Vibracijski senzor utemeljen na promjeni razdiobe elektromagnetskoga polja u svjetlovodu.

Lujo, Ivan

Doctoral thesis / Disertacija

2020

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Electrical Engineering and Computing / Sveučilište u Zagrebu, Fakultet elektrotehnike i računarstva**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:168:374085

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-05-13**

Repository / Repozitorij:

FER Repository - University of Zagreb Faculty of Electrical Engineering and Computing repozitory

DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

Sveučilište u Zagrebu
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

Ivan Lujo

VIBRACIJSKI SENZOR UTEMELJEN NA PROMJENI RAZDIOBE ELEKTROMAGNETSKOGA POLJA U SVJETLOVODU

DOKTORSKI RAD

Zagreb, 2020.

Sveučilište u Zagrebu
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

Ivan Lujo

VIBRACIJSKI SENZOR UTEMELJEN NA PROMJENI RAZDIOBE ELEKTROMAGNETSKOGA POLJA U SVJETLOVODU

DOKTORSKI RAD

Mentor: Prof. dr. sc. Zvonimir Šipuš

Zagreb, 2020.

University of Zagreb

FACULTY OF ELECTRICAL ENGINEERING AND COMPUTING

Ivan Lujo

VIBRATION SENSOR BASED ON ELECTROMAGNETIC FIELD REDISTRIBUTION IN OPTICAL FIBER

DOCTORAL THESIS

Supervisor: Professor Zvonimir Šipuš, PhD

Zagreb, 2020

Doktorski rad izrađen je na Sveučilištu u Zagrebu, Fakultetu elektrotehnike i računarstva, na Zavodu za radiokomunikacije.

Mentor: prof. dr. sc. Zvonimir Šipuš

Doktorski rad ima: 190 stranica

Doktorski rad br.: _____

O mentoru

Zvonimir Šipuš rođen je 12. ožujka 1964. godine u Zagrebu. Diplomirao je i magistrirao na Elektrotehničkom fakultetu u Zagrebu 1988. godine, odnosno 1991. godine, a doktorirao je 1997. godine na Chalmers University of Technology, Göteborg, Švedska. Od prosinca 1988. godine do srpnja 1993. godine bio je zaposlen u Institutu Ruđer Bošković, Zagreb, u Laboratoriju za poluvodiče. Sudjelovao je u razvoju uređaja za mjerenje koncentracije eksplozivnih plinova zasnovanih na poluvodičkim senzorima. Od kolovoza 1993. godine radi na Zavodu za radiokomunikacije, Fakultet elektrotehnike i računarstva, Zagreb, gdje je i danas u svojstvu redovitog profesora. Od rujna 1994. godine do listopada 1997. godine nalazio se na znanstvenom usavršavanju na Department of Microwave Technology, Chalmers University of Technology, Göteborg, Švedska, gdje je bio doktorski student. Na istom je sveučilištu u jesen 1999. godine izabran u zvanje gostujući istraživač (Adjunct Researcher) s obvezom da šest tjedana godišnje pomaže u istraživačkom radu i u poslijediplomskoj nastavi. Tu aktivnost je obavljao do 2005. godine. Od 2006. godine obavlja nastavu i u Europskoj doktorskoj školi iz antena (European School of Antennas). Znanstvenoistraživačka djelatnost Zvonimira Šipuša vezana je uz analizu mikrovalnih antena i antenskih nizova, uz numeričke metode u elektromagnetizmu te uz svjetlovodne komunikacijske i senzorske sustave. Autor je ili koautor više od 60 znanstvenih radova objavljenih u znanstvenim časopisima. Zvonimir Šipuš dobitnik je državne godišnje nagrade za znanost za 2006. godinu, za istraživanja konformnih antenskih i periodičnih struktura.

About the Supervisor

Zvonimir Šipuš was born in Zagreb, Croatia, in 1964. He received the B.Sc. and M.Sc. degrees in electrical engineering from the University of Zagreb, Croatia, in 1988 and 1991, respectively, and the Ph.D. degree in electrical engineering from Chalmers University of Technology, Gothenburg, Sweden, in 1997. From 1988 to 1993, he worked at Ruđer Bošković Institute, Zagreb, Croatia, as Research Assistant, involved in the development of detectors for explosive gases. In 1994, he joined the Antenna Group at Chalmers University of Technology, where he was involved in research projects concerning conformal antennas and soft and hard surfaces. In 1997, he joined the Faculty of Electrical Engineering and Computing, University of Zagreb, where he is currently a Professor. From 1999 to 2005, he was also an Adjunct Researcher at the Department of Electromagnetics, Chalmers University of Technology. Since 2006 he was engaged in teaching in the European Doctoral School of Antennas (ESoA). His current research interests include analysis and design of electromagnetic structures with application to antennas, microwaves, and optical communication and sensor systems. He is author or co-author of more than 60 papers in scientific journals. Prof. Šipuš received the annual national science award in 2006 for research of conformal antennas and periodic structures.

Zahvala i posveta

Veliko hvala mom vjernom mentoru Zvonimiru Šipušu na iznimnom strpljenju i razumijevanju kojim me popratio na ovom neočekivano dugačkom putovanju.

Veliko hvala i Marku Bosiljevcu na nebrojeno mnogo asistencija pri mjerenjima u labosu i na spremnosti da se svaki put ispočetka, nakon duljeg perioda moje neaktivnosti, sa mnom prisjeća "Kako smo ono prošli put...?"

Posvetio bih ovaj doktorat mojim roditeljima koji su me uvijek ohrabrivali da pokušam skočiti, a istovremeno pružali veliku sigurnost da neću daleko pasti ako slučajno ne uspijem. Vi ste zaslužni (i velikim dijelom odgovorni) za sve što jesam. Neizmjerno vam hvala na svemu. Mama, možeš tati reći da sam konačno diplomirao.

Mojim velikim curama, Eni i Iskri, hvala što su strpljivo čekale i dočekale da im se mogu barem malo više posvetiti. Sad sam ostao bez glavnog aduta za izmotavanje.

A na kraju, u sredini i na početku ogromno hvala mojoj Lunji, mojoj divljoj ženi, mojoj svakodnevnoj potpori i pomoći. Nikad se nisi žalila i nikad nisam morao objašnjavati. Ti si takva da i nemaš pojma što sve radiš za mene i koliko mi to znači, ali ja znam...

Sažetak

Mjerenjem promjena na točkastom uzorku optičkog signala koji se širi višemodnim svjetlovodom moguće je detektirati i karakterizirati vibracije kojima je svjetlovod izložen. Promatrano svojstvo pruža mogućnost izrade senzorskog sustava za integriranu detekciju vibracija unutar velikih struktura - duž cijelog položenog vlakna, a kao senzorski element logičan izbor je CCD kamera. CCD kamera međutim unosi vrlo nisko ograničenje na frekvencije koje je moguće detektirati odnosno, ako se koristi specijalizirana kamera, znatno povećava cijenu sustava. Mjerenjem točkastog uzorka u jednoj točki pomoću detektorske diode eliminirana je potreba za kamerom, ali se narušavaju značajke detekcije vibracija zbog inherentnog svojstva usrednjavanja signala na površini detekcije. U radu se predlaže alternativni pristup koji kombinira najbolja obilježja oba opisana sustava. Umjesto CCD kamere se koristi sustav detektorskih dioda koje razlažu ukupni točkasti uzorak na manje segmente. Korelacijom signala takvih segmenata točkastog uzorka moguće je doći do informacije o vibracijama koje djeluju na vlakno na bilo kojem njegovom dijelu. Frekvencija koja se tako može detektirati ovisi o brzini rada dioda i akvizicijskog sustava, koje su nekoliko redova veličine veće od brzine rada korištenih kamera. Predloženi sustav je praktično izveden i uspješno testiran u usporedbi s komercijalnim kontrolnim detektorom. U radu je detaljno opisan proces istraživanja, teorijska podloga, metodologija optimizacije parametara sustava, te naposljetku rezultati testiranje. Prezentirani su rezultati koji pokazuju da je prvotni cilj ostvaren - povećana je funkcionalnost mjernog sustava, a da pri tome nije povećana njegova cijena. Razmatrani svjetlovodni senzorski sustav pogodan je za ugradnju u velike strukture (mostove, visoke zgrade, letjelice, itd.) te kao dio sustava za nadzor zaštićenog područja. Uz manje modifikacije moguće ga je koristiti u nadzoru električnih strojeva.

Ključne riječi: mjerenje vibracija, svjetlovodni senzor, točkasti uzorak u višemodnom svjetlovodu, integrirano mjerenje, pametne strukture za nadzor, korelacijske metode

Extended abstract

The importance of measuring vibrations may not be generally obvious, but our civilization has been in need of such measurements for a long time, and the need is steadily increasing. Vibrations are present in every mechanical device with moving parts (electrical or otherwise), and in all physical structures, especially large ones. Measuring vibrations can provide us with the information about the structure or machine health status, need for maintenance or warning of a catastrophic failure. Since all machines and structures produce vibrations there is something that can almost be called a spectral fingerprint, that belongs to a well working machine, or a statically healthy structure. Monitoring the modulations of the spectral domain fingerprint, i.e. vibration components, information on system changes can be obtained. With continuous monitoring of the machine or structure the cost of regular maintenace, failure detection or catastrophic failure damage can be significantly reduced. This is, obviously, only true if the monitoring system price can be kept low.

Using classic vibration detection systems provides easy solutions for one point monitoring. In case of larger machines or structures multiple point measurement is employed. However, this relies on identifying critical points correctly and placing sensors at those points. When dealing with very large structures, such as a water damn or a bridge and even very high rise buildings, the length of the structure can be several hundreds of meters or even several kilometers. If we are considering oil and gas pipelines then the structure can extend for hundreds or thousands of kilometers. Identifying crucial points for vibration measurement is a difficult enough job for such examples, but even then we are left with tens, hundreds or thousands of individual point measurement devices which all need a power supply, communication channel and maintenance of their own.

Using an integrated fiber optic sensor makes the whole length of fiber a detector. Since optical fibers can transmit optical signals for several tens or hundreds of kilometers, without the need for additional amplifiers, they are a perfect tool for long range vibration detection.

It is possible to detect and characterize vibrations perturbing a multimode optical fiber by measuring the changes in the specklegram of an optical signal travelling along it. The optical signal in the fiber propagates in a certain ordered way. There are a limited number of paths that a light ray can take so that it does not loose optical power and can reach the other end of

the fiber, several tens or hundreds of kilometers away. These paths are called modes and the standard communication optical fibers normally support hundreds of modes. The superposition of these modes produces a specific optical signal distribution in a fiber cross section for every point of the fiber, and that characteristic pattern is called a specklegram. It is the result of the geometry of the fiber core and cladding, material refraction indices, wavelength of the signal, the way the fiber is laid out etc. While most of these parameters are fairly constant if the fiber is not perturbed, they are subject to change due to outside perturbation. When the fiber is bent, twisted, extended or compressed, certain modifications of geometry and/or refraction indices of the core and cladding can occur. This causes a redistribution of the optical signal and the superposition of modes on all sections of the fiber that come after the point of perturbation. It is important to note that generally there is no power loss included, i.e. total light intensity remains fairly constant. Only the redistribution of optical signal in the fiber cross section takes place. The theoretical background and the mathematical analysis of the problem are provided in detail in the thesis. When the optical signal reaches the end of the fiber the light leaving the fiber refracts because of the change in the propagation material (silica to air), and thus produces a light cone emanating from the fiber end which can be projected onto a screen. Such a projection is actually the specklegram of the fiber end section, enlarged by several orders of magnitude (depending on the screen distance) as described by the Snell's law.

This property enables the production of an integrated type sensor system for vibration detection on large structures - along the full length of the installed fiber, with a CCD camera as the logical detection element for the specklegram. The camera is used to provide detection in a relatively large and dense 2D array of photodetectors (camera pixels), so that the details of the specklegram can be noted. Following the specklegram changes over time produces a difference signal between neighboring pictures which is strongly correlated with the outside force perturbing the fiber. The camera, however, causes a very low frequency detection limit, or raises the price significantly if a specialized camera is used. Using a single photodiode raises this limitation but does not guarantee successful detection, since the change in the specklegram can happen at any part of the total surface and don't have to be detectable at other parts. If a larger photodiode is used than the detection of changes in the specklegram suffers from inherent integration of optical signal across the surface of the diode, and the information about the perturbing vibration is mostly lost. To determine the best photodiode size for the purpose, as well as the optimal number of detectors and their placement, a custom LabVIEW program was written. It enabled performing simulated acquisitions on the recorded specklegram videos from the actual system under perturbation. The process of photodiode size selection as well as placement and number of single detectors in the total detector array have been thoroughly investigated and the optimization of a system alternative to the CCD camera has been described in detail in the thesis.

As a conclusion of the process, an alternative approach that combines the best characteristics of both detection variants is proposed. Instead of the CCD camera, an array of detector photodiodes is used. They break down the specklegram into smaller segments. The number, size and positions of the photodetectors have been optimized, and are not subject to rigorous placement, but function with a relatively straightforward positioning along the outside border of the specklegram. Several statistical correlating methods have been investigated for providing a single signal, from the individual photodetector signals, that correlates strongly with the perturbing force signal. The vibration frequency that can be detected depends on the sampling frequency of the diodes and the acquisition system, which are normally several orders of magnitude higher than for the CCD camera.

The results achieved in the testing stage have been used as guidelines in building a prototype of the proposed vibration detection system. Two sets of photodiode detector arrays have been used in combination with two different optical fibers, one of which was standard, communication grade fiber, and the other one was specially built to specification as a highly multimode fiber with a large core. Moreover, the fiber have been placed in contact with the perturbing vibration in two different ways so that integrated detection and one point detection (isolated segment) were both tested. The test measurements were performed over a wide range of mechanical vibration frequencies from 29Hz to 500Hz and with several different acceleration values ranging to 2g. A controlled vibration source was used as the fiber perturbator, and the result was monitored with a commercial grade accelerometer in parallel to the optical fiber vibration detection. A new custom LabVIEW program was written for signal acquisition from the array photodiodes and the control accelerometer. The signal was processed in real time and the information on spectral components was provided as well. With the three elements (detector, fiber and placement) variations, all eight possible combinations were tested. Almost all of them yielded results that justified the proposed system. Only the combination of the highly multimode fiber and very small detector diodes did not produce results that were correlated to the used control detector. All the other combinations provided correct vibration frequency detection and some of them implied that acceleration level can be measured as well. This is true of both the integrated detection (along the length of the fiber) and the single point (isolated segment) detection. Abundant measurement results have been provided in the thesis, and a detailed result discussion is provided.

The conclusion of the thesis summarizes the optimization of the optical fiber specklegram based vibration detection system through the usage of multiple photodetectors placed along the outside border of the specklegram. This modification of the previously presented systems removes the frequency limitations imposed by the usage of a CCD camera as a detection element and improves the functionality of the system significantly. At the same time the price of the system is kept low as no specially designed elements (fibers or photodiodes) are required. All

the used elements are commercial grade and standard in the communication installations.

The proposed system has been successfully prototyped and tested in comparison with a commercial grade control vibration detector. The theoretical background for the functionality has been mathematically established. The proposed optical fiber vibration detection system is suitable for installation in large structures (bridges, tall buildings, aircraft, etc.) or as a part of perimeter security systems. With some modification it is possible to use it in electrical machines condition monitoring.

It is of some note that the proposed system provides a functionality that is very difficult or impossible to achieve using alternative approaches to vibration detection. Since the whole length of the fiber works as an integrated vibration detector, and can detect vibrations at literally any point along the fiber, the consequence is that an infinite number of measurement points is available. However, the signals from all the points are integrated into the single specklegram as a result of superposition of all the propagating modes. This means that the basic system provides no spatial distinction, e.g. for a detected vibration from a several kilometers long fiber you have to further investigate, using some other means, to determine the exact section of the fiber (or structure) where the vibration perturbation actually took place. This makes the proposed system an inexpensive and wide encompassing solution for integrated vibration detection as part of an early warning monitoring system. However, it needs to be accompanied with additional, preferably portable, detection systems for further investigation and exact location determining.

The same applies if the optical fiber vibration detection system is used as part of a perimeter security systems. It can be easily deployed over large areas to detect incoming intruders through the vibrations that they produce when moving across the area. However it cannot, by itself, be used to determine the exact location of the intruder, and would need to be accompanied with some additional monitoring systems, such as movable cameras or similar. If multiple instances of the systems were deployed in a certain overlapping pattern, a level of spatial distinction between different signals could be achieved.

Keywords: vibration measurement, optical fiber sensor, multimode fiber specklegram, integrated measurement, smart structures for monitoring, correlation methods

Sadržaj

Uvod 1

1. Sustavi za mjerenje vibracija pomoću svjetlovodnih vlakana 4

1.1. Podjela svjetlovodnih senzorskih sustava 4

1.1.1. Podjela senzorskih sustava prema mjestu modulacije svjetlosnog signala 4

1.1.2. Podjela senzorskih sustava po načinu detekcije 5

1.1.3. Osnovni tipovi vibracijskih svjetlovodnih senzorskih sustava 5

1.2. Intenzitetno bazirani svjetlovodni senzori 5

1.2.1. Senzori sa savijajućim strukturama 6

1.2.2. Kontaktni i beskontaktni intenzitetni svjetlovodni senzori za dinamičke pomake 7

1.3. Fabry-Perot interferometarski senzorski sustavi 10

1.3.1. Distribuirana detekcija i mjerenje vibracija interferometarskim metodama 12

1.3.2. Distribuirana detekcija i mjerenje vibracija metodama povratnog raspršenja 14

1.4. Senzorski sustavi temeljeni na Braggovim rešetkama 15

2. Točkasti uzorak svjetlovoda (*specklegram*) 17

2.1. Nastanak točkastog uzorka u vlaknu 17

2.2. Lokalne nepravilnosti na vlaknu 19

2.3. Princip detekcije vanjskih utjecaja 20

2.3.1. Broj modova u svjetlovodu 26

2.4. Utjecaj vanjske sile na raspodjelu polja u svjetlovodu 27

2.4.1. Izračun preko svih N uzoraka 31

2.4.2. Izračun preko $n << N$ uzoraka 32

2.5. Primjeri primjene točkastog uzorka (*specklegram*-a) u senzorskim sustavima . . 33

2.5.1. Beskontaktno mjerenje vibracija pomoću točkastog uzorka 33

2.5.2. Mjerenje statičkog naprezanja pomoću sprege osnovnih svjetlovodnih modova 33

2.5.3. Mjerenje temperature pomoću točkastog uzorka 34
2.5.4. Točkasti uzorak u detekciji pozicije pritiska 34
2.5.5. Različita obilježja pojedinih regija u točkastom uzorku 35
2.5.6. Točkasti uzorak u sustavima za osiguranje prostora 36

3. Mjerenje vibracija pomoću analize točkastog uzorka svjetlovoda 37
3.1. Opis prototipa sustava 37
3.2. Ograničenja prototipa 38
3.2.1. Frekvencija uzorkovanja 38
3.2.2. Obrada podataka 40
3.3. Redizajn mjernog sustava 42
3.4. Ograničenja prvog razvijenog mjernog sustava za mjerenje vibracija pomoću kamere 42
3.5. Odabir pogodne programske okoline/jezika 43
3.6. Dodatna poboljšanja programa za mjerenje 45
3.7. Rezultati unapređenja programa za obradu podataka 46
3.7.1. Segmentiranje slike 47
3.7.2. Centralno (C) pozicionirani segmenti 50
3.7.3. Sjeverno (N) pozicionirani segmenti 53
3.7.4. Sjeverozapadno (NW) pozicionirani segmenti 56
3.7.5. Zapadno (W) pozicionirani segmenti 59
3.7.6. Jugozapadno (SW) pozicionirani segmenti 62
3.7.7. Južno (S) pozicionirani segmenti 65
3.8. Diskusija rezultata segmentiranja točkastog uzorka 68
3.9. Promjena pristupa analize slike 69
3.9.1. Mogućnost simuliranja višestrukih detektorskih segmenata 70

4. Metode za analizu signala iz detektorskih dioda 74
4.1. Metoda razlike među pojedinim "slikama": *PfPPD* (*Point for Point Picture Difference*) 74
4.2. Metoda razlika među sumama elemenata "slika": *SumDIff* (*Sum Difference*) 75
4.3. Korelacijska metoda 1: *Correlation* 75
4.4. Korelacijska metoda 2: *Corr. Ef* 76
4.5. Metoda momenata: *Mom. Ef* 76
4.6. Analiza signala detektorskih dioda različitim statističkim metodama izračuna . 77

5. Simuliranje detekcije detektorskim diodama 78
5.1. Simulacije za dvodimenzionalno polje detektorskih dioda 79
5.1.1. Veličina i raspored detektorskih dioda na točkastom uzorku 80
5.1.2. Usporedba metoda za diode veličine 14^2 piksela 81
5.1.3. Usporedba metoda za diode veličine 7^2 piksela 82
5.1.4. Usporedba metoda za diode veličine 3^2 piksela 83
5.1.5. Usporedba metoda za diode veličine 2^2 piksela 84
5.1.6. Usporedba metoda za diode veličine 1^2 piksela 85
5.1.7. Rezultati simulacije dvodimenzionalno raspoređenih dioda analizirani po veličini dioda 86
5.1.8. Usporedba različitih veličina detektorskih dioda metodom PfPPD . . . 88
5.1.9. Usporedba različitih veličina det. dioda metodom SumDiff 89
5.1.10. Usporedba različitih veličina det. dioda metodom Correlation 90
5.1.11. Usporedba različitih veličina det. dioda metodom Corr. Ef 91
5.1.12. Usporedba različitih veličina det. dioda metodom Mom. Ef 92
5.1.13. Rezultati simulacije dvodimenzionalno raspoređenih detektorskih dioda analizirani po primijenjenoj metodi izračuna i broju elemenata detektorskog polja 93
5.2. Simulacija detektorskih dioda u konfiguraciji dva ukrižana linearna polja 96
5.3. Veličina i raspored det. dioda u križnoj konfiguraciji 97
5.3.1. Usporedba metoda za diode veličine 14^2 piksela^2 98
5.3.2. Usporedba metoda za diode veličine 7^2 piksela^2 99
5.3.3. Usporedba metoda za diode veličine 3^2 piksela^2 100
5.3.4. Usporedba metoda za diode veličine 2^2 piksela^2 101
5.3.5. Usporedba metoda za diode veličine 1^2 piksela^2 102
5.4. Diskusija rezultata za simulacije polja detektorskih dioda u dvije različite konfiguracije 103

6. Eksperimentalni mjerni sustav s detektorskim diodama 105
6.1. Elementi mjernog sustava 105
6.1.1. Detektorske diode 105
6.1.2. Svjetlovodna vlakna 106
6.1.3. Kontrolni detektor (akcelerometar) 107
6.1.4. Upravljani generator mehaničkih vibracija 109
6.1.5. Uređaj za akviziciju 109
6.1.6. Ostali elementi mjernog sustava 111
6.2. Proces mjerenja 112
6.2.1. Način prikaza rezultata 112

6.3. Eksperimentalni rezultati 113
6.3.1. Male detektorske diode i specijalno višemodno vlakno 113
6.3.2. Velike detektorske diode i jako višemodno vlakno 125
6.3.3. Male detektorske diode i standardno višemodno vlakno 136
6.3.4. Velike detektorske diode i standardno višemodno vlakno 136
6.3.5. Velike detektorske diode i standardno višemodno vlakno postavljeno u petlju 147
6.3.6. Male detektorske diode i jako višemodno vlakno postavljeno u petlju . 163
6.4. Diskusija eksperimentalnih rezultata 164
6.5. Diskusija neusklađenosti simuliranih i eksperimentalnih rezultata 165
6.5.1. Proces akvizicije slike kamerom 165
6.5.2. Proces akvizicije signala fotodiodama 166

7. Zaključak 168

Dodaci 170

A. Mjerenje amplitude vibracija 170
A.1. Usporedba linearnosti odziva različitih statističkih metoda obrade signala . . . 171
A.2. Odziv metoda na različite amplitude uzbudnog signala u promatranom frekvencijskom rasponu 176

B. LabVIEW program za mjerenje vibracija pomoću detektorskih dioda 180

Literatura 182

Životopis 188

Resume 190

Uvod

Problematika najčešće neželjenih vibracija je vezana uz cijeli niz tehnoloških rješenja u današnjoj civilizaciji. Potreba za praćenjem parametara mehaničkih vibracija se javlja od rotacijskih strojeva i transformatora do velikih nosećih struktura kao što su mostovi ili visoke zgrade[1]. Svrha takvog neprekidnog nadzora je utvrđivanje stanja stroja ili strukture, odnosno potrebe za preventivnim održavanjem, intervencijom ili stavljanju izvan pogona radi sprečavanja katastrofalnog kvara i sl. Naime, kod strojeva i struktura ili objekata velikih dimenzija, vibracije su prisutne prilikom normalnog funkcioniranja ili u normalnom stanju. Ukoliko se znaju obilježja takvih *zdravih* vibracija, kontinuiranim nadzorom se, u slučaju detektirane promjene obilježja vibracija, mogu alarmirati službe zadužene za stroj, strukturu ili objekt kako bi spriječili kvarove, nesreće ili druge nepoželjne događaje. Praćenje vibracija može poslužiti i u svrhu zaštite prostora s ograničenim pristupom, pri čemu idealni detektori u potpunosti obuhvaćaju cijeli zaštićeni prostor. S obzirom na tako veliki broj mogućih primjena i broj ponuđenih rješenja je vrlo velik i raznovrstan. Rješenja mogu biti kontaktna ili beskontaktna, ali većina ih podrazumijeva mjerenje u jednoj točki u određenom vremenskom trenutku. Mjerenja u više točaka se pretežno ostvaruju multipliciranjem sustava predviđenih za mjerenje u jednoj točki.

Kao suštinski drugačiji pristup predloženo je mjerenje vibracija pomoću višemodnog svjetlovodnog vlakna, odnosno točnije, pomoću točkastog uzorka optičkog signala koji se emitira iz višemodnog svjetlosnog vlakna. Pri tome ključna razlika u odnosu na ostale, klasične sustave dolazi od činjenice da se radi o integriranom senzorskom sustavu, odnosno da se detekcija obavlja duž cijelog vlakna. To znači da u takvom sustavu ne postoje diskretne točke detekcije. Treba naglasiti da u najosnovnijem obliku primjene takvog sustava nema lokalizacije vibracija, odnosno da nije moguće odrediti gdje su se na vlaknu vibracije dogodile, ali se može registrirati i izmjeriti njihova pojava bilo gdje duž vlakna. Posebnim izvedbama moguće je i od takvog sustava napraviti sustav s diskretnom točkom detekcije ili segmentiranjem vlakna suziti područje detekcije na kraće odsječke. Ipak, ovakav sustav svoju najbolju potencijalnu primjenu pronalazi upravo u specifičnim situacijama u kojima se vibracije potencijalno mogu dogoditi bilo gdje na duljim strukturama ili na rubu zaštićenog područja, prvenstveno jer drugi načini detekcije vibracija teško mogu isporučiti sustav s takvim svojstvima. Još jedna prednost predloženog svjetlovodnog senzorskog sustava je mogućnost ugradbe vlakna u samu strukturu, primjerice u

zidove visoke zgrade ili ukopavanjem u tlo oko zaštićenog područja. Na taj način svjetlovod postaje nedjeljivi dio same strukture te ga je gotovo nemoguće detektirati ili ometati osim direktnim fizičkim djelovanjem. Upotrebom takvog sustava omogućuje se kontinuirano praćenje i nadzor strukture (ili određenog prostora) s aspekta prisustva i karakterizacije vibracija. Nadalje sustav ima veliku potencijalnu primjenu u takozvanim "pametnim strukturama" nadzora, odnosno u zaštiti prostora od neželjnog pristupa.

Ovaj rad predstavlja detaljnu analizu i razradu jednog takvog senzorskog sustava. Konačni rezultat je izrada upotrebljivog mjernog sustava za određivanje frekvencija vibracija analizom promjene u točkastom uzorku svjetlovoda koji je izložen vibracijama.

Sam rad je strukturiran na sljedeći način:

U prvom poglavlju opisani su principi i osnovna svojstva nekih od najčešće primjenjivanih sustava za detekciju i karakterizaciju vibracija pomoću svjetlovoda.

U drugom poglavlju je pojašnjena pojava točkastog uzorka signala u višemodnom svjetlovodu te koncept senzorskih sustava temeljenih na točkastom uzorku. Prikazana je i matematička podloga za povezivanje promjena u točkastom uzorku s vanjskom silom koja djeluje na vlakno. Kratko je predstavljeno nekoliko senzorskih sustava koji počivaju na detekciji i analizi točkastog uzorka, od prvih prijedloga upotrebe točkastog uzorka u senzorici prije tridesetak godina, pa do posljednjih godina u kojima je obnovljen i pojačan interes za to područje.

Treće poglavlje opisuje prvu eksperimentalnu izvedbu sustava koja je uključivala CCD kameru, te su prikazani postignuti rezultati, kao i mogućnosti i ograničenja takvog sustava. Zatim su opisana poboljšanja softvera izrađenog za obradu podataka prikupljenih kamerom. Opisana je metodologija istraživanja alternativnog pristupa detekcije pomoću detektorskih dioda, temeljenog na obradi signala prikupljenih pomoću CCD kamere.

U četvrtom poglavlju opisane su različite metode statističke obrade signala prikupljenih sa simuliranih segmenata, odnosno s detektorskih dioda.

Peto poglavlje predstavlja rezultate simulacija, koje su sustavno provođene kako bi se prije izrade fizičkog sustava pokušali odrediti optimalni parametri za sustav detektora (veličina detektorskih dioda, potreban broj, pozicioniranje i konfiguracija razmještaja dioda te uspješnost statističkih metoda u izvlačenju informacije iz signala pojedinačnih detektorskih dioda).

U šestom poglavlju prezentirana je praktična izvedba detekcijskog sustava izvedena prema prethodnim zaključcima u nekoliko alternativnih varijanti. Predstavljeni su sastavni dijelovi sustava te metodologija eksperimenata i način prikaza rezultata. Nakon toga slijede rezultati obavljenih mjerenja. Pokazana je mogućnost određivanja frekvencije vibracija i kategorizacija varijanti mjernog sustava prema stupnju uspješnosti te je ponuđena diskusija rezultata. Eksperimentalni rezultati su uspoređeni sa simulacijskim predviđanjima te je raspravljena razlika među njima. Naposljetku, ponuđen je konačni zaključak o svojstvima predloženog vibracijskog detektorskog sustava, njegovim ograničenjima i prednostima, te mogućnostima primjene.

U dodatku A prikazan je dio mjerenja vezan uz mogućnosti mjerenja amplitude vibracija. Zbog prevelike opsežnosti s obzirom na planirani obim rada nisu detaljno razmatrana.

Poglavlje 1

Sustavi za mjerenje vibracija pomoću svjetlovodnih vlakana

U ovom poglavlju dan je kratak pregled relevantne klasifikacije svjetlovodnih senzorskih sustava za detekciju vibracija te je navedeno nekoliko primjera takvih sustava sa svojstvima koja su zanimljiva iz perspektive usporedbe sa sustavom koji je tema ovog rada.

1.1 Podjela svjetlovodnih senzorskih sustava

Postoji nekoliko različith podjela optičkih svjetlovodnih senzorskih sustava koje se temelje na različitim aspektima modulacije svjetlosnog signala [2]. Ponuđena su objašnjenja za nekoliko osnovnih podjela koje su relevantne za vibracijski detekcijski sustav koji je tema ovog rada.

1.1.1 Podjela senzorskih sustava prema mjestu modulacije svjetlosnog signala

Prema mjestu modulacije signala senzorski sustavi se jednostavno dijele na dvije skupine:

- intrinsične
- ekstrinsične.

Osnovno obilježje instrinsičnog sustava jest da u procesu modulacije, odnosno obavljanja mjerenja, svjetlosni signal ne napušta svjetlovod. To omogućuje bolju kontrolu nad signalom, odnosno znači da sustav raspolaže dovoljno jakim signalom uz manje količine vanjskog šuma. S druge strane, ovakvi sustavi najčešće zahtijevaju direktan fizički svjetlovoda kontakt s promatranom pojavom (strukturom, uređajem), kako bi se djelovanje promatrane fizikalne pojave na svjetlovod, pomoću kojega se obavlja detekcija, moglo ostvariti.

Ukoliko je sustav ekstrinsičnog tipa to znači da optički signal u procesu modulacije, odnosno detekcije koju obavlja, napušta vlakno i jedan dio svog širenja obavlja najčešće u slobodnom

prostoru, a ponekad i u prostoru ispunjenom nekim drugim medijem osim zraka, npr. raznim otopinama, drugim vrstama stakla i sl. Pri tome se nakon modulacije može obavljati povratni prihvat u svjetlovod ili detekcija signala pomoću detektorskih elemenata. U oba slučaja javlja se problem usmjeravanja izvornog moduliranog signala natrag na prihvatnu točku (svjetlovod ili detektore), što najčešće rezultira smanjenom razinom signala, odnosno ne uspijeva se prikupiti sav raspoloživi optički signal jer dio bude izgubljen u drugom mediju. Osim toga, u pravilu dolazi i do većeg gušenja signala na prevaljenom putu, nego što bi to bio slučaj u samom svjetlovodu, što nije poželjno osim ako je upravo u službi modulacije/detekcije izvornog signala. Sve navedeno rezultira smanjenim odnosom signal/šum. Ipak, ovakvi sustavi imaju značajnu prednost u tome što fizički kontakt s promatranom pojavom (strukturom, uređajem) nije nužan, pa se detekcija obavlja beskontaktno, odnosno *daljinski*.

1.1.2 Podjela senzorskih sustava po načinu detekcije

Podjela po načinu detekcije predviđa četiri različita slučaja:

- detekcija u jednoj točki
- kvazi distribuirana detekcija, koja se može opisati i kao detekcija u n točaka
- distribuirana detekcija, koja u idealnom slučaju predviđa detekciju u beskonačno mnogo točaka, uz prostornu distinkciju pozicija pojedinih točaka, odnosno mogućnost lokalizacije mjerenja
- integrirana detekcija, koja također podrazumijeva detekciju u beskonačno mnogo točaka, ali bez prostorne distinkcije, odnosno senzorski sustav isporučuje samo jedan zajednički rezultat za sve točke

1.1.3 Osnovni tipovi vibracijskih svjetlovodnih senzorskih sustava

Po principu rada, velika većina vibracijskih svjetlovodnih senzorskih sustava može se svrstati u tri kategorije:

- Intenzitetno bazirani svjetlovodni senzori (*IBS*)
- Fabry-Perot interferometarski senzorski senzori (*FPI*)
- Senzorski sustavi temeljeni na Braggovim rešetkama u vlaknu (*Fiber Bragg Gratings - FBG*)

1.2 Intenzitetno bazirani svjetlovodni senzori

Senzori koji se zasnivaju na modulaciji intenziteta koriste cijeli niz raznovrsnih konfiguracija, poput mikrosavijajuće konstrukcije, sprege između dva vlakna, pomične rešetke ili maske i modifikacije plašta oko jezgre vlakna. U skladu s prethodno opisanom podjelom, razlikujemo

kontaktne i beskontaktne senzore. U pravilu ovakvi sustavi funkcioniraju na način da se modulacija intenziteta svjetlosti događa modulacijom trasnmisivnih svojstava svjetlovoda posredstvom kontakta s vanjskim čimbenikom ili modulacijom reflektivnih svojstava prepreke na putu signala u slučaju beskontaktne detekcije. Principijelna shema ovakvih sustava je predstavljena na slici 1.1.

Slika 1.1: Principijelna shema svjetlovodnih senzorskih sustava temeljenih na modulaciji intenziteta signala (*IBS*) [3]

1.2.1 Senzori sa savijajućim strukturama

Mikrosavijajuće strukture su među prvima korištene za modulaciju intenziteta svjetlosti u svjetlovodu. Mogu se koristiti u kombinaciji s jednomodnim i višemodnim svjetlovodima. U oba slučaja se, kao posljedica deformacije svjetlovoda pod djelovanjem vanjske mikrosavijajuće strukture, javlja gušenje signala zbog prijenosa optičke snage između osnovnih modova i onih višeg reda. Viši modovi se zatim guše u plaštu svjetlovoda, što dovodi do smanjenja ukupne snage optičkog signala koji se širi svjetlovodom. Mikrosavijajuća struktura se svodi na češljastu konstrukciju kroz koju prolazi svjetlovodno vlakno. Poželjan period češljastih deformacija je vezan uz razliku propagacijskih konstanti između vođenih i nevođenih modova [4, 5, 6, 7, 8, 9, 10, 11]. Osnovni izgled strukture je prikazan na slici 1.2.

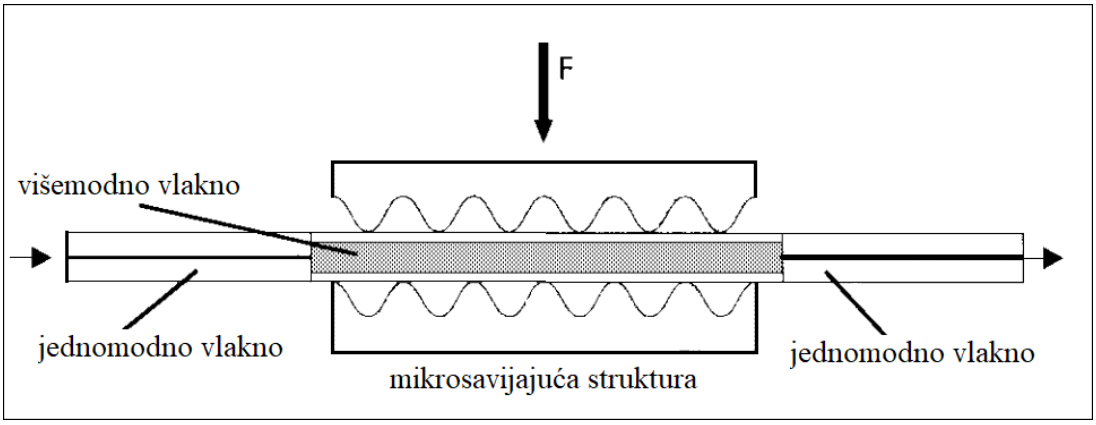

Slika 1.2: Struktura za mikrosavijajuće djelovanje na svjetlovod [7]

Pokazane su i neke alternativne izvedbe kao primjerice na slici 1.3, gdje spiralna žica integrirana u optički kabel oko svjetlovoda obavlja funkciju strukture koja obavlja zadaću prethodno pokazane strukture za mikrosavijanje.

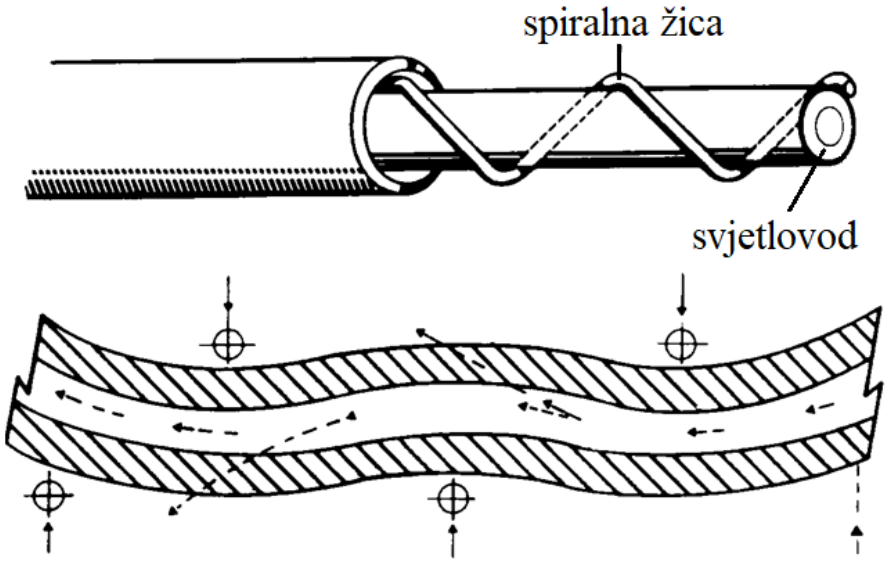

Slika 1.3: Spiralna žica za mikrosavijajuće djelovanje na svjetlovod

Sličan princip, ali u drugom redu veličine postiže se makrosavijajućim strukturama koje zahvaljujući promjeni geometrije vlakna, uslijed savijanja većeg radijusa, izazivaju znatno povećanje gušenja u vlaknu [12, 13, 14]. Iako je u osnovi struktura jednaka kao i za mikrosavijanje, u ovom slučaju su dimenzije strukture i izbočina znatno veće od dimenzija jezgre vlakna. Mehanizam gušenja nije povezan sa sprezanjem nižih modova u više, već s promjenom geometrijskih uvjeta širenja signala vlaknom. Primjenom principa geometrijske optike jednostavno je pokazati da jedan dio *svjetlosnih zraka* uslijed savijanja vlakna više ne zadovoljava uvjete za totalnu refleksiju (kritični kut). Daljnje širenje takvih zraka kroz svjetlovod je time onemogućeno i mijenja se ukupna snaga optičkog signala na izlazu iz svjetlovoda. Primjer takve strukture i njenog djelovanja na mjereno gušenje vlakna su prikazani na slici 1.4.

1.2.2 Kontaktni i beskontaktni intenzitetni svjetlovodni senzori za dinamičke pomake

Beskontaktna detekcija pomaka se često koristi za detekciju vibracija. Svjetlosni signal se vlaknom dovodi do pozicije detekcije te se nakon refleksije prikuplja u jedno ili više prihvatnih vlakana. Pri tome je potrebno eliminirati ili reducirati detekciju refleksija s okolnih površina. Dodatan problem je osigurati potpuno stacionarnu točku u blizini stroja na koju se montira senzor, odnosno s koje se svjetlosni signal odašilje prema površini refleksije. Na slici 1.5 prikazan je primjer takvog sustava. Slični primjeri opisani su u literaturi [15, 16].

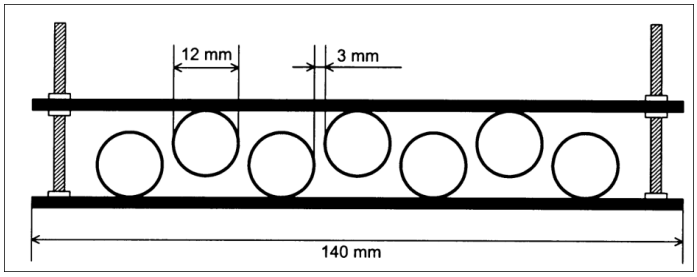

(a) Struktura za makrosavijanje svjetlovoda

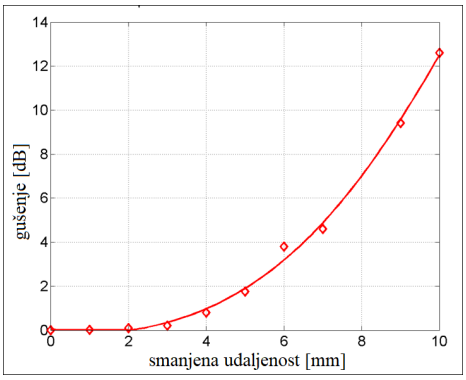

(b) Ovisnost gušenja o smanjenju udaljenosti između makrosavijajućih izbočina

Slika 1.4: Makrosavijanje svjetlovoda a) struktura za makrosavijanje i b) povećanje gušenja zbog savijanja (mjerne točke su naznačene)

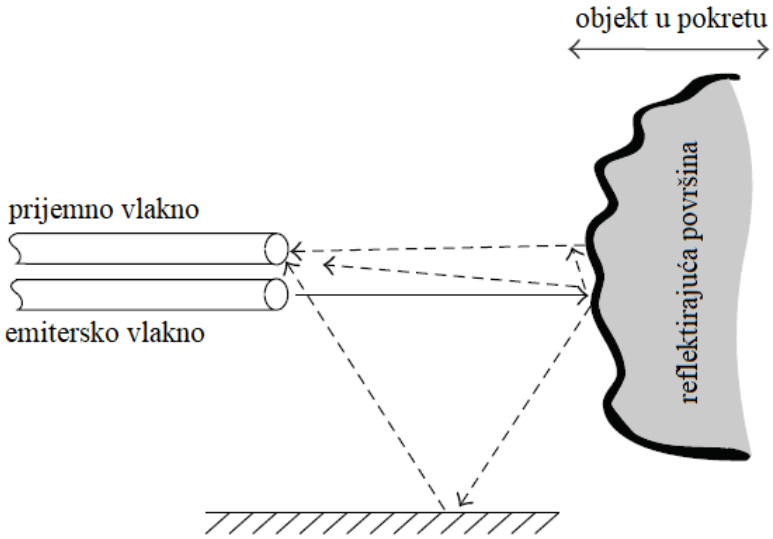

Slika 1.5: Beskontakni sustav za detekciju vibracija pomoću reflektiranog svjetlosnog signala

Malo drugačija izvedba svjetlovodnog vibracijskog detektorskog sustava je istraživana na Zavodu za radiokomunikacije Fakulteta elektrotehnike i računarstva. Princip rada je baziran na promjeni intenziteta svjetlosti koja se prenosi između dva svjetlovodna vlakna između kojih se nalazi veći zračni raspor (znatno veći od valne duljine signala). Uslijed djelovanja vibracija dolazi do pomaka između vlakana i mijenja se ukupna količina energije koja se prenosi s jednog na drugo vlakno. Osnovni princip rada sustava ilustriran je na slici 1.6, gdje 1 označava dolazno vlakno, 2 držač dolaznog vlakna, 3 fleksibilni dio vlakna koji se giba zbog vibracija, 4 kolimirajuća leća za prihvat dolaznog svjetlosnog snopa, 5 prihvatno vlakno te 6 kućište senzora [17].

Ovakva konstrukcija dobro ilustrira koncept, ali ima potencijalnu konstrukcijsku manu na mjestu savijanja vlakna. Naime, nije poznato koliko takvog naprezanja bi vlakno moglo izdržati prije pucanja, a kontinuirana izloženost naprezanju na stroju koji vibrira bi mogla brzo do

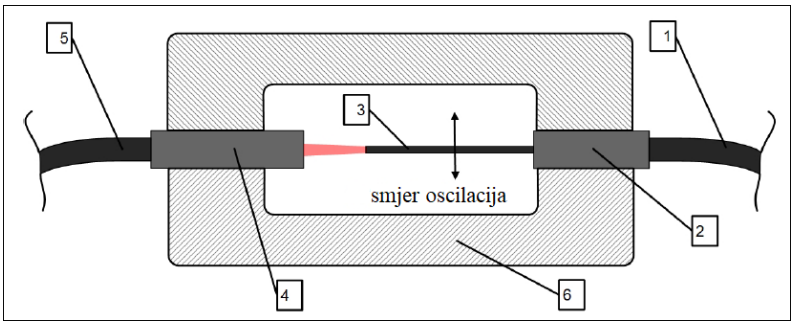

Slika 1.6: Sustav za detekciju vibracija pomoću spregnutih svjetlovoda

toga dovesti. Nadalje, slobodno vlakno bi se s vremenom savinulo uslijed djelovanja gravitacije i time bi se promijenila transmisijska svojstva sustava. Iz tog razloga je dizajn revidiran i izvedena je alternativa kod koje je eliminirana potreba za vibrirajućim vlaknom [17]. Umjesto vlakna koje se savija u ovoj varijanti je primijenjen fleksibilni zaslon koji djelomično zasjenjuje prijenos između dolaznog i prihvatnog vlakna uslijed gibanja zbog vibracija. Ova izvedba senzora je prikazana na slici 1.7, gdje 1 označava dolazno vlakno, 2 kolimirajuću leću dolaznog vlakna (svjetlosni izvor), 3 zaslon odnosno oštricu za zasjenjivanje, 4 savitljivi nosač oštrice, 5 kolimirajuću leću prihvatnog vlakna, 6 prihvatno vlakno te 7 kućište senzora.

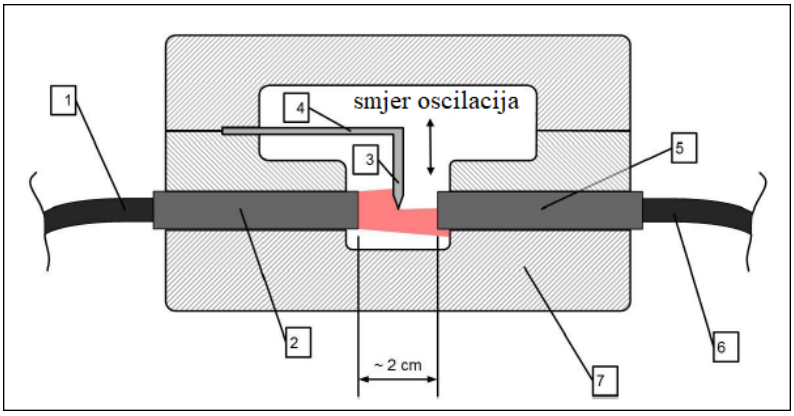

Slika 1.7: Sustav za detekciju vibracija pomoću spregnutih svjetlovoda s modulirajućom oštricom

Na slici 1.8 su prikazani rezultati ostvareni mjerenjem vibracija ovakvim sustavom, pri čemu je na lijevom grafu prikazana dubina modulacije signala na različitim frekvencijama, a na desnom grafu prijenosna funkcija za modulaciju u ovisnosti o primijenjenoj akceleraciji sustava. Ovakva izvedba intenzitetnog senzora za vibracije nije beskontaktna, ali je eliminirana potreba za stacionarnom točkom u mjerenju, odnosno senzor se može postaviti direktno na stroj (ili strukturu) koja vibrira.

Oba predstavljena principa detekcije vibracija spadaju u kategoriju relativno jednostavnih sustava niske cijene. Njihova glavna ograničenja su vezana uz činjenicu da pružaju mogućnost detekcije u jednoj točki te da je detekcija vibracija moguća samo po jednoj osi za rješenje na slici 1.7. Postoje ideje kako proširiti ovaj sustav za detekciju vibracija po dvije osi, no to još nije

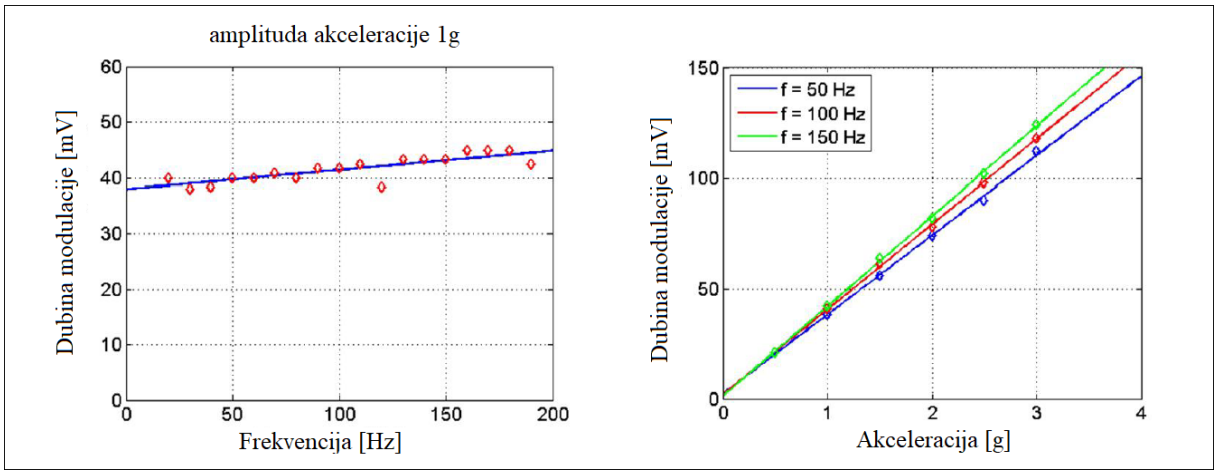

Slika 1.8: Rezultati mjerenja sustavom za detekciju vibracija pomoću spregnutih svjetlovoda s moduli-rajućom oštricom

eksperimentalno isprobano. Iako su takvi sustavi načelno dobri za obavljanje mjerenja u strogo kontroliranim uvjetima i slučajevima kada vibracije očekujemo na točno određenim pozicijama, za generalno praćenje rada/zdravlja velikih strojeva ili struktura mogu biti teško primjenjivi. Naime, ukoliko nije poznato gdje se očekuje kvar, odnosno manifestacija kvara u obliku vibracija, potreban je veći broj pojedinačnih detektora kako bi se pokrilo što više problematičnih točaka. Za generalni, nespecifičan nadzor na velikim strukturama, odnosno strojevima, idealno bi bilo imati kvazi-distribuirani ili pravi distribuirani sustav koji bi mogao istovremeno nadzirati jako veliki broj točaka i trenutačno upozoriti na pojavu problema uz točnu specifikaciju lokacije [18, 19]. Alternativno, integrirani sustav nudi međurješenje za nadziranje cijele strukture ili stroja koje može alarmirati u slučaju problematičnog stanja te pokrenuti daljnje postupanje. U daljnjem postupanju se, upotrebom drugih metoda, može pristupiti utvrđivanju točne lokacije i uzroka problema - detektiranih neželjenih vibracija.

Iako po svojoj osnovi sustav koji je predstavljen i analiziran u ovom radu pripada u malo širu kategoriju intenzitetnih senzora, ipak nije tipičan predstavnik te kategorije. Naime, radi se o specifičnom pristupu temeljenom na preraspodjeli intenziteta ili energije po presjeku vlakna, pri čemu može doći i do promjene ukupne količine energije koja se širi svjetlovodom, ali to nije nužno za mehanizam detekcije. Inače, za tipične predstavnike ove kategorije, je promjena ukupne količine energije u svjetlovodu najčešće nužan uvjet za detekciju. Prema navedenom, predloženi sustav spada u kategoriju integriranih, intrinsičnih intenzitetnih sustava za detekciju vibracija, uz dodatno pojašnjenje - pomoću točkastog uzorka.

1.3 Fabry-Perot interferometarski senzorski sustavi

Fabry-Perot interferometri počivaju na međusobnoj interferenciji višestrukih zraka unutar optičke rezonatorske šupljine, tj. unutar optičke konstrukcije koju omeđuju djelomično propusne

stijenke. U slučaju svjetlovodnih senzora, takva struktura se kreira unutar vlakna upotrebom nekoliko različitih proizvodnih procesa. Na slici 1.9 je prikazan osnovni izgled jednog takvog sustava.

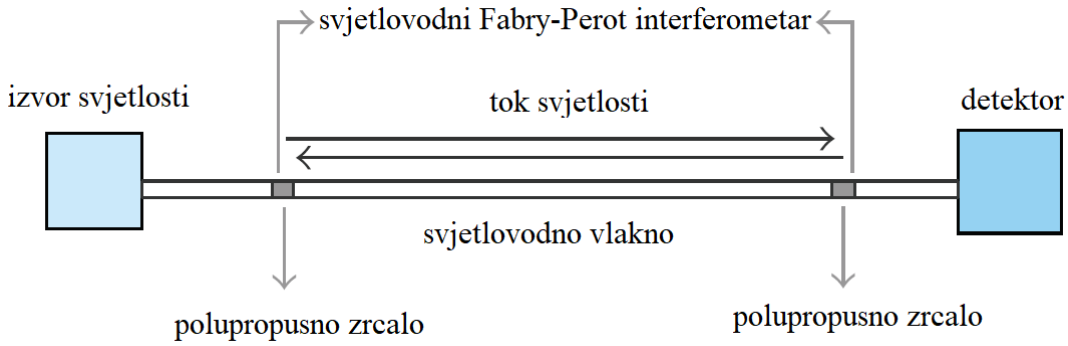

Slika 1.9: Prikaz osnovnih elemenata Fabry-Perot interferometarskog sustava [2].

Moguće su i izvedbe s optičkom šupljinom izvan samog vlakna, te se ovisno o konfiguraciji takvi sustavi nazivaju instrinsičnim (šupljina unutar vlakna) ili ekstrinsičnim (šupljina izvan vlakna) interferometrima. Kao rezultat višestrukih refleksija unutar optičke šupljine i interferencije među pojedinim reflektiranim zrakama, javljaju se interferencijske pruge, odnosno periodičke promjene u električnom signalu, kao rezultatu konverzije optičkog signala. Detekcija počiva na promjeni razmaka između polupropusnih zrcala, odnosno osnovne valne duljine šupljine.
Neke varijante ovakvih mjernih sustava su isprobane i na Zavodu za radiokomunikacije Fakulteta elektrotehnike i računarstva u Zagrebu [20]. U sklopu diplomskog rada je korištena konfiguracija kao na slici 1.10.

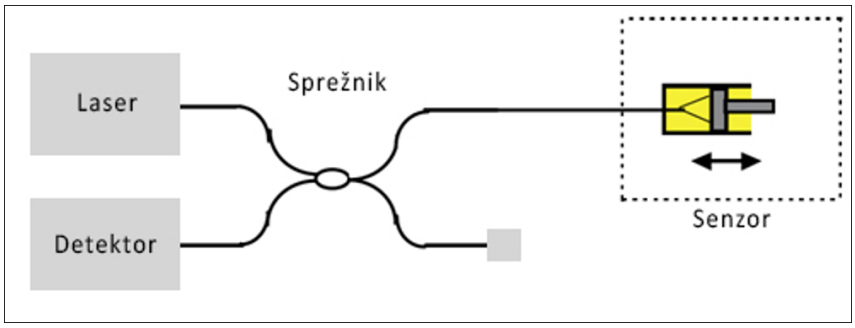

Slika 1.10: Shematski prikaz varijante Fabry-Perot interferometarskog sustava za mjerenje vibracija pomoću svjetlovoda

U ovakvom sustavu detekcija se temelji na različitim putevima koje prevaljuje optički signal u jednom odnosno drugom kraku sustava. Na krajevima dolazi do refleksije i povratni signali se miješaju prije detekcije. Ukoliko postoji razlika u putu koji signali prevaljuju, dolazi do fazne razlike među signalima. U jednom od krakova se zrcalo povezuje s vibracijama i time se mijenja udaljenost koju signal prevaljuje u ovisnosti o vibracijama. Kada među pomiješanim

signalima postoji fazna razlika, rezultat njihovog miješanja varira po amplitudi - smjenjuju se konstruktivna i destruktivna interferencija. Na slici 1.11 je prikazan rezultantni signal iz takvog sustava izloženog vibracijama. Jasno su izraženi ekstremi konstruktivne i destruktivne interferencije što odgovara dobro poznatom uzorku tamnih i svjetlih pruga kod interferometarskih pokusa. Mjerenjem njihovog razmaka i brojanjem vrhova može se odrediti frekvencija i amplituda pomaka koji uzrokuje promjenu faze signala u jednom od krakova, a to nas dovodi do karakterizacije vibracija koje djeluju na krak. Zabilježeni su i primjeri primjene drugih tipova interferometara s posebnim vrstama vlakana [21].

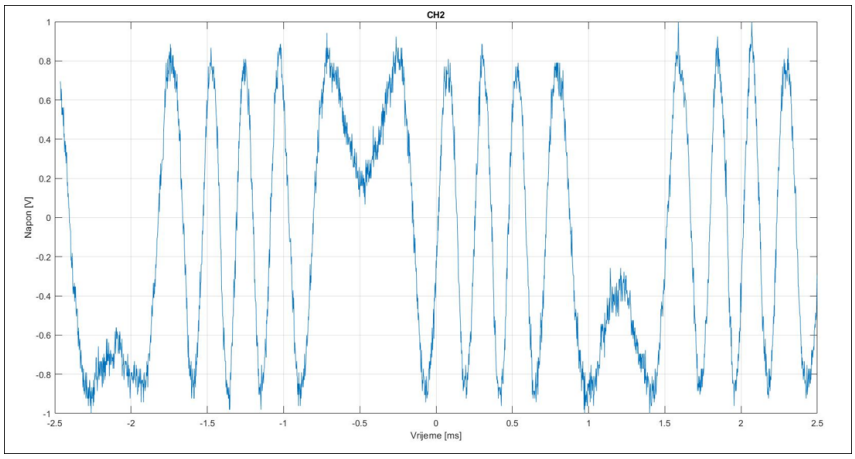

Slika 1.11: Shematski prikaz varijante Fabry-Perot interferometarskog sustava za mjerenje vibracija pomoću svjetlovoda

Iako ovakvi sustavi potencijalno nude visoku preciznost i osjetljivost, njihova izvedba zahtijeva složenije mjerne sustave, odnosno posebno izrađena vlakna, te ih time čini skupljima od prethodno opisanih sustava. Primjeri u literaturi za ovakav tip senzora su navedeni u [22, 23, 24, 25, 26]

1.3.1 Distribuirana detekcija i mjerenje vibracija interferometarskim metodama

Važno je navesti i postojanje sustava koji pružaju mogućnost distribuiranog mjerenja vibracija na relativno velikim udaljenostima (do stotinjak km). Pri tome ostvaruju mogućnost mjerenja u velikom broju točaka prostorne rezolucije 10 m ili bolje [27, 28]. Mjerna svojstva takvih sustava svakako nadilaze mogućnosti mjernog sustava koji se ovim radom predstavlja, ali pri tome ne treba gubiti iz vida važnu činjenicu da je integrirano mjerenje bilo samo jedna od motivacija za izradu ovog mjernog sustava. Druga podjednako važna komponenta je bila jednostavnost i niska cijena sustava. Naime, sustavi koji se mogu pohvaliti mogućnošću distribuiranog mjerenja vibracija nisu temeljeni na analizi točkastog uzorka. Takvi sustavi su u pravilu temeljeni na interferometarskim metodama ili na metodama mjerenja povratnog raspršenja. Iako su rezultati

koje ostvaruju dosta dobri, cijena i kompleksnost takvih sustava su znatno veći od onoga što se u ovom radu predlaže. U slučaju interferometarskih tehnika potrebno je osigurati referentnu granu paralelno sa osjetilnom radi mogućnosti usporedbe faze između signala koji njima putuju. Na slici 1.12 shematski je prikazano nekoliko osnovnih oblika senzora za vibracije temeljenih na interferometarskim tehnikama.

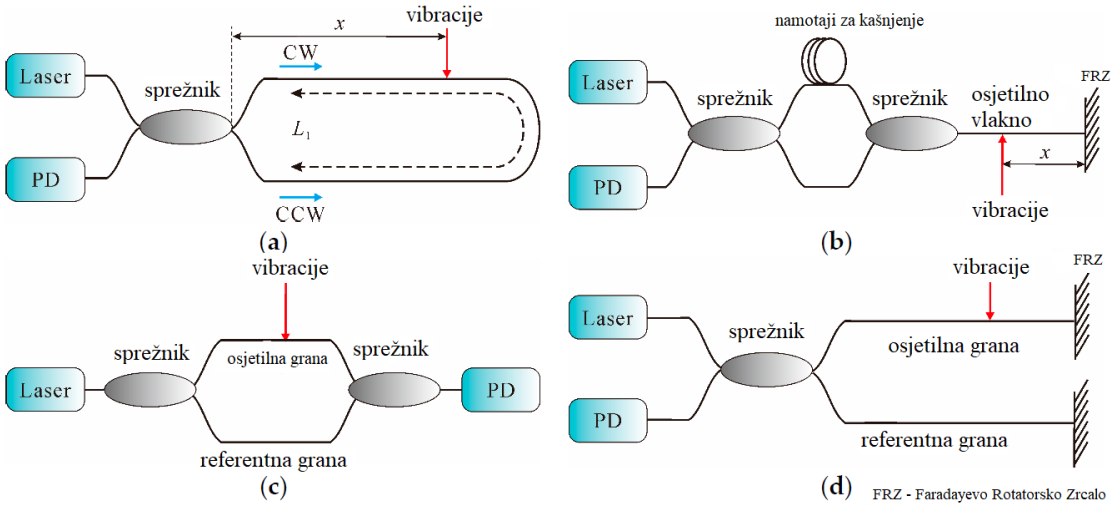

Slika 1.12: Shematski prikazi nekoliko interferometarskih metoda za detekciju vibracija pomoću svjetlovoda:
a) Sagnacov senzor temeljen na konfiguraciji petlje; b) Sagnacov senzor u inline izvedbi; c) Mach-Zehnder interferometarski (MZI) senzor i d) Michelsonov interferometarski (MI) senzor [27].

U slučajevima kada sustav sadrži i referentnu i osjetilnu granu, potrebno je referentnu granu izolirati od vanjskih utjecaja koje se pokušava izmjeriti. To znatno povećava kompleksnost i cijenu takvih sustava u praktičnim izvedbama. Među njima su najčešće korišteni Sagnacovi interferometarski senzori koji mogu detektirati poziciju za jedan izvor vibracija. Međutim, ukoliko dođe do istovremenog djelovanja više izvora nije više moguće locirati niti jedan od njih zbog toga što dođe do nestajanja pravilnog rasporeda nul točaka interferencije. Osim toga, nije ih moguće koristiti na niskim frekvencijama zbog karakteristika samog interferometra. Navedeni nedostatci se mogu donekle kompenzirati složenijom obradom signala, međutim time sustav postaje još kompleksniji.

MZI pristup je nešto jeftiniji, ali ima samo mogućnost detekcije vibracija, a ne i lociranja njihovog izvora. To znači da nudi podjednaku funkcionalnost kao i sustav koji je tema ovog rada, ali je izvedba u slučaju MZI senzora složenija. Daljnjim dodavanjem paralelnih grana i detektorskih elemenata moguće je postići lokalizaciju, ali uz značajan porast cijene sustava. Primjer je dualni MZI sustav prikazan na slici 1.13.

Naposljetku, MI senzorski sustavi su također testirani u proširenim varijantama kako bi se pokušalo kompenzirati nedostatke koji su proizlazili iz osnovne izvedbe. To je rezultiralo dulanim MI (DMI) senzorskim sustavom prikazanim na slici 1.14.

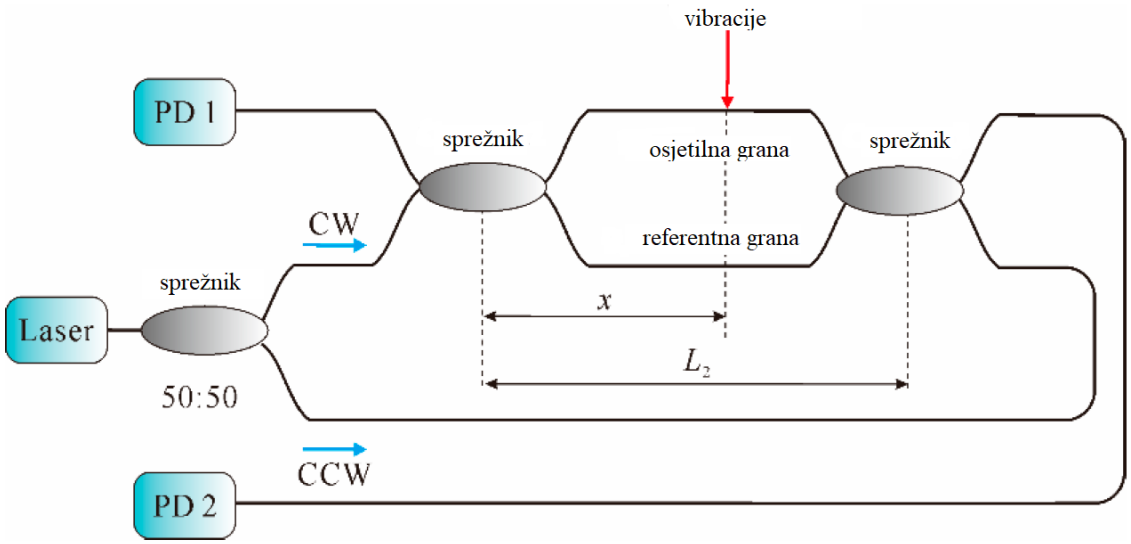

Slika 1.13: Shematski prikaz za DMZI senzor za vibracije [27].

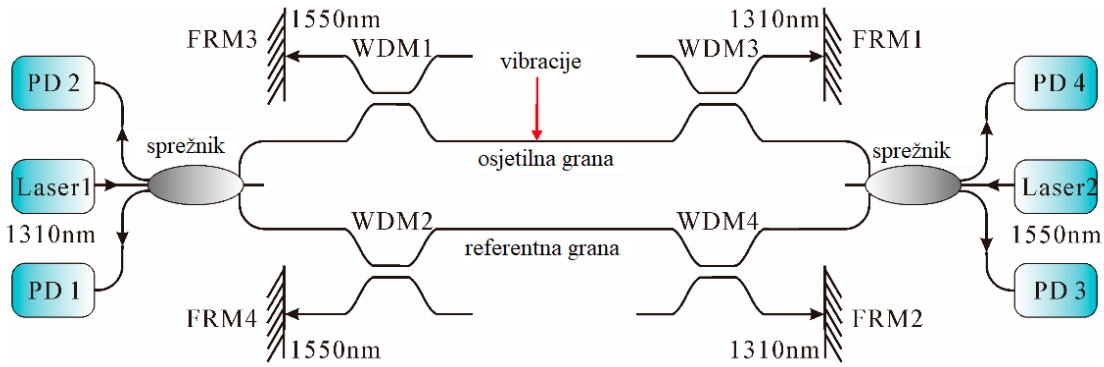

Slika 1.14: Shematski prikaz za DMI senzor za vibracije [27]; WDM - Multipleksiranje po valnoj duljini (*Wavelength Division Multiplexing*); FRM - Faradayevo rotirajuće zrcalo (*Faraday Rotating Mirror*).

Iskušavane su i razne kombinacije navedenih interferometarskih sustava koje su bile manje ili više uspješne u detekciji vibracija, međutim svi su sustavi bili podjednako složeni ili složeniji od upravo navedenih.

1.3.2 Distribuirana detekcija i mjerenje vibracija metodama povratnog raspršenja

Kod metoda temeljenih na povratnom raspršenju signala (Rayleigh-evo raspršenje) osnovni mehanizmi rada su već jako dobro poznati kroz OTDR (*Optical Time Domain Reflectometry*) sustave za nadzor telekomunikacijske mreže, ali su prilagođeni za senzorske primjene. Primjenom faznog OTDR-a mjeri se promjena faze u odnosu na referentno mjerenje. Na slici 1.15 je shematski prikazana adaptacija sustava kako bi se princip rada OTDR-a proširio na detekciju vibracija pomoću ukopanog vlakna. Oba vlakna se pobuđuju istovremeno i usporedbom signala

iz oba vlakna se dobiju informacije o vibracijama. Iako sustav ostvaruje impresivne rezultate s mogućnostima detekcije izvora vibracije duž 12 km vlakna na udaljenosti do 4,5 m od vlakna, iz shematskog prikaza je očito da se radi o vrlo kompleksnom sustavu. Ostali sustavi koji se temelje na istom principu rada su još kompleksniji i više cijene izvedbe.

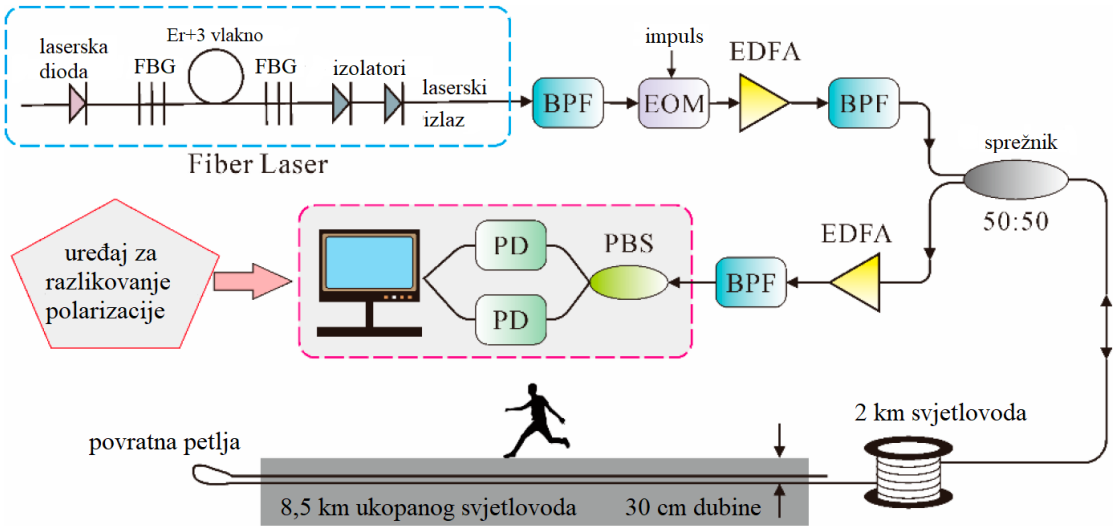

Slika 1.15: Shematski prikaz sustava za mjerenje vibracija pomoću povratnog raspršenja: BPF - pojasno propusni filtar; EOM - elektro optički modulator; EDFA - erbijem dopirano vlakno s pojačanjem; PBS - *Polarization Beam Splitter* [27].

1.4 Senzorski sustavi temeljeni na Braggovim rešetkama

Princip detekcije ovakvih senzorskih sustava počiva na implementaciji periodičkih struktura u samom svjetlovodnom vlaknu. Periodička struktura se sastoji od niza polupropusnih zrcala koja nastaju malim izmjenama indeksa loma jezgre. Implementacijom takve strukture postiže se izrazita reflektivnost za određenu valnu duljinu (povezano s periodom rešetke), dok je za druge valne duljine struktura *prozirna*. Vanjskim djelovanjem, odnosno naprezanjem vlakna, mijenja se duljina vlakna, a time i perioda strukture. U skladu s promjenom periode dolazi do *crvenog* ili *plavog* pomaka reflektirane valne duljine [22]. Navedeni princip je prikazan na slici 1.16. Pomoću Braggovih rešetki moguće je mjeriti naprezanja vlakna, odnosno temperaturu okoline vlakna. Posebno su pogodne za implementaciju kvazi-distribuiranih senzora jer je moguće izraditi vlakno s višestrukim FBG-ovima za različite valne duljine na različitim pozicijama u vlaknu.

Kada je vlakno izloženo vibracijama, dolazi do periodičkih istezanja i sabijanja vlakna, a time i ugrađene Braggove rešetke. Spektralne komponente rezultantnog signala na određenim valnim duljinama variraju zajedno s periodom Braggove rešetke. Iako je u izvedbama detekcijskih sustava za vibracije sam mjerni sustav nešto složeniji od ponuđenog opisa, osnovni

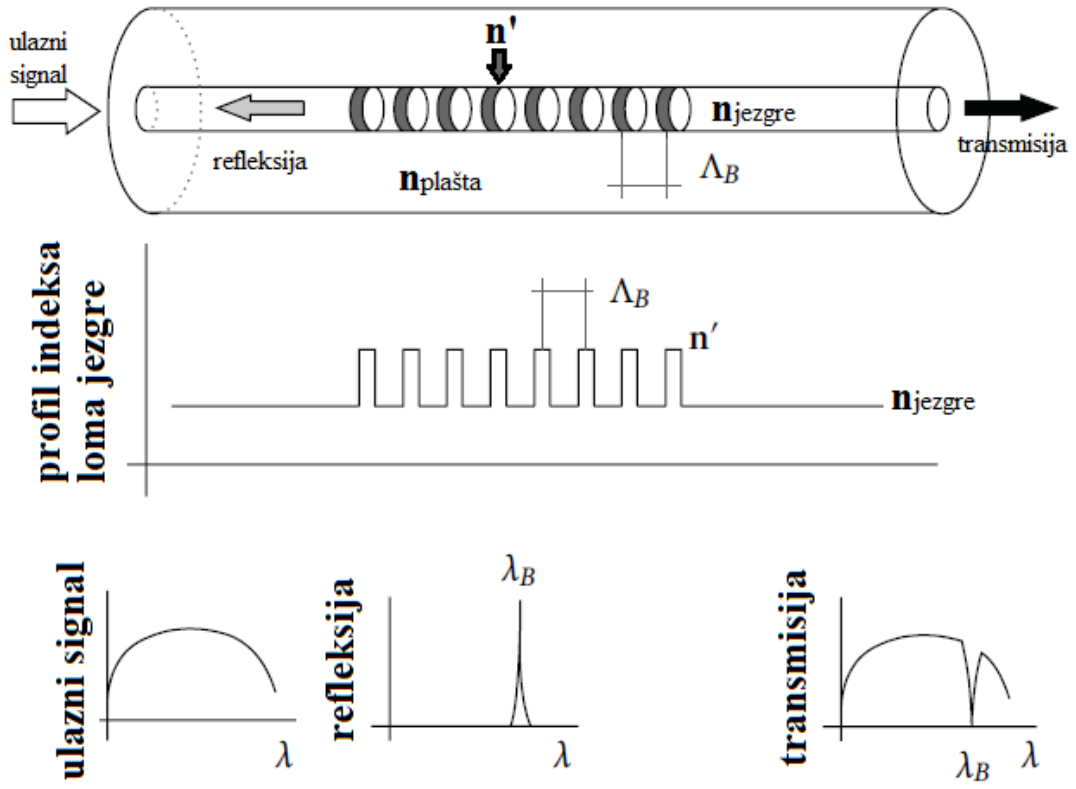

Slika 1.16: Prikaz principa djelovanja Braggove rešetke u svjetlovodnom vlaknu [2].

mehanizam je identičan. Jedan od osnovnih problema sustava za mjerenje naprezanja pomoću FBG-a je udvojena ovisnost rezultata o temperaturi i naprezanju. Kako bi se eliminirao utjecaj temperature u odnosu na naprezanje, sustavi najčešće implementiraju dodatnu mjernu granu s identičnom FBG koja je izolirana od naprezanja, a dijeli istu temperaturu kao i glavna grana. Oduzimanjem signala kompenzacijske grane od signala glavne grane može se eliminirati utjecaj temperature na konačni rezultat mjerenja naprezanja [29, 30].

Poglavlje 2

Točkasti uzorak svjetlovoda (*specklegram*)

U ovom poglavlju opisan je nastanak točkastog uzorka prilikom širenja optičkog signala svjetlovodom. Dan je kratak uvid u fizikalne razloge zbog kojih dolazi do promjena u uzorku kada se vlakno izloži djelovanju vanjske mehaničke sile, a zatim je predstavljena matematička analiza problematike. Obrazloženo je kako se ta pojava može iskoristiti za detekciju i parametrizaciju vanjskih utjecaja na vlakno te je navedeno nekoliko primjera svjetlovodnih detektorskih sustava koji to iskorištavaju.

2.1 Nastanak točkastog uzorka u vlaknu

Kada se u višemodni svjetlovod ubaci koherentni elektromagnetski signal, u pravilu laserski optički signal, vlaknom se širi cijeli niz pojedinačnih modova. Svaki mod predstavlja jedno od mogućih rješenja distribucije elektromagnetskog polja u dielektričnom valovodu, odnosno svjetlovodnom vlaknu. Na slici 2.1 prikazana je raspodjela energije u planarnom valovodu za nekoliko osnovnih modova prema [31].
Valovodni mehanizam širenja signala je najjednostavnije objasniti za slučaj planarnog svjetlovoda kod kojeg modove možemo odrediti primjenom geometrijske optike (slika 2.2).

Amplitude tih rješenja modova, odnosno *zraka*, variraju s obzirom na izvorni kut upada svjetlosti u vlakno (vezano uz kut pod kojim se signal reflektira od granice između jezgre i plašta svjetlovoda). Prema Snellovom zakonu, zbog razlike u indeksu loma materijala jezgre i plašta, bilo koja zraka koja upada na granicu pod kutem većim od kritičnog, na granici se u potpunosti reflektira. U idealnim uvjetima, u kojima je vlakno položeno bez ikakvih zakrivljenja i nije podložno vanjskim djelovanjima (temperature ili mehaničkog naprezanja i sl.), upadni signal bi se duž cijelog vlakna uvijek reflektirao na isti način, odnosno pod istim kutem. Dodatna pretpostavka za takav rezultat je i savršena homogenost vlakna, odnosno materijala od kojega je izrađeno, kao i savršena geometrija izrade samog vlakna. Pri tome vlaknom propagiraju samo signali koji se nakon dvostruke refleksije u fazi *slažu* s nereflektiranim signalom, odnosno daju

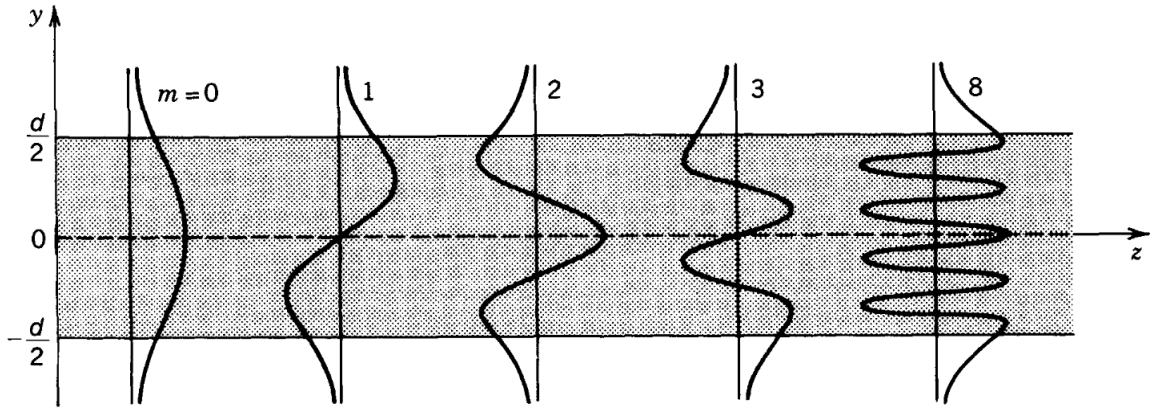

Slika 2.1: Raspodjela polja nekoliko osnovnih modova po presjeku svjetlovoda za smjer širenja zračenja duž osi planarnog svjetlovoda. Na z osi je prikazano električno polje za različite modove m u ovisnosti o udaljenosti od osi valovoda y.

konstruktivnu interferenciju. Ostali signali, zbog destruktivne prirode interferencije, iščezavaju nakon nekog broja refleksija. Time je ograničen ukupni broj modova koji se mogu na taj način svjetlovodom širiti.

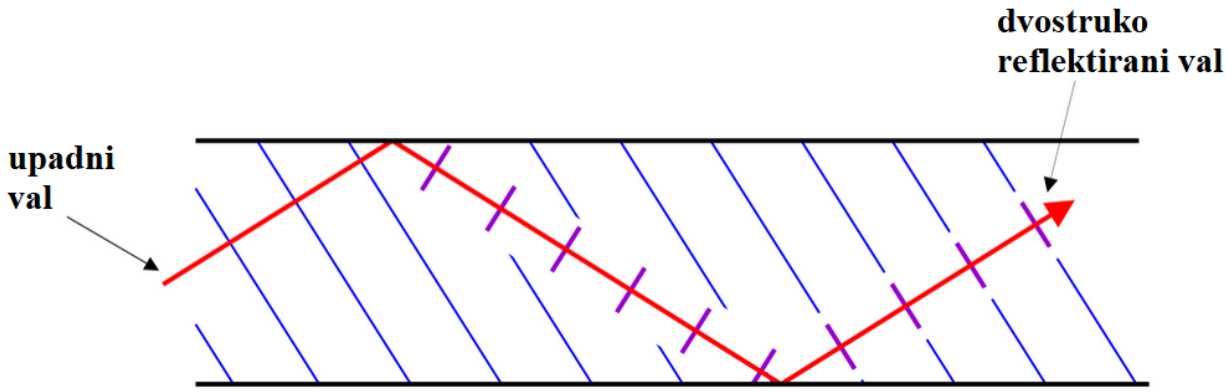

Slika 2.2: Poklapanje u fazi za zrake koje upadaju na granicu jezgre svjetlovoda pod kutem većim od kritičnog [31].

Na bilo kojoj lokaciji duž svjetlovoda takvi pojedinačni modovi se po presjeku svjetlovoda raspoređuju na način specifičan za tu određenu lokaciju. Pri tome se po ukupnoj površini presjeka jezgre izmjenjuju pozicije na kojima je suma svih upadnih svjetlosnih signala konstruktivna i većeg intenziteta od onog pojedinačnih zraka, ali i pozicije na kojima je slučaj upravo suprotan. Zbog toga promatranjem distribucije intenziteta svjetlosti po presjeku vlakna možemo uočiti tzv. točkasti uzorak (*speckle pattern* ili *specklegram*). Svojstva takvog uzorka su detaljno opsana u [32],a izgled je prikazan na slici 2.3. U idealnom slučaju bi takav uzorak na nekoj poziciji bio vremenski nepromjenjiv, dok se prostorno, duž vlakna, mijenja zbog različite brzine širenja pojedinih modova.

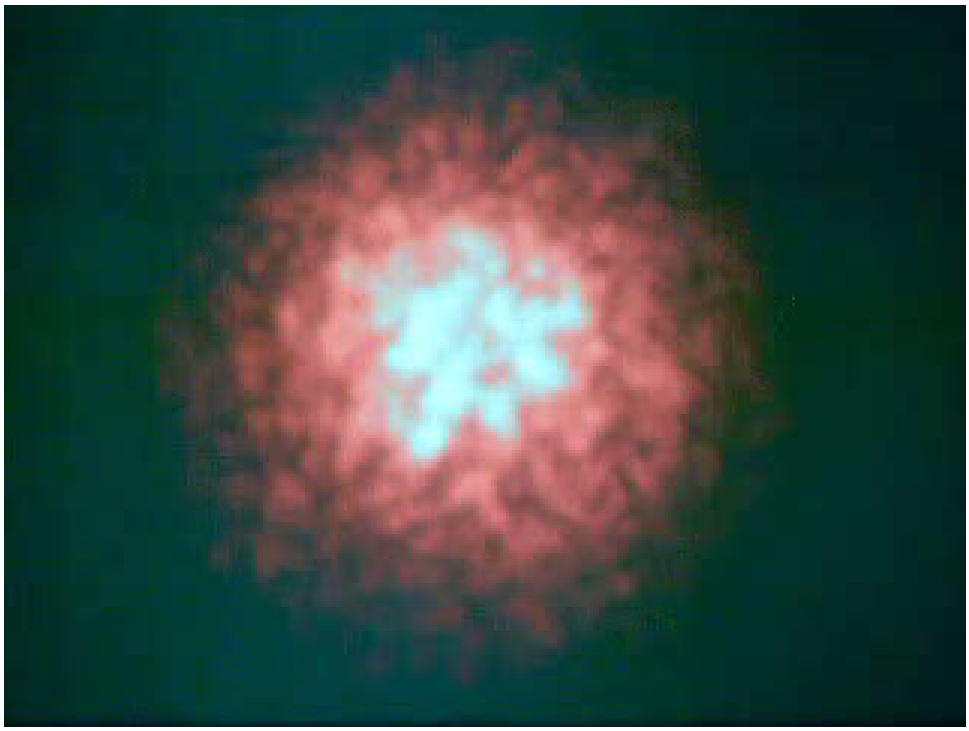

Slika 2.3: Izgled točkastog uzorka projiciranog s kraja svjetlovodnog vlakna na zaslon u slobodnom prostoru

2.2 Lokalne nepravilnosti na vlaknu

U realnim slučajevima vlakno donekle zadovoljava pretpostavku homogenosti po pitanju materijala i geometrije, ali teško može biti položeno bez ikakvih naprezanja (torzija ili savijanja) te izolirano od temperaturnih promjena. Zbog toga generalno ne vrijedi pretpostavka o zadržavanju kuta refleksije duž cijelog vlakna za pojedini mod, već se kod svake nepravilnosti vlakna kutevi refleksije mijenjaju. To znači da je matematički izrazito teško opisati i predvidjeti kako će nekakav vanjski utjecaj (bez obzira na njegovu prirodu) izmijeniti distribuciju energije u točkastom uzorku, iako su zabilježena istraživanja u kojima se tvrdi da je to moguće napraviti [33]. Međutim, to ujedno nudi i objašnjenje zašto je ovakav predloženi senzorski sustav integriranog karaktera. S obzirom da vlakno cijelom svojom dužinom može biti izloženo raznim vanjskim djelovanjima (savijanju, pritisku, torziji, promjeni temperature), na svim lokacijama duž vlakna može doći do lokalne promjene distribucije energije po presjeku vlakna. Takva promjena automatski povlači za sobom promjene u svim segmentima vlakna koji se nalaze nakon pozicije na kojoj je došlo do perturbacije svjetlovoda. Na poziciji na kojoj promatramo točkasti uzorak nije moguće ustanoviti gdje na vlaknu je došlo do perturbacije, odnosno fizičke uzbude vlakna, moguće je samo ustvrditi da se promjena dogodila negdje prije promatranog segmenta. Ukoliko bi se vlakno moglo izolirati od vanjskih utjecaja po svim segmentima osim onog pomoću kojega želimo obavljati detekciju, lokalizacija bi bila moguća. Alternativno, može se postići da je vlakno značajno podložnije perturbacijama na detektorskoj poziciji, pa se na taj način

izolira tražena pojava od ostalih smetnji. Detaljnu matematičku analizu događanja prilikom jednostavnih lokalnih izobličenja na vlaknu može se pronaći u [34].

2.3 Princip detekcije vanjskih utjecaja

Za princip rada ovog sustava, na sreću, nije nužno da vlakno bude u potpunosti matematički opisano, odnosno da se može analizirati put optičkog signala kroz cijelo vlakno. Naime, kako god da vlakno jest položeno, zakrivljeno, pritisnuto ili napregnuto, konačni rezultat širenja signala je nekakav točkasti uzorak. Njega je doduše nemoguće matematički predvidjeti, odnosno iz njega nije moguće odrediti kako izgleda vlakno i što sve na njega djeluje, ali ukoliko se okolina vlakna ne mijenja značajno i uzorak bi trebao biti relativno konstantan kao što je prikazano na slici 2.4.

Zatim jedan segment vlakna izložimo vanjskom utjecaju - mehaničkim vibracijama i promatramo kako se distribucija optičkog signala u točkastom vlaknu mijenja, što je prikazano na slici 2.5.

Zbog vanjskog mehaničkog djelovanja dolazi do lokalizirane promjene geometrije vlakna i gustoće materijala te se zbog toga mijenjaju kutevi pod kojima se zrake pojedinih modova reflektiraju od granice između jezgre i plašta svjetlovoda. Posljedično, dolazi do preraspodjele energije među modovima koji se šire duž svjetlovoda, odnosno modovi se više ne šire na jednak načini kroz ostatak svjetlovoda i mijenja se točkasti uzorak na svim slijednim segmentima svjetlovoda.

U slučaju kada ne dolazi do prevelikog savijanja svjetlovoda (radijus savijanja veći od nekoliko centimetara) ne dolazi ni do gušenja ukupnog signala, odnosno do značajnijeg *izbacivanja* pojedinih modova iz jezgre vlakna što je opisano jednadžbom (2.1). Pri tome se oni nastavljaju širiti vlaknom, ali nekom izmijenjenom putanjom u odnosu na prethodnu, kada vlakno nije bilo pod vanjskim utjecajem. Konačni rezultat tog procesa je da pojedine zrake ostaju unutar vlakna i šire se njime, ali njihove putanje više ne odgovaraju prethodnim putanjama širenja. Usporedbom uzorka iz dva različita trenutka možemo ustanoviti je li u međuvremenu vlakno bilo izloženo vanjskom mehaničkom djelovanju.

$$I_T = \sum_{i=1}^{N} I_i = constant, \tag{2.1}$$

pri čemu je I_T ukupni intenzitet optičkog signala u svjetlovodu.

Ukoliko takvu usporedbu provodimo kontinuirano u vremenu, možemo dobiti *signal promjene* koji je koreliran sa silom koja je na vlakno djelovala [35], što je prikazano na slici 2.6. Daljnjom analizom takvog signala moguće je parametrizirati mehaničku silu, odnosno odrediti joj frekvenciju i amplitudu.

