

DOI: 10.32347/2412-9933.2024.59.122-130

УДК 681.5 : 004.5

Поплавський Олександр Анатолійович

Кандидат технічних наук, доцент, доцент кафедри інформаційних технологій,

<https://orcid.org/0000-0003-0465-6843>

Київський національний університет будівництва і архітектури, Київ

Шкуратов Олексій Іванович

Доктор економічних наук, професор, директор ВСП «Інституту інноваційної освіти КНУБА»

<https://orcid.org/0000-0002-8656-723X>

Київський національний університет будівництва і архітектури, Київ

Колісник Сергій Петрович

Доктор медицини, доцент кафедри фізичної та реабілітаційної медицини

<https://orcid.org/0000-0001-9424-0037>

Вінницький національний медичний університет імені Пирогова, Вінниця

Поплавська Анна Анатоліївна

Доктор філософії в галузі біомедичної інженерії

<https://orcid.org/0000-0002-7446-0523>

Новий Лісабонський університет, Лісабон, Португалія

Йовенко Дмитро Сергійович

Бакалавр, студент

<https://orcid.org/0009-0009-8003-705X>

Київський національний університет будівництва і архітектури, Київ

**МЕТОДОЛОГІЧНІ ОСНОВИ СОМАТОСКОПІЧНИХ ДОСЛІДЖЕНЬ
У АВТОМАТИЗОВАНИХ СИСТЕМАХ ПІДТРИМКИ ПРИЙНЯТТЯ РІШЕНЬ**

***Анотація.** Автоматизовані системи підтримки прийняття рішень (АСППР) набувають широкого застосування в різноманітних галузях науки і техніки, зокрема в медицині, де їхня роль у діагностичних, прогностичних та терапевтичних процесах є незаперечною. Використання обчислювальних технологій у медичній практиці стало необхідним етапом розвитку галузі, проте зростання обсягів даних, що потребують обробки, та підвищені вимоги до точності, швидкості й надійності рекомендацій суттєво ускладнюють процеси прийняття рішень. Збільшення кількості даних у поєднанні з необхідністю мінімізації ризиків помилкових рішень підштовхує наукове співтовариство до пошуку новітніх інформаційних технологій, здатних забезпечити високий рівень точності обчислювальних операцій і мінімізувати часові витрати на їх виконання. Соматоскопічні вимірювання, які є важливим елементом оцінки стану опорно-рухового апарату і загальної фізичної постави пацієнта, вимагають точного і систематичного аналізу зображень, що допомагає ідентифікувати критично важливі анатомічні маркери. Цей процес передбачає точне визначення ключових точок на зображеннях анатомічних структур, що є основою для побудови точних прогнозів щодо стану пацієнта та подальшого планування лікування. В умовах постійного зростання обсягів медичних даних і жорсткіших вимог до якості рішень, що приймаються, особливої актуальності набуває впровадження інноваційних технологій, зокрема глибокого навчання, яке забезпечує покращення процесів аналізу і діагностики. У роботі акцентовано увагу на використанні спеціалізованих архітектур нейронних мереж, які уможливають здійснювати ідентифікацію ключових анатомічних точок на зображеннях, що, своєю чергою, сприяє глибокому і точному аналізу анатомічних структур. Такий підхід значно підвищує ефективність діагностичних процесів, мінімізуючи ймовірність помилок у прийнятті рішень та оптимізуючи роботу медичних систем. Результати проведених досліджень демонструють значний потенціал використання алгоритмів глибокого навчання в медичних системах для автоматизованого аналізу зображень, що дає змогу значно підвищити точність і швидкість прийняття рішень. Така автоматизація сприяє зниженню ризику суб'єктивних помилок, пов'язаних із людським фактором, що має особливе значення у складних клінічних випадках. Отже, подальший розвиток досліджень у цьому напрямі має надзвичайно важливе значення для медичної галузі, оскільки відкриває нові можливості для вирішення складних діагностичних завдань на*

інноваційному технологічному рівні. Інтеграція технологій глибокого навчання в процеси виокремлення соматоскопічних даних дає змогу не лише підвищити ефективність діагностики, але й створити передумови для розроблення нових систем підтримки прийняття рішень, що оптимізують медичну практику.

Ключові слова: автоматизовані системи підтримки рішень; соматоскопічні вимірювання; глибоке навчання; нейронні мережі; медична діагностика; аналіз зображень; опорно-руховий апарат; машинне навчання

Постановка проблеми

Актуальність проблеми полягає в необхідності значного підвищення точності й об'єктивності діагностичних процедур, спрямованих на виявлення патологій опорно-рухового апарату (ОРА), що є однією з ключових систем організму людини, яка забезпечує підтримку, рухливість та захист внутрішніх органів. Структурні порушення ОРА, такі як сколіоз, остеопороз, артрита та інші патології, мають серйозний вплив на загальний стан здоров'я, функціонування пацієнтів і їхню якість життя. Своєчасна і точна діагностика цих захворювань є критично важливою для ефективного лікування та профілактики ускладнень.

