

ISSN 2181-922X

O'ZBEKISTON

TIL VA MADANIYAT

UZBEKISTAN

LANGUAGE AND CULTURE

2021 Vol. 1

www.navoiy-uni.uz
www.uzlc.uz

Alisher Navoiy nomidagi Toshkent davlat o'zbek tili va adabiyoti universiteti

Bosh muharrir: Shuhrat Sirojiddinov

Bosh muharrir o'rinnbosari: Zaynobiddin Abdirashidov

Mas'ul kotib: Ozoda Tojiboyeva

Tahrir kengashi

Ahmadali Asqarov, Abdulaziz Mansur, Akmal Saidov, Akmal Nur, Adham Ashirov, Nizomiddin Mahmudov, Hamidulla Dadaboyev, Samixon Ashirboyev, Bahodir Karimov, Aftondil Erkinov, Baxtiyor Mengliyev, Sulton Normamatov, Murtazo Sayidumarov, G'aybullha Boboyorov, Qosimboy Ma'murov, Nozliya Normurodova, Abdi Mamatov.

Tahrir hay'ati

Frederik Bressand (Fransiya)	Shahid Tasleem (Hindiston)
Ingeborg Baldauf (Germaniya)	Almaz Ülvi (Ozarbayjon)
Homid Abbas Xan (Saudiya Arabiston)	Vahit Türk (Turkiya)
Rochelle Almeida (AQSH)	Abdulvahap Kara (Turkiya)
Akrom Habibullayev (AQSH)	Mustafa Kaçalin (Turkiya)
Valeri S. Xan (O'zbekiston)	Timur Kocaoğlu (AQSH)
Xisao Komatsu (Yaponiya)	Alizoda Saidumar (Tojikiston)
Gürer Gülsevin (Turkiya)	Dilorom Ashurova (O'zbekiston)
Eunkyung Oh (Janubiy Koreya)	Isa Habibbeyli (Ozarbayjon)
Dilnoza Duturayeva (O'zbekiston)	Shodmon Vohidov (Tojikiston)
Rustam Suleymanov (O'zbekiston)	Darya Jigulskaya (Rossiya)

"O'zbekiston: til va madaniyat" jurnali – lingvistika, tarix, adabiyot, tarjimashunoslik, san'at, etnografiya, falsafa, antropologiya va ijtimoiy tadqiqotlarni o'rganish kabi sohalarni qamrab olgan akademik jurnal.

Jurnal bir yilda to'rt marta chop etiladi.

Jurnalning maqsadi – ko'rsatilgan sohalarga oid dolzarb mavzulardagi bahs-munozaraga undaydigan, yangi, innovatsion g'oyalarga boy, o'z konsepsiysiga ega bo'lgan tadqiqotlarni nashr etishdir.

Ingliz, rus va o'zbek tillaridagi, shuningdek, boshqa turkiy tillarda yozilgan maqolalar qabul qilinadi. Iqtisodiy tahlillar hamda siyosatga oid maqolalar e'lon qilinmaydi.

Jurnalda kitoblarga yozilgan taqrizlar, adabiyotlar sharhi, konferensiylar hisobotlari va tadqiqot loyihalari natijalari ham e'lon qilinadi. Mualliflar fikri tahririyat nuqtai nazaridan farq qilishi mumkin.

Alisher Navoiy nomidagi Toshkent davlat o'zbek tili va adabiyoti universiteti

O'zbekiston, Toshkent, Yakkasaroy tumani, Yusuf Xos Hojib ko'chasi, 103.

Email: uzblangcult@gmail.com

Website: www.uzlc.uz

Manzura Abjalova
(Toshkent, O'zbekiston)
abjalovamanzura@navoiy-uni.uz

Dilrabo Elova
(Toshkent, O'zbekiston)
dilrabo@navoiy-uni.uz

Tabiiy tilni qayta ishlash (nlp)da so'z turkumlarini teglash masalasi

Abstrakt

Kompyuter lingvistikasida tabiiy tilni qayta ishlash ancha murakkab jarayon bo'lib, unda ijtimoiy tabiatga ega tilning barcha hodisalari, umumiyligi va xususiy jihatlari, istisnoli holatlari, fonetik, morfonologik, leksik, grammatik, semantik va hatto orfoepik xususiyatlarini e'tiborga olish zarur hisoblanadi. Sun'iy intellekt tizimini yaratishga bel bog'langan ayni damda matn birliklarini raqamli texnologiyalar orqali qayta ishlanishiga erishish muhim natija hisonlanadi. Bunday jarayonda so'zlarning turkumini aniqlash zarur. Jahan kompyuter lingvistikasidan ushbu lingvo-texnik tahlilning so'zlar turkumini aniqlash – PoS-tagger, ya'ni so'z turkumlarini teglash, shuningdek, uning matnlarni avtomatik qayta ishlash jarayoni bosqichi ekanligi ma'lum. Til korpuslarini yaratish uchun boshlangan dastlabki teglash harakatlari bugungi kunga kelib, matn bilan bog'liq ko'plab dolzarb masalalar yechimini bermoqda. NLP, ya'ni tabiiy tilni qayta ishlash jarayonida ham so'z turkumlarini teglash birlamchi vazifa hisoblanib, buning natijasida omonimlikni, ko'p ma'noli so'zlar semantikasini aniqlash kabi turli lingvistik noaniqlar matn tarkibida tahlil qilinishiga erishiladi.

Mazkur maqolada so'z turkumlarini teglash zarurati, matnlarni kompyuter tahlili jarayonida uning ahamiyati, teglash usullari haqida so'z yuritiladi.

