

Кырг.

2019 - 117

КЫРГЫЗ РЕСПУБЛИКАСЫНЫН УЛУТТУК ИЛИМДЕР АКАДЕМИЯСЫ
АВТОМАТИКА ЖАНА МААЛЫМАТ ТЕХНОЛОГИЯЛАР ИНСТИТУТУ

Б. Н. Ельцина атындагы

КЫРГЫЗ-РОССИЯ СЛАВЯН УНИВЕРСИТЕТИ

Диссертациялык кеңеш № 05.18.579

Кол жазма укугунда
УДК 519.688.004.912(575.2) (043.3)

КӨЧКӨНБАЕВА БУЛЖАР ОСМОНАЛИЕВНА

КЫРГЫЗ ТИЛИ УЧУН МОРФОЛОГИЯЛЫК АНАЛИЗАТОРДУН
МОДЕЛДЕРИН ЖАНА АЛГОРИТМДЕРИН ИШТЕП ЧЫГУУ

05.13.18- математикалык моделдөө, сандык ыкмалар жана программалар
комплекси

Техника илимдеринин кандидаты окумуштуулук
даражасын изденип алуу учун жазылган диссертациянын
АВТОРЕФЕРАТЫ

Бишкек -2019

Диссертациялык иш академик М.М.Адышов атындағы Ош технологиялық университетинин “Эсептөө техникаларын жана автоматташтырган системаларды программалық жабдуу” кафедрасында жана А.С. Джаманбаев атындағы жаратылыш байлыктары институтунда аткарылды.

Илимий жетекчи: физика-математика илимдеринин доктору, профессор Сатыбаев Абдуганы Джунусович
(М.М. Адышев атындағы ОшТУ, «Маалымат технологиялары жана башкаруу» кафедрасынын башчысы)

Расмий оппоненттер: физика-математика илимдеринин доктору, КР УИАнын мүчө-корреспонденти Панков Павел Сергеевич
(КР УИАнын Математика институту, “Эсептөө математикасы” лабораториясынын башчысы)

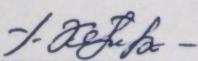
техника илимдеринин доктору, профессор Торобеков Бекжан
(И. Раззаков атындағы КМТУ, өнүгүү жана мамлекеттик тил боюнча проректор)

Жетектоочу мекеме: Ош мамлекеттік университети,
“Программалоо” кафедрасы
Ош шаары, 723500, Ленин көчөсү 331

Диссертация 2019-ж. 28-ионунда saat 14:00де Кыргыз Республикасынын Улуттук илимдер академиясынын Автоматика жана маалыматтык технологиялар институтунун жана Б.Н. Ельцин атындағы Кыргыз-Россия Славян университетинин алдындағы Д. 05.18.579 диссертациялык көңешинин отурумунда жақталат. Дареги: 720071, Бишкек ш., Чүй проспекти, 265, ауд. 346, сайт: www.ait.kg.

Диссертация менен Кыргыз Республикасынын Улуттук илимдер академиясынын китеңканасында 720071, Бишкек ш., Чүй проспекти, 265, «а» дареги боюнча жана КР УИА АжМТИнин сайтында www.ait.kg дареги боюнча таанышса болот. E-mail: gulsaat@mail.ru.

Автореферат 2019-жылдын 27-майында жөнөтүлдү.

Диссертациялык көңештин окумуштуу катчысы, ф.м.и.к.  - Керимкулова Г.К.

ИШТИН ЖАЛПЫ МУНӨЗДӨМӨСҮ

Маселенин актуалдуулугу. Азыркы күндө, маданияттын, илимдин жана техниканын өнүгүү доорунда, маалыматтар менен иштөө: аларды өзгөртүү жана башка формага өткөрүү амалдары адам баласынын бардык чөйрөсүндө алдынкы маселелердин бири болууда. Негизинен табигый тилдеги маалыматтарды иштеп чыгуу усулдары жана караҗаттары — эң жөнөкөй документтерден баштап, маалымат издеөчү системаларга, машиналык пикир алмашуучу системаларга чейин чоң мааниге ээ болууда.

Табигый тилдеги тексттер менен байланышкан программалар етө көп жана алардын берилген текстти изилдөө терендиги да ар түрдүү болуп эсептелет.

Берилген текстти изилдөө терендигине жараша түзүлгөн программалар негизинен табигый тилдеги тексттердин үстүнөн жүргүзүлүүчү теменкү программалык белүктөрден турат: кийирилген тексттеги тамгалар – сөздөр – сөздүн маңызы – ... - сөздүн мааниси - түзүлүшү – чыгуучу тексттин тамгалары ж.б. Кандай гана текст болбосу, аны изилдөөдо жана алгоритмин түзүүдө эң бириңчи модуль катары морфологиялык анализатордун каралышы талашсыз.

Табигый тилдеги тексттердин үстүнөн иштөөчү программалардын дээрлик көпчүлүгүндө морфологиялык анализ белүгү эң керектүү белүк болуп саналат жана бул маселенин актуалдуулугун туюннат. Программанын морфологиялык анализдөө белүгү изилдөөчү тексттин көлемүнүн чоң болгонуна карабай эффективдүү жана тез иштөөсү система тарабынан талап кылынат.

Түзүлүүчү алгоритмдерге, белгилүү алгоритмдерге караганда бир канча каттуу талаптар коюлат жана азыркы күндөгү эсептөө техникаларында эстин аз белүгүн пайдаланусу, жогорку ылдамдыкта иштөөсү талап кылынат.

Бул багытта, кыргыз тилинин морфологиялык анализаторунун алгоритмдери көнерири изилдене злек, ошондуктан кыргыз тилинин формалдык грамматикасын, машиналык көнору, морфологиялык, синтаксистик жана семантикалык анализаторлордун негизинде эксперттик системалар сыйктуу колдонмо программаларды иштеп чыгуу актуалдуу маселе боюнча калууда.

Диссертациялык иштин илимий программалар жана илимий изилдөөчү иштер менен байланышы.

Диссертациялык иш академик М.М. Адышев атындағы Ош технологиялық университетинде эл аралык TEMPUS -544319-TEMPUS-1-2013-1-FR-TEMPUS-JPCR “Professional Master's Degree in computer science as a second competence in Central Asia” (PROMIS) долбоорунун алкагында ишке ашты.

Изилдөөнүн максаты. Бул диссертациялык иштин максаты принциптерди, алгоритмдерди, программаларды иштеп чыгуу жана персоналдык компьютердердин оперативдик эсине кайрылууну оптималдаштыруучу лингвистикалык моделдерди камтыйган кыргыз тилинин автоматтык морфологиялык анализинин математикалык моделин,

алгоритмдерин түзүү жана түзүлгөн модулду керектүү текст менен иштөөчү колдонмо программаларда пайдалануу болуп саналат.

Изилдоонун маселелери:

- Заманбап эсептөөчү машиналарда эффективдүү иштеп жаткан морфологиялык анализатор программаларына обзор берүү;
- Кыргыз тилинин морфологиялык таблицасын жана сөздүгүн түзүү;
- Морфологиялык анализдин маселелерин чечүүдө маалыматтар базасынын структурасын иштеп чыгуу;
- Кыргыз тили үчүн морфологиялык анализатордун математикалык моделин түзүү;
- Иштелип чыккан математикалык моделдин негизинде так жана толук морфологиялык анализ жүргүзүүчү программанын алгоритмин түзүү. Ошондой эле моделдин негизинде сөздөрдү нормалдаштыруу маселелерин изилдөө;
- Embarcadero RAD Studio XE3 чейресүндө морфологиялык анализатордун программасын түзүү.

Иштин илимий жаңылыгы:

- ❖ Эрежелердин жардамында сөз формаларын белгилүү сандагы белүктөргө боло турган кыргыз тилинин морфологиялык түзүлүшүнүн модели иштелип чыкты. Бул моделдин жардамында сөздөрдү нормалдаштыруунун оптималдуу алгоритми түзүлдү;
- ❖ Биринчилерден болуп сөздүктөгү сөздөрдүн негизин издөө алгоритминин салыштырмалуу жогорку ылдамдыкта иштөөсүнө жетүүгө боло турган сөздүктүн структурасы жана мындан сөздүктөн сөздөрдү издөөнүн алгоритми иштелип чыккан. Жогорку ылдамдыкка жетүү үчүн убактылуу массив түзүлүп алынды;
- ❖ Морфологиялык анализатордун математикалык модели жана анын негизинде “NLP” программасынын иштөө алгоритми түзүлгөн. Алгоритмге ылайык атайдын лексикасы жана жалпы колдонуучу 15 мингэ жакын лексемди өзүнө камтыган кыргыз тилинин машиналык морфологиялык сөздүгү түзүлгөн.

