Senzori za detekciju položaja i navika sjedenja te njihov utjecaj na sjedenje

Jaković, Marko

Master's thesis / Diplomski rad

2020

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Forestry / Sveučilište u Zagrebu, Šumarski fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:108:013158

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-28**

Repository / Repozitorij:

University of Zagreb Faculty of Forestry and Wood Technology

ŠUMARSKI FAKULTET SVEUČILIŠTA U ZAGREBU
DRVNOTEHNOLOŠKI ODSJEK

SVEUČILIŠNI DIPLOMSKI STUDIJ
OBLIKOVANJE PROIZVODA OD DRVA

Marko Jaković

SENZORI ZA DETEKCIJU POLOŽAJA I NAVIKA SJEDENJA TE NJIHOV UTJECAJ NA SJEDENJE

DIPLOMSKI RAD

Zagreb, 2020.

SVEUČILIŠTE U ZAGREBU – ŠUMARSKI FAKULTET
DRVNOTEHNOLOŠKI ODSJEK

SVEUČILIŠNI DIPLOMSKI STUDIJ
OBLIKOVANJE NAMJEŠTAJA OD DRVA

SENZORI ZA DETEKCIJU POLOŽAJA I NAVIKA SJEDENJA TE NJIHOV UTJECAJ NA SJEDENJE

Diplomski rad

Diplomski studij:	Oblikovanje proizvoda od drva
Predmet:	Namještaj i zdravlje
Student:	Marko Jaković, univ. bacc. ing. techn. lign.
JBMAG:	0068226934
Broj indeksa:	987/18
Mentor:	izv. prof. dr. sc. Zoran Vlaović
Ispitno povjerenstvo:	1. izv. prof. dr. sc. Zoran Vlaović
	2. prof. dr. sc. Ivica Grbac
	3. doc. dr. sc. Danijela Domljan
Datum odobrenja teme:	17. 4. 2020.
Datum predaje rada:	15. 9. 2020.
Datum obrane rada::	25. 9. 2020.

Zagreb, 25. rujan 2020.

Dokumentacijska kartica

Naslov	Senzori za detekciju položaja i navika sjedenja te njihov utjecaj na sjedenje
Title	Sensors for detecting posture, sitting habits and their influence on sitting
Autor	Marko Jaković
Adresa autora	Kebel 29b, 49221 Bedekovčina
Mjesto izrade	Šumarski fakultet Sveučilišta u Zagrebu
Vrsta objave	Diplomski rad
Mentor	Izv. prof. dr. sc. Zoran Vlaović
Izradu rada pomogao	
Godina objave	2020.
Obujam	Stranica: 71 Slika: 67 Navoda literature: 34 Web izvora: 4
Ključne riječi	Pametna stolica; senzori u stolicama; Navike sjedenja
Key words	Smart chair; Sensors in chair; Sitting habits
Sažetak	Prekomjerno sjedenje je postalo normalna pojava u ljudskim životima, zbog čega naše tijelo trpi. U ovom radu istražene su relevantne baze te je napravljen pregled postojeće literature koja se bavi razvijanjem i integriranjem različitih senzora pomoću kojih možemo promatrati i analizirati sjedenje pojedinca.
Summary	Excessive sitting has become a normal occurrence in human lives, which is why our body suffers. In this paper, the relevant databases were explored and was created a review of the existing literature dealing with the development and integration of various sensors with which we can observe and analyze the sitting of an individual.

	IZJAVA **O IZVORNOSTI RADA**	OB ŠF 05 07
		Revizija: 1
		Datum: 28. 6. 2017.

Izjavljujem da je moj diplomski rad izvorni rezultat mojega rada te da se u izradi istoga nisam koristio drugim izvorima osim onih koji su u njemu navedeni.

_____

Marko Jaković

U Zagrebu, 21. 9. 2020.

SADRŽAJ

Predgovor VII
1. UVOD 18
1.1. Sjedenje kod uredskih poslova kao uzrok bolesti 18
1.1.1. Biomehanika tijela prilikom stajanja i sjedenja 19
1.1.2. Načini rada u uredu s obzirom na položaj tijela 22
1.1.3. Udobnost uredskih radnih stolica 28
2. CILJ ISTRAŽIVANJA 18
3. MATERIJALI I METODE ISTRAŽIVANJA 19
3.1. Način odabira relevantne literature 19
3.2. Kratki opisi pretraživanih baza 19
3.2.1. Web of Science 19
3.2.2. Scopus 20
3.2.3. IEEE Xplore 20
3.3. Rezultati pretraživanja prema odabranim kriterijima 21
4. REZULTATI ISTRAŽIVANJA 22
4.1. Znanstveni članci koji su ispunili kriterije pretraživanja 22
4.1.1. Baza *Web of Science Core Collection* 22
4.1.2. Baza *IEEE Xplore* 31
4.1.3. Baza *Scopus* 55
5. RASPRAVA I ZAKLJUČAK 64
LITERATURA 66
POPIS SLIKA 68

Predgovor

Prije šest godina bio sam netko tko je po struci bio stolar, radio kao pomoćni električar i sanjao o tome da jednog dana upiše smjer Drvne tehnologije na Šumarskom fakultetu . Na tom putu nikad nisam bio sam ni usamljen, stoga bih se htio zahvaliti obitelji, prijateljima koji su uvijek bili uz mene. Također, htio bih se zahvaliti i svim nastavnicima Šumarskog fakulteta čije ću mudre izreke nositi nositi u srcu, a savjete uvijek imati na umu.

Posebno bih se htio zahvaliti mentoru izv. prof. dr. sc. Zoran Vlaović koji mi je uvelike pomogao i bez kojeg bi bilo puno teže prekoračiti ovu posljednju prepreku koju kao student Šumarskog fakulteta trebam prekoračiti. Svojim savjetima, strpljenjem i konstruktivnim kritikama pomogao mi je da dođem do kraja zacrtanog puta.

1. UVOD

U ovom diplomskom radu prikazat će se kratki osvrt na to kako, zašto, gdje i na čemu ljudi sjede pri radu te kako to utječe na zdravlje ljudi.

Smatra se da pasivno sjedenje dulje vrijeme nije zdravo za čovjeka, nego da bi se svako određeno vrijeme trebao promijeniti položaj. Proučavana je literatura koja opisuje uporabu različitih senzora (osjetnika) i tehnologija koji detektiraju na koji način/kako sjedimo, koliko sjedimo te kakav to utjecaj ima na naše zdravlje. Postoji velik broj različitih metoda i senzora za očitavanje tlakova i dobivanje podataka tijekom sjedenja, međutim, pitanje je kako takve podatke tumačiti i kako ih obraditi da bismo ih mogli koristiti u svrhe prevencije oboljenja i izazivanja problema uzrokovanih dugotrajnim, nepravilnim i neudobnim sjedenjem, na isto takvim stolicama: neprimjerenim za obavljanje rada, nepravilno podešenima za sjedenje osobe i s drugim nedostacima.

1.1. Sjedenje kod uredskih poslova kao uzrok bolesti

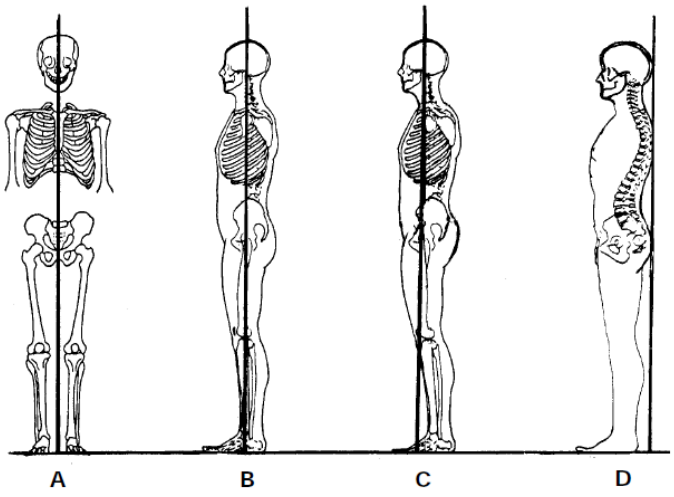
Prekomjerno sjedenje je tema mnogih istraživanja kao potencijalni uzrok različitih oboljenja. Kada govorimo o prekomjernom sjedenju u kombinaciji s lošim sjedećim položajem, tada govorimo o poprilično podmuklom uzroku različitih oboljenja jer se prvi uzroci takvog sjedenja javljaju tek nakon određenog vremena. To znači da ljudi često ni nisu svjesni kako način na koji sjede možda neće rezultirati bolovima na kraju dana, ali ako to radimo svakodnevno, tada nakon nekog perioda nastane problem. Sjedenje kod uredskih poslova je tu posebno naglašeno jer je prosječno radno vrijeme osam sati dnevno, a od zaposlenika u uredu se očekuje da što više vremena od tih osam sati provede na svom radnom mjestu marljivo radeći.

Statistika pokazuje da u SAD-u odrasle osobe prosječno sjede 9,3 sati dnevno, 6,5 sati provode u nekoj laganoj aktivnosti, a 0,7 sati provode vježbajući (Spear, 2012). Godine 2013. provedeno je istraživanje i zaključeno da 11 % svih Europljana starijih od 14 godina sjedi više od 8,5 sati dnevno (Schwartz, 2016). Život u današnjem dobu donosi brojne pogodnosti, sve više fizičkih poslova odrađuju strojevi, te se sve više traži od ljudi da rade poslove na računalu, što bi moglo imati štetan učinak zbog produljenog vremena u sjedećem položaju (Spear, 2012). Opće je poznato da je preporučeno baviti se nekim sportom ili fizičkom aktivnošću barem 30 minuta dnevno. Rezultati istraživanja koje je proveo Owen (2008) ukazuju na to da velika količina sjedećih aktivnosti na dnevnoj bazi, bez obzira na količinu fizičke aktivnosti, jest povezana s razvojem poznatih kroničnih oboljenja kralježnice (citirano u Spear, 2012).

1.1.1. Biomehanika tijela prilikom stajanja i sjedenja

Kineziologija je relativno mlada znanost, ime joj je izvedeno od grčke riječi *kinesiz* – pokret. Danas se definira kao opća, sveobuhvatna znanost o kretanju. Važna stavka kineziologije je biomehanika koja se bavi proučavanjem svojstva tijela u mehaničkom smislu. Biomehanika u kineziologiji uključuje precizne opise ljudskih pokreta i proučava uzroke i načine pokreta (Knudson, 2007). Harrari, Y. N. (2011) je u svojoj knjizi *Sapiens: Kratka povijest čovječanstva* konstatirao da "mi ljudi kao vrsta (homo sapiens) postojimo otprilike 200000 godina". Pogledamo li u povijest sjedenja kao pretežitog načina obavljanja poslova ili drugih radnji, značajno smo počeli sjediti tek nekih posljednjih 200 godina, što znači da je naše tijelo imalo 180000 godina da se biomehanički prilagodi za hodanje i aktivan život, a samo 200 godina za život u pretežito sjedećem položaju. Takva relativno nagla promjena sigurno doprinosi bolovima u ljudskom tijelu uzrokovanim nepravilnim i prekomjernim sjedenjem.

Prvo je potrebno proučiti biomehaniku stajanja kako bi mogli razumjeti biomehaniku sjedenja. Ljudi su jedna od rijetkih, a vjerojatno i jedina vrsta na svijetu koja ima uspravan stav i koja je potpuno prilagođena za život na dvije noge. Svi položaji i promjene položaja nakon ustajanja iz kreveta su zapravo promjene iz stajaćeg položaja, a to su radnje hodanja, čučanja, penjanja i sjedenja (koje također može biti tumačeno kao promjena iz stajaćeg položaja) (Harrison *et al.*, 1999). Normalan stajaći položaj je u radu Harrisona i suradnika (1999) opisan kao savršeno poravnanje uha, ramena, kuka, koljena i gležnjeva. Woodhull i suradnici su 1985 (citirano u Harrison *et al.*, 1999) izjavili kako je dobar stajaći položaj često idealiziran i da istraživanja pokazuju da je centar gravitacije prosječnog stajaćeg položaja nešto ispred gležnjeva (slika 1). Slika 1 prikazuje pogled s prednje strane na ljudsko tijelo prilikom stajanja (A), prosječan stajaći položaj dobiven istraživanjima (B) i položaj koji je idealiziran kao idealan stajaći položaj (C i D).



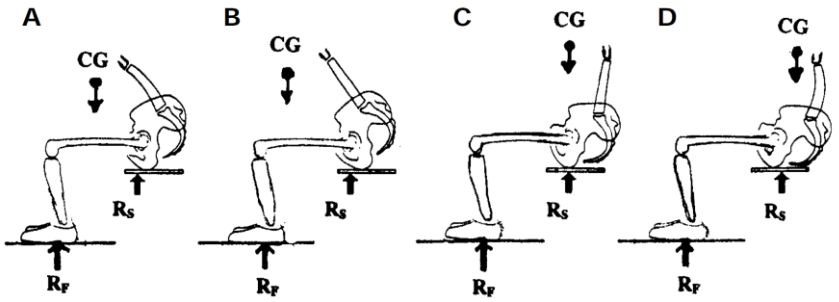
Slika 1. Prikaz idealnog i realnog položaja tijela prilikom stajanja

Izvor: Harrison *et al.*, 1999

Harrison i suradnici (1999) u svom radu napominju da je idealan stajaći položaj opisan u literaturi prije više od stotinu godina.

Biomehaniku sjedećeg položaja je najjednostavnije podijeliti prema središtu gravitacije. U radovima Harrisona i suradnika (1999) i Vlaovića (2009) je opisano da je Schoberth (1962) to podijelio na tri položaja (slika 2). Na slici 2. Rs predstavlja reakcijsku silu na sjedalu, Rf reakcijsku silu na stopala, a CG centar

gravitacije. Srednji položaj (slika 2.c) prikazuje centar gravitacije iznad sjednih kostiju, a 25 % mase osobe se prenosi na pod preko stopala, Slika 2.d prikazuje opušteni središnji položaj pri kojem su leđa zakrivljena, a manje od 25 % mase osobe se prenosi na pod preko stopala, dok slike 2.a i 2.b prikazuju sjedeći položaj u kojem je centar gravitacije daleko ispred sjednih kostiju te je samim time veće opterećenje na noge, odnosno više od 25 % mase osobe (Harrison *et al.*, 1999; Vlaović, 2009).

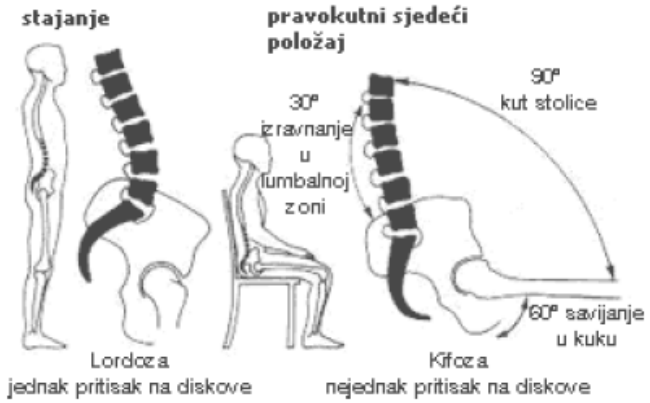


Slika 2. Prikaz Schoberth-ovih triju kategorija sjedenja prema položaju djelovanja centra gravitacije

Izvori: Harrison *et al.*, 1999; Vlaović, 2009

U radu Vlaovića (2005) opisano je kako je američki ortopedski kirurg Keegan, 1953. rendgenom snimao osobe koje su ležale na boku te je prikazao velike promjene u lumbalnom dijelu kada se mijenja položaj iz stajaćeg položaja u sjedeći i nagnuti. Tu je također prikazano da je položaj s kutom u kuku od 45° i 135° između bedara i torza prirodni opuštajući položaj kakvog često zauzimamo spavajući na boku.

Pri sjedenju se zdjelica (lat. pelvis) zakreće unazad (slika 3), a lumbalni dio kralježnice izravnava. Elektromiografija (EMG) ukazuje da pognuto ili naslonjeno sjedenje opušta mišiće trupa i da takvo sjedenje zahtjeva minimalnu mišićnu aktivnost za držanje tijela u ravnoteži. Međutim, pritisak na diskove je najveći upravo dok osoba sjedi u pognutom položaju (Vlaović, 2005).



Slika 3. Položaj zdjelice i kralježnice kod stajanja i sjedenja

Izvor: Mandal 2002, citirano u Vlaović, 2005

1.1.1.1. *Bolesti uzrokovane sjedenjem*

U istraživanju koje je 2002. godine objavio *Journal of the American Medical Association*, procjenjuje se da stanovnici SAD-a troše 85,9 milijardi dolara godišnje u potrazi za olakšanjem bolova u području vrata i križa pomoću operacija, MRI skenova, posjeta liječniku, rendgena i lijekova. Također, procjenjuje se da zbog bolova u križima bude izgubljeno više od 93 milijuna radnih dana koje radnici provedu kod kuće zbog bolova Spear, 2012. Nažalost, na zdravlje se počne misliti tek pri pojavi bolesti (Grbac i Domljan, 2007). Čovjek suvremenog svijeta provede čak polovinu svojeg života pasivno sjedeći, četvrtinu ležeći, a samo preostalu četvrtinu u pokretu (Grbac 2006, citirano u: Grbac i Domljan, 2007). Navedeni položaji upućuju na važnost sustavnog i interdisciplinarnog pristupa u rješenjima konstrukcijskih vrsta namještaja za sjedenje i ležanje Grbac i Domljan, 2007. Veliki uzročnik nepravilnog sjedenja jest činjenica da različiti proizvođači uredskih radnih stolica proizvode stolice s različitim načinima postizanja ispravnog položaja sjedenja, tako da neki korisnici ne znaju prepoznati kako sjede, a neki ne znaju ispravno podesiti i namjestiti stolicu (Goossens, Netten i Van der Doelen, 2012).

Prema radu Bontrup i suradnika (2019) bolovi u donjem dijelu leđa predstavljaju treći vodeći uzrok ne dolaska na posao zbog samo-dijagnosticirane nemogućnosti rada bez bolova priliko rada. To vodi do velikog ekonomskog tereta za tvrtke i društvo budući da se godišnje izgubi više od 93 milijuna radnih dana (Spear, 2012). Nameće se da je identificiranje uzroka i prevencija takvog oboljenja od značajne važnosti kako bi se taj problem u ekonomskom i zdravstvenom smislu umanjio. Iako se očekuje da su bolovi u donjem dijelu leđa usko povezani s uredskim poslovima, zapravo postoji malo radova koji to potvrđuju. Bontrup *et al.*, 2019 navode kako dosadašnja istraživanja upućuju na to da sjedenje u periodima duljim od sedam (7) sati dnevno značajno pridonosi riziku oboljenja donjeg dijela leđa. U istom radu se navodi kako s druge strane postoji nekoliko članaka i istraživanja koja nisu uspjela potvrditi povezanost prekomjernog sjedenja prilikom rada u uredu s rizicima oboljenja donjeg dijela leđa. Rezultat nedostatka dokaza pripisuje se varljivoj prirodi bolova u donjem dijelu leđa, kao i mogućoj pogrešci u metodi obrade podataka. Neki od razloga zbog kojih je moguć nedostatak dokaza su nepouzdane mjerni uređaji, kratak period mjerenja i potencijalno premalen broj ispitanika.

Dugotrajno sjedenje prepoznaje se kao ozbiljan metabolički zdravstveni problem zbog nekoliko patogenih mehanizama koji povezuju mišićnu neaktivnost s povećanim zdravstvenim rizicima: niska potrošnja energije – što dovodi do nakupljanja masnoća, a može doći i do lakših upala; umanjene funkcije endokrinog sustava žlijezda što može prouzročiti loš rad nekoliko organa i tkiva popraćenih umanjenim lučenjem antioksidansa (Grooten *et al.*, 2013).

U radu koji su objavili Grbac i Domljan (2007) se ukazuje na dobivene podatke s njemačkog instituta za sigurnost na radu o aktivnostima implementacije novih tehnologija koja podrazumijeva dulje provođenje vremena za računalom, zbog čega se zbog dugotrajnog i nepravilnog sjedenja pojavljuju bolovi u glavi (14 %), vratu i ramenima (24 %), leđima (57 %), stražnjici (16 %), potkoljenicama (19 %) te koljenima i stopalima (2 %) pri čemu statičko sjedenje može uzrokovati stres i probleme kardiovaskularnog sustava i probavnih organa.

1.1.2. Načini rada u uredu s obzirom na položaj tijela

Kada bi se željelo podijeliti način rada u uredu s obzirom na osnovni položaj tijela, tada se to najlakše može svesti na rad za vrijeme sjedenja, u kombiniranom položaju (sjedenje i stajanje) i za vrijeme stajanja.

Svaki od ovih položaja ima određene zahtjeve, prednosti i mane. Svakako je važno napomenuti da udobnost položaja najviše ovisi o pojedincu te da ni jedan položaj nije potpuno zdrav i idealan za ljudsko tijelo. Odnosno, niti jedan od osnovnih položaja čovjek ne može održavati stalno, a ako još k tome dodamo druge aspekte života kao što su zanemarivanje zdrave prehrane, aktivnog života (redovitog vježbanja i kretanja) i slično, tada nam ni sama promjena položaja ne može jamčiti zdravlje u leđima.

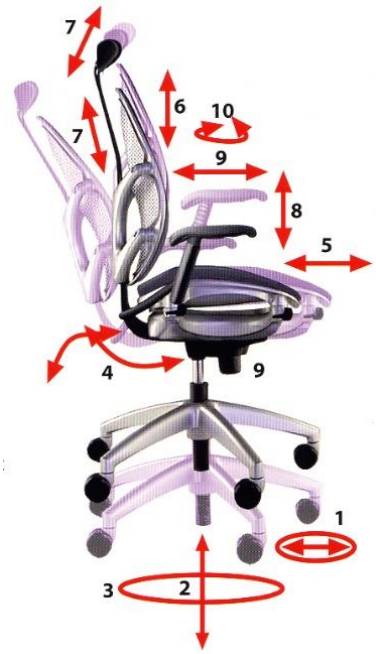
Sjedeći položaj je privukao veliku pažnju 1970-ih u Švedskoj, već su tada Nachemson i Elfstrom ugradili tlačne senzore u međukralješčane diskove četvero živih ispitanika kako bi prikazali da sjedeći položaj izaziva veće opterećenje na diskove nego stajanje ili ležanje (Harrison *et al.*, 1999). Autori tada ističu da je pitanje o normalnom položaju kralježnice prilikom sjedenja jako zanimljivo te da je postavljeno još 1911. godine. S današnje točke gledanja od tada je prošlo 110 godina.

1.1.2.1. *Sjedenje prilikom rada u uredu*

Rad prilikom sjedenja je najzastupljeniji način rada koji se ne odnosi samo na rad u uredu već i na obrazovne ustanove (učenici, studenti). S obzirom na te činjenice smatra se najvećom opasnosti i najvećim uzrokom oboljenja, a posebice bolovima u donjem, lumbalnom, dijelu leđa. Prema definiciji, uredski namještaj za sjedenje namijenjen je opremanju ureda ili drugih radnih prostora, a ima funkciju podupiranja ljudskog tijela na pravilan način prilikom sjedenja. Za razliku od ostalih stolica, na uredske radne stolice postavljaju se drugačiju zahtjevi. One moraju osigurati udoban i nesmetan rad u uredu (Vlaović, 2009).

Uredsko poslovanje ima značajnu ulogu za zdravlje suvremenog čovjeka, naročito zbog današnjih poslova temeljenih na uporabi informatičkih tehnologija i dugotrajnom sjedenju. Nažalost uz pozitivne posljedice uvođenja digitalizacije, sve se više uočavaju i negativne posljedice ovih pomagala na zdravlje uredskog čovjeka. Statistički podaci u Njemačkoj potvrđuju da čak 80 % uredskih djelatnika pati od nekog oblika oštećenja kralježnice, a jedan od većih razloga odlaska ove populacije radnika na bolovanje predstavljaju bolovi u leđima, s udjelom čak oko 10 %. U prilog tome su podaci istraživanja njemačkog instituta za sigurnost na radu o aktivnostima i najčešćim položajima djelatnika u administrativnim poslovima koji 96 % radnog vremena sjede, 3 % stoje, a samo 1 % se kreću (Grbac i Domljan, 2007).

Slika 4 prikazuje primjer uredske radne stolice s njezinim mogućnostima podešavanja kako bi stolica bila prilagodljiva svakom korisniku.



10 – zakretanje rukonaslona
9 – horizontalno klizanje rukonaslona
8 – namještanje rukonaslona po visini
7 – namještanje po dubini/visini naslona za glavu
6 – namještanje visine naslona
5 – namještanje sjedala po dubini
4 – namještanje udobnosti pomoću mehanizma
3 – zakretanje oko okomite osi
2 – namještanje visine pomoću plinskog cilindra
1 – pomicanje na kotačima

Slika 4 Prikaz uredske radne stolice s njezinim mogućnostima podešavanja

Izvor: Vlaović, 2005

Prema normi HRN EN 1335-1 preporučuje se sjedeći položaj sa slike 5, a podrazumijeva da visinu stolice treba namjestiti tako da laktovi s podlakticama čine kut veći ili jednak 90° kada su podlaktice na površini stola. Koljena bi također trebala tvoriti kut koji je veći ili jednak 90° dok stopala trebaju biti ravno i čvrsto na podu.



Slika 5 Prikaz pravilnog sjedenja prema HRN EN 1335-1

Izvor: Vlaović 2009

S ovim se preporukama ne slažu svi autori te još nitko do sada nije dao realno objašnjenje zašto bi taj položaj bio bolji od bilo kojeg drugog (Vlaović, 2009). Na uredskim radnim stolicama bi tijelo trebalo zauzeti najbolji položaj za maksimalno rasterećenje kralježnice, boreći se tako protiv trajnih oštećenja, osiguravajući istovremeno udobnost kako bi se osigurala koncentracija pri radu. Za ergonomski ispravno radno mjesto mora se uzeti u obzir i uskladiti međuodnos optimalnih razmaka, odnosa visina i kutova (Grbac i Domljan, 2007).