Kalit so'zlar: tabiiy tilni qayta ishlash, teglash, teg, so'zlar turkumi, formal til, pragmatik xususiyat, korpus, polisemiya, omonimiya.

The Task of Tagging Part of Speech in Natural Language Processing

Abstract

Natural language processing is a complex process that requires

consideration of all phenomena, general and particular aspects, exceptions, phonetic, morphological, lexical, grammatical, semantic and even orthoepic features of a social language. At the same time, since the creation of an artificial intelligence system is an important result, it is important to achieve the processing of text units using digital technologies. In this process, it is necessary to determine the parts of speech of words. In computational linguistics, it is known that this linguistic and technical analysis is a stage of marking words – PoS-tagger, that is, tagging a part of speech of words, and is also considered the main stage of automatic text processing. Initial attempts to create tags to create a language corpus solved many of the most pressing text problems today. In natural language processing (NLP), word labeling is also a primary concern, which leads to the analysis of various linguistic ambiguities in the text, such as the definition of homonymy and semantics of ambiguous words.

This article discusses about part-of-speech tagging words, its significance in the process of computer analysis of texts, and the methods of tagging.

Key words: natural language processing, tagging, tag, part-of-speech, formal language, pragmatic feature, corpus, polysemy, homonymy, PoS-tagging.

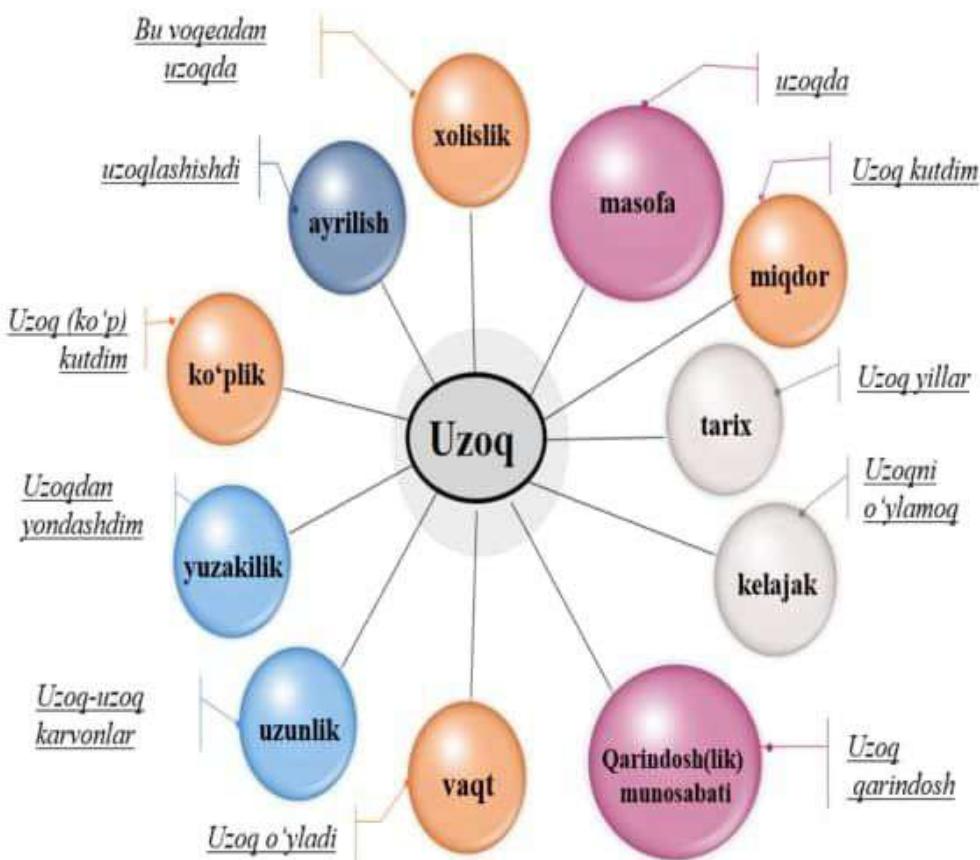
Kirish

Inson borki, muloqotga oshiqadi, o'z fikrlari va tuyg'ularini izhor etishni xohlaydi. Axborot asrida bo'lajak haqiqatni virtual tasavvur qiling: yoningizdagi robot itga "Men seni yaxshi ko'raman" (mehr, samimi yunosabat izhor etilyapti) va "Men seni yaxshi ko'ryapman" (ko'zning yaxshi ko'rayotganligini anglatadi) jumlalarini aytdingiz. Har ikki jumlanı eshitib it dumini qimirlatadi. Lekin u bu jumlalarni qanday ma'noda qabul qilgan bo'ladi?

Robot it "Men seni yaxshi ko'raman, Qoravoy" deganingizni eshitganida, u "yaxshi ko'rmoq" ibora ekanligini anglashi mumkin. Ko'zlariningizdan, yuzingizda namoyon bo'lib turgan mehringiz orqali bu ifodaning tuyg'u ekanligini va unga qandaydir yunosabat bildirishini tushunadi. Lekin unga qarata aynan ko'rish a'zoingiz (ko'z)ning shoh pardasi yanada ravshan ko'ra boshlaganini bildirib aytilgan "Men seni yaxshi ko'ryapman" (buyam sevinch va hayajon bilan) jumladagi birikmani to'g'ri ma'noda tushunmasligi mumkin. Mana shu misol robotni, ya'ni mashinani biz biladigan tilda muloqot qilishni o'rgatish kerakligini ko'rsatadi.

Yuqoridagi misoldan ayon bo'lganidek, muayyan so'zning turli xil kontekstda ishlatalishidagi farqni tushunish judayam muhim. Tilning pragmatik xususiyatiga oid ushbu fikrga "uzoq" so'zi orqali

yana bir misol keltiramiz (1-chizma):



1-chizma.

