Stručni članak *Zaprimljen: 20. 08. 2026.*
https://doi.org/ 10.54478/ers.35.48.6 *Prihvaćen: 4. 09. 2026.*

RAZVOJ I IMPLEMENTACIJA APLIKACIJE ZA MJERENJE OPSEGA POKRETA KORIŠTENJEM RAČUNALNOG VIDA

Fabian Bojanac[1]

[1]*Student Sveučilišta u Rijeci, Fakultet zdravstvenih studija*

Sažetak
Mjerenje opsega pokreta ključno je u fizioterapiji. Cilj je evaluirati autorsku aplikaciju (MediaPipe) za bezmarkersko mjerenje kinematike u usporedbi s goniometrom. Mjereno je 5 pokreta na 3 ispitanika. Aplikacija pokazuje visoku točnost za pokrete abdukcije ramena i retrofleksije kuka (MAE<3°), prihvatljivu za pokret fleksije kuka i koljena (MAE<7°), no neprihvatljivu za pokret fleksije lakta (MAE=16°). Zaključno, 2D računalni vid obećava, ali pati od perspektivnog skraćenja kod gornjih ekstremiteta.

Ključne riječi: *fizioterapij; goniometrija; MediaPipe; opseg pokreta; računalni vid.*

DEVELOPMENT AND IMPLEMENTATION OF AN APPLICATION FOR MEASURING RANGE OF MOTION USING COMPUTER VISION

Fabian Bojanac[1]

[1]*Student University of Rijeka, Faculty of Health Studies*

Abstract
Measuring range of motion is crucial in physiotherapy. The aim was to evaluate a custom MediaPipe app for markerless kinematics against a goniometer. Five movements were tested on 3 subjects. The app showed high accuracy for movements of shoulder abduction and hip retroflexion (MAE<3°), acceptable for movements of hip and knee flexion (MAE<7°) but unacceptable for the movement of elbow flexion (MAE=16°). In conclusion, 2D computer vision shows potential but suffers from foreshortening.

Keywords: *computer vision; goniometry; MediaPipe; physiotherapy; range of motion.*

1. Uvod

Opseg pokreta (ROM) jedan je od temeljnih kvantitativnih parametara za procjenu funkcionalnog statusa mišićno-koštanog i neuromuskularnog sustava u fizioterapiji (Norkin i White, 2016; Zulle, Fužinac-Smojver i Lulić Drenjak, 2012). U standardnom kliničkom kontekstu, mjerenje se provodi kroz dva osnovna modaliteta: aktivni i pasivni. Aktivni opseg pokreta kliničaru pruža dragocjen uvid u strukturni integritet samog zgloba te u stanje neuromuskularne funkcije i motoričke kontrole, dok pasivna evaluacija primarno izolira elastičnost zglobne čahure i prisutnost mehaničkih barijera (Clarkson, 2005). Smanjenje fiziološkog opsega pokreta, poznato kao hipomobilnost, manifestira se uslijed širokog spektra čimbenika koji obuhvaćaju mehaničke traume, upalne i degenerativne procese te dugotrajnu imobilizaciju. Ograničenje pokretljivosti u samo jednom zglobnom segmentu neizbježno dovodi do biomehaničkog preopterećenja susjednih kinetičkih lanaca, što dugoročno rezultira abnormalnom distribucijom sila, asimetrijom u obrascima hoda i razvojem kroničnih bolnih sindroma (Neumann, 2016). U svakodnevnoj kliničkoj rutini, tradicionalna manualna goniometrija predstavlja najšire prihvaćeni referentni standard. Međutim, ova metoda pati od duboko ukorijenjenih metodoloških ograničenja poput visoke varijabilnosti mjerenja, problematike palpacije te subjektivnosti vizualnog očitavanja uslijed pogreške paralakse. Dodatni značajni nedostatak konvencionalnih metoda je statička priroda mjerenja. Manualni goniometar omogućuje registraciju kutne vrijednosti isključivo u statičkim točkama na samom početku i kraju izvedenog pokreta. Zbog ove tehničke limitiranosti, u potpunosti se

