

**ВАЗОРАТИ МАОРИФ ВА ИЛМИ ҶУМҲУРИИ ТОЧИКИСТОН
ДОНИШГОҲИ МИЛЛИИ ТОЧИКИСТОН**

ТДУ: 004.5.7.9+519.25+811.21/.22

Бо ҳуқуқи дастнавис

ТБК: 22.18 (2T)

П - 33



ПИРОВ САИДАЛИ МИРЗОАЛИЕВИЧ

**ТАҲИЯ ВА ТАДҚИҚИ КРИТЕРИЯҲОИ МИҚДОРӢ БАРОИ
БАҲОДИҲИИ ХУШОҲАНГИИ КАЛИМАҲОИ ТОЧИКӢ**

А В Т О Р Е Ф Е Р А Т И

диссертатсия барои дарёфти дараҷаи илмии номзади илмҳои техникий
аз рӯи ихтисоси 05.13.11 –Таъминоти математикӣ ва барномавии
мошинҳои ҳисоббарор, мұчтамаъҳо ва шабакаҳои компьютерӣ

Душанбе, 2025

Кори илмӣ дар кафедраи технологияҳои иттилоотӣ ва иртиботии факултети механикаю математикаи Донишгоҳи миллии Тоҷикистон иҷро шудааст.

Роҳбарони илмӣ:

доктори илмҳои физикаю математика,
академики АМИТ, профессор **Усмонов З.Ҷ.**
ва доктори илмҳои техникӣ, дотсенти
кафедраи информатикаи Донишгоҳи
миллии Тоҷикистон Мирзоев С.Ҳ.

Муқарризони расмӣ

Муминов Баҳодир Болтаевич – доктори илмҳои техники, профессор, мудири кафедраи зеҳни сунъии Донишгоҳи давлатии иқтисодии Тошкент, Ҷумҳурии Узбекистон

Ғафуров Миршафӣ Ҳамитович - номзади илмҳои техникӣ, дотсенти кафедраи технологияҳои иттилоотӣ ва ҳифзи маълумоти Донишгоҳи техникии Тоҷикистон ба номи академик М.С. Осимӣ

Муассисаи пешбар

Институти математикаи ба номи А. Ҷӯраеви
АМИТ

Ҳимоя «16» майи соли 2025 соати «14:00» дар ҷаласаи Шурои диссертационии 6D.KOA-049 дар назди Донишгоҳи техникии Тоҷикистон ба номи академик М.С.Осимӣ аз рӯйи нишонии: 734042, ш. Душанбе, хиёбони академикҳо Раҷабовҳо, 10 баргузор мегардад.

Бо диссертатсия дар Китобхонаи марказии Донишгоҳи техникии Тоҷикистон ба номи академик М.С.Осимӣ ва тавассути сомонаи <http://ttu.tj> шинос шудан мумкин аст.

Автореферат «__» соли 2025 мувофиқи феҳристи тасдиқшуда фиристонда шуд.

Котиби илмии Шурои диссертационии
6D.KOA-049, номзади илмҳои
техникӣ, дотсент



Султонзода Ш.М.

Муқаддима

Мубрамияти мавзуи таҳқиқот. Таърих гувоҳ аст, ки дар ҳар давру замон олимону муҳаққиқон ба масъалаи покизагии забон, диққати маҳсус додаанд ва имрӯз ҳам ин масъулияти асосиро идома додаистодаанд. Ҳифзи забон аз нуқсонҳои гуногуни зоҳирӣ, хусусан ҳамнишиниву ноҷурии овозҳои таркиби калима муҳимтарин вазифаи ҳар як фарди чомеа аз ҷумла эҷодкорону зиёйён буда таъмини форамию покизагии он яке аз талаботҳои хушоҳангӣ дар илми сухансанҷӣ мебошад. Ин нукта ба тафсил дар китоби Пешвои миллат Суҳанҳои ҳикматомӯзи Президент Эмомалӣ Раҳмон дар бораи забон бараъло қайд гардидааст, ҳикмате аз онро ин ҷо овардан айни муддао аст: “Поку беолоиш нигоҳ доштани забон ва асолату шевоии онро ҳифз кардан қарзи фарзандии ҳар яки мову шумост. Бинобарин олимону зиёйёни мо бояд бо таҳқиқи масъалаҳои муҳимтарини забон ва таҷдиду таҳияи қомусу фарҳангномаҳо, ки барои баланд бардоштани сатҳи забондонӣ ва маърифати забономӯзии наслҳои имрӯзу оянда заруранд, ҷиддӣ машғул шаванд”.

Бо пайдо гардидаи аввалин барномаҳои компьютерӣ, андешаи коркард, нигоҳдорӣ, таҳлил, талафуз ва тарҷумаи матнҳо низ ба вучуд омад. Барномаҳои гуногун барои коркарди иттилооти матнӣ таҳия гардидаанд, ки муҳимтарин масъалаҳои илми забоншиносиро ҳал мекунанд. Яке аз масъалаҳои мазкур ин хушоҳангӣ ё хоноии матнҳо ва баҳодиҳии он тавассути компьютер мебошад, ки он барои қисме аз забонҳои дунё ҳали худро пайдо намудааст. Масалан, дар дастаи барномаҳои оффисии Office, ки маҳсули ширкати Microsoft мебошад, афзоре мавҷуд аст, ки омори муносибхонии матнро пешниҳод мекунад ва ғайр аз баҳодиҳии хониши осон ва ҳисоб кардани миқдори калимаҳои душворталафғуз, инчунин қобилияти арзёбӣ кардани хушоҳангиро низ дорад.

Калима, ибора ва ё матне хушоҳанг номида мешавад, ки агар дар таркиби он ҳамсадоҳои нодир, якмаҳрача ё маҳрачи наздик набошанд. Дар таркиби калимаҳои хушоҳанг садонокҳо нисбат ба ҳамсадоҳо бештар буда, то се ҳичои қушодро дошта метавонанд. Баҳри ҳифз намудани покизагию хушоҳангии забони тоҷикӣ аз душворталафғузӣ, таноғурот ва чигилий зарур аст, ки аз тамоми роҳу воситаҳо, хусусан аз технологияҳои иттилоотии муосир, истифода карда меъёр, амсилаи математикий ва системаҳои компьютерии маҳсус таҳия карда шаванд. Таҳқиқоти мазкур асосан ба таҳияи асосҳои системаи шинохти ҳудкори хушоҳангии калимашаклҳои тоҷикӣ равона гардидааст, ки асоси онро γ -таснифгар ташкил медиҳад.

Гарчанде, ки меъёрҳои хушоҳангӣ дар баъзе забонҳо ба расмият дароварда нашудаанд, вале онҳо мавҷуд мебошанд. Масалан, муҳимтарин меъёрҳои хушоҳангии матн: соҳтори ҳичо, таносуби овозҳои пасту баланд, саҳми ҳамсадоҳои сонорӣ, овозҳои хуштакиу шавшувдор ва якҷояшавии ҳамсадоҳо ба ҳисоб мераванд. Масъалаи хушоҳангии матн масъалаи хеле мураккаб буда, ҳатто одамони як минтақа метавонанд, ки дар бораи зебогии нутқ фаҳмиши гуногун дошта бошанд. Ин ҷо омилҳои зиёдеро ба ҳисоб

гирифтан зарур аст, ки дар асоси онҳо пойдевори фаҳмиши ҳар як инсон дар алоҳидагӣ сохта мешавад. Гайр аз ин, як қатор хусусиятҳое низ мавҷуд аст, ки онҳо сифати иттилооти ин ё он сарчашмаро ҳалалдор мекунанд (масалан, дар матн метавонад ҳуруф, дар китоб сифати қоғаз, дар нутқ бошад овоз ва оҳанг).

Дараҷаи таҳқиқи мавзуи илмӣ. Сарчашмаҳо нишон медиҳанд, ки аввалин шуда мутафаккирони Юнони қадим сухангӯи суҳансанчиро шурӯъ намуда, онро мавриди омӯзишу баррасӣ қарор додаанд. Асари “Риторика” (Суҳанварӣ) – и Арасту далели равшани ин гуфтаҳо мебошад. Дар хусуси масъалаи покизагии забон мутафаккирони машриқзамин аз қабили Абӯалӣ ибни Сино, Шамс Қайси Розӣ, Асадии Тӯсӣ, Шамси Гургонӣ, Т. Зехнӣ, Х. Шарифов, М. Шукуров, Б. Камолиддинов ва дигарон корҳои зиёдеро анҷом додаанд, ки муҳимтарин сарчашмаҳои омӯзиши паҳлуҳои гуногуни масъалаи мазкур ба ҳисоб мераванд.

Аз оғози асри гузашта то имрӯз хусусиятҳои гуногуни фонетикаи забони адабии ҳозираи тоҷикиро олимони машҳури ин соҳа И.И. Зарубин, Л. Бузургзода, В.С.Соколова, В.С. Растворгуев, Ш. Бобомуродов, Т.Н. Ҳаскашев, М. Файзов, А.Неъматов, Ш.Кабиров ва шогирдонашон мавриди омӯзишу баррасӣ қарор додаанд. Саҳми шодравон профессор Т.Н. Ҳаскашев ва М. Файзов дар омӯзишу инкишофи фонетикаи забони адабии муосири тоҷик хеле зиёд мебошад. Ин муҳаққиқони ватаний таҳлилу муқоисаҳои илмӣ, назариявӣ ва амалии арзишмандеро дар илми фонетикаи тоҷик анҷом дода, хусусиятҳои тавлидӣ (физиологӣ) ва шунавоии (акустикӣ) овозҳои забони тоҷикиро бо истифодаи асбобҳои (рентгенограмма, политограмма) маҳсуси дар соҳаи тиб ва ғайра истифодашаванд ошкор намудаанд.

Ба омӯзиши масъалаи мазкур аз нигоҳи илми риёзӣ ва технологияҳои иттилоотӣ дар хориҷи кишвар олимони зиёде ба мисли Rudolf Flesch, Gunning R., Kincaid J., Spache G., Fry E., Hedman S., McLaughlin, G., В. Франчина, Р. Вакка, Оборнева И. В., Иванов К.В., Фомин А.Ю. ва дигарон машғул гардида, амсилаҳои математикии баҳодиҳӣ ва таҳлили хушоҳангии матнҳои англисӣ, итолиявӣ, русӣ ва забонҳои дигарро аз рӯйи параметрҳои гуногун омода намуда, натиҷаҳои назаррасеро ба даст овардаанд, ки дар қалонтарин ширкатҳои ҷаҳонӣ, аз қабили Microsoft, пайкараҳои миллии забонҳо, сомонаҳои ҷуғрофӣ ва байналмилаӣ ва дигар вазорату корхонаҳои даҳлдор истифода мешаванд.

Дар Ҷумҳурии Тоҷикистон дар самти коркарди забони табиӣ, маҳсусан забони тоҷикӣ муҳаққиқон Усмонов З.Ҕ., Исмоилов М.А, Тошхӯчаев Ҳ.А., Умаров М.А., Зарипов С.А., Шарифофф Ш., Гращенко Л.А., Ҳудойбердиев Ҳ.А., Солиев О.М., Довудов Г.М., Қосимов А.А., Қаюмов М.М. ва дигарон якҷоя бо шогирдонашон таҳқиқот бурда истодаанд.

Таҳияи системаҳои шинохти ҳудкори хушоҳангии қалимашаклҳо имконияти соҳтани фарҳангӣ лӯғавии қалимашаклҳои хушоҳангро медиҳад, ки он дар оянда метавонад қисми зарурии пайкараи матнҳои забони тоҷикӣ гардад. Муваффақиятҳо дар самти таҳияи шинохти ҳудкори хушоҳангии қалимашаклҳо замина ба рушди босуръати системаҳои ҳудкори баҳодиҳии

хушохангӣ гузошта, имкон медиҳад, ки хушохангиву душворталаффузии ҷумлаҳо, матнҳо, асарҳо, китобҳо дарсӣ, матни имтиҳонҳои хонандагону донишҷӯён ва эҷодиёти ҳаргуна муаллифон арзёбӣ гарданд.

Робитаи таҳқиқот бо барномаҳо (лоиҳаҳо) ва ё мавзуъҳои илмӣ. Кори диссертационӣ дар доираи нақшай корҳои илмӣ - таҳқиқотии кафедраи технологияҳои иттилоотӣ ва иртиботии факултети меҳаникаи математикаи Дошигҳои миллии Тоҷикистон тибқи амалишавии нақшай илми-таҳқиқотии мавзуъҳои бучавӣ, рақами қайди давлатӣ № 0122TJ14117 (01.01.2021-31.12.2025) «Татбиқи методҳои риёзӣ ва технологияҳои нави иттилоотӣ дар соҳаи забоншиносӣ ва омӯзиши методҳои рамзгузории алифбой» ба қайд гирифта шудааст ва лоиҳаи тадқиқоти бунёдии рақами қайди давлатӣ № 0116TJ00661 (01.01.2016-31.12.2021) «Татбиқи методҳои моделсозии математикӣ ва технологияҳои нави иттилоотӣ дар соҳаи маориф ва забоншиносӣ», ичро гардидааст.

ТАВСИФИ УМУМИИ ТАДҚИҚОТ

Мақсади таҳқиқот. Таҳияи асосҳои системаҳои худкори шинохти хушохангии калимашаклҳои забони тоҷикӣ ва истифодаи он дар намуди маҷмуаи барномаи компьютерӣ.

Вазифаҳои таҳқиқот. Барои ба мақсад расидан масъалаҳои зерин ҳал карда мешаванд:

- ҷамъоварӣ ва омодасозии маҷмуаи матнҳо барои омӯзиш ва гузаронидани озмоишҳои гуногуни илмӣ, аз ҷумла муайянкунии хушохангии калимашаклҳо;
- таҳқиқи иттилоъдии аломатҳое, ки барои шинохт ва муайянкунии хушохангии калимашаклҳо таъйин шудаанд;
- тафтиши самаранокии усулҳои математикие, ки барои муайянкунии хушохангии калимашаклҳо истифода мешаванд;
- таҳқиқи самаранокии истифодаи унсурҳои алифбои N -граммҳои рамзии басомадашон баланд барои муайянкунии калимашаклҳо;
- соҳтани лоиҳаи маҷмааи нармағзори компьютерӣ барои ба таври автоматӣ муайян кардани хушохангии калимашаклҳои тоҷикӣ ва татбиқи он.

Объекти таҳқиқот – амсилаҳои математикию компүтерии таҳлил ва баҳодиҳии хушохангии маҷмуи калимашаклҳои чопии забони тоҷикӣ.

Мавзуи таҳқиқот – шинохти худкори хушохангии калимашаклҳои тоҷикӣ дар асоси аломатҳо ва басомади N -граммҳои он.

Усулҳои таҳқиқот. Барои ҳалли масъалаҳое, ки дар банди “Мақсади кор” номбар шудаанд, методҳои фонетикӣ, методҳои омори риёзӣ, ҳисобҳои таҷрибавӣ, назарияи маҷмуъҳо, таҳлили системавӣ, амсиласозии математикӣ ва компүтерӣ, барномасозии ба объект нигаронидашуда барои таҳияи воситаҳои барномавӣ ва коркарди манбаи додаҳои релятсионӣ истифода шудаанд.

Асосҳои назариявии таҳқиқот. Асосҳои назариявии диссертатсияро

сарчашмаҳои илмии ниёгон, натиҷаҳои илмии олимони давру замонҳои гуногун, ки ба мавзуи диссертатсия иртибот доранд, ташкил медиҳанд.

Навғонии илмии таҳқиқот. Натиҷаҳои асосии диссертатсия нав буда, чунин ифода мегарданд:

- иттилоъдиҳии алломатҳое, ки барои шинохт ва муайянкуни хуشوҳангии калимашаклҳо таъйин шудаанд таҳқиқ карда шуд;
- самаранокии истифодаи N-граммаҳои ҳуруфӣ ($N=1,2,3$) ба сифати алломатҳои муайянкунандай хуشوҳангии калимашаклҳо муқаррар карда шуд;
- самаранокии таснифгари Усмонов З.Ч. муқаррар карда шуд, ки қобилияти бо саҳеҳии то 96% муайян кардани хуشوҳангии маҷмуи калимашаклҳоро дорад;
- бо мақсади комилан кам кардани ҳаҷми раванди ҳисобкуниҳо имконияти самаранокии истифодаи на ҳама, балки танҳо элементҳои алифбои N-граммаҳои ($N=1,2,3$) рамзии баландбасомад барои муайянкуни хуشوҳангии калимашаклҳо истифода карда шуд;
- бори аввал дар Тоҷикистон маҷмааи барномаи компютерии замонавӣ барои шинохти худкори хуشوҳангии калимашаклҳои тоҷикӣ, соҳта шуд.

Нуктаҳои ба ҳимояи пешниҳодшаванд:

1. Алломатҳое, ки барои шинохт ва муайянкуни хуشوҳангии калимашаклҳо таъйин шудаанд;
2. Тасвири миқдории калимашаклҳои тоҷикӣ, ки хуشوҳангиро дар намуди тақсимоти басомади N-граммаҳои ҳуруфӣ ($N=1,2,3$) тавсиф мекунанд;
3. Татбиқи самаранокии таснифгари Усмонов З.Ч., ҳамчун методи нав ва мувоғиқ барои муайян кардани хуشوҳангии калимашаклҳои тоҷикӣ;
4. Бо мақсади комилан кам кардани ҳаҷми раванди ҳисобкуниҳо имконияти самаранокии истифодаи на ҳама, балки танҳо элементҳои алифбои N-граммаҳои ($N=1,2,3$) рамзии баландбасомад барои муайянкуни хуشوҳангии калимашаклҳо истифода карда шуд;
5. Маҷмааи барномаи компютерии замонавӣ барои шинохти худкори хуشوҳангии калимашаклҳои тоҷикӣ.

Аҳамияти назариявӣ ва амалии таҳқиқот. Аҳамияти назариявии диссертатсия дар он зухур меёбад, ки дар он бо усули таҷрибавӣ, усули нави таснифоти бузургихои тасодуфии фосиладор мавриди санчиш қарор ёфт ва самаранокии татбиқи он бо мақсади шинохти худкори хуشوҳангии калимашаклҳои чопии тоҷикӣ, муқаррар карда шуд. Аҳамияти амалии кор аз он иборат аст, ки вай барои татбиқи амсилаҳои риёзиву иттилоотӣ ва маҷмааи барномаи компютерии дар он соҳташуда дар соҳаҳои илму маориф, фарҳанг, забоншиносӣ, адабиётшиносӣ ва низомҳои компютерии коркарди матн барои шинохти худкори хуشوҳангии калимашаклҳои тоҷикӣ пешбинӣ шудааст.