Mashinani tilga o'qitish uchun nima qilmoq kerak?

Ma'lumki, deyarli barcha mamlakat xalq ta'limi maskanlarida boshlang'ich sinflaridanoq o'quvchi gapni o'qiydi va undagi ot, sifat, son, fe'l, ravish, olmosh so'z turkumlarini aniqlaydi. Mana shu so'z turkumlari tegi hisoblanadi. So'z turkumlarini teglash (ingliz tilida bu part-of-speech tagging (POS tagging yoki PoS tagging yoxud POST), rus tilida частеречная разметка deyiladi) matnni avtomatik qayta ishslash bosqichi bo'lib, uning vazifasi matnda qo'llangan so'z (shakl) larning turkumi va grammatik xususiyatlarini aniqlash hisoblanadi. Shu vazifasi bilan POS-tagging matnni avtomatik tahlil qilishning dastlabki bosqichlaridan biri sanaladi.

Korpus lingvistikasida so'z turkumlarini teglash, grammatik kategoriyalarni teglash va so'zlarni toifalashda noaniqliklarni bartaraf etish uchun so'zni faqat uning lug'atdagi shakliga asoslanib emas, balki matn (jumla)dagi ifodasi bo'yicha uning turkumlik tegi va jumla (xatboshi, ibora)da boshqa so'zlar bilan birikish imkoniyatini hisobga olish muhim sanaladi. Gap bo'laklari teglarini identifikatsiyalash bir mucha qiyin jarayon [15]. Sababi o'zbek tilidagi jamiki so'zlarni universal holda 12 turkum doirasida teglash

imkoniyati yo'q. So'z uning jumla tarkibida reallashish holati va N-gramm [Abjalova, 2020:73-77] so'zlarning semantik valentligiga binoan polifunksional bo'lishi mumkin. Masalan: "Shifoxonaga bemorni keltirishdi" va "Shifoxonaga bemor odamni keltirishdi" jumlalarining 1-sida bemor so'zi turkumlik belgisi (kim? so'rog'iga javob berayotgan tushum kelishigidagi so'z)ga ko'ra ot turkumi, 2-jumlada esa (qanday? so'rog'iga javob beryapti) sifat turkumi vazifasidagi so'z hisoblanadi. O'zbek tili izohli lug'ati [5]da mavjud 11 000 o'zlashma so'zlardan 66 ta xuddi shunday polifunksional so'zlar aniqlandi [14].

Bir so'zning kontekstda ifodalanishiga ko'ra turli turkumga xoslanishi so'z turkumlari (ST) teglari uchun umumiylar parameterni belgilash imkonini bermaydi. Bu holat korpus uchun ST teglarini qo'lida bajarish imkonsizligini ko'rsatadi. Shuningdek, yangi kontekstlarning yuzaga kelishi va tilda neologizmlarning paydo bo'lishi teglashtirish jarayonining davomiyligini ko'rsatadi. Shu bois til korpusida ST teglashtirishda mashinali kodlashtirishga tayaniladi.

Rus tilidagi matnlarni qayta ishlashda so'z turkumlarini teglashtirish uchun Yandex qidiruv tizimida Mystem morfologik analizatori, TreeTagger'da rus tili utuliti [Abjalova, 2020:157], Python dasturlash tilida yaratilgan NLTK dasturiy kutubxona mavjud [19].

So'z turkumlarini teglash tarixi

PoS-tagging bo'yicha tadqiqotlar korpus tilshunosligi bilan chambarchas bog'liq. Matnni kompyuterda tahlil qilish uchun ingliz tilining birinchi yirik korpusi 1960-yillarning o'rtalarida Genri Kucher va V.Nelson Frensis tomonidan Braun Universitetida ishlab chiqilgan. Shu bois mazkur til korpusi "Braun korpusi" nomiga ega bo'lgan.

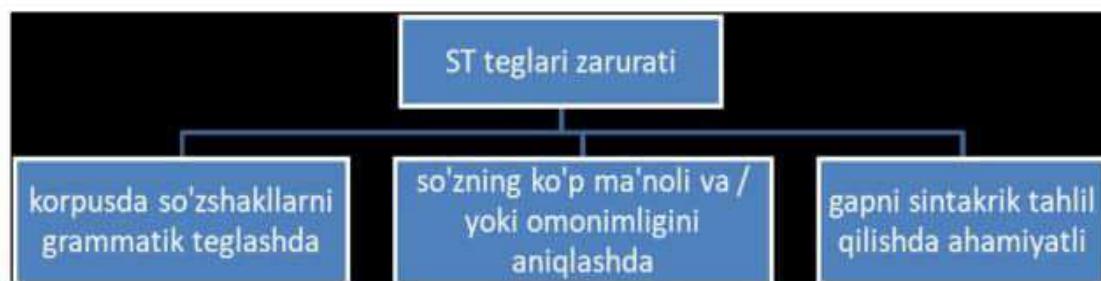
Brown korpusida so'z turkumlarini teglash uchun ko'p yillar davomida inson tomonidan so'zlar va ularning turkumlari ro'yxat qilingan. Qoidalarga asoslangan dastlabki harakatlar Green va Rubin dasturi yordamida qo'lida tuzilgan yirik ro'yxat asosida amalgalashdi. Bunda, asosan, lingvistik birliklarning ketma-ket doimiy joylashuvi e'tiborga olingan. Masalan, artikldan keyin ot turkumi (noun) keladi, fe'l (verb) turkumi emas. Bunday qat'iy qoidalarga asoslangan dastur 70% to'g'ri ishladi. Uning natijalari bir necha bor qo'lida tekshirildi va tuzatildi, keyinchalik foydalanuvchilar tomonidan ham tuzatishlarni yuborish imkoniyati yaratildi, natijada 70-yillarning oxiriga kelib teglashtirish (yoxud markirovka) deyarli mukammal bo'ldi [20].