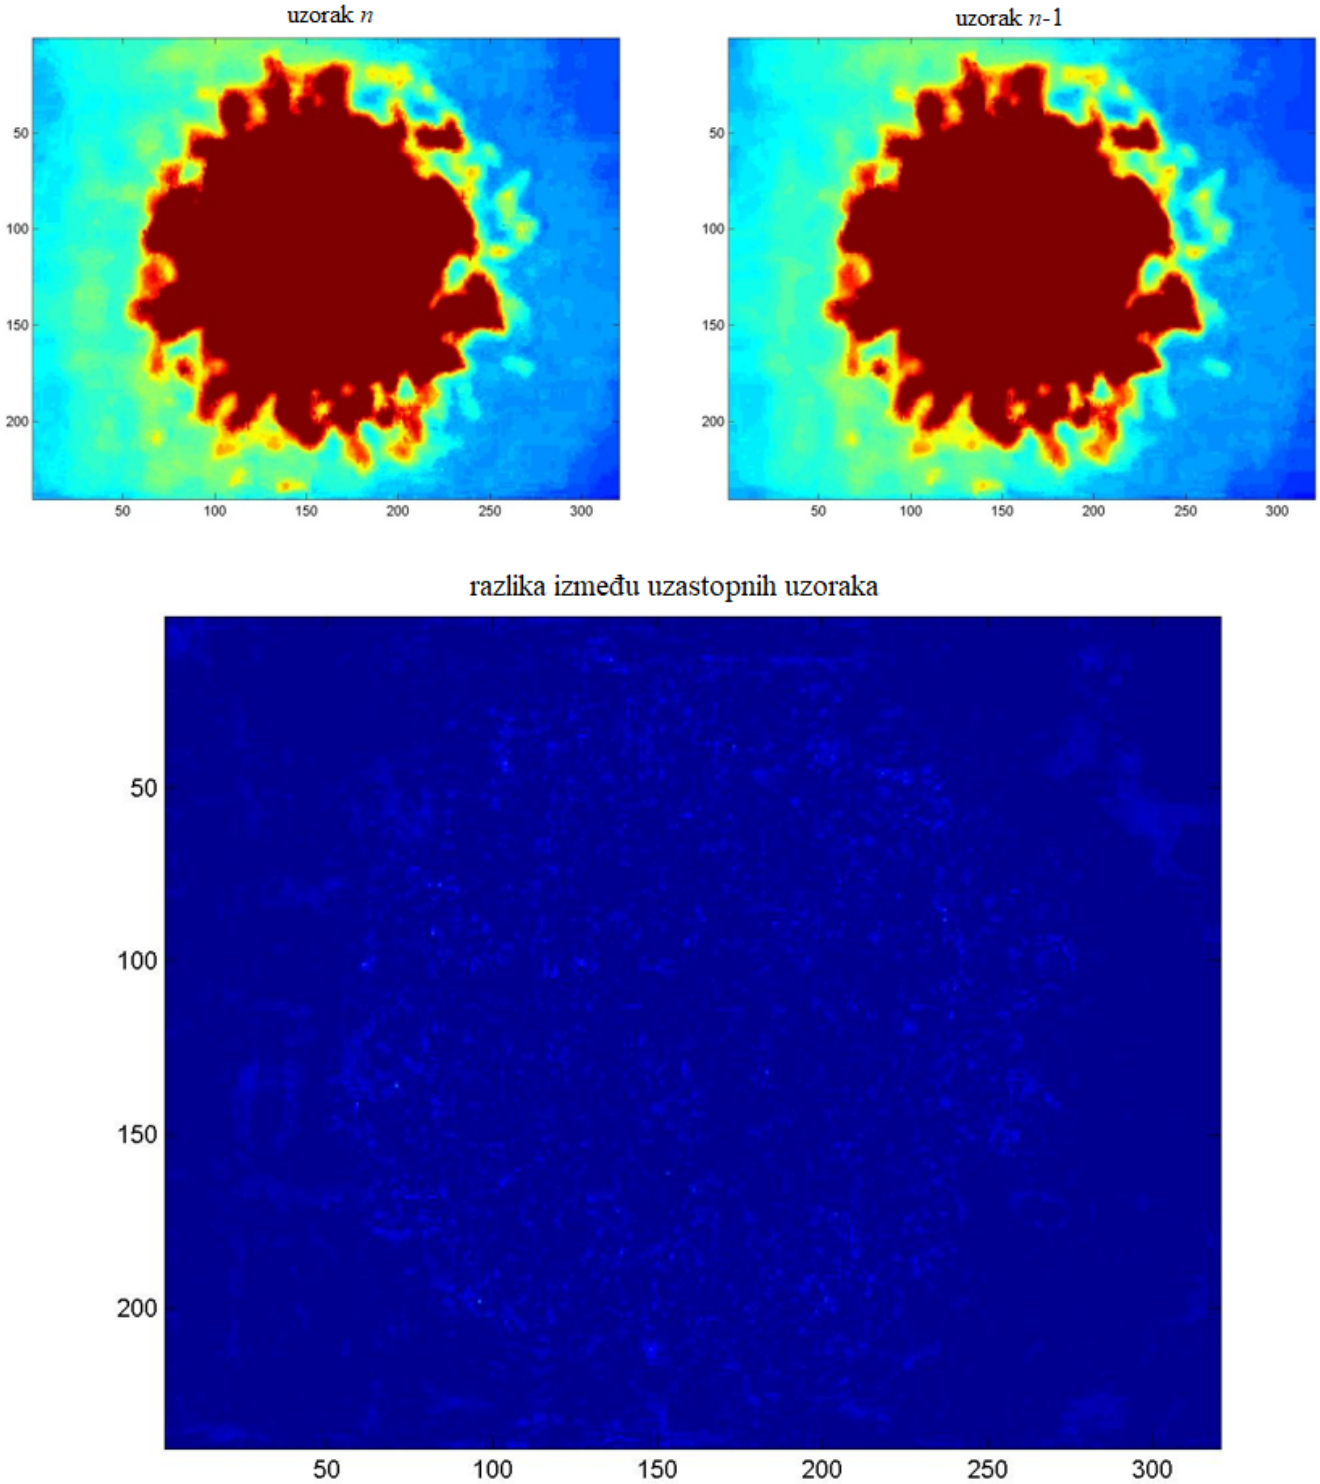

Slika 2.4: Razlika između uzastopnih uzoraka kada nema vanjskog djelovanja na vlakno

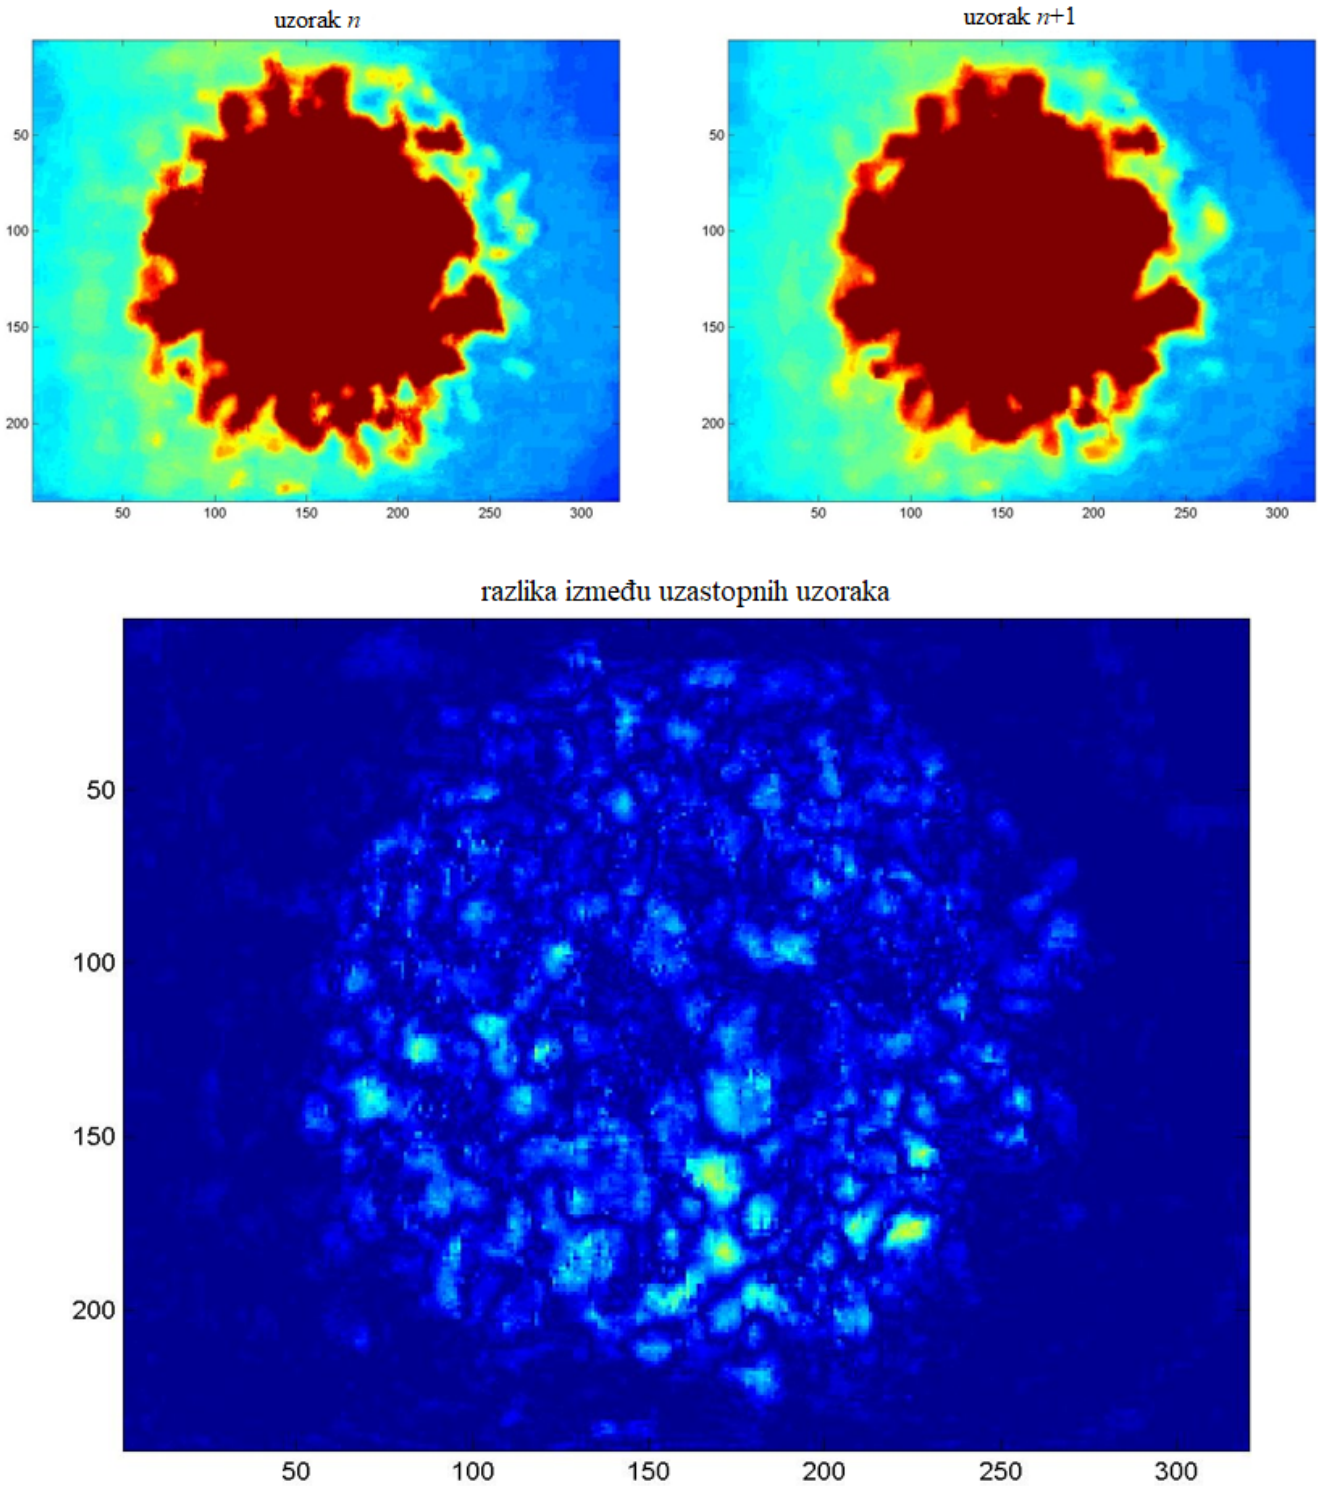

Slika 2.5: Razlika između uzastopnih uzoraka kada je vlakno izloženo utjecaju vanjske sile

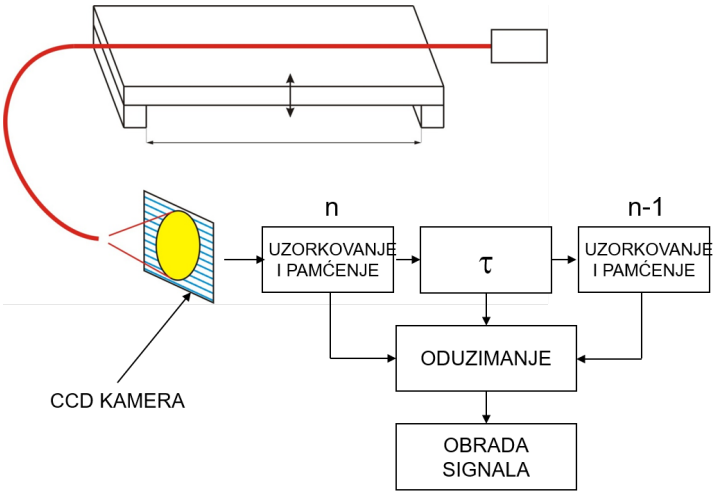

Slika 2.6: Shematski prikaz principa rada

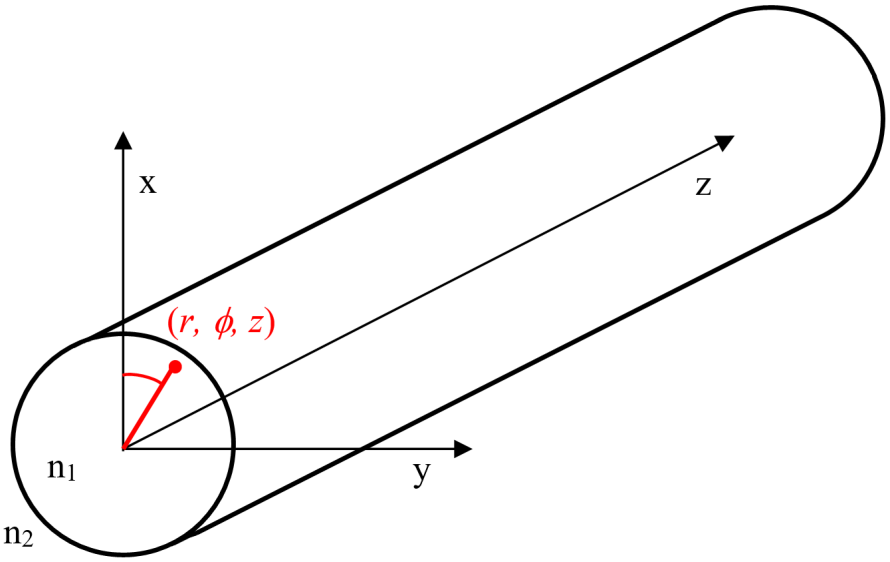

Slika 2.7: Radijalni koordinatni sustav sa $\hat{z}$ osi postavljenom duž vlakna

Za vlakno prikazano na slici 2.7 jednadžbe koje opisuju električno i magnetsko polje unutar vlakna mogu se zapisati na sljedeći način:

$$\vec{E} = \vec{E}_0(r,\phi)e^{j(\omega t - \beta_z z)} \tag{2.2}$$

$$\vec{H} = \vec{H}_0(r,\phi)e^{j(\omega t - \beta_z z)} \tag{2.3}$$

Njihove komponente u smjeru osi z možemo prikazati kao kombinaciju nekoliko funkcija:

$$E_z(r,\phi,z,t) = A \cdot F_1(r) \cdot F_2(\phi) \cdot F_3(z) \cdot F_4(t). \tag{2.4}$$

Za F_3 i F_4 pretpostavljen je oblik:

$$F_3(z) \cdot F_4(t) = e^{j\omega t} \cdot e^{-j\beta z}. \tag{2.5}$$

Osim toga, zbog simetrije u cilindričnom koordinatnom sustavu, može se pretpostaviti:

$$F_2(\phi) = e^{jm\phi}, \tag{2.6}$$

pri čemu vrijedi:

$$F_2(\phi) = F_2(\phi + 2\pi), \tag{2.7}$$

a m je cijeli broj u rasponu od $-\infty$ do $+\infty$.
Za F_1 vrijedi:

$$\frac{\partial^2 F_1}{\partial r^2} + \frac{1}{r}\frac{\partial F_1}{\partial r} + \left(q^2 - \frac{m^2}{r^2}\right)F_1 = 0, \tag{2.8}$$

što je oblik Besselove jednaždbe, čija su rješenja Besselove funkcije prikazane na slikama 2.8 i 2.9 . Analogni izvod vrijedi za H_z.

Kako Besselove funkcije druge vrste imaju singularitet kada $r \to 0$, slijedi da su za $r < a$ rješenja u obliku Besselovih funkcija prve vrste

$$E_z(r < a) = AJ_m(ur)e^{jm\phi}e^{j(\omega t - \beta_z z)} \tag{2.9}$$

$$H_z(r < a) = BJ_m(ur)e^{jm\phi}e^{j(\omega t - \beta_z z)}. \tag{2.10}$$

Pri tome su A i B konstante koje je potrebno odrediti, a vrijedi:

$$u^2 = k_0^2 n_1^2 - \beta_z^2. \tag{2.11}$$

Budući da je funkcija polja u plaštu eksponencijalno padajuća, moramo malo izmijeniti Besselovu jednadžbu:

$$\frac{\partial^2 F_1}{\partial r^2} + \frac{1}{r}\frac{\partial F_1}{\partial r} - \left(w^2 + \frac{m^2}{r^2}\right)F_1 = 0, \tag{2.12}$$

pri čemu se uvodi:

$$w^2 = -q^2 = \beta_z^2 - k_0^2 n_2^2. \tag{2.13}$$

Iz svega navedenog slijedi da su za $r > a$ rješenja jednadžbi električnog i magnetskog polja

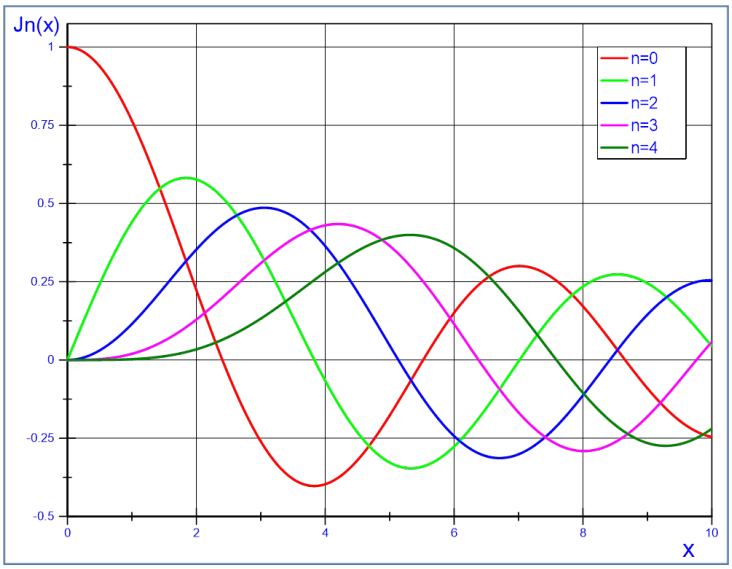

Slika 2.8: Besselove funkcije $J_n(x)$ prvog reda

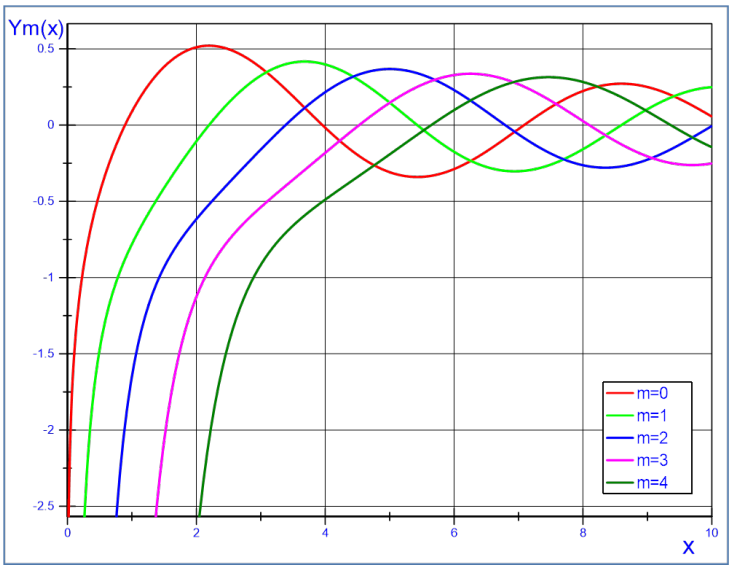

Slika 2.9: Besselove funkcije $Y_n(x)$ drugog reda

u obliku:

$$E_z(r > a) = CK_m(wr)e^{jm\phi}e^{j(\omega t - \beta_z z)} \tag{2.14}$$

za električno, odnosno:

$$H_z(r > a) = DK_m(wr)e^{jm\phi}e^{j(\omega t - \beta_z z)} \tag{2.15}$$

za magnetsko polje.

Uvjet da u i w moraju biti realni brojevi za svjetlovod bez gubitaka ima kao posljedicu

ograničenje za koeficijent rasprostiranja β_z:

$$n_2 k_0 \leq \beta_z \leq n_1 k_0. \tag{2.16}$$

Karakteristična jednadžba za koeficijent rasprostiranja β_z dobiva se iz uvjeta da je tangencijalno električno i magnetsko polje kontinuirano na granici jezgre i plašta. Karakteristična jednadžba glasi:

$$(\mathscr{J}_m + \mathscr{K}_m)({k_0}^2 {n_1}^2 \mathscr{J}_m + {k_0}^2 {n_2}^2 \mathscr{K}_m) = \left(\frac{m\beta_z}{a}\right)^2 \left(\frac{1}{u^2} + \frac{1}{w^2}\right), \tag{2.17}$$

pri čemu vrijedi:

$$\mathscr{J}_m = \frac{J'_m(ua)}{uJ_m(ua)}, \quad \mathscr{K}_m = \frac{K'_m(wa)}{wK_m(wa)} \tag{2.18}$$

2.3.1 Broj modova u svjetlovodu

U svrhu lakšeg uspoređivanja svjetlovodnih vlakana različitih indeksa loma n_1 za jezgru i n_2 za plašt te polumjera jezgre a, uobičajeno je razmatrati normiranu frekvenciju:

$$V = \frac{\omega}{\omega_0}, \quad \text{gdje je} \quad \omega_0 = \frac{c}{a\sqrt{n_1^2 - n_2^2}}. \tag{2.19}$$

Stoga vrijedi:

$$V = \frac{\omega}{c} a \sqrt{n_1^2 - n_2^2} = \frac{2\pi}{\lambda_0} a \sqrt{n_1^2 - n_2^2} = k_0 a \sqrt{n_1^2 - n_2^2}. \tag{2.20}$$

Pomoću tog bezdimenzionalnog broja možemo odrediti koliko se modova širi u svjetlovodu.

Da bismo odredili broj modova koji se može širiti jezgrom svjetlovoda promatrat ćemo Besselovu funkciju $J_{\kappa-1}$ koja opisuje distribuciju komponenti polja E_z i H_z u jezgri:

$$J_{\kappa-1}(x) \cong \sqrt{\frac{2}{\pi x}} \cos\left(x - \frac{\kappa\pi}{2} + \frac{\pi}{4}\right), \quad x >> 1. \tag{2.21}$$

Uz fiksiranu kutnu promjenjivost κ dobivamo da za najviši mod koji se može širiti vrijedi:

$$V = u_{\kappa, M_\kappa} a = \frac{\pi}{2}(\kappa + 2M_\kappa), \tag{2.22}$$

odnosno da je:

$$M_\kappa = \frac{V}{\pi} - \frac{\kappa}{2}. \tag{2.23}$$

Ukupni broj modova je jednak:

$$M = 4\sum_{\kappa=0}^{\kappa_{max}} M_\kappa = 4\sum_{\kappa=0}^{\kappa_{max}} \left(\frac{V}{\pi} - \frac{\kappa}{2}\right) = 4\cdot\left[\frac{V}{\pi}(\kappa_{max}+1) - \frac{1}{2}\frac{\kappa_{max}(\kappa_{max}+1)}{2}\right], \tag{2.24}$$

pri čemu faktor 4 predstavlja ortogonalna rješenja orjentacije električnog i magnetskog polja za linearno polarizirane modove u definiranom sustavu.

Iz navedene jednadžbe možemo odrediti κ_{max} jer za njega vrijedi da je $M_{\kappa_{max}} = 0$. Dobijemo da je $\kappa_{max} = 2V/\pi$. Iz toga slijedi:

$$M = 4\cdot\left[\frac{2V^2}{\pi^2} + \frac{V}{\pi} - \frac{V^2}{\pi^2} - \frac{V}{2\pi}\right] = \frac{4V^2}{\pi^2} + \frac{2V}{\pi} \tag{2.25}$$

Taj izraz se može pojednostaviti na

$$M \cong \frac{V^2}{2}, \tag{2.26}$$

odnosno:

$$M \cong \frac{1}{2}\left(\frac{2\pi a}{\lambda_0}\right)^2 \cdot \left(n_1^2 - n_2^2\right) = \frac{1}{2}\left(\frac{2\pi a}{\lambda_0}\right)^2 \cdot (NA)^2 \tag{2.27}$$

Za višemodno vlakno tipičnih karakteristika:
$n_1 = 1,46$
$n_2 = 1,45$
$2a = 50\mu\text{m}$
te valnu duljinu crvene laserske svjetlosti koju smo koristili u pokusima
$\lambda_0 = 0,65\mu\text{m}$
vrijedi:
$NA = 0,17$
$V = 41,19$
pa broj modova iznosi približno
$M \approx 850$.

2.4 Utjecaj vanjske sile na raspodjelu polja u svjetlovodu

Prema [35] veza između prostorne distribucije svjetlosti i mehaničke sile koja djeluje na vlakno može se matematički zapisati kako slijedi. Linearno polarizirane komponente elektromagnet-

skog vala u svjetlovodu sa stepeničastim indeksom loma mogu se zapisati kao:

$$\vec{E} = \sum_{m=0}^{N'} A_m J_{n_m}(u_m r)\cos(n_m\theta)\exp[-i(\beta_m z - \phi_m)]\hat{x}, \tag{2.28}$$

$$\vec{H} = n_1\sqrt{\frac{\varepsilon_0}{\mu_0}}\sum_{m=0}^{N'} B_m J_{n_m}(u_m r)\cos(n_m\theta)\exp[-i(\beta_m z - \phi_m)]\hat{y}, \tag{2.29}$$

odnosno:

$$\vec{H} = -Y\hat{z}\times\vec{E}, \tag{2.30}$$

uz:

$$Y = n_1\sqrt{\frac{\varepsilon_0}{\mu_0}}, \tag{2.31}$$

pri čemu je N' broj modova koji se šire svjetlovodom, β_m je propagacijska konstanta za m-ti mod, ϕ_m je slučajni faktor faze, odnosno početne faze povezane s m-tim modom, Y je karakteristična admitancija jezgre vlakna, r je normalizirani radijus, n_1 je indeks loma jezgre, u_m je modalni parametar definiran jednadžbom:

$$u_m = a\sqrt{k^2 n_1^2 - {\beta_m}^2}, \tag{2.32}$$

pri čemu je k valni broj u vakuumu te a radijus vlakna.

Prostorna raspodjela intenziteta svjetlosti u svjetlovodu je dana izrazom:

$$I = \frac{1}{2}Re\left\{\left(\vec{E}\times\vec{H}\right)\cdot\hat{z}\right\}. \tag{2.33}$$

Uvrštavanjem jednadžbi (2.28) i (2.30) u jednadžbu (2.33), uz okomite komponente električnog i magnetskog polja vala, dobije se izraz:

$$\begin{aligned} I = \frac{1}{2}Y\sum_{m=0}^{N'}\sum_{l=0}^{N'} & A_m A_l J_{n_m}(u_m r) J_{n_l}(u_l r) \\ & \cdot\cos(n_m\theta)\cos(n_l\theta)\exp[-i(\Delta\beta_{ml} z - \Delta\phi_{ml})], \end{aligned} \tag{2.34}$$

gdje su $\Delta\beta_{ml}$ i $\Delta\phi_{ml}$ razlike između propagacijskih konstanti i početne faze m-tog, odnosno l-tog moda. Izraz u eksponentu je za bilo koji m, l par indeksa kompleksno konjugirana vrijednost

one za l,m par te se stoga oba ova izraza mogu predstaviti jednom kosinusnom funkcijom:

$$\begin{aligned} I = \frac{1}{2}Y \sum_{m=0}^{N'} \Big[& A_m^2 J_{n_m}^2(u_m r)\cos^2(n_m\theta) \\ & + 2\sum_{l=m+1}^{N'} A_m A_l J_{n_m}(u_m r) J_{n_l}(u_l r) \\ & \cdot \cos(n_m\theta)\cos(n_l\theta)\cos(\Delta\beta_{ml}z - \Delta\phi_{ml})\Big] \end{aligned} \tag{2.35}$$

Kada se vlakno nalazi pod djelovanjem vanjske sile, tako da se indeks loma ili duljina vlakna ili oboje mijenjaju sa silom $F(t)$, dio izraza koji uključuje razliku u konstantama propagacije $\Delta\beta_m$ će se mijenjati s funkcijom sile:

$$\delta(\Delta\beta_{ml}z) \propto F(t) \tag{2.36}$$

Odgovarajuća promjena u prostornoj raspodjeli intenziteta je:

$$\begin{aligned} I = \frac{1}{2}Y \sum_{m=0}^{N'} \Big\{ & A_m^2 J_{n_m}^2(u_m r)\cos^2(n_m\theta) \\ & + 2\sum_{l=m+1}^{N'} A_m A_l J_{n_m}(u_m r) J_{n_l}(u_l r) \\ & \cdot \cos(n_m\theta)\cos(n_l\theta)\cos\left[\Delta\beta_{ml}z - \Delta\phi_{ml} + \gamma_{ml}F(t)\right]\Big\}, \end{aligned} \tag{2.37}$$

pri čemu je γ_{ml} faktor proporcionalnosti.

Upotrebom trigonometrijskih identiteta jednadžba (2.37) može se napisati:

$$\begin{aligned} I = & \frac{1}{2}Y \sum_{m=0}^{N'} A_m^2 J_{n_m}^2(u_m r)\cos^2(n_m\theta) \\ & + Y \sum_{m=0}^{N'} \Big(\sum_{l=m+1}^{N'} A_m A_l J_{n_m}(u_m r) J_{n_l}(u_l r)\cos(n_m\theta)\cos(n_l\theta) \\ & \cdot \big\{ \cos\left(\Delta\beta_{ml}z - \Delta\phi_{ml}\right)\cos\left[\gamma_{ml}F(t)\right] \\ & - \sin\left(\Delta\beta_{ml}z - \Delta\phi_{ml}\right)\sin\left[\gamma_{ml}F(t)\right]\big\}\Big). \end{aligned} \tag{2.38}$$

Uz pretpostavku malenog utjecaja vanjske sile $\gamma_{ml}F(t)$ jednadžba (2.38) može se aproksi-

mirati izrazom:

$$
\begin{aligned}
I = & \frac{1}{2} Y \sum_{m=0}^{N'} A_m^2 J_{n_m}^2(u_m r) \cos^2(n_m \theta) \\
& + Y \sum_{m=0}^{N'} \sum_{l=m+1}^{N'} A_m A_l J_{n_m}(u_m r) J_{n_l}(u_l r) \cos(n_m \theta) \cos(n_l \theta) \\
& \cdot \left[\cos\left(\Delta\beta_{ml} z - \Delta\phi_{ml}\right) - \gamma_{ml} F(t) \sin\left(\Delta\beta_{ml} z - \Delta\phi_{ml}\right) \right].
\end{aligned}
\tag{2.39}
$$

Konačno, intenzitet za bilo koju točku se može odrediti izračunom integrala prostorne raspodjele intenziteta na području i-te točke (područja promatranja):

$$
I_i = \int_{a_i} I da_i \tag{2.40}
$$

$$
\begin{aligned}
I_i = & \frac{1}{2} \int_{a_i} Y \sum_{m=0}^{N'} A_m^2 J_{n_m}^2(u_m r) \cos^2(n_m \theta) da_i \\
& + \int_{a_i} Y \sum_{m=0}^{N'} \sum_{l=m+1}^{N'} A_m A_l J_{n_m}(u_m r) J_{n_l}(u_l r) \cos(n_m \theta) \cos(n_l \theta) \\
& \cdot \left[\cos\left(\Delta\beta_{ml} z - \Delta\phi_{ml}\right) - \gamma_{ml} F(t) \sin\left(\Delta\beta_{ml} z - \Delta\phi_{ml}\right) \right] da_i.
\end{aligned}
\tag{2.41}
$$

Dio izraza koji predstavlja silu $F(t)$, se može izdvojiti kako bi se izoliralo djelovanje vanjske sile na intenzitet pojedinog područja promatranja:

$$
\begin{aligned}
I_i = & \frac{1}{2} \int_{a_i} Y \sum_{m=0}^{N'} A_m^2 J_{n_m}^2(u_m r) \cos^2(n_m \theta) da_i \\
& + \int_{a_i} Y \sum_{m=0}^{N'} \sum_{l=m+1}^{N'} A_m A_l J_{n_m}(u_m r) J_{n_l}(u_l r) \cos(n_m \theta) \cos(n_l \theta) \left[\cos\left(\Delta\beta_{ml} z - \Delta\phi_{ml}\right) \right] da_i \\
& - F(t) \int_{a_i} Y \sum_{m=0}^{N'} \sum_{l=m+1}^{N'} \gamma_{ml} A_m A_l J_{n_m}(u_m r) J_{n_l}(u_l r) \cos(n_m \theta) \cos(n_l \theta) \left[\sin\left(\Delta\beta_{ml} z - \Delta\phi_{ml}\right) \right] da_i.
\end{aligned}
\tag{2.42}
$$

Integral za i-tu točku (područje promatranja) može se uvesti pod sumaciju kako bi se dobio

izraz:

$$
\begin{aligned}
I_i = & \frac{1}{2} Y \sum_{m=0}^{N'} A_m^2 J_{n_m}^2(u_m r) \cos^2(n_m \theta) da_i \\
& + Y \sum_{m=0}^{N'} \sum_{l=m+1}^{N'} \left[\cos\left(\Delta\beta_{ml} z - \Delta\phi_{ml}\right) \right] A_m A_l \int_{a_i} J_{n_m}(u_m r) J_{n_l}(u_l r) \cos(n_m \theta) \cos(n_l \theta) da_i \\
& - F(t) Y \sum_{m=0}^{N'} \sum_{l=m+1}^{N'} \gamma_{ml} \sin\left(\Delta\beta_{ml} z - \Delta\phi_{ml}\right) A_m A_l \int_{a_i} J_{n_m}(u_m r) J_{n_l}(u_l r) \cos(n_m \theta) \cos(n_l \theta) da_i,
\end{aligned}
\tag{2.43}
$$

odnosno:

$$
I_i = A_i \left\{ 1 + B_i [\cos(\delta_i) - F(t) \phi_i \sin(\delta_i)] \right\} \tag{2.44}
$$

Prvi pribrojnik izraza (2.43) odgovara A_i pribrojniku izraza (2.44) i predstavlja vlastitu ili samointerakciju moda. Sljedeća dva pribrojnika predstavljaju međumodalnu interakciju, što je vidljivo iz dvostruke sumacije. Argument trigonometrijskih funkcija u (2.43) je identičan za svaki m, l par, što znači da će drugi pribrojnik biti fazno pomaknut u odnosu na treći, što je zastupljeno s $\cos\delta_i$ i $\sin\delta_i$ u jednadžbi (2.44). Faktor B_i predstavlja međumodalnu interakciju za stanje mirovanja. Kada se sustav pobudi, međumodalna interakcija se promijeni za $F(t) \cdot \phi_i$. Treba uočiti da su A_i, B_i, ϕ_i i δ_i konstantne vrijednosti za neki određeni i. Ovakav rezultat odgovara rezultatu za malo pobuđeni intereferometar. To nam omogućuje da točkasti uzorak projiciran iz svjetlovoda promatramo kao niz ili polje interferometara koji su istovremeno jednako pobuđeni.

Iako su takvi interferometri očito povezani, možemo pretpostaviti da su, za dovoljno malenu površinu uzorkovanja i dovoljno velik broj prostornih uzoraka, pojedine točke slabo ili nasumično korelirane s pobudnom silom po fazi, amplitudi i dubini modulacije, odnosno pretpostavljamo da su $\{A_i, B_i, \phi_i$ i $\delta_i\}$ praktički nasumični brojevi, u određenim granicama.

2.4.1 Izračun preko svih N uzoraka

U slučaju kada se zbrajaju apsolutne razlike svih pojedinačnih uzorkovanih piksela/detektora, što odgovara mjernom sustavu sa CCD kamerom, osnovni izraz za izlazni signal glasi:

$$
\Delta I_T = \sum_{i=1}^{N} \left| C_i \frac{dF(t)}{dt} \sin(\delta_i) \right| \tag{2.45}
$$

Izlazni signal može se zapisati i kao:

$$\Delta I_T = \left[\sum_{i=1}^{N} |C_i \sin(\delta_i)|\right] \left|\frac{dF(t)}{dt}\right|. \tag{2.46}$$

Budući da se suma provodi preko velikog broja elemenata, usprkos lokalnim varijacijama u distribuciji, ukupni rezultat će ostati kostantan i zamijenjen konstantom C, što dovodi do izraza:

$$\Delta I_T = C \left|\frac{dF(t)}{dt}\right|. \tag{2.47}$$

U slučaju sinusne pobude vlakna vanjskom silom $F(t) \sim \sin(\omega t)$, rezultantni signal poprima oblik:

$$\Delta I_T = \omega C \left|\cos(\omega t)\right|. \tag{2.48}$$

2.4.2 Izračun preko $n << N$ uzoraka

U slučaju kada se razmatra samo doprinos malog broja prostornih uzoraka, što odgovara površini jedne detektorske diode, uz doprinos vremenski nepromjenjivih vrijednosti I_0, jednadžba za izlazni signal glasi:

$$I_T = I_0 + \sum_{i=1}^{n} -A_i B_i \phi_i F(t) \sin(\delta_i), \tag{2.49}$$

što se može reducirati na:

$$I_T = I_0 + \sum_{i=1}^{n} C_i F(t) \sin(\delta_i). \tag{2.50}$$

Kako je faktor F(t) neovisan o sumi, može se izvući izvan sume, što dovodi do:

$$I_T = I_0 + \left[\sum_{i=1}^{n} C_i \sin(\delta_i)\right] F(t), \tag{2.51}$$

odnosno:

$$\Delta I_T = \left[\sum_{i=1}^{n} C_i \sin(\delta_i)\right] \frac{dF}{dt} \tag{2.52}$$

Kod povećanja n prema N, vrijednost u uglatim zagradama pada na 0.

U slučaju sinusne pobude vlakna vanjskom silom, kao u prethodnom primjeru, izlazni signal poprima oblik:

$$\Delta I_T = \left[\sum_{i=1}^{n} C_i \sin(\delta_i)\right] \sin(\omega t). \tag{2.53}$$

Sve navedene jednadžbe odnose se na potpunu izolaciju od bilo kakve vanjske pobude svih segmenata vlakna, osim jednog na koji direktno djeluje sila i za koji je napravljen ovaj proračun. U praktičnoj primjeni, a čak i u laboratorijskim uvjetima, je takvu pretpostavku nemoguće zadovoljiti. Bez obzira na to, ovakav rezultat daje teorijsku podlogu za primjenu pristupa koji su opisani u narednim poglavljima.

2.5 Primjeri primjene točkastog uzorka (*specklegram*-a) u senzorskim sustavima

Načelno objašnjenje principa rada senzora s točkastim uzorkom je ponuđeno u [36] uz vrlo optimistične prognoze potencijala takvih sustava. Pojašnjena je sličnost s interferometarskim metodama uz povlačenje paralele s njihovom karakterističnom razinom osjetljivosti. Međutim, kao razlika je istaknuta činjenica da ne postoje zasebni putevi za zrake u klasičnom interferometarskom smislu, već su višestruke zrake zapravo različiti modovi u svjetlovodu.

Generalni pregled ovog područja može se pronaći u posebnom poglavlju u [37]. U njemu su opisani glavni principi modulacije točkastog uzorka optičkog signala, te mogućnosti primjene i glavna obilježja pripadajućih sustava.

2.5.1 Beskontaktno mjerenje vibracija pomoću točkastog uzorka

Zanimljiva kombinacija prethodno opisanog intenzitetnog principa detekcije i analize točkastog uzorka je ponuđena u [38]. Upotrebom detektorske CCD kamere velike brzine uspješno je beskontaktno detektirana frekvencija vibracija površine na koju je projiciran točkasti uzorak. Ova varijanta senzora spada u senzore s detekcijom u jednoj točki, ekstrinsičnog tipa i intenzitetnog principa detekcije uz analizu točkastog uzorka. Osnovni princip detekcije prikazan je na slici 2.10a, a pripadajući rezultati na slici 2.11b.

2.5.2 Mjerenje statičkog naprezanja pomoću sprege osnovnih svjetlovodnih modova

Također su predstavili i poboljšanje dinamičkog raspona sustava za mjerenje naprezanja pomoću točkastog uzorka, primjenom korelacijskih metoda za obradu rezultata [39]. Korelacija je tražena između referentnih uzoraka za modalna stanja i trenutačno bilježenih uzoraka. Ovaj pristup je ponešto drugačiji od pristupa koji je prikazan u ovom radu jer zahtijeva kalibraciju prije početka mjerenja, ali zato omogućuje dobro mjerenje amplitude naprezanja. Treba pri tome imati na umu da opisani sustav mjeri longitudinalno statičko naprezanje, pa je promjena točkastog uzorka znatno manja, odnosno predvidljivija.

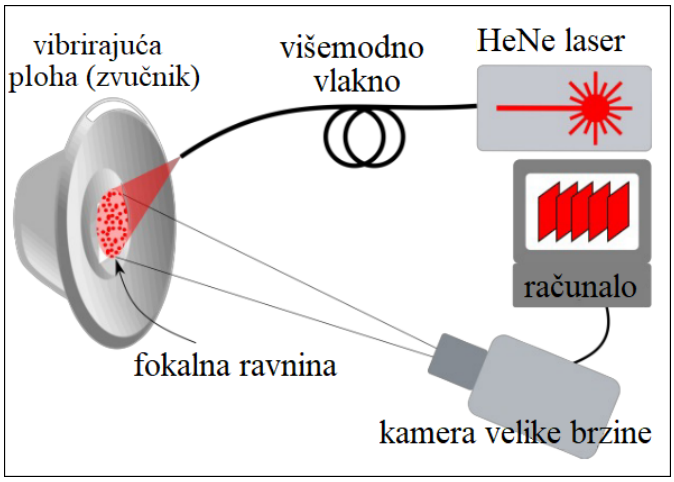

(a) Shematski prikaz principa rada

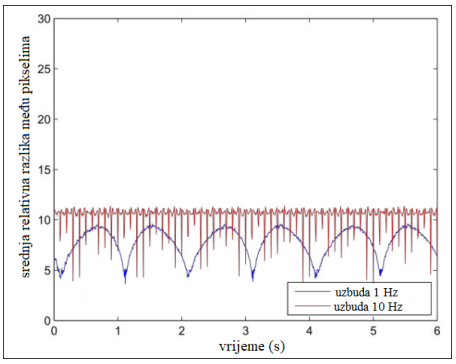

(b) Rezultati mjerenja na dvije različite frekvencije

Slika 2.10: Sustav za beskontaktno mjerenje vibracija pomoću kamere i točkastog uzorka [38].

Ovakav princip mjerenja naprezanja se istražuje i u mikrovalnom optičkom području kao što je navedeno u radu [40].

Alternativno ovom pristupu druga grupa je razvijala sustav koji je koristio dva paralelna vlakna od kojih je samo jedno bilo izloženo naprezanju, ali rezultate su temeljili na intereferometarskim tehnikama [41], a ne na zapažanjima vezanim uz točkasti uzorak. Intereferencijski uzorak koji su pri tome dobili ima određene sličnosti s točkastim uzorkom i također je obrađivan korelacijskim metodama.

U radu [42] su pojašnjeni osnovni principi sprege među modovima kod naprezanja vlakna na primjeru svjetlovoda s malim brojem modova (*Few Mode Fiber - FMF*). Istraživanja su rađena čak i u smjeru poništavanja promjena u točkastom uzorku, kako bi se uzorak stabilizirao [43].

Slični mehanizmi su primijenjeni u eksperimentalnom sustavu za mjerenje hidrostatskog pritiska opisanom u [44] te u sustavu za mjerenje naprezanja/temperature vlakna pomoću SMS strukture (*Single mode - Multi mode - Single mode*) prema [45].

2.5.3 Mjerenje temperature pomoću točkastog uzorka

Nadalje, ista grupa se bavila i istraživanjem utjecaja temperature na preraspodjelu točkastog uzorka, odnosno energije među modovima u vlaknu [46]. Osnovna shema sustava i dio rezultata prikazani su na slici 2.11.

2.5.4 Točkasti uzorak u detekciji pozicije pritiska

Sljedeći primjer predstavlja kombinaciju mikrosavijajuće strukture i detekcije točkastog uzorka pomoću kamere [47]. Sustav koristi višestruka paralelna svjetlovodna vlakna kako bi razlikovao točke pritiska na modulacijskom elementu, zahvaljujući promjenama u točkastom uzorku koji

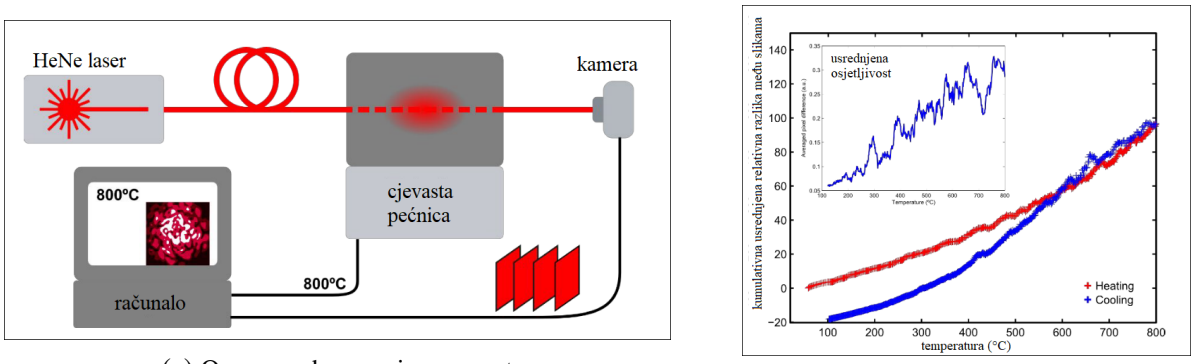

(a) Osnovna shema mjernog sustava

(b) Temperaturna karakteristika sustava

Slika 2.11: Sustav za mjerenje temperature pomoću kamere i točkastog uzorka [46].

se snima pomoću CCD kamere. Osnovna ideja sustava i modulacijskog elementa prikazana je na slici 2.12.

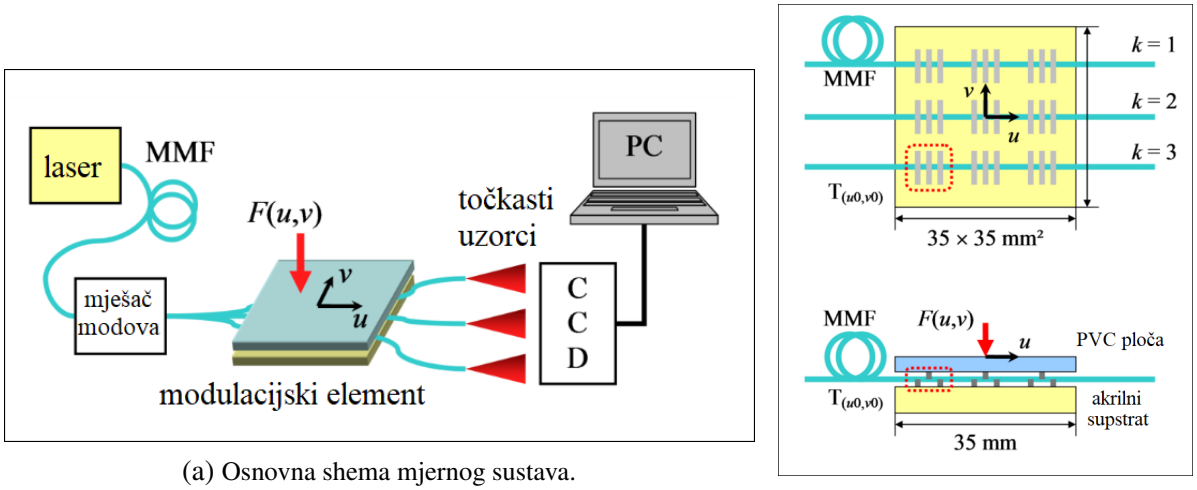

(a) Osnovna shema mjernog sustava.

(b) Detalj modulacijske pločice u bočnom i pogledu iz ptičje perspektive

Slika 2.12: Sustav za mjerenje temperature pomoću kamere i točkastog uzorka [47].

2.5.5 Različita obilježja pojedinih regija u točkastom uzorku

Proučavanjem obilježja različitih regija točkastog uzorka bavilo se više istraživačkih grupa [48, 49, 50]. Njihova istraživanja mogu se sumirati opisom prstenastih regija koje se šire od središta jezgre vlakna i među kojima u određenim uvjetima pobude vlakna dolazi do preraspodjele energije. Ta preraspodjela energije događa se zbog sprege među modovima i može se dovesti u vezu sa slikom 2.1, prilagođenom za slučaj cilindričnog valovoda. Takav zaključak odgovara i navedenim eksperimentalnim rezultatima postignutim primjenom SMS strukture, koja zapravo obavlja posao modalnog filtra u sustavima u kojima se primijenjuje. Upravo iz tog razloga je područje detekcije vanjskih utjecaja na vlakno najbolje na granici između dvije prstenaste regije. Kako ta granica u pravilu nije oštra, treba ciljati granicu između regija za

koje je razlika u ukupnoj energiji koja se njima širi značajna. Najočitija takva regija, osim ako je vlakno specijalno dizajnirano za drugačije funkcioniranje (primjerice [51, 52]), nalazi se na rubu jezgre, odnosno na rubu projiciranog točkastog dijagrama. Navedeni zaključci su potvrđeni i rezultatima ovog rada, ali su metode kojima su rezultati dobiveni nešto drugačije, kao što će biti opisano.

2.5.6 Točkasti uzorak u sustavima za osiguranje prostora

Od navednih primjena točkastog uzorka u senzorskim sustavima najjednostavnijom se čini ona za osiguranje prostora. Naime, kako u slučaju detekcije vibracija vlakno djeluje kao integrirani detektorski element, to znači da je moguće vlaknom opasati prostor koji se štiti. Zbog visoke razine osjetljivosti, takvo vlakno je moguće zakopati u zemlju ili integrirati u neku barijeru tipa ograde ili zida koji fizički štite prostor. U slučaju kontakta s barijerom ili tlom u blizini vlakna, dolazi do pobude samog vlakna (djelovanja vanjske sile), te posljedično promjene u distribuciji modova, odnosno točkastom uzorku. Očita je prednost svjetlovoda u ovakvoj primjeni u odnosu na klasične perimetarske senzorske sustave. U literaturi se nalazi nekoliko primjera ovakve primjene, za svjetlovodne senzore zasnovane na točkastom uzorku [53, 54, 55, 56, 57].

Poglavlje 3

Mjerenje vibracija pomoću analize točkastog uzorka svjetlovoda

U poglavlju je opisan prvi izrađeni prototip sustava za detekciju i karakterizaciju vibracija, pri čemu je kao detektorski element korištena web kamera kao jednostavan i jeftin CCD senzor. Opisan je praktični sustav zasnovan na principu detekcije promjena u točkastom uzorku opisanom u prethodnom poglavlju te neki rezultati koji su postignuti takvim sustavom.

3.1 Opis prototipa sustava

U prvoj implementaciji sustava za mjerenje vibracija prikazanoj na Slici 3.1, kao detektorski element je korištena web kamera, namijenjena širokoj potrošnji, rezolucije 320×240 piksela i nazivne frekvencije uzorkovanja 30 Hz, odnosno 30 fps (*fps - frames per second*).

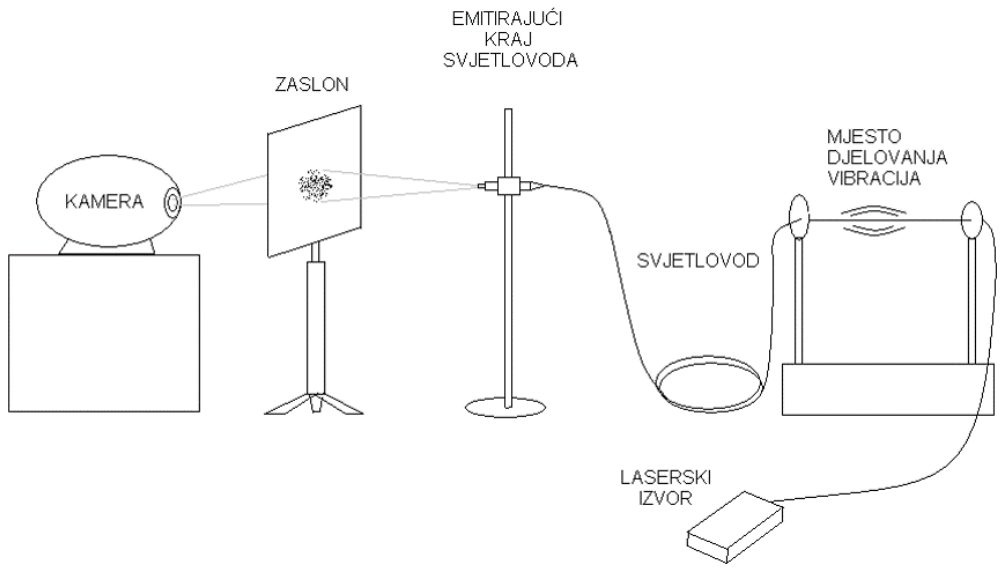

Slika 3.1: Shematski prikaz prototipa sustava za mjerenje vibracija s kamerom kao detektorom

Svjetlost iz lasera je ubačena u svjetlovod koji je bio razapet između dva fiksna nosača. Na segmentu svjetlovoda između nosača je primjenjivana vanjska mehanička sila kontrolirane frekvencije i amplitude. Svjetlost iz svjetlovoda je projicirana na zaslon te je snimana kamerom. Tako prikupljeni podaci su potom obrađivani na računalu. Detalji izvedbe su prikazani na slici 3.2.

(a) Prikaz cijelog sustava

(b) Detalj projekcije točkastog uzorka na zaslon

Slika 3.2: Praktična izvedba sustava u laboratoriju

3.2 Ograničenja prototipa

3.2.1 Frekvencija uzorkovanja

Nakon nekoliko bezuspješnih pokušaja ispravne detekcije frekvencije poznatih vibracija ustanovljen je prvi i najveći problem ovakvog pristupa. Kod jeftinih, konzumerskih kamera je brzina rada deklarirana na oko 30 slika u sekundi. U realnim uvjetima rada, u kojima se osvjetljenje ne može u potpunosti regulirati, brzina rada kamere opada i do 12 fps, pa i niže. Zbog ograničenja osjetljivosti detektorskog čipa u jeftinim kamerama, potrebna im je relativno velika količina svjetlosne energije kako bi uspjele zabilježiti sliku. Kada ta količina energije nije dostupna u 1/30 sekundi, takvi sustavi automatski provode integraciju signala u duljem vremenu uzorkovanja (*TDI - time delay and integrate*), ne bi li uspješno isporučili barem nekakvu sliku. Zbog toga dolazi do nepouzdanosti u frekvenciji uzorkovanja, a taj postupak također dovodi i

do *razmazivanja* pomičnih slika. Ovi problemi su vrlo jednostavno uočljivi i poznati iz iskustva s web kamerama ili kamerama na mobitelima kada ih se koristi u noćnim uvjetima rada pri lošem osvjetljenju. Navedeni problemi se mogu izbjeći primjenom industrijskih ili profesionalnih kamera, međutim tada cijena detektora značajno raste (nekoliko redova veličine). Pri tome upravljanje kamerom postaje kompliciranije, a i prostor potreban za primjenu se povećava jer su takve kamere u pravilu glomaznije od konzumerskih, jednostavnih varijanti. Kada smo ustanovili problem, pokušali smo ga riješiti intervencijom u upravljački program (*driver*) za kameru i fiksiranjem frekvnecije uzorkovanja koju je bilo moguće održavati (oko 25 Hz) s obzirom na uvjete osvjetljenja u kojima je sustav funkcionirao. Uz takvu korekciju sustav je ispravno detektirao vibracije koje smo inducirali na svjetlovodu što je prikazano na slici 3.3

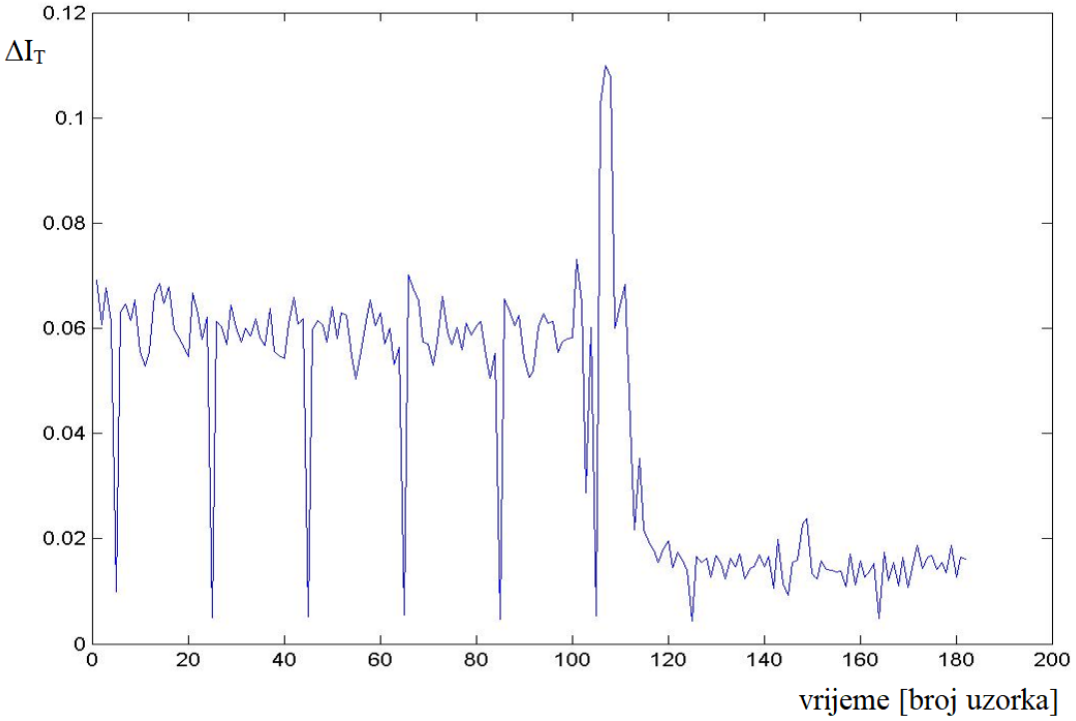

Slika 3.3: Prikaz izlaznog signala sustava za detekciju za slučaj kada je sustav izložen vibracijama koje oko 110. uzorka naglo prestaju.

Ukoliko bismo mogli zanemariti sve ostale opisane probleme, upotreba ovakve, konzumerske kamere bi prema Shannonovom teoremu o uzorkovanju teoretski limitirala najvišu frekvenciju signala koji se može ispravno detektirati na 12 Hz. Uz takvo ograničenje detektorski sustav gubi primjenjivost na strojevima, gdje su zanimljive frekvencije vibracija oko 50 Hz zbog frekvencije napona napajanja, odnosno oko prvog harmonika na 100 Hz. Osim ograničenja brzine rada, sustav s kamerom je podložan i nešto zahtjevnijim uvjetima primjene, odnosno nije naročito robustan. Dodatno značajno svojstvo je i veličina detektorskog sustava što je kod kamera nešto teže/skuplje reducirati.

3.2.2 Obrada podataka

Sustav je u prvim iteracijama funkcionirao tako da se prvo snimao video materijal trajanja nekoliko sekundi koji se zatim upotrebom komercijalne programske podrške (*software*) rastavljao na pojedinačne slike. Nakon toga su te slike učitavane i obrađivane u namjenski napisanom kodu u Matlab-u.

Naposljetku je iz takvog video materijala bilo moguće izvući frekvenciju vibracija, te neke naznake veličine relativne promjene amplitude vibracija, bez konkretne mjere te promjene. Mjerenja su obavljena u malom broju točaka, na svega nekoliko različitih frekvencija i amplituda vibracijskog signala. Rezultati takvih mjerenja su za spektralnu domenu prikazani na slici 3.4, a za vremensku domenu na slici 3.5. Značajan dio problema u ovoj fazi istraživanja je bio vezan uz problematiku proizvodnje kontroliranih vibracija za pobudu svjetlovoda. Taj problem je ilustriran slikom 3.6 koja prikazuje upotrebu vibracijske preše, namijenjene za testiranje građevinskih konstrukcija od nekoliko tona, za pobudu svjetlovoda.

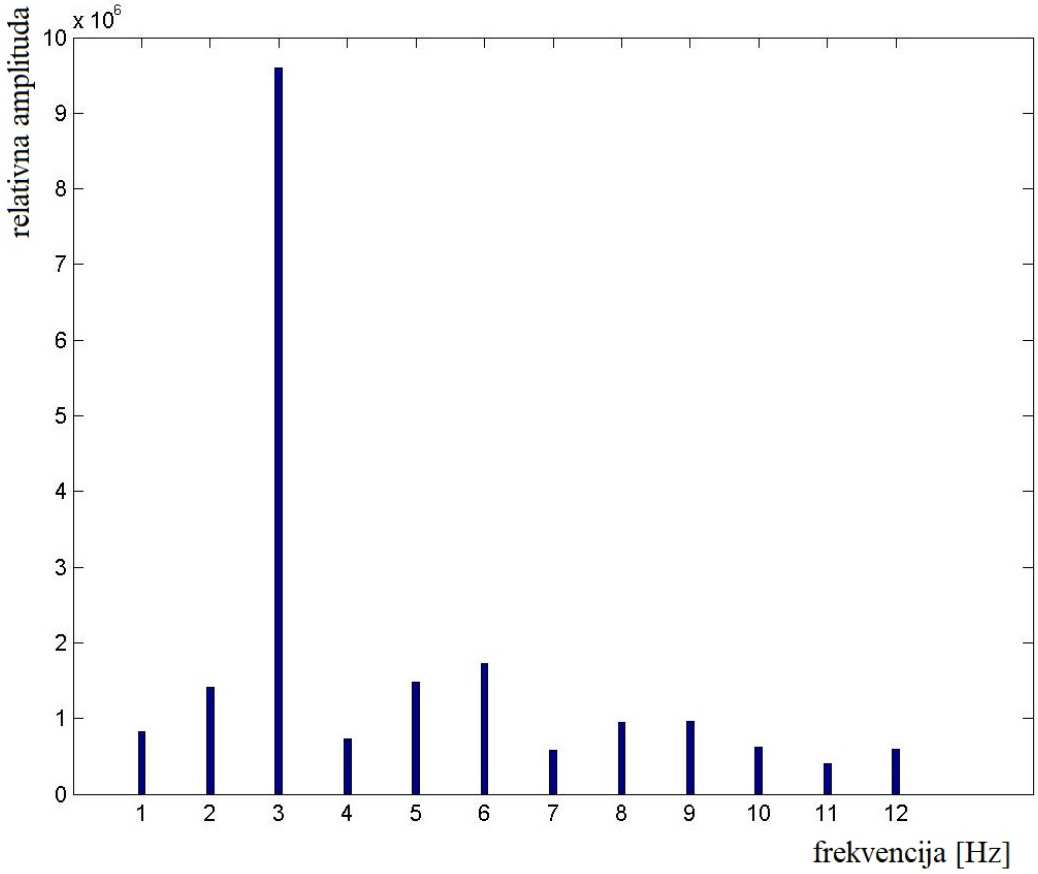

Slika 3.4: Spektar izlaznog signala sustava za pobudu kontroliranim vibracijama frekvencije 3Hz.

Rezultati ove varijante sustava objavljeni su u [58] te također objavljeni i prezentirani na međunarodnoj konferenciji [59].

Primjena ovakvog sustava nikako nije bila praktična jer se do rezultata dolazilo dugotrajnim postupkom uz primjenu nekoliko različitih softverskih alata koji nisu bili međusobno pove-

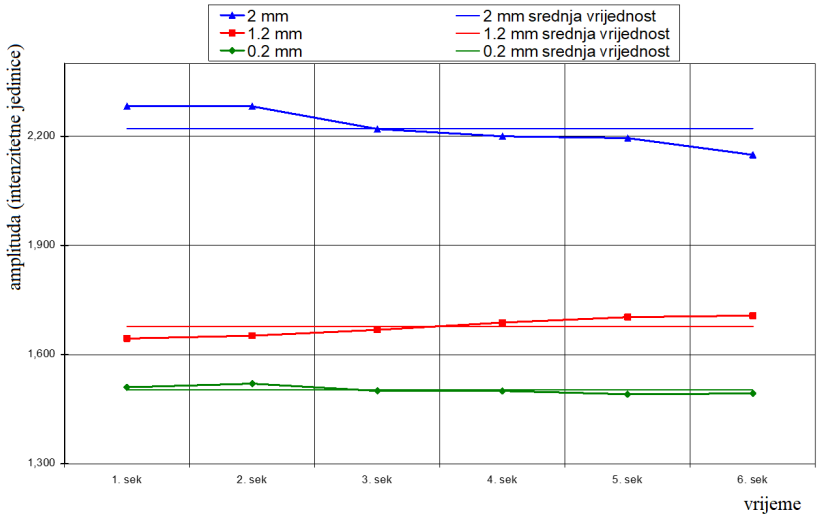

Slika 3.5: Usporedba srednje vrijednosti izlaznog signala za nekoliko različitih amplituda pobudne sile na vlakno.

zani. Međutim, ovim pristupom su demonstrirane osnovne mogućnosti, odnosno potencijal za primjenu pristupa praćenja vibracija na svjetlovodu pomoću točkastog uzorka.

Također je jasno ustanovljeno koja su ograničenja pristupa mjerenja uz pomoć kamere, pa se krenulo s razmatranjem nekih drugih varijanti detekcije vibracija pomoću točkastog uzorka svjetlovoda.

Slika 3.6: Pobuda svjetlovoda kontroliranim vibracijama pomoću vibracijske preše na Građevinskom fakultetu Sveučilišta u Zagrebu

3.3 Redizajn mjernog sustava

Nakon istraživanja nekoliko alternativnih opcija za mjerenje vibracija pomoću svjetlovodnog vlakna ustanovljeno je da niti jedna od njih, u uvjetima u kojima su testirane, ne daje konzistentno rezultate koji po točnosti odgovaraju onima koji su dobiveni prototipom mjernog sustava zasnovanog na točkastom uzorku uz kameru kao detektor.
Kako bi se istražilo unapređenje sustava razmatrane su kamere industrijske namjene koje su nudile znatno veću brzinu rada, odnosno veći broj uzoraka u sekundi i do nekoliko stotina fps. Nažalost, takve kamere su zahtijevale značajno povećanje ulaganja u senzorski sustav. Iako je bilo jasno da bi se neki od problema prototipa riješili upotrebom takvih kamera, kompromis po pitanju cijene i drugih karakteristika sustava, kao što su veličina i kompleksnost analize ocijenjeni su neprihvatljivima. Kako bi se ustanovile druge mogućnosti za rješenje problema, bilo je potrebno napraviti neke ključne preinake na prvotnom mjernom sustavu.

3.4 Ograničenja prvog razvijenog mjernog sustava za mjerenje vibracija pomoću kamere

Prethodno je opisano da su u prvoj izvedbi sustava obrada signala i prikaz rezultata obavljani naknadno, nakon prikupljanja podataka za mjerenje. Cijeli proces je tekao na sljedeći način:

- snimanje videa točkastog uzorka u relativno kratkom trajanju (<10s) softverskim alatom za snimanje videa
- rastavljanje video zapisa na pojedine uzorke (slike) u odvojenom programu za obradu slike
- obrađivanje pojedinačnih slika kako bi se eliminirala informacija o boji i kako bi bile prebačene u crno-bijelu varijantu, tj. kako bi svaka slika sadržavala samo podatak o intenzitetu svjetlosti po pikselima
- učitavanje slika u Matlab program napisan za tu svrhu kako bi se proračunao i analizirao signal koji je bio posljedica vibracija te kako bi se prikazali rezultati mjerenja

Iako je ovaj pristup bio dovoljno dobar za tzv. dokaz principa rada (*proof of concept*), proces je bio predugačak i nepraktičan za testiranje i usporedbu različitih varijanti rada te testiranje novih pristupa i ideja.

Kako je već rečeno, u ovoj fazi nismo na raspolaganju imali ni pouzdan izvor kontroliranih mehaničkih vibracija odgovarajuće frekvencije (koje su zbog kamere nekad bile ograničene na 6-7 Hz). Osim pokusa na građevinskom fakultetu prikazanog na slici 3.6, koji je jedini uključivao potpuno kontrolirani izvor vibracija, eksperimentirali smo i s različitim varijantama izvora vibracija koje su uključivale zvučnike. Na tako niskim frekvencijama zvučnici ipak nisu u mogućnosti vrlo uspješno reproducirati vibracije jer su u pravilu predviđeni za nekoliko

desetaka Herza više frekvencije.

Prva nužna modifikacija koja je napravljena je bila prilagodba sustava za rad u realnom vremenu. Kako bi se prilikom različitih testiranja moglo obaviti mjerenje u većem broju mjernih točaka te relativno jednostavno ustanoviti vrijednost i točnost rezultata, važno je da su isti što neposrednije dostupni. U idealnom slučaju su rezultati dostupni u tzv. realnom vremenu, što bi značilo da se prikupljanje podataka te obrada i prikaz istih obavljaju gotovo istovremeno, odnosno da je rezultat mjerenja dostupan trenutačno.

3.5 Odabir pogodne programske okoline/jezika

Za rješenje ove zadaće odabrana je programska razvojna okolina *LabVIEW* koja se izrazito često koristi baš u svrhu razvoja i testiranja novih uređaja. Upotrebom te okoline omogućen je direktan dohvat slika s kamere i istovremena obrada pomoću alata za obradu slike koji su dio pripadajućeg paketa *Vision*. Za tu svrhu je napisan novi programski kod namijenjen za dohvat i obradu slike s tekst kamere. Paralelno s tim operacijama odvijala se obrada pripremljenih slika i prikaz rezultata u drugom dijelu koda koji se prethodno dodvijao u MatLab-u, a koji je za tu svrhu nanovo napisan u LabVIEW okolini.

LabView programska okolina i pripadajuća programska paradigma *Dataflow* posebno su pogodni za implementaciju paralelnih programskih operacija. U pristupu *Dataflow* programske naredbe se ne izvode slijedno, u smislu u kojem je to slučaj u klasičnim, sekvencijalnim, programskim jezicima. Naime, LabVIEW je razvijen kao okolina za programiranje za neprogramere. Primarna svrha ove okoline, odnosno programskog jezika, jest čitanje, prikaz i manipulacija podacima (nizovima numeričkih vrijednosti) koji se dohvaćaju putem akvizicijskih uređaja *DAQ*-ova (*Data Acquisition* uređaja). Samo programersko sučelje je grafičkog tipa, a većina programiranja se obavlja pomoću miša kojim se povlače virtualne žice koje povezuju virtualne instrumente. Svaki objekt na programerskoj radnoj površini *Block Diagram*-u se ponaša kao instrument, koji je potrebno žicama povezati s ostalim elementima kako bi se ostvarila određena funkcionalnost. Redoslijed izvođenja naredbi, odnosno stavljanja pojedinih instrumenata u pogon, je određen upravo žicama koje ih povezuju. *Dataflow* je definiran na način da svaki instrument (objekt) *Block Diagram*-a čeka na dostupnost podataka/vrijednosti na ulaznim priključnicama. Ukoliko su podaci/vrijednosti dostupni, instrument obavlja svoj zadatak i isporučuje nove podatke/vrijednosti na izlaznim priključnicama, ukoliko posjeduje takve. Nakon toga se može pokrenuti sljedeći instrument koji je te podatke čekao, itd. Zahvaljujući ovome moguće je definirati potpuno paralelne komade programskog koda koji nisu međusobno povezani žicama i koji ne moraju čekati na izvođenje, ukoliko su ulazni podaci/vrijednosti dostupni. S obzirom na kritičnost točnosti frekvencije uzorkovanja, radi izračuna spektralnih komponenti uzorkovanog signala, a i s obzirom na izrazito nesimetričnu prirodu procesa akvizicije i obrade

podataka u slučaju prikupljanja slike, ovakav odabir okoline je pojednostavnio rješenje zadatka. Na slici 3.7 prikazano je korisničko sučelje pripremljenog programa za mjerenje.

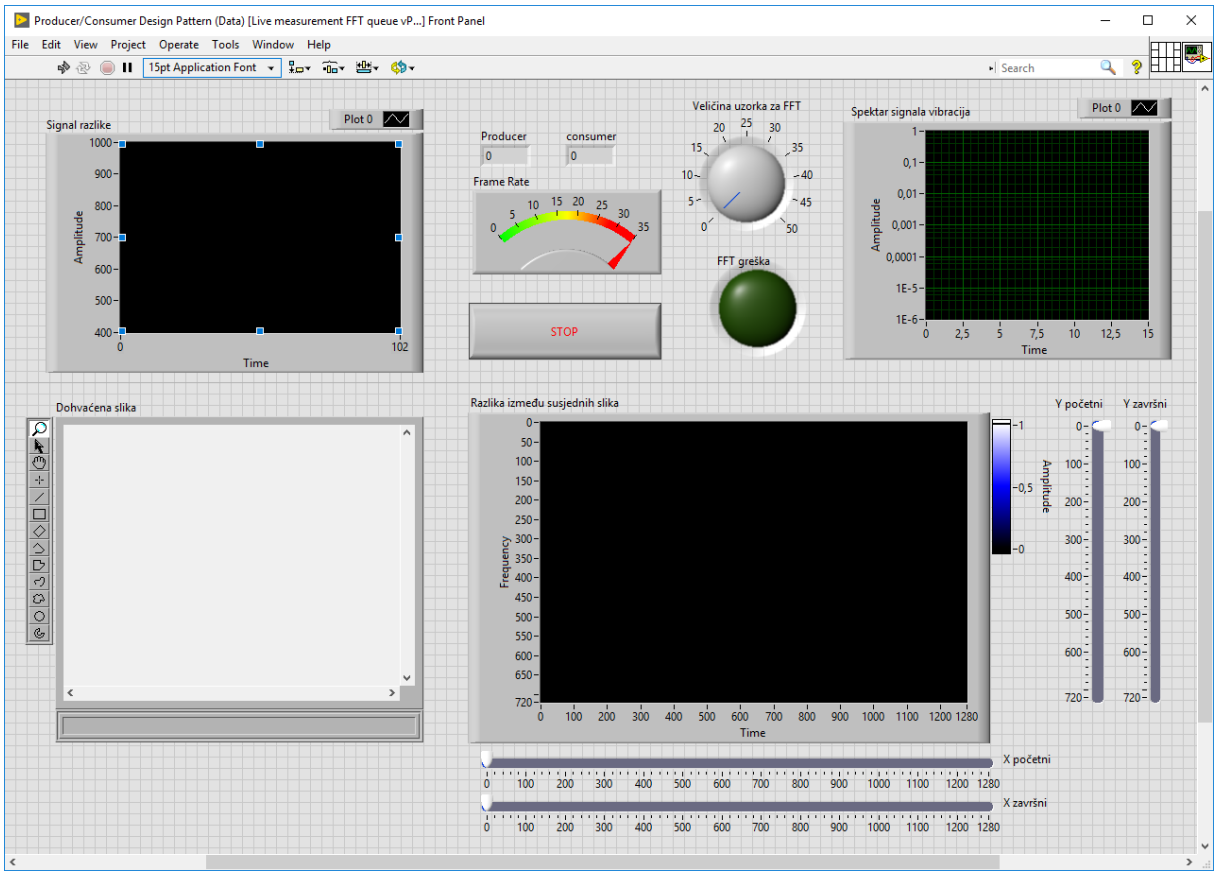

Slika 3.7: Korisničko sučelje programa pripremljenog za mjerenje vibracija u relanom vremenu

Programom je omogućen trenutačni uvid u:

- dohvaćenu sliku (uzorak)
- razliku u odnosu na susjednu sliku
- ukupni broj dohvaćenih slika
- brzinu dohvata
- ukupni broj slika nad kojima je obavljena analiza
- vremenski signal kao posljedicu djelovanja vibracija na svjetlovod
- spektar signala nakon FFT-a provedenog na zadanom broju uzoraka

U izvedbi rješenja korištena je tzv. *Producer/Consumer* arhitektura programa. Ona je namijenjena upravo za slučajeve u kojima se akvizicija podataka i njihova obrada odvijaju različitim tempom. Kako je već naglašeno, tempiranje akvizicije podataka je u ovom primjeru kritično, a sama obrada i prikaz su nešto fleksibilniji, odnosno nije od presudne važnosti da se dogode u točno određenom trenutku, dok god taj trenutak nije značajno kasniji od samog trenutka akvizicije. Ovakva arhitektura podrazumijeva korištenje dvije (ili više) odvojenih petlji koje pristupaju zajedničkom spremniku podataka, stogu. Pri tome se akvizicijom ubacuje podatke na vrh stoga, čime se stog povećava i to predstavlja *Producer* stranu programa. Obrada i prikaz poda-

taka se odvijaju u drugom segmentu programa koji podatke uzima s dna stoga i tako smanjuje njegovu veličinu te se naziva *Consumer*. Na taj način se izbjegava da brzina obrade podataka direktno utječe na brzinu prikupljanja podataka, te se isključuje potreba za eventualnim pauzama u nadzoru, koje su inače potrebne u sličnim mjernim situacijama za izračun i prikaz mjernih rezultata, odnosno omogućuje se kontinuiran nadzor prikupljanja i obrade podataka uz paralelni prikaz trenutačnih rezultata.

3.6 Dodatna poboljšanja programa za mjerenje

Pored trenutačnog mjerenja izrađeni program je omogućio i jednu opciju koja je značajno povećala mogućnosti eksperimentiranja, a to je obrada proizvoljno odabranog segmenta slike. Pomoću klizača koji se na slici 3.7 nalaze pored prozora za prikaz razlike između susjednih uzoraka, moguće je odabrati dio uzorka (slike sa CCD senzora) nad kojim se obavlja obrada. Odabir se obavlja postavljanjem početne i završne vrijednosti za x odnosno y os, a obrada se obavlja za sve piksele koji se nalaze u zadanom rasponu.
Na taj način omogućen je odabir područja slike na koje se obrada slike fokusira, odnosno za kojega se proračunavaju rezultati za vrijeme mjerenja. Uz aktivan prikaz spektralnog sastava tako izvučenog signala, pokušalo se ustanoviti postoji li neki dio slike koji je važniji/pouzdaniji za detekciju vibracija od ostalih dijelova, odnosno postoje li dijelovi slike čiji je utjecaj u pouzdanoj detekciji zanemariv. Osim testiranja za različite segmente slike, na ovaj način je omogućeno i testiranje za segmente različitih veličina. Time se pokušalo odrediti najmanju veličinu i najbolju poziciju segmenta slike koji još uvijek sadrži informaciju o vibracijama kada ga usporedimo s vremenski susjednim segmentima na isti pozicijama. Ovakvo testiranje je bilo vođeno idejom da možda postoje područja na koja se naročito značajno i pouzdano odražavaju vanjski fizički utjecaji na vlakno. Takav dojam je stečen promatranjem rezultantnog točkastog uzorka (razlika među susjednim slikama) za vrijeme različitih mehaničkih pobuda svjetlovodnog vlakna. Ukoliko je pretpostavka o postojanju takvih područja točna, potreba za kamerom, kao najslabijom ili najlimitiranijom komponentom mjernog sustava, bi mogla biti eliminirana.

Radi reference za buduće pokušaje napravljena je simulacija akvizicije i mjerenja koja po svojim parametrima odgovara performansama prethodno korištenog sustava, sa svim ograničenjima koja to uključuje. Na slici 3.8 je prikazan odabir segmenta koji odgovara ograničenju koje je imao prethodno korišteni sustav, odnosno obuhvaćen je cijeli točkasti uzorak.

Analizom cijelog točkastog uzorka zabilježen je spektralni sastav vibracijskog signala prikazan na slici 3.9. Iako je zabilježeno da je izražena komponenta na frekvenciji 3Hz, koja odgovara frekvenciji pobude sustava, ona nije značajno dominantna u ukupnom spektralnom sastavu signala. Napomenimo da je za detekciju vibracija u ovim slučajevima primijenjena jednadžba (2.52), koja će jednako tako biti primijenjena i u slučajevima promatranja segmentiranog

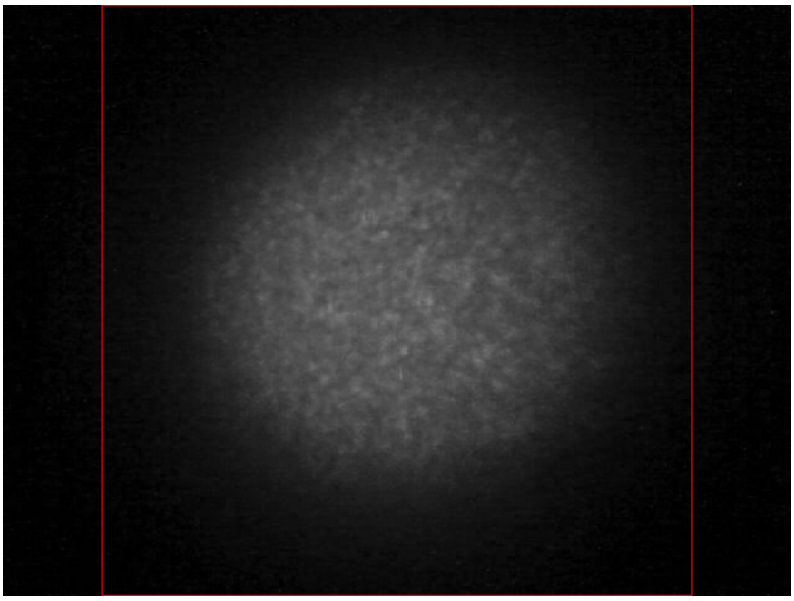

Slika 3.8: Pozicioniranje segmenta za analizu slike tako da odgovara postavkama prethodno korištenog sustava

točkastog uzorka.

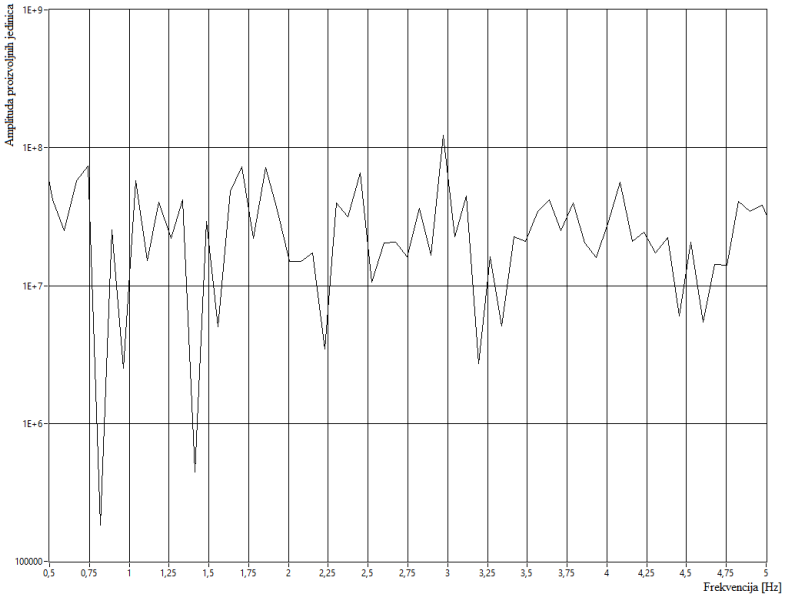

Slika 3.9: Spektralni sastav signala zabilježenog mjernim sustavom kroz analizu cijelog točkastog uzorka

3.7 Rezultati unapređenja programa za obradu podataka

Očekivani rezultat eksperimentiranja u ovoj fazi je bio taj da je za cijelu sliku detekcija bila pouzdana, ali uz razliku da je sada rezultat bio dostupan gotovo trenutačno.

Zanimljivo je bilo da se redukcijom slike, odnosno odabirom određenih segmenata, povre-

meno postizalo zadovoljavajuće rezultate, ali ta detekcija nije bila pouzdana. Događalo se da za neku odabranu poziciju su u jednom mjerenju rezultati izvrsni, a da sljedećom prilikom za iste postavke sustava detekcija nije korektna. Kako je svakim novim mjerenjem došlo do nekih nenamjernih i slučajnih izmjena u sustavu, teško je bilo reproducirati identične uvjete mjerenja i usporediti rezultate direktno. Iz tog razloga pristupilo se izradi nadogradnje mjernog sustava u smislu automatizacije pozicije i veličine segmentiranja slike, a sve u svrhu postizanja lakše usporedivih rezultata. Značajan napredak je ostvaren omogućavanjem učitavanja snimljene video datoteke ili niza slika, kako bi se moglo mijenjati parametre analize za uvijek isti ulazni set uzoraka. Na taj način se moglo učinkovito uspoređivati rezultate za različite postavke segmentacije mjernog sustava. Navedeni postupak optimizacije pozicije segmenata za detekciju vibracija pomoću točkastog uzorka je detaljno opisan pod konferencijskim radom [60], a rezultati su i prezentirani na navedenoj konferenciji.

3.7.1 Segmentiranje slike

Sljedeći odjeljci prikazuju rezultate detekcije vibracija različitih amplituda, ali fiksne frekvencije $f = 3$ Hz, za nekoliko različitih pozicioniranja segmenata, te nekoliko različitih veličina segmenata. Radi lakše orijentacije korištene su oznake za strane svijeta prema uobičajenom rasporedu za kartografiju, pri čemu je sjever (N) pozicioniran na vrhu slike, zapad (W) lijevo, jug (S) dolje, itd.

Postupak se sastojao od snimanja kratkog video materijala uz poznati pobudni signal vlakna, nakon čega je na uvijek istom materijalu simulirana detekcija segmentima različitih veličina.

Vibracijski signal je korišten za upravljanje generatorom mehaničkih vibracija koje su djelovale na svjetlovodno vlakno. Na slici 3.10 prikazana su obilježja uzbudnog signala za mehanički vibrator.

U svakom odjeljku je na vrhu stranice slikom prikazana pozicija i veličina segmenta u točkastom dijagramu, a u stupcu ispod slike nalaze se odzivi svjetlovodnog detekcijskog sustava za četiri različite amplitude pobudnog mehaničkog vibracijskog signala.

Za simulaciju detekcije korištene su postavke prikazane na slici 3.11.

Pri tome su veličine simuliranih segmenata jednake za sve pozicije, uz iznimku za centralno pozicionirane segmente (C) gdje su uključene dodatne dvije veličine segmenata koje imaju smisla samo za tu poziciju. Sve dimenzije segmenata su dane u pikselima.

Rezultati koji su prikazani su međusobno različiti i za nekoliko redova veličine po apsolutnim vrijednostima jer se radi o sumama intenziteta točaka u rasponu od 480^2 do 3^2 pojedinačnih elemenata. Ni uz logaritamsko skaliranje toliki raspon vrijednosti nije moguće prikazati na jednom grafu, a da su pri tome uočljivi detalji na svakoj od krivulja. Iz tog razloga se pristupilo normiranju svake od krivulja kako bi rezultati ušli u isti raspon. Time su pak krivulje postale isuviše slične i međusobno preklopljenje do mjere da je raspoznavanje pojedinačnih rezultata

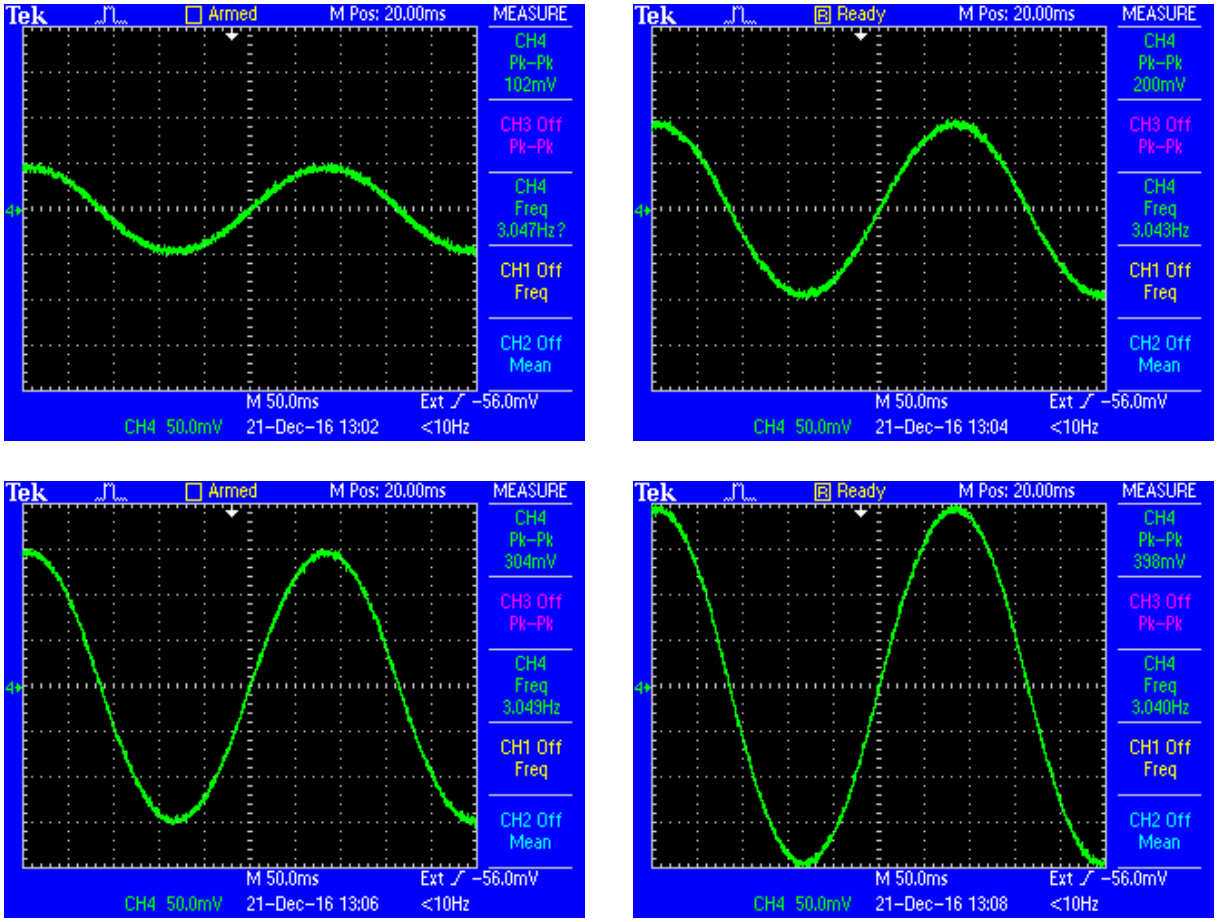

Slika 3.10: Oscilogrami korištenih uzbudnih signala mehanički vibrator koji je djelovao na svjetlovod $f = 3Hz; U_{VV} =$[100; 200; 300; 400] mV

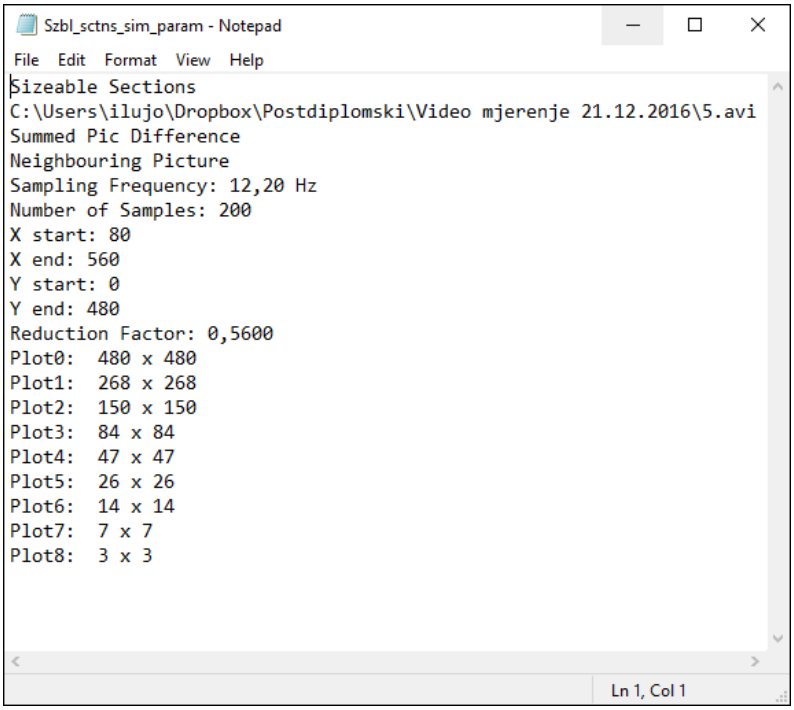

Szbl_sctns_sim_param - Notepad

File Edit Format View Help

```
Sizeable Sections
C:\Users\ilujo\Dropbox\Postdiplomski\Video mjerenje 21.12.2016\5.avi
Summed Pic Difference
Neighbouring Picture
Sampling Frequency: 12,20 Hz
Number of Samples: 200
X start: 80
X end: 560
Y start: 0
Y end: 480
Reduction Factor: 0,5600
Plot0:  480 x 480
Plot1:  268 x 268
Plot2:  150 x 150
Plot3:  84 x 84
Plot4:  47 x 47
Plot5:  26 x 26
Plot6:  14 x 14
Plot7:  7 x 7
Plot8:  3 x 3
```

Ln 1, Col 1

Slika 3.11: Zapis iz konfiguracijske datoteke za primjer simulacije detekcije nad segmentima slike

ponovno onemogućeno. Iz navedenih razloga su normirane krivulje prikazane na razdvojenim grafovima.

Tri dimenzije po kojima se rezultati analiziraju i po kojima je uređen njihov prikaz su:

- veličina segmenta (numerirana 0 do 8)
- pozicija segmenta (C; N; NW; W; SW; S)
- amplituda pobudnog signala (100mV; 200mV; 300mV; 400mV).

Još jedna dobra strana ovakvog pristupa je mogućnost pojedinačnog vrednovanja svakog od rezultata jednostavnom indikacijom pomoću okvira u boji. Za spektralne odzive je rezultat, s aspekta detekcije točne frekvencije vibracija, označen na sljedeći način:

Za spektralne odzive s točnom detekcijom vibracija na 3 Hz i relativnom dominacijom te spektralne komponente u kombinaciji s drugim harmonikom nad ostalim komponentama spektra.

Za spektralne odzive s točnom detekcijom vibracija na 3 Hz, ali bez dominacije te spektralne komponente u kombinaciji s drugim harmonikom nad ostalim komponentama spektra.

Za spektralne odzive bez detekcije vibracija na 3 Hz, odnosno uz točnu detekciju, ali uz dominaciju drugih spektralnih komponenti.