Саҳеҳият ва асоснокии натиҷаҳои бадастомада, бо як силсила озмоишҳои ҳисоббарорӣ тасдиқ мешаванд, ки дар онҳо хуشوҳангии калимашаклҳои гуногун бо саҳеҳияти кифоя баланд муайян шудаанд.

Мутобиқати диссертатсия ба шиносномаи ихтиносии илмӣ. Мундариҷаи таҳқиқоти диссертатсия ба бандҳои 1, 4 ва 7-и шиносномаи

ихтисоси илмӣ барои дарёфти дараҷаи илмии номзади илмҳои техникӣ аз рӯйи ихтисоси 05.13.11 – «Таъминоти математикӣ ва барномавии мошинҳои ҳисоббарор, комплексҳо ва шабакаҳои компьютерӣ», мувофиқат меқунад:

Б.1. Амсилаҳо, усулҳо ва алгоритмҳои банақшагирӣ ва таҳлили барнома ва низоми барномавӣ, инчунин тағийирдиҳии эквивалентӣ, верификатсия ва тестиронии онҳо;

Б.4. Низоми идоракунии манбаи маълумот ва дониш;

Б.7. Интерфейсҳои инсон-мошин, амсилаҳо, усулҳо, алгоритмҳо ва воситаҳои барномавии мошинии графикӣ, визуализатсия, коркарди тасвир, низоми ҳақиқати виртуалӣ, муоширати мултимедӣ.

Саҳми шахсии довталаби дараҷаи илмӣ дар таҳқиқот. Гузориши масъала ва интихоби методҳои тадқиқот ба роҳбарони илмӣ тааллук дошта, натиҷаҳои асосии кори диссертационӣ аз тарафи муаллиф мустақилона ба даст оварда шудаанд.

Тасвib ва амалисозии натиҷаҳои диссертатсия. Натиҷаҳои асосии кор дар конференсияҳо ва семинарҳои зерин пешниҳод ва муҳокима гардидаанд:

- семинарҳои илмӣ-тадқиқотӣ дар Донишгоҳи миллии Тоҷикистон, Донишгоҳи техникии Тоҷикистон ба номи М.С. Осимӣ, Донишгоҳи технологи Тоҷикистон ва Донишгоҳи славянини Тоҷикистону Россия дар солҳои 2014-2023;

- конференсияи илмӣ-амалии байналмилалии "Перспективы развития науки и образования", соли 2016., Душанбе;

- конференсияи илмӣ-амалии байналмилалии "Нақши технологияҳои иттилоотио коммуникатсионӣ дар рушди инноватсионии иқтисодии Ҷумҳурии Тоҷикистон", соли 2017, шаҳри Душанбе;

- конференсияи байналмилалии илмии "Современные проблемы математики и их приложения", 14-15 июня соли 2017, шаҳри Душанбе, шаҳри Кӯлоб;

- Конференсияи илмӣ-амалии байналхалқии «XII Ломоносовские чтения», посвященной Дню таджикской науки и 30-летию установления дипломатических отношений между Республикой Таджикистан и Российской Федерацией (29-30 апреля 2022). Часть I. Естественные науки. – Душанбе, 2022;

- Материалы международной научно-практической конференции "Современные проблемы математики и её приложения", посвященной 20-летию развития естественных, точных и математических наук 2020-2040 годы . -Душанбе -2022;

- Маводҳои конференсияи байналмилалии илмӣ-амалӣ дар мавзуи «Таҳлили компьютерии масъалаҳои илм ва технология» баҳшида ба «Солҳои 2020-2040 эълон гардидани 20-солаи омӯзиш ва рушди илмҳои табиатшиносӣ, дақиқ ва риёзӣ дар соҳаи илму маориф» ва «75-солагии Донишгоҳи миллии Тоҷикистон». -Душанбе -2023.

Интишорот аз рӯйи мавзуи диссертатсия. Аз рӯйи мавзуи диссертационӣ 13 мақола нашр шудаанд, [1-М - 13-М]. Аз онҳо 6 мақолаи

илмӣ, дар нашрияҳои аз тарафи КОА –и назди Президенти Ҷумҳурии Тоҷикистон тавсияшуда, нашр гардидаанд.

Соҳтор ва ҳачми кор. Рисолаи илмӣ аз мундариҷа, се боб, хулоса ва рӯйхати адабиёт, ки аз 137 номгӯй иборат аст, таркиб ёфтааст. Муҳтавои диссертатсия дар 143 саҳифа дарҷ гардида, 13 ҷадвал ва 59 расмро дар бар мегирад.

Муаллиф ба роҳбарони илмӣ – доктори илмҳои физикаю математика, профессор, академики АМИТ **Усмонов З.Ҷ.** ва доктори илмҳои техникӣ, дотсент Мирзоев С.Ҳ., инчунин ба кормандони Донишгоҳи миллии Тоҷикистон, Институти математикаи ба номи А. Ҷӯраеви АМИТ ва Донишгоҳи техникии Тоҷикистон ба номи академик М.С. Осимӣ миннатдории маҳсуси худро баён мекунад.

МУҲТАВОИ АСОСИИ ТАДҚИҚОТ

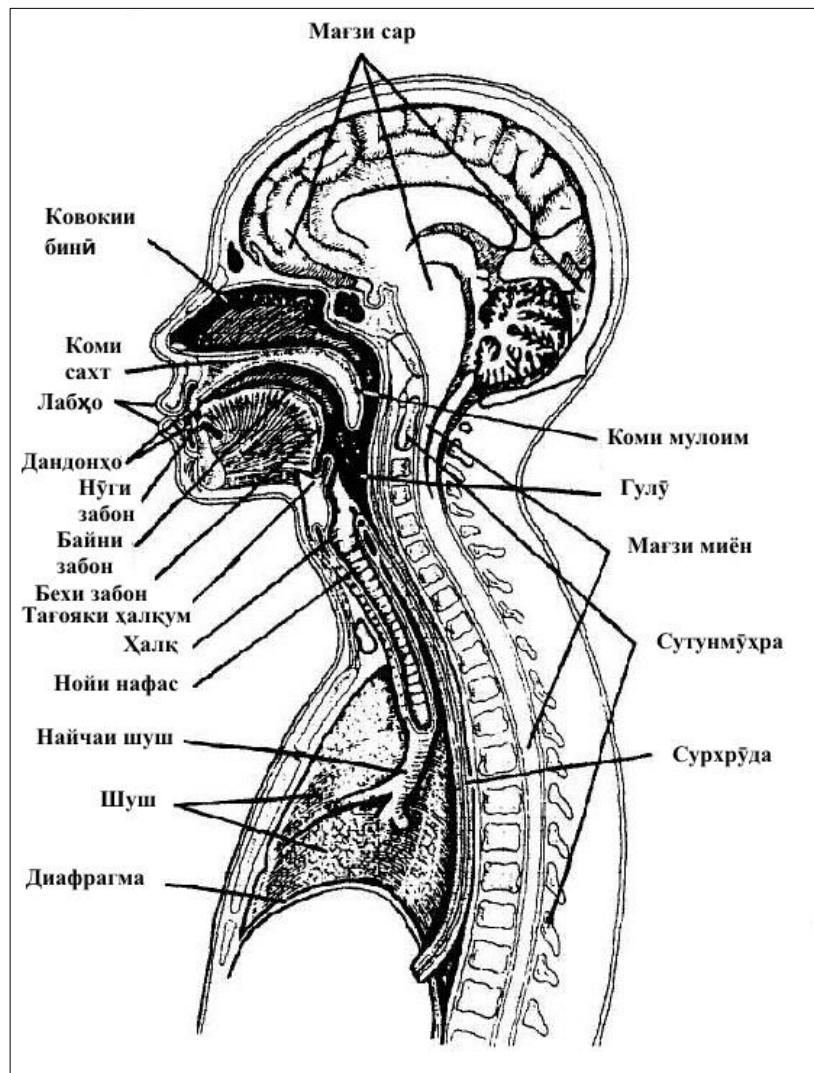
Дар **муқаддима** аҳамияти мавзуи интихобгардида асоснок карда шуда, ҳадаф, вазифаҳо, объект ва мавзуи тадқиқот муайян шудаанд, навғонӣ ошкор, аҳамияти назариявӣ ва амалии кор муаррифӣ шудааст, инчунин муқаррароти ба ҳимоя пешниҳодшуда, усулҳои таҳқиқ, асос ва маводи омӯзиш тавсиф дода шуда, дар бораи тасвиби тадқиқот ва соҳтори он маълумот оварда шудааст.

Дар **боби 1** масъалаи хушоҳангии матнҳо, тарзҳои ҳалли он, ҷанбаҳои пайдоиши овозҳои нутқ ва хусусиятҳои физикию тавлидии онҳо таҳлил карда мешаванд. Дар **зербоби 1.1** андешаҳои муҳаққиқони давру замони гуногун аз соҳаҳои филология, математика ва технологияҳои иттилоотӣ дар бораи масъалаи хушоҳангӣ ва душворталафғузии калимаҳо мавриди таҳқиқ қарор гирифтаанд.

Дар **зербоби 1.2** ҷанбаҳои пайдоиши овозҳои нутқ баррасӣ шудаанд. Соҳти овозии забонҳои муюширати байни одамон табиати бисёр мураккаб дошта, аз ин рӯ зарурати омӯзиши паҳлӯҳои гуногуни он ба миён меояд. Нутқи мо, пеш аз ҳама, ҳодисаи овозӣ буда, табиати физикӣ дорад. Ҳар як ҳодисаи овозӣ дар вақту замони муайян бо қувваю зудии ба худ хос ба вуқӯй меояд.

“Дар заминаи физикию акустикӣ табиати физикии овозҳои нутқ ва алломатҳои онҳо: дарозӣ, дараҷаи паҳннокиу қувватнокӣ, соҳти формантию спектрӣ мавриди таҳлилу таҳқиқ қарор мегиранд. Ин алломатҳои физикии овозҳои нутқ дар шароит ва ҳолатҳои гуногуни фонетикӣ таҳқиқу муқоиса ва дараҷаи молик будани онҳо ба ин хусусиятҳо нисбат ба овозҳои дигар таъмин карда мешавад. Таснифи акустикии овозҳо низ дар асоси ҳамин алломатҳо сурат мегирад”.

Овозҳое, ки мо мешунавем, манбаъ ва сабаби пайдоиш доранд. Манбаъ ва сабаби пайдо гардидани овозҳои нутқ ин дастгоҳи гуфтори инсон ва кори узвҳои он аст (рас. 1.1).



Расми 1 - Дастиғи гүфтөр

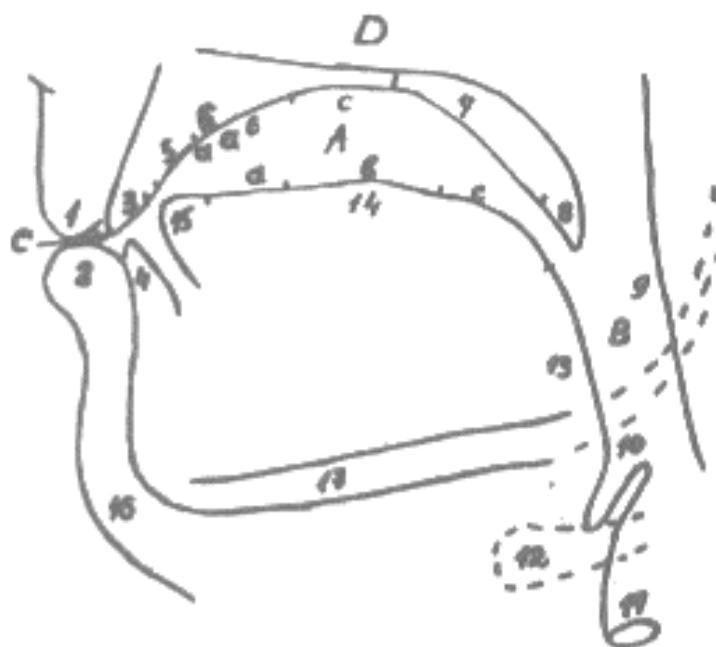
Қисми асоси ҳалқ, ки дар овозсозӣ (садосозӣ) саҳми асосӣ дорад садопардаҳо мебошанд. Садопардаҳо қодиранд, ки дар як сония тахминан аз 40 то 1700 маротиба ларзанд, вале дар нутқи маъмулӣ лапиши онҳо ба 85-200 (дар нутқи мардон) ё 160-340 (дар нутқи занон) ларза дар сония баробар аст. Садопардаҳои мардон ғафс ва аз занон тунук мебошанд, ки аз ин хотир микдори ларзишҳои садои мардон паст ва аз занон баланд мебошад.

Ҳар як забон дорои низоми овозҳои ба худ хос аст, ки онҳо ба воситаи узвҳои гуногун сохта мешаванд. Узвҳои овозсозии фаъоли забони точиқӣ: садопардаҳо, деворҳои ҳалқ, коми мuloим бо забонча, забон ва лабҳо мебошанд, ки дар ташаккули овозҳо саҳми бештар доранд. Масалан, аз 30 фонема (овоз)-и забони точиқӣ 20 фонема (66,7%) дар қисми пеши забон ва танҳо 10 фонемаи дигар: садонокҳои у, ў, о ва ҳамсадоҳои г, к, х, ф, қ, Ҷ, Ҳ (33,3%) дар қисми қафои забон сохта мешаванд. Ба узвҳои овозсозии ғайрифаъол: коми сахт, дандонҳо, милкҳои дандонҳо ва ковокии бинӣ дохил мешаванд.

Гарчанде ки хусусиятҳои дастгоҳи овозсозии забони тоҷикӣ ҳанӯз ҳам таҳқиқ нашуда бошад ҳам оиди бъазе аз онҳо мълумоти муқаддимавӣ мавҷуд аст. Яке аз ин гуна хусусиятҳое, ки ба дастгоҳи овозсозии забони тоҷикӣ тааллук дорад, хусусияти мусиқавӣ - хушвозию хушоҳангӣ мебошад. Хушоҳангӣ ин ҳамнишинии комили овозҳое мебошад, ки барои гӯянда осонию ба шунаванда форамӣ меорад. Талаботҳои хушоҳангӣ бояд мутобики хусусиятҳои фонетикии забон мушаххас бошанд. Хушоҳангӣ ҳамеша ба гуногунрангии фонетикаи як забони миллӣ вобастагӣ дорад”¹.

Дар зербоби 1.3 хусусиятҳои физикии овозҳо, хусусан овозҳои забони тоҷикӣ мавриди омӯзишу баррасӣ қарор гирифтаанд.

Дар зербоби 1.4 сухан дар бораи хусусиятҳои тавлидии овозҳои забони тоҷикӣ меравад. Алифбои ҳозираи забони адабии тоҷикӣ аз 35 ҳарф ва 30 овоз (фонема) иборат аст, ки онҳоро ба ду гурӯҳи асосӣ: 1) садонокҳо ва 2) ҳамсадоҳо ҷудо мекунанд. Дар талафғузи садонокҳо монеа дида намешавад. Ғайр аз ин садонокҳо бо дигар хусусиятҳояшон аз ҳамсадоҳо фарқ мекунанд. Чун дар талафғузи садонокҳо монеа дида намешавад, гуфтани мумкин аст, ки онҳо овозҳои форам ҳастанд. Ҳамсадоҳо нисбатан бештар буда, нақши зиёдро дар ташкили калима ва матн доранд. Ҳангоми талафғузи ҳамсадоҳо бошад, онҳо ба монеаҳои гуногун дучор мешаванд, ки ин то як андоза роҳи ҷараёни овозро гирифта вазниниро дар талафғуз пеш меорад. Масъалаи халалдор шудани хушоҳангии калимашаклҳо низ аз ҳамнишиниву төъдоди ҳамсадоҳо вобастагӣ дорад. Барои равшантар шудани гуфтаҳоямон нақшай узвҳои нутқро меорем, ки тавассути асбоби рентгенограмма гирифта шудааст (рас. 1.2).



Расми 2 – Инъикоси узвҳои нутқ дар рентгенограмма

¹ Ҳаскашев, Т.Н. Фонетикаи забони адабии тоҷик / Т.Н. Ҳаскашев. – Душанбе. : Маориф, 1989. – 200 с.

Дар нақшай рентгении расми 1.2 бо рақамҳо узвҳои талаффуз ва бо ҳарфҳо ковокиҳои дастгоҳи нутқ ишора карда шудааст. Ковокии даҳон – А, ковокии ҳалқ – В, ковокии даромадгоҳи даҳон – С, ковокии бинӣ – Д. Бо рақамҳои 1 – лаби боло; 2 – лаби поён; 3 – дандонҳои боло; 4 – дандонҳои поён; 5 – садопардаҳо; 6 – коми сахт: а) қисми пеш, в) қисми мобайн, с) қисми қафо; 7 – коми нарм; 8 – забонча; 9 – девораи ҳалқ; 10 – тағояки болои ҳалқ; 11 – ҳалқ; 12 – устухони зери забон; 13 – реша ё асоси забон; 14 – пушти забон: а) пеши забон, в) байни забон, с) қафои забон; 15 – нӯги забон; 16 – манаҳ; 17 – ҷоғи поён ишора гардидаанд.

Дар **зербоби 1.5** боби якуми рисола хулосаҳо оид ба боби якум оварда шудаанд.

Дар **боби 2** ташаккули асосҳои андозагирии хушоҳангӣ, татбиқи амсилаи математикӣ ва компьютерӣ бо истифодаи элементҳои униграмма, биграмма ва триграмммаҳо дида баромада шудааст.

Дар **зербоби 2.1** ташаккули асосҳои андозагирии хушоҳангӣ дида баромада шудааст. Хушоҳангӣ (эвфония) мағҳуми сифатӣ мебошад, зоро ҳар фард ба садои калима, чумла, шеър, матн ва гуфтор ба таври худ баҳо медиҳад. Дар баробари ин, мағҳуми баррасишаванда оморӣ аст, зоро маҷмуи шахсони алоҳида нисбати як объект дар бисёр мавридҳо андешаи «умумӣ»-ро ифода мекунанд. Ин далел асоси рушди эвфонометрия ҳамчун фанни нави илмӣ, ки ба омӯзиши қолабҳои хушоҳангӣ дар нутқи хаттӣ ва шифоҳӣ бо истифода аз усулҳои риёзӣ ва оморӣ нигаронида шудааст, ба ҳисоб меравад. Аҳамияти амалии чунин тадқиқотҳо дар таъсири бешубҳаи сифати овозии нутқ ба натиҷаҳои дарки иттилоот мебошад.

Ташаккули асосҳои эвфонометрия аз соҳтан ё муроҷиат кардан ба маҷмуаи матни аллакай мавҷудбудаи ягон забони табиӣ (бехтараш ба пайкараи забонӣ) оғоз меёбад. Маҷмуа бояд ба қадри кофӣ намоён буда фарогири адабиёти бадеӣ, мақолаҳои рӯзномаю маҷаллаҳо, матнҳои илмию оммавӣ аз соҳаҳои гуногуни дониш, асарҳои ҷамъиятию сиёсӣ, намоишнома ва ғайраҳо бошад. Мувофиқи матлаб аст, ки ҳаҷми маҷмуа аз даҳҳо миллион калима иборат бошад.

