



**Kauno technologijos universitetas**

Informatikos fakultetas

# **Mašininio mokymosi metodų taikymas analizuojant viršutinių galūnių reabilitacijos pratimus**

Baigiamasis magistro studijų projektas

---

**Timas Akelis**

Projekto autorius

**m.d. dr. Valdas Grigaliūnas**

Vadovas

---

**Kaunas, 2026**



**Kauno technologijos universitetas**

Informatikos fakultetas

# **Mašininio mokymosi metodų taikymas analizuojant viršutinių galūnių reabilitacijos pratimus**

Baigiamasis magistro studijų projektas

Dirbtinio intelekto informatika (6211BX007)

---

**Timas Akelis**

Projekto autorius

**m.d. dr. Valdas Grigaliūnas**

Vadovas

**doc. prakt. Vytenis Punys**

Recenzentas

---

**Kaunas, 2026**



**Kauno technologijos universitetas**

Informatikos fakultetas

Timas Akelis

## **Mašininio mokymosi metodų taikymas analizuojant viršutinių galūnių reabilitacijos pratimus**

Akademinio sąžiningumo deklaracija

Patvirtinu, kad:

1. baigiamąjį projektą parengiau savarankiškai ir sąžiningai, nepažeisdamas kitų asmenų autoriaus ar kitų teisių, laikydamasis Lietuvos Respublikos autorių teisių ir gretutinių teisių įstatymo nuostatų, Kauno technologijos universiteto (toliau – Universitetas) intelektinės nuosavybės valdymo ir perdavimo nuostatų bei Universiteto akademinės etikos kodekse nustatytų etikos reikalavimų;
2. baigiamajame projekte visi pateikti duomenys ir tyrimų rezultatai yra teisingi ir gauti teisėtai, nei viena šio projekto dalis nėra plagijuota nuo jokių spausdintinių ar elektroninių šaltinių, visos baigiamojo projekto tekste pateiktos citatos ir nuorodos yra nurodytos literatūros sąrašė;
3. įstatymų nenumatytų piniginių sumų už baigiamąjį projektą ar jo dalis niekam nesu mokėjęs;
4. suprantu, kad išaiškėjus nesąžiningumo ar kitų asmenų teisių pažeidimo faktui, man bus taikomos akademinės nuobaudos pagal Universitete galiojančią tvarką ir būsiu pašalintas iš Universiteto, o baigiamasis projektas gali būti pateiktas Akademinės etikos ir procedūrų kontrolieriaus tarnybai nagrinėjant galimą akademinės etikos pažeidimą.

Timas Akelis

*Patvirtinta elektroniniu būdu*

Timas Akelis. Mašininio mokymosi metodų taikymas analizuojant viršutinių galūnių reabilitacijos pratimus. Magistro studijų baigiamasis projektas / vadovas m.d. dr. Valdas Grigaliūnas; Kauno technologijos universitetas, Informatikos fakultetas.

Studijų kryptis ir sritis (studijų krypčių grupė): Informatikos mokslai, Informatika (B01).

Reikšminiai žodžiai: reabilitacija, mašininis mokymasis, „MediaPipe“, kompiuterinė rega.

Kaunas, 2026. 56 p.

### **Santrauka**

Šiame darbe nagrinėjamos kompiuterinio intelekto metodų taikymo galimybės vertinant viršutinių galūnių reabilitacinių pratimų atlikimą, remiantis vaizdiniais duomenimis. Tyrimo aktualumą lemia augantis automatizuotų sprendimų poreikis sveikatos priežiūros srityje, siekiant objektyviai ir nuosekliai įvertinti paciento atliekamus judesius.

Tyrimo metu analizuojami vaizdo įrašai, kuriuose užfiksuoti viršutinių galūnių judesiai atliekant reabilitacinius pratimus. Žmogaus kūno skeleto aptikimui ir pagrindinių sąnarių taškų išgavimui taikytas „MediaPipe“ algoritmas, leidžiantis iš vaizdinių duomenų išskirti struktūrizuotą judesio informaciją. Remiantis gautais skeleto duomenimis, buvo apskaičiuojami judesių parametrai, tokie kaip kampai tarp sąnarių, judesio trajektorijos bei stabilumo rodikliai.

Darbo metu sukurti ir pritaikyti mašininio mokymosi modeliai, skirti įvertinti pratimų atlikimo kokybę. Tyrime analizuojamas skirtingų modelių efektyvumas, lyginant jų gebėjimą atpažinti taisyklingus ir netaisyklingus judesius. Vertinimas atliekamas remiantis iš vaizdo duomenų išgautais požymiais.

Gauti rezultatai parodė, kad kompiuterinio intelekto metodai, derinami su skeleto aptikimo algoritmais, gali būti sėkmingai taikomi automatizuotam reabilitacinių pratimų vertinimui. Modeliai geba identifikuoti netikslius ar neteisingai atliekamus judesius bei suteikia pagrindą objektyviam vertinimui. Nustatyta, kad tokie sprendimai gali padidinti vertinimo nuoseklumą ir sumažinti subjektyvumo įtaką.

Tyrimo rezultatai patvirtina kompiuterinio intelekto potencialą reabilitacijos srityje ir sudaro prielaidas tolimesniems tyrimams, orientuotiems į pažangesnius judesių analizės metodus bei realaus laiko vertinimo sistemas.

Timas Akelis. Application of Machine Learning Methods in Analyzing Upper Limb Rehabilitation Exercises. Master's Final Degree Project / supervisor m.d. dr. Valdas Grigaliūnas; Faculty of Informatics, Kaunas University of Technology.

Study field and area (study field group): Computer science, Informatics (B01).

Keywords: rehabilitation, machine learning, “MediaPipe”, computer vision.

Kaunas, 2026. 56 pages.

### **Summary**

This study investigates the application of artificial intelligence methods for evaluating the performance of upper limb rehabilitation exercises based on visual data. The relevance of the research is driven by the increasing demand for automated solutions in the healthcare domain, aiming to objectively and consistently assess patient movements.

The study analyzes video recordings capturing upper limb movements during rehabilitation exercises. For human body skeletal detection and extraction of key joint points, the MediaPipe algorithm was employed, enabling the transformation of visual data into structured motion information. Based on the extracted skeletal data, motion parameters such as joint angles, movement trajectories, and stability metrics were calculated.

During the research, machine learning models were developed and applied to evaluate the quality of exercise performance. The study examines the effectiveness of different models by comparing their ability to distinguish between correct and incorrect movements. The evaluation is performed using features extracted from video data.

The obtained results demonstrate that artificial intelligence methods, combined with skeletal detection algorithms, can be effectively applied for automated assessment of rehabilitation exercises. The models are capable of identifying inaccurate or improperly executed movements and provide a basis for objective evaluation. It was determined that such solutions can enhance evaluation consistency and reduce the impact of subjectivity.

The results of the study confirm the potential of artificial intelligence in the field of rehabilitation and provide a foundation for future research focused on more advanced motion analysis methods and real-time assessment systems.

## Turinys

Lentelių sąrašas .....	7
Paveikslų sąrašas .....	8
Santrumpų ir terminų sąrašas .....	9
Įvadas.....	10
<b>1. DI metodų taikymo reabilitacijos pratimų analizei apžvalga .....</b>	<b>11</b>
1.1. DI taikymas reabilitacijoje .....	11
1.2. Judesių analizė.....	12
1.3. Klasifikavimo metodai .....	15
1.4. Paaškinamojo dirbtinio intelekto panaudojimo galimybės .....	16
1.5. Apibendrinimas .....	17
<b>2. Judesių analizės ir klasifikavimo metodologija .....</b>	<b>19</b>
2.1. Tyrimo metodinis modelis.....	19
2.2. Duomenų aprašymas .....	20
2.3. Duomenų paruošimas ir požymių išgavimas.....	21
2.4. Mašininio mokymosi modelių kūrimas ir taikymas .....	23
<b>3. Reabilitacijos pratimų klasifikavimo, vertinimo ir XAI analizės rezultatai.....</b>	<b>25</b>
3.1. Pratimų klasifikacijos eksperimentas ir rezultatai .....	25
3.1.1. Klasifikacijos uždavinio motyvacija .....	25
3.1.2. Pratimų klasifikacijai naudotų duomenų struktūra.....	26
3.1.3. Modelio architektūra ir mokymo metodika.....	28
3.1.4. Pratimų klasifikacijos rezultatai .....	28
3.1.5. Apibendrinimas .....	30
3.2. Pratimų atlikimo teisingumo klasifikavimo uždavinys .....	31
3.2.1. Naudotas modelis ir alternatyvių architektūrų vertinimas.....	31
3.2.2. Bendrų pratimų atlikimo teisingumo klasifikacijos rezultatų analizė .....	33
3.2.3. Teisingumo analizė pagal kiekvieną pratimą .....	35
3.2.4. Klaidų analizė ir interpretacija .....	36
3.2.5. Skyriaus apibendrinimas .....	38
3.3. Paaškinamųjų dirbtinio intelekto (XAI) metodų taikymas pratimų teisingumo analizei.....	38
3.3.1. XAI poreikis .....	38
3.3.2. Naudoti XAI metodai ir jų taikymo logika.....	39
3.3.3. Bendroji požymių svarbos analizė.....	42
3.3.4. Universalių pratimų kokybės rodiklių biomechaninė interpretacija .....	44
3.3.5. Požymių svarbos analizė pagal atskirus pratimus .....	46
3.3.6. Modelio generalizacijos ir specializacijos balansas .....	47
3.3.7. XAI reikšmė rezultatų patikimumui ir klinikinei interpretacijai.....	49
3.3.8. Apibendrinimas .....	51
<b>Išvados .....</b>	<b>52</b>
<b>Dirbtinio intelekto įrankių naudojimas.....</b>	<b>53</b>
<b>Literatūros sąrašas .....</b>	<b>54</b>

## Lentelių sąrašas

3.1 lentelė. Naudotų 117 biomechaninių požymių grupės, jų apimtis ir apskaičiavimo metodologija .....	27
3.2 lentelė. Skirtingos modelio architektūros .....	32
3.3 lentelė. Modelio rezultatai per pratimą.....	35
3.4 lentelė. Rezultatų pasiskirstymas pagal atskirus pratimus.....	36
3.5 lentelė. Konkrečių pratimų biomechaninių požymių svarbos palyginimas.....	46

## Paveikslų sąrašas

1.1 pav. Skeletinė žmogaus pozos reprezentacija gauta iš vaizdinės medžiagos [16] .....	13
1.2 pav. Pirštų trajektorijos judesio metu pavyzdys [19] .....	14
1.3 pav. Simetriškų viršutinių galūnių judesių pavyzdys: a) – kairės rankos; b) – dešinės rankos judesio amplitudės [20] .....	15
2.1 pav. Pratimo vaizdas be skeletinės reprezentacijos ir su skeletine reprezentacija .....	21
3.1 pav. Nagrinėjamų pratimų tipai .....	25
3.2 pav. Pratimų klasifikavimo pasiskirstymo matrica .....	29
3.3 pav. Klasifikavimo kryžminės entropijos nuostolių grafikas .....	30
3.4 pav. Mokymo ir validacijos nuostolių grafikas .....	34
3.5 pav. Klasifikacijos maišaties matrica .....	35
3.6 pav. Gradiento paremtų įvesčių svarba.....	40
3.7 pav. Permutacijų požymių svarbos grafikas .....	41
3.8 pav. Paaiškinamųjų DI metodų palyginimas skirtingiems požymiams .....	42
3.9 pav. Įvesties pasiskirstymas teisingo ir neteisingo pratimo atžvilgiu.....	43
3.10 pav. Svarbiausių požymių, leidžiančių nustatyti judesio kokybę, grafikas .....	45
3.11 pav. Pratimų požymių koreliacijų matrica.....	48

## Santrumpų ir terminų sąrašas

### Santrumpos:

DI – dirbtinis intelektas.

MM – mašininis mokymasis.

VR – virtuali realybė.

XAI – paaiškinamasis dirbtinis intelektas (angl. Explainable Artificial Intelligence).

SHAP – *SHapley Additive exPlanations* metodas.

LIME – *Local Interpretable Model-agnostic Explanations* metodas.

ReLU – tiesinė aktyvacijos funkcija su nuline neigiama dalimi (*Rectified Linear Unit*).

### Terminai:

**Biomechaniniai požymiai** – iš žmogaus judesių apskaičiuojami kiekybiniai parametrai, apibūdinantys judesio trajektoriją, kampus, simetriją, stabilumą ar judesio kokybę.

**MediaPipe** – „Google“ sukurta sistema žmogaus kūno pozos ir judesių analizei realiu laiku.

**Skeletinė reprezentacija** – žmogaus kūno modelis, sudarytas iš tarpusavyje susietų sąnarių taškų, naudojamas judesių analizei.

**Permutavimas (*Permutation*)** – duomenų arba požymių reikšmių atsitiktinis permaišymas, naudojamas modelio jautrumui ar požymių svarbai vertinti.

**Kineziologija (*Kinesiology*)** – mokslas, tiriantis žmogaus judesius, jų biomechaniką ir funkcinis aspektus.

**Atsitiktinis neuronų išjungimas (*Dropout*)** – neuroninių tinklų reguliavimo metodas, kurio metu dalis neuronų mokymo metu atsitiktinai išjungiami siekiant sumažinti modelio persimokymą (*overfitting*).

**Sigmoidinė aktyvacijos funkcija (*Sigmoid activation*)** – aktyvacijos funkcija, transformuojanti reikšmes į intervalą nuo 0 iki 1 ir dažnai naudojama dvejetainės klasifikacijos uždaviniuose.

**BCEWithLogitsLoss** – dvejetainės kryžminės entropijos nuostolių funkcija su integruota sigmoidine aktyvacija (*Binary Cross-Entropy with Logits Loss*), naudojama dvejetainės klasifikacijos modelių mokymui.

## Įvadas

Reabilitacija yra esminė sveikatos priežiūros dalis, kurios tikslas yra atkurti arba pagerinti paciento funkcinį pajėgumą po traumų, neurologinių sutrikimų ar lėtinių ligų. Viršutinių galūnių funkcionalumo sutrikimai yra viena dažniausių problemų, todėl reabilitacijos procesas tampa svarbia pacientų gydymo ir gyvenimo kokybės atkūrimo dalimi. Reabilitacinių pratimų efektyvumas dažnai priklauso nuo to, kaip tiksliai ir nuosekliai pacientas atlieka paskirtus judesius. Tačiau praktikoje pratimų vertinimas dažnai remiasi specialisto vizualiniu stebėjimu ir subjektyvia patirtimi, todėl atsiranda poreikis objektyvesniems ir automatizuotiems vertinimo metodams.

Pastaraisiais metais sparčiai vystantis kompiuterinio intelekto technologijoms atsirado galimybė žmogaus judesių analizei taikyti vaizdinių duomenų apdorojimo bei mašininio mokymosi metodus. Žmogaus kūno skeletinių taškų nustatymo algoritmai leidžia iš vaizdo įrašų išgauti struktūrizuotą informaciją apie kūno judesius, o neuroniniai tinklai suteikia galimybę automatiškai atpažinti sudėtingus judesių modelius bei vertinti jų atlikimo kokybę. Dėl to didėja poreikis kurti išmanias reabilitacijos vertinimo sistemas, galinčias padėti specialistams stebėti pacientų pažangą ir objektyviau vertinti pratimų atlikimą, ypač nuotolinės reabilitacijos ir telemedicinos kontekste.

Darbo naujumą sudaro kelių skirtingų neuroninių tinklų architektūrų pritaikymas viršutinių galūnių reabilitacinių pratimų analizei naudojant iš vaizdo įrašų išgautus biomechaninius požymius. Tyrime nagrinėjamas ne tik skirtingų pratimų klasifikavimo uždavinys, bet ir pratimų atlikimo kokybės vertinimas, kuriam skiriamas pagrindinis dėmesys. Modeliai analizuojami naudojant *XAI* siekiant nustatyti jų gebėjimą atskirti taisyklingai ir netaisyklingai atliekamus judesius bei identifikuoti svarbiausius biomechaninius požymius, darančius įtaką vertinimo rezultatams.

**Darbo tikslas** – ištirti mašininio mokymosi metodų taikymo galimybes viršutinių galūnių reabilitacijos pratimų analizei, remiantis iš vaizdo duomenų išgautais biomechaniniais požymiais.

### **Darbo uždaviniai:**

1. išanalizuoti mokslinę literatūrą, nagrinėjančią dirbtinio intelekto ir mašininio mokymosi metodų taikymą reabilitacijos judesių analizei ir vertinimui;
2. paruošti reabilitacijos vaizdo duomenų rinkinį ir išgauti skeletinę judesių informaciją;
3. suformuoti biomechaninių požymių rinkinį, apibūdinantį viršutinių galūnių judesių dinamiką, stabilumą ir simetriją;
4. klasifikuoti reabilitacijos pratimų tipus taikant mašininio mokymosi modelius ir įvertinti šio klasifikavimo tinkamumą;
5. įvertinti skirtingų neuroninių tinklų architektūrų taikymo galimybes, klasifikuojant reabilitacijos pratimų atlikimo taisyklingumą;
6. įvertinti biomechaninių požymių įtaką modelių sprendimams, taikant paaiškinamojo dirbtinio intelekto metodus.

Tyrimas sudarytas iš trijų pagrindinių dalių: pirmame skyriuje analizuojami dirbtinio intelekto, judesių analizės, klasifikavimo metodų ir *XAI* taikymo reabilitacijoje moksliniai pagrindai. Antrame skyriuje aprašoma tyrimo metodologija – naudotas duomenų rinkinys, vaizdo įrašų segmentavimas, skeletinės informacijos išgavimas, biomechaninių požymių formavimas ir mašininio mokymosi modelių kūrimas. Trečiame skyriuje pateikiami pratimų klasifikavimo, atlikimo teisingumo vertinimo ir paaiškinamojo dirbtinio intelekto analizės rezultatai, o darbo pabaigoje suformuluojamos pagrindinės išvados.

## 1. DI metodų taikymo reabilitacijos pratimų analizei apžvalga

### 1.1. DI taikymas reabilitacijoje

Dirbtinio intelekto ir mašininio mokymosi metodai pastaraisiais metais vis plačiau taikomi sveikatos priežiūros srityje, siekiant pagerinti diagnostikos, gydymo ir paciento būklės stebėsenos procesus. Reabilitacijoje šie metodai ypač aktualūs dėl didelio judesių duomenų kiekio ir poreikio objektyviai įvertinti paciento funkcinę būklę laikui bėgant [1, 2]. Mokslinėje literatūroje pabrėžiama, kad automatizuota judesių analizė gali padėti sumažinti subjektyvaus vertinimo įtaką ir sudaryti sąlygas nuoseklesniam paciento progreso sekimui [3, 4].

Vienas pagrindinių dirbtinio intelekto taikymo reabilitacijoje tikslų – automatizuotas paciento judesių vertinimas, leidžiantis identifikuoti tiek bendrus funkcinis sutrikimus, tiek subtilius judesių kokybės pokyčius. Tyrimuose nurodoma, kad mašininio mokymosi modeliai gali būti sėkmingai taikomi vertinant judesių amplitudę, koordinaciją, simetriją bei judesių tolygumą [1, 4]. Tokie rodikliai yra tiesiogiai susiję su reabilitacijos proceso efektyvumu ir dažnai naudojami klinikinėje praktikoje kaip paciento progreso indikatoriai.

Naujausi tyrimai rodo, kad biomechaniniai ir kinematiniai rodikliai gali būti naudojami ne tik bendram judesio vertinimui, bet ir funkcinį pokyčių stebėjimui skirtingų reabilitacijos metodų metu. Hwang ir kt. nustatė, kad aktyvios robotinės terapijos atveju su paciento būklės pagerėjimu labiau siejosi judesio greičio rodikliai, o aktyviai-asistuojamos terapijos metu didesnę svarbą turėjo judesio tolygumo požymiai [5]. Tai rodo, kad skirtingi biomechaniniai požymiai gali atspindėti skirtingus motorinės funkcijos aspektus.

Literatūroje išskiriamos kelios pagrindinės dirbtinio intelekto taikymo kryptys reabilitacijoje. Viena jų – judesių ar pratimų atpažinimas, kai modeliai klasifikuoja paciento atliekamus veiksmus pagal judesių sekas ar laikinius požymius [6, 7]. Kita kryptis – reabilitacijos pratimų atlikimo kokybės vertinimas, kurio metu siekiama nustatyti, ar pratimas atliekamas taisyklingai, atsižvelgiant į biomechaninius kriterijus [8, 9]. Pastaroji kryptis laikoma sudėtingesne, nes reikalauja ne tik atpažinti judesį, bet ir įvertinti jo kokybinius aspektus.

Nemaža dalis ankstesnių tyrimų reabilitacijos srityje remiasi specializuotais jutikliais, tokiais kaip inerciniai matavimo įrenginiai ar elektromiografijos sistemos, leidžiančios tiksliai registruoti judesių parametrus [4, 9]. Nors šie metodai pasižymi dideliu matavimo tikslumu, jie dažnai reikalauja papildomos įrangos, sudėtingo paruošimo ir riboja praktinį pritaikymą kasdienėje klinikinėje aplinkoje [3]. Dėl šios priežasties vis didesnis dėmesys skiriamas vaizdo duomenimis pagrįstiems sprendimams, kurie leidžia analizuoti judesius, naudojant įprastas kameras ir sumažinti technologinius barjerus [1, 10].

Be vaizdo duomenų analizės, naujesniuose tyrimuose taip pat nagrinėjamas multimodalinių duomenų panaudojimas reabilitacijos sistemose. Abdallah ir kt. pristatė hibridinę reabilitacijos sistemą, jungiančią robotiką, elektromiografinius signalus ir dirbtinio intelekto metodus paciento būklės bei raumenų nuovargio vertinimui [11]. Tokie sprendimai rodo tendenciją integruoti kelis biomechaninių duomenų šaltinius siekiant tikslesnio funkcinį sutrikimų vertinimo.

Tačiau, nepaisant sparčios metodų plėtros, literatūroje akcentuojama, kad daugelis dirbtinio intelekto modelių veikia kaip sudėtingos „juodosios dėžės“, kurių sprendimų priėmimo logika nėra lengvai

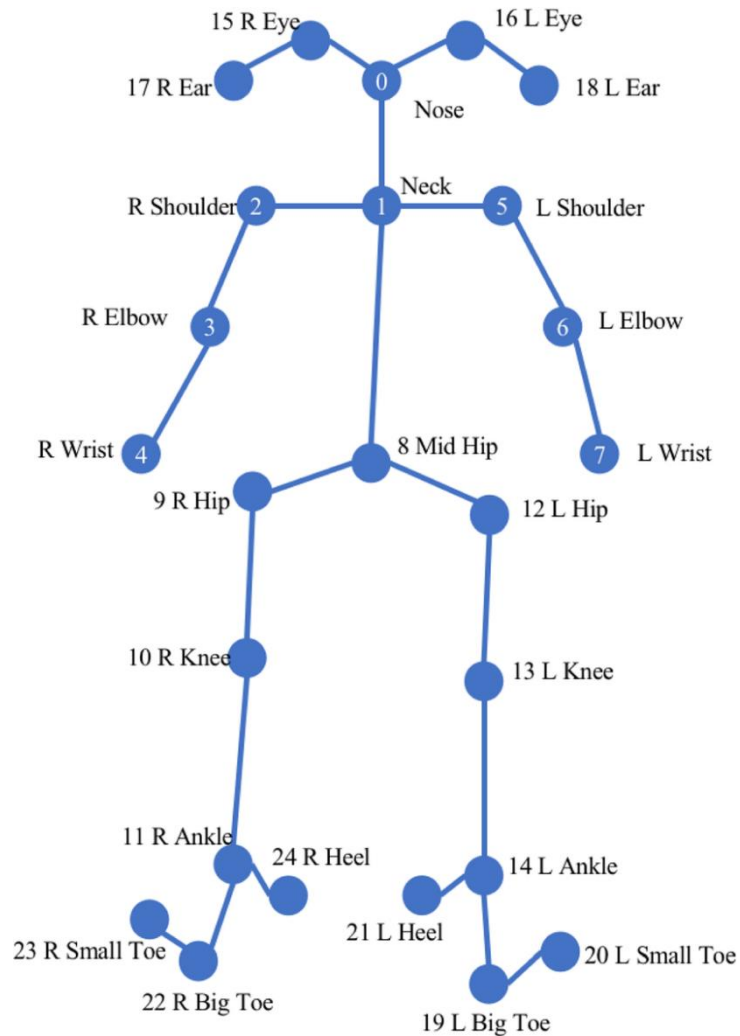
interpretuojama [12, 13]. Klinikinėje praktikoje tai kelia pasitikėjimo problemą, nes reabilitacijos specialistams svarbu suprasti, kodėl modelis priėmė vieną ar kitą sprendimą [8]. Dėl šios priežasties pastaraisiais metais vis daugiau dėmesio skiriama paaiškinamojo dirbtinio intelekto metodams (*XAI*), kurie leidžia susieti modelių sprendimus su fiziškai ir biomechanškai prasmingais požymiais.

