

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU

FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I

INFORMACIJSKIH TEHNOLOGIJA OSIJEK

Josip Zidar

**Metode dizajna energetski učinkovitih sustava ultra niske
snage za detekciju udara u lancu opskrbe**

Doktorska disertacija



Osijek, 2025.

JOSIP JURAJ STROSSMAYER UNIVERSITY OF OSIJEK
FACULTY OF ELECTRICAL ENGINEERING, COMPUTER SCIENCE
AND INFORMATION TECHNOLOGY OSIJEK

Josip Zidar

Ultra low-power energy-efficient system design methods
for impact detection in the supply chain

Doctoral dissertation



Osijek, 2025.

Doktorska disertacija izrađena je na Fakultetu elektrotehnike, računarstva i informacijskih tehnologija Osijek, Sveučilišta Josipa Jurja Strossmayera u Osijeku.

Mentor: dr.sc. Tomislav Matić, izvanredni profesor, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek, Sveučilište Josipa Jurja Strossmayera u Osijeku

Disertacija ima 98 stranica.

Disertacija broj:

Povjerenstvo za ocjenu doktorske disertacije:

1. Dr. sc. Ivan Aleksi, izvanredni profesor, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek, Sveučilište Josipa Jurja Strossmayera u Osijeku
2. Dr. sc. Goran Martinović, redoviti profesor u trajnom zvanju, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek, Sveučilište Josipa Jurja Strossmayera u Osijeku
3. Dr. sc. Vlado Sruk, izvanredni profesor, Fakultet elektrotehnike i računarstva, Sveučilište u Zagrebu

Povjerenstvo za obranu doktorske disertacije:

1. Dr. sc. Ivan Aleksi, izvanredni profesor, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek, Sveučilište Josipa Jurja Strossmayera u Osijeku
2. Dr. sc. Goran Martinović, redoviti profesor u trajnom zvanju, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek, Sveučilište Josipa Jurja Strossmayera u Osijeku
3. Dr. sc. Vlado Sruk, izvanredni profesor, Fakultet elektrotehnike i računarstva, Sveučilište u Zagrebu

Datum obrane doktorske disertacije:

Zahvale

Zahvaljujem mentoru na poslijediplomskom studiju izv. prof. dr. sc. Tomislav Matiću koji me svojim znanjem i iskustvom vodio na putu prema akademskom stupnju doktora znanosti. Zahvaljujem mu na nebrojenim komentarima i smjernicama koje su značajno pridonijele izradi ove disertacije. Zahvaljujem izv. prof. dr. sc. Ivan Aleksiju na pomoći pri rješavanju brojnih izazova s kojima se mladi doktorand susreće. Hvala mu na velikoj podršci pri uključivanju u stručni i znanstveno-istraživački rad.

Zahvaljujem svojim roditeljima, Nikoli i Željki, na potpori i vjeri u mene tijekom cijelog mog školovanja. Posebno zahvaljujem svome ocu, bez njega ne bih bio čovjek koji danas jesam. Zahvaljujem svojoj braći, Filipu i Luki, na izvoru inspiracije i upornosti te na vjeri u mene tijekom studija. Zahvaljujem stricu Petru na motivaciji te na vjeri u obrazovanje kao jedan od temeljnih stupova društva.

Zahvaljujem kolegama Mariju, Josipu i Ani te svim ostalim kolegama koji su na bilo koji način pomogli u oblikovanju ovog postignuća.

Zahvaljujem profesorima, asistentima, suradnicima i administrativnom osoblju Fakulteta elektrotehnike, računarstva i informacijskih tehnologija Osijek koji su direktnim ili indirektnim putem pozitivno utjecali na razvoj moje karijere, ali i na karijere budućih magistara inženjera.

Sadržaj

Popis slika	iii
Popis tablica	vi
Popis kratica i oznaka	viii
1 Uvod	1
1.1 Motivacija za istraživanje	1
1.2 Ciljevi disertacije	2
1.3 Pregled sadržaja disertacije	3
2 Problemi tijekom skladištenja i transporta	4
3 Dosadašnje spoznaje i rješenja	8
3.1 Pregled postojećih rješenja	8
3.1.1 Nadzor i upravljanje uvjetima okoline u industrijskim procesima . . .	8
3.1.2 Primjene u logističkim procesima	14
3.2 Dosadašnja istraživanja na području detekcije udara u lancu opskrbe	15
3.3 Dosadašnja istraživanja na području potrošnje energije ugradbenih sustava .	19
3.4 Usporedba postojećih rješenja i izazova	25
4 Metode detekcije udara i određivanje kuta sudara u lancu opskrbe	29
4.1 Metoda za detekciju i mjerenje intenziteta udara paketa u lancu opskrbe ugradbenim sustavima ultra niske snage	29
4.1.1 Pametna naljepnica za detekciju udara paketa	30
4.1.2 Eksperimentalni rezultati	35
4.2 Metoda određivanja kuta sudara paketa prilikom detekcije udara uporabom vektora ubrzanja	50
4.2.1 Procjena horizontalnog i vertikalnog kuta sudara na temelju izmjerenog ubrzanja	50
4.2.2 Eksperimentalni rezultati	53

5	Metode dizajna energetske učinkovitih sustava niske snage	58
5.1	Metoda optimalne prilagodbe napona i frekvencije mikroupravljača za postizanje ultra niske potrošnje sustava za računalno zahtjevnih algoritme	58
5.1.1	Eksperimentalni postav	59
5.1.2	Dinamičko skaliranje frekvencije	60
5.1.3	Dinamičko skaliranje napona i frekvencije	67
5.1.4	Dizajn energetske optimiziranih ugradbenih sustava	70
5.2	Analiza potrošnje energije SPI i I2C komunikacijskih protokola u ugradbenim sustavima ultra niske potrošnje energije	73
5.2.1	Eksperimentalni postav	75
5.2.2	Potrošnja energije tijekom SPI i I2C komunikacije	76
6	Zaključak	79
6.1	Zaključci	79
6.2	Budući rad	82
	Literatura	83
	Sažetak	96
	Abstract	97
	Životopis	98

Popis slika

1.1	Primjer procesa unutar lanca opskrbe.	2
2.1	Primjer izazova koji se pojavljuju u lancu opskrbe.	5
3.1	Implementacija sustava praćenja u lancu opskrbe <i>kimchi</i> : RFID ulaz (a); prijenosni čitač (b) [25].	11
3.2	Primjena pametnog pakiranja u sustavu hladnog lanca opskrbe.	12
3.3	Shema predložene pametne oznake s prikazom podsustava: energetski podsustav (a); kontrolni podsustav (b); detekcijski podsustav (c); komunikacijski podsustav (d); pametni upravljački podsustav (e). Ekvivalentni model detekcijskog kruga (f) [34].	13
3.4	Ugradbeni sustav za dostavu lijekova postavljen u dostavni kombi. Kontejneri (zelene kutije) i RFID oznake vidljivi su s lijeve strane [40].	15
3.5	Dinamičko skaliranje napona i frekvencije, radne točke.	20
4.1	Arhitektura računalnog sustava Pametne naljepnice (a). Moguća stanja Pametne naljepnice u načinima rada za: detekciju udara (b); kontinuirano mjerenje vibracija (c).	31
4.2	Dizajn elektroničkog dijela prototipa Pametne naljepnice: gornji sloj (a); donji sloj (b).	32
4.3	Prototip Pametne naljepnice (crvena oznaka 3) zaljepljena na testni paket od drvene ploče (crvena oznaka 2) s amortizacijskim materijalom od spužve (crvena oznaka 1) (a); paket s Pametnom naljepnicom u kartonskoj kutiji (b).	32
4.4	Primjer vrijednosti magnitude ubrzanja $M(t)$: prije poništavanja šuma (a); detekcija vrhova nakon poništavanja šuma (b).	33
4.5	Laboratorijski testovi detekcije udara: pad paketa na pod (a); pad utega na paket (b).	35
4.6	Vrijednosti detekcije udara za horizontalni pad paketa s odabраних visina (800 Hz, bez FIFO-a), mjereno unutar paketa. Osi ubrzanja za udar s visine 100 cm (a), 50 cm (c), 20 cm (e), 10 cm (g) i valni oblik magnitude ubrzanja za udar s visine 100 cm (b), 50 cm (d), 20 cm (f) i 10 cm (h).	37
4.7	Vrijednosti detekcije udara za vertikalni pad paketa s odabраних visina (800 Hz, bez FIFO-a), mjereno unutar paketa. Osi ubrzanja za udar s visine 100 cm (a), 50 cm (c), 20 cm (e), 10 cm (g) i valni oblik magnitude ubrzanja za udar s visine 100 cm (b), 50 cm (d), 20 cm (f) i 10 cm (h).	38

4.8	Vrijednosti detekcije udara za horizontalni pad paketa s odabраних visina (3200 Hz, FIFO). Valni oblik magnitude ubrzanja: mjereno unutar paketa za udar s visine 100 cm (a), 50 cm (c), 20 cm (e), 10 cm (g); mjereno na paketu za udar s visine 100 cm (b), 50 cm (d), 20 cm (f) i 10 cm (h).	40
4.9	Vrijednosti detekcije udara za vertikalni pad paketa s odabраних visina (3200 Hz, FIFO). Valni oblik magnitude ubrzanja: mjereno unutar paketa za udar s visine 100 cm (a), 50 cm (c), 20 cm (e), 10 cm (g); mjereno na paketu za udar s visine 100 cm (b), 50 cm (d), 20 cm (f) i 10 cm (h).	41
4.10	Vrijednosti detekcije udara za horizontalni pad paketa s odabраних visina (1600 Hz, FIFO). Valni oblik magnitude ubrzanja: mjereno unutar paketa za udar s visine 100 cm (a), 50 cm (c), 20 cm (e), 10 cm (g); mjereno na paketu za udar s visine 100 cm (b), 50 cm (d), 20 cm (f) i 10 cm (h).	42
4.11	Vrijednosti detekcije udara za vertikalni pad paketa s odabраних visina (1600 Hz, FIFO). Valni oblik magnitude ubrzanja: mjereno unutar paketa za udar s visine 100 cm (a), 50 cm (c), 20 cm (e), 10 cm (g); mjereno na paketu za udar s visine 100 cm (b), 50 cm (d), 20 cm (f) i 10 cm (h).	43
4.12	Vrijednosti detekcije udara za horizontalni pad paketa s odabраних visina (400 Hz, FIFO). Valni oblik magnitude ubrzanja: mjereno unutar paketa za udar s visine 100 cm (a), 50 cm (c), 20 cm (e), 10 cm (g); mjereno na paketu za udar s visine 100 cm (b), 50 cm (d), 20 cm (f) i 10 cm (h).	44
4.13	Vrijednosti detekcije udara za vertikalni pad paketa s odabраних visina (400 Hz, FIFO). Valni oblik magnitude ubrzanja: mjereno unutar paketa za udar s visine 100 cm (a), 50 cm (c), 20 cm (e), 10 cm (g); mjereno na paketu za udar s visine 100 cm (b), 50 cm (d), 20 cm (f) i 10 cm (h).	45
4.14	Vrijednosti detekcije udara za pad utega na nepomični paket (1600 Hz, FIFO). Valni oblik magnitude ubrzanja mjereno unutar paketa za pad utega s visine 100 cm (a), 50 cm (b) i 20 cm (c). Za pad s visine od 10 cm vrijednost magnitude nije prešla prag detekcije. . . .	46
4.15	Slanje paketa s Pametnom naljepnicom na putovanje od Osijeka do Dubrovnika.	47
4.16	Detekcija dvaju udara (a) i (b) te njihove magnitude ubrzanja za paket na putovanju od Osijeka do Dubrovnika (1600 Hz, FIFO).	48
4.17	Mjerni postav uključuje: Keysight 34465A multimetar (a); dijagram mjernog postava (b).	49
4.18	Kutovi nagiba, prevaljivanja i skretanja rotirajućeg paketa.	51
4.19	Prototip Pametne naljepnice za detekciju udara.	53
4.20	Izmjerene vrijednosti kuteva pri rotaciji paketa u horizontalnom smjeru za očekivane kutove $\phi' = -180^\circ$ i $\theta' = 0^\circ$ (a); $\phi' = -135^\circ$ i $\theta' = 0^\circ$ (b); $\phi' = 90^\circ$ i $\theta' = 0^\circ$ (c); $\phi' = 180^\circ$ i $\theta' = 0^\circ$ (d). Vrijednosti senzora ubrzanja prikazane su s $x(t)$, $y(t)$ i $z(t)$. Kutovi udara paketa označeni su s <i>Roll</i> i <i>Pitch</i>	55

4.21	Izmjerene vrijednosti kuteva pri rotaciji paketa u vertikalnom smjeru za očekivane kutove $\phi' = -180^\circ$ i $\theta' = 0^\circ$ (a); $\phi' = 135^\circ$ i $\theta' = -45^\circ$ (b); $\phi' = -135^\circ$ i $\theta' = 45^\circ$ (c); $\phi' = 0^\circ$ i $\theta' = 0^\circ$ (d). Vrijednosti senzora ubrzanja prikazane su s $x(t)$, $y(t)$ i $z(t)$. Kutovi udara paketa označeni su s <i>Roll</i> i <i>Pitch</i>	57
5.1	Mjerni postav uključuje: GW INSTEK PSB-1400L izvor napajanja (a); dijagram mjernog postava (b).	59
5.2	Graf potrošnje energije s primijenjenim DFS-om za operaciju: E_{FFT128} (a); E_{FFT32} (b); E_{CRC32} (c); E_{MD5} (d); E_{SHA256} (e).	66
5.3	Eksponencijalni model za izračun stabilnog napona (crveni krugovi označavaju točke $T1$ i $T2$).	68
5.4	Usporedba DVFS-a i DFS-a. Graf potrošnje energije za operaciju: E_{FFT128} (a); E_{FFT32} (b); E_{CRC32} (c); E_{MD5} (d); E_{SHA256} (e).	69
5.5	Dijagram konfiguracije I2C-a (a) i dijagram konfiguracije SPI-a (b).	75
5.6	Push-pull (a) i pull-up (b) konfiguracije.	77

Popis tablica

3.1	Pregled postojećih sustava u literaturi. Skraćenice za parametre: T = temperatura, V = vlaga, S = svjetlost, KUD = Koncentracija ugljen-dioksida, P = pritisak, L = Lokacija, OV = oznaka vremena (eng. <i>timestamp</i>)	26
4.1	Krhkost izražena u g razinama za različite kategorije proizvoda [65].	30
4.2	Izmjerena potrošnja struje pametne naljepnice pri različitim frekvencijama uzorkovanja ubrzanja.	49
4.3	Procijenjeno trajanje rada Pametne naljepnice na temelju mjerenja potrošnje struje u načinu niske potrošnje i aktivnom načinu za različit broj mjerenih udara po danu.	50
4.4	Usporedba izmjerenih i očekivanih vrijednosti kuteva pri rotaciji paketa u horizontalnom smjeru.	54
4.5	Usporedba izmjerenih i očekivanih vrijednosti kuteva pri rotaciji paketa u vertikalnom smjeru.	56
5.1	Prosječne vrijednosti od 100 mjerenja električne struje i vremena izvođenja pojedinih algoritama u ovisnosti o ulaznim vrijednostima frekvencije pri fiksnom naponu (DFS).	64
5.2	Izračunata potrošnja električne energije uz dinamičko skaliranje frekvencije, na temelju tablice 5.1 (podebljane vrijednosti označavaju minimalnu izmjerenu potrošnju).	65
5.3	Izračunata potrošnja električne energije uz dinamičko skaliranje napona i frekvencije (podebljane vrijednosti označavaju minimalnu izmjerenu potrošnju).	70
5.4	Izračunati postotak smanjenja potrošnje energije za DFS u odnosu na DVFS.	70
5.5	Izračunate PPW vrijednosti za energetski optimiziran sustav (veći iznos je bolji).	71
5.6	Proširena usporedba karakteristika I2C i SPI komunikacijskih protokola	74
5.7	Karakteristike mjernog postava.	76
5.8	Potrošnja struje tijekom SPI komunikacije s registrima uređaja.	76
5.9	Potrošnja struje tijekom I2C komunikacije s registrima uređaja.	77
5.10	Pregled prikladnosti komunikacijskih protokola i sabirnica	78

Popis algoritama

4.1	Detekcija udara i pohrana mjerenja	34
4.2	Procjena kuta sudara paketa	52
5.1	FFT funkcija za ulazne podatke veličine n (potencije broja 2).	61
5.2	CRC32 funkcija za ulazne podatke veličine n	61
5.3	MD5 funkcija za ulazne podatke veličine n	62
5.4	SHA256 funkcija za ulazne podatke veličine n	63
5.5	Programski pristup za dinamičko prilagođavanje frekvencije prema zahtjevima operacija	71

Popis kratica i oznaka

AHRS	Attitude and Heading Reference System
ASTM	American Society for Testing and Materials
CPU	Central Processing Unit
DDL	Digital Delay Line
DFC	Dynamic Frequency Control
EKF	Extended Kalman Filter
FPGA	Field-Programmable Gate Array
IMU	Inertial Measurement Unit
ISO	International Organization for Standardization
MEMS	Micro Electronic Mechanical Systems
RO	Ring Oscillator
VCO	Voltage Controlled Oscillators
WSN	Wireless Sensor Network
CPLD	Complex Programmable Logic Device
CRC	Cyclic Redundancy Check
DFS	Dynamic Frequency Scaling
DVFS	Dynamic Voltage and Frequency Scaling
DVS	Dynamic Voltage Scaling
EEPROM	Electrically Erasable Programmable Read-Only Memory
ER	Energy reduction

FFT	Fast Fourier Transformation
FIFO	First-In First-Out
I2C	Inter Integrated Circuit
IoT	Internet of Things
LDO	Low-Dropout Regulator
MD5	Message-Digest Algorithm 5
MCU	Microcontroller Unit
NFC	Near Field Communication
PPW	Performance Per Watt
PLL	Phase-Locked Loop
RFID	Radio-Frequency Identification
RTC	Real-Time Clock
RH	Relative Humidity
RMS	Root Mean Square
SHA	Secure Hash Algorithm
SPI	Serial Peripheral Interface
UART	Universal Asynchronous Receiver-Transmitter

1

Uvod

Lanac opskrbe je velik i složen proces koji se sastoji od nekoliko faza. Glavne faze uključuju transport, skladištenje, inventuru, pakiranje, informacije i kontrolu (slika 1.1). Pakirani proizvodi u lancu opskrbe izloženi su riziku od fizičkih oštećenja uslijed raznih čimbenika, uključujući udare, vibracije, promjene temperature, vlažnosti zraka, tlaka te izloženosti svjetlu. Iako su paketi propisno zaštićeni amortizirajućim materijalom, visoke razine ubrzanja mogu rezultirati ozbiljnim oštećenjima proizvoda unutar paketa [1]. Rukovanje velikim paletama složenih kutija s proizvodima može dovesti do oštećenja proizvoda, najčešće zbog vibracija (neravnoteža u opterećenju, nepravilne površine) ili udara (padovi, iskliznuća) tijekom rukovanja i transporta [2, 3].

1.1 Motivacija za istraživanje

Proizvodi nerijetko putuju tisućama kilometara prije nego što stignu do krajnjeg korisnika. Tijekom procesa skladištenja i transporta mogu biti izloženi različitim uvjetima okoline koji mogu nepovoljno utjecati na njihovu kvalitetu i sigurnost. Precizno praćenje i zapisivanje ovih uvjeta postalo je nužnost kako bi se osigurala kvaliteta i smanjio rizik od oštećenja ili kvarenja. Razvoj sustava s niskom potrošnjom energije preduvjet je za produljenje vremena trajanja baterije, smanjenje operativnih troškova i dugotrajno praćenje bez potrebe za čestim zamjenama ili punjenjem baterija. Detekcija udara i vibracija tijekom transporta može pružiti važne informacije o mogućim oštećenjima proizvoda. Korištenjem naprednih senzora i algoritama za detekciju udara, moguće je identificirati trenutke kada je proizvod bio izlo-



Slika 1.1: Primjer procesa unutar lanca opskrbe.

žen štetnim uvjetima i poduzeti odgovarajuće mjere kako bi se spriječila daljnja oštećenja u budućnosti. Oštećeni proizvodi rezultiraju izravnim financijskim gubicima, povećanjem količine otpada i negativnim utjecajem na okoliš, dok istovremeno mogu narušiti reputaciju poduzeća te dovesti do dodatnih operativnih troškova povezanih s povratima, zamjenama i logistikom [4, 5].

1.2 Ciljevi disertacije

Tradicionalni sustavi za praćenje uvjeta skladištenja i transporta često se suočavaju s ograničenom skalabilnošću i visokom potrošnjom energije, čineći ih nepogodnim za dugotrajnu upotrebu u izazovnim uvjetima.

Prvi znanstveni doprinos ovog rada je razvoj metode za detekciju i kvantitativnu procjenu vjerojatnosti oštećenja, na temelju udara paketa tijekom skladištenja i transporta. Primjenom ove metode unaprijeđuje se praćenje i očuvanje integriteta proizvoda tijekom cijelog logističkog procesa, od trenutka otpreme do dostave na krajnje odredište. Identifikacija i detekcija udara tijekom transporta predstavljaju izazov zbog varijabilnosti uvjeta pod kojima se udari događaju. Navedeni doprinos detaljno je objašnjen u poglavlju 4.

Drugi znanstveni doprinos uključuje razvoj metode za procjenu vertikalnih i horizontalnih kutova sudara paketa, što omogućuje detaljnu analizu uvjeta pod kojima dolazi do oštećenja. Problem kod kvantifikacije oštećenja paketa javlja se kada kut sudara nije poznat, što onemogućuje procjenu je li paket pao pod ostrim ili blagim kutom. U takvim uvjetima teško je odrediti jedinstvenu razinu oštećenja. Ovisno o izmjerenim vrijednostima intenziteta udara i kuta sudara, moguće je preciznije procijeniti stanje paketa tijekom logističkog procesa. Navedeni doprinos detaljno je objašnjen u potpoglavlju 4.2.

Treći znanstveni doprinos uključuje razvoj metode ultra niske potrošnje, s kojom se ostvaruju zahtjevi za dugotrajnim i pouzdanim radom ugradbenog sustava. Razvoj sustava s niskom potrošnjom energije jedan je od preduvjeta za ostvarenje ciljeva ove disertacije. Radni režim ugradbenog sustava dinamički se prilagođava zahtjevima performansi, čime se postiže optimalna potrošnja energije. Navedeni doprinos detaljno je objašnjen u poglav-

lju 5. Predloženi doprinosi ove disertacije omogućuju višu razinu učinkovitosti i pouzdanosti sustava za praćenje uvjeta u lancu opskrbe, doprinose optimizaciji logističkih procesa te smanjenju rizika od oštećenja proizvoda.

1.3 Pregled sadržaja disertacije

Struktura ovog rada nalazi se u nastavku. U poglavlju 2 pružen je pregled na probleme koji se pojavljuju tijekom skladištenjka i transporta. Poglavlje 3 posvećeno je pregledu relevantne literature te analizi postojećih rješenja unutar istraživačkog područja. U poglavlju 4 predstavljene su metode za detekciju udara i određivanje kuta sudara uslijed skladištenja i transporta u lancu opskrbe. Poglavlje 5 predstavlja metodu niske potrošnje energije s primjenom na ugradbene sustave. Zaključno, poglavlje 6 iznosi glavne zaključke rada, uz preporuke i smjernice za buduće istraživanje.

2

Problemi tijekom skladištenja i transporta

U današnjem globaliziranom tržištu, učinkovit i siguran transport proizvoda unutar lanca opskrbe ključan je za zadovoljstvo kupaca i smanjenje financijskih gubitaka zbog oštećenja proizvoda. Ubrzani razvoj tehnologije i globalizacija tržišta značajno su povećali složenost lanca opskrbe, gdje se svakodnevno transportira iznimno velik broj proizvoda. Očuvanje kvalitete i integriteta proizvoda tijekom transporta postaje ključan izazov za proizvođače i distributere. Oštećenje proizvoda uzrokovano udarima i vibracijama tijekom transporta može dovesti do znatnih financijskih gubitaka, smanjenja zadovoljstva kupaca i narušavanja reputacije kompanija. Proizvodi tijekom transporta, skladištenja i rukovanja mogu biti izloženi različitim opasnostima, uključujući promjene temperature, vlažnosti zraka, udare i vibracije (slika 2.1). Navedeni utjecaji mogu uzrokovati ozbiljna oštećenja, posebno kod osjetljivih proizvoda kao što su elektronički uređaji ili kod prehrambenih proizvoda gdje nepropisna temperatura može uzrokovati kvarenje hrane. Tradicionalne metode zaštite, kao što su ambalaža i zaštitni materijali, često nisu dovoljno učinkovite u pronalasku uzroka i prevenciji svih potencijalnih oštećenja, što ukazuje na potrebu za naprednijim tehnologijama koje mogu pružiti preciznije informacije o uvjetima transporta [6–8].

U transportu osjetljivih proizvoda, kao što su elektronički uređaji, medicinska oprema i prehrambeni artikli, precizno praćenje uvjeta transporta predstavlja ključni faktor za očuvanje kvalitete i sigurnosti tih proizvoda. Primjerice, prilikom transporta televizijskih prijemnika, izloženost udarnim silama koje prelaze specificirane amplitude može dovesti do nepopravljivih oštećenja. Sukladno tome, u nastavku su navedeni izazovi i problemi koji se pojavljuju tijekom skladištenja i transporta proizvoda [9].



Slika 2.1: Primjer izazova koji se pojavljuju u lancu opskrbe.

Izazovi i problematika koji su predmet analize u ovome doktorskom radu:

- neadekvatno praćenje informacija o uvjetima okoline tijekom skladištenja i transporta u lancu opskrbe
- nedostatak podataka o pojavi i intenzitetu udara tijekom skladištenja i transporta
- nedostatak informacija o kutu sudara pod kojim je došlo do udara paketa
- nepoznavanje podataka o vremenu i/ili lokaciji udara paketa ili nepovoljnih uvjeta okoline
- ograničeno operativno vrijeme ugradbenih sustava zbog kratkog vijeka trajanja baterije i ograničenih izvora napajanja
- problemi s kvalitetom koji utječu na korisnike u lancu opskrbe
- izazovi u usklađenosti sa zakonima i propisima za sve sudionike u lancu opskrbe.

Za praćenje uvjeta skladištenja i transporta u okviru ove disertacije, potreban je razvoj naprednih metoda i sustava koji omogućuju detekciju i analizu mehaničkih udara u stvarnom vremenu. Procjena vertikalnih i horizontalnih kutova nagiba pri udaru paketa također pružaju dodatne informacije o ozbiljnosti i potencijalnim uzrocima oštećenja, čime se mogu unaprijediti dizajn ambalaže i metode rukovanja. Potreban je pristup podacima o stanju paketa tijekom cijelog transportnog procesa. Na temelju izazova u ovome doktorskom radu, predlažu se sljedeći pristupi i metode.

- 1) Detekcija udara paketa u lancu opskrbe uz prikupljene vrijednosti amplitude udara i vremenom (lokacijom) kada je došlo do pojave udara.
- 2) Metoda koja omogućuje procjenu kuta pod kojim je došlo do udara paketa, koja se temelji na metodi za detekciju udara. Utvrđeno je da razina oštećenja paketa ovisi i o površini na kojoj se udar manifestira.
- 3) Definirati kriterije za procjenu vjerojatnosti oštećenja paketa, koji se temelje na faktorima kao što su intenzitet udara, vertikalni i horizontalni kutovi sudara, vrijeme trajanja udara

- 4) Optimizacija potrošnje energije uz primjenu metoda dinamičkog skaliranja napona i frekvencije te optimizacijom komunikacijskih protokola. Cilj je postići istu razinu funkcionalnosti sustava uz istovremeno mjerljivo smanjenje potrošnje energije.
- 5) Implementacija metoda za ultra nisku potrošnju energije omogućuju duži vijek trajanja baterije i kontinuirani rad uređaja bez potrebe za čestim zamjenama baterija, što omogućuje primjenu u lancu opskrbe.

Razvoj metode za detekciju udara paketa uključuje razvoj ugradbenog računalnog sustava koji se fiksira na odabrani paket. Razvijeni ugradbeni sustav u daljnjem tekstu ovog rada referirat će se kao "Pametna naljepnica" (engl. *Smart Sticker*). Za testiranje metoda detekcije udara paketa razvijen je eksperimentalni sustav koji omogućuje kontrolirano ispuštanje paketa pod pravim kutom s unaprijed definiranih visina. Amplituda udara određena je masom paketa i početnom referentnom visinom s koje je paket pušten. Implementacija metode za procjenu kutova nagiba temelji se na podacima prikupljenih senzorom ubrzanja (engl. *accelerometer*), koji pružaju uvid u dinamičke uvjete tijekom transporta. Kut sudara paketa pruža detaljnije informacije o razini oštećenja paketa i uvid u površinu udara. Ukoliko se udar paketa manifestira na manjoj površini (rub paketa) može se očekivati da je deformacija paketa veća u odnosu na slučaj kada bi se udar manifestirao na većoj površini paketa. Ovim pristupom moguć je razvoj naprednih modela i simulacija koji mogu predvidjeti potencijalna oštećenja i optimizirati metode pakiranja.

Uzimajući u obzir navedene zahtjeve, predloženi sustav treba biti realiziran u skladu s navedenim izazovima. Prisutni su tehnički izazovi poput otpornosti na vanjske utjecaje, mjerna preciznosti senzora i pouzdanosti. Kako bi se prikupljeni podaci prenijeli u sustav za prikupljanje podataka, potrebno je osigurati pouzdanu povezivost. Prisutni su zahtjevi za obradom, analizom prikupljenih podataka i integracijom podataka iz različitih izvora, karakteristično za sustave stvarnog vremena. Kako bi sustav mogao ispunjavati svoju zadaću tijekom cijelog razdoblja skladištenja i transporta, nužno je ostvariti svojstvo ultra niske potrošnje energije. Preporučene metodologije za opisani ugradbeni računalni sustav obuhvaćaju učinkovitu razmjenu informacija uz nisku potrošnju energije, kao i pouzdano čitanje i pohranu prikupljenih podataka. Memorijska ograničenja stvaraju potrebu za komprimiranim spremanjem podataka bez gubitaka.