Дар асоси 20 асари адибони форсу тоҷик аз давру замонҳои муҳталиф ва осори дорои жанрҳои гуногун маҷмуаи матниро тартиб додем, ки аз 6 811 саҳифаи электронӣ иборат буда 2 206 587 калимаро дар бар мегиряд. Натиҷаи омории ин пажӯҳиш дар ҷадвали 2.1.1 оварда шудааст.

Ҷадвали 2.1.1.

Омори маҷмуаи матни таҳқиқшаванда

№	Номи адиб	Номи асар	Миқдори саҳифа	Миқдори калима
1	Абдурамони Ҷомӣ	Баҳористон	139	31 934
2	Саъдии Шерозӣ	Гулистон	150	39 589
3	Носири Хисрав	Сафарнома	100	34 523

4	Ибни Муқаффаъ	“Калила ва Димна”	120	39 647
5	Садриддин Айнӣ	«Марги судхӯр»	220	57 926
6	Хусайн Вонзи Кошифӣ	Футувватнома	336	93 874
7	Мухаммадиев Ф.	Шаби савум	288	94 952
8	Мехмон Бахтий	Тилисми Сайҳун	45	12 020
9	Сорбон	Романи Туграл	190	57 876
10	Муҳаммадҷони Шакурии Бухорой	Садри Бухоро	188	112 709
11	Муҳаммадҷони Шакурии Бухорой	Хуросон аст ин ҷо	361	92 104
12	Ҷалолуддини Балхӣ	800 ғазали дилошӯб	287	83 215
13	Эмомалӣ Раҳмонов	Нигоҳе ба таъриҳ ва тамаддуни ориёй	371	144 387
14	Ғафуров Б.Ғ.	Тоҷикон	870	305 673
15	Лоиқ Шералий	Куллиёт	830	210 713
16	Абулқосим Фирдавсӣ	Шоҳнома. Ҷилди 1	277	57 694
17	Худойназар Асозода	Достони зиндагӣ (китоби 4-ум)	321	145 205
18	Худойназар Асозода	Достони зиндагӣ (китоби 5-ум)	480	223 087
19	Абулғазли Байҳакӣ	Таърихи Байҳакӣ	756	235 890
20	Маҷлиси Олии ҶТ	Кодекси андоз	482	133 569
			6811	2 206 587

Ба се синф тақсим кардани калимашаклҳо дар асоси пурсиши афкори умум ба воситаи пурсишнома (анкета) сурат гирифт. Мусоҳибон ба рости ҳар як калимашакли аз рӯйхати \bar{L} яке аз се рақами: -1, +1 ва 0 гузориданд, ки онҳо аломатҳои сифатии мувофиқи овозҳои «душвор», «форам» ва «миёна»-ро кодгузорӣ мекунанд. Ба мутахассисон (соҳибони забон) калимашаклҳои интихобшударо пешкаш намудем, онҳо ба ҳар як калима яке аз се рақами: -1, 0 ё +1 -ро гузоштанд, ки мувофиқан сифати аломатҳои талаффизи “душвор”, “миёна” ва “форам” -ро кодгузорӣ мекунанд. Пурсишнома бо ҳаҷми шаш саҳифаи чопӣ дар шакли ҷадвал пешкаши мутахассисон гардид.

Мутахассис калимашаклҳои дар анкетабударо аз назар мегузаронад, агар талаффизи он душвор бошад, онгоҳ ба рости он рақами -1, агар талаффизи калимашакл на душвору на форам, миёна бошад, онгоҳ ба рости он рақами 0 ва агар талаффизи калима форам бошад, онгоҳ дар паҳлӯи он рақами +1 ро менависад.

Дар асоси хусусиятҳои гуногуни овозҳои забони тоҷикӣ, қонуниятҳои ҳамнишинии онҳо, пурсиши соҳибони забон ва коркарди компьютерии калимашаклҳо 16 аломатеро ошкор намудем, ки тавсифкунандай сифати гуногуни овозии калимашаклҳои забони адабии тоҷик мебошанд. Аломатҳое, ки барои тавсифи миқдориу сифатии хушоҳангии калимашаклҳо интихоб гардидаанд дар ҷадвали 2.1.4 бо қиматҳои имконпазирашон оварда шудаанд.

Ҷадвали 2.1.4. - Аломатҳои тавсифкунандай хусусиятҳои миқдориу сифатии
калимашаклҳо

№	Аломати калимашаклҳо	Қиматҳои имконпазир	Теъдоди мавқеи аломат
1	Дарозӣ (миқдори ҳарфҳо)	Аз 1 то 30	2

2	Шумораи садонокҳо	аз 1 то 15	2
3	Шумораи ҳамсадоҳо	аз 1 то 15	2
4	Ҳамсадои Ғ	1-ҳаст, 0-нест	1
5	Ҳамсадои Ж	1-ҳаст, 0-нест	1
6	Ҳамсадои Қ	1-ҳаст, 0-нест	1
7	Ҳамсадои Ҳ	1-ҳаст, 0-нест	1
8	Ҳамсадои Ҷ	1-ҳаст, 0-нест	1
9	Ҳамсадои ҶҶ	1-ҳаст, 0-нест	1
10	Биграммаи НГ	1-ҳаст, 0-нест	1
11	Биграммаи НД	1-ҳаст, 0-нест	1
12	Биграммаи РД	1-ҳаст, 0-нест	1
13	Биграммаи СТ	1-ҳаст, 0-нест	1
14	Биграммаи ФТ	1-ҳаст, 0-нест	1
15	Биграммаи ХТ	1-ҳаст, 0-нест	1
16	Биграммаи ШТ	1-ҳаст, 0-нест	1

Дар зербоби 2.2 амсилаи шинохти хушоҳангии калимашаклҳои тоҷикӣ бо истифодаи униграммаҳо дида баромада шудааст. Дар ин фасл ва фаслҳои ояндаи ин боб равиши системавие истифода бурда мешавад, ки соли 2015 барои аз сифр таҳия намудани асосҳои эвфонометрияи забонҳои табии, аз он ҷумла забони тоҷикӣ пешниҳод шуда буд ва онро барои забонҳои табиии гуногун ҳам татбиқ кардан мумкин аст. Асоси ин равишро γ-таснифгари бузургиҳои тасодуғии фосиладор (дискретӣ) ташкил медиҳад, ки он аз тарафи академики АМИТ Усмонов З.Ҕ. таҳия ва коркард гардидааст. Таснифгари номбурдаро барои ҳалли масъалаҳои муҳталифи илми забоншиносӣ ва ошкор намудани хусусиятҳои воҳидҳои матни гуногун, аз ҷумла муайян кардани сифати талаффузи калимашаклҳо, истифода намудан мумкин аст. Дар ин қисмати кор таснифгари болозикрро барои муайян кардани сифати овозии калимашаклҳо истифода мекунем, ки он сегонаи математикии аз се қисм иборат бударо, пешкаш мекунад:

- симои рақамӣ (СР), яъне тавсифи миқдории калимашаклҳо;
- формулаҳои масофаи байни СР калимашаклҳо;
- алгоритми қабули қарорҳо дар асоси тимсолҳо.

Таснифгари мазкурро барои шинохти худкори сифати калимашаклҳои маҷмуи муайян: асари назмӣ ё насрӣ, ки пешакӣ аз пайкараи матнӣ интиҳоб гардидааст, истифода мебарем. Пайкараи матнӣ ин маҷмуи матнҳои дорои жанрҳои гуногун, мебошад, ки дар шакли электронӣ нигоҳдорӣ шудааст. Пайкараи матниро барои гузаронидани пажӯҳишҳои гуногуни соҳаи забоншиносӣ, таъриҳ ва соҳаҳои дигар истифода мекунанд. Аз пайкараи матнҳои тоҷикӣ маҷмуи баъзе калимашаклҳоро интиҳоб мекунем. Чунин маҷмуъ калимашаклҳои нисбатан серистеъмоли талаффузашон “душвор”, “миёна” ва “хушоҳанг” – ро дар бар мегирад.

Маҷмуи калимашаклҳои тоҷикиро бо ҳарфи *G* ишора карда онро аз рӯйи сифати талаффузашон ба се гурӯҳ чудо мекунем: G_1 – душворталаффуз, G_2 – хушоҳанг ва G_3 – калимашаклҳои миёна ё бетараф. Аз ҳар як гурӯҳ 1000-1500 калимашаклро интиҳоб мекунем. Гурӯҳи G_1 -ро бо ягон тарзе ба 3 зергурӯҳи

– G_{11} , G_{12} , G_{13} – бо андозаҳои таҳминан баробари шумораи калимашаклҳо, ҷудо мекунем. Гурӯҳи G_2 -ро низ бо ягон тарзе ба 3 зергурӯҳи G_{21} , G_{22} , G_{23} – бо андозаҳои таҳминан баробари шумораи калимашаклҳо, ҷудо мекунем. Зергурӯҳҳои G_{1i} ва G_{2j} -ро ҳамчун зергурӯҳои калимашаклҳо (матнҳо) дидамебароем.

Дар қадами аввал ба сифати унсурҳои тавсифкунандай инъикоси миқдории зергурӯҳои калимашаклҳо алифбои ягонаи тоҷикиро истифода мекунем, ки он аз 35 ҳарф (ё униграмма): ***а, б, в, ..., э, ю, я*** иборат аст.

Барои ҳар яке аз 6 зергурӯҳҳои G_{1i} ва G_{2j} симои рақамии ягонаэро дар намуди ҷадвали қонуни тақсимот, дохил мекунем

$$\begin{array}{cccccc} \bar{N} & : & 1 & 2 & \dots & m \\ P & : & p_1 & p_2 & \dots & p_m, \end{array} \quad (2.2.1)$$

дар сатри аввал рӯйхати $m = 35$ ҳарфи тоҷикӣ бо тартиби алифбо рақамгузоришида ва дар сатри дуюм бошад басомадҳои онҳо барои гурӯҳи мушаҳҳас оварда шудааст, зимнан эҳтимолияти онҳо низ ба қимати ифодаи зерин баробар аст:

$$\sum_{k=1}^m p_k = 1.$$

Ба ҳар яке аз 6 зергурӯҳ функсияе мувофиқ гузошта мешавад:

$$F(s) = \sum_{k=1}^s p_k \quad (s = 1, \dots, m) \quad (2.2.2)$$

– аналоги дискретии функсияи тақсимот. Бигузор T_1 , T_2 – ҷуфти зергурӯҳи калимашаклҳои ихтиёри аз маҷмуи $\{G\}$ ва

$$F^{(\alpha)}(s) = \sum_{k=1}^s p_k^{(\alpha)} -$$

функсияҳои дискретии мувофиқи онҳо, $\alpha = 1, 2$ ва $s = 1, \dots, 35$ бошанд.

Таърифи 1. *Масофаи байни зергурӯҳи калимашаклҳои T_1 ва T_2 – ро аدادи мусбати $\rho(T_1, T_2)$ меномем, ки он бо формулаи зерин муайян карда мешавад:*

$$\rho(T_1, T_2) = \sqrt{\frac{m}{2}} \max_s \left| \sum_{k=1}^s (p_k^{(1)} - p_k^{(2)}) \right| \quad (2.2.3),$$

яъне масофаи байни бузургихои тасодуфии дискретӣ (бо маҷмуи яхелаи қиматҳои имконпазири \bar{N}) ҳамчун масофаи максималии байни функсияҳои дискретии онҳо $F^{(1)}(s)$ ва $F^{(2)}(s)$, ҳисоб карда мешавад, ки он бо коэффиценти вазн $\sqrt{m/2}$ зарб карда шудааст.

Гипотезаи \mathbb{H} «якчинсагии» гурӯҳи калимашаклҳо. Он барои нишон додани хусусиятҳои хоси калимашаклҳо ҷалб карда шудааст, ки барои соҳтани амсилаи риёзии шинохтани сифати овозии калимашаклҳо пешбинӣ мегардад.

Гипотезаи \mathbb{H} . Гурӯҳи калимашаклҳое, ки садои хушоҳанг доранд «якчинса» ва гурӯҳи калимашаклҳои ғайри онро (яъне душворталафғуз)-ро «ғайри якчинса» меноманд.

Дар бораи «якчинсагӣ»-и хушоҳангии гурӯҳи калимашаклҳо сухан ронда, мо шабоҳат, монандӣ, якнавъӣ ва наздикии онҳоро дар назар дорем.

Амсилаи риёзии \mathbb{H} -гипотезаҳо. Бигузор γ – ягон адади мусбат бошад.

Таърифи 2. *Гурӯҳи калимашаклҳои T_1 ва T_2 γ - якчинса номида мешаванд (садои форам доранд), агар масофаи байни онҳо*

$$\rho(T_1, T_2) \leq \gamma, \quad (2.2.4)$$

ва γ - ғайриякчинса номида мешавад (садои дағал доранд), агар масофаи байни онҳо

$$\rho(T_1, T_2) > \gamma \quad (2.2.5)$$

бошиад.

Нобаробариҳои (2.1.4) ва (2.1.5) амсилаи риёзии гипотезаҳои \mathbb{H} ном доранд.

Таърифи 3. γ -таснифари аз як параметри ҳақиқии γ вобастаро алгоритми қабули қарор дар бораи тааллук доштани ҷуфтӣ зергурӯҳи калимашаклҳои T_1 ва T_2 ба як ё ду сифатҳои гуногуни овозии калимашаклҳо меноманд.

Бигузор $\tau = \tau(\gamma)$ – суммаи миқдори хатогиҳои гипотезаи \mathbb{H} якбора дар ду ҳолат бошиад: ичро нагардидани нобаробарии “якчинсагӣ” дар ҳолати ду зергурӯҳи калимашаклҳо ба як гурӯҳ мансуб будан ва ичро нагардидани нобаробарии “ғайриякчинсагӣ” дар ҳолате, ки ду зергурӯҳи калимашаклҳо ба гурӯҳҳои гуногун мансуб бошанд. Онгоҳ барои γ – ҳои муайяншуда нишондиҳандай иҷроиши гипотезаҳо бо бузургии π , аз рӯйи формулаи

$$\pi = 1 - \tau(\gamma)/L,$$

муайян карда мешавад, ки дар он L – шумораи масофаҳои мутақобилаи байни ҳамаи ҷуфтҳои зергурӯҳҳои калимашаклҳои маҷмуи G (дар ҳолати мо $L = G_6^2 = 15$) мебошад. Аз ин формула бармеояд, ки π метавонад қиматҳояшро аз порчаи $[0, 1]$ қабул кунад, илова бар ин $\pi = 0$ аст, агар $\tau = L (= 15)$ ва $\pi = 1$ аст, агар $\tau = 0$ бошиад. Дар ҳолати аввал, гипотезаи \mathbb{H} бояд корношоям эътироф карда шавад ва дар ҳолати дуюм - ба намунаи омӯзишӣ комилан мувоғиқ мебошад.

Аз сабаби он, ки самаранокии γ -таснифгар аз қимати параметри γ вобаста

аст, зарур аст, ки чунин қимати онро пайдо намоем, ки барои он π қимати максималиро қабул мекунад. Мохияти танзими γ -таснифгар аз рӯйи маълумоти интихобшудаи таълимӣ маҳз аз ҳамин иборат аст. Агар чунин танзимот қобили қабул бошад, пас дар бораи ҳалли маълаи омӯзиши таснифгари γ ва моилияти он ба шинохти хушоҳангии қалимашаклҳои тоҷикӣ аз маҷмуаҳои муҳталиф сухан рондан мумкин аст.

Натиҷаҳои низомӣ дар мисоли коллексияи амсилаи G тавассути иҷрои пайдарпайи амалҳои зерин оварда мешаванд:

- ҳисобкуни симоҳои рақами (басомади унigrammaҳо) барои ҳамаи 6 зергурӯҳи қалимашаклҳои маҷмуаи амсилаи G ;
- ҳисобкуниҳои масофаи понздаҳ ҷуфтҳо $\rho(T_1, T_2)$ байни гурӯҳҳои маҷмуаи G бо формулаҳои (2.2.1), (2.2.2) ва (2.2.3) (натиҷаи ҳисобкуниҳо дар ҷадвали 2.2.2 оварда шудааст);
- ҳисобкуниӣ бо ёрии алгоритми танзими γ -таснифгар интервалӣ бехтарини қиматҳои γ , ки барои он бузургии $\tau = \tau(\gamma)$ суммаи миқдори ҳолатҳои ҳатогиҳои гипотезаи Н қимати камтаринро соҳиб мегардад ва мувофиқан бузургии π нишондиҳандай иҷрои гипотезаи Н қимати максималиро қабул мекунад.

Ҷадвали 2.2.2 – Масофаи байни гурӯҳҳои маҷмуа ва зергурӯҳҳои санҷидашаванда

Матнҳо	Гурӯҳи қалимашаклҳои душворталаффуз (G_1)			Гурӯҳи қалимашаклҳои хушоҳанг (G_2)		
	G_{11}	G_{12}	G_{13}	G_{21}	G_{22}	G_{23}
Гурӯҳи қалимашаклҳои душворталаффуз (G_1)	G_{11}					
	G_{12}	0.0423				
	G_{13}	0.1974	0.1863			
Гурӯҳи қалимашаклҳои хушоҳанг (G_2)	G_{21}	0.4708	0.4580	0.6202		
	G_{22}	0.3399	0.3270	0.4893	0.1521	
	G_{23}	0.4455	0.4327	0.5949	0.1385	0.1074

Дар ҷадвали 2.2.2 натиҷаҳои зерин ба даст омадаанд:

- маҷмуи ҳамаи ҷуфтҳои масофаҳо дар порчаи [0.0423, 0.6202] ҷойгиранд, дар ин ҳолат масофаи хурдтарин дар байни зергурӯҳҳои G_{11} ва G_{12} дар гурӯҳҳои душворталаффуз ва масофаи қалонтарин дар байни зергурӯҳҳои G_{13} дар гурӯҳи душворталаффуз ва G_{21} дар гурӯҳи хушоҳанг дидо мешаванд;
- ниминтервали оптимальии қиматҳои γ дар ҳудудҳои зерин аст

$$\gamma^{\text{опт}} \in [0.1974; 0.3270];$$

мувофиқи таърифи 3 ин маънои онро дорад, ки агар масофаи байни ду зергурӯҳи қалимашаклҳо $\rho(T_1, T_2)$ аз қимати ниминтервали нишондодашудаи $\gamma^{\text{опт}}$ зиёд нашавад, онгоҳ ҷуфтъи зергурӯҳи қалимашаклҳо ба ҳамон як гурӯҳ тааллуқ доранд; агар зиёд бошад, онгоҳ ба гурӯҳҳои алоҳида мутааллиқанд;

- қайд мекунем, ки барои ҳамаи гурӯҳҳои маҷмуаи G гипотезаи H ва амсилаи риёзии он дар намуди таърифи 3 пурра тасдиқ гардид ва аз ин рӯ ҳосил

шуд

$$\tau = \tau_{min} = 0,$$

яъне амсилаҳои математикии (2.2.4) ва (2.2.5) ичро гардианд;

- дар натиҷаи ин нишондиҳандаи самаранокӣ, кори амсилаи риёзии пешниҳодшудаи шинохти хушоҳангии калимашаклҳо баробар мебошад

$$\pi = \pi_{max} = 1.$$

Санчиши амсила. Ҳамин тавр, танзими (омӯзиши) γ -таснифгар бо додаҳои амсилаи маҷмуи матнҳои G бо муваффақият анҷом ёфт. Барои санчиши таснифгар гурӯҳи G_3 - калимашаклҳои бетараф (миёна) интиҳоб карда шудааст, ки ба қадом гурӯҳ мансуб буданашон номаълум аст. Гурӯҳи G_3 -ро низ бо ягон тарзе ба се зергурӯҳи G_{31} , G_{32} , G_{33} чудо мекунем.

