 200,000 requiring surgical intervention. Without timely treatment, these conditions can lead to functional impairment and an increased risk of OA, highlighting the need for accurate and efficient diagnostic tools.

Despite MRI's advantages, traditional radiological analysis faces challenges, including overwhelming image volumes and inter-observer variability. Studies indicate only moderate agreement among radiologists in knee MRI assessments, emphasizing the necessity of AI-assisted approaches for improving diagnostic reliability. Deep learning models can automate segmentation and classification, reducing subjectivity and streamlining interpretation. Research

has demonstrated the effectiveness of AI in knee MRI analysis, with CNN-based approaches achieving high accuracy in cartilage lesion detection. These advancements highlight AI's transformative potential in knee injury diagnostics, improving patient outcomes and clinical decision-making.

Building upon these insights, my doctoral research focuses on developing a deep learning-based model designed to automatically segment knee MRI images and identify, classify, and differentiate various knee lesions. These include meniscal tears, ACL injuries, arthritis-related degeneration, and normal anatomical structures. The objective of this research is to bridge the gap between traditional MRI interpretation and AI-powered diagnostic tools, ultimately improving the accuracy and efficiency of knee injury evaluation.

The study begins with a **systematic review and meta-analysis** of DL models applied to meniscal tear detection and knee pathology classification. Unlike previous reviews, this study introduces several key innovations: a focused analysis of meniscal lesion classification, meta-analyses quantifying DL model accuracy, and a direct comparison of DL models with musculoskeletal radiologists' assessments. Additionally, this review uniquely validates DL findings against arthroscopy, the gold standard for diagnosis, and employs the CLAIM checklist to assess study rigor. A thorough database search identified 236 relevant studies, from which 12 were selected after applying inclusion criteria. The findings underscore the diverse approaches utilized in DL-based knee pathology classification, with reported AUC values ranging from 0.83 to 0.94. Although DL models frequently achieve high accuracy, surpassing radiologists in some cases, challenges such as segmentation accuracy, 3D imaging integration, and generalizability remain.

The second phase of the research involved **dataset curation and preprocessing** to ensure consistency and reliability for DL model training. A standardized dataset of 650 knee MRI scans (2016–2019) was obtained from the County Emergency Hospital of Alba Iulia following ethical approval. MRI scans were categorized into five groups: ACL injury, combined ACL and meniscus injury, isolated meniscus tear, arthritis, or normal. The preprocessing workflow included orientation adjustments, intensity normalization, spatial resampling, and format conversion to ensure data uniformity. A novel application, **PreProcMed**, was developed to streamline MRI preprocessing, anonymization, and NIfTI format conversion, facilitating deep learning model training with minimal effort. By automating preprocessing steps, this tool significantly enhances workflow efficiency for researchers and clinicians.

The third phase focused on **developing and evaluating deep learning models** for knee pathology detection. Two segmentation models were introduced: **KneeSAM**, achieving a Dice similarity coefficient of 0.8026, and a U-Net model trained on 2D proton-density sagittal knee MRI scans, attaining a Dice similarity score of 0.95. The segmentation results were validated through comparative analysis with expert radiologists and orthopedic surgeons, demonstrating high reliability.

For knee lesion classification and detection, a **multiclass CNN-LSTM model** was developed, integrating knee MRI scans with musculoskeletal radiology reports for a comprehensive assessment of ACL and meniscus tears, osteoarthritic changes, and other pathological conditions. The model achieved 78.64% accuracy and a precision score of 77.28%. To enhance classification performance, a CNN model leveraging transfer learning via ResNet-50 was developed, significantly improving accuracy to 86%, with a precision of 94% and an AUC of 0.90. These findings align with previously reported literature, demonstrating the robustness of the proposed approach.

Additionally, an LSTM-based model for knee MRI report classification was designed, exhibiting strong accuracy, precision, and recall. When applied to an external dataset, transfer learning improved the CNN model's performance from an AUC of 0.77 to 0.85, highlighting the importance of large, high-quality training datasets in enhancing DL model generalizability.

Key contributions of this research include:

### 1. **Comprehensive Review and Meta-Analysis**

- Conducted a systematic review and meta-analysis of DL models for knee pathology detection.
- Identified critical gaps such as dataset standardization, arthroscopic validation, and the need for multi-center studies.
- Provided insights into improving AI-based knee pathology detection.

## 2. Dataset Collection and Preprocessing

- Curated a high-quality, annotated dataset of knee MRI scans from the County Emergency Hospital of Alba Iulia.
- Developed preprocessing techniques, including intensity normalization and augmentation, to enhance model robustness.

## 3. Development of PreProcMed Application

- Created an innovative tool for rapid preprocessing, anonymization, and conversion of knee MRI scans into NIfTI format.
- Streamlined dataset preparation for ACL and meniscal tear segmentation and localization, reducing effort for researchers and clinicians.