zanemaruje dinamička kinematika pokreta, odnosno podaci o brzini, ubrzanju, fluidnosti tranzicije te kontinuitetu kretnje kroz cjelokupni luk gibanja. Brojna kineziološka istraživanja dokumentirala su da standardna pogreška manualnog mjerenja goniometrom u kliničkim uvjetima varira između 5,0° i 10,0° (Gajdosik i Bohannon, 1987). Upravo se taj raspon odstupanja u fizioterapijskoj praksi smatra klinički prihvatljivim te služi kao referentna granica za validaciju novih mjernih instrumenata. Sva odstupanja koja značajno premašuju navedene vrijednosti klasificiraju se kao klinički neprihvatljiva jer izravno kompromitiraju točnost funkcionalne dijagnoze. Kako bi se u potpunosti razumjela kompleksnost kinezimetrijskog mjerenja, nužno je analizirati specifične biomehaničke karakteristike anatomskih segmenata. Primjerice, kinematika zgloba koljena otežava preciznu vizualnu analizu zbog prisutnosti složenog mehanizma kotrljanja i klizanja bedrene kosti po tibijalnom platou, što rezultira kontinuiranim pomicanjem trenutačne osi rotacije tijekom izvođenja kretnje. S druge strane, zglob ramena najmobilniji je zglobni sustav u ljudskom tijelu, a svaki pokret abdukcije zahtijeva preciznu biomehaničku sinkronizaciju poznatu kao skapulohumeralni ritam. Kao odgovor na ta ograničenja i kompleksnosti, razvijaju se sustavi računalnog vida bez markera (engl. markerless pose estimation). Ovi sustavi koriste standardnu računalnu opremu, čime se eliminira potreba za skupom optoelektroničkom laboratorijskom tehnikom i ljepljenjem fizičkih markera izravno na kožu pacijenta. Među dostupnim programskim rješenjima ističe se Google MediaPipe, alat koji pomoću standardne komercijalne kamere prepoznaje 33 ključne anatomske točke na tijelu u stvarnom vremenu (Lugaresi i sur., 2019). Iako ovakvi računalni programi postižu visoku točnost, podložni su pogreškama uslijed perspektivnog skraćenja i vizualnog zamućenja pri bržim kretnjama (Martins, Carvalho i Soares, 2023). Cilj ovog pilot-istraživanja bio je razviti i evaluirati autorsku aplikaciju utemeljenu na okviru Google MediaPipe za analizu kinezimetrije u stvarnom vremenu te usporediti njezinu točnost sa standardnim manualnim goniometrom, uzimajući pritom u obzir granice klinički prihvatljivih odstupanja.

2. Metode

Istraživanje je provedeno po nacrtu preliminarne komparativne studije radi evaluacije dvaju neovisnih mjernih instrumenata. Uključen je prigodni uzorak od tri zdrava ispitanika muškog spola, životne dobi između 20 i 25 godina, bez prisutnih patoloških stanja mišićno-koštanog i neuromuskularnog sustava te s indeksom tjelesne mase unutar raspona normalnih vrijednosti. Kriteriji isključenja obuhvaćali su prisutnost boli, lokalnog edema, povijest kirurških zahvata na lokomotornom sustavu te neurološke deficite. Zbog specifičnih tehničkih zahtjeva algoritma računalnog vida, svi su ispitanici tijekom cjelokupnog testiranja nosili pripijenu sportsku odjeću kako bi se spriječilo vizualno zaklanjanje anatomskih kontura i omogućila precizna softverska detekcija zglobnih centara. Korištena su dva osnovna mjerna instrumenta. Za konvencionalnu manualnu kinezimetriju primijenjen je standardni univerzalni dvokraki plastični goniometar s kutnom skalom podjele od 1,0°, koji se sastoji od fiksnog kraka za poravnanje s proksimalnom polugom te pokretnog kraka za praćenje distalnog segmenta. Za digitalno mjerenje korištena je tehnička oprema koja se sastojala od prijenosnog računala i monokularne RGB web kamere rezolucije 720p, čvrsto fiksirane na stativ na konstantnoj visini od 1,2 metra te na udaljenosti od točno 2,5 metara od ispitanika. Kako bi se osigurala visoka klinička ponovljivost, sva su mjerenja započinjala iz prirodnog anatomskog neutralnog položaja, odnosno nultog položaja, koji se u fizioterapiji strogo definira kao uspravan stojeći stav s opuštenim ekstremitetima uz tijelo, gdje početna mjerna vrijednost teži kutu od 0°. Mjereno je ukupno pet funkcionalnih kretnji. Pokret fleksije u koljenu, pokret fleksije u kuku, pokret retrofleksije u kuku i pokret fleksije u laktu izvodili su

