

LATVIJAS UNIVERSITĀTE
DATORIKAS FAKULTĀTE

**SKEITBORDA TRIKU KLASIFIKĀCIJAS
METODES IZMANTOJOT MAŠĪNMĀCĪŠANOS
AR IMU SENSORU DATIEM**

BAKALaura DARBS

Autors: **Raimonds Rava**

Stud. apl. rr07016

Darba vadītājs: M.dat. Jānis Judvaitis

RĪGA 2020

ANOTĀCIJA

Mūsdienās arvien vairāk tiek izmantoti valkājami sensori, it īpaši sportā, tajā skaitā skeitbordā. Apvienojumā ar mašīnmācīšanos šīs ierīces spēj sniegt informāciju par sportista veiktajām darbībām, skeitbordā tas būtu par izpildītajiem trikiem. Šī darba ietvaros ir apzināti pašreizējie risinājumus skeitborda triku atpazīšanā, kā arī izstrādāts jauns risinājums, kas sevī ietver papildus sensoru izvietojumu uz sportista ķermeņa. Darbā tiek salīdzinātas dažādas mašīnmācīšanās metodes triku klasificēšanai, kā arī izpētīta papildus sensoru ietekme uz precizitāti, palielinot atpazīstamo triku skaitu.

Atslēgvārdi: valkājami sensori, IMU, skeitbords, darbību klasifikācija, mašīnmācīšanās.

ABSTRACT

Skateboarding trick classification methods using machine learning with IMU sensor data.

Nowadays wearable sensors are being used more and more, especially in sports, including skateboarding. In combination with machine learning, these devices can provide information about the activities performed by the athlete, in skateboarding it would be the performed tricks. Within the scope of this work, the current solutions for skateboard trick classification have been analyzed, as well as a novel solution has been proposed, which includes the placement of additional sensors on the athlete's body. The thesis compares different machine learning methods for trick classification, as well as investigates the effect of additional sensors on the classification precision as the number of classified tricks are increased.

Key words: wearable sensors, IMU, skateboarding, activity classification, machine learning.

Saturs

Apzīmējumu saraksts	6
Ievads	7
1. Literatūras analīze	9
1.1. IMU	9
1.2. Datu iegūšana	10
1.2.1. Datu kopa	10
1.2.2. Notikumu atpazīšana	11
1.3. Mašīnmācīšanās	11
1.3.1. Pazīmju atlasīšana	12
1.3.2. Klasifikātori	12
1.3.3. Dziļie neironu tīkli	13
2. Risinājuma apraksts	14
2.1. Datu iegūšana	14
2.1.1. Triki	14
2.1.2. Datu ievākšanas process	15
2.2. Notikuma atpazīšana	16
2.2.1. Notikumu izgriešana	16
2.2.2. Algoritmu pārbaudes apraksts	16
2.3. Pazīmju atlasīšana	16
2.4. Mašīnmācīšanās	17
3. Risinājuma Implementācija	19
3.1. Sensori	19
3.1.1. Izvēlētās IMU ierīces	19
3.1.2. Sensoru uzstādījumu	19
3.1.3. Sensoru izvietojums	20
3.2. Notikuma datu iegūšana	20
3.2.1. Notikumu loga izgriešana	20
3.2.2. Notikumu atpazīšanas algoritmi	22
3.3. Pazīmju atlasīšana	22
3.3.1. Statistikas pazīmes	22

3.3.2.	Signāla apstrāde	22
3.3.3.	Pazīmju izvēle	23
3.4.	Triku klasifikācija	23
3.4.1.	Mašīnmācīšanas klasifikātori	23
3.4.2.	Dziļo neironu tīkls	23
4.	Risinājuma rezultāti	25
4.1.	IMU sensori	25
4.2.	Datu kopa	26
4.3.	Notikuma atpazīšana	27
4.3.1.	Notikumu nobīde	28
4.3.2.	Algoritmu pārbaude	28
4.4.	Pazīmju atlasīšana	29
4.5.	Mašīnmācīšanās	30
	Nobeigums un secinājumi	35
	Pateicība	36
	Literatūras saraksts	37

APZĪMĒJUMU SARAKSTS

Skeitbords - sporta veids.

Skrituļdēlis - inventārs, kas tiek izmantots skeitbordā.

IMU - Inertial Measurement Unit. Inerces mērījumu bloks.

LSTM - Long Short Term Memory. Neironu tīkla paveids.

CLDNN - convolutional long-short-term deep neural network. Neironu tīkla paveids.

FFT - Ātrā Furjē transformācija.

Flip triks - skeitborda palēciena triks, kura laikā skrituļdēlis un/ vai sportists veic rotāciju ap kādu (vai nevienu) no savām asīm.

RBSVM - Radial-basis Support Vector Machine. Mašīnmācīšanas klasifikators.

kNN - K-Nearest Neighbor. Mašīnmācīšanas klasifikators.

PDT - Partial Decision Tree. Mašīnmācīšanas klasifikators.

RF - Random Forest. Mašīnmācīšanas klasifikators.

NB - Naive Bayes. Mašīnmācīšanas klasifikators.

LSVM - Linear Support Vector Machine. Mašīnmācīšanas klasifikators.

IEVADS

Valkājāmo ierīču izmantošanai sporta pētījumos pēdējos gados ir tendence pieaugt [1]. Skeitbords pirmo reizi kļuvis par olimpisko sporta veidu 2021. gada olimpiskajās spēlēs Japānā un tiek paredzēts, ka skeitborda popularitāte un tirgus lielums tuvāko piecu gadu laikā pieaugs [2]. Pēc autoram domām, pieaugs arī interese par Valkājāmo sensoru izmantošanu šajā sporta veidā, konkrēti veikto triku atpazīšanā un klasificēšanā.

Autors izvēlējās aplūkot skeitborda triku klasifikācijas risinājumus un metodes, kas ir balstītas uz inerces mērījumu bloka (IMU) ierīču datiem, jo tās sniedz sportistam lielāku brīvību, salīdzinājumā, piemēram, ar uz video datiem balstītām metodēm, kur nepieciešams atsevišķi novietot video kameru un trikus var veikt tikai atrodoties kadrā.

Līdz šim skeitborda triku atpazīšanas pētījumos Valkājāmie sensori tikuši izvietoti tikai uz skrituļdēļa [3] [4] [5], kas pēc autora domām, var ierobežot atpazīstamo triku skaitu un precizitāti. Tāpēc, kā galveno šī darba mērķi autors uzstāda skeitborda triku atpazīšanas risinājuma izstrādāšanu, kas sevī ietver vairāku IMU ierīču izmantošanu, kas būtu izvietotas arī uz sportista ķermeņa, lai iegūtu labāku priekšstatu par trika veikšanu. Lai šo mērķi sasniegtu darba ietvaros tika veikta datu ievākšana izmantojot IMU ierīces, datu kopas izveide, datu apstrāde un triku atpazīšana izmantojot mašīnmācīšanās klasifikātorus un neironu tīklus.

Darbā autors sniedz atbildes uz šādiem jautājumiem:

- Kādas metodes tiek izmantotas skeitborda triku atpazīšanā?
- Vai izmantojot papildus sensorus uz sportista ķermeņa, tiek uzlabota triku atpazīšanas precizitāte?
- Vai palielinoties atpazīstamo triku skaitam papildus sensori sniedz ievērojamu uzlabojumu precizitātē?

Darbā izmantotās pētniecības metodes:

- Literatūras analīze
- Prototipa izstrāde
- Datu analīze
- Iegūto rezultātu analīze

Darbs ir strukturēts četrās nodaļās. Pirmā nodaļa satur literatūras analīzi un apraksta esošos skeitborda triku atpazīšanā izmantotos risinājumus. Otrā nodaļa apraksta autora piedāvāto risinājumu. Trešā nodaļa apraksta risinājuma implementāciju un metodes, kas tika izmantotas rezultātu iegūšanai, kā arī tiek pieminētas problēmas, ar kurām autors saskārās risinājuma ieviešanā. Ceturtajā nodaļā ir apkopoti iegūtie rezultāti un veikta autora piedāvātā risinājuma salīdzināšana ar citiem risinājumiem. Katrā no šīm nodaļām tiek aplūkotas galvenās risinājuma sastāvdaļas - sensori, datu kopa, datu apstrāde un mašīnmācīšanās.

1. LITERATŪRAS ANALĪZE

Valkājамie IMU sensori sportā apvienojumā ar mašīnmācīšanos, lai atpazītu sportista kustības un sniegumu tiek izmantoti dažādos sporta veidos, tajā skaitā arī skeitbordā [6]. Šajā nodaļā autors aplūkos kādas metodes un risinājumi tiek izmantoti skeitbordā un citos sporta veidos, lai no IMU ierīču datiem veiktu darbību atpazīšanu.

1.1. IMU

IMU ierīces sevī satur akselerometra, žiroskopa un magnetometra sensorus. Skeitborda triku atpazīšanā tiek izmantots akselerometrs un žiroskops. Sīkāk izmantotās IMU ierīces sensorus autors aprakstījis kursa darbā [7].

Valkājamās IMU ierīces tiek izmantota dažādos sporta veidos, kā, piemēram, no datiem, kas iegūti uz plaukstu locītavām novietotām IMU ierīcēm, ir iespējams atpazīt sitiena veidus tenisā un golfā [8], vairākas dažādas darbības volejbolā [9], uz sporta apaviem novietotām IMU ierīcēm, agrīni atpazīt futbola spērienu [10] un citas darbības tādos sporta veidos kā, peldēšana [11], svarcelšana [12], basketbols [13] un citos. Izmantoto IMU ierīču skaits ir atkarīgs no pētāmās problēmas. Visbiežāk tiek izmantota viena IMU ierīce [6], bet ir pētījumi [14] par trampīnlēkšanu, kur tiek izmantoti līdz pat deviņiem sensoriem, kas ir novietoti uz sportista ķermeņa. Skeitborda triku atpazīšanas pētījumos tiek izmantota viena IMU ierīce, kas ir novietota skrituļdēļa apakšā [3] [4] [5]. Autoram nav zināmi pētījumi, kuros sensori būtu novietoti arī uz sportista ķermeņa. Sīkāk sensoru izvietošanu skeitbordā autors aprakstījis kursa darbā [7].

Vairākumā no skeitborda triku klasifikācijas pētījumiem, parasti tiek izmantota 200hz diskretizācijas frekvence gan akselerometram, gan žiroskopam [3] [4] (skatīt 1.1. tabulu). Tomēr ir arī veikts pētījums [5], kurā diskretizācijas frekvence bija daudz mazāka - 20hz un tika sasniegta 95% precizitāte piecu triku klasifikācijā.

1.1. tabula.