Doprinosi ovog doktorskog rada imaju potencijal sniziti troškove povezane s oštećenjem proizvoda uz povećanje učinkovitosti transporta i skladištenja. Time se unapređuje korisničko iskustvo te omogućuje pouzdanija i učinkovitija dostava proizvoda. Doprinosi u poglavlju 4 primjenjivi su za testiranje i razvoj tehnologije pakiranja. Zabilježeni intenzitet udara primjenjuje se kao mjera oštećenja paketa, ukoliko je prekoračen intenzitet udara koji se smatra štetan za pojedinu vrstu paketa. Razvijena Pametna naljepnica primjenjiva je za automatizaciju sustava za inspekciju i individualno nadgledanje pakiranja. Doprinosi pred-

stavljani u poglavlju 5 omogućuju dugotrajan, višemjesečni rad sustava za praćenje uvjeta tijekom skladištenja i transporta. Predstavljani doprinosi imaju široku primjenu u raznovrsnim industrijama koje se oslanjaju na transport i skladištenje osjetljivih proizvoda, kao što su elektronska, farmaceutska, kemijska i prehrambena industrija. Istraživanja u ovome području ističu suvremene izazove u logistici i transportu te doprinose održivom razvoju i smanjenju ekološkog otiska tehnologije.

3

Dosadašnje spoznaje i rješenja

U ovom poglavlju izložen je pregled prethodnih istraživanja fokusiranih na lanac opskrbe te strategije za smanjenje potrošnje energije u ugradbenim sustavima.

3.1 Pregled postojećih rješenja

Praćenje proizvoda tijekom skladištenja, transporta i kroz cijeli životni ciklus predstavlja temeljni aspekt u različitim znanstvenim i industrijskim disciplinama, osiguravajući transparentnost, optimizaciju logističkih procesa te održavanje kvalitete i sigurnosti proizvoda u svim fazama njegova upravljanja. Radiofrekvencijska identifikacija (engl. *Radio-Frequency Identification - RFID*) primijenjena je u industrijama poput tekstilne, prehrambene, farmaceutske, medicinske, elektroničke itd. [10–12]. U nastavku ovog poglavlja nalazi se pregled postojećih rješenja koja se odnose na praćenje uvjeta u skladištenju i transportu proizvoda.

3.1.1 Nadzor i upravljanje uvjetima okoline u industrijskim procesima

Kontrolirani temperaturni uvjeti preduvjet su za očuvanje kvalitete i sigurnosti proizvoda tijekom skladištenja. Kontrola i praćenje uvjeta primjenjuje se u prehrambenoj industriji gdje se želi osigurati visoka kvaliteta svih proizvoda, ali osobito pokvarljive hrane poput mlijeka, jaja, mesa, voća ili povrća. Različiti proizvodi zahtijevaju specifične temperaturne uvjete kako bi se spriječilo kvarenje, degradacija ili rast bakterija. Prehrambena industrija zahtjeva

propisanu temperaturu, posebno kod zamrznutih proizvoda [13]. Pregrijavanje može uzrokovati degradaciju prehrambenih proizvoda, lijekova i kozmetičkih proizvoda te skraćivanje životnog vijeka elektroničkih proizvoda. Previsoka temperatura može izazvati i omekšavanje, deformaciju, topljenje ili čak oslobađanje štetnih kemikalija iz plastike. Relativna vlaga može utjecati na proizvode kao što su hrana, papir, elektronika ili građevinski materijal. Previsoka vlaga može uzrokovati kondenzaciju, plijesan, koroziju ili kvarenje proizvoda. Prisutnost UV zračenja može nepovoljno utjecati na proizvod ili ambalažu proizvoda, čime dolazi do gubitka integriteta ambalaže, gubitka boje, propuštanja ili kontaminacije proizvoda. UV zračenje može uzrokovati fizičko oštećenje materijala, poput starenja, pucanja, promjene površinske strukture ili gubitka čvrstoće kod materijala poput gume, plastike, drva ili tekstila [5, 14, 15]. Mehanički izvori oštećenja mogu uzrokovati fizička oštećenja na proizvodu odnosno ogrebotine, pukotine, lomove ili deformacije. Gubitkom integriteta ambalaže može doći do propuštanja ili kontaminacije proizvoda, smanjenja roka trajanja ili izgubljene vrijednosti. Oštećeni proizvodi mogu biti neprihvatljivi za prodaju, moraju se povući s tržišta ili prodavati po sniženoj cijeni, što rezultira financijskim gubitkom [8, 16].


Kako bi se utjecaj navedenih izazova smanjio, potpuna automatizacija elemenata lanca opskrbe postao je cilj uslijed brzog razvoja informacijskih tehnologija. RFID tehnologija pružila je rješenje za informacijske probleme u razvoju procesa opskrbnog lanca. Nastankom i razvojem RFID tehnologije, baterija, mikroupravljača i senzora niske potrošnje, omogućen je potpun pristup informacijama o uvjetima skladištenja i distribucije proizvoda. Navedene informacije su od interesa za proizvođača, distributera, prodavatelja i krajnjeg kupca. Osim što svim sudionicima omogućuje uvid u podatke o uvjetima okoline, sustav za praćenje uvjeta okoline omogućuje uvid u podatke na svim mjestima opskrbnog lanca, s mogućim početkom mjerenja već u procesu proizvodnje [17].

Sustav sljedivosti unaprijeđuje sigurnost i kvalitetu u lancu opskrbe hranom. Učinkovit sustav sljedivosti omogućuje pravovremeno povlačenje proizvoda s tržišta radi sigurnosti i zaštite potrošača, što smanjuje ukupne troškove povlačenja te olakšava otkrivanje i uklanjanje uzroka nastalih problema. Upravljanje kvarljivim prehrambenim proizvodima zahtijevaju kontroliranu temperaturu kako bi se održala kvaliteta. Propisno odabrani intervali temperature produljuju ili održavaju rok trajanja kvarljivih namirnica. Zamrzavanje i hlađenje su najčešće korištene metode za usporavanje rasta bakterija koje dovode do kvarenja hrane [10, 13]. RFID oznaka (engl. *RFID tag*) za praćenje lanca zamrznute hrane predstavljena je u [18]. Sustav integrira senzore svjetla, temperature i vlage, mikroupravljač, memorijski sklop, elektroniku male snage i RFID antenu za komunikaciju. Oznake se mogu istovremeno očitavati tijekom prolaska kroz čitač, na potpuno automatiziran način. Sustav je primijenjen na interkontinentalni logistički lanac svježe ribe. Autori u [19] predstavljaju razvoj pametnih RFID oznaka koje sadrže senzore s mogućnošću mjerenja temperature, relativne vlage zraka i prisutnosti hlapljivih spojeva amino-skupine. RFID oznake potrošačima mogu garantirati svježinu i kvalitetu, dok bi maloprodajnoj industriji omogućile učinkovitije

upravljanje zalihama hrane i autentičnost proizvoda. Sustav opisan u [20] integrira RFID tehnologiju s metodama spektralne analize kako bi omogućio procjenu ključnih parametara kvalitete sira, uključujući pH vrijednost, sadržaj vode, koncentraciju klorida i udio masti. RFID oznaka koristi se za identifikaciju sira i pruža informacije o kvaliteti putem web sučelja. Razvoj i evaluacija sustava sljedivosti temeljenog na RFID tehnologiji za sigurnost i kvalitetu goveda/govedine u Kini predstavljen je u [21]. Analizirani su zahtjevi lanca opskrbe govedinom te ključne informacije o sljedivosti takvog sustava. Predložen je konceptualni model za opisivanje procesa prikupljanja, transformacije i prijenosa informacija o sljedivosti duž opskrbnog lanca. Autori u [15] daju pregled istraživanja i tehnologije koje omogućuju razvoj novih generacija inteligentne ambalaže za hranu. Ambalaža može detektirati, nadzirati ili evidentirati promjene u proizvodu, pakiranju ili njegovom okolišu. Autor u [22] analizira prednosti i nedostatke korištenja RFID i blockchain tehnologija u izgradnji sustava koji obavlja cijeli proces prikupljanja podataka i upravljanje informacijama svih karika u opskrbnom lancu poljoprivredno-prehrambenih proizvoda.

Projekt koji se temelji na Internetu poljoprivrednih stvari (engl. *Agricultural Internet of Things*) u [23], integrira senzorske tehnologije, RFID sustave i tehnologiju bežičnih senzorskih mreža (engl. *Wireless Sensor Networks - WSN*) za prikupljanje podataka o kretanju i okolišnim uvjetima ciljanih objekata. Prikupljeni podaci iz lanaca opskrbe svježim povrćem objedinjeni su i predstavljeni putem intuitivnog sučelja, pružajući krajnjim korisnicima uvid u ključne informacije. Sustav koristi napredne metode upravljanja i analize podataka kako bi osigurao povezivanje informacija, kompatibilnost programskog kôda i sljedivost unutar lanca opskrbe. Korištenje RFID tehnologije za praćenje i nadzor prehrambenih proizvoda te osiguranje sigurnosti i kvalitete hrane analizirano je u [11]. Rad daje pregled osnova RFID tehnologije, postojećih senzora i RFID senzorskih oznaka. Implementacija senzora i novih tehnologija omogućavaju detekciju markera pokvarene hrane. Senzor plina je učinkovit alat za provjeru integriteta ambalaže prehrambenih proizvoda, omogućujući detekciju potencijalnih propuštanja ili promjena u atmosferi unutar pakiranja. Autori u [24] predložili su integrirani sustav za sljedivost i nadzor svježine prehrambenih proizvoda koji se temelji na RFID tehnologiji, bežičnim senzorskim mrežama (WSN) i tehnikama rudarenja podataka. Sustav omogućuje praćenje lokacije proizvoda te prikupljanje podataka o temperaturi i vlažnosti tijekom skladištenja i transporta, čime se osigurava kvaliteta i sigurnost hrane. Sustav je implementiran na lancu opskrbe *kimchi* u Koreji, a tehnike rudarenja podataka koriste se za predviđanje podataka sa senzora koji nedostaju.


Autori u [25] testirali su RFID sustav na lancu opskrbe, uz mjerenje temperature i vlage. Sustav se koristi za praćenje lako pokvarljive hrane u lancu opskrbe *kimchi*. Postignuta je preciznost od 96.67 % u praćenju smjera kretanja proizvoda, korištenjem IoT senzora i modela strojnog učenja. RFID tehnologija prati smjer kretanja proizvoda putem jačine signala i vremenskih oznaka. Predloženi uređaj temelji se na Raspberry Pi sustavu, a primjena je prikazana na slici 3.1. Sustav je pokazao ograničenja u RFID skeniranju zbog metalnih prepreka



Slika 3.1: Implementacija sustava praćenja u lancu opskrbe *kimchi*: RFID ulaz (a); prijenosni čitač (b) [25].

i zahtjeva visoke troškove implementacije, dok je složenost strojnog učenja povećala operativne izazove. Autori u [20] predlažu RFID oznaku za sustav praćenja, pri čemu se RFID oznake koriste za identifikaciju sira na kojemu se provode analize kvalitete. Potrošači mogu dobiti informacije o kvaliteti sira na razvijenoj online platformi. Autori u [18] predstavljaju ugradbeni sustav temeljen na mikroupravljaču MSP430F tvrtke Texas Instruments, gdje se koristi RFID predajnik od 13.56 MHz i senzori za praćenje tragova hrane u hladnom lancu opskrbe. Kompleksni programabilni logički uređaj (engl. *Complex Programmable Logic Device* - *CPLD*) koristi se za energetski učinkovitu komunikaciju te istovremeno djeluje kao izvor napajanja. Predloženi uređaj u stvarnim uvjetima ostvaruje maksimalni radni vijek rada do 35 h , koristeći bateriju kapaciteta 25 mAh i provodeći mjerenja temperature svake 2 min tijekom transporta od Frankfurta do Vitorije.

Autori u [26] predstavili su novi sustav procjene kvalitete hrane koji se ne temelji samo na datumima "upotrebljivo do", već umjesto toga uključuje praćenje temperature u stvarnom vremenu za točnu procjenu svježine i sigurnosti hrane. Predlaže se nova tehnologija koja koristi pametno označavanje hrane, koja se temelji na bežičnoj vremensko-temperaturnoj povijesti (engl. *time-temperature history*). Izrađuje se pomoću fleksibilne tiskane pločice ispisane u kolutima (engl. *roll-to-roll*), kako bi potrošačima pružila podatke o sigurnosti hrane u stvarnom vremenu putem pametnih telefona (slika 3.2) i NFC protokola. NFC (engl. *Near Field Communication*) je podskup RFID tehnologije koja je dizajnirana za podršku komunikacije kratkog dometa za mobilne uređaje. NFC pristup bez baterije predstavljen je na senzorskoj naljepnici RF430FRL152H tvrtke Texas Instruments [27]. Senzorska naljepnica




Slika 3.2: Primjena pametnog pakiranja u sustavu hladnog lanca opskrbe.

mjeri temperaturu i šalje podatke o temperaturi skeniranja. Glavna primjena je u medicinskoj industriji gdje se pacijentova temperatura može odmah skenirati pomoću mobilnog telefona i NFC komunikacije. Autori u [28] predstavljaju bežični sustav za praćenje tjelesne temperature, namijenjen za primjenu u medicini i kućnoj zdravstvenoj njezi. Sustav se temelji na NFC tehnologiji i koristi inovativni dizajn ultra niske potrošnje energije, analogni sklop te integrirano sučelje za prikupljanje energije. Jedna od ključnih karakteristika sustava je njegova sposobnost rada u uvjetima ograničenih energetske resursa. U većini slučajeva baterija se ne može puniti, već se odlaže nakon korištenja. U specifičnim aplikacijama uređaj omogućuje rad bez upotrebe baterije, koristeći prikupljenu energiju za bežični prijenos trenutnih očitavanja senzora integriranih na sklopu. Ovakav pristup omogućuje jednostavno i učinkovito praćenje temperature uz minimalno održavanje.

Autori u [29] istražuju utjecaj sastava hrane, temperature i orijentacije RFID oznaka na performanse RFID tehnologije u prehrambenoj industriji. Eksperimentalno su pokazali da visok sadržaj vode i soli u hrani značajno smanjuje domet očitavanja zbog dielektričnih svojstava, dok nepravilna orijentacija oznaka dodatno otežava čitljivost. RFID sustav potrebno je prilagoditi specifičnim karakteristikama proizvoda, poput prilagođavanja frekvencije i pozicioniranja oznaka za proizvode s visokim udjelom vode ili metala u ambalaži. Precizna kontrola snage antene i optimizacija orijentacije oznaka ključni su za pouzdano očitavanje u stvarnim industrijskim uvjetima. Samoreagirajući vremensko-temperaturni indikator (engl. *time-temperature indicator*) za osiguranje hladnog opskrbnog lanca kvarljive hrane predstavljen je u [30]. Korišteni indikator je neproziran pri hladnim temperaturama zbog raspršenja svjetlosti izazvanog nanovlaknima. Znak upozorenja za neadekvatnu temperaturu pojavljuje se kada indikator postane proziran. Indikator nepovratno postaje proziran uslijed neadekvatne temperature. Nedostatak ovakvog rješenja je nedovoljna količina informacija o trajanju i mjestu pojave nepovoljnih uvjeta, dok su prednosti cijena i jednostavnost primjene. Autori u [14] implementirali su indikator kritične temperature koji koristi tehnolo-

logiju mikrofluidike, koji je integriran s RFID oznakama. Indikator omogućava nepovratne vizualne promjene boje uz prijenos podataka putem RFID čitača. Time se omogućava praćenje temperature u stvarnom vremenu na odabranim mjestima u lancu opskrbe. Pasivni senzor vlage predstavljen je u [31], gdje se omogućuje prikaz maksimalne relativne vlage tijekom određenog vremenskog razdoblja. Senzor mjeri vlagu na principu lateralne oksidacije aluminijskih slojeva na nanorazini. Autori u [32] koristili su oznaku pasivne temperature. Energetski optimizirana oznaka u kombinaciji sa senzorom temperature male snage, omogućuje očitavanje temperature na udaljenosti od 6 m , pri efektivnoj izlaznoj snazi čitača od 1 W . Višesenzorna platforma za mjerenje uvjeta okoline predstavljena je u [33]. Bazirana je na fleksibilnim polimernim supstratima integriranim u tiskanu naljepnicu. Platforma obuhvaća visokofrekventnu radiofrekvencijsku identifikaciju, senzore s kanalima za kapacitivno mjerenje vlage, dva kanala za detekciju amonijaka na bazi otpora s mogućnošću zagrijavanja i jedan otporni kanal za detekciju temperature (engl. *resistance temperature detectors*). Pametna oznaka koja se temelji na tehnologiji fleksibilne tiskane pločice (engl. *Printed Circuit Board - PCB*), s primjenom u IoT sustavima, predstavljena je u [34]. Tiskana pametna oznaka integrira senzor za vlagu s linearnom osjetljivošću od 0.004% relativne vlage (engl. *Relative Humidity - RH*) i tiskanu bateriju s kapacitetom od 100 mAh , izrađenu s litij-željezo-fosfatnom tehnologijom. Vizualan prikaz predložene oznake nalazi se na slici 3.3.




Slika 3.3: Shema predložene pametne oznake s prikazom podsustava: energetski podsustav (a); kontrolni podsustav (b); detekcijski podsustav (c); komunikacijski podsustav (d); pametni upravljački podsustav (e). Ekvivalentni model detekcijskog kruga (f) [34].

U budućnosti se očekuje poboljšanje performansi čitača, oznaka i IoT senzora u različitim uvjetima. Očekuje se razvoj modela klasifikacije te primjena tehnika strojnog učenja kako bi se minimizirala pojava pogrešnih očitavanja. Sustav predstavljen u [18] umetnut je u pakiranje ribe. Mjerene podatke pohranjuje lokalno, tako da ih krajnji korisnik može dohvatiti samo pomoću RFID čitača ili pametnog telefona, za razliku od [25] gdje je potrebno osigurati web-poslužitelj za svrhu pohrane podataka. Ključna prednost RFID sustava je mogućnost čitanja podataka bilo kada i na bilo kojem mjestu lanca opskrbe bez otvaranja kutija ili ambalaže proizvoda. Pasivni pristupi poželjni su zbog toga što ne zahtijevaju bateriju niti dodatnu elektroniku potrebnu za njezino punjenje i rad. Relativno velika veličina uređaja nedostatak je u sustavima poput [18] i [25].

3.1.2 Primjene u logističkim procesima

U industriji proizvodnje odjeće, RFID oznake se koriste za detekciju krivotvorenog proizvoda [35, 36]. Pasivne RFID oznake koriste se za zaštitu podataka, sprječavanje neovlaštene autorizacije i prevenciju kloniranja oznaka. Autori u [37] eksperimentalno pokazuju da RFID tehnologija značajno poboljšava točnost inventara, ubrzava procese inventure, omogućuje bolje upravljanje zalihama i povećava prodaju u lancu opskrbe odjeće i maloprodaje. Ključni rezultati uključuju smanjenje situacija kada je artikl nedostupan, brže praćenje artikala i povećanje dostupnosti proizvoda za kupce. Autori u [38] predstavljaju novo pravilo raspoređivanja u proizvodnji temeljeno na dostupnim informacijama u proizvodnom procesu. Eksperimentalna evaluacija pokazala je da korištenje RFID tehnologije omogućuje smanjenje prosječnog vremena traženja resursa za više od 30 %, uz značajno smanjenje broja zastoja i kašnjenja u proizvodnom procesu. Sustav je omogućio točnije i brže prikupljanje podataka, što je rezultiralo boljim iskorištenjem kapaciteta i povećanjem ukupne učinkovitosti raspoređivanja. Za poboljšanje logističkih operacija bolničkih ljekarni autori u [39] koriste kombinaciju barkoda i RFID tehnologije. Hibridna implementacija navedenih tehnologija rezultirala je smanjenjem broja ručno izvedenih zadataka s 10 na 4, dok je broj automatiziranih aktivnosti porastao s 1 na 7. Autori u [40] uključili su RFID tehnologiju u dio sustava distribucije lijekova, gdje se RFID koristi na mjestu identifikacije tereta. Prikaz sustava nalazi se na slici 3.4. Rješenje omogućuje praćenje tereta i nadzor distribucijskih zadataka, što dovodi do smanjenja broja poslovnih aktivnosti koje mora obavljati prijevoznik. Da bi se to postiglo, rješenje automatski provjerava teret, prilagođava rutu i razmjenuje informacije sa središnjim skladištem, bez ikakve intervencije vozača. Autori u [41] predstavljaju koncept ušivene kodirane oznake, osmišljen s ciljem unapređenja sigurnosnih mehanizama i otklanjanje postojećih ranjivosti u sustavima temeljenim na RFID tehnologiji. Razvijena je trajna, teško uklonjiva oznaka koja omogućuje pouzdanu identifikaciju i automatizirano praćenje proizvoda kroz cijeli lanac opskrbe, čime se povećava sigurnost i transparentnost u industriji. Autori u [42] predstavljaju sustav RFID-SMS za unapređenje raspoređivanja



Slika 3.4: Ugradbeni sustav za dostavu lijekova postavljen u dostavni kombi. Kontejneri (zelene kutije) i RFID oznake vidljivi su s lijeve strane [40].

u proizvodnim pogonima. Sustav omogućuje praćenje u stvarnom vremenu te razmjenu proizvodnih i transportnih zadataka između poduzeća. Sustav koristi RFID uređaje za prikupljanje podataka i donošenje dinamičkih odluka tijekom izvođenja procesa radi poboljšanja učinkovitosti. Autori u [43] predstavljaju primjenu EPC Gen2 standarda za identifikaciju putnika u sustavima javnog prijevoza, koji se temelji na RFID tehnologiji. Omogućeno je otkrivanje polazišta i odredišta putnika uz preciznije praćenje ulaska i izlaska putnika iz vozila. Predloženi sustav omogućava efikasniju identifikaciju putnika u stvarnom vremenu te povećava ukupnu učinkovitost javnog prijevoza.

3.2 Dosadašnja istraživanja na području detekcije udara u lancu opskrbe

Uslijed kontinuiranog rasta ekonomije, trgovine i povećanja volumena ponude i potražnje proizvoda, isporuka se ubrzava primjenom metoda slaganja tijekom skladištenja i transporta. Pakirani proizvodi u lancu opskrbe imaju određeni rizik od fizičkog oštećenja zbog različitih opasnosti (engl. *hazard*) koje uključuju udare, vibracije, temperaturu, vlažnost, svjetlost i pritisak [16, 44, 45]. Rukovanje velikim paletama na kojima su složene kutije proizvoda može rezultirati oštećenjima proizvoda, a uzrok za to su vibracije i udari. Vibracije mogu nastati uslijed neravnoteže u teretu ili nepravilnih površina, a udari mogu nastupiti tijekom manipulacije paketima [46]. Za istraživanje ovog problema, autori u [47–49] koriste različite simulacijske tehnike za analizu mogućih vibracija i oštećenja od udara određenog proizvoda. Osim toga, definirano je nekoliko standarda materijala za pakiranje kako bi se spriječila ili smanjila šteta uzrokovana različitim opasnostima. Standardi opisuju postupke

i uređaje za testiranje materijala za pakiranje. Najčešće korišteni standardi su oni Američkog društva za ispitivanje materijala (engl. *American Society for Testing and Materials - ASTM*), npr. [50], i Međunarodne organizacije za normizaciju (*International Organization for Standardization - ISO*), npr. [51, 52]. Učinci vibracija i udara povezani su s energijom koja može uzrokovati oštećenje proizvoda. Količina energije ovisi o nekoliko čimbenika koji uključuju ubrzanje, frekvenciju, položaj, visinu slaganja itd. U [53] autori istražuju utjecaj vibracija na oštećenja voća tijekom transporta. Utvrđeno je da vibracije uzrokuju mehanička oštećenja poput ogrebotina, modrica i trljanja plodova, pri čemu su ključni faktori intenzitet vibracija i karakteristike ambalaže. Simulacije vibracija omogućile su realističnu procjenu štetnih utjecaja. Predloženo rješenje usmjereno je na optimizacije u dizajnu i materijalima ambalaže kako bi se smanjila oštećenja i očuvala kvaliteta voća. Cilj je smanjiti pogoršanje kvalitete voća kod vibracija u rasponu od 0 do 10 Hz korištenjem simulacijskih pristupa. Vodeći proizvođač indikatora za detekciju udara WAN-YO [54] predstavio je jednokratne kemijske detektore udara. Kemijski detektor udara aktivira se nepovratnim crvenilom kada intenzitet udara premaši prag sile g . Ponuđeni pragovi sile udara mogu biti 5, 37, 50, 75 i 100 g . Predloženi indikator predstavlja povoljno rješenje, uz to da nije ponovno iskoristiv u slučaju aktiviranja i ne omogućuje praćenje vremenske oznake ili lokacije udara. Napredni sustav za praćenje i nadzor pošiljki u stvarnom vremenu DB Schenker Smartbox predstavljen je u [55], koji koristi senzorsku tehnologiju za pružanje detaljnog uvida u uvjete transporta. Ovakv uređaj omogućuje praćenje lokacije pošiljke putem GPS-a, kao i praćenje ključnih parametara poput temperature, vlažnosti, g -sile, nagiba i izloženosti svjetlu. Koristi se u svim vrstama prijevoza, uključujući zračni, pomorski i intermodalni transport.

Autori u [56] predlažu metodu optimizacije amortizirajućih materijala kako bi se ispravio vibracijski odziv uzrokovan pomakom težišta. Korišten je matematički model sustava ambalaže, a vibracijski odziv uravnoteženih i neuravnoteženih proizvoda analiziran je pomoću *Runge – Kutta* metode. Provedene su simulacije konačnih elemenata i eksperimentalne provjere koje su potvrdile da povećanjem koeficijenta prigušenja na strani pomaka mase dolazi do smanjenja vibracijskog odziva. Rezultati istraživanja nude praktične smjernice za optimizaciju dizajna zaštitne ambalaže proizvoda s neuravnoteženom masom. U posljednjih nekoliko godina različite simulacijske tehnike korištene su za proučavanje učinaka vibracija i udara na proizvode u lancu opskrbe. Za tu primjenu koristi se posebno sklopovlje koje simulira vibracije i udare u laboratorijskim uvjetima. Za ispitivanje učinaka vibracija koristi se stol za vibracije ili tresilica (engl. *shaker*) [48, 57, 58].

Autori u [59] predstavili su optimizirani dizajn ambalaže za kućanske aparate koji poboljšava zaštitu proizvoda tijekom transporta. Korištenjem numeričkih simulacija (alat ABAQUS) i eksperimentalnih testova, razvijen je sustav ambalaže koji učinkovito apsorbira udare, smanjujući rizik od oštećenja proizvoda. Integrirane su naprede metode analize za predviđanje performansi ambalaže kako bi se postigle ekonomske i ekološke učinkovitosti kroz smanjenje potrošnje materijala. U [60] autori su mjerili vibracije uzrokovane kamionima

na cesti u ovisnosti o brzini kamiona, stanja ceste i razini opterećenja. Maksimalne amplitude vibracija detektirane su između 3 i 3.5 Hz. Autori u [61] mjere vibracije unutar tri različite vrste kamiona. Istraživanje modelira transportno okruženje kamionskog prijevoza u Koreji primjenom statističke analize i profila gustoće spektralne snage. Profil koji dijeli vibracijske događaje na visoke i niske razine na temelju RMS ubrzanja. Istraživanje je omogućilo usporedbu razina vibracija u domaćem transportu s međunarodnim standardima (ASTM i ISTA). Podaci o ubrzanju prikupljeni su pomoću komercijalnog snimača ubrzanja [62] pričvršćenog ljepljivom trakom. Razvijeni profil modela daje slične rezultate u usporedbi s rezultatima koji su predstavljani međunarodnim standardima. Autori u [63] predložili su tehniku nadziranog strojnog učenja za detekciju udara za klasifikaciju grubosti ceste prema ISO8608 : 2016. Autori su u ovom istraživanju koristili su visoko učinkovite laserske skenere s preciznošću $< 1\text{ mm}$. Pristup za detekciju udara implementiran je na vozila s dva kotača (motor, moped). Predložena metoda može detektirati događaje na cesti na temelju grubosti ceste, brzine vozila i izbočenja opruge. Autori u [64] koristili su linearni niz od tri piezoelektrična senzora za detekciju udara u kompozitnim pločama. Predložena metoda koristi duboko učenje za određivanje energije i lokacije udara.

Za detekciju udara u lancu opskrbe potrebno je definirati razinu mehaničkog stresa koju proizvod može podnijeti. Ta razina izražava se u jedinicama g , što predstavlja višekratnik standardnog gravitacijskog ubrzanja od 9.81 m/s^2 . Maksimalne vrijednosti udarnih sila izraženih u g za određene kategorije proizvoda opisane su u literaturi kroz koncept krhkosti. Krhkost proizvoda odražava njegovu sposobnost da podnese mehanička ili fizička opterećenja prije nego što dođe do oštećenja [47, 65, 66]. Osim udara, tijekom transporta proizvodi su izloženi i vibracijama, čiji intenzitet ovisi o uvjetima na cesti, brzini kretanja vozila i razini opterećenja. Utjecaj vibracija može dodatno pridonijeti oštećenju proizvoda tijekom transporta [53, 67]. Maksimalne vrijednosti ubrzanja uzrokovane vibracijama tijekom kamionskog transporta u pravilu ne prelaze 1 g , s dominantnim frekvencijama ispod 100 Hz [60, 61].

Autori u radu [68] analiziraju algoritam za detekciju pada prije samog udara (engl. *pre-impact fall detection*) u području kuka, s ciljem smanjenja rizika od ozljeda kod starije populacije. Padovi su jedan od glavnih uzroka ozbiljnih ozljeda i smrtnosti u starijoj populaciji. Cilj je bio poboljšati preciznost i pouzdanost sustava detekcije pada prije udara koristeći senzor ubrzanja, kutnu brzinu i nagib trupa, uz optimizaciju točnosti i vremena reakcije. Sustav aktivira zaštitni zračni jastuk 402 ms prije udara s 100% točnošću i bez lažnih aktivacija tijekom svakodnevnih aktivnosti. Ključna poboljšanja uključuju sigurniji aktivator jastuka i pouzdanu detekciju padova, uz potrebna dodatna testiranja za širu primjenu. Autori u [69] analiziraju detekciju padova u scenarijima koji uključuju situacije bliske padu koristeći senzore inercije, s primjenom kod starijih osoba u prevenciji ozljeda. Pristup se temelji na analizi podataka prikupljenih iz inercijskih senzora kako bi se predvidjeli padovi prije samog udara. U radu su korišteni napredni algoritmi za obradu signala i klasifikaciju, čime je omogućeno razlikovanje između stvarnih padova i situacija koje ih oponašaju.

