Razvoj podatkovne rukavice za snimanje i analizu pokreta

Jurakić, Marko

Undergraduate thesis / Završni rad

2020

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Mechanical Engineering and Naval Architecture / Sveučilište u Zagrebu, Fakultet strojarstva i brodogradnje**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:235:327533

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-29**

Repository / Repozitorij:

Repository of Faculty of Mechanical Engineering and Naval Architecture University of Zagreb







SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

ZAVRŠNI RAD

Marko Jurakić

Zagreb, 2020.

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

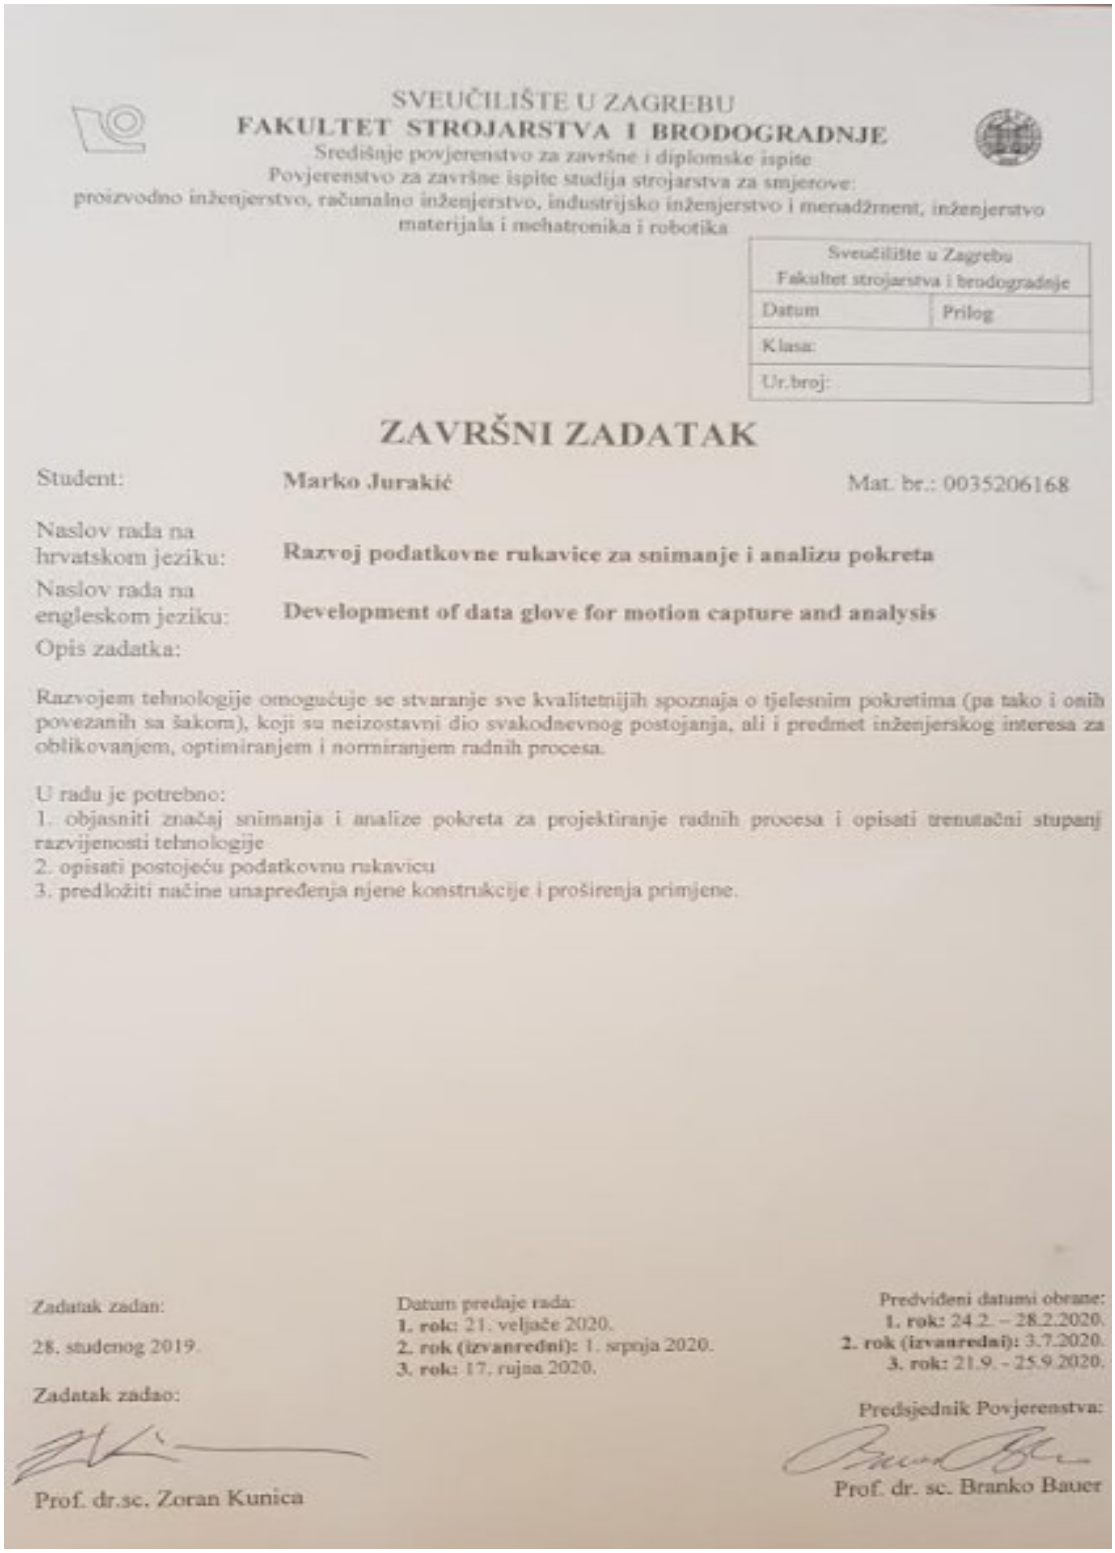
ZAVRŠNI RAD

Mentor:
Prof. dr.sc. Zoran Kunica, dipl.ing.

Student:
Marko Jurakić

Zagreb, 2020.

ZADATAK



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE
Središnje povjerenstvo za završne i diplomske ispite
Povjerenstvo za završne ispite studija strojarstva za smjerove:
proizvodno inženjerstvo, računalno inženjerstvo, industrijsko inženjerstvo i menadžment, inženjerstvo materijala i mehatronika i robotika

Sveučilište u Zagrebu Fakultet strojarstva i brodogradnje	
Datum	Prilog
Klasa:	
Ur.broj:	

ZAVRŠNI ZADATAK

Student: **Marko Jurakić** Mat. br.: 0035206168

Naslov rada na hrvatskom jeziku: **Razvoj podatkovne rukavice za snimanje i analizu pokreta**

Naslov rada na engleskom jeziku: **Development of data glove for motion capture and analysis**

Opis zadatka:

Razvojem tehnologije omogućuje se stvaranje sve kvalitetnijih spoznaja o tjelesnim pokretima (pa tako i onih povezanih sa šakom), koji su neizostavni dio svakodnevnog postojanja, ali i predmet inženjerskog interesa za oblikovanjem, optimiranjem i normiranjem radnih procesa.

U radu je potrebno:
1. objasniti značaj snimanja i analize pokreta za projektiranje radnih procesa i opisati trenutačni stupanj razvijenosti tehnologije
2. opisati postojeću podatkovnu rukavicu
3. predložiti načine unapređenja njene konstrukcije i proširenja primjene.

Zadatak zadan:
28. studenog 2019.

Datum predaje rada:
1. rok: 21. veljače 2020.
2. rok (izvanredni): 1. srpnja 2020.
3. rok: 17. rujna 2020.

Predviđeni datumi obrane:
1. rok: 24.2. – 28.2.2020.
2. rok (izvanredni): 3.7.2020.
3. rok: 21.9. - 25.9.2020.

Zadatak zadao:
Prof. dr.sc. Zoran Kunica

Predsjednik Povjerenstva:
Prof. dr. sc. Branko Bauer

IZJAVA

Izjavljujem da sam ovaj rad izradio samostalno koristeći znanja stečena tijekom studija i navedenu literaturu.

Zahvaljujem prof. dr.sc. Kunici na savjetima, razumijevanju i strpljenju i na pruženoj tehničkoj opremi.

Zahvaljujem roditeljima Sonji i Miroslavu i sestri Anji koji su me podržavali u ostvarivanju ovog rada.

U Zagrebu, 16. rujna 2020.

Marko Jurakić

SAŽETAK

Snimanjem i analizom pokreta ruke, stvaraju se osnove za poboljšanje i ubrzavanje izvođenja tjelesnih radnih procesa, bilo montaže ili nekog drugog procesa u proizvodnji, sportu, medicini ili plesnoj umjetnosti. U ovome je radu nadograđena postojeće podatkovna rukavica, već opremljena senzorima sila, mikročipom MPU6050, čime je omogućeno praćenje i snimanje pomaka pri pokretima ruke. Pomoću Arduino Mega 2560 i programskog okruženja IDE izveden je niz eksperimenata u kojima se na osnovi podataka o pomacima, izračunavao rad ostvaren pri pokretima ruke.

Ključne riječi: podatkovna rukavica, praćenje pokreta, pomak, MPU6050, Arduino

SUMMARY

Motion capture and analysis of body motions creates a base for improving human body movements executed during manual work processes, either assembly, either any other process in production, sport, medicine or art of dancing. In this work, the existing data glove with force sensors is improved, with microchip MPU6050. In that way, capturing, tracking and analysis of displacement during hand movements is made possible. By Arduino Mega 2560 and IDE programming enviorenment, number of experiments have been conducted, in which, on the bases of displacements, work encountered during hand movements has been calculated.

Key words: data glove, motion capture, displacement, MPU6050, Arduino

S A D R Ž A J

ZADATAK I
IZJAVA II
SAŽETAK III
SUMMARY IV
POPIS SLIKA VII
POPIS TABLICA IX
POPIS OZNAKA I MJERNIH JEDINICA FIZIKALNIH VELIČINA X

1. UVOD 1

2. PRAĆENJE POKRETA 2
2.1. Kratka povijest razvijanja tehnologije praćenja pokreta 2
2.2. Tehnologija praćenja pokreta 3
2.2.1. Mehaničko praćenje pokreta 3
2.2.2. Praćenje pokreta pomoću egzoskeletona 4
2.2.3. Grafička marioneta 5

3. PODATKOVNA RUKAVICA I NJENA ULOGA U DANAŠNJOJ INDUSTRIJI 6
3.1. Metode – Mjerenje vremena (MTM) 6
3.2. Sustav analize pokreta 6

4. POSTOJEĆA PODATKOVNA RUKAVICA 9
4.1. Opis postojeće podatkovne rukavice 9
4.2. Mogućnosti unaprjeđenja postojeće podatkovne rukavice 10

5. NADOGRADNJA POSTOJEĆE PODATKOVNE RUKAVICE 12
5.1. Mikročip MPU6050 12
5.2. Očitavanje signala i dobivanje stvarne akceleracije 13
5.2.1. Spajanje MPU6050 na Arduino Mega2560 13
5.2.2. Ispitivanje senzora 14
5.3. Računanje brzine i pomaka 18
5.4. Kalibracija očitanih vrijednosti 22
5.5. Računanje rada 23

6. EKSPERIMENTI 25
6.1. Eksperiment guranja čaše 25
6.1.1. Guranje čaše po glatkoj površini 26

6.1.2. Guranje čaše po hrapavoj površini 28
6.2. Guranje tegle s cvijećem 30
6.2.1 Guranje tegle po glatkoj površini 31
6.2.2. Guranje tegle po hrapavoj površini.....33
6.3. Guranje multimetra 35
6.3.1. Guranje multimetra po glatkoj površini 36
6.3.2. Guranje multimetra po hrapavoj površini 38
6.4. Zaključak eksperimenata 40

7. ZAKLJUČAK.....41

8. LITERATURA 43

POPIS SLIKA

Slika 1. Snimanje pokreta odijelima sa LED [7]....2
Slika 2. Glumac u odijelu za praćenje pokreta [6]....3
Slika 3. Calvertov mehanički egzoskeleton [9]....4
Slika 4. Rezultat praćenja pokreta grafičkom marionetom [6]....5
Slika 5. Grafički prikaz površine na kojoj kamere prate pokret [4]....7
Slika 6. Kontrolni volumen prikazan u 3D softveru [4]....7
Slika 7. Prikaz kontrolnog volumena na radnoj stanici [4]....8
Slika 8. Rukavica sa postavljenim senzorima....9
Slika 9. Materijali korišteni za izradu senzora: a) elektroda, b) sloj velostata, c) sloj spužvice, d) pamučna tkanina, e) pomoćni pribor....10
Slika 10. Mikročip MPU6050 [12]....13
Slika 11. Shema spajanja MPU6050 na Arduino mega2560....14
Slika 12. Rezultati pomicanja senzora....15
Slika 13. Filter koji aproksimira zadnjih 100 vrijednosti napisan u programskom jeziku....16
Slika 14. Očitane vrijednosti senzora aproksimirane filterom....17
Slika 15. Prikaz trapeznog pravila....18
Slika 16. Trapezno pravilo napisano u programskom kôdu....18
Slika 17. Računanje brzine i puta napisano u programskom jeziku....19
Slika 18. Graf akceleracije (plavo), brzine (crveno) i pomaka (zeleno)....19
Slika 19. Računanje pomaka u sve tri osi....20
Slika 20. Računanje pomaka u sve tri osi....21
Slika 21. Prostorna dijagonala kvadra....21
Slika 22. Računanje ukupnog puta....22
Slika 23. Eksperimentalno mjerenje pomaka pri kalibraciji....23
Slika 24. Senzor MPU6050 na podatkovnoj rukavici....24
Slika 25. Računanje rada....24
Slika 26. Čaša i njezina masa....25
Slika 27. Guranje čaše po glatkoj površini....26
Slika 28. Prikaz rezultata guranja čaše po glatkoj površini....27
Slika 29. Guranje čaše po hrapavoj površini....28
Slika 30. Rezultati guranja čaše po hrapavoj površini....29

