



В. В. Мосіюк, Д. В. Федасюк

Національний університет "Львівська політехніка", м. Львів, Україна

РОЗПІЗНАВАННЯ ПОШКОДЖЕНЬ МЕНІСКА ЗАСОБАМИ ГЛИБИННИХ НЕЙРОННИХ МЕРЕЖ

У контексті сучасних медичних досліджень важливим завданням є підвищення точності діагностики та лікування ушкоджень колінного суглоба, зокрема меніска. Враховуючи обмеження традиційних методів, таких як артроскопія, які часто залежать від досвіду та вмінь хірурга, з'являється потреба в удосконаленні та застосуванні інноваційних технологій. Запропоновано використання глибоких нейронних мереж (ГНМ) для автоматизованого розпізнавання типів пошкоджень меніска під час хірургічних втручань на підставі зображень, отриманих з артроскопічних камер. Розглянуто різні конфігурації архітектури нейронної мережі YOLOv8 – від Nano до Large, що дає змогу адаптувати рішення під конкретні клінічні потреби і обчислювальні ресурси. Використання глибокого навчання в медицині не є новим явищем, проте ця робота вказує на новизну в адаптації потужних алгоритмів до специфічних викликів, пов'язаних із діагностикою стану внутрішньосуглобових структур. Для розроблення ефективної системи діагностики було створено набір даних, який містить анотовані зображення ушкоджень меніска. Цей набір даних було використано для тренування та тестування моделей, що дало можливість проаналізувати і порівняти здатність кожної моделі до узагальнення та точного розпізнавання патологій. Проаналізовано попередні роботи, що розглядають застосування класичних методів глибокого навчання для медичних діагностичних систем. Результати дослідження виявили, що застосування ГНМ демонструє значні переваги у точності та швидкості оброблення медичних зображень. Проте, враховуючи складність і різноманітність пошкоджень меніска, вирішено використати глибокі навчальні моделі для докладного аналізу великих наборів даних. У ході дослідження було розроблено та навчено моделі на підставі глибокого навчання, що дало можливість значно збільшити точність ідентифікації типів ушкоджень. На підставі отриманих даних проведено експериментальні випробування, під час яких моделі, навчені на розширених наборах даних, продемонстрували вищі показники точності класифікації. Ці результати підтверджують потенціал використання глибокого навчання для поліпшення діагностичних можливостей в медицині. Дослідження може стати важливим внеском у подальше удосконалення технологій в області медичної діагностики, зокрема в покращення ефективності хірургічних втручань та забезпечення високої точності діагностики в режимі реального часу. Це відкриває нові можливості для подальшої роботи в напрямі інтеграції глибокого навчання в клінічну практику, сприяючи ефективному та безпечному лікуванню пацієнтів.

Ключові слова: машинне навчання; згорткові нейронні мережі; комп'ютерний зір; артроскопія; комп'ютерна діагностика; пошкодження меніска.

Вступ / Introduction

Згідно з визначенням [11], меніск (англ. *Meniscus*) – важлива складова колінного суглоба, яка виконує функцію амортизації та стабілізації, що дає змогу забезпечувати рухливість і зменшувати тиск між стегновою та гомілковою кістками. Пошкодження меніска часто виникає у спортсменів, які займаються контактними видами спорту, такими як футбол, баскетбол чи боротьба, а також у людей, чия професійна діяльність потребує інтенсивного фізичного навантаження на коліна. Поширеність цієї травми вимагає ефективних методів діагностики та лікування.

Традиційне лікування пошкодження меніска містить

консервативні методи, такі як фізіотерапія, використання ортезів та протизапальних препаратів, і, у випадках більш серйозних ушкоджень, хірургічне втручання. Ендоскопічна хірургія, особливо артроскопія, є "золотим" стандартом для лікування значних ушкоджень меніска. Ця малоінвазивна процедура дає змогу хірургу оглянути внутрішній стан суглоба через невеликі розрізи за допомогою артроскопа, що забезпечує точність і мінімізує пошкодження окільних тканин [2].

Удосконалення глибоких нейронних мереж відкриває нові можливості не тільки у покращенні діагностики пошкоджень меніска за допомогою аналізу МРТ-зображень [7], але й у ширшому контексті. Ці технології може бути використано для автоматичного розпізна-

Інформація про авторів:

Мосіюк Василь Володимирович, магістр, аспірант, кафедра програмного забезпечення.

Email: vasyl.v.mosiiuk@lpnu.ua; <https://orcid.org/0009-0000-2009-3951>

Федасюк Дмитро Васильович, д-р техн. наук, професор, завідувач кафедри програмного забезпечення.

Email: dmytro.v.fedasyuk@lpnu.ua; <https://orcid.org/0000-0003-3552-7454>

Цитування за ДСТУ: Мосіюк В. В., Федасюк Д. В. Розпізнавання пошкоджень меніска засобами глибоких нейронних мереж.

Науковий вісник НЛТУ України. 2024, т. 34, № 4. С. 41–48.

Citation APA: Mosiiuk, V. V., & Fedasyuk, D. V. (2024). Meniscus tears recognition by deep neural networks. *Scientific Bulletin of UNFU*, 34(4), 41–48. <https://doi.org/10.36930/40340406>

вання та класифікації типів ушкоджень на підставі різних видів діагностичних даних, у т.ч. рентгенівські знімки та комп'ютерну томографію. Застосування глибоких нейронних мереж дає змогу не тільки підвищити точність ідентифікації патологічних змін у меніску, але й значно скорочує час оброблення медичних зображень, що є критично важливим у швидкісному клінічному середовищі. Отже, інтеграція цих технологій може істотно покращити якість і швидкість медичного обслуговування, що отримують пацієнти з пошкодженнями меніска.