Pojam krhkost koristi se kao mjera maksimalnog ubrzanja koje proizvod može podnijeti bez oštećenja. Za televizijske prijemnike, razina ubrzanja iznad $85g$ može uzrokovati oštećenja prijemnika [65, 66]. Osim intenziteta udara, kut sudara paketa također može utjecati na razinu oštećenja proizvoda. Za veće površine udara (npr. prednja/zadnja strana ravnog TV panela), rezultirajuća sila po površini je manja u usporedbi s manjim površinama udara (npr. gornja/donja/lijeva/desna strana ravnog TV panela). Ukoliko je kut sudara nepovoljan, dovoljna je i manja visina pada paketa da bi došlo do oštećenja paketa. Navedena tvrdnja potvrđena je u [59], gdje se rubovi ili kutovi proizvoda navode kao najkritičnija mjesta pakiranoga paketa. Procjena vertikalnih i horizontalnih kuteva sa senzorom ubrzanja, žiroskopom (engl. *gyroscope*) ili jedinicom inercijskog mjerenja (engl. *Inertial Measurement Unit* - *IMU*) primjenjuje se u prijevoznim sredstvima gdje su potrebni parametri kao što su brzina i smjer kretanja. Autori u [70] predstavili su algoritam procjene horizontalnog i vertikalnog nagiba koji se koristi u osobnom vozilu. Predloženi algoritam procjene ima za cilj dobiti točnije vrijednosti od IMU-a u prometu. U [71] autori su predstavili algoritam za procjenu kuta nagiba s primjenom na osobnom vozilu. Učinkovit dizajn i implementacija takvih ugradbenih sustava u komercijalnim vozilima mogu doprinijeti smanjenju vjerojatnosti prometnih nesreća. Implementacija sustava stvarnog vremena za vozila s višeosnim žiroskopom i senzorima ubrzanja predstavljena je u [72]. Procjena vertikalnih i horizontalnih kuteva pruža uvid u dinamiku vozila u stvarnom vremenu pri standardnim uvjetima na cesti.


Procjena kuta bočnog klizanja i kuta nagiba osobnog vozila predstavljena je u [73]. Korištenje simulacija i stvarnih eksperimenata s automobilima pokazuje poboljšanja u usporedbi s tradicionalnom metodom proširenog Kalmanovog filtra (engl. *Extended Kalman Filter* - *EKF*). Poboljšanja točnosti i smanjenje troškova IMU-a raspravlja se u [74]. Autori su predložili metodu kalibracije koja uspoređuje izlazne vrijednosti IMU-a s apsolutnim kutnim vrijednostima. Primjenom linearizacije i kompenzacije senzorskih pogrešaka moguće je poboljšati pouzdanost i preciznost očitavanja senzora. Kalmanovi filtri koriste se u [70–73] za smanjenje šuma tijekom vožnje i upravljanja. Sustav za referenciranje vertikalnih i horizontalnih kuteva (engl. *Attitude and Heading Reference System* - *AHRS*) koji se temelji na pristupačnom mikroelektromehaničkom sustavu (engl. *Micro Electronic Mechanical Systems* - *MEMS*) predstavljen je u [75]. Korištenje komplementarnog filtra povećava pouzdanost informacija, gdje se veća numerička težina daje pouzdanijim senzorima. Vrijednosti dobivene senzorom ubrzanja korištene su za ispravljanje drifta žiroskopa, čime se osiguravaju prihvatljivi rezultati. Algoritam za izračun Eulerovih kutova predložen je u [76]. Magnetski kompas i senzor ubrzanja predloženi su za minimizaciju pogreške žiroskopa zbog pomaka i termičkog drifta. Predloženi algoritam ima za cilj poboljšati točnost i vrijeme izvođenja u usporedbi s izravnim algoritmom Eulerovih kutova. Autor u [77] predstavio je detekciju nagiba koristeći značajke senzora ubrzanja s tri osi. Senzor ubrzanja mjeri orijentaciju u odnosu na referentno gravitacijsko polje Zemlje. Korištenje senzora ubrzanja za detekciju

nagiba predstavljeno je u [78]. Kut nagiba dobiva se integriranjem izlaza žiroskopa s izlazom senzora ubrzanja. Nalaze primjenu u širokom spektru područja, uključujući navigacijske sustave, stabilizaciju platformi, robotiku, mobilne uređaje, virtualnu i proširenu stvarnost te sustave za sportsku i fitness analizu.

3.3 Dosadašnja istraživanja na području potrošnje energije ugradbenih sustava

Sustavi ultra niske potrošnje predstavljaju klasu računalnih i elektroničkih sustava projektiranih sa svrhom obavljanja tražene funkcije uz minimalnu potrošnje energije, često pomičući granice energetske učinkovitosti. Razvoj sustava ultra niske potrošnje predstavlja kontinuirani izazov usmjeren na postizanje ravnoteže između sve većih zahtjeva za naprednim funkcionalnostima i potrebe za održivom, energetski učinkovitom potrošnjom energije. Takvi sustavi unapređuju sposobnosti suvremene elektronike u raznim područjima, od potrošačke elektronike do industrijskih primjena [79]. DVFS (engl. *Dynamic Voltage and Frequency Scaling*) uključuje dinamičko podešavanje radne frekvencije i napona procesora na temelju zahtjeva radnog opterećenja. Slika 3.5 ilustrira različita stanja potrošnje energije i postavljenih performansi u kojima se sustav može nalaziti. Sustav može postići ravnotežu između energetske učinkovitosti i računalne snage smanjenjem frekvencije i napona pri niskom opterećenju, uz njihovo povećanje kada su potrebne veće performanse. Ova metoda omogućuje sustavu da štedi energiju tijekom razdoblja niže aktivnosti, produžujući trajanje baterije i minimizirajući stvaranje topline [80].

DVFS je značajan u primjenama gdje poboljšanja energetske učinkovitosti imaju velik utjecaj. Maksimiziranje trajanja rada uz ograničene energetske resurse također je jedna od prednosti DVFS-a, primjerice za uređaje na Internetu stvari (engl. *Internet of Things - IoT*) [81, 82], bežičnim senzorskim čvorovima [83, 84], mobilnim uređajima [85], temperaturnim sensorima na čipu u [86], ili nosivoj tehnologiji u [87]. Nosive tehnologije (engl. *wearables*) poput pametnih satova, fitness trackera i medicinskih uređaja za praćenje također se oslanjaju na svojstva ultra niske potrošnje i DVFS. Minimalna potrošnja energije i produžen vijek trajanja baterije predstavljaju temeljne zahtjeve. Bežični senzori korišteni u pametnim kućama [88], višejezgrenim sustavima [89], i poljoprivredi [90] često su napajani baterijama i moraju biti energetski učinkoviti kako bi trajali godinama. Medicinski uređaji poput pacemakera i implantata za praćenje glukoze u krvi moraju raditi kontinuirano, pouzdano i uz minimalnu potrošnju energije. U primjenama poput medicinskih implantata ili udaljenih senzora, gdje zamjena baterije može biti nepraktična ili nemoguća, dizajn niske potrošnje energije ključan je faktor za dugovječnost uređaja [91]. IoT uređaji poput pametnih brava, sigurnosnih sustava, termostata i sustava rasvjete također zahtijevaju energetski učinkovito djelovanje. Mobilni uređaji poput laptopa, pametnih telefona, tableta ili e-čitača značajno



Slika 3.5: Dinamičko skaliranje napona i frekvencije, radne točke.

su poboljšani s produljenim operativnim vremenom na bateriji, što izravno poboljšava korisničko iskustvo [92]. Porastom potražnje za energetski učinkovitim računarstvom u različitim primjenama dovelo je do istraživanja i implementacije DVFS-a na mikroupravljačima. Fokus istraživanja je smanjenje potrošnje energije i produljenje trajanja baterije, posebno u prijenosnim i ugradbenim uređajima, gdje je učinkovito korištenje energije ključno. DVFS je postao održivo rješenje za dinamičko prilagođavanje energetskih i performansnih karakteristika mikroupravljača, omogućujući optimalan odgovor na promjenjive računalne zahtjeve. Autori u [93] provode usporedbu različitih hash algoritama, uključujući SHA-3 i algoritme poput Blake2, Shake, Kangaroo Twelve i Blake3. Evaluacija se temelji na metrikama poput broja ciklusa po bajtu i zauzeću memorijskog prostora, a testiranja su izvedena na PIC32 mikroupravljaču. Dobiveni rezultati omogućuju rangiranje algoritama prema njihovoj učinkovitosti i mogu poslužiti kao temelj za odabir odgovarajućeg hash algoritma u različitim komunikacijskim i prijenosnim sustavima.

Autori u [84] primijenili su metodu upravljanja energijom u bežičnim senzorskim mrežama (WSN) za IoT aplikacije s ograničenim resursima. Provedena je eksperimentalna implementacija hibridnog rješenja upravljanja energijom. Primjenjuju se DVFS i tehnike upravljanja radnim ciklusom za optimizaciju radnih uvjeta tijekom obrade podataka i smanjenje potrošnje energije odašiljača. Odabir više radne frekvencije može dovesti do učinkovitije potrošnje energije zbog njenog utjecaja na radni ciklus. S povećanjem radne frekvencije dolazi do skraćivanja ukupnog radnog vremena, što rezultira smanjenjem energetskih gubitaka tijekom faze mirovanja. Pristup dinamičke kontrole frekvencije (engl. *Dynamic Frequency Control - DFC*) u razvoju ugradbenih aplikacija predstavljen je u [94]. Ovaj pristup rezultira kraćim vremenom obrade i mogućim uštedama u metrikama kao što su prosječna potrošnja struje, ukupna potrošnja energije i srodnim pokazateljima, ovisno o aplikaciji. U testiranim scenarijima aplikacija, dinamička kontrola frekvencije smanjila je vrijeme izvođenja do 33 % i

ukupnu potrošnju energije do 49 % u usporedbi sa zadanim statičkim pristupom. Autori u [95] predlažu sklop koji osigurava regulaciju digitalne linije kašnjenja (engl. *Digital Delay Line* - *DDL*) usklađene s prstenastim oscilatorom (engl. *Ring Oscillator* - *RO*). Kako bi se osiguralo da vrijeme propagacije kroz DDL odgovara referentnom vremenu, pretvarač kontrolira napon napajanja digitalnog podsustava. Cilj ovog sklopa je jamčiti brzinu obrade središnje procesorske jedinice (engl. *Central Processing Unit* - *CPU*) za aplikacije u stvarnom vremenu, uz ograničavanje napona napajanja. Rezultati predloženog sklopa pokazuju da implementacija omogućuje učinkovitost pretvorbe energije iznad 50 % pri 2.5 μW izlazne snage. Autori u [96] razmatraju korištenje DVFS-a za poboljšanje energetske učinkovitosti sklopovlja sa senzorima ubrzanja u neuronskim mrežama, posebno za smanjenje statičke i dinamičke snage u nepravilnim neuronskim mrežama. Istražuju se različite razine granularnosti za implementaciju DVFS-a, a prezentiran je algoritam prediktivnog strojnog učenja kao sredstvo za poboljšanje preciznosti. Rezultati simulacije pokazuju da su postignute značajne uštede energije i smanjenje snage na modelima *AlexNet*, *VGG16* i *ResNet50*. Konkretno, postignuta je prosječna ušteda dinamičke energije od 59–66 % i prosječno smanjenje statičke snage od 69–80 % u usporedbi s osnovnim postavom.

Autori u [97] predstavljaju D2VFS, tehniku dinamičkog podešavanja napona i frekvencije prilagođenu trenutnom naponu na kondenzatoru kod prekidnih sustava napajanih iz okoline. D2VFS dinamički modulira razine napona na temelju promjenjivog opterećenja i zahtjeva za procesorskom snagom te istovremeno prilagođava frekvenciju rada po potrebi. Eksperimentalni rezultati pokazuju da ova metoda omogućuje do devet puta više procesorskih ciklusa po punjenju kondenzatora, smanjuje potrebnu veličinu kondenzatora do šest puta, prepolovljuje broj kontrolnih točaka i skraćuje vrijeme izvođenja zadataka do 300 % u odnosu na statički postavljene frekvencije. Prednosti D2VFS potvrđene su kroz različite aplikacije i izvore energije, čime se značajno povećava efikasnost i pouzdanost prekidnih sustava u realnim uvjetima. Autori u radu [98] obavljaju precizno mjerenje dinamičkog skaliranja napona i frekvencije kod niskoenergetskih mikroupravljača u bežičnim senzorskim mrežama. Autori su razvili i validirali metodologiju koja omogućuje točno praćenje i analizu potrošnje energije tijekom promjena napona i frekvencije rada mikroupravljača MSP430L5529. Rezultati pokazuju da predloženi pristup omogućuje detaljnu karakterizaciju energetskog ponašanja mikroupravljača pri različitim radnim uvjetima, čime se olakšava primjena DVFS tehnika za produljenje autonomije senzorskih čvorova i optimizaciju ukupne potrošnje energije. Viši napon i frekvencija mogu rezultirati značajnim povećanjem normalizirane snage od 57 %, dok se potrošnja energije povećala za 37 % s porastom frekvencije. Autori u [99] istraživali su karakterizacije različitih mikroupravljača na temelju periodičkih radnih ciklusa. Dobiveni podaci karakterizacije uključuju aktivnu potrošnju energije, potrošnju energije u stanju mirovanja, potrošnju energije za spremanje podataka i potrošnju energije perifernih uređaja. Kod analiziranih mikroupravljača, potrošnja varira u rasponu od 0.2 *mJ* do 2.5 *mJ* po izvršenju zadatka, ovisno o tipu mikroupravljača i radnim uvjetima. Efikasniji mikroupravljači

postizu i do 10 puta manju potrošnju energije u odnosu na manje optimizirane modele za specifične zadatke. Potreban je odabir odgovarajuće arhitekture za maksimalnu energetske učinkovitost i produljenje trajanja baterije senzorskih čvorova. Autori u radu [100] predlažu korištenje tehnike prebacivanja frekvencije signala takta koja može smanjiti potrošnju energije senzorskih čvorova na mikroupravljaču. Koncept smanjenja potrošnje energije temelji se na prebacivanju radnog takta između niskih i visokih frekvencija, ovisno o aplikacijskom kôdu mikroupravljačke jedinice (engl. *Microcontroller Unit - MCU*). Tehnika je pokazala smanjenje potrošnje energije mikroupravljača do 66.9%. Visoka frekvencija za obradu podataka senzorskih čvorova slike korisna je za smanjenje ukupne potrošnje energije. Autori u radu [101] kvantificiraju uštedu energije postignutom s DVFS-om. DVFS donosi kvadratnu uštedu energije, a sustav koji koristi DVFS izvodi zadatak u zadanom roku, ali to čini uz manju potrošnju energije. Uštede energije postignute DVFS-om mogu doseći čak 59.02% za aktivne komponente, poput VCO-a (engl. *Voltage Controlled Oscillators*) i CPU-a, što pokazuje da DVFS shema adekvatno funkcionira za aplikacije koje zahtijevaju obradu podataka. Autori u [102] predlože model skaliranja frekvencije, koji uzima u obzir kašnjenje sklopovlja i omogućuje preciznije određivanje optimalne radne frekvencije procesora za smanjenje potrošnje energije. Rad predlaže analitički model za pronalaženje energetski učinkovitih točaka uzimajući u obzir dodatne energetske troškove, a sastoji se od dva parametra: faktor skaliranja frekvencije i radnog ciklusa. Dodatni troškovi sklopovlja u dizajnima s više načina rada proizlaze iz varijacija kašnjenja pri različitim naponima napajanja i mogu dovesti do dodatne potrošnje energije.

Korištenje DVFS-a za probleme minimizacije energije u sustavima s mješovitom kritičnošću predloženo je u radu [103]. Autori su prvi pokazali da je moguće koristiti DVFS u sustavima s miješanom kritičnošću, a da se pritom ne ugrozi sigurnost i pravovremenost izvršavanja zadataka visoke kritičnosti. Predložen je model koji omogućuje prilagodbu frekvencije procesora ovisno o trenutnom režimu kritičnosti sustava, čime se smanjuje ukupna potrošnja energije. Ulazi algoritma uključuju parametre modela zadatka, kao što su vrijeme izvođenja, maksimalna i minimalna frekvencija. Izlazi algoritma uključuju optimalnu frekvenciju procesora i napon te odgovarajuću potrošnju energije. Rezultati eksperimentalne evaluacije pokazuju da se korištenjem predloženog pristupa može značajno smanjiti potrošnja energije u odnosu na tradicionalne pristupe koji ne koriste DVFS, uz zadržavanje garancija za izvršavanje za kritičnih zadataka. DFS (engl. *Dynamic Frequency Scaling - DFS*) metoda za smanjenje potrošnje energije u Atmel ATmega 16 mikroupravljaču prikazana je u radu [104]. Primjena ove tehnike rezultira povećanjem vremena trajanja baterije i poboljšanjem energetske efikasnosti sustava. Zaključili su da se potrošnja energije smanjuje s najnižom frekvencijom od 1 MHz, uz ograničenje da određen broj zadataka nije obavljen prema rasporedu. Stoga se predlaže DVFS metoda kako bi se osiguralo ispunjavanje ograničenja za rad u stvarnom vremenu za izvođenje robotskih aplikacija na ATmega16. Autori u radu [105] predstavili su sustav upravljanja koji se može dodati postojećim mikro-

upravljačima koji nemaju ugrađenu podršku za upravljanje energijom. Svrha istraživanja je održavanje računalne snage uz prilagođavanje frekvencije mikroupravljača. Autori su neovisno testirali 32 instrukcije PIC mikroupravljača i zaključili su da svaka instrukcija troši različite količine energije. Cilj programske podrške za procjenu potrošnje energije jest omogućiti precizan izračun potrošnje energije pri različitim radnim frekvencijama, uz mogućnost definiranja maksimalne frekvencije radi procjene potrošnje energije na najvišim razinama opterećenja. Korištenje regulatora napona na integriranom sklopu (engl. *on-chip regulator*) za DVFS u multiprocesorima prikazano je u radu [106]. Autori pokazuju da on-chip regulatori mogu pružiti bolje uštede energije u usporedbi s tradicionalnim regulatorima, ali postoje izazovi u njihovoj implementaciji, poput učinkovitosti i karakteristika prijelaznog napona. Rad opisuje i modelira ove troškove te provodi sveobuhvatnu analizu sustava s integriranim regulatorima. Napredna metodologija koja integrira DC-DC regulator s podrškom za DVS (engl. *Dynamic Voltage Scaling - DVS*), opisano je u [107]. Predloženi trostupanjski pretvarač je kombinacija buck i switched-capacitor pretvarača koji omogućuje manje induktore (1 nH) od buck pretvarača, dok generira širi raspon izlaznih napona u usporedbi s half-mode switched-capacitor pretvaračem. Mjerenja su provedena za raspon statičkih uvjeta struje opterećenja (0.3 do 0.8 A), radnih ciklusa (40 do 65%), radnih frekvencija (50 do 160 MHz) i broja faza (1 do 4). Energetska učinkovitost sustava postiže maksimalnu vrijednost od 77% u uvjetima niskog opterećenja pri radnom ciklusu od 50% .

Autori u radu [108] uveli su tehniku koja dinamički podešava napon i frekvenciju CPU-a na temelju statistike pristupa memoriji u stvarnom vremenu, postižući značajne uštede energije, posebno u programima ograničenim na memoriju. Istraživanje i implementacija DVFS-a u CloudSim simulatoru prikazani su u radu [109]. Ovaj rad naglašava potrebu za alatima svjesnim energije u simulaciji velikih i distribuiranih sustava, pokazujući blisku vezu između učinkovitosti DVFS-a i arhitekture sklopovlja. Istraživanje o fino granuliranom DVFS-u korištenjem on-chip regulatora [110] uspješno je uskladilo suprotstavljene zaključke o učinkovitosti DVFS-a pri različitim vremenskim skalama i brzinama skaliranja. Predložili su finoizrnuti mehanizam DVFS-a vođen mikroarhitekturom koji podešava napon i frekvenciju za pojedinačne pristupe memoriji izvan čipa, pokazujući značajne uštede energije uz minimalno smanjenje performansi za radna opterećenja koja intenzivno koriste memoriju. Studija koja se fokusira na modeliranje potrošnje energije za DVFS politike [111] predstavila je matematički model za procjenu potrošnje energije pod različitim DVFS politikama. Cilj ovog modela je pomoći korisnicima u pronalaženju optimalnih konfiguracija za njihove aplikacije i ciljeve smanjenja energije, pokazujući visoku točnost u usporedbi s mjerenjima u stvarnom vremenu.

Autori u [112] istražuju problem raspodjele zadataka i skaliranja frekvencije procesora u okruženju mobilnog rubnog računarstva (engl. *edge computing*). Glavni cilj je optimizirati i rasteretiti zadatke s mobilnih uređaja na rubne servere kako bi se postigla minimalna potrošnja energije i kašnjenje, uzimajući u obzir ograničene resurse i dinamičke uvjete mreže.

Rezultati rada pokazuju da zajednička optimizacija raspodjele zadataka i skaliranja frekvencije procesora može značajno smanjiti ukupnu potrošnju energije i vrijeme izvršavanja zadataka u usporedbi s konvencionalnim pristupima gdje se ti problemi rješavaju odvojeno. Autori su razvili algoritme temeljene na konveksnoj optimizaciji koji omogućuju dinamičko prilagođavanje prema trenutnim uvjetima sustava. Prediktivni temperaturni pristup DVFS-u [113] koristio je brojače performansi u komercijalnim mikroprocesorima za predviđanje lokalizirane temperature i učinkovito prilagođavanje napona/frekvencije. Ovaj pristup pružio je programsku podršku za termičke probleme otkrivene nakon izrade rasporeda proizvodnje, pokazujući usporedive performanse s DVFS-om uz korištenje temperaturnih senzora. Razvoj energetske učinkovitog algoritma za raspoređivanje zadataka u DVFS-om omogućenom oblaku prikazan je u radu [114]. Ovo istraživanje usmjereno je na stvaranje algoritama koji poboljšavaju energetske učinkovitost u okruženjima oblaka, posebno u kontekstu raspoređivanja zadataka. Sveobuhvatni pregled algoritama za raspoređivanje u energetske svjesnim sustavima u stvarnom vremenu [115] pružio je sustavnu klasifikaciju postojećih pristupa. Predlaže se ravnoteža između uštede energije i ispunjavanja vremenskih ograničenja u više-jezgrenim arhitekturama.

Trenutni razvoj na području komunikacijskih protokola niske potrošnje energije, poput I2C i SPI, usmjereno je na smanjenje potrošnje energije uz očuvanje ili poboljšanje brzine i pouzdanosti komunikacije. To se postiže optimizacijom sklopovlja i programske podrške s FPGA (engl. *Field-Programmable Gate Array*) komponentama niske potrošnje. Autori u radu [116] precizno su simulirali model smanjene potrošnje za sustave niske potrošnje koristeći periferne uređaje. Metoda se može primijeniti na različite skupove instrukcija i periferne uređaje. Prema istraživanju, fluktuacije napajanja i netočnosti zaokruživanja brojeva uzrokuju probleme u procjeni potrošnje energije. Ovaj rad uvodi novu metodu mjerenja potrošnje energije koristeći sklopovlje za mjerenje visoke preciznosti i programsku kontrolu na niskoj razini za točno ocjenjivanje potrošnje energije. Autori u [117] predlažu dizajn sinkronog protokola podatkovne linije koji nastoji smanjiti potrošnju energije koristeći samo dvije podatkovne linije. Predloženi sustav troši 12 mW , dok standardni 3-žični SPI dizajn troši 19 mW energije, što predstavlja značajno poboljšanje. Također omogućuje simplex i half-duplex prijenos podataka pri istoj brzini. Dizajn je potvrđen korištenjem FPGA kao kontrolera i dodatnog sklopa kao ciljanog uređaja.

Autori u radu [118] analiziraju postojeće pristupe za poboljšanje energetske učinkovitosti i predlažu inovativna rješenja usmjerena na smanjenje količine podataka koji se prenose i obrađuju na razini uređaja. Cilj je poboljšati energetske učinkovitost I2C komunikacijskog protokola smanjenjem struje curenja (engl. *leakage current*). *Turbo* pristup formulira optimalne pull-up otpornike. Povećanjem vrijednosti pull-up otpornika na SDA i SCL linijama, potrošnja energije se značajno smanjuje jer se smanjuje struja. Autori u [119] razvili su novi dizajn *SPI – Switch* sučelja optimiziranog za nisku potrošnju energije na FPGA platformi. Rezultati pokazuju da predloženo sučelje niske potrošnje troši manje energije od postojećih

metoda, pri čemu se zadržavaju visoke performanse uz nisko zauzeće logičkih elemenata i memorije. Autori u radu [120] uspoređuju potrošnju energije različitih serijskih sučelja, kao što su UART (engl. *Universal Asynchronous Receiver-Transmitter*), SPI, I2C i drugih, kako bi identificirali energetski najučinkovitiji pristup. Uspoređeni su rezultati sveobuhvatne analize za potrošnju energije nekoliko serijskih sučelja u različitim scenarijima. Rezultati pokazuju da je I2C sučelje optimalan izbor za aplikacije s niskim brzinama prijenosa podataka, dok je SPI sučelje prikladnije za primjene koje zahtijevaju visoke brzine prijenosa.

Autori u [121] implementirali su I2C i SPI protokole na FPGA-u. Autori evaluiraju performanse, potrošnju energije i složenost dizajna ova dva protokola implementirana na FPGA-u. Rezultati pokazuju da SPI protokol ima superiorne performanse i nižu potrošnju energije po Mbps u usporedbi s I2C protokolom, iako I2C protokol ima jednostavniji dizajn. Autori u [122] predlažu implementaciju Flex-SPI protokola u računalnu arhitekturu, koja pruža osnovu za komunikaciju između različitih uređaja. Provedena je analiza Flex-SPI protokola po pitanju performansi, pouzdanosti i potrošnje energije. Analiza potrošnje energije Flex-SPI protokola uključuje mjerenje energije koju koristi komunikacijska veza u različitim scenarijima prijenosa podataka. Te informacije se potom uspoređuju s potrošnjom energije I2C standarda. Autori u [123] uspoređuju potrošnju energije SPI i I2C s različitim pull-up otpornicima. Utvrdili su da pull-up otpornik veći od $47\text{ k}\Omega$ zahtjeva smanjenje parazitne kapacitivnosti sabirnice kako bi pravilno funkcionirao. SPI prijenos je završen otprilike 200 milisekundi brže nego očekivano, dok je I2C trajao 50 ms duže (uz uračunate NACK i CONTINUE naredbe na sabirnici). Utjecaj kapacitivnosti sabirnice na komunikacijski protokol uzrokuje ovu razliku u vremenu. Autori u [124] predlažu dizajn digitalnog kruga koji može pretvarati signale između SPI i I2C komunikacijskih protokola, predstavljajući novi pristup SPI i I2C. Kontrolni modul koristi automate za regulaciju prijenosa podataka između dvaju sučelja i osigurava da komunikacija poštuje specifikacije protokola svakog sučelja. Rezultati simulacije pokazuju da konverzijski krug može pretvoriti signale između dvaju protokola uz očuvanje integriteta podataka.

3.4 Usporedba postojećih rješenja i izazova

Prema postojećim rješenjima iz prethodnog poglavlja, do danas postoji nekoliko sustava za praćenje uvjeta u skladištenju i transportu u opskrbnom lancu, prikazano u tablici 3.1. U dosadašnjem istraživanju pokazalo se da je najčešće područje primjene u prehrambenoj industriji, ponajviše za osiguravanje kvalitete hrane i sigurnosti za konzumaciju. Nakon toga, moguća je primjena u medicini, za skladištenje i transport lijekova ili cjepiva. Moguća je primjena na pacijentima prilikom boravka unutar ali i izvan bolnice. Postoji primjena u tekstilnoj industriji za zaštitu odjevnih predmeta od krađe, ili za prepoznavanje lažnih kopija odjevnih predmeta. Nadzor uvjeta okoline tijekom skladištenja i transporta u opskrbnom

Tablica 3.1: Pregled postojećih sustava u literaturi. Skraćenice za parametre: T = temperatura, V = vlaga, S = svjetlost, KUD = Koncentracija ugljen-dioksida, P = pritisak, L = Lokacija, OV = oznaka vremena (eng. *timestamp*)

Ref.	God.	Mjesto primjene	Mjereni parametri	Problem istraživanja
[2]	2023	Lanac opskrbe svježim voćem	mehanička oštećenja	pregled mehaničkih oštećenja i analiza učinkovitosti različitih metoda pakiranja u zaštiti kvalitete proizvoda tijekom transporta i skladištenja
[14]	2016	Praćenje lanca opskrbe svježih i lako kvarljivih proizvoda	T, indikator boje	visoki troškovi implementacije, RFID interferencije, ne pruža preciznu lokaciju prekoračenja temperature, ograničena granularnost podataka, ovisnost o sustavima bez vizualnog nadzora
[18]	2009	Logistički lanci svježe ribe	T, V, S	visoki troškovi implementacije, ometanje signala, nepouzdanost senzora u ekstremnim uvjetima, upravljanje velikim količinama podataka i standardizaciji sustava
[20]	2012	Industrija proizvodnje sira	T, V, KUD, P, RFID oznake za praćenje	slabljenje RF signala, visoki troškovi implementacije, potreba za održavanjem RFID oznaka, kompleksnost upravljanja velikim količinama podataka
[22]	2016	Praćenje i sljedivost u agro-prehrambenom lancu	T, V, L, kvaliteta i stanje proizvoda	visoki troškovi implementacije, tehnološku složenost integracije RFID-a i blockchaina, pravne i regulatorne izazove, ograničenu skalabilnost sustava
[24]	2017	Praćenje i sljedivost u prehrambenom lancu opskrbe	T, V	visoki troškovi implementacije, RFID interferencije, gubitak podataka senzora, energetska učinkovitost
[25]	2020	Prehrambena industrija, lanac kvarljivih namirnica	T, V, S	visoki troškovi implementacije, RFID interferencije, potencijalni problemi s privatnošću i sigurnosti podataka
[26]	2019	Prehrambna industrija, hladni lanac opskrbe	T, OV	visoki troškovi implementacije, spor odziv senzora, visoka otpornost antene koja ograničava praktičnost primjene, osjetljivi materijali u procesu proizvodnje
[29]	2018	Industrija hrane i pića, praćenje i identifikacija proizvoda	T, osjetljivost oznaka, domet čitanja	troškovi i kompleksnost implementacije, ograničenja kod čitanja zbog dielektričnih svojstava hrane (visok sadržaj vode)
[34]	2020	Praćenje uvjeta, industrijske aplikacije, medicinska primjena	V	ograničena energetska gustoću baterije, niža osjetljivost senzora u usporedbi s alternativnim tehnologijama, tehnički izazovi, troškovi proizvodnje
[40]	2017	Medicinska industrija, distribucija lijekova	OV, L	visoki inicijalni troškove implementacije, tehnološka složenost evolutivnih algoritama, pouzdanost inteligentnih vozila u stvarnim uvjetima, skalabilnost na šira geografska područja
[41]	2017	Tekstilna industrija, praćenje i autentifikacija proizvoda	oznaka odjeće	ograničenu preciznost i uspješnost algoritma na određenim vrstama tkanina, potrebu za prilagodbom sustava različitim tekstilnim materijalima, nemogućnost elektroničkog čitanja na daljinu
[42]	2018	Unapređenje proizvodnih i transportnih procesa između preduzeća	razmjena logističkih podataka	RFID interferencije, upravljanja velikim volumenom podataka, izazovi oko privatnosti i sigurnosti, nedostatak standardizacije za interoperabilnost između sistema

lancu predstavlja još jednu značajnu primjenu ovakvih sustava. Prije početka razvojnog procesa potrebno je definirati optimalnu primjenu postojeće RFID tehnologije, mikroupravljača, senzora i komponenata ultra niske potrošnje. Time se osiguravaju energetska učinkovitost i pouzdana funkcionalnost sustava. Također, potrebno je analizirati i prevladati specifične izazove koji utječu na rad sustava. Prema postojećim rješenjima iz područja istraživanja, izazove je moguće podijeliti na tehničke i razvojne.