Пас аз соҳтани симои рақамии зергурӯҳҳои калимашаклҳо ва ҳисобкунии масофаҳои байни онҳо аз рӯйи формулаи (2.2.3), ҷадвали масофаҳои ҳар як 6 гурӯҳи калимашаклҳои ин маҷмуа дар шакли зерин ҳосил гардид:

Ҷадвали 2.2.3 – Масофаи байни гурӯҳҳои маҷмуа ва зергурӯҳҳои санчидашаванда

Матнҳо	Гурӯҳи калимашаклҳои бетараф (G_3)		
	G_{31}	G_{32}	G_{33}
Гурӯҳи калимашаклҳои душворталафғуз (G_1)	G_{11}	0.1280	0.1155
	G_{12}	0.1127	0.1187
	G_{13}	0.2832	0.2610
Гурӯҳи калимашаклҳои хушоҳанг (G_2)	G_{21}	0.3525	0.3592
	G_{22}	0.2215	0.2283
	G_{23}	0.3272	0.3339

Дар ҷадвали 2.2.3 қатакчаҳои сатри якум ва дуюм ададҳое бо ранги ғафси моил нишон дода шудааст, ки ба масофаи ҳадди ақал аз объектҳои санчидашуда то элементҳои маҷмуаи матнҳо мувофиқат мекунанд. Натиҷаҳои бадастомада нишон медиҳанд, ки ҳамсояҳои наздиктарини сегонаи зергурӯҳҳои интиҳобшуда танҳо бо зергурӯҳҳои калимашаклҳои душворталафғуз якхела мебошанд.

Хулоса γ -таснифгар бо қимати доимии $\gamma = \gamma^{\text{опт}}$ дар гурӯҳҳои калимашаклҳои тасодуфан интиҳобгардида санчида шуд ва қобилияти шинохти худкори хушоҳангии калимашаклҳои тоҷикӣ тавассути униграммаҳо 100%-ро ташкил дод.

Дар **зербоби 2.3** амсилаи шинохти хушоҳангии калимашаклҳои тоҷикӣ ҳангоми истифодаи биграммаҳо (чуфти ҳарфҳои калимашакл) дидо баромада шуд, ки дар ин ҳолат унсурҳои γ -таснифгарро биграммаҳои: **аа, аб, ав, ..., ая, ба, бб, ..., бя, ..., яя** ва симои рақамии онҳо иборат гардид. Се гурӯҳи калимашаклҳо аз маҷмуаи матнҳо интиҳоб гардида, ҳар қадоме аз онҳо дар навбати худ боз ба се зергурӯҳ ҷудо гардидаанд. Басомадҳои ҳар яке аз 1225

биграммаҳои зергуруҳҳои калимашаклҳои аз маҷмуа интихоб гардида ҳисоб карда шуда, фосилаи байни онҳо ошкор ва байни ҳам муқоиса гардиданд. Самаранокии γ- таснифгар бо истифодаи биграммаҳо диде баромада шуда, амсилаҳои риёзӣ ва компютерии калимашаклҳо бо истифодаи биграммаҳо, ҳисоб карда шудаанд.

Дар зербоби 2.4 амсилаи шинохти хушоҳангии калимашаклҳои тоҷикӣ ҳангоми истифодаи триграммҳо (сегонаи ҳарфҳои калимашакл) диде баромада шуд, ки дар ин ҳолат унсурҳои γ- таснифгар аз триграммҳои: **ааа, ааб, аав, ..., аая, аба, абб, ..., абя, ..., яя, яяб, ..., яя** ва симои рақамии онҳо иборат гардид. Се гурӯҳи калимашаклҳо аз маҷмуаи матнҳо интихоб гардида, ҳар қадоме аз онҳо дар навбати худ боз ба се зергуруҳ ҷудо гардидаанд. Басомадҳои ҳар яке аз 42875 триграммҳои зергуруҳҳои калимашаклҳои аз маҷмуа интихобгардида ҳисоб карда шуда, фосилаи байни онҳо пайдо ва байнан муқоиса гардидаанд. Самаранокии γ- таснифгар бо истифодаи триграммҳо диде баромада шуда, амсилаҳои риёзӣ ва компютерии калимашаклҳо бо истифодаи триграммҳо, ҳисоб карда шудаанд.

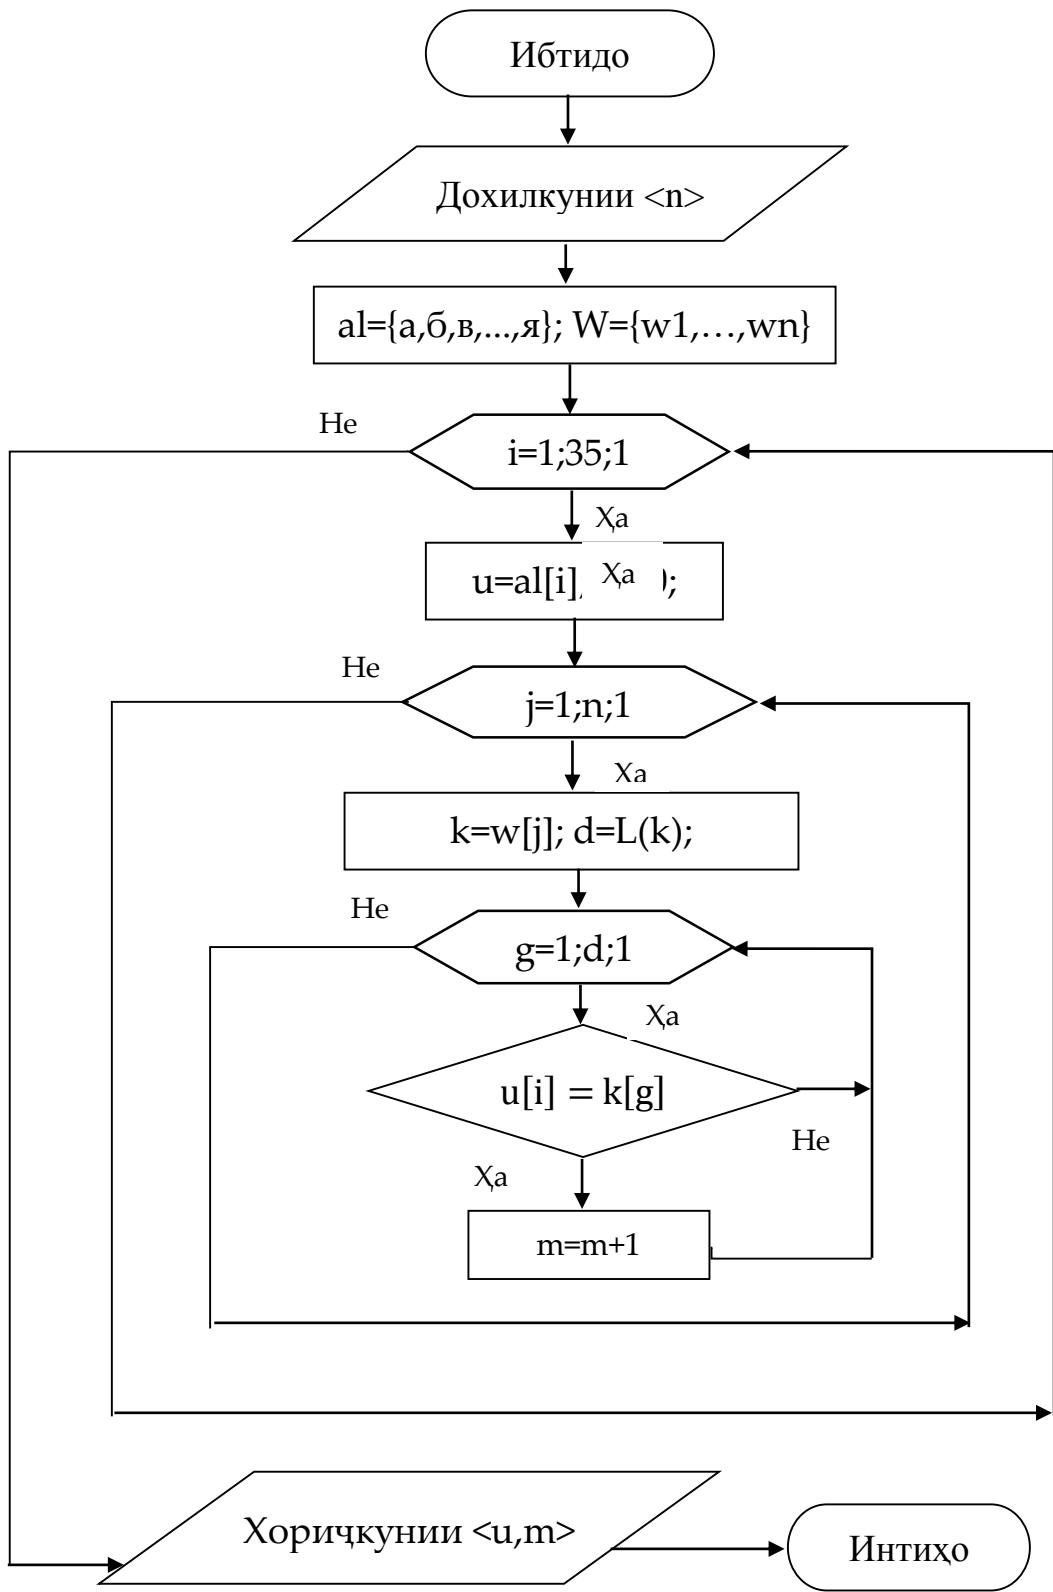
Дар зербоби 2.5 хулосаи боби дуюм оварда шудааст.

Дар боби 3 сухан дар бораи соҳтор, имконот ва татбиқи маҷмааи барномавии дар доираи диссертатсия омодагардида меравад. Маҷмааи дар доираи рисолаи илмӣ таҳиягардида “ХУШСАДО” номгузорӣ шудааст.

Дар зербоби 3.1 соҳтори маҷмааи барнома ва қисматҳои он шарҳу тавзех додашудааст. Муҷтамаи барномаи “ХУШСАДО” бо истифода аз низоми мусири барномасозии RAD Studio, маҳсулоти барномавии ширкати Embarcadero дар муҳити барномасозии Delphi, таҳия карда шудааст. Барои соҳтани муҷтамаи мазкур ҷузъҳои зерини муҳити барномасозии Delphi истифода гардидаанд: Form, Ribbon, Label, Panel, Button, Memo, ListBox, StringGrid, Splitter, ImageList, RichEdit, OpenDialog, SaveDialog, PrintDialog, ActionManager, StatusBar ва ғайраҳо. Алгоритми коркарди униграммаҳои калимашаклҳои забони тоҷикиро дар шакли блок-схема тасвир менамоем (ниг. ба расми 3).

Дар зербоби 3.2 маҷмуаи матнӣ ҷамъоваришуда тавассути нармағзори таҳиягардида коркард шудааст.

Дар зербоби 3.3 дар асоси амсилаҳои математикии шинохти хушоҳангии калимашаклҳо, ки дар боби 2 оварда шуда буданд, амсилаи иттилоотӣ (компютерӣ)-и шинохти худкори сифати овозии калимашаклҳо таҳия шудааст. Барои таҳлили фонетикий ва рентгенограммавии калимаҳоро ичро кардан фармони Тахлилро аз нармағзори Хушсадо ичро мекунем (ниг. ба расми 4).



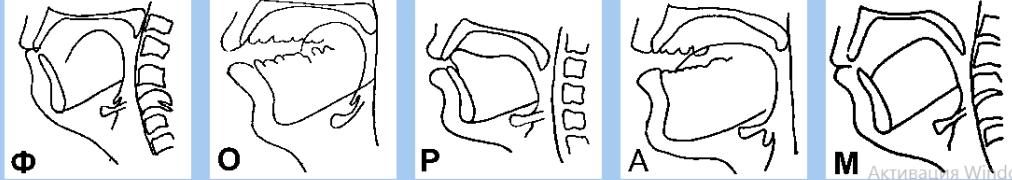
Расми 3. Блок-схемаи коркарди унigramмаҳои калимашаклҳо

Хушсадо

Меню Хушсоданий Мазъумот

Тахлил Унитрагма Биграмма Триграммма
 Тахлили хушсоданини калимаю

форам	сонории "р" қисми пеши забон ба тарафи милкҳои пеши боло бардошта мешавад. Фонемаи "а" садоноки гайрилабии дарачаи бардошти поён ва катори омехта аст. Аз ҳамсадоҳои сонорӣ ба гурӯҳи дулашибо фонемаи "м" дохил аст. Фонемаи сонории лабулабии зини "м" димофӣ буда, аз рӯйи узвҳои овозсоз бо ҳамсадоҳои "Бб" ва "п" ҳамузв мебошад.
-------	--



Активация Windows
Чтобы активировать Windows, перейдите к параметрам компьютера.

Расми 4 – Тахлили хусусиятҳои овозҳои калимашаклҳои зебо

Қисмати дигари барнома, ки ҳангоми гузариш ба речай Васеъшуда пайдо мегардад барои ҳисобкунни симоҳои рақамии ҳарф, дуҳарфӣ ва сехарфиҳои гурӯҳи калимаҳо ва масофаҳои байни зергурӯҳҳои калимаҳо пешбинӣ шудааст (ниг. ба расми 5).

Хушсадо

Меню Хушсоданий Мазъумот

Тахлил Васеъшуда Интилоҳи речо

Тахлили хушсоданини калимаю

мерезад	мотамам	худованд
обойд	навбатест	шому
ноз	зулматсӯз	худодод
нолаи	навҷавонон	хушксолӣ
сабзаи	маъзурам	шоҳӣ
равад	каҷисобиҳои	тарфи
зор	дӯстдориҳои	уммедҳои
лабҳои	масъудӣ	шамоли
канои	захмдор	

№	Уни	Бас.м	Бас.нис.	Чамъи бас.	№	Уни	Бас.м	Бас.нис.	Чамъи бас.	№	Уни	Бас.м	Бас.нис.	Чамъи б	D(n,m)= F(n) - F(m)	Dm
1	а	340	0,1318340	0,13183404	1	а	496	0,1656090	0,16560934	1	а	519	0,1624920	0,162492	0,0031171760908130	0,02
2	б	101	0,0391624	0,17099651	2	б	110	0,0367270	0,20233722	2	б	83	0,0259860	0,188478	0,01385883172016	
3	в	43	0,0166731	0,18766963	3	в	40	0,0133550	0,21569282	3	в	36	0,0112710	0,199749	0,015943290999505	
4	г	40	0,0155098	0,20317952	4	г	46	0,0153580	0,23105175	4	г	62	0,0194110	0,219160	0,011890826183903	
5	ғ	1	0,0003877	0,20356727	5	ғ	0	0	0,23105175	5	ғ	40	0,0125230	0,231684	0,00063265534396198	
6	ҳ	169	0,0655292	0,26909654	6	ҳ	173	0,0577620	0,28881469	6	ҳ	174	0,0544770	0,286161	0,00265313824021096	

Чтобы активировать Windows, перейдите к параметрам компьютера.

Расми 5 – Ҳисобкунни симои рақамии ҳарфҳо

Дар зербоби 3.4 ҳулосаҳои асосии боби сеюм пешниҳод шудаанд. Дар ҳулосаи рисола натиҷаҳои умумии таҳқиқот ҷамъбаст гардида, ҳулосаи асосӣ тартиб дода шудааст ва самтҳои асосии таҳқиқоти минбаъда вобаста ба мавзуи рисола, муайян карда шудаанд.

ХУЛОСА

Натицаҳои таҳқиқоти диссертационӣ, ҳалли нави масъалаи ҳамгирии мубрамро вобаста ба таҳияи асосҳои системаҳои шинохти худкори хушоҳангии калимашаклҳои тоҷикӣ дар худ таҷассум мекунад. Дар асоси таҳқиқотҳои гузаронидашуда чунин натицаҳо ба даст оварда шудааст:

- ✓ таҳлили масъалаи хушоҳангии матн ва роҳҳои ҳалли он дар сарчашмаҳои мавҷудбуда ва таҳияи асосҳои андозагирии хушоҳангии калимашаклҳои забонҳои табиӣ, аз ҷумла забони тоҷикӣ [1-М, 2-М, 11-М];
- ✓ коркарди компьютерии матни Гулистони Саъдӣ, ошкор намудани маълумоти оморӣ ва хусусиятҳои ҳамнишинии овозҳои таркиби калимаҳои он [3-М];
- ✓ маҷмуаи матни калонҳаҷм интиҳоб гардида, элементҳои он: униграмма, биграмма ва триграммро аз нуқтаи назари математикӣ ва компьютерӣ таҳқиқ гардидаанд [4-М, 5-М, 6-М];
- ✓ пайдо намудани аломатҳои душворталафғузӣ дар асосӣ пурсиши соҳибони забон, таснифи калимашаклҳои тоҷикӣ ва таҳия намудани барномаҳои компьютерии тавсифи аломатҳо [7-М, 8-М];
- ✓ ҳизои тоҷикӣ таҳқиқ гардида, алгоритм ва барномаи ҷудокунии ҳизоҳои калимаҳои тоҷикӣ таҳия карда шудааст [10-М, 12-М];
- ✓ барои ҳалли масъалаи шинохти худкори хушоҳангии калимашаклҳои забони тоҷикӣ маҷмааи барномавӣ дар забони барномасозии Delphi соҳта шудааст [13-М].

