Optimiranje kaotičnih sljedova radi poboljšanja performanci programski određenoga radijskoga sustava

Novosel, Leonard

Doctoral thesis / Disertacija

2019

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:168:515697

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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



Repository / Repozitorij:

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







Sveučilište u Zagrebu
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

Leonard Novosel

Optimiranje kaotičnih sljedova radi poboljšanja performanci programski određenoga radijskoga sustava

DOKTORSKI RAD

Zagreb, 2019.



Sveučilište u Zagrebu
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

Leonard Novosel

Optimiranje kaotičnih sljedova radi poboljšanja performanci programski određenoga radijskoga sustava

DOKTORSKI RAD

Mentor: Prof. dr. sc. Gordan Šišul

Zagreb, 2019.



University of Zagreb

FACULTY OF ELECTRICAL ENGINEERING AND COMPUTING

Leonard Novosel

Chaotic sequences optimization for software defined radio performance enhancement

DOCTORAL THESIS

Supervisor: Professor Gordan Šišul, PhD

Zagreb, 2019.

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

Mentor: prof. dr. sc. Gordan Šišul

Doktorski rad ima: 113 stranica

Doktorski rad br.: _____

O mentoru

Gordan Šišul rođen je u Rijeci u Hrvatskoj 1971. godine. Diplomirao, magistrirao i doktorirao je elektrotehniku na Fakultetu elektrotehnike i računarstva Sveučilišta u Zagrebu 1996., 2000. i 2004. godine. Trenutno je zaposlen kao redoviti profesor na istom fakultetu. Njegovi istraživački interesi uključuju primjene obrade signala u bežičnim komunikacijama, algoritme za raspodjelu resursa, tehnike modulacije i modeliranje propagacije.

About the Supervisor

Gordan Šišul was born in Rijeka, Croatia in 1971. He received B.Sc., M. Sc. and Ph.D. degrees in electrical engineering from the Faculty of Electrical Engineering and Computing, University of Zagreb, Croatia in 1996, 2000 and 2004 respectively. He is currently employed as a Full Professor at the same Faculty. His research interests include signal processing applications in wireless communications, resource allocation algorithms, modulation techniques and radio propagation.

Sažetak

Komunikacijski sustavi s tehnikama proširenog spektra (eng. *Spread Spectrum*) koriste se već nekoliko desetljeća. Pristup fizičkom sloju korištenjem tehnika proširenog spektra omogućuje robusnu i sigurnu komunikaciju. Zbog takvih dobrih karakteristika tehnike proširenog spektra razvijaju se i danas te koriste u radijskim senzorskim mrežama. Kako bi se ostvarile bolje performance u pogledu kapaciteta sustava i učestalosti pogreške bita te povećanja broja uređaja, potrebno je optimirati sljedove za proširenje pojasa.

Kaotični nelinearni sustavi generiraju signale koji su vrlo slični bijelom šumu. Kako bi se kaotični signali mogli koristiti u komunikacijskom sustavu s proširenim spektrom moraju se analizirati njihova korelacijska svojstva. Analizom korelacijskih svojstava kaotičnih signala korištenjem Golayevog parametra moguće je generirati optimirane kaotične sljedove za proširenje pojasa. Nadalje, u radijskom komunikacijskom sustavu potrebno je rekonstruirati podatke na prijamu. Razne sinkronizacijske tehnike omogućuju rekonstrukciju nepoznatih parametara poslanog signala. Kako bi se otkrile promjene koje unosi komunikacijski kanal, koriste se referentni simboli. Usporedbom primljenih simbola te referentnih simbola moguće je procijeniti nepoznate parametre signala. Optimirani kaotični sljedovi mogu se koristiti kao referentni sinkronizacijski simboli. Za evaluaciju optimiranih kaotičnih sljedova potrebno je imati arhitekturu kojoj se jednostavno mijenja struktura ili parametri prijenosa. Arhitektura programski određenog radija (eng. *Software Defined Radio*) omogućuje jednostavnu izmjenu dijelova sustava kao i tehnika prijenosa. Optimirani kaotični sljedovi evaluiraju se u laboratorijskom modelu programski određenog radijskog sustava prema normi za senzorske mreže IEEE 802.15.4. Rezultati evaluacije performanci kaotičnih sljedova uspoređuju se s performancama Gold sljedova definiranih u navedenoj normi. Evaluacija performanci pokazuje da optimirani kaotični sljedovi pokazuju bolje performance kao sljedovi za proširenje pojasa i kao referentni sinkronizacijski sljedovi.

Ključne riječi: kaos, prošireni spektar, optimirani kaotični sljedovi, programski određeni radio, radijske senzorske mreže

Extended abstract

Spread spectrum communication systems have been used for several decades. Further developments are continuously made to achieve higher transmission rates, increased spectral efficiency, and higher degree of data protection. Modern radio communication systems strive to reduce the cost of equipment and upgrades to the radio network. The focus of research is shifting to find the most effective modulation and encoding by optimizing the spectral efficiency of the modulation process, the power consumption of the communication system, and the simplicity of extending and replacing the existing systems. Thus research is being led in the fields of smart and green communication networks.

Physical layer access using spread spectrum techniques enables robust and secure communication. By further optimizing the spread spectrum access techniques, large number of devices can be used in single network. Increasing the user and device capacities with minimal change to modulation and coding schemes is the main goal in optimizing existing systems. Spread spectrum access techniques are still being developed and are being widely used in wireless sensor networks. In order to achieve better system capacity and bit error rate as well as increase the number of user devices, it is necessary to optimize the spreading sequences. One direction of research can be carried out in the use of some unconventional transfer and modulation procedures. The use of chaos and chaotic modulation as transmission technology in communication systems can also be considered unconventional. Chaotic behaviour has been identified in many non-linear natural systems where it was considered as noise and unwanted behaviour. Chaos is generated from nonlinear elements in a system. Chaotic behaviour can be seen in relatively simple nonlinear systems.

Research in the field of using chaos in communication systems has been carried out for several decades where it has been found that chaotic modulation procedures show better performance compared to standard modulation techniques. The results of nonlinear techniques can be successfully used to increase the performance of known modulation techniques and as a method of encoding and protecting the data. Much of the research in chaotic communication is carried out in the field of chaotic modulation procedures and signaling, chaotic synchronization and encryption, and the generation of random signals and sequences. Chaotic random signal generators show greater resistance to different analytic attacks, which is particularly important in cryptographic applications and spread spectrum communication systems.

Using chaos in existing communication systems increases capacity, robustness, quality of service, security, and more effectively exploiting existing resources. Chaotic signals show complex behaviour and generated signals are spread across a wide frequency bandwidth space. Chaotic nonlinear systems generate signals that are similar to white noise. Because of its nature, or sensitivity to small changes in initial conditions, chaotic systems are resisting synchronization

and achieving stable states. This property can be used for safer and more robust communication. This phenomenon is used in communication systems based on an spread spectrum techniques, or by multiplying the information signals by some chaotic pseudo-random sequence. The information signal in the transmitter is multiplied by the transmitter's chaotic sequence. The receiver knows the replica of the chaotic pseudo-random spreading sequence and in the receiver the signal is multiplied by the replica of the chaotic sequence.

In order to achieve robust and secure communication in spread spectrum systems, chaotic pseudorandom sequences with good correlation properties have to be generated. There is a great research interest in the area of generating chaotic sequences for spread spectrum applications with properties that show performance improvements in relation to the currently used spreading sequences. The correlation characteristics of the sequences are used as a basis to determine sequences that will improve synchronization and bit error rate performance. Correlation properties analysis can be used to design and generate chaotic sequences that achieve the same or better performance in relation to orthogonal or maximum length sequences widely used in spread spectrum communication systems today. Optimal spreading sequences for multiple access scenarios should have low crosscorrelation to minimize mutual interference. Good autocorrelation properties are also needed for detection and despreading after the signal is received through a noisy channel. Both good crosscorrelation and autocorrelation properties are often hard to achieve in spreading sequence design.

Chaotic maps are mathematical objects in the form of iterated functions that describe discrete non-linear systems from which sample based signals can be generated. Several chaotic maps will be used for generating chaotic spreading sequences for software defined radio model in this paper. One dimensional chaotic maps are especially suited for generating spreading sequences with desired properties. One dimensional maps describe the evolution of one variable with regard to the chaotic system parameter. Several chaotic maps were chosen for spreading sequence generation in this thesis: quadratic or logistic map, tent map and Chebyshev map. Discrete signals of length 32, 64 and 128 are generated using the three aforementioned chaotic maps. Bipolar spreading sequence is obtained from discrete signal by applying a threshold function.

Using the results of correlation properties analysis, Golay figure of merit factor is defined from autocorrelation function. The Golay figure of merit factor shows the dissipation of energy in correlation function sidelobes. Sequences with narrower main autocorrelation function component display wider bandwidths and achieve better performance metrics. Golay's figure of merit factor is used to describe and select optimized chaotic sequences as spread spectrum sequences. Spreading sequences with high value of Golay figure of merit are chosen as optimized spreading sequences. Chaotic sequences are expected to have better synchronization and error performance after optimization by maximizing Golay figure of merit factor. A rela-

tion between mean square crosscorrelation function and Golay figure of merit factor has been found. Spreading sequences used in code division multiple access systems need to have good crosscorrelation properties to limit multiple access interference.

In synchronous systems, orthogonal sequences have the optimal performance in reducing interference. When synchronization and code alignment in the system is not optimal, the orthogonality is reduced. In this thesis Golay figure of merit factor of generated chaotic sequences is calculated after generation and a subset of chaotic sequences with high Golay figure of merit are chosen. Chosen spreading sequences are tested in LR-WPAN system model for software defined radio. A subset of 16 sequences is chosen based on their Golay figure of merit factor as spreading sequences in model presented in this thesis. Maximal and mean Golay figure of merit factor is calculated for the 16 generated chaotic sequences and compared against Gold sequences described in IEEE 802.15.4 standard for LR-WPA networks.

The radio communication system needs to reconstruct the data in the receiver. Various synchronization techniques enable the estimation of unknown parameters of the transmitted signal. Reference symbols are used to estimate the changes made by a communication channel. By comparing received symbols and reference symbols, it is possible to estimate the unknown signal parameter. Optimized chaotic sequences can be used as reference synchronization symbols. A synchronization header is constructed in accordance with the IEEE standard used in this thesis. Synchronization header iis used in BPSK demodulation process for symbol timing, frequency and phase synchronization. Various measurements are performed using a virtual instrument in LabView on demodulated signal to show synchronization performance.

To evaluate optimized chaotic sequences, it is necessary to have an radio architecture that enables a simple change in system structure or parameters. There are many simulation software tools that allow comparison of parameters and performance, but such simulation tools only emulate some distortions that are present in real systems and radio channels. It is particularly demanding to simulate and include various channel effects and actual signal distortion on radio communication systems.

Radio communication systems use free space to transmit information, which could be realistically simulated only with the use of a large number of variables. The software defined radio architecture bridges the demanding part between the simulation tool and the transmission of the actual radio signals. Platform based communication systems and software defined radio concept enable the creation of prototypes of existing communication systems and optimization of subsystems in a larger radio network.

The software defined radio system can be viewed as being composed of two basic parts. The first subsystem is a software part, which can be called a simulation part or part of a signal processing. The program part is responsible for digital signal processing and runs on a computer platform in the form of a software tool that performs all functions of the physical layer through

the subroutines. The second subsystem consists of hardware that converts digital information from the program part to a signal with a complex envelope that is suitable for transmission using electromagnetic waves.

Software defined radio enables a researcher to change system structure, various parts as well as physical layer access technology. Such a model is especially tailored to evaluate the performance of new coding techniques, encapsulation, modulation procedures, and physical layer access techniques as well as the data protection methods.

Results presented in this thesis were obtained using a LR-WPAN software defined radio model programmed in LABView environment. Physical layer of LR-WPAN model is based on direct sequence spread spectrum with BPSK modulation. Multiple access is achieved by using different spreading sequence for each user. The proposed system model is programmed in LabView for software defined radio Universal Software Radio Peripheral (USRP) transceiver chain. Optimized chaotic sequences are evaluated in the software defined radio laboratory model according to the IEEE 802.15.4 sensor network standard.

The number of users is varied from 1 to 10 users so that performance in multiple user environment can be evaluated. Waveforms of particular users are only separated by their spreading sequence as this system is modelled as a Code Division Multiple Access system. With CDMA technique, user waveforms occupy the same channel at the same time intervals. To distinguish individual user data, spreading codes need to have good cross correlation properties. That is, spreading codes should be orthogonal for all time delays.

Bit error rate and modulation quality measurements were obtained using programs in LabView where they are called virtual instruments that calculate various parameters of received waveform. The USRP receiving device performs analog to digital conversion so that waveform samples are available on the host computer for parameter analysis. Bit error rate performance is evaluated after successful despreading, demodulation and synchronization procedures are performed so it shows the performance of the entire communication system from transmitter through channel conditions to transmitter. Performance degradation due to software defined radio imperfections is also included in the final results and is considered constant. The performance of the entire system is measured by comparing bit error rates after the frame synchronization and data recovery.

To measure the synchronization performance of chaotic sequences defined in LR-WPAN standard, EVM (Error Vector Magnitude) is used. EVM is the value of the root mean square value of the length of the vector of the detected symbol after demodulation to the ideal reference symbol location defined by used modulation technique. EVM is measured after demodulation and synchronization is performed therefore showing the performance of receiver and synchronization systems. EVM shows the influence of all distortions present in the communication system, but it also shows the performance of spreading and synchronization sequences in miti-

gating these distortions EVM is calculated in LabView on the waveform samples. The accuracy of EVM calculation and measurements is dependent on USRP digitization precision.

Chaotic sequences generated by Chebyshev, quadratic and tent maps are evaluated against Gold codes defined in original standard. Spreading sequences of lengths 32, 64 and 128 samples are used in software defined radio system presented in this paper. For each sequence length the system is scaled from 1 to 10 users and BER and EVM are measured. Synchronization performance is evaluated for synchronization preamble of length 16 and 32. Sequence in the preamble is generated using the same chaotic map as for spreading sequence generation. Original synchronization sequence defined in standard is used with Gold spreading codes.

The performance results of chaotic sequences are compared with the performance of Gold sequences defined in the IEEE standard. Evaluation of performance shows that optimized chaotic spreading sequences show better performance as spread spectrum sequences and as reference synchronization sequences. The longer spreading codes show better performance due to increased resilience to interference. By optimising chaotic codes correlation properties improved system performance can be achieved. The enhancement of the entire multiple user system leads to increased system capacity.

Synchronization is performed only using spreading code correlation and synchronization headers in frame preamble after despreading. It was shown that chaotic codes after optimization have better performance than Gold codes defined in standard. The results show that the optimised chaotic sequences generated from Chebyshev map have better performance than Gold sequence and chaotic sequences generated from quadratic and tent maps. Chebyshev sequence has higher values of mean and maximum Golay figure of merit factors that show correlation properties.

The distortions in communication system based on software defined radio used to model the LR-WPAN system are considered constant during the evaluation of all sequences. Sequences with better correlation properties should be more effective in mitigating the distortions. It should also be noted that spreading sequence plays a pivotal role in overall performance. This is largely due to multiple access method used in this model. The multiple access is achieved using only different spreading sequences without any mutual synchronization between the transmitter or the receiver.

Novel spreading sequences can be generated by using various generation methods and systems. One of the methods is by using the chaotic nature of simple nonlinear systems. Discrete nonlinear systems are especially suitable for analysis and usage in digital communication systems. The main Correlation properties of spreading sequences are essential for performance of spread spectrum systems. By comparing and optimizing correlation properties, optimized sequences can be generated with significant improvement in overall communication system performance. The performance of such optimised chaotic sequences can be evaluated using

a system model based on software defined radio. Software defined radio enables a researcher to build real world communication system prototypes and experiments by changing system parts and parameters. With further research into correlation properties, spreading sequences with superior performance could be found. These sequences should have better performance in asynchronous systems where such optimized sequences can be used to achieve higher user and device capacities.

In the "Introduction" section, the motivation for research and an overview of previous research and results in the field of nonlinear chaotic systems is given. The section is an overview of the research into the use of chaos in communication systems and the development of chaotic communication systems.

In chapter two "Osnove kaosa" a short introduction to nonlinear systems and chaos is provided by reviewing the use of chaos in various scientific and engineering areas. The development of the chaos theory and the basic phenomena and features of systems that behave chaotic are shown. The basic concepts needed to understand the behavior of chaotic systems are introduced.

In the third chapter "Osnove prijenosa podataka proširenim spektrom", the motivation and an overview of the development of data transmission methods based on spread spectrum techniques is given. The basics of several spread spectrum techniques are described, as well as the advantages and disadvantages of using the spread spectrum. Detailed description of the transmission techniques in direct sequence systems and the method of using direct sequence spreading in multi-access code division systems is given. The correlation characteristics of the optimal spreading sequences are described and performance degradations due to the interference of multiple access are displayed. An overview of generation and properties of basic orthogonal sequences is given. The synchronization sequence method by partial correlation with respect to the synchronization threshold is explained.

The fourth chapter "Model sustava" describes the characteristics of the physical layer and the media access control layer according to the standard for personal radio networks. In general, an overview of the standard for personal radio networks and the topology of such networks is given. The method of programming a system model on a software defined radio platform is described. Detailed description of all parts of the media access control layer and the physical layer according to the standard is given. A way of transmitting data is described based on software defined radio architecture. Basic concepts and the use of software defined radio is introduced. Detailed description of the laboratory model programmed in the LabView software tool is provided.

Chapter 5 "Optimiranje kaotičnih sljedova" provides a mathematical description of the correlation properties of optimal spreading sequences. The term Golay figure of merit correlation parameter is defined as well as the connection with the autocorrelation and crosscorrelation function. The method of optimizing chaotic sequences is described in relation to Golay's figure of

merit factor. An overview of three one-dimensional chaotic maps is used to generate optimized sequences for bandwidth expansion. A method of generating bipolar sequences from signals generated by chaotic maps is described. A comparison of the Golay figure of merit dependence on the chaotic system parameter and the method of generating optimized chaotic sequences by selecting certain values of the chaotic system parameter is compared. The correlation properties of chaotic sequences generated by different methods in relation to the Gold sequences are compared.

In the sixth chapter "Sinkronizacijske tehnike u radijskim komunikacijskim sustavima" the techniques of synchronization and estimation of unknown parameters of the modulated signal are described. A mathematical description of the method of estimation of unknown phase, frequency and sampling time of the modulated signal on the receiver is presented. A description of the estimation method using the known reference symbols is shown. Methods of estimator performance in the laboratory model for phase, frequency and sampling time are explained. A channel equalization method using known reference symbols is described.

In Chapter Seven, "Mjerni postav sustava i evaluacija performanci", describes the measurement procedure and system performance evaluation. The description of the measurement setup and settings of the communication system on the software defined radio architecture is given. The power measurement process for obtaining a reference level for comparing the performance of a software defined radio architecture is given. Bit error rate performance is compared against the received signal power in the system with the chaotic sequences and Gold sequences. The performance of chaotic sequences and Gold sequences in a multi-user environment is compared. The performance of the chaotic sequences as reference symbols for the estimation of unknown parameters is compared. The results of comparison show the performance improvement in the system with optimized chaotic sequences.

In the eighth chapter, "Zaključak", the results are commented. The motivation for further research through better methods of optimizing chaotic sequences is given.

Keywords: chaos, spread spectrum, optimised chaotic sequences, software defined radio, wireless sensor networks

Sadržaj

1. Uvod 1

2. Osnove kaosa 6
- 2.1. Ovisnost o početnim uvjetima 7
- 2.2. Upotreba kaosa 8
- 2.3. Kaotični iteratori 9
- 2.4. Bifurkacijski dijagram 10
- 2.5. Ljapunovljev eksponent 11

3. Osnove prijenosa podataka proširenim spektrom 13
- 3.1. Vrste sustava s proširenim spektrom 15
  - 3.1.1. Sustavi s proširenjem izravnim slijedom 16
  - 3.1.2. Sustavi s višestrukim pristupom po kodu 17
- 3.2. Sljedovi za proširenje pojasa 20
- 3.3. Optimalni slučajni sljedovi 22
- 3.4. Walsh-Hadamard sljedovi 22
- 3.5. Gold sljedovi 23
- 3.6. Sinkronizacija slijeda za proširenje 24

4. Model sustava 27
- 4.1. Model sustava na platformi programski određenog radija 28
  - 4.1.1. Sloj upravljanja pristupa mediju 28
  - 4.1.2. Fizički sloj 29
- 4.2. Programski određeni radio 31
  - 4.2.1. Reprogramimabilnost 32
  - 4.2.2. Rekonfigurabilnost 32
  - 4.2.3. Ograničenja 33
- 4.3. Dijelovi programski određenog radija 33
  - 4.3.1. Digitalna obrada signala 33
  - 4.3.2. Radiofrekvencijski dio 34

4.3.3. Pretvorba u signal s kompleksnom ovojnicom . . . 34
4.3.4. USRP platforma . . . 35
4.4. Izvedba modela u LabView programskom alatu za platformu programski određenog radija . . . 37

5. Optimiranje kaotičnih sljedova . . . 42
5.1. Kaotični iteratori za generiranje sljedova . . . 44

6. Sinkronizacijske tehnike u radijskim komunikacijskim sustavima . . . 59
6.1. Procjena najvećom podudarnosti za diskretne signale . . . 60
6.2. Procjena frekvencije nosioca korištenjem poznatih referentnih simbola . . . 62
6.2.1. Praktične izvedbe procjenitelja frekvencije . . . 63
6.3. Procjena faze nosioca korištenjem poznatih referentnih simbola . . . 64
6.4. Sinkronizacija takta uzorkovanja . . . 65
6.5. Procjena kanala . . . 66

7. Mjerni postav sustava i evaluacija performanci . . . 68
7.1. Mjerenje snage USRP platforme . . . 70
7.2. Učestalost pogreške bita u odnosu na prijamnu snagu . . . 71
7.3. Učestalost pogreške bita u višekorisničkom okruženju . . . 74
7.4. Evaluacija performanci sinkronizacije . . . 80

8. Zaključak . . . 94

Literatura . . . 97

Popis oznaka . . . 104

Popis slika . . . 105

Popis tablica . . . 110

Životopis . . . 111

Biography . . . 113

Poglavlje 1

Uvod

Digitalni komunikacijski sustavi razvijaju se i istražuju proteklih nekoliko desetljeća kako bi se ostvarile što veće brzine prijenosa, povećala spektralna učinkovitost i stupanj zaštite podatka. S druge strane teži se smanjenju troškova opreme te što povoljnijem proširenju i nadogradnji mreže. Fokus istraživanja prebacuje se s pronalaženja što učinkovitijih modulacijskih postupaka i kodiranja na optimiranje zahtjeva između spektralne učinkovitosti modulacijskog postupka, potrošnje električne energije komunikacijskog sustava i jednostavnosti proširenja i zamjene postojećih sustava. Smjer istraživanja okreće se pametnim i zelenim komunikacijskim mrežama uz maksimalno iskorištavanje postojećih kapaciteta kanala i dostupnih modulacijskih tehnika.

Trenutno, najveći dio istraživanja i razvoja radijskih sustava provodi se u segmentu povećanja podrške za velik broj uređaja u područjima profesionalnih upotreba radijskih komunikacijskih sustava. Korisnici radijskih sustava zahtijevaju neometanu, sigurnu i robusnu komunikaciju sa što manjom složenošću sustava i ukupnih troškova. Jedan od načina ostvarivanja zadanih zahtjeva, uz što manji opseg izmjena postojećih sustava i načina komuniciranja, jest optimiranje performanci poznatih modulacijskih tehnika i komunikacijskih sustava. Jedan od smjerova istraživanja je pronalaženje modulacijskih postupaka i tehnika prijenosa sa što većom spektralnom učinkovitošću. Drugi smjerovi istraživanja provode se u korištenju nekih nekonvencionalnih postupaka prijenosa i modulacije. Pod nekonvencionalnim postupcima može se smatrati i upotreba kaosa i kaotičnih modulacija kao tehnika prijenosa u komunikacijskim sustavima.

Istraživanja u polju korištenja kaosa u komunikacijskim sustavima provode se već nekoliko desetljeća [1, 2, 3, 4]. Pronalaskom sinkronizacijskih mogućnosti u kaotičnim sustavima Pecore [1] otvorilo se veliko područje istraživanja u upotrebi kaosa u komunikacijskim sustavima. Istraživanje Pecore u sinkronizaciji kaotičnih sustava [1] omogućilo je korištenje kaotičnih nosioca i razvoj kaotičnih modulacijskih postupaka. Prije tog istraživanja smatralo se da kaotični nosioci i modulacijske tehnike ne mogu biti korištene u komunikaciji zbog nepostojanja sin-

kronizacijskih postupaka samog nelinearnog sustava. Razvojem prvog sklopa za generiranje kaotičnih signala, a koji se mogu koristiti u kaotičnim komunikacijskim tehnikama, pripisuje se Chui. Razvoj takvog sklopa pokazao je da se kaotični signali mogu generirati korištenjem jednostavnih sklopova uz malu potrošnju energije [5].

Nelinearne tehnike i upotreba teorijskih rezultata kaosa omogućuju dodatno proširenje i poboljšanje postojećih tehnika prijenosa kao i dijelova komunikacijskog sustava [2, 6, 7]. Rezultati nelinearnih tehnika mogu se uspješno upotrijebiti u povećanju performanci poznatih modulacijskih tehnika [2, 8, 9, 10, 11, 12, 13, 14, 15, 16, 17]. Zapravo su kaotični sustavi najprije upotrebljavani kao generatori slučajnih brojeva u svrhu poboljšanja postojećih enkripcijskih algoritama u kriptografiji [18, 19, 20]. Veliko područje istraživanja u korištenju kaosa provodi se u enkripciji i kompresiji slika [14, 21, 22] gdje se koriste dobra svojstva nelinearnih sustava u sakrivanju i kodiranju podataka.

Nelinearne ili kaotične modulacijske tehnike mogu omogućiti robusniju komunikaciju kao i povećanje broja korisnika i uređaja uz zadržavanje iste razine kompleksnosti sustava. Komunikacijski sustavi koji koriste kaos u nekom svojem dijelu pokazuju poboljšane performance od sustava koji ne koriste kaotične postupke [2, 8, 9, 10, 23].

Veliki dio istraživanja u kaotičnim komunikacijama provodi se u području kaotičnih modulacijskih postupaka i signala nosioca, kaotične sinkronizacije i enkripcije te generatora slučajnih signala i sljedova [24]. Kaotični generatori slučajnih signala pokazuju veću otpornost na različite analitičke napade što je posebno važno u kriptografskim primjenama i komunikacijskim sustavima s proširenim spektrom [25]. U kriptografskim primjenama koriste se dobra svojstva kaotičnih sustava koja poboljšavaju razinu sigurnosti unoseći veću slučajnost [26, 27, 28, 29]. Svojstva kaotičnih nelinearnih sustava omogućuju im otpornost na razne napade analiziranjem dugotrajnih pravilnosti.

Korištenjem kaosa u postojećim komunikacijskim sustavima povećava se kapacitet, robusnost, kvaliteta usluge, sigurnost te učinkovitije iskorištavaju postojeći resursi. Kaotični signali pokazuju kompleksno ponašanje te generiraju signale sa širokim frekvencijskim pojasom [24]. Upotreba kaotičnih tehnika prijenosa raširena je u mnogim komunikacijskim sustavima, posebno onima gdje je potreba dodatna razina robusnosti i zaštite podataka [8, 23, 30]. Dosta istraživanja bavi se kaotičnim maskiranjem informacijskog signala gdje se na informacijski signal dodaje kaotični signal u svrhu zaštite [7]. Prijamnik, uz pretpostavku sinkroniziranih kaotičnih sustava, rekonstruira originalnu informaciju oduzimanjem kaotičnog nosioca. Takav način prijenosa često ne jamči dovoljnu razinu zaštite jer dodavanje kaotičnog signala povećava snagu moduliranog signala i napadač može procijeniti poslanu informaciju prateći promjene u snazi signala [31]. Umjesto dodavanja kaotičnog nosioca na sam informacijski signal, korištenjem kaotičnog modulatora signal informacije se koristi u nelinearnom kaotičnim sustavu kako bi promijenio dinamički model samog sustava. Na izlazu sustava dobiva se kaotično modulirani

signal. Prijamnik detektira dinamičku promjenu signala te rekonstruira poslanu informaciju [32]. Kod tehnike diskretne kaotične modulacije CSK (eng. *Chaotic Shift Keying*) informacija se modulira korištenjem dva kaotična sustava [33] ovisno šalje li se simbol "-1" ili simbol "1". Pojedini kaotični sustav se koristi za određeni poslani simbol.

Zbog same svoje prirode, odnosno osjetljivosti na male promjene početnih uvjeta, kaotični sustavi se opiru sinkronizaciji i postizanju stabilnih stanja. To se svojstvo može koristiti za sigurniju i robusniju komunikaciju. Zbog te osjetljivosti često je teško sinkronizirati dva udaljena kaotična sustava. Kako bi se iskoristila dobra svojstva slučajnosti kaotičnih sustava, moguće je ostvariti sinkronizaciju generiranjem replike kaotičnog signala na prijamniku. Ta se pojava koristi kod komunikacijskih sustava koji se temelje na proširenom spektru, odnosno množenjem informacijskih signala nekim kaotičnim pseudoslučajnim slijedom [2]. Informacijski signal se u odašiljaču množi (proširuje) odašiljačkim kaotičnim slijedom. Prijamnik poznaje repliku kaotičnog signala za proširenje te se u prijamniku signal množi replikom kaotičnog slijeda kako bi se sažeo.

Kako bi se ostvarila robusna i sigurna komunikacija u sustavima s proširenim spektrom potrebno je generirati kaotične pseudoslučajne sljedove s dobrim korelacijskim svojstvima. Postoji veliki istraživački interes u području generiranja kaotičnih sljedova za proširenje spektra sa svojstvima koja pokazuju poboljšanja performanci u odnosu na trenutno korištene sljedove za proširenje. Najčešće se analiziraju korelacijska svojstva sljedova koja se koriste za poboljšanje sinkronizacije i performanci prijenosa [34, 35, 36]. Analizom korelacijskih svojstava mogu se dizajnirati i generirati kaotični sljedovi koji ostvaruju jednake ili bolje performance u odnosu na ortogonalne ili sljedove maksimalne duljine [37, 38, 39, 40].

Prijenosna tehnika koja koristi modulaciju korištenjem kaotične dinamičke simbolike preslikava informacijske simbole u različite trajektorije kaotičnog iteratora promjenom nekih vrijednosti nelinearnog sustava [41, 42, 43]. Korištenjem svojstva kaotičnog sustava na osjetljivost promjene početnih uvjeta ostvaruju se trajektorije koje vrlo brzo divergiraju.

Kod takvih istraživanja u analizi komunikacijskih sustava potrebno je imati platformu koja omogućuje jednostavan i brz model izmjene parametara i dijelova komunikacijskog sustava. Postoje mnogi simulacijski programski alati koji omogućuju usporedbu parametara i performanci, no takvi simulacijski alati samo emuliraju neka izobličenja koja su prisutna u stvarnim sustavima i prijenosnim sredstvima. Posebno je zahtjevno vjerno simulirati i uključiti razne utjecaje kanala i stvarnih izobličenja signala na radijske komunikacijske sustave. Radijski komunikacijski sustavi koriste slobodni prostor za prijenos informacije, a koji bi se mogao vjerno simulirati tek uz korištenje nebrojeno mnogo varijabli. Programski određeni radio SDR (eng. *Software Defined Radio*) premošćuje zahtjevan dio između simulacijskog alata i prijenosa signala stvarnim radijskim kanalima. Komunikacijski sustavi temeljeni na platformi i ideji programski određenog radija omogućuju izradu prototipa postojećih komunikacijskih sustava te

optimiranje određenih podsustava [44, 45, 46, 47].

Programski određeni komunikacijski sustav može se promatrati kao da je sastavljen od dva osnovna dijela, odnosno podsustava. Prvi podsustav je programski određeni dio, koji se može nazvati simulacijskim dijelom, odnosno dijelom obrade signala. Drugi podsustav se sastoji od sklopova koji pretvaraju digitalnu informaciju iz programskog dijela u signal s kompleksnom ovojnicom pogodan za prijenos nekim sredstvom [47, 48, 49].

Upravo je takva sinergija simulacijskog dijela i sklopovskog dijela dobro prilagođena za izradu prototipa, analizu i evaluaciju performanci različitih dijelova komunikacijskog sustava. Programski dio zadužen je za digitalnu obradu signala i izvodi se na računalnoj platformi u obliku programskog alata. Programski alat, kroz potprograme, obavlja sve funkcije komunikacijskih slojeva potrebne za odašiljanje i primanje signala [47, 49]. Blokovska podjela zadataka u obliku potprograma omogućuje izmjenu parametara svakog pojedinog dijela komunikacijskog sustava te provjeru performanci i utjecaja na kvalitetu prijenosa. Takav model je posebno prilagođen provjeri performanci novih tehnika kodiranja, enkrpcije, modulacijskih postupaka i pristupa fizičkom sloju kao i metoda zaštite podataka [49].

U ovom radu evaluirat će se kaotični sljedovi generirani iz različitih kaotičnih sustava. Model temeljen na programski određenom radiju će se koristiti za evaluaciju parametara kvalitete prijenosa u digitalnim radijskim sustavima.

U drugom poglavlju rada daje se općeniti uvod u kaos, nelinearne sustave koji se ponašaju kaotično te svojstva takvih sustava. Uvođenjem nekih osnovnih pojmova iz teorije kaosa pojašnjavaju se pojave u takvim sustavima. Daje se opis ponašanja nelinearnih sustava u različitim uvjetima.

Treće poglavlje opisuje osnove proširenog spektra i sustava koji koriste višestruki pristup po kodu. Daje se pregled nekih sljedova za proširenje pojasa, a koji se koriste u radijskim komunikacijskim sustavima. Opisuje se i degradacija performanci uslijed neoptimalnih svojstava sljedova za proširenje kao i problemi u realnim sustavima.

Četvrto poglavlje objašnjava izradu modela sustava na arhitekturi programski određenog radija. Daje se pregled svih dijelova sustava te opisuje način rada programski određenog radija. Pojašnjavaju se ograničenja pri korištenju arhitekture programski određenog radija. Opisuje se model sustava na arhitekturi programski određenog radija u LabView programskom alatu te opisuje način rada pojedinog bloka. Povezuje se izrađen model sustava sa zadanim modelom prema IEEE normi kroz fizički sloj te sloj kontrole pristupa mediju.

Peto poglavlje opisuje metode optimiranja kaotičnih sljedova te daje pregled korištenih kaotičnih iteratora. Opisuje se ponašanje pojedinog kaotičnog iteratora u odnosu na parametar nelinearnog sustava. Objašnjava se generiranje diskretnih bipolarnih sljedova iz signala dobivenog iz kaotičnog sustava. Objašnjavaju se metode optimiranja sljedova u odnosu na Golayev faktor u dva načina generiranja sljedova. Prikazuju se rezultati optimiranja kaotičnih sljedova u

odnosu na Golayev parametar. Daje se povezanost Golayevog parametra u odnosu na parametar nelinearnog sustava.

Šesto poglavlje daje pregled osnovnih tehnika sinkronizacije parametara signala u prijamniku. Posebno se izdvajaju modeli sinkronizacije koji koriste referentne simbole za procjenu parametara (eng. *Data-Aided*). Daje se pregled tehnika sinkronizacije koje se koriste u modelu korištenom za evaluaciju performanci.

Sedmo poglavlje opisuje načine mjerenja i određivanja performanci kaotičnih sljedova i sustava programski određenog radija. Daje se pregled mjernog postava sustava te uočena ograničenja. Prikazuju se i rezultati i poboljšanja performanci pri korištenju kaotičnih sljedova u evaluaciji na modelu za programski određeni radio. Performance su evaluirane kroz vrijednosti učestalosti pogreške bita te mjera kvalitete demoduliranog signala. Promatra se sustav za jednog korisnika te višekorisnički sustav. U sustavu s jednim korisnikom izvršena su mjerenja snage na ulazu u prijamnik te izmjerene performance preko učestalosti pogreške bita.

Osmim poglavljem zaključuje se doktorski rad.

Poglavlje 2

Osnove kaosa

Potpuna i jednoznačna definicija kaosa nije određena već se kaos opisuje kao dugotrajno aperiodičko ponašanje u determinističkom sustavu koje pokazuje ovisnost o početnim uvjetima. Pojava kaosa primjećena je u mnogim područjima: atmosfersko vrijeme i klima, gibanju nebeskih tijela, promjena u populaciji, medicini kroz analizu srčanog ritma i rada mozga, u laserima i električnim krugovima, dinamici fluida i mnogim drugim prirodnim sustavima [50, 51]. Kaos se općenito javlja u nelinearnim dinamičkim sustavima pri određenim uvjetima. Kaotično ponašanje sustava može se primjetiti i u vrlo jednostavim sustavima ako se određeni parametri sustava podese na prikladan način. Danas se kaosom smatra ponašanje determinističkog sustava na prividno nepredvidiv način [52].

Općenito postoje dvije vrste dinamičkih sustava: diferencijalne jednadžbe i iteratori (difrencijske jednadžbe, preslikavanja). Diferencijalne jednadžbe opisuju promjenu sustava u kontinuiranom vremenu, dok iteratori prikazuju promjenu nelinearnog sustava u diskretnim vremenskim trenucima. Zato su iteratori izrazito pogodni za promatranje nelinearnih sustava jer omogućuju fino namještanje diskretnog koraka te simulaciju sustava u programskim alatima.

U ovom radu koristit će se deterministički kaos koji se pojavljuje u nelinearnim diskretnim sustavima pri čemu se takvi sustavi počnu ponašati neperiodično, a rezultat im izrazito ovisi o početnim uvjetima koji ulaze u takav sustav.

Općenito, svako kaotično ponašanje trebalo bi imati sljedeća tri obilježja [53]:

- aperiodičko dugotrajno ponašanje,
- determinizam,
- visoku osjetljivost na početne uvjete.

Obilježje aperiodičkog dugotrajnog ponašanja opisuje kretanje trajektorija koje ne konvergiraju prema fiksnim točkama, periodičnim ili kvaziperidiočnim orbitama kada $t \to \infty$. Sustav ima kompleksne uzorke oscilacija u faznom prostoru koji ponekad izgledaju kao šum. U kaotičnom sustavu takve se kompleksne oscilacije mogu u potpunosti ponovno stvoriti ako se može postići dovoljna preciznost u početnim uvjetima [53, 54].

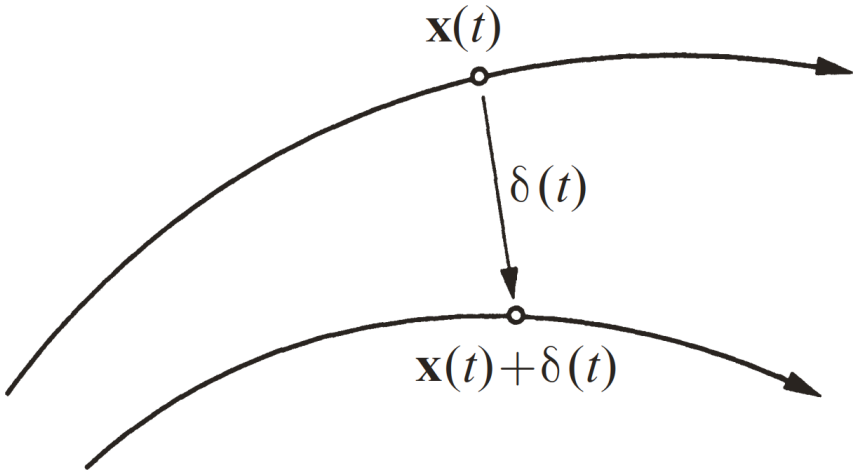
Determinizam pretpostavlja da nelinearni sustav nema slučajnih ulaza ili pojave šuma, odnosno ne postoji stohastička veličina koja bi mogla proizvesti slučajne signale. Nepravilno i nepredvidivo ponašanje sustava proizlazi iz nelinearnosti u sustavu, a ne slučajnih procesa koji utječu na sustav izvana. Visoka osjetljivost na početne uvjete opisuje eksponencijalnu divergenciju vrlo bliskih trajektorija ako sustav ima pozitivan Ljapunovljev eksponent [53, 54].

2.1 Ovisnost o početnim uvjetima

Edward Lorenz proučavao je konvekcijsko gibanje u atmosferi korištenjem jednostavnog analognog računala. Jednadžbe koje opisuju takvo gibanje relativno su jednostavne te se očekivalo da će biti moguće predvidjeti njihovo ponašanje, a samim time i ponašanje atmosferskog vremena. Računalnim pokusom Lorenz je pokazao da jednadžbe ne konvergiraju već počinju oscilirati na neperiodičan i nepravilan način. Lorenz je također pokazao ovisnost sustava o početnim uvjetima pri čemu je pri maloj promjeni početnog uvjeta došlo do značajne promjene u ponašanju sustava i načina na koji sustav oscilira što se popularno naziva leptirov učinak. Smatralo se da su takvi nelinearni sustavi po samoj prirodi nepredvidljivi, no Lorenz je pokazao da postoji struktura u pozadini naoko nepredvidljivih oscilacija [52, 54, 55].

Ovisnost o početnim uvjetima prepoznaje se u nekoreliranim oscilacijama nelinearnog sustava uslijed male promjene početnih vrijednosti. Trajektorije različitih početnih uvjeta brzo divergiraju s protokom vremena. Praktična upotreba takvih sustava moguća je zbog dugoročne nepredvidljivost u sustavima gdje je potrebna visoka razina slučajnosti.

Neka je $\mathbf{x}(t)$ točka na trajektoriji nelinearnog sustava u trenutku t, a druga točka $\mathbf{x}(t)+\delta(t)$, gdje je $\delta(t)$ vektor pomaka vrlo malog iznosa, npr. $\|\delta_0\| = 10^{-15}$. Tada se može promatrati putanje različitih trajektorija kao na slici 2.1 [54].



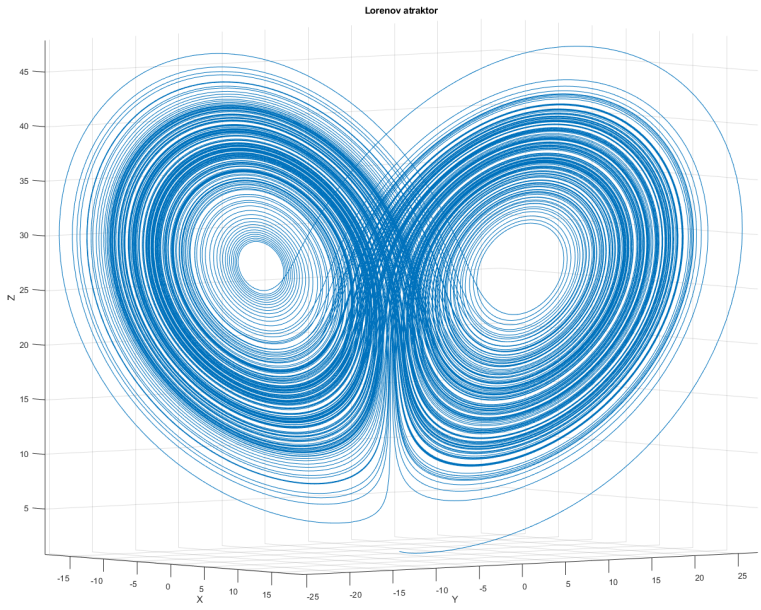
Slika 2.1: Putanje s različitim početnim uvjetima

Numerički se može pokazati da vrijedi

$$\|\delta(t)\| \sim \|\delta_0\| e^{\lambda t} \tag{2.1}$$

gdje se λ naziva Ljapunovljevim eksponentom. Iz 2.1 može se vidjeti da se vrlo bliske trajektorije počinju udaljavati eksponencijalno brzo. Jedan od osnovnih testova za detekciju kaotičnog ponašanja je računanje Ljapunovljevog eksponenta koji je veći od 0 za kaotična stanja sustava [53].

Iscrtavanjem trajektorija u faznom prostoru varijabli dobivaju se krivulje na kojima se može vidjeti stabilnost i ponašanje sustava. Krivulje pokazuju postoji li u sustavu točka prema kojoj u beskonačnosti konvergira sustav, a koja se naziva atraktor. Jedna od takvih krivulja ima oblik leptirovih krila upravo za sustav kojeg je promatrao Edward Lorenz, a može se vidjeti na slici 2.2.



Slika 2.2: Atraktor oblika leptirovih krila za Lorenzov sustav

2.2 Upotreba kaosa

Nelinearnost i kaos su se do tada smatrali smetnjom odnosno šumom ili samo kao zanimljiva pojava za istraživanje bez neke praktične primjene. Razvojem i istraživanjima pronađene su mnoge upotrebe kaosa i kaotičnih sustava za različite inženjerske probleme. Kaos i kaotične pojave postale su korisne i dio rješenja za neke probleme. S obzirom na to da postoji određeni red i determinizam u nelinearnim sustavima koji pokazuju kaotično ponašanje, analizom signala

iz raznih znanstvenih i inženjerskih grana pronašlo se kaotično ponašanje. Tako je kaotično ponašanje pronađeno u ekologiji, medicini, ekonomiji, meterologiji i mnogim drugim prirodnim i tehničkim znanostima i sustavima [52, 55].

Kako se kaotični sustavi ponašaju na prividno slučajan i nepredvidiv način posebno je zanimljiva primjena kaosa za šifriranje i kodiranje poruka i podataka korištenjem svojevrsnoga kaotičnog signala nosioca [53]. Zbog svoje osjetljivosti na početne uvjete kaotični signali su prikladni za korištenje u komunikacijskim sustavima. Upotreba kaosa u komunikacijskim sustavima posebno je doživjela razvoj krajem 20-og stoljeća nakon otkrića kaotične sinkronizacije Pecore i Carrola [1]. Primjena kaosa u komunikacijskim sustavima je prikladna za generatore slučajnih brojeva, modeliranje i mjerenje komunikacijskih kanala, kriptografiju, kodiranje slike i videa, kao zamjena za sljedove za proširenje pojasa, za kompresiju, enkripciju i modulaciju [33, 34, 35, 56, 57, 58].

2.3 Kaotični iteratori

Kaotični iteratori predstavljaju diskretne kaotične nelinearne sustave u jednostavnom matematičkom obliku. Iteratori opisuju nelinearni sustav u diskretnim vremenskim trenutcima. Jedna od temeljnih postavki kaosa jest da jednostavni sustavi ne moraju uvijek proizvoditi jednostavno i predvidljivo ponašanje. Odnosno, smatra se da se u deteminističkom sustavu može pojaviti prividno stohastičko ponašanje pod određenim uvjetima [52].

Iteratori se matematički opisuju kroz diferencijske jednadžbe i općenito se prikazuju kao:

$$x_{n+1} = F(x_n) \tag{2.2}$$

gdje je x_n vrijednost varijable za korak n, $F(x_n)$ je $F : X \to X$ preslikavanja ili funkcija iteratora odnosno autonomni diskretni dinamički nelinearni sustav.

Stanje nelinearnog sustava x_0 kada je $t = 0$ naziva se početno stanje. Sustav može poprimiti po potrebi velik broj početnih stanja. Skup svih stanja ili točaka kroz koje prolazi sustav iz početnog stanja naziva se trajektorija ili orbita [54]. Sustav će doći u ta stanja iteriranjem funkcije $F(x)$ tako da je $x_1 = F(x_0)$, $x_2 = F(x_1) = F(F(x_0))$, ..., $x_n = F(x_{n-1}) = F^n(x_0)$ gdje je F^n n-ta iteracija i može se prikazati kao kompozicija funkcije [53, 54, 55]:

$$F^n = \underbrace{F \circ F \circ \cdots \circ F}_{\text{n puta}} \tag{2.3}$$

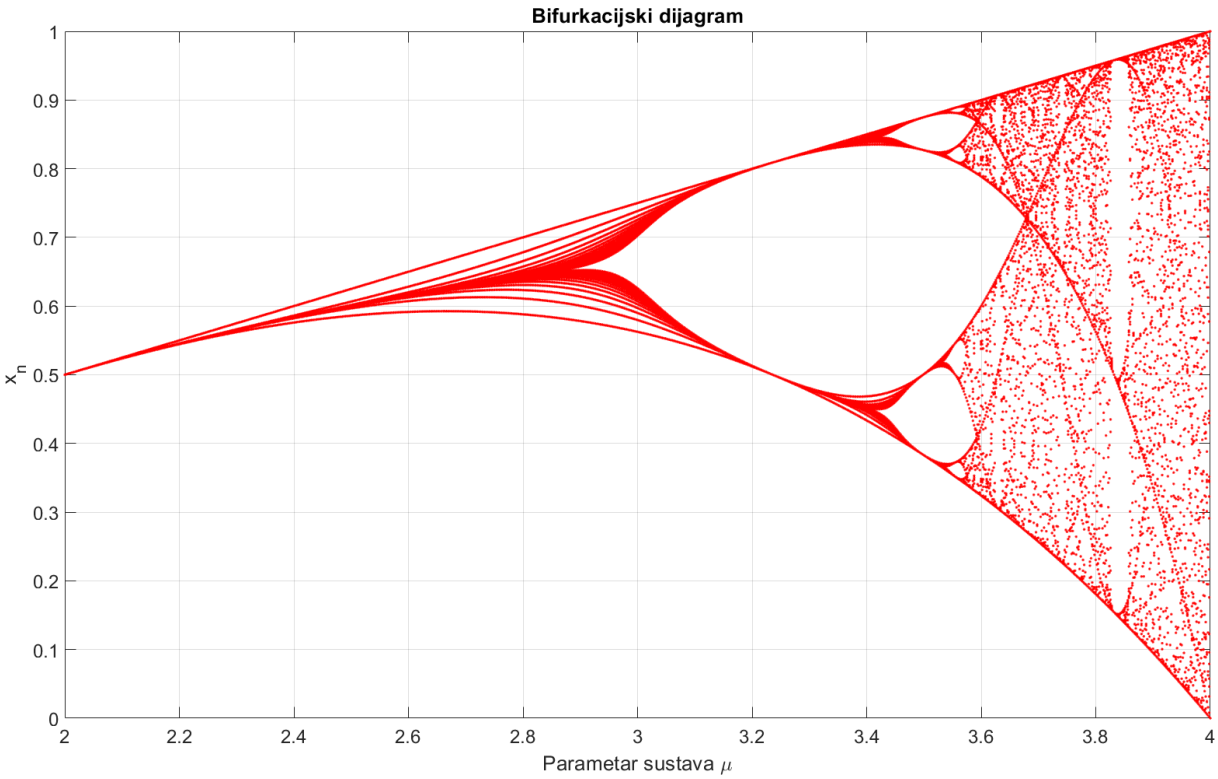
gdje je operator kompozicije definiran kao $F \circ F = F(F(x))$.