Tehnički izazovi uspoređenih rješenja su:

- 1) dugotrajni rad u zahtjevnim uvjetima okoline
- 2) mehanički stres
- 3) neadekvatne ili velike dimenzije uređaja
- 4) radno područje korištenih komponenata
- 5) osjetljivost baterijskih tehnologija.

Razvojni izazovi uspoređenih rješenja su:

- 1) gubitak podataka uslijed gubitka napajanja
- 2) kratko ili nedostatno operativno vrijeme zbog ograničenja baterijskog napajanja
- 3) ograničena memorija za pohranu podataka
- 4) mehanizmi za zaštitu integriteta podataka nisu prisutni
- 5) zahtjevi za mjerenjem različitih parametara.

Na temelju dosadašnjih istraživanja i rješenja, moguće je detaljnije analizirati izazove koji su zajednički za radove na području praćena uvjeta okoline u lancu opskrbe.

- 1) Nedostatak informacija o nepovoljnim uvjetima okoline: Mnogi sustavi ne pružaju dovoljno podataka o promjenama u okolini koje mogu utjecati na učinkovitost i sigurnost lanca opskrbe.
- 2) Promjenjivi klimatski uvjeti okoline: temperatura, vlaga zraka, kiša i oborine, snijeg i led, vjetar, sunčevo (UV) zračenje, atmosferski tlak, kvaliteta zraka (prašina, dim).
- 3) Promjenjivi mehanički uvjeti okoline: vibracije, udari, komprimiranje paketa (pritisak), trenje, nagib i prevrtanje, akceleracija i deceleracija, korozivni uvjeti.
- 4) Potreba za mjerenjem specifičnih ili rijetkih parametara: U nekim slučajevima, praćenje ključnih parametara, poput mikroklimatskih uvjeta ili specifičnih kemijskih svojstava, zahtijeva napredne tehnologije koje su često skupe i teško dostupne.
- 5) Ograničeno operativno vrijeme sustava: Mnogi uređaji i senzori koji se koriste u lancu opskrbe imaju ograničen vijek trajanja baterije ili zahtijevaju čestu zamjenu, što povećava operativne troškove i složenost održavanja.

- 6) Visoki troškovi implementacije: Uvođenje novih tehnologija, poput RFID sustava ili blockchain rješenja za praćenje transparentnosti i sigurnosti, često zahtijeva značajna financijska ulaganja.
- 7) RFID interferencije (smetnje): RFID tehnologija, iako korisna za praćenje proizvoda, može biti podložna smetnjama u okruženjima s visokom koncentracijom metala ili elektromagnetskih polja, što smanjuje njezinu pouzdanost.
- 8) Velike i nepraktične dimenzije uređaja: Neki od postojećih sustava za praćenje i kontrolu uvjeta okoline u lancu opskrbe su prevelikih dimenzija ili nepraktični za integraciju u postojeće logističke procese.

Tehnički izazovi mogu se djelomično ili potpuno prevladati primjenom postojećih tehnoloških rješenja na području razvoja ugradbenih sustava. Jedna od prednosti RFID komunikacije jest mogućnost elektromagnetskog prikupljanja energije, što omogućuje nadogradnju sustava s funkcijom punjenja baterija. Niska potrošnja energije nužan je aspekt za realizaciju sustava koji prati uvjete okoline u skladištenju i transportu. Primjenom metoda za uštedu energije i komponenata ultra niske potrošnje moguće je ostvariti tjedne ili mjeseca rada sustava. Zbog čestih intervala mjerenja, primjenom metoda za komprimiranje mjerenih podataka umanjuje se ograničenje memorijskog prostora za pohranu. Blockchain tehnologija može biti jedno od rješenja za sigurnost i integritet podataka, ukoliko postoji adekvatna arhitektura lanca opskrbe [125]. Zahtjevi za mjerenjem novih parametara proširuju mogućnosti za nove primjene sustava. Senzori inercije i ubrzanja omogućuju detekciju pojave udara ili vibracija tijekom transporta i skladištenja. Osim navedenih izazova, istraživanja također ukazuju na potrebu za boljom integracijom novih tehnologija poput blockchaina i 3D identifikatora u postojeće logističke sustave kako bi se povećala transparentnost, sigurnost i učinkovitost. Međutim, implementacija ovih tehnologija suočava se s tehničkim i organizacijskim preprekama, poput problema s kompatibilnosti sustava, visokih troškova integracije, složenosti prilagodbe infrastrukture, nedostatak standardizacije te potencijalnih sigurnosnih rizika.

4

Metode detekcije udara i određivanje kuta sudara u lancu opskrbe

U ovom poglavlju predstavljene su metode za detekciju udara i određivanje kuta sudara tijekom skladištenja i transporta u lancu opskrbe. Predložen je dizajn uređaja za rad u stvarnom vremenu koji omogućava praćenje i detekciju udara na paketu u lancu opskrbe tijekom skladištenja, isporuke i rukovanja.

4.1 Metoda za detekciju i mjerenje intenziteta udara paketa u lancu opskrbe ugradbenim sustavima ultra niske snage

Za procjenu vjerojatnosti oštećenja paketa tijekom skladištenja i transporta, ugradbeni sustav treba mjeriti, obrađivati i pohranjivati podatke nepoželjnih uvjeta okoline. Pohranjeni podaci moraju biti dostupni potrošaču na zahtjev. Ovisno o vrsti proizvoda u lancu opskrbe, krajnji cilj je detekcija pojave neželjenih događaja. Ugradbeni sustav mora zadovoljiti ograničenja koja se spominju u poglavlju 2: dug operativni vijek na baterijskom napajanju, sakupljanje energije, mala fizička veličina, cijena, dostatna veličina memorije za pohranu podataka te sigurnost i integritet pohranjenih podataka. Zbog zahtjeva za baterijskim napajanjem, sustav je dizajniran u skladu s niskim energetske ograničenjima, kako bi se omogućio dugotrajan rad. Dizajn uključuje sklopovlje niske potrošnje energije uz program-


ski kôd koji omogućuje rad metode za detekciju udara uz minimalnu potrošnju energije. Razvijeni sustav testiran je u laboratorijskom okruženju kroz testiranje rada detekcije udara paketa. Nakon laboratorijske validacije, metoda za detekciju udara testirana je u stvarnom okruženju, točnije, postavljena je na transportirani paket u lancu opskrbe.

4.1.1 Pametna naljepnica za detekciju udara paketa

Za ostvarenje traženih znanstvenih doprinosa, dizajniran je i implementiran sustav niske potrošnje energije za praćenje uvjeta u lancu opskrbe – Pametna naljepnica. Sustav se primjenjuje za evaluaciju metoda predloženih u okviru ove doktorska disertacije. Sustav se napaja Li-ion baterijom, pohranjuje podatke senzora u internu memoriju i prenosi ih korisniku putem RFID komunikacije. Ovisno o konfiguraciji senzora, može pratiti i zapisivati sljedeće podatke u stvarnom vremenu: temperaturu, vlagu, pritisak, intenzitet svjetlosti, vibracije i udare. Pametna naljepnica postavlja se na paket ili na paletu proizvoda prije otpreme. Nakon dostave Pametne naljepnice na odredište, korisnik može pristupiti pohranjenim podacima radi analize i identifikacije neželjenih događaja. Pametna naljepnica za detekciju udara sastoji se od elemenata prikazanih na slici 4.1. Za mjerenje ubrzanja koristi se senzor ADXL372 uz način rada s niskom potrošnjom energije. Mjerni raspon od $\pm 200 g$ koji obuhvaća g vrijednosti dane u tablici 4.1. Podržana je frekvencija uzorkovanja od $400 Hz$ do $6400 Hz$ te $12 bitni$ izlaz podataka [126]. Za mjerenje kalendarskog vremena koristi se sat stvarnog vremena (engl. *Real-Time Clock* - *RTC*) niske potrošnje.

Tablica 4.1: Krhkost izražena u g razinama za različite kategorije proizvoda [65].

Kategorija	Vrsta proizvoda	Razina [g]
Izuzetno krhko	Precizni mjerni instrumenti (npr. multimetri, osciloskopi, laboratorijske vage), optički instrumenti (npr. mikroskopi, teleskopi), laboratorijska oprema visoke preciznosti (npr. spektrometri, kromatografi), medicinska oprema (npr. MRI uređaji, ultrazvučni skeneri), satelitska tehnologija i komponente	15-25
Vrlo krhko	Porculanski predmeti, stakleni proizvodi, instrumenti s mehaničkim udarima, visokotehnološki senzori i detektori	25-40
Krhko	Elektronička oprema, televizijski prijamnici, desktop računala, precizni zasloni, matične ploče	40-60
Umjereno osjetljivo	Laptopi, monitori, tableti, pametni mobiteli, fotografski aparati, registar blagajne	60-85
Umjereno robusno	Perilice rublja, hladnjaci, (mikrovalne) pećnice, klima uređaji, audio sustavi, aparati	85-115
Robusno	Strojevi, metalno posuđe, alati za rad, industrijski kompresori, vanjska sportska oprema, vojna oprema	≥ 115




Slika 4.1: Arhitektura računalnog sustava Pametne naljepnice (a). Moguća stanja Pametne naljepnice u načinima rada za: detekciju udara (b); kontinuirano mjerenje vibracija (c).

Pametna naljepnica temelji se na dizajnu ugradbenog sustava niske potrošnje energije koji podržava tri načina rada: pasivni način, aktivni način i način prijenosa podataka. Zadovoljava postavljene zahtjeve: detekcija udara, procjena kuta sudara, dugotrajan rad, sakupljanje energije, mala fizička veličina (80 mm x 60 mm x 6.5 mm), cijena i količina memorije za pohranu podataka. Male dimenzije omogućavaju postavljanje sustava na proizvod ili na paletu proizvoda. Uređaj je testiran u laboratorijskim uvjetima te na paketu poslanom putem lokalne dostavne službe na putovanje od približno ~ 1600 km u oba smjera.

Prvo, kada je Pametna naljepnica u *pasivnom načinu* rada, ADXL372 neprekidno mjeri ubrzanje. Koristi se FIFO (engl. *First-in First-out*) način rada s niskom potrošnjom uz mogućnost buđenja mikroupravljača nakon što izmjereno ubrzanje premaši unaprijed definiranu razinu praga. Događaj buđenja postavlja Pametnu naljepnicu u *aktivni način* rada. Mikroupravljač analizira podatke o ubrzanju, pohranjuje trenutno vrijeme i vrijednosti ubrzanja u EEPROM (engl. *Electrically Erasable Programmable Read-Only Memory*), nakon čega prelazi u način rada s niskom potrošnjom energije.


Drugo, kada je Pametna naljepnica u *aktivnom načinu* rada, može neprekidno mjeriti ubrzanje, tj. podatke o vibracijama. Nakon što izmjerena g sila premaši unaprijed definiranu razinu praga, vrijednost ubrzanja udara i vrijeme događaja udara pohranjuju se u EEPROM. Budući da su sve komponente uređaja osim RFID-a u aktivnom načinu rada, dolazi do značajne potrošnje energije.

Konačno, kada je Pametna naljepnica u načinu rada za *prijenos podataka*, korisnici mogu dohvatiti podatke putem NFC tehnologije ili UART komunikacijskog protokola. U ovome načinu uređaj koji čita podatke služi kao izvor napajanja, a energija baterije se štedi. Prijenos podataka putem NFC-a ostvaruje se korištenjem elektromagnetskog polja, koje istovremeno omogućuje prijenos energije. Dizajniran je prototip tiskane pločice sustava, prikazan na slici 4.2. Razvijeni prototip tiskane pločice testiran je u laboratorijskom okruženju.



Slika 4.2: Dizajn elektroničkog dijela prototipa Pametne naljepnice: gornji sloj (a); donji sloj (b).

Slika 4.3a prikazuje prototip Pametne naljepnice za detekciju udara ugrađen u paket za testiranje. Paket za testiranje, u kojemu je postavljena šperploča, ima identičnu težinu i dimenzije kao 15" prijenosno računalo. Materijal za ublažavanje paketa je originalni materijal za pakiranje 15" prijenosnog računala. U svrhu testiranja, šperploča i materijal za ublažavanje umetnuti su u originalnu kartonsku kutiju (slika 4.3b). Prototip Pametne naljepnice može biti postavljen na šperploču (slika 4.3a), ili na vanjsku površinu kutije paketa (slika 4.3b).




Slika 4.3: Prototip Pametne naljepnice (crvena oznaka 3) zaljepljena na testni paket od drvene ploče (crvena oznaka 2) s amortizacijskim materijalom od spužve (crvena oznaka 1) (a); paket s Pametnom naljepnicom u kartonskoj kutiji (b).


Vrijednosti ubrzanja mjere se za osi $x(t)$, $y(t)$, $z(t)$, koje se koriste za izračun vrijednosti magnitude:

$$M(t) = \sqrt{x(t)^2 + y(t)^2 + z(t)^2}. \quad (4.1)$$

Netočnost mjerenja senzora ubrzanja iznosi $\pm 3g$. Šum i netočnosti senzora manifestiraju se kao mala odstupanja oko nule na grafu magnitude ubrzanja $M(t)$ (slika 4.4a), osobito kada uređaj miruje i nema promjena ubrzanja. U prvom koraku obrade signala obavlja se uklanjanje šuma. Sve vrijednosti koje ne prelaze unaprijed definirani prag smatraju se šumom te se postavljaju na nulu. Ovaj pristup omogućuje da algoritam za detekciju udara reagira samo na ispravne događaje. U idućem koraku se primjenjuje metoda za detekciju udara, koja pronalazi sve vrijednosti iznad definiranog praga. Maksimalna vrijednost M_p definira se kao glavni vrh s najvećom vrijednošću g te predstavlja najintenzivniji udar paketa unutar mjernog vremenskog perioda (slika 4.4b). Vjerojatnost oštećenja proizvoda određena je intenzitetom udara i kategoriji proizvoda prema tablici 4.1. Trenutak sudara paketa s udarnom površinom prikazan je oznakom t_p . U algoritmu 4.1 prikazan je način na koji Pametna naljepnica detektira udar i izvršava pripadajuće funkcije.



(a)



(b)

Slika 4.4: Primjer vrijednosti magnitude ubrzanja $M(t)$: prije poništavanja šuma (a); detekcija vrhova nakon poništavanja šuma (b).

Algoritam 4.1 Detekcija udara i pohrana mjerenja

```

procedura DETEKCIJA_UDARA
    Inicijaliziraj periferije (I2C, UART, RTC, GPIO)
    Učitaj inicijalne podatke iz EEPROM-a
    status ← CEKANJE
    dok 1 radi
        ako je status = DETEKCIJA tada
            Provjeri FIFO status akcelerometra
            ako je FIFO pun tada
                Pročitaj sve uzorke iz FIFO u memoriju
                za i = 0 do broj_uzoraka radi
                    ako je  $|X_i| > \text{PRAG}$  ili  $|Y_i| > \text{PRAG}$  ili  $|Z_i| > \text{PRAG}$  tada
                        Pronadi  $M_p$  i  $t_p$ 
                        Izračunaj magnitudu  $M$  i  $M_{RMS}$ 
                        Pročitaj vremensku oznaku
                        status ← POHRANA
                        break
                    kraj ako je
                kraj za
            ako je status ≠ POHRANA tada
                Obriši privremenu memoriju, pripremi za pasivni način rada
            kraj ako je
        kraj ako je
    inače ako je status = POHRANA tada
        Zapiši broj uzoraka i vremensku oznaku u EEPROM
        za i = 0 do broj_uzoraka radi
            Zapiši  $X_i$ ,  $Y_i$ ,  $Z_i$  u EEPROM
        kraj za
        Ažuriraj brojač mjerenja i adresu zapisa
        status ← DETEKCIJA
        Pripremi za pasivni način rada
    inače ako je NFC naredba = GET tada
        za j = 0 do broj_mjerenja radi
            Ispiši broj uzoraka, vrijeme i sve uzorke za j-to mjerenje
        kraj za
    inače ako je NFC naredba = SHOW tada
        za j = 0 do broj_mjerenja radi
            Ispiši vrijeme i uzorke za j-to mjerenje
        kraj za
    inače ako je NFC naredba = RESET tada
        Resetiraj brojač mjerenja i adresu zapisa u EEPROM-u
    inače ako je NFC naredba = SYNC tada
        Sinkroniziraj RTC s primljenim vremenom
    inače ako je NFC naredba = EEPROM ERASE tada
        Obriši cijeli EEPROM
    kraj ako je
    ako je vrijeme_neaktivnosti > prag tada
        Pripremi za pasivni način rada
    kraj ako je
    kraj dok
kraj procedura

```

Još jedna vrijednost koja se izračunava iz grafa magnitude ubrzanja $M(t)$ je srednja kvadratna vrijednost (engl. *Root Mean Square* - RMS) glavnog vrha, točnije M_{RMS} , označeno plavom površinom na slici 4.4b. Vrijednost M_{RMS} pruža uvid u moguće oštećenje paketa. Na primjer, ako paket padne dva puta s približno jednakim maksimalnim vrijednostima ubr-

zanja, usporedba M_{RMS} vrijednosti pomaže odrediti koji je pad značajniji za spremanje u memoriju, budući da M_{RMS} pruža informacije o ukupnom energetsom utjecaju udara. Za primjer dan na slici 4.4b, detektirani udar ima glavni vrh koji se dogodio u trenutku t_p . Odgovarajuća maksimalna vrijednost vrha M_p definirana je formulom:

$$M_p = \max_{t \in [t_1, t_2]} M(t). \quad (4.2)$$

Srednja kvadratna vrijednost detektiranog glavnog vrha izračunava se s formulom:


$$M_{RMS} = \sqrt{\frac{1}{n} \sum_{t=t_1}^{t_2} M(t)}, \quad (4.3)$$

$$n = \frac{t_2 - t_1}{T_S} + 1, \quad (4.4)$$

gdje su t_1 i t_2 vremenski trenuci početka i kraja glavnog vrha, n je broj uzoraka unutar vremenskog intervala $[t_1, t_2]$, a T_S je period uzorkovanja. Nakon detektiranog udara, definirajuće vrijednosti glavnog vrha M_{RMS} , M_p i t_p pohranjuju se u memoriju Pametne naljepnice.

4.1.2 Eksperimentalni rezultati


Provedeno je nekoliko eksperimenata kako bi se procijenila metoda mjerenja intenziteta udara Pametne naljepnice. Testovi su provedeni u laboratorijskom okruženju koristeći paket prikazan na slici 4.3b. Korišten je mjerni postav za ispuštanje paketa s različitih visina na ravan drveni pod, prikazano na slici 4.5. U eksperimentima, paket se ispušta horizontalno i vertikalno. Ispuštanjem paketa reproducira se scenario pada paketa tijekom skladištenja




Slika 4.5: Laboratorijski testovi detekcije udara: pad paketa na pod (a); pad utega na paket (b).

i transporta (slika 4.5a). Za drugi eksperimentalni postav, prikazan na slici 4.5b, obavljeno je ispuštanje okruglog utega na paket koji je horizontalno postavljen na drveni pod. Ovaj scenarij predstavlja mogućnost utjecaja drugog paketa na promatrani paket. Za treći eksperiment, proveden je test u stvarnom okruženju skladištenja i transporta. Paket s postavljenom Pametnom naljepnicom poslan je na putovanje kroz Hrvatsku, na put od Osijeka do Dubrovnika i natrag. Duljina jednosmjerne vožnje iznosi otprilike 800 km s ukupnim trajanjem od 5 dana.


U prvom eksperimentu koristi se samo aktivni način rada i ne primjenjuju se postupci štednje energije. Maksimalna frekvencija uzorkovanja za ADXL senzor kada se koristi s I2C komunikacija iznosi (800 Hz). Glavni prag za detekciju udara postavljen je na 5 g s ukupno 170 vrijednosti koje se pohranjuju u memoriju. Pametna naljepnica postavljena je unutar paketa (pričvršćena za šperploču) i izvan paketa (zalijepljena na kutiju). Paket se ispušta vertikalno i horizontalno s različitih visina, a svaki pad se ponavlja 4 puta. Traži se povezanost između vrijednosti $x(t)$, $y(t)$, $z(t)$ i $M(t)$ kako bi se procijenio vremenski interval glavnog vrha i kako bi se pronašao potreban broj uzoraka za procjenu udara. Odabrani rezultati za $x(t)$, $y(t)$ i $z(t)$ osi i RMS vrijednosti za testirane visine prikazani su na slikama 4.6 i 4.7. Najviše vrijednosti ubrzanja vidljive su na osi $z(t)$ za horizontalni pad (os $z(t)$ je orijentirana u smjeru gore/dolje) i na osi $y(t)$ za vertikalni pad (os $y(t)$ je orijentirana u smjeru gore/dolje). Izmjerene vrijednosti ubrzanja za druge osi su znatno niže. Za horizontalnu visinu pada od 50 cm i više, izmjerene g vrijednosti prelaze 80 g . Takva razina ubrzanja može uzrokovati oštećenje pakiranog uređaja ili paketa, osobito ako se radi o proizvodima osjetljivima na intenzivne udare (tablica 4.1). Osim toga, za vertikalni pad, visina pada manja od 20 cm rezultira vrijednostima ubrzanja većim od 60 g . Razlog za to je oblik korištenog paketa, odnosno znatno manja udarna površina u odnosu na površinu udara kod horizontalnog pada, vidljivo na slici 4.3b. Stoga se može zaključiti kako se kod vertikalnog pada očekuju veće razine oštećenja u odnosu na udar kod horizontalnog pada, za istu visinu pada paketa. Osim toga, paket može udariti u pod oštrim kutem (kutevi 45° , 135° , 225° , 315°), što rezultira minimalnom površinom udara i većim vrijednostima intenziteta udara. Za sva mjerenja na osima $x(t)$, $y(t)$, $z(t)$ izračunavaju se vrijednosti $M(t)$, na temelju jednadžbe (4.1). Prikaz rezultata za horizontalni pad nalazi se na slikama 4.6b, 4.6d, 4.6f i 4.6h. Prikaz rezultata za vertikalni pad nalazi se na slikama 4.7b, 4.7d, 4.7f i 4.7h. Budući da je glavna vrijednost vrha M_p približno jednaka za sve osi $x(t)$, $y(t)$ i $z(t)$ u usporedbi s originalnim mjerenjima, radi pojednostavljenja analize i interpretacije rezultata, u svim daljnjim testovima u poglavlju razmatraju se isključivo ukupne vrijednosti ubrzanja $M(t)$, umjesto pojedinačnih komponenti po osima. Ukupno vrijeme trajanja udara približno je konstantno za sve testirane visine pada ($\approx 50\text{ ms}$), dok je trajanje glavnog vrha značajno manje od ukupnog vremena mjerenja ($\approx 8\text{ ms}$). Za zahtjeve detektiranja udara i snimanja vrijednosti ubrzanja u minimalnom trajanju od 50 ms , odabrana frekvencija uzorkovanja od 800 Hz pokazala se dostatnom za detekciju glavne vrijednosti vrha.




(a)




(b)




(c)




(d)




(e)



(f)




(g)




(h)


Slika 4.6: Vrijednosti detekcije udara za horizontalni pad paketa s odabranih visina (800 Hz, bez FIFO-a), mjereno unutar paketa. Osi ubrzanja za udar s visine 100 cm (a), 50 cm (c), 20 cm (e), 10 cm (g) i valni oblik magnitude ubrzanja za udar s visine 100 cm (b), 50 cm (d), 20 cm (f) i 10 cm (h).




(a)




(b)




(c)




(d)




(e)



(f)



(g)




(h)

Slika 4.7: Vrijednosti detekcije udara za vertikalni pad paketa s odabranih visina (800 Hz, bez FIFO-a), mjereno unutar paketa. Osi ubrzanja za udar s visine 100 cm (a), 50 cm (c), 20 cm (e), 10 cm (g) i valni oblik magnitude ubrzanja za udar s visine 100 cm (b), 50 cm (d), 20 cm (f) i 10 cm (h).


U drugom eksperimentu koriste se aktivan i pasivan način rada kako bi se omogućila niska potrošnja energije Pametne naljepnice. U pasivnom načinu rada s niskom potrošnjom energije aktivni su senzor ubrzanja, RTC i sustav upravljanja baterijom. Mikroupravljač je u načinu rada za štednju energije, dok su memorija i NFC isključeni (slika 4.1). Za uštedu energije koristi se FIFO značajka ADXL senzora, uz korištenje prekida (engl. *interrupt*) kada se premaši unaprijed definirana vrijednost praga od $5g$. Kada dođe do udara koji aktivira prekid, Pametna naljepnica prelazi u aktivan način za spremanje podataka o udaru. FIFO značajka senzora omogućuje korištenje viših frekvencija uzorkovanja i nije ograničena I2C komunikacijskim protokolom. Međutim, kapacitet FIFO spremnika ograničava maksimalni broj pohranjenih vrijednosti ubrzanja za svaku os na 170 uzoraka. Rezultati prvog eksperimenta pokazuju da trajanje udara iznosi približno $\approx 50ms$. Maksimalna frekvencija uzorkovanja u FIFO načinu rada u tom slučaju iznosi $170/50ms = 3400Hz$. Stoga se koristi najbliža frekvencija uzorkovanja ADXL senzora od $3200Hz$. Prema Nyquist-Shannonovom teoremu, frekvencija uzorkovanja signala mora biti barem dvostruko veća od maksimalne frekvencije signala. Ovo pravilo vrijedi samo za periodične signale ili za signale čija je maksimalna frekvencija jasno definirana [127]. Za detekciju glavnog vrha koji traje $\approx 8ms$, potrebna je frekvencija uzorkovanja od minimalno $\approx 125Hz$. U praksi, za uzorkovanje neperiodičnih signala, potrebna je nekoliko puta veća frekvencija uzorkovanja. Stoga se koriste frekvencije uzorkovanja od $1600Hz$ (12.8 puta veća) i $400Hz$ (3.2 puta veća) s istim brojem pohranjenih uzoraka kako bi se analizirale moguće razlike u vrijednostima glavnog vrha u ovisnosti o frekvenciji uzorkovanja.

Mjerenja s najvišom frekvencijom uzorkovanja (slike 4.8 i 4.9) pokazuju detaljan udar na grafu $M(t)$. Vidljiv je glavni vrh u mjerenjima $M(t)$, a najveća izmjerena vrijednost magnitude je iznad $150g$ (slika 4.9b), što odgovara vrijednostima izmjerjenima u prvome eksperimentu. Niža frekvencija uzorkovanja ubrzanja rezultira nižom potrošnjom energije Pametne naljepnice. Provedeni su eksperimenti pri frekvencijama uzorkovanja od $1600Hz$ (slike 4.10 i 4.11) i $400Hz$ (slike 4.12 i 4.13). Moguće je vidjeti kako nema značajne razlike u vrijednostima glavnog vrha grafa $M(t)$ kada se usporedi s rezultatima dobivenim pri frekvenciji uzorkovanja od $800Hz$ za prvi eksperiment (slike 4.6 i 4.7) ili pri frekvenciji uzorkovanja od $3200Hz$ u drugom eksperimentu. Za frekvenciju uzorkovanja $400Hz$ (slike 4.12 i 4.13) na grafu $M(t)$ nisu vidljivi manji vrhovi, koji su vidljivi kod mjerenja s većom frekvencijom uzorkovanja. Na temelju dobivenih rezultata, preporučena je minimalna frekvencija uzorkovanja od $800Hz$ za pouzdanu detekciju udara. Kada je riječ o utjecaju frekvencije uzorkovanja, iz rezultata na slikama 4.10 do 4.13 uočava se da mjerene vrijednosti $M(t)$ minimalno odstupaju. Kod mjerenja izvan paketa, maksimalne vrijednosti $M(t)$ su veće u odnosu na mjerenja unutar paketa. Razlike u vrijednostima $M(t)$ za eksperimente provedene s Pametnom naljepnicom unutar i izvan paketa nastaju zbog vrste i debljine materijala pakiranja. Ovaj eksperimentalni pristup može se primijeniti u analizi i testiranju učinkovitosti zaštitnog pakiranja. Razlika između sile udara unutar paketa i sile udara izvan paketa može


kvantificirati efikasnost zaštitnog pakiranja.




Slika 4.8: Vrijednosti detekcije udara za horizontalni pad paketa s odabranih visina (3200 Hz, FIFO). Valni oblik magnitude ubrzanja: mjereno unutar paketa za udar s visine 100 cm (a), 50 cm (c), 20 cm (e), 10 cm (g); mjereno na paketu za udar s visine 100 cm (b), 50 cm (d), 20 cm (f) i 10 cm (h).




Slika 4.9: Vrijednosti detekcije udara za vertikalni pad paketa s odabranih visina (3200 Hz, FIFO). Valni oblik magnitude ubrzanja: mjereno unutar paketa za udar s visine 100 cm (a), 50 cm (c), 20 cm (e), 10 cm (g); mjereno na paketu za udar s visine 100 cm (b), 50 cm (d), 20 cm (f) i 10 cm (h).




Slika 4.10: Vrijednosti detekcije udara za horizontalni pad paketa s odabranih visina (1600 Hz, FIFO). Valni oblik magnitude ubrzanja: mjereno unutar paketa za udar s visine 100 cm (a), 50 cm (c), 20 cm (e), 10 cm (g); mjereno na paketu za udar s visine 100 cm (b), 50 cm (d), 20 cm (f) i 10 cm (h).