3.7.2 Centralno (C) pozicionirani segmenti

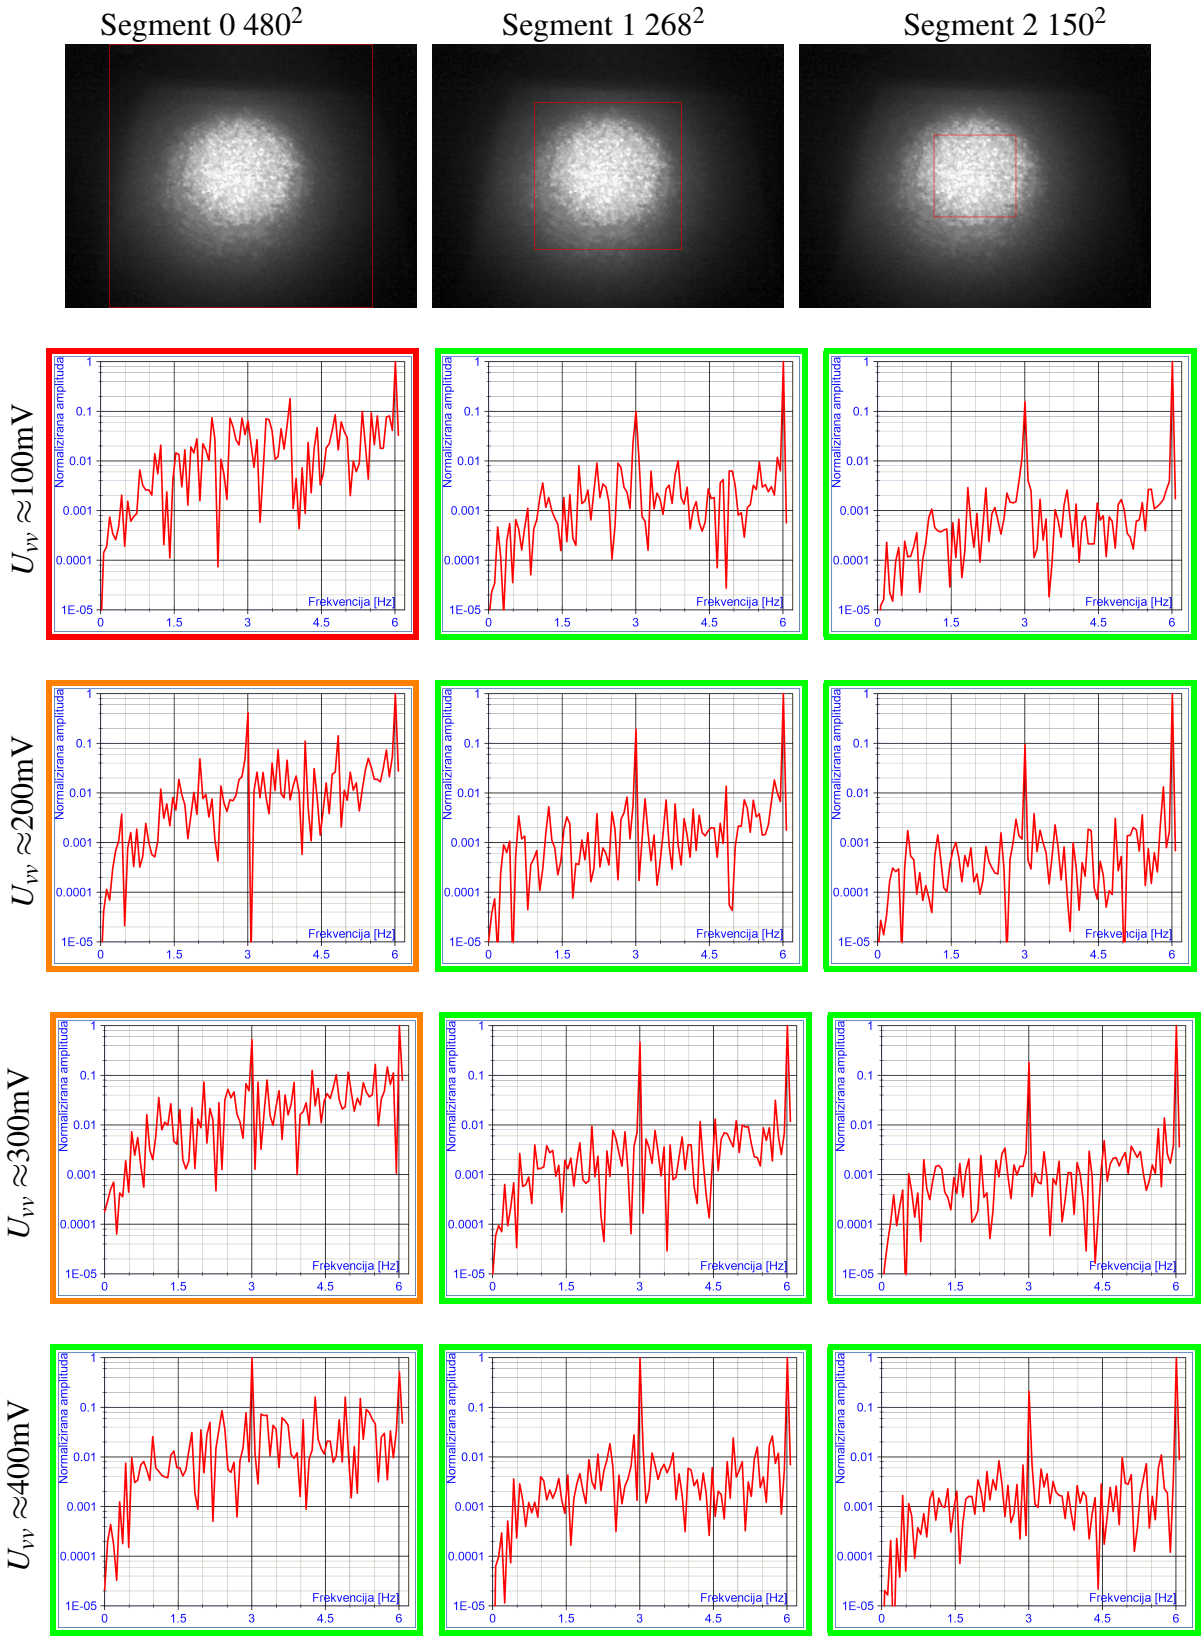

Slika 3.12: Prikaz spektara rezultata različitih segmentiranja slike za četiri različite amplitude pobudnog signala: centralno pozicionirani segmenti (1.dio)

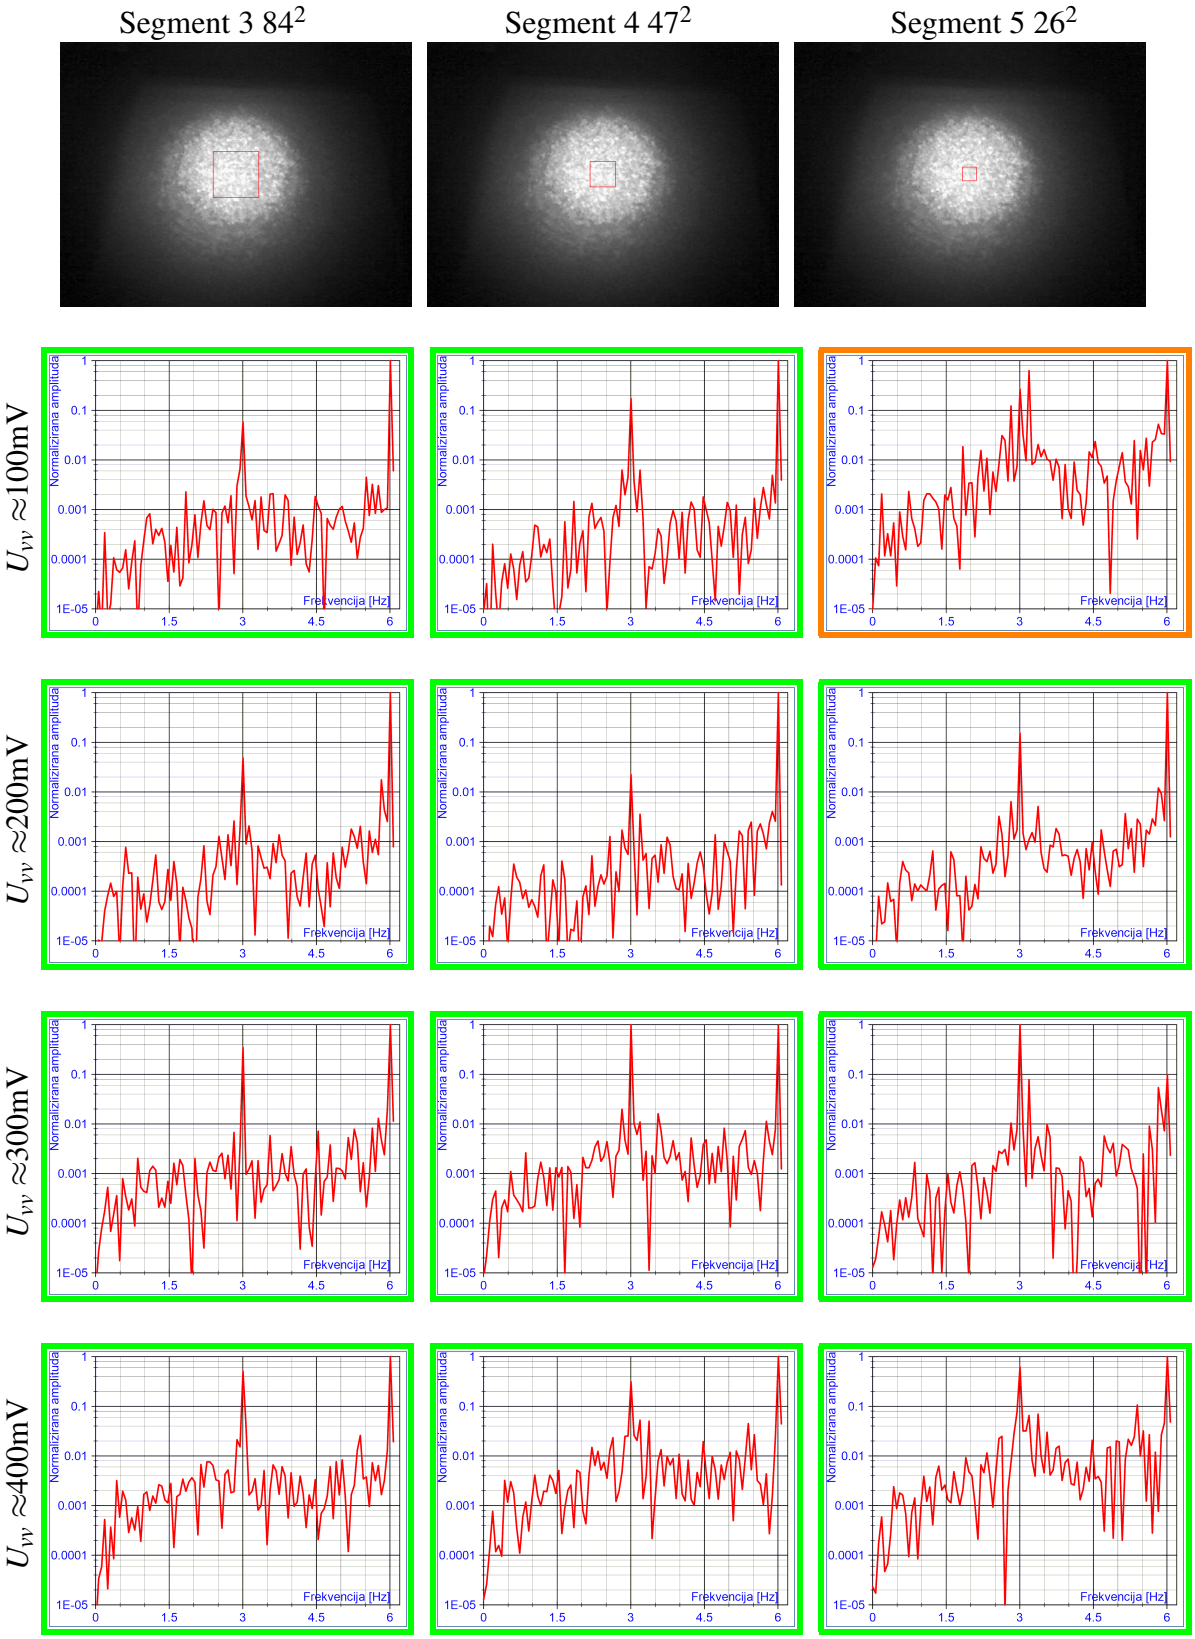

Slika 3.13: Prikaz spektara rezultata različitih segmentiranja slike za četiri različite amplitude pobudnog signala: centralno pozicionirani segmenti (2.dio)

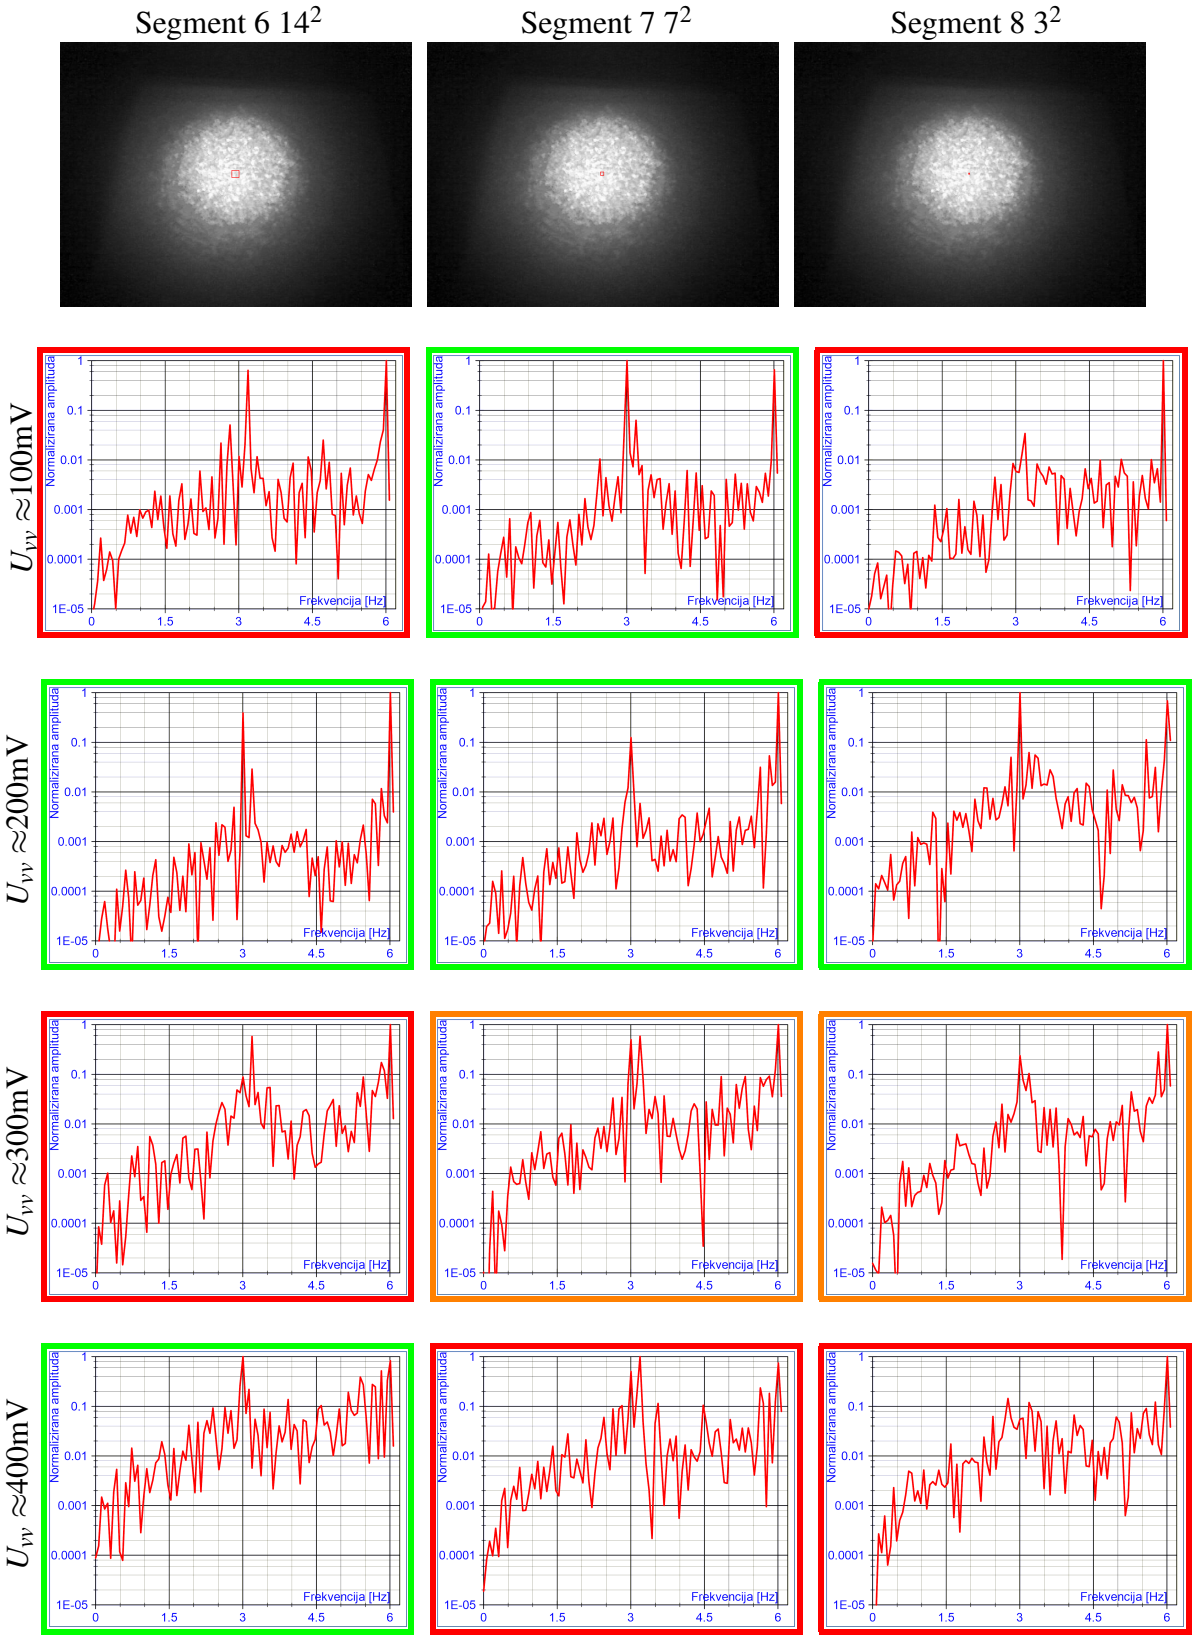

Slika 3.14: Prikaz spektara rezultata različitih segmentiranja slike za četiri različite amplitude pobudnog signala: centralno pozicionirani segmenti (3.dio)

3.7.3 Sjeverno (N) pozicionirani segmenti

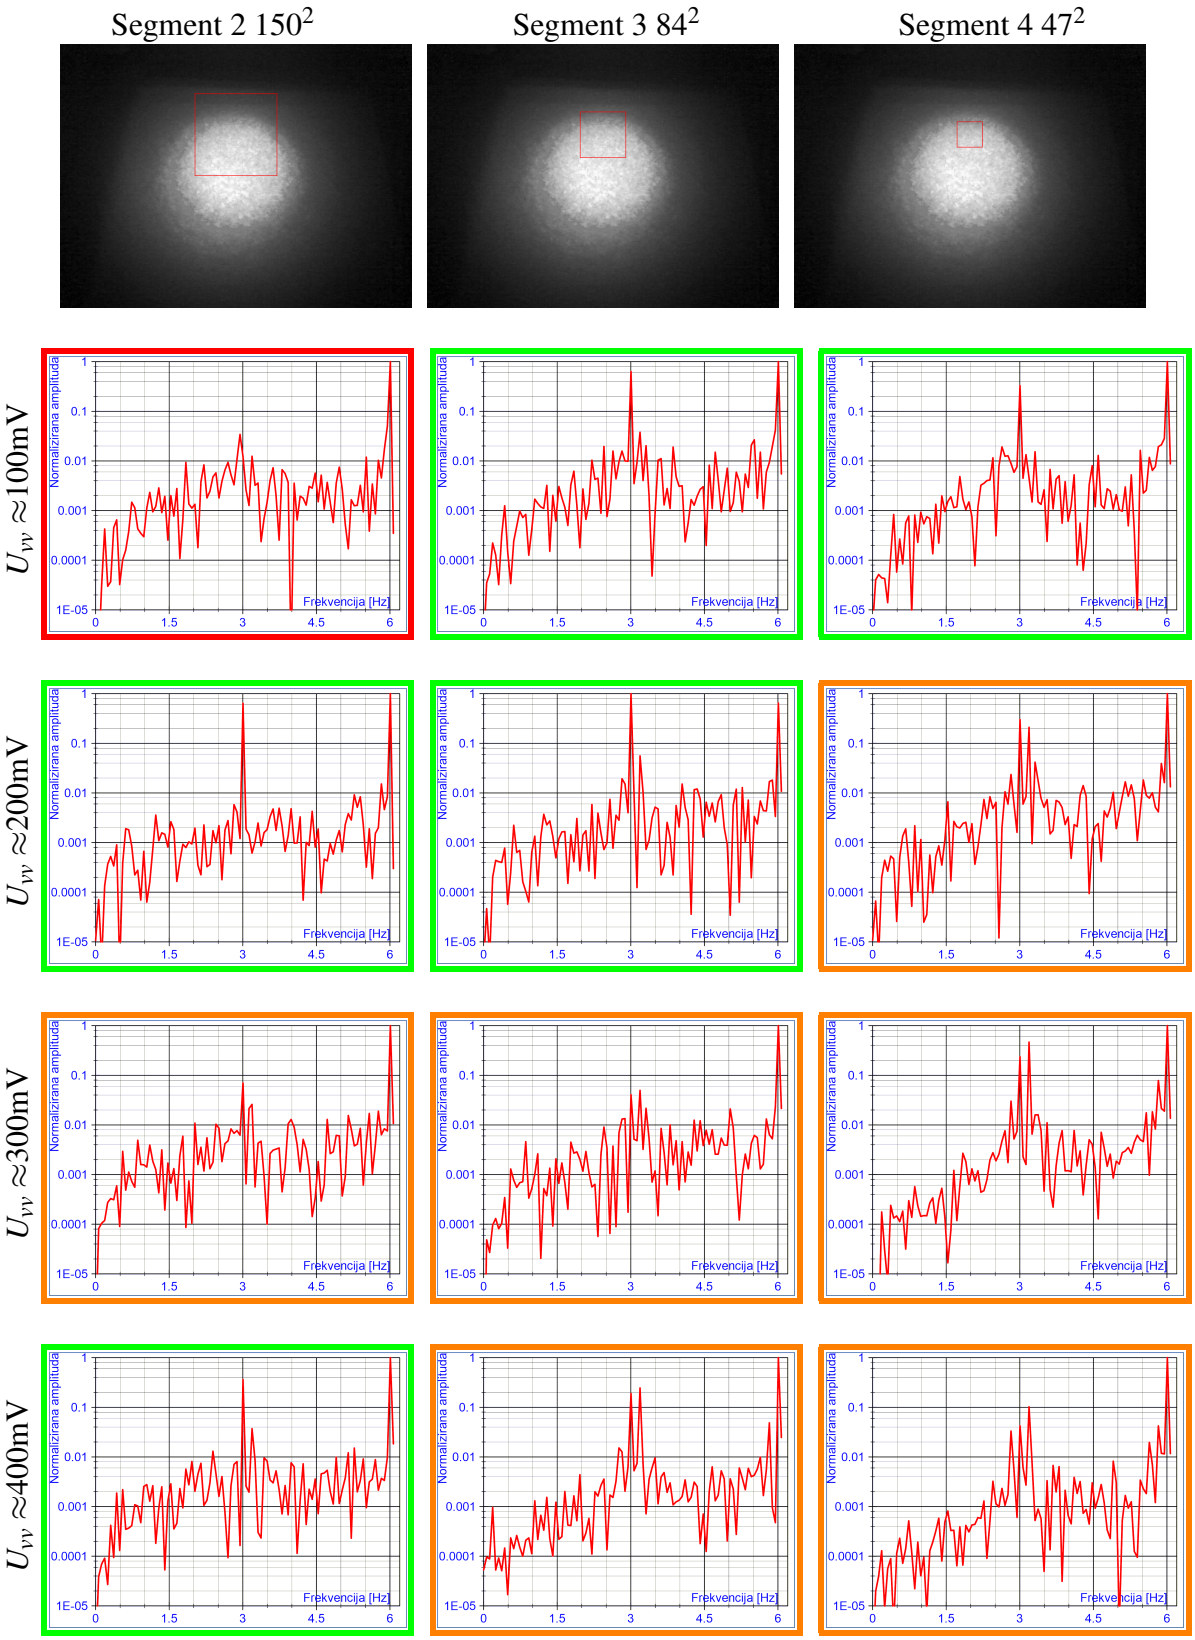

Slika 3.15: Prikaz spektara rezultata različitih segmentiranja slike za četiri različite amplitude pobudnog signala: sjeverno pozicionirani segmenti (1.dio)

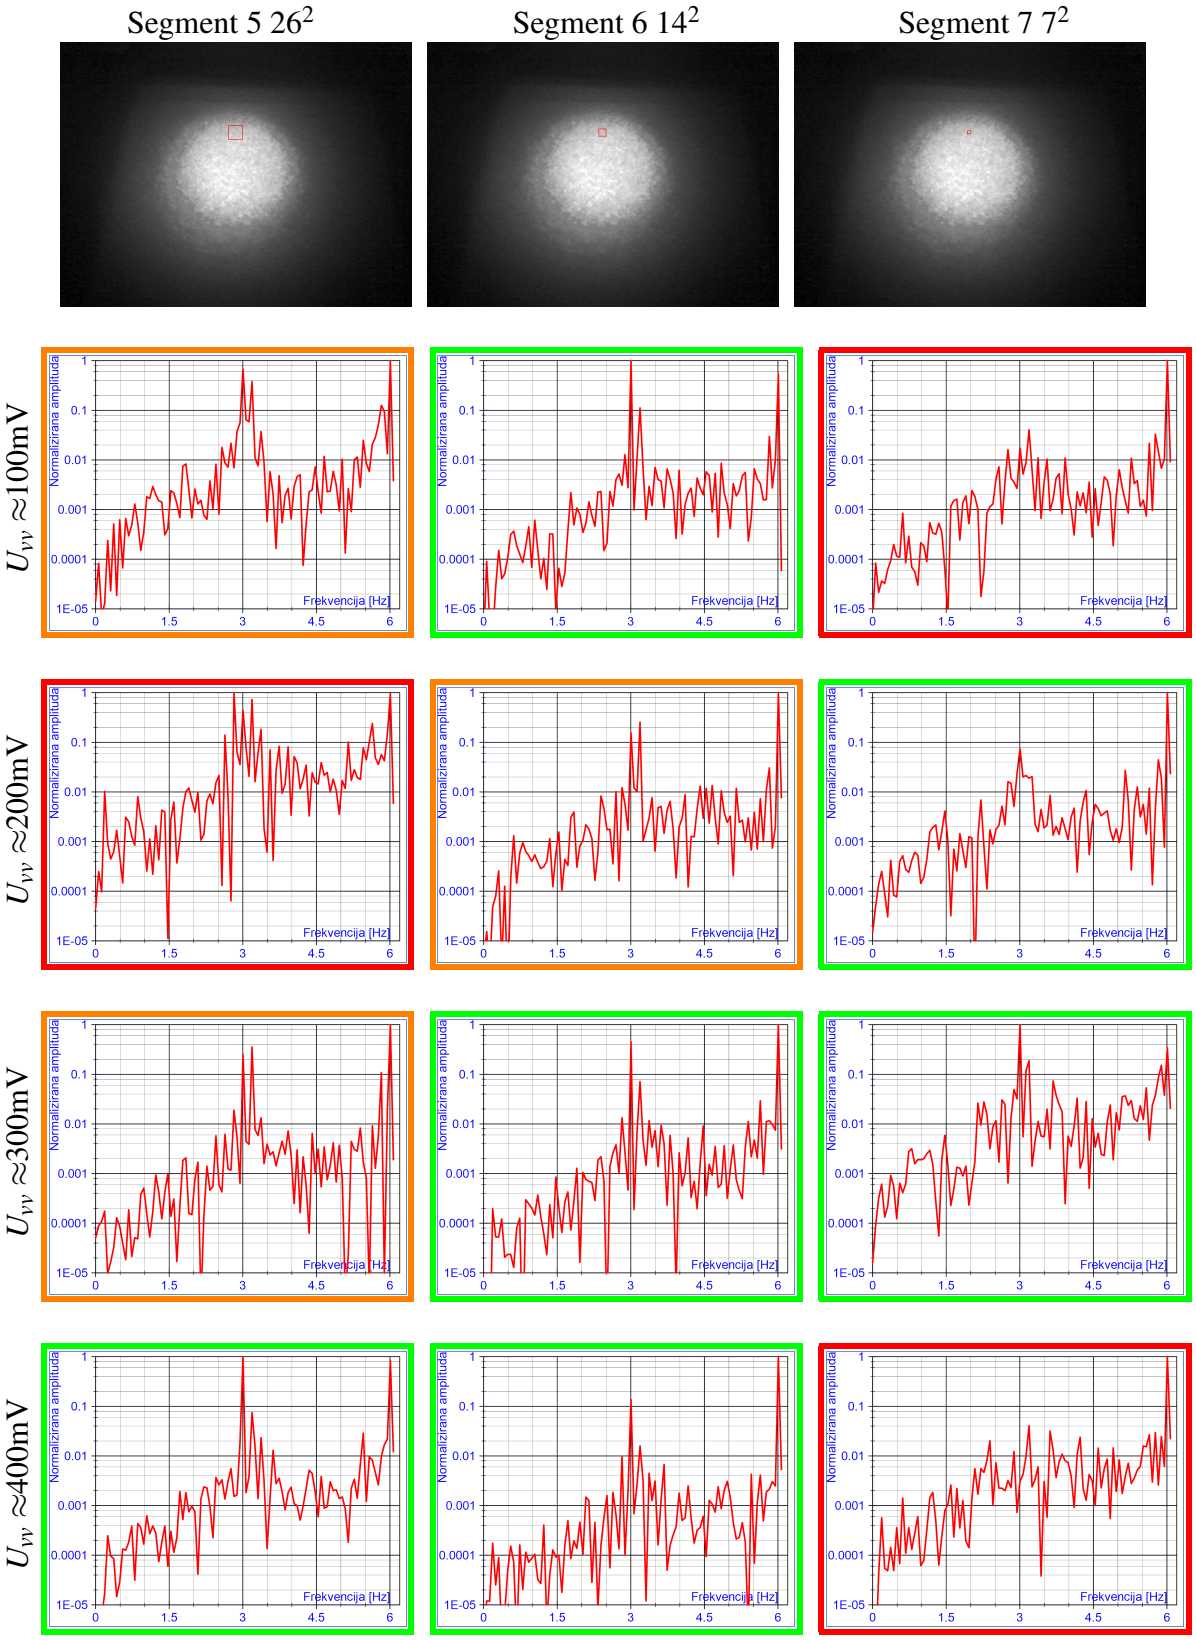

Slika 3.16: Prikaz spektara rezultata različitih segmentiranja slike za četiri različite amplitude pobudnog signala: sjeverno pozicionirani segmenti (2.dio)

Segment 8 3^2

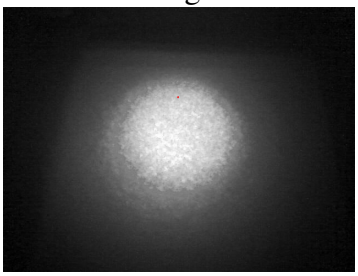

$U_{vv} \approx 100$mV

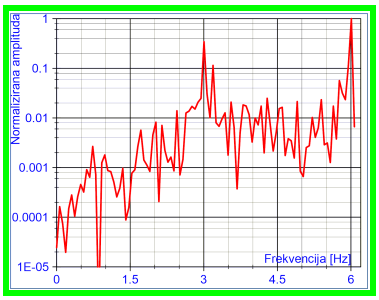

$U_{vv} \approx 200$mV

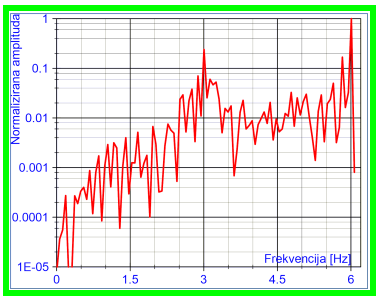

$U_{vv} \approx 300$mV

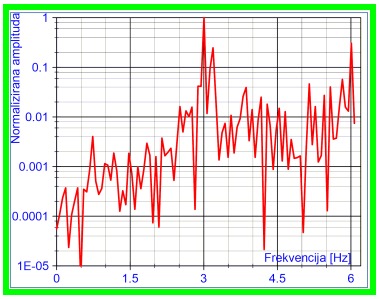

$U_{vv} \approx 400$mV

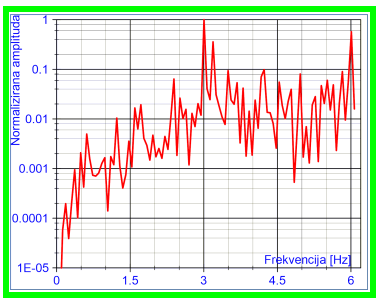

Slika 3.17: Prikaz spektara rezultata različitih segmentiranja slike za četiri različite amplitude pobudnog signala: sjeverno pozicionirani segmenti (3.dio)

3.7.4 Sjeverozapadno (NW) pozicionirani segmenti

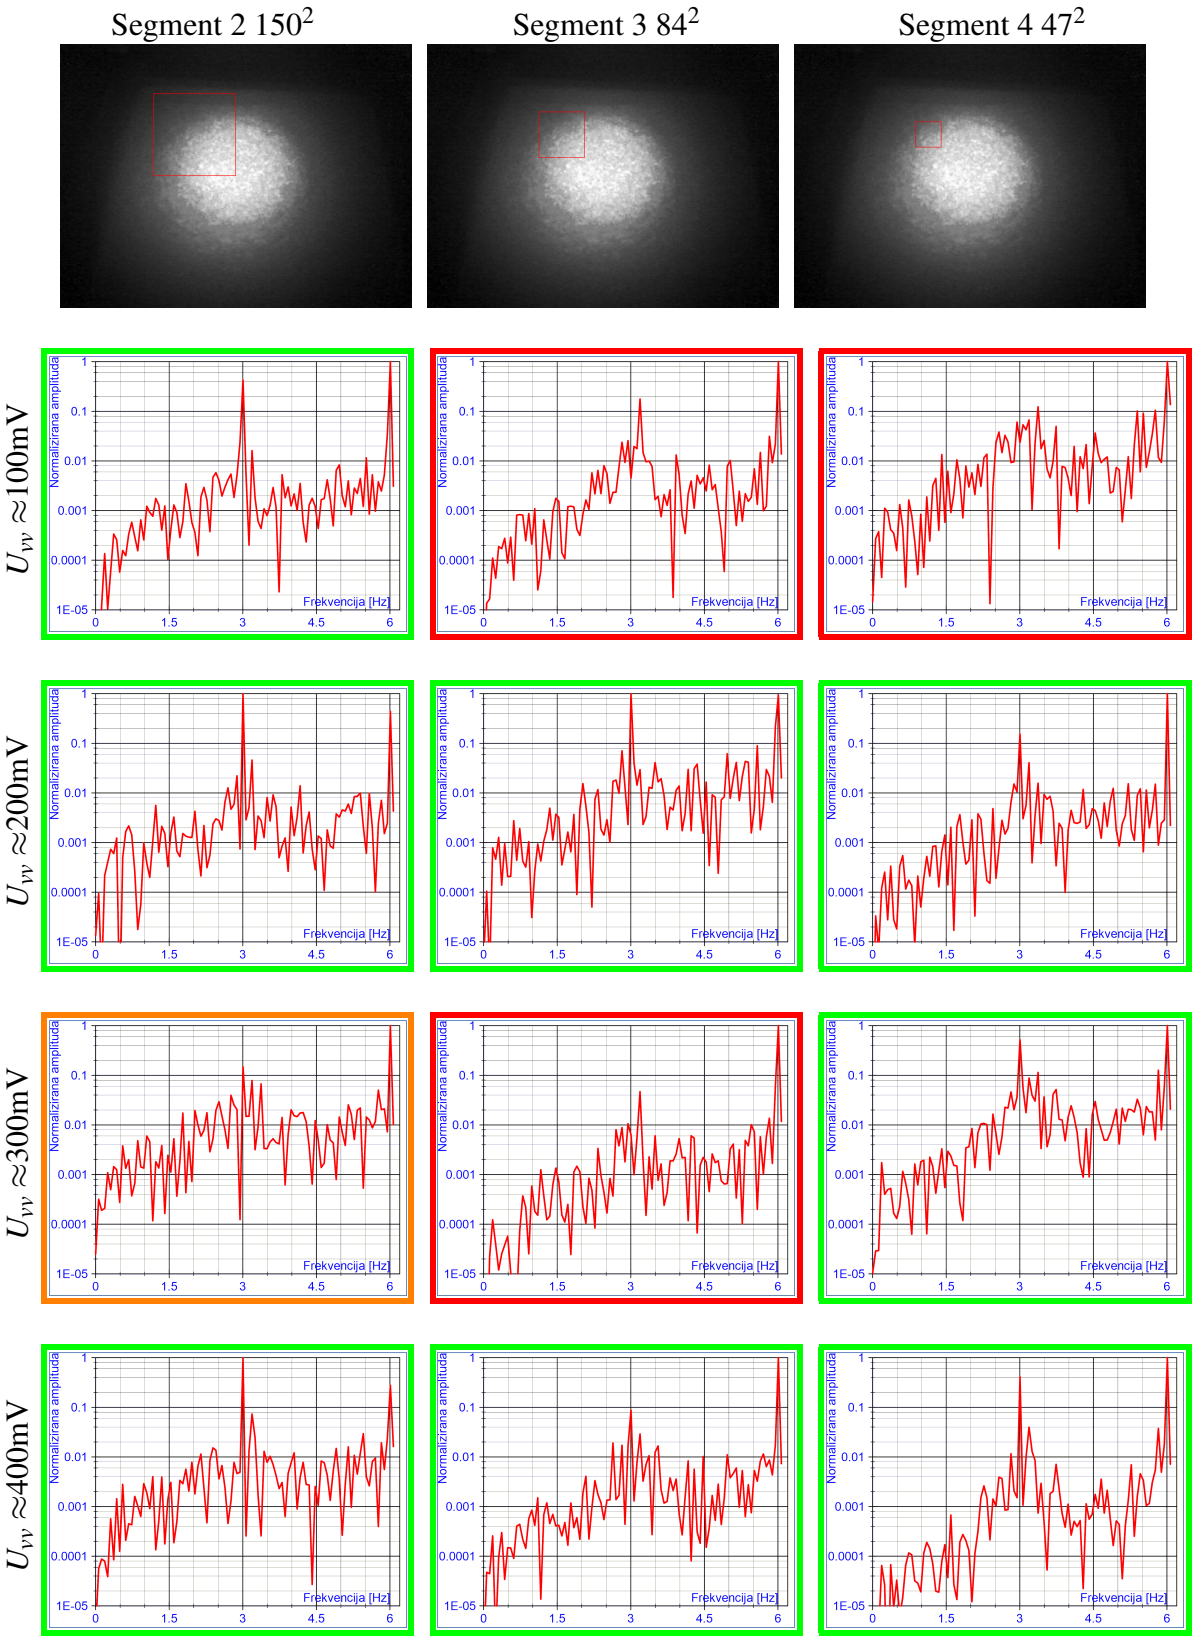

Slika 3.18: Prikaz spektara rezultata različitih segmentiranja slike za četiri različite amplitude pobudnog signala: sjeverozapadno pozicionirani segmenti (1.dio)

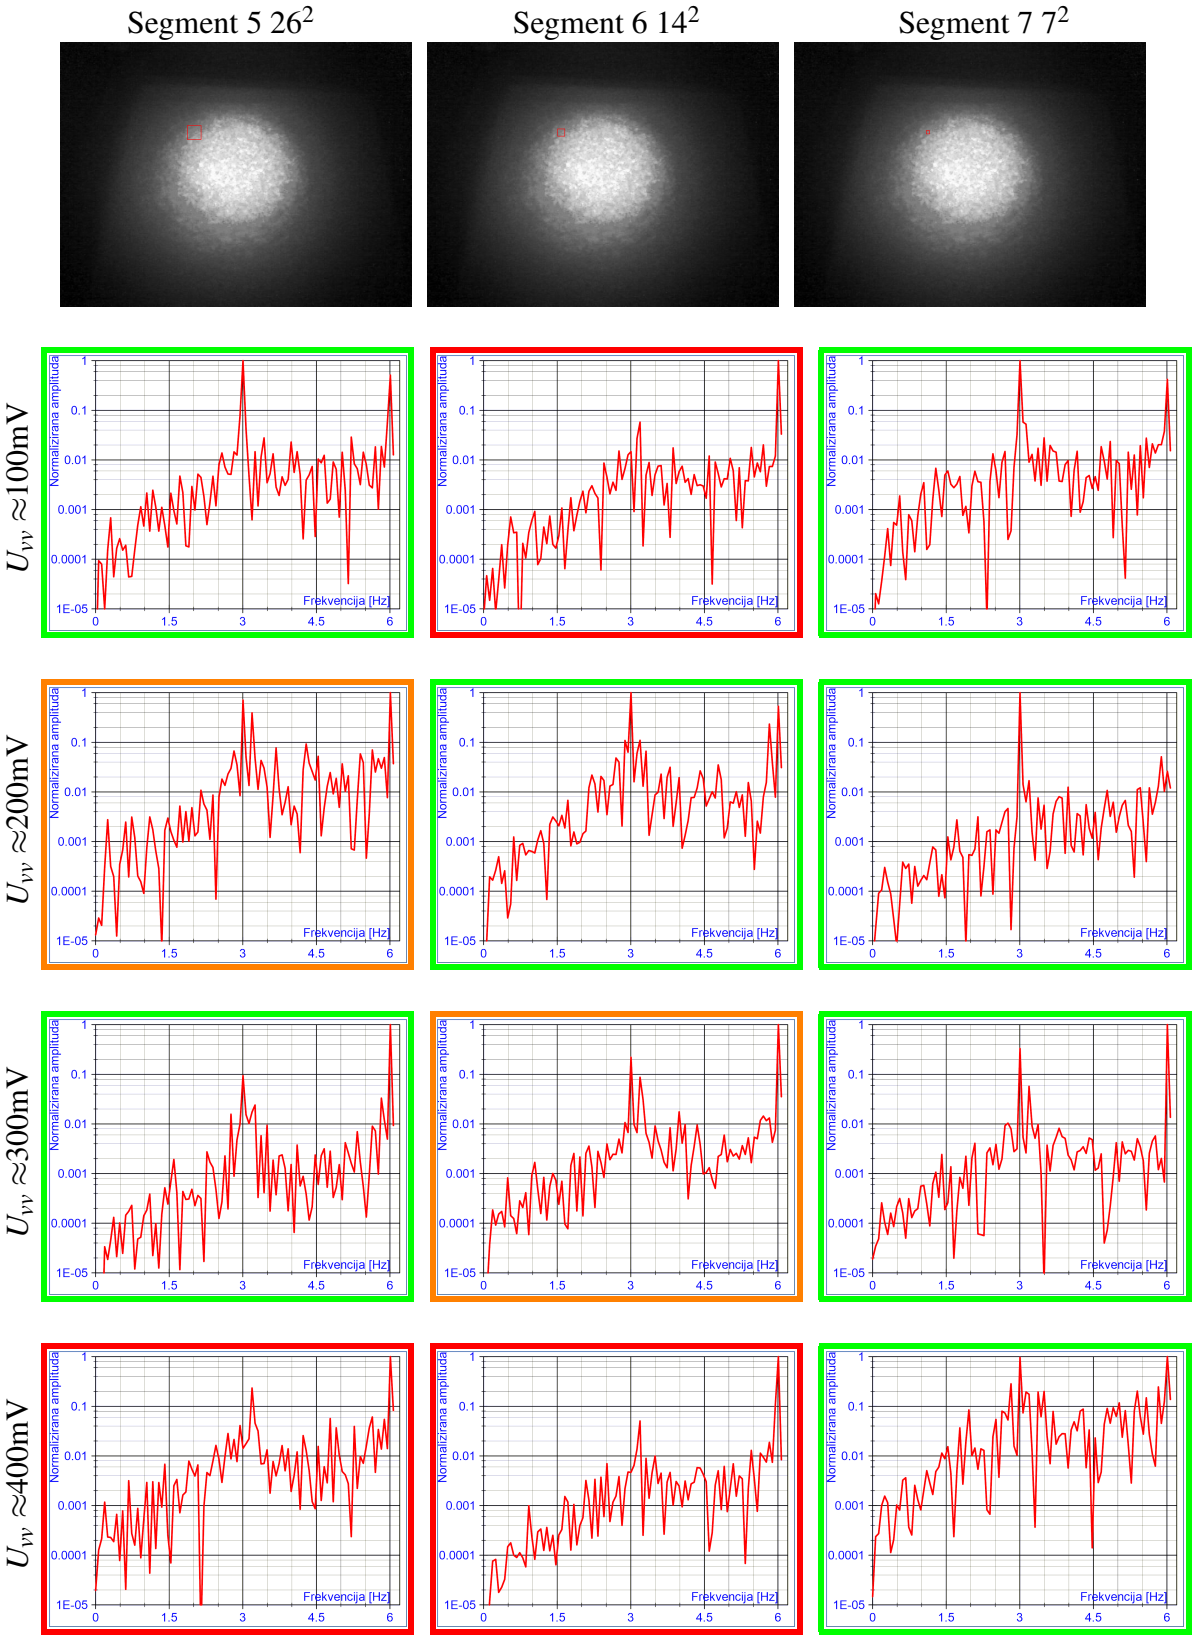

Slika 3.19: Prikaz spektara rezultata različitih segmentiranja slike za četiri različite amplitude pobudnog signala: sjeverozapadno pozicionirani segmenti (2.dio)

Segment 8 3^2

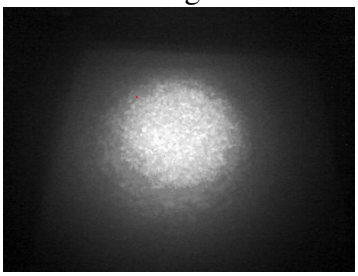

$U_{vv} \approx 100$mV

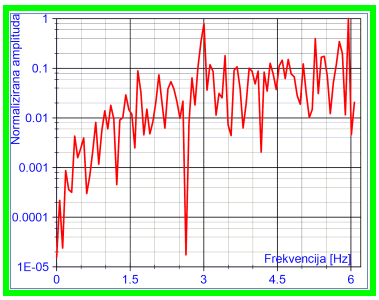

$U_{vv} \approx 200$mV

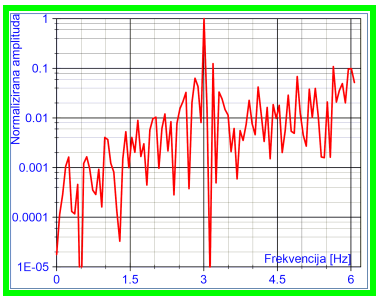

$U_{vv} \approx 300$mV

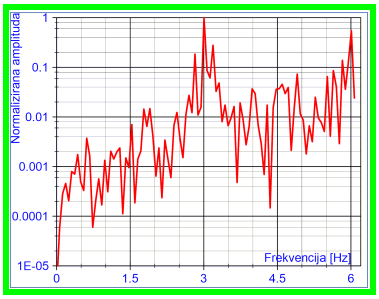

$U_{vv} \approx 400$mV

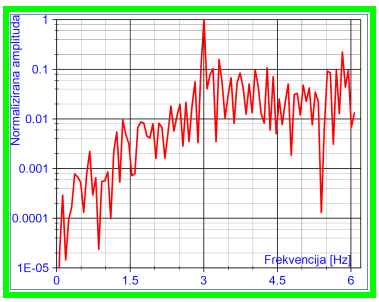

Slika 3.20: Prikaz spektara rezultata različitih segmentiranja slike za četiri različite amplitude pobudnog signala: sjeverozapadno pozicionirani segmenti (3.dio)

3.7.5 Zapadno (W) pozicionirani segmenti

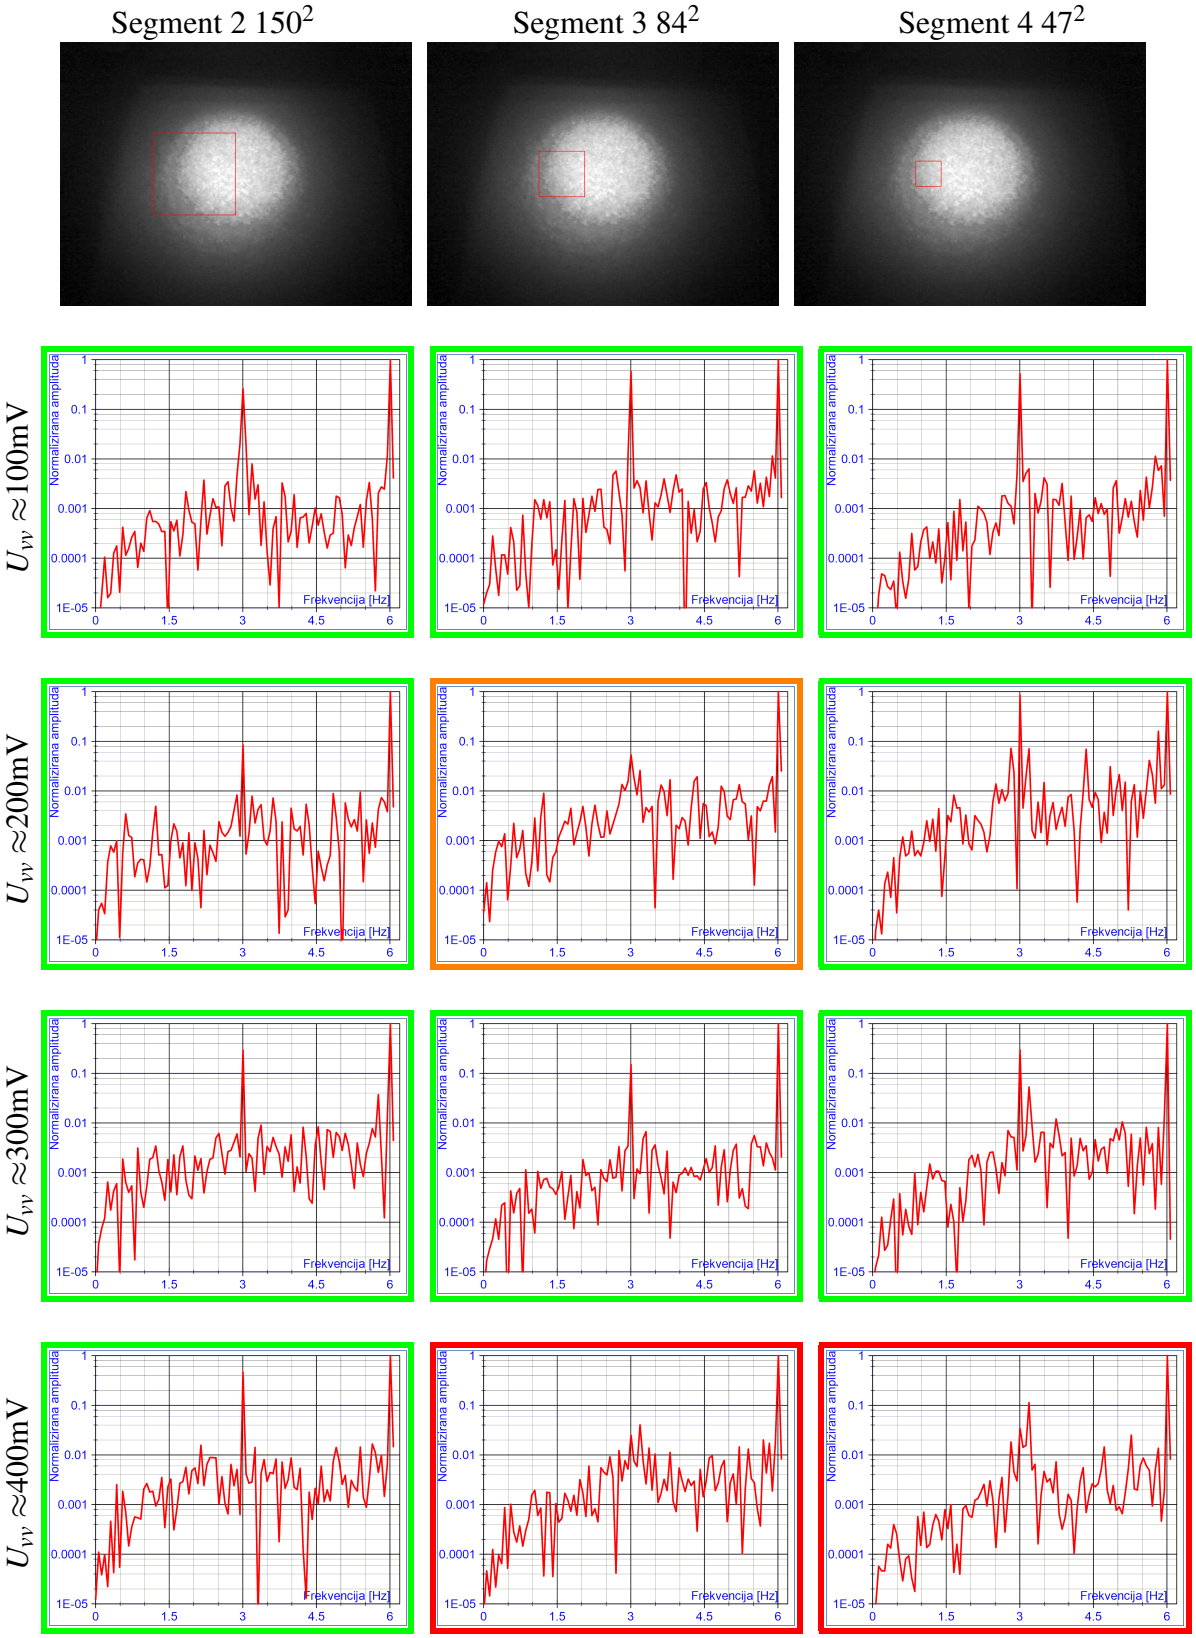

Slika 3.21: Prikaz spektara rezultata različitih segmentiranja slike za četiri različite amplitude pobudnog signala: zapadno pozicionirani segmenti (1.dio)

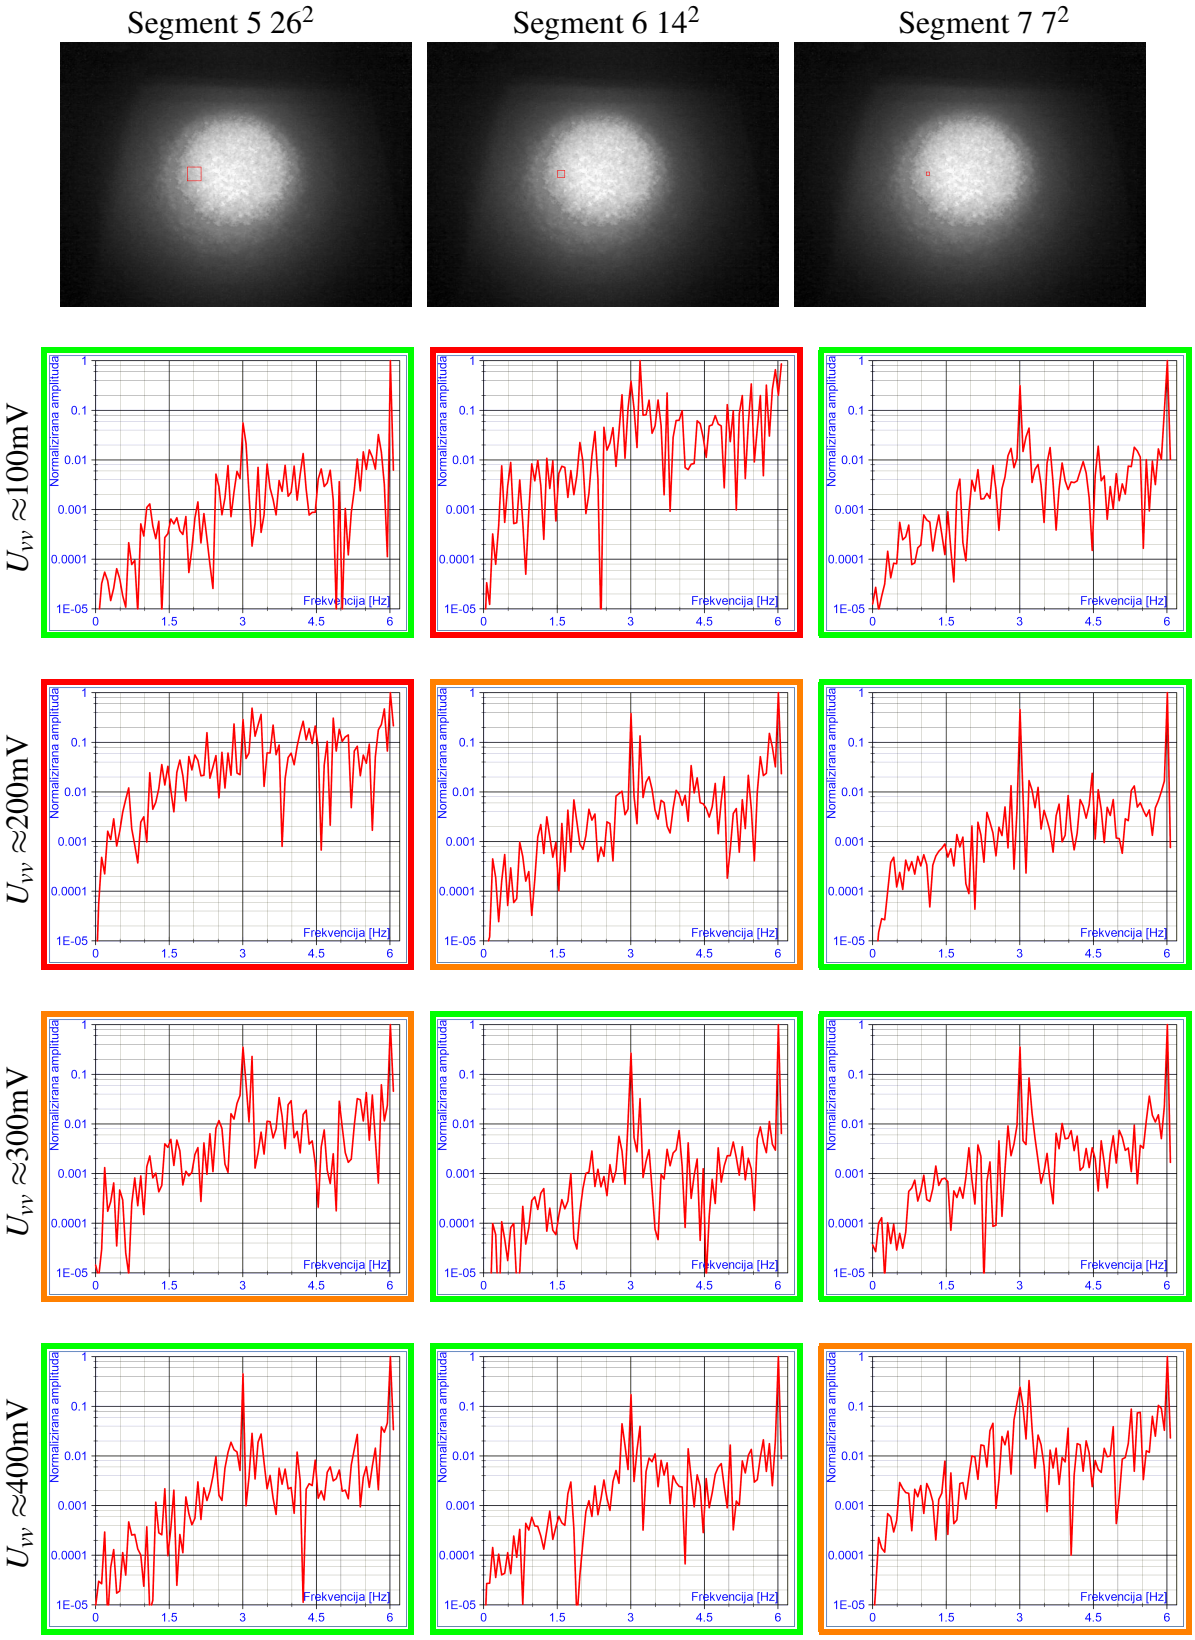

Slika 3.22: Prikaz spektara rezultata različitih segmentiranja slike za četiri različite amplitude pobudnog signala: zapadno pozicionirani segmenti (2.dio)

Segment 8 3^2

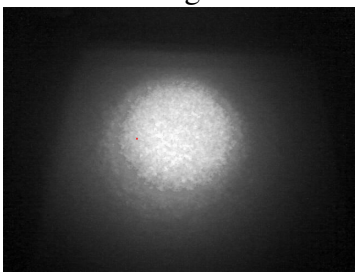

$U_{vv} \approx 100$mV

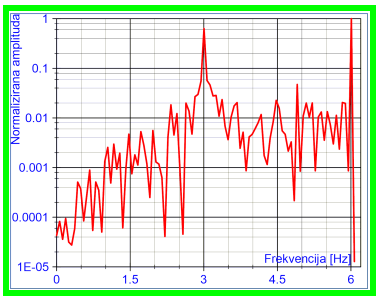

$U_{vv} \approx 200$mV

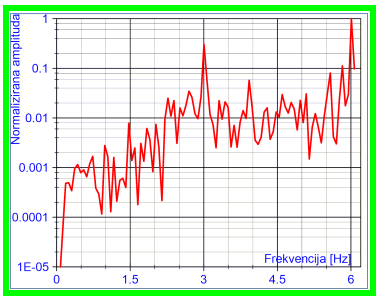

$U_{vv} \approx 300$mV

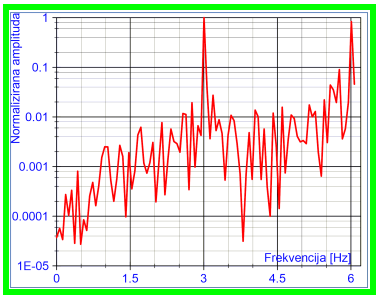

$U_{vv} \approx 400$mV

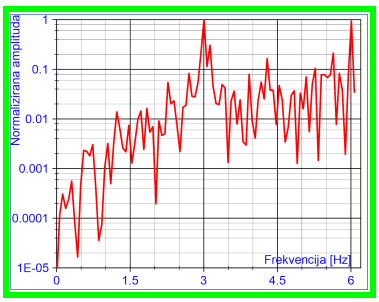

Slika 3.23: Prikaz spektara rezultata različitih segmentiranja slike za četiri različite amplitude pobudnog signala: zapadno pozicionirani segmenti (3.dio)

3.7.6 Jugozapadno (SW) pozicionirani segmenti

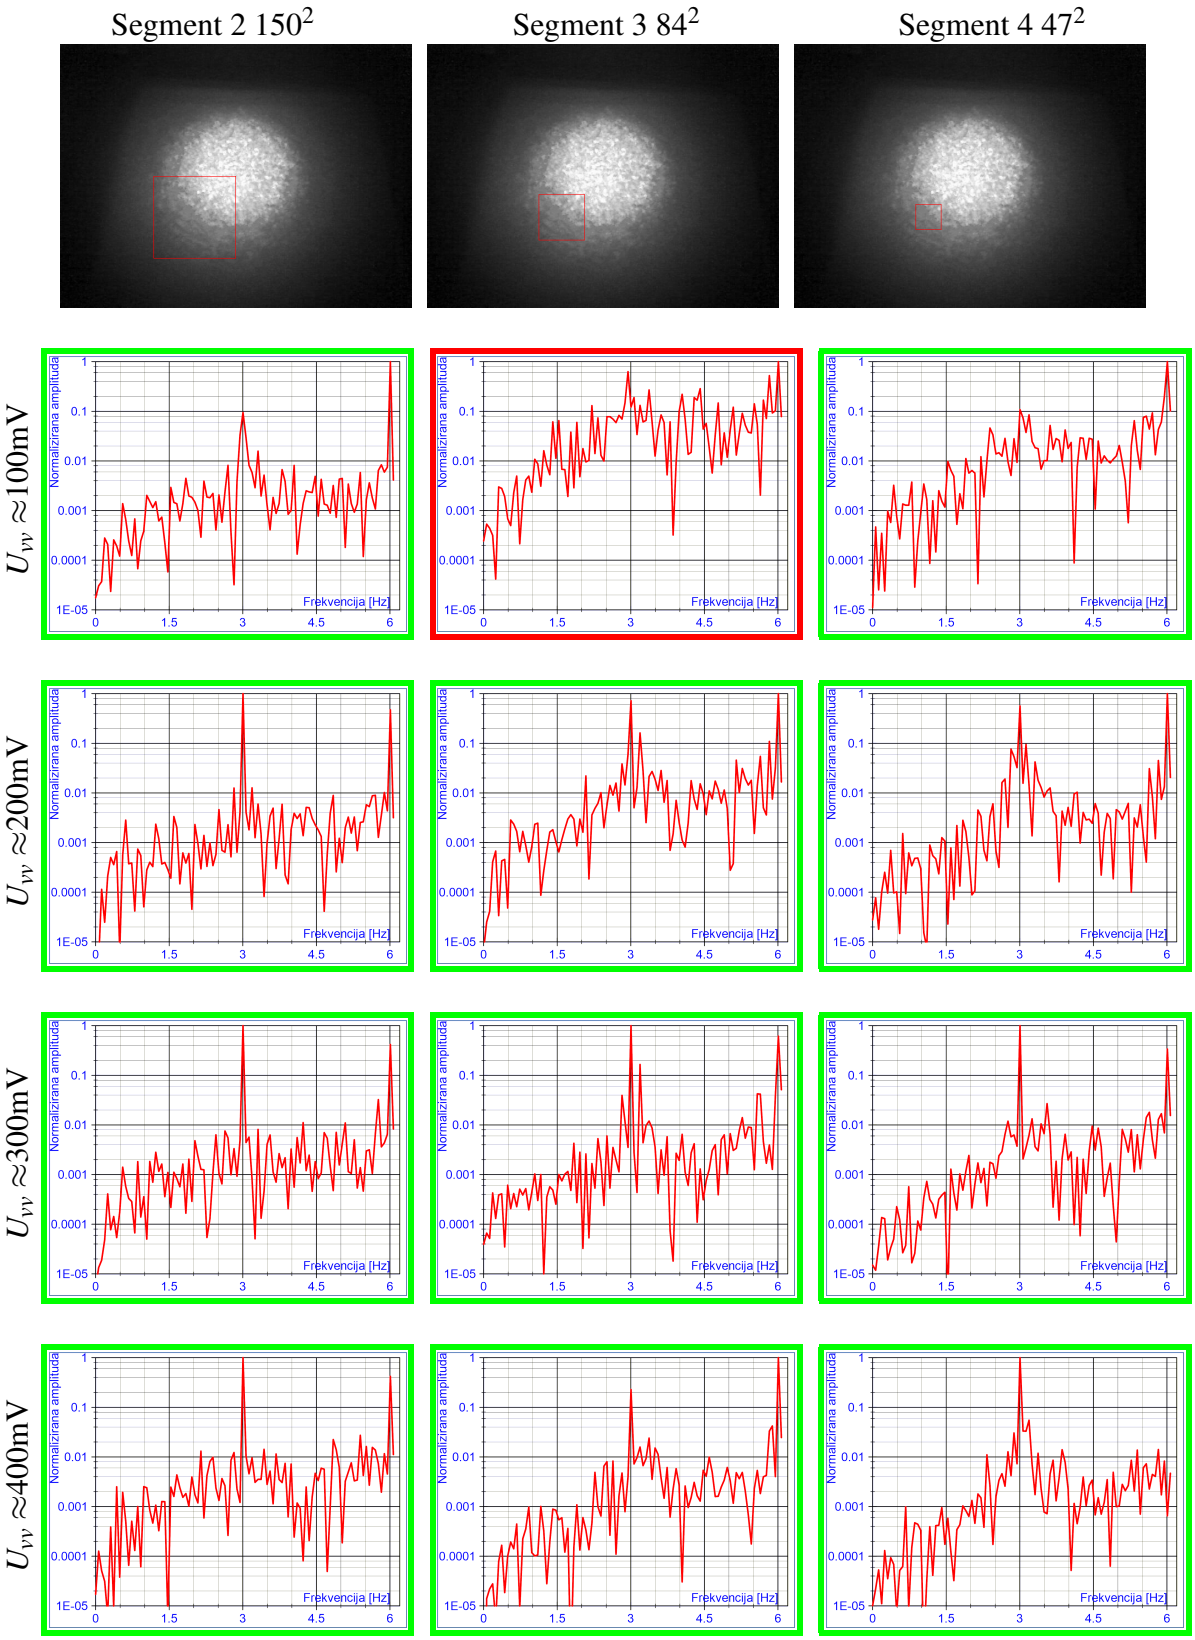

Slika 3.24: Prikaz spektara rezultata različitih segmentiranja slike za četiri različite amplitude pobudnog signala: jugozapadno pozicionirani segmenti (1.dio)

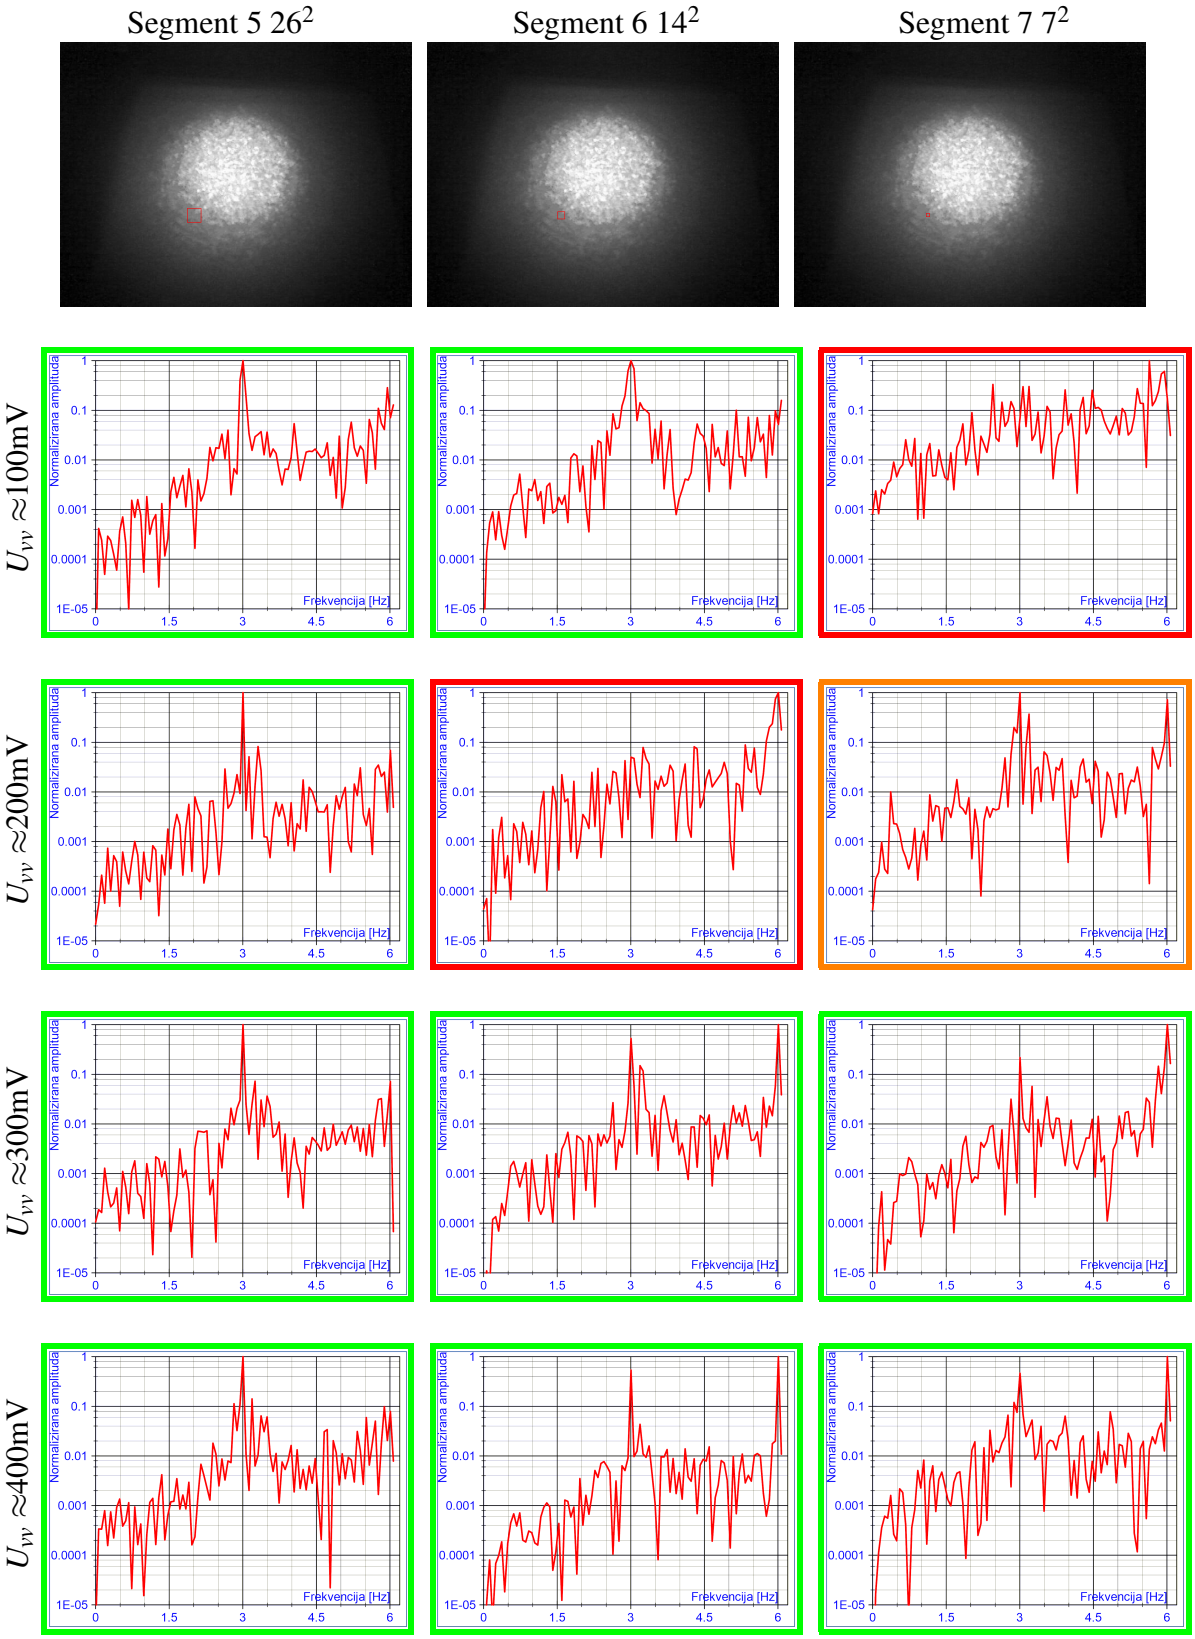

Slika 3.25: Prikaz spektara rezultata različitih segmentiranja slike za četiri različite amplitude pobudnog signala: jugozapadno pozicionirani segmenti (2.dio)

Segment 8 3^2

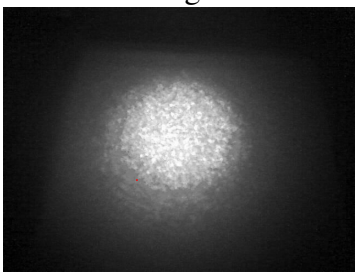

$U_{vv} \approx 100$mV

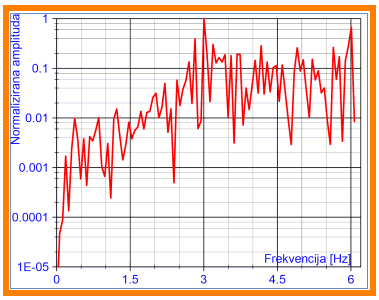

$U_{vv} \approx 200$mV

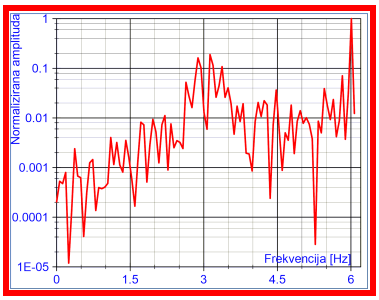

$U_{vv} \approx 300$mV

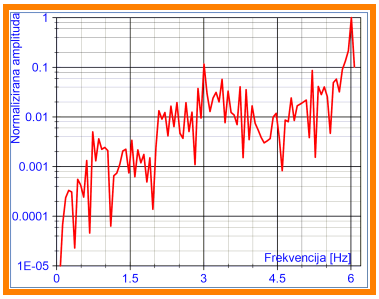

$U_{vv} \approx 400$mV

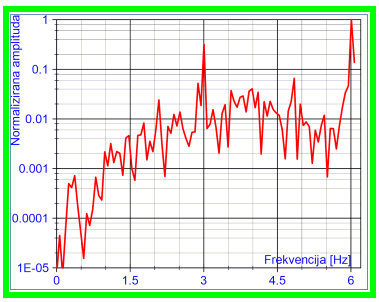

Slika 3.26: Prikaz spektara rezultata različitih segmentiranja slike za četiri različite amplitude pobudnog signala: jugozapadno pozicionirani segmenti (3.dio)

3.7.7 Južno (S) pozicionirani segmenti

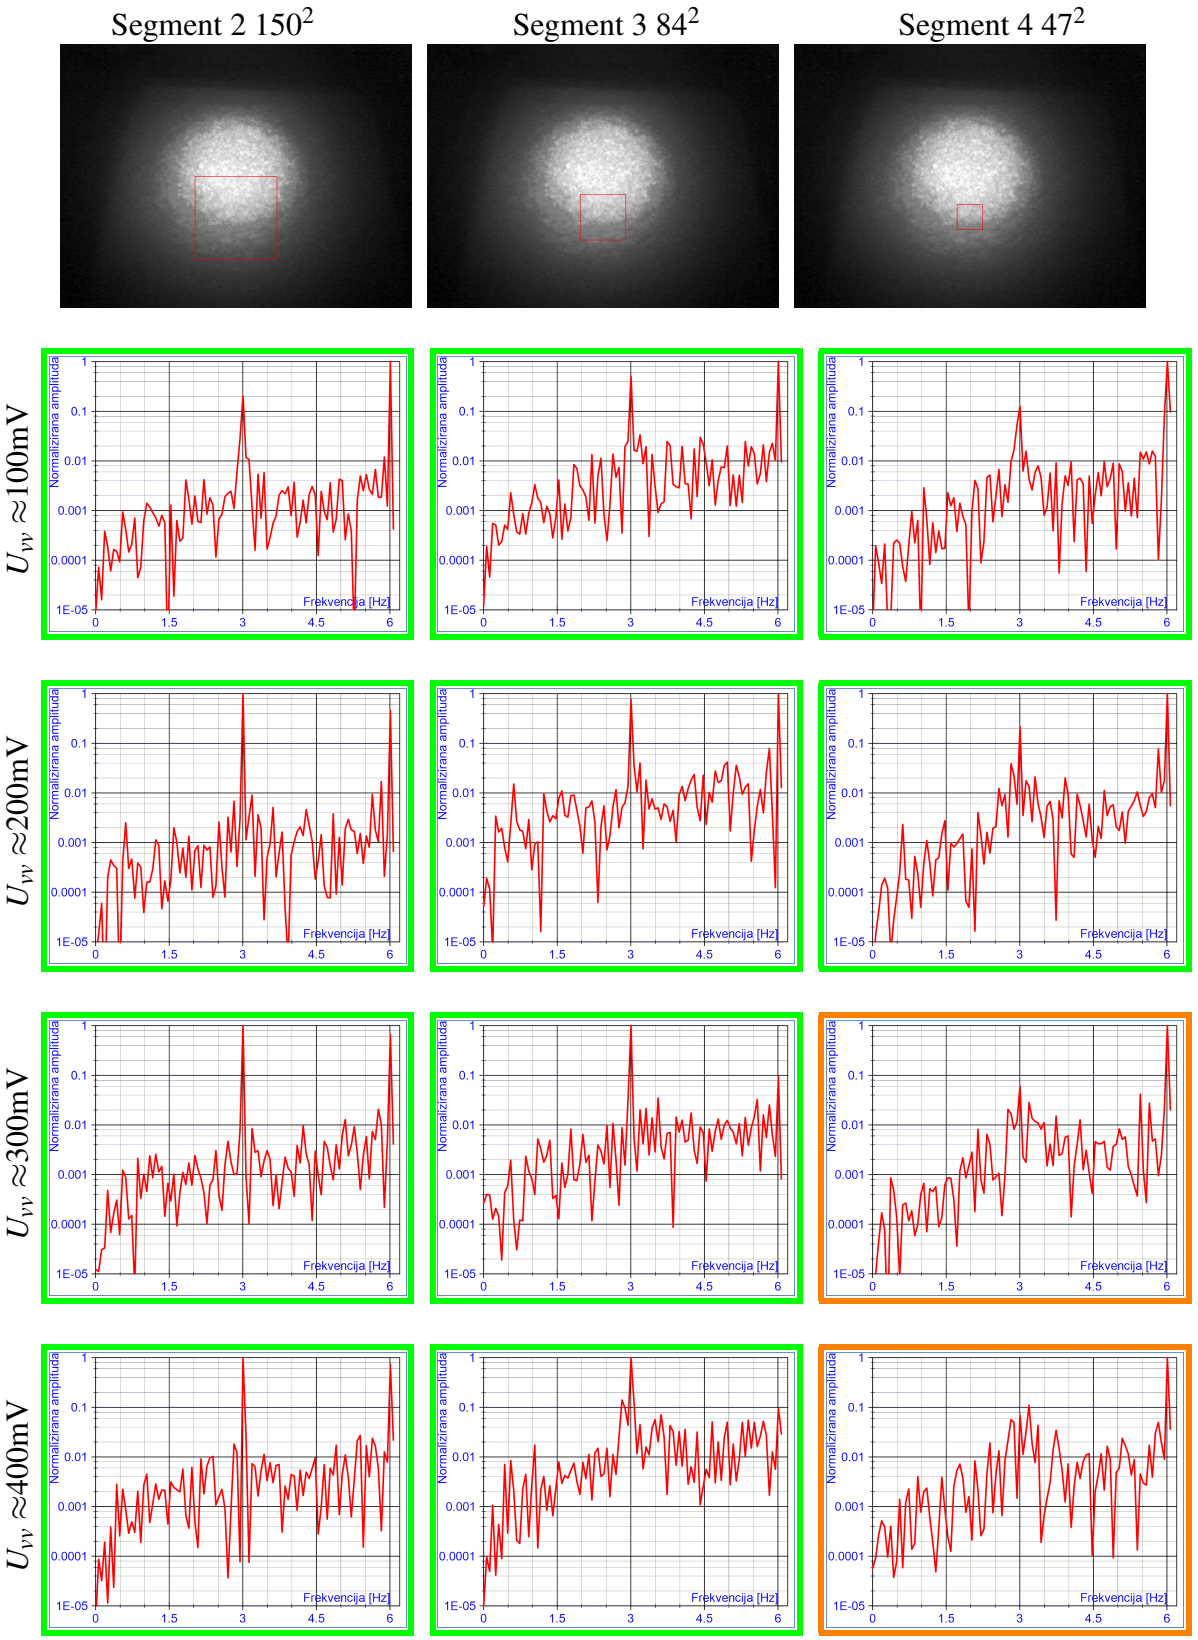

Slika 3.27: Prikaz spektara rezultata različitih segmentiranja slike za četiri različite amplitude pobudnog signala: južno pozicionirani segmenti (1.dio)

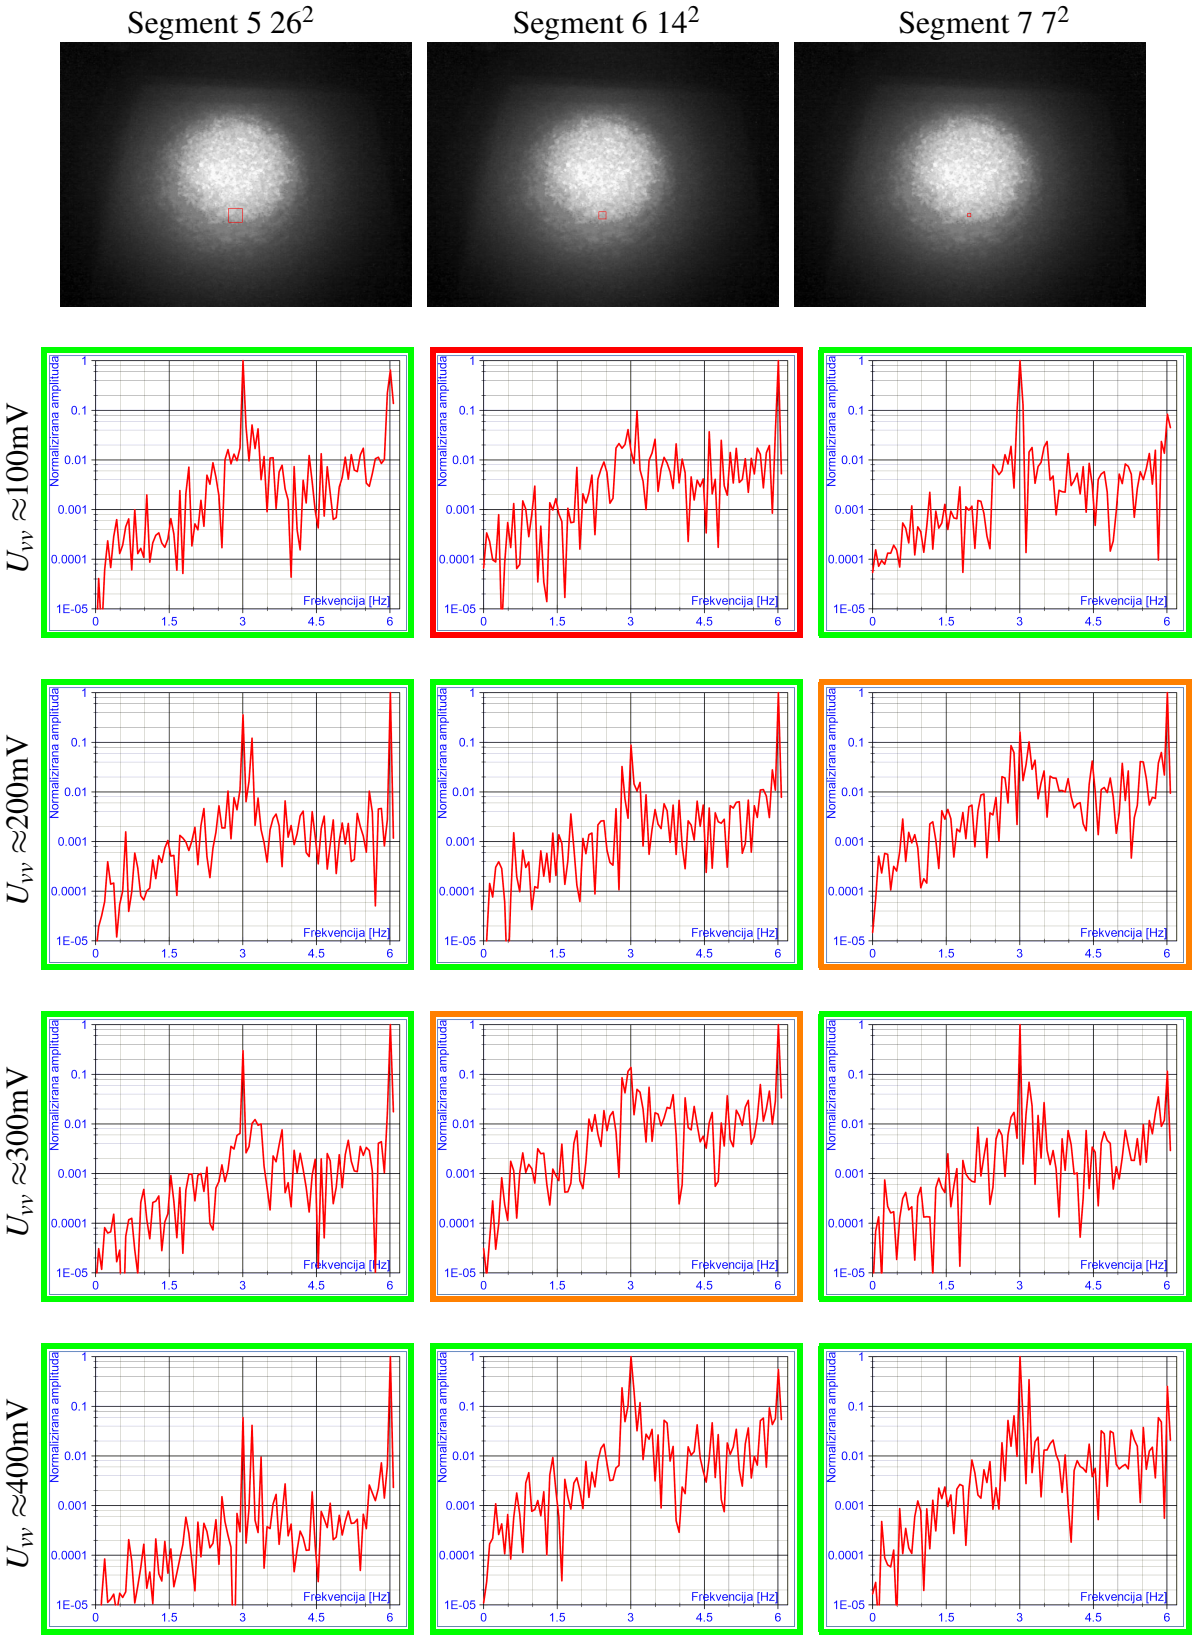

Slika 3.28: Prikaz spektara rezultata različitih segmentiranja slike za četiri različite amplitude pobudnog signala: južno pozicionirani segmenti (2.dio)

Segment 8 3^2

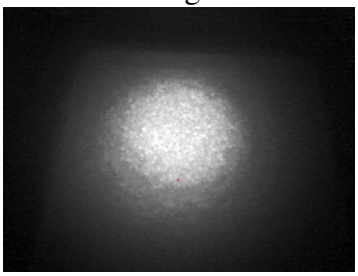

$U_{vv} \approx 100$mV

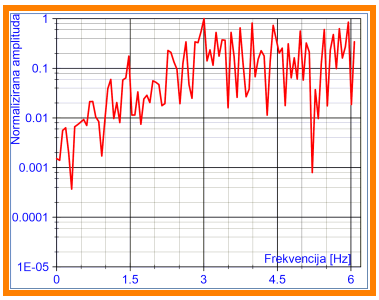

$U_{vv} \approx 200$mV

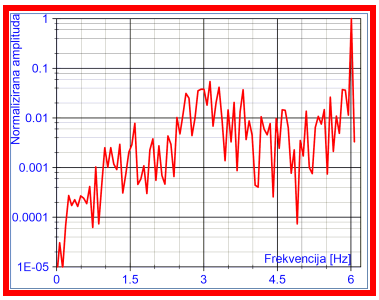

$U_{vv} \approx 300$mV

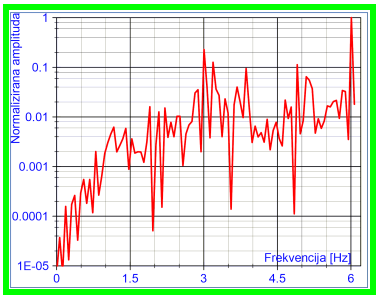

$U_{vv} \approx 400$mV

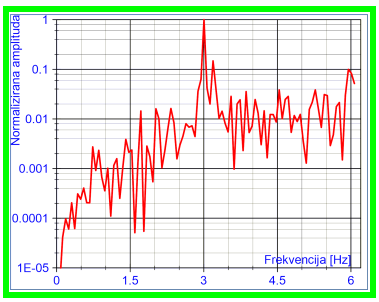

Slika 3.29: Prikaz spektara rezultata različitih segmentiranja slike za četiri različite amplitude pobudnog signala: južno pozicionirani segmenti (3.dio)

3.8 Diskusija rezultata segmentiranja točkastog uzorka

Osnovna ideja ovog pristupa je bila razmotriti mogućnost da je informacija o djelovanju vanjske sile na svjetlovod sadržana i u manjem dijelu točkastog dijagrama, a ne samo u cjelokupnoj njegovoj površini. Međutim, takav zaključak je relativno trivijalan ukoliko se opet promatra veliki broj pojedinačnih detektora, odnosno piksela, a osim toga ne dovodi bliže rješenju problema s ograničenjima koje nameće kamera. Stoga je u promatranju naznačenih segmenata slika u prikazanim rezultatima cijela površina unutar označenog okvira tretirana kao jedinstven detektor, odnosno intenziteti signala zabilježeni na pojedinim pikselima unutar okvira su sumirani i tako dobivena suma je razmatrana kao vrijednost signala segmenta u određenom vremenskom trenutku. Na taj način je dobiven signal koji se u vremenu mijenja i čijom su analizom dobiveni prikazani spektri.

Ovakav rezultat je značajan jer je usmjerio istraživanje prema mogućnosti izbacivanja kamere iz mjernog sustava, odnosno prema zamjeni kamere odgovarajućim detektorskim diodama.

Istovremeno se pokušalo eksperimentalno utvrditi pogodnu veličinu diode i poziciju na kojoj bi detekcija bila zagarantirana. Iako je ovdje prikazan velik broj pojedinačnih spektara, ukupni broj obavljenih mjerenja i simulacija je još znatno veći jer su mjerenja/simulacije obavljene i na drugim frekvencijama. Međutim, prikazani rezultati su dovoljni da se naglasi još jedan ključan zaključak, a taj je da **ne postoji određena veličina ili pozicija simuliranog segmenta koja bez iznimke garantira točne rezultate detekcije vibracija**, odnosno njihove frekvencije.

Ponuđena je jednostavna metoda vrednovanja prikazanih rezultata označavanjem okvira grafova bojama (simbolima * ? ! za crno bijeli tisak). Primijenjena metoda je temeljena na procjeni (bez krutih numeričkih granica), ali dobro služi za ilustraciju navedenog zaključka. I letimičnim pregledom rezultata se može ustanoviti da je točna detekcija vrlo česta, ali i da ponekad nepredvidivo izostaje. Takve, netočne ili nesigurne detekcije, nisu striktno vezane za neku određenu veličinu ili poziciju segmenta, odnosno amplitudu vibracijskog signala na neki očit način.

Sumarni pregled prikazanih rezultata s aspekta točnosti detekcije frekvencije vibracija:

Točna detekcija 68,75% | Nesigurna detekcija 15,34% | Netočna detekcija 15,91%

Treba napomenuti i da predstavljeni rezultati predstavljaju *zapadne* dvije trećine točkastog uzorka. Pod pretpostavkom da je kružna simetrija poprečnog presjeka vlakna dovoljan poticaj za intuitivni zaključak da se raspored uzorka neće drastično mijenjati za ostatak slike, preostali dio rezultata nije prezentiran.

Konačno, na temelju ovih rezultata pretpostavljeno je da se upotrebom nekoliko detekcijskih segmenata/dioda, raspoređenih po točkastom uzorku, može prikupiti dovoljno različitih pojedinačnih signala da bi se u potpunosti izbjegao gubitak detekcije vibracija, odnosno da bi se njihova detekcija mogla obaviti s velikim stupnjem pouzdanosti.

Sljedeći korak istraživanja je simulacija nekoliko detektorskih segmenata (dioda) koji istovremeno obavljaju detekciju na različitim pozicijama točkastog uzorka. Pri tome se svaki od segmenata tretira kao zaseban element detekcije - detektorska dioda. Potrebno je istražiti i različite statističke modele kombinacija tako prikupljenih signala, kako bi se došlo do ukupnog rezultata koji bi bio koreliran sa signalom svakog pojedinačnog detektora.

Time se omogućuje testiranje prethodno navedene pretpostavke i prikupljaju se podaci potrebni za izradu fizičkog sustava za detekciju vibracija preko točkastog uzorka pomoću pojedinačnih detektorskih dioda, odnosno uz eliminaciju kamere koja postavlja ranije opisana oštra ograničenja na funkcioniranje sustava.

3.9 Promjena pristupa analize slike

Prethodno prikazanim rezultatima utvrđeno je da se najbolje pozicije za detekciju vibracija nalaze uz rub točkastog uzorka. Naime, kao što je iz samog točkastog uzorka očito, najveći dio energije raspodijeljene u modovima se nalazi u središtu vlakna, odnosno njegove jezgre. Iako i među tim modovima dolazi do preraspodjele intenziteta, te su promjene manje značajne i dominantne nego što je to slučaj s promjenama intenziteta za modove koji se nalaze blizu ruba jezgre, odnosno u dijelu u kojem je koncentrirana manja količina ukupne energije. Kada se u tom dijelu presjeka dogode promjene one su značajnije i lakše uočljive. To je očekivani rezultat jer je energija koja se nalazi u rubnom dijelu jezgre direktnije vezana uz više modove koji se šire vlaknom. Na takve modove geometrijska izobličenja vlakna, koja su izraženija dalje od središta jezgre vlakna, jače i djeluju. Do vrlo sličnog zaključka su relativno nedavno došle i druge istraživačke grupe [48, 49, 50], metodama koje su dugačije od ovdje opisanih i primijenjenih. Ta činjenica daje još veću težinu zaključcima koji su proizašli iz simulacija segmentiranja slike.

Usprkos svemu navedenom, uzimanjem u obzir samo jednog takvog segmenta ne može se ostvariti pouzdana detekcija vibracija. Iako će ona u većini slučajeva biti uspješna, ne postoji nikakva garancija da će se preraspodjela intenziteta dogoditi u nekom određenom rubnom području točkastog uzorka. Moguće je primjenom prstenaste maske uzeti u obzir cijelo rubno područje točkastog uzorka kao što su uradile druge istraživačke grupe. Time bi bila smanjena ukupna količina podataka koji se trebaju obraditi, ali takav pristup ne otklanja potrebu za korištenjem kamere, što je bio primarni cilj u daljnjem istraživanju. Uzevši u obzir sve dotadašnje rezultate zaključeno je da je za pouzdanu detekciju potrebno prikupiti i obraditi više od jednog segmenta slike, a potom na prikupljene podatke primijeniti neku statističku metodu korelacije, kako bi konačni rezultat zastupao sve pojedinačne segmente ukupne slike.

3.9.1 Mogućnost simuliranja višestrukih detektorskih segmenata

Nova nadogradnja mjernog sustava se sastojala u daljnjoj doradi sustava za obradu koji je nakon ovog poboljšanja omogućavao simulaciju mjernog sustava s višestrukim segmentima za detekciju. Višestruki segmenti su pri tome mogli biti postavljeni u dvije različite konfiguracije prikazane na slici 3.30. Nadalje, bilo je moguće mijenjati i ukupni broj segmenata kao i njihovu veličinu.

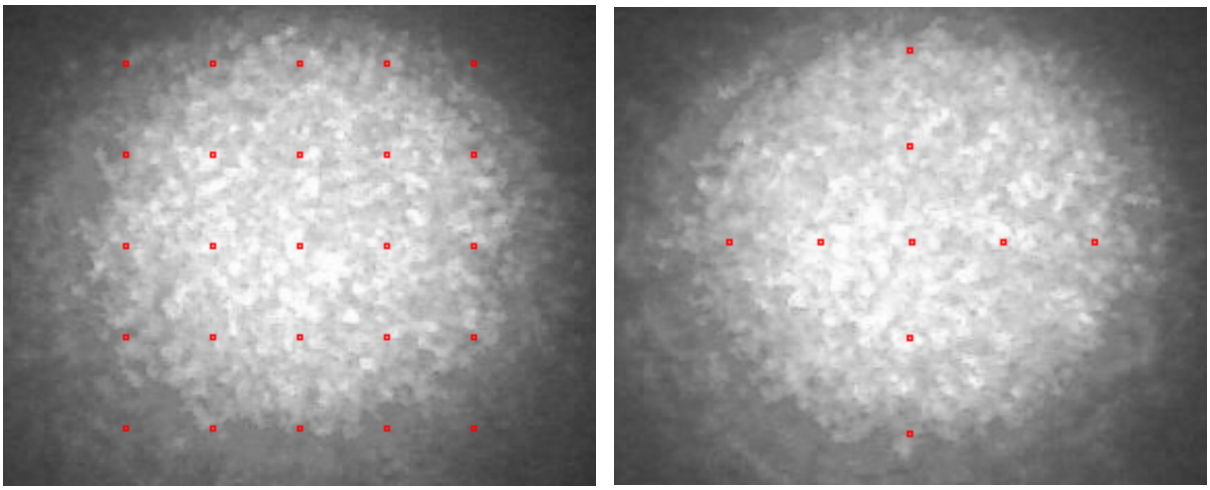

(a) Dvodimenzionalno polje detektora

(b) Ukrižana linearna polja detektora

Slika 3.30: Simulacija detektorskih dioda u dvije konfiguracije

Sustavnim eksperimentiranjem došlo se do zaključka da je moguće značajno smanjiti veličinu uzorka (u odnosu na cijelu sliku) te da nije potrebno obuhvatiti sva rubna područja, već nekoliko ključnih razdvojenih pozicija. Takvim postavkama mjernog sustava potpuno uspješno je obavljena detekcija za sve snimljene i testirane slučajeve.

U svojoj konačnoj varijanti za rad s kamerom ili alternativnim učitavanjem videa/slika, te mogućnostima odabira pojedinačnih ili višestrukih segmenata u različitim konfiguracijama korisničko sučelje je imalo izgled prikazan na slici 3.31.

Novo proširenje opcija za parametrizaciju mjerenja omogućavalo je odabir:

- mjerenja uživo/iz videa/iz niza slika
- broja uzoraka za FFT (*Fast Fourier Transform*)
- segmentacije slike za jedan segment promjenjive veličine ili za polje simuliranih detektorskih dioda
- područja slike na kojem se obavlja segmentacija/na kojem se simuliraju diode
- redukcijskog faktora pri uzastopnim simulacijama za veličinu segmenta/broj dioda
- u slučaju simulacije detektorskih dioda
  - početnog broja dioda po osi x
  - početnog broja dioda po osi y
  - promjene početnog broja dioda po jednoj ili obje osi kroz simulaciju

  - veličine simuliranih dioda
- zapisivanja rezultata u tekstualnu datoteku.