Kaotični iteratori, zbog svoje diskretne prirode, posebno su pogodni za proučavanje i upotrebu u računalima. Jednostavno modeliranje kaotičnih sustava diskretnim iteratorima omogu-

ćuje dublje istraživanje i razvoj novih načina upotrebe kaosa [53].

2.4 Bifurkacijski dijagram

Općenito, bifurkacija predstavlja trenutak u kojem iz jedne privlačne fiksne točke kaotičnog sustave nastanu dvije vrijednosti. Ovaj se događaj pojavljuje samo u određenim uvjetima u ovisnosti o vrijednosti parametra kaotičnog sustava i početnog uvjeta. Ako se prikažu vrijednosti dobivene korištenjem kaotičnog iteratora u ovisnosti o nekom parametru sustava dobiva se dijagram orbita. Bifurkacijski dijagram prikazuje sva moguća stanja kroz koja sustav nepredvidivo prolazi za određenu vrijednost parametra sustava. Na bifurkacijskom dijagramu lako se može uočiti povećanje perioda odnosno broja vrijednosti koje sustav može poprimiti. Povećanjem perioda, primjećuje se pojava sve više frekvencijskih komponenti u spektru kaotičnog signala kako se mijenja parametar sustava. Na slici 2.3 vidi se bifurkacijski dijagram populacijskog iteratora za početni uvjet $x_0 = 0.5$ te promjenu parametra u intervalu $\mu = [2 \quad 4]$. Parametar sustava određuje ponašanje sustava, a može se promatrati kao proizvoljna vrijednost varijable μ. Svaki nelinearni sustav, za određene vrijednosti parametre sustava, ponašat će se na drugačiji način. Za određene vrijednosti parametra, sustav će se ponašati periodičko, a vrijednosti će konvergirati jednoj ili više fiksnih točaka. Promjenom parametra sustav može početi oscilirati bez pojave konvergencije te prelazi u kaotično stanje.



Slika 2.3: Bifurkacijski dijaram za populacijski iterator

2.5 Ljapunovljev eksponent

Obilježje sustava koji je u kaotičnom području rada jest pozitivan Ljapunovljev eksponent. Ljapunovljev eksponent numerički pokazuje iznos ovisnosti o malim promjenama početnih uvjeta u sustavu. Neka je x_0 početni uvjet, a $x_0 + \delta_0$ vrlo malo odstupanje početnog uvjeta. Neka je δ_n odstupanje nakon n iteracija. Ako je $|\delta_n| \approx |\delta_0| e^{n\lambda}$, tada se λ naziva Ljapunovljev eksponent. Ljapunovljev eksponent za kontinuirane sustave može se dobiti kao [53]:

$$\lambda = \frac{1}{n} \ln \left| \frac{\delta_n}{\delta_0} \right| \tag{2.4}$$

gdje je n red derivacije u kompozicji. Ako je $\delta_n = f^n(x_0 + \delta_0) - f^n(x_0)$, dobiva se

$$\lambda = \frac{1}{n} \ln \left| \frac{f^n(x_0 + \delta_0) - f^n(x_0)}{\delta_0} \right| = \frac{1}{n} \ln \left| (f^n)'(x_0) \right| \tag{2.5}$$

Izraz u logaritmu može se prikazati kao

$$(f^n)'(x_0) = \prod_{i=0}^{n-1} f'(x_i) \tag{2.6}$$

Što daje

$$\lambda = \frac{1}{n} \ln \left| \prod_{i=0}^{n-1} f'(x_i) \right| = \frac{1}{n} \sum_{i=0}^{n-1} \ln \left| f'(x_i) \right| \tag{2.7}$$

Ako se pretpostavi da $n \to \infty$, Ljapunovljev eksponent poprima oblik

$$\lambda = \lim_{n \to \infty} \{ \frac{1}{n} \sum_{i=0}^{n-1} \ln \left| f'(x_i) \right| \} \tag{2.8}$$

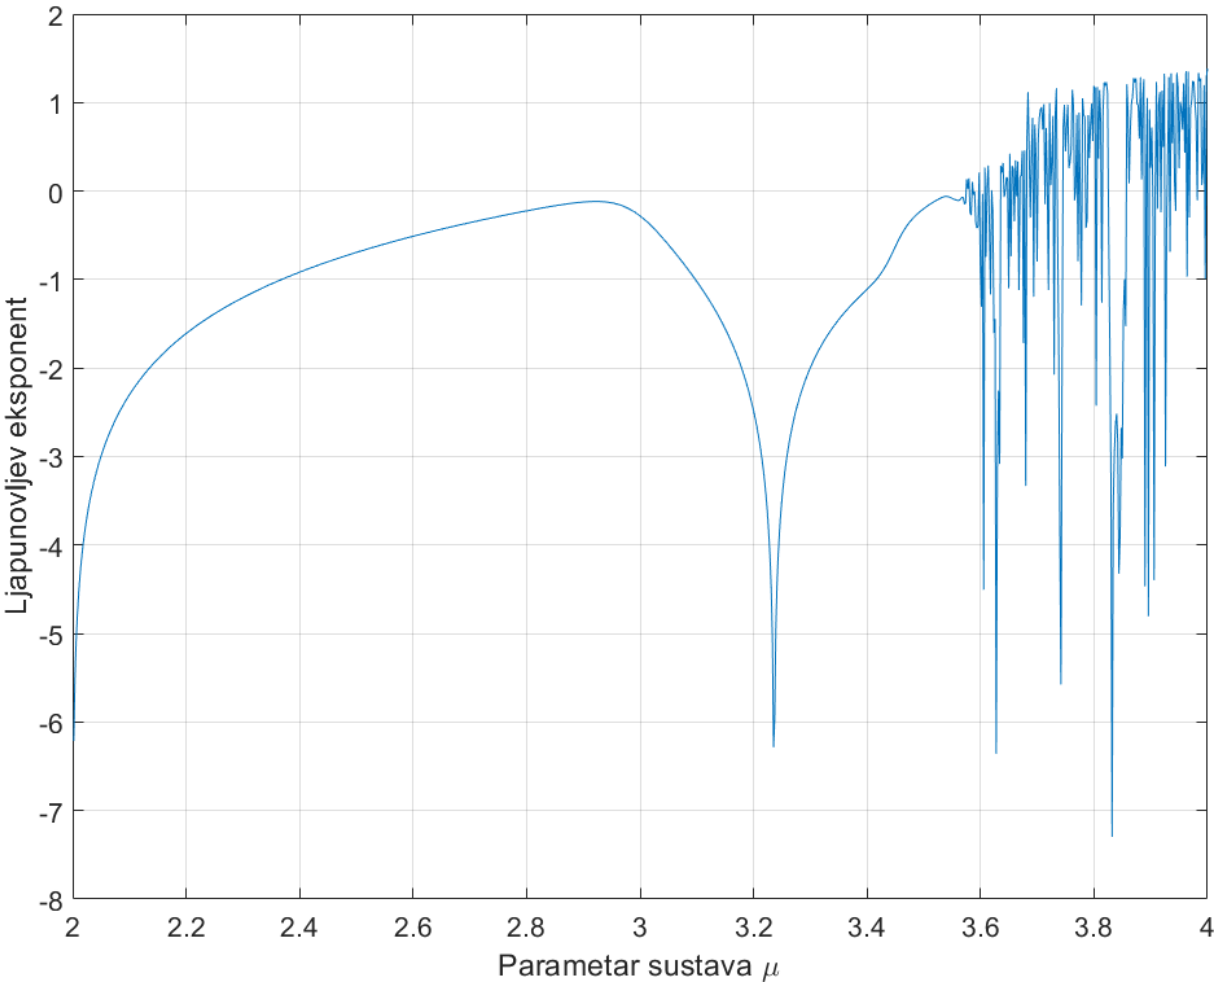
Ljapunovljev eksponent za diskretne sustave možemo prikazati kao

$$\lambda(X) = \frac{1}{N} \sum_{i=1}^{N} \ln \left| \frac{F(X_{i+1}) - F(X_i)}{X_{i+1} - X_i} \right| \tag{2.9}$$

gdje je N broj uzoraka kaotičnog signala, a $F(X)$ funkcija kaotičnog iteratora u diskretnom vremenu.

Izračunom i usporedbom Ljapunovljevog eksponenta može se provjeriti nalazi li se dinamički sustav u kaotičnom području rada ili je u periodičkom ili kvaziperiodičkom području. Na slici 2.4 može se vidjeti promjena Ljapunovljevog eksponenta populacijskog iteratora u odnosu na parametar sustava μ.

Stanje sustava često ovisi o parametru sustava. Ako se promatra populacijski iterator tada će on za različite vrijednosti parametra $\mu = [0 \quad 4]$ prolaziti kroz razne oblike ponašanja. Za



Slika 2.4: Promjena Ljapunovljevog eksponenta za populacijski iterator

$\mu = [0 \quad 3]$ sustav je u režimu postojanog stanja, što znači da će se sustav konvergirati jednoj vrijednosti varijable X_n u koju će doći nakon nekoliko iteracija. Promjenom parametra sustava μ položaj fiksne točke će se lagano mijenjati.

Za vrijednosti parametra $\mu > 3$ fiksna točka postaje nestabilna te vrijednosti X_n počinje oscilirati između dva broja. Ta se pojava naziva ciklus perioda 2. Gledajući spektar takvog signala, pojavljuje se još jedna diskretna frekvencija. Povećanjem parametra sustava μ od 3.5 do 3.57 periodi se udvostručavaju. Pri vrijednosti $\mu > 3.57$ period se udvostruči beskonačno mnogo puta te nastaje kaotično osciliranje. Kako se parametar sustava mijenja, ponašanje se mijenja iz postojanog u periodični te konačno prelazi u kaotično. Na bifurkacijskom dijagramu mogu se vidjeti prijelazi te ponašanja sustava. Zanimljivo je primijetiti da čak i unutar kaotičnog područja postoje prozori postojanog ponašanja za neke vrijednosti parametra μ [52].

Poglavlje 3

Osnove prijenosa podataka proširenim spektrom

Prvotni razvoj tehnika proširenog spektra započet je za primjene u vojne svrhe gdje se prošireni spektar koristio za sigurnu komunikaciju koju je teško otkriti i ometati. Kasnije su tehnike prijenosa proširenim spektrom prilagođene za civilne i komercijalne upotrebe. Tehnike prijenosa proširenim spektrom još uvijek su vrlo raširene bez obzira na dug period korištenja. Tehnike prijenosa proširenim spektrom posebno se aktivno koriste u područjima senzorskih mreža upravo zbog svoje otpornosti na smetnje.

Općenito postoji nekoliko uvjeta koje sustav mora zadovoljiti kako bi se smatrao sustavom s proširenim spektrom [59]:

1. Modulirani signal u prijenosnom pojasu zauzima značajno veći pojas frekvencija od informacijskog signala u osnovnom pojasu.
2. Proširenje spektra provodi se korištenjem posebnog signala za proširenje koji je neovisan od podatkovnog signala u osnovnom pojasu.
3. Prijamnik rekonstruira originalnu poruku korelacijom proširenog signala sa sinkroniziranom kopijom signala kojim se proširuje spektar.

Prošireni signal u prijenosnom pojasu frekvencija ima vrlo malu gustoću snage spektra koja se mijenja u ovisnosti o korištenom slijedu za proširenje i broju korisnika. Snaga proširenog signala sumjerljiva je sa snagom šuma. Prednost takvog načina prijenosa je smanjen utjecaj uskopojasnih sustava koji rade u istom pojasu. Proširenjem spektra povećava se otpornost na feding i intersimbolnu interferenciju te omogućuje dobro i jednostavno razdvajanje višestaznih komponenti. Signal iz osnovnog pojasa se kodira i maskira slijedom za proširenje koji bi trebao imati obilježja što sličnija bijelom šumu. Slijed za proširenje ima značajno kraće trajanje impulsa $T_c << T_b$ gdje je T_b trajanje bita u osnovnom pojasu. Jedan uzorak slijeda za proširenje naziva se i podimpulsom, a T_c trajanje podimpulsa.

Temelj za korištenje tehnika proširenog spektra dolazi iz izraza za kapacitet kanala prema

C. E. Shanonu. Izraz za kapacitet povezuje širinu pojasa, snagu signala te snagu bijelog šuma i interferencije [59]:

$$C = \int_0^B \log_2 \left(1 + \frac{\mathscr{P}_s(f)}{\mathscr{P}_n(f) + \mathscr{P}_j(f)}\right) df = B \log_2 \left(1 + \frac{P_s}{B \cdot N_0 + P_j}\right) = B \log_2 (1 + SNR) \quad (3.1)$$

gdje su B širina pojasa, $\mathscr{P}_s$, $\mathscr{P}_n$, $\mathscr{P}_j$ gustoće spektra snaga signala, šuma i interferencije. Snage P_s, $P_n = B \cdot N_0$ i P_j su pripadajuće snage unutar pojasa B te SNR odnos signala i šuma [59].

Pojam odnosa signala i šuma SNR (eng. *Signal-to-noise ratio*) je preuzet iz analognih sustava, no digitalni sustavi uobičajeno koriste diskretne vrste signala, odnosno impulse. U digitalnim sustavima kao varijabla se ne koristi analogna veličina odnosa signala i šuma SNR, već E_b/N_0, gdje je N_0 spektar gustoće snage šuma, a E_b energija bita. Energija bita E_b i trajanje T_b te sveukupna snaga šuma P_s u pojasu B mogu se izraziti kao [59]:

$$E_b = P_s T_b \quad (3.2)$$

$$P_n = N_0 B \quad (3.3)$$

Omjer energije bita i gustoće snage šuma dobiva se kao:

$$\frac{E_b}{N_0} = \frac{P_s T_b}{N_0} = \frac{P_s}{N_0}\left(\frac{1}{R_b}\right) = \frac{P_s}{N_0 B}\left(\frac{B}{R_b}\right) = \frac{P_s}{P_n}\left(\frac{B}{R_b}\right) \quad (3.4)$$

Iz jednadžbi 3.1, 3.2, 3.3 i 3.4 dobiva se sljedeći izraz za kapacitet [59]:

$$C = B \log_2 \left[1 + \left(\frac{E_b}{N_0}\right)\left(\frac{R_b}{B}\right)\right] \text{ bit/s} \quad (3.5)$$

Iz 3.5 vidljivo je da se kapacitet sustava linearno povećava s dostupnom širinom pojasa B. Ideja iza pristupa korištenjem proširenog spektra jest upravo povećanje širine pojasa B množenjem signalom koji ima kratko trajanje impulsa T_c. Proširenjem pojasa smanjuje se osjetljivost na uskopojasne smetnje te povećava osjetljivost prijama. Prijamniku koji ne poznaje korišteni slijed za proširenje pojasa, prošireni signal izgledat će kao signal šuma.

Shannonova formula 3.5 pokazuje da se isti kapacitet sustava može ostvariti uz značajno manji odnos signala i šuma odnosno energije bita i gustoće snage šuma, ako se poveća širina zauzetog spektra. Mjera koja pokazuje koliko manji odnos signala i šuma pri tehnici proširenog

pojasa u odnosu na *SNR* klasičnih modulacijskih tehnika naziva se procesni dobitak G_p:

$$G_p = \frac{T_b}{T_c} = \frac{B_{ss}}{B_N} \tag{3.6}$$

gdje je B_{ss} širina pojasa frekvencija nakon proširenja, a B_N širina pojasa u osnovnom pojasu frekvencija.

Bez obzira na kompleksnost sustava s tehnikom prijenosa korištenjem proširenog spektra, takvi sustavi imaju značajne prednosti u odnosu na sustave s drugim tehnikama prijenosa [59]:

1. Signali u tehnici proširenog spektra se mogu prenositi u frekvencijskim područjima gdje su prisutni drugi sustavi, a da pri tome postoji minimalni utjecaj na rad oba sustava.
2. Proširenim spektrom se prenosi širokopojasni signal koji ima bolje performance u odnosu na klasične modulacijske tehnike pri višestaznom širenju i u frekvencijski selektivnom kanalu.
3. Tehnika prijenosa proširenim spektrom omogućuje robusniji i pouzdaniji prijenos u urbanim i zatvorenim sredinama.
4. Tehnika proširenog spektra omogućuje smanjenje interferencije od drugih i sličnih signala u mrežama s velikom gustoćom korisnika ili uređaja
5. Ćelijski sustavi koji koriste tehniku višestrukog pristupa korištenjem proširenog spektra CDMA (eng. *Code Division Multiple Access*) nude znatno veću fleksibilnost u radu i veći kapacitet u odnosu na tehnike višestrukog pristupa po frekvenciji FDMA (eng. *Frequency Division Multiple Access*) i vremenu TDMA (eng. *Time Division Multiple Access*)

Sustavi s višestrukim pristupom po kodu CDMA omogućuju višekorisničke mreže i višestruki pristup korištenjem tehnika proširenog spektra gdje svaki korisnik koristi svoj slijed za proširenje. Sljedovi za proširenje pojasa svakog korisnika trebali bi imati takva svojstva da se podaci mogu prenijeti zajedničkim kanalom bez narušavanja i interferencije s podacima drugih korisnika. Sljedovi za proširenje pojasa trebali bi biti ortogonalni jedan u odnosu na drugi, odnosno da njihova linearna kombinacija iznosi 0.

3.1 Vrste sustava s proširenim spektrom

Postoji nekoliko vrsta sustava s proširenim spektrom u odnosu na način proširenje pojasa [59]:

1. DSSS (eng. *Direct Sequence Spread Spectrum*) Proširenje izravnim slijedom
2. FHSS (eng. *Frequency Hopping Spread Spectrum*) Sustavi s frekvencijskim skakanjem
3. THSS (eng. *Time-Hopping Spread Spectrum*) Sustavi s vremenskim skakanjem
4. MCSS Sustavi s više nosilaca (eng. *Multicarrier Spread Spectrum*)

U komercijalnim primjenama najzastupljeniji su DSSS i FHSS sustavi.

3.1.1 Sustavi s proširenjem izravnim slijedom

Kod proširenja izravnim slijedom, signal se iz osnovnog pojasa množi pseudoslučajnim slijedom za proširenje kraćeg trajanja podimpulsa T_c, odnosno veće širine pojasa. Nakon proširenja pojasa, prošireni signal se modulira nekom od poznatih modulacijskih tehnika (M-PSK, M-QAM, GMSK, FSK).

Kompleksna ovojnica jednog BSPK moduliranog signala može se prikazati kao [60]:

$$\tilde{s}(t) = b\sqrt{E_b}g(t-kT), \quad 0 \leq t \leq T \tag{3.7}$$

gdje je b informacijski simbol u osnovnom pojasu, $g(t)$ je niz pravokutnih impulsa, a T je trajanje simbola. Ako se pretpostavi BPSK modulacija, podatkovni simbol b može biti +1 ili -1. Pretpostavlja se da su svi signali oblika pravokutnog impulsa trajanja T [60]:

$$g(t-kT) = \begin{cases} \sqrt{\dfrac{1}{T}}, & 0 \leq t \leq T \\ 0, & \text{inače} \end{cases} \tag{3.8}$$

U tehnici prijenosa s direktnim proširenjem spektra, prenosi se niz pravokutnih impulsa duljine Q [60]:

$$g(t) = \sum_{q=1}^{Q} c(q)g_c(t-qT_c) \tag{3.9}$$

gdje je $c(q)$ slijed za proširenje sastavljen od pojedinačnih signala, koji se nazivaju i podimpulsi. Svaki podimpuls poprima diskretne vrijednosti +1 ili -1 i ima trajanje T_c. Podimpulsi su oblika pseudoslučajnog slijeda i imaju period ponavljanja jednak periodu simbola.

Signal na ulazu u prijamnik može se prikazati kao [60]:

$$\tilde{x}(t) = \tilde{s}(t) + \tilde{w}(t) \tag{3.10}$$

gdje je $\tilde{w}(t)$ prikaz kompleksne ovojnice bijelog šuma u kanalu.

Za takav signal $\tilde{x}(t)$ signal na izlazu optimalnog prijamnika ima oblik [60]

$$\begin{aligned} y &= \int_0^T \tilde{x}(t)g^*(t)dt \\ &= b\sqrt{E_b}\int_0^T |g(t)|^2 dt + \int_0^T \tilde{w}(t)g^*(t)dt \\ &\approx b\sqrt{E_b} + \eta \end{aligned} \tag{3.11}$$

gdje je $g^*(t)$ kompleksno konjiguriana vrijednost signala $g(t)$. gdje je b BPSK ili QPSK modu-

lirani simbol, a η uzorak bijelog šuma. Optimalni prijamnik u obliku prilagođenog filtra radi na principu da svojom inverznom karakteristikom maksimizira energiju korisnog dijela signala te popravlja odnos signala i šuma. Ako je optimalni filtar prilagođen, snaga šuma bit će zanemariva u odnosu na snagu korisnog dijela signala. Srednja vrijednost bijelog šuma iznosi nula, a varijanca bijelog šuma η može se prikazati kao

$$\begin{aligned}\sigma_\eta^2 &= \mathbf{E}\left[\left|\left(\int_0^T \tilde{w}(t)g^*(dt)\right)\right|^2\right] \\ &= \int_0^T\int_0^T \mathbf{E}[\tilde{w}(t)\tilde{w}^*(s)g(t)g^*(s)dtds \\ &= \int_0^T\int_0^T N_0\delta(t-s)g(t)g^*(s)dtds \\ &= N_0\int_0^T |g(t)|^2 dt \\ &= N_0\end{aligned} \tag{3.12}$$

gdje je N_0 gustoća snage šuma, $\mathbf{E}$ je očekivanje, a $\delta(t)$ Diracov impuls.

3.1.2 Sustavi s višestrukim pristupom po kodu

U sustavima s višestrukim pristupom po kodu CDMA (eng. *Code Division Multiple Access*) postoji K odašiljača koji dijele zajednički kanal. Kompleksni prikaz svih K signala proširenog spektra može se prikazati kao [60]:

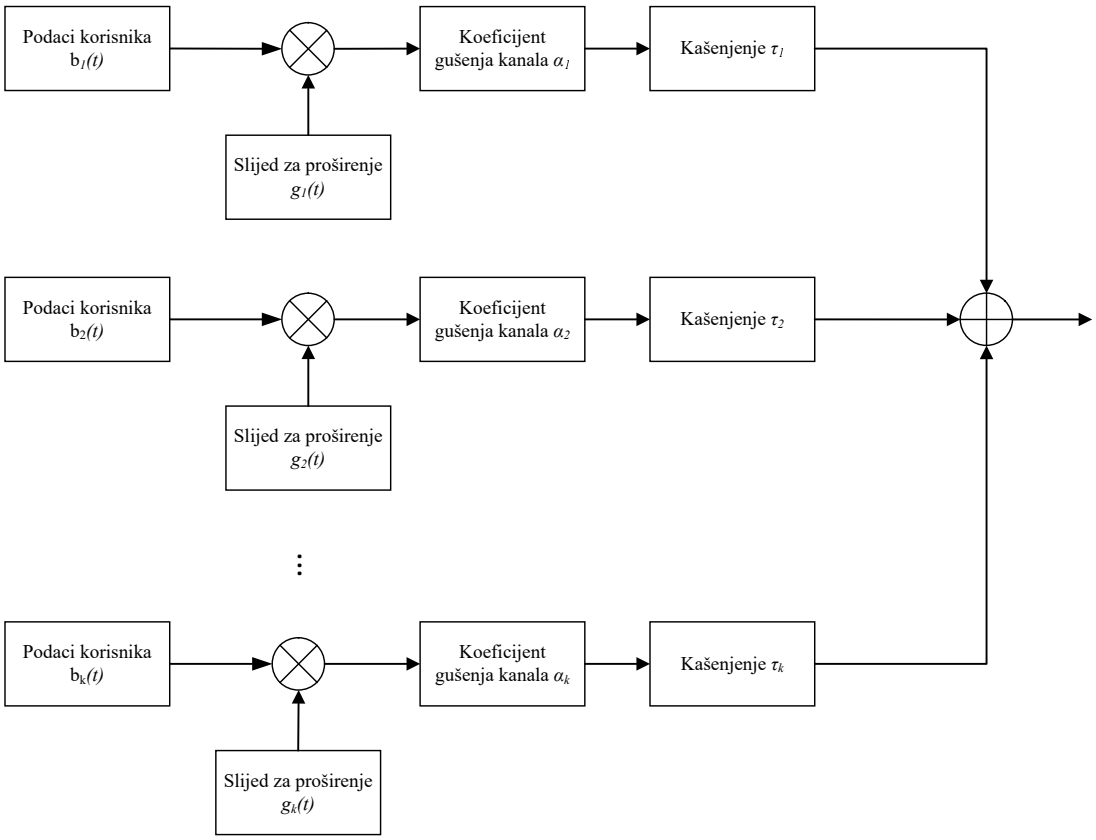
$$\tilde{x}(t) = \sum_{k=1}^{K} \alpha_k \tilde{s}_k(t) + \tilde{w}(t), \quad 0 \le t \le T \tag{3.13}$$

gdje su α_k kompleksni koeficijenti odziva kanala u K propagacijskih staza. Pojedini odaslani signal može se prikazati kao:

$$\tilde{s}_k(t) = b_k\sqrt{E_b}g_k(t) \tag{3.14}$$

gdje b_k predstavlja različite podatkovne impulse pojedinog korisnika u osnovnom pojasu, a g_k slijed za proširenje pojedinog korisnika. Izgled takvog sustava može se vidjeti na slici 3.1.

Jednadžba 3.13 predstavlja sinkroni sustav s višestrukim pristupom po kodu, odnosno pretpostavlja se da su frekvencija, faza i vremenski takt identični za sve korisnike. U realnim sustavima s nezavisnim odašiljačima zahtjev na idealnu sinkronizaciju je teško ostvariv. U prijamniku signal se demodulira te sažima istim slijedom za proširenje kao u odašiljaču. Ako sljedovi nisu optimalno sinkronizirani, može se pojaviti križna korelacija željenog, korisnog



Slika 3.1: Model sustava s višestrukim pristupom po kodu za K korisnika

slijeda sa sljedovima ostalih korisnika pri čemu se javlja međusobna interferencija. Međusobna interferencija očituje se kao smanjenje odnosa korisnog signala i šuma. Ako se pretpostavi da je željeni signal jednog korisnika za $k = 1$ u 3.13, onda se prilagođeni prijamnik za korisnika 1, sa slijedom za proširenje $g_1(t)$ može prikazati kao [60]:

$$\begin{aligned} y &= \int_0^T \tilde{x}(t) g_1^*(t) dt \\ &= \alpha_1 b_1 \sqrt{E_b} + \eta_1 + \sum_{k=2}^{K} \alpha_k b_k \sqrt{E_b} \int_0^T g_k(s) g_1^*(s) dt \\ &= \alpha_1 b_1 \sqrt{E_b} + \eta_1 + \sqrt{E_b} \sum_{k=2}^{K} \alpha_k b_k R_{1k} \end{aligned} \tag{3.15}$$

gdje je $0 \leq t \leq T$, a posljednji član interferencija u višestrukom pristupu.

Ako se pretpostavi da su podatkovni impulsi b_k međusobno nezavisni i imaju srednju vri-

jednost nula, na izlazu prijamnika u obliku optimalnog filtra 3.11 bit će [60]:

$$\begin{aligned}\mathbf{E}[y] &= \alpha_1 b_1 \sqrt{E_b} + \mathbf{E}[\eta_1] + \mathbf{E}\left[\sqrt{E_b}\sum_{k=0}^{K}\alpha_k b_k R_{1k}\right] \\ &= \alpha_1 b_1 \sqrt{E_b} + 0 + 0 \\ &= \alpha_1 b_1 \sqrt{E_b}\end{aligned} \tag{3.16}$$

Varijanca signala y može se prikazati kao [60]:

$$\begin{aligned}\sigma_Y^2 &= \mathbf{E}\left[(Y - \mathbf{E}[y]^)2\right] \\ &= \mathbf{E}\left[|\eta_1|^2 + 2\left\{\eta_1^*\left(\sqrt{E_b}\sum_{k=2}^{K}\alpha_k b_k R_{1k}\right)\right\} + \left|\sqrt{E_b}\sum_{k=2}^{K}\alpha_k b_k R_{1k}\right|^2\right] \\ &= N_0 + 0 + E_b\sum_{k=2}^{K}\sum_{l=2}^{K}\alpha_k\alpha_l^*\mathbf{E}[b_k b_l^*]\mathbf{E}[R_{1k}R_{1l}^*] \\ &= N_0 + E_b\sum_{k=2}^{K}\sum_{l=2}^{K}\alpha_k\alpha_l^*\delta(k-l)\mathbf{E}[R_{1k}R_{1l}^*] \\ &= N_0 + E_b\sum_{k=2}^{K}|\alpha_k|^2\mathbf{E}[|R_{1k}|^2]\end{aligned} \tag{3.17}$$

gdje su R_{kl} iznosi križne korelacije između različitih sljedova za proširenje pojasa. Slijed za proširenje ima Q podimpulsa za proširenje u periodu T, a ako sljedovi za proširenje imaju slična svojstva kao optimalni slučajni signal, onda je [60]:

$$\mathbf{E}\left[|R_{jk}|^2\right] \approx \frac{1}{Q} \tag{3.18}$$

Doprinos izraza za interferenciju višestrukog pristupa ukupnoj varijanci šuma je približno [60]:

$$\sigma_{MAI}^2 \approx E_b\sum_{k=2}^{K}|\alpha_k|^2\frac{1}{Q} \tag{3.19}$$

Ako se pretpostavi da se snaga svakog odašiljača može podesiti tako da je primljena snaga konstantna onda je

$$\alpha_k = 1, \quad \forall k \tag{3.20}$$

onda se doprinos interferencije višestrukog pristupa ukupnoj snazi šuma može prikazati drugim momentom u obliku [60]:

$$\sigma_{MAI}^2 = \frac{K-1}{Q}E_b \tag{3.21}$$

Članovi iz jednadžbe 3.16 koji opisuju interferenciju višestrukog pristupa mogu se prikazati

preko koeficijenta D_g koji opisuje pogoršanje performanci uslijed interferencije višestrukog pristupa [60]:

$$D_g = \left(1 + \frac{K-1}{Q}\frac{E_b}{N_0}\right)^{-1} \tag{3.22}$$

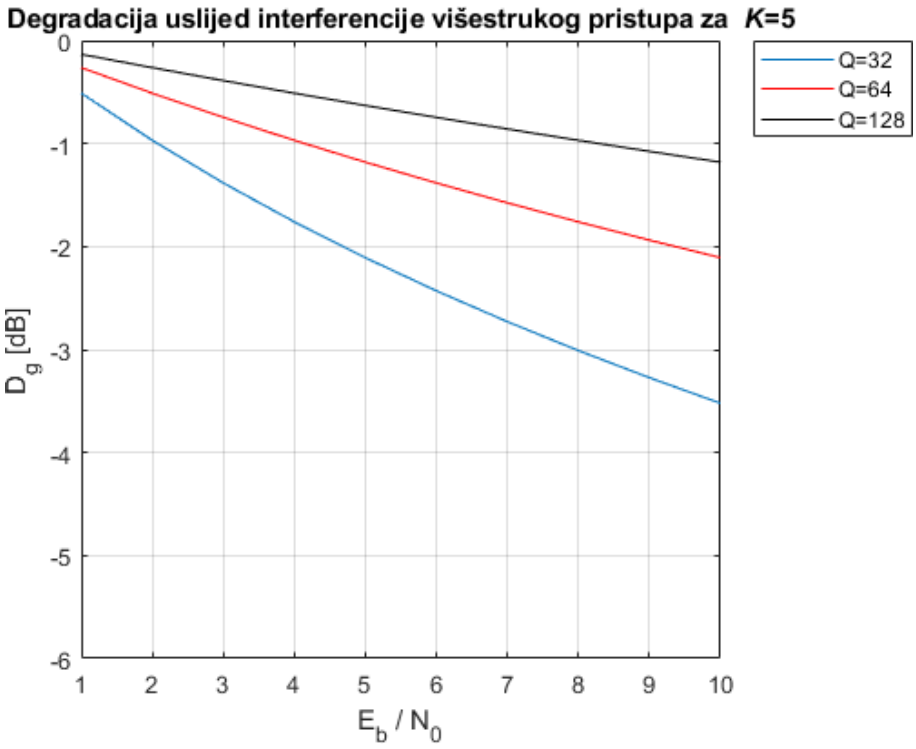
Omjer korisnog signala u odnosu na ukupni šum i interferenciju uslijed višestrukog pristupa *SINR* (eng. *Signal-to-interference-plus-noise Ratio*) kojeg prijamnik vidi uključuje cjelokupni šum u kanalu te ukupnu interferenciju višestrukog pristupa [60]:

$$\begin{aligned} SINR &= \frac{(\mathbf{E}[y])^2}{\sigma_Y^2} \\ &= \frac{E_b}{(N_0 + \frac{K-1}{Q}E_b)} \\ &= \frac{E_b}{N_0}\left(\frac{1}{1 + \frac{K-1}{Q}\frac{E_b}{N_0}}\right) \\ &= \frac{E_b}{N_0}D_g \end{aligned} \tag{3.23}$$

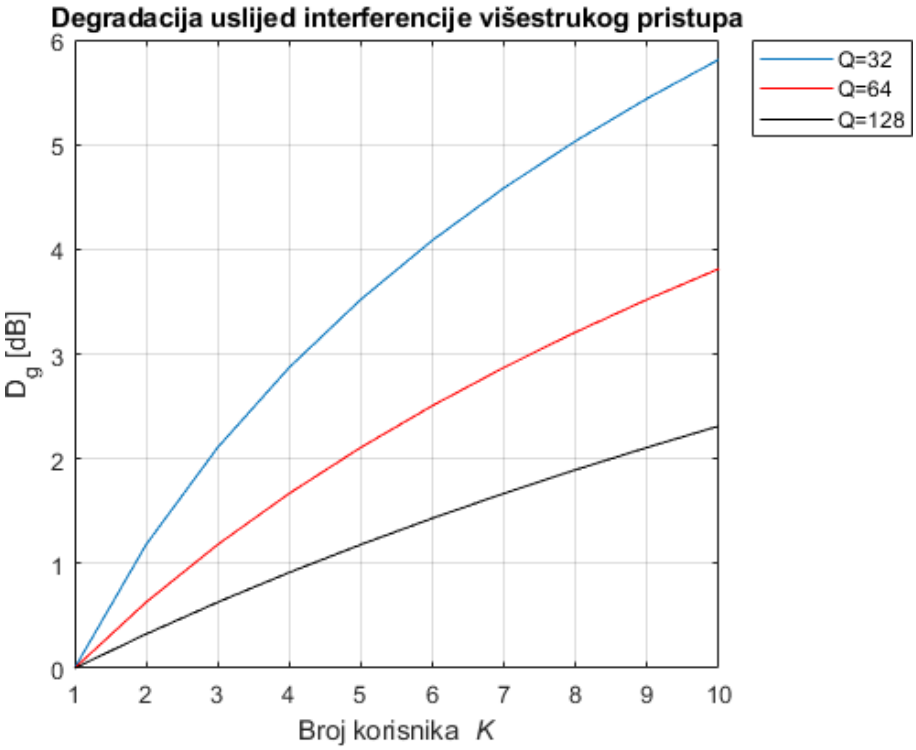
Faktor degradacije D_g ovisi o odnosu energije bita i šuma E_b/N_0, broju korisnika K i faktoru proširenja Q. Kod sustava s višestrukim pristupom po kodu uslijed vremenskih pomaka u višestaznom prostiranju pojavljuje se križna korelacija zbog nesavršene sinkronizacije. Sljedovi za proširenje pojasa trebali bi imati dobra križnokorelacijska svojstva kako bi se smanjila interferencija višestrukog pristupa u višekorisničkom sustavu pri takvim vremenskim pomacima. Ako se pretpostavi konstantan iznos omjera E_b/N_0, iz 3.23 vidi se da će se omjer korisnog signala u odnosu na šum smanjivati kako se dodaju korisnici u sustav svaki s vlastitim slijedom za proširenje. Dodavanjem korisnika povećava se interferencija višestrukog pristupa odnosno dolazi do povećanja faktora degradacije D_g. Samim dodavanjem novih sljedova za proširenje povećava se vjerojatnost pojave križnekorelacije s drugim kodovima i korisnicima. Korištenjem zaštitnog kodiranja te naprednijim arhitekturama prijamnika može se smanjiti utjecaj višestrukog prostiranja i vremenskog kašnjenja na performance višekorisničkog sustava promatrane kroz učestalost pogreške bita.

3.2 Sljedovi za proširenje pojasa

Sljedovi za proširenje pojasa trebali bi osigurati mogućnost višekorisničkog rada za višestruki pristup po kodu. Osnovni zahtjev koji omogućuje takav istovremeni rad jest ortogonalnost sljedova za proširenje. Kako bi se ostvarila ortogonalnost podaci u osnovnom pojasu svakog



Slika 3.2: Degradacija uslijed interferencije višestrukog pristupa uz 5 korisnika i promjenjivi odnos E_b/N_0



Slika 3.3: Degradacija uslijed interferencije višestrukog pristupa uz E_b/N_0 = 10 dB i različit broj korisnika

korisnika proširuju se jedinstvenim slijedom za proširenje pojasa [60]:

$$g_k(t) = \sum_{q=1}^{Q} c_k(q) g_c(t - qT_c), \quad 0 \leq t \leq T \tag{3.24}$$

gdje je $\{c_k(q)\}$ slijed za proširenje korisnika k. Ortogonalnost $g_j(t)$ i $g_k(t)$ za različite vremenske pomake τ može se prikazati kao [60]:

$$R_{jk}(\tau) = \int_{-\infty}^{\infty} g_j(t+\tau) g_k^*(t) dt \approx 0, \quad j \neq k \tag{3.25}$$

Izraz 3.25 pokazuje da bi križna korelacija različitih sljedova za proširenje trebala biti nula za sve vremenske pomake τ ako se želi postići ortogonalnost sljedova za proširenje.

3.3 Optimalni slučajni sljedovi

Neka su x_m i y_n slučajni sljedovi simbola $+1$ i -1 duljine Q. Po definiciji $m \neq n$, x_n i y_m su nezavisni i imaju srednju vrijednost nula. Za optimalne slučajne sljedove križna korelacija može se definirati kao [60]:

$$R_{xy} = \mathbf{E}\left[\frac{1}{Q}\sum_{q=1}^{Q} x_q y_{q+k}\right] \tag{3.26}$$

gdje je k broj uzoraka za koje je slijed pomaknut, a y_{q+k} slijed stvoren pomakom slijeda x_q za k uzoraka.

Autokorelacija optimalnog slučajnog slijeda x_m može se prikazati kao [60]:

$$\begin{aligned} R_{xx} &= \mathbf{E}\left[\frac{1}{Q}\sum_{q=1}^{Q} x_q y_{q+k}\right] \\ &= \begin{cases} \dfrac{1}{Q}\displaystyle\sum_{q=1}^{Q} \mathbf{E}[x_q]\mathbf{E}[x_{q+k}] = 0 \times 0 = 0, & k \neq 0 \\ \dfrac{1}{Q}\displaystyle\sum_{q=1}^{Q} \mathbf{E}[x_q^2] = 1, & k = 0 \end{cases} \end{aligned} \tag{3.27}$$

3.4 Walsh-Hadamard sljedovi

Jedna od najpoznatijih grupa sljedova za proširenje pojasa koji pokazuju svojstva ortogonalnosti jesu Walsh-Hadamard sljedovi. Pretpostavka za generiranje Walsh-Hadamard sljedova jest vremenska sinkronost signala svih korisnika u proširenom pojasu. Walsh-Hadamard sljedovi mogu

se generirati korištenjem matrica u kojima su redovi međusobno ortogonalni i svaki red sadrži slijed za proširenje pojasa. Za sljedove duljine 2 ortogonalna matrica ima oblik [60]:

$$\mathbf{H}_1 = \begin{bmatrix} 1 & 1 \\ 1 & -1 \end{bmatrix} \tag{3.28}$$

Za sljedove duljine 4 ortogonalna matrica može se prikazati kao [60]:

$$\mathbf{H}_2 = \begin{bmatrix} \mathbf{H}_1 & \mathbf{H}_1 \\ \mathbf{H}_1 & -\mathbf{H}_1 \end{bmatrix} = \begin{bmatrix} 1 & 1 & 1 & 1 \\ 1 & -1 & 1 & -1 \\ 1 & 1 & -1 & -1 \\ 1 & -1 & -1 & 1 \end{bmatrix} \tag{3.29}$$

Općenito može se generirati 2^n sljedova za proširenje duljine 2^n korištenjem izraza [60]:

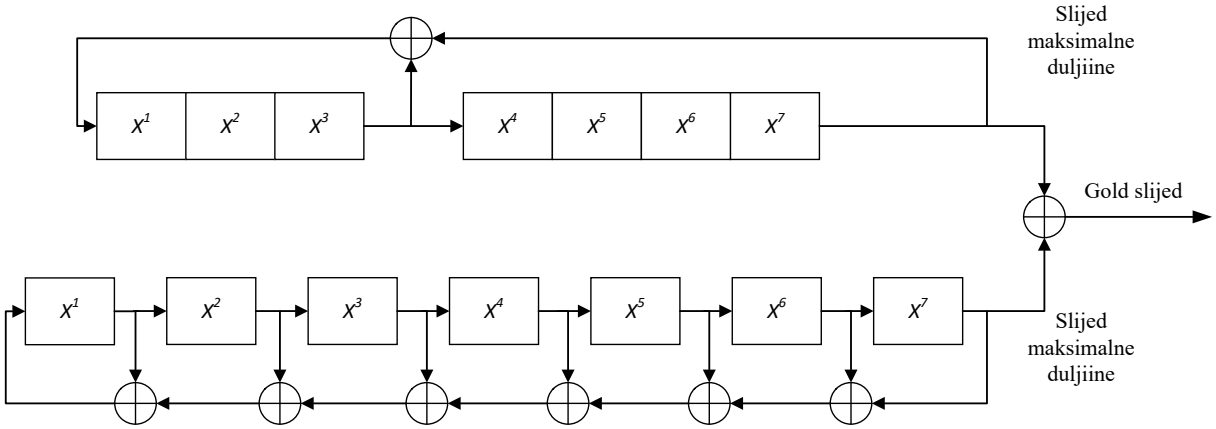
$$\mathbf{H}_n = \begin{bmatrix} \mathbf{H}_{n-1} & \mathbf{H}_{n-1} \\ \mathbf{H}_{n-1} & -\mathbf{H}_{n-1} \end{bmatrix} \tag{3.30}$$

Svi redovi matrice $\mathbf{H}$ generirani izrazom 3.30 su međusobno ortogonalni, odnosno njihova linearna kombinacija iznosi 0.

Ako se promatra križnokorelacijska funkcija za Walsh-Hadamard sljedove s vremenskim pomakom, može se primijetiti da postoji određena križna korelacija što se vidi iz pojave dodatnih komponenti u križnokorelacijskoj funkciji. Walsh-Hadamard sljedovi pokazuju odlična križnokorelacijska svojstva u višekorisničkom okruženju ako su signali u proširenom pojasu idealno vremenski sinkronizirani. U realnim uvjetima pri kojima dolazi do vremenskog pomaka, križnokorelacijska svojstva nisu optimalna.

3.5 Gold sljedovi

U praktičnim primjenama sljedova za proširenje u višekorisničkim sustavima potrebna su dobra križnokorelacijska svojstva kako bi se poruke svih korisnika mogle prenijeti. Sljedovi maksimalne duljine imaju odlična križnokorelacijska svojstva pri nepoznatim vremenskim pomacima. Gold je pokazao da se korištenjem dvaju generatora sljedova maksimalne duljine mogu dobiti sljedovi za proširenje koji pokazuju dobra križnokorelacijska svojstva pri različitim vremenskim pomacima [61]. Ideja iza generatora Gold sljedova za proširenje jest korištenje dvaju



Slika 3.4: Generiranje Gold sljedova

posmačnih registara za generiranje sljedova maksimalne duljine koji imaju različito početno stanje. Izborom početnih stanja i specifičnih polinoma posmačnih registara, mogu se generirati sljedovi za proširenje koji imaju križnokorelaciju prema izrazu [60, 61]:

$$|R_{jk}(\tau)| \leq \frac{1}{Q} + \frac{2}{\sqrt{Q}}, \quad j \neq k \tag{3.31}$$

gdje je $Q = 2^{m-1}$, a m maksimalna potencija karakterističnog polinoma posmačnog registra.

Gold sljedovi trebali bi pokazivati poboljšane performance u stvarnim sustavima gdje postoji nepoznati pomak u vremenu, frekvenciji i fazi u signalu na ulazu u prijamnik.

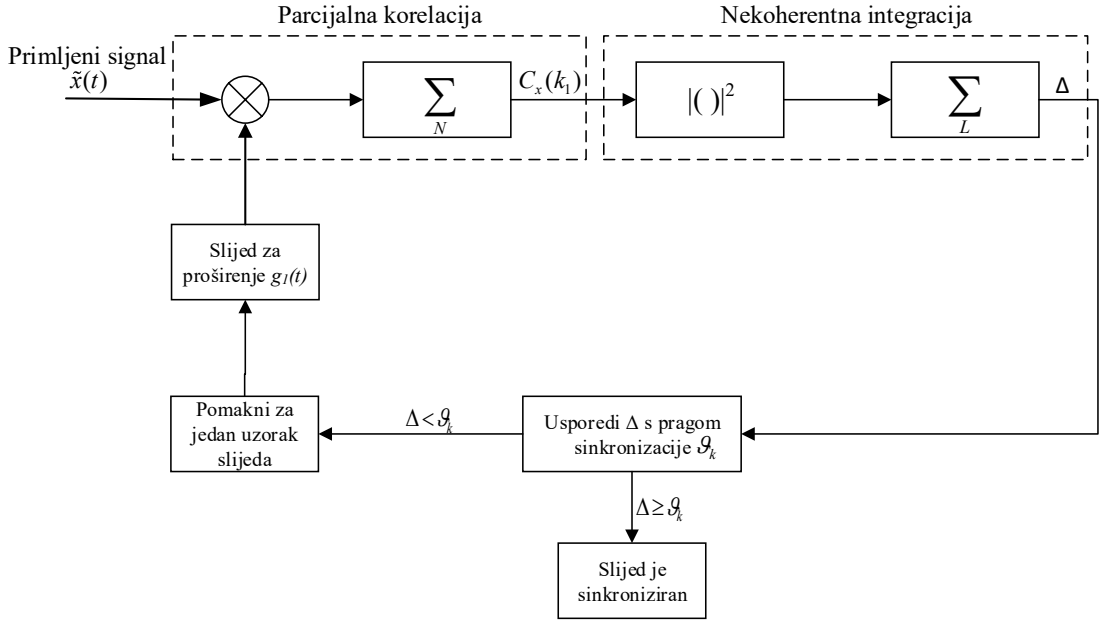
3.6 Sinkronizacija slijeda za proširenje

Točna rekonstrukcija i sinkronizacija faze kao i takta simbola u koherentnim modulacijskim tehnikama čest je problem koji se rješava raznim sinkronizacijskim postupcima. U sustavima s tehnikama prijenosa korištenjem proširenog spektra postoji još jedna razina sinkronizacije. Prije same koherentne demodulacije potrebno je izvršiti i sinkronizaciju samog slijeda za proširenje.