Ushbu korpusdan son-sanoqsiz so'zlar chastotasi va ularning turkumlarini o'rghanish uchun foydalanilgan va boshqa ko'plab tillarda shunga o'xhash teglarni shakllantirish hamda rivojlantirishga sababchi bo'lgan. Yaxshi teglangan ta'limiylar korpuslar til modelini sinovdan o'tkazish va takomillashtirish uchun qimmatli manbadir. Matnlar korpusi tilshunosga grammatik qoidalarni ishlab chiqishida e'tibordan chetda qolgan lingvistik va nutqiy vaziyatlarni ko'rsatib (yoxud eslatib) turadigan tabiiy til manbasidir.

Bir muncha vaqt so'z turkumlarini teglash tabiiy tilni qayta ishslash (NLP)ning ajralmas qismi deb hisoblangan, sababi ba'zi bir holatlar mavjudki, so'zning turkumini uning (ayniqsa, polifunktional va ko'p ma'noli so'zlarning) semantikasini, hattoki kontekst pragmatikasini tahlil qilmasdan aniqlab bo'lmaydi. Kompyuter dasturlarida esa ularning mukammalligini ta'minlovchi semantik va pragmatik tahlil bosqichlarini yaratish anchayin murakkab jarayon hisoblanadi.

So'z turkumlarini teglash zarurati

ST teglashtirish usullarini ko'rib chiqishdan oldin, avvalo, STni teglash nima uchun kerak va ulardan qayerda foydalanilishiga to'xtalamiz (2-chizma).



2-chizma.

Eng muhimi, ST teglari tabiiy tilni qayta ishslash (Natural Language Processing / NLP) uchun eng birlamchi zaruriy lingvistik element hisoblanadi, shu bois STni teglash NLPda turli xil muammolarni soddalashtirish uchun dastlabki shart sifatida amalga oshiriladi.

Tilning fonetik, leksik, morfologik, sintaktik va semantik sathlarini o'zida qamragan universal lingvistik axborot tizimi (korpus)da aynan morfotahlilni amalga oshirish uchun ham so'z turkumlarini teglash zarur hisoblanadi. Shunda istalgan so'z (shakl) ga o'quvchi uchun to'g'ri tahlil natijasi til korpusida taqdim etish imkoniyati bo'ladi. Til korpusi mavjud bo'lмаган holda ko'pgina

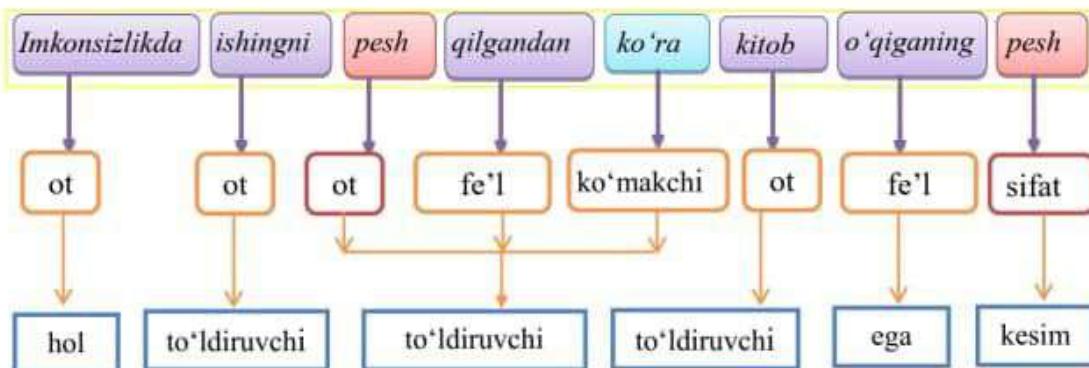
tillarda so'zlarning turlanish va tuslanish jarayonlarida lingvistik ta'minotga kiritilgan morfologik lug'atlarga murojaat qilinadi. [Abjalova, 2020:38-39, 155].

O'zbek tilida 50 000 dan ortiq leksemalar mavjud bo'lib, korpus va lingvistik kompyuter dasturlari bazasida har bir leksemaning turkumi aniqlab berilishi o'ta muhim masala hisoblanadi. Shunday so'zlar mavjudki, turkumlik belgisini o'zida namoyon qilmaydi yoxud gap tarkibida kontekstual ma'nosi o'quvchini chalg'itadi. Masalan, "... test sinovlaridan o'tkazish yuzasidan shaxsan javobgarligi belgilab qo'yilsin" (<https://lex.uz/acts/-4276890>), "Shaxsan o'zim keldim", "Shaxsan bajardim", "Bular hammasi lotinchaga yoki lotinchaga yaqin so'zlar. Men, shaxsan, shunday deb bilaman". (A. Qahhor, Adabiyot muallimi) jumlalaridagi shaxsan yasama so'zining turkumini aniqlash mushkul. Ba'zi o'rirlarda o'zlik olmoshi o'rnida qo'llanilayotgan leksema (olmosh), ba'zi hollarda ravish leksema tarzida o'zini namoyon etadi. Bu holatda so'zning turkumini aniqlashda turkumlarning kategorial xususiyatlariga murojaat etiladi. Ular 4 ta [22]: semantik, sintaktik, morfologik va so'z yasalishi xususiyatlaridir.