Biežāk izmantotie uzstādījumi skeitborda triku atpazīšanā izmantotajām IMU ierīcēm [7]

	Akselerometrs	Žiroskops
Diskretizācijas frekvence	200hz	200hz
Amplitūda	+/-16g	2000°/s
Izšķirtspēja	16bit	16bit

1.2. Datu iegūšana

Svarīgs posms, risinot jebkuru mašīnmācīšanās klasifikācijas problēmu, ir iegūt korektu un problēmu labi aprakstošu datu kopu.

1.2.1. Datu kopa

Mašīnmācīšanās algoritmi strādā precīzāk un spēj labāk vispārināt [15], ja tiek izmantoti vairāk dati. Sporta darbību atpazīšanas pētījumos, kuros izmanto IMU ierīces, datu kopas izmērs ļoti variē atkarībā no pētījuma un sporta veida. Tā var saturēt sākot no 150 datu paraugiem, līdz pat vairākiem simtiem tūkstošu datu paraugiem [6]. Skeitborda jomā veiktajos pētījumos, konkrēti datu kopas izmēri netiek minēti, bet [3] pētījumā tiek aprakstīts datu iegūšanas process - septiņi dalībnieki, veic sešus trikus, katru triku atkārtojot piecas reizes, tātad šajā pētījumā kopējais datu kopas izmērs ir 210 datu paraugi.

Katram sportistam, kas veic trikus ir sava maniere kā šis triks tiek izpildīts, tāpēc, lai izvairītos no mašīnmācīšanās algoritmu pārmērīgas pielāgošanās konkrētai sportista manierei, tiek piesaistīti vairāki sportisti datu ievākšanai. Dalībnieku skaits, kas piedalās sporta darbību atpazīšanas pētījumos ar IMU ierīcēm ir diapazonā no viena līdz trīsdesmit [6] dalībniekiem. Skeitborda triku klasifikācijas pētījumos, šis skaits ir diapazonā no viena [5] līdz vienpadsmit [4] dalībniekiem.

Iegūto datu sadalījums pa klasēm var atstāt iespaidu uz klasifikātoru darbības precizitāti. Jo proporcionāli lielāks datu skaits ir kādā no klasēm, jo sliktāk klasifikātori atpazīst tās klases, kurās datu ir mazāk [16]. Datu ievākšanas procesā šo problēmu var risināt nosakot noteiktu triku skaitu, kas ir jāuztaisa, katram sportistam [3] [5], bet ne vienmēr šāds risinājums ir iespējams. Palielinot triku skaitu, ir pieļaujams, ka ne visus trikus, katrs sportists būs spējīgs uztaisīt, tāpēc tiek arī veidotas un izmantotas datu kopas, kur datu sadalījums starp klasēm nav pilnībā vienlīdzīgs [4].

Lielākajā daļā veikto pētījumu, atpazīstamo triku skaits ir salīdzinoši neliels (skatīt 1.2. tabulu). Divos pētījumos pieci [17] [5], vienā seši [3] triki. Tikai vienā pētījumā klašu skaits ir lielāks - divpadsmit [4], kur vienpadsmit no tiem ir triki, bet viena klase atvēlēta trikam kurš nav veiksmīgi izpildīts, konkrēti, nav veikta pareiza rotācija un dēlis nav piezemējies uz ritenīšiem.

Trika nosaukums	Skaits cik pētījumos parādās
ollie	4
nollie	4
kickflip	4
popShuvit	4
heelflip	2
360 flip	2
fsShuvit	1
360 popShuvit	1
varial kickflip	1
double kickflip	1
hardflip	1
fs180	1
nollie popShuvit	1
Neveiksmīgs triks	1

1.2.2. Notikumu atpazīšana

Triku klasifikācija tiek veikta, katram veiktajam trikam atsevišķi, tāpēc, pirms iespējams veikt klasifikāciju, ir jāatrod katrs atsevišķais triks un tā notikuma logs.

Izvēlētajam notikuma logam ir jābūt pietiekami garam, lai tajā iekļautos viss veicamais triks. Ja papildus tiek atpazīts vai triks ir izpildīts veiksmīgi, tad tiek iekļauta arī noteikta garuma signāla daļa pēc trika piezemēšanās, kas satur šo informāciju [4]. Notikuma loga garums skeitborda pētījumos parasti tiek izvēlēts 1s - 1.5s garumā [3] [4] [17].

Notikuma loga atrašana, visbiežāk, tiek veikta meklējot piezemēšanās brīdi, jo trieciena moments rada augstas smailes sensoru signālos[3][4]. Viena no izmantotajām metodēm ir aplūkot akselerometra visu asu vērtību kvadrātu summas un novērtēt vai tiek pārkāpta iepriekš uzstādīta robežvērtība [3]. Ir uzlabojumi šai metodei, kur atrastais potenciālais piezemēšanas brīdis, tiek pārbaudīts aplūkojot žiroskopa mērījumu smailes [4]. Sīkāk par šīm metodēm autors aprakstījis [7].

1.3. Mašīnmācīšanās

Mašīnmācīšanās process sevī ietver vairākus soļus - pazīmju izvēli, atlasīšanu, modeļu un klasifikātoru izvēli un pielāgošanu, apmācību un precizitātes novērtēšanu.

1.3.1. Pazīmju atlasīšana

Pazīmes, kas parasti tiek izvēlētas no IMU ierīču signāliem laika vērtību apgabalā, ir vidējā vērtība, standartnovirze, dispersija, starpkvartilu diapozons, vidējā absolūtā novirze, asimetrija, korelācija starp asīm, entropija un ekscesa koeficients [18] [19]. Laika vērtību apgabals nav vienīgais, kas tiek izmantots pazīmju iegūšanai. Izmantojot Furjē transformāciju vai ātro Furjē transformāciju (FFT) tiek iegūts signāls frekvenču vērtību apgabalā. No frekvenču vērtību apgabala atlasītās pazīmes parasti ir vidējā frekvence, spektrālā enerģija (FFT koeficientu kvadrātu summa) un entropija [19]. Bez Furjē transformācijas, pirms tiek aprēķinātas pazīmes, tiek veiktas arī citas signāla manipulācijas un to kombinācijas, kā piemēram filtrēšana (zemo/augsto vērtību filtrs), diskrēta kosinusa transformācija, viļņu transformācija, autokorelācija un citas [18] [19] [20].

Labāko pazīmju atlasīšana ir atklāta problēma. Šobrīd nav metodes pazīmju atlasīšanai no IMU datiem, kas konsekventi sniegtu labāku rezultātu par citām metodēm. Pazīmju atlasīšanas metožu veiktspēja variē atkarībā no pārbaudāmās datu kopas [21]. Ir vairākas automātiskās pazīmju atlasīšanas metodes, kā SelectKBest[22], ReliefF[23], un Robust feature selection [24], kas ir veiksmīgi izmantotas ar IMU ierīču datiem [25]. Klasifikātoru veiktspēju ietekmē ne tikai labāku pazīmju identificēšana, bet arī optimālā pazīmju skaita noteikšana [21].

Skeitborda triku klasifikācijas pētījumos izmantotās pazīmes laika vērtību apgabalā ir vidējā vērtība, dispersija, asimetrija, starpasu korelācija un ekscesa koeficients. Frekvenču vērtību apgabalā - dominējoša frekvence un joslas platums [3]. Pazīmes tiek atlasītas no akselerometra un žiroskopa katras ass signāla. Klasifikācijas veikšanai tiek atlasītas tikai tās pazīmes, kuras dod labāko sniegumu [3]. Sīkāk par pazīmju atlasīšanu skeitborda pētījumos autors aprakstījis [7].

1.3.2. Klasifikātori

Uz IMU ierīču datiem balstītā sporta aktivitāšu atpazīšanā tiek izmantoti daudz dažādi klasifikātori. Visbiežāk tiek izmantots Support Vector Machine, kam seko Naive Bayes (NB) un k-Nearest Neighbors (kNN), vēl vērts pieminēt Random Forests (RF) [6].

Skeitborda triku atpazīšanā izmantotie klasifikātori - NB ($n = 3$), kNN ($n = 3$), Radial-basis Support Vector Machine (RBSVM) ($n = 3$), RF ($n = 2$), Linear Support Vector Machine (LSVM) ($n = 1$), Partial Decision Tree (PDT) ($n = 1$) un Logistic Regression ($n = 1$)[3] [4][5]. Nav viens klasifikātors, kas visos pētījumos būtu sasniedzis augstāko rezultātu. Pētījumā [3]

labāko precizitāti sasniedza NB un RBSVM, klasificējot sešus trikus ar precizitāti 97.8%, [5] pētījumā Logistic Regression un NB klasificēja piecus trikus ar 95% precizitāti un [4] pētījumā labākais rezultāts tika sasniegts izmantojot RBSVM klasifikātoru, kas klasificēja vienpadsmit trikus ar precizitāti 89.1%

1.3.3. Dziļie neironu tīkli

Dziļo neironu tīklu izmantošanai klasifikācijas problēmu risināšanai ir tendence pieaugt [26], tomēr sporta aktivitāšu klasifikācijā ar IMU ierīču datiem, šobrīd tie tiek izmantoti retāk, kā 1.3.2. nodaļā minētie klasifikātori [6]. Viens no iemesliem ir tas, ka dziļo neironu tīklu sniegums uzlabojas ar ļoti lielu datu daudzumu [26], ko ne vienmēr ir iespējams iegūt veidojot datu kopu ar IMU ierīcēm (skatīt 1.2. nodaļu).

Sporta jomā ar IMU datiem galvenokārt tiek izmantoti konvolūcijas neironu tīkli [6], kā, piemēram, trampīnlēkšanas kļūdu klasifikācijā [27], volejbola aktivitāšu klasifikācijā [9], atvēziena klasificēšana golfā, tenisā un badmintonā [28], bet ir arī izmantots Long Short Term Memory (LSTM) neironu tīkls darbību klasificēšanā distanču slēpošanā [29]. Ārpus sporta pētījumiem, ir pētīti neironu tīkli, kur konvolūcijas un LSTM slāņi ir apvienoti vienotā arhitektūrā - CLDNN [30], kā rezultātā ir iegūts uzlabojums 4-6% apmērā pār standarta LSTM neironu tīkliem, veicot klasifikāciju izmantojot laika rindas datus.

Skeitbordā triku atpazīšanā divos pētījumos ir izmantoti mākslīgie neironu tīkli [5] [17]. Vienā no pētījumiem nav aprakstīta tīkla uzbūve, otrā ir izmantots Multi layer Feed forward neironu tīkls [31]. Abi tīkli tika izmantoti piecu triku klasifikācijai un sasniegtā precizitāte bija 90% [5] un 98.7% [17], jāpiebilst, ka šajā pētījumā, apmācība notika uz mākslīgi ģenerētas datu kopas.