ТАВСИЯҲОИ АМАЛӢ ДАР АСОСИ НАТИЦАҲОИ ТАҲҚИҚОТ

Натицаҳои таҳқиқотро барои ҳалли масъалаҳои забоншиносӣ ва адабиётшиносӣ, гузаронидани озмоишҳои гуногуни сухансанҷии масъалаҳои мушахҳас, системаҳои фонетикӣ ва системаҳои таълимию назоратӣ истифода бурдан мумкин аст. Натицаҳои ҳисобкуниҳои компьютерӣ нишон медиҳанд, ки барои таснифи калимашаклҳо ба синфҳо муайян кардани хусусиятҳои сифатию миқдории онҳо аҳамияти калони амалӣ дорад. Гуфта мешавад, ки натицаҳои таҳқиқоти кори диссертационӣ барои хондани курсҳои маҳсус («Усулҳои таҳлили матн дар компьютер», «Асосҳои лингвистии тарҷумаи мошинӣ», «Технологияҳои компьютерӣ дар тадқиқотҳои забоншиносӣ»), иҷрои корҳои лабораторӣ ва мустақилона, курсӣ, дипломӣ ва магистрӣ барои донишҷӯён ва магистрҳои самтҳои «Информатика», «Забоншиносии компьютерӣ» ва «Забоншиносӣ ва технологияҳои нави иттилоотӣ» дар донишгоҳҳои Ҷумҳурии Тоҷикистон, истифода мешавад.

Маҷмааи барномаи компьютерии дар доираи диссертатсияи мазкур соҳташуда барои истифодабарӣ дар соҳаҳои илму маориф, фарҳанг, забоншиносӣ, адабиётшиносӣ, системаҳои компьютерии коркарди матн ва шинохти худкори хушоҳангии калимашаклҳои тоҷикӣ, системаҳои зеҳни

сунъӣ ва омӯзиши мошинӣ барои ҳалли масъалаҳои мубрами забоншиносии компьютерӣ пешбинӣ карда шудааст.

ФЕҲРИСТИ ИНТИШОРОТИ ИЛМИИ ДОВТАЛАБИ ДАРЁФТИ ДАРАҶАИ ИЛМИЙ

a) Мақолаҳое, ки дар нашрияҳои тақризшавандай Комиссияи олии аттестацонии назди Президенти Ҷумҳурии Тоҷикистон чоп шудаанд:

[1 – М] Пиров С.М. К разработке основ эвфонометрии слов [Текст] / З.Д. Усманов, С.М. Пиров // Известия Академии наук Республики Таджикистан. Отделение физико-математических, химических, геологических и технических наук. - 2015. - №3 (160). - С. 39-42.

[2 – М] Пиров С.М. Дар бораи баъзе масъалаҳои хушоҳангии матнҳои тоҷикӣ [Матн] / С.М. Пиров // Паёми Донишгоҳи миллии Тоҷикистон. -2017, -№ 4-3. -С.105-109.

[3 – М] Пиров С.М. Таҳқиқи биграммаҳои “Гулистон”-и Саъдии Шерозӣ [Матн] / С.М. Пиров // Паёми Донишгоҳи миллии Тоҷикистон. -2017, -№ 1/5. - С.156-159.

[4 – М] Пиров С.М. Алгоритм распознавания благозвучия таджикских слов при использовании униграмм [Текст] / С.М. Пиров // Доклады Национальной академии наук Таджикистана. -2022, т. 65, № 1-2. С.57-62.

[5 – М] Пиров С.М. Алгоритми шинохти хушоҳангии қалимаҳои тоҷикӣ бо истифодаи биграммаҳо [Матн] / С.М. Пиров // Паёми ДМТ, баҳши илмҳои табии. -2022. -№2. - С. 102-111.

[6 – М] Пиров С.М. Алгоритм распознавания благозвучия таджикских слов при использовании триграмм [Текст] / С.М. Пиров // Вестник, Филиала МГУ им. В.М.Ломоносов в г.Душанбе, раздел информатика. -2023, Том 1, -№1 (29). -С. 35 - 42.

б) Мақолаҳое, ки дар дигар нашрияҳо ба табъ расидаанд:

[7 – М] Пиров С.М. Дар бораи гурӯҳбандии қалимаҳои забони тоҷикӣ аз рӯйи талаффузашон [Матн] / С.М. Пиров // РТСУ. Перспективы развития фундаментальных и прикладных лингвистических исследований в Республике Таджикистан. – Душанбе: Персис, 2016. - 1(7). -С. 16 -18.

[8 – М] Пиров С.М. Дар бораи маҷмӯи аломатҳои тавсифкунандаи хушоҳангии қалимаҳои тоҷикӣ [Матн] / С.М. Пиров // Маводи конференсияи илмӣ-амалии байналмилалӣ. ДТГ. -Душанбе -2017. -С. 352-355.

[9 – М] Пиров С.М. Басомади биграммаҳои ҳарфҳои тоҷикӣ [Матн] / С.М. Пиров // Маводи Конференсияи ҷумҳуриявии илмию назариявии ҳайати устодону кормандони ДМТ баҳшида ба ҷашнҳои «5500-солагии Саразми бостонӣ», «700-солагии шоири барҷастаи тоҷик Камоли Ҳуҷандӣ» ва «20-

солаи омӯзиш ва рушди фанҳои табиатшиносӣ, дақиқ ва риёзӣ дар соҳаи илму маориф (солҳои 2020-2040)». – Ҷилди 1. -2020. -С. 39-40.

[10 – М] Пиров С.М. Алгоритми содаи ба ҳичоҳо ҷудокунии калимаҳои тоҷикӣ [Матн] / С.М. Пиров // Маводи конференсияи байналмилалии илмӣ-амалӣ дар мавзӯи «Муаммоҳои муосири математика ва татбиқи он» баҳшида ба «Солҳои 2020-2040 эълон гардидани 20-солаи омӯзиш ва рушди илмҳои табиатшиносӣ, дақиқ ва риёзӣ». -2022. -С. 158-161.

[11 – М] Пиров С.М. Таҳлили моделҳои баҳодиҳии хулоҳангии матнҳо [Матн] / С.Х. Мирзоев, С.М. Пиров // Маводи конференсияи байналмилалии илмӣ-амалӣ дар мавзӯи «Таҳлили компютерии масъалаҳои илм ва технология» баҳшида ба «Солҳои 2020-2040 эълон гардидани 20-солаи омӯзиш ва рушди илмҳои табиатшиносӣ, дақиқ ва риёзӣ дар соҳаи илму маориф» ва «75-солагии Дошишгоҳи миллии Тоҷикистон». -2023. -С. 396-404.

Шаҳодатномаҳо дар бораи бақайдгирии давлатии барномаи компютерӣ барои МЭҲ:

[12-М]. Пиров С.М. Шаҳодатнома. Ҷудокунии ҳичоҳои калимаҳои тоҷикӣ / С.М. Пиров // Свидетельство об официальной регистрации программы для ЭВМ в отделе по правам и защите прав автора Министерства культуры Республики Таджикистан (№ 150, 9.11.2022г.).

[13-М]. Пиров С.М. Автоматизированная система анализа текстов и оценка благозвучия таджикских слов [Текст] / С.Х. Мирзоев, А.А. Косимов, С.М. Пиров// Свидетельство о государственной регистрации информационного ресурса №1202500527 от 28.02.2025 внесен в реестр информационных ресурсов Республика Таджикистан.

**МИНИСТЕРСТВО ОБРАЗОВАНИЯ И НАУКИ РЕСПУБЛИКИ
ТАДЖИКИСТАН
ТАДЖИКСКИЙ НАЦИОНАЛЬНЫЙ УНИВЕРСИТЕТ**

УДК: 004.5.7.9+519.25+811.21/.22

На правах рукописи

ББК: 22.18 (2Т)

П - 33



ПИРОВ САИДАЛИ МИРЗОАЛИЕВИЧ

**РАЗРАБОТКА И ИССЛЕДОВАНИЕ КОЛИЧЕСТВЕННЫХ
КРИТЕРИЕВ ДЛЯ ОЦЕНКИ БЛАГОЗВУЧИЯ ТАДЖИКСКИХ СЛОВ**

А В Т О Р Е Ф Е Р А Т

**диссертации на соискание учёной степени кандидата технических
наук по специальности 05.13.11 – «Математическое и программное
обеспечение вычислительных машин, комплексов и компьютерных
сетей»**

Душанбе, 2025

Работа выполнена на кафедре «Информационные и коммуникационные технологии» механико-математического факультета Таджикского национального университета.

Научные руководители:

Усмонов З.Ч. доктор физико-математических наук, академик НАНТ, профессор

Мирзоев С.Х. доктор технических наук, доцент кафедры информатики Таджикского национального университета

Официальные оппоненты

Муминов Баходир Болтаевич – доктор технических наук, профессор, заведующий кафедрой искусственного интеллекта Ташкентского государственного экономического университета

Гафуров Миршафи Хамитович – кандидат технических наук, доцент кафедры “Информационная технология и защита информации” Таджикского технического университета имени академика М.С. Осими

Ведущая организация

Институт математики имени А. Джураева
НАНТ

Защита состоится «16» мая 2025 года в «14:00» на заседании Диссертационного Совета 6D.KOA-049 при Таджикском техническом университете имени академика М.С. Осими по адресу: 734042, г. Душанбе, проспект академиков Раджабовых, 10.

С диссертацией можно ознакомиться в библиотеке Таджикского технического университета имени академика М.С. Осими и сайте <http://ttu.tj>.

Автореферат разослан «___» _____ 2025 года в соответствии с утвержденным реестром.

Ученый секретарь диссертационного совета 6D.KOA-049,
кандидат технических наук, доцент



Султонзода Ш.М.

Введение

Актуальность темы исследования. История показывает, что во все времена ученые и исследователи уделяли особое внимание вопросу чистоты языка и сегодня продолжают эту главную обязанность. Защита языка от различных внешних дефектов, особенно сочетание и несогласие звуков словесного состава, является важнейшей задачей каждого индивидуума общества, в том числе творческих людей и интеллигентов, а обеспечение его красоты и чистоты — одним из требований благозвучия в науке анализа речи. Этот момент четко отмечен в книге Лидера нации «Мудрые слова Президента Эмомали Рахмона о языке. Уместно процитировать его здесь: «Содержать язык в чистоте, сохранять его подлинность и благозвучность – сыновний долг каждого из нас. Поэтому наши ученые и интеллигенты должны серьезно заняться исследованием важнейших вопросов языка, обновлять и создавать словари и энциклопедии, которые необходимы для повышения уровня знаний языка и культуры изучения языков нынешнего и будущих поколений».

С появлением первых компьютерных программ появилась и идея обработки, хранения, анализа, произнесения и перевода текстов. Для обработки текстовой информации разработаны различные программы, решающие важнейшие задачи лингвистической науки. Одной из таких задач является задача благозвучия или удобочитаемости текстов и их оценка с помощью компьютера, которая решена для некоторых языках мира. Например, в офисном пакете Office от корпорации Microsoft есть инструмент, который собирает статистику удобочитаемости и, помимо оценки лёгкости чтения и подсчёта количества сложных фраз, способен оценивать благозвучие.

Слово, выражение или текст называется благозвучным, если в его составе отсутствуют уникальные согласные, согласные из одного артикуляционного органа или из близких артикуляционных органов. В составе благозвучных слов гласных звуков больше, чем согласных и гласные звуки могут иметь до трёх открытых слогов. Для сохранения чистоты и благозвучия таджикского языка необходимо разработать стандарты, математические модели и специальные компьютерные системы с использованием всех средств, особенно современных информационных технологий. Данное исследование в основном сосредоточено на разработке основ системы автоматического распознавания эвфонии таджикских словоформ, основой которой является γ-классификатор.

Хотя критерии благозвучности не формализованы в некоторых языках, они существуют. Например, важнейшими критериями благозвучности текста являются: слоговая структура, соотношение низких и высоких звуков, доля звонких согласных, свистящих звуков и сочетание согласных. Вопрос красоты текста — очень сложный вопрос, и даже жители одного региона могут по-разному понимать красоту речи. Здесь необходимо учитывать множество факторов, на основе которых строится фундамент понимания каждого человека в отдельности. Кроме того, существует ряд особенностей, влияющих

на качество информации из того или иного источника (например, в тексте может быть шрифт, качество бумаги в книге, голос и тон в речи).

Степень изученности и разработанности темы исследования.

Источники показывают, что первые мыслители Древней Греции начали изучать ораторское искусство и обсуждали его. Труд Аристотеля «Риторика» (Речь) является ярким доказательством этих утверждений. Относительно вопроса чистоты языка мыслители востока, такие как Абуали ибн Сина, Шамс Кайс Рази, Асади Туси, Шамс Гургони, Т. Зехни, Х. Шарифов, М. Шукuroв, Б. Камолиддинов и др. написали множество работ, которые считаются важнейшими источниками изучения различных сторон этого вопроса.

С начала прошлого века и по сегодняшний день разнообразные свойства фонетики современного таджикского литературного языка изучают известные учёные этой области И.И. Зарубин, Л. Бузургзода, В.С. Соколова, В.С. Растворгуев, Ш. Бобомуродов, Т.Н. Хаскашев, М. Файзов, А. Неъматов, Ш. Кабиров и их ученики. Профессор Т.Н. Хаскашев и М. Файзов внесли огромный вклад в изучение и развитие фонетики современного таджикского литературного языка. Этими отечественными исследователями проведены ценные научные, теоретические и практические анализы и сравнения в науке о таджикской фонетике, выявлены физиологические и акустические характеристики звуков таджикского языка с использованием специальных инструментов (рентгенограмма, политограмма и др.), используемых в области медицины и др.

Многие ученые, такие как Rudolf Flesch, Gunning R., Kincaid J., Spache G., Fry E., Hedman S., McLaughlin, G., В. Франчина, Р. Вакка, Оборнева И. В., Иванов К.В., Фомин А.Ю. и другие занимались изучением данного вопроса с применением математики и информационных технологий и разработали математические модели для оценки и анализа текстов на английском, итальянском, русском и других языках по различным параметрам и достигли значительных результатов, которые используются в крупнейших мировых компаниях, таких как Microsoft, национальных корпусах языков мира, географических и международных сайтах, различными министерствами и учреждениями.

В Республике Таджикистан в области обработки естественного языка, а именно таджикского языка, ученые Усмонов З.Дж., Исмоилов М.А., Тошхуджаев К.А., Умаров М.А., Зарипов С.А., Шарифофф Ш., Гращенко Л.А., Худойбердиев Х.А., Солиев О.М., Давудов Г.М., Касимов А.А., Каюмов М.М. и другие проводят исследования вместе со своими учениками.

Создание компьютерного инструментария для автоматического распознавания качества звучания слов обеспечивает возможность составления эвфонометрического словаря, который может быть полезным дополнением к лингвистическому корпусу таджикского языка. Успехи в разработке основ эвфометрии слов неизбежно повлекут за собой ускоренное развитие систем автоматической оценки благозвучия предложений, текстов, произведений, учебников и творчества авторов.

Связь исследования с программами (проектами) или научными темами: Данное исследование выполнено в рамках реализации плана научно-исследовательской работы кафедры информационных и коммуникационных технологий механико-математического факультета Таджикского национального университета бюджетной темы «Применение математических методов и новых информационных технологий в сфере лингвистики и изучения методов алфавитного кодирования» (государственный регистрационный номер № 0122TJ14117 (01.01.2021-31.12.2025)) и исследовательского проекта «Применение методов моделирования и новых информационных технологий в сфере образования и лингвистики» (государственный регистрационный номер № 0116TJ00661 (01.01.2016-31.12.2021)).

ОБЩАЯ ХАРАКТЕРИСТИКА РАБОТЫ

Цель работы. Разработка основ системы автоматического распознавания благозвучия словоформ таджикского языка и применение ее в виде комплекса программного обеспечения.

Задачи исследования. Для достижения цели решаются следующие задачи:

- сбор и подготовка коллекции текстов для изучения и осуществления научных экспериментов разного типа, в том числе определения благозвучия словоформ;
- исследование информативности признаков, которые предназначены для распознавания и определения благозвучия словоформ;
- проверка эффективности математических методов, применяемых для распознавания благозвучия словоформ;
- исследование эффективности применения высокочастотных элементов алфавита символьных N -грамм для распознавания словоформ;
- проектирование и применение комплекса программного обеспечения для автоматизированного различения эвфонии таджикских слов.

Объект исследования. В качестве объекта исследования определены математические и компьютерные модели анализа и оценки множества печатных словоформ таджикского языка.

Предмет исследования. Автоматическое распознавание благозвучия таджикских словоформ на основе признаков и частотности его N -грамм.

Методы исследования. Для решения целей и задач, поставленных в исследовании, используются фонетические методы, методы математической статистики, вычислительного эксперимента, теории множеств, системного анализа, распознавания, математическое и компьютерное моделирование и объектно-ориентированное программирование для разработки программных средств.

Теоретические основы исследования. Теоретическую основу диссертации составляют научные источники наших предков, научные

результаты ученых разных эпох и времен, имеющие отношение к теме диссертации.

Научная новизна работы. Основные результаты диссертации являются новыми и заключаются в следующем:

- исследована информативность признаков на предмет количественного описания таджикских словоформ;
- установлена эффективность использования N -грамм ($N=1,2,3$) в качестве символов, идентифицирующих словоформы;
- установлена эффективность модификатора З.Д. Усманова, способного распознавать с точностью до 96% благозвучие коллекции словоформ;
- с целью существенного сокращения объёма вычислительных процедур установлена возможность эффективного использования не всех, а только высокочастотных элементов алфавита буквенных N -грамм ($N=1, 2, 3$);
- впервые в Таджикистане создан объектно-ориентированный компьютерный программный комплекс для распознавания благозвучия таджикских слов.

Положения, выносимые на защиту:

- 1.Признаки труднопроизносимых и благозвучных таджикских словоформ;
- 2.Количественный образ таджикских словоформ, характеризующий благозвучие в виде распределения частотностей буквенных N -грамм($N=1,2,3$);
- 3.Эффективность применения модификатора З.Д. Усманова, как нового и соответствующего метода распознавания благозвучия таджикских словоформ;
- 4.Возможность эффективного использования не всех, а только высокочастотных элементов алфавита буквенных N -грамм ($N=1, 2, 3$) с целью существенного сокращения объёма вычислительных процедур для определения благозвучия слов;
- 5.Современный комплекс компьютерных программ для автоматического распознавания благозвучия таджикских словоформ.

Теоретическая и практическая значимость исследования.

Теоретическая значимость работы состоит в том, что в ней экспериментально апробирован новый метод классификации дискретных случайных величин и установлена эффективность его применения для целей распознавания благозвучия печатных таджикских словоформ с буквенным алфавитом. Практическая значимость работы заключается в том, что она предназначена для реализации созданного в ней комплекса компьютерных программ в области науки и образования, культуры, языкоznания, литературоведения и компьютерных систем обработки текстов для автоматического распознавания благозвучия таджикских словоформ.

