

MUHAMMAD AL-XORAZMIY
AVLODLARI
ILMIY-AMALIY VA AXBOROT-
TAHLILIY JURNAL

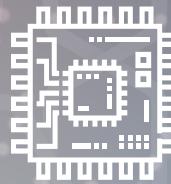
DESCENDANTS OF MUHAMMAD
AL-KHWARIZMI
SCIENTIFIC-PRACTICAL AND
INFORMATION-ANALYTICAL JOURNAL



1(23)/2023

ISSN-2181-9211

MUHAMMAD AL-XORAZMIY NOMIDAGI
TOSHKENT AXBOROT TEKNOLOGIYALARI UNIVERSITETI



MUHAMMAD AL-XORAZMIY AVLODLARI

Ilmiy-amaliy va axborot-tahliliy jurnal 2017 yilda
ta'sis etilgan

1(23)/2023

Tahririyat kengashi a'zolari

Maxkamov B.SH.	– Muhammad al-Xorazmiy nomidagi Toshkent axborot texnologiyalari universiteti (TATU) rektori, Tahririyat kengashi raisi
Sultanov Dj.B..	– Tahririyat kengashi raisi o'rinnbosari
Tashev K.A.	– Tahrir kengashi raisi o'rinnbosari
Raximov B.N.	– t.f.d., prof. bosh muharrir
Nosirov X.X.	– PhD, dots. bosh muharrir o'rinnbosari
Muharrirlar:	
Kamilov M.M.	– t.f.d., prof., akademik.
Musayev M.M.	– t.f.d., prof.
Abduraxmonov K.P.	– f.-m.f.d., prof.
Jumanov J.X.	– t.f.d., prof.
Muxamediyeva D.T.	– t.f.d., prof.
Isayev R.I.	– t.f.n., prof.
Yusupov A.	– f.-m.f.d., prof.
Yakubova M.Z.	– t.f.d., prof. (Qozog'iston)
Xalikov A.A.	– t.f.d., prof. (TTYTM)
Nazarov A.M.	– t.f.d., prof. (TDTU)
Jmud V.A.	– professor (Rossiya)
Miroslav Skoric	– professor (Avstriya)
Dzhurakhalov.A	– professor (Belgiya)
Abrarov S.M.	– professor (Kanada)
Kyamaka K.	– professor (Avstriya)
Chedjou J.Ch.	– professor (Avstriya)
Davronbekov D.A.	– t.f.d., prof.
Anarova Sh.A.	– t.f.d., prof.
Pisetksiy Y.V.	– t.f.d., prof.
Nishonov A.X.	– t.f.d., dots.
Muminov B.B.	– t.f.d., prof.
Raximov N.O.	– t.f.d., dots.
Amirsaidov U.B.	– t.f.d., dots.
Kerimov K.F.	– t.f.d., dots
Ganiyev A.A.	– t.f.n., dots.
Gavrilov I.A.	– t.f.n., dots.
Gubenko V.A.	– t.f.n., dots.
Pulatov Sh.U.	– t.f.n., dots.
Muradova A.A.	– PhD, dots
Shaxobiddinov A.SH.	– PhD
Madaminov X.X.	– PhD, dots
Xudaybergenov T.A.	– PhD, dots
Ro'ziboyev O.B.	– PhD, dots
Yaxshibayev D.S.	– PhD, dots.
Mirsagdiyev O.A.	– PhD, dots.
Puziy A.N.	– PhD
Berdiev A.A.	– PhD, bosh muharrir yordamchisi
Arabboyev M.M.	– PhD, texnik muxarrir
Begmatov Sh.A.	– PhD, texnik muxarrir
Xudaybergenov J.D	– texnik muxarrir

MUNDARIJA

DASTURIY VA KOMPYUTER INJINIRING

TEXNOLOGIYALARINING ZAMONAVIY MUAMMOLARI

Botirov F.B. Axborot xavfsizligi incidenti: axborotni himoyalashga qaratilgan yondashuvlar	3
Siddiqov I.K., Fayzullayeva B.B. Simulation of continuous-discrete systems with multiple synchronous interruptions	7
Babadjanov E.S., To'liyev X.I., Kenjayev X.B. Sog'in sigirlarning sut mahsuldarlik tahlili va laktatsiya egrichizig'ini qurish usuli	11
Xudoqulov Z.T., Boyquziyev I.M., Allanov O., Murodov M.M. GOST R 34.12.2015 shifrlash standarti algoritmlarini kriptotahlii usullariga baholash natijalari	15
Нишинов А.Х., Беглербеков Р.Ж., Кудияров Б.С., Мухсинов Ш.Ш., Ментураев Ф.З. Номинал белгили тимсолларни таснифлашда информатив белгиларни танлаш ва кластерлаш алгоритми	19
Ташев К.А., Юлдашева Н.С. Шахсни идентификацияловчи биометрик тизимлар	23
Отахонова Б.И., Олимжонов О.О., Рахимов И.И. Матли маълумотларда учрайдиган орфографик хатоликларни бартараф этиш usullari	28
Rahimov M.F., To'rayeva M.Sh. Mashinani o'qitish usulidan foydalangan holda yurak kasalliklarini tasniflash	32
Xudaybergenov T.A., Hamrayeva S.I., Jumaniyazova M.K. SK6812 RGB LED asosida taqiladigan yorug'lik identifikatorli bilaguzukni IEEE802.15.7 8-CSK Symbol Point asosida xaritalashni loyihalashtirish	36
Иргашева Д.Я., Агзамова М.Ш. Анализ биометрических технологий аутентификации и современных систем защиты информации	40
Abdirazakov F.B. Nutq signallarga raqamli ishlov berish usullari tahlili	49

OPTIK ALOQA TIZIMLARI, TELEKOMMUNIKATSIIYA TARMOQLARI VA KOMMUTATSIIYA TIZIMLARINING RIVOJLANISH TAMOYILLARI

Исаев Р., Турсимуратов С.С. Об одном методе оценки показателей надежности волоконно-оптических линии связи	56
Рахимов Б.Н., Кенгесбаев С.К., Тураев Б.Э. Создание оптоэлектронного преобразователя фотоколориметра	62
Maxmudov S.O., Temirova D.X. "Aqli shahar" tizimi infrastrukturasini modelinini yaratish	66
Maxmudov I.A., Tillaboyev M., Saparbayev R.K. Multiservs tarmog'i resurs va xizmatlarini taqqid etish jarayonlarini intellektuallashtirish masalalari model va usuli	72
Маткубонов Д.М. Модель системы управления маршрутизацией с использованием нечетких множеств	76
Тураев Б.Э. Оптоэлектронные методы определения содержания веществ в жидких и газообразных средах	82

RAQAMLI TELEVIDENIYE VA RADIOESHITTIRISH, SIMSIZ TEXNOLOGIYALAR VA RADIOTEXNIKANI RIVOJLANTIRISH ISTIQBOLLARI

Иманкул М.Н., Давронбеков Д.А., Манбетова Ж.Д. Интегрированные системы связи для служб быстрого реагирования	86
---	----

Muassis:

*Muhammad al-Xorazmiy nomidagi
Toshkent axborot texnologiyalari
universiteti*

Manzil:

*100084, O'zbekiston, Toshkent sh., Amir
Temur ko'chasi, 108
Telefon: 71 238-64-38;
e-mail: alxorazmiy@tuit.uz
Jurnal sayti: <http://alxorazmiy.uz>*

Bosishga ruxsat etildi:

*Qog'oz bichimi 60x84 1/8
Bosma tabog'i 15,5. Adadi 100 nusxa
Buyurtma raqami №195 "Fan va
texnologiyalar Markazining
bosmaxonasi"da chop etildi
Toshkent shahri Olmazor ko'chasi, 171.
Jurnal O'zbekiston Matbuot va
axborot agentligida 2017 yil
22 iyunda 0921 raqami bilan ro'yxatdan
o'tgan.
Jurnal yilda 4 marotaba
(har chorakda) chop etiladi.*