## 4. Deep Learning Models for Knee Structure Segmentation

- Developed **KneeSAM**, a segmentation model achieving a Dice similarity coefficient consistent with existing literature.
- Implemented a **U-Net model**, which outperformed previous approaches in segmenting knee structures with high accuracy.

## 5. CNN-Based Models for Knee Lesion Classification and Detection

- Designed a **multiclass CNN-LSTM model**, integrating MRI scans with musculoskeletal radiology reports for ACL and meniscus tear classification.
- Developed a **CNN model with transfer learning**, significantly enhancing classification accuracy and clinical applicability.

## **6. Performance Evaluation and Model Optimization**

- Conducted extensive evaluations of DL architectures and hyperparameter configurations to optimize performance.
- Implemented strategies to mitigate overfitting and improve model generalization for real-world clinical settings.

## **7. Clinical and AI Integration Perspective**

- Examined the challenges and opportunities of integrating AI-based models into orthopedic diagnostic workflows.
- Proposed recommendations for large-scale validation and real-time deployment strategies in clinical settings.

## **8. Scientific Dissemination and Knowledge Contribution**

- Presented findings at international conferences on orthopedics and AI.
- Published research detailing methodology, experimental results, and clinical implications of AI-driven knee lesion detection.

This doctoral research advances the field of AI-assisted orthopedic diagnostics by establishing a robust deep learning framework for knee pathology analysis. The study not only provides new insights into DL model performance but also introduces novel preprocessing techniques and software tools that enhance model reliability and clinical applicability. Future research will focus on refining segmentation models, expanding datasets, and integrating DL frameworks into real-world orthopedic diagnostics, ultimately contributing to improved patient outcomes and AI-driven advancements in musculoskeletal imaging.

**UNIVERSITATEA DE MEDICINĂ ȘI FARMACIE  
“VICTOR BABEȘ” DIN TIMIȘOARA  
FACULTATEA DE MEDICINA  
DEPARTAMENTUL XV – ORTOPEDIE-TRAUMATOLOGIE II**

**BOTNARI ALEXEI**



# **TEZĂ DE DOCTORAT**

**Deep Learning pentru diagnosticul asistat de IA al  
patologiei genunchiului în imagistica RMN:  
Modele avansate de segmentare,  
clasificare și detecție.**

## **R E Z U M A T**

Conducător de doctorat:  
**PROF. UNIV. DR. JENEL MARIAN PĂTRAȘCU**

**Timișoara  
2025**





## REZUMAT

Leziunile genunchiului sunt printre cele mai frecvente tulburări musculo-scheletale, având un impact semnificativ asupra costurilor de îngrijire medicală și a morbidității pacienților. Structura complexă a articulației genunchiului, compusă din ligamente, meniscuri, cartilaj și oase, îl face deosebit de vulnerabil, în special în rândul sportivilor și al persoanelor implicate în activități fizice solicitante. Leziunile comune, cum ar fi rupturile ligamentului încrucișat anterior (LCA), deteriorarea meniscurilor și leziunile cartilajului, pot duce la complicații severe, inclusiv gonartroza și instabilitate cronică, dacă nu sunt diagnosticate și tratate prompt.

Imagistica prin Rezonanță Magnetică Nucleară (RMN) a devenit standardul de aur pentru diagnosticul leziunilor de genunchi, oferind o vizualizare de înaltă rezoluție și non-invazivă a țesuturilor moi. Cu toate acestea, acuratețea sa depinde de expertiza radiologului, ceea ce duce la variabilitate între observatori și inconsistențe diagnostice. Mai mult, volumul mare de date RMN face ca interpretarea manuală să fie consumatoare de timp, subliniind necesitatea unor soluții automate.

Inteligența artificială (IA), în special învățarea profundă Deep Learning (DL), a apărut ca un instrument promițător în imagistica medicală, îmbunătățind acuratețea și eficiența în analiza RMN a genunchiului. Rețelele neuronale convoluționale (CNN) au demonstrat o performanță superioară în identificarea unor tipare complexe în imaginile medicale, depășind metodele tradiționale de diagnosticare. Prin valorificarea seturilor mari de date, modelele de învățare profundă pot detecta și clasifica autonom tulburările patologice cu o precizie ridicată, având potențialul de a revoluționa diagnosticul leziunilor de genunchi.

Leziunile de genunchi reprezintă o provocare semnificativă pentru sănătatea publică, în special în sport. În SUA, aproximativ 200.000 de leziuni ale ligamentului încrucișat anterior (LIA) au loc anual, iar leziunile meniscului afectează 12–14% din populația generală. Leziunile cartilajului afectează aproape 900.000 de persoane în fiecare an, dintre care peste 200.000 necesită intervenție chirurgicală. Fără un tratament prompt, aceste afecțiuni pot duce la incapacitate funcțională și la un risc crescut de gonartroza, subliniind necesitatea unor instrumente de diagnostic precise și eficiente.