Степень достоверности результатов диссертации. Полученные результаты подтверждаются серией вычислительных экспериментов по идентификации с достаточно высокой точностью различных коллекций текстов.

Соответствие диссертации паспорту научной специальности. Содержание исследования данной диссертации соответствует пунктам 1, 4 и 7 паспорта специальности 05.13.11 – «Математическое и программное обеспечение вычислительных машин, комплексов и компьютерных сетей»:

П.1.Модели, методы и алгоритмы проектирования и анализа программ и программных систем, их эквивалентных преобразований, верификации и тестирования;

П.4.Системы управления базами данных и знаний;

П.5.Человеко-машические интерфейсы; модели, методы, алгоритмы и программные средства машинной графики, визуализации, обработки изображений, систем виртуальной реальности, мультимедийного общения.

Личный вклад соискателя учёной степени. Постановка задачи и выбор методов исследования осуществлялись соискателем под руководством научных руководителей. Основные результаты диссертационной работы получены автором самостоятельно.

Апробация результатов работы. Материалы работы представлены и обсуждались на:

- научно-исследовательских семинарах Таджикского национального университета, Таджикского технического университета имени академика М.С. Осими, Технологического университета Таджикистана и Российско-Таджикского (Славянского) университета в период 2014-2023 гг.;

- международной научно-практической конференции «Перспективы развития науки и образования», 2016 г., Душанбе;

- международной научно-практической конференции «Роль ИКТ в инновационном развитии экономики Республики Таджикистан», 2017 г., Душанбе;

- международной научной конференции «Современные проблемы математики и их приложения», 14-15 июня 2017 г., Душанбе, Кулъаб;

- международной научно-практической конференции «XII Ломоносовские чтения», посвященной Дню таджикской науки и 30-летию установления дипломатических отношений между Республикой Таджикистан и Российской Федерацией (29-30 апреля 2022). Часть I. Естественные науки. – Душанбе, 2022;

- международной научно-практической конференции “Современные проблемы математики и её приложения”, посвященной 20-летию развития естественных, точных и математических наук 2020-2040 годы. -Душанбе - 2022;

- международной научно-практической конференции «Компьютерный анализ проблемы наука и технология» посвященной «2020-2040 годы объявлены двадцатилетием изучения и развития естественных, точных и математических наук» и «75-летию Таджикского национального университета». -Душанбе -2023.

Публикации по теме диссертации. По теме диссертации опубликовано 13 работ, из них 6 статей в журналах из перечня, рекомендованного ВАК при

Президенте Республики Таджикистан, [1-А - 13-А].

Структура и объём диссертации. Диссертация состоит из введения, трех глав, заключения и библиографического списка. Библиографический список включает 137 наименований. Основная часть диссертации изложена на 143 страницах. Диссертация содержит 59 рисунков и 13 таблиц.

Автор выражает свою особую признательность и благодарность научными руководителям – доктору физ.-мат. наук, профессору, академику НАНТ, глубокоуважаемому Усманову З.Д. и доктору технических наук, доценту Мирзоеву С.Х., а также сотрудникам Таджикского национального университета, Института математики имени А. Джураева НАНТ и Таджикского технического университета имени академика М.С. Осими.

ОСНОВНАЯ ЧАСТЬ ИССЛЕДОВАНИЯ

Введение диссертации включает в себя обоснование актуальности выбранной темы диссертации, определение цели, задач, объекта и предмета исследования, раскрытие новизны, изложение теоретической и практической значимости работы, положения, вынесенные на защиту, описание методологической базы и материал исследования, сведения об апробации работы и ее структуре.

В **главе 1** рассматриваются проблема благозвучия текстов, анализируются существующие методы её решения, аспекты появления звуков речи и их физические и фонологические характеристики.

В **подглаве 1.1** исследованы мнения исследователей разных эпох и времен из области филологии, математики и информационных технологий о вопросе благозвучия и трудного произношения слов.

В **подглаве 1.2** рассматриваются аспекты появления звуков речи. Фонетический строй языков человеческого общения имеет очень сложную природу, поэтому необходимо изучать различные его аспекты. Наша речь, прежде всего, является акустическое явлением и имеет физическую природу. Каждое акустическое событие происходит в определенное время и с силой и скоростью, свойственным ему.

На физической и акустической основе анализируются и исследуются физическая природа звуков речи и их характеристики: длина, уровень тона и силы, формантная и спектральная структура. Исследуются и сравниваются эти физические признаки звуков речи в разных фонетических состояниях и ситуациях, а также определяется степень владения ими этими характеристиками по сравнению с другими звуками. На этих признаках основана и акустическая классификация звуков.

Звуки, которые мы слышим, имеют источник и причину появления. Источником и причиной появления звуков речи является речевой аппарат человека и работа его органов (см. рисунок 1).

Основной частью гортани, играющей важную роль в звукообразовании, являются голосовые связки. Голосовые связки способны вибрировать примерно от 40 до 1700 раз в секунду, но при нормальной речи их пульсация

равна 85-200 (в мужской речи) или 160-340 (в женской речи) колебаний в секунду. Мужские голосовые связки толще, а женские тоньше, поэтому количество голосовых колебаний у мужчин ниже, а у женщин выше.

Каждый язык имеет свою систему звуков, которые создаются с помощью разных органов. Активными голосовыми органами таджикского языка являются: голосовые связки, стенки гортани, мягкое небо с языком, язык и губы, которые в большей степени способствуют образованию звуков. Например, из 30 фонем (звуков) таджикского языка 20 фонем (66,7%) находятся в передней части языка и только 10 других фонем: гласные у, ў, о и согласные г, к, х, ф, қ, ъ, ҳ (33,3%) создаются в задней части языка. К пассивным голосовым органам относятся твердое небо, зубы, десны и полость носа.

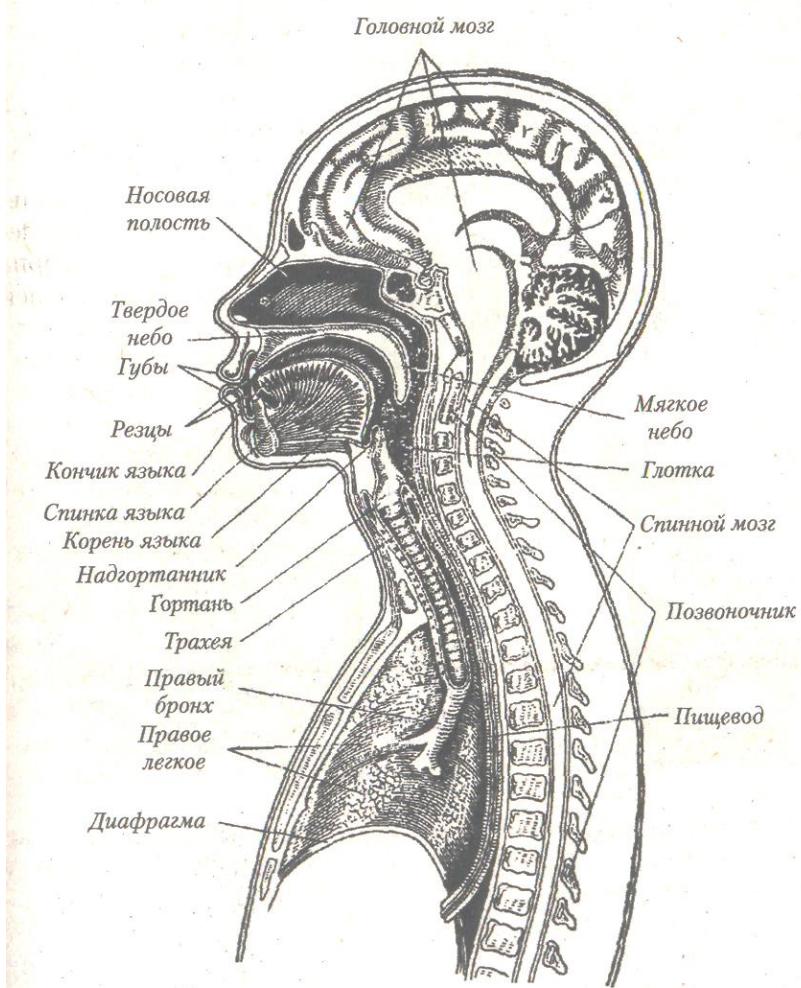


Рисунок 1 - Речевой аппарат

Хотя особенности речевого аппарата таджикского языка еще не исследованы, о некоторых из них имеются предварительные сведения. Одной из таких особенностей, принадлежащих голосовой системе таджикского языка, является музыкальная особенность – благозвучие. Благозвучие – это идеальное сочетание голосов, которое приносит легкость говорящему и удовольствие слушателю. Требования к произношению должны быть

конкретными в соответствии с фонетическими характеристиками языка. Благозвучие всегда зависит от фонетического разнообразия национального языка.

В подглаве 1.3 рассматриваются физические свойства звуков, особенно звуки таджикского языка.

В подглаве 1.4 речь идёт об артикуляционной характеристике таджикских звуков. Современный алфавит таджикского литературного языка состоит из 35 букв и 30 звуков (фонем), которые делятся на две основные группы: 1) гласные и 2) согласные. В произношении гласных звуков никаких препятствий нет. Кроме того, гласные отличаются от согласных и другими характеристиками. Поскольку в произношении гласных нет никаких препятствий, можно сказать, что это приятные звуки. Согласных относительно больше, и они играют важную роль в организации слов и текста. При произношении согласных они сталкиваются с различными препятствиями, которые в той или иной степени становятся на пути голосового потока и вызывают затруднения в произношении. Проблема нарушения гармонии словоформ зависит и от количества согласных. Чтобы внести ясность в то, о чём мы говорим, приведем план органов речи, полученный с помощью аппарата рентгенограммы (см. рисунок 2).

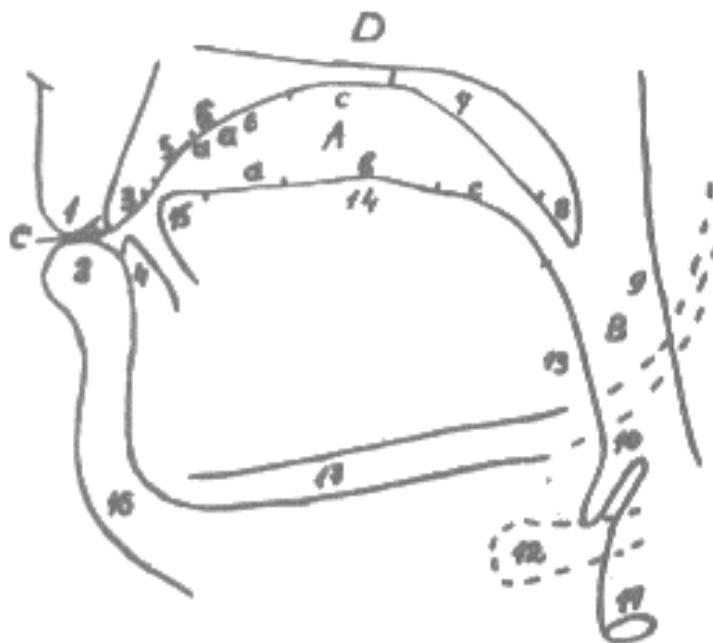


Рисунок 2 - Отображение органа речи на рентгенограмме

На рентгенограмме, приведенной на рисунке 2 органы произношения обозначены цифрами, а полости речевого аппарата – буквами. А – Полость рта, Б – полость глотки, С – полость дверца рта, Г – полость носа. Цифрами указаны: 1 – верхняя губа; 2 – нижняя губа; 3 – верхние зубы; 4 – нижние зубы; 5 – голосовые связки; 6 – твердое нёбо: а) передняя часть, в) средняя часть, в)

задняя часть; 7 – мягкая нёбо; 8 – язычок; 9 – стенка глотки; 10 – надгортанник; 11 — гортань; 12 – подъязычная кость; 13 – корень языка; 14 – спинка языка; а) передняя часть спинки языка, в) средняя часть спинки языка, в) задняя часть спинки языка; 15 – кончик языка; 16 – подбородок; 17 – нижняя челюсть.

Подглава 1.5 первой главы включает в себя вывода, сделанные по итогам данной главы.

Глава 2 посвящена исследованию вопросов формирования основ эвфонометрии таджикского языка, использования математических и компьютерных моделей с применением элементов униграмм, биграмм и триграмм.

В **подглаве 2.1** рассматривается формирование основ эвфонометрии таджикского языка. Эвфония (благозвучие) – понятие *качественное*, ибо всякий индивид по-своему оценивает звучание слова, предложения, стихотворения, текста и речи. Вместе с тем рассматриваемое понятие – *статистическое*, поскольку совокупность индивидов относительно одних и тех же объектов во многих случаях высказывает “общее” мнение. Этот факт служит основой для развития эвфонометрии – новой научной дисциплины, нацеленной на изучение закономерностей благозвучия письменной и устной речи математико-статистическими методами. Практическая значимость таких исследований заключается в несомненном влиянии качества звучания речи на результаты восприятия информации.

Первый этап разработки основ эвфонометрии начинается с создания или же с обращения к уже имеющейся **коллекции текстов** (ещё лучше к лингвистическому корпусу) того или иного естественного языка. Коллекция должна быть достаточно представительной, включать в надлежащих пропорциях художественную литературу, газетные и журнальные статьи, научные и научно-популярные тексты из разных областей знаний, общественно-политические произведения, драматургию и т.п. Желательно, чтобы объём коллекции исчислялся десятками миллионов словоупотреблений.

На основе 20 произведений персидско-таджикских писателей разных эпох и произведений разных жанров мы составили коллекцию текстов, состоящую из 6811 электронных страниц и содержащую 2206587 слов. Статистические результаты данного исследования представлены в таблице 2.1.1.

Таблица 2.1.1.
Статистика исследуемой коллекции текстов

№	Номи адаб	Номи асар	Миқдори сахифа	Миқдори калима
1	Абдурамони Чомӣ	Баҳористон	139	31 934
2	Саъдии Шерозӣ	Гулистон	150	39 589
3	Носири Хисрав	Сафарнома	100	34 523
4	Ибни Мукаффаъ	“Калила ва Димна”	120	39 647
5	Садриддин Айнӣ	«Марғи судҳӯр»	220	57 926

6	Ҳусайн Воизи Кошифӣ	Футувватнома	336	93 874
7	Муҳаммадиев Ф.	Шаби савум	288	94 952
8	Меҳмон Бахтӣ	Тилисми Сайхун	45	12 020
9	Сорбон	Романи Туғрал	190	57 876
10	Муҳаммадҷони Шакурии Бухорӣ	Садри Бухоро	188	112 709
11	Муҳаммадҷони Шакурии Бухорӣ	Хуросон аст ин ҷо	361	92 104
12	Ҷалолуддини Балҳӣ	800 ғазали дилошӯб	287	83 215
13	Эмомалӣ Раҳмонов	Нигоҳе ба таъриҳ ва тамаддуни ориёй	371	144 387
14	Ғафуров Б.Ғ.	Тоҷикон	870	305 673
15	Лоиқ Шералӣ	Куллиёт	830	210 713
16	Абулқосим Фирдавсӣ	Шоҳнома. Ҷилди 1	277	57 694
17	Худойназар Асозода	Достони зиндагӣ (китоби 4-ум)	321	145 205
18	Худойназар Асозода	Достони зиндагӣ (китоби 5-ум)	480	223 087
19	Абулғазли Байҳақӣ	Таърихи Байҳақӣ	756	235 890
20	Маҷлиси Олии ҶТ	Кодекси андоз	482	133 569
			6811	2 206 587

На основе результатов опроса общественного мнения, проведенного посредством анкеты, словоформы были разделены на три класса. Респонденты ставили справа от каждой словоформы из списка \bar{L} одну из трех цифр: -1, +1 и 0, которые кодируют качественные признаки, соответствующие звукам «трудный», «приятный» и «средний». Выбранные словоформы мы предъявляли экспертом (лингвистам), они присваивали каждому слову одну из трех цифр: -1, +1 или 0, соответствующих знаков качества произношений «трудный», «приятный» и «средний» для их кодирования. Экспертам была представлена анкета объемом шесть печатных страниц в виде таблицы.

Эксперт исследует словоформы в анкете, если она трудна в произношении, то справа от нее ставит цифра -1, если произношение словоформы не сложное, не приятное, а среднее, то цифра 0 – справа от него, и если произношение слова приятное, то рядом пишет цифру +1.

На основе различных особенностей звуков таджикского языка, закономерностей их сочетания, опроса носителей языка и компьютерной обработки словоформ мы выявили 16 признаков, описывающих различное звуковое качество словоформ таджикского литературного языка. Признаки, выбранные для количественного и качественного описания благозвучия словоформ, представлены в таблице 2.1.2 с их возможными значениями.

Таблица 2.1.2.

Признаки количественных и качественных характеристик словоформ.

№	Признак словоформ	Возможные значения	Число позиций признака
1	Длина (количество букв)	От 1 до 30	2
2	Число гласных	От 1 до 15	2

3	Число согласных	аз 1 то 15	2
4	Согласный F	От 1 до 15	1
5	Согласный Ж	1-да, 0-нет	1
6	Согласный Қ	1-да, 0-нет	1
7	Согласный X	1-да, 0-нет	1
8	Согласный Ч	1-да, 0-нет	1
9	Согласный Ь	1-да, 0-нет	1
10	Биграмма НГ	1-да, 0-нет	1
11	Биграмма НД	1-да, 0-нет	1
12	Биграмма РД	1-да, 0-нет	1
13	Биграмма СТ	1-да, 0-нет	1
14	Биграмма ФТ	1-да, 0-нет	1
15	Биграмма ХТ	1-да, 0-нет	1
16	Биграмма ШТ	1-да, 0-нет	1

В подглаве 2.2 рассмотрена модель распознавания благозвучия таджикских словоформ с использованием униграмм. В этой и последующих подглавах данной главы используется системный подход, который был предложен в 2015 году для разработки основ эвфонометрии естественных языков, в том числе таджикского языка, которой может быть применен к различным естественным языкам. В основе этого подхода лежит γ-классификатор дискретных случайных величин, разработанный академиком НАНТ Усмоновым З.Дж. Упомянутый классификатор может быть использован для решения различных задач лингвистической науки и выявления характеристик различных текстовых единиц, в том числе для определения произношения словоформ. В этой части работы для определения звукового качества словоформ мы используем упомянутый выше классификатор, который представляет собой математическую триаду, состоящую из трех частей:

- цифровой портрет (ЦП), т.е. количественное описание словоформ;
- формулы расстояния между ЦП словоформы;
- алгоритм принятия решения на основе образов.