Автоматизация процесса определения параметров реле железнодорожной автоматики и телемеханики Mukhammedova D.B., Gavrilov I.A., Puziy A.N., Alkhakov R.R. The hybrid wavelet video encoder with interframe coding on a contour selection basis and its efficiency estimation	90
Mallayev O.U., Ruzimov O.N. Elektr energiya iste'molini ONLINE monitoring qilish qurilmasi va uning strukturasi	94
Raximov B.N., Berdiyev A.A., Xudayberganov J.D. Telekommunikatsiya tizimlarida akustik aks-sado shovqinlarini bartaraf qilishda zamonaviy usullarining qiyosiy tahlili	103
Djumanov J. X., Anorboyev E. A., Jamolov X.M. Kuzatuv quduqlaridan yer osti suvlari sathi va tok o'tkazuvchanligini aniqlovchi masofaviy ma'lumot uzatish qurilmasini yaratish	109
Рахимов Б.Н., Ибрагимов Д.Б. Формирование шумовых сигналов с использованием деаутентификации через отражающую антеннную решетку ВАН-АТТА и антенну креосан направленных против радиоуправляемых взрывных устройств	113
Халиков А.А., Хуррамов А.Ш., Ўрков О.Х. IP- тармок асосидаги тезкор технологик радио алоқа тармоғи ишончлилигини ҳисоблаш методикаси	118
Abdullaev A.X. Magnit maydonagi tok o'tkazuvchi halqasimon plastinkaning chiziqli bo'lmagan deformatsiyasi	126
Мадаминов X.Х., Алиев У.Т., Худайберганов Ж.Д. Ep usti LPWAN тармоклари технологиялари ва уларни сунъий йўлдош тизимга мослаштириш имкониятларини таҳлил килиш	133
Sultonova M.O. Atmosfera optik aloqa tizimlari asosidagi transport tarmoqlarining ishonchliligini baholash usuli	137
Rahimov B. N., Berdiyev A.A., Babajanova A.T., Alimuhammedova M.E. Ko'p kanalli sensorlardagi ma'lumotlarni avtomatlashtirilgan tahlilini olib boruvchi apparat-dasturiy majmuasining arxitekturasini ishlab chiqish	144
ILMIY AXBOROTLAR	147
Boltayev S.T., Valiyev S.I., Mirsagdiyev O.A., Kasimova Q.A. Turli toifadagi poyezdlar uchun yo'l keshimlariga poyezdlarni yaqinlashish uslubiyatini ishlab chiqish	152
Кодиров Ф.М. Телекоммуникация электр таъминоти тизимларини таҳлил килишининг тизимли ёндашуви	160
Sultanov R.R. Research and design structure and formal model of information system for managing educational system and e-content design based on elements of artificial intelligence	167
Mukhtarov F.M., Muminov K.Z. Goals and objectives of information security	174
Beknazarov S.S., Kucharova Sh.S. 3D modellashtirish va misollar bilan animatsiya	177
Elov B.B., Khamroeva Sh.M., Xusainova Z.Y. NLP (tabiiy tilga ishllov berish) ning Pipeline konveyeri	181
Orinbaev A.B. Elektr energiyasini uzatishda sarflanadigan xarajatlarni optimallashtirishning deterministik modeli	192
Сейтназаров К.К., Базарбаева А.К., Туремуратова Б.К. Критерии оценивания студентов в высших учебных заведениях и их анализ	197
Yusupov Ya.T., Aripova M.X., Ibragimova B.B. "Radioelektron qurilmalar va tizimlar" ta'lim yo'nalişidagi mutaxassislik fanlarining "Oliy matematika" fani bilan bog'liqligi tahlili	201
Igamberdiev K.A. Gidravlik tizimlarini tebranma harakatlarini turg'unlik va stabillashtirish jarayonining matematik modeli	205
Мўминов Б.Б., Даулетов А.Ю. Ташкилотларда электрон хужжат айланishi тизимларининг мантикий - функционал жараёнларини лойихалаш ва вақтини ҳисоблаш	208
Meliqo'ziyev R.Sh. Harbiy bo'ilnma jangovar imkoniyatlarini baholash mezoni va algoritimi	215

Elov B.B., Khamroeva Sh.M., Xusainova Z.Y.

NLP (tabiiy tilga ishlov berish) ning Pipeline konveyeri

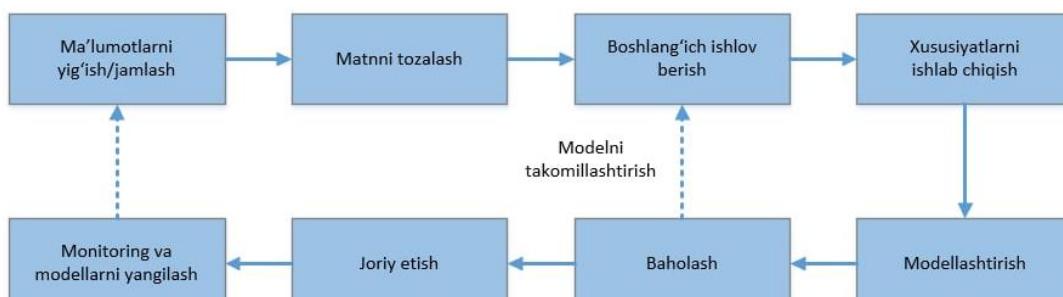
NLP masalasi bir necha kichik qismlarga ajratilib, bosqichma-bosqich hal qilinishi lozim. Ushbu maqolada NLP masalasini hal qilishning har bir bosqichida zarur bo‘lgan matnni qayta ishlashning barcha shakllari ko‘rib chiqiladi. NLPda matnni bosqichma-bosqich qayta ishlash pipeline jarayoni (konveyeri) deb yuritiladi. Har qanday NLP modelini yaratishda pipeline jarayoni amalga oshirilishi lozim bo‘lgan qadamlar ketma-ketligidir. Matnni qayta ishlash konveyerini rejalahtirish va ishlab chiqish har qanday NLP loyihasini yaratishing boshlang‘ich nuqtasi sifatida qaraladi. Ushbu maqolada pipeline jarayonini amalga oshirish uchun bajariladigan qadamlar va ularning NLP vazifalarini hal qilishdagi o‘rni haqida mulohaza yuritiladi. Ushbu maqolada NLP pipeline konveyeridagi eng keng tarqalgan dastlabki ishlov berish bosqichlari tahlil qilindi. Qayta ishlash bosqichlarining barchasi turli NLP kutubxonalarida oldindan o‘qitilgan, foydalishni mumkin bo‘lgan modellar sifatida aniqlangan. Zaruriyat bo‘lganda, berilgan masala shartiga qarab qo‘shimcha, moslashtirilgan oldindan ishlov berish qadamlari ishlab chiqilishi mumkin. Muayyan dastlabki ishlov berish bosqichi berilgan NLP muammosiga qanday xizmat qilishimi faqat ko‘plab tajribalar bilan aniqlash mumkin.

Kalit so‘zlar: NLP, pipeline jarayoni (konveyeri), tokenizatsiya, lemmatizatsiya, stemming, POS-tagging, morfologik tahlil.

Kirish

Odatda, NLP masalasi bir necha kichik qismlarga ajratilib, bosqichma-bosqich hal qilinishi lozim. Ushbu maqolada NLP masalasini hal qilishning har bir bosqichida zarur bo‘lgan matnni qayta ishlashning barcha shakllari ko‘rib chiqiladi. NLPda matnni bosqichma-bosqich qayta ishlash **pipeline jarayoni** (konveyeri) deb yuritiladi [1-4]. Har qanday NLP modelini yaratishda pipeline jarayoni amalga oshirilishi

lozim bo‘lgan qadamlar ketma-ketligidir. Matnni qayta ishlash *konveyerini rejalahtirish* va *ishlab chiqish* har qanday NLP loyihasini yaratishing boshlang‘ich nuqtasi sifatida qaraladi. Ushbu maqolada pipeline jarayonini amalga oshirish uchun bajariladigan qadamlar va ularning NLP vazifalarini hal qilishdagi o‘rni haqida mulohaza yuritiladi. Quyidagi 1-rasmda zamonaviy NLP tizimini ishlab chiqish uchun umumiy pipeline konveyerining asosiy komponentlari ko‘rsatilgan [5].



1-rasm. Pipeline konveyerining asosiy bosqichlari

Pipeline konveyerining asosiy bosqichlari quyidagilardan iborat:

1. *Ma'lumotlarni yig'ish.*
2. *Matnni tozalash.*
3. *Boshlang‘ich ishlov berish.*
4. *Xususiyatlarni ishlab chiqish.*
5. *Modellashtirish.*
6. *Baholash.*
7. *Joriy etish.*
8. *Monitoring va modelni yangilash.*

Asosiy qism

Har qanday NLP tizimini ishlab chiqish jarayonida birinchi qadam berilgan vazifaga tegishli ma'lumotlarni yig'ishdir. Qoidalarga asoslangan NLP tizimini ishlab chiqish uchun *qidalarni loyihalash* va *sinab ko‘rish* uchun training (test) ma'lumotlariga ega bo‘lish kerak. Biz oлган ma'lumotlar kamdan-kam hollarda “toza” bo‘ladi va keyingi bosqichda *matnni tozalash* amali bajariladi. Matn tozalanganidan so‘ng, matn

ma'lumotlarini *kanonik shaklga aylantirish* kerak. Ushbu amal *dastlabki ishlov berish* bosqichida amalga oshiriladi [6-10]. Shundan so‘ng NLP vazifasini bajarish uchun zarur bo‘lgan *xususiyatlarni ishlab chiqish* lozim. Ushbu xususiyatlar *modellashtirish algoritmlari* orqali tushunarli formatga aylantiriladi. Keyingi bosqichda *modellashtirish* va *baholash* amalga oshiriladi. Bu bosqichda bir yoki bir nechta til modellari yaratiladi va ular tegishli baholash ko‘rsatkichlari (metrikalari) yordamida taqqoslanadi. Ishlab chiqilgan modellar orasidan eng yaxshisi tanlab olingandan so‘ng ushbu modelni joriy etish lozim. Va nihoyat, doimiy tarzda *modelning ishlashini kuzatib boramiz* va, agar zaruriyat bo‘lsa, uning ishlashini takomillashtirishimiz, uni yangilashimiz zarur. Dastlabki bosqichlarda ko‘p vaqt *xususiyatlarni ishlab chiqish*, *modellashtirish* va *baholashda* sarflanadi [6,7,11-15].