Slika 31. Tegla i njezina masa.....30
Slika 32. Prikaz guranja tegle 31
Slika 33. Rezultati guranja tegle po glatkoj površini 32
Slika 34. Guranje tegle po hrapavoj površini.....33
Slika 35. Rezlutati guranja tegle po hrapavoj površini.....34
Slika 36. Multimetar i mjerenje njegove mase 35
Slika 37. Guranje multimetra po glatkoj površini 36
Slika 38. Rezultati guranja multimetra po glatkoj površini 37
Slika 39. Guranje multimetra po hrapavoj površini 38
Slika 40. Rezultati guranja multimetra po hrapavoj površini 39

POPIS TABLICA

Tablica 1. Konstante kojima se dijeli signal ovisno o rasponu mjerenja [2] 12
Tablica 2. Rezultati mjerenja udaljenosti 23

POPIS OZNAKA I MJERNIH JEDINICA FIZIKALNIH VELIČINA

Oznaka	**Mjerna jedinica**	**Naziv**
D	m	duljina
eng.		engleski
F	N	sila
s	m	put
W	J	rad

1. UVOD

Digitalizacijom i automatizacijom proizvodnih postrojenja pokušava se postići što veća efikasnost i produktivnost strojeva koji djeluju kao samostalne ćelije koje mogu funkcionirati skoro samostalno, bez čovjeka. Međutim, u mnogim granama industrije je još uvijek potreban i isplativ ručni rad (naprimjer u montaži). Tako, u želji za što većom efikasnošću, i ručni su procesi predmet razmatranja, i to posebno stoga što se time ručni radni procesi analiziraju, poboljšavaju te u narednoj fazi olakšano evoluiraju u automatske. To je i tema ovog završnog rada, naime, daljnji razvoj i iskušavanje postojeće podatkovne rukavice koja treba poslužiti za praćenje i analizu pokreta ruke čovjeka, kao sredstva za poboljšanje izvedbe ručnih procesa i radnih mjesta, koje vodi prema boljem razumijevanju prirode pokreta i skraćenju vremena procesa. U skladu s tim, u ovome će se radu prikazati i neke tehnologije za praćenje pokreta i njihov trenutni stupanj razvijenosti.

2. PRAĆENJE POKRETA

2.1. Kratka povijest razvijanja tehnologije praćenja pokreta

Praćenje pokreta (engl. *motion control*) je prisutno u širokom spektru područja, od tehničkih područja i medicine do filmske industrije i računalnih igara. Praćenje pokreta je, prema Scottu Dyeru, Jeffu Martinu i Johnu Zulaufu [5], mjerenje udaljenosti i orijentacije nekog predmeta u fizičkom prostoru, te interpretiranje tih informacija na način na koji će ih računalo moći razumjeti i iskoristiti.

U ranim danima praćenja pokreta u filmskoj industriji se koristilo rotoskopiranje, koje je izumio Max Fleischer 1919. godine. Rotoskopiranje se koristilo za animaciju u filmovima na način da bi se snimio glumac kamerom te bi animator, sliku po sliku crtao preko lika preko glumca.

80-ih godina prošlog stoljeća došlo je do porasta istraživanja ljudskihg pokreta. Tom Calvert je koristio potenciometar kako bi mjerio fleksiju i ekstenziju koljena [9]. To je bio jedan od prvih pokušaja praćenja ljudskog pokreta. Nedugo nakon toga, znanstvenici na MIT-u su razvili odijelo prekriveno LE diodama i snimali pokrete glumca optičkim snimačem pokreta i pomoću dvije kamere.



Slika 1. Snimanje pokreta odijelima sa LED [7]

2.2. Tehnologija praćenja pokreta

2.2.1. Mehaničko praćenje pokreta

Mehaničko praćenje pokreta je nastalo 60-ih godina prošlog stoljeća, a izumio ga je Lee Harrison. Harrison je pomoću analognih strujnih krugova i katodne cijevi uspio prikazati animirane figure. Kasnije je osnovao tim koji je razvio „Bone generator“ ili „generator kostura“. Generator kostura je omogućio kreiranje 3D animacije bez korištenja softvera za poligonalno modeliranje ili CPU-a. Realnija animacija je postignuta dodavanjem „kože“ na kostur, odnosno mreže koja generira rotacijske vektore koji bi obuhvatili kosti. Kako je izgledao takav animirani lik vidi se na (Slika 2.).

Ova tehnologija nije postigla komercijalan uspjeh, ali postoje tehnologije inspirirane generatorom kostiju koje su se koristile u filmovima (naprimjer *Star Wars*).



Slika 2. Glumac u odijelu za praćenje pokreta [6]

2.2.2. Praćenje pokreta pomoću egzoskeletona

Začetnik ove tehnologije praćenja pokreta je već spomenuti Tom Calvert. Njegovo istraživanje se odnosilo na kliničko promatranje abnormalnosti u kretanju. Calvert je pratio fleksiju pomoću potenciometra i mogao je dobiti podatke o promjeni kuta fleksije koljena u vremenu.

Ova tehnologija se koristi i danas, ali je razlika u tome što se potenciometri ne nalaze na egzoskeletonu nego su manjih dimenzija i ugrađeni su u odijela, a prednost joj je niska cijena s obzirom na ostale kompliciranije i skuplje tehnologije.



Slika 3. Calvertov mehanički egzoskeleton [9]

2.2.3. Grafička marioneta

U isto vrijeme kada je razvijen Calvertov mehanički egzoskeleton, na MIT-u je razvijen prvi optički snimač ljudskog pokreta. Godine 1983. su Delle Rae Maxwell i Carol Ginsberg predstavili grafičku marionetu [6]. Grafička marioneta se sastojala od odijela u koje su ušivena infracrvena LED svjetla na zglobove i druge karakteristične točke na tijelu. Uz odijelo, potpuno praćenje pokreta je zahtijevalo još dvije kamere koje su sadržavale dvoosne lateralne diode koje detektiraju poziciju točke svjetla na površini odijela (Slika 4.).

Rezultat je figura nalik na „*stick mana*“. Mane ove tehnologije su sporo obrađivanje podataka radi dobivanja slike odnosno animacije i velika cijena opreme.



Slika 4. Rezultat praćenja pokreta grafičkom marionetom [6]

3. PODATKOVNA RUKAVICA I NJENA ULOGA U DANAŠNJOJ INDUSTRIJI

Proizvodnja je je doživjela mnogo promjena u povijesti, od vremena kada bi jedan čovjek izrađivao cijeli proizvod, do prve industrijske revolucije gdje su uvedeni strojevi i čovjek više nije igrao glavnu ulogu u proizvodnji, preko pokretne trake koju je izumio Ransom E. Old i usavršio Henry Ford, do današnje automatizacije i digitalizacije cijelog procesa proizvodnje.

3.1. Metode – Mjerenje vremena (MTM)

U svemu tom navedenom vremenu, uvijek se posebna pažnja posvećivala što točnijem određivanju vremena izvedbe procesa. U sklopu toga, razvijani su tzv. sustavi unaprijed određenih vremena, od kojih je jedan od najpoznatnijh MTM (eng. *Methods-Time Measuement*, što se prevodi kao: Metode – Mjerenje vremena). Metodom MTM se kompleksna ručna operacije dijeli na jednostavne (osnovne) pokrete kojima je unaprijed dodijeljena normirana vremenska vrijednost, čiji je iznos određen, osim vrstom pokreta, i uvjetima pod kojima se pokret vrši. [8]

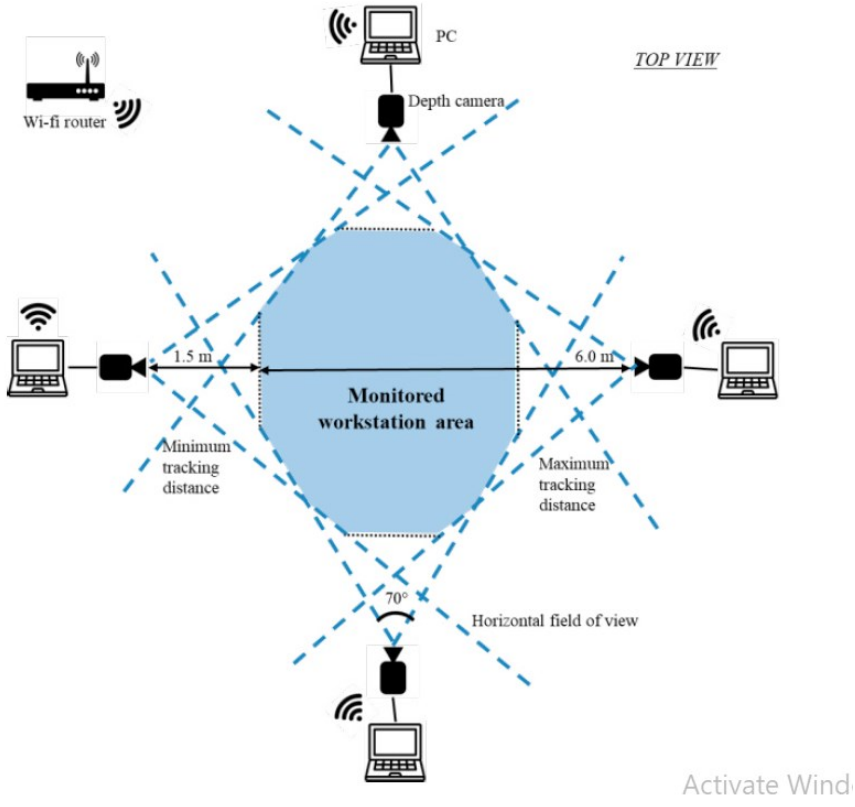
MTM se i danas rasprostranjeno koristi, konstantno se unaprjeđuje, i ima više inačica.

3.2. Sustav analize pokreta

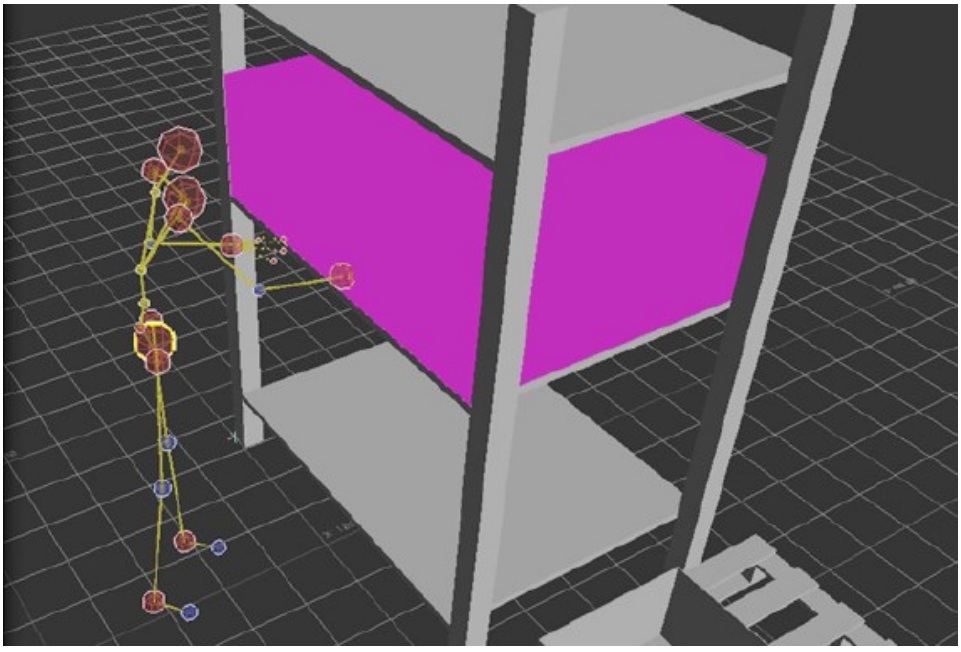
Još jedan sustav koji se koristi za praćenje i analizu pokreta čovjeka na njegovom radnom mjestu je tzv. Sustav analize pokreta (eng. *Motion Analysis System*) [4]. Sustav analize pokreta se bazira na praćenju cijelog tijela čovjeka i mjeri brzine njegovih kretnji. Ovaj sustav ne koristi markere ili odijela za praćenje, odnosno radnik ne mora nositi nikakvu dodatnu opremu na sebi koja bi ga ometala u radu.