Ma'lumki, o'zbek tilida 12 so'z turkumi (mustaqil so'z turkumlari: ot, fe'l, sifat, ravish, son, olmosh; yordamchi so'z turkumlari: bog'lovchi, ko'makchi, yuklama; alohida olingan so'zlar turkumi: modal, taqlid, undov)ga so'z yasovchi qo'shimchalarining qo'shilishi natijasida 4 so'z turkumi: ot, fe'l, sifat, ravish yasaladi. Aniqlangan yasovchi qo'shimchalar (337 ta: ot yasovchi qo'shimcha 114 ta, fe'l yasovchi 58 ta, sifat yasovchi 117 ta, ravish yasovchi qo'shimcha 48 ta) [Abjalova, 2020:122-123] sirasida -an ravish yasovchi affiks hisoblanadi. Ushbu parametrdan kelib chiqib xulosalash mumkinki, ot turkumiga mansub "shaxs" so'ziga -an yasovchi qo'shimchasi birikishi natijasida yasama ravish hosil qilingan: shaxs (Ot) □ {-an} => shaxsan.

Umuman olganda, so'z o'ta murakkab hodisa sifatida talqin qilinib, ayni vaqtida ham til birligi, ham nutq birligi bo'lishi ta'kidlanadi. Til birligi bilan nutq birligining teng kelib qolishi holati, asosan, o'zgarmaydigan turkumlarga kuzatiladi. Bizga ma'lum bo'lgan polifunktional, ko'p ma'noli va omonim so'zlar tabiat esa jiddiy tadqiqot va amaliy kuzatuv jarayonlarini talab etadi.

Uzoq davrlar mobaynida tilshunoslikda tilning eng katta birligi yoki butunligi gap deb qaraldi. Hatto gap til birligi emas, balki nutq birligi degan qarash ham keng yoyilgan edi. So'nggi davrlarda gap, aniqrog'i, uning qolipini til birligi sifatida baholash ommalashdi.



3-chizma.

"Imkonsizlikda ishingni pesh qilgandan ko'ra kitob o'qiganing pesh" gapida (3-chizma) so'zlarning turkumlarga teglanishi natijasida gap bo'laklarining aniqlanishi va "pesh" omonim so'zining ketma-ket kelgan so'zlar (pesh qilmoq (Ot + F); o'qiganing pesh (F + Sif) va joylashuv o'rniga ko'ra (gap so'nggida ot-kesim => Sifat) turkumi aniqlanishini ko'rish mumkin.

So'z turkumi har qanday so'z birikmasi (3-chizmada "pesh qilgandan ko'ra" – vositali to'ldiruvchi uch turkumdag'i so'zlar birikuvidan iborat) va gap strukturasida turli sintaktik funksiyalarni bajarishi mumkin. Har bir so'z turkumida asosiy, birlamchi sintaktik funksiya mavjud bo'ladi. Birlamchi sintaktik funksiya so'z turkumining leksik ma'nosidan kelib chiqadi va bu ma'noning o'ziga xos transpozitsiyasi sifatida gavdalanadi [Ganiyeva, 2019:277].

ST teglash uchun lingvistik bazada so'zlar va ularning turkumlari ko'rsatilgan ro'yxatning kiritilishi kifoya emas. Yuqoridagi so'z turkumini aniqlash holatidagi kabi izchillikning yo'qolishi yoxud bir shaklga ega polifunktional, omonim yoki ko'p manoli so'zlarning gapda ifodalagan turkumini topish hatto mutaxassis tilshunosni ham fikr yuritishga, izlanishga undaydi. Shuningdek, o'zbek tilidagi ko'pgina so'zlar muayyan turkumga mansubligi aniqlanmagan. Har bir tabiiy tilda mavjud bunday muammolar e'tiborga olinib STni teglashda bir necha usullarga tayaniladi.

So'z turkumlarini teglash usullari

Aksariyat hollarda so'z turkumlarini teglashda quyidagi usul (metod, algoritm)larga asoslaniladi [16, 18, 19]:

- qoidalarga asoslangan usul
- stoxastik (yoxud statistik) usul.

Qoidalarga asoslangan PoSteglar Engazaliy teglash usullaridan biri bu qoidalarga asoslangan POS-tegash sanaladi. Bunda, asosan, Brill usuli qo'l keladi. [Bril, 1992]. Qoidalarga asoslangan teggerlar

har bir so'zni teglash uchun lug'at yoxud leksikadan foydalanadilar. Agar so'zda (polifunksional, omonim, ko'p ma'noli so'zlar nazarda tutilmoxda) bir nechta teglar bo'lsa, unda qoidalarga asoslangan teggerlar gapdag'i so'zning turkumlik tegini to'g'ri aniqlash uchun qo'lida yozilgan qoidalardan foydalanadi. Yanada aniq teglarni berishda so'zning lingvistik xususiyatlarini undan oldingi va keyingi so'zlarni tahlil qilish orqali qoidalarga asoslanib belgilash orqali ham amalga oshirilishi mumkin. Masalan, qaratqich kelishigidagi ismga mansub so'zdan so'ng kelgan lingvistik birlik egalik qo'shimchasini olgan ot turkumidagi so'z hisoblanadi. Masalan, mening kitobim, akamning uyi, Salimaning ko'ylagi kabi. Demak, bunday holda so'zning ot turkumligi o'zining oldida kelayotgan qaratqich kelishigidagi ism orqali belgilanadi. Ingliz tilidan misolga e'tibor qaratamiz: oldingi so'z artikl bo'lsa, u holda undan keyin kelayotgan so'z ot turkumiga oid leksik birlik sanaladi. Masalan, an egg, a book, the train, the windows kabi.