Dastlabki bosqichlar

Yuqorida aytiganidek, NLP dasturi, odatda, matnni so‘zlarga (tokenlarga) va gaplarga bo‘lish orqali tahlil qiladi. Shunday qilib, har qanday NLP pipeline konveyeri **matnni jumlalarga ajratish** (*gaplar segmentatsiyasi*) va keyinchalik **gaplarni so‘zlarga ajratish** (*so‘zlarni tokenizatsiyalash*)ni to‘g‘ri amalgaga oshiruvchi tizimni ishlab chiqish zarur.

Gap segmentatsiyasi. Oddiy qoidaga ko‘ra, nuqta va so‘roq belgilari paydo bo‘lganda matnni gaplarga ajratish orqali gaplarni segmentatsiyalashimiz mumkin. Ammo oddiy qoidani buzishi mumkin bo‘lgan *qisqartmalar*, *manzil shakllari* (*sh.k – shunga ko‘ra, va b.-va boshqalar*) yoki ko‘p nuqta (...) bo‘lishi mumkin. Python tilida mavjud NLP kutubxonalaridagi standart metodlar orqali gap va so‘zlarni ajratish imkoniyati taqdim etilgan. Quyidagi Python tilidagi kodda **Natural Language Tool Kit (NLTK)** kutubxonasidan gap va so‘z ajratuvchidan qanday foydalanish ko‘rsatilgan:

```
from nltk.tokenize import sent_tokenize,
word_tokenize
mytext = "Odatda NLP masalasini bir nechta kichik qismlarga ajratib bosqichma-bosqich hal qilish lozim. Ushbu maqolada NLP masalasini hal qilishning har bir bosqichda zarur bo‘lgan matnni qayta ishlashning barcha shakllarini ko‘rib chiqiladi."
my_sentences = sent_tokenize(mytext)
```

So‘zlarni tokenizatsiyalash. Tilning asosiy birligi uning so‘z boyligi – leksikasidir. Ammo lug‘at (leksika) o‘z ichiga nimani oladi? “So‘z” atamasi keng ma’noli bo‘lib, ilmiy uslubda qo‘llash uchun ushbu atamani aniqlashtirib olish lozim. Agar matndan ajratuvchilar (*oraliq bo‘shliqlar, ba’zi tinish belgilari va boshqalar*) orqali so‘zlarni ajratib olsak, matnda ko‘plab **tokenlar** hosil qilinadi [16,17]. **Token** matndan chegarasi bilan ajralib turadigan har qanday birlikdir. “*Daraxt bir yerda ko‘karadi*” gapida 4 ta token mavjud: *daraxt, bir, yerda, ko‘karadi*. “*Halol mehnat yerda qolmas*” jumlasida 4 ta token mavjud: *halol, mehnat, yerda, qolmas*.

Gapni tokenizatsiya qilish singari gaplarni so‘zlarga aylantirish uchun tinish belgilaringin mavjudligiga qarab matnni so‘zlarga bo‘lishning oddiy qoidasidan boshlashimiz mumkin. NLTK kutubxonasi buni amalgaga oshirishga imkon beradi:

```
for sentence in my_sentences:
    print(sentence)
    print(word_tokenize(sentence))
```

Mavjud bo‘lgan yechimlar (tokenizatorlar)ning ko‘pchiligi berilgan matnni 100% to‘g‘ri tokenlarga ajratmasligini va ushbu algoritmlar mukammal emasligini yodda tutish kerak. Masalan, quyidagi gapni ko‘rib chiqamiz:

“*Sumbula sapchib o‘rnidan turdi-da: «Xayriyat, tushim ekan», – dedi hansirab.*”

Agar biz yuqorida gapni NLTK tokenizer orqali ishlatsak, *[o‘rnidan] [/] [turdi] [-] [da] [:]* alohida tokenlar sifatida aniqlanadi. Shuningdek, agar tvitlarni tokenlamoqchi bo‘lsak, tokenizator *heshtegni* ikkita tokenga ajratadi: “#” belgisi va *undan keyingi qator*. Bunday hollarda, bizning maqsadimiz uchun (o‘zimiz tomonimizdan) yaratiladigan maxsus tokenizatordan foydalanishimiz kerak bo‘lishi mumkin. Shuning uchun tokenizatorda, ba’zan **grafematik tahlilning** ba’zi elementlari bajarilishi lozim:

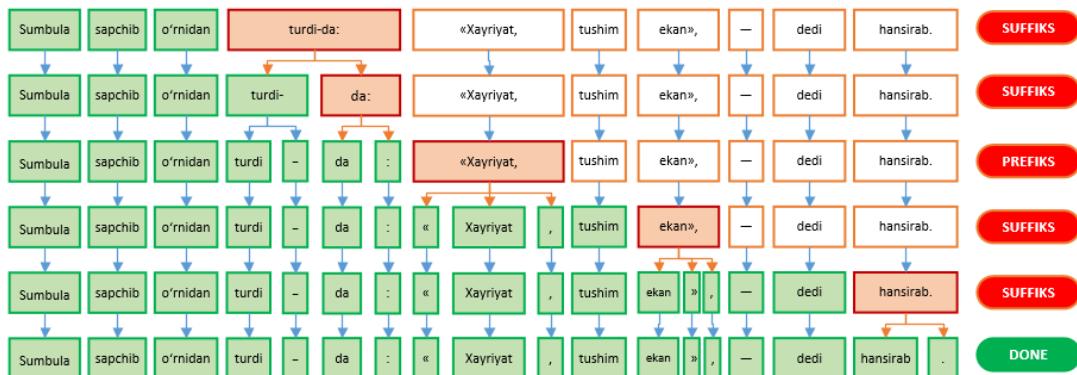
- *harflar ketma-ketligi;*
- *sonlar;*
- *tinish belgilari;*
- *ierogliflar;*
- *ajratuvchilar;*
- *turli grafik belgilari.*

Quyida o‘zbek tilidagi 2 ta gapga mos tokenizatsiya jarayoni va <http://uznatcorpara.uz/uz/Tokenizer> dasturidagi varianti keltirilgan:

Muntazam bajarildigan qadamlar: NLP pipeline konveyerida muntazam bajariladigan boshlang‘ich qayta ishlash amallarini ko‘rib chiqaylik. Aytaylik, biz yangiliklar saytidagi maqolaning toifasini *siyosat, sport, biznes* va boshqa mavzulardan biri sifatida belgilaydigan dasturiy ta’minotni ishlab chiqmoqdamiz. Bizda gapni segment va tokenlarga ajratuvchi dastur mavjud bo‘lsin. Bu holda yangiliklarni guruhlarga ajratish vositasini ishlab chiqish uchun qanday ma’lumotlar foydali ekanligi haqida o‘ylashni boshlashimiz kerak.

O‘zbek tilidagi tez-tez ishlatiladigan so‘zlarning ba’zilari, masalan, *albatta, ammo, asosan, aynan, balki, barcha, bilan, biroq* kabi so‘zlar ushbu vazifa uchun zarur hisoblanmaydi. Chunki ular to‘rtta toifani ajratish uchun o‘z-o‘zidan hech qanday mazmunni anglatmaydi. Bunday so‘zlar **nomuhim so‘zlar** deb ataladi va, odatda, keyingi tahlildan olib tashlanadi. Biroq o‘zbek tili uchun nomuhim so‘zlarning standart ro‘yxati mavjud emas. Mualliflar tomonidan ishlab chiqilgan o‘zbek tilidagi nomuhim so‘zlarning ba’zilari quyidagi jadvalda keltirilgan:

Sumbula sapchib o'rnidan turdi-da: «Xayriyat, tushim ekan», — dedi hansirab.



Matnni kriting

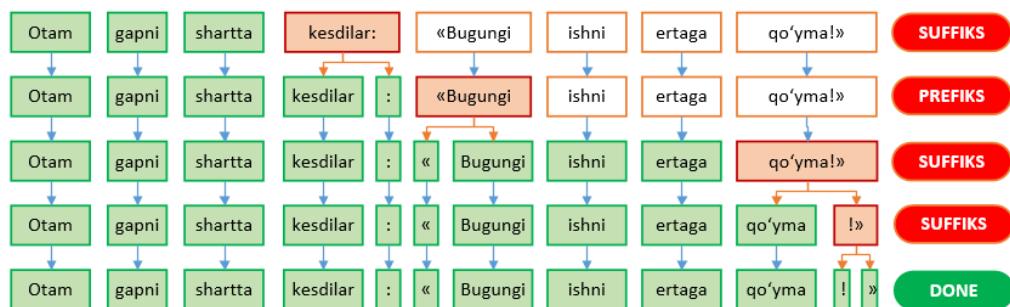
"Sumbula sapchib o'rnidan turdi-da: «Xayriyat, tushim ekan», — dedi hansirab."

tokenizatsiya

Sumbula sapchib o'rnidan turdi-da : « Xayriyat , tushim ekan » , — dedi hansirab .