se u sagitalnoj ravnini s ispitanikom pozicioniranim u bočnom profilu u odnosu na kameru. S druge strane, pokret abdukcije u ramenu izvodio se u frontalnoj ravnini s ispitanikom okrenutim leđima kameri. Prilikom izvođenja pokreta abdukcije u ramenu ispitanici su izvodili obveznu vanjsku rotaciju dlana prema gore pri prelasku razine od 90° kako bi se uspješno prevenirao koštani udar velikog tuberkula o akromion. Za potrebe digitalne evaluacije razvijen je autorski računalni program u jeziku Python, uz integraciju okvira Google MediaPipe (verzija 0.10) za visokopreciznu bezmarkersku ekstrakciju skeletne topologije. Sustav je dizajniran tako da u stvarnom vremenu automatski analizira dvodimenzionalnu udaljenost između ključnih točaka te prepoznaje ravninu gibanja. Prije izvršavanja matematičkog izračuna zglobnog kuta, program provodi rigoroznu validaciju pouzdanosti koordinata provjeravajući ugrađenu komponentu vidljivosti s definiranim graničnim pragom od 0,60. Ako je navedeni uvjet zadovoljen, unutarnji zglobni kut izračunava se primjenom standardnog trigonometrijskog pravila kosinusa nad vektorima proksimalnog i distalnog segmenta. Aplikacija je programirana za izračun čistih apsolutnih geometrijskih kutova izravno u odnosu na dinamički generiranu vertikalnu os ekrana u prostoru, čime se premošćuje potreba za relativnom kalibracijom. Kako bi se uspješno eliminirao visokofrekventni tehnički šum i mikro-podrhtavanje koordinata uslijed niže frekvencije uzorkovanja komercijalne kamere, unutar programskog koda implementirano je dvoetapno zaglađivanje signala kroz filtar pomičnog medijana i eksponencijalni pomični prosjek. Svaki pojedinačni pokret izveden je kroz tri uzastopna ponavljanja. Primijenjen je strogo standardizirani vremenski protokol brzine izvođenja: koncentrična faza kretnje trajala je točno četiri sekunde, izometrijsko zadržavanje u maksimalnoj amplitudi iznosilo je dvije sekunde kako bi filtri prikupili adekvatan broj stabilnih uzoraka, nakon čega je uslijedila ekscentrična faza spuštanja u trajanju od dodatne četiri sekunde. Za obradu podataka program nije očitavao apsolutne minimume i maksimume kretnje koji uslijed vizualnog zamućenja mogu biti podložni nerealnim ekstremnim vrijednostima, već je izdvajao statistički stabilne parametre definirajući neto opseg pokreta kao razliku između 95. i 5. percentila prikupljenih vrijednosti. Cjelokupna statistička obrada konačnih podataka provedena je na razini individualnih aritmetičkih sredina, a validacija točnosti razvijenog računalnog programa utvrđena je strogim izračunom srednje apsolutne pogreške (MAE)

3. Rezultati

Zbirni rezultati komparativne analize mjerenja opsega pokreta manualnim goniometrom i razvijenom aplikacijom prikazani su u Tablici 1.

Analizom zbirnih deskriptivnih pokazatelja vidljivo je da performanse računalnog programa značajno osciliraju ovisno o promatranom zglobu i odabranoj ravnini gibanja. Najviša razina točnosti zabilježena je pri procjeni pokreta retrofleksije u kuku (MAE=2,54°) i pokreta abdukcije u ramenu (MAE=2,55°), gdje su odstupanja između dvaju instrumenata bila minimalna i gotovo zanemariva. Primjerice, kod pokreta abdukcije u ramenu razlika u ukupnim prosjecima iznosila je svega nekoliko stupnjeva, s goniometrijskim prosjekom od 169,44° u odnosu na vrlo sličnih 166,90° izmjerenih računalnim programom. Umjerena, ali klinički prihvatljiva odstupanja zabilježena su kod pokreta velikih amplituda u sagitalnoj ravnini, točnije kod pokreta fleksije u kuku (MAE=6,39°) i pokreta fleksije u koljenu (MAE=6,65°). Kod pokreta fleksije u koljenu, ukupni prosjek manualnog mjerenja iznosio je 118,00°, dok je računalni program zabilježio 117,79°. S obzirom na to da uobičajena standardna pogreška manualnog mjerenja iznosi između 5,0° i 10,0°, ovakvi se rezultati uslijed računalne analize smatraju potpuno zadovoljavajućima za kliničku praksu (Gajdosik i Bohannon, 1987). Detaljnijim uvidom utvrđeno je da programski algoritam računalnog vida