1.1.2.2. *Aktivno i dinamičko sjedenje*

Ako se već opisuje sjedenje, tada svakako treba spomenuti i aktivno sjedenje koje se nameće kao alternativa pasivnom sjedenju na krutoj stolici. Radi se o varijanti sjedenja gdje prilikom rada (u uredu) imamo malene ili veće pomake tijela kako bi aktivirali mišiće. U to se može ubrojiti sjedenje na stolici koja potiče dinamičko, odnosno aktivno sjedenje ili korištenje stolova podesivih po visini tako da po potrebi možemo stajati i raditi. Tu se ubrajaju i stolice koje nemaju potpuno fiksno postolje stolice te se na taj način potiče aktivacija mišića trupa kako bi se održala ravnoteža (O'Sullivan *et al.*, 2012).

Prvo je potrebno objasniti da su aktivno sjedenje i dinamičko sjedenje dva slična, no ne ista pojma. Izraz dinamičko sjedenje smišljen je kako bi opisao zamisao mijenjanja položaja i omogućio različitoj skupini mišića naizmjenično opuštanje (Vlaović, 2005). Ustvari, dinamičko sjedenje, podržano individualno podesivim i gibljivim stolcima, pruža korisniku djelomičnu slobodu gibanja i veći sklad položaja tijela s mentalnom aktivnošću. Samim time, stvaraju se osnove za nova oblikovano-konstrukcijska načela u rješenju problema sjedenja i razvijanju se nove vrste uredskih stolica (slika 6) koje ne prisiljavaju korisnika na kruti sjedeći položaj, već mu pomažu da sjedi na dinamičan način sa „savršeno uravnoteženim tijelom" (Grbac i Domljan, 2007).

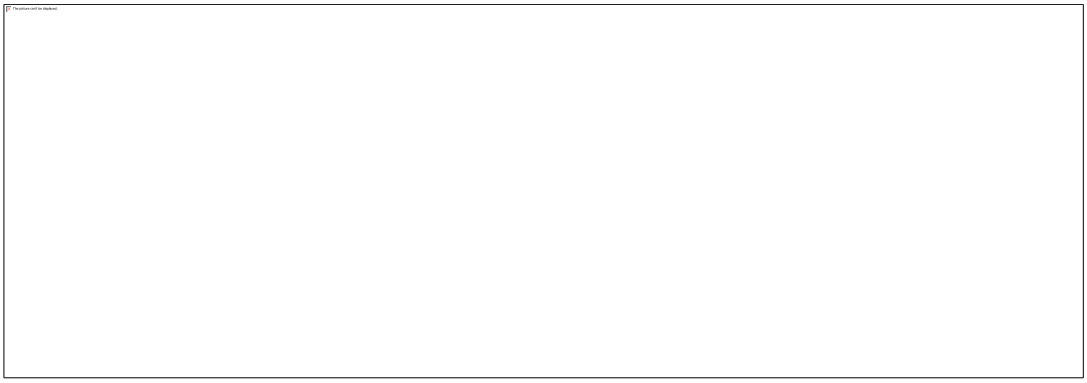


Slika 6 Prikaz stolice za dinamičko sjedenje

Izvor: Web 1

Aktivno sjedenje temeljeno na teoretskim prednostima sjedenja na lopti omogućuje tijelu puno veću slobodu prostornog gibanja u skladu s mentalnom aktivnosti i neprestanu aktivnost ponajviše leđnih mišića,

što povoljno utječe na cijeli organizam. Iako aktivno sjedenje nudi mnoge mogućnosti, još uvijek nisu istražene sve prednosti, mane te utjecaj na ljudsko tijelo. Povezivanje mogućnosti slobodnih pokreta tijela pri sjedenju i održavanja ravnoteže uključivanjem vlastitih mišića, bez posebnih oslonaca uzrokovalo je malu revoluciju u oblikovno-funkcionalnim parametrima rješavanja problema izrade namještaja za sjedenje. Novi koncepti sjedenja su unazad dvadesetak godina uočeni posebice u oblikovanju uredskog namještaja za sjedenje (Grbac i Domljan, 2007). Slika 7 prikazuje nekoliko primjera stolica za aktivno sjedenje.



Slika 7. Prikaz nekoliko stolica za aktivno sjedenje

Izvor: Web 2

Dakle može se reći da je glavna razlika između stolice za dinamičko sjedenje i stolice za aktivno sjedenje u tome što stolica za dinamičko sjedenje uz "obično" sjedenje nudi veći raspon pokreta, dok se stolica za aktivno sjedenje konstrukcijski i funkcionalno oslanja na to da korisnik bez prestanka bude u nekom laganom, jedva primjetnom pokretu.

Pretpostavka je da je problem pasivnog sjedenja taj da se nakon nekog vremena ljudsko tijelo opusti i prestane sjediti pravilno. Ljudi prilikom dužeg sjedenja radije sjede u različitim položajima nego u jednom udobnom i pravilnom, time se uzastopno mijenja opterećenje tijela prilikom sjedenja (Callaghan i McGill 2001, citirano u O'Sullivan *et al.*, 2012). Produljeno vrijeme niske razine mišićne aktivnosti se često povezuje s bolovima u drugim mišićnim skupinama (Westgaard i DeLuca, 1999, citirano u O'Sullivan *et al.*, 2012). Zanimljivo je da većina znanstvenih radova dokazuje da dinamičko odnosno aktivno sjedenje daje male ili nikakve promjene kod položaja tijela prilikom sjedenja, aktivacije mišića trbuha ili udobnosti (van Dieen *et al.,* 2001, Gregory *et al*., 2006, McGill *et al*., 2006, O'Sullivan *et al.,* 2006, Kingma i van Dieen 2009, citirano u O'Sullivan *et al.*, 2012). U doba kada su O'Sullivan i suradnici radili istraživanje (2012. godine) još nitko nije napravio usporedbu klasičnog uredskog sjedenja i razine aktivacije mišića, udobnosti i položaja leđa.

Opće popularna stolica za aktivno sjedenje prikazana je na slici 8, a sličan model je korišten u istraživanju O'Sullivana i sur. 2012. godine. Istraživanje je pokazalo da nije bilo razlike između mišićne aktivnosti pri sjedenju na aktivnoj stolici *Backapp*i klasičnoj uredskoj stolici. Nažalost, nedostatak ovog tipa stolice jest da se na njoj ne može sjediti za klasičnim radnim stolom već stol mora imati mogućnost podešavanja po visini ili mora biti viši od radnog stola uobičajene visine radne ploče.



Slika 8 Prikaz stolice Backapp Smart *proizvođača "Backapp"*

Izvor: Web 3

Dinamično, ali i aktivno sjedenje se povezuje s povećanjem neudobnosti u nekoliko radova u kojima je korištena stolica proizvođača *Backapp* Gregory et al. 2006, citirano u O'Sullivan *et al.*, 2012), što se može povezati sa smanjenjem opterećenja i drugačijeg položaja kuka te se pretpostavlja da se na spomenutoj stolici više povećava mišićna aktivnost u nogama nego u trupu, što nije do sada izmjereno (O'Sullivan *et al.*, 2012). Spominje se da povećana fizička aktivnost zaposlenika prilikom rada u uredu tako da imaju više kratkih pauza tokom rada i uvijete za rad na aktivnoj stolici ili neki drugi način ima pozitivan utjecaj na zdravlje zaposlenika, kao što je bolja razina šećera u krvi, manji bolovi u leđima i vratu te bolje raspoloženje radnika (Dunstan, Howard, *et al*., 2012, Dunstan, Kingwell, *et al,.* 2012; Pronk *et al.,* 2012, citirano u Grooten *et al.*, 2013). Pojedini znanstvenici vjeruju da uredska stolica bez naslona za leđa može imati iste ili slične pozitivne efekte kao stolica koja potiče aktivno sjedenje na zdravlje jer se vjeruje da sjedenje na stolici bez naslona aktivira mišiće trbuha, ali do danas ne postoje dokazi o tome (Ekblom-Bak i Ekblom 2012, citirano u Grooten *et al.,* 2013). Pri aktivnom sjedenju često se koriste stolice koje s namjerom nemaju potpuno stabilno postolje stolice, kada često dolazi do toga da je centar mase tijela nešto viši nego kod klasičnog sjedenja. Posljedica takvog položaja na ljudsko tijelo još uvijek nije potpuno poznata. Istraživanja pokazuju da korištenje lopti za vježbanje (tzv. pilates lopte) za aktivno sjedenje u uredu uzrokuju uspravniji i pravilniji stav gornjeg dijela tijela i povećanu mišićnu aktivnost, ali i veću neudobnost nego uredske stolice (Gregory, Dunk, i Callaghan 2006; Kingma i van Dieen 2009, citirano u Grooten *et al.*, 2013). Zanimljivo je da u istraživanju koje su proveli Grooten i suradnici (2013) rezultati nisu potvrdili početnu tezu već je otkrivena manja mišićna aktivnost i manje naginjanja prilikom sjedenja kod stolica koje zapravo potiču takvo sjedenje, nego li kod klasičnih uredskih radnih stolica. Poznato je da dulje sjedenje umara ljude, umor vodi do opuštanja tijela iz pravilnog sjedećeg položaja u nepravilan što dugoročno dovodi do oboljenja.

Stolovi s promjenjivim radnim položajem (stajanje-sjedenje) nude neku vrstu rješenja za taj problem (Schwartz *et al.*, 2016). Schwartz (2019) je u svom istraživanju zaključio da nema dokaza koji ukazuju na srednjoročne promjene u kognitivnim izvedbama kada se promatra reakcijsko vrijeme, brzina rada i koncentracija. Ustanovljeno je da se korištenjem radnih stanica koje imaju stolove s mogućnošću podešavanja za rad prilikom sjedenja i stajanja, vrijeme sjedenja smanji za otprilike 171 minutu po radnom danu. Smatra se da takvo smanjenje vremena sjedenja rezultira povećanoj fizičkoj aktivnosti, a smanjuje se mentalni umor što dovodi do povećanja pažnje, koncentracije i pamćenja (Schwartz *et al.*, 2019).

1.1.2.3. *Stajanje prilikom rada u uredu*

Kao što prekomjerno sjedenje loše utječe na zdravlje čovjeka tako i prekomjerno stajanje na mjestu loše utječe na zdravlje, prvenstveno na noge i stopala. Moguća su nateknuća stopala ili koljena, a u kombinaciji s neudobnim cipelama se to potencijalno dobro iskustvo za čovjeka može pretvoriti u loše. Smatra se da je jedan od negativnih učinaka sjedenja na ljudsko zdravlje smanjena potrošnja kalorija koja može dovesti do debljanja. Stajanje prilikom rada aktivira mišiće za održavanje ravnoteže što rezultira većom potrošnjom kalorija. Preporuka je da osobe s uredskim radnim mjestima trebaju tijekom radnog dana četiri sata provesti u laganoj fizičkoj aktivnosti (stajanje, hodanje i sl.). Procjenjuje se da je 39 % odraslih ljudi diljem svijeta pretilo, dok taj postotak iznosi 69 % u razvijenim zemljama poput SAD-a (Gibbs *et al.*, 2017).

Jedan od općih zaključaka na istraživanja provedenih u školama u kojima su zamijenjene klasične školske stolice i stolovi s visokim stolovima jest da školska atmosfera u kojoj se prakticira stajanje ispred sjedenja ili kombinacija stajanja i sjedenja ispred sjedenja umanjuje šansu za nakupljanjem kilograma zbog veće kalorijske potrošnje prilikom stajanja, ali i pozitivno djeluje na koncentraciju, pažnju pa čak i produktivnost (Blake, Benden i Wendel, 2012). Stolovi namijenjeni za rad pri stajanju imaju jedan nedostatak, a to je da su namijenjeni za rad samo prilikom stajanja te često nemaju mogućnost podešavanja po visini, odnosno jedna dimenzija stola mora odgovarati svima, što ergonomski nije ispravno. Svaki čovjek se svojom antropometrijom razlikuje od ostalih te mu zapravo treba stol koji može biti jednokratno prilagođen upravo njemu. Prednost takvih stolova je što su cjenovno puno prihvatljiviji od višekratno podesivih ili automatiziranih podiznih stolova. Postoje i druga rješenja u obliku dodatnih konstrukcija (umetaka, podložaka i sl.) koje se stave na stol i koje imaju mogućnost podešavanja po visini, ali njihov nedostatak je pretjerano zauzimanje površine stola. Slika 9 prikazuje stol koji ima mogućnost podešavanja po visini kako bi bio prikladan za rad prilikom stajanja



Slika 9. Prikaz radnog mjesta za rad prilikom stajanja

Izvor: Web 4

O važnosti kretanja pisao je Ramazzini još prije 300 godina, kada je objasnio zašto ljudi koji rade stojeći, a ne hodajući, budu toliko umorni na kraju dana: jer pri stajanju uvijek isti mišići moraju stalno biti

napeti kako bi se održala stabilnost. Ramazzini je savjetovao da radnici ne sjede ili stoje mirno, već da se kreću i fizički vježbaju u slobodno vrijeme (Kroemer i sur. 2003, citirano u: Vlaović, 2009).

1.1.3. Udobnost uredskih radnih stolica

Udobnost se može odnositi i na osjećaj udobnosti i na osjećaj neudobnosti. Na isti način većina istraživača i praktičara smatraju da su udobnost i neudobnost dva polarna pojma. Udobnost sjedenja zasniva se na mehaničkoj, psihofizičkoj i psihološkoj udobnosti, kao i na navikama sjedenja, znanju o sjedenju i dr. Mehaničku udobnost osiguravaju konstrukcija uredskih stolica i njihovo udovoljavanje brojnim uporabnim zahtjevima. Psihofizičku udobnost osigurava ergonomska usklađenost stolice s korisnikom, a psihološkoj udobnosti pridonose vanjski utjecaji poput ambijenta, boja, temperature površine materijala i ostalo (Vlaović, Bogner i Domljan, 2006).

Točna definicija udobnosti namještaja za sjedenje predstavlja stanovit problem. Nekadašnji pojam udobnosti bio je povezan uz mekoću. Danas se pažnja sve više okreće prilagođenosti ljudskom tijelu. Istina je da se mekani namještaj također prilagođava ljudskom tijelu, ali to onda nosi u sebi neke druge probleme. Osnovni element današnjeg shvaćanja udobnosti je specifičan tlak koji djeluje na pojedine dijelove tijela. Taj tlak je to manji što je površina dodira ljudskog tijela i namještaja veća (Vlaović, 2005).

Ako se govori o uredskim poslovima i sjedenju, tada je jedna od značajnih uloga dobrog sjedenja kvalitetna i udobna radna stolica. U svojem istraživanju Vlaović (2010) je zaključio da najveći indeks udobnosti imaju sjedala s mrežom te da je utjecaj tvrde podloge na sjedenje primaran, iz čega proizlazi da je okvirna konstrukcija sjedala s mrežom najprilagodljivija tijelu.

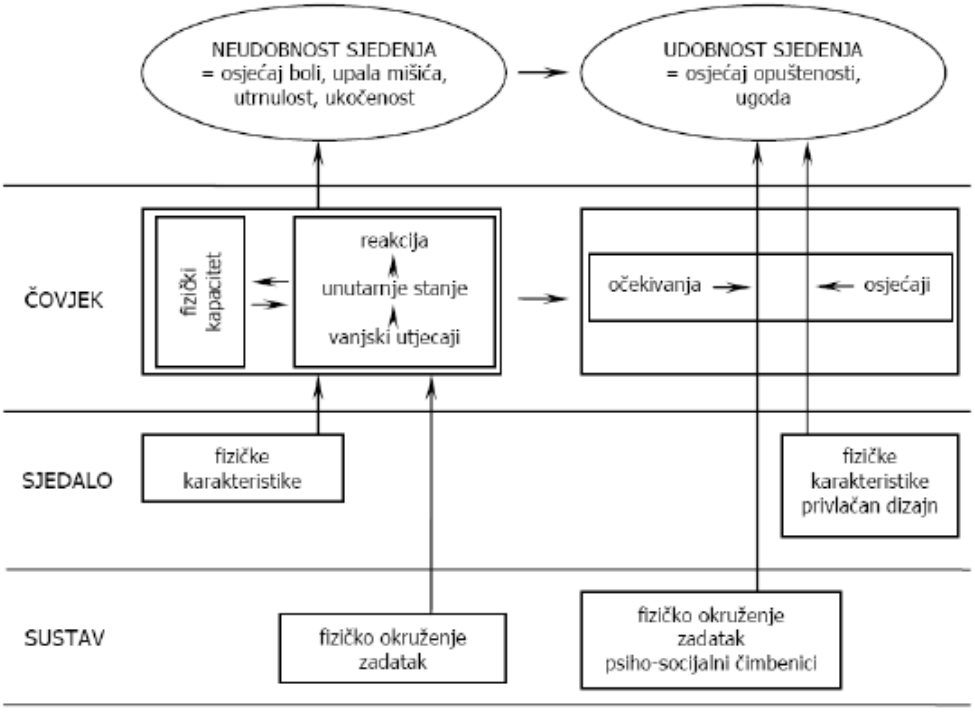
Ovisno o tome gdje pojedina osoba radi, može se razlikovati i ispravan način sjedenja. Sjedeći je položaj najčešći radni položaj modernog čovjeka u industrijski razvijenom svijetu. Neovisno o vrsti posla, pravilan i fiziološki ispravan sjedeći položaj smanjuje zamor pri radu i opterećenje kralješnice, a odgovarajući povoljan položaj pri sjedenju uvelike pridonosi povećanju koncentracije i radnog učinka. Sjedeći radni položaj moguće je razmatrati usklađivanjem antropometrijskih veličina s oblikom sjedala i naslona ili, mehaničkim pristupom, utvrđivanjem odnosa između korisnika i kvalitete sjedala, pri čemu veliki utjecaj ima indeks udobnosti. Indeks udobnosti stolice kao jedan od pokazatelja udobnosti sjedenja proizlazi iz mehaničkih svojstava promatrane stolice (Vlaović *et al.*, 2010).

Za udobno sjedenje nisu bitna samo i isključivo svojstva sjedala i naslona, već i drugi činitelji poput dojma, rasterećenosti i opće ugode i opuštenosti organizma, ali i zamora, biomehaničkih uvjeta, naprezanja i cirkulacije. Zbog metabolizma se naprimjer, neprestano izlučuju toplina i vlaga i osjećaj udobnosti ovisi o ravnoteži primanja i otpuštanja topline i vlage na mjestu dodira tijela s podlogom (Hänel i sur., 1997; Horvat, 2008, citirano u: Vlaović, 2010). Stoga je osjećaj udobnosti povezan s parametrima kao što su tlak, temperatura i relativna vlaga na mjestu dodira tijela s podlogom. *Mehanička udobnost* definirana je kao dio ukupne udobnosti koja ovisi o raspodjeli dodirnog tlaka po ljudskom tijelu u dodiru sa sjedalom. Dodirni tlak, njegova raspodjela i vrijeme djelovanja glavni su čimbenici mehaničke udobnosti.

Prema tome su De Looze i suradnici (2003) pretpostavili da se različiti čimbenici udobnosti i neudobnosti sjedenja mogu raščlaniti na tri (3) osnovne razine (slika 10):

1. Sustav – na razini sustava važnu ulogu nemaju samo fizičke osobine već i psihosocijalni čimbenici kao što su zadovoljstvo na poslu i društvena potpora.
2. Sjedalo – na razini sjedala na osjećaj udobnosti može, uz fizička obilježja, utjecati njegov privlačan dizajn.
3. Čovjek – na razini čovjeka utjecajni čimbenici podrazumijevaju individualna očekivanja i druge individualne osjećaje ili emocije.

Općenito se može reći da su u tome modelu na jednoj strani živi činitelji – čovjek sa svojim osobinama, a na drugoj strani neživi – stolica i materijali od kojih je napravljena te njihova svojstva kao što su gustoća, tvrdoća, masa i ostalo (Vlaović *et al.*, 2010).



Slika 10. Prikaz teorijskog modela udobnosti i neudobnosti te njihovih čimbenika na razini čovjeka, sjedala i sustava

Izvor: De Looze *et al.,* 2003, citirano u: (Vlaović, 2005)

Za ispitivanje udobnosti postoje subjektivne i objektivne metode. Subjektivne metode su najčešće u obliku upitnika koji sadrže skale udobnosti i neudobnosti i koriste se za procjenu udobnosti i neudobnosti te jesu li udobnost i neudobnost dva polarna pojma. Objektivne metode u usporedbi sa subjektivnima mogu imati neke prednosti: potrebno je manje vremena, manje ispitanika, manja sklonost greškama i sl. Kod objektivnih metoda se koriste razna mehanička pomagala koja mjere određena svojstva (Vlaović, 2005).

2. CILJ ISTRAŽIVANJA

U moderno doba čovjek mora sve više i dulje sjediti, a sve većom digitalizacijom i informatizacijom poslova i aktivnosti vjerojatno će sjediti još i dulje tijekom radnoga vremena.

Cilj ovog rada je na temelju nalaza i zaključaka suvremene literature u dostupnim bibliografskim bazama podataka napraviti pregled stanja tehnike i tehnologije primijenjenih osjetnika (senzora) pri sjedenju na uredskim stolicama, u smislu prevencije određenih bolesti i povećanja zdravlja korisnika. Odnosno, istražiti kako senzori položaja i navika sjedenja, te kako informacije dobivene takvim senzorima utječu na poboljšanje položaja sjedenja i na zdravlje.

3. MATERIJALI I METODE ISTRAŽIVANJA

3.1. Način odabira relevantne literature

U ovom poglavlju bit će opisan način pretrage navedenih citatnih baza i baza znanstvenih članaka s cjelovitim tekstovima: *Web of Science Core Collection, Scopus* i *IEEE Xplore.*

U ovom radu obrađene su poznate relevantne baze po jasno definiranim parametrima, dobiveni radovi su potom pregledani te je odlučeno ulaze li u područje koje zahvaća tema ovog rada ili ne. Svaka od navedenih baza pretraživana je na jednak način, s jednakim parametrima te će biti prikazani rezultati pretrage i koliko je članaka odabrano nakon procjene radi li se o relevantnom članku za ovaj rad.

Pretraživani su članci isključivo na engleskom jeziku, u razdoblju od 2010. do 2020. godine s ključnim riječima: *"smart chair"* i *"sensor chair"*. Korištene su obje riječi smart chair i sensor chair bez navodnika uz uporabu Booleva operatora „AND“. Niže u tekstu je jasno opisano s uputama „korak po korak“ kako je svaka baza pretraživana. Važno je napomenuti da se kod nekih baza tek nakon prve pretrage otkrilo polje koje je trebalo označiti i potom osvježiti stranicu da bi dobili radove sa slobodnim pristupom.

Nakon dobivanja rezultata, u prvom koraku je provjereno odgovara li naslov i sažetak svakog članaka spomenutim uvjetima. Nakon toga su odabrani članci u drugom koraku detaljno provjereni na koji način su sukladni s temom ovog rada. Na kraju su, u trećem koraku, odabrani radovi koji su najuže vezani s temom ovog rada, a koji obrađuju teme "pametnih stolica".

Parametri za pretraživanje:

- Ključne riječi: smart chair, sensor chair
- Vremensko razdoblje: 2010. – 2020.
- Jezik objave znanstv. članaka: engleski
- Vrsta pristupu baze: slobodan pristup (*open source*)

Datum pretrage baze: 14. 2. 2020., Web of Science
14. 2. 2020., Scopus
18. 3. 2020., IEEE Xplore

3.2. Kratki opisi pretraživanih baza

3.2.1. Web of Science

Web of Science (WoS) je platforma u izdanju Clarivate Analytics (bivši Thomson Reuters *Intellectual Property i Science business*) putem koje su dostupne citatne baze koje pokrivaju sva područja znanosti.

Platforma sadrži više od 33.000 indeksiranih časopisa te gotovo milijardu zapisa citiranih referenci, a uključuje članke, zbornike s konferencija, izvještaje, patente i drugo. Putem Web of Science sučelja dostupne su brojne baze podataka, a za potrebe ovoga istraživanja rabljena je baza *Core Collection*

Postupak je bio ovakav: u tražilicu je utipkan prvi pojam „smart chair“ (bez navodnika), potom je dodan jedan red (odabirom na *add row*), podešen je Boolev operator AND i utipkan je drugi pojam „sensor chair“ (bez navodnika), također je potrebno podesiti filtere: engleski jezik, raspon godina 2010-2020, polje pretrage *topic* (tema rada), te pokrenuti pretragu. Nakon dobivenih rezultata potrebno je označiti kvačicu na slobodan pristup (eng. *open access*) te osvježiti stranicu odabirom naredbe *refine*.

3.2.2. Scopus

Scopus je citatna baza podataka koja indeksira izvore iz cijeloga svijeta, a uključuje više od 70 milijuna zapisa za više od 23.700 recenziranih časopisa (od kojih je više od 4.000 u otvorenom pristupu), 300 *trade* časopisa iz gotovo svih područja znanosti, više od 600 nakladničkih cjelina, 8 milijuna konferencijskih radova te više od 1,4 milijarde citiranih referenci od 1970.

Postupak je bio ovakav: u tražilicu je utipkan prvi pojam „smart chair“ (bez navodnika), potom je potrebno odabrati operator AND i utipkati drugi pojam „sensor chair“ (bez navodnika), također je potrebno podesiti filtere: engleski jezik, raspon godina 2010-2020, polje pretrage *Article title, Abstract, Keywords*, slobodan pristup, te odabrati tipku za pretragu.