2-rasm. Tokenizatsiya jarayoniga namuna

Otam gapni shartta kesdilar: «Bugungi ishni ertaga qo'yma!»



Matnni kriting

Otam gapni shartta kesdilar: «Bugungi ishni ertaga qo'yma!»

tokenizatsiya

Otam gapni shartta kesdilar : « Bugungi ishni ertaga qo'yma ! »

3-rasm. Tokenizatsiya jarayoniga namuna

1-jadval

O'zbek tilidagi umumiy nomuhim so'zlar

afsuski	beri	eng	Ila	mening	orqada	shak-shubhasiz	ustida
aftidan	bilan	esa	iloyim	Misli	orqaga	shekilli	ustidan
agar	binoan	essiz	ishonamanki	misoli	orqali	shu	ustiga
aksincha	biroq	evaziga	ishqilib	mobaynida	o'sha	shubhasiz	va
albatta	biroz	faqat	jihatdan	mobodo	ostida	shunchaki	vaqtida
allaqachon	biz	gar	joiz	modomiki	oxir	shunday	xayriyat
alqissa	bizning	garchand	juda	mos	o'zi	shunga	xo'sh
ammo	bo'yи	garchi	jumladan	na, na	o'zim	shuning uchun	xolos

ammo-lekin	bog'liq	go'yo	Kabi	nachora	o'zimiz	shuningdek	xuddi
aqalli	bois	go'yoki	kerak	nafaqat	o'zingiz	singari	xullas
arafasida	boshqa	goh	keyin	nafar	o'zları	siz	xususan
aro	bu	chunonchi	keyingi	natijada	pastda	sizniki	ya'ni
aslida	bular	ham	kim	negaki	pastga	sizning	yana
aslo	bundan	hamda	kimdir	nimagaki	payida	tabiiyki	yanada
asosan	bunday	hamma	kimga	o'rniiga	qachonki	tag'in	yaxshi
asosiy	butun	hammasi	ko'p	o'rtasida	qadar	tahminan	yaxshiyam
avvalambor	chamasi	haqiqatda	ko'plab	o'sha	qarab	tashqari	yo
avvalgi	chog'i	haqiqatdan	ko'proq	o'z	qarata	to'g'risi	yo'qsa
avvalo	chunki	har	ko'ra	o'zi	qaratilgan	toki	yo'q-yo'q
axir	chunonchi	har holda	ko'proq	o'zim	qayta	tomon	yo'sinda
aynan	darhaqiqat	har qalay	lekin	o'zimiz	qaytanga	tufayli	yoki
ayni	darhol	hatto	lozim	o'zingiz	qisqasi	turli	yonida
ayniqsqa	darkor	hech	ma'lum	o'zini	qo'yingki	u	yonidan
aytaylik	dastavval	hokazo	mabodo	o'zları	quyida	uchun	yoniga
aytgancha	davomida	holda	mana	o'z-o'zidan	quyidagi	ular	yo'q
aytganday	demak	hozir	masalan	ochig'i	ravishda	ularni	yoxud
ba'zi	deyarli	hozirda	mayli	oid	rostdan	ularning	yuqorida
balki	deylik	ichida	mazkur	olaylik	rosti	unda	yuqoriga
baravarida	doim	ichidan	mazmuni	oldiga	sana	unga	yuzasidan
barcha	doir	ichiga	men	oldin	sari	uni	zero
barchasi	doirasida	ichkarida	meni	orasida	sayin	uning	zeroki
baribir	ehtimol	ichra	menimcha	orasiga	seningcha	ushbu	zotan

Ba'zi NLP paketlarida nomuhim so'zlar ro'yxatlari (ba'zi chet tillar uchun) mavjud bo'lib, ko'p hollarda, berilgan masalaga ko'ra ular o'zaro farq qilishi mumkin. *Tinish belgilarini* va/yoki *raqamlarni* olib tashlash matnni tasniflash, ma'lumot olish va ijtimoiy media tahlili kabi ko'plab NLP muammolari uchun umumiy qadam hisoblanadi. Quyidagi dastur kodida ingliz tilidagi berilgan matnlar to'plamidan *nomuhim so'zlar, raqamlar, tinish belgilari* va *kichik harflarga o'tkazish* qanday olib tashlanishi ko'rsatilgan:

```
from uzcorpus import stopwords
from string import punctuation
def preprocess_corpus(texts):
    mystopwords=set(stopwords.words("uzbek"))
    def remove_stops_digits(tokens):
        return [token.lower() for token in tokens
                if token not in mystopwords and
                token.isdigit() and token not in punctuation]
    return
    remove_stops_digits(word_tokenize(text))
for text in texts]
```

Shuni ta'kidlash kerakki, ushbu to'rtta jarayon barcha NLP masalalari uchun *majburiy* yoki *ketma-ket* bajarilishi talab etilmaydi. Yuqoridagi funksiya NLP loyihamizga matnni qayta ishslash bosqichlarini qanday amalgalga oshirishni ko'rsatadi. Ushbu funksiya orqali matn

ma'lumotlariga dastlabki ishlov berilgan. So'z darajasidagi xususiyatlarni hisobga oladigan muntazam bajariladigan dastlabki ishlov berish bosqichlari – stemming va lemmatizatsiya hisoblanadi.

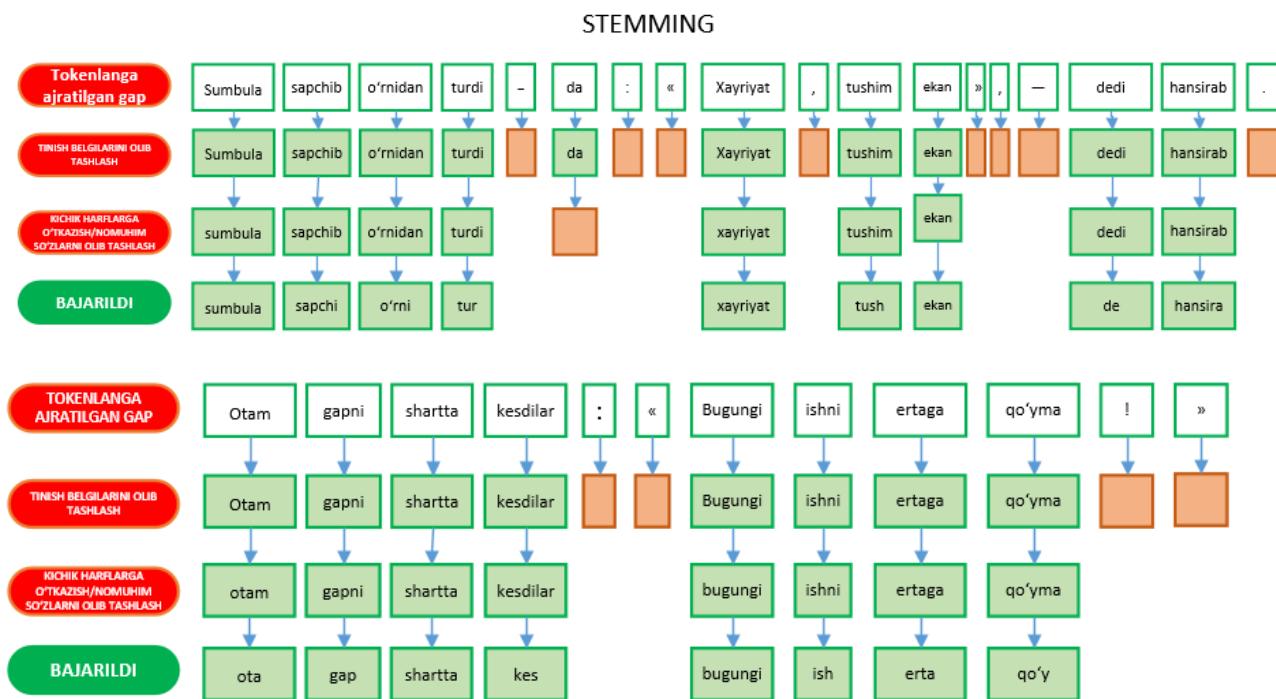
Natijalar va muhokama

Stemming va lemmatizatsiya. Stemming jarayonida so'zdagi *qo'shimchalar* olib tashlanadi va so'zni qandaydir **asosiy shaklg qisqartirish** (so'zshaklni *qo'shimchasiz* holga keltirish) amalga oshiriladi.