Četiri kamere za mjerenje dubine odnosno udaljenosti se postavljaju i kalibriraju iznad radne stanice (Slika 5.) i prate operatora u procesu montaže. MAS, skraćeno od *Motion Analysis*

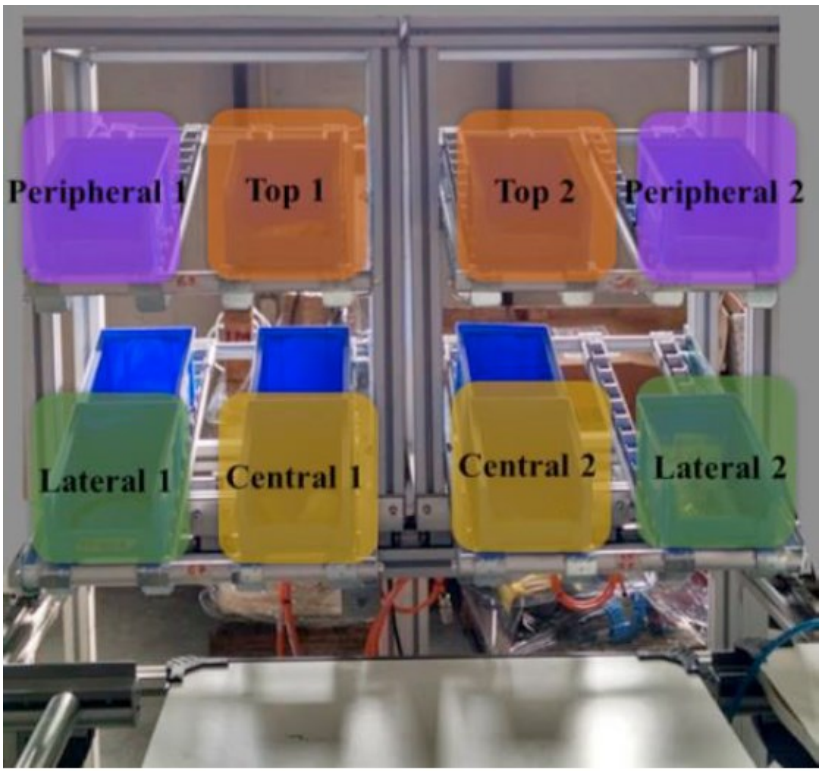
System, uvodi princip kontrolnog volumena, eng. *Control Volume.* Kontrolni volumen predstavlja geometrijsko tijelo u 3D prostoru (Slika 6.) u radnoj stanica i koristi se za obilježavanje prostora u kojem se nalaze dijelovi predmeta ili naprimjer kutiju s alatom (Slika 7.).



Slika 5. Grafički prikaz površine na kojoj kamere prate pokret [4]



Slika 6. Kontrolni volumen prikazan u 3D softveru [4]



Slika 7. Prikaz kontrolnog volumena na radnoj stanici [4]

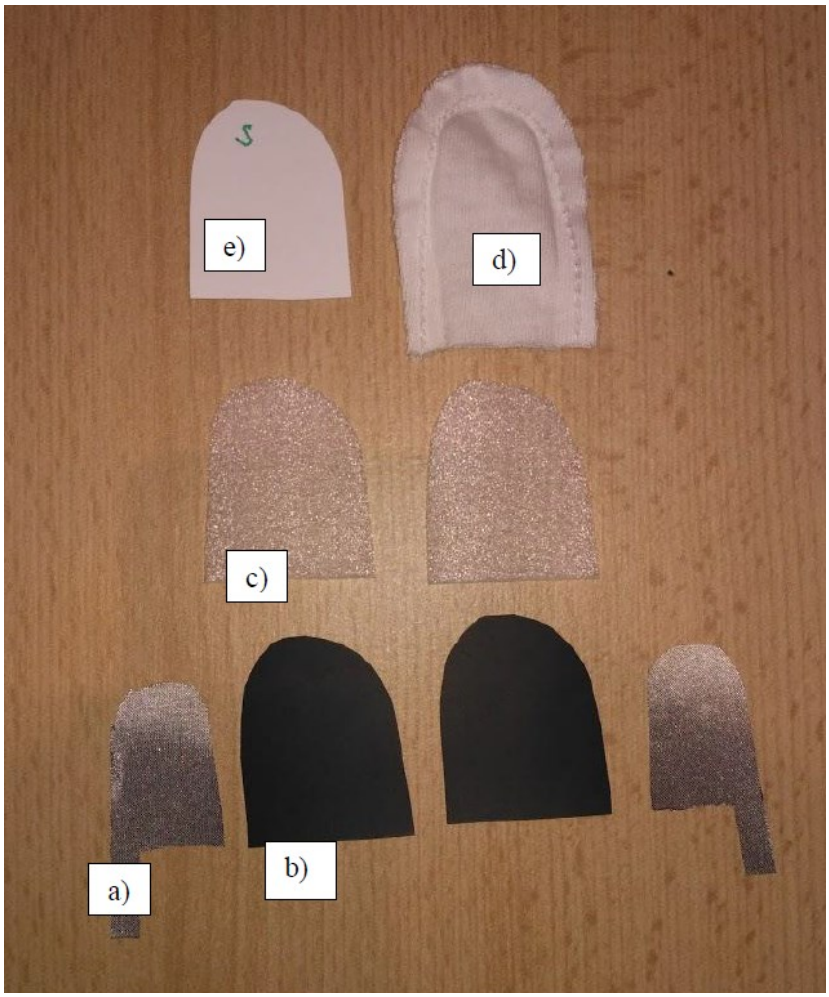
4. POSTOJEĆA PODATKOVNA RUKAVICA

4.1. Opis postojeće podatkovne rukavice

Postojeća podatkovna rukavica (Slika 8.) razvijena je na Fakultetu strojarstva i brodogradnje Sveučilišta u Zagrebu [10]. Rukavica radi na temelju promjene otpora velostata. Velostat je materijal koji mijenja otpor sa promjenom aktivne sile koja djeluje na njega. Senzori koji se nalaze na jagodicama se izrađuju od velostata, provodljive tkanine, elektrode i spužvice (Slika 9.).



Slika 8. Rukavica sa postavljenim senzorima



Slika 9. Materijali korišteni za izradu senzora: a) elektroda, b) sloj velostata, c) sloj spužvice, d) pamučna tkanina, e) pomoćni pribor

Očitavanje senzora se obavlja pomoću pločice Arduino koja sadrži mikrokontroler, a za programiranje i interpretaciju signala se koristi Arduinov službeni softver IDE (*Integrated Development Environment*).

Programski kôd za očitavanje signala i pretvorbu informacija u realne vrijednosti je detaljno opisan u diplomskom radu [10].

4.2. Mogućnosti unaprjeđenja postojeće podatkovne rukavice

Sa verzijom podatkovne rukavice koju je razvio Štivić [10] se može mjeriti aktivna sila koja djeluje na vrške prstiju i time se može odrediti silu koja se pojavljuje pri rukovanju nekim

predmetom. Pomoću dobivenih informacija može se odrediti i potrebnu silu pritiska, upotrebljivu naprimjer za računalom upravljanog robotskog manipulatora pri hvatanju predmeta. To je korisno ako se želi automatizirati neki proces i zamijeniti ručni rad robotskim radom, ali time se ipak ne dobiju sve potrebne informacije za potpunu automatizaciju. Cilj ovog rada je, pomoću dodatnog senzora, dobiti podatke o pomaku ruke odnosno rukavice kako bi se mogao izračunati rad ostvaren pokretom.

5. NADOGRADNJA POSTOJEĆE PODATKOVNE RUKAVICE

5.1. Mikročip MPU6050

Kako bi se dobio pomak, koristit će se mikročip MPU6050 koji sadrži akcelerometar i giroskop. MPU6050 omogućuje praćenje akceleracije u *X*, *Y* i *Z* osi, te rotacije oko te tri osi.

Mogući rasponi akceleracija i kutnih brzina su, kako slijedi:

Akceleracije:

- +/-2g
- +/-4g
- +/-8g
- +/-16g

Kutna brzina (˚/s):

- +/-250
- +/-500
- +/-1000
- +/-2000.

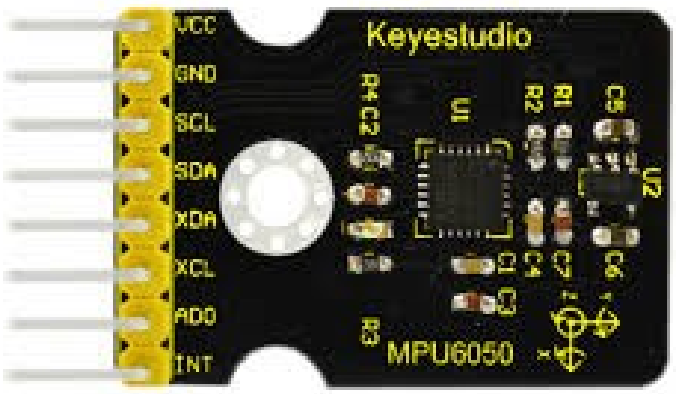
Senzor daje „sirove“ vrijednosti i potrebno ih je podijeliti sa brojem koji je zadao proizvođač kako bi se dobilo vrijednost u jedinicama sile teže, odnosno g-u (Tablica 1.).

Tablica 1. Konstante kojima se dijeli signal ovisno o rasponu mjerenja [2]

0	±2*g*	16384 LSB/*g*
1	±4*g*	8192 LSB/*g*
2	±8*g*	4096 LSB/*g*
3	±16*g*	2048 LSB/*g*

U ovom radu je korišten raspon od +/-2g, pa se očitane vrijednosti trebaju podijeliti sa 16384, te pomnožiti sa 9,81 kako bi se dobilo akceleraciju u m/s^2.

Akceleracija je druga derivacija pomaka, pa ako se akceleracija integrira dobiva se brzina, a ako se integrira dvaput, dobije se pomak.



Slika 10. Mikročip MPU6050 [12]

5.2. Očitavanje signala i dobivanje stvarne akceleracije

5.2.1. Spajanje MPU6050 na Arduino Mega2560

Senzor MPU6050 će se spojiti na Arduino Mega2560 [1]. Na samom čipu se nalazi osam nožica ali za ovaj projekt je potrebno spojiti četiri nožice:

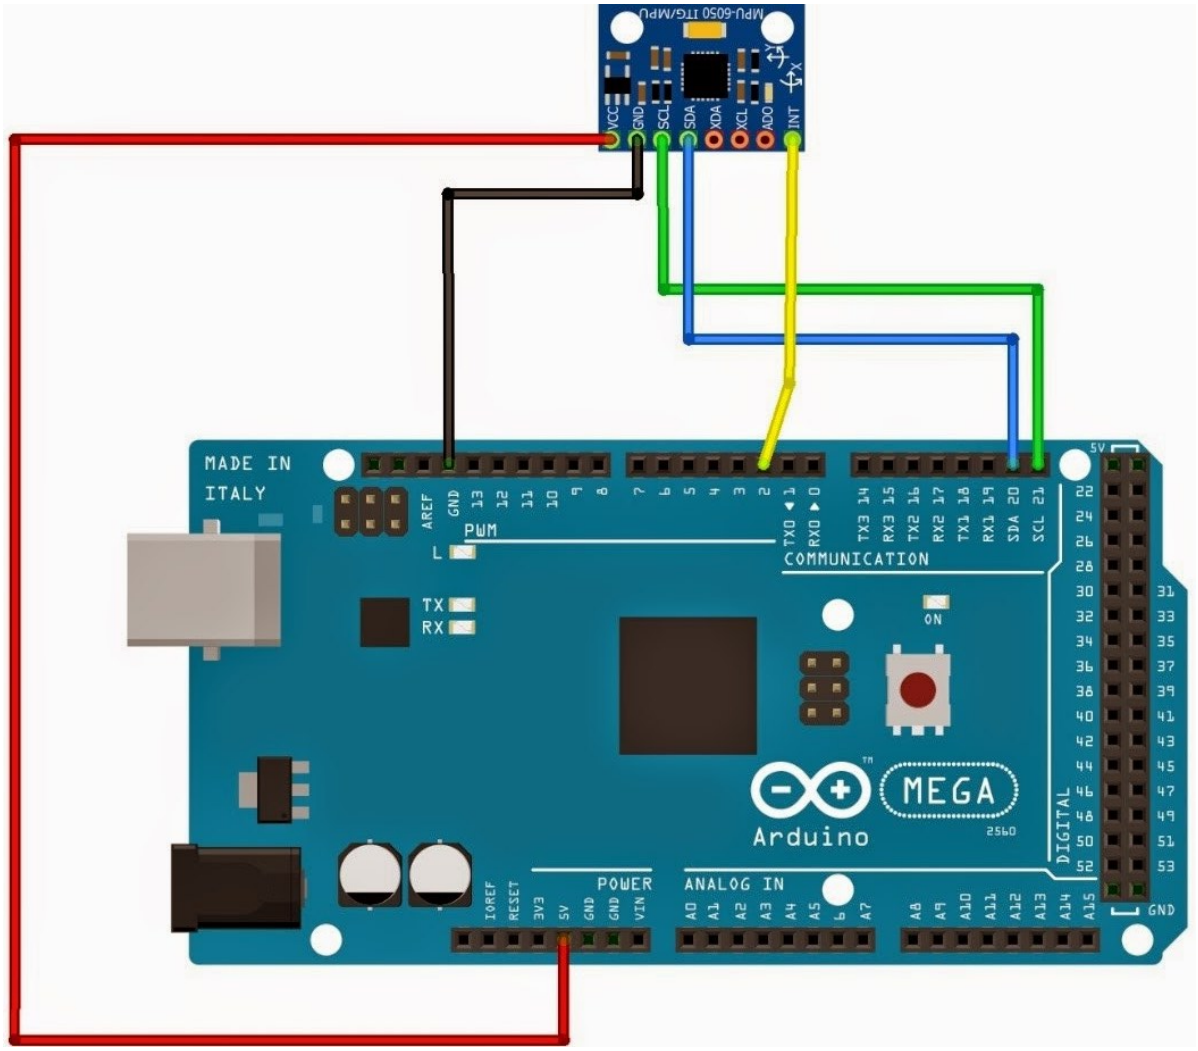
V_{cc} – 5 ili 3,3 V

GND – Nula

SCL i SDA – izlazi sa kojih se očitavaju vrijednosti senzora.

Izlaze SCL i SDA je potrebno spojiti na ulaze Arduina koji su predviđeni iza komunikaciju sa I^2C senzorima, a to su pinovi 20 i 21 na pločici Arduinu Mega2560 i pinovi 4 i 5 na pločici Arduino Uno.

Slika 11. prikazuje shemu spajanja.