2. RISINĀJUMA APRAKSTS

Šobrīd visi autoram zināmie risinājumi izmanto vienu IMU ierīci, kas ir pievienota skrituļdēļa apakšā (skatīt 1.1. nodaļu) un triku atpazīšanā balstās tikai uz skrituļdēļa kustību. Šāda izvēle sensoru izvietojumā ierobežo atpazīstamo triku skaitu, vai var sniegt neprecīzus rezultātus klasificējamo triku skaitam palielinoties, jo sportista rotācija trika laikā un kāju pozīcija trika sākumā netiek ņemta vērā. Piemēram, sportists var veikt triku un šī trika laikā rotēt savu ķermeni pa 180 grādiem, ko ar vienu sensoru, kas atrodas uz skrituļdēļa, nav iespējams noteikt. Vai arī sportists var veikt *ollie* (palēcienu) savā ierastajā stājā (ar ērto kāju priekšā), vai *switch* stājā (ar neērto kāju priekšā). Dēļa kustība abos gadījumos būs vienāda, bet šie triki tiek uzskatīti par diviem dažādiem - *ollie* un *switch ollie*. Autors uzskata, ka šo problēmu var risināt, pievienojot papildus sensorus pie sportista kājām, kas sniegtu informāciju par to, kādu rotāciju veic sportists un ar kuru kāju tiek veikts lēciena atspēriens.

2.1. Datu iegūšana

Šobrīd nav publiskas skeitborda triku IMU signālu datu kopas, kurā būtu IMU ierīces novietotas arī uz sportista kājām, tāpēc šī darba ietvaros autors pats izveidoja datu kopu, kas tika izmantota risinājuma pārbaudei.

2.1.1. Triki

Šajā darbā, kā arī citos triku klasifikācijas pētījumos, tiek apskatīti tikai *Flip triki*. *Flip triki* vieni no otra tiek atšķirti pēc rotācijām, kuras veic dēlis, un rotācijām, kuras veic sportists. Darbā izmantotie triki (skatīt 2.2. tabulu) tika izvēlēti balstoties uz citos pētījumos izmantotajiem trikiem, kas minēti 1.2.1. nodaļā. Veicot datu kopas triku izvēli [32], tika pievērsta uzmanība, lai būtu pievienoti triki no visām iespējamajām triku veikšanas stājām (skatīt 2.1. tabulu). Konkrēti tika izvēlēti triki, kuriem klasifikācija tika veikta [3] un [4]

2.1. tabula.

Triku veikšanas stājas

Nosaukums	Apraksts
-	ērtais braukšanas virziens, atspēriens tiek veikts ar aizmugurējo kāju
nollie	ērtais braukšanas virziens, atspēriens tiek veikts ar priekšējo kāju
fakie	neērtais braukšanas virziens, atspēriens tiek veikts ar priekšējo kāju, mainīts dēļa virziens - gals, kurš parasti ir aizmugurē, atrodas priekšā
switch	neērtais braukšanas virziens, atspēriens tiek veikts ar aizmugurējo kāju

pētījumos, jo šajos darbos ir vislielākais pētāmo triku skaits un augstākā precizitāte. Papildus tam tika pievienoti triki, kuru atpazīšanu bez kāju sensoriem autors uzskata par apgrūtinātu - triki, kur sakrīt dēļu rotācijas, bet nesakrīt sportista rotācijas (*fs 180* un *fs shuvit*) un triki, kuriem dēļa kustība ir vienāda, bet vienīgā atšķirība ir ar kuru kāju tiek veikts triks (*ollie* un *switch ollie*).

2.2. tabula.

Pētījumā iekļautie triki

Trika nosaukums	Dēļa rotācija	Sportista rotācija	Stāja
ollie			-
kickflip	360° -X		-
pop shuvit	180° + Z		-
heelflip	360° +X		-
fs shuvit	180° - Z		-
fs 180	180° - Z	180° - Z	-
bs 180	180° + Z	180° + Z	-
360 flip	360° + Z, 360° -X		-
varial kickflip	180° + Z, 360° -X		-
nollie			nollie
nollie fs shuvit	180° - Z		nollie
nollie pop shuvit	180° + Z		nollie
switch ollie			switch
switch pop shuvit	180° + Z		switch
fakie ollie			fakie
fakie kickflip	360° -X		fakie
fakie fs shuvit	180° - Z		fakie
fakie pop shuvit	180° + Z		fakie
fakie fs 180	180° - Z	180° - Z	fakie
fakie bs180	180° + Z	180° + Z	fakie

2.1.2. Datu ievākšanas process

Piesaistītie sportisti triku veikšanai izmantoja savu inventāru, kam tika pievienotas IMU ierīces. IMU ierīces straumē datu lasījumus reālā laikā uz mobilajā ierīcē uzstādītu lietotni. Katra atsevišķā trika sensora dati tiek ierakstīti savā datnē, datne tiek marķēta ar trika nosaukumu, sportista identifikatoru un trika kvalitātes apzīmējumu (skatīt 2.3. tabulu), kas tiek izvēlēts katra trika datu ievākšanas beigās, balstoties uz to, kā triks tika paveikts. Dalībniekiem nav uzstādījums veikt visus trikus, jo triku saraksts ir liels un tiek pieļauta iespēja, ka ne katrs dalībnieks visus trikus spēs izpildīt, līdzīgi, kā tas ir veikts citos pētījumos, kur triku skaits ir bijis liels (skatīt 1.2.1. nodaļu). Tomēr, tiks pievērsta uzmanība, lai seši triku datu paraugi (*ollie*, *nollie*, *kickflip*, *pop shuvit*, *heelflip*, *360 flip*), kas ir abos 2.1.1. nodaļā minētajos

pētījumos, sastādītu katrs vismaz 5% no kopēja ievāktā datu daudzuma. Šāds uzstādījums ir izvēlēts, lai no divdesmit izvēlētajiem trikiem, šo triku klases saturētu pietiekamu lielu datu paraugu skaitu - vismaz vidējo paraugu skaitu klasē.

2.3. tabula.
Triku kvalitātes klasifikācija

Nosaukums	Apraksts
Neveiksmīgs	Triks nav izpildīts veiksmīgi
Ar labojumu	Tūlīt pēc trika veikšanas, lai noturētos uz dēļa, sportists ir veicis papildus manevrus ar kājām
Bez labojuma	Pēc trika veikšanas nav veikti papildus manevri

2.2. Notikuma atpazīšana

Šajā nodaļā autors apraksta, kādas metodes tika izmantotas notikuma atrašanā un izgriešanā no iegūtajiem datiem.

2.2.1. Notikumu izgriešana

Notikumu izgriešana tika veikta manuāli, lai pārliecinātos par to ka iegūtie dati un atrastie datu logi ir korekti. Iegūtie notikuma logi kalpo ne tikai mašīnmācīšanās darba daļai, bet arī tika izmantoti lai pārbaudītu notikumu atpazīšanas algoritmu precizitāti.

2.2.2. Algoritmu pārbaudes apraksts

Šī darba ietvaros autors pārbaudīs arī divus notikuma atpazīšanas algoritmus. Lai iegūtu pilnīgāku kopskatu par algoritmu precizitāti, katrs apskatītais notikumu atpazīšanas algoritms tiks pārbaudīts uz visiem datiem - veiksmīgi izpildītu triku datiem un ar un bez labojumiem veikto triku datiem, kā arī atsevišķi uz katra trika datiem, lai pārliecinātos, vai algoritms strādā vienlīdz labi uz visiem trikiem.

2.3. Pazīmju atlasīšana

Izmantoto statistikas pazīmju izvēle šajā darbā tiks balstīta uz 1.3.1. nodaļā minētajām skeitborda jomā izmantotajām pazīmēm, no kurām vērtīgākās pazīmes tika izvēlētas izmantojot pazīmju atlasīšanas algoritmu.

2.4. Mašīnmācīšanās

Triku klasificēšana tika veikta izmantojot mašīnmācīšanās klasifikatorus un neirona tīklus. Lai precīzāk varētu salīdzināt risinājuma precizitāti ar citu pētījumu rezultātiem, datu kopa tika sadalīta trīs triku grupās:

1. Seši triki, kas tika izmantoti [3] pētījumā : *ollie, kickflip, heelflip, pop shuvit, 360 flip, nollie*.
2. Vienpadsmit triki, kas vistuvāk atbilst trikiem, kas tika izmantoti [4] pētījumā: *ollie, kickflip, heelflip, pop shuvit, 360 flip, fs shuvit, nollie, varial kickflip, nollie fsShuvit, nollie pop Shuvit, fs180*. Trīs triki - *Hardflip, 360 pop shuvit un double kickflip*, kas tika izmantoti [4] pētījumā, bet netika iekļauti šī darba izvēlēto triku sarakstā, to sarežģītības dēļ, šajā triku grupā tika aizstāti ar citiem.
3. Visi triki (skatīt 2.2. tabulu), kuru dati tika ievākti šī darba ietvaros.

Izmantoto klasifikātoru izvēle ir balstīta uz 1.3.2. nodaļā minētajiem skeitborda triku klasifikācijā izmantotajiem klasifikātoriem. Tika pievērsta uzmanība, lai tiktu iekļauti visi klasifikātori, kas ir izmantoti [3] un [4] pētījumos, jo ar šiem pētījumiem tiks veikta rezultātu salīdzināšana. Izvēlētie klasifikātori:

- RBSVM
- kNN
- PDT
- RF
- NB
- LSVM

Klasifikācija tiks veikta arī izmantojot neironu tīklu. Tiks izveidots modelis kas sevī iekļauj konvolūcijas slāņus apvienojumā ar LSTM slāni. Šāds neirona tīkla veids tika izvēlēts balstoties uz 1.3.3. nodaļā minēto CLDNN neironu tīklu.

Apmācība un precizitātes noskaidrošana gan mašīnmācīšanās klasifikātoriem, gan neironu tīklam, tiks veikta katrai triku grupai atsevišķi. Tā kā neveiksmīgi izpildīti triki citos pētījumos [4] ir pasliktinājuši precizitāti un rezultāts ir pārbaudīts atsevišķi visiem

mēģinājumiem un mēģinājumiem, kuri ir izpildīti veiksmīgi. Šī darba ietvaros katrai triku grupai arī tiks veikta rezultātu iegūšana no visiem triku mēģinājumiem un no mēģinājumiem, kas ir bijuši veiksmīgi. Papildus tam, lai noskaidrotu kāda ietekme uz rezultātu ir kāju IMU ierīcēm, tiks veikta klasifikācija arī bez kāju IMU ierīču datiem. Tātad katrai no trīs triku grupām tiks iegūti rezultāti četrās datu grupās:

1. Visi triku mēģinājumi ar visu IMU ierīču datiem.
2. Veikmīgie triku mēģinājumi ar visu IMU ierīču datiem.
3. Visi triku mēģinājumi ar tikai skeitborda IMU ierīces datiem.
4. Veikmīgie triku mēģinājumi ar tikai skeitborda IMU ierīces datiem.