Иштин практикалык мааниси — жүргүзүлгөн изилдөөлөрдүн натыйжасында персоналдык компьютердердеги сөздөрдү нормалдаштыруучу автоматтык морфологиялык анализди ишке ашыруучу процедуралардын модулу пайда болду. Бул программалык каражат персоналдык компьютердердеги ишке ашырылган баарлашуучу, издөөчү жана иш кагаздарды даярдоочу системаларынын эффективдүүлүгүн олуттуу жогорулатууга жол берет, жана келечекте тексттерди лингвистикалык иштеп чыгууга ар кандай статистикаларды чогултуу, издөө жана ар түрдүү шарттар боюнча тексттен фрагменттерди белүү, машиналык которуу системаларында жана башка ушул сыйктуу системаларга каражат катары пайдаланылат.

Иштелип чыккан жумуштун жыйынтыкторы Ош гуманитардык педагогикалык институтунун электрондук библиотекасынын маалымат издөө программаларына, Ош технологиялык университетинин окуу процессине кириштеди, ошондой эле Кыргыз Республикасынын Президентине караштуу

Мамлекеттик тил боюнча улуттук комиссиясынын эксперттери тарабынан текшерилди жана жакшы баага арзыды.

Алынган жыйынтыктардын экономикалык эффективдүүлүгү.

Диссертациялык эмгектин жыйынтыгында кыргыз тили үчүн морфологиялык анализатордун программасы түзүлдү. Анын экономикалык эффективдүүлүгү эсептөөлөргө таянып 35465,52 сомду түздү.

Коргоого коюуучу негизги жоболор:

1. Морфологиялык анализатордун иштөөсүнүн концептуалдык схемасы;
2. Морфологиялык анализди оптималдаштыруунун алгоритми;
3. Атоочтуктардын грамматикалык формаларынын фрейм-модели;
4. Кыргыз тилинин морфологиялык анализинин математикалык модели;
5. Морфологиялык анализатордун иштөө алгоритми.

Изденүүчүнүн жеке салымы:

Морфологиялык анализатордун математикалык модели жана программасын алгоритми, ошондой эле диссертациялык эмгекте көлтирилген илимий жаңылыктарга ээ болгон негизги жыйынтыктар жеке автор тарабынан алынды. Кыргыз тилинин морфологиялык анализин изилдөө боюнча илимий көнештер фил. и.д., профессор Т. Садыков тарабынан берилди жана диссертациялык иштеги маселенин коюулушу, алынган жыйынтыктарга баа берүү илимий жетекчи Сатыбаев А. Дж. менен чогуу ишке ашты.

Изилдоонун натыйжаларынын тастыкталышы: Автор тарабынан иштин негизги илимий жыйынтыктары “Turklang 2016” (Бишкек, 2016) IV Эл аралык конференциясында, “Turklang 2017” (Казань, 2017) V Эл аралык конференциясында, М.Тагаевдин 75-жылдыгына арналган конференцияда (Бишкек, 2017), А.Асановдун 75-жылдыгына арналган конференцияда (Ош, 2018), “Turklang 2018” (Гашкент, 2018) VI Түрк тилдерин компьютердик иштеп чыгуу боюнча эл аралык конференциясынын алкагында доклад жасалган.

Публикациядагы диссертациянын жыйынтыктарынын толук чагылдырылышы. Диссертациялык иштин материалдары боюнча 13 макала жарык көрдү. Алардын ичинен 5 макала РИНЦке кирген Россиялык журналдарда, 6 макала Кыргыз Республикасынын ЖАК тарабынан сунушталган журналдарда басылып чыккан. Автор тарабынан иштелип чыккан “NLP Морфологический анализатор” программасына Кыргызпатен тарабынан автордук күбөлүк берилген.

Диссертациянын колөмү жана түзүлүшү: Диссертация киришүүдөн, беш баптап, жалпы жыйынтыктан, 93 атальшты камтыган пайдаланылган адабияттардын тизмесинен жана 4 тиркемеден турат. Эмгектин колөмү 137 беттөн туруп, 9 таблицаны жана 33 сүрөттү камтыйт.

Автор диссертациялык иште жыйынтыктарды алууда баалуу көнешин берген жетекчиси физика-математика илимдеринин доктору, профессор Абдуганы Джунусович Сатыбаевке терең ыраазычылык билдирет.

ИШТИН НЕГИЗГИ МАЗМУНУ

Киришүүдө диссертациялык иштин темасынын актуалдуугу такталды, иштин максаты, милдеттери, илимий жаңылыгы, изилдеөнүн жыйынктарынын практикалык мааниси, ошондой эле коргоого коюулуучу негизги жоболор көлтирилдү.

Биринчи бапта табигый тилдеги тексттерди морфологиялык иштеп чыгуунун ыкмаларын жогорку деңгээлгө жеткирүүнүн керектүүлүгү каралат. Кейгөйдү чечүүгө бар болгон жакындоолор, колдонулган усулдар жана учурда иштелип чыккан морфологиялык системалар карапты, алардын кемчилиттери менен артыкчылыктары анализденди. Изилдеөнүн милдеттери такталды.

Бул багытта кыргыз окумуштууларынын арасынан Т. Садыковдун, Н. Исаилованнын жана П.С. Панковдун эмгектерин айтууга болот.

Казак окумуштуулары А. А. Шарипбаев, Д.Р. Рахимова, У.А. Тукеев, Ж.М. Жумановдор казак тилинин мисалында орус тилинен казак тилине которуучу программанын үстүнөн иштешкен. Мында алар которууда атайын сөздүктөр таблицасын түзүп алышкан жана окушоштуктарды анализдешкен.

Орус окумуштууларынын ичинен билүү маселеге кайрылгандар Г.Г. Белоногов, Е.И. Анно, О.Б. Бабко-Малая, И.А. Батманов, И.Г. Бидер, И.А. Большаков, Д. Варга, В.Н. Волков, А.Ф. Гельбух, Е.Р. Добрушина, Х.Ф. Исхакова, Е.А. Казаков жана В.А. Тузовдорду айтууга болот. В.А. Тузов эрежелерге таянган орус тилинин формалдык моделин түзүп чыккан. Алардын эмгектеринде флексивдүү тилдердин анализи караптады.

Ал эми түрк тилдеринин кенири изилдөөлөр К. Altintaş жана I. Çicekliye, татар тилин изилдөөгө Д. Сулаймановдун жана А. Гатиатулиндин эмгектерин, түркмөн тилин изилдөөгө А.С. Тантагудун жана башкалардын эмгеги таандык.

Окумуштуулар J. Hankamer, L. Karttunen, Koskenniemi, H. Trost немец жана англий тилдерин изилдешкен.

Экинчи бапта коюулган маселени чечүүдө колдонулуучу ыкмалар жана материалдар көлтирилди.

Изилдеөнүн объектиси: табигый тилдеги тексттерди морфологиялык иштеп чыгуунун методдору изилдөөнүн объектиси болуп эсептелет.

Изилдеөнүн предмети: текстти иштеп чыгуунун автоматтык морфологиялык анализинин программасын түзүүдө, аны формалдык түрдө кароо үчүн керек болгон кыргыз тилинин морфологиялык түзүлүшүн изилдөө; сөздүктүү сунуштоонун ыкмалары жана компьютердин эсинде сакталган сөздүктөр жеткиликтүүлүкүтү ылдамдатууга байланыштуу морфологиялык маалыматтар; морфологиялык анализдин алгоритмдери жана сөздөрдү нормалдаштыруу.

Изилдеөн ыкмалары: алдыда коюолган маселени чечүүдө морфологиялык анализдин ыкмалары, лингвистикалык мыйзам ченемдүүлүктөрдү туюндуруучу математикалык моделдей элементтери, ошондой эле объектке багытталган программалоонун ыкмалары колдонулган.

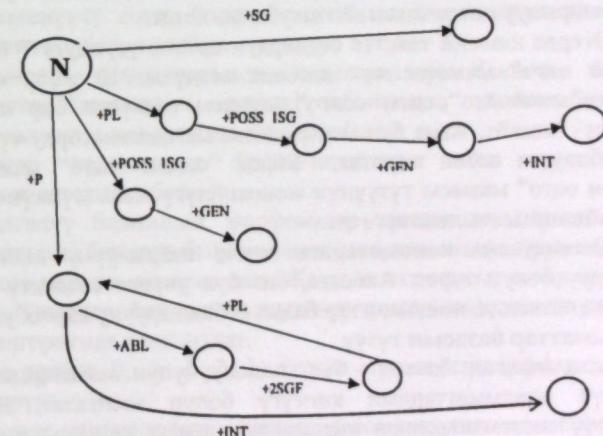
Үчүнчү бапта автор тарабынан иштелип чыккан компьютердин эсине кайрылууну азайтуу менен сөзди анализдеө үчүн баардык маалыматтарды

алууга жол берген морфологиялык сөздүктүү уюштуруу ыкмасы айтылат. Сөздүктүн түзүлүшүнүн алгоритмдери менен андагы маалыматтарды издеө көлтирилет.