Мы используем этот классификатор для автоматического распознавания голосовых качеств определенного набора словоформ: поэтического или прозаического произведения, заранее выбранного из корпуса текстов. Корпус текстов – это совокупность текстов разных жанров, хранящихся в электронном виде. Корпус текстов используется для проведения различных исследований в области языкоznания, истории и других областях. Мы извлекли список некоторых слов из коллекции таджикских текстов. В таком списке собраны наиболее часто употребляемые словоформы «грубых», «нейтральных» и «благозвучных» звуков. Из коллекции таджикских текстов извлекаем список некоторых слов. Такой список содержит наиболее употребительные словоформы “грубого”, “нейтрального” и “приятного” звучаний.

Множество таджикских словоформ обозначаем буквой *G* и разделим его по качеству звучание на 3 группы: G_1 – грубозвучные, G_2 – благозвучные и G_3 – нейтральные слова. Из каждой группы выбираем по 1000-1500 словоформ.

Группу G_1 разделим каким-либо образом на 3 подгруппы словоформ – G_{11} , G_{12} , G_{13} – приблизительно одинаковых размеров словоформ (в смысле числа словоформ). Далее, используя какой-либо способ, также разделим группу G_2 на 3 подгруппы словоформ – G_{21} , G_{22} , G_{23} , которые по количеству словоформ являются приблизительно одинаковыми. Подгруппы G_{1i} и G_{2j} будем рассматривать как тексты (произведения).

В качестве элементов для описания количественного образа словоформы используем единый таджикский алфавит, состоящий из 35 букв (униграмм):

а, б, в, ..., э, ю, я.

Для каждой из 6-и подгруппы G_{1i} и G_{2j} вводим единый цифровой портрет, заданный в виде таблицы закона распределения.

$$\begin{array}{cccccc} \bar{N} & : & 1 & 2 & \dots & 35 \\ P & : & p_1 & p_2 & \dots & p_m, \end{array} \quad (2.2.1)$$

где в первой строке указывается занумерованный в алфавитном порядке список $m = 35$ таджикских букв (униграмм), а во второй – их частотность для конкретной подгруппы, причём

$$\sum_{k=1}^{35} p_k = 1.$$

Каждой из 6 подгруппе словоформы соответствует функция

$$F(s) = \sum_{k=1}^s p_k \quad (s = 1, \dots, m) \quad (2.2.2)$$

–дискретный аналог функции распределения. Пусть произвольная пара подгруппы словоформ T_1 , T_2 из $\{G\}$ и

$$F^{(\alpha)}(s) = \sum_{k=1}^s p_k^{(\alpha)} -$$

соответствующие им дискретные функции, $\alpha = 1, 2$ и $s = 1, \dots, m$.

Определение 1. Расстоянием между подгруппы T_1 и T_2 назовем положительное число $\rho(T_1, T_2)$, определяемое по формуле:

$$\rho(T_1, T_2) = \sqrt{\frac{m}{2}} \max_s \left| \sum_{k=1}^s (p_k^{(1)} - p_k^{(2)}) \right| \quad (2.2.3),$$

то есть расстояние между дискретными случайными величинами (с одинаковым набором \bar{N} возможных значений) вычисляется как максимальное расстояние между их дискретными функциями $F^{(1)}(s)$ и $F^{(2)}(s)$, умноженное на весовой коэффициент $\sqrt{m/2}$.

Гипотеза \mathbb{H} “однородности” подгруппы словоформы. Она привлекается для того, чтобы выделить характерную особенность словоформ, предназначенную для построения математической модели распознавания качества звучания слов. Её мы формулируем в следующем виде.

ГИПОТЕЗА \mathbb{H} . Слова, которые звучат сладко, – “однородны”, а которые не звучат сладко (то есть, звучат грубо) – “не однородны”.

Говоря об “однородности” благозвучия слов, мы имеем в виду их похожесть, одинаковость, сходность, однотипность, родственность и т.п.

Математическая модель \mathbb{H} -гипотезы. Пусть γ – некоторое положительное число.

Определение 2. Подгруппы T_1 и T_2 называются γ -однородными (звукут сладко), если

$$\rho(T_1, T_2) \leq \gamma, \quad (2.2.4)$$

и γ -неоднородными (звукут грубо), если

$$\rho(T_1, T_2) > \gamma \quad (2.2.5).$$

Неравенства (2.2.4) и (2.2.5) являются математической моделью (интерпретацией) гипотезы \mathbb{H} .

Определение 3. γ -классификатор – зависящий от одного вещественного параметра γ алгоритма принятия решения об отнесении пары подгруппы T_1 и T_2 к одному или двум разным качествам звучания слов.

Пусть $\tau = \tau(\gamma)$ – суммарное количество нарушений гипотезы \mathbb{H} одновременно в двух случаях: невыполнения неравенства “однородности” в случае двух подгруппы словоформ, принадлежащих одной группе, и невыполнения неравенства “неоднородности” в случае двух подгруппы словоформ, принадлежащих разным группам. Тогда для фиксированного γ показатель выполнения гипотезы будет определяться величиной π , задаваемой формулой

$$\pi = 1 - \tau(\gamma)/L,$$

где L – число взаимных расстояний между всеми парами подгруппы словоформ из коллекции G (в нашем случае $L = G_6^2 = 15$). Из этой формулы следует, что π может принимать значения из отрезка $[0, 1]$, причём $\pi = 0$, если $\tau = L$ ($= 15$), и $\pi = 1$, если $\tau = 0$. В первом случае гипотезу \mathbb{H} следует признать непригодной, а во втором – полностью согласованной с обучающей выборкой.

В связи с тем, что эффективность γ -классификатора зависит от значения параметра γ , представляет интерес найти такое его значение, при котором π принимает максимальное значение. Именно в этом и заключается суть

настройки γ -классификатора на данных обучающей выборки. Если такая настройка будет приемлемой, то можно говорить о решении задачи обучения γ -классификатора и его предрасположенности к распознаванию благозвучия таджикских слов самых разнообразных коллекций.

Итоговые результаты на примере модельной коллекции G приведены путём последовательного выполнения следующих операций:

- вычисление цифровых портретов (частотности букв) для всех 6 подгрупп словоформ модельной коллекции G ;
- вычисление по формулам (2.2.1), (2.2.2) и (2.2.3) пятнадцати парных расстояний $\rho(T_1, T_2)$ между подгруппами коллекции G (результаты расчетов приведены в таблице 2.2.2);
- вычисление с помощью алгоритма настройки γ -классификатора оптимального интервала значений γ , для которого величина $\tau = \tau(\gamma)$ суммарного числа случаев нарушения гипотезы H достигает минимального значения и, следовательно, величина π показателя выполнения гипотезы H принимает максимальное значение.

Таблица 2.2.2 – Расстояния между подгруппами коллекции G

Подгруппы		Группа грубозвучных словоформ (G_1)			Группа сладкозвучных словоформ (G_2)		
		G_{11}	G_{12}	G_{13}	G_{21}	G_{22}	G_{23}
Группа грубозвучных словоформ (G_1)	G_{11}						
	G_{12}	0.0423					
	G_{13}	0.1974	0.1863				
Группа сладкозвучных словоформ (G_2)	G_{21}	0.4708	0.4580	0.6202			
	G_{22}	0.3399	0.3270	0.4893	0.1521		
	G_{23}	0.4455	0.4327	0.5949	0.1385	0.1074	

В таблице 2.2.2 получены следующие результаты:

- совокупность всех пар расстояний размещается на отрезке [0.0423, 0.6202], при этом минимальное расстояние реализуется между подгруппами G_{11} и G_{12} в грубозвучных подгруппах, а максимальное – между G_{13} в грубозвучных и G_{21} в сладкозвучных подгруппах;
- оптимальный полуинтервал значений γ оказывается в пределах

$$\gamma^{\text{опт}} \in [0.1974; 0.3270];$$

в соответствии с определением 3 это значит, что если расстояние $\rho(T_1, T_2)$ между двумя подгруппами словоформ не превосходит значения $\gamma^{\text{опт}}$ из указанного полуинтервала, то пара подгруппы принадлежат одной и той же группе; если же превосходит, то принадлежат разным группам словоформ;

- отметим, что для всех (без исключений) подгруппы коллекции G полностью подтвердилась гипотеза H и её математическая интерпретация в виде определения 3, и потому получено

$$\tau = \tau_{min} = 0,$$

то есть ни одно из неравенств (2.2.4) и (2.2.5) не было нарушено;

- вследствие чего показатель эффективности, предложенной в настоящей работе математической модели распознавания благозвучия словоформ оказался равным

$$\pi = \pi_{max} = 1.$$

Тестирование модели. Таким образом, успешно проведена настройка (обучение) γ -классификатора на данных модельной коллекции текстов G . С целью тестирования данного классификатора выбраны группы G_3 нейтральных слов, которые не знаем к какой группе относятся. Группу G_3 тоже разделим каким - либо образом на 3 подгруппы G_{31} , G_{32} , G_{33} приблизительно одинаковых размеров (в смысле числа слов).

После того, как был сформирован цифровой портрет подгруппы словоформ и вычислены расстояния по формуле (2.2.3), получена следующая таблица расстояний от каждого из подгруппы до всех 6 подгрупп исходной коллекции:

Таблица 2.2.3 – Расстояния между подгруппами коллекции и тестируемыми подгруппами

Группы	Группа нейтральных слов (G_3)		
	G_{31}	G_{32}	G_{33}
Группа грубозвучных словоформ (G_1)	G_{11}	0.1280	0.1155
	G_{12}	0.1127	0.1187
	G_{13}	0.2832	0.2610
Группа сладкозвучных словоформ (G_2)	G_{21}	0.3525	0.3592
	G_{22}	0.2215	0.2283
	G_{23}	0.3272	0.3339

В таблице 2.2.3 выделены пары ячеек, которые соответствуют минимальным расстояниям от тестируемых объектов до элементов коллекции текстов. Полученные результаты показывают, что ближайшими соседями выбранной тройки подгрупп оказались однородные только с подгруппами грубозвучных слов.

Заключение. Проведено тестирование γ -классификатора, имеющего фиксированное значение $\gamma = \gamma^{\text{опт}}$, на случайных выборках группы, по результатам которого подтверждена 100%-ная способность распознавания благозвучия таджикских слов.

В **подглаве 2.3** рассмотрена модель распознавания благозвучия таджикских слов при использовании биграмм, где в качестве элементы γ -классификатора выступали биграммы: **аа, аб, ав, ..., ая, ба, бб, ..., бя, ..., яя** и их ЦП. Из коллекции G выбрано 3 группы словоформ: G_1 – грубозвучные, G_2 – сладкозвучные и G_3 – нейтральные слова и каждое из них в своей очереди

разделены на 3 подгруппы. Из каждой группы выбираем по 1000-1500 слов. Для каждой подгруппы сопоставлен цифровой портрет – распределения частотностей символьных биграмм.

Исследована эффективность γ-классификатора с использованием биграмм, рассчитаны математические и компьютерные модели словоформ с использованием биграмм.

В **подглаве 2.4** рассмотрен метод распознавания созвучности таджикских словоформ при использовании триграмм (триад словообразных букв), в данном случае элементы γ-классификатора взяты из триграмма: **ааа, ааб, аав, ..., аяа, аба, абб, ..., абя, ..., аяа, ааб, ..., яяя** и их цифровой портрет. Из коллекции текстов были выбраны три группы словоформ, каждая из которых далее разделена на три подгруппы. Были подсчитаны частоты каждой из 42875 триграмм выбранных из коллекции подгрупп словоформ, найдено расстояние между ними и проведено их сравнение. Была исследована эффективность γ-классификатора с использованием триграмм, а также рассчитаны математическая и компьютерная модели словоформ с использованием триграмм. В **подглаве 2.5** подводится итог второй главе.

В **главе 3** рассказывается о структуре, возможностях и реализации программного комплекса, подготовленного в рамках диссертации. Комплекс, разработанная в рамках научной диссертации, носит название «ХУШСАДО». Структура программы и ее части описаны в **подглаве 3.1**.

Программный комплекс «ХУШСАДО» разработан с использованием современной системы программирования RAD Studio, программного продукта компании Embarcadero, в среде программирования Delphi. Для создания этого пакета использовались следующие компоненты среды программирования Delphi: Form, Ribbon, Label, Panel, Button, Memo, ListBox, StringGrid, Splitter, ImageList, RichEdit, OpenDialog, SaveDialog, PrintDialog, ActionManager, StatusBar и т. д.

Опишем алгоритм обработки униграмм таджикских словоформ в виде блок-схемы (см. рисунок 3).

В **подглаве 3.2** собранная коллекция текстов обрабатывается разработанным программным обеспечением.

В **подглаве 3.3** на основе математических моделей распознавания благозвучие словоформ, представленных в главе 2, разработана информационная (компьютерная) модель автоматического распознавания голосовых качеств словоформ. Для фонетического анализа слов и отображение рентгенограммы фонемы нужно выполнить команду «**Таҳлил**» из программы «ХУШСАДО» (см. рисунок 4).

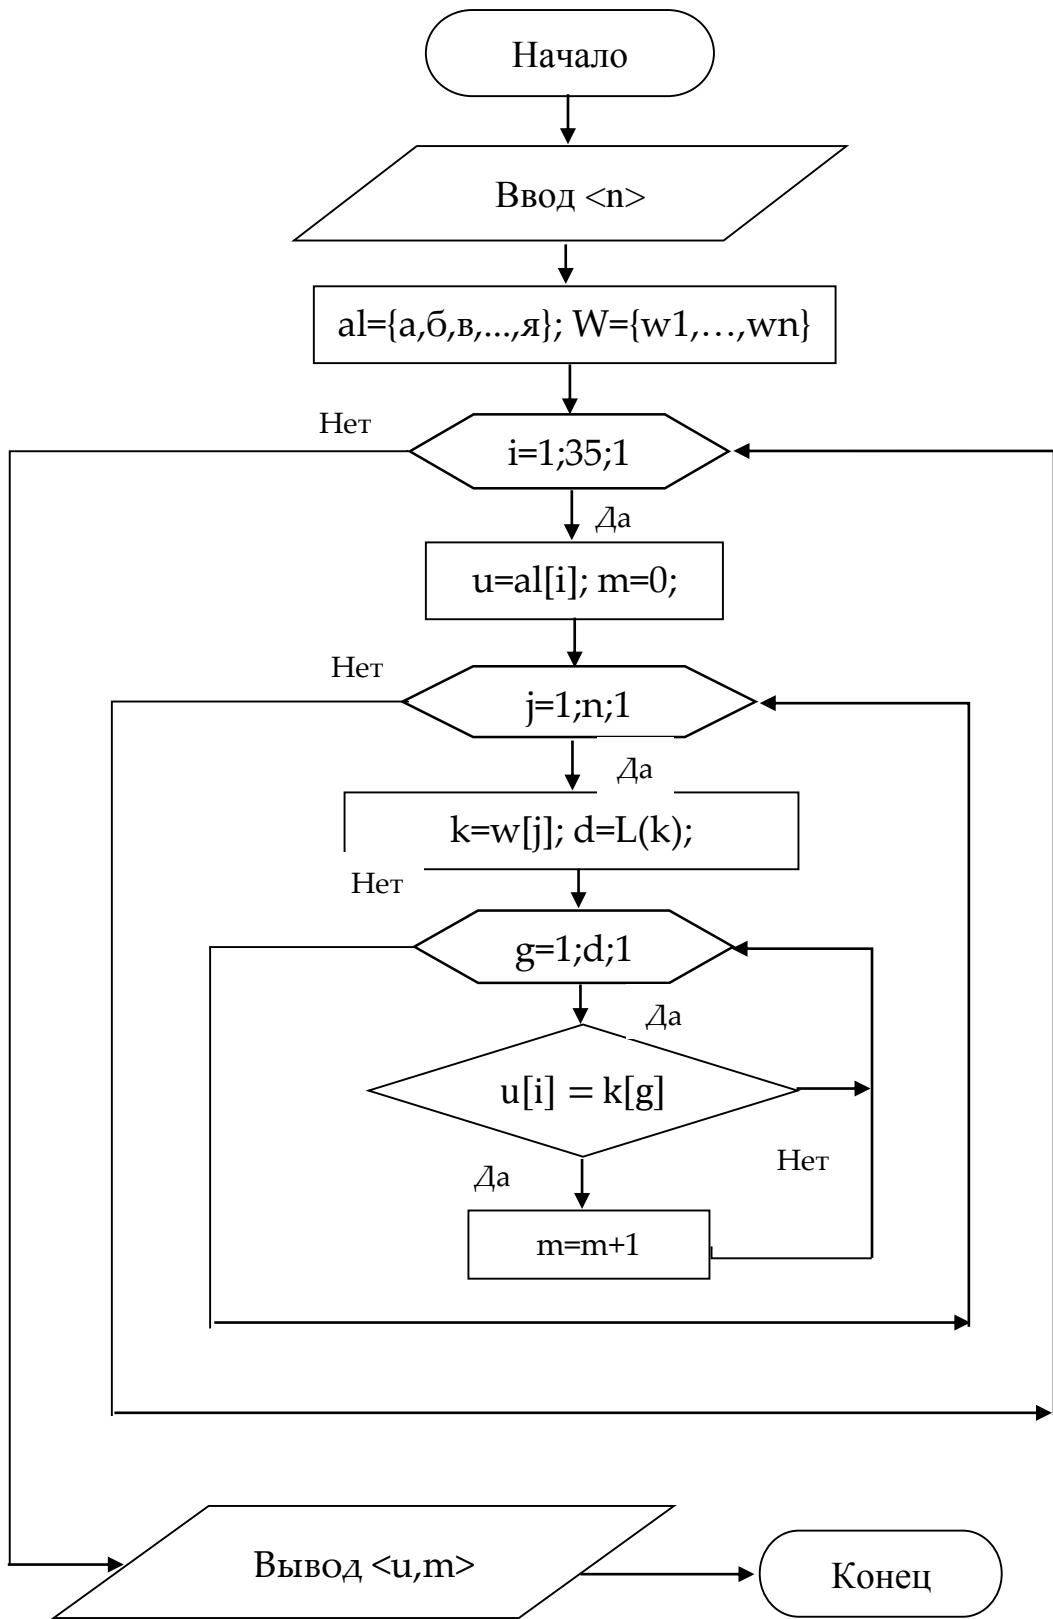


Рисунок 3. Блок-схема обработки униграммы словоформы

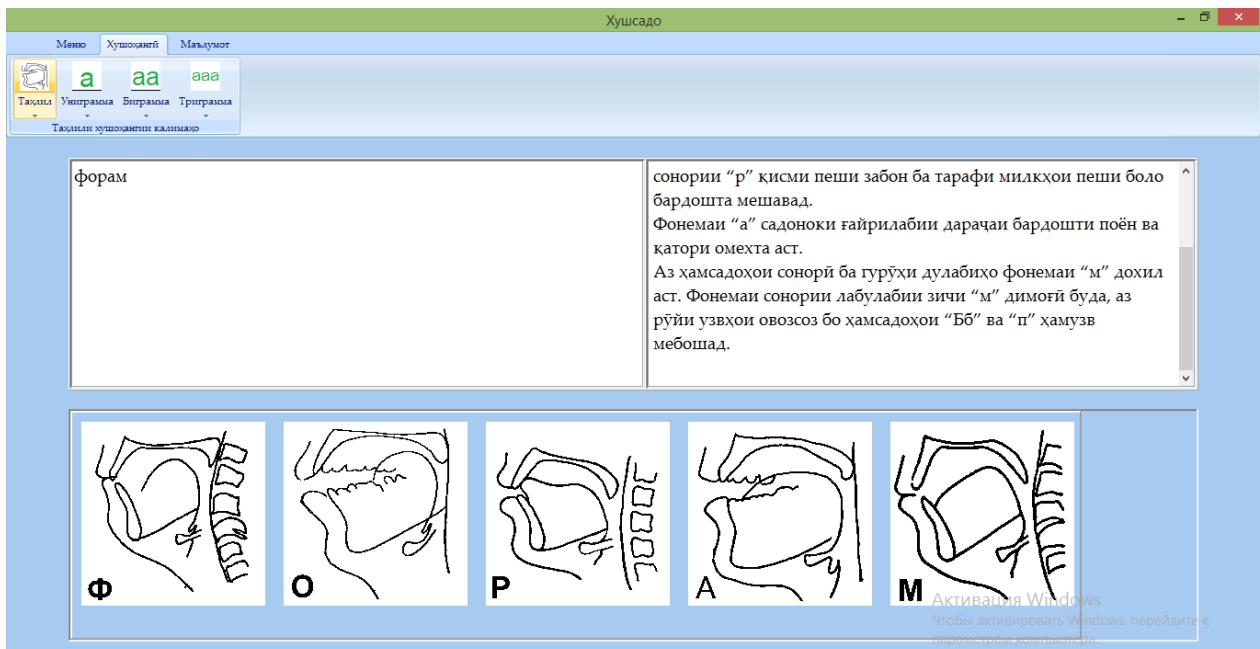


Рисунок 4 – Анализ голосовых характеристик красивых словоформ

Другая часть программы **Хушсадо**, которая появляется при переходе на режиме Расширенный (Васеъшуда) и служить для вычислении цифровых портретов (ЦП) униграмм, биграмм, триграмм группы словоформ и их расстояний (см. рис. 5).