PoS teglaridagi bunday holatlar qoidalar shaklida kodlanadi.

Ushbu qoidalar quyidagilarni tashkil etishi mumkin:

1. Lingvistik me'yorlarga asoslangan qoidalar. Tilning orfografik qoidalariga asoslangan yuzlab qoidalar umumiyligi, xususiy va istisnoli qoidalar bazasi tarzida shakllantiriladi [Abjalova, 2020].

2. Kontekstli shablon qoidalari, ya'ni gap tarkibidagi ko'chma ma'noga ega so'zning muntazam ravishda konnotativ ma'noda qo'llanishi dastur xotirasida saqlanadi, natijada keyingi jarayonlarda o'sha konnotativ so'z bilan bog'liq noaniqliklar bartaraf etiladi.

Qoidalarga asoslangan metodga binoan so'z turkumlarini teglash ikki bosqichda amalga oshiriladi:

Birinchi bosqichda PoS-tegger (izohli, imlo, morfologik yoxud orfografik) lug'at(lar)ga tayanadi. Ulug'at yordamida har bir so'zning turkum(lar)ini aniqlab chiqadi.

Ikkinci bosqichda polifunksional yoki omonim so'zlarning turkumlari qo'lida yoziladi va bunday so'zlarni jumla tarkibidagi vazifasini aniqlash qoidalaringning katta ro'yxati ishlab chiqiladi.

Qoidalarni avtomatik generatsiya qilish metodining yaqqol namunasi – amerikalik lingvist Erik Brill metodidir [Brill, 1995]. Ish uslubi quyidagicha:

1. Boshlash: Har bir so'z o'sha so'zning tez-tez qo'llaniladigan tegi bilan bog'lanishi lozim. Noma'lum so'zlar ot so'z turkumi sifatida qabul qilinadi. Mazkur bosqichdan nafaqat o'rganish jarayoni boshlanadi, balki omonimlarni bartaraf etish metodi [2] ham

harakatga keladi.

2. Tez-tez uchraydigan xatolik uchun o'zgarish (qayta ishlash) qoidasini yaratish kerak.

3. Istalgan minimal xatoga erishguncha ikkinchi bosqichni takrorlash lozim.

O'tkazish (qayta ishlash) qoidalarida "eski teg, yangi teg, shart" to'plamlari o'z ifodasini topadi va qoidada belgilangan shart bajarilganda eski teg yangisi bilan almashtiriladi. Ushbu metodning kamchiligi qoidalar sonining ko'payishi bilan aniqlik darajasining pasayishida kuzatiladi [Brill, 1992], bu Paretoning prinsipiga mos keladi: 80% harakat 20% natijani ta'minlaydi. Shu bilan birga, prinsip aksincha jarayonda ham ishlaydi: boshlash bosqichining faqat bitta qadamini bajarish natijasida omonimlikni bartaraf etishda yuqori aniqlikka erishish mumkin. SinTagRus korpusida o'tkazilgan test natijalaridan ma'lum bo'ldiki, ushbu metod har bir so'zning gapdag'i o'rnini 97,4%, morfologik xususiyatlarning to'liq majmuini 87,6% aniqlik bilan topish imkonini beradi [Abjalova, 2020:73].

Qoidalarga asoslangan ST teglari xususiyatlari

Qoidalarga asoslangan PoS teglari quyidagi xususiyatlarga ega:

- Ushbu tegerlar bilimga asoslanadi.

- Qoidalari qo'lida yaratiladi.

- Axborotlar qoidalari shaklida kodlanlanadi.

- Qoidalari cheklangan bo'ladi. Raqamli texnologiya uchun cheksizlik mavhumlikni ifodalaydi, "va shu kabilar", "..." (ko'p nuqta), "va hokazo" kabi birikma va belgilar ro'yxatning davomiyligini emas, balki noaniqligini bildiradi. Shu bois kompyuter lingvistikasida bu kabi noaniqliklarga yo'l qo'yilmaydi, balki har bir lingvistik birlikning tabiatini, xususiyatlari dasturiy ta'minot bazasida aniq ko'rsatilishi talab etiladi.

- Tilni modellashtirishda teglashtirish qoidalariiga asoslaniladi.

Stoxastik teglash usuli. Mazkur usul chastota yoki ehtimollik (statistika)ka asoslanadi. Shu bois ayrim manbalarda statistik yoxud ehtimolikka asoslangan usul tarzida tushuntiriladi. [16, 19, 20, 21]. Ayon bo'lganidek, oddiy stoxastik teglashda ST teglari uchun quyidagi metodlardan foydalaniladi:

1. Chastotani yondashuv. Ushbu yondashuvda stoxastik tegerlar so'zning matnda ma'lum bir teg bilan uchrashi ehtimoli asosida grammatik noaniqliklarni bartaraf etadi. Shuni ham aytish

mumkinki, o'rganilayotgan to'plam (matn qismi)da muayyan so'z bilan tez-tez qo'llaniladigan teg o'sha so'zning noaniqligiga ma'lumot berishga yordamchi tegdir. Masalan, qo'llanilish darajasiga binoan tushun kelishigidagi so'zdan so'ng kelgan lingvistik birlik fe'l turkumiga mansub hisoblanadi: kitobni o'qimoq, ismni yozmoq, mamlakatni aylanib chiqmoq => {Wni Ə V} kabi. Teglash jarayonidagi bunday yondashuvning asosiy muammosi, u tabiiy tilda birikuvchanligi bo'limgan teglar ketma-ketligini keltirib chiqarishi mumkin. Masalan, "Do'stimga kitobni sovg'a qilish uchun sotib oldim" misolida sovg'a so'zi o'ng tomondan "qilish uchun" birikmasi bilan birikuvchanlikka ega, ammo chapdag'i so'z bilan (kitobni) na grammatik, na semantik jihatdan birika oladi. Bunday hollarda teglashtirishda birikuvchanlikka ega bo'limgan so'zlar nomutanosibligiga asoslanish natijasida morfoanaliz jarayonida noto'g'ri ma'lumot yuzaga keladi.