Морфологиялык анализаторду түзүүнүн эң кеми үч жолу бар экени белгилүү: (1) сөздүккө негизделген анализаторду түзүү, (2) сөздүктүү пайдаланбай, грамматикага негизделген анализаторду түзүү, жана (3) сөздүк менен грамматиканы айкаштыра колдонгон анализаторду түзүү.

Белгилүү болгондой, кыргыз тили мүчелөмө тилдердин катары кирип, сөздүктөгү жаңы сөз куранды мүчөнүн сөздүн негизине жалгаша келиши аркылуу жасалса, тексттеги сөздүн грамматикалык формасы сөздүктөгү сөзгө уланды мүчөнүн уланышы аркылуу уюшулат. Мында сөздүн унгусу үндөштүктүн эрежесине ылайык өзүнө жалганган мүчелөрдүн ар түрдүү варианта өзгөрүп келишин шарттайт. Мисалы: тоо+Ø=тоо, тоо+нын=тоонун, үй+нын= үйдүн ж.б.

Кыргыз тилинде атооч сөз формалары сөзгө мүчелөрдүн төмөнкү фрейм-модели боюнча уланышы аркылуу ишке ашырылат (1-сүрөт). Көрүнүп тургандай, моделдин түйүндөрү атооч сөздөрдүн морфологиясына тиешелүү ар кандай абалдары көрсөтсө, түйүндөрү байланыштырып турган өтмөктор (жебечелер) атооч сөздөрдүн морфологиясына тиешелүү конкреттүү категорияларды көрсөттөт. Ал эми N – атооч сөздүн (noun) сөздүктөгү формасы (негизи).



1-сүрөт. Атооч сөз формаларын уюштуруунун фрейм-модели

Жогорудагы моделдин негизинде $word(x)$ предикатын карай турган болсок, ал x объекти менен мүчелөр көптүгүнүн ортосундагы байланышты камсыз кылат. Мисалдагы учурду карасак төмөнкүдөй предикаттар келип чыгат:

$word(N, SG); word(kumen, SG)$

$word(N, P, POSS_ISG, GEN, INT); word(kumen, P, POSS_ISG, GEN, INT);$

*word(N, POSS_ISG, IGEN); word(kumen, POSS_ISG, IGEN);
word(N, PL, ABL, 2SGF, PL, INT); word(kumen, PL, ABL, 2SGF, PL, INT)*

Ошентип, табигый тилдеги текст үчүн морфологиялык анализатордун иштөө принциптерин кароодо төмөнкүдөй этаптарды эске алуу кажет:

1. Киргизилген текстти сөз формаларына белүп алуу.
2. Андан соң сөз формаларын лемматизациялоо, атап айтканда, сөз формасын сөздүн сөздүктөгү формасына айландыруу.
3. Сөз формасын уюштурган уланды мүчөнү же мүчөлөрдүн тизмегин белүп алуу.
4. Уланды мүчөлөр тизмегин андан ары жиктөө жана ар бир мүчөнүн тиешелүү морфологиялык белгилерин аныктоо.

Маселени чечүүнүн эки жолу бар: биринчиси кийирилген сөздү «ондон солго» карай анализдөө, экинчиси «солдон онго» карай анализдөө ыкмасы. Айтылган ыкмалардын алгоритмдерин карап көрсөк, томенкүдөй жыйынтыкка ээ болобуз. Биринчи ыкмада аффикстердин комплексине оқшогон ақыркы белүкту белүп алуу аракети көрүлөт, андан кийин сөздүктөн калган баштапкы белүкту текшерүү жүргүзүлөт. Экинчи ыкмада сөздүктөн мүмкүн болгон баштапкы чынжырчаны издөө жүргүзүлөт, андан кийин калган оң жактагы белүк аффикстер белүгүү катары каралат. Эки учурда тен издөө ийгиликсиз болсо, сөз формасын башынан белүктөө жүргүзүлөт.

Эреже сыйктуу, морфологиялык анализде сөздүктөн маалыматты аныктоо бир канча көп убакытты талап кылат. Тактап айтканда, бул учурда дисктин эсine кайрылуу операциясына көп убакыт кетет.

Эгерде илмий текстте сөздөрдүн орточо узундугу 7-10 тамгадан турса, «солдон онго» ыкмасы жок дегенде сөздүккө 10 жолу кайрылуу жасайт. Эрежеге ылайык, «ондон солго» ыкмасы сөздүккө бир кыйла аз сандагы кайрылуу жасайт, жана бул морфологиялык анализаторду түзүүдө тандалуучу ыкма болууга себеп жаратат. Бирок «ондон солго» ыкмасына караганда, «солдон онго» ыкмасы түзүүнүн жонокойлугу жана мүмкүнчүлүктөрү боюнча бир кыйла артыкчылыктарга ээ.

Ошондуктан компьютердин эсine кайрылууну азайтуу маселеси да актуалдуу болуп турат. Албетте, биз бул учурда сөздүктүү түзүү маселесин, башкача айтканда, маалыматтар базасын башкарууна карообуз туура болот.

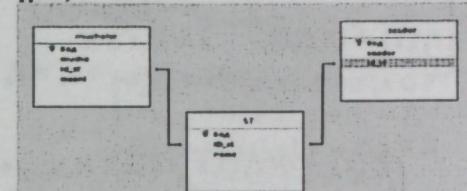
Маалыматтар базасын түзүү

Маалыматтар базасы – бул колдонуучунун талаптарын канааттандырган көректүү маалыматтардын көптүгү болуп эсептелет. Бул маалыматтар башкаруу системаларынын жардамында ирткө көлтирилип, таблица түрүндө сакталат жана ар бир таблица ар башка маалыматты сактайт.

Бүгүнкү күнде маалыматтарды башкаруу үчүн көптөгөн системалар колдонулат. Анткени көп сандаган маалыматтардын ичинен көректүүсүн белүп алуу бир канча убакытты талап кылат. Ошондуктан азыр SQL, MySQL, Oracle, Access жана башка көптөгөн маалыматтар базасын башкаруу системалары колдонулуп келет. Бул системалар аркылуу маалыматты башкаруу, сорттоо, издөө жөнөл жана көп убакытты талап кылбайт. Биздин учурда табигый тилдеги текст менен иштөөчү жогорудагы алгоритмди текшерүү максатында

Embarcadero RAD Studio чейресүндө тесттик programma түзүлдү. Мында маалыматтар базасын башкаруу үчүн Access системасы пайдаланылды.

Мында үч таблица түзүлүп, алардын ортосундагы байланыш томенкүдөй турдө түзүлдү (2-сүрөт):



2-сүрөт. Маалыматтар базасынын схемасы

Жогорудагы схемадан корунуп тургандай, маалыматтар базасы мүчөлөр, сөздөр жана сөз түркүмүн камтыган таблицалардан турат. Алар *it_st* ачкыч талаанын жардамында байланышат.

Морфологиялык анализдин алгоритмин оптималдаштыруу

Компьютердердин эсine кайрылууну азайтуу максатында биз томенкүдөй алгоритмди пайдаландык:

1. Кийирилүүчү же анализденүүчү сөздүн биринчи эки тамгасы боюнча маалыматтар базасынан сөздөрдү белүп алабыз.
2. Виртуалдык эсти пайдаланып атайын массивге жайгаштырабыз.
3. Анализденүүчү сөздү “ондон солго” ыкмасын пайдаланып салыштырып, сөздүн негизин белүп алабыз.
4. Мүчөлөрдү грамматикалык категориялар боюнча белгилөө үчүн маалыматтар базасында мүчөлөр таблицасын пайдаланабыз. Итерациянын саны мүчөлөрдин санынан көз каранды болот.
5. 1-сүрөттө көрсөтүлгөн фрейм-моделдин текст түрүндөгү формасын жыйынтык катары алабыз

Белгилүү болгондой, морфемалар тилдин эң кичине маани берүүчү (семантикалык) бирдиги болуп саналат, алардан сөздүн формасы түзүлөт, андан ары, ошого жараша, лексема дагы. Кыргыз тилинде мүчөлөр төрт негизги түрө болуноят. Төмөндө баяндалган мүчөлөр сөздүн негизин аныктоочу иштелип жаткан алгоритмде колдонулат.

