

BERT TIL MODELIDAN FOYDALANGAN HOLDA O'ZBEK TILI LINGVISTIK MUAMMOLARINI YECHISH

Jumanazarov Mardonbek Davronbek o'g'li

jumanazarovmardonbek99@gmail.com,

UrDU magistranti

Madatov Xabibulla Axmedovich

fizika-matematika fanlari nomzodi

khabibulla@urdu.uz,

UrDU dotsenti

Annotatsiya. BERTbek nomi bilan ma'lum bo'lgan o'zbek BERT modelining paydo bo'lishi o'zbek tili uchun tabiiy tilni qayta ishlashda (NLP) muhim bosqichni ko'rsatadi. Ushbu maqola BERTbekning turli lingvistik vazifalarni, xususan, hissiyotlarni tahlil qilish, matnlarni tasniflash, niqoblangan tilni modellashtirish (MLM) va nomuhim so'zlarni olib tashlashdagi imkoniyatlarini o'rganadi. Tadqiqotchilar va ishlab chiquvchilar ushbu oldindan o'rgatilgan modeldan foydalanish orqali o'zbek tilidagi NLP ilovalarining samaradorligi va aniqligini oshirishi, til texnologiyasi va lingvistik tadqiqotlardagi yutuqlarni qo'llab-quvvatlashi mumkin.

Abstract. The advent of the Uzbek BERT model, known as BERTbek, marks a significant milestone in natural language processing (NLP) for the Uzbek language. This essay explores the capabilities of BERTbek in addressing various linguistic tasks, specifically sentiment analysis, text classification, masked language modeling (MLM), and stopwords removal. By leveraging this pre-trained model, researchers and developers can enhance the efficiency and accuracy of NLP applications in Uzbek, fostering advancements in language technology and linguistic research.

Аннотация. Появление узбекской модели BERT, известной как BERTbek, знаменует собой важную веху в области обработки естественного языка (NLP) для узбекского языка. В этом эссе исследуются возможности БЕРТбека в решении различных лингвистических задач, в частности, анализа настроений, классификации текста, моделирования языка в масках (MLM) и удаления стоп-слов. Используя эту предварительно обученную модель, исследователи и разработчики могут повысить эффективность и точность приложений НЛП на узбекском языке, способствуя развитию языковых технологий и лингвистических исследований.

Kalit so'zlar: *NLP, BERT, o'zbek tili, sentiment tahlil, matnlar tasnifi, MLM (maskalangan tilni modellashtirish), nomuhim so'zlar.*


Kirish

BERT (Transformerlardan ikki tomonlama kodlovchi vakilliklari) modellari matnning chuqur kontekstli tasvirlarini taqdim etish orqali NLP sohasida inqilob

qildi. O'zbek tili uchun mo'ljallangan BERTbek dasturining ishlab chiqilishi avval ixtisoslashtirilgan hisoblash resurslari yo'qligi sababli qiyin bo'lgan NLP vazifalari uchun yangi yo'llarni ochadi. O'zbekcha matnning katta jamlanmasida tayyorlangan ushbu model tilning nozik tomonlarini qamrab olgan bo'lib, yanada nozik va samarali lingvistik tahlil qilish imkonini beradi. BERTbekning hissiyotlarni tahlil qilish, matn tasnifi, MLM va nomuhim so'zlarni olib tashlashda qo'llanilishi uning ko'p qirraliligi va o'zbek kontekstidagi lingvistik vazifalarni o'zgartirish imkoniyatlarini ko'rsatadi.

NLP vazifalari

Sentiment tahlil. BERTbek jamoatchilik fikrini tushunish, bozor tadqiqotlari va ijtimoiy media monitoringi uchun muhim bo'lgan matn segmentlarining emotsional ohangini aniqlaydigan hissiyotlarni tahlil qilishda ustundir. BERTbek orqali kiritilgan matnni qayta ishlash orqali his-tuyg'ularni ijobiy, salbiy yoki neytral deb aniq tasniflash mumkin, bu esa o'zbekzabon jamoalarning jamoaviy kayfiyati yoki fikri haqida qimmatli ma'lumotlarni taqdim etish imkonini beradi.



O'zbek tilidagi matnlarni sentiment tahlil qilish bosqichlari dastlab berilgan matnni fundamental NLP qadamlardan, masalan transliteratsiya [Kutlimuratova, Kuriyozov, Tillaeva, 2022: 161-171], tokenlash [Sharipov, Salayev, Matlatipov, 2021], hamda stopwrd(nomuhim so'z)lardan tozalash [Kutlimuratova, 2021] kabi qadamlardan o'tkazib, keyin sentiment tahlil qiluvchi modelga kerakli formatda yetkazib berishdan iborat. Bu bosqichlar quidagi blok-sxemada ko'rsatilgan.

Lingvistik qoidalar qurish usulida salbiy va ijobiy ma'no beruvchi so'zlar bazasidan yoki umumiy lingvistik qoidalardan foydalaniladi. Sentimental gaplarda sifatlar ko'p qo'llanilganligi uchun sifatlarning orttirma darajasini yasovchi so'zlarni ham kiritish orqali matnning salbiy yoki ijobiy ekanligini aniqroq aytishimiz mumkin.