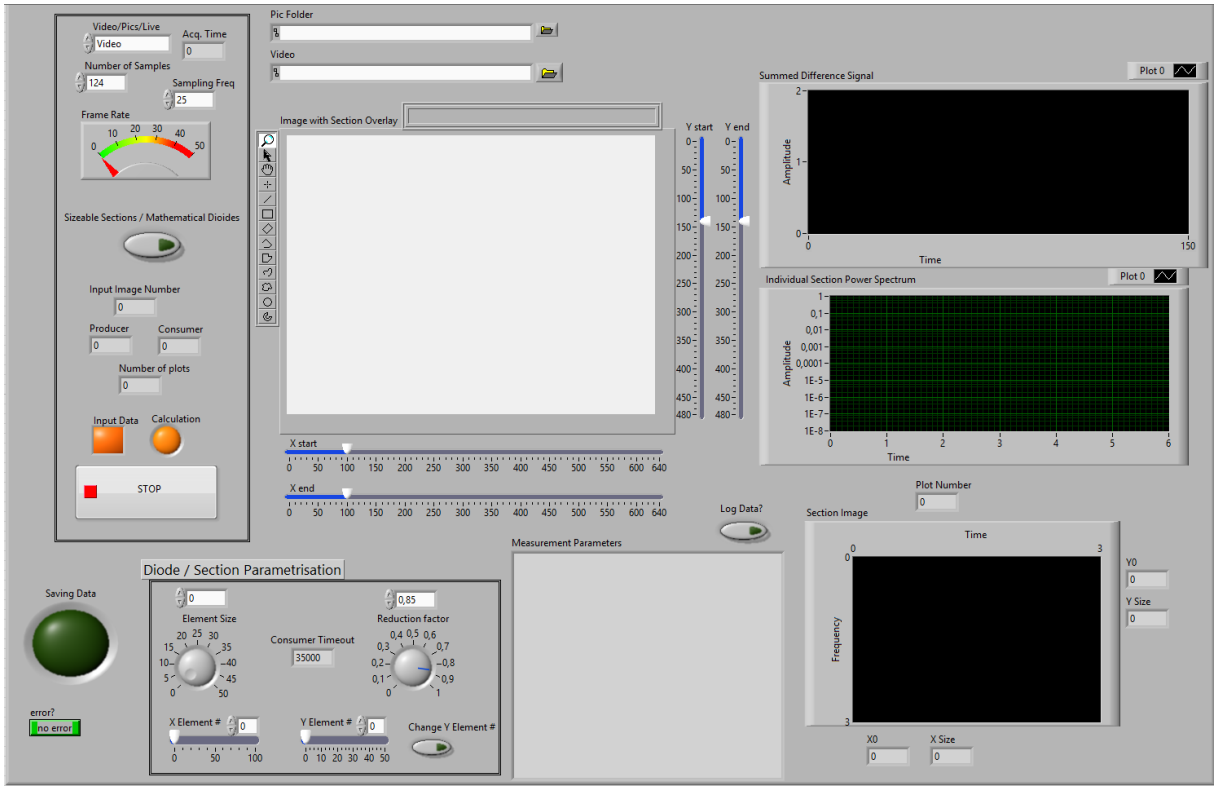

Slika 3.31: Korisničko sučelje konačne verzije programa za mjerenje vibracija u realnom vremenu ili na temelju prethodno napravljenih snimki uz mogućnost simulacije jednostrukih/višestrukih segmenata za analizu slike

Osim određivanja rasporeda, veličine i broja segmenata koji su sudjelovali u obradi, odnosno u izračunu rezultata mjerenja, unapređenjem programa je omogućeno i da se provede nekoliko uzastopnih simulacija u kojima se u slučaju pojedinačnih segmenata pripadajuća veličina smanjuje, a u slučaju višestrukih segmenata (simuliranih dioda) veličina segmenata ostaje ista, ali se smanjuje njihov broj na zadanoj površini. Primjeri za ovakve višestruke simulacije su ponuđeni na slici 3.32 i slici 3.33.

Budući da se radilo o većem broju uzastopnih simulacija s različitim parametrima, ukupni rezultat je radi lakše usporedbe bio prikazan na odvojenom ekranu na kojem je bilo moguće uključiti ili isključiti pojedine elemente prikaza (*Plot X*), odnosno neke veličine segmenata ili broj dioda što je prikazano na slici 3.35.

Uz rezultate mjerenja popratno je zapisivana i datoteka koja sadržava podatke o parametrima obavljene simulacije, kako bi na raspolaganju bila dostupna potpuna informacija o provedenom postupku. Primjer takvog zapisa dan je na slici 3.34, a rezultat pripadajućeg mjerenja na slici 3.35.

Još jedna inovacija uvedena u sustav je mogućnost odabira između različitih statističkih metoda obrade signala pojedinih segmenata. Te metode će detaljnije biti pojašnjenje u sljedećem

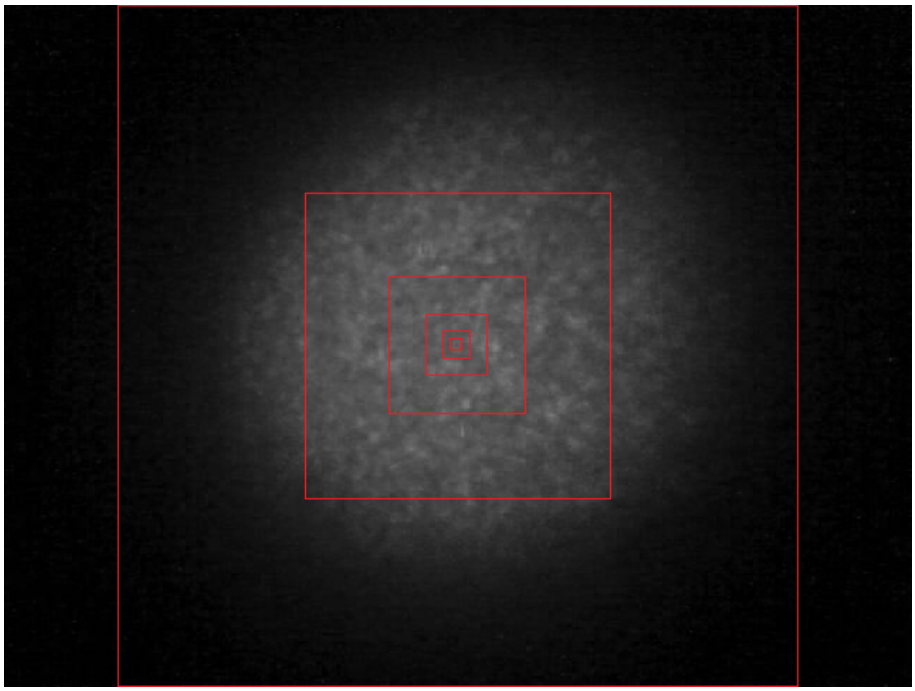

Slika 3.32: Prikaz različitih veličina segmentacije slike na točkastom uzorku

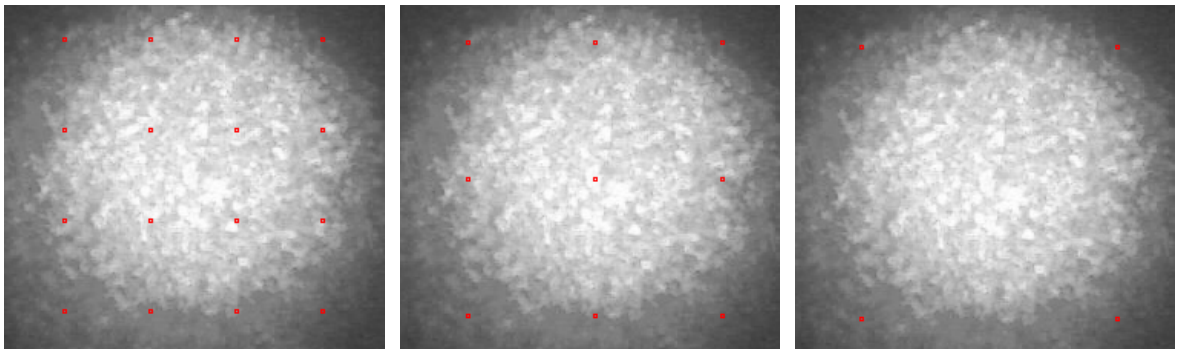

(a) 16 simuliranih segmenata (b) 9 simuliranih segmenata (c) 4 simulirana segmenta

Slika 3.33: Raspored simuliranih segmenata - detektorskih dioda za:

poglavlju. Takvim pristupom je moguće, bez obzira na broj simuliranih segmenata, doći do jedne integralne vrijednosti izračunate na temelju vrijednosti sa svih segmenata u danom vremenskom trenutku. Promatranjem tih vrijednosti kroz vrijeme dobije se vremenski signal koji bi očekivano trebao biti koreliran s mehaničkom pobudom koja djeluje na svjetlovodno vlakno.

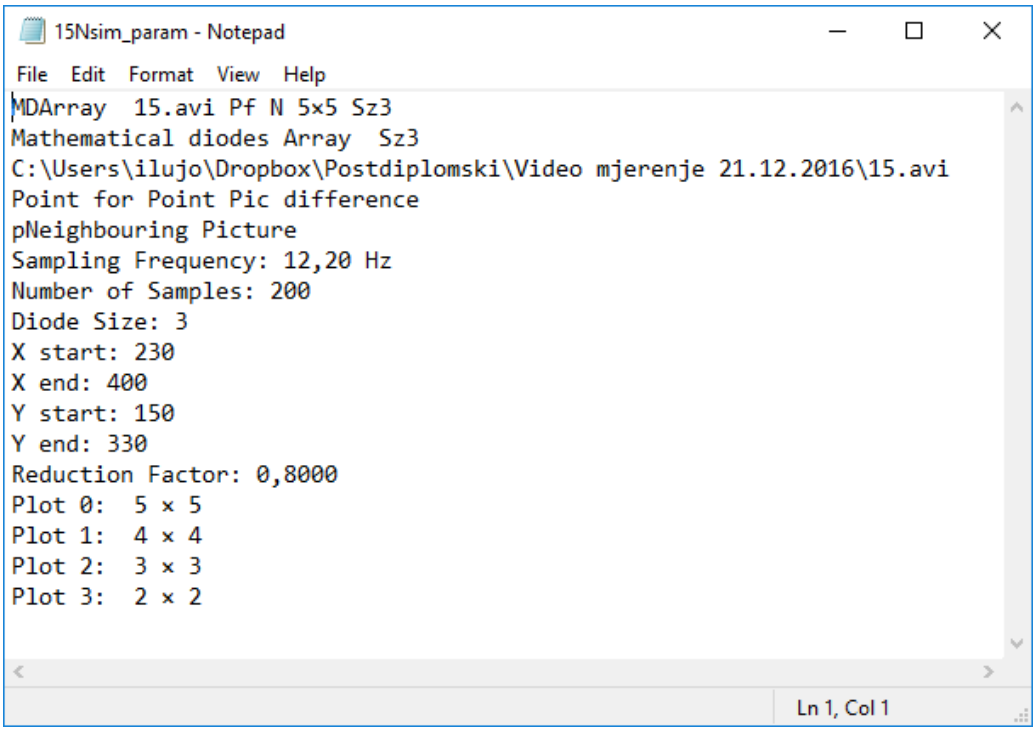
15Nsim_param - Notepad

File Edit Format View Help

```
MDArray  15.avi Pf N 5x5 Sz3
Mathematical diodes Array  Sz3
C:\Users\ilujo\Dropbox\Postdiplomski\Video mjerenje 21.12.2016\15.avi
Point for Point Pic difference
pNeighbouring Picture
Sampling Frequency: 12,20 Hz
Number of Samples: 200
Diode Size: 3
X start: 230
X end: 400
Y start: 150
Y end: 330
Reduction Factor: 0,8000
Plot 0:  5 x 5
Plot 1:  4 x 4
Plot 2:  3 x 3
Plot 3:  2 x 2
```

Ln 1, Col 1

Slika 3.34: Zapis parametara provedene višestruke simulacije

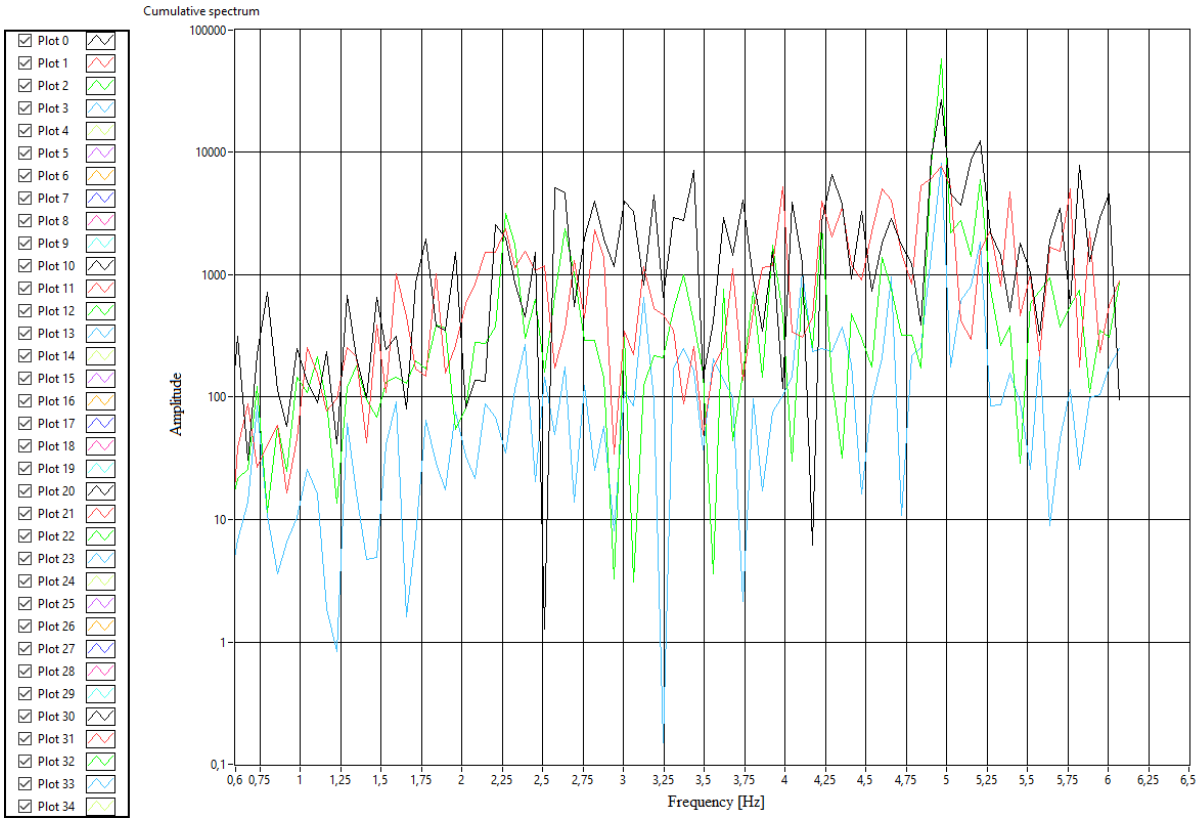

Slika 3.35: Rezultat višestrukih simulacija s promjenjivim brojem dioda za konfiguraciju 2D polja pri vibracijama frekvencije 5Hz

Poglavlje 4

Metode za analizu signala iz detektorskih dioda

U ovom poglavlju detaljnije su pojašnjene pojedine metode korištene za analizu signala s detektorskih dioda. Korelacijom pojedinačnih signala s dioda izračunati su signali koji sadrže informaciju o vibracijama kojima je svjetlovod izložen. Kao primjer za objašnjenje metoda razmatran je sustav dvodimenzionalnog polja sa 3×3 detektorskih dioda.

4.1 Metoda razlike među pojedinim "slikama": *PfPPD* (*Point for Point Picture Difference*)

Ova metoda je direktno prenesena iz ranije opisane varijante senzorskog sustava koja je bila bazirana na slikovnom senzoru (kameri). Metoda je korištena kako bi se izračunala direktna razlika u intenzitetu svjetlosti piksela na istim pozicijama, ali koji pripadaju dvjema različitim slikama prema jednadžbama (4.1) i (4.2).

$$\mathbf{A^n} = \begin{bmatrix} d_1^n & d_2^n & d_3^n \\ d_4^n & d_5^n & d_6^n \\ d_7^n & d_8^n & d_9^n \end{bmatrix} \tag{4.1}$$

$$\mathbf{A^{n-1}} = \begin{bmatrix} d_1^{n-1} & d_2^{n-1} & d_3^{n-1} \\ d_4^{n-1} & d_5^{n-1} & d_6^{n-1} \\ d_7^{n-1} & d_8^{n-1} & d_9^{n-1}, \end{bmatrix} \tag{4.2}$$

pri čemu je d_i^n vrijednost signala s promatrane detektorske diode na poziciji i u vremenskom

trenutku n. Nakon opisanog oduzimanja dobije se tzv. slika razlike (4.3), a sumom svih njenih elemenata (intenziteta po pikselima) moguće je dobiti mjeru različitosti među pojedinim detektiranim slikama (4.4). Ako se postupak ponavlja kroz neki vremenski period rezultat je funkcija koja opisuje promjene među slikama u ovisnosti o vremenu. S obzirom da su razlike među slikama posljedica geometrijskih izobličenja svjetlovoda koja nastaju kao posljedica vibracija koje na njega djeluju, signal razlika zapravo sadrži informacije o vibracijama.

Iako je u postavi s diodama besmisleno govoriti o slikama u klasičnom smislu, matematički metoda ima smisla ako se pojedine detektorske diode tretira kao piksele slika. U suštini radi se o usporedbi vrijednosti napona na detektorskim diodama u različitim vremenskim trenutcima, te potom o sumi takvih razlika preko sve četiri diode.

$$\mathbf{R^n} = \mathbf{A^n} - \mathbf{A^{n-1}} = \begin{bmatrix} \Delta d_1^n & \Delta d_2^n & \Delta d_3^n \\ \Delta d_4^n & \Delta d_5^n & \Delta d_6^n \\ \Delta d_7^n & \Delta d_8^n & \Delta d_9^n \end{bmatrix} \tag{4.3}$$

$$r(n) = \sum_{i=1}^{9} \Delta d_i^n \tag{4.4}$$

4.2 Metoda razlika među sumama elemenata "slika": *SumDIff* (*Sum Difference*)

U sklopu ove metode se pojedinačne detektorske diode, odnosno njihovi pripadajući signali, ne tretiraju kao zasebne točke za usporedbu među slikama kako je definirano jednadžbom (4.1), već se koristi suma vrijednosti sa svih detektorskih elementa kako bi se opisala svojstva neke *slike* prema jednadžbi (4.5). Konačni signal ove metode je rezultat razlike među tako opisanim sumama.

$$r(n) = \sum_{i=1}^{9} d_i^n - \sum_{i=1}^{9} d_i^{n-1} \tag{4.5}$$

4.3 Korelacijska metoda 1: *Correlation*

Korelacijski koeficijent za određeni par (uzastopnih) *slika* se određuje prema izrazu (4.6). Niz takvih korelacijskih koeficijenata predstavlja signal perturbacije vlakna. Izraz prema kojem se

obavlja izračun koeficijenata je preuzet iz [61]

$$c(n) = \frac{\langle d_i^n d_i^{n-1} \rangle - \langle d_i^n \rangle \langle d_i^{n-1} \rangle}{\sqrt{\left(\langle d_i^{n2} \rangle - \langle d_i^n \rangle^2 \right)^2 \left(\langle d_i^{n-1\,2} \rangle - \langle d_i^{n-1} \rangle^2 \right)^2}}, \tag{4.6}$$

pri čemu $\langle\rangle$ označavaju usrednjavanje preko prostornih koordinata, odnosno različitih pozicija detektorskih dioda. U slučaju potpune podudarnosti uzastopnih slika korelacijski koeficijent poprima vrijednost 1, a smanjuje se s povećanjem razlike među slikama.

4.4 Korelacijska metoda 2: *Corr. Ef*

Kao i u prethodnoj metodi, postupak je zasnovan na izračunu korelacijskog koeficijenta. Potom se izračunati korelacijski koeficijenti tretiraju kao pojedine vrijednosti odgovora sustava na perturbacijski signal. Ova korelacijska metoda je preuzeta iz [62, 63]. Izraz za izračun koeficijentata glasi:

$$ic(n) = \frac{1}{K} \sum_{i=1}^{9} d_i^n d_i^{n-1} \tag{4.7}$$

pri čemu je normizacijski faktor:

$$K = \sum_{i=1}^{9} (d_i^n)^2 \tag{4.8}$$

Ovaj se izraz može zapisati i kao:

$$ic(n) = \frac{\langle d_i^n d_i^{n-1} \rangle}{\langle d_i^{n2} \rangle} \tag{4.9}$$

koristeći istu notaciju kao i za jednadžbu (4.6).

4.5 Metoda momenata: *Mom. Ef*

Za razliku od prethodne dvije, ova metoda se temelji na izračunu momenata za određeni set ulaznih vrijednosti. Izračun započinje utvrđivanjem srednje vrijednosti po poziciji dioda:

$$\overline{\mu_i^n} = \frac{\sum_{i=1}^{3} \sum_{j=1}^{3} i d_{i,j}^n}{\sum_{i=1}^{3} \sum_{j=1}^{3} d_{i,j}^n} \tag{4.10}$$

$$\overline{\mu_j^n} = \frac{\sum_{i=1}^{3} \sum_{j=1}^{3} j d_{i,j}^n}{\sum_{i=1}^{3} \sum_{j=1}^{3} d_{i,j}^n} \tag{4.11}$$

gdje i i j predstavljaju odgovarajuće indekse redaka i stupaca 3×3 matrice.

Moment p-tog reda se definira kao:

$$\mu_p = \frac{\sum_{i=1}^{3}\sum_{j=1}^{3}[(i-\overline{\mu_i^n})^2 + (j-\overline{\mu_j^n})^2]^{p/2} d_{i,j}^n}{\sum_{i=1}^{3}\sum_{j=1}^{3} d_{i,j}^n} \tag{4.12}$$

To znači da jednadžbe za moment prvog reda poprima oblik:

$$\mu_1 = \frac{\sum_{i=1}^{3}\sum_{j=1}^{3}[(i-\overline{\mu_i^n})^2 + (j-\overline{\mu_j^n})^2]^{1/2} d_{i,j}^n}{\sum_{i=1}^{3}\sum_{j=1}^{3} d_{i,j}^n} \tag{4.13}$$

Navedena metoda momenata je također preuzeta iz [62, 63].

4.6 Analiza signala detektorskih dioda različitim statističkim metodama izračuna

U sklopu ovog rada su korištene sve prethodno navedene metode. Pri analizi signala u simulacijama detekcije pomoću fotodioda, kao i onog zabilježenog na stvarnim detektorskim diodama, svaka od opisanih metoda je dala rezultate. Važno je naglasiti i da je prva metoda *PfPPD* korištena prvenstveno kao poveznica s ranijom izvedbom mjernog sustava opisanom u poglavlju 3 (koja je bila zasnovana na upotrebi slikovnog CCD senzora - kamere). Preostale metode su primjerenije simuliranoj i praktičnoj izvedbi koja je predstavljena i analizirana u ovome radu. Rezultati koji su proizašli iz primjene opisanih metoda objavljeni su i prezentirani na konferencij [64], a detaljno su prikazani i analizirani u sljedećim poglavljima.

Poglavlje 5

Simuliranje detekcije detektorskim diodama

Kao što je navedeno u odjeljku 3.3, sustav je značajno dorađen i unaprijeđen mogućnostima za istovremenu simulaciju višestrukih detektorskih segmenata s mogućnošću primjene različitih statističkih metoda za obradu tako dobivenih signala. Osnovna motivacija za ovakav pristup je bila mogućnost zamjene kamere alternativnim načinom detekcije - diodama. Svaki simulirani detekcijski segment predstavlja jednu diodu, te se vrijednosti intenziteta svjetlosti detektirane po pikselima jednog segmenta sumiraju u jedinstven signal koji je povezan s određenim segmentom sukladno jednadžbi (2.52). Takvi signali se prikupljaju iz svih pojedinačnih segmenata i obrađuju ovisno o odabranoj statističkoj metodi.

Iako je testiranje sa segmentima različitih veličina i na različitim pozicijama jasno najavilo mogućnost takve detekcije, nisu sasvim jasni parametri takvog sustava. Nepoznanice su potreban broj segmenata (za koji bi bilo poželjno da je što manji), veličina detektorskih dioda te njihov raspored, odnosno pozicioniranje na točkastom uzorku.

Softverski je omogućeno simuliranje bilo koje veličine segmenata i njihovo proizvoljno pozicioniranje na točkastom uzorku. Raspored je moguće odabrati kao jednostavno dvodimenzionalno polje ili dva ukrižana linearna polja i pri tom je moguće regulirati broj elemenata po dimenzijama za oba slučaja.

S obzirom na već opisani problem prikaza rezultata iz poglavlja 3.7, isti pristup u prikazu i vrednovanju rezultata je zadržan i u ovom slučaju. Dodatno opterećenje za prikaz u ovom slučaju predstavlja i povećanje neovisnih dimenzija problema.

U prethodnom slučaju je problem, odnosno rezultat simulacija, analiziran po dimenzijama veličine segmenata, njihove pozicije i promjenjive amplitude mehaničkih vibracija. Pri tome je metoda proračuna rezultata bila nepromjenjiva, odnosno svi su rezultati izračunati primjenom metode *SumDiff* prema jednadžbi (4.5).

S obzirom na povećanje mogućnosti manipulacije postavkama segmentiranja, parametri koji

se sada moraju razmotriti su sljedeći:

- konfiguracija polja dioda (dvodimenzionalno ili križno postavljena jednodimenzionalna polja)
- broj dioda po osima slike (radi jednostavnosti je isti broj detektora postavljan po obje osi)
- veličina detektorskih segmenata/dioda
- metoda statističke analize signala iz pojedinih elemenata

Pozicioniranje dioda nije obavljano direktno, već je to napravljeno za detektorsko polje. Ovisno o broju dioda u polju mijenjala se i njihova pozicija jer su raspoređivane ravnomjerno unutar granica polja uz krajnje diode na samoj granici, tj. kao da su postavljene u vrhove odgovarajućeg pravokutnog segmenta. Pozicija polja je kroz prikazane simulacije održavana fiksnom, tako da se rubne diode (granice polja) nalaze na rubu intenzivnijeg dijela točkastog uzorka, što je empirički utvrđena optimalna pozicija koja ima uporište i u rasporedu modova u jezgri svjetlovoda, kao i prema rezultatima drugih istraživačkih grupa koje se bave istom problematikom [48, 49, 50].

Zbog povećane dimenzije problema (4 nezavisna parametra), isti skup rezultata je prikazan na dva različita načina kako bi se olakšalo donošenje zaključaka o različitim dimenzijama.

Rezultati koji započinju odjeljkom 5.1.2 prikazuje rezultate spektralne analize za različit broj dioda i različite metode, a uz istu veličinu dioda na jednoj slici, odnosno veličina dioda se mijenja promjenom promatrane slike.

Rezultati koji započinju odjeljkom 5.1.8 prikazuje rezultate spektralne analize za različit broj i veličinu dioda, a uz istu primijenjenu metodu na jednoj slici, odnosno primijenjena metoda se mijenja promjenom promatrane slike.

Pojedinačni rezultati (grafovi) su ponovno vrednovani obojanim okvirima na jednak način kao i u odjeljku 3.7.

Prije prikaza rezultata dan je pregled rasporeda i veličina detektorskih dioda na točkastom uzorku na slici 5.1.

5.1 Simulacije za dvodimenzionalno polje detektorskih dioda

Za odjeljke 5.1.2 do 5.1.6 prikazani rasporedi vrijede na način da redak sa slike 5.1 odgovara rasporedu po svim retcima stranice prikaza (jer su svi retci jednaki po veličini dioda, a metode se mijenjaju). Rezime rezultata za takav prikaz rezultata simulacija ponuđen je u odjeljku 5.1.7.

Za odjeljke 5.1.8 do 5.1.12 prikazani raspored sa slike 5.1 odgovara direktnim preslikavanjem, odnosno svaki rezultat je direktno vezan uz sliku na istoj poziciji (jer je metoda fiksna po stranici, a veličine dioda se mijenjaju po retcima). Za ovakav prikaz rezultata simulacija rezime je ponuđen u odjeljku 5.1.13.

5.1.1 Veličina i raspored detektorskih dioda na točkastom uzorku

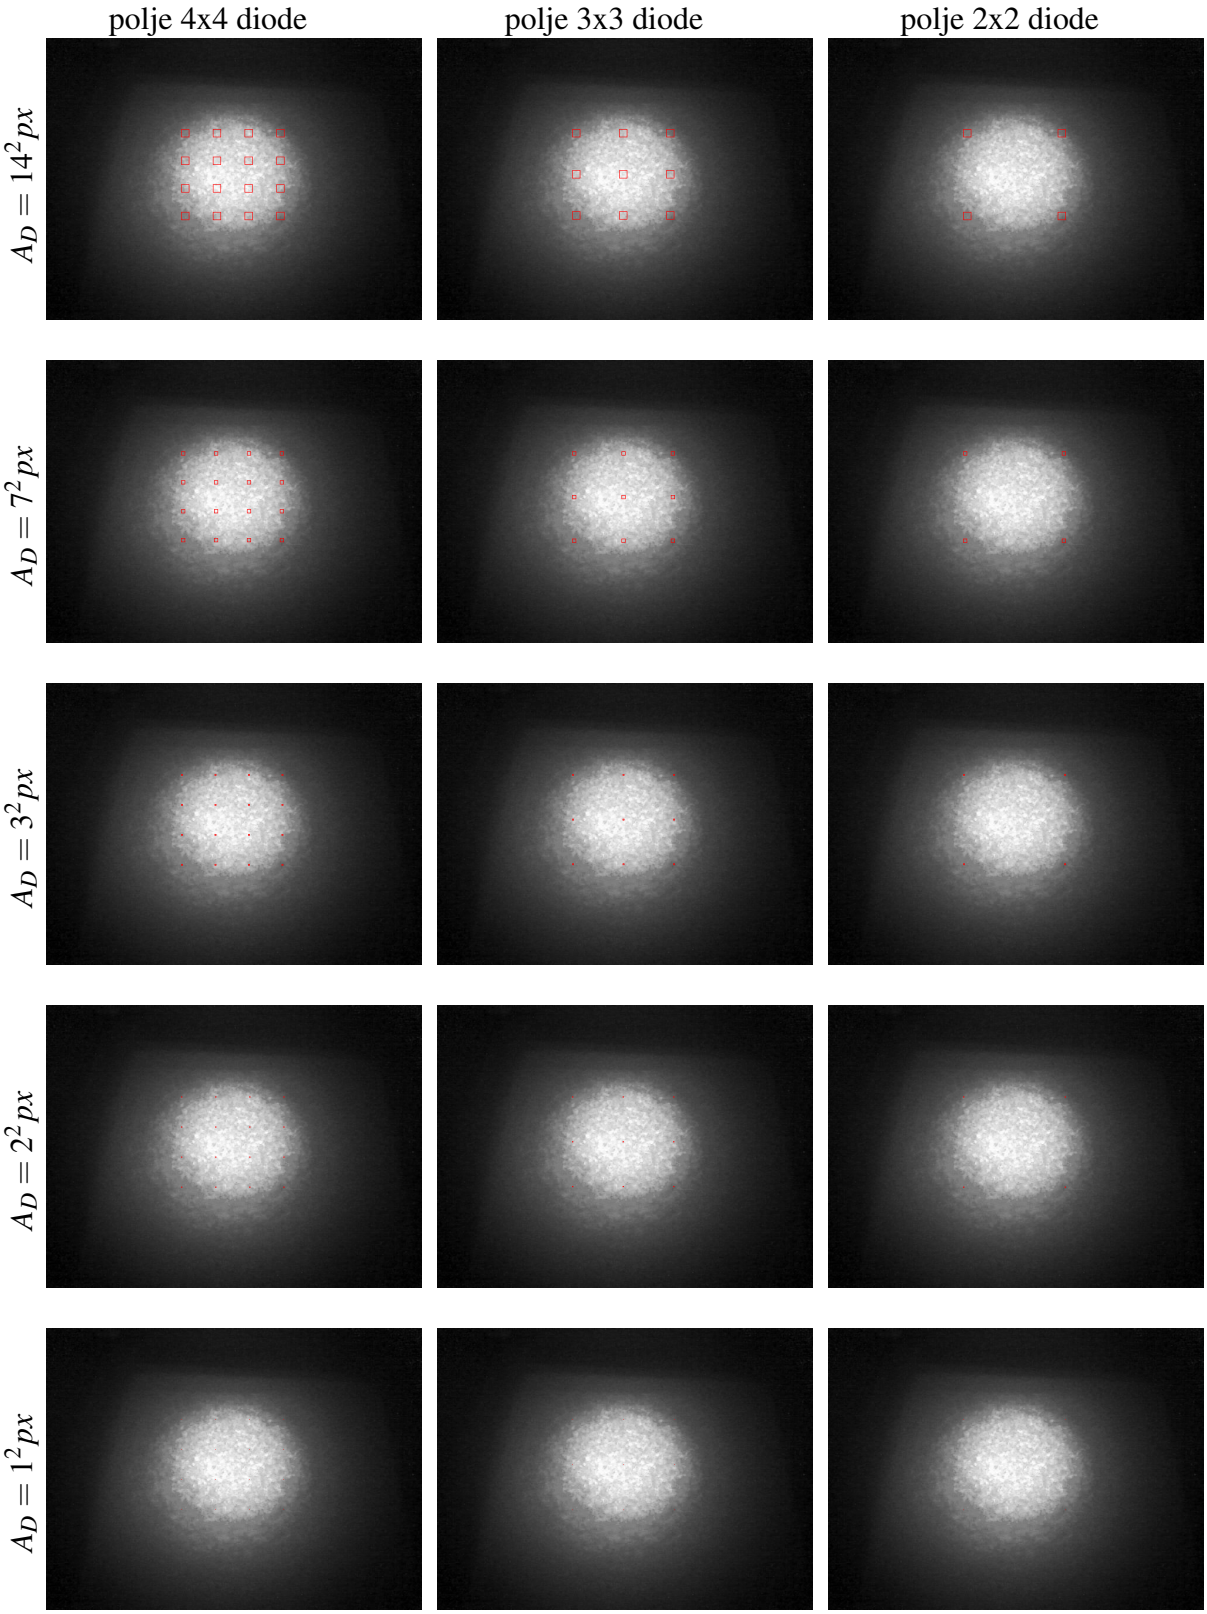

Slika 5.1: Prikaz veličina i rasporeda simuliranih detektorskih dioda na točkastom uzorku

5.1.2 Usporedba metoda za diode veličine 14^2 piksela

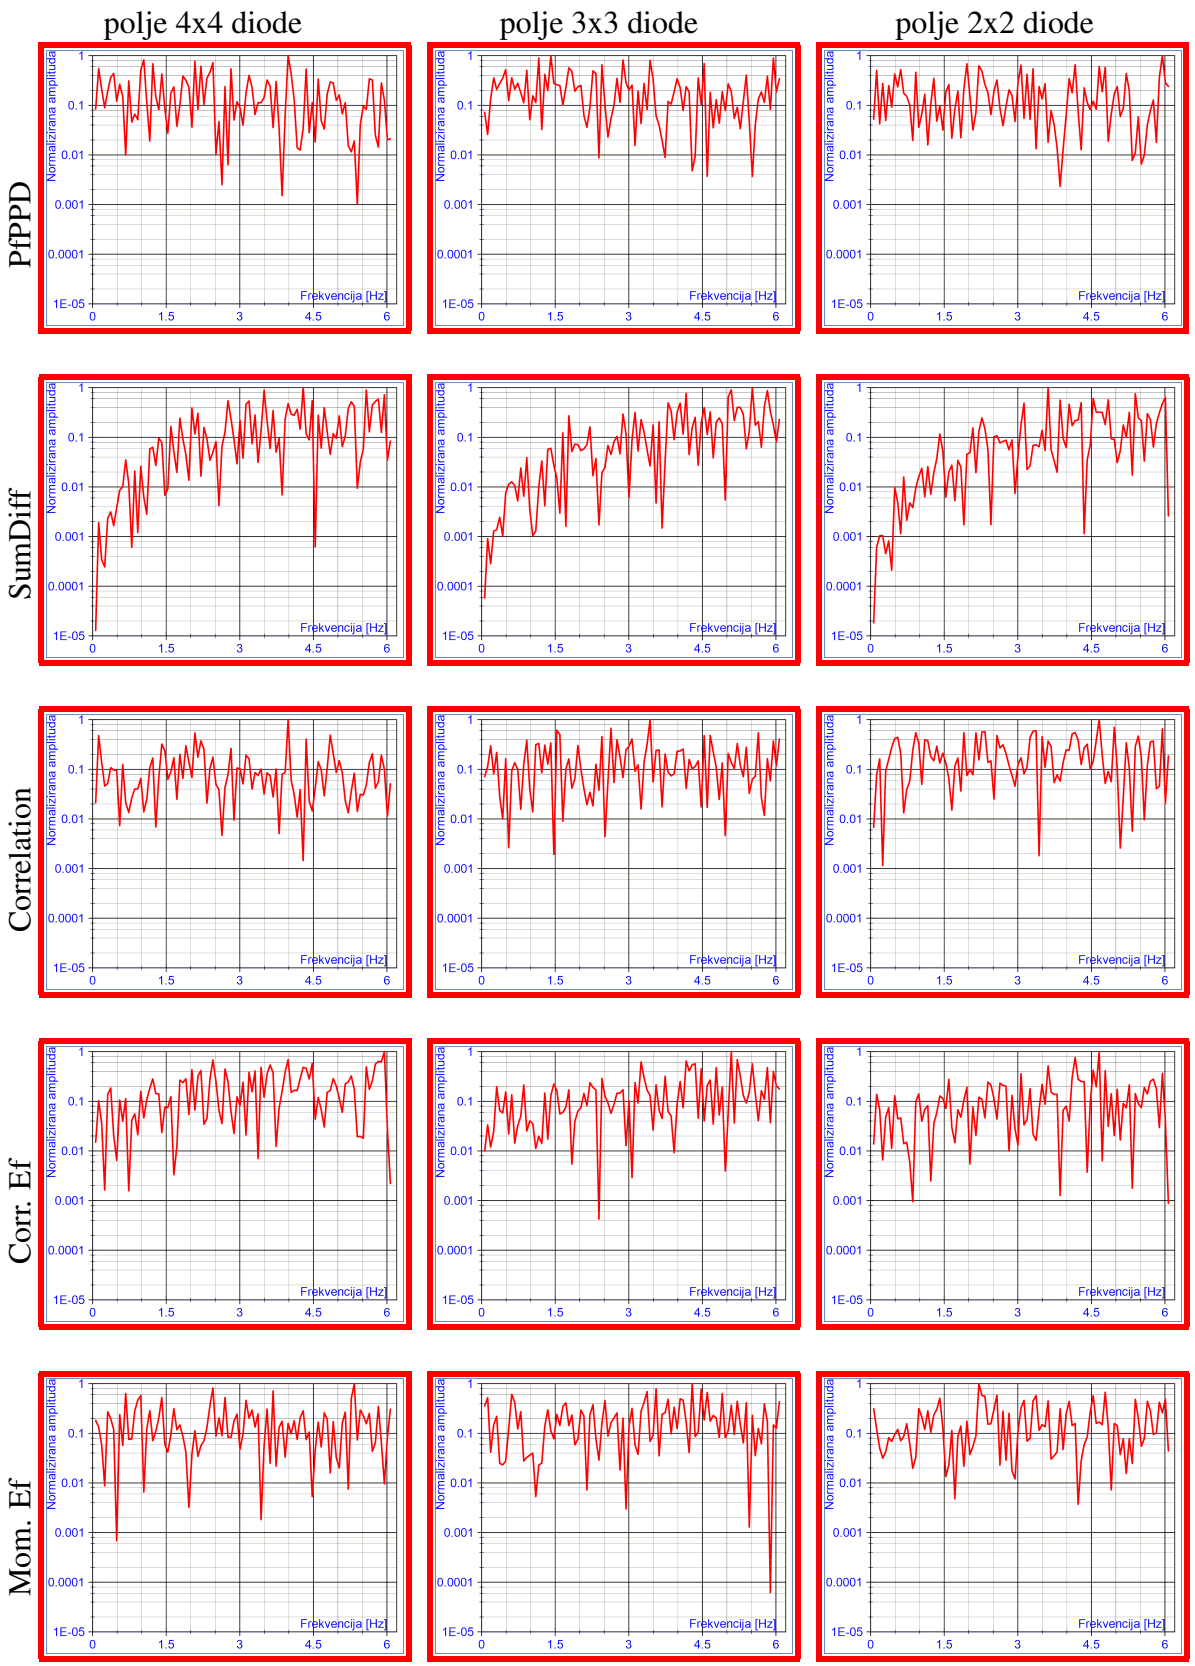

Slika 5.2: Usporedba metoda za veličinu dioda 14^2 px

5.1.3 Usporedba metoda za diode veličine 7^2 piksela

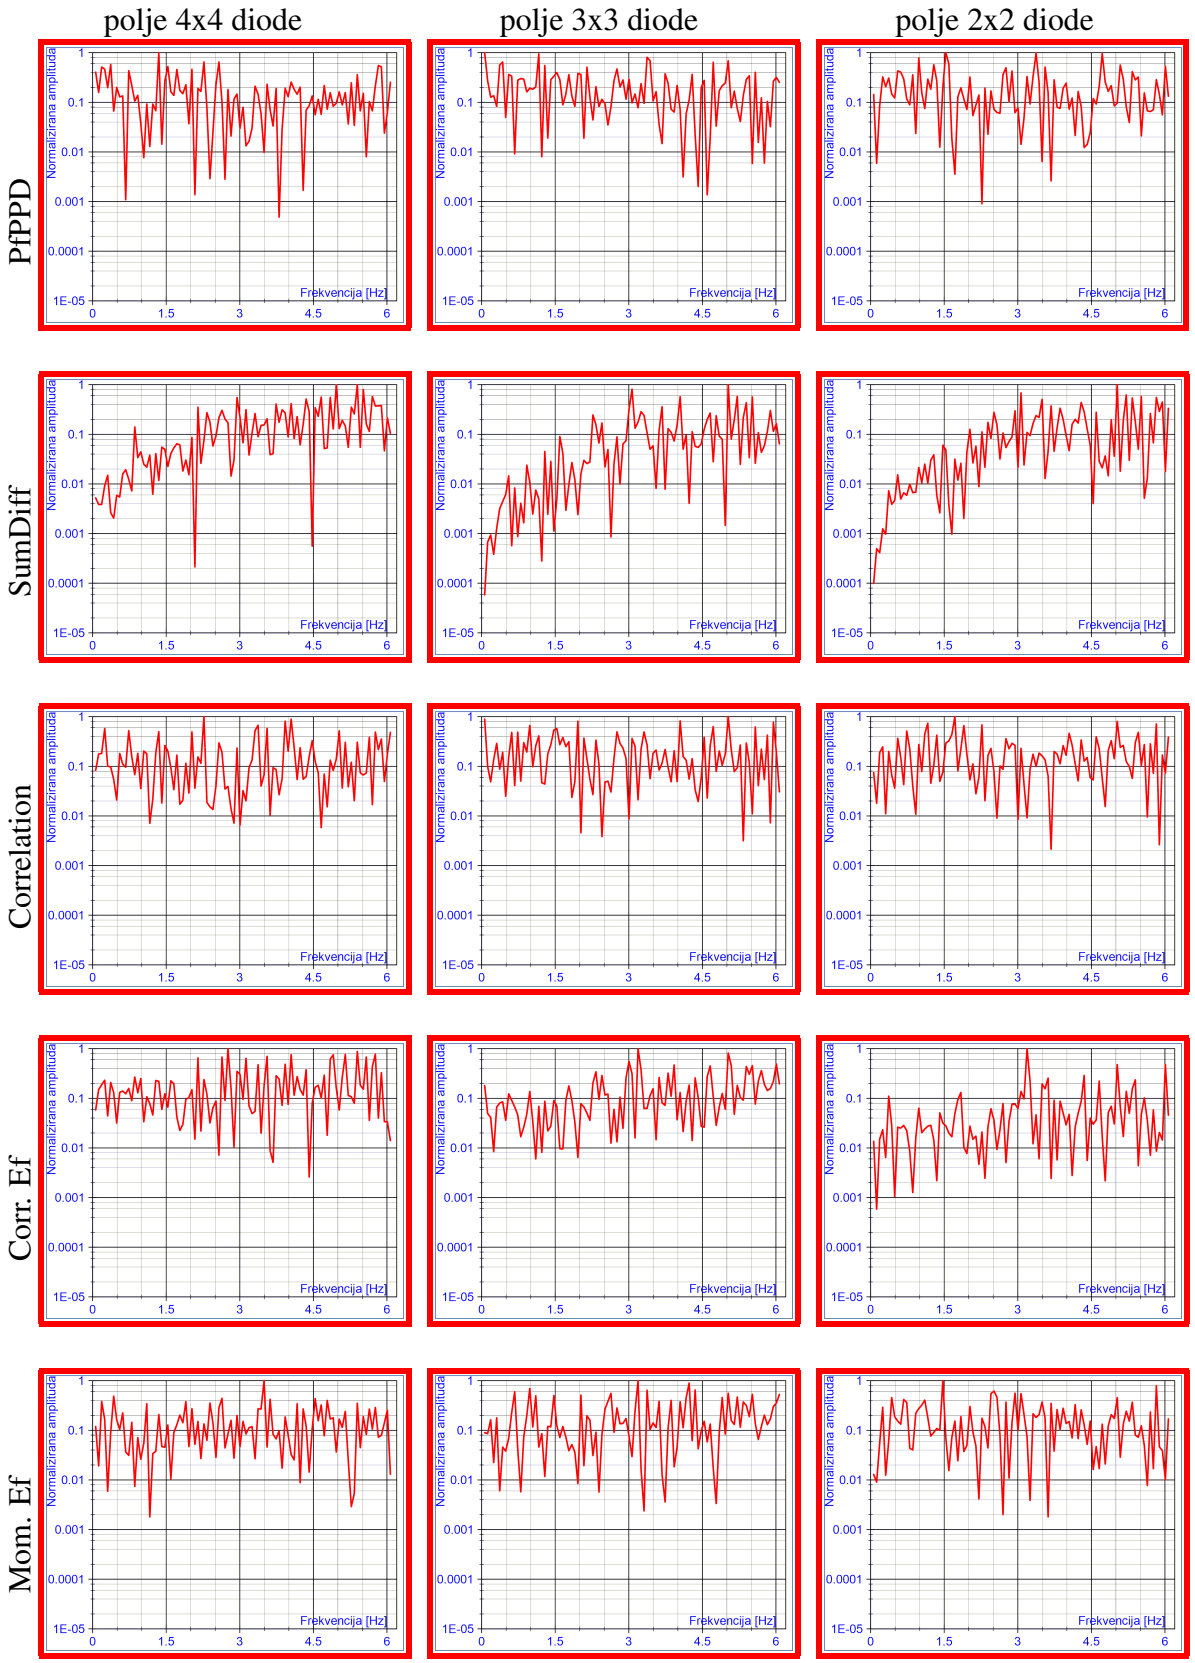

Slika 5.3: Usporedba metoda za veličinu dioda 7^2 px

5.1.4 Usporedba metoda za diode veličine 3^2 piksela

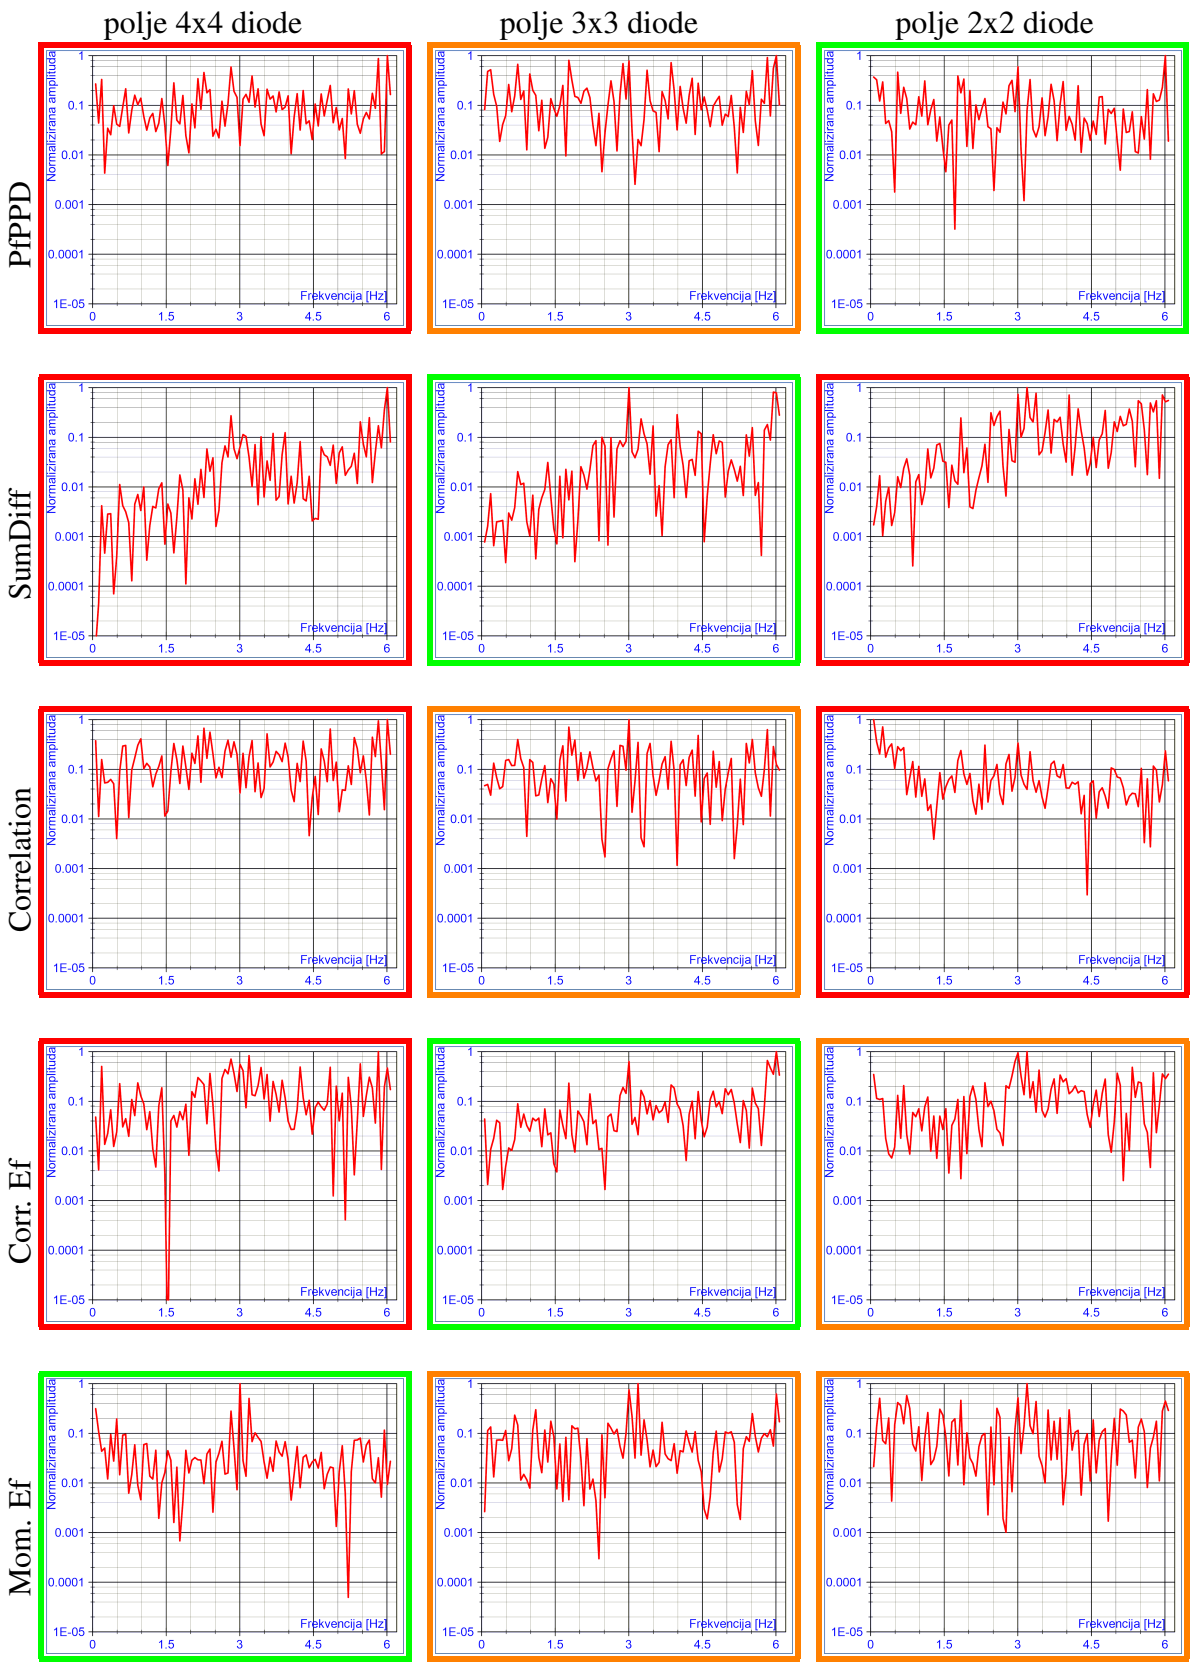

Slika 5.4: Usporedba metoda za veličinu dioda 3^2 px

5.1.5 Usporedba metoda za diode veličine 2^2 piksela

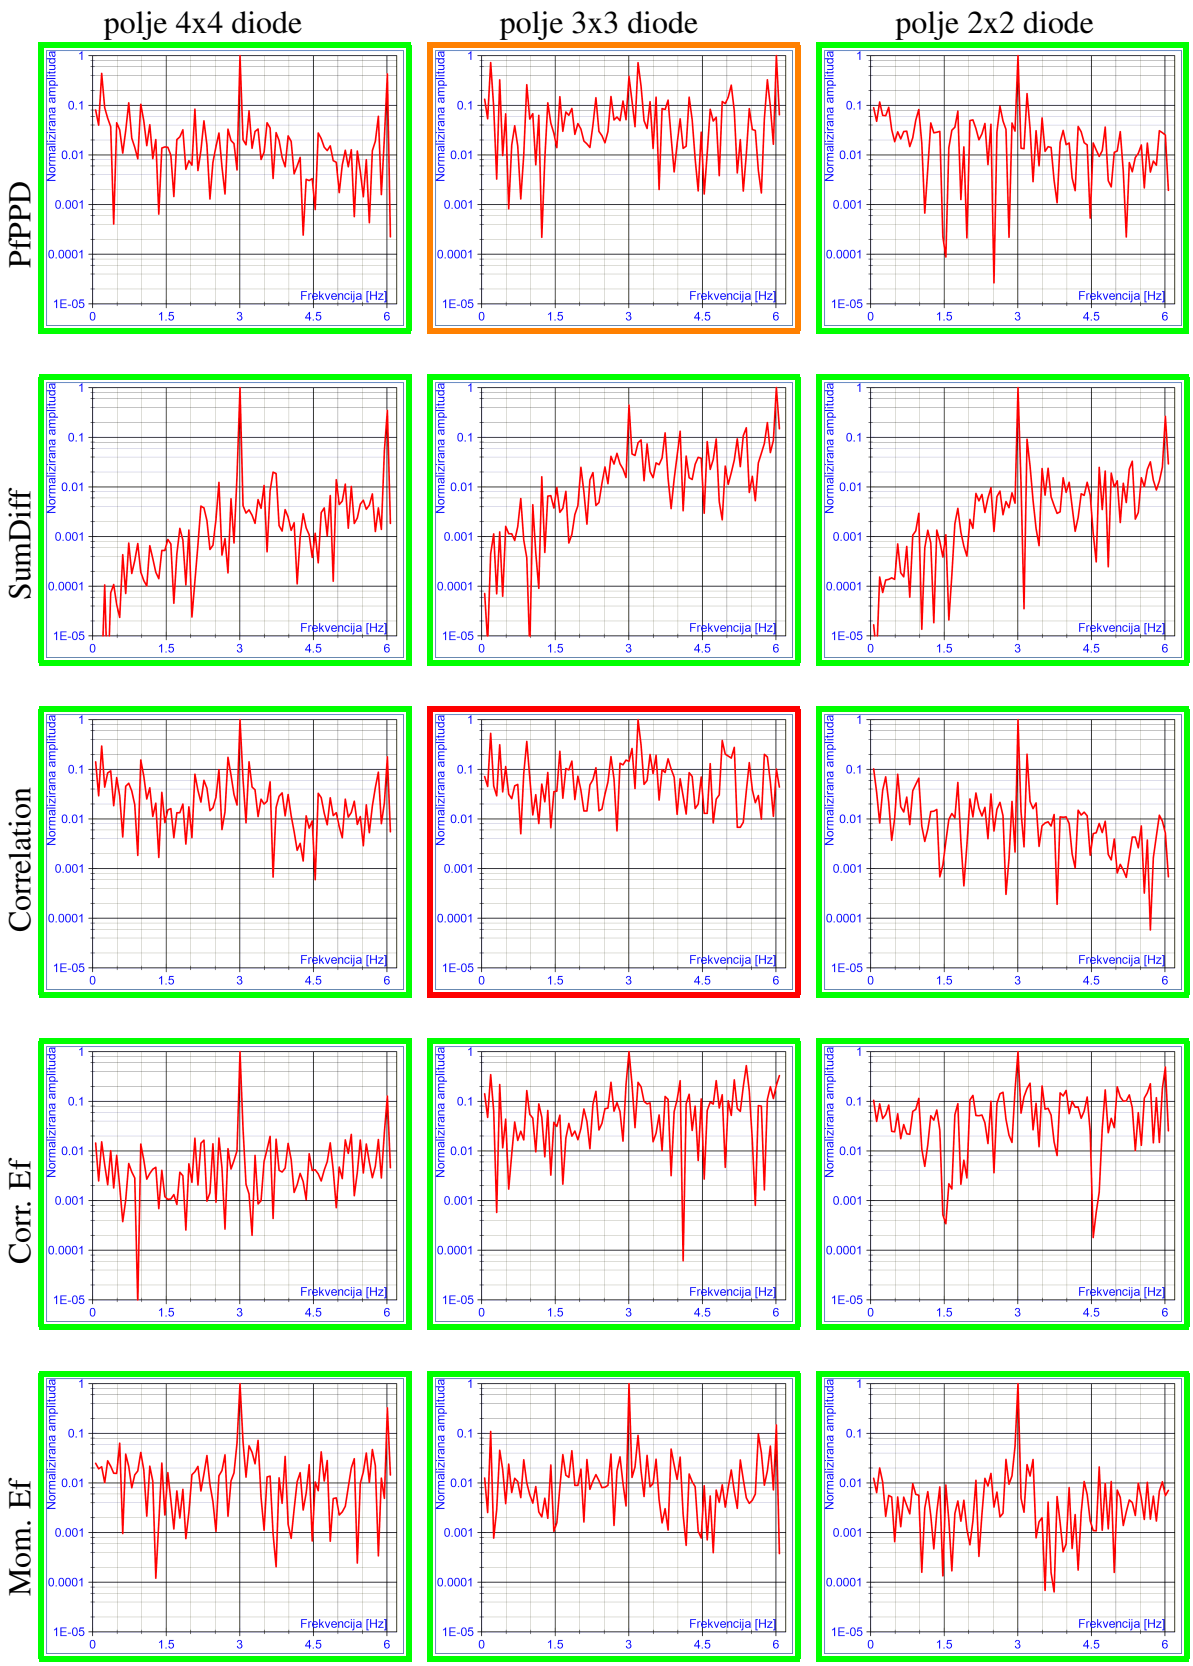

Slika 5.5: Usporedba metoda za veličinu dioda 2^2 px

5.1.6 Usporedba metoda za diode veličine 1^2 piksela

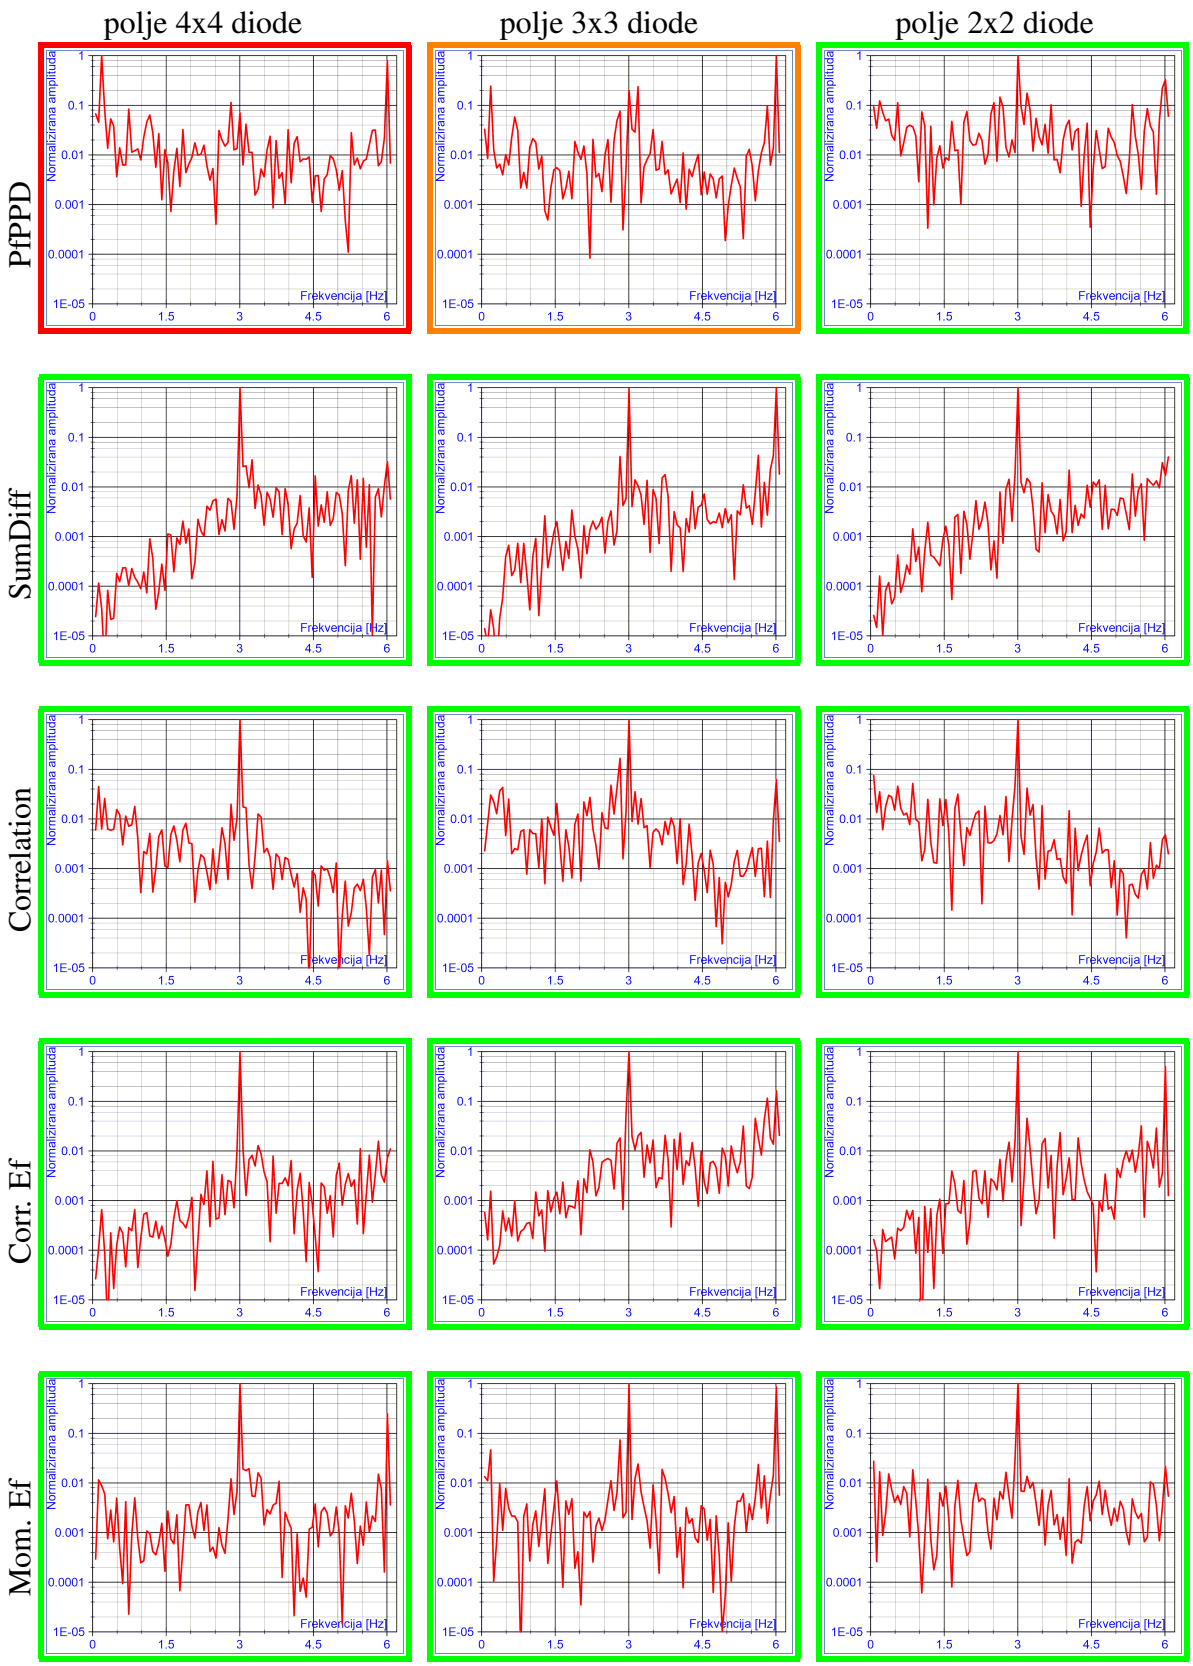

Slika 5.6: Usporedba metoda za veličinu dioda 1^2 px

5.1.7 Rezultati simulacije dvodimenzionalno raspoređenih dioda analizirani po veličini dioda

Simulacije su odrađene i za konfiguracije s većim dimenzijama dioda, konkretno 26^2 i 47^2 px^2, no ti rezultati nisu uključeni u ovaj prikaz budući da s takvim dimenzijama dioda sustav nije uopće uspijevao detektirati vibracije, kao što se može pretpostaviti iz trenda prikazanog u tablici.

Veličina dioda	Ispravna detekcija	Nesigurna detekcija	Kriva detekcija
14^2 px^2	0	0	15
7^2 px^2	1	1	13
3^2 px^2	4	5	6
2^2 px^2	10	2	3
1^2 px^2	11	3	1
$\sum$	26	11	38
%	34,7	14,7	50,7

S obzirom da za diode veličine 14^2 i 7^2 px^2 praktički ne postoje slučajevi detekcije, u daljnjim analizama i prikazima rezultata referirati ćemo se samo na 3 najmanje veličine (1^2 do 3^2).

Veličina dioda	Ispravna detekcija	Nesigurna detekcija	Kriva detekcija
3^2 px^2	4	5	6
%	26,7	33,3	40,0
2^2 px^2	10	2	3
%	66,7	13,3	20.0
1^2 px^2	11	3	1
%	73.3	20,0	6,7

Iz navedenih rezultata dosta očito slijedi da je detekcija najuspješnija u slučajevima kada su diode sustava najmanje moguće veličine, odnosno 1 px. Valja napomenuti da u ovom slučaju

nije razlikovana detekcija po metodi statističke obrade rezultata, odnosno sve su statističke metode uzete u obzir za sve veličine dioda. Nije razrađeno ni razlikovanje po broju detektora u polju. Te dimenzije će biti detaljnije analizirane nakon sljedećih odjeljaka.

5.1.8 Usporedba različitih veličina detektorskih dioda metodom PfPPD

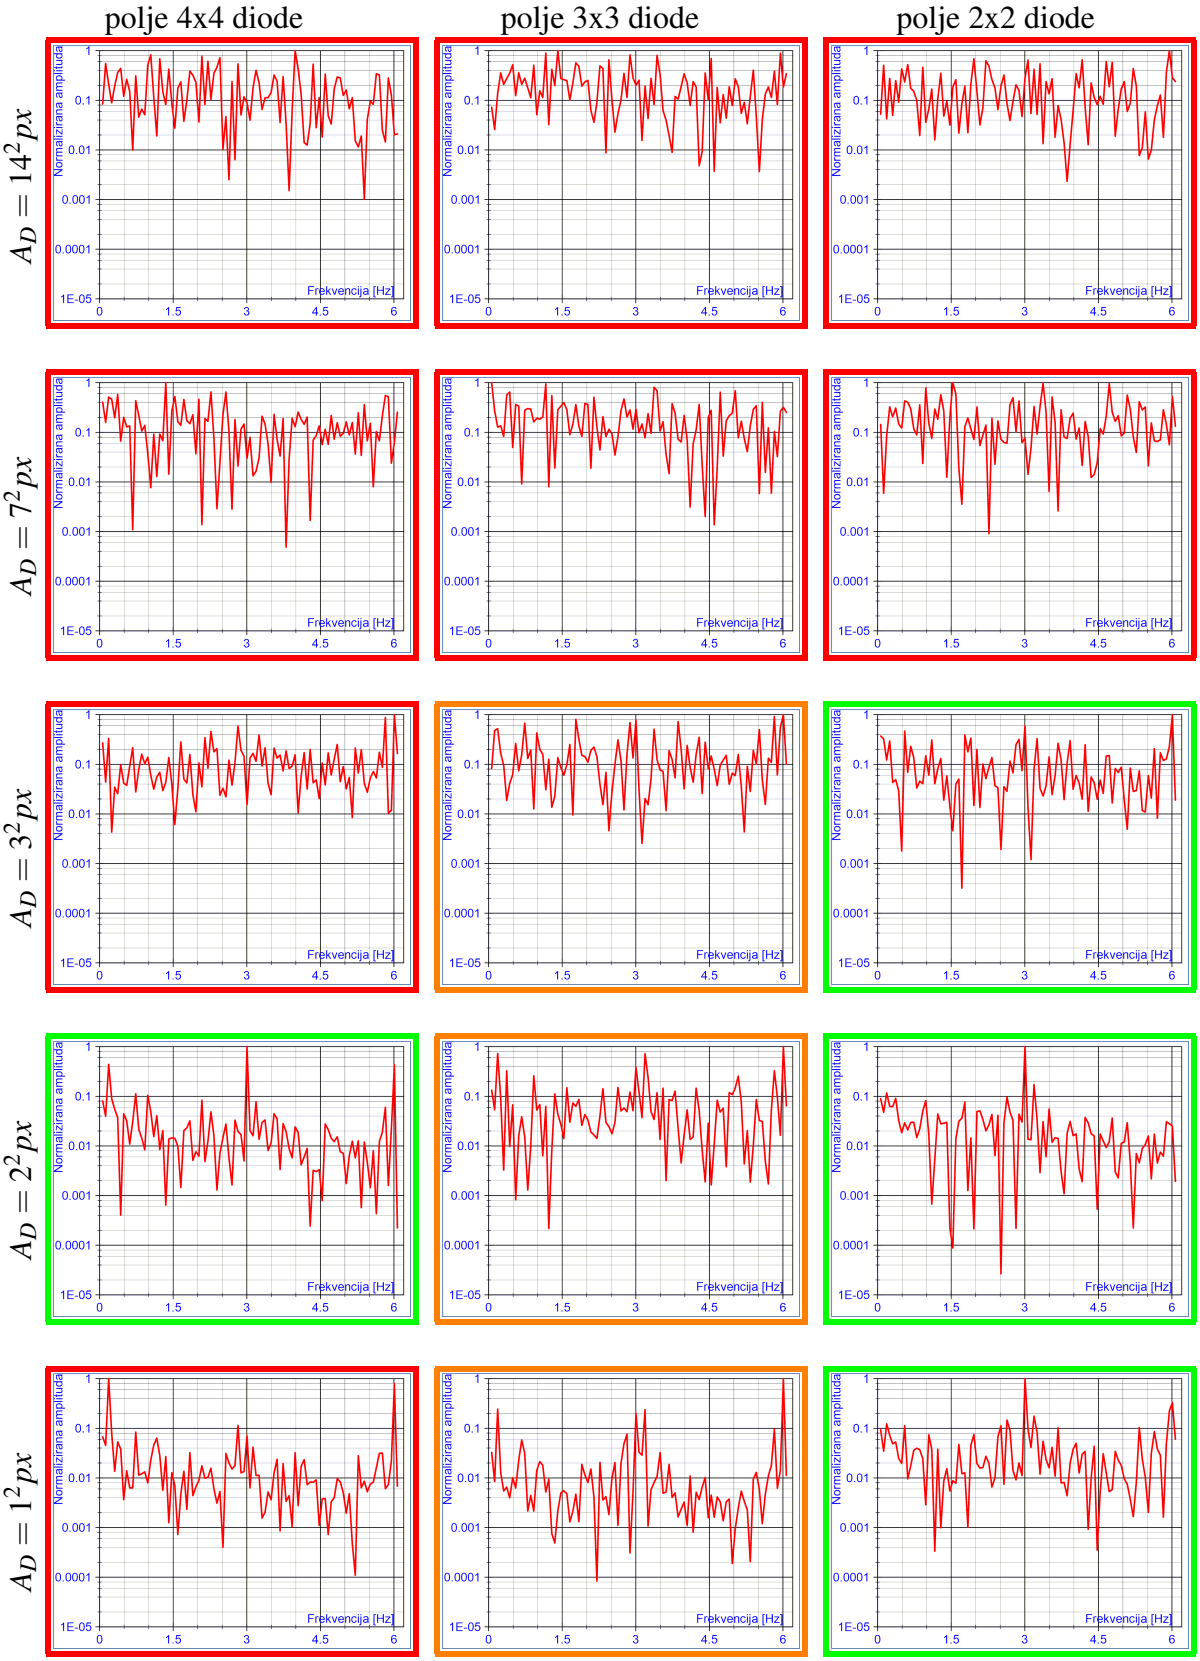

Slika 5.7: Usporedba različitih veličina detektorskih dioda metodom PfPPD

5.1.9 Usporedba različitih veličina det. dioda metodom SumDiff

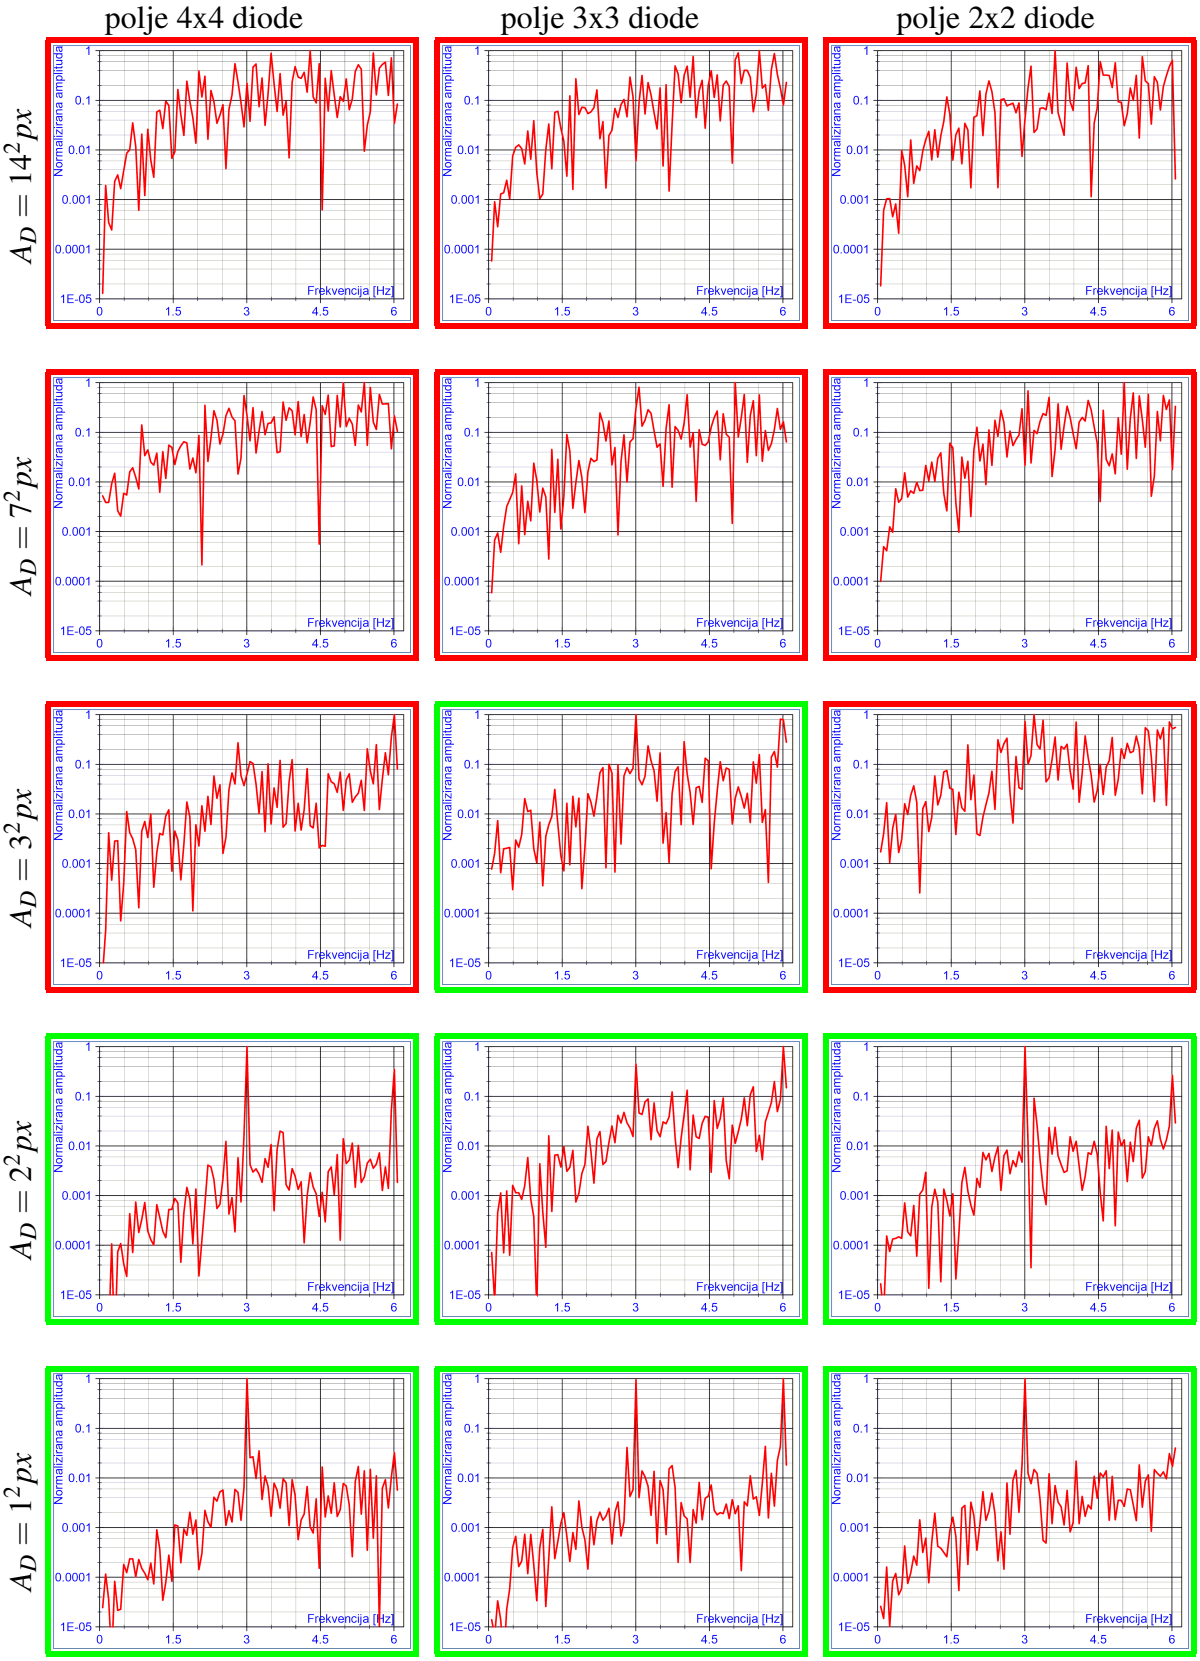

Slika 5.8: Usporedba različitih veličina detektorskih dioda metodom SumDiff

5.1.10 Usporedba različitih veličina det. dioda metodom Correlation

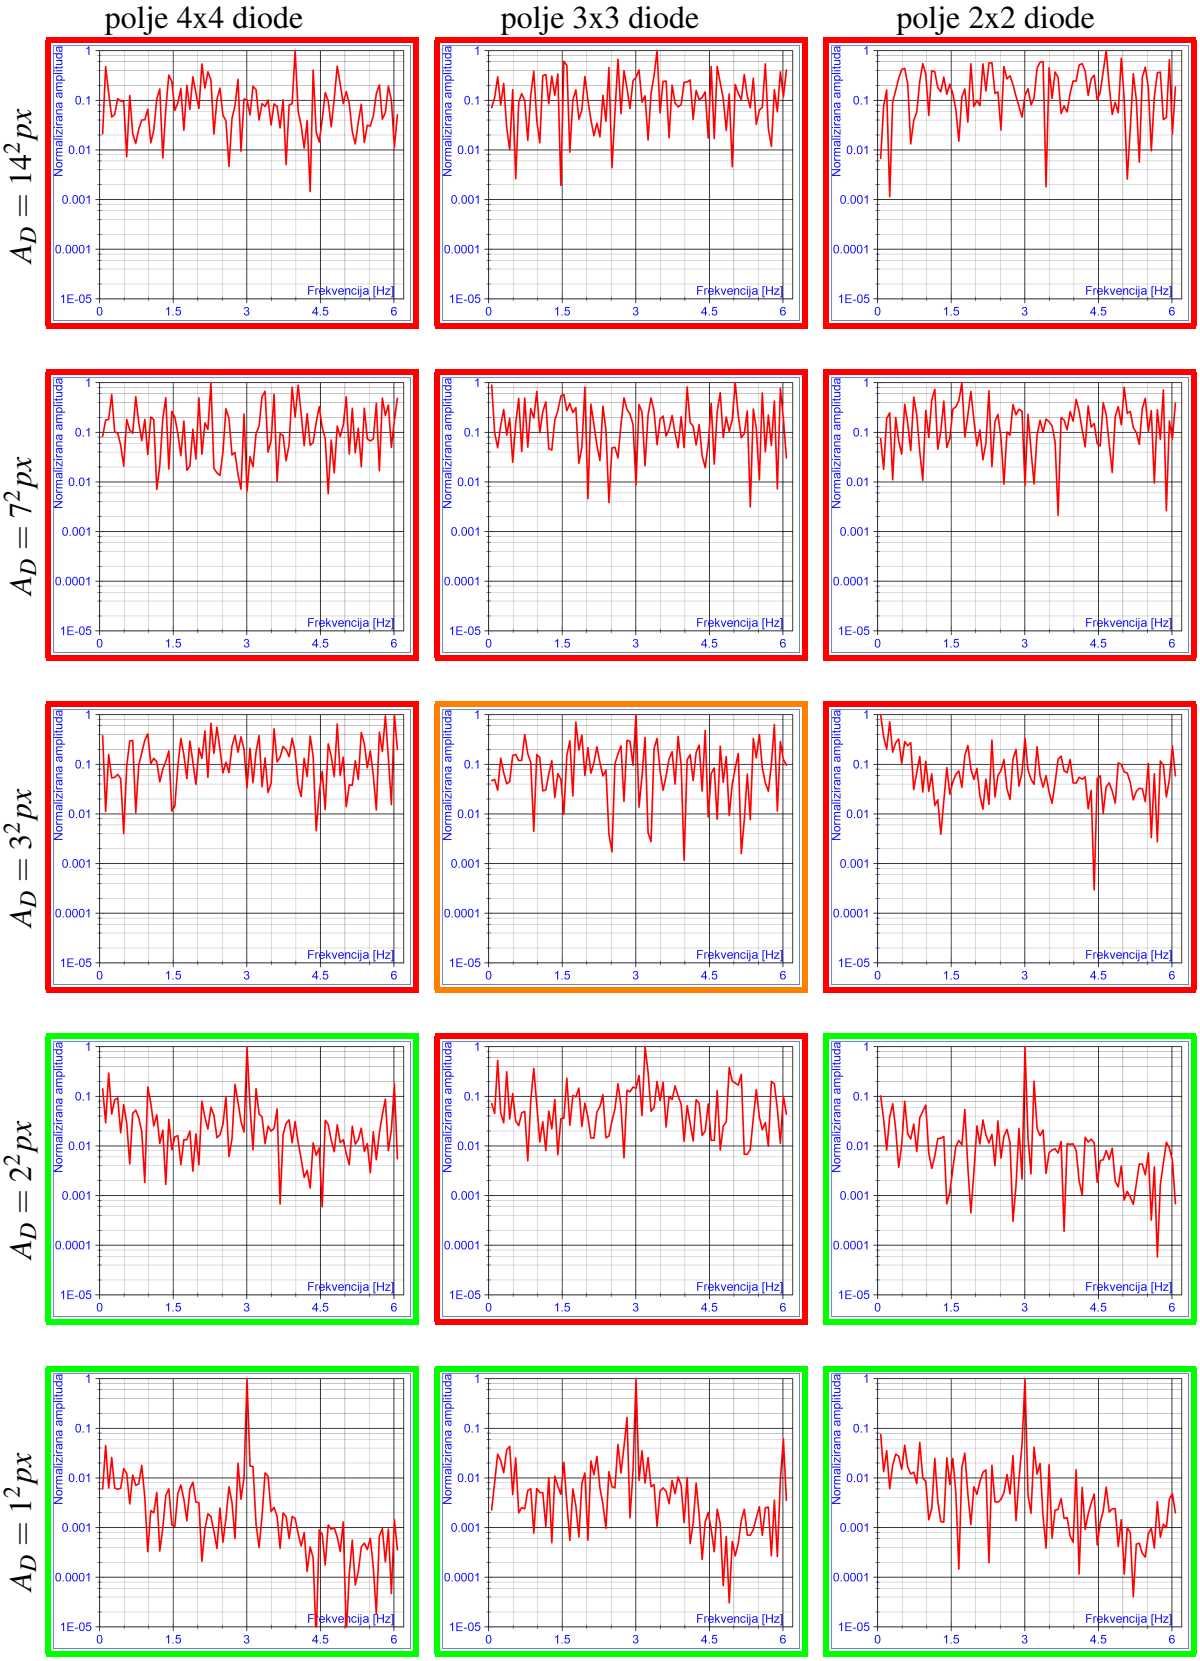

Slika 5.9: Usporedba različitih veličina detektorskih dioda metodom Correlation

5.1.11 Usporedba različitih veličina det. dioda metodom Corr. Ef

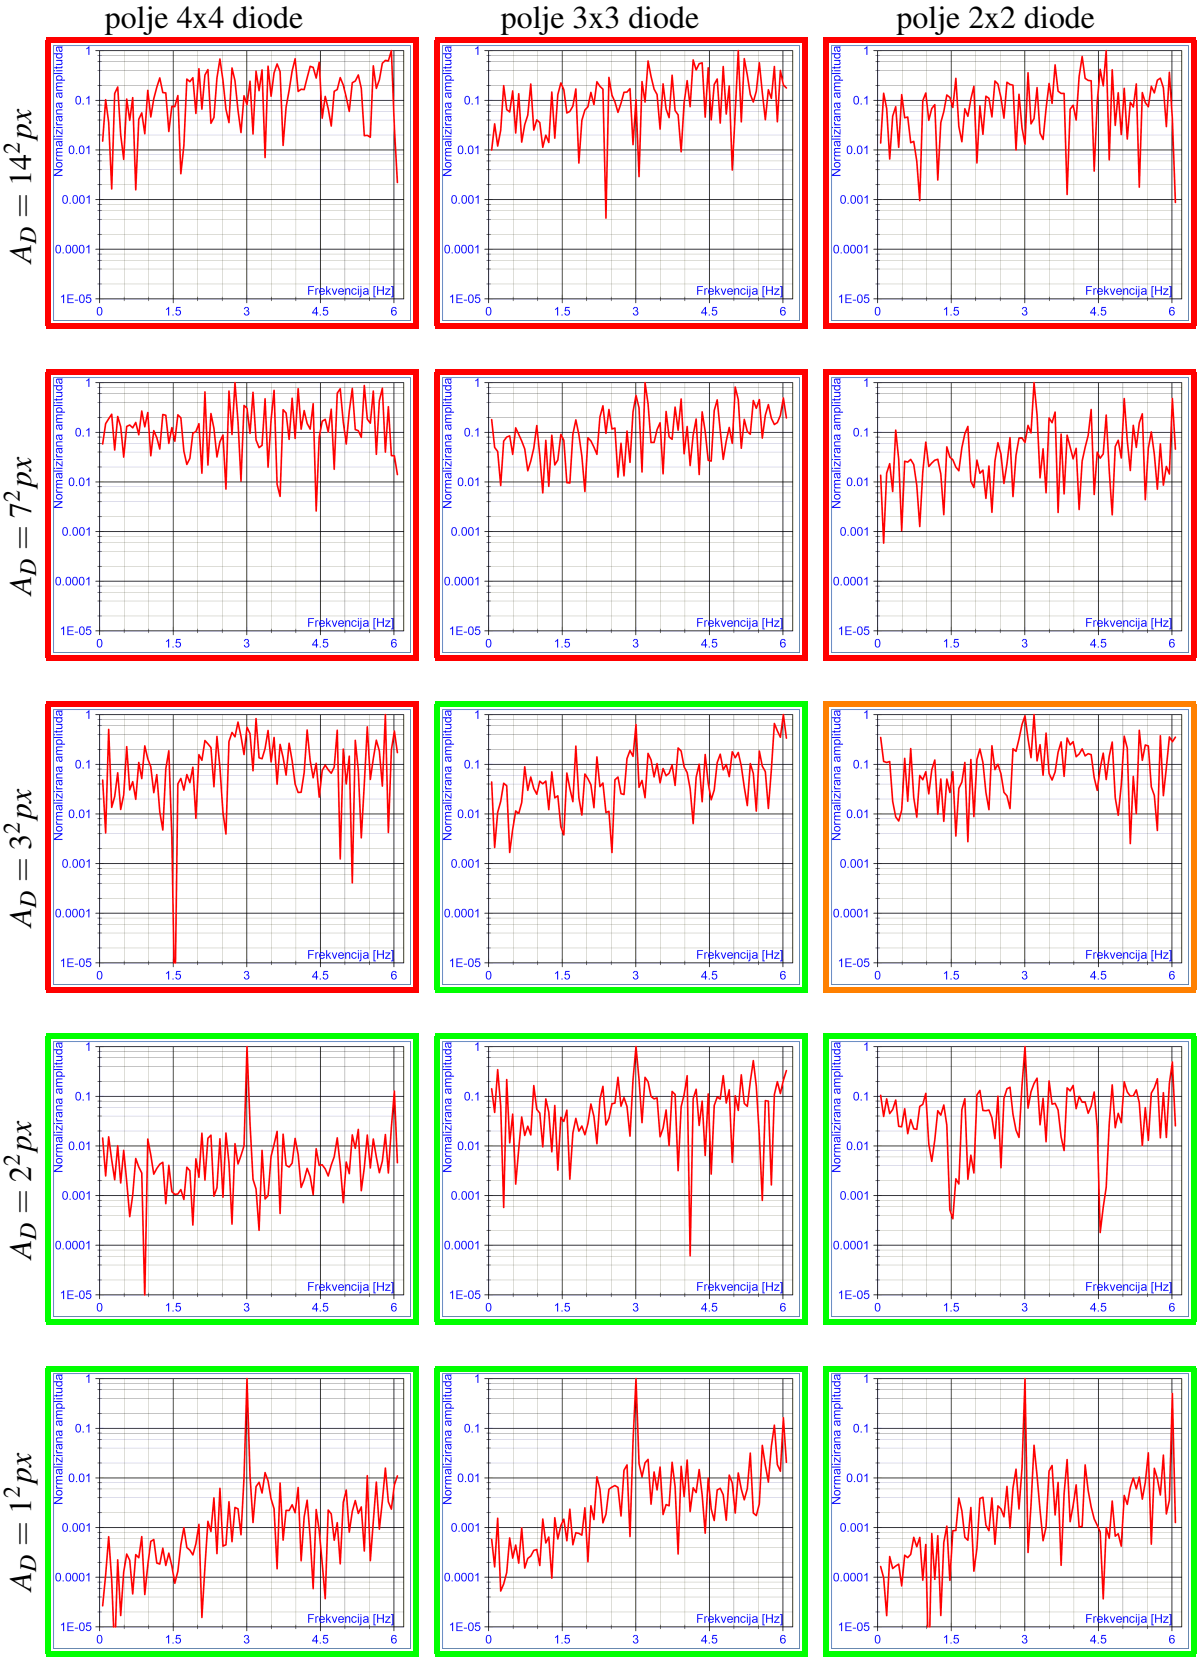

Slika 5.10: Usporedba različitih veličina detektorskih dioda metodom Corr. Ef

5.1.12 Usporedba različitih veličina det. dioda metodom Mom. Ef

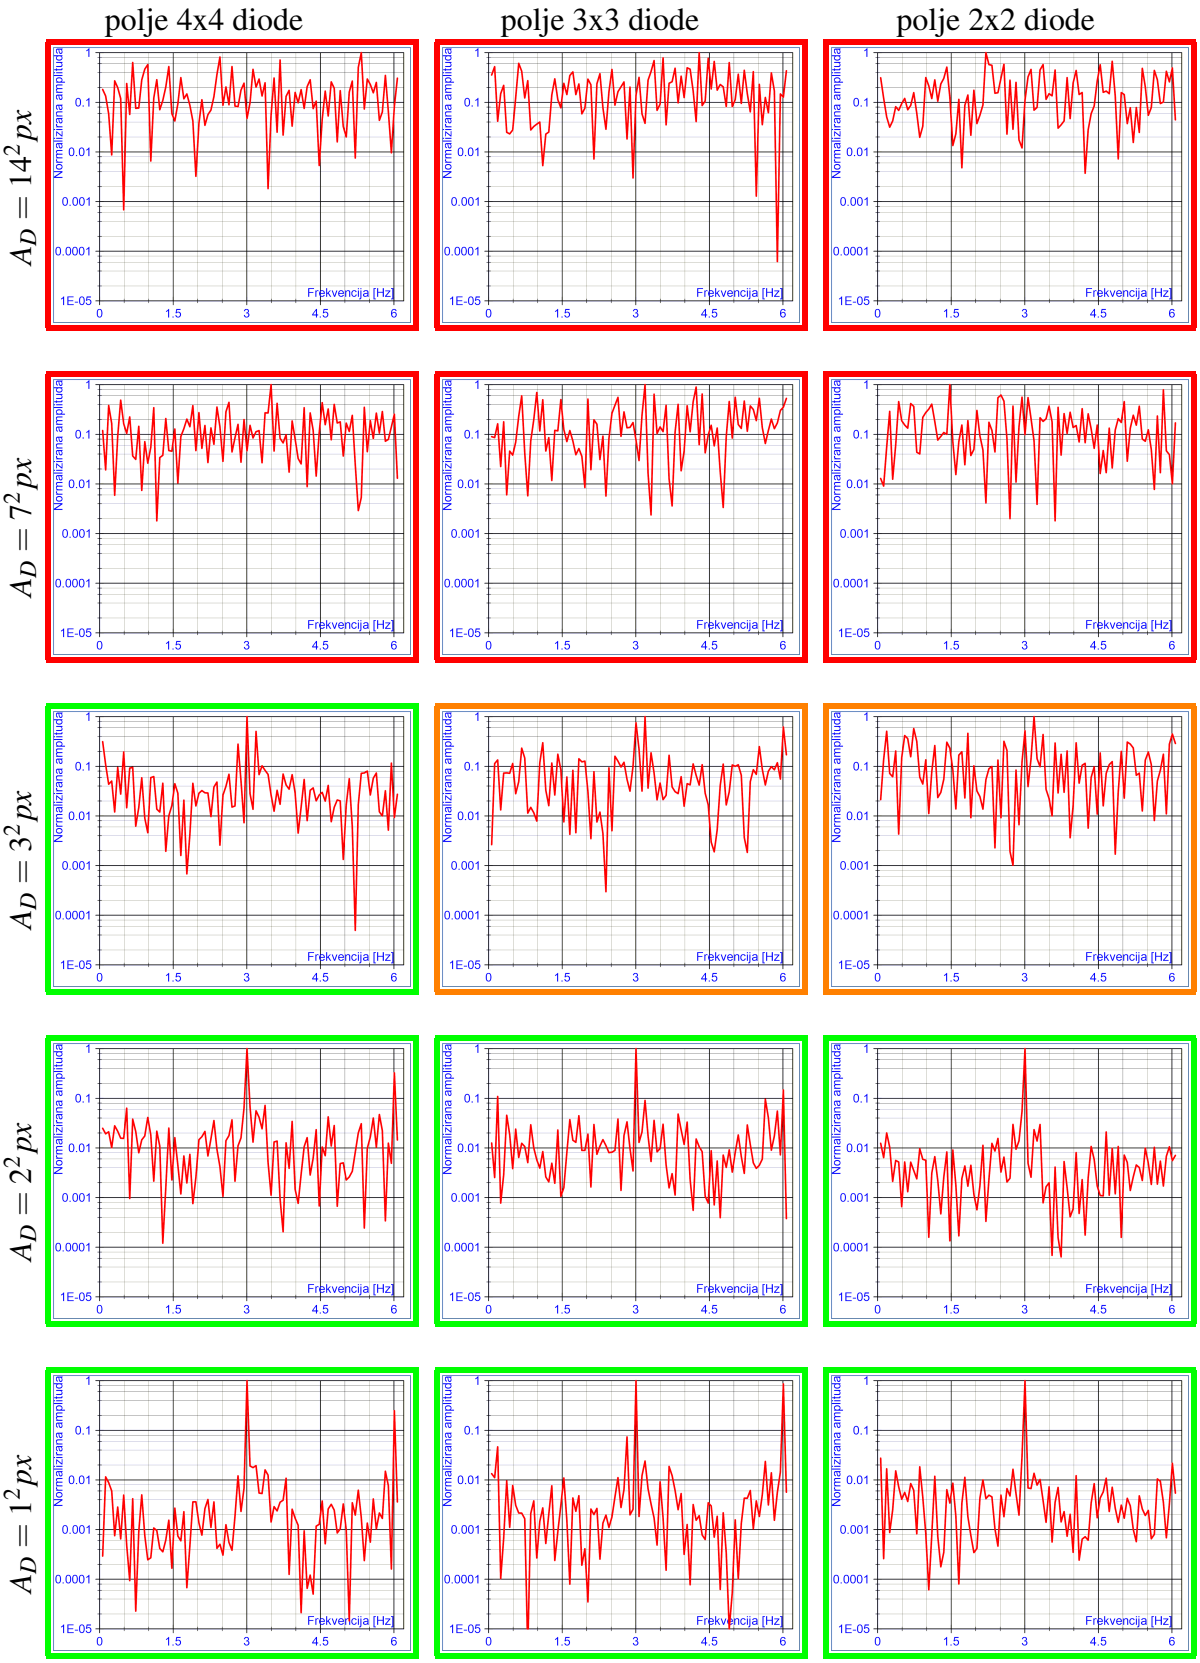

Slika 5.11: Usporedba različitih veličina detektorskih dioda metodom Mom. Ef

5.1.13 Rezultati simulacije dvodimenzionalno raspoređenih detektorskih dioda analizirani po primijenjenoj metodi izračuna i broju elemenata detektorskog polja

Ovi rezultati sortirani su po ključu metode za statističku obradu podataka kako bi se olakšalo analizu s tog aspekta.