Белгилеп алабыз P_i , $i = 1, 2, 3, 4$ үчүн мүчөлөрдүн (аффикстердин) томенкү көптүктөрүн:

Терминалдар массалык баш мүчөлөрдүн томенкү топтомун билдириет

P_1 – үч тамгалуу мүчөлөрдүн көптүгү (көптүк түрдүн мүчесү);

P_2 – мүчөлөрдүн көптүгү (илик жөндөмөсүнүн мүчөлөрү);

P_3 – мүчөлөрдүн көптүгү (жеке жалгоолору);

P_4 – мүчөлөрдүн көптүгү (жөндөмө мүчесү).

Эгерде сөз $x \in P_i$ болсо, анда бардык $i = 1, \dots, 4$ үчүн $P_i(x)$ деп алабыз.

Эгерде сөз $x \in W$ болсо, анда $W(x)$ деп белгилейбиз.

Эгерде сөз $x \in Q$ болсо, анда $Q(x)$ деп белгилейбиз.

Анда биздин *A-H* эрежелеребиз томенкү формулалар боюнча өзгөрөт [6].

Каалагандай z сөзү $x_0 + x_1 + x_2 + \dots + x_k$ тамгалардан турсун дейли. (x_i – сөздөгү тамгалардын эң көбү). $i = k$, $x = x_i$ десек:

1-кадам.

$$A = \begin{cases} P_4(x) \rightarrow Q(z \setminus x), & z = z \setminus x \in N, x_{i-n} + \dots + x_{i-1} + x_i \neq P_1 \\ & n = \text{length}(P_1) \\ P_1(x) \rightarrow Q(z \setminus x), & z = z \setminus x \in N, \\ & x_{i-2} + x_{i-1} + x_i \neq P_4 \end{cases}$$

2-кадам

$$B = \begin{cases} P_2(x) \rightarrow Q(z \setminus x), & z = z \setminus x \in N, x_{i-2} + x_{i-1} + x_i \neq P_1 \\ & x_{i-2} + x_{i-1} + x_i \neq P_4 \\ P_1(x) \rightarrow Q(z \setminus x), & z = z \setminus x \in N, \\ & x_{i-2} + x_{i-1} + x_i \neq P_4 \end{cases}$$

3-кадам

$$C = \begin{cases} P_4(x) \rightarrow Q(z \setminus x), & z = z \setminus x \in N, \\ & x_{i-2} + x_{i-1} + x_i \neq P_1 \\ P_3(x) \rightarrow Q(z \setminus x), & z = z \setminus x \in V \\ P_1(x) \rightarrow Q(z \setminus x), & z = z \setminus x \in N, \\ & x_{i-n} + \dots + x_{i-1} + x_i \neq P_3 \\ & n = \text{length}(P_3) \end{cases}$$

4-кадам

$$D = \begin{cases} P_2(x) \rightarrow Q(z \setminus x), & z = z \setminus x \in N, \\ & x_{i-n} + \dots + x_{i-1} + x_i \neq P_1 \\ P_3(x) \rightarrow Q(z \setminus x), & z = z \setminus x \in V, \\ & x_{i-n} + \dots + x_{i-1} + x_i = P_4 \\ P_1(x) \rightarrow Q(z \setminus x), & z = z \setminus x \in N, \\ & x_{i-n} + \dots + x_{i-1} + x_i \neq P_3 \end{cases}$$

5-кадам

$$E = \begin{cases} P_1(x) \rightarrow Q(z \setminus x), & z = z \setminus x \in N, \\ & x_{i-2} + x_{i-1} + x_i \neq P_3 \\ P_2(x) \rightarrow Q(z \setminus x), & z = z \setminus x \in V, x_{i-n} + \dots + x_{i-1} + x_i = P_1 | \\ & x_{i-n} + \dots + x_{i-1} + x_i \neq P_4 \end{cases}$$

6-кадам

$$F = \begin{cases} P_4(x) \rightarrow Q(z \setminus x), & z = z \setminus x \in N, \\ & x_{i-n} + \dots + x_{i-1} + x_i \neq P_1 \\ P_3(x) \rightarrow Q(z \setminus x), & z = z \setminus x \in V, \\ & x_{i-n} + \dots + x_{i-1} + x_i = P_4 \end{cases}$$

7-кадам

$$G = \begin{cases} P_2(x) \rightarrow Q(z \setminus x), & z = z \setminus x \in V, \\ & x_{i-n} + \dots + x_{i-1} + x_i = P_1 \\ P_3(x) \rightarrow Q(z \setminus x), & z = z \setminus x \in V \\ & x_{i-n} + \dots + x_{i-1} + x_i = P_4 \end{cases}$$

8-кадам

$$H = \begin{cases} P_3(x) \rightarrow Q(z \setminus x), & z = z \setminus x \in V \\ & x_{i-n} + \dots + x_{i-1} + x_i = P_4 \\ P_1(x) \rightarrow Q(z \setminus x), & z = z \setminus x \in N, \\ & x_{i-n} + \dots + x_{i-1} + x_i \neq P_3 \end{cases}$$

Бул кадамдардан кийин сөздөрдүн аффикстерин текшерүү бүтөт, эгерде жыйынтык жок болсо 1-кадамга кайрадан кайтат. Жыйынтыгында сөздүн нормалдуу формасын алабыз.

Төртүнчү бап иштин борбордук белүгү болуп эсептелет. Мында автор тарабынан иштелип чыккан кандайдыр бир деңгээлде тилден көз каранды болбогон табигый тилдин формалдык лингвистикалык модели жана бул модельдин негизинде түзүлгөн системанын структуралык схемасы көлтирилди (3-сүрөт).

Морфологиялык категориялар. Алардын тизмеси төмөнкү категориялар менен аныкталат:

1. Зат атооч – Noun:

Сан категориясы – Number

1. Жекелик сан – singular

2. Көптүк сан – plural

Энтектери:

1. SG $\leftrightarrow \emptyset$

2. PL $\leftrightarrow \text{ЛАр}$

Таандык категория – Possessive

Жекелик сан – singular:

1. Таандык жекелик сан 1-жак- 1st person singular possessive ('my'),

2. Таандык жекелик сан 2-жак- 2nd person singular possessive ('your'),

3. Таандык жекелик сан 2-жак, сылык түрү - 2nd person sing.poss. formal ('youg'),

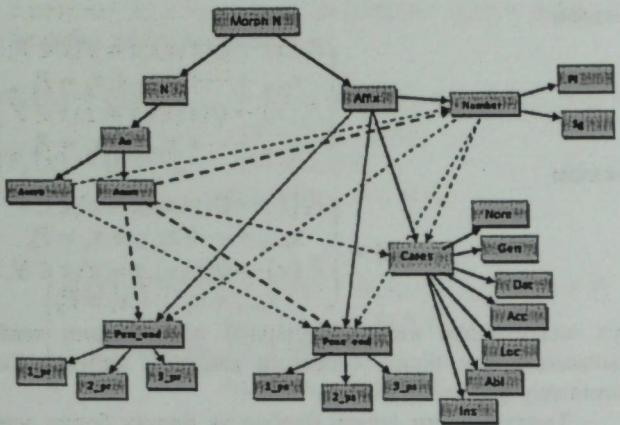
4. Таандык жекелик сан 3-жак- 3rd person singular possessive ('his/her/its'),
Көптүк сан – plural:

5. Таандык көптүк сан 1-жак - 1st person plural possessive ('our'),

6. Таандык көптүк сан 2-жак - 2nd person plural possessive ('your'),

7. Таандык көптүк сан 2-жак, сылык түрү - 2nd person pl.poss. formal ('your'),

8. Таандык көптүк сан 3-жак - 3rd person plural possessive ('their'),



3-сүрөт. Атоочтук сөздөрдүн жасалуу модели

Кыргыз тилинин морфологиясынын математикалык модели

Ар кандай агглютинативдик тилдер үчүн сөз формасын $S_n = h_1 h_2 \dots h_n$ деп алсак, мында h_i ($i=1, 2, \dots, n$) A алфавитиндең элементі, n – элементтердин саны (жолчонун узундугу). Биз изилдөөдө кыргыз алфавитин пайдаланыбиз. Алфавит 36 тамгадан турат жана “_” символу курук символ үчүн колдонулат:

жана биз жолчого камтылуучу жолчо үчүн төмөнкүдөй белгилөөнүү кийирип алабыз: $1 \leq i \leq j \leq n$ үчүн S_{ij} камтылуучу жолчосу төмөнкүдөй аныкталат:

$$S_n[i:j] = h_i h_{i+1} \dots h_j$$

$$S_n[:j] = h_1 h_2 \dots h_j$$

$$S_n[i:] = h_i h_{i+1} \dots h_n$$

Биздин белгилөөлөрдүн негизинде аттайын камтылуучу жолчо $S_n[i:i+1] = h_i h_{i+1}$ удаалаш тамгалар жубу (h_1, h_2), аркылуу белгиленет. Мында камтылган индекс i ($i=1, 2, \dots, n-1$) ге барабар жана удаалаш жайгашкан тамгалар жубунун баштапкы позициясын көрсөтөт $h_1=h_i$, $h_2=h_{i+1} \in A$. $i=n$ үчүн удаалаш жуп null символоду кошуу менен $(h_n, '_')_{i=n}$ барабар болот. Ошентип $S_n = h_1 h_2 \dots h_n$ жолкосу n удаалаш жупка ээ болот.