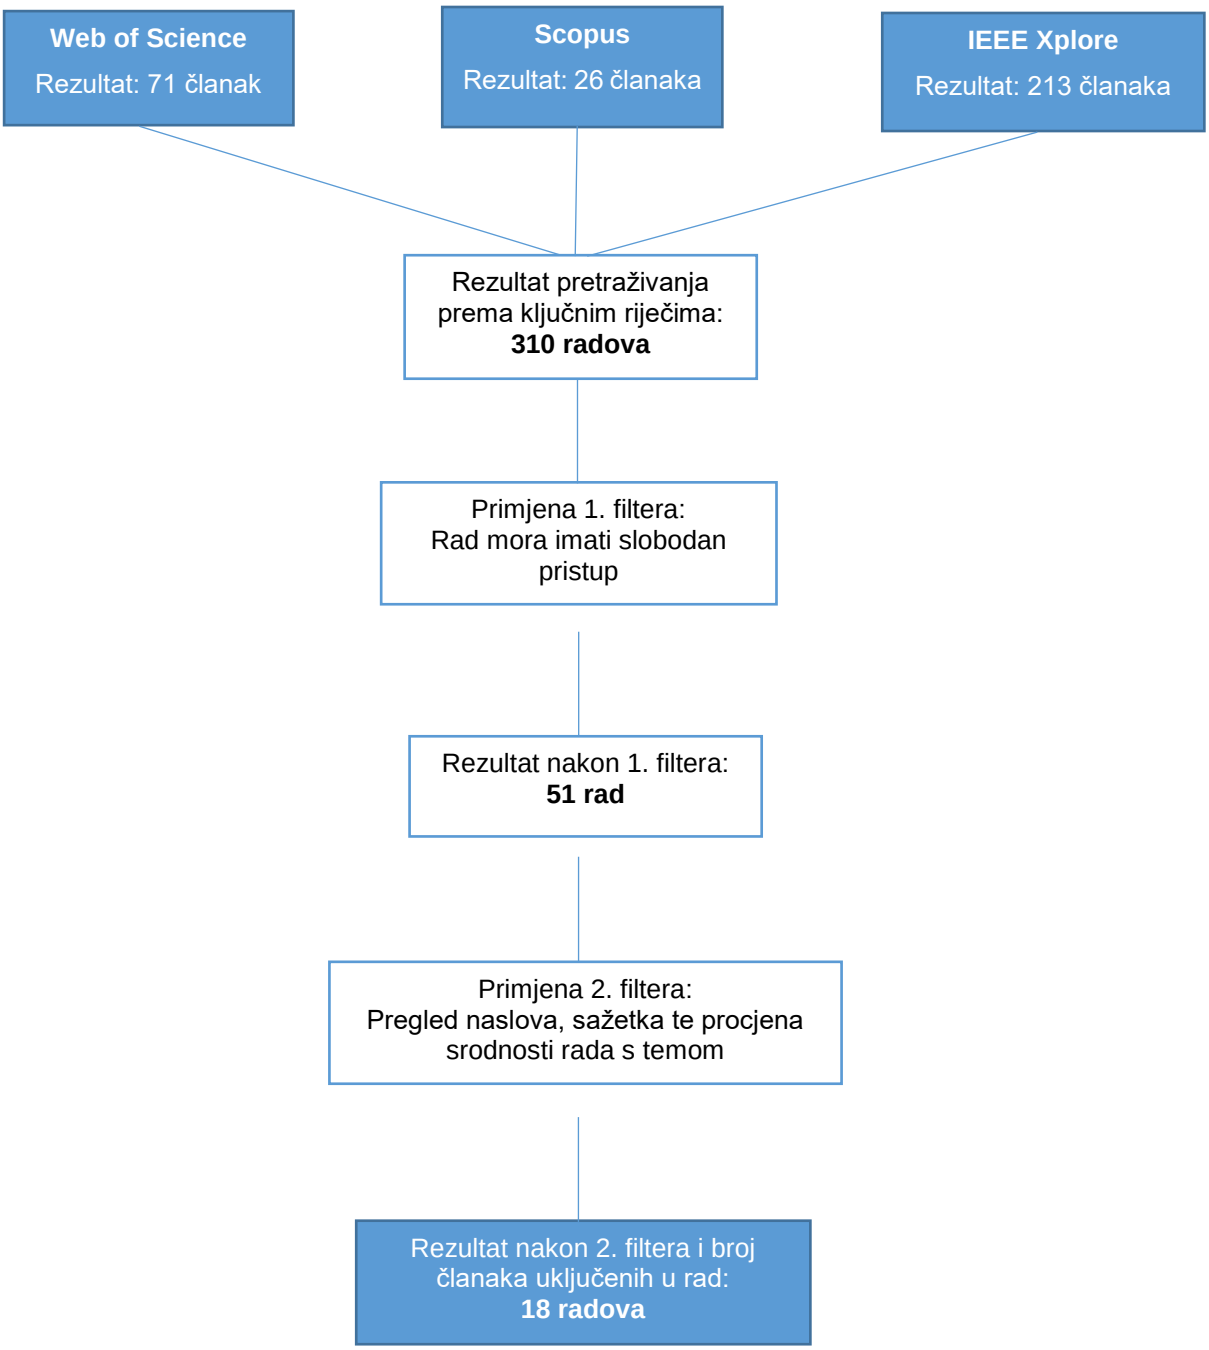
3.2.3. IEEE Xplore

IEEE/IET Electronic Library (IEL) jedna je od najopsežnijih i najznačajnijih baza znanstvenih i stručnih članaka u okviru područja elektrotehnike, računarstva, ICT-a i srodnih područja.

Baza sadrži više od 4 milijuna dokumenata s cjelovitim tekstom, više od 180 časopisa, više od 1.700 konferencijskih zbornika, više od 3.000 tehničkih standarda te više od 670 knjiga – MIT press eBooks. Dostupan sadržaj za IEEE/IE Electronic Library (IEL) seže od 1880. godine, sadržaj IEEE ASPP paketa od 2010., a MIT Press eBooks od 1943. godine s trajnim zadržavanjem prava pristupa na naslove e-knjiga u tekućoj godini.

Postupak je bio ovakav: u tražilicu je utipkan prvi pojam „smart chair“ (bez navodnika), potom je potrebno odabrati operator AND i utipkati drugi pojam „sensor chair“ (bez navodnika), također je potrebno podesiti filtere: engleski jezik, raspon godina 2010-2020, polje pretrage *All metadata,* te odabrati tipku za pretragu. Nakon dobivenih rezultata potrebno je odabrati *open access only* (slobodan pristup) i osvježiti pretragu.

3.3. Rezultati pretraživanja prema odabranim kriterijima



Slika 11. Shematski prikaz pretrage radova

4. REZULTATI ISTRAŽIVANJA

U ovome poglavlju obrađeni su znanstveni radovi koji su prema zadanim kriterijima odabrani nakon pretrage relevantnih citatnih i baza podataka cjelovitih znanstvenih članaka. Svaki odabrani rad je ukratko opisan te su iz njih izdvojeni i prikazani bitni podaci za ovaj diplomski rad. Podaci važni za ovaj rad su: vrsta senzora (senzor tlaka, senzor otkucaja srca i sl.), način rada senzora (kontaktni, beskontaktni, bežični i sl.), broj ispitanika, programska podrška, ručna ili automatska obrada podataka i sl.

Kako bi bolje razumjeli način na koji sjedimo i kakav to utjecaj ima na naše zdravlje, obrađeni su znanstveni radovi o sjedenju na stolicama u kojima su različiti senzori bili ugrađeni u različite dijelove stolica. Uz samo razumijevanje kako sjedimo, bitno je da ti senzori imaju svrhu poticanja da sjedimo udobnije, kvalitetnije i prikladnije našem tijelu te da uz minimalne promjene naših navika poboljšamo kvalitetu sjedenja, a posljedično i kvalitetu života.

4.1. Znanstveni članci koji su ispunili kriterije pretraživanja

U nastavku su prikazani odabrani članci koji su ukratko opisani i prikazani kroz najvažnije dijelove njihova teksta: ciljeve rada, opis metode, rezultate i zaključak.

Razvrstani su prema izvorima iz kojih su preuzeti (bazama), a svakome je istaknut naslov na engleskome jeziku, autori i godina izdavanja.

4.1.1. Baza *Web of Science Core Collection*

4.1.1.1. *Human activity recognition based on smart chair (Chien-Cheng et al., 2019)*

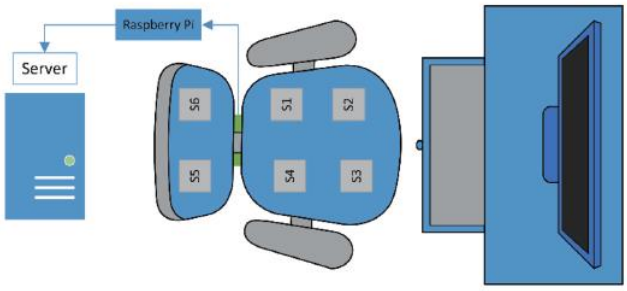
U ovome radu autori su prezentirali "pametnu stolicu" koja može otkriti i razlučiti neke dnevne aktivnosti ljudi starije životne dobi. Navodi se kako stolica ima potencijal biti izvor mnogih informacija o ponašanju ljudi, s obzirom da se većina poslova u domu obavlja sjedeći. Stolica je opremljena sa šest senzora osjetljivih na pritisak i mini računalo *Raspberry Pi* za prikupljanje podataka. Senzori u stolici preko računala šalju podatke na server gdje se analiziraju i obrađuju dok korisnik sjedi na stolici. Senzori u stolici mogu prepoznati i razlučiti pet različitih aktivnosti: rad za stolom, jedenje, drijemanje, kašljanje i gledanje televizije. Često broj aktivnosti i radnji koje se mogu razlikovati ovisi o broju senzora i njihovoj mikro-lokaciji u stolici. Međutim, previše aktivnosti koje bi računalo moralo razlikovati može dovesti do pogrešaka u sustavu pri procjeni aktivnosti. "Pametna stolica" se sastoji od šest senzora osjetljivih na pritisak, analogno-digitalni (A/D) pretvarač (MCP 3008), računala (Raspberry Pi) i standardne uredske stolice. Četiri senzora su smještena u sjedalo stolice, a dva u naslon stolice. Slika 12 prikazuje spomenute komponente.



Slika 12. Prikaz komponenti sustava
(a) senzor tlaka, (b) mikro računalo Raspberry Pi i (c) A/D pretvarač MCP 3008

Izvor: Lee, Saidy i Fitri, 2019

Senzori generiraju analogni signal kojeg A/D pretvarač MCP 3000 pretvara u digitalne signale koji su ulazni podaci računalu . Računalo šalje digitalni signal na server za obradu i analizu kao što je prikazano na slici 13



Slika 13. Shematski prikaz prijenosa podataka u stolici

Izvor: Lee, Saidy i Fitri, 2019

Da bi se moglo razlikovati zadane položaje u radu su testirane tri metode klasifikacije algoritama: slučajne šume (eng. *random forest, RF*), izrazito slučajno stablo (eng. *extremely randomized tree, ERT*) i stroj za podršku vektora (eng. *support vector machine, SVM*). Odabran je algoritam slučajne šume.

Osam ispitanika sudjelovalo je u prikupljanju podataka u fazi istraživanja. Svaka aktivnost, osim kašljanja, se izvodila po 10 minuta. Aktivnosti su se izvodile sljedećim redom bez pauze: jedenje, rad za stolom, spavanje te gledanje televizije. S obzirom na to da je kašljanje spontana aktivnost za njega je posebno izdvojeno 20 minuta. Prilikom provjere rezultata uočeno je da je u nekim slučajevima došlo do pogreške, odnosno da algoritam nije dobro prepoznao aktivnost.

Razvijena je pametna stolica koja može otkriti i klasificirati pet uobičajenih aktivnosti u sjedećem položaju. Sustav se sastojao od šest senzora tlaka, *Raspberry Pi* i uredske stolice. Četiri senzora tlaka postavljena su na sjedalo za otkrivanje informacija sudionika dok su sjedili i dvoje na naslonu kako bi uhvatili detalje kada se ispitanik nasloni. Podaci prikupljeni putem *Raspberry Pi* poslani su poslužitelju na pred obradu i analiza. Provedene su dvije faze pokusa na prikupljenim podacima nakon predaje poslužitelju. U dvije faze eksperimenti, za svako očitavanje podataka svakog sudionika, srednje vrijednosti i varijance izvlače se iz perioda od 30 sekundi s preklapanjem od 50 %. Ove su značajke izvučene domene frekvencije i vremena, što rezultira četiri značajke po senzoru. Budući da je korišteno šest senzora, vektori značajke 24-dimenzionalnosti izdvajaju se za svakog korisnika. RF i ERT klasifikatori pokazali su vrlo visoku izvedbu

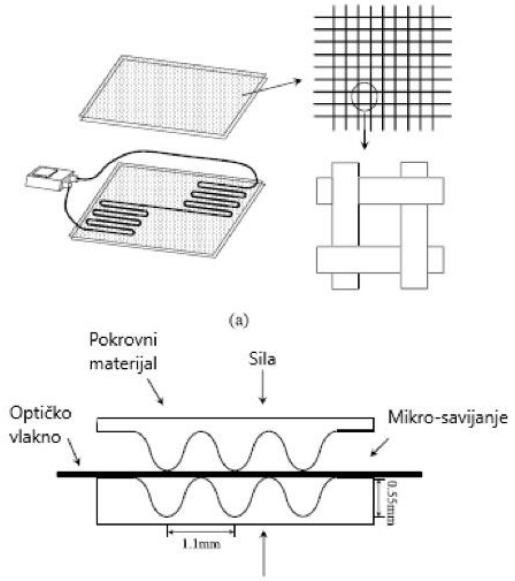
klasifikacije tijekom ispitivanja, a najviše se postiglo ERT-om. ERT je dobio do 98 % u ovisnosti o korisniku fazi i 97 % u fazi neovisnoj o korisniku.

Rezultati dobiveni klasifikatorima na pet aktivnosti pokazali su da je predloženi algoritam nadmašio sve ostale navedene u literaturi.

4.1.1.2. *Unobtrusive i continuous BCG-based human identification using a microbend fiber sensor (Yi Zhang et al., 2019)*

Rad eksperimentalno prezentira nenametljivo kontinuirano identificiranje osobe pomoću balistokardiografije (BCG) na temelju senzora koji vrši mikro-savijanje optičkog vlakna (slika 14). Balistokardiografija je tehnika dobivanja grafičkog prikaza ponavljajućih pokreta ljudskog tijela nastalih uslijed naglog izbacivanja krvi u velike žile pri svakom otkucaju srca. Autori smatraju da je takav način identifikacije osobe prigodan, odnosno da osoba samo sjedne, nasloni se, a da stolica prepozna o kome se radi.

Biometričko prepoznavanje ljudi je već nekoliko godina trend koji je pokrenula prvenstveno industrija pametnih telefona, te se kroz pametne telefone i aplikacije proširilo na plaćanje preko pametnih telefona s potvrdom otiska prsta i sl. Postoje različite vrste parametara koji se promatraju i koji se mogu koristiti za biometričko prepoznavanje ljudi, kao što su: govor, otisak prsta, skeniranje šarenice oka, fotografsko skeniranje lica (2D), skeniranje lica u 3D, prepoznavanje načina nošenja mobilnog uređaja kod hodanja, prepoznavanje samog hodanja i prepoznavanje rukopisa. U radu se navodi da postoji i metoda identifikacije pomoću otkucaja srca (EKG), ali je nezgodna jer je potrebno montirati nekoliko elektroda na tijelo osobe.

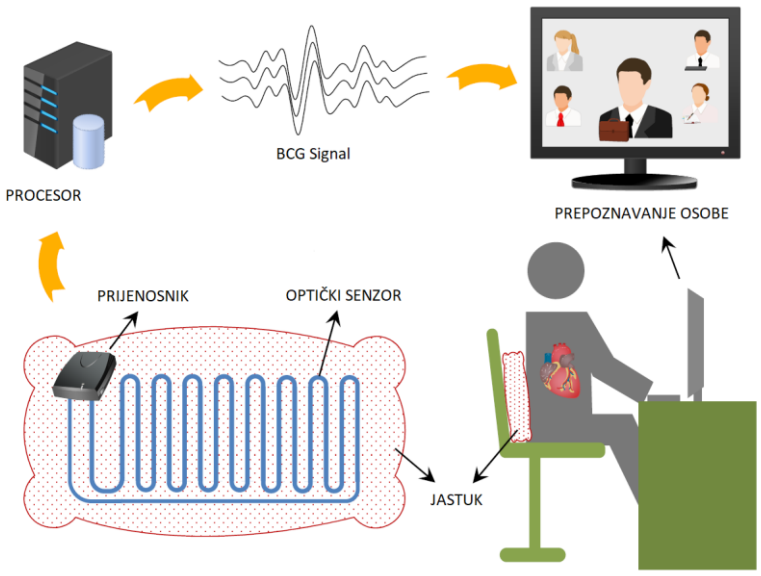


Slika 14. Shematski prikaz senzora u stolici

Izvor: Zhang *et al.*, 2019

Glavni cilj ovog rada je razvijanje jastuka sa senzorom za identifikaciju osobe koji prati BCG signale osobe koja se nasloni na jastuk. Pri tome se u senzoru događa mikro-savijanje optičkog vlakna i očitavaju

se vibracije među kojima je i otkucaj srca. Eksperimentalni rezultati pokazuju da filtrirani BCG signal otkriva obrazac BCG signala u ispitaniku. Glavna prednost ovakvog načina identifikacije u odnosu na EKG je ta da je mnogo lakše i jednostavnije za osobu da sjedne i nasloni se na jastuk, nego da se na nju trebaju spajati razne elektrode. Također, u radu se nekoliko puta napominje kako je to prvo istraživanje koje koristi senzor za BGC prepoznavanje osobe.



Slika 15. Prikaz rada jastuka za identifikaciju osobe

Izvor: Zhang *et al.*, 2019

Slika 15 prikazuje rad jastuka za identifikaciju osobe, gdje se najbolje može vidjeti prigodnost i jednostavnost korištenja takvog jastuka. Bitno je svakako da se prije identifikacije osobe na jastuku snime BCG signali pojedinca.

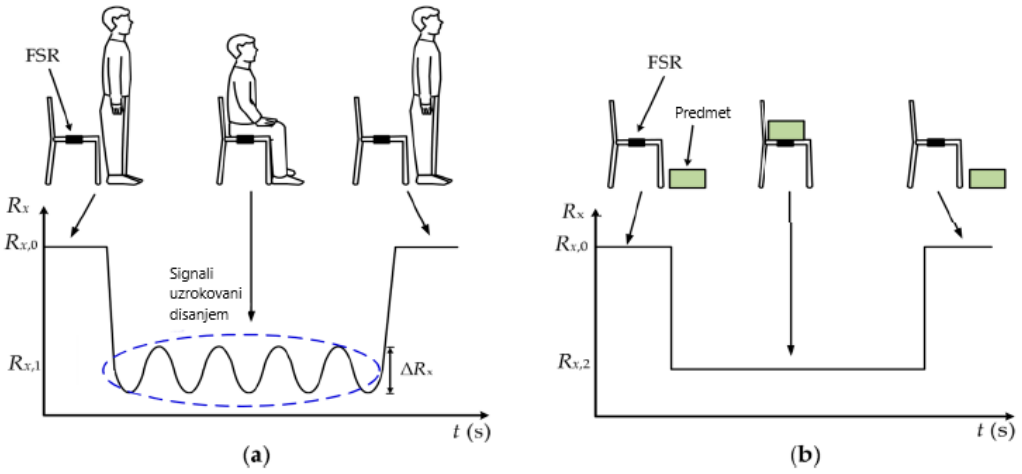
Autori preporučuju biometričku identifikaciju čovjeka pomoću BCG-a te dokazuju kako su u ovome radu dobiveni kontinuirani i dobri rezultati prepoznavanja. Autori također naglašavaju da je ovo biometrička metoda prepoznavanja koju je teže *hakirati* te da se iz tog razloga može koristiti kod vojnih vozila gdje se jasno može vidjeti tko vozi kao i vitalne funkcije. Prilikom ovog rada napravljen je i malen pokus te je ustanovljeno da se pametan telefon može otključavati ovom metodom.

4.1.1.3. *Seat occupancy detection based on low-power microcontroller i a single FSR (Sifuentes at al., 2019)*

Kako bi mogli razlikovati predmete koji su stavljeni na stolicu od osoba koje sjednu na stolicu nadzire se varijacije signala otpora koji senzor očitava prilikom disanja čovjeka.

Sustavi za očitavanje zauzeća stolice u pravilu koriste mehaničke senzore koji otkrivaju masu, tlak, silu ili ubrzanje nad stolicom. Mehanički senzori mogu biti senzori otpora (mjeri otpor koji mjerna sprava mora pružati), kapacitivni senzori (beskontaktna detekcija objekta) ili induktivni senzori (beskontaktna detekcija objekta), ali prvi je najčešći. Problem takvih mehaničkih senzora je razlikovanje nekog predmeta od žive osobe te se on rješava tako da se uspoređuju podaci po već postavljenim obrascima ili se kombiniraju podaci s još nekim senzorima. Često se kombiniraju senzori otpora sa senzorom topline i kapacitivnim senzorima. U radu se navodi primjer invalidskih kolica, odnosno kako se sjedeći položaj klasificira pomoću četiri (4) senzora tlaka i 12 senzora koji mjere otpor sili, a koji su smješteni u sjedalu i naslonu. Korist ovakvih sustava za otkrivanje kada netko sjedi na stolici te radi li se o predmetu ili osobi je moguća kod pametnih zračnih jastuka, odnosno da se uključuju zračni jastuci samo na mjestima gdje ima putnika, a npr. kod zračnog prometa da se prilikom ukrcavanja točno vidi gdje već netko sjedi.

FSR senzor čiji se otpor sili (Rx) smanjuje povećanjem sile koja djeluje na njega, detektirat će tako pojavu korisnika koji sjedne na stolicu ili predmet koji se stavi na stolicu. To je poprilično jeftin i tanki senzor koji se može lako ugraditi u stolicu, ali ima određena ograničenja po pitanju točnosti. Princip na kojem radi sustav je prikazan na slici 16 a): u prvoj fazi je sjedalo prazno (Rx = 0), u drugoj osoba sjedne na stolicu (Rx se značajno smanjuje sa Rx_0 na Rx_1 zbog djelovanja mase osobe) te dok osoba sjedi njezino disanje uzrokuje male varijacije u signalu (∆R) koji očitava senzor, što omogućava da se potvrdi da na stolici sjedi osoba.

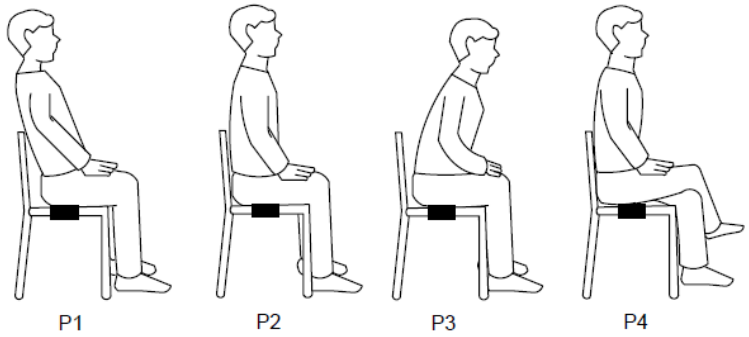


Slika 16. Prikaz rada FSR senzora i način razlikovanja osoba (a) od predmeta (b)

Izvor: Sifuentes *et al.*, 2019

Na slici 16 b) možemo vidjeti usporedbu s grafikonom kada se na stolicu stavi predmet odnosno da nema varijacija signala koje uzrokuje disanje. Slika 16 prikazuje grafičku usporedbu slučaja kada na stolici sjedi osoba u odnosu kada je na stolici samo predmet. Grafikoni prikazuju otpore sili (Rx) koji očitava senzor u odnosu na vrijeme u sekundama.

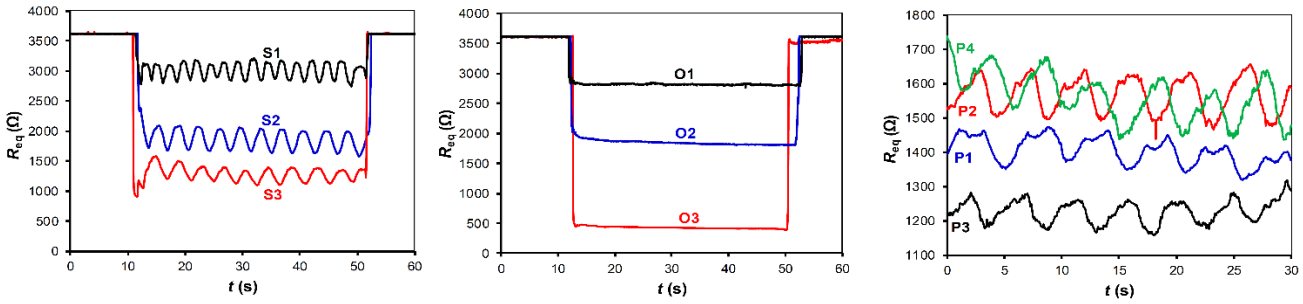
Također, u svrhu ispitivanja stolica je ispitivana s tri premeta različite mase (O1: 5 kg; O2: 10 kg; O3: 30 kg). Ispitanici su bili zamoljeni da sjednu na stolice i slobodnu dišu, ali da pri tome ne razgovaraju kako to ne bi utjecalo na mjerenje. Istraživanje je provedeno u četiri različita sjedeća položaja (slika 17.).



Slika 17. Prikaz četiri različita položaja pri kojima se provodilo mjerenje

Izvor: Sifuentes *et al.*, 2019

Rezultati ispitivanja su prikazani na slici 18 a) za različite ispitanike. Ispitanici su sjedili u periodu od 10 sekundi te se promatrala poprilično velika razlika u signalima od 600 do 2400 Ω kod različitih ispitanika različitih masa. Kod najtežeg ispitanika (S3) očitani otpor je pao na prosječnu vrijednost od 1250 Ω. Prilikom sjedenja očitana je varijacija otpora od otprilike ± 125 Ω uz 12 udisaja u minuti za S3 i 24 udisaja u minuti za S1. Na slici 18 b) su prikazani rezultati mjerenja predmeta i njihove očitane razlike zbog mase. Iako se radi o manjim iznosima mase od onih kod ispitanika, rezultati su gotovo slični i to zato jer je predmet malih gabaritnih dimenzija te on stvara veći jedinični tlak (djeluje na manjoj površini, dok je kod osoba to djelovanje raspodijeljeno na veću površinu).



a) b) c)

Slika 18. Prikaz rezultata ispitivanja
(a) kod osoba, (b) kod predmeta, (c) kod osoba po različitim sjedećim položajima

Izvor: Sifuentes *et al.*, 2019

Slika 18 c) prikazuje varijacije otpora sila prilikom sjedenja po različitim sjedećim položajima. Položaj P4 pruža manje stabilne rezultate od ostalih, vjerojatno zato jer su ispitanici u tom položaju imali prekrižene noge.