Har bir token uchun uning (*lemma deb ataluvchi*) boshlang'ich (*yoki normal*) shakli mavjud. Nutq(matn)da ushbu boshlang'ich shakl turli grammatic shakllarni olgan holda (fleksiya sodir bo'lishi ham mumkin) ishlatalidi. Quyidagi rasmda ikkita gapning stemming bosqichilari ko'rsatilgan.

Bu o'rinda **so'zshakl** atamasiga ham aniqlik kiritishimiz kerak. So'zshakl lemma (leksema)ning nutqda *qo'llanishi* shaklidir. “**Daraxt**” lemmasi ot so'z turkumiga oid bo'lgan turli grammatic shakllarni olib, ko'plab so'zshakllarni hosil qilishi mumkin:

- *daraxt, daraxtni, daraxting, daraxtga, daraxtdan;*
- *daraxtlar, daraxtlarni, daraxtlarning, daraxtlarga, daraxtlardan;*
- *daraxtim, daraxting, daraxti, daraxtimiz, daraxtingiz, daraxtlari.*



4-rasm. Stemming jarayoniga namunalar

Shu tartibda boshqa lemmalar ham nutqda qo'llanish vaqtida so'zshakl ko'rinishga keladi. O'zbek tilida so'z tarkibining odatiy strukturasi quyidagi ko'rinishda bo'ladi:

"O'zak + so'z yasovchi + lug'aviy shakl + sintaktik shakl"

Grammatik vositaning joylashishidagi tartib, izchillik uning ma'no va grammatik xususiyati bilan bog'liq bo'lib, quyidagi ketma-ketlikda shakllantiriladi:

- 1) yangi lug'aviy ma'no hosil qiluvchi;
- 2) lug'aviy ma'noga ta'sir qiluvchi;
- 3) lug'aviy ma'noga ta'sir qilmaydigan, lekin so'zni bog'laydigan vosita qo'shiladi.

Qo'shimchaning joylashuvdagi me'yoriy holat ba'zan buziladi:

opa-lar-im / opa-m-lar, ayt-di-n-g-lar / ayt-di-l-a-r-ing.

O'zbek tilida **qo'shimcha morfemalar** o'zakdan keyin ketma-ket qo'shiladi. Morfotaktika qoidalari so'zshaklda morfema va allomorflarning qanday ketma-ketlikda joylashuvini aniqlaydi. Shularga tayanib, o'zbek tilidagi ayrim morfemalarning bog'lanish imkoniyatini quyidagi jadvalda kuzatamiz:

Yuqoridaq jadvaldan *-lar*, *-im*, *-ing*, *-imiz*, *-si*, *-ni* kabi qo'shimchalar o'zakka to'g'ridan-to'g'ri qo'shilishini ko'rish mumkin. Boshqa affiksal morfemaning esa chap tomoniga qo'shiladi. *-man*, *-san*, *-miz*, *-siz* qo'shimchalari esa o'zakka to'g'ridan-to'g'ri qo'shila olmaydi. Chunki ulardan oldin o'zakka avval boshqa morfema (masalan, zamon qo'shimchasi) qo'shilib, undan keyingi pozitsiyani bu qo'shimchalar guruhi egallaydi, ular affiksal morfemalardan o'ng tomonda joylashish xususiyatiga ega.

3-jadval. Chap tomonda joylashuvchi morfemalar

morfemalar	chap tomonda joylashish xususiyati (+/-)	misol
<i>-lar</i>	+	bola+lar+dan
<i>-man</i>	-	bor+a+man
<i>-san</i>	-	o'qi+y+san
<i>-miz</i>	-	yoz+a+miz
<i>-siz</i>	-	ayt+ib+siz
<i>-ing</i>	+	kel+ing
<i>-im</i>	+	kitob+im
<i>-imiz</i>	+	daftar+imiz
<i>-si</i>	+	uka+si
<i>-ni</i>	-	ashula+ni

Demak, o'zbek tilida o'zak va qo'shimchalarining joylashuvchi minimal tarzda quyidagi ko'rinishda bo'ladi:

Vatan - dosh - im - ga
Asos + so'z yasovchi + shakl yasovchi + shakl yasovchi

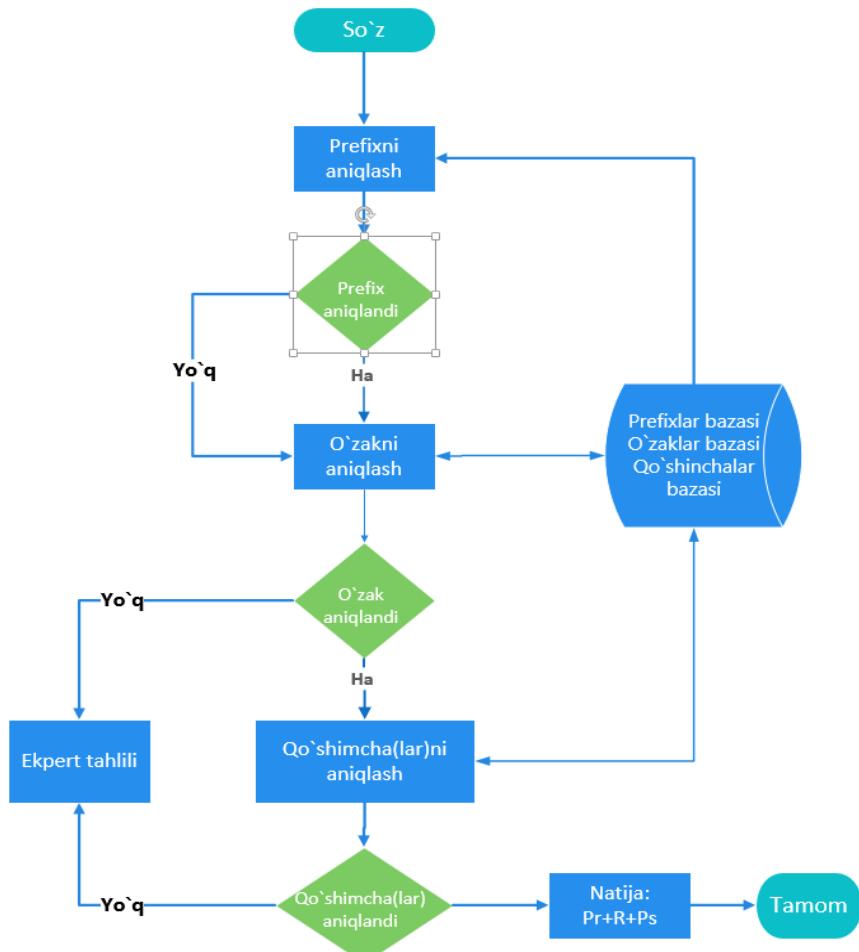
Yangi so'z yoki so'zshakllarini tilning eng kichik birligi – **morflarini birlashtirish** orqali hosil qilinadi. Morflar o'zak (*so'z asosi*) va qo'shimchalarga bo'linadi:

- *oldqo'shimcha (so'z yasovchi);*
- *so'zdan keyin qo'shiluvchi so'z yasovchi;*
- *sintaktik shakl yasovchi;*
- *lug'aviy shakl yasovchi qo'shimchalar.*

So'zning asosiy lug'aviy ma'nosini o'zak anglatadi. Qo'shimchalar esa so'zga qo'shimcha ma'no beradi. So'zni morfemalarga ajratish **morfemik tahlil** deyiladi (5-rasm). Masalan:

Jadal	-	lash	-	tir	-	il	-	di
asos	+	so'z yasovchi	+	shakl yasovchi	+	shakl yasovchi	+	sintaktik shakl yasovchi

Quyidagi 5-rasmda so'z tarkibini aniqlash algoritmini keltiramiz:



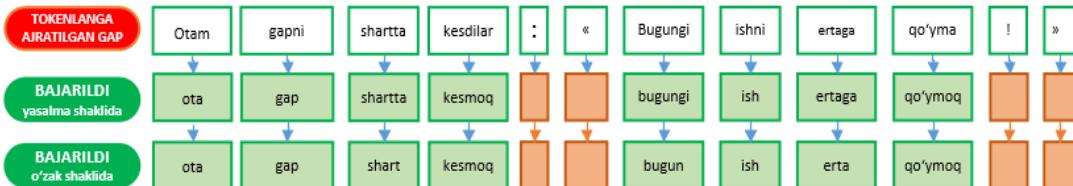
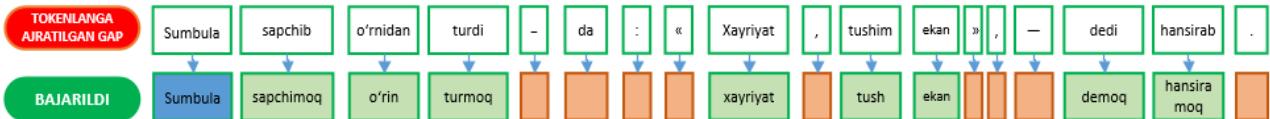
5-rasm. O'zbek tilidagi so'z tarkibini aniqlash algoritmi