2. Teglarning ketma-ketligi ehtimoli yoxud n-gramma usuli. Stoxastik usulning mazkur yondashuvi tegger berilgan teglar ketma-ketligining qo'llanilish ehtimolini hisoblaydi. Ketma-ketlik o'lchovi, ya'ni n (bigram – ikki element ketma-ketligi, trigram – uch ketma-ket teg, 4 gram – to'rt teg ketma-ketligi) teglarga asoslangani uchun bu yondashuv N-gramma usuli ham deyiladi. N-gramma – matnlarga avtomatik ishlov berishda keng qo'llaniladigan matematik hisob vositasidir. O'zbek kompyuter lingvistikasida S.Rizayev harf birikmalarini bigramm, trigramm terminlari bilan ifodalagan [Rizayev, 2006:18]

Yashirin Markov modeli stoxastik usulda faol qo'llaniladi. 1960-yillarda Baum L.E. va uning hamkasblari tomonidan ishlab chiqilgan [Baum, L. E., Sell, G. R. 1968: 211-227] mazkur usul statistik jarayonda yuzaga keladigan barcha variantlar ehtimolligini hisobga olishga yordam beradi. Masalan, ma'lum bir matnda ot turkumiga oid so'zlar bog'lovchiga nisbatan tez-tez va ko'p uchrasa unda ayni kontekstda mavjud omonim katta ehtimollik bilan bog'lovchi emas, ot turkumiga oid so'z bo'ladi, keyingi ehtimollikda bog'lovchi sifatida hisobga olinadi. Kontekstni tavsiflash uchun N-grammadan foydalilanadi. N-gramma – so'zlar yoki teglar kabi N-identifikator elementlarning ketma-ketligini ifodalaydi.

Yashirin Markov modellari termodinamika, statistik mexanika, fizika, kimyo, iqtisodiyot, moliya, signallarni qayta ishlash, axborot nazariyasi, nutqni qayta ishlash, husnixat, imo-ishoralarni tanib olish, [Thad Starner, Alex Pentland. 1995.] so'z turkumlarini teglash va bioinformatikada keng qo'llaniladigan statistik model

hisoblanadi [Li, N. 2003], [Ernst, Jason. 2012].

So'z turkumlarini stoxastik teglash usuli xususiyatlari

Stoxastik PoS-tegerlar quyidagi xususiyatlarga ega:

- Mazkur teglashtirish teglarning ketma-ket qo'llanish darajasi bo'yicha ehtimolligiga asoslanadi.
- Ta'lim korpusi talab qilinadi.
- Korpusda mavjud bo'limgan so'zlar uchun hech qanday ehtimollik bo'lmaydi.
- Ta'lim korpusidan tashqari boshqa tur til korpusidan ham foydalanish mumkin.
- Eng oddiy ST teglash usuli, chunki bu usulda til korpusidagi faol tarzda ketma-ket qo'llangan teglarni tanlab oladi.

Amaliy natija

Bir necha yillar davomida olib borilgan tadqiqotlar va 2020-2021-yillardagi amaliy sa'y-harakatlar natijasida Toshkent davlat o'zbek tili va adabiyoti universiteti Axborot texnologiyalari hamda Amaliy tilshunoslik va lingvodidaktika kafedralari hamkorligida AM-FZ-201908172 raqamli "O'zbek tili ta'limiy korpusini yaratish" mavzusidagi amaliy loyiha doirasida O'ZBEK TILI MILLIY va TA'LIMIY KORPUSLARI yaratildi. Bugungi kunda mazkur korpusda mosfoanalizator (avtomatik morfologik tahlil), sinonimizator (qidiruvga yozilgan so'zga uning ma'nodoshlarini taqdim etish dasturi) [4], shuningdek, so'zni bo'g'lnlarga ajratish, izoh (lar)ini taqdim etish va antonimlarini ko'rsatish imkoniyatlari yaratilgan [3].

The screenshot shows a web browser window with the URL <http://uschoolcorpus.uz/uz/dictionary/?q=balandroqdanmikan&li=true&tl=false&si=true&sd=false&al=tr>. The page title is 'O'zbek tili milliy korpusi'. A search bar contains the word 'balandroqdanmikan'. To its right is a blue button labeled 'Izlash'. Below the search bar, the word is defined with its parts of speech: 'So'z tarkibi: [baland] - roq (Sifatga qo'shiluvchi lug'aviy shakl yasovchi ∈ Lug'viy shakl yasovchi) - dan (Kelishik qo'shimchalarli ∈ Sintaktik shakl yasovchi) - mi (Lug'viy shakl yasovchi) - kan (Fe'lga qo'shiluvchi lug'aviy shakl yasovchi ∈ Lug'viy shakl yasovchi)'. Below this, it lists 'So'z bo'g'inlari: ba-land-roq-dan-mi-kan'. Underneath, it defines 'Izoh(lar)i: **baland** [ba-land]'. At the bottom left, there is a note: '1 Pastdan yuqoriga tomon o'lchami uzun; qaddi, bo'yli'. On the right side of the search results, there is a sidebar with checkboxes for parts of speech: Izoh(lar)i (checked), Omonim(lar)i (unchecked), Sinonim(lar)i (checked), Antonim(lar)i (checked), and Paronimi (unchecked). A yellow arrow icon is located in the top right corner of the search results area.