3. RISINĀJUMA IMPLEMENTĀCIJA

Šajā nodaļā autors aprakstīta kādas konkrētas metodes, risinājumi un rīki ir izmantoti, lai īstenotu 2. nodaļā aprakstīto risinājumu.

3.1. Sensori

Šajā nodaļā ir aprakstītas izvēlētās IMU ierīces, kuras tiek izmantotas risinājuma īstenošanā, kāds ir to izvietojums, kā arī aprakstīts izvēlēto uzstādījumu pamatojums.

3.1.1. Izvēlētās IMU ierīces

Datu ievākšanai tika izmantotas trīs Suunto Movesense IMU ierīces[33]. Šīs ierīces tika izvēlētas vairāku iemeslu dēļ. Pirmkārt, tās ir trieciendrošas, kas veicot skeitborda trikus ir svarīgi. Otrkārt, ir pieejama mobilā lietotne (Movesense Showcase) datu straumēšanai no ierīcēm uz mobilo telefonu. Šī lietotnes programmatūras kods tika pielāgots, lai atbalstītu vienlaicīgi trīs sensorus, kā arī varētu veikt datu ierakstīšanu un marķēšanu. Treškārt, izmērs ir atbilstošs, lai to varētu novietot uz skrituļdēļa un apaviem un sportistam netiktu traucēta triku veikšana [33].

3.1.2. Sensoru uzstādījumu

Visām trim izmantotajām IMU ierīcēm uzstādījumi tika izvēlēti vienādi (skatīt 3.1. tabulu). Izvēlētā diskretizācijas frekvence ir zemāka, nekā tā ir bijusi lielākajā daļā citos skeitborda triku atpazīšanas pētījumos, kas aprakstīti 1.1 nodaļā. Izvēlētā frekvence ir 52Hz, tā ir zemākā divu iemeslu dēļ. Pirmkārt, lai nodrošinātu stabilu datu pārraidi vienlaicīgi no trīs sensoriem, kas ir problēma Movesense IMU ierīcēm [34]. Otrkārt, autors uzskata, ka 200Hz diskretizācijas frekvence ir pārāk augsta triku atpazīšanai, ko ir arī pierādījis pētījums, kas minēts 1.1 nodaļā, veiksmīgi klasificējot trikus izmantojot 20Hz frekvenci.

3.1. tabula.

Izmantotie uzstādījumi eksperimentā

	Akselerometrs	Žiroskops
Diskretizācijas frekvence	52Hz	52Hz
Amplitūda	+/-16g	2000°/s.
Izšķirtspēja	16bit	16bit



3.1. att. Sensoru atrašanās vieta uz apaviem un skrituļdēļa

3.1.3. Sensoru izvietojums

Viena IMU ierīce tika pievienota dēļa apakšā (skatīt 3.1. attēlu), zem stiprinājumiem, tādējādi samazinot iespēju sportistam ierīci sabojāt, neveiksmīgas piezemēšanās gadījumā. Šī vieta tiek izvēlēta, tādēļ, ka tā ir pēdas daļa, kas netiek izmantota triku izpildīšanā, bet no tās var iegūt informāciju par pēdas kustību. Divas IMU ierīces tika pievienotas katra pie savas kājas, pēdas aizmugurē virs papēža kaula (skatīt ??).

3.2. Notikuma datu iegūšana

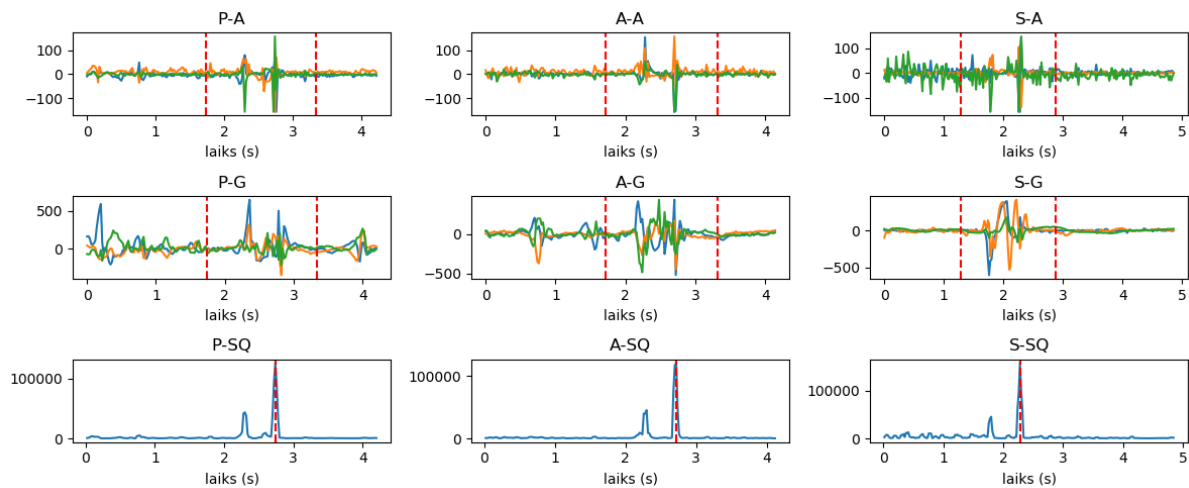
Notikuma loga izmērs tika izvēlēts 1.6s garumā, 1s pirms piezemēšanās brīža un 0.6s pēc piezemēšanās brīža. Loga garums tika izvēlēts balstoties uz citiem skeitborda triku pētījumiem, kas aprakstīti 1.2.2 nodaļā.

3.2.1. Notikumu loga izgriešana

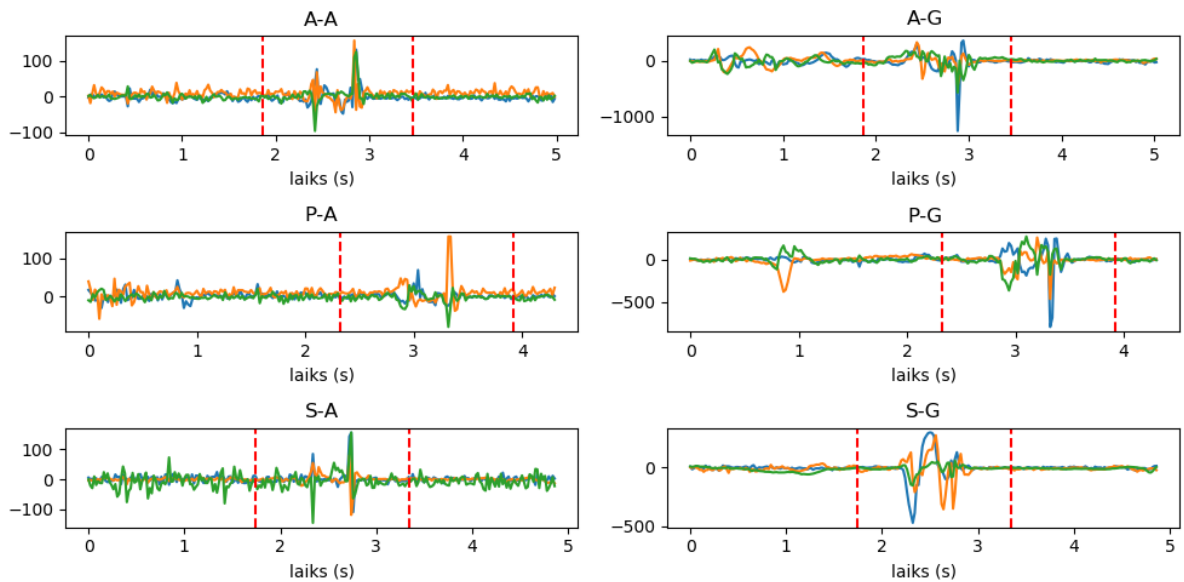
Notikumu loga izgriešana tika veikta balstoties uz 1.2.2 nodaļu - tika meklētas akcelerometra visu trīs asu kvadrātu summas maksimālās vērtības trika datnē (skatīt 3.2. attēlu). Katram trikam tika manuāli pārbaudīts vai atrastā vērtībā atbilst trika piezemēšanās brīdim. Ja tā bija kļūdaina, tad tika meklēta nākamā augstākā vērtība, līdz tika atrasta tā, kas sakrīt ar trika piezemēšanas brīdi.

Tā kā sensori savā starpā nav sinhronizēti, tika pārbaudīts vai datu straumēšana no sensoriem noris korekti. Aplūkojot ienākošos datus, tika konstatēts, ka vismaz vienam no

sensoriem, katrā trika izpildē ienākošajos datos ir bijusi nobīde laikā. 3.3. attēlā redzams viena trika ierakstītie sensoru dati, sarkanās vertikālās līnijas nodala trika notikumu. Var redzēt, ka notikuma moments, starp atsevišķām IMU ierīcēm nesakrīt, kā arī ierakstītais laika posms ir atšķirīgs. Šī iemesla dēļ, katram sensoram notikumu atrašana tika veikta atsevišķi. Izgrieztie notikumi tika saglabāti atsevišķās datnēs.



3.2. att. Notikuma atpazīšana pēc akcelerometra asu kvadrātu summas maksimālās vērtības. IMU apzīmējumi: aizmugurējās kāja (A-), priekšējā kāja (P-), skrituļdzelis (S-). Signālu apzīmējumi: akcelerometra signāls (A), žiroskopa (G), akcelerometra signāla kvadrātu summa (SQ).



3.3. att. Ienākošo datu nobīde. IMU apzīmējumi: aizmugurējās kāja (A-), priekšējā kāja (P-), skrituļdzelis (S-). Signālu apzīmējumi: akcelerometra signāls (A), žiroskopa signāls (G)

3.2.2. Notikumu atpazīšanas algoritmi

Darba ietvaros tika pārbaudīti divi notikumu atpazīšanas algoritmi. Abi algoritmi atrod notikumu meklējot piezemēšanās momentu. Uzstādītā pieļaujamā kļūda no manuāli atrastā piezemēšanās momenta ir +/-0.05s.

Pirmais algoritms veic piezemēšanās brīža meklēšanu balstoties tikai uz akcelerometra datiem līdzīgi kā tas tika darīts [3] pētījumā (skatīt 1.2.2. nodaļu). Pirmā algoritma darbība noris sekojoši: tiek aprēķināta visu akcelerometra asu vērtību kvadrātu summa ar slīdošu logu garumā 3. Tā kā ir zināms, ka vienā datnē ir tikai viena trika dati, tad netiek uzstādīta robežvērtība, tā vietā tiek meklēta maksimālā kvadrātu summas vērtība, un šīs vērtības pozīcija tiek uzskatīta par piezemēšanās brīdi.

Otrs pārbaudītais algoritms darbojās tā pat kā pirmais algoritms, bet tiek veikta papildus pārbaude - atrodot maksimālo akcelerometra kvadrātu summas vērtību, tiek pārbaudīts vai žiroskopa datu kvadrātu summas vērtība šajā pozīcija pārsniedz iepriekš uzstādītu robežvērtību.