У межах цього дослідження було також використано глибоку нейронну мережу для розпізнавання пошкоджень меніска на зображеннях, отриманих із відеопотоку камери артроскопу під час хірургічних втручань. Артроскопія дає змогу лікарям здійснювати діагностику та лікування ушкоджень всередині суглобів через невеликі розрізи. Артроскоп – це тонкий трубчастий інструмент, який оснащений світлодіодом та відеокамерою, що передає високоякісні зображення внутрішньо-суглобових структур на монітор у реальному часі. Це дає змогу хірургам виконувати точні маніпуляції, мінімізуючи травматизацію тканин та сприяючи швидшому відновленню пацієнтів. Використання глибоких нейронних мереж для аналізу відеопотоку з артроскопа дає змогу автоматизувати процес розпізнавання типових і атипичних патологічних змін, забезпечуючи хірургам додаткову інформацію для ефективнішого лікування.

Постановка завдання дослідження – навчання нейронних мереж для розпізнавання пошкоджень меніска, їх тестування та валідація отриманих результатів.

Об'єкт дослідження – розпізнавання пошкоджень меніска на зображеннях, отриманих з відеопотоку артроскопічних камер.

Предмет дослідження – алгоритми та методи тренування, тестування та валідації глибоких нейронних мереж, що дасть змогу підвищити результативність оперативних втручань під час лікування пошкоджень меніска та зменшити вплив людського чинника у процес, що дасть змогу підвищити точність діагностики та лікування ушкоджень колінного суглоба, насамперед меніска.

Мета роботи – натренувати моделі глибокого навчання YOLOv8 різних конфігурацій у завданні розпізнавання пошкоджень меніска на зображеннях, отриманих з відеопотоку артроскопічних камер під час хірургічних операцій, та проаналізувати результати їх роботи.

Для досягнення зазначеної мети визначено такі основні завдання дослідження:

1. Провести аналіз сучасних методів застосування глибоких нейронних мереж (ГНМ) для діагностики пошкоджень меніска, що дасть змогу покращити точність та швидкість діагностики, знизити його вартість та зменшити навантаження на медичних фахівців;
2. Створити набір даних, що містить анотовані зображення пошкоджень меніска, який допоможе використати нейронні мережі для розпізнавання таких об'єктів;
3. Адаптувати моделі YOLOv8 різних конфігурацій (від Nano до Large) для розпізнавання ділянок з пошкодженнями меніска, що дасть змогу порівняти показники цих моделей і обрати конфігурацію, яка найкраще відповідає потребам програмно-апаратного забезпечення та забезпечує отримання відповідних результатів у реальних умовах клінічного застосування;
4. Провести оцінку та здійснити порівняння ефективності тренуваних моделей різних конфігурацій, що забезпе-

чить розуміння їхньої продуктивності у різних сценаріях застосування. Це дасть змогу визначити, яка модель найкраще надається для специфічних клінічних умов, беручи до уваги не тільки точність, але й швидкість оброблення медичних даних, вимоги до обчислювальних ресурсів і сумісність із медичним обладнанням.

Аналіз останніх досліджень та публікацій. Глибоке навчання DL (англ. *Deep Learning*) є революційним напрямком у машинному навчанні, який використовує моделі глибоких нейронних мереж DNN (англ. *Deep Neural Networks*) для аналізу великих обсягів даних. Ця передова технологія набула широкого застосування в медицині, особливо в обробленні медичних зображень, де вона допомагає ідентифікувати складні патологічні зміни. Конволюційні нейронні мережі CNN (англ. *Convolutional neural networks*), як ключовий елемент DL, виявилися особливо цінними для діагностики різних захворювань завдяки їх здатності ефективно обробляти візуальні дані та вловлювати просторові ієрархії характеристик.

Підхід до виявлення об'єктів з використанням мережі на архітектурі піраміди ознак FPN (англ. *Feature Pyramid Network*), представлений у роботі [7], значно покращує точність розпізнавання об'єктів в різних масштабах. Автори створили багаторівневу архітектуру, де кожен рівень піраміди використовується для виявлення об'єктів різних розмірів. Результати показують, що такий підхід не тільки покращує здатність системи до локалізації об'єктів, але й ефективно збільшує її здатність до класифікації.

Дослідження [1, 12, 17] відображають зростаючу роль штучного інтелекту у медицині та особливо у використанні глибокого навчання для оброблення й аналізу медичних зображень. Завдяки своїй здатності до оброблення великих обсягів даних і виявлення складних залежностей, глибоке навчання стає незамінним інструментом у боротьбі з глобальними викликами в охороні здоров'я.

Аналіз використання глибокого навчання для виявлення раку гортані в реальному часі за допомогою відеоларингоскопії, який виконали автори роботи [1], демонструє, як моделі конволюційних нейронних мереж можуть бути навчені розрізняти нормальні та патологічні тканини на зображеннях гортані, забезпечуючи потенціал для раннього виявлення раку. Модель показала високу точність у класифікації та виявленні ракових змін, що вказує на обіцянку застосування цієї технології у клінічній практиці для поліпшення діагностичних можливостей і спрощення процесу виявлення раку гортані в реальному часі.

У публікації [17] проаналізовано використання глибокого навчання для оброблення медичних зображень у контексті COVID-19. Дослідження демонструє, як штучний інтелект може сприяти швидкому аналізу зображень рентгенівських знімків грудної клітини, виявляючи типові пневмонічні ознаки, пов'язані з вірусом. Результати вказують на високу точність моделей у класифікації знімків, що може значно спростити процес діагностики та моніторингу хворих на COVID-19.