Dirbtinio intelekto metodai turi didelį potencialą reabilitacijos srityje, ypač vertinant automatizuotus judesius. Vis dėlto išlieka poreikis tyrimams, kurie ne tik įvertintų modelių tikslumą, bet ir analizuotų, kokiais biomechaniniais požymiais šie modeliai remiasi priimdami sprendimus. Šis aspektas tampa esminis, siekiant užtikrinti tokių metodų patikimumą ir pagrįstumą reabilitacijos kontekste.

## **1.2. Judesių analizė**

Žmogaus judesių analizė reabilitacijos kontekste yra viena pagrindinių priemonių objektyviai vertinant paciento funkcinę būklę ir terapijos efektyvumą. Mokslinėje literatūroje pabrėžiama, kad judesių vertinimas turėtų būti grindžiamas kiekybiniais biomechaniniais rodikliais, leidžiančiais apibūdinti ne tik judesio faktą, bet ir jo atlikimo kokybę [1, 4]. Tokie rodikliai apima sąnarių padėtis, judesių amplitudę, judesių eigą laike, simetriją bei judėjimo tolygumą. Literatūroje pažymima, kad dinaminiai biomechaniniai rodikliai, tokie kaip judesio greitis ar trajektorijos stabilumas, gali būti tiesiogiai siejami su klinikiniais viršutinių galūnių funkcijos vertinimais po insulto [14, 5]. Tai pagrindžia poreikį analizuoti ne tik statines sąnarių padėtis, bet ir visą judesio eigą laike.

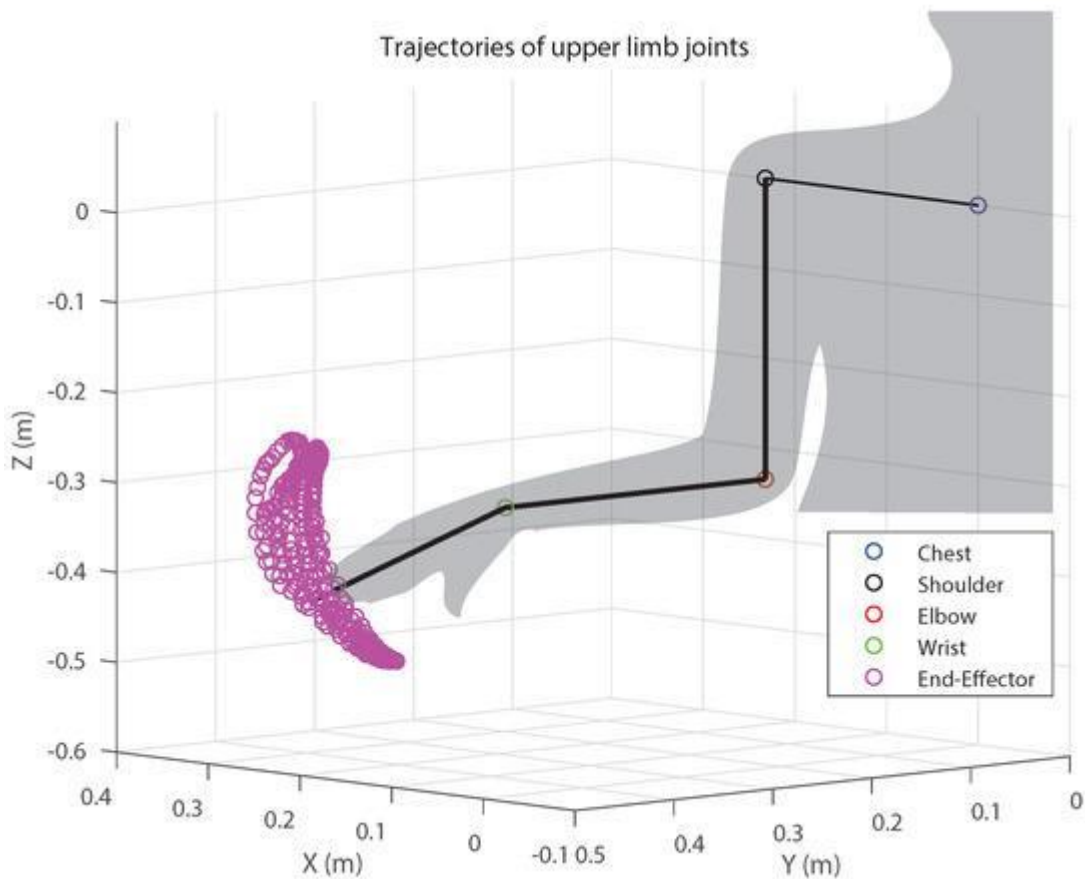
Vienas plačiausiai taikomų požiūrių reabilitacijos judesių analizėje yra skeletinės informacijos naudojimas. Skeletinė reprezentacija aprašo žmogaus kūną kaip tarpusavyje susijusių sąnarių ir segmentų sistemą, leidžiančią analizuoti judesius nepriklausomai nuo vaizdo fono, apšvietimo ar individualių antropometrinių skirtumų [10]. Tokia reprezentacija laikoma ypač tinkama automatizuotai analizei, nes sumažina vaizdo duomenims būdingą triukšmą ir leidžia susikoncentruoti į patį judesį. Sisteminėje kompiuterinės regos technologijų apžvalgoje pažymima, kad skeletinės žmogaus pozos reprezentacijos tapo viena svarbiausių automatizuotos judesių analizės krypčių judėjimo sutrikimų tyrimuose [15]. Tokie metodai leidžia sumažinti vaizdo duomenų sudėtingumą ir efektyviai išskirti biomechanškai reikšmingus požymius.



1.1 pav. Skeletinė žmogaus pozos reprezentacija gauta iš vaizdinės medžiagos [16]

Kaip matyti paveiksle (1.1 pav.), žmogaus judesiai reprezentuojami per pagrindinius kūno sąnarius, tokius kaip pečiai, alkūnės, riešai ir klubai. Šių sąnarių padėčių kitimas laike sudaro pagrindą tolimesnei biomechaninei analizei. Remiantis tokiais duomenimis, išgaunami erdviniai požymiai, leidžiantys vertinti judesio trajektorijas ir amplitudes, kurios yra svarbios nustatant, ar reabilitacijos pratimas atliekamas pilna judesio apimtimi [4, 9, 17].

Judesių trajektorijų analizė leidžia nustatyti ne tik judesio ribas, bet ir galimus nuokrypius ar kompensacinius judesius. Pavyzdžiui, riešo ar alkūnės judėjimo trajektorija (1.2 pav.) gali atskleisti netolygų judesį arba sumažintą judesio amplitudę, kas dažnai siejama su funkciniu sutrikimu ar netaisyklingu pratimo atlikimu [8, 9, 18].




1.2 pav. Pirštų trajektorijos judesio metu pavyzdys [19]

Be sąnarių padėčių ir trajektorijų, reikšmingą vaidmenį atlieka sąnarių kampai, apibūdinantys kūno segmentų tarpusavio orientaciją. Sąnarių kampai leidžia tiesiogiai vertinti judesio biomechaninį teisingumą, nes atspindi, ar judesys atliekamas fiziologiškai pagrįstose ribose [1, 8]. Skirtingai nei absoliučios padėties, kampiniai požymiai yra mažiau jautrūs kameros padėčiai ir individualiems kūno proporcijų skirtumams, todėl plačiai naudojami reabilitacijos tyrimuose.

Svarbi judesių analizės dalis yra judesio eiga laike. Literatūroje pabrėžiama, kad judesio kokybė reabilitacijos metu dažnai pasireiškia ne galutinėje padėtyje, o per visą judesio atlikimo procesą [9]. Tokie dinaminiai rodikliai kaip judesio greitis, pagreitis ar tolygumas leidžia nustatyti, ar judesys atliekamas sklandžiai, ar pasižymi staigiais, trūkčiojančiais pokyčiais, kurie gali rodyti prastą motorinę kontrolę [18]. Todėl judesio tolygumas laikomas svarbiu reabilitacijos pratimų kokybės indikatoriumi [8]. Hwang ir kt. tyrime taip pat nustatyta, kad judesio tolygumo rodikliai yra reikšmingai susiję su pacientų motorinės funkcijos pagerėjimu robotinės reabilitacijos metu [5]. Tai papildomai sustiprina šių požymių svarbą automatizuotame judesių kokybės vertinime.

Vertinant viršutinių galūnių reabilitacijos pratimus, ypatingas dėmesys skiriamas judesių simetrijai (1.3 pav.). Asimetriški judesiai dažnai interpretuojami kaip kompensacinio elgesio požymis, kai pacientas viena kūno puse kompensuoja kitos pusės silpnumą [3, 4]. Tokiais atvejais net ir iš pažiūros teisingai atliekamas pratimas gali neatitikti reabilitacijos tikslų.



1.3 pav. Simetriškų viršutinių galūnių judesių pavyzdys: a) – kairės rankos; b) – dešinės rankos judesio amplitudės [20]

Apibendrinant galima teigti, kad judesių analizė, pagrįsta skeletiniais duomenimis ir biomechaniniais požymiais, sudaro tvirtą pagrindą automatizuotam reabilitacijos pratimų vertinimui. Literatūroje išskiriami *erdviniai*, *kampiniai*, *dinaminiai* ir *simetrijos* požymiai, kurie kartu leidžia kompleksiskai vertinti judesio kokybę [1, 8]. Vis dėlto daugelyje tyrimų šie požymiai analizuojami fragmentiškai, ne jungiant jų į vieningą analizės sistemą. Tai išryškina poreikį tyrimams, kurie integruotai *vertintų* biomechaninius požymius tiek reabilitacijos pratimų klasifikacijos, tiek judesio kokybės *vertinimo analizės* kontekste [14, 21].

### 1.3. Klasifikavimo metodai

Automatizuotas reabilitacijos pratimų analizavimas dažniausiai apima dvi tarpusavyje susijusias, tačiau konceptualiai skirtingas užduotis: pratimų tipų atpažinimą ir pratimų atlikimo kokybės vertinimą. Mokslinėje literatūroje pabrėžiama, kad šių užduočių sprendimas reikalauja skirtingų metodologinių požiūrių, nors abi remiasi tais pačiais judesių duomenimis [1, 9, 22].

Pratimų klasifikavimo užduotyje siekiama automatiškai nustatyti, kokio tipo reabilitacijos pratimą pacientas atlieka. Ši problema dažniausiai formuluojama kaip daugiaklasė klasifikacija, kurioje modeliai mokomi atpažinti judesių struktūrinius skirtumus, pasireiškiančius per sąnarių padėčių, kampų ar judesių trajektorijų sekas [6, 10, 14]. Tyrimuose nurodoma, kad tinkamai parinkti biomechaniniai požymiai leidžia pasiekti aukštą pratimų atpažinimo tikslumą, net ir naudojant santykinai paprastas neuroninių tinklų architektūras [1, 4, 21].

Kita, metodologiškai sudėtingesnė užduotis yra reabilitacijos pratimų atlikimo kokybės vertinimas. Šiuo atveju tikslas nėra atpažinti patį judesį, bet nustatyti, ar jis atliekamas taisyklingai, laikantis biomechaninių ir terapinių reikalavimų. Literatūroje pažymima, kad net to paties pratimo atveju teisingas ir neteisingas atlikimas gali skirtis subtiliais judesių kokybės aspektais, tokiais kaip judesio tolygumas, simetrija ar kampų stabilumas [8, 9]. Dėl šios priežasties atlikimo kokybės vertinimas laikomas viena sudėtingiausių automatizuotos reabilitacijos analizės problemų.

Sprendžiant šias užduotis, literatūroje taikomi įvairūs mašininio mokymosi metodai – nuo tradicinių klasifikatorių, tokių kaip atraminių vektorių mašinos ar atsitiktiniai miškai, iki giliųjų neuroninių tinklų modelių [1, 2, 21, 22]. Nors sudėtingesni modeliai dažnai pasižymi didesniu tikslumu, tyrimuose pabrėžiama, kad jų veikimas stipriai priklauso nuo požymių parinkimo ir duomenų

paruošimo kokybės [6, 11]. Tai ypač aktualu reabilitacijos kontekste, kur duomenų kiekiai dažnai yra riboti, o modelių permokymo (angl. *overfitting*) rizika – didelė. Literatūroje taip pat pažymima, kad papildomų signalų, tokių kaip elektromiografijos duomenys, integravimas gali padidinti modelių jautrumą paciento būklės pokyčiams [11, 23]. Tačiau tokie sprendimai dažnai padidina sistemų sudėtingumą ir apsunkina jų praktinį pritaikymą kasdienėje klinikinėje aplinkoje.

Svarbus aspektas, išskiriamas literatūroje, yra pratimų klasifikavimo ir atlikimo kokybės vertinimo tarpusavio ryšys. Kai kuriuose tyrimuose šios užduotys sprendžiamos atskirai, o kituose – integruotai, pavyzdžiui, pirmiausia nustatant pratimo tipą, o vėliau vertinant jo atlikimo teisingumą [9]. Tokia hierarchinė analizė leidžia taikyti skirtingus vertinimo kriterijus skirtingiems pratimams, tačiau kartu padidina sistemos sudėtingumą ir reikalauja aiškios metodologinės struktūros. Panašus principas taikomas ir personalizuotose robotinės reabilitacijos sistemose, kuriose pirmiausia nustatoma paciento judesio būseną, o vėliau adaptyviai koreguojama pagalbinio judesio trajektorija [23]. Tokie metodai rodo, kad hierarchinis judesių vertinimas tampa vis aktualesnis individualizuotose reabilitacijos sistemose.

Literatūroje taip pat pažymima, kad dauguma darbų pagrindinį dėmesį skiria modelių tikslumui, o mažiau dėmesio skiriama sprendimų interpretacijai. Dėl to tampa sudėtinga įvertinti, ar modeliai remiasi biomechanškai prasmingais požymiais, ar tik išnaudoja duomenų statistinius dėsningumus [12, 13]. Šis aspektas ypač svarbus atliekant pratimų kokybės vertinimą, nes klaidingi sprendimai gali turėti tiesioginę įtaką reabilitacijos procesui [8].

#### **1.4. Paaiškinamojo dirbtinio intelekto panaudojimo galimybės**

Didėjant dirbtinio intelekto ir mašininio mokymosi metodų taikymui medicinoje, vis daugiau dėmesio skiriama modelių sprendimų skaidrumui ir interpretacijai. Nors sudėtingi neuroninių tinklų modeliai dažnai pasižymi aukštu tikslumu, jų veikimas dažnai apibūdinamas kaip „juodosios dėžės“, nes sprendimų priėmimo logika nėra tiesiogiai suprantama naudotojui [12, 13]. Reabilitacijos kontekste toks sprendimų nepermatomumas kelia papildomų iššūkių, nes klaidingi ar nepagrįsti sprendimai gali turėti tiesioginę įtaką paciento terapijos eigai [8].

Mokslinėje literatūroje pabrėžiama, kad klinikinėje praktikoje dirbtinio intelekto sprendimai turi būti ne tik tikslūs, bet ir paaiškinami [24], kad reabilitacijos specialistai galėtų suprasti, kodėl modelis priėmė konkretų sprendimą [12]. Tai ypač aktualu vertinant reabilitacijos pratimų atlikimo kokybę, kur sprendimai dažnai grindžiami subtiliais biomechaniniais skirtumais tarp taisyklingų ir netaisyklingų judesių [8, 9, 22].

Paaiškinamasis dirbtinis intelektas (angl. *Explainable Artificial Intelligence, XAI*) apima metodų grupę, skirtą modelių sprendimų interpretacijai ir jų ryšio su įvesties duomenimis analizei. XAI metodai leidžia nustatyti, kurie požymiai daro didžiausią įtaką modelio sprendimams, ir taip įvertinti, ar šie sprendimai remiasi fiziškai ir biomechanškai prasmingais rodikliais [13, 25, 26]. Literatūroje pažymima, kad tokia analizė yra būtina siekiant užtikrinti modelių patikimumą ir jų rezultatų klinikinį pagrįstumą. Naujesniuose reabilitacijos tyrimuose pabrėžiama, kad biomechaninių požymių interpretacija tampa ypač svarbi personalizuotose ir adaptyviose sistemose, kuriose modelių sprendimai tiesiogiai priklauso nuo individualių paciento judesio parametrų [23]. Tai dar labiau išryškina paaiškinamojo dirbtinio intelekto metodų svarbą klinikinėje praktikoje.

Modelių interpretacijai dažnai naudojami SHAP (angl. *SHapley Additive exPlanations*) ir LIME (angl. *Local Interpretable Model-agnostic Explanations*) metodai, leidžiantys nustatyti, kurie požymiai turi didžiausią įtaką modelio sprendimams [25, 26]. Tyrimuose nurodoma, kad XAI analizė gali atskleisti tiek bendrus judesio kokybės dėsniumus, tiek pratimo tipui būdingus vertinimo kriterijus, kurie kitu atveju liktų paslėpti sudėtinguose modeliuose [12]. Sisteminė kompiuterinės regos technologijų analizė taip pat parodė, kad dauguma dabartinių automatizuotų judesių analizės sistemų orientuojasi į klasifikavimo tikslumą, tačiau mažiau dėmesio skiria biomechaniniam sprendimų pagrįstumui ir interpretacijai [15]. Šis aspektas laikomas vienu svarbiausių iššūkių diegiant tokias sistemas klinikinėje aplinkoje.

Svarbu pažymėti, kad paaiškinamasis dirbtinis intelektas nėra skirtas pakeisti mašininio mokymosi modelius, bet veikiau juos papildyti. Literatūroje akcentuojama, jog XAI metodai padeda identifikuoti galimus modelių šališkumus, perpratimo požymius ar neadekvačiai naudojamus požymius, taip prisidedant prie modelių patikimumo didinimo [13, 25, 26]. Tai ypač svarbu tais atvejais, kai modeliai naudojami sprendimų palaikymo sistemose, kurios gali turėti įtakos klinikiniam sprendimams.

Apibendrinant galima teigti, kad paaiškinamojo dirbtinio intelekto metodai tampa neatsiejama automatizuotų reabilitacijos analizės sistemų dalimi. Jie leidžia ne tik įvertinti modelių veikimo rezultatus, bet ir suprasti sprendimų priėmimo logiką, taip sudarant sąlygas objektyvesniam ir labiau pagrįstam reabilitacijos pratimų vertinimui. Šis aspektas yra ypač aktualus tyrimuose, kuriuose analizuojamas ne tik pratimų atpažinimas, bet ir jų atlikimo teisingumas.

## **1.5. Apibendrinimas**

Atlikta mokslinės literatūros analizė parodė, kad dirbtinio intelekto ir mašininio mokymosi metodai turi didelį potencialą reabilitacijos srityje, ypač automatizuoto judesių vertinimo kontekste. Tyrimuose nuosekliai pabrėžiama automatizuotų metodų nauda mažinant subjektyvaus vertinimo įtaką ir sudarant sąlygas kiekybiškai analizuoti paciento judesių kokybę bei jų pokyčius laike. Vis dėlto literatūra taip pat atskleidžia reikšmingus metodologinius iššūkius, susijusius su judesių vertinimo patikimumu ir rezultatų interpretacija.

Analizuoti darbai rodo, kad didelė dalis tyrimų orientuojasi į reabilitacijos pratimų ar judesių atpažinimą, pasiekiant aukštą klasifikavimo tikslumą naudojant įvairius biomechaninius požymius ir mašininio mokymosi modelius. Tačiau pratimų atlikimo kokybės vertinimas literatūroje nagrinėjamas rečiau ir dažnai apsiriboja siauru požymių rinkiniu arba konkrečiais judesio aspektais. Tai riboja galimybes kompleksiskai įvertinti judesio kokybę ir palyginti skirtingų metodų rezultatus.

Biomechaninių požymių analizė atskleidė, kad literatūroje dažniausiai naudojami erdviniai ir kampiniai rodikliai, leidžiantys aprašyti judesio struktūrą ir amplitudę. Tuo tarpu judesio dinamikos, tolygumo ir simetrijos požymiai, nors ir pripažįstami kaip svarbūs reabilitacijos kokybės indikatoriai, neretai analizuojami fragmentiškai arba naudojami kaip papildomi kriterijai. Tai rodo, kad egzistuoja poreikis integruoti skirtingų tipų biomechaninius požymius į vieningą analizės sistemą.

Literatūros analizė taip pat išryškino interpretacijos problemą. Nors sudėtingi neuroninių tinklų modeliai leidžia pasiekti aukštą klasifikavimo tikslumą, jų sprendimų pagrįstumas dažnai lieka nepakankamai paaiškintas. Klinikinėje aplinkoje tai kelia pasitikėjimo iššūkių, nes reabilitacijos specialistams svarbu suprasti, kokiais biomechaniniais kriterijais grindžiami modelių sprendimai. Dėl

šios priežasties paaiškinamojo dirbtinio intelekto metodai vis dažniau įvardijami kaip būtinas automatizuotų reabilitacijos analizės sistemų komponentas.

Atsižvelgiant į šiuos aspektus, šis tyrimas pozicionuojamas kaip kompleksinė analizė, jungianti kelias literatūroje dažnai atskirai nagrinėjamas kryptis. Skirtingai nuo darbų, orientuotų tik į pratimų atpažinimą, šiame tyrime nagrinėjama tiek reabilitacijos pratimų klasifikavimo, tiek jų atlikimo teisingumo vertinimo problema. Be to, tyrime naudojamas platus biomechaninių požymių rinkinys, apimantis erdvinis, kampinius, dinامينius ir simetrijos rodiklius, siekiant visapusiškai apibūdinti judesių kokybę.

Svarbus šio tyrimo aspektas yra paaiškinamojo dirbtinio intelekto metodų taikymas, leidžiantis analizuoti, kokie biomechaniniai požymiai daro didžiausią įtaką modelių sprendimams. Toks požiūris leidžia ne tik įvertinti modelių tikslumą, bet ir jų sprendimų pagrįstumą biomechaniniu požiūriu, kas literatūroje įvardijama kaip vienas pagrindinių iššūkių reabilitacijos analizės srityje.

## 2. Judesių analizės ir klasifikavimo metodologija

### 2.1. Tyrimo metodinis modelis

Šiame skyriuje pateikiamas bendras tyrimo metodologinis pagrindas ir konceptinė struktūra, apibrėžianti atlikto tyrimo eigą bei pagrindinius jo etapus. Tyrimo metodologija formuojama remiantis literatūros analizės metu išryškintomis problemomis ir rekomendacijomis, siekiant užtikrinti nuoseklų, pagrįstą ir pakartojamą reabilitacijos pratimų analizės procesą. Tyrimas grindžiamas vaizdo duomenų analize, kuri leidžia vertinti paciento judesius nenaudojant specializuotų jutiklių. Toks pasirinkimas atitinka literatūroje akcentuojamą poreikį kurti mažiau invazinius ir praktiškai pritaikomus reabilitacijos analizės metodus [1, 3]. Vaizdo duomenys laikomi pirminiu informacijos šaltiniu, iš kurio išgaunama tolimesnei analizei reikalinga judesių informacija.