Lemmatizatsiya – bu so'zning barcha turli so'zshakllarini **asosiy so'z** yoki **lemma** bilan taqoslash jarayoni. Bu stemming jarayoniga o'xshash ko'rinsa-da, ular, aslida, boshqacha. Quyida lemmatizatsiya jarayoni ko'rsatiladi: E'tibor berilishi lozim jihat shuki, stemming va lemmatizatsiyani farqlash lozim. Chunki ko'pincha o'zbek tilida stemming va lemmatizatsiya natijasi bir xildek ko'rindi, ammo ular batamom farqli jarayonlar sanaladi: stemming o'zakdan qo'shimchani kesish, lemmatizatsiya esa o'zakning lug'atdagi variantini

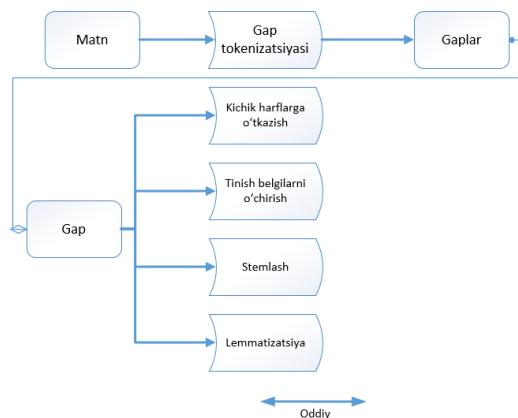
aniqlash jarayonidir. Quyida stemming va lemmatizatsiya jarayoni tahliliga misollar keltiramiz (7-rasm).

Lemmatizatsiya ko'proq lingvistik bilimlarni talab qiladi, zero o'zbek tili matnlari uchun samarali natija qaytaruvchi lemmatizatorlarni modellashtirish va ishlab chiqish hozir ham NLP tadqiqotlarida ochiq muammo bo'lib qolmoqda.

Berilgan matndan nomuhim so'zlar, raqamlar, tinish belgilari va kichik harflarni olib tashlash.



6-rasm. Lemmatizatsiya jarayoniga namunalar



7-rasm. Stemming va lemmatizatsiya o'rtaqidagi farq qadamlarining hammasi ham doim ham zaruriy qadamlar hisoblanmaydi. Misol uchun, agar biz matndagi *raqamlar* va *tinish belgilarni* olib tashlasak, birinchi navbatda, olib tashlangan narsalar unchalik muhim bo'lmasligi mumkin. Biroq biz, odatda, matnda stemming jarayonini bajarishdan oldin bosh harflarni kichik harf bilan almashtiramiz.

Lemmatizatsiya so'z va uning kontekstining ma'lum miqdordagi lingvistik tahlilni o'z ichiga olganligi sababli unga stemming jarayonidan ko'ra ko'proq vaqt talab etiladi va u, odatda, faqat zarurat tug'ilganda qo'llanadi. NLP pipeline konveyerining dastlabki ishlov berish bosqichlari uchun qaysi lemmatizator yoki stemmerdan foydalanish berilgan masalaning shartiga mos holda tanlanadi.

Lemmatizatsiya jarayonidan oldin biz matndan leksema va kichik harflarni olib tashlamaymiz. Chunki lemmanni olish uchun so'zning turkumini (part of speech) bilishimiz kerak va bu gapdag'i barcha tokenlarning buzilmasligini talab qiladi. Ma'lumotlarimizni qanday qayta ishslashni aniq tushunganingizdan so'ng bajarilishi kerak bo'lgan dastlabki ishlov berish amallarining ketma-ket ro'yxatini tayyorlash maqsadga muvofiq. Mualliflar tomonidan ishlab chiqilgan o'zbek tili morfoanalizatoridan (<http://uznatcorpora.uz/>) NLP pipeline konveyeridagi tokenizatsiya, stemming va lemmatizatsiya boshqichlariga namunalar va ma'lumotlar bazasidagi ER model quyida keltirilgan:

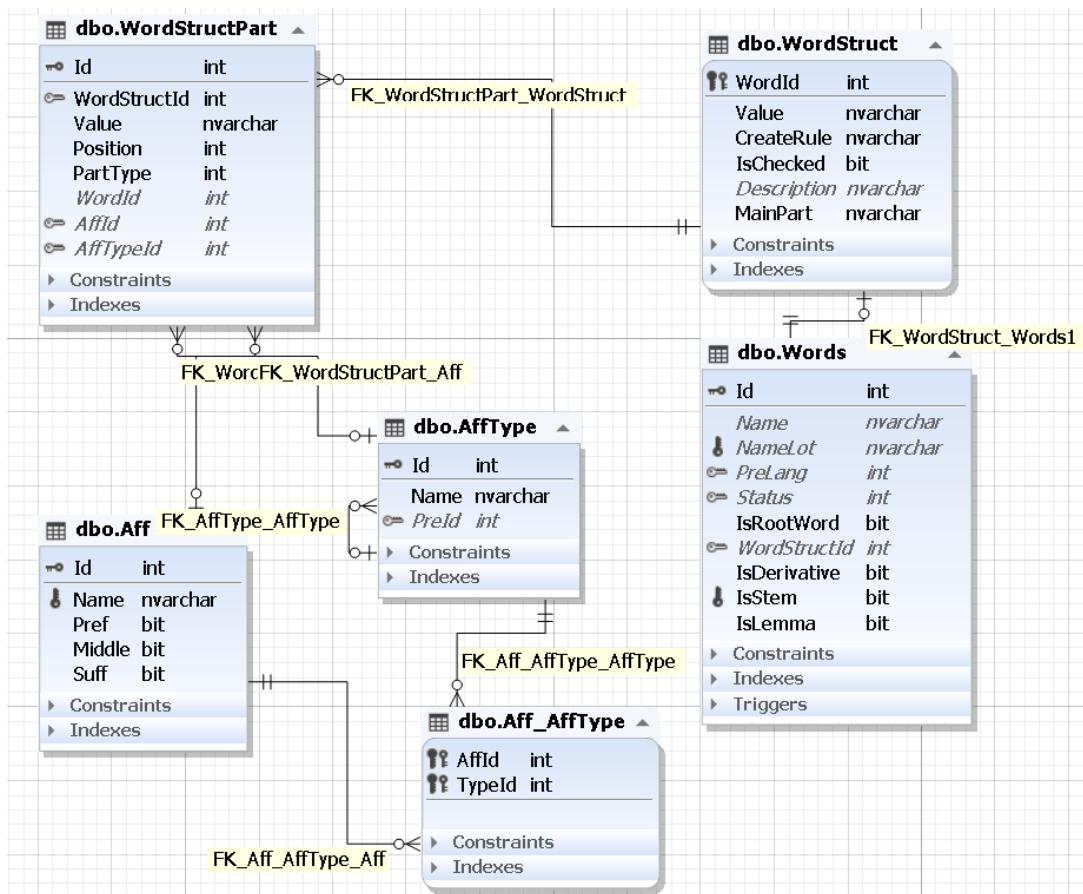
STEMMING

qishlog'im	→ qishlog'
etagi	→ etag
shunaqa	→ shun
bunday	→ bun
ikkovimiz	→ ikk
ayblov	→ ayblo
taroq	→ taro
shahrimiz	→ shahr
singlim	→ singl
o'rnинг	→ o'rn
nonni	→ non
shuhratim	→ shuhrat
maktabdan	→ maktab
olamning	→ olam

LEMMATIZATSİYA

qishlog'im	→ qishloq
etagi	→ etak
shunaqa	→ shu
bunday	→ bu
ikkovimiz	→ ikki
ayblov	→ aybla
taroq	→ tara
shahrimiz	→ shahar
singlim	→ singil
o'rnинг	→ o'rin
nonni	→ non
shuhratim	→ shuhrat
maktabdan	→ maktab
olamning	→ olam

8-rasm. Matn fragmenti uchun umumiyl dastlabki ishlov berish bosqichlari



9-rasm. NLP pipeline konveyerining ER modeli

Matnni kiriting

"Sumbula sapchib o'rnidan turdi-da: «Xayriyat, tushim ekan», — dedi hansirab."

Analiz

Nº	So'z	Lemma	So'z turkumi	O'zak va qo'shimchalar
1	Sumbula	sumbula	Ot	{sumbula}
2	sapchib	sapchimoq	Fe'l	{sapchi}-b
3	o'rnidan	o'rın	Ot	{o'rın}-i-dan
4	turdi-da	turdi-da		{turdi-da}
5	Xayriyat	xayriyat	Modal	{xayriyat}
6	tushim	tushim	Ot	{tushim}
7	ekan	ekan	Fe'l	{ekan}
8	dedi	demoq	Fe'l	{de}-di
9	hansirab	hansiramoq	Fe'l	{hansira}-b

10-rasm. O'zbek tili morfoanalizatori (<http://uznatcorpara.uz/>)**Dastlabki ishlov berishning qo'shimcha bosqichlari:**

Yuqorida NLP pipeline konveyerida bir nechta umumiy dastlabki ishlov berish bosqichlari ko'rib chiqildi. Bunda matnlarning mohiyati aniq ko'rsatilmagan bo'lsa-da, oddiy inglizcha matn bilan ishlash taxmin qilindi. Quyida yana bir nechta dastlabki ishlov berishning qo'shimcha bosqichlarini keltiramiz.

Matnni normallashtirish. Ijtimoiy media postlaridagi yangiliklarni aniqlash masalasini ko'rib chiqaylik. Ijtimoiy media matni gazetalarda foydalaniladgan tildan juda farq qiladi. So'zlar turli yo'llar bilan yozilishi mumkin, masalan, *qisqartirilgan shakllarda, telefon raqami turli formatlarda yozilishi mumkin, ismlar ba'zan kichik harflar bilan yoziladi* va hokazo. Bunday ma'lumotlar bilan ishlash uchun NLP vositalarini ishlab

chiqishda matnning barcha o'zgarishlarni qamrab oladigan **kanonik shaklini** hosil qilishimiz lozim. Ushbu jarayon **matnni normallashtirish** deb nomlanadi. Matnni normallashtirishning ba'zi umumiy qadamlari matnni barcha *kichik yoki katta harflarga aylantirish*, *raqamlarni matnga aylantirish* (masalan, 9 - to'qqizga), *qisqartmalarni kengaytirish* va hokazo. Matnni normallashtirishning oddiy usuli Spacy paketida taqdirm etilgan.

Tilni aniqlash. Ko'pgina veb-kontent ingliz tilidan tashqari tillarda yoziladi. Misol uchun, bizdan mahsulotimiz haqidagi barcha sharhlarni internetda to'plashimiz so'ralgan deylik. Turli elektron tijorat veb-saytlarini tahlil qilish natijasida mahsulotimizga tegishli sahifalarni skanerlashni boshlaganimizda, biz bir nechta inglizcha bo'lмаган sharhlar paydo bo'lishiga guvoh bo'lamic. NLP pipeline konveyerining asosy qismi tilga xos vositalar bilan qurilganligi sababli inglizcha matnni kutayotgan NLP quvurimizda qayday o'zgarishlarni amalga oshirish lozim? Bunday hollarda **tilni aniqlash** NLP pipeline konveyerining birinchi qadami sifatida

amalga oshiriladi. Tilni aniqlash uchun Polyglot kabi NLP paketlaridan foydalanishimiz mumkin. Ushbu amal bajarilgandan so'ng NLP pipeline konveyerining keyingi qadamlari tilga xosligini kuzatish mumkin.

Dunyo bo'ylab ko'p odamlar kundalik hayotlarida bir nechta tillarda gaplashadilar. Shunday qilib, ijtimoiy tarmoqlardagi postlarda bir nechta tillardan foydalanadilar. Kodlarni aralashtirishga misol sifatida 5-rasmdagi LCDdagı **Singlish** (Singapur jargoni + Ingliz tili) iborasini ko'rishimiz mumkin. Bitta iborada *tamil*, *ingliz*, *malay* va uchta *xitoy tilidagi* so'zlar mavjud. Kodlarni aralashtirish tillar o'rtasida almashinishing ushbu hodisasiga ishora qiladi. Odamlar o'z yozuvlarida bir nechta tillardan foydalanganda, ular, ko'pincha, bu tillarda so'zлarni **lotin yozuvida**, **inglizcha imlo bilan** yozadilar. Demak, ingliz tilidagi matn bilan birga boshqa tildagi so'zлар ham yoziladi. Bu jarayon **transliteratsiya** sifatida tanilgan. Ushbu ikkala hodisa ham ko'p tilli jamoalarda keng tarqalgan va matnni boshlang'ich qayta ishslash jarayonida ularni inobatga olish kerak [5].

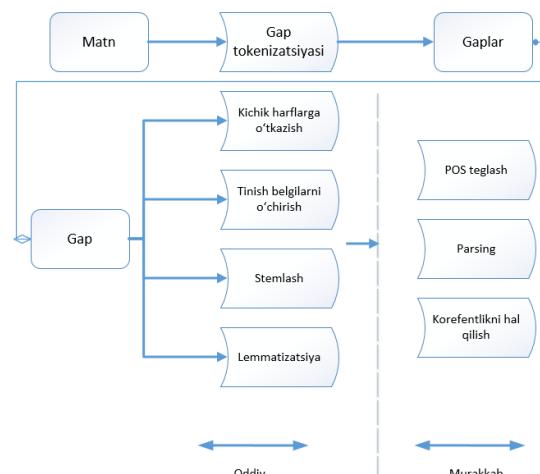


Translation: Hey, when we date we always eat at the coffeeshop(one).

11-rasm. Singlish tilidagi post

Yuqorida umumiy boshlang'ich ishlov berish bosqichlari muhokama qilindi. Ushbu ro'yxat to'liq bo'lmasa-da, ma'lumotlar to'plamining tabiatiga qarab talab qilinishi mumkin bo'lgan turli xil boshlang'ich ishlov berish usullari haqida tasavvur beradi deb umid qilamiz.

Kengaytirilgan ishlov berish: Kompaniyadagi bir million hujjat to'plamidagi *shaxs va tashkilot nomlarini aniqlash* tizimini ishlab chiqish masalasini ko'rib chiqamiz. Biz ilgari muhokama qilgan matnni qayta ishslashning umumiy bosqichlari bu kontekstga mos kelmasligi mumkin. Ismlarni identifikatsiyalash bizdan POS teglarini amalga oshirishni talab qiladi. Chunki tegishli atoqli otlarni aniqlash shaxs va tashkilot nomlarini aniqlashda foydali bo'lishi mumkin. Loyihaning dastlabki ishlov berish bosqichida POS teglarini qanday qilamiz? Oldindan o'qitilgan va oson foydalanish mumkin bo'lgan POS teggerlari NLTK, spaCy va Parsey McParseface Tagger kabi NLP kutubxonalarida qo'llaniladi. Biz, odatda, o'zimizning POS-teglesh yechimlarimizni ishlab chiqishimiz shart emas. Shuni ta'kidlash kerakki, bir xil dastlabki ishlov berish bosqichi uchun turli NLP kutubxonalaridagi natijalar o'rtasida farqlar bo'lishi mumkin.

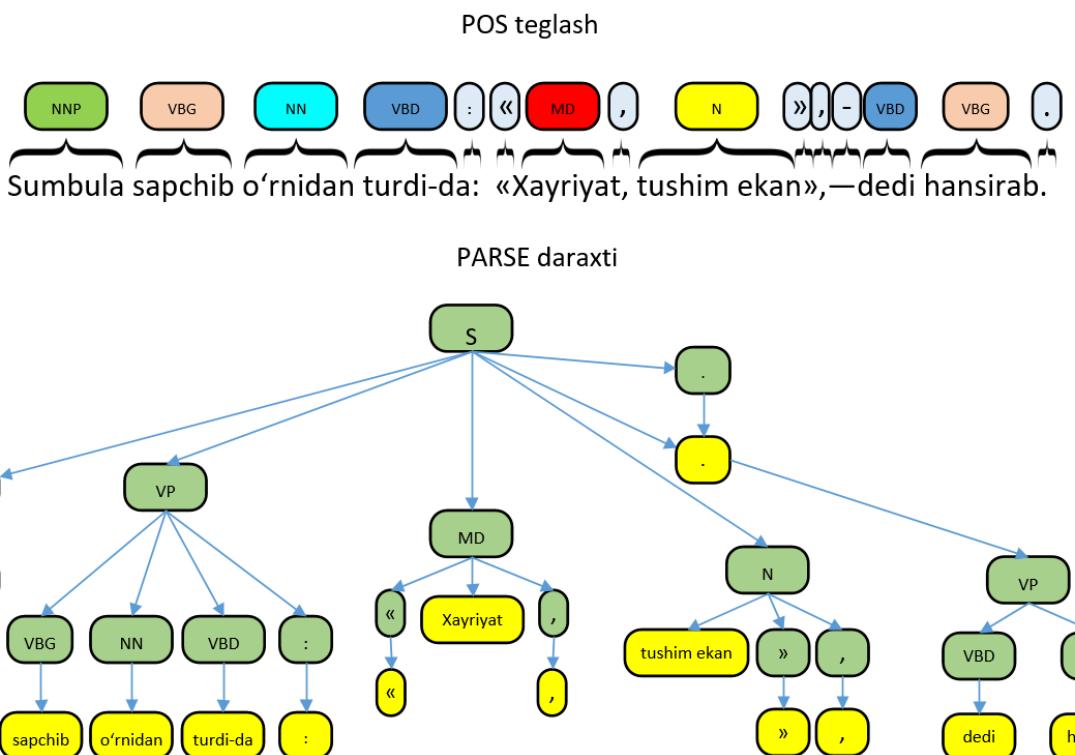


12-rasm. Matn fragmenti uchun kengaytirilgan ishlov berish bosqichlari

Bu amalga oshirishdagi farqlar va turli kutubxonalar o'rtasidagi algoritmlar bilan bog'liq. NLP loyihasida qaysi kutubxonadan (yoki kutubxonalaridan) foydalanish – berilgan masala shartiga bog'liq. Keling, biroz boshqacha muammoni ko'rib chiqaylik: kompaniyamizning millionlab hujjatlar to'plamidagi shaxs va tashkilot nomlarini aniqlash bilan bir qatorda, bizdan ma'lum bir shaxs va tashkilot qandaydir tarzda bir-biriga bog'liqligini aniqlashimiz so'raladi. Buning uchun bizga gapdagidagi ikkita shaxs o'rtasidagi "munosabat"ni ko'rsatadigan shablonlarni aniqlash

usulini ishlab chiqish kerak. Bu bizdan gapning sintaktik ifodalanishining qandaydir shakliga ega bo‘lishni talab qiladi. Bundan tashqari, biz obyektning bir necha

eslatmalarini aniqlash va bog‘lash usulini aniqlashimiz lozim.