Ovaj rad dokazuje da je detektiranje i analiziranje prisutnost osobe prilikom sjedenja izvedivo korištenjem FSR senzora. Predloženi sustav prvo detektira osobe pomoću njihovih masa, a potom i razlikuje osobe od neživih predmeta detektirajući disanje. Predlaže se da se ovakav sustav poveže sa

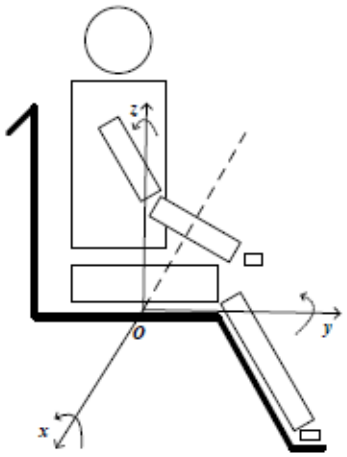
složenijim autonomnim sustavom koji svojim doprinosima može dati širu sliku osoba koje sjede na stolicama, poput već spomenutih pametnih zračnih jastuka i slično.

4.1.1.4. *Activity level assessment using a smart cushion for people with sedentary lifystyle (Ma et al., 2017)*

Postavljanjem pametnog jastuka na stolicu možemo promatrati način sjedenja korisnika koristeći senzore ugrađene u jastuk. Posebno se obraća pažnja na model za analizu načina sjedenja kako bi se prepoznale navike sjedenja. U radu se prezentira jastuk koji sadrži senzore osjetljive na tlak i senzore inercije.

Mnoge naše dnevne aktivnosti kao što je rad za stolom, gledanje televizije, jedenje, putovanja do posla i druge, dovode nas u stanje prekomjernog sjedenja. Stoga je važno promatranje sjedećih aktivnosti i procjenjivanje razine napora fizičke aktivnosti. Kako bi se istražila razina aktivnosti kod ljudi s pretežito sjedećim načinom života razvili su pametan jastuk koji ima mogućnost praćenja sjedećih položaja. Aktivnost može biti prepoznata, a razina aktivnosti se kvantificira kako bi se moglo podsjetiti korisnike da je potrebno vježbati ili napraviti pauzu i samim time umanjiti zdravstveni rizik.

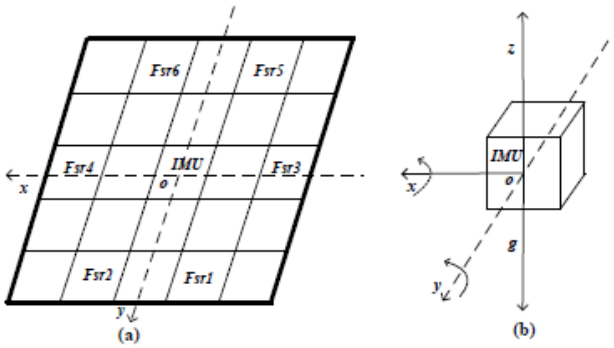
Temeljem prijašnjih istraživanja na temi analize načina sjedenja, autori su razvili tzv. *Body posture analysis model* (BPAM), tj. model sjedećeg ponašanja promatrajući tri dijela tijela: trup, stražnjica i bedra kao što je i prikazano na slici 19. Definirali su prednje i stražnje strane senzora u odnosu na lokaciju tijela po X-osi, lijevo-desno po Y-osi, te gore-dolje po Z-osi.



Slika 19. Analiziranje načina sjedenja modelom sjedećeg ponašanja

Izvor: Ma *et al.*, 2017

Korištena su dva tipa senzora u jastuku: šest senzora osjetljivih na tlak i 9-osnih inercijskih mjernih jedinica (IMU). Shematski prikaz senzora prikazan je na slici 20.



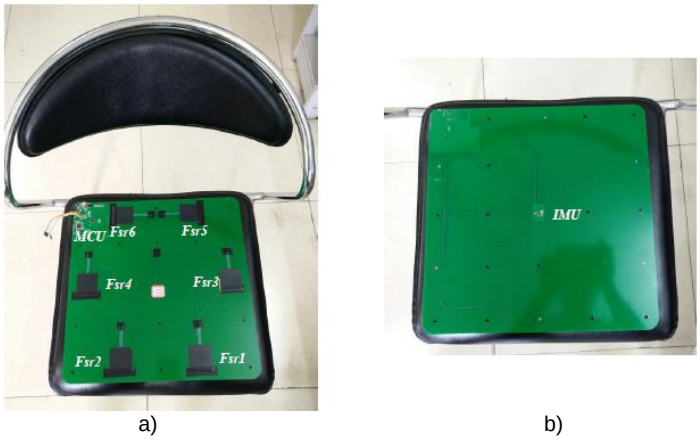
Slika 20. Shematski prikaz senzora u jastuku
a) raspored senzora osjetljivih na tla; b) IMU senzor s prikazom triju osi

Izvor: Ma *et al.*, 2017

U ovom radu istraživani jastuk prikazuje tri prednosti: 1) integrirana jedinica koja kombinira senzore osjetljive na tlak i ubrzanje; 2) jednostavna implementacija budući da se svi senzori nalaze u jastuku i 3) neinvazivan je kao uređaj za praćenje sjedećih položaja i aktivnosti.

Korišteni senzor za očitavanje tlaka je FSR406 (*Interlink Electronics*). Kako se sila primjenjuje na njegovo osjetno područje, iznos otpora tlaka bit će na odgovarajući način podešen. Raspon očitavanja tlaka je od 1,5 do 150 kg/cm^2. Ako se uzme u obzir da su dimenzije prosječnog sjedala stolice dimenzija 40 cm širine i 40 cm dužine, sjedalo je podijeljeno na 5 polja po širini i 5 po dužini. Šest senzora osjetljivih na tlak je pojedinačno smješteno na različita polja.

Slika 21 prikazuje matičnu ploču pametnog jastuka, gdje je pod a) prikaz gornje stane ploče, a pod b) je prikaz donje strane ploče. U lijevom gornjem kutu je kontrolna jedinica matične ploče koja se sastoji od nekoliko komponenti: mikro upravljača (MCU), *bluetooth* jedinice za povezivanje za prijenos podataka, vibracijskog elektromotora upravljanog MCU-om kako bi se alarmirao korisnik te napajanja.



a) b)

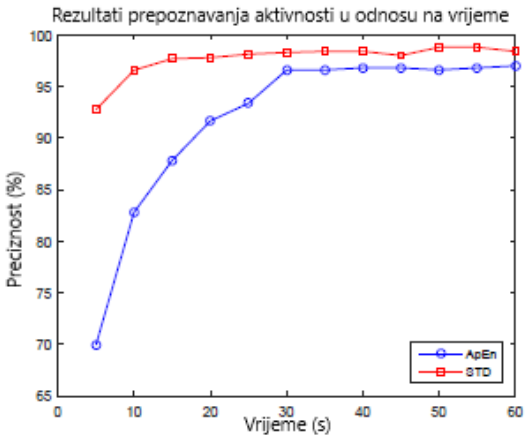
Slika 21. Prikaz matične ploče sa senzorima
a) Gornja stana ploče; b) donja strana ploče

Izvor: Ma *et al.*, 2017

Koristeći pametan jastuk, u stanju su prikupljati vremenski zapis ispitnih podataka. Kod istraživanja i eksperimenta korištena su invalidska kolica iz razloga što osobe koje ih koriste sigurno prekomjerno sjede,

stvara se veliki pritisak na stražnjicu čime se umanjuje protok krvi, a što pak dovodi do ozljede tkiva, koje u nekim slučajevima mogu dovesti do pojave rana.

U prosjeku je ispitivanje trajalo dva sata i ispitanici su morali napraviti šest ispitivanja kroz dva tjedna. Prilikom ispitivanja mogli su malo i stajati ali su morali što je više moguće sjediti u kolicima te su mogli sami odabrati period za testiranje i morali su izvoditi učestale aktivnosti u invalidskim kolicima: čitanje knjige, rad na računalu za radnim stolom, razgovaranje, njihanje (naprijed-nazad ili lijevo-desno) i tjelesna aktivnost (npr. dizanje utega)



Slika 22. Prikaz rezultata prepoznavanja aktivnosti grafikonom

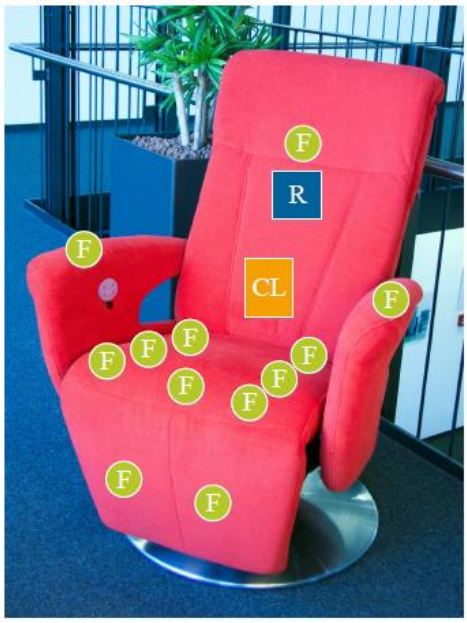
Izvor: Ma *et al.*, 2017

Prepoznavanje aktivnosti i procjena razine ljudi sa sjedilačkim načinom života vrlo su korisni i mogu promovirati tjelesno vježbanje i dovesti do aktivnijeg života. Autori su u ovom radu predložili metodu klasifikacije aktivnosti i procjenu razine aktivnosti pomoću novo dizajniranog pametnog jastuka. Jastuk kombinira senzore tlaka i IMU bolje od prethodnih sustava. Prikladan je za praćenje ponašanja u sjedećem položaju u kontekstima kao što su radno mjesto, automobil ili u invalidskim kolicima, a može se lako implementirati s jeftinim ugrađenim uređajima. Izvršeni su eksperimenti na korisnicima invalidskih kolica; izvršeno je prepoznavanje aktivnosti i procjena razine aktivnosti s točnošću od 98 % (slika 22).

4.1.2. Baza *IEEE Xplore*

4.1.2.1. *A connected chair as part of a smart home environment (Hesse et al., 2017)*

Rad predstavlja stolicu koja u sebi ima integrirane senzore, sustav za podizanje, bežični prijenosnik i kontrolnu jedinicu. Senzori su u stanju promatrati disanje, otkucaje srca i aktivnosti korisnika prilikom sjedenja. Sustav za podizanje koristi se za podešavanje stolice prema potrebama korisnika, bežični prijenosnik koristi se za povezivanje bežičnih senzora s jedinicom za prikupljanje i obradu podataka. Ugrađeno je nekoliko senzora za očitavanje otpora sili (FSR), galvanski senzor za reakciju na kožu (GSR) i senzor za beskontaktno mjerenje rada srca i disanja. Mikro upravljač prikuplja podatke sa senzora, kontrolira rad sustava za podizanje i bežično komunicira s kontrolom jedinicom za obradu i pohranu podataka putem *bluetooth* tehnologije. Slika 23 prikazuje stolicu koja sadrži sve nabrojene senzore s označenim njihovim smještaj u stolici.



Slika 23. KogniChair stolica s integriranim senzorima
F – senzor za očitavanje otpora sili; R – senzor za beskontaktno mjerenje rada srca i disanja; CL – kontrolna jedinica

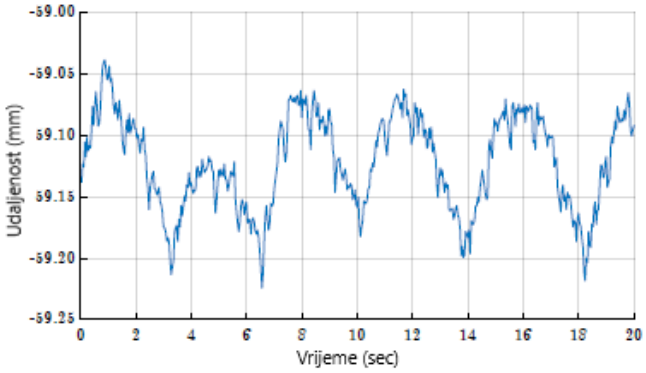
Izvor: Hesse *et al.*, 2017

Jedan od najvažnijih čimbenika koji se mora svakako osigurati u ovoj stolici je da svi senzori, sva promatranja i sva mjerenja budu bez ometanja korisnika prilikom korištenja stolice. U radu se spominje da je ovakav koncept stolice izveden za jednu stomatološku ordinaciju.

U *KogniChair* stolicu ugrađeno je ukupno 12 FSR senzora (proizvođača *Interlink Electronics*), sedam (7) u sjedalo, dva (2) u odmorište za noge, po jedan (1) u svaki naslon za ruke, i jedan (1) u naslon za leđa. Sve komponente su potpuno integrirane u stolicu.

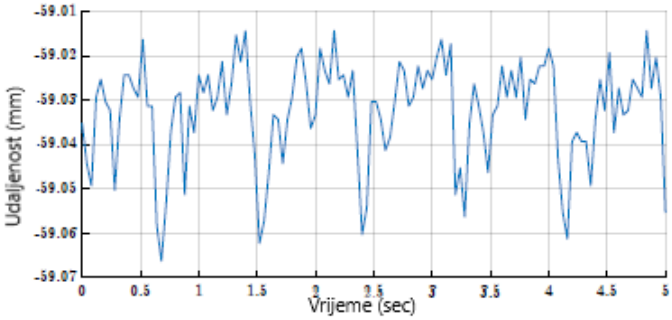
Kod primjene ovakve stolice se u radu dosta naglašava potencijal stolice takvog tipa u sklopu pametne kuće. Odnosno, FSR senzor može se koristiti i za očitavanje prisutnosti, odnosno, stolica očita da je netko sjeo na nju te sustav prepozna u kojoj prostoriji koju svjetiljku ili grijanje treba uključiti. Moguće je

prepoznavanje obrazaca sjedenja korisnika i utjecaj navika korisnika na zdravlje. Senzor za beskontaktno mjerenje otkucaja srca i disanja mjeri pomake tijela koje uzrokuje disanje (slika 24) i kucanje srca (slika 25).



Slika 24. Grafički prikaz neobrađenih podataka dobivenih senzorom za mjerenje disanja.

Izvor: Hesse *et al.*, 2017



Slika 25. Grafički prikaz neobrađenih podataka dobivenih senzorom za mjerenje otkucaja srca

Izvor: Hesse *et al.*, 2017

Sustav za podizanje pomaže korisnicima da lakše sjednu i ustanu, što je naročito korisno za pripadnike starije populacije. Sjedalo je podignuto te čim korisnik sjedne na sjedalo, što se detektira pomoću FSR senzora, stolica se podesi u preferirani položaj. Ako korisnik želi ustati, sjedalo se podigne i ostaje u tom položaju dok korisnik ne ustane. Sustav za podizanje se može iskoristiti tako da se stolica podesi u položaj koji korisniku najbolje odgovara prilikom gledanja npr. filma i sl. Ova stolica se odnosi na čitav sustav koji je u fazi razvoja, s ciljem da se u konačnici uklopi u "pametnu kuću" kao jednom cjelovitom sustavu.

Predstavljena je inteligentna i povezana stolica s integriranim FSR-ima, GSR senzorom, radarskim senzorom i sustavom za podizanje, naslonom za noge, naslonom i naslonom za glavu. Njegovim senzorima i sustavom za podizanje upravlja mikro upravljačka logika i podaci se mogu bežično prenositi. Svaka je komponenta neprimjetno integrirana tako da stolica izgleda poput naslonjača koji se naslanja u seriju. Stoga se stapa u dnevnoj sobi i može stvoriti visoku stopu prihvaćanja među korisnicima. Predstavljeni programi potencijalno mogu poboljšati dobrobit korisnika nudeći kvalificirani kondicijski trening, način opuštanja i pomoćne funkcije. Za razliku od prethodnog rada, dodatna vrijednost generira se povezivanjem stolice s pametnim kućnim okruženjem, što omogućuje i proširuje nove značajke i aplikacije.

4.1.2.2. *Assessing blood pressure unobtrusively by smart chair (Zazula et al., 2015)*

U ovom radu prezentirana je stolica s nenametljivim senzorima koji mjere funkcionalne zdravstvene parametre osobe koja sjedi na stolici. Senzori osjetljivi na pritisak smješteni su u sjedalo i naslon, dok je u rukonaslone ugrađena kombinacija elektroda u obliku slova "U" i PPG-senzor (*photoplethysmographic*) za sinkronizirano mjerenje elektrokardiografa (ECG, eng.) i PPG.

Od ljudi se često očekuje da redovito mjere krvni tlak, što znači da često moraju skidati i stavljati opremu za mjerenje tlaka te po potrebi slati podatke liječniku. Ova radnja može biti poprilično zahtjevna i često pogrešno izvedena kod osoba starije dobi. A zbog sve veće cijene zdravstvenih usluga i zbog nedovoljnog broja osoba teško je očekivati da svako mjerenja tlaka mogu izvoditi medicinske sestre. Samim time postavlja se potreba da svaka osoba može kod kuće mjeriti tlak jednostavnije i automatski, a bez potrebe za posebnim radom i pažnjom. Ako bi senzori i algoritmi mogli otkriti otkucaje srca i disanje, takav bi sustav mogao biti primijenjen u krevet i bilježiti podatke dok osoba spava što može biti korisno u bolnicama, staračkim domovima i sličnim ustanovama. Dugoročno kod takvog promatranja i korištenja senzora neinvazivnim putem donosi prednosti jer se mogu prije i točnije uočiti devijacije od normalnog stanja korisnika.



Slika 26. Uredska stolica koja je prilagođena za pokus

Izvor: Zazula *et al.*, 2015

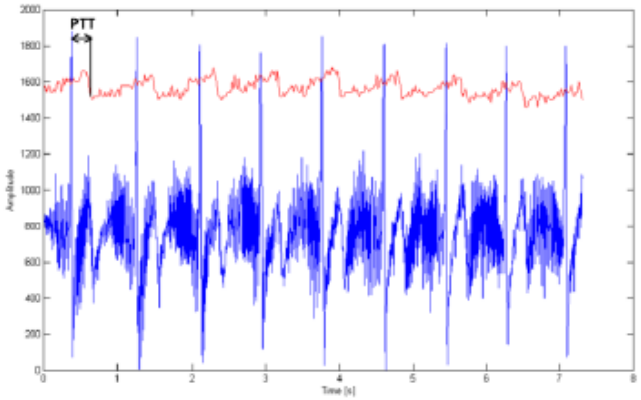
Uzevši u obzir napisano, autorima je jedino imalo smisla napraviti pametnu stolicu (slika 26.) koja kada korisnik sjedne na nju očita otkucaj srca, te preračunava rad srca, procjenjuje razinu kisika u krvi i krvni tlak, stvara nekoliko nestandardnih EKG mjerenja, mjeri temperaturu prsta, prati disanja, prati pokrete i sjedeći položaj i poziciju leđa i ostalih dijelova tijela. Fokus ovoga rada je na mjerenjima dobivenih od senzora u rukonaslonu (slika 27). Senzor pomoću fotopletizmografije - PPG (mjerenje krvnog protoka u koži prstiju uz primjenu termalnog testa) i EKG signala procjenjuje različite kardiovaskularne parametre.



Slika 27. Prikaz PPG senzora u rukonaslonu pokusne stolice

Izvor: Zazula *et al.*, 2015

Na slici 27 je prikazan PPG senzor u obliku slova "U" , takav oblik osigurava stabilan i dobar kontakt između ispitanikove kože i površine senzora. Računali su prolazno vrijeme pulsa (PTT), a kao vremenski interval uzeli vrijednosti između vrhunca EKG R vala i najbliži kasniji otkucaj srca (slika 28). Dobiveno je da je PTT obrnuto proporcionalan krvnom tlaku.



Slika 28. Prikaz EKG (Plavo) i PPG (crveno) mjerenja za omogućivanje procjene PTT

Izvor: Zazula *et al.*, 2015

Ispitivanje je provedeno na 11 zdravih muških ispitanika starosti (28,9 ± 6,6) godina, visine (180,6 ± 5,1) cm i mase (90,2 ± 16,9) kg. Svim ispitanicima je izmjeren krvni tlak prije ispitivanja kao referentna vrijednost za usporedbu. Mjerilo se je vrijeme koje je potrebno od referentnog EKG R vrhunca do PPG mjerenja. Mjerenja su rađena prilikom odmaranja i nakon vježbanja.

Nakon ispitivanja ispitanika i analiziranja podataka pronađeno je nekoliko modela za koje se smatra da su bolji od nekih drugih prilikom obrade podataka ali nisu donesene neke zakonitosti.

Autori sumnjaju da su razlog možda pojedinačne razlike u vaskularnim parametrima koji utječu na ovaj odnos. Stoga su pokušali isključiti ove razlike modeliranjem promjena krvnog tlaka od ostatka do stanja nakon vježbanja s promjenama PTT-a za svakog ispitanika. Očekivali su da bi ovo moglo zaobići međuljudske varijacije, no to nije bilo točno. Zaključak autora je ova metoda još uvijek nije dovoljno pouzdana i precizna jer nisu uspjeli dobiti očekivane rezultate.

4.1.2.3. *Design i implementation of a smart chair system for IoT (Song et al., 2016)*

U današnje vrijeme većina ljudi provodi više od polovice dana na stolicama različitih namjena i za različite potrebe kao što su učenje, vožnja ili rad. Iz tog razloga suvremeni ljudi imaju značajno veće probleme s kralježnicom, kukovima i skoliozom, koja se u prošlosti nije toliko učestalo pojavljivala. U ovom radu je prezentirana stolica sa sjedalom u dva dijela koju je proizveo *Hera-Tech* te je poznata po tome da umanjuje bolove u leđima i kukovima tako što smanjuje područje sjedenja. Kroz ovaj rad dizajniran je i implementiran prototip pametne IoT (*Internet of Things,* Internet stvari) stolice kombinirajući tip stolice s odvojenim podijeljenim sjedalom, IoT uređajem za komunikaciju i raznim senzorima za mjerenje načina sjedenja na stolici. Usto, napravljena je i aplikacija za pametne telefone koja vizualno prikazuje rezultate sjedenja. Korištenjem pametne IoT stolice, položaj sjedenja može biti lako korigiran gledajući u korisnikovu aplikaciju na mobilnom uređaju. Ovako prikupljeni podaci mogu poslužiti za razumijevanje osobnih navika vezanih za sjedenje, za ispravljanje položaja sjedenja kod djece, za pružanje medicinskih informacija medicinskom osoblju i za analizu obrazaca prilikom učenja ili rada.

Ugrađen IoT uređaj i nekoliko senzora rađenih po mjeri koji su postavljeni u stolicu očitavaju parametre korisnika prilikom sjedenja. Potom ugrađeni IoT uređaj šalje podatke dobivene iz senzora na mobilni uređaj ili na server pomoću Bluetooth 4.0 povezanosti. Na kraju, mobilni uređaj ili server primi podatke, obradi ih i vizualizira način trenutnog sjedenja u stvarnom vremenu. Prilikom ovog rada korišten je „Arduino Pro mini“ jer je jednostavan za programiranje i jer je dovoljno malen da bude neprimjetan u stolici.

Pokusi su izvođeni uporabom komercijalno dostupnih senzora (tlaka, vlaka, nagiba i sl.) kako bi procijenili mogu li se koristiti takvi postojeći senzori za ovu namjenu. Kao rezultat, zaključeno je da ti senzori nisu prikladni zbog nekoliko problema. Prvo su dizajnirali senzor tlaka koji ima potreban raspon osjetljivosti. Potom su dizajnirali analogni senzor nagiba u četiri razine koristeći DAC strujne krugove. Pametna IoT stolica koristi Bluetooth 4.0 i *iBeacon* tehnologiju za prijenos podataka ali se je uslijed ispitivanja dokazalo da *iBeacon* tehnologija nije dovoljno pouzdana. Kako bi se takav problem riješio, odlučilo se da se tijekom pokusa za prijenos podataka koristi Bluetooth 4.0.



a) Prikaz dobrog sjedećeg položaja



b) Sjedenje na prednjem rubu



c) Prekrižena desna noga preko lijeve



d) Prekrižena lijeva noga preko desne



e) Nagnut prema naprijed



f) Nagnut prema natrag

Slika 29. Prikaz raznih sjedećih položaja proučavanih u istraživanju

Izvor: *Park* et al.*, 2016*

Slike 29 a) do 29 f) prikazuju razne sjedeće položaje kao i njihove vizualizacije na mobilnoj aplikaciji posebno napravljenoj za ovu stolicu uz ove senzore. Na slikama se može vidjeti da aplikacija uspješno bilježi i prikazuje sjedeće položaje , što znači da senzor pritiska i senzor nagiba radi dobro. Stolica koja je u ovom radu prezentirana s pripadajućim senzorima i aplikacijom ima široku potencijalnu primjenu.

4.1.2.4. *An ergonomics chair with Internet of Thing technology using SVM (Prueksanusak et al., 2019)*

Kontinuirano sjedenje od jutra do večeri može ozbiljno utjecati na čovjeka u negativnom smislu kao: bolovi u tijelu, kronične glavobolje, utrnulost, nadutost, ukočenost i slično, što su sve simptomi *office syndrome*-a. *Office Syndrome* (eng.) podrazumijeva skupinu simptoma koji se javljaju kod ljudi koji rade u uredu. Odjel za javno zdravstvo je izjavio da 60 % ljudi koji imaju *Office syndrome* imaju tri karakteristična simptoma, kronični bolovi u leđima popraćeni bolovima u vratu, ramenima i glavoboljom. Radnici u skupini 16-24 godina su u opasnosti da razviju ovo oboljenje.

U ovom radu cilj je identificirati sjedeći položaj koristeći tehniku strojnog učenja. Ergonomska stolica s 10 senzora na pritisak je predstavljena kako bi zabilježila težinu u svakom dijelu stolice prilikom opterećenja. Uz to razvijena je mobilna aplikacija koja vizualno prikazuje sjedeći položaj korisnika u stvarnom vremenu i obavještava korisnika kada sjedi pogrešno. Konstatira se da postoji samo malen broj senzora koji se inače ugrađuje u stolice prilikom takvog razvijanja. Uz senzore koriste se i kamere za identifikaciju i klasificiranje načina sjedenja iz dobivene slike/snimke.