Slika 4.11: Vrijednosti detekcije udara za vertikalni pad paketa s odabranih visina (1600 Hz, FIFO). Valni oblik magnitude ubrzanja: mjereno unutar paketa za udar s visine 100 cm (a), 50 cm (c), 20 cm (e), 10 cm (g); mjereno na paketu za udar s visine 100 cm (b), 50 cm (d), 20 cm (f) i 10 cm (h).




Slika 4.12: Vrijednosti detekcije udara za horizontalni pad paketa s odabраних visina (400 Hz, FIFO). Valni oblik magnitude ubrzanja: mjereno unutar paketa za udar s visine 100 cm (a), 50 cm (c), 20 cm (e), 10 cm (g); mjereno na paketu za udar s visine 100 cm (b), 50 cm (d), 20 cm (f) i 10 cm (h).



Slika 4.13: Vrijednosti detekcije udara za vertikalni pad paketa s odabраних visina (400 Hz, FIFO). Valni oblik magnitude ubrzanja: mjereno unutar paketa za udar s visine 100 cm (a), 50 cm (c), 20 cm (e), 10 cm (g); mjereno na paketu za udar s visine 100 cm (b), 50 cm (d), 20 cm (f) i 10 cm (h).

U trećem eksperimentu simulirana je situacija pada teškog objekta na paket, kako bi se ispitali učinci udara pokretnog objekta na paket s ugrađenom Pametnom naljepnicom, prikazano na slici 4.5b. Ovaj scenarij predstavlja realnu mogućnost tijekom procesa transporta, gdje drugi objekti ili paketi unutar kontejnera ili kamionske prikolice mogu pasti na promatrani paket i potencijalno oštetiti njegov sadržaj. Korišteni uteg ima masu od 1.25 kg i promjer od 125 mm s rupom u sredini. Utteg se pušta s odabrane visine i udara u paket postavljen horizontalno na drvenom podu. Rezultati su prikazani na slici 4.14. Mjerenje za pad utega s visine od 10 cm nije prisutno jer vrijednost praga detekcije nije prekoračeno prilikom udara s navedene visine. Utteg pada u središte paketa, a to je područje najveće apsorpcije udara. Apsorpcija udara također objašnjava niže intenzitete glavnog vrha pohranjenog u mjerenjima, što je u skladu s rezultatima dobivenim iz prethodnih eksperimenata udara paketa. Može se zaključiti kako međusobni utjecaj paketa manje utječe na razine oštećenja, zbog toga što oba paketa koriste zaštitne materijale koji međusobno poništavaju utjecaj udara. Iznimka su proizvodi koji nemaju ambalažu ili nisu čvrsto fiksirani unutar pakiranja, poput voća ili povrća, pa su tako podložni utjecaju udara ili vibracija.



Slika 4.14: Vrijednosti detekcije udara za pad utega na nepomični paket (1600Hz, FIFO). Valni oblik magnitude ubrzanja mjeren unutar paketa za pad utega s visine 100 cm (a), 50 cm (b) i 20 cm (c). Za pad s visine od 10 cm vrijednost magnitude nije prešla prag detekcije.


U četvrtom eksperimentu, paket s prototipom Pametne naljepnice postavljenom na proizvod, šalje se lokalnom dostavnom službom na putovanje kroz Hrvatsku, od Osijeka do Dubrovnika i nazad. Frekvencija uzorkovanja iznosi 1600 Hz uz korištenje načina niske po-

trošnje i FIFO načina rada. Pametna naljepnica detektira sve udare s intenzitetom preko 5 g , a u memoriju je moguće zapisati 379 mjerenja za detekciju udara. Korištene su dvije dugmaste baterije (engl. *coin cell*) ukupnog kapaciteta 400 mAh . Prikaz poslanog paketa nalazi se na slici 4.15. Prvo zabilježeno mjerenje prikazano je na slici 4.16a gdje se dogodio udar srednjeg intenziteta. Intenzitet prvog mjerenja usporediv je s laboratorijskim mjerenjem pada paketa s visine od 50 cm . Takve razine udara imaju štetne učinke na osjetljive vrste proizvoda navedene u tablici 4.1. Drugo zabilježeno mjerenje, prikazano na slici 4.16b, nije usporedivo s laboratorijskim eksperimentima. Nekoliko rastućih vrhova premašuje vrijednost od 150 g u kratkom vremenskom periodu. Prema broju lokalnih maksimalnih vrijednosti, može se zaključiti kako je paket poskakivao ili se odbijao nakon prvog kontakta. Paket je došao u stacionarno stanje tek prilikom zadnje maksimalne vrijednosti, kada je završilo mjerenje. Ovakva mjerenja sa sigurnošću nepovoljno utječu na proizvode osjetljive na udare ili vibracije, posebno ako nisu korišteni materijali za pakiranje koji su adekvatni za takve uvjete. U slučaju slanja paketa i očitavanja podataka poput onih prikazanih na slici 4.16, moguće je očekivati oštećenje ukoliko se radi o osjetljivom proizvodu.

Provedeno je nekoliko eksperimenata radi evaluacije detekcije udara Pametne naljepnice. Prema analiziranim podacima o ubrzanju, vidljive su korelacije u magnitudama kod detektiranih udara paketa za različite visine pada paketa (10 cm , 20 cm , 50 cm i 100 cm). Izveden je i eksperiment detekcije udara pri padu utega na paket s različitih visina, čime je obuhvaćen scenario međusobnog udara paketa u transportu i skladištenju. Pametna naljepnica ispitana je na komercijalnom paketu. Sustav je postavljen na proizvod unutar paketa, a pošiljka je poslana putem lokalne dostavne službe na putovanje od 1600 km . Maksimalna vrijednost magnitude M_p i srednja vrijednost kvadrata RMS detektiranog udara pohranjuju se u memoriju, uz oznaku kalendarskog datuma i vremena (engl. *timestamp*). Podaci se mogu prenijeti korisniku putem NFC tehnologije ili putem UART komunikacije bez dodatne



Slika 4.15: Slanje paketa s Pametnom naljepnicom na putovanje od Osijeka do Dubrovnika.



Slika 4.16: Detekcija dva udara (a) i (b) te njihove magnitude ubrzanja za paket na putovanju od Osijeka do Dubrovnika (1600 Hz, FIFO).

potrošnje energije. Izuzetno niska potrošnja energije postignuta je specifičnim dizajnom sklopovlja u kombinaciji s niskom potrošnjom energije senzora ubrzanja i FIFO načinom rada, što omogućuje dulje operativno vrijeme Pametne naljepnice u lancu opskrbe.

Za provedena mjerenja korištene su različite frekvencije uzorkovanja, kako bi se uočio njihov utjecaj na detekciju udara. Provedeni eksperimenti pokazuju da je potrebna minimalna frekvencija uzorkovanja od 800 Hz za pravilnu detekciju udara. Osim toga, kada se Pametna naljepnica nalazi unutar paketa, mjerenja pokazuju niže maksimalne vrijednosti udara u usporedbi s mjerenjima izvan paketa. S pravilnom upotrebom zaštitnog sloja na paketu, poput kartona i zaštitne pjene, otpornost paketa na udare se povećava. Uočeno je da vertikalni pad paketa rezultira većim maksimalnim vrijednostima udara u usporedbi s horizontalnim padom paketa. Razlog za to je znatno manja kontaktna površina pri udaru kod vertikalnog pada. U trećem testu, gdje je pošiljka poslana na putovanje s lokalnom dostavnom službom, zabilježena su dva događaja jakog udara. Analizom zabilježenih događaja moguće je procijeniti razinu oštećenja proizvoda, ukoliko se radi o paketu koji nije zaštićen od udara intenziteta 80 g .

Pametna naljepnica mora biti konstruirana kao sustav iznimno niske potrošnje energije kako bi se omogućio dugotrajan rad tijekom perioda skladištenja i transporta. Ova specifikacija ostvaruje se kroz poseban dizajn sklopovlja koji uključuje korištenje RTC-a iznimno niske potrošnje i ADXL senzora koji je optimiziran za rad u načinu s niskom potrošnjom energije. Razlike u potrošnji struje Pametne naljepnice za način rada s niskom potrošnjom i aktivni način rada dane su u tablici 4.2. Pametna naljepnica najviše vremena provodi u načinu rada s niskom potrošnjom, uz detekciju prelaska definirane granice praga ubrzanja, nakon čega ulazi u aktivan način na kratko vrijeme, čime se umanjuje ukupna potrošnja energije. Struja Pametne naljepnice mjerena je visokopreciznim multimetrom Keysight 34465A (slika 4.17a), gdje je svaka izmjerena vrijednost prosjek od 100 mjerenja. Dijagram korištenog mjernog postava nalazi se na slici 4.17b. Iz mjerenja prikazanih u tablici 4.2 vidljiva je najveća potrošnja struje pri najvišoj frekvenciji uzorkovanja od 3200 Hz , koja je 47.57 puta manja u načinu rada s niskom potrošnjom u odnosu na aktivni način rada. U najboljem slu-


Tablica 4.2: Izmjerena potrošnja struje pametne naljepnice pri različitim frekvencijama uzorkovanja ubrzanja.

Frekvencija uzorkovanja [Hz]	Način niske potrošnje [μA]	Aktivni način rada [μA]	Smanjenje potrošnje energije
400	16.869	1540	91.29x
800	19.204	1542	80.30x
1600	23.951	1554	64.88x
3200	32.897	1565	47.47x

čaju, potrošnja je 91 puta manja pri najnižoj frekvenciji uzorkovanja od 400 Hz . Na temelju dobivenih mjerenja moguće je procijeniti radni vijek Pametne naljepnice za detekciju udara. Procjena se temelji na idealnim uvjetima, bez uzimanja u obzir utjecaja kao što su niska ili visoka temperatura, varijacije u kapacitetu baterije, homogenost kemije u ćelijama, utjecaj samopražnjenja ili stanje zdravlja baterije. U tablici 4.3 nalazi se procijenjeno vrijeme rada za različite frekvencije uzorkovanja. Vrijednosti se temelje na korištenju baterije od 90 mAh pri temperaturi od 25°C . Broj procijenjenih dana rada smanjuje se uslijed povećanja frekvencije uzorkovanja. Može se uočiti da broj udara ima zanemariv utjecaj na procijenjeno vrijeme rada. Razlog za to je značajno manje vrijeme rada u aktivnom načinu rada, u odnosu na vrijeme rada u načinu niske potrošnje. Za preporučenu frekvenciju uzorkovanja od 800 Hz , uz pretpostavku pojave 10 izmjerenih vrijednosti udara iznad postavljenog praga detekcije, procijenjeno vrijeme rada iznosi ~ 195 dana, što je dovoljno za dugotrajna putovanja. Radni vijek Pametne naljepnice za detekciju udara može se produžiti prema potrebi primjenom baterije većeg kapaciteta.



(a)



(b)

Slika 4.17: Mjerni postav uključuje: Keysight 34465A multimetar (a); dijagram mjernog postava (b).

Tablica 4.3: Procijenjeno trajanje rada Pametne naljepnice na temelju mjerenja potrošnje struje u načinu niske potrošnje i aktivnom načinu za različit broj mjerenih udara po danu.


Frekvencija uzorkovanja [Hz]	Procijenjeno trajanje rada [dani]				
	5 udara	10 udara	20 udara	50 udara	100 udara
400	222.177	222.061	221.830	221.138	219.994
800	195.182	195.093	194.914	194.380	193.496
1600	156.508	156.450	156.334	155.989	155.416
3200	113.959	113.928	113.867	113.683	113.378

4.2 Metoda određivanja kuta sudara paketa prilikom detekcije udara uporabom vektora ubrzanja

Horizontalni i vertikalni kutevi paketa mijenjaju se tijekom otpreme i rukovanja zbog slobodnog pada ili sudara s drugim objektom. Pametna naljepnica postavljena je na paket, a senzor ubrzanja koristi se za mjerenje ubrzanja u osima $x(t)$, $y(t)$ i $z(t)$. Na temelju pohranjenih mjerenja moguće je procijeniti horizontalne i vertikalne kutove nagiba kako bi se dobili dodatni podaci o mogućim oštećenjima. Predložena metoda testirana je u laboratorijskom okruženju.

4.2.1 Procjena horizontalnog i vertikalnog kuta sudara na temelju izmjerenog ubrzanja

Za izvođenje metode odabran je Eulerov koordinatni sustav, koji omogućuje precizno opisanje orijentacije objekta u trodimenzionalnom prostoru korištenjem tri uzastopne rotacije oko koordinatnih osi. Ovaj sustav temelji se na Eulerovim kutovima (slika 4.18), koji definiraju rotaciju oko zadanih osi prema unaprijed definiranom redoslijedu, čime se osigurava fleksibilnost u modeliranju rotacijskih kretanja. Kako bi se procijenila vjerojatnosti oštećenja paketa u skladištenju i transportu, potrebno je odrediti horizontalni kut θ (engl. *Pitch*) i vertikalni kut ϕ (engl. *Roll*) sudara na temelju mjerenih podataka. Budući da senzor ubrzanja vrši mjerenja na temelju referentne Zemljine gravitacije, nije moguće odrediti os zakretanja ψ (engl. *Yaw*). Kako bi se ostvarilo trodimenzionalno orijentiranje u prostoru, sustav je potrebno proširiti za žiroskopom. Za razvoj ove metode nije korišten žiroskop, s obzirom na to da os zakretanja ne pruža bitne informacije o razini oštećenja. Oštećenja paketa tijekom skladištenja i transporta određena su silom udara te kutom pod kojim je došlo do sudara. Horizontalni ili vertikalni nagib detektiranog udara može rezultirati manje ozbiljnim oštećenjima u usporedbi s udarom koji se dogodi pod kutom. Udar koncentriran na manju



Slika 4.18: Kutovi nagiba, prevajjivanja i skretanja rotirajućeg paketa.

površinu uzrokuje veća oštećenja zbog povećanog tlaka, budući da se ista sila raspoređuje na manjoj površini. Tlak je iskazan formulom:

$$P[\text{Pa}] = \frac{F[\text{N}]}{A[\text{m}^2]}, \quad (4.5)$$

gdje je F sila, a A površina. Za konstantnu silu F , smanjenjem površine A dolazi do povećanja tlaka P . Povećanjem tlaka povećava se rizik od deformiranja paketa i oštećenja proizvoda.

Metoda za procjenu horizontalnog i vertikalnog kuta sudara opisana je u nastavku. Algoritam 4.2 pronalazi točku maksimalne vrijednosti udara. Za procjenu kuta sudara koristi se maksimalna vrijednost udara, zajedno s 5 vrijednosti prije maksimalne vrijednosti udara i 5 vrijednosti poslije maksimalne vrijednosti udara za osi $x(t)$, $y(t)$ i $z(t)$. Na taj način se uključuju značajne vrijednosti za sve tri osi u vremenskom okviru maksimalne vrijednosti udara. $\overline{A_x}$, $\overline{A_y}$ i $\overline{A_z}$ u jednadžbama 4.6, 4.7 i 4.8 predstavljaju prosjek od 11 vrijednosti za svaku os u vremenskom okviru maksimalne vrijednosti udara. Jednadžbe 4.9 i 4.10 koriste se za izračun horizontalnog i vertikalnog kuta nagiba.

$$\overline{A_x} = 11^{-1} \sum_{i=0}^{10} A_x(i) \quad (4.6)$$

$$\overline{A_y} = 11^{-1} \sum_{i=0}^{10} A_y(i) \quad (4.7)$$

$$\overline{A_z} = 11^{-1} \sum_{i=0}^{10} A_z(i) \quad (4.8)$$

$$Pitch(\theta) = \arctan \frac{A_x}{\sqrt{(A_y)^2 + (A_z)^2}} [^\circ] \quad (4.9)$$

$$Roll(\phi) = \arctan \frac{A_y}{\sqrt{(A_x)^2 + (A_z)^2}} [^\circ] \quad (4.10)$$

Za metodu određivanja kuta sudara u lancu opskrbe korišten je prototip Pametne naljepnice (slika 4.19) koji je razvijen za primjenu metode za detekciju udara. Pametna naljepnica pohranjuje podatke o udaru u memoriju kada ubrzanje prijeđe definiranu vrijednost praga. Za svaki udar pohranjuje se po 170 vrijednosti ubrzanja za svaku os $x(t)$, $y(t)$ i $z(t)$. Unutar tih 510 vrijednosti nalaze se vrijednosti detektiranog udara. Na temelju omjera intenziteta udara između mjerenih osi, moguće je odrediti da li je došlo do povećanog rizika od oštećenja. Ukoliko je kut sudara manji (npr. udarac na rub, kut ili zakrivljeni dio paketa), moguće je odrediti da postoji povećan rizik od oštećenja paketa. U znanstvenim i industrijskim primjenama, mjerenje kuta sudara postalo je standard za pouzdanu procjenu integriteta proizvoda, jer omogućuje razlikovanje između blage, srednje i visoke štete.

Algoritam 4.2 Procjena kuta sudara paketa

```

1: procedura PROCJENA_KUTA(podaci, broj_mjerenja)
2:   measid ← Unos ID-a mjerenja
3:   ako je measid < 0 ili measid > broj_mjerenja tada
4:     Ispiši "Nevažeći ID mjerenja."
5:   vрати
6:   kraj ako je
7:   RMS ←  $\sqrt{\sum(\text{kvadrat podataka za } measid)}$ 
8:   maxRMS ← max(RMS)
9:   indexMaxRMS ← index of maxRMS
10:  x_local_max ← max(|podaci[measid][indexMaxRMS - 5 : indexMaxRMS +
    5, 1]|)
11:  y_local_max ← max(|podaci[measid][indexMaxRMS - 5 : indexMaxRMS + 5, 2]|)
12:  z_local_max ← max(|podaci[measid][indexMaxRMS - 5 : indexMaxRMS + 5, 3]|)
13:  x_out ←  $\frac{1}{11} \sum_{i=indexMaxRMS-5}^{indexMaxRMS+5} data\_all[measid][i, 1]$ 
14:  y_out ←  $\frac{1}{11} \sum_{i=indexMaxRMS-5}^{indexMaxRMS+5} data\_all[measid][i, 2]$ 
15:  z_out ←  $\frac{1}{11} \sum_{i=indexMaxRMS-5}^{indexMaxRMS+5} data\_all[measid][i, 3]$ 
16:  Pitch ← atan2d(-x_out,  $\sqrt{y\_out^2 + z\_out^2}$ )      ▷ Izračunati horizontalni kut
17:  Roll ← atan2d(y_out, z_out)                      ▷ Izračunati vertikalni kut
18:  ispis rezultata i grafički prikaz
19:  vрати
20: kraj procedura

```



Slika 4.19: Prototip Pametne naljepnice za detekciju udara.

4.2.2 Eksperimentalni rezultati

Provedena su dva eksperimenta udara paketa uz izmjenu kuta sudara kako bi se procijenili promatrani kutovi. Korištenjem kutomjera postavljeni su početni očekivani vertikalni kutovi ϕ' i očekivani horizontalni kutovi θ' paketa, nakon čega je paket ispušten na horizontalnu drvenu površinu. Udar je izvršen u smjeru gravitacije jer senzor ubrzanja koristi gravitaciju kao referentnu točku. Senzor je pozicioniran na središte paketa, čime su minimizirane moguće pogreške uzrokovane nehomogenostima materijala ili odstupanjima u ručnom ispuštanju. Za svako novo mjerenje, kut korištenog paketa rotira se u smjeru zakretanja (ϕ' ili θ') za 45° u odnosu na prethodni položaj. Mjerenja se ponavljaju sve dok se ne postigne rotacija paketa oko promatrane osi. Izmjereni kutovi predstavljaju rezultate dobivene mjerenjima pomoću Pametne naljepnice. Očekivani kutevi su kutevi koji su ručno postavljeni, odnosno to je kut paketa pod kojim paket udara na površinu. Korištenjem Pametne naljepnice za detekciju udara zabilježena je dinamika svakog udara, kako bi se osigurala usporedivost između očekivanih i izmjerenih kutova sudara. Ovim eksperimentalnim pristupom omogućena je pouzdana validacija algoritama za detekciju orijentacije paketa pri udaru. Algoritam je primjenjiv na optimizaciji dizajna ambalaže i zaštitnih materijala.

Prvi test izveden je s paketom koji se, nakon svakog mjerenja, rotira u vertikalnom smjeru. Vrijednosti ubrzanja i procijenjeni vertikalni kutovi nagiba prikazani su na slici 4.20. Drugi eksperiment izveden je s paketom koji se, nakon svakog mjerenja, rotira u horizontalnom smjeru. Vrijednosti ubrzanja i procijenjeni horizontalni kutovi prikazani su na slici 4.21. Za usporedbu, vrijednosti izmjerenih i očekivanih vertikalnih i horizontalnih kutova za provedene


eksperimente prikazane su u tablicama 4.4 i 4.5. Izmjerene vrijednosti izračunate su na temelju metode za procjenu kuta sudara koja je dana u algoritmu 4.2.

U prvome testu, rezultati pokazuju kako vrijednosti izmjerenog kuta odgovaraju vrijednostima očekivanog kuta. S rotacijom paketa u vertikalnom smjeru, vidljivo je kako se procijenjeni vertikalni kut mijenja te prati očekivani vertikalni kut. U drugom testu, rezultati također pokazuju podudaranje između izmjerenog i očekivanog kuta sudara pri rotaciji u horizontalnom smjeru.


U procjeni kuta sudara prisutne su greške, koje mogu nastati uslijed slijedećih faktora. Utjecaj Zemljine gravitacije, koja iznosi $1g$, unosi sustavnu grešku u procjenu rezultata. Metoda ispuštanja paketa i generiranja udara, koja uključuje ručno udaranje paketa u drvenu površinu, podložna je varijacijama zbog ljudskog faktora, uključujući potencijalne nepravilnosti u kutu udara. Zabilježena odstupanja mogu biti rezultat fizičke deformacije testiranog paketa, koja proizlazi iz nehomogenosti materijala i različite čvrstoće udarne površine. Lokacija senzora na paketu nije u apsolutnom centru, s obzirom na to da je centriranje senzora otežano zbog prisutnosti proizvoda unutar paketa. Neponovljivost generiranog udara pri početnom kutu također može uzrokovati odstupanja u izmjerenim kutevima.

Tablica 4.4: Usporedba izmjerenih i očekivanih vrijednosti kuteva pri rotaciji paketa u horizontalnom smjeru.


Br. mjerenja	Izmjeren ϕ [°]	Izmjeren θ [°]	Očekivan ϕ' [°]	Očekivan θ' [°]
1 (Sl. 4.20a)	-174.289	-24.121	-180	0
2 (Sl. 4.20b)	-121.886	8.237	-135	0
3	-92.379	1.783	-90	0
4	-41.943	-17.144	-45	0
5	-29.595	-4.470	0	0
6	48.846	-6.091	45	0
7 (Sl. 4.20c)	95.365	-11.806	90	0
8 (Sl. 4.20d)	178.331	1.852	180	0




(a)



(b)



(c)



(d)


Slika 4.20: Izmjerene vrijednosti kuteva pri rotaciji paketa u horizontalnom smjeru za očekivane kutove $\phi' = -180^\circ$ i $\theta' = 0^\circ$ (a); $\phi' = -135^\circ$ i $\theta' = 0^\circ$ (b); $\phi' = 90^\circ$ i $\theta' = 0^\circ$ (c); $\phi' = 180^\circ$ i $\theta' = 0^\circ$ (d).

Vrijednosti senzora ubrzanja prikazane su s $x(t)$, $y(t)$ i $z(t)$. Kutovi udara paketa označeni su s $Roll$ i $Pitch$.


Tablica 4.5: Usporedba izmjerenih i očekivanih vrijednosti kuteva pri rotaciji paketa u vertikalnom smjeru.

Br. mjerenja	Izmjeren ϕ [°]	Izmjeren θ [°]	Očekivan ϕ' [°]	Očekivan θ' [°]
1 (Sl. 4.21a)	-177.839	6.454	-180	0
2 (Sl. 4.21b)	142.334	-67.283	135	-45
3	-21.649	-25.376	-45	-45
4	8.891	6.031	0	0
5	-22.777	22.172	-45	45
6	-99.162	83.242	-90	90
7 (Sl. 4.21c)	171.235	44.154	135	45
8 (Sl. 4.21d)	-13.479	-17.011	0	0


Tijekom skladištenja i transporta paketa u lancu opskrbe, prilikom oštećenja paketa nisu poznati svi faktori koji utječu na razinu oštećenja. Predložena metoda za određivanje kuta sudara proširuje mogućnosti za procjenu vjerojatnosti oštećenja paketa, pružajući detaljniji uvid u prirodu i uzrok nastalih oštećenja. Procjena vjerojatnosti da je došlo do oštećenja temelji se na procjeni vertikalnih i horizontalnih kutova u trenutku udara paketa. Vertikalni i horizontalni kutovi sudara procjenjuju se na temelju mjerenja ubrzanja izvedenih s Pametnom naljepnicom koja je postavljena na paket. Provedena su dva eksperimenta, a analizirani rezultati pokazuju da izmjereni vertikalni i horizontalni kutovi sudara odgovaraju očekivanim kutevima sudara. Provedena mjerenja uzrokovala su udubljenja rubova kartonskog paketa kod mjerenja koja nisu isključivo horizontalna ili vertikalna. Razvijena metoda dolazi do izražaja kod udara u kritične površine paketa. Kritične površine paketa predstavljaju najmanje površine koje su najizloženije udarima, poput rubova, zakrivljenih dijelova ili drugih strukturno osjetljivih područja.




(a)



(b)



(c)



(d)

Slika 4.21: Izmjerene vrijednosti kuteva pri rotaciji paketa u vertikalnom smjeru za očekivane kutove $\phi' = -180^\circ$ i $\theta' = 0^\circ$ (a); $\phi' = 135^\circ$ i $\theta' = -45^\circ$ (b); $\phi' = -135^\circ$ i $\theta' = 45^\circ$ (c); $\phi' = 0^\circ$ i $\theta' = 0^\circ$ (d). Vrijednosti senzora ubrzanja prikazane su s $x(t)$, $y(t)$ i $z(t)$. Kutovi udara paketa označeni su s $Roll$ i $Pitch$.

5

Metode dizajna energetski učinkovitih sustava niske snage

Za realizaciju energetski učinkovitog sustava, u ovom poglavlju predloženo je korištenje dinamičkog skaliranja frekvencije (DFS) i dinamičkog skaliranja napona i frekvencije (DVFS) kako bi se smanjila potrošnja električne energije i postiglo svojstvo ultra niske potrošnje. Metoda se temelji na razini opterećenja i računalnim zahtjevima koji su aktivni u zadanom trenutku. Izvođenje odabranih operacija analizirano je s obzirom na potrošnju električne energije. Navedena metoda preduvjet je za dizajniranje ugradbenih sustava na energetski optimiziran način. Analizirani su tehnički aspekti sklopovlja te implementacija DVFS-a na razini programskog kôda.

5.1 Metoda optimalne prilagodbe napona i frekvencije mikroupravljača za postizanje ultra niske potrošnje sustava za računalno zahtjevne algoritme

Analiza potrošnje energije provedena je za računalne operacije FFT (engl. *Fast Fourier Transform*), CRC32 (engl. *Cyclic Redundancy Check*), MD5 (engl. *Message-Digest Algorithm 5*) i SHA256 (engl. *Secure Hash Algorithm*). Za potrebe dinamičkog skaliranja napona, korištena je eksponencijalna funkcija za izračun stabilnog napona. Za postizanje ultra niske potrošnje ugradbenog sustava, razvijena je metoda za dinamičko skaliranje napona


i frekvencije na temelju zahtjeva opterećenja. Tijekom izvođenja računalnih operacija razina performansi usklađuje se i prilagođava specifičnim zahtjevima svakog opterećenja, kako bi se minimizirala potrošnja energije. Opisani pristup moguće je generalizirati i primijeniti na različite kategorije ugradbenih sustava. Predložena je analiza performansi po wattu (engl. *Performance Per Watt* - *PPW*), s ciljem određivanja idealne ravnoteže između potrošene energije i postignutih (željenih) performansi. Mjerenje potrošnje energije temelji se na primjerima operacija iz stvarnog svijeta, pri čemu je glavni cilj ove metode postizanje ultra niske potrošnje energije. U nastavku se nalaze mjerni postav, rezultati mjerenja potrošnje energije pri primjeni DFS-a i DVFS-a. PPW analiza ima primjenu u smanjenju potrošnje energije kod izvođenja planiranih opterećenja za novorazvijene ugradbene sustave.

5.1.1 Eksperimentalni postav

Za potrebe mjerenja korišten je Keysight 34465A multimeter, opisan u prethodnom poglavlju. Navedeni uređaj omogućava razlučivost od $6\frac{1}{2}$ znamenki i maksimalnu brzinu očitavanja do 50000 očitavanja/s. U tehničkom listu [128] navedena je osnovna točnost istosmjernog napona od 30 dijelova na milijun (engl. *parts per million* - *ppm*). Za istosmjerno napajanje korišteno je programabilno višerazinsko GW Instek *PSB-1400L* napajanje, koje je prikazano na slici 5.1a. Napajanje omogućuje izlazni napon od 0 do 40 V i izlaznu struju od 0 do 40 A, s ukupnom izlaznom snagom od 400 W. Točnost mjerenja napona iznosi 0.1 %, a točnost mjerenja struje 0.1 %. Navedena je točnost potrebna prilikom izvođenja mjerenja i osiguravanja ponovljivih rezultata [129]. Dijagram korištenog mjernog postava nalazi se na slici 5.1b. Simbol ampermetra predstavlja Keysight multimeter, dok simbol istosmjernog izvora napona predstavlja istosmjerno napajanje GW Instek. Oznaka LDO predstavlja regulator napona s niskim padom napona (engl. *low-dropout regulator*).



(a)



(b)

Slika 5.1: Mjerni postav uključuje: GW INSTEK PSB-1400L izvor napajanja (a); dijagram mjernog postava (b).

Odabran je mikroupravljač ARM Cortex-M0+ ultra niske potrošnje, model STM32L0 [130]. Korišteno razvojno okruženje je STM32CubeIDE, koje omogućuje dinamičko generiranje kôda na temelju definiranog rasporeda pinova i konfiguracije. Ova značajka omogućuje primjenu frekvencijskih konfiguracija za DFS. Razvojno okruženje uključuje napredne mogućnosti otklanjanja pogrešaka (engl. *debugging*) s točkama prekida (engl. *breakpoints*), preglednim točkama (engl. *watchpoints*), praćenjem varijabli u stvarnom vremenu i alatom za analizu sustava koji su korišteni za implementaciju odabranih operacija i mjerenje vremena izvođenja [131].