У роботі [12] розглянуто використання методів глибокого навчання для автоматичної сегментації раку порожнини рота та орофарингіального раку. Результати показують, що модель здатна ефективно ідентифікувати та сегментувати патологічні тканини на зображен-

нях, отриманих за допомогою вузькосмугової візуалізації, що відкриває нові можливості для точнішої діагностики та вдосконалення лікувальних стратегій.

Дослідження [16] зосереджене на оцінюванні різних архітектур конволюційних нейронних мереж, таких як YOLO, SSD та Faster R-CNN, з метою визначення їхньої ефективності у різних сценаріях виявлення об'єктів. Основними критеріями є точність детекції, швидкість оброблення медичних даних, обчислювальні ресурси та загальність алгоритму.

Завдяки алгоритмам глибокого навчання стало можливим швидко виявляти і локалізувати об'єкти на зображеннях, що дає змогу медичним фахівцям ефективно використовувати цю інформацію для діагностики та лікування. Наприклад, в дослідженні [8] мережу YOLO було використано для аналізу зображень ультразвуку з метою виявлення патологій у реальному часі, значно підвищуючи точність діагностики порівняно з традиційними методами.

Удосконалення технологій глибокого навчання також сприяє покращенню систем автоматичного водіння. Алгоритми глибокого навчання можна використовувати для точного і швидкого виявлення пішоходів, транспортних засобів та перешкод на дорозі, що допомагає забезпечити безпечніше і більш ефективне автоматичне водіння [5]. Такі системи здатні швидко обробляти великі обсяги візуальної інформації, виявляючи об'єкти та їхні параметри в реальному часі, що важливо для адаптації до складних дорожніх умов.

У сфері відеоспостереження глибоке навчання використовується для аналізу відеопотоків з метою ідентифікації аномальних подій або небезпечних ситуацій. Системи, засновані на глибокому навчанні, можуть ефективно відслідковувати динамічні зміни у відеопотоках, швидко реагуючи на потенційні загрози, що забезпечує вищий рівень безпеки в громадських місцях або на промислових об'єктах. Глибоке навчання має велике значення не тільки для розширення можливостей наявних технологій, але і для удосконалення нових методів оброблення медичних даних [3]. Ця технологія дає змогу створювати складні моделі, здатні самостійно адаптуватися та оптимізувати свою продуктивність відповідно до змін у вхідних даних. Така можливість самонавчання і адаптації відкриває нові перспективи для використання глибокого навчання у різноманітних сферах, від медицини до автоматичного водіння та від систем безпеки до розумних міст [4].

Сучасні дослідження [4, 15] показують, що глибоке навчання може відігравати ключову роль у виявленні та класифікації медичних станів за допомогою штучних нейронних мереж, таких як YOLO (англ. *You Only Look Once*), що демонструють високу швидкість і точність у визначенні об'єктів на медичних зображеннях, що має важливе значення для медичної діагностики.

Результати дослідження та їх обговорення / Research results and their discussion

Моделювання процесу розпізнавання пошкодження на кадрах з відеопотоку. На рис. 1 відображено схему процесу розпізнавання пошкодження меніска у відеопотоці, яка використовує глибоку нейронну мережу.

Процес розділений на дві основні частини, а також лінійний етап застосування натренованої моделі над попередньо опрацьованими зображеннями з кадрів відеопотоку. Алгоритм:

- Опрацювання зображень набору даних містить:
 - фільтрацію зображень: відбираються тільки ті зображення, що містять потрібні класи (пошкодження меніска у цьому випадку);
 - трансформації зображень: застосування різних трансформацій до зображень, таких як зміна кута нахилу, обертання, віддзеркалення, додавання шуму тощо, для збільшення різноманітності даних;
 - розподіл на набори: поділ даних на тренувальні, валідаційні та тестові набори для подальшого навчання моделі.
- Попереднє опрацювання відеопотоку містить:
 - поділ на кадри: відеопотік поділяють на окремі кадри;
 - корекцію розміру та кольору: вносяться зміни у розмір і кольорову палітру кадрів для підготовки до їх оброблення;
 - фільтрацію: застосування різних методів фільтрації, таких як згладжування, для покращення якості кадрів та зменшення кількості шуму на зображенні.
- Тренування моделі машинного навчання ML (англ. *Machine Learning*): використання тренувальних даних для навчання моделі глибокого навчання.
- Розпізнавання пошкодження меніска: застосування натренованої моделі до попередньо опрацьованих кадрів для ідентифікації можливих пошкоджень меніска.
- Результати: виведення результатів розпізнавання.



Рис. 1. Схема алгоритму розпізнавання пошкодження меніска у відеопотоці, що використовує глибоку нейронну мережу / The diagram of the algorithm for recognizing meniscus tears in a video stream using a deep neural network

Система, побудована на алгоритмі зі схеми (див. рис. 1), здатна надавати хірургу інформацію про розміщення потенційно уражених ділянок меніска, отримуючи відеопотік з камери артроскопа в ході проведення операції, потенційно зменшуючи вплив людського чиннику на хірургічний процес.

Підготовка набору даних. Навчання моделі нейронної мережі розпочинають зі збирання набору даних, який складається з великої кількості анотованих зображень. Анотація зображень передбачає позначення на зображеннях розташування та характеристик пошкодження меніска, що дає змогу моделі навчатися розпізнавати та класифікувати ці об'єкти на нових зображеннях.

Підготовка даних містить поділ зібраного набору даних на тренувальний і валідаційний набори. Тренувальний набір використовують для безпосереднього навчання моделі, водночас як валідаційний набір дає змогу перевірити модель на переносимість (англ. *Model Generalization*), як здатності моделі ефективно працювати з новими, раніше невидимими даними, яких не використовували під час її тренування. Це ключова особливість, оскільки показує, наскільки добре модель можна застосовувати до реальних ситуацій або різних сценаріїв використання, які можуть відрізнятися від умов, у яких вона була навчена.

