

МРНТИ16.31.21

А.Ә.Жаңабекова¹, А.А.Қаршығаева²

¹А.Байтұрсынұлы атындағы Тіл білімі институты Қолданбалы лингвистика
бөлімінің менгерушісі, филология ғылымдарының докторы.

Алматы қаласы, Қазақстан

²А.Байтұрсынұлы атындағы Тіл білімі институты Фонетика бөлімінің
ғылыми қызметкері, филология ғылымдарының кандидаты.
Алматы қаласы, Қазақстан

**МӘТИНДЕР КОРПУСЫНА ФОНЕТИКАЛЫҚ БЕЛГІЛЕНИМДЕР
ЕНГІЗҮГЕ АРНАЛҒАН НҰСҚАУЛЫҚ СИПАТТАМАСЫ
(Професор Ә.Жұнісбектің үшқадамдық ұстанымы бойынша)**

Аннотация: Мәтіндер корпусына енгізілген фонетикалық белгіленім программасы Ә.Жұнісбектің үшқадамдық жүйесі бойынша сипатталған. Бірінші –сөздің жуан/жіңішкелгіне қарай әуезін (тембр) көрсетеді. Екінші –сөзді автоматты түрде буынға бөледі және қандай буын екенін сипаттайды. Ушінші – сөз құрамындағы әрбір дыбыстың фонетикалық талданымын көрсетеді. Болашақтаорпұска енгізілген бұл фонетикалық сипаттама буынды автоматты бөле алатын программаның интернет желісінде жұмыс істеуін қамтамасыз етеді.

Макалада мәтіндер корпусына енгізілген фонетикалық белгіленім бағдарламасын жасауға арналған лингвистикалық нұсқаулыққа сипаттама беріледі. Профессор Ә.Жұнісбектің үшқадамдық нұсқаулығы басшылыққа алынып, програ-ммаға дайындалу барысы қарастырылады. Сонымен қатар лингвистикалық мәлі-меттер енгізілгеннен кейінгі фонетикалық белгіленім терезесінен скриншот беріледі.

Тірек сөздер: мәтіндер корпусы, белгіленім, фонетикалық белгіленім, фонетикалық нұсқаулық, буын, әуез

А.А. Жанабекова¹, А.А. Каршығаева²

¹заведующий отделом Прикладной лингвистики Института языкоznания имени
А. Байтұрсынова, док.филол.н., Алматы, Казахстан

²старший научный сотрудник отдела Фонетики Института языкоznания имени
А. Байтұрсынова, канд.филол.н., Алматы, Казахстан

**ОПИСАНИЕ ИНСТРУКЦИЙ ДЛЯ ВНЕДРЕНИЯ ФОНЕТИЧЕСКИХ
РАЗМЕТОК В КОРПУС ТЕКСТОВ**

Аннотация. Программа фонетической разметки, входящая в корпус текстов, описывается трехступенчатой системой А. Жунусбека. Первый показывает тембр в зависимости от твердости / мягкости слова. Второй – автоматически делит слово на слоги и описывает, какой это слог. Третий показывает фонетический анализ

каждого звука в слове. Это фонетическое описание, которое будет включено в корпус в будущем, позволит программе, которая может автоматически разделять слоги, работать в Интернете. В статье описывается лингвистическая инструкция для разработки программы фонетической разметки, внедренной в корпус текстов. На основе трехшаговой инструкции профессора А.Жунисбека рассматривается процесс подготовки к программе. А также делается скриншот окна фонетической разметки после внедрения лингвистических данных.

Ключевые слова: корпус текстов, разметка, фонетическая разметка, фонетическая инструкция, слог, тембр

A.A. Zhanabekova¹, A.A. Karshygaeva²

¹Head of the Department of Applied Linguistics, A. Baitursynly Institute of the Linguistics, Doctor of Philology, Almaty, Kazakhstan

²Senior Researcher, Phonetics Department, A. Baitursynly Institute of the Linguistics, Candidate of Philological Sciences, Almaty, Kazakhstan

DESCRIPTION OF INSTRUCTIONS FOR IMPLEMENTING PHONETIC MARKINGS INTO THE TEXT BODY

Annotation. The phonetic notation program included in the main text is described by A. Zhunisbek's three-stage system. The first shows the melody (timbre) depending on the thickness / subtlety of the word. The second one automatically divides the word into syllables and describes which syllable it is. The third shows the phonetic analysis of each sound in the word. This phonetic description, included in the future case, allows the program to run on the Internet, which can automatically separate syllables.

The article describes the linguistic instruction for the development of a phonetic markup program, embedded in the text corpus. Based on the three-step instructions of Professor A. Zhunisbek, the process of program preparation is considered. And also a screenshot of the phonetic markup window after the introduction of linguistic data is given.