sustavno precjenjuje opseg kod pokreta fleksije u kuku za prosječno 5,0° do 7,0° u odnosu na goniometar. Nasuprot tome, kritično i klinički neprihvatljivo odstupanje registrirano je isključivo kod pokreta fleksije u laktu, gdje je sustav precijenio amplitudu za prosječno 16,03°. Dok je goniometrijski prosjek za lakat iznosio 130,00°, računalni program je neprecizno procijenio amplitudu na čak 146,03°. Navedeno odstupanje znatno premašuje dopuštene granice mjerne pogreške definirane u kineziološkoj literaturi (Gajdosik i Bohannon, 1987; Norkin i White, 2016), što ukazuje na ozbiljnu tehničku limitaciju u sposobnosti dvodimenzionalnog računalnog vida da točno locira distalne segmente podlaktice tijekom izvođenja fleksije.

Tablica 1. *Zbirni prikaz deskriptivnih pokazatelja i validacije točnosti aplikacije (°)*

Pokret i zglob	Ukupni prosjek (Gonio.)	Ukupni prosjek (App.)	MAE
Fleksija koljena	118,00° (SD = 4,30°)	117,79° (SD = 10,93°)	6,65°
Fleksija kuka	119,11° (SD = 3,48°)	125,50° (SD = 3,11°)	6,39°
Retrofleksija kuka	16,00° (SD = 2,12°)	16,96° (SD = 1,73°)	2,54°
Fleksija lakta	130,00° (SD = 5,32°)	146,03° (SD = 8,72°)	16,03°
Abdukcija ramena	169,44° (SD = 2,74°)	166,90° (SD = 3,30°)	2,55°

Legenda: Gonio*. – goniometar,* ***App.*** *– aplikacija,* ***SD*** *– standardna devijacija,* ***MAE*** *– srednja apsolutna pogreška*

4. Rasprava i zaključak

Rezultati ovog istraživanja pokazuju da bezmarkerski sustav temeljen na MediaPipe okviru posjeduje visok potencijal za objektivnu kinezimetriju, ali uz izražena biomehanička ograničenja. Najviša razina točnosti zabilježena je pri evaluaciji pokreta abdukcije u ramenu i pokreta retrofleksije u kuku. Prilikom izvođenja ovih pokreta, cjelokupni promatrani segment ostaje u potpunosti vidljiv i optički neopterećen tijekom cijelog luka gibanja, što neuronskoj mreži omogućuje besprijekorno praćenje ključnih točaka bez rizika od okluzije, odnosno vizualnog preklapanja segmenata. Ovi rezultati potvrđuju da algoritmi računalnog vida pokazuju superiorne performanse isključivo kada se kretnja odvija strogo paralelno s ravninom senzora kamere. S druge strane, kod pokreta velikih amplituda u sagitalnoj ravnini, točnije pri pokretu fleksije u koljenu i pokretu fleksije u kuku, sustav bilježi umjerena odstupanja. Iako tradicionalna manualna goniometrija pri ovim pokretima pati od vlastitih ograničenja, poput problematike palpacije, dinamičkog pomicanja osi rotacije i subjektivnosti ispitivača, računalni algoritam suočava se s drugačijim izazovima. Pri maksimalnoj fleksiji kuka, tijelo prirodno izvodi suptilnu stražnju rotaciju zdjelice i blagu fleksiju lumbalne kralježnice, uslijed čega računalni program gubi savršeni dvodimenzionalni profil i bilježi deformacije vektora (Neumann, 2016). Dodatni biomehanički problem leži u činjenici da kod specifičnih pokreta kuka ljudsko tijelo nema prikladan pomični proksimalni koštani krak koji bi sustavu poslužio kao fiksna referenca za točno mjerenje kuta. Najteže tehničko ograničenje registrirano je kod pokreta fleksije u laktu, a izravna je posljedica optičkog fenomena perspektivnog skraćenja te specifične anatomske građe lakatnog zgloba. Naime, u ovom se kontekstu pod "nosećim kutom" ne podrazumijeva kut opterećenja, već prisutnost prirodnog fiziološkog valgusa koji varira ovisno o tjelesnoj građi i spolu pacijenta. Ta anatomska specifičnost omogućuje ruci da pri ekstenziji ne zapinje za zdjelicu, no pri maksimalnoj fleksiji neizbježno uzrokuje blago medijalno usmjeravanje podlaktice. Zbog tog usmjeravanja šaka i podlaktica izlaze iz izravnog profila kamere, a budući da monokularna