Korištena metoda	Ispravna detekcija	Nesigurna detekcija	Kriva detekcija
PfPPD	2	4	9
SumDiff	8	0	7
Corr.	3	2	10
Corr. Ef	7	3	6
Mom. Ef	6	11	6
$\sum$	26	11	38
%	34,7	14,7	50,7

Sumarni podaci su identični kao i ranije jer se radi o istim rezultatima sortiranim po drugačijem ključu.

Za ocjenu uspješnosti pojedine metode izračuna ponovno isključujemo rezultate analize dobivene pomoću dvije najveće dimenzije simuliranih dioda uz jednako obrazloženje kao i ranije.

Korištena metoda	Ispravna detekcija	Nesigurna detekcija	Kriva detekcija
PfPPD	4	3	2
%	44,4	33,3	22,2
SumDiff	7	0	2
%	77,8	0	22,2
Corr.	5	1	3
%	55,6	11,1	33,3
Corr. Ef	7	1	1
%	77,8	11,1	11,1
Mom. Ef	7	2	0
%	77,8	22,2	0

Ono što je očekivano kod prikazanog rezultata je da je metoda PfPPD najmanje uspješna. Ta je metoda bila polazište u izračunima i *naslijeđena* je iz sustava s kamerom. Sve preostale metode pokazuju bolje rezultate, pri čemu je najbolji rezultat metode momenata Mom. Ef, budući da uz jednak stupanj ispravnih detekcija, kao i neke od preostalih statističkih metoda, nema krivih detekcija, već su one, u najgorem slučaju, nesigurne.

Objedinjavanjem prikazanih rezultata s dodatno testiranim (ali neprikazanim) rezultatima za dvodimenzionalno polje veličine 5×5 elemenata, po kriteriju broja elemenata u polju dolazimo do sljedećih vrijednosti:

Veličina polja	Ispravna detekcija	Nesigurna detekcija	Kriva detekcija
5×5	7	6	12
%	28	24	48
4×4	10	0	15
%	40	0	60
3×3	9	5	11
%	36	20	44
2×2	11	2	12
%	44	8	12

Iako pojedinačni rezultati za polje dimenzija 5×5 nisu prikazani, iz sumarne tablice je očito da polje s takvim brojem elemnata pokazuje najlošije rezultate među prikazanima. Također, uz jednako opravdanje kao i ranije, odbacujemo dvije najveće veličine dioda kao irelevantne s obzirom da za takve veličine simuliranih dioda detekciju praktički ne ostvarujemo. Nakon takve redukcije, pročišćeni rezultat poprima sljedeće vrijednosti:

Veličina polja	Ispravna detekcija	Nesigurna detekcija	Kriva detekcija
4×4	10	0	5
%	66,7	0	33,3
3×3	9	5	1
%	60	33,3	6,7
2×2	11	2	2
%	73,3	13,3	13,3

Prije konačnog zaključka za simulaciju detekcije pomoću dioda moramo razmotriti i alternativnu konfiguraciju elemenata u vidu križne kombinacije dva linearna polja dioda.

5.2 Simulacija detektorskih dioda u konfiguraciji dva ukrižana linearna polja

Kako je navedeno u poglavlju 3.3, postoji alternativa jednostavnom dvodimenzionalnom rasporedu dioda u obliku dva ukrižana linearna polja dioda. Potencijalna prednost ovakve konfiguracije je veća gustoća pojedinačnih detektorskih elemenata po dvije dimenzije, ali manji ukupni broj elemenata zbog linearnih korištenih polja. Razmatrane su jednake ukupne dimenzije polja (odnosno okvira u kojem se nalazi), jednake veličine pojedinih dioda te jednak broj elemenata po osima kao i u prethodnom slučaju. Sva simulirana mjerenja su analizirana upotrebom svih opisanih statističkih metoda obrade signala. Sve simulacije su obavljene na istom video materijalu za signal frekvencije $f = 3Hz$ i $U_{vv} = 300mV$, kao i u slučaju dvodimenzionalnog polja dioda.

Na slici 5.3 su prikazane veličine i raspored dioda za sve simulirane dimenzije. Rezultati prikazani u odjeljcima 5.3.1 do 5.3.5 su sortirani po veličini dioda, što znači da svi rezultati na jednoj slici odgovaraju jednom retku prikazanom na slici 5.12. Prelaskom na sljedeću sliku rezultata prelazi se i na sljedeći redak slike 5.12 s prikazom rasporeda i veličine dioda.

U ovom slučaju rezultati su prikazani samo na jedan način, s obzirom da je iscrpna analiza već provedena za slučaj dioda u dvodimenzionalnom rasporedu. Nakon prikaza rezultata ponuđena je analiza za križnu konfiguraciju, te konačni zaključak za cijelu proceduru simulacija detekcije pomoću polja dioda.

5.3 Veličina i raspored det. dioda u križnoj konfiguraciji

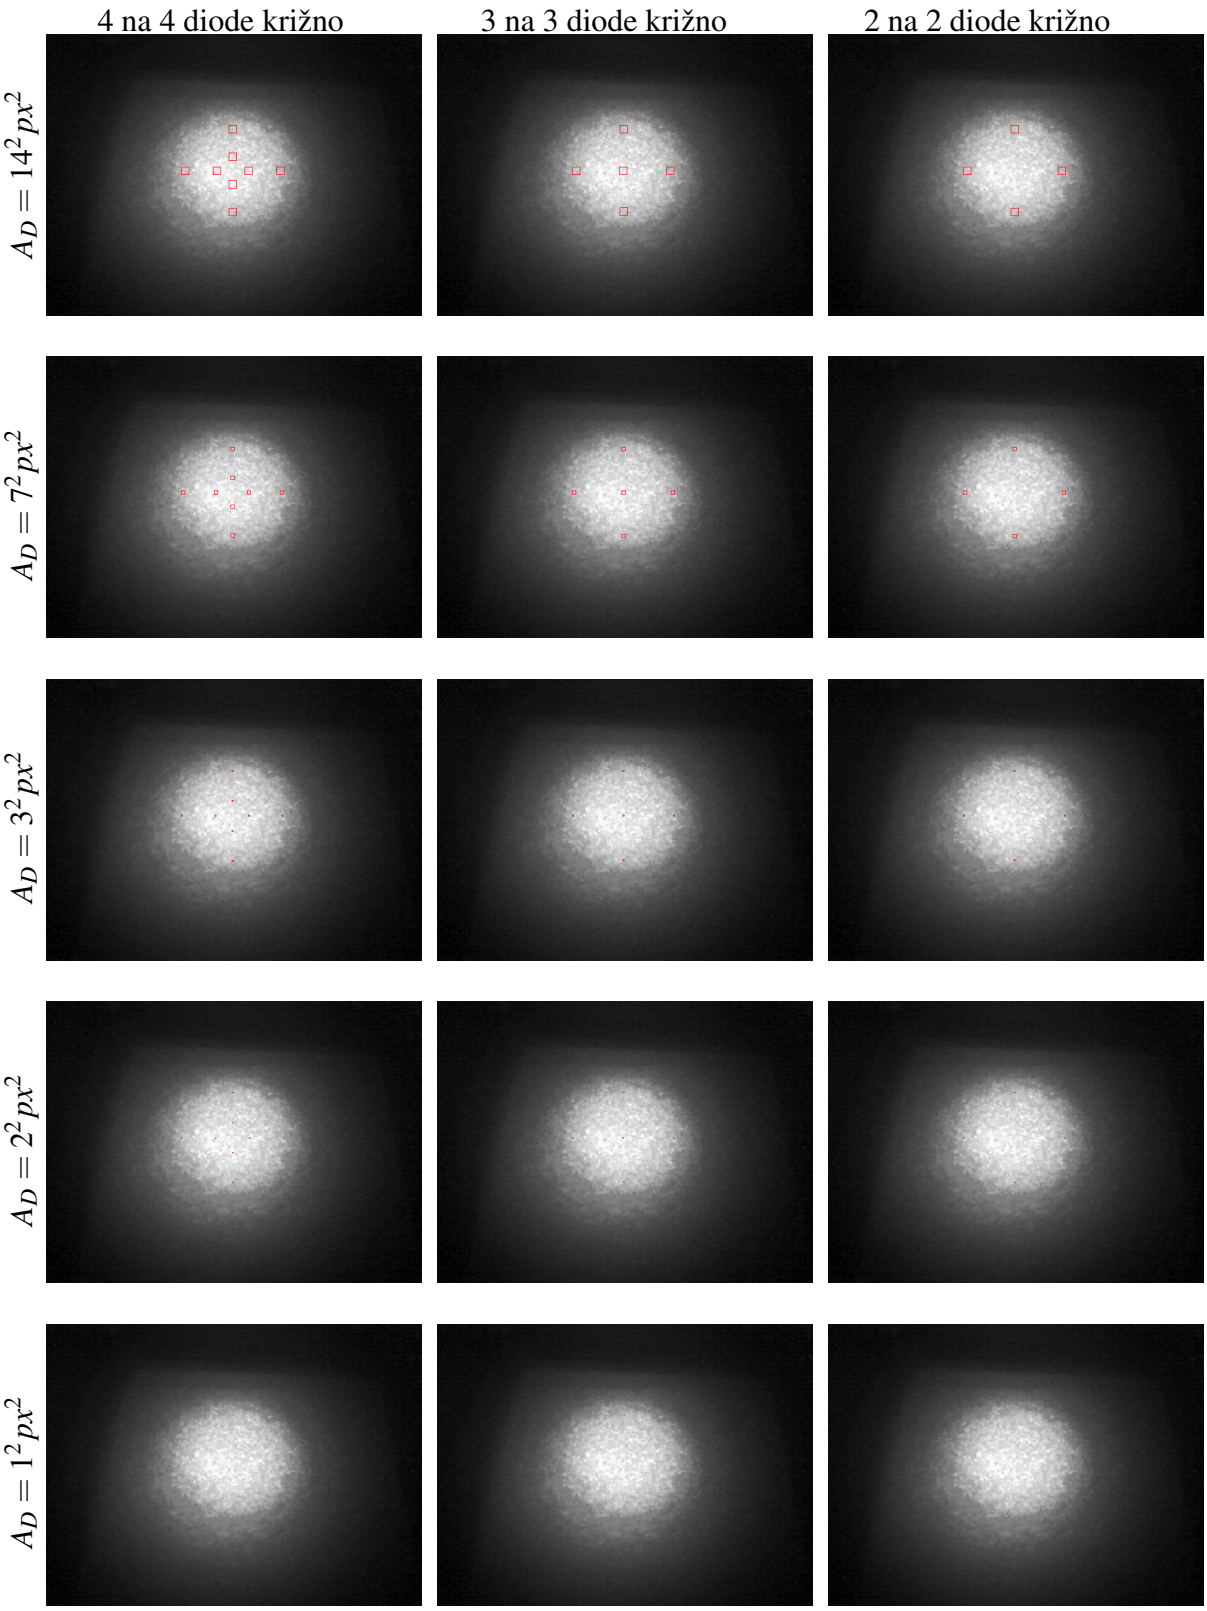

Slika 5.12: Prikaz veličina i rasporeda simuliranih detektorskih dioda na točkastom uzorku u križnoj konfiguraciji

5.3.1 Usporedba metoda za diode veličine 14^2 piksela^2

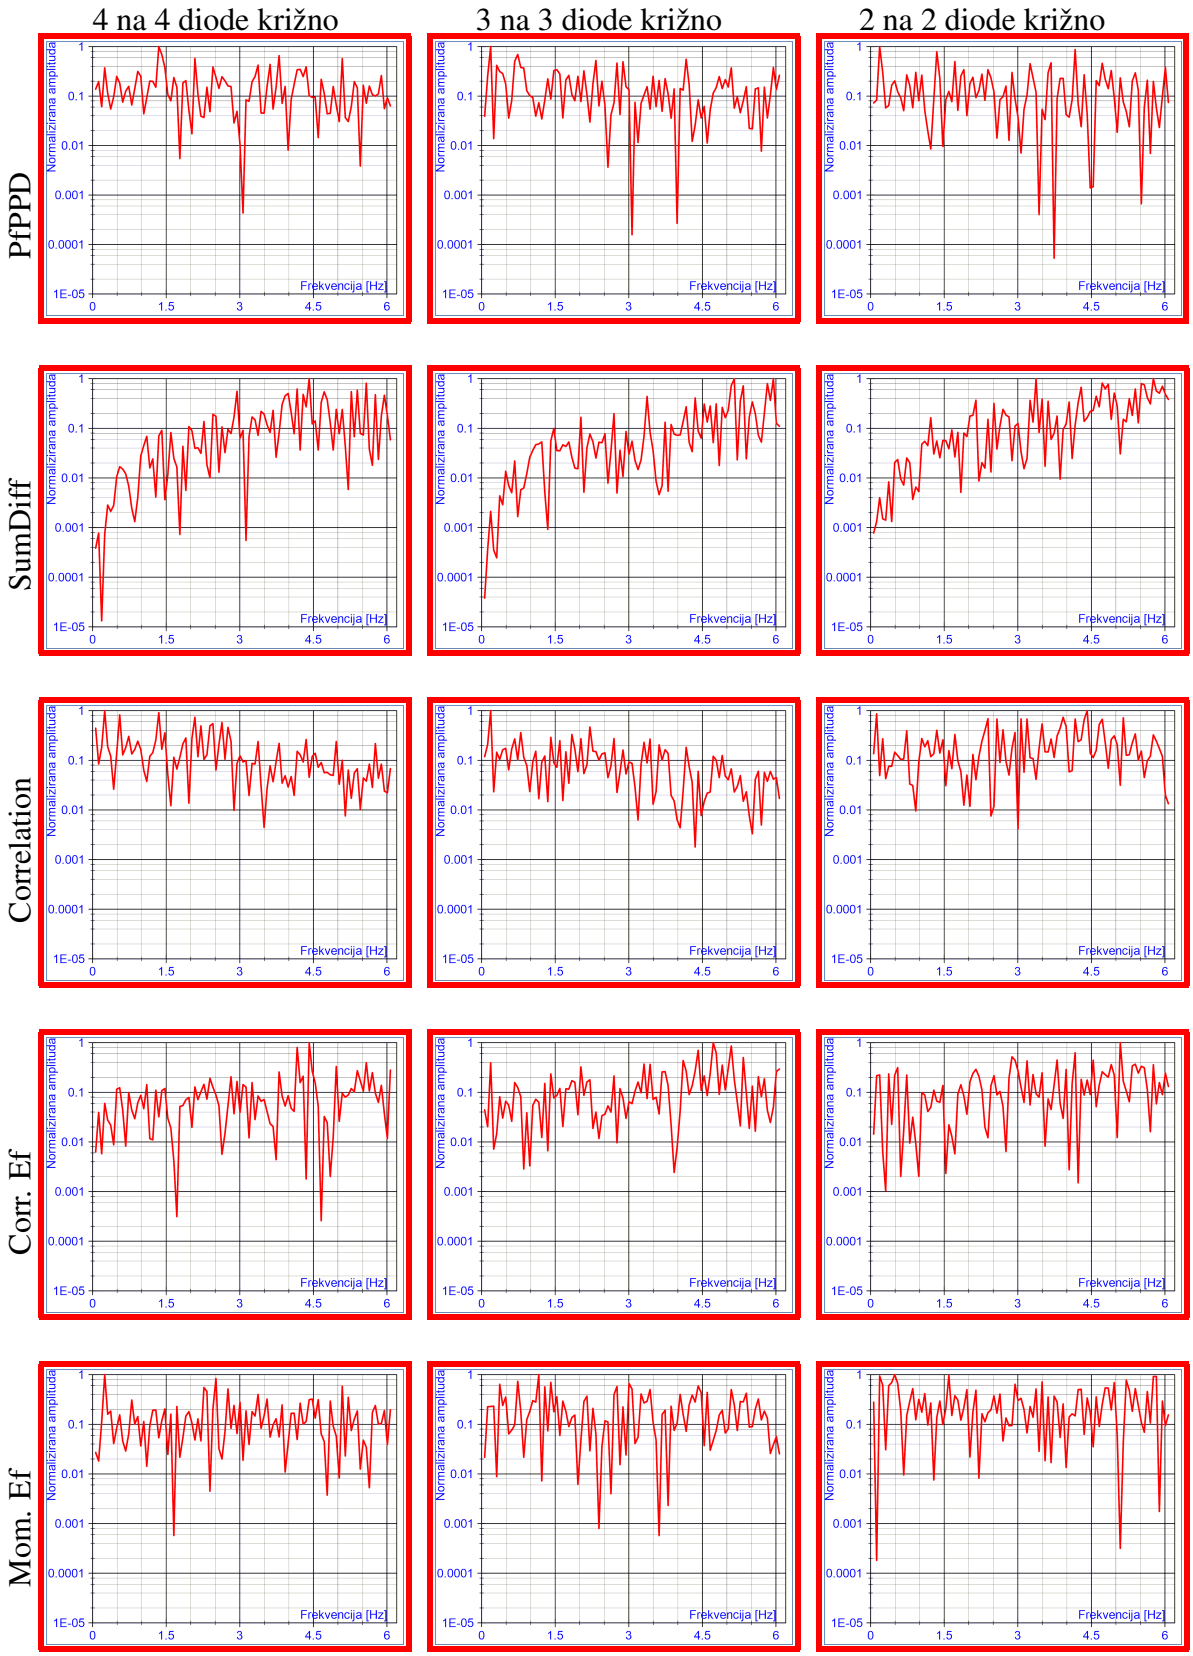

Slika 5.13: Usporedba metoda za križnu konfiguraciju dioda veličine 14^2 px^2

5.3.2 Usporedba metoda za diode veličine 7^2 piksela^2

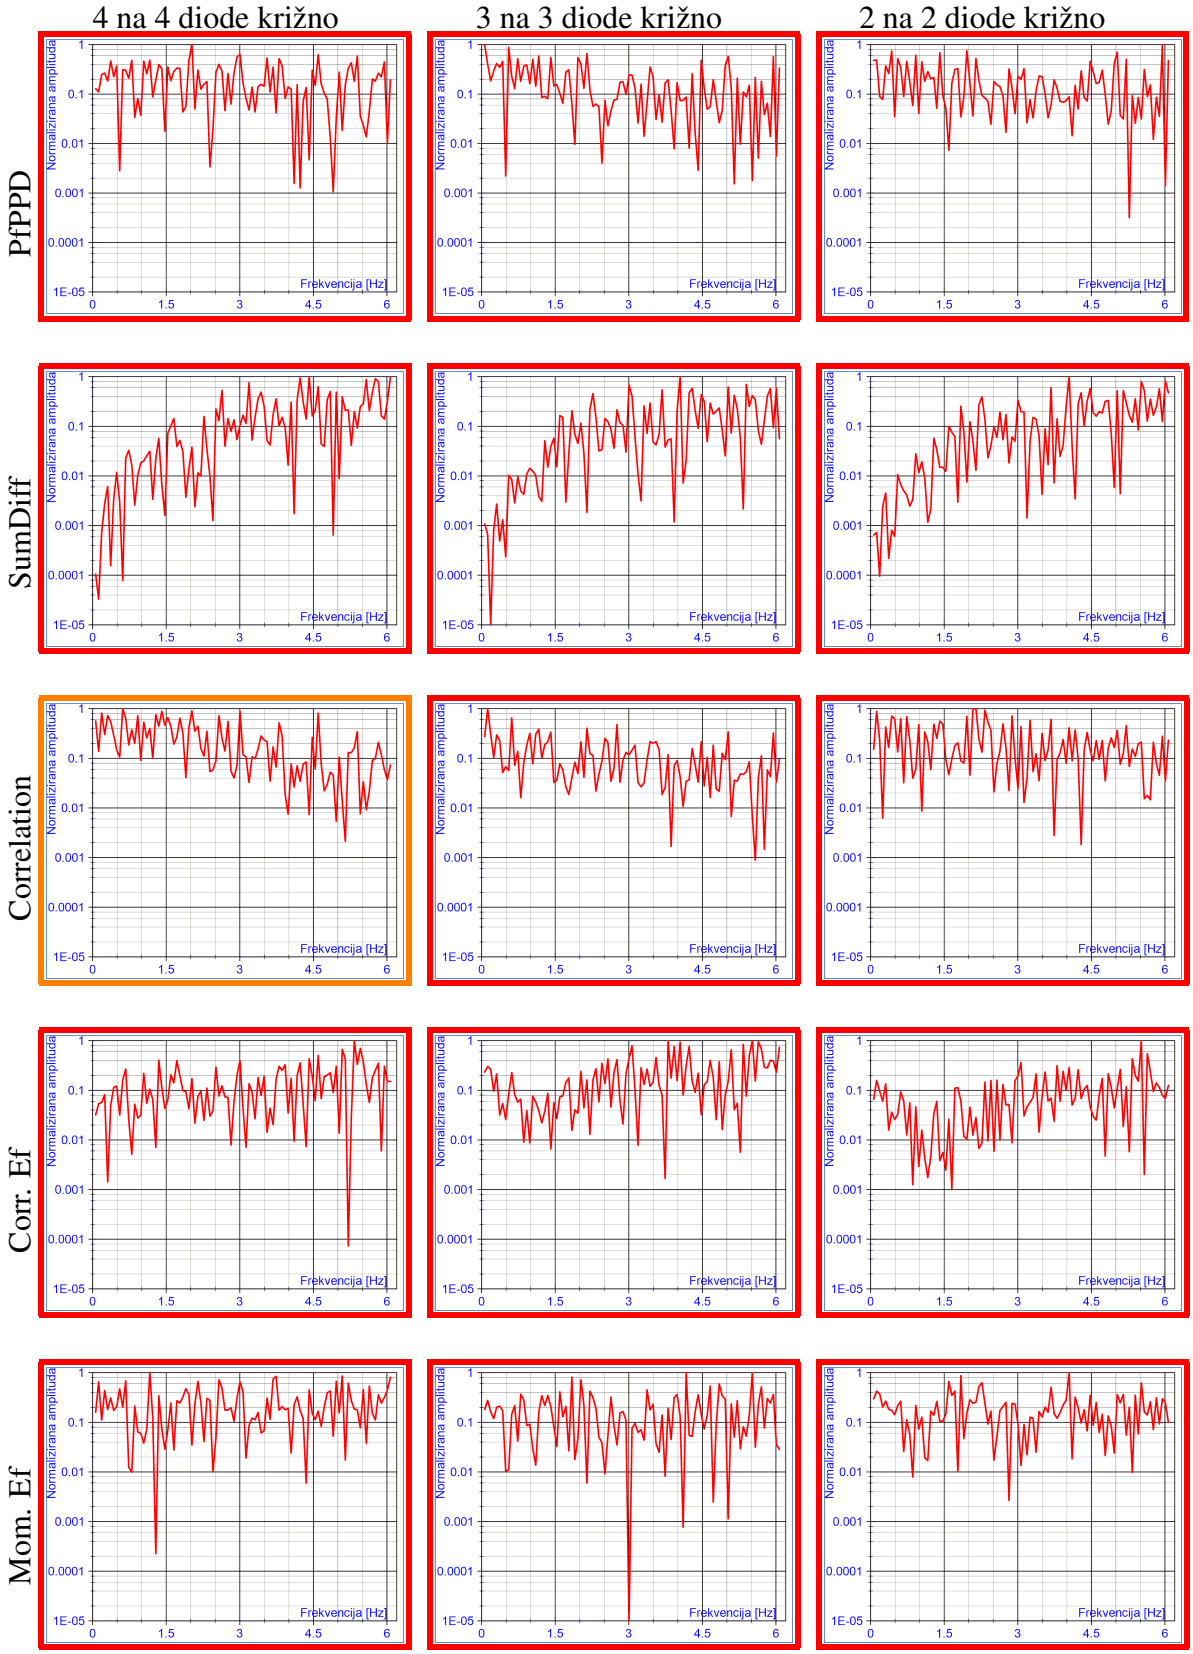

Slika 5.14: Usporedba metoda za križnu konfiguraciju dioda veličine 7^2 px^2

5.3.3 Usporedba metoda za diode veličine 3^2 piksela^2

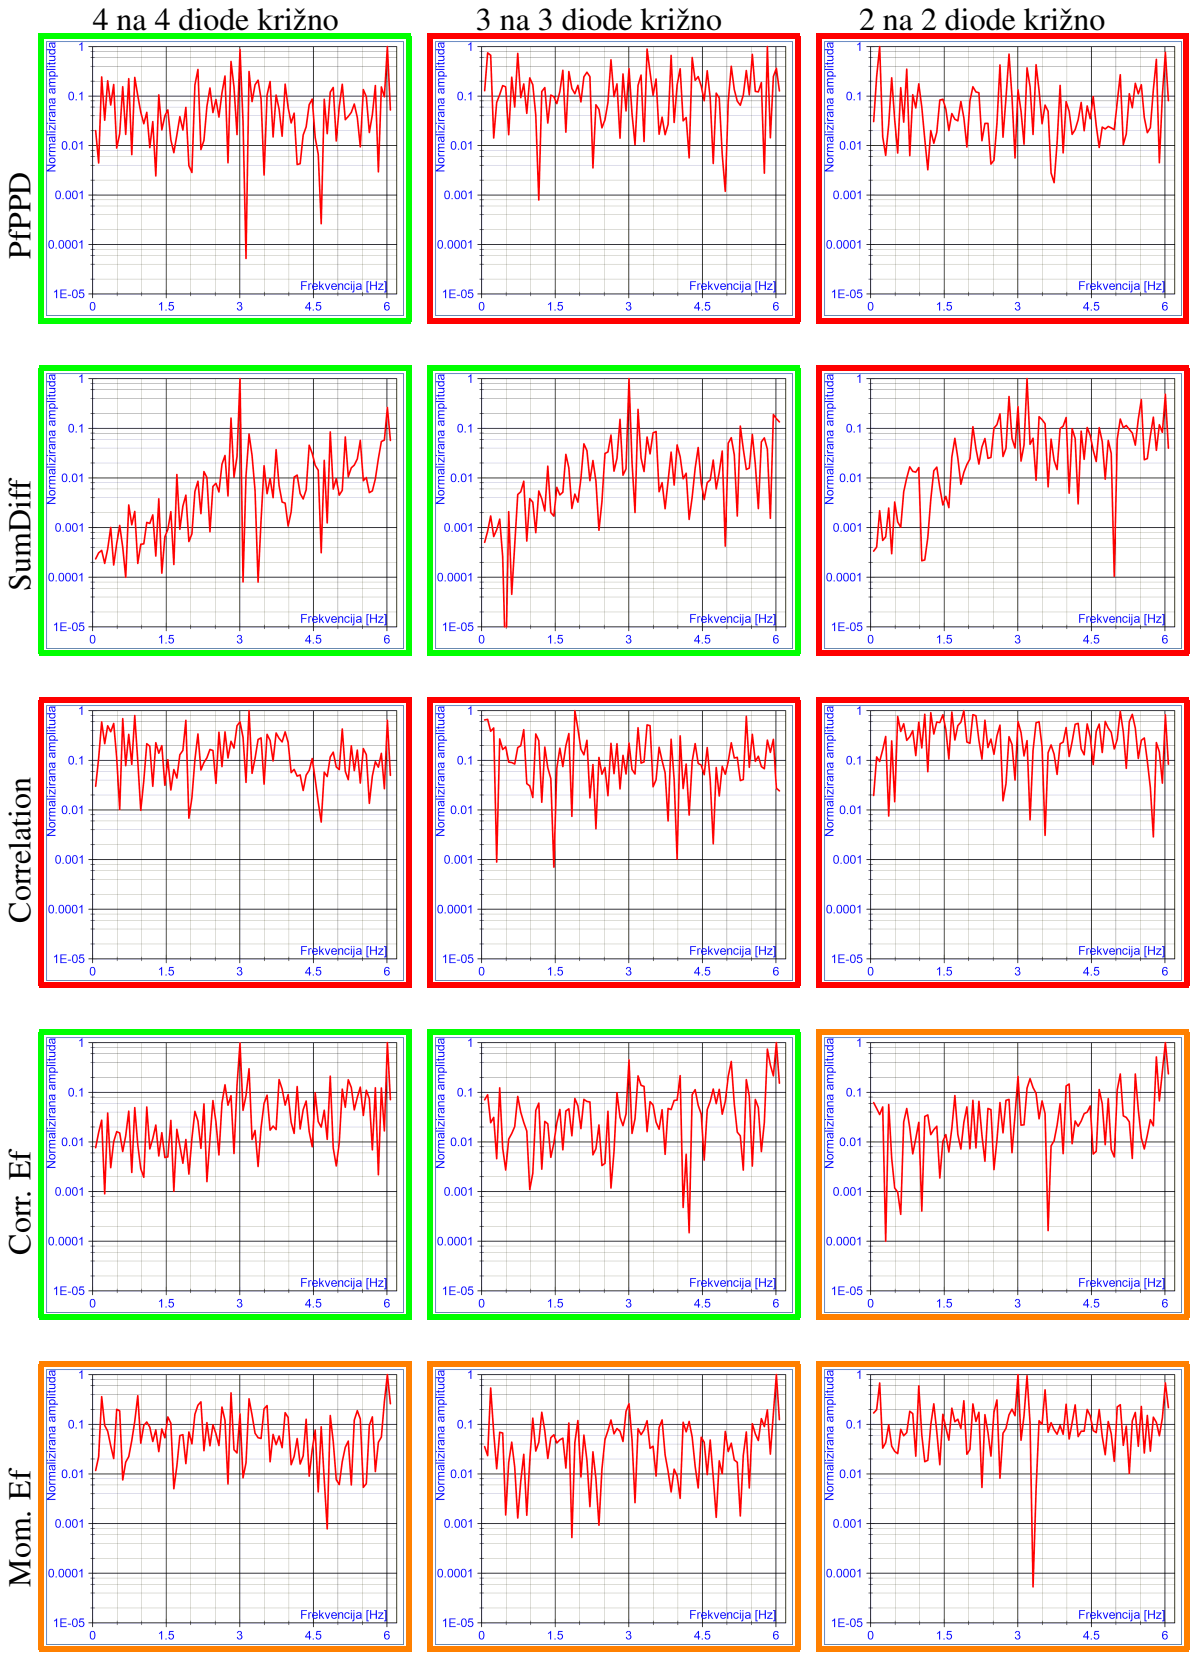

Slika 5.15: Usporedba metoda za križnu konfiguraciju dioda veličine 3^2 px^2

5.3.4 Usporedba metoda za diode veličine 2^2 piksela^2

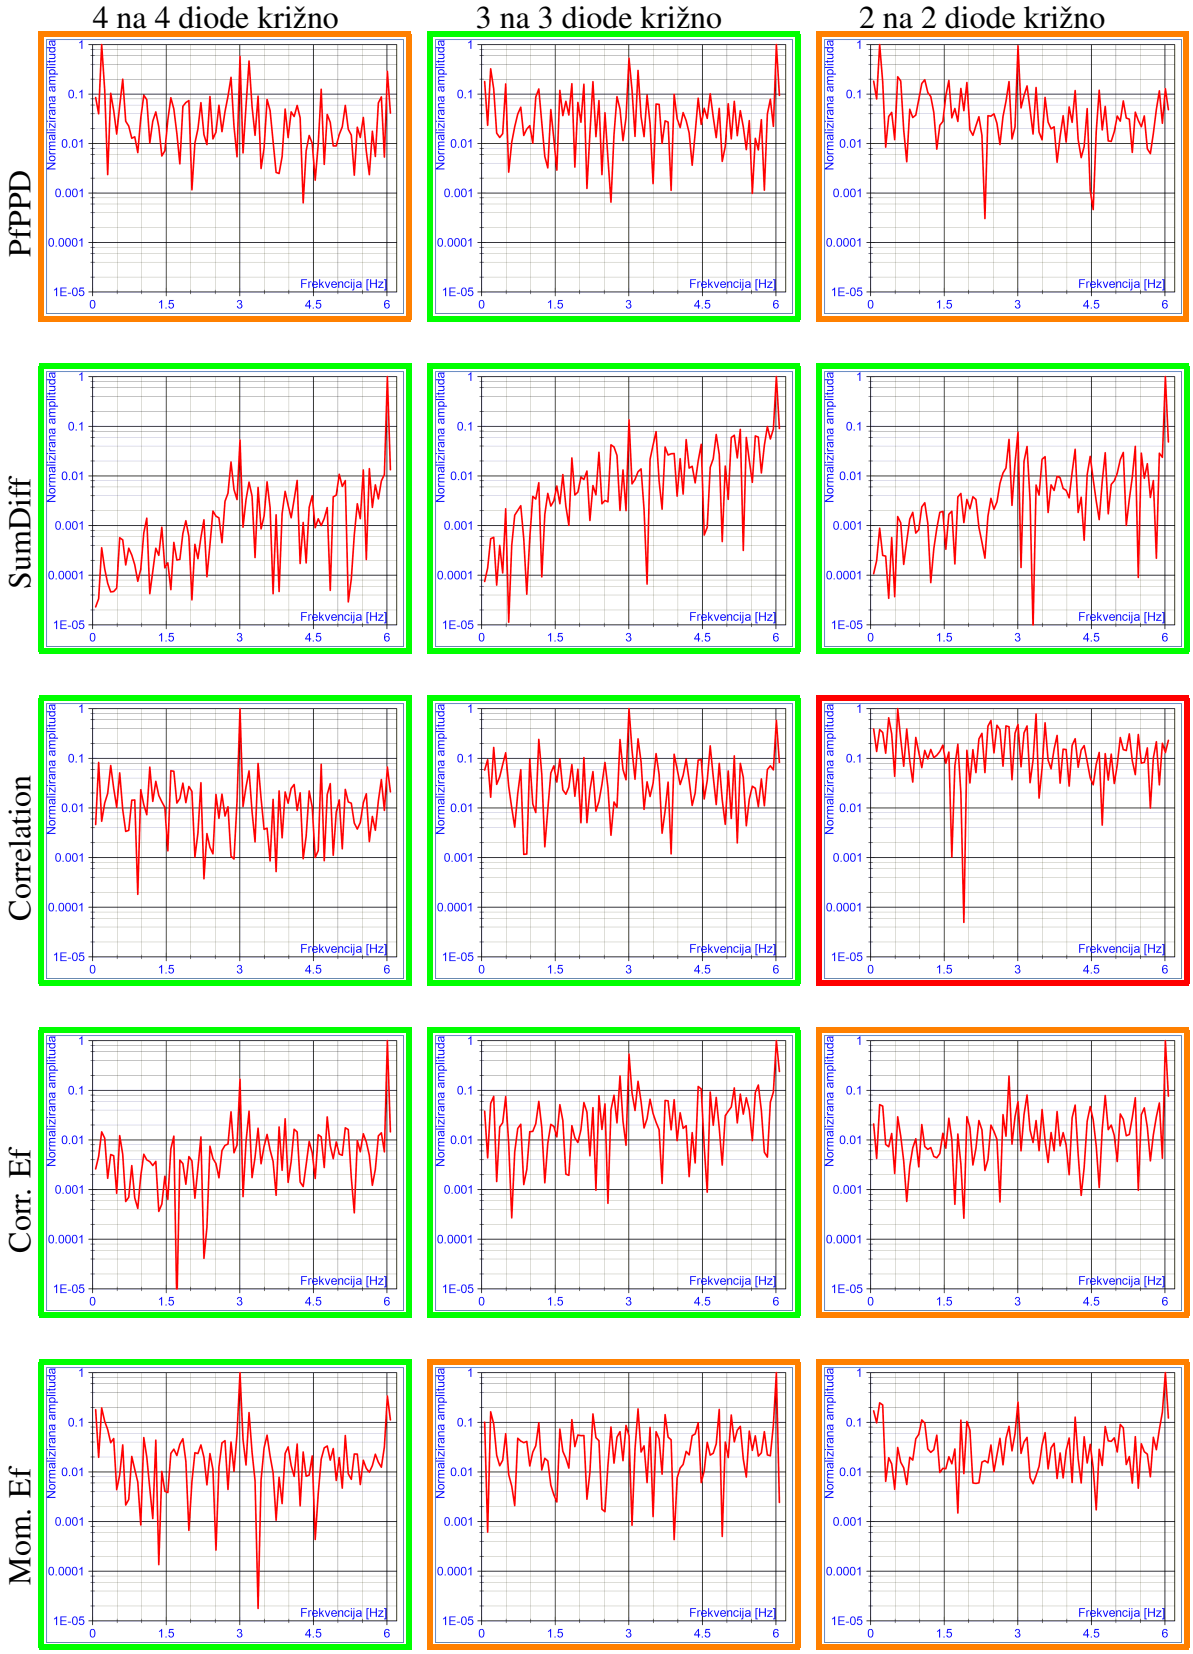

Slika 5.16: Usporedba metoda za križnu konfiguraciju dioda veličine 2^2 px^2

5.3.5 Usporedba metoda za diode veličine 1^2 piksela^2

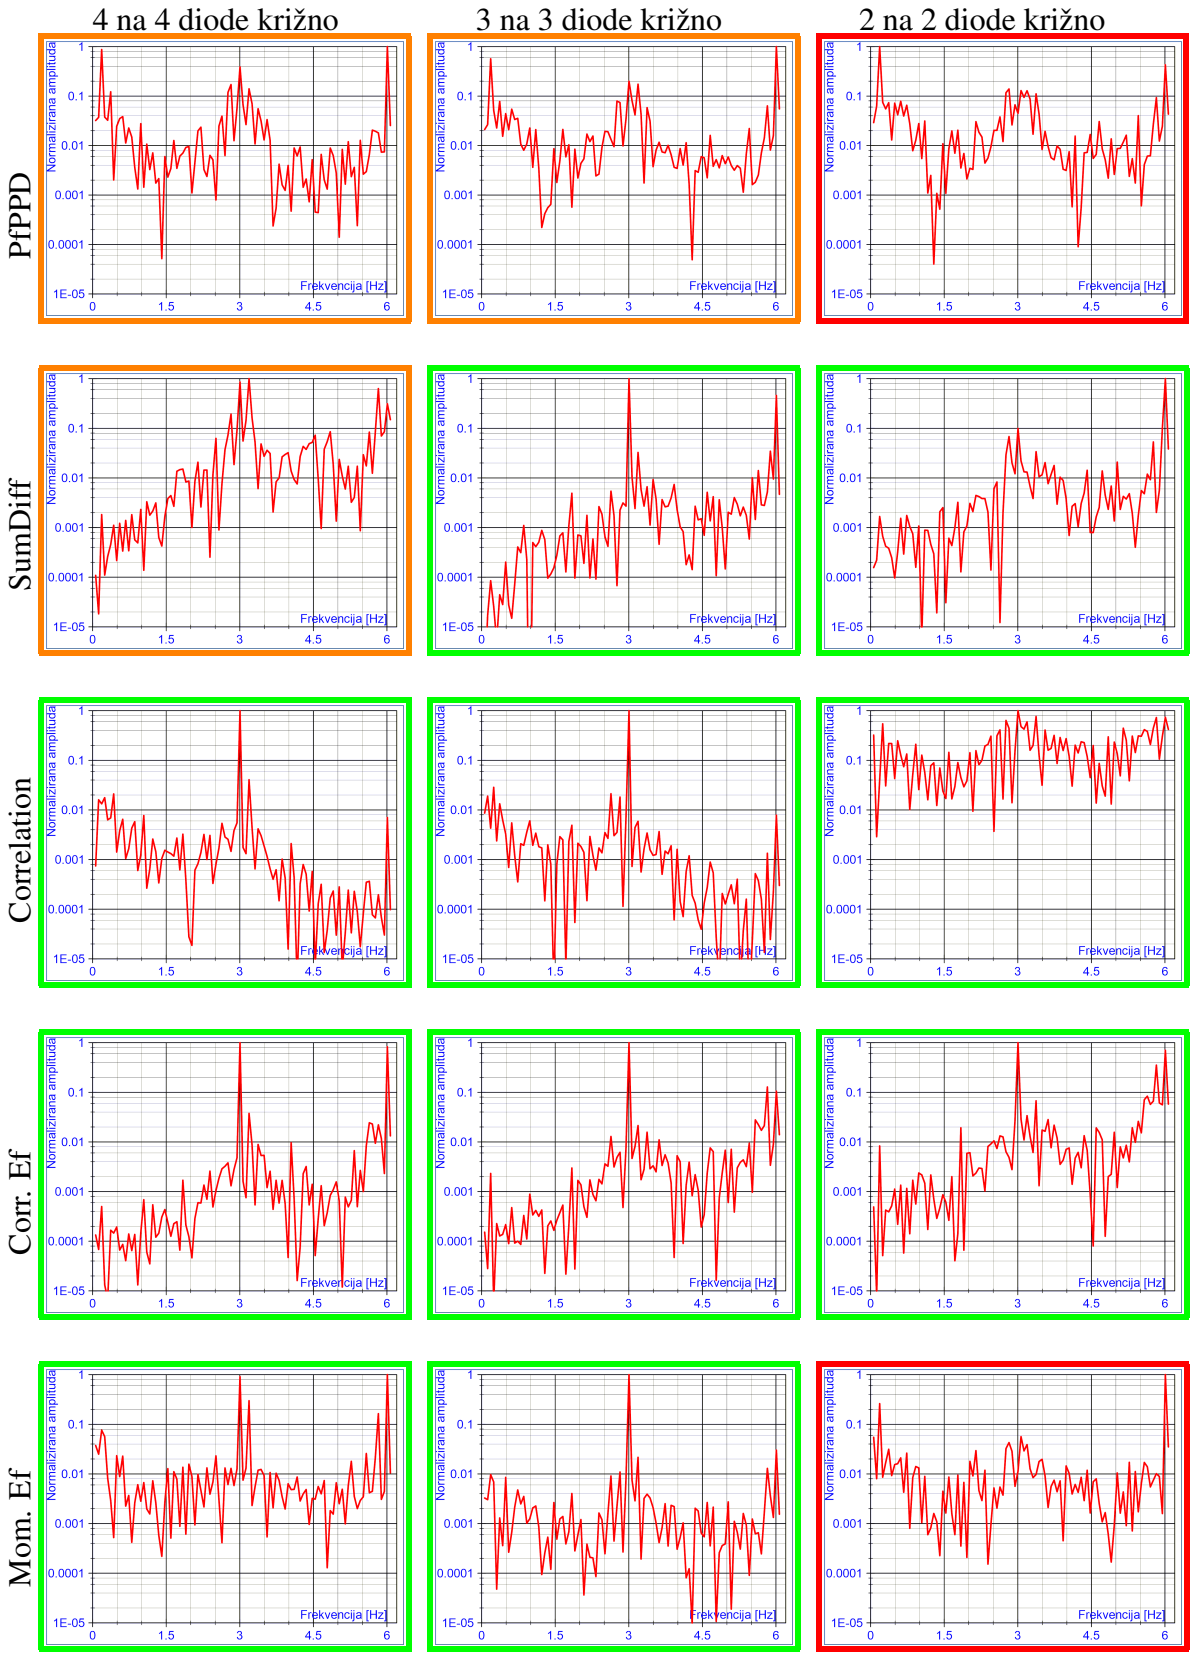

Slika 5.17: Usporedba metoda za križnu konfiguraciju dioda veličine 1^2 px^2

5.4 Diskusija rezultata za simulacije polja detektorskih dioda u dvije različite konfiguracije

Usporedbom sumarnih tablica za sve prezentirane rezultate (i neke koji nisu direktno predstavljeni, ali su spomenuti) dolazimo do sljedećih nekoliko zaključaka:

- Najbolje rezultate daju najmanje simulirane diode, odnosno površina detekcije treba biti što manja
- Veći broj dioda u polju ne daje bolje rezultate, odnosno polje dimenzije 2×2 je dalo najbolje rezultate od svih analiziranih simulacija
- Rezultati blago indiciraju da je dvodimenzionalno polje dioda povoljnija konfiguracija, ali uz napomenu da za slučaj 2+2 dimenzije križne konfiguracije rubne diode (zbog zadržane prethodne dimenzije detektorskog polja) ostaju malo previše *unutar* točkastog uzorka, odnosno ne nalaze se na samom rubu, gdje se pretpostavlja da bi ostvarili bolju detekciju - usporedivu i komplementarnu s 2×2 konfiguracijom (dvodimenzionalno polje).
- Metode statističke analize daju podjednako dobre rezultate ako zanemarimo metodu Pf-PPD koja je naslijeđena iz prototipa sustava sa CCD kamerom. Metoda momenata (Mom. Ef) pri tome ostvaruje malenu prednost pred ostalim predstavljenim statističkim metodama.

Iz svih navedenih rezultata intenzivnih simulacija polja detektorskih dioda dobili smo solidnu ideju o početnim parametrima za predloženu modifikaciju mjernog sustava pomoću detektorskih dioda. Ono što nedostaje je poveznica između piksela kojima smo baratali u analizama i dimenzija detektorskih dioda u stvarnom svijetu. Tu poveznicu nije sasvim jednostavno izvući, ali orijentacijsku vrijednost ćemo izračunati pomoću slike 5.18.

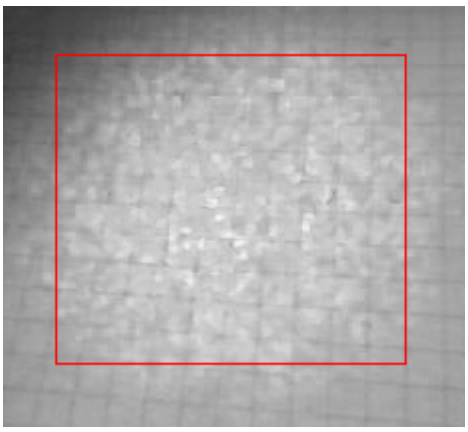

Slika 5.18: Prikaz točkastog uzorka i segmenta poznate veličine na podlozi s referentnim dimenzijama

Prikazana slika je daleko od idealne. Naime, zbog geometrije kutije u kojoj su rađena mjerenja i u kojoj je bila pozicionirana i kamera, koja nije smjela ometati projekciju točkastog uzorka iz svjetlovoda, nije bilo moguće postići paralelnost između ravnine detekcije kamere i

zaslona za projekciju. Također je bilo nužno pustiti nešto dodatne svjetlosti u kutiju kako bi mreža na podlozi bila vidljiva. Točkasti uzorak je inače u potpunosti maskira. Iako nije moguće sa velikom točnošću i preciznošću odrediti dimenzije jednog piksela slike (dimenzija nije striktno gledano ni konstantna preko cijele slike zbog kuta), ipak je prikazano dovoljno za okvirnu procjenu.

Naznačeni crveni segment slike je dimenzije w_x =175 px po osi x i h_y =155 px po osi y. Uz malo manipulacije u programu za obradu slike njegova širina je na temelju dimenzija podloge procijenjena na $w_x \approx$ 4,75 cm te $h_y \approx$ 4,25 cm. Izračunata površina segmenta u pikselima je $A_p x$ =27125 px^2 Istovremeno vrijedi A ≈2020 mm^2.

Iz navedenog vrijedi da je površina jednog piksela 1px≈0,0745 mm^2, što nas dovodi do sljedećih dimenzija za simulirane veličine dioda u pikselima:

A_{sd}[px^2]	A_D[mm^2]
1^2	0,0745
2^2	0,298
3^2	0,6705
7^2	3,651
14^2	14,602
26^2	50,362
47^2	164,571

U sljedećim poglavljima slijedi prezentacija izrade i testiranja praktične izvedbe svjetlovodnog sustava za detekciju vibracija pomoću točkastog uzorka s diodama kao detektorskim elementima.

Poglavlje 6

Eksperimentalni mjerni sustav s detektorskim diodama

Nakon velikog broja obavljenih simulacija i detaljne analize rezultata pristupilo se izradi fizičkog mjernog sustava za provedbu svega ustanovljenog u realni sustav. Idejna shema sustava je prikazana na slici 6.1.

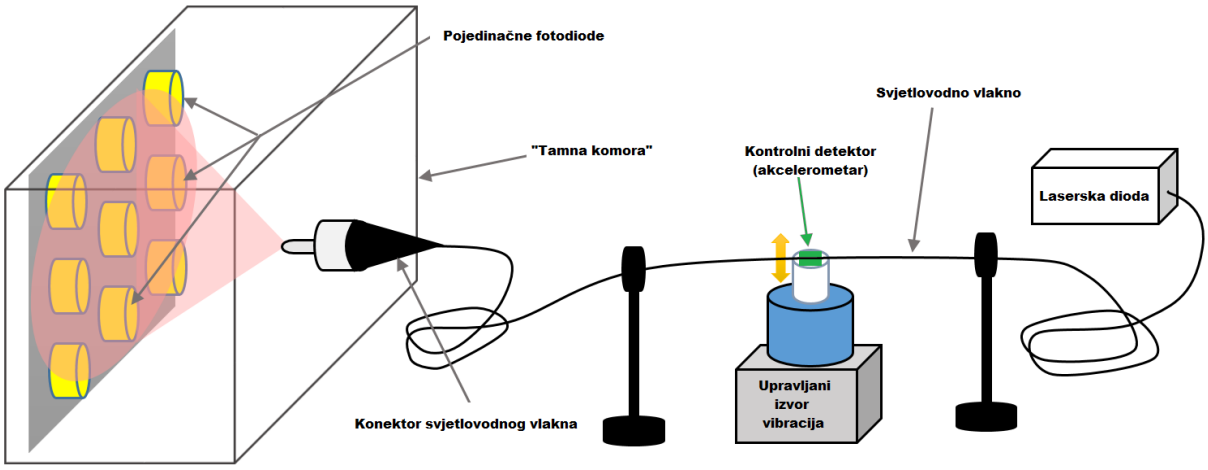

Slika 6.1: Shematski prikaz svjetlovodnog sustava za mjerenje vibracija s fotodiodama kao detektorskim elementima

6.1 Elementi mjernog sustava

6.1.1 Detektorske diode

Za potrebe izrade sustava naručene su fotodiode vrlo malene aktive površine THORLabs FDS025 (u daljnjem tekstu *mala dioda*), a kako je na raspolaganju bilo i nekoliko fotodioda S6775 proizvođača Hamamatsu (u daljnjem tekstu *velika dioda*) odlučeno je napraviti dvije varijante detektorskog sustava (odnosno polja detektorskih diodadioda). Detalji o upotrijebljenim diodama

i dio njihovih specifikacija su prikazani na slici 6.2.

Kao što se može vidjeti na slikama 6.2d i 6.2e dioda FDS025 je opremljena kuglastom lećom, što povećava njenu efektivnu detektorsku površinu. S obzirom na geometriju sustava i činjenicu da zrake iz svjetlovoda ne padaju paralelno na leću, to efektivno povećanje površine nije u punoj površini presjeka leće (odnosno površini rupe u koju je ugniježđena), već nešto manje. Koliko točno manje nije moguće ustanoviti jer proizvođač nije pružio dovoljno podataka za izračun, a i preostalu geometriju sustava je relativno teško točno izmjeriti. Ono što sa sigurnošću možemo ustvrditi jest da je efektivna površina negdje unutar raspona od površine aktivnog detektorskog dijela diode koja iznosi 0,049 mm^2 do maksimalno moguće efektivne površine (uslijed djelovanja leće) iznosa 1,766 mm^2. Ta maksimalno moguća efektivna površina detekcije odgovara površini od 23,7 px^2 prema proračunu iz odjeljka 5.4 što bi otprilike odgovaralo simuliranoj diodi veličine 5^2px^2. Međutim, kao što je rečeno, efektivna je veličina detektora sigurno manja, odnosno unutar raspona veličina simuliranih dioda za koje su prezentirani i rezultati u prethodnom poglavlju. Površina Hamamtsu diode, prikazane na slici 6.2a, je direktno definirana u specifikaciji 6.2c i iznosi 26,4 mm^2, odnosno preračunato u piksele odgovara otprilike simuliranoj diodi dimenzija 19^2 px^2.

Detektorske diode su spojene prema shemi spajanja koju je ponudio proizvođač i koja je prikazana na slici 6.3

6.1.2 Svjetlovodna vlakna

U sustavu je korišteno više svjetlovodnih vlakana koji nisu imali *osjetilnu* funkciju. Kako se radi o standardnim varijantama spojnih kabela oni neće biti posebno opisani. Međutim, dva vlakna su korištena kao aktivni *osjetilni* elementi senzorskog sustava. Jedno vlakno je bilo standardno višemodno vlakno za komunikacijske namjene uobičajenih dimenzija jezgre i plašta 62,5/125 μm te numeričke aperture 0,275.

Drugo vlakno je specijalno višemodno vlakno koje se inače koristi zbog svoje robusnosti i veće otpornosti na prodor vlage u materijal vlakna. Također je pogodnije za postupke krimpanja i lijepljenja konektora, ali za potrebe ovog sustava je zanimljivo zbog dimenzija jezgre. Dimenzije jezgre i plašta su 200/225 μm a numerička apertura je iznosa 0,39. Zahvaljujući ovakvoj geometriji vlakno podržava znatno veći broj modova od standardnog višemodnog vlakna te je u daljnjem tekstu navedeno kao specijalno višemodno vlakno. Ovo vlakno je također korišteno i za snimanje video materijala na kojima su obavljane simulacije, što je predstavljeno u poglavljima 3 i 5.

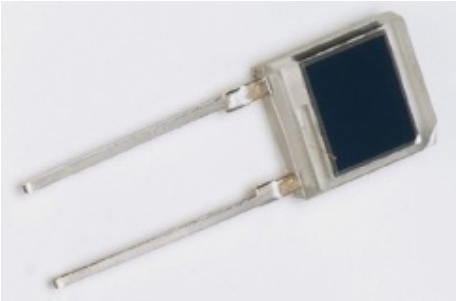

(a) Dioda Hamamatsu S6775 (*velika dioda*)

(b) Dioda Thorlabs FDS025 (*mala dioda*)

Type no.	Package	Photosensitive area size (mm)	Effective photosensitive area (mm^2)
S2506-02	Plastic	2.77 × 2.77	7.7
S2506-04			
S6775		5.5 × 4.8	26.4
S6775-01			
S6967			

(c) Detalj specifikacije Hamamatsu S6775

Physical Specifications	
Active Area Diameter	Ø0.25 mm
Coupling Lens	Ø0.06″ Ball Lens

(d) Detalj specifikacije Thorlabs FDS025

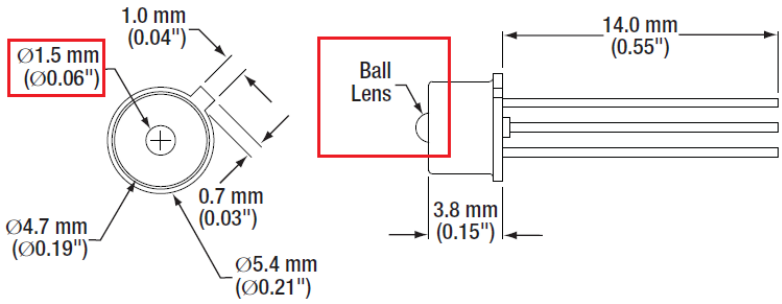

(e) Građa diode Thorlabs FDS025

Slika 6.2: Fotodiode korištene za izvedbu mjernog sustava

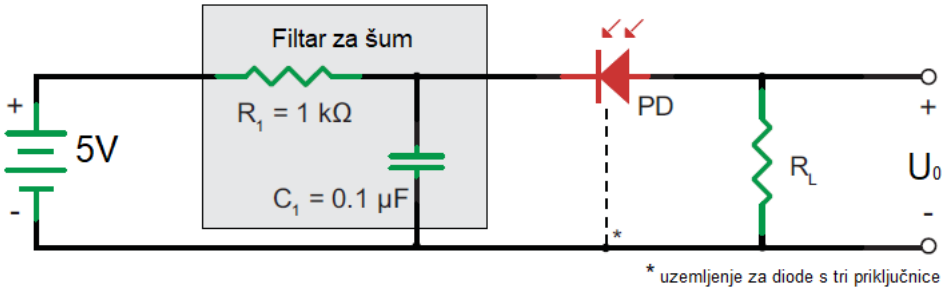

Slika 6.3: Načelna shema spoja za diode

6.1.3 Kontrolni detektor (akcelerometar)

Kao kontrolni detektor je korišten maleni troosni akcelerometar ADXL335 proizvođača Analog devices. Uređaj je predviđen za ubrzanja raspona ±3g i na izlazu daje naponski signal za svaku od osi. Odlikuje ga visoki stupanj linearnosti odziva i osjetljivost od 300mV/g. U slučajevima znatnijih promjena temeperature radne okoline potrebno je unijeti korekcije u rezultate koje

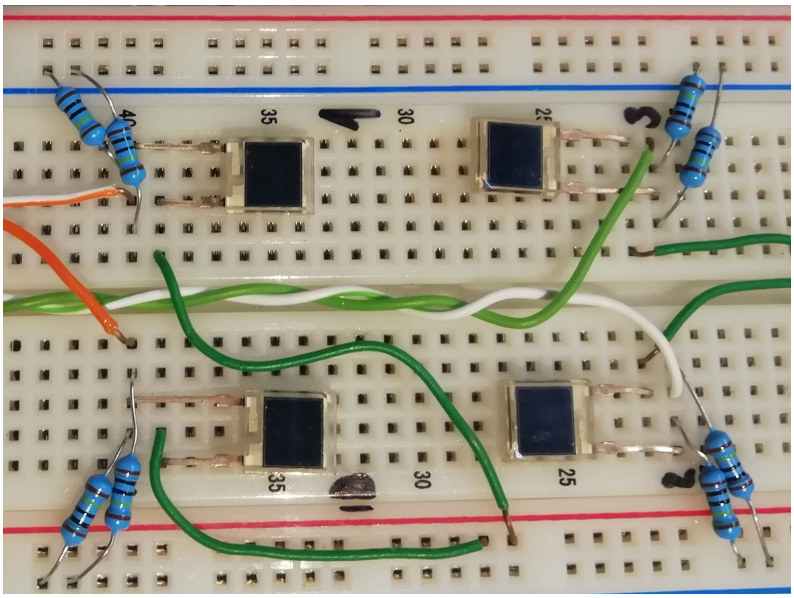

Slika 6.4: Detektorsko polje u izvedbi s diodama Hamamatsu S6775

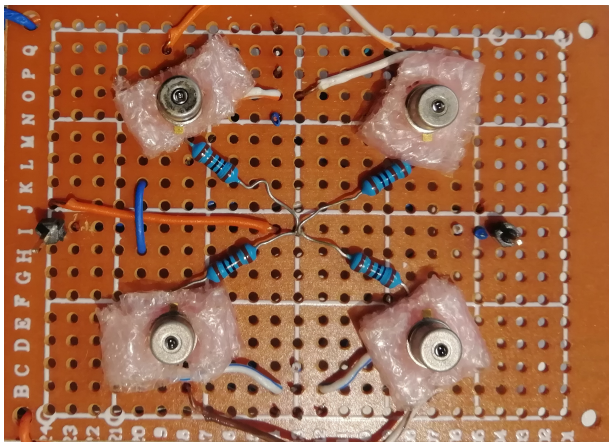

(a) Prednja strana spoja - detektor

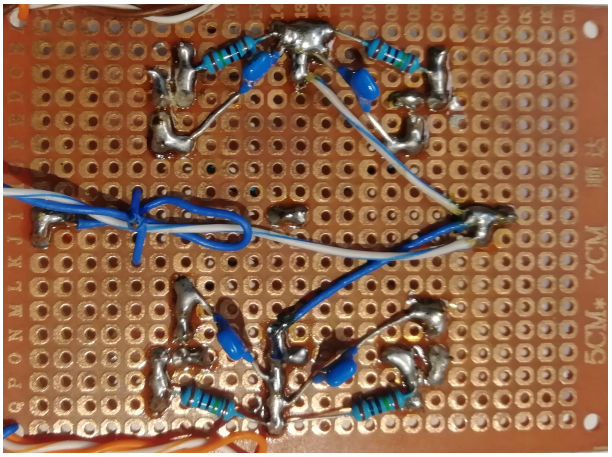

(b) Stražnja strana spoja

Slika 6.5: Detektorsko polje u izvedbi s diodama Thorlabs FDS025

isporučuje, ali u mjerenjima koja smo radili to nije bio sluičaj. Akcelereometar je prikazan na slici 6.6.

Slika 6.6: Akcelerometar ADXL335 koji je u mjerenjima korišten kao kontrolni detektor za vibracije

6.1.4 Upravljani generator mehaničkih vibracija

Za proizvodnju kontroliranih mehaničkih vibracija korišten je Smart Shaker K2004E01 proizvođača The Modal Shop. Na slici 6.7a je prikazan sam uređaj, a na slici 6.7b njegove osnovne specifikacije vezane uz vibracije.

(a) Izgled uređaja

SPECIFICATIONS	
Performance	**K2004E01**
Shaker Performance	
Output Force, sine pk	
Natural Air Cooling	4.5 lbf (20 N)
Output Force, random RMS	
Natural Air Cooling	3 lbf (13.3 N)
Output Force, shock pk	9 lbf (40 N)
Stroke Length	
Continuous pk-pk	0.2 in (5 mm)
Between Stops	0.35 in (9 mm)
Frequency Range [1]	DC-11 kHz
Acceleration [1, 2]	
No load	64 g pk
0.1 lb (0.045 kg) load	26 g pk
1 lb (0.454 kg) load	4.2 g pk
2 lb (0.907 kg) load [max payload]	2.2 g pk

(b) Specifikacije uređaja

Slika 6.7: Upravljani generator mehaničkih vibracija

6.1.5 Uređaj za akviziciju

Kao akvizicijski uređaj korišten je MyRIO proizvođača National Instruments prikazan na slici 6.8. Radi se o vrlo fleksibilnom prijenosnom multifunkcionalnom uređaju, čije mogućnosti daleko nadilaze potrebe akvizicije u ovom sustavu. Međutim, taj je uređaj izrazito pogodan za programiranje u LabVIEW programskom okruženju te je stoga odabran za funkciju akvizicije signala sa dioda. Kod korištenog LabVIEW programa prikazan je u dodatku B.

Za potrebe mjerenja preko polja dioda razvijen je poseban program koji se izvodio na samom MyRIO uređaju. Program je putem komunikacije s računalom omogućio upravljanje i nadzor, pri čemu je PC služio samo za parametriziranje i pokretanje mjerenja te prikaz rezultata, a kompletno mjerenje i zapisivanje podataka se obavljalo na MyRIO uređaju. Razvijeni program je omogućio:

- promjenjivu brzinu akvizicije (do 500kS/s po kanalu)
- istovremenu akviziciju 6 ulaznih signala (četiri fotodiode, kontrolni detektor i signal koji pobuđuje vibrator)
- trenutačnu obradu zabilježenih signala svim predstavljenim statističkim metodama

(a) MyRIO multifunkcijski uređaj

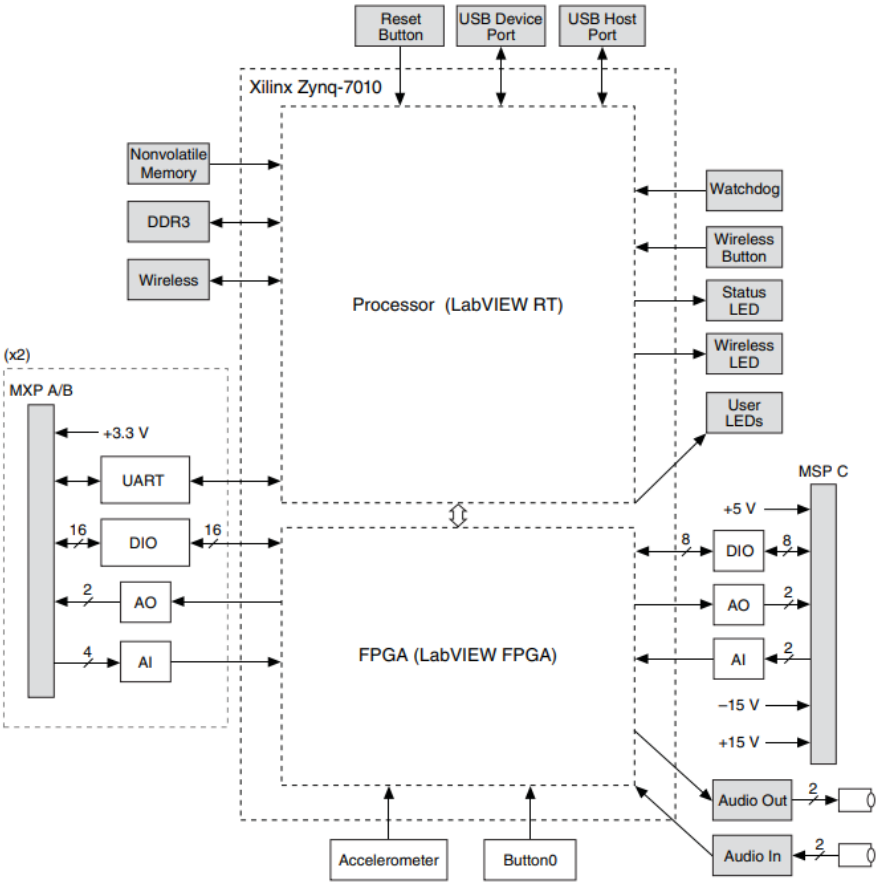

(b) Blok dijagram MyRIO uređaja

Slika 6.8: National Instruments MyRIO

- prikaz pripadnih rezultantnih vremenskih signala u *realnom* vremenu
- spektralnu analizu s odabirom vremena integracije signala i prikaz rezultata u *realnom* vremenu
- zapis svih vremenskih signala (svih šest ulaznih i pet izračunatih za različite statističke metode obrade signala) te rezultate svih spektralnih analiza u posljednjem zabilježenom integracijskom periodu.

Na slici 6.9 prikazano je korisničko sučelje pripremljenog programa.

Uvođenjem dioda kao detektorskih elemenata znatno je pala potreba za brzinom rada pro-

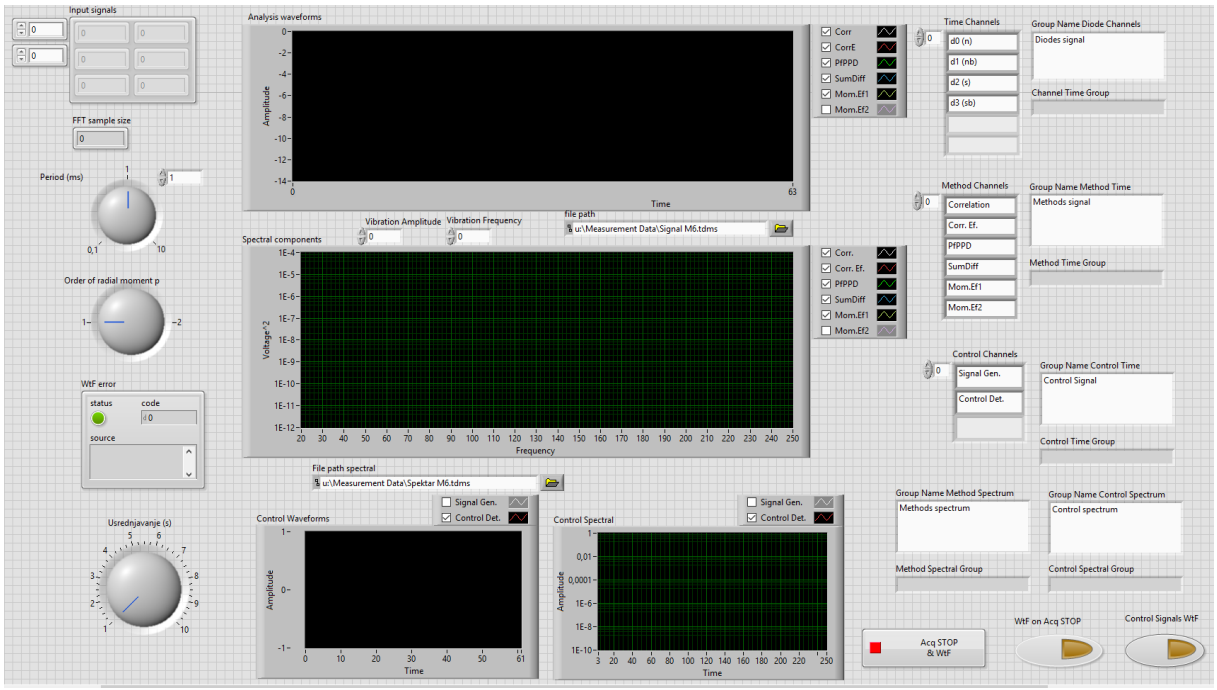

Slika 6.9: Korisničko sučelje programa za mjerenje vibracija pomoću svjetlovoda i fotodioda

grama, iako je frekvencija kojom je obavljana akvizicija porasla za gotovo dva reda veličine. Umjesto 200000 paralelnih signala sada je u obradu išlo šest paralelnih ulaznih signala. Iako u ovom slučaju to nije bilo nužno, jer je sustav mogao podatke obrađivati i većom brzinom od one kojom su pristizali, zadržana je *producer/consumer* arhitektura programa koja je pogodna za asimetrične sustave prikupljanja i obrade podataka. Sve statističke metode, koje su napisane za varijantu sustava s kamerom kao detektorom, jednostavno su prilagođene za potrebe varijante s diodama. Pri tome su signali s dioda obrađivani kao pojedinačni pikseli, odnosno složeni su u *sliku*, a uzastopne slike su zatim proslijeđene istim, već opisanim statističkim metodama za obradu. Svi rezultati mjerenja i proračuna su mogli biti zapisani u datoteke koje su sustavno imenovane ovisno o odabranim parametrima mjerenja, odnosno signala koji se zapisuje (*Write to File - WtF* prekidači).

6.1.6 Ostali elementi mjernog sustava

Za provođenje mjerenja korišteni su još:

- Laserska dioda kao izvor svjetlosti (crvena vidljiva svjetlost)
- Svjetlovodno višemodno vlakno (*standardno*)
- Svjetlovodno specijalno višemodno vlakno (*specijalno*)
- Generator signala za pobudu upravljanog mehaničkog vibratora
- Tamna komora, odnosno kutija u kojoj je obavljana projekcija i detekcija točkastog dijagrama.

6.2 Proces mjerenja

Sam proces mjerenja je bio uređen na sljedeći način:

- Odabran je niz frekvencija u rasponu do 500 Hz, pri čemu su pojedinačne frekvencije primarni brojevi kako bi se izbjegla pobuda vlastitih mehaničkih rezonantnih frekvencija sustava u više mjernih točaka. Ukoliko bi do takve pojave ipak došlo ona ne bi utjecala na veći broj mjerenja. Frekvencijske mjerne točke su gušće raspoređene u rasponu do 100 Hz, a nakon te vrijednosti znatno rjeđe.
- Za svaku frekvencijsku točku je obavljeno mjerenje na četiri do pet različitih amplituda uzbude za vibrator kontroliranih pomoću akcelerometra. Nije bilo moguće dobiti odziv kontrolnog detektora za najmanju amplitudu uzbude na svim frekvencijama.
- Kako raspolažemo s dva diodna detektorska sustava i dva različita svjetlovodna vlakna, postoje četiri moguće kombinacije za mjerenja.
- Na prethodno navedene varijante dodaje se i modifikacija sprege između vlakna i vibratora na način da vlakno ne detektira vibracije cijelom duljinom između ovjesnih točaka, već samo u jednoj točki (ili najbliže tome što se može postići). Ovakva varijanta je izvedena postavljanjem vlakna u oblik petlje koja je onda bila podložna izobličenjima zbog djelovanja vibratora. Navedene varijante su prikazane na slikama 6.10 i 6.15 pod b).

Kako je navedeno u prethodnom poglavlju, mjerni sustav je bilježio sve ulazne signale (četiri diode i dva kontrolna signala) i analizirao ih u tom obliku te dodatno primjenom svih predstavljenih statističkih metoda. Zbog velike opsežnosti tako prikupljenih podataka neće moći svi biti prikazani, već će na veliki dio njih biti ponuđen samo opisni osvrt, a pokazani će biti ključni, koji najbolje ilustriraju rezultate provedenih mjerenja.

6.2.1 Način prikaza rezultata

Prikazani rezultati mjerenja su prvenstveno orijentirani na frekvenciju detektiranih vibracija, odnosno na spektar proračunatog signala. Kako različite statističke metode daju rezultate u vrlo velikom rasponu vrijednosti, različite i po sedam do osam redova veličine, potrebno ih je svesti na istu mjeru kako bi usporedba rezultata bila moguća. Očiti odgovor je normiranje, ali kao norma u ovom slučaju nije odabrana najveća spektralna komponenta. Naime, s obzirom da je u nekim slučajevima bila izražena i prisutnost viših harmonika osnovnog signala, ali i nekih drugih komponenti, za normu je uzeta srednja vrijednost cijelog raspoloživog spektra, uz izuzeće DC signala, odnosno srednja vrijednost je izračunata za frekvencije od 1 do 250 Hz. Na taj način je dobijen podatak o tome koliko je dominantna najveća spektralna komponenta (za koju se nadamo da odgovara frekvenciji uzbudnih vibracija) nad svim ostalim komponentama spektra. Taj podatak se za generalnu procjenu uspješnosti detekcije činio značajnijim od relativnog omjera između dominantne komponente i bilo koje druge pojedinačne spektralne komponente.

Kako bi ipak bio dostupan i taj omjer, na grafove su uvršteni i podaci o omjerima između prve i druge najdominantnije spektralne komponente. Iz praktičnih razloga uvedene su skraćenice PDK, DDK i TDK kao oznake za Prvu, Drugu i Treću Dominantnu Komponentu spektra. Namjerno nisu korišteni nazivi osnovni/viši harmonici jer se nije uvijek radilo o komponentama diretkno vezanim uz osnovni vibracijski signal.

6.3 Eksperimentalni rezultati

Kao što je već navedeno, mjerenja su rađena u cijelom nizu frekvencijski i amplitudno različitih točaka. Sljedeća tablica daje pregled jednih i drugih odvojeno (kako bi se smanjio broj kombinacija za prikaz). Napomenimo da je za svaku navedenu frekvenciju odrađeno mjerenje s uzbudama koje su odgovarale svim navedenim amplitudama i tako za sve kombinacije svjetlovoda i dioda u dvije različite postavke sustava. Pri tome su signali iz grupe Frekvencija$_L$ dohvaćani frekvencijom uzorkovanja f_{SL}=500 Hz, a signali iz grupe Frekvencija$_H$ dohvaćani frekvencijom uzorkovanja f_{SH}=1000 Hz. Osim frekvencije uzorkovanja mijenjana je i duljina trajanja akvizicije (usrednjavanje), ovisno o trenutnoj kombinaciji ostalih parametara mjerenja.

Tablica 6.1: Tablični prikaz uzbudnih frekvencijskih točaka u kojima je obavljano mjerenje

Frekvencija$_L$ [Hz]	29	37	47	59	67	79	89	100	103	157
Frekvencija$_H$ [Hz]	211	241	313	379	419	487	-	-	-	-

Amplituda je određivana pomoću kontrolnog detektora (akcelerometra), budući da je isti korišten kao referentna vrijednost po pitanju amplitude vibracija, odnosno točnije - akceleracije. Mjerenje je izvedeno u svim navedenim amplitudnim točkama gdje god je to bilo moguće. U jednom dijelu mjerenja su izostale najniže amplitudne vrijednosti zbog ograničenja mjernog opsega kontrolnog detektora.

6.3.1 Male detektorske diode i specijalno višemodno vlakno

Sljedeći rezultati prikazuju odziv mjernog sustava (odziv samih dioda i rezultate statističkih metoda analize) te njegovu usporedbu s odzivom referentnog detektora na niskim frekvencijama za akceleraciju od 1,17 g , odnosno amplitudu signala detektora U_{VV}=700 mV.

Tablica 6.2: Tablični prikaz amplitudnih vrijednosti signala kontrolnog detektora i odgovarajućih vrijednosti akceleracije za točke u kojima je obavljano mjerenje

U_{VV} [mV]	200	450	700	950	1200
Akceleracija [g]	0,33	0,75	1,17	1,58	2

Sprega između svjetlovoda i vibratora je pri tome ostvarena na način da je svjetlovod bio razapet između fiksnih točaka, te je u međuprostoru ostvarivao fizički kontakt s vibratorom. Navedeno je prikazano na slici 6.10. Na ovaj način su snimljeni video materijali na kojima su rađene simulacije. Problem ovakvog pristupa je pojava dodatnih parcijalnih vibracija na segmentima koji se nalaze izvan uporišnih točaka. To pogotovo dolazi do izražaja na nižim frekvencijama, na kojima za jednaku vrijednost akceleracije na kontorolnom detektoru treba ostvariti puno veći hod pomičnog dijela vibratora, a time i svjetlovoda. U pozadini slike pod b) je vidljiva tamna komora u kojoj je rađeno snimanje uzorka kamerom, odnosno detekcija diodama.

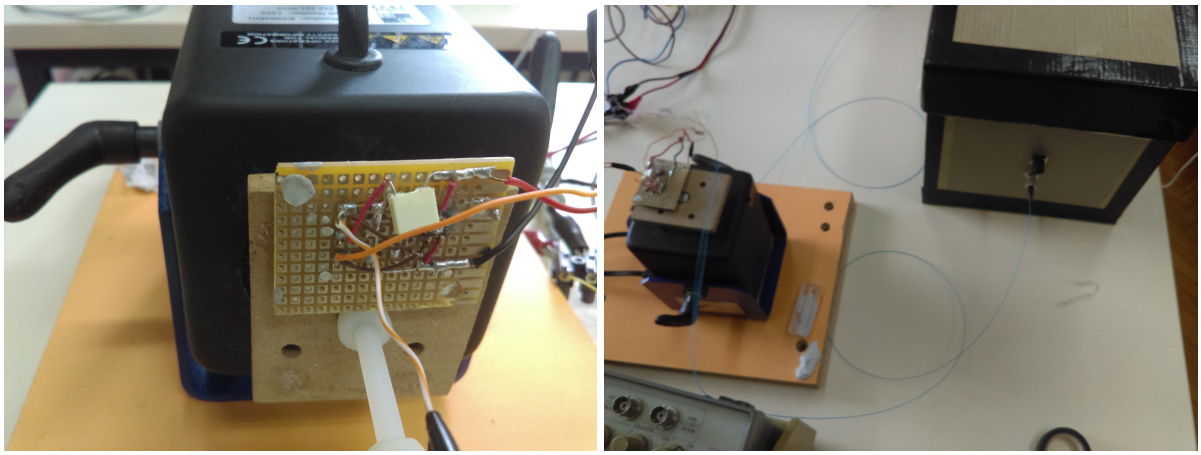

(a) Kontrolni detektor montiran na vibrator (b) Razapeto vlakno pod vibracijama

Slika 6.10: Detalji mjernog sustava

Uvidom u rezultate prikazane na slikama odjeljka 6.3.1 jasno je da direktna detekcija iz signala detektorskih dioda nije pouzdana, odnosno da samo povremeno signal s dioda pokazuje spektralna obilježja koja odgovaraju onima referentnog detektora. Situacija je nešto bolja od frekvencije 89 Hz na više, ali za pouzdanu detekciju se nije moguće uvijek osloniti na niti jednu od četiri diode.

Promatranjem slika odjeljka dolazi se do zaključka da je situacija nešto povoljnija za neke od statističkih metoda obrade, ali opet za frekvencije veće od 89 Hz. Pri tome neke od metoda (npr. metoda momenata - Mom. Ef), u rasponu nižih frekvencija, detektiraju više harmonike osnovne vibracijske frekvencije. Primjetan je i utjecaj frekvencije mrežnog napona, koji registrira čak i kontrolni detektor.

Spektar signala s detektorskih dioda

Slika 6.11 a)

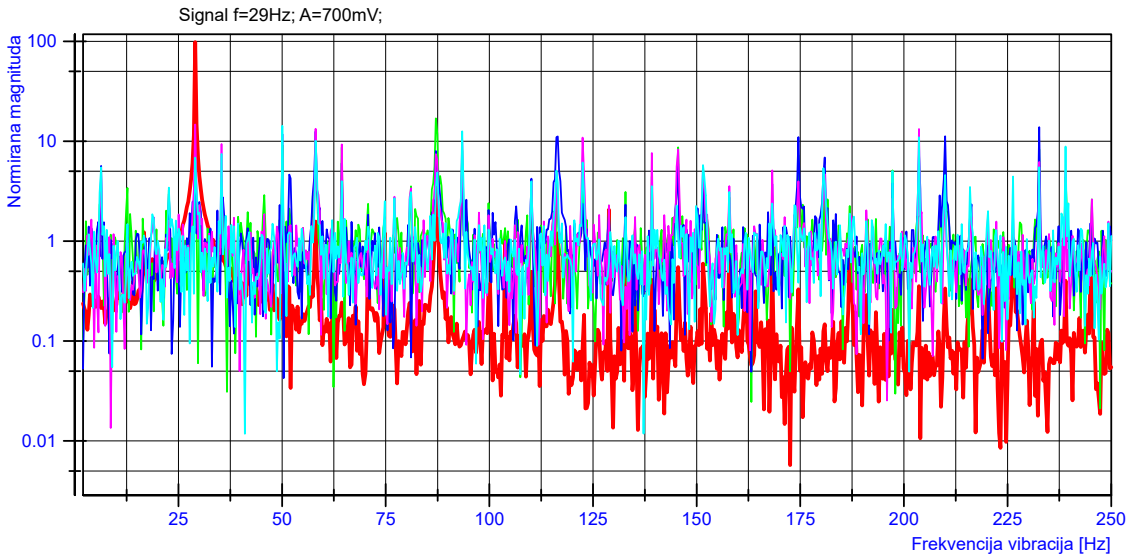

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det.	98.01	29	3.47	87	2.06	129	14.51
	D_gr	16.92	87	9.14	50	8.67	146	2.67
	D_bl	13.80	233	12.50	58	11.77	50	0.43
	D_vi	14.65	29	13.32	58	13.23	204	0.41
	D_tu	14.20	50	12.53	93	10.95	204	0.54

Slika 6.11 b)

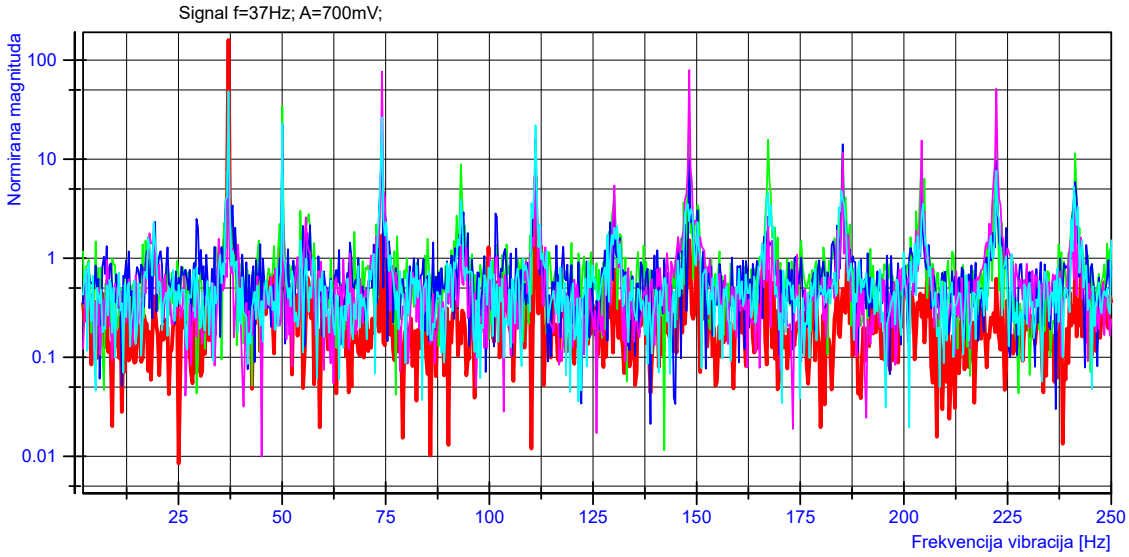

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det.	159.26	37	6.59	111	2.22	50	13.83
	D_gr	34.27	50	28.50	148	19.80	74	0.80
	D_bl	22.66	50	21.41	74	16.04	111	0.25
	D_vi	79.49	148	76.63	74	51.30	222	0.16
	D_tu	48.42	37	26.33	74	22.88	50	2.65

Slika 6.11 c)

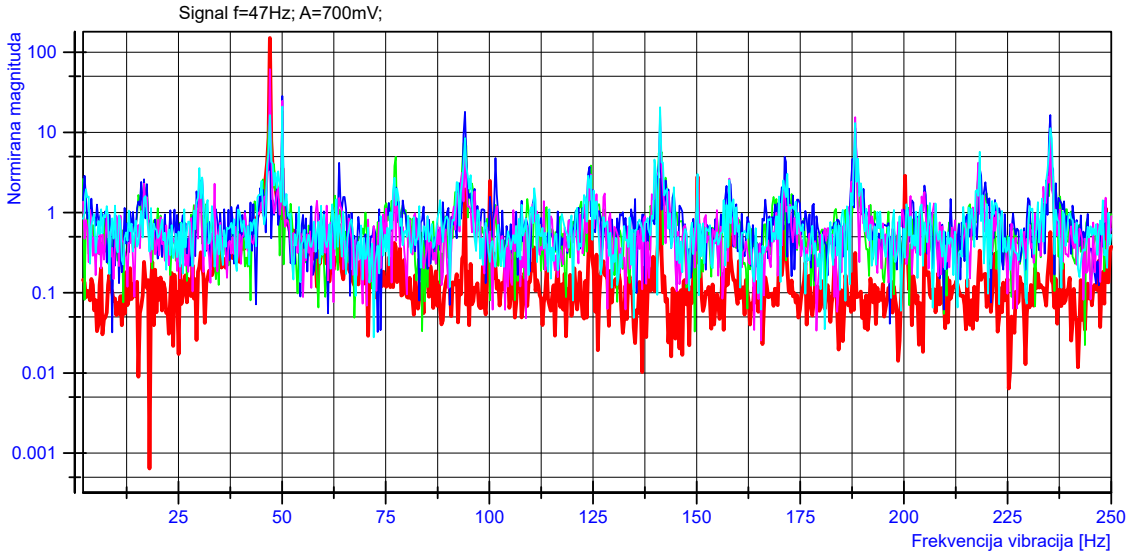

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det.	150.45	47	3.57	50	2.89	200	16.25
	D_gr	18.55	50	16.81	47	8.70	94	0.43
	D_bl	28.40	50	18.00	94	16.53	235	1.98
	D_vi	61.65	47	24.82	50	16.39	141	3.95
	D_tu	21.00	50	20.62	141	16.52	47	0.08

Slika 6.11 d)

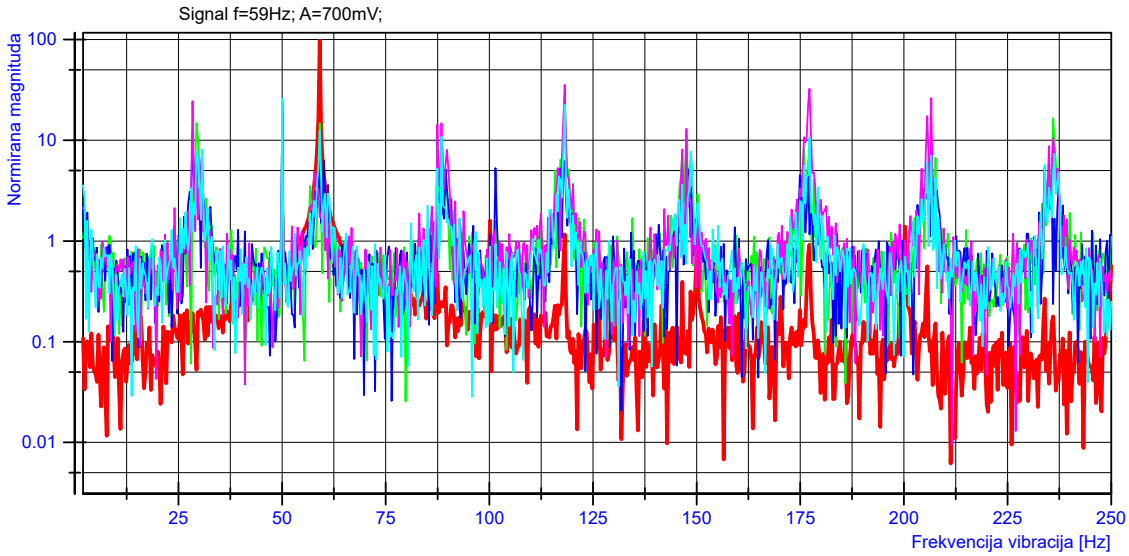

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det.	97.56	59	1.73	50	1.59	100	17.51
	D_gr	25.75	118	21.26	50	16.55	236	0.83
	D_bl	23.92	50	11.59	28	9.18	207	3.15
	D_vi	35.44	118	32.48	177	26.25	207	0.38
	D_tu	25.97	50	22.56	118	12.64	59	0.61

Slika 6.11 e)

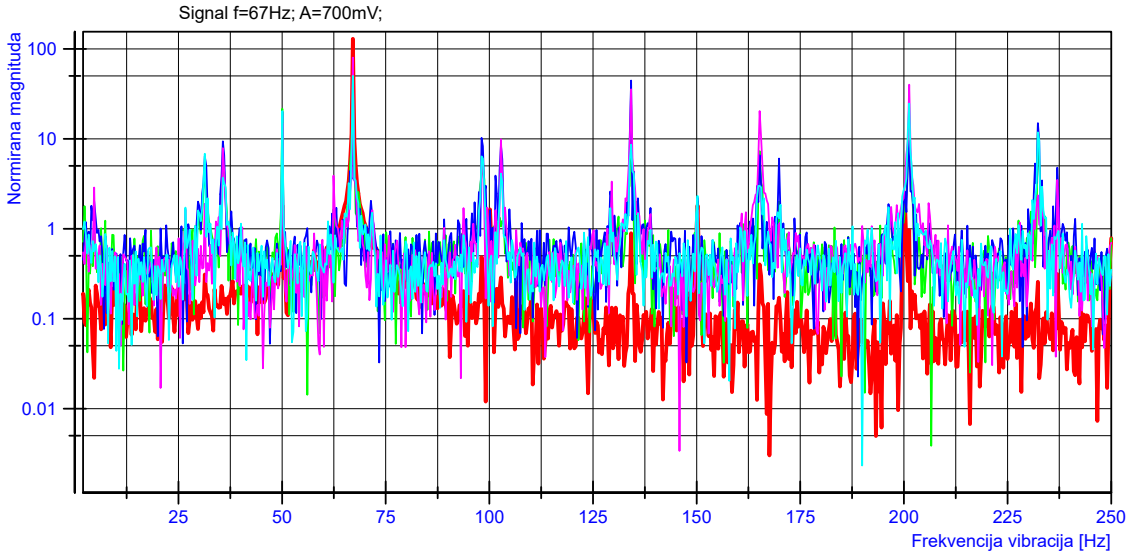

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det.	129.62	67	1.83	200	1.83	50	18.50
	D_gr	45.76	67	23.82	134	21.66	50	2.84
	D_bl	44.53	134	20.08	50	19.01	67	3.46
	D_vi	80.32	67	39.97	201	35.54	134	3.03
	D_tu	49.99	67	24.74	201	20.32	50	3.05

Slika 6.11 f)

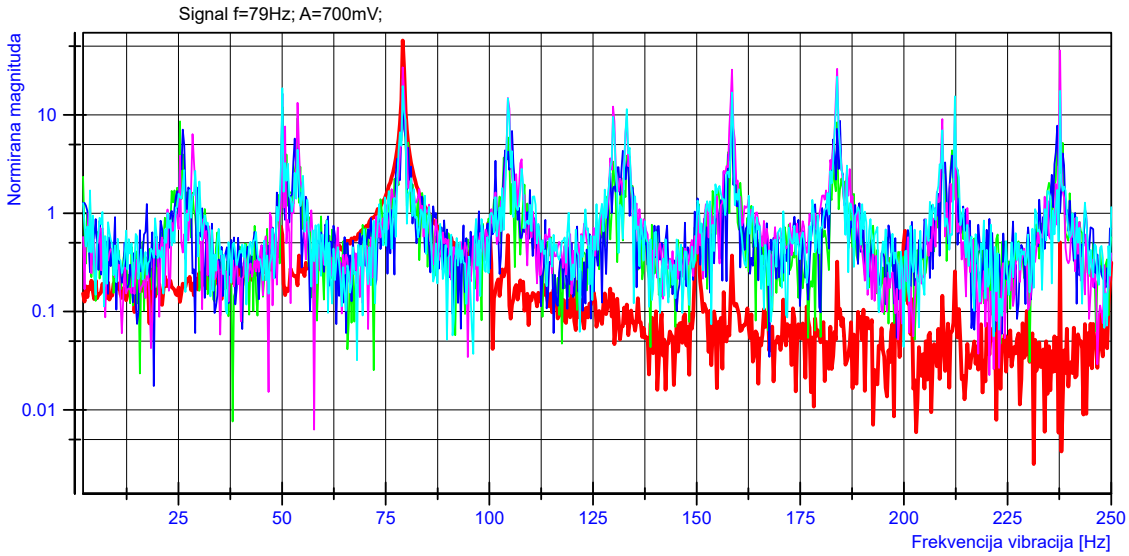

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det.	57.20	79	1.11	73	0.81	100	17.12
	D_gr	23.46	79	12.12	50	11.77	159	2.87
	D_bl	18.49	79	16.52	50	8.72	185	0.49
	D_vi	45.37	238	30.53	79	29.46	184	1.72
	D_tu	24.49	184	19.67	79	18.66	50	0.95

Slika 6.11 g)

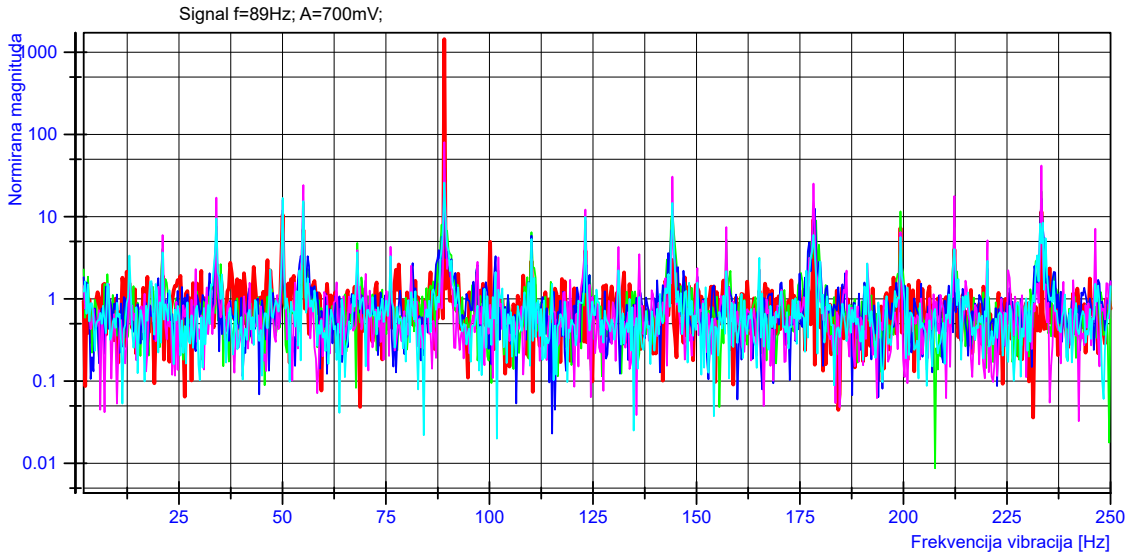

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det.	1441.98	89	11.52	233	10.58	50	20.98
	D_gr	30.43	89	20.37	233	14.98	55	1.74
	D_bl	38.94	89	16.63	233	12.56	179	3.70
	D_vi	80.29	89	42.02	233	30.80	144	2.81
	D_tu	26.00	89	16.92	50	15.50	55	1.87