3.3. Pazīmju atlasīšana

Šajā nodaļā ir aprakstīts kā no notikuma loga darba ietvaros tika veikta pazīmju iegūšana un izvēle.

3.3.1. Statistikas pazīmes

Izvēlētās statistikas pazīmes, kas tiks aprēķinātas darba ietvaros, ir vidējā vērtība, dispersija, asimetrija, ekscesa koeficients, starpasu korelācija maksimālā vērtība, minimālā vērtība un summa. Šīs pazīmes tika izvēlētas balstoties uz 1.3.1. nodaļā aprakstītajām pazīmēm, konkrēti tām, kuras ir izmantotas skeitborda triku atpazīšanas pētījumos, kā arī pievienotas papildus pazīmes (maksimālā vērtība, minimālā vērtība un summa).

3.3.2. Signāla apstrāde

Izvēlētās statistikas pazīmes šī darba ietvaros tika iegūtas no visa trika loga. Manipulācijas, kā Furjē transformācija, autokorelācija, u.c. kas pieminētas 1.3.1. nodaļā, šī darba ietvaros netika veiktas. Nākotnes pētījumi varētu ietvert signāla apstrādes un manipulācijas ietekmes uz rezultātu novērošanu.

3.3.3. Pazīmju izvēle

Pazīmju novērtēšana un labāko pazīmju atlase tika veikta izmantojot pazīmju atlasīšanas algoritmu SelectKBest. Nākotnes pētījumos būtu vērtīgi veikt salīdzinājumu ar ReliefF, Robust feature selections (skatīt 1.3.1. nodaļu) vai citām metodēm.

Pazīmju skaits tika izvēlēts pārbaudot klasifikātoru precizitāti ar visu iespējamo pazīmju skaitu. Tā, kā katram klasifikātoram augstākā precizitāte var tikt sasniegta pie dažādu pazīmju skaita, tad gala skaits tiek izvēlēts atrodot maksimālo vidējo precizitāti starp pārbaudītajiem klasifikātoriem. Pazīmju skaits tika izvēlēts katrai triku grupai un datu grupai (skatīt 2.4. nodaļu) atsevišķi. Lai nodrošinātu, ka testa dati neiespaido pazīmju skaita izvēli, šajā posmā apmācības datu kopa tika sadalīta un 30% no tās tika izmantoti precizitātes aprēķināšanai.

3.4. Triku klasifikācija

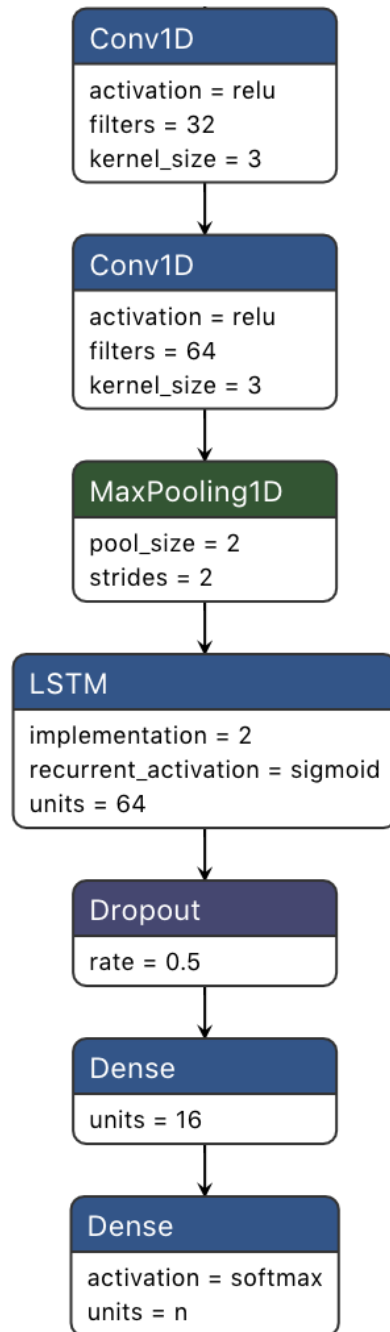
Datu kopas sadalījums apmācības datu kopā un testa datu kopā - 70% apmācības datu kopa, 30% testa datu kopa. Testa datu kopa tika izmantota tikai un vienīgi gala precizitātes aprēķināšanai.

3.4.1. Mašīnmācīšanas klasifikātori

Mašīnmācīšanās klasifikātori tika izmantoti ar noklusētajām parametru vērtībām. Nākotnes pētījumos būtu interesanti noskaidrot, kādu uzlabojumu precizitātei sniedz klasifikātoru parametru optimāla pielāgošana triku klasifikācijas problēmas risināšanai.

3.4.2. Dziļo neironu tīkls

Dziļo neironu tīkla modeļa izveide un tā parametru pielāgošana tika veikta izmantojot tikai pusi no datiem. Kad modeļa gala struktūra tika izvēlēta (skatīt 3.4. attēlu), vienīgā modifikācija tika veikta izejas slānim - tika uzstādīts atpazīstamo klašu skaits atkarībā no izmantotās triku grupas. Šāda pieeja tika izvēlēta lai izvairītos no pārmērīgas parametru pielāgošanas un informācijas noplūdes no testa kopas. Lai iegūtu precīzāku priekšstatu par tīkla veiktspēju, tā precizitāte tiks aprēķināta, veicot k-fold savstarpējo validāciju [35].




3.4. att. Neironu tıkla modelə uzbüve.

4. RISINĀJUMA REZULTĀTI

Šajā nodaļā ir aplūkoti un aprakstīti nozīmīgākie iegūti darba rezultāti. Rezultāti ir iekļauti no visiem darba veidošanas ciklā iesaistītajiem posmiem - IMU sensoru izmantošanas, datu kopas izveidošanas, notikumu atpazīšanas, pazīmju atlasīšanas un triku klasifikācijas.


4.1. IMU sensori

No risinājumā izmantotajām trīs IMU ierīcēm, kurā katrā tika izmantoti divi trīsasu sensori, kopumā tika iegūti astoņpadsmit signāli, kas raksturo katru veikto triku (skatīt 4.1. attēlu). No ievāktajiem 1203 triku datu paraugiem 178 nebija izmantojami sensoru nepilnīgu



4.1. att. Trika *Kickflip* sensoru dati. Aizmugurējās kājas akselerometra (A-A) un žiroskopa (A-G) dati, priekšējās kājas akselerometra (P-A) un žiroskopa (P-G) dati, skrituļdēļa akselerometra (S-A) un žiroskopa (S-G) dati.

datu dēļ. Tika novērotas divas galvenās problēmas. Pirmā - daļā no datnēm trūka viena sensora datu lasījumi. Pēc autora domām, šajos gadījumos IMU ierīce zaudēja savienojumu ar mobilo lietotni, bet netika parādīts kļūdas paziņojums. Otrā problēma - trika datu ierakstīšana tiek priekšlaicīgi pārtraukta. Lai gan datu ierakstīšanas procesā, trika ierakstīšana vienmēr tika pārtraukta pēc trika veikšanas, daļā no datnēm bija nepilnīgi trika dati (skatīt 4.2. attēlu). Šāda problēma, visticamāk, parādījās tāpēc, ka datu sūtīšana no IMU ierīces uz mobilo lietotni, notiek ar laika aizkavi un datu saglabāšana ir pārtraukta pirms visi trika dati ir izsūtīti no IMU ierīces.



4.2. att. Priekšlaicīga datu ieraksta pārtraukšana. Akselerometra dati (A), žiroskopa dati (G).

4.2. Datu kopa


Datu kopas izveidē piedalījās četri sportisti (skatīt 4.1. tabulu), kuri ar skeitbordu nodarbojas vaļasprieka līmenī. Ne visi sportisti veica visus trikus, kā arī ievākto datu paraugu skaits starp sportistiem nav vienāds. Kopējais ievāktais datu paraugu skaits ir 1025, šis skaits

4.1. tabula.

Datu ievākšanas procesa dalībnieki

Nr.	Pieredze	Datu parauga %
1.	17 gadi	78.05%
2.	16 gadi	11.51%
3.	16 gadi	8.78%
4.	16 gadi	1.66%


iekļauj arī mēģinājumus, kas nebija veiksmīgi. Neveiksmīgi izpildītu triku dati sastāda 28% no kopējās datu kopas un šis sadalījums starp trikiem ir nevienmērīgs (skatīt 4.3. attēlu).




4.3. att. Veiksmīgi/neveiksmīgi izpildītu triku sadalījums datu kopā

Triku sadalījums datu kopā (skatīt 4.4. attēlu) ir salīdzinoši vienmērīgs, lielākā daļa triku datu paraugā sastāda 4% - 6% no kopēja datu kopas paraugu skaita, bet ir arī pāris izņēmumi. Visvairāk veiktais triks ir *kickflip* 8.2%, vismazāk veiktais *fakie popShuvit* 2.9%). 2.1.2. nodaļā aprakstītais uzstādījums, par [3] pētījumā minētajiem trikiem ir izpildīts, katrs no šiem trikiem sastāda vismaz 5% no kopējā triku skaita.

Triku kvalitātes rādītāju sadalījums datu kopā (skatīt 4.5. attēlu). Līdzīgi kā neveiksmīgi izpildītu triku paraugiem arī paraugiem ar pielabojumu sadalījums starp trikiem nav vienmērīgs.



4.4. att. Triku sadalījums datu kopā



4.5. att. Triku kvalitātes sadalījums datu kopā

4.3. Notikuma atpazīšana

Šajā nodaļā ir aprakstīti notikumu atpazīšanas rezultāti, kā arī notikuma nobīde starp sensoriem.

4.3.1. Notikumu nobīde

Tika pārbaudīta 3.3. nodaļā aprakstīta ienākošo sensoru datu nobīde. Kopējā vidēja nobīde viena trika ietvaros ir 0.4s. Vidējā nobīde vislielākā ir skrituļdēļa IMU sensoriem (skatīt 4.2. tabulu). Asimetrijas rādītāji visiem sensoriem ir robežās starp -0.5 un 0.5, kas nozīmē, ka sensoru nobīde ir aptuveni simetriska uz abām pusēm.

4.2. tabula.
Sensoru nobīdes rādītāji

Pazīme	IMU1	IMU2	IMU3
Vidējā nobīde	0.12s	0.07s	0.22s
Asimetrija	-0.34	0.21	0.18

4.3.2. Algoritmu pārbaude

Tika pārbaudīti 3.2.2. nodaļā un aprakstītie algoritmi. Visaugstākā precizitāte ir trikiem, kuri veikti bez pielabojuma, un zemākā tiem trikiem, kuri nav veiksmīgi (skatīt 4.3. tabulu). Viszemākā precizitāte tika atklāta priekšējās kājas sensoram, pie trikiem kas nebija veiksmīgi, kas var būt izskaidrojams ar papildus soļa speršanu, lai saglabātu līdzsvaru.