**Vaizdo įrašų paruošimas ir segmentavimas.** Pirmasis metodologinis etapas apima vaizdo įrašų paruošimą ir segmentavimą. Kadangi reabilitacijos pratimai dažnai atliekami kartotinai, vaizdo įrašai suskaidomi į atskirus pratimų kartojimus, kurie vėliau analizuojami kaip savarankiški judesių pavyzdžiai. Toks sprendimas leidžia sumažinti duomenų heterogeniškumą ir sudaro sąlygas tikslesniam modelių mokymui bei vertinimui.

**Skeletinės informacijos išskyrimas.** Antrajame etape iš vaizdo duomenų išgaunama skeletinė informacija, aprašanti pagrindinių kūno sąnarių padėtis ir jų kitimą laike. Skeletinė reprezentacija pasirenkama kaip tarpinė judesio forma, leidžianti atsieti judesių analizę nuo vaizdo specifikos ir sutelkti dėmesį į biomechaninius aspektus. Remiantis literatūra, tokia reprezentacija yra tinkama tiek judesiams klasifikuoti, tiek atlikimo kokybei vertinti [1, 10, 17].

**Biomechaninių požymių formavimas.** Trečiajame etape iš skeletinių duomenų suformuojamas biomechaninių požymių rinkinys. Šie požymiai apima sąnarių padėtis, kampus, judesių amplitudes, dinamikos rodiklius ir judesių simetrijos charakteristikas. Požymių formavimas grindžiamas literatūroje identifikuotais judesių kokybės indikatoriais ir siekia visapusiškai apibūdinti viršutinių galūnių judesių eigą [4, 8, 9, 14].

**Pratimų klasifikavimas ir kokybės įvertinimas.** Ketvirtajame etape taikomi mašininio mokymosi metodai dviem pagrindinėms užduotims spręsti: reabilitacijos pratimų tipų klasifikacijai ir pratimų atlikimo kokybės vertinimui. Šios užduotys sprendžiamos atskirai, atsižvelgiant į jų skirtingą tikslą ir sudėtingumą. Modelių veikimas vertinamas naudojant standartinius klasifikavimo rodiklius, leidžiančius objektyviai palyginti skirtingų sprendimų efektyvumą [21, 22, 25].

**Paaškinamojo dirbtinio intelekto metodų taikymas.** Galiausiai, siekiant užtikrinti modelių sprendimų pagrįstumą ir atitikimą biomechaniniams principams, tyrime taikomi paaškinamojo dirbtinio intelekto metodai. Šie metodai leidžia nustatyti, kurie biomechaniniai požymiai daro didžiausią įtaką modelių sprendimams, ir įvertinti, ar modeliai remiasi fiziškai prasmingais judesių aspektais. Tokia analizė yra svarbi ne tik modelių patikimumui vertinti, bet ir tolimesniam jų taikymui reabilitacijoje [8, 12, 13, 25, 26].

Apibendrinant, tyrimo metodologija grindžiama nuosekliu procesu, apimančiu vaizdo duomenų paruošimą, skeletinės informacijos išgavimą, biomechaninių požymių formavimą, mašininio mokymosi modelių taikymą ir jų sprendimų interpretaciją. Šis konceptas sudaro pagrindą

tolimesniems skyriams, kuriuose detaliai aprašomi naudojami duomenys, požymių formavimo metodai ir eksperimentų rezultatai.

## 2.2. Duomenų aprašymas

Šiame poskyryje aprašomi tyrime naudoti duomenys, jų struktūra bei atrankos principai. Kadangi darbo tikslas orientuotas į viršutinių galūnių reabilitacinių pratimų analizę, duomenų parinkimas buvo vykdomas siekiant užtikrinti biomechaninį nuoseklumą ir tinkamumą tolesniam automatizuotam vertinimui.

**Naudojamas duomenų rinkinys.** Tyrimui naudotas viešai prieinamas „Zenodo Multi-modal Physical Rehabilitation Dataset“ [27], kuriame pateikiami reabilitacinių pratimų vaizdo įrašai su anotacijomis. Duomenų rinkinį sudaro 130 pilno ilgio vaizdo įrašų, apimančių 1 072 individualius pratimų kartojimus, atliktus 65 skirtingų dalyvių. Kiekvienas įrašas papildytas metaduomenimis, kuriuose nurodomas pratimo tipas, dalyvio identifikatorius, kartojimų ribos bei atlikimo kokybės žymos.

Rinkinys apima šešis skirtingus pratimų tipus, skirtus tiek viršutinių, tiek apatinių galūnių funkcijai vertinti, o vaizdo įrašai pateikiami iš dviejų skirtingų kamerų perspektyvų. Toks daugiamodalis pobūdis suteikia lankstumo analizei, tačiau kartu didina duomenų variaciją ir sudėtingumą. Dėl šios priežasties, siekiant išlaikyti metodologinį nuoseklumą, būtina taikyti tikslingą duomenų atranką.

Apibendrinant galima teigti, kad pradinis duomenų rinkinys yra pakankamai platus ir įvairus, tačiau jo tiesioginis panaudojimas nėra tinkamas dėl skirtingų judesių tipų ir analizei nereikalingos variacijos.

**Duomenų atranka ir analizės posistemė.** Atsižvelgiant į tyrimo tikslą, iš pradinio duomenų rinkinio buvo atrinkta tik ta dalis, kuri susijusi su viršutinių galūnių judesiais. Analizei pasirinkti trys pratimų tipai (Ex1–Ex3), apimantys pečių, alkūnių ir riešų funkciją, tuo tarpu apatinių galūnių pratimai buvo pašalinti. Toks sprendimas leido sumažinti duomenų heterogeniškumą ir išvengti modelių mokymo metu atsirandančio triukšmo.

Papildomai buvo apribota naudojama vaizdo perspektyva – pasirinkta tik priekinė pusiau šoninė projekcija. Ši projekcija užtikrina geriausią viršutinių galūnių sąnarių matomumą ir yra tinkamiausia pozų atpažinimo metodams taikyti. Vienos kameros naudojimas taip pat sumažina variaciją tarp įrašų ir leidžia suformuoti nuoseklesnį duomenų rinkinį.

Siekiant užtikrinti duomenų kokybę, į analizę įtraukti tik tie dalyviai, kurių įrašai turi pilnas anotacijas ir pakankamą kartojimų skaičių. Galutinėje duomenų posistemėje panaudoti 47 vaizdo įrašai ir 493 individualūs kartojimai, kurie sudaro pakankamą pagrindą modelių mokymui ir vertinimui. Ši atranka leidžia suformuoti biomechaniškai vientisą ir metodologiškai nuoseklią duomenų aibę, tinkamą tolesnei analizei.

**Duomenų struktūravimas analizės reikmėms.** Atrinkti duomenys tolesniam apdorojimui buvo organizuojami kartojimo lygmeniu, kuris šiame tyrime laikomas pagrindiniu analizės vienetu. Kiekvienas pilno ilgio vaizdo įrašas buvo suskaidytas į atskirus segmentus pagal anotacijose nurodytas kartojimų ribas. Tokiu būdu kiekvienas pratimų atlikimas tapo savarankišku vienetu, turinčiu susietus metaduomenis – dalyvio identifikatorių, pratimo tipą ir atlikimo kokybės žymą.

Šis segmentavimo procesas leidžia pereiti nuo ilgų, heterogeniškų vaizdo sekų prie aiškiai apibrėžtų ir biomechanškai vientisų judesių. Tai yra svarbu modelių mokymui, nes sumažinamas nereikalingos informacijos kiekis ir užtikrinamas tiesioginis ryšys tarp judesio ir jo anotacijos. Be to, tokia struktūra leidžia tiksliau vertinti modelių veikimą skirtingų pratimų ir atlikimo kokybės atžvilgiu.

Galutinis rezultatas – 493 segmentuoti kartojimai, kurie naudojami kaip pagrindiniai duomenų vienetai visose tolimesnėse tyrimo stadijose. Tokia reprezentacija sudaro pagrindą vėlesniam požymių skaičiavimui ir modelių įvestims formuoti.

### 2.3. Duomenų paruošimas ir požymių išgavimas

Šiame skyriuje aprašomas duomenų apdorojimo procesas, kurio metu iš vaizdo įrašų išgaunama struktūrizuota skeletinė informacija ir formuojami biomechaniniai požymiai. Šis etapas yra esminis visam tyrimui, nes nuo jo priklauso tiek modelių mokymo kokybė, tiek galutinių rezultatų interpretacija.

**Skeletinės informacijos išgavimas iš vaizdo duomenų.** Pirmasis duomenų paruošimo etapas apima vaizdo įrašų transformaciją į skeletinę reprezentaciją, kuri leidžia analizuoti žmogaus judesius nepriklausomai nuo vaizdo aplinkos veiksnių (2.1 pav.). Šiam tikslui naudojamas „MediaPipe Pose“ algoritmas, kuris kiekviename vaizdo kadre identifikuoja pagrindinius žmogaus kūno sąnarių taškus ir pateikia jų koordinatas erdvėje.



a) Pratimas be skeletinės reprezentacijos



b) Pratimas su skeletine reprezentacija

2.1 pav. Pratimo vaizdas be skeletinės reprezentacijos ir su skeletine reprezentacija

Iš kiekvieno vaizdo kadro išgaunami 33 orientyrai, apimantys pagrindinius kūno segmentus, tačiau šiame tyrime analizuojami tik viršutinių galūnių sąnariai – pečiai, alkūnės ir riešai. Tokia atranka leidžia sumažinti nereikalingos informacijos kiekį ir koncentruotis į tyrimo objektą – viršutinių galūnių judesių analizę.

Kadangi vaizdo duomenys gali būti skirtingos kokybės ir mastelio, papildomai taikomas koordinačių normalizavimas. Sąnarių padėtys transformuojamos į santykinės reikšmės kūno atžvilgiu, dažniausiai naudojant torso ar pečių liniją kaip referencinį pagrindą. Tai leidžia sumažinti individualių kūno proporcijų ir kameros pozicijos įtaką.

Apibendrinant galima teigti, kad skeletinės informacijos išgavimas leidžia pereiti nuo sudėtingų vaizdo duomenų prie struktūrizuotos, analizei tinkamos reprezentacijos, kuri sudaro pagrindą tolimesniam požymių skaičiavimui.

**Duomenų segmentavimas ir laikinės sekos formavimas.** Gauti skeletiniai duomenys tolesniam apdorojimui organizuojami laiko sekų forma, atitinkančia atskirus pratimų kartojimus. Remiantis anotacijose pateiktomis ribomis, kiekvienas vaizdo įrašas suskaidomas į segmentus, kuriuose fiksuojamas vienas pilnas judesio ciklas.

Kiekvienas segmentas sudarytas iš nuoseklių kadro sekos, kur kiekviename kadre pateikiamos sąnarių koordinatės. Tokia struktūra leidžia analizuoti judesio eigą laike ir išgauti dinaminę informaciją, kuri yra būtina vertinant judesio kokybę. Skirtingai nei statiniai požymiai, laikinės sekos leidžia įvertinti judesio tęstinumą, stabilumą ir reguliarumą.

Kadangi skirtingų kartojimų trukmė gali skirtis, taikomas sekų ilgio suvienodinimas. Tam naudojami interpolacijos arba „padding“ metodai, leidžiantys visus segmentus transformuoti į vienodo ilgio sekas. Tai yra būtina sąlyga daugeliui mašininio mokymosi modelių, ypač neuroniniams tinklams, kurie reikalauja vienodos įvesties struktūros.

Tokiu būdu iš 47 pilno ilgio vaizdo įrašų buvo suformuoti 493 individualūs pratimų kartojimų segmentai, apimantys tris viršutinių galūnių pratimus: Ex1, Ex2 ir Ex3. Kiekvienas segmentas atitinka vieną pratimų kartojimą ir yra aprašytas kaip laiko seka su susietomis sąnarių koordinatėmis. Tokia struktūra sudaro pagrindą tolimesniam biomechaninių požymių skaičiavimui ir mašininio mokymosi modelių įvestims formuoti.

**Biomechaninių požymių formavimas.** Iš skeletinių duomenų išgaunami biomechaniniai požymiai, kurie naudojami kaip įvestis mašininio mokymosi modeliams. Šie požymiai formuojami remiantis literatūroje identifikuotais judesių kokybės rodikliais ir siekia apibūdinti judesio struktūrą bei dinamiką.

Pirmiausia skaičiuojami sąnarių kampai, apibūdinantys segmentų tarpusavio orientaciją. Kampai tarp peties–alkūnės–riešo taškų leidžia įvertinti judesio biomechaninę kokybę ir yra vieni svarbiausių požymių reabilitacijos analizėje. Skirtingai nei absoliučios koordinatės, kampiniai rodikliai yra mažiau jautrūs išoriniams veiksniams. Toliau išgaunami trajektorijų ir amplitudės požymiai, kurie apibūdina sąnarių judėjimo ribas. Šie rodikliai leidžia nustatyti, ar judesys atliekamas pilna amplitude, ar yra ribotas dėl funkcinių sutrikimų. Taip pat skaičiuojami judesio dinamikos rodikliai – greitis ir pagreitis, kurie leidžia įvertinti judesio tolygumą ir kontrolę.

Papildomai analizuojama judesių simetrija tarp kairės ir dešinės kūno pusės. Simetrijos rodikliai leidžia nustatyti galimus kompensacinius judesius, kurie dažnai pasireiškia netaisyklingo pratimo atlikimo metu. Tokie požymiai yra ypač svarbūs vertinant reabilitacijos pažangą.

Galutiniame etape visi požymiai sujungiami į vieningą požymių vektorių, kuris naudojamas modelių mokymui. Tokia integruota reprezentacija leidžia kompleksiskai vertinti judesius, jungiant skirtingus biomechaninius aspektus į vieną analizės sistemą.

#### **2.4. Mašininio mokymosi modelių kūrimas ir taikymas**

Šiame skyriuje aprašomas mašininio mokymosi modelių kūrimo procesas, skirtas spręsti viršutinių galūnių reabilitacinių pratimų analizės uždavinius. Modeliai kuriami remiantis ankstesniuose etapuose išgautais biomechaniniais požymiais, kurie leidžia aprašyti judesių struktūrą ir dinamiką kiekybine forma. Šio etapo tikslas – sukurti sprendimus, gebančius tiek identifikuoti atliekamą pratimą, tiek įvertinti jo atlikimo kokybę.

**Uždavinių formulavimas.** Tyrime nagrinėjamos dvi skirtingo pobūdžio klasifikavimo užduotys, kurios sprendžiamos nuosekliai, siekiant išvengti metodologinių netikslumų. Pirmoji užduotis yra pratimų tipų klasifikacija, kuri formuluojama kaip daugiaklasė problema. Šiuo atveju modelis, remdamasis tik biomechaniniais požymiais, turi nustatyti, kuriam iš nagrinėjamų pratimų tipų priklauso konkretus judesys. Toks formulavimas leidžia įvertinti, ar išgauti požymiai pakankamai gerai apibūdina skirtingų judesių struktūrinius skirtumus.

Antroji užduotis – pratimų atlikimo kokybės vertinimas – yra binarinė klasifikavimo problema, kurioje modelis sprendžia, ar konkretus judesys atliktas taisyklingai. Skirtingai nei pirmojoje užduotyje, šiame etape į modelio įvestį įtraukiama papildoma informacija apie pratimo tipą. Toks sprendimas yra pagrįstas tuo, kad skirtingiems pratimams taikomi skirtingi biomechaniniai kokybės kriterijai, todėl jų neįtraukimas galėtų lemti netikslias prognozes.

Šių dviejų užduočių atskyrimas leidžia išvengti informacijos nutekėjimo tarp įvesties ir tikslinės klasės bei užtikrina, kad modeliai mokytųsi realių judesių dėsningumą, o ne pasinaudotų papildoma kontekstine informacija kaip „užuomina“. Tokia sprendimo logika atitinka metodologiškai korektiško mašininio mokymosi principus.

**Modelių struktūra ir mokymo procesas.** Abiem užduotims spręsti naudojami daugiasluoksniai neuroniniai tinklai, kurie leidžia modeliuoti sudėtingus netiesinius ryšius tarp biomechaninių požymių. Modelių įvestis sudaryta iš anksčiau išgautų požymių vektorių, apibūdinančių sąnarių kampus, judesio amplitudę, dinamiką ir kitus biomechaninius aspektus.

Pratimų klasifikavimo užduotyje naudojamas neuroninis tinklas su keliomis pilnai sujungtomis paslėptomis sluoksnių struktūromis, kuriose taikomos nelinearinės aktyvacijos funkcijos. Toks modelis leidžia išmokti sudėtingas požymių kombinacijas, kurios skiria skirtingus judesių tipus. Išvesties sluoksnyje naudojama tikimybinė klasifikacija, leidžianti priskirti įrašą vienai iš kelių klasių.

Kokybės vertinimo užduotyje naudojama panaši architektūra, tačiau modelio įvestis papildoma pratimo tipo kodavimu. Tai leidžia modeliui interpretuoti požymius kontekste ir tiksliau vertinti judesio kokybę. Išvestis šiuo atveju yra binarinė, nurodanti, ar judesys atliktas taisyklingai.

Modelių mokymui taikomas iteracinis optimizavimo procesas, kurio metu siekiama minimizuoti prognozavimo klaidą. Naudojamas adaptacinis optimizavimo algoritmas (angl. *Adam*), kuris leidžia efektyviai atnaujinti svorius net esant sudėtingai požymių struktūrai. Siekiant išvengti per didelio

prisitaikymo prie treniravimo duomenų, taikomi reguliarizacijos metodai, tokie kaip atsitiktinis neuronų išjungimas (angl. *dropout*) ir ankstyvas mokymo stabdymas.

Papildomai visi įvesties duomenys yra normalizuojami, kad skirtingų požymių masteliai būtų suderinti. Tai yra svarbi sąlyga stabiliai modelių konvergencijai ir efektyviam mokymui.

**Modelių vertinimo principai ir metodologinis pagrindimas.** Modelių veikimas vertinamas naudojant standartinius klasifikavimo rodiklius, kurie leidžia įvertinti tiek bendrą tikslumą, tiek klaidų pobūdį. Pagrindinis rodiklis yra **tikslumas** (angl. *accuracy*), tačiau papildomai analizuojami **preciziškumo** (angl. *precision*), **jautrumo** (angl. *recall*) ir **F1 mato** (angl. *F1-Score*) rodikliai, kurie suteikia išsamesnį vaizdą apie modelio gebėjimą diferencijuoti klases.

Vertinimui naudojama duomenų skaidymo strategija, kai duomenys padalijami į mokymo, validacijos ir testavimo aibes. Toks skaidymas leidžia objektyviai įvertinti modelio gebėjimą apibendrinti nematytus duomenis ir sumažina per didelio prisitaikymo riziką. Papildomai naudojamos klaidų matricos, kurios leidžia identifikuoti sisteminės modelio klaidas ir geriau suprasti jo sprendimų struktūrą.

Pasirinkta metodika yra pagrįsta tiek teoriniais mašininio mokymosi principais, tiek praktiniais eksperimentais, atliktais šiame tyrime. Gauti rezultatai rodo, kad vidutinio sudėtingumo neuroniniai tinklai yra pakankami nagrinėjamosioms užduotims spręsti, o sudėtingesni modeliai ne visada suteikia papildomos naudos.

### 3. Reabilitacijos pratimų klasifikavimo, vertinimo ir *XAI* analizės rezultatai


#### 3.1. Pratimų klasifikacijos eksperimentas ir rezultatai

Šiame poskyryje pateikiami eksperimentai, skirti įvertinti modelio gebėjimą klasifikuoti viršutinių galūnių reabilitacinius pratimus. Eksperimento tikslas – nustatyti, ar išgauti biomechaniniai požymiai yra pakankamai informatyvūs skirtingų judesių tipų atskyrimui. Modelis mokomas naudojant tik požymių vektorius, neįtraukiant papildomos informacijos apie pratimo tipą į įvestį, siekiant užtikrinti objektyvų vertinimą.


##### 3.1.1. Klasifikacijos uždavinio motyvacija

Klasifikacijos uždavinys šiame tyrime iš anksto buvo vertinamas kaip metodologiškai nesudėtingas. Trys naudojami pratimų tipai (3.1 pav.) yra biomechaniskai aiškiai skirtingi:

- Ex1 – rankos kėlimas į šoną, kai ištiesinta dešinė ranka keliama į šoną frontaliwoje plokštumoje, atliekant peties atitraukimo judesį (angl. *arm abduction*);
- Ex2 – „V–W“ rankų judesys, kai abi rankos sklandžiai pereina tarp „V“ ir „W“ formų, derinant peties ir alkūnės sąnarių judesius (angl. *arm VW*);
- Ex3 – atsispaudimai nuo stalo, kai viršutinė kūno dalis juda atliekant atsispaudimo judesį, rankomis remiantis į stalą (angl. *push-ups with hands on a table*).



a) Ex1 – rankos kėlimas į šoną



b) Ex2 – „V–W“ rankų judesys



c) Ex3 – atsispaudimai nuo stalo

3.1 pav. Nagrinėjamų pratimų tipai

Šių pratimų biomechaniniai skirtumai yra tokie ryškūs, kad net trumpi skeletinių taškų fragmentai leidžia modeliams labai tiksliai atskirti pratimo tipą. Todėl atsižvelgiant į aiškius biomechaninius skirtumus tarp pratimų, buvo tikimasi aukšto klasifikavimo tikslumo.

Klasifikacijos proceso tikslas šiame tyrime – ne sukurti sudėtingą pažangų modelį, o patikrinti, ar MediaPipe ir biomechaninių požymių išgavimas buvo atliktas tinkamai, ir ar pratimų struktūriniai skirtumai yra pakankamai ryškiai užfiksuoti požymių erdvėje.

### 3.1.2. Pratimų klasifikacijai naudotų duomenų struktūra

Pratimų klasifikavimo modeliui buvo naudojamas 117 biomechaninių požymių rinkinys, apskaičiuotas iš „MediaPipe“ algoritmu išgautų žmogaus kūno orientyrų. Šie požymiai apima sąnarių padėties statistiką, sąnarių kampus, judesio dinamiką, trajektorijos charakteristikas, simetrijos rodiklius ir judesio kokybės parametrus. Tokia požymių struktūra leidžia aprašyti ne tik galutinę kūno padėtį, bet ir visą pratimų atlikimo eigą, todėl yra tinkama skirtingų judesių tipų atpažinimui.

Šiame eksperimente modelio įvestyje sąmoningai nebuvo naudojamos pratimų tipų žymos ar vienetinė koduotė (angl. *one-hot encoding*). Jų įtraukimas į klasifikavimo modelį sukeltų informacijos nutekėjimą, nes modelis gautų klasę nurodančią informaciją kaip įvesties požymį. Tokiu atveju modelis ne mokytųsi atpažinti pratimų biomechaninių skirtumų, o tiesiog naudotų iš anksto pateiktą atsakymą.

Dėl šios priežasties klasifikavimo modelis buvo mokomas tik remiantis biomechaniniais požymiais. Toks sprendimas leido objektyviai įvertinti, ar iš vaizdo duomenų išgauti požymiai pakankamai tiksliai apibūdina skirtingų pratimų judesio struktūrą. Kitaip tariant, modelio rezultatai parodo tikrąją požymių informacinę vertę, o ne dirbtinai pagerintą klasifikavimo tikslumą dėl papildomos klasės informacijos. Toliau pateikiama po grupių suskirstyta požymių lentelė (3.1 lentelė.), nurodant kiek požymių priklausė kiekvienai grupei, kokius tipus jie atspindi ir koku metodu buvo apskaičiuoti.