$1 \leq j \leq n_{max}$ (мында n_{max} кыргыз тишиндеги мүмкүн болгон сөз узундугу) интервалында жолугуусу мүмкүн болгон берилген иреттеген $(h_1, h_2)_j$ тамгалар жубу үчүн жана $S_n = h_1 h_2 \dots h_n$; $n \geq j$ болсо, $(h_1, h_2)_j \in S_n$ учурда удаалаш жуп болгон $(h_1, h_2)_j S_n$ дин i ($1 \leq i \leq n$) позициясында болсо, $(h_1, h_2)_i = (h_1, h_2)_j$ $i=j$ үчүн аткарылат. Жыйынтыктап айтканда биз дагы эки символду таптык:

$g_m = S_n[:m]$ жана $e_m = S_n[m:]$ ар кандай сез формасын ирттеген эки жуп камтылуучу жолчолор катары төмөнкүдей берүүгө болот:

бардык $1 \leq m \leq n$ үчүн $S_n^m = (g_m, e_m)$.

L көптүгү (h_1, h_2), ирреттелген жуп тамгаларынын мүмкүн болгон бардык түрүн камтысынын жана каалаган кыргыз сөздөрүндө $i=1, \dots, n_{max}$ позициясында жолуксун. Анда L жөнөкөй мейкиндиги төмөнкүдей аныкталат:

$$L = \{(h_1, h_2) | h_1, h_2 \in A \text{ and } 1 \leq i \leq n_{max}\}$$

Андан ары G_k , E_k , жана T_k көптүктөрү берилсін. Мында G_k , E_k , $T_k \subset L$, $1 \leq k \leq n_{max}$ абалды аныктайтын жана төмөнкүдөй табылат:

$$G_k = \{(h_1, h_2)_i | i = k \text{ and } (h_1, h_2)_i \in g_m \text{ and } 1 \leq m \leq n_{max}\}$$

$$E_k = \{(h_1, h_2)_i | i = k \text{ and } (h_1, h_2)_i \in e_m \text{ and } 1 \leq m \leq n_{max}\}$$

$$T_k = \{(h_1, h_2)_i | i = k, h_1 = s_n[k:k], h_2 = s_n[k+1,k+1], 1 \leq i \leq n_{max}\}$$

Ошентип, $(h_1, h_2)_i$ ирттеген жубу үчүн $S_n = h_1 h_2 \dots h_n$ менен белгиленген ар кандай берилген сөз формасынын $i=1, 2, \dots, n$ позициясында жолугуусу жогоруда каралган үч көптүктөн төмөнкүдөй аныктоого болот:

$$Pr(s_n[i:i+1] \in G_l) = Pr((h_1, h_2)_i \in G_l) = P_G((h_1, h_2)_l) \quad (1)$$

$$Pr(s_n[i:i+1] \in E_t) = Pr((h_1, h_2)_i \in E_t) = P_E((h_1, h_2)_i) \quad (2)$$

$$Pr(s_n[i:i+1] \in T_l) = Pr((h_1, h_2)_i \in T_l) = P_T((h_1, h_2)_i) \quad (3)$$

Мында (1) тенденце иреттелген (h_1, h_2) , жубунун сөздүн негизинде жайгашуусун аныктайт, (2) тенденце иреттелген (h_1, h_2) , жубунун сөздүн аффикс белүгүндө жайгашуусун аныктайт, ал эми (3) тенденце иреттелген (h_1, h_2) , жубунун сөздүн негизи менен аффикс белүктөрүүнүн ортосунда жайгашуусун аныктайт.

Кыргыз тилиндеги сөздөрдүн грамматикалык формасы агглютинативдик чыңкырыччынын жаралуу эрежесине ылайык унгудан жана уланды аффикстерден турат. Сөздөрдүн грамматикалык формасынын моделин төмөнкүдөй көрсөтүүгө болот:

$$S = R + \sum_{i=0}^m U_i, (m \leq 8) \quad (4),$$

мында, S – сөз формасы, R – уңгу же сөздүн негизи, U_r – уланды аффикстер.

(4) формуладан көрүнүп турғандай сөздүн грамматикалык формасын табууда $k=length(S)-length(R)$ жолу итерациялоодон кийин сөздүн үнгусу жана уланды мүчөлөр бөлүнүп алынат.

Уланды аффикстердин саны сегиз көрсөткүчке чейин жетиши ыктымал, башкача айтканда:

$$\sum_{l=0}^8 U_l = U_0 + U_1 + U_2 + \dots + U_8 \quad (5)$$

Аныктама 1: Эгерде $U_m = \emptyset$ болсо, анда S функциясы сөздүн негизине же унгуга барабар болот, жана кийирилген сөз эч кандай ажыроосуз сөздүктөгү лексемага дал келет.

Эгерде изилденүүчүү сөз формасынын узундугу $l=length(S)$ аркылуу табылса, анда создуктөн табылган сөз формаларынын көптүгүн тү деп алсак, ал ($l \times m$) сегментациялык матрицасын жаратат.

$$m \left\{ \begin{array}{c} \overbrace{1 \ 1 \ a_{31}a_{41} \dots a_{l1}}^{l \geq l} \\ 1 \ 1 \ a_{32}a_{42} \dots a_{l2} \\ \dots \\ 1 \ 1 \ a_{3m}a_{4m} \dots a_{lm} \end{array} \right\}$$

матрицадагы ар бир жолчо бир сөз формасын берет жана кайсы жолчонун суммасы максималдуу болсо, ошол создун негизи болот.

Матрицанын негизинде

$$\begin{cases} x_1 + x_2 + x_3 + \dots + x_l \leq l \\ x_1 + x_2 + x_3 + \dots + x_{l-i} \leq l - i \end{cases}$$

тендештиктөр системасы алынат.

Системаны чыгарууда кайсы жолчодо бирлердин саны көп болсо, ошол жолчонун элементтеринен түзүлгөн көптүк тендеменин тамыры катары кабыл алынат.

Мисалы, абалы деген создун нормалдуу формасын табууда создуктөн 6 массивдин элементти алынат. Массивдердин элементтерин сегментациялоодон кийин компьютердин эсинде төмөнкүдөй матрица түзүлөт:

$$M = \begin{vmatrix} 1 & 1 & 1 & 0 & 0 \\ 1 & 1 & 1 & 0 & 0 \\ 1 & 1 & 1 & 0 & 0 \\ 1 & 1 & 1 & 1 & 0 \\ 1 & 1 & 1 & 1 & 0 \end{vmatrix}$$

Матрицанын элементтерин анализдеп 4 жана 5 жолчолорду бөлүп аласыз:

$$M = \begin{vmatrix} 1 & 1 & 11 & 0 \\ 1 & 1 & 11 & 0 \end{vmatrix}$$

Бул экى жолчонун узундуктарын бир елчөмдүү массивге жайгаштырабыз:
 $L=\{l_1, l_2\}$. Биздин учурда экى жакын жолчолордун саны 2 ге барабар болду. Кээ бир учурда бул көрсөткүч бир кыйла көп болот. Мисалы **кыргыздар** сөзү үчүн бул көрсөткүч {кыргыз, кыргын, кыргыч, кыргый, ...} болуп өсүп кетет. Алынган массивдин жакындаштырылган маанисин итерациялоо аркылуу табабыз:

```
For i:=1 to length(L) do
If min>l[i] then min:=l[i];
```