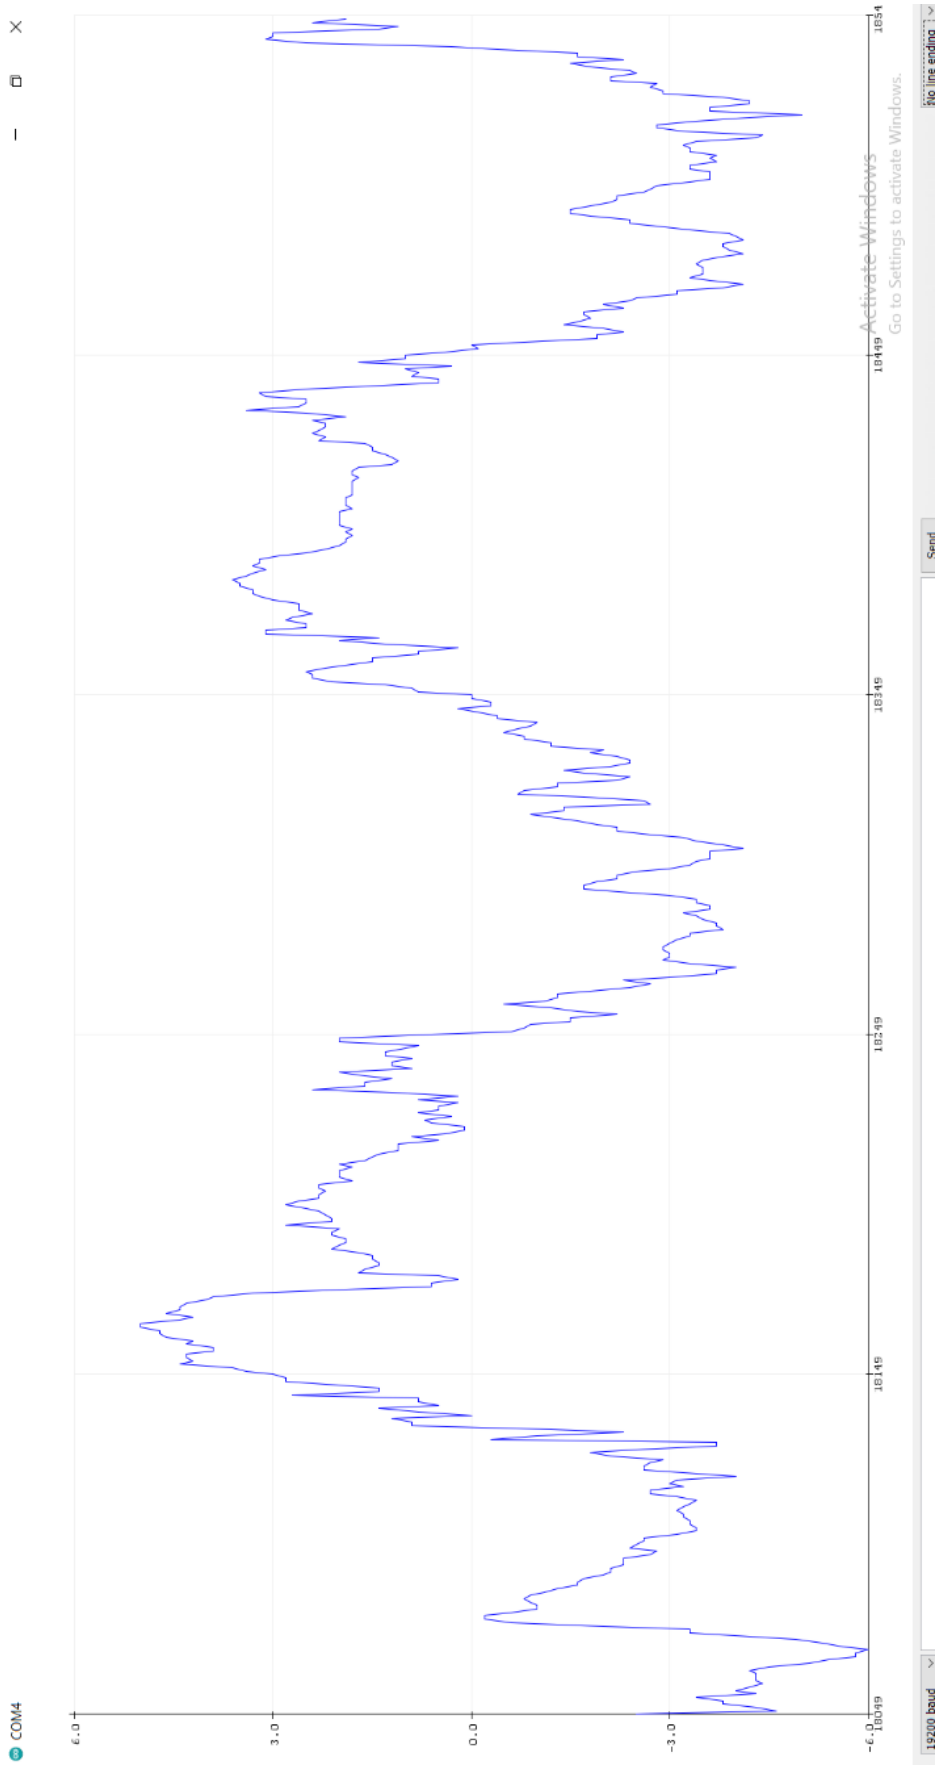


Slika 11. Shema spajanja MPU6050 na Arduino mega2560

5.2.2. Ispitivanje senzora

Kao eksperiment će se senzor pomicati naprijed-nazad po svojoj *x* osi te će se rezultati prikazati u *serial plotteru* [3] u obliku grafa.

Na grafu na slici 12. se vidi da su prisutne oscilacije. Uvest će se filter koji će aproksimirati vrijednost senzora kako bi se graf „izgladio“. U glavnu petlju programskog koda će se ubaciti *while* petlja koja će izračunati aritmetičku sredinu zadnjih 100 mjerenja (Slika 13.).



Slika 12. Rezultati pomicanja senzora

```
int x=0;
ax=0;
while (x<100){

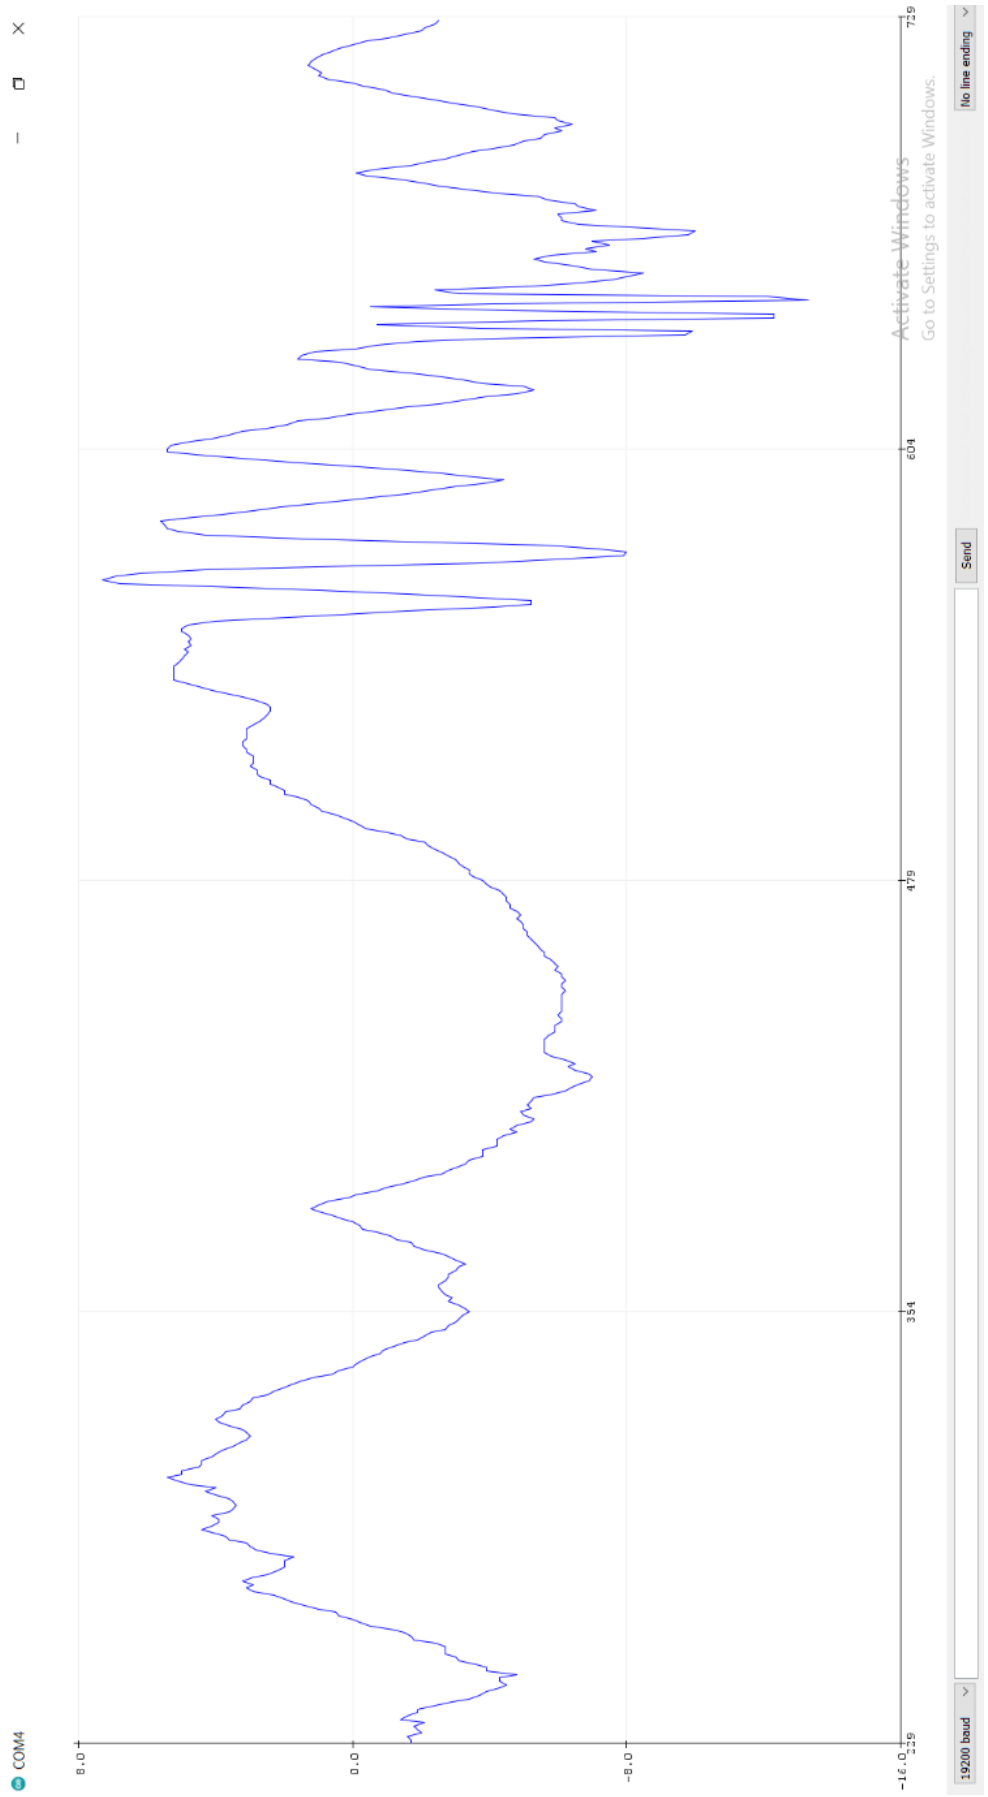
Wire.beginTransmission(MPU);
Wire.write(0x3B); // Start with register 0x3B (ACCEL_XOUT_H)
Wire.endTransmission(false);
Wire.requestFrom(MPU, 6, true);
realx =(Wire.read() << 8 | Wire.read()) / 16384.0 ; // X-axis value
ax = ax + realx;
x++;
```

Slika 13. Filter koji aproksimira zadnjih 100 vrijednosti napisan u programskom jeziku

Ponovno se provodi eksperiment te se dobiju rezultati vidljivi na slici 14.

Na slici 14. vidi se da su pri sličnim pokretima, oscilacije mnogo manje. Mana ovog filtera je što graf kasni za određenu vremensku vrijednost za stvarnom akceleracijom ali u ovom eksperimentu se rezultati računaju nakon obavljene operacije, a ne tijekom tako da nam ovaj problem nije jako bitan.

Sada kada su rezultati točniji, mogu se koristiti za daljnje računanje brzine i pomaka.

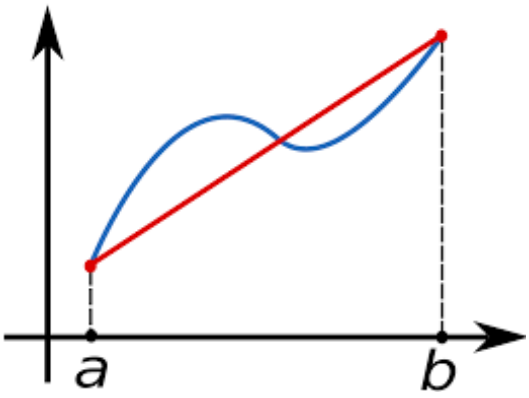


Slika 14. Očitane vrijednosti senzora aproksimirane filterom

5.3. Računanje brzine i pomaka

Za računanje prvog i drugog integrala akceleracije, korišteno je trapezno pravilo (Slika 15.).

Trapezno pravilo se temelji na činjenici da je površina integrala neke funkcije, njena vrijednost u nekom vremenskom intervalu. Naprimjer, površina ispod funkcije akceleracije, u vremenu od 10 ms, jest iznos brzine nakon 10 ms.