3.1 lentelė. Naudotų 117 biomechaninių požymių grupės, jų apimtis ir apskaičiavimo metodologija

Požymių grupė	Požymių kiekis	Požymių pavyzdžiai	Gavimo metodologija	Biomechaninė paskirtis
1. Sąnarių padėties statistika	33 požymiai	Vid. riešo X koordinatė, peties Y koordinatės std. nuokrypis, maks. alkūnės Z koordinatė	Iš „MediaPipe“ orientyrų (x, y, z) apskaičiuojamos min., maks., vidurkio ir standartinio nuokrypio reikšmės	Apibūdina sąnarių trajektorijas ir kūno segmentų erdvinę padėtį
2. Sąnarių kampai	20 požymių	Vid. alkūnės kampas, peties lenkimo kampo std. nuokrypis	Kampai apskaičiuojami tarp trijų taškų taikant vektorinę analizę, pvz., petys–alkūnė–riešas	Atspindi judesio pobūdį, sąnarių padėtį ir amplitudę, leidžia diferencijuoti skirtingus viršutinių galūnių judesius
3. Kampų dinaminiai parametrai	20 požymių	Vid. kampinis greitis, maks. kampinis pagreitis	Iš kampų laiko eilučių apskaičiuojamos pirmosios ir antrosios išvestinės	Vertina judesio intensyvumą, ritmiškumą ir kampinės kontrolės stabilumą
4. Judėjimo trajektorijos rodikliai	12 požymių	Riešo trajektorijos ilgis, peties judesio amplitudė	Integruojami orientyrų poslinkiai, apskaičiuojant 3D trajektorijos ilgį ir judesio amplitudę	Padedą diferencijuoti Ex1, Ex2 ir Ex3 pagal judesio kryptį, amplitudę ir trajektorijos pobūdį
5. Judėjimo sklandumo rodikliai	8 požymiai	Vid. judesio trūkčiojimas, judesio trūkčiojimo std. nuokrypis	Skaičiuojama trečioji padėties išvestinė pagal laiką, t. y. jerk	Įvertina judesio sklandumą, kontrolę ir galimus kompensacinius virpesius
6. Simetrijos požymiai	12 požymių	Riešų Y koord. santykis, pečių koord. skirtumas	Palyginamos kairės ir dešinės kūno pusės sąnarių padėtyt bei trajektorijos	Svarbūs vertinant abiejų kūno pusių koordinaciją, laikyseną ir kompensacinius judesius
7. Požymių kokybės rodikliai (visibility)	12 požymių	Vid. riešo matomumas, alkūnės matomumo std. nuokrypis	„MediaPipe“ matomumo balai (0–1) apdorojami statistiškai	Naudojami prastai matomiems kadrams įvertinti ir analizės stabilumui užtikrinti

Šių požymių rinkinys sudarytas taip, kad modelis galėtų išmokti atskirti visus tris pratimų tipus remdamasis ne atsitiktinėmis orientyrų pozicijomis, o visu biomechaniniu judesio parašu, kuris apima:

- kūno padėtį erdvėje;
- sąnarių tarpusavio ryšius;
- judesio kryptį;
- kampų kitimą laike;
- judesio ritmiką;
- judėjimo sklandumą;
- asimetrinius ar kompensacinius judesius.

Tiksliai sukonstruoti požymiai paaiškina, kodėl modelis pasiekė 100 % tikslumą – visi pratimai biomechanškai yra tokie skirtingi, kad net paprastos, bet informatyvios taisyklės leidžia juos atskirti beveik be klaidų.

### 3.1.3. Modelio architektūra ir mokymo metodika

Pratimų klasifikavimui buvo sukurtas daugiasluoksnis perceptronas (angl. *Feedforward Neural Network*) taip, kad gebėtų efektyviai įvertinti biomechaninių požymių struktūrą ir atskirti tris tyrime nagrinėtus pratimų tipus. Modelio architektūra buvo parinkta kaip pakankamo sudėtingumo, kad atspindėtų netiesinius ryšius tarp požymių, tačiau kartu riboto sudėtingumo, kad būtų išvengta perteklinio prisitaikymo prie duomenų (angl. *overfitting*).

Modelio struktūra:

- įvesties sluoksnis: 117 biomechaninių požymių;
- paslėptas sluoksnis 1: 128 neuronai, *ReLU* aktyvacija, *Dropout*(0,3);
- paslėptas sluoksnis 2: 64 neuronai, *ReLU* aktyvacija, *Dropout*(0,3);
- išvesties sluoksnis: 3 neuronai (*softmax*), atitinkantys Ex1–Ex3 pratimus.

Mokymo konfigūracija:

- nuostolio funkcija: *CrossEntropyLoss*;
- optimizatorius: *Adam* (mokymosi žingsnis = 0,001);
- duomenų standartizacija: *StandardScaler* (mokyta tik pagal treniravimo aibę);
- duomenų padalijimas: stratifikacija pagal pratimo tipą;
- mokymo aibė: 345 įrašai, apie 70 % duomenų;
- validavimo aibė: 74 įrašai, apie 15 % duomenų;
- testavimo aibė: 74 įrašai, apie 15 % duomenų;
- ankstyvasis stabdymas (angl. *Early stopping*): *patience* = 15 epochų;
- paketo dydis (angl. *Batch size*): 32;
- maksimalus epochų skaičius: 100.

Toks modelio ir mokymo konfigūracijos derinys leido stabiliai konverguoti, sumažinti perteklinio prisitaikymo prie treniravimo duomenų riziką ir išnaudoti iš anksto paruoštus 117 biomechaninių požymių.

### 3.1.4. Pratimų klasifikacijos rezultatai

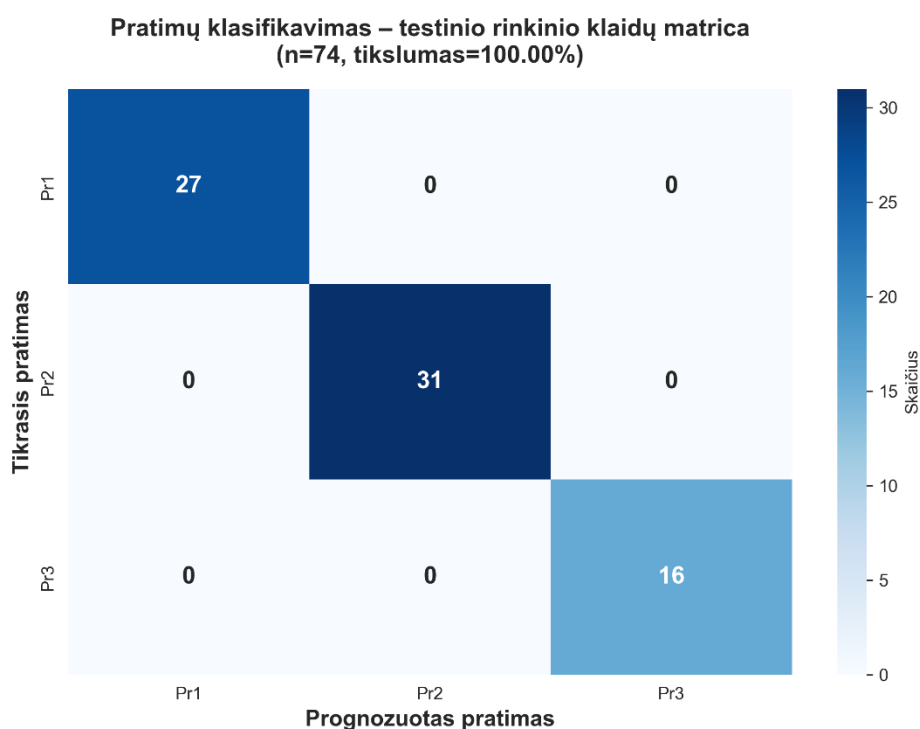
Pratimų klasifikacijos modelio kūrimas vyko keliais etapais, kurių metu buvo vertinama, kaip duomenų paruošimo kokybė ir požymių struktūra veikia modelio gebėjimą atpažinti skirtingus pratimų tipus. Ankstyvieji eksperimentai parodė, kad modelio rezultatai reikšmingai priklauso nuo vaizdo įrašų segmentavimo. Pirmasis modelio variantas, mokyta naudojant pilnus vaizdo įrašus, kuriuose buvo keli pratimų kartojimai, pasiekė apie 75,76 % tikslumą. Tai rodė, kad pilno ilgio vaizdo įrašai modeliui buvo per daug heterogeniški, nes viename įrašė galėjo būti kelios judesio fazės ir skirtingi kartojimai.

Atlikus vaizdo įrašų segmentavimą į individualius pratimų kartojimus, modelio tikslumas padidėjo iki 91,67 %. Šis pagerėjimas parodė, kad kartojimų lygmens segmentavimas yra būtina duomenų paruošimo dalis, nes kiekvienas įrašas tampa aiškiai apibrėžtu vieno judesio pavyzdžiu. Tokia

struktūra leidžia modeliui tiksliau susieti biomechaninius požymius su konkrečiu pratimo tipu ir sumažina interpretacinį neapibrėžtumą.


Galutinis klasifikavimo modelis buvo mokomas naudojant 117 biomechaninių požymių, apibūdinančių sąnarių padėtį, kampus, judesio dinamiką, simetriją ir trajektorijos savybes. Tokia įvesties struktūra leido modeliui atpažinti pratimų tipus remiantis pačių judesių biomechaniniais skirtumais.

Atlikus modelio treniravimą, jis pasiekė 100,00 % tikslumą treniravimo, validacijos ir testavimo aibėse. Testavimo rinkinyje buvo teisingai suklasifikuoti visi 74 pavyzdžiai, todėl klaidingų klasifikacijų neužfiksuota. Šį rezultatą patvirtina 3.2 pav. pateikta pratimų klasifikavimo pasiskirstymo matrica, kurioje visi Ex1, Ex2 ir Ex3 pavyzdžiai priskirti teisingoms klasėms, o klaidingų klasifikacijų tarp pratimų tipų nenustatyta.



3.2 pav. Pratimų klasifikavimo pasiskirstymo matrica

Prarasties kreivių analizė, pateikta 3.3 pav., rodo stabilų modelio mokymosi procesą. Treniravimo ir validacijos prarasties reikšmės mažėjo nuosekliai, be ryškaus išsiskyrimo tarp mokymo ir validacijos kreivių, todėl galima teigti, kad modelis nebuvo linkęs į perteklinį prisitaikymą prie treniravimo duomenų. Tai papildomai pagrindžia, kad aukštas validacijos ir testavimo tikslumas nebuvo vien duomenų įsiminimo rezultatas, o atspindėjo modelio gebėjimą generalizuoti trijų analizuotų pratimų biomechaninius skirtumus.



3.3 pav. Klasifikavimo kryžminės entropijos nuostolių grafikas

Aukštas galutinis tikslumas tyrime turi dvi svarbias reikšmes. Pirma, jis rodo, kad trys pratimų tipai yra aiškiai išreikšti biomechaniniu požiūriu ir gali būti patikimai atskirti remiantis vien iš vaizdo duomenų išgautais požymiais. Tai patvirtina, kad pratimų klasifikacija šiame tyrime gali būti laikoma išspręstu uždaviniu. Antra, toks rezultatas sudaro pagrindą pereiti prie sudėtingesnio ir kliniškai reikšmingesnio uždavinio – pratimų atlikimo teisingumo vertinimo. Skirtingai nei pratimų tipų atpažinimas, taisyklingumo klasifikacija reikalauja įvertinti ne tik tai, koks pratimas atliekamas, bet ir kaip tiksliai jis vykdomas biomechaniniu požiūriu.

### 3.1.5. Apibendrinimas

Šiame skyriuje buvo išanalizuotas pratimų klasifikavimo į tris viršutinių galūnių pratimų tipus procesas, pradedant nuo uždavinio formulavimo ir baigiant galutinių rezultatų interpretacija. Atliekant klasifikaciją siekta nustatyti, ar iš MediaPipe orientyrų išvesti biomechaniniai požymiai yra pakankamai informatyvūs, kad modelis galėtų patikimai, be papildomos semantinės informacijos, atskirti skirtingus pratimų tipus. Šiam tikslui buvo parengtas 117 požymių rinkinys, apimantis sąnarių padėties, kampų, judėjimo dinamikos, trajektorijų, simetrijos ir sklaidumo charakteristikas, kurių visuma suteikė modeliui nuoseklią biomechaninę judesio reprezentaciją.

Modelio architektūra, sudaryta iš dviejų paslėptųjų sluoksnių ir optimizuota naudojant „Adam“ algoritmą bei standartizacijos procedūras, parodė, kad net palyginti paprasta neuroninė struktūra gali veiksmingai pasinaudoti sudarytu biomechaninių požymių rinkiniu. Pradiniai rezultatai, siekę nuo 75,76 % iki 91,67 %, atskleidė segmentavimo ir duomenų kokybės svarbą, tačiau šie rezultatai priklausė ankstesniems modelio variantams ir nebuvo laikomi galutiniais. Galutinis modelis buvo mokomas naudojant 117 biomechaninių požymių ir tinkamai suformuotas mokymo, validacijos bei testavimo aibes, todėl gautas rezultatas leidžia objektyviai įvertinti požymių rinkinio informacinę vertę pratimų tipų klasifikavimo uždavinyje.

Galutinis klasifikavimo rezultatas – 100 % tikslumas testavimo aibėje – rodo, kad sukurtas požymių rinkinys ir duomenų apdorojimo metodika yra tinkamai pritaikyta pratimų identifikavimo uždaviniui. Tai reiškia, kad pratimų tipų klasifikavimo uždavinys šiame tyrimo etape yra praktiškai išspręstas, o sukurtas metodas gali būti laikomas pakankamai patikimu tolimesniam taikymui.

Šio skyriaus rezultatai sudaro būtinas prielaidas pereiti prie kito, sudėtingesnio tyrimo etapo – pratimų atlikimo teisingumo vertinimo. Skirtingai nei pratimų tipų klasifikacija, taisyklingumo analizė reikalauja ne tik identifikuoti judesio tipą, bet ir įvertinti, ar konkretus kartojimas atliktas laikantis biomechaninių reikalavimų. Todėl aukštas klasifikacijos tikslumas ne tik patvirtina duomenų apdorojimo metodikos kokybę, bet ir užtikrina tvirtą pagrindą modeliui pereiti prie kokybinio, kliniškai svarbaus judesio vertinimo.

### **3.2. Pratimų atlikimo teisingumo klasifikavimo uždavinys**

Pratimų atlikimo teisingumo klasifikavimas yra esminė tyrimo dalis, tiesiogiai susijusi su reabilitacinio proceso kokybės vertinimu. Skirtingai nei pratimų tipo identifikavimas, kuris remiasi aiškiai išreikštais biomechaniniais judesio skirtumais, teisingumo analizė reikalauja atpažinti daug subtilesnius ir neretai tarpusavyje persidengiančius judesio niuansus. Taisyklingas ir netaisyklingas pratimų atlikimas gali būti labai panašūs globalia trajektorija, tačiau skirtis amplitudėmis, judesio sklandumu, segmentine sąnarių kontrole ar momentinėmis kompensacijomis. Tokie skirtumai yra kur kas mažiau išreikšti nei pratimų tipų atveju, todėl modelio užduotis tampa reikšmingai sudėtingesnė.

Reabilitacijos kontekste šis uždavinys yra itin aktualus, nes tikslus judesių atlikimas lemia terapijos efektyvumą bei saugumą. Klinikinėje praktikoje net nedidelis nukrypimas nuo taisyklingos biomechaninės trajektorijos gali turėti neigiamą poveikį sąnarių apkrovai, raumenų aktyvacijai ar kompensacinių judesių susiformavimui. Todėl šiame skyriuje pristatomas modelis yra ne tik techninis eksperimentas, bet ir koncepcinis įrodymas, kad modernios kompiuterinės regos ir mašininio mokymosi priemonės gali būti naudojamos kuriant objektyvias, automatizuotas reabilitacijos palaikymo sistemas.

#### **3.2.1. Naudotas modelis ir alternatyvių architektūrų vertinimas**

Prieš pasirenkant galutinį modelį, buvo atlikta platesnė architektūrų analizė, siekiant nustatyti, kuri neuroninio tinklo konfigūracija geriausiai tinka pratimų atlikimo teisingumo vertinimui. Buvo išbandyti keli modeliai, besiskiriantys sluoksnių skaičiumi, neuronų kiekiu, atsitiktinių neuronų išjungimų (angl. *dropout*) reikšmėmis ir optimizavimo parametrais. Ši analizė leido įvertinti modelių polinkį į perteklinį įsiminimą, generalizacijos gebėjimą ir jautrumą duomenų variacijai.

Pirmieji eksperimentai apėmė gilesnius modelius, turinčius tris ar daugiau paslėptųjų sluoksnių ir didesnius neuronų kiekius (pvz., 256–128–64). Nors tokios architektūros demonstravo aukštą tikslumą treniravimo rinkinyje, validacijos rezultatai buvo gerokai prastesni, o mokymo kreivės rodė ryškius pertreniravimo požymius. Taip pat buvo išbandyti modeliai, kuriuose taikytas didesnis atsitiktinių neuronų išjungimas (angl. *dropout*) (nuo 0,3 iki 0,5), tačiau tokiais atvejais tinklas prarasdavo per daug struktūrinės informacijos, todėl klasifikavimo tikslumas tiek treniravimo, tiek validacijos duomenyse sumažėdavo. Iš viso buvo išbandyta 10 skirtingų neuroninio tinklo konfigūracijų, siekiant įvertinti architektūros gylio, sluoksnių pločio, regularizacijos bei optimizavimo parametru įtaką modelio gebėjimui generalizuoti biomechaninių požymių duomenis (3.2 lentelė.).

3.2 lentelė. Skirtingos modelio architektūros

Modelio konfigūracija	Paslėptieji sluoksniai	<i>Dropout</i>	Mokymosi greitis	Paketų dydis
Bazinė (2 sluoksnių)	[64, 32]	0,3	0,001	32
Gilioji (4 sluoksnių)	[128, 64, 32, 16]	0,3	0,001	32
Plati (2 sluoksnių)	[256, 128]	0,3	0,001	32
Siaura (3 sluoksnių)	[32, 16, 8]	0,3	0,001	32
Didelio dropout	[64, 32]	0,5	0,001	32
Mažo dropout	[64, 32]	0,1	0,001	32
Didelio paketo dydžio	[64, 32]	0,3	0,001	64
Mažo paketo dydžio	[64, 32]	0,3	0,001	16
Didelio mokymosi greičio	[64, 32]	0,3	0,01	32
Mažo mokymosi greičio	[64, 32]	0,3	0,0001	32

Atlikta architektūrų analizė parodė, kad modelio veikimą labiausiai paveikė regularizacijos stiprumas, tinklo gylis bei mokymosi parametrai. Geriausi rezultatai buvo pasiekti naudojant mažesnę atsitiktinių neuronų išjungimo koeficientą ( $\text{dropout} = 0,1$ ), kai modelis pasiekė 91,89 % tikslumą. Standartinis  $\text{dropout} = 0,3$  taip pat demonstravo gerus rezultatus – bazinis modelis pasiekė 90,54 % tikslumą, tačiau agresyvesnė regularizacija ( $\text{dropout} = 0,5$ ) sumažino klasifikavimo tikslumą iki 89,19 %. Tai rodo, kad nagrinėjamas biomechaninių požymių rinkinys yra pakankamai informatyvus ir nereikalauja itin stiprios regularizacijos, nes per didelis neuronų išjungimas gali lemti reikšmingos judesio struktūrinės informacijos praradimą.

Analizuojant tinklo gylio įtaką nustatyta, kad keturių paslėptųjų sluoksnių architektūra, sudaryta iš 128, 64, 32 ir 16 neuronų, pasiekė 89,19 % tikslumą ir 88,89 % jautrumą. Nors toks modelis gebėjo pakankamai gerai atpažinti teisingai atliktus pratimus, jo bendras tikslumas nebuvo didesnis už paprastesnių dviejų sluoksnių modelių rezultatus. Siauresnė trijų paslėptųjų sluoksnių architektūra, sudaryta iš 32, 16 ir 8 neuronų, taip pat pasiekė 89,19 % tikslumą, tačiau pasižymėjo mažesniu preciziškumu – 86,84 %. Tai rodo, kad nei didesnis tinklo gylis, nei pernelyg mažas neuronų kiekis nesuteikė aiškaus pranašumo, o nagrinėjamam biomechaninių požymių rinkiniui tinkamiausia buvo vidutinio sudėtingumo architektūra.

Tinklo pločio analizė parodė, kad platesnė dviejų paslėptųjų sluoksnių architektūra, sudaryta iš 256 ir 128 neuronų, nepasiekė didesnio bendro tikslumo nei bazinis dviejų sluoksnių modelis, sudarytas iš 64 ir 32 neuronų. Abiejų modelių tikslumas siekė 90,54 %. Vis dėlto platesnis modelis pasižymėjo didesniu preciziškumu – 93,94 %, tačiau mažesniu jautrumu – 86,11 %. Tai leidžia teigti, kad didesnis neuronų kiekis pakeitė modelio klaidų pobūdį, bet reikšmingai nepagerino bendro klasifikavimo tikslumo. Todėl vidutinio pločio architektūra laikytina pakankama biomechaninių požymių reprezentacijai.

Papildomai buvo įvertinta paketų dydžio (angl. batch size) įtaka modelio stabilumui. Geriausią rezultatą pasiekęs modelis buvo mokomas naudojant 32 pavyzdžių paketą ir pasiekė 91,89 % tikslumą. Keičiant paketų dydį bazinėje architektūroje nustatyta, kad tiek didesnis 64 pavyzdžių

paketas, tiek mažesnis 16 pavyzdžių paketas pasiekė 87,84 % tikslumą. Tai rodo, kad 32 pavyzdžių paketas suteikė tinkamiausią kompromisą tarp stabilaus gradientų skaičiavimo ir modelio gebėjimo generalizuoti duomenis.

Mokymosi greičio analizė parodė, kad standartinis „Adam“ optimizatoriaus mokymosi greitis, lygus 0,001, buvo tinkamiausias nagrinėjamam uždaviniui. Naudojant didesnę mokymosi greitį, lygų 0,01, modelio mokymas tapo mažiau stabilus, o tikslumas sumažėjo iki 83,78 %. Tuo tarpu per mažas mokymosi greitis, lygus 0,0001, lėmė nepakankamą modelio prisitaikymą prie duomenų ir pasiekė žemiausią rezultatą – 78,38 % tikslumą. Tai rodo, kad per dideli parametru atnaujinimai gali trikdyti stabilią konvergenciją, o pernelyg maži riboja modelio gebėjimą efektyviai išmokyti biomechaninių požymių struktūrą.

Atsižvelgus į atliktus eksperimentus ir įvertinus kiekvienos architektūros pranašumus bei apribojimus, galutiniu modeliu pasirinktas dviejų paslėptųjų sluoksnių neuroninis tinklas, sudarytas iš 64 ir 32 neuronų, taikant 0,1 atsitiktinių neuronų išjungimo koeficientą. Ši konfigūracija pasiekė geriausią bendrą rezultatą – 91,89 % tikslumą, 91,67 % preciziškumą, 91,67 % jautrumą ir 91,67 % F1 rodiklį. Toks pasirinkimas užtikrina geriausią balansą tarp modelio išraiškingumo, generalizacijos ir mokymo stabilumo, nes modelis išliko pakankamai lankstus biomechaninių požymių tarpusavio ryšiams išmokyti, tačiau nebuvo perteklinis pagal nagrinėjamo duomenų rinkinio apimtį.