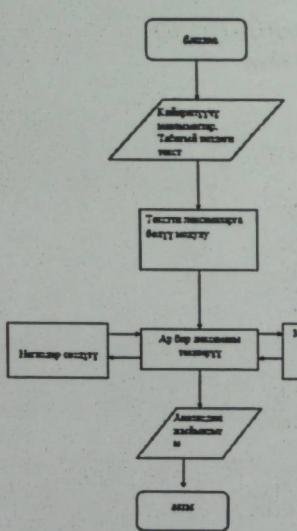
Бул механиздин жыйынтыгында узундугу боюнча минималдуу жолчону аласыз. Ал M[5] болуп табылат б.а. теменкү фрагмент аткарылат:

```
ss2:=trim(Edit1.Text);
d:=strtoint(edit3.Text);
edit2.Text:="";
1:
l:=length(ss2);
for i:=1 to 46 do
if (ss2=m[i]) or (ss2=(copy(m[i],1,length(m[i])-1))+'б')
or (ss2=(copy(m[i],1,length(m[i])-1))+'з') then
begin
edit2.Text:=m[i];
form1.RichEdit3.Lines.Add(mucho.edit2.Text);
case strtoint(m3[i]) of
1:form1.RichEdit3.Lines.Add('зам атооч');
2:form1.RichEdit3.Lines.Add('сын атооч');
3:form1.RichEdit3.Lines.Add('сан атооч');
4:form1.RichEdit3.Lines.Add('ам атооч');
5:form1.RichEdit3.Lines.Add('этини');
6:form1.RichEdit3.Lines.Add('тактооч');
7:form1.RichEdit3.Lines.Add('сырдык сөз');
8:form1.RichEdit3.Lines.Add('тууранды сөз');
9:form1.RichEdit3.Lines.Add('жандооч');
10:form1.RichEdit3.Lines.Add('байламта');
11:form1.RichEdit3.Lines.Add('кызматчы сөз');
end;end;
ss3:=ss3+copy(ss2,l,l);
ss2:=copy(ss2,1,l-1);
if edit2.Text=" then goto 1
else if (m[i]!=") then
begin
timer1.Enabled:=true; end;
aff:="";
for i:=1 to length(ss3)-1 do
aff:=aff+ss3[Length(ss3)-i];edit4.Text:=aff;
Морфологиялык анализатордун алгоритми
Аталган алгоритмдин блок схемасы 4 жана 5-сүрөттөрдо корсөтүлген.
Морфологиялык анализ жүргүзүүнүн 3 деңгээлин бөлүп кароого болот:
1. Создун грамматикалык маанисин гана аныктоо;
2. Создун негизин гана аныктоо;
3. Создун грамматикалык маанисин жана негизин аныктоо.
Морфологиялык анализди өтө терен же толук эмес изилдөө коюлган маселеге жараша болот.
```

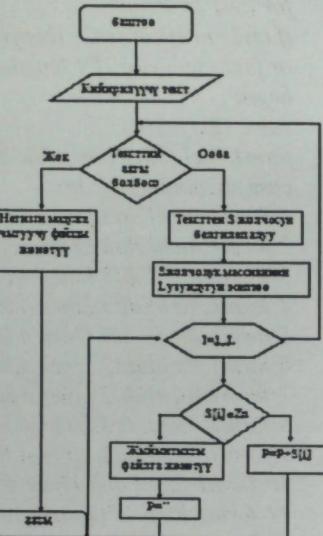
Морфологиялык анализ табигый тил менен байланышкан ар түрдүү маселелердин баштапкы текпичи болгондуктан, анын канчалык так аткарылгандыгы чоң маанингэ ээ.

Морфологиялык анализдин ықмаларын 3 типке бөлсө болот:

1. мүчелердүн сөздүгү менен анализдөө;
2. мүчелер жана негиздер сөздүгүнүн жардамында анализдөө;
3. сез тутумдарынын сөздүгүнүн жардамында анализдөө.



4-сүрөт. Морфологиялык анализдин алгоритми



5-сүрөт. Текстти лексемаларга белүү модулунын алгоритми

Бешинчи бапта түзүлгөн морфологиялык анализатордун программасын тесттен өткөрүү амалдары каралат.

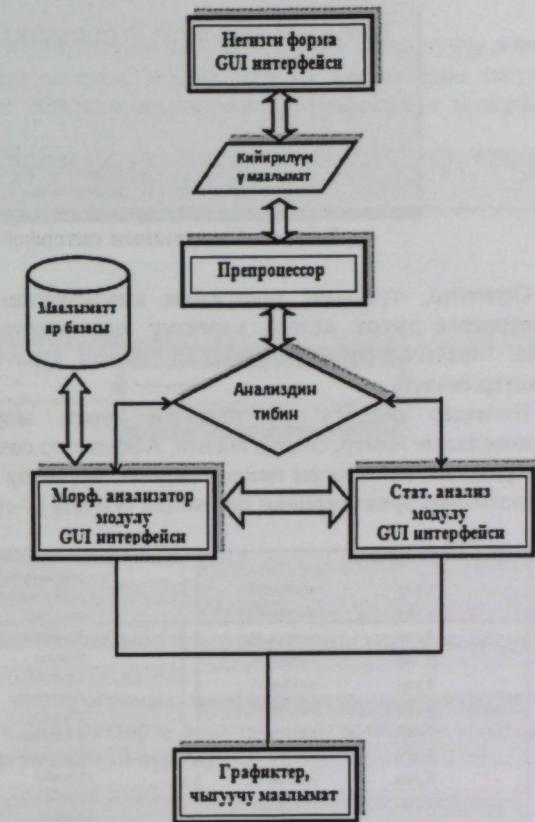
Иштөлип чыккан программа табигый тилде жазылган тексттерди кийирилүүчүк маалымат катары кабыл алат жана анын негизин бөлүп алат. Жыйынтыгында табылган сөздүн лексикалык маанилери чыгуучу маалымат катары кайтарылат. Программаны түзүү үчүн объекттер менен иштөөчү RAD Studio XE3 чөйрөсү тандалып алынды. Бул чөйрөде типтер менен иштөөдө кийирилген тексттерди кайра иштеп чыгуу үчүн кыргыз тилинин алфавити үчүн unistring тиби колдонулду.

Түзүлгөн система: маалыматтар базасынан, колдонуучу үчүн ыңгайлуу интерфейстен, морфологиялык анализ жана статистикалык анализ модулдарынан турат.

Программанын техникалык камсыздалуусун карасак, 800 дөн ашык жолчодон турат жана 15,7 Мб эстин көлемүн ээлейт. Маалыматтар базасы менен иштөөдө 16 Мб эстин көлемү керектелет жана лингвистикалык

таблицаны сактоо үчүн 40 Кб эстин көлемү керектелет. Ошентип, "NLP" программасы 69 функциядан жана 22 тұрактуң чондуктан турат.

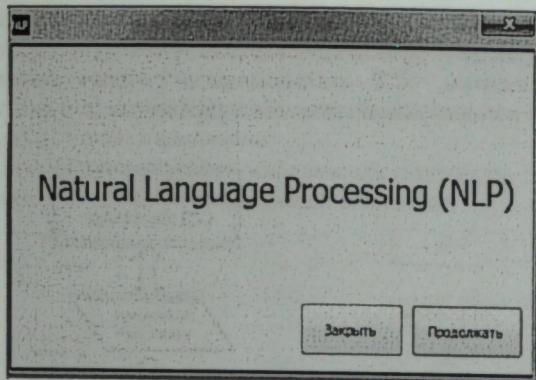
Ошентип, NLP атальшындагы система иштөлип чыкты. Системаны түзүүдө концептуалдык схеманы түзүп алдык (6-сүрөт.)



6-сүрөт. Түзүлүүчү системанын концептуалдык схемасы

Түзүлгөн системаны тесттен откоруу

Морфологиялык анализатордун билүү версиясында маалыматтар базасында көп колдонуулуучу маалыматтар камтылган. Колдонуучу үчүн интерфейс маалыматтар базасынан маалыматтарды алуу максатында GUI форматында түзүлген (7-сүрөт).



7-сүрөт. Системанын интерфейси

Ошентип, түзүлгөн программа маалыматтар базасынан кийирилген параметрлерге туура келген керектүү маалыматтарды болуп алуу менен иштейт. Маалыматтар базасы эки сөздүктөн турат: негиздер сөздүгү жана аффикстер сөздүгү.

Негиздер сөздүгү үч талаадан турат: морфологиялык маалымат, идентификациялык номер, сөздүн негизи. Аффикстер сөздүгүндө мүчөлөр көптүгү идентификациялык номери менен сакталат. Мүчөлөр көптүгү кыргыз тилинин морфологиялык эрежелеринин негизинде түзүлдү (8-сүрөт).