№	Уни	Бас.м	Бас.нис.	Чамъи бас.	№	Уни	Бас.м	Бас.нис.	Чамъи бас.	№	Уни	Бас.м	Бас.нис.	Чамъи б.	D(n,m)= F(n) - F(m) /Dm
1	а	340	0,1318340	0,13183404	1	а	496	0,1656090	0,16560934	1	а	519	0,1624920	0,162492	0,003117176090813010
2	б	101	0,03916240	0,17099651	2	б	110	0,0367270	0,20233722	2	б	83	0,0259860	0,188478	0,01385883172016
3	в	43	0,01667310	0,18766963	3	в	40	0,0133550	0,21569282	3	в	36	0,0112710	0,199749	0,015943290999505
4	г	40	0,01550980	0,20317952	4	г	46	0,0153580	0,23105175	4	г	62	0,0194110	0,219160	0,011890826183903
5	ғ	1	0,00038770	0,20356727	5	ғ	0	0	0,23105175	5	ғ	40	0,0125230	0,231684	0,00063265534396198
6	Ҷ	169	0,06552920	0,26909654	6	Ҷ	173	0,0577620	0,28881469	6	Ҷ	174	0,0544770	0,286161	0,00265313824021096

Рисунок 5 – Вычисления ЦП униграмммы

В подглаве 3.4 представлены основные выводы третьей главы. В заключении диссертации подводятся общие результаты исследования, оформляется основной вывод и определяются основные направления дальнейших исследований, связанных с темой диссертации.

ЗАКЛЮЧЕНИЕ

Основными результатами диссертации являются:

- ✓ анализ вопроса благозвучия текста и путей его решения в доступных источниках и разработка основ эвфонометрии словоформ естественных языков, в том числе таджикского языка [1-А, 2-А, 11-А];
- ✓ компьютерная обработка текста произведения Саади «Гулистан», выявляющая статистические данные и особенности сочетания звуков в его словесном составе [3-А];
- ✓ отобрана большая коллекция текстов и ее элементы: униграмма, биграмма и триграммма исследованы с математической и компьютерной точки зрения [4-А, 5-М, 6-А];
- ✓ нахождение труднопроизносимых признаков на основе опроса носителей языка, классификации таджикских словоформ и разработки компьютерных программ для описания символов [7-А, 8-А];
- ✓ Исследованы таджикские слоги, разработаны алгоритм и программа разделения слогов таджикских слов [10-А, 12-А];
- ✓ для решения задачи автоматического распознавания благозвучие словоформ таджикского языка создан программный комплекс на языке программирования Delphi [13-А].

Рекомендации по практическому использованию результатов.

Результаты исследования могут быть использованы при решении задач по языкоznанию и литературоведение, проведении различных речевых тестов по конкретным вопросам, фонетическим системам и учебно-контрольным системам. Результаты компьютерных расчетов показывают, что определение их качественных и количественных характеристик имеет большое практическое значение для классификации словоформ на классы. Сообщается, что результаты исследования диссертационной работы для чтения спецкурсов («Методы анализа текста на компьютере», «Лингвистические основы машинного перевода», «Компьютерные технологии в лингвистических исследованиях»), выполнения лабораторных и самостоятельных работ, курсовых, дипломных и магистерских работ для студентов и магистров по направлениям «Компьютерная лингвистика», «Лингвистика и новые информационные технологии» и «Информатика» в вузах Республики Таджикистан.

Комплекс компьютерных программ, созданных в рамках данной диссертации, применяется в сферах науки и образования, культуры, филологии, компьютерных систем обработки текста, систем искусственного интеллекта и машинного обучения для решения актуальных задач компьютерной лингвистики.

Публикации по теме диссертации
Статьи, опубликованные в научных журналах, рекомендованных ВАК
при Президенте Республики Таджикистан

- [1 – А] Пиров С.М. К разработке основ эвфонометрии слов [Текст] / З.Д. Усманов, С.М. Пиров // Известия Академии наук Республики Таджикистан. Отделение физико-математических, химических, геологических и технических наук. - 2015. - №3 (160). - С. 39-42.
- [2 – А] Пиров С.М. Дар бораи байзе масъалаҳои хушоҳангии матнҳои тоҷикӣ [Матн] / С.М. Пиров // Паёми Донишгоҳи миллии Тоҷикистон. -2017, -№ 4-3. -С.105-109.
- [3 – А] Пиров С.М. Таҳқиқи биграммаҳои “Гулистон”-и Саъдии Шерозӣ [Матн] / С.М. Пиров // Паёми Донишгоҳи миллии Тоҷикистон. -2017, -№ 1/5. - С.156-159.
- [4 – А] Пиров С.М. Алгоритм распознавания благозвучия таджикских слов при использовании униграмм [Текст] / С.М. Пиров // Доклады Национальной академии наук Таджикистана. -2022, т. 65, № 1-2. С.57-62.
- [5 – А] Пиров С.М. Алгоритми шинохти хушоҳангии калимаҳои тоҷикӣ бо истифодаи биграммаҳо [Матн] / С.М. Пиров // Паёми ДМТ, баҳши илмҳои табииӣ. -2022. -№2. - С. 102-111.
- [6 – А] Пиров С.М. Алгоритм распознавания благозвучия таджикских слов при использовании триграмм [Текст] / С.М. Пиров // Вестник, Филиала МГУ им. В.М.Ломоносов в г.Душанбе, раздел информатика. -2023, Том 1, -№1 (29). -С. 35 - 42.

Статьи в материалах научных конференций

- [7 – А] Пиров С.М. Дар бораи гурӯҳбандии калимаҳои забони тоҷикӣ аз рӯйи талаффузашон [Матн] / С.М. Пиров // РТСУ. Перспективы развития фундаментальных и прикладных лингвистических исследований в Республике Таджикистан. – Душанбе: Персис, 2016. - 1(7). -С. 16 -18.
- [8 – А] Пиров С.М. Дар бораи маҷмӯи аломатҳои тавсифкунандаи хушоҳангии калимаҳои тоҷикӣ [Матн] / С.М. Пиров // Маводи конференсияи илмӣ-амалии байналмилалӣ. ДТТ. -Душанбе -2017. -С. 352-355.
- [9 – А] Пиров С.М. Басомади биграммаҳои ҳарфҳои тоҷикӣ [Матн] / С.М. Пиров // Маводи Конференсияи ҷумҳуриявии илмию назариявии ҳайати устодону кормандони ДМТ баҳшида ба ҷашинон «5500-солагии Саразми бостонӣ», «700-солагии шоири барҷастаи тоҷик Камоли Ҳӯҷандӣ» ва «20-солаи омӯзиш ва рушди фанҳои табиатшиносӣ, дақиқ ва риёзӣ дар соҳаи илму маориф (солҳои 2020-2040)». – Ҷилди 1. -2020. -С. 39-40.
- [10 – А] Пиров С.М. Алгоритми содаи ба ҳиҷоҳо чудокунии калимаҳои тоҷикӣ [Матн] / С.М. Пиров // Маводи конференсияи байналмилалии илмӣ-амалий дар мавзӯи «Муаммоҳои муосири математика ва татбиқи он» баҳшида ба «Солҳои

2020-2040 эълон гардидани 20-солаи омӯзиш ва рушди илмҳои табиатшиносӣ, дақиқ ва риёзӣ». -2022. -С. 158-161.

[11 – А] Пироев С.М. Таҳлили моделҳои баҳодиҳии хуҷоҳангии матнҳо [Матн] / С.Х. Мирзоев, С.М. Пироев // Маводи конференсияи байналмилалии илмӣ-амалӣ дар мавзӯи «Таҳлили компютерии маъсаҳои илм ва технология» баҳшида ба «Солҳои 2020-2040 эълон гардидани 20-солаи омӯзиш ва рушди илмҳои табиатшиносӣ, дақиқ ва риёзӣ дар соҳаи илму маориф» ва «75-солагии Дошишгоҳи миллии Тоҷикистон». -2023. -С. 396-404.

Авторские права и свидетельство:

[12-А]. Пироев С.М. Свидетельство. Ҷудокунии ҳичоҳои калимаҳои тоҷикӣ / С.М. Пироев // Свидетельство об официальной регистрации программы для ЭВМ в отделе по правам и защите прав автора Министерства культуры Республики Таджикистан (№ 150, 9.11.2022г.).

[13-А]. Пироев С.М. Автоматизированная система анализа текстов и оценка благозвучия таджикских слов [Текст] / С.Х. Мирзоев, А.А. Косимов, **С.М. Пироев**// Свидетельство о государственной регистрации информационного ресурса №1202500527 от 28.02.2025 внесен в реестр информационных ресурсов Республика Таджикистан.

ШАРҲИ МУХТАСАР

рисолаи Пиро Сайдали Мирзоалиевич дар мавзуи «Таҳия ва тадқиқи критерияҳои миқдорӣ барои баҳодиҳии хушоҳангии қалимаҳои тоҷикӣ», барои дарёфти дараҷаи илмии номзади илмҳои техникӣ аз рӯйи ихтисоси 05.13.11 – «Таъминоти математикӣ ва барномавии мошинҳои ҳисоббарор, комплексҳо ва шабакаҳои компьютерӣ»

Қалимаҳои қалидӣ: дастгоҳи гуфткор, овоз, алифбо, забони тоҷикӣ қалима, алломат, хушоҳанг, душворталаффуз, басомад, бузургиҳои тасодуфӣ, симои рақамӣ, алгоритмҳои коркарди матн, таснифгар, баҳодиҳӣ, пайкараи матнҳо, таъминоти барномавӣ, амсилаҳои баҳодиҳии хушоҳангӣ.

Объекти таҳқиқот – амсилаҳои математикию компьютерии таҳлил ва баҳодиҳии хушоҳангии маҷмуи қалимашаклҳои чопии забони тоҷикӣ.

Мавзуи таҳқиқот – шинохти худкори хушоҳангии қалимашаклҳои тоҷикӣ дар асоси алломатҳо ва басомади N -граммаҳои он.

Үсулҳои таҳқиқот. Барои ҳалли мақсаду вазифаҳои дар тадқиқот гузошташуда аз методҳои фонетикӣ, таҳлили оморӣ, ҳисобҳои таҷрибавӣ, назарияи маҷмуъҳо, таҳлили системавӣ, амсиласозии математикӣ ва компьютерӣ, барномасозии ба объект нигаронидашуда барои таҳияи воситаҳои барномавӣ ва коркарди манбаи додаҳои реляционӣ истифода шудааст.

Навғонии илмии тадқиқот.

- иттилоъдиҳии алломатҳое, ки барои шинохт ва муайянкунии хушоҳангии қалимашаклҳо таъйин шудаанд таҳқиқ карда шуд;
- самаранокии истифодаи N -граммаҳои хуруфӣ ($N=1,2,3$) ба сифати алломатҳои муайянкунандай хушоҳангии қалимашаклҳо муқаррар карда шуд;
- самаранокии таснифгари Усмонов З.Ҷ. муқаррар карда шуд, ки қобилияти бо саҳеҳии то 96% муайян кардани хушоҳангии маҷмуи қалимашаклҳоро дорад;
- бо мақсади комилан кам кардани ҳаҷми раванди ҳисобкуниҳо имконияти самаранокии истифодаи на ҳама, балки танҳо элементҳои алифбои N -граммаҳои ($N=1,2,3$) рамзии баландбасомад барои муайянкунии хушоҳангии қалимашаклҳо истифода карда шуд;
- бори аввал дар Тоҷикистон маҷмааи барномаи компьютерии замонавӣ барои шинохти худкори хушоҳангии қалимашаклҳои тоҷикӣ, соҳта шуд.

Дараҷаи эътиимоднокии натиҷаҳои рисола. Натиҷаҳои бадастомада, бо як силсила озмоишҳои ҳисоббарорӣ тасдиқ мешаванд, ки дар онҳо хушоҳангии қалимашаклҳои гуногун бо саҳеҳияти кифоя баланд муайян шудаанд.

Соҳаи истифодабарӣ: Натиҷаҳои бадастомадаро дар соҳаҳои илму маориф, фарҳанг, забоншиносӣ, адабиётшиносӣ, низомҳои компьютерии коркарди матн, зеҳни сунъӣ ва омӯзиши мошинӣ барои ҳалли масъалаҳои мубрами забоншиносии компьютерӣ истифода бурдан мумкин аст.

РЕЗЮМЕ

диссертация Пиров Сайдали Мирзоалиевич на тему «Разработка и исследование количественных критериев для оценки благозвучия таджикских слов», на соискание ученой степени кандидат технических наук по специальности 05.13.11 – «Математическое и программное обеспечение вычислительных машин, комплексов и компьютерных сетей»

Ключевые слова: речевой аппарат, звук, алфавит, таджикский язык, слово, признак, благозвучие, труднопроизносимые, частота, случайные величина, цифровой портрет, алгоритмы обработки текста, классификатор, оценка, корпус текстов, программное обеспечение, модели оценки благозвучие.

Объект исследования. В качестве объекта исследования определены математические и компьютерные модели анализа и оценки множества печатных словоформ таджикского языка.

Предмет исследования. Автоматическое распознавание благозвучия таджикских словоформ на основе признаков и частотности его N -грамм.

Методы исследования. Для решения целей и задач, поставленных в исследовании, используются фонетические методы, методы математической статистики, вычислительного эксперимента, теории множеств, системного анализа, распознавания, математические и компьютерные моделирование и объектно-ориентированного программирования для разработки программных средств.

Научная новизна работы. Основные результаты диссертации являются новыми и заключаются в следующем:

- исследована информативность признаков на предмет количественного описания таджикских словоформ;
- установлена эффективность использования N -грамм ($N=1,2,3$) в качестве символов, идентифицирующих словоформы;
- установлена эффективность модификатора З.Д. Усманова, способного распознавать с точностью до 96% благозвучие коллекции словоформ;
- с целью существенного сокращения объёма вычислительных процедур установлена возможность эффективного использования не всех, а только высокоточных элементов алфавита буквенных N -грамм ($N=1, 2, 3$);
- впервые в Таджикистане создан объектно-ориентированный компьютерный программный комплекс для распознавания благозвучия таджикских слов.

Степень достоверности результатов диссертации. Полученные результаты подтверждаются серией вычислительных экспериментов по идентификации с достаточно высокой точностью в различных коллекциях текстов.

Область применения: Полученные результаты могут быть использованы в сферах науки и образования, культуры, филологии, компьютерных систем обработки текста, систем искусственного интеллекта и машинного обучения для решения актуальных задач компьютерной лингвистики.

SUMMARY

of the thesis of Pirov Saidali Mirzoalievich on the topic "Development and research of quantitative criteria for assessing the euphony of Tajik words", submitted for the degree of candidate of technical sciences by specialty 05.13.11 – “Mathematical and software computing machines, complexes and computer networks”

Key words: speech apparatus, sound, alphabet, Tajiki language, word, feature, euphony, difficult to pronounce, frequency, random variable, digital portrait, text processing algorithms, classifier, assessment, text corpus, software, euphony assessment models.

Object of the research. The object of the research is the definition of mathematical and computer models of analysis and evaluation of the set of printed word forms of Tajik language.

Subject of the research. Automatic recognition of euphony of Tajik words based on features and frequency of its N-grams.

Research methods: Phonetic methods, methods of mathematical statistics, computational experiment, set theory, system analysis, mathematical and computer modeling, object-oriented programming for the development of software and relational database processing are used for solution the goals and objectives set in the study.

The scientific novelty of the work.

- the informativeness of features for quantitative description of Tajiki words was investigated;
- the efficiency of using letter N-grams ($N = 1, 2, 3$) as text descriptors was established;
- the efficiency of the modifier of Usmanov Z.D., capable of recognizing the euphony of words with an accuracy of up to 96%, was established;
- for the first time in Tajikistan, an object-oriented computer software package for recognizing the euphony of Tajiki words was created.

The degree of reliability of thesis results.

The obtained results are confirmed by a series of computational experiments to identify authors with sufficiently high accuracy in various text collections.

Field of the application. The results of the thesis can be used in the fields of science and education, culture, linguistics, philology, computer systems for processing text, artificial intelligence systems and machine learning to solve urgent problems of computer linguistics.

Сдано в печать 28.02.2025 Формат 60x84
1/16, тираж. 60 экзем.
Отпечатано в типографии ТНУ
г. Душанбе.