З огляду на зростаючу кількість пацієнтів, що звертаються до медичних установ, актуальним стає питання розроблення нових методів діагностики, які забезпечують високу точність, швидкість та об'єктивність оцінки стану ОРА. У цьому контексті особливого значення набувають соматоскопічні вимірювання, що допомагають візуально аналізувати зовнішні ознаки тіла для виявлення патологій. Проте методи ручного проведення таких вимірювань, як правило, супроводжуються високим рівнем суб'єктивності, що може негативно позначатися на точності діагностики.

Автоматизація процесів соматоскопії, зокрема визначення ключових анатомічних точок, таких як точки кісткових виступів в ділянках суглобів, хребта та кінцівок, є перспективним напрямом для підвищення точності й ефективності діагностичних втручань. Виявлення та аналіз ключових точок тіла дає змогу не лише об'єктивно оцінювати положення анатомічних структур, а й виявляти асиметрії, кутові відхилення та інші критично важливі параметри, які можуть свідчити про наявність патологій ОРА.

Сучасні інформаційні технології пропонують широкий спектр методів визначення ключових точок, від ручних до автоматизованих алгоритмів, заснованих на комп'ютерному зорі. Ручні методи, що залежать від досвіду фахівця, схильні до варіацій у результатах, тоді як автоматизовані алгоритми, що використовують технології машинного навчання та глибоких нейронних мереж, пропонують більшу точність і надійність. Однак питання вибору найбільш ефективних методів і підходів для

ідентифікації ключових точок залишається відкритим, оскільки якість цих процедур безпосередньо впливає на ефективність подальших соматоскопічних вимірювань і діагностики. Розроблення нових методологій, що інтегрують інноваційні підходи, уможливило значно покращити точність діагностичних систем і оптимізувати процеси прийняття рішень у медицині.

Мета статті

Метою пропонованої статті є здійснення комплексного аналізу сучасних технологічних рішень і алгоритмічних інструментів, які застосовуються для ідентифікації анатомічних маркерів на зображеннях. На підставі проведеного аналізу передбачається створення високопродуктивного інструментарію, що дасть змогу забезпечити швидке і точне виявлення ключових анатомічних орієнтирів. Це своєю чергою сприятиме підвищенню діагностичної точності, оптимізації медичних процедур, а також мінімізації ризиків, пов'язаних із суб'єктивним фактором у процесах оцінювання морфологічних характеристик пацієнтів.

Аналіз основних досліджень і публікацій

У сучасній науково-дослідницькій парадигмі автоматизованої діагностики захворювань опорно-рухового апарату (ОРА) значну увагу приділяють розробленню та впровадженню передових алгоритмів штучного інтелекту, глибокого навчання та комп'ютерного зору. Ці технології орієнтовані на підвищення точності і швидкості ідентифікації анатомічних маркерів, що є критично важливим для ранньої діагностики і терапії таких патологій, які супроводжуються порушеннями постави, зміни форми грудної клітки та кінцівок, внаслідок вроджених аномалій розвитку, травм, захворювань, запальних та дегеративних процесів. Зокрема, значні успіхи було досягнуто у використанні глибоких нейронних мереж для автоматизованого аналізу зображень, що допомагає ефективно ідентифікувати ключові анатомічні структури, такі як кісткові контури тазу, суглоби, хребці та інші важливі орієнтири [1].

Розроблення автоматизованих систем підтримки прийняття рішень у медичній діагностиці активно інтегрує інноваційні підходи до виявлення анатомічних маркерів на основі аналізу зображень. Одним із ключових напрямів є автоматизація розпізнавання поверхневих орієнтирів анатомічних структур спини та постави, що значно зменшує залежність від суб'єктивних оцінок, властивих традиційним ручним методам діагностики [2]. Такі алгоритми використовують можливості глибокого навчання для побудови ефективних моделей автоматичного визначення маркерів, що дає змогу знизити кількість похибок, зумовлених людським фактором.

Дослідження, що стосуються автоматизації визначення анатомічних орієнтирів, демонструють успіхи в застосуванні алгоритмів машинного навчання для аналізу тривимірних зображень та карт глибини, що допомагає більш точно ідентифікувати положення анатомічних структур на зображеннях спини [3]. Важливим аспектом є адаптація алгоритмів глибокого навчання для медичних завдань, що, своєю чергою, сприяє підвищенню діагностичної точності і полегшує прийняття рішень у клінічних умовах.

Значну увагу також приділено міждисциплінарним підходам, що інтегрують машинне навчання і комп'ютерний зір у діагностику ОРА. Дослідження з використанням автоматизованих систем для аналізу постави та інших маркерів опорно-рухового апарату продемонстрували значне зниження часу опрацювання даних та підвищення точності оцінок [4]. Крім того, алгоритми, що використовуються для відстеження рухів та ідентифікації гравців у спортивних подіях, можуть бути адаптовані для медичних завдань, що свідчить про універсальність таких підходів [5].