Код	-	muchо	-
1	лар	кептүк, PL	
2	лер	кептүк, PL	
3	лор	кептүк, PL	
4	лер	кептүк, PL	
5	дар	кептүк, PL	
6	дер	кептүк, PL	
7	дер	кептүк, PL	
8	дор	кептүк, PL	
9	дер	кептүк, PL	
10	тар	кептүк, PL	
11	тер	кептүк, PL	

Код	-	sozder	-	ID_st
1	азалам		1	
2	азаламдык		2	
3	аалаш		5	
4	аалим		1	
5	алы		1	
6	алым		1	
7	аамылт		1	
8	аарчы		5	
9	аарчыл		5	
10	аарчын		5	
11	аары		1	
12	аба		1	
13	абаз		1	
14	абай		1	

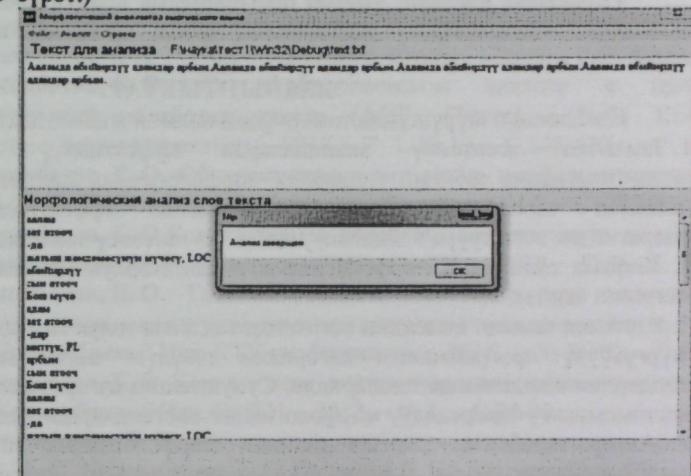
8-сүрөт. а) аффикстер базасы; б) негиздер базасы

Теориялык жактан сөз өзгөртүүчү аффикстерден түзүлгөн бул чыңжырчалар агглютинативдик түрк тилдеринде чексиз узундука ээ болуусу мүмкүн. Бирок, маалыматтар базасын түзүүде аны чектүү деп алуу кабыл алынган жана ал эн көбү сегиз аффикске чейин жетүүсү мүмкүн жана бул статистикалык жактан негиздүү.

Морфологиялык анализатор программасынын иштөө механизми төмөнкүдей. Морфологиялык анализдин программасы аффикстердин чыңжырынын улануу мүмкүндүгүн алломорфтордун кезектешүү эрежесине

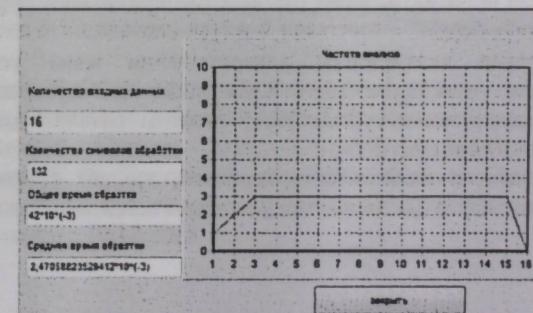
ылайык текшерет, ошондой эле алынган негиздин уланган аффикстердин негизинде морфонологиялык касиеттерге жооп берүүсү текшерилет. Программадын иштөөсү үчүн керек болгон бардык маалыматтар программадын иштөөсү менен оперативдик эске жүктөлөт. Ошентип, түйүндүк маалыматтар базасына кайрылуудан арылабыз жана программадын иштөө тездиги жогорулайт.

Кыргыз тили үчүн сүйлөмдердүү сөздөргө ақыратуучу жана ар бир сөздү аналиzedеп, сөздүн негизин, морфологиялык касиеттерин табуучу программа иштелип чыкты. Алынган жыйынтыктар графикалык интерфейсте көрүнүп турат (9-сүрөт.)



9-сүрөт. Анализатор программынын иштөө жыйынтығы

Ошондой эле программа морфологиялык анализ үчүн статистикалык анализ да жасайды, анда сөздөрдү анализдеөнүн жыштығы эсептелип чыгат жана диаграммасы түргузулат (10-сүрөт.)



10-сүрөт. Статистикалык анализдин жыйынтығы

Жыйынтыктап айтканда, кыргыз тили бардык түрк тилдери сыйктуу эле агглютинативдик тилдердин катарына кирет жана сөздөр негизден жана аффикстер көптүгүнөн турат.

NLP программасын тесттен откөрүүде оң жыйынтыктарды берди жана ал маалымат-издөөчү программаларга, машиналык которуюу системаларында баштапкы модул катары же окуу процессинде кыргыз тилинин морфологиялык анализин үйрөнүү максатында колдонулат.

Корутундуда диссертациялык иште алынган негизги илмий жана практикалык жыйынтыктар тизмектелди.

Тиркемеде иштелип чыккан программалык коддун листинги, кириштөө актылары, аффикстердин жыйындысы жана программага Кыргызпатент тарабынан алынган күбөлүк тиркелди.

ЖЫЙЫНТЫКТАР

Изилдөөнүн жүрүшүндө төмөнкүдей илмий жыйынтыктар алынды:

1. Заманбап эсептөөчү машиналарда эффективдүү иштей турган агглютинативдик табигый тилдердин морфологиялык жактан түзүлүү модели иштелип чыкты. Түзүлгөн программанын эффективдүүлүгү катары оперативдик эсти туура пайдалануу жана тез иштөөсү эсептелет.
2. Кыргыз тили үчүн морфологиялык анализатордун математикалык модели иштелип чыкты.
3. Иштелип чыккан модельдин негизинде так жана толук морфологиялык анализ жүргүзүүчү программанын алгоритми түзүлүп чыкты жана формалдык тилдердин жардамында текшерилди. Сунушталган алгоритмдер жана моделдер жалпысынын универсалдуу морфологиялык системаларды түзэ алат.
4. Автор тарабынан кыргыз тилинин морфологиялык таблицасы жана морфологиялык сөздүк түзүлдү. Бул сөздүк оз ичине (белгилүү булактардан алынган) 15 000 жакын лексеманы камтыйт.
5. Морфологиялык анализдин маселелерин чечүүдө мөалыматтар базасы менен иштөө талабы келип чыкканыктан, программада мөалыматтар базасынын структурасы иштелип чыкты. Мөалыматтарды башкаруу үчүн компьютердин эсine бир жолу кайрылуу менен керектүү сөздөрдүн массивин түзүп алуу амалдары ишке ашты жана бул компьютердин эсин эффективдүү пайдаланууга мүмкүндүк берди.
6. Жогоруда көлтирилген алгоритмдерди жана усулдарды практикалык тестирилөө үчүн Embarcadero RAD Studio XE3 программалоо чөйрөсүндө 800 дөн ашык жолчодон турган “NLP” системи иштелип чыкты.

Практикалык сунуштар

Алынган жыйынтыктар табигый тилдин үстүнөн иштөөчү колдонмо программаларга баштапкы модул катары пайдаланылат.