5.1.2 Dinamičko skaliranje frekvencije

Dinamičko skaliranje frekvencije predstavlja adaptivnu tehniku koja omogućava povećanje energetske učinkovitosti, redukciju toplinskog utjecaja, optimizaciju izvedbe u dinamičkim okruženjima te smanjenje razine buke u računalnim sustavima visokih performansi. U ovome poglavlju koristi se za poboljšanje energetske učinkovitosti, što je moguće postići bez dodatnih promjena sklopovlja. Vrijednosti koje se promatraju u ovome poglavlju uključuju radnu frekvenciju, izmjerenu struju, fiksni radni napon od 3.3 V i vrijeme izvođenja za operacije FFT128, FFT32, CRC32, MD5 i SHA256.

FFT je prikazan s pseudokôdom u algoritmu 5.1, gdje se FFT128 i FFT32 odnose na uzorke veličine 128 i 32. FFT je učinkovit algoritam za izračun diskretne Fourierove transformacije, koji značajno smanjuje računalnu složenost s $O(N^2)$ na $O(N \log N)$ u slučaju kada je broj uzoraka potencija broja 2, što omogućuje brzu analizu frekvencijskog sadržaja diskretnih signala [132]. Hash vrijednost (engl. *hash*) je matematički izračunata vrijednost koja služi za sažimanje podataka u svrhu bržeg pretraživanja, usporedbe ili provjere integriteta [133]. CRC32 funkcija koja generira 32-bitnu hash vrijednost, prikazana je s pseudokôdom u algoritmu 5.2. CRC32 se koristi za detekciju pogrešaka u digitalnim podacima tako da ulazne podatke pretvara u binarni polinom, a zatim taj polinom dijeli s unaprijed definiranim generatorskim polinomom stupnja 32. Ostatak tog dijeljenja predstavlja 32-bitni hash podataka [134]. Široko korištena kriptografska funkcija MD5, prikazana je u algoritmu 5.3. MD5 prihvaća ulaz proizvoljne duljine i iz nje generira fiksnu 128-bitnu hash vrijednost, koja se najčešće koristi za provjeru integriteta podataka ili kao kontrolna suma [135]. Kriptografska funkcija SHA256 prikazana je u algoritmu 5.4. Algoritam prihvaća ulazne podatke proizvoljne duljine i za svaki ulaz izračunava jedinstvenu, fiksnu 256-bitnu hash vrijednost, pri čemu i najmanja promjena ulaza rezultira potpuno drugačijim hashom, što osigurava visoku razinu sigurnosti i integriteta podataka [136]. Ulazni podaci za algoritam 5.1 generirani su nasumično, a ulazni podaci za algoritme 5.2–5.4 predstavljaju niz abecednih slova s duljinom podataka od 26.

Algoritam 5.1 FFT funkcija za ulazne podatke veličine n (potencije broja 2).

```

1: procedura FFT(podaci,  $n$ )
2:   ako je  $n \leq 1$  tada
3:     vrați
4:   kraj ako je
5:    $parni[1 \dots n/2] \leftarrow$  novi niz kompleksnih brojeva
6:    $neparni[1 \dots n/2] \leftarrow$  novi niz kompleksnih brojeva
7:   za  $i = 0$  do  $n/2 - 1$  radi
8:      $parni[i] \leftarrow podaci[2 \cdot i]$ 
9:      $neparni[i] \leftarrow podaci[2 \cdot i + 1]$ 
10:  kraj za
11:  FFT(parni,  $n/2$ )
12:  FFT(neparni,  $n/2$ )
13:  za  $i = 0$  do  $n/2 - 1$  radi
14:     $kut \leftarrow -2 \cdot \pi \cdot i/n$ 
15:     $t \leftarrow \text{kompleksni}(\cos(kut), \sin(kut))$ 
16:     $t \leftarrow t \times neparni[i]$  ▷ Kompleksno množenje
17:     $podaci[i] \leftarrow parni[i] + t$ 
18:     $podaci[i + n/2] \leftarrow parni[i] - t$ 
19:  kraj za
20:  vrați podaci
21: kraj procedura

```

Algoritam 5.2 CRC32 funkcija za ulazne podatke veličine n

```

1: procedura CRC32(podaci,  $n$ )
2:    $crc \leftarrow 0xFFFFFFFF$  ▷ Inicijaliziraj CRC sa svim postavljenim bitovima
3:   za  $i = 0$  do  $n - 1$  radi
4:      $crc \leftarrow crc \oplus podaci[i]$  ▷ XOR CRC s trenutnim bajtom podataka
5:     za  $j = 0$  do 7 radi
6:       ako je  $crc \& 1$  tada
7:          $crc \leftarrow (crc \gg 1) \oplus CRC32\_POLY$  ▷ Obrada svakog bita
8:       inače
9:          $crc \leftarrow crc \gg 1$ 
10:      kraj ako je
11:    kraj za
12:  kraj za
13:  vrați  $crc \oplus 0xFFFFFFFF$  ▷ Konačni XOR za dobivanje komplementa
14: kraj procedura

```

Algoritam 5.3 MD5 funkcija za ulazne podatke veličine n

```

1: procedura MD5(podaci,  $n$ , rezultat)
2:   stanje  $\leftarrow$  [0x67452301, 0xEFCDAB89, 0x98BADCFE, 0x10325476]
3:                                      $\triangleright$  Inicijalizacija stanja
4:   spremnik[64]  $\leftarrow$  novi niz bajtova                                      $\triangleright$  Inicijalizacija spremnika
5:   bitovi  $\leftarrow$   $n \cdot 8$                                                   $\triangleright$  Izračun duljine u bitovima
6:   za  $i = 0$  do  $n - 1$  korak 64 radi
7:     duljina_bloka  $\leftarrow$  min(64,  $n - i$ )
8:     Postavi sve elemente u spremnik na 0
9:     Kopiraj duljina_bloka bajtova iz podaci[ $i$ ] u spremnik
10:    MD5_TRANSFORM(stanje, spremnik)
11:  kraj za
12:  spremnik[0]  $\leftarrow$  0x80                                                  $\triangleright$  Dodaj bit '1' na kraj poruke
13:  kopiraj bitovi u spremnik[56] do spremnik[63]
14:  MD5_TRANSFORM(stanje, spremnik)
15:  za  $j = 0$  do 3 radi
16:    rezultat[ $j \cdot 4 + 0$ ]  $\leftarrow$  (stanje[ $j$ ]  $\gg$  0) & 0xFF
17:    rezultat[ $j \cdot 4 + 1$ ]  $\leftarrow$  (stanje[ $j$ ]  $\gg$  8) & 0xFF
18:    rezultat[ $j \cdot 4 + 2$ ]  $\leftarrow$  (stanje[ $j$ ]  $\gg$  16) & 0xFF
19:    rezultat[ $j \cdot 4 + 3$ ]  $\leftarrow$  (stanje[ $j$ ]  $\gg$  24) & 0xFF
20:  kraj za
21:  vрати rezultat
22: kraj procedura

```

Algoritam 5.4 SHA256 funkcija za ulazne podatke veličine n

```

1: procedura SHA256(podaci,  $n$ , rezultat)
2:   stanje  $\leftarrow$  [0x6a09e667, 0xbb67ae85, 0x3c6ef372, 0xa54ff53a, 0x510e527f, 0x9b05688c,
3:   0x1f83d9ab, 0x5be0cd19]                                ▷ Inicijalizacija stanja
4:   spremnik[64]  $\leftarrow$  novi niz bajtova                    ▷ Inicijalizacija spremnika
5:   ukupno_bitova  $\leftarrow n \cdot 8$                             ▷ Izračun duljine u bitovima
6:   za  $i = 0$  do  $n - 1$  korak 64 radi
7:     duljina_bloka  $\leftarrow \min(64, n - i)$ 
8:     postavi sve elemente u spremnik na 0
9:     kopiraj duljina_bloka bajtova iz podaci[ $i$ ] u spremnik
10:    SHA256_TRANSFORM(stanje, spremnik)
11:  kraj za
12:  spremnik[0]  $\leftarrow$  0x80                                    ▷ Dodaj bit '1' na kraj poruke
13:  ako je  $n \bmod 64 < 56$  tada
14:    kopiraj ukupno_bitova u spremnik[56] do spremnik[63]
15:    SHA256_TRANSFORM(stanje, spremnik)
16:  inače
17:    kopiraj ukupno_bitova u spremnik[56] do spremnik[63]
18:    SHA256_TRANSFORM(stanje, spremnik)
19:    SHA256_TRANSFORM(stanje, spremnik + 64 - 8)
20:  kraj ako je
21:  za  $j = 0$  do 7 radi
22:    rezultat[ $j \cdot 4 + 0$ ]  $\leftarrow$  (stanje[ $j$ ]  $\gg$  24) & 0xFF
23:    rezultat[ $j \cdot 4 + 1$ ]  $\leftarrow$  (stanje[ $j$ ]  $\gg$  16) & 0xFF
24:    rezultat[ $j \cdot 4 + 2$ ]  $\leftarrow$  (stanje[ $j$ ]  $\gg$  8) & 0xFF
25:    rezultat[ $j \cdot 4 + 3$ ]  $\leftarrow$  stanje[ $j$ ] & 0xFF
26:  kraj za
27:  vрати rezultat
28: kraj procedura

```

Tablica 5.1 pokazuje da se vrijeme izvođenja značajno smanjuje s višom radnom frekvencijom. Izvođenje operacija poput FFT-a pri nižim radnim frekvencijama ne zadovoljava kriterije rada u stvarnom vremenu, što ih čini neprimjenjivima u aplikacijama koje to zahtijevaju. Primjerice, ukoliko sustav obavlja FFT funkciju nakon detekcije udara, vrijeme izvođenja FFT funkcije utječe na rad sustava. Ukoliko sustav radi na frekvenciji od 131 kHz, vrijeme izvođenja FFT32 funkcije iznosi 10868.02 ms $\approx$ 11 sekundi, što nije prihvatljivo. Dugo vrijeme izvođenja može rezultirati propuštanjem novih udara koji se mogu dogoditi u tom vremenskom periodu, čime se gubi mogućnost pravovremene detekcije svih događaja.

Tablica 5.1: Prosječne vrijednosti od 100 mjerenja električne struje i vremena izvođenja pojedinih algoritama u ovisnosti o ulaznim vrijednostima frekvencije pri fiksnom naponu (DFS).

f [kHz]	U_{DFS} [V]	I_{DFS} [mA]	t_{FFT128} [ms]	t_{FFT32} [ms]	t_{CRC32} [ms]	t_{MD5} [ms]	t_{SHA256} [ms]
131	3.30	0.06056	68971.02	10868.02	85.34	72.51	645.00
262	3.30	0.09104	23956.00	3774.00	29.67	25.23	224.50
524	3.30	0.15177	10391.98	1637.16	12.88	10.94	97.43
1048	3.30	0.27323	4873.25	767.71	6.04	5.13	45.68
2097	3.30	0.51297	2362.00	372.11	2.93	2.49	22.15
4194	3.30	0.99585	1163.52	183.29	1.44	1.23	10.91
8000	3.30	2.07838	605.70	95.42	0.75	0.64	5.68
16000	3.30	3.73185	301.69	47.52	0.37	0.32	2.83


S izmjerenom strujom, naponom i vremenom izvođenja moguće je izračunati potrošnju električne energije za pojedinu operaciju, prema jednadžbi (5.1). *ALG* predstavlja testirani algoritam (FFT128, FFT32, CRC32, MD5 i SHA256). Vrijednosti izmjerene i prikazane u tablici 5.1 predstavljaju prosječne vrijednosti dobivene iz 100 mjerenja za struju, napon i vrijeme izvođenja, kako bi se minimizirale moguće pogreške u mjerenju. Izračunata potrošnja energije po operaciji prikazana je u tablici 5.2. Na najvišoj radnoj frekvenciji od 16000 *kHz* izmjerena je najveća vrijednost struje. Unatoč tome, dolazi do niže potrošnje energije po operaciji zbog drastičnog smanjenja vremena izvođenja. Prema dobivenim rezultatima, moguće je zaključiti da niža frekvencija smanjuje potrošnju struje, ali kraće vrijeme izvođenja pri višim frekvencijama rezultira manjom ukupnom potrošnjom energije.

$$E_{ALG} = U_{DFS(ALG)} \cdot I_{DFS(ALG)} \cdot t_{ALG} [\mu W s] \quad (5.1)$$

Pri interpretaciji rezultata u tablici 5.2 primjetna je anomalija. Potrošnja energije pri frekvenciji od 8000 *kHz* je viša od očekivane, što je vidljivo i na slici 5.2. Uzrok tome nalazi se u načinu konfiguracije mikroupravljača. U ovom slučaju koristi se fazno zaključana petlja (engl. *Phase Locked Loops* - *PLL*) kako bi se postigla frekvencija od 8000 *kHz*. Stoga, povećana potrošnja energije uzrokovana je radom PLL-a.

Tablica 5.2: Izračunata potrošnja električne energije uz dinamičko skaliranje frekvencije, na temelju tablice 5.1 (podebljane vrijednosti označavaju minimalnu izmjerenu potrošnju).

f [kHz]	E_{FFT128} [μWs]	E_{FFT32} [μWs]	E_{CRC32} [μWs]	E_{MD5} [μWs]	E_{SHA256} [μWs]
131	13783.40	2171.90	17.05	14.49	128.90
262	7197.41	1133.87	8.91	7.58	67.45
524	5204.66	819.95	6.45	5.48	48.80
1048	4393.95	692.20	5.45	4.63	41.19
2097	3998.36	629.90	4.96	4.21	37.49
4194	3823.68	602.35	4.74	4.03	35.85
8000	4154.29	654.45	5.15	4.38	38.95
16000	3715.34	585.21	4.61	3.92	34.83



Slika 5.2: Graf potrošnje energije s primijenjenim DFS-om za operaciju: E_{FFT128} (a); E_{FFT32} (b); E_{CRC32} (c); E_{MD5} (d); E_{SHA256} (e).


5.1.3 Dinamičko skaliranje napona i frekvencije

Za dodatnu uštedu energije, dinamičko skaliranje napona (DVS) integrirano je s dinamičkim skaliranjem frekvencije (DFS). Dinamičko skaliranje napona i frekvencije (DVFS) predstavlja tehniku koja značajno produžuje vijek trajanja baterije u prijenosnim uređajima te minimizira potrošnju energije u podatkovnim centrima [89, 137]. Kada maksimalne performanse nisu potrebne, skaliranje napona može značajno smanjiti potrošnju energije bez utjecaja na funkcionalnost. Skaliranje napona i frekvencije učinkoviti su načini za balansiranje performansi i energetske učinkovitosti u različitim vrstama računalnih sustava. Potrebno je napraviti izračun naponskih razina, s obzirom na to da nedovoljna razina radnog napona može negativno utjecati na upotrebljivost i stabilnost rada mikroupravljača ili mikroprocesora. Formula za izračun vrijednosti napona je:

$$U_{DVFS}(f) = A \cdot e^{f/B} [V], \quad (5.2)$$

gdje su $A = 1.791011$ i $B = 26.1804846$. $U_{DVFS}(f)$ se izračunava na temelju odabranih vrijednosti napajanja mikroupravljača i odgovarajućih frekvencija. Prema tehničkim specifikacijama mikroupravljača [130], najniža vrijednost napajanja je $1.8 V$ za frekvenciju od $0.131 MHz$. Za frekvenciju od $16 MHz$, odgovarajuća vrijednost napajanja je $3.3 V$. Postavljene su dvije točke, $T1(0.131, 1.8)$ i $T2(16, 3.3)$ za koje se radi regresijska krivulja. Regresija se koristi za izračun eksponencijalne funkcije $U_{DVFS}(f)$ u jednadžbi (5.2), na temelju točaka $T1$ i $T2$. Analiza regresije provedena je korištenjem Microsoft Excel 2019, koji omogućuje izvođenje linearnih i nelinearnih regresijskih modela putem ugrađenih funkcija i alata. Os f odnosi se na radnu frekvenciju u MHz, a os $U_{DVFS}(f)$ predstavlja odgovarajuću vrijednost napona u voltima, kao što je prikazano na slici 5.3. Umetanjem vrijednosti frekvencije iz tablice 5.1 u jednadžbu (5.2), mogu se izračunati odgovarajuće razine napona za svaku frekvenciju. Izračunate razine napona prikazane su u tablici 5.3, a označene su s U_{DVFS} . Ove vrijednosti predstavljaju ciljane napone DC–DC pretvarača tijekom rada.


Za implementaciju dinamičkog skaliranja napona potrebno je procijeniti učinkovitost predloženog rješenja. U slučaju nedovoljne učinkovitosti DC–DC pretvarača, njegova primjena može biti nepotrebna, jer može povećati troškove proizvodnje bez ostvarivanja očekivanih ušteda u potrošnji energije. Stoga je visoka razina učinkovitosti preduvjet za implementaciju DVS-a. Učinkovitost DC–DC pretvarača, posebno u kontekstu linearnih pretvarača, značajno se povećala s napretkom tehnologije. Uvođenjem napajanja s impulsnim načinom rada sredinom 1970-ih, učinkovitost DC–DC pretvorbe značajno se poboljšala, s 60 % na 80 % [138]. S ciljem visoke učinkovitosti u cijelom rasponu napona, moderni DC–DC pretvarači koriste adaptivne mehanizme upravljanja. Takvi sustavi prilagođavaju radne parametre u stvarnom vremenu kako bi zadovoljili dinamičke zahtjeve za rad DVS-a. DVS može smanjiti učinkovitost DC-DC pretvarača, stoga optimizacija potrošnje energije u različitim elektroničkim uređajima ovisi o odnosu između DVS-a i učinkovitosti DC–DC pretvarača.



Slika 5.3: Eksponencijalni model za izračun stabilnog napona (crveni krugovi označavaju točke $T1$ i $T2$).

Tablica 5.3 prikazuje rezultate potrošnje energije po operaciji, s primijenjenim DVFS-om. Pri frekvenciji od 2097 kHz postignuta je optimalna točka za potrošnju energije po operaciji. Fokus energetske optimizacije je pronalazak optimalne točke za zadanu operaciju. Za postizanje svojstava ultra niske potrošnje za potrebe sustava koji je korišten u ovome poglavlju, preporučuje se primijeniti radni napon od 1.94 V i radnu frekvenciju od 2097 kHz . Vremena izvođenja operacija za DFS prikazanih u tablici 5.1 se ne mijenjaju u odnosu na DVFS, s obzirom da se radi o istim radnim frekvencijama. Slika 5.4 prikazuje usporedbu potrošnje energije između DFS-a i DVFS-a za odabrane operacije. Smanjenje napona značajno utječe na potrošnju energije. Vrijednosti za frekvenciju od 16000 kHz nisu prikazane na slici, jer u ovom slučaju nema razlike u naponu između DFS-a i DVFS-a. U nastavku je prikazan izračun postotka smanjenja energije (engl. *Energy Reduction* - *ER*), koji služi kao mjera za usporedbu smanjenja potrošnje energije između DFS-a i DVFS-a. Formula za izračun prikazana je u jednadžbi (5.3). Na temelju navedene formule izračunate su vrijednosti u tablici 5.4. Iz tablice 5.4 vidljivo je smanjenje potrošnje energije od 27.74% do 47.74% s korištenjem DVFS-a u odnosu na vrijednosti koje su dobivene korištenjem DFS-a. Najveće uštede energije prisutne su pri nižim radnim frekvencijama.

$$ER_{ALG} = \left(\frac{E_{ALG}^{DFS} - E_{ALG}^{DVFS}}{E_{ALG}^{DFS}} \right) \cdot 100 [\%] \quad (5.3)$$



Slika 5.4: Usporedba DVFS-a i DFS-a. Graf potrošnje energije za operaciju: E_{FFT128} (a); E_{FFT32} (b); E_{CRC32} (c); E_{MD5} (d); E_{SHA256} (e).

Tablica 5.3: Izračunata potrošnja električne energije uz dinamičko skaliranje napona i frekvencije (podebljane vrijednosti označavaju minimalnu izmjerenu potrošnju).

f [kHz]	U_{DVFS} [V]	I_{DVFS} [mA]	E_{FFT128} [μWs]	E_{FFT32} [μWs]	E_{CRC32} [μWs]	E_{MD5} [μWs]	E_{SHA256} [μWs]
131	1.80	0.05970	7411.90	1167.92	9.17	7.79	69.31
262	1.81	0.08679	3761.05	592.51	4.66	3.96	35.25
524	1.83	0.14471	2747.86	432.90	3.41	2.89	25.76
1048	1.86	0.26162	2376.75	374.42	2.95	2.50	22.28
2097	1.94	0.49866	2285.48	360.06	2.83	2.41	21.43
4194	2.10	0.97246	2378.58	374.70	2.95	2.51	22.30
8000	2.43	2.03865	3001.95	472.92	3.72	3.16	28.15
16000	3.30	3.73185	3715.34	585.21	4.61	3.92	34.83

Tablica 5.4: Izračunati postotak smanjenja potrošnje energije za DFS u odnosu na DVFS.

f [kHz]	ER_{FFT128} [%]	ER_{FFT32} [%]	ER_{CRC32} [%]	ER_{MD5} [%]	ER_{SHA256} [%]
131	46.23	46.23	46.23	46.23	46.23
262	47.74	47.74	47.74	47.74	47.74
524	47.20	47.20	47.20	47.20	47.20
1048	45.91	45.91	45.91	45.91	45.91
2097	42.84	42.84	42.84	42.84	42.84
4194	37.79	37.79	37.79	37.79	37.79
8000	27.74	27.74	27.74	27.74	27.74

5.1.4 Dizajn energetski optimiziranih ugradbenih sustava

Dizajniranje energetski optimiziranih ugradbenih sustava obuhvaća integraciju sklopovlja i programske podrške s ciljem razvoja učinkovitih i održivih rješenja. Ključni aspekt za realizaciju energetski optimiziranog sustava je PPW analiza, gdje se nastoji zadovoljiti zahtjeve za performansama uz minimalizaciju potrošnje energije. PPW vrijednosti prikazane su u tablici 5.5, a izvedene su iz radne frekvencije, izmjerene struje i napona te potvrđuje rezultate dobivene u tablici 5.3. Iz perspektive razvoja programske podrške, algoritam 5.5 omogućuje individualni pristup u prema vrsti opterećenja. U predloženoj algoritmu, *Operacija1* predstavlja vremenski kritično opterećenje, gdje se odabire način rada visokih performansi.

Tablica 5.5: Izračunate PPW vrijednosti za energetski optimiziran sustav (veći iznos je bolji).

f [kHz]	U _{DVFS} [V]	I _{DVFS} [mA]	PPW[kHz/mW]
131	1.80	0.05970	1219.683
262	1.81	0.08679	1669.726
524	1.83	0.14471	1982.774
1048	1.86	0.26162	2148.801
2097	1.94	0.49866	2167.205
4194	2.10	0.97246	2051.563
8000	2.43	2.03865	1614.152
16000	3.30	3.73185	1299.218

Operacija2 je primjer opterećenja koje nema zahtjeve za radom u stvarnom vremenu. Tada je moguće izvođenje u načinu rada za uštedu energije. *Operacija3* je primjer opterećenja s fleksibilnim rokom izvođenja, gdje je cilj obaviti zadatak uz najmanju moguću potrošnju energije. Varijabla *uvjet_operacije* može postati *zadovoljen* u slučaju internih uvjeta ili pojave vanjskog događaja. U svim ostalim slučajevima postavljene su zadane postavke za uštedu energije, sve dok ne dođe do pojave određenih uvjeta opterećenja.

Algoritam 5.5 Programski pristup za dinamičko prilagođavanje frekvencije prema zahtjevima operacija

```

1: procedura DINAMIČKO_SKALIRANJE
2:   Inicijalizacija HAL-a
3:   Konfiguracija takta ← Zadana (postavka za uštedu energije)
4:   Inicijalizacija ulazno/izlaznih pinova
5:   Inicijalizacija privatnih varijabli
6:   dok istina radi
7:     ako je uvjet_operacije1 zadovoljen tada
8:       Početak Operacije1 ← odaberi način rada (Visoke performanse)
9:       Izvođenje Operacije1
10:      Kraj Operacije1 ← odaberi način rada (Ušteda energije)
11:     kraj ako je
12:     ako je uvjet_operacije2 zadovoljen tada
13:       Početak Operacije2
14:       Izvođenje Operacije2           ▷ Izvodi se u načinu rada za uštedu energije
15:       Kraj Operacije2
16:     kraj ako je
17:     ako je uvjet_operacije3 zadovoljen tada
18:       Početak Operacije3 ← odaberi način rada (Energetski učinkovit način)
19:       Izvođenje Operacije3
20:       Kraj Operacije3 ← odaberi način rada (Ušteda energije)
21:     kraj ako je
22:   kraj dok
23: kraj procedura
    
```

Pravilno podešavanje napona i frekvencije dodatno smanjuje potrošnju energije pri izvođenju zadanih operacija u ugradbenom sustavu. Unatoč tome, učinkovitost ovog pristupa ovisi o vremenskim ograničenjima sustava, pri čemu strogi vremenski zahtjevi mogu ograničiti mogućnost primjene. Prijelaz iz načina uštede energije u način visokih performansi rezultira kašnjenjem u izvedbi koje uzrokuje pogreške kod operacija sa strogim vremenskim ograničenjima. Za integraciju dinamičkog skaliranja napona potrebno je integrirati DC–DC pretvarač, uz uvjet dostatne učinkovitosti. Gubici DC–DC pretvarača moraju biti znatno manji od uštede energije dinamičkim skaliranjem napona. U suprotnom, dodatni troškovi komponenata i razvoja ne donose dovoljnu korist. U tom slučaju, preporučljivo je pronaći i odabrati fiksnu optimalnu točku s najvišom PPW vrijednošću odnosno s najvišim performansama po wattu (tablica 5.5). Korištene metode dinamičkog skaliranja frekvencije i dinamičkog skaliranja napona omogućuju svojstva ultra niske potrošnje ugradbenih sustava. Razvijena metoda za ultra nisku potrošnju energije djeluje na najnižoj frekvenciji kada su zahtjevi za računalnu snagu niski, dok se pri većim zahtjevima dinamički skalira do optimalnih razina radi postizanja maksimalne učinkovitosti. S ovim pristupom, sustav se može automatski prilagoditi razinama energije u stvarnom vremenu prema zahtjevima opterećenja. Korištenje DFS-a dovodi do poboljšanja u pogledu potrošnje energije u usporedbi s fiksnom radnom frekvencijom i postavljenom programskom konfiguracijom. Rezultati pokazuju da uvođenje DVS-a u kombinaciji s DFS-om može smanjiti potrošnju energije od 27.74 % do 47.74 %. Rezultati analize performansi po wattu prikazuju optimalnu radnu točku, koja ima ključnu funkciju prilikom dizajniranja sustava ultra niske potrošnje energije. Kada je potrebna računalna snaga, optimalno je podići frekvenciju na maksimum (u ovom slučaju, 16000 kHz), obaviti zadanu operaciju, i nakon toga postaviti zadanu radnu frekvenciju. Kada računalna snaga nije potrebna i sustav čeka na određeni događaj, npr. unos od korisnika, promjenu stanja sustava ili vremenski događaj, najučinkovitiji način za očuvanje energije u zadanom vremenskom okviru je rad sustava na najnižoj frekvenciji (u ovom slučaju, 131 kHz). Sustav također može biti u stanju mirovanja na minimalnoj frekvenciji kada računalna snaga nije potrebna, nakon čega se po potrebi može povećati na optimalnu radnu vrijednost (u ovom slučaju, 2097 kHz) radi učinkovitijeg korištenja energije. Za energetski optimiziran sustav potrebno je identificirati optimalnu ravnotežu između performansi i potrošnje energije.

5.2 Analiza potrošnje energije SPI i I2C komunikacijskih protokola u ugradbenim sustavima ultra niske potrošnje energije

Kod razvoja ugradbenih sustava s ultra niskom potrošnjom, energetska učinkovitost i operativno vrijeme postaju ključni razvojni parametri koji određuju funkcionalnost i dugotrajnost sustava. Ukupna potrošnja energije ovisi i o izboru korištenih komunikacijskih protokola. U ovome poglavlju izvršena je detaljna usporedba i analiza potrošnje energije komunikacijskih protokola I2C i SPI, koji se široko primjenjuju u ugradbenim sustavima. Navedeni komunikacijski protokoli koriste se u suvremenim ugradbenim sustavima za komunikaciju s perifernim uređajima na niskim ili srednjim brzinama prijenosa podataka. Autori u [139] raspravljaju o različitim parametrima koje je potrebno uzeti u obzir prilikom odabira protokola, uključujući značajke, prednosti, nedostatke, broj uređaja, brzinu prijenosa podataka i potrošnju energije. I2C je serijski komunikacijski protokol kojeg je izumio Philips labs, a omogućuje povezivanje više uređaja na jednu sabirnicu, pri čemu jedan uređaj djeluje kao upravljač (engl. *controller*), a ostali kao ciljevi (engl. *target*). I2C protokol se primjenjuje za uređaje koji imaju niske zahtjeve brzine prijenosa. Primjeri uređaja koji koriste ovaj protokol uključuju mikroupravljače, senzore, aktuatorske sklopove, satove stvarnog vremena, uređaje za praćenje, upravljače napajanjem te različite vrste memorijskih modula. Cilj primjene I2C protokola je omogućavanje komunikacije između navedenih uređaja. I2C omogućuje povezivanje do 128 uređaja na jednu sabirnicu te podržava brzine komunikacije do 3.4 *Mbps* [140]. SPI je sinkroni serijski komunikacijski protokol koji je razvila Motorola, a omogućuje povezivanje nekoliko uređaja na jednu sabirnicu, pri čemu jedan uređaj djeluje kao upravljač (engl. *controller*), a ostali kao ciljevi (engl. *target*). U ugradbenim sustavima, SPI protokol se koristi za komunikaciju između uređaja koji zahtijevaju visoke brzine prijenosa podataka perifernih uređaja. Tipični uređaji koji koriste ovaj protokol uključuju mikroupravljače, kamere, zaslone i ekrane, kontrolne uređaje, bežične komunikacijske module te memorijske kartice ili uređaje za pohranu podataka. SPI podržava brzine komunikacije do 60 *Mbps*. Iako broj ciljanih uređaja na sabirnici može varirati od jednog do nekoliko stotina, uobičajeno je da broj ciljanih uređaja bude ograničen na manji broj, s obzirom na ograničenja upravljača [141]. Specijalizirane implementacije sklopovlja omogućavaju povezivanje brojnih uređaja, gdje svaki uređaj zahtjeva svoj specifičan pin za odabir ciljanog uređaja. Broj dostupnih ulazno/izlaznih (I/O) pinova na mikroupravljaču ili mikroprocesoru ograničava broj uređaja koji se mogu povezati. Ograničenje broja I/O pinova može se zaobići primjenom dodatnog sklopovlja, primjerice I/O ekspanzera ili multipleksera. Karakteristike navedenih protokola nalaze se u tablici 5.6.