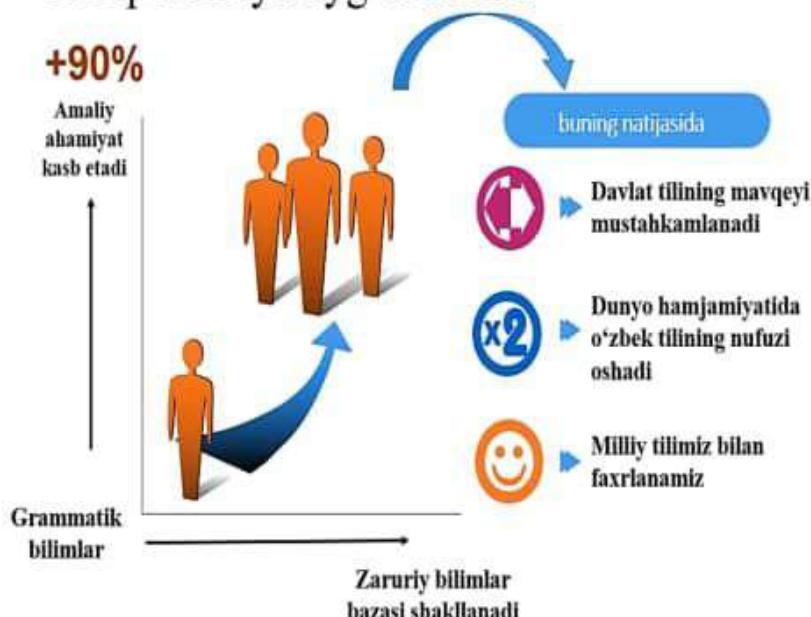
5-rasm. O'zbek tili Milliy korpusida "balandroqdanmikan" so'zshaklining morfologik tahlil ("So'z tarkibi" qismida) natijasi

Xulosa

Xulosa tarzida aytish joizki, tabiiy tilni qayta ishlash (NLP) da so'z turkumlarini teglash algoritmlarni yaratish avtomatik tahlil, morfoanaliz va tarjimon dasturlari uchun birlamchi shart amalga oshirilgan sanaladi, natijada matnlarning grammatik jihatdan sifatli tahlil qilinishiga erishiladi. Bugungi kunda neyrotarmoqqa asoslangan sun'iy intellekt tizimida qoidalarga asoslangan va stoxastik usullardan gibrildar foydalanilmoqda.

Lingvistik bilimlar kompyuter dasturlari va til korpuslari bazasi uchun eng zarur ma'lumot manbai hisoblanadi. Lingvistik protsessorda lisoniy ma'lumotlar bazasini shakllantirishda kundalik hayotda til bilimlaridan foydalanish ko'nikmalariga asoslanilsa va bunday vaziyatlar adabiy til me'yorlariga aylantirilsa kompyuter dasturlarining tahlil imkoniyati mutaxassis darajasida mukammallikka yetadi. Shu bois lingvistik kompetensiya va nutqiy kompetensiya doimiy ravishda bir-birini taqozo etadi. Aynan so'z (asosan, polifunksional, ko'p ma'noli, omonim so'zlar)ning turkumini belgilashda ham maqola avvalida "uzoq" so'zi misolidagi kabi so'zning pragmatik va kontekstual ma'nolari hamda qo'shimcha semalariga asoslanilsa, raqamlı texnologiya dasturlari va tizimlarining amaliy ahamiyati yanada oshadi.

Lingvistik kompetensiya va nutqiy kompetensiya uyg‘unlashsa



Umuman olganda, bugungi kunda lingvistik bilimlar tildan amalda foydalanish imkoniyatiga asoslanib mukammallashtirilsa va shunday nazariy manbalarga tayanilib, kompyuter dasturlari va tizimlari uchun formal o‘zbek tili yaratilsa, kelajakda barcha turdag'i (o‘zbek tarjimon dasturi, nutqni tanish, o‘zbek tili morfoanalizatori, kompyuter muloqoti kabi) dastur hamda elektron tizimlarining yuzaga kelishiga zamin yaratiladi.

Adabiyotlar

Abjalova M. Tahrir va tahlil dasturlarining lingvistik modullari. [Matn] : monografiya / M.A. Abjalova. – Toshkent: Nodirabegim, 2020. – 176 b.

Abjalova M., Yuldashev A. Methods for Determining Homonyms in Linguistic Systems // ACADEMICIA: An International Multidisciplinary Research Journal. Vol. 11, Issue 2, February 2021. Impact Factor: SJIF 2021 = 7.492 (<https://saarj.com>). ISSN: 2249-7137. DOI: 10.5958/2249-7137.2021.00522.X

Abjalova M. O‘zbek tili Milliy korpusida so‘zshakllarni leksikografik baza asosida qidiruv imkoniyatlari // Kompyuter lingvistikasi: muammo, yechim, istiqbollar. Respublika I Ilmiy-texnik konferensiya to‘plami. – Toshkent: ToshDO’TAU. – B. 12-17.

Abjalova M. O‘zbek tili milliy korpusida sinonimayzer yoxud sinonimizatorini yaratish masalasi // O‘zbek Milliy va ta’limiy korpuslarining yaratishning nazariy hamda amaliy masalalari. Xalqaro ilmiy-amaliy konferensiya to‘plami. – Toshkent: ToshDO’TAU. – B. 38-40.

O‘zbek tilining izohli lug‘ati: 80 000 dan ortiq so‘z va so‘z birikmasi (A. Madvaliyev