Kada korisnik sjedne na stolicu, sila koja se očitava na svakom senzoru šalje se na „oblak“ servera i tamo se očitavanja pohranjuju u bazu kao neobrađeni podaci. Te neobrađene podatke koriste kako bi ih strojevi obrađivali i učili u postupku strojnog učenja, potom se taj model sprema na server. Dobiven rezultat od predviđanja bit će također spremljen u bazu i bit će pokazan korisniku prilikom sjedenja na koji način korisnik trenutno sjedi. Ako korisnik sjedi na nepravilan način tada će ga program obavijestiti putem mobilne aplikacije kako bi promijenili položaj i samim time izbjegli Office Syndrome. Njihova ergonomska stolica (slika 30.) ima 4 senzora u naslonu i 6 u sjedalu, a ESPino32 je odabran kao glavni mikro upravljač koji ima bežičnu i Bluethooth komunikacijski modul ugrađen.



a) b)

Slika 30. Prikaz pokusne stolice s pritisnim senzorima

Izvor: Prueksanusak, Rujivipatand i Wongpatikaseree, 2019

U obzir se uzelo 5 sjedećih položaja za klasificiranje: Normalno uspravno sjedenje, Sjedenje s prekriženom lijevom nogom, sjedenje s prekriženom desnom nogom, sjedenje na prednjoj polovici stolice i sjedenje uz naslanjanje na naslon. Podaci se šalju svakih 5 sekundi na oblak. Podaci za svaki način

sjedenja su se prikupljali 2 minute po osobi. U ispitivanju je sudjelovalo 36 volontera ispitanika od kojih je bilo 22 muških, a 14 ženskih sudionika. Mobilna aplikacija koja je razvijena za Android platformu koristi se za komunikaciju s korisnicima. U mobilnoj aplikaciji nalaze se 3 glavne značajke:

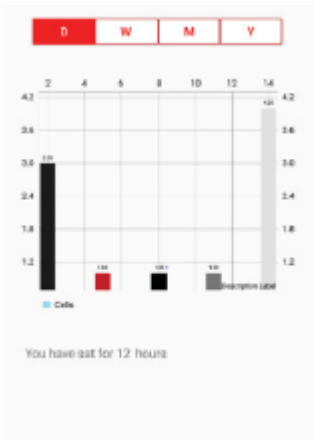
1. Kontrolna ploča (Slika 31.) je kumulativan prikaz načina sjedenja korisnika kroz dan.
2. Prikaz načina sjedenja u stvarnom vremenu (Slika 32.) je dobar jer korisnicu mogu u stvarnom vremenu vidjeti na koji od onih 5 načina sjede.
3. Grafički prikaz predstavlja odnos između podataka s ograničenim informacijama u jedinici vremena (slika 33).



Slika 31. Prikaz Kontrolne ploče aplikacije



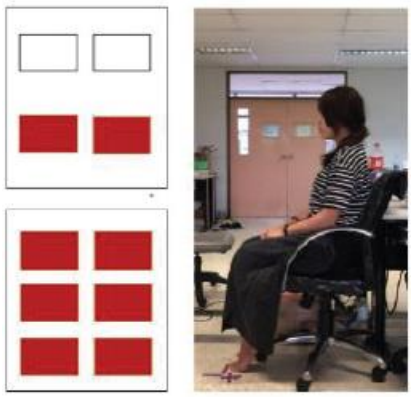
Slika 32. Prikaz načina sjedenja u stvarnom vremenu



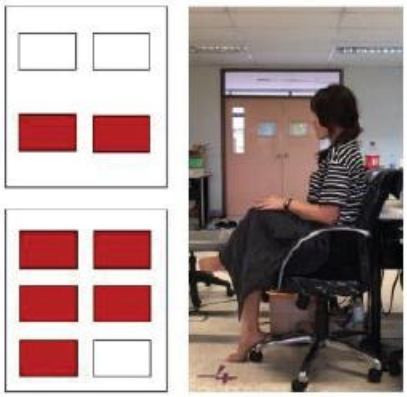
Slika 33. Grafički prikaz podataka kroz period

Izvor: Prueksanusak, Rujivipatand i Wongpatikaseree, 2019

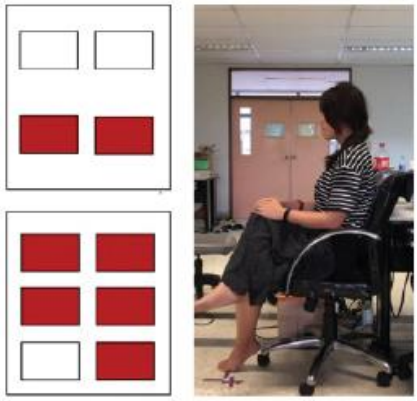
Ispitanici su sjedili u svakom od pet (5) položaja po 1 minutu i tako u dva ciklusa. Naposljetku je prikupljeno 3500 podataka o sjedenju u bazi podataka za klasifikaciju sjedenja. Slike 34 a) do 34 e) prikazuju način sjedenja prilikom ispitivanja i aktivaciju senzora na stolici.



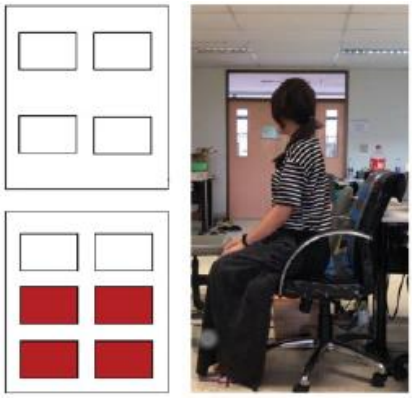
a) Normalno uspravno sjedenje



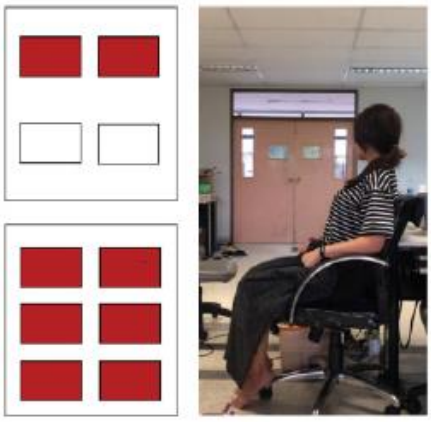
b) Prekrižena lijeva noga



c) Prekrižena desna noga



d) Sjedenje na prednjoj polovici sjedala



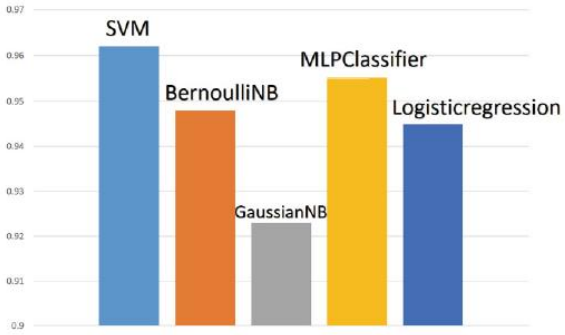
e) Sjedenje s nagibom na naslon

Slika 34. Načini sjedenja prilikom ispitivanja i aktivaciju senzora na stolici

Izvor: Prueksanusak, Rujivipatand i Wongpatikaseree, 2019

Nakon prikupljanja podataka ispitanika, analizirani su podaci kako bi se uklonili dvostruki podaci mjerenja.

Klasifikacija načina sjedenja bila je evaluirana uz pomoć pet tehnika i rezultati su pokazali da je svih pet tehnika strojnog učenja postiglo rezultate preko 90 % kod klasifikacije načina sjedenja. SVM je tehnika koja je postigla najbolji rezultat s 96,2 % (slika 35), samim tim SVM je odabran kao tehnika kojom će se klasificirati i predviđati načini sjedenja kod ove stolice. Analizirali su i detalje podataka, kod testiranja su odvajali muške ispitanike od ženskih (10 muških i 10 ženskih) kako bi se utvrdila točnost kod klasifikacije načina sjedenja kod svakog načina sjedenja.



Slika 35. Grafički prikaz rezultata strojnog učenja

Izvor: Prueksanusak, Rujivipatand i Wongpatikaseree, 2019

Svrha ovog rada bila je usmjerena na smanjenje učestalosti *Office Syndrome*-a. Korisnika se upućuje da pravilno razumije sjedenje i prepoznaje problem uredskog sindroma u sjedećem položaju. Kroz ovo istraživanje razvijena je ergonomska stolica koja kombinira ugrađeni IoT uređaj za otkrivanje položaja sjedenja pomoću senzora sile. Šest senzora sile ugrađeno je ispod površine stolice i četiri senzora sile na naslonu stolice, a zatim se podatci šalju na poslužitelj kako bi predvidjeli držanje sjedećeg položaja. Fokusirali su se na pet sjedećih položaja, uključujući ravne, sjednite s križem lijeve noge, sjednite s križem desne noge, sjednite samo polovicu stolice i naslonite se na stolicu. Za predviđanje sjedećeg položaja uspoređeno je pet tehnika strojnog učenja. SVM je postigao najveću preciznost s 96,2 %, stoga je SVM algoritam odabran za predviđanje položaja sjedenja na mobilnoj aplikaciji. Rezultat predviđanja prikazat će se korisniku putem mobilne aplikacije u stvarnom vremenu. U međuvremenu, ako korisnik ima pogrešno držanje, upozorit će korisnika putem mobilne aplikacije.

4.1.2.5. *A smart chair sitting posture recognition system using flex sensors i FPGA implemented Artificial Neural Network (Hu et al., 2020)*

Sjedenje je najčešći položaj u kojem se nalaze moderni ljudi a loš sjedeći položaj može utjecati na položaj glave u odnosu na tijelo i aktivnost mišića, uzrokovati zdravstvene probleme posebice za mlade osobe (studenti i sl.). Postojeći sustavi za prepoznavanje sjedećeg položaja koji su predloženi u literaturama mogu se kategorizirati prema tipovima senzora. Glavne vrste senzora uključuju optičke senzore, senzore za očitavanje ubrzanja, senzore pritiska i tekstilne senzori. Međutim, optički i sustavi za mjerenje ubrzanja pate od slabe robusnosti i osjetljivosti na smetnje iz okoline. Štoviše, osjećaj špijuniranja, odnosno da Vas netko neprestano promatra rezultira lošim korisničkim iskustvom.

Za rješavanje gore spomenutih problema, predlaže se rješenje s novom pametnom stolicom u okvirima novih senzora i obradom prikupljenih podataka kod prepoznavanja sjedećeg položaja. Cilj ovog rada je uvesti savitljive senzore sa strojnim učenjem kako bi se formirao čim jednostavniji sustav za prepoznavanje sjedećih položaja. U ovom radu je samo 6 pasivnih savitljivih senzora priključeno na stolicu.



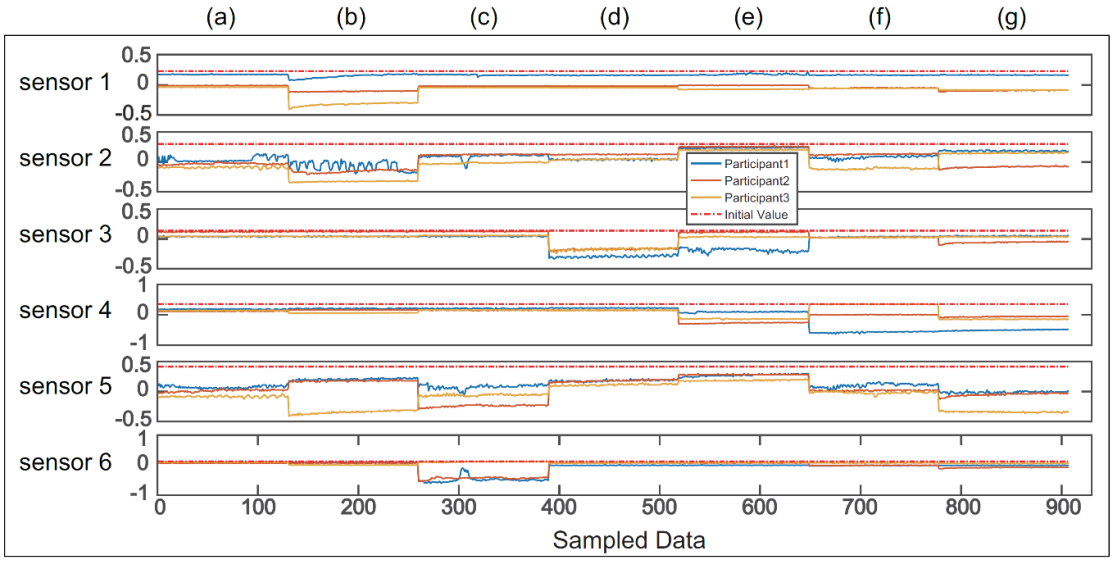
a) Ravno uspravno sjedenje | *b) Sjedenje s lijevim nagibom* | *c) Sjedenje desnim nagibom* | *d) Sjedenje u opuštenom položaju* | *e) Sjedenje sa značajnim nagibom na naslon* | *f) Sjedenje s lijevom nogom ispod desne* | *g) Sjedenje s desnom nogom ispod lijeve*

Slika 36. Odabrani sjedeći položaji za ispitivanje

Izvor: Hu, Tang i Tang, 2020

Odabrano je sedam sjedećih položaja koji su povezani sa zdravljem, a prikazani su na 36: ravno uspravno sjedenje, sjedenje s lijevim nagibom, sjedenje desnim nagibom, sjedenje u opuštenom položaju, sjedenje sa značajnim nagibom na naslon, sjedenje s lijevom nogom ispod desne, sjedenje s desnom nogom ispod lijeve. Položaji su odabrani iz nekoliko razloga: položaji a) i d) su vrlo česti položaji, držanje kod položaja b) i c) može izazvati razne zdravstvene tegobe, dok držanje u položaju e) može povećati napetost u mišićima što može uzrokovati bolove. Držanje u položaju f) i g) može nepovoljno utjecati na zdjelicu, kralježnicu i mišiće.

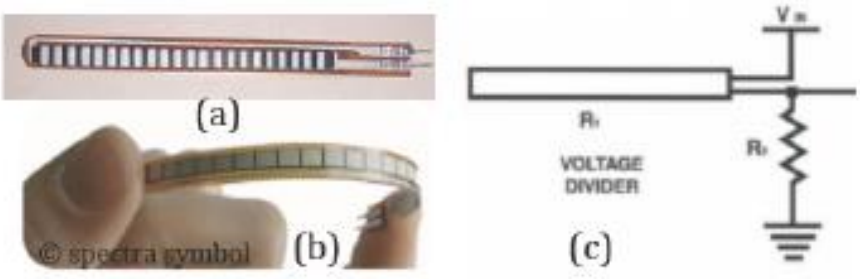
Slika 37 prikazuje snimljena mjerenja sa svih šest senzora kod troje ispitanika prema položaju sjedenja.



Slika 37. Grafički prikaz prikupljenih podataka prema različitim sjedećim položajima

Izvor: Hu, Tang i Tang, 2020

Savitljiv senzor sastoji se od polimera s vodljivim česticama i plastičnom izolacijom. Kad se savitljivi senzor savije u različite oblike, mijenja se udaljenost provodnih čestica s oblikom senzora, što rezultira razlikom otpora. Ukupna duljina senzora je 73,7 mm, a aktivna duljina senzora je 55,4 mm. Širina senzora je 6,4 mm, a debljina 0,5 mm, a težina 0,27 g.



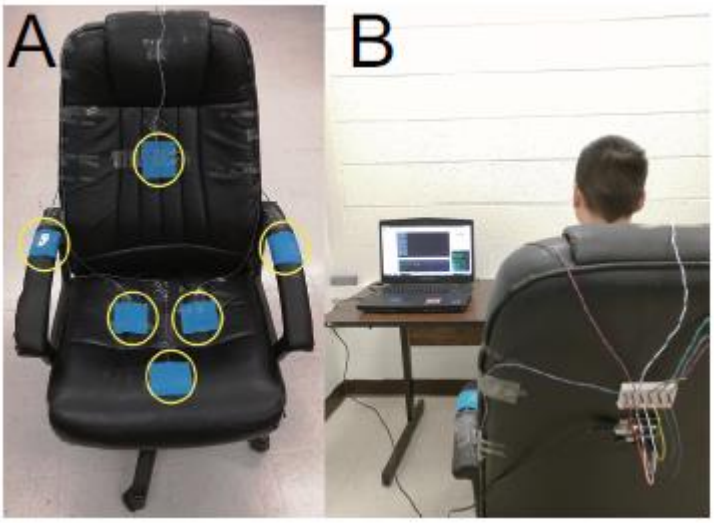
Slika 38. Prikaz savitljivog senzora korištenog u ispitivanju

Izvor: Hu, Tang i Tang, 2020

Slika 38 prikazuje savitljivi senzor: a) slika izravnatog senzora; b) Slika savijenog senzora; c) shematski prikaz senzora.

U istraživanju je sudjelovalo 11 ispitanika (4 ženska i 7 muških) s rasponom godina od 25 do 33 godine, težina varira od 45 do 95 kg, a visina od 159 do 186 cm. Ispitanici su zamoljeni da sjednu na stolicu i izmjenjuju gore spomenutih 7 sjedećih položaja, a da pri tome u svakom položaju sjede 30 sekundi za prikupljanje podataka.

Slika 39 prikazuje ugrađene savitljive senzore na stolicu koja je korištena prilikom ovog ispitivanja i fotografirana s prednje (39a) i stražnje (39b) strane.



Slika 39. Stolica s ugrađenim savitljivim senzorima

Izvor: Hu, Tang i Tang, 2020

Da bi se usporedila izvedba između različitih metode strojnog učenja, proučavali smo i vektor podrške strojnog učenja (SVM) algoritma kao alternativne metode u našem sustavu prepoznavanja sjedećeg položaja. Dobro je poznato da u usporedbi s metodama neuronske mreže, SVM s linearnim jezgrom ima jednostavnije računske operacije, što ga čini lakšim biti implementirani u nosive senzore. Nakon uspoređivanja rezultata zaključeno je da SVM ima preciznost od 88,37 % što je znatno niže od ANN koji ima 97,43 % točnosti. Sustav koji je razvijen sastoji se od kontrolnog dijela i Datapath-a.

Kontrolni dio: sadrži ADC modul, modul za kontrolu protoka i tri upravljačka modela za računanje na ulaznom sloju, skrivenom sloju i izlazu ANN-a. Sustav djeluje na sljedeći način: Prvo, ADC Upravljački modul šalje upravljačke signale na ADC i prima podaci iz ADC-a s brzinom uzorkovanja od 5 uzoraka / sekundi. Zatim modul kontrole protoka upravlja ANN-obradom teći. Izlazni upravljački modul započinje s radom nakon primanja početnog signala iz kontrolnog modula. Tada modul za kontrolu izlaza šalje upravljački signal modulu upravljanja prijenosom podataka. Nakon toga, modul kontrole prijenosa podataka pretvara podatke iz potpisanog 2 binarnog koda u pravi binarni kod koji olakšava operacije usporedbe.

Da bi procijenili rad sustava prepoznavanja sjedenja na pametnoj stolici, dobili su podatke od ukupno 11 osoba (četiri žene i sedam muškaraca). Svaka osoba je sudjelovala u eksperimentu morala je sjediti na stolici da vježba svih sedam položaja. Ispitanik zadržava jedan položaj 30 sekundi, a zatim se prebaci na drugi položaj. Sustav bilježi podatke sa senzora tijekom eksperimenta. Ukupni podaci su podijeljeni u dva dijela. Prvi dio sadrži podaci devet osoba (četiri žene i pet muškaraca) za obuku i procjenu, uključujući unakrsnu procjenu ANN modela. Drugi dio podataka (dvije osobe) koristi se samo za potvrđivanje rezultata ANN modela kako bi se izbjeglo prekomjerno preklapanje.

Prvi dio skupa podataka je prikupljen od devet sudionika i ima ukupno 9791 uzoraka iz svakog senzora. Podaci su organizirani u redove, svaki red ima šest uzoraka podataka što odgovara šest senzora. Postavljanje sustava kod prikupljanja podataka prikazano je na slici 48. Dakle, podaci svakog stupca (senzora) su normalizirani sa svojim specifičnim parametrima u rasponu između (-1) i (+1) za obuku ANN modela. Dvoslojni model s 28 čvorova u skrivenom sloju postiže točnost na 97,86 % u fazi treninga. Položaj

s nagibom prema naprijed (E) može se prepoznati s točnošću od 100 % Prema matricama zbrke, najmanja točnost, 90,1 %, zabilježena je na položaju tijela s prekriženom lijevom nogom (F).

Sustav za prepoznavanje načina sjedenja male snage bio je realiziran. Sustav je postigao točnost od 97,78 % s jednim modelom i 97,43 % s drugim modelom. Dinamična potrošnja energije je 7,35 mW s brzinom uzorkovanja od pet uzoraka / sekundi i maksimalnim kašnjenjem od 8,714 ns. Predloženi sustav donosi dulji vijek trajanja baterije, bolje korisničko iskustvo i robusnost u usporedbi na druge vrste senzorskih sustava. Koliko je poznato, ovaj rad je postigao najmanju potrošnju energije, najjednostavnije dijelove i najveću točnost među sličnim radovima. Osim toga, ovaj će sustav prepoznavanja biti dio pametnog sustav za praćenje zdravlja koji donosi velike izazove za obradu količina podataka s većom i postizanje dobre izvedbe s kompliciranim zahtjevima.

4.1.2.6. *User activity recognition based on smart chair with pressure sensors (Fitri i Lee, 2018)*

Dnevne aktivnosti koje prevladavaju kod većine ljudi su one koje obavljam u sjedećem položaju. Većina dnevnih aktivnosti izvodi se sjedeći, a to uključuje rad u uredu, objed, spavanje, gledanje filma, igranje igara itd. Studija upotrebe stolice provela se s 50 ispitanika, a zaključuje da je 50 % ispitanika potrošilo više od devet sati dnevno sjedeći, a 20 % ispitanika provelo je više od 14 sati dnevno sjedeći. Studija je koristila šest senzora pritiska za prepoznavanje tri aktivnosti među svim aktivnostima koje je obavljalo osam različitih ispitanika (tri muška i pet žena). Te aktivnosti uključuju jedenje, rad na računalu i spavanje. Točnost modela u ovom radu je iznad 97 %.

Smart stolica obrađena u ovom radu sastoji se od obične uredske stolice s dva kvadratna senzora za osjet otpora sili (FSR) na naslonu i četiri na sjedalu kao što je prikazano na slici 40. Aktivnosti su prikupljane od ispitanika koji su izvodili te tri ispitne aktivnosti što je prirodnije moguće u periodu od po 10 minuta za svaku aktivnost. Prilikom ovog ispitivanja korištena je i kamera koja je snimala ispitanike kako bi se potvrdila očitavanja senzora, odnosno kako bi se potencijalna anomalija s podacima mogla razjasniti.



Slika 40. Prikaz ispitne stolica s FSR senzorima

Izvor: Lee i Lee, 2018

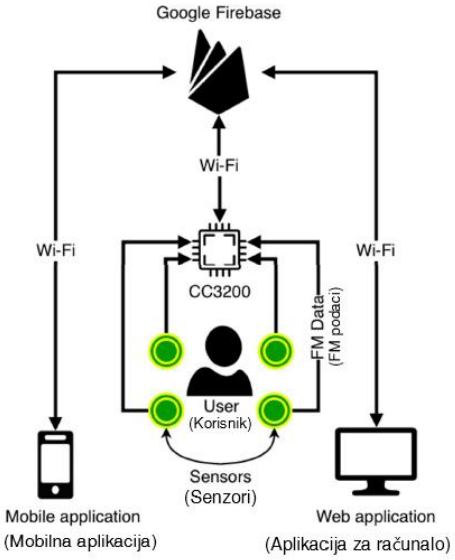
Da bi provjerili uspješnost ovog eksperimenta, provedena su dva eksperimenta. Prvi ovisi o korisniku, a drugi je neovisan o korisniku. Kod eksperimenta koji ovisi o korisniku podaci ispitanika uključeni su u skup podataka o pokusu i dostiže točnost od 97 %, a kod neovisnog o ispitaniku nema podataka koji su uključeni u testne podatke ako su ispitanici uključeni u skup podataka o pokusima i dostiže točnost od 96 %. S ugrađenih šest senzora u stolicu i ugrađena četiri senzora u sjedalo i dva senzora u naslon, učinkovit su način za postizanje veće preciznosti s ekstrahiranjem više značajki. Klasifikator slučajnih šuma korišten je za procjenu informativno testiranih ovih značajki za klasifikaciju aktivnosti. Postignute su vrlo visoke performanse klasifikacije, dobivene do 97% za korisnike i 96% neovisno o korisniku.

4.1.2.7. *Smart system for posture correction (Flutur et al., 2019)*

Jedan od ključnih elemenata ove digitalne revoluciju predstavlja Internet stvari (IoT). IoT uspijeva međusobno povezati različite objekte u cilju razmjene podataka preko mreža bez ljudske interakcije. Povezani predmeti su počeli igrati sve važniju ulogu u našem svakodnevnom životu. Međutim, medicinsko polje još nije u potpunosti prigrlilo koncept IoT-a.

U današnje vrijeme, čak i ako uredski posao ne uključuje fizički rad, sjedenje je faktor rizika za pojavu jednog od najraširenijih kroničnih oboljenja, odnosno poremećaja kralježnice, što dovodi do bolova u donjem dijelu leđa i disfunkcije pokreta. Točnije, bolovi u donjem dijelu leđa pojavljuju se kod gotovo svake odrasle osobe na svijetu. U Europi više od 50 % zaposlenih koristi računalo najmanje pola dana. To dovodi do povećanih tjelesnih neaktivnost i do ponavljajućih pokreta u ramenu, ruci, i zglobu.