Galutinis architektūros variantas buvo toks:

- įvesties sluoksnis: 120 požymių, sudarytų iš 117 biomechaninių požymių ir 3 pratimo tipo kodavimo požymių;
- paslėptasis sluoksnis 1: 64 neuronai, *ReLU* aktyvacija, *Dropout* 0,1;
- paslėptasis sluoksnis 2: 32 neuronai, *ReLU* aktyvacija, *Dropout* 0,1;
- išvesties sluoksnis: *sigmoid* aktyvacija (dvi klasės: taisyklingas / netaisyklingas);
- nuostolio funkcija: *BCEWithLogitsLoss*;
- optimizatorius: *Adam* (mokymosi žingsnis 0,001);
- mokymo schema: ankstyvas stabdymas (*patience* = 15), maksimaliai 100 epochų.

Skirtingai nei pratimų tipų klasifikavimo uždavinyje, šiame modelyje pratimo tipo kodavimas buvo įtrauktas kaip papildoma kontekstinė informacija. Toks sprendimas pagrįstas tuo, kad skirtingų pratimų taisyklingumas vertinamas pagal nevienodus biomechaninius kriterijus, todėl modelis turi ne tik įvertinti judesio požymius, bet ir interpretuoti juos konkrečiau pratimo kontekste.

Ši architektūra išsiskyrė stabilia treniravimo dinamika ir itin geru validacijos rinkinio tikslumu. Modelis gebėjo išlaikyti nuoseklų mokymąsi, o nuostolio (angl. *loss*) kreivės neparodė pernelyg didelio svyravimo ar išsibalansavimo tarp treniravimo ir validacijos duomenų. Tai leido jį pasirinkti kaip galutinį šiame tyrimo etape ir laikyti tinkamiausiu teisingumo klasifikavimo uždaviniui.

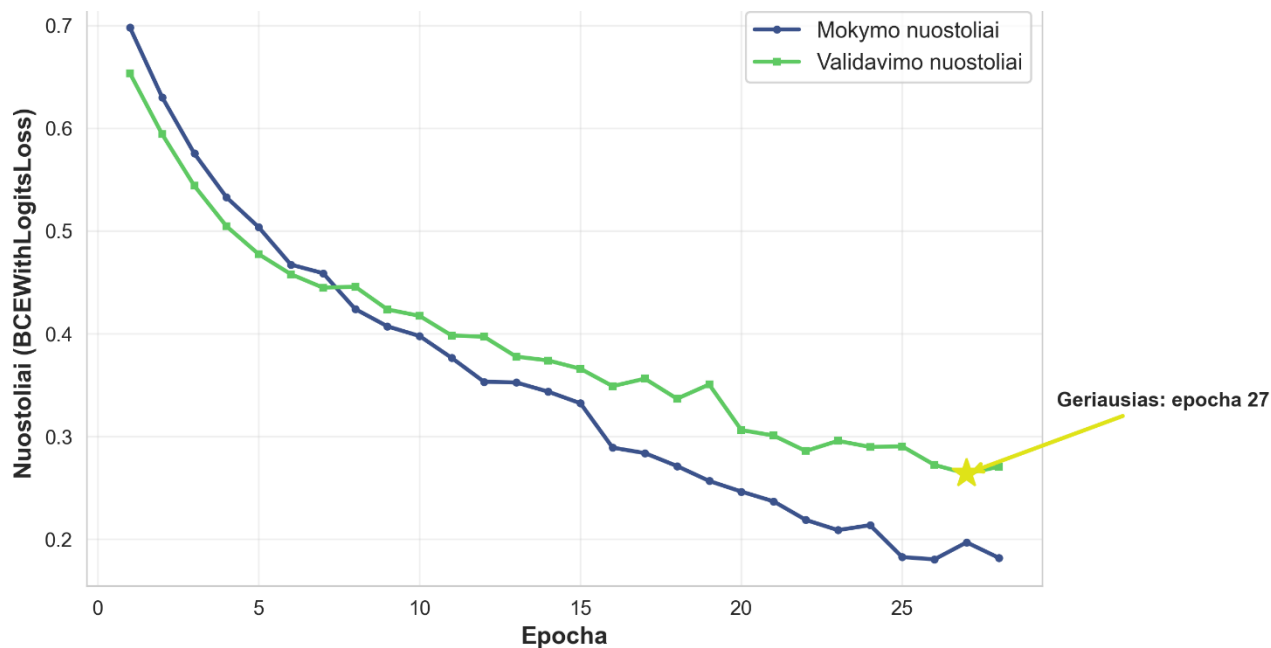
### 3.2.2. Bendrų pratimų atlikimo teisingumo klasifikacijos rezultatų analizė

Pratimų atlikimo kokybės klasifikavimo modelio vertinimas buvo atliekamas naudojant testavimo duomenų rinkinį, sudarytą iš segmentuotų pratimų kartojimų, kurie nebuvo matyti mokymo proceso metu. Šis testavimo žingsnis buvo esminis siekiant nustatyti modelio gebėjimą generalizuoti į naujus kartojimus ir įvertinti, ar išmokyti biomechaniniai dėsniniai yra pakankami teisingumo prognozėms atlikti. Galutinis modelis pasiekė 86,49 % bendrą klasifikavimo tikslumą, o tai rodo, kad jis geba pakankamai patikimai atskirti taisyklingus ir netaisyklingus pratimų atlikimus.

Šis tikslumas, nors ir žemesnis nei pratimų tipų klasifikacijos atveju, yra pagrįstas uždavinio sudėtingumu. Teisingumo klasifikavimas yra sudėtingesnis uždavinys, nes taisyklingi ir netaisyklingi kartojimai dažnai skiriasi tik subtiliais biomechaniniais bruožais: mažesne judesio amplitude, nežymiu trajektorijos nukrypimu, laiko struktūros pokyčiais ar judesio sklandumo sumažėjimu. Todėl 86,49 % tikslumas atspindi modelio gebėjimą identifikuoti pagrindinius taisyklingo ir netaisyklingo atlikimo skirtumus, tačiau kartu parodo, kad ribiniai atvejai išlieka sudėtingi automatizuotam vertinimui.

Modelio veikimą galima detaliau suprasti analizuojant papildomas klasifikavimo metrikas. Testavimo aibėje modelis pasiekė 84,21 % preciziškumą, 88,89 % jautrumą ir 86,49 % F1 rodiklį. Šie rezultatai rodo, kad modelis išlaiko gana gerą balansą tarp gebėjimo atpažinti taisyklingus kartojimus ir gebėjimo nepriimti netaisyklingų atlikimų kaip taisyklingų. Šiek tiek didesnis jautrumas nei preciziškumas rodo, kad modelis yra kiek labiau linkęs priskirti kartojimus taisyklingai klasei, todėl dalis netaisyklingų atlikimų gali būti įvertinti per palankiai. Reabilitacijos kontekste tai yra svarbus aspektas, nes klaidingas netaisyklingo judesio priskyrimas taisyklingam gali sumažinti automatizuoto grįžtamojo ryšio patikimumą.

Modelio mokymo eigą papildomai iliustruoja 3.4 pav. pateiktas mokymo ir validacijos nuostolių grafikas. Jame matoma, kaip kito prarasties reikšmės mokymo metu, todėl šis grafikas leidžia įvertinti, ar modelis mokėsi stabiliai ir ar nebuvo ryškaus persimokymo požymių. Stabilus validacijos prarasties kitimas rodo, kad modelis gebėjo išlaikyti pakankamą generalizaciją ir nebuvo pritaikytas vien tik mokymo duomenims.



3.4 pav. Mokymo ir validacijos nuostolių grafikas

Svarbiausia šio etapo vizualinė analizė yra 3.5 pav. pateikta klasifikacijos maišaties matrica, kuri leidžia įvertinti modelio klaidų pobūdį. Testavimo aibėje modelis teisingai atpažino 32 netaisyklingus ir 32 taisyklingus kartojimus. Klaidingai 6 netaisyklingi kartojimai buvo priskirti taisyklingiems, o 4 taisyklingi kartojimai – netaisyklingiems. Tai reiškia, kad modelis padarė 10 klaidų iš 74 testavimo pavyzdžių. Klaidų pasiskirstymas rodo, kad modelis nėra stipriai šališkas vienai klasei, tačiau šiek tiek dažniau netaisyklingą atlikimą įvertina kaip taisyklingą.



3.5 pav. Klasifikacijos maišaties matrica

Bendras modelio įvertinimas sudaro pagrindą detalesnei analizei pagal atskirus pratimus, nes teisingumo požymiai ir klaidų pobūdis gali skirtis priklausomai nuo konkretaus judesio tipo. Rankos kėlimas į šoną, „V–W“ rankų judesys ir atsispaudimai nuo stalo turi skirtingus taisyklingumo kriterijus, todėl tolesniuose poskyriuose pateikiama analizė pagal pratimus padeda išryškinti, kur modelis veikia tiksliausiai, o kur susiduria su ribiniais biomechaniniais iššūkiais. Ši informacija svarbi siekiant suprasti modelio ribotumus ir nustatyti galimas tobulinimo kryptis.

### 3.2.3. Teisingumo analizė pagal kiekvieną pratimą

Pratimų atlikimo teisingumo vertinimas reikalauja detalesnės analizės pagal atskirus pratimus, nes kiekvienas iš trijų tyrime naudotų judesių pasižymi skirtinga biomechanine struktūra ir skirtingais taisyklingo atlikimo kriterijais. Dėl šios priežasties bendras modelio tikslumas neviseiškai atskleidžia, kuriuos pratimus modelis vertina patikimiausiai, o kuriuose dažniau susiduriama su ribiniais arba dviprasmiškais atlikimo atvejais. Toliau pateiktoje lentelėje (3.3 lentelė.) parodyti pratimų atlikimo teisingumo klasifikavimo rezultatai pagal kiekvieną pratimą.

3.3 lentelė. Modelio rezultatai per pratimą

Pratimas	Tikslumas	Preciziškumas	Jautrumas	F1 rodiklis
Ex1 – rankos kėlimas į šoną	96,30 %	100,00 %	92,86 %	96,30 %
Ex2 – „V–W“ rankų judesys	80,65 %	83,33 %	71,43 %	76,92 %

Ex3 – atsispaudimai nuo stalo	81,25 %	77,78 %	87,50 %	82,35 %
Bendrai	86,49 %	84,21 %	88,89 %	86,49 %

Gauti rezultatai rodo, kad modelis tiksliausiai vertino Ex1 pratimą – rankos kėlimą į šoną. Šio pratimo tikslumas siekė 96,30 %, o preciziškumas – 100,00 %, todėl galima teigti, kad modelis beveik be klaidų atpažino taisyklingus ir netaisyklingus šio pratimo atlikimus. Tokį rezultatą galima sieti su aiškia ir santykinai paprasta pratimo biomechanine struktūra: ranka daugiausia keliama į šoną viena pagrindine kryptimi, todėl nukrypimai nuo taisyklingos trajektorijos yra lengviau identifikuojami.

Ex2 ir Ex3 pratimų rezultatai buvo žemesni. Ex2 pratimo tikslumas siekė 80,65 %, o F1 rodiklis – 76,92 %, todėl šis pratimas modeliui buvo sudėtingiausias. Tai gali būti siejama su „V–W“ judesio koordinaciniu pobūdžiu, kai vertinant taisyklingumą svarbi ne tik rankų padėtis, bet ir sklandus perėjimas tarp skirtingų rankų formų. Ex3 pratimo tikslumas siekė 81,25 %, o F1 rodiklis – 82,35 %. Šio pratimo atveju modelis geriau atpažino taisyklingus atlikimus, tačiau dėl mažesnio testavimo bandinių skaičiaus rezultatai turėtų būti interpretuojami atsargiau.

Apibendrinant galima teigti, kad modelio veikimo kokybė priklauso nuo konkretaus pratimo biomechaninio sudėtingumo. Paprastesnės ir aiškiau apibrėžtos trajektorijos pratimas buvo klasifikuojamas tiksliausiai, o sudėtingesni judesiai pasižymėjo mažesniu tikslumu. Vis dėlto bendras 86,49 % tikslumas rodo, kad pasirinktas biomechaninių požymių rinkinys leidžia pakankamai patikimai vertinti viršutinių galūnių reabilitacijos pratimų atlikimo taisyklingumą.

### 3.2.4. Klaidų analizė ir interpretacija

Pratimų atlikimo teisingumo klasifikavimo uždavinys iš prigimties yra sudėtingesnis nei pratimų tipo identifikavimas, todėl modelio klaidų analizė suteikia vertingų įžvalgų apie tai, kokie biomechaniniai aspektai yra sunkiausiai įvertinami automatizuotai. Kadangi taisyklingas ir netaisyklingas atlikimas dažnai skiriasi tik subtiliais požymiais – nežymiai sumažėjusia amplitude, trumpais trajektorijos disbalanso epizodais ar judesio sklandumo praradimu – klaidos dažniausiai atsiranda ribiniuose atvejuose. Tai atsispindi ir modelio prognozių tikimybių pasiskirstyme: kuo mažesnis skirtumas tarp taisyklingų ir netaisyklingų kartojimų vidutinių tikimybių, tuo sudėtingiau modeliui priimti aiškų sprendimą.

Toliau pateiktoje lentelėje (3.4 lentelė.) parodytas modelio pasitikėjimo pasiskirstymas pagal atskirus pratimus. Netaisyklingų kartojimų vidutinė tikimybė parodo, kokią vidutinę tikimybę modelis priskyrė klasei „taisyklingas“, kai kartojimas iš tikrųjų buvo netaisyklingas. Taisyklingų kartojimų vidutinė tikimybė rodo atitinkamą modelio pasitikėjimą tais atvejais, kai kartojimas iš tikrųjų buvo taisyklingas. Atskyrimo reikšmė apskaičiuota kaip skirtumas tarp šių dviejų vidutinių tikimybių.

3.4 lentelė. Rezultatų pasiskirstymas pagal atskirus pratimus

Pratimas	Netaisyklingų vid. tikimybė	Taisyklingų vid. tikimybė	Atskyrimas	Tikslumas
Ex1 – rankos kėlimas į šoną	0,107 ( $\sigma = 0,096$ )	0,814 ( $\sigma = 0,154$ )	0,707	96,3 %
Ex2 – „V–W“ rankų judesys	0,222 ( $\sigma = 0,256$ )	0,718 ( $\sigma = 0,256$ )	0,496	80,7 %

Ex3 – atsispaudimai nuo stalo	0,392 ( $\sigma = 0,328$ )	0,840 ( $\sigma = 0,231$ )	0,448	81,3 %
-------------------------------	----------------------------	----------------------------	-------	--------

Lentelėje pateikti rezultatai rodo, kad aiškiausias taisyklingų ir netaisyklingų kartojimų atskyrimas pasiektas Ex1 pratime. Netaisyklingiems Ex1 kartojimams modelis vidutiniškai priskyrė tik 0,107 taisyklingumo tikimybę, o taisyklingiems – 0,814. Šių reikšmių skirtumas siekė 0,707, todėl modelis galėjo gana aiškiai diferencijuoti abi klases. Tai paaiškina ir aukščiausią šio pratimo tikslumą – 96,3 %. Toks rezultatas rodo, kad rankos kėlimo į šoną biomechaninė struktūra yra aiškiai apibrėžta, o nukrypimai nuo taisyklingos trajektorijos modelio atpažįstami pakankamai patikimai.

Ex2 ir Ex3 pratimų atveju atskyrimas buvo mažesnis. Ex2 pratime skirtumas tarp netaisyklingų ir taisyklingų kartojimų vidutinių tikimybių siekė 0,496, o Ex3 pratime – 0,448. Tai rodo, kad šių pratimų taisyklingi ir netaisyklingi atlikimai modelio požymių erdvėje buvo artimesni vieni kitiems. Ex2 atveju tai galima sieti su sudėtingesne „V–W“ judesio koordinacija, kai taisyklingumą lemia ne vien rankų padėtis, bet ir sklandus perėjimas tarp skirtingų judesio fazių. Ex3 atveju didesnė netaisyklingų kartojimų vidutinė tikimybė, siekianti 0,392, rodo, kad dalis netaisyklingų atsispaudimų nuo stalo buvo gana panašūs į taisyklingus atlikimus, todėl modelis juos vertino ne taip užtikrintai.

Analizuojant modelio klaidas galima išskirti dvi pagrindines jų grupes. Pirmoji apima atvejus, kai taisyklingas atlikimas klaidingai priskiriamas netaisyklingam. Tokios klaidos dažniausiai gali atsirasti tada, kai judesys yra arti minimalios reikalaujamos amplitudės ribos arba pasižymi nedideliu šoniniu trajektorijos svyravimu, kuris biomechanškai dar gali būti priimtinas, tačiau modelio sprendimų ribose patenka į netaisyklingo judesio zoną. Antroji grupė apima priešingus atvejus, kai netaisyklingas atlikimas priskiriamas taisyklingam. Šios klaidos yra svarbios rehabilitacijos kontekste, nes gali lemti per palankų paciento judesio įvertinimą. Jos tikėtinos tais atvejais, kai judesio defektas yra subtilus, pavyzdžiui, šiek tiek sumažinta amplitudė, nedidelė kompensacija arba nežymus ritmo nestabilumas.

Be biomechaninių niuansų, klaidoms įtakos gali turėti ir techniniai veiksniai. „MediaPipe“ algoritmas, nors ir efektyvus, nėra visiškai atsparus uždengtiems sąnariams, greitiems judesiams ar situacijoms, kai dalyvio padėtis kameros atžvilgiu kinta. Tokiais atvejais skeletinių taškų lokalizavimas gali svyruoti, o tai paveikia išvestinius požymius ir galutinius modelio sprendimus. Taip pat dalyvių individualios judesių variacijos, pavyzdžiui, skirtingas atlikimo tempas, nežymiai kitokia rankos padėtis ar nevienodas laikymas judesio fazėse, gali būti biomechanškai priimtinos, tačiau modelio interpretuojamos kaip artimos klaidos ribai.

Apibendrinant galima teigti, kad klaidų analizė patvirtina ryšį tarp modelio pasitikėjimo atskyrimo ir klasifikavimo tikslumo. Ex1 pratime, kuriame taisyklingų ir netaisyklingų kartojimų tikimybės buvo aiškiausiai atskirtos, pasiektas didžiausias tikslumas. Ex2 ir Ex3 pratimai pasižymėjo mažesniu tikimybių atskyrimu ir žemesniu tikslumu, todėl jų vertinimas modeliui buvo sudėtingesnis. Šie rezultatai rodo, kad modelis patikimai atpažįsta ryškesnes biomechanines anomalijas, tačiau susiduria su didesniais sunkumais tada, kai netaisyklingi kartojimai yra labai artimi taisyklingam judesiui.

### 3.2.5. Skyriaus apibendrinimas

Šiame skyriuje pristatyta pratimų atlikimo teisingumo klasifikavimo analizė parodė, kad sukurtas modelis, pagrįstas 120 įvesties požymių rinkiniu ir dviejų paslėptųjų sluoksnių neuronine architektūra, geba pakankamai patikimai atskirti taisyklingus ir netaisyklingus viršutinių galūnių reabilitacijos pratimų kartojimus. Modelio įvestį sudarė 117 biomechaninių požymių ir 3 pratimo tipo kodavimo požymiai, kurie buvo įtraukti todėl, kad teisingumo vertinimo kriterijai priklauso nuo konkretaus pratimo biomechanikos. Galutinis modelis testavimo aibėje pasiekė 86,49 % tikslumą, 84,21 % preciziškumą, 88,89 % jautrumą ir 86,49 % F1 rodiklį.

Detalesnė analizė pagal pratimus parodė, kad modelio veikimo kokybė priklauso nuo konkretaus judesio struktūros. Geriausi rezultatai pasiekti Ex1 pratime – rankos kėlime į šoną, kurio tikslumas siekė 96,30 %. Šio pratimo atveju modelis aiškiausiai atskyrė taisyklingus ir netaisyklingus kartojimus, nes jų vidutinių tikimybių skirtumas siekė 0,707. Ex2 ir Ex3 pratimų tikslumas buvo mažesnis – atitinkamai 80,65 % ir 81,25 %, o taisyklingų ir netaisyklingų kartojimų tikimybių atskyrimas taip pat buvo mažesnis. Tai rodo, kad koordinaciškai sudėtingesni arba kelių kūno segmentų kontrolės reikalaujantys judesiai modeliui buvo sunkiau vertinami.

Klaidų analizė parodė, kad modelis patikimai atpažįsta aiškesnius taisyklingo ir netaisyklingo atlikimo atvejus, tačiau sunkiau klasifikuoja ribinius kartojimus, kuriuose netaisyklingumas pasireiškia subtiliais biomechaniniais nukrypimais. Tokie atvejai gali būti susiję su nedideliu judesio amplitudės sumažėjimu, laikinu trajektorijos nestabilumu, judesio ritmo pokyčiais arba individualiomis dalyvių atlikimo variacijomis. Dėl šios priežasties pratimų atlikimo teisingumo klasifikavimas yra sudėtingesnis nei pratimų tipo atpažinimas, net jei naudojamas tas pats biomechaninių požymių pagrindas.

Apibendrinant galima teigti, kad pasirinkta dviejų paslėptųjų sluoksnių neuroninio tinklo architektūra su 0,1 atsitiktinių neuronų išjungimo koeficientu yra tinkama šiam uždaviniui, nes užtikrina pakankamą balansą tarp tikslumo, generalizacijos ir stabilumo. Gauti rezultatai sudaro pagrindą tolimesnei XAI analizei, kurios tikslas – nustatyti, kokie biomechaniniai požymiai labiausiai lemia modelio sprendimus ir kaip šie požymiai skiriasi tarp atskirų pratimų.

### 3.3. Paaiškinamųjų dirbtinio intelekto (XAI) metodų taikymas pratimų teisingumo analizei

#### 3.3.1. XAI poreikis

Pratimų atlikimo teisingumo vertinimas, kaip buvo parodyta ankstesniame skyriuje, yra sudėtingas uždavinys, kuriame modelis turi atpažinti subtilius biomechaninius judesio skirtumus tarp taisyklingo ir netaisyklingo atlikimo. Nors bendras modelio tikslumas yra pakankamai aukštas ir rodo, kad sukurtas metodas geba patikimai identifikuoti daugumą kokybės aspektų, tokie rezultatai savaime nėra pakankami praktiniam taikymui reabilitacijos kontekste. Reabilitacijos procesas yra glaudžiai susijęs su paciento saugumu, ilgalaikiu judėjimo funkcijos atkūrimu ir individualizuota progresijos stebėseną, todėl DI sprendimai negali būti vertinami tik pagal jų tikslumą – būtina suprasti, kodėl modelis priima konkrečius sprendimus.

Tokiais atvejais paaiškinamasis dirbtinis intelektas (XAI) tampa esmine tyrimo dalimi. XAI metodai leidžia atskleisti skaitinius ir vizualius pagrindimus, kuriais remiasi modelis vertindamas judesio teisingumą. Tai suteikia galimybę įvertinti, ar modelis mokosi biomechanškai pagrįstų dėsningumų,

ar jo sprendimai paremti atsitiktinėmis priklausomybėmis, galinčiomis sukelti klaidingą ar potencialiai pavojingą interpretaciją. Atnaujinta tyrimo analizė parodė, kad modelis iš tiesų išmoko reikšmingus, kineziologijoje įtvirtintus kokybės rodiklius – judesio tolygumą, simetriją, sąnarių kampų kontrolę, trajektorijos stabilumą ir kompensacinių judesių nebuvimą. Tai ne tik sustiprina modelio patikimumą, bet ir leidžia pradėti nagrinėti jo veikimą iš klinikinės perspektyvos.