În ciuda avantajelor RMN-ului, interpretarea radiologică tradițională se confruntă cu provocări, inclusiv volume copleșitoare de imagini și variabilitate între observatori. Studiile indică doar un acord moderat între radiologi în evaluările RMN-ului de genunchi, subliniind necesitatea abordărilor asistate de inteligență artificială pentru îmbunătățirea fiabilității diagnostice. Modelele de învățare profundă pot automatiza segmentarea și clasificarea, reducând subiectivitatea și simplificând interpretarea. Cercetările au demonstrat eficacitatea IA în analiza RMN-ului genunchiului, abordările bazate pe CNN atingând o precizie ridicată în detectarea leziunilor cartilajinoase. Aceste progrese subliniază potențialul transformator al inteligenței artificiale în diagnosticul leziunilor de genunchi, îmbunătățind rezultatele pacienților și luarea deciziilor clinice.

Bazându-mă pe aceste informații, cercetarea mea doctorală se concentrează pe dezvoltarea unui model bazat pe învățare profundă, destinat să segmenteze automat imaginile RMN ale genunchiului și să identifice, clasifice și diferențieze diverse leziuni ale genunchiului. Acestea includ leziuni meniscale, leziuni ale ligamentului încrucișat anterior, degenerare asociată artrozei și structuri anatomice normale. Obiectivul acestei cercetări este de a reduce diferențele dintre interpretarea tradițională a RMN-ului și instrumentele de diagnostic bazate pe inteligență artificială, îmbunătățind în cele din urmă acuratețea și eficiența evaluării leziunilor genunchiului.

Studiul începe cu o **revizuire sistematică și o meta-analiză** a modelelor DL aplicate la detectarea leziunilor de menisc și clasificarea patologiei genunchiului. Spre deosebire de articolele anterioare, acest studiu introduce câteva inovații cheie: o analiză concentrată a clasificării leziunilor meniscale, meta-analize care cuantifică acuratețea modelului DL și o comparație directă a modelului DL cu interpretarea medicilor radiologi. În plus, acest review validează în mod unic constatările DL prin compararea cu artroscopia genunchiului, standardul de aur pentru diagnostic, și folosește lista de verificare CLAIM pentru a evalua rigurozitatea studiului. O căutare amănunțită în baza de date a identificat 236 de studii relevante, dintre care 12 au fost selectate după aplicarea criteriilor de includere. Constatările subliniază abordările diverse utilizate în clasificarea patologiei genunchiului bazată pe DL, cu valori AUC raportate cuprinse între 0,83 și 0,94. Deși modelele DL ating frecvent o precizie ridicată, depășind radiologii în unele cazuri, provocări precum precizia segmentării, integrarea imaginilor 3D și setul de date care nu este general răman.

A doua fază a cercetării a implicat **analiza și preprocesarea setului de date** pentru a asigura consistența și fiabilitatea antrenamentului modelului DL. Un set de date standardizat de 650 de scanări RMN ale genunchiului (2016–2019) a fost obținut de la Spitalul Clinic Județean de Urgență Alba Iulia, după aprobarea etică. Scanările RMN au fost clasificate în cinci grupuri:

leziune de LIA, leziune combinată de LIA și menisc, ruptură izolată de menisc, artroza și normal. Fluxul de lucru de preprocesare a inclus ajustări de orientare, normalizare a intensității, resampling spațial și conversie de format pentru a asigura uniformitatea datelor. O aplicație nouă, **PreProcMed**, a fost dezvoltată pentru a simplifica preprocesarea RMN, anonimizarea și conversia în format NIfTI, facilitând antrenarea modelelor de învățare profundă cu un efort minim. Prin automatizarea pașilor de preprocesare, acest instrument îmbunătățește semnificativ eficiența fluxului de lucru pentru cercetători și clinicieni.

A treia etapă s-a concentrat pe dezvoltarea și evaluarea modelelor de învățare profundă pentru detectarea patologiei genunchiului. Au fost introduse două modele de segmentare: **KneeSAM**, care a atins un coeficient de similaritate Dice de 0,8026, și un model U-Net antrenat pe scanări RMN sagitale 2D cu protoni de densitate a genunchiului, care a obținut un scor de similaritate Dice de 0,95. Rezultatele segmentării au fost validate prin analiză comparativă cu radiologi și ortopezi experți, demonstrând o fiabilitate ridicată.