Ako se pretpostavi da se samo odašilje slijed za proširenje bez moduliranih podataka, onda se niskofrekvencijski ekvivalent signala u prijenosom pojasu frekvencija može prikazati kao [60]:

$$\begin{aligned} \tilde{x}(t) &= \sqrt{E_b} g(t) e^{j(2\pi\Delta f t + \phi)}, \qquad 0 \leq t < T \\ &= \sqrt{E_b} g(t-T) e^{j(2\pi\Delta f t + \phi)}, \quad T \leq t < 2T \end{aligned} \tag{3.32}$$

gdje je Δf rezidualna pogreška frekvencije nakon konverzije na frekvenciju osnovnog pojasa, ϕ je rezidualna pogreška faze, a $g(t)$ je slijed za proširenje pojasa. Slijed za proširenje pojasa ponavlja se svakih T sekundi. Sklop za sinkronizaciju slijeda za proširenje može se vidjeti na slici 3.5.



Slika 3.5: Postupak sinkronizacije slijeda za proširenje

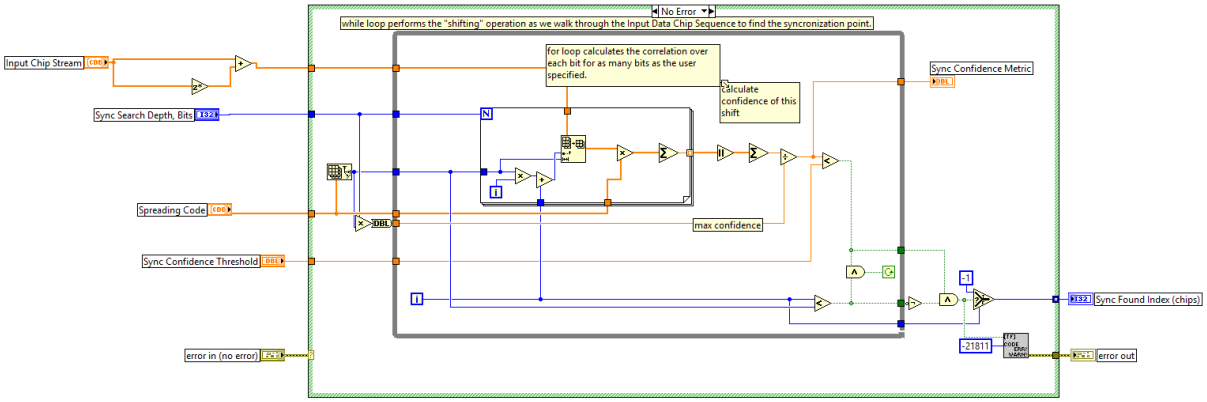
Signal $\tilde{x}(t)$ uzorkuje se svakih T_c, odnosno na vrijeme uzorkovanja slijeda za proširenje što se može prikazati kao[60]:

$$\begin{aligned}\tilde{x}(kT_c) &= \sqrt{E_b}g(kT_c \bmod T)e^{j(2\pi\Delta fkT_c+\phi)} \\ &= \sqrt{E_b}c(k \bmod Q)e^{j(2\pi\Delta fkT_c+\phi)}\end{aligned} \tag{3.33}$$

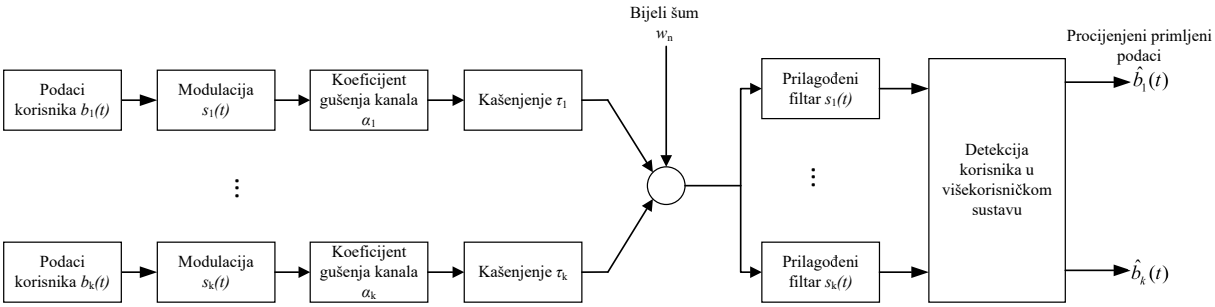
gdje modulo-Q operacija predstavlja ponavljanje slijeda svakih Q uzoraka. Zbog pogreške frekvencije provodi se parcijalna korelacija preko svih uzoraka slijeda u kojima se faza neznatno mijenja. Pretpostavlja se da je pogreška frekvencije dovoljno mala da je faza približno jednaka ϕ u vremenu $[k_1, k_1+\Delta k]$. Parcijalna korelacija se može prikazati kao [60]:

$$\begin{aligned}C_x(k_1) &= \sum_{k=k_1}^{k_1+\Delta k} x(kT_c)c^*((m_0+(k-k_1)) \bmod Q) \\ &= E_b \sum_{k=k_1}^{k_1+\Delta k} c(k \bmod Q)c^*((m_0+(k-k_1)) \bmod Q)e^{j(2\pi\Delta ftT_c+\phi)} \\ &\approx E_b e^{j\phi'} \sum_{k=k_1}^{k_1+\Delta k} c(k \bmod Q)c^*((m_0+(k-k_1)) \bmod Q)\end{aligned} \tag{3.34}$$

gdje je m_0 nepoznati pomak slijeda za proširenje između primljenog signala i lokalno generiranog slijeda u prijamniku. Vrijednost $C_x(k_1)$ ovisi o tome koliko su dobro sljedovi poravnati.



Slika 3.6: Sinkronizacija slijeda iznad zadanog praga izvedena za programski određeni radio



Slika 3.7: Detekcija korisnika u višekorisničkom sustavu

Idealno bi trebalo biti [60]:

$$C_x(k_1) \approx \begin{cases} E_b \Delta k e^{j\phi'}, & \text{ako su sljedovi poravnati} \\ 0, & \text{u suprotnom} \end{cases} \tag{3.35}$$

gdje je ϕ' suma rezidualnih pogrešaka faze ϕ i promjena faze uslijed pogreške frekvencije. Kako bi se povećala pouzdanost sinkronizacije, uvodi se prag odluke θ_x. Varijabla D u ovisnosti o nekoherentnoj sumi $C_x(k_i)$ pokazuje pouzdanost sinkronizacije:

$$\Delta = \sum_{l=1}^{L_1} |C_x(k_l)|^2 \tag{3.36}$$

gdje je L_1 broj uzoraka primljenog signala. Ako je varijabla Δ veća od zadanog praga pouzdanosti sinkronizacije, pretpostavlja se da je slijed poravnat i sinkroniziran. Nakon sinkronizacije pretpostavlja se da se korisnički podaci mogu demodulirati. Proces detekcije može se promatrati kao filtriranje prilagođenim filtrom. U sustavima s proširenim spektrom, prilagođeni filtar je sam slijed za proširenje za svakog korisnika. Detekcija korisnih podataka može se vidjeti na slici 3.7.

Poglavlje 4

Model sustava

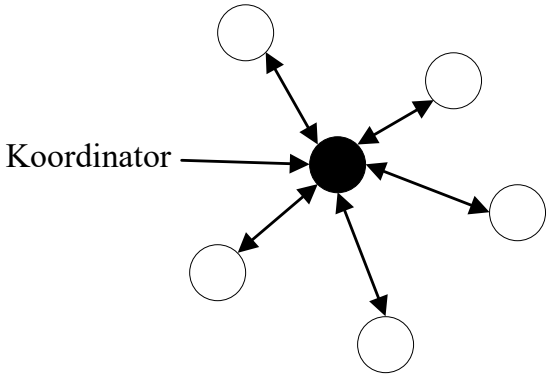
IEEE 802.15.4 norma [62] opisuje fizički sloj i sloj pristupa mediju MAC (eng. *Media Access Control*) za radijske osobne mreže WPAN (eng. *Wireless Personal Area Networks*). Postoje tri klase radijskih osobnih mreža: mreže visoke propusnosti HR-WPAN (eng. *High Rate-Wireless Personal Area Networks*), mreže srednje propusnosti MR-WPAN (eng. *Medium Rate-Wireless Personal Area Networks*) i mreže niske propusnosti LR-WPAN (eng. *Low Rate Wireless Personal Area Network*). U ovom radu modelirat će se sustav za LR-WPAN mreže na platformi programski određenog radija.

LR-WPAN mreže su jednostavne, jeftine komunikacijske radijske mreže kod kojih su glavne karakteristike niska potrošnja energije i niske brzine prijenosa. Glavna ideja takvih mreža jest jednostavnost primjene, pouzdanost, niska cijena i dug vijek trajanja baterije. Sama norma [62] opisuje nekoliko izvedbi fizičkog sloja u ovisnosti o korištenom pojasu frekvencija. Sustavi po normi IEEE 802.15.4 rade u nekoliko pojasa frekvencija [62, 63]:

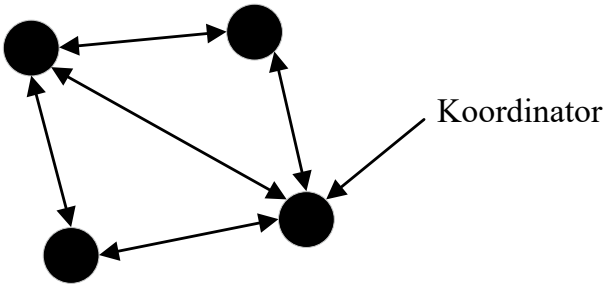
- 780 MHz, gdje se nalazi 7 kanala,
- 868 MHz, gdje se nalazi 1 kanal,
- 915 MHz, gdje se nalazi 10 kanala,
- 2450 MHz, gdje se nalazi 16 kanala.

Uređaji određeni IEEE 802.15.4 normom koriste se u senzorskim mrežama s različitim zahtjevima. Upotreba takvih uređaja moguća je u mrežama koje služe nadzoru i upravljanjem komunalijama, željezničkim komunikacijskim sustavima, radiofrekvencijskoj identifikaciji, nadzoru uređaja u teškim propagacijskim uvjetima, medicinskim mrežama na tijelu i sl [63, 64].

Ovisno o zahtjevima, mreže prema IEEE 802.15.4 normi mogu se izvesti u dvije topologije: zvijezda i topologiji ravnopravnih čvorova (eng. *peer-to-peer*). U topologiji zvijezde komunikacija se ostvaruje između uređaja i središnje upravljačke jedinice koja se naziva koordinator, a sami krajnji uređaji ne komuniciraju direktno. U topologiji ravnopravnih čvorova postoji koordinator, no uređaji mogu komunicirati direktno ako su u međusobnom dometu. Prednost takve topologije je neovisnost o drugoj infrastrukturi pri čemu se mogu stvarati mreže na velikom



Slika 4.1: Topologija zvijezde



Slika 4.2: Topologija ravnopravnih čvorova

području samim spajanjem susjednih čvorova [62, 63].

4.1 Model sustava na platformi programski određenog radija

4.1.1 Sloj upravljanja pristupa mediju

Komunikacija korištenjem zadanih okvira podataka omogućuje smanjenje kompleksnosti u slanju podataka dok zadržava robusnost pri propagaciji radijskim kanalima sa šumom. Izgled okvira jedinice podataka fizičkog sloja PPDU (eng. *PHY Protocol Data Unit*) može se vidjeti na slici 4.1. U okviru fizičkog sloja u polju preambule prenose se zaglavlja za sinkronizaciju SHR (eng. *Synchronization Header*) te zaglavlje za oznaku početka okvira SFD (eng. *Start of Frame Delimiter*). SHR se koristi za sinkronizaciju simbola u demodulatoru u prijamniku te za procjenu nepoznatih parametara primljenog signala. Korištenjem SHR procjenjuje se nepoznata frekvencija, faza te sinkronizira početak simbola i okvira [62].

U samoj normi [62] zadano je nekoliko duljina preambule te SFD polja u ovisnosti o postavkama sustava. Zbog izvedbe modela ovog sustava na programski određenom radiju, potrebno je koristiti sinkronizacijske okvire te se pri evaluaciji performanci koriste duljine preambule od 16 i 32 bita te SFD polje. Bez korištenja SHR polja za sinkronizaciju performance sustava su izrazito loše te sustav nije upotrebljiv za komunikaciju.

Tablica 4.1: Okvir podatka

Duljina u oktetima		
0/2/4	0/1	16/24/32
Preambula	SFD polje	PSDU
SHR		Podaci

Tablica 4.2: Izgled polja preambule i početka okvira

Duljina preambule	Preambula	SFD polje
0	Ne postoji	Ne postoji
16	0011 1111 0101 1001	0011 1000
32	0000 1111 1101 1011 0110 0111 0010 1010	1000 0100

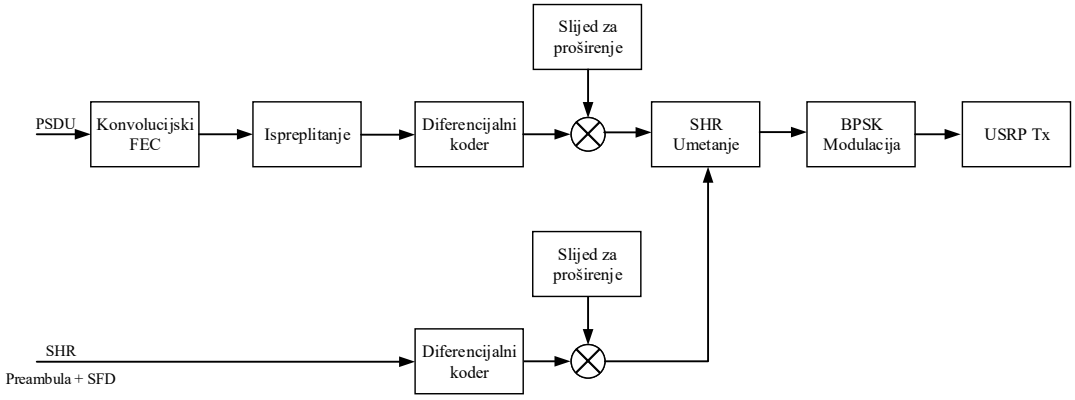
U modelu korištenom u ovom radu evaluirat će se performance sljedova generiranih iz kaotičnih sustava za sinkronizaciju u odnosu na sljedove definirane u normi. Izmjenom SHR polja u preambuli promatrat će se performance sinkronizacije na prijamniku. U SHR polju izmjenjivat će se kaotični sljedovi generirani iz različitih kaotičnih generatora te sljedovi definirani normom. Isto tako promatrat će se sljedovi različitih duljina od 16 i 32 simbola. Simboli SHR polja direktno se koriste kao referentni simboli za procjenu nepoznatih parametara primljenog signala. Slijed s boljom dinamikom u procjeni parametara trebao bi pokazivati bolje performance. SFD polje koristi se za pronalaženje početka okvira podataka u primljenom demoduliranom nizu bitova.

4.1.2 Fizički sloj

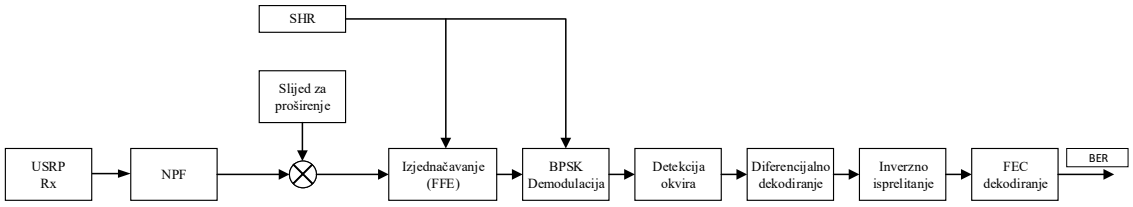
Model fizičkog sloja odašiljača sustava po normi IEEE 802.15.4 može se vidjeti na slici 4.3 [62]. Okvir podataka na fizičkom sloju prema 4.1 se oblikuje iz korisničkih podataka. Okvir se prvo zaštićuje kodiranjem korištenjem unaprijed zaštitnog kodiranja FEC (eng. *Forward Error Correction*). FEC koristi konvolucijski koder omjera koda 1/2 i duljinom bitova u memoriji kodera (eng. *Constraint length*) k=7. Sam koder opisan je polinomina [62]:

$$\begin{aligned} G_0(x) &= 1 + x^2 + x^3 + x^5 + x^6 \\ G_1(x) &= 1 + x + x^2 + x^3 + x^6 \end{aligned} \tag{4.1}$$

Kodirani podaci ulaze u blok za ispreplitanje koji miješa ulazne simbole kako bi se raspršila potencijalna pogreška u prijenosu. Nakon ispreplitanja podaci se dodatno kodiraju diferencijalnim koderom. Zaštićeni podaci se potom proširuju slijedom za proširenje pojasa. Slijed



Slika 4.3: Model odašiljača



Slika 4.4: Model prijamnika

za proširenje pojasa prema normi je Gold slijed, a u modelu će se koristiti i optimirani kaotični sljedovi. Na početak okvira korisnih podatka umeću se diferencijalno kodirana sinkronizacijska zaglavlja i preambula koji su prošireni istim slijedom za proširenje kao i korisni podaci. Prošireni podaci se moduliraju BPSK modulacijskom tehnikom te prosljeđuju odašiljačkom uređaju programski određenog radija.

Prijamni uređaj programski određenog radija prima elektromagnetski val te obavlja analogno digitalnu pretvorbu. Digitalizirani podaci obrađuju su u prijamnom programu programski određenog radija. Prijamni program sastoji se od blokova niskopropusnog filtra, dijela za sažimanje, demodulaciju i izjednačavanje te dekodiranje i detektiranje izvornih podataka. Niskopropusni filtar filtrira nepotrebne komponente nastale uslijed kvantizacije i digitalne pretvorbe. Filtrirani signal se sažima istim slijedom za proširenje pojasa kao u odašiljaču pri čemu se vrši sinkronizacija slijeda. Nakon postignute dovoljne razine sinkronizacije iznad unaprijed zadanog praga, signal se izjednačuje te koherentno demodulira pri čemu se obavlja sinkronizacija faze, frekvencije i vremenskog takta moduliranih simbola. Sinkronizacija i izjednačavanje se oslanjaju na poznate podatke u preambuli i sinkronizacijskom zaglavlju okvira. Blok za izjednačavanje nije definiran u normi no potreban je u stvarnim sustavima, posebno kod prijenosu u radijskim kanalima s višestaznim širenjem. U koherentnoj izvedbi potrebno je rekonstruirati

fazu digitalnog nosioca kako bi se pouzdano mogli detektirati modulirani simboli. Koherentna modulacija pokazuje bolje performance u kanalima s bijeli šumom, no sama izvedba je kompleksnija. Demodulator koristi SHR zaglavlje u primljenom paketu za ispravljanje pomaka frekvencije i faze. Nakon ispravljanja frekvencije i faze prelazi se u detekciju početka korisnih podatka. Postoje dva načina izvedbe demodulatora: koherentna i nekoherentna.

4.2 Programski određeni radio

Definicija programski određenog radija SDR (eng. *Software Defined Radio*) nije jedinstveno potvrđena. Općeniti se sustav programski određenog radija opisuje kao radijski sustav u kojem su neke ili sve funkcije fizičkog sloja izvedene programski. Sustav programski određenog radija se sastoji od programskog alata koji obavlja funkcije fizičkog sloja te sklopovskih komponenti koje provode analogno-digitalnu i digitalno-analognu pretvorbu. Programski određeni radio se može prikazati kao primopredajni sustav u kojem se frekvencijsko područje, širina kanala, zaštitno kodiranje kao i modulacijski postupci zajedno s upravljanjem radijskim resursima izvodi u softverskom alatu na upravljačkoj jedinici. Takva fleksibilna platforma omogućava evaluaciju i poboljšanja radijskog sučelja kroz izmjenu dijelova programa za obradu signala. Izmjenom programa mogu se jednostavno promijeniti frekvencijsko područje rada, optimirati modulacijski postupak, zaštitno kodiranje i omogućiti dinamičku prilagodbu radijskog sučelja. Programski određeni radio omogućava brzu izradu prototipa komunikacijskog sustava, testiranje novih radijskih sučelja i poboljšanja postojećih sustava [65].

Osnovna motiv za razvoj platforme programski određenog radija je zahtjev da se analogno digitalna i digitalno analogna pretvorba signala obavlja što bliže antene. Programski određeni radio omogućuje da radijsko sučelje radi bez ograničenja sklopovskih komponenti. Kod arhitekture programski određenog radija zadaće obrade signala izvršavaju se na programimabilnim procesorima. Takva arhitektura daje mogućnost udaljene nadogradnje komunikacijskog sustava (npr. bazne stanice) kao i programiranje prilagodljivih i kognitivnih radijskih sučelja. Upotreba programski određenog radija raširena je u istraživačkom području gdje se koristi za izradu točnih modela radijskih sustava i provođenje istraživanja u novim načinima obrade signala, razvoj novih naprednih modulacijskih postupaka i učinkovitijih kodnih shema [66, 67].

Definicija programski određenog radija nije jednoznačno određena već ovisi o istraživačkom i razvojom području. Joseph Mitola [48] smislio je 1991. godine naziv softverski radio kako bi predočio uporabu programskih alata koji zamjenjuju sklopovske komponente u komunikacijskom sustavu. Njegov je cilj bio smanjiti broj različitih sustava radijskih komunikacija u raznim službama američke vojske korištenjem univerzalnih sklopovskih komponenti, a obradu signala pretočiti u programski dio. Općenito programski određeni radio obavlja pretvorbu digitalnih informacija u osnovom pojasu u analogni signal s kompleksnom ovojnicom pogodan za

prenošenje radijskim kanalom. Takav analogni signal se, osim za prijenos informacije, može koristiti i za mjerenje nekih karakteristika radijskog kanala što je posebno zanimljivo u sustavima kognitivnog radija. Programski određeni radio obavlja sve zadaće normalnog radijskog sučelja: modulira signal u osnovnom pojasu na visokofrekvencijski sinusni signal nosioc, pretvara dobiveni sinusni signal u elektromagnetsku energiju te odašilje antenom u kanal. Osnovni problem koji se pokušava riješiti softverskim radijima je prenosivost valnog oblika između različitih uređaja i sustava. Cilj je razviti univerzalni jezik za valne oblike koji će svi uređaji na arhitekturi programski određenog radija razumjeti te omogućiti ispravno slanje sadržane informacije [68].

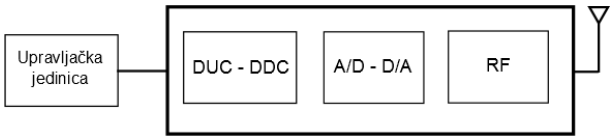
S obzirom na to da je potrebno definirati opseg upotrebe softverskih komponenti u implementaciji radijskog sučelja, u literaturi se definira pet razina rješenja. Razina 0 je u potpunosti sklopovska implementacija komunikacijskog sustava. Razina 1, softverski upravljani radio, uspostavlja softversku kontrolu nad sklopovskim elementima komunikacijskog sustava. Razina 2, programski određeni radio, provodi modulaciju i obradu u osnovnom pojasu korištenjem softverskih blokova, a konverzija na prijenosnu frekvenciju provodi se u sklopovskom dijelu. Razina 3, idealni softverski radio, omogućava programimabilnost radiofrekvencijskog dijela s analognom pretvorbom kod antene. Razina 4, potpuni softverski radio, omogućava brzo (u razini milisekunde) pretvaranje iz razine komunikacijskih protokola s digitalnom obradom signala u analogni oblik signala s kompleksnom ovojnicom pogodan za slanje radijskim kanalom [67].

4.2.1 Reprogramimabilnost

Razvoj sve bržih mikroelektroničkih reprogramimabilnih čipova omogućava obradu signala u osnovnom pojasu na procesorima opće namjene što omogućuje provođenje obradbe signala bliže ulazu analognog signala u sustav, odnosno bliže anteni. Reprogramimabilnost omogućava upravljanje konverzijom prema gore i dolje izmjenom digitalne frekvencije uzrokovanja bloka za pretvorbu, izmjenu zaštitnog kodiranja, modulacijske i zaštitne postupke, filtriranje i širine kanala koji određuju različita radijska sučelja. Programski određeni radio omogućuje fleksibilnu izmjenu osnovnih parametara kako bi se radijsko sučelje prilagodilo novim zahtjevima i uvjetima u kanalu.

4.2.2 Rekonfigurabilnost

Rekonfigurabilnost se može definirati kao izmjena arhitekture sustava kako bi se prilagodila zahtjevima korisnika. Fleksibilnošću sustava osigurava se dugotrajnost i upotrebljivost pri izmjeni generacija i tehnologije. Rekonfigurabilnost omogućava izvedbu više od jednog radijskog sučelja u različitim sustavima izmjenom dijela softvera što daje mogućnost izvedbe više gene-



Slika 4.5: Osnovni dijelovi sustava arhitekture programski određenog radija

racija ili vrsta radijskih sustava korištenjem istog sklopovlja.

4.2.3 Ograničenja

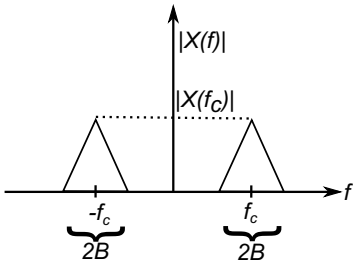
Uslijed prebacivanja obrade podataka u programski alat, programski određeni radio obrađuje sve podatke u osnovnom pojasu u istom procesoru pri čemu dolazi do povećanja vremena odziva i pojave kašnjenja pa se ne može govoriti o obradi signala u stvarnom vremenu. Osnovno ograničenja sustava sa programski određenim radijom je ograničena sposobnost obrade podataka svakog podsustava kao i ograničene brzine prijenosa podataka između samih blokova. Na dostupnim sustavima primjećeno je da brzina rada i pouzdanost ovisi o kvaliteti i brzini kojoj upravljačka jedinica (npr. osobno računalo) komunicira s uređajem programski određenog radija.

4.3 Dijelovi programski određenog radija

Svaki se sustav programski određenog radija sastoji od nekoliko osnovnih sastavnica: radiofrekvencijskog dijela, analogno-digitalnog i digitalno-analogno pretvornika, dijela za digitalnu obradu signala i sučelja prema upravljačkoj jedinici [66]. S druge strane imamo samu upravljačku jedinicu opremljenu softverskom platformom koja obrađuje signale u osnovnom pojasu te omogućuje fleksibilnost u obradi digitalnog valnog oblika. Na slici 4.5 može se vidjeti osnovni dijelovi sustava koji je postavljen na arhitekturi programski određenog radija. Na slici mogu se vidjeti dijelovi za digitalno naduzorkovanje i poduzorkovanje (DUC, DDC), analogno digitalnu pretvorbu (A/D, D/A) te radiofrekvencijski dio (RF).

4.3.1 Digitalna obrada signala

Dio za digitalnu obradbu signala koristi FPGA čipove kako bi poboljšao brzinu obrade signala i ukupne performance sustava. Primarna zadaća ovog bloka je filtriranje signala te digitalna konverzija na gore, odnosno interpolacija digitalnog signala na međufrekvenciju. Konverzija na gore, odnosno interpolacija vrši se dodavanjem potrebnog broja nula između dva uzorka originalnog signala. U prijamnom smjeru vrši se digitalna pretvorba na dolje uzorkovanjem nižom frekvencijom.



Slika 4.6: Spektar signala širine $2B$ oko frekvencije f_c

Analogno digitalni i digitalno analogni pretvornik dio je sustava za obradu signala u sustavu programski određenog radija koji omogućava pretvorbu iz digitalnih interpoliranih signala u analogni radiofrekvencijski signal s kompleksnom ovojnicom na međufrekvenciji i obrnuto. Stvaranje valnog oblika digitalnog signala glavna je zadaća digitalno-analogne pretvorbe gdje se digitalna informacija pretvara u razmjernu vrijednost napona. Obrnuta procedura je analogno-digitalna pretvorba gdje se analogni signal uzorkuje određenom frekvencijom korištenjem ograničenog broja bitova. Broj bitova te sama frekvencija uzorkovanja glavni su ograničavajući faktor u vjernom prikazu analogne informacije u obliku digitalnog valnog oblika [68].

4.3.2 Radiofrekvencijski dio

Radiofrekvencijski dio sadrži miješala, oscilatore i širokopojasna pojačala. Miješala i oscilatori omogućuju slanje elektromagnetske energije na radnoj frekvenciji sustava koju određujemo u programskom alatu, a sam sustav dopušta korištenje te frekvencije. Miješalo miješanjem sa signalom oscilatora radi konverziju na gore u radiofrekvencijskom dijelu te prenosi signal na antenu koja zrači elektromagnetsku energiju u kanal. U odašiljačkom dijelu, prije konverzije na gore nalazi se niskopropusni filtar koji određuje osnovnu širinu pojasa, dok u prijamnom dijelu filtrira primljene signale izvan željenog pojasa.

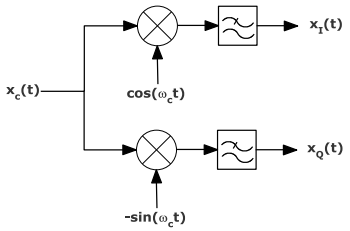
4.3.3 Pretvorba u signal s kompleksnom ovojnicom

Signal s kompleksnom ovojnicom, nakon modulacije odnosno obrade u programskom dijelu, nosi svu potrebnu informaciju u zapisu analognog signala. Neka je $x(t)$ neki signal sa širinom pojasa frekvencija $2B$ oko središnje frekvencije f_c s Fourierovom transformacijom $X(f)$ prikazanom na slici 4.6. Osnovno ograničenje takvog sustava je da pola širine spektra frekvencija ne smije biti veća od središnje frekvencije $B \leq f_c$.

Signal u propusnom pojasu frekvencija se može zapisati kao [60]:

$$x_c(t) = x_I(t)\sqrt{2}\cos(2\pi f_c t) - x_Q(t)\sqrt{2}\sin(2\pi f_c t) \tag{4.2}$$

$$= A(t)\sqrt{2}\cos(2\pi f_c t + \Theta(t)) \tag{4.3}$$



Slika 4.7: Generiranje signala s kompleksnom ovojnicom

gdje je f_c frekvencija nosioca, $x_I(t)$ i $x_Q(t)$ su kofazna i kvadraturna komponenta signala. $A(t)$ i $\Theta(t)$ se dobivaju kao:

$$A(t) = \sqrt{x_I(t)^2 + x_Q(t)^2} \tag{4.4}$$

$$\Theta(t) = \arctan\left(\frac{x_Q(t)}{x_I(t)}\right) \tag{4.5}$$

$x_I(t)$ i $x_Q(t)$ su signali u osnovnom pojasu, a dobivaju se pomoću izraza:

$$x_I(t) = A(t)\cos(\Theta(t)) \tag{4.6}$$

$$x_Q(t) = A(t)\sin(\Theta(t)) \tag{4.7}$$

Signal s kompleksnom ovojnicom u osnovnom pojasu frekvencija može se zapisati kao:

$$\tilde{x}(t) = x_I(t) + jx_Q(t) = A(t)\exp[j\Theta(t)]. \tag{4.8}$$

Signal u propusnom pojasu frekvencija može se dobiti iz signala s kompleksnom ovojnicom iz:

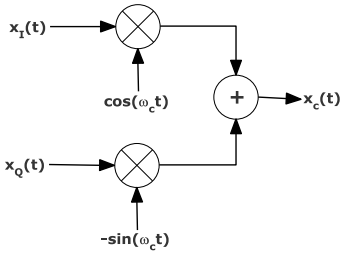
$$x(t) = \sqrt{2}\mathfrak{Re}[\tilde{x})(t)\exp[j2\pi f_c t]]. \tag{4.9}$$

Sustav programski određenog radija prima i odašilje takav signal s kompleksnom ovojnicom na svojim antenskim priključnicama, a koji nosi moduliranu informaciju. Signal s kompleksnom ovojnicom može se generirati množenjem ulaznog signala sa sinusnim signalima na prijenosnoj frekvenciji f_c koji su pomaknuti za 90° međusobno kao što je prikazano na slici 4.7, čime se dobivaju kofazna i kvadraturna komponenta signala.

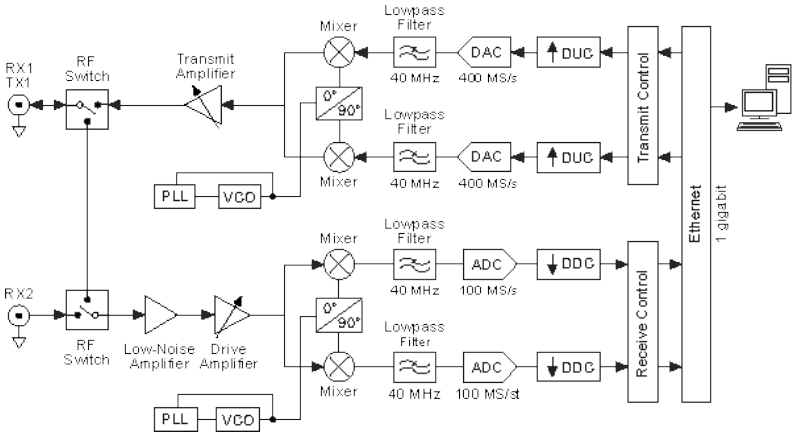
Razdvajanje kofazne i kvadraturne komponente primljenog signala obavlja se množenjem signala istim harmonijskim signalima kao što je prikazano na slici 4.8.

4.3.4 USRP platforma

USRP (eng. *Universal Softvare Radio Peripheral*) komercijalna je platforma programski određenog radija koja pokriva frekvencijska područja većine radijskih sustava od 50 MHz do 6

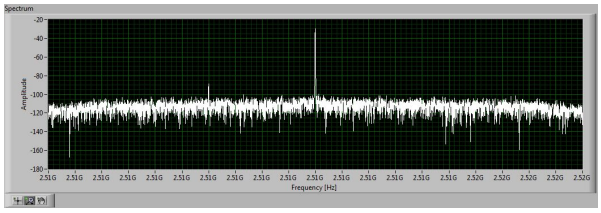


Slika 4.8: Obnavljanje signala s kompleksnom ovojnicom

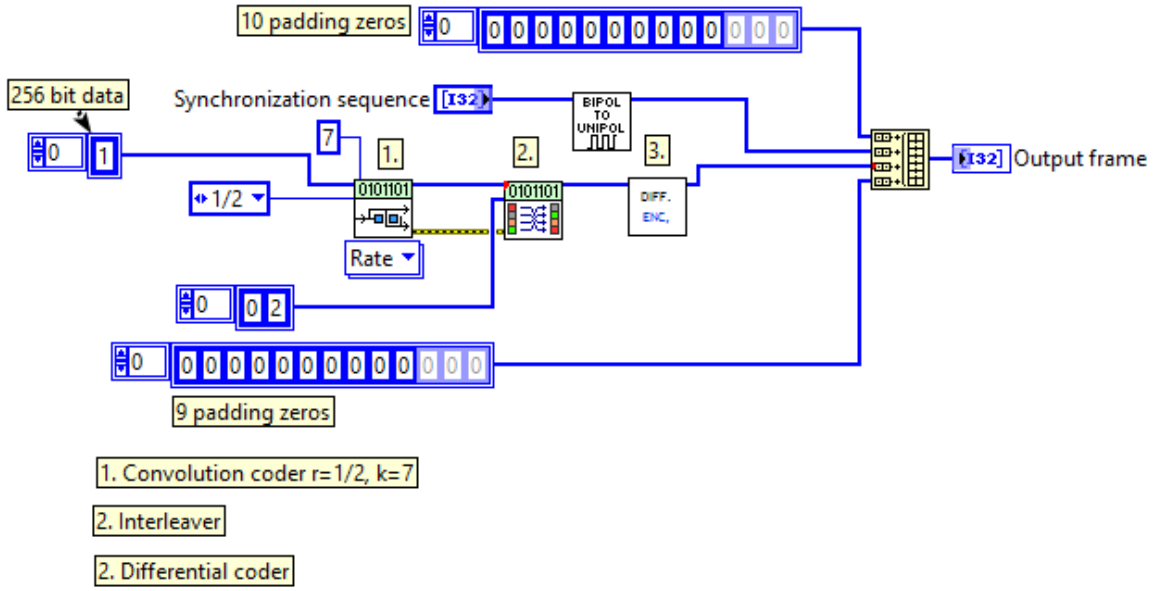


Slika 4.9: USRP arhitektura, preuzeto iz [69]

GHz. USRP platforma tip je arhitekture s direktnim pretvaranjem gdje se radiofrekvencijski signal pretvara na međufrekvenciju odmah nakon primanja, odnosno prije analogno-digitalne pretvorbe [69]. Prednosti takve arhitekture su jednostavnost sklopovlja, jednostavno izvođenje u tehnici integriranih krugova, jednostavna izvedba filtera te dobra selekcija korisnog signala u željenom pojasu. Nedostatak je potreba za lokalnim oscilatorom u kojem su kofazna i kvadraturna komponenta signala fazno i amplitudno idealno sinkronizirane. Jedan od najvećih nedostataka jest nedovoljna izolacija pri čemu postoji signal lokalnog oscilatora čak i kad ne postoji signal na ulazu kao što se vidi na slici 4.10. S obzirom na to da je većina takvih uređaja širokopojasna to daje dodatne zahtjeve na miješalo i niskošumno pojačalo koje bi trebalo biti linearno u cijelom području frekvencija [46]. USRP provodi prilagodbu analognog signala s kompleksnom ovojnicom koja se zahtijeva od gotovo svakog radijskog sučelja: digitalno-analognu i analogno-digitalno analognu pretvorbu, konverziju prema gore i dolje kako bi se dobile kofazna (I) i kvadraturna (Q) komponenta radiofrekvencijskog signala. USRP uređaj



Slika 4.10: Curenje lokalnog oscilatora na USRP platformi



Slika 4.11: Priprema paketa za odašiljanje

povezuje se s upravljačkim računalom gigabitnom žičanom mrežom kojom upravlja sloj MAC baziran na otvorenom kodu.

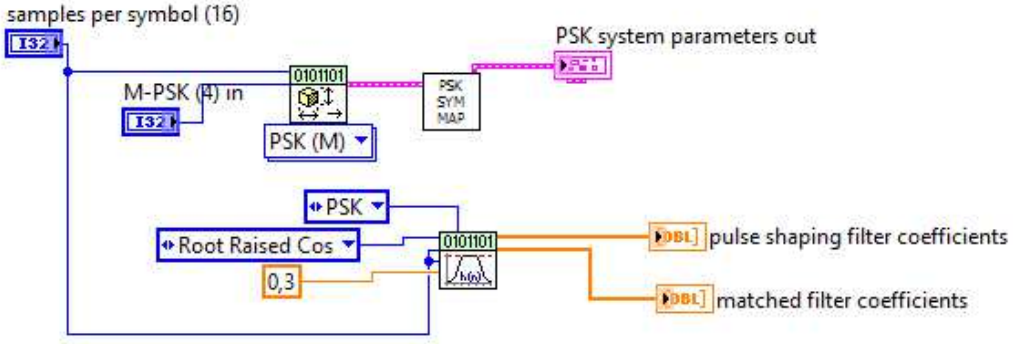
4.4 Izvedba modela u LabView programskom alatu za platformu programski određenog radija

Model sustava prema normi [62] izveden je u programskom alatu LabView za platformu programski određenog radija. U odašiljačkom dijelu prvo se stvara paket prema prikazu u normi [62]. Priprema paketa može se vidjeti na slici 4.11. Podaci se prvo kodiraju konvolucijskim koderom, isprepliću te kodiraju diferencijalnim koderom. Na početak okvira stavlja se sinkronizacijsko zaglavlje te dodatne nule kako bi se uklonila greška zbog kašnjenja u koderima u prijamniku.

Paket se prvo modulira BSPK modulacijskim postupkom uz filtriranje filtrom s kosinusim zaobljenjem karakteristike i koeficijentom zaobljenja $\alpha = 0.3$ što se može vidjeti na slici 4.12.

Nakon BPSK modulacije, modulirani signal svakog korisnika šalje se potprogramu za proširenje pojasa. Signali svakog pojedinog korisnika proširuju se određenim slijedom za proširenje te zbrajaju u zajednički valni oblik kao na slici 4.13 pogodan za slanje USRP programski određenim radijom. U odašiljačkom uređaju signal se naduzorkuje na željeni broj uzoraka, pretvara u analogni sinusni signal te miješa sa signalom lokalnog oscilatora kako bi se translatirao na prijenosnu frekvenciju.

Odašiljački upravljački program za USRP programski određeni radio prima valni oblik s ko-



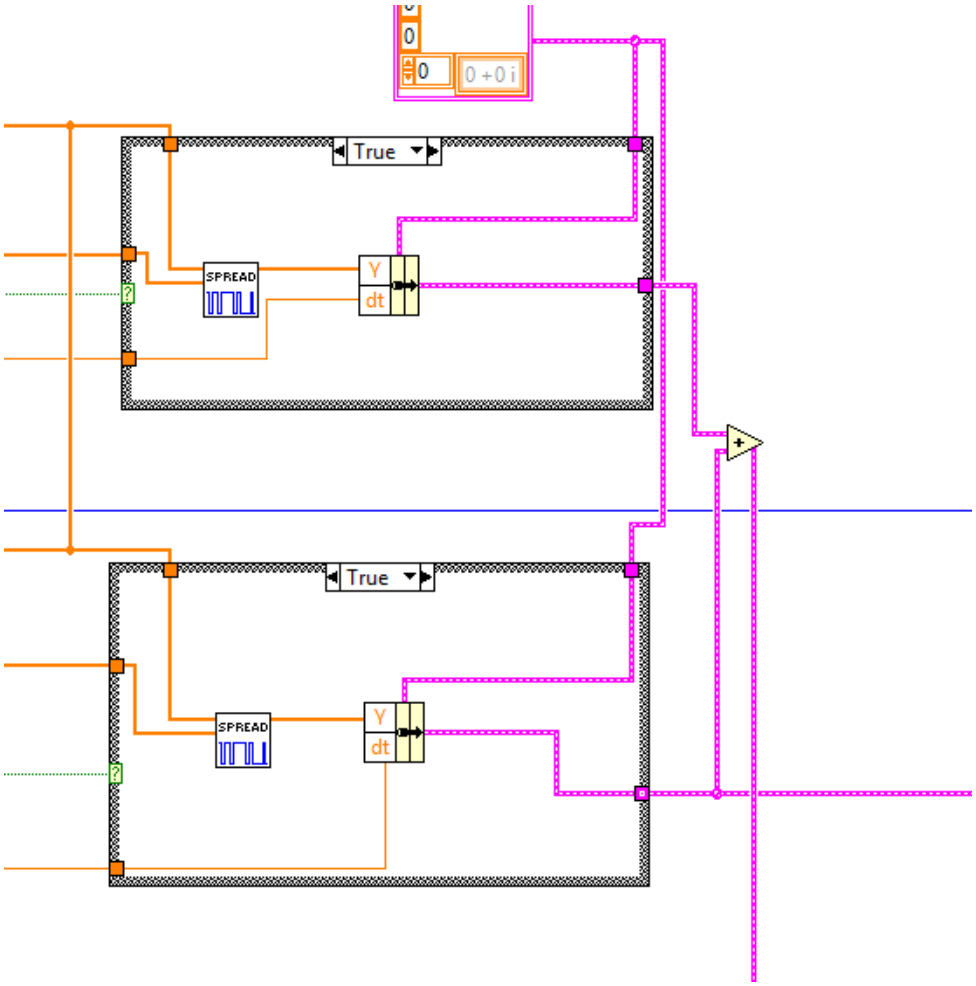
Slika 4.12: Postavljanje parametara PSK modulacije

risnički moduliranim podacima te prilagođava za korištenje s USRP uređajem. Prijamni upravljački program upravlja prijamnim USRP uređajem te prilagođava primljeni signal za obradu u LabView programskom alatu kao na slici 4.14. Prijemni USRP uređaj translatira signal na prijenosnoj frekvenciji u osnovni pojas, pretvara u diskretni signal te poduzorkuje.

Iz prijamnog uređaja, nakon pretvorbe u diskretni signal, ulazni signal u osnovnom pojasu se filtrira niskopropusnim filtrom kako bi se uklonile neželjene komponente nastale nakon pretvorbe. Filtrirani signal se šalje na postupke sažimanja spektra i demodulacije kao na slici 4.15. Pokazalo se da se korištenjem dodatnog niskopropusnog filtra nakon analogno digitalne pretvorbe smanjuju konačne pogreške i povećavaju performance.

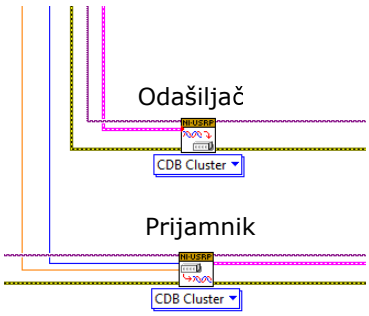
Kako bi se filtrirani signal mogao demodulirati potrebno ga je prvo pomnožiti sa slijedom za proširenje pojasa te korelacijom detektirati podatke. Slijedu za proširenje pojasa se provjerava duljina i tip podataka te se obavlja sinkronizacija slijeda ako je ona omogućena kao na slici 4.16. Kada je slijed sinkroniziran, obavlja se sažimanje pojasa metodom podimpuls po podimpuls gdje se uzima niz ulaznih podatka duljine slijeda za proširenje pojasa, množi sa slijedom za proširenje pojasa te provodi odluka o diskretnoj vrijednosti metodom apsolutne većine diskretnih vrijednosti što se može vidjeti na slici 4.17.

Nakon sažimanja spektra, podaci se moraju PSK demodulirati. Prije PSK demodulacije, obavlja se procjena kanala korištenjem programa za izjednačavanje u otvorenoj petlji. Sustav za izjednačavanje nije predviđen normom, no uočeno je da bez izjednačavanja sustav ima loše performance te ga nije bilo moguće koristiti za komunikaciju. Nakon izjednačavanja obavlja se PSK demodulacija pri čemu se koriste simboli za sinkronizaciju iz zaglavlja paketa. Cijeli potprogram za demodulaciju može se vidjeti na slici 4.18. Bez provedene sinkronizacije, učestalost pogreške bita iznosi 0.5 što pokazuje da bez sinkronizacijskih postupaka takav sustav nije moguće koristiti. Nakon demodulacije izlazni signal je u obliku bitova te je potrebno detektirati početak paketa korištenjem zaglavlja. Nakon što je određen početak paketa korelacijom s poznatim zaglavljem, paket se šalje na diferencijalno dekodiranje, inverzno ispreplitanje te konvolucijsko dekodriranje. Nakon tih koraka, dobivaju se primljeni informacijski bitovi koji

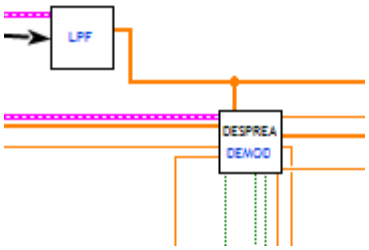


Slika 4.13: Višekorisnički sustav s višestrukim pristupom po kodu

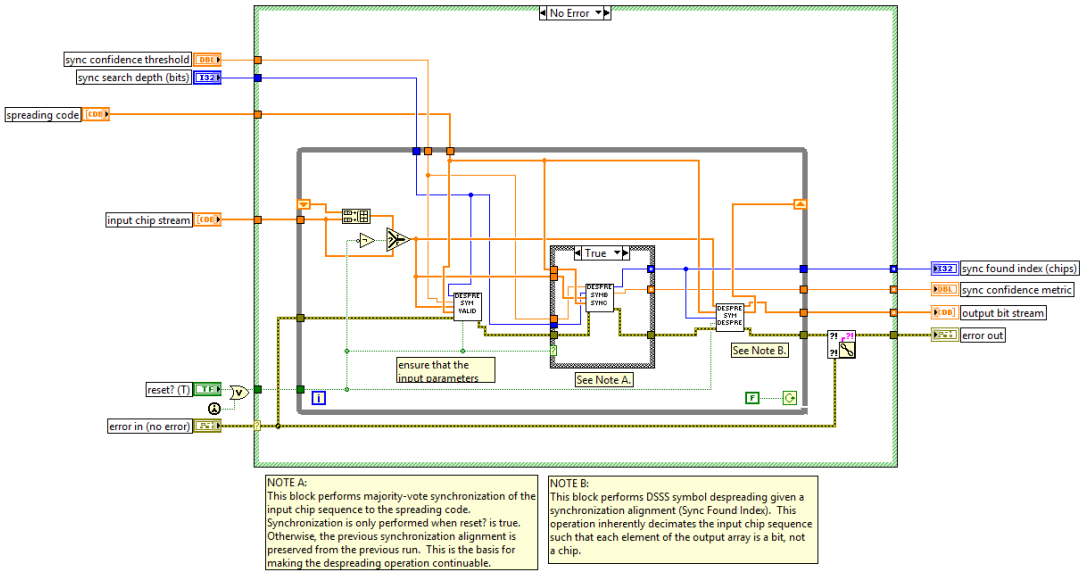
se uspoređuju s poslanim bitovima kako bi se odredila učestalost pogreške bita BER (eng. *Bit Error Rate*).