Інші наукові розробки зосереджуються на поліпшенні наявних моделей для виявлення анатомічних структур. Наприклад, у роботі [6] проаналізовано ефективність глибоких нейронних мереж для покращення аналізу зображень, отриманих за допомогою ультразвукових технологій, що дає змогу значно підвищити точність діагностичних процедур. У роботі [7] розглянуто застосування методів сегментації зображень на основі штучних нейронних мереж для підвищення точності виявлення анатомічних маркерів. Дослідження [8] демонструє використання алгоритмів комп'ютерного зору для аналізу зображень кісткових структур, що сприяє автоматизації і підвищенню об'єктивності діагностичних процесів.

Виклад основного матеріалу

Соматоскопія, як метод візуальної оцінки зовнішніх анатомічних орієнтирів тіла людини, відіграє важливу роль у діагностиці та скрінінгу стану опорно-рухового апарату. Виявлення ключових анатомічних точок на тілі людини є центральним аспектом цього методу, оскільки уможливило отримати точні й об'єктивні дані щодо симетрії, вирівняності та нахилів різних частин тіла. Ці точки включають верхівку голови для оцінки вертикального положення, орбітальні ямки для симетрії обличчя, трагуси вух для аналізу кутів нахилу голови, а також акроміально-ключичні точки плечових суглобів для визначення рівності плечей. Лопатки оцінюються для симетрії лопаточного пояса, а вигини хребта – для виявлення деформацій шийного, грудного та поперекового відділів.

Виявлення осьових орієнтирів таза, колінних суглобів, гомілковостопних суглобів і п'яткових кісток дає змогу оцінити симетрію та вирівняність кінцівок, що є важливим для діагностики порушень постави та інших патологій опорно-рухового апарату. Ці ключові точки служать маркерами, які допомагають комплексно оцінювати анатомічну структуру і функціональні відхилення, що є критично важливим для виявлення сколіозу, кіфозу, лордозу та інших деформацій хребта.




Рисунок 1 – Ключові точки на тілі людини

До впровадження методів глибокого навчання основними інструментами для задач виявлення ключових точок у комп'ютерному зорі були класичні алгоритми, такі як Harris Corner Detector та SIFT (Scale-Invariant Feature Transform) [9].

Алгоритм Harris Corner Detector ґрунтується на аналізі локальних змін інтенсивності пікселів у зображенні з метою ідентифікації точок, де інтенсивність змінюється різко у всіх напрямках, тобто куточків. Цей підхід використовує матрицю градієнтів для обчислення матриці автокореляції, яка моделює зміну інтенсивності в різних напрямках.

Виходячи з цієї матриці, обчислюється показник Харріса, який вказує на наявність куточків, де значення показника досягає максимуму. Отже, алгоритм Harris дає змогу виявляти місця різких змін інтенсивності, характерних для кутових точок, які особливо помітні на зображенні [10].

Алгоритм SIFT, або масштабно-інваріантне перетворення ознак, являє собою більш складний метод, який забезпечує стійкість до масштабування, обертання та часткових змін освітлення [11]. Спочатку алгоритм будує гауссові піраміди зображень, що уможливорює виявляти локальні екстремуми в просторі різниць гауссових фільтрів (DoG). Ці екстремуми слугують кандидатами для потенційних ключових точок. Після цього нестабільні точки відсіюються, для кожної ключової точки визначається орієнтація на основі локальних градієнтів, і формується дескриптор – вектор, що характеризує орієнтації градієнтів. Ці дескриптори застосовуються для точного зіставлення ключових точок між різними зображеннями, що робить SIFT високоефективним у завданнях розпізнавання об'єктів і тривимірної реконструкції [12].

Однак недоліком традиційних методів, таких як Harris Corner Detector і SIFT, є їх обмеженість у виявленні попередньо визначених точок, оскільки вони лише виявляють локальні екстремуми або кути без урахування контексту зображення [13]. З появою архітектур глибокого навчання, ці методи поступово втратили популярність, оскільки сучасні нейронні мережі демонструють більшу гнучкість і здатність адаптуватися до складних задач комп'ютерного зору [14]. Глибокі моделі забезпечують вищу точність у виявленні та класифікації об'єктів, мінімізуючи потребу в ручному передпроцесингу даних, який є необхідним для класичних алгоритмів. Це робить підходи на основі глибокого навчання більш ефективними та застосовуваними в широкому спектрі задач, від розпізнавання об'єктів до високоточних медичних аналізів.

Нейронні мережі являють собою фундамент сучасних систем машинного навчання, оскільки вони базуються на взаємодії численних елементарних обчислювальних одиниць, відомих як нейрони, які колективно спрямовані на розв'язання складних задач. Існує декілька типів нейронних мереж, кожен з яких характеризується специфічними архітектурними особливостями і підходить для вирішення різних категорій задач.

Штучні нейронні мережі (ANN, Artificial Neural Networks) є базовим типом, що складається з одного або кількох шарів нейронів і використовується переважно для простих задач класифікації та регресії. Конволюційні нейронні мережі (CNN, Convolutional Neural Networks) спеціалізуються на обробці візуальних даних, таких як зображення і

відео, завдяки наявності конволюційних шарів, які здатні екстрагувати характерні особливості зображень, включаючи контури, текстури та патерни. Це робить CNN надзвичайно ефективними для задач комп'ютерного зору, зокрема розпізнавання об'єктів на зображеннях.