Було створено спеціалізований набір даних, який складався з 500 зображень, отриманих із кадрів відеоматеріалів проведених операцій з менісектомії. Ці зображення містили різноманітні приклади пошкоджень меніска, що давало змогу покрити широкий спектр клінічних випадків. Кожне зображення було проанотоване, визначаючи точні ділянки, де розташовані пошкодження, що забезпечувало високу точність навчання моделі. З усього набору 33 зображення було виділено для валідаційного набору даних, додатково, 18 зображень було виокремлено для тестового набору. Використання цих окремих наборів даних дає змогу забезпечити об'єктивну оцінку продуктивності та переносимості моделі в клінічних умовах.

Переносимість є критичною для моделей машинного навчання, оскільки вона вказує на їх практичну придатність. Модель, яка показує високу точність на тренувальних даних, але погано справляється з тестовими або реальними даними, може мати проблеми з перенавчанням (*overfitting*). Перенавчання відбувається, коли модель занадто точно адаптується до тренувального набору даних, у т.ч. шум і випадковості, що не відображають загальних закономірностей, які можна застосувати до нових даних.

Тестування моделі проводять за допомогою тестового набору даних, який складається з зображень, не використаних під час тренування. Цей етап має за мету оцінити здатність моделі до узагальнення своїх навчальних здобутків на нових даних, що відображають реальні умови використання. Завдяки тестовому набору можна об'єктивно оцінити продуктивність моделі поза контекстом навчання, що допомагає виявити можливі проблеми з точністю або переносимістю перед клінічним застосуванням.

Валідація моделі є остаточним кроком, де модель піддається ретельному аналізу з використанням різних метрик якості, таких як точність (*accuracy*), чутливість (*sensitivity*), специфічність (*specificity*) і інші. Цей етап дає змогу переконатися, що модель не тільки відповідає технічним вимогам, але й відповідає клінічним стандартам ефективності. Валідація важлива для забезпечення довіри лікарів і пацієнтів до нової технології, а також для вирішення будь-яких регулятивних вимог перед впровадженням технології в медичну практику. Валідація зазвичай містить залучення клінічних експертів, які можуть оцінити клінічну релевантність та корисність результатів, які надає система.

Процес тренування моделі глибинного навчання.

Було виконано навчання моделей для мереж різного розміру: YOLOv8 Nano, YOLOv8 Small, YOLOv8 Medium, та YOLOv8 Large. Це зроблено з метою створення моделей, які можуть бути ефективно застосовані з апа-

ратним забезпеченням різної продуктивності. Малі моделі, як YOLOv8 Nano та Small, призначені для використання за умови обмежених обчислювальних ресурсів, наприклад, на мобільних пристроях або вбудованих системах. Навпаки, більші моделі, як YOLOv8 Medium та Large, можна застосувати для досягнення вищої точності в середовищах з достатніми обчислювальними ресурсами, таких як серверні системи або спеціалізоване медичне обладнання.

Тренування також має за мету порівняння результатів, які кожна з моделей надає, для визначення найбільш оптимальної конфігурації з урахуванням балансу між точністю та обчислювальною вартістю. Внаслідок такого порівняння можна обрати найбільш придатну модель, яка забезпечує найкращу продуктивність за заданих обмежень апаратного забезпечення. Такий підхід дає змогу досягнути максимальної ефективності використання ресурсів, одночасно забезпечуючи високий рівень точності і надійності в розпізнаванні пошкоджень меніска.

Для процесу тренування було написано виконуваний файл команд (рис. 2.), за допомогою якого програмний засіб бібліотеки Ultralytics YOLO CLI виконав процес навчання моделей на базі мереж різної конфігурації, використавши попередньо створений набір даних.

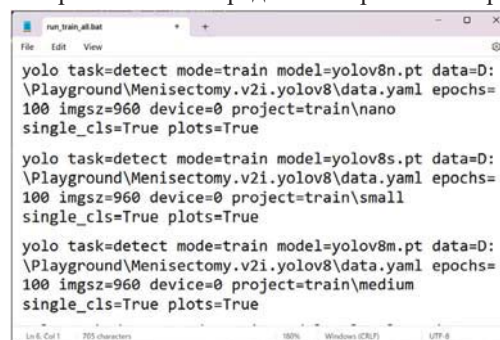


Рис. 2. Фрагмент коду, використаний для процесу навчання моделей / Code snippet, used for the models training process

Було вказано такі параметри, як кількість епох (*epochs*), розмір зображення для розпізнавання (*imgsz*) та те, що остаточна модель буде монокласовою – розпізнаватиме тільки один клас об'єктів (*single_cls*).

Епоха у тренуванні глибинних нейронних мереж визначається як один повний прохід усього набору даних через навчальний алгоритм, де модель вчиться розпізнавати закономірності, адаптуючи свої ваги для зменшення помилок. Кількість епох під тривалість навчання зазвичай впливає на здатність моделі до генералізації; занадто мала кількість може призвести до недонавчання, а занадто велика – до перенавчання. Тому часто використовують такі методи, як раннє припинення, для оптимізації кількості епох з метою підвищення ефективності і уникнення зайвих обчислень.

Тривалість навчання глибинних нейронних мереж зазвичай залежить від їхньої розмірності, яка впливає на кількість параметрів та обчислювальну складність моделі. Для лабораторної конфігурації системи, яка містить CPU Intel Xeon E5-2670 v3 з 12 ядрами та 24 потоками, 64GB оперативної пам'яті та графічним процесором Nvidia GTX1080Ti з 11 GB відеопам'яті, було проведено тренування мереж різного розміру: Nano, Small, Medium та Large. Ці тренування показали залежність часу навчання від розмірності мереж, які викладено у таблиці. Згідно з отриманими замірами, дійшли виснов-

ку, що складність мережі має прямий вплив на часові та ресурсні витрати. Чим більша кількість параметрів мережі, тим більше часу та більше пам'яті потрібно для її тренування. Це також збільшує розмір остаточної моделі, що водночас веде до збільшення обчислювальних витрат, що може бути критичним для обмежених або ресурсоощадних середовищ.

Таблиця. Статистика тренування мереж YOLOv8 різної конфігурації / Training statistics of YOLOv8 networks of different configurations

Мережа YOLOv8	Конфігурація: шарів / параметри	Тривалість епохи тренування		Об'єм пам'яті для тренування, GB	Фінальний розмір моделі, MB
		середня, с	загальна, хв		
Nano	$\frac{225}{3\ 011\ 043}$	8	15	4,5	6,3
Small	$\frac{225}{11\ 135\ 987}$	15	30	8	22,
Medium	$\frac{295}{25\ 856\ 899}$	300	550	14	52,1
Large	$\frac{365}{43\ 630\ 611}$	1200	2000	21	83,6

У процесі навчання всі мережі пройшли через 100 епох і зведені графіки зміни ключових метрик мереж різного розміру відносно кількості пройдених епох такі, як точність, повнота та загальна середня точність.

Точність (англ. *Precision*) вимірює частку правильно ідентифікованих об'єктів серед тих, які модель класифікувала як позитивні. Висока точність вказує на те, що модель рідко помиляється, коли визначає об'єкт як позитивний.




Рис. 3. Графік зміни точності (а), повноти (б) та загальної середньої точності (с) за умови зростання кількості епох навчання для мереж різного розміру / Graph of the change in precision (a), recall (b) and the mean average accuracy (c) with the increase in the number of training epochs for networks of different sizes

За графіком (рис. 3,а) можна побачити, що точність збільшується з часом для всіх моделей, однак різні вер-

сії мають різну динаміку покращення. Мережа Nano починає з приблизно 0.2 точності і досягає близько 0.6, показуючи значне покращення. Мережі Small та Medium також показують стабільне зростання з початкових значень трохи вище 0.2 до приблизно 0.65 і 0.7 відповідно. Водночас, модель Large, показує дещо гіршу динаміку, досягаючи 0.65. Зазвичай, це може вказувати на потенційні проблеми з перенавчанням моделі або недостатньою ефективністю великої моделі для даного обсягу тренувальних даних, особливо якщо врахувати, що більші моделі зазвичай потребують більшого та різноманітнішого набору даних для оптимальної продуктивності.

Повнота (англ. *Recall*) показує, яка частка всіх дійсно позитивних об'єктів була коректно ідентифікована моделлю. Це стосується застосувань, де важливо не пропустити жодного позитивного випадку.

Усі моделі демонструють позитивну динаміку збільшення повноти (рис. 3,б), що вказує на їхню здатність ефективніше ідентифікувати релевантні об'єкти з часом. Модель Nano, яка починає з нижчих показників повноти близько 0.1, досягає значного покращення, зростаючи до приблизно 0.5. Мережа Small, стартуючи з повноти близько 0.2, підвищує свої показники до приблизно 0.55, тоді як Medium, починаючи з 0.25, також досягає стабільного зростання до 0.6. Це вказує на те, що навіть менші моделі можуть бути ефективними у задачах, які потребують високої повноти детекції, залежно від властивостей і обсягу даних, на яких вони тренують.

Загальна середня точність mAP (англ. *mean Average Precision*) є стандартною метрикою для завдань об'єктного виявлення, яка враховує точність і повноту за всіма класами і на різних рівнях порогу визначення. Це дає уявлення про загальну продуктивність моделі.

За графіком (рис. 3,с), мережа Nano починає з нижчих значень mAP близько 0,1 і з часом значно покращується, досягаючи приблизно 0,5. Мережа Small, починаючи з приблизно 0,15 mAP, також показує вражаюче поліпшення, зростаючи до позначки 0,55. Водночас, Medium стартує з mAP близько 0,2 і з часом стабілізується на рівні приблизно 0,6. Ці показники свідчать про здатність навіть менших моделей досягати високих рівнів точності, зокрема за достатньої кількості тренувань, що є корисним у сценаріях з обмеженими обчислювальними ресурсами.

Ця тенденція вказує на потенціал менших моделей для досягнення порівнянної точності з більшими моделями, що робить їх привабливим вибором для застосувань, де швидкість оброблення медичних даних та ефективність ресурсів мають вирішальне значення.

Отже, аналіз графіків зміни показників для отриманих моделей в ході навчання підтверджує, що зі збільшенням кількості епох тренування всі моделі показують позитивний тренд у зростанні показників точності та повноти. Це свідчить про покращення їх здатності ефективно ідентифікувати і класифікувати об'єкти з меншою кількістю помилок. Водночас, більші моделі зазвичай стартують з вищих показників, але менші моделі демонструють значний прогрес, що робить їх вигідним вибором для сценаріїв з обмеженими ресурсами. Вибір оптимальної моделі залежить від специфічних потреб застосування, обсягу доступних даних і вимог до швидкості оброблення медичних даних.

Аналіз отриманих результатів дослідження. Точність є ключовою для застосувань, де помилки можуть мати вагомні наслідки у медичній діагностиці або системах безпеки. Швидкість оброблення медичних даних важлива для реалізації систем реального часу, наприклад, у відеоспостереженні чи автономному водінні, де затримки у виявленні об'єктів можуть призвести до негативних наслідків. Ефективне використання обчислювальних ресурсів критично важливе для застосувань з обмеженими апаратними можливостями, як у мобільних пристроях або пристроях з обмеженими ресурсами. Нарешті, загальність дає змогу алгоритму легко адаптуватися до різних умов та типів даних, що робить його ідеальним для різноманітних застосувань без потреби істотного перенавчання.

За результатами порівняльного аналізу, автори наголошують на важливості ретельного вибору алгоритмів на підставі цих критеріїв, враховуючи конкретні потреби та обмеження завдання. Вибір відповідного алгоритму може значно покращити результати виявлення об'єктів і ефективність систем оброблення зображень у реальному світі.

Подальші удосконалення та дослідження у сфері глибокого навчання безперечно принесуть нові відкриття і покращення у багатьох сферах застосування. Завдяки своїй здатності до оброблення великих масивів даних і виявлення складних залежностей, глибоке навчання стає незамінним інструментом у боротьбі з глобальними викликами, зокрема у сфері здоров'я, безпеки та екології.

Далі наведено результати перевірки отриманих моделей на тестовому зображенні та візуальне відображення зон, виділених моделлю, як потенційно пошкоджених ділянок меніска. Це дає змогу оцінити, наскільки точно моделі виявили та локалізували ушкоджені ділянки порівняно з очікуваними зонами, які були визначені в процесі підготовки набору даних вручну.

На зображенні (рис. 4,а) показано ділянку колінного суглоба під час артроскопії. Присутній робочий інструмент, який зазвичай використовується для діагностики або втручання. Виділено прямокутниками дві зони, де меніск коліна має пошкодження. Ці області меніска виглядають як місця з тканинними розривами або ушкодженнями.




Рис. 4.а. Тестове зображення з промаркованими областями з пошкодженнями / Test image with marked areas with tears (a); результати розпізнавання пошкоджень меніска на тестовому зображенні моделлю / Results of meniscus tears recognition on the test image by the model: YOLOv8 Nano (b); YOLOv8 Small (c); YOLOv8 Medium (d); YOLOv8 Large (e, f);

На зображенні (рис. 4,б), отриманому від моделі YOLOv8 Nano, виокремлено три зони зі значенням впевненості моделі у пошкодженні меніска (0.4, 0.6, і 0.8). Якщо порівнювати це з тестовим зображенням, можна дійти висновку, що модель точно виділила ділянки, які й очікувалось, що дає змогу визнати її ефективною для виконання завдання за умови обмежених обчислювальних ресурсів.

На зображенні (рис. 4,с) отриманому від моделі YOLOv8 Small, виявлено дві зони зі значенням впевненості у пошкодженні меніска (0.8, 0.9), показуючи високу точність. Водночас, модель YOLOv8 Medium (рис. 4,д),

виявила три зони зі значенням впевненості (0.3, 0.4, 0.7), що свідчить про меншу точність. Причини гірших результатів можуть бути пов'язані з перенавчанням чи недостатністю даних для навчання більшої моделі, або з особливостями даних, які можуть включати шуми, прийняті за реальні особливості, що ускладнює роботу моделі.

Модель YOLOv8 Large (рис. 4,е,ф) виявила три зони з упевненістю в пошкодженні меніска на рівнях 0.3, 0.3 і 0.4, що є низькими значеннями порівняно з іншими моделями. Це може вказувати на проблеми з точністю виявлення реальних ушкоджень. Подібно до моделі

YOLOv8 Medium, ці результати можуть бути зумовлені перенавчанням, де модель ідеально працює на тренувальних даних, але погано адаптується до нових даних, а також іншими чинниками, які чинять більш істотний вплив на моделі з великою кількістю параметрів.

Додаткові кроки з адаптації зображень перед розпізнаванням (крок попереднє опрацювання зображень), наприклад видалення шумів, чи корекція кольору-тону, а також більш тонке налаштування параметрів мережі очікувано мають покращити результати мереж Medium та Large.

Також візуальний аналіз графічних зображень дає змогу прийняти до уваги те, що результати роботи моделі достатньою мірою можуть бути ефективним джерелом допоміжної інформації для хірурга, де остаточне рішення щодо пошкодження все ж таки буде за ним, а надана інформація тільки доповнює відеореєстр.

Обговорення результатів дослідження. З огляду на те, що предмет дослідження є новим, немає відповідних досліджень, які використовують нейронні мережі для розпізнавання пошкоджень меніска на зображеннях з артроскопа під час проведення операції. Зазвичай наявні дослідження сконцентровані на неінвазивних практиках діагностики, таких як МРТ-знімки колінного суглоба і на аналізі цих знімків засобами штучних нейронних мереж з метою розпізнавання потенційно уражених ділянок меніска. Підхід до аналізу зображень, які надходять під час проведення операції є новим, тому що передусім стосується процесу асистування хірургу, коли програмна система на базі моделі глибокого навчання надає контекстну інформацію виконавцю і тим зменшує можливість пропустити потенційно уражені ділянки через людський чинник.

Наприклад, автори роботи [6], які використали маскову регіональну конволюційну нейронну мережу Mask R-CNN (англ. *Mask Region-based Convolutional Neural Network*) для виявлення і діагностики розривів меніска на МРТ знімках, підтверджують величезний потенціал глибокого навчання у медичній діагностиці. Це дослідження продемонструвало, що після тренування та валідації, модель ефективно розпізнавала здорові та пошкоджені меніски, демонструючи середню точність для трьох типів менісків (здорові, порвані та дегенеративні) від 68 до 80 %.

У дослідженні [13] було розроблено нейронну мережу, яка автоматично ідентифікувала і класифікувала стани меніска на знімках МРТ. Модель проходила навчання та валідацію на обширному наборі даних, що містив зображення здорових і ушкоджених менісків. Результати експерименту демонструють високий рівень точності моделі у виявленні розривів, знижуючи при цьому ймовірність людської помилки та підвищуючи ефективність діагностичного процесу. Це дослідження відкриває нові перспективи застосування штучного інтелекту у клінічних діагностичних методиках, сприяючи більш швидкому та точному визначенню потреб пацієнтів у подальшому лікуванні або оперативному втручанні.

У межах дослідження [14] автори розробили модель конволюційної нейронної мережі для діагностики розривів меніска. Модель була навчена та перевірена на значній кількості даних з МРТ, показавши високий рівень точності у виявленні та класифікації різних типів розривів меніска. Результати підтвердили потенціал

застосування глибокого навчання в клінічній практиці, зокрема для підтримки ортопедів і радіологів у швидкому та точному діагностуванні ушкоджень меніска.

У дослідженні [10], у якому використали візуальну каскадно-прогресуючу конволюційну нейронну мережу C-PCNN (англ. *Cascaded-Progressive Convolutional Neural Network*), автори демонструють, як глибоке навчання можна використовувати для точного визначення локації та типу розривів меніска, підвищуючи можливість діагностики та лікування.

У роботі [9] автори досліджували особливості використання візуально інтерпретованих моделей МРТ для тонкого градування пошкоджень меніска, що дало їм змогу розробити інтелектуальну систему підтримки діагностики та лікування. Ця робота вказує на здатність глибокого навчання не тільки точно ідентифікувати травми, але й допомагати медичним фахівцям у прийнятті обґрунтованих рішень, забезпечуючи більш високий рівень персоналізованого лікування.

Отже, за результатами виконаної роботи можна сформулювати такі наукову новизну та практичну значущість результатів дослідження.

Наукова новизна отриманих результатів дослідження – розроблено метод аналізу результатів роботи моделі глибокого навчання на базі нейронної мережі YOLOv8, що дає змогу розпізнавати пошкодження меніска на зображеннях з артроскопічних камер під час проведення операцій.

Практична значущість результатів дослідження – результати дослідження можна застосувати під час розроблення систем комп'ютерного асистування для хірургів і в навчальних середовищах як джерело контекстних даних щодо розпізнаних ділянок пошкоджень для доповнення відеореєстру з камер артроскопа.

Висновки / Conclusions

На підставі проведеного дослідження було натреновано моделі глибокого навчання YOLOv8 різних конфігурацій в завданні розпізнавання пошкоджень меніска на зображеннях, отриманих з відеопотоку артроскопічних камер під час хірургічних операцій, та проаналізовано результати їх роботи. За результатами проведеного дослідження можна зробити такі основні висновки.

1. Проаналізовано сучасні методики використання глибоких нейронних мереж у медичних діагностичних системах, зокрема для діагностики станів внутрішньосуглобових структур. Глибокі нейронні мережі продемонстрували високу точність у розпізнаванні та класифікації пошкоджень на артроскопічних зображеннях.
2. Сформовано та вручну проанотовано набір даних з 500 артроскопічних зображень, який було використано для тренування та тестування моделей.
3. Навчено адаптовані моделі YOLOv8, які показали здатність точно розпізнавати ділянки з пошкодженнями меніска. Це дає змогу значно підвищити ефективність діагностичних процедур, мінімізуючи вплив людського чинника.
4. Підтверджено ефективність використання глибоких нейронних мереж для задач, пов'язаних з медичною візуалізацією і діагностикою, що відкриває перспективи для подальшого удосконалення та застосування цих технологій у клінічній практиці.

Виконане дослідження може стати значним внеском у модернізацію медичних діагностичних технологій, зокрема у вдосконалення хірургічних втручань та забезпечення високої точності діагностики в режимі реаль-

ного часу, зменшити вплив людського чиннику, забезпечуючи хірургам важливу інформацію в реальному часі, сприяючи ефективнішому та безпечнішому лікуванню пацієнтів. Результати, отримані в ході дослідження, можна використати для порівняння з іншими моделями нейронних мереж.

References

1. Azam, M. A., Sampieri, C., Ioppi, A., Africano, S., Vallin, A., Mocellin, D., Fragale, M., Guastini, L., Moccia, S., Piazza, C., Mattos, L. S., & Peretti, G. (2022). Deep Learning Applied to White Light and Narrow Band Imaging Videolaryngoscopy: Toward Real-Time Laryngeal Cancer Detection. *The Laryngoscope*, Vol. 132, pp. 1798–1806. <https://doi.org/10.1002/lary.29960>
2. Chambers, H. G. M. D., & Chambers, R. C. D. O. (2019). The Natural History of Meniscus Tears. *Journal of Pediatric Orthopaedics*, Vol. 39, pp. S53–S55. <https://doi.org/10.1097/BPO.0000000000001386>
3. Cong, X., Li, S., Chen, F., Liu, C., & Meng, Y. (2023). A Review of YOLO Object Detection Algorithms based on Deep Learning. *Frontiers in Computing and Intelligent Systems*, Vol. 4(2), pp. 17–20. <https://doi.org/10.54097/fcis.v4i2.9730>
4. Diwan, T., Anirudh, G., & Tembume, J. V. (2023). Object detection using YOLO: challenges, architectural successors, datasets and applications. *Multimedia Tools and Applications*, Vol. 82, pp. 9243–9275. <https://doi.org/10.1007/s11042-022-13644-y>
5. Lavanya, G., & Pande, S. D. (2023). Enhancing Real-time Object Detection with YOLO Algorithm. *EAI Endorsed Transactions on Internet of Things*, Vol. 10. <https://doi.org/10.4108/eetiot.4541>
6. Li, J., Qian, K., Liu, J., Huang, Z., Zhang, Y., Zhao, G., Wang, H., & Li, M. (2022). Identification and diagnosis of meniscus tear by magnetic resonance imaging using a deep learning model. *Journal of Orthopaedic Translation*, Vol. 34, pp. 91–101. <https://doi.org/10.1016/j.jot.2022.05.006>
7. Lin, T.-Y., Dollár, P., Girshick, R., He, K., Hariharan, B., & Belongie, S. (2017). Feature Pyramid Networks for Object Detection, 2017 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Honolulu, HI, USA, pp. 936–944. <https://doi.org/10.1109/CVPR.2017.106>
8. Liu, C., Tao, Y., Liang, J., Li, K., & Chen, Y. (2018). Object Detection Based on YOLO Network, 2018 *IEEE 4th Information Technology and Mechatronics Engineering Conference (ITOEC)*, Chongqing, China, pp. 799–803. <https://doi.org/10.1109/ITOEC.2018.8740604>
9. Luo, A., Gou, S., & Tong, N. (2024). Visual interpretable MRI fine grading of meniscus injury for intelligent assisted diagnosis and treatment. *npj Digital Medicine*, Vol. 7, 97. <https://doi.org/10.1038/s41746-024-01082-z>
10. Ma, Y., Qin, Y., Liang, C., Li, X., Li, M., Wang, R., Yu, J., Xu, X., Lv, S., & Luo, H. (2023). Visual Cascaded-Progressive Convolutional Neural Network (C-PCNN) for Diagnosis of Meniscus Injury. *Diagnostics*, Vol. 13(12), Article ID 2049. <https://doi.org/10.3390/diagnostics13122049>
11. Markes, A. R., Hodax, J. D., & Chunbong, B. Ma. (2020). Meniscus Form and Function. *Clinics in Sports Medicine*, Vol. 39, pp. 1–12. <https://doi.org/10.1016/j.csm.2019.08.007>
12. Paderno, A., Piazza, C., Del Bon, F., Lancini, D., Tanagli, S., Deganello, A., Peretti, G., & De Momi, E. (2021). Deep Learning for Automatic Segmentation of Oral and Oropharyngeal Cancer Using Narrow Band Imaging: Preliminary Experience in a Clinical Perspective. *Frontiers in Oncology*, Vol. 11, 32–26. <https://doi.org/10.3389/fonc.2021.626602>
13. Roblot, V., Giret, Y., Antoun, M. B., Morillot, C., Chassin, X., Cotton, A., Zerbib, J., & Fournier, L. (2019). Artificial intelligence to diagnose meniscus tears on MRI. *Diagnostic and Interventional Imaging*, Vol. 100, Issue 4, pp. 243–249. <https://doi.org/10.1016/j.diii.2019.02.007>
14. Shin, H., Choi, G. S., & Shon, O. J. (2022). Development of convolutional neural network model for diagnosing meniscus tear using magnetic resonance image. *BMC Musculoskelet Disord*, Vol. 23, 510–536. <https://doi.org/10.1186/s12891-022-05468-6>
15. Sirisha, U., Praveen, S. P., & Srinivasu, P. N. (2023). Statistical Analysis of Design Aspects of Various YOLO-Based Deep Learning Models for Object Detection. *International Journal of Computational Intelligence Systems*, Vol. 16, 126–131. <https://doi.org/10.1007/s44196-023-00302-w>
16. Srivastava, S., Divekar, A. V., & Anilkumar, C. (2021). Comparative analysis of deep learning image detection algorithms. *Journal of Big Data*, Vol. 8, 66–72. <https://doi.org/10.1186/s40537-021-00434-w>
17. Sweta, B., Praveen, K. R. M., Quoc-Viet, P., & Thippa, R. G. (2021). Deep learning and medical image processing for coronavirus (COVID-19) pandemic: A survey. *Sustainable Cities and Society*, Vol. 65, 56–61. <https://doi.org/10.1016/j.scs.2020.102589>

V. V. Mosiuk, D. V. Fedasyuk

Lviv Polytechnic National University, Lviv, Ukraine

MENISCUS TEARS RECOGNITION BY DEEP NEURAL NETWORKS

In the realm of contemporary medical research, a critical task is enhancing the accuracy of diagnostics and treatment for injuries to the knee joint, especially the meniscus. Given the limitations of traditional methods like arthroscopy, which often rely on the surgeons experience and skills, there is an emerging need for developing and applying innovative technologies. Proposed to use deep neural networks (DNNs) for automated recognition of meniscal tears during surgical operations based on images from arthroscopic cameras. Various configurations of YOLOv8 architecture, ranging from Nano to Large, are considered, enabling the tailoring of solutions to specific clinical needs and computational resources. While deep learning in medicine is not a novel phenomenon, this work emphasizes the innovation in adapting powerful algorithms to the specific challenges associated with diagnosing the condition of intra-articular structures. A dataset was created to develop an effective diagnostic system that includes annotated images of meniscal tears. This dataset was utilized to train and test models, allowing for the analysis and comparison of each models ability to generalize and accurately recognize pathologies. Previous works that explore the application of classical deep learning methods to medical diagnostic systems were reviewed. The study's findings revealed that the application of DNNs significantly enhances medical images accuracy and processing speed. However, considering the complexity and diversity of meniscal injuries, it was decided to use deep learning models for detailed analysis of large datasets. During the research, models based on deep learning were trained, which significantly increased the accuracy of identifying types of damage. Experimental tests conducted based on the data obtained showed that models trained on expanded datasets demonstrated higher classification accuracy. These results confirm the potential of using deep learning to improve medical diagnostic capabilities. The research could make a significant contribution to the further development of technologies in medical diagnostics, particularly in optimizing surgical interventions and ensuring high diagnostic accuracy in real time. This opens new possibilities for further work toward integrating deep learning into clinical practice, facilitating effective and safe treatment of patients.

Keywords: machine learning; convolutional neural networks; computer vision; arthroscopy; computer diagnostics; meniscus injury.