kamera ne posjeduje dubinski senzor, svako odstupanje izvan ravnine algoritam percipira isključivo kao dvodimenzionalno geometrijsko skraćenje poluge (Martins i sur., 2023). Iako su rezultati ovog pilot-istraživanja iznimno indikativni, nužno ih je interpretirati u kontekstu metodoloških ograničenja samog rada. Uzorak je bio prigodan, izrazito malen i sastavljen isključivo od zdravih studenata muškog spola bez prisutnih patologija mišićno-koštanog sustava. U stvarnoj kineziterapijskoj praksi pacijenti često prezentiraju atipične obrasce pokreta, zglobne kontrakture, mišićne spazme te antalgične obrasce praćene boli i kineziofobijom. Buduća istraživanja trebala bi uključiti veći broj pacijenata s dijagnosticiranim patologijama kako bi se utvrdilo može li razvijeni algoritam uspješno prepoznati i kompenzirati takve atipične biomehaničke devijacije. Nadalje, statična priroda testnog protokola uz ekstremno sporo izvođenje pokreta ne odražava u potpunosti dinamične uvjete iz funkcionalne kinezimetrije, gdje je brzina kretnje znatno veća, što kod standardnih kamera stvara dodatno vizualno zamućenje. Unatoč navedenim ograničenjima računalne i tehničke opreme, razvijena aplikacija nudi obećavajuće mogućnosti za modernizaciju fizioterapije. Problem perspektivnog skraćenja i niske frekvencije uzorkovanja mogao bi se uspješno riješiti upotrebom naprednijih dubinskih senzora ili korištenjem kvalitetnijih kamera na modernim pametnim telefonima u kombinaciji s nosivim inercijalnim mjernim jedinicama (IMU). Takva integracija omogućuje da računalni vid postane ne samo pristupačan dijagnostički alat u ambulanti, već i temelj za pametne aplikacije koje pacijentima pružaju vizualnu povratnu informaciju u stvarnom vremenu za sigurno i neovisno provođenje rehabilitacije kod kuće.

5. Literatura

1. Clarkson, H. M. (2005). Joint Motion and Function Assessment: A Research-Based Practical Guide. Baltimore: Lippincott Williams & Wilkins.
2. Gajdosik, R. L. i Bohannon, R. W. (1987). Clinical goniometry: a review of the literature. Physical Therapy, 67(12), 1867-1872.
3. Lugaresi, C. i sur. (2019). MediaPipe: A Framework for Building Perception Pipelines. arXiv [Preprint].
4. Martins, J., Carvalho, V. i Soares, F. (2023). Validation of a markerless pose estimation system based on MediaPipe for upper limb rehabilitation tracking. Computer Methods and Programs in Biomedicine, 231, 107412.
5. Neumann, D. A. (2016). Kinesiology of the Musculoskeletal System: Foundations for Rehabilitation (3. izd.). St. Louis: Mosby Elsevier.
6. Norkin, C. C. i White, D. J. (2016). Measurement of Joint Motion: A Guide to Goniometry (5. izd.). Philadelphia: F.A. Davis Company.
7. Zulle, M., Fužinac-Smojver, A. i Lulić Drenjak, J. (2012). Mjerenje opsega pokreta i antropometrijsko mjerenje. Rijeka: Medicinski fakultet Sveučilišta u Rijeci.