Key words: text corpus, markup, phonetic markup, phonetic instruction, syllable, timbre

Мәтіндер корпусы тілдердегі әртүрлі стильдегі жазба мәтіндердің электронды түрдегі жиынтығы ғана емес, ол тіл деңгейлеріне қатысты тілдік талдауларды автоматты түрде талдау көрсететін компьютерлік бағдарламаға негізделген замануи тілдік құрал. Сондықтан корпустарға осындай автоматты талдаулар жасайтын бағдарламалар жасау керек. Ал компьютер формальді модельдерге сүйеніп қана әртүрлі амалдарды жасай алғатындығын ескерсек, онда компьютерлік бағдарламаға лингвистикалық нұсқаулықтар енгізу қажеттігі туындаиды. Олай болса, компьютер автоматты түрде тілдік талдауларды жасау мүмкіндігіне ие болу үшін тілдің әр деңгейіне сәйкес лингвистикалық әзірлемелер жасау қолданбалы бағытта лингвистикалық өнімдер дайындастырын тілші-мамандардың алдында тұрган маңызды мәселе.

Қазақ тіл білімінде қазіргі кезде XXI ғасырдың бас кезеңдерінен бастап, ұлттық корпустар жасау ісі қолға алынып келеді. А.Байтұрсынұлы атындағы Тіл білімі

институтында Қолданбалы лингвистика бөлімі де ақпараттық технология заманының талабына сәйкес ұлттық корпустар құрастыру ісіне белсенді араласып келеді. Профессор А.Құбановтың бастамасымен корпус құрастырудың әдістәсілдері, технологиясы барынша зерттеліп, А.Жұбанов және А.Жаңабековының авторлығымен «Корпустық лингвистика» оку құралы ретінде де жарық көрді. Тәжірибе жүзінде 2009 жылдардан бері лингвистикалық белгіленімдер енгізудің бағдарламалары да жасалып, біршама тәжірибе жинақталды. Бұл ретте алдымен морфология денгейінің талдаулары жүзеге асырылды. Мұндай автоматты бағдарламаны морфологиялық анализатор деп атайды. Программалық жағын информатика институтының бұрынғы ғылыми қызыметкері К.Қойбағаров жасады. К.Қойбағаровтың программалық қолдауымен және математик ері тілші-ғалым, Қолданбалы лингвистика маманы, профессор А.Жұбановтың идеяларымен лингвистикалық және экстралингвистикалық белгіленімдер кою ісі жүзеге асырылуда. Осылай лингвистикалық белгіленімдер әзірлемесін дайындауда тіл білімінің сала мандарының да білік-дағдылары қажет екендігі белгілі. Профессор Ә.Жұнісбек фонетика саласының теориялық мәселелерімен шұғылданып қана қоймай, тіл білі-мінің қолданбалы бағыттары – окулық, әдістеме, сол сияқты сөйлеу синтезі және анализі сияқты бағдарламалық жұмыстармен да айналысып отырады. Осы ретте корпусқа фонетикалық белгіленімдерді Ә.Жұнісбектің 3-қадамдық нұсқаулығына сүйеніп жасап отырмыз.

Ә.Жұнісбектің 3-қадамдық нұсқаулығында мәтіндегі сөздер үш түрлі белгісі бойынша сипатталады. Олар: сөздің әуезі, сөздерді буынға автоматты бөлу, дыбыстардың (эріпптер) фонетикалық сипаттамасы. Осы белгілер бойынша программаға тәмендегідей нұсқаулық дайындалды.

Бірінші қадам: Сөздің әуезін (тембр) көрсету. Қазақ тілінде сөздер дауысты дыбыстың жауан/жінішкелігіне қарай жуан әуезді және жінішке әуезді болып белінеді. Программа корпуста автоматты түрде сөздердің осы жуан не жінішке екенин ажырып көрсетуі қажет. Қазақ тілінде түбір сөздерге қосымшалар жалғанғанда сөз құрамындағы дауысты дыбыстың жуан/жінішкелігіне қарай жалғанады. Соған сәйкес жуан әуезді не жінішке әуезді сөз болып анықталады. Осы белгіні программа автоматты түрде ажырату үшін мынадай ереже беру керек. Егер сөздің бірінші буыннандағы (немесе сөз құрамындағы) дауысты дыбыстар жуан дауыстылар (*a, ы, ұ, о*) болса, онда бұл сөз сингормониялық тұрғыдан *жуан әуезді* болып саналады. Егер сөздің бірінші буыннандағы (немесе сөз құрамындағы) дауысты дыбыстар жінішке дауыстылар (*a, ы, ұ, о*) болса, онда бұл сөз сингормониялық тұрғыдан *жінішке әуезді* болып саналады.

Екінші қадам: Сөзді буынға бөлