

Ruslanova Zilola Yuldashевна

**O'zbek tili birliklarini tokenlash,
stentlash, himmatlashning
lingvistik asoslari**

Monografiya

2019 yil 10 oy

O'ZBEKISTON RESPUBLIKASI
OLIIY TA'LIM, FAN VA INNOVATSIYA VAZIRLIGI

ALISHER NAVOIY NOMIDAGI TOSHKENT DAVLAT
O'ZBEK TILI VA ADABIYOTI UNIVERSITETI

XUSAINOVA ZILOLA YULDASHEVNA

O'ZBEK TILI BIRLIKLARINI
TOKENLASH, STEMLASH,
LEMMALASHNING LINGVIK
ASOSLARI

MONOGRAFIYA

Toshkent – 2025

UO'K: 811.512.133'32

KBK 81.20'zb

X 93

Xusainova Z.Y.

O'zbek tili birliklarini tokenlash, stemlash, lemmalashning lingvistik asoslari. Monografiya. – Toshkent: Noble Print, 2025. – 148 b.

Ushbu monografiya doktorantlar, magistrantlar, mustaqil izlanuvchilar, bakalavriat bosqichi talabalari uchun mo'ljallangan.

Monografiyadan o'zbek tili birliklarini tokenlash, stemlash va lemmalash jarayonlarini lingvistik hamda dasturiy asosda o'rganish natijalari tilshunoslikning nazariy hamda amaliy yo'nalishlarida qo'llaniladigan samarali vosita sifatida foydalanish mumkin. Shuningdek, ish natijalaridan kompyuter lingvistikasi, tabiiy tilni qayta ishlashga oid o'quv-metodik qo'llanmalar, darsliklar yaratishda, o'zbek tilidagi leksik birliklar, korpus lingvistikasi, avtomatik morfologik tahlil bo'yicha maxsus kurs va seminarlar o'tishda, morfologik va tokenlash asosidagi elektron lug'atlarni boyitishda foydalanish mumkin.

Mas'ul muharrir:

B.B. Elov

Taqrizchilar:

f.f.d., prof. S. Normamatov

t.f.f.d., dotsent R. Alayev

Monografiya Alisher Navoiy nomidagi Toshkent davlat o'zbek tili va adabiyoti universiteti Ilmiy-texnikaviy kengashi majlisida muhokama qilinib nashrga tavsiya etilgan (2025-yil 17-dekabrda 6-sonli bayonnom).

© Xusainova Z.Y.
Noble Print, 2025

ISBN 978-9910-8466-7-0

KIRISH

Jahon kompyuter lingvistikasi amaliyotida tabiiy tilga ishlov berish usullaridan keng foydalanilmoqda. Tabiiy tilga ishlov berish (Natural language processing – NLP) loyihalarida doimiy bajariladigan vazifalar mavjud. Ular fundamental xarakterga ega bo'lganligi sababli keng ko'lamda o'rganilgan. Ushbu vazifalarni yaxshi tushunish NLPning turli ilovalarini yaratishga imkon beradi. Tilni modellashtirish, matnni tasniflash, axborot olish, ma'lumot izlash, suhbat agenti, matnni umumlashtirish, savol-javob tizimlari, mashina tarjimai, tematik modellashtirish NLPning asosiy sohalaridir. Tabiiy tilni qayta ishlash – sun'iy intellekt sohasining mashinalarni inson tilini tushunish va qayta ishlashga qaratilgan yo'nalishi. Tabiiy tilni qayta ishlash mashina uchun oson ish emas, chunki mashina matn bilan emas, raqamlar bilan ishlaydi.

Dunyo tilshunosligida XX asr oxirida avtomatik tarjima sifatini yaxshilash, tilni lingvistik modellashtirish, muayyan tillar doirasida so'zlarni lemmalash nazariyasi, algoritmini yaratish kabi masalalar kun tartibiga qo'yildi. Natijada axborot-qidiruv tizimida faol qo'llanuvchi tokenizator, stemmer, lemmatizator singari ilovalar ishlab chiqildi. Bundan tashqari, til korpuslarini yaratish, ularni lingvistik annotatsiyalash, matnning avtomatik qayta ishlaydigan dasturiy vositalar – morfoanalizator, stemmer, lemmatizator, parser, orfokorrektorlarni ishlab chiqish kompyuter lingvistikasining ilmiy-nazariy muammolariga aylandi.

O'zbek kompyuter lingvistikasi sohasida til korpusi, nutq korpusi, avtomatik tarjima, sun'iy intellekt, o'zbek tilini tushunish va qayta ishlash borasida ilmiy izlanishlarga e'tibor qaratilmoqda. Lekin ushbu ilmiy tahlil berishning dastlabki bosqichlarini amalga oshiruvchi ilovalar tokenizator, stemmer, lemmatizatorlarni ishlab chiqish masalasi ilmiy jihatdan o'rganilmagan. Zero, "...davlat tilining sofligini ta'minlash uchun tabiiy tilni qayta ishlash va aholining nutq madaniyatini oshirish; davlat tilining kommunikativ asho'rat texnologiyalari va kommunikatsiyalariga faol qatnashib, ularni rivojlantirish" (2025-yil 17-dekabrda 6-sonli bayonnom).

Ushbu monografiya Alisher Navoiy nomidagi Toshkent davlat o'zbek tili va adabiyoti universiteti Ilmiy-texnikaviy kengashi majlisida muhokama qilinib nashrga tavsiya etilgan (2025-yil 17-dekabrda 6-sonli bayonnom).

© Xusainova Z.Y.
Noble Print, 2025

ISBN 978-9910-8466-7-0

Statistik usullarga asoslangan stemmerlar

n-grammi stemmeri		Kamchiliklari
Afzalliklari	Afzalliklari	Afzalliklari
1) n-gramm va satrlarni taqqoslashga asoslangan;	o'zaro	1) tahlil juda ko'p vaqt talab qiladi;
2) tabiiy tilga bog'liq emas.		2) n-grammlarni saqlash uchun yetarlicha katta hajmdagi xotira talab qilinadi;
		3) amalga qo'llash murakkab.
	HMM stemmeri	
Afzalliklari	Afzalliklari	Kamchiliklari
1) HMM metodiga asoslangan;		1) tatbiq qilish murakkab;
2) tabiiy tilga bog'liq emas.		2) over stemming yuzaga kelishi mumkin.
	YASS stemmeri	
Afzalliklari	Afzalliklari	Kamchiliklari
1) klasterizatsiya va masofani aniqlashda iyerarxik yondashuvdan foydalaniladi;	1) klasterlarni hosil qilishdagi chegara (shart)larni aniqlash murakkab;	
2) korpusga asoslangan;	2) yetarli tezlikka ega texnika (kompyuter) talab qilinadi;	
3) tabiiy tilga bog'liq emas.	3) murakkab hisob-kitoblar talab qilinadi.	

7-ilova

Fleksiya va so'z yasalishi usullariga asoslangan stemmerlar

Krovets stemmeri		Kamchiliklari
Afzalliklari	Afzalliklari	Afzalliklari
1) tushunarli (sodda);		1) katta hajmdagi hujjatlar uchun samarali natija qaytarmaydi;
2) boshqa stemmerlar uchun boshlang'ich stemmer sifatida foydalanish tavsiya qilinadi.	2) lug'atdan tashqari so'zlarni ishlamaydi;	
	3) aniqlik ko'rsatkichi past;	
	4) lug'at avvaldan ishlab chiqilishi lozim.	
	Xerox stemmeri	
Afzalliklari	Afzalliklari	Kamchiliklari
1) katta hajmdagi hujjatlarni samarali qayta ishlashi mumkin;	1) lug'atdan tashqari so'zlarni ishlamaydi;	
2) prefikslarni o'chirish imkoniyati mavjud;	2) faqat ingliz tiliga moslashtirilgan;	
3) stemlash natijasida har doim ma'noga ega so'z hosil qilinadi.	3) tabiiy tilga bog'liq.	

MUNDARIJA

KIRISH.....	
I BOB. TOKENLASH, STEMLASH VA LEMMALASHNING NAZARIY ASOSLARI.....	3
§ 1.1. Jahon va o'zbek tilshunosligida tokenlash jarayonining umumiy tavsifi.....	6
§ 1.2. Stemlash jarayonining umumiy tavsifi.....	6
§ 1.3. Lemmalash jarayoni: umumiy tavsif va tahlil.....	12
II BOB. O'ZBEK TILI LEKSIK BIRLIKLARINI STEMLASH VA LEMMALASHNING LINGVISTIK ASOSLARI.....	33
§ 2.1. O'zbek tili so'zshakllarini stemlash: muammo va yechimlar.....	43
§ 2.2. O'zbek tilida turli tuzilishli so'zlarni lemmalash usullari.....	43
§ 2.3. Til korpusi qidiruv tizimini optimallashtirishda lemmalashning ahamiyati.....	64
III BOB. O'ZBEK TILI LEKSIK BIRLIKLARINI TOKENLASH, STEMLASH VA LEMMALASHNING DASTURIY ASOSLARI.....	71
§ 3.1. O'zbek tili birliklarini BoW va BPE algoritmlari asosida tokenlash.....	83
§ 3.2. Affikslarni ajratishga asoslangan UzbStemming algoritmini ishlab chiqish.....	107
§ 3.3. O'zbek tilidagi so'zlarni lemmalash muammosi va usullari.....	112
XULOSA.....	122
FOYDALANILGAN ADABIYOTLAR RO'YXATI.....	125
ILOVALAR.....	141

Xusainova Z.Y.

O'zbek tili birliklarini tokenlash, stemlash, lemmalashning lingvistik asoslari

MONOGRAFIYA



9527

Bosishga ruxsat etildi: 19.12.2025-yil.
Bichimi 60x84 $\frac{1}{16}$, "Times New Roman"
garniturada raqamli bosma usulida bosildi.
Shartli bosma tabog'i: 9,5. Adadi: 100.

"Noble Print" MChJ bosmaxonasida chop etildi.
100194, Toshkent shahri, Yunusobod-II, 62-uy.