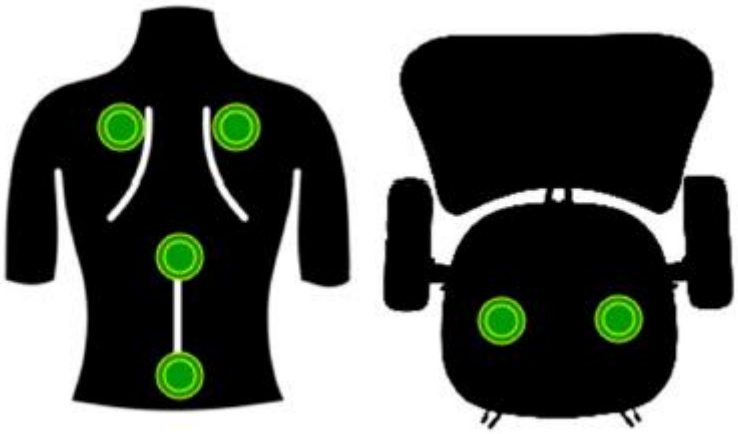
Jezgra sustava prikazana je na slici 41, a sav fokus predstavljenog istraživačkog projekta je u Single-Chip bežičnom MCU CC3200 dizajniranim od strane Texas Instruments. Senzori koji su dizajnirani prikupljaju podatke od korisnika i pohranjuju ih u CC3200 MCU jedinicu. MCU mjeri frekvencijski signal svakog senzora, a zatim podatke šalje na Google Firebase Cloud putem Wi-Fi-ja u baze podataka u JSON formatu. Sve informacije su tada procesirane i unutar specijaliziranog stvorenog mikro servisa informacije udovoljavaju standardu openEHR.



Slika 41. Prikaz rada sustava za obradu podataka

Izvor: Flutur *et al.*, 2019

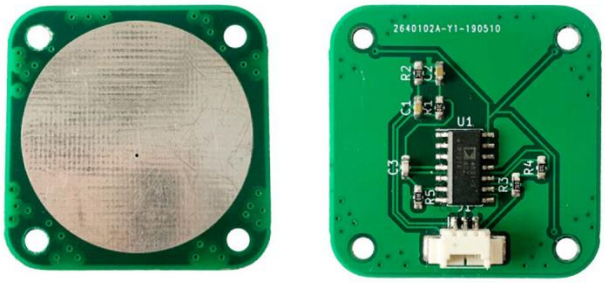
CC3200 je jedan čip proizveden od strane Texas Instruments. Odlučeno je da ga njegova procesorska moć i mogućnost povezivanja čine prikladnim izborom za MCU. U usporedbi s integracijom na drugim platformama, gdje je već implementiran Firebase API, kada je u pitanju ovaj proizvod, softver na MCU koji se bavi baza podataka bila je posebno dizajnirana za ovu jedinu svrhu. Šest senzora s kojih prikupljamo podatke nalazi se u ključnim točkama kako bi se prikupila relevantna očitanja o položaju ljudskog tijela (Slika 42).



Slika 42. Prikaz položaja senzora na stolici

Izvor: Flutur *et al.*, 2019

Osjetljivi element je kapacitivni senzor za detekciju neposredne blizine. Odabrani su senzori ove vrste jer ispunjavaju sve kriterije za primjenu u ovom radu (Slika 43). Temeljni koncept dizajniranja prve iteracije ovih senzora bio je korištenje frekvencijske modulacije za prijenos podataka s operacijskim oscilatorima na bazi pojačala. Primijećeno je da je senzorna ploča u povratnoj informaciji očitavala znatnu količinu šumova odnosno podataka koji nisu bitni i velikih varijacija zbog povećane osjetljivosti senzora, tako daj dodan referentni kondenzator.



Slika 43. *Prikaz senzora: prednja strana i stražnja strana*

Izvor: (Flutur *et al.*, 2019)

Prikupljanjem i pohranjivanjem podataka upravlja sustav oblaka (eng. *cloud*) i baza podataka u stvarnom vremenu koji pruža Google Firebase. Ovaj način nudi jednostavan pristup relevantnim informacijama za aplikacije.

Korisnik može koristiti podatke koji su predstavljeni na lako razumljiv način, da shvati na koji način i u kojem trenutku ima pogrešan sjedeći položaj. Istodobno, prepoznavši što koji je za njega ispravan položaj, korisnik može upotrijebiti obavijesti pružene internet aplikacijom (slika 53) i mobilnom aplikacijom (slika 54) kako bi bolje razumio kada sjedi neispravno, tako da se dobro držanje može pretvoriti u naviku.



Slika 44. Prikaz web sučelja aplikacije
Izvor: Flutur *et al.*, 2019



Slika 45. Prikaz mobilne aplikacije
Izvor: Flutur *et al.*, 2019

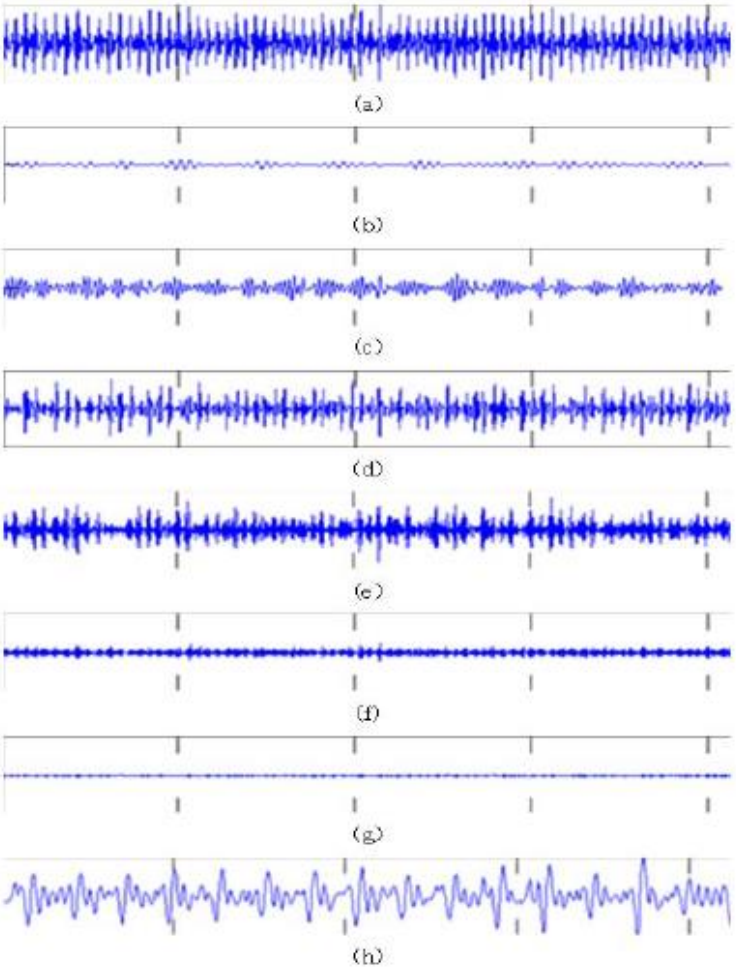
Jedna od glavnih značajki koja omogućuje raznolikost, ali i pouzdanost je način kalibracije. Pritiskom na gumb "Kalibriraj" koji je smješten u prozoru koji se otvorio u padajućem izborniku pokrenut će se postupak prikupljanja podataka koji daju granične vrijednosti, koje djeluju kao referentne točke u algoritmima. Naprimjer, algoritam može navesti da osoba od osam (8) godina i osoba od 25 godina mogu imati jednaku stopu ispravnosti držanja, ali senzori imaju različita očitanja za njih zbog razlike u veličini i masi.

Stvaranje korisničkog sučelja bilo je presudno jer se lako može komunicirati s podacima koje pružaju senzori. Jedinstvenost ovog dizajna za ispravljanje položaja ne proizlazi iz upotrebe senzora, već u individualnosti svake značajke. Senzori su posebno dizajnirani i stvoreni za ovu posebnu uporabu. Uređaj je bio izložen na različitim događajima gdje su porote testirale značajke s tehničke perspektive, ali isto tako su svi prisutni mogli testirati proizvod. Desetak ljudi testiralo je uređaj u vremenskom intervalu od samo nekoliko sati, tako da su se funkcije kalibracije i analize u stvarnom vremenu pokazale da djeluju i da mogu biti usmjerene na različite osobe i vrste tijela u tako kratkom vremenu. Korisničko iskustvo je fokus, pa činjenica da ispitanici nisu imali poteškoće u navigaciji kroz aplikaciju nije iznenadila.

4.1.2.8. *Smart chair based on multi heart rate detection system (Ahn et al., 2015)*

Cilj ovog rada bio je osmisliti i ispitati pametnu stolicu. Pametna stolica osmišljena je za istodobno mjerenje beskontaktnog elektrokardiograma (EKG) i balistokardiograma (BCG) bez ograničenja. Tim načinom bilo je za cilj nadomjesti nedostatke dvije vrste spektra. U slučaju neograničenog EKG-a može se mjeriti dok ispitanik nosi odjeću. U slučaju BCG-a, moguće su neograničena mjerenja. Usto, postoji prednost ovakvog mjerenja, a to je da sjedeći položaj ne utječe na mjerenja. Ali, postoji puno nedostataka na koje utječe "šum" pokreta. U ovom radu je istovremeno mjereno EKG-om i BCG-om osmišljeno da umanji neuspjeh u mjerenju podataka otkucaja srca.

Za mjerenje EKG-a bez ograničenja, raspored elektroda sastojao se od kontaktne površine leđa i stražnjice. Pored toga, implementiran je i mjerni sustav BCG primjenom Loadcell (SB S-beam load cell, 100 kgf). Senzori su smješteni ispod podloge sjedala radi mjerenja promjene težine. Signal mjerenja prenosi se putem pametnog telefona na Android platformi u stvarnom vremenu. Sustav je koristio MCU opće namjene (ATmega8L) za implementaciju bežičnog prijenosnog i obradu signala. Mjerenje EKG-a moguće je bez potrebe skidanja ili montiranja elektroda na tijelo, odnosno dok je osoba odjevena.



Slika 46. Implementacija BCG obrade signala

Izvor: Ahn, Noh i Jeong, 2015

U ovoj studiji implementiran je mjerni krug za neograničeni EKG i BCG. Prvi, ADC izveden je na ATmega8L za mjerenje obrade signala. Tada je vršna točka svakog signala otkrivena digitalnom obradom signala. Slika 46 prikazuje postupak obrade signala neograničenog EKG-a. Oznake na slici predstavljaju: (a) prikazuje mjere izvornog signala, (b) izvršena je diferencijalna obrada signala, (c) proces koji se nastavlja na kvadrat signala pojačan je QRS signalom, (d) operacija je izvedena korištenjem granične vrijednosti za detekciju karakterističnih točaka, (e) pokazuje vršnu točku mjernog signala kroz obradu signala.

BCG je mjerena promjena tjelesne težine kod opterećenja senzora za mjerenje. BCG je izveden pretvorbom izvornog signala kroz šest koraka. Na slici 46 prikazan je proces obrade signala kod mjerenja BCG-om: (a) prikazuje izvorni signal koji se mjeri pametnom stolicom; od (b) do (g) je izražen kao signal odvojene valutne transformacije koraka 6; dok je slika (h) u značenju BCG signala ostvarena ponovnom kombinacijom (c), (d) i (e).

U ovom radu implementirana je pametna stolica za mjerenje korisničkih zdravstvenih informacija u svakodnevnom životu. Primijenjeni sustav može se nadzirati u stvarnom vremenu putem bežičnog prijenosa. Procjena performansi primijenjenog sustava provedena je radi usporedbe ocjene učinkovitosti komercijalno dostupnih proizvoda. Eksperimentalno okruženje prikazano je na slici 47. Izvršen je prvi mjerni eksperiment usmjeren na zdrave ispitanike 10 osoba radi ocjene primijenjenog sustava. Ispitanici su trebali sjediti u udobnom položaju odmjerenom u pametnoj stolici. Pored toga, sustav za otkrivanje vrha s istodobnim mjerenjima mjernih instrumenata EKG-a komercijaliziran je kako bi se usporedio njegov rad. Ispitanici su sjedili oko 10 minuta pri istom sjedećem položaju.



Slika 47. Prikaz ispitanika na stolici

Izvor: (Ahn, Noh i Jeong, 2015)

Usto je u ovome radu implementiran i sustav za mjerenje fiziološkog signala u sjedećem položaju. Sustav omogućuje mjerenje EKG-a i BCG-a u sjedećem položaju. Informacije o mjerenjima mogu se pratiti na računalu i pametnom telefonu u stvarnom vremenu. Provedbom sustava VV potvrđeno je da ima visoki afinitet i komercijalizaciju kroz ocjenu izvedbe HVR-a.

4.1.2.9. *Care-Chair: Sedentary activities i behavior assessment with smart sensing on chair backrest (Kumar et al., 2016)*

Prema Svjetskoj zdravstvenoj organizaciji (WHO), mentalno zdravlje i emocionalno blagostanje važni su problemi starije odrasle osobe (60 i više godina), jer otprilike 15 % njih pati od različitih mentalnih poremećaja. Uglavnom postoje standardizirane mjere tjelesnog zdravlja u smislu tjelesnih vitalnih zdravstvenih znakova (poput otkucaja srca, brzine disanja, razine šećera u krvi, krvnog tlaka itd.). Prema National Health Service (NHS) u Ujedinjenom Kraljevstvu, starije odrasle osobe u prosjeku provode 10 sati ili više svakog dana sjedeći ili ležeći, što ih čini najuzvišenijom dobnom skupinom. Velika većina stanovništva provodi većinu svog vremena u sjedećem položaju što potencijalno čini stolac bogat izvor informacija i uvida u svakodnevnu aktivnost osobe. Ljudi obično provode znatno veći dio svakodnevnog života sjedeći na stolici, na primjer: stariji ljudi koji danju sjede na stolici ili invalidskim kolicima (kod kuće ili u ustanovi za koju imaju pomoć), studenti koji pohađaju nastavu u školi i školi i ljudi koji rade u radnim stolovima tijekom radnog vremena.

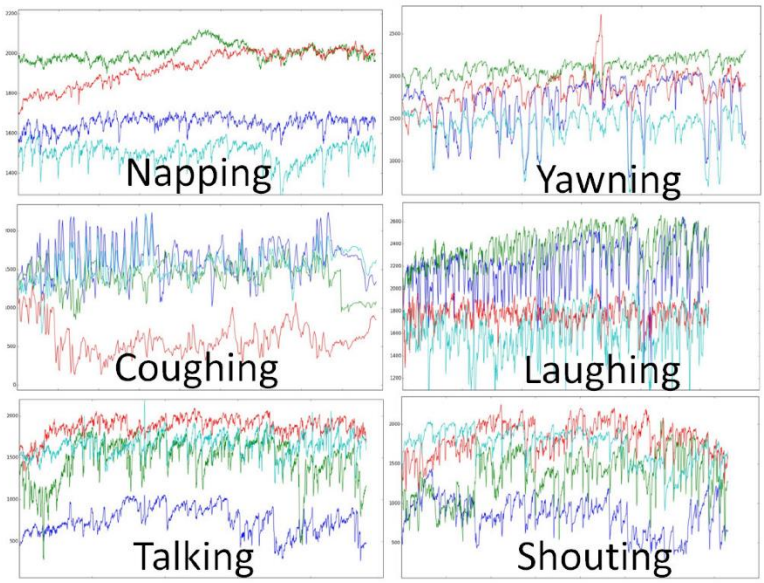
U ovom radu navodi se da u jednoj studiji upotrebe stolice provedenoj s 50 korisnika rezultati pokazuju da je 55 % korisnika provelo više od devet sati dnevno, a 20 % korisnika više od 14 sati dnevno, sjedeći na stolici. Također, 91 % korisnika tvrdilo je da ima primarni stolac, a 61 % korisnika je jedini korisnik svoje osobne stolice. Također su rezultati pokazali da je 67 % korisnika često koristilo naslon stolice. Te informacije, koje se često zanemaruju, mogu otkriti mnoštvo važnih suptilnih opažanja o fizičkom i mentalnom zdravlju, pa čak mogu stvoriti upozorenja ili prijedloge predostrožnosti. U ovom radu osmišljen je pametni sustav stolice pod nazivom „Care-Chair“ koji iz vrlo malo senzora pritiska na naslonu stolice može nametljivo detektirati i analizirati dnevne sjedeće aktivnosti i ponašanje korisnika na stolici. Sustav koristi samo četiri pravokutna FSR-a kao pritisne senzore montirane na naslon obične stolice kako bi prepoznali i razvrstali vrlo specifične i složene aktivnosti prilikom sjedenja. Tijekom istraživačkih studija otkriveno je da su senzori postavljeni na naslon stolice osjetljiviji na različite funkcionalne i emocionalne aktivnosti u sjedećem položaju u odnosu na senzore na sjedalu stolice.

U klasičan naslon stolice ugrađena su samo četiri senzora tlaka (otporni na silu). Senzor RFduino (postavljen na stražnjoj strani naslona stolice) spojen je na pritisne senzore za čitanje podataka iz analognog u digitalni oblik. Prikupljeni podaci senzora (brzina uzorkovanja 10 Hz za svaki senzor tlaka) tada se šalju preko RFduinovog Bluetooth odašiljača do prijemnika u blizini. Sustav je također ograničen na korištenje niže brzine uzorkovanja zbog ograničenih mogućnosti izračunavanja (i osjetljivosti i prijenosa) RFduina i drugih srodnih senzorskih platformi. Prijemnik može biti bilo pametni telefon, tablet ili neki drugi RFduino uređaj kao bazna stanica spojena na računalo.

Svaki od četiri senzora tlaka na naslonu stolice uzorkuje se frekvencijom 10 Hz. Ispitivano je s različitim frekvencijama uzorkovanja i primijećeno je da je uzorkovanje od 10 Hz dovoljno osjetljivo za snimanje čak i suptilnih pokreta i promjena pritiska s ispitanikovih leđa. Tako se od svakog pojedinog podatka senzora tlaka izračunavaju četiri karakteristike, čime četiri senzora tlaka stvaraju ukupno 16 značajki koje će se koristiti u treningu i predviđanju.

Prikupljeni su podaci o sjedećim aktivnostima korisnika s ukupno pet korisnika. Svaki je korisnik bio upućen da prirodno obavlja skup od 19 odabranih aktivnosti. Odabranih 19 sjedećih aktivnosti od interesa za Care-Chair su kategorizirane u nastavku. Većina ovih 19 aktivnosti za svakog korisnika trajalo je više od dvije (2) minute, osim aktivnosti koje je teško oponašati dugo, poput štucanja (trajalo je prosječno

1:24' minuta po korisniku) i kašljanja (trajalo je 1:38 minuta po korisniku). Neobrađeni podaci senzora pritiska tijekom nekih aktivnosti prikazani su na slici 48.



Slika 48. Primjer signala snimljenih tijekom različitih radnji
(napping - spavanje, yawing - zijevanje, coughing - kašljanje, laughing - smijanje, talking - pričanje, shouting - vikanje)
Izvor: Kumar *et al.*, 2016

19 aktivnosti koje su odabrane za promatranje i ispitivanje:

- statičke aktivnosti: spavanje, sjedenje mirno
- uglavnom aktivnosti zasnovane na pokretu: gledanje lijevo, gledanje unatrag desno, kimanje glavom u stranu, kimanje glave prema dolje, mahanje rukom
- korisničke funkcionalne aktivnosti: razgovor, kihanje, kašljanje, pijenje, jedenje, štucanje
- uglavnom aktivnosti koje se temelje na emocijama: plakanje, smijeh, vikanje, plač, zijevanje, vikanje

U sustavu Care-Chair stolice izračunava se brzina disanja iz svakog od četiri senzora tlaka. Konačno, prosječni iznos od četiri odvojeno izračunane brzine disanja koristi se kao konačni broj disanja. No, pristup poništava podatke sa senzora koji možda nisu u dobrom kontaktu s leđima korisnika.

Sustav Care-Chair je osmišljen kako bi mogao klasificirati veliki broj od 19 jednostavnih i složenih sjedećih aktivnosti korisnika, uključujući korisničke funkcionalne i emocionalne aktivnosti, a ne samo statičke sjedeće aktivnosti i položaje temeljene na kretanju. Studija klasifikacije aktivnosti utvrdila je klasifikator koji daje visoku točnost i malo kašnjenja u fazi treninga.

4.1.2.10. *Smart Chair (Sodhi et al., 2017)*

Internet stvari (IoT - *Internet of Things*) je mreža fizičkih uređaja koja je povezana senzorima za otkrivanje signala, softvera i pokretača kako bi poduzeli potrebne mjere, elektroniku i mrežno povezivanje za prikupljanje i razmjenu podataka s drugim povezanim uređajima. Ti se uređaji nazivaju i pametni uređaji. Ovaj rad je implementirao koncept Interneta stvari u školama ili učilištima u kojima je sustav provjere prisutnosti automatiziran. Cilj pametne stolice je provjeriti prisustvo ljudskog bića i automatizirati postupak pohađanja u učionici, kao i sugerirati učeniku da održi zdravo sjedenje.

Ovaj rad je temeljen na IoT-u da bi se dinamika u učionici učinila „pametnijom“ pomoću pametne stolice u automatizaciji procesa sudjelovanja. Smart Chair pomaže u prepoznavanju učenika i koristi senzore pritiska i temperature za održavanje evidencije o prisutnosti učenika u lokalnoj bazi podataka koja je unutar mrežne povezanosti pametne stolice (Sodhi i Kunwar, 2017). To također znači učeniku da održava ispravno držanje za svoj zdrav način života. Da bi se projekt brzo i učinkovito razvijao, izvedba projekta obavljena je u skladu sa životnim ciklusom razvoja softvera za brzi razvoj aplikacija (ili RAD). RAD je suvremeni koncept koji se prije svega fokusira na podjelu zadataka na module i zatim na „prototipiranje“ ili izgradnju svakog modula paralelno. Projekt je bio organiziran u četiri vitalna modula radi lakše izvedbe.

Senzori:

- Korišteni senzori su EM-18 radio frekvencijska identifikacija (RFID), mikro-elektro mehanički sustavi (MEMS), temperaturni senzor LM35 i jednopolna stanica ESP 4-150. Ovi senzori djeluju neovisno jedan o drugom. Glavni cilj prikupljanja i pohranjivanja podataka je nadgledanje pohađanja i držanja učenika u učionici.
- Mikro-upravljač PIC može se promatrati kao središte pametne stolice. PIC mikro-upravljač je mjesto na kojem se podaci senzori, obrađuju i prosljeđuju u bazu podataka pomoću ZigBee modula.
- RFID: Nakon što učenik uđe u razred, student mora otići, sjediti na bilo kojoj klupi i pregledati svoju karticu protiv čitača RFID kartica. Ovim će se označiti dolazak učenika i nakon toga, kako bi se osiguralo da učenik pohađa cijelo vrijeme nastave, koriste se razni senzori koji su objašnjeni u nastavku. Nakon postavljanja RFID sustava, ručni rad nije potreban što je glavna karakteristika IoT-a.
- Senzor za jednostruku opterećenje: Ovo je senzor koji će se prvi aktivirati i koristi za mjerenje težine. Maksimalna težina koja se može izmjeriti je 150 kilograma.
- Temperaturni senzor LM35: Cilj ovog senzora temperature je otkriti je li pritisak na pametnoj stolici od čovjeka ili bilo kojeg drugog teškog materijala. Očitavanja su u Celzijusu i mogu mjeriti temperaturu -55o u većem rasponu od - C do 150o C.
- Mikro-elektro mehanički sustavi (MEMS): Za držanje učenika koristi se MEMS [5]. Raspon je pokrenut za normalno držanje. Ako vrijednost prelazi definirani raspon određeno vrijeme, tada LCD prikazuje nenormalno držanje, u suprotnom prikazuje normalno držanje.
- ZigBee bežično prenosi podatke s PIC mikro-upravljača na lokalni server.
- Internet aplikacija je sučelje za studente i nastavnike za nadzor pohađanja učenika u učionici.

ZigBee modul:

Ovaj se modul koristi za prijenos podataka s PIC mikro-upravljača na lokalni poslužitelj putem bežične komunikacije. Lokalni poslužitelj prima podatke uz pomoć ZigBee modula prijemnika. ZigBee nastavlja s prijenosom podataka i ažurira status posjećenosti učenika u web aplikaciji.

Server:

Modul Web-poslužitelj radi kao moderator između IoT uređaja i web aplikacije. Poslužitelj dohvaća podatke s PIC mikro-upravljača i pohranjuje ih u bazu podataka. Te podatke dodatno može zatražiti studentski portal, portal nastavnika ili portal administrator kao zahtjev. Ti se zahtjevi postavljaju putem sučelja programa za odmor programa (Rest API) iz web aplikacije.

Internet aplikacija:

Prijava na stranicu podijeljena je na dva dijela. Jedno je prijava za učenika, a drugo je prijava za nastavnika. Internet aplikacija izrađena je prihvaćanjem MVC okvira. Prednost upotrebe MVC-a je u tome što se kod može ponovo upotrebljavati kad god je to potrebno i mogu se načiniti različiti prikazi za prijavu nastavnika i učenika.

Rezultati pametne stolice analizirani su modularno jer je u razvoju pametne stolice slijedio modularni RAD pristup. Ideja Smart Chair bila je pokrenuta kako bi trajanje nastave bilo produktivnije za nastavnika i za studente. Sastavljen je i implementiran sustav temeljen na PIC mikro-upravljaču na ploči da bi se pomoću senzora tlaka i senzora temperature korisnički ID mogao prepoznati putem RFID čitača i statusa zauzetosti stolice. Štoviše, stolica također ima MEMS troosni akcelerometar koji se koristi za provjeru držanja tijela i preporučuje promjenu držanja tijela ako je položaj nepovoljan za zdravlje. Pohađanje nastave učenika pohranjuje se u bazu podataka. Konačno, kreira se prijava učitelja za pregled pohranjenih podataka iz cijelog evidencije o pohađanju učenika. Sustav pametnih stolica ne samo da nudi rješenje problema ručnog pohađanja, već postavlja i temelj pametnoj klasi.