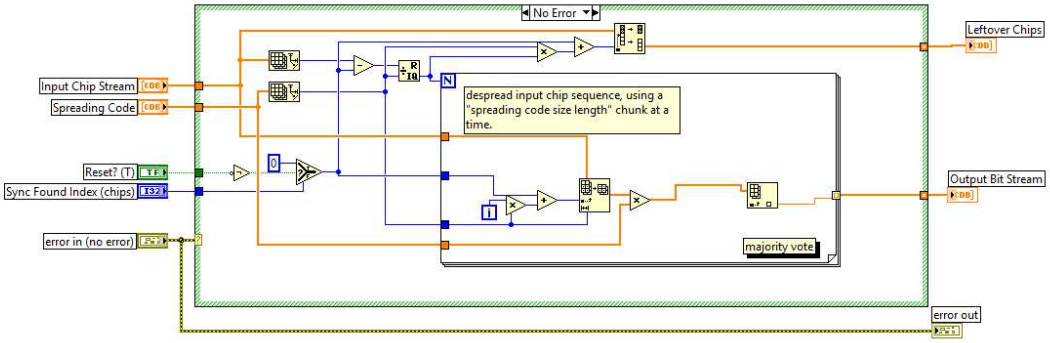
Slika 4.14: Odašiljački i prijamni program za upravljanje USRP uređajima



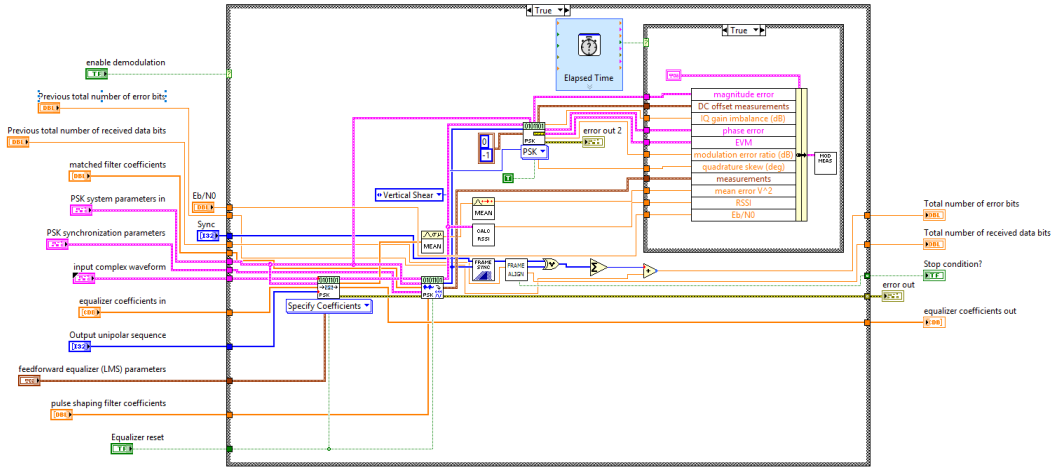
Slika 4.15: Niskopropusni filtar prije demodulacije



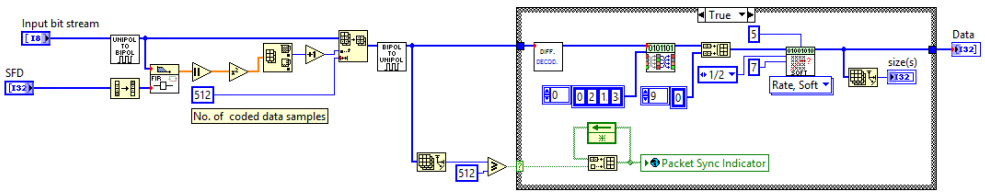
Slika 4.16: Provjera slijeda za proširenje i sinkronizacija slijeda



Slika 4.17: Sažimanje pojasa podimpuls po podimpuls



Slika 4.18: PSK demodulacija, sinkronizacija i mjerenje parametara za procjenu performanci



Slika 4.19: Sinkronizacija početka paketa te diferencijalno i konvolucijsko dekodiranje

Poglavlje 5

Optimiranje kaotičnih sljedova

Optimalni sljedovi za proširenje pojasa za višestruki pristup po kodu trebali bi imati dobra autokorelacijska i dobra križnokorelacijska svojstva. Kako bi se mogla ostvariti brza i pouzdana sinkronizacija slijeda, autokorelacijska funkcija trebala bi imati što manje sekundarnih komponenti uz izraženu autokorelacijsku vrijednost za pomak slijeda od 0 uzoraka. Optimalan oblik autokorelacijske funkcije jest Diracov impuls za što bi bio potreban beskonačan spektar. Za postizanje optimalnih performanci u višekorisničkom slučaju, sljedovi za proširenje bi trebali imati što manji iznos međusobne križne korelacije [60]. Optimiranje korelacijskih parametara može se provoditi kroz analizu srednjih kvadratnih vrijednosti autokorelacijskih i križnokorelacijskih funkcija. Kod optimiranja križne korelacije promatra se međusobna srednja kvadratna križnakorelacija svih sljedova u sustavu [70].

Korelacijska svojstva sljedova numerički se provjeravaju i optimiraju nakon generiranja svih sljedova i opisuju kvalitetu sljedova za proširenje pojasa, a koristit će se aperiodička korelacijska funkcija. Ako su c_X i c_Y slijedovi za proširenje pojasa, onda se aperiodička korelacijska funkcija može definirati kao [70]:

$$C_{XY}(\tau) = \begin{cases} \sum_{k=0}^{N-1-\tau} c_X(k)c_Y^*(k+\tau) & \text{za } 0 \leq \tau \leq N-1 \\ \sum_{k=0}^{N-1+\tau} c_X(k)c_Y^*(k) & \text{za } 1-N \leq \tau < 0 \\ 0 & \text{u suprotnom} \end{cases} \tag{5.1}$$

Pomoću aperiodičke korelacijske funkcije 5.1 može se definirati Golayev korelacijski parametar sljedova GF koji se dobiva kao [70, 71, 72]:

$$GF = \frac{N^2}{2\sum_{\tau=1}^{N-1} |C_{XX}(\tau)|^2} \tag{5.2}$$

gdje je N duljina, a C_{XX} aperiodička autokorelacijska funkcija slijeda c_X. Golayev parametar

opisuje udio raspršenja energije u bočnim komponentama autokorelacijske funkcije. Sljedovi za proširenje pojasa sadrže konačnu količinu energije koja se opisuje kroz korelacijsku funkciju. Idealan slučaj bi bio da je sva energija sadržana u glavnoj komponenti autokorelacijske funkcije, odnosno da autokorelacijska funkcija ima oblik Diracovog impulsa za sve pomake autokorelacije. Smanjenje energije u glavnoj komponenti autokorelacijske funkcije povećava potreban omjer signala i šuma za uspješnu detekciju i sinkronizaciju slijeda. Ako su bočne komponente izražene, slijed će se sinkronizirati na pogrešnom mjestu što dovodi do smanjenja kvalitete i performanci prijenosa [60].

Sljedovi u višekorisničkom sustavu, odnosno u sustavu koji koristi tehnike višestrukog pristupa pomoću sljedova CDMA (eng. *Code Division Multiple Access*) moraju imati dobra križnokorelacijska svojstva kako bi se podaci svih korisnika mogli uspješno i pravilno detektirati. Sljedovi u CDMA tehnici trebali bi imati što nižu međusobnu križnokorelacijsku funkciju kako bi se smanjila interferencija višestrukog pristupa. Taj je uvjet jednostavno ostvariti u savršeno sinkroniziranim sustavima u kojima je moguće koristiti ortogonalne sljedove za proširenje pojasa [59, 60]

Ortogonalni sljedovi imaju niske vrijednosti križnokorelacijske funkcije ako je pomak ili kašnjenje slijeda nula, odnosno ako su sljedovi savršeno sinkronizirani i poravnati. U realnim sustavima dolazi do kašnjenja, odnosno sljedovi se ne mogu savršeno poravnati što dovodi do smanjenja ortogonalnosti te povećanja razine međusobne interferencije [60].

Križna korelacija se može promatrati kroz srednju kvadratnu križnokorelacijsku funkciju MSCCF (eng. *Mean Square Cross Correlation Function*) koja se može zapisati kao [70]:

$$R_{cc} = \frac{1}{S(S-1)} \frac{1}{N^2} \sum_{x=1}^{S} \sum_{y=1, y\neq x}^{S} \sum_{l=1-N}^{N-1} |C_{XY}(l)|^2 \tag{5.3}$$

gdje je S veličina skupa promatranih sljedova, a N duljina slijeda. Kako bi se ostvarila uspješna komunikacija, slijed bi trebao imati visoke vrijednosti srednje kvadratne autokorelacijske funkcije MSACF (eng. *Mean Square Autocorrelation Function*), a skup svih korištenih sljedova u sustavu niske razine međusobne srednje kvadratne križnokorelacijske funkcije [70]. Optimiranje sljedova u cijelom sustavu trebalo bi se provoditi u odnosu na dvije varijable korelacijskih funkcija što može biti vremenski zahtjevno.

U radu [70] autori su pronašli vezu Golayevog faktora i srednje kvadratne križnokorelacijske funkcije:

$$GF \leq \frac{1}{A(1-R_{CC})} \tag{5.4}$$

gdje je A

$$A = \frac{3V}{4} + 1 \tag{5.5}$$

a V je veličina prostora sljedova.

Korištenjem 5.4 dobiva se uvid u povezanost autokorelacijske i križnokorelacijske funkcije preko jedne varijable. Ta povezanost omogućuje optimiranje sljedova samo preko Golayevog parametra sljedova. Proračun križnokorelacijskih vrijednosti za velike skupove sljedova za proširenje često je problematičan jer se računaju vrijednosti križne korelacije svakog slijeda sa drugim sljedovima. Takav proračun je minimalne kompleksnosti $O(N^2)$.

U ovom radu optimiranje kaotičnih sljedova obavlja se nakon generiranja sljedova te je potrebno imati pregledan način vrednovanja korelacijskih parametra te se izraz 5.4 koristi za optimiranje sljedova za proširenje pojasa u višekorisničkom sustavu s višestrukim pristupom po kodu.

Kaotični sljedovi s visokim Golayevim parametrom trebali bi pokazivati bolje performance u višekorisničkom sustavu. Kako bi se provjerila metoda optimiranja korištenjem Golayevog parametra, generirani su sljedovi s visokim i niskim vrijednostima Golayevog parametra iz nekoliko jednodimenzionalnih kaotičnih sustava. Performance sljedova su evaluirane u modelu prema normi za radijske osobne lokalne mreže s niskom propušnošću LR-WPAN (eng. *Low Rate Wireless Personal Area Network*). Model je izrađen za platformu programski određenog radija kako bi se mogli mijenjati i evaluirati razni parametri prijenosa. Performance su uspoređivane u odnosu na Gold sljedove koji su određeni prema normi IEEE 802.15.4 za LR-WPA mreže.

Sljedovi s visokom vrijednošću Golayevog parametra trebali bi imati širi spektar, niže razine križnokorelacijske funkcije te pokazivati bolje performance u višekorisničkom sustavu uslijed smanjenje međusobne inteferencije višestrukog pristupa MAI (eng. *Multiple Access Interference*). Sljedovi s viskom GF optimalnije raspršuju informaciju i energiju u zadanom pojasu frekvencija što poboljšava otpornost na smetnje, interferenciju i namjerno blokiranje signala [70].

5.1 Kaotični iteratori za generiranje sljedova

Kako bi se generirali sljedovi sa što boljim svojstvima, za generiranje je korišteno nekoliko jednodimenzionalnih kaotičnih iteratora: populacijski iterator, iterator šatorsko krilo i Čebiševljev iterator [50, 51, 53].

Izabrani iteratori su dobro proučeni i njihova matematička svojstva i ponašanje je poznato.

Populacijski iterator se može zapisati kao [53]:

$$X_{n+1} = \mu X_n(1 - X_n) \tag{5.6}$$

gdje je vrijednost varijable X za korak iteracije n, a $\mu = [0 \quad 4]$ je parametar kaotičnog sustava. Kaotično ponašanje pojavljuje se za vrijednosti $\mu > 3.57$.

Iterator šatorsko krilo može se zapisati kao [73]:

$$X_{n+1} = \begin{cases} 2\mu X_n & \text{ako je } 0 \leq X_n \leq 0.5 \\ 2\mu(1-X_n) & \text{ako je } 0.5 < X_n \leq 1. \end{cases} \tag{5.7}$$

gdje je $0 < \mu \leq 2$.

Čebiševljev iterator ima oblik [21]:

$$X_{n+1} = \cos(\mu \cdot \arccos(X_n)) \tag{5.8}$$

gdje je $\mu \geq 2$.

Kaotični iteratori 5.6, 5.7 i 5.8 preslikavaju ulazne vrijednosti u neki zadani interval karakterističan za svaki iterator. Kako bi se dobile diskretni bipolarni sljedovi pogodni za korištenje u sustavu s proširenim spektrom, generirani signal X_n se diskretizira oko srednje vrijednosti korištenjem praga:

$$\vartheta_n = \begin{cases} -1, \overline{X_n} \leq 0.5 \\ 1, \overline{X_n} > 0.5 \end{cases} \tag{5.9}$$

gdje je

$$\overline{X_n} = \frac{\sum_1^n X_n}{n} \tag{5.10}$$

srednja vrijednosti X_n.

Korištenjem 5.9 dobivaju se diskretni bipolarni uzroci slijeda za proširenje pojasa koji su pogodni za analizu korelacijskih svojstava. Analizom korelacijskih svojstava u odnosnu na parametar kaotičnog sustava μ moguće je odabrati vrijednosti parametra kaotičnog sustava kako bi se generirali optimirani sljedovi za proširenje pojasa. Promjenom parametra sustava μ mijenja se ponašanje te sustav može biti u stabilnom ili kaotičnom području. Za generiranje optimiranih sljedova u ovom radu koristit će se vrijednosti parametra kaotičnog sustava μ za koje se pojavljuje kaotično ponašanje. Izabrani jednodimenzionalni iteratori, 5.6, 5.7 i 5.8 odabrani su za generiranje sljedova za proširenje i analizu jer je područje kaotičnog ponašanja dobro opisano i ograničeno parametrom sustava μ. Ponašanje korištenih kaotičnih iteratora je detaljno proučeno u odnosu na parametar sustava u literaturi [40, 50, 51, 55, 73].

Prijašnjom analizom korelacijskih svojstava nekih sljedova u [74] uočeno je da se sljedovi s većim Golayevim faktorom GF pojavljuju s porastom parametra sustava μ. Veći iznos parametra sustava μ može se povezati s većom "kaotičnošću" sustava, odnosno većim unosom i raspršenjem energije kroz nelinearni sustav. Povećanjem parametra μ raste i Ljapunovljev eksponent sustava koji pokazuje brzinu divergencije trajektorija [53]. To raspršenje energije,

odnosno povećanje šuma ili slučajnosti može se vidjeti na bifurkacijskom dijagramu populacijskog iteratora. Povećanjem parametra μ generiraju se izlazni signali sa sve većim brojem perioda odnosno šireg frekvencijskog spektra. Kod generiranja kontinuiranih signala korištenjem populacijskog iteratora u obliku diferencijalne jednadžbe za određene vrijednosti parametra μ pojavljuju se signali generirani s periodama koje teže beskonačnosti.

Nakon početne analize, postavljena je hipoteza da se promjenom parametra sustava mogu generirati sljedovi za proširenje pojasa s boljim korelacijskim svojstvima što je u manjoj mjeri provjereno i u prijašnjem članku [74]. Hipoteza je provjerena generiranjem većeg broja sljedova korištenjem jednodimenzionalnih iteratora s promjenom parametra kaotičnog sustava.

Broj generiranih sljedova kaotičnog sustava odabran je kako bi se maksimizirao Golayev faktor GF te je nakon nekoliko iteracija odabran broj sljedova od $N = 3 \times 10^8$. Tim je brojem sljedova omogućena fina podjela intervala parametra kaotičnog sustava u obliku

$$\mu_n = \mu_0 + \frac{n}{N}, \quad \mu_n < \mu_1 \tag{5.11}$$

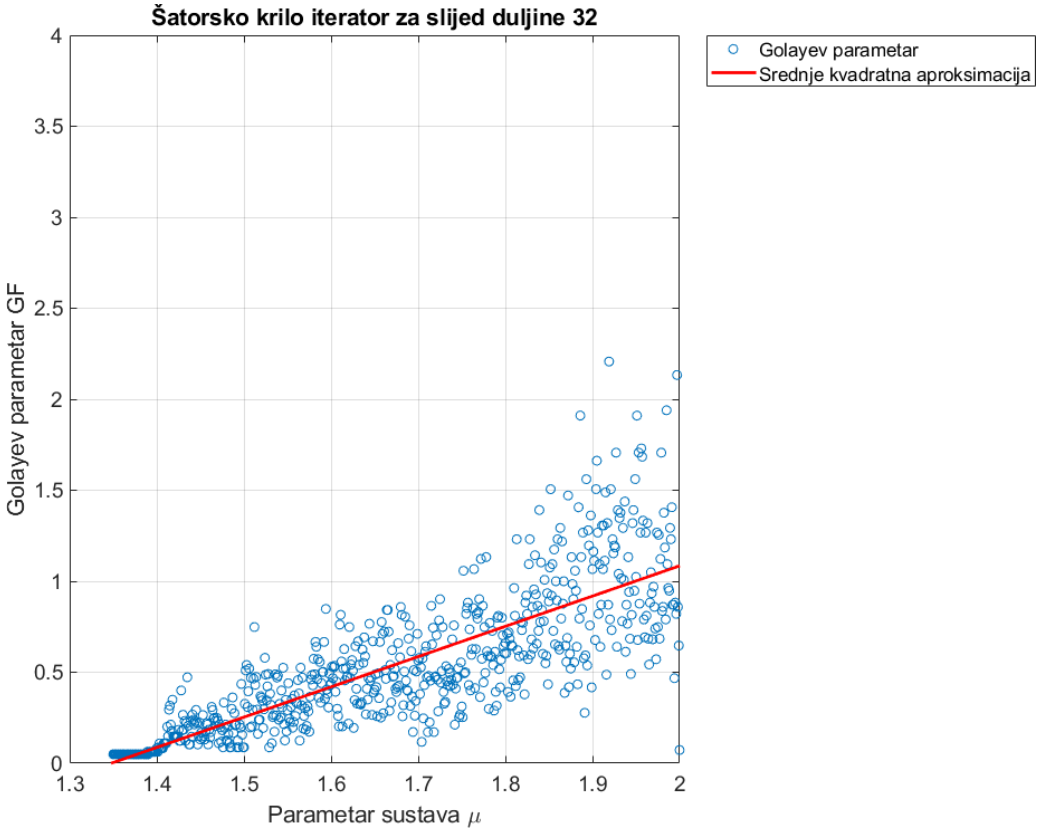
gdje su μ_0 i μ_1 početne i konačne vrijednosti parametra iteratora u kojem je sustav u kaotičnom području, a n korak iteracije.

Za svaku diskretnu vrijednost μ_n generira se slijed duljine 32, 64 ili 128 uzoraka te se izračunava Golayev parametar GF. Sljedovi s najvišim vrijednostima GF odabiru se za sljedove za proširenje pojasa. Za evaluaciju odabran je podskup od 16 sljedova s najvišim vrijednostima parametra GF. Uz sljedove za proširenje odabrani su i sljedovi koji će se koristiti kao referentni sljedovi za sinkronizaciju u preambuli. Odabrani sljedovi za proširenje pojasa i sinkronizaciju evaluiraju se u modelu sustava po normi za senzorske mreže na platformi softverski definiranog radija.

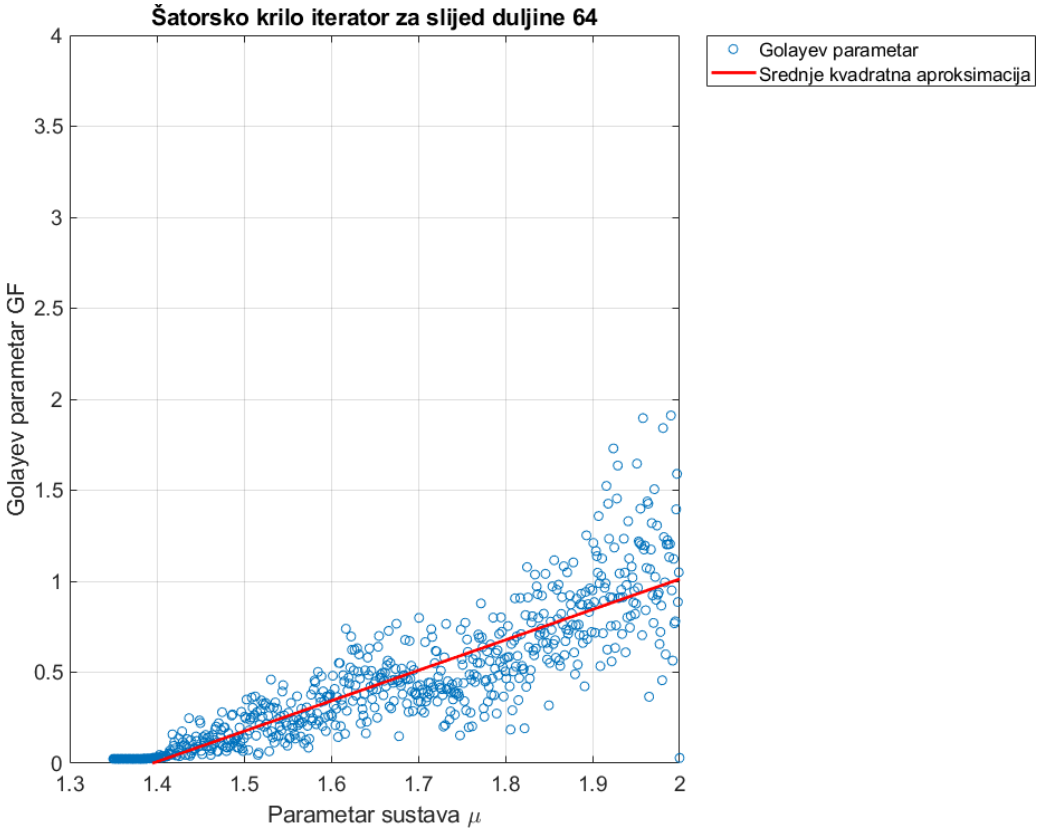
Na slikama 5.1, 5.2, 5.3, 5.4, 5.5, 5.6, 5.7, 5.8 i 5.9 može se vidjeti usporedba promjene Golayeveg parametra GF u odnosu na parametar kaotičnog sustava μ. Može se uočiti da GF raste s porastom μ za sve odabrane jednodimenzionalne kaotične iteratore što se može koristiti za generiranje sljedova s boljim svojstvima odabirom što veće vrijednosti parametra μ. Hipoteza o povezanosti parametara kaotičnog sustava i korelacijskih parametara dobivenih signala potvrđena je rezultatima prikazanim na slikama.

Metoda generiranja optimiranih sljedova korištena je na dva načina. U prvom je korišten promjenjivi parametar iteratora μ pri čemu se radila i potvrda hipoteze. U drugom načinu su se koristili rezultati prvog načina, pri čemu se generirao drugi skup sljedova za proširenje pojasa s visokim vrijednostima parametra μ. Takav odabir parametra μ trebao bi generirati sljedove s većom vrijednosti GF, odnosno optimiranije sljedove.

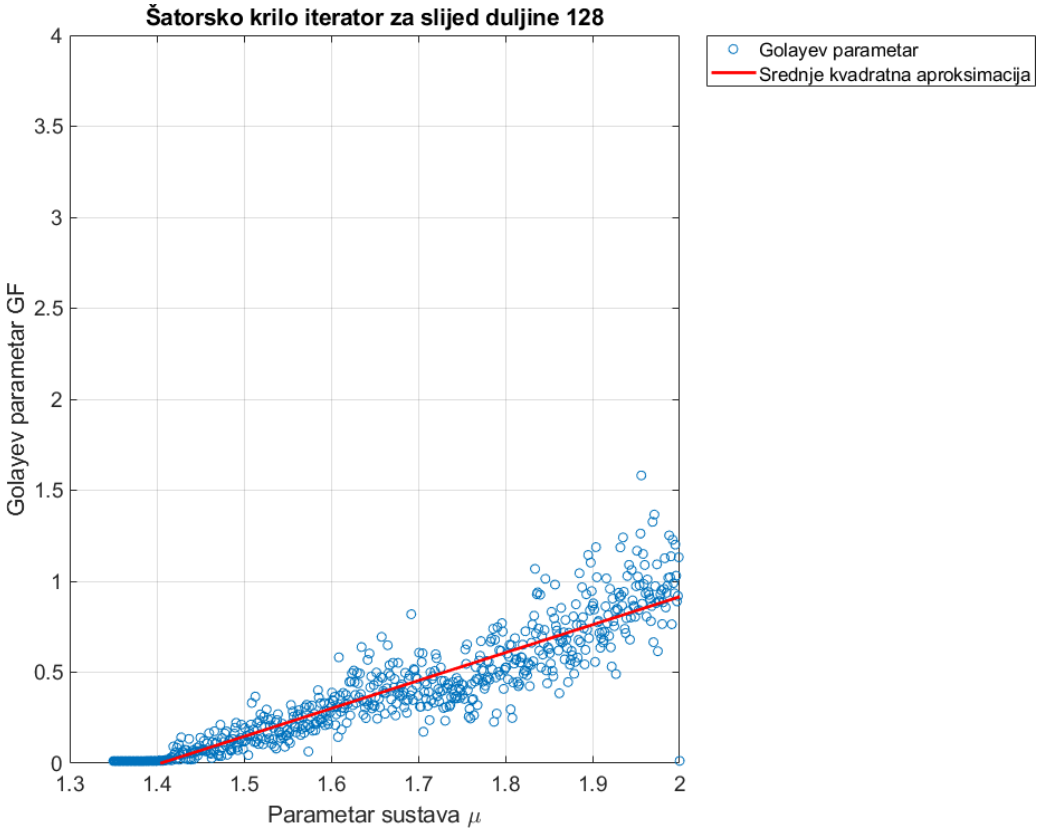
Kako bi se provjerili rezultati optimiranja sljedova, izdvojene su vrijednosti srednjeg i maksimalnog Golayevog parametra za cijeli skup sljedova za proširenje pojasa nakon postupka op-



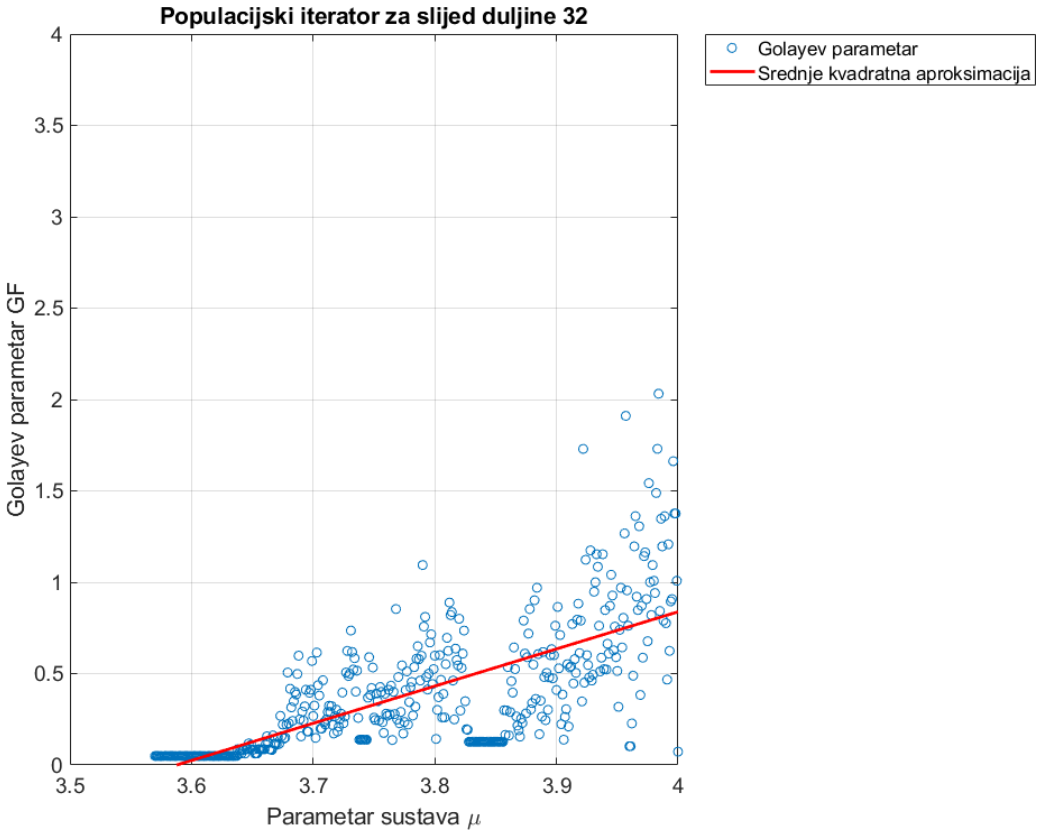
Slika 5.1: Promjena GF za iterator šatorsko krilo za slijed duljine 32



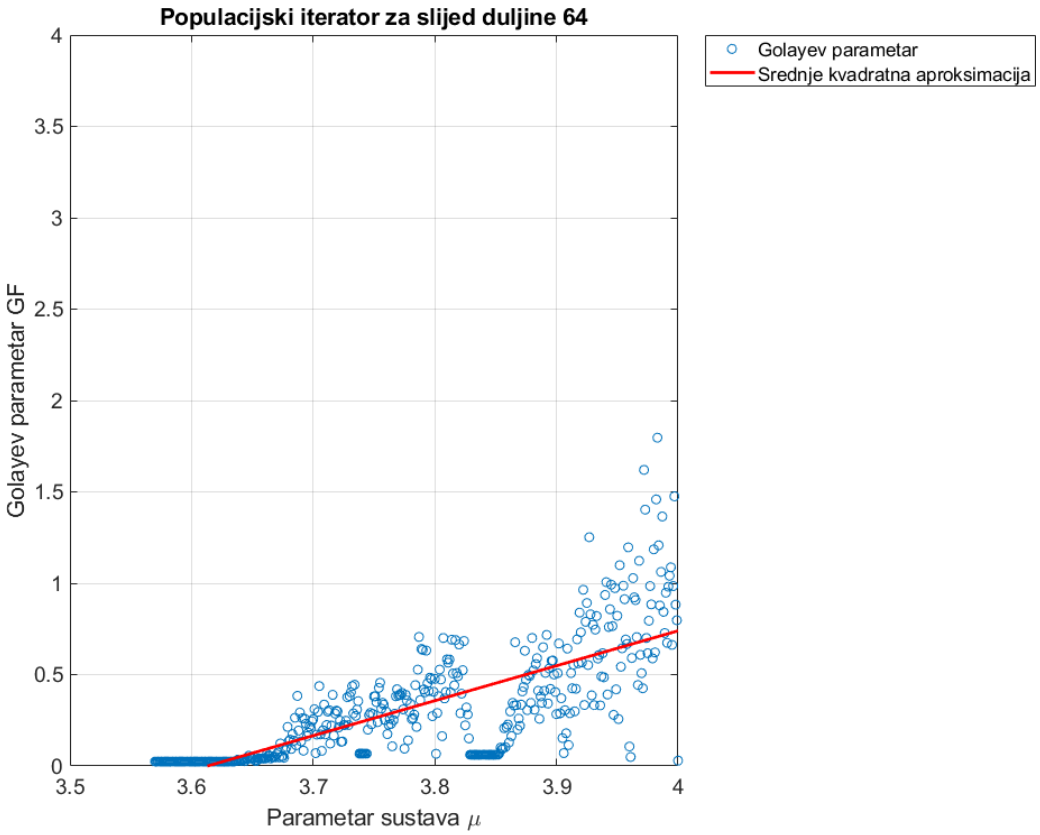
Slika 5.2: Promjena GF za iterator šatorsko krilo za slijed duljine 64



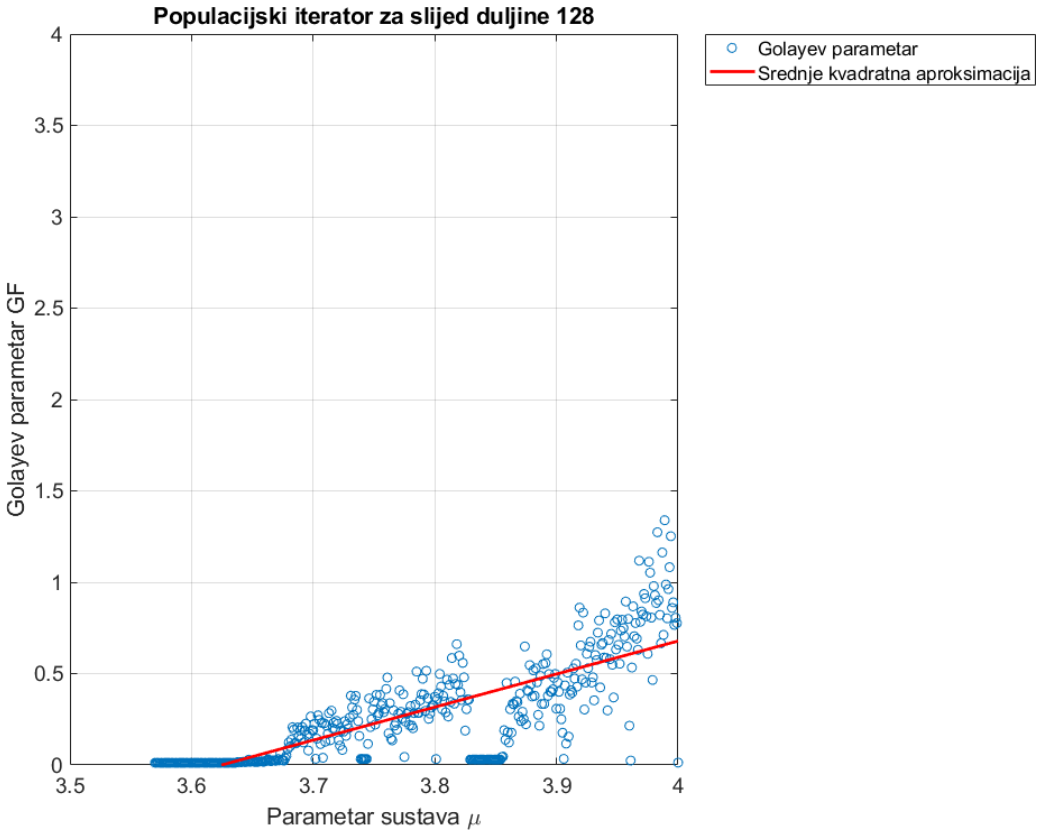
Slika 5.3: Promjena GF za iterator šatorsko krilo za slijed duljine 128



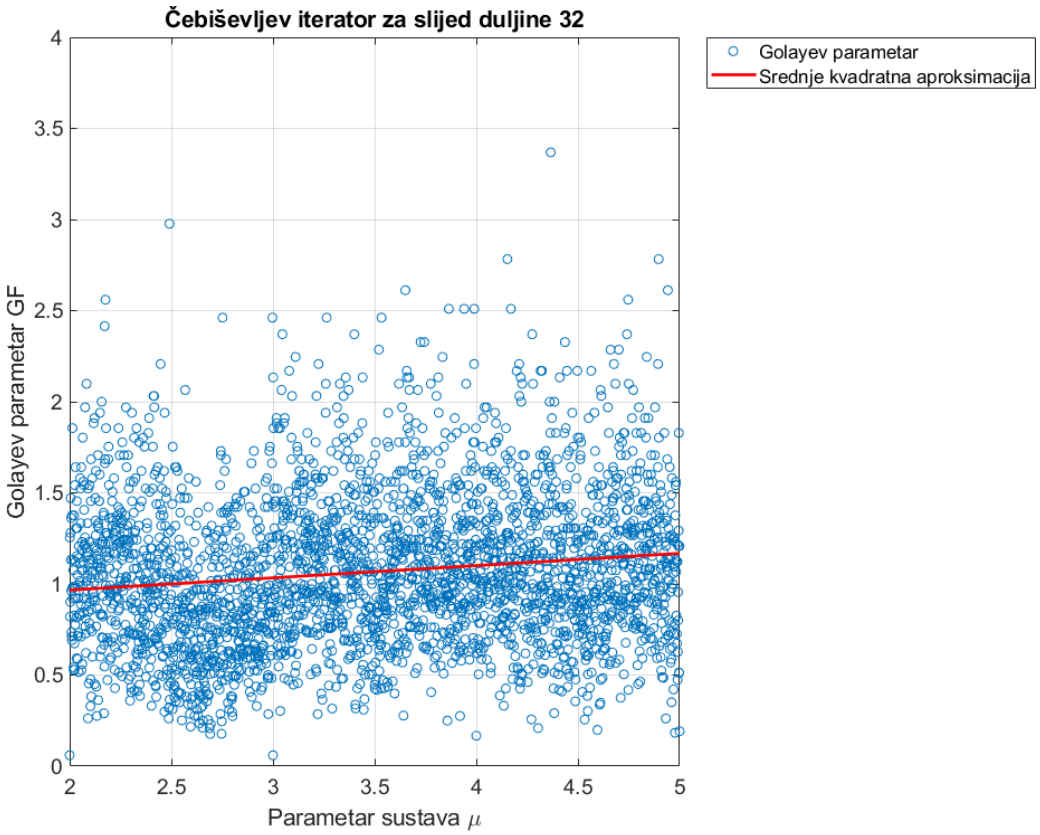
Slika 5.4: Promjena GF za populacijski iterator za slijed duljine 32



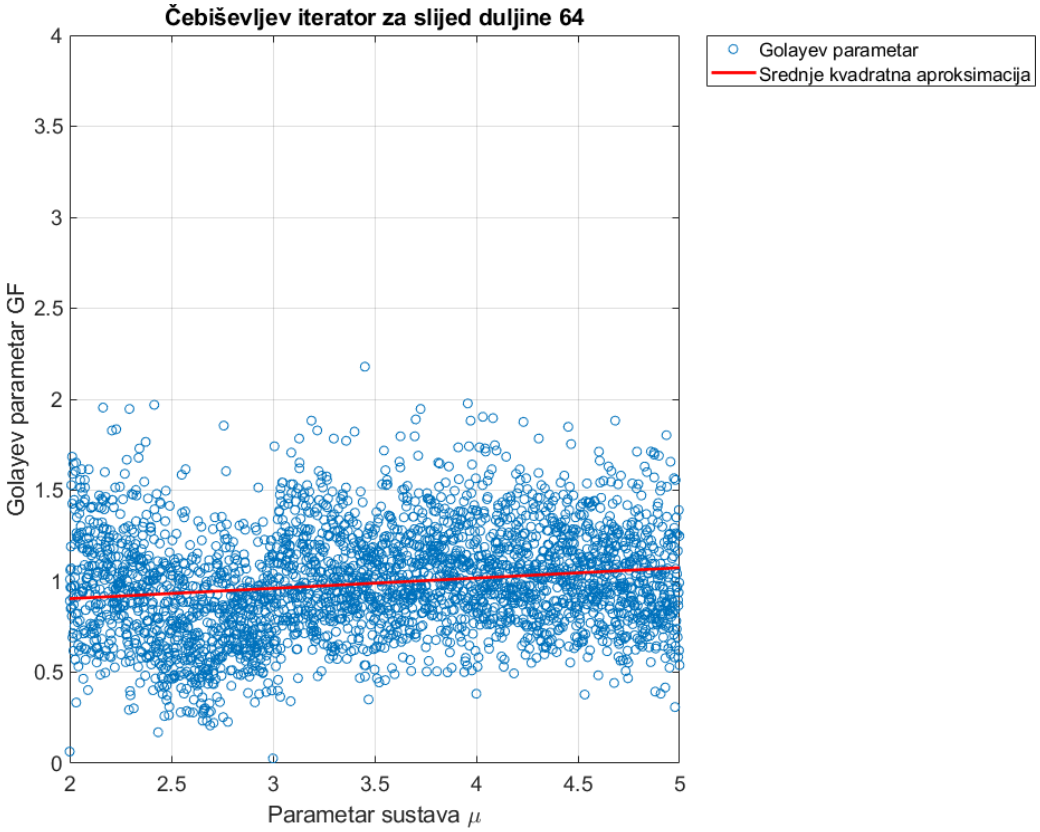
Slika 5.5: Promjena GF za populacijski iterator za slijed duljine 64



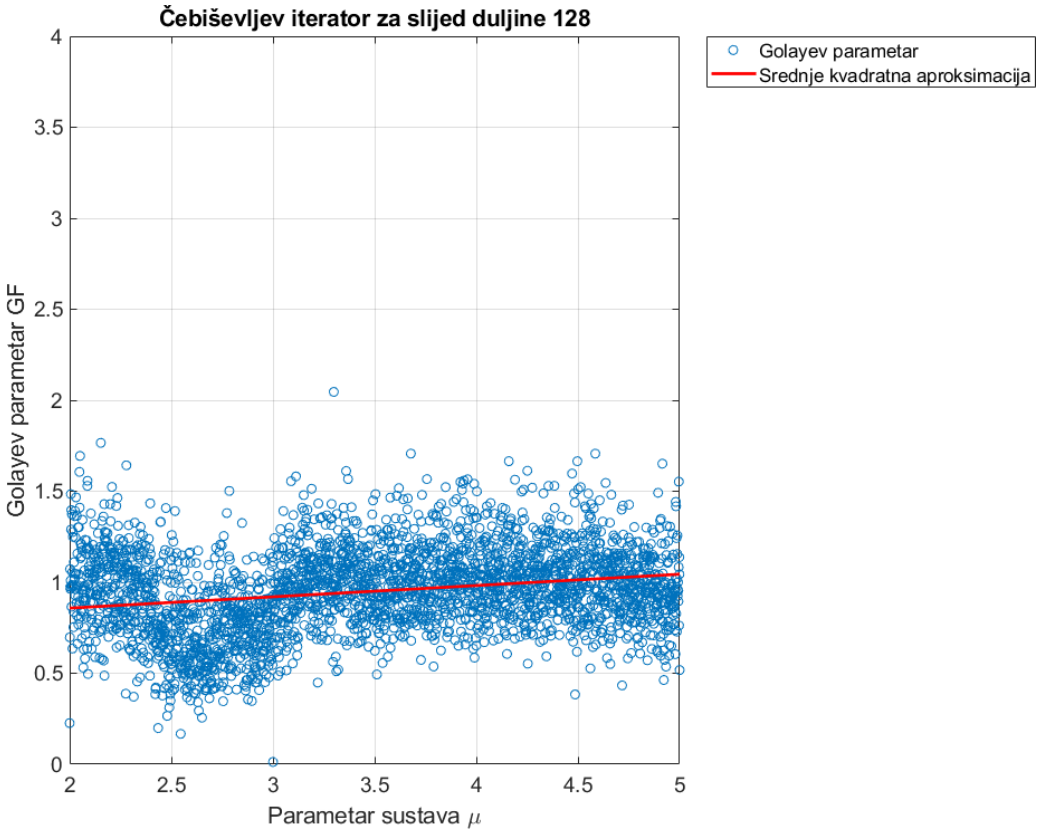
Slika 5.6: Promjena GF za populacijski iterator za slijed duljine 128



Slika 5.7: Promjena GF za Čebiševljev iterator za slijed duljine 32



Slika 5.8: Promjena GF za Čebiševljev iterator za slijed duljine 64



Slika 5.9: Promjena GF za Čebiševljev iterator za slijed duljine 128

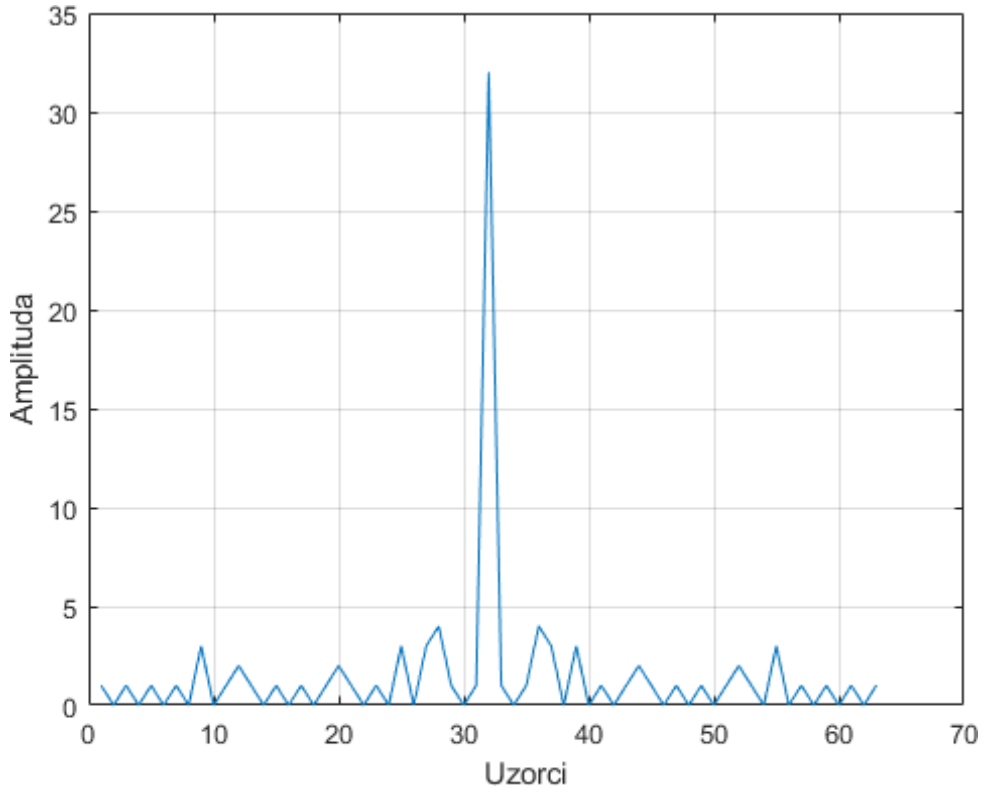
timiranja. Istim programom izračunat je *GF* za Gold sljedove, dok je maksimalni *GF* dobiven iz postupka odabira optimiranih sljedova.

U tablici 5.1 prikazani su izračunati parametri *GF* za sljedove koji su generirani promjenom μ. Može se uočiti da se takvom metodom generiranja i optimiranja sljedova mogu generirati sljedovi koji imaju značajno veći *GF* u odnosu na Gold sljedove. Visoki srednji *GF* pokazuje da bi cijeli skup trebao imati dobra korelacijska svojstva za višestruki pristup. Iznos *GF* je normiran na kvadrat duljine slijeda tako da je moguće samo uspoređivati sljedove iste duljine.

Korelacijska svojstva se mogu prikazati i vizualno iscrtavanjem vrijednosti autokorelacijske i križnokorelacijske funkcije. Na slikama 5.10 i 5.11 mogu se vidjeti autokorelacijske funkcije Gold slijeda i generiranog slijeda iz Čebiševljevog iteratora. Može se vidjeti da kaotični slijed ima izraženiju glavnu komponentu uz manje vrijednosti bočnih komponenti u odnosu na Gold slijed.

Takav oblika autokorelacijske funkcije, s nižim bočnim komponentama, trebao bi omogućiti bolje performance u sustavima koji koriste neku korelacijsku metodu za sinkronizaciju jer je većina energije sadržana u glavnoj komponenti. Više razine bočnih komponenti mogu dovesti do sinkronizacije na krivom mjestu u slijedu te pogoršavanja performanci sustava [59, 60].