Рекурентні нейронні мережі (RNN, Recurrent Neural Networks) призначені для роботи з послідовними даними, такими як текстові рядки, часові ряди або послідовності зображень. Їх ключова особливість полягає у використанні зворотних зв'язків, які допомагають акумулювати і враховувати інформацію з попередніх етапів опрацювання даних, що особливо важливо для задач прогнозування й аналізу тимчасових залежностей. Глибокі нейронні мережі (DNN, Deep Neural Networks), що включають значну кількість прихованих шарів, уможливають моделювати складні нелінійні залежності в даних, що робить їх придатними для широкого спектра застосувань, включаючи обробку природної мови, прогнозування ринкових трендів та інші складні задачі.

На сьогодні нейронні мережі, зокрема конволюційні нейронні мережі (CNN), стали незамінними для задач виявлення ключових точок на зображеннях, що підтверджується численними публікаціями та оглядами. Вони демонструють здатність адаптуватися до вирішення специфічних завдань комп'ютерного зору завдяки високій ефективності в обробці великих обсягів даних, можливості виявлення складних шаблонів і структур у візуальних даних, а також досягнення високої точності та стійкості до змін умов освітлення, масштабу й орієнтації. Потенціал CNN у навчанні на великих наборах даних робить їх ідеальними для роботи з варіативними і складними зображеннями, що виходить за рамки можливостей традиційних методів.

Окрім того, важливим аспектом роботи нейронних мереж є процес навчання, який включає збирання та підготовку великих обсягів даних, необхідних для ефективного функціонування моделей. Цей процес визначає якість побудованих моделей та їх здатність до узагальнення на нових, невідомих даних, що є основою успіху в практичному застосуванні нейронних мереж у різноманітних завданнях комп'ютерного зору і не тільки.

У сучасних задачах розпізнавання постави, відслідковування руху та інших суміжних областях активно використовуються вже наявні датасети з анотованими ключовими точками на тілі людини. Одним з найвідоміших таких наборів даних є MPII Human Pose Dataset, який містить понад 25 тисяч зображень з детально анотованими ключовими точками, що відображають людей у різноманітних

позах і контекстах [15]. Цей датасет є широко застосовуваним у задачах комп'ютерного зору, спрямованих на аналіз та розпізнавання людської активності.

Ще один важливий ресурс – COCO (Common Objects in Context), який включає понад 200 тисяч зображень з анотаціями ключових точок різних частин тіла людей (рис. 2) [16]. COCO є надзвичайно популярним у дослідженнях і розробках, що стосуються задач виявлення, сегментації та розпізнавання об'єктів, завдяки своїй масштабності та багатофункціональності. Використання таких датасетів значно спрощує розроблення алгоритмів для автоматичного аналізу постанти та відстеження рухів, забезпечуючи необхідну базу для тренування моделей глибокого навчання з високою точністю і надійністю [17].

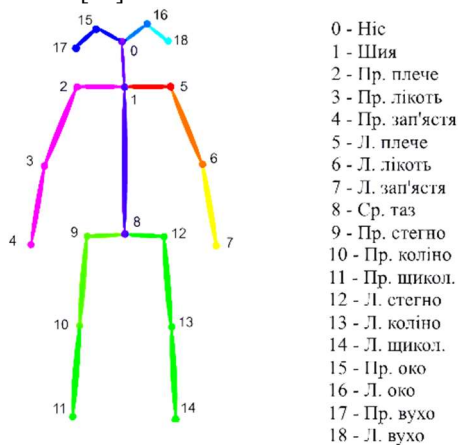


Рисунок 2 – Ілюстрація прикладу анотації ключових точок на зображеннях, представлених у загальнодоступних датасетах

Використання даних датасетів слід розглядати як важливу складову процесу попереднього навчання нейронних мереж. Ці набори даних, що містять значні обсяги зображень з анотованими ключовими точками людського тіла, слід використовувати для ініціалізації базових ваг нейронних мереж через процес попереднього навчання (pre-training). Таке попереднє навчання дає змогу сформуванню початкових параметри мережі, забезпечуючи її здатністю до розпізнавання загальних патернів, структур та об'єктів, що суттєво покращує ефективність подальшого донавчання на специфічних цільових задачах.

Попередньо навчені моделі отримують фундаментальне розуміння базових характеристик зображень, таких як контури, текстури та інші візуальні атрибути, що знижує вимоги до обсягів цільових даних для тонкого налаштування (fine-tuning). Цей підхід є ключовим для підвищення стійкості моделей до варіацій в умовах освітлення, масштабу та орієнтації, що є вирішальним у задачах, де точність і надійність алгоритмів відіграють критичну роль. До того ж такий підхід не лише

оптимізує початкову фазу навчання, але й значно зменшує час і ресурси, необхідні для їхньої подальшої спеціалізації. Це забезпечує створення високоадаптивних і точних моделей, які здатні успішно функціонувати в складних і мінливих умовах, характерних для реальних застосувань.