Priekšējās kājas sensoram tika arī novērots precizitātes uzlabojums starp trikiem, kas veikti ar pielabojumu un trikiem, kas veikti bez tā (uzlabojums par 4.1% - 4.2%), kamēr pārējiem sensoriem notikumu atpazīšanā uzlabojums ir neliels (0.5% - 0.07% un 0.1%), vai pat bijis negatīvs (algoritms nr. 2, IMU3 - 0.04%). Autors uzskata, ka iemesls šim uzlabojumam varētu būt tāds, ka pielabojuma manevrs parasti tiek veikts ar priekšējo kāju, un tas ir radījis papildus trokšņus triku datus ar pielabojumu.

4.3. tabula.

Notikumu atpazīšanas precizitāte katrai IMU ierīcei atsevišķi. Aizmugurējās kājas sensors (IMU1), priekšējās kājas sensors (IMU2), skrituļdēļa sensors(IMU3)

	Algoritms nr.1			Algoritms nr.2		
	IMU1	IMU2	IMU3	IMU1	IMU2	IMU3
Precizitāte	0.928	0.883	0.912	0.936	0.883	0.922
Precizitāte veiksmīgiem trikiem	0.954	0.927	0.938	0.962	0.927	0.949
Precizitāte neveiksmīgiem trikiem	0.861	0.771	0.847	0.868	0.771	0.854
Precizitāte trikiem ar pielabojumu	0.951	0.901	0.937	0.958	0.901	0.951
Precizitāte trikiem bez pielabojuma	0.956	0.942	0.938	0.965	0.943	0.947

Lai gan algoritma nr. 2 rezultāti ir augstāki vai tādi paši kā algoritmam nr. 1, ievērojams uzlabojums precizitātē netika novērots. Vidēji aizmugurējās kājās IMU ierīces precizitāte tika

uzlabota par 0.7%, priekšējās kājas par 0.02% un skrituļdēļa par 1.02%. Maksimālais precizitātes uzlabojums - 1.4%, ir skrituļdēļa IMU ierīcei veicot notikumu atpazīšanu trikiem ar pielabojumu. Aplūkojot notikuma atpazīšanas precizitāti atsevišķi katram trikam (skatīt 4.4. tabulu) netika novērotas tendence kādam no algoritmiem būt krietni veiksmīgākam konkrēta trika atpazīšanā.

4.4. tabula.

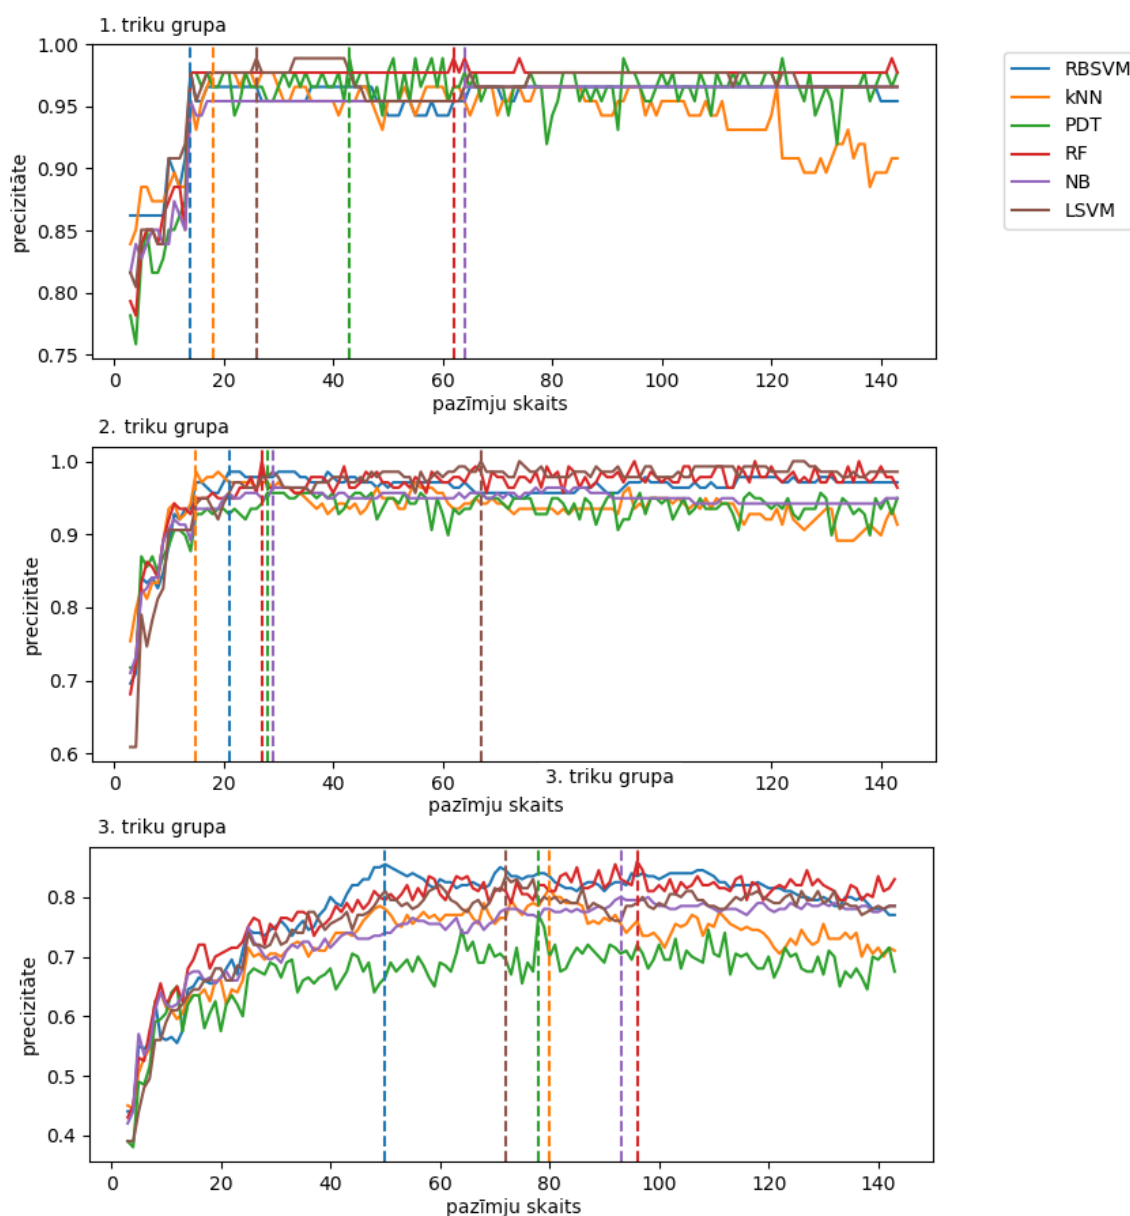
Notikuma atpazīšanas precizitāte katram trikam atsevišķi. Aizmugurējās kājas sensors (IMU1), priekšējās kājas sensors (IMU2), skrituļdēļa sensors(IMU3)

Triks	Algoritms nr.1			Algoritms nr.2		
	IMU1	IMU2	IMU3	IMU1	IMU2	IMU3
ollie	0.889	0.944	0.944	0.950	0.950	0.950
kickflip	0.968	0.935	0.903	0.968	0.935	0.903
pop shuvit	0.913	1	1	0.957	1	1
heelflip	0.897	0.949	0.923	0.897	0.949	0.949
fs shuvit	0.824	0.706	0.882	0.824	0.706	0.882
fs 180	0.944	1	1	0.944	1	1
bs 180	0.737	0.947	0.895	0.737	0.947	0.895
360 flip	0.95	0.925	0.875	0.95	0.925	0.875
varial kickflip	1	0.821	0.857	1	0.821	0.857
nollie ollie	0.895	0.895	0.895	0.895	0.895	0.921
nollie fs shuvit	1	0.714	0.964	1	0.714	0.964
nollie pop shuvit	0.963	0.778	0.926	0.963	0.778	0.926
switch ollie	0.962	0.962	0.923	0.962	0.962	0.923
switch pop shuvit	0.964	0.786	0.786	1	0.786	0.786
fakie ollie	1	1	0.889	1	1	0.889
fakie kickflip	0.917	0.778	0.944	0.917	0.778	0.944
fakie fs shuvit	0.889	0.944	1	0.889	0.944	1
fakie pop shuvit	0.9	0.867	0.9	0.9	0.867	0.967
fakie fs 180	1	0.933	0.933	1	0.933	0.933
fakie bs180	0.917	0.917	0.875	0.958	0.917	0.917

4.4. Pazīmju atlasīšana

Pazīmju skaita izvēle tika veikta kā aprakstīts 3.3.3. nodaļā izmantojot SelectKBest algoritmu. Katrā triku grupā, visiem precizitātes mērījumiem, katram klasifikātoram tika atrasta precizitāte ar pilnās pārslases metodi pazīmju skaitam. Pazīmju skaits, pie kura katram klasifikātoram ir maksimālā precizitāte, ļoti variē (skatīt, 4.6. attēlu). Kā tas tika sagaidīts, izvēloties pazīmju skaitu balstoties uz vidējo maksimālo vērtību zaudējums precizitātē tika novērots - pie 1. datu grupas, 1. triku grupai vidēji tas ir 0.9%, 2. triku grupai - 0.8%, trešajai triku grupai - 2.4% (skatīt 4.5. tabulu). Tālākos pētījumos būtu vērtīgi atlasīt pazīmju skaitu katram klasifikātoram atsevišķi, lai izvairītos no precizitātes zuduma. Izvēlēto pazīmju skaitu

skatīt 4.6. tabulā, FN kolonnā.



4.6. att. Klasifikatoru precizitāte mainoties pazīmju skaitam. Maksimālā precizitāte norādīta ar vertikālajām līnijām.

4.5. Mašīnmācīšanās

Šajā nodaļā tiek aplūkoti iegūtie klasifikatoru precizitātes dati. Visi dati balstās uz 4.6. tabulā aprakstītajiem rezultātiem.