Autokorelacijsku funkciju slijeda s visokim razinama bočnih komponenti može se vidjeti na slici 5.12. Slika prikazuje autokorelaciju slijeda s niskim *GF* koji je generiran korištenjem

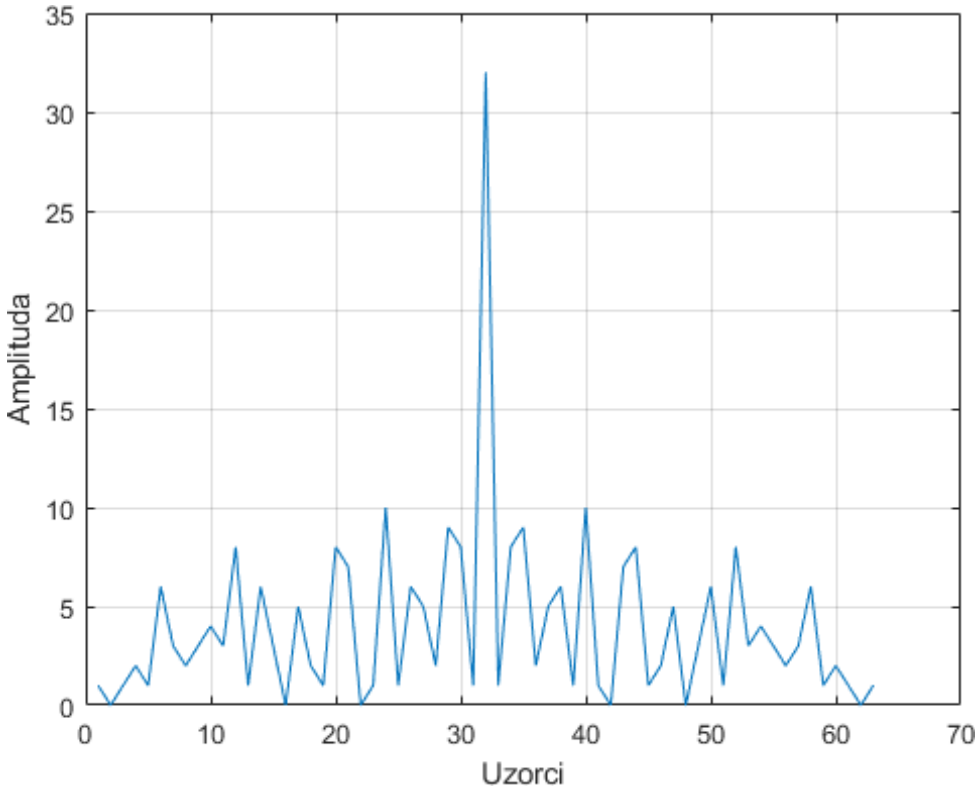


Slika 5.10: Izgled autokorelacijske funkcije za slijed generiran Čebiševljevim iteratorom

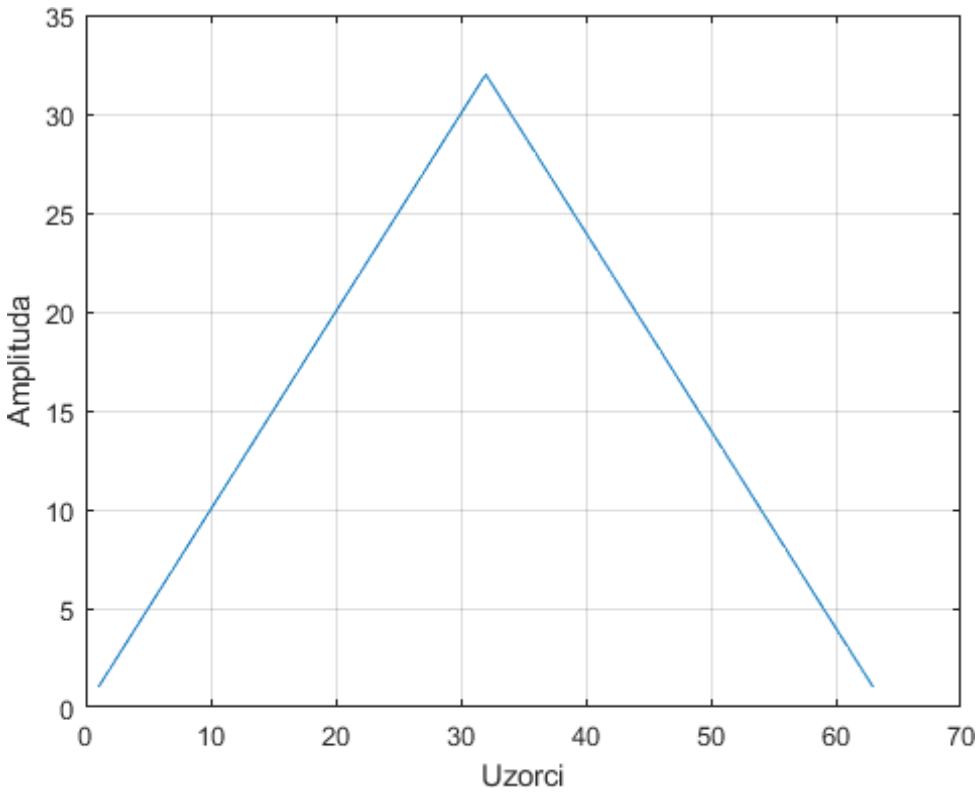
Čebiševljevog iteratora. Takav slijed nije optimiran za korištenje u sustavu s proširenim spektrom jer ne raspršuje energiju optimalno po cijelom spektru. Sinkronizacija takvog slijeda je otežana te zahtijeva veće amplitude signala kako bi se se detektirao slijed. U ovom radu će biti evaluirani i sljedovi s niskim *GF* kako bi se pokazalo da takvi sljedovi nisu optimirani za prijenos u sustavima s proširenim spektrom.

Iznosi amplitude idealne križnokorelacijske funkcije trebali bi biti što manji kako bi se što bolje odvojili podaci za svakog korisnika u višekorisničkom sustavu. Veće razine križne korelacije povećavaju međusobnu interferenciju te smanjuju ukupan koristan omjer signala i šuma. Na slikama 5.13 i 5.14 mogu se vidjeti križne korelacije za dva slijeda iz skupa sljedova za proširenje pojasa korištenih za evaluaciju u modelu sustava. Kod oba slijeda postoje križne korelacije, no kod sljedova generiranog Čebiševljevim iteratorom križne korealcije imaju niže amplitude.

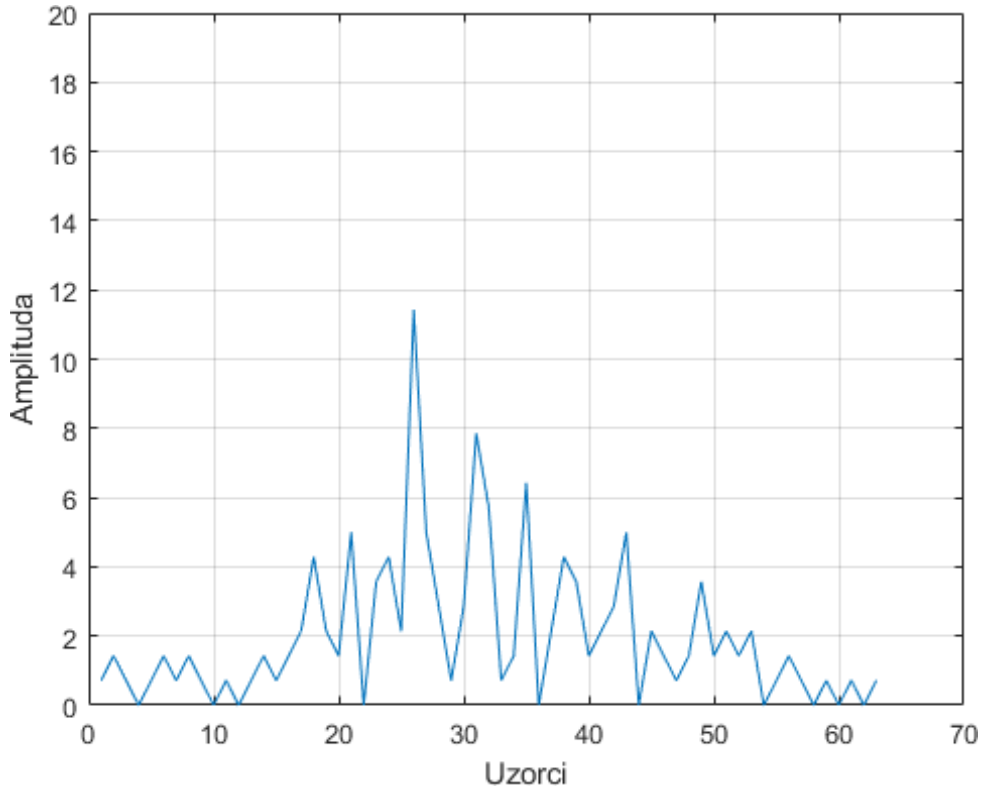
Na slici 5.15 može se vidjeti križnokorelacijska funkcija za sljedove generirane Čebiševljevim iteratorom s niskom vrijednošću Golayevog faktora $GF = 0.0854$. Oblik funkcije pokazuje da postoji izražena korelacija za sve pomake sljedova. Takvi sljedovi nisu pogodni za korištenje u višekorisničkim sustavima. Korištenjem takvih sljedova povećava se interferencija višestrukog pristupa odnosno prijamnik će teško razlučiti pojedine tokove podataka ako su oni međusobno korelirani. S obzirom na to da prijamnik ne može razlučiti korisni signal, on se smatra šumom.



Slika 5.11: Izgled autokorelacijske funkcije za Gold slijed



Slika 5.12: Izgled autokorelacijske funkcije za sljedove generirane Čebiševljevim iteratorom uz nisku vrijednost *GF*

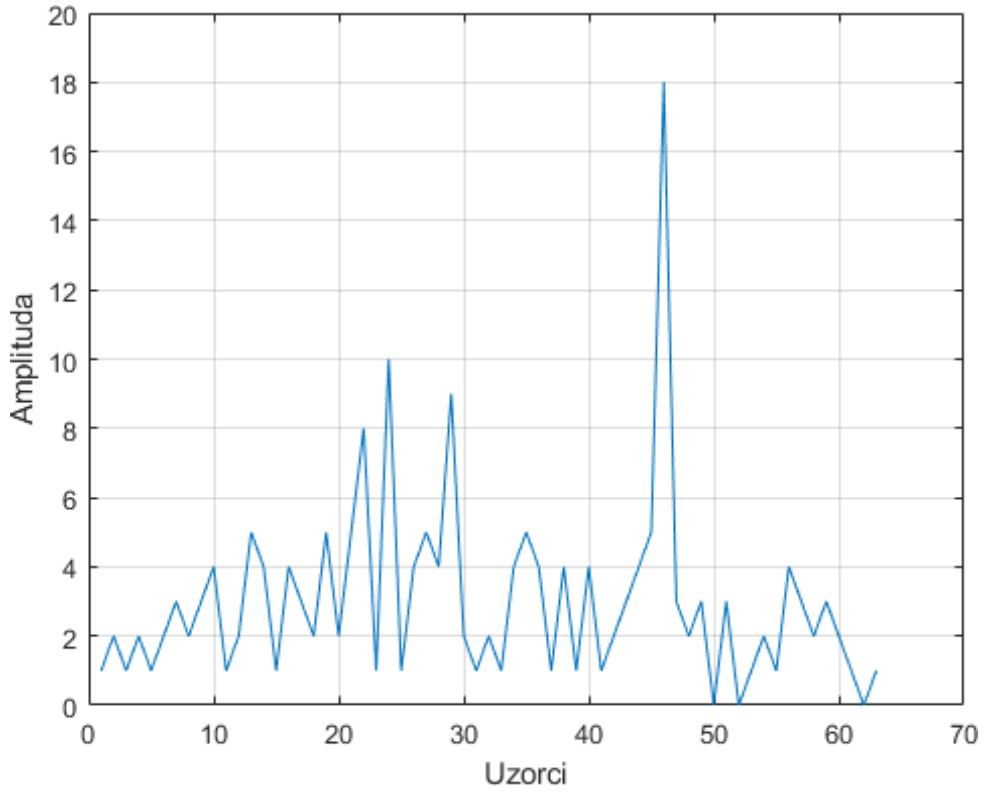


Slika 5.13: Izgled križnokorelacijske funkcije za sljedove generirane Čebiševljevim iteratorom

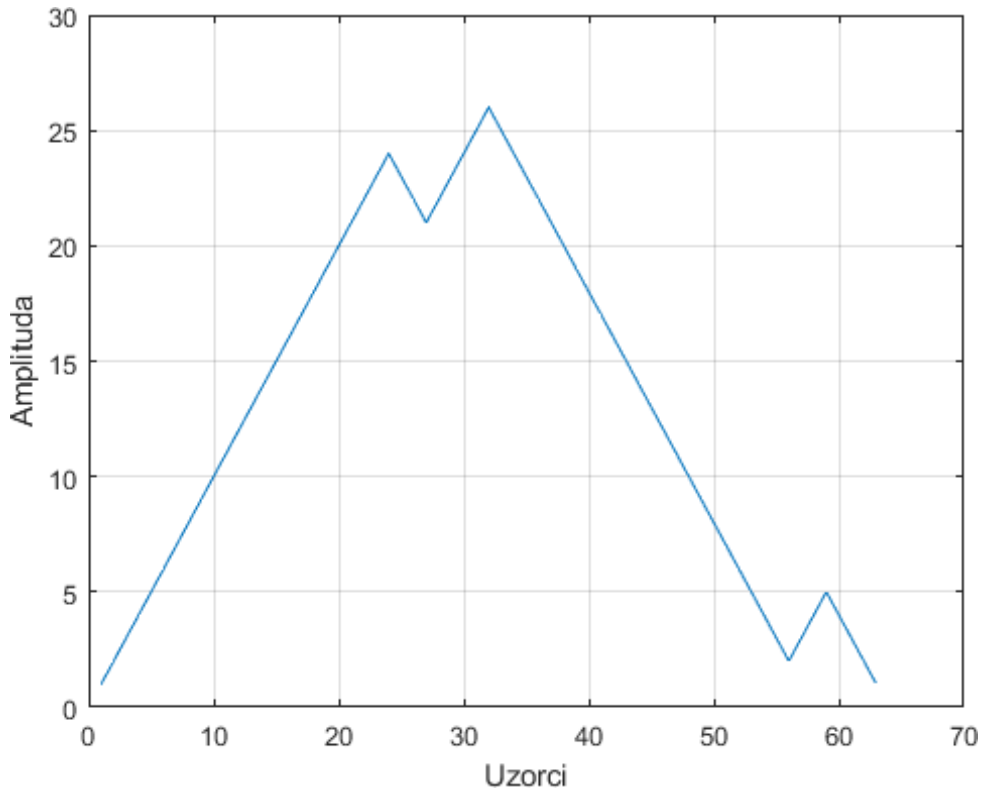
Evaluacijom sljedova s niskim *GF* u programski određenom modelu primjećeno je da se osjetljivost smanjila za oko 20 dB u odnosu na sljedove s visokim *GF*. Osjetljivost se promatrala kroz prag sinkronizacije slijeda, gdje je za sljedove s visokim *GF* postavljen prag od 0.05, dok je za sljedove s niskim *GF* postavljen na 0.001 kako bi se mogao provesti postupak sažimanja i demodulacije. Prag osjetljivosti predstavlja minimalnu vrijednost rezultata sinkronizacije slijeda prema jednadžbi 3.36. Podsustav za sinkronizaciju slijeda izveden je u LabView programskom alatu prema modelu na slici 3.7 pri čemu se koristi vrijednost *Sync Confidence Threshold* za određivanje minimalne razine praga sinkronizacije slijeda za proširenje. Usporedbom vrijednosti praga sinkronizacije pri kojima se slijed uspješno sinkronizira dobivena je razlika od 20 dB za sljedove s visokim i niskim *GF*. Smanjenje osjetljivosti slijeda direktno utječe na otpornost na šum pri čemu se otpornost na šum smanjuje.

U tablicama 5.1 i 5.2 uspoređeni su korelacijska svojstva generiranih sljedova u odnosu na Golayevo parametra. Tablica 5.1 prikazuje vrijednosti Golayevog parametra za prvi način generiranja kaotičnih sljedova. Promjenom parametra sustava μ u intervalu od 0 do 4, za svaki diskretni korak, generiran je slijed. Za svaki tako generirani slijed izračunat je Golayev parametar te su sljedovi s najvišim vrijednostima odabrani u poseban skup. Potom je određen srednji Golayev parametar za cijeli skup. Vrijednost Golayevog parametra usrednjena je na kvadrat duljine slijeda.

Može se vidjeti da svi kaotični sljedovi imaju značajno više vrijednosti Golayevog para-



Slika 5.14: Izgled križnokorelacijske funkcije za Gold sljedove



Slika 5.15: Izgled križnokorelacijske funkcije za sljedove generirane Čebiševljevim iteratorom uz nisku vrijednost *GF*

Tablica 5.1: Korelacijski parametri sljedova uz promjenjive parametare sustava

Sljedovi duljine 32		
Slijed	Srednji GF za cijeli skup	Maksimalni GF
Gold	1.1064	
Populacijski	5.0642	5.3333
Šatorsko krilo	5.2941	6.0952
Čebiševljev	6.7016	8
Sljedovi duljine 64		
Slijed	Srednji GF za cijeli skup	Maksimalni GF
Gold	1.2647	
Populacijski	3.2824	3.8788
Šatorsko krilo	2.8737	3.6312
Čebiševljev	3.8074	4.4138
Sljedovi duljine 128		
Slijed	Srednji GF za cijeli skup	Maksimalni GF
Gold	1.5729	
Populacijski	2.2313	2.441
Šatorsko krilo	2.1226	2.5536
Čebiševljev	2.6241	2.7601

metra te bi trebali pokazivati bolje performance u višekorisničkim sustavu. Kod generiranja maksimalna ostvariva vrijednost za kaotične sljedove je iznosila 8 te nije pronađen kaotični slijed s većim vrijednostima. Dodatnim istraživanjem te boljim algoritmom generiranja postoji mogućnost pronalaženja sljedova s boljim karakteristikama.

Kako se Golayev parametar povećava s promjenom parametra sustava μ, što se može vidjeti na slikama, drugi način generiranja sljedova je postavljanje parametra sustava μ na visoku vrijednost te promjenom početnog uvjeta $x_{0,k}$ generirati kaotične sljedove. Za svaku diskretnu vrijednost početnog uvjeta $x_{0,k}$ u intervalu od -1 do 1 generiran je zaseban slijed, odnosno postoji skup početnih vrijednosti $x_{0,k}$.

Ako je μ_c konstantna vrijednost parametra sustava odabrana analizom rezultata prethodnog načina generiranja sljedova, onda se diskretni kaotični signal za korak n može prikazati kao:

$$x_n = \mu_c F(x_{n-1}) \tag{5.12}$$

Tablica 5.2: Korelacijski parametri sljedova s visokom vrijednošću parametra sustava μ

Sljedovi duljine 32		
Slijed	Srednji GF za cijeli skup	Maksimalni GF
Gold	1.1064	
Populacijski	6.2634	7.1111
Šatorsko krilo	5.1598	6.4
Čebiševljev	6.7134	8
Sljedovi duljine 64		
Slijed	Srednji GF za cijeli skup	Maksimalni GF
Gold	1.2647	
Populacijski	3.7343	4.531
Šatorsko krilo	3.2579	3.6835
Čebiševljev	3.7353	4.3761
Sljedovi duljine 128		
Slijed	Srednji GF za cijeli skup	Maksimalni GF
Gold	1.5729	
Populacijski	2.5283	2.6563
Šatorsko krilo	2.3909	2.6392
Čebiševljev	2.5911	2.9008

gdje je F funkcija kaotičnog iteratora. U ovom slučaju sljedovi se generiraju tako da se za svaki slijed odabere različiti početni uvjet $x_{0,k}$:

$$x_{n,k} = \mu_c F^n(x_{0,k}) \tag{5.13}$$

gdje je F^n n-ta kompozicija funkcije F, a k je veličina skupa početnih uvjeta iz intervala $[-1 \quad 1]$. Odnosno ako se promatra prva vrijednost nakon početnog uvjeta:

$$x_{1,1} = \mu_c F(x_{0,1}),\ \ x_{1,2} = \mu_c F(x_{0,2}),\ \ \ldots,\ \ x_{1,k} = \mu_c F(x_{0,k}) \tag{5.14}$$

Na ovaj način se jedan kaotični signal iz skupa $x_{n,k}$ duljine n može prikazati kao:

$$x_{1,k} = \mu_c F(x_{0,k}),\ \ x_{2,k} = \mu_c F(x_{1,k}),\ \ \ldots,\ \ x_{n,k} = \mu_c F(x_{n-1,k}) \tag{5.15}$$

Iz skupa $[-1 \quad 1]$ odabire se k početnih vrijednosti koje se koriste kao ulaz u kaotični sustav s konstantnom vrijednošću parametra μ_c.

Za svaki slijed određen je Golayev parametar te srednja vrijednost Golayevog parametra za cijeli skup. Očekuje se da će s tim postupkom generirati optimalniji sljedovi za proširenje. Za svaki pojedini iterator određena je jedna vrijednost parametra sustava μ, tako je za populacijski iterator postavljena vrijednost $\mu = 3.995$, za iterator šatorsko krilo $\mu = 1.95$ dok je za Čebiševljev iterator postavljen $\mu = 4.995$.

U tablici 5.2 mogu se vidjeti rezultati drugog načina generiranja. Maksimalna vrijednost Golayevog parametra je 8, no pronađeni su i ostali sljedovi s višim vrijednostima što se može vidjeti u srednjem *GF* za cijeli skup sljedova. Srednji *GF* će rasti što je veći *GF* za pojedini generirani slijed u skupu. U tablici se može vidjeti da je moguće dodatno poboljšati karakteristike sljedova ovim načinom generiranja. Sljedovi i skupovi sljedova generirani na ovaj način pokazuju bolje korelacijska svojstva i bolje performance u sustavu programski određenog radija.

Poglavlje 6

Sinkronizacijske tehnike u radijskim komunikacijskim sustavima

Većina komunikacijskih sustava temelje se na digitalnim odnosno diskretnim tehnikama prijenosa. Fokus postupaka sinkronizacije stavlja se na metode u digitalnim komunikacijskim sustavima kod kojih je potrebno obnoviti vrijeme uzorkovanja, fazu i frekvenciju signala nositelja na uzorcima signala [75].

Kao osnovni uzorak za objašnjenje postupaka sinkronizacije uzima se modulirani signal. Signal moduliran PSK modulacijskim postupkom u pojasnom propusnom pojasu frekvencija može se prikazati kao [75]:

$$s(t) = Re\{\tilde{s}(t)e^{j2\pi f_c t}\} \tag{6.1}$$

gdje f_c označuje frekvenciju prijenosnog signala, a $\tilde{s}$ signal s kompleksnom anvelopom. Kod PSK modulacijskog postupka vrijedi da je

$$\tilde{s}(t) = \sum_i b_k g(t - iT) \tag{6.2}$$

gdje je $g(t)$ pravokutni impuls. Primljeni signal nakon prijenosa kanalom s kašnjenjem τ može se prikazati kao

$$\tilde{x}(t) = \tilde{s}(t - \tau) + n(t) \tag{6.3}$$

gdje je $n(t)$ iznos ukupnog signala smetnje u kanalu. Kako bi se modulirana informacija detektirala u signalu na prijenosnoj frekvenciji, signal se translatira (demodulira) na osnovni pojas frekvencija množenjem s lokalnim referentnim signalom frekvencije f_{cL} te propuštanjem kroz niskopropusni filtar. Lokalni referentni signal često nije u potpunosti istovjetan signalu nosiocu što se opisuje vrijednošću pomaka frekvencije nosioca $v = f_c - f_{cL}$. Primljeni signal se onda

može prikazati kao [75]:

$$r(t) = s(t) + n(t) \tag{6.4}$$

gdje je

$$s(t) = e^{j(2\pi vt+\Theta)}\tilde{s}(t-\tau) \tag{6.5}$$

U izrazu 6.5 $\Theta = -(2\pi f_c\tau + \phi_L)$ je iznos pomaka faze pa se $s(t)$ može prikazati kao

$$s(t) = e^{j(2\pi vt+\Theta)}\sum_i c_i g(t-iT+\tau) \tag{6.6}$$

Vidljivo je iz 6.6 da primljeni signal u osnovnom pojasu frekvencija ima nekoliko nepoznatih parametara: v, Θ i τ uz nepoznate simbole podataka. Procjena nepoznatih parametara ključna je za uspješnu detekciju simbola informacijskog signala što je zadaća sinkronizacije. Ako se $r(t)$ propusti kroz prilagođeni filtar bez provedene sinkronizacije izlaz iz filtra može se prikazati kao [75]:

$$x(t) = e^{j(2\pi vt+\Theta)}\sum_i c_i h(t-iT-\tau) + n(t) \tag{6.7}$$

gdje je $h(t) = g(t) * g(-t)$. Ako se $x(t)$ uzrokuje u trenutcima $kT+\tau$ na izlazu detektora dobivaju se diskretne vrijednosti primljenog signala [75]:

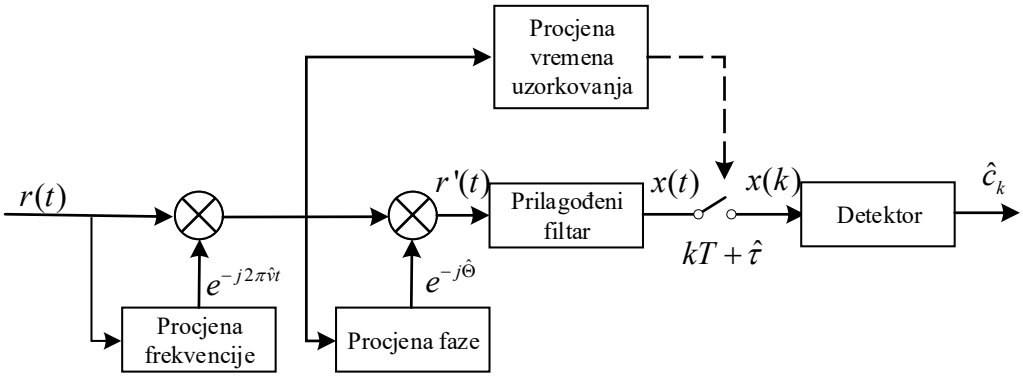
$$x(k) = c_k e^{j[2\pi v(kT+\tau)+\Theta]} + n(k) \tag{6.8}$$

Vidljivo je iz 6.8 da će parametri primljenog signala biti rotirani od optimalnog položaja te je potrebno napraviti procjenu nepoznatih vrijednosti frekvencije $\hat{v}$, faze $\hat{\Theta}$ i vremena uzorkovanja $\hat{\tau}$ [75].

Otklanjanje pogreške iznosa $e^{j(2\pi vt+\Theta)}$ obavlja se u dva koraka. Prvo se primljeni valni oblik množi s $e^{-j(2\pi\hat{v}t)}$, a potom se umnožak $r(t)e^{-j(2\pi\hat{v}t)}$ množi s $e^{-j\hat{\Theta}}$. Pretpostavlja se da pogreška frekvencije $v-\hat{v}$ je dovoljno mala da se kut $2\pi(v-\hat{v})+\Theta$ značajno ne mijenja u vremenu T_0 [75].

6.1 Procjena najvećom podudarnosti za diskretne signale

Digitalni komunikacijski sustavi koriste uzrokovane signale koji su uzimani u diskretnim vremenskim trenucima. Pretpostavlja se da je primljeni valni oblik prvo filtriran nisko propusnim filtrom $H(f)$ i potom uzorkovan frekvencijom uzorkovanja $1/T_s$. Niskopropusni filtar treba imati sljedeće karakteristike [75]:



Slika 6.1: Koherentni PSK prijamnik

- Filtar ima idealan pravokutni oblik

$$H(f) = \begin{cases} 1, & |f| \leq B_{LPF} \\ 0, & \text{inače.} \end{cases} \tag{6.9}$$

- Širina pojasa filtra je dovoljno velika za propuštanje svih komponenti signala bez izobličenja.
- Frekvencija uzorkovanja $1/T_s$ je dvostruko veća od širine pojasa filtra:

$$\frac{1}{T_s} = 2B_{LPF} \tag{6.10}$$

.

Ako se svi nepoznati parametri primljenog signala označe $\boldsymbol{\gamma}$, tada se izlaz filtra može prikazati kao [75]:

$$x(t) = s(t, \boldsymbol{\gamma}) + n(t) \tag{6.11}$$

Nakon uzimanja uzoraka u vremenskim trenucima kT_s dobiva se

$$x(kT_s) = s(kT_s, \boldsymbol{\gamma}) + n(kT_s) \tag{6.12}$$

gdje je $k = 0, 1, \ldots, L_0 - 1$. Neka je $\tilde{\boldsymbol{\gamma}}$ procijenjena vrijednost $\boldsymbol{\gamma}$, onda se 6.12 može zapisati kao

$$\boldsymbol{x}(kT_s) = s(kT_s, \tilde{\boldsymbol{\gamma}}) + n(kT_s) \tag{6.13}$$

Za procjenu nepoznatih parametara signala metodom najveće podudarnosti potrebno je pronaći

ekstrem funkcije gustoće vjerojatnosti [75]:

$$\begin{aligned} p(\boldsymbol{x}|\tilde{\boldsymbol{\gamma}}) &= \prod_{k=0}^{L_0-1} \frac{1}{2\pi N_0/T_s} \exp\left\{-\frac{|x(kT_s)-s(kT_s,\tilde{\boldsymbol{\gamma}})|^2}{2N_0/T_s}\right\} \\ &= C\exp\left\{-\frac{T_s}{2N_0}\sum_{k=0}^{L_0-1}|x(kT_s)-s(kT_s,\tilde{\boldsymbol{\gamma}})|^2\right\} \end{aligned} \tag{6.14}$$

gdje je

$$C = \left(\frac{T_s}{2\pi N_0}\right)^{L_0} \tag{6.15}$$

Funkcija gustoće vjerojatnosti u ovisnosti o općem parametru $\tilde{\boldsymbol{\lambda}}$, $p(\boldsymbol{x}|\tilde{\boldsymbol{\lambda}})$ dobiva se usrednjavanjem neželjenih parametara iz funkcije gustoće vjerojatnosti $p(\boldsymbol{x}|\tilde{\boldsymbol{\gamma}})$ [75]:

$$p(\boldsymbol{x}|\tilde{\boldsymbol{\lambda}}) = \int_{-\infty}^{\infty} p(\boldsymbol{x}|\tilde{\boldsymbol{\gamma}})p(\tilde{\boldsymbol{u}})d\tilde{\boldsymbol{u}} \tag{6.16}$$

Procjena najvećom podudarnosti vrijednosti $\boldsymbol{\lambda}$ može se dobiti maksimizacijom $p(\boldsymbol{x}|\tilde{\boldsymbol{\gamma}}$ [75]:

$$\tilde{\boldsymbol{\lambda}}_{ML}(x) = \arg\left\{\max_{\tilde{\lambda}}\{p(\boldsymbol{x}|\tilde{\boldsymbol{\lambda}}\}\right\} \tag{6.17}$$

Neka je skalirajući faktor

$$B = C\exp\left\{-\frac{T_s}{2N_0}\sum_{k=0}^{L_0-1}|x(kT_s)|^2\right\} \tag{6.18}$$

onda se fukncija podudarnosti može definirati kao

$$\begin{aligned} \Lambda(\boldsymbol{x}|\tilde{\boldsymbol{\gamma}}) &= \frac{1}{B}p(\boldsymbol{x}|\tilde{\boldsymbol{\gamma}}) \\ &= \exp\left\{\frac{T_s}{N_0}\sum_{k=0}^{L_0-1} Re\left[x(kT_s)s^*(kT_s,\tilde{\boldsymbol{\gamma}})\right] - \frac{T_s}{2N_0}\sum_{k=0}^{L_0-1}|s(kT_s,\tilde{\boldsymbol{\gamma}})|^2\right\} \end{aligned} \tag{6.19}$$

Procjena najvećom podudarnosti za nepoznati opći parametar $\tilde{\boldsymbol{\gamma}}$ dobiva se kao [75]:

$$\tilde{\boldsymbol{\lambda}}_{ML}(x) = \arg\left\{\max_{\tilde{\lambda}}\{\Lambda(\boldsymbol{x}|\tilde{\boldsymbol{\lambda}})\}\right\} \tag{6.20}$$

6.2 Procjena frekvencije nosioca korištenjem poznatih referentnih simbola

Korištenjem poznatih referentnih podataka ili simbola unutar poslanih podataka moguće je napraviti procjenu frekvencije signala nosioca. Referentni simboli najčešće se prenose u zaglavlju

paketa ili u zasebnom sinkronizacijskom kanalu. Pretpostavka je da se radi o uzorkovanim odnosno diskretnim vrijednostima signala na prijamniku te da je vrijeme uzorkovanja poznato, odnosno koristi se izraz za procjenu metodom najveće podudarnosti 6.20 za nepoznatu frekvenciju [75]:

$$\Gamma(\tilde{v}) = \left| \sum_{k=0}^{L_0-1} c_k^* x(k) \right| \tag{6.21}$$

gdje je $\Gamma(v)$ procjena frekvencije, c_k PSK modulirani signal, a $x_(k)$ uzorkovani signal na izlazu prilagođenog filtra.

6.2.1 Praktične izvedbe procjenitelja frekvencije

Neka je $y(k)$ uzorkovani primljeni signal nakon filtriranja prilagođenim filtrom oblika [75]:

$$y(k) = c_k e^{j[2\pi v(kT+\tau)+\Theta]} + n(k) \tag{6.22}$$

gdje je c_k PSK modulirani signal, a $n(k)$ uzorci bijelog šuma iz kanala. Može se vidjeti iz 6.22 da procjena primljenog signala ovisi o c_k,τ i Θ. Korištenjem svojstva PSK modulacijskog postupka $c_k c_k^* = 1$, moguće je ukloniti ovisnost primljenog signala o modulaciji, odnosno usrednjiti informacijski signal [75]. Ako se 6.22 pomnoži s c_k^* i označi $z(k) = y(k)c_k^*$ dobiva se

$$z(k) = e^{j[2\pi v(kT+\tau)+\Theta]} + n^{'}(k) \tag{6.23}$$

Neka je $R(m)$ autokorelacija vrijednosti $z(k)$ dana kao

$$R(m) = \frac{1}{L_0 - m} \sum_{k=m}^{L_0-1} z(k) z^*(k-m), \quad 1 \leq m \leq L_0 - 1 \tag{6.24}$$

uvrštavanjem 6.24 u 6.23 dobiva se

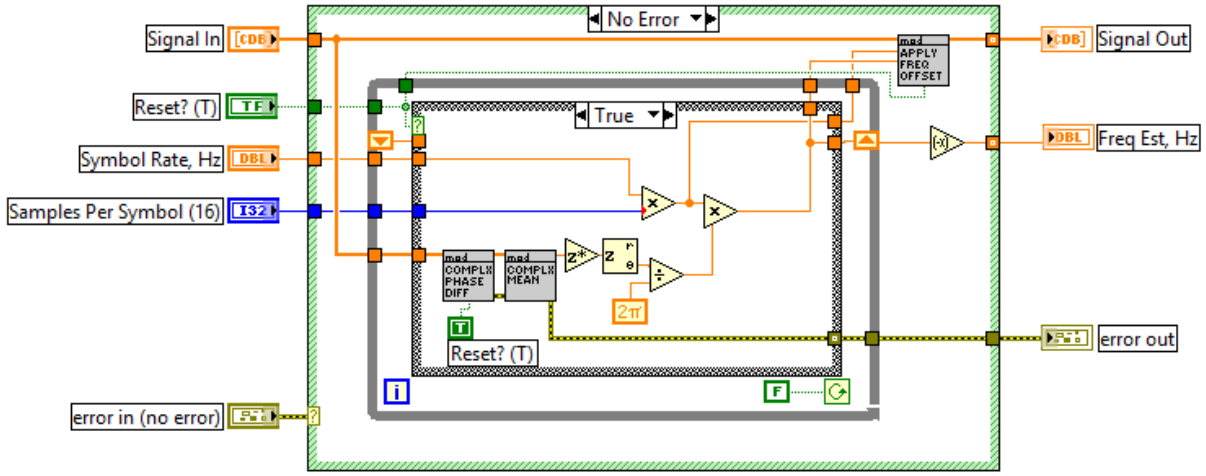
$$R(m) = e^{j2\pi mvT} + n''(m), \quad 1 \leq m \leq L_0 - 1 \tag{6.25}$$

Ako se označi razlika

$$e(m) = \arg\{R(m)\} - 2\pi mvT \tag{6.26}$$

može se pretpostaviti da je vektor pogreške $e(m)$ mali za visoke omjere signala i šuma. Ako se m ograniči na $1 \leq m \leq N$ gdje je

$$N < \frac{1}{2|v_{max}T|} \tag{6.27}$$



Slika 6.2: Procjena frekvencije nosioca izvedena za programski određeni radio

a v_{max} interval nepouzdanosti v onda se dobiva

$$\frac{1}{N}\sum_{m=1}^{N} e(m) = \frac{1}{N}\sum_{m=1}^{N} \arg\{R(m)\} - \pi(N+1)vT \tag{6.28}$$

Ako se desna strana 6.28 izjednači s nulom i riješi po varijabli v dobiva se Fitzov izraz za procjenu

$$\hat{v} = \frac{1}{\pi N(N+1)T}\sum_{m=1}^{N} \arg\{R(m)\} \tag{6.29}$$

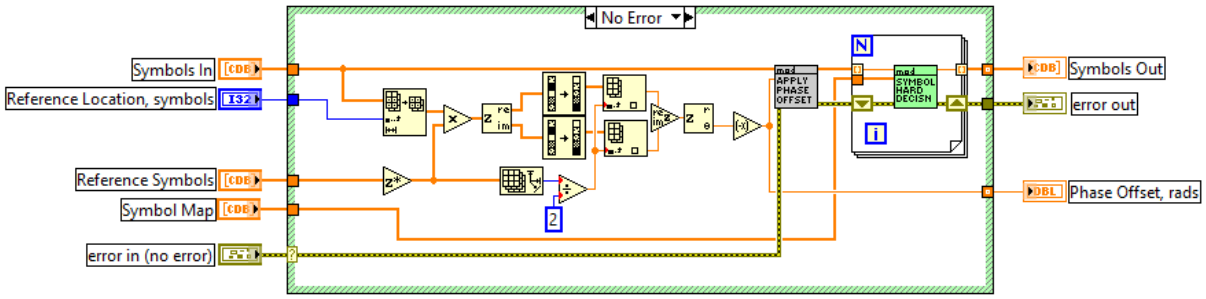
Fitzov procjenitelj 6.29 omogućuje jednostavnu izvedbu procjene frekvencije uzorkovanog nositelja i koristi se za grubu i finu procjenu frekvencije u sustavu korištenom u ovom radu. Točnost procjenitelja se smanjuje kako se smanjuje količina dostupnih uzoraka za procjenu no sama izvedba ne zahtijeva veliko zauzeće resursa. Usporedbe raznih procjenitelja i dodatnih praktičnih izvedbi procjenitelja frekvencije mogu se pronaći u [75].

6.3 Procjena faze nosioca korištenjem poznatih referentnih simbola

Kao i kod procjene frekvencije, procjena faze nosioca koristi metodu najveće podudarnosti. Za procjenu faze nosioca pretpostavlja se da je obavljena procjena frekvencije nosioca.

Kompleksna ovojnica primljenog signala može se prikazati kao [75]:

$$x(t) = s(t) + n(t) \tag{6.30}$$



Slika 6.3: Procjena faze u modelu za programski određeni radio

gdje je

$$s(t) = e^{j(2\pi vt+\Theta)} \sum_i c_i g(t - iT - \tau) \tag{6.31}$$

a $n(t)$ je bijeli šum. Parametar v označuje pomak frekvencije, Θ pomak faze nosioca koji se procjenjuje, a T je vrijeme uzimanja uzoraka. Niz c_i predstavlja informacijske simbole, T je period simbola, a $g(t)$ oblik impulsa modulacijskog postupka.

Nepoznata faza Θ je konstanta iz intervala $\pm\pi$. Svi drugi parametri v, τ i c_i se pretpostavlja da su poznati prijamniku. U ovom slučaju c_i su poznati referentni simboli u preambuli koji se koriste za sinkronizaciju.

Procjena Θ metodom najveće podudarnosti izvodi se iz funkcije vjerojatnosti [75]:

$$\Lambda(r|\tilde{\Theta}) = \exp\left\{ \frac{1}{N_0} \int_0^{T_0} Re\left\{x(t)\tilde{s}^*(t)\right\} dt - \frac{1}{2N_0} \int_0^{T_0} |\tilde{s}(t)|^2 dt \right\} \tag{6.32}$$

gdje je $\tilde{s}(t)$ poznati referentni signal. Provođenjem metode najveće podudarnosti dobiva se [75]:

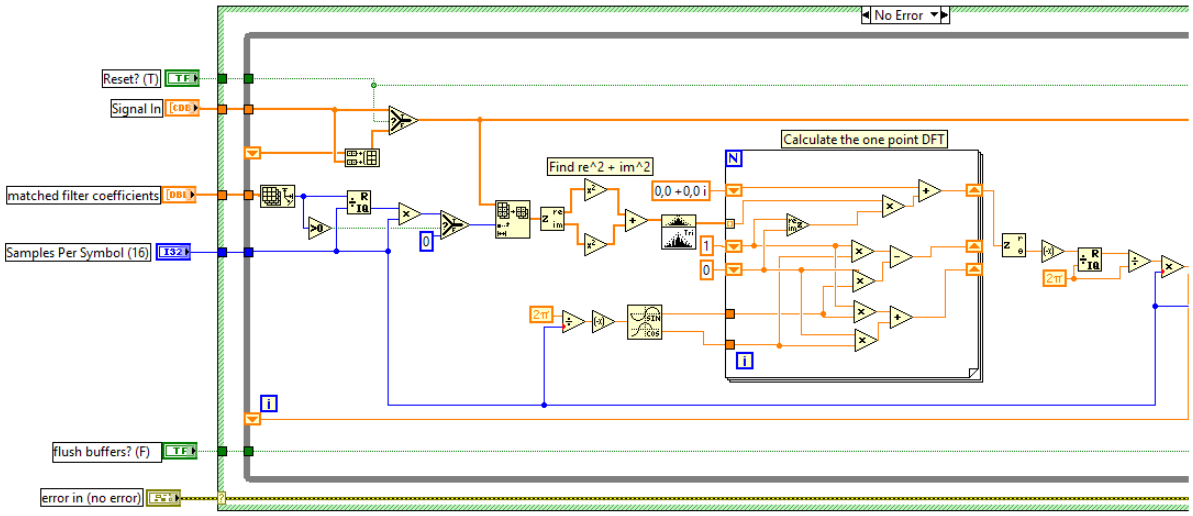
$$\hat{\Theta} = \arg\left\{ \sum_{k=0}^{L_0-1} c_k^* x(k) \right\} \tag{6.33}$$

gdje je $L_0 = T_0/T$ duljina intervala procjene, $x(k)$ uzorak primljenog signala nepoznate faze u trenutku $t = kT + \tau$, a $c(k)$ poznati referentni simboli.

6.4 Sinkronizacija takta uzorkovanja

U digitalnim komunikacijskim sustavima, izlaz demodulatora se mora uzorkovati taktom u točnom trenutcima $t_m = mT + \tau$ gdje je T vrijeme trajanja simbola, a τ je kašnjenje zbog konačnog vremena propagacije od odašiljača do prijamnika. Prijamnik mora poznavati takt uzorkovanja signala T kao i točno mjesto na kojem će uzimati uzorke signala [76].

Procjenitelj takta uzorkovanja opisan u [77] moguće je izvesti u digitalnoj tehnici na uzor-



Slika 6.4: Procjena takta uzorkovanja u modelu za programski određeni radio

kovanim signalima. Signal

$$x_k = \left| \sum_{n=-\infty}^{\infty} a_n g(\frac{kT}{N} - nT - \varepsilon T) + \tilde{n}(\frac{kT}{N}) \right|^2 \tag{6.34}$$

gdje je $x(t) = g_T(t) g_R(t)$ predstavlja uzorke filtriranog primljenog signala. Može se vidjeti da uzorci ulaznog signala imaju osnovni harmonik na $1/T$ te se može razviti u Fourierov red kao [77]:

$$X_m = \sum_{k-mLN}^{(m+1)LN-1} x_k e^{-j2\pi k/N} \tag{6.35}$$

te se može dobiti procjena normalizirane faze kao

$$\hat{\varepsilon}_m = \frac{-1}{2\pi} \arg(X_m) \tag{6.36}$$

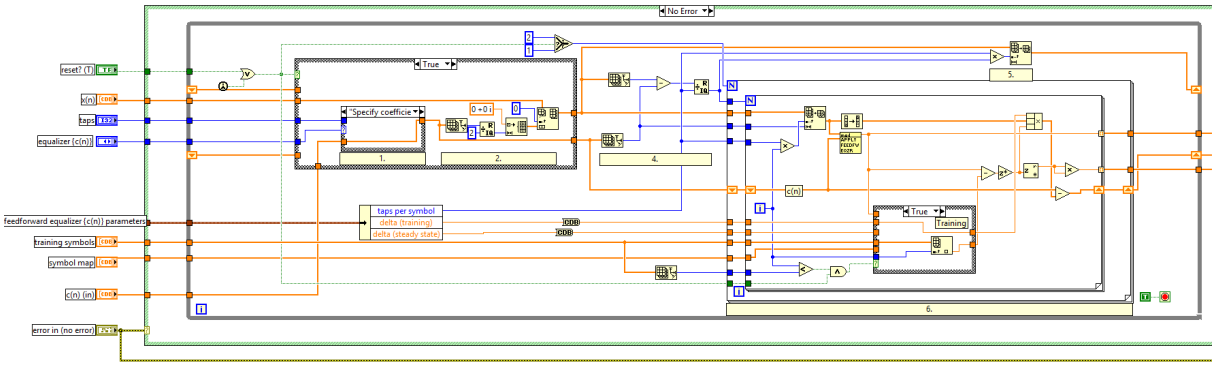
Ako se pretpostavi da je detektor neki općeniti prilagođeni filtar, odnosno da vrijedi $g_R(t) = g_T^*(-t + \alpha T)$ može se dobiti da je optimalan trenutak uzimanja uzoraka

$$t_{opt,n} = nT + \varepsilon T + \alpha T \tag{6.37}$$

odnosno da je za uzorak n optimalan pomak uzimanja uzoraka $(\varepsilon + \alpha)T$.

6.5 Procjena kanala

Procjena kanala je metoda digitalne obrade signala u prijamniku koja smanjuje interfernciju među simbolima uzrokovanu višestaznim širenjem signala od odašiljača do prijamnika. Sklopovi za izjednačavanje koriste poznati niz referentnih simbola kako bi odredili odziv kanala.



Slika 6.5: Procjena kanala u modelu za programski određeni radio

Sustav za izjednačavanje ima oblik inverznog filtra odziva kanala. U stvarnim prijamnicima nije moguće u potpounosti ukloniti utjecaj šuma, inferferencije i izobličenja signal te uvijek postoji rezidualna interferencija među simbolima [78].

Postoji mnogo izvedbi sustava za izjednačavanje no najčešći su linearni sustavi za izjednačavanje koji koriste tehniku srednje kvadratne pogreške za procjenu kanala. Takvi se sklopovi za izjednačavanje jednostavno izvode u digitalnoj obradi signala korištenjem filtera s konačnim impulsnim odzivom FIR (eng. *Finite Impulse Response*). U takvoj strukturi za izjednačavanje, trenutne i prošle vrijednosti primljenog signala se linearno ponderiraju koeficijentima filtera i zbrajaju kako bi se dobile vrijednosti na izlazu [78]:

$$\hat{d}_k = \sum_{n=-N_1}^{N_2} (c_n^*) y_{k-n} \tag{6.38}$$

gdje su c_n^* kompleksne vrijednosti koeficijenata filtera, $\hat{d}_k$ je izlaz filtera za uzorak k, y_i je primljeni signal u trenutku $t_0 + iT$, a $N = N_1 + N_2 + 1$ je broj koefcijenata filtera.

Signal pogreške b_k za uzorak k se može prikazati kao [78]:

$$\begin{aligned} b_n(k) &= y(k-n) - \sum_{i=1}^{n} K_i y(k-n+i) \\ &= b_{n-1}(k-1) + K_{n-1} f_{n-1}(k) \end{aligned} \tag{6.39}$$

Signal pogreške se u sljedećem koraku koristi za izračunavanje koeficijenata filtera.

Korištenjem adaptivnog algoritma za računanje srednje kvadratne pogreške dobiva se pogreška u procjeni [78]:

$$e_k = d_k - \hat{d}_k = x_k - \hat{d}_k \tag{6.40}$$

Srednja kvadratna pogreška dobiva se kao

$$|e_k|^2 = e_k^* e_k \tag{6.41}$$

Poglavlje 7

Mjerni postav sustava i evaluacija performanci

Performance komunikacijskog sustava u programski određenom modelu u ovom radu određuju se korištenjem virtualnih instrumenata i potprograma u LabView programskom alatu. U LabView alatu moguće je mjeriti performance sinkronizacije kao i učestalost pogreške bita u primljenom i demoduliranom signalu.

Odašiljački i prijamni uređaj programski određenog radija spojeni su i postavljeni u primopredajni sustav kao na slici 7.1. Uređaji su spojeni koaksijalnim kabelom te posebnim serijskim kabelom kojim se razmjenjuju upravljačke informacije i omogućuje komunikacija s računalom bez potrebe spajanja drugog kabela za lokalnu mrežu. Kabel kojim su spojeni USRP uređaji je serijski SCSI kabel s brzinom prijenosa od 6 Gb/s.