Bu turdagi dasturga oddiy misol:

import re

pos_suzlar="yaxshi, a'lo, chiroyli, aqlli, go'zal, yoqdi, bo'ladi, ajoyib, ko'p, qiziqarli"

neg_suzlar="yomon, rasvo, xunuk, aqlsiz, dabdala, qiziqarsiz, zerikarli, yoqmadi"

kuchaytiruvchi_suzlar="juda, eng, bag'oyatda, g'oyat, nihoyatda, behad "

gap=input("Matn kiriting: ")

gap1=gap.split()

t=0

for i in gap.split():

if re.findall(i,pos_suzlar):

t=1

if re.findall(j, kuchaytiruvchi_suzlar):

print("Bu ijobiy gapligi aniq")

break

print("Bu ijobiy gap")

break

elif re.findall(i, neg_suzlar):

t=1

if re.findall(j, kuchaytiruvchi_suzlar):

print("Bu salbiy gapligi aniq")

break

print("Bu salbiy gap")

break

j=i

if t==0: print("Aniqlab bo'lmadi.")

Matnlar tasnifi

Matnlarni tasniflashda BERTbek matnga oldindan belgilangan toifalarni tayinlaydi, bu esa kontentni tashkil etish, mavzuni ochish va ma'lumot qidirishni osonlashtiradi. Yangilik maqolalarini saralash, ilmiy maqolalarni tasniflash yoki veb-kontentni tartibga solish bo'ladimi, BERTbekning chuqur o'rganish imkoniyatlari tasniflash topshiriqlarida yuqori aniqlik va dolzarblikni ta'minlaydi, o'zbek tilida ma'lumotlarga kirish va boshqarishni yaxshilaydi.

Niqoblangan tilni modellashtirish (MLM)

BERTning asosiy o'quv komponenti bo'lgan MLM jumlada yetishmayotgan so'zlarni bashorat qilishni o'z ichiga oladi. BERTbekning MLM tilidagi malakasi tilni ilg'or tushunish va yaratish imkonini beradi, matnni to'ldirish, avtomatik tuzatish va til o'rgatish kabi vazifalarni bajarishda yordam beradi. Bu qobiliyat o'zbek tilidan dinamik foydalanishni qo'llab-quvvatlovchi tilga asoslangan intellektual dasturlarni ishlab chiqish uchun juda muhimdir.

Nomuhim so'zlarni olib tashlash

BERT modellarining to'g'ridan-to'g'ri qo'llanilishi bo'lmasa-da, nomuhim so'zlarni olib tashlash NLP-da dastlabki ishlov berishning muhim bosqichidir.

BERTbek kontekst va foydalanish asoslarini tushunish orqali nomuhim soʻzlar roʻyxatini aniqlashtirishga yordam beradi va shu bilan quyi oqim NLP vazifalarining aniqligini oshiradi. BERTbek tegishli boʻlmagan soʻzlarni aniqlash va yoʻq qilish orqali oʻzbek tilidagi lingvistik tahlillarning yoʻnalishi va samaradorligini oshiradi.

Xulosa

Oʻzbek BERT modeli BERTbek oʻzbek tilidagi turli lingvistik vazifalarni hal qilish uchun yangi vosita hisoblanadi. Uning his-tuygʻularni tahlil qilish (sentiment tahlil), matn tasnifi, MLM va nomuhim soʻzlarni olib tashlashda qoʻllanilishi modelning moslashuvi va oʻzbekcha matnni qayta ishlash va tushunishdagi kuchini koʻrsatadi. BERTbek nafaqat lingvistik tadqiqotlar va NLP ilovalarini ishlab chiqishni olgʻa siljitadi, balki oʻzbek tilining texnologik imkoniyatlarini kengaytirishga sezilarli hissa qoʻshadi va oʻzbek tilida soʻzlashuvchilar uchun tilni qayta ishlash yanada qulay, aniq va nozik boʻlgan kelajakni vaʼda qiladi.

Foydalanilgan adabiyotlar:

1. Salaev, U. I., Kuriyozov, E. R., & Matlatipov, G. R. (2023, November). Design and Implementation of a Tool for Extracting Uzbek Syllables. In *2023 IEEE XVI International Scientific and Technical Conference Actual Problems of Electronic Instrument Engineering (APEIE)* (pp. 1750-1755). IEEE.
2. Madatov, K. (2019). A prolog format of uzbek WordNet's entries. *Human Language Technology as a Challenge for Computer Science and Linguistics*, 316-320.
3. Allaberdiev, B., Matlatipov, G., Kuriyozov, E., & Rakhmonov, Z. (2024). Parallel texts dataset for Uzbek-Kazakh machine translation. *Data in Brief*, 110194.
4. Kutlimuratova, B., Kuriyozov, E., & Tillaeva, M. (2022). TEACHING ENGLISH AS A FOREIGN LANGUAGE FOR PRIMARY SCHOOL CHILDREN: LITERATURE REVIEW. *FOREIGN LANGUAGE TEACHING AND APPLIED LINGUISTICS*, 161-171.
5. Sharipov, M., Salaev, U., & Matlatipov, G. (2021). OʻZBEK TILI FEʼL SOʻZ TURKUMI UCHUN CHEKLI AVTOMATLAR ASOSIDA STEMMING ALGORITMINI YARATISH. *COMPUTER LINGUISTICS: PROBLEMS, SOLUTIONS, PROSPECTS*, 1(1).
6. Kutlimuratova, B. (2021). Uzbek students learning English as a foreign language: Error analysis using corpora.
7. Sharipov, M., & Salaev, U. (2022). Uzbek affix finite state machine for stemming. *arXiv preprint arXiv:2205.10078*.
8. Madatov, K., Bekchanov, S., & Vičić, J. (2023). Uzbek text summarization based on TF-IDF. *arXiv preprint arXiv:2303.00461*.
9. Niyazmetova, Kumushoy & Kuriyozov, Elmurod. (2023). Oʻzbek tilidagi matnlarni sentiment tahlil qilish.