Slika 15. Prikaz trapeznog pravila

Prvi integral funkcije akceleracije, odnosno brzina jest:

$$\vec{a} = \frac{\vec{v}}{dt}. \quad (1)$$

Drugi integral funkcije akceleracije, odnosno put jest:

$$\vec{a} = \frac{\vec{s}}{d^2t}\ . \quad (2)$$

Trapezno pravilo napisano u programskom kôdu je prikazano na slici 16.

```
speedx2 = speedx2 + ((0.5*da+acx1)*elapsedTime)/1000 ;
int b = speedx2*10;
speedx2=(float(b)/10);
if (abs(speedx2) > 0){
putx = putx + abs(speedx)+0.5*abs(speedx2-speedx);
```

Slika 16. Trapezno pravilo napisano u programskom kôdu

```
AccX=ax/100;
acx2=(AccX-AccErrorX)*9.81;
int a = acx2*10;
speedx=speedx2;
acx2=( float(a))/10;
da = (acx2-acx1);

previousTime = currentTime;        // Previous time is stored before the actual time read
currentTime = millis();            // Current time actual time read
elapsedTime = (currentTime - previousTime);

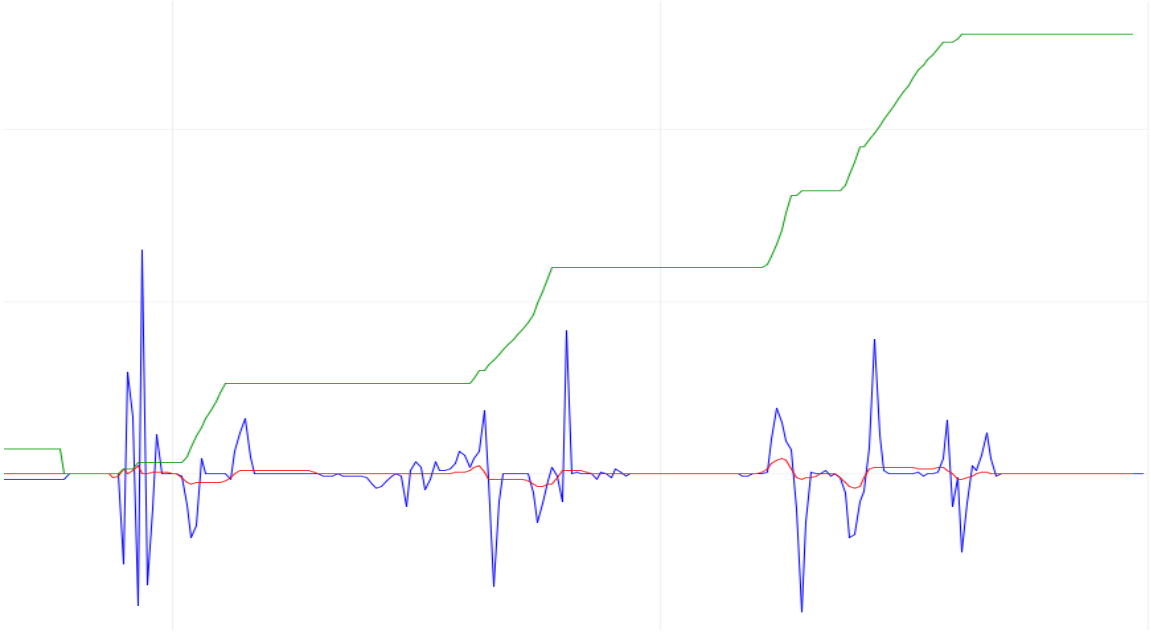

speedx2 = speedx2 + ((0.5*da+acx1)*elapsedTime)/1000 ;
int b = speedx2*10;
speedx2=(float(b)/10);
if (abs(speedx2) > 0.3){
putx = putx + abs(speedx)+0.5*abs(speedx2-speedx);
```

Slika 17. Računanje brzine i puta napisano u programskom jeziku

Na Slika 17. je prikazan kod za računanje brzine i puta.

Na Slika 18. se vidi graf koji prikazuje promjenu akceleracije te promjenu brzine i pomaka u smjeru osi *x*.

Na grafu se može vidjeti da se pomak ne mijenja za brzine manje od 0,2 m/s. Razlog tomu je oscilacija u očitanju brzine koja iznosi malo manje od 0,2 m/s. Kako bi se izbjegao rast puta dok je stvarna brzina nula. Stavljeno je ograničenje od 0,2 m/s.



Slika 18. Graf akceleracije (plavo), brzine (crveno) i pomaka (zeleno)

Za dobivanje brzine i pomaka u smjerovima *Y* i *Z*, potrebno je kôd sa slika 17. i 18. kopirati dva puta i zamijeniti varijable sa oznakom *X* u varijable za osi *Y* i *Z*. Kôd je prikazan na slikama 20. i 21.

```
AccX=ax/100;
AccX=ay/100;
AccX=az/100;
acx2=(AccX-AccErrorX)*9.81;
acy2=(AccY-AccErrorY)*9.81;
acz2=(AccZ-AccErrorZ)*9.81;
int a = acx2*10;
int d = acy2*10;
int c = acz2*10;

speedx=speedx2;
speedy=speedy2;
speedz=speedz2;
acx2=( float(a))/10;
acy2=( float(d))/10;
acz2=( float(c))/10;
da = (acx2-acx1);
day = (acy2-acy1);
daz = (acz2-acz1);

previousTime = currentTime;        // Previous time is stored before the actual time read
currentTime = millis();            // Current time actual time read
elapsedTime = (currentTime - previousTime);


speedx2 = speedx2 + ((0.5*da+acx1)*elapsedTime)/1000 ;
speedy2 = speedy2 + ((0.5*day+acy1)*elapsedTime)/1000 ;
speedz2 = speedz2 + ((0.5*daz+acz1)*elapsedTime)/1000 ;
int b = speedx2*10;
int e = speedy2*10;
int f = speedz2*10;
speedx2=(float(b)/10);
speedy2=(float(e)/10);
speedz2=(float(f)/10);
```

Slika 19. Računanje pomaka u sve tri osi

```
speedy=speedy2;
speedz=speedz2;
acx2=( float(a))/10;
acy2=( float(d))/10;
acz2=( float(c))/10;
da = (acx2-acx1);
day = (acy2-acy1);
daz = (acz2-acz1);

previousTime = currentTime;        // Previous time is stored before the actual time read
currentTime = millis();            // Current time actual time read
elapsedTime = (currentTime - previousTime);

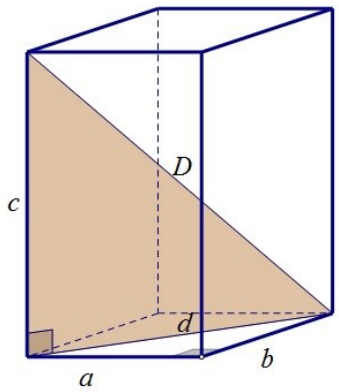

speedx2 = speedx2 + ((0.5*da+acx1)*elapsedTime)/1000 ;
speedy2 = speedy2 + ((0.5*day+acy1)*elapsedTime)/1000 ;
speedz2 = speedz2 + ((0.5*daz+acz1)*elapsedTime)/1000 ;
int b = speedx2*10;
int e = speedy2*10;
int f = speedz2*10;
speedx2=(float(b)/10);
speedy2=(float(e)/10);
speedz2=(float(f)/10);
if (abs(speedx2) > 0){
putx = putx + abs(speedx)+0.5*abs(speedx2-speedx);
}
 if (abs(speedy2) > 0){
puty = puty + abs(speedy)+0.5*abs(speedy2-speedy);

}
 if (abs(speedz2) > 0){
putz = putz + abs(speedz)+0.5*abs(speedz2-speedz);

}
```

Slika 20. Računanje pomaka u sve tri osi

Pomaci su vektori koji u određenoj jedinici vremena, kada se zbroje, tvore kvadar. Ako je promatrana jedinica vremena vrlo mala, pretpostavit će se da je krivulja pomaka jednaka pravcu, odnosno u ovom slučaju, prostornoj dijagonali.



Slika 21. Prostorna dijagonala kvadra

Formula za računanje duljine prostorne dijagonale kvadra jest(3):

$$D = \sqrt{a^2 + b^2 + c^2} \tag{3}$$

gdje su:

D – duljina dijagonale, mm

a – pomak u osi *X*, mm

b – pomak u *Y* osi, mm

c – pomak u *Z* osi, mm.

U programskom jeziku će se nakon svakog ciklusa, koji traje nekoliko desetinki milisekunde, izračunati ukupan pomak ruke na ovaj način.

Programski kôd je prikazan na slici 23.

```
dputx=putx1-putx2;
dputy=puty1-puty2;
dputz=putz1-putz2;

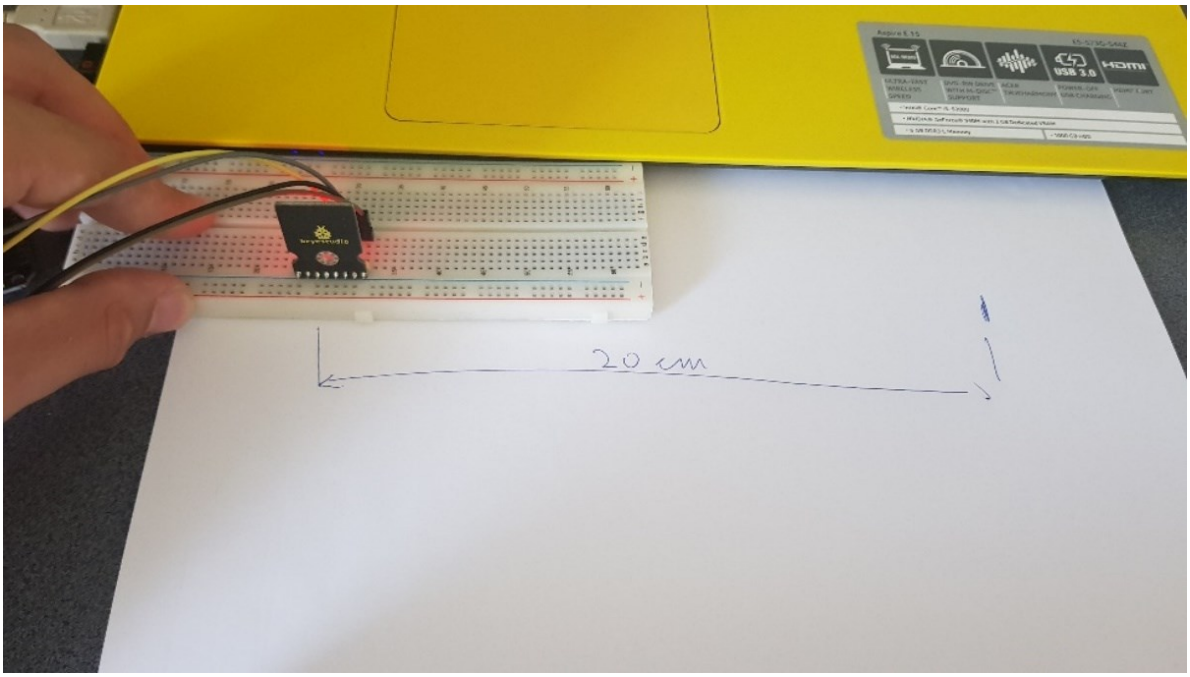
dput=sqrt(sq(dputx)+sq(dputy)+sq(dputz));
pomak=pomak+dput;
```

Slika 22. Računanje ukupnog puta

5.4. Kalibracija očitanih vrijednosti

Kako bi se stvarni pređeni put pridružio vrijednosti puta u kôdu, akcelerometar će se pomicati za određenu udaljenost, te će se izračunati aritmetička sredina izmjerenih vrijednosti.

Za što točnije rezultate, mjerena je udaljenost samo u smjeru osi *X*.



Slika 23. Eksperimentalno mjerenje pomaka pri kalibraciji

Za eksperiment je uzeta udaljenost od 20 cm i izvedeno je šest mjerenja. Rezultati su prikazani u tablici 2.

Tablica 2. Rezultati mjerenja udaljenosti

Mjerenje broj	1	2	3	4	5	6	Aritmetička sredina
Izmjerena vrijednost	1,95	2,15	2,00	2,00	2,15	2,1	2,05

Rezultati ovog eksperimenta pokazuju da senzor očitava vrijednost od 0,102 za svaki prijeđeni centimetar u stvarnosti.

5.5. Računanje rada

Jednadžba rada jest:

$$W = F * s \tag{4}$$

pri čemu su:

W – rad, J

F – sila, N

s – pomak, mm.

Sila će se mjeriti postojećom podatkovnom rukavicom na koju će se zalijepiti mikročip MPU6050 (Slika 24.).



Slika 24. Senzor MPU6050 na podatkovnoj rukavici

Programski kôd će pratiti pomak i silu te njihovim umnoškom izračunati rad. Zbog oscilacija senzora sile i akcelerometra, rezultat neće biti u potpunosti točan i kontinuiran.

```
float sila=analogRead(A0);
//Serial.println(sila);
float rad= putx*sila/50;
Serial.println(rad);
```

Slika 25. Računanje rada

6. EKSPERIMENTI

Obavit će se šest eksperimenata koristeći tri različita predmeta i dvije različite površine. Mjerit će se podaci kako bi se mogli usporediti i vidjeti hoće li biti razlike u očitavanju. Pokusi su obavljani višekratno, i ovdje su u nastavku redom prikazani oni sa smislenim i stabilnim očitanjima. Duljina pomaka je oko 30 cm.

6.1. Eksperiment guranja čaše

U prvom eksperimentu će se gurati čaša (Slika 26.) po različitim površinama. Masa čaše je 461 grama.