Після завершення етапу попереднього навчання на загальновідомих наборах даних для тонкого налаштування, було створено власний спеціалізований датасет з анотованими ключовими точками, що відповідають вимогам досліджуваного завдання. Створення цього датасету було необхідним для подальшого проведення тонкого налаштування (fine-tuning) ваг нейронної мережі, з метою підвищення її адаптивності та точності в контексті специфічних умов експлуатації. Власний датасет було ретельно анотовано для цільового застосування, що допомогло нейронній мережі ефективно інкорпорувати у свої параметри знання про унікальні патерни і структури, які не були репрезентовані у загальнодоступних наборах даних.

Завдяки цьому підходу було реалізовано ефективну адаптацію попередньо навчених моделей до нових задач, що включало мінімізацію розриву між розподілами тренувальних даних та специфічними вимогами цільового завдання.

Створення власного датасету передбачає ретельне збирання зображень та їх анотування із залученням фахівців з багаторічним стажем роботи з визначення анатомічних орієнтирів (рис. 3). Також важливим є стандартизація й уніфікація умов зйомки, оскільки саме ці параметри істотно впливають на точність подальшого комп'ютерного аналізу. Для забезпечення консистентності даних необхідно визначити фіксовані параметри зйомки, такі як висота камери, відстань до пацієнта, рівень освітленості.

Ця уніфікація умов уможливує зменшити варіативність вхідних даних, що сприяє підвищенню точності моделі на етапі тонкого налаштування ваг нейронної мережі, забезпечуючи стабільність і узгодженість анотованих зображень, необхідних для ефективного навчання.



Рисунок 3 – Процес збирання емпіричних даних та їх детальна анотація з використанням стандартизованих анатомічних маркерів

Після завершення етапу збирання та стандартизації даних виконується навчання нейронних мереж, яке зазвичай здійснюється за допомогою алгоритму зворотного поширення помилки (backpropagation). Цей алгоритм виконує ітеративне коригування ваг зв'язків між нейронами, оптимізуючи мережу шляхом мінімізації функції втрат, що характеризує різницю між передбаченими моделлю та фактичними значеннями анотованих даних. Завдяки градієнтному спуску ваги коригуються у напрямку, що зменшує помилку, що дає змогу мережі поступово адаптуватися та покращувати свої прогностичні можливості.

1. Пряме поширення (Forward Propagation).

Спочатку вхідні дані x пропускаються через всі шари нейронної мережі, щоб отримати прогнозоване значення y' :

$$y' = f(Wx + b), \quad (1)$$

де W – матриця ваг; b – вектор зміщень; f – активаційна функція.

2. Обчислення помилки (Loss Calculation).

Потім обчислюється функція втрат, яка визначає різницю між прогнозованим значенням y' і справжнім значенням y :

$$L = \frac{1}{2} (y - y')^2. \quad (2)$$

Це найбільш типова функція втрат для задач регресії.

3. Зворотне поширення помилки (Backpropagation).

Помилка передається назад через мережу, щоб обчислити градієнт функції втрат щодо кожної ваги.

Використовуємо правило ланцюгової похідної:

$$\frac{dL}{dW} = \frac{dL}{dy'} \cdot \frac{dy'}{dz} \cdot \frac{dz}{dW}, \quad (3)$$

де $z = Wx + b$.

Розпишемо похідні:

$$\frac{dL}{dW} = (y - y') \cdot f'(z) \cdot x, \quad (4)$$

де $f'(z)$ – похідна активаційної функції.

4. Оновлення ваг (Weight Update).

Ваги оновлюються в напрямку, протилежному до градієнта, що мінімізує функцію втрат. Це робиться за допомогою алгоритму градієнтного спуску:

$$W_{new} = W_{old} - \eta \cdot \frac{dL}{dW}, \quad (5)$$

де η – швидкість навчання.

Цикл навчання повторюється для кожного зразка у навчальному наборі, забезпечуючи поступове налаштування ваг нейронної мережі до

тих пір, поки модель не досягне високого рівня апроксимації вихідних значень на основі вхідних даних. Алгоритм зворотного поширення помилки (backpropagation) є фундаментальною складовою багатьох сучасних методологій навчання нейронних мереж, зокрема в контексті глибокого навчання, де він відіграє ключову роль в оптимізації моделей за рахунок ефективного зменшення похибок у передбаченнях.

З розвитком технологій комп'ютерного зору та глибокого навчання виникли потужні засоби для автоматизованого аналізу візуальних даних, що суттєво підвищило ефективність і точність обробки зображень. Одним із найважливіших досягнень у цій галузі стало створення спеціалізованих архітектур згорткових нейронних мереж (CNN), розроблених для розв'язання задач визначення ключових точок на зображеннях. Ці архітектури демонструють здатність автоматично виокремлювати, класифікувати та аналізувати характерні ознаки анатомічних структур, забезпечуючи високоточну ідентифікацію їхнього розташування та відповідних маркерів.

Архітектура YOLO (You Only Look Once) є однією з провідних у сфері глибокого навчання для детекції об'єктів на зображеннях і відео, відзначаючись високою швидкістю й ефективністю завдяки використанню єдиної нейронної мережі для одночасного прогнозування обмежувальних рамок і класів об'єктів [18]. Це дає змогу обробляти вхідне зображення через мережу лише один раз, що суттєво підвищує продуктивність моделі, роблячи її придатною для застосування в режимі реального часу. Хоча YOLO спочатку була орієнтована на виявлення об'єктів, її архітектура може бути адаптована для задач визначення ключових точок (рис. 4).



Рисунок 4 – Застосування архітектури YOLO для ідентифікації анатомічних маркерів на зображеннях

У межах таких задач, як PoseTED, YOLO-v4 використовується для детекції людей шляхом локалізації осіб за допомогою обмежувальних рамок. Після цього мережа просторового трансформатора (Spatial Transformer Network, STN) виділяє релевантні області шляхом обрізання вихідного зображення згідно з передбаченими рамками. Магістральна мережа виконує обробку цих областей для генерації складних представлень ознак, а процес визначення ключових точок щодо відповідних обмежувальних рамок спрощується завдяки кодеру-декодеру на основі Transformer з позиційним кодуванням. Заключним етапом є прогнозування ключових точок за допомогою мережі прямого зв'язку, що забезпечує подання точок у вигляді векторів, асоційованих з різними частинами тіла.

Крім того, остання версія архітектури – Ultralytics YOLOv8 надає підтримку визначення ключових точок нативно, що допомагає ще більше спростити процес інтеграції цих можливостей у реальні застосування.

Висновки

У пропонованій статті було розглянуто сучасні методи та засоби, що використовуються в автоматизованих системах підтримки прийняття

рішень, зокрема, можливості застосування конволюційних нейронних мереж для визначення ключових точок на зображеннях у розрізі соматоскопічних вимірювань. Проведений аналіз показав, що використання сучасних архітектур CNN є ефективним інструментом для автоматизації процесу аналізу анатомічних структур та діагностики стану опорно-рухового апарату. Це підкреслює важливість інтеграції новітніх технологій глибинного навчання в системи автоматизованої діагностики, що може суттєво покращити якість медичних обстежень і сприяти розвитку нових методів аналізу зображень.

Результати дослідження свідчать про значний потенціал використання алгоритмів глибокого навчання для автоматизованого аналізу медичних зображень, що уможливує підвищити точність, швидкість та об'єктивність діагностичних процедур. Це сприяє зниженню ризику суб'єктивних помилок, пов'язаних з людським фактором, що є особливо важливим у складних клінічних випадках. Отже, подальший розвиток досліджень у цьому напрямі має велике значення для медичної галузі, оскільки відкриває нові можливості для вирішення складних діагностичних завдань на інноваційному технологічному рівні.

Список літератури

1. Shin Y. et al. "Artificial intelligence in musculoskeletal ultrasound imaging," *Ultrasonography*, vol. 40, no. 1, pp. 30–44, 2021. Available: <https://doi.org/10.14366/usg.20080>.
2. Michoński J. et al. "Automatic recognition of surface landmarks of anatomical structures of back and posture," *Journal of Biomedical Optics*, vol. 17, no. 5, p. 056015, 2012. Available: <https://doi.org/10.1117/1.jbo.17.5.056015>.
3. Wang J., Zhang Y., and Liu X. "Automatic landmark detection of human back surface from depth images via deep learning," *World Journal of Clinical & Medical Images*, vol. 1, no. 1, pp. 12–23, 2022. Available: <https://doi.org/10.33140/wjcmi.01.01.07>.
4. Naik B. T. et al. "DeepPlayer-Track: player and referee tracking with jersey color recognition in soccer," *IEEE Access*, vol. 10, pp. 32494–32509, 2022. Available: <https://doi.org/10.1109/access.2022.316144>.
5. Smith A. et al., "Automated posture analysis using machine learning techniques," *International Journal of Medical Informatics*, vol. 144, 2020. Available: <https://doi.org/10.1016/j.ijmedinf.2020.104292>.
6. Taylor M. C. et al. "Deep neural networks for musculoskeletal ultrasound imaging: A review," *Journal of Medical Imaging*, vol. 7, no. 4, 2020. Available: <https://doi.org/10.1117/1.JMI.7.4.040802>.
7. Lee P. et al. "Segmentation of musculoskeletal structures using deep learning: A review," *IEEE Transactions on Medical Imaging*, vol. 39, no. 2, pp. 359–373, 2020. Available: <https://doi.org/10.1109/TMI.2020.2973417>.
8. Morgan K. J. et al. "Bone structure analysis via deep learning and computer vision techniques," *Journal of Orthopaedic Research*, vol. 38, no. 8, pp. 1634–1645, 2021. Available: <https://doi.org/10.1002/jor.24678>.
9. Gonzalez R. C. and Woods R. E. *Digital Image Processing*, 4th ed., Pearson Education Limited, Harlow, Essex, England, 2018. ISBN: 978-1-292-22304-9.
10. Harris C. and Stephens M. "A combined corner and edge detector," in *Proceedings of the 4th Alvey Vision Conference*, Manchester, UK, 1988, pp. 147–151.
11. Lowe D. G. "Distinctive image features from scale-invariant keypoints," *International Journal of Computer Vision*, vol. 60, no. 2, pp. 91–110, 2004. Available: <https://doi.org/10.1023/B:VISI.0000029664.99615.94>.
12. Mikolajczyk K. and Schmid C. "A performance evaluation of local descriptors," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 27, no. 10, pp. 1615–1630, 2005. Available: <https://doi.org/10.1109/TPAMI.2005.188>.
13. Smith S. M. and Brady J. M. "SUSAN—A New Approach to Low Level Image Processing," *International Journal of Computer Vision*, vol. 23, pp. 45–78, 1997. Available: <https://doi.org/10.1023/A:1007963824710>.
14. Krizhevsky A., Sutskever I., and Hinton G. E. "ImageNet classification with deep convolutional neural networks," *Communications of the ACM*, vol. 60, no. 6, pp. 84–90, May 2017. Available: <https://doi.org/10.1145/3065386>.