Slika 6.11 h)

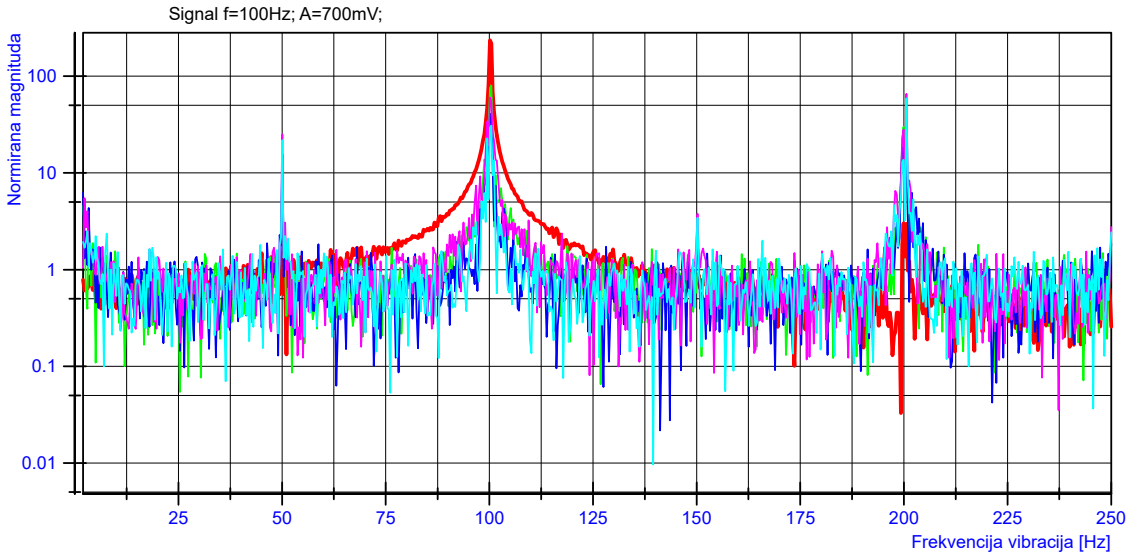

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det.	234.78	100	5.57	93	5.07	108	16.25
	D_gr	79.96	100	29.94	200	26.70	201	4.27
	D_bl	40.95	100	20.76	201	19.29	1	2.95
	D_vi	65.80	201	60.18	100	33.89	99	0.39
	D_tu	59.02	201	30.87	100	22.72	99	2.81

Slika 6.11 i)

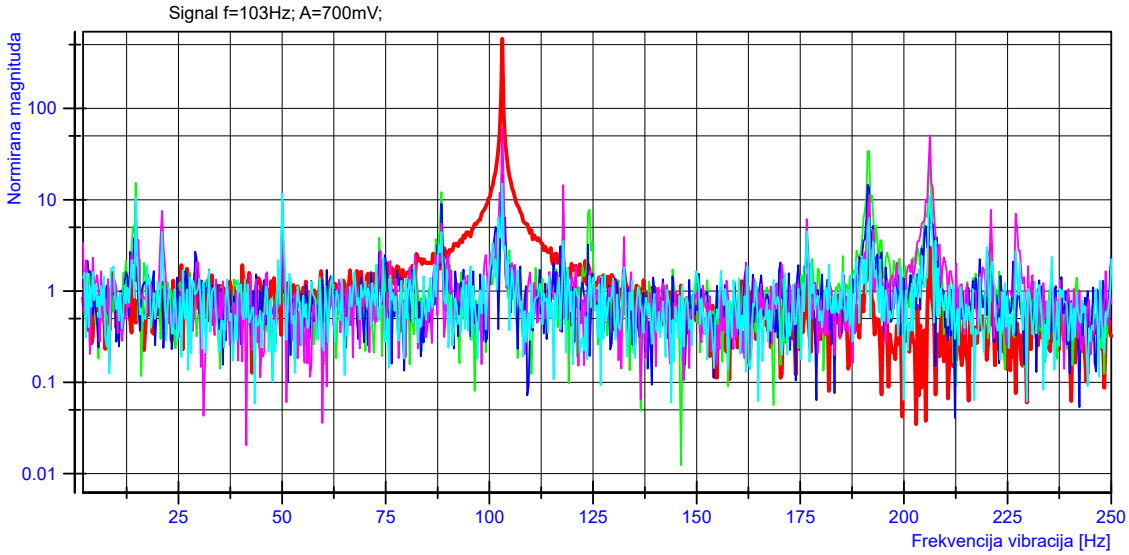

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det.	578.25	103	5.42	96	4.64	110	20.28
	D_gr	34.09	192	31.71	206	30.79	103	0.31
	D_bl	18.66	103	14.63	191	9.33	50	1.06
	D_vi	59.84	103	50.94	206	14.49	118	0.70
	D_tu	15.10	103	11.60	50	10.88	206	1.15

Slika 6.11 j)

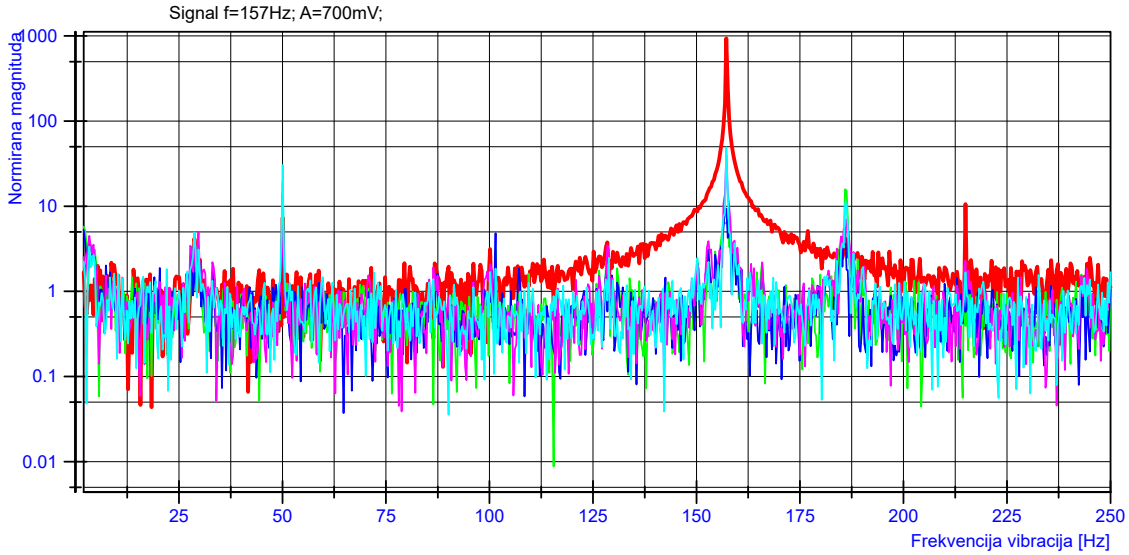

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det.	934.90	157	10.61	215	9.95	164	19.45
	D_gr	19.27	50	15.89	186	10.29	1	0.84
	D_bl	13.71	50	9.40	157	8.84	2	1.64
	D_vi	40.39	157	13.93	50	7.65	2	4.62
	D_tu	49.18	157	30.46	50	10.88	186	2.08

Spektar signala proračunatog statističkim metodama

Slika 6.11 k)

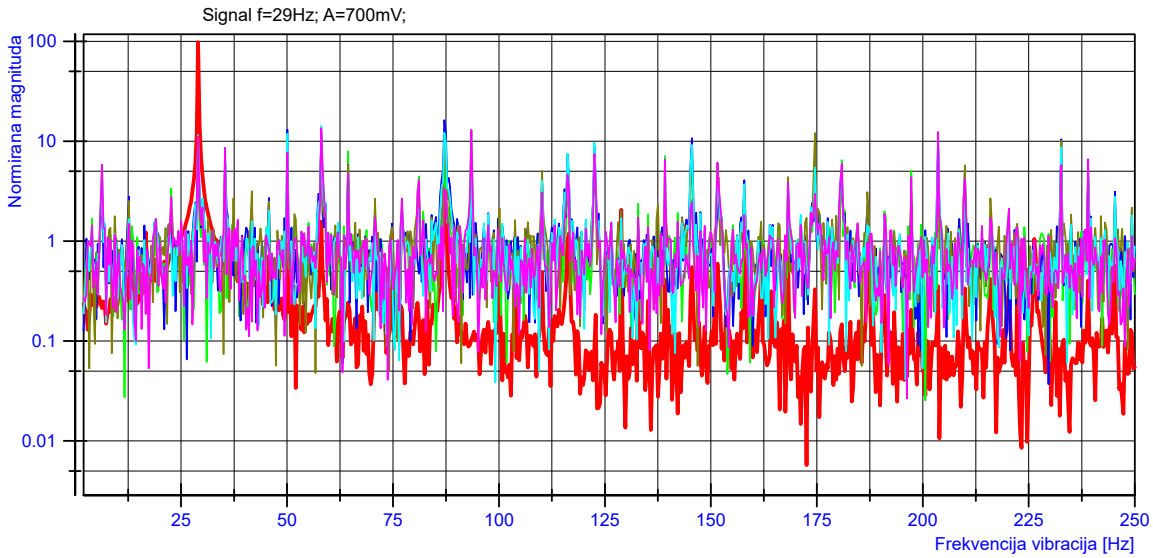

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det	98.01	29	3.47	87	2.06	129	14.51
	Correlation	12.87	93	11.88	58	10.85	29	0.35
	Corr. Ef.	16.21	87	13.03	50	11.73	58	0.95
	SumDiff	12.12	175	11.49	29	11.15	58	0.23
	PfPPD	14.17	58	12.30	204	12.18	87	0.61
	Mom.Ef1	13.45	58	12.98	93	12.34	204	0.15

Slika 6.11 l)

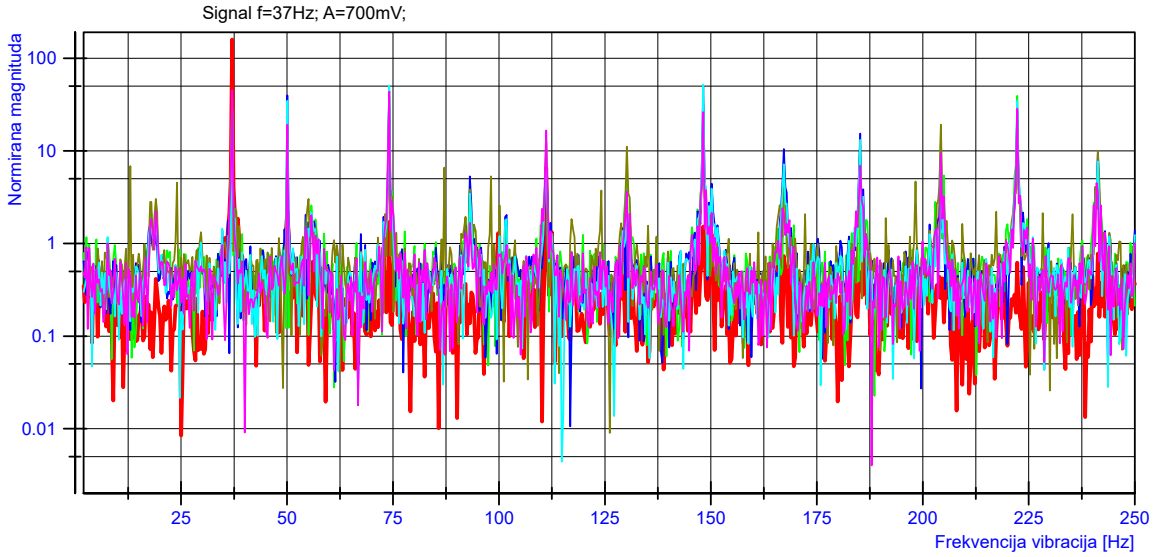

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det	159.26	37	6.59	111	2.22	50	13.83
	Correlation	46.00	74	39.28	222	37.03	37	0.69
	Corr. Ef.	50.00	148	44.08	74	39.73	50	0.55
	SumDiff	38.66	74	30.58	148	22.14	222	1.02
	PfPPD	52.01	148	50.91	74	34.68	50	0.09
	Mom.Ef1	45.35	37	43.52	74	28.58	222	0.18

Slika 6.11 m)

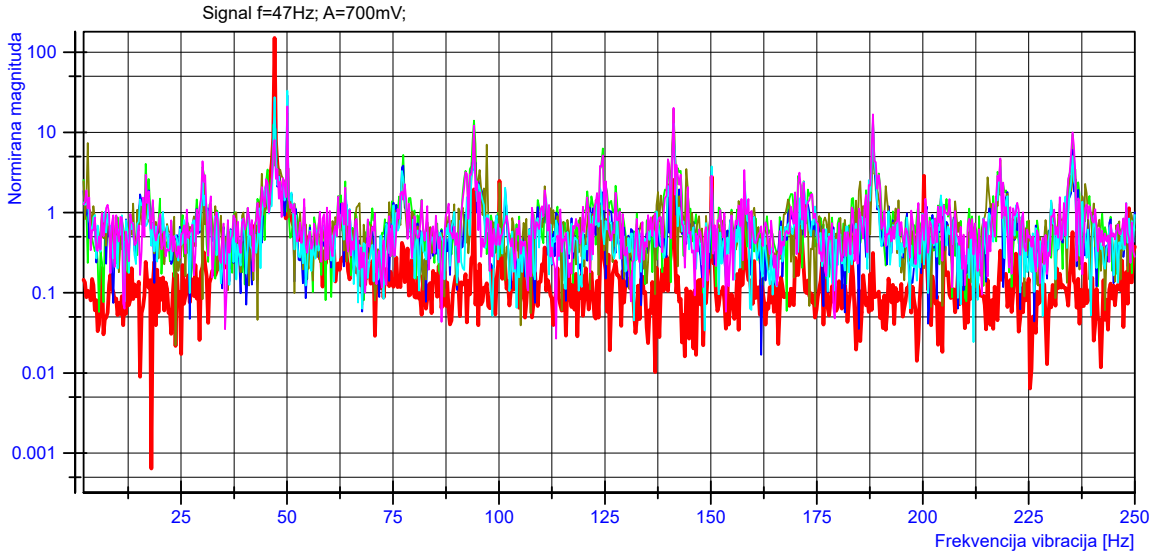

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det	150.45	47	3.57	50	2.89	200	16.25
	Correlation	14.21	188	14.02	94	12.50	47	0.06
	Corr. Ef.	29.02	50	24.11	47	11.54	188	0.81
	SumDiff	19.77	141	19.03	47	17.44	50	0.17
	PfPPD	33.06	50	27.54	47	14.19	188	0.79
	Mom.Ef1	21.14	50	20.27	141	16.78	188	0.18

Slika 6.11 n)

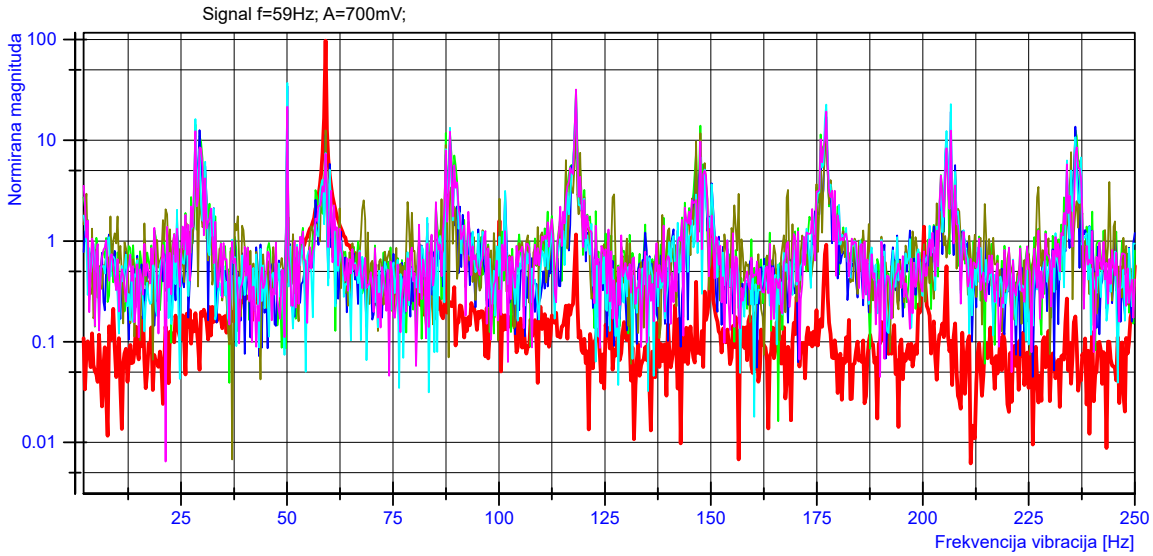

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det	97.56	59	1.73	50	1.59	100	17.51
	Correlation	31.16	118	17.08	177	14.36	28	2.61
	Corr. Ef.	34.55	50	23.54	118	19.22	207	1.67
	SumDiff	20.06	50	13.83	118	13.04	177	1.62
	PfPPD	37.18	50	28.04	118	22.86	207	1.23
	Mom.Ef1	31.95	118	21.50	50	19.33	177	1.72

Slika 6.11 o)

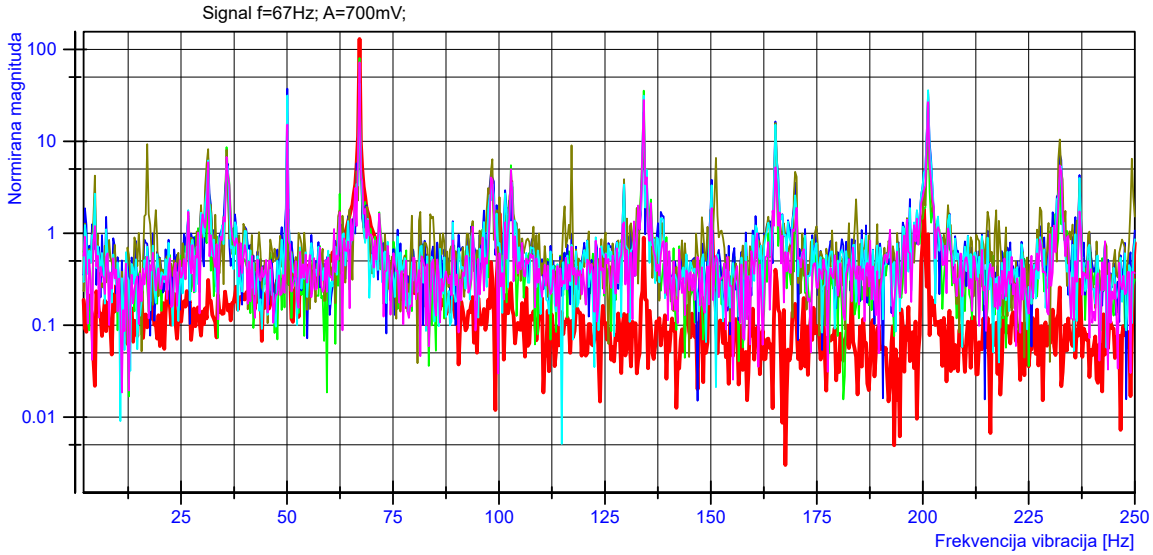

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det	129.62	67	1.83	200	1.83	50	18.50
	Correlation	80.50	67	35.38	134	20.54	201	3.57
	Corr. Ef.	37.25	50	34.09	201	20.80	134	0.38
	SumDiff	32.52	201	19.46	67	18.60	134	2.23
	PfPPD	42.50	67	36.00	201	31.51	50	0.72
	Mom.Ef1	72.14	67	28.17	134	26.71	201	4.08

Slika 6.11 p)

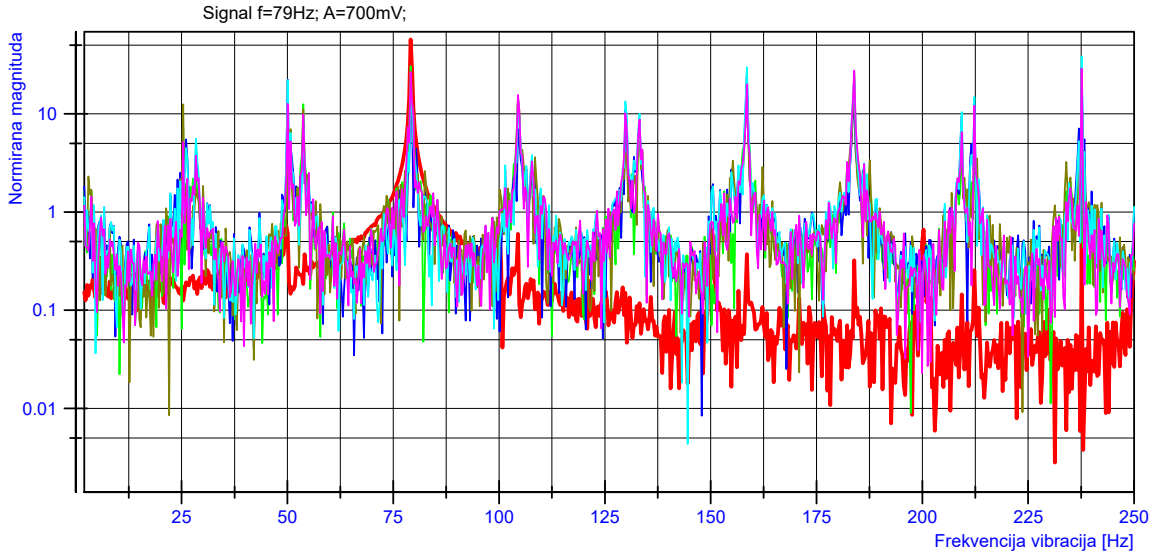

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det	57.20	79	1.11	73	0.81	100	17.12
	Correlation	30.53	79	26.96	238	25.95	184	0.54
	Corr. Ef.	29.76	238	25.93	159	22.25	50	0.60
	SumDiff	26.98	79	25.88	238	21.95	184	0.18
	PfPPD	38.38	238	29.82	159	23.31	184	1.10
	Mom.Ef1	28.77	238	27.56	184	26.60	79	0.19

Slika 6.11 q)

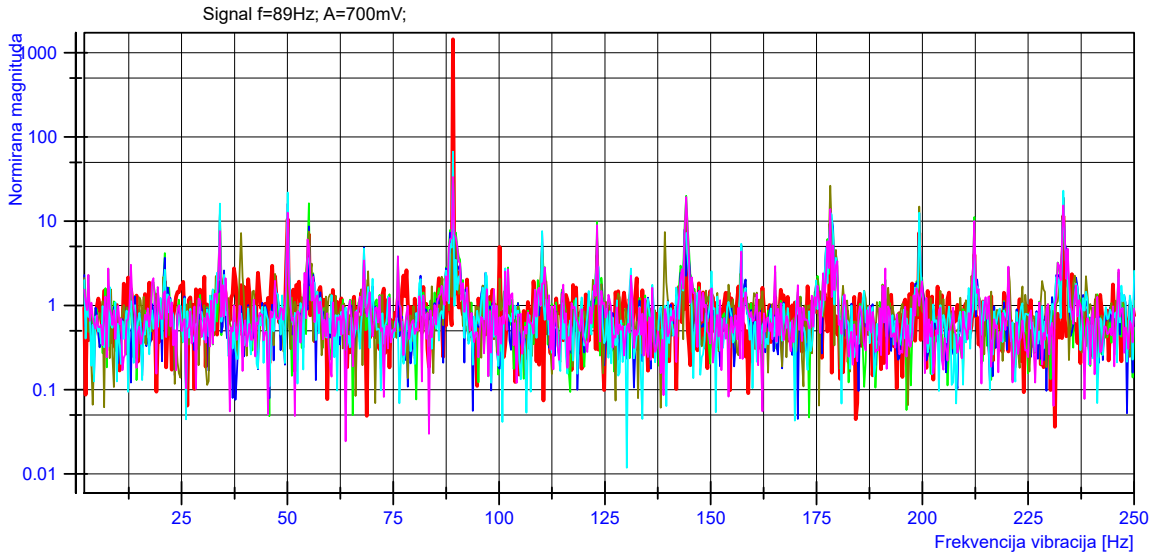

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det	1441.98	89	11.52	233	10.58	50	20.98
	Correlation	23.98	89	20.04	144	19.18	233	0.78
	Corr. Ef.	49.54	89	19.12	233	16.20	50	4.13
	SumDiff	45.16	89	26.44	178	17.87	233	2.32
	PfPPD	66.85	89	22.97	233	21.92	50	4.64
	Mom.Ef1	33.53	89	19.36	144	15.40	233	2.39

Slika 6.11 r)

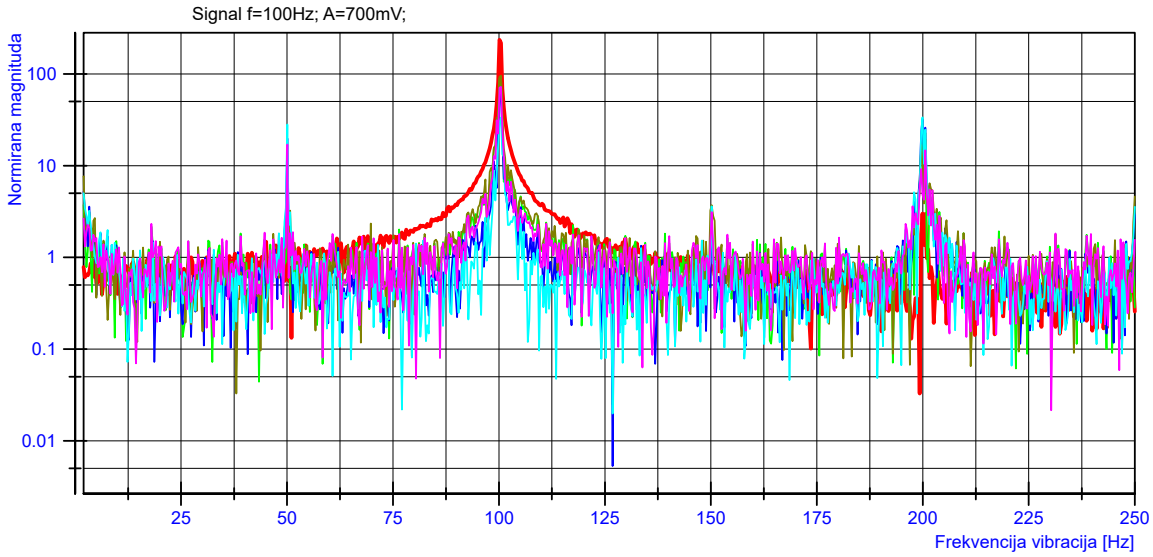

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det	234.78	100	5.57	93	5.07	108	16.25
	Correlation	92.44	100	22.90	201	18.59	200	6.06
	Corr. Ef.	59.66	100	32.27	200	26.01	201	2.67
	SumDiff	95.79	100	33.52	99	19.48	201	4.56
	PfPPD	33.66	200	33.44	100	28.06	50	0.03
	Mom.Ef1	72.10	100	31.18	99	16.99	50	3.64

Slika 6.11 s)

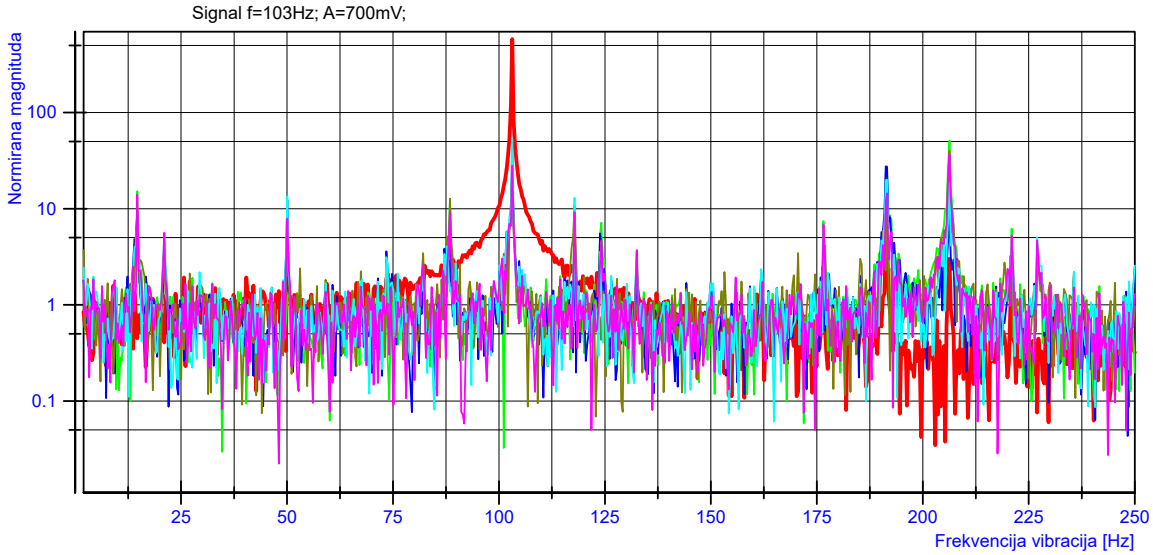

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det	578.25	103	5.42	96	4.64	110	20.28
	Correlation	51.26	206	24.23	192	22.37	103	3.25
	Corr. Ef.	46.07	103	27.56	191	12.37	50	2.23
	SumDiff	40.26	206	27.25	103	12.70	88	1.70
	PfPPD	53.33	103	20.00	192	18.36	206	4.26
	Mom.Ef1	37.06	206	27.95	103	14.41	192	1.23

Slika 6.11 t)

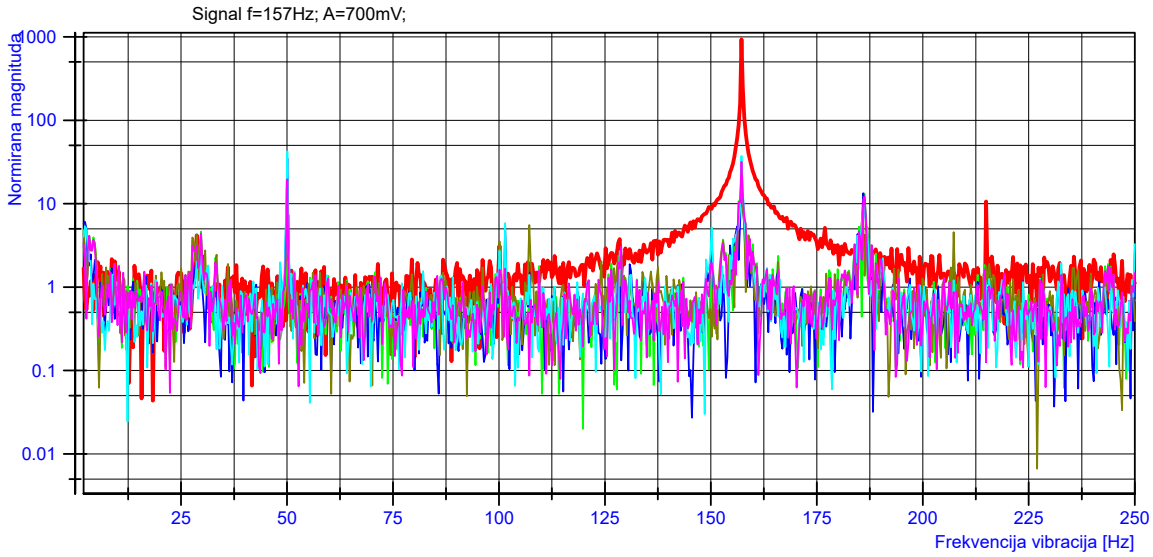

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det	934.90	157	10.61	215	9.95	164	19.45
	Correlation	18.86	157	13.75	1	13.27	186	1.37
	Corr. Ef.	35.12	50	23.07	157	13.37	186	1.83
	SumDiff	25.04	157	7.17	186	5.62	2	5.43
	PfPPD	42.36	50	37.37	157	9.60	186	0.54
	Mom.Ef1	31.84	157	19.71	50	12.26	186	2.08

6.3.2 Velike detektorske diode i jako višemodno vlakno

Rezultati prikazani na slikama ovog odjeljka pokazuju nešto bolju situaciju od prethodno prezentiranih rezultata. Detekcija je neznatno pouzdanija i za frekvencije niže od 89 Hz, ali su i dalje jako izraženi višestruki harmonici osnovne frekvencije koji često imaju veću amplitudu od osnovne komponente signala. Navedeno je, sigurno barem djelomično, posljedica parcijalnih mehaničkih vibracija (pobude vlastitih frekvencija) komada vlakna koje ostvaruje spregu s mehaničkim vibratorom. Kako cijelo vlakno djeluje kao senzor (integriranog tipa), svaka pojava vibracija na bilo kojem njegovom dijelu se manifestira na odzivnom signalu sustava.

S obzirom na sve navedeno, nemoguće je doći do konkretnijih zaključaka o boljim ili lošijim statističkim metodama proračuna za ovu testiranu konfiguraciju.

Spektar signala s detektorskih dioda

Slika 6.12 a)

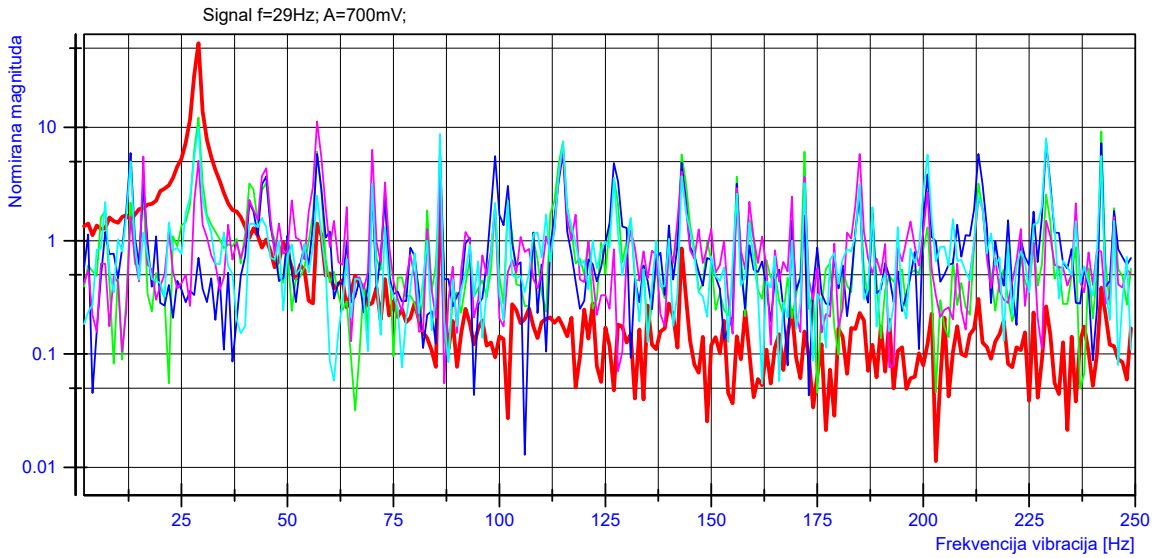

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det.	55.38	29	2.50	86	1.68	12	13.45
	D_gr	12.19	29	9.20	242	7.52	115	1.22
	D_bl	7.27	229	7.25	242	6.62	86	0.01
	D_vi	11.29	57	6.49	115	6.33	70	2.40
	D_tu	10.03	29	8.76	86	8.03	229	0.59

Slika 6.12 b)

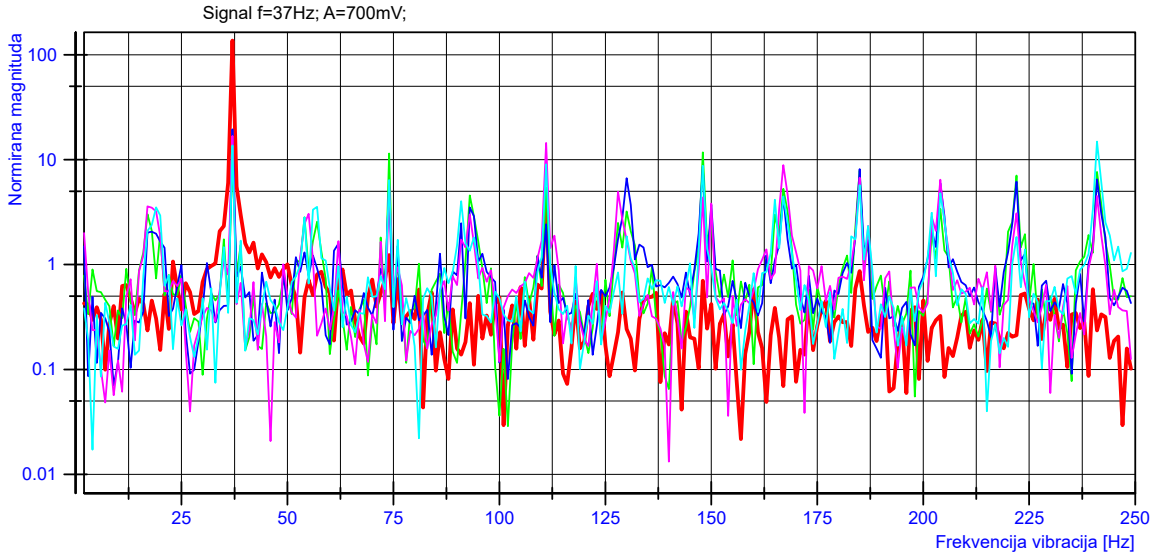

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det.	136.58	37	4.47	111	1.62	42	14.85
	D_gr	11.74	148	11.44	74	10.23	37	0.11
	D_bl	19.44	37	8.65	148	8.14	185	3.52
	D_vi	16.80	37	14.47	111	8.87	167	0.65
	D_tu	14.86	241	13.69	37	9.03	111	0.36

Slika 6.12 c)

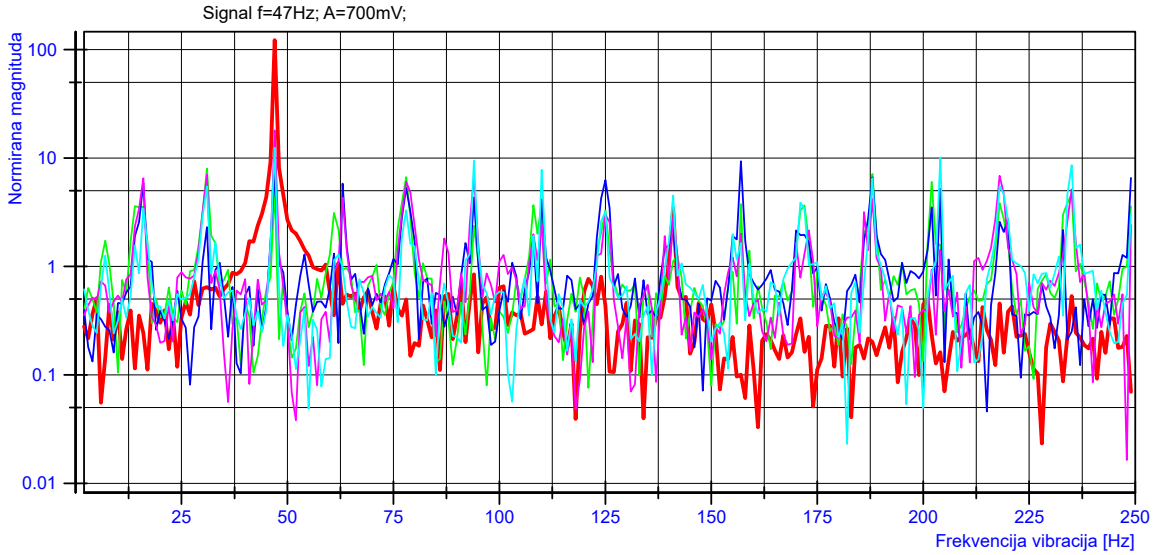

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det.	122.09	47	3.43	141	1.71	41	15.51
	D_gr	8.01	31	7.12	188	6.68	78	0.51
	D_bl	9.36	157	7.14	47	6.63	188	1.18
	D_vi	17.95	47	7.00	31	6.88	218	4.09
	D_tu	12.43	47	10.13	204	9.46	94	0.89

Slika 6.12 d)

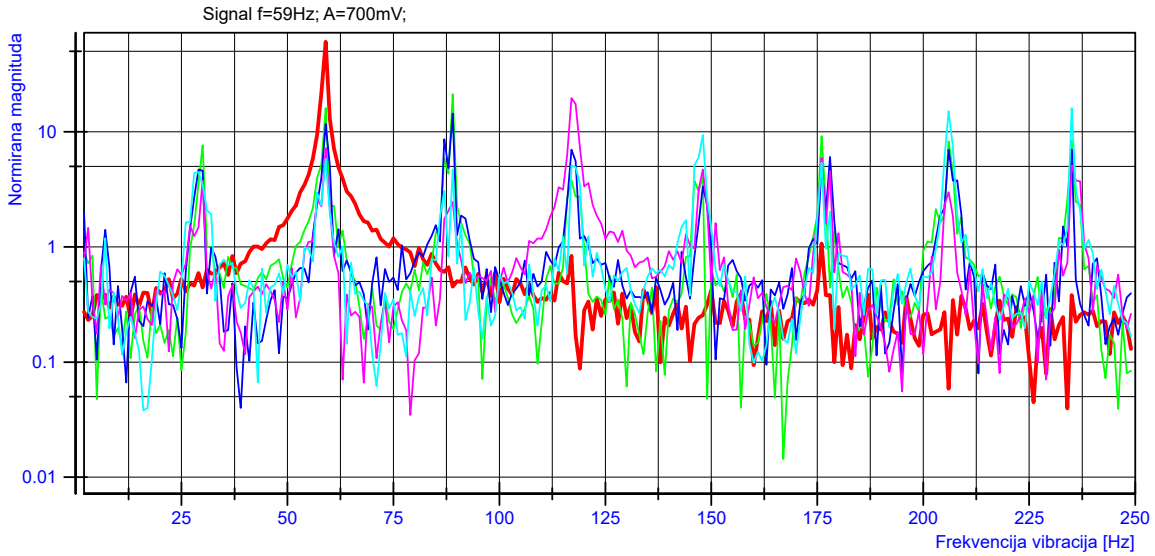

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det.	60.44	59	1.41	71	1.19	75	16.32
	D_gr	21.22	89	16.04	59	9.14	176	1.22
	D_bl	14.41	89	11.66	59	8.61	87	0.92
	D_vi	19.57	117	7.22	59	5.95	176	4.33
	D_tu	16.00	235	15.06	206	9.40	148	0.26

Slika 6.12 e)

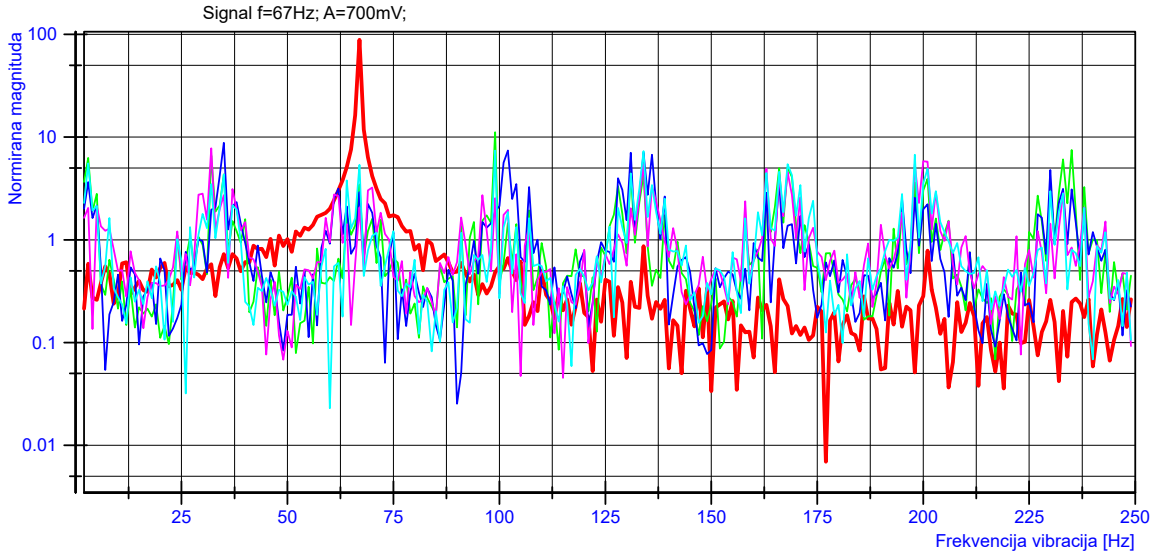

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det.	88.59	67	1.74	75	1.31	54	17.07
	D_gr	11.15	99	7.49	235	6.60	32	1.73
	D_bl	8.81	35	7.38	102	7.10	134	0.77
	D_vi	7.79	32	5.82	200	5.43	134	1.27
	D_tu	7.38	99	7.32	134	6.72	198	0.04

Slika 6.12 f)

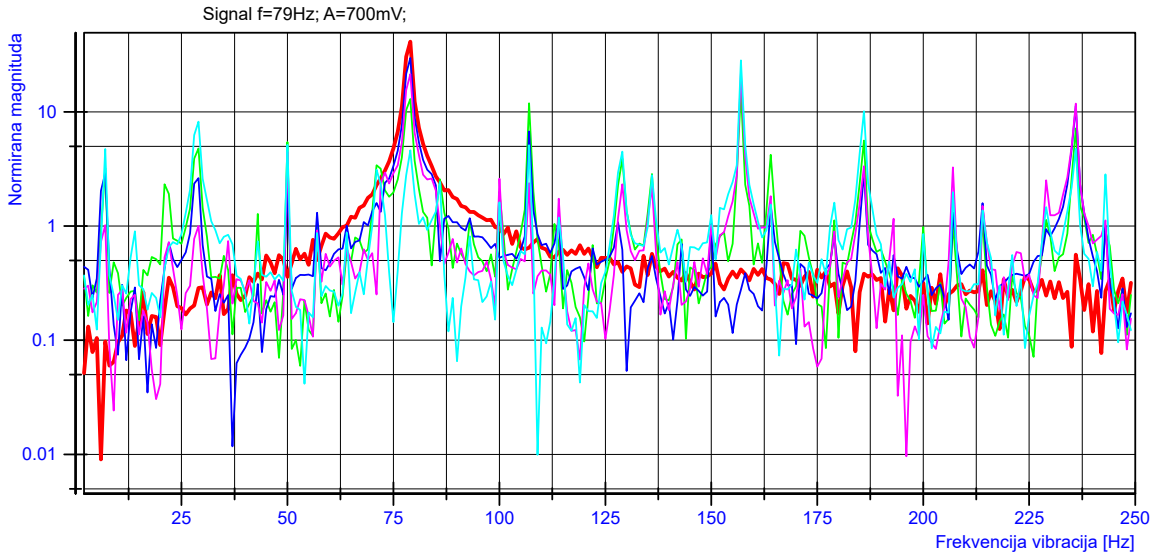

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det.	41.20	79	2.07	88	1.21	65	12.99
	D_gr	15.26	157	12.97	79	11.93	107	0.71
	D_bl	29.69	79	11.33	236	6.74	107	4.18
	D_vi	21.99	157	21.42	79	11.85	236	0.11
	D_tu	28.29	157	10.14	186	8.21	29	4.46

Slika 6.12 g)

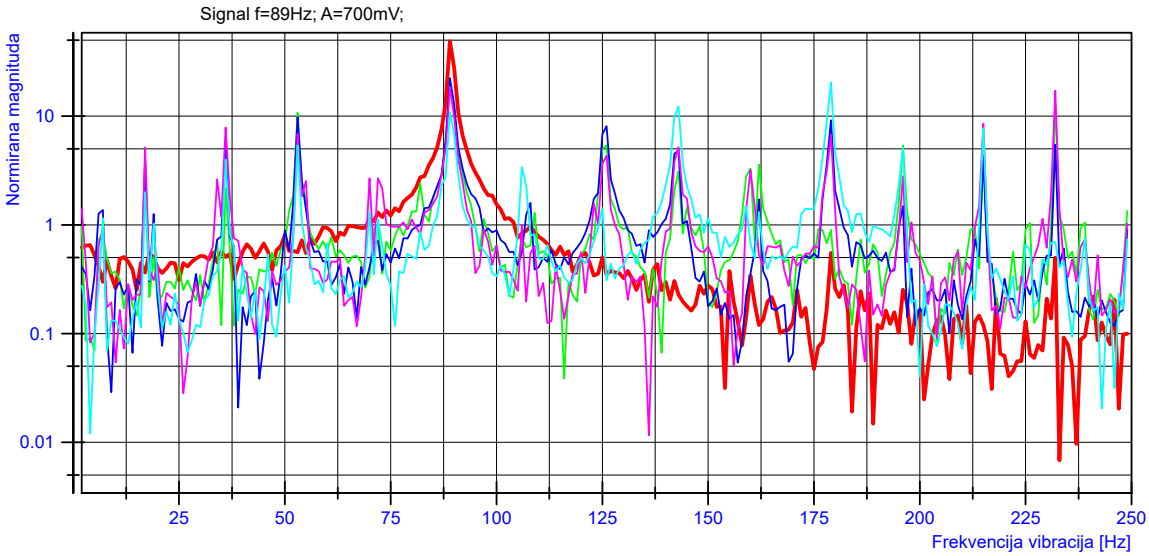

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det.	48.77	89	1.42	76	1.36	74	15.36
	D_gr	20.55	89	12.84	232	10.72	53	2.04
	D_bl	22.29	89	9.80	53	9.18	179	3.57
	D_vi	18.62	89	17.16	232	8.52	215	0.35
	D_tu	20.45	179	12.26	143	10.87	89	2.22

Slika 6.12 h)

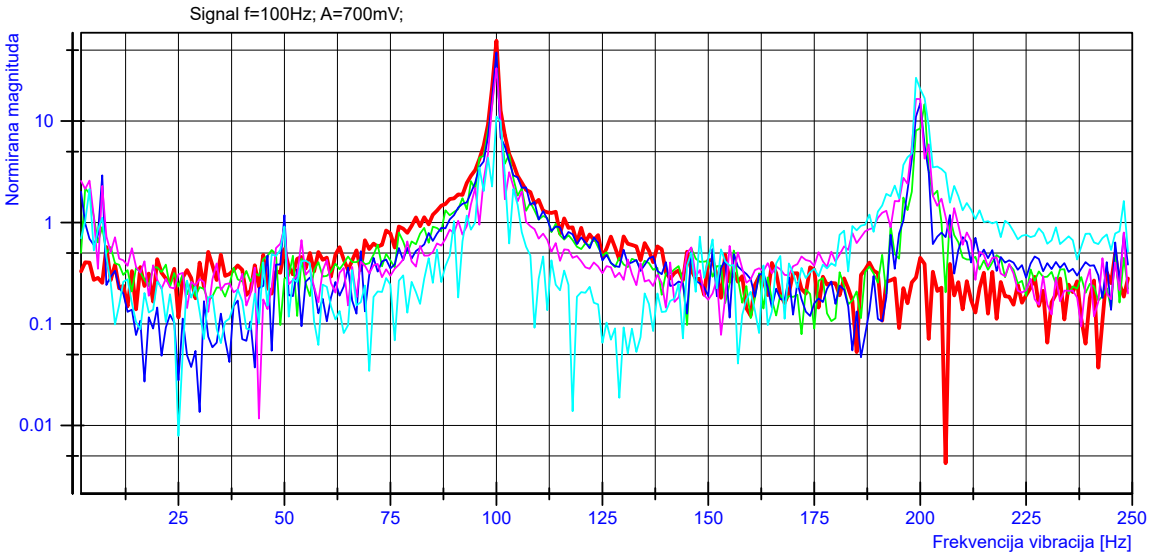

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det.	61.86	100	1.89	91	1.67	110	15.15
	D_gr	43.23	100	14.69	201	4.69	103	4.69
	D_bl	47.38	100	14.94	200	2.92	7	5.01
	D_vi	33.13	100	16.49	199	5.85	202	3.03
	D_tu	26.68	199	11.07	100	4.33	98	3.82

Slika 6.12 i)

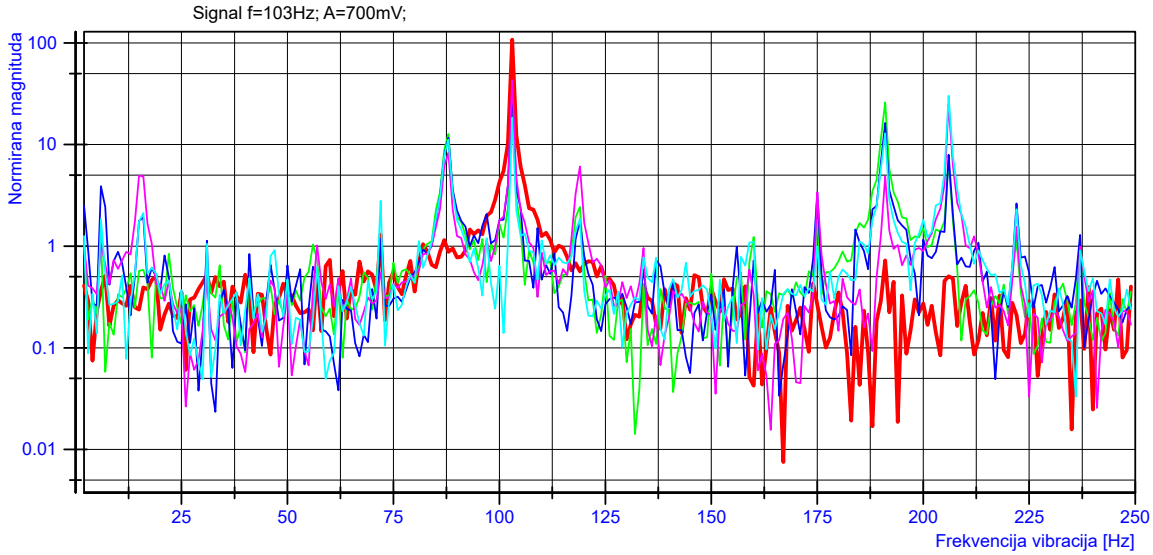

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det.	107.56	103	1.46	93	1.43	95	18.67
	D_gr	27.91	103	25.99	191	12.67	88	0.31
	D_bl	35.29	103	16.31	191	11.62	88	3.35
	D_vi	42.95	103	24.83	206	8.31	88	2.38
	D_tu	30.17	206	18.33	103	12.87	191	2.16

Slika 6.12 j)

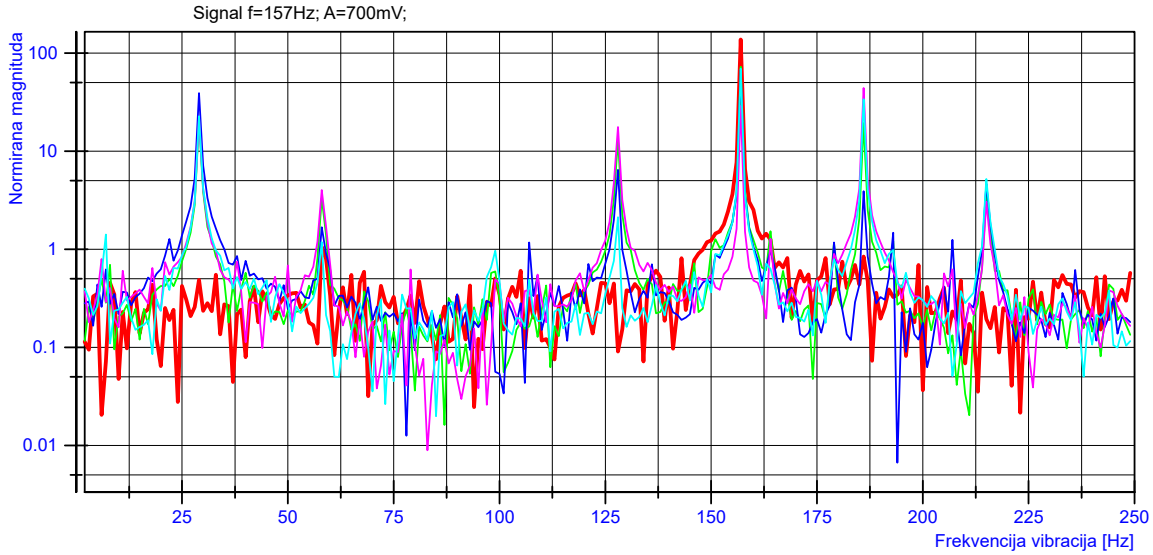

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det.	137.62	157	1.44	163	1.06	58	19.80
	D_gr	72.49	157	20.78	29	19.36	186	5.43
	D_bl	67.76	157	39.06	29	6.44	128	2.39
	D_vi	44.09	186	28.89	157	22.19	29	1.84
	D_tu	69.48	157	33.78	186	22.65	29	3.13

Spektar signala proračunatog statističkim metodama

Slika 6.12 k)

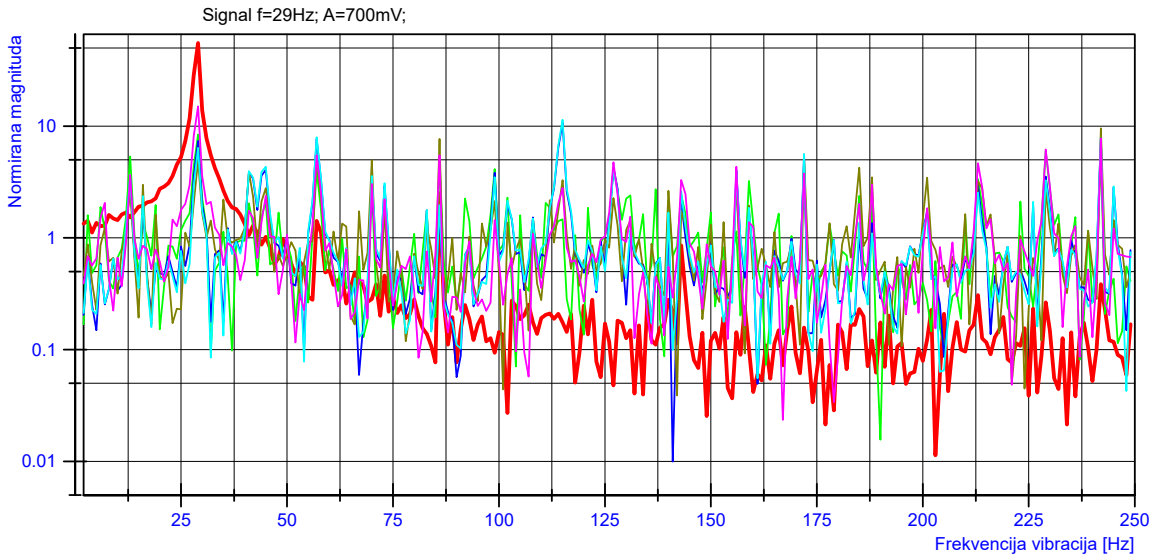

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det	55.38	29	2.50	86	1.68	12	13.45
	Correlation	8.40	29	6.16	242	5.98	229	1.35
	Corr. Ef.	10.74	115	8.00	242	7.64	57	1.28
	SumDiff	9.56	242	7.69	86	5.44	57	0.95
	PfPPD	11.43	115	7.93	57	7.76	242	1.59
	Mom.Ef1	15.00	29	7.74	242	6.18	229	2.87

Slika 6.12 l)

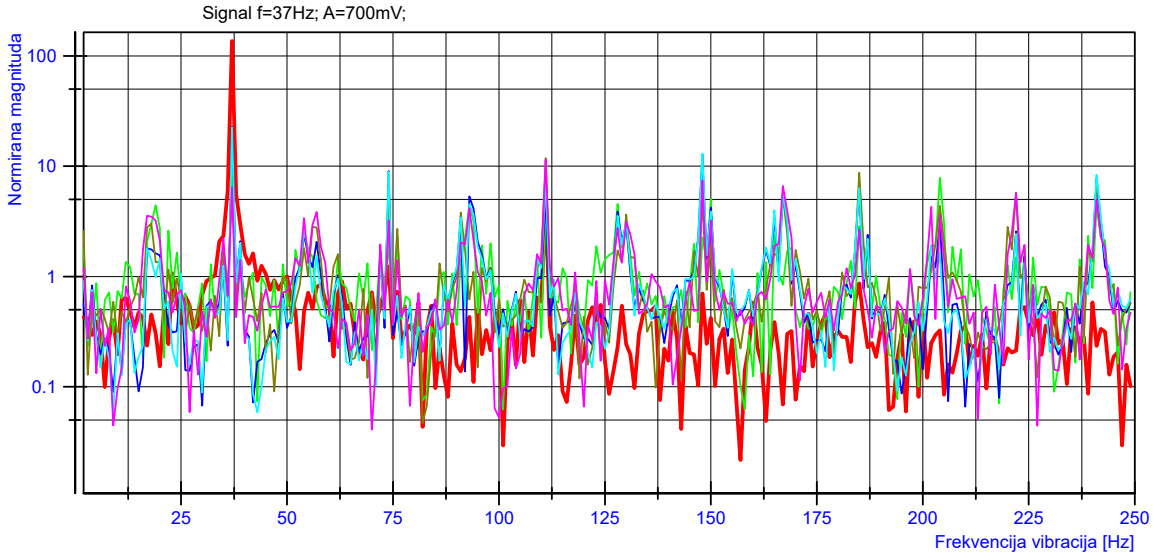

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det	136.58	37	4.47	111	1.62	42	14.85
	Correlation	7.85	204	6.00	37	5.06	150	1.17
	Corr. Ef.	22.81	37	12.77	148	9.06	74	2.52
	SumDiff	11.84	111	8.74	37	8.73	185	1.32
	PfPPD	22.52	37	13.03	148	8.91	74	2.38
	Mom.Ef1	11.39	111	7.42	148	6.64	167	1.86

Slika 6.12 m)

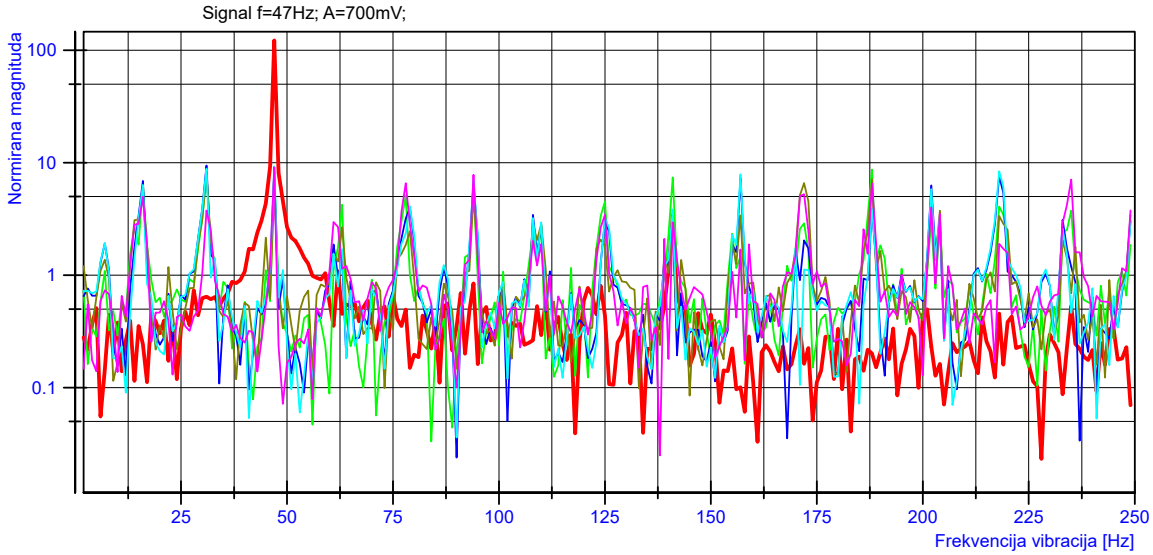

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det	122.09	47	3.43	141	1.71	41	15.51
	Correlation	8.80	47	8.68	188	7.97	31	0.06
	Corr. Ef.	9.47	31	8.34	47	7.59	218	0.55
	SumDiff	7.90	31	7.15	188	6.59	172	0.43
	PfPPD	9.26	47	8.84	31	8.40	218	0.20
	Mom.Ef1	9.12	47	7.82	94	7.09	235	0.67

Slika 6.12 n)

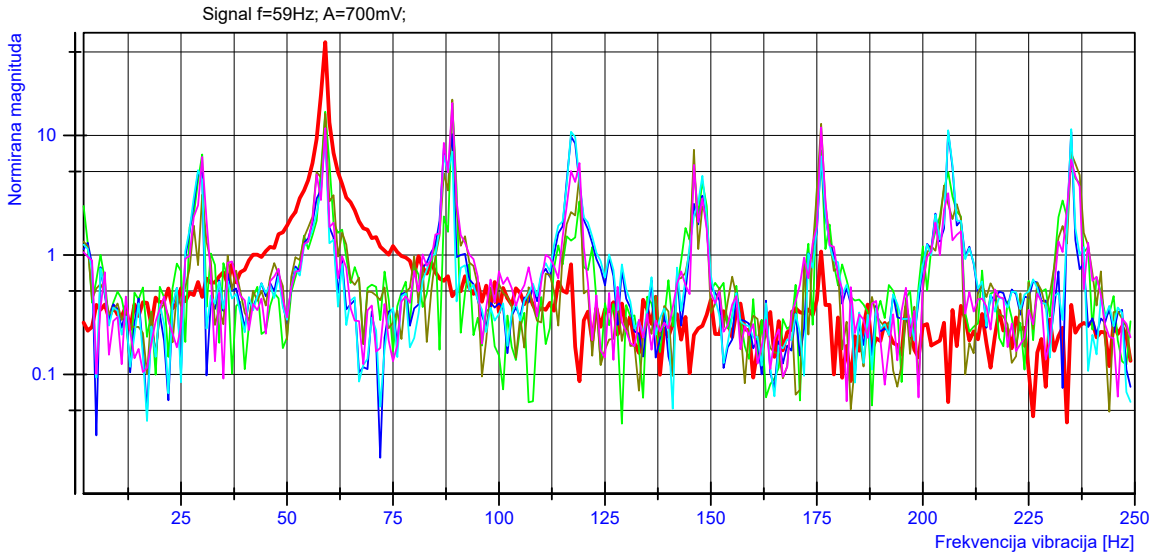

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det	60.44	59	1.41	71	1.19	75	16.32
	Correlation	18.72	89	15.81	59	7.52	176	0.73
	Corr. Ef.	11.07	59	10.78	206	10.72	235	0.12
	SumDiff	19.93	89	15.18	59	12.52	176	1.18
	PfPPD	11.29	235	11.04	206	10.74	117	0.10
	Mom.Ef1	18.71	89	11.65	176	11.54	59	2.06

Slika 6.12 o)

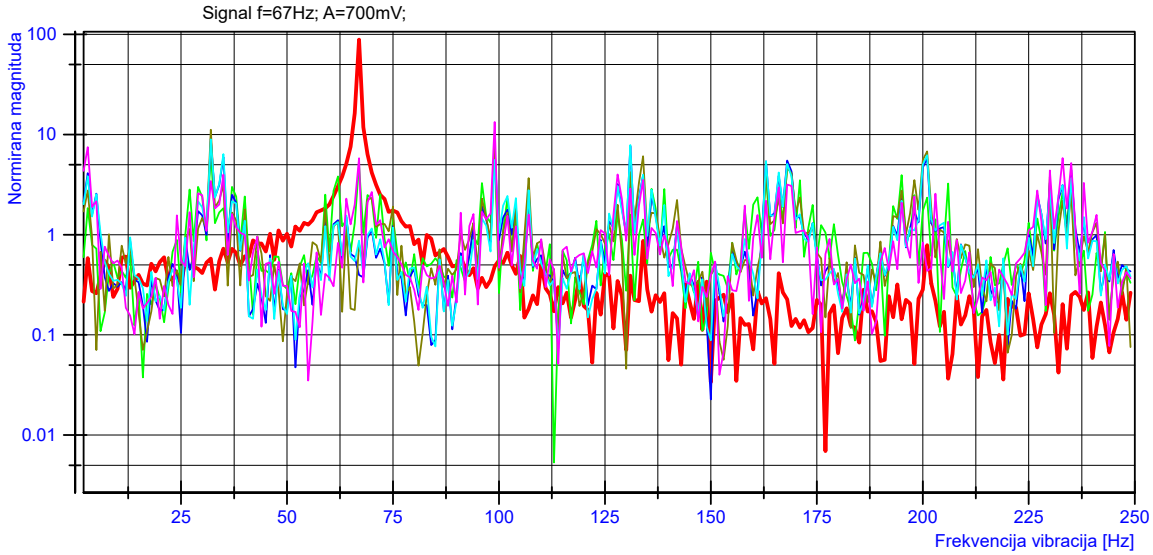

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det	88.59	67	1.74	75	1.31	54	17.07
	Correlation	8.26	99	6.98	32	5.02	67	0.73
	Corr. Ef.	9.08	32	7.65	131	7.12	99	0.74
	SumDiff	11.15	32	7.67	99	6.77	201	1.62
	PfPPD	8.95	32	7.85	131	6.38	35	0.57
	Mom.Ef1	13.36	99	7.47	3	5.83	233	2.52

Slika 6.12 p)

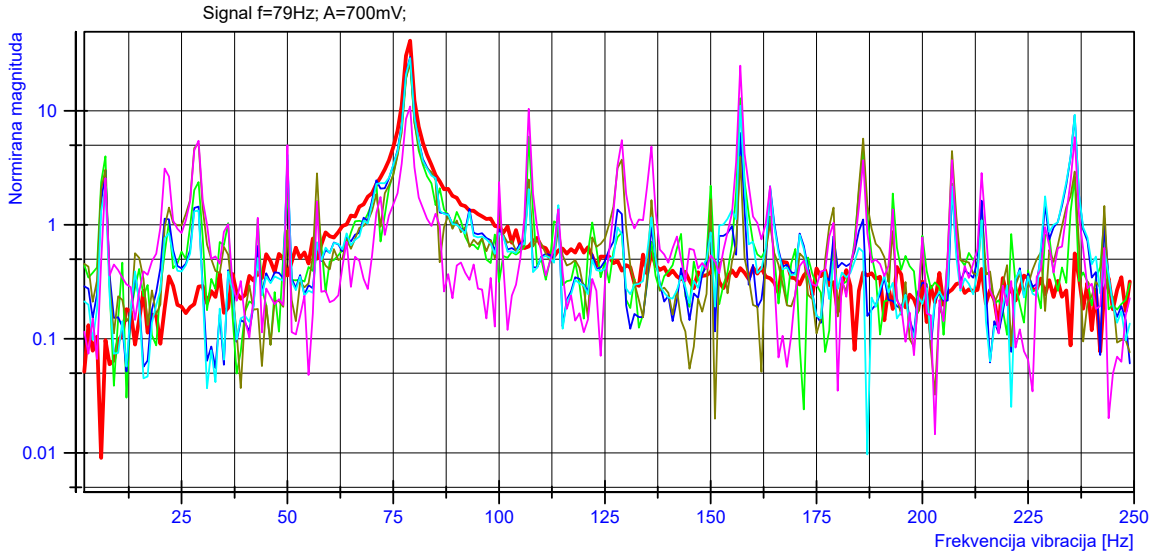

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det	41.20	79	2.07	88	1.21	65	12.99
	Correlation	26.94	79	12.91	157	5.95	107	3.19
	Corr. Ef.	29.63	79	9.15	236	6.38	157	5.10
	SumDiff	26.73	79	5.70	186	5.17	29	6.71
	PfPPD	29.02	79	11.10	157	9.24	236	4.17
	Mom.Ef1	24.93	157	10.94	79	10.40	107	3.58

Slika 6.12 q)

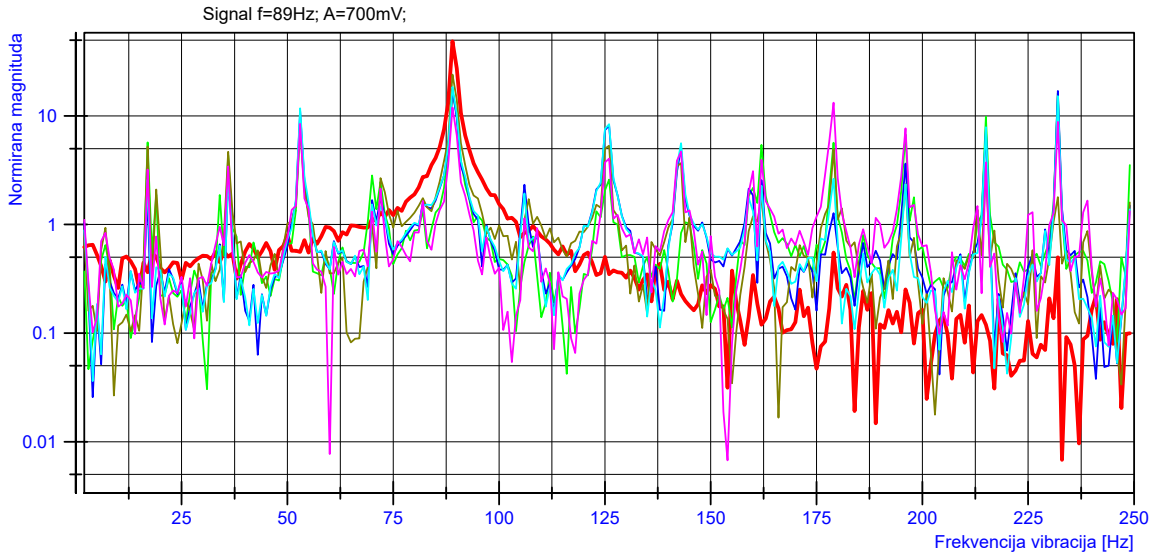

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det	48.77	89	1.42	76	1.36	74	15.36
	Correlation	17.19	89	16.32	232	9.82	215	0.23
	Corr. Ef.	17.20	89	16.98	232	11.06	53	0.06
	SumDiff	24.05	89	8.68	53	5.32	126	4.43
	PfPPD	18.47	89	15.24	232	11.74	53	0.83
	Mom.Ef1	13.28	179	11.95	89	8.82	232	0.46

Slika 6.12 r)

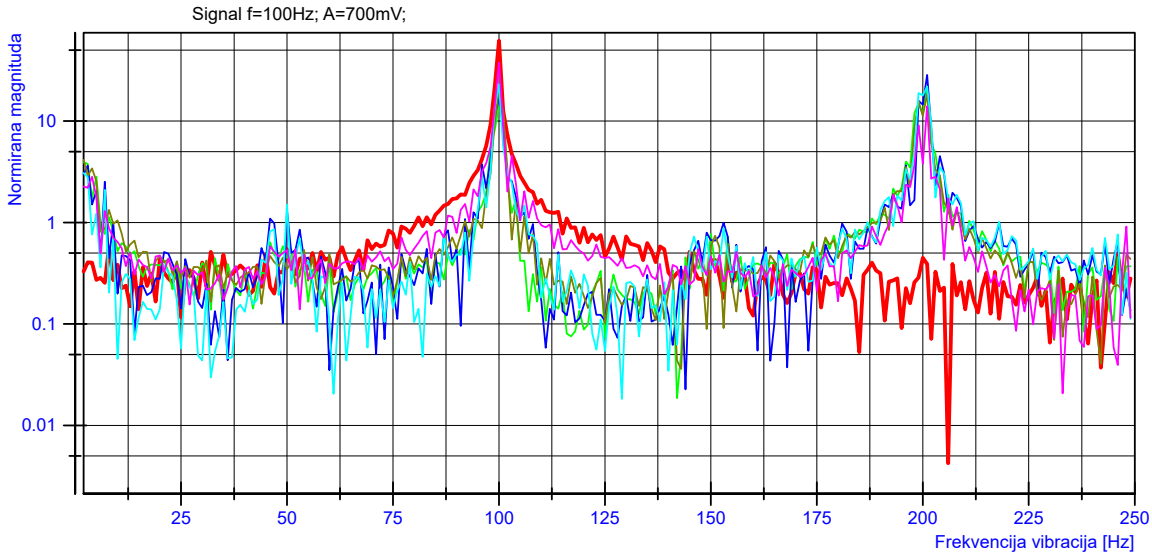

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det	61.86	100	1.89	91	1.67	110	15.15
	Correlation	21.76	201	14.80	199	13.98	100	1.67
	Corr. Ef.	28.44	201	17.36	100	15.82	199	2.14
	SumDiff	20.27	100	18.41	201	15.68	199	0.42
	PfPPD	23.07	100	21.93	201	18.83	199	0.22
	Mom.Ef1	37.63	100	13.99	201	9.05	199	4.30

Slika 6.12 s)

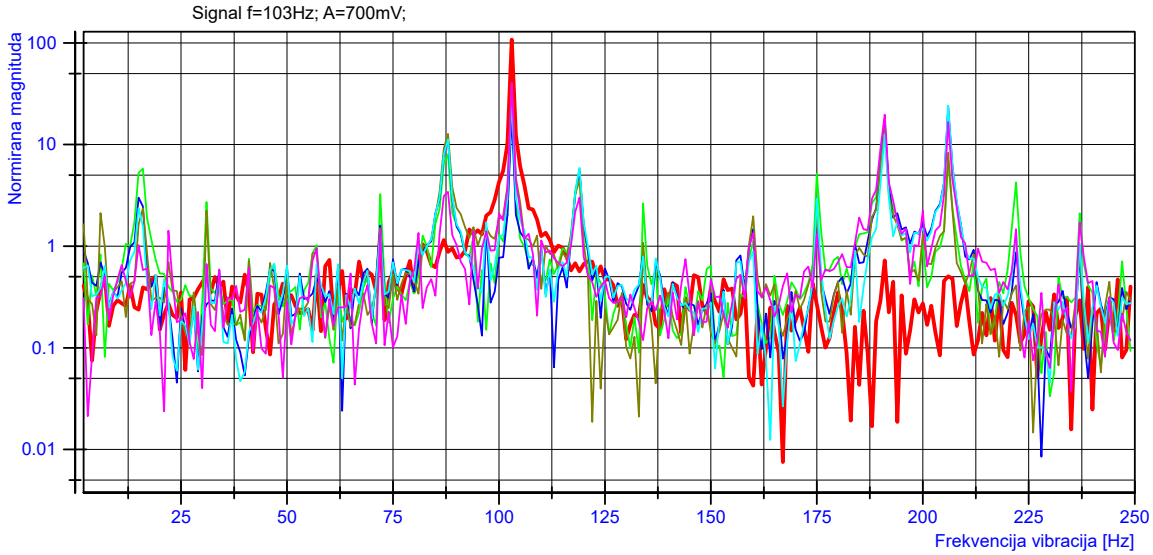

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det	107.56	103	1.46	93	1.43	95	18.67
	Correlation	25.16	103	18.02	191	8.01	88	1.45
	Corr. Ef.	23.49	206	20.14	103	16.40	191	0.67
	SumDiff	39.81	103	14.67	191	12.70	88	4.34
	PfPPD	28.47	103	24.19	206	12.58	191	0.71
	Mom.Ef1	40.55	103	19.68	191	16.62	206	3.14

Slika 6.12 t)

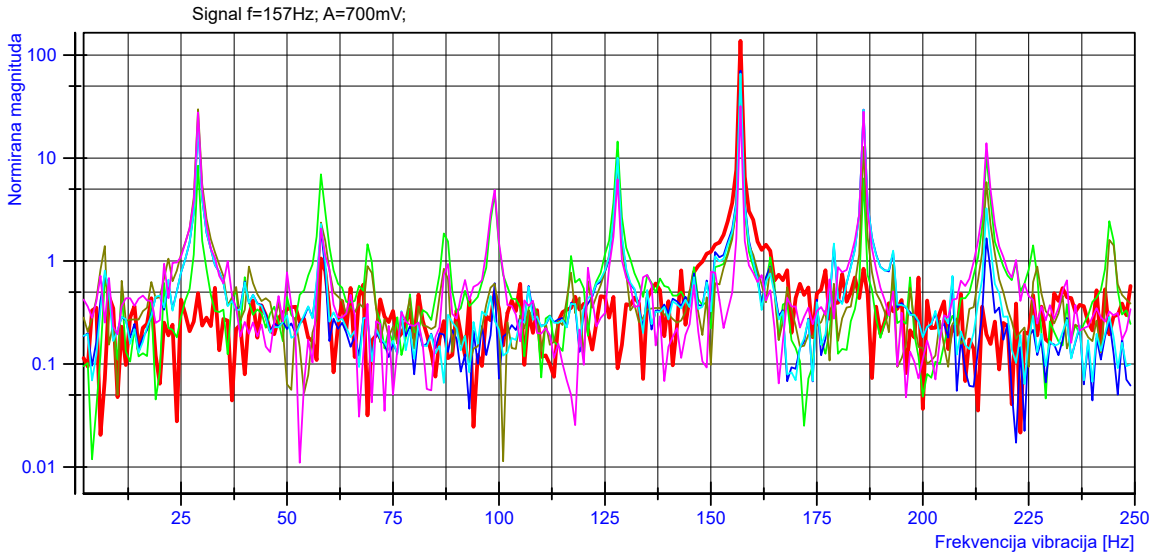

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det	137.62	157	1.44	163	1.06	58	19.80
	Correlation	59.54	157	14.51	128	10.70	215	6.13
	Corr. Ef.	70.83	157	29.61	186	21.92	29	3.79
	SumDiff	62.86	157	29.82	29	12.80	186	3.24
	PfPPD	66.15	157	29.32	186	21.94	29	3.53
	Mom.Ef1	31.98	157	28.23	186	27.74	29	0.54

6.3.3 Male detektorske diode i standardno višemodno vlakno

Kako je i najavljeno u uvodnom dijelu poglavlja, dio mjerenja je proveden uz upotrebu standardnog višemodnog vlakna. Motivacija za to je bila u nešto drugačijem izgledu točkastog uzorka za taj tip vlakna. Struktura je *zrnatija*, odnosno točke uzorka su nešto veće kao što je prikazano na slici 6.13. U skladu s time za očekivati je nešto drugačije ponašanje sustava u slučaju mjerenja na takvom uzorku.

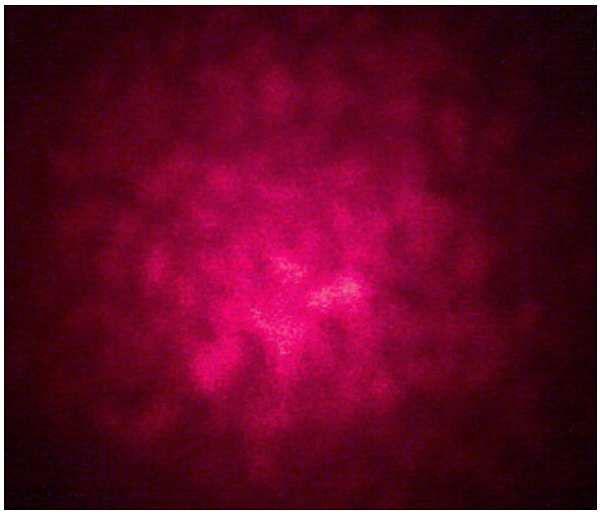

(a) standardno višemodno vlakno

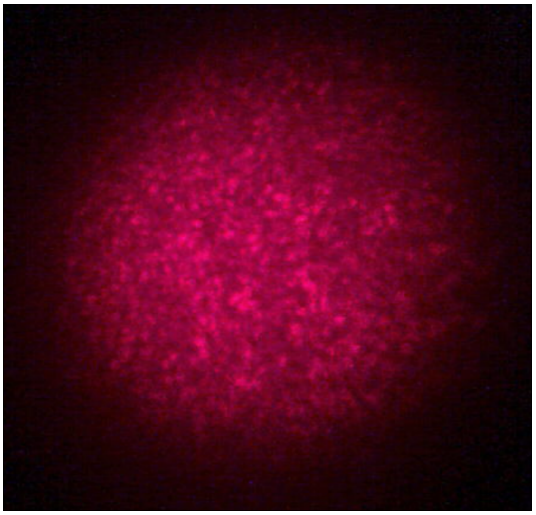

(b) jako višemodno vlakno

Slika 6.13: Izgled točkastog uzorka za:

Mjerenja upotrebom malih dioda nisu dala nikakve relevantne, odnosno upotrebljive rezultate. Na njima je bilo nemoguće detektirati bilo kakva obilježja povezana s uzbudnim signalom tj. signalom kontrolnog detektora. Iz tog razloga ti rezultati neće ni biti prikazani. Dakle, preskačemo tu konfiguraciju i odmah prelazimo na kombinaciju s velikim diodama.

6.3.4 Velike detektorske diode i standardno višemodno vlakno

Uvidom u rezultate na slikama ovog odjeljka očito je da je u ovoj konfiguraciji detekcija značajno popravljena i gotovo potpuno pouzdana, bez obzira promatramo li rezultate analize direktno na signalu s detektorskih dioda ili na signalu koji je dobijen statističkom obradom signala sa svih dioda. Viši harmonici osnovne frekvencije vibracija su znatno manje izraženi te su puno rjeđi slučajevi u kojima su takve komponente dominantnije od osnovne frekvencije nego je to bio slučaj s jako višemodnim vlaknom.

