

ՀԱՅԱՍՏԱՆԻ ԱԶԳԱՅԻՆ ՊՈԼԻՏԵԽՆԻԿԱԿԱՆ ՀԱՄԱԼՍԱՐԱՆ

Թանթուշյան Արամ Միքայելի

Հեռահաղորդակցական ցանցերում ազդանշանների
մոդուլացման տեսակների նույնականացման մեթոդի
մշակումը և հետազոտումը

ԱՏԵՆԱԽՈՍՈՒԹՅՈՒՆ

Ե.12.03 - «Հեռահաղորդակցական ցանցեր, սարքավորումներ և
համակարգեր» մասնագիտությամբ տեխնիկական
գիտությունների թեկնածուի գիտական աստիճանի համար

Գիտական ղեկավար՝ ֆ.-մ. գ. դ., պրոֆեսոր,
ՀՀ ԳԱԱ ակադեմիկոս Ա.Գ. Ղուլյան

Բովանդակություն

ՆԵՐԱԾՈՒԹՅՈՒՆ.....	4
ԳԼՈՒԽ 1. ՄԱՆ ՈԼՈՐՏՈՒՄ ՆԱԽԿԻՆՈՒՄ ԿԱՏԱՐՎԱԾ ՀԵՏԱԶՈՏՈՒԹՅՈՒՆՆԵՐԸ.....	9
1.1 Անալոգային մոդուլացումների նույնականացման ալգորիթմներ.....	11
1.2 Թվային մոդուլացումների նույնականացման ալգորիթմներ.....	12
1.3 Անալոգային և թվային մոդուլացման տեսակների զուգահեռ նույնականացման ալգորիթմներ.....	13
1.4 Արհեստական նեյրոնային ցանցերի միջոցով մոդուլացման տեսակների նույնականացման ալգորիթմներ.....	14
ԳԼՈՒԽ 2. ՄԱՆ ՄԵԹՈԴՆԵՐՈՒՄ ԿԻՐԱՌՎՈՂ ՏՎՅԱԼՆԵՐԻ ՆՈՒՅՆԱԿԱՆԱՑՄԱՆ ՏԵԽՆՈԼՈԳԻԱՆԵՐԸ ԵՎ ԴՐԱՆՑ ՀԱՄԵՄԱՏԱԿԱՆ ՎԵՐԼՈՒԾՈՒԹՅՈՒՆԸ.....	17
2.1 Տվյալների նույնականացման տեխնոլոգիաների նկարագրությունը.....	18
2.1.1 Արհեստական նեյրոնային ցանցեր.....	30
2.1.1.1 Մխալանքի հակադարձ տարածում.....	36
2.1.1.2 ԱՆՑ կիրառումը ՄԱՆ համակարգերում.....	38
2.2 Նույնականացման մեթոդների համեմատական վերլուծություն և մեթոդի ընտրություն.....	40
ԳԼՈՒԽ 3. ԴԻՏԱՐԿՎՈՂ ՍՈՂՈՒԼԱՑՄԱՆ ՏԵՄԱԿՆԵՐԸ ԵՎ ԱԶԴԱՆՇԱՆՆԵՐԻ ՀԻՄՆԱԿԱՆ ԲՆՈՒԹԱԳՐՈՂ ՀԱՏԿԱՆԻՇՆԵՐԸ.....	43
3.1 Անալոգային մոդուլացման տեսակները.....	43
3.2 Անալոգային մոդուլացված ազդանշանների հիմնական բնութագրող հատկանիշները.....	48
3.2.1 Հզորության սպեկտրալ խտություն՝ Y_{max}	48
3.2.2 Ակնթարթային փուլի կենտրոնացված ոչ զծային բաղադրիչի բացարձակ արժեքի ստանդարտ դեվիացիա՝ $\sigma_{բփ}$	51
3.2.3 Հզորության սպեկտրի համաչափություն՝ P.....	54
3.3 Թվային մոդուլացման տեսակները.....	56
3.4 Թվային մոդուլացված ազդանշանների հիմնական բնութագրող հատկանիշները.....	68
3.4.1 Հզորության սպեկտրալ խտություն՝ Y_{max}	68
3.4.2 Ակնթարթային փուլի կենտրոնացված ոչ զծային կոմպոնենտի բացարձակ արժեքի ստանդարտ դեվիացիա՝ $\sigma_{բփ}$	69
3.4.3 Ակնթարթային փուլի կենտրոնացված ոչ զծային բաղադրիչի ստանդարտ դեվիացիա՝ $\sigma_{փ}$	70

3.4.4 Նորմավորված-կենտրոնացված ակնթարթային ամպլիտուդայի բացարձակ արժեքի ստանդարտ դեվիացիա՝ $\sigma_{բա}$	71
3.4.5 Նորմավորված-կենտրոնացված ակնթարթային հաճախականության բացարձակ արժեքի ստանդարտ դեվիացիա՝ $\sigma_{բհ}$	72
3.4.7 Ակնթարթային փուլի բաշխվածության քանակը՝ $\phi_{բբ}$	75
3.4.8 Ակնթարթային ամպլիտուդայի բաշխվածության քանակը՝ $A_{բբ}$	79
ԳԼՈՒԽ 4. ՄՇԱԿՎԱԾ ՄԵԹՈՂԻ ԾՐԱԳՐԱՅԻՆ ԿՈՂԸ ԵՎ ՓՈՐՁԱՐԱՐԱԿԱՆ ԱՐԴՅՈՒՆՔՆԵՐԸ 83	
4.1 ԱՆՑ բազային մոդելի ալգորիթմը.....	83
4.1.1 ԱՆՑ բազային մոդելի ուսուցումը և թեստավորումը.....	87
4.2 Անալոգային մոդուլացման տեսակների նույնականացումը.....	92
4.3 Թվային մոդուլացման տեսակների նույնականացումը.....	102
ԵԶՐԱԿԱՑՈՒԹՅՈՒՆ.....	105
Գրականության ցանկ.....	108
Հավելված 1.....	116
Օգտագործված հապավումների ցանկ.....	117

ՆԵՐԱԾՈՒԹՅՈՒՆ

Ատենախոսության թեմայի արդիականությունը: Քսանմեկերրորդ դարի տեխնոլոգիաների սրընթաց զարգացմանը զուգահեռ կատարելագործվում և բարելավվում են հեռահաղորդակցական կապի համակարգերը, սարքավորումները, որոնք ավելի լայն և նաև նոր կիրառություն են ստանում զանազան ոլորտներում, ինչպիսիք են օդագնացությունը, բժշկությունը, IoT տեխնոլոգիաները, անօդաչու թռչող սարքերի ոլորտը և այլն [1-4]: Վերոնշյալը առաջացնում է կապի որակի բարելավման, կապի անվտանգության ապահովման, տվյալների հաղորդման արագության բարձրացման և հատկապես ռադիոհաճախականային սպեկտրի արդյունավետ բաշխման և մեծ ծավալի տվյալների փոխանցման խնդիրների լուծմանն ուղղված հետազոտությունների և զարգացման գործընթացների անհրաժեշտություն: Այս մասին է վկայում այն փաստը, որ ներկայումս հեռահաղորդակցական բազմաթիվ խոշոր և աշխարհահռչակ ընկերություններ զբաղվում են «5G» համակարգերի մշակմամբ, ինչի հիմնական մաս է կազմում միլիմետրանոց ալիքների տիրույթը [5]: Միլիմետրանոց ալիքների շերտը համեմատաբար շատ քիչ է օգտագործվում ներկայումս, ինչից հետևում է, որ անցումը միլիմետրանոց ալիքներին համապատասխանող գերբարձր ռադիոհաճախականային տիրույթին հնարավորություն կտա օգտագործել լայն թողունակության շերտեր, հասնել տվյալների հաղորդման շատ բարձր արագությունների և խուսափել միջկանալային ինտերֆերենցիայից:

Ներկայումս խիտ բաշխված ռադիոհաճախականային սպեկտրի պարագայում հեռահաղորդակցական կապի խանգարումները լուրջ խնդիր են առաջացնում կապի համակարգերի այնպիսի տեխնոլոգիաներում, ինչպիսիք են ծրագրավորված ռադիոկապը (SDR) [6] և ճանաչողական ռադիոն (Cognitive radio) [7], և կարող են ճակատագրական դեր խաղալ ռազմական նշանակության կապի ցանցերում:

Ռադիոկապի խանգարումների պատճառ հանդիսացող ազդանշանների հայտնաբերման նպատակով իրականացվող ռադիոհաճախականային սպեկտրի մոնիթորինգի ժամանակ հարկ է լինում հայտնաբերել անհայտ, չլիցենզավորված ռադիոճառագայթող սարքավորման կողմից անօրինականորեն հաղորդվող, ռազմական ռադիոէլեկտրոնային հետախուզման տեսանկյունից «վտանգի» մասին

տեղեկատվություն պարունակող, թշնամու կողմից հաղորդվող ազդանշանները, որոնց մասին առկա չեն սկզբնական տեղեկություններ:

Այս խնդրի կիրառական և արդիական լուծումներից մեկն է հանդիսանում անհայտ հեռահաղորդակցական ազդանշանի այսպես կոչված «կույր» դեմոդուլացումը, ինչի հիմնական բաղկացուցիչ մասն է կազմում անհայտ ազդանշանի մոդուլացման տեսակի նույնականացումը:

Աշխատանքի նպատակը և խնդիրները: Ատենախոսության նպատակն է մշակել հեռահաղորդակցական ազդանշանների անալոզային և թվային մոդուլացման տեսակների ավտոմատացված նույնականացման արդյունավետ, իրական ժամանակում իրագործելի մեթոդ:

Վերոնշյալ նպատակն իրականացնելու համար անհրաժեշտ է եղել լուծել հետևյալ խնդիրները.

1. Ազդանշանի հիմնական բնութագրող հատկանիշների որոշման նպատակով ուսումնասիրել անալոզային և թվային մոդուլացման տեսակների առանձնահատկությունները նկարագրող ֆիզիկական բնութագրերը:

2. Թվային M-PSK, M-QAM մոդուլացման տեսակների համար մշակել այդ ազդանշանների առանձնահատկությունները բնութագրող հիմնական հատկանիշներ:

3. Մոդուլացման տեսակների նույնականացման համար հետազոտել և որոշել տվյալների նույնականացման նպատակահարմար և իրագործելի տեխնոլոգիա:

4. Հիմնավորել ընտրված նույնականացման տեխնոլոգիայի ծրագրային ալգորիթմի իրագործելիությունը LabVIEW գրաֆիկական ծրագրավորման միջավայրում:

5. Մշակել մոդուլացման տեսակների նույնականացման մեթոդի ծրագրային ալգորիթմը, որը հնարավորություն է տալիս իրական ժամանակում գեներացնել մոդուլացված ազդանշանները, իրականացնել ազդանշանների հիմնական բնութագրող հատկանիշների առանձնացումը ազդանշանից և այդ տվյալների հիման վրա՝ համապատասխան ալգորիթմի միջոցով, կատարել մոդուլացման տեսակի նույնականացման գործառույթը:

Գիտական նորույթը:

1. Հետազոտվել են առկա մոդուլացման տեսակների նույնականացման մեթոդները և կատարվել է համեմատական վերլուծություն, ինչի արդյունքում յուրաքանչյուր մեթոդի համար ներկայիս տեխնոլոգիական հնարավորությունների պարագայում սահմանվել են արդյունավետության չափանիշներ, ինչը հնարավորություն է տալիս՝ կախված դրված խնդրի պահանջներից և հնարավոր պայմաններից, կատարել մեթոդի արդյունավետ ընտրության:

2. Մշակվել են թվային M-PSK, M-QAM ազդանշանների նույնականացման համար նախատեսված երեք հիմնական բնութագրող հատկանիշներ, որոնք միաժամանակ կատարում են նաև նախկինում լայն կիրառություն ունեցող այլ մոդուլացման տեսակների նույնականացման համար կիրառվող որոշ այլ հիմնական բնութագրող հատկանիշների գործառույթը: Վերոնշյալը հնարավորություն է տվել տասը թվային մոդուլացման տեսակների նույնականացման համար ութ հիմնական բնութագրերի փոխարեն կիրառել չորսը:

3. Առաջարկվել է տվյալների նույնականացման տեխնոլոգիայի՝ արհեստական նեյրոնային ցանցերի տվյալների նույնականացման արդյունքում վերջնական որոշում կայացնելու նոր մեթոդ, որը հնարավորություն է տալիս խուսափել լրացուցիչ ժամանակատար հաշվարկներից:

4. Մշակվել է անալոգային և թվային մոդուլացման տեսակների զուգահեռ նույնականացման մեթոդ և համապատասխան ծրագրային կոդ:

Պաշտպանությանը ներկայցվող հիմնական դրույթները:

1. Իրականացրած հետազոտությունների և համեմատական վերլուծության արդյունքում սահմանված տվյալների նույնականացման մեթոդի ընտրության չափանիշները ՄԱՆ համակարգերում:
2. Թվային մոդուլացման տեսակների նույնականացման համար մշակված ազդանշանների հիմնական բնութագրող հատկանիշները:
3. Արհեստական նեյրոնային ցանցերի նույնականացման գործառույթի եզրափակիչ որոշման կայացման նոր մեթոդը:

4. Անալոգային և թվային մոդուլացման տեսակների ավտոմատացված նույնականացման մեթոդը և ծրագրային կոդը:

Աշխատանքի տեսական և կիրառական նշանակությունը:

1. Մշակված ծրագրային կոդը կարող է հիմք հանդիսանալ ավելի կատարելագործված՝ FPGA-ի միջոցով հաշվարկներ իրականացնող համակարգի համապատասխան ծրագրային կոդի մշակման համար:

2. Մշակված հիմնական բնութագրող հատկանիշները կարող են կիրառվել առկա մոդուլացումների նույնականացման համակարգերի բարելավման համար:

3. Ատենախոսության մեջ առաջ քաշվող դրույթները կարող են օգտակար լինել Հայաստանի Հանրապետության ռադիո էլեկտրոնային անվտանգությանն ուղղված գործառույթների շրջանակում մշակվող նմանատիպ համակարգերում:

Ստացված արդյունքների ապրոբացիան: Ատենախոսության հիմնական դրույթները զեկուցվել և քննարկվել են ՀԱՊՀ տարեկան գիտաժողովներում (2018-2019):

Ատենախոսության արդյունքների ներդրումը: Սույն ատենախոսության շրջանակներում իրականացրած հետազոտությունների արդյունքում մշակված թվային մոդուլացման տեսակների նույնականացման համար նախատեսված ազդանշանների հիմնական բնութագրող հատկանիշները ներդրվել են OLYMP Engineering LLC ընկերության կողմից Հնդկաստանում հեռահաղորդակցական ցանցերում կիրառվող Blind demodulator համակարգերում, ինչը հնարավորություն է տվել բարելավել նշված համակարգի միջոցով իրականացվող հեռահաղորդակցական ազդանշանների մոդուլացման տեսակների նույնականացման ճշտությունը (Հավելված 1):

Հրատարակված աշխատանքներ: Ատենախոսության նյութով տպագրվել է 6 գիտական հոդված տեղական գիտական ամսագրերում:

Ատենախոսության կառուցվածքն ու ծավալը: Ատենախոսությունը բաղկացած է ներածությունից, 4 գլուխներից, եզրակացությունից, մեկ հավելվածից և օգտագործված գրականության ցանկից, որը ներառում է 92 անուն գրականություն: Ատենախոսությունը շարադրված է 118 էջի վրա, պարունակում է 39 նկար, 9 աղյուսակ: Ատենախոսության առաջին՝ «ՄԱՆ ոլորտում նախկինում կատարված հետազոտությունները» գլխում ներկայացված է ՄԱՆ խնդրի շրջանակներում նախկինում կատարված

աշխատանքների ուսումնասիրությունը: Երկրորդ՝ «ՄԱՆ մեթոդներում կիրառվող տվյալների նույնականացման տեխնոլոգիաները և դրանց համեմատական վերլուծությունը» գլխում նկարագրված են ՄԱՆ խնդրի լուծման համար կիրառվող տվյալների նույնականացման տեխնոլոգիաները և իրականացված համեմատական վերլուծության արդյունքներն ու համապատասխան տեխնոլոգիայի ընտրությունը: Ատենախոսության երրորդ՝ «Դիտարկվող մոդուլացման տեսակները և ազդանշանների հիմնական բնութագրող հատկանիշները» գլխում իրականացվել է այս աշխատանքի շրջանակներում դիտարկվող մոդուլացման տեսակների առանձնահատկությունները բնութագրող ֆիզիկական պարամետրերի ուսումնասիրությունը և ներկայացված են ազդանշանների գոյություն ունեցող և սույն աշխատանքի շրջանակներում նոր մշակված հիմնական բնութագրող հատկանիշները: Չորրորդ՝ «Մշակված մեթոդի ծրագրային կոդը և փորձարարական արդյունքները» գլուխը նվիրված է մշակված ծրագրային կոդի աշխատանքի և դրա միջոցով կատարված փորձերի արդյունքների նկարագրությանը: Եզրակացությունում նշված են իրականացված աշխատանքի արդյունքում ստացված եզրահանգումները:

ԳԼՈՒԽ 1. ՄԱՆ ՈԼՈՐՏՈՒՄ ՆԱԽԿԻՆՈՒՄ ԿԱՏԱՐՎԱԾ ՀԵՏԱԶՈՏՈՒԹՅՈՒՆՆԵՐԸ

ՄԱՆ-ն իրենից ներկայացնում է համակարգ, որն առանց ազդանշանի մոդուլացման տեսակի մասին որևէ տեղեկությունների, կարողանում է ավտոմատացված կերպով ճիշտ որոշել վերջինիս մոդուլացման տեսակը և հայտնել այն դեմոդուլյատորին: ՄԱՆ համակարգերը բաղկացած են երեք հիմնական բլոկերից՝ ազդանշանի մշակման, մոդուլացման տեսակի նույնականացման և ազդանշանի դեմոդուլացման: Ազդանշանի մշակման փուլում համակարգը ընդունված ազդանշանից առանձնացնում է որևէ L տևողությամբ հատված և բաժանում է այն հաջորդական սեգմենտների, որոնց երկարությունն ընտրվում է՝ ելնելով տվյալ խնդրի պահանջներից: Այդ սեգմենտներից յուրաքանչյուրի համար իրականացվում է ազդանշանի հիմնական բնութագրող հատկանիշների առանձնացում: Բարձրակարգ և նպատակահարմար մշակված բնութագրող հատկանիշները ՄԱՆ-ի կարևորագույն առանձնահատկություններն են, քանի որ դրանցից են կախված հետագա նույնականացման ճշտությունը և արդյունավետությունը: Ազդանշանի հիմնական բնութագրող հատկանիշները այնպիսի պարամետրեր են, որոնք յուրաքանչյուր մոդուլացման տեսակի համար հիմնականում ունենում են հստակ արժեքների միջակայք: Նշված հիմնական բնութագրող հատկանիշները ցանկացած ՄԱՆ համակարգի համար կարող են լինել յուրովի մշակված՝ համապատասխան դրված խնդրին: Հնարավոր է, որ երկու տարբեր մոդուլացման տեսակներ ունենան, օրինակ՝ երկու բնութագրող հատկանիշներ, որոնք իրենց հերթին ունենան շատ մոտ արժեքներ, բայց գոյություն չունեն այնպիսի երկու մոդուլացման տեսակներ, որոնց համար բոլոր հիմնական բնութագրող հատկանիշներն ունենան միևնույն արժեքները: Այսպիսով՝ յուրաքանչյուր մոդուլացման տեսակի համար ազդանշանի տարբեր բնութագրերի և SNR-ի արժեքների դեպքում նախօրոք չափվում և որոշվում են հիմնական բնութագրող հատկանիշների արժեքները, այնուհետև իրական ժամանակում կատարված հաշվարկների արդյունքների հիման վրա, նույնականացման ալգորիթմը երկրորդ բլոկում տվյալների նույնականացման տեխնոլոգիայի միջոցով կատարում է մոդուլացման տեսակի նույնականացում և երրորդ բլոկում մոդուլացման տեսակի մասին տեղեկատվությունը փոխանցում է դեմոդուլյատորին:

ՄԱՆ խնդրի հետազոտությունները սկսվել են դեռ անցած դարում: Մոդուլացումների տեսակների ավտոմատացված նույնականացման խնդրի լուծման համար իրենց նշանակալի և կարևորագույն ներդրումն են ունեցել Ե.Ե. Ազգոուզը և Ա.Կ. Նանդին: Նրանք իրենց աշխատանքի մեջ ներկայացրել են ՄԱՆ մեթոդներ և ալգորիթմներ անալոզային և թվային մոդուլացման տեսակների համար [8]: Նշված աշխատանքում նկարագրված է նմուշի ճանաչման և տեսական որոշման մեթոդները: Նկարագրված է նաև մշակված ազդանշանների հիմնական բնութագրող հատկանիշները անալոզային, թվային և համադրված՝ անալոզային և թվային մոդուլացումների նույնականացման ալգորիթմների համար: Այդ աշխատանքում անալոզային, թվային և համադրված անալոզային և թվային մոդուլացման տեսակների համար մշակվել է համապատասխանաբար չորս, հինգ և ինը հիմնական բնութագրող հատկանիշներ: Նրանք նաև մշակել էին մոդուլացումների ավտոմատացված նույնականացման ալգորիթմ օգտագործելով արհեստական նեյրոնային ցանց: Ալգորիթմը մշակվել է մեկ թաքնված շերտով նեյրոնային ցանցերի և երկու թաքնված շերտով ցանցերի համար: Նշված երկու ցանցի տեսակների համար իրականացվել են ՄԱՆ փորձեր, ինչպես նաև կատարվել է ստացված արդյունքների համեմատական վերլուծությունը: Փորձերն իրականացվել են AM, DSB, USB, LSB, FM, 2ASK, 4ASK, 2PSK, 4PSK, 2FSK և 4FSK անալոզային և թվային մոդուլացման տեսակների համար:

Ազգոուզի և Նանդիի կատարած հետազոտությունները, մշակած հիմնական բնութագրող հատկանիշները և ալգորիթմները լուրջ ներդրում են ունեցել մոդուլացումների ավտոմատացված նույնականացման խնդրի լուծման համար և հիմք են հանդիսացել հետագա զարգացված և մշակված այլ ալգորիթմների, մեթոդների և հետազոտությունների համար: Չնայած նրան, որ վերոնշյալ աշխատանքը դրական խթան է ունեցել ՄԱՆ խնդրի լուծման համար, այնուհանդերձ նրանց առաջարկած լուծումը նախատեսված է սահմանափակ քանակի մոդուլացման տեսակների համար և դրանում օգտագործված է մոդուլացման տեսակի տեսական որոշման մեթոդը, որը արդյունավետ և նպատակահարմար լուծում չի հանդիսանում այս խնդրի համար, ինչի հիմնավորումը ներկայացված է երկրորդ գլխում իրականացված ՄԱՆ մեթոդների համեմատական վերլուծության մեջ: Մինևույն ժամանակ, հարկ է նշել, որ նշված

աշխատանքում ներկայացված ալգորիթմների միջոցով ստացված նույնականացման ճշտությունները անալոգային և թվային մոդուլացման տեսակների համար հավասար են համապատասխանաբար 99.73% և 98%՝ $SNR = 10dB$ -ի դեպքում:

1.1 Անալոգային մոդուլացումների նույնականացման ալգորիթմներ

Ներկայացված են անալոգային մոդուլացման տեսակների ճանաչման համար նախկինում մշակված որոշ մեթոդներ և ալգորիթմներ և դրանց արդյունքները: Պ.Ս. Ֆաբրիցին, Լ.Բ. Լոպեսը և Գ.Բ. Լոկհարթը իրենց աշխատանքի [9] մեջ առաջարկել են անալոգային մոդուլացումների դասակարգիչ, որի աշխատանքը հիմնված է ակնթարթային ամպլիտուդայի և հաճախականության տատանումների վրա: Որպես ազդանշանի գլխավոր բնութագրող հատկանիշ օգտագործվել են ամպլիտուդայի առավելագույն արժեքի և նրա միջին արժեքի հարաբերությունը և ակնթարթային հաճախականության բացարձակ արժեքի միջինը: Նրանց մշակված նույնականացման մեթոդը հնարավորություն ունի ճանաչել անալոգային մոդուլացման AM, FM և SSB տեսակները: Արդյունքները ցույց են տվել, որ AM, FM և SSB ազդանշանների դասակարգումը հնարավոր է իրականացնել $SNR \geq 35dB$ արժեքի դեպքում՝ չնայած նրան, որ SSB և FM ազդանշանների միջև դասակարգումը հնարավոր էր $SNR \geq 5 dB$ պայմանի դեպքում:

Յ.Օ. Ալ-ջալիլին [10] առաջարկել է դասակարգիչ՝ միաշերտ անալոգային մոդուլացման տեսակներից ցածր կողային շերտով և վերին կողային շերտով (Lower side band - LSB և upper side band – USB) մոդուլացումների տեսակների ճանաչման համար: Որպես բնութագրող հատկանիշ նրանք կիրառել են բացասական և դրական հաճախականային թռիչքների քանակների G հարաբերությունը: Արդյունքում ստացվել է, որ $G > 1$ USB-ի դեպքում, և $G < 1$ LSB-ի դեպքում: Փորձերի արդյունքները ցույց են տվել, որ տվյալ նույնականացման մեթոդը ճշգրիտ ցուցանիշներ ունի $SNR \geq 0$ դեպքում:

Անալոգային մոդուլացման տեսակների նույնականացման համեմատաբար նոր ալգորիթմ առաջարկել են Բ.Բ. Դահապը և Հ.Բ. Ահմեդը [11]: Նրանց աշխատանքը նպատակն է նոր ալգորիթմի միջոցով բարելավել Ազոուզի և Նանդիի մշակված մեթոդը անալոգային մոդուլացման տեսակների նույնականացման համար: Նրանք Ազոուզի և Նանդիի մշակված չորս հիմնական բնութագրող հատկանիշների փոխարեն կիրառել են

երեքը և արդյունքում ստացել են մոդուլացման տեսակի նույնականացման 97% ճշտություն՝ $SNR=0dB$ դեպքում, ինչը Ազոուզը և Նանդին ստացել էին $SNR=10dB$:

Այսպիսով՝ անալոգային մոդուլացման տեսակները ներկայումս լայն կիրառություն չունեն, այդ իսկ պատճառով դրանց նույնականացման վերաբերյալ նոր հետազոտությունների քանակը սահմանափակ է: Միննույն ժամանակ կարելի է եզրակացնել, որ առկա լուծման եղանակների արդյունքները բավականին մեծ ճշտություն ունեն միայն այն դեպքում, երբ ազդանշանների մոդուլացման տեսակների նույնականացման գործառույթը իրականացվել է միայն անալոգային մոդուլացման տեսակների համար:

1.2 Թվային մոդուլացումների նույնականացման ալգորիթմներ

Թվային մոդուլացման տեսակների ավտոմատացված նույնականացման առաջին մեթոդներից մեկը 1984 թվականին առաջարկել է Ֆ.Ֆ. Լիեդոկեն: Իր աշխատանքի մեջ [12] նա ներկայացրել է մոդուլացումների նույնականացման մեթոդ ASK, FSK, PSK մոդուլացված ազդանշանների համար: Մոդուլացման տեսակների նույնականացման համար նա որպես ազդանշանի գլխավոր բնութագրող հատկանիշ կիրառել է ամպլիտուդայի, հաճախականության, փուլային տարբերության հիստոգրամները (histogram) և ամպլիտուդայի ու հաճախականության տատանումները: Իր առաջարկած լուծման միջոցով կատարված հետազոտությունների արդյունքում նա կարողացել է իրականացնել մոդուլացումների նույնականացում միայն $SNR \geq 18dB$ արժեքի դեպքում:

Կ. Ալսալեհը, Կ. Ֆարելը և Ռ. Մամունը իրենց աշխատանքում [13] ներկայացրել են թվային մոդուլացումների նույնականացման մեթոդ, որը նախատեսված է ճանաչել PSK2, PSK4, FSK2 և FSK4 տեսակները: Հիմնական բնութագրող հատկանիշներն են՝ միջինացված ակնթարթային հաճախականության միջին արժեքը և ստանդարտ շեղումը, ակնթարթային թողունակության շերտի միջին արժեքը և ստանդարտ շեղումը և դիֆերենցիալ ակնթարթային հաճախականության թռիչքների մակարդակները: Յուրաքանչյուր նույնականացման տեսակի համար իրականացվել են թվով հազար փորձարկումներ և արդյունքում $SNR \geq 15dB$ դեպքում ստացվել է իննսունինը տոկոսից բարձր ճշտություն:

Հաղի Վալիպուրը ներկայացրել է թվային ASK, FSK, PSK, 16-QAM մոդուլացման տեսակների նույնականացման մեթոդ, որպես հիմնական բնութագրող հատկանիշներ կիրառվել են [8]-ում ներկայացված բնութագրերը և որոշ ստատիստիկ բնութագրեր որոնք ստացվել են կոմպլեկս ազդանշանի վերլուծության արդյունքում [14]: Աջակցող վեկտորային մեքենայի միջոցով իրականացվել է նույնականացման գործառնությունը և ստացվել են 96% ճշտությամբ արդյունքների SNR = 0dB դեպքում: Հարկ է համարվում նշել, որ նշված արդյունքները ստացվել են աջակցող վեկտորային մեքենայի բավարար և բազմատեսակ ուսուցանող տվյալների պարագայում:

1.3 Անալոգային և թվային մոդուլացման տեսակների զուգահեռ նույնականացման ալգորիթմներ

Ա. Մարտինը առաջարկել է դասակարգիչ AM, FM, SSB, 2ASK և 2FSK անալոգային և թվային մոդուլացումների տեսակների համար [15]: Որպես նշված ազդանշանների հիմնական բնութագրող հատկանիշ կիրառել է ամպլիտուդայի հիստոգրամը, ազդանշանի թողունակության շերտը և սպեկտրալ բաղադրիչների հարաբերությունը: Թեստավորման ընթացքում կիրառվել և գեներացվել են իրական ազդանշաններ և դրա արդյունքում ստացվել է ինսուն տոկոսից բարձր ճշտության գործակից: FM ազդանշանի համար հաջողության գործակիցը հավասար է 80%:

Լ.Վ. Դոմինգեսը, Ջ.Մ. Բոռալլոն և Ջ.Պ. Գարսիան ներկայացրել են դասակարգիչ AM, DSB, SSB, FM, 2ASK, 4ASK, 2PSK, 4PSK, 2FSK, 4FSK անալոգային և թվային ազդանշանների համար [16]: Ազդանշանների մոդուլացումների տեսակների նույնականացման համար մշակված ալգորիթմը հիմնված է ակնթարթային ամպլիտուդայի, ակնթարթային փուլի և ակնթարթային հաճախականության հիստոգրամների վրա: Բոլոր տեսակների համար իրականացվել է հարյուր թեստավորում և SNR \geq 40dB պայմանի դեպքում բոլոր տեսակները դասակարգվել են անթերի ճշտությամբ: SNR=10dB դեպքում ճիշտ նույնականացման հավանականությունը հավասար է զրոյի:

Տ.Սանը, Ջ.Ջիան և Գ.Յուն առաջարկել են անալոգային և թվային մոդուլացումների նույնականացման մեթոդ 2ASK, 4ASK, 2FSK, 4FSK, 16QAM, AM, DSB ազդանշանների համար [17]: Որպես հիմնական բնութագրող հատկանիշներ նրանք կիրառել են հայտնի

[8]-ում ներկայացված հատկանիշները և նույնականացումը իրականացրել են այդ հատկանիշների համար հաշվարկված շեմային արժեքների հետ համեմատության միջոցով: Արդյունքում ստացվել է 87% ճշտություն՝ $SNR = 0$ դեպքում, բացառությամբ QAM16 ազդանշանի, որի նույնականացման ճշտությունը զգալի ցածր է: Իրականացված հետազոտությունների արդյունքում պարզվել է, որ SNR-ի ցածր արժեքների դեպքում բարձր ճշտություններ ստացվել են միայն անալոգային կամ միայն թվային մոդուլացման տեսակների համար նախատեսված ալգորիթմների միջովով, անալոգային և թվային մոդուլացման տեսակների զուգահեռ նույնականացման համար նույնականացման փորձերը հիմնականում իրականացվել են սահմանափակ քանակի մոդուլացման տեսակների համար և առաջարկված ալգորիթմների մեծամասնության մեջ օգտագործված են մինչև [8]-ում ներկայացված հիմնական բնութագրող հատկանիշները:

1.4 Արհեստական նեյրոնային ցանցերի միջոցով մոդուլացման տեսակների նույնականացման ալգորիթմներ

Արհեստական նեյրոնային ցանցերի զարգացմամբ և հետազոտությամբ զբաղվում են դեռևս նախորդ դարից: Դրանք լայնածավալ կիրառություն ունեն մոդուլացումների տեսակների նույնականացման համակարգերում: ԱՆՑ-երի մանրամասն նկարագրությունը ներկայացված է Գլուխ 2-ում:

Մ.Դ. Վոնգը և Ա.Կ. Նանդին իրենց հետազոտությունների արդյունքում կազմված աշխատանքի [18] մեջ ներկայացրել են իրենց կողմից մշակված ՄԱՆ մեթոդը, որն իրականացվել է արհեստական նեյրոնային ցանցերի և գենետիկ ալգորիթմի միջոցով: ՄԱՆ մեթոդը նախատեսված է ASK2, ASK4, BPSK, QPSK, FSK2, FSK4, QAM16, QAM32 և QAM64 թվային մոդուլացումների համար: Նրանց մշակած մեթոդի շրջանակներում որպես ազդանշանի հիմնական բնութագրող հատկանիշներ օգտագործվել են Ազգոուզի և Նանդիի [8] կողմից անալոգային մոդուլացումների տեսակների ճանաչման համար մշակված բնութագրերը և իրենց մշակած ստատիկ հատկանիշների շարքը՝ երկրորդ, երրորդ, չորրորդ դասի «կուսուլանտները», և ազդանշանի իրական ու կեղծ բաղադրիչների խաչաձև «կուսուլանտները»: Փորձերի արդյունքում նրանք ստացել են մեթոդի աշխատանքի որակի անթերի ցուցանիշներ:

Կ. Հասանք և համահեղինակներն իրենց կատարած աշխատանքի նկարագրության մեջ [19] ներկայացրել են մոդուլացումների նույնականացման մեթոդ, որի մշակվել և իրականացվել է վեյվլեթ ձևափոխության և արհեստական նեյրոնային ցանցերի միջոցով: Վեյվլեթ ձևափոխությունը կիրառվել է ազդանշանի հիմնական բնութագրող հատկանիշների առանձնացման համար: Նույնականացումն իրականացվել է MSK, FSK, ASK, PSK և QAM թվային մոդուլացումների տեսակների համար: Արդյունքում $SNR \geq 4dB$ դեպքում ստացվել են իդեալական ճշտությամբ արդյունքներ:

Մոդուլացումների ավտոմատացված նույնականացման նպատակով արհեստական նեյրոնային ցանցերը կիրառվում են նաև համեմատաբար նոր տեխնոլոգիաներում, որոնցից են օրինակ՝ ճանաչողական ռադիոները: Չեն Մեյը և Ժու Քին ներկայացրել են [20] նոր արդյունավետ մոդուլացումների ճանաչման համատեղ մեթոդ ճանաչողական ռադիոների համար: Այստեղ որպես նույնականացման տեխնոլոգիա կիրառվում է հակադարձ տարածման նեյրոնային ցանց: Այս համակարգում որպես ազդանշանի հիմնական բնութագրեր կիրառվել են [8]-ում ներկայացված բնութագրերը: Տեղեկատվության մեկից ավելի կրող հաճախականության միջոցով փոխանցման դեպքում, ինչպես օրինակ՝ OFDM տեխնոլոգիան, նույնականացման ալգորիթմի գործառությանին արդյունավետությունը զգալի նվազում է: Այս պատճառով Չեն Մեյը և Ժու Քին համալրել են բնութագրերի շարքը մոմենտների կոմբինացիաներով, որոնք կարող են տարբերել բազմակրող ազդանշանը մեկ կրող ունեցող ազդանշանից: Փորձերն իրականացվել են վեց տեսակի թվային մոդուլացումների համար՝ 2FSK, 2ASK, 4ASK, BPSK, QPSK և OFDM:

Եվս մեկ թվային մանիպուլացումների ավտոմատացված նույնականացման մեթոդ է մշակել Կ.Ֆ. Ֆատիման [21]: Նա նույնպես իրականացրել է իր մշակած մեթոդը դիսկրետ վեյվլեթ ձևափոխության և արհեստական նեյրոնային ցանցերի միջոցով: Վեյվլեթ ձևափոխության միջոցով ստացված վեյվլեթ գործակիցները հանդիսացել են ազդանշանի հիմնական բնութագրեր, որոնք ներկայացվել են հակադարձ տարածման արհեստական նեյրոնային ցանցի մուտքերին: Նշված մեթոդն իրականացվել է յոթ տեսակի թվային մանիպուլացումների ավտոմատացված ճանաչման համար՝ 8PSK, 16PSK, 2QAM, 8QAM, 16QAM, 2PSK և 8 FSK: Ստացված արդյունքները բավականին մեծ

ճշտություն ունեն, բացառությամբ $SNR=5dB$ դեպքի, որի բարելավման համար հեղինակն իր աշխատանքի մեջ առաջարկել է լուծումներ:

Շ. Ալմասպուրը և Մ.Մոնիրին ներկայացրել են 2ASK, 4ASK, 2FSK, 4FSK, QPSK, 2PSK, 4PSK, 4QAM, 16QAM մոդուլացման տեսակների նույնականացման մեթոդ արհեստական նեյրոնային ցանցերի միջոցով [22]: Այս տաս թվային մոդուլացման տեսակների նույնականացման համար օգտագործվել է տասնվեց բնութագրող հատկանիշներ՝ որոնցից մեծ մասը կրկին հանդիսանում են [8]-ում ներկայացված բնութագրերը: $SNR = 0dB$ դեպքում ստացված արդյունքների ճշտությունը հավասար է 98%:

Նախկինում կատարված մոդուլացման տեսակների նույնականացման խնդրի հետազոտությունների և առաջարկված լուծման մեթոդների վերաբերյալ իրականացված ուսումնասիրությունների հիման վրա եզրակցվել է, որ անալոգային և թվային մոդուլացումների զուգահեռ նույնականացման այնպիսի մեթոդի մշակումը, որը սահմանափակ քանակի հիմնական բնութագրող հատկանիշների կիրառման և պարզ ոչ ժամանակատար հաշվարկների միջոցով՝ SNR -ի ցածր արժեքների դեպքում, հնարավորություն ունի զուգահեռաբար բարձր ճշտությամբ նույնականացնել ամենից լայն կիրառություն ունեցող բոլոր անալոգային և թվային մոդուլացման տեսակները, ինչը նոր և արդյունավետ լուծում է ՄԱՆ խնդրի համար:

ԳԼՈՒԽ 2. ՄԱՆ ՄԵԹՈԴՆԵՐՈՒՄ ԿԻՐԱՌՎՈՂ ՏՎՅԱԼՆԵՐԻ ՆՈՒՅՆԱԿԱՆԱՑՄԱՆ ՏԵԽՆՈԼՈԳԻԱՆԵՐԸ ԵՎ ԴՐԱՆՑ ՀԱՄԵՄԱՏԱԿԱՆ ՎԵՐԼՈՒԾՈՒԹՅՈՒՆԸ

Ներկայումս գոյություն ունեն բազմաթիվ ՄԱՆ համակարգեր և դասակարգման ալգորիթմներ, որոնց վերաբերյալ առկա են բազմաթիվ գիտական հոդվածներ, ատենախոսություններ և այլ աշխատություններ: ՄԱՆ խնդիրն ունի համաշխարհային կարևորություն, քանի որ դրա հետազոտությունը և զարգացումն իրականացվում են այնպիսի երկրներում, ինչպիսիք են ԱՄՆ-ն, Չինաստանը, Եգիպտոսը, Հնդկաստանը և այլն: Սույն ատենախոսության հիմքում ընկած խնդրի լուծման առաջնային նախապայմաններից է նույնականացման տեխնոլոգիայի հիմնավորված ընտրությունը և վերջինիս համապատասխանեցումը տվյալ խնդրի լուծմանը: Ներկայումս գոյություն ունեն բազմաթիվ տարածված դասակարգման տեխնոլոգիաներ և ալգորիթմներ, որոնցից յուրաքանչյուրը նախատեսված է կոնկրետ խնդիրների լուծման համար: Այս պատճառով իրականացվել է համապատասխան տեխնիկական գրականության և նախկինում կատարված աշխատանքների հետազոտություն [23-24], ինչի արդյունքում ներկայացվել է մոդուլացման տեսակների նույնականացման տեխնոլոգիայի ընտրության համար մեր կողմից իրականացված նշված նույնականացման մեթոդների և տեխնոլոգիաների հետազոտությունը և համեմատական վերլուծությունը [25]: Իրականացված վերլուծությունը առաջինն է իր տեսակի մեջ, քանի որ ի տարբերություն նախկինում կատարված աշխատանքների [23-24], այստեղ մանրամասնորեն նկարագրված են տվյալների նույնականացման տեխնոլոգիաներ, դրանց առավելություններն ու թերությունները հեռահաղորդակցական ազդանշանների նույնականացման շրջանակներում և ներկայացված է դրանց համեմատական վերլուծությունը, ինչը հնարավորություն է տալիս կատարված վերլուծության արդյունքները կիրառել այլ աշխատանքներում: Վերոնշյալ համեմատական վերլուծության հիման վրա ընտրվել է առավել արդյունավետ, նպատակահարմար, իրագործելի և հեռանկարային նույնականացման տեխնոլոգիան, որը կիրառվել է այս աշխատանքի շրջանակներում մշակված մեթոդում: Հաջորդիվ ներկայացված է նույնականացման տեխնոլոգիաներից՝ տեսական որոշման, համաստեղության

դիագրամի վերլուծության, վեյվլեթ ձևափոխության, վեկտորային աջակցող մեքենայի և արհեստական նեյրոնային ցանցերի համառոտ նկարագրությունը [25]:

2.1 Տվյալների նույնականացման տեխնոլոգիաների նկարագրությունը

Տեսական որոշման մեթոդ

Ինչպես արդեն նշվել էր ՄԱՆ ալգորիթմներն ունեն երկու հիմնական մոտեցում՝ տեսական որոշման և նմուշի ճանաչման: ՄԱՆ խնդիրներում ընդունված է համարել, որ բոլոր մոդուլացման տեսակների պատահման հավանականությունը նույնն է: Այդ իսկ պատճառով տեսական որոշման մոտեցման դեպքում կիրառվում է առավելագույն հավանականության չափանիշը: Հավանականության տեսության միջոցով լուծվող ՄԱՆ ալգորիթմները հիմնված են հավանականության բաշխվածության գործառույթի վրա, որը հաշվարկվում է ընդունված ազդանշանից ստացված պարամետրերի միջոցով [26]: Ալգորիթմներում առավելագույն հավանականության չափանիշը կիրառվում է կամ ամբողջական ընդունված ազդանշանի վրա, կամ նրա որոշ բնութագրերի, ինչպիսիք են՝ ակնթարթային փուլ կամ ակնթարթային ամպլիտուդա, որի արդյունքում առաջանում է հավանականությունների հարաբերություն կամ հավանականության ֆունկցիաների խումբ: Նույնականացման վերջնական որոշումն ընդունվում է համեմատելով հավանականությունների հարաբերությունը կամ համեմատելով գործառույթները շեմային արժեքների հետ: Գերազանց պայմանների դեպքում տեսական որոշման վրա հիմնված դասակարգիչները կարող են ճիշտ նույնականացման հավանականության բարձր արժեքներ ստանալ՝ ընդունված ազդանշանից ստացված տվյալների քիչ քանակի դեպքում: Իդեալական պայմանների դեպքում տեսական որոշման դասակարգիչները նույնիսկ կարող են չափանիշ հանդիսանալ այլ դասակարգիչների աշխատանքի ճշտության ստուգման համար: Այնուամենայնիվ, նշված տեսակի դասակարգիչների գործնական կիրառումը սահմանափակ է և դրանց օպտիմալացման լուծումները հանգեցնում են հաշվարկների զգալի բարդեցմանը: Այս խնդիրը հաղթահարելու նպատակով բազմաթիվ փորձեր են կատարվել պարզեցնել հավանականության գործառույթները, փորձերը հանգեցրել են մի քանի այլընտրանքային լուծումների, սակայն վերջիններս նույնպես զգալիորեն չեն նվազեցրել հաշվարկների բարդության աստիճանը: Տեսական որոշման ալգորիթմների մշակման մեկ այլ թերություն է

համարվում այն փաստը, որ կրողի հաճախականության, փուլի, սիմվոլների հաճախականության, ժամանակային շեղման, ազդանշանի հզորության և այլ պարամետրերի չիմացությունը զգալի սահմանափակում է դասակարգչի աշխատանքը: Այս թերության վերացման եղանակներից մեկն անհայտ պարամետրերը որպես դետերմինիստիկ դիտարկելն է և դրանք ընդունված ազդանշանների տվյալներից հաշվարկելը, որը հանգեցնում է այսպես կոչված ընդհանրացված հավանականության հարաբերակցության թեստի կիրառմանը (generalized likelihood ratio test): Երկրորդ տարբերակը՝ դիտարկել դրանք որպես պատահական փոփոխականներ և միջինացնել հավանականության գործառույթներն ըստ այդ տվյալների: Սա կոչվում է միջինացված հավանականության հարաբերակցություն թեստ (average likelihood ratio test): Այն դեպքում, երբ միջինացված հավանականության հարաբերակցություն թեստը կիրառվում է մի շարք անհայտ պարամետրերի հետ, իսկ ընդհանրացված հավանականության հարաբերակցության թեստը մեկ այլ անհայտ խմբի վրա, ապա այդ դեպքը կոչվում է հիբրիդային հավանականության հարաբերակցության թեստ (hybrid likelihood ratio test) և հիմնականում կիրառվում է նախապես սպասված մոդուլացումների տեսակների հետ աշխատանքի դեպքում: Այս պատճառով տեսական որոշման դասակարգիչները կիրառելի չեն «կույր» դեմոդուլացման համակարգերում [27]: Տեսական որոշման ալգորիթմների մեկ այլ թերություն է համարվում այն փաստը, որ ազդանշանի հիմնական բնութագրող հատկանիշները, որոնք նախամշակման փուլում առանձնացվում են ընդունված ազդանշանից հետագա հաշվարկների իրականացման համար, ալգորիթմի առցանց կիրառումից առաջ պետք է իրական ժամանակում թեստավորման փուլում հաշվարկվեն և համապատասխան հատկանիշների համար արժեքների տիրույթի առավելագույն և նվազագույն շեղեր սահմանվեն: Բացի այդ տեսական որոշման ալգորիթմի արդյունքների ճշտությունը կախված է համակարգի մուտքին տրված ազդանշանի գլխավոր բնութագրող հատկանիշների արժեքների ճիշտ հերթականությունից, ինչը վկայում է այն մասին, որ համակարգը զուգահեռ հաշվարկներ կատարելու հնարավորություն չունի՝ զգալի կերպով դանդաղեցնելով ալգորիթմի աշխատանքը: Վերջինս նույնպես հանգեցնում է տվյալ աշխատանքի համար նշված մեթոդի աննպատակահարմարությանը:

Նույնականացում համաստեղության դիագրամի վերլուծության միջոցով

Ազդանշանի մոդուլացման տեսակի ճանաչման մեկ այլ մեթոդ է հանդիսանում ազդանշանի սիմվոլների հետազոծի և համաստեղության վերլուծությունը: QAM ազդանշանների համար համաստեղության որևէ կետի դիրքը կախված է ազդանշանի ամպլիտուդայից կամ փուլից, կամ երկուսից միաժամանակ: Հետևաբար տարբեր կարգի QAM ազդանշաններ ունեն ամպլիտուդայի և փուլի տարբեր մակարդակներ և յուրաքանչյուր տեսակ ունի առանձնահատուկ սիմվոլների հետազոծեր և համաստեղության դիագրամ: Այս նույնականացման տեսակի հիմքում ընկած է ազդանշանի համափուլ I և քառակուսային Q բաղադրիչների առանձնացումը: Ենթադրենք ունենք ազդանշան, որը նկարագրվում է հետևյալ հայտնի հավասարմամբ՝

$$S = A \cos(\omega t + \varphi) : \quad (2.1)$$


Քանի որ $\cos(A + B) = \cos(A)\cos(B) + \sin(A)\sin(B)$, հետևաբար տեղադրելով այն հավասարում (2. 1)-ի մեջ կստանանք՝

$$S = A \cos(\omega t + \varphi) = A \cos(\omega t)\cos(\varphi) + A \sin(\omega t)\sin(\varphi) , \quad (2.2)$$

որտեղ $I = A \cos(\varphi)$ և $Q = A \sin(\varphi)$:

Ինչպես հայտնի է համաստեղության դիագրամը դա I և Q կոմպոնենտների դետեկտման արդյունքում ստացված ազդանշանի սիմվոլների պատկերն է (նկ. 2. 1. ա)):

Վեկտորային դիագրամը ներկայացնում է I և Q հարթությունում ազդանշանի վեկտորի ամբողջ հետազոծը (նկ. 2. 1. բ)):



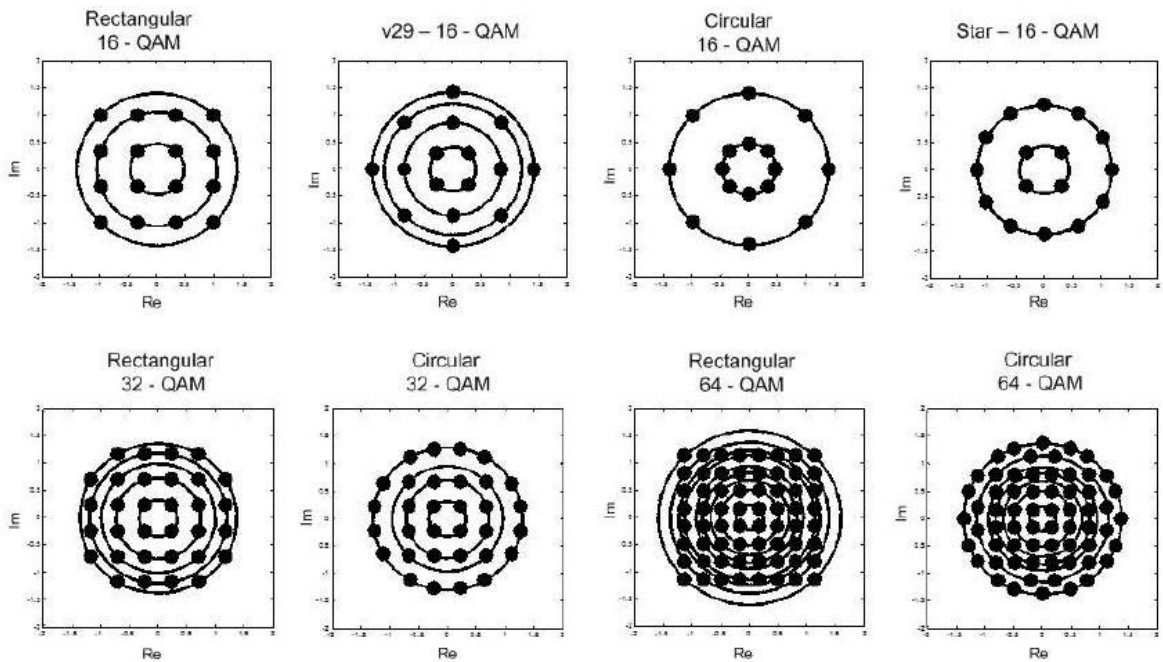
Նկ. 2.1 Համաստեղություն (ա) և վեկտորային դիագրամ (բ)

Ն. Սիմադին և Ռ. Բերանգին առաջարկել են QAM և PSK մոդուլացումների նույնականացման մեթոդ՝ նմուշի ճանաչման տեխնոլոգիայի և գենետիկ ալգորիթմի

կիրառամբ [28]: Նրանց առաջարկած մեթոդը դասակարգում է սիմվոլները և հիերարխիկ կլաստերավորումը, որպեսզի գտնի իրական կլաստերները, որոնք հավասար են մոդուլացման մակարդակներին: Այս մեթոդի հիմնական առավելությունն այն է, որ որոշման տիրույթները կարող են ճշտությամբ սահմանվել: Փորձերի արդյունքները ցույց են տվել, որ առաջարկված մեթոդն աղմուկի առկայության դեպքում մեծ հաջողություն է ցուցաբերում և կարող է հեշտությամբ կիրառվել միաչափ մոդուլացման տեսակների ճանաչման համար, ինչպիսին է, օրինակ՝ FSK-ն: Համաստեղության դիագրամների վերլուծման և համեմատման արդյունքում ընտրվում է այն մոդուլացման տեսակը, որն ամենից շատ է համընկնում հայտնի նմուշի հետ: Սկզբում բոլոր QAM ազդանշանների համար սահմանվում են իդեալական սիմվոլների կլաստերների կենտրոններ, որոնք այնուհետև համեմատվում են ազդանշանից ստացվածների հետ: 4, 16, 64, 256 QAM ազդանշանների համար առանցքային հարթության քառորդ մասում սահմանվում են համապատասխանաբար 1, 4, 16, 64 կլաստերային կենտրոններ: Բոլոր կենտրոնները սահմանվում են I և Q քառորդ հարթությունում և $[0, 1]$ միջակայքում: Ընդունված ազդանշանի կետերի բացարձակ արժեքները հաշվարկվում և նորմավորվում են, որից հետո դրանք տրվում են գենետիկ ալգորիթմին: Գենետիկ ալգորիթմի տված կենտրոնները համեմատվում են 256 QAM ազդանշանի իդեալական կենտրոնների հետ: Համեմատությունն իրականացվում է կենտրոնների միջև Էվկլիդյան հեռավորության հաշվարկմամբ: Ստացված արժեքը համեմատվում է համապատասխանաբար 256 QAM ազդանշանի համար հաշվարկված շեմային արժեքի հետ և այն դեպքում, երբ վերջինս փոքր է այդ արժեքից, ապա մոդուլացման տեսակը որոշվում է ի օգուտ 256QAM-ի: Հակառակ դեպքում՝ նույն գործողությունն իրականացվում է 64 QAM ազդանշանի հետ և այդպես շարունակ:

Մինևույն ժամանակ, գոյություն ունի այս մեթոդի կիրառման խնդիր, որը սահմանափակում է համաստեղության դիագրամի միջոցով իդեալական ամպլիտուդայի և փուլի մակարդակների և ընդունված ազդանշանի առանձնացված տվյալների համեմատության միջոցով մոդուլացման տեսակի ճանաչումը: Այդ խնդիրը համակարգում առկա հաճախականային շեղումն է:

Մոդուլացման կարգի հաշվարկը հնարավոր է իրականացնել նաև ընդունված ազդանշանի ամպլիտուդայի հավանականության խտության գործառույթի կիրառմամբ [29]: Այս մոտեցումը հիմնված է I և Q հարթության կենտրոնի շուրջ գտնվող սիմվոլները միմյանց միացնող շրջանների քանակի հաշվարկմամբ: Շրջանները առաջանում են հաճախականության շեղման հետևանքով:



Նկ. 2.2 M-QAM ազդանշանների համաստեղություններ

Այնուամենայնիվ, որոշ դեպքերում միայն շրջանների քանակի հաշվարկները բավարար չեն: Օրինակ՝ 16 QAM ազդանշանի երկու տարբեր դիագրամներ ունեն երկու շրջան, բայց խտության տարբեր արժեքներ՝ 4, 12 և 8, 8 (նկ. 2. 2): Այս երկուսի միջև նույնականացման համար պետք է կիրառել նաև խտության մասին տեղեկատվությունը: Այս մեթոդը կիրառում է սիմվոլների բաշխվածության միջինի ալգորիթմը որպեսզի կառուցի կլաստերներ, որի արդյունքում հնարավոր կլինի հաշվարկել շրջանների քանակը: Այս համակարգն ունի երկու մուտք, որից մեկը տվյալների խումբն է, իսկ մյուսը՝ կլաստերների քանակը: Ելնելով կլաստերների քանակից սահմանվում է կենտրոնների քանակ՝ հաշվարկելով յուրաքանչյուր տվյալի կետի ամենակարճ հեռավորությունը այդ կլաստերի կենտրոնից: Նշված ամենակարճ հեռավորության հաշվարկի արդյունքում բոլոր տվյալների կետերը համապատասխանեցվում են

ամենամոտ գտնվող կլաստերի կենտրոնին՝ անհրաժեշտության դեպքում թարմացնելով դրա գտնվելու վայրը: Այս գործընթացը շարունակվում է այնքան ժամանակ մինչև կենտրոնների գտնվելու վայրը դառնում է անփոփոխ:

Տվյալ աշխատանքի շրջանակներում դրված խնդրի լուծման համար համաստեղության վերլուծության միջոցով ՄԱՆ մեթոդի մշակումը, չնայած վերջինիս առավելությունների և թերությունների, արդյունավետ և նպատակահարմար չէ, քանի որ այն կիրառելի է միայն թվային մոդուլացումների համար:

Վեյվլեթ ձևափոխություն

Վեյվլեթն ակիքանման տատանում է, որի ամպլիտուդան սկսվում է աճել զրոյից և նորից նվազում է դեպի զրոն: Վեյվլեթ ձևափոխությունը նման է Ֆուրյե ձևափոխությանն այն մասով, որ նա նույնպես տրոհում է ազդանշանը բաղկացուցիչ մասերի: Ֆուրյե ձևափոխումը փոխակերպում է ժամանակային ազդանշանը հաճախականայինի, տրոհելով այն տարբեր հաճախականությունների սինուսների հաջորդականության: Մայր ակիքի ձևը դա հիմնական ակիքն է: Վեյվլեթներն ունեն հատուկ մասշտաբային հատկանիշներ: Դրանք տեղակայված են ժամանակային և հաճախականային տիրույթներում, ապահովելով ավելի սերտ կապվածություն ֆունկցիայի և նրա գործակիցների միջև: Այլ կերպ ասած, վեյվլեթի հիմնական ունակությունը դա մեծ ազդանշանի հատուկ հատվածի վերլուծությունն է, որի արդյունքում բացահայտվում են ազդանշանի յուրահատուկ բնութագրեր, որն այլ կերպ հնարավոր չէր լինի ստանալ: Պատկերացնենք ունենք կոմպլեկս ֆունկցիա ψ , որը բավարարում է հետևյալ պահանջներին [30]՝

$$\int_{-\infty}^{\infty} |\psi(t)|^2 dt < \infty, \quad (2.3)$$

$$C_{\psi} = 2\pi \int_{-\infty}^{\infty} \frac{|\Psi(\omega)|^2}{|\omega|} d(\omega) < \infty, \quad (2.4)$$

որտեղ Ψ - և ψ -ի Ֆուրյե ձևափոխությունն է: Առաջին պայմանը ապահովում է ψ ֆունկցիայի էներգիայի վերջավոր լինելու հանգամանքը, իսկ երկրորդ պայմանը այն, որ

եթե $\Psi(\omega)$ -ն համասեռ ֆունկցիա է, ապա $\Psi(0) = 0$, որտեղ ψ ֆունկցիան դա մայր վեյվլեթն է: Վեյվլեթ ձևափոխությունը լինում է շարունակական և դիսկրետ:

Տարբեր թվային մոդուլացված ազդանշաններ պարունակում են ամպլիտուդայի, հաճախականության և փուլի տարբեր փոփոխականներ: Վեյվլեթ ձևափոխությունը հնարավորություն ունի առանձնացնելու փոփոխական ինֆորմացիան, որը հնարավորություն է ընձեռում հեշտությամբ իրականացնել մոդուլացման նույնականացում: Իդեալական դեպքում՝ Հաարի վեյվլեթ ձևափոխության դեպքում PSK ազդանշանի ամպլիտուդան հաստատուն մեծություն է, իսկ FSK ազդանշանի ամպլիտուդան բազմաքայլ ֆունկցիա է: Հետևաբար մուտքային ազդանշանի Հաարի վեյվլեթ ձևափոխության տատանումը կարելի է օգտագործել որպես բնութագրող հատկանիշ երկու տեսակի ազդանշանները տարբերակելու համար: Վեյվլեթ ձևափոխությունը չի հանդիսանում ազդանշանի մոդուլացման տեսակի նույնականացման տեխնոլոգիա, այլ հանդիսանում է ազդանշանի մշակման և հիմնական բնութագրող հատկանիշների առանձնացման արդյունավետ միջոց:

Լ. Հոնգը և Կ.Ց. Հոն գարգացրել են վեյվլեթ ձևափոխության մոտեցումը և կիրառել են QAM տեսակի ազդանշանները նույնականացման համար [31]: Ի տարբերություն PSK և FSK ազդանշանների QAM ազդանշանները չունեն հաստատուն ամպլիտուդայի արժեք: QAM ազդանշանի Հաար վեյվլեթ ձևափոխությունը FSK-ի նույնատեսակ բազմաքայլ ֆունկցիա է, քանի որ ամպլիտուդան փոփոխվում է սիմվոլի փոփոխմանը համապատասխան: Հակառակ դեպքում՝ ամպլիտուդայի նորմավորման դեպքում այն նման կլինի PSK ազդանշանին և Հաար վեյվլեթ ձևափոխությունը կունենա հաստատուն արժեք: Ամպլիտուդայի նորմավորումը փոքր ազդեցություն ունի PSK և FSK ազդանշանների վեյվլեթ ձևափոխման վրա, քանի որ դրանց ամպլիտուդան կոնստանտ է: Հետևաբար PSK, FSK և QAM ազդանշանները կարող են տարբերակվել գնահատելով դրանց Հաար վեյվլեթ ձևափոխման տատանումներն ամպլիտուդայի նորմավորված և ոչ նորմավորված արժեքի դեպքում: Վերոնշյալ աշխատանքում իրականացված հետազոտությունների արդյունքները ցույց են տվել, որ նույնականացման տոկոսային ճշտությունը գերազանցում է 97%-ը 50 դիտարկված սիմվոլների համար՝ $SNR \geq 5dB$ պայմանի դեպքում:

Վեյվլեթ ձևափոխության միջոցով ՄԱՆ խնդրի լուծման մեկ այլ միջոց առաջարկել են Ա. Հոսսենը և Ֆ. Ալ-Վադահին օգտագործելով շարունակական վեյվլեթ ձևափոխության գործակիցների էնտրոպիան [32]: Համաձայն նրանց հետազոտության արդյունքների՝ յուրաքանչյուր մոդուլացման տեսակ ունի իր յուրահատուկ էնտրոպիան: Էնտրոպիան դա հավանականության բաշխման ֆունկցիան է: Նրանք փորձարկել են մեկ և երկու փուլից բաղկացած ցանցեր, ինչի արդյունքում երկփուլանի ցանցի միջոցով ստացվել են ավելի ճշգրիտ արդյունքներ: Նրանք կիրառել են Մեյեր վեյվլեթ գոիչը մեկ փուլանի ցանցի և Մեյերի և Բիոր 3.5 գոիչների կոմպրինացիան երկփուլանի ցանցի համար: Շարունակական վեյվլեթ ձևափոխության էնտրոպիան 2048 կետից բաղկացած ազդանշանի համար հաշվարկվել է հետևյալ քայլերի հերթականությամբ՝

1. Օգտվելով Մեյերի վեյվլեթից հաշվարկել բոլոր բլոկերի շարունակական վեյվլեթ ձևափոխման գործակիցները $i=1:10$ մասշտաբով:
2. Նորմավորել բոլոր գործակիցներն ըստ ամենամեծ գործակցի:
3. Քվանտացնել բոլոր գործակիցները տասը հավասար առանձնացված մակարդակների ($j=1:10$):
4. Գտնել յուրաքանչյուր մակարդակի հավանականությունը $P_{i,j}$ բոլոր մասշտաբների համար:
5. Գտնել ընդհանուր էնտրոպիան կիրառելով հետևյալ հավասարումը՝

$$Entropy = \sum_{i=1}^{10} \sum_{j=1}^{10} P_{i,j} \log_2 \left(\frac{1}{P_{i,j}} \right) \quad (2.5)$$

Վերջնական դասակարգումն իրականացվում է հետևյալ աղյուսակի հիման վրա՝

Աղյուսակ 2. 1. Էնտրոպիայի շեմային արժեքներ

Մոդուլացման տեսակ	Էնտրոպիայի շեմային արժեք՝ T
PSK	$T > 0.75$
FSK	$0.7 < T < 0.75$
ASK	$0.45 < T < 0.7$
PM	$0.38 < T < 0.45$
FM	$0.36 < T < 0.38$
AM-DSB	$0.32 < T < 0.36$
SSB	$0.27 < T < 0.32$
DSB	$0.2 < T < 0.27$

Չնայած որ այս մեթոդը թվում է արդյունավետ, լինելով պարզ և օգտագործելով միայն մեկ բնութագրող հատկանիշ, այնուամենայնիվ՝ ճշտության աստիճանը խոստումնալից չէ: Այս մեթոդի կիրառման արդյունքում ստացվել է 99% ճշտությամբ արդյունք՝ $SNR = 15 \text{ dB}$, 87.2%՝ $SNR = 10 \text{ dB}$, 84%՝ $SNR = 6 \text{ dB}$, և 54% $SNR = 3 \text{ dB}$ դեպքում: Այս մեթոդի այլ թերություն է համարվում այն փաստը, որ $SNR < 8 \text{ dB}$ դեպքում առաջանում են դժվարություններ FSK և PSK ազդանշանների տարբերակման համար: Երկփուլանի ցանցը ASK և PSK ազդանշանների տարբերակման համար SNR -ի համապատասխանաբար 15dB, 10dB, 6dB, 3dB արժեքների դեպքում ներկայացնում է համապատասխանաբար 100%, 100%, 99%, 95% ճշտության ցուցանիշներ: Երկփուլանի ցանցի ընդհանուր ճշտության արժեքները SNR -ի տարբեր արժեքների դեպքում բերված է հետևյալ աղյուսակում՝

Աղյուսակ 2.2 Երկփուլանի ցանցի թեստավորման արդյունքներ

SNR	15	10	6	3
Արդյունավետություն, %	100	99.4	93	72.2

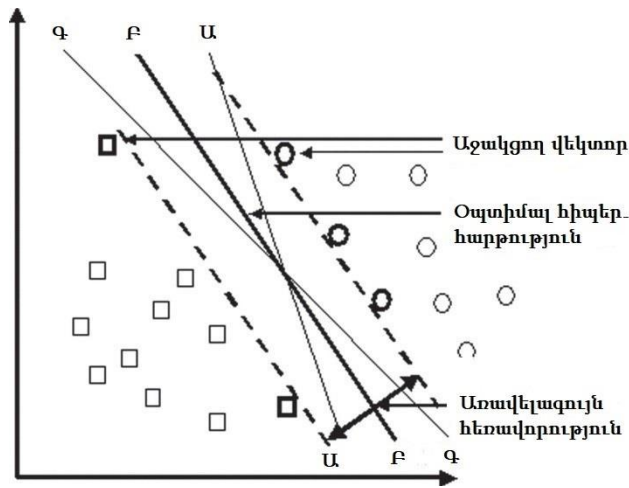
Վեյվլեթ ձևափոխությունը հնարավորություն է տալիս հաշվարկել այնպիսի բնութագրեր, որոնք հնարավոր չէ հաշվարկել Ֆուրյե ձևափոխության միջոցով, ինչի հետևանքով վեյվլեթ ձևափոխությունը մոդուլացման տեսակների նույնականացման

համար նախատեսված հիմնական բնութագրող հատկանիշների առանձնացման այլընտրանքային մեթոդ է: Վեյվլեթ ձևափոխության մեթոդը բազմաթիվ դեպքերում համադրվում է տարբեր դասակարգիչների հետ [33–37]:

Վեյվլեթ ձևափոխությունը նպատակահարմար չի համարվել և չի կիրառվել այս աշխատանքում որպես ընդունված ազդանշանի հիմնական բնութագրերի առանձնացման մեթոդ, քանի որ մշակվող մեթոդի ծրագրային ալգորիթմն իրականացվել է LabVIEW գրաֆիկական ծրագրավորման միջավայրում և նախատեսվում է մշակված ՄԱՆ ալգորիթմի հետագա զարգացման համար փոխակերպել ծրագրային ալգորիթմը և համապատասխանեցնել FPGA-ին [38] համապատասխան կողի, ինչի դեպքում օպերատիվ հիշողության առումով բավականին սահմանափակումներ են առաջանում LabVIEW-ում առկա Wavelet Transforms [39] գործիքների հետ աշխատանքում:

Աջակցող վեկտորային մեքենաներ

Աջակցող վեկտորային մեքենան (SVM) համեմատաբար նոր ունիվերսալ ուսուցանվող մեքենա է, որը ստեղծվել է 1992 թ. Վապնիկի կողմից [40]: ԱՎՄ-ները լայն կիրառություն ունեն նմուշի ճանաչման, հավանականության խտության և ռեգրեսիայի հաշվարկման խնդիրների շրջանակներում: ԱՎՄ-ի առաջնային նպատակն է առավելագույնս մեծացնել երկու տարբեր դասերին պատկանող տվյալներին համապատասխանող երկու ամենամոտ գտնվող կետերի միջև հեռավորությունը: Երկրորդ կարևորագույն գործառույթն է բոլոր տվյալների կետերն իրենց համապատասխան դասին պատկանելու փաստի հավաստիացումը: Երկու գծայնորեն առանձնացվող տվյալների խմբերը երկու դասի բաժանելու համար անհրաժեշտ է գտնել հիպերհարթություն, որն իրականացվում է երկու ամենամոտ կետերի միջև առավելագույն հեռավորության չափման միջոցով: Այս հիպերհարթությունը կոչվում է օպտիմալ առանձնացման հիպերհարթություն, որը նվազեցնում է սխալ նույնականացման ռիսկը ոչ միայն ուսուցման փուլում դիտարկվող կետերի համար, այլ նաև անհայտ կետերի համար՝ թեստավորման փուլում (Նկ. 2.3):




Նկ. 2.3 Օպտիմալ հիպերհարթություն

Երկրաչափության մեջ հիպերհարթությունը մեկ տարածական չափով փոքր է այն շրջապատող տարածության չափից, որում այն դիտարկվում է: Եթե տարածությունը եռաչափ է, ապա հիպերհարթությունը երկչափ է, իսկ երկչափ տարածության դեպքում՝ համապատասխանաբար միաչափ: Հիպերհարթությունը, որն երկու կողմերից ունի առավելագույն հեռավորություն ամենամոտ կետերից, կոչվում է առավելագույն սահմանի հիպերհարթություն:

Ի սկզբանե ԱՎՄ-ը նախատեսված էր երկուական դասակարգման համար, բայց իրական դասակարգման խնդիրները հիմնականում լինում են բազմաթիվ դասերի համար: Բազմատեսակ դասակարգման համար գոյություն ունեն բազմաթիվ մեթոդներ, ինչպիսիք են Direct Acyclic Graph (DAG), Binary Tree (BT), One-Against-One (OAO) և One-Against-All (OAA) [41]: Բազմատեսակ դասակարգման համար գծային առանձնացվող տվյալներից հնարավոր է անցում կատարել ոչ գծային տարածություն՝ օգտվելով Կեռնեյի ֆունկցիաներից: Ոչ գծային նույնականացման բանաձևը մաթեմատիկորեն կարելի է ներկայացնել հետևյալ կերպ [42]՝

$$g(\phi) = W \cdot K(\phi_{(x)} \cdot \phi_{(y)}) + b, \quad (2.6)$$

որտեղ $g(\phi)$ նույնականացման ֆունկցիան է, W – ն հիպերհարթությանը նորմալ վեկտորը, $K(\phi_{(x)} \cdot \phi_{(y)})$ – Կեռնեյի ֆունկցիան և b – ն շեղումն է (բիաս):



Նկ 2.4 ԱՎՄ-ի անցումը ոչ գծային դասակարգմանը

Նկ. 2.4–ում պատկերված է ԱՎՄ աշխատանքի սկզբունքը ոչ գծային դասակարգման համար: Կետների ֆունկցիայի օգնությամբ երկչափ տարածությունը փոխակերպվում է եռաչափի: Եռաչափ տարածությունում հնարավոր է դառնում գտնել կետերի դասերն առանձնացնող հիպերհարթություն: Պատկերացնենք, որ ունենք S տվյալների խումբ, որը բաղկացած է $(x_1, y_1), \dots, (x_n, y_n), x \in R^n$ կետերից: Այստեղ y_i հավասար է 1 կամ (-1), ինչը նշանակում է որ x պատկանում է 1-ին կամ 2-րդ դասին: Պետք է գտնել հիպերհարթություն, որպեսզի առանձնացնել երկու դասերը և դասավորել յուրաքանչյուր դասը հիպերհարթության մի կողմում և հնարավորինս մեծացնել սահմանը:

Բոլոր այն դեպքերի համար, երբ տվյալները չեն կարող գծայնորեն առանձնացվել, կարելի է օգտագործել *hinge loss* [43] ֆունկցիան՝

$$\max(0, 1 - y_i(w \cdot x_i - b)) \tag{2.7}$$

Այն դեպքում, երբ $y_i(w \cdot x_i - b) \geq 1$, բոլոր $1 \leq i < n$ համար սահմանափակումը բավարարվում է, այսպես առաջ ֆունկցիան հավասար է զրոյի, ինչից հետևում է, որ x_i -ն գտնվում է սահմանի ճիշտ կողմում: Բոլոր սահմանի սխալ կողմում գտնվող տվյալների համար ֆունկցիայի արժեքը համաչափ է սահմանից դրանց գտնվելու հեռավորությանը՝

$$\left[\frac{1}{n} \sum_{i=1}^n \max(0, 1 - y_i(w \cdot x_i - b)) \right] + \lambda \|w\|^2 : \quad (2.8)$$

Հավասարում (2.8)-ում λ -ն բնորոշում է սահմանաչափի մեծացման և x_i -ի սահմանի ճիշտ կողմում գտնվելու միջև փոխկապակցվածությունը:

ԱՎՄ-ները արդյունավետ են և ճշգրիտ արդյունքներ են ցուցաբերում ոչ զծային հարթություններում և հնարավորություն են տալիս կիրառել տարբեր Կեռնելի ֆունկցիաներ՝ կախված տվյալ խնդրի բարդությունից [44-46]: Միննույն ժամանակ ԱՎՄ-ի հիպերհարթության C պարամետրը հնարավորություն է տալիս կարգավորել նույնականացման ճշտությունը: Այն դեպքում, երբ C -ին տրված է մեծ արժեք, ապա կետերի միջև սխալ դասակարգման հնարավորությունը հասցված է նվազագույնին, իսկ ցածր արժեքի դեպքում այն կետը, որը հեռու է գտնվում մնացած իր դասին պատկանող կետերից կարող է անտեսվել [47]: Այս հանգամանքը հնարավորություն է ստեղծում կարգավորելու ԱՎՄ-ի զգայունությունը համակարգում առկա աղմուկների նկատմամբ: ԱՎՄ-ների թերությունն է՝ վերջիններիս երկուական նույնականացման համար նախատեսված լինելու հետ կապված խնդիրը, որի հետևանքով բազմաթիվ դասերի դասակարգման գործընթացի համար դրանց ուսուցման տևողությունը զգալի մեծանում է: Համապատասխան Կեռնելի ֆունկցիայի ընտրությունը դիտարկվող խնդրի պայմաններին նույնպես ԱՎՄ-ների թերությունն է, քանի որ այն առաջացնում է լրացուցիչ հաշվարկների պահանջ և երկարացնում վերջիններիս տևողությունը:

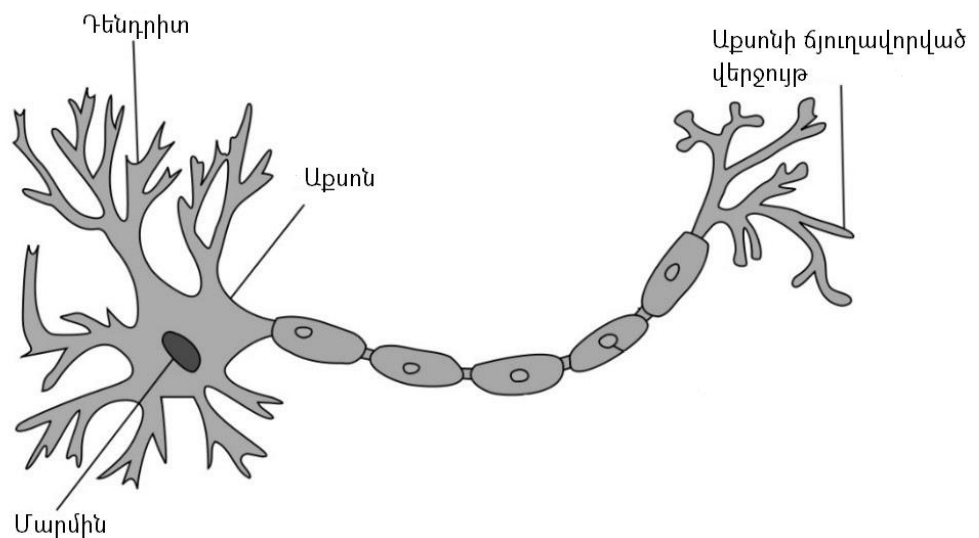
2.1.1 Արհեստական նեյրոնային ցանցեր

Հաջորդիվ ներկայացված է իրականացված հետազոտությունների արդյունքում կազմված արհեստական նեյրոնային ցանցերի մանրամասն նկարագրությունը և կիրառման հնարավորությունները մոդուլացման տեսակների նույնականացման խնդրի շրջանակներում [48]: Արհեստական նեյրոնային ցանցերը (ԱՆՑ) էվոյուցիոն զարգացում ապրող տեխնոլոգիաներ են, որոնք ընկած են ներկայումս ամենից արագ տեմպերով զարգացող տեխնոլոգիաներից մեկի՝ արհեստական բանականության, հիմքում: ԱՆՑ-ն իրենից ներկայացնում է համակարգ, որը կանխագուշակման և ճանաչման միջոցով գեներացնում է տրված մուտքերին համապատասխան ելքեր: Ներկայումս ԱՆՑ-երն ունեն լայն ճանաչում, շարունակաբար զարգանում են և

կիրառվում են այնպիսի բազմաբնույթ հավելվածներում ինչպիսիք են՝ բժշկական ախտորոշումը, ազդանշանների մշակումը, արժույթի փոխարժեքի կանխագուշակումը, մոդուլացման տեսակի ավտոմատացված ճանաչումը և այլն:

Ներկայումս արհեստական նեյրոնային ցանցերը համարվում են մոդուլացման ավտոմատացված նույնականացման/ճանաչման ամենատարածված և արդյունավետ տեխնոլոգիաներից, քանի որ դրանց միջոցով հնարավոր է ստանալ մոդուլացումների նույնականացման բավականին բարձր ճշտությամբ արդյունքներ: Արհեստական նեյրոնային ցանցերի սկզբնական հետազոտություններն անցկացրել են ամերիկացի նեյրոհոգեբան ՈԻ. Մակկալոկը և մաթեմատիկոս ՈԻ. Պիտսը հազար ինը հարյուր քառասուններեք թվականին: Նրանց աշխատության մեջ նրանք փորձել էին բացատրել նեյրոնի ֆունկցիան՝ Էլեկտրական շղթաների միջոցով ստեղծելով պարզագույն արհեստական նեյրոնային ցանց [49]:


Նեյրոնը մարդու նյարդային համակարգի գլխավոր բաղկացուցիչ մասն է: Այն կազմված է մարմնից, աքսոնից և դենդրիտներից (նկ. 2.5): Աքսոնը ճյուղավորվող վերջույթով երկարավուն էլուստ է, որի միջոցով նյարդային իմպուլսները մարմնից հաղորդվում են մնացած բջիջներին: Նեյրոնները կապված են միմյանց հետ սինապսների միջոցով, իսկ դենդրիտները կարգավորում են այդ կապը [50]:



Նկ.2.5 Նեյրոնի կառուցվածքը

Կապնվելով միմյանց հետ նեյրոնները ձևավորում են ցանց, որի պատկերավոր օրինակ կարող է հանդիսանալ մարդկային գլխուղեղի նյարդային համակարգը: Այս համակարգի աշխատանքով է պայմանավորված մարդու իրերի ընկալումը, նմուշների ճանաչումը, մտածելու ունակությունը և ընդհանրապես գլխուղեղի նորմալ գործունեությունը: Նեյրոնային ցանցի միջոցով հնարավոր է ճանաչել արդեն իսկ ծանոթ նմուշները, տվյալները, իրերը և այլն:

Ու. Մակկալոկի և Ու. Պիտսի հետազոտություններին հաջորդիվ Դ. Հեբբը 1949թ. [51] նկարագրել էր նեյրոնների ուսուցման գլխավոր սկզբունքները, իսկ մի քանի տարի անց ամերիկացի նեյրոֆիզիոլոգ Ֆ. Ռոզենբլատը մշակեց սարքավորում, որը մոդելավորում էր գլխուղեղի ընկալումը և անվանեց այն պերցեպտրոն [52]: Պերցեպտրոնը նեյրոնի մաթեմատիկական մոդելն է, որը բաղկացած է մի քանի մուտքերից, թաքնված շերտից և մեկ ելքից: Պերցեպտրոնները լինում են մեկ շերտանի և բազմաշերտ: Միաշերտ պերցեպտրոնի այն տեսակն է, որն ունի մեկ թաքնված շերտ: Պերցեպտրոնի յուրաքանչյուր շերտ բաղկացած է նեյրոններից, որոնցից յուրաքանչյուրը կապված է հաջորդող շերտի բոլոր նեյրոնների հետ: Այդ նեյրոններն ունեն միմյանց կապող կապուղիներ, որոնք ունեն յուրօրինակ կշիռ կամ գործակից "**w**": Տվյալ կապուղու կշռի արժեքը բազմապատկվում է դրանով փոխանցվող տվյալների արժեքներին: Բացառությամբ մուտքային շերտի նեյրոնների, ցանկացած նեյրոն կապնվում է նախորդ շերտի բոլոր նեյրոնների հետ և իր մուտքին դրանցից բոլորից ստացված արժեքները գումարվում են և այդ գումարը հանդիսանում է տվյալ նեյրոնի մուտքային արժեքը: Այն դեպքում, երբ այդ գումարը գերազանցում է նախապես սահմանված շեմային արժեքն, ապա տվյալ նեյրոնի ելքը 1 է, իսկ հակառակ դեպքում՝ 0: Այս ելքային արժեքները համապատասխանաբար բնորոշում են նեյրոնի ակտիվ և պասիվ վիճակները: Մեկ շերտանի պերցեպտրոնն արդյունավետ լուծում չի հանդիսանում բարդ հաշվարկներ պահանջող խնդիրների համար ինչպիսիք են՝ տվյալների դասակարգումը կամ մարդկային դեմքի ճանաչումը: Նման խնդիրների համար օգտագործվում են բազմաշերտ արհեստական նեյրոնային ցանցեր, որոնք բաղկացած են մեկ մուտքային շերտից, մեկից ավելի թաքնված շերտերից և մեկ ելքային շերտից: Նկ. 2.6-ում պատկերված է երկու թաքնված շերտից բաղկացած ԱՆՑ-ի սխեման:



Նկ. 2.6 Բազմաշերտ նեյրոնային ցանց

Այստեղ՝ $i = 1, 2, \dots, N$; $j = 1, 2, \dots, J$; $h = 1, 2, \dots, H$; $k = 1, 2, \dots, K$, որտեղ $i - ն, j - ն, h - ն, k - ն$ համապատասխան շերտի նեյրոնների համարներն են, իսկ $l - ը$ ($l = 0, 1, \dots, L$) շերտի համարը:

Բացառությամբ ելքային շերտի, մնացած նեյրոնները կապված են իրենց հաջորդող շերտի նեյրոնների հետ կապուղիներով, որոնցից յուրաքանչյուրն ունի առանձնահատուկ կշիռ: Մուտքային և դրան հաջորդող շերտի համար նշանակենք այդ կշիռը՝ w_{ij} : ԱՆՑ-ում նաև գոյություն ունի «Բիաս» նեյրոն հասկացությունը, որն իրենից ներկայացնում է լրացուցիչ նեյրոնային հանգույց՝ բոլոր շերտերի համար, բացառությամբ մուտքային շերտի: Բիաս նեյրոնը կապված է տվյալ շերտի բոլոր նեյրոնների հետ և այդ նեյրոնի ելքային արժեքը մշտապես հավասար է 1-ի: Բիաս նեյրոնները կիրառվում են ցանցի նեյրոնների մուտքին տրված 0 արժեքի հետևանքով առաջացած թերի ուսուցումը չեզոքացնելու նպատակով: Այն դեպքում, երբ նեյրոնների մուտքին տրվում է 0, ցանցը չի կարողանում լիարժեք անցնել ուսուցման փուլը և թերի է սովորում: Ինքնուրույն սովորելու ունակությունը նեյրոնային ցանցերի կարևորագույն

առանձնահատկություններից է: Սովորելու գործառույթը լինում է երեք տեսակի՝ վերահսկվող, չվերահսկվող և ամրապնդվող:

- Վերահսկվողն այն ուսուցման տեսակն է, որի դեպքում ցանցին տրվում են մուտքային և պահանջվող ելքային արժեքների ուսուցողական զույգերի խմբեր: Ուստի՝ իմանալով ցանկալի ելքային արժեքը, հանելով պահանջվող արժեքից փաստացի ստացված ելքային արժեքը հնարավոր է հաշվել ցանցի սխալի չափը: Ցանցի սխալի չափն իմանալու դեպքում հակադարձ տարածման հնարքի միջոցով փոփոխվում են կապուղիների կշիռները և հաստատվում է այնպիսի կշիռների համադրություն, որի դեպքում փաստացի ստացված արժեքը հավասարեցվում է ցանկալի արժեքին:
- Չվերահսկվող է կոչվում այն ուսուցման տեսակը, որի դեպքում ցանցին տրվում է մուտքային տվյալների խումբ և ցանցը դրանց շրջանակում պետք է ինքնուրույն հայտնաբերի որևէ նմուշ: Այս տեսակը հաճախ օգտագործվում է խորհրդատվական ալգորիթմներում, ելնելով նրանց կանխագուշակման ունակությունից: Դրանք գուշակում են օգտագործողի նախապատվությունները ելնելով տվյալ օպերատորին համապատասխան խմբավորված օպերատորների նախապատվություններից:
- Ամրապնդվող ուսուցումը նման է վերահսկվողին այն իմաստով, որ նույնպես ունի հետադարձ կապ, բայց ելքային փաստացի արժեք ստանալու փոխարեն նա ստանում է դրական հատուցում, կախված նրանից, թե ինչ ճշտությամբ է կատարել իր առաջադրանքը: Այս ուսուցման տեսակի նպատակն է ցանցի սխալվել-ուղղվելու հիման վրա բարելավվել հատուցումը: Սկզբունքորեն այս տեսակը նման է կենդանու վարքագծին, երբ վերջինս հիշում և կրկնում է նախկինում իր կատարած քայլերը՝ կեր ստանալու համար:

ԱՆՑ մուտքային շերտի նեյրոնների ելքերը նույն դրանց մուտքին տրված x_i ազդանշաններն են, իսկ հաջորդ շերտի նեյրոնների մուտքերը բնութագրվում են հետևյալ հավասարմամբ՝

$$Net_j^{l_1} = \sum_{i=1}^N x_i w_{ij} + \theta_j, \quad (2.9)$$

որտեղ i -ն մուտքի համարն է; j -ն նեյրոնի համարը շերտում; l -ը շերտի համարն է; θ_j -ն բիաս նեյրոնի ելքային արժեքի և տվյալ կապուղու կշռի արտադրայալը՝ $\theta_j = 1 \times w_{bj}^l$, $l = 1, 2, \dots, L$: Նեյրոնի ներսում դրա մուտքային արժեքը տրվում է տվյալ նեյրոնի $f(x)$ ակտիվացման ֆունկցիային: Ակտիվացման ֆունկցիաները լինում են տարբեր տեսակի [53]՝

- Գծային - $f(x) = k \cdot x$

- Գծային սահմանափակված - $f(x) = \begin{cases} p, & x > \alpha \\ -p, & x < -\alpha \\ x, & -\alpha < x < \alpha \end{cases}$,

p – որոշակի արժեք, $-\alpha$ և α – շեմային արժեք

- Բինար - $f(x) = \text{sign}(x) = \begin{cases} 1, & x > 0 \\ 0, & x \leq 0 \end{cases}$

- Փոփոխված սահմանային - $f(x + 1) = \begin{cases} 1, & x > 0 \\ f(x), & x = 0 \\ -1, & x < 0 \end{cases}$

- Հիպերբոլիկ տանգենս - $f(x) = \text{th}(c \cdot x) = \frac{e^{cx} - e^{-cx}}{e^{cx} + e^{-cx}}$,

$c > 0$ – սիգմոիդի լայնության գործ., ըստ արսցիսների առանցքի

- Լոգարիֆմիկ - $f(x) = \ln(x + \sqrt{x^2 + 1})$,

բնորոշ է նրանով, որ ունի $[-\infty; \infty]$ արժեքների տիրույթ՝

բեկման կետով կոորդինատային առանցքի սկզբում

- Սիգմոիդ - $f(x) = \frac{1}{1 + e^{-x}}$,

- Բիպոլյար սիգմոիդ - $f(x) = \frac{1}{1 + e^{-x}} - 0.5$, արժեքների տիրույթ – $[-0.5; 0.5]$

Վերոնշյալ բոլոր դեպքերում $x = \text{Net}_j^{l_1}$:

Սիգմոիդ ֆունկցիան մոնոտոն է և տարածվում է դիֆերենցելի ամբողջ տիրույթում, որի հետևանքով լայն կիրառություն է ստացել արհեստական նեյրոնային ցանցերում:

Նեյրոնի ելքը, մուտքին տրված արժեքն ակտիվացման ֆունկցիային տրվելուց հետո, ստանում է հետևյալ տեսքը՝

$$O_j^{l_1} = f\left(\sum_{i=1}^N x_i w_{ij} + \theta_j\right): \quad (2.10)$$

Հաջորդ շերտին անցում կատարելիս կապուղու կշիռները բազմապատկվում են $O_j^{l_1}$ ին: Հետևաբար՝ l_2 շերտի նեյրոնների մուտքային և ելքային արժեքները համապատասխանաբար բնութագրվում են հետևյալ կերպ՝

$$Net_h^{l_2} = \sum_{j=1}^J O_j^{l_1} w_{jh} + \theta_h, \quad (2.11)$$

$$O_h^{l_2} = f \left(\sum_{j=1}^J O_j^{l_1} w_{jh} + \theta_h \right): \quad (2.12)$$

Ելքային շերտի համար կունենանք՝

$$Net_k^L = \sum_{h=1}^H O_h^{l_2} w_{hk} + \theta_k, \quad (2.13)$$

$$O_k^L = f \left(\sum_{h=1}^H O_h^{l_2} w_{hk} + \theta_k \right): \quad (2.14)$$

Թեստավորման փուլում աշխատելու համար ԱՆՑ-երին անհրաժեշտ է անցնել ուսուցանում: Ուսուցման ժամանակ ցանցի նեյրոնների կապուղիների կշիռներին տրվում են պատահական փոքր արժեքներ, որոնց միջոցով ցանցն իրականացնում է հաշվարկներ և ելքում ստանում է տվյալներ, որոնք բնականաբար տարբերվում են պահանջված արժեքներից: Որպեսզի ցանցը կարողանա ելքում ստանալ ճշգրիտ արժեքներ անհրաժեշտ է սահմանել այնպիսի կշիռների համադրություն, որոնց դեպքում համակարգի սխալը կունենա նվազագույն արժեք: Այսպիսով, ուսուցման փուլի նպատակն է հաշվարկել այնպիսի կշիռների արժեքներ, որոնց դեպքում ցանցի ելքային արժեքներն առավելագույնս մոտ կլինեն պահանջվող արժեքներին: Այս խնդրի լուծման համար կիրառվում է սխալանքի հակադարձ տարածման մեթոդը:

2.1.1.1 Սխալանքի հակադարձ տարածում

ԱՆՑ-երն ուսուցանելու համար ցանցի մուտքերին տրվում են ուսուցանող տվյալների խումբ՝ (x_z, t_z) , $z = 1, 2, \dots, P$, որտեղ t_z – դա մուտքային x_z տվյալներին համապատասխանող ելքային արժեքներն են, իսկ P -ն՝ ուսուցանող զույգերի ընդհանուր քանակը: Ուսուցման ընթացքում համակարգը հաշվարկում է ելքում ստացված և

պահանջվող արժեքների տարբերությունը սխալանքի ֆունկցիայով, որը բնութագրվում է հետևյալ հավասարմամբ՝

$$E_z = \frac{1}{2} \sum_{k=1}^K (y_k - t_{zk})^2: \quad (2.15)$$

Հավասարում (2.15)-ում՝ t_{zk} -ն դա t_z -ի z -րդ էլեմենտն է, իսկ y_k -ն k -րդ ստացված էլքային արժեքը: Հետևաբար ցանցի ընդհանուր սխալը հաշվարկվում է հետևյալ հավասարմամբ՝

$$E = \sum_z E_z = \frac{1}{2} \sum_z \sum_k (t_{zk} - y_k)^2: \quad (2.16)$$

Ուսուցման սկզբում w կշիռներին տրվում են պատահական փոքր արժեքներ, իսկ ուսուցման ընթացքում կշիռները թարմացվում են դեպի գրադիենտի բացասական ուղղություն այնքան ժամանակ, մինչ E -ն կստանա հնարավորինս նվազագույն արժեք: Ցանցի նեյրոնները միմյանց կապող յուրաքանչյուր կապուղու կշռի արժեքը թարմացվում է հետևյալ հավասարմամբ՝

$$w_{ij} = w_{ij} - \Delta w_{ij}, \quad (2.17)$$

որտեղ

$$\Delta w_{ij} = \eta \frac{\partial E_z}{\partial w_{ij}}: \quad (2.18)$$

Հավասարում (2.18)-ում՝ η -ն ուսուցման արագության գործակիցն է: Ելքային շերտի համար E_z -ի ածանցյալը ըստ w_{hk} -ի կարելի է հաշվարկել պարզ դիֆերենցիալ հավասարմամբ՝

$$\frac{\partial E_z}{\partial w_{hk}} = \frac{\partial E_z}{\partial O_k} \frac{\partial O_k}{\partial \text{Net}_k^L} \frac{\partial \text{Net}_k^L}{\partial w_{hk}}, \quad (2.19)$$

որտեղ

$$\frac{\partial E_z}{\partial O_k} = \frac{1}{2} \frac{\partial}{\partial O_k} (t_{zk} - O_k)^2 = O_k - t_{zk}, \quad (2.20)$$

$$\frac{\partial O_k}{\partial Net_k^L} = \frac{\partial}{\partial Net_k^L} f(Net_k^L) = O_k(1 - O_k), \quad (2.21)$$

$$\frac{\partial Net_k^L}{\partial w_{hk}} = \frac{\partial}{\partial w_{hk}} \left(\sum_{h=1}^H O_h^L w_{hk} + \theta_k \right) = O_h : \quad (2.22)$$

Այսպիսով ստանում ենք՝

$$\frac{\partial E_z}{\partial w_{hk}} = (O_k - t_{zk}) O_k (1 - O_k) O_h : \quad (2.23)$$

Ելնելով հավասարում (2.23)-ից էլքային շերտի համար կունենանք՝

$$\frac{\partial E_z}{\partial w_{hk}} = \delta_k = (O_k - t_{zk}) O_k (1 - O_k), \quad (2.24)$$

որից կհետևի, որ մնացած շերտերի համար համապատասխանաբար կստանանք՝

$$\delta_h = O_h (1 - O_h) \sum_{k=1}^K w_{hk} \delta_k, \quad (2.25)$$

$$\delta_j = O_j (1 - O_j) \sum_{h=1}^H w_{jh} \delta_h, \quad (2.26)$$

$$\delta_i = O_i (1 - O_i) \sum_{j=1}^J w_{ij} \delta_j : \quad (2.27)$$

Հավասարում (2.18)-ից հետևում է, որ յուրաքանչյուր հաջորդ շերտերի համար կշոյի փոփոխությունը կբնութագրվի համապատասխանաբար հետևյալ հավասարումներով՝

$$\Delta w_{hk} = \eta \delta_k O_h, \quad (2.28)$$

$$\Delta w_{jh} = \eta \delta_h O_j, \quad (2.29)$$

$$\Delta w_{ij} = \eta \delta_j O_i : \quad (2.30)$$

2.1.1.2 ԱՆՑ կիրառումը ՄԱՆ համակարգերում

ԱՆՑ-ի միջոցով ՄԱՆ-ի խնդրի լուծման համար ցանցի յուրաքանչյուր մուտքին տրվում է մեկ հաշվարկված հիմնական բնութագրող հատկանիշ, ինչի արդյունքում նեյրոնների համապատասխան ակտիվ և պասիվ վիճակների հաշվարկների և

համադրությունների միջոցով ակտիվանում է ելքային շերտի այն նեյրոնը, որը համապատասխանում է նույնականացված մոդուլացման տեսակին: Անհրաժեշտ է հաշվի առնել ցանցի մուտքին տրված բնութագրող հատկանիշների քանակը, քանի որ դրանց քանակի ավելացումը և նվազեցումը անմիջական ազդեցություն ունի հաշվարկների բարդության և ուսուցման տևողության վրա: Բազմաշերտ ԱՆՑ-ի դեպքում ցանցի կառուցվածքի որոշման հստակ մեխանիզմ գոյություն չունի: Խորհուրդ է տրվում թաքնված շերտերի և դրանց բաղկացուցիչ մաս կազմող նեյրոնների քանակը համապատասխանեցնել տվյալ խնդրին: Դրանց քանակը պետք է համապատասխանի խնդրի բարդությանը, քանի որ դրանց անհրաժեշտ քանակի պակասի դեպքում կարող է սուժել նույնականացման որակը, իսկ ավելցուկի դեպքում՝ երկարում է ուսուցման տևողությունը: Ուսուցման որակի բարելավման համար բավականին լայն հնարավորություններ է ստեղծում դրանց քանակի ինքնակազմակերպումը:

ԱՆՑ-ները համարվում են նմուշի ճանաչման մոտեցման ամենաարդյունավետ տեխնոլոգիաներից, քանի որ ունեն մի շարք նշանակալի առավելություններ: ԱՆՑ-ի մուտքերին ազդանշանի հիմնական բնութագրող հատկանիշները տրվում են զուգահեռ, որի արդյունքում համակարգի պատասխանի ճշտությունը կախված չէ դրանց հերթականությունից: Հիմնական բնութագրող հատկանիշների մշակմանը զուգահեռ բաշխված սխեման ապահովում է համակարգի ազդանշանների թվային մշակման վերադասավորման հնարավորությունն ու հարմարավետությունը: Այս ամենի հետ մեկտեղ ԱՆՑ-ները չունեն ուսուցման լրացուցիչ ծրագրավորման կարիք , քանի որ դրանք սովորում են ինքնուրույն և ադապտացվում են բարդ հաշվարկներին, որը համարվում է դրանց գլխավոր առավելություններից մեկը:

Մինևույն ժամանակ ԱՆՑ-ի կիրառման դեպքում վերանում է ելքային արժեքների տիրույթների վերին և ցածր շեմերի նախնական մեխանիկական հաշվարկների անհրաժեշտությունը:

Այս ցանցերի հետազոտությունները շարունակվում են առ այսօր և նրանք կիրառվում են այնպիսի ոլորտներում, ինչպիսիք են՝ բժշկությունը, ֆինանսները, էներգետիկ արդյունաբերությունը և այլն: Հուսադրող և հիմնարար փաստ է հանդիսանում նաև այն, որ բազմաթիվ սիմուլյացիաների և մշակված ալգորիթմների [54-

58] արդյունքները ցույց են տալիս, որ ԱՆՑ-ներն ունեն գրեթե իդեալական ցուցանիշներ ՄԱՆ-ի համար:

Ի լրումն վերոնշյալին՝ հարկ է նշել, որ ԱՆՑ-երը ընկած են ներկայումս կայծակնային արագությամբ զարգացող տեխնոլոգիաներից մեկի՝ արհեստական ինտելեկտի, հիմքում, ինչը ապահովում է դրանց հետագա շարունակական զարգացումը: Սա հնարավորություն կընձեռի ապագայում էլ ավելի բարելավվել և զարգացնել այս մոդուլացման տեսակի նույնականացման համար կիրառվող տեխնոլոգիան, ինչը հնարավորություն կտա առավել մեծ ճշտությամբ լուծել ՄԱՆ խնդիրը:

2.2 Նույնականացման մեթոդների համեմատական վերլուծություն և մեթոդի ընտրություն

Գոյություն ունեն բազմաթիվ նույնականացման, դասակարգման մեթոդներ և ալգորիթմներ որոնցից յուրաքանչյուրը նախատեսված է կոնկրետ խնդիրների լուծման համար, ունի իր առանձնահատկությունները, իրականացման բարդությունները, առավելությունները և թերությունները: Հաշվի առնելով վերոնշյալ բոլոր չափանիշները՝ տվյալ աշխատանքի հիմքում ընկած խնդրի լուծման համար հարկավոր է ընտրել այն տեխնոլոգիան, որի միջոցով հնարավոր կլինի ստանալ ամենից բարձր մոդուլացման տեսակների նույնականացման ճշտություն: Մոդուլացումների ճանաչման հիմնական երկու՝ տեսական որոշման և նմուշի ճանաչման, մոտեցումներից ավելի նպատակահարմար ճանաչվեց նմուշի ճանաչման մեթոդը, քանի որ տեսական որոշման մոտեցումն ունի այնպիսի թերություններ, որոնք զգալի սահմանափակում են դրված խնդրի լուծման հնարավորությունները: Տեսական որոշման մոտեցման հիմքում ընկած է հավանականության խտության ֆունկցիան, այսինքն դասակարգիչը ընտրությունը կատարում է ելնելով տվյալ տեսակի պատահման հավանականությունից: Հավանականության խտության ֆունկցիաների օպտիմալացումը զգալի բարդացնում են հաշվարկները: Բացի դրանից հավանականությունը չափելու համար հարկավոր է մոդուլացումների բոլոր տեսակների համար նախապես մեխանիկորեն հաշվարկել ազդանշանի հիմնական բնութագրող հատկանիշների շեմային արժեքները, ինչը լրացուցիչ ժամանակային ռեսուրսներ է պահանջում: Տեսական որոշման մոտեցման դեպքում նույնականացման ճշտությունը կախված է համակարգի մուտքին տրված

ազդանշանի բնութագրող հատկանիշների արժեքների հստակ հերթականությունից, ինչը բացառում է զուգահեռ հաշվարկներ իրականացնելու հնարավորությունը: Այս թերությունը զգալի երկարացնում է հաշվարկների տևողությունը և նվազեցնում է դասակարգչի աշխատանքի որակը, քանի որ հաշվարկների իրականացման արագությունը չափազանց կարևոր դեր է խաղում իրական ժամանակում դասակարգչի աշխատանքի համար:

Ինչ վերաբերում է նմուշի ճանաչման մոտեցման շրջանակներում ուսումնասիրված մեթոդներին, ապա ինչպես արդեն նշվել է վեյվլեթ ձևափոխության միջոցով ազդանշանի գլխավոր բնութագրող հատկանիշների ստացումը նպատակահարմար չէ, քանի որ որպես հեռանկար նախատեսվում է ալգորիթմի իրական ժամանակում աշխատելու արագության բարձրացման համար կիրառել FPGA-ներ, ինչը լրացուցիչ հաշվարկային բարդությունների կատեղծի LabVIEW գրաֆիկական ծրագրավորման միջավայրում:

Նմուշի ճանաչման մոտեցման շրջանակում ընկած մեթոդներից ազդանշանի համաստեղության միջոցով մոդուլացման ճանաչումը նույնպես չի համապատասխանում այս աշխատանքի խնդրի պահանջներին, քանի որ այն կիրառելի չէ անալոգային մոդուլացումների համար:

Այսպիսով, աջակցող վեկտորային մեքենաների և արհեստական նեյրոնային ցանցերի միջև ընտրությունը կատարվել է արհեստական նեյրոնային ցանցերի օգտին: ԱՆՑ-երի հիմնական և կարևորագույն հատկությունը, որը համարվում է որոշիչ այս ընտրության մեջ, դա դրանց ինքնուրույն սովորելու ունակությունն է: Այս հատկությունը հնարավորություն է տալիս խուսափելու բարդ և ժամանակատար հաշվարկներից, ուսուցման լրացուցիչ ծրագրավորումից, յուրաքանչյուր մոդուլացման տեսակի հիմնական բնութագրող հատկանիշների համար արժեքների շեմերի նախնական մեխանիկական հաշվարկից: Կառուցելով արհեստական նեյրոնային ցանցը հնարավոր է նրան շատ մեծ քանակի ինֆորմացիա սովորեցնել, այդպիսով ապահովելով արդյունքների շատ մեծ ճշտություն: Նեյրոնային ցանցը հեշտ է վերակազմավորել դրված խնդրի պահանջներին համապատասխան և փոփոխելով թաքնված շերտերի նեյրոնների քանակը ստանալ հաշվարկների ավելի բարձր արագություն և ճշտություն: Ցանցի մուտքին տրված ազդանշանի հիմնական բնութագրող հատկանիշների

հերթականությունը նշանակություն չունի ԱՆՑ-ի համար, քանի որ նրանք ապահովում են տվյալների զուգահեռ մշակումը, ինչը ևս զգալի արագացում է հաշվարկների տևողությունը և հանդիսանում տվյալ մեթոդի կարևորագույն առավելություններից մեկը:

Ի տարբերություն մնացած նույնականացման մեթոդների ԱՆՑ-ը հնարավորություն ունի տոկոսային հարաբերակցությամբ արտացոլելու առավել ճիշտ պատասխանը: ԱՆՑ-երի զարգացումները նշանակալի հեռանկարներ են ստեղծում ՄԱՆ խնդրի լուծման ալգորիթմների բարելավման և զարգացման համար: Հիմնվելով վերոնշյալ առավելությունների և առանձնահատկությունների վրա ԱՆՑ համարվում է այս աշխատանքի հիմքում ընկած խնդրի լուծման համար առավել արդյունավետ, նպատակահարմար, արդիական և արագ աշխատող մեթոդը:

ԳԼՈՒԽ 3. ԴԻՏԱՐԿՎՈՂ ՄՈԴՈՒԼԱՑՄԱՆ ՏԵՍԱԿՆԵՐԸ ԵՎ ԱԶԴԱՆՇԱՆՆԵՐԻ ՀԻՄՆԱԿԱՆ ԲՆՈՒԹԱԳՐՈՂ ՀԱՏԿԱՆԻՇՆԵՐԸ

Ինչպես արդեն նշվել է ՄԱՆ համակարգերը բաղկացած են երեք հիմնական բլոկերից՝ ընդունված հեռահաղորդակցական ազդանշանի մշակման, մոդուլացման տեսակի նույնականացման և դեմոդուլացման: Ազդանշանի մշակման բլոկում ընդունված անհայտ ազդանշանը բաժանվում է հավասար երկարության հաջորդական սեգմենտների, որոնցից առանձնացվում են հիմնական բնութագրող հատկանիշները: Ազդանշանի հիմնական բնութագրող հատկանիշները այն տվյալներն են, որոնք բնութագրում են տվյալ ազդանշանի առանձնահատկությունները: Ճիշտ ընտրված բնութագրող հատկանիշների դեպքում հնարավոր է շատ մեծ ճշտությամբ որոշել ազդանշանի մոդուլացման տեսակը, քանի որ այդ բնութագրող հատկանիշների արժեքները յուրաքանչյուր մոդուլացված ազդանշանի համար հատուկ կլինեն: Գույություն ունեն մոդուլացման տեսակներ, որոնց դեպքում բնութագրող հատկանիշներից որևէ մեկի արժեքներն այդ տեսակների համար շատ մոտ են կամ հավասար են, բայց չկան այնպիսի մոդուլացման տեսակներ, որոնց համար բոլոր բնութագրող հատկանիշների արժեքները հավասար են միմյանց: Հիմնական բնութագրող հատկանիշների հաշվարկի համար կիրառվել են ազդանշանի այնպիսի պարամետրեր, ինչպիսիք են ակնթարթային ամպլիտուդան, ակնթարթային փուլը, ակնթարթային հաճախականությունը և հզորության սպեկտրը:

Այս աշխատանքի շրջանակներում ուսումնասիրվել են անալոգային և թվային մոդուլացման տեսակները և դրանց համապատասխան հիմնական բնութագրող հատկանիշներն ու դրանց հաշվարկը [59-60]:

3.1 Անալոգային մոդուլացման տեսակները

Անալոգային մոդուլացման տեսակների նույնականացման համար նախատեսված ազդանշանների հիմնական բնութագրող հատկանիշների գործառույթների նկարագրման նպատակով այս աշխատանքում ներկայացվել են DSB, SSB և FM անալոգային մոդուլացման տեսակները [61-62]:

DSB ամպլիտուդային մոդուլացում

DSB անալոգային մոդուլացման դեպքում մոդուլացված $s(t)$ ազդանշանը բնութագրվում է հետևյալ հայտնի հավասարման տեսքով [61]

$$s(t) = A(t)_c(1 + mx(t))\cos(\omega_0 t), \quad (3.1)$$


որտեղ $A(t)_c$ -ն կրողի ամպլիտուդան է, m -ը մոդուլացման ինդեքսը, $x(t)$ -ն ինֆորմացիոն ազդանշանը, իսկ ω_0 -ն կրողի հաճախականությունը: Այն դեպքերում, երբ մոդուլացման $x(t)$ ֆունկցիան պարբերական է և արտահայտվում է Ֆուրյեի շարքով, ապա ստացվում է՝

$$x(t) = \sum_{k=1}^{\infty} c_k \cos(k\omega_1 t - \varphi_k), \quad (3.2)$$

որտեղ $k = 1, 2, \dots, N$, c_k -ն և φ_k -ն համապատասխանաբար k -րդ տատանման ամպլիտուդան և փուլն են, իսկ ω_1 ազդանշանի հաճախականությունն է: Հավասարում (3.1)-ից և (3.2)-ից հետևում է՝

$$\begin{aligned} s(t) &= A(t)_c \left[1 + m \sum_{k=1}^{\infty} c_k \cos(k\omega_1 t - \varphi_k) \right] \cos(\omega_0 t) = \\ &= A(t)_c \left\{ \cos(\omega_0 t) + \frac{m}{2} \sum_{k=1}^{\infty} c_k \cos[(\omega_0 + k\omega_1)t - \varphi_k] + \right. \\ &\quad \left. + \frac{m}{2} \sum_{k=1}^{\infty} c_k \cos[(\omega_0 - k\omega_1)t + \varphi_k] \right\} \end{aligned} \quad (3.3)$$

Այսպիսով, DSB մոդուլացված ազդանշանի սպեկտրը բաղկացած է ω_0 հաճախությամբ տատանումից, $(\omega_0 + k\omega_1)$ և $(\omega_0 - k\omega_1)$ հաճախականություններով տատանումներից: Հաճախականային տիրույթում դրանք երկու կողային շերտերն են՝ կրողի ձախ և աջ կողմերից, որոնք կոչվում են համապատասխանաբար ցածր կողային շերտ LSB և բարձր կողային շերտ USB: Նկ. 3.1-ում պատկերված է DSB մոդուլացված ազդանշանի սպեկտրը, որը համաչափ է կրող ազդանշանի նկատմամբ:



Նկ. 3.1 DSB մոդուլացված ազդանշանի սպեկտրը

SSB ամպլիտուդային մոդուլացում

SSB մոդուլացումը դա մեկ կողային շերտով ամպլիտուդային մոդուլացումն է, որը բաժանվում է երկու տեսակի՝ ցածր կողային շերտով LSB մոդուլացում և բարձր կողային շերտով մոդուլացում USB: Ինչպես երևում է նկ. 3.1-ում DSB ազդանշանի կրողն աջ և ձախ կողմից ունի կողային թերթիկներ, որոնք պարունակում են միևնույն տեղեկատվությունը: Հետևաբար, դրանցից միայն մեկն է անհրաժեշտ ինֆորմացիայի փոխանցման համար: Այդ նպատակի իրականացման համար է ծառայում SSB մոդուլացումը: SSB մոդուլացման դեպքում, կողային շերտերից մեկի գտման համար դիմում են Հիլբերտ ձևափոխման օգնությանը: SSB մոդուլացման դեպքում կրողը բնութագրվում է հետևյալ հավասարմամբ [62]՝

$$s(t) = x(t)\cos(\omega_0 t) \pm x_m(t)\sin(\omega_0 t), \quad (3.4)$$

որտեղ $x(t)$ -ն մոդուլացվող ազդանշանն է, իսկ $x_m(t)$ -ն դա $x(t)$ -ի օրթոգոնալ լրացումն է, որը հաշվարկվում է Հիլբերտ ձևափոխման միջոցով: Ենթադրենք, որ $x(t)$ – ն դա N քանակի հարմոնիկների գումար է, ապա կունենանք՝

$$x(t) = \sum_{k=1}^N c_k \cos(\omega_k t + \varphi_k), \quad (3.5)$$


որտեղ c_k – ն, f_k – ն և φ_k – ն համապատասխանաբար k -րդ հարմոնիկի ամպլիտուդան, հաճախականությունը և փուլն են: Օրթոգոնալ լրացումը կբնութագրվի հետևյալ տեսքով՝

$$x_m(t) = \sum_{k=1}^N c_k \sin(\omega_k t + \varphi_k) : \quad (3.6)$$

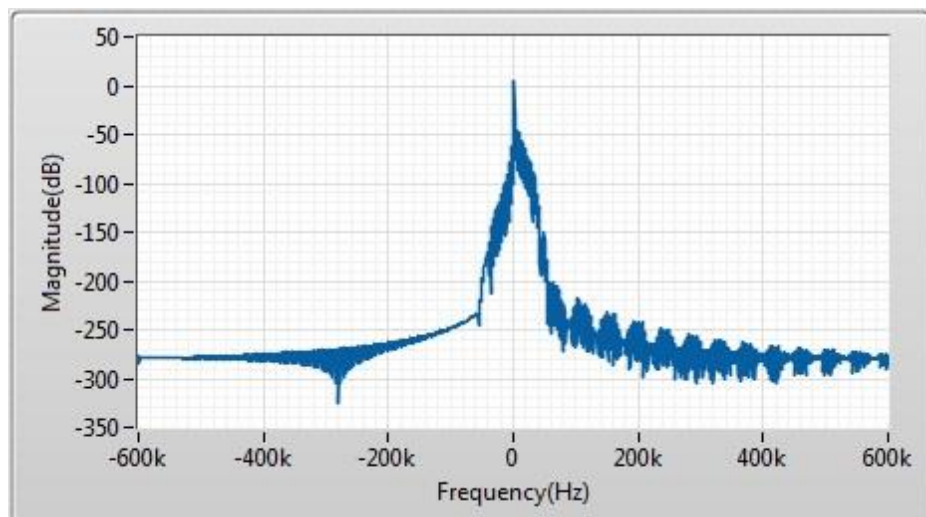
Այսպիսով, եթե տեղադրենք (3.5) և (3.6) հավասարումները (3.4) հավասարման մեջ, ապա կարող ենք ներկայացնել SSB մոդուլացումը հետևյալ տեսքով՝

$$s(t) = \sum_{k=1}^N c_k \cos((\omega_0 \pm \omega_k)t + \varphi_k) \quad (3.7)$$