ЖАРЫК КӨРГӨН ЭМГЕКТЕРДИН ТИЗМЕСИ

1. Кочконбаева, Б. О. Automatic processing of text in natural language [Текст] / Б. О. Кочконбаева, А. Алдосова // Бюллетень науки и практики. – 2018. – Т. 4, № 7. – С. 216-221.
2. Кочконбаева, Б. О. Алгоритм синтаксического анализатора для машинного перевода текстов [Текст] / Б. О. Кочконбаева // Труды V Междунар. науч.-практ. Конф. Информатизация общества. – Астана, 2016. – С.92-95.
3. Кочконбаева, Б. О. Защита информации с помощью криптографических методов [Текст] / Б. О. Кочконбаева, Н. Р. Абыраева // Изв. ОшТУ. – 2010. – № 2. – С.183-186.
4. Кочконбаева, Б. О. Лексический анализатор естественного текста [Текст] / Б. О. Кочконбаева, Н. Р. Абыраева // Изв. ОшТУ. – 2014. – С.207-209.
5. Кочконбаева, Б. О. О морфологическом анализе в приложениях автоматической обработки текста (АОТ) [Текст] / Б. О. Кочконбаева // Бюллетень науки и практики. – 2018. – Т. 1, № 12. – С.608-612.
6. Кочконбаева, Б. О. Об оптимизации алгоритма морфологического анализа [Текст] / Б. О. Кочконбаева, Т. Садыков. – Ташкент, 2018. – С. 293-299
7. Кочконбаева, Б. О. Компьютерная обработка естественного языка [Текст] / Б. О. Кочконбаева, Н. Р. Абыраева // Изв. ОшТУ. – 2015. – С.86-89.
8. Кочконбаева, Б. О. Табигый тилдеги тексттерди орус тилинен кыргыз тилине машиналык которуюуда сөздөрдү анализдөөнүн алгоритмин түзүү [Текст] / Б. О. Кочконбаева // Изв. КТУ им. Раззакова. – 2016. – № 2(38). – С.55-58.
9. Кочконбаева, Б. О. Кыргыз тили үчүн сөздүн негизинаныктоо модели [Текст] / Б. О. Кочконбаева // Изв. ОшТУ. – 2018. – № 1. – С.24-30.
10. Кочконбаева, Б. О. Улуттук корпүс үчүн морфологиялык белгилөөлер [Текст] / Б. О. Кочконбаева, Т. С. Садыков, Б. Ш. Шаршенбиев // Вестн. КРСУ. – 2018. – Т. 18, № 1. – С.91-95.
11. Кочконбаева, Б. О. Модель морфологического анализа кыргызского языка [Текст] / Б. О. Кочконбаева, Т. С. Садыков // Издательство Академии наук Республики Татарстан – Казань, 2017. – С.135-155.
12. Кочконбаева, Б. О. Математическое моделирование и алгоритм морфологического анализа кыргызского языка [Текст] / Б. О. Кочконбаева, А. Дж. Сатыбаев // Бюллетень науки и практики. – 2019. – Т. 5, № 3. – С. 220-224.
13. Кочконбаева, Б. О. Тестирование программы морфологического анализатора естественного языка [Текст] / Б. О. Кочконбаева, А. Дж. Сатыбаев // Бюллетень науки и практики. – 2019. – Т. 5, № 3. – С. 215-219.
14. Кочконбаева, Б. О. Программа для ЭВМ «Natural Language Processing. Морфологический анализатор кыргызского языка» [Текст] / Свидетельство КР, №537-Кыргызпатент, 19.12.2018.

Кочконбаева Бұажар Осмоналиевнанын 05.13.18 - математикалық моделдөө, сандық ықмалар жана программалар комплекси адистиги бойонча «Кыргыз тили үчүн морфологиялык анализатордун моделдерин жана алгоритмдерин иштеп чыгуу» аттуу темасында аткарылган диссертациясынын

ТАРЖЫМАЛЫ

Ачыкч сөздөр: морфологиялык анализатор, машиналык которуу, стемминг, морфологиялык талдоо, лемматизация, аффикстер, сөз формасы, сөздүн нормалдык формасы.

Изилдөө объектиси: табигый тилдеги тексттерди морфологиялык иштеп чыгуунун ықмалары изилдөөнүн объектиси болуп эсептелет.

Изилдөөнүн предмети: текстти иштеп чыгуунун автоматтык морфологиялык анализинин программасын түзүүдө, аны формалдык түрдө кароо үчүн керек болгон кыргыз тилинин морфологиялык түзүлүшүн изилдөө; сөздүктүү сунуштоонун ықмалары жана компьютердин эсинде сакталган сөздүккө жеткиликтүүлүктүү ылдамдатууга байланыштуу морфологиялык маалыматтар; морфологиялык анализдин жана сөдердүн негизин табуунун ықмалары жана алгоритмдері.

Иштин максаты: морфологиялык анализатордун алгоритмдерин жана моделдерин түзүү.

Изилдөө ықмалары: алдыда коюлган маселени чечүүдө морфологиялык анализдин ықмалары, лингвистикалык мыйзам ченемдүүлүктөрдү түннүрүүчүү математикалық моделдөө элементтери, ошондой объектке бағытталган программалоонун ықмалары колдонулган.

Аппаратура: ноутбук Intel Core i3, Embarcadero RAD Studio XE3

Иштин негизги натыйжалары: морфологиялык анализдин математикалық моделдери жана алгоритмдерин иштелип чыкты, ошондой эле морфологиялык анализатордун автоматташтырылган системасы жана көп колдонулучу сөздөрдүн сөздүгү түзүлгөн.

Изилдөөнүн натыйжаларын колдонуу: иштелип чыккан морфологиялык анализатордун системасы М.М. Адышев атындагы Ош технологиялык университетинин окуу процессинде колдонууга киргизилди жана мамлекеттик Ош педагогикалык институтунун электрондук библиотекасына маалымат издөөчү модул катары кириштеди. Ошондой эле Кыргыз Республикасынын Президентине караштуу Мамлекеттик тил боюнча улуттук комиссиясынын экспертери тарабынан жактырылды.

Колдонуу тармагы: изилдөөнүн натыйжалары жана иштелип чыккан система машиналык которуу, эксперттик системаларда, окутуу жана үйрөтүүчү системаларда базалык модуль катары колдонулат.

РЕЗЮМЕ

диссертации Кочконбаевой Бужар Осмоналиевны на тему: "Разработка моделей и алгоритмов морфологического анализатора для кыргызского языка" на соискание ученой степени кандидата технических наук по специальности 05.13.18 - математическое моделирование, численные методы и комплексы программ

Ключевые слова: морфологический анализатор, машинный перевод, стемминг, морфологический анализ, лемматизация, аффиксы, словоформа, нормальная форма слов.

Объект исследования: методы обработки текстов естественного языка.

Предмет исследования: изучение строения словоформ кыргызского языка, создание программы автоматического морфологического анализатора для обработки естественного текста; визуализация морфологических данных, с хорошим доступом к словарю, хранящегося на жестком диске; методы и алгоритмы морфологического анализа и нормализации слов;

Цель исследования: разработка автоматизированного морфологического анализатора.

Методы исследования: при решении поставленных задач в работе использованы методы морфологического анализа. Применены элементы моделирования для построения математических моделей, описывающих лингвистические закономерности, а также методы объективно-ориентированного программирования.

Аппаратура: ноутбук Intel Core i3, Embarcadero RAD Studio XE3

Полученные результаты и их новизна: разработаны математические модели и алгоритмы морфологического анализа, а также автоматизированная система морфологического анализатора и словарь с часто используемыми словами.

Использование результатов исследования: автоматизированная система морфологического анализа внедрена в учебный процесс Ошского технологического университета им. М.М. Адышева и в электронную библиотеку Ошского государственного педагогического института в качестве модуля поиска информации. А также программа получила положительные отзывы от экспертов национальной комиссии по Государственному языку при Президенте Кыргызской Республики.

Область применения: Результаты исследования и разработанная система могут быть использованы в системах машинного перевода, экспертных системах, обучающих системах, как базисный модуль.

SUMMARY

of the dissertation of Kochkonbaeva Buazhar Osmonalievna on the theme:
"Development of models and algorithms of morphological analyzer for the
Kyrgyz language" for the degree of candidate of technical sciences, specialty
05.13.18 - mathematical modeling, numerical methods and program complexes.

Keywords: morphological analyzer, machine translation, stemming, morphological analysis, lemmatization, affixes, word form, normal form of words.

Object of the research: Natural language text processing methods.

Subject of research: study of the structure of word forms of the Kyrgyz language, the creation of an automatic morphological analyzer program for processing natural text; visualization of morphological data, with good access to the dictionary stored on the hard disk; methods and algorithms for morphological analysis and normalization of words;

Purpose of the research: Development of an automated morphological analyzer.

Research methods: in solving the tasks in the work used analytical methods. The elements of modeling are used to build mathematical models that describe linguistic patterns, as well as methods of object-oriented programming.

Hardware: laptop Intel Core i3, Embarcadero RAD Studio XE3

Using the results of the study: an automated system of morphological analysis was introduced into the educational process of the Osh technological University after named M.M. Adyshev and the electronic library of the Osh State Pedagogical Institute as a module for information retrieval. As well as the program received positive feedback from experts of the national commission on the State language under the President of the Kyrgyz Republic.

Scope: The research results and the developed system can be used in machine translation systems, expert systems, training systems, as a basic module.

Кочконбаева Бұажар Осмоналиевна



**КЫРГЫЗ ТИЛИ УЧУН МОРФОЛОГИЯЛЫК АНАЛИЗАТОРДУН
МОДЕЛДЕРИН ЖАНА АЛГОРИТМДЕРИН ИШТЕП ЧЫГУУ**

Техника илимдеринин кандидаты окумуштуулук
даражасын изденип алуу үчүн жазылган диссертацияга

АВТОРЕФЕРАТ

Басылмага кол коюлган: 17.05.2019 ж.

Форматы 60x84/16. Көлемү 1,5 б.т.

Офсеттик кагаз. Нускамасы 60 даана.

Н. Исанов ат. Кыргыз мамлекеттik курулуш,
транспорт жана архитектура университети
«Авангард» окуу-басма борбору
720020, Бишкек ш., Малдыбаев көч., 34, б