Spektar signala s detektorskih dioda

Slika 6.14 a)

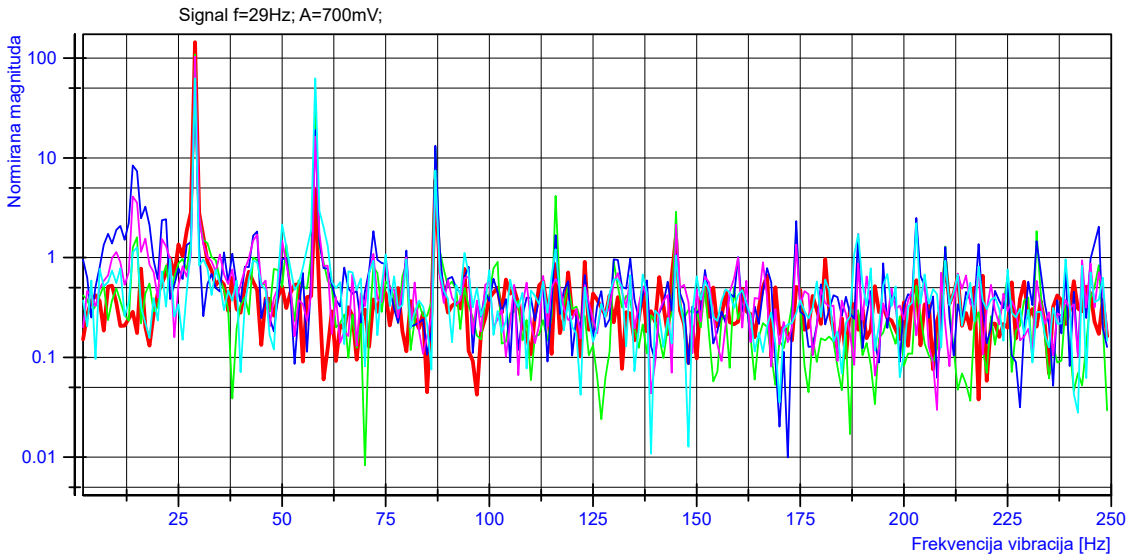

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det.	144.73	29	6.00	87	4.87	58	13.82
	D_gr	109.03	29	30.16	58	12.54	87	5.58
	D_bl	60.08	29	19.02	58	13.24	87	5.00
	D_vi	103.08	29	16.34	58	6.40	87	8.00
	D_tu	62.91	58	62.73	29	7.50	87	0.01

Slika 6.14 b)

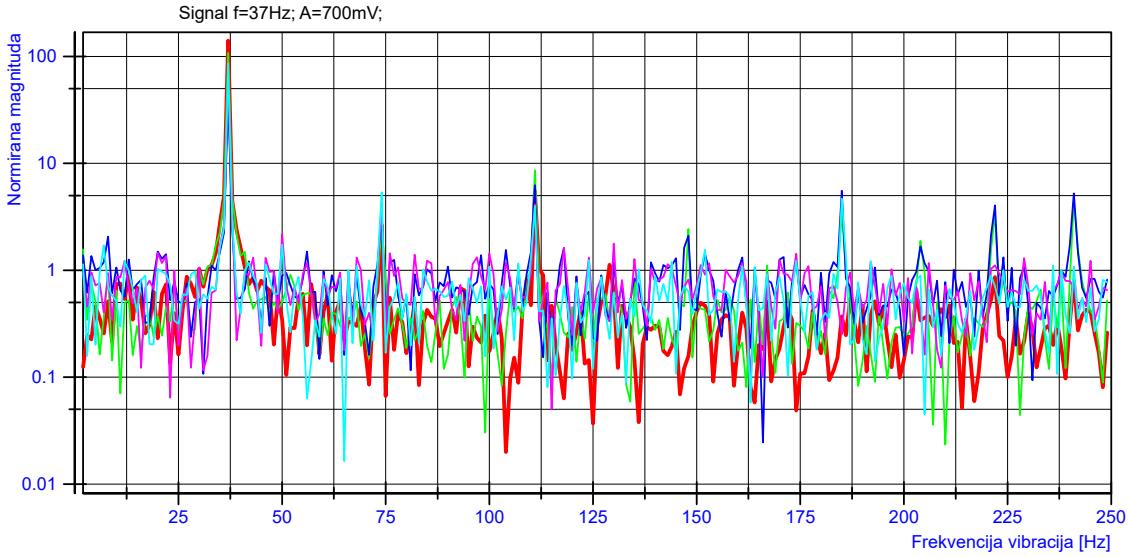

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det.	140.37	37	5.52	111	2.66	74	14.05
	D_gr	107.63	37	8.62	111	4.46	241	10.96
	D_bl	42.77	37	6.25	111	5.54	185	8.35
	D_vi	64.28	37	4.26	74	4.13	111	11.79
	D_tu	86.83	37	5.37	74	4.66	185	12.09

Slika 6.14 c)

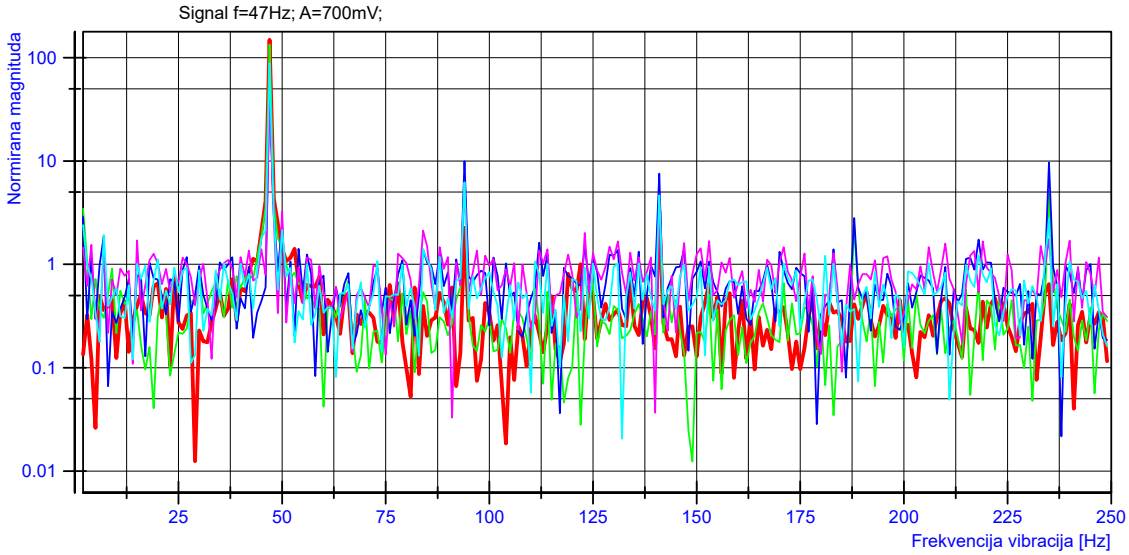

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det.	148.85	47	3.30	141	2.26	94	16.54
	D_gr	134.39	47	7.29	94	4.78	235	12.66
	D_bl	55.95	47	9.97	94	9.68	235	7.49
	D_vi	43.80	47	6.14	94	4.26	141	8.53
	D_tu	88.93	47	6.23	94	4.66	141	11.55

Slika 6.14 d)

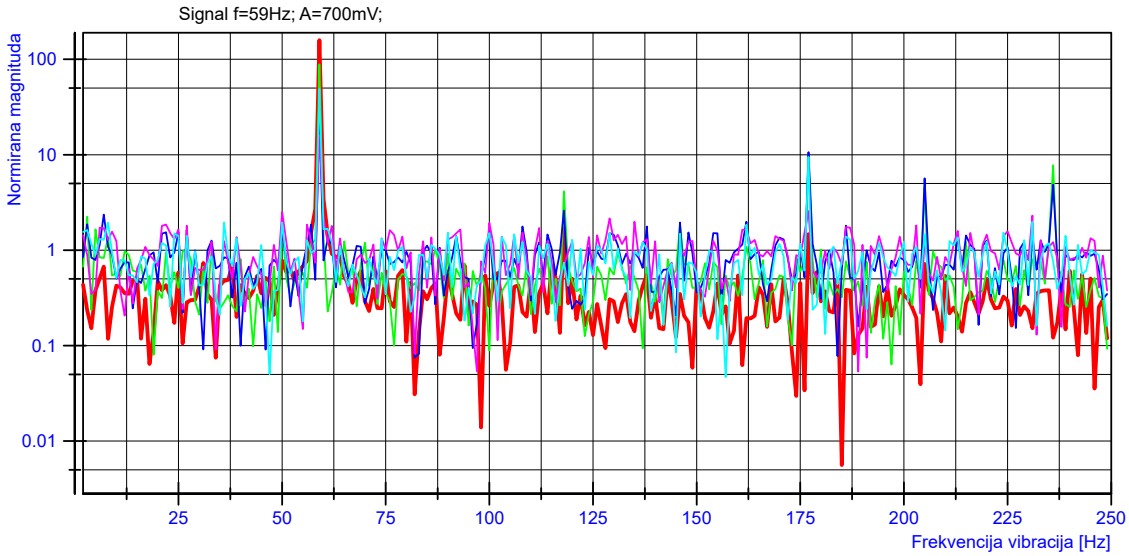

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det.	158.47	59	1.70	118	1.47	177	19.69
	D_gr	88.74	59	9.54	177	7.77	236	9.69
	D_bl	30.67	59	10.67	177	5.66	205	4.59
	D_vi	16.06	59	2.56	177	2.52	50	7.98
	D_tu	48.79	59	9.48	177	1.98	231	7.12

Slika 6.14 e)

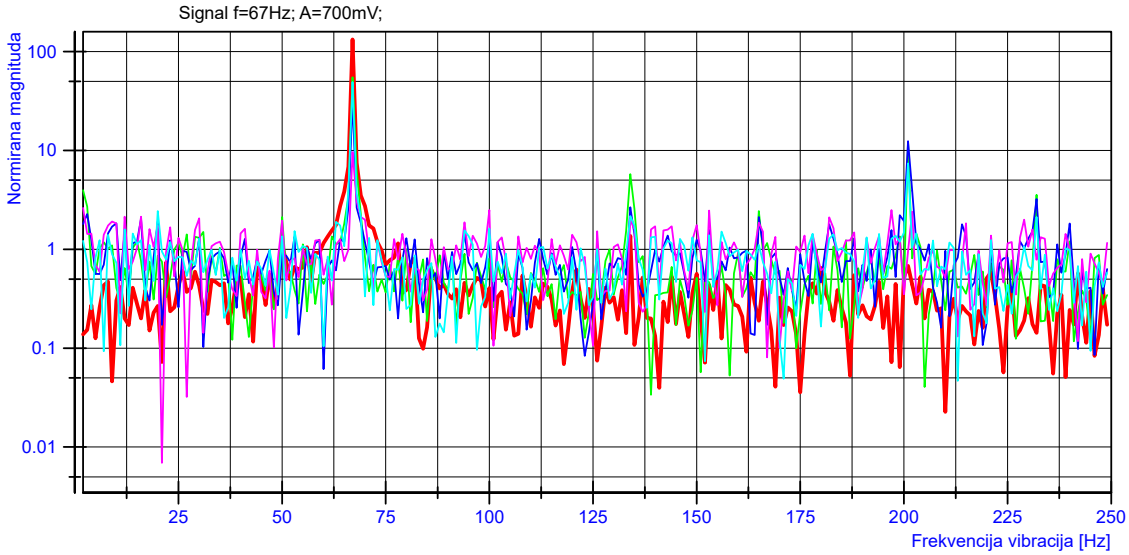

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det.	132.67	67	1.37	134	1.15	78	19.86
	D_gr	54.98	67	12.23	201	5.77	134	6.53
	D_bl	32.44	67	12.43	201	3.22	232	4.17
	D_vi	9.63	67	2.49	197	2.49	100	5.87
	D_tu	49.22	67	7.41	201	2.44	20	8.22

Slika 6.14 f)

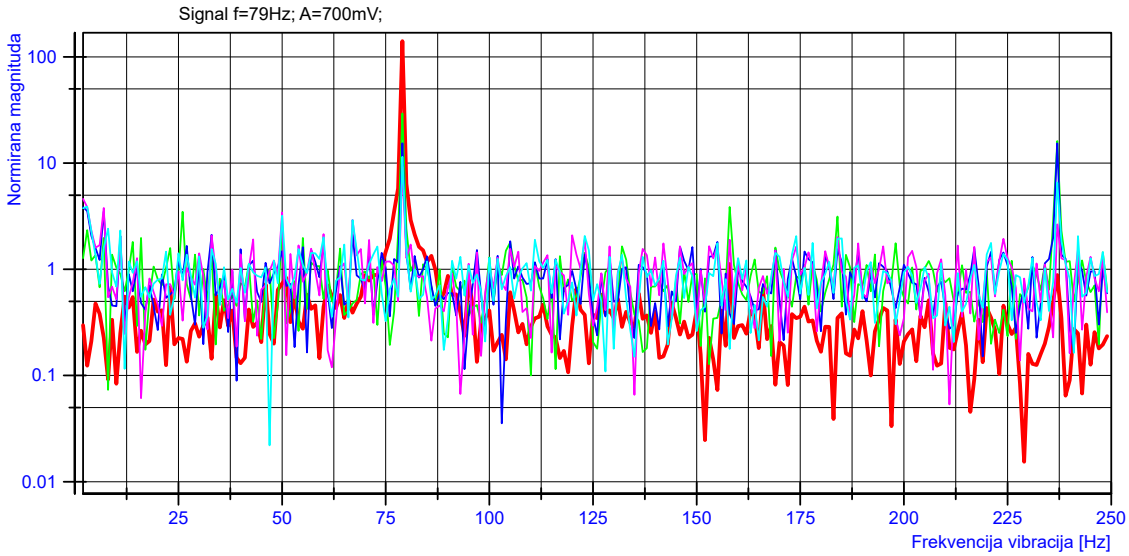

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det.	141.12	79	1.34	86	1.12	158	20.22
	D_gr	29.48	79	16.17	237	3.87	158	2.61
	D_bl	15.45	79	15.36	237	3.51	7	0.03
	D_vi	9.25	79	3.77	7	3.43	50	3.90
	D_tu	11.48	79	6.59	237	3.89	3	2.41

Slika 6.14 g)

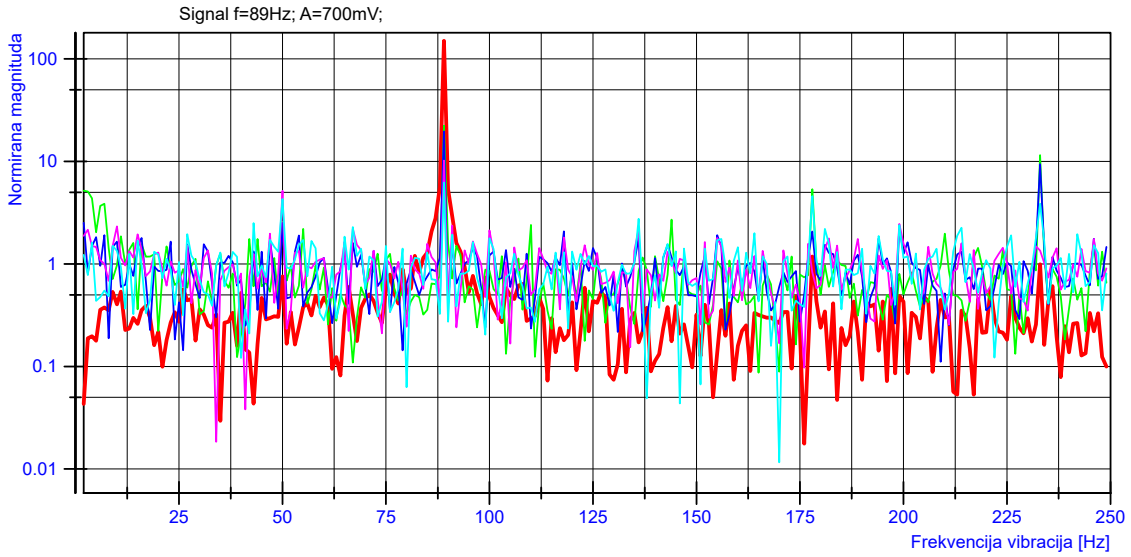

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det.	149.98	89	1.20	82	1.18	178	20.97
	D_gr	22.28	89	11.51	233	5.37	178	2.87
	D_bl	19.55	89	9.41	233	2.51	50	3.18
	D_vi	10.20	89	5.16	50	2.45	199	2.96
	D_tu	6.22	89	4.59	178	4.30	50	1.32

Slika 6.14 h)

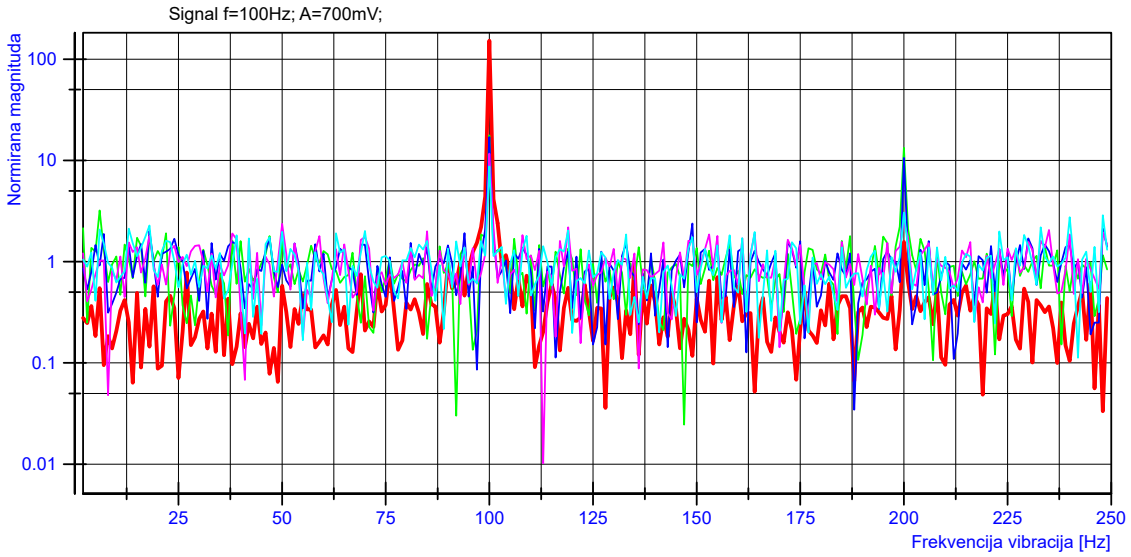

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det.	152.08	100	1.57	200	1.16	104	19.86
	D_gr	17.69	100	13.29	200	3.20	6	1.24
	D_bl	17.01	100	10.57	200	2.38	149	2.07
	D_vi	11.67	100	2.49	200	2.37	50	6.71
	D_tu	8.73	100	3.05	200	2.87	248	4.57

Slika 6.14 i)

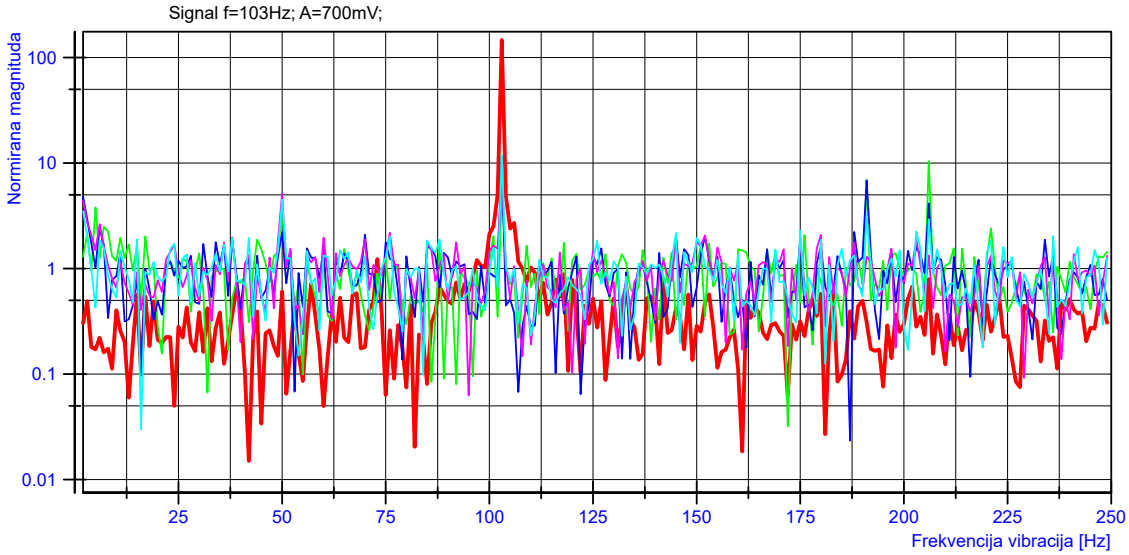

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det.	146.65	103	2.70	106	1.23	73	17.35
	D_gr	10.41	206	6.93	191	5.37	103	1.77
	D_bl	11.38	103	6.82	191	4.14	206	2.22
	D_vi	7.89	103	5.13	50	2.63	6	1.87
	D_tu	11.90	103	4.50	50	3.17	191	4.22

Slika 6.14 j)

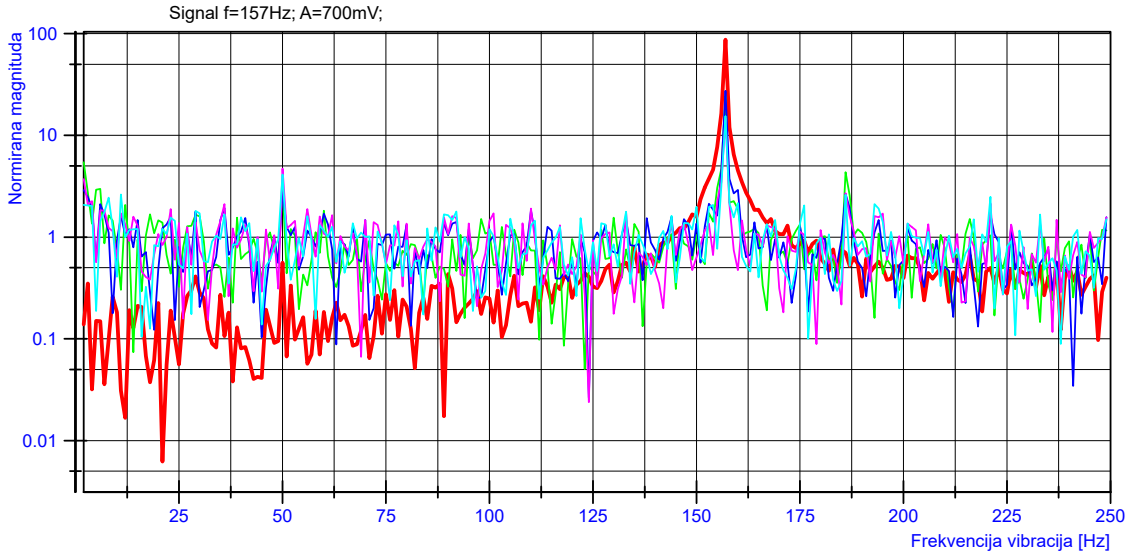

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det.	86.98	157	1.86	165	1.68	149	16.70
	D_gr	24.44	157	4.34	186	3.31	50	7.51
	D_bl	27.41	157	2.91	160	2.76	50	9.74
	D_vi	14.71	157	4.72	50	2.71	186	4.94
	D_tu	15.47	157	4.12	50	2.62	11	5.75

Spektar signala proračunatog statističkim metodama

Slika 6.14 k)

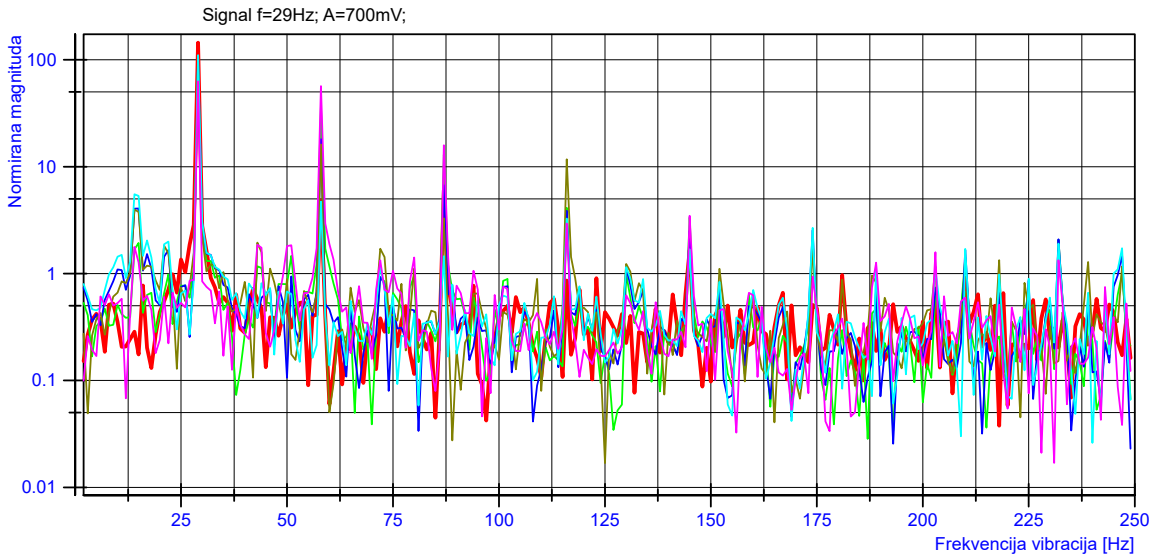

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det	144.73	29	6.00	87	4.87	58	13.82
	Correlation	92.19	29	37.38	58	12.97	87	3.92
	Corr. Ef.	106.20	29	18.11	58	6.74	87	7.68
	SumDiff	97.27	29	16.17	58	11.73	116	7.79
	PfPPD	110.64	29	5.52	14	4.71	58	13.02
	Mom.Ef1	63.10	29	56.83	58	15.87	87	0.45

Slika 6.14 l)

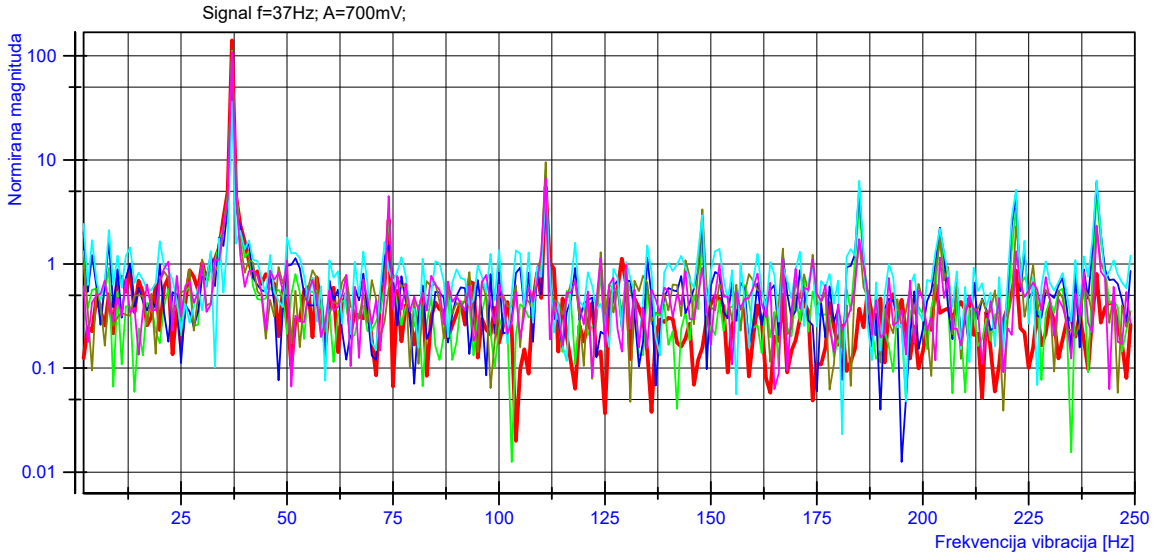

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det	140.37	37	5.52	111	2.66	74	14.05
	Correlation	111.65	37	8.12	111	4.72	241	11.38
	Corr. Ef.	80.74	37	7.09	111	6.07	241	10.56
	SumDiff	102.83	37	9.51	111	3.36	148	10.34
	PfPPD	36.36	37	6.33	241	6.29	185	7.59
	Mom.Ef1	108.81	37	6.64	111	4.50	74	12.15

Slika 6.14 m)

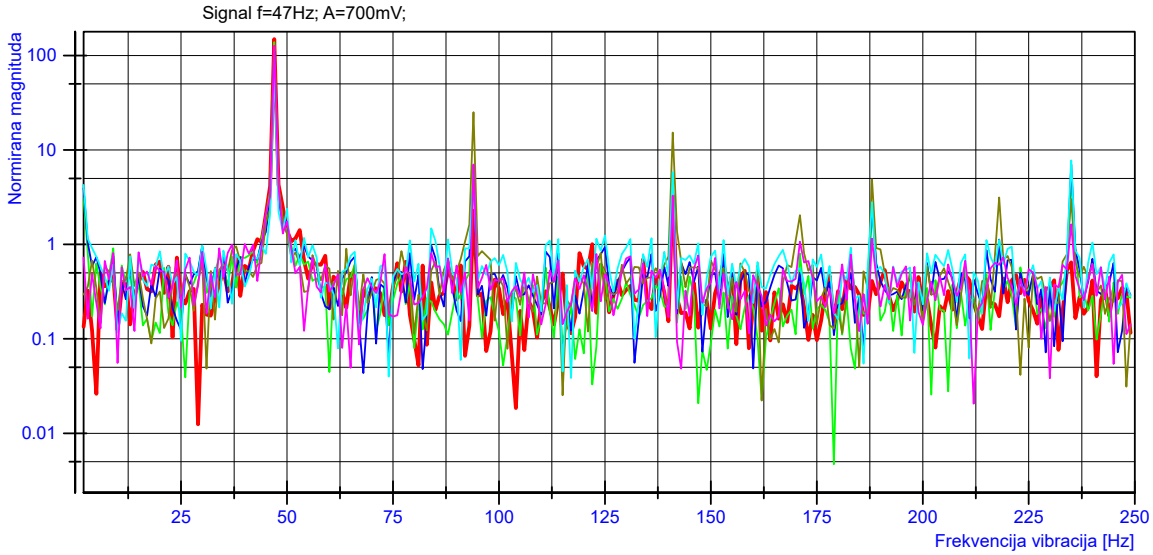

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det	148.85	47	3.30	141	2.26	94	16.54
	Correlation	138.51	47	6.95	94	5.26	235	12.99
	Corr. Ef.	111.22	47	7.00	235	5.40	141	12.01
	SumDiff	83.30	47	25.09	94	15.27	141	5.21
	PfPPD	80.03	47	7.77	235	5.82	141	10.13
	Mom.Ef1	126.61	47	7.01	94	3.27	141	12.57

Slika 6.14 n)

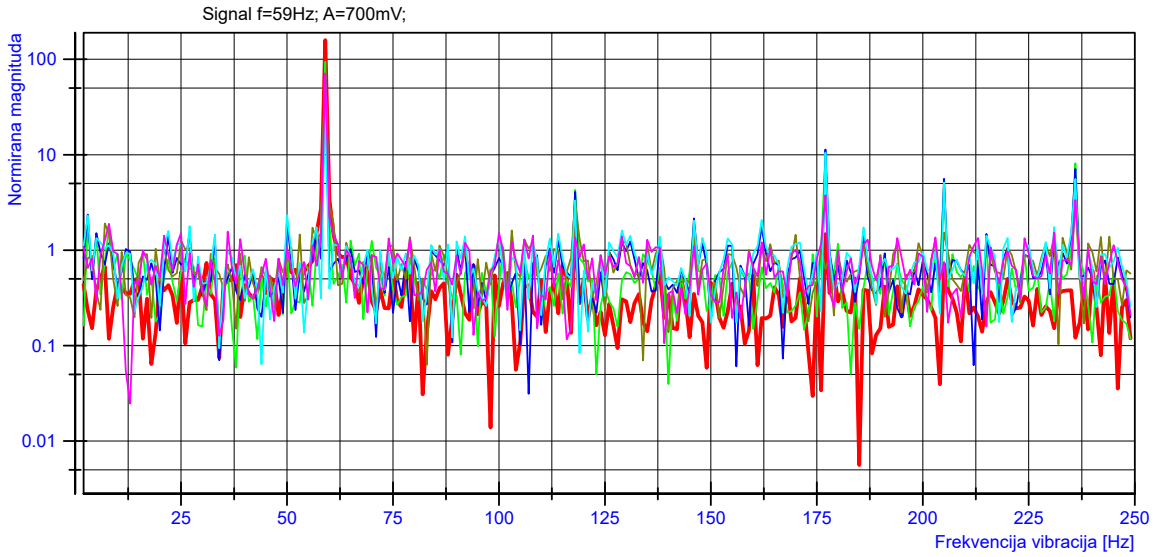

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det	158.47	59	1.70	118	1.47	177	19.69
	Correlation	94.56	59	10.06	177	8.14	236	9.73
	Corr. Ef.	61.69	59	11.33	177	7.11	236	7.36
	SumDiff	65.35	59	3.28	236	3.22	118	12.99
	PfPPD	38.04	59	10.53	177	5.58	236	5.58
	Mom.Ef1	71.42	59	3.77	177	3.36	236	12.77

Slika 6.14 o)

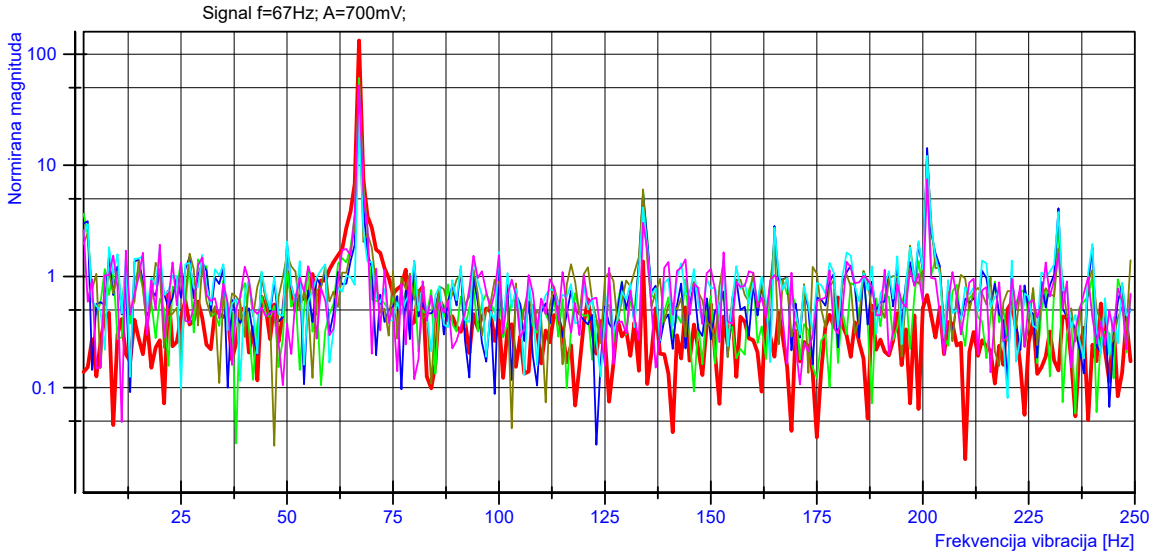

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det	132.67	67	1.37	134	1.15	78	19.86
	Correlation	60.96	67	13.56	201	5.81	134	6.53
	Corr. Ef.	45.07	67	14.30	201	5.52	134	4.99
	SumDiff	42.65	67	12.11	201	6.08	134	5.47
	PfPPD	28.97	67	12.12	201	4.18	134	3.78
	Mom.Ef1	52.44	67	7.48	201	3.05	134	8.46

Slika 6.14 p)

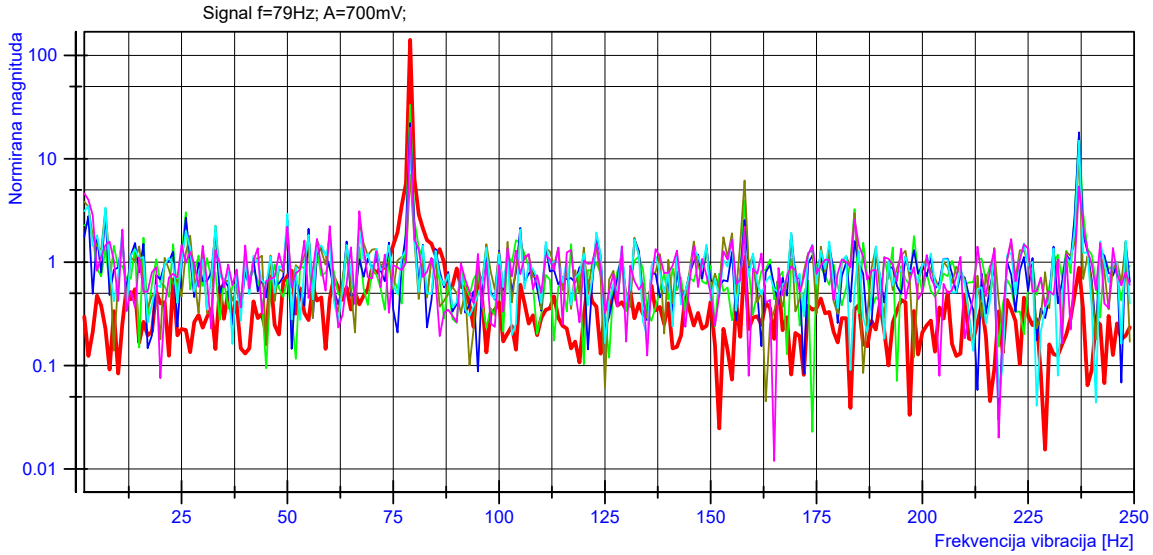

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det	141.12	79	1.34	86	1.12	158	20.22
	Correlation	33.16	79	17.50	237	3.98	158	2.78
	Corr. Ef.	22.07	79	18.01	237	3.13	7	0.88
	SumDiff	12.04	237	7.04	79	6.18	158	2.33
	PfPPD	14.96	237	12.68	79	3.51	3	0.72
	Mom.Ef1	19.98	79	5.41	237	3.11	67	5.67

Slika 6.14 q)

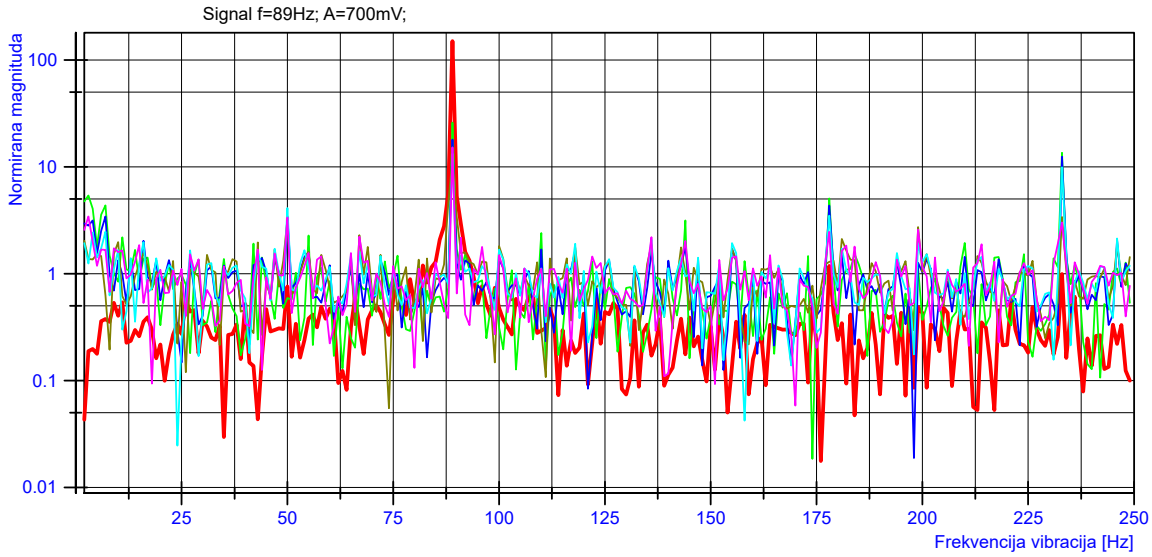

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det	149.98	89	1.20	82	1.18	178	20.97
	Correlation	25.91	89	13.52	233	5.40	3	2.82
	Corr. Ef.	17.99	89	12.38	233	4.33	178	1.62
	SumDiff	11.92	89	3.39	233	3.23	50	5.46
	PfPPD	13.26	89	9.86	233	4.12	50	1.29
	Mom.Ef1	15.22	89	3.43	3	3.35	50	6.47

Slika 6.14 r)

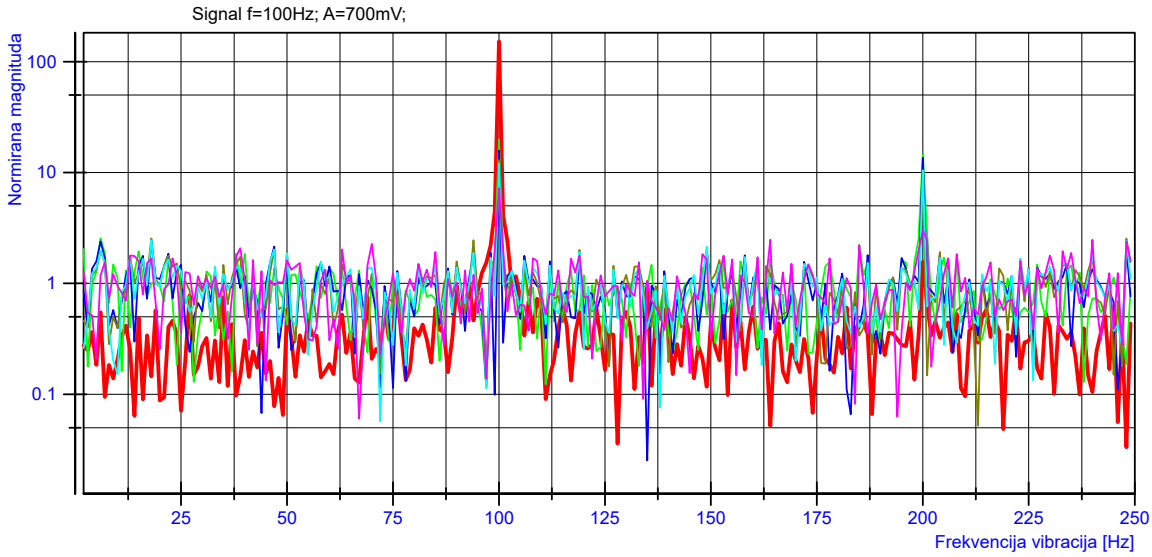

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det	152.08	100	1.57	200	1.16	104	19.86
	Correlation	19.74	100	14.52	200	2.55	6	1.33
	Corr. Ef.	15.76	100	13.56	200	2.40	18	0.65
	SumDiff	12.94	100	10.26	200	2.54	18	1.01
	PfPPD	12.07	100	10.49	200	2.46	18	0.61
	Mom.Ef1	7.24	100	2.99	200	2.47	240	3.84

Slika 6.14 s)

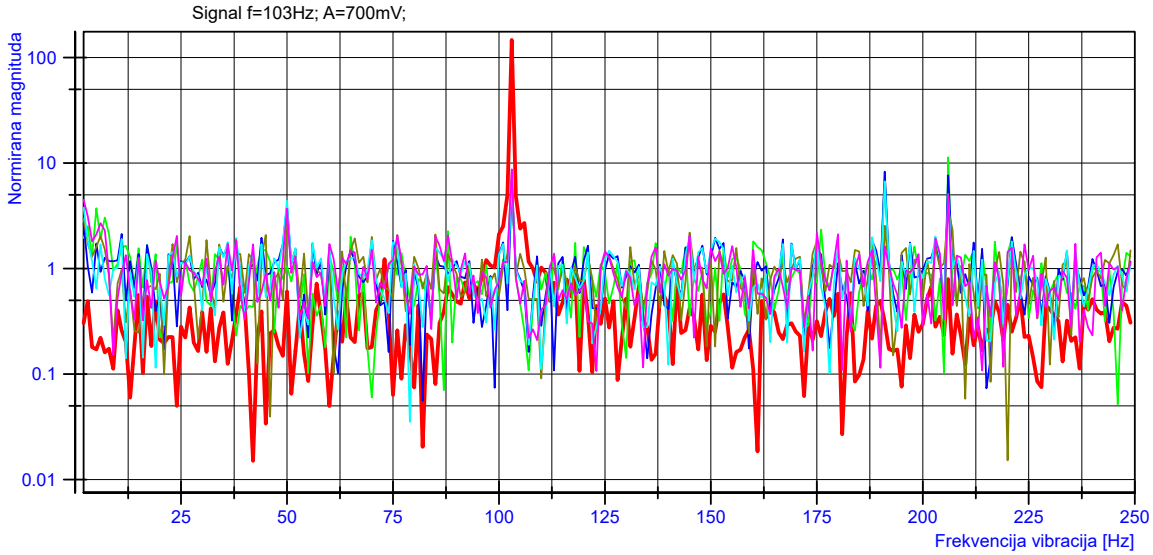

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det	146.65	103	2.70	106	1.23	73	17.35
	Correlation	11.31	206	7.70	191	6.81	103	1.67
	Corr. Ef.	8.29	191	7.64	206	6.08	103	0.35
	SumDiff	8.07	103	3.57	206	2.76	50	3.54
	PfPPD	6.71	191	6.58	103	4.71	206	0.08
	Mom.Ef1	8.72	103	5.10	206	3.70	50	2.33

Slika 6.14 t)

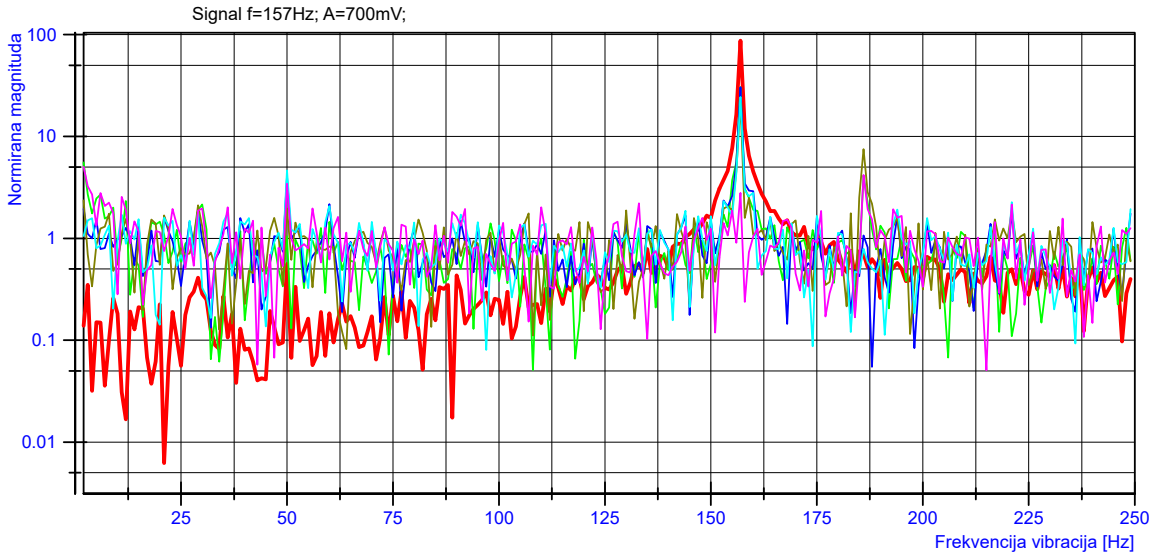

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det	86.98	157	1.86	165	1.68	149	16.70
	Correlation	30.44	157	4.15	186	2.69	6	8.65
	Corr. Ef.	30.41	157	4.04	50	2.35	153	8.77
	SumDiff	21.41	157	7.50	186	2.49	159	4.56
	PfPPD	24.45	157	4.62	50	2.79	160	7.24
	Mom.Ef1	4.19	186	3.43	50	2.79	157	0.87

6.3.5 Velike detektorske diode i standardno višemodno vlakno postavljeno u petlju

U najavi eksperimentalnih rezultata opisano je osam mogućih kombinacija elemenata mjernog sustava. Naime, moguće je birati između dva detektorska polja (male i velike diode), dvije vrste vlakna (standardno i jako višemodno) te dva načina ostvarivanja sprege između vlakna i vibratora (ovješeno vlakno ili petlja). Kako je za prezentaciju rezultata potrebno jako puno prostora, preostale rezultate ćemo ograničiti samo na najuspješniju varijantu. Prethodno prezentirane varijante su prikazane radi toga što te konfiguracije odgovaraju postavkama simuliranih detektorskih sustava.

Najuspješnija varijanta u eksperimentalnim mjerenjima, s aspekta točnosti detektirane frekvencije i njenog poklapanja s rezultatima kontrolog detektora, je kombinacija velikih dioda i standardnog višemodnog vlakna koje je s vibratorom povezano u vidu petlje. Sličan primjer iz literature je [13]. Ovakva konfiguracija je prikazana na slici 6.15. U takvoj konfiguraciji vlakno mijenja karakter detekcije od integriranog sustava, koji mjeri duž cijelog vlakna, prema mjerenju u jednoj točki. Makar i dalje cijelo vlakno funkcionira kao detektor vibracija, vibracije su sada ograničene na jedan mali segment vlakna i ne prenose se izvan njega. Time je eliminiran najveći dio parcijalnih vibracija i vibracija na preostalim segmentima vlakna koje su stvarale probleme na prethodno prezentiranim konfiguracijama mjernog sustava. Na slici 6.15 b) može se uočiti i *curenje* svjetlosti iz vlakna kao posljedice savijanja pod djelovanjem vibratora.

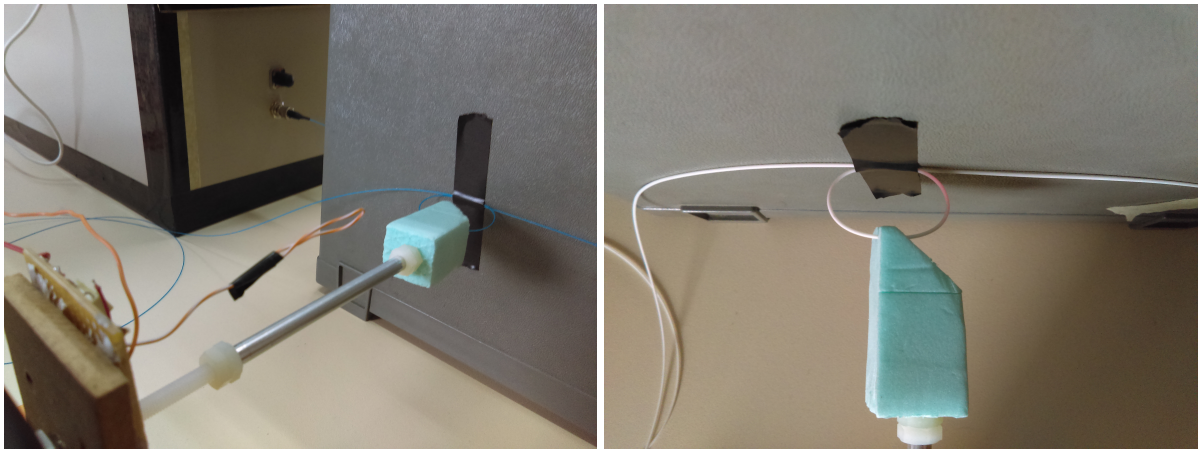

(a) Ruka vibratora pritišće vlakno (b) Detalj svjetlovodne petlje

Slika 6.15: Vlakno spregnuto s vibratorom preko petlje

Iako su već i rezultati odjeljka 6.3.4 jako dobri, rezultati u ovoj posljednjoj prikazanoj konfiguraciji još su nešto bolji, odnosno čišći u odnosu na spektar kontrolnog detektora, iako je ovakva konfiguracija očito utjecala i na rad vibratora znatno više nego je to prethodno bio slučaj. Ta je činjenica očita iz usporedbe oblika osnovne spektralne komponente primjerice za kontrolni detektor u konfiguraciji iz odjeljka 6.3.4 slika l) te odjeljka 6.3.5 slika l).

Spektar signala s detektorskih dioda

Slika 6.16 a)

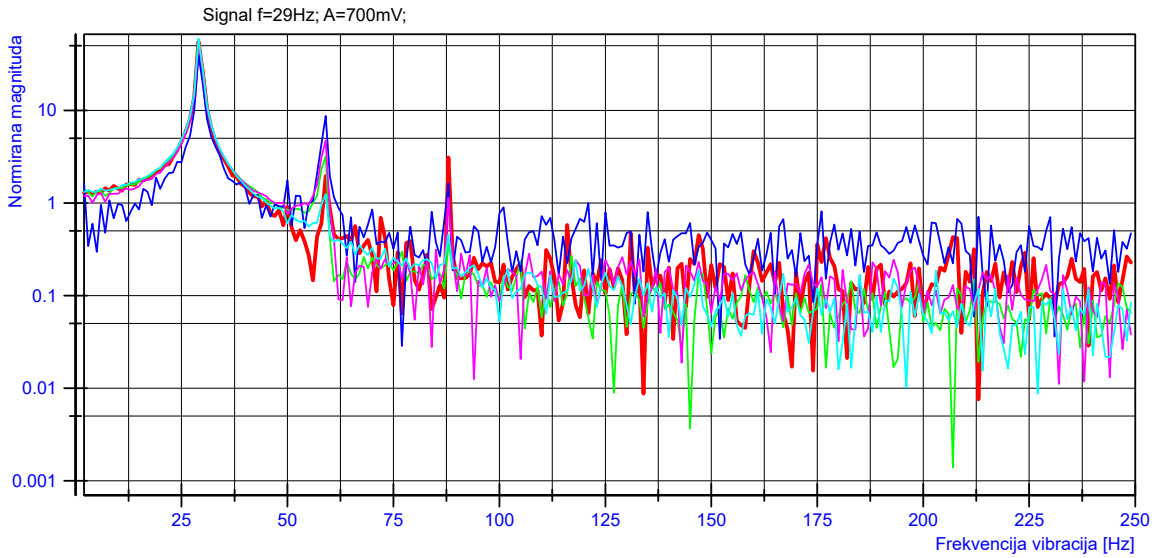

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det.	55.50	29	3.11	88	1.96	59	12.52
	D_gr	58.60	29	3.20	59	1.46	10	12.63
	D_bl	40.12	29	8.73	59	2.79	24	6.62
	D_vi	55.42	29	4.75	59	1.44	12	10.67
	D_tu	59.43	29	1.43	6	1.38	3	16.19

Slika 6.16 b)

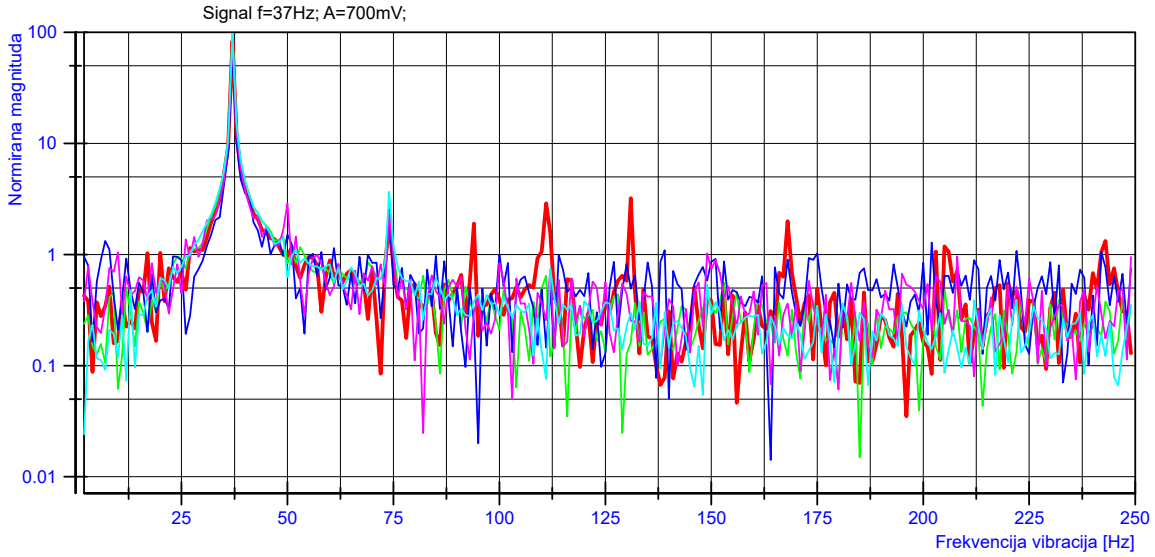

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det.	83.57	37	3.21	131	2.89	111	14.16
	D_gr	96.48	37	2.74	74	1.46	49	15.47
	D_bl	71.24	37	2.54	74	1.71	45	14.48
	D_vi	85.88	37	2.88	50	2.41	74	14.74
	D_tu	96.73	37	3.67	74	1.41	49	14.21

Slika 6.16 c)

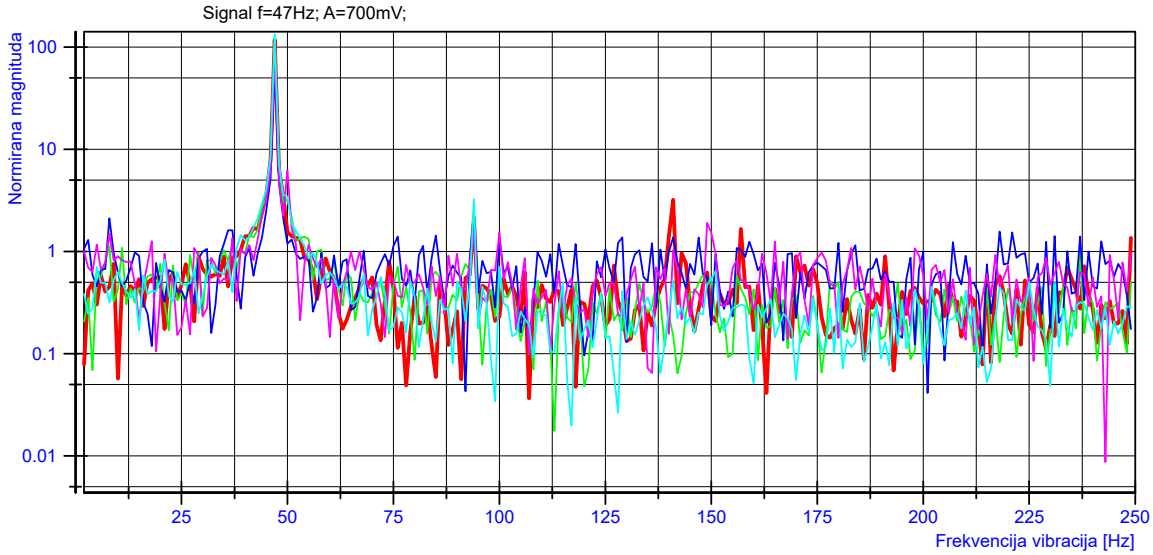

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det.	118.16	47	3.21	141	2.14	94	15.66
	D_gr	122.55	47	3.24	50	2.64	94	15.78
	D_bl	65.60	47	2.41	94	2.11	8	14.35
	D_vi	87.26	47	6.22	50	1.90	149	11.47
	D_tu	132.84	47	3.27	94	1.45	39	16.09

Slika 6.16 d)

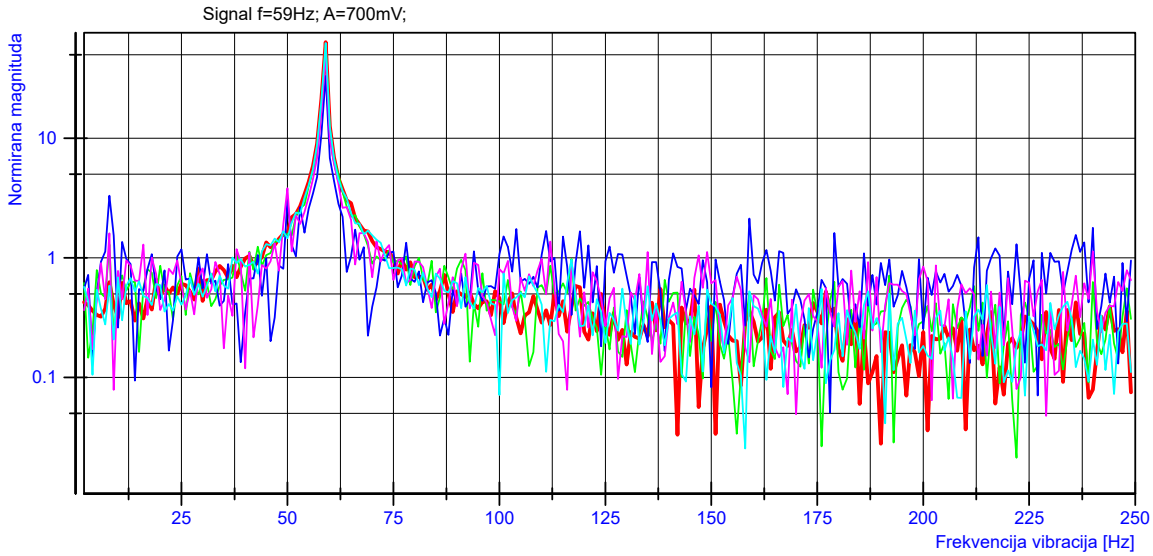

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det.	63.63	59	1.34	45	1.04	41	16.77
	D_gr	60.19	59	2.28	66	1.60	50	14.22
	D_bl	33.26	59	3.31	8	3.07	50	10.02
	D_vi	50.27	59	3.82	50	2.66	64	11.19
	D_tu	62.57	59	2.39	52	1.69	69	14.18

Slika 6.16 e)

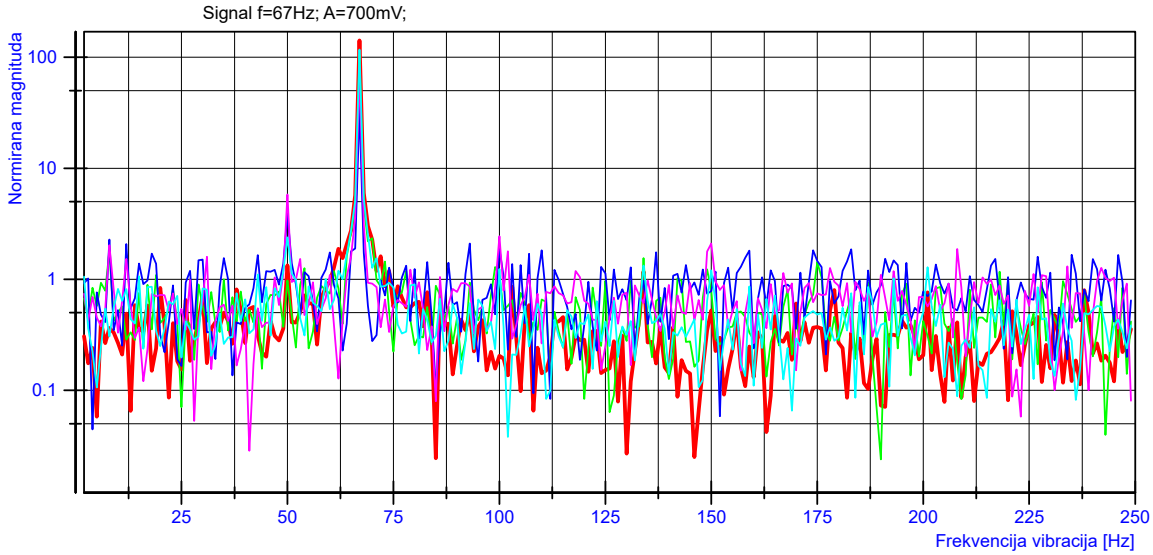

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det.	141.93	67	1.88	62	1.61	72	18.78
	D_gr	105.60	67	2.34	70	1.82	8	16.54
	D_bl	35.01	67	3.86	50	2.28	8	9.58
	D_vi	72.00	67	5.81	50	2.44	100	10.93
	D_tu	117.55	67	2.39	50	1.55	71	16.92

Slika 6.16 f)

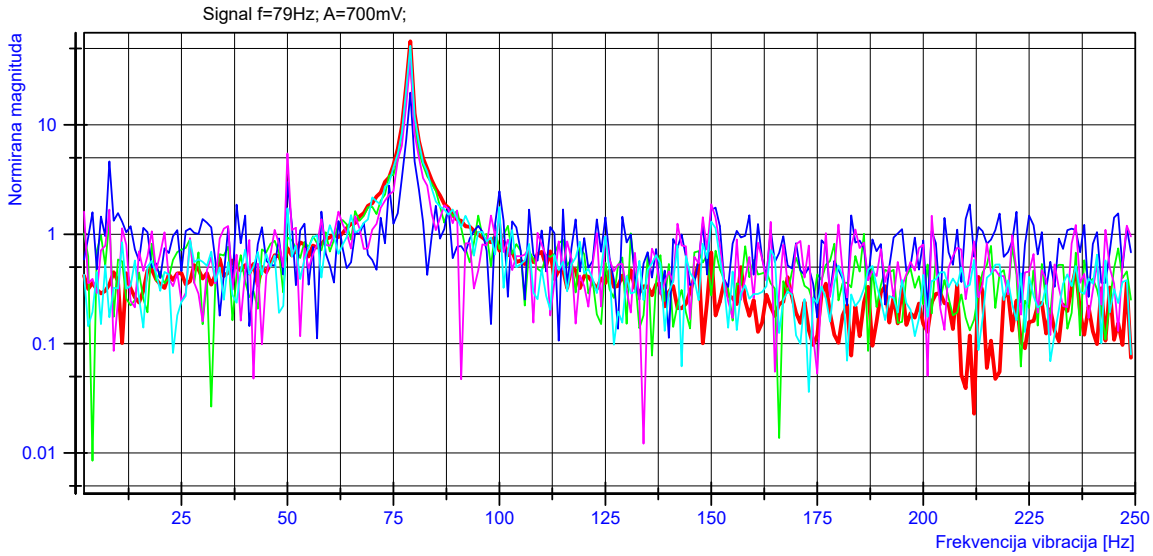

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det.	58.03	79	0.99	61	0.95	99	17.68
	D_gr	47.95	79	1.78	70	1.71	88	14.30
	D_bl	19.65	79	4.63	8	2.99	50	6.28
	D_vi	38.92	79	5.49	50	1.88	150	8.51
	D_tu	52.88	79	2.18	70	1.77	100	13.85

Slika 6.16 g)

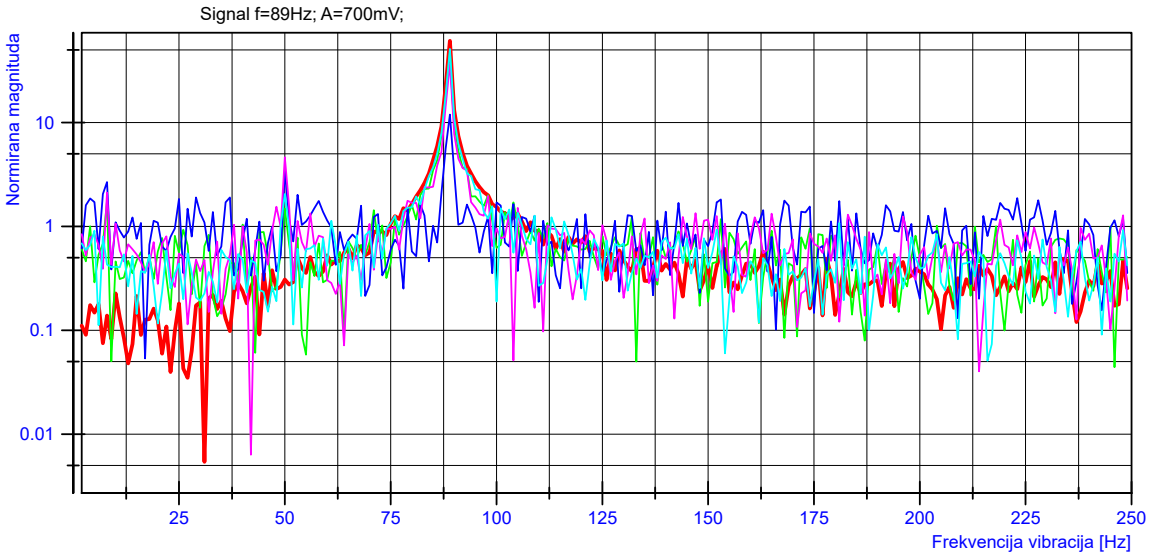

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det.	61.08	89	1.49	78	1.33	105	16.13
	D_gr	48.04	89	2.00	98	1.95	95	13.81
	D_bl	11.93	89	3.49	50	2.67	8	5.34
	D_vi	37.05	89	4.63	50	2.38	83	9.03
	D_tu	51.10	89	2.05	50	1.94	81	13.97

Slika 6.16 h)

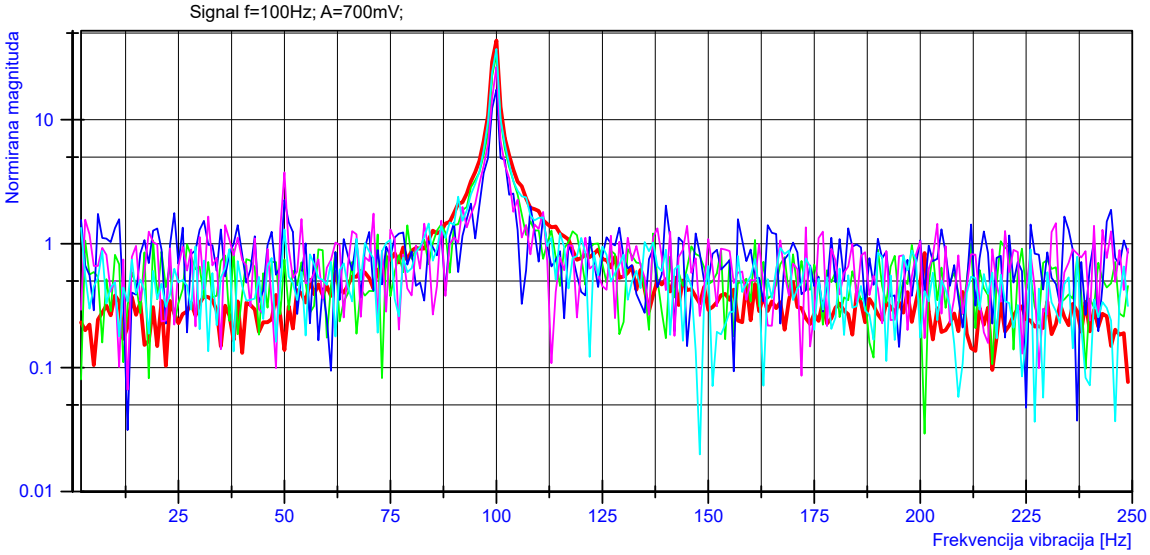

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det.	43.59	100	1.38	114	1.27	85	15.00
	D_gr	33.71	100	1.52	108	1.44	87	13.46
	D_bl	17.51	100	2.54	104	2.25	50	8.38
	D_vi	26.72	100	3.76	50	2.26	105	8.52
	D_tu	37.27	100	2.40	91	1.63	111	11.91

Slika 6.16 i)

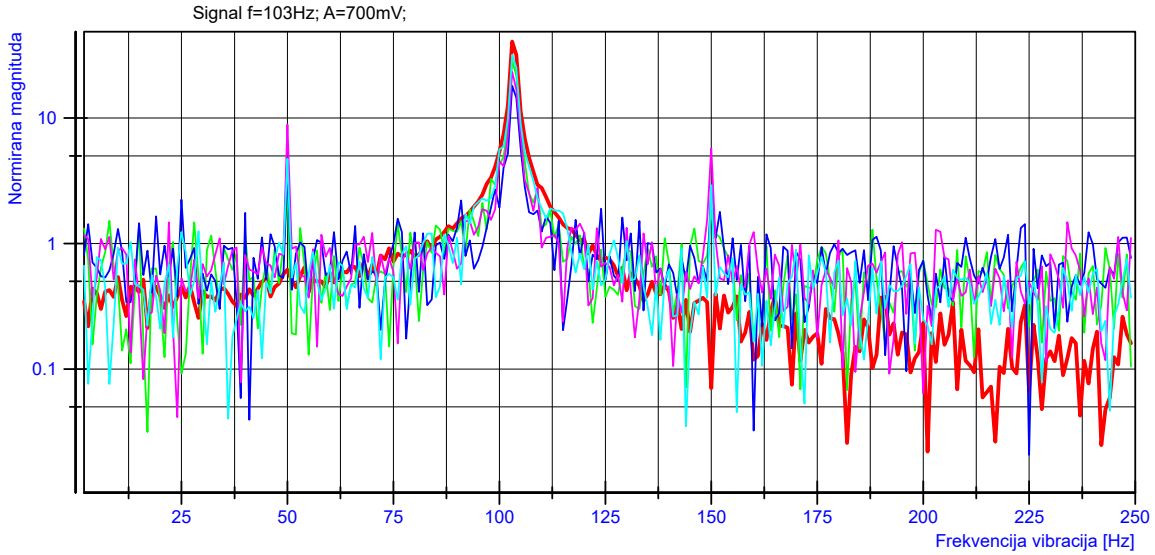

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det.	40.74	103	1.38	88	1.07	120	14.70
	D_gr	28.80	103	3.28	98	2.75	109	9.44
	D_bl	18.09	103	4.04	50	2.88	150	6.51
	D_vi	23.31	103	8.87	50	5.72	150	4.20
	D_tu	31.99	103	4.74	50	2.92	150	8.29

Slika 6.16 j)

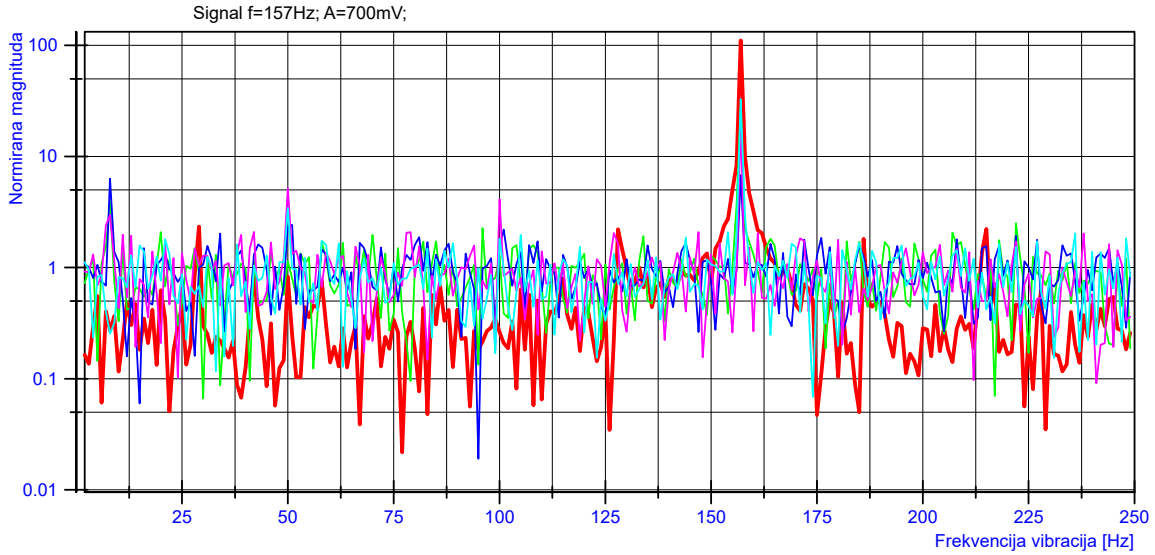

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det.	110.56	157	2.34	29	2.23	215	16.74
	D_gr	27.38	157	3.91	8	2.52	222	8.45
	D_bl	6.80	157	6.32	8	2.42	51	0.32
	D_vi	20.27	157	5.15	50	4.12	100	5.95
	D_tu	32.80	157	3.44	50	2.08	154	9.79

Spektar signala proračunatog statističkim metodama

Slika 6.16 k)

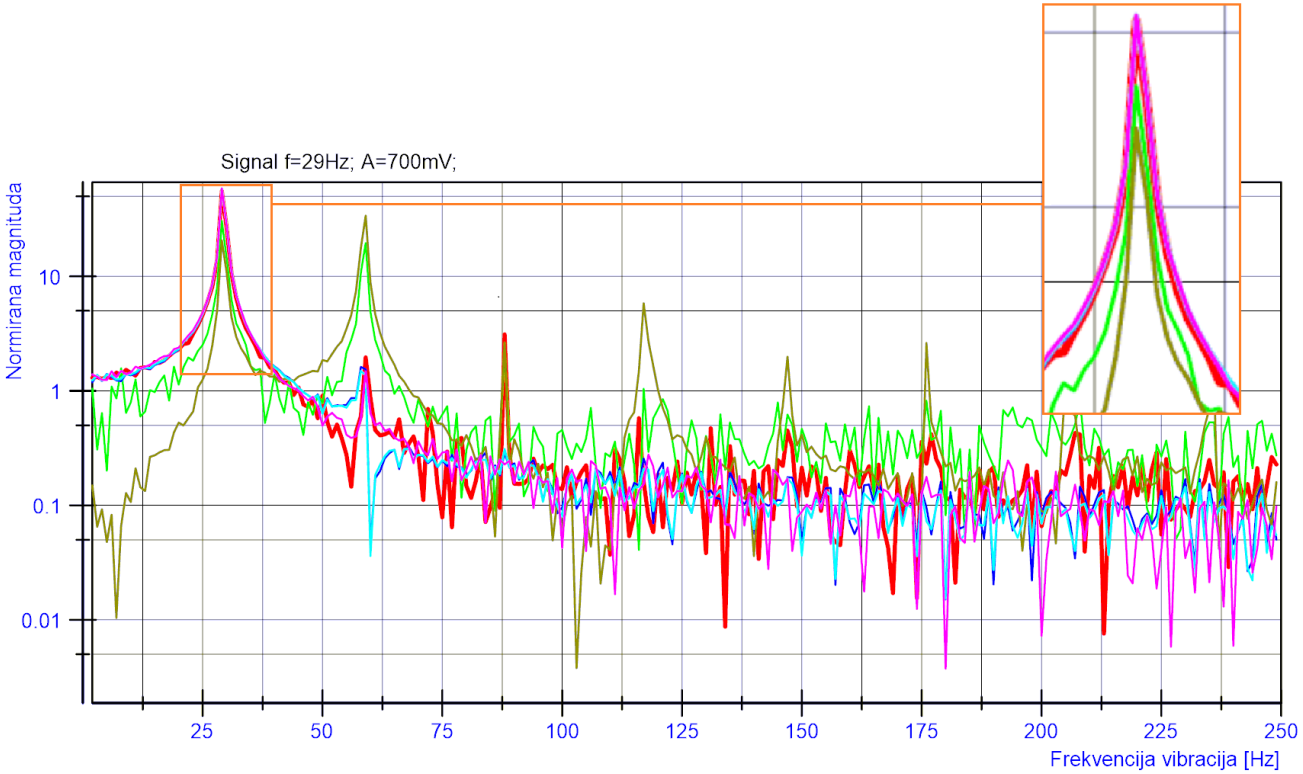

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det	55.50	29	3.11	88	1.96	59	12.52
	Correlation	30.46	29	19.55	59	2.28	88	1.93
	Corr. Ef.	58.26	29	1.62	58	1.59	13	15.56
	SumDiff	33.93	59	20.63	29	5.83	117	2.16
	PfPPD	58.67	29	1.61	13	1.49	58	15.62
	Mom.Ef1	58.63	29	1.63	11	1.50	8	15.56

Slika 6.16 l)

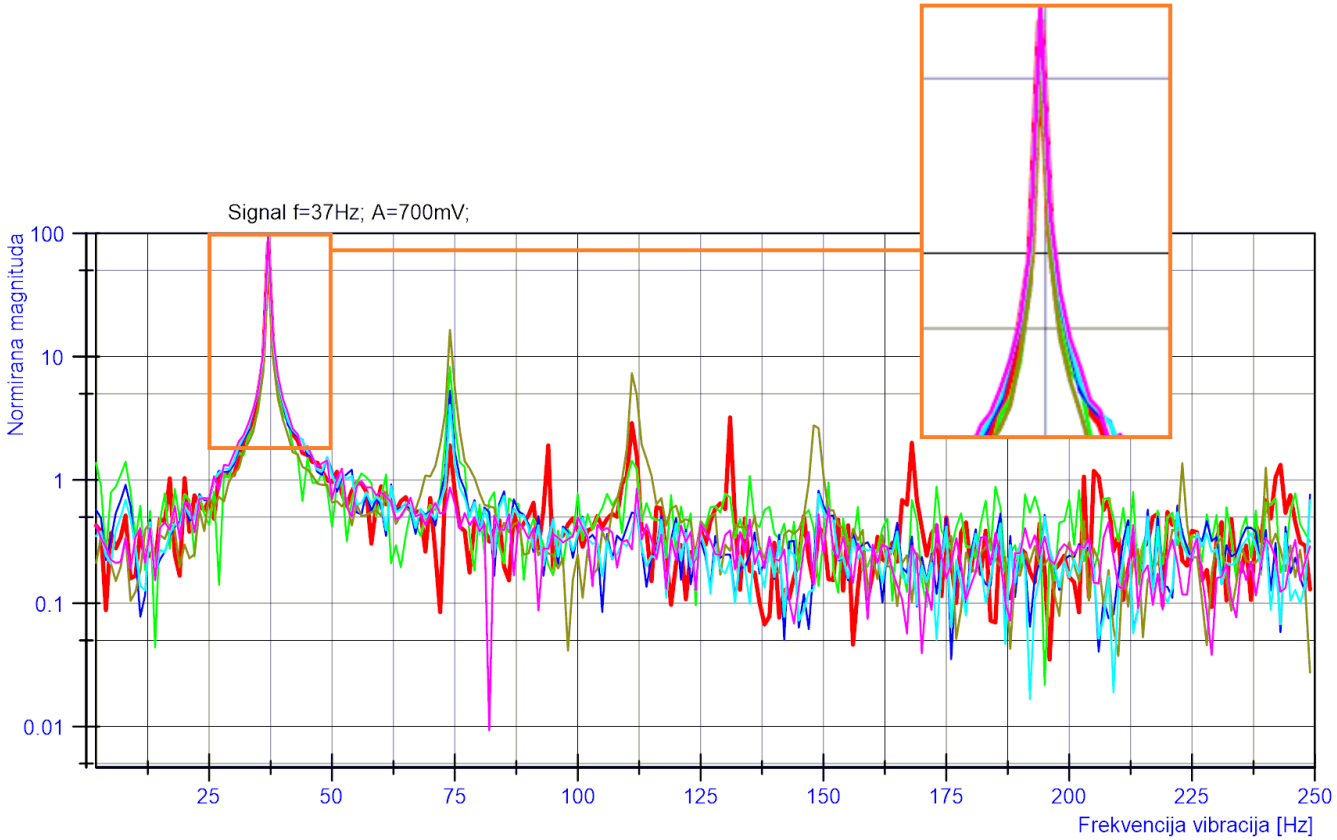

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det	83.57	37	3.21	131	2.89	111	14.16
	Correlation	69.83	37	8.26	74	1.66	31	9.27
	Corr. Ef.	88.70	37	5.28	74	1.52	49	12.25
	SumDiff	66.37	37	16.45	74	7.34	111	6.06
	PfPPD	93.20	37	4.04	74	1.54	49	13.63
	Mom.Ef1	97.18	37	1.88	45	1.44	49	17.13

Slika 6.16 m)

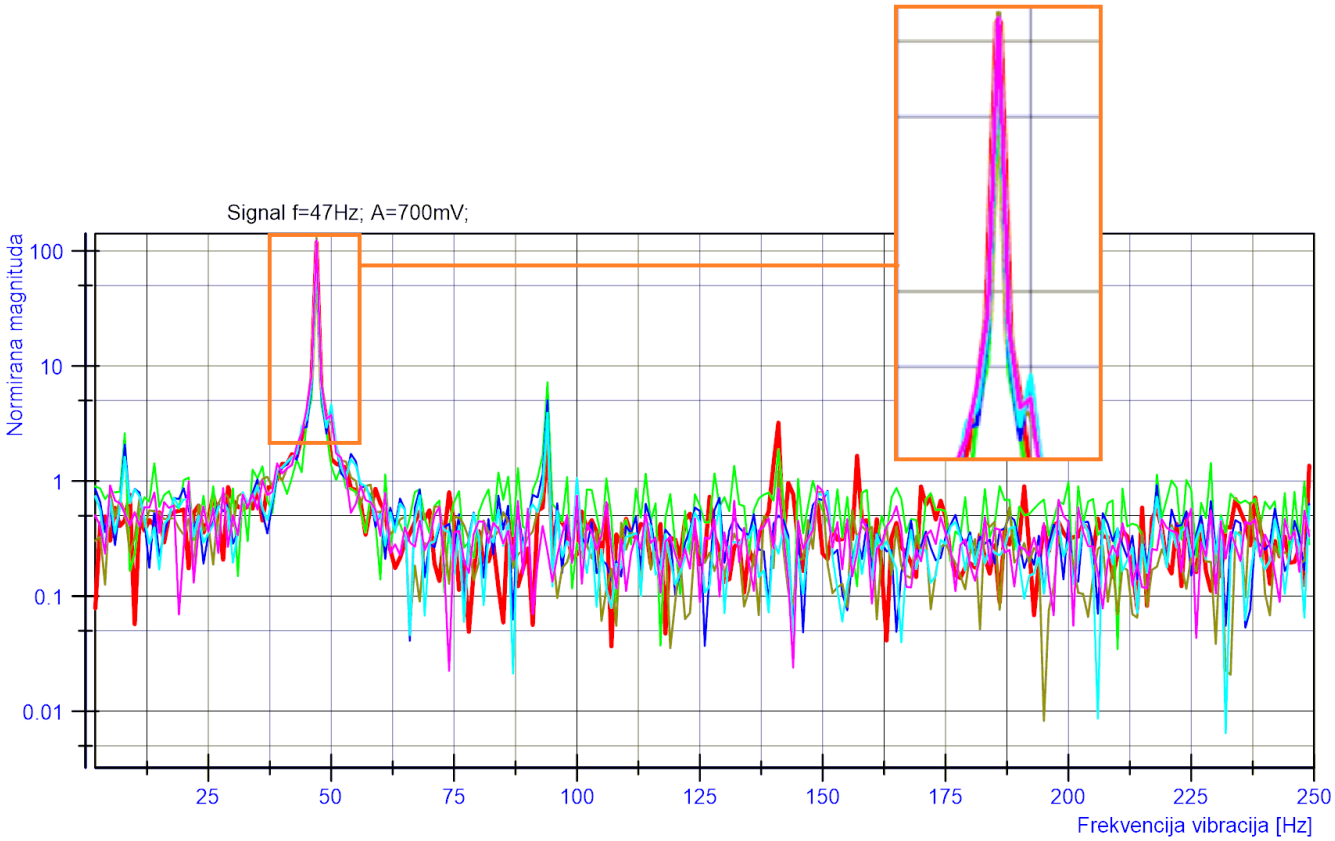

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det	118.16	47	3.21	141	2.14	94	15.66
	Correlation	72.04	47	7.22	94	2.60	8	9.99
	Corr. Ef.	110.63	47	5.04	94	4.54	50	13.41
	SumDiff	129.54	47	2.77	94	1.22	141	16.70
	PfPPD	120.77	47	4.65	50	3.91	94	14.15
	Mom.Ef1	123.56	47	3.76	50	1.43	39	15.17

Slika 6.16 n)

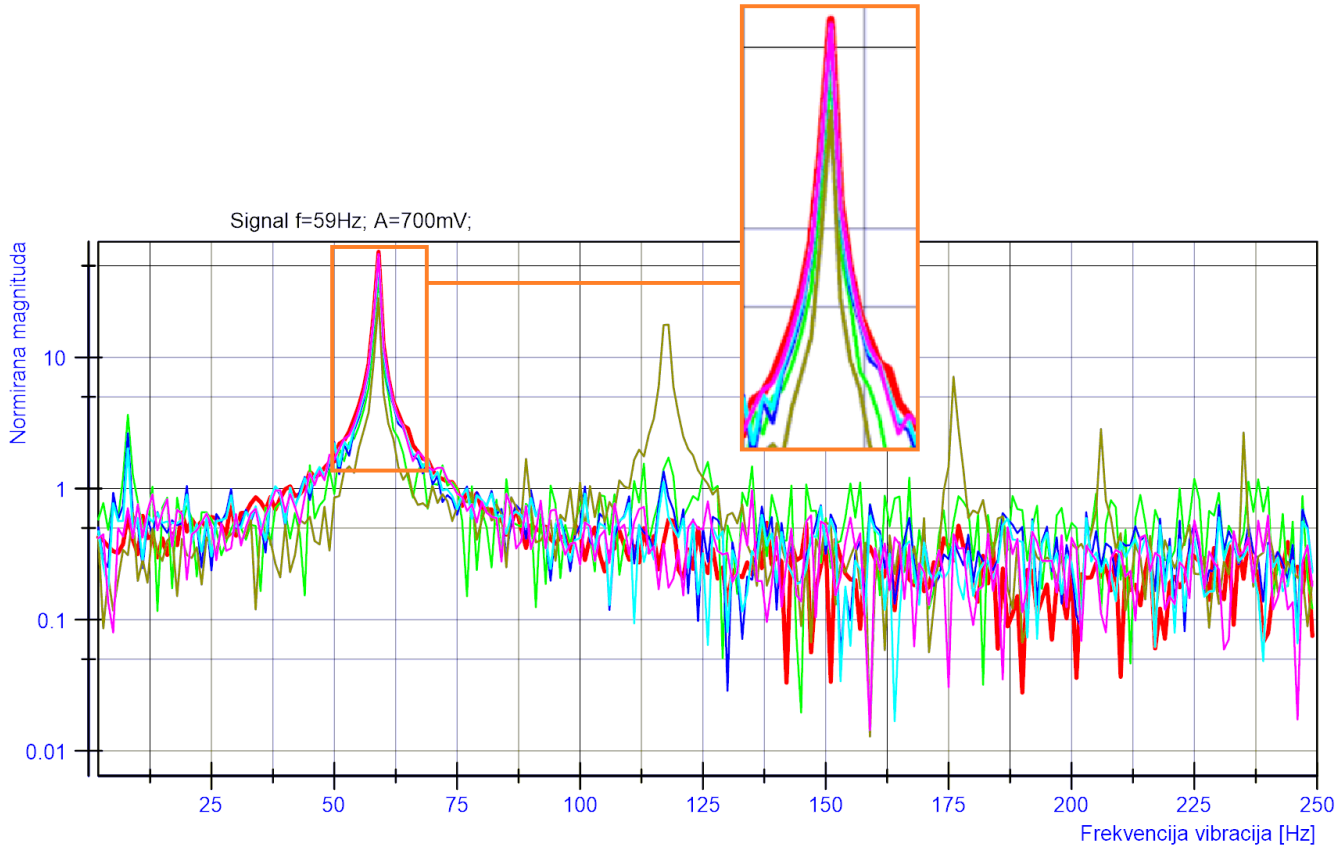

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det	63.63	59	1.34	45	1.04	41	16.77
	Correlation	42.77	59	3.64	8	2.04	51	10.70
	Corr. Ef.	54.78	59	2.64	8	2.27	50	13.17
	SumDiff	28.15	59	17.80	118	7.11	176	1.99
	PfPPD	58.54	59	2.29	52	2.20	50	14.08
	Mom.Ef1	61.31	59	1.91	67	1.81	49	15.06

Slika 6.16 o)

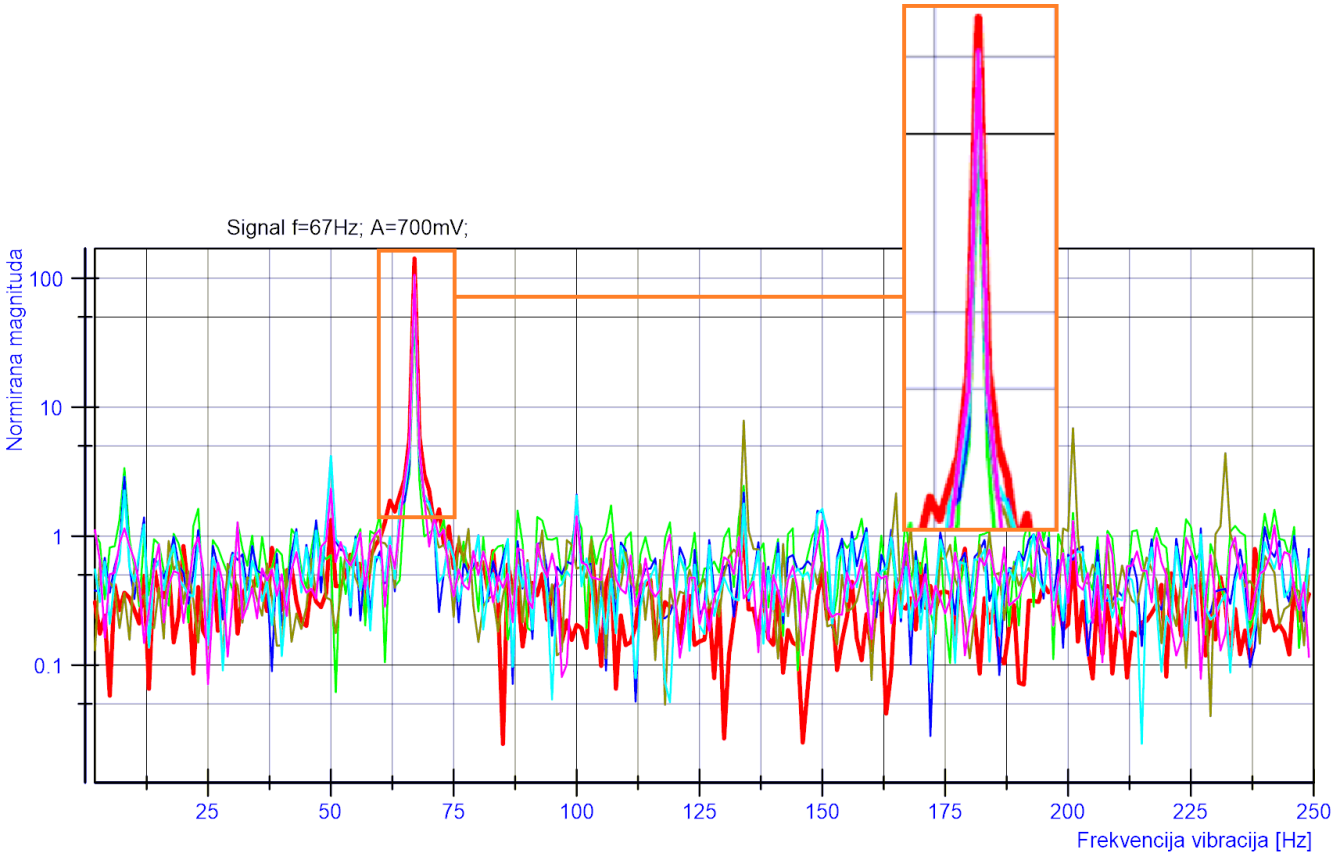

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det	141.93	67	1.88	62	1.61	72	18.78
	Correlation	56.80	67	3.37	8	2.46	134	12.27
	Corr. Ef.	87.45	67	4.18	50	2.88	8	13.21
	SumDiff	99.95	67	7.85	134	6.88	201	11.05
	PfPPD	102.99	67	4.19	50	2.26	8	13.91
	Mom.Ef1	105.86	67	2.34	50	1.43	100	16.56

Slika 6.16 p)

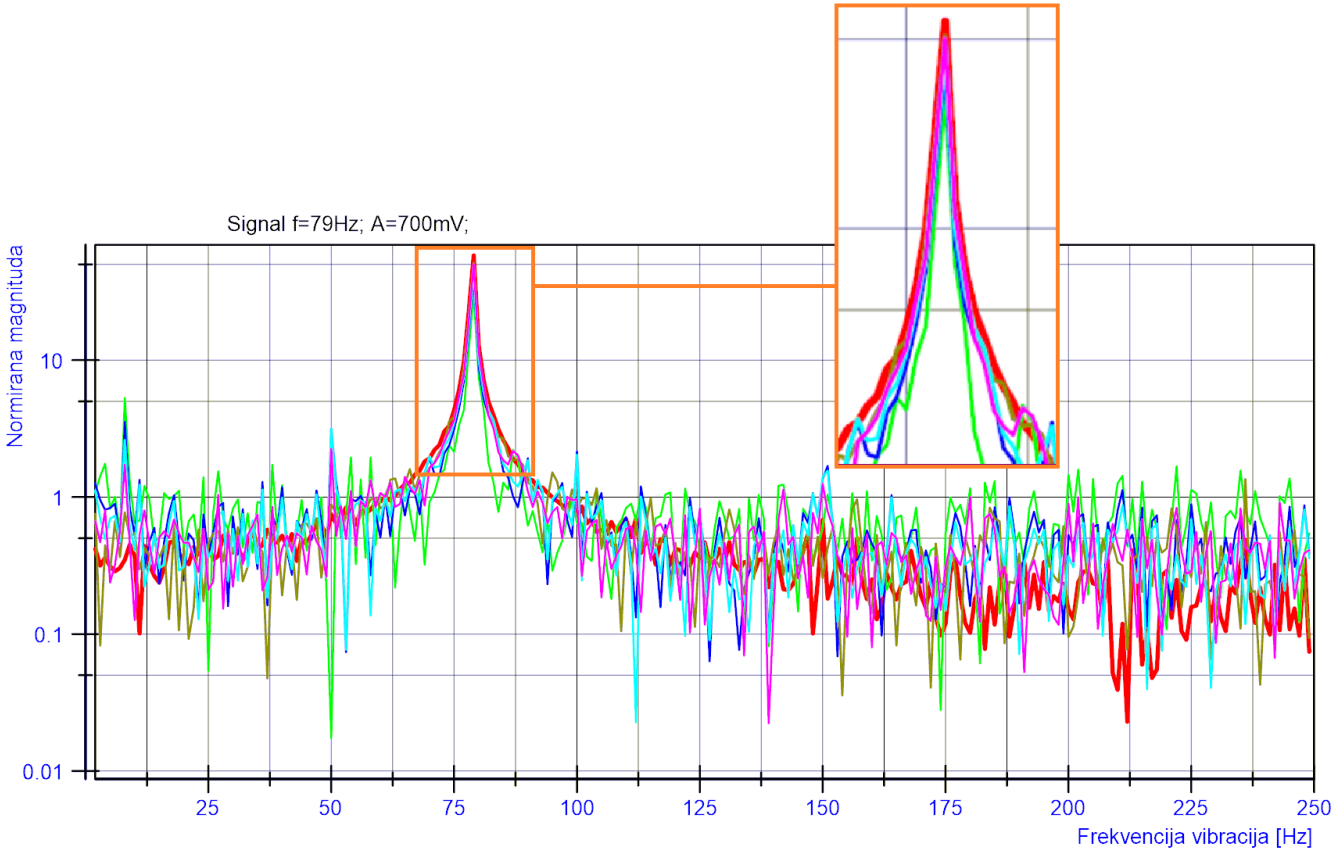

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det	58.03	79	0.99	61	0.95	99	17.68
	Correlation	31.04	79	5.29	8	2.38	74	7.68
	Corr. Ef.	41.39	79	3.54	8	3.16	50	10.68
	SumDiff	51.47	79	1.88	88	1.60	66	14.37
	PfPPD	46.79	79	3.16	50	2.60	8	11.70
	Mom.Ef1	50.22	79	2.25	50	2.18	87	13.49

Slika 6.16 q)

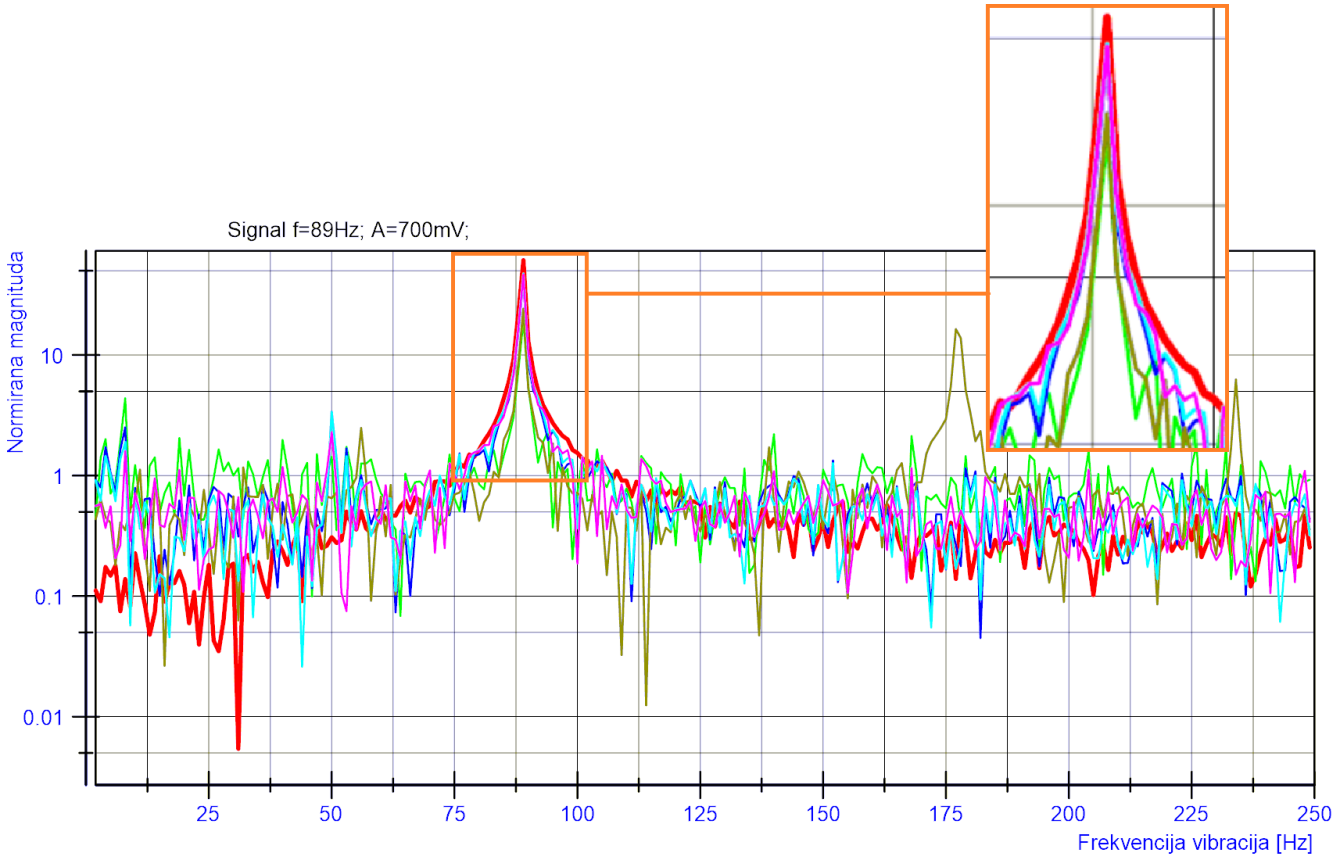

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det	61.08	89	1.49	78	1.33	105	16.13
	Correlation	19.51	89	4.38	8	2.32	94	6.49
	Corr. Ef.	42.99	89	3.38	50	2.51	8	11.04
	SumDiff	24.25	89	16.40	177	6.26	234	1.70
	PfPPD	47.29	89	3.37	50	2.38	95	11.47
	Mom.Ef1	46.31	89	2.28	50	1.75	96	13.08

Slika 6.16 r)

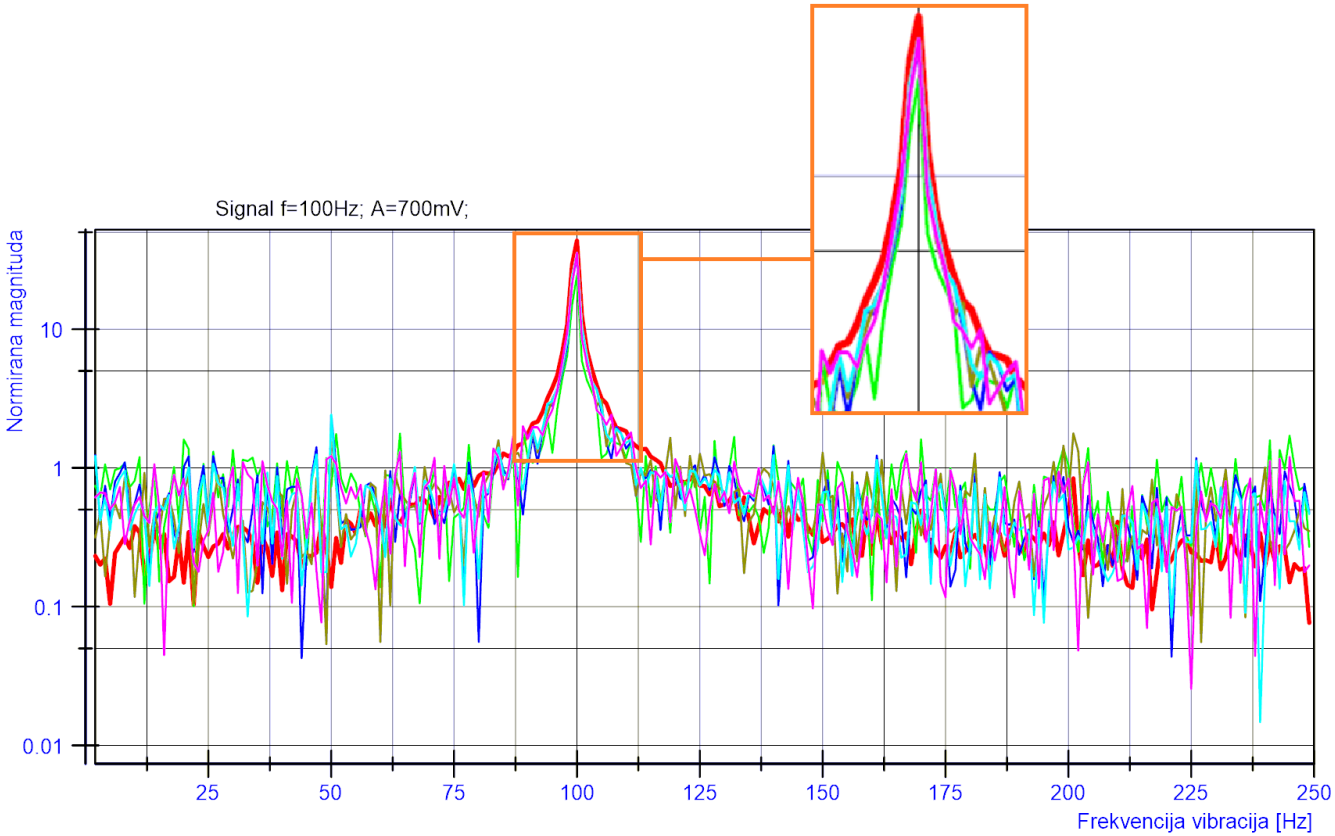

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det	43.59	100	1.38	114	1.27	85	15.00
	Correlation	24.44	100	2.23	94	1.92	89	10.40
	Corr. Ef.	32.33	100	2.89	94	2.40	50	10.49
	SumDiff	35.51	100	3.09	105	2.06	107	10.60
	PfPPD	35.25	100	2.42	50	1.93	91	11.63
	Mom.Ef1	35.45	100	2.40	107	2.00	89	11.69

Slika 6.16 s)

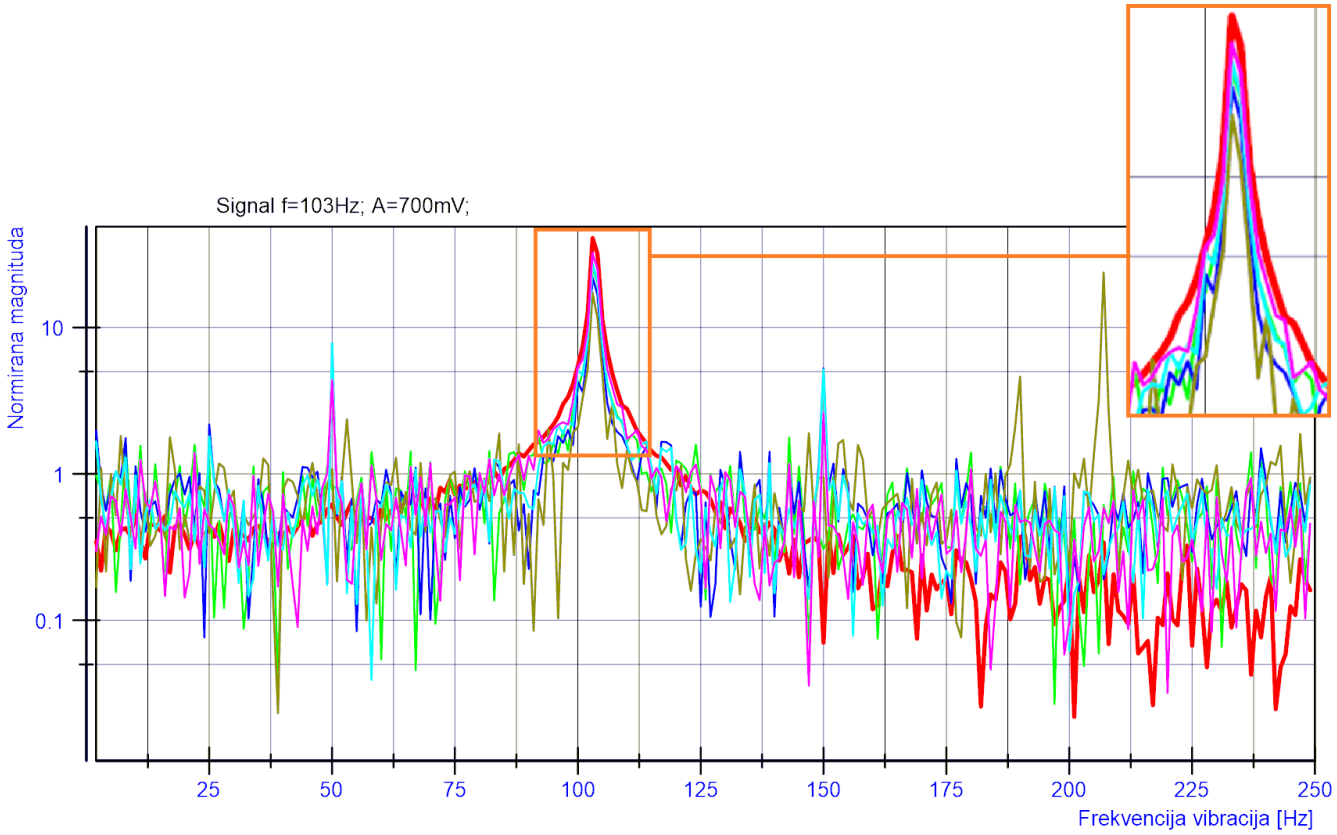

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det	40.74	103	1.38	88	1.07	120	14.70
	Correlation	25.26	103	1.98	97	1.86	111	11.06
	Corr. Ef.	22.00	103	7.81	50	5.26	150	4.50
	SumDiff	23.71	207	17.19	103	4.62	190	1.40
	PfPPD	27.41	103	7.79	50	5.16	100	5.46
	Mom.Ef1	32.19	103	4.37	50	2.60	150	8.67

Slika 6.16 t)

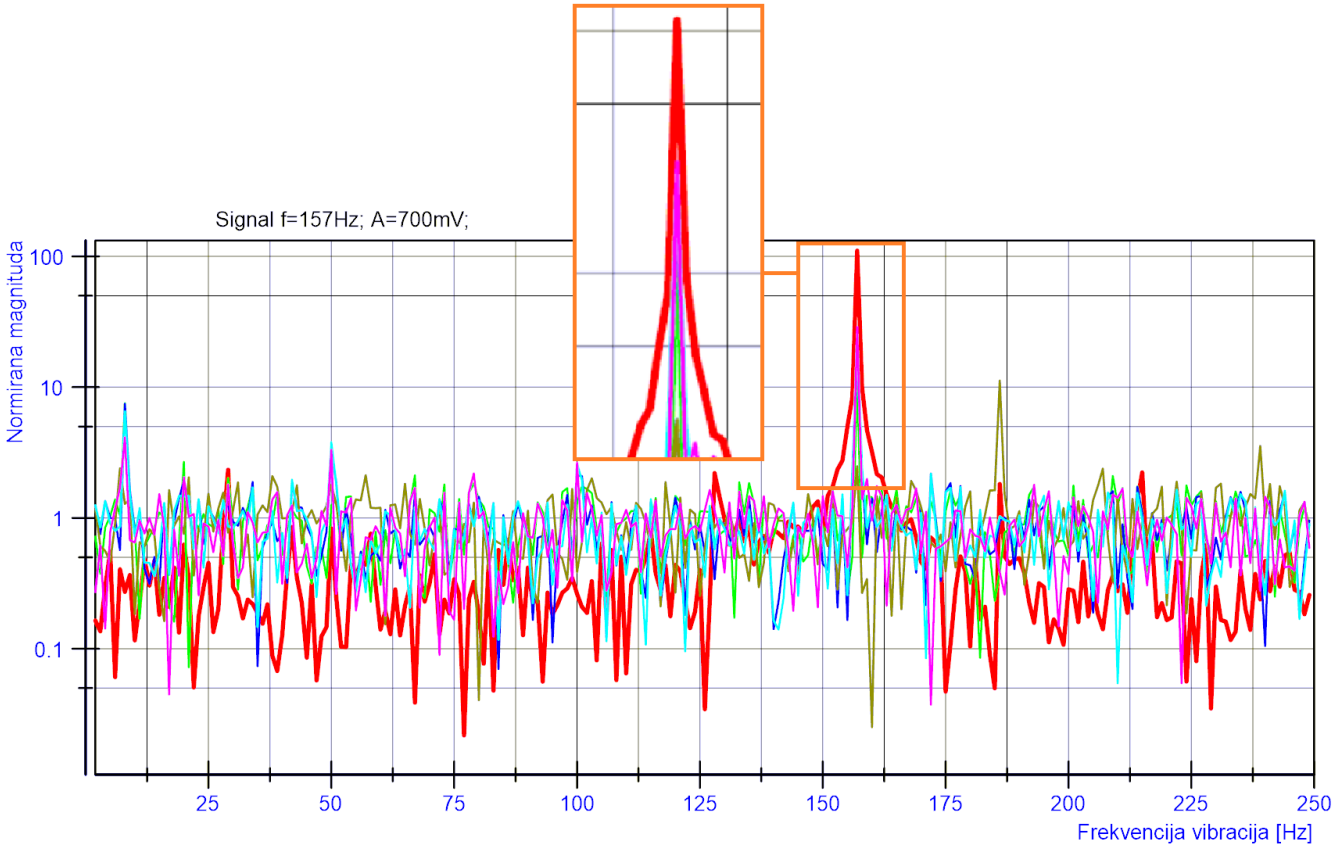

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det	110.56	157	2.34	29	2.23	215	16.74
	Correlation	11.23	157	7.55	8	2.69	20	1.72
	Corr. Ef.	18.43	157	7.45	8	3.11	50	3.93
	SumDiff	11.25	186	3.55	239	2.49	157	5.01
	PfPPD	25.47	157	6.58	1	6.51	8	5.88
	Mom.Ef1	28.85	157	4.14	8	3.33	50	8.43

6.3.6 Male detektorske diode i jako višemodno vlakno postavljeno u petlju

Iako nisu prezentirani kompletni rezultati za ovakvu konfiguraciju, ponuđen je detalj iz rezultata koji ukazuje na važnost primjene statističkih metoda izračuna.