Tablica 5.6: Proširena usporedba karakteristika I2C i SPI komunikacijskih protokola

Karakteristika	I2C	SPI
Broj linija	2 (SDA, SCL)	4 (MISO, MOSI, SCK, CS)
Brzina prijenosa	Do 3.4 Mbps	Do 60 Mbps
Tip prijenosa	Polu-dvosmjerna	Potpuno-dvosmjerna
Adresiranje	Potrebno, podržava do 128 uređaja	Nije potrebno
Kompleksnost implementacije	Jednostavnija, ne zahtijeva dodatno sklopovlje	Složenija zbog dodatnih linija i potreba za CS linijama
Povezivanje više uređaja	Podrška za više uređaja na istoj sabirnici	Podrška za više uređaja, svaki s vlastitom CS linijom
Pouzdanost	Kontrola protoka i rukovanje greškama	Potreban dodatni sklop ili algoritam za detekciju grešaka
Napajanje	5 V, 3.3 V i 1.8 V	5 V, 3.3 V te 2.5 V i 1.8 V kod novih uređaja
Topologija sabirnice	Sabirnica s jednim master uređajem i više slave uređaja	Komunikacija od točke do točke sa zasebnim CS linijama za svaki uređaj
Kontrola sinkronizacije	Sinkronizacija preko zajedničkog takta (SCL linija)	Sinkronizacija preko takta kontrolera (SCK linija)
Otpornost na šum	Manje otporan na smetnje zbog zajedničke sabirnice	Više otporan na smetnje zbog zasebnih linija
Pogodnost za velike udaljenosti	Nije prikladan za velike udaljenosti	Ograničen na kratke udaljenosti, ali može raditi s pojačivačima
Tipične primjene	Senzori, RTC moduli, EEPROM-ovi	SD kartice, DAC/ADC moduli, zasloni
Proširivost	Jednostavno dodavanje uređaja pomoću adresa	Svaki novi uređaj zahtijeva dodatnu CS liniju

I2C protokol je namijenjen povezivanju uređaja s manjim zahtjevima za brzinom prijenosa podataka, dok se SPI protokol koristi kada su potrebne veće brzine prijenosa. I2C karakterizira jednostavnost, manja složenost i niža brzina u usporedbi sa SPI protokolom, koji je složeniji, sofisticiraniji i brži. S obzirom da su oba protokola primjenjiva u perifernoj komunikaciji, prilikom dizajna ugradbenih sustava ultra niske potrebno je razmotriti potrošnju energije prilikom implementacije. U nastavku je analizirana potrošnje energije I2C i SPI komunikacijskih protokola prilikom izvođenja operacija. Operacije koje se izvode su zapisivanje i čitanje registara. Operacije se mogu izvesti korištenjem mikroupravljača koji je povezan na ciljni uređaj, uz uvjet da ciljni uređaj podržava oba komunikacijska protokola, kako bi usporedba bila moguća.


5.2.1 Eksperimentalni postav

Eksperimentalni postav uključuje dvije konfiguracije sklopovlja:

- mikroupravljač povezan s I2C uređajima (slika 5.5a)
- mikroupravljač povezan sa SPI uređajima (slika 5.5b)

I2C konfiguracija koristi dva povlačna otpornika (engl. *pull-up*), čija vrijednost otpora utječe na rezultate potrošnje energije. S nižim vrijednostima otpora, potrošnja energije pri komunikaciji se povećava. Potrebno je odabrati vrijednost otpora koja rezultira pouzdanim integritetom signala I2C komunikacije. Smanjenje otpora pull-up otpornika omogućava veću brzinu prijenosa podataka, uz napomenu da preniska otpornost može negativno utjecati na kvalitetu signala te oštetiti uređaje na sabirnici. Analizom tehničkih specifikacija uređaja spojenih na sabirnicu moguće je precizno odrediti optimalne vrijednosti pull-up otpornika. Prilikom mjerenja, na SPI ili I2C sabirnicu povezan je jedan uređaj. Karakteristike korištenog mjernog postava nalaze se u tablici 5.7. Autori u [123] predlažu korištenje pull-up otpornika s vrijednosti otpora od $47\text{ k}\Omega$ za I2C, kako bi se postiglo energetski najučinkovitije rješenje. Pravilno dimenzioniranje pull-up otpornika pridonosi optimizaciji potrošnje energije u fazi projektiranja sklopovlja.

Pin za odabir sklopa (engl. *Chip Select - CS*) mikroupravljača postavljen je u potisno-povlačni (engl. *push-pull*) način rada. U sustavima gdje postoji mogućnost da pinovi završe u neodređenom stanju, preporučuje se upotreba pull-up otpornika na linijama za odabir sklopa. Potrošnja energije za I2C i SPI protokole ovisi o nekoliko čimbenika, uključujući frekvenciju takta, razinu napona i detalje implementacije. Stvarna potrošnja energije može varirati ovisno o specifičnoj primjeni, načinu upotrebe te zahtjevima za brzinom prijenosa. Stoga je potrebno analizirati tehničke specifikacije korištenih uređaja kako bi se precizno odredila potrošnja energije sučelja. Mjerenja struje provedena su korištenjem prethodno navedenog digitalnog multimetra Keysight 34465A, koji pruža visoku razinu preciznosti, brzinu mjerenja i razlučivost. Model mikroupravljača, frekvencija takta i senzor koji se koristi kao ciljni uređaj prikazani su u tablici 5.7.



Slika 5.5: Dijagram konfiguracije I2C-a (a) i dijagram konfiguracije SPI-a (b).

Tablica 5.7: Karakteristike mjernog postava.

Karakteristika	Vrijednost
Mikroupravljač	<i>STM32L010K4T6</i>
I2C/SPI uređaj	<i>LPS22HBTR</i>
Vrsta uređaja	<i>MEMS senzor tlaka</i>
Radna frekvencija MCU [KHz]	1048
Radni napon [V]	3.3
Vrijednosti I2C pull-up otpornika [$k\Omega$]	47
Duljina korištene žice [cm]	15
Polarnost SPI takta (CPOL)	<i>Visoka</i>
Faza SPI takta (CPHA)	<i>Drugi brid</i>
Izvor napajanja	<i>GW Instek PSB – 1400L</i>
Mjerni multimetar	<i>Keysight 34465A</i>

5.2.2 Potrošnja energije tijekom SPI i I2C komunikacije

S obzirom na razlike u načinu rada, brzina prijenosa kod I2C protokola najčešće se izražava u kilohercima (kHz), dok se kod SPI protokola koristi jedinica kilobita u sekundi ($kbit/s$). Tablica 5.8 prikazuje potrošnju struje tijekom SPI komunikacije s registrima uređaja. Rezultati pokazuju da operacija čitanja troši manje energije u odnosu na operaciju pisanja. Za operaciju čitanja, upravljač šalje zahtjev za podatke, a ciljni uređaj vraća tražene podatke putem MISO (engl. *Master In Slave Out*) linije. Kod operacije pisanja, upravljač šalje adresu registra i podatke koji će biti upisani u registar, što povećava potrošnju energije. Tablica 5.9 prikazuje potrošnju struje tijekom I2C komunikacije s registrima uređaja. Rezultati provedenih mjerenja ukazuju na to da I2C sabirnica ima veću potrošnju energije tijekom aktivnog prijenosa podataka u odnosu na stanje mirovanja. Na I2C sabirnici potrošnja energije raste kada se podatkovni signal (SDA) nalazi na niskoj logičkoj razini, što


Tablica 5.8: Potrošnja struje tijekom SPI komunikacije s registrima uređaja.

Brzina komunikacije [Kbit/s]	Potrošnja struje za čitanje [μA]	Potrošnja struje za pisanje [μA]
neaktivno	458.92	458.92
4,093	269.57	606.45
8,187	270.07	686.12
16,375	271.44	867.54
32,75	273.59	1124.30
65,5	274.02	1231.91
131	275.26	1001.59

Tablica 5.9: Potrošnja struje tijekom I2C komunikacije s registrima uređaja.

Brzina komunikacije [Kbit/s]	Potrošnja struje za čitanje [μA]	Potrošnja struje za pisanje [μA]
neaktivno	270.05	270.05
4	523.49	539.17
8	505.96	519.05
16	475.77	486.67
32	441.18	456.16
65	403.80	417.72
131	376.97	404.45

je karakteristično za prijenos i primanje podataka. Razlike u konfiguraciji prikazane su na slici 5.6, gdje push-pull konfiguracija odgovara SPI protokolu, a pull-up konfiguracija I2C protokolu. Vremenski raspored komunikacije na I2C sabirnici određuje se generiranjem i održavanjem signala sata (engl. *clock*) na SCL liniji, čime se sinkronizira prijenos podataka između svih uređaja. Budući da frekvencija signala sata izravno određuje brzinu prijenosa, ona se za I2C izražava u kilohercima (kHz). SPI je također sinkroni serijski komunikacijski protokol, ali je dizajniran za rad pri većim brzinama u usporedbi s I2C-om. Svojstvo dvosmjernе komunikacije SPI protokola omogućuje istovremeni prijenos podataka. Operacije čitanja i pisanja ne zahtijevaju jednak broj ciklusa signala sata, pa se zbog toga brzina prijenosa za SPI izražava u kbit/s . Prema mjerenjima potrošnje struje SPI komunikacije, rezultati su pokazali da čitanje podataka troši manje energije u odnosu na pisanje podataka. Kod operacije čitanja, upravljač šalje zahtjev za podacima, a ciljni uređaj vraća tražene podatke putem MISO linije. Kod operacije pisanja, upravljač istovremeno šalje adresu registra i podatke koji se upisuju u odabrani registar. Budući da ciljni uređaj mora zapisati primljene podatke u registar, potrošnja energije za operaciju pisanja raste. Prema tome



Slika 5.6: Push-pull (a) i pull-up (b) konfiguracije.

operacija čitanja rezultira manjom potrošnjom energije u odnosu na operaciju pisanja. U procesu dizajniranja ugradbenih sustava koji koriste ultra nisku potrošnju energije, preporuča se minimizacija potrošnje energije svih integriranih perifernih uređaja. Provedena je analiza potrošnje energije za SPI i I2C komunikacijske protokole, pri čemu su korištene brzine komunikacije do 100 kHz . Na temelju rezultata, u tablici 5.10 nalazi se preporučeni odabir komunikacijskog protokola za specifične scenarije rada sustava. Iz tablice se može zaključiti da ne postoji situacija u kojoj jedan protokol uvijek daje bolje rezultate od drugog. Koji će protokol biti pogodniji zavisi o intenzitetu korištenja sabirnice, kao i o tome da li se češće izvode operacije čitanja ili pisanja. Na primjer, čitanje podataka sa senzora zahtijeva isključivo operacije čitanja, dok upisivanje podataka u memoriju podrazumijeva isključivo operacije pisanja. Prilikom dizajna energetski učinkovitog sustava, odabir komunikacijskog protokola treba uskladiti s uvjetima rada. Odabir komunikacijskog protokola jedan je od čimbenika koji utječe na ukupnu potrošnju energije sustava.

Tablica 5.10: Pregled prikladnosti komunikacijskih protokola i sabirnica

Scenarij	Stanje sabirnice	Prikladan protokol
Komunikacija se odvija povremeno, a komunikacijska linija većinu vremena provodi u stanju mirovanja	Mirovanje	I2C
Kontinuirano dohvaćanje podataka (npr. mjerenja sa senzora) bez čestih upisa u registre	Kontinuirano slanje	SPI
Prisutnost elektromagnetskih smetnji	Kontinuirano slanje	SPI
Komunikacija je uravnotežena, broj operacija čitanja i pisanja registra je podjednak	50% vremena aktivno	I2C
Applikacija s većim brojem ciljnih uređaja, kod I2C protokola raste potrošnja energije zbog potrebe za smanjenjem otpora pull-up otpornika	50% vremena aktivno	SPI

6

Zaključak

Sustavno praćenje uvjeta u lancu opskrbe zahtjeva razvoj metoda za detekciju traženih parametara uz istovremenu implementaciju metoda ultra niske potrošnje energije. Za ostvarenje traženih doprinosa u sklopu ove doktorske disertacije, razvijen je sustav Pametna naljepnica. Sustav je korišten za implementaciju predloženih metoda, omogućuje praćenje uvjeta tijekom skladištenja i transporta, detekciju udara i vibracija te procjenu vjerojatnosti oštećenja paketa. Metode za detekciju udara i procjenu kuta sudara baziraju se na mjerenim vrijednostima senzora ubrzanja. Primijenjen je pristup ultra niske potrošnje energije s ciljem produljenja operativnog vijeka sustava te povećanja pouzdanosti tijekom kontinuiranog praćenja uvjeta skladištenja i transporta. Napredni sustavi i komponente otvaraju mogućnosti za daljnja istraživanja u primjeni energetske učinkovitih metoda u različitim industrijskim aplikacijama, posebno u sektorima gdje je kontinuitet praćenja ključan za održavanje kvalitete proizvoda i za smanjenje rizika oštećenja tijekom transporta.

6.1 Zaključci

Predložene metode u sklopu ove doktorske disertacije validirane su u laboratorijskim uvjetima. Analizirane su mjerene vrijednosti detektiranih udara tijekom skladištenja i transporta. Maksimalna vrijednost ubrzanja M_p i M_{RMS} vrijednost detektiranog vrha M_p predstavljaju mjerljive indikatore intenziteta udara. Provedeno je nekoliko eksperimenata sa svrhom ispitivanja učinkovitosti rada metode za detekciju udara i procjene kuta sudara paketa. Rezultati prikazuju mjerenja pada paketa s različitih visina uz različite frekvencije uzorkovanja. Funk-

cionalnost metoda eksperimentalno je provjerena i na komercijalnom paketu, pri čemu je uređaj bio integriran na paket proizvoda unutar pakiranja. Provedeno je i eksperimentalno ispitivanje udara kroz kontrolirano ispuštanje standardizirane mase na paket s različitim visinama. Validacija sustava u realnim uvjetima ostvarena je slanjem paketa na putovanje od 1600 *km* putem komercijalne dostavne službe, gdje je sustav bio integriran unutar paketa. Provedeni eksperimenti pokazuju da je potrebna minimalna frekvencija uzorkovanja od 800 Hz za pravilnu detekciju udaraca. Kada je sustav integriran unutar paketa, mjerenja pokazuju niže maksimalne vrijednosti udara nego kada je sustav postavljen izvan paketa. Pravilnom upotrebom zaštitnog sloja na paketu, poput kartona i zaštitne pjene, povećava se otpornost paketa na udarce. Uočljivo je da vertikalni pad paketa pokazuje veće maksimalne vrijednosti udaraca nego horizontalni pad, što je posljedica znatno manje kontaktne površine pri udaru kod vertikalnog pada. U eksperimentu slanja paketa lokalnom dostavnom službom, zabilježena su dva udarca visokog intenziteta koja bi rezultirala oštećenjem proizvoda. Budući da sustav koristi bateriju kao izvor napajanja, primjenjene su metoda za ultra nisku potrošnju energije. Na temelju mjerenja potrošnje energije napravljena je procjena očekivanog operativnog vremena. Predstavljena je metoda za procjenu horizontalnog i vertikalnog kuta sudara u trenutku udara paketa. Za procjenu vjerojatnosti oštećenja paketa, osim samog intenziteta udara, važan je i kut pod kojim dolazi do sudara paketa s udarnom površinom. Procjena kuta sudara obavlja se na temelju vrijednosti ubrzanja na tri mjerene osi. Najkritičnije površine paketa su one gdje najmanja površina paketa dolazi u kontakt s udarom, poput rubova ili zakrivljenih dijelova. Provedena su dva eksperimenta za procjenu kuta sudara paketa, a analizirani rezultati pokazuju da izmjereni horizontalni i vertikalni kutovi prilikom udara odgovaraju očekivanim kutovima sudara.

Pravilna integracija mikroprocesora ili mikroupravljača i senzorskih modula omogućuje znatno veće operativno vrijeme na baterijskom napajanju kod sustava za praćenje uvjeta tijekom skladištenja i transporta. Analiza primjene komunikacijskih protokola i metode niske potrošnje energije poput dinamičkog skaliranja napona i frekvencije adekvatan je pristup za postizanje svojstva ultra niske potrošnje. Korištenje DVFS-a može smanjiti potrošnju energije do 47 % u odnosu na korištenje samo dinamičkog skaliranja frekvencije, uz očuvanje funkcionalnosti sustava. Dugoročni utjecaj DVFS-a očituje se u značajnim uštedama energije, jer omogućuje uređajima da prilagode napon i radnu frekvenciju na temelju zahtjeva radnog opterećenja, čime se smanjuje ukupna potrošnja energije. U sustavima visokih performansi, DVFS smanjuje stvaranje topline uslijed niže potrošnje energije, što povećava pouzdanost i dugovječnost uređaja. Iako DVFS ima nekoliko prednosti, prisutni su i određeni nedostaci. Utjecaj na performanse i uvedeno kašnjenje (engl. *latency*) može unijeti greške kod vremenski osjetljivih zahtjeva. Učinkovitost DVFS-a ovisi o primijenjenom opterećenju. Pod određenim uvjetima, konstantno prebacivanje između opterećenja može zahtijevati više energije nego rad na fiksnoj frekvenciji. Brze promjene napona mogu uzrokovati padove napona regulatora što može rezultirati nestabilnim radom sustava. Potrošnja energije I2C

sabirnice raste proporcionalno udjelu vremena tijekom kojeg je podatkovna linija na niskoj logičkoj razini, kao i odabranoj vrijednosti otpora pull-up otpornika. U primjenama s više I2C uređaja, potrebno je korištenje pull-up otpornika nižih vrijednosti u usporedbi s primjenom sa samo jednim I2C uređajem, čime dolazi do povećanja potrošnje energije. Povećanje potrošnje energije kod SPI komunikacijskog protokola izravno je povezano s brojem operacija čitanja i pisanja; uočeno je da povećanje broja operacija pisanja rezultira većom potrošnjom energije. SPI troši više energije za ciljne uređaje koji zahtijevaju veći broj operacija pisanja. Prijedlog odabira komunikacijskog protokola temelji se na specifičnim zahtjevima primjene. U sklopu ove doktorske disertacije ostvarena su tri ključna znanstvena doprinosa, a njihova realizacija potvrđena je kroz razvoj, implementaciju i eksperimentalnu validaciju predloženih metoda i sustava.

- Prvi doprinos, razvoj metode za detekciju i kvantitativnu procjenu vjerojatnosti oštećenja na temelju udara paketa tijekom skladištenja i transporta, ostvaren je implementacijom na Pametnoj naljepnici. Analiza intenziteta detektiranih udara omogućuje precizno praćenje izloženosti paketa štetnim mehaničkim utjecajima u stvarnom vremenu. Eksperimentalni rezultati u laboratorijskim i realnim logističkim uvjetima potvrdili su visoku točnost detekcije udara i mogućnost procjene razine oštećenja prema karakteristikama proizvoda.
- Drugi doprinos, razvoj metode za procjenu vertikalnih i horizontalnih kutova sudara, proveden je analizom ubrzanja u svim prostornim smjerovima. Time je omogućena detaljna rekonstrukcija mehanizama oštećenja i identificiranje kritičnih površina paketa, što je eksperimentalno potvrđeno podudaranjem izmjerenih i očekivanih kutova sudara. Ova metoda omogućuje prepoznavanje kuta sudara i precizniju procjenu rizika od oštećenja, što predstavlja napredak u odnosu na dosadašnja rješenja.
- Treći doprinos, razvoj metode ultra niske potrošnje energije za ugradbene sustave, ostvaren je primjenom dinamičkog skaliranja napona i frekvencije te optimizacijom komunikacijskih protokola. Analiza performansi po wattu (PPW) omogućuje postizanje maksimalne energetske učinkovitosti pri izvršavanju računalnih opterećenja. Time je omogućeno dugotrajano operativno vrijeme na ograničenom napajanju, što je potvrđeno eksperimentalnim mjerenjima potrošnje energije i procjenom operativnog vijeka sustava.

Integracija razvijenih metoda omogućuje prepoznavanje mehaničkih uzroka oštećenja u lancu opskrbe. Time se doprinosi optimizaciji logističkih procesa, smanjenju rizika od oštećenja proizvoda i povećanju učinkovitosti transporta i skladištenja.

6.2 Budući rad

Iako detekcija udara i procjena kuta sudara u lancu opskrbe pružaju adekvatnu procjenu vjerojatnosti oštećenja paketa, u ovome području su prisutni izazovi koji mogu postati temom budućeg rada. Budući rad temeljen na ovoj disertaciji obuhvaća provođenje serije eksperimenata za detekciju udara unutar različitih modaliteta transporta kao što su kamioni, vlakovi, zrakoplovi i brodovi. Cilj ovih testova bio bi evaluirati i usavršiti tehnologije senzora i algoritme za obradu podataka prema realnim uvjetima skladištenja i transporta. Takvi eksperimenti omogućuju bolje razumijevanje dinamike udara koja se javlja tijekom transportnih operacija te pridonose razvoju robustnijih sustava za rano upozoravanje. Daljnja istraživanja obuhvaćaju predviđanje i analizu vijeka trajanja proizvoda na temelju uvjeta okoline s ciljem smanjenja otpada i optimizacije distribucije svježih proizvoda. Prediktivni modeli temeljili bi se na dostupnim podacima o temperaturi, vlažnosti, vibracijama i drugim mjerodavnim čimbenicima koji utječu na degradaciju proizvoda. Implementacija ovih prediktivnih modela povećala bi učinkovitost lanaca opskrbe i doprinijela smanjenju ekološkog otiska povezanog s prekomjernom proizvodnjom i otpadom. Za predviđanje razine oštećenja razmatra se korištenje metoda strojnog učenja i naprednih algoritama za analizu podataka na temelju povijesnih podataka o udarima i vibracijama. Istraživanje zaštite i integriteta pohranjenih podataka o udarima trebalo bi se usmjeriti na razvoj i implementaciju robustnih metoda zaštite podataka koji se prikupljaju tijekom zapisivanja detektiranih udara u transportnim operacijama. Potrebno je istražiti mehanizme za detekciju i pravovremeno spriječavanje neautoriziranih pristupa ili manipulacije podacima, uključujući implementaciju sustava za kontinuirano praćenje integriteta i povjerljivosti podataka. Svaki od ovih smjerova budućih istraživanja ima potencijal dodatno unaprijediti tehnologije praćenja uvjeta u lancu opskrbe, povećati učinkovitost, smanjiti energetske zahtjeve i poboljšati kvalitetu podataka prikupljenih u stvarnom vremenu.

Literatura

- [1] S. Alsobhi, K. Krishnan, D. Gupta i A. Almaktoom. Analysis of damage costs in supply chain systems. *International Journal of Industrial and Systems Engineering*, 28, 01 2016.
- [2] M. Lin, O. Fawole, W. Saeys, D. Wu, J. Wang, U. Opara, B. Nicolai, K. Chen i J. E. Mechanical damages and packaging methods along the fresh fruit supply chain: A review. *Critical Reviews In Food Science and Nutrition*, 63:10283–10302, 11 2023.
- [3] Z.-W. Wang i L.-J. Wang. Accelerated random vibration testing of transport packaging system based on acceleration psd: Accelerated random vibration testing of transport packaging. *Packaging Technology and Science*, 30, 10 2017.
- [4] J. Heising, M. Dekker, P. Bartels i M. Boekel. Monitoring the quality of perishable foods: Opportunities for intelligent packaging. *Critical reviews in food science and nutrition*, 54:645–654, 01 2014.
- [5] J. Wang, H. Wang, J. He, L. Li, M. Shen, X. Tan, H. Min i L. Zheng. Wireless sensor network for real-time perishable food supply chain management. *Computers and Electronics in Agriculture*, 110:196–207, 01 2015.
- [6] M. Christopher i H. Peck. Building the resilient supply chain. *International Journal of Logistics Management*, 15:1–13, 07 2004.
- [7] D. Hellström i M. Saghir. Packaging and logistics interactions in retail supply chains. *Packaging Technology and Science*, 20:197 – 216, 05 2007.
- [8] A. Eissa i G. Gomaa. Comparison of package cushioning materials to protect vibration damage to golden delicious apples. *Int. J. Latest Trends Agric. Food Sci.*, 2, 01 2012.
- [9] A. Uhov, D. Kostrin, V. Gerasimov, L. Selivanov i V. Simon. Development of an electronic device for monitoring the physical parameters of specialized cargoes during their transportation. *LETI Transactions on Electrical Engineering & Computer Science*, 18: 44–54, 01 2025.

- [10] M. M. Aung i Y. Chang. Traceability in a food supply chain: Safety and quality perspectives. *Food Control*, 39:172–184, 05 2014.
- [11] F. Bibi, C. Guillaume, N. Gontard i B. Sorli. A review: Rfid technology having sensing aptitudes for food industry and their contribution to tracking and monitoring of food products. *Trends in Food Science & Technology*, 62, 02 2017.
- [12] R. Angeles. Rfid technologies: Supply-chain applications and implementation issues. *Inf. Syst. Manag.*, 22(1):51–65, 2005.
- [13] M. M. Aung i Y. Chang. Temperature management for the quality assurance of a perishable food supply chain. *Food Control*, 40, 11 2013.
- [14] G. Lorite, T. Selkälä, T. Sipola, J. Palenzuela, E. Jubete, A. Viñuales, G. Cabañero, H. Grande, J. Tuominen, S. Uusitalo, L. Hakalahti, K. Kordás i G. Toth. Novel, smart and rfid assisted critical temperature indicator for supply chain monitoring. *Journal of Food Engineering*, 193, 07 2016.
- [15] M. Vanderroost, P. Ragaert, F. Devlieghere i B. Meulenaer. Intelligent food packaging: The next generation. *Trends in Food Science & Technology*, 39, 09 2014.
- [16] J. Gustavsson, C. Cederberg, U. Sonesson, R. Otterdijk i A. Meybeck. Global food losses and food waste - extent, causes and prevention. Fao study, Food and Agriculture Organization of the United Nations, 01 2011. URL <https://www.fao.org/sustainable-food-value-chains/library/details/en/c/266053/>.
- [17] A. Dolgui. Radio frequency identification (rfid) in supply chain: Technology, applications and concerns. *IFAC Proceedings Volumes (IFAC-PapersOnline)*, svezak 14, stranice 49–56, 05 2012.
- [18] E. Abad, F. Palacio, M. Nuin, A. García de Cortázar, A. Juarros, J. M. Gómez Cama i S. Marco. Rfid smart tag for traceability and cold chain monitoring of foods: Demonstration in an intercontinental fresh fish logistic chain. *Journal of Food Engineering*, 93:394–399, 08 2009.
- [19] E. Smits, J. Schram, M. Nagelkerke, R. Kusters, G. Heck, V. Acht, M. Koetse, J. Brand, G. Gelinck i H. Schoo. Development of printed rfid sensor tags for smart food packaging. *14th International Meeting on Chemical Sensors*, 01 2012.
- [20] P. Papetti, C. Costa, F. Antonucci, S. Figorilli, S. Solaini i P. Menesatti. A rfid web-based infotracing system for artisanal italian cheese quality traceability. *Food Control*, 27:234–241, 09 2012.

-
- [21] J. Feng, Z. Fu, Z. Wang, M. Xu i Z. Xiaoshuan. Development and evaluation on a rfid-based traceability system for cattle/beef quality safety in china. *Food Control*, 31: 314–325, 06 2013.
- [22] F. Tian. An agri-food supply chain traceability system for china based on rfid & blockchain technology. *2016 13th International Conference on Service Systems and Service Management (ICSSSM)*, stranice 1–6, 2016.
- [23] Y. Liu, W. Han, Y. Zhang, L. Li, J. Wang i L. Zheng. An internet-of-things solution for food safety and quality control: A pilot project in china. *Journal of Industrial Information Integration*, 3, 06 2016.
- [24] G. Alfian, J. Rhee, H. Ahn, J. Lee, U. Farooq, M. F. Ijaz i A. Syaekhoni. Integration of rfid, wireless sensor networks, and data mining in an e-pedigree food traceability system. *Journal of Food Engineering*, 05 2017.
- [25] G. Alfian, M. Syafrudin, U. Farooq, M. Maarif, A. Syaekhoni, N. L. Fitriyani, J. Lee i J. Rhee. Improving efficiency of rfid-based traceability system for perishable food by utilizing iot sensors and machine learning model. *Food Control*, 110:107016, 04 2020.
- [26] B. Maskey, J. Sun, K. Shrestha, S. Kim, M. Park, Y. Kim, H. Park, S. Lee, H. Yejin, J. Lee, Y. Majima, J. Kim, J. Lee, G. Bahk, G. Koirala i G. Cho. A smart food label utilizing roll-to-roll gravure printed nfc antenna and thermistor to replace existing “use-by” date system. *IEEE Sensors Journal*, PP:1–1, 10 2019.
- [27] Texas Instruments. Battery-Less NFC/RFID Temperature Sensing Patch: RF430FRL152H Application Report. Application Note SLOA212A, Texas Instruments, 2016. URL <http://www.ti.com/lit/an/sloa212a/sloa212a.pdf>. Pristupljeno: 9.5.2025.
- [28] C. Kollegger, C. Steffan, P. Greiner, M. Wiessflecker, G. Holweg i B. Deutschmann. Intelligent plaster for accurate body temperature monitoring and investigations regarding emi using near-field magnetic scan. *e & i Elektrotechnik und Informationstechnik*, 133, 01 2016.
- [29] P. Barge, A. Biglia, L. Comba, P. Gay, D. Ricauda Aimonino i C. Tortia. The influence of food composition and tag orientation on uhf rf identification. *Journal of Food Engineering*, 246:242–252, 11 2018.
- [30] S. Choi, Y. Eom, S. Kim, D. Jeong, J. Han, J.-M. Koo, S. Hwang, J. Park i D. Oh. A self-healing nanofiber-based self-responsive time-temperature indicator for securing a cold-supply chain. *Advanced Materials*, 32:1907064, 02 2020.