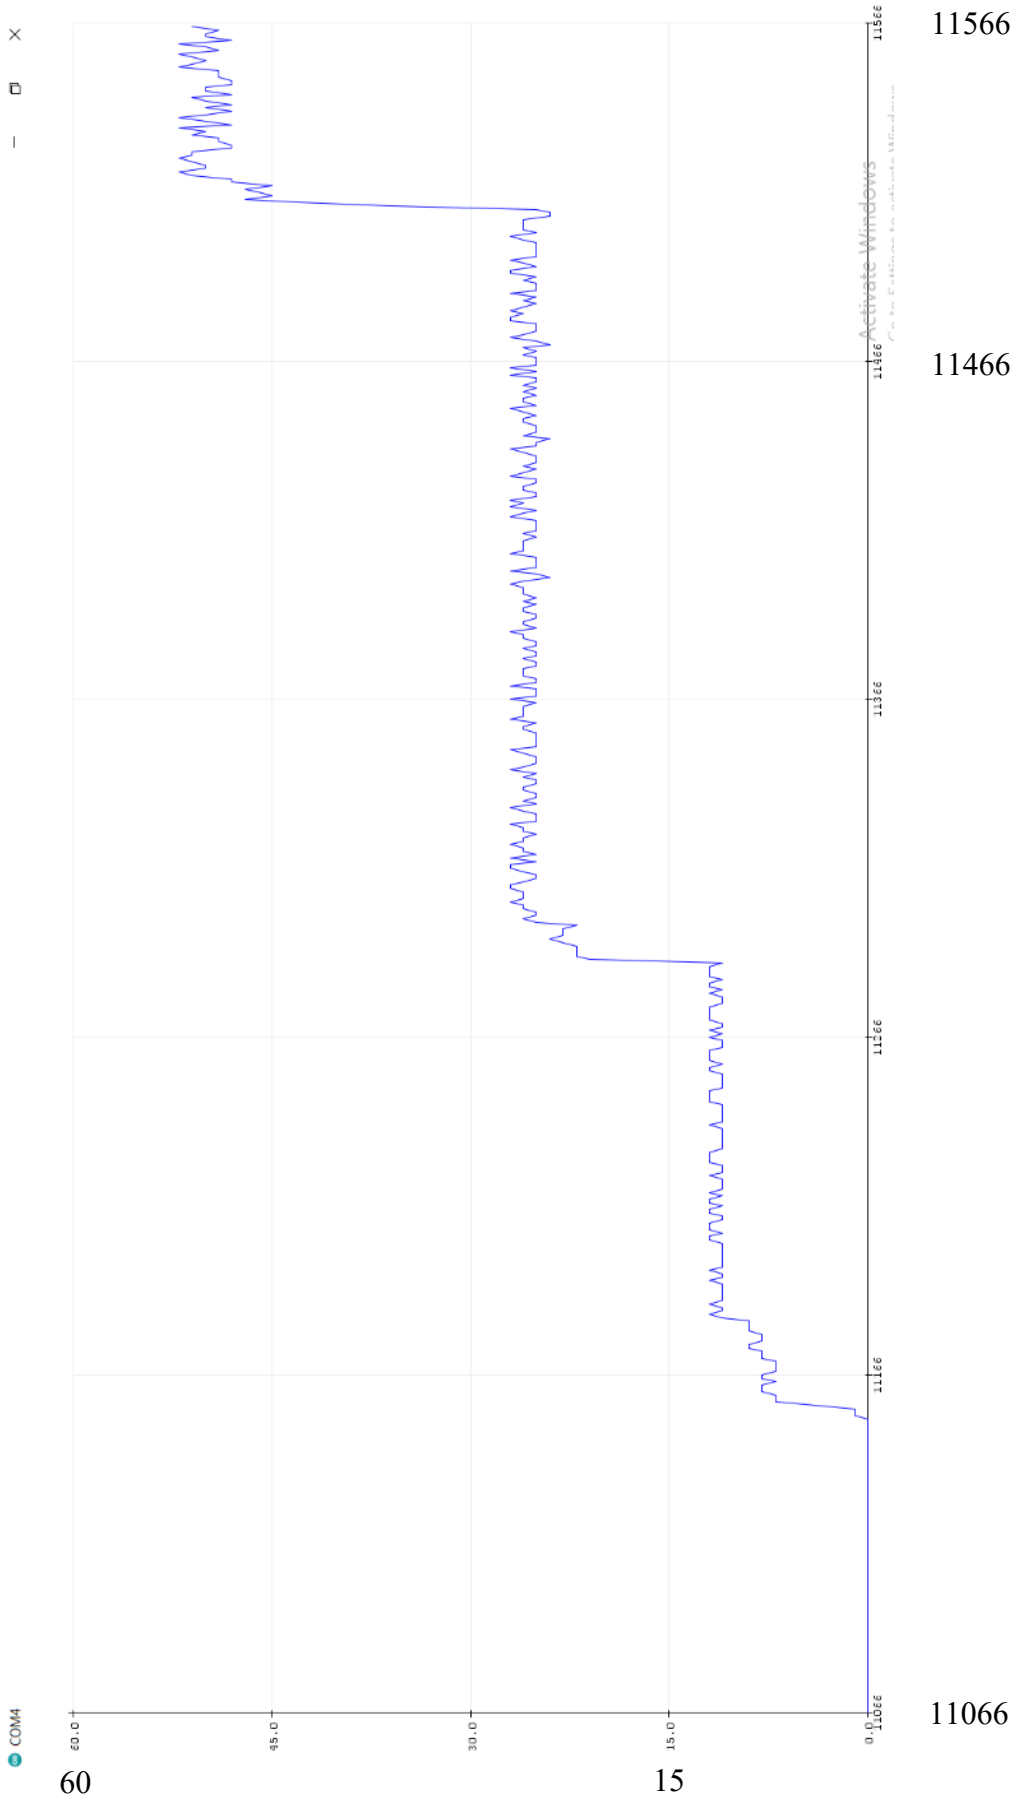
Slika 26. Čaša i njezina masa

6.1.1. Guranje čaše po glatkoj površini



Slika 27. Guranje čaše po glatkoj površini

Rezultati su prikazani na grafu očitanom *serial plotter*om (Slika 28.). Na apscisi je vrijeme u milisekundama, a na ordinati rad u Joulima.



Slika 28. Prikaz rezultata guranja čaše po glatkoj površini

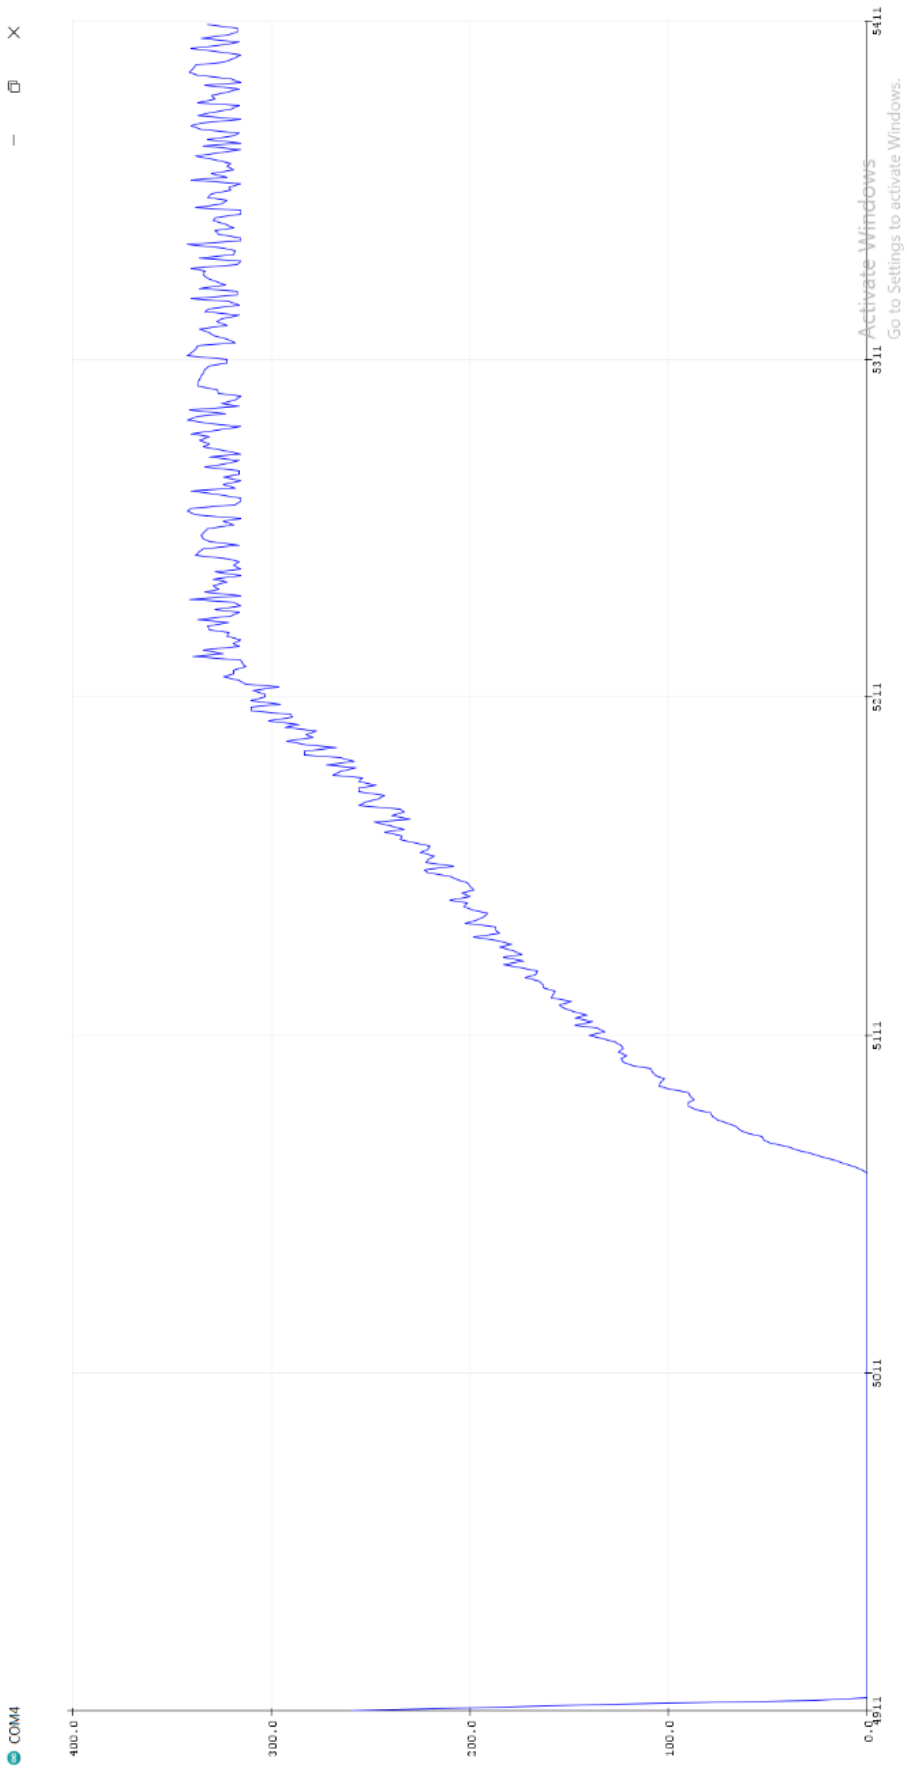
6.1.2. Guranje čaše po hrapavoj površini

Drugi dio ovog eksperimenta je guranje čaše jednake mase po hrapavoj površini. Kao hrapavu površinu će se koristiti ručnik.



Slika 29. Guranje čaše po hrapavoj površini

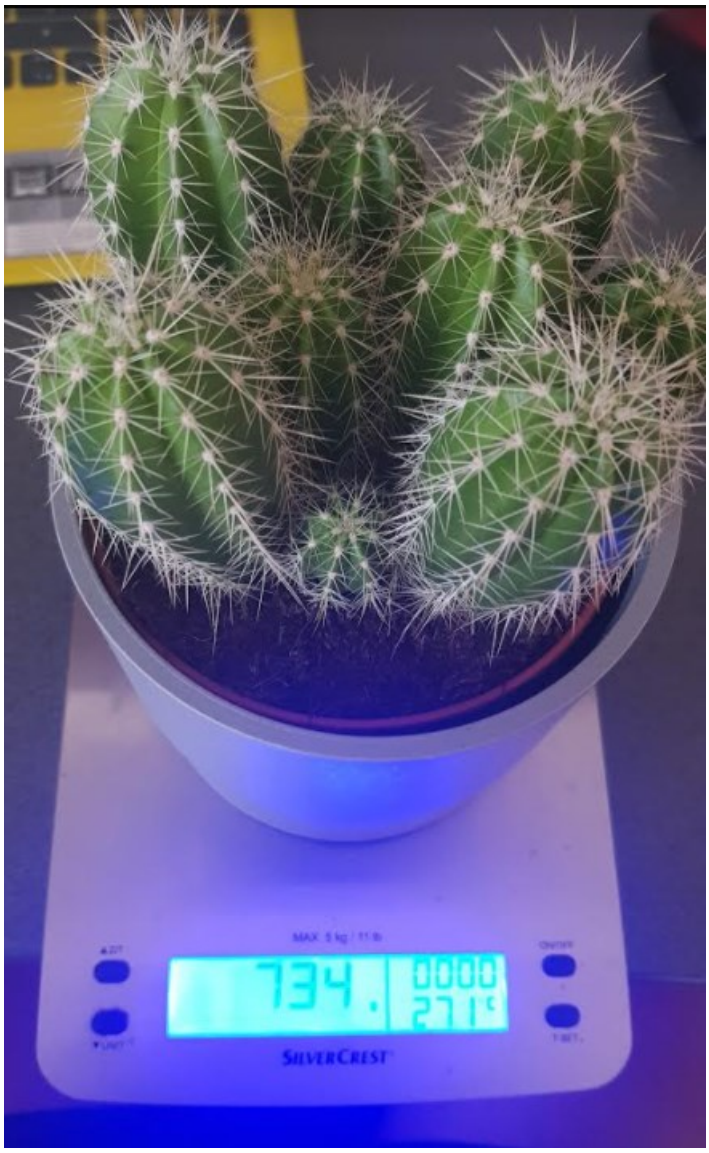
Rezultati su prikazani na slici 30. Iz grafa se može vidjeti da je izmjerena vrijednost koja predstavlja rad veća u ovom slučaju nego u prijašnjem, i to očekivano, jer je trenje veće.