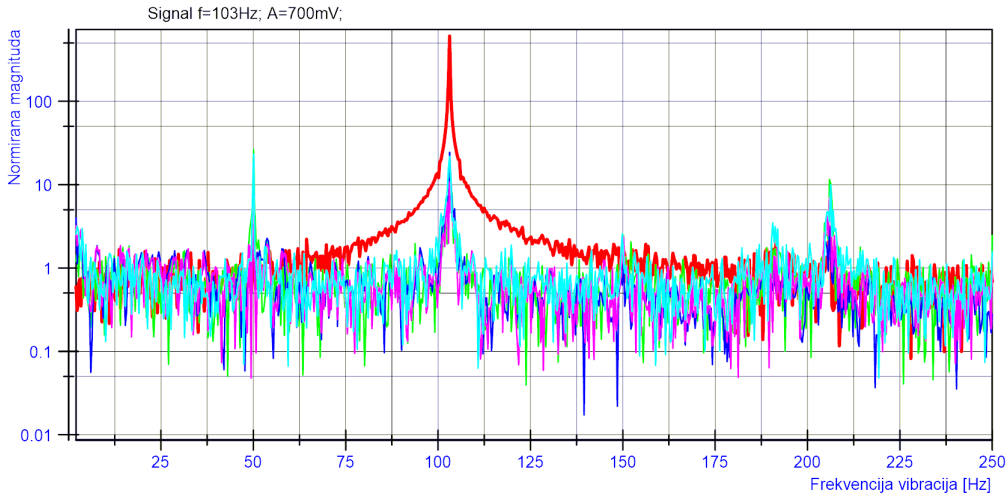

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det.	606.31	103	13.60	100	12.42	106	16.49
	D_gr	26.39	50	15.08	103	11.96	1	2.43
	D_bl	24.42	103	7.36	1	7.34	102	5.21
	D_vi	15.76	50	10.71	103	7.84	2	1.68
	D_tu	23.09	50	21.77	103	13.68	1	0.26

(a) Spektar diretkno iz signala dioda

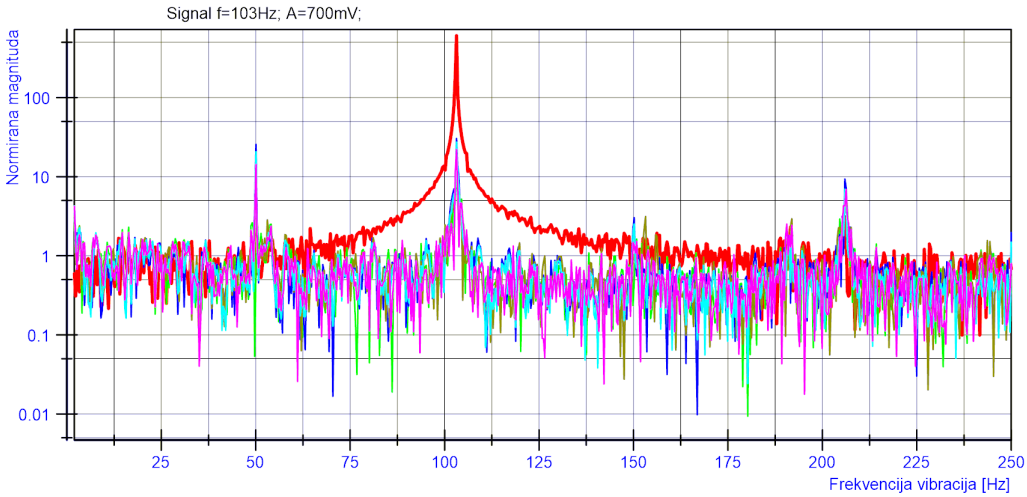

	Signal	Prva dominatna komponenta (PDK)	PDK frek. [Hz]	Druga dominatna komponenta (DDK)	DDK frek. [Hz]	Treća dominatna komponenta (TDK)	TDK frek. [Hz]	Omjer PDK/DDK[dB]
	Ctrl Det	606.31	103	13.60	100	12.42	106	16.49
	Correlation	14.22	103	7.74	1	5.51	206	2.64
	Corr. Ef.	30.43	103	25.68	50	9.36	206	0.74
	SumDiff	17.23	103	6.50	50	5.21	1	4.23
	PfPPD	27.30	103	20.54	50	6.92	206	1.24
	Mom.Ef1	22.07	103	14.25	50	8.08	1	1.90

(b) Spektar na temelju statističkog proračuna

Slika 6.17: Usporedba rezultata za direktnu detekciju diodama i proračun primjenom statističkih metoda

Pažljivim pregledom vrijednosti navedenih u tablicama ispod grafova, može se primijetiti da su u slučaju direktnog signala s detektorskih dioda 3/4 PDK prepoznate kao najizraženije na frekvenciji koja ne odgovara frekvenciji vibracija ili njenom višekratniku (50 Hz umjesto 103 Hz). Istovremeno su sve statističke metode analize rezultirale točnom detekcijom frekvencije vibracija. Ovaj rezultat je još značajniji ako se prisjetimo da se statistička analiza provodi nad signalima s detektorskih dioda, dakle istim onima koji su u pojedinačnoj samostalnoj analizi dali krivi rezultat. Ovaj primjer vrlo jasno ilustrira prednost primjene statističkih metoda obrade za utvrđivanje frekvecnije vibracija. Naime, iako je signal s jedne od detektorskih dioda omogućio ispravnu detekciju frekvencije vibracija (promatramo PDK frekvenciju), generalno ne postoji način za odabir *ispravne* diode. Statističke metode sve signale objedinjuju u jedinstveni signal čijom analizom izvlačimo najbolju šansu za detekciju iz dostupnih vrijednosti.

6.4 Diskusija eksperimentalnih rezultata

Na osnovi izvršenih opsežnih mjerenja pokazalo se da je ispravna detekcija frekvencije vibracija moguća i pouzdana predloženim mjernim sustavom. Moguća je na prikazanom rasponu frekvencija, ali i za više frekvencije prema tablici 6.1 s podjednakim stupnjem točnosti i pouzdanosti. U ovom radu nisu predstavljena sva obavljena mjerenja radi preopsežnosti. Posebno valja istaknuti da se metoda momenata (Mom. Ef) u konfiguraciji iz odjeljka 6.3.5 pokazala kao naročito uspješna, odnosno pouzdana s najboljim omjerom PDK/DDK, koji je na nižim frekvencijama usporediv s onim što daje kontrolni detektor.

Opravdanost uvođenja statističkih metoda obrade signala dobro ilustrira slika 6.17. Na njoj je prikazan rezultat detekcije za jednu od konfiguracija koja nije prezentirana među ostalim rezultatima. Iz usporedbe se jasno vidi da većina detektorskih dioda samostalno ne obavlja ispravnu detekciju, odnosno 3/4 prikazuju signal koji nije u direktnoj vezi s uzbudnim vibracijama. Bez obzira na to i činjenicu da se sve statističke metode temelje na signalima s tih istih dioda, sve metode ispravno detektiraju vibracije, odnosno pokazuju jednaku frekvenciju uzbudnih vibracija kao i kontrolni detektor.

Svi prezentirani rezultati su vezani uz jednaku vrijednost amplitude signala kontrolnog detektora U_{VV}=700 mV. Mjerenja su napravljena i u drugim točkama prema tablici 6.2, ali opet radi opsežnosti ne mogu biti prezentirana. Kao i u slučaju neprezentiranih pobudnih frekvencija, rezultati su podjednake točnosti i pouzdanosti kao i ovi koji su prezentirani.

Uspješno je pokazana opravdanost uvođenja polja diodnih detektora i statističkih metoda za obradu tako pribavljenih signala za detekciju vibracija pomoću točkastog uzorka svjetlovoda. Postoji određeno neslaganje između simuliranih rezultata i onih koji su proizašli iz mjerenja, ali konačni cilj koji je postavljen pred sustav je u potpunosti ostvaren. U svim provedenim mjernim scenarijima je zabilježena uspješna detekcija ispravne frekvencije vibracija upotrebom

predstavljenih (namjenskih) statističkih metoda i rezultati su potvrđeni usporedbom s kontrolnim detektorom komercijalne namjene.

Napomenimo na kraju i da je svjetlovodni detektorski sustav mogao detektirati i manje akceleracije (odnosno amplitude vibracija) od najmanjih iz tablice 6.2 za koje su mjerenja obavljena. Međutim, takve vrijednosti su izvan mjernog dosega korištenog kontrolnog detektora, a bez referente vrijednosti daljnja mjerenja nisu imala smisla, pa je taj dio istraživanja ostavljen za neke buduće napore.

6.5 Diskusija neusklađenosti simuliranih i eksperimentalnih rezultata

Iako na prvi pogled simulacijski rezultati odudaraju od eksperimentalnih, postoji jasan razlog za prividnu nesukladnost.
Simulacijskim rezultatima je pokazano da se informacija o promjenama distribucije energije u točkastom uzorku, odnosno promjenama rasporeda modova u svjetlovodu, nalazi i u dijelu slike koji je manji od ukupnog. Sustavnim pristupom pokazano je da se veličina segmenta slike može smanjivati do krajnjih granica simulacijskog sustava, ali što je još važnije, da se statističkom obradom kombinacije nekoliko takvih segmenata može relativno pouzdano doći do rezultata, odnosno do tražene informacije o prisutnim vibracijama. Simulacije su poslužile kao dobar putokaz za broj, veličinu i pozicioniranje dioda, te za testiranje statističkih pristupa u obradi kombiniranih signala. Prelaskom na eksperimentalni sustav ustanovljeno je da rezultati nisu najbolji za najmanje diode, odnosno da detektor sa sustavom relativno velikih dioda daje bolje i pouzdanije rezultate negoli onaj s relativno malenim diodama. Ovo odstupanje je posljedica frekvencije uzorkovanja. Naime, iako je simuliranje veličine detektora kao segmenta sveukupne slike bilo relativno jednostavno, simulacija je bila nepotpuna. Između simulirane diode i stvarne je ključna razlika u vremenu integracije/akvizicije signala.

6.5.1 Proces akvizicije slike kamerom

Kako je u slučaju stvarnih dioda najmanja frekvencija uzorkovanja bila oko 40 puta veća od one za koju su prezentirani rezultati simulacija, energija koja je u tom vremenu dospjela na detektor je u skladu s time sigurno značajno manja. Nemoguće je reći koliko manja jer priljev energije na detektor nije konstantan već ovisi o mehaničkoj pobudi kojoj je svjetlovod u tom vremenu izložen. Upravo iz toga slijedi ključna razlika između detekcije segmentiranom slikom kamere i detekcije realnim diodama, te objašnjenje razlike u rezultatima. Kod simuliranih dioda frekvencija uzorkovanja je oko 12,2 Hz. Vrijeme akvizicije upadne energije za svaki od piksela slike je otprilike 82ms. Otprilike, jer detekcija po površini slikovnog detektora nije garantirano ravno-

mjerna (po više kriterija). U tom vremenu je obuhvaćeno *osvjetljavanje* detektora, ali i vrijeme potrebno za *čitanje* vrijednosti za sve pojedinačne detektore (piksele) i njihovo resetiranje kao priprema za sljedeću akviziciju. S obzirom da se radi o velikom broju pojedinačnih detektora, teško je reći koliko je točno vrijeme integracije upadnog signala, ali svakako nešto kraće od 82ms. S obzirom da potrebni tehnički podaci o korištenoj kameri nisu dostupni, jer značajno nadilaze informacije uobičajene za konzumerske web kamere, stvarno vrijeme integracije signala nije moguće odrediti. U literaturi se općenito navodi vrijeme od nekoliko stotina μs do nekoliko desetaka ms ovisno o tipu sustava i veličini detektora (broju piksela). Za ovu kameru, s obzirom na dostupne podatke, relativno je razumna pretpostavka od 1-2 ms sistemskog vremena potrebnog za *čitanje* slike. U preostalom vremenu od 80 ms integracije upadne svjetlosne energije dolazi do gubitka informacija o bržim promjenama. S obzirom da se preraspodjele točkastog uzorka događaju praktički kaotično, u tako dugom vremenu integracije na većim promatranim površinama dolazi do gotovo potpunog usrednjavanja signala. Smanjenjem površine akvizicije/integracije postiže se veća varijacija signala detektora za promatrani segment i time se omogućuje detekcija, ali samo za najmanje segmente.

6.5.2 Proces akvizicije signala fotodiodama

U eksperimentalnom sustavu u kojem je detektor formiran kombinacijom signala polja fotodioda, svaka dioda je imala vlastiti rezervirani kanal za akviziciju. Akvizicija je obavljana frekvencijom 500 Hz, odnosno vrijeme akvizicije je bilo 2 ms. Iako je nemoguće ustanoviti koliko je stvarno vrijeme integracije signala, činjenica je da je brzina rada ovog sustava daleko veća nego je to slučaj kod CCD kamere. Naime, analogno digitalni konverter koji se koristio za akviziciju frekvencijom 500 Hz podržava frekvencije uzorkovanja do 200 kHz. Iz toga proizlazi da je vrijeme koje je rezervirano za rad sustava zanemarivo u odnosu na 2 ms. Dakle, ako ustvrdimo da je vrijeme integracije 2ms vjerojatno radimo potpuno zanemarivu grešku. Osim akvizicijskog sustava potencijalno *usko grlo* za brzinu rada su i diode. Međutim, tipična brzina rada koju one podržavaju je daleko iznad frekvencija koje su korištene i vrijeme reakcije, odnosno porasta/pada signala, je u pravilu reda veličine ns ili stotinjak ps. Konkretno za diodu FDS025 je navedeno *Rise/Fall time* = 47/246 ps, dok je za diodu S6775 samo navedeno da je *high speed*.

Uz takvo, značajno kraće vrijeme akvizicije, mogućnost da se integracijom signal s detektora usrednji u odnosu na promjene koje se u vlaknu događaju, je znatno manja. Isto tako, ukupna količina energije koja upada na detektore je znatno manja jer je vrijeme prikupljanja energije znatno kraće nego za kameru. U slučaju manjih dioda (FDS025) je to dovelo do izazito malene razine signala po uzorku. Iz tog razloga su se veće diode pokazale kao bolje rješenje, iako je to na prvi pogled u kontradikciji s rezultatima simulacija.

Naposljetku, simulacije su predvidjele najbolju detekciju diodama veličine 1^2 ili 2^2 px^2, dok

su eksperimentalni rezultati pokazali jako dobru detekciju diodama veličine 19^2 px^2. Omjer površina između eksperimentalno korištenih dioda i simuliranih je 361/4≈90. Omjer između procijenjenih vremena integracije u eksperimentalnom i simulacijskom sustavu je procijenjen okvirno na 2/80 uz veliki broj nepoznatih parametara, što nas dovodi u isti red veličine kao i kod omjera površina. Preostala razlika u omjerima može se pripisati promjeni tipa svjetlovoda. Naime, za snimanje videa na kojima su provođene simulacije korišteno je jako višemodno vlakno, a najbolji eksperimentalni rezultati su postignuti uz primjenu standardnog višemodnog vlakna. Kako je prikazano na slici 6.13, točkasti uzorak specijalnog višemodnog vlakna se sastoji od više manjih elemenata negoli je to slučaj kod standardnog višemodnog vlakna. Ta razlika u zrnatosti teksture se zapravo može povezati s virtualno manjom površinom diode u odnosu na "točke" uzorka standardnog vlakna, tj. omjer između veličine elemenata uzorka i površine diode je manji nego što je to slučaj za jako višemodno vlakno. Iako je nemoguće brojčano odrediti tu razliku u omjerima, slika nam daje za pravo da okvirno procijenimo da se radi o nekoliko puta većim elementima točkastog uzorka za standardno u odnosu na specijalno višemodno vlakno. Tih *nekoliko puta* je faktor koji nam nedostaje u izjednačavanju omjera površina i vremena integracije kod usporedbe simuliranih i stvarnih dioda.

Poglavlje 7

Zaključak

Predstavljeni rad opisuje istraživanje kojem je konačni cilj bila izrada funkcionalnog svjetlovodnog senzora za mjerenje vibracija na temelju promjena u raspodjeli točkastog uzorka signala u višemodnom svjetlovodu. S obzirom na postojanje većeg broja sličnih rješenja za mjerenje pomoću svjetlovoda u jednoj točki, želja je bila izvesti senzorski sustav pogodan za integrirano mjerenje duž cijelog vlakna što bi omogućilo nadzor u slučaju velikih struktura poput mostova ili visokih zgrada, odnosno za nadzor štićenih područja. Kako bi ovakav sustav bio opravdan, njegova cijena je morala biti dovoljno niska za implementaciju u velikim dimenzijama od nekoliko stotina metara. Tada opravdanost ovakvog sustava dolazi do izražaja u odnosu na ostale, klasičnije, pristupe. Istraživanje za realizaciju takvog senzorskog sustava se odvijalo u nekoliko faza.

U prvoj fazi je izrađen prototip koji je kao detektor koristio CCD kameru niske cijene. Iako je ona zbog vlastite brzine rada nametnula vrlo oštro ograničenje funkcionalnosti sustava za frekvencije iznad 10ak Hz, poslužila je da se dokaže mogućnost detekcije vibracija i određivanje njihove frekvencije. Time je pripremljen teren za daljnje istraživanje. Uklanjanje ograničenja na očiti način - nabavkom bolje kamere - narušilo bi jednu od osnovnih motivacija istraživanja (nisku cijenu), te je odlučeno istražiti alternativne mogućnosti za detekciju promjena u točkastom uzorku. Ideja je bila reducirati kameru na njene osnovne elemente - piksele, te potom ustanoviti parametre takvih pojedinačnih elemenata koji su nužni za uspješnu detekciju.

Cilj druge faze bio je analizirati podatke dobivene mjernim sustavom sa CCD kamerom i na osnovu zaključaka analize odrediti startegiju zamjene senzorskog elementa – CCD kamere. Iako su rezultati ubrzo pokazali da je detekciju moguće obaviti s manjim dijelom slike točkastog uzorka signala, bilo je potrebno odrediti koliko takvih dijelova treba biti, koja je pogodna veličina pojedinačnih elemenata, koja je najbolja pozicija odnosno raspored za detekciju. Takvi dijelovi CCD senzora trebali su biti zamijenjeni detektorskim diodama i bilo je važno optimizirati parametre kako bi konačni sustav detektorskih dioda bio što jednostavniji (manji). Ključni problem je bila kaotična priroda točkastog uzorka i činjenica da nije moguće znati na kojem

dijelu uzorka će doći do promjene zbog vanjskih utjecaja. Procesom simulacija ustanovljeni su pogodni parametri za izradu fizičkog senzorskog sustava za mjerenje vibracija i istraživanje je moglo prijeći u sljedeću fazu.

U trećoj fazi je izrađen sustav temeljen na zaključcima prethodnog istraživanja. Broj detektorskih dioda je značajno reduciran u odnosu na broj piksela prethodno korištene kamere. Sa samo četiri diode realizirano je detektorsko polje u vrhovima pravokutnika koji je smješten unutar granica točkastog uzorka. Signali iz tih četiriju dioda su analizirani primjenom statističkih metoda obrade signala, što je osiguralo da je u konačnom rezultatu zastupljen signal sa svake od detektorskih dioda. Time je praktički onemogućeno da se promjena u točkastom uzorku u nekom trenutku dogodi neprimjetno za detektorski sustav (što bi bio slučaj kada bi se koristila samo jedna dioda). Istovremeno, diode nisu bile prevelike, pa na njihovim površinama nije dolazilo do kritičnog usrednjavanja signala prilikom promjena, što bi također rezultiralo maskiranjem promjena u točkastom uzorku, odnosno djelovanja vanjske sile na svjetlovod. Izrađeni sustav je potvrdio rezultate simulacija i uspješno odradio ulogu detekcije vibracija i određivanja njihove frekvencije za sve mjerene situacije. Gornja frekvencija za detekciju je limitirana brzinom rada dioda i sustava za akviziciju signala s njih, te nije dosegnuta u mjerenjima koja su provedena. Pri tome se cijene sustava nije promijenila, iako je funkcionalnost znatno unaprijeđena.

Konačni rezultat je svjetlovodni vibracijski senzor za integrirano mjerenje, temeljen na točkastom uzorku. Pogodan je za ugradnju na velikim strukturama ili oko štićenih područja, a cijena mu je vrlo niska u usporedbi s drugim rješenjima koja istovremeno ne mogu ponuditi usporedive rezultate. Osjetljiv je po sve tri osi. Uz manje modifikacije moguće ga je koristiti i u nadzoru vibracija električnih strojeva.

Dodatak A

Mjerenje amplitude vibracija

Iako ova problematika nije bila primarna motivacija pri izradi ovog rada, prikupljena je dovoljna količina podataka da se mogu ponuditi neke osnovne informacije o takvim mogućnostima. Rezultati će biti ponuđeni bez opsežne diskusije i analize, uz naznaku da se i u ovom slučaju radi o vrlo uskom izboru od ukupno prikupljenih rezultata mjerenja.

Prikazani rezultati su prikupljeni u istim eksperimentalnim uvjetima kao i oni prikazani u 6.3, uključujući frekvencijske i amplitudne raspone, a odnose se na konfiguraciju koja je u detekciji frekvencije dala najbolje rezultate - velike diode i standardno višemodno vlakno postavljeno u petlju.

Na slikama je osim krivulje koja odgovara rezultatima analize statističkim metodama prikazana i linearna aproksimacija pravcem koji se najbolje poklapa sa stvarnim mjernim točkama. Kao dodatni parametar u legendi na grafovima ponuđena je mjera poklapanja linearne aproksimacije s izmjerenim točkama za svaku od krivulja. Za kontrolni detektor mjera, naravno, iznosi 1. Referentna krivulja je crvena, i ona prikazuje rezultate za kontrolni detektor. Najbolju linearnost pokazuje metoda momenata (Mom. Ef), koja je i kod detekcije frekvencije vibracija davala najstabilnije rezultate.

A.1 Usporedba linearnosti odziva različitih statističkih metoda obrade signala

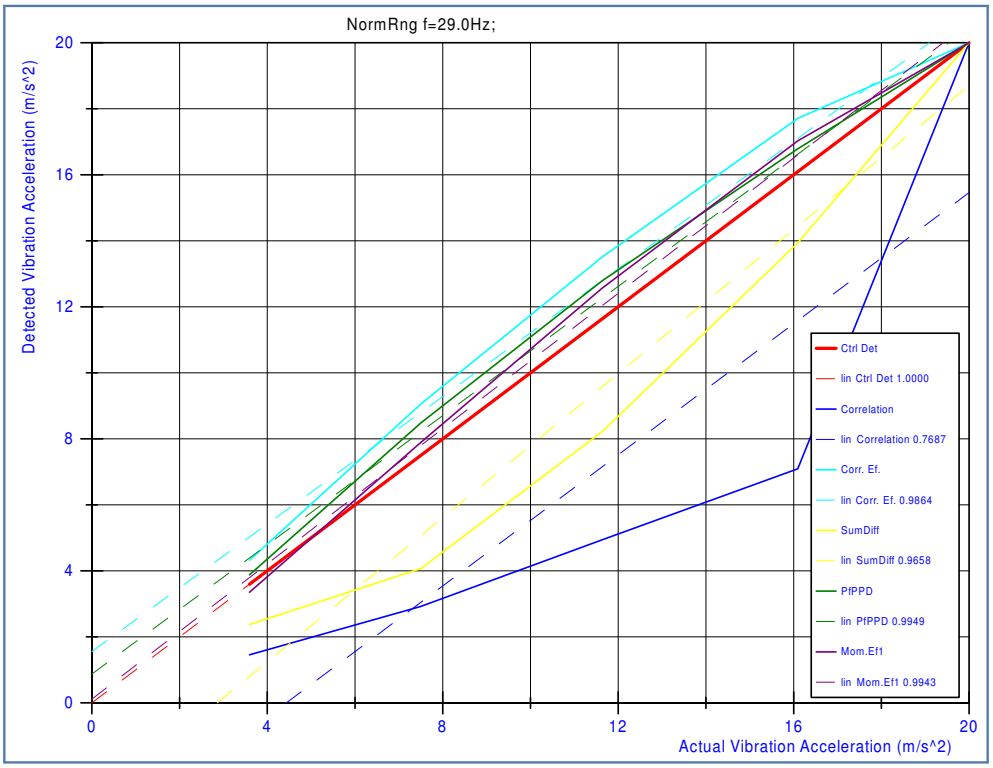

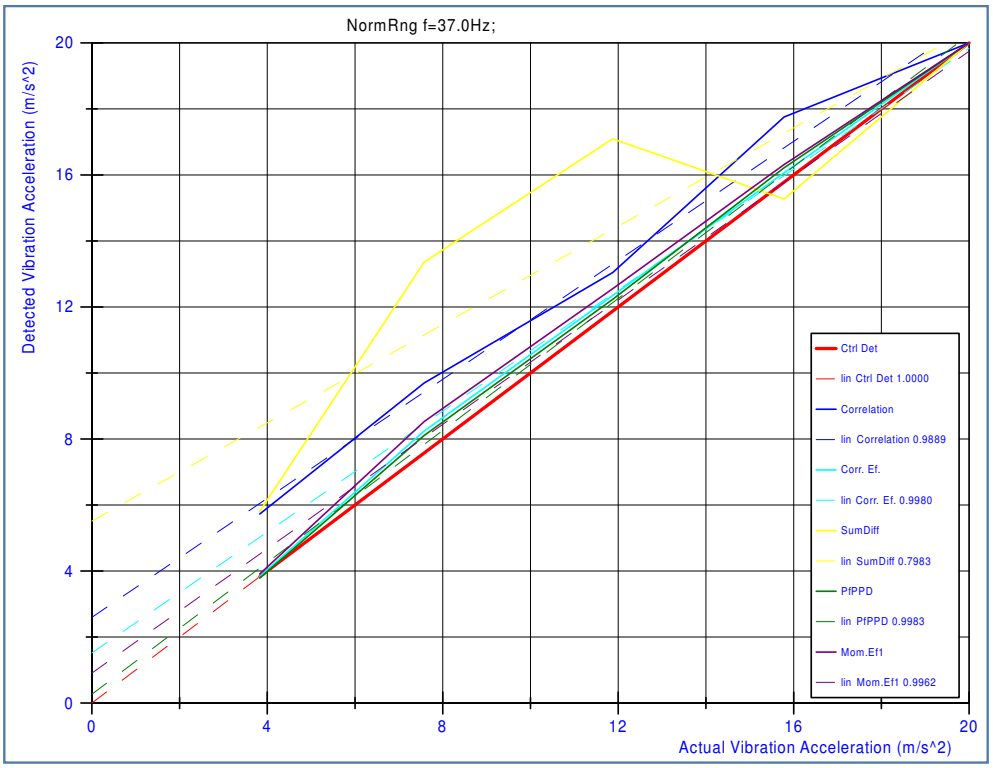

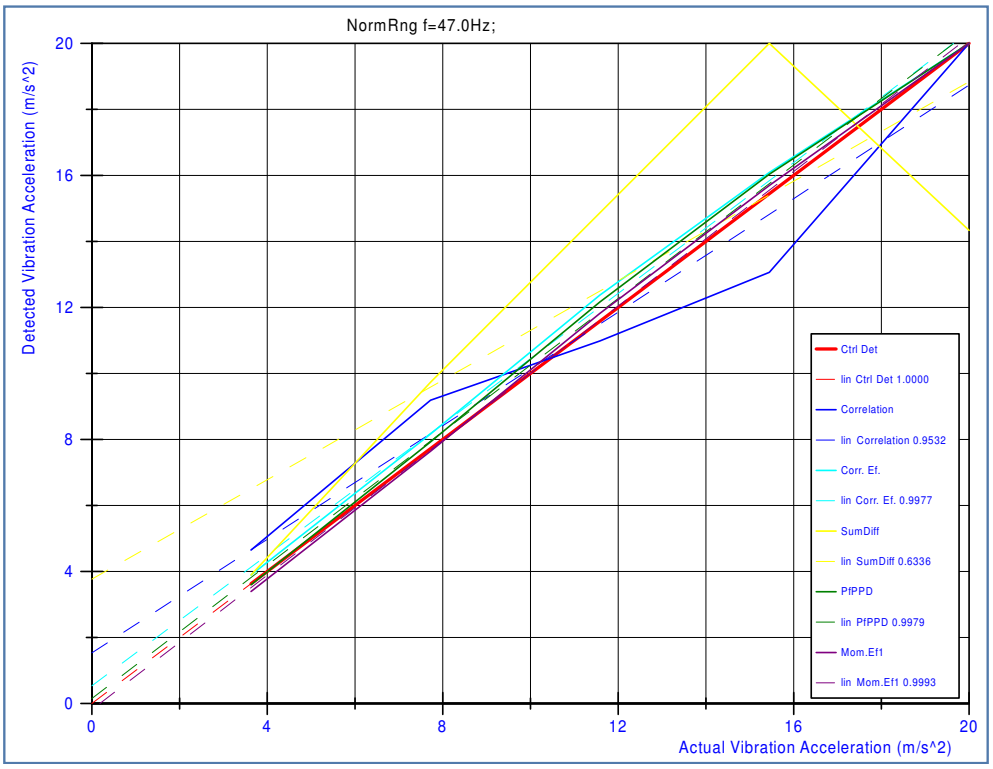
NormRng f=47.0Hz;
Detected Vibration Acceleration (m/s^2)
Actual Vibration Acceleration (m/s^2)
0
4
8
12
16
20
Ctrl Det
lin Ctrl Det 1.0000
Correlation
lin Correlation 0.9532
Corr. Ef.
lin Corr. Ef. 0.9977
SumDiff
lin SumDiff 0.6336
PfPPD
lin PfPPD 0.9979
Mom.Ef1
lin Mom.Ef1 0.9993

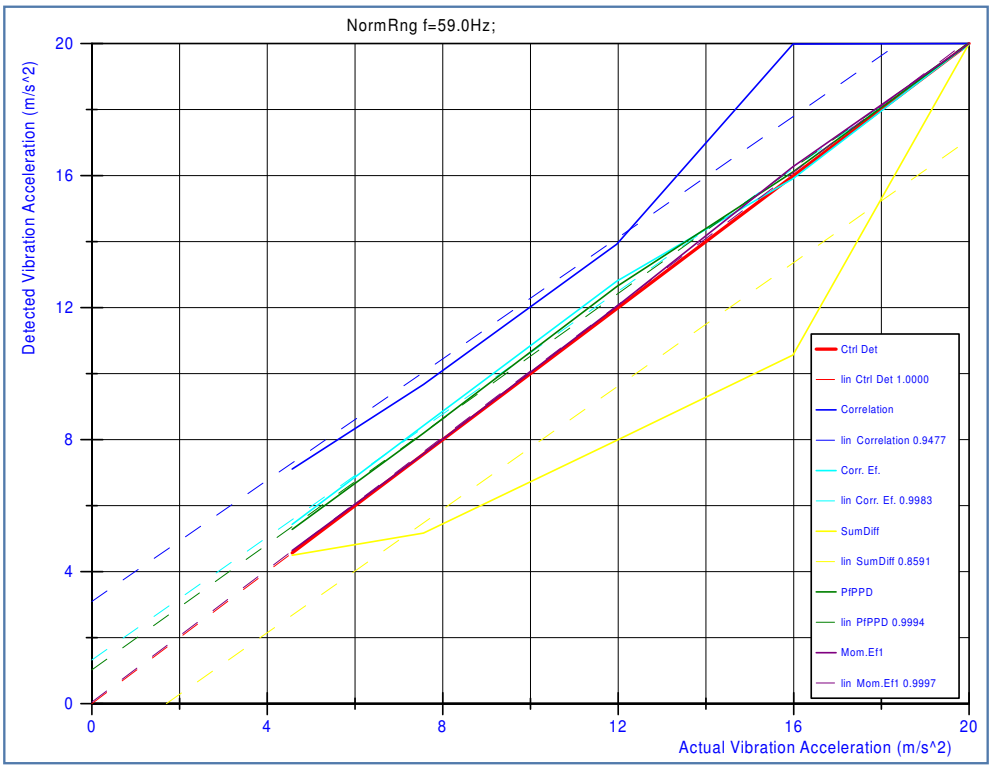
NormRng f=59.0Hz;
Detected Vibration Acceleration (m/s^2)
Actual Vibration Acceleration (m/s^2)
0
4
8
12
16
20
Ctrl Det
lin Ctrl Det 1.0000
Correlation
lin Correlation 0.9477
Corr. Ef.
lin Corr. Ef. 0.9983
SumDiff
lin SumDiff 0.8591
PfPPD
lin PfPPD 0.9994
Mom.Ef1
lin Mom.Ef1 0.9997

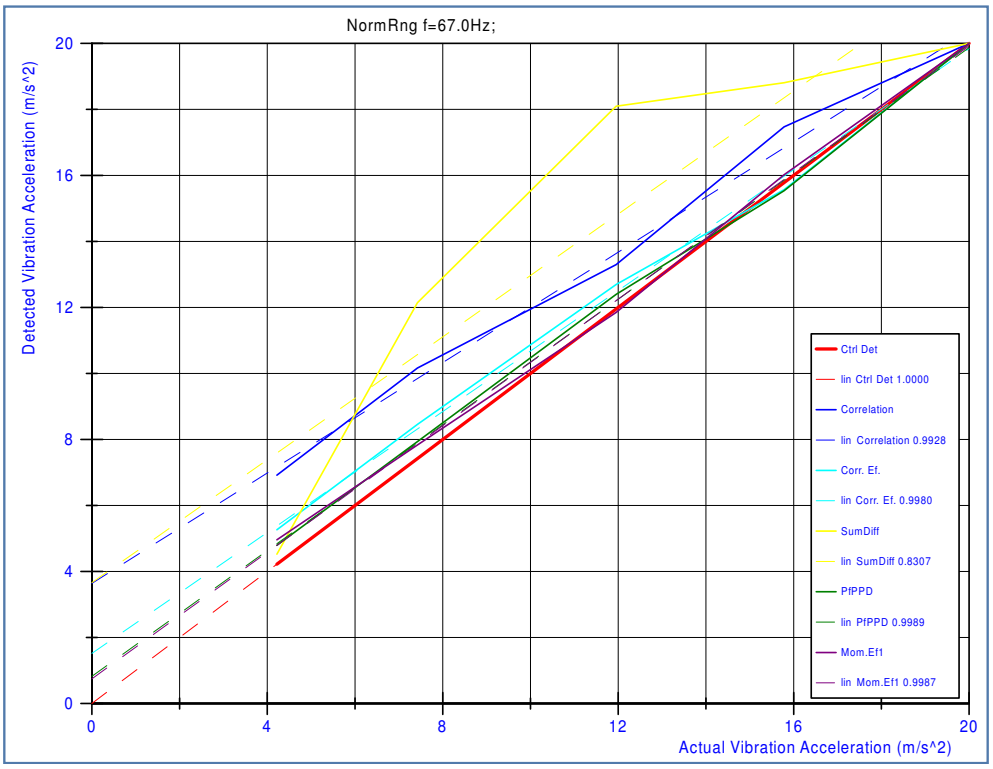
NormRng f=67.0Hz;
Detected Vibration Acceleration (m/s^2)
Actual Vibration Acceleration (m/s^2)
0
4
8
12
16
20
Ctrl Det
lin Ctrl Det 1.0000
Correlation
lin Correlation 0.9928
Corr. Ef.
lin Corr. Ef. 0.9980
SumDiff
lin SumDiff 0.8307
PfPPD
lin PfPPD 0.9989
Mom.Ef1
lin Mom.Ef1 0.9987

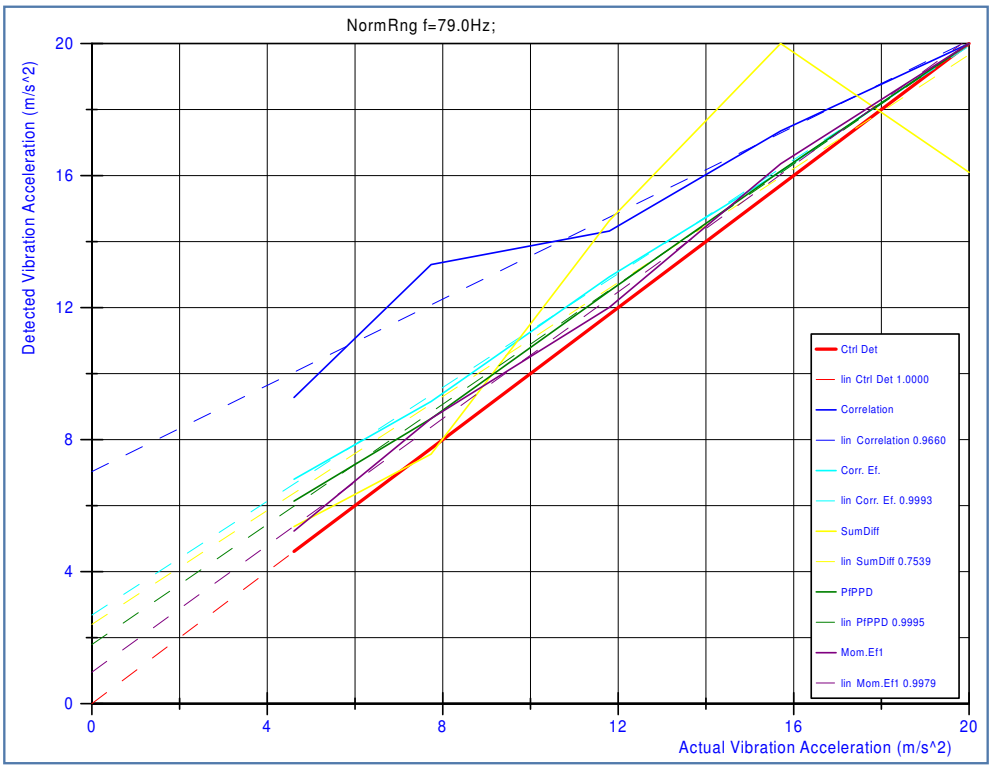
NormRng f=79.0Hz;
Detected Vibration Acceleration (m/s^2)
Actual Vibration Acceleration (m/s^2)
0
4
8
12
16
20
Ctrl Det
lin Ctrl Det 1.0000
Correlation
lin Correlation 0.9660
Corr. Ef.
lin Corr. Ef. 0.9993
SumDiff
lin SumDiff 0.7539
PfPPD
lin PfPPD 0.9995
Mom.Ef1
lin Mom.Ef1 0.9979

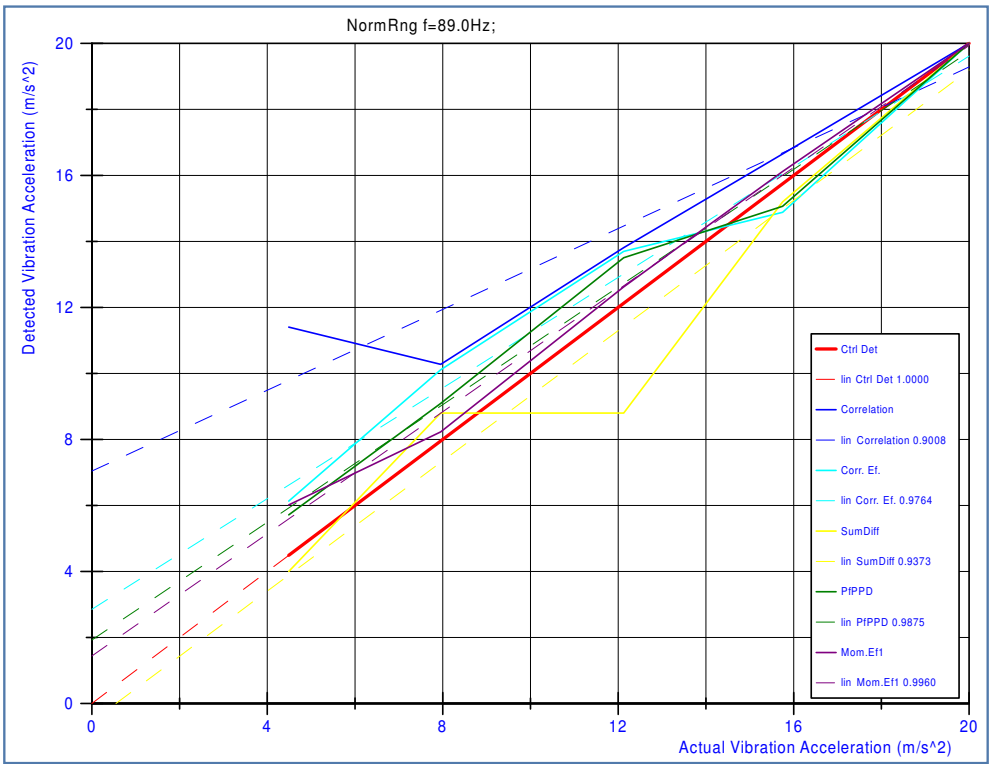
NormRng f=89.0Hz;
Detected Vibration Acceleration (m/s^2)
Actual Vibration Acceleration (m/s^2)
0
4
8
12
16
20
Ctrl Det
lin Ctrl Det 1.0000
Correlation
lin Correlation 0.9008
Corr. Ef.
lin Corr. Ef. 0.9764
SumDiff
lin SumDiff 0.9373
PfPPD
lin PfPPD 0.9875
Mom.Ef1
lin Mom.Ef1 0.9960

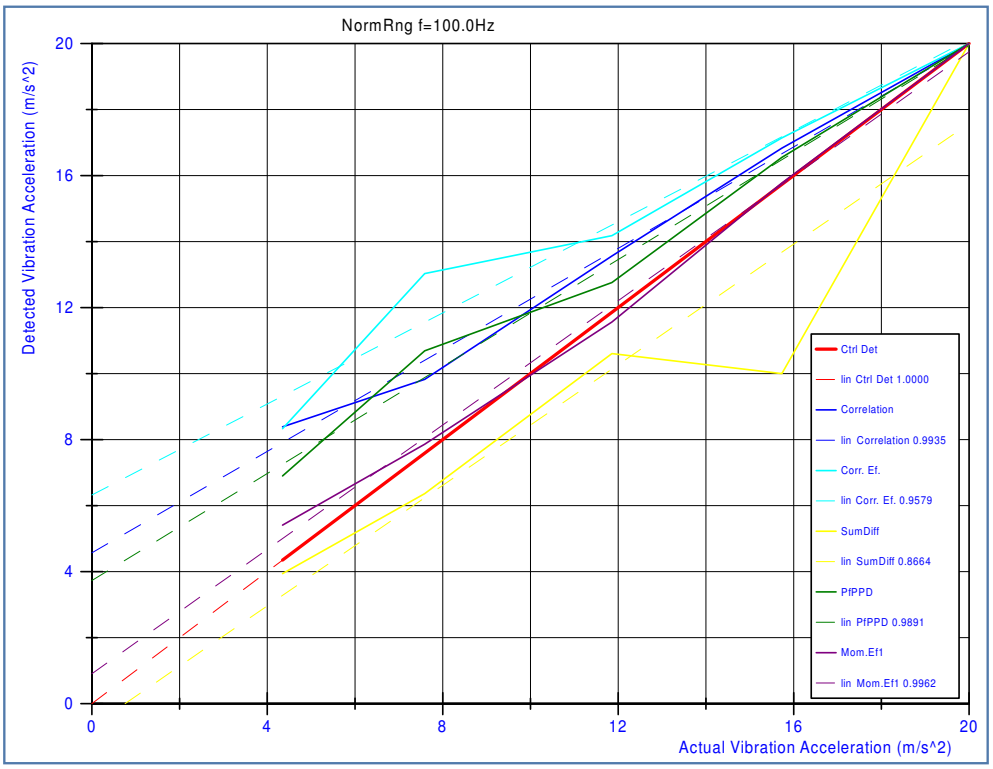
NormRng f=100.0Hz
Detected Vibration Acceleration (m/s^2)
Actual Vibration Acceleration (m/s^2)
0
4
8
12
16
20
Ctrl Det
lin Ctrl Det 1.0000
Correlation
lin Correlation 0.9935
Corr. Ef.
lin Corr. Ef. 0.9579
SumDiff
lin SumDiff 0.8664
PfPPD
lin PfPPD 0.9891
Mom.Ef1
lin Mom.Ef1 0.9962

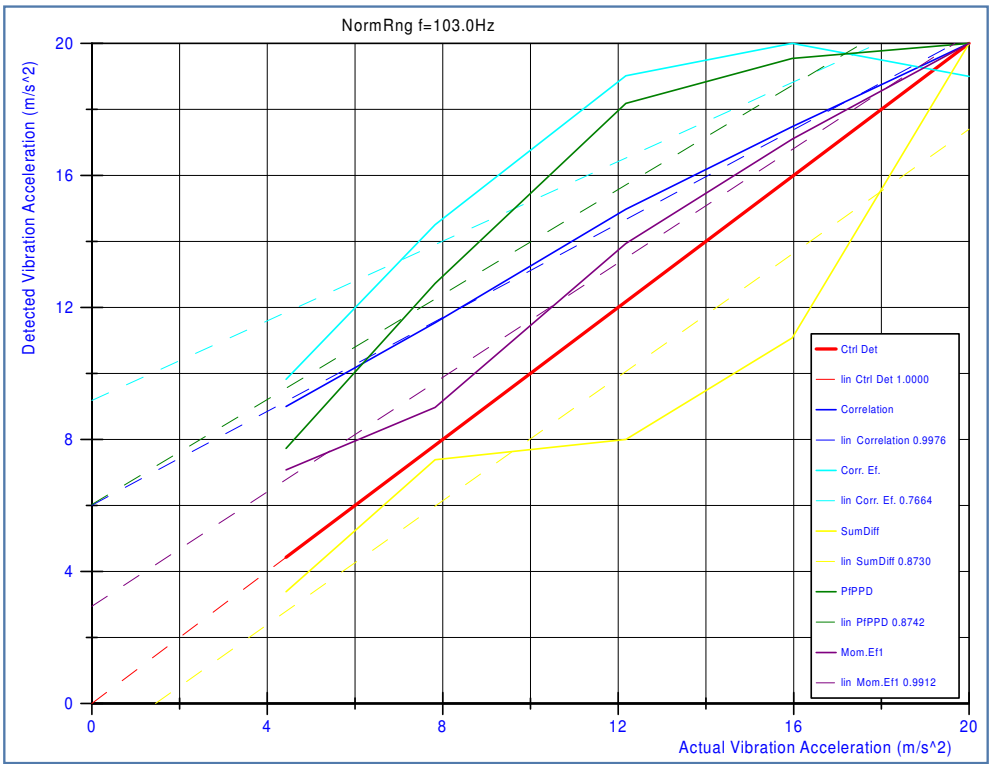
NormRng f=103.0Hz
Detected Vibration Acceleration (m/s^2)
Actual Vibration Acceleration (m/s^2)
0
4
8
12
16
20
Ctrl Det
lin Ctrl Det 1.0000
Correlation
lin Correlation 0.9976
Corr. Ef.
lin Corr. Ef. 0.7664
SumDiff
lin SumDiff 0.8730
PfPPD
lin PfPPD 0.8742
Mom.Ef1
lin Mom.Ef1 0.9912

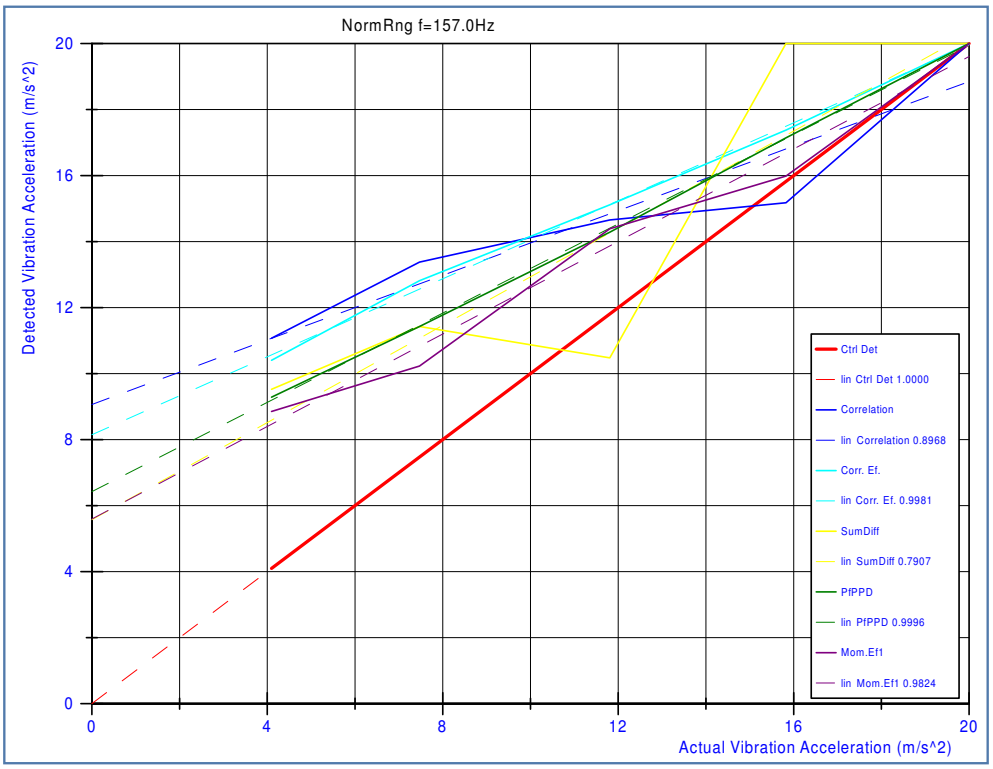
NormRng f=157.0Hz
Detected Vibration Acceleration (m/s^2)
Actual Vibration Acceleration (m/s^2)
0
4
8
12
16
20
Ctrl Det
lin Ctrl Det 1.0000
Correlation
lin Correlation 0.8968
Corr. Ef.
lin Corr. Ef. 0.9981
SumDiff
lin SumDiff 0.7907
PfPPD
lin PfPPD 0.9996
Mom.Ef1
lin Mom.Ef1 0.9824

A.2 Odziv metoda na različite amplitude uzbudnog signala u promatranom frekvencijskom rasponu

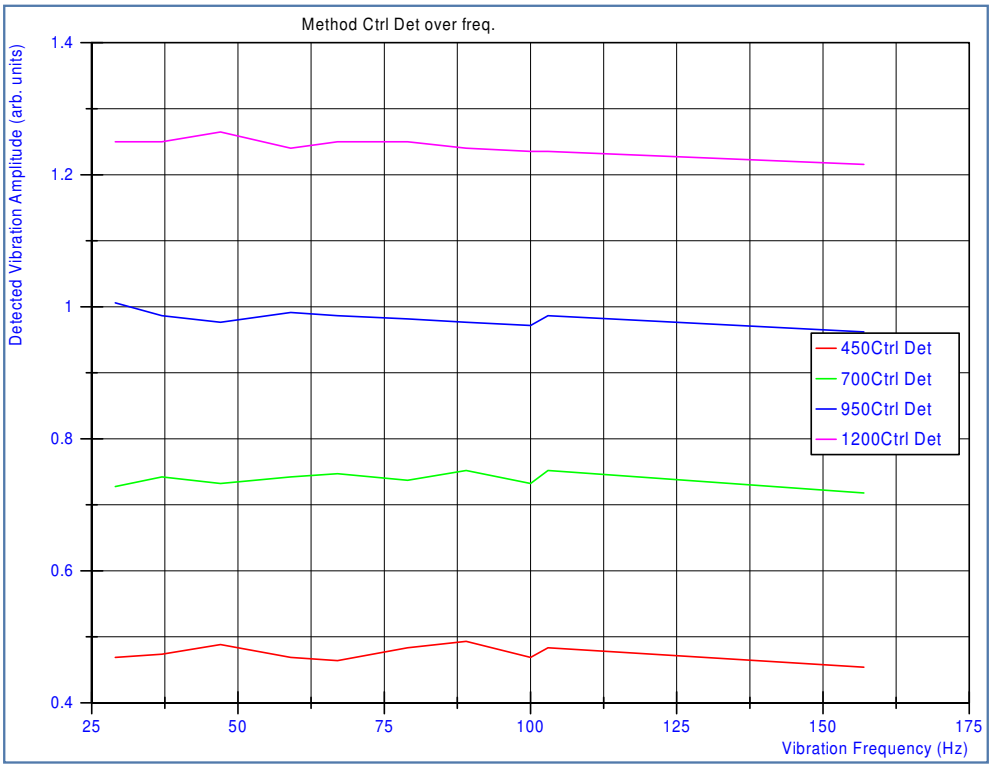

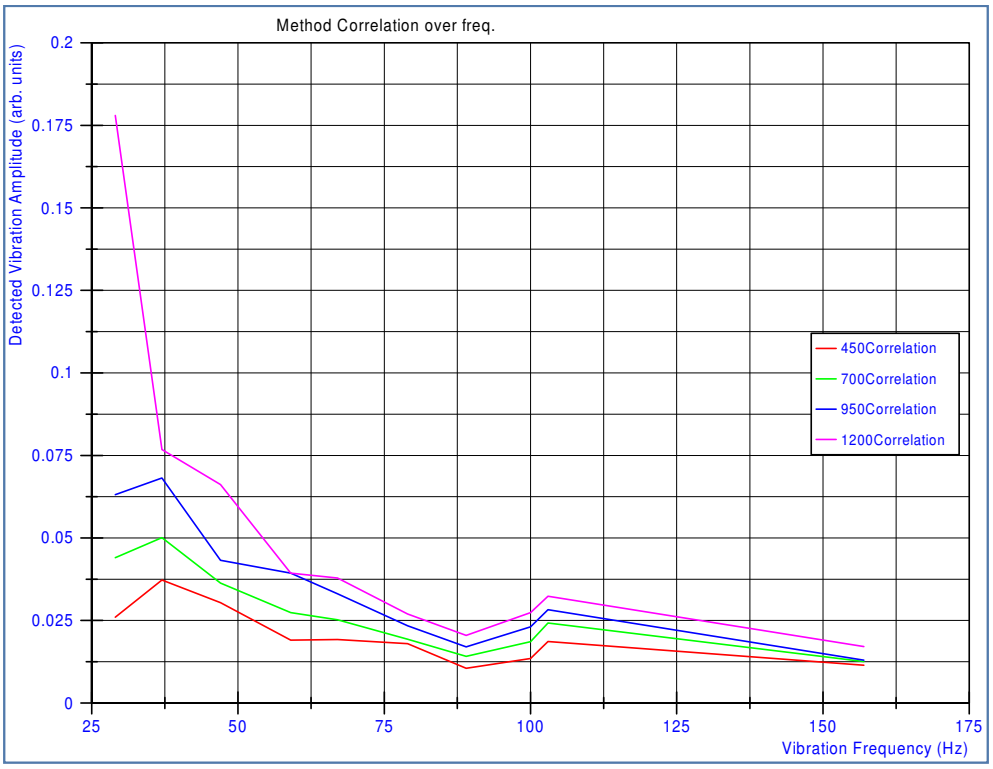

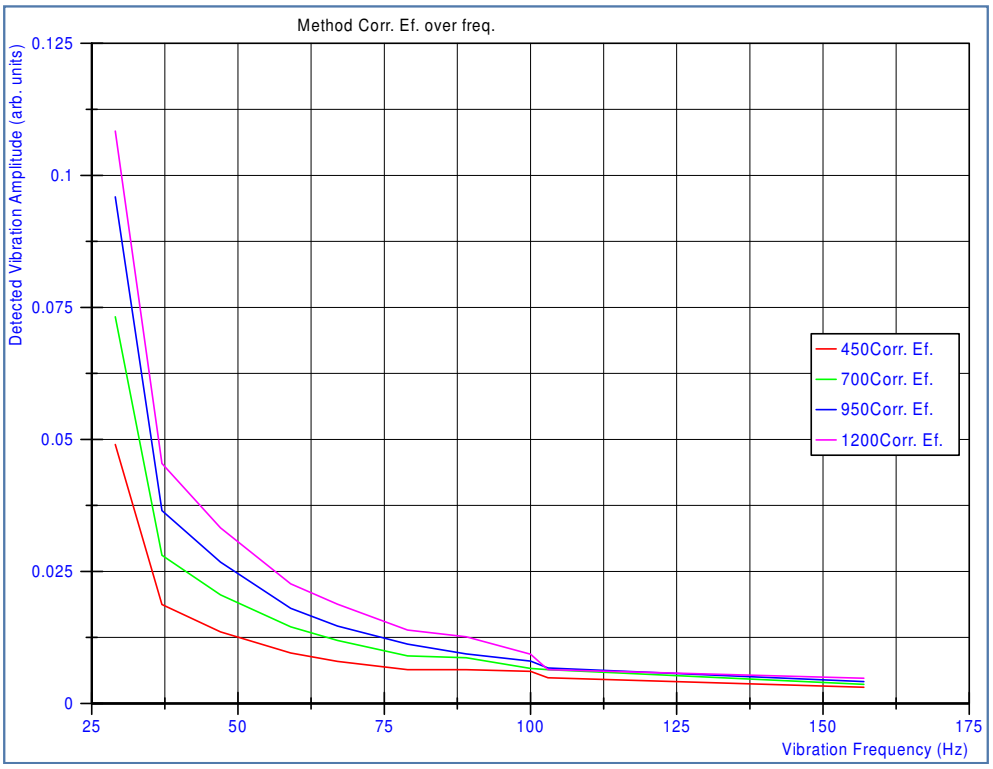
Method Corr. Ef. over freq.
Detected Vibration Amplitude (arb. units)
0.125
0.1
0.075
0.05
0.025
0
25
50
75
100
125
150
175
Vibration Frequency (Hz)
450Corr. Ef.
700Corr. Ef.
950Corr. Ef.
1200Corr. Ef.

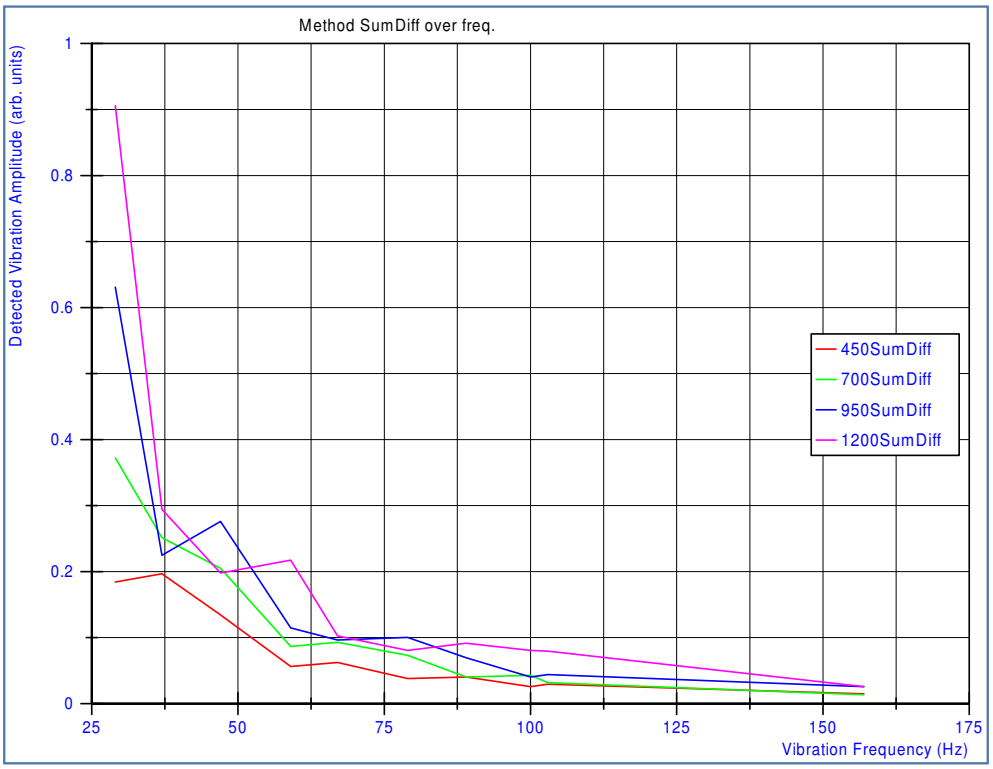
Method SumDiff over freq.
Detected Vibration Amplitude (arb. units)
1
0.8
0.6
0.4
0.2
0
25
50
75
100
125
150
175
Vibration Frequency (Hz)
450SumDiff
700SumDiff
950SumDiff
1200SumDiff

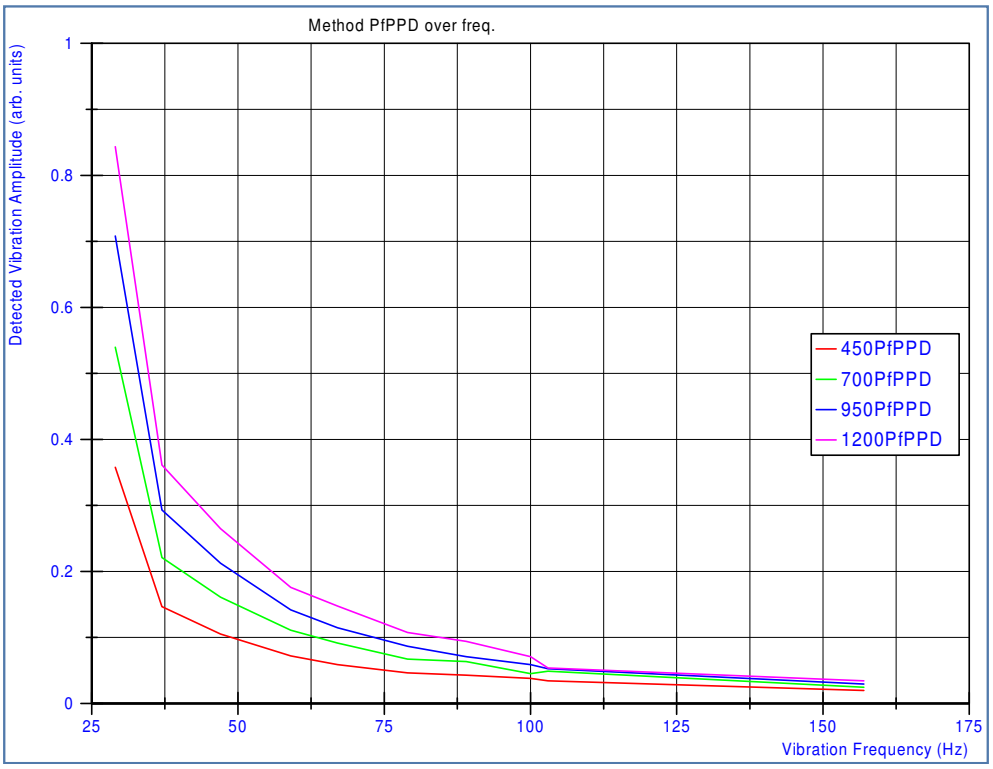

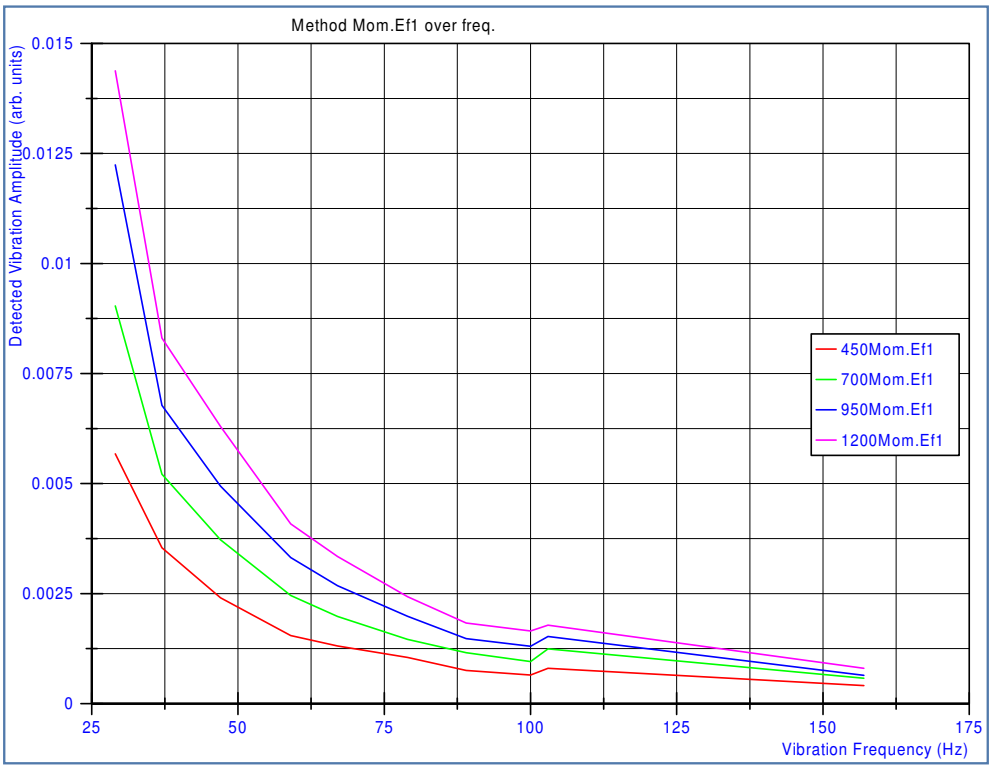

Iako je amplituda odziva kontrolnog detektora nominalno konstantna, zbog nedovoljno fine regulacije amplitude vibratora nije bilo moguće postići savršeno jednake vrijednosti na svim frekvencijama. Iz tog razloga karakteristika nije pravac čak ni u slučaju kontrolnog detektora, iako je njegov odziv u praksi linearan. Prividna nelinearnost za kontrolni detektor posljedica je manjkavosti kontrole mjernog sustava, ali je praktički zanemariva.

Rezultati ukazuju da je informacija o amplitudi prisutna u detektiranim i obrađenim signalima, ali da nije u najpovljnijem obliku za iskorištavanje, odnosno da nije linearna. Uz dodatne dorade mjernog sustava možda bi bilo moguće postići mjerenje amplitude vibracija predstavljenim pristupom.

Dodatak B

LabVIEW program za mjerenje vibracija pomoću detektorskih dioda

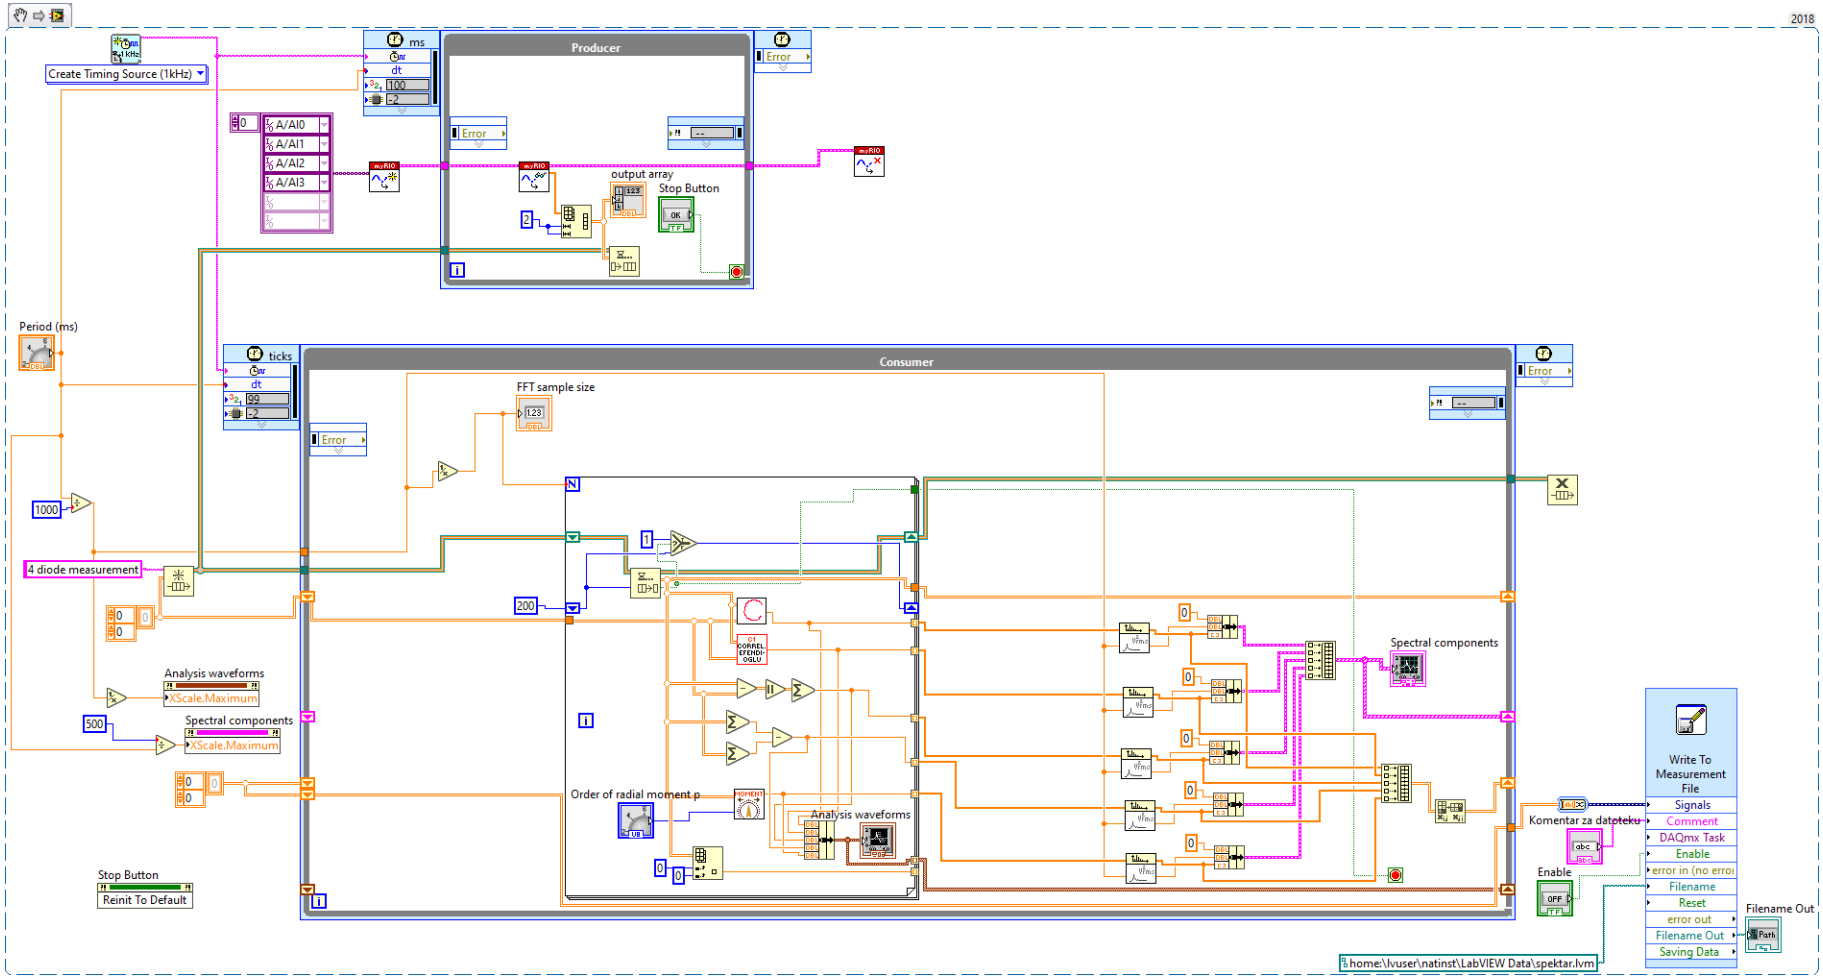

Slika B.1: LabVIEW kod programa napisanog za mjerenja na detektorskim diodama

Literatura

[1] Udd, E., Fiber optic smart structures, 1996.

[2] García, Y. R., Corres, J. M., Goicoechea, J., "Vibration detection using optical fiber sensors", 2010.

[3] Perrone, G., Vallan, A., "A low-cost optical sensor for noncontact vibration measurements", in IEEE Transactions on Instrumentation and Measurement, Vol. 58, No. 5, 2009, str. 1650–1656.

[4] Blake, J. N., Kim, B. Y., Shaw, H. J., "Fiber-optic modal coupler using periodic microbending", Optics Letters, Vol. 11, No. 3, 1986, str. 177.

[5] Blake, J. N., Engan, H. E., Shaw, H. J., Kim, B. Y., "Analysis of intermodal coupling in a two-mode fiber with periodic microbends", Optics Letters, Vol. 12, No. 4, 1987, str. 281.

[6] Đonlagić, D., Završnik, M., "Fiber-optic microbend sensor structure", OPTICS LETTERS, Vol. 22, No. 11, 1997, str. 837–839.

[7] Donlagić, D., Culshaw, B., "Microbend sensor structure for use in distributed and quasi-distributed sensor systems based on selective launching and filtering of the modes in graded index multimode fiber", Journal of Lightwave Technology, Vol. 17, No. 10, 1999, str. 1856–1868.

[8] Yu, F. T. S., Zhang, J., Yin, S., Ruffin, P. B., "Analysis of a fiber specklegram sensor by using coupled-mode theory", Applied Optics, Vol. 34, No. 16, 1995, str. 3018.

[9] Fujiwara, E., Marques dos Santos, M. F., Suzuki, C. K., "Optical fiber specklegram sensor analysis by speckle pattern division", Applied Optics, Vol. 56, No. 6, feb 2017, str. 1585.

[10] Fujiwara, E., Wu, Y. T., Suzuki, C. K., "Vibration-based specklegram fiber sensor for measurement of properties of liquids", Optics and Lasers in Engineering, Vol. 50, No. 12, dec 2012, str. 1726–1730.

[11] Pan, K., Uang, C.-M., Cheng, F., Yu, F. T. S., "Multimode fiber sensing by using mean-absolute speckle-intensity variation", Applied Optics, Vol. 33, No. 10, 1994, str. 2095.

[12] Garcia-Valenzuela, A., Tabib-Azar, M., “Fiber-optic force and displacement sensor based on speckle detection with 0.1 nN and 0.1 Å resolution”, Sensors and Actuators: A. Physical, Vol. 36, No. 3, 1993, str. 199–208.

[13] Domański, A. W., Poczesny, T., Prokopczuk, K., Makowski, P., “An optical fiber loop sensor for vibration monitoring”, Photonics Letters of Poland, Vol. 2, No. 2, 2010, str. 58–60.

[14] Poczesny, T., Prokopczuk, K., Domanski, A. W., “Comparison of optical fiber inertial vibration sensors”, Acta Physica Polonica A, Vol. 122, No. 5, 2012, str. 954–956, dostupno na: http://www.optics11.com/

[15] Martins, A., Rocha, A. M., Neto, B., Teixeira, A., Facão, M., Nogueira, R., Lima, M., Andre, P., “Modeling of Bend Losses in Single-Mode Optical Fibers”, Institutu de Telecomunicacoes, No. 1, 2009, dostupno na: http://www.rp-photonics.com/bend{_}losses-

[16] Conforti, G., Brenci, M., Mencaglia, A., Mignani, A. G., “Fiber optic vibration sensor for remote monitoring in high power electric machines”, Applied Optics, Vol. 28, No. 23, 1989, str. 5158.

[17] Igrec, B., Bosiljevac, M., Sipus, Z., Babic, D., Rudan, S., “Fiber optic vibration sensor for high-power electric machines realized using 3D printing technology”, in Photonic Instrumentation Engineering III, Vol. 9754. SPIE, mar 2016, str. 975410.

[18] Yu, F. T. S., “Fiber vibration sensor that uses the speckle contrast ratio”, Optical Engineering, Vol. 34, No. 1, 1995, str. 236, dostupno na: https://www.spiedigitallibrary.org/journals/Optical-Engineering/volume-34/issue-1/0000/Fiber-vibration-sensor-that-uses-the-speckle-contrast-ratio/10.1117/12.188329.short

[19] Rodriguez-Cobo, L., Lomer, M., Galindez, C., Lopez-Higuera, J. M., “POF vibration sensor based on speckle pattern changes”, in OFS2012 22nd International Conference on Optical Fiber Sensors, Vol. 8421. SPIE, oct 2012, str. 84 212Y–84 212Y–4.

[20] Maslać, J., “Optički senzorski sustavi zasnovani na interferometarskoj ispitnoj metodi”, Doktorski rad, 2017.

[21] Kim, B. Y., Blake, J. N., Huang, S. Y., Shaw, H. J., “Use of highly elliptical core fibers for two-mode fiber devices”, Optics Letters, Vol. 12, No. 9, 1987, str. 729.

[22] Gangopadhyay, T. K., Henderson, P. J., “Vibration: history and measurement with an extrinsic Fabry–Perot sensor with solid-state laser interferometry”, Applied Optics, Vol. 38, No. 12, 1999, str. 2471.

[23] Kist, R., Ramakrishnan, S., Wolfelschneider, H., “The Fiber Fabry-Perot And Its Applications As A Fiber-Optic Sensor Element.”, in Fiber Optic Sensors I, Vol. 0586, 1986, str. 126.

[24] Murphy, K. A., Gunther, M. F., Vengsarkar, A. M., Claus, R. ., “Quadrature phase-shifted, extrinsic Fabry-Perot optical fiber sensors”, Optics Letters, Vol. 16, No. 4, 1991.

[25] Lee, C. E., Taylor, H. F., “Fiber-Optic Fabry-Perot Temperature Sensor Using a Low-Coherence Light Source”, Journal of Lightwave Technology, Vol. 9, No. 1, 1991, str. 129–134.

[26] Murphy, K. A., Gunther, M. F., Vengsarkar, A. M., Claus, R. O., “Fabry–Perot fiber-optic sensors in full-scale fatigue testing on an F-15 aircraft”, Applied Optics, Vol. 31, No. 4, 1992, str. 431.

[27] Liu, X., Jin, B., Bai, Q., Wang, Y., Wang, D., Wang, Y., “Distributed fiber-optic sensors for vibration detection”, Sensors (Switzerland), Vol. 16, No. 8, 2016.

[28] Liang, S., Zhang, C. X., Lin, B., Lin, W. T., Li, Q., Zhong, X., Li, L. J., “Influences of semiconductor laser on fibre-optic distributed disturbance sensor based on Mach-Zehnder interferometer”, Chinese Physics B, Vol. 19, No. 12, 2010.

[29] Gangopadhyay, T. K., “Prospects for Fibre Bragg gratings and Fabry-Perot interferometers in fibre-optic vibration sensing”, Sensors and Actuators, A: Physical, Vol. 113, No. 1, jun 2004, str. 20–38.

[30] Campanella, C. C. E., Cuccovillo, A., Campanella, C. C. E., Yurt, A., Passaro, V. M., “Fibre Bragg Grating based strain sensors: Review of technology and applications”, Sensors (Switzerland), Vol. 18, No. 9, sep 2018.

[31] Saleh, B. E. A., Teich, M. C., Wiley, C. J., Fundamentals of Photonics. Wiley, 1991, Vol. 5.

[32] Takai, N., Asakura, T., “Statistical properties of laser speckles produced under illumination from a multimode optical fiber”, Journal of the Optical Society of America A, Vol. 2, No. 8, 1985, str. 1282.

[33] Plöschner, M., Tyc, T., Čižmár, T., “Seeing through chaos in multimode fibres”, Nature Photonics, Vol. 9, No. 8, 2015, str. 529–535.

[34] Skorobogatiy, M., Jacobs, S., Johnson, S., Fink, Y., “Geometric variations in high index-contrast waveguides, coupled mode theory in curvilinear coordinates”, Optics Express, Vol. 10, No. 21, 2002, str. 1227, dostupno na: http://www.opticsexpress.org/abstract.cfm?URI=OPEX-9-13-748.

[35] Spillman, W. B., Kline, B. R., Maurice, L. B., Fuhr, P. L., “Statistical-mode sensor for fiber optic vibration sensing uses”, Applied Optics, Vol. 28, No. 15, 1989, str. 3166.

[36] Wu, S., Yin, S., Yu, F. T. S., “Sensing with fiber specklegrams”, Applied Optics, Vol. 30, No. 31, 1991, str. 4468.

[37] Yu, F. T., “Fiber specklegram sensors”, in Fiber Optic Sensors, Second Edition. CRC Press, jan 2017, str. 201–252.

[38] Robles-Urquijo, I., Lomer, M., Rodriguez-Cobo, L., Lopez-Higuera, J. M., “Non-contact vibration analysis using speckle-based techniques”, in 25th International Conference on Optical Fiber Sensors, Vol. 10323. SPIE, apr 2017, str. 103237W.

[39] Rodriguez-Cobo, L., Lomer, M., Cobo, A., Lopez-Higuera, J. M., “Optical fiber strain sensor with extended dynamic range based on specklegrams”, Sensors and Actuators, A: Physical, Vol. 203, 2013, str. 341–345.

[40] Valley, G. C., Sefler, G. A., Justin Shaw, T., “Multimode waveguide speckle patterns for compressive sensing”, Optics Letters, Vol. 41, No. 11, jun 2016, str. 2529.

[41] Pomarico, J. A., Sicre, E. E., Patrignani, D., De Pasquale, L., “Optical fiber strain gauge based on speckle correlation”, Optics and Laser Technology, Vol. 31, No. 3, 1999, str. 219–224, dostupno na: www.elsevier.com/locate/optlastec

[42] Kumar, A., Goel, N. K., Varshney, R. K., “Studies on a few-mode fiber-optic strain sensor based on LP 01 -LP 02 mode interference”, Journal of Lightwave Technology, Vol. 19, No. 3, 2001, str. 358–362.

[43] Anderson, D. Z., Bolshtyansky, M. A., Zel’dovich, B. Y., “Stabilization of the speckle pattern of a multimode fiber undergoing bending”, Optics Letters, Vol. 21, No. 11, 1996, str. 785.

[44] Chen, D., Wu, C., Tse, M. L., Tam, H. Y., “Hydrostatic pressure sensor based on mode interference of a few mode fiber”, Tech. Rep., 2011.

[45] Salik, E., Medrano, M., Cohoon, G., Miller, J., Boyter, C., Koh, J., “SMS fiber sensor utilizing a few-mode fiber exhibits critical wavelength behavior”, IEEE Photonics Technology Letters, Vol. 24, No. 7, 2012, str. 593–595.

[46] Rodriguez-Cobo, L., Lomer, M., Lopez-Higuera, J. M., “Fiber specklegram sensors sensitivities at high temperatures”, 24th International Conference on Optical Fibre Sensors, Vol. 9634, No. 1, sep 2015, str. 96347J.

[47] Fujiwara, E., Wu, Y. T., dos Santos, M. F. M., Schenkel, E. A., Suzuki, C. K., "Development of a tactile sensor based on optical fiber specklegram analysis and sensor data fusion technique", Sensors and Actuators, A: Physical, Vol. 263, 2017, str. 677–686, dostupno na: http://dx.doi.org/10.1016/j.sna.2017.07.031

[48] Xu, X., Spillman, Jr., W. B., Claus, R. O., Meissner, K. E., Chen, K., "Spatially distributed fiber sensor with dual processed outputs", in 17th International Conference on Optical Fibre Sensors, Vol. 5855. SPIE, may 2005, str. 58.

[49] Rodriguez-Cobo, L., Lomer, M., Cobo, A., Lopez-Higuera, J. M., "Radial processing scheme of speckle patterns for sensing applications", in Optics InfoBase Conference Papers, 2013.

[50] Qian, S., Xu, Y., Zhong, L., Su, L., "Investigation on sensitivity enhancement for optical fiber speckle sensors", Optics Express, Vol. 24, No. 10, may 2016, str. 10829.

[51] Haakestad, M. W., Engan, H. E., "Acoustooptic properties of a weakly multimode solid core photonic crystal fiber", Journal of Lightwave Technology, Vol. 24, No. 2, feb 2006, str. 838–845.

[52] Šipuš, Z., Bosiljevac, M., Lujo, I., "Specialty optical fibers: Analysis and characterization", Automatika, Vol. 50, No. 3-4, 2009, str. 234–244.

[53] Englund, M., Ipatti, A., Karioja, P., "Fiber optic security monitoring sensor", in Micro-optical Technologies for Measurement, Sensors, and Microsystems II and Optical Fiber Sensor Technologies and Applications, Vol. 3099, 1997, str. 281–296, dostupno na: http://spiedl.org/terms

[54] Dhall, A., Chhabra, J. K., Aulakh, N. S., "Intrusion detection system based on speckle pattern analysis", Experimental Techniques, Vol. 29, No. 1, 2005, str. 25–31.

[55] Arnaoudov, R., Bock, W. J., Miletiev, R., Angelov, Y., Eftimov, T., "Performance evaluation of a few- and multi-mode fiber-optic perimeter sensor", in Conference Record - IEEE Instrumentation and Measurement Technology Conference, 2007.

[56] Miletiev, R., Arnaudov, R., Bock, W., Eftimov, T., Bao, X., "Performance evaluation of a few- and multimode fiber optic perimeter sensor with selective mode excitation", Photonics Letters of Poland, Vol. 2, No. 1, 2010, str. 43–45.

[57] Kumagai, T., Sato, S., Nakamura, T., "Fiber-Optic Vibration Sensor for Physical Security System", in IEEE International Conference on Condition Monitoring and Diagnosis. IEEE International Conference on Condition Monitoring and Diagnosis 23-27 September 2012, Bali, Indonesia Fiber-Optic, 2012, str. 1171–1174.

[58] Lujo, I., Klokoc, P., Komljenovic, T., Bosiljevac, M., Sipus, Z., "Fiber-optic vibration sensor based on multimode fiber", Radioengineering, Vol. 17, No. 2, 2008, str. 93–97.

[59] Lujo, I., Klokoč, P., Komljenović, T., Šipuš, Z., "Measuring structural vibrations with a multimode fiber optical sensor", Conference Proceedings - ICECom 2007, 19th International Conference on Applied Electromagnetics and Communications, No. 2, 2007, str. 3–6.

[60] Lujo, I., Bosiljevac, M., Šipuš, Z., "Speckle pattern analysis based optical fiber vibration sensor", in Conference Proceedings - ICECom 2016, 22nd International Conference on Applied Electromagnetics and Communications. KoREMA - Croatian Society for Communications, Computing, Electronics, Measurement and Control; Unska 3, HR-10000 Zagreb, Croatia, 2016, str. s_34_4.

[61] Fesenko, O., Yatsenko, L., "Nanoplasmonics, nano-optics, nanocomposites, and surface studies: Selected proceedings of the second fp7 conference and the third international summer school nanotechnology: From fundamental research to innovations, august 23-30, 2014, yaremche-lviv, ukra", Springer Proceedings in Physics, Vol. 167, 2015, str. 329–338.

[62] Efendioglu, H. S., Yildirim, T., Toker, O., Fidanboylu, K., "New statistical features for the design of fiber optic statistical mode sensors", Optical Fiber Technology, Vol. 19, No. 4, 2013, str. 279–284, dostupno na: http://dx.doi.org/10.1016/j.yofte.2013.02.009

[63] Efendioglu, H. S., "A Review of Fiber-Optic Modal Modulated Sensors: Specklegram and Modal Power Distribution Sensing", IEEE Sensors Journal, Vol. 17, No. 7, 2017, str. 2055–2064.

[64] Lujo, I., Bosiljevac, M., Šipuš, Z., "Comparison of different statistical methods for specklegram-based fiber optic vibration sensor", in Conference Proceedings - ICECom 2019, 23rd International Conference on Applied Electromagnetics and Communications. KoREMA - Croatian Society for Communications, Computing, Electronics, Measurement and Control; Unska 3, HR-10000 Zagreb, Croatia, 2019, str. s_15_6.

Životopis

Ivan Lujo rođen je u Dubrovniku 14.5.1984. godine. Diplomirao je na Fakultetu elektrotehnike i računarstva Sveučilišta u Zagrebu 2007. godine. Iste godine započinje s radom na Elektrotehničkom odjelu Tehničkog veleučilišta u Zagrebu na kojem je sudjelovao u različitim vidovima nastave iz više kolegija. Posebno se posvetio programiranju u LabVIEW programskoj okolini koje je uveo kao novi kolegij u program elektrotehničkog odjela TVZ-a 2012. godine. Studenti koje je mentorirao ostvarili su zapažene rezultate na međunarodnim natjecanjima. 2018. godine izabran je u zvanje višeg predavača. Nositelj je više kolegija iz područja mjerenja i senzorike, a obavljao je i funkcije voditelja Specijalističkog diplomskog studija elektrotehnike i pomoćnika pročelnika odjela. U rujnu 2019. napušta TVZ i prelazi u privatni sektor, ali ostaje u nastavi kao vanjski suradnik.
U istraživačkom radu bavi se primjenama svjetlovoda u senzorskim sustavima.

Popis objavljenih djela

Radovi u časopisima

[1] Šipuš, Z., Bosiljevac M., Lujo I., "Specialty optical fibers: Analysis and characterization," Automatika, vol. 50, no. 3–4, pp. 234–244, 2009.

[2] Lujo, I., Klokoč P., Komljenović T., Bosiljevac M., Šipuš, Z., "Fiber-optic vibration sensor based on multimode fiber," Radioengineering, vol. 17, no. 2, pp. 93–97, 2008.

Radovi u zbornicima konferencija

[1] Lujo I. , Klokoč P., Komljenović T., Šipuš, Z., "Measuring structural vibrations with a multimode fiber optical sensor," Conf. Proc. - ICECom 2007, 19th Int. Conf. Appl. Electromagn. Commun., no. 2, pp. 3–6, 2007.

[2] Klokoč, P., Lujo, I., Bosiljevac, M., Burum, N., "Optical sensor system for vibration measuring," in Proceedings ELMAR-2008, Volume 2, 2008, pp. 625–628.

[3] Lujo, I., Bosiljevac M., Šipuš, Z., “Speckle pattern analysis based optical fiber vibration sensor,” in Conference Proceedings - ICECom 2016, 22nd International Conference on Applied Electromagnetics and Communications, 2016, p. s-34-4.

[4] Lujo, I.,, Bosiljevac M., Šipuš, Z., “Comparison of different statistical methods for specklegram-based fiber optic vibration sensor,” in Conference Proceedings - ICECom 2019, 23rd International Conference on Applied Electromagnetics and Communications, 2019, p. s-15-6.
Svi navedeni radovi su direktno povezani s područjem doktorskog istraživanja.

Biography

Ivan Lujo was born in Dubrovnik on May 14th 1984. He graduated form the Faculty of Electrical Engineering and Computing, University of Zagreb, in 2007. That same year he began working at the Zagreb University of Applied Sciences, Dept. of Electrical Engineering, where he participated in holding classes of multiple courses. He was especially engaged with the course in LabVIEW graphical programing which he introduced to the curriculum of the EE dept. on 2012. Students under his mentorship have achieved excellent results in international student competitions. In 2018. he was elected senior lecturer. He held the chair of multiple courses related to sensors and measurements, and was also engaged as Head of the Graduate Studies in Electrical Engineering, as well as assistant Head of the EE dept. In September 2019. he left the Zagreb University of Applied Sciences to join the private sector, but continues to hold classes as an associate.

In his scientific research he mainly deals with optical fiber sensor systems.