Pirmajā triku grupā, kur tika atpazīti seši triki, tika pārspēta [3] pētījumā sasniegtā precizitāte. Precizitātes uzlabojums ir 0.6% izmantojot visus triku datus, izmantojot tikai veiksmīgo triku datus tika sasniegta ideāla precizitāte testa kopā un uzlabota precizitāte par 2.2%. Autors uzskata, ka šāds rezultāts tika sasniegts galvenokārt pateicoties lielākai datu

Precizitātes izmaiņas izvēloties pazīmju skaitu

1. Triku grupa	Precizitāte pie izvēlētā pazīmju skaita	Maksimālā precizitāte	Zudums
RBSVM	0.965	0.977	0.011
kNN	0.954	0.977	0.022
PDT	0.988	0.988	0
RF	0.977	0.988	0.011
NB	0.965	0.965	0
LSVM	0.977	0.988	0.011
2. Triku grupa			
RBSVM	0.985	0.985	0
kNN	0.971	0.985	0.014
PDT	0.956	0.956	0
RF	0.971	0.985	0.014
NB	0.963	0.963	0
LSVM	0.978	1	0.022
3. Triku grupa			
RBSVM	0.84	0.855	0.015
kNN	0.785	0.815	0.03
PDT	0.77	0.77	0
RF	0.78	0.8	0.02
NB	0.765	0.8	0.035
LSVM	0.79	0.835	0.045

kopai un veiksmīgai pazīmju atlasīšanai, jo uzlabojums tika sasniegts arī bez uz kājām uzstādīto IMU ierīču datiem. Otrajā triku grupā, atpazīstot vienpadsmit trikus, salīdzinājumā ar [4] pētījumu uzlabojums bija krietni lielāks. Visu triku datiem precizitātes uzlabojums ir 18.7%. Veiksmīgo triku datiem viens no klasifikatoriem atkal sasniedza ideālu precizitāti, un precizitātes uzlabojums salīdzinājumā ar pētījumu ir 10.9%. Ir jāpiemin ka šajā triku grupā iegūtais rezultāts ir tikai salīdzinājums ar vienādu triku skaitu un veiktie triki, kā minēts 2.4. nodaļā, pilnībā nesakrīt. Augstākā precizitāte trešajai triku grupai, klasificējot divdesmit dažādus trikus, ir 0.88 visiem triku datiem un veiksmīgajiem trikiem tā ir 0.904.

Lai atbildētu uz šajā darbā autora izvirzītajiem jautājumiem tika veikta precizitātes salīdzināšana katrā no triku grupām ar un bez papildus pie kājām pievienoto IMU ierīču datiem. Pirmajā triku grupā papildus IMU ierīču izmantošana nesniedza augstākus rezultātus izmantojot visus triku datus. No datiem, kas iegūti tikai pie skrituļdēļa IMU ierīces rezultāts bija par 0.8% augstāks. Nebija sagaidīts, ka papildus IMU ierīces sniegs uzlabojumu šajā triku grupā, jo šos trikus, vienu no otra atšķir tikai skrituļdēļa rotācija. Tomēr veicot pārbaudi ar veiksmīgi izpildītiem trikiem, gan ar papildus IMU ierīcēm, gan bez tām, tika sasniegta ideāla precizitāte. Izmantojot kāju IMU ierīces šī precizitāte tika sasniegta četriem no sešiem

Triku klasifikācijas precizitāte. Izmantoto pazīmju skaits (FN)

1. triku grupa	RBSVM	kNN	PDT	RF	NB	LSVM	FN
Precizitāte	0.984	0.984	0.935	0.959	0.967	0.976	20
Precizitāte veiksmīgiem trikiem	1	1	1	0.989	0.989	1	21
Precizitāte bez kāju IMU	0.984	0.992	0.951	0.976	0.967	0.992	15
Precizitāte bez kāju IMU veiksmīgiem trikiem	0.989	0.989	1	0.989	0.989	1	23
Pētījuma precizitāte [3]	0.978	0.960	0.934	-	0.978	-	-
2. triku grupa	RBSVM	kNN	PDT	RF	NB	LSVM	
Precizitāte	0.975	0.955	0.939	0.949	0.949	0.985	30
Precizitāte veiksmīgiem trikiem	1	0.986	0.944	0.993	0.986	0.993	25
Precizitāte bez kāju IMU	0.955	0.939	0.914	0.949	0.939	0.919	14
Precizitāte bez kāju IMU veiksmīgiem trikiem	1	0.979	0.867	0.972	0.972	0.979	17
Pētījuma precizitāte [4]	0.781	0.763	-	0.798	0.571	0.708	
Pētījuma precizitāte veiksmīgiem trikiem [4]	0.891	0.863	-	0.872	0.639	0.825	
3. triku grupa	RBSVM	kNN	PDT	RF	NB	LSVM	
Precizitāte	0.880	0.812	0.711	0.799	0.815	0.838	78
Precizitāte veiksmīgiem trikiem	0.904	0.881	0.772	0.804	0.872	0.890	71
Precizitāte bez kāju IMU	0.740	0.744	0.640	0.747	0.718	0.763	16
Precizitāte bez kāju IMU veiksmīgiem trikiem	0.772	0.753	0.653	0.795	0.836	0.813	16

klasifikatoriem, bez papildus IMU ierīcēm, tā tika sasniegta diviem. Otrajā triku grupā par 3% augstāka precizitāte bija izmantojot papildus IMU ierīces, bet veiksmīgiem trikiem abos gadījumos atkal tika sasniegta ideāla precizitāte. Trešajā triku grupā, kurā tika iekļauti triki, kuru atpazīšanu bez papildus sensoriem autors uzskata par apgrūtinātu (skatīt 2.4. nodaļu), precizitātes atšķirība ir lielāka. Precizitātes uzlabojums visiem triku datiem izmantojot kāju IMU ierīces ir 11.7%, veiksmīgi izpildītiem trikiem tas ir 6.5%. Pēc šiem rezultātiem var redzēt, ka pie trikiem, kurus var atšķirt tikai pēc skrituļdeļa kustības, papildus IMU ierīču dati rezultātu neuzlabo, vai uzlabojums ir neliels, tomēr palielinoties triku skaitam, precizitātes uzlabojums ir būtisks.

Salīdzinājumā ar mašīnmācīšanās klasifikatoriem, neironu tīklu precizitāte (skatīt 4.7. tabulu) bija zemāka. Autors uzskata, ka viens no iemesliem ir nepietiekamais datu daudzums, lai veiksmīgi apmācītu tīklu. Augstākie rezultāti pirmajās divās triku grupās tika sasniegti neizmantojot papildus IMU ierīču datus. Tomēr trešajā grupā, palielinoties triku dažādībai, precizitāte bija augstāka, izmantojot pie kājām pievienoto IMU ierīču datus. Šajā triku grupā, atšķirībā no mašīnmācīšanās klasifikatoriem, augstākā precizitāte tika sasniegta ar visiem triku mēģinājumiem, nevis tikai veiksmīgi izpildītiem trikiem. Pēc autora domām šāds rezultāts ir


tāpēc, ka neveiksmīgi izpildīti triki sastāda gandrīz 30% no kopējās datu kopas izmēra un, arī pat, ja šie dati neappraksta triku tik precīzi, kā veiksmīgie triki, ieguvums no lielākas datu kopas apmācības laikā uzlabo precizitāti.

4.7. tabula.

Triku klasifikācijas precizitāte Neironu tīklam

1. triku grupa	Neironu tīkls	standartnovirze
Precizitāte	0.933	0.046
Precizitāte veiksmīgiem trikiem	0.964	0.043
Precizitāte bez kāju IMU	0.971	0.028
Precizitāte bez kāju IMU veiksmīgiem trikiem	0.990	0.016
2. triku grupa		
Precizitāte	0.879	0.059
Precizitāte veiksmīgiem trikiem	0.872	0.059
Precizitāte bez kāju IMU	0.935	0.034
Precizitāte bez kāju IMU veiksmīgiem trikiem	0.941	0.029
3. triku grupa		
Precizitāte	0.809	0.036
Precizitāte veiksmīgiem trikiem	0.782	0.059
Precizitāte bez kāju IMU	0.735	0.059
Precizitāte bez kāju IMU veiksmīgiem trikiem	0.767	0.027

Visaugstāko precizitāti trešajā triku grupā sasniedza RBSVM klasifikators - 0.88. Aplūkojot šī klasifikatora pārpratumu matricu (skatīt 4.7 attēlu), var redzēt, ka visbiežākās kļūdas sastāda nepareiza trika veikšanas stājas (skatīt 2.1. tabulu) klasifikācija. Tas nozīmē, ka trika laikā izpildītā skrituļdēļa un sportista rotācija ir atpazīta pareizi, bet nesakrīt stāja (*fakie bs180 - bs180, fakie pop shuvit - pop shuvit*). Konkrēti tiek nepareizi klasificēta noklusējuma stāja un *fakie* stājā. Šīs kļūdas sastāda 54.05% no visām kļūdām. Pēc autora domām, tieši šīs kļūdas sastāda tik lielu daļu, jo triki, kas izpildīti *fakie* stājā, no parastās atšķirās tikai ar braukšanas virzienu, kuru ar darbā izvēlētajām pazīmēm ir grūtāk noteikt. Pārējās kļūdas ir nepareiza trika rotācijas (*heelflip - kickflip*), vai izmantotās atspēriena kājas (*fs shuvif - switch pop shuvit*) atpazīšana, bet šajās kļūdās likumsakarības netika novērotas.



4.7. att. RBSVM klasifikatora pārpratuma matrica

NOBEIGUMS UN SECINĀJUMI

Darba ietvaros ir izpētītas šobrīd izmantotās metodes un pieejas skeitborda triku atpazīšanas jomā, kā arī autors ir izstrādājis jaunu risinājumu skeitborda triku atpazīšanai. Autora izstrādātais risinājums sastāv no trīs bezvadu IMU ierīcēm. Viena IMU ierīce ir novietota uz skrituļdeļa un divas uz sportista kājām, lai iegūtu pilnīgāku priekšstatu par veiktajām darbībām trika izpildes laikā.

Triku klasificēšanā autors izmantoja mašīnmācīšanās klasifikatorus un neironu tīklu. Tika sasniegta augstāka mašīnmācīšanās klasifikatoru precizitāte salīdzinot ar citiem skeitborda triku pētījumiem ar vienādiem un līdzīgiem trikiem. Šāda precizitāte pēc autora domām tika sasniegta tāpēc, ka tika veikta veiksmīga pazīmju izvēle un skaita noteikšana. Tomēr arī jāatzīst, ka viens no iemesliem kāpēc tika sasniegta tik augsta precizitāte ir tas, ka liela daļu no datu kopas datiem (78%) tika iegūti no viena sportista, kā rezultātā klasifikatori var būt pārmērīgi pielāgojušies šī sportista triku veikšanas manierei. Neirona tīkla precizitāte, salīdzinājumā ar mašīnmācīšanās klasifikatoru precizitāti bija zemāka. Iemesls, kādēļ neironu tīkla rezultāti bija zemāki, visticamāk, ir nepietiekamais datu paraugu skaits datu kopā, kā rezultātā modeļa apmācība nebija tik veiksmīga.

Autors uzskata, ka ir sasniedzis uzstādīto darba mērķi, izstrādājot skeitborda triku atpazīšanas risinājumu, kas izmanto arī uz sportista ķermeņa izvietotas IMU ierīces. Tomēr par iegūto rezultātu korektumu autors vēlētos pārliecināties izmantojot sabalansētāku datu kopu.