Model uređaja USRP 2920 predstavlja odašiljački uređaj dok je USRP 2932 prijamni uređaj. Sami USRP uređaji su univerzalni te je njihov rad određen programom u LabView programskom alatu. Model USRP 2932 odabran je kao prijamni uređaj zbog dodatnih modula koji omogućuju stabilniji rad lokalnog oscilatora korištenjem GPS reference. Korištenjem GPS reference za lokalni oscilator dobiva se točnost oscilatora od 10 ppb (dijelova na milijardu eng. *parts per billion*). Spajanjem uređaja serijskim kabelom omogućuje se bolja sinkronizacija i stabilnost odašiljačkog i prijamnog lokalnog oscilatora kako bi se smanjile greške uslijed pomaka frekvencije lokalnih oscilatora. Usporedba specifikacija uređaja programski određenog radija može se vidjeti u tablici 7.1. Kao što se može vidjeti u tablici 7.1, USRP uređaji daju različitu izlaznu snagu koja nije normirana ni umjerena te je potrebno dodatno mjerenje snage kako bi se utvrdile referentne vrijednosti.

Iz tablice 7.1 se može vidjeti da USRP uređaji, ovisno o modelu, rade na različitim frekvencijskim pojasevima. Kako bi se izbjegla potencijalna interferencija s drugim sustavima, za radnu frekvenciju sustava programski određenog radija odabrana je frekvencija 868 MHz. Područje frekvencija oko 868 MHz dodijeljeno je upravo za radijske sustave kratkog dometa i



Slika 7.1: Primopredajni sustav programski određenih radija

Tablica 7.1: Usporedba specifikacija uređaja programski određenog radija

	USRP 2920	USRP 2932
Opseg frekvencija	od 20 MHz do 2.2 GHz	od 400 MHz do 4.4 GHz
Maksimalna izlazna snaga odašiljača	od 17 dBm do 20 dBm	od 17 dBm do 20 dBm
Maksimalna stvarna širina pojasa	20 MHz	20 MHz
Digitalno analogni pretvarač	2 kanala, 400 MS/s, 16 bit	2 kanala, 400 MS/s, 16 bit
Analogno digitalni pretvarač	2 kanala, 100 MS/s, 14 bit	2 kanala, 100 MS/s, 14 bit
SFDR	80 dB	80 dB
Maksimalna dozvoljena ulazna snaga	0 dBm	0 dBm
Točnost frekvencije	2.5 ppm	25 ppb (bez GPS), 10 ppb (s GPS)

senzorske radijske mreže te nije potrebna posebna dozvola za korištenje.

Korištena širina pojasa je 1 MHz što u pojasu frekvencija oko 868 MHz nije predviđeno originalnom normom. Širina pojasa od 1 MHz je korištena zbog jednostavnijeg mjerenja snage primljenog signala kao i ostalih parametara. Sama širina pojasa može se jednostavno mijenjati u LabView programu za programski određeni radio. Stvarna širina pojasa povezana je i s brzinom uzorkovanja pri analogno digitalnoj i digitalnoj analognoj pretvorbi u samim USRP uređajima. Ako se uzme brzina uzorkovanja od $1 \cdot 10^6$ uzoraka (1 MS/s eng. MS *Mega Sample*) dobiva se širina pojasa od 1 MHz. Širina iskorištenog pojasa ovisi i o upotrijebljenom slijedu

za proširenje i trajanju *čipa* slijeda za proširenje pojasa kao i broju uzoraka pri naduzorkovanju u PSK modulacijskom postupku. Kako bi se signal uspješno prenio, pri modulaciji u LabView programu, podaci se naduzorkuju s određenim brojem uzoraka. Najčešće se uzima 16 uzoraka po jednom PSK moduliranom simbolu te pri brzini simbola od 62500 Bd dobiva se 1 MS/s na izlazu modulatora.

Prijamni uređaj kao i demodulator moraju imati iste postavke frekvencije uzorkovanja te brzine prijenosa simbola. Prijamni uređaj poduzorkuje signal u odnosu na postavljen broj uzoraka te frekvenciju uzorkovanja. Demodulator koristi broj uzoraka u svakom simbolu kako bi detektirao modulirane simbole te uspješno detektirao informaciju sadržanu u moduliranom signalu.

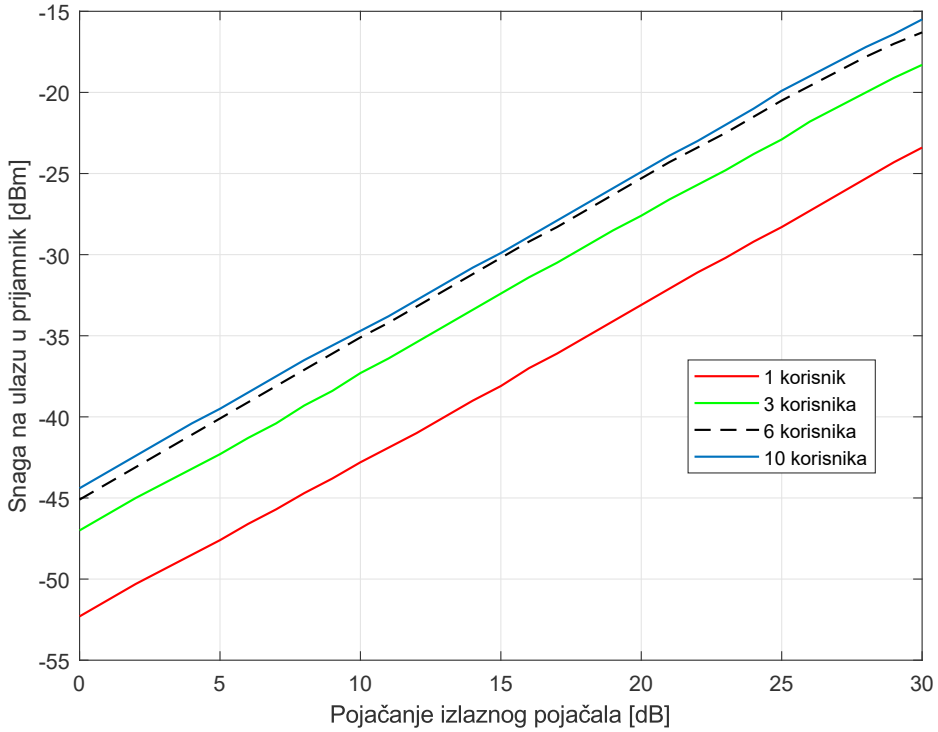
Nakon provedene demodulacije i sinkronizacije mjere se i uspoređuju performance sustava. Osnovna mjera performanci i kvalitete prijenosa u komunikacijskim sustavima jest učestalost pogreške bita BER (eng. *Bit Error Rate*). Učestalost pogreške bita određuje se kao broj pogrešno prenesenih i primljenih bitova u odnosu na ukupan broj primljenih bitova. Pri evaluaciji modela u ovom radu učestalost pogreške bita određuje se u odnosu na $1 \cdot 10^8$ ukupno primljenih bitova.

Podaci iz primljenog okvira, nakon provedenog pronalaženja početka okvira korištenjem referentnih simbola u preambuli, uspoređuju se s poslanim podacima. S obzirom na to da se koristi isto računalo za odašiljanje i primanje, poslani podaci su odmah dostupni na računalu za usporedbu. U protivnom se za izračun učestalosti pogreške bita može koristiti podatak iz bloka za provjeru cikličke pogreške CRC (eng. *Cyclic Redundancy Check*). Pri direktnoj provjeri podataka primljeni bitovi i poslani bitovi uspoređuju korištenjem logičke funkcije ekskluzivno ili (XOR). Nakon što se napravi XOR operacija nad bitovima, izlaz XOR funkcije je niz nula i jedinica. Jedinice predstavljaju indeks bita koji je pogrešno prenesen. Zbrajanjem jedinica u izlazu XOR funkcije i dijeljenjem s brojem ukupno prenesenih bitova direktno se dobiva učestalost pogreške bita.

7.1 Mjerenje snage USRP platforme

USRP platforma omogućuje jednostavan razvoj programski određenih radijskih sustava. Glavni nedostatak te platforme jest nedostatak jasne reference za procjenu performanci radijskih sustava. Izlazna odašiljačka snaga može se mijenjati korištenjem izlaznog pojačala u koracima od 0,5 dB, no sama referentna razina nije poznata i može se razlikovati među uređajima bez obzira što su uređaji iste oznake. Zbog toga se dio rezultata u ovom radu evaluira u odnosu na broj korisnika u sustavu. Kako bi se dobile performance u odnosu na snagu signala, izvršena su mjerenja signala na ulazu u prijamnik programski određenog radija.

Analizatorom spektra mjerena je srednja snaga signala na ulazu u prijamnik u pojasu od 1



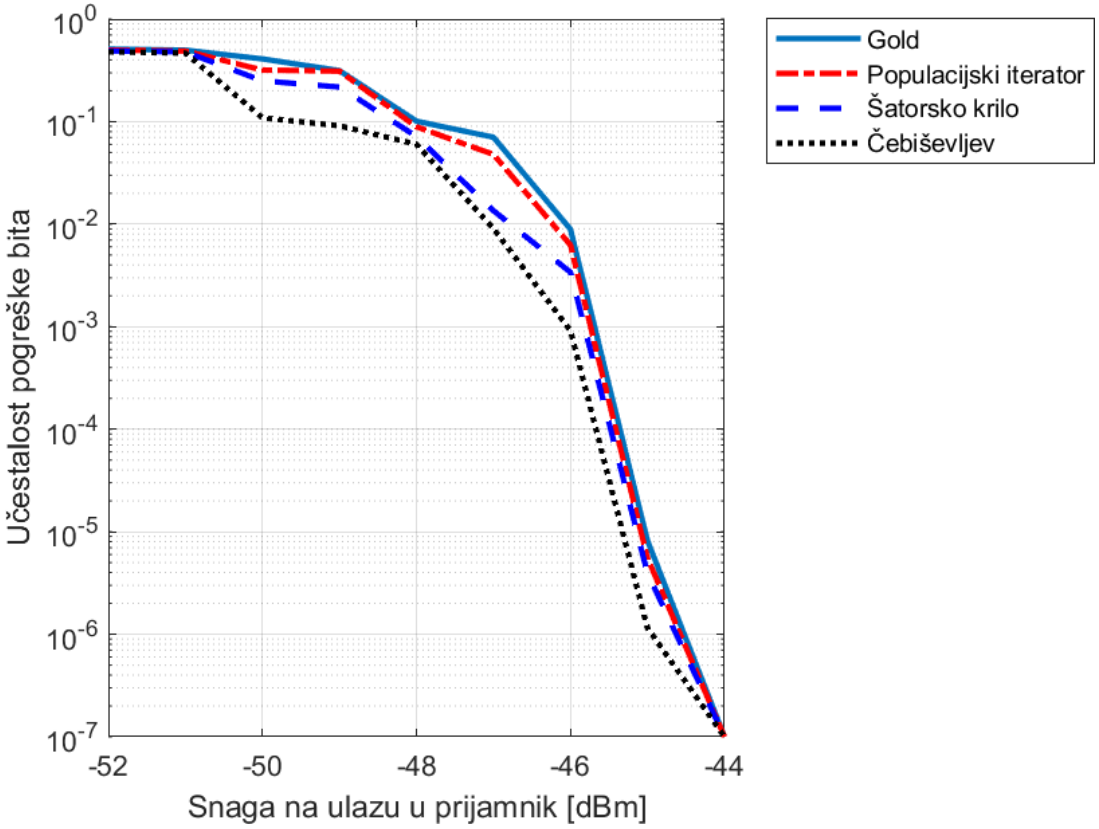
Slika 7.2: Ovisnost snage na prijamniku u odnosu na pojačanje izlaznog pojačala

MHz za različite vrijednosti pojačanja odašiljačkog pojačala. Pojačanje odašiljačkog pojačala mijenjalo se u koracima od 1 dB. S obzirom na to da se koristi tehnika prijenosa korištenjem proširenog spektra te višestruki pristup po kodu, srednja snaga signala ovisit će o broju korisnika odnosno sljedova. Isto tako snaga može ovisiti i o vrsti i duljini sljeda za proširenje te je potrebno izmjeriti snagu za sve duljine sljedova kao i vrste sljedova. Mjerenja su potrebna kako bi se definirao raspon pojačanja odnosno snaga kao referenca za evaluaciju performanci svih sljedova. Rezultati mjerenja snage na ulazu u prijamnik za različit broj korisnika mogu se vidjeti na slici.

Na slici 7.2 može se vidjeti da se snaga relativno pravilno mijenja s porastom pojačanja odašiljačkog pojačala. Isti princip mjerenja proveden je i za ostale duljine i vrste sljedova. Može se primijetiti povećanje snage pri povećanju broja korisnika što je karakteristično za sustave s višestrukim pristupom po kodu.

7.2 Učestalost pogreške bita u odnosu na prijamnu snagu

U radijskim komunikacijskim sustavima kao referenca za evaluaciju performanci koristi se omjer signal šum, energije bita i gustoće snage šuma ili neka slična mjera koja je povezana s energijom ili snagom signala. S obzirom na to da USRP platforma nije umjerena te da nije poznata referentna snaga, za evaluaciju performanci koristit će se izmjerena snaga moduliranog

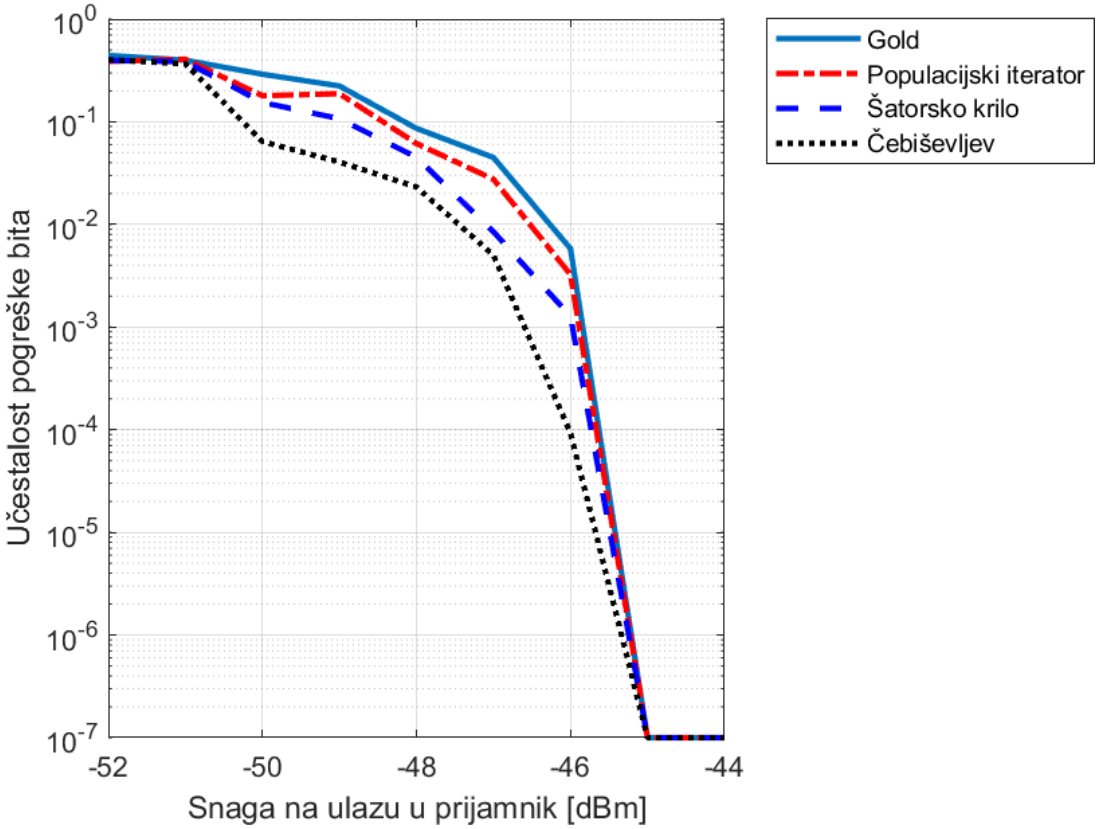


Slika 7.3: Učestalost pogreške bita u odnosu na snagu na ulazu u prijamnik za sljedove duljine 32

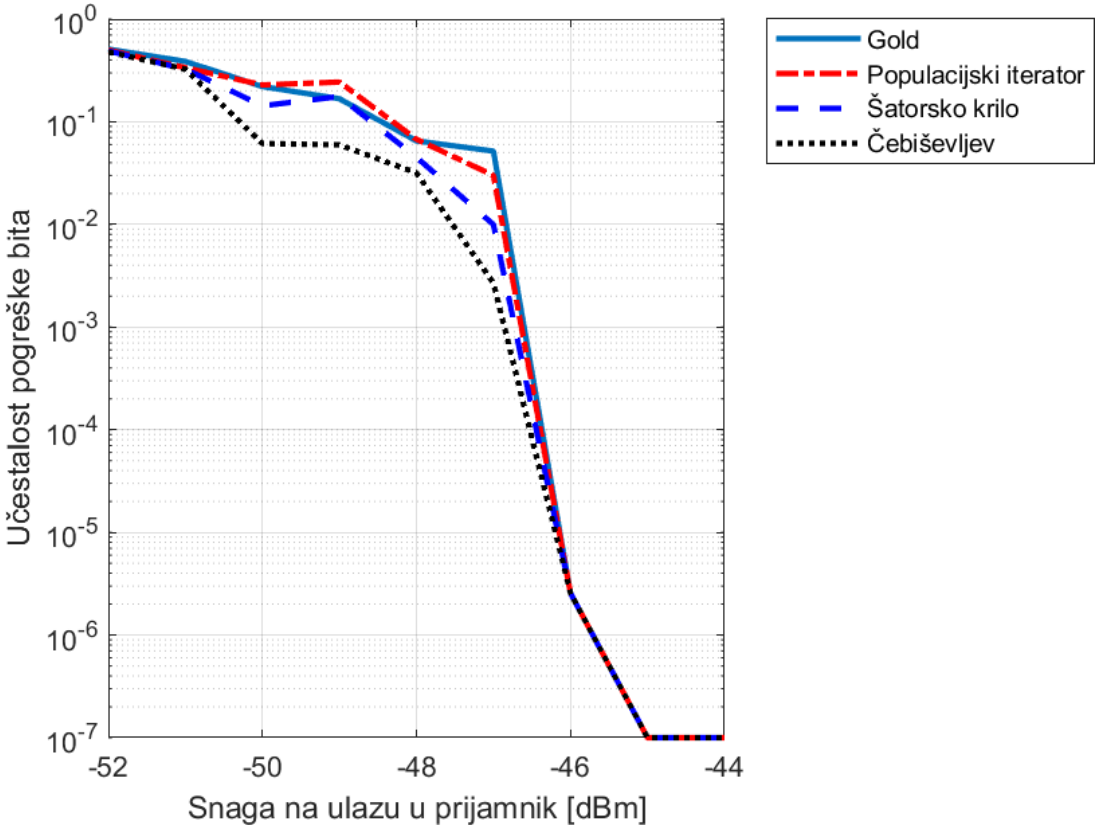
signala opisana u prethodnom dijelu. Snaga signala u ulazu u prijamnik relativno pravilno se mijenja promjenom pojačanja odašiljačkog pojačala što će koristiti kako bi se evaluirale performance za različite snage signala.

Na slikama 7.3, 7.4 i 7.5 mogu se usporediti performance modela u odnosu na različitu snagu na ulazu u prijamnik. Snaga se mijenjala promjenom pojačanja odašiljačkog pojačala te se određivala učestalost pogreške bita u sustavu s jednim korisnikom. Za ovaj slučaj je isključena sinkronizacija sljedova u odnosu na zadani prag sinkronizacije. Pri uključenom pragu sinkronizacije, demodulacija se provodi tek nakon uspješno sinkroniziranog slijeda za proširenje. Sinkronizacija slijeda za proširenje u odnosu na prag može se uspješno provesti i na nižim razinama signala što onemogućuje direktnu usporedbu performanci u odnosu na snagu jer se sinkronizacija postiže za veliki raspon prijamne snage.

Slike 7.3, 7.4 i 7.5 pokazuju da kaotični sljedovi imaju bolje performance u odnosu na Gold sljedove te da kaotični sljedovi s višim Golayevim faktorom pokazuju bolje performance. Razlika u performancama između različitih kaotičnih sljedova ovisi o Golayevom faktoru slijeda. Slijed s najvišim Golayevim faktorom je kaotični slijed generiran Čebiševljevim iteratorom te on pokazuje najbolje performance u cijelom sustavu. Kaotični sljedovi generirani populacijskim iteratorom i iteratorom oblika šatorskog krila pokazuju performance koje su vrlo slične Gold sljedovima. Pri isključenoj sinkronizaciji slijeda ne mogu se iskoristiti dobra autokorela-



Slika 7.4: Učestalost pogreške bita u odnosu na snagu na ulazu u prijamnik za sljedove duljine 64



Slika 7.5: Učestalost pogreške bita u odnosu na snagu na ulazu u prijamnik za sljedove duljine 128

cijska svojstva.

Vidljivo je da na nižim razinama signala sustav vrlo brzo postaje neupotrebljiv za prijenos podataka. To je očekivano ponašanje jer razine korisnog signala padaju na razine šuma u kanalu te sažimanje spektra i demodulacija ne mogu rekonstruirati stvarne podatke. S obzirom na to da se koristi paketski prijenos gdje su i sinkronizacijski podaci za PSK demodulaciju sadržani u zaglavlju paketa, netočnom rekonstrukcijom podatka povećavaju se i pogreške sinkronizacije. Sam odnos učestalosti pogreške bita i snage signala ovise o korištenom sklopovlju. USRP platforma programski određenog radija nema umjerene odašiljačke snage u odnosu na neku referencu te je potrebno za svaki sustav provesti mjerenja. Korištenjem nekih drugih modela uređaja programski određenog radija mogle bi se ostvariti bolje performance.

7.3 Učestalost pogreške bita u višekorisničkom okruženju

Norma prema kojoj je modeliran sustav koristi se za senzorske mreže. Takve mreže imaju veliki broj čvorova koji odašilju u različitim vremenskim trenutcima. Kako bi se evaluirali kaotični sljedovi u odnosu na Gold sljedove u takvom sustavu, model za programski određeni radio prilagođen je za simulaciju višekorisničkog okruženja.

Kako bi se simuliralo višekorisničko okruženje, program modulatora i demodulatora izvodi se za svakog korisnika ili uređaj zasebno. S obzirom da se radi o sustavu na arhitekturi programskog određenog radija, povećanje primopredajnih elemenata obavlja se kopiranjem programa za modulator i demodulator te se dobiva paralelni slijed modulatora i demodulatora u ovisnosti o broju uređaja ili korisnika u sustavu. Za evaluaciju performanci u ovom radu, koristit će se sustav koji se skalira od 1 do 10 korisnika.

Svaki primopredajni put ima svoje postavke i ulazne podatke kojim se ostvaruje višestruki pristup. U slučaju modela u ovom radu mijenjaju se podaci koji svaki korisnik ili uređaj šalje te slijed za proširenje pojasa. Korištenjem odvojenih sljedova za proširenje pojasa za svakog korisnika dobiva se sustav s višestrukim pristupom po slijedu (kodu) CDMA (eng. *Code Division Multiple Access*). U takvom sustavu podaci svih korisnika ili uređaja prenose se istovremeno i na istoj frekvenciji. Podaci su u kanalu odvojeni dodatnim modulacijskih korakom pri kojem se množe s točno određenim slijedom za proširenje.

Kako se u CDMA načinu pristupa u isto vrijeme šalju podaci svih korisnika, potrebno je imati sljedove za proširenje pojasa koji imaju dobra križnokorelacijska svojstva kako bi se, na prijamniku, mogli uspješno odvojiti i detektirati tokovi podataka svakog korisnika.

Očekivano je da će se povećanjem broja korisnika povećati i mogućnost pogrešnog prijenosa zbog povećanja broja prostora u kojima može doći do križne korelacije različitih tokova podataka.

Performance kaotičnih sljedova za proširenje pojasa koji su generirani različitim kaotičnim

sustavima uspoređuju se s Gold sljedovima koji se koriste u normi. Performance se uspoređuju za nekoliko duljina slijeda za proširenje pojasa kao i različitih duljina sinkronizacijskog zaglavlja. Isto tako se uspoređuju performance za različite načine generiranja optimiranih kaotičnih sljedova.

Na slikama 7.6, 7.7 i 7.8 prikazani su početne performance programski određenog sustava prije nego je provedeno optimiranje kaotičnih sljedova. Slike i rezultati preuzeti su iz [74]. Može se vidjeti da su i neoptimirani kaotični sljedovi pokazivali dobre performance usporedive s Walsh ortogonalnim sljedovima. Proširenjem rezultata rada [74] došlo se do optimiranih kaotičnih sljedova te poboljšanja rada modela na programski određenom radiju.

Posebno se vidi poboljšanje za sljedove generirane populacijskim iteratorom (oznake *quad* ili *Quadratic map*) te iteratorom šatorsko krilo (oznake *tent* ili *Tent map*). Nakon postupka optimiranja učestalost pogreške bita poboljšana je za nekoliko redova veličine. Daljnje istraživanje u korištenju dvodimenzionalnih i trodimenzionalnih kaotičnih iteratora nije provedeno u sklopu ovog rada jer u višedimenzionalnim iteratorima ne postoji jedan parametar sustava. Varijable višedimenzionalnog iteratora ovise jedna o drugoj te nije moguće promatrati promjene korelacijskih karakteristika u odnosu na parametar sustava.

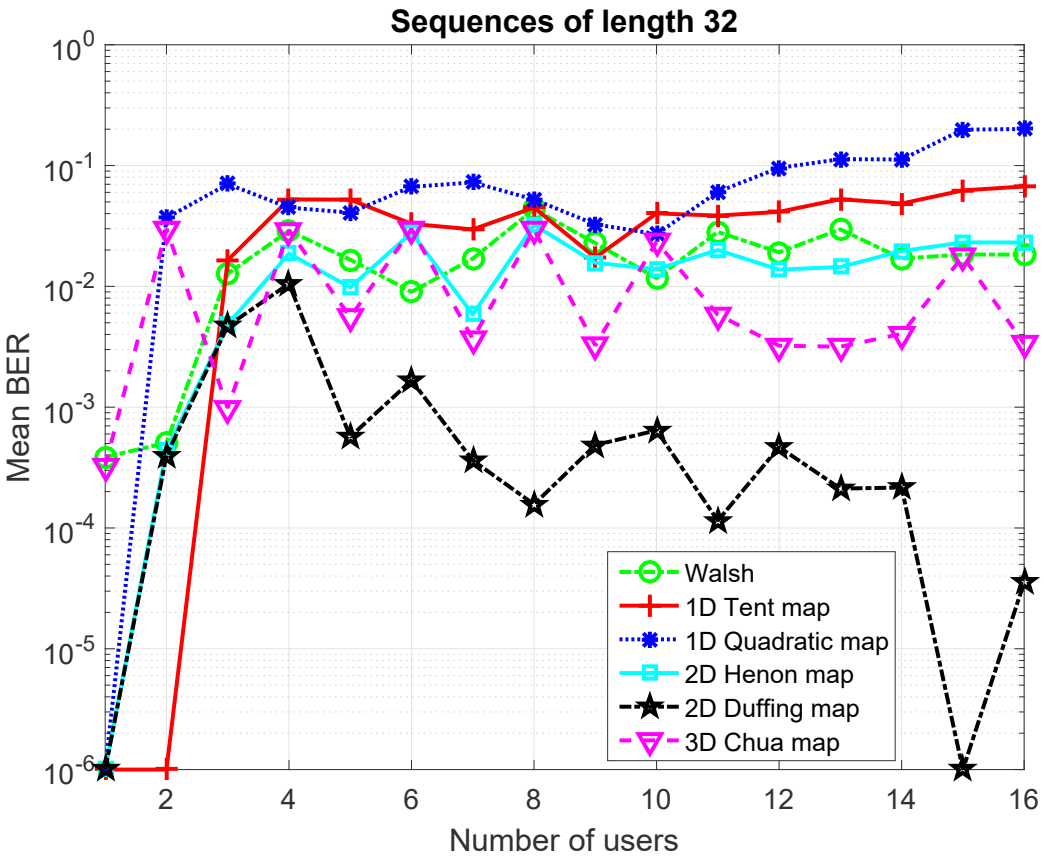
Performance sustava u [74] mijenjale su se promjenom broja korisnika odnosno promjenom korelacijskih svojstava. Dodatnim istraživanjem u području korelacijskih parametara i karakteristika došlo se do pronalaska metode optimiranja kaotičnih sljedova korištenjem Golayeovg faktora.

Na slikama se koriste kratice koje označuju različite slučajeve:

- SH*xx* označuje zaglavlje duljine *xx*, npr. SH16 cheb32 FH označuje zaglavlje duljine 16 bitova koje je generirano korištenjem Čebiševljevim iteratorom
- Oznaka *cheb32* pokazuje da se radi o sustavu koji koristi slijed za proširenje pojasa duljine 32 generiran Čebišeljvevim iteratorm.
- Za generiranje kaotičnih sljedova koriste se tri kaotična iteratora: Čebiševljev iterator (oznaka slijeda cheb), iterator oblika šatorsko krilo (oznaka slijeda tent) te populacijski (kvadratni) iterator (oznaka slijeda quad).

Kako bi se dobile što veće vrijednosti Golayevog faktora, koristile su se dvije metode generiranja odnosno optimiranja kaotičnih sljedova. Prvi način generiranja je promjenom iznosa parametra sustava μ u cijelom rasponu vrijednosti za koje je sustav kaotičan. Drugi način generiranja je postavljanje vrijednosti parametra sustava na visoki iznos te generiranje kaotičnih signala promjenom početnih uvjeta. Tako generirani sljedovi imaju oznaku *PU*. Sljedovi generirani s promjenom početnih uvjeta imaju više vrijednosti Golayevog parametra te se očekuje da će postizati bolje performance.

Učestalost pogreške bita određena je usporedbom broja krivo prenesenih bitova u odnosu na ukupan broj primljenih bitova. Simulacija je zaustavljena kada je primljeno $1 \cdot 10^8$ bitova za



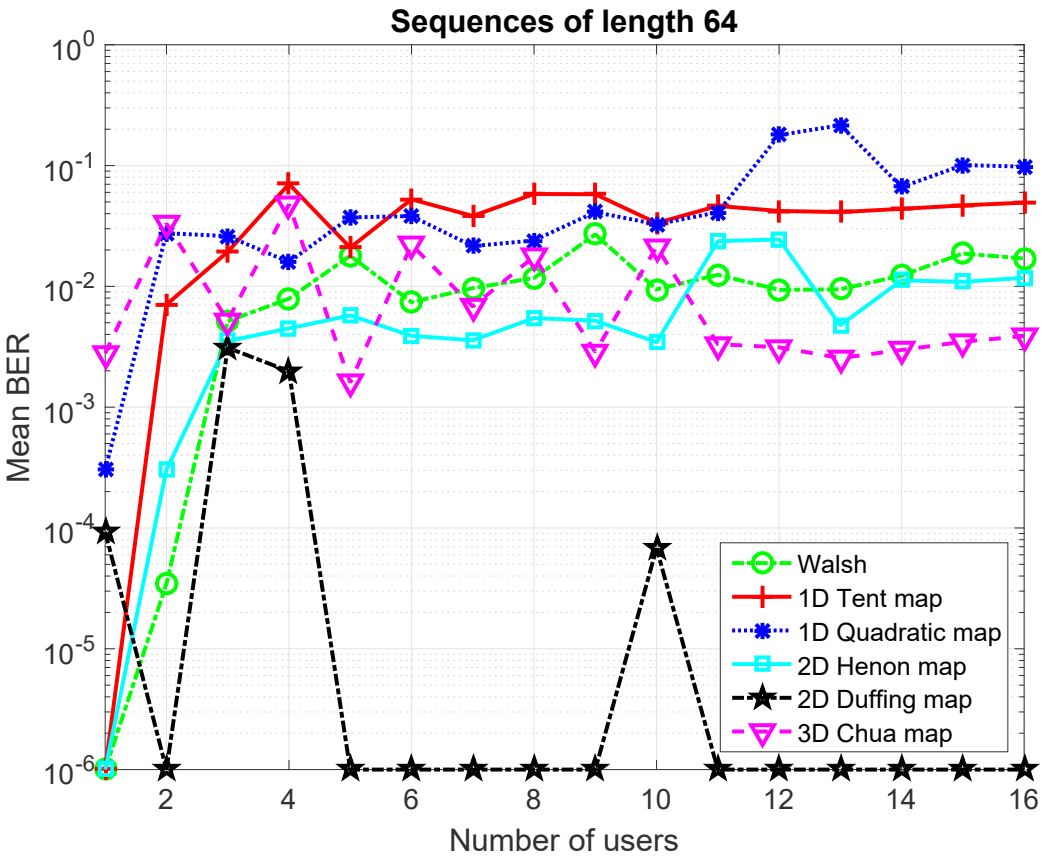
Slika 7.6: Učestalost pogreške bita za sljedove duljine 32, preuzeto iz [74]

svakog korisnika.

Na slikama 7.9, 7.11 i 7.13 uspoređuju se učestalosti pogreške bita za sustav s duljinom slijeda za sinkronizaciju od 16 bita. Slike 7.10, 7.12 i 7.14 prikazuju performance za sustav s duljinom sinkronizacijskog okvira od 32 bita. Na svim slikama uspoređuju se performance sljedovi za proširenje pojasa različitih duljina. Kao referenca uzeti su Gold sljedovi definirani u normi [62].

Na učestalost pogreške bita utječu karakteristike slijeda za proširenje kao i slijeda za sinkronizaciju. Slijed za proširenje trebao bi imati dobra svojstva kako bi uspješno odvojio svaki tok podataka u zajedničkom kanalu. Slijed za sinkronizaciju mora imati dobru dinamiku kako bi se smanjila izobličenja nastala u cijelom sustavu.

Slika 7.9 uspoređuje učestalost pogreške bita za sustav s najkraćim sljedovima za proširenje pojasa kao i najkraćom duljinom okvira za sinkronizaciju. Može se vidjeti da kaotični sljedovi pokazuju bolje performance u odnosu na Gold sljedove. Najbolje performance pokazuju sljedovi koji su generirani s visokim iznosom Golayevog faktora. Optimiranim generiranjem sljedova, sljedovi generirani Čebiševljevim iteratorom (oznaka *cheb*) imali su najviše vrijednosti Golayevog faktora. Na slikama se može vidjeti da ti sljedovi u svim slučajevima imaju bolje performance u odnosu na ostale sljedove. Prema tablici druga najveća vrijednost Golayevog

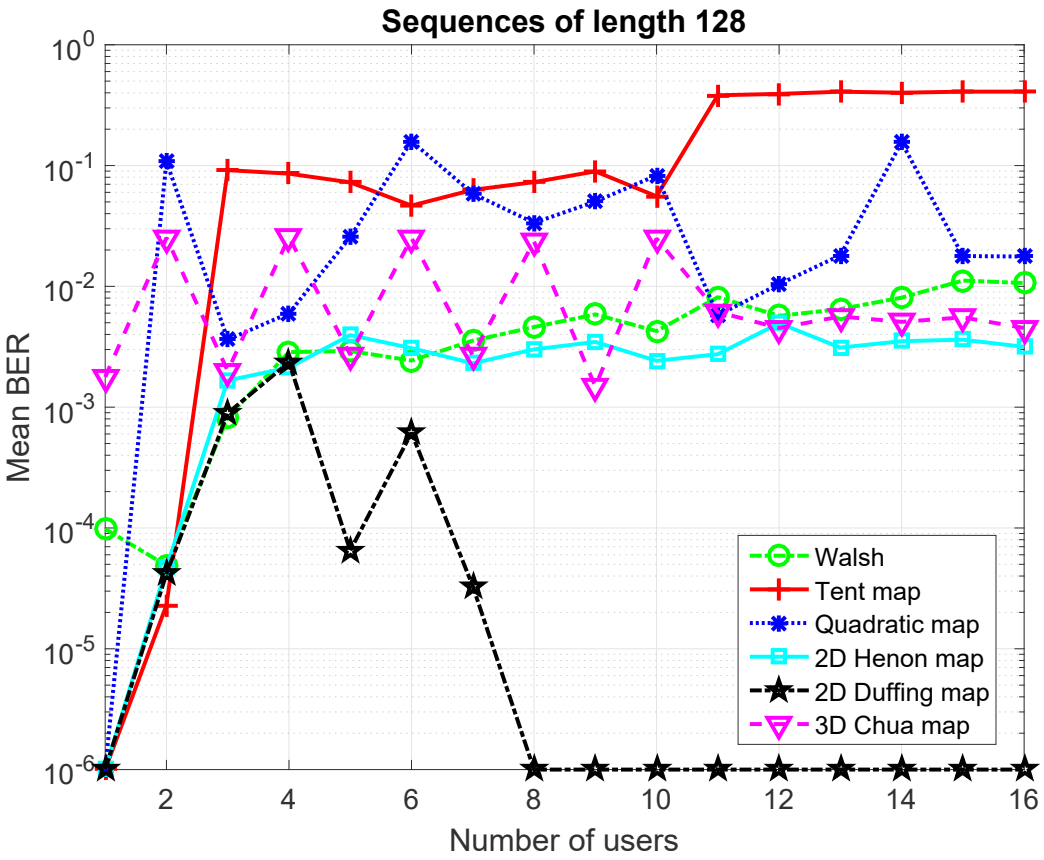


Slika 7.7: Učestalost pogreške bita za sljedove duljine 64, preuzeto iz [74]

faktora dobivena je za sljedove generirane iteratorom šatorsko krilo (oznaka *tent*). Ti sljedovi pokazuju nešto lošije performance u odnosu na sljedove generirane Čebiševljevim iteratorom. Performance sljedova generiranih populacijskim (kvadratnim) iteratorom (oznaka *quad*) su najlošije u skupu kaotičnih sljedova. Sljedovi generirani populacijskim iteratorom imali su najniže vrijednosti Golayevog faktora.

Performance učestalosti pogreške bita pokazuju da se metoda optimiranja sljedova u odnosu na Golayev parametar može primijeniti za izbor sljedova koji će poboljšati rad sustava. U evaluaciji sljedovi generirani Čebiševljevim iteratorom pokazuju najbolje rezultate, a pri generiranju dobivene su najviše vrijednosti Golayevog parametra.

Na svim slikama se može primijetiti naglo pogoršanje performanci pri povećanju broja korisnika s 1 na 3. Razlog tome je u asinkronom načinu prijenosa i neoptimalnom načinu dodavanja signala proširenog pojasa svakog korisnika u kanal. Signali u proširenom pojasu svakog korisnika se dodaju odnosno zbrajaju međusobno pri pozivu odašiljačkog programa koji se izvršava u petlji. Ako podaci nisu spremni pri izvršenju petlje, šalje se niz nula. Takav način je najjednostavniji za implementaciju no nije optimalan za prijenos. Kada je sustav postavljen za samo jednog korisnika, podaci su uvijek pripremljeni i šalje se samo jedan zbrojeni signal. U višekorisničkom slučaju, podaci svih korisnika ne moraju biti spremni za slanje u pojedinoj



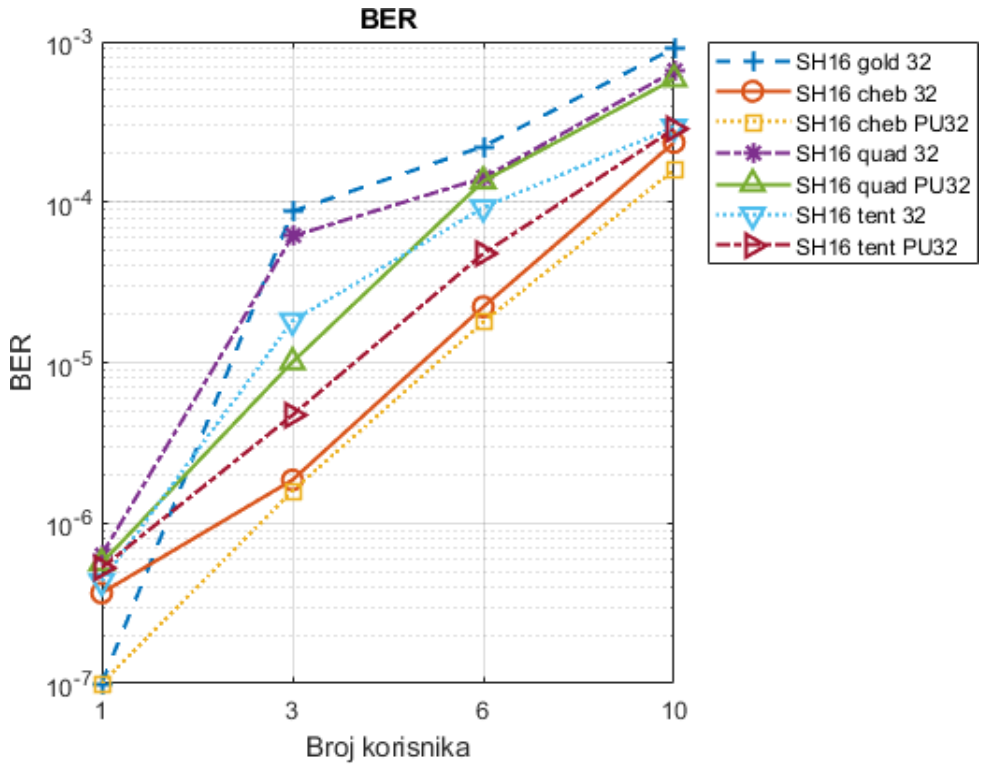
Slika 7.8: Učestalost pogreške bita za sljedove duljine 128, preuzeto iz [74]

diskretnoj iteraciji petlje te zbrojeni valni oblik nije optimalan, odnosno postoji određena križna korelacija sa zamjenskim podacima što dovodi do značajnog pogoršanja performanci. Ujedno postoji i križna korelacija u korisnim podacima što dovodi do daljnje degradacije performanci.

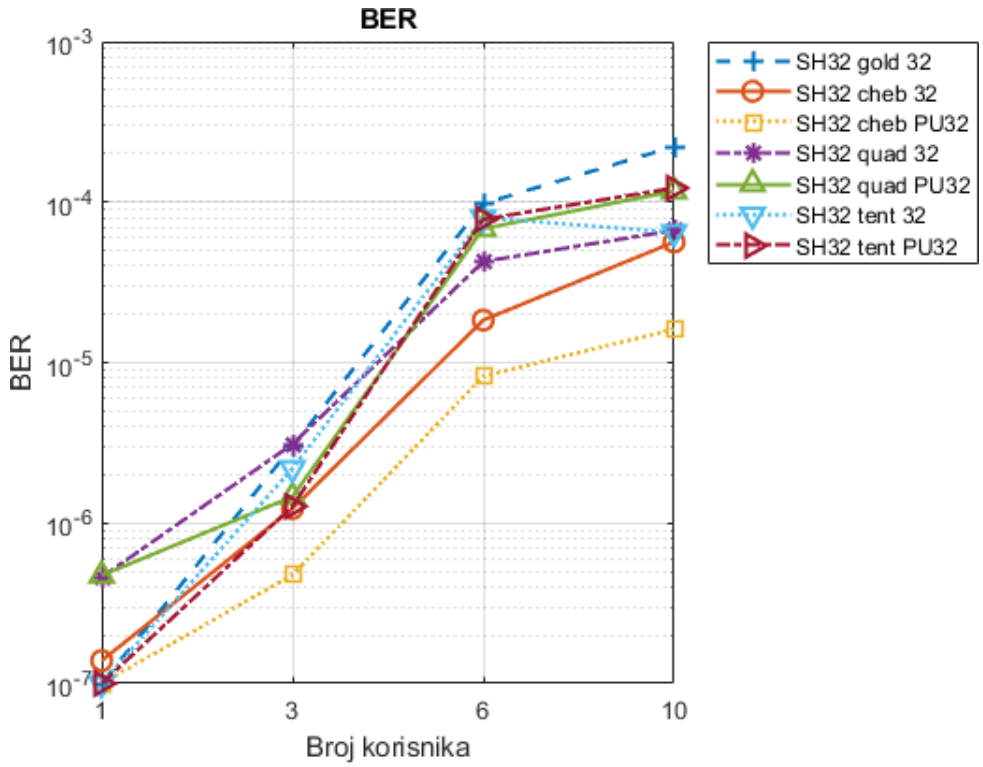
Pri takvom načinu prijenosa ne postoji međusobna sinkronizacija odašiljačkog i prijamnog programa te vremenski resursi kao i kanal nisu optimalno iskorišteni. Taj nedostatak je u samoj izvedbi programa, a ne u karakteristikama sljedova i cjelokupnog sustava.

Povećanjem duljine okvira za sinkronizaciju dobivaju se bolje performance što se može vidjeti na slici 7.10. Dulji slijed za sinkronizaciju omogućuje veći prostor za ispravljanje pogrešaka u prijenosu kao i robusniju sinkronizaciju sustava i okvira na prijamniku.

Na slikama 7.11 i 7.12 uspoređuju se performance sustava sa slijedom za proširenje pojasa duljine 64. Može se vidjeti da svi kaotični sljedovi pokazuju bolje performance što je u skladu s metodom optimiranja sljedova. Usporedbom performanci sustava s duljinom slijeda za proširenje 32 na slikama 7.9 i 7.10 s performancama sustava s duljinom slijeda za proširenje 64 na slikama 7.11 i 7.12 može se vidjeti da duljina slijeda za proširenje pojasa značajno utječe na performance sustava. Logično je da će sustav s duljim slijedom za proširenje imati bolje performance, no vidljivo je da duljina slijeda za proširenje utječe značajnije na performance u odnosu na slijed za sinkronizaciju. Razlog tome je u samoj izvedbi sustava pri čemu se prim-

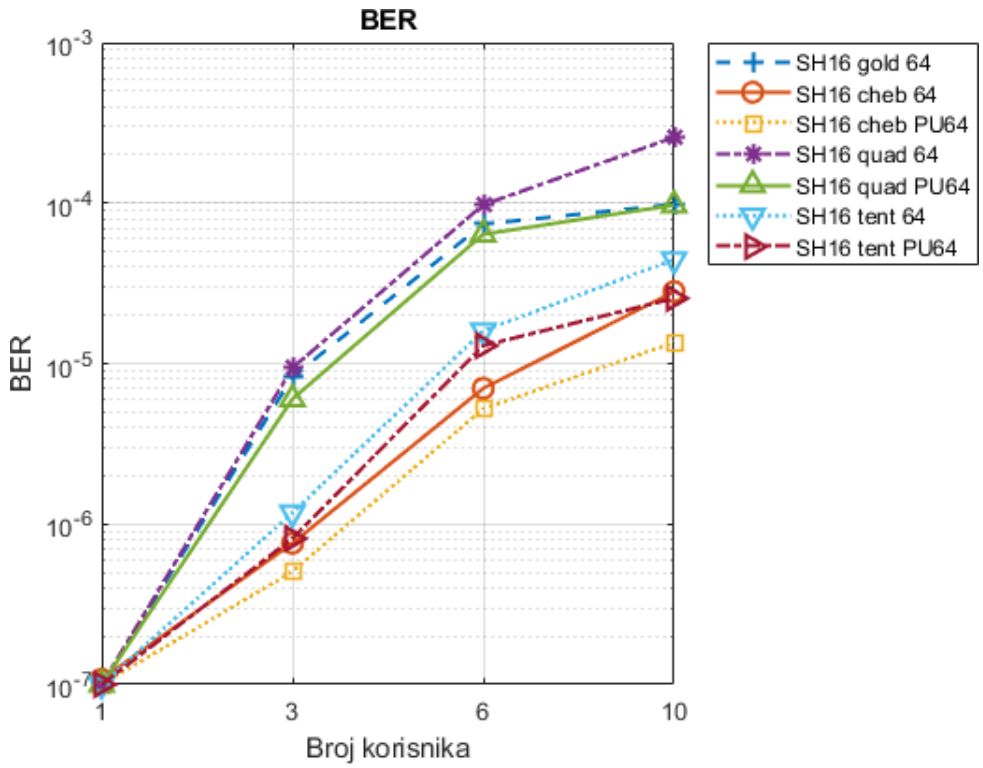


Slika 7.9: Učestalost pogreške bita za sljedove za proširenje duljine 32 uz duljinu slijeda za sinkronizaciju 16



Slika 7.10: Učestalost pogreške bita za sljedove za proširenje duljine 32 uz duljinu slijeda za sinkronizaciju 32

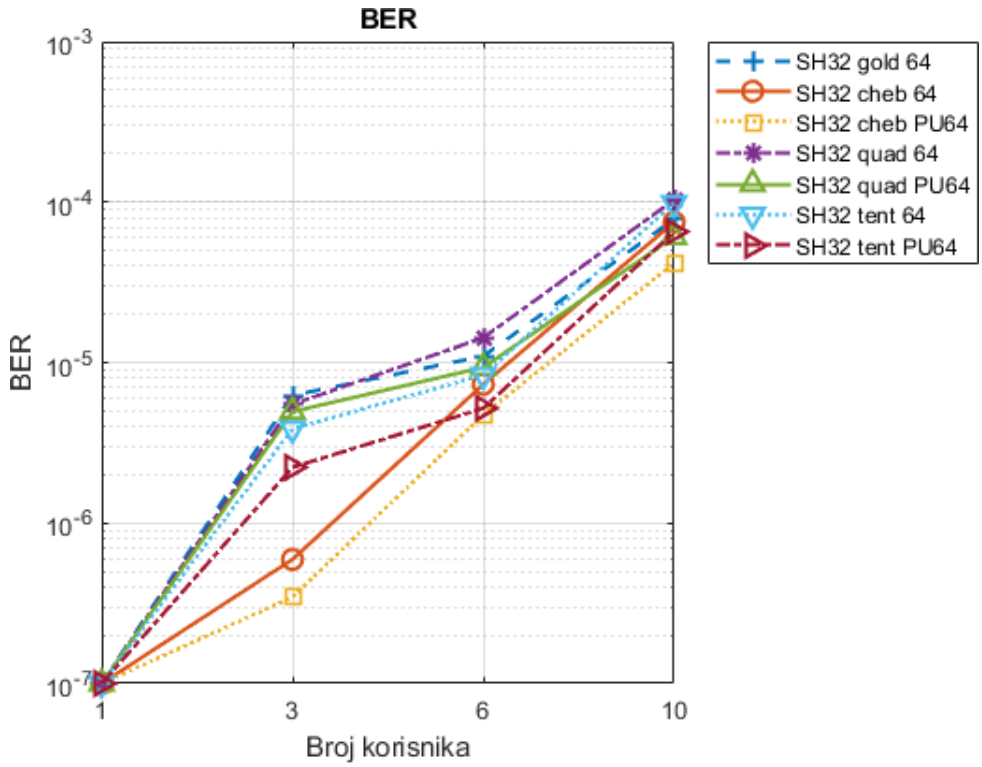
ljeni podaci prvo množe s slijedom za proširenje pojasa kako bi se sažeo pojas. Pri tome se koriste dobra korelacijska svojstva slijeda kako bi se uklonila izobličenja. Taj prvotni demodulacijski korak se zapravo može promatrati kao vrsta zaštitnog dekodiranja te je jasno da će on imati najveći utjecaj na performance sustava. Ako se podaci pogrešno detektiraju već pri prvom koraku u sažimanju pojasa, ostatak sustava će teško rekonstruirati i ispraviti pogreške. Naime, pri sažimanju pojasa potrebno je i ispravno detektirati i sinkronizacijsku preambulu. Ako je sinkronizacijska preambula pogrešno detektirana, sustav će imati pogrešne referentne podatke za sinkronizaciju pri demodulaciji. U ovakvoj implementaciji sustava s višestrukim pristupom po kodu očito je nužno imati dobro generirane i optimirane sljedove kako bi sustav ispravo radio.