13-rasm. NLP pipeline konveyerida POS teglash va gap strukturasiga namuna

Xulosa.

Ushbu maqolada NLP pipeline konveyeridagi eng keng tarqalgan dastlabki ishlov berish bosqichlari tahlil qilindi. Qayta ishlash bosqichlarining barchasi turli NLP kutubxonalarida oldindan o‘qitilgan, foydalanish mumkin bo‘lgan modellar sifatida aniqlangan. Zaruraiyat bo‘lganda, berilgan masala shartiga qarab qo‘srimcha, moslashtirilgan oldindan ishlov berish qadamlari ishlab chiqilishi mumkin. Muayyan dastlabki ishlov berish bosqichi berilgan NLP muammosiga qanday xizmat qilishini faqat ko‘plab tajribalar bilan aniqlash mumkin. Alisher Navoiy nomidagi Toshkent Davlat o‘zbek tili va adabiyoti universitet olimlari tomonidan ishlab chiqilgan o‘zbek tili morfoanalizatorida (<http://uznatcorpara.uz/>) NLP pipeline konveyerining tokenizatsiya, stemming va lemmatizatsiya boshqichlari ishlab chiqilgan hamda amaliyotga tadbiq etilgan.

Foydalilanigan adabiyotlar

1. Saloot, M. A., & Pham, D. N. (2021). Real-time Text Stream Processing: A Dynamic and Distributed NLP Pipeline. ACM International Conference Proceeding Series. <https://doi.org/10.1145/3459104.3459198>
2. Becquin, G. (2020). End-to-end NLP Pipelines in Rust. <https://doi.org/10.18653/v1/2020.nlpos-1.4>
3. Peng, N., Ferraro, F., Yu, M., Andrews, N., DeYoung, J., Thomas, M., Gormley, M. R., Wolfe, T.,

Harman, C., van Durme, B., & Dredze, M. (2015). A concrete Chinese NLP pipeline. NAACL-HLT 2015 - 2015 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies - Demonstrations, Proceedings. <https://doi.org/10.3115/v1/n15-3018>

4. Noji, H., & Miyao, Y. (2016). Jigg: A framework for an easy natural language processing pipeline. 54th Annual Meeting of the Association for Computational Linguistics, ACL 2016 - System Demonstrations. <https://doi.org/10.18653/v1/p16-4018>

5. S.Vajjala, B.Majumder, A.Gupta, H.Surana. Practical Natural Language Processing. A Comprehensive Guide to Building Real-World NLP Systems. 2020. 455 p.

6. Botir E.B., Axmedova X.I. Business Process Modeling That Distinguishes Homonymy Within Three Parts of Speechs in Uzbek Language // International conference on information science and communications technologies application, trends and opportunities (IEEE - UBMK - VII. Uluslararası Bilgisayar Bilimleri ve Mühendisliği Konferansı). Ankara, 2022.

7. B. Elov, Sh. Hamraeva, X. Axmedova Methods for creating a morphological analyze // 14th International Conference on Intelligent Human Computer Interaction. 19-23 October 2022, Tashkent.

8. B. Elov, Sh. Hamroyeva, D. Elova. Morfologik analizatorni yaratish usullari // O'zbekiston: til va madaniyat. Amaliy filologiya masalalari. 2022-yil 5 (1) son. – B. 67-87.
9. Менглиев Б.Р., Хамроева Ш.М. Структура и единицы морфоанализатора узбекского языка // Компьютерная лингвистика и вычислительные онтологии. Выпуск 5 (Труды XXIV Международной объединенной научной конференции «Интернет и современное общество», IMS-2021, Санкт-Петербург, 24 – 26 июня 2021 г. Сборник научных трудов). – СПб.: Университет ИТМО, 2021. – 82 с
10. Elov B.B. N-gramm til modellari vositasida o'zbek tilida matn generatsiya qilish // Kompyuter lingvistikasi: muammolar, yechim va istiqbollar / Xalqaro ilmiy-amaliy konferensiya to'plami. Elektron nashr / ebook. – Toshkent: 2022.
11. Soysal, E., Wang, J., Jiang, M., Wu, Y., Pakhomov, S., Liu, H., & Xu, H. (2018). CLAMP - a toolkit for efficiently building customized clinical natural language processing pipelines. Journal of the American Medical Informatics Association, 25(3). <https://doi.org/10.1093/jamia/ocx132>
12. Tenney, I., Das, D., & Pavlick, E. (2020). BERT rediscovers the classical NLP pipeline. ACL 2019 - 57th Annual Meeting of the Association for Computational Linguistics, Proceedings of the Conference. <https://doi.org/10.18653/v1/p19-1452>
- Attardi, G. (2015). DeepNL: A deep learning NLP pipeline. 1st Workshop on Vector Space Modeling
13. for Natural Language Processing, VS 2015 at the Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, NAACL-HLT 2015. <https://doi.org/10.31115/v1/w15-1515>
14. Koeva, S., Obreshkov, N., & Yalamov, M. (2020). Natural language processing pipeline to annotate bulgarian legislative data. LREC 2020 - 12th International Conference on Language Resources and Evaluation, Conference Proceedings.
15. de Vries, W., van Cranenburgh, A., & Nissim, M. (2020). What's so special about BERT's layers? A closer look at the NLP pipeline in monolingual and multilingual models. Findings of the Association for Computational Linguistics Findings of ACL: EMNLP 2020. <https://doi.org/10.18653/v1/2020.findings-emnlp.389>
16. Elov B. Tabiiy tilni qayta ishlash (nlp)da spacy modulidan foydalanish. Science and innovative development. 4/2022. Tashkent. 41-55 p.
17. Xusainova Z.Y. NLP: tokenizatsiya, stemming, lemmatizatsiya va nutq qismlarini teglash. O'zbek amaliy filologiyasi istiqbollar / Respublika ilmiy-amaliy konferensiya to'plami. Elektron nashr / ebook. – Toshkent: ToshDO'TAU, 26.10.2022. 159-163 b.
- Elov Botir Boltayevich** Alisher Navoiy nomidagi Toshkent Davlat o'zbek tili va adabiyoti universiteti Kompyuter lingvistikasi va raqamli texnologiyalar kafedrasi mudiri t.f.f.d, dotsent.
E-mail: elov@navoiv-uni.uz
- Hamroyeva Shahlo Mirjanovna** Alisher Navoiy nomidagi Toshkent Davlat o'zbek tili va adabiyoti universiteti Kompyuter lingvistikasi va raqamli texnologiyalar dotsenti f.f.d.
E-mail: shaxlo.xamrayeva@navoiv-uni.uz
- Xusainova Zilola Yuldashevna** Alisher Navoiy nomidagi Toshkent Davlat o'zbek tili va adabiyoti universiteti Kompyuter lingvistikasi va raqamli texnologiyalar kafedrasi tayanch doktoranti.
E-mail: xusainovazilola@navoiv-uni.uz
- B.B. Elov, Sh.M. Khamroeva, Z.Y. Xusainova
NLP (TABIIY TILGA ISHLOV BERISH) NING
PIPELINE KONVEYERI**
- The problem of NLP should be divided into several small parts and solved step by step. This article examines all forms of text processing required at each stage of NLP problem solving. In NLP, the step-by-step processing of text is called a pipeline process (conveyor). A pipeline is a sequence of steps that must be followed when building any NLP model. Planning and developing a text processing in the NLP pipeline pipeline. All processing steps are defined as pre-trained, usable models in various NLP libraries. If necessary, additional, customized preprocessing steps can be developed depending on the given problem condition. How a particular preprocessing step works for a pipeline is considered the starting point for any NLP project. This article discusses the steps involved in implementing a pipeline process and their role in solving NLP tasks. This article analyzes the most common preprocessing steps given NLP problem can only be determined with a lot of experimentation.
- Keywords:** NLP, pipeline process (conveyor), tokenization, lemmatization, stemming, POS-tagging, morphological analysis.