*XAI* metodų reikalingumą pagrindžia ir tai, kad reabilitacijoje sprendimų interpretacija yra neatsiejama nuo personalizavimo. Fizioterapeutai priima sprendimus remdamiesi tiek bendrais biomechaniniais principais, tiek individualiomis paciento savybėmis – amplitudžių ribomis, skausmo tolerancija, sąnarių mobilumu ar kompensaciniais įpročiais. Todėl automatizuota sistema, kuri gali pateikti paaiškinimus apie tai, kokie požymiai prisidėjo prie tam tikro įvertinimo, gali būti naudojama ne tik diagnozei paremti, bet ir paciento mokymui, jo motyvacijos stiprinimui bei korekcinės terapijos planavimui. Toks aiškinamumas leidžia sistemą integruoti į realią klinikinę praktiką, nes suteikia skaidrumą ir profesionalų pasitikėjimą modelio logika.

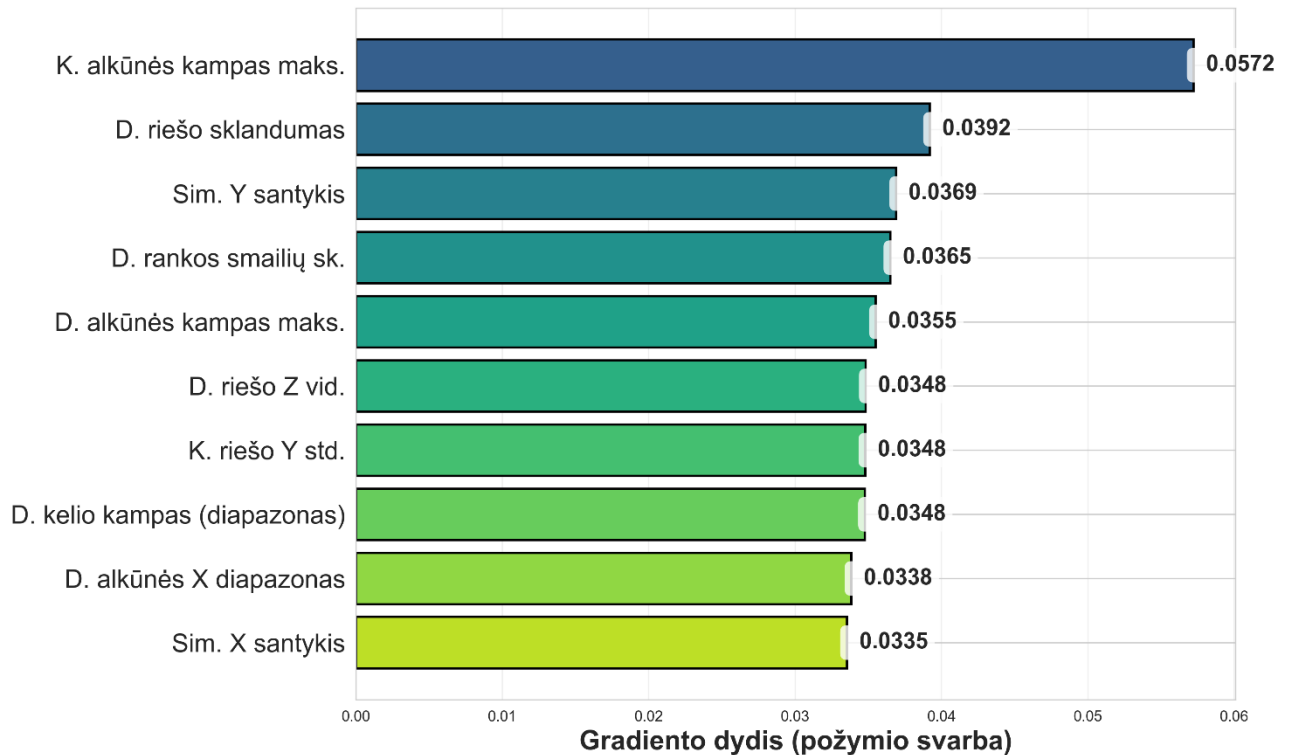
Šio skyriaus tikslas – detalai išanalizuoti, kokie požymiai yra svarbiausi modelio sprendimams, kaip jie skiriasi tarp pratimų, kaip modelis suderina bendrąsias kokybės vertinimo taisykles su pratimo specifiniais reikalavimais ir kaip šios išvalgos padeda suprasti jo veikimą giliau nei leidžia vien tik klasifikacijos metrikos. Taip pat šiame skyriuje bus siekiama parodyti, kad modelio išmoktos taisyklės yra biomechanškai pagrįstos, o tai yra kertinis reikalavimas visoms sveikatos priežiūros *DI* sistemoms.

### **3.3.2. Naudoti *XAI* metodai ir jų taikymo logika**

Pratimų atlikimo teisingumo klasifikavimo modelio veikimo analizei buvo taikytas kelių paaiškinamojo dirbtinio intelekto (*XAI*) metodų rinkinys. Šių metodų derinys pasirinktas tam, kad būtų galima išsamiai ir iš kelių perspektyvų įvertinti, kokie požymiai labiausiai prisideda prie modelio sprendimų, koku būdu jie sąveikauja, ir ar modelio mokymosi procesas remiasi biomechanškai pagrįstomis savybėmis. Kadangi kokybės klasifikacija yra jautrus ir kliniškai reikšmingas uždavinys, vienas metodas negali suteikti viso reikalingo vaizdo – todėl šiame tyrime buvo pasirinkta naudoti trijų skirtingų tipų *XAI* metodus, kurių kiekvienas pateikia kitokio pobūdžio informaciją apie modelio sprendimų pagrindą.

Pirmasis metodas – gradientais pagrįsta svarbos analizė (angl. *gradient-based feature importance*). Šis metodas įvertina, kaip jautriai modelio išvestis reaguoja į nedidelius kiekvieno požymio pokyčius (3.6 pav.). Kitaip tariant, jis parodo, kurie požymiai turi tiesioginę, momentinę įtaką modelio prognozei. Gradientų metodai yra ypač naudingi vertinant aukšto tikslumo modelius, nes jie leidžia identifikuoti požymius, kurie lemia sprendimą tose situacijose, kur modelis yra „tikras“ savo sprendimu. Be to, gradientinė analizė atskleidžia ir požymius, kurie turi nuoseklų vaidmenį klasifikacijos procesuose.

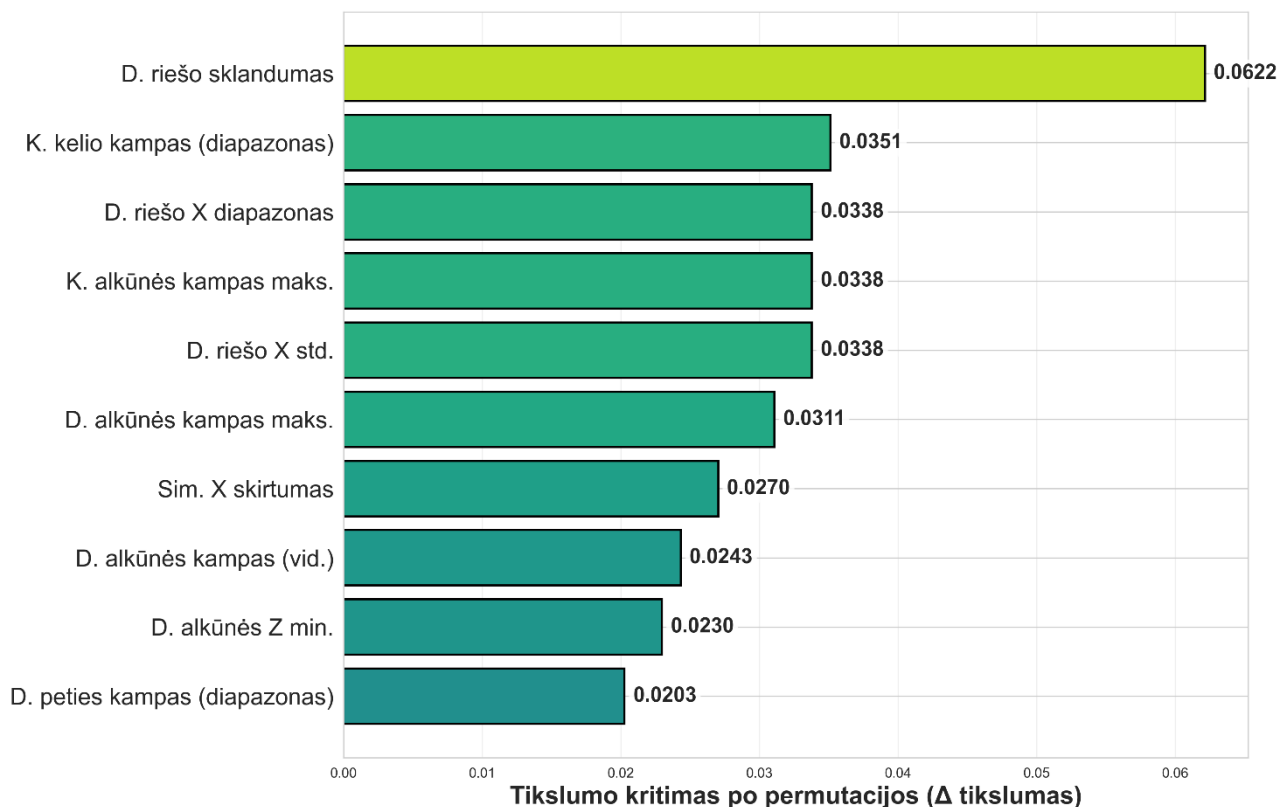
### Gradientais grįsta požymių svarba 10 svarbiausių požymių teisingumo prognozavimui



3.6 pav. Gradientu pagrįstų įvesčių svarba

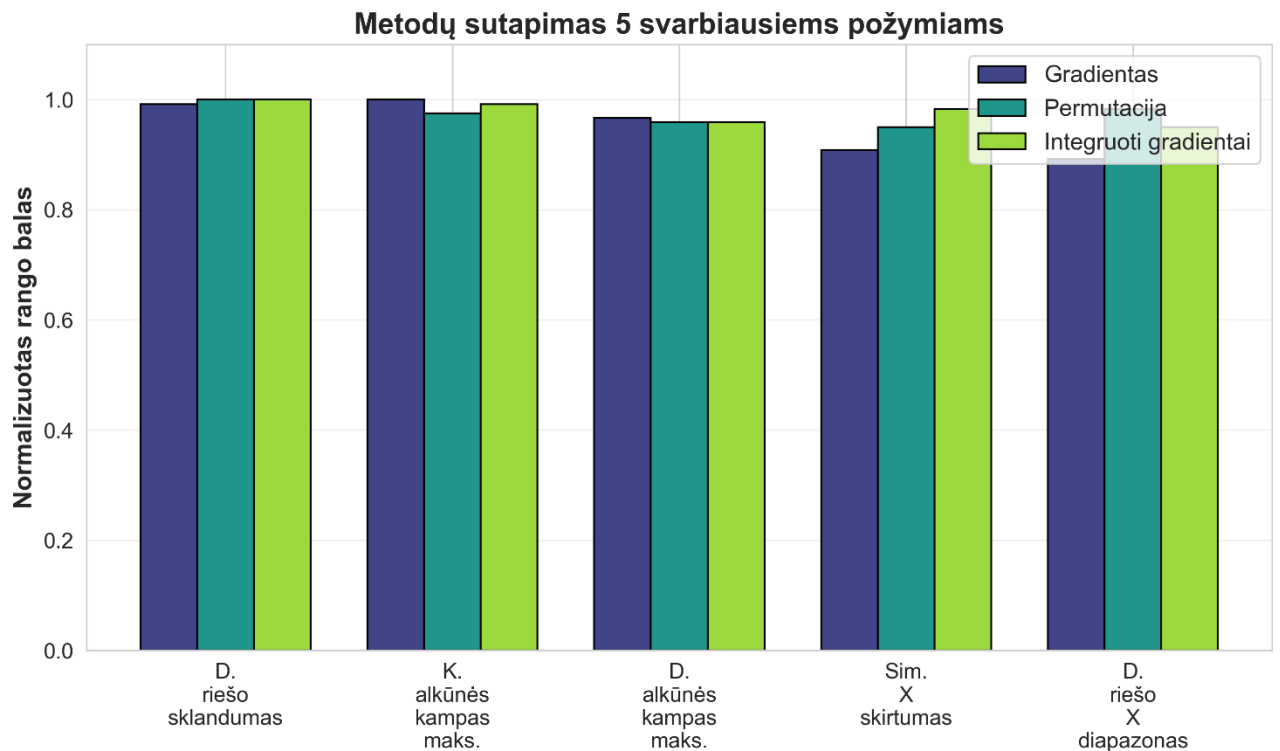
Antrasis metodas, permutacijų svarbos analizė (angl. *permutation feature importance*), taikomas norint įvertinti kiekvieno požymio globalią įtaką modelio tikslumui. Permutavus (atsitiktinai sumaišius) tam tikro požymio reikšmes ir įvertinus, kiek blogėja modelio veikimas, galima nustatyti, kurie požymiai yra reikalingi modeliui stabiliai klasifikuoti taisyklingus ir netaisyklingus kartojimus (3.7 pav.). Šis metodas yra itin vertingas, nes jis nepriklauso nuo modelio architektūros ir gali būti taikomas bet kokio tipo neuroniniam tinklui. Permutacijų analizė taip pat atskleidžia požymius, kurie nebūtinai daro didelę momentinę įtaką (kaip gradientų metodas), bet yra būtini ilgalaikiam stabilumui ir bendram modelio veikimui.

**Permutacijų požymių svarba  
10 svarbiausių požymių teisingumo prognozavimui**



3.7 pav. Permutacijų požymių svarbos grafikas

Trečiasis metodas – integruotų gradientų analizė (angl. *Integrated Gradients*). Šis metodas jungia gradientinės analizės tikslumą su globaliu stabilumo vertinimu, nes skaičiuoja požymių svarbą integruojant gradientus nuo neutralaus bazinio įvesties taško iki realaus duomenų taško. Integruotų gradientų metodas yra ypač tinkamas reabilitacinės biomechanikos analizei, nes jis leidžia įvertinti ne tik tiesioginę įtaką sprendimui, bet ir tai, kaip modelio sprendimai kinta matuojant visą požymio reikšmės intervalą. Šis požiūris padeda identifikuoti sudėtinius, kelių požymių sąveika paremtus sprendimus, kurie natūraliai būdingi motorinių judesių analizėje.



3.8 pav. Paaiškinamųjų DI metodų palyginimas skirtingiems požymiams

Šių trijų metodų kombinacija (3.8 pav.) suteikia pilną ir daugiasluksnį modelio veikimo vaizdą:

- **gradientai** parodo momentinį poveikį,
- **permutacijos** įvertina globalią svarbą,
- **integruoti gradientai** atskleidžia kintančią požymių įtaką visame jų diapazone.

Be to, kelių metodų sutapimas yra esminis patikimumo rodiklis. Nepaisant metodologinių skirtumų, skirtingi *XAI* metodai nuosekliai identifikavo tuos pačius arba biomechanškai artimus požymius. Dažniausiai išryškėjo alkūnės kampų kontrolę apibūdinantys rodikliai, ypač kairiosios ir dešinėsios alkūnės kampo maksimalios reikšmės, riešo judesio tolygumo įvertis, simetrijos požymiai bei riešo ir alkūnės trajektorijos stabilumo rodikliai. Toks rezultatų sutapimas patvirtina, kad modelis mokosi biomechanškai prasmingų dėsningumų ir nesiremia atsitiktinėmis koreliacijomis, kurios galėtų mažinti praktinio taikymo patikimumą.

### 3.3.3. Bendroji požymių svarbos analizė

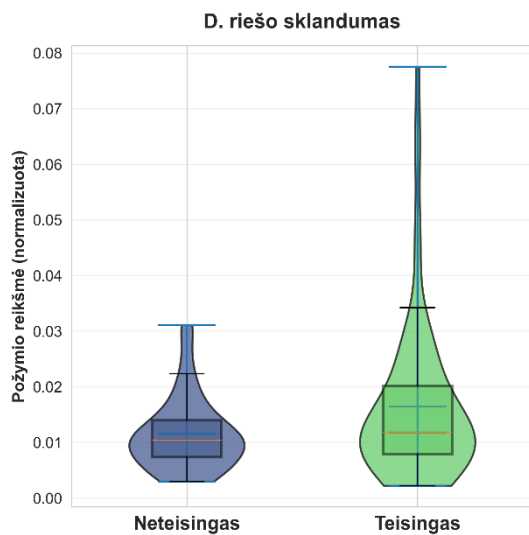
Analizuojant modelio sprendimų logiką trimis skirtingais *XAI* metodais – gradientine svarbos analize, permutacijų svarba ir integruotais gradientais – paaiškėjo, kad modelis remiasi ne pavieniais signalais, o nuoseklia biomechaninių požymių struktūra, kuri yra būdinga visų trijų viršutinių galūnių pratimų taisyklingam atlikimui. Šių metodų rezultatai tarpusavyje sutampa, o tai rodo, kad modelis veikė stabiliai, jo sprendimai buvo grindžiami tais pačiais pagrindiniais dėsningumais nepriklausomai nuo *XAI* metodologijos.

Svarbu pažymėti, kad šiame tyrime identifiukuoti požymiai pasikartoja keliuose analizės dimensijose:


- jie dažnai pasirodo trijų *XAI* metodų konsensuse,
- jie pasirodo atskirų pratimų analizėse,
- jie taip pat atkartojami skirtumų tarp taisyklingų ir netaisyklingų atlikimų analizėje (t. y. didžiausio procentinio pokyčio požymiuose).

Gradientinė analizė parodė (3.6 pav.), kad svarbiausias požymis buvo kairiosios alkūnės kampo maksimali reikšmė (angl. *left\_elbow\_angle\_max*), kurios svarba siekė 0,0572. Tai rodo, kad modelio prognozės buvo ypač jautrios alkūnės lenkimo amplitudės pokyčiams. Šis rezultatas biomechanškai pagrįstas, nes visi trys analizuoti pratimai – rankos kėlimas į šoną, „V–W“ rankų judesys ir atsispaudimai nuo stalo – reikalauja kontroliuojamo alkūnės bei viršutinės galūnės judesio. Todėl net nedideli alkūnės kampo pokyčiai gali būti reikšmingi atskiriant taisyklingą ir netaisyklingą atlikimą.

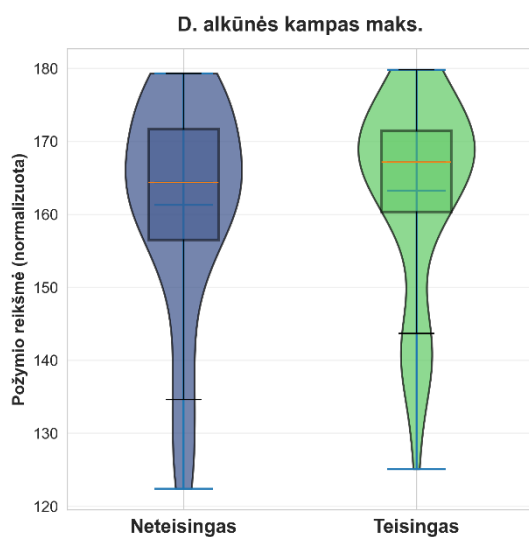
Kitas itin svarbus požymis buvo dešiniojo riešo judesio tolygumo įvertis (angl. *right\_wrist\_smoothness\_score*). Nors gradientinėje analizėje (3.6 pav.) šis požymis buvo antras pagal svarbą, permutacijų analizėje (3.7 pav.) jis tapo svarbiausiu rodikliu: sumaišius šio požymio reikšmes, modelio tikslumas sumažėjo 6,22 %. Tai leidžia teigti, kad judesio tolygumas yra vienas svarbiausių globalių pratimų kokybės indikatorių. Biomechanškai tai reiškia, kad taisyklingam atlikimui būdingas sklandus, kontroliuojamas ir be staigių trūkčiojimų atliekamas judesys, o netolygus riešo judėjimas gali rodyti kompensacijas, nepakankamą motorinę kontrolę arba netikslų pratimo atlikimą.



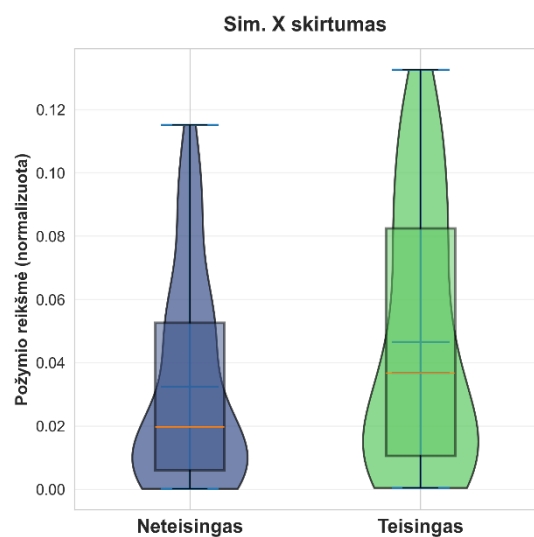
a) Dešinio riešo sklandumas



b) Kairiosios alkūnės maksimalus kampas



c) Dešinioios alkūnės maksimalus kampas



d) Simetrijos X ašies skirtumas

3.9 pav. Įvesties pasiskirstymas teisingo ir neteisingo pratimo atžvilgiu

Reikšmingą vietą užėmė ir dešinėsios alkūnės kampo maksimali reikšmė (angl. *right\_elbow\_angle\_max*), kuri pateko į svarbiausių požymių sąrašus visuose taikytuose XAI metuose (3.8 pav.). Kartu su kairiosios alkūnės kampo maksimalia reikšme šis rodiklis rodo, kad modelis daug dėmesio skyrė abiejų viršutinių galūnių sąnarių kampų kontrolei. Tai ypač svarbu vertinant pratimus, kuriuose taisyklumas priklauso nuo tinkamos rankų padėties, judesio amplitudės ir alkūnių lenkimo ar tiesimo kontrolės (3.9 pav.).

Simetrijos požymiai taip pat išliko reikšmingi, tačiau jie nebėra vieninteliai dominuojantys rodikliai. Vertikaliosios simetrijos santykis (angl. *symmetry\_y\_ratio*) gradientinėje analizėje pateko tarp trijų svarbiausių požymių, o horizontaliosios simetrijos skirtumas (angl. *symmetry\_x\_difference*) bei vertikaliosios simetrijos skirtumas (angl. *symmetry\_y\_difference*) buvo svarbūs permutacijų analizėje. Tai rodo, kad modelis vertino ne tik atskirų sąnarių judesius, bet ir bendrą kūno bei rankų pusiausvyrą. Asimetriškas judesys gali rodyti kompensacinį elgesį, netolygų krūvio paskirstymą arba nepakankamą kūno kontrolę pratimo metu.

Papildomai svarbūs buvo sąnarių padėties variacijos ir judesio amplitudės požymiai. Permutacijų analizėje išsiskyrė dešiniojo riešo X koordinatės diapazonas (angl. *right\_wrist\_x\_range*), dešiniojo riešo X koordinatės standartinis nuokrypis (angl. *right\_wrist\_x\_std*) ir dešinėsios alkūnės X koordinatės diapazonas (angl. *right\_elbow\_x\_range*). Šie požymiai rodo, kad modelis vertino ne tik galutinę rankos padėtį, bet ir judesio trajektorijos stabilumą. Didesnė šoninė riešo ar alkūnės variacija gali reikšti, kad judesys atliekamas nestabiliai arba nukrypsta nuo taisyklingos trajektorijos.