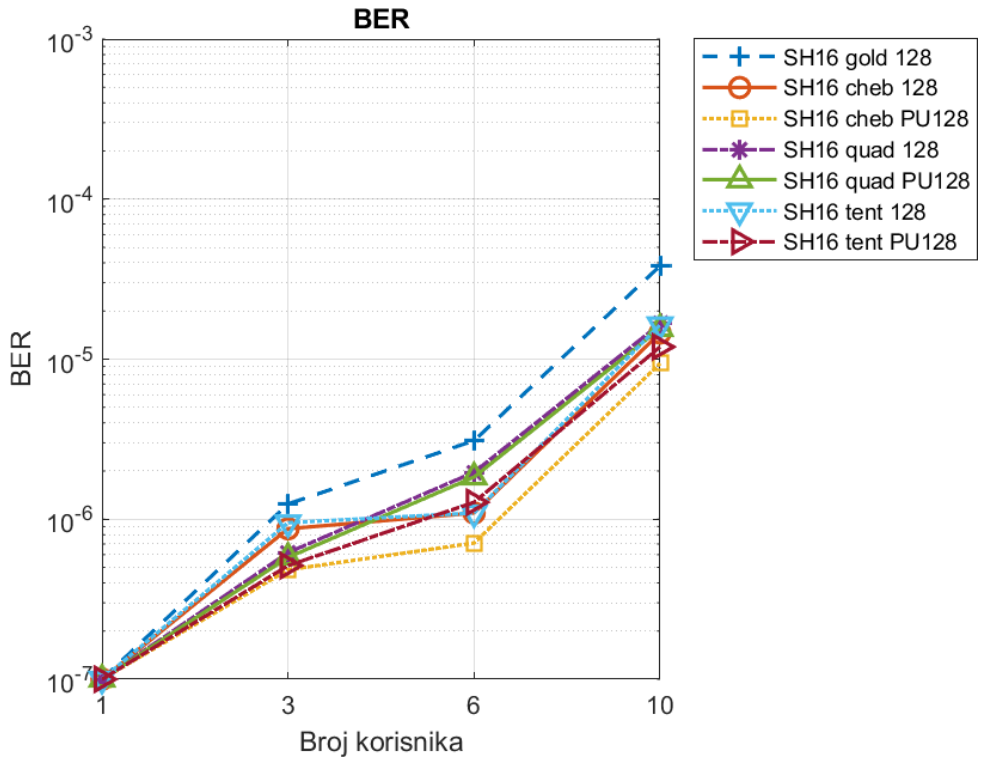
Slika 7.11: Učestalost pogreške bita za sljedove za proširenje duljine 64 uz duljinu slijeda za sinkronizaciju 16

7.4 Evaluacija performanci sinkronizacije

Kod programski određenog radija, mjerenje performanci provodi se korištenjem virtualnih instrumenata u LabView programskom alatu. Virtualni instrument je zapravo potprogram koji obavlja proračune i daje rezultate mjerenja primljenog valnog oblika. U ovom slučaju takav virtualni instrument može se poistovjetiti s analizatorom signala. Dio mjerenja se dobiva i iz samog programa za demodulaciju kao i bloka za izjednačavanje kanala. Svi virtualni instrumenti uzimaju kompleksne vrijednosti primljenog simbola s kompleksnom ovojnicom te određuju potrebne vrijednosti. U slučaju mjerenja srednjih vrijednosti virtualnom instrumentu može

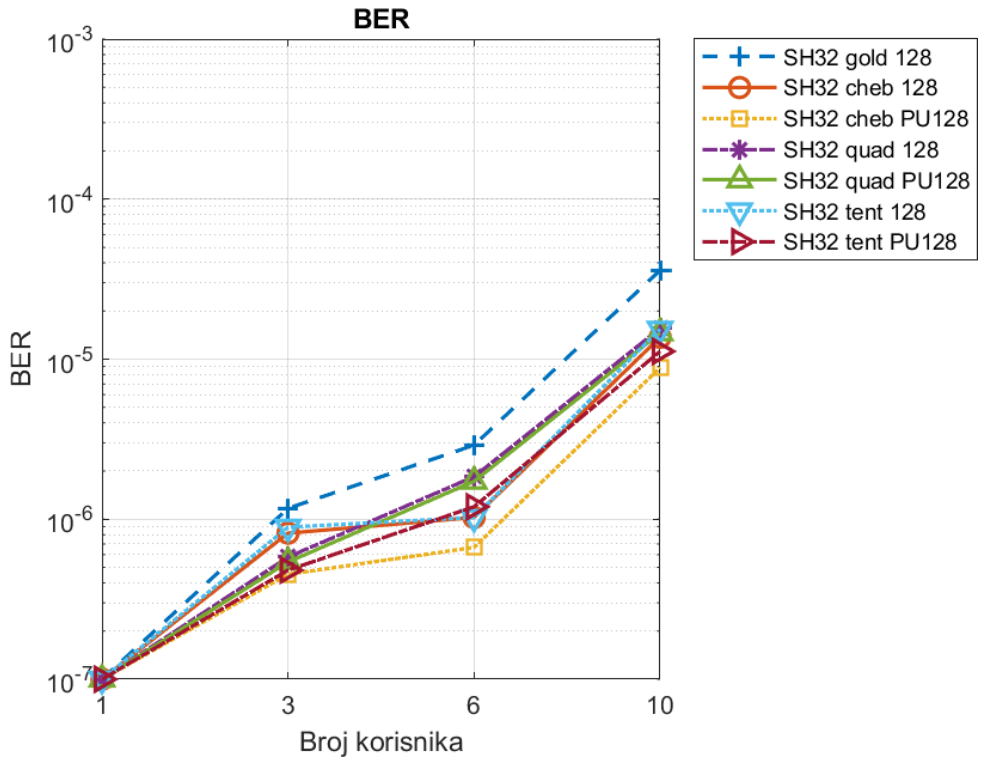


Slika 7.12: Učestalost pogreške bita za sljedove za proširenje duljine 64 uz duljinu slijeda za sinkronizaciju 32



Slika 7.13: Učestalost pogreške bita za sljedove za proširenje duljine 128 uz duljinu slijeda za sinkronizaciju 16

se zadati nad kolikim brojem kompleksnih simbola će raditi usrednjavanje. S obzirom na to da se proračun obavlja nad uzorcima analognog valnog oblika, postoji određena greška u kvatizi-



Slika 7.14: Učestalost pogreške bita za sljedove za proširenje duljine 128 uz duljinu slijeda za sinkronizaciju 32

ranju, odnosno u analogno digitalnoj pretvorbi, te se rezultati tih mjerenja ne mogu uzimati kao apsolutne veličine već samo za relativnu međusobnu usporedbu.

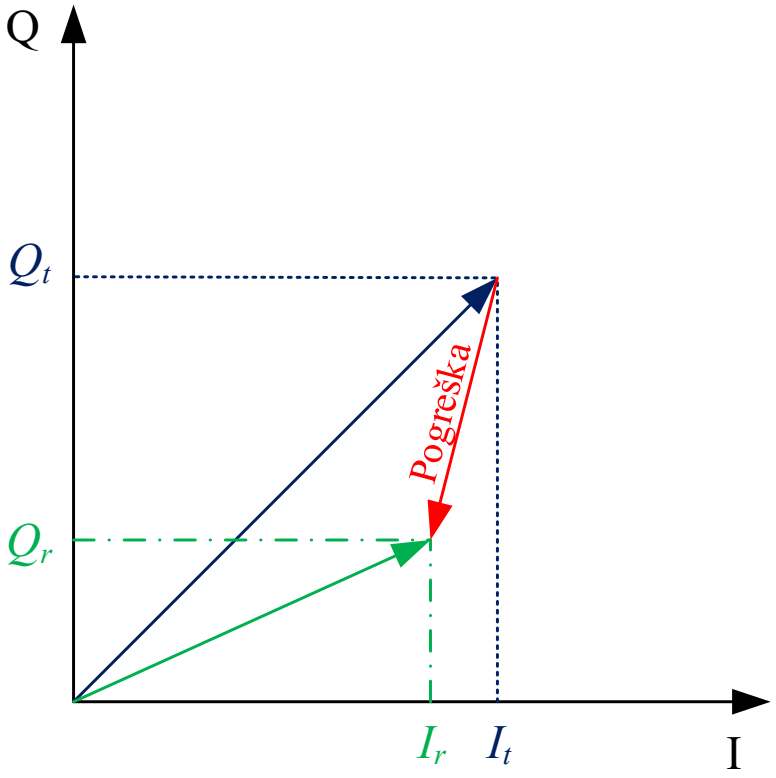
Kako bi se provjerila kvaliteta modulacije te rad modulatora i demodulatora koristi se parametar veličine verzora pogreške EVM (eng. *Error Vector Magnitude*). EVM pokazuje obilježja digitalnog odašiljača i prijamnika kroz prikaz ukupne pogreške u fazi i amplitudi u demoduliranom signalu. Optimalno sinkronizirani prijamnik će demodulirati primljene simbole idealno poravnate s dijagramom stanja. U stvarnim prijamnicima zbog različitih izobličenja i utjecaja šuma doći će do pomaka točke u dijagramu stanja. EVM pokazuje koliki je pomak položaja primljenog simbola od idealnog položaja u dijagramu stanja kroz odstupanja amplitude i faze.

EVM se može definirati kao [79]:

$$\begin{aligned} EVM &= \sqrt{(I_r - I_t)^2 + (Q_r - Q_t)^2} \\ &= \sqrt{(\Delta I)^2 + (\Delta Q)^2} \end{aligned} \tag{7.1}$$

gdje su I_r i Q_r iznosi komponenti primljenog signala, a I_t i Q_t idealna mjesta u dijagramu stanja.

Kroz vrijednosti EVM može se prikazati kvaliteta demoduliranog signala pomoću čega se provjeravaju performance sljedova za proširenje pojasa kao i sinkronizacijskih sljedova. Dobra korelacijska svojstva sljedova za proširenje omogućuju ispravnu detekciju korisnog signala u



Slika 7.15: Prikaz veličine verzora pogreške

višekorisničkom sustavu gdje je potrebno korelacijskim tehnikama prepoznati ispravni signal te odbaciti ostale. Pri sinkronizaciji slijed za sinkronizaciju treba imati dovoljnu dinamiku kako bi se uspješno detektirale promjene u frekvenciji, fazi i amplitudi signala u osnovnom pojasu.

Uz prikaz performanci kroz vrijednosti EVM-a, prikazat će se i performance za pojedine podsustave koji koriste sinkronizacijsko zaglavlje za procjenu parametara. Sinkronizacijsko zaglavlje koristi se u bloku za izjednačavanje kanala kao referentni simboli, za procjenu faze pri sinkronizaciji u PSK demodulatoru te za sinkronizaciju frekvencije digitalnog nosioca pri demodulaciji u PSK demodulatoru.

Kod prikaza performanci pri izjednačavanju koristi se iznos kvadrata napona pogreške (eng. *Equilizer Error*) V^2 koji pokazuje apsolutnu razliku za koji je bilo potrebno ispraviti sažeti signal. Iznos pogreške izjednačavanja indirektno pokazuje kvalitetu sljedova za proširenje pojasa jer će sljedovi s boljim svojstvima bolje detektirati signal iz grupe signala u višekorisničkim sustavu te neće biti potrebno znatnije izjednačavanje.

Performance pri procjeni faze promatraju se kroz rezidualnu pogrešku faze (eng. *Phase Error*) nakon provedene sinkronizacije u PSK demodulatoru. Rezidualna pogreška faze proizlazi

iz nemogućnosti demodulatora da u potpunosti ispravno procijeni fazu korištenjem referentnih simbola u sinkronizacijskom zaglavlju. Iznos rezidualne pogreške faze pokazuje kvalitetu slijeda za proširenje pojasa te slijeda za sinkronizaciju. S obzirom na to da se demodulacija i sinkronizacija provode nakon procjene kanala postoji direktan utjecaj dobrih svojstava sljedova na konačni iznos pogreške faze. Sljedovi s dobri svojstvima u proširenju pojasa imat će manja izobličenja pri sažimanju i demodulaciji. Isto tako dobri sinkronizacijski sljedovi omogućit će podsustavima za izjednačavanje i sinkronizaciju bolje referentne vrijednosti i samim time bolje performance u cijelom sustavu.

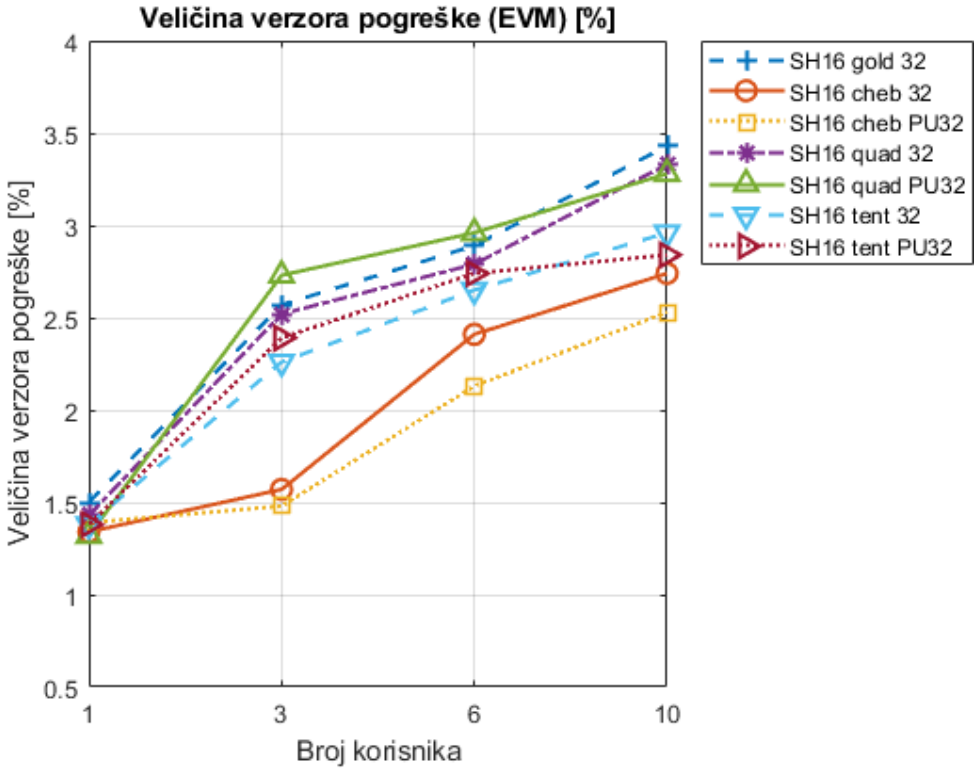
Rezidualni pomak frekvencije (eng. *Frequency Offset*) koristi se kao mjera performanci u sinkronizaciji frekvenciji digitalnog nosioca pri demodulaciji i translaciji signala u osnovni pojas. Rezidualni pomak je razlika između detektirane frekvencije nosioca i stvarne frekvencije koja je unaprijed poznata sustavu. Pri procjeni frekvencije koriste se ista dobra korelacijska svojstva sljedova za proširenje pojasa i sinkronizaciju kao i kod procjene kanala i faze demoduliranog signala.

Pri evaluaciji višekorisničkog sustava za programski određeni radio te evaluaciji kaotičnih sljedova uspoređivale su se performance za nekoliko slučajeva:

- usporedba svih sljedova za proširenje pojasa duljine 32 i duljinom sinkronizacijskog polja 16 (npr. SH16 cheb 32),
- usporedba svih sljedova za proširenje pojasa duljine 32 i duljinom sinkronizacijskog polja 32 (npr. SH32 cheb 32),
- usporedba sljedova za proširenje pojasa duljine 32 i duljinom sinkronizacijskog polja 16 i 32 (npr. SH16 cheb 32 i SH32 cheb 32),
- usporedba sljedova za proširenje pojasa duljine 32 i 64 te duljinom sinkronizacijskog polja 32 (npr. SH32 cheb 32 i SH32 cheb 64).

Odabirom tih parametara za usporedbu može se provjeriti nekoliko hipoteza. Prva je evaluacija performanci kaotičnih sljedova u odnosu na Gold sljedove zadane u IEEE normi sustava te evaluacija algoritma generiranja optimiranih sljedova u odnosu na Golayev faktor GF.

Za evaluaciju performanci odabrani su parametri sustava koji bi trebali pokazivati najlošije performance (najkraći sljedovi za proširenje duljine 32 te slijed za sinkronizaciju duljine 16). Na slikama se mogu vidjeti performance različitih sljedova u odnosu na broj korisnika. S obzirom na to da USRP platforma nema poznatu i jednoznačnu referencu za omjer snage signala i šuma, performance se evaluiraju u odnosu na broj korisnika. Slike 7.16, 7.17, 7.18, 7.19, 7.20 7.21 ,7.22 i 7.23 pokazuju da generirani kaotični sljedovi iz različitih iteratora pokazuju bolje performance u odnosu na Gold sljedove. Posebno se ističu sljedovi generirani Čebiševljevim iteratorom, a koji imaju najveće iznose Golayevog faktora. Isto tako sljedovi generirani s visokim iznosom parametra sustava μ (sljedovi s oznakom PU) pokazuju bolje performance u odnosu na Gold sljedove te kaotične sljedove generirane s promjenjivim parametrom μ. Slje-

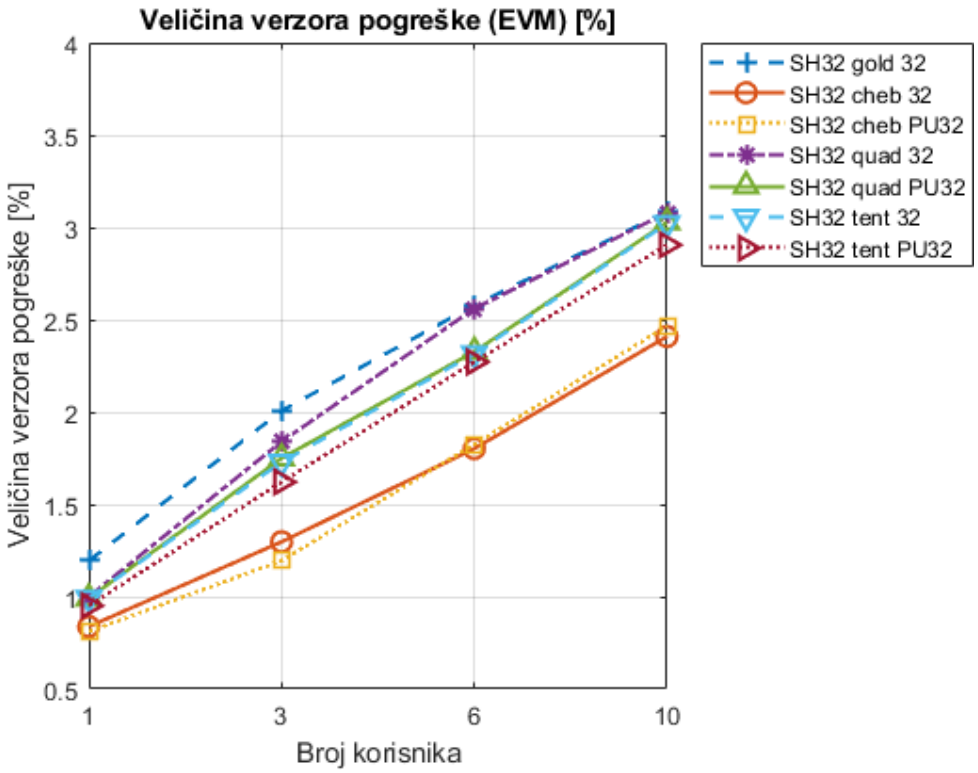


Slika 7.16: Veličina verzora pogreške za sljedove za proširenje duljine 32 i duljinom sinkronizacijskog zaglavlja 16 bita

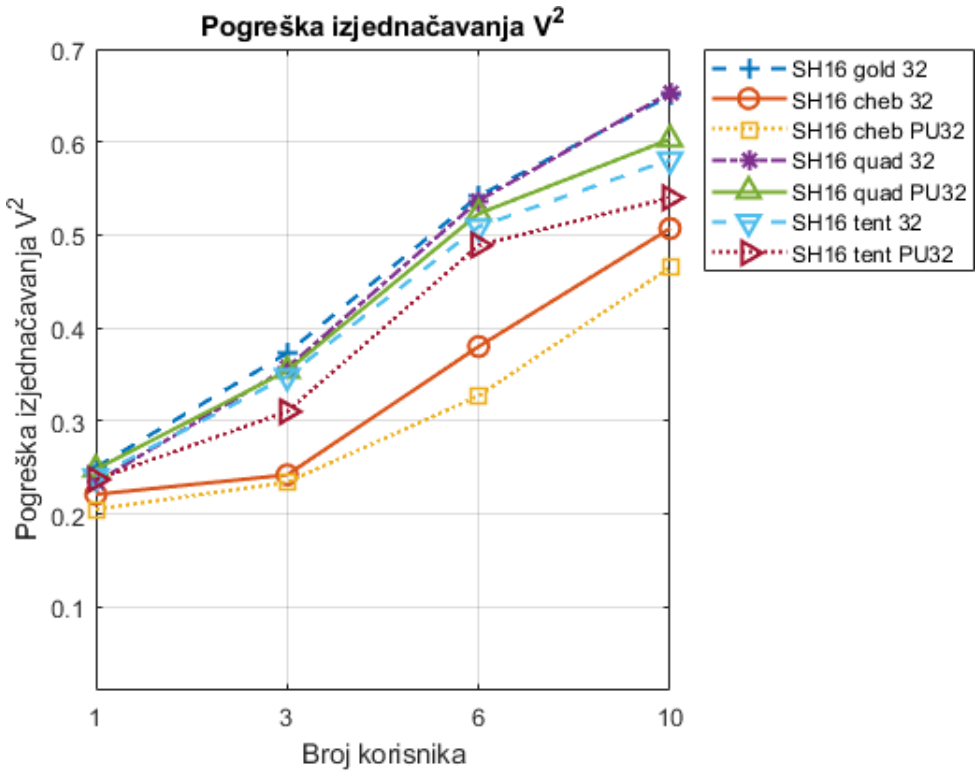
dovi s fiksiranim parametrom μ imaju veće vrijednosti Golayevog parametra što govori u prilog metode optimiranja sljedova za višekorisnički sustav.

Drugi korak evaluacije je provjera učinka sinkronizacijskih zaglavlja na performance sustava. Očekuje se da će sustavi s duljim sinkronizacijskim okvirom imati bolje performance što se i potvrđuje usporedbom performanci na slikama 7.24, 7.26, 7.28 i 7.30. Na slikama se može primijetiti da kaotični sljedovi pokazuju bolje performance u odnosu na Gold sljedove.

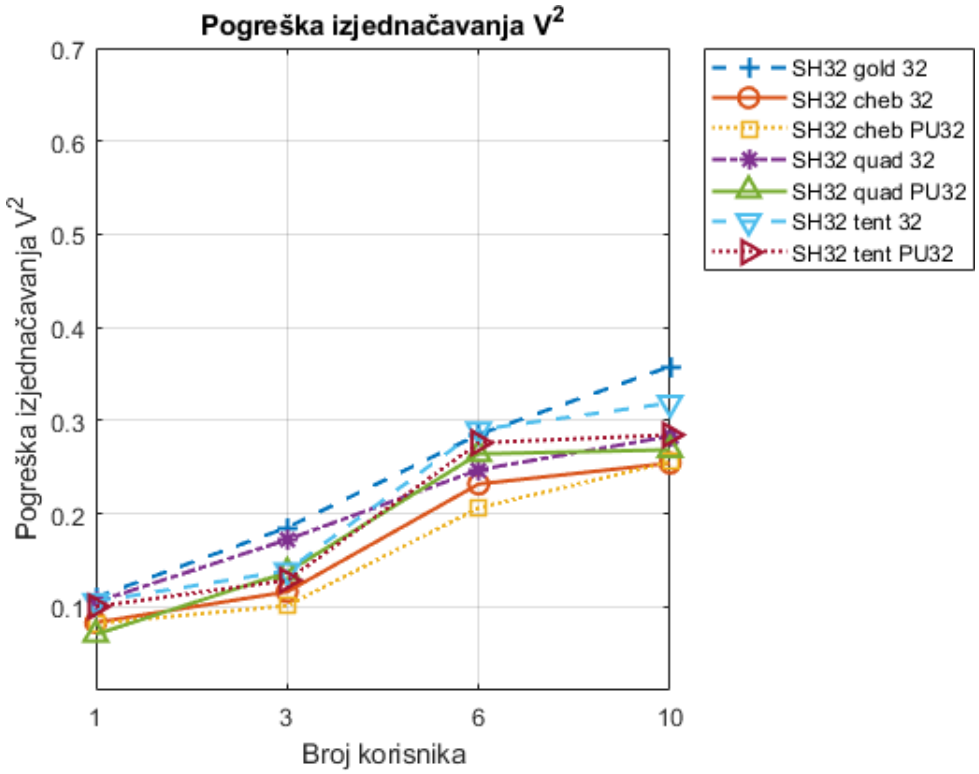
Uspoređivanjem performanci na slikama 7.25, 7.27, 7.29 i 7.31 može se uočiti da kvaliteta demoduliranog signala dosta ovisi o slijedu za proširenje pri čemu dulji sljedovi te sljedovi s višim Golayevim faktorom pokazuju bolje performance. Rezultati pokazuju da dulji slijed za sinkronizaciju povećava performance, no nije glavni parametar za konačne performance sustava. Logično je da slijed za proširenje pojasa ima veći utjecaj na samu konačnu kvalitetu i performance sustava jer se prije procjene kanala, PSK demodulacije i sinkronizacije signal mora sažeti i detektirati iz skupine signala u kanalu. Ako se već taj prvi korak detekcije ne provede kvalitetno, sami podaci kao i sinkronizacijski okvir neće biti ispravno obnovljen te će i same procjene kanala, frekvencije i faze imati veću pogrešku.



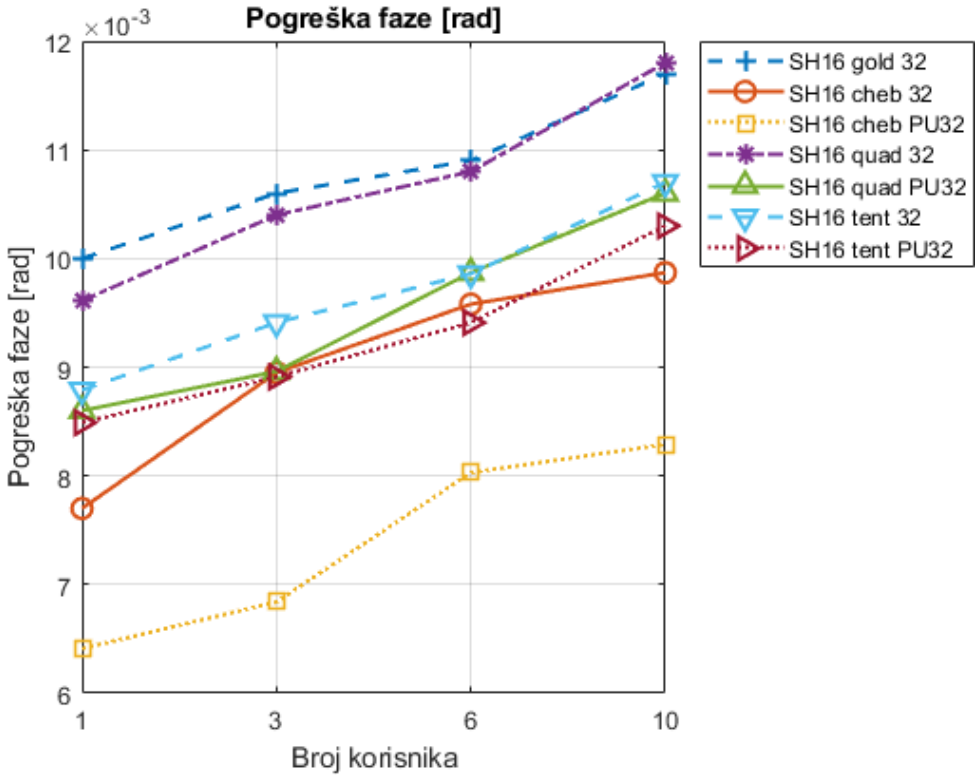
Slika 7.17: Veličina verzora pogreške za sljedove za proširenje duljine 32 i duljinom sinkronizacijskog zaglavlja 32 bita



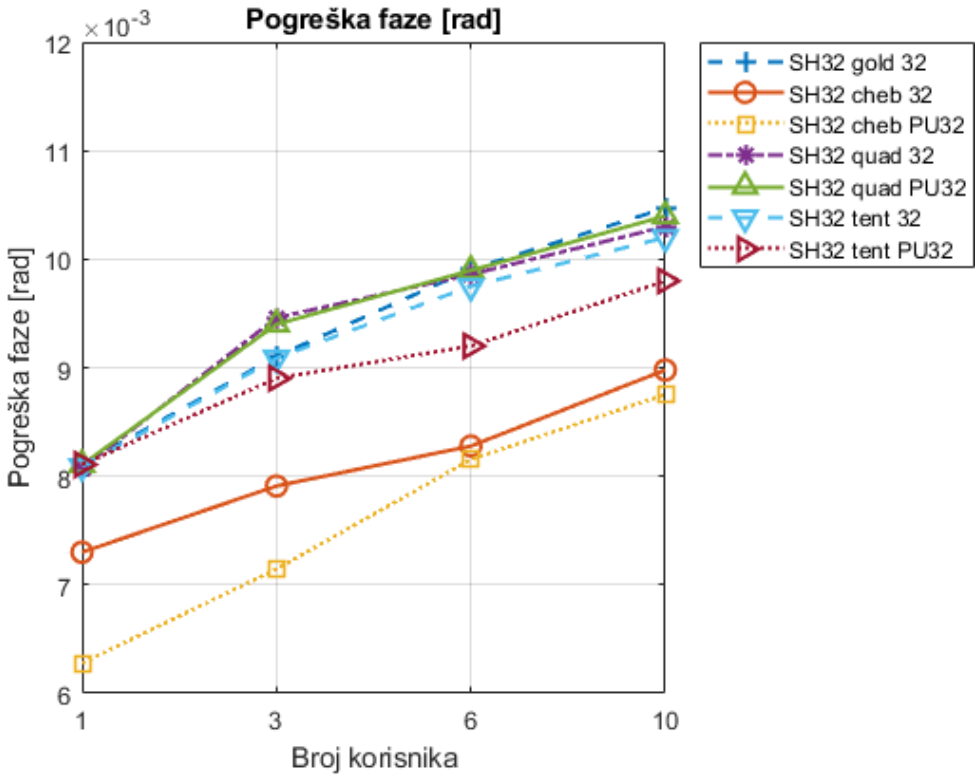
Slika 7.18: Pogreška izjednačavanja za sljedove za proširenje duljine 32 i duljinom sinkronizacijskog zaglavlja 16 bita



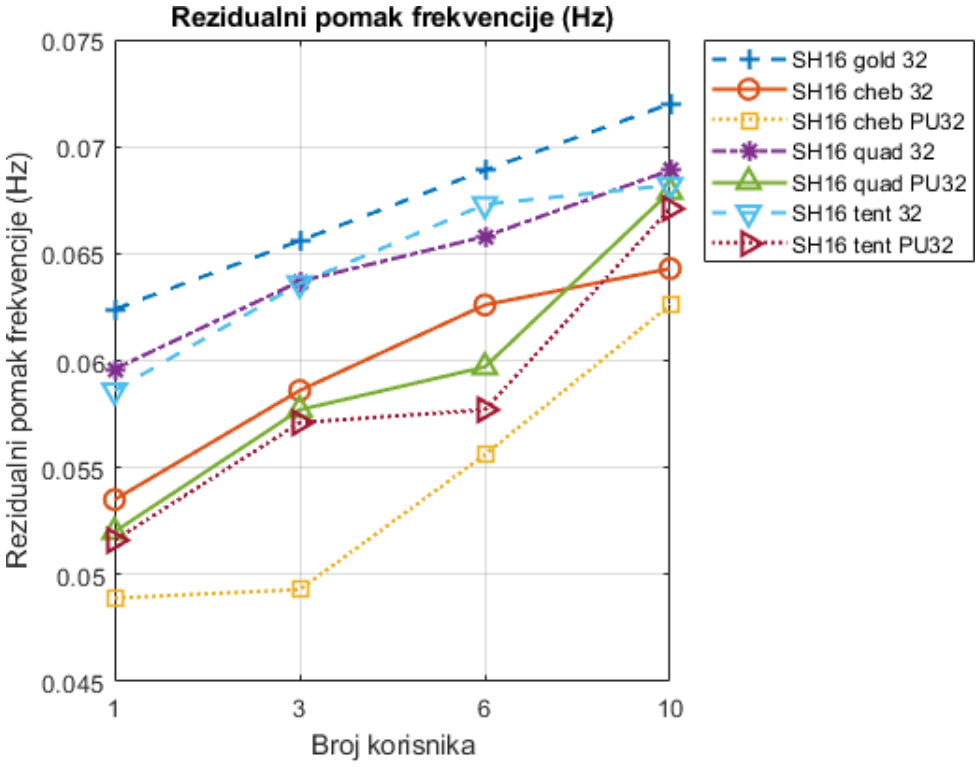
Slika 7.19: Pogreška izjednačavanja za sljedove za proširenje duljine 32 i duljinom sinkronizacijskog zaglavlja 32 bita



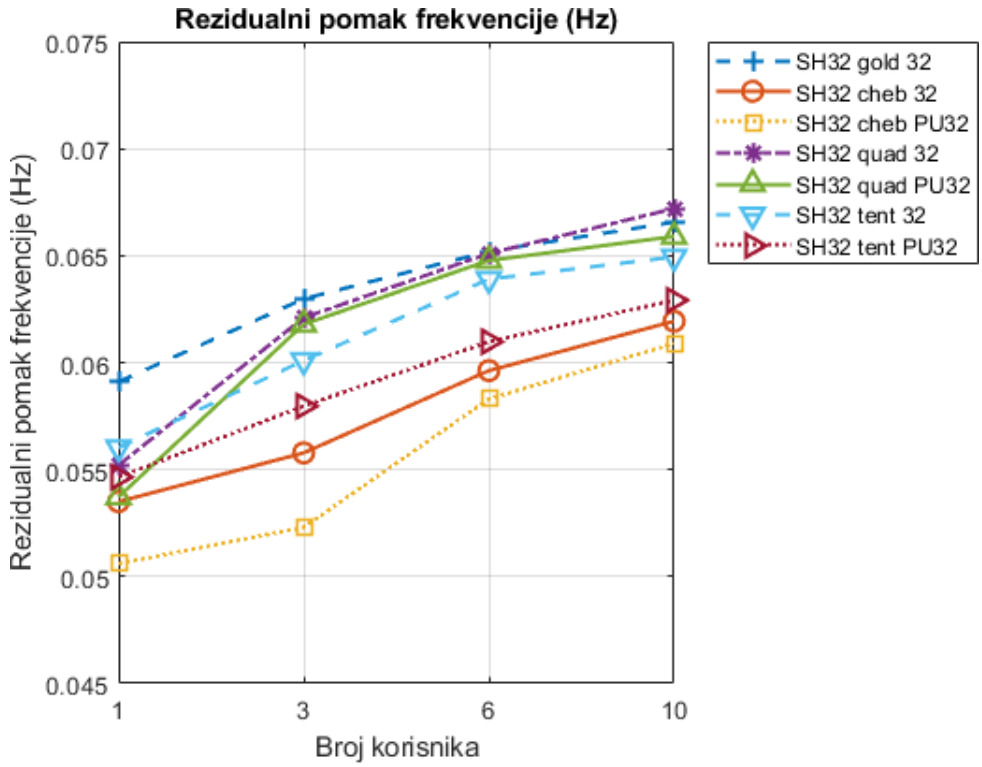
Slika 7.20: Pogreška faze za sljedove za proširenje duljine 32 i duljinom sinkronizacijskog zaglavlja 16 bita



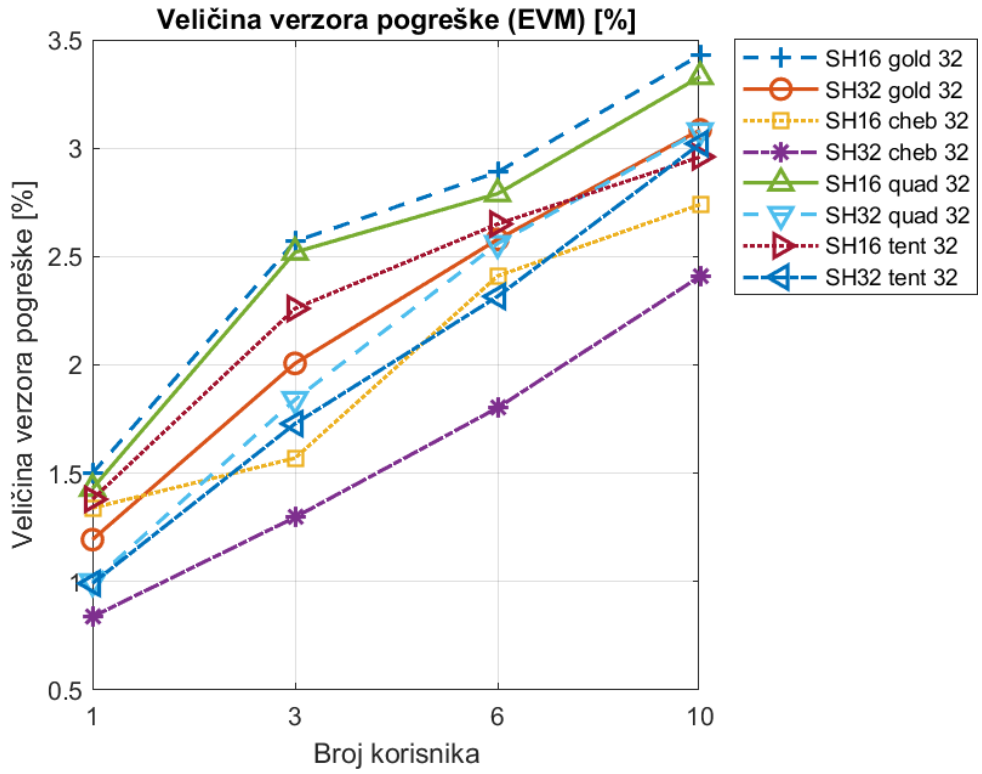
Slika 7.21: Pogreška faze za sljedove za proširenje duljine 32 i duljinom sinkronizacijskog zaglavlja 32 bita



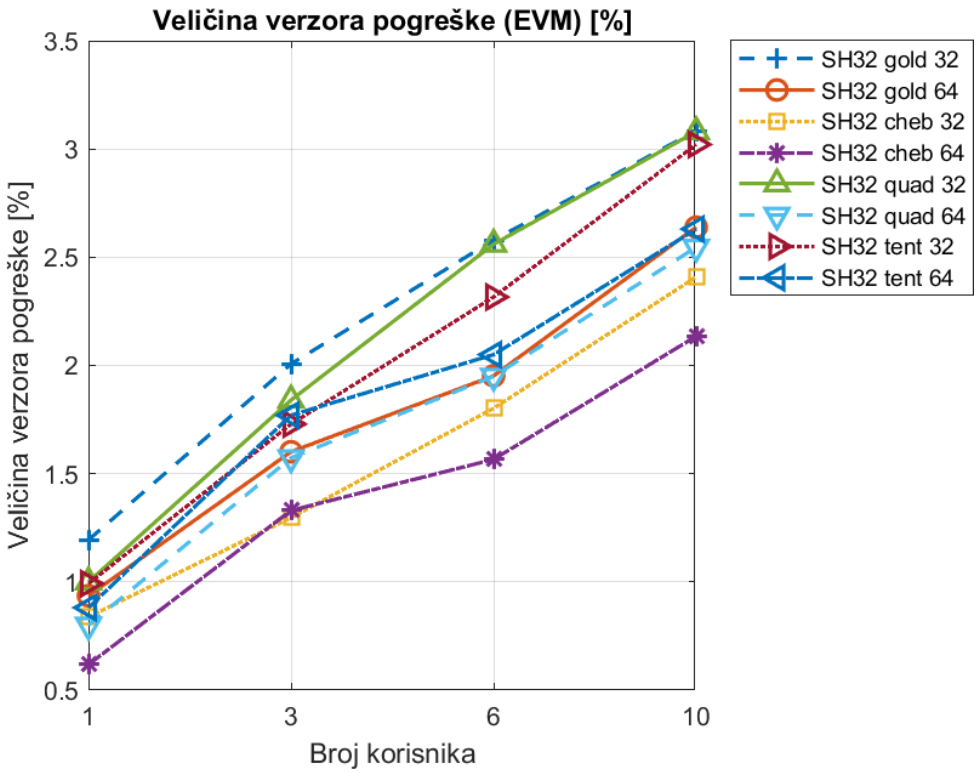
Slika 7.22: Rezidualna pogreška frekvencije za sljedove za proširenje duljine 32 i duljinom sinkronizacijskog zaglavlja 16 bita



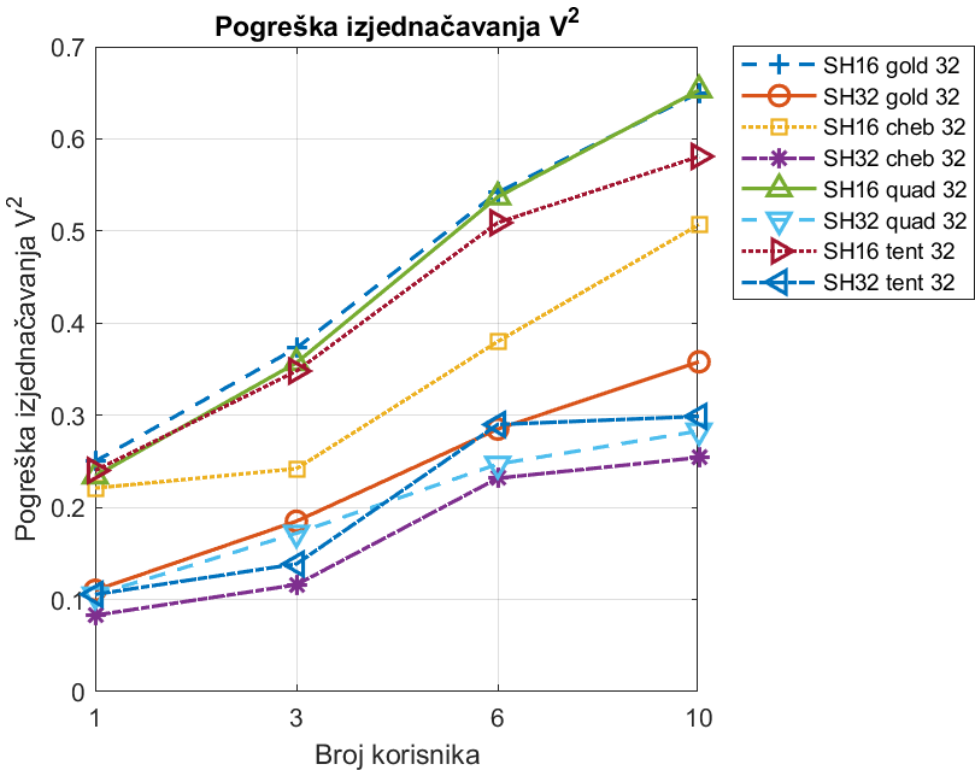
Slika 7.23: Rezidualna pogreška frekvencije za sljedove za proširenje duljine 32 i duljinom sinkronizacijskog zaglavlja 32 bita



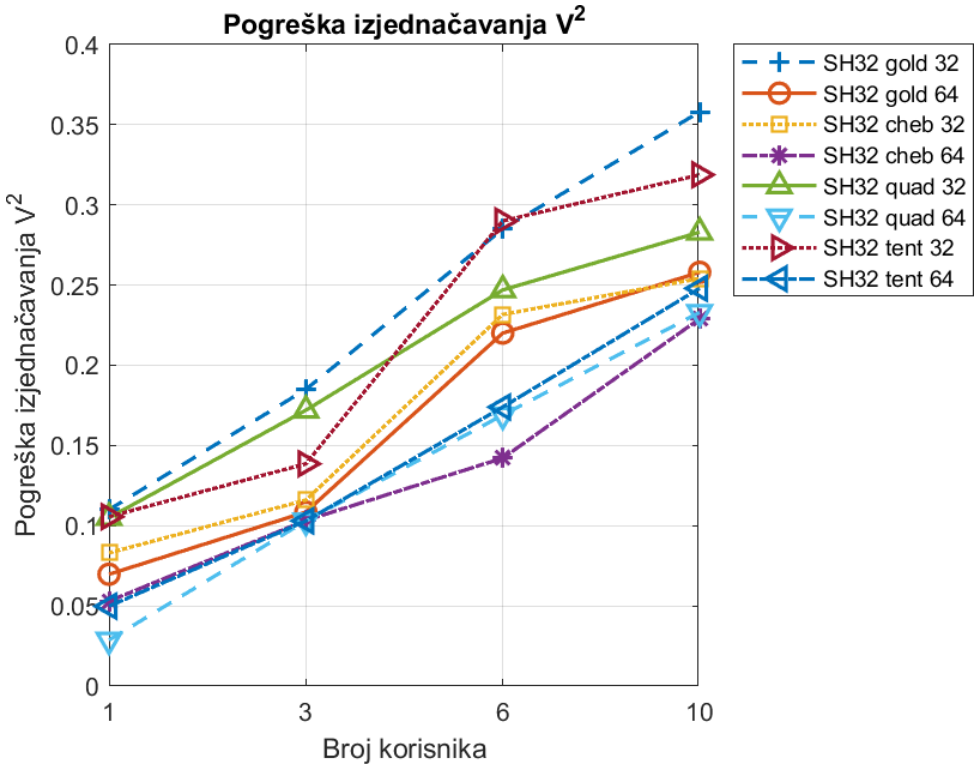
Slika 7.24: Usporedba EVM za sljedove za proširenje duljine 32 i duljinom sinkronizacijskog zaglavlja 16 i 32 bita



Slika 7.25: Usporedba EVM za sljedove za proširenje duljine 32 i duljinom sinkronizacijskog zaglavlja 32 bita