4.1.3. Baza *Scopus*

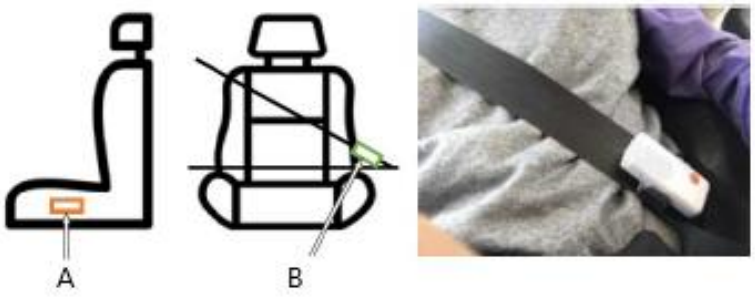
4.1.3.1. *Transforming Smart Vehicles i Smart Homes into Private Diagnostic Spaces (Deserno i Reichertz, 2020)*

Pametna odjeća, pametni satovi, pametna vozila ili pametne kuće postaju današnja normala. Zadnje dvoje imaju prednosti u pogledu pojedinačnog napajanja, računalnih i skladišnih kapaciteta i komunikacijskih sučelja bez baterija. Drugim riječima, pametni automobili i pametne kuće mogu zamijeniti dijagnostičke uređaje u javnim bolnicama s pojedinačnim senzorima za kontinuirano praćenje zdravlja. Danas su nova vozila, kao i pametne kuće, opremljena s puno senzora, kao i sa središnjom procesnom jedinicom (računalom). U pametnim automobilima sustav upravljačke mreže (CAN) povezuje sve senzore i djelujuće uređaje. Kao rezultat toga, pametni automobili i pametni apartmani su slične tehnološke prirode i mogu formirati privatne dijagnostičke prostore. Međutim, medicinska upotreba senzora još nije istražena, jer se oni koriste isključivo za pomoć u vožnji i kontrolu klime / energije.

Sekundarna upotreba senzora okoline je korištenje podataka koji su već zabilježeni. Na primjer, sustav upravljanja sigurnosnim pojasom u automobilu prepoznaje zauzeta sjedala integriranom skalom. Takvi se podaci mogu koristiti za nadgledanje tjelesne težine vozača ili putnika, koji je, primjerice, svakodnevno putujući automobilom i pati od srčane bolesti. Drugi primjer su volan i papučica, koji bilježe najmanje pokrete koji u ranoj fazi mogu upućivati na Parkinsonovu bolest u ranoj fazi.

Slično tome, u pametnim kućama se postojeći senzori mogu smisleno koristiti medicinski. Danas smatramo dom pametnim ako smo sposobni kontrolirati klima uređaj, rasvjetu i prozore putem aplikacije radi uštede energije i isporuke personalizirane klimatizacije u sobi (premda bi pametni dom to trebao učiniti automatski). Kako bi postigao ovaj cilj, pametni dom prati sva vrata i prozore kod otvaranja i zatvaranja. Uz to, može nadzirati potrošnju tople i hladne vode kao i sve utičnice. Nadalje, pametne kuće i pametni automobili mogu pratiti mobilnost. Jednostavno oduzimanje vremena potrebnom starijim osobama od otvaranja vrata spavaće sobe ujutro do prelaska kroz hodnik i otvaranja kupaonskih vrata ukazuje na bilo kakav trend stjecanja ili gubitka mobilnosti. Isto, na primjer, od otvaranja vozačevih vrata automobila do pokretanja motora.

Integriranje dodatnih medicinskih senzora ima značajan potencijal, a prednost sustava CAN i BASIS je ta što se dodatni senzori mogu lako integrirati. Dakle, pametna okruženja možemo dodatno opremiti medicinskim senzorima, isključivo dizajniranim za praćenje vitalnih signala. Obično postoje četiri osnovna vitalna znaka koja su standardna u većini medicinskih okruženja: (1) tjelesna temperatura, (2) otkucaji srca i puls, (3) brzina disanja i (4) krvni tlak. S povećanom snagom računala, nadzor vitalnih znakova utemeljen na snimanju kamerom postaje sve precizniji. Međutim, neprekidno snimanje, osobito kod kuće, još nije naišlo na potpuno odobravanje zbog privatnosti. Otuda je vidljivo da je nedostatak prihvaćanja korisnika kao glavni ograničavajući faktor ove bio-monitoring tehnologije. BCG i SCG tehnologija je isto tako jeftina. Međutim, robusnost procjene kretanja tijela na temelju ubrzanja postaje presudna u automobilima tijekom vožnje (na grbavim cestama). Iznenađujuće, čini se da je moguće raditi mjerenja ako je BCG integriran u sigurnosni pojas, ako se senzor podataka postavi blizu kopče i upotrijebi drugi senzor samo za hvatanje „buke“. Slika 49 prikazuje položaj BCG senzora u automobilu.



Slika 49. Položaj BCG senzora integriranog na pojas
A) senzor za očitavanje buke, b) BCG Senzor

Izvor: (Deserno, 2020)

Slika 50 (gore lijevo i gore desno) prikazuje eksperimentalnu postavku za mjerenje EKG-a u automobilu. Osim toga, cECG se može integrirati u automobile i domove. Ovdje jedna elektroda i koža korisnika tvore kondenzator koji šalje EKG-ov električni potencijal u pojačalo signala. Tekstilne elektrode omogućuju udobnu integraciju senzorskih uređaja u automobilsko sjedalo (slika 50, gore desno), fotelju (slika 50, dolje lijevo) ili u krevet kao navlaka madraca (slika 50, dolje desno).



Slika 50. Prikaz EKG i cEKG senzora u automobilu i namještaju

Izvor: (Deserno, 2020)

Središnju procesnu jedinicu smatra se jezgrom pametnog okruženja. Kao i senzorski uređaji, i ova se jezgra mora transformirati u dijagnostičku svrhu s obzirom na svoj hardver i softver za skladištenje i analizu podataka. Prema BASIS konceptu, pametne kuće imaju središnju jedinicu za obradu koja je integrirana u kutiji s osiguračima. U bliskoj budućnosti, zdravstvene obavijesti generirat će se autonomno iz privatnih dijagnostičkih prostora. Stoga pametna okruženja moraju izvući odgovarajuće podatke iz skladišta podataka. Da bi se omogućilo kontinuirano praćenje zdravlja i da bi se zadovoljile rastuće zdravstvene potrebe, od kritične su važnosti pristupačna, neinvazivna i jednostavna rješenja u zdravstvu.

4.1.3.2. *Real time visualization of asymmetrical sitting posture (Anwarya et al., 2019)*

Sjedenje uspravno (ravno leđima i ramenima), simetrično (ista težina prenesena s obje strane na potporno područje sjedećim kostima) i stabilno držanje (uklanjanje težine sa stopala) su neophodni za izbjegavanje ergonomskih problema. Uobičajeni su asimetrični sjedeći položaji, poput sjedenja nagnutog na jednu stranu sa savijenom kralježnicom; držeći koljena, gležnjeve ili ruke prekriženih; debeli predmeti (novčanik, mobiteli i papirnati dokumenti) u stražnjem džepu; i ležeći na stolu itd. Ovi asimetrični sjedeći položaji povezani su s okomitom osi u frontalnoj ravnini, poznatoj kao zdjelična asimetrija. Asimetrični položaji je jedan od vodećih uzroka (80-90 %) za bolove u donjem dijelu leđa.

Sjedenje prekriženih nogu dovodi do asimetričnog korištenja unutarnjih i vanjskih trbušnih mišića što može uzrokovati neravnotežu kralježnice. Ponovo, lumbalni kralješci su slabi za savijanje ili uvijanje, iako dobro podnose pritiskanje, također, sjedenje s prekriženim nogama može rezultirati bolovima u leđima. Više od 80 % studenata sjedi odmarajući bradu na jednoj ruci tijekom učenja za stolom. Takvo držanje s dugim vremenom može uzrokovati trajne razlike u visini ramena, položaju očiju i položaju kukova. Asimetrično sjedenje poput sjedenja s bradom naslonjenom na ruku ili prekriženim nogama, koje proizlaze iz loših navika, može utjecati na ravnotežu kralježnice i može dovesti do trajne deformacije kralježnice, poput kifoze, skolioze i lordoze. Jedan element koji može pridonijeti izbjegavanju asimetričnog sjedenja je osmišljavanje i razvoj automatskog praćenja sjedenja u stvarnom vremenu i pružanje pravovremenih intervencija putem mobilnog telefona ili računala. Razvoj automatskog asimetričnog sustava za nadgledanje sjedenja u stvarnom vremenu zahtijeva ugradnju hardverskih i softverskih komponenti. Softverske komponente su Arduino programiranje i razvoj Android aplikacije. Stoga, predloženi sustav ima glavni hardver s dva dijela i Android aplikaciju.

Piezoelektrični materijali imaju svojstva promjene električnog otpora kada se materijal deformira. Zbog toga su piezoelektrični provodni filmovi pogodni za korištenje kao tlačni senzori zbog svoje jednostavne strukture u različitim primjenama. Za vrijeme sjedenja vrše se pritisni tlaci na gornju površinu FPS-a, a donja je površina ravna, pa tlak rezultira smanjenjem otpora zbog otpora velostata i zbog blagog pada u dodiru otpor između provodnog materijala i Velostata.

Neobrađeni podaci iz ovih šest FPS-a mogu sadržavati šum, poput mehaničkih, rastezljivih, konstantnih pristranosti, treperenja, temperaturnih učinaka i kalibracijskih pogrešaka. Čitanja s FPS-a sastoje se od bučnih šiljaka u nacrtanom grafikonu koje je potrebno ukloniti prije upotrebe podataka za analizu. Jedan od načina smanjenja buke je primjena naprednih optimalnih rekurzivnih tehnika filtra kao što je Kalmanov filter. To je algoritam za filtriranje koji može ukloniti šum iz signala, zadržavajući korisne informacije.

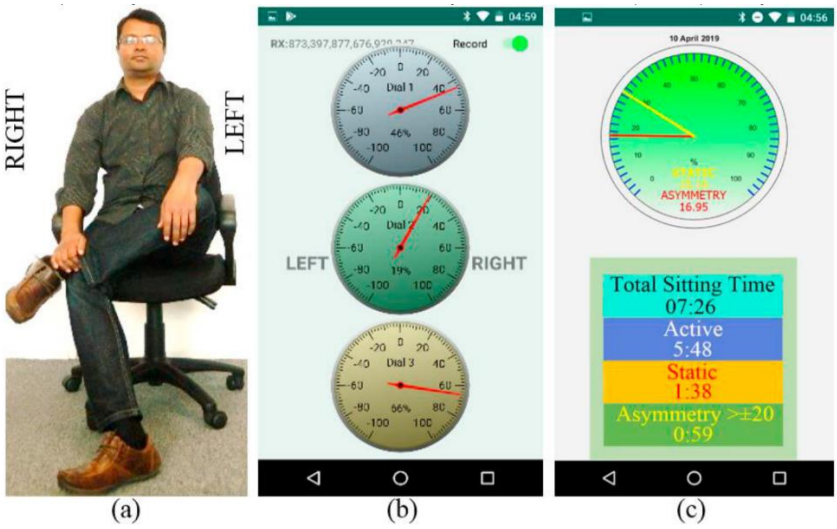
Trenutno su dostupne različite vrste bežičnih tehnologija za prijenos podataka kao što su Bluetooth, Globalni sustav za mobilne uređaje, ZigBee, Opća paketna radio usluga, Z-Wave, infracrvena veza i Wi-Fi. Bluetooth mreža ima mogućnost serijskog prijenosa podataka do 3 Mbps unutar fizičkog raspona od 10 do 100 metara, ovisno o vrsti Bluetooth uređaja. Bluetooth se može povezati s pametnim telefonom koristeći serijsku komunikaciju. Čitanje sa šest FPS-a prenosi se na naš razvijeni program Smartphone pomoću Bluetooth tehnologije.

Arduino Nano u asimetričnom sustavu nadgledanja sjedenja djeluje kao bazna stanica. Arduino integrirano razvojno okruženje (IDE) je programski softver za više platformi koji omogućuje nadzor nad

izlazima koji dolaze iz senzorskih čvorova na serijskom monitoru. Budući da je Arduino Nano s niskim troškovima, standardom male snage i najfleksibilnijim sustavom bežično nadgledanje, on se široko koristi kao otvoreni izvorni hardver i softverska platforma za razvoj.

Smartphone i aplikacije važan su alat za pristup informacijama. Pametni telefoni imaju ugrađenu Bluetooth tehnologiju za prijem ili prijenos bežičnih podataka. Prema arhitekturi Androida postoje četiri vrste aplikacija: aktivnosti, usluge, davatelji sadržaja i prijemnici za emitiranje. Aplikacija je osmišljena s obzirom na: a) Zahtjev: Analiza zahtjeva provodi se pregledom literature, raspravom sa stručnjakom i korisnicima, b) Dostupnost tržišta: Pregledavaju se platforme za razvoj mobilnog softvera na tržištu.

Aplikacija za Android razvijena je za prikupljanje i prikazivanje informacija o asimetričnom položaju sjedenja u stvarnom vremenu. Samsung S9 pametni telefon koristi se za povezivanje s Bluetoothom i prikupljanje podataka o FPS-u. Za vizualizaciju ASP-a koristi se očitanje s FPS1 na FPS6. ASP je prikazan na slici 51b i 51c. Slika 51a prikazuje držanje s asimetričnim sjedenjem u položaju križanih nogu.



Slika 51. Prikaz asimetričnog sjedenja i vizualizacija podataka

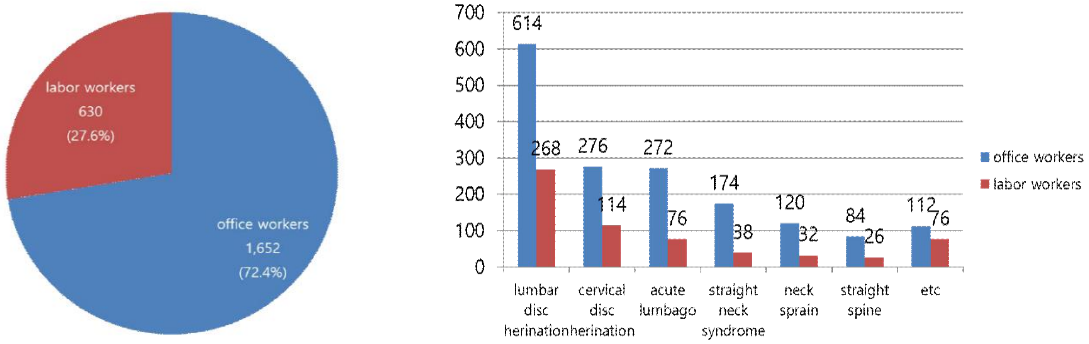
Izvor: (Anwary, Bouchachia i Vassallo, 2019)

Procjenjuje se trajanje svakodnevnog vremena sjedenja. Trajanje aktivnog sjedenja procjenjuje se kada nema svih nula čitanja sa svih šest FPS-a. Trajanje statičkog sjedenja procjenjuje se kada vrijednosti očitavanja brojčanika budu manje od ±5. Trajanje asimetričnog sjedenja procjenjuje se kada bilo koje biranje pokazuje više od ±20 tijekom više od pet minuta. U ovom istraživanju osmišljen je, razvijen i implementiran jeftin novi hardver i Android aplikacija za nadgledanje i poboljšanje sjedenja. Kao dio ovog istraživanja, rade fleksibilan senzor tlaka s obzirom na senzorski sustav za pritisak sjedala kompatibilan s ljudskom biomehanikom za uporabu ugrađenu u složena sučelja, poput presvlake sjedala i stolice. Fleksibilni senzori tlaka koriste novu višeslojnu metodu koja je predložena kao cjelovito rješenje za proizvodnju i upotrebu u stvarnom svijetu. Fleksibilna priroda senzora omogućava oblikovanje antropomorfnih parametara različitih veličina ljudskih leđa i varijacija oblika stolica.

4.1.3.3. *Smart chair cover for posture correction (Kim i Lim, 2019)*

Mnogi ljudi u ovom moderniziranom svijetu provode oko polovice dana na stolici, uglavnom zbog povećanog radnog vremena i obrazovanja. Pored toga, čak i djeca i starije populacije provode više vremena sjedeći zbog generaliziranog računala u domaćinstvu širom svijeta. Kako bi se u Južnoj Koreji ispitali socio-demografski aspekti i životni stil, provedena je anketa o zdravlju i prehrani. Na pitanje "koliko često provodite vrijeme sjedeći tijekom posljednjih sedam dana", od svih 4806 ispitanika, 713 osoba odgovorilo je manje od tri sata, 1274 osobe odgovorilo je tri do pet sati, 1961. odgovorilo je pet do 10 sati , a 858 ljudi odgovorilo je više od 10 sati. Grupa s najviše odgovora je pet do 10 sati, a najmanje je manje od tri sata.

Slika 52 prikazuje rezultate ankete sa 2.282 radnika koji su se liječili u jednoj korejskoj bolnici za vrijeme rada istraživanja. Grafikon a) prikazuje postotak oboljelih od bolesti leđne moždine prema njihovom zanimanju. Većina pacijenata kojima je prvi put dijagnosticirana bolest leđne moždine u bolnici su uredski radnici, ukupno 1.652 i čine 72,4 % (plavo). Međutim, 630 radnika koji rade kao fizički radnici doprinose samo s 27,6 % od ukupnog broja ispitanika koji su odgovorili na anketu (crveno). Grafikon b) na slici 52 detaljnije prikazuje rezultate iz grafikona a), ilustrirajući omjer uredskih radnika i fizičkih radnika u svakoj grupi bolesti leđne moždine.



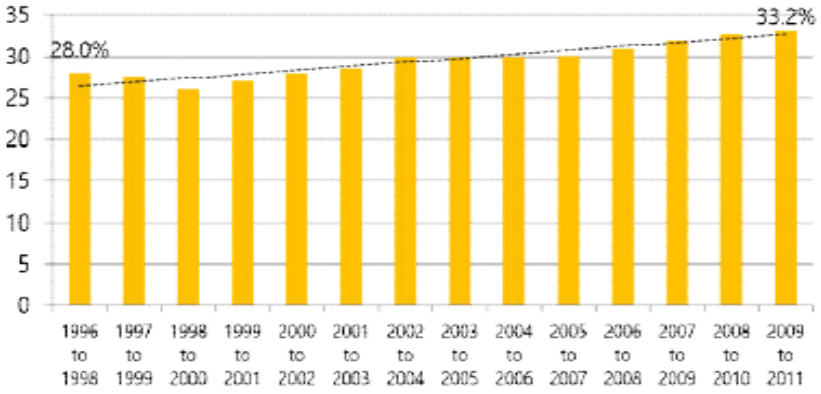
a) b)

Slika 52. Grafički prikaz ankete

a) Prikaz udjela uredskih radnika i fizičkih radnika u odnosu na oboljenje kralježnice; b) Grafički prikaz ostalih oboljenja

Izvor: Kim i Lim, 2019

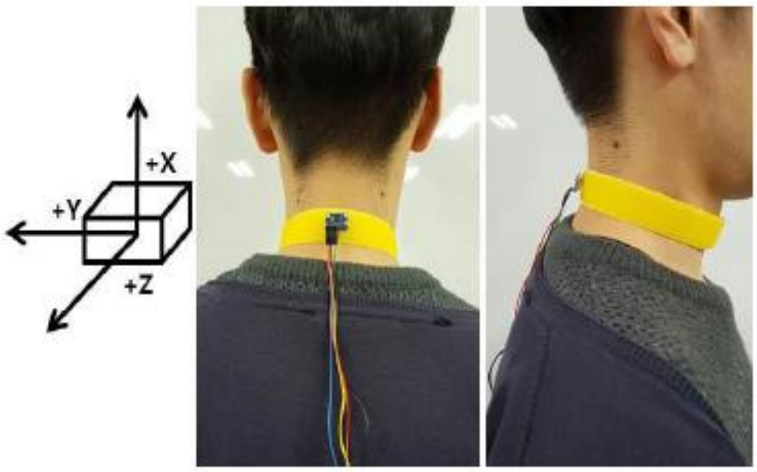
Na slici 53 prikazan je trend u populaciji bolesnika s kralježnicom u Sjedinjenim Američkim Državama, a može se primijetiti da pacijente s oboljenjem leđne moždine tretiraju ne samo u Koreji, nego i u SAD-u.



Slika 53. Prikaz trenda oboljenja leđne moždine

Izvor: Kim i Lim, 2019

Na slici 54 je primjer senzora ubrzanja pričvršćenog za vrat ispitanika pomoću kojeg je provedeno klasificiranje sjedećeg položaja. Stavljen je senzor ubrzanja između kralježnice iza vrata i izmjereni položaj promjene u odnosu na gravitacijsko ubrzanje kako bi razlikovali držanje poput sjedenja uspravno, sjedenja s izbočenim vratom prema naprijed prema monitoru, ležanja naslona stolice, sjedenja s prekriženom nogom , i sjedi s rukom koja podržava torzo. Ograničenje ovog istraživanja je neugodnost vezanja senzora na kralježnicu kad god korisnik sjedne.



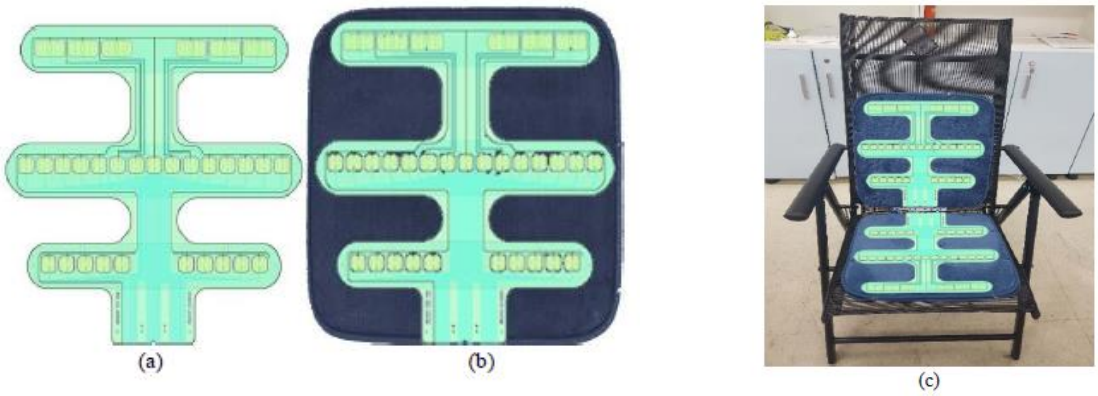
Slika 54. Prikaz primjera senzora pričvršćenoga na vrat korisnika

Izvor: Kim i Lim, 2019

Pametni jastuk iz ovog rada koristi Arduino ploču i povezani su dva para od 30 senzora tlaka koji mjere pritisak na sjedalu i naslonu. Podaci se na pametni telefon prenose bežičnom komunikacijom, a iz tih podataka sustav identificira položaj tijela.

Identificirano držanje zatim se uspoređuje s vrijednošću koja je prethodno pohranjena u bazi podataka, a zatim je definirano odgovarajuće držanje. Slika i tekst prikladan za definirano držanje šalju se na pametni telefon dok sustav dobiva podatke u stvarnom vremenu i skupljene podatke. Pored toga, kada sustav dulje vrijeme prepozna nepravilno držanje, telefon vibrira i alarm se prijavljuje putem pametnog

telefona, ostavljajući korisniku da slijedi rutinu istezanja. Sustav prati je li korisnik izveo istezanje tijekom unaprijed određenog razdoblja i usmjerava ga do sljedećeg pokreta ili rutine istezanja.



a) Senzor koji je korišten u ispitivanju; b) Ugrađeni senzor u jastuk; c) Prikaz pokusne stolice sa senzorima na jastucima na sjedalu i naslonu

Slika 55. Primjer senzora korištenog u radu

Izvor: Woo Lim Kim i Lim, 2019

U ovom istraživanju korišteno je ukupno 30 senzora tlaka koji su ugrađeni u pametni jastuk i međusobno su povezani plahtom kao što je prikazano na slici 65 (a). Veličine su 380 mm u širinu, 388 mm u duljinu i 0,95 mm debljine, što je dovoljno da pokrije cijelu stolicu, a da ne utječe na udobnost sjedenja. Za središnji dio sjedala predviđeno je 15 senzora, prema podacima da je od sva četiri položaja poput naginjanja desno / lijevo, sjedenje s prekriženom desnom / lijevom nogom većina pritiska u sredini sjedala.

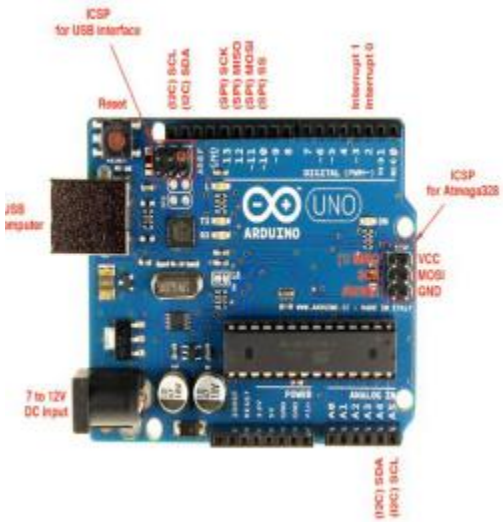
Loš položaj je kada je korisnik nagnut lijevo ili desno, kada je nagnutog prema naprijed, kada je desna noga prekrižena, kada je lijeva noga prekrižena i kada je korisnik nagnut prema nazad. Uključujući pravilan položaj, korisnik će vidjeti ukupno sedam položaja.

Rezultati u ovom istraživanju doprinose za danji razvoj senzora iz ovog rada, obzirom da je svrha rada bila razvoj senzora i integracija istih u jastuk nema konkretnih rezultata o točnosti očitovanja. Navodi se samo kako senzor dobro prepoznaje različite sjedeće položaje.