Slika 30. Rezultati guranja čaše po hrapavoj površini

6.2. Guranje tegle s cvijećem

Masa tegle je 734 grama (Slika 31.).



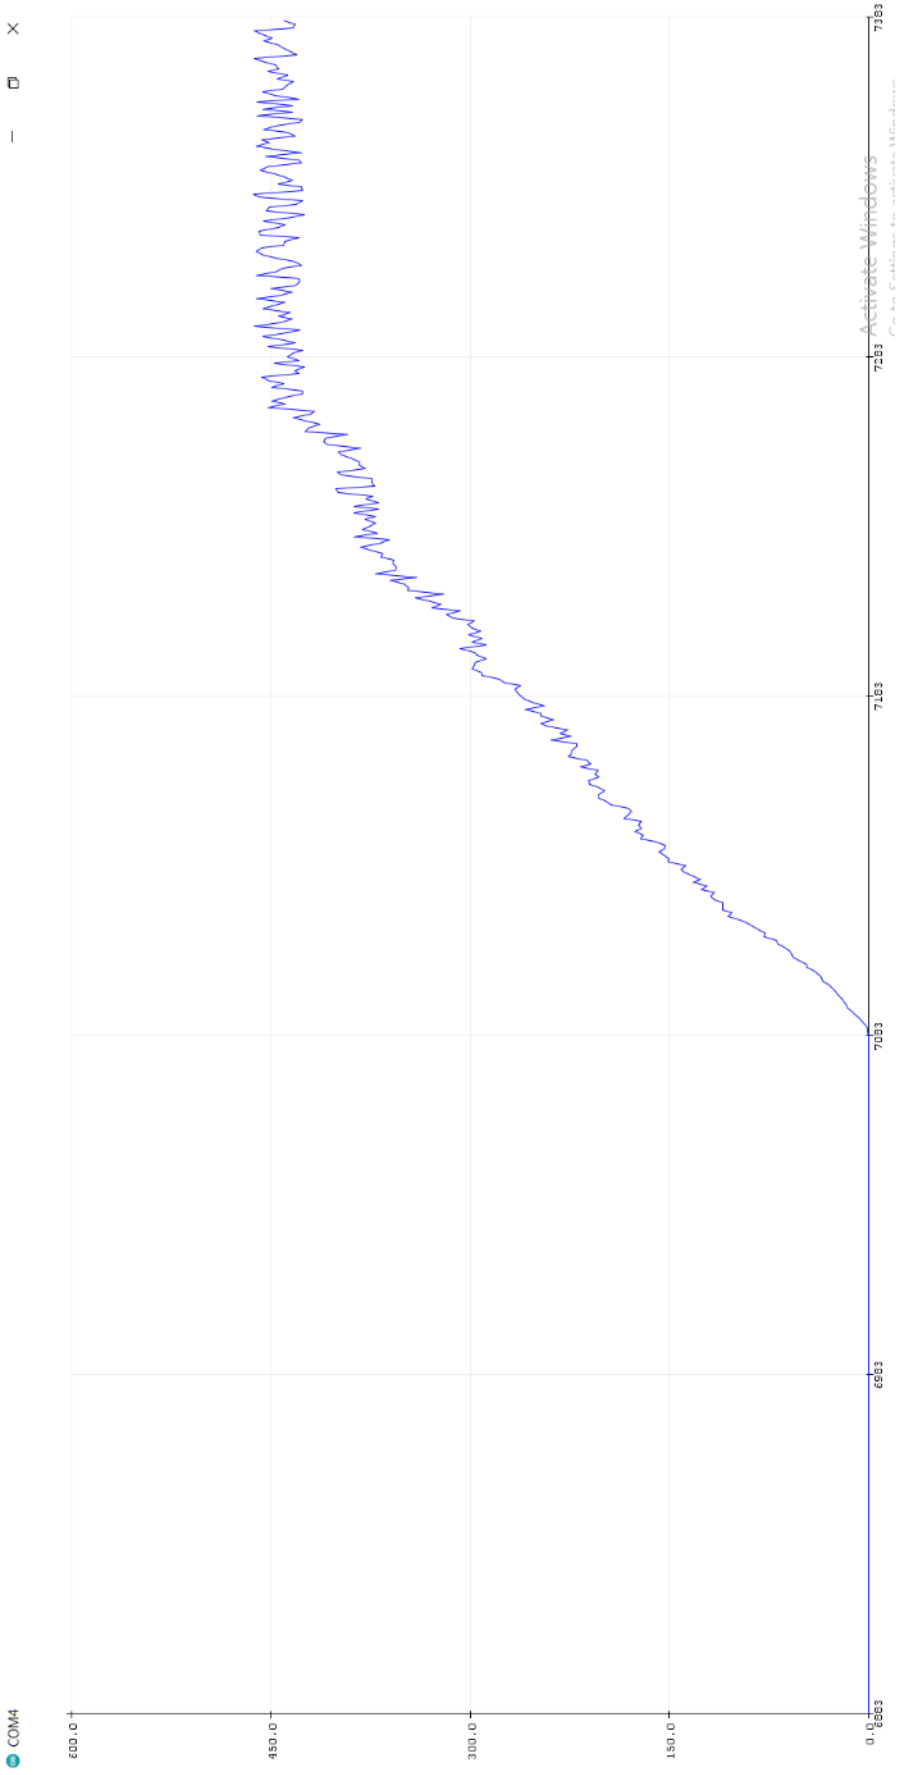
Slika 31. Tegla i njezina masa

6.2.1 Guranje tegle po glatkoj površini



Slika 32. Prikaz guranja tegle

Prilikom ovog eksperimenta, predmet odnosno tegla je pomicana manjom brzinom, što se vidi na grafu prikazanom na slici 33. Također se vidi da je očitana vrijednost veća nego kod čaše.



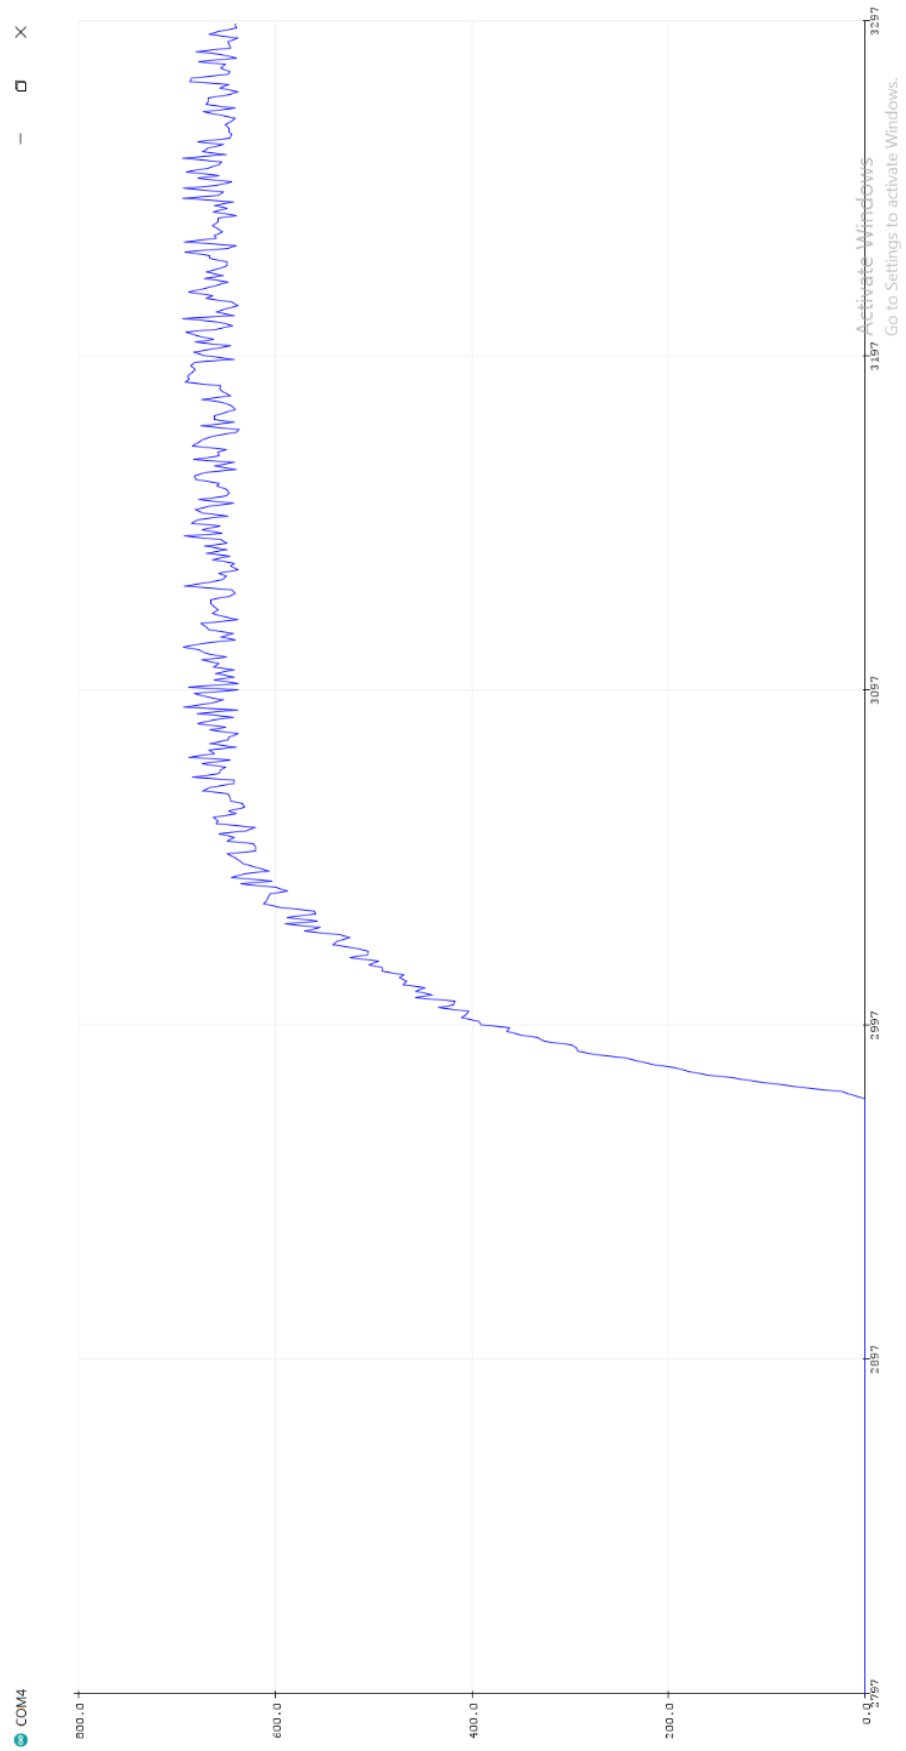
Slika 33. Rezultati guranja tegle po glatkoj površini

6.2.2. Guranje tegle po hrapavoj površini



Slika 34. Guranje tegle po hrapavoj površini

Očitana je vrijednost veća kod hrapave površine (Slika 35.), što je očekivano.



Slika 35. Rezlutati guranja tegle po hrapavoj površini

6.3. Guranje multimetra



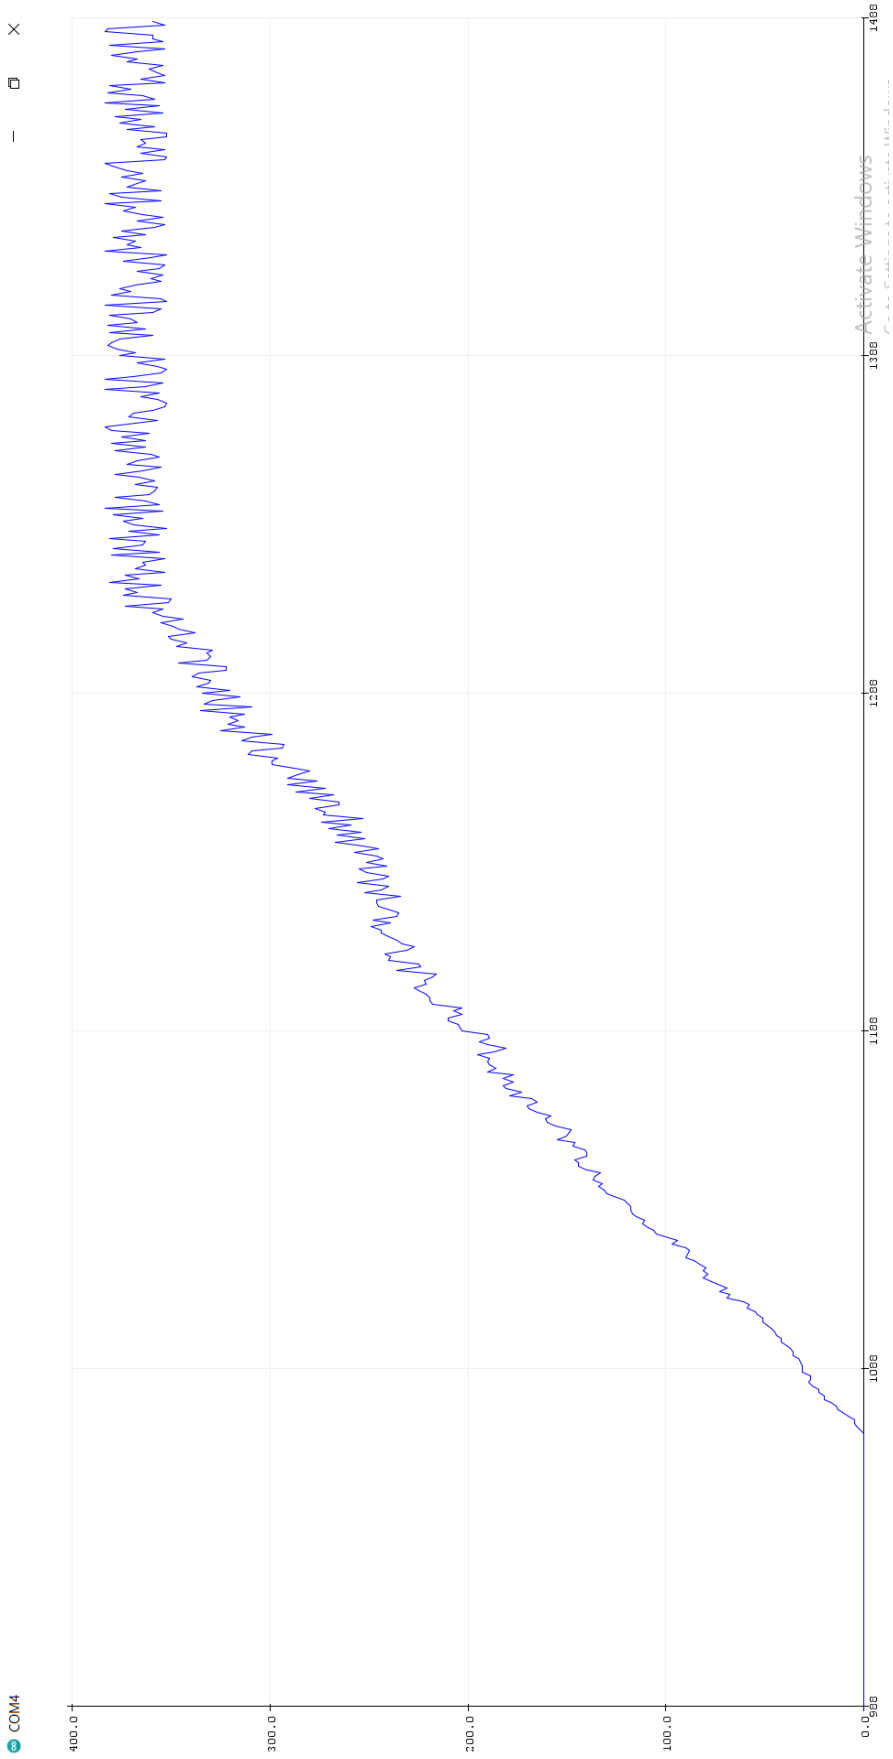
Slika 36. Multimetar i mjerenje njegove mase