Նկ. 3.2-ում պատկերված են LSB (ա) և USB (բ) մոդուլացված ազդանշանների սպեկտրները:



ա) LSB



բ) USB

Նկ. 3.2 LSB և USB մոդուլացված ազդանշանների սպեկտրները

Նկ. 3.2-ում երևում է, որ ի տարբերություն DSB ազդանշանի, SSB ազդանշանի սպեկտրի համաչափությունը խախտված է կողային թերթիկներից մեկի գոման պատճառով, ինչը հանդիսանում է նշված երկու մոդուլացման տեսակների հիմնական տարբերությունը:

FM հաճախականային մոդուլացում

FM մոդուլացված ազդանշանը բնութագրվում է հետևյալ հայտնի հավասարմամբ [61]՝

$$s(t) = A(t)_e \cos(\theta(t)), \quad (3.8)$$

որտեղ $\theta(t)$ -ն ակնթարթային փուլն է և փոփոխվող հաճախականության դեպքում բնութագրվում է հետևյալ կերպ՝

$$\theta(t) = \int [\omega_0 + \Delta\omega x(t)] dt = \omega_0 t + \Delta\omega \int x(t) dt: \quad (3.9)$$


Հետևաբար, հաճախականային մոդուլացված ազդանշանը կարելի է ներկայացնել հետևյալ հավասարման միջոցով՝

$$s(t) = A(t)_e \cos(\omega_0 t + \beta \sin(\Omega t)): \quad (3.10)$$

Հավասարում (3.10)-ում β -ն դա հաճախականային մոդուլացման ինդեքսն է, որը ցույց է տալիս թե ինչքանով է կրող հաճախականությունը շեղված կենտրոնական հաճախականությունից և բնութագրվում է հետևյալ կերպ՝

$$\beta = \frac{\Delta\omega}{\Omega}, \quad (3.11)$$

որտեղ $\Delta\omega$ -ն դա հաճախականային դեվիացիան է, որը հավասար է մոդուլացված ազդանշանի ակնթարթային հաճախականության և կենտրոնական կրող հաճախականության տարբերությունը, իսկ Ω -ն ինֆորմացիոն ազդանշանի հաճախականությունն է: Նկ. 3.3-ում պատկերված է հաճախականային մոդուլացված ազդանշանի սպեկտրը:




Նկ. 3.3 FM մոդուլացված ազդանշանի սպեկտրը

3.2 Անալոգային մոդուլացված ազդանշանների հիմնական բնութագրող հատկանիշները

3.2.1 Հզորության սպեկտրալ խտություն՝ γ_{max}

Այս աշխատանքում դիտարկված բոլոր մոդուլացումների տեսակների մոդելավորումներն իրականացվել են ամերիկյան «National Instruments» ընկերության LabVIEW [63] ծրագրավորման միջավայրում «NI Modulation Toolkit» [64] բաժնում ներառված վիրտուալ գործիքների միջոցով: Վերոնշյալ հիմնական բնութագրող հատկանիշի հաշվարկն իրականացվել է ցածրհաճախականային կոմպլեքս ազդանշանի տվյալների միջոցով՝ կոմպլեքս ազդանշանից «Unbundle By Name» գործիքի միջոցով առանձնացնելով կոմպլեքս արժեքների զանգվածը: Բոլոր ազդանշանների ակնթարթային ամպլիտուդան և փուլը ստացվել են «Complex to Polar» [65] վիրտուալ գործիքի միջոցով, որը պատկերված է նկ. 3.4-ում:



Նկ. 3.4 «Complex to Polar» վիրտուալ գործիք

Այս գործիքը հաշվարկում է ակնթարթային ամպլիտուդան և փուլը համապատասխանաբար՝

$$A(t) = |Z(t)| = |a(t) + jb(t)| = \sqrt{a(t)^2 + b(t)^2} \quad (3.12)$$

և

$$\theta = \arg(Z(t)) = \arctan2(b(t), a(t)) \quad (3.13)$$

հավասարումների միջոցով: Հավասարումներ (3.12)–ում և (3.13)–ում $Z(t)$ -ն ազդանշանի անալիտիկ ներկայացումն է, իսկ $a(t)$ -ն և $jb(t)$ -ն համապատասխանաբար այդ ազդանշանի իրական և կեղծ մասերն են: Ազդանշանի կրող հաճախականության իմացության դեպքում հաշվարկների հեշտացման համար կարելի է դրանք իրականացնել ցածր հաճախականային ազդանշանի վրա: Ստանալով ակնթարթային ամպլիտուդայի $a(t)$ արժեքների զանգվածը, ծրագիրը փոխանցում է այն վիրտուալ ենթազործիքի մուտքին, որն իրականացնում է Y_{max} -ի հաշվարկման գործառույթը: Y_{max} -ը հաշվարկվում է հետևյալ հավասարմամբ [8]

$$Y_{max} = \frac{\max_{FFT} |A(i)_{cn}|^2}{N_s}, \quad (3.14)$$

որտեղ $A(i)_{cn}$ -ը դա կենտրոնացված և նորմավորված ամպլիտուդան է և հաշվարկվում է հետևյալ կերպ՝

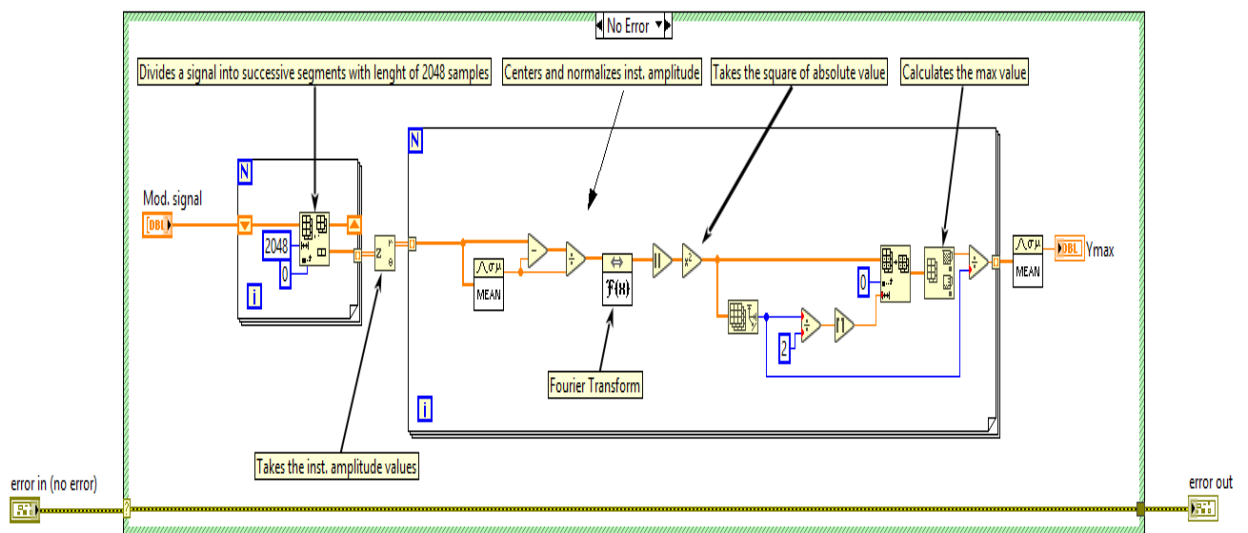
$$A(i)_{cn} = \frac{A(t)_i - A_m}{A_m}, \quad (3.15)$$

որտեղ $A(t)_i$ -ն դա ակնթարթային ամպլիտուդայի արժեքների զանգվածի i -րդ արժեքն է, իսկ A_m -ը ակնթարթային ամպլիտուդայի միջինացված արժեքն է և բնութագրվում է հետևյալ հավասարմամբ՝

$$A_m = \frac{1}{N_s} \sum_{i=1}^{N_s} A(t)_i, \quad (3.16)$$

որտեղ N_s -ը դա ազդանշանից առանձնացված սեգմենտի կետերի քանակն է: Արագ Ֆուրյե ձևափոխությունը իրականացվում է $A(i)_{cn}$ զանգվածի արժեքների նկատմամբ, որի արդյունքում ստացվում է ազդանշանի հաճախականային սպեկտրը: Այնուհետև սպեկտրի կետերին համապատասխան մագնիտուդների արժեքները բարձրացվում են քառակուսի՝ հզորության սպեկտրը ստանալու համար: Հաջորդիվ հզորության սպեկտրի առավելագույն արժեքը բաժանվում է բոլոր դիտարկված կետերի քանակի վրա: Այսպիսով՝ Y_{max} -ն ազդանշանի հզորության սպեկտրալ խտության առավելագույն արժեքն է: Այս հիմնական բնութագրող հատկանիշը կիրառվում է անալոգային մոդուլացումների ավտոմատացված նույնականացման ալգորիթմներում

հաճախականային FM և ամպլիտուդային DSB, SSB տեսակների խմբի տարբերակման համար: Հավասարում (3.10)-ից երևում է, որ FM մոդուլացված ազդանշանների ակնթարթային ամպլիտուդան ունի հաստատուն արժեք և հետևաբար այս մոդուլացման տեսակը ամպլիտուդային տեղեկատվություն չի պարունակում և դրա նորմավորված կենտրոնացված ակնթարթային ամպլիտուդան հավասար է զրոյի: Հետևաբար FM ազդանշանի հզորության սպեկտրալ խտության առավելագույն արժեքը միշտ ձգտում է զրոյի, իսկ DSB, SSB մոդուլացումների դեպքում Y_{max} -ը միշտ զրոյից մեծ արժեք է ստանում, քանի որ այդ տեսակների ակնթարթային ամպլիտուդան ունի զրոյից տարբեր արժեքներ: Նկ 3.5-ում պատկերված է Y_{max} -ի հաշվարկն իրականացնող ծրագրի հատվածը:



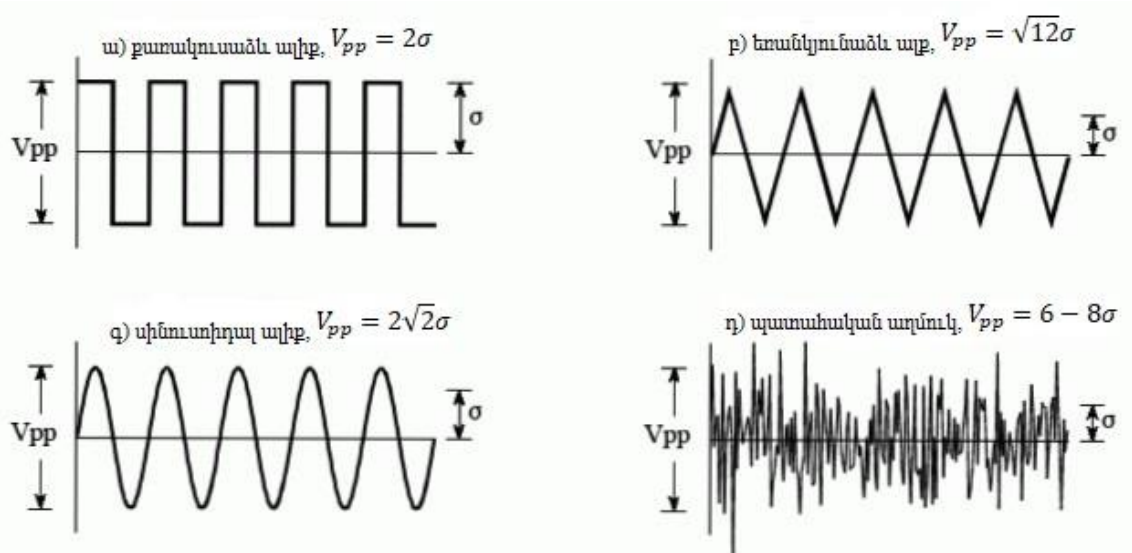
Նկ. 3.5 Y_{max} – ի հաշվարկը LabVIEW ծրագրավորման միջավայրում

Նկ. 3.5-ում պատկերված է ծրագրային միջավայրի բոլոր դիագրամը: Ինչպես երևում է նկարում՝ սկզբում մոդուլացված ազդանշանը բաժանվում է 2048 կետից բաղկացած հաջորդական սեգմենտների, որոնցից առանձնացվում է ազդանշանի ակնթարթային ամպլիտուդայի արժեքների զանգվածը: Այնուհետև՝ բոլոր սեգմենտների համար հերթականությամբ հաշվարկվում է նորմավորված և կենտրոնացված ակնթարթային ամպլիտուդան, իրականացվում է Ֆուրյե ձևափոխում, ձևափոխված ազդանշանի բացարձակ արժեքները բարձրացվում են քառակուսի և հաշվարկվում է դրանց առավելագույն արժեքը: Քանի որ նշված գործողությունները իրականացվում են առկա

բոլոր սեգմենտների համար, ապա արդյունքում ստացված սեգմենտների սպեկտրալ խտության առավելագույն արժեքները միջինացվում են:

3.2.2 Ակնթարթային փուլի կենտրոնացված ոչ գծային բաղադրիչի բացարձակ արժեքի ստանդարտ դեվիացիա՝ $\sigma_{բփ}$

Էլեկտրոնիկայում միջին ասելով հաճախ նկատի ունեն հաստատուն հոսանքի արժեքը (DC – Direct current), իսկ փոփոխական հոսանքը (AC – Alternating current) բնութագրում է ազդանշանի տատանումը միջին արժեքի շուրջ: Այն դեպքում, երբ ազդանշանը պարզ հաջորդական տատանվող ալիք է ինչպես սինուսը կամ քառակուսաձև ալիքը, ապա դրա տատանման մեծությունը կարելի է բնութագրել դրանց գագաթից-գագաթ ամպլիտուդայի արժեքով: Իրական ազդանշանների դեպքում հազվադեպ են հանդիպում մոնոքրոմատիկ տատանումներ՝ դրանք լինում են անկանոն, որոնց դեպքում գագաթից-գագաթ ամպլիտուդի արժեքի բնութագրումը դառնում է ոչ արդյունավետ, ինչի պատճառով հարկավոր է կիրառել ավելի ընդհանրացված մեթոդ՝ ստանդարտ դեվիացիա, որը բնութագրվում է σ (փոքրատառ սիգմա) նշանով: Նկ. 3.6-ում պատկերված են ստանդարտ դեվիացիայի և գագաթից-գագաթ արժեքների փոխկապակցվածությունը որոշ ազդանշանների համար [66]:



Նկ. 3.6 Ազդանշանների տատանման ստանդարտ դեվիացիան

Միջին շեղումը իրենից ներկայացնում է թիվ, որը բնութագրում է միջինից կետերի հեռավորության չափը: Այնուամենայնիվ միջին շեղումը գրեթե երբեք չի կիրառվում

ստատիստիկայում, քանի որ այն չի համապատասխանում ազդանշանների տատանման ֆիզիկական բնութագրերի հետ: Բազմաթիվ դեպքերում գլխավոր պարամետր է հանդիսանում ոչ թե շեղումը միջինից, այլ դրա շեղման հզորությունը: Ստանդարդ շեղումը նման է միջին շեղմանը բացառությամբ, որ միջինացումը իրականացվում է ոչ թե ամպլիտուդայի այլ հզորության արժեքով : Ստանդարդ դեվիացիան բնութագրվում է հետևյալ հավասարմամբ [66]՝

$$\sigma^2 = \frac{1}{N-1} \left[\sum_{i=0}^{N-1} x_i^2 - \left(\frac{1}{N} \sum_{i=0}^{N-1} x_i \right)^2 \right]; \quad (3.17)$$

Հաջորդ օգտագործված հիմնական բնութագրող հատկանիշը բնութագրվում է ակնթարթային փուլի ոչ գծային բաղադրիչի կենտրոնացված բացարձակ արժեքի ստանդարտ դեվիացիայի միջոցով: $\sigma_{\text{բփ}}$ հիմնական բնութագրող հատկանիշը հաշվարկվում է հետևյալ հավասարմամբ [8]՝

$$\sigma_{\text{բփ}} = \sqrt{\frac{1}{C} \left(\sum_{A(i)_n > A_t} \Phi(i)_{NL}^2 \right) - \left(\frac{1}{C} \sum_{A(i)_n > A_t} |\Phi(i)_{NL}| \right)^2}, \quad (3.18)$$

որտեղ $\Phi(i)_{NL}$ -ը դա ակնթարթային փուլի կենտրոնացված ոչ գծային բաղադրիչն է, C -ն դա այն կետերի քանակն է, որոնց համար $A(i)_n > A_t$, որտեղ $A(i)_n$ -ը նորմավորված ակնթարթային ամպլիտուդան է, իսկ A_t -ն նախապես որոշված ամպլիտուդայի շեմային այն արժեքը, որից ցածր հաշվարկները նպատակահարմար չեն՝ աղմուկների բարձր մակարդակի պատճառով: Ազդանշանի նորմավորված ակնթարթային ամպլիտուդան բնութագրվում է հետևյալ կերպ՝

$$A(i)_n = \frac{A(t)_i}{A_m}, \quad (3.19)$$

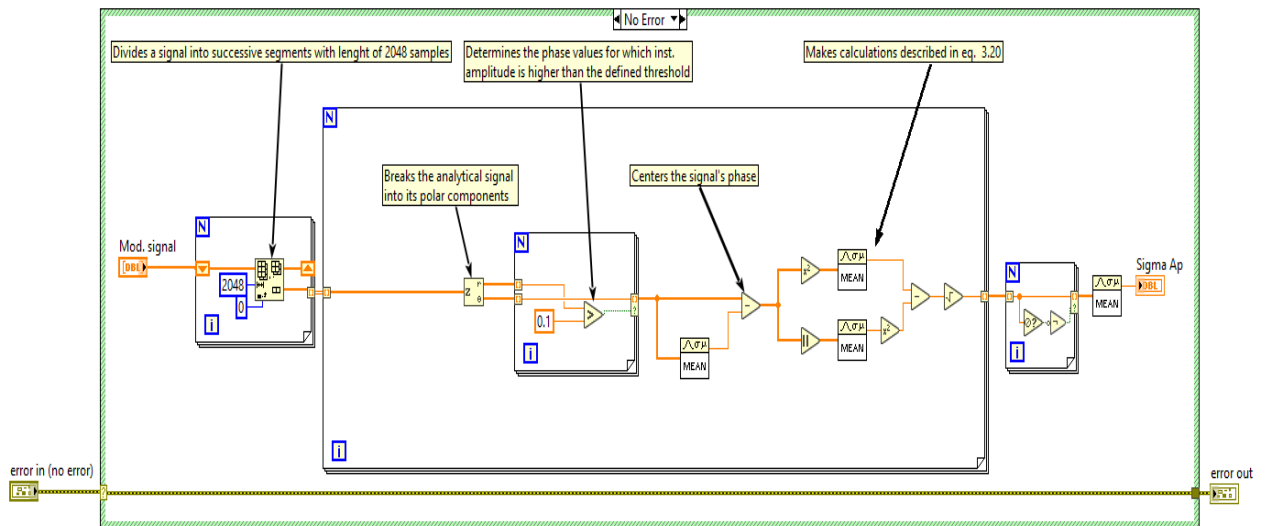
Այս հիմնական բնութագրող հատկանիշը կիրառվում է տարբերակելու համար այն մոդուլացման տեսակները, որոնք ունեն բացարձակ փուլային ինֆորմացիա և նրանց որոնք չունեն: Ուսումնասիրենք DSB մոդուլացման ակնթարթային փուլի արժեքները: Երկշերտանի ամպլիտուդային DSB մոդուլացված ազդանշանի անալիտիկ ներկայացվումը բնութագրվում է հետևյալ տեսքով [67]՝

$$z(t) = x(t)e^{j2\pi f_c t} : \quad (3.20)$$

Այս հավասարումից հետևում է, որ ակնթարթային փուլը DSB մուդուլացման դեպքում ունի երկու արժեք՝

$$\phi(t) = \begin{cases} 2\pi f_c t, & x(t) > 0 \\ 2\pi f_c t + \pi, & x(t) < 0 \end{cases} : \quad (3.21)$$

Քանի որ ազդանշանի փուլի գծային կոմպոնենտի հիմնական ներդրողը կրող ազդանշանն է, ապա գծային կոմպոնենտը $2\pi f_c t$ -ն հեռացնելուց հետո կստանանք ակնթարթային փուլի երկու արժեք՝ 0 և π : Այնուհետև կենտրոնացնելով փուլը՝ հանելով միջին արժեքը, ստանում ենք, որ կենտրոնացնելուց և գծային կոմպոնենտը հեռացնելուց հետո, փուլի բացարձակ արժեքը հաստատուն մեծություն է և հավասար է $|\frac{\pi}{2}|$, ինչը նշանակաւում է, որ DSB մոդուլացված ազդանշանը չունի բացարձակ փուլային ինֆորմացիա: Մյուս երկու դիտարկվող անալոգային մոդուլացված ազդանշանների՝ SSB և FM, ակնթարթային փուլի բացարձակ արժեքները հաստատուն չեն, ինչը հնարավորություն է տալիս այս հիմնական բնութագրի միջոցով տարբերակել DSB տեսակը SSB և FM տեսակներից: Նկ. 13-ում պատկերված է ծրագրի այն հատվածը, որն իրականացնում է $\sigma_{\text{բփ}}$ -ի հաշվարկը:



Նկ. 3.7 $\sigma_{\text{բփ}}$ – ի հաշվարկը LabVIEW միջավայրում

Նկ. 3.7-ում պատկերված ծրագրային կողը սկզբում, ինչպես նախորդ բնութագրող հատկանիշի դեպքում, առանձնացնում է մոդուլացված ազդանշանի հաջարդական

սեգմենտները և հաջորդիվ իրականացնում է հաշվարկները յուրաքանչյուր սեգմենտի համար: Առանձնացված սեգմենտի անալիտիկ ազդանշանից հաշվարկվում են ակնթարթային ամպլիտուդան և ակնթարթային փուլը: Այնուհետև իրականացվում է այն փուլային արժեքների առանձնացումը, որոնց դեպքում ակնթարթային ամպլիտուդան մեծ է նախապես որոշված շեմային արժեքից: Առանձնացված փուլային արժեքների համար իրականացվում է կենտրոնացում և այնուհետև իրականացվում է հաշվարկը ըստ հավասարում (3.18)-ի: Արդյունքում բոլոր սեգմենտների համար հաշվարկված $\sigma_{\text{փ}}$ -ի արժեքները միջինացվում են:

3.2.3 Հզորության սպեկտրի համաչափություն՝ P

P-ն բարձրհաճախականային ազդանշանի սպեկտրի աջ և ձախ կողային թերթիկների համաչափությունը կրողի նկատմամբ բնութագրող ազդանշանի հիմնական հատկանիշն է: Այն կիրառվում է SSB մոդուլացումների խումբը (LSB, USB) և DSB, FM մոդուլացումների խումբը միմյանցից տարբերակելու համար: Ինչպես արդեն նշվել էր՝ SSB մոդուլացումների դեպքում ազդանշանի կրողի աջ կամ ձախ կողային շերտը գտվում է, ինչն անհնարին է դարձնում սպեկտրի համաչափությունը: Մինևույն ժամանակ DSB, FM մոդուլացումների դեպքում ազդանշանի սպեկտրը կրողի շուրջ համաչափ է: Այս հիմնական բնութագրող հատկանիշը որոշվում է հետևյալ հավասարմամբ [8]՝

$$P = \frac{P_l - P_u}{P_l + P_u}; \quad (3.22)$$

Նշված հավասարման մեջ P_l -ը և P_u -ն համապատասխանաբար ցածր և բարձր կողային շերտերի սպեկտրալ հզորություններն են և բնութագրվում են հետևյալ հավասարումներով՝

$$P_l = \sum_{i=1}^{f_{cn}} |X(i)|^2, \quad (3.23)$$

$$P_u = \sum_{i=1}^{f_{cn}} |X(i + f_{cn} + 1)|^2; \quad (3.24)$$

Հավասարումներ (3.23)-ում և (3.24)-ում X_e -ն բարձրհաճախականային ազդանշանի Ֆուրյե ձևափոխությունն է, իսկ $(f_{cn} + 1)$ -ը ազդանշանի կրողին համապատասխանող կետի համարն է:

Բարձրհաճախականային ազդանշանի Ֆուրյե ձևափոխությունը հաշվարկվում է LabVIEW ծրագրային միջավայրում առկա վիրրտուլա գործիքի միջոցով՝ հետևյալ հավասարմամբ՝

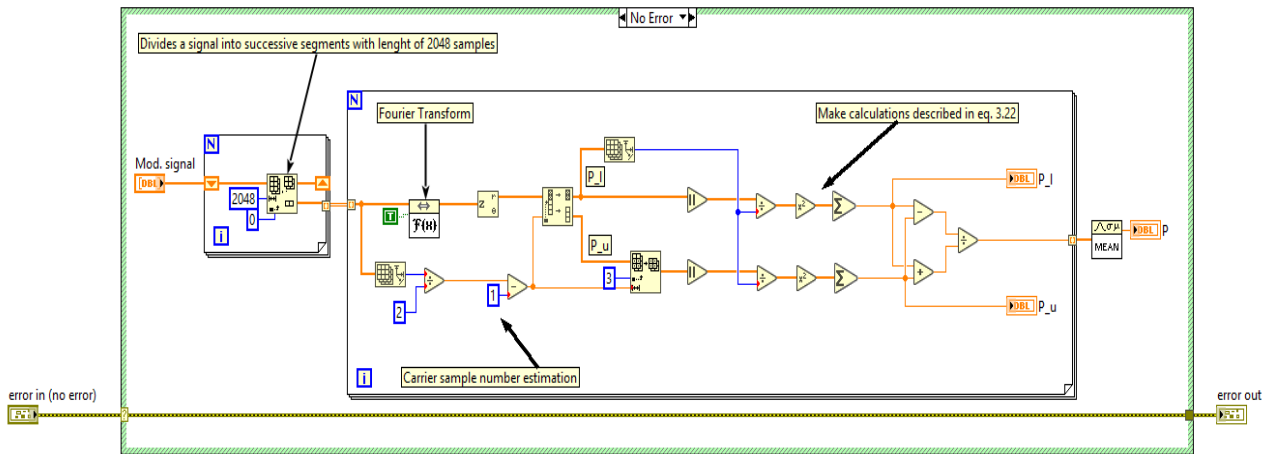
$$X(i) = \sum_{i=0}^{N-1} x_i e^{-j2\pi f_i / N}, \quad (3.25)$$

որտեղ $i=0, 1, \dots, N-1$:

Հավասարում (3.24)-ում f_{cn} -ը որոշվում է հետևյալ կերպ՝

$$f_{cn} = \frac{f_c N_s}{f_s} - 1 : \quad (3.26)$$

Այսպիսով, գտնելով ազդանշանի կրողին համապատասխանող կետը, P_i -ի և P_u -ի հաշվարկման համար դիտարկվում են նույն f_{cn} քանակությամբ կետեր՝ երկու դեպքում էլ կրողին համապատասխանող կետի հզորության արժեքը չի ներառվում հաշվարկների մեջ: Ինչպես երևում է հավասարում (3.22)-ից աղմուկի բացակայության դեպքում DSB և FM մոդուլացումների համար $P = 0$, քանի որ սպեկտրի համաչափության հետևանքով այդ երկու մոդուլացված ազդանշանների ցածր կողային շերտի և բարձր կողային շերտի հզորությունները հավասար են, իսկ SSB-ի համար $|P| = 1$: Հետևաբար նման տարբերությունը հնարավորություն է ընձեռում տվյալ բնութագրող հատկանիշի միջոցով տարբերակել SSB մոդուլացված ազդանշանները DSB և FM մոդուլացման տեսակներից: Այս բնութագրող հատկանիշի հաշվարկի իրականացումը LabVIEW ծրագրավորման միջավայրում պատկերված է նկ. 3.8-ում:



Նկ. 3.8 P-ի հաշվարկը LabVIEW միջավայրում

Նկ. 3.8-ում պատկերված կողում նույնպես սկզբում առանձնացվում են ազանշանի հաջորդական սեգմենտները: Յուրաքանչյուր սեգմենտի համար իրականացվում է Ֆուրյե ձևափոխություն և առանձնացվում են մագնիտուդների արժեքները: Ազդանշանի կրողի հաճախականության իմացության դեպքում հնարավոր է այս բնութագրող հատկանիշի հաշվարկն իրականացնել ցածրհաճախականային ազդանշանի սպեկտրի տվյալների հիման վրա: Հետևաբար, ծրագրում կենտրոնական հաճախականության հաշվարկն իրականացվել է ոչ թե (3.26) հավասարման միջոցով, այլ մշակվել է հաշվարկի այլ միջոց՝ որպես կենտրոնական հաճախականություն վերցնելով սեգմենտի կետերի քանակի կեսին համապատասխանող արժեքը: Այնուհետև առանձնացվում են ցածր և բարձր կողային շերտերը և հավասարում (3.22)-ի համապատասխան իրականացվում են հաշվարկները: Վերջում բոլոր սեգմենտների համար ստացված արժեքները միջինացվում են:

3.3 Թվային մոդուլացման տեսակները

Ինչպես արդեն նշվել էր տվյալ աշխատանքում դիտարկվում են l' անալոգային, և՛ թվային մոդուլացման տեսակները: Թվային հեռահաղորդակցման անլար կապի համակարգերում մոդուլացվող ազդանշանը կարելի է ներկայացնել սիմվոլների կամ իմպուլսների ժամանակային շարքի միջոցով, որտեղ յուրաքանչյուր սիմվոլ ունի M սահմանափակ քանակի արժեքներ: Յուրաքանչյուր սիմվոլ ներկայացնում է N քանակի բիթեր, որտեղ $N = \log_2 M$ բիթ/սիմվոլ [68]:

Քանի որ թվային ինֆորմացիան ներկայացվում է «1»-երի և «0»-ների միջոցով, ապա միայն այդ երկու վիճակների առկայությունը հեշտացնում է ազդանշանի վերականգնումը և սահմանափակում է աղմուկների ազդեցությունը: Միևնույն ժամանակ անալոգային ազդանշանները կարող են անսահման քանակի ձևեր ունենալ: Անալոգային կապի համակարգերում նույնիսկ չնչին կողմնակի ազդեցությունը կարող է զգալի աղավաղել ազդանշանը, որից հետո դա չի կարելի վերականգնել ազդանշանի ուժեղացման միջոցով, քանի որ աղմուկն անմիջականորեն կապված է լինում անալոգային ազդանշանի հետ:

Թվային համակարգերում սխալի առաջացման համեմատաբար շատ ցածր հավանականությունը հնարավոր է դարձնում ազդանշանի մեծ ճշտությամբ փոխանցումը: Հեռահաղորդակցման թվային համակարգերը ավելի կայուն են կողմնակի աղմուկների նկատմամբ և թվային ազդանշաններն ավելի քիչ են ենթարկվում աղավաղումների: Գոյություն ունեն նաև թվային կապի համակարգերի այլ կարևոր առավելություններ ինչպիսիք են՝ դրանց հուսալիությունը, դրանցում ներառված ինտերֆերենցիայից պաշտպանման գործառույթները, կապուղու կողավորումը, ռադիոհաճախականային սպեկտրի արդյունավետ օգտագործումը, նախագծման ցածր արժեքը, թվային համակարգերի ծրագրային ապահովումը, ինչի նպատակով կիրառվում են միկրոպրոցեսորներ, թվային կոմուտատորներ և մեծ ինտեգրալային սխեմաներ:

Թվային հեռահաղորդակցման համակարգերն ունեն նաև իրենց թերությունները: Թվային համակարգերը ավելի մանրակրկիտ մշակում են պահանջում և կապի որակի վատացումը ունի շեմային բնութագիր: Այն դեպքում, երբ SNR-ի արժեքը նվազում է ինչ-որ չափից, ապա կապի որակը կարող է թռիչքաձև փոփոխվել բարձրից դեպի շատ ցածր, մինչդեռ անալոգային համակարգերում նման անցումները ավելի սահուն են տեղի ունենում [68]:

Վերջին ժամանակներում թվային անլար կապի համակարգերի և տեխնոլոգիաների սրընթաց զարգացման և նոր թվային մոդուլացման տեսակների մշակման հետևանքով գրեթե ամբողջ աշխարհում անալոգային կապի համակարգերը փոխարինվել են թվային հեռահաղորդակցման համակարգերով: Այդ իսկ պատճառով այս աշխատանքի հիմքում

ընկած խնդրի շրջանակներում թվային մոդուլացման տեսակները և դրանց ավտոմատացված նույնականացումն ավելի արդիական են և առավել մեծ հետաքրքրություն են ներկայացնում: Տվյալ աշխատանքի շրջանակներում դիտարկվել են BPSK, QPSK, 8PSK, 2FSK, 4FSK, 2ASK, 4ASK, 16 QAM, 32QAM և 64QAM թվային մանիպուլացման/մոդուլացման տեսակները և մոդուլացման այս տեսակների ավտոմատացված նույնականացման համար նախատեսված Ազգոուզի և Նանդիի [8] մշակված γ_{max} , σ_{ap} , σ_{dp} , σ_{aa} , σ_{af} բնութագրող հատկանիշները և մշակվել են E_m , φ_{ph} , A_{ph} թվային մոդուլացված ազդանշանների հիմնական բնութագրող հատկանիշները: Թվային մոդուլացման տեսակներին համապատասխանող հիմնական բնութագրող հատկանիշների գործառույթի բնութագրման նպատակով ստորև հակիրճ ներկայացված են սույն աշխատանքում դիտարկված թվային մոդուլացման տեսակները:

Թվային մոդուլացման տեսակներից M-PSK (Phase Shift Keying) փուլային մոդուլացման տեսակները ներկայում ավելի լայն կիրառություն ունեն, քան ամպլիտուդային և հաճախականային մոդուլացումները: Թվային փուլային մոդուլացման տեսակները կիրառվում են կոմերցիոն և ռազմական նշանականության հավելվածներում ինչպիսիք են՝ Wireless LAN-ը, Bluetooth-ը, RFID-ն և այլն [69-71]:

Այս տեսակի մոդուլացման դեպքում ազդանշանի ամպլիտուդան և հաճախականությունը մնում են անփոփոխ: PSK թվային մոդուլացման սխեմա կիրառում է սահմանափակ քանակի փուլերի արժեքներ, որոնցից յուրաքանչյուրին նշանակված է թվային բիթերի առանձնահատուկ կոմբինացիա, որոնք կոչվում են սիմվոլներ: Սիմվոլների և դրանց ներկայացրած բիթերի քանակի փոխկապակցվածությունը որոշվում է հետևյալ հավասարմամբ [72]՝

$$\frac{\text{բիթ}}{\text{սիմվոլ}} = \log_2 M , \quad (3.27)$$

որտեղ M-ը մոդուլացման կարգն է: Հետևաբար՝ M=2 դեպքում յուրաքանչյուր սիմվոլի միջոցով հնարավոր է ներկայացնել մեկ բիթ:

PSK փուլային մոդուլացում

M-PSK ազդանշանները բնութագրվում են հետևյալ կերպ [68]՝

$$s_i(t) = \sqrt{\frac{2E}{T}} \cos(\omega_0 t + \phi_i(t)), \quad (3.28)$$

որտեղ $i=1, 2, \dots, M$, E -ն սիմվոլի էներգիան է և T -ն սիմվոլի տևողությունը, ω_0 -ն ազդանշանի հաճախականությունը և $\phi_i(t)$ -ն ազդանշանի փուլը: Հավասարում (3.28)-ում $\sqrt{\frac{2E}{T}}$ -ն ամպլիտուդային անդամն է և դուրս է բերվում հետևյալ կերպ: Ներկայացնենք ազդանշանը հետևյալ հայտնի հավասարմամբ՝

$$s(t) = A \cos \omega t, \quad (3.29)$$

որտեղ A -ն ազդանշանի ամպլիտուդան է, իսկ ω -ն ազդանշանի հաճախականությունը: Քանի որ ամպլիտուդայի առավելագույն արժեքը $\sqrt{2}$ անգամ մեծ է դրա միջին քառակուսային արժեքից, ապա հավասարում (3.29)-ը կարելի է ներկայացնել հետևյալ կերպ՝

$$s(t) = \sqrt{2A_{rms}^2} \cos \omega t : \quad (3.30)$$

Պատկերացնելով, որ ազդանշանը բնութագրվում է հոսանքի կամ լարման տատանումների միջոցով կարելի է ենթադրել, որ A_{rms}^2 -ը ներկայացնում է միջին հզորությունը՝ P : Հետևաբար հավասարում (3.30)-ը կարելի է ներկայացնել հետևյալ տեսքով՝

$$s(t) = \sqrt{2P} \cos \omega t : \quad (3.31)$$


Այստեղից P -ի փոխարեն տեղադրելով $\frac{E}{T}$ Ջոուլ/վարկյան կստանանք հավասարում (3.28)-ում ներկայացված ամպլիտուդային անդամը:

Կախված M-PSK մոդուլացման կարգից $\phi_i(t)$ -ն կարող է ունենալ M քանակի դիսկրետ արժեքներ: Ազդանշանի $\phi_i(t)$ փուլը բնութագրվում է հետևյալ հավասարմամբ [60]՝

$$\phi_i(t) = \frac{2\pi i}{M}, \quad (3.32)$$

որտեղ $i=1, 2, \dots, M$:

Այն դեպքում, երբ $M = 2$ ազդանշանի փուլը ունի երկու արժեք «0» և « π »: Այս տեսակ փուլային մոդուլացված ազդանշանները կոչվում են BPSK: Նկ. 3.9-ում պատկերված է թե ինչպես է BPSK մոդուլացումների դեպքում հնարավոր տվյալները փոխանցել երկու սիմվոլների միջոցով, որոնք միմյանցից շեղված են π -ով, և փուլի յուրաքանչյուր արժեքին համապատասխանում են «1» կամ «0» արժեքները:



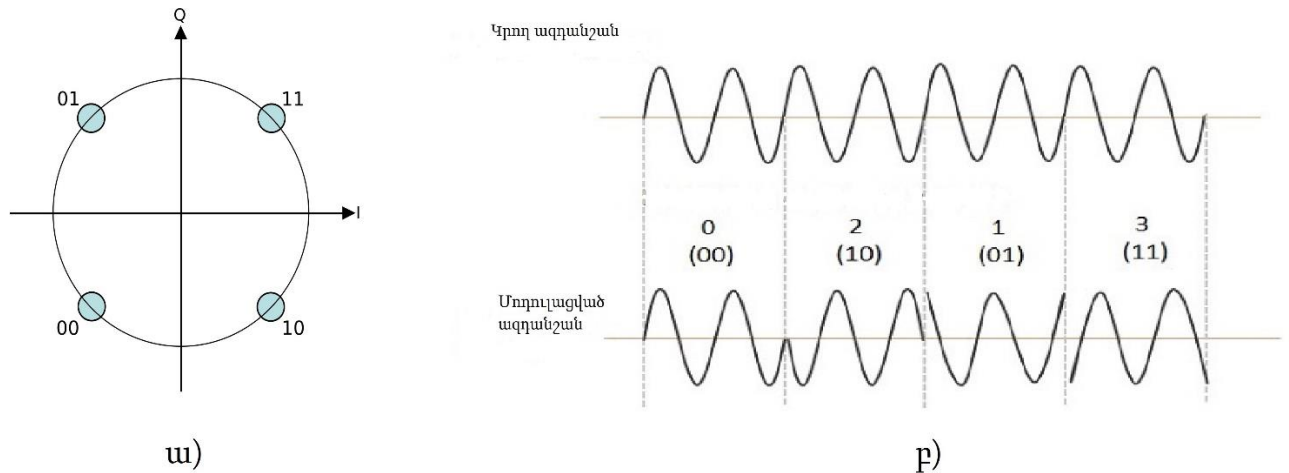
Նկ. 3.9 ա) BPSK ազդանշանի համաստեղության դիագրամը, բ) BPSK մոդուլացված ազդանշան

BPSK մոդուլացման տեսակը արդյունավետ է անվտանգության և ազդանշանի ցածր BER-ի տեսանկյունից [73], բայց այս մոդուլացման տեսակի դեպքում տվյալների փոխանցման քանակը և հետևաբար արագությունը համեմատ ավելի բարձր կարգի PSK մոդուլացումների սահմանափակ են:

Հեռահաղորդակցական ցանցերում ավելի հաճախ կիրառվող փուլային մոդուլացման տեսակ է QPSK-ն: Նշված տեսակը կիրառվում է օրինակ՝ CDMA բջջային կապի համակարգերում, թվային վիդեո հեռարձակման DVB-S համակարգերում և այլն [74-75]:


Այս մոդուլացման տեսակը տարբերվում է BPSK տեսակից նրանով, որ այստեղ 2 փուլային արժեքի փոխարեն ազդանշանը ունենում է միմյանցից հավասարաչափ շեղված 4 փուլային արժեք: Quadrature նշանակում է, որ ազդանշանի I և Q բաղադրիչները շեղված եք միմյանցից 90 աստիճանով: Հավասարում (3.32)-ի մեջ M -ին տալով 4 արժեք կտեսնենք, որ QPSK ազդանշանն ունի չորս փուլային արժեք: Գոյություն ունի երկու I արժեք և երկու Q արժեք, հետևաբար այս մոդուլացման տեսակի դեպքում

հավասարում (3.27)-ի մեջ M -ի փոխարեն տեղադրելով 4 կատանանք, որ յուրաքանչյուր սիմվոլի միջոցով հնարավոր է ներկայացնել 2 բիթ (նկ. 3.10): Վերոնշյալից հետևում է, որ QPSK ազդանշանի միջոցով միևնույն թողունակության շերտի դեպքում երկու անգամ ավել տվյալներ է հնարավոր փոխանցել քան BPSK ազդանշանի դեպքում:



Նկ. 3.10 ա) QPSK ազդանշանի համաստեղության դիագրամը, բ) QPSK մոդուլացված ազդանշան

Փուլային 8PSK մոդուլացման դեպքում ազդանշանը ցանկացած ժամանակի պահի կարող է անցում կատարել ութ վիճակների միջև: Այլ կերպ ասած ազդանշանի փուլը կարող է ստանալ ութ տարբեր արժեքներ յուրաքանչյուր սիմվոլի ժամանակային պահի: Տեղադրելով հավասարում (3.27)-ի մեջ M -ի փոխարեն 8 կատանանք, որ տվյալ մոդուլացման տեսակի դեպքում յուրաքանչյուր սիմվոլ ներկայացնում է երեք բիթ: Համեմատելով BPSK ազդանշանի հետ կտեսնենք, որ միևնույն սիմվոլների հաճախության դեպքում ավելի բարդ մոդուլացման սխեման՝ 8PSK-ն, ապահովում է երեք անգամ մեծ բիթերի հաճախություն քան BPSK ազդանշանը: Հաշվի առնելով վերոնշյալը՝ 8PSK մոդուլացման տեսակը ավելի արդյունավետ է սպեկտրի օգտագործման տեսանկյունից քան BPSK և QPSK ազդանշանները, բայց ավելի հակված է բիթային սխալներին: Հավասարում (3.32)-ի մեջ տեղադրելով M -ի փոխարեն 8 կտեսնենք, թե ինչ ութ արժեքներ կարող է ստանալ տվյալ մոդուլացման տեսակի փուլը: Նկ. 3.11-ում պատկերած է 8PSK ազդանշանի համաստեղության դիագրամը:



Նկ. 3.11 8PSK ազդանշանի համաստեղության դիագրամը

Այսպիսով՝ պարզ է դառնում, որ այս երեք մոդուլացման տեսակները տարբերվում են միմյանցից իրենց փուլերի քանակով, ինչը երևում է դրանց համապատասխան համաստեղության դիագրամներում ներկայացված սիմվոլների բաշխվածությունից:

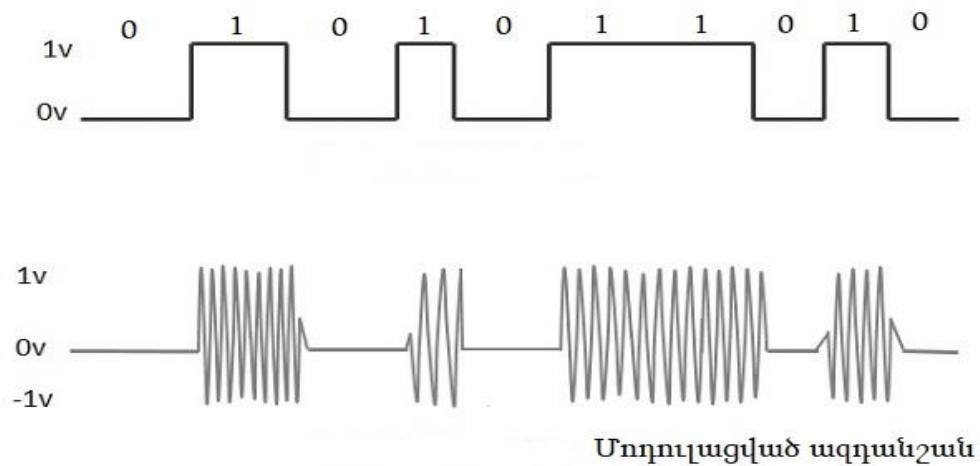
ASK ամպլիտուդային մոդուլացում

Ամպլիտուդային ASK մոդուլացման դեպքում ազդանշանի հաճախականությունն ու փուլը մնում են անփոփոխ, իսկ թվային սոլյալները փոխանցվում են ազդանշանի ամպլիտուդայի փոփոխությունների միջոցով: Թվային ամպլիտուդային մոդուլացման ամենապարզ տեսակը 2ASK-ն է, որն ունի երկու ամպլիտուդային մակարդակ և յուրաքանչյուր սիմվոլ ներկայացնում է մեկ բիթ՝ «1»-ը կրող ազդանշանի առկայության դեպքում և «0»-ն դրա բացակայության դեպքում (նկ. 3.12):

Ամպլիտուդային մոդուլացված ASK ազդանշանները բնութագրվում են հետևյալ հավասարմամբ [68]՝

$$s_i(t) = \sqrt{\frac{2E_i(t)}{T}} \cos(\omega_0 t + \phi), \quad (3.33)$$

որտեղ $i=1, 2, \dots, M$, $\sqrt{\frac{2E_i(t)}{T}}$ – ամպլիտուդային անդամն է, որը կարող է ընդունել M դիսկրետ արժեքներ, իսկ ϕ -ն ազդանշանի փուլի կամայական հաստատուն արժեքը:




Նկ. 3.12 ASK մոդուլացված ազդանշան

Նկ. 3.12-ում մոդուլացված ազդանշանը համապատասխանում է ռադիո հաղորդման, որում կիրառվել են երկու ազդանշաններ, որոնց ամպլիտուդաները հավասար են «0»-ի և $\sqrt{\frac{2E}{T}}$ -ի: Ամպլիտուդային 4ASK մոդուլացումը այն տեսակն է, երբ կրող ազդանշանի ամպլիտուդայի 4 տարբեր արժեքներին համապատասխանում են տարբեր երկու բիթից բաղկացած սիմվոլներ:

Քանի որ հեռահաղորդակցական ազդանշանի վրա եթերում տարածվելու ընթացքում ազդեցություն գործած աղմուկները հիմնականում մեծ հետևանք են թողնում վերջինիս ամպլիտուդայի վրա, ապա հետևաբար թվային ամպլիտուդային մոդուլացումները, ինչպես և անալոգային ամպլիտուդային մոդուլացումները, ամենից ենթական են աղմուկների ազդեցությանը:

FSK հաճախականային մոդուլացում

Թվային հաճախականային FSK մոդուլացման տեսակները կիրառվում են բազմաթիվ հավելվածներում ինչպիսիք են՝ Bluetooth-ը [70], FM ռադիոն, հեռաչափությունը [76-77] և այլն: Այս մոդուլացման դեպքում կրող ազդանշանի հաճախականությունը փոփոխվում է համապատասխան բիթային ազդանշանի, որտեղ ցածր հաճախականությունը համապատասխանում է երկուական «0»-ի, իսկ բարձր հաճախականությունը «1»-ի (նկ. 3.13): Հաճախականային մոդուլացման դեպքում ազդանշանի փուլը և ամպլիտուդան մնում են անփոփոխ:



Նկ. 3.13 FSK մոդուլացում

Նկ. 3.13-ում պատկերված f_1 և f_2 հաճախականությունները համապատասխանում են բիթային ազդանշանի ցածր և բարձր մակարդակներին: Այս տեսակը կոչվում է 2ASK մոդուլացում, որտեղ ազդանշանը ունի երկու սիմվոլ, որոնցից յուրաքանչյուրը ներկայացնում է մեկ բիթ:

Թվային հաճախականային մոդուլացումը բնութագրվում է հետևյալ հավասարմամբ [68]՝

$$s_i(t) = \sqrt{\frac{2E(t)}{T}} \cos(\omega_i t + \phi), \quad (3.34)$$

որտեղ $i=1, 2, \dots, M$, ω_i – ազդանշանի հաճախականությունն է, որը կարող է ունենալ M դիսկրետ արժեքներ, իսկ ϕ -ն ազդանշանի փուլի կամայական հաստատուն արժեքն է: 4FSK ազդանշանի դեպքում կստանանք 4 հաճախականություններից կազմված ազդանշան, որոնցից յուրաքանչյուրը ներկայացնում է մեկ սիմվոլ՝ կազմված երկու բիթից:

Հաճախականային մոդուլացման առավելություններից է համարվում աղուկների հանդեպ կայուն լինելը, քանի որ դեմոդուլյատորը իր գործառույթի ընթացքում դետեկտում է տրված ազդանշանի հաճախականությունների փոփոխությունները և հետևաբար ամպլիտուդայի տատանումները կարելի է անտեսել: Հակառակ կողմից, քանի որ հաճախականային մոդուլացված ազդանշանը պարունակում է տարբեր

հաճախանային սպեկտրալ բաղադրիչներ, ապա հետևաբար M-FSK մոդուլացումը արդյունավետ չէ սպեկտրի զբաղեցման տեսանկյունից:

M-QAM քառակուսային-ամպլիտուդային մոդուլացում

Ներկայումս ամենից տարածված և զարգացող մոդուլացման սխեման դա M-QAM թվային մոդուլացման տեսակն է: Այն կիրառվում է OFDM համակարգերում ենթակրողների մոդուլացման համար, միկրոալիքային ռադիոներում, WiMAX տեխնոլոգիաներում, 802.11n անլար կապի ստանդարտում և այլն [78-82]:


M-QAM մոդուլացման դեպքում բիթային տեղեկատվությունը մոդուլացվում է կրող ազդանշանի ամպլիտուդայի և փուլի փոփոխությունների միջոցով: Ամպլիտուդային և փուլի յուրաքանչյուր համադրություն ձևավորում է սիմվոլ, որը կախված QAM մոդուլացման կարգից ներկայացնում է համապատասխան քանակի բիթեր: Կրող ազդանշանի ամպլիտուդայի և փուլի փոփոխման համար գեներացվում են երկու օրթոգոնալ սինուսոիդալ ազդանշաններ: Այդ ազդանշանները ինչպես արդեն նշվել է կոչվում են ազդանշանի I և Q բաղադրիչներ և բնութագրվում են հավասարում (2.2)-ի միջոցով: Նշված հավասարումից հետևում է, որ ազդանշանի փուլը կարելի է փոփոխել այս երկու բաղադրիչների ամպլիտուդաների փոփոխության միջոցով:

M-QAM մոդուլացման տեսակները բնութագրվում են հետևյալ հավասարմամբ [60]՝

$$s_i(t) = \sqrt{\frac{2E_i(t)}{T}} \cos(\omega t + \phi_i(t)), \quad (3.35)$$

որտեղ $i=1, 2, \dots, M$:

Քառակուսային-ամպլիտուդային մոդուլացման տեսակներից 16QAM-ի դեպքում, երբ հավասարում (3.35)-ում i -ն ունի 16 արժեք, առկա են չորս I արժեք և չորս Q արժեք, որոնց միջոցով ձևավորվում են տասնվեց սիմվոլներ, որոնք ներկայացնում են չորս բիթից բաղկացած տվյալներ (նկ. 3.14):



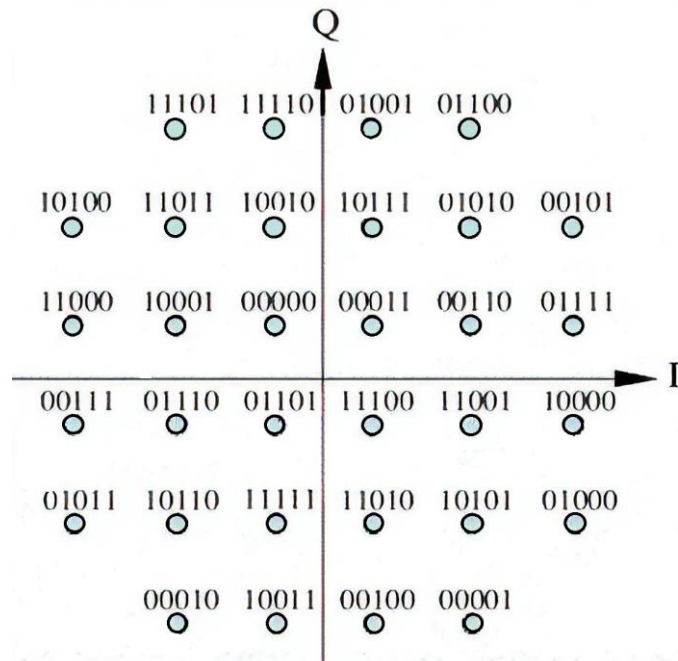
Նկ. 3.14 16QAM ազդանշանի համաստեղության դիագրամը

Թվային 16QAM-ի միջոցով հնարավոր է ավելի շատ տեղեկատվություն փոխանցել քան BPSK, QPSK, 8PSK ազդանշանների միջոցով: Նկ. 3.14-ից երևում է, որ I և Q հարթության ամեն քառորդ մասում պատկերված չորս սիմվոլների համար ազդանշանի ամպլիտուդան ունի երեք արժեք, քանի որ երկու սիմվոլների համար վերջինիս արժեքները հավասար են:

32QAM քառակուսային-ամպլիտուդային մոդուլացում

Ներկայիս հեռահաղորդակցական կապի համակարգերում ոչ պակաս կարևորություն և լայն կիրառություն ունի նաև 32QAM քառակուսային-ամպլիտուդային մոդուլացման տեսակը: 32QAM մոդուլացման տեսակի դեպքում կան I-ի և Q-ի վեցական արժեքներ, որոնք ձևավորում են երեսունվեց հնարավոր փուլի և ամպլիտուդայի համադրություն: Քանի որ գործ ունենք թվային համակարգերի հետ, որտեղ կիրառվում են երկուական թվային տվյալներ, ապա երեսունվեցին ամենամոտ թիվը, որը հանդիսանում է 2-ի աստիճան դա 32-ն է: Հետևաբար, չորս անկյունային սիմվոլները, որոնց փոխանցման համար ամենից շատ հզորությունն է պահանջվում, չեն օգտագործվում (նկ. 3.15): Այս մոդուլացման տեսակի յուրաքանչյուր սիմվոլ ներկայացնում է 5 բիթից բաղկացած տվյալներ և սպեկտրալ տեսանկյունից ավելի

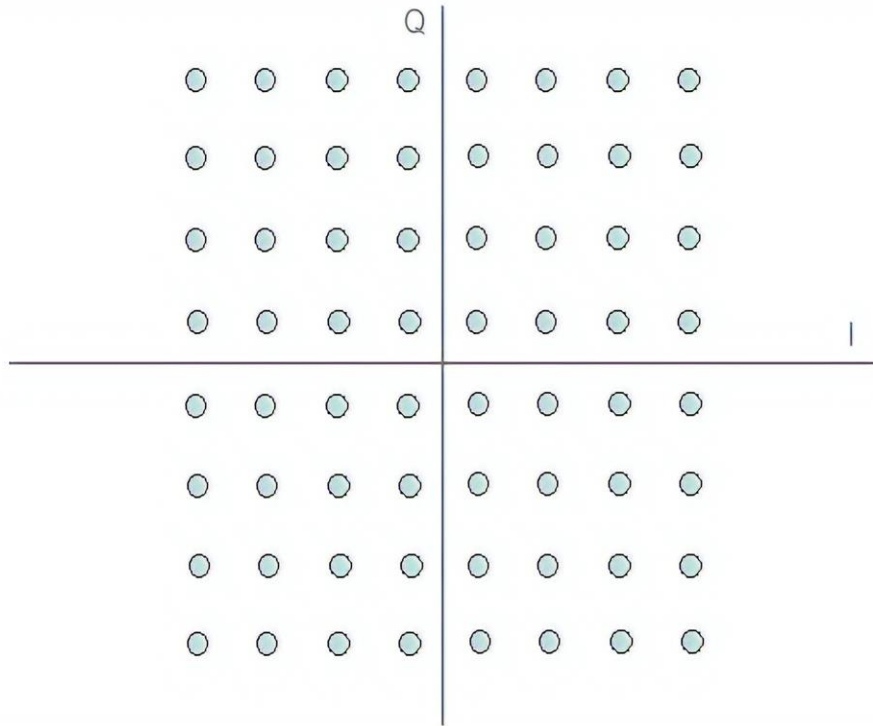
արդյունավետ է քան 16QAM-ը: Այստեղ ազդանշանի ամպլիտուդան քառորդ հարթությունում 8 սիմվոլների համար ունի 5 արժեք:



Նկ. 3.15 32QAM ազդանշանի համաստեղության դիագրամը

64QAM քառակուսային-ամպլիտուդային մոդուլացում

Նկ. 3.16-ում պատկերված է 64QAM մոդուլացման համաստեղության դիագրամը: Դա լայն կիրառություն ունի OFDM տեխնոլոգիաներում՝ ենթակրողների մոդուլացման համար, WiMAX, WLAN, WiBro, UWB [82-84] տեխնոլոգիաներում և այլն: Այս մոդուլացման տեսակի համաստեղության դիագրամի վրա կա I և Q բաղադրիչների 8 ական արժեք, որոնց միջոցով ստացվում են 64 սիմվոլներ: Հավասարում (3.32)-ում M-ին տալով 64 արժեքը կտեսնենք, որ յուրաքանչյուր սիմվոլ կարող է ներկայացնել 6 բիթ:



Նկ. 3.16 64 QAM ազդանշանի համաստեղության դիագրամը

Դիտարկելով նկ. 3.16-ում պատկերված 64QAM մոդուլացման համաստեղության դիագրամը, կարող ենք տեսնել, որ ազդանշանի ամպլիտուդան ունի տասը արժեք:

Այսպիսով՝ ներկայացված թվային մոդուլացման տեսակներից M-PSK մոդուլացված ազդանշանները տարբերվում են միմյանցից դրանց փուլի փոփոխության քանակով, M-ASK ազդանշանները տարբերվում են միմյանցից ակնթարթային ամպլիտուդայի արժեքների քանակով, M-FSK ազդանշանները՝ ըստ կարգերի, տարբերվում են հաճախականության փոփոխական քանակով, իսկ M-QAM մոդուլացված ազդանշանները տարբերվում միմյանցից և փուլերի փոփոխման և ամպլիտուդայի փոփոխման քանակներով: Այս եզրակացությունը հիմք է հանդիսանում այս մոդուլացման տեսակների համար նախատեսված հիմնական բնութագրող հատկանիշների կիրառման և մշակման համար:

3.4 Թվային մոդուլացված ազդանշանների հիմնական բնութագրող հատկանիշները

3.4.1 Հզորության սպեկտրալ խտություն՝ γ_{max}

Տվյալ բնութագրող հատկանիշը մանրամասն ներկայացված է անալոգային մոդուլացման տեսակների նույնականացման համար նախատեսված հիմնական

բնութագրերի բաժնում, բայց այն նաև կիրառվում է թվային մոդուլացումների համար: Թվային մոդուլացման տեսակների նույնականացման դեպքում տվյալ հատկանիշը կիրառվում է տարբերակելու համար այն մոդուլացված ազդանշանները, որոնք պարունակում են ամպլիտուդային տեղեկատվություն և նրանց որոնք չեն պարունակում: Թվային 2FSK և 4FSK ազդանշանների ակնթարթային ամպլիտուդայի արժեքը հաստատուն մեծություն է և հետևաբար դրանց կենտրոնացված-նորմավորված ակնթարթային ամպլիտուդայի արժեքը հավասար է զրոյի: Սա նշանակում է, որ մոդուլացման այս տեսակների հզորության սպեկտրալ խտությունն իդեալական պայմաններում նույնպես հավասար կլինի զրոյի, ինչը նշանակում է, որ դրանք չեն պարունակում ամպլիտուդային տեղեկատվություն: Մյուս կողմից M-PSK, M-ASK, M-QAM ազդանշանների ակնթարթային ամպլիտուդան ունենում է ոչ հաստատուն արժեքներ և հետևաբար դրանց համար γ_{max} -ի արժեքը կլինի տարբեր զրոյից:

Այս հիմնական բնութագրող հատկանիշի գործառույթն իրականացնող ծրագրի հատվածը պատկերված է նկ. 3.5-ում:

3.4.2 Ակնթարթային փուլի կենտրոնացված ոչ գծային կոմպոնենտի բացարձակ արժեքի ստանդարտ դեվիացիա՝ σ_{ϕ}

Ինչպես և γ_{max} -ը այս բնութագիրը նկարագրված է անալոգային մոդուլացումների բաժնում և կիրառվում է նաև թվային մոդուլացումների նույնականացման համար: Այն կիրառվում է բացարձակ փուլային տեղեկատվություն պարունակող և չպարունակող թվային մոդուլացման տեսակների նույնականացման համար: Ինչպես DSB ամպլիտուդային ազդանշանը, այնպես էլ BPSK ազդանշանի ակնթարթային փուլը ունի երկու արժեք՝ «0» և « π »: Գծային բաղադրիչի վերացնելուց և կենտրոնացնելուց հետո փուլը ստանում է երկու արժեք՝ $-\frac{\pi}{2}$ և $\frac{\pi}{2}$, այսինքն դրա բացարձակ արժեքը դառնում է կոնստանտ և հավասար $|\frac{\pi}{2}|$: Հետևում է, որ BPSK ազդանշանը չի պարունակում բացարձակ փուլային տեղեկատվություն: Հայտնի է նաև, որ 2ASK և 4ASK ազդանշանները նույնպես չեն պարունակում վերոնշյալ տեղեկատվությունը: Այսպիսով, կարելի է եզրակացնել, որ տվյալ հիմնական բնութագրող հատկանիշը կիրառվում է BPSK, 2ASK և 4ASK ազդանշանները և բացարձակ փուլային տեղեկատվություն

պարունակող ազդանշանների տարբերակման համար: σ_{Φ} -ի հաշվարկն իրականացնող ծրագրի հատվածը պատկերված է նկ. 3.17-ում:

3.4.3 Ակնթարթային փուլի կենտրոնացված ոչ գծային բաղադրիչի ստանդարտ դեվիացիա՝

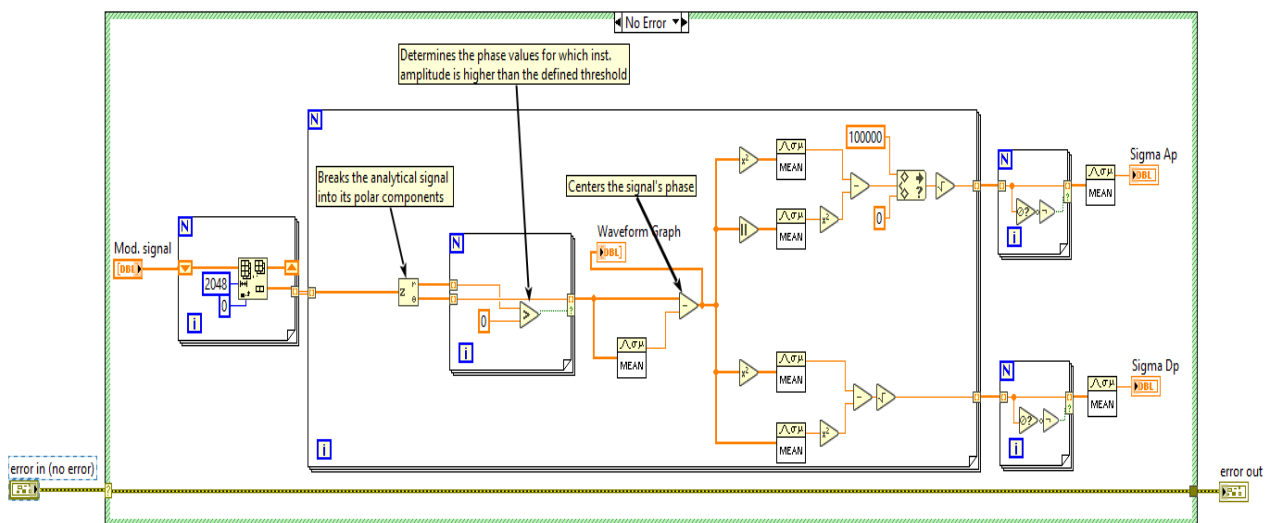
σ_{Φ}

Տվյալ հիմնական բնութագրող հատկանիշը բնութագրվում է հետևյալ հավասարմամբ [8]՝

$$\sigma_{\Phi} = \sqrt{\frac{1}{C} \left(\sum_{A(i)_n > A_t} \Phi(i)_{NL}^2 \right) - \left(\frac{1}{C} \sum_{A(i)_n > A_t} \Phi(i)_{NL} \right)^2}, \quad (3.36)$$

որտեղ $\Phi(i)_{NL}$ -ը ակնթարթային փուլի կենտրոնացված ոչ գծային բաղադրիչն է, C -ն դա այն կետերի քանակն է որոնց համար $A(i)_n > A_t$, որտեղ $A(i)_n$ -ը նորմավորված ակնթարթային ամպլիտուդան է, որը բնութագրվում է (3.19) հավասարմամբ:

Ի տարբերություն σ_{Φ} -ի, տվյալ հատկանիշը կիրառվում է տարբերակելու համար այն ազդանշանները, որոնք պարունակում են «ուղղակի» փուլային տեղեկատվություն և նրանց, որոնք չեն պարունակում: Թվային 2ASK և 4ASK ազդանշանների դեպքում փուլի փոփոխություն չի գրանցվում, այդ իսկ պատճառով դրանք չեն պարունակում փուլային տեղեկատվություն, ինչից հետևում է, որ տվյալ հատկանիշը կիրառվում է 2ASK և 4ASK և մնացած տեսակների տարբերակման համար: Նկ. 25-ում պատկերված է σ_{Φ} և σ_{Φ} հատկանիշների ծրագրային հաշվարկման հատվածը:



Նկ. 3.17 σ_{Φ} -ի և σ_{Φ} -ի հաշվարկը

Նկ. 3.17-ում պատկերված ծրագրային կոդի գործառույթի նկարագրությունը լիովին նույնն է ինչ $\sigma_{\text{բփ}}$ -ի հաշվարկի նկարագրությունը, բացառությամբ, որ այստեղ ավելանում է $\sigma_{\text{փ}}$ -ի հաշվարկը իրականացրած համաձայն (3.36) հավասարման:

3.4.4 Նորմավորված-կենտրոնացված ակնթարթային ամպլիտուդայի բացարձակ արժեքի ստանդարտ դեվիացիա՝ $\sigma_{\text{բա}}$

Ինչպես նկարագրված էր ASK մոդուլացման հատվածում 2ASK ազդանշանի ակնթարթային ամպլիտուդան ունի հավասար մեծությամբ և հակառակ նշաններով երկու արժեք: Այստեղից հետևում է, որ ակնթարթային ամպլիտուդայի բացարձակ արժեքը հաստատուն մեծություն է և այս ազդանշանը չի պարունակում բացարձակ ամպլիտուդային տեղեկատվություն:

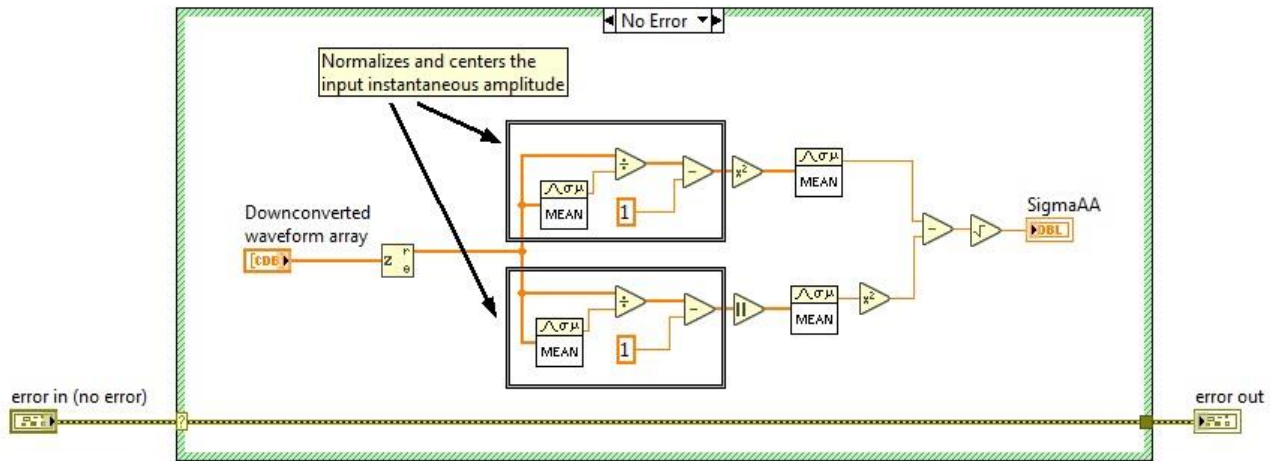
Մինևս ժամանակ՝ 4ASK ազդանշանի ակնթարթային ամպլիտուդան ունի չորս տարբեր արժեքներ, ինչը նշանակում է, որ այս ազդանշանը պարունակում է բացարձակ ամպլիտուդային տեղեկատվություն: Հետևաբար $\sigma_{\text{բա}}$ -ն կիրառվում է 2ASK և 4ASK ազդանշանները միմյանցից տարբերակելու համար:

Տվյալ բնութագրող հատկանիշը հաշվարկվում է հետևյալ հավասարմամբ [8]՝

$$\sigma_{aa} = \sqrt{\frac{1}{N_s} \left(\sum_{i=1}^{N_s} A(i)_{cn}^2 \right) - \left(\frac{1}{N_s} \sum_{i=1}^{N_s} |A(i)_{cn}| \right)^2}, \quad (3.37)$$

որտեղ N_s -ը դիտարկվող ազդանշանի սեգմենտի կետերի քանակն է, իսկ $A(i)_{cn}$ -ը նորմավորված-կենտրոնացված ամպլիտուդան, որը հաշվարկվում է հավասարում (3.15)-ի միջոցով:

Նկ. 3.18-ում պատկերված է այս հիմնական բնութագրի ծրագրային հաշվարկը:



Նկ. 3.18 σ_{pm} -ի հաշվարկը

Այստեղ մոդուլացված ազդանշանի զանգվածից առանձնացվում է ակնթարթային ամպլիտուդաների արժեքների զանգվածը, ինչից հետո իրականացվում է դրանց նորմավորումը և կենտրոնացումը և հավասարում (3.37)-ի համաձայն կատարված հաշվարկները:

3.4.5 Նորմավորված-կենտրոնացված ակնթարթային հաճախականության բացարձակ արժեքի ստանդարտ դեվիացիա՝ σ_{ph}

2FSK և 4FSK մոդուլացման տեսակները միմյանցից տարբերակելու համար օգտագործվում է σ_{ph} հատկանիշը, որը բնութագրվում է հետևյալ հավասարմամբ [8]՝

$$\sigma_{af} = \sqrt{\frac{1}{C} \left(\sum_{A(i)_n > A_t} f(i)_{NC}^2 \right) - \left(\frac{1}{C} \sum_{A(i)_n > A_t} |f(i)_{NC}| \right)^2}, \quad (3.38)$$

որտեղ $f(i)_{NC}$ -ը ազդանշանի նորմավորված-կենտրոնացված հաճախականությունն է, C -ն այն կետերի քանակն է որոնց համար $A(i)_n > A_t$, որտեղ $A(i)_n$ -ը նորմավորված ակնթարթային ամպլիտուդան է, իսկ A_t -ն նախապես որոշված ամպլիտուդայի շեմային այն արժեքը, որից ցածր հաշվարկները նպատակահարմար չեն՝ աղմուկների բարձր մակարդակի պատճառով: Հավասարում (3.38)-ում $f(i)_{NC}$ -ը բնութագրվում է հետևյալ տեսքով՝

$$f(i)_{NC} = \frac{f(i)_m}{r_s}, \quad (3.39)$$

որտեղ r_s -ը սիմվոլների հաճախությունն է, իսկ $f(i)_m$ -ը կենտրոնացված հաճախականությունն է:

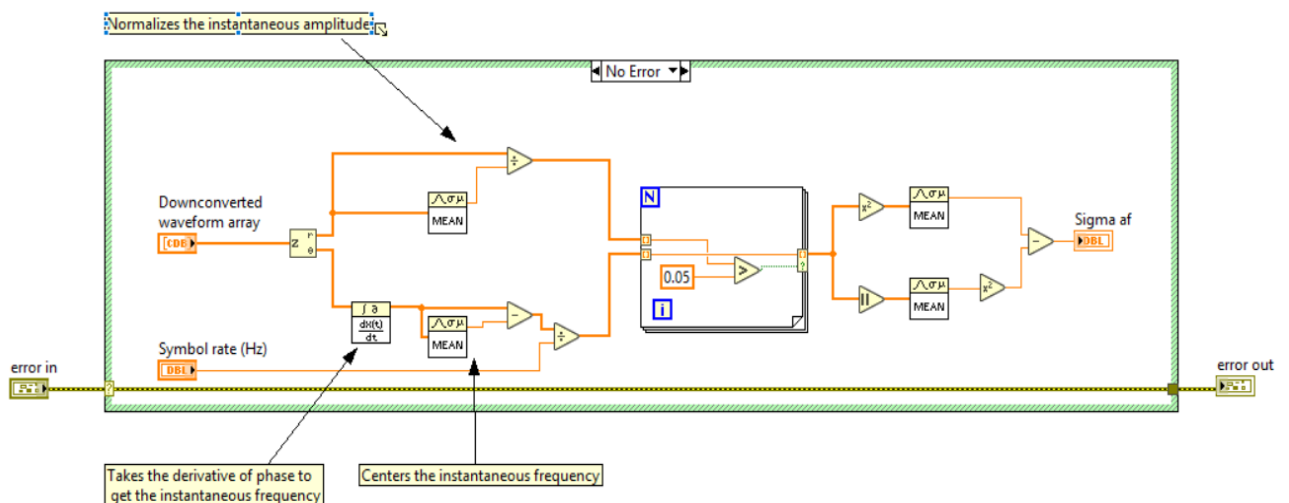
Հավասարում (3.39)-ում $f(i)_m$ -ը որոշվում է հետևյալ կերպ՝

$$f(i)_m = f(i) - m_f, \quad (3.40)$$

որտեղ $f(i)$ -ն ակնթարթային հաճախականությունն է, իսկ m_f -ը հաճախականության միջին արժեքը, որը բնութագրվում է հետևյալ հավասարմամբ՝

$$m_f = \frac{1}{N_s} \sum_{i=1}^{N_s} f(i): \quad (3.41)$$

Քանի որ 2FSK ազդանշանի նորմավորված-կենտրոնացված հաճախականությունը ունի երկու արժեք՝ հավասար մեծությամբ և հակառակ նշաններով, ապա հետևում է, որ հաճախականության բացարձակ արժեքը հաստատուն մեծություն է: Այստեղից պարզ է դառնում, որ 2FSK ազդանշանը չի պարունակում բացարձակ հաճախականային տեղեկատվություն: Իր հերթին 4FSK ազդանշանը պարունակում է բացարձակ հաճախականային տեղեկատվություն, ինչով և տարբերվում է 2FSK ազդանշանից: Այս հիմնական բնութագրող հատկանիշի համար նախատեսված ծրագրի հատվածը պատկերված է նկ. 27-ում:



Նկ. 3.19 σ_{ph} -ի հաշվարկը

Այս բնութագրող հատկանիշի հաշվարկն իրականացնելու համար ակնթարթային փուլի ածանցելու միջոցով ստացվել է ակնթարթային հաճախականությունը, որը

այնուհետև կենտրոնացվում և նորմավորվում է ըստ սխմվողների հաճախության արժեքի: Հաջորդիվ վերցվում են այն ակնթարթային հաճախականության արժեքները, որոնց դեպքում ակնթարթային ամպլիտուդան մեծ է նախորոք որոշված շեմային արժեքից: Վերջում իրականացվում է հավասարում (3.38)-ով սահմանված հաշվարկը:

3.4.6 Ակնթարթային ամպլիտուդայի նորմավորված արժեքի միջինը՝ E_m

Ազդանշանների տվյալ հիմնական բնութագրող հատկանիշը մշակվել է հատուկ M-PSK և M-QAM մոդուլացման տեսակների տարբերակման համար: Ինչպես արդեն նշվել է և երևում է հավասարում (3.28)-ից M-PSK մոդուլացված ազդանշանների ակնթարթային ամպլիտուդան չի փոփոխվում: Միննույն ժամանակ M-QAM մոդուլացումների դեպքում՝ ինչպես երևում է հավասարում (3.35)-ից, ակնթարթային ամպլիտուդայի արժեքները փոփոխական են՝ օրինակ 16QAM մոդուլացման դեպքում (նկ. 3. 14) բացարձակ ամպլիտուդան ունի երեք արժեք:

Դիտարկվող E_m հիմնական բնութագրող հատկանիշի հաշվարկի համար մշակվել է հետևյալ հավասարումը՝

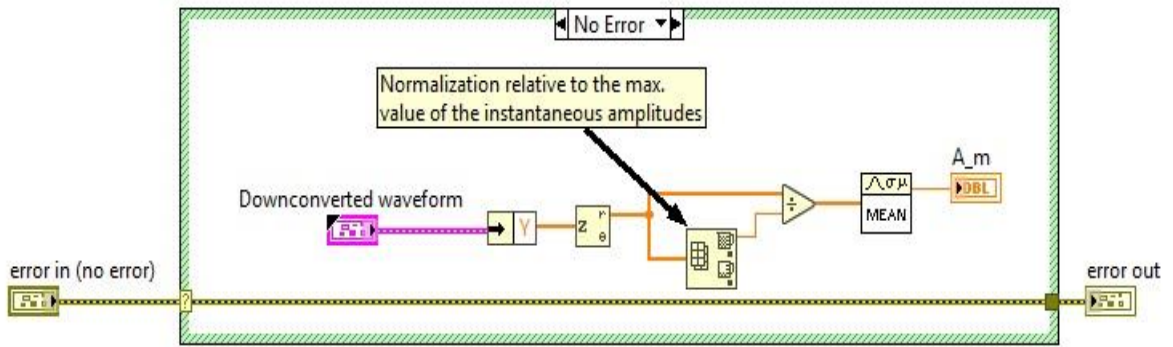
$$E_m = \frac{1}{N_s} \sum_{i=1}^{N_s} A(i)_{n_{max}}, \quad (3.42)$$

որտեղ $A(i)_{n_{max}}$ -ը ազդանշանի ակնթարթային ամպլիտուդայի նորմավորված արժեքն է՝ նորմավորված ըստ դրա առավելագույն արժեքի, և բնութագրվում է հետևյալ հավասարմամբ՝

$$A(i)_{n_{max}} = \frac{A(i)}{A(i)_{max}}, \quad (3.43)$$

որտեղ $A(i)$ -ն ամպլիտուդայի ակնթարթային արժեքն է, իսկ $A(i)_{max}$ -ն ակնթարթային ամպլիտուդայի առավելագույն արժեքը:

Տվյալ բնութագրի ծրագրային իրականացումը պատկերված է նկ. 3.20-ում:



Նկ. 3.20 E_m -ի հաշվարկը

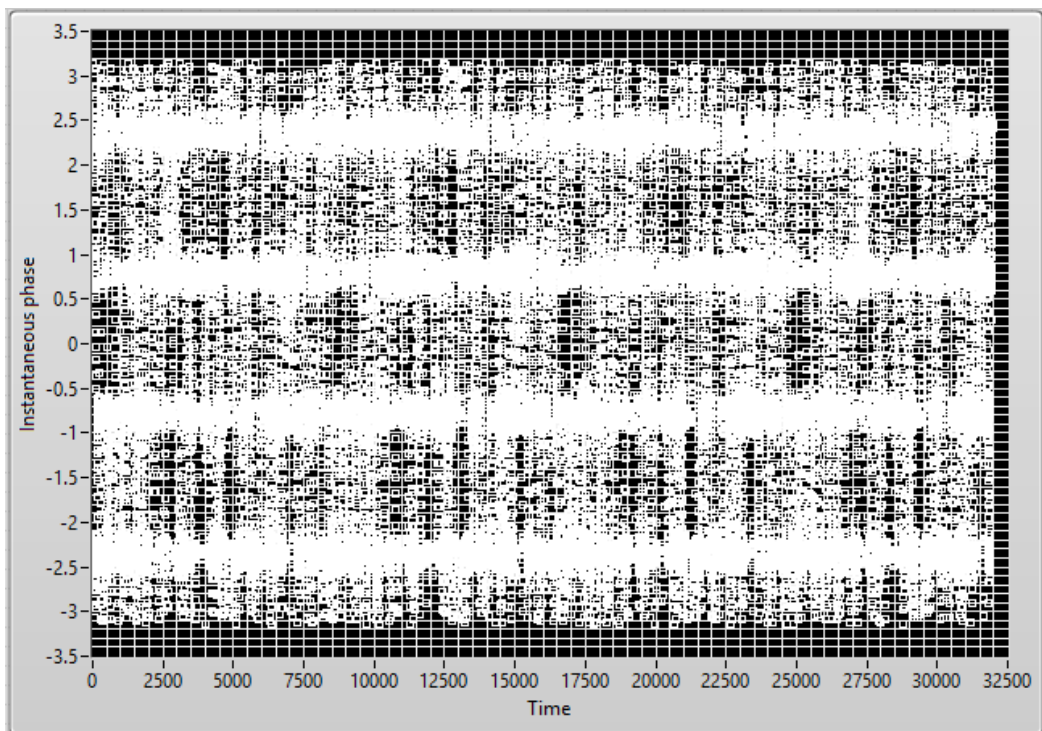
Տվյալ հիմնական բնութագրող հատկանիշի հաշվարկը բավականին պարզ է և ոչ ժամանակատար, ինչը այն դարձնում է արդյունավետ միջոց ներկայումս ամենալայն կիրառություն ունեցող թվային մոդուլացման տեսակների՝ BPSK-ի և QAM-ի միմյանցից տարբերակման համար: Մոդուլացված ազդանշանից առանձնացվում է վերջինիս ակնթարթային ամպլիտուդայի զանգվածը, ինչից հետո այդ զանգվածի բոլոր էլեմենտները բաժանվում են առավելագույն արժեքի վրա: Այնուհետև, իրականացվում է այդ արժեքների միջինի հաշվարկը: Նորմավորումն իրականացվում է աղմուկների արդյունքում առաջացած ամպլիտուդայի տատանումների կոմպենսացման համար: Իրականացրած փորձերի հիման վրա պարզվել է, որ, քանի որ PSK ազդանշանների դեպքում ամպլիտուդան իդեալական դեպքում ունի հաստատուն արժեք, ապա այս հիմնական բնութագրող հատկանիշը նույնպես PSK ազդանշանների համար ունենում է հաստատուն մեկին մոտ արժեք, իսկ QAM մոդուլացման տեսակի համար այս բնութագրի արժեքը հիմնականում կիսով չափ փոքր արժեք է ստանում:

3.4.7 Ակնթարթային փուլի բաշխվածության քանակը՝ φ_{PF}

Ազդանշանի տվյալ բնութագրող հատկանիշը մշակվել է և նախատեսված է տարբերակելու թվային փուլային M-PSK մոդուլացման տեսակները ըստ դրանց կարգերի: Քանի որ ներկայացված հիմնական բնութագրող հատկանիշների մեջ առկա է բնութագրող հատկանիշ՝ σ_{PF} -ն, որը հնարավորություն է տալիս տարբերակել BPSK և QPSK ազդանշանները, ապա այս հիմնական բնութագիրը ավելի շատ նախատեսված է 8PSK մոդուլացման տեսակի և մնացած երկու դիտարկվող փուլային մոդուլացված

ազդանշանների տարբերակման համար: Այս հատկանիշը նաև հանդիսանում է լրացուցիչ միջոց BPSK և QPSK մոդուլացման տեսակների տարբերակման համար:


Տվյալ հատկանիշը բնութագրում է ակնթարթային փուլի արժեքների իրենց ամբողջ արժեքների տիրույթում բաշխվածության հաճախությունը: Այլ կերպ ասած՝ այն հայտնաբերում է դրանց մեջ միևնույն արժեքին մոտ կամ կրկնվող արժեքների խտության քանակը, ինչը հենց փուլային մոդուլացման կարգի մասին տեղեկատվությունն է: Նկ. 3.21-ում առավել պատկերավոր լինելու համար պատկերված է QPSK մոդուլացված ազդանշանի ակնթարթային փուլի արժեքների գրաֆիկը՝ ներկայացված բաղկացուցիչ կետերի տեսքով:



Նկ. 3.21 QPSK ազդանշանի ակնթարթային փուլի գրաֆիկը ներկայացված բաղկացուցիչ կետերի միջոցով

Նկ. 3.21-ում պատկերված գրաֆիկի վրա կարելի է հստակ տեսնել չորս հորիզոնական գծեր, որոնք վկայում են այն մասին, որ տվյալ ազդանշանի ակնթարթային փուլը չորս անգամ փոփոխվել է: Հետևաբար կարելի է եզրակացնել, որ այս նույն պատկերը կտեսնենք մյուս փուլային մոդուլացված ազդանշանների դեպքում, որում համապատասխան գծերի քանակը կվկայի դրա փուլի փոփոխությունների քանակի մասին:

Այսպիսով՝ տվյալ հիմնական բնութագրող հասկանիշը մշակվել է ակնթարթային փուլի փոփոխությունների քանակի միջոցով փուլային մոդուլացված ազդանշանի կարգը հայտնաբերելու համար: Որոշված արժեքների տիրույթում փուլերի կրկնման քանակի մասին տեղեկատվությունը ստացվել է հիստոգրամի միջոցով [85]: Հիստոգրամը դա թվային արժեքների բաշխվածության ճշգրիտ ներկայացումն է, այսինքն վերցված արժեքների տիրույթում դիտարկվող թվային տվյալների պատահման քանակի ներկայացումը: Հիստոգրամը հաշվարկում է ակնթարթային փուլի առավելագույն և նվազագույն արժեքների տարբերության հարաբերությունը ինչ-որ N արժեքի և ներկայացնում է թե քանի արժեք ունի ակնթարթային փուլը տվյալ տիրույթում: Նկ. 3.22-ում պատկերված է 8PSK մոդուլացված ազդանշանի ակնթարթային փուլի արժեքների հիստոգրամը:



Նկ. 3.22. 8PSK ազդանշանի հիստոգրամը

Նկ. 3.22-ում հստակ երևում են ութ հիմնական առավելագույն արժեք ունեցող գագաթներ, որոնք վկայում են այն մասին, որ այս 8 տիրույթներում տվյալ ազդանշանի ակնթարթային փուլը ունեցել է առավելագույն քանակի արժեքներ, այսինքն տվյալ փուլային մոդուլացված ազդանշանի կարգը հավասար է ութի:

Այսպիսով՝ տվյալ հիմնական բնութագրող հատկանիշի հաշվարկման համար մշակվել է հետևյալ հավասարումը՝

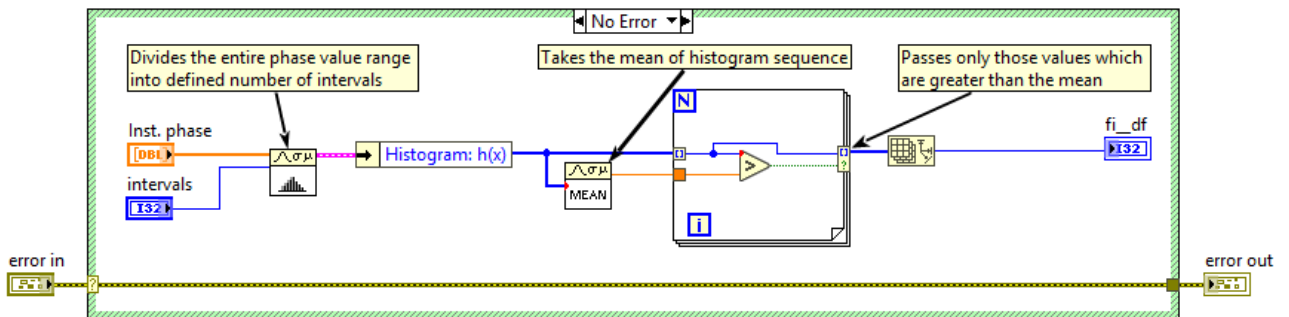
$$\varphi_{PP} = \sum_{i=0}^{N-1} H_i, \quad (3.44)$$

$$H_i = \begin{cases} 1, & h_i(\varphi) > h_{i_m}(\varphi) \\ 0, & h_i(\varphi) \leq h_{i_m}(\varphi) \end{cases},$$

որտեղ $h_i(\varphi)$ -ն հիստոգրամի $h(\varphi) = \{h_0(\varphi), h_1(\varphi), \dots, h_{N-1}(\varphi)\}$ հաջորդականության i -րդ անդամն է, իսկ $h_{i_m}(\varphi)$ -ը միևնույն հաջորդականության միջին արժեքն է և բնութագրվում է հետևյալ հավասարմամբ՝

$$h_{i_m}(\varphi) = \frac{1}{N-1} \sum_{i=0}^{N-1} h_i(\varphi): \quad (3.45)$$

Նկ. 3.23-ում պատկերված է տվյալ բնութագրող հատկանիշի համար մշակված ծրագրային կոդը:




Նկ. 3.23 φ_{PP} – հաշվարկի ծրագրային կոդը

Նկ.3.23-ում պատկերված կոդում ակնթարթային փուլի բաշխվածության քանակը նշված արժեքների տիրույթներում որոշվում է LabVIEW ծրագրավորման միջավայրի «Histogram VI» վիրտուալ գործիքի միջոցով [86]: Այնուհետև հաշվարկվում է հիստոգրամի հաջարդականության միջին արժեքը: Հաջորդականության բոլոր անդամները ներմուծվում են For օղակման մեջ, որտեղ կատարվում է հիստոգրամի հաջորդականության յուրաքանչյուր անդամի համեմատությունը հաշվարկված միջին արժեքի հետ և էլքում ստացվում են այն արժեքները, որոնք մեծ են այդ միջին արժեքից: Ստացված արժեքների քանակը ազդանշանի փուլի M կարգն է:

3.4.8 Ակնթարթային ամպլիտուդայի բաշխվածության քանակը՝ $A_{\text{բբ}}$


Ինչպես նշվել է M-QAM մոդուլացման դեպքում, ազդանշանի սիմվոլները ձևավորվում են համապատասխան ազդանշանի I և Q բաղադրիչների ամպլիտուդայի և փուլի արժեքների կոմբինացիաների: Թվային M-QAM մոդուլացման M կարգի իմացության համար նպատակահարմար չէ կիրառել նրանում փարունակված փուլային տեղեկատվությունը, քանի որ ակնհայտ շփոթմունք կառաջանա PSK մոդուլացման հետ: Այս պատճառով մշակվել է ազդանշանի հիմնական բնութագրող հատկանիշ, որը հնարավորություն կտա հայտնաբերել M-QAM ազդանշանի կարգը: Դիտարկենք 32QAM ազդանշանի համաստեղության դիագրամը (նկ. 3.14): Ինչպես արդեն նշվել է յուրաքանչյուր M-QAM ազդանշանի համար ամպլիտուդան ունի համապատասխան քանակի արժեքներ (նկ. 3.24):



Նկ. 3.24. 32QAM ազդանշանի ամպլիտուդայի գրաֆիկ

Նկ. 3.23-ում պատկերված է 32QAM մոդուլացված ազդանշանի ամպլիտուդայի գրաֆիկը՝ ներկայացված բաղկացուցիչ կետերի միջոցով: Նկարում հստակ երևում են 5 զձեր, որոնք համապատասխանում են ամպլիտուդայի արժեքների խտությանը տվյալ տիրույթներում: Հետևաբար, դիտարկելով ակնթարթային ամպլիտուդայի գրաֆիկը

կարելի է տեսնել վերջինիս ակնթարթային ամպլիտուդայի փոփոխությունների քանակը, ինչը երևում է նաև նկ. 3.25-ում հիստոգրամի գրաֆիկից:



Նկ. 3.25 16QAM ազդանշանի ակնթարթային ամպլիտուդայի հիստոգրամը

Տվյալ հիմնական բնութագրող հատկանիշը բնութագրվում է հետևյալ հավասարմամբ՝

$$A_{\text{pp}} = \sum_{i=0}^{N-1} H_i, \quad (3.46)$$

$$H_i = \begin{cases} 1, & h_i(A) > h_{i-m}(A) \\ 0, & h_i(A) < h_{i-m}(A) \end{cases}$$

որտեղ $h_i(A)$ -ն հիստոգրամի $h(A) = \{h_0(A), h_1(A), \dots, h_{N-1}(A)\}$ հաջորդականության i -րդ անդամն է, իսկ $h_{i-m}(A)$ -ը միևնույն հաջորդականության միջին արժեքն է և բնութագրվում է հետևյալ հավասարմամբ՝

$$h_{i-m}(A) = \frac{1}{N-1} \sum_{i=0}^{N-1} h_i(A): \quad (3.47)$$

Տվյալ մշակված բնութագրող հատկանիշը նախատեսված է հաշվարկել ազդանշանում առկա ակնթարթային ամպլիտուդայի փոփոխման քանակը, ինչը հենց հանդիսանում է վերջինիս ամպլիտուդայի կարգը: Տվյալ բնութագրի հաշվարկի

ծրագրային կողմը միևնույն է ինչ ներկայացված է $\varphi_{\text{բբ}}$ -ի համար նկ.3.23-ում, բացառությամբ որ տվյալ դեպքում հիստոգրամի մուտքին տրվում է ակնթարթային ամպլիտուդայի արժեքների զանգվածը:

Այսպիսով՝ դիտարկվել են թվային մոդուլացման տեսակների նույնականացման համար նախատեսված ազդանշանների հիմնական բնութագրող հատկանիշները, որոնք համապատասխանաբար նախատեսված են տարբերակել՝

- Y_{max} – 2FSK, 4FSK և մնացած մոդուլացման տեսակները
- $\sigma_{\text{բփ}}$ – BPSK, 2ASK, 4ASK և մնացած մոդուլացման տեսակները
- $\sigma_{\text{փ}}$ – 2ASK, 4ASK և մնացած մոդուլացման տեսակները
- $\sigma_{\text{բա}}$ – 2ASK և 4ASK մոդուլացման տեսակները
- $\sigma_{\text{բհ}}$ – 2FSK և 4FSK մոդուլացման տեսակները
- E_m – PSK և QAM մոդուլացման տեսակները
- $\varphi_{\text{բբ}}$ – BPSK, QPSK, 8PSK մոդուլացման տեսակները
- $A_{\text{բբ}}$ – 16QAM, 32QAM, 64QAM մոդուլացման տեսակները

Վերոնշյալ հիմնական բնութագրող հատկանիշների գործառնությունների ուսումնասիրման արդյունքում, պարզվել է, որ ա) մշակված E_m հիմնական բնութագրի միջոցով հնարավոր է նաև տարբերակել M-FSK ազդանշանները մնացած մոդուլացման տեսակներից, բացառությամբ M-PSK տեսակները, քանի որ այդ մոդուլացման տեսակների դեպքում ակնթարթային ամպլիտուդայի միջին արժեքը հավասար կլինի 1-ի, իսկ մնացածի դեպքում այն 1-ից փոքր թիվ է: M-PSK մոդուլացման տեսակներից հնարավոր է տարբերակել M-FSK մոդուլացումները $\varphi_{\text{բբ}}$ բնութագրող հատկանիշի միջոցով ստացված փուլի կարգի մասին տեղեկատվության միջոցով, որը միշտ հստակ արժեք ունի փուլային մոդուլացված ազդանշանների համար, բ) մշակված $\varphi_{\text{բբ}}$ հիմնական բնութագրի միջոցով հնարավոր է նաև իրականացնել Ազգոուզի և Նանդիի կողմից առաջարկված $\sigma_{\text{բփ}}$, $\sigma_{\text{փ}}$ բնութագրերի գործառնությունը, քանի որ ազդանշանի փուլը BPSK ազդանշանի համար կունենա երկու արժեք, իսկ 2ASK և 4ASK ազդանշանների համար 1 արժեք, ինչը հնարավորություն է տալիս տարբերակել BPSK, 2ASK, 4ASK ազդանշանները մնացած մոդուլացման տեսակներից և 2ASK, 4ASK մոդուլացումները

BPSK մոդուլացման տեսակից, գ) մշակված $A_{\text{բբ}}$ բնութագրող հատկանիշի միջոցով իրականացնել $\sigma_{\text{բա}}$ բնութագրի գործառույթը, քանի որ ազդանշանի ամպլիտուդան 2ASK ազդանշանի համար ունի երկու արժեք, իսկ 4ASK ազդանշանի համար 4 արժեք, ինչը հնարավորություն է տալիս տարբերակել 2ASK և 4ASK ազդանշանները: Հետևաբար, մշակված հիմնական բնութագրող հատկանիշների միջոցով հնարավորություն է առաջանում սույն աշխատանքում դիտարկված թվային մոդուլացման տեսակների նույնականացման համար նախատեսված ութ բնութագրող հատկանիշների փոխարեն կիրառել չորս հատկանիշ:

Այսպիսով՝ մշակված հիմնական բնութագրող հատկանիշների միջոցով հնարավոր է օպտիմալացնել ազդանշանների նույնականացման համար կիրառվող բնութագրող հատկանիշները, ինչը հնարավորություն է տալիս ավելի արդյունավետ հաշվարկներ իրականացնել՝ կրճատելով դրանց տևողությունը իրական ժամանակում և նվազեցնելով վերջիններիս իրականացման համար սպառվող համակարգչի օպերացիոն հիշողության ծավալը:

ԳԼՈՒԽ 4. ՄՇԱԿՎԱԾ ՄԵԹՈԴԻ ԾՐԱԳՐԱՅԻՆ ԿՈՂԸ ԵՎ ՓՈՐՁԱՐԱՐԱԿԱՆ ԱՐԴՅՈՒՆՔՆԵՐԸ

Ինչպես արդեն նշվել է՝ տվյալ աշխատանքի հիմքում ընկած խնդրի լուծման նպատակով մշակված մեթոդի շրջանակներում որպես մոդուլացման տեսակների նույնականացման համակարգ ընտրվել է արհեստական նեյրոնային ցանցը: Քանի որ մեթոդի ալգորիթմը մշակվել է LabVIEW գրաֆիկական ծրագրավորման միջավայրում և այնտեղ առկա չեն որևէ արհեստական նեյրոնային ցանցերին վերաբերող գրադարաններ կամ վիրտուալ գործիքների խմբեր, ապա անհրաժեշտ է նախ և առաջ հիմնավորել նշված ցանցերի իրագործելիությունը LabVIEW միջավայրում: Այս պատճառով LabVIEW միջավայրում մշակվել է արհեստական նեյրոնային ցանցի բազային մոդել, որը նախատեսված է պարզ հաշվարկներ իրականացնելու և ազդանշանի տեսակի նույնականացման պարզ խնդիր լուծելու համար [87]: Մշակված ԱՆՑ ալգորիթմի գործառնությունը չորս տեսակի մոդելավորված ազդանշանների՝ Sine, Triangle, Square, Sawtooth նույնականացումն է: Ալգորիթմի փորձարկումների համար բոլոր այս ազդանշանները գեներացվել են իրականին մոտ պայմաններում՝ գումարելով մոդելավորված սպիտակ գաուսյան աղմուկ:


Նշված ազդանշանների նույնականացման համար որպես հիմնական բնութագրող հատկանիշներ ընտրվել են դրանց հարմոնիկաների մակարդակները, որոնք առանձնացվել են ազդանշաններից նախամշակման փուլում:

Այս նախնական փորձնական աշխատանքի նպատակն է հիմնավորել, որ չորս տեսակի ազդանշանների ճանաչման արդյունքների ճշտության աստիճանը բավարար հիմք է հանդիսանում եզրակացնելու, որ ԱՆՑ ալգորիթմի մշակումը հնարավոր է իրականացնել LabVIEW միջավայրում և զարգացնել ու բարելավել այն ավելի բարդ հաշվարկների և կոմպլեկս խնդիրների, մասնավորապես ՄԱՆ խնդրի լուծման համար:


4.1 ԱՆՑ բազային մոդելի ալգորիթմը

Ազդանշանների Sine, Triangle, Square և Sawtooth [88] տեսակների համար որպես գլխավոր բնութագրող հատկանիշ ընտրվել է նշված ազդանշանների հարմոնիկաների հզորության մակարդակները և այդ ընտրությունը հիմնավորված է այն փաստով, որ այս ազդանշաններից յուրաքանչյուրն ունի առանձնահատուկ հարմոնիկաների հզորության


մակարդակներ և միմյանց հաջորդող հարմոնիկաների հզորության մակարդակների միջև յուրահատուկ տարբերություն:




ա) Sine



բ) Triangle



զ) Square



ը) Sawtooth

Նկ.4.1 Ազդանշանների սպեկտրներ՝ ա) Sine, բ) Triangle, գ) Square, ը) Sawtooth

Նկ. 4.1-ում պատկերված ազդանշանների հաճախականությունը և ամպլիտուդան պատահական կերպով ընտրվել են համապատասխանաբար 10 Հց և 1 և դրանց գումարվել է գաուսյան աղմուկ՝ մոդելավորված ազդանշաններին իրական տեսք տալու

համար: Նկար 4.1 (ա)-ում պատկերված է Sine ազդանշանի սպեկտրը, որում երևում է, որ սինուսը ունի մեկ հիմնական հարմոնիկա, որը համապատասխանում է ազդանշանի հաճախականությանը:

Նկ. 4.1 (բ)-ում պատկերված Triangle ազդանշանի սպեկտրից երևում է, որ վերջինիս հարմոնիկաների հզորության մակարդակները բավականին կտրուկ են նվազում և առաջին ու երկրորդ հարմոնիկաների հզորության մակարդակների միջև տարբերությունը զգալի չափով մեծ է:

Ինչպես երևում է նկ. 4.1 (գ)-ում Square ազդանշանի հարմոնիկաների հզորության մակարդակները նվազում են համեմատաբար սահուն կերպով և ի տարբերություն մյուս ազդանշանների ունեն բարձր արժեքներ:

Sawtooth ազդանշանը համեմատած մնացած ազդանշանների ունի երկու առանձնահատկություն: Առաջինը դա այն է, որ վերջինս ունի հարմոնիկաներ ոչ միայն իր հաճախականությանը պատիկ գույգ կամ կենտ հաճախությունների վրա, այլ ունի հարմոնիկներ բոլոր պատիկ հաճախությունների վրա՝ $2f$, $3f$, $4f$ և այլն: Երկրորդ առանձնահատկությունը կայանում է նրանում, որ այս ազդանշանի հարմոնիկաների միմյանց մոտիկ գտնվելու պատճառով դրանց հզորությունների մակարդակների միջև տարբերությունը աննշան է:

Աղյուսակ 4.1-ում բերված են վերոնշյալ մոդելավորված չորս ազդանշանների առաջին չորս հարմոնիկաների մակարդակները, որոնք չափվել են LabVIEW ծրագրավորման միջավայրում մշակված ալգորիթմի միջոցով:

Աղյուսակ 4.1. Առաջին չորս հարմոնիկաների մակարդակները

№	Sine	Triangle	Square	Sawtooth
1	0,99848	0,81229	1,27299	0,654083
2	0,00481117	0,0890761	0,425666	0,318342
3	0,00468779	0,0317383	0,254277	0,274312
4	0,00439043	0,0159492	0,184412	0,230254

Ինչպես երևում է աղյուսակում ներկայացված ազդանշանների հարմոնիկաների հզորության բոլոր մակարդակները առանձնահատուկ են և փոփոխվում են

ազդանշանին հատուկ կերպով: Այս հանգամանքը հանդիսանում է ազդանշանները միմյանցից տարբերակելու հիմնական բնութագրող հատկանիշ:

Ազդանշանի մշակման փուլից հետո, երբ դրանց հիմնական բնութագրող հատկանիշները առանձնացված են, այդ արժեքները ցանցի մուտքերին տալու համար հարկավոր է նորմավորել դրանք ըստ հիմնական հարմոնիկայի մակարդակի: Այլ կերպ ասած հարկավոր է ազդանշանի առաջին հարմոնիկային հաջորդող երեք հարմոնիկաների հզորության մակարդակների արժեքները բաժանել այդ ազդանշանի հիմնական հարմոնիկայի մակարդակի վրա: Նորմավորումն անհրաժեշտ է, որպեսզի թեստավորման փուլում համակարգը որպես արհեստական նեյրոնային ցանցի մուտքային արժեք վերցնի հարմոնիկաների մակարդակների նորմավորված արժեքը, քանի որ դրանց հզորության մակարդակների հարաբերությունը շատ քիչ տատանումներ կունենա իսկզբանե ցանցի ուսուցման փուլում դրա մուտքերին տրված արժեքների նկատմամբ: Այս հանգամանքը հնարավորություն կտա, որպեսզի թեստավորման փուլում սիմուլացված ազդանշանների ամպլիտուդայի փոփոխությունները զգալի ազդեցություն չունենան նեյրոնային ցանցի գործառույթի ճշտության վրա:

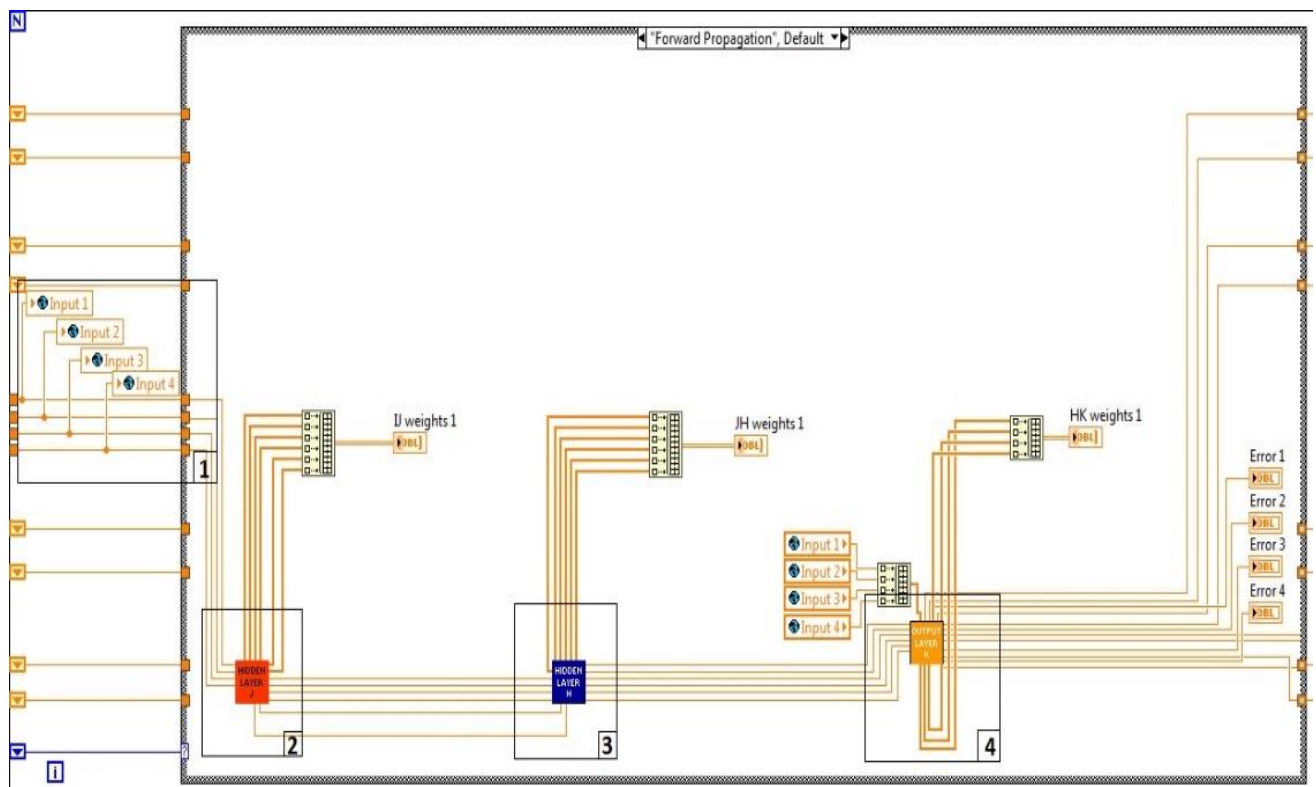
4.1.1 ԱՆՑ բազային մոդելի ուսուցումը և թեստավորումը

Մշակված արհեստական նեյրոնային ցանցի բազային մոդելը կազմված է չորս նեյրոնից բաղկացած մուտքային շերտից, վեցական նեյրոններից բաղկացած երկու թաքնված շերտերից և ելքային շերտից, որը բաղկացած է չորս ելքային նեյրոններից: Մուտքային շերտի նեյրոնների քանակը համապատասխանում է դրա մուտքին տրվող հիմնական բնութագրող հատկանիշների քանակին՝ տվյալ դեպքում ազդանշանի չորս հարմոնիկաների նորմավորված հզորության մակարդակներին: Ցանցի ուսուցման համար դրա մուտքերին տրված ուսուցողական զույգերի և՛ մուտքային, և՛ ելքային ստուգողական տվյալները դա ազդանշանի հարմոնիկաների հզորության մակարդակների նորմավորված արժեքներն են:

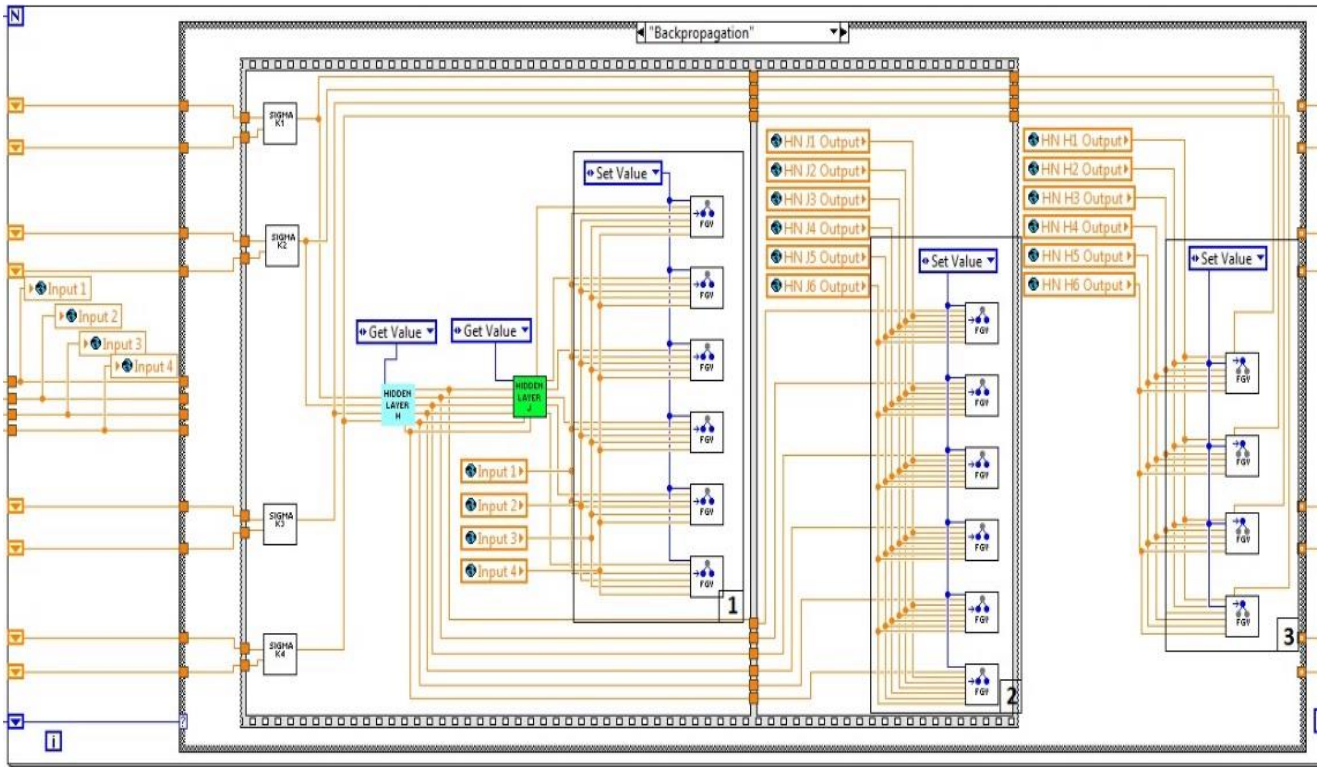
Այսպիսով՝ ցանցին տրվել է առաջադրանք, որպեսզի վերջինս գտնի նեյրոնային կապուղիների կշիռների այնպիսի համադրություն, որի դեպքում ցանցը ելքում ստանա նույն արժեքները ինչ որ տրված է դրա մուտքին: Այդ պատճառով ելքային չորս