- [31] C. Schoo i M. Knoll. Self-writing smart labels for humidity monitoring. *Sensors and Actuators A: Physical*, 205:1–5, 01 2014.
- [32] Z. Qi, Y. Zhuang, X. Li, W. Liu i Y. Du. Full passive uhf rfid tag with an ultra-low power, small area, high resolution temperature sensor suitable for environment monitoring. *Microelectronics Journal*, 45, 01 2013.
- [33] A. Vásquez Quintero, F. Molina-Lopez, E. Smits, E. Danesh, J. Brand, K. Persaud, I. A. Oprea, N. Barsan, U. Weimar, N. Rooij i D. Briand. Smart rfid label with a printed multisensor platform for environmental monitoring. *Flexible and Printed Electronics*, 1:025003, 06 2016.
- [34] N. Pereira, V. Correia, N. Peřinka, C. Costa i S. Lanceros-Méndez. All-printed smart label with integrated humidity sensors and power supply. *Advanced Engineering Materials*, 23, 11 2020.
- [35] L. Corchia, G. Monti i L. Tarricone. A frequency signature rfid chipless tag for wearable applications. *Sensors*, 19, 01 2019.
- [36] C. Munoz-Ausecha, J. Ruiz-Rosero i G. Ramirez-Gonzalez. Rfid applications and security review. *Computation*, 9:69, 06 2021.
- [37] M. Bertolini, E. Bottani, F. Gino, A. Rizzi i A. Volpi. Experimental evaluation of business impacts of rfid in apparel and retail supply chain. *International Journal of RF Technologies Research and Applications*, 3:257–282, 01 2012.
- [38] J. Chongwatpol i R. Sharda. Rfid-enabled track and traceability in job-shop scheduling environment. *European Journal of Operational Research*, 227:453–463, 06 2013.
- [39] A. Romero. *Improving the Logistics Operations of the Hospital Pharmacy Using a Barcode-Rfid Identification System*, stranice 733–747. Springer Netherlands, 07 2014.
- [40] E. Onieva, E. Osaba, I. Angulo, A. Moreno, A. Bahillo i A. Perallos. Improvement of drug delivery routes through the adoption of multi-operator evolutionary algorithms and intelligent vans capable of reporting real-time incidents. *IEEE Transactions on Automation Science and Engineering*, 14:1–11, 09 2015.
- [41] V. Kumar, L. Koehl, X. Zeng i D. Ekwall. Coded yarn based tag for tracking textile supply chain. *Journal of Manufacturing Systems*, 42:124–139, 01 2017.
- [42] K. Ding, P. Jiang i S. Su. Rfid-enabled social manufacturing system for inter-enterprise monitoring and dispatching of integrated production and transportation tasks. *Robotics and Computer-Integrated Manufacturing*, 49:120–133, 02 2018.

- [43] D. Cardoso, D. Manfro i E. Pignaton de Freitas. Improvement in the detection of passengers in public transport systems by using uhf rfid. *International Journal of Wireless Information Networks*, 27, 03 2020.
- [44] A. Rushton, P. Croucher i P. Baker. *The Handbook of Logistics and Distribution Management: Understanding the Supply Chain*. Kogan Page, 2017.
- [45] S. Alsobhi, K. Krishnan, D. Gupta i A. Almaktoom. Analysis of damage costs in supply chain systems. *International Journal of Industrial and Systems Engineering*, 28:70, 01 2018.
- [46] A. Emblem. 3 - packaging functions. A. Emblem i H. Emblem, editors, *Packaging Technology*, stranice 24–49. Woodhead Publishing, 2012. ISBN 978-1-84569-665-8. doi: <https://doi.org/10.1533/9780857095701.1.24>. URL <https://www.sciencedirect.com/science/article/pii/B9781845696658500032>.
- [47] G. Zhang, X. Song, Y. Shi, F. Su i Y. Cao. *Evaluation on Cushioning Packaging System of Laptop During Drop Based on ABAQUS*, stranice 437–442. Springer Singapore, 01 2018.
- [48] C. Bernad, A. Laspalas, D. González, E. Liarte i M. Jiménez. Dynamic study of stacked packaging units by operational modal analysis. *Packaging Technology and Science*, 23: 121 – 133, 04 2010.
- [49] V. Chonhenchob, S. Sittipod, D. Swasdee, P. Rachtanapun, S. Singh i J. Singh. Effect of truck vibration during transport on damage to fresh produce shipments in thailand. *Journal of Applied Packaging Research*, 3, 01 2009.
- [50] ASTM. Standard test method for drop test of loaded containers by free fall. Standard ICS Code: 55.180.10, American Society for Testing and Materials, ASTM International, 100 Barr Harbor Drive, PO Box C700, West Conshohocken, PA, 19428-2959 USA, 2017. URL <https://www.astm.org/d5276-98r09.html>.
- [51] ISO Central Secretary. Rubber, vulcanized or thermoplastic — determination of compression set part 1: At ambient or elevated temperatures. Standard ISO 815-1:2014(E), International Organization for Standardization, Geneva, CH, 2014. URL <https://www.sis.se/api/document/preview/917717/>.
- [52] ISO Central Secretary. Packaging-complete, filled transport packages and unit loads-vertical random vibration test. Standard ISO 13355, International Organization for Standardization, Geneva, CH, 2016.
- [53] I. Fernando, J. Fei, R. Stanley i H. Enshaei. Measurement and evaluation of the effect of vibration on fruits in transit-review. *Packaging Technology and Science*, 31, 08 2018.

- [54] Wan-Yo Enterprise Co. Ltd. Products & Services: Shock Indicators, Pallet Cushion, Tilt Indicators, 2024. URL <https://www.tradeindia.com/wan-yo-enterprise-co-ltd-7667350/product-services.html>. Pristupljeno: 9.5.2025.
- [55] DB Schenker. Sensor Technology, 2024. URL <https://www.dbschenker.com/de-en/products/sensor-technology>. Pristupljeno: 9.5.2025.
- [56] X. Yang, H. Li, Y. Sun, Y. Cai, H. Zhou i F. Zhong. Research on the design method of cushioning packaging for products with unbalanced mass. *Applied Sciences*, 13:8632, 07 2023.
- [57] T. Fadiji, C. Coetzee, L. Chen, O. Chukwu i U. Opara. Susceptibility of apples to bruising inside ventilated corrugated paperboard packages during simulated transport damage. *Postharvest Biology and Technology*, 118:111–119, 08 2016.
- [58] F. Shahbazi, A. Rajabipour, S. Mohtasebi i S. Rafie. Simulated in-transit vibration damage to watermelons. *Journal of Agricultural Science and Technology*, 12:23–34, 01 2010.
- [59] G. Kun i W. Xi. Design and analysis of cushioning packaging for home appliances. *Procedia Engineering*, 174:904–909, 12 2017.
- [60] R. Zhou, L. Yan, B. Li i J. Xie. Measurement of truck transport vibration levels in china as a function of road conditions, truck speed and load level. *Packaging Technology and Science*, 28:n/a–n/a, 11 2015.
- [61] J. Park, S. Choi i H. Jung. Measurement and analysis of vibration levels for truck transport environment in korea. *Applied Sciences*, 10:6754, 09 2020.
- [62] Lansmont Corporation. SAVER 3X90 Data Logger, 2024. URL https://www.lansmont.com/products/data_loggers/saver_3x90/. Pristupljeno: 9.5.2025.
- [63] C. Gorges, K. Öztürk i R. Liebich. Impact detection using a machine learning approach and experimental road roughness classification. *Mechanical Systems and Signal Processing*, 117:738–756, 08 2018.
- [64] A. Damm, C. Spitzmüller, A. Raichle, A. Bühler, P. Weißgraeber i P. Middendorf. Deep learning for impact detection in composite plates with sparsely integrated sensors. *Smart Materials and Structures*, 29, 10 2020.
- [65] Quality Foam. Package Design Guide: Fragility and G-Factor Table, 2024. URL <http://www.qualityfoam.com/package-design-guide-1.asp>. Pristupljeno: 9.5.2025.

- [66] Simpак International. Protective Packaging 101: Defining Fragility Levels/Classifications, 2024. URL <https://simpakinternational.com/protective-packaging-101-defining-fragility-levelsclassifications/>. Pristupljeno: 9.5.2025.
- [67] I. Fernando, J. Fei, R. Stanley i V. Rouillard. Evaluating packaging performance for bananas under simulated vibration. *Food Packaging and Shelf Life*, 23:100428, 03 2020.
- [68] S. Ahn, D. Choi, J. Kim, S. Kim, Y. Jeong, M. Jo i Y. Kim. Optimization of a pre-impact fall detection algorithm and development of hip protection airbag system. *Sensors and Materials*, 30:1743, 08 2018.
- [69] J. Lee, S. Robinovitch i E. Park. Inertial sensing-based pre-impact detection of falls involving near-fall scenarios. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 23, 09 2014.
- [70] W. Baek, B. Song, Y. Kim i S. Hong. Roll and pitch estimation via an accelerometer array and sensor networks. *International Journal of Automotive Technology*, 8:753–760, 12 2007.
- [71] J. García Guzmán, L. Prieto González, J. Pajares Redondo, S. Sanz i B. Boada. Design of low-cost vehicle roll angle estimator based on kalman filters and an iot architecture. *Sensors*, 18:1800, 06 2018.
- [72] K. Mazhar, A. Khan, Bhatti i A. T. Naseer. A novel roll and pitch estimation approach for a ground vehicle stability improvement using a low cost imu. *Sensors*, 20:340, 01 2020.
- [73] G. Jiang, L. Liu, C. Guo, J. Chen, F. Muhammad i X. Miao. A novel fusion algorithm for estimation of the side-slip angle and the roll angle of a vehicle with optimized key parameters. *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering*, 231, 06 2016.
- [74] M. Okulski i M. Ławryńczuk. Development of a high-efficiency pitch/roll inertial measurement unit based on a low-cost accelerometer and gyroscope sensors. *Proceedings of the 24th International Conference on Methods and Models in Automation and Robotics*, stranice 657–662, 08 2019.
- [75] M. Islam, M. Shajid-Ul-Mahmud, T. Islam, M. Amin i M. H. Haider. A low cost mems and complementary filter based attitude heading reference system (ahrs) for low speed aircraft. *Proceedings of the 2016 IEEE Region 10 Conference (TENCON)*, stranice 1–5, 09 2016.

- [76] A. Janota, V. Šimák, D. Nemec i J. Hrbček. Improving the precision and speed of euler angles computation from low-cost rotation sensor data. *Sensors (Basel, Switzerland)*, 15:7016–39, 03 2015.
- [77] M. Pedley. *Tilt Sensing Using a Three-Axis Accelerometer*. NXP Semiconductors, rev. 6 izdanje, 3 2013. URL <https://www.nxp.com/docs/en/application-note/AN3461.pdf>. Pristupljeno: 9.5.2025.
- [78] C. J. Fisher. *Using an Accelerometer for Inclination Sensing*. Analog Devices, Inc., 2 2010. URL <https://www.analog.com/media/en/technical-documentation/app-notes/an-1057.pdf>. Pristupljeno: 9.5.2025.
- [79] Z. W. Nianxiong Nick Tan, Dongmei Li. *Ultra-Low Power Integrated Circuit Design*. Springer New York, NY, 2014.
- [80] M. Wolf. Chapter 5 - processors and systems. M. Wolf, editor, *The Physics of Computing*, stranice 149–203. Morgan Kaufmann, Boston, 2017. ISBN 978-0-12-809381-8. doi: <https://doi.org/10.1016/B978-0-12-809381-8.00005-5>. URL <https://www.sciencedirect.com/science/article/pii/B9780128093818000055>.
- [81] C. Zhuo, S. Luo, H. Gan, J. Hu i Z. Shi. Noise-aware dvfs for efficient transitions on battery-powered iot devices. *IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems*, 39(7):1498–1510, 2020.
- [82] A. Toor, S. Islam, N. Sohail, A. Akhunzada, J. Boudjadar, H. A. Khattak, I. Ud Din i J. Rodrigues. Energy and performance aware fog computing: A case of dvfs and green renewable energy. *Future Generation Computer Systems*, 101, 07 2019.
- [83] Z. Zhang, Y. Zhao, H. Li, C. Lin i J. Liu. Dvfo: Learning-based dvfs for energy-efficient edge-cloud collaborative inference. *IEEE Transactions on Mobile Computing*, stranice 1–18, 2024.
- [84] S. Khriji, R. Cheour i O. Kanoun. Dynamic voltage and frequency scaling and duty-cycling for ultra low-power wireless sensor nodes. *Electronics*, 11:4071, 12 2022.
- [85] Y.-M. Chang, P.-C. Hsiu, Y.-H. Chang i c.-w. Chang. A resource-driven dvfs scheme for smart handheld devices. *ACM Transactions on Embedded Computing Systems (TECS)*, 13, 12 2013.
- [86] B. Zambrano, E. Garzón, S. Strangio, G. Iannaccone i M. Lanuzza. A 0.6v–1.8v compact temperature sensor with 0.24 °c resolution, ± 1.4 °c inaccuracy and 1.06nj per conversion. *IEEE Sensors Journal*, 22(12):11480–11488, 2022.

- [87] J. M. Kim, M. Kim i S. W. Chung. Application-aware scaling governor for wearable devices. *2014 24th International Workshop on Power and Timing Modeling, Optimization and Simulation (PATMOS)*, stranice 1–8, 2014.
- [88] A. Chakraborty, M. Islam, F. Shahriyar, S. Islam, H. Zaman i M. Hasan. Smart home system: A comprehensive review. *Journal of Electrical and Computer Engineering*, 2023:1–30, 03 2023.
- [89] F. M. Mahbub ul Islam, M. Lin, L. Yang i K.-K. R. Choo. Task aware hybrid dvfs for multi-core real-time systems using machine learning. *Information Sciences*, 433-434, 08 2017.
- [90] S. Bhattacharya i M. Pandey. Deploying an energy efficient, secure & high-speed sidechain-based tinyml model for soil quality monitoring and management in agriculture. *Expert Systems with Applications*, 242:122735, 2024.
- [91] M. M. H. Shuvo, T. Titirsha, N. Amin i S. K. Islam. Energy harvesting in implantable and wearable medical devices for enduring precision healthcare. *Energies*, 15(20), 2022.
- [92] S. Saxena, G. Sanchez i M. Pecht. Batteries in portable electronic devices: A user’s perspective. *IEEE Industrial Electronics Magazine*, 11:35–44, 06 2017.
- [93] A. Zniti i N. Ouazzani. Hash algorithm comparison through a pic32 microcontroller. *Bulletin of Electrical Engineering and Informatics*, 12:2457–2463, 08 2023.
- [94] A. Kaushik, S. Chumbalakar, S. Musunuri i A. Pillai. *Evaluation of Dynamic Frequency Control on an Automotive Microcontroller*, stranice 313–327. Springer, 01 2022.
- [95] B. Labbé, P. Fan, T. Achuthan, P. Prabhat, G. P. Knight i J. Myers. A supply voltage control method for performance guaranteed ultra-low-power microcontroller. *IEEE Journal of Solid-State Circuits*, 56(2):601–611, 2021.
- [96] S. Liu i A. Karanth. Dynamic voltage and frequency scaling to improve energy-efficiency of hardware accelerators. *2021 IEEE 28th International Conference on High Performance Computing, Data, and Analytics (HiPC)*, stranice 232–241, 2021.
- [97] S. Ahmed, Q. Ain, J. Siddiqui, L. Mottola i M. H. Alizai. Intermittent computing with dynamic voltage and frequency scaling. *Proceedings of the International Conference on Embedded Wireless Systems and Networks (EWSN) 2020*, 02 2020.
- [98] R. Cheour, S. Khriji, M. Götz, A. Mohamed i O. Kanoun. Accurate dynamic voltage and frequency scaling measurement for low-power microcontrollers in wireless sensor networks. *Microelectronics Journal*, 105:104874, 08 2020.

- [99] M. Götz, S. Khriji, R. Chéour, W. Arief i O. Kanoun. Benchmarking-based investigation on energy efficiency of low-power microcontrollers. *IEEE Transactions on Instrumentation and Measurement*, 69(10):7505–7512, 2020.
- [100] P. Duangmanee i P. Uthansakul. Clock-frequency switching technique for energy saving of microcontroller unit (mcu)-based sensor node. *Energies*, 11:1194, 05 2018.
- [101] R. Antonio, R. Costa, A. Ison, W. Lim, R. Pajado, D. Roque, R. Yutuc, C. Densing, M. T. de Leon, M. Rosales i L. Alarcon. Implementation of dynamic voltage frequency scaling on a processor for wireless sensing applications. *Proceedings of the 2017 IEEE Region 10 Conference (TENCON 2017)*, stranice 2955–2960, 11 2017.
- [102] K. B. Chun, C. Lee i W. W. Ro. A frequency scaling model for energy efficient dvfs designs based on circuit delay optimization. *2015 International Symposium on Consumer Electronics (ISCE)*, stranice 1–2, 2015.
- [103] P. Huang, P. Kumar, G. Giannopoulou i L. Thiele. Energy efficient dvfs scheduling for mixed-criticality systems. *2014 International Conference on Embedded Software (EMSOFT)*, stranice 1–10, 2014.
- [104] A. Pillai i T. Isha. Dynamic frequency scaling based energy consumption reduction for power-aware embedded systems - a simulation and experimental approach. *Journal of Electrical Systems*, 10:36–47, 03 2014.
- [105] A. Lueangvilai, C. Robertson i C. Martinez. A dynamic frequency controlling technique for power management in existing commercial microcontrollers. *Journal of Computing Science and Engineering*, 6, 06 2012.
- [106] W. Kim, M. Gupta, G.-Y. Wei i D. Brooks. System level analysis of fast, per-core dvfs using on-chip switching regulators. *Proceedings - International Symposium on High-Performance Computer Architecture*, stranice 123 – 134, 03 2008.
- [107] W. Kim, D. Brooks i G.-Y. Wei. A fully-integrated 3-level dc-dc converter for nanosecond-scale dvfs. *IEEE Journal of Solid-State Circuits*, 47(1):206–219, 2012.
- [108] K. Choi, R. Soma i M. Pedram. Fine-grained dynamic voltage and frequency scaling for precise energy and performance tradeoff based on the ratio of off-chip access to on-chip computation times. *IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems*, 24(1):18–28, 2005.
- [109] T. Guerout, T. Monteil, G. Da Costa, R. Calheiros, R. Buyya i M. Alexandru. Energy-aware simulation with dvfs. *Simulation Modelling Practice and Theory*, 39:76–91, 12 2013.

- [110] S. Eyerman i L. Eeckhout. Fine-grained dvfs using on-chip regulators. *TACO*, 8:1, 04 2011.
- [111] F. Diniz Rossi, M. Storch, I. de Oliveira i C. A. F. De Rose. Modeling power consumption for dvfs policies. *2015 IEEE International Symposium on Circuits and Systems (ISCAS)*, stranice 1879–1882, 2015.
- [112] T. Q. Dinh, J. Tang, Q. D. La i T. Q. S. Quek. Offloading in mobile edge computing: Task allocation and computational frequency scaling. *IEEE Transactions on Communications*, 65(8):3571–3584, 2017.
- [113] J. S. Lee, K. Skadron i S. W. Chung. Predictive temperature-aware dvfs. *IEEE Transactions on Computers*, 59(1):127–133, 2010.
- [114] Z. Tang, L. Qi, Z. Cheng, K. Li, S. Khan i K. Li. An energy-efficient task scheduling algorithm in dvfs-enabled cloud environment. *Journal of Grid Computing*, 14, 04 2015.
- [115] M. Bambagini, M. Marinoni, H. Aydin i G. Buttazzo. Energy-aware scheduling for real-time systems. *ACM Transactions on Embedded Computing Systems*, 15:1–34, 01 2016.
- [116] G. Berthou, K. Marquet, T. Risset i G. Salagnac. Accurate power consumption evaluation for peripherals in ultra low-power embedded systems. *2020 Global Internet of Things Summit (GIoTTS)*, stranice 1–6, 2020.
- [117] S. L. Chen, T.-K. Chi, M.-C. Tuan, C.-A. Chen, L.-H. Wang, W.-Y. Chiang, M.-Y. Lin i P. A. Abu. A novel low-power synchronous preamble data line chip design for oscillator control interface. *Electronics*, 9:1509, 09 2020.
- [118] Y. Song, S. Li, C. Zhang, S. Li i L. Lu. Rethinking power efficiency for next-generation processor-free sensing devices. *Sensors*, 22(8), 2022.
- [119] S. Kaur i N. Sharma. Designing and implementation of low power spi-switch interface on fpga. *International Journal of Engineering Research and*, V4, 05 2015.
- [120] K. Mikhaylov i J. Tervonen. Evaluation of power efficiency for digital serial interfaces of microcontrollers. *2012 5th International Conference on New Technologies, Mobility and Security (NTMS)*, stranice 1–5, 2012.
- [121] A. Oudjida, M. L. Berrandjia, R. Tiar, L. Ahmed i K. Tahraoui. Fpga implementation of i2c & spi protocols: A comparative study. *2009 16th IEEE International Conference on Electronics, Circuits, and Systems (ICECS)*, 12 2009.

- [122] P. Visconti, G. Giannotta, R. Brama, P. Primiceri, R. De fazio i A. Malvasi. Framework implementation, firmware development and characterization of flex-spi communication protocol: Energy consumption analysis and comparison with i2c standard. *International Journal on Smart Sensing and Intelligent Systems*, Vol.10:pp. 754 – 792, 12 2017.
- [123] T. Solheim i M. Grannæs. A comparison of serial interfaces on energy critical systems. *2015 Nordic Circuits and Systems Conference (NORCAS): NORCHIP & International Symposium on System-on-Chip (SoC)*, stranice 1–4, 2015.
- [124] D. Trivedi, A. Khade, K. Jain i R. Jadhav. Spi to i2c protocol conversion using verilog. *2018 Fourth International Conference on Computing Communication Control and Automation (ICCUBEA)*, stranice 1–4, 2018.
- [125] S. Saberi, M. Kouhizadeh, J. Sarkis i L. Shen. Blockchain technology and its relationships to sustainable supply chain management. *International Journal of Production Research*, 57:1–19, 10 2018.
- [126] Analog Devices, Inc. *ADXL372: Micropower, 3-Axis, $\pm 200g$ Digital Output, MEMS Accelerometer*, Rev. C izdanje, 9 2022. URL <https://www.mouser.com/datasheet/2/609/ADXL372-1503804.pdf>. Pristupljeno: 9.5.2025.
- [127] C. E. Shannon. Communication in the presence of noise. *Proceedings of the IRE*, 37 (1):10–21, 1949.
- [128] Keysight Technologies. Digital Multimeters 34460A, 34461A, 34465A ($6\frac{1}{2}$ digit), 34470A ($7\frac{1}{2}$ digit), 2024. URL <https://www.keysight.com/us/en/assets/7018-03846/data-sheets/5991-1983.pdf>. Pristupljeno: 9.5.2025.
- [129] GW Instek. PSB-1000 Series Programmable Multi-range D.C. Power Supply, 2024. URL <https://www.gwinstek.com/en-global/products/downloadSeriesDownNew/7000/1366>. Pristupljeno: 9.5.2025.
- [130] STMicroelectronics. STM32L010K8 STM32L010R8 Value line ultra-low-power 32-bit MCU Arm-based Cortex-M0+, 2019. URL <https://www.st.com/resource/en/datasheet/stm32l010k8.pdf>. Pristupljeno: 9.5.2025.
- [131] STMicroelectronics. STM32CubeIDE user guide (UM2609), November 2024. URL https://www.st.com/resource/en/user_manual/um2609-stm32cubeide-user-guide-stmicroelectronics.pdf. Pristupljeno: 9.5.2025.
- [132] J. W. Cooley, P. A. W. Lewis i P. D. Welch. The fast fourier transform and its applications. *IEEE Transactions on Education*, 12(1):27–34, 1969.

- [133] C. Ikeagwu, V. Ejiofor, O. Eze i G. Akawuku. Survey of cryptography models for security of computer-based integrated school information management system. *Research Output Journal of Engineering and Scientific Research*, 4:60–70, 04 2025.
- [134] D. Alnajjar i M. Suguiy. A comprehensive guide for crc hardware implementation. *2015 IEEE International Conference on Electronics, Computing and Communication Technologies (CONECCT)*, 08 2015.
- [135] B. Schneier. *Applied Cryptography: Protocols, Algorithms and Source Code in C*. Wiley, 2015.
- [136] T. H. Tran, H. L. Pham i Y. Nakashima. A high-performance multimem sha-256 accelerator for society 5.0. *IEEE Access*, 9:39182–39192, 2021.
- [137] Y. Xia, M. Zhou, X. Luo, S. Pang i Q. Zhu. A stochastic approach to analysis of energy-aware dvs-enabled cloud datacenters. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 45(1):73–83, 2015.
- [138] K. Gunawardane, N. Padmawansa, N. Kularatna, K. Subasinghage i T. T. Lie. Current context and research trends in linear dc-dc converters. *Applied Sciences*, 12(9), 2022.
- [139] F. Leens. An introduction to i2c and spi protocols. *IEEE Instrumentation & Measurement Magazine*, 12(1):8–13, 2009.
- [140] NXP Semiconductors. *I2C-bus specification and user manual*, 10 2021. URL <https://www.nxp.com/docs/en/user-guide/UM10204.pdf>. Pristupljeno: 9.5.2025.
- [141] NXP Semiconductors. *MC9S12XHZ512, MC9S12XHZ384, MC9S12XHZ256 Data Sheet*, 10 2010. URL <https://www.nxp.com/docs/en/data-sheet/MC9S12XHZ512.pdf>. Poglavlje 16: Serial Peripheral Interface (SPIV4). Pristupljeno: 9.5.2025.

Sažetak

U doktorskoj disertaciji razvijene su i eksperimentalno potvrđene metode dizajna energetski učinkovitih sustava ultra niske snage za detekciju udara u lancu opskrbe. Na temelju znanstvenih doprinosa, moguće je kvantitativno odrediti da li je došlo do povećanog rizika od oštećenja tijekom skladištenja i transporta, uz optimizaciju potrošnje energije u ugradbenim sustavima. Analizirani su ključni izazovi suvremenih logističkih procesa, uključujući nedostatak preciznih podataka o intenzitetu i kutu udara, ograničeno operativno vrijeme sustava zbog baterijskih ograničenja, uz potrebu za pouzdanim i dugotrajnim nadzorom uvjeta skladištenja i transporta. Za implementaciju i validaciju metoda razvijena je "Pametna naljepnica" - ugradbeni sustav niske potrošnje energije temeljen na naprednim senzorima ubrzanja, koji omogućuju kontinuiranu detekciju amplitude udara, vremena i kuta sudara, uz učinkovitu pohranu i prijenos podataka putem RFID/NFC komunikacije. Razvijene su metode za procjenu horizontalnog i vertikalnog kuta sudara na temelju vektora ubrzanja, čime se omogućuje detaljna analiza mehanizama oštećenja proizvoda. Poseban znanstveni doprinos predstavlja implementacija dinamičkog skaliranja napona i frekvencije (DVFS) na razini mikroupravljača, čime je postignuta ultra niska potrošnja električne energije, uz produljenje autonomnog rada sustava na nekoliko mjeseci. Eksperimentalni rezultati, dobiveni u laboratorijskim i realnim logističkim uvjetima, potvrđuju visoku točnost detekcije udara, mogućnost procjene vjerojatnosti oštećenja prema karakteristikama proizvoda te značajno smanjenje potrošnje električne energije u odnosu na postojeća rješenja. Predloženi koncept i metode imaju široku primjenu u industrijama s visokim zahtjevima za sigurnost i integritet proizvoda tijekom transporta, doprinoseći optimizaciji logističkih procesa, smanjenju operativnih troškova i povećanju održivosti lanca opskrbe.

Ključne riječi: lanac opskrbe, detekcija udara, oštećenje paketa, ugradbeni računalni sustavi, ultra niska potrošnja

Abstract

Ultra low-power energy-efficient system design methods for impact detection in the supply chain

In the doctoral dissertation, methods for designing energy-efficient ultra low-power systems for impact detection in the supply chain were developed and experimentally validated. Based on the scientific contributions, it is possible to quantitatively determine whether there is an increased risk of damage during storage and transport, while optimizing energy consumption in embedded systems. Key challenges of modern logistics processes were analyzed, including the lack of precise data on impact intensity and angle, limited system operating time due to battery constraints, and the need for reliable and long-term monitoring of storage and transport conditions. For the implementation and validation of the proposed methods, a "Smart Label" was developed—an embedded low-power system based on advanced accelerometer sensors, enabling continuous recording of impact amplitude, time, and angle, with efficient data storage and transfer via RFID/NFC communication. Methods were developed for estimating horizontal and vertical collision angles based on acceleration vectors, enabling detailed analysis of product damage mechanisms. A significant scientific contribution is the implementation of dynamic voltage and frequency scaling (DVFS) at the microcontroller level, resulting in ultra low energy consumption and extended autonomous system operation lasting several months. Experimental results, obtained in both laboratory and real-world logistics environments, confirm high accuracy of impact detection, the ability to assess damage levels according to product characteristics, and a significant reduction in energy consumption compared to existing solutions. The proposed concept and methods have broad applications in industries with high requirements for product safety and integrity during transportation, contributing to the optimization of logistics processes, reduction of operational costs, and increased sustainability of the supply chain.

Keywords: supply chain, impact detection, package damage, embedded computer systems, ultra low-power

Životopis

Josip Zidar rođen je 27.09.1994. u Virovitici. U Virovitici završava srednju školu 2013. godine, smjer Elektrotehničar. Nakon toga upisuje Elektrotehnički fakultet Osijek (sadašnji Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek). Akademski naziv magistar inženjer računarstva stječe 2018. godine na Fakultetu elektrotehnike, računarstva i informacijskih tehnologija Osijek. Nakon završetka studiranja angažiran je na poslovima koji uključuju IT podršku i PLC programiranje. Sredinom 2020. godine angažiran je kao mlađi istraživač na projektu "Pametna naljepnica za mjerenje i praćenje uvjeta skladištenja i transporta proizvoda", nakon čega je upisao doktorski studij. Područje znanstvenog i stručnog interesa obuhvaća FPGA, digitalnu elektroniku, arhitekturu računala, CAD/CAM dizajn, ugradbene računalne sustave, mikrokontrolere, IoT sustave, ultra nisku potrošnju energije. Kao autor i koautor objavio je četiri rada u znanstvenim časopisima A kategorije te pet radova u zbornicima međunarodnih znanstvenih skupova. Održava nastavu na stručnom i prijediplomskom studiju računarstva i sudjeluje kao sumentor u izradi završnih i diplomskih radova.

U Osijeku, 2025.

Josip Zidar