Bendra XAI analizė parodė, kad patikimiausiais požymiais galima laikyti tuos, kurie pasikartojo keliuose skirtinguose XAI metuose. Į visų trijų metodų svarbiausių požymių sąrašus pateko kairiosios alkūnės kampo maksimali reikšmė, dešiniojo riešo judesio tolygumo įvertis ir dešinėsios alkūnės kampo maksimali reikšmė. Tai leidžia teigti, kad būtent alkūnės kampų kontrolė ir riešo judesio tolygumas sudaro pagrindinį modelio sprendimų pagrindą vertinant viršutinių galūnių reabilitacijos pratimų atlikimo teisingumą.

Svarbu pažymėti, kad naujoje analizėje pratimo tipo kodavimo požymiai nepateko tarp svarbiausių modelio sprendimus lemiančių rodiklių. Tai rodo, kad nors pratimo tipas buvo įtrauktas į teisingumo klasifikavimo modelio įvestį, modelis daugiausia rėmėsi ne pačia pratimo žyma, o realiais biomechaniniais signalais. Šis rezultatas sustiprina modelio interpretacijos patikimumą, nes parodo, kad sprendimai buvo grindžiami judesio kokybės požymiais, o ne formalia klasės informacija.

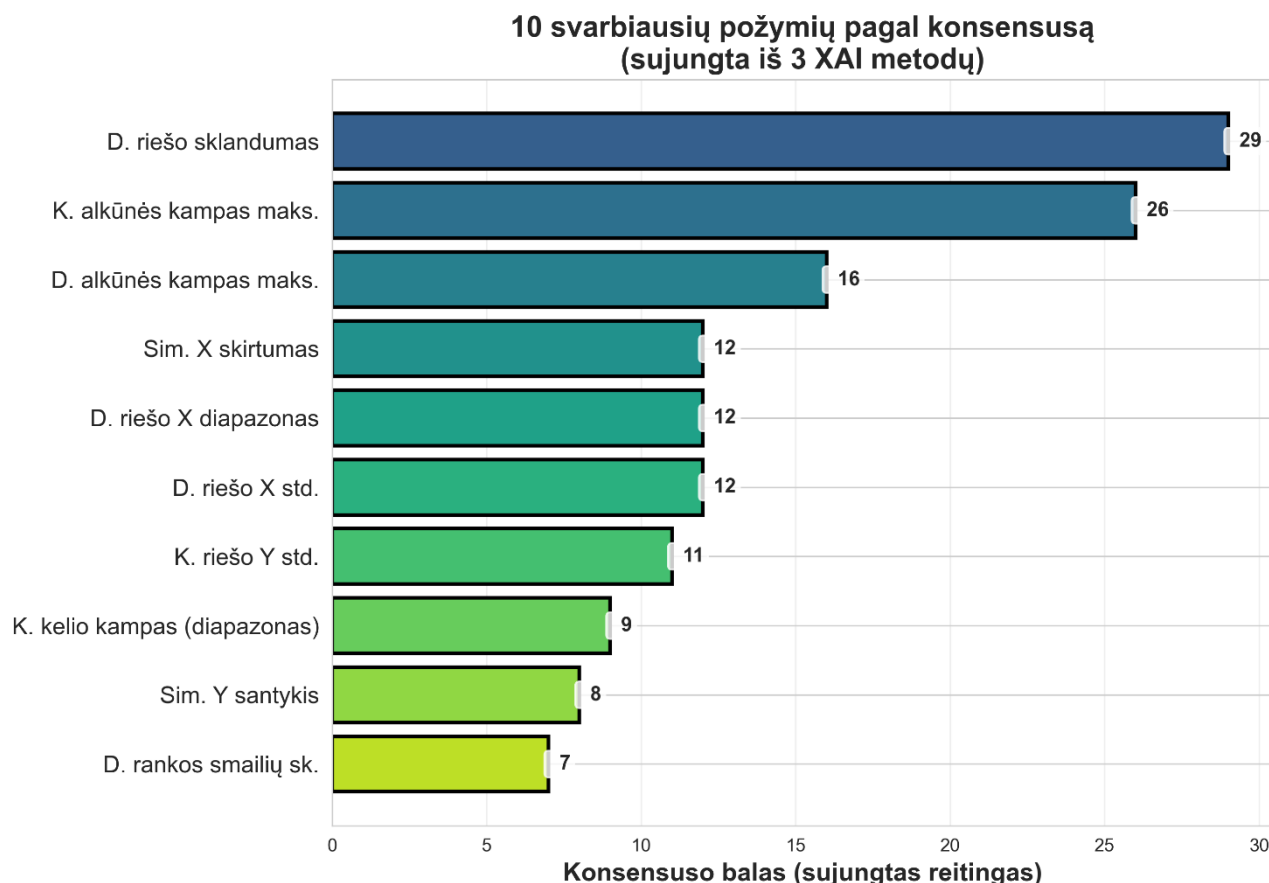
Apibendrinant galima teigti, kad bendroji požymių svarbos analizė patvirtino modelio sprendimų biomechaninį pagrįstumą. Modelis daugiausia rėmėsi alkūnės kampų kontrole, riešo judesio tolygumu, simetrijos rodikliais ir sąnarių padėties stabilumu. Šie požymiai tiesiogiai siejasi su reabilitacinių pratimų atlikimo kokybe, todėl XAI rezultatai leidžia teigti, kad modelis išmoko prasmingus judesio vertinimo dėsningumus, o ne atsitiktines ar techniškai nereikšmingas duomenų koreliacijas.

#### **3.3.4. Universalių pratimų kokybės rodiklių biomechaninė interpretacija**

XAI analizė atskleidė, kad modelis, atlikdamas pratimų teisingumo klasifikaciją, remiasi nuosekliu ir biomechaniskai pagrįstu požymių rinkiniu, kuris yra bendrai svarbus visiems pratimų tipams. Šiuos požymius galima vadinti universaliais kokybės rodikliais, nes jie nepriklauso nuo konkretaus pratimo

trajektorijos ar judesio plokštumos, tačiau visada išlieka informatyvūs vertinant, ar kartojimas buvo atliktas taisyklingai.

Bendras *XAI* metodų konsensusas pateiktas 3.10 pav. Jame apibendrinami trijų taikytų *XAI* metodų – gradientinės analizės, permutacijų svarbos ir integruotų gradientų – rezultatai. Kuo didesnis konsensuso balas, tuo nuosekliau konkretus požymis buvo identifikuotas kaip svarbus skirtinguose paaiškinamumo metoduose. Šis grafikas leidžia įvertinti ne pavienio metodo rezultatą, o bendrą modelio sprendimų struktūrą.



3.10 pav. Svarbiausių požymių, leidžiančių nustatyti judesio kokybę, grafikas

Pagal 3.10 pav. aiškiausiai išsiskyrė du požymiai: dešiniojo riešo judesio sklandumo įvertis (angl. *right\_wrist\_smoothness\_score*) ir kairiosios alkūnės kampo maksimali reikšmė (angl. *left\_elbow\_angle\_max*). Pirmasis požymis pasiekė didžiausią konsensuso balą ir buvo svarbiausias tiek permutacijų, tiek integruotų gradientų analizėse. Tai rodo, kad judesio sklandumas yra vienas stabiliausių modelio sprendimų pagrindų. Biomechanškai tai pagrįsta, nes taisyklingai atliekamas pratimas turėtų pasižymėti tolygiu, kontroliuojamu ir be staigių trūkčiojimų vykdomu judesiu. Netolygus riešo judėjimas gali rodyti kompensacinius judesius, nepakankamą motorinę kontrolę arba netikslų pratimo atlikimą.

Kairiosios alkūnės kampo maksimali reikšmė buvo antras pagal konsensuso balą požymis ir svarbiausias gradientinėje analizėje. Tai rodo, kad modelis jautriai vertino alkūnės lenkimo ar tiesimo amplitudę. Kadangi visi trys analizuoti pratimai reikalauja kontroliuojamos viršutinių galūnių padėties, alkūnės kampo kontrolė tampa reikšmingu judesio taisyklingumo indikatoriumi.

Netinkamas alkūnės kampas gali reikšti nepakankamą judesio amplitudę, neteisingą rankos padėtį arba kompensacinį atlikimą.

Kiti konsensuso grafike pateikti požymiai gali būti grupuojami į kelias bendras biomechanines kategorijas. Pirmoji kategorija apima sąnarių kampų kontrolę, kurią papildomai atspindi dešinėsios alkūnės kampo maksimali reikšmė ir kiti kampiniai rodikliai. Antroji kategorija susijusi su simetrija, kuri leidžia įvertinti bendrą kūno ir rankų pusiausvyrą. Trečioji kategorija apima riešo padėties kintamumo ir judesio amplitudės požymius, rodančius trajektorijos stabilumą ir nukrypimus nuo taisyklingo judesio. Galiausiai temporaliniai požymiai, tokie kaip rankos judesio smailių skaičius, atspindi judesio ritmiškumą ir ciklo struktūrą.

Toks požymių pasiskirstymas rodo, kad modelis pratimų taisyklingumą vertina kompleksiskai. Jis nesiremia vienu izoliuotu parametru, bet jungia judesio sklandumo, sąnarių kampų kontrolės, simetrijos, trajektorijos stabilumo ir ritmiškumo informaciją. Šie požymiai gerai atitinka klinikinį judesio kokybės vertinimo principą: taisyklingai atliekami reabilitaciniai pratimai pasižymi aiškesne amplitude, stabilesne trajektorija, geresne kūno segmentų kontrole ir nuoseklesniu judesio atlikimu.

Svarbu pabrėžti, kad universalūs požymiai veikia kaip modelio sprendimų karkasas – bazinė struktūra, kuria modelis remiasi vertindamas bet kurį iš trijų pratimų. Šie požymiai leidžia modeliui generalizuoti teisingumo vertinimo taisykles skirtingų tipų judesiams, o jų pasikartojimas skirtinguose XAI metoduose rodo, kad modelio mokymasis buvo nuoseklus ir biomechaniskai logiškas. Tolesniuose poskyriuose bus nagrinėjama, kaip šie universalūs požymiai derinami su pratimams specifiniais rodikliais, kurie leidžia modeliui prisitaikyti prie kiekvieno pratimo biomechanikos ir vertinti taisyklingumą tiksliau.

### 3.3.5. Požymių svarbos analizė pagal atskirus pratimus

Nors universalieji požymiai, aptarti ankstesniame poskyryje, sudaro bendrą modelio sprendimų karkasą, XAI analizė parodė, kad kiekvienas pratimas turi ir savitą biomechaninį požymių rinkinį, kuris daro reikšmingą įtaką modelio gebėjimui atpažinti taisyklingą ir netaisyklingą atlikimą. Tai logiška, nes skirtingi pratimai aktyvuoja skirtingas judesio plokštumas, skirtingas kūno dalis ir turi unikalius biomechaninius kriterijus, apibrėžiančius jų taisyklingumą.

Tyrimo metu nustatyta, kad modelis ne tik remiasi bendraisiais judesio kokybės principais (tokiais kaip tolygumas ar simetrija), bet ir išmoksta po 3–5 kiekvienam pratimui būdingus požymius, kurių svarba yra daugiau nei dvigubai didesnė nei vidutinė. Tai rodo, kad modelis geba efektyviai derinti generalizaciją su specializacija, analogiškai kaip tai daro žmogaus ekspertas vertindamas judesių kokybę.

Lentelėje (3.5 lentelė.) pateikti rezultatai atskleidžia aiškią priklausomybę tarp pratimo biomechaninės struktūros ir modelio naudojamų požymių tipų. Paprastesniuose, linijinio pobūdžio judesiuose dominuoja trajektorijos stabilumo rodikliai, kurie leidžia labai tiksliai identifikuoti nukrypimus nuo taisyklingo atlikimo. Tokie pratimai pasižymi aiškia judesio kryptimi ir mažesniu variabilumu, todėl modelis geba pasiekti itin aukštą tikslumą.

3.5 lentelė. Konkrečių pratimų biomechaninių požymių svarbos palyginimas

Pratimas	Požymis	Santykinė svarba (kartai virš vidurkio)	Biomechaninė reikšmė
----------	---------	---	----------------------

Ex1 (rankos kėlimas į šoną)	Kairiosios alkūnės kampas (maks.)	3,56×	Maksimalus alkūnės lenkimas judesio viršūnėje
	(bendras modelio tikslumas)	96,3 %	Aukštas tikslumas rodo aiškiai apibrėžtą judesio struktūrą
Ex2 („V–W“ rankų judesys)	Kairiojo riešo Y std. nuokrypis	2,84×	Vertikali riešo judesio variacija
	Kairiosios alkūnės kampas (maks.)	2,62×	Alkūnės lenkimo amplitudė „V–W“ figūroje
	(bendras modelio tikslumas)	80,7 %	Vidutinio sudėtingumo koordinacinis judesys
Ex3 (atsispaudimai nuo stalo)	Kairiosios alkūnės kampas (maks.)	3,20×	Kritinis kėlimo fazės alkūnės kampas
	Y simetrijos santykis	2,70×	Kūno simetrija vertikaliuoje plokštumoje
	(bendras modelio tikslumas)	81,3 %	Didelė priklausomybė nuo simetrijos ir laikysenos

Tuo tarpu judesiuose, kuriuose reikalinga koordinacija tarp kūno segmentų, išryškėja simetrijos ir judesio amplitudės požymių svarba. Šie parametrai atspindi ne tik galutinę judesio padėtį, bet ir viso judesio atlikimo kokybę, įskaitant abiejų kūno pusių suderinamumą. Tokiuose pratimuose modelio tikslumas išlieka aukštas, tačiau mažesnis nei paprastesnių judesių atveju, nes padidėja galimų variacijų skaičius.

Sudėtingesniuose judesiuose, tokiuose kaip „V–W“ rankų judesys ir atsispaudimai nuo stalo, didesnę reikšmę įgyja kelių požymių grupių derinys: sąnarių kampų kontrolė, simetrija, riešo padėties kintamumas ir judesio sklandumas. Šiuose pratimuose netaisyklingas atlikimas dažnai pasireiškia ne vien galutinės padėties paklaida, bet ir judesio eigos nestabilumu, nevienodu tempu ar kompensaciniais kūno segmentų judesiais. Dėl šios priežasties Ex2 ir Ex3 pratimai pasižymėjo mažesniu modelio tikslumu nei aiškesnės trajektorijos Ex1 pratimas.

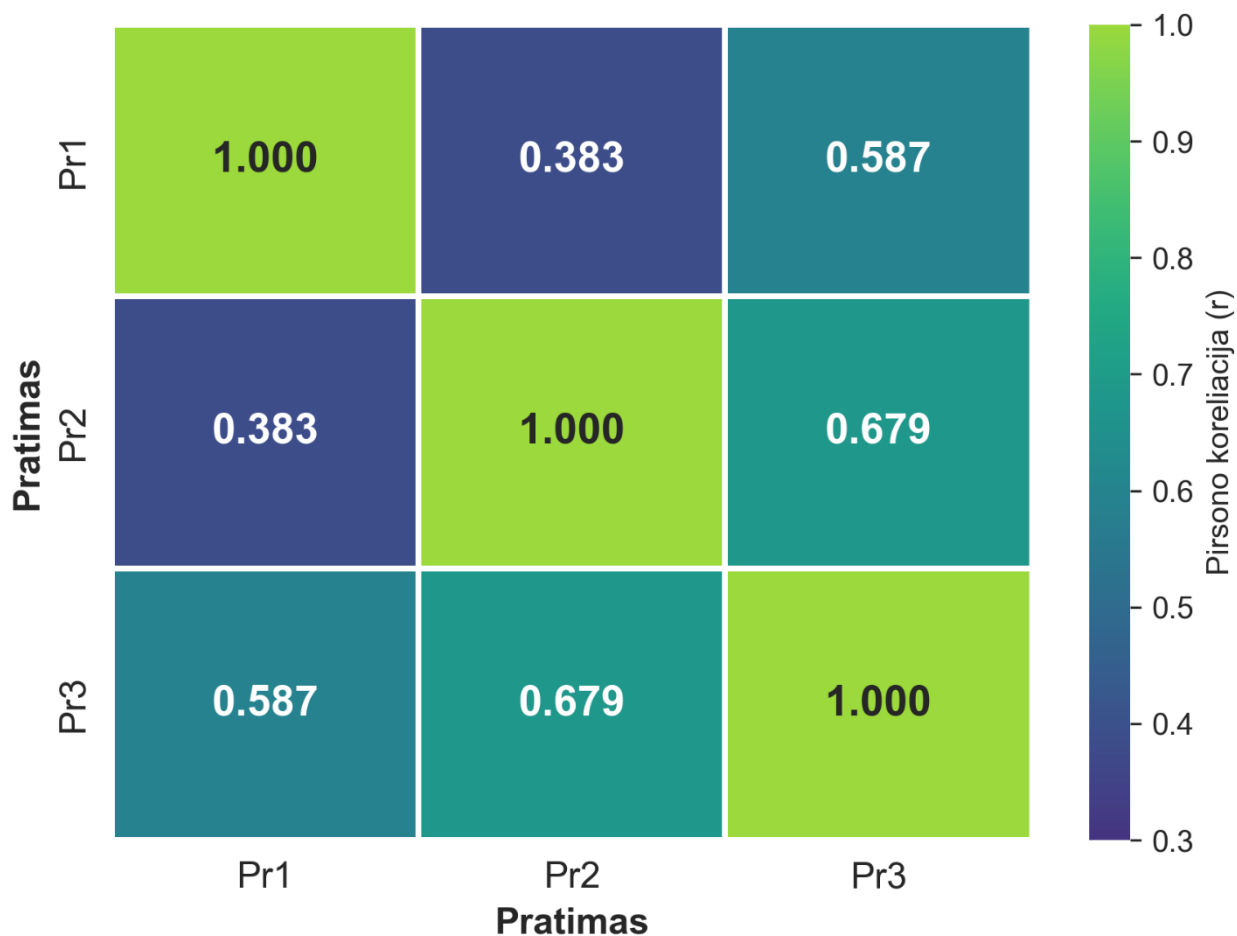
Apibendrinant galima teigti, kad modelio sprendimų logika yra glaudžiai susijusi su kiekvieno pratimo biomechanika. Skirtingiems pratimams svarbūs skirtingi požymių tipai – nuo statinių padėties rodiklių iki dinaminių judesio charakteristikų. Tai patvirtina, kad efektyvi automatizuota reabilitacijos pratimų analizė turi būti grindžiama ne tik bendraisiais judesio kokybės kriterijais, bet ir pratimo-specifiniais biomechaniniais modeliais.

### 3.3.6. Modelio generalizacijos ir specializacijos balansas

Vienas iš svarbiausių klausimų, nagrinėjamų vertinant pratimų atlikimo teisingumo modelį, yra tai, kiek modelis remiasi bendro pobūdžio taisyklėmis, taikomomis visiems pratimams, ir kiek geba prisitaikyti prie kiekvieno pratimo biomechaninės specifikos. Šis balansas yra esminis siekiant tinkamai modeliuoti žmogaus judesį: pernelyg generalizuojantis modelis ignoruotų specifinius judesio komponentus, o pernelyg specializuotas modelis nesugebėtų perkelti žinių tarp pratimų ir būtų mažiau stabilus realiose sąlygose.

Atlikta XAI analizė atskleidė, kad modelis pasižymi daliniu generalizacijos ir specializacijos santykiu. Koreliacijos tarp pratimų požymių svarbos profilių parodė vidutinio stiprumo ryšį – vidutinis koreliacijos koeficientas siekė  $r = 0,550$ . Ši reikšmė rodo, kad modelis naudoja tam tikrus

bendrus biomechaninius principus, tačiau kartu išlaiko pakankamai aiškius pratimams būdingus požymių svarbos skirtumus. Kitaip tariant, modelis geba perkelti dalį judesio kokybės vertinimo logikos tarp pratimų, tačiau kiekvieno pratimo taisyklingumą vertina atsižvelgdamas į jo specifinę biomechaninę struktūrą.



3.11 pav. Pratimų požymių koreliacijų matrica

Toks balansas ypač matomas analizuojant atskirų pratimų koreliacijų matricą (3.11 pav.). Didžiausią tarpusavio požymių svarbos panašumą demonstravo Ex2 ir Ex3 pora – jų koreliacija siekė  $r = 0,679$ . Tai galima sieti su tuo, kad tiek „V–W“ rankų judesyje, tiek atsispaudimuose nuo stalo svarbūs alkūnių kampų pokyčiai, abiejų rankų koordinacija ir viršutinės kūno dalies kontrolė. Vidutinė koreliacija nustatyta tarp Ex1 ir Ex3 ( $r = 0,587$ ), nes šie pratimai turi bendrą viršutinės galūnės kontrolės požymių, tačiau skiriasi judesio pobūdžiu ir apkrovos paskirstymu. Mažiausią koreliaciją parodė Ex1 ir Ex2 pora –  $r = 0,383$ , kas rodo, kad rankos kėlimas į šoną ir „V–W“ rankų judesys turi labiausiai skirtingus biomechaninius požymių svarbos profilius.

Generalizacijos ir specializacijos balansas aiškiai atsiskleidė analizuojant tiek universalius, tiek konkreitiems pratimams būdingus biomechaninius požymius. Tarp universalių požymių svarbiausia buvo kairiosios alkūnės kampo maksimali reikšmė, kuri pateko į svarbiausių požymių sąrašus visuose trijuose pratimuose. Taip pat reikšmingi buvo dešiniojo riešo judesio tolygumo įvertis, vertikalsios simetrijos santykis ir kairiojo riešo vertikalsios padėties standartinis nuokrypis. Šie požymiai veikė

kaip bendras modelio sprendimų pagrindas, leidžiantis vertinti judesio stabilumą, kontrolę, koordinaciją ir sąnarių padėties tikslumą nepriklausomai nuo konkretaus pratimo.

Vis dėlto vien universalių požymių nepakako tiksliam pratimų atlikimo vertinimui, todėl modelis papildomai išmoko ir pratimams specifinius biomechaninius dėsniumus. Ex1 pratime, kuriame atliekamas rankos kėlimas į šoną, ypač svarbūs buvo dešiniojo riešo judesio tolygumo įvertis, dešniosios rankos judesio viršūnių skaičius ir dešiniojo riešo X koordinatės diapazonas. Šie požymiai atspindi rankos kėlimo trajektorijos sklandumą, judesio ciklo aiškumą ir šoninio pakėlimo amplitudę.

Ex2 pratime, kuriame atliekamas „V–W“ rankų judesys, didžiausią reikšmę įgijo kairiojo riešo Y koordinatės standartinis nuokrypis, kairiosios alkūnės kampo maksimali reikšmė, dešniosios alkūnės kampo diapazonas ir dešniosios alkūnės X koordinatės diapazonas. Šie požymiai atspindi rankų aukščio kontrolę, alkūnių lenkimo amplitudę ir šoninio alkūnių judėjimo stabilumą, kurie yra svarbūs sklandžiam perėjimui tarp „V“ ir „W“ padėčių.

Ex3 pratime, t. y. atsispaudimuose nuo stalo, svarbiausi buvo kairiosios alkūnės kampo maksimali reikšmė, vertikaliosios simetrijos santykis, kairiojo riešo Y koordinatės standartinis nuokrypis, horizontaliosios simetrijos santykis ir dešiniojo riešo judesio tolygumo įvertis. Šie požymiai rodo, kad modelis šio pratimo taisyklumą siejo su alkūnės lenkimo kontrole, kūno simetrija, rankų atramos stabilumu ir sklandžiu judesio atlikimu.

Šios specializuotos savybės užtikrina, kad modelis gali diferencijuoti tarp biomechanškai skirtingų judesių ir suprasti, kokie rodikliai yra svarbūs tik tam tikrame pratimo kontekste. Tai ypač svarbu pratimų atlikimo teisingumo vertinime, nes tas pats požymis skirtinguose pratimuose gali turėti nevienodą reikšmę: vienu atveju jis gali rodyti taisyklingą judesio amplitudę, kitu – kompensacinį judesį arba trajektorijos nestabilumą.