նեյրոնների պահանջվող ելքային արժեքները համապատասխանաբար հավասար են մուտքային արժեքներին:

Ցանցի ուսուցումը իրականացվել է սխալի հակադարձ տարածման հիման վրա [88]: Քանի որ ուսուցման ժամանակ տվյալները անցնում են ուղիղ և հակադարձ տարածման փուլերը, ապա ընդհանուր իտերացիաների քանակը վերցվել է 32768, որը հանդիսանում է երկուսի աստիճան: Նկ. 4.2-ում պատկերված են LabVIEW միջավայրում մշակված ԱՆՑ-ի բազային մոդելի ուղիղ տարածման և հակադարձ տարածման կողի հատվածները:



ա) Ուղիղ տարածում



բ) Հակադարձ տարածում

Նկ. 4.2 ԱՆՑ-ի կողք LabVIEW միջավայրում

ա) - 1) Մուտքային ազդանշաններ, 2) 1-ին թաքնված շերտ, 3) 2-րդ թաքնված շերտ, 4) ելքային շերտ;

բ) - 1) 1-ին թաքնված շերտի կշիռների թարմացում, 2) 2-րդ թաքնված շերտի կշիռների թարմացում, 3) ելքային շերտի կշիռների թարմացում

Ուսուցման փուլում ցանցը հաշվարկում է ելքային նեյրոններից յուրաքանչյուրի սխալը հետևյալ հավասարմամբ՝

$$E_k = \frac{1}{2} (y_k - t_z)^2, \quad (4.1)$$

որտեղ k -ն ($k = 1, 2, \dots, K$) ելքային շերտի նեյրոնի հերթական համարն է, z -ը ($z = 1, 2, \dots, Z$) ելքային նեյրոնին համապատասխանող պահանջվող արժեքի հերթական համարն է, t_z -ը պահանջվող ելքային արժեքների z -րդ էլեմենտն է, իսկ y_k -ն k -րդ նեյրոնին համապատասխանող փաստացի ստացված արժեքը: Ուսուցուման փուլի արդյունքում ստացված ելքային նեյրոնների սխալների արժեքները յուրաքանչյուր ազդանշանի համար պատկերված են աղյուսակ 4.2-ում:

Աղյուսակ 4.2. Ելքային K նեյրոնների սխալները բոլոր ազդանշանների համար

Նեյրոնի №	Sine	Triangle	Square	Sawtooth
k_1	1,22629E-5	1,22269E-5	1,30666E-5	1,2749E-5
k_2	1,22765E-5	1,23371E-5	1,31654E-5	1,28466E-5
k_3	1,21942E-5	1,22235E-5	1,31754E-5	1,26765E-5
k_4	1,22888E-5	1,21981E-5	1,30192E-5	1,26339E-5

Աղյուսակ 4.2-ում բերված տվյալներից երևում է, որ ստացված սխալների չափերը շատ փոքր են, ինչը վկայում է նրա մասին, որ ուսուցումը արդյունավետ է անցել բոլոր ազդանշանների տեսակների համար:

Գլուխ 2-ում բերված ԱՆՑ-երի նկարագրության համաձայն ցանցի յուրաքանչյուր նեյրոնի համար սիզմոնիալ ֆունկցիայի միջոցով սահմանվում է ակտիվ կամ պասիվ վիճակ՝ կախված վերջինիս արժեքի 0-ին կամ 1-ին մոտ լինելուց: Հետևաբար ակտիվ նեյրոնների համադրության միջոցով ելքային շերտում ստացվում են ակտիվ և պասիվ նեյրոններ, որոնց տարբեր համադրություններ համապատասխանում են տարբեր ազդանշանների, ինչի միջոցով և տեղի է ունենում ԱՆՑ-ի տվյալների նույնականացումը: Վերոնշյալ գործողությունները LabVIEW միջավայրում իրականացնելու համար անհրաժեշտ է բոլոր նեյրոնների համար լրացուցիչ ծրագրային կոդ մշակել, որը կիրականացնի նեյրոնի ակտիվ և պասիվ վիճակի որոշումը, ինչը նպատակահարմար չի համարվել կոդի արդյունավետության տեսանկյունից, սպա առաջարկվում է ԱՆՑ-ի վերջնական որոշման կայացման նոր մեթոդ: Ազդանշանների տեսակներից յուրաքանչյուրի ուսուցուման փուլի ավարտին հաշվարկված արհեստական նեյրոնային ցանցի կապուլիների կշիռների համադրությունը, որի միջոցով ստացվել են աղյուսակ 4.2-ում ներկայացված վերջնական սխալի չափերը, պահպանվում են տվյալ ազդանշանին հատուկ ֆայլում: Հարկ է նշել, որ միևնույն ազդանշանի գեներացման տարբեր պարամետրերի պարագայում կարելի է իրականացնել արհեստական նեյրոնային ցանցի բազմաթիվ ուսուցումներ: Սա հնարավորություն կտա ազդանշանի պարամետրերի փոփոխման արդյունքում առաջացած ազդանշանի հիմնական

բնութագրող հատկանիշների փոփոխված արժեքների համար նույնպես հաշվարկել ցանցի կապուղիների կշիռների համադրություն, որը պահպանվում է ազդանշանին հատուկ ֆայլում: Այնուհետև՝ թեստավորման ժամանակ պատահական սկզբունքով գներացվել է վերոնշյալ ազդանշաններից որևէ մեկը, ինչից հետո նախամշակման փուլում առանձնացվել են վերջինիս հիմնական բնութագրող հատկանիշները և համապատասխանաբար տրվել են ԱՆՑ-ի մուտքերին: ԱՆՑ-ը առկա բոլոր ֆայլերում պահպանված կշիռների համադրությունների և հավասարում (2.15)-ի միջոցով հաշվարկում է իր մուտքին տրված տվյալները: Այնուհետև հաշվարկվում է ցանցի ընդհանուր սխալի չափը հետևյալ հավասարմամբ՝

$$E = \sum_k E_k = \frac{1}{2} \sum_k (y_k - t_z)^2 : \quad (4.2)$$

Քանի որ, ուսուցման փուլում չորս տեսակի ազդանշանի համար հաշվարկվել են ցանցի կշիռների համադրություններ և պահպանվել են չորս տարբեր ֆայլերում, ապա ցանցը թեստավորման ընթացքում իր մուտքին տրված տվյալները հաշվարկում է չորս տարբեր կշիռների համադրությունների միջոցով: Արդյունքում միաչափ զանգվածում գրանցվում են ցանցի ընդհանուր չորս սխալի արժեքներ: Ելնելով այն փաստից, որ տրված ազդանշանի հիմնական բնութագրող հատկանիշների հաշվարկը պետք է հանգեցնի ցանցի նվազագույն սխալի այդ ազդանշանին համապատասխանող կշիռների համադրության պարագայում, ապա ցանցի սխալների միաչափ զանգվածից ընտրելով ամենափոքր արժեքը, համակարգը որոշում է իր մուտքին տրված ազդանշանի տեսակը: ԱՆՑ-ի վերջնական որոշման կայացման այս մեթոդը համարվում է արդյունավետ հաշվարկների կրճատման և ծրագրավորման պարզության տեսանկյունից: Այս մեթոդի միջոցով SNR-ի տարբեր արժեքների դեպքում իրականացված ԱՆՑ-ի դասակարգման ճշտության տոկոսային արդյունքները բերված են աղյուսակ 4.3-ում:

Աղյուսակ 4.3. Արհեստական ներդրնային ցանցի բազային մոդելի միջոցով կատարված չորս տեսակ ազդանշանների նույնականացման արդյունքները

SNR	Sine	Triangle	Square	Sawtooth
3dB	95%	95%	100%	100%
10dB	99%	97%	100%	100%
15dB	100%	99%	100%	100%
20dB	100%	100%	100%	100%

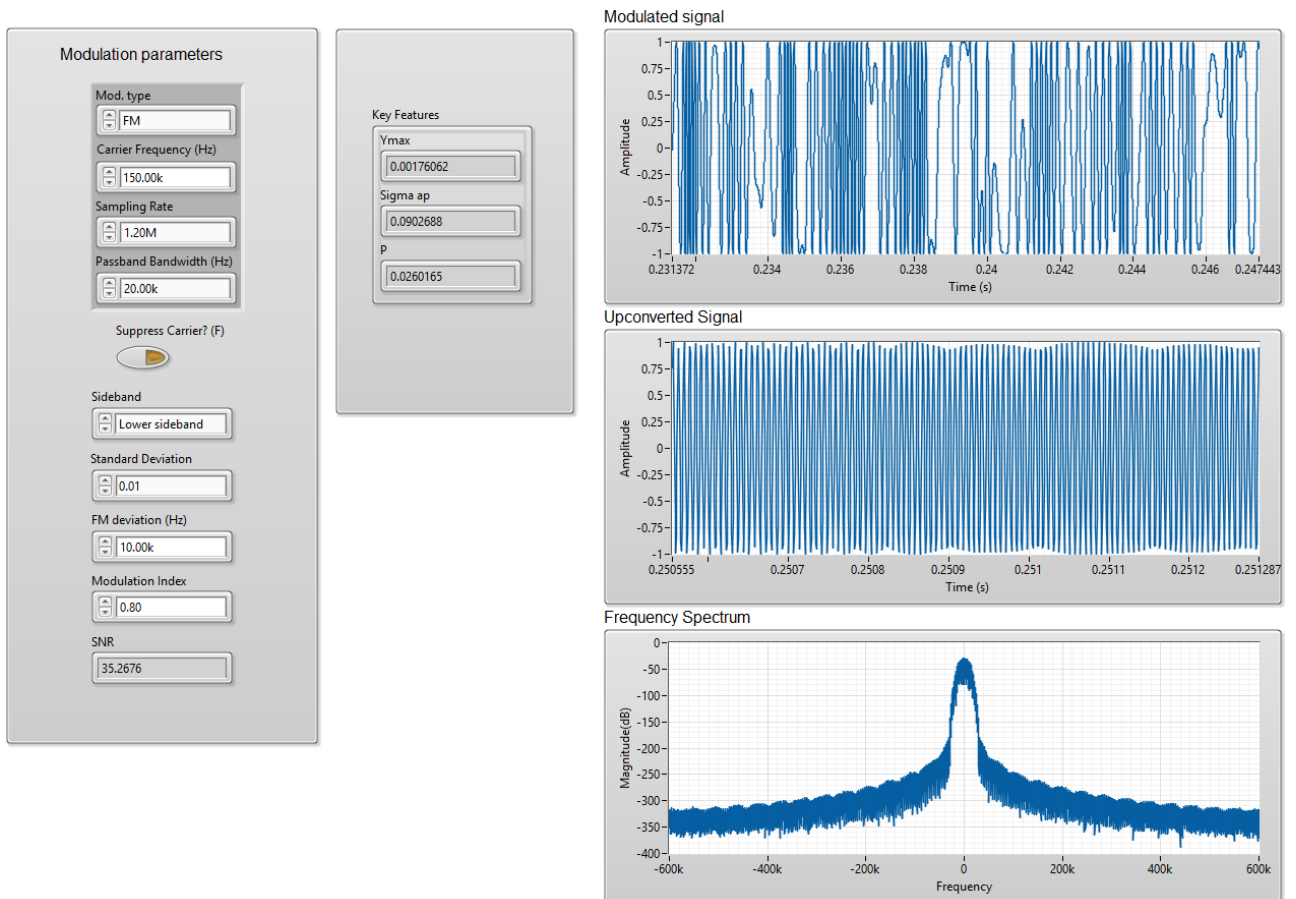
Աղյուսակ 4.3-ում ներկայացված տվյալներից կարելի է եզրակացնել, որ մշակված ալգորիթմը գերազանց ճշտությամբ նույնականացրել է Square և Sawtooth տեսակի ազդանշանները: Շատ չնչին, բայց գրանցված անճշտություններ եղել են Sine և Triangle ազդանշանների նույնականացման դեպքում՝ SNR-ի շատ ցածր արժեքների պայմանում:

Այս նախնական փորձնական աշխատանքի նպատակն է տեսության փորձնական հիմնավորումը և նույնականացման մեթոդի իրագործելիության ապացուցումը: Մշակված ալգորիթմի միջոցով իրականացված նույնականացման արդյունքների ճշտությունը հիմք է հանդիսանում LabVIEW գրաֆիկական ծրագրավորման միջավայրում հեռահաղորդակցական ազդանշանների մոդուլացումների տեսակների ավտոմատացված նույնականացման խնդրի լուծման նպատակով ալգորիթմի հետագա զարգացման համար: Վերոնշյալ փորձնական աշխատանքի արդյունքում հայտնաբերվեց, որ ստացված արդյունքների ճշտությունը հնարավոր է բարելավել թաքնված շերտերի ներդրումների քանակի փոփոխմամբ և/կամ SNR-ի ավելի շատ արժեքների դեպքում ցանցի ուսուցանման միջոցով:

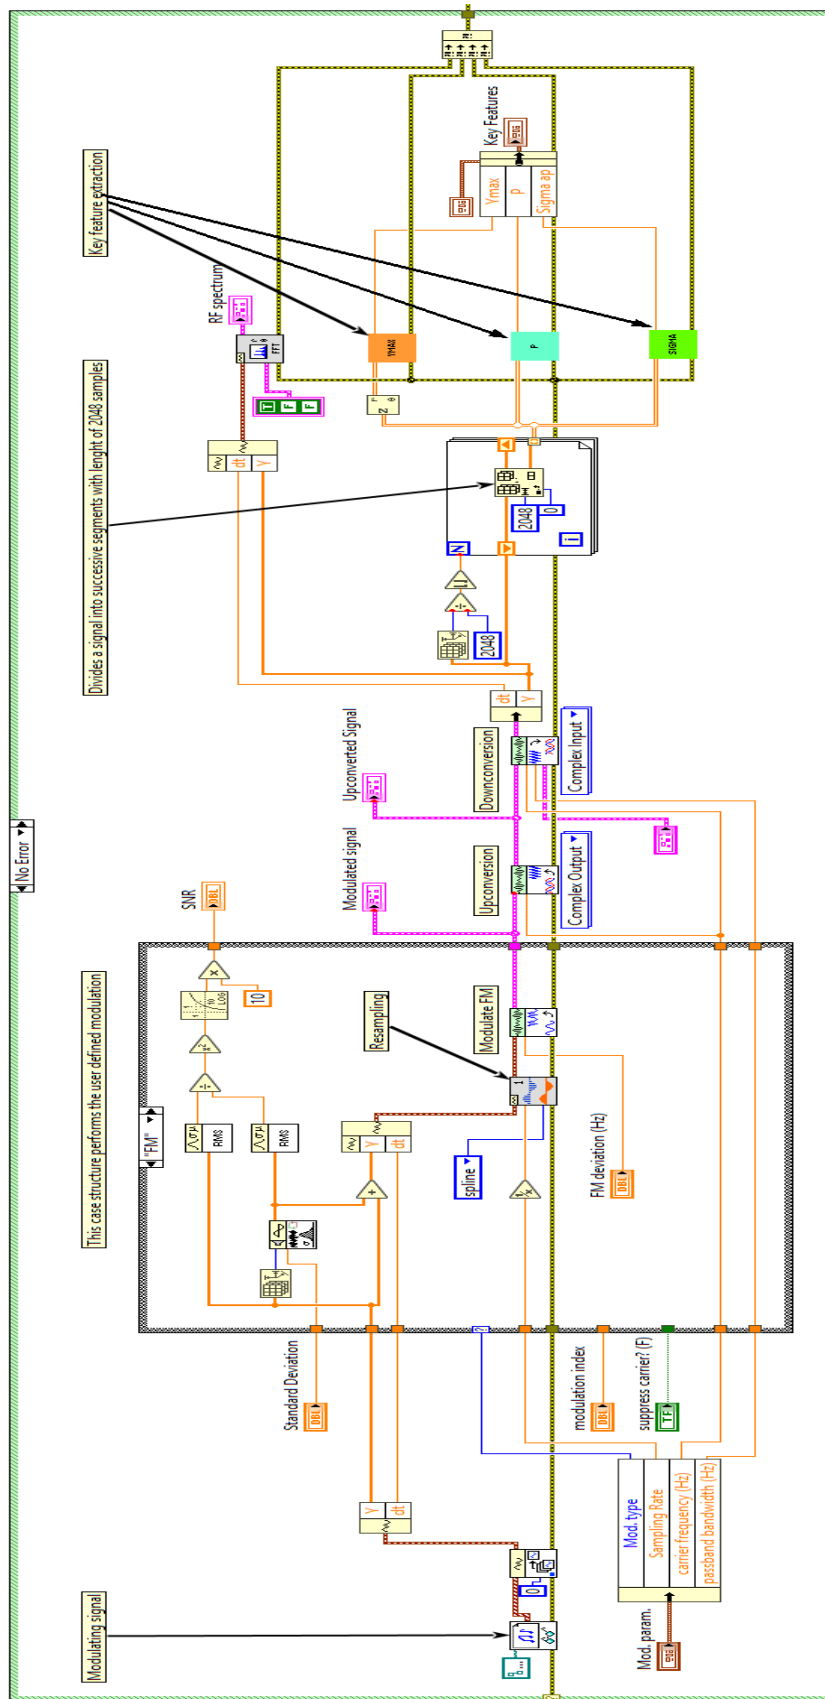
4.2 Անալոգային մոդուլացման տեսակների նույնականացումը

Տվյալ աշխատանքի շրջանակներում մշակված մեթոդի փորձնական իրականացումը կատարվել է անալոգային և թվային մոդուլացման տեսակների համար: Ստորև նկարագրված է անալոգային մոդուլացման տեսակների ավտոմատացված նույնականացման համար իրականացված փորձերը և դրանց արդյունքները [89]: Ինչպես արդեն նշվել է անալոգային մոդուլացման տեսակներից դիտարկվել են DSB, SSB և FM մոդուլացման տեսակները և փորձերը կատարվել են իրական գեներացված

ազդանշանների վերլուծության հիման վրա: Նկ. 4.4-ում և 4.5-ում համապատասխանաբար պատկերված են ՄԱՆ համակարգի առաջին բլոկի՝ ազդանշանի մշակման, օգտվողի միջերեսը և ծրագրային կոդի իրականացման հատվածը, որտեղ առանձնացվում են անալոգային մոդուլացման տեսակների համար նախատեսված մշակված հիմնական բնութագրող հատկանիշները:



Նկ. 4.4 Ազդանշանի մոդուլացման և հիմնական բնութագրերի առանձնացման ծրագրային կոդի օգտվողի միջերեսը



Նկ. 4.5 Ազդանշանի մոդուլացման և հիմնական բնութագրերի առանձնացման ծրագրային կոդի բլոկ դիագրաման


Նկ. 4.5–ում պատկերված է ՄԱՆ համակարգի առաջին բլոկում իրականացվող հաշվարկների և ազդանշանի մշակման գործընթացը, ինչը կատարվում ըստ տվյալների հոսքի հերթականության: Սկզբում ֆայլի միջից բեռնվում է գեներացված իրական ազդանշանի ալիքաձևի գրառումը, որի տվյալները այնուհետև ներմուծվում են օգտվողի կողմից տրված մոդուլացման տեսակին համապատասխանող կառուցվածքային բլոկի մեջ, որտեղ իրականացվում է ազդանշանի մոդուլացումը: Դրանից հետո մոդուլացված ազդանշանը խառնիչի միջոցով նստեցվում է օգտվողի կողմից որոշված հաճախականությամբ կրող ազդանշանի վրա: Քանի որ, ընդունող կողմում ենթադրաբար հայտնաբերվում և վերլուծության է ենթարկվում հենց բարձրհաճախականային հեռահաղորդակցական ազդանշանը, ապա նշված ալգորիթմում ազդանշանի վերլուծությունը և հիմնական բնութագրող հատկանիշների առանձնացումը իրականացվել է այդ ազդանշանի սեզմենտներից: Բարձրհաճախականային ազդանշանը այնուհետ բաժանվել է միմյանց հավասար հաջորթական սեզմենտների, որոնցից յուրաքանչյուրը պարունակում է 2048 կետ: Տվյալ մոդուլացված ազդանշանի դեպքում ստացվել է 2048 կետից բաղկացած 403 սեզմենտ, որոնցից յուրաքանչյուրի համար իրականացվել է հիմնական բնութագրող հատկանիշների հաշվարկը: Յուրաքանչյուր հիմնական բնութագրող հատկանիշի վերջնական արժեքը ստացվել է իրականացված 403 հաշվարկների արդյունքների միջինացմամբ:

Ինչպես երևում է նկ. 4.4–ում իրականացվել է FM հաճախականային մոդուլացում, որի արդյունքում հզորության սպեկտրալ խտության՝ Y_{max} -ի համար ստացվել է 0.001 Վտ/Հց արժեքը, ինչը համապատասխանում է վերոնշյալ տեսությանը այն մասին, որ տվյալ մոդուլացման դեպքում Y_{max} -ը ունենում է զրոյին մոտ արժեք, ակնթարթային փուլի կենտրոնացված ոչ գծային կոմպոնենտի բացարձակ արժեքի ստանդարտ դեվիացիայի՝ $\sigma_{\text{բփ}}$ -ի համար ստացվել է 0.90, ինչը նույնպես համապատասխանում է տեսությանը այն մասով, որ FM ազդանշանի ակնթարթային փուլի բացարձակ արժեքը հավասար չէ $|\frac{\pi}{2}|$ և այն պարունակում է փուլային տեղեկատվություն, ինչը հնարավորություն է տալիս տարբերակել այս ազդանշանը DSB մոդուլացման տեսակից, իսկ սպեկտրալ համաչափության՝ P-ի համար ստացվել է շատ փոքր զրոյին ձգտող

արժեք, ինչը վկայում է տվյալ մոդուլացման տեսակի սպեկտրի սիմետրիկության մասին:

Այսպիսով ՄԱՆ մեթոդի առաջին փուլում ազդանշանի գեներացումից և հիմնական բնութագրող հատկանիշների հաջող առանձնացումից հետո նշված բնութագրերին համապատասխանող տվյալների միջոցով իրականացվում է արհեստական նեյրոնային ցանցի ուսուցանում:

Բարելավված և զարգացված ալգորիթմում անալոգային մոդուլացված ազդանշաններից առանձնացված երեք հիմնական բնութագրերի դեպքում ընտրվել է արհեստական նեյրոնային ցանցի 3-6-6-3 կառուցվածքը, ինչը նշանակում է որ ցանցը բաղկացած է մեկ մուտքային շերտից, որը բաղկացած է երեք նեյրոններից, երկու թաքնված շերտերից՝ յուրաքանչյուրը կազմված վեցական նեյրոններից և մեկ ելքային շերտից՝ բաղկացած երեք ելքային նեյրոններից: Ուսուցման սկզբում ցանցի բոլոր նեյրոնների կապուղիներին տրվում է պատահական ընտրված կշիռ/գործակից, ինչը իրականացվում է «Random Number» վիրտուալ գործիքի միջոցով (նկ. 4.6): Այս գործիքը պատահականության սկզբունքով գեներացնում է [0-1) միջակայքում գտնվող թիվ [90]:

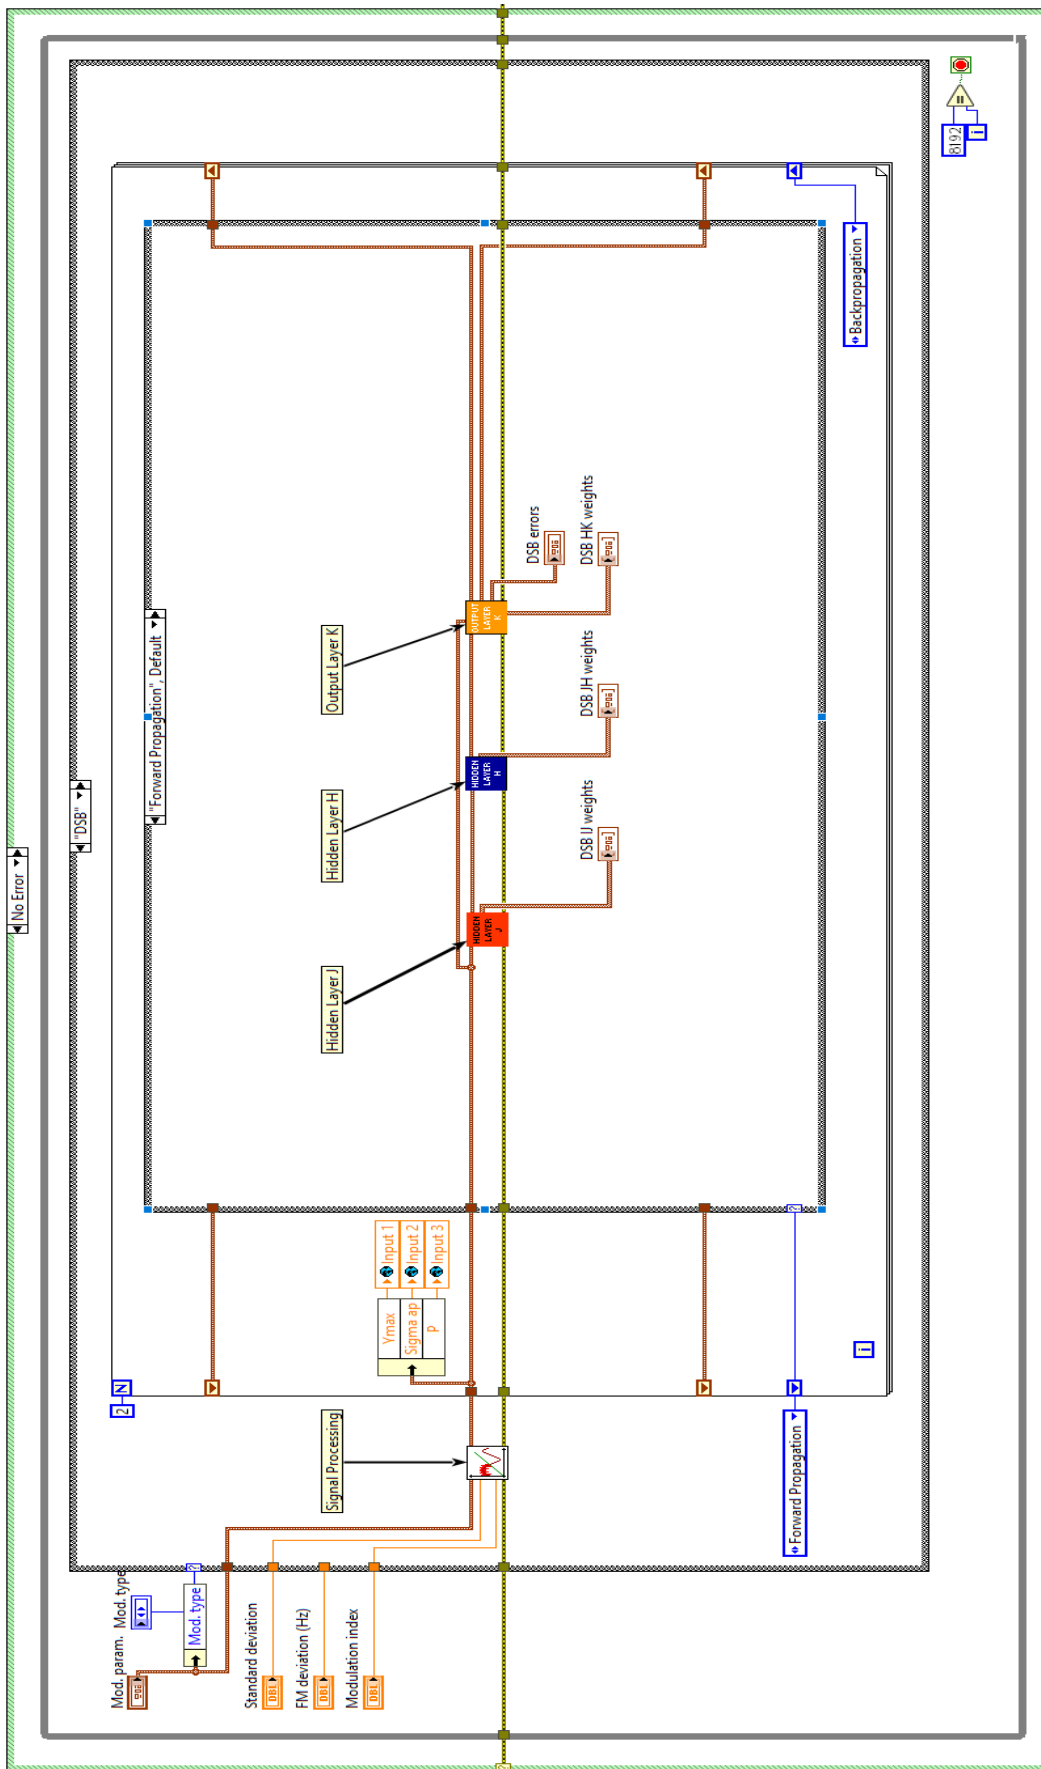


Նկ. 4.6 «Random Number» վիրտուալ գործիք

Ցանցի նեյրոնները մշակվել են «Functional Global Variable» կոչվող կառուցվածքի միջոցով [91]: Այս կառուցվածքը իրենից ներկայացնում է մի այնպիսի վիրտուալ գործիք, որը չգրանցված ռեգիստրների միջոցով դրանց հիշողության մեջ պահպանում է ներմուծված տվյալները:

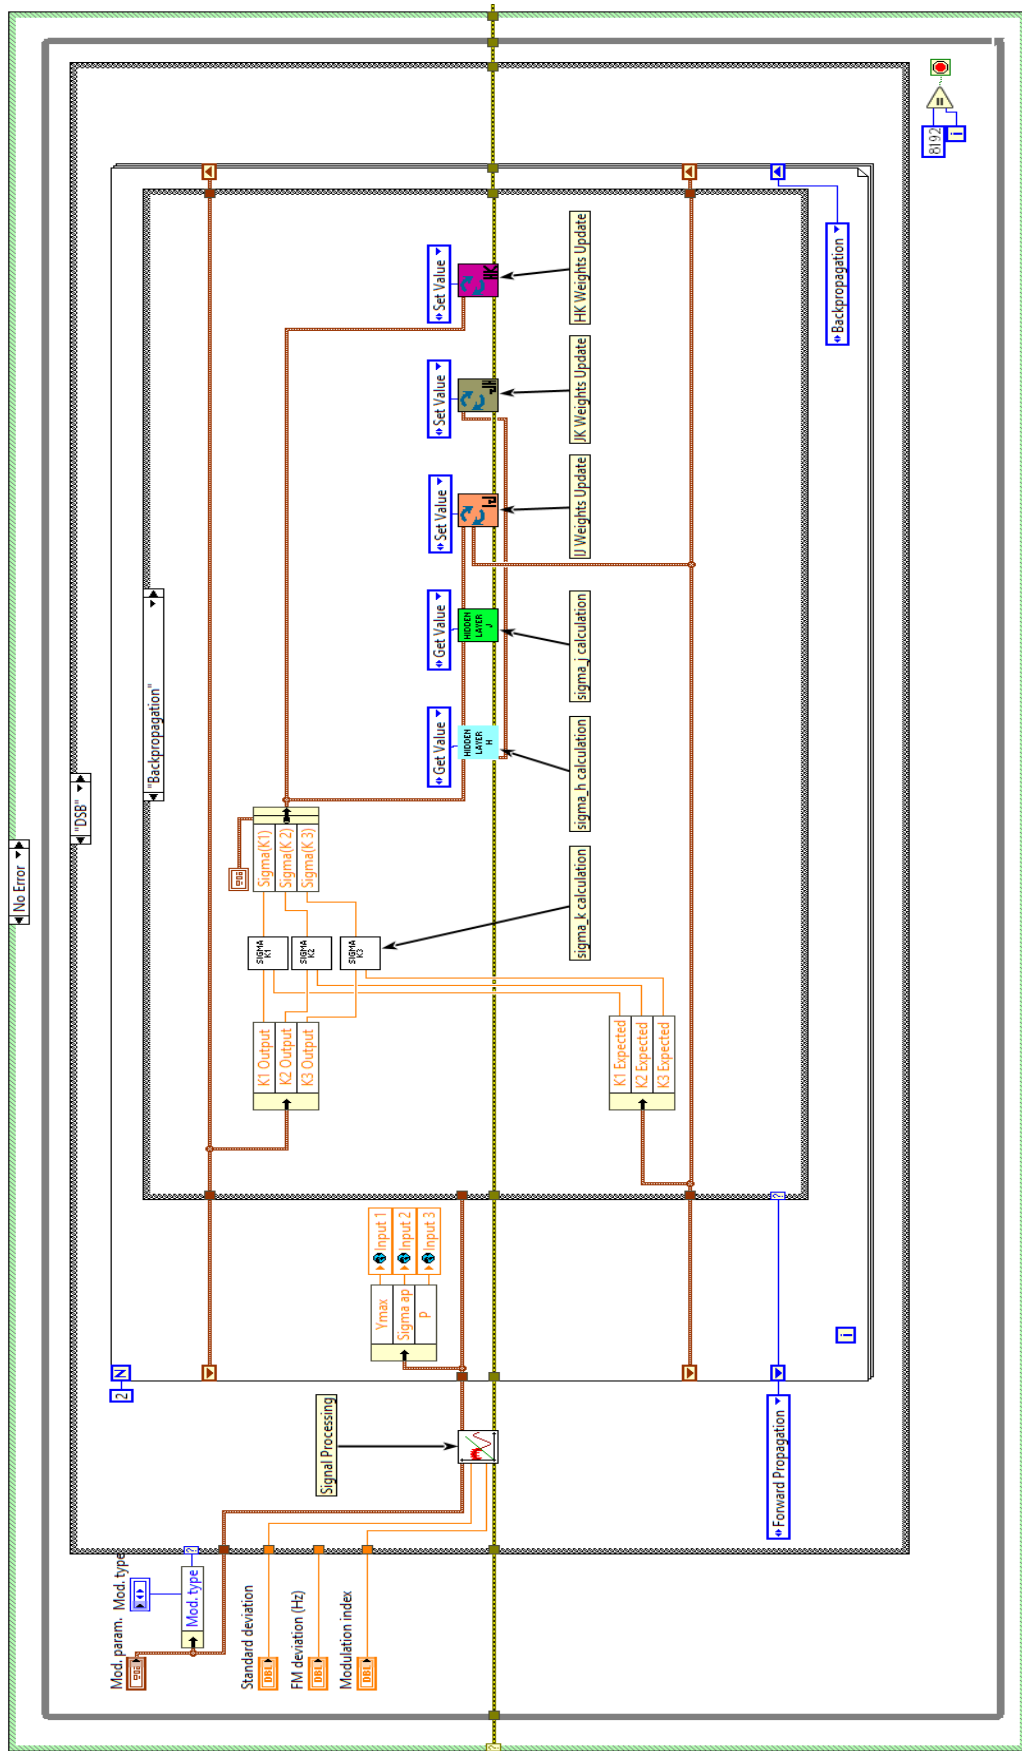
Այսպիսով, կշիռների գեներացումից հետո մուտքային շերտին հաջորդող շերտերի նեյրոնների մուտքերը և ելքերը հաշվարկվում են համապատասխանաբար հավասարումներ (2.9)-ի և (2.10)-ի գործառույթներն իրականացնող ծրագրային ալգորիթմների միջոցով: Մշակված արհեստական նեյրոնային ցանցի ծրագրային կոդը առաջին փուլում հաշվարկներն իրականացնում է առաջընթացի ռեժիմում՝ ելքային շերտի նեյրոններից յուրաքանչյուրի համար ստանալով համապատասխան արժեքներ: Այդ արժեքները համեմատվում են սկնկալվող արժեքների հետ և դրանց

տարբերությունը հաշվարկվում է համապատասխան հավասարում (2.15)-ի: Նկ. 4.7-ում պատկերված է արհեստական նեյրոնային ցանցի մշակված կողի զարգացված և բարելավված տարբերակի առաջընթացի ռեժիմը, որի միջոցով իրականացվել են ն' անալոգային և թվային մոդուլացման տեսակների ուսուցումը՝ վերջիններիս համար նախատեսված հիմնական բնութագրող հատկանիշների միջոցով:



Նկ. 4.7 ԱՆՑ-ի ծրագրային կողի առաջընթացի ռեժիմը

ԱՆՑ էլքային նեյրոնների սխալը հաշվարկելուց հետո ալգորիթմը անմիջապես անցում է կատարում սխալանքի հակադարձ տարածման ռեժիմ: Այստեղ հավասարում (2.24)-ին համապատասխանող ծրագրային կոդի միջոցով իրականացվում է էլքային նեյրոններից յուրաքանչյուրի համար նախատեսված δ_k գործակցի հաշվարկը: Այնուհետև ալգորիթմը հետ անցում է կատարում երկրորդ H թաքնված շերտին, որտեղ նեյրոնները ներմուծում են ուսուցման առաջընթացի ռեժիմում գեներացված և իրենց հիշողության մեջ պահված w_{hk} կշիռների արժեքները և հաշվարկված δ_k գործակիցների և հավասարում (2.25)-ին համապատասխանող ծրագրային ալգորիթմի միջոցով հաշվարկվում են H թաքնված շերտի նեյրոններից յուրաքանչյուրի δ_h գործակիցները: Նույն գործողությունները իրականացվում են նաև հաջորդիվ J թաքնված շերտում և հաշվարկվում են δ_j գործակիցները: Քանի որ, կշիռների թարմացումը բնութագրվում է հավասարումներ (2.18, 2.28-2.30)-ի միջոցով, ապա սիգմա գործակիցների հաշվարկից հետո հաջորդաբար փոփոխվում են բոլոր շերտերի նեյրոնների կապուղիների կշիռները նշված հավասարումներին համապատասխանող կոդի միջոցով: Ինչպես արդեն նշվել է նեյրոնները իրենց մեջ պահպանում են վերջին մուտքագրված տվյալները: Այս պատճառով սխալանքի հակադարձ տարածման ռեժիմում իրականացվող հաշվարկների ավարտից հետո ալգորիթմը կրկին անցում է կատարում առաջընթացի ռեժիմ, որտեղ նոր հաշվարկները իրականացվում են արդեն թարմացված կշիռների արժեքների հիման վրա: Նշված ԱՆՑ-ի ալգորիթմի երկու ռեժիմներին համապատասխանող գործողությունները շարունակվում են այնքան ժամանակ մինչև որ ցանցի էլքային նեյրոնների սխալը կլինի հավասար զրոյի: Քանի որ նման հաշվարկներում սխալի բացարձակ գրոյին հավասարվելու համար հարկավոր է շատ երկար ժամանակ, ապա տվյալ ալգորիթմում ուսուցման ավարտը տրվում է օգտվողի կողմից: ԱՆՑ-ի երկու ռեժիմների գործառույթը ներառված է մեկ օղակման մեջ, որին տրված է պայման դադարել իր գործողությունը այն ժամանակ, երբ վերջինիս կրկնումների քանակը կհավասարվի 8192-ի: Այս թիվը ընտրված է կամայական կերպով և որոշվել է փորձարկումների արդյունքում, քանի որ այդքան կրկնությունների քանակը բավարար է սխալների շատ փոքր արժեքների ստացման համար:



Նկ. 4.8 ԱՆՑ-ի ծրագրային կոդի սխալանքի հակադարձ տարածման ռեժիմը

Նկ 4.8-ում պատկերված է ԱՆՑ-ի սխալանքի հակադարձ տարածման գործառույթն իրականացնող ծրագրային կոդը:

Անալոգային մոդուլացման բոլոր տեսակների համար իրականացվել է ԱՆՑ-ի ուսուցում $SNR=35dB$ դեպքում: Դիտարկված չորս մոդուլացման տեսակներից յուրաքանչյուրի համար ուսուցումը միջինում տևել է 1.98 վարկյան: Աղյուսակ 4.4-ում բերված են յուրաքանչյուր մոդուլացման ուսուցման արդյունքում ստացված ԱՆՑ-ի սխալների չափերը:

Աղյուսակ 4.4. ԱՆՑ-ի ուսուցման արդյունքները անալոգային մոդուլացումների համար

Ներքոնի №	DSB	LSB	USB	FM
k_1	6.25296E-13	1.60281E-14	5.41212E-9	1.05123E-13
k_2	4.77346E-13	2.39505E-20	8.01069E-11	2.66709E-13
k_3	5.36926E-5	2.67953E-21	0.377353	5.04831E-7

Ինչպես երևում է վերոնշյալ աղյուսակում բերված տվյալներից արհեստական ներքոնային ցանցի ուսուցումը գերազանց է անցել բոլոր ուսուցանվող մոդուլացման տեսակների համար բացի USB տեսակից: Սա պայմանավորված է այն հանգամանքով, որ USB մոդուլացման դեպքում ազդանշանի սպեկտրի համաչափությունը բնութագրող հատկանիշի՝ P-ի արժեքը շատ մոտ է (-1)-ին, ինչն էլ դժվարություն է առաջացնում մշակված ցանցի համար: Կարելի է եզրակացնել, որ մշակված մեթոդի միջոցով ԱՆՑ-ը ընդամենը 7.94 վարկյանում ուսուցանվել է նույնականացնել չորս տարբեր անալոգային մոդուլացման տեսակներ: Հարկ է նշել, որ այս արդյունքները գրանցվել են ԱՆՑ-ի պարզ ծրագրային կոդի ավտորիթմի միջոցով:

Ինչպես արդեն նշվել է ուսուցման ավարտից հետո ձեռք բերված ցանցի կշիռների համադրությունների տվյալները պահպանվել են համապատասխան ֆայլերի մեջ, որոնց միջոցով հաջորդիվ իրականացվել է մշակված մեթոդի թեստավորում: Դիտարկված անալոգային մոդուլացման տեսակներից յուրաքանչյուրի համար իրականացվել է 100 նույնականացման փորձ: Հարկ է նշել, որ ուսումը իրականացվել է մեկ պարամետրերի համադրության դեպքում գեներացված ազդանշանից առանձնացված հիմնական բնութագրող հատկանիշների համար: Մինևույն ժամանակ, մեթոդի նույնականացման

ճշտությունը չափելու համար փորձերի ժամանակ կիրառվել են մոդուլացման տարբեր պարամետրեր, ինչպիսիք են կրող հաճախականությունը, SNR-ը, մոդուլացման խորությունը, հաճախականային դեվիացիան, դիսկրետացման հաճախությունը: Իրականացված փորձերի արդյունքները բերված են աղյուսակ 4.5-ում:

Աղյուսակ 4.5 Անալոգային մոդուլացման տեսակների նույնականացման ճշտության արդյունքները

SNR	DSB, %	LSB, %	USB, %	FM, %
Inf.	100	100	100	100
20 dB	100	100	100	100
15 dB	100	100	100	100
10 dB	100	100	100	100
5 dB	100	100	100	100

Ինչպես երևում է աղյուսակ 4.5-ում բերված արդյունքներից մշակված մեթոդի միջոցով հնարավոր է եղել հասնել անալոգային մոդուլացման տեսակների ավտոմատացված նույնականացման գերացանց արդյունքների: Նույնականացումը համակարգչային մակարդակի վրա յուրաքանչյուր մոդուլացման տեսակի համար միջինում իրականացվել է 0.9 վարկյանում: Հաշվի առնելով, որ մշակված և հետազոտված մեթոդի շրջանակներում մշակված ծրագրային կողմ բավականին պարզ է և չի ներառում իր մեջ բարդ մաթեմատիկական հաշվարկներ, և, որ ուսուցանումը յուրաքանչյուր մոդուլացման տեսակի համար իրականացվել է մեկ անգամ, ապա կարելի է գրակացնել, որ մշակված մեթոդը բավականին արդյունավետ է և ճշգրիտ անալոգային մոդուլացման տեսակների նույնականացման համար:

4.3 Թվային մոդուլացման տեսակների նույնականացումը

Թվային մոդուլացման տեսակների համար նույնականացումը իրականացվել է միննույն կողմի միջոցոց, ինչը կիրառվել է և նկարագրված է անալոգային մոդուլացման տեսակների նույնականացման համար: Թվային BPSK, QPSK, 8PSK, 2FSK, 4FSK, 2ASK, 4ASK, 16 QAM, 32QAM և 64QAM տասը մոդուլացման տեսակների համար կիրառվել է ԱՆՑ-ի 5-10-10-5 կառուցվածքը, քանի որ թվային մոդուլացված ազդանշանների նույնականացման համար մշակված բնութագրող հատկանիշները թույլ են տվել նախատեսված ութ հիմնական բնութագրերի փոխարեն կիրառել չորսը: Հետևաբար

ԱՆՑ-ի ուսուցանումը իրականացվել է 10 մոդուլացման տեսակների համար, որոնցից յուրաքանչյուրի ուսուցումը միջինում տևել է 1.54 վարկյան: Դիտարկված թվային մոդուլացման տեսակներից յուրաքանչյուրի համար իրականացված ԱՆՑ-ի ուսուցման վերջնական էլքային նեյրոնների սխալների արժեքները բերված է աղյուսակ 4.6-ում:

Աղյուսակ 4.6. ԱՆՑ-ի ուսուցման արդյունքները թվային մոդուլացումների համար

Մոդուլացման տեսակը	Նեյրոն k_1 -ի սխալը	Նեյրոն k_2 -ի սխալը	Նեյրոն k_3 -ի սխալը	Նեյրոն k_4 -ի սխալը
2ASK	5.26791E-5	1.61978E-13	1.04256E-5	7.74495E-12
4ASK	5.78268E-5	1.3514E-14	1.28472E-5	3.10897E-13
2FSK	4.94698E-5	4.77408E-5	6.34916E-12	1.82986E-11
4FSK	4.93781E-5	4.25943E-5	3.66833E-12	1.11873E-12
BPSK	5.23306E-5	2.53416E-14	3.30797E-11	3.30017E-11
QPSK	5.23398E-5	1.63612E-13	1.06268E-11	1.15514E-11
8PSK	5.30139E-5	2.46347E-13	8.77881E-11	5.91559E-11
16QAM	5.07723E-5	7.9816E-13	5.04549E-13	8.88915E-15
32QAM	5.30489E-5	8.15575E-15	8.76266E-12	9.32344E-16
64QAM	5.0543E-5	4.19937E-14	3.04331E-12	2.16426E-11

Աղյուսակ 4.6-ում բերված տվյալներից երևում է, որ ԱՆՑ ուսուցանման արդյունքում թվային մոդուլացման տեսակների համար ստացվել են շատ փոքր սխալի արժեքներ, ինչը վկայում է այն մասին, որ ուսուցանումը հաջող է անցել: Կարելի է եզրակացնել, որ մշակված մեթոդի միջոցով ԱՆՑ-ը ընդամենը 10.14 վարկյանում ուսուցանվել է նույնականացնել տաս տարբեր թվային մոդուլացման տեսակներ:

Դիտարկված թվային մոդուլացման տեսակներից յուրաքանչյուրի համար իրականացվել է 100 նույնականացման փորձ, ինչի արդյունքները ներկայացված են աղյուսակ 4.7-ում:

Աղյուսակ 4.7 Թվային մոդուլացման տեսակների նույնականացման ճշտության արդյունքները

Մոդուլացման տեսակը	SNR=20dB	SNR=15dB	SNR=10dB	SNR=5dB
2ASK, %	100	100	99	98
4ASK, %	100	100	98	99
2FSK, %	100	100	97	97
4FSK, %	100	100	99	98
BPSK, %	100	100	100	99
QPSK, %	100	100	100	99
8PSK, %	100	100	100	98
16QAM, %	100	100	99	97
32QAM, %	100	100	98	95
64QAM, %	100	100	98	93

Աղյուսակ 4.7-ում ներկայացված ԱՆՑ-ի նույնականացման ճշտության արդյունքներից երևում է, որ SNR=20dB և SNR=15dB դեպքում ԱՆՑ-ի նույնականացման արդյունքները անթերի են: Ճշտությունը սկսել է նվազել SNR=10dB պարագայում և ամենից ցածր տոկոսային արժեքը գրանցվել է 64QAM մոդուլացման տեսակի համար՝ SNR=5dB դեպքում: Հարկ է նշել, որ վերոնշյալ արդյունքները ստացվել են ԱՆՑ-ի սահմանափակ ուսուցանման պարագայում, այսինքն ԱՆՑ-ը յուրաքանչյուր մոդուլացման տեսակը համար ուսուցանվել է մեկ անգամ:

Այսպիսով՝ կատարված փորձարարական աշխատանքների արդյունքում թվային մոդուլացման տեսակների նույնականացումը յուրաքանչյուր թվային մոդուլացման տեսակի համար իրականացվել է 0.77 վարկյանում և ստացվել են ճշգրիտ արդյունքներ: Քանի որ յուրաքանչյուր մոդուլացման տեսակի համար ԱՆՑ-ի մեկական ուսուցանում է իրականացվել, ապա կարելի է մեծացնել արդյունքների ճշտությունը ավելացնելով ուսուցանումների քանակը՝ ցանցի մուտքին տալով տարբեր SNR-ների պարագայում գեներացված ազդանշաններից առանձնացված հիմնական բնութագրող հատկանիշների արժեքները:

ԵԶՐԱԿԱՑՈՒԹՅՈՒՆ

Հեռահաղորդակցական ցանցերում կապի խանազրումներ առաջացնող, առանց համապատասխան ռադիոհաճախականության օգտագործման թույլտվության հաղորդվող, ռադիոէլեկտրոնային պատերազմի շրջանակներում կարևոր նշանակություն ունեցող անհայտ ազդանշանների հայտնաբերումը կարևորագույն խնդիր է առկա ռադիոկապի համակարգերի համար: Նշված խնդրի լուծումներից մեկը անհայտ ազդանշանի մոդուլացման տեսակի նույնականացումն է: Սույնատենախոսության նպատակն է մշակել թվային և անալոգային մոդուլացման տեսակների ավտոմատացված գուգահեռ նույնականացման մեթոդ, որը թույլ կտա իրական ժամանակում իրականացնել հեռահաղորդակցական ազդանշանների նույնականացման գործառույթը: Սույն աշխատանքի հիմքում ընկած խնդրի իրականացման արդյունքում ստացվել են հետևյալ եզրակացությունները և արդյունքները:

1. Յուրաքանչյուր մոդուլացման տեսակ ունի իր առանձնահատկությունը նկարագրող ֆիզիկական բնութագրեր, որոնք ճշգրիտ մշակված հավասարումների միջոցով կարող են հաշվարկվել և կիրառվել մոդուլացումների նույնականացման համակարգերում որպես ազդանշանների հիմնական բնութագրող հատկանիշներ: Հնարավոր է, որ երկու տարբեր մոդուլացված ազդանշանների համար հիմնական բնութագրերից որոշների հաշվարկման արդյունքում ստացվեն միմյանց շատ մոտ կամ հավասար արժեքներ, բայց գոյություն չունեն այնպիսի երկու մոդուլացման տեսակներ, որոնց համար մշակված բոլոր հիմնական բնութագրող հատկանիշները ունենան միևնույն արժեքները: Այս հանգամանքը թույլ է տալիս առնվազն մեկ բնութագրող հատկանիշի միջոցով տարբերակել երկու մոդուլացման տեսակները:

2. Մշակվել են թվային M-PSK, M-QAM մոդուլացման տեսակների նույնականացման համար նախատեսված հիմնական բնութագրող հատկանիշներ, որոնք հնարավորություն են տվել մեծ ճշտությամբ տարբերակել նշված մոդուլացման տեսակները: Այս բնութագրերի մշակման արդյունքում պարզվել է, որ դրանք կարելի է նաև կիրառել այլ թվային մոդուլացման տեսակների նույնականացման համար, քանի որ դրանք կատարում են նաև այդ տեսակների նույնականացման համար նախկինում

մշակված և լայն կիրառություն ունեցող հիմնական բնութագրերի գործառույթը: Այսպիսով մշակված բնութարերի միջոցով թվային տասը մոդուլացման տեսակների նույնականացման համար նախատեսված ութ բնութագրերի փոխարեն կիրառվել են չորսը, ինչը հնարավորություն է տվել օպտիմալացնել կիրառվող բնութագրող հատկանիշները և խուսափել լրացուցիչ հաշվարկներից:

3. Իրականացվել է ՄԱՆ համար կիրառվող տվյալների նույնականացման տեխնոլոգիաների հետազոտություն և համեմատական վերլուծություն, ինչի արդյունքում որոշվել է տվյալ աշխատանքի համար նպատակահարմար, իրագործելի և արդյունավետ տեխնոլոգիան: Կատարված վերլուծության շրջանակներում նկարագրվել են ՄԱՆ խնդրի լուծման համար օգտագործվող բոլոր տեխնոլոգիաների առավելությունները և թերությունները, ինչը հետագա աշխատանքներում կարող է հիմք հանդիսանալ տվյալների նույնականացման տեխնոլոգիայի ընտրության համար:

4. Ծրագրավորման LabVIEW միջավայրում մշակվել է տվյալների նույնականացման տեխնոլոգիայի՝ արհեստական նեյրոնային ցանցի ծրագրային կոդը, որի համար առաջարկվել է նույնականացման գործընթացի արդյունքում վերջնական որոշման կայացման նոր մեթոդ: Այս մեթոդը հնարավորություն է տվել խուսափել լրացուցիչ հաշվարկներից, ինչը արդյունավետ լուծում է հանդիսացել մշակված ծրագրային կոդի համար:

5. Արհեստական նեյրոնային ցանցի միջոցով մոդուլացման տեսակների նույնականացման նպատակով անալոգային և թվային մոդուլացման տեսակների համար իրականացվել է մշակված ցանցի ուսուցանում, որը համապատասխանաբար տևել է 7.94 և 10.14 վարկյան: Հետևաբար մշակված ցանցը սովորել է տարբերակել չորս անալոգային մոդուլացման տեսակներ ընդամենը 7.94 վարկյանում և տասը թվային մոդուլացման տեսակներ՝ 10.14 վարկյանում:

6. Մշակվել է անալոգային և թվային մոդուլացման տեսակների զուգահեռ նույնականացման մեթոդի ծրագրային կոդը, որի միջոցով ստացվել են նույնականացման ճշգրիտ աղբյուրներ: Անալոգային մոդուլացման տեսակների համար SNR=5dB պարագայում ստացվել է 100% նույնականացման ճշտություն, իսկ թվային մոդուլացման տեսակների համար SNR=5dB դեպքում ամենացածր

նույնականացման ճշտությունը ստացվել է 93%՝ 64QAM մոդուլացման տեսակի համար:
Թվային մոդուլացման մյուս տեսակների համար SNR=5dB պարագայում
նույնականացման ճշտությունը միջինում կազմում է 97.7%:

Գրականության ցանկ

1. S.M. Musa, Zh. Wu, Aeronautical Telecommunications Network: Advances, Challenges, and Modeling, 1st Edition, CRC Press, 2015, p. 290
2. K. Rheuban, E. A. Krupinski, Understanding Telehealth, 1st Edition, McGraw-Hill Education / Medical, 2017, p. 336
3. D.M. Marshall, R.K. Barnhart, E. Shappee, M.T. Most, Introduction to Unmanned Aircraft Systems, 2nd Edition, CRC Press, 2016, p. 395
4. O. Vermesan, M. Eisenhauer, H. Sundmaeker, P. Guillemin, M. Serrano, E. Tragos, J. Valiño, V. Valiño, A. Derwees, A. Gluhak, B. Roy. 3 Internet of Things Cognitive Transformation Technology Research Trends and Applications, 2017, p. 96.
5. X. Zhang, Y. Liu, Y Wang, J. Bai, Performance analysis and optimization for non-uniformly deployed mmWave cellular network, EURASIP Journal on Wireless Communications and Networking, 2019, p. 15
6. S. Mathad, Sunil, C. Vijaya, “Modified Automatic Digital Modulation Recognizer for Software Defined Radio”, Microelectronics, Electromagnetics and Telecommunications, p. 433-442
7. Salam, R. Sheriff, S. Al-Araji, K. Mezher, Automatic Modulation Classification in Cognitive Radio Using Multiple Antennas and Maximum-Likelihood Techniques, Conference: 15th IEEE International Conference on Computer and Information Technology, Liverpool, UK, 2015, p. 5
8. E.E. Azzouz, A.K. Nandi, “Automatic Modulation Recognition of Communication Signals”, Dordrecht: Kluwer Academic Publishers, 1996. – 214 p.
9. P.M. Fabrizio, L.B. Lopes, G.B. Lockhart, “Receiver recognition of analogue modulation types,” IERE Conference on Radio Receiver and Associated Systems, Bangor, Wales, 1986, pp. 135-140
10. Y.O. Al-jalili, “Identification algorithm for upper and lower sideband SSB signals,” Signal Processing, Vol. 42, No. 2, March 1995, pp. 207-213

11. B.I. Dahap, H.I. Ahmed, New Algorithms for Automatic Modulation Recognition for Analogue Signals Using Multi Features, *International Journal of Signal Processing Systems* Vol. 2, No. 2, 2014, p. 144-148
12. F. F. Liedtke, "Computer simulation of an automatic classification procedure for digitally modulated communication signals with unknown parameters", *Signal Processing*, Vol. 6, No. 4, August 1984, pp 311-323
13. K. Alssaleh, K. Farrell, R.J. Mammone, "A new method of modulation classification for digitally modulated signals," *MELCOM 92, Communication, Fusing, Command, Control, and Intelligence*, October 1992. Pp 30.5.1-30.5.5.
14. M. H. Valipour, Automatic digital modulation recognition in presence of noise using SVM and PSO, *Sixth International Symposium on Telecommunications (IST)*, 2012, p. 378-382
15. Martin, "A signal analysis and classification strategy for implementation in an EW communication receiver," *Fifth International Conf. on Radio Receiver and Associated Systems*, July 1990, pp. 222-226
16. L.V. Dominguez, J.M. Borrallo and J.P. Garcia, "A general approach to the automatic classification of radio communication signals," *Signal Processing*, Vol. 22, No. 3, March 1991, pp. 239-250
17. T. Sun, J. Jia, G. Yu, Automatic modulation recognition of both digital and analog communication signals, *International Conference on Electrical, Mechanical and Industrial Engineering*, Atlantis Press, 2016, p. 154-156
18. M.L.D. Wong, A.K. Nandi. "Automatic digital modulation recognition using artificial neural network and genetic algorithm", *Signal Processing* 84, 2004, pp 351-365
19. K. Hassan, I. Dayoub, W. Hamouda, and M. Berbineau. "Automatic modulation recognition using wavelet transform and neural networks in wireless systems", *EURASIP Journal on Advances in Signal Processing*, 2010, p. 13
20. Ch. Mei, Zh. Qi, "Cooperative automatic modulation recognition in cognitive radio", *The Journal of China Universities of Posts and Telecommunications*, Vol. 17(2), April 2010, pp 46-52

21. K.F. Fatima, "Digital modulation classification using wavelet transform and artificial neural network", *Journal of Zankoy Sulaimani*, Vol. 13(1), 2010, pp 59-70
22. Sh. Almaspour, M. R. Moniri, "Automatic modulation recognition and classification for digital modulated signals based on ANN algorithms", *Journal of Multidisciplinary Engineering Science and Technology*, Vol. 3 Issue 12, 2016, p. 6230-6235
23. С.С. Аджемов, Н.В. Кленов, М.В. Терешонок, Д.С. Чиров, «Методы распознавания видов цифровой модуляции сигналов в когнитивных системах», ВМУ, Серия 3, Физика.Астрономия, Н. 6, 2015, с. 19-27
24. O.A. Dobre, A. Abdi, Y. Bar-Ness, W. Su, "A Survey of Automatic Modulation Classification Techniques: Classical Approaches and New Trends", *IEEE Journal on Selected Areas in Communications*, 2000, p. 42
25. А.М. Тантушян, Методы автоматического распознавания модуляций и их сравнительный анализ // *Известия НАН РА и НПУА. Серия Техн. науки.* – 2018. – Т. – 71, N 2., С. 195-202
26. H. L. P. Kumar, L. Shrinivasan, "Automatic Digital Modulation Recognition System Using Feature Extraction", *Emerging trends in electrical, communications and information technologies*, Vol. 394, Singapore, 2017, pp. 201-208
27. Yu Zaihe, "Automatic modulation classification of communication signals", August, 2006, P. 231
28. N. Ahmadi, R. Berangi, "A Template Matching Approach to Classification of QAM Modulation using Genetic Algorithm", *Signal Processing: An International Journal (SPIJ)*, Vol. 3: Issue 5, 2009, p. 95 – 109
29. T. Evren, H. Celebi, H. Arslan, "A joint modulation identification and frequency offset correction algorithm for QAM systems", 2009, p. 6
30. <http://www.hpl.hp.com/hpjournal/94dec/dec94a6.pdf>
31. L. Hong and K. C. Ho, "Identification of digital modulation types using the wavelet transform," *MILCOM 1999. IEEE Military Communications. Conference Proceedings (Cat. No.99CH36341)*, Atlantic City, NJ, 1999, pp. 427-431

32. Hossen, F. Al-Wadahi, "A Two-Stage Network for Modulation Classification Based on Entropy of Wavelet Transform", 3rd International Conference: SETIT, Tunisia, 2005, p 5
33. K. Hassan, I. Dayoub, W. Hamouda, M. Berbineau, "Automatic Modulation Recognition Using Wavelet Transform and Neural Networks in Wireless Systems", EURASIP Journal on Advances in Signal Processing, 2010, p. 13
34. F. K. Faek, "Digital Modulation Classification Using Wavelet Transform and Artificial Neural Network", Journal of Zankoy Sulaimani, 2010, 13(1) Part A, pp 59 – 70
35. X. Z. Feng, J. Yang, F. L. Luo, J. Y. Chen, X. P. Zhong, "Automatic Modulation Recognition by Support Vector Machines Using Wavelet Kernel", Journal of Physics: Conference Series 48, 2006, pp. 1264 - 1267
36. M. Walencykowska, A. Kawalec, "Type of modulation identification using Wavelet Transform and Neural Networks", BULLETIN OF THE POLISH ACADEMY OF SCIENCES TECHNICAL SCIENCES, Vol. 64, No. 1, 2016, p. 257-261
37. Y. Liua, X. Guo, "Modulation recognition based on wavelet transform and fractal theory", Volume 15, Number 3, March 2019, pp. 998-1004
38. <https://numato.com/kb/learning-fpga-verilog-beginners-guide-part-1-introduction/>
39. http://zone.ni.com/reference/en-XX/help/372656C-01/lvasptconcepts/wa_overview/
40. B. Boser, I. Guyon, V. Vapnik, "A Training Algorithm for Optimal Margin Classifier", Proceedings of the Fifth Annual ACM Workshop on Computational Learning Theory, Vol. 5, 1996, pp 144 – 152
41. Q. Ren, G. Sun, Y. Zhang, "Modulation Mode Recognition Based On Multi-Class Classification of Support Vector Machine", Proceedings of the 2013 International Conference on Software Engineering and Computer Science, 2013, pp 150 - 154
42. Z. Xin, W. Ying, Y. Bin, "Signal Classification Method Based on Support Vector Machine and High-Order Cumulants", Wireless Sensor Network, issue 2, 2010, pp. 48-52
43. https://en.wikipedia.org/wiki/Hinge_loss
44. Zh. Zhao, Yu. Zhou, F. Mei, Ji. Li, Automatic Modulation Classification by Support vector Machines, International Symposium on Neural Networks, Advances in Neural Networks, 2004, p. 654-659

45. M. Keshk, E. Elrabie, F. El-Samie and M. El-Naby, "Blind Modulation Recognition in Wireless MC-CDMA Systems Using a Support Vector Machine Classifier," *Wireless Engineering and Technology*, Vol. 4 No. 3, 2013, p. 145-153
46. E. Shermeh, R. Ghazalian, Recognition of communication signal types using genetic algorithm and support vector machines based on the higher order statistics, *Elsevier Digital Signal Processing*, vol. 20, Issue 6, 2010, p. 1748-1757
47. Sh. Abe, "Support vector machines for pattern classification", Springer-Verlag, London, 2005, P. 344
48. А.Г. Гулян, О.Ж. Севоян, А.М. Тантушян, Искусственные нейронные сети и их применение в автоматическом распознавании модуляций // *Известия НАН РА и НПУА. Серия Тех. Науки.* - 2017. - Т. 70, №3. - С. 358-365.
49. McCulloch W.S., Pitts W. A logical calculus of the ideas immanent in nervous activity // *Bulletin of mathematical biophysics* - Chicago, 1943. – Vol. 5. – P. 115-133.
50. N.T. Carnevale, M.L. Hines, *The Neuron*, Cambridge University Press, 2006, p. 480
51. D.O. Hebb, *The Organization of Behavior: A Neuropsychological Theory.* - New York: John Wiley and Sons, Inc., 1949. - 335 p.
52. Rosenblatt F. *Principles of neurodynamics // Perceptions and the theory of brain mechanism.* - Washington, DC: Spartan Books, 1961. - 260 p.
53. <http://www.nestor.minsk.by/kg/2000/45/kg04514.html>
54. Yaqin Z., Guanghui R., Xuexia W., Zhilu W., Xuemai G. Automatic digital modulation recognition using artificial neural networks // *Neural Networks and Signal Processing.* - China, 2003. - Vol. 1. - P. 257–260.
55. Wong M.L.D., Nandi A.K. Automatic digital modulation recognition using artificial neural network and genetic algorithm // *Signal Processing.* - Liverpool, UK, 2004. - N 84. – P. 351 – 365.
56. Hassan K., DayouI. B, Hamouda W., Berbineau M. Automatic Modulation Recognition Using Wavelet Transform and Neural Networks in Wireless Systems // *EURASIP Journal on Advances in Signal Processing.* - Cairo, Egypt, 2010. – Vol. 2010, Article ID 532898. - 13 p.

57. J. Jagannath et al., "Artificial Neural Network Based Automatic Modulation Classification over a Software Defined Radio Testbed," 2018 IEEE International Conference on Communications (ICC), Kansas City, MO, 2018, pp. 1-6
58. Y. Ettetfagh, M. H. Moghaddam and S. Eghbalian, "An adaptive neural network approach for automatic modulation recognition," 2017 51st Annual Conference on Information Sciences and Systems (CISS), Baltimore, MD, 2017, pp. 1-5
59. А.М. Тантушян, Извлечение и расчет ключевых характеристик сигнала для классификации аналоговых модуляций, Вестник РАУ: Физико-математические и естественные науки, 2018, N 2, С. 64-76
60. А.Г. Гулян, О.Ж. Севоян, А.М. Тантушян, Ключевые характеристики цифровых сигналов для автоматического распознавания вида манипуляций телекоммуникационных сигналов// ВЕСТНИК ИНЖЕНЕРНОЙ АКАДЕМИИ АРМЕНИИ. Сборник научно-технических статей. - 2018. - Т. 15, №4. - С. 602-605.
61. А. А. Харкевич, Основы радиотехники, Государственное издательство литературы по вопросам связи и радио, Москва, (1962)
62. <http://www.dsplib.ru/content/ssb/ssb.html>
63. <http://www.ni.com/ru-ru/shop/labview.html>
64. <http://sine.ni.com/nips/cds/view/p/lang/ru/nid/210568>
65. http://zone.ni.com/reference/en-XX/help/371361P-01/glang/complex_to_polar/
66. S. W. Smith, The Scientist & Engineer's Guide to Digital Signal Processing, California Technical Publishing, 1999, p. 646
67. Крухмалев В. В., Гордиенко В. Н., Моченов А. Д. и др. Основы построения телекоммуникационных систем и сетей. 2-е изд., испр. -М.: Горячая Линия-Телеком, 2008.- 424 с.
68. Бернارد Скляр. «Цифровая связь. Теоретические основы и практическое применение (2)». Издательский дом "Вильямс". – 2003. – Р. 1104
69. J. Leary, P. Roshan, 802.11 Wireless LAN Fundamentals, Cisco Press, 2003, p. 312
70. L. Harte, Introduction to Bluetooth: Technology, Operation, Profiles, and Services, DiscoverNet, 2009, p. 102

71. V.D. Hunt, RFID: A Guide to Radio Frequency Identification, Wiley-Interscience, 2007, p. 240
72. Солонина А.И., Улахович Д.А., Арбузов С.М. Соловьева Е.Б. Основы цифровой обработки сигналов: Курс лекций. Изд. 2-е испр. и перераб.- СПб.: БХВ – Петербург, 2005.- 768 с.
73. V. Meghdadi, BER calculation, Wireless Communications by Andrea Goldsmith, 2008, p. 9
74. M.A. Abu-Rgheff, Introduction to CDMA Wireless Communications, Academic Press, 2007, p. 632
75. Morello, V. Mignone, "DVB-S2: The Second Generation Standard for Satellite Broad-Band Services," in Proceedings of the IEEE, vol. 94, no. 1, 2006, p. 210-227
76. G.L. Frost, Early FM Radio: Incremental Technology in Twentieth-Century America, Johns Hopkins University Press, 2010, p. 208
77. D. Bailey, Practical Radio Engineering and Telemetry for Industry, Australia, 2003, p. 320
78. H. Rohling, OFDM: Concepts for Future Communication Systems (Signals and Communication Technology), Springer, 2011, p. 254
79. T. Manning, Microwave Radio Transmission Design Guide, N 2, Norwood, 2009, p. 280
80. L. Nuaymi, WiMAX Technology for Broadband Wireless Access, West Sussex, 2007, p. 283
81. E. Perahia, Next Generation Wireless LANs: 802.11n and 802.11ac, Cambridge University Press; 2 edition, 2013, p. 478
82. L. Korowajczuk, TE, WiMAX and WLAN Network Design, Optimization and Performance Analysis, Reston, USA, 2011, p. 719
83. V. Fotheringham, Ch. Sharma, Wireless Broadband: Conflict and Convergence (IEEE Series on Digital & Mobile Communication) 1st Edition, Wiley-IEEE Press, 2008, p. 254
84. K. Siwiak, D. McKeown, Ultra-wideband Radio Technology 2nd Edition, Wiley, 2004, p. 264

85. K. Duncan, The Diagrams Book: 50 Ways to Solve Any Problem Visually, LID Publishing, 2014, p. 128
86. http://zone.ni.com/reference/en-XX/help/371361P-01/gmath/histogram_discrete/
87. А.Г. Гулян, О.Ж. Севоян, А.М. Тантушян. Автоматическое распознавание четырех видов симулированных сигналов с помощью искусственной нейронной сети, Известия, том 4, С. 467-471. (2017).
88. R.F. Graf, Oscillator Circuits, Newnes, 1996, p.192
89. R. Rojas, Neural Networks. A systematic introduction. - Berlin, Springer-Verlag, 1996, 247 p
90. А.М. Tantushyan, An algorithm for analog modulation classification, Proceedings of NPUA, Information technologies, electronics, radio engineering, 2018, N 2, p. 95-102
91. http://zone.ni.com/reference/en-XX/help/371361R-01/glang/random_number_0_1/
92. <https://forums.ni.com/t5/Example-Programs/Basic-Functional-Global-Variable-Example/ta-p/3503982>

Հավելված 1

OLYMP Engineering LLC

Հաստատում եմ
«ՕԼԻՄՊ ԷՆՋԻՆԵՐԻՆԳ» ՍՊԸ տնօրեն
Օ.Ժ. Սևոյան
«22» Մարտի 2019 թ.

Արամ Միքայելի Թանթույանի «Հեռահաղորդակցական ցանցերում ազդանշանների մոդուլացման տեսակների նույնականացման մեթոդի մշակումը և հետազոտումը» թեմայով ատենախոսության արդյունքների

ՆԵՐԴՐՄԱՆ ԱԿՏ

ՀՀ ԳԱԱ ՌՖԷԻ 3-րդ կուրսի ասպիրանտ Ա.Ս. Թանթույանի կողմից իր ատենախոսական աշխատանքի շրջանակներում մշակված հեռահաղորդակցական ազդանշանների հիմնական բնութագրերի հաշվարկային կոդը «ՕԼԻՄՊ ԷՆՋԻՆԵՐԻՆԳ» ՍՊԸ կողմից ներդրվել է Հնդկաստանում հեռահաղորդակցական ցանցերում կիրառվող «Blind Demodulator» համակարգերում:

Ա.Ս. Թանթույանի կողմից մշակված ազդանշանների հիմնական բնութագրերի «key feature» կիրառությունը վերոնշյալ համակարգում թույլ է տալիս բարելավել աշխատանքի ճշտությունը:

Օգտագործված հասցավումների ցանկ

IoT – Internet of Things (իրերի համացանց)

SNR – Signal to Noise Ratio (ազդանշան-աղմուկ հարաբերություն)

SDR – Software Defined Radio (ծրագրավորվող ռադիոկապ)

AM – Amplitude Modulation (ամպլիտուդային մոդուլացում)

DSB – Double Sideband (երկու կողային շերտ)

USB – Upper Sideband (բարձր կողային շերտ)

LSB – Lower Sideband (ցածր կողային շերտ)

FM – Frequency Modulation (հաճախականային մոդուլացում)

ASK – Amplitude Shift Keing (թվային ամպլիտուդային մոդուլացում)

PSK – Phase Shift Keying (թվային փուլային մոդուլացում)

FSK – Frequency Shift Keying (թվային հաճախականային մոդուլացում)

QAM – Quadrature Amplitude Modulation (քառակուսային-ամպլիտուդային մոդուլացում)

FPGA - Field Programmable Gate Array

SVM – Support Vector Machine (աջակցող վեկտորային մեքենա)

WLAN – Wireless Local Area Network (անլար լոկալ ցանց)

CDMA – Code Division Multiple Access (կոդի բաժանումը բազմակի մուտքի)

DVB-S - Digital Video Broadcasting-Satellite (թվային արբանյակային տեսահեռարձակում)

BER – Bit Error Rate (բիթերի սխալի հաճախություն)

RFID – Radio Frequency Identification (ռադիոհաճախականային նույնականացում)

OFDM - Orthogonal Frequency Division Multiplexing (օրթոգոնլա հաճախային բաժանում մուլտիպլեքսավորմամբ)

WiMAX- Worldwide Interoperability for Microwave Access

WiBro – Wireless Broadband (անլար լայնաշերտ)

UWB – Ultra Wide Band (զեր լայնաշերտ)

ՄՆ – Մոդուլացումների նույնականացում

ՄԱՆ – Մոդուլացումների ավտոմատացված նույնականացում

ԱՆՑ – Արհեստական նեյրոնային ցանց

ԱՎՄ – Աջակցող վեկտորային մեքենա