Izmjerena masa multimetra je 542 grama. Multimetar je nešto teži od čaše ali je njegova površina načinjena od gume zbog koje je veći faktor trenja.

6.3.1. Guranje multimetra po glatkoj površini



Slika 37. Guranje multimetra po glatkoj površini

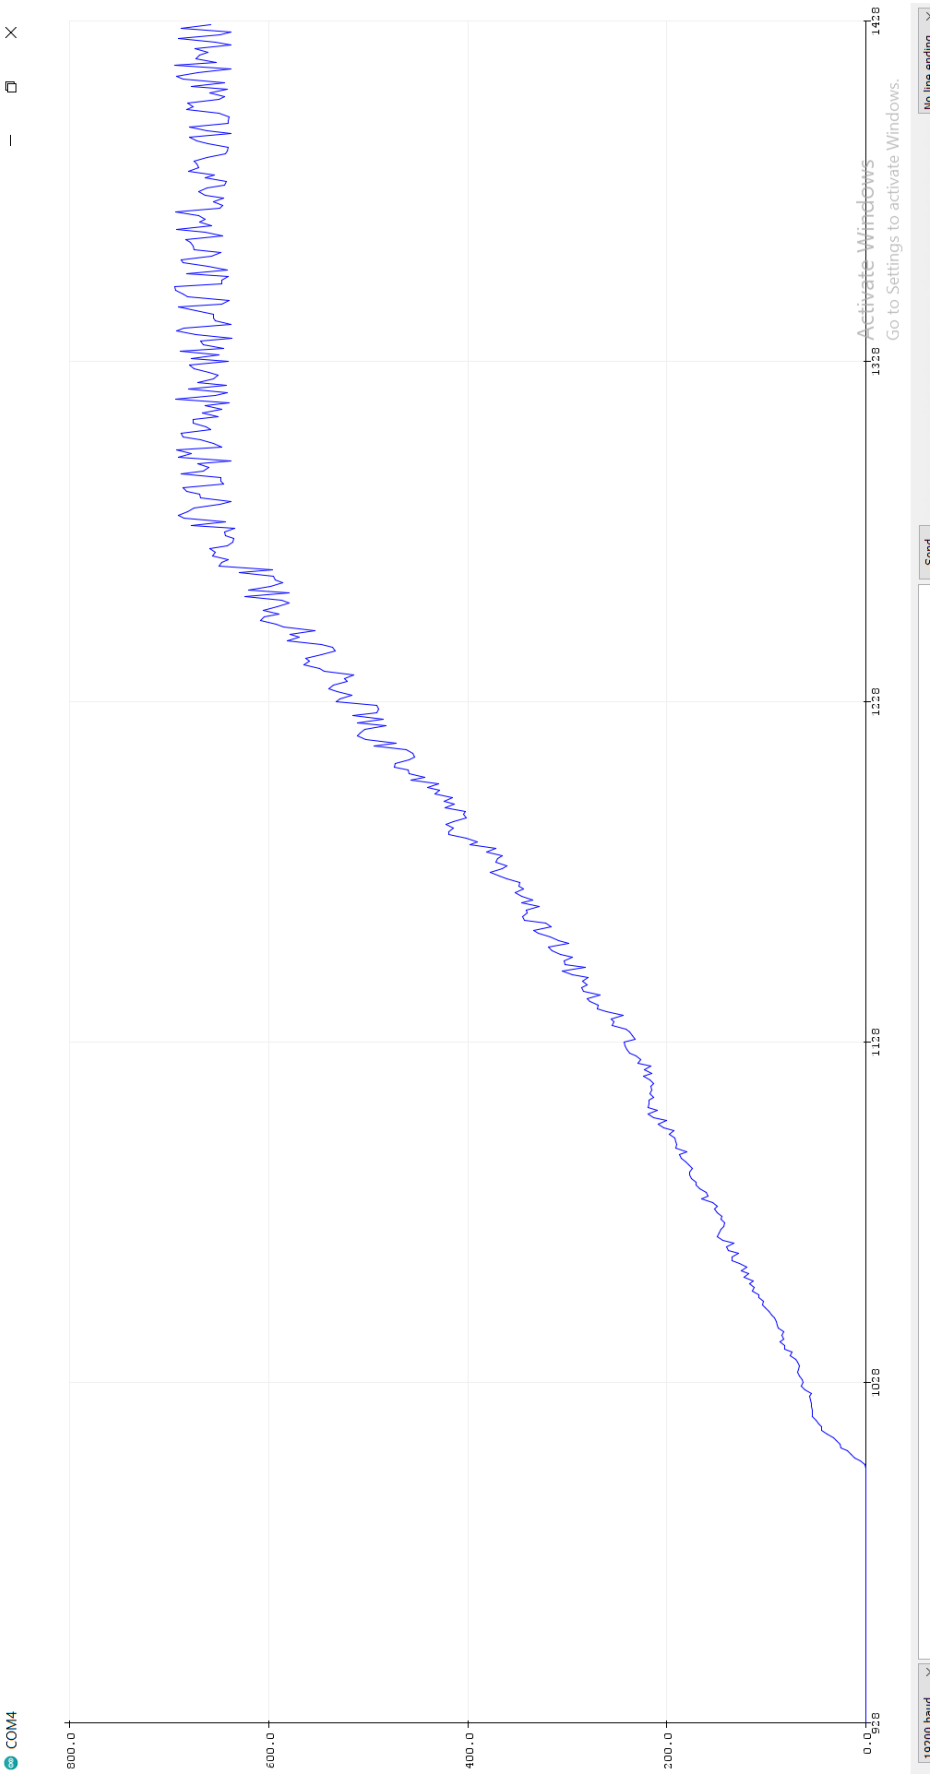


Slika 38. Rezultati guranja multimetra po glatkoj površini

6.3.2. Guranje multimetra po hrapavoj površini



Slika 39. Guranje multimetra po hrapavoj površini



Slika 40. Rezultati guranja multimetra po hrapavoj površini

6.4. Zaključak eksperimenata

Nakon provedenih šest eksperimenata i promatranja rezultata, može se zaključiti da su rezultati očekivani i u skladu sa zakonima fizike, odnosno razlikuje se rezultat pri guranju predmeta po glatkoj i hrapavoj površini te se razlikuju rezultati guranja predmeta različitih masa po istoj površini.

U vezi sila, rezultati ovdje provedenih eksperimenata smatraju se konzistentnima s usporedivim rezultatima prije izvedenih pokusa [10], premda sada ti podaci nisu striktno praćeni i bilježeni.

7. ZAKLJUČAK

Praćenje pokreta ima veliku ulogu u razvoju današnje tehnologije i i industrije, a i u ostalim područjima kao što su sport (za praćenje pokreta sportaša te analizu i napredak u tehnici izvedbe), filmskoj industriji (za snimanje i animiranje likova te postizanje stvarnijeg iskustva gledanja filma). Također se tehnologija praćenja pokreta može primijeniti za edukaciju medicinskog osoblja, gdje se pomoću nje mogu analizirati pokreti pri operacijama u virtualnoj stvarnosti. Kirurzi mogu time prenijeti svoje iskustvo na mlađe naraštaje. Upravo u medicini su korisni podaci o silama koje se upotrebljavaju, a tu je korisna podatkovna rukavica opisana u ovom radu.

U radu je postojeća podatkovna rukavica nadograđena – opremljena s mikročipom MPU6050 koji sadrži senzor akceleracije i žiroskop. Na taj način omogućuje se proširenje područja primjene postojeće podatkovne rukavice: očitavanjem i obradom podataka o pomaku, u kombinaciji sa senzorima sile već postojećim na rukavici, u konačnici se može izračunati rad ostvaren pri pokretu. Korištena je pločica Arduino Mega 2560 te je načinjen odgovarajući programski kôd, napisan pomoću Arduinovog okruženja IDE koje se bazira na programskom jeziku C++.

U sklopu rada su provedeni eksperimenti u kojima su korištena tri predmeta, kako bi se usporedili rezultati pri promjeni mase, te dvije različite površine kako bi se vidjelo hoće li doći do promjena u rezultatima. Promatrajući rezultate eksperimenata, može se zaključiti da podatkovna rukavica daje rezultate sukladne očekivanjima, a u vezi sila u skladu s prije izvođenim pokusima.

Dakle, unaprijeđenom podatkovnom rukavicom za praćenje i analizu pokreta mogu se pratiti pokret kao i sila upotrijebljena u nekoj radnji, naprimjer pri operaciji rezanja, bušenja ili hvatanja. Pomoću tih podataka se mogu analizirati i simulirati pojedine radnje-operacije odnosno određivati parametri procesa i konstrukcijske značajke alata. Za ručne procese, dobiveni bi podaci mogli poslužiti za stabiliziranje i normiranje rada, dok bi za automatske mogli poslužiti za definiranje putanja i sila hvatanja, ali i za samo konstruiranje uređaja.

Mogući daljnji razvitak podatkovne rukavice jest povezivanje rukavice s 3D softverom i virtualnom stvarnošću radi zornijeg prikaza pokreta, fino podešavanje senzora za praćenje pomaka radi točnijih rezultata, daljnje opremanje rukavice senzorima kao što su senzori za snimanje kontrakcije mišića kako bi se moglo pratiti stanje radnika. Uz to, a i uključenjem funkcije praćenja orijentacije (već sadržane u mikročipu MPU6050), znatno bi se proširilo područje primjene podatkovne rukavice.

Prednost ove rukavice je niska cijena senzora za pokret koja iznosi oko 2 USD, i pločice Arduino koja košta oko 20 USD, kao i jednostavnost programiranja u Arduinovom okruženju IDE te velika dostupnost raznih primjera na internetu.

8. LITERATURA

[1] Arduino Official Store: Arduino Mega 2560 Rev3. Dostupno na: https://store.arduino.cc/arduino-mega-2560-rev3, pristupljeno: 2020-09-17.

[2] Arduino Playground - MPU-6050. Dostupno na: https://playground.arduino.cc/Main/MPU-6050/, pristupljeno: 2020-09-17.

[3] Arduino Tutorial – Arduino Getting Started: Serial Plotter. Dostupno na: https://arduinogetstarted.com/tutorials/arduino-serial-plotter, pristupljeno: 2020-09-17.

[4] M. Bortolini, M. Faccio, M. Gamberi i F. Pilati: Motion Analysis System (MAS) for production and ergonomics assessment in the manufacturing processes. Computers & Industrial Engineering. 2020, 139 (1).

[5] S. Dyer, J. Martin i J. Zulauf: Motion Capture. Dostupno na: http://web.mit.edu/comm-forum/legacy/papers/furniss.html, pristupljeno: 2020-09-17.

[6] C. M. Ginsberg i D. Maxwell: Graphical marionette. SIGGRAPH Comput Graph. 1984; 18 (1), str. 26–27.

[7] ikrima: Character Animation with Kinect Motion Capture: Blog. Dostupno na: http://blog.kiteandlightning.la/character-animation-with-kinect-motion-capture/, pristupljeno: 2020-09-17.

[8] Methods-Time Measurement. Wikipedia. Dostupno na: https://en.wikipedia.org/w/index.php?title=Methods-time_measurement&oldid=960026755, pristupljeno: 2020-09-17.

[9] Lam: Motion Capture. Lam's Blog. Dostupno na: https://lamho.wordpress.com/51-2/, pristupljeno: 2020-09-17.

[10] I. Štivić: Podatkovna rukavica za snimanje i analizu pokreta. Diplomski rad. Fakultet strojarstva i brodogradnje, Sveučilište u Zagrebu. 2019.