Pentru clasificarea și detectarea leziunilor de genunchi, a fost dezvoltat un model **multiclass CNN-LSTM**, integrând examinările RMN ale genunchiului cu interpretarea radiologică pentru o evaluare cuprinzătoare a rupturilor de ligament încrucișat anterior și menisc, modificărilor artrozice și altor condiții patologice. Modelul a atins o acuratețe de 78,64% și un scor de precizie de 77,28%. Pentru a îmbunătăți performanța clasificării, a fost dezvoltat un model CNN care folosește învățarea prin transfer prin intermediul ResNet-50, îmbunătățind semnificativ acuratețea la 86%, cu o precizie de 94% și un AUC de 0,90. Aceste constatări se aliniază cu literatura raportată anterior, demonstrând robustețea abordării propuse.

În plus, a fost proiectat un model bazat pe LSTM pentru clasificarea rapoartelor de RMN la genunchi, demonstrând o acuratețe, precizie și rechemare ridicate. Când a fost aplicat pe un set de date extern, transferul de învățare a îmbunătățit performanța modelului CNN de la un AUC de 0,77 la 0,85, subliniind importanța seturilor mari de date de antrenament de înaltă calitate în îmbunătățirea caracterului general al modelului DL.

Contribuțiile cheie ale acestei cercetări includ:

## 1. Review complet și Meta-analiză:

- Am efectuat o revizuire sistematică și o meta-analiză a modelelor DL pentru detectarea patologiei genunchiului. Identificat lacune critice, cum ar fi standardizarea seturilor de date, validarea artroscopică și necesitatea studiilor multicentrice.

- Am oferit perspective asupra îmbunătățirii detectării patologiei genunchiului bazate pe inteligență artificială.

## 2. Colectarea și Preprocesarea Setului de Date

- Am creat un set de date de înaltă calitate, cu comentarii, de scanări RMN ale genunchiului de la Spitalul Clinic Județean de Urgență Alba Iulia.
- Am dezvoltat tehnici de preprocesare, inclusiv normalizarea intensității și augmentarea, pentru a îmbunătăți robustețea modelului.

## 3. Dezvoltarea aplicației PreProcMed

- Am creat un instrument inovator pentru preprocesarea rapidă, anonimizarea și conversia scanărilor RMN ale genunchiului în format NIfTI.
- Pregătirea setului de date pentru segmentarea și localizarea rupturii de ligament încrucișat anterior (ACL) și a rupturii meniscale a fost simplificată, reducând efortul pentru cercetători și clinicieni.

## 4. Modele de învățare profundă pentru segmentarea structurii genunchiului

- Am dezvoltat **KneeSAM**, un model de segmentare care atinge un coeficient de similaritate Dice consistent cu literatura existentă.
- Am implementat un model **U-Net**, care a depășit abordările anterioare în segmentarea structurilor genunchiului cu o precizie ridicată.

## 5. Modele bazate pe CNN pentru clasificarea și detectarea leziunilor genunchiului

- Am proiectat un model **multiclass CNN-LSTM**, integrând scanări RMN cu rapoarte de radiologie musculoscheletală pentru clasificarea rupturilor de LIA și menisc.
- Am dezvoltat un model CNN cu învățare prin transfer, îmbunătățind semnificativ acuratețea clasificării și aplicabilitatea clinică.

## **6. Evaluarea Performanței și Optimizarea Modelului**

- Am efectuat evaluări extinse ale arhitecturilor DL și configurațiilor de hiperparametri pentru a optimiza performanța.
- Am implementat strategii pentru a reduce supra învățarea și a îmbunătăți generalizarea modelului pentru setările clinice din lumea reală.

## **7. Perspectiva integrării clinice a inteligenței artificiale**

- Am examinat provocările și oportunitățile integrării modelelor bazate pe inteligență artificială în fluxurile de lucru de diagnostic al afecțiunilor ortopedice.
- Am propus recomandări pentru validarea la scară largă și strategiile de implementare în timp real în mediile clinice.

## **8. Diseminare Științifică și Contribuție la Cunoașterea generala**

- Am prezentat rezultatele la conferințe naționale despre ortopedie și inteligență artificială.
- Am publicat date din cercetare detaliind metodologia, rezultatele experimentale și implicațiile clinice ale detectării leziunilor la genunchi prin inteligență artificială.

Această cercetare doctorală avansează domeniul diagnosticului afecțiunilor ortopedice asistate de IA prin stabilirea unui cadru robust de învățare profundă pentru analiza patologiei genunchiului. Studiul nu doar că oferă noi perspective asupra performanței modelului DL, dar introduce și tehnici noi de preprocesare și instrumente software care îmbunătățesc fiabilitatea modelului și aplicabilitatea clinică. Cercetările viitoare se vor concentra pe rafinarea modelelor de segmentare, extinderea seturilor de date și integrarea cadrelor DL în diagnosticul ortopedic din lumea reală, contribuind în cele din urmă la îmbunătățirea rezultatelor pacienților și la progresul în imagistica musculo-scheletala bazate pe inteligență artificială.