Darba izstrādes laikā autors identificēja vairākas tēmas, kas varētu tikt iekļautas nākotnes pētījumos. Kā vienu no potenciālajiem pētījuma virzieniem, autors uzskata triku kvalitātes atpazīšanu (trijs veikts veiksmīgi bez pielabojuma, veiksmīgi ar pielabojumu, neveiksmīgi) un trika atpazīšanu pa daļām, pēc to raksturojošām pazīmēm (deļa rotācijām, sportista rotācijām, atspēriena kājas). Tika atklātas problēmas ne tikai klasifikācijā, bet arī citos darba posmos - notikumu atpazīšanas uzlabošanā, pazīmju atlasīšanā un sensoru signālu apstrādes ietekmē uz rezultātu.

PATEICĪBA

Darba autors vēlās izteikt pateicību visiem, kas piedalījās datu kopas izveidošanā procesā, gan sportistiem, gan tiem, kas palīdzēja ar datu ievākšanu: Armandam Andžem, Reinim Elsterma, Edgaram Turķim un Oskaram Verzemniekam.

Autors vēlās arī izteikt pateicību darba vadītājam Jānim Judvaitim, par vērtīgu padomu un priekšlikumu sniegšanu bakalaura darba izstrādes procesā.

LITERATŪRAS SARAKSTS

- [1] Valentina Camomilla, Elena Bergamini, Silvia Fantozzi, and Giuseppe Vannozzi. Trends supporting the in-field use of wearable inertial sensors for sport performance evaluation: A systematic review. *Sensors*, 18(3):873, 2018.
- [2] Inc Grand View Research. Skateboard market size worth \$2.4 billion by 2025. <https://www.prnewswire.com/news-releases/skateboard-market-size-worth-2-4-billion-by-2025-cagr-3-1-grand-view-research-inc-300885354.html>, 2019. [tiešsaistē] [skatīts 7.05.2020].
- [3] Benjamin H Groh, Thomas Kautz, Dominik Schuldhaus, and Bjoern M Eskofier. Imu-based trick classification in skateboarding. In *KDD Workshop on Large-Scale Sports Analytics*, volume 17, 2015.
- [4] Benjamin H Groh, Martin Fleckenstein, Thomas Kautz, and Bjoern M Eskofier. Classification and visualization of skateboard tricks using wearable sensors. *Pervasive and Mobile Computing*, 40:42–55, 2017.
- [5] Muhammad Amirul Abdullah, Muhammad Ar Rahim Ibrahim, Muhammad Nur Aiman Bin Shapiee, Mohd Azraai Mohd Razman, Rabiuh Muazu Musa, and Anwar PP Abdul Majeed. The classification of skateboarding trick manoeuvres through the integration of imu and machine learning. In *Symposium on Intelligent Manufacturing and Mechatronics*, pages 67–74. Springer, 2019.
- [6] Emily E Cust, Alice J Sweeting, Kevin Ball, and Sam Robertson. Machine and deep learning for sport-specific movement recognition: A systematic review of model development and performance. *Journal of sports sciences*, 37(5):568–600, 2019.
- [7] Raimonds Rava. Skeitborda triku atpazīšanas un klasifikācijas metodes. *Kursa darbs*, 2019.
- [8] Marko Kos and Iztok Kramberger. A wearable device and system for movement and biometric data acquisition for sports applications. *IEEE Access*, 5:6411–6420, 2017.
- [9] Thomas Kautz, Benjamin H Groh, Julius Hannink, Ulf Jensen, Holger Strubberg, and Bjoern M Eskofier. Activity recognition in beach volleyball using a deep convolutional neural network. *Data Mining and Knowledge Discovery*, 31(6):1678–1705, 2017.

- [10] Eva Dorschky, Dominik Schuldhaus, Harald Koerger, and Bjoern M Eskofier. A framework for early event detection for wearable systems. In *Proceedings of the 2015 ACM International Symposium on Wearable Computers*, pages 109–112, 2015.
- [11] Zhendong Zhang, Dongfang Xu, Zhihao Zhou, Jingeng Mai, Zhongkai He, and Qining Wang. Imu-based underwater sensing system for swimming stroke classification and motion analysis. In *2017 IEEE International Conference on Cyborg and Bionic Systems (CBS)*, pages 268–272. IEEE, 2017.
- [12] C Crema, A Depari, A Flammini, Emiliano Sisinni, T Haslwanter, and S Salzmänn. Imu-based solution for automatic detection and classification of exercises in the fitness scenario. In *2017 IEEE Sensors Applications Symposium (SAS)*, pages 1–6. IEEE, 2017.
- [13] Alexander Hölzemann and Kristof Van Laerhoven. Using wrist-worn activity recognition for basketball game analysis. In *Proceedings of the 5th international Workshop on Sensor-based Activity Recognition and Interaction*, pages 1–6, 2018.
- [14] Heike Brock and Yuji Ohgi. Development of an inertial motion capture system for kinematic analysis of ski jumping. *Proceedings of the Institution of Mechanical Engineers, Part P: Journal of Sports Engineering and Technology*, 231(4):275–286, 2017.
- [15] Pedro Domingos. A few useful things to know about machine learning. *Communications of the ACM*, 55(10):78–87, 2012.
- [16] Gary Weiss and Foster Provost. The effect of class distribution on classifier learning: An empirical study. *Tech Rep*, 09 2001.
- [17] Nicholas Kluge Corrêa, Júlio César Marques de Lima, Thais Russomano, and Marlise Araujo dos Santos. Development of a skateboarding trick classifier using accelerometry and machine learning. *Research on Biomedical Engineering*, 33(4):362–369, 2017.
- [18] Oscar D Lara and Miguel A Labrador. A survey on human activity recognition using wearable sensors. *IEEE communications surveys & tutorials*, 15(3):1192–1209, 2012.
- [19] Stephen J Preece, John Y Goulermas, Laurence PJ Kenney, Dave Howard, Kenneth Meijer, and Robin Crompton. Activity identification using body-mounted sensors—a review of classification techniques. *Physiological measurement*, 30(4):R1, 2009.
- [20] Mitchell Yuwono, Steven W Su, Bruce D Moulton, and Hung T Nguyen. Unsupervised segmentation of heel-strike imu data using rapid cluster estimation of wavelet features.

In *2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pages 953–956. IEEE, 2013.

- [21] Martin A O’Reilly, William Johnston, Cillian Buckley, Darragh Whelan, and Brian Caulfield. The influence of feature selection methods on exercise classification with inertial measurement units. In *2017 IEEE 14th International Conference on Wearable and Implantable Body Sensor Networks (BSN)*, pages 193–196. IEEE, 2017.
- [22] Oliver Kramer. Scikit-learn. In *Machine learning for evolution strategies*, pages 45–53. Springer, 2016.
- [23] Marko Robnik-Šikonja and Igor Kononenko. Theoretical and empirical analysis of relieff and rrelieff. *Machine learning*, 53(1-2):23–69, 2003.
- [24] Feiping Nie, Heng Huang, Xiao Cai, and Chris H Ding. Efficient and robust feature selection via joint $\ell_2, 1$ -norms minimization. In *Advances in neural information processing systems*, pages 1813–1821, 2010.
- [25] Austin Harris, Hanna True, Zhen Hu, Jin Cho, Nancy Fell, and Mina Sartipi. Fall recognition using wearable technologies and machine learning algorithms. In *2016 IEEE International Conference on Big Data (Big Data)*, pages 3974–3976. IEEE, 2016.
- [26] Vivienne Sze, Yu-Hsin Chen, Tien-Ju Yang, and Joel S Emer. Efficient processing of deep neural networks: A tutorial and survey. *Proceedings of the IEEE*, 105(12):2295–2329, 2017.
- [27] Heike Brock, Yuji Ohgi, and James Lee. Learning to judge like a human: convolutional networks for classification of ski jumping errors. In *Proceedings of the 2017 ACM International Symposium on Wearable Computers*, pages 106–113, 2017.
- [28] Akash Anand, Manish Sharma, Rupika Srivastava, Lakshmi Kaligounder, and Divya Prakash. Wearable motion sensor based analysis of swing sports. In *2017 16th IEEE International Conference on Machine Learning and Applications (ICMLA)*, pages 261–267. IEEE, 2017.
- [29] Aliaa Rassem, Mohammed El-Beltagy, and Mohamed Saleh. Cross-country skiing gears classification using deep learning. *arXiv preprint arXiv:1706.08924*, 2017.
- [30] Tara N Sainath, Oriol Vinyals, Andrew Senior, and Haşim Sak. Convolutional, long short-term memory, fully connected deep neural networks. In *2015 IEEE International*

Conference on Acoustics, Speech and Signal Processing (ICASSP), pages 4580–4584. IEEE, 2015.

- [31] Daniel Svozil, Vladimir Kvasnicka, and Jiri Pospichal. Introduction to multi-layer feed-forward neural networks. *Chemometrics and intelligent laboratory systems*, 39(1):43–62, 1997.
- [32] Skateboard trick list. <https://www.skateboardhere.com/skateboard-trick-list.html>. [tiešsaistē] [skatīts 28.04.2020].
- [33] Suunto Oy. Movesense sensora tehnisko datu lapa. <https://www.movesense.com/wp-content/uploads/2017/11/Movesense-Sensor-Datasheet--20171109.pdf>, 2017. [tiešsaistē] [skatīts 28.04.2020].
- [34] Suunto Oy. Movesense best practices. http://www.movesense.com/docs/esw/best_practices/. [tiešsaistē] [skatīts 21.03.2020].
- [35] Juan D Rodriguez, Aritz Perez, and Jose A Lozano. Sensitivity analysis of k-fold cross validation in prediction error estimation. *IEEE transactions on pattern analysis and machine intelligence*, 32(3):569–575, 2009.

Bakalaura darbs „Skeitborda triku klasifikācijas metodes izmantojot mašīnmācīšanos ar IMU sensoru datiem” izstrādāts LU Datorikas fakultātē.

Ar savu parakstu apliecinu, ka pētījums veikts patstāvīgi, izmantoti tikai tajā norādītie informācijas avoti un iesniegtā darba elektroniskā kopija atbilst izdrukai.

Autors: Raimonds Rava

Rekomendēju/nerekomendēju darbu aizstāvēšanai

Vadītājs: pētnieks M.dat. Jānis Judvaitis __.06.2020.

Recenzents: profesors Dr.math. Kārlis Podnieks

Darbs iesniegts Datorikas fakultātē __.06.2020.

Dekāna pilnvarotā persona: vecākā metodiķe Ārija Sproģe _____

Darbs aizstāvēts bakalaura gala pārbaudījuma komisijas sēdē

__.06.2020. prot. Nr. ____

Komisijas sekretārs(-e): _____