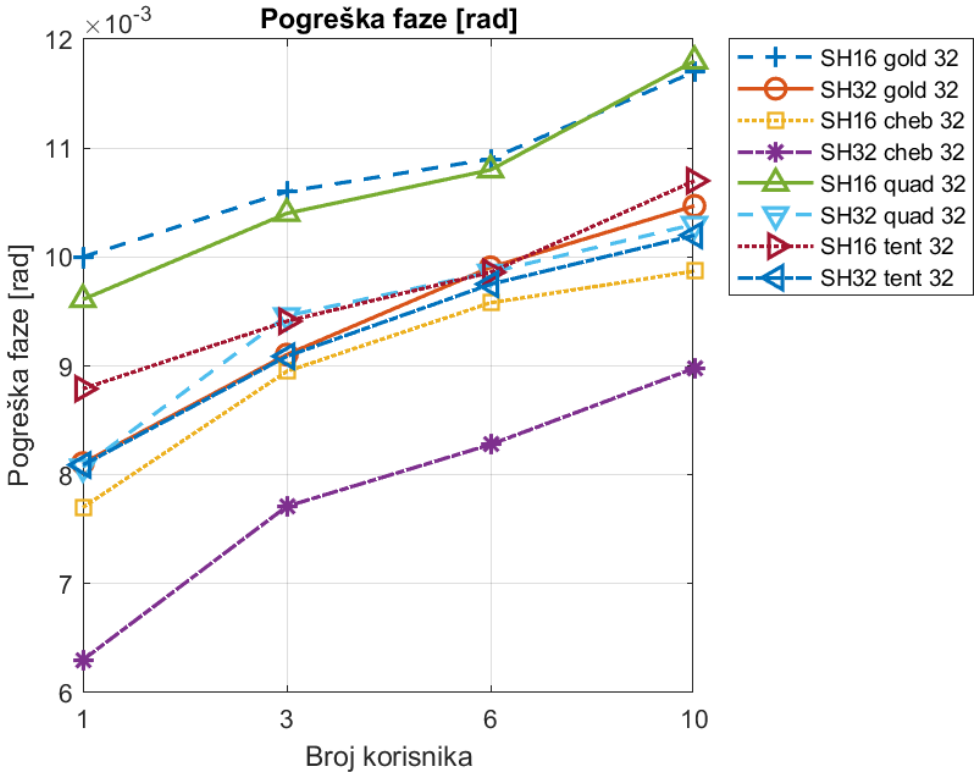


Slika 7.26: Usporedba pogreške izjednačavanja za sljedove za proširenje duljine 32 i duljinom sinkronizacijskog zaglavlja 16 i 32 bita

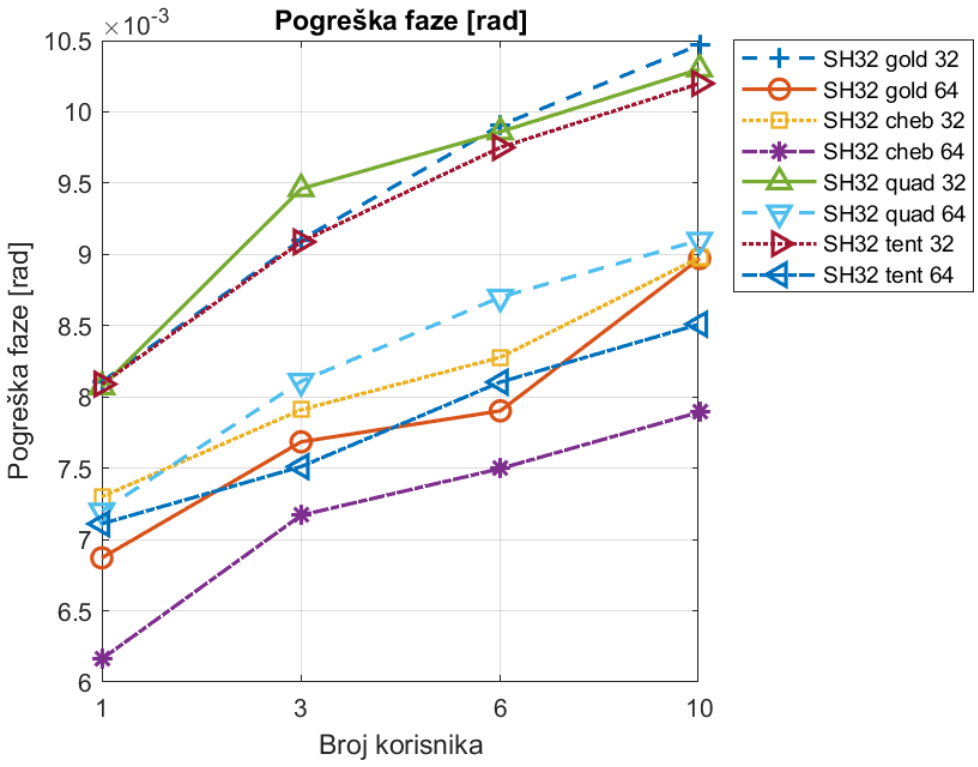


Slika 7.27: Usporedba pogreške izjednačavanja za sljedove za proširenje duljine 32 i 64 i duljinom sinkronizacijskog zaglavlja 32 bita

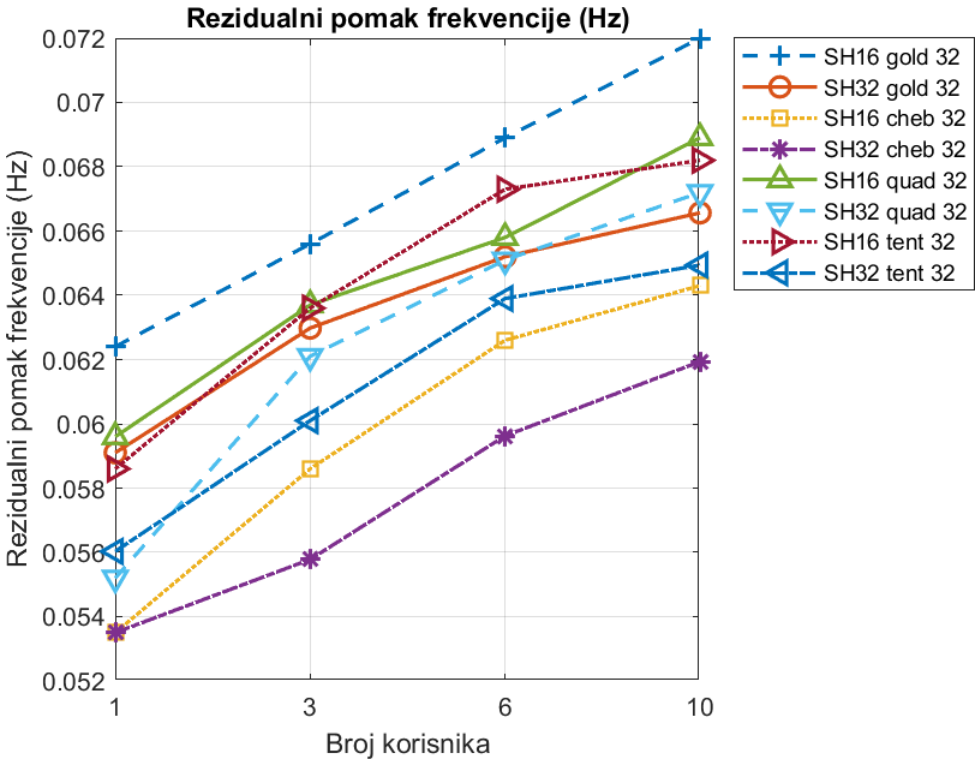
Rezultati evaluacije performanci sinkronizacije korištenjem kaotičnih sljedova pokazuju da korištenjem optimiranih kaotičnih sljedova za proširenje pojasa kao i za referentne sinkronizacijske simbole značajno poboljšava rad sustava. Dodatna poboljšanja mogla bi se postići optimiranjem samog algoritma za sinkronizaciju kako bi se učinkovito iskoristila dobra korelacijska svojstva kaotičnih sljedova.



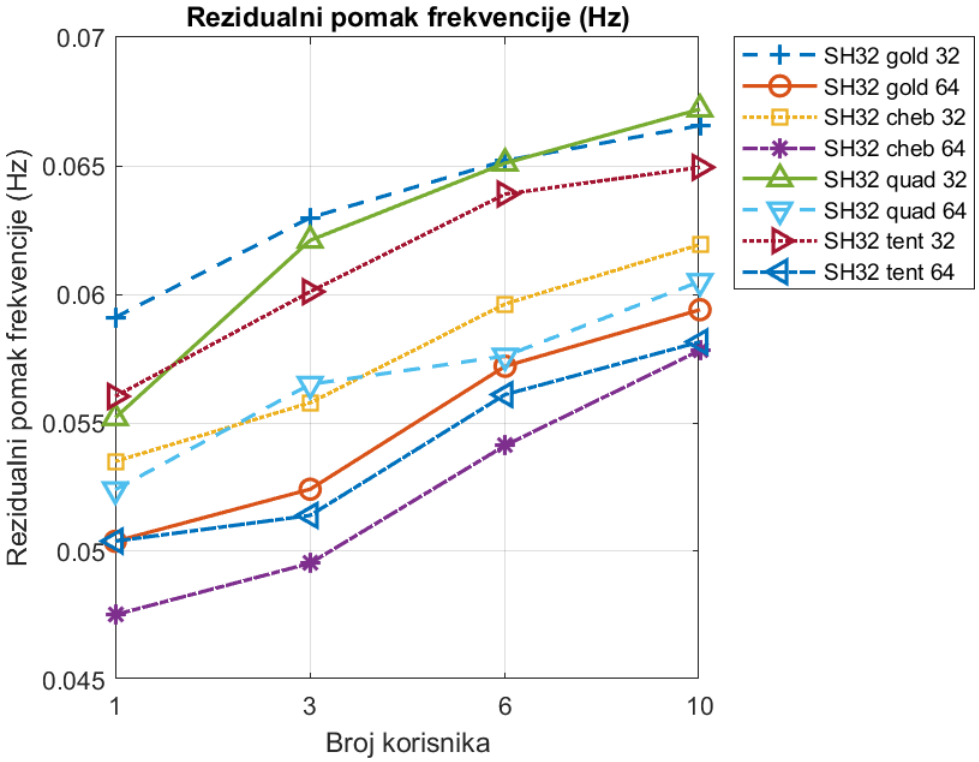
Slika 7.28: Usporedba rezidualne pogreške faze za sljedove za proširenje duljine 32 i duljinom sinkronizacijskog zaglavlja 16 i 32 bita



Slika 7.29: Usporedba rezidualne pogreške faze za sljedove za proširenje duljine 32 i 64 i duljinom sinkronizacijskog zaglavlja 32 bita



Slika 7.30: Usporedba rezidualnog pomaka frekvencije za sljedove za proširenje duljine 32 i duljinom sinkronizacijskog zaglavlja 16 i 32 bita



Slika 7.31: Usporedba rezidualnog pomaka frekvencije za sljedove za proširenje duljine 32 i 64 i duljinom sinkronizacijskog zaglavlja 32 bita

Poglavlje 8

Zaključak

Razvojem novih generacija radijskih komunikacijskih sustava često se zapostavljaju moguća proširenja i povećanje iskoristivosti starih generacija i postojećih sustava. Među najvećim preprekama korištenju starijih generacija sustava ili modulacijskih postupaka je nemogućnost analize i usporedbi performanci pri izmjeni nekog dijela sustava. Korištenjem modela temeljenih na programski određenom radiju omogućuje se analiza i usporedba novih mogućnosti i iskoristivosti starijih sustava i tehnika pristupa fizičkom sloju. Modeliranjem fizičkog sloja i osnovnih dijelova viših slojeva mogu su ostvariti upotrebljivi sustavi na arhitekturi programski određenog radija. Poboljšanjem performanci postojećih radijskih komunikacijskih sustava analizom rada na platformi programski određenog radija omogućuje se nova vrijednost za takve sustave.

Tehnika pristupa korištenjem proširenog spektra posebno je raširena zbog svoje jednostavnosti, robusnosti i velikih mogućnosti primjene. U tehnikama proširenog spektra, za proširenje pojasa koriste se razne vrste sljedova čija su svojstva dobro poznata. Glavni problem je ostvariti višestruki pristup, odnosno mogućnost uspješnog slanja i primanja podataka više korisnika u isto vrijeme u istom kanalu na jednoj frekvenciji. Sljedovi koji bi trebali omogućiti takvo slanje i primanje trebali bi biti savršeno ortogonalni za sve pomake u vremenu i slijedu za proširenje. Pri kašnjenju dolazi do pomaka primljenog proširenog signala što dovodi do gubitka ortogonalnosti i smanjenja performanci. Kako bi se omogućio rad u realnim uvjetima gdje dolazi do raznih izobličenja, koriste se sljedovi koji pokazuju dobra svojstva pri kašnjenju, odnosno ne gube u potpunosti ortogonalnost [59].

Komunikacijski sustavi koji koriste neke tehnike prijenosa korištenjem kaosa obećavaju povećanje sigurnosti, robusnosti, brzine prijenosa kao i smanjenje troškova. Takvi sustavi bili bi učinkovitiji u odnosu na sustave koji ne koriste kaotične tehnike prijenosa. Kaotični signali se mogu iskoristiti u sustavima s proširenim spektrom zbog svoje sličnosti sa signalima šuma. Signali generirani kaotičnim sustavom imaju dobra autokorelacijska svojstva, a promjenom raznih parametara kaotičnog sustava mogu se generirati i skupovi kaotičnih signala koji imaju dobra ortogonalna svojstva. Kaotični signali, s obzirom na to da su slični šumu, imaju širok frekvencij-

ski pojas. Dobra korelacijska svojstva uz širok pojas frekvencija, jednostavnost generiranja kao i velik broj kaotičnih signala, čine ih dobrim kandidatima za upotrebu u sustavima s proširenim spektrom [53]. Ta se ideja potvrdila i u ovoj disertaciji. Cilj istraživanja bio je evaluirati poboljšanje performanci komunikacijskog sustava s proširenim spektrom i višestrukim pristupom po kodu korištenjem optimiranih kaotičnih sljedova za proširenje pojasa. Postupak optimiranja kaotičnih sljedova odnosi se na usporedbu korelacijskih parametra za različite vrijednosti parametara kaotičnog sustava. Evaluacija performanci optimiranih kaotičnih sljedova provela se na laboratorijskom prototipu komunikacijskog sustava po normi IEEE 802.15.4. Laboratorijski prototip izveden je na arhitekturi programski određenog radija kako bi se performance evaluirale u realnim radijskim kanalima.

Prijašnja istraživanja [74] pokazivala su da je moguće generirati kaotične signale s nekim željenim korelacijskim svojstvima promatrajući korelacijske koeficijente. Odabirom parametra sustava i početnih uvjeta može se generirati kaotični signal s poboljšanim korelacijskim svojstvima. Takvi sljedovi poboljšavaju performance sustava, posebno u višekorisničkom okruženju. Izradom fizičkog sloja modela na arhitekturi programski određenog radija omogućena je upotreba kaotičnih sljedova u komunikacijskom sustavu s proširenim spektrom.

Proširenjem prijašnjih istraživanja [74] ostvaruje se prvi doprinos ovog rada kroz optimiranje kaotičnih sljedova generiranih iz nelinearnih diskretnih sustava za prijenos podataka proširenim spektrom. Optimiranje se provodilo kroz maksimiziranje Golayevog parametra koji opisuje korelacijska svojstva skupa sljedova [71]. Za svaku diskretnu vrijednost parametra sustava generirao se slijed određene duljine te se računao Golayev parametar. Najveća prepreka u korištenom postupku optimiranja jest proračun nakon generiranja sljedova. Daljnje istraživanje bi se moglo provesti u otkrivanju korelacijskih svojstava prije generiranja te promatranja potprostora pri određenom parametru sustava u kojem se generiraju sljedovi s najvećim iznosom Golayevog parametra. Nekoliko kaotičnih sustava pokazalo se posebno pogodnim za generiranje optimiranih kaotičnih sljedova. Odabrani kaotični sustavi su dobro proučeni te je poznato njihovo ponašanje. Ponašanje sustava je bitno jer će sustav proći kroz razna stanja promjenom parametra sustava. Potrebno je dovesti sustav u kaotično područje odabirom odgovarajućeg parametra sustava te odabrati signale generirane samo u tom području.

Upotrebom optimiranih kaotičnih sljedova primijećena su poboljšanja u performancama preko učestalosti pogreške bita te veličine verzora pogreške. Učestalost pogreške bita je najčešća mjera performanci sustava jer pokazuje utjecaj cijelog put od izvora informacije, preko odašiljača i kanala do prijamnika. Preko vrijednosti učestalosti pogreške bita vidi se kvaliteta i mogućnosti modulacijskih i sinkronizacijskih postupaka.

U komunikacijskim sustavima, za ispravan i kvalitetan rad, potrebno je sinkronizirati parametre odašiljača i prijamnika. Između odašiljača i prijamnika, na korisni signal, djeluje kanal svojim slučajnim izobličenjima. Prijamnik mora imati neku referencu kako bi mogao detek-

tirati utjecaj kanala na signal od promjene signala kroz modulacijski postupak. U digitalnim komunikacijskim sustavima najčešće se prenose referentni simboli unutar korisne informacije. Referentni simboli poznati su odašiljaču i prijamniku i trebali bi imati dobra autokorelacijska svojstva kako bi detektirali sva izobličenja u kanalu. Drugi doprinos ovog rada jest odabir sljedova generiranih iz kaotičnih sustava koji imaju dobra autokorelacijska svojstva. Sljedovi su generirani i optimirani već pri generiranju sljedova za proširenje te je bilo potrebno prilagoditi duljine za preambulu u okviru podataka. Pokazalo se da tako optimirani kaotični sljedovi poboljšavaju performance sinkronizacije. Kao mjera performanci za sinkronizaciju uzeta je veličina verzora pogreške koja pokazuje kvalitetu demoduliranog signala, odnosno u toj su vrijednosti sadržani sva rezidualna izobličenja zaostala nakon sinkronizacije. Isto tako sinkronizacijski slijed korišten u bloku za procjenu kanala gdje se pokazalo da poboljšava performance sklopa za izjednačavanje. Dodatno se promataralo i vrijednosti pogreške frekvencije i faze kao mjere performanci sinkronizacijskog slijeda.

Kako bi se svi sljedovi mogli evaluirati i usporediti performance kao treći doprinos izveden je model laboratorijskog prototipa komunikacijskog sustava s kaotičnim sljedovima izveden na platformi programski određenog radija. Sam model pokazuje mogućnosti platforme programski određenog radija kao temelja za razvoj budućih i poboljšanje postojećih radijskih komunikacijskih sustava. Hipoteza da će se performance poboljšati korištenjem kaotičnih sljedova provjerene su na višekorisničkom modelu komunikacijskog sustava. Sam sustav je modeliran prema normi za radijske senzorske mreže kako bi se mogle usporediti performance sa stvarnim sustavom. Provjerene su performance svih kaotičnih sljedova za proširenje pojasa te pripadajućih sinkronizacijskih sljedova. Dobiveni rezultati potvrdili su da kaotični sljedovi poboljšavaju performance stvarnog radijskog sustava.

Rezultati po potvrdili postavljene hipoteze o povezanosti Golayevog korelacijskog faktora i performanci sljedova za proširenje pojasa. Sljedovi s većim iznosom Golayevog faktora pokazuju bolje performance u programski određenom radijskom sustavu. Očekivano, dulji sljedovi pokazivali su bolje performance zbog povećane otpornosti na šum i izobličenja. Kaotični sljedovi generirani Čebiševljevim iteratorom, a koji su generirani s najvećim vrijednostima Golayevog faktora, pokazivali su najbolje performance. U odnosu na Gold sljedove koji se koriste za proširenje pojasa u izvornoj normi, svi kaotični sljedovi poboljšali su performance sustava.

Daljnje istraživanje može se odvijati u više smjerova. Jedan je optimiranje kaotičnih sljedova prije generiranja promatranjem karakteristika spektra i korelacijskih parametara. Prepoznavanjem nekih karakterističnih obilježja moglo bi se pronaći sljedove koji bi omogućili daljnje poboljšanje performanci. Drugi smjer bi bio optimiranje samog modela kako bi se poboljšala brzina izvođenja te ostvarila bolja sinkronizacija između uređaja programski određenog radija.

Literatura

[1] Pecora, L. M., Carroll, T. L., “Synchronization in chaotic systems”, Physical review letters, Vol. 64, No. 8, 1990, str. 821.

[2] Kaddoum, G., “Wireless chaos-based communication systems: A comprehensive survey”, IEEE Access, Vol. 4, 2016, str. 2621–2648.

[3] Short, K. M., “Steps toward unmasking secure communications”, International Journal of Bifurcation and Chaos, Vol. 4, No. 04, 1994, str. 959–977.

[4] Yang, T., Chua, L. O., “Impulsive control and synchronization of nonlinear dynamical systems and application to secure communication”, International Journal of Bifurcation and Chaos, Vol. 7, No. 03, 1997, str. 645–664.

[5] Chua, L., “Dynamic nonlinear networks: State-of-the-art”, IEEE Transactions on Circuits and Systems, Vol. 27, No. 11, 1980, str. 1059–1087.

[6] Yang, T., “A survey of chaotic secure communication systems”, International journal of computational cognition, Vol. 2, No. 2, 2004, str. 81–130.

[7] Cuomo, K. M., Oppenheim, A. V., “Circuit implementation of synchronized chaos with applications to communications”, Physical review letters, Vol. 71, No. 1, 1993, str. 65.

[8] Kaddoum, G., “Design and performance analysis of a multiuser ofdm based differential chaos shift keying communication system”, IEEE Transactions on Communications, Vol. 64, No. 1, 2016, str. 249–260.

[9] Yang, H., Tang, W. K., Chen, G., Jiang, G.-P., “System design and performance analysis of orthogonal multi-level differential chaos shift keying modulation scheme”, IEEE Transactions on Circuits and Systems I: Regular Papers, Vol. 63, No. 1, 2016, str. 146–156.

[10] Wang, L., Cai, G., Chen, G. R., “Design and performance analysis of a new multiresolution m-ary differential chaos shift keying communication system”, IEEE Transactions on Wireless Communications, Vol. 14, No. 9, 2015, str. 5197–5208.

[11] Cheng, G., Wang, L., Chen, Q., Chen, G., "Design and performance analysis of generalised carrier index m-ary differential chaos shift keying modulation", IET Communications, 2018.

[12] Kaddoum, G., Tadayon, N., "Differential chaos shift keying: A robust modulation scheme for power-line communications", IEEE Transactions on Circuits and Systems II: Express Briefs, Vol. 64, No. 1, 2017, str. 31–35.

[13] Kim, E., Yang, I., Lee, D., "Time-delay robust nonlinear dynamic inversion for chaos synchronization with application to secure communications", Mathematical Problems in Engineering, Vol. 2015, 2015.

[14] Subashini, V., Poornachandra, S., "Chaos based image encryption using bogdanov map", Journal of Computational and Theoretical Nanoscience, Vol. 14, No. 9, 2017, str. 4508–4514.

[15] Fontes, R. T., Eisencraft, M., "A digital bandlimited chaos-based communication system", Communications in Nonlinear Science and Numerical Simulation, Vol. 37, 2016, str. 374–385.

[16] Yao, J.-L., Li, C., Ren, H.-P., Grebogi, C., "Chaos-based wireless communication resisting multipath effects", Physical Review E, Vol. 96, No. 3, 2017, str. 032226.

[17] Kaddoum, G., Soujeri, E., Nijsure, Y., "Design of a short reference noncoherent chaos-based communication systems", IEEE Transactions on Communications, Vol. 64, No. 2, 2016, str. 680–689.

[18] Çavuşoğlu, Ü., Akgül, A., Zengin, A., Pehlivan, I., "The design and implementation of hybrid rsa algorithm using a novel chaos based rng", Chaos, Solitons & Fractals, Vol. 104, 2017, str. 655–667.

[19] Çavuşoğlu, Ü., Kaçar, S., Zengin, A., Pehlivan, I., "A novel hybrid encryption algorithm based on chaos and s-aes algorithm", Nonlinear Dynamics, Vol. 92, No. 4, 2018, str. 1745–1759.

[20] Hu, X., Yang, X., Shen, Z., He, H., Hu, W., Bai, C., "Chaos-based partial transmit sequence technique for physical layer security in ofdm-pon", IEEE Photonics Technology Letters, Vol. 27, No. 23, 2015, str. 2429–2432.

[21] Stoyanov, B., Kordov, K., "Novel image encryption scheme based on chebyshev polynomial and duffing map", The Scientific World Journal, 2014.

[22] Xu, L., Li, Z., Li, J., Hua, W., "A novel bit-level image encryption algorithm based on chaotic maps", Optics and Lasers in Engineering, Vol. 78, 2016, str. 17–25.

[23] Al-Hussaibi, W., "Effect of filtering on the synchronization and performance of chaos-based secure communication over rayleigh fading channel", Communications in Nonlinear Science and Numerical Simulation, Vol. 26, No. 1-3, 2015, str. 87–97.

[24] Eisencraft, M., Attux, R., Suyama, R., Chaotic signals in digital communications. CRC Press, 2018.

[25] Tam, W. M., Lau, F. C.-M., Tse, C., Lawrance, A. J., "Exact analytical bit error rates for multiple access chaos-based communication systems", IEEE Transactions on Circuits and Systems II: Express Briefs, Vol. 51, No. 9, 2004, str. 473–481.

[26] Delgado-Restituto, M., Rodriguez-Vazquez, A., "Mixed-signal map-configurable integrated chaos generator for chaotic communications", IEEE Transactions on Circuits and Systems I: Fundamental Theory and Applications, Vol. 48, No. 12, 2001, str. 1462–1474.

[27] Pareschi, F., Setti, G., Rovatti, R., "Implementation and testing of high-speed cmos true random number generators based on chaotic systems", IEEE transactions on circuits and systems I: regular papers, Vol. 57, No. 12, 2010, str. 3124–3137.

[28] Wang, Z., Saraf, N., Bazargan, K., Scheel, A., "Randomness meets feedback: Stochastic implementation of logistic map dynamical system", in Design Automation Conference (DAC), 2015 52nd ACM/EDAC/IEEE. IEEE, 2015, str. 1–7.

[29] Nejati, H., Beirami, A., Ali, W. H., "Discrete-time chaotic-map truly random number generators: design, implementation, and variability analysis of the zigzag map", Analog Integrated Circuits and Signal Processing, Vol. 73, No. 1, 2012, str. 363–374.

[30] Kaddoum, G., Soujeri, E., "Nr-dcsk: A noise reduction differential chaos shift keying system", IEEE Transactions on Circuits and Systems II: Express Briefs, Vol. 63, No. 7, 2016, str. 648–652.

[31] Li, S., Alvarez, G., Li, Z., Halang, W. A., "Analog chaos-based secure communications and cryptanalysis: a brief survey", arXiv preprint arXiv:0710.5455, 2007.

[32] Feng, J.-c., Chi, K. T., "On-line adaptive chaotic demodulator based on radial-basis-function neural networks", Physical Review E, Vol. 63, No. 2, 2001, str. 026202.

[33] Parlitz, U., Chua, L. O., Kocarev, L., Halle, K., Shang, A., "Transmission of digital signals by chaotic synchronization", International Journal of Bifurcation and Chaos, Vol. 2, No. 04, 1992, str. 973–977.

[34] Mazzini, G., Setti, G., Rovatti, R., “Chaotic complex spreading sequences for asynchronous ds-cdma. i. system modeling and results”, Circuits and Systems I: Fundamental Theory and Applications, IEEE Transactions on, Vol. 44, No. 10, 1997, str. 937–947.

[35] Rovatti, R., Setti, G., Mazzini, G., “Chaotic complex spreading sequences for asynchronous ds-cdma. part ii. some theoretical performance bounds”, Circuits and Systems I: Fundamental Theory and Applications, IEEE Transactions on, Vol. 45, No. 4, 1998, str. 496–506.

[36] Setti, G., Rovatti, R., Mazzini, G., “Synchronization mechanism and optimization of spreading sequences in chaos-based ds-cdma systems”, IEICE Transactions on Fundamentals of Electronics, Communications and Computer Sciences, Vol. 82, No. 9, 1999, str. 1737–1746.

[37] Rahnama, N., Talebi, S., “Performance comparison of chaotic spreading sequences generated by two different classes of chaotic systems in a chaos-based direct sequence code division multiple access system”, Communications, IET, Vol. 7, No. 10, 2013, str. 1024–1031.

[38] Rovatti, R., Setti, G., Mazzini, G., “Chaos-based spreading compared to m-sequences and gold spreading in asynchronous cdma communication systems”, in 13th European Conference on Circuit Theory and Design (ECCTD’97). ECCTD, 1997, str. 312–317.

[39] Cimatti, G., Rovatti, R., Setti, G., “Chaos-based spreading in ds-uwb sensor networks increases available bit rate”, IEEE Transactions on Circuits and Systems I: Regular Papers, Vol. 54, No. 6, 2007, str. 1327–1339.

[40] Kohda, T., Tsuneda, A., “Pseudonoise sequences by chaotic nonlinear maps and their correlation properties”, IEICE Transactions on Communications, Vol. 76, No. 8, 1993, str. 855–862.

[41] Stojanovski, T., Kocarev, L., Harris, R., “Applications of symbolic dynamics in chaos synchronization”, IEEE Transactions on Circuits and Systems I: Fundamental Theory and Applications, Vol. 44, No. 10, 1997, str. 1014–1018.

[42] Maggio, G. M., Reggiani, L., “Pseudo-chaotic communication method exploiting symbolic dynamics”, uS Patent 6,882,689. Apr. 19 2005.

[43] Hao, B.-L., Zheng, W.-M., Applied symbolic dynamics and chaos. World scientific, 1998, Vol. 7.

[44] Zvonar, Z., Mitola, J., Software radio technologies: selected readings. Wiley-IEEE Press, 2001.

[45] Valerio, D., “Open source software-defined radio: A survey on gnuradio and its applications”, Forschungszentrum Telekommunikation Wien, Vienna, Technical Report FTW-TR-2008-002, 2008.

[46] Tuttlebee, W. H., Software defined radio: enabling technologies. John Wiley & Sons, 2003.

[47] Collins, T. F., Getz, R., Pu, D., Wyglinski, A. M., Software Defined Radio for Engineers. Artech House, 2018.

[48] Mitola, J., “The software radio architecture”, IEEE Communications magazine, Vol. 33, No. 5, 1995, str. 26–38.

[49] Wyglinski, A. M., Pu, D., Digital communication systems engineering with software-defined radio. Artech House, 2013.

[50] Parker, T. S., Chua, L. O., “Chaos: A tutorial for engineers”, Proceedings of the IEEE, Vol. 75, No. 8, 1987, str. 982–1008.

[51] Devaney, R. L., “An introduction to chaotic dynamical systems”, 2003.

[52] Stewart, I., Kocka li se Bog?: nova matematika kaosa. Jesenski i Turk, 2013.

[53] Strogatz, S. H., Nonlinear dynamics and chaos: with applications to physics, biology, chemistry, and engineering. CRC Press, 2018.

[54] Moon, F. C., Chaotic and fractal dynamics: introduction for applied scientists and engineers. John Wiley & Sons, 2008.

[55] Gleick, J., Chaos: Making a new science. Open Road Media, 2011.

[56] Heidari-Bateni, G., McGillem, C., “Chaotic sequences for spread spectrum: An alternative to pn-sequences”, in Wireless Communications, 1992. Conference Proceedings., 1992 IEEE International Conference on Selected Topics in. Vancouver, BC, Canada: IEEE, 1992, str. 437–440.

[57] Dedieu, H., Kennedy, M. P., Hasler, M., “Chaos shift keying: modulation and demodulation of a chaotic carrier using self-synchronizing chua’s circuits”, Circuits and systems II: Analog and digital signal processing, IEEE Transactions on, Vol. 40, No. 10, 1993, str. 634–642.

[58] Kolumban, G., “Differential chaos shift keying: A robust coding for chaotic communication”, in Proc. 4th Int. Workshop on Nonlinear Dynamics of Electronic Systems, 1996, str. 87–92.

[59] Sklar, B., Digital communications. Prentice Hall Upper Saddle River, 2001, Vol. 2.

[60] Haykin, S. S., Moher, M., Koilpillai, D., "Modern wireless communications". Pearson Education, 2005.

[61] Gold, R., "Optimal binary sequences for spread spectrum multiplexing (corresp.)", IEEE Transactions on information theory, Vol. 13, No. 4, 1967, str. 619–621.

[62] "Ieee standard for local and metropolitan area networks– part 15.4: Low-rate wireless personal area networks (lr-wpans)–amendment 5: Physical layer specifications for low energy, critical infrastructure monitoring networks.", IEEE Std 802.15.4k-2013 (Amendment to IEEE Std 802.15.4-2011 as amended by IEEE Std 802.15.4e-2012, IEEE Std 802.15.4f-2012, IEEE Std 802.15.4g-2012, and IEEE Std 802.15.4j-2013), Aug 2013, str. 1-149.

[63] Kuorilehto, M., Kohvakka, M., Suhonen, J., Hämäläinen, P., Hännikäinen, M., Hamalainen, T. D., Ultra-low energy wireless sensor networks in practice: Theory, realization and deployment. John Wiley & Sons, 2008.

[64] Loo, J., Mauri, J. L., Ortiz, J. H., Mobile ad hoc networks: current status and future trends. CRC Press, 2016.

[65] Novosel, L., "Osnovni principi rada i upotreba softverski definiranog radija u radijskim komunikacijskim sustavima".

[66] Li, B., "Analysis and design of software defined radio", in Internet Computing & Information Services (ICICIS), 2011 International Conference on. IEEE, 2011, str. 415–418.

[67] Lian, D., "Analysis of designing software defined radio", in Electrical and Control Engineering (ICECE), 2010 International Conference on. IEEE, 2010, str. 2663–2666.

[68] Goeller, L., Tate, D., "A technical review of software defined radios: Vision, reality, and current status", in Military Communications Conference (MILCOM), 2014 IEEE. IEEE, 2014, str. 1466–1470.

[69] "Ettus Research: Test report: SBX without UHD corrections", http://files.ettus.com/performance_data/sbx/SBX-without-UHD-corrections.pdf, accessed 30 Mar 2017.

[70] Oppermann, I., Vucetic, B. S., "Complex spreading sequences with a wide range of correlation properties", Communications, IEEE Transactions on, Vol. 45, No. 3, 1997, str. 365–375.

[71] Golay, M. J., "The merit factor of long low autocorrelation binary sequences (corresp.)", Information Theory, IEEE Transactions on, Vol. 28, No. 3, 1982, str. 543–549.

[72] Francois, M., Grosges, T., Barchiesi, D., Erra, R., "A new pseudo-random number generator based on two chaotic maps", Informatica, Vol. 24, No. 2, 2013, str. 181–197.

[73] Al-shameri, W. F. H., Mahiub, M. A., "Some dynamical properties of the family of tent maps", 2013.

[74] Novosel, L., Šišul, G., "Performance evaluation of chaotic spreading sequences on software-defined radio", EURASIP Journal on Wireless Communications and Networking, Vol. 2017, No. 1, Apr 2017, str. 80, dostupno na: https://doi.org/10.1186/s13638-017-0866-7

[75] Mengali, U., Synchronization techniques for digital receivers. Springer Science & Business Media, 2013.

[76] Proakis, J., Salehi, M., "Digital communications, (mcgrawhill, new york, 2008)", Google Scholar.

[77] Oerder, M., Meyr, H., "Digital filter and square timing recovery", IEEE Transactions on communications, Vol. 36, No. 5, 1988, str. 605–612.

[78] Rappaport, T. S. *et al.*, Wireless communications: principles and practice. prentice hall PTR New Jersey, 1996, Vol. 2.

[79] Georgiadis, A., "Gain, phase imbalance, and phase noise effects on error vector magnitude", IEEE Transactions on Vehicular Technology, Vol. 53, No. 2, 2004, str. 443–449.

Popis oznaka

AWGN Additive White Gaussian Noise

BER Bit Error Rate

CDMA Code Division Multiple Access

CRC Cyclic Redundancy Check

CSK Chaotic Shift Keying

DSSS Direct Sequence Spread Spectrum

EVM Error Vector Magnitude

FDMA Frequency Division Multiple Access

FEC Forward Error Correction

FIR Finite Impulse Response

FPGA Field-programmable Gate Array

FSK Frequency Shift keying

FSSS Frequency Hopping Spread Spectrum

GPS Global Positioning System

HR-WPAN High Rate-Wireless Personal Area Networks

IEEE The Institute of Electrical and Electronics Engineers

LR-WPAN Low Rate-Wireless Personal Area Networks

MAC Media Access Control

MAI Multiple Access Interference

MCSS Multicarrier Spread Spectrum

MR-WPAN Medium Rate-Wireless Personal Area Networks

MSACF Mean Square Auto Correlation Function

MSCCF Mean Square Cross Correlation Function

MSK Minimum Shift Keying

PPDU PHY Protocol Data Unit

PSK Phase Shift Keying

QAM Quadrature Amplitude Modulation

SCSI Small Computer System Interface

SDR Software Define Radio

SFD Start of Frame Delimiter

SFDR Spurious-free Dynamic Range

SHR Synchronization Header

SINR Signal-to-interference-plus-noise Ratio

SNR Signal-to-noise Ratio

TDMA Time Division Multiple Access

THSS Time Hopping Spread Spectrum

USRP Universal Softvare Radio Peripheral

WPAN Wireless Personal Area Networks

Popis slika

2.1. Putanje s različitim početnim uvjetima 7
2.2. Atraktor oblika leptirovih krila za Lorenzov sustav 8
2.3. Bifurkacijski dijaram za populacijski iterator 10
2.4. Promjena Ljapunovljevog eksponenta za populacijski iterator 12

3.1. Model sustava s višestrukim pristupom po kodu za K korisnika 18
3.2. Degradacija uslijed interferencije višestrukog pristupa uz 5 korisnika i promjenjivi odnos E_b/N_0 21
3.3. Degradacija uslijed interferencije višestrukog pristupa uz E_b/N_0 = 10 dB i različit broj korisnika 21
3.4. Generiranje Gold sljedova 24
3.5. Postupak sinkronizacije slijeda za proširenje 25
3.6. Sinkronizacija slijeda iznad zadanog praga izvedena za programski određeni radio 26
3.7. Detekcija korisnika u višekorisničkom sustavu 26

4.1. Topologija zvijezde 28
4.2. Topologija ravnopravnih čvorova 28
4.3. Model odašiljača 30
4.4. Model prijamnika 30
4.5. Osnovni dijelovi sustava arhitekture programski određenog radija 33
4.6. Spektar signala širine $2B$ oko frekvencije f_c 34
4.7. Generiranje signala s kompleksnom ovojnicom 35
4.8. Obnavljanje signala s kompleksnom ovojnicom 36
4.9. USRP arhitektura, preuzeto iz [69] 36
4.10. Curenje lokalnog oscilatora na USRP platformi 36
4.11. Priprema paketa za odašiljanje 37
4.12. Postavljanje parametara PSK modulacije 38
4.13. Višekorisnički sustav s višestrukim pristupom po kodu 39
4.14. Odašiljački i prijamni program za upravljanje USRP uređajima 40
4.15. Niskopropusni filtar prije demodulacije 40

4.16. Provjera slijeda za proširenje i sinkronizacija slijeda 40
4.17. Sažimanje pojasa podimpuls po podimpuls 41
4.18. PSK demodulacija, sinkronizacija i mjerenje parametara za procjenu performanci 41
4.19. Sinkronizacija početka paketa te diferencijalno i konvolucijsko dekodiranje . . 41

5.1. Promjena GF za iterator šatorsko krilo za slijed duljine 32 47
5.2. Promjena GF za iterator šatorsko krilo za slijed duljine 64 47
5.3. Promjena GF za iterator šatorsko krilo za slijed duljine 128 48
5.4. Promjena GF za populacijski iterator za slijed duljine 32 48
5.5. Promjena GF za populacijski iterator za slijed duljine 64 49
5.6. Promjena GF za populacijski iterator za slijed duljine 128 49
5.7. Promjena GF za Čebiševljev iterator za slijed duljine 32 50
5.8. Promjena GF za Čebiševljev iterator za slijed duljine 64 50
5.9. Promjena GF za Čebiševljev iterator za slijed duljine 128 51
5.10. Izgled autokorelacijske funkcije za slijed generiran Čebiševljevim iteratorom . 52
5.11. Izgled autokorelacijske funkcije za Gold slijed 53
5.12. Izgled autokorelacijske funkcije za sljedove generirane Čebiševljevim iteratorom uz nisku vrijednost *GF* 53
5.13. Izgled križnokorelacijske funkcije za sljedove generirane Čebiševljevim iteratorom 54
5.14. Izgled križnokorelacijske funkcije za Gold sljedove 55
5.15. Izgled križnokorelacijske funkcije za sljedove generirane Čebiševljevim iteratorom uz nisku vrijednost *GF* 55

6.1. Koherentni PSK prijamnik 61
6.2. Procjena frekvencije nosioca izvedena za programski određeni radio 64
6.3. Procjena faze u modelu za programski određeni radio 65
6.4. Procjena takta uzorkovanja u modelu za programski određeni radio 66
6.5. Procjena kanala u modelu za programski određeni radio 67

7.1. Primopredajni sustav programski određenih radija 69
7.2. Ovisnost snage na prijamniku u odnosu na pojačanje izlaznog pojačala 71
7.3. Učestalost pogreške bita u odnosu na snagu na ulazu u prijamnik za sljedove duljine 32 72
7.4. Učestalost pogreške bita u odnosu na snagu na ulazu u prijamnik za sljedove duljine 64 73
7.5. Učestalost pogreške bita u odnosu na snagu na ulazu u prijamnik za sljedove duljine 128 73
7.6. Učestalost pogreške bita za sljedove duljine 32, preuzeto iz [74] 76

7.7. Učestalost pogreške bita za sljedove duljine 64, preuzeto iz [74] 77
7.8. Učestalost pogreške bita za sljedove duljine 128, preuzeto iz [74] 78
7.9. Učestalost pogreške bita za sljedove za proširenje duljine 32 uz duljinu slijeda za sinkronizaciju 16 79
7.10. Učestalost pogreške bita za sljedove za proširenje duljine 32 uz duljinu slijeda za sinkronizaciju 32 79
7.11. Učestalost pogreške bita za sljedove za proširenje duljine 64 uz duljinu slijeda za sinkronizaciju 16 80
7.12. Učestalost pogreške bita za sljedove za proširenje duljine 64 uz duljinu slijeda za sinkronizaciju 32 81
7.13. Učestalost pogreške bita za sljedove za proširenje duljine 128 uz duljinu slijeda za sinkronizaciju 16 81
7.14. Učestalost pogreške bita za sljedove za proširenje duljine 128 uz duljinu slijeda za sinkronizaciju 32 82
7.15. Prikaz veličine verzora pogreške 83
7.16. Veličina verzora pogreške za sljedove za proširenje duljine 32 i duljinom sinkronizacijskog zaglavlja 16 bita 85
7.17. Veličina verzora pogreške za sljedove za proširenje duljine 32 i duljinom sinkronizacijskog zaglavlja 32 bita 86
7.18. Pogreška izjednačavanja za sljedove za proširenje duljine 32 i duljinom sinkronizacijskog zaglavlja 16 bita 86
7.19. Pogreška izjednačavanja za sljedove za proširenje duljine 32 i duljinom sinkronizacijskog zaglavlja 32 bita 87
7.20. Pogreška faze za sljedove za proširenje duljine 32 i duljinom sinkronizacijskog zaglavlja 16 bita 87
7.21. Pogreška faze za sljedove za proširenje duljine 32 i duljinom sinkronizacijskog zaglavlja 32 bita 88
7.22. Rezidualna pogreška frekvencije za sljedove za proširenje duljine 32 i duljinom sinkronizacijskog zaglavlja 16 bita 88
7.23. Rezidualna pogreška frekvencije za sljedove za proširenje duljine 32 i duljinom sinkronizacijskog zaglavlja 32 bita 89
7.24. Usporedba EVM za sljedove za proširenje duljine 32 i duljinom sinkronizacijskog zaglavlja 16 i 32 bita 89
7.25. Usporedba EVM za sljedove za proširenje duljine 32 i duljinom sinkronizacijskog zaglavlja 32 bita 90
7.26. Usporedba pogreške izjednačavanja za sljedove za proširenje duljine 32 i duljinom sinkronizacijskog zaglavlja 16 i 32 bita 90

7.27. Usporedba pogreške izjednačavanja za sljedove za proširenje duljine 32 i 64 i duljinom sinkronizacijskog zaglavlja 32 bita 91
7.28. Usporedba rezidualne pogreške faze za sljedove za proširenje duljine 32 i duljinom sinkronizacijskog zaglavlja 16 i 32 bita 92
7.29. Usporedba rezidualne pogreške faze za sljedove za proširenje duljine 32 i 64 i duljinom sinkronizacijskog zaglavlja 32 bita 92
7.30. Usporedba rezidualnog pomaka frekvencije za sljedove za proširenje duljine 32 i duljinom sinkronizacijskog zaglavlja 16 i 32 bita 93
7.31. Usporedba rezidualnog pomaka frekvencije za sljedove za proširenje duljine 32 i 64 i duljinom sinkronizacijskog zaglavlja 32 bita 93

Popis tablica

4.1. Okvir podatka 29
4.2. Izgled polja preambule i početka okvira 29

5.1. Korelacijski parametri sljedova uz promjenjive parametare sustava 56
5.2. Korelacijski parametri sljedova s visokom vrijednošću parametra sustava μ . . 57

7.1. Usporedba specifikacija uređaja programski određenog radija 69

Životopis

Leonard Novosel rođen je 12. siječnja 1987. godine u Zagrebu. Pohađao je Osnovnu školu Markuševec te XV. gimnaziju u Zagrebu. Po završetku srednje škole upisuje Fakultet elektrotehike i računarstva Sveučilišta u Zagrebu. Diplomirao je 2013. godine na profilu Radiokomunikacijske tehnologije pod mentorstvom prof. dr. sc. Gordana Šišula s temom *Analiza radijskog sučelja u tehnologiji LTE*.

Od listopada 2013. godine zaposlen je kao asistent na Zavodu za radiokomunikacije Fakulteta elektrotehnike i računarstva. Poslijediplomski studij upisao je 2013. godine pod mentorstvom prof. dr sc. Gordana Šišula.

Sudjeluje u izvođenju laboratorijskih i auditornih vježbi na više kolegija, među kojima su Planiranje mobilnih sustava, Elektroničke komunikacije, Mobilne komunikacije i Radijske pristupne mreže. Objavio je više radova na konferencijama te znanstveni rad iz područja obrade signala i radiokomunikacija.

Osnovno područje interesa je optimiranje i poboljšanje performanci programski određenih radijskih komunikacijskih sustava korištenjem kaosa i nelinearne dinamike te mjerenja propagacijskih karakteristika kanala korištenjem programski određenog radija.

Popis objavljenih djela

Rad u časopisima

1. Novosel, L., Šišul, G. "Performance evaluation of chaotic spreading sequences on software-defined radio", Eurasip journal on wireless communications and networking, 80-1-80, 2017, Rad iz područja doktorskog istraživanja

Rad u zbornicima skupova s međunarodnom recenzijom

1. Novosel, L., Šišul G. "Chaotic Direct Sequence Spread Spectrum Software Defined Radio System Model Using LabView", Proceedings ELMAR-2016 Muštra, Mario ; Tralić, Dijana ; Zovko-Cihlar, Branka (ur.), Zagreb: Croatian Society in Marine - ELMAR, 2016. 257-260

2. Novosel, L., Šišul G. "Performance evaluation of chaotic sequences for DSSS multiple access on software defined radio", ICECom 2016, Conference Proceedings / Bonefačić, Davor ; Šipuš, Zvonimir (ur.), Zagreb: KoREMA - Croatian Society for Communications, Computing, Electronics, Measurement and Control, 2016.,
3. Novosel, L., Šišul G. "Software defined radio DSSS system model using 1/f noise as spreading sequence", Proceedings ELMAR-2015 / Muštra, Mario ; Tralić, Dijana ; Zovko-Cihlar, Branka (ur.), Zagreb: Croatian Society in Marine - ELMAR, 2015. 9-12
4. Novosel, L., Šišul G. Comparison of pseudo noise sequence lengths for a correlator channel sounder, Proceedings of ELMAR-2014 / Tralić, Dijana ; Muštra, Mario ; Cihlar-Zovko, Branka (ur.), Zagreb: Croatian Society in Marine - ELMAR, 2014. 135-138

Biography

Leonard Novosel was born January 12, 1987 in Zagreb, Croatia. He attended elementary school and high school in Zagreb. Upon finishing high school, he enrolled in the Faculty of Electrical Engineering and Computing at the University of Zagreb. He graduated in 2013 on the profile Wireless Technologies under the supervision of prof. dr. sc. Gordan Šišul with the theme Analysis of the LTE wireless interface.

Since October 2013 he has been employed as an assistant at the Department of Wireless Communications of the Faculty of Electrical Engineering and Computing and started PhD in electrical engineering under the supervision of prof. dr. sc. Gordan Šišul.

He is participating in several courses, including Mobile Systems Planning, Electronic Communications, Mobile Communications and Radio Access Networks. He has published several papers at conferences and scientific journals in the field of signal processing and radio communication. The primary area of interest is the optimization and performance improvement of software defined radio communication systems using chaos and nonlinear dynamics and channel propagation characteristics measurements using software defined radio.