4.1.3.4. *Design i Implementation of Modernised Dental Chair using Voice Recognition Control Circuit (Puviarasi i Greeshma, 2019)*

Općenito, u bolnicama se stomatološka stolica za pacijenta može upravljati prema naprijed / natrag ili prema gore / prema dolje prema tretmanu za pacijente koje operira čovjek. Ponekad stolica neće raditi pravilno zbog pojave korozije na radnim dijelovima i prekomjernog opterećenja, a stomatolog može imati bolove u nogama zbog kontinuiranog upravljanja stolicom. Da bi se riješili ovi problemi, planira se dizajnirati stomatološku stolicu za prepoznavanje glasa liječnika. Ovaj projekt opisuje dizajn pametne, motorizirane stomatološke stolice s glasom. Glasovnu naredbu daje stomatolog/čovjek, senzor prepoznaje glas i šalje naredbu Arduinu. Ova se glasovna naredba pretvara u niz podataka i odgovorna je za pokret stolice. Inteligentna stomatološka stolica dizajnirana je tako da je liječnik lako kontrolira, a prednost je dizajn s niskim troškovima. Ovaj je sustav dizajniran i razvijen kako ne bi trošili energiju i vrijeme liječnika. Upotreba ove nove inovacije u kombinaciji s mehaničkim okvirom imajući u vidu krajnji cilj da se preuređuje redovno svakodnevno postojanje i pokrene entuzijazam za dosljedno razvijanje današnjeg društva.

Programirani modul sastavljen u ovom radu omogućava da stomatološka stolica razumije riječi izgovorene pomoću mikrofona i da se stomatološko sjedalo pomiče kako je naznačeno danim ležajevima. Klijent može sam kontrolirati stomatološko sjedalo svojim glasom koristeći posebne pozive prema naprijed, natrag, nagore i prema dolje. Ultrazvučni senzor je uređaj koji se koristi da osjeti prepreku sa stražnje strane stomatološke stolice.



Slika 56. Prikaz Arduino modula

Izvor: Puviarasi i Greeshma, 2019



Slika 57. Prikaz testnog uređaja

Izvor: Puviarasi i Greeshma, 2019

Kretnje stomatološke stolice osigurane su motorima koji su povezani sa stolicom i pogonom koji se sastoji od mikro-upravljača i pogona motora. Govorna tehnologija koristi se za smanjenje fizičkog napora stomatologa, a glasovni se modul koristi za obavljanje glasovne radnje. Na slici 57 prikazan je rezultat, kada korisnik kaže naredbu DOLJE, krug reagira na njega i stolica se pomiče dolje i to se može vidjeti na LCD zaslonu, za naredbu GORE također funkcionira na isti način.

Arduino je platforma otvorenog koda za izradu elektroničkih projekata (slika 56), a služi za izradu uređaja koji mogu osjetiti i kontrolirati više uređaja. Uglavnom se koristi u današnjim tehnikama razvoja. To je ploča za razvoj mikro-upravljača za pisanje softvera za hardverski krug.

Prepoznavanje glasa je metoda promjene govornog signala u nizu riječi koja sugerira onu od pridruženih algoritamskih programa nametnutih kao program koji se dodatno naziva i automatsko prepoznavanje govora (ASR). Prepoznavanje govora klasificira se kao povezano prepoznavanje riječi i prepoznavanje izolirane riječi. Stoga, prepoznavanje govora nije ništa drugo nego obrazac koji odgovara podržanoj obuci i prepoznavanju.

Ovaj rad se bavi mehanizmom kontrole glasa zubne stolice. Sastoji se od dva dijela oni su hardver i softver. Hardverska arhitektura sastoji se od ugrađenog sustava koji se sastoji od Arduino Uno ploče, modula za prepoznavanje glasa, Bluetooth modula i pogonskog motora. Djeluje na naredbe koje je dao stomatolog. Pneumatski cilindri odgovorni su za kretanje stolice. Stolica se kreće gore-dolje dok se pritisak nakuplja na stolici oslobađanjem plina. Na pneumatski cilindar pričvršćen je manometar, a na njega je pričvršćen magnetni ventil. Pneumatski cilindri produžavaju i povlače klipnu klip kako bi osigurali silu potiskivanja kako bi se sjedalo kretalo linearno. Željena naredba koju korisnik daje šalje se putem mikrofona. Dani ulaz šalje se modulu za prepoznavanje glasa. Glasovna naredba koja se mijenja u razni niz prenosi se na pridruženu Arduino ploču. Arduino pretvara ove upute u određene naredbe koje motori mogu prepoznati. Arduino odlučuje o kretanju motora, glasovni modul osposobljava se s nekim naredbama. Mogući su različiti smjerovi pokreta: gore, dolje, sprijeda, natrag i zaustavljanje.

5. RASPRAVA I ZAKLJUČAK

U ovom diplomskom radu u svrhu analize postojećih senzora te njihove namjene ciljano je birano i detaljno je obrađeno 18 znanstvenih radova iz relevantnih znanstvenih baza. U svakom od tih radova potvrđuje se isti problem, a to je da je nepravilno sjedenje jako štetno za naše zdravlje te ga dugoročno može ozbiljno narušiti. Sjedenje utječe loše na ljudsko tijelo jer se ljudsko tijelo još uvijek nije u prilagodilo za potpuno sjedilački način života. Loš sjedeći položaj i fizička neaktivnost rezultiraju slabljenjem mišićnog tkiva koje se ne koristi zbog čega osoba sve teže sjedi u pravilnom položaju. Prekomjerno sjedenje na početku stvara umanjenu mobilnost vrata i kukova, što se kasnije pretvara u bolove u vratu, glavobolje, bolove u ramenima, bolove u leđima te na posljetku do nekih težih i kroničnih oboljenja. Zdrav i aktivan način života, pravilno sjedenje te kontrola sjedenja putem pametne stolice i aplikacije je trenutno najbolji način za borbu protiv bolova uzrokovanih sjedenjem.

Također, u svakom od obrađenih radova prezentirana je neka pokusna stolica, naslonjač, jastuk i slično, čime se pokušava doskočiti tom problemu. Većina obrađenih radova (Lee, Saidy i Fitri, 2019; Zhang *et al.*, 2019; Sifuentes *et al*., 2019; Ma *et al*., 2017; Hesse *et al*., 2017) bazira se na mjerenju kontaktnih tlakova između korisnikova tijela i stolice te očitavanju i raspoznavanju položaja sjedenja, gdje se pojavljuje nekoliko vrsta senzora koji to bilježe. Gotovo svi radovi se temelje na tome da uz očitavanja pritiska tijela i određivanja trenutnog položaja, očitavaju i druge parametre, poput rada srca, aktivnosti pojedinih mišićnih skupina, disanja, procjena razine kisika u krvi, te prikazivanjem kako određeni položaji prilikom sjedenja utječu na npr. broj otkucaja srca u minuti, disanje i slično. Jer, ako nismo u mogućnosti jasno izvući podatke i analizirati ih tada nismo ni u mogućnosti vidjeti u koje doba dana, koliko često i koliko dugo pogrešno sjedimo.

U značajnom dijelu radova koristi se Force sensitive resistor (FSR), odnosno senzor koji mjeri otpor nekoj sili te se na taj način koristi kao senzor za praćenje i definiranje sjedećeg položaja. S obzirom na to, da dok sjedimo malo tko od nas zna koliko ispravno sjedimo i kako će trenutni sjedeći položaj utjecati na naše zdravlje, pojavila se potreba da stolica bude opremljena raznim vrstama senzora koji će u realnom vremenu procjenjivati trenutno stanje, analizirati ga i u odnosu na naše navike i druge okolnosti prikazivati sve relevantne podatke. Na osnovi tih podataka i pomoću algoritama može se korisnika upućivati na manje štetan način sjedenja, a da se pri tome ne narušava udobnost sjedenja. Udobnost se može odnositi i na osjećaj udobnosti i na osjećaj neudobnosti. Potencijalna mana takvih senzora je da ako i se koristili priliko mjerenja radnih sati, odnosno koliko sati zaposlenik provede na radnom mjestu, da bi se umjesto osobe mogao staviti predmet na stolicu. Tom problemu doskače se na način da se senzor podesi da osjeti i prepozna obrazac disanja (mjeri otpor koji stvara prsni koš u naslonu prilikom disanja) ili čak otkucaja srca. Često se stavi i poseban senzor za precizno mjerenje rada srca. U nekim radovima naglasak je na stolici kao na Internet of things (IoT) uređaju, odnosno kao uređaju koji je ukomponiran u "pametnu kuću" na način da kada korisnik dođe i sjedne na određenu stolicu tada se automatski upali točno definirana rasvjeta i slično.

U prethodno obrađenim radovima navode se različiti senzori čije su svrhe i primjene specifične. Od 18 obrađenih radova u njih 15 nalaze se senzori osjetljivi na tlak pomoću kojih se pokušava dobiti točna slika u stvarnom vremenu o tome kako ljudi sjede i pokušava se predvidjeti kakav to učinak dugoročno

može imati. U većini radova se uz senzor osjetljiv na tlak nalazi još neki senzor, poput senzora za praćenje rada srca, senzora za praćenje disanja, senzora za glasovno upravljanje stolicom, senzora za očitavanje topline i drugi. U većini radova je napravljena aplikacija za pametni uređaj (telefon) koja obrađuje podatke i prikazuje ih korisniku u stvarnom vremenu. Tako se pokušava osvijestiti korisnika i prikazati mu kako trenutno sjedi. U svim radovima koji imaju senzore osjetljive na tlak i uz njih dodatne senzore radi se usporedba na koji način dišemo, na koji način nam srce kuca u kojem položaju. Ključno je da senzori precizno prepoznaju položaj u kojem se nalazi korisnik kako bi se ostali podaci mogli sortirati po različitim sjedećim položajima.

Problem nepravilnog sjedenja i njegov utjecaj na ljudsko zdravlje bit će problem još niz godina. Cilj ovog rada bio je da se pokuša prikazati što i kako se događa prilikom lošeg sjedenja te koje su sve posljedice ali i na koji način nam suvremena tehnika i tehnologija može pomoći umanjiti taj problem. Većina ljudi dok sjedi i radi neki posao nije trenutno svjesna svojeg položaja te se smatra da bi računalna podrška prilikom sjedenja mogla doprinijeti spoznajama o trenutnom položaju i načinu sjedenja.

Senzori osjetljivi na tlak pokazuju dobre rezultate te su skoro u svim radovima, u kojima je provedeno takvo ispitivanje, imali točnost prepoznavanja položaja više od 90 %. Senzori osjetljivi na tlak su relativno jednostavni za integriranje u stolicu i oni su zapravo nužni da bi se točno definirao položaj i način na koji osoba sjedi. Bitno je da su takvim senzorom pokrivena potrebna polja ili ako je moguće cijelo sjedalo i naslon, u kojem bi se slučaju dobili precizniji rezultati. Senzori osjetljivi na tlak su osnova „pametne stolice“ jer su oni ti koji zapravo osjete kada netko sjedi, kako sjedi, koji radnju radi prilikom sjedenja, koliko jako se naginje na naslon, mikrolokaciju osobe na sjedalu i sl.

Radovi u kojima se još uz senzore osjetljive na tlak nalaze neki drugi senzori (senzor za mjerenje pulsa) ili senzori koji su optimizirani na način da mogu osjetiti neke druge životne funkcije (npr. disanje) pokazuju kako ljudsko tijelo funkcionira prilikom lošeg sjedećeg položaja kao i kod dobrog. Detektiranje i ispravljanje lošeg sjedećeg položaja je ključno da bi se izbjegli bolovi u leđima ili u krajnjem slučaju teža oboljenja kralježnice.

Međutim, smatra se da je uz samo definiranje sjedećeg položaja bitno i pratiti ostale životne funkcije, što se u daljnjim istraživanjima može povezati s drugim znanstvenim područjima gdje se može ustanoviti da pojedini organ u ljudskom tijelu u nekom specifičnom sjedećem položaju ima nepotrebna opterećenja koja dugoročno mogu dovesti do nekih oboljenja. Da bi stolica mogla funkcionirati na takav način potreban je program koji će pratiti i analizirati sve te aktivnosti, u radu je obrađeno nekoliko takvih programa, ali još uvijek nema neke stabilne verzije koja bi mogla biti plasirana na tržište i napraviti ozbiljan iskorak u industriji. Razvoj i istraživanje na ovu temu je potrebno nastaviti zbog velikog potencijala stolica takvog tipa čije široko područje primjene samo potvrđuje njezinu nužnost. Stolica koja prati životne funkcije i sjedeći položaj nije korisna samo za potrebe ureda, već na taj način možemo točno vidjeti kako nam djeca u školama sjede te na vrijeme upućivati svakog pojedinca kako treba sjediti. Potencijala primjena ovakvog sustava pametne stolice nije samo u uredima i školama, već i u zdravstvenim ustanovama kod teško pokretnih ili nepokretnih pacijenata gdje je moguće neinvazivno promatrati osnovne životne funkcije pacijenta kao i uočiti svaki pomak sa stolice ili invalidskih kolica koji nije potreban ili dopušten od strane medicinskog osoblja.

LITERATURA

1. Ahn, B. G., Noh, Y. H. and Jeong, D. U. (2015) 'Smart chair based on multi heart rate detection system', *2015 IEEE SENSORS - Proceedings*, pp. 6–9. doi: 10.1109/ICSENS.2015.7370628.
2. Anwary, A. R., Bouchachia, H. and Vassallo, M. (2019) 'Real time visualization of asymmetrical sitting posture', *Procedia Computer Science*, 155(2018), pp. 153–160. doi: 10.1016/j.procs.2019.08.024.
3. Blake, J. J., Benden, M. E. and Wendel, M. L. (2012) 'Using Stand/Sit Workstations in Classrooms', *Journal of Public Health Management and Practice*, 18(5), pp. 412–415. doi: 10.1097/PHH.0b013e3182215048.
4. Bontrup, C., William R. T., Fliesser, M., Visscher, R., Green, T., Wippert, P. M.,Zemp, R. (2019) 'Low back pain and its relationship with sitting behaviour among sedentary office workers', *Applied Ergonomics*. doi: 10.1016/j.apergo.2019.102894.
5. Deserno, T. M. (2020) 'Transforming Smart Vehicles and Smart Homes into Private Diagnostic Spaces', *ACM International Conference Proceeding Series*, pp. 165–171. doi: 10.1145/3379310.3379325.
6. Flutur, G., Movileanu, B., Karoly, L., Danci, I., Cosovanu, D., Stan, O. P. (2019) 'Smart Chair System for Posture Correction', *Proceedings - Euromicro Conference on Digital System Design, DSD 2019*, pp. 436–441. doi: 10.1109/DSD.2019.00069.
7. Gibbs, B. B., Kowalsky, R. J., Perdomo, S. J., Grier, M., Jakicic, J. M., (2017) 'Energy expenditure of deskwork when sitting, standing or alternating positions', *Occupational Medicine*, 67(2), pp. 121–127. doi: 10.1093/occmed/kqw115.
8. Goossens, R. H. M., Netten, M. P. and Van der Doelen, B. (2012) 'An office chair to influence the sitting behavior of office workers', *Work*, 41, pp. 2086–2088. doi: 10.3233/WOR-2012-0435-2086.
9. Grbac, I. and Domljan, D. (2007) 'Namještaj i zdrav život', *Sigurnost*, 49(3), pp. 263–279.
10. Grooten, W. J. A., Conradsson, D., Äng, B. O., Franzén, E., (2013) 'Is active sitting as active as we think?', *Ergonomics*, 56(8), pp. 1304–1314. doi: 10.1080/00140139.2013.812748.
11. Harrison, D. D. Harrison, S. O., Croft, A. C., Harrison, D. E., Troyanovich, S. J., (1999) 'Sitting biomechanics Part I: Review of the Literature', *Journal of Manipulative and Physiological Therapeutics*, 22(9), pp. 594–609. doi: 10.1016/S0161-4754(99)70020-5.
12. Hesse, M., Krause, A. F., Vogel, L., Chamadiya, B., Schilling, M., Schack, T., Jungeblut, T. (2017) 'A connected chair as part of a smart home environment', *2017 IEEE 14th International Conference on Wearable and Implantable Body Sensor Networks, BSN 2017*, pp. 47–50. doi: 10.1109/BSN.2017.7936004.
13. Hu, Q., Tang, X. and Tang, W. (2020) 'A Smart Chair Sitting Posture Recognition System Using Flex Sensors and FPGA Implemented Artificial Neural Network', *IEEE Sensors Journal*, XX(XX), pp. 1–1. doi: 10.1109/jsen.2020.2980207.
14. Kim, W L and Lim, S. B. (2019) 'Smart chair cover for posture correction', *International Journal of Emerging Trends in Engineering Research*, 7(8), pp. 191–196. doi: 10.30534/ijeter/2019/14782019.
15. Kim, Woo Lim and Lim, S. B. (2019) 'Smart chair cover for posture correction', *International Journal of Emerging Trends in Engineering Research*, 7(8), pp. 191–196. doi: 10.30534/ijeter/2019/14782019.
16. Knudson, D. (2007) 'Fundamentals of biomechanics', Springer science+Business Media, LLC, 2. izdanje, str.1-6
17. Kumar, R., Bayliff, A., De, D., Evans, A., Das, S. K., Makos, M. (2016) 'Care-Chair: Sedentary Activities and Behavior Assessment with Smart Sensing on Chair Backrest', *2016 IEEE International Conference on Smart Computing, SMARTCOMP 2016*, pp. 1–8. doi: 10.1109/SMARTCOMP.2016.7501682.
18. Lee, C.-C., Saidy, L. and Fitri (2019) 'Human Activity Recognition Based on Smart Chair', *SENSORS AND MATERIALS*, 31(5, SI), pp. 1589–1598. doi: 10.18494/SAM.2019.2280.
19. Lee, F. and Lee, C. C. (2018) 'User Activity Recognition Based on Smart Chair with Pressure

Sensors', *2018 IEEE International Conference on Consumer Electronics-Taiwan, ICCE-TW 2018*, pp. 3–4. doi: 10.1109/ICCE-China.2018.8448643.
20. Ma, C., Li, W., Gravina, R., Cao, J., Li, Q., Fortino, G. (2017) 'Activity Level Assessment Using a Smart Cushion for People with a Sedentary Lifestyle', *SENSORS*, 17(10). doi: 10.3390/s17102269.
21. O'Sullivan, K., McCarthy, R., White, A., O'Sullivan, L., Wim D. (2012) 'Lumbar posture and trunk muscle activation during a typing task when sitting on a novel dynamic ergonomic chair', *Ergonomics*, 55(12), pp. 1586–1595. doi: 10.1080/00140139.2012.721521.
22. Park, M., Song, Y., Lee, J., Paek, J. (2016) 'Design and Implementation of a smart chair system for IoT', *2016 International Conference on Information and Communication Technology Convergence, ICTC 2016*, pp. 1200–1203. doi: 10.1109/ICTC.2016.7763406.
23. Prueksanusak, B., Rujivipatand, P. and Wongpatikaseree, K. (2019) 'An Ergonomic Chair with Internet of Thing Technology using SVM', *TIMES-iCON 2019 - 2019 4th Technology Innovation Management and Engineering Science International Conference*, pp. 1–5. doi: 10.1109/TIMES-iCON47539.2019.9024488.
24. Puviarasi, R. and Greeshma, A. (2019) 'Design and implementation of modernised dental chair using voice recognition control circuit', *International Journal of Innovative Technology and Exploring Engineering*, 8(9 Special Issue 2), pp. 355–357. doi: 10.35940/ijitee.I1076.0789S219.
25. Schwartz, B., Kapellusch, J. M., Schrempf, A., Probst, K., Haller, M., Baca, A. (2016) 'Effect of a novel two-desk sit-to-stand workplace (ACTIVE OFFICE) on sitting time, performance and physiological parameters: Protocol for a randomized control trial', *BMC Public Health*, 16(1), pp. 1–11. doi: 10.1186/s12889-016-3271-y.
26. Schwartz, B., Kapellusch, J. M., Baca, A., Wessner, B. (2019) 'Medium-term effects of a two-desk sit/stand workstation on cognitive performance and workload for healthy people performing sedentary work: a secondary analysis of a randomised controlled trial', *Ergonomics*, 62(6), pp. 794–810. doi: 10.1080/00140139.2019.1577497.
27. Sifuentes, E., Gonzalez-Landaeta, R., Cota-Ruiz, J., Reverter, F. (2019) 'Seat Occupancy Detection Based on a Low-Power Microcontroller and a Single FSR', *SENSORS*, 19(3). doi: 10.3390/s19030699.
28. Sodhi, S. S. and Kunwar, A. S. (2017) 'Smart Chair', (Icici), pp. 139–148.
29. Vlaović, Z. (2005) 'Istraživanje udobnosti uredskih radnih stolica'- magistarski rad. Zagreb: Šumarski Fakultet.
30. Vlaović, Z. (2009) *Činitelji udobnosti uredskih stolica'*- disertacija. Sveučilište u Zagrebu, Šumarski Fakultet.
31. Vlaović, Z., Grbac, I., Domljan, D., Bublić, A. (2010) 'Uredske radne stolice - Istraživanje deformacija i indeksa udobnosti', *Drvna Industrija*, 61(3), pp. 159–168.
32. Vlaović, Z., Bogner, A. and Domljan, D. (2006) 'Istraživanje udebnosti uredskih stolica s obzirom na obilježja ispitanika', *Drvna Industrija*, 57(3), pp. 109–117.
33. Zazula, D., Kranjec, J., Kranjec, P., Cigale, B. (2015) 'Assessing blood pressure unobtrusively by smart chair', *2015 38th International Convention on Information and Communication Technology, Electronics and Microelectronics, MIPRO 2015 - Proceedings*, (May), pp. 385–389. doi: 10.1109/MIPRO.2015.7160300.
34. Zhang, Y., Chen, Z., Chen, W., Li, H. (2019) 'Unobtrusive and Continuous BCG-Based Human Identification Using a Microbend Fiber Sensor', *IEEE ACCESS*, 7, pp. 72518–72527. doi: 10.1109/ACCESS.2019.2919407.

Web izvori:

Web 1: https://dynamicsitting.co.uk/product/hacker-office-chair/ (24. 4. 2020.)

Web 2: https://www.fully.com/chairs (24. 4. 2020.)

Web 3: https://www.backapp.com/en/products/backapp-smart/ (20. 4. 2020.)

Web 4: https://www.humanscale.com/products/standing-desks/float-table (24. 4. 2020.)

POPIS SLIKA

Slika 1. Prikaz idealnog i realnog položaja tijela prilikom stajanja 19
Slika 2. Prikaz Schoberth-ovih triju kategorija sjedenja prema položaju djelovanja centra gravitacije . 20
Slika 3. Položaj zdjelice i kralježnice kod stajanja i sjedenja 20
Slika 4 Prikaz uredske radne stolice s njezinim mogućnostima podešavanja 23
Slika 5 Prikaz pravilnog sjedenja prema HRN EN 1335-1 23
Slika 6 Prikaz stolice za dinamičko sjedenje 24
Slika 7. Prikaz nekoliko stolica za aktivno sjedenje 25
Slika 8 Prikaz stolice Backapp Smart proizvođača "Backapp" 26
Slika 9. Prikaz radnog mjesta za rad prilikom stajanja 27
Slika 10. Prikaz teorijskog modela udobnosti i neudobnosti 29
Slika 11. Shematski prikaz pretrage radova 21
Slika 12. Prikaz komponenti sustava 23
Slika 13. Shematski prikaz prijenosa podataka u stolici 23
Slika 14. Shematski prikaz senzora u stolici 24
Slika 15. Prikaz rada jastuka za identifikaciju osobe 25
Slika 16. Prikaz rada FSR senzora i način razlikovanja osoba (a) od predmeta (b) 26
Slika 17. Prikaz četiri različita položaja pri kojima se provodilo mjerenje 27
Slika 18. Prikaz rezultata ispitivanja 27
Slika 19. Analiziranje načina sjedenja modelom sjedećeg ponašanja 28
Slika 20. Shematski prikaz senzora u jastuku 29
Slika 21. Prikaz matične ploče sa senzorima 29
Slika 22. Prikaz rezultata prepoznavanja aktivnosti grafikonom 30
Slika 23. KogniChair stolica s integriranim senzorima 31
Slika 24. Grafički prikaz neobrađenih podataka dobivenih senzorom za mjerenje disanja. 32
Slika 25. Grafički prikaz neobrađenih podataka dobivenih senzorom za mjerenje otkucaja srca 32
Slika 26. Uredska stolica koja je prilagođena za pokus 33
Slika 27. Prikaz PPG senzora u rukonaslonu pokusne stolice 34
Slika 28. Prikaz EKG (Plavo) i PPG (crveno) mjerenja za omogućivanje procjene PTT 34
Slika 29. Prikaz raznih sjedećih položaja proučavanih u istraživanju 36
Slika 30. Prikaz pokusne stolice s pritisnim senzorima 37
Slika 31. Prikaz Kontrolne ploče aplikacije 38
Slika 32. Prikaz načina sjedenja u stvarnom vremenu 38
Slika 33. Grafički prikaz podataka kroz period 38
Slika 34. Načini sjedenja prilikom ispitivanja i aktivaciju senzora na stolici 39
Slika 35. Grafički prikaz rezultata strojnog učenja 40
Slika 36. Odabrani sjedeći položaji za ispitivanje 41
Slika 37. Grafički prikaz prikupljenih podataka prema različitim sjedećim položajima 42
Slika 38. Prikaz savitljivog senzora korištenog u ispitivanju 42

Slika 39. Stolica s ugrađenim savitljivim senzorima 43
Slika 40. Prikaz ispitne stolica s FSR senzorima 45
Slika 41. Prikaz rada sustava za obradu podataka 46
Slika 42. Prikaz položaja senzora na stolici 47
Slika 43. Prikaz senzora: prednja strana i stražnja strana 47
Slika 44. Prikaz web sučelja aplikacije 48
Slika 45. Prikaz mobilne aplikacije 48
Slika 46. Implementacija BCG obrade signala 49
Slika 47. Prikaz ispitanika na stolici 50
Slika 48. Primjer signala snimljenih tijekom različitih radnji 52
Slika 49. Položaj BCG senzora integriranog na pojas 56
Slika 50. Prikaz EKG i cEKG senzora u automobilu i namještaju 56
Slika 51. Prikaz asimetričnog sjedenja i vizualizacija podataka 58
Slika 52. Grafički prikaz ankete 59
Slika 53. Prikaz trenda oboljenja leđne moždine 60
Slika 54. Prikaz primjera senzora pričvršćenoga na vrat korisnika 60
Slika 55. Primjer senzora korištenog u radu 61
Slika 56. Prikaz Arduino modula 62
Slika 57. Prikaz testnog uređaja 62