15. Andriluka M., Pishchulin L., Gehler P., and Schiele B. "2D Human Pose Estimation: New Benchmark and State of the Art Analysis," in *Proceedings of the 2014 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Columbus, OH, USA, Jun. 23–28, 2014, pp. 3686–3693. Available: <https://doi.org/10.1109/CVPR.2014.471>.
16. Lin T.-Y. et al. "Microsoft COCO: Common Objects in Context," in *European Conference on Computer Vision (ECCV)*, 2014, pp. 740–755. Available: https://doi.org/10.1007/978-3-319-10602-1_48.
17. Cao Z., Simon T., Wei S.-E., and Sheikh Y. "Realtime Multi-Person 2D Pose Estimation Using Part Affinity Fields," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2017, pp. 7291–7299. Available: <https://doi.org/10.1109/CVPR.2017.143>.
18. Redmon J. and Farhadi A. "YOLOv3: An Incremental Improvement," arXiv preprint arXiv:1804.02767, 2018. Available: <https://arxiv.org/abs/1804.02767>.

This project has received funding through the EURIZON project, which is funded by the European Union under grant agreement No. 871072.

Стаття надійшла до редколегії 12.09.2024

Oleksandr Poplavskyi

PhD (Eng.), Associate Professor, Assistant Professor of the information technologies department,
<https://orcid.org/0000-0003-0465-6843>

Kyiv National University of Construction and Architecture, Kyiv

Oleksii Shkuratov

DSc (Economics), Professor, Director of the Institute of Innovative Education, Kyiv National University of Construction and Architecture, <https://orcid.org/0000-0002-8656-723X>

Kyiv National University of Construction and Architecture, Kyiv

Serhii Kolisnyk

DSc (Medicine), Associate Professor of the Department of Physical and Rehabilitation Medicine
<https://orcid.org/0000-0001-9424-0037>

Vinnitsia National Pirogov Memorial Medical University, Vinnitsia

Anna Poplavska

PhD (Biomedical Engineering)

<https://orcid.org/0000-0002-7446-0523>

Nova University Lisbon, Lisbon, Portugal

Dmytro Yovenko

Bachelor, Student,

<https://orcid.org/0009-0009-8003-705X>

Kyiv National University of Construction and Architecture, Kyiv

METHODOLOGICAL FOUNDATIONS OF SOMATOSCOPIC RESEARCH IN AUTOMATED DECISION SUPPORT SYSTEMS

Abstract. *Automated Decision Support Systems (ADSS) are widely applied in various fields of science and technology, particularly in medicine, where their role in diagnostic, prognostic, and therapeutic processes is undeniable. The use of computational technologies in medical practice has become a necessary stage in the development of the field; however, the increasing volume of data that requires processing, along with heightened demands for accuracy, speed, and reliability of recommendations, significantly complicates decision-making processes. The growing amount of data, combined with the need to minimize the risks of erroneous decisions, drives the scientific community to seek innovative information technologies that can ensure a high level of accuracy in computational operations while minimizing the time required for their execution. Somatoscopic measurements, which are a crucial element in assessing the condition of the musculoskeletal system and overall physical posture of a patient, require precise and systematic image analysis that allows the identification of critically important anatomical markers. This process involves the accurate determination of key points on images of anatomical structures, which serves as the foundation for making precise predictions about the patient's condition and subsequent treatment planning. In the context of continuously increasing volumes of medical data and stricter requirements for the quality of decisions, the implementation of innovative technologies, particularly deep learning, becomes increasingly relevant as it enhances the processes of analysis and diagnosis. The aim of this study is to conduct a comprehensive analysis of the methodological aspects of applying deep learning in the context of automating the diagnosis of the musculoskeletal system and posture assessment. The study emphasizes the use of specialized neural network architectures that enable the identification of key anatomical points on images, thereby facilitating a deeper and more accurate analysis of anatomical structures. This approach significantly improves the efficiency of diagnostic processes by minimizing the likelihood of errors in decision-making and optimizing the performance of medical systems. The results of the conducted research demonstrate the significant potential of deep learning algorithms in medical systems for the automated analysis of images, allowing for substantial improvements in the accuracy and speed of decision-making. Such automation contributes to reducing the risk of subjective errors associated with the human factor, which is particularly important in complex clinical cases. Therefore, the further development of research in this direction is of paramount importance for the medical field, as it opens new*

opportunities for solving complex diagnostic tasks at an innovative technological level. The integration of deep learning technologies into the processes of extracting somatoscopic data not only enhances diagnostic efficiency but also creates prerequisites for the development of new decision support systems that optimize medical practice.