Galiausiai, toks derinys tarp generalizacijos ir specializacijos rodo subalansuotą ir biomechanškai prasmingą modelio mokymosi struktūrą. Modelis naudojami bendromis taisyklingo judėjimo savybėmis, tokiomis kaip sąnarių kampų kontrolė, judesio tolygumas, simetrija ir trajektorijos stabilumas, tačiau kartu pritaiko sprendimą konkrečiam pratimui, atpažindamas tik tam judesiui būdingus požymius. Toks veikimo principas atitinka ir klinikinį požiūrį: terapeuto vertinimas taip pat remiasi tiek universaliais judesio kokybės kriterijais, tiek konkretaus pratimo biomechaniniais reikalavimais.

Šiame tyrime užfiksuota pusiausvyra rodo, kad modelio architektūros parinkimas buvo tinkamas, o požymių rinkinys – pakankamai informatyvus, kad būtų galima generuoti patikimą ir interpretuojamą sprendimą skirtingų pratimų kontekste. Kitaip tariant, modelis išmoko taisykles, kurios yra ir biomechanškai prasmingos, ir pakankamai universalios, ir pakankamai specializuotos, kad galėtų spręsti pratimų atlikimo teisingumo klasifikavimo uždavinį.

### **3.3.7. XAI reikšmė rezultatų patikimumui ir klinicinei interpretacijai**

Paaškinamojo dirbtinio intelekto analizė šiame tyrime atliko esminį vaidmenį vertinant ne tik modelio tikslumą, bet ir jo klinikinį patikimumą. Klasifikacijos metrikos – tokios kaip tikslumas, preciziškumas (angl. precision), jautrumas (angl. recall) ar F1 matas (angl. F1-Score) – leidžia įvertinti, kaip gerai modelis atlieka uždavinį statistiniu požiūriu, tačiau šios metrikos pačios savaime nesuteikia informacijos apie tai, ar modelio sprendimai yra biomechanškai pagrįsti, ar jis remiasi

taisyklingomis judesio savybėmis, ar galbūt modelio veikimas yra atsitiktinis arba nulemtas duomenų artefaktų. *XAI* metodai suteikė galimybę patikrinti, ar modelis priima sprendimus taip, kaip tikėtasi iš žmogaus eksperto perspektyvos.

Vienas iš svarbiausių atradimų buvo tas, kad visi trys taikyti *XAI* metodai – gradientai, permutacijos ir integruoti gradientai – nuosekliai identifikavo biomechaniskai artimus kertinius požymius, tiesiogiai susijusius su pratimų atlikimo kokybe. Tarp svarbiausių rodiklių išryškėjo alkūnės kampų kontrolė, riešo judesio tolygumas, simetrijos požymiai ir trajektorijos stabilumo parametrai. Toks skirtingų metodų rezultatų sutapimas yra stiprus indikatorius, kad modelis mokosi iš tikrų judesio savybių, o ne iš nereikšmingų statistinių koreliacijų. Šis atradimas yra svarbus praktiniam taikymui, nes leidžia teigti, jog sistema turi potencialo veikti klinikinėje aplinkoje, kur sprendimų skaidrumas ir pagrįstumas yra būtini reikalavimai.

*XAI* analizė taip pat padėjo identifikuoti galimas modelio spragų sritis. Tam tikri pratimų specifiniai požymiai yra jautresni interpretacijai ir rodo, kad sudėtingesnių judesių, tokių kaip „V–W“ rankų judesys ar atsispaudimai nuo stalo, taisyklingumo vertinimas reikalauja išsamesnės judesio eigos analizės. Toks rezultatas išryškina potencialias modelio tobulinimo kryptis – pavyzdžiui, papildyti požymių rinkinį detalesniais laikiniais parametrais arba naudoti laiko eilučių analizės metodus, kurie padėtų tiksliau įvertinti judesio fazių nuoseklumą, trajektorijos stabilumą ir koordinaciją. Ši analizė taip pat leidžia aiškiai suprasti, kur modelis veikia geriausiai ir kur reikalingas papildomas duomenų praturtinimas ar architektūros adaptavimas.

Dar viena svarbi *XAI* metodo taikymo vertė yra jo potencialas būti naudojamam kaip diagnostinė ir edukacinė priemonė. Kadangi *XAI* gali nurodyti, kurie požymiai labiausiai prisidėjo prie priskyrimo „taisyklinga“ arba „netaisyklinga“, tokia informacija gali būti integruota į reabilitacijos sistemas, leidžiančias pacientui matyti ne tik galutinį įvertinimą, bet ir kokiomis konkrečiomis judesio savybėmis jis turėtų atidžiau rūpintis. Pavyzdžiui, sistema galėtų pateikti naudotojui aiškinimą: „judesys atliktas netolygiai dėl didelių riešo greičio variacijų“ arba „rankos šoninė padėtis buvo nestabili“, kas padėtų pacientui suprasti savo klaidas ir jas koreguoti. Tokios grįžtamojo ryšio formos gerina terapijos efektyvumą ir skatina paciento motyvaciją aktyviai dalyvauti reabilitacijos procese.

Galiausiai, *XAI* analizė padėjo įvertinti modelio sprendimų patikimumą platesniame klinikinės praktikos kontekste. Kadangi dirbtinio intelekto sprendimai sveikatos priežiūros srityje turi atitikti aukštus skaidrumo ir atsekamumo standartus, gebėjimas matyti, kaip modelis priėmė konkretų sprendimą, yra esminis veiksnys kuriant pasitikėjimą tokia sistema. Šio tyrimo rezultatai rodo, kad modelio sprendimų logika yra susijusi su pripažintais biomechaniniais principais, o tai leidžia modelį laikyti ne „juodąja dėže“, bet aiškinama ir analizuojama sistema, kurios sprendimus galima pagrįsti tiek moksliniais, tiek klinikiniais argumentais.

Apibendrinant galima teigti, kad *XAI* suteikia fundamentalią informaciją, leidžiančią reabilitacijos sistemoms pereiti iš eksperimentinio etapo į realų klinikinį taikymą. Aiškios, biomechaniskai pagrįstos sprendimų interpretacijos kuria pasitikėjimą, padeda identifikuoti tobulinimo kryptis, o kartu leidžia sistemos naudotojams – tiek terapeutams, tiek pacientams – geriau suprasti judesio kokybės įvertinimus ir priimti labiau informuotus sprendimus.

### 3.3.8. Apibendrinimas

Šiame skyriuje atlikta paaiškinamojo dirbtinio intelekto analizė leido išsamiai įvertinti, kaip modelis priima sprendimus pratimų atlikimo teisingumo klasifikavimo uždavinyje. Trijų skirtingų *XAI* metodų – gradientinės svarbos analizės, permutacijų svarbos ir integruotų gradientų – taikymas parodė, kad modelio sprendimai yra pagrįsti biomechanškai prasmingais požymiais, susijusiais su sąnarių kampų kontrole, judesio tolygumu, simetrija ir trajektorijos stabilumu. Skirtingų metodų rezultatų sutapimas rodo, kad modelis nesiremia atsitiktiniais duomenų artefaktais, o išmoksta realius judesio kokybės dėsningumus.

*XAI* analizė parodė, kad modelio sprendimų struktūrą sudaro du pagrindiniai komponentai: universalūs ir pratimams specifiniai požymiai. Universalūs požymiai, tokie kaip kairiosios alkūnės kampo maksimali reikšmė, dešiniojo riešo judesio tolygumo įvertis, simetrijos rodikliai ir sąnarių padėties stabilumo parametrai, buvo svarbūs keliuose analizės lygmenyse. Šie požymiai atspindi esminius taisyklingo motorinio judėjimo bruožus – kontroliuojamą sąnarių padėtį, sklandų judesio atlikimą, kūno pusiausvyrą ir stabilią trajektoriją. Dėl to galima teigti, kad modelio sprendimai yra biomechanškai interpretuojami ir atitinka realaus žmogaus judėjimo vertinimo principus.

Tuo pačiu *XAI* metodai atskleidė, kad modelis geba adaptuoti savo sprendimų logiką skirtingiems pratimams, identifikuodamas pratimams būdingus svarbiausius požymius. Ex1 pratime, kuriame atliekamas rankos kėlimas į šoną, modelis labiausiai akcentavo rankos kėlimo trajektorijos sklandumą, judesio ciklo aiškumą ir šoninio pakėlimo amplitudę. Ex2 pratime, t. y. „V–W“ rankų judesyje, svarbiausi buvo riešo vertikalios padėties kaita, alkūnių kampų kontrolė ir šoninio alkūnių judėjimo stabilumas. Ex3 pratime, atliekant atsispaudimus nuo stalo, modelio sprendimams didžiausią reikšmę turėjo alkūnės lenkimo kontrolė, kūno simetrija, rankų atramos stabilumas ir judesio tolygumas. Tai rodo, kad modelis geba atpažinti skirtingų pratimų biomechaninius reikalavimus ir pagal juos pritaikyti sprendimo logiką.

Svarbią įžvalgą suteikė ir generalizacijos bei specializacijos balanso analizė. Vidutinio stiprumo pratimų tarpusavio koreliacija, siekusi  $r = 0,550$ , parodė, kad modelis nei pernelyg generalizuoja, nei pernelyg prisitaiko prie vieno pratimo. Jis naudoja bendrus judesio kokybės principus, tačiau kartu išlaiko gebėjimą atpažinti kiekvienam pratimui būdingus biomechaninius požymius. Toks veikimo principas yra tinkamas reabilitacijos uždaviniams, nes taisyklingumo vertinimas turi remtis tiek universaliais judesio kokybės kriterijais, tiek konkretais pratimo specifika.

Galiausiai, *XAI* analizė parodė, kad modelio sprendimų logika yra ne tik skaidri, bet ir kliniškai prasminga. Gebėjimas identifikuoti svarbiausius požymius, paaiškinti sprendimų priežastis ir suprasti galimų klaidų kilmę sudaro prielaidas praktiniam tokių metodų taikymui automatizuotose reabilitacijos sistemose. Tokia analizė gali padėti ne tik vertinti pratimų atlikimo kokybę, bet ir formuoti aiškesnį grįžtamąjį ryšį pacientui ar specialistui.

Apibendrinant galima teigti, kad *XAI* analizė šiame tyrime ne tik papildė modelio tikslumo vertinimą, bet ir suteikė pagrindą interpretuoti jo sprendimus biomechaniniu požiūriu. Tai leidžia modelio rezultatus vertinti ne kaip izoliuotas statistines prognozes, o kaip paaiškinamus ir kliniškai prasmingus judesio kokybės vertinimus.

## Išvados

1. Atlikta mokslinės literatūros analizė parodė, kad dirbtinio intelekto ir mašininio mokymosi metodai gali būti taikomi reabilitacijos judesių kokybės analizei, vertinant tokius biomechaninius požymius kaip sąnarių kampai, judesių amplitudė, simetrija ir judesio dinamika.
2. Parengta ir segmentuota viršutinių galūnių reabilitacinių pratimų vaizdo duomenų aibė sudarė sąlygas išgauti nuoseklią skeletinę judesių informaciją bei atlikti tolimesnę biomechaninę analizę. Gauti rezultatai parodė, kad santykinai nedidelės apimties duomenų rinkinys, sudarytas iš 47 vaizdo įrašų ir 493 segmentuotų pratimų kartojimų, yra pakankamas žmogaus judesių analizei bei kompiuterinio intelekto modelių taikymui reabilitacinių pratimų vertinimo uždaviniuose.
3. Suformuotas 117 biomechaninių požymių rinkinys, apimantis erdvinius, kampinius, dinامينius, simetrijos ir judesio kokybės parametrus, leidžia apibūdinti viršutinių galūnių judesių dinamiką, stabilumą bei judesių tarpusavio koordinaciją. Sudarytas požymių rinkinys suteikė galimybę struktūrizuoti analizuoti reabilitacinių pratimų atlikimo biomechanines savybes ir pritaikyti jas tolimesniems klasifikavimo bei vertinimo uždaviniams.
4. Mašininio mokymosi modelių vertinimas parodė, kad 117 biomechaninių požymių rinkinys yra tinkamas viršutinių galūnių reabilitacijos pratimų tipams klasifikuoti. Nenaudojant pratimo tipo kodavimo įvestyje, galutinis modelis testavimo aibėje pasiekė 100 % tikslumą ir teisingai suklasifikavo visus 74 pavyzdžius. Tai patvirtina, kad Ex1, Ex2 ir Ex3 pratimai pasižymi aiškiai atskiriamais biomechaniniais judesio požymiais.
5. Pratimų atlikimo taisyklingumo klasifikavimo uždavinys pasirodė sudėtingesnis nei pratimų tipų atpažinimas, tačiau neuroninių tinklų modeliai užtikrino pakankamai aukštus vertinimo rodiklius. Galutinis modelis, naudojęs 117 biomechaninių požymių ir 3 pratimo tipo kodavimo požymius, testavimo aibėje pasiekė 86,49 % tikslumą, 84,21 % preciziškumą, 88,89 % jautrumą ir 86,49 % F1 rodiklį. Detalesnė analizė parodė, kad modelio veikimo kokybė priklauso nuo konkretaus pratimo biomechaninio sudėtingumo: Ex1 pratime tikslumas siekė 96,30 %, o koordinaciškai sudėtingesniuose Ex2 ir Ex3 pratimuose – atitinkamai 80,65 % ir 81,25 %. Tai rodo, kad didesnis judesio koordinacijos ir trajektorijos kintamumas apsunkina taisyklingo ir netaisyklingo atlikimo atskyrimą.
6. Pritaikyti paaiškinamojo dirbtinio intelekto metodai parodė, kad modelio sprendimams didžiausią įtaką daro biomechanškai pagrįsti požymiai, susiję su alkūnės kampų kontrole, riešo judesio tolygumu, simetrija ir trajektorijos stabilumu. Svarbiausiais rodikliais nustatyti kairiosios alkūnės kampo maksimali reikšmė, dešiniojo riešo judesio tolygumo įvertis ir dešniosios alkūnės kampo maksimali reikšmė. Vidutinė koreliacija tarp pratimų požymių svarbos profilių siekė  $r = 0,550$ , todėl galima teigti, kad modelis suderina bendrus judesio kokybės vertinimo principus su konkrečiam pratimui būdingais biomechaniniais požymiais.

## **Dirbtinio intelekto įrankių naudojimas**

Rengiant šį baigiamąjį projektą buvo naudojami generatyvinio dirbtinio intelekto įrankiai pagalbinei darbo rengimo veiklai. „ChatGPT 5.5“ buvo naudojamas lietuviško teksto gramatikos ir sklandumo redagavimui. Programinio kodo korekcijoms, klaidų paieškai ir techninių sprendimų tikslinimui buvo naudojami „Claude Sonnet 4.5“ ir „Claude Sonnet 4.6“ modeliai.

Generatyvinio dirbtinio intelekto įrankiai šiame darbe buvo naudojami tik kaip pagalbinės priemonės, skirtos teksto kokybei gerinti ir programinio kodo taisymui. Jie nebuvo naudojami pirminiams tyrimo duomenims kurti, keisti ar falsifikuoti, taip pat nebuvo naudojami eksperimentiniams rezultatams, skaičiavimams, grafikams ar literatūros šaltiniams generuoti. Visi tyrime pateikti duomenų apdorojimo žingsniai, modelių mokymo rezultatai, klasifikavimo metrikos, *XAI* analizės rezultatai ir jų interpretacijos buvo parengti autoriaus, o ne sugeneruoti generatyvinio dirbtinio intelekto priemonėmis.

## Literatūros sąrašas

1. MU, Pengyu, DAI, Mingyu, MA, Xuenan. *Application of Artificial Intelligence in Rehabilitation Assessment*. Journal of Physics: Conference Series, 2021, vol. 1802, no. 3, 032057. Prieiga per: <https://doi.org/10.1088/1742-6596/1802/3/032057>
2. BINI, Stefano A. *Artificial Intelligence, Machine Learning, Deep Learning, and Cognitive Computing: What Do These Terms Mean and How Will They Impact Health Care?* The Journal of Arthroplasty, 2018. Prieiga per: <https://doi.org/10.1016/j.arth.2018.02.067>
3. WORLD HEALTH ORGANIZATION. *Rehabilitation* [interaktyvus]. Geneva: World Health Organization, 2023 [žiūrėta 2026-05-19]. Prieiga per: <https://www.who.int/news-room/fact-sheets/detail/rehabilitation>
4. SUMNER, James et al. *Artificial intelligence in physical rehabilitation: A systematic review*. Artificial Intelligence in Medicine, 2023, vol. 146, 102693. Prieiga per: <https://doi.org/10.1016/j.artmed.2023.102693>
5. HWANG, Donghwan, SHIN, Joon-Ho, KWON, Suncheol. *Kinematic Assessment to Measure Change in Impairment during Active and Active-Assisted Type of Robotic Rehabilitation for Patients with Stroke*. Sensors, 2021, vol. 21, no. 21, 7055. Prieiga per: <https://doi.org/10.3390/s21217055>
6. AVOLA, Danilo, CINQUE, Luigi, FORESTI, Gian Luca, MARINI, Marco Raoul. *An interactive and low-cost full body rehabilitation framework based on 3D immersive serious games*. Journal of Biomedical Informatics, 2019, vol. 89, p. 81–100. Prieiga per: <https://doi.org/10.1016/j.jbi.2018.11.012>
7. JACK, K., MCLEAN, S. M., MOFFETT, J. K., GARDINER, E. *Barriers to treatment adherence in physiotherapy outpatient clinics: A systematic review*. Manual Therapy, 2010, vol. 15, no. 3, p. 220–228. Prieiga per: <https://doi.org/10.1016/j.math.2009.12.004>
8. BEN-ISRAEL, D. et al. *The impact of machine learning on patient care: A systematic review*. Artificial Intelligence in Medicine, 2020, vol. 103, 101785. Prieiga per: <https://doi.org/10.1016/j.artmed.2019.101785>
9. YEH, Shih-Ching et al. *Machine learning-based assessment tool for imbalance and vestibular dysfunction with virtual reality rehabilitation system*. Computer Methods and Programs in Biomedicine, 2014, vol. 116, no. 3, p. 311–318. Prieiga per: <https://doi.org/10.1016/j.cmpb.2014.04.014>
10. LEE, Seong-Ran et al. *An Evidence-Based Intelligent Method for Upper-Limb Motor Assessment via a VR Training System on Stroke Rehabilitation*. IEEE Access, 2021. Prieiga per: <https://doi.org/10.1109/ACCESS.2021.3075778>
11. ABDALLAH, Ismail Ben, BOUTERAA, Yassine, ALOTAIBI, Ahmed. *AI-driven hybrid rehabilitation: synergizing robotics and electrical stimulation for upper-limb recovery after stroke*. Frontiers in Bioengineering and Biotechnology, 2025, vol. 13, article 1619247. Prieiga per: <https://doi.org/10.3389/fbioe.2025.1619247>
12. AUNG, Yuri Y. M., WONG, David C. S., TING, Daniel S. W. *The promise of artificial intelligence: a review of the opportunities and challenges of artificial intelligence in healthcare*.

- British Medical Bulletin, 2021, vol. 139, no. 1, p. 4–15. Prieiga per: <https://doi.org/10.1093/bmb/ldab016>
13. TOPOL, Eric J. *High-performance medicine: the convergence of human and artificial intelligence*. Nature Medicine, 2019, vol. 25, p. 44–56. Prieiga per: <https://doi.org/10.1038/s41591-018-0300-7>
  14. LAM, Wing Tung, TANG, Yuk Ming, FONG, Kenneth N. K. *A systematic review of the applications of markerless motion capture technology for clinical measurement in rehabilitation*. Journal of NeuroEngineering and Rehabilitation, 2023, vol. 20, article 57. Prieiga per: <https://doi.org/10.1186/s12984-023-01186-9>
  15. PECORARO, Pasquale Maria, MARSILI, Luca, ESPAY, Alberto J. *Computer Vision Technologies in Movement Disorders: A Systematic Review*. Movement Disorders Clinical Practice, 2025, vol. 12, no. 9, p. 1229–1243. Prieiga per: <https://doi.org/10.1002/mdc3.70123>
  16. LIU, Jiaji, MU, Xiaofang, LIU, Zhenyu, LI, Hao. Human skeleton behavior recognition model based on multi-object pose estimation with spatiotemporal semantics. *Machine Vision and Applications*, 2023, vol. 34, article 44. Prieiga per: <https://doi.org/10.1007/s00138-023-01396-0>
  17. LUGARESI, Camillo et al. *MediaPipe: A Framework for Building Perception Pipelines*. arXiv, 2019. Prieiga per: <https://doi.org/10.48550/arXiv.1906.08172>
  18. HELLSTEN, Thomas, KARLSSON, Jonny, SHAMSUZZAMAN, Muhammed, PULKKIS, Göran. *The Potential of Computer Vision-Based Marker-Less Human Motion Analysis for Rehabilitation*. Rehabilitation Process and Outcome, 2021, vol. 10. Prieiga per: <https://doi.org/10.1177/11795727211022330>
  19. TSILOMITROU, Ourania, GKOUNTAS, Konstantinos, EVANGELIOU, Nikolaos, DERMATAS, Evangelos. *Wireless Motion Capture System for Upper Limb Rehabilitation*. Applied System Innovation, 2021, vol. 4, no. 1, 14. Prieiga per: <https://doi.org/10.3390/asi4010014>
  20. KUKLA, Mateusz, MALIGA, Wojciech. *Symmetry Analysis of Manual Wheelchair Propulsion Using Motion Capture Techniques*. Symmetry, 2022, vol. 14, no. 6, 1164. Prieiga per: <https://doi.org/10.3390/sym14061164>
  21. LIAO, Y., VAKANSKI, A., XIAN, M. *A Deep Learning Framework for Assessing Physical Rehabilitation Exercises*. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2020, vol. 28, no. 2, p. 468–477. Prieiga per: <https://doi.org/10.1109/TNSRE.2020.2966249>
  22. MENNELLA, Ciro, MANISCALCO, Umberto, DE PIETRO, Giuseppe, ESPOSITO, Massimo. *A deep learning system to monitor and assess rehabilitation exercises in home-based remote and unsupervised conditions*. Computers in Biology and Medicine, 2023, vol. 163, 107485. Prieiga per: <https://doi.org/10.1016/j.combiomed.2023.107485>
  23. CHEN, Jiayue, CHENG, Zhongjiang, CAI, Yutong, ZHANG, Shisheng, ZHU, Chi, ZHANG, Yang. *Robot-Assisted Mirror Rehabilitation for Post-Stroke Upper Limbs: A Personalized Control Strategy*. Sensors, 2025, vol. 25, no. 18, 5659. Prieiga per: <https://doi.org/10.3390/s25185659>
  24. BAJWA, Junaid et al. *Artificial intelligence in healthcare: transforming the practice of medicine*. Future Healthcare Journal, 2021, vol. 8, no. 2, e188–e194. Prieiga per: <https://doi.org/10.7861/fhj.2021-0095>

25. HOLZINGER, Andreas, BIEMANN, Chris, PATTICHIS, Constantinos S., KELL, Douglas B. *What do we need to build explainable AI systems for the medical domain?* arXiv, 2017. Prieiga per: <https://doi.org/10.48550/arXiv.1712.09923>
26. TONEKABONI, Sana, JOSHI, Shalmali, MCCRADDEN, Melissa D., GOLDENBERG, Anna. *What Clinicians Want: Contextualizing Explainable Machine Learning for Clinical End Use.* arXiv, 2019. Prieiga per: <https://doi.org/10.48550/arXiv.1905.05134>
27. VAKANSKI, Alexander, XIAN, Huan ir JANVEJA, Piyush. A Dataset of Human Body Movements for Physical Rehabilitation Exercises [interaktyvus]. Zenodo, 2024. Prieiga per: <https://doi.org/10.5281/zenodo.13305826>