Keywords: automated decision support systems; somatoscopic measurements; deep learning; neural networks; medical diagnostics; image analysis; musculoskeletal system; machine learning

References

1. Shin, Y., et al. (2021). Artificial intelligence in musculoskeletal ultrasound imaging. *Ultrasonography*, 40(1), 30–44. <https://doi.org/10.14366/usg.20080>.
2. Michoński, J., et al. (2012). Automatic recognition of surface landmarks of anatomical structures of back and posture. *Journal of Biomedical Optics*, 17(5), 056015. <https://doi.org/10.1117/1.jbo.17.5.056015>.
3. Wang, J., Zhang, Y. & Liu, X. (2022). Automatic landmark detection of human back surface from depth images via deep learning. *World Journal of Clinical & Medical Images*, 1(1), 12-23. <https://doi.org/10.33140/wjcmi.01.01.07>.
4. Naik, B. T., et al. (2022). DeepPlayer-Track: Player and referee tracking with jersey color recognition in soccer. *IEEE Access*, 10, 32494–32509. <https://doi.org/10.1109/access.2022.316144>.
5. Smith, A., et al. (2020). Automated posture analysis using machine learning techniques. *International Journal of Medical Informatics*, 144. <https://doi.org/10.1016/j.ijmedinf.2020.104292>.
6. Taylor, M. C., et al. (2020). Deep neural networks for musculoskeletal ultrasound imaging: A review. *Journal of Medical Imaging*, 7(4). <https://doi.org/10.1117/1.JMI.7.4.040802>.
7. Lee, P., et al. (2020). Segmentation of musculoskeletal structures using deep learning: A review. *IEEE Transactions on Medical Imaging*, 39(2), 359–373. <https://doi.org/10.1109/TMI.2020.2973417>.
8. Morgan, K. J., et al. (2021). Bone structure analysis via deep learning and computer vision techniques. *Journal of Orthopaedic Research*, 38(8), 1634–1645. <https://doi.org/10.1002/jor.24678>.
9. Gonzalez, R. C. & Woods, R. E. (2018). *Digital Image Processing* (4th ed.). Pearson Education Limited.
10. Harris, C. & Stephens, M. (1988). A combined corner and edge detector. In *Proceedings of the 4th Alvey Vision Conference* (pp. 147–151). Manchester, UK.
11. Lowe, D. G. (2004). Distinctive image features from scale-invariant keypoints. *International Journal of Computer Vision*, 60(2), 91–110. <https://doi.org/10.1023/B:VISI.0000029664.99615.94>.
12. Mikolajczyk, K. & Schmid, C. (2005). A performance evaluation of local descriptors. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 27(10), 1615–1630. <https://doi.org/10.1109/TPAMI.2005.188>.
13. Smith, S. M., & Brady, J. M. (1997). SUSAN – A new approach to low level image processing. *International Journal of Computer Vision*, 23, 45–78. <https://doi.org/10.1023/A:1007963824710>.
14. Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84–90. <https://doi.org/10.1145/3065386>.
15. Andriluka, M., Pishchulin, L., Gehler, P., & Schiele, B. (2014). 2D human pose estimation: New benchmark and state of the art analysis. In *Proceedings of the 2014 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 3686–3693). Columbus, OH, USA. <https://doi.org/10.1109/CVPR.2014.471>.
16. Lin, T.-Y., et al. (2014). Microsoft COCO: Common objects in context. In *European Conference on Computer Vision (ECCV)* (pp. 740–755). https://doi.org/10.1007/978-3-319-10602-1_48.
17. Cao, Z., Simon, T., Wei, S.-E., & Sheikh, Y. (2017). Realtime multi-person 2D pose estimation using part affinity fields. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 7291–7299). <https://doi.org/10.1109/CVPR.2017.143>.
18. Redmon, J., & Farhadi, A. (2018). YOLOv3: An incremental improvement. *arXiv preprint arXiv:1804.02767*. <https://doi.org/10.48550/arXiv.1804.02767>.

Посилання на публікацію

- APA Poplavskyi, O., Shkuratov, O., Kolisnyk, S., Poplavska, A. & Yovenko, D. (2024). Methodological foundations of somatoscopic research in automated decision support systems. *Management of Development of Complex Systems*, 59, 122–130, [dx.doi.org/10.32347/2412-9933.2024.59.122-130](https://doi.org/10.32347/2412-9933.2024.59.122-130).
- ДСТУ Поплавський О. А., Шкуратов О. І., Колісник С. П., Поплавська А. А., Йовенко Д. С. Методологічні основи соматоскопічних досліджень у автоматизованих системах підтримки прийняття рішень. *Управління розвитком складних систем*. Київ, 2024. № 59. С. 122 – 130, [dx.doi.org/10.32347/2412-9933.2024.59.122-130](https://doi.org/10.32347/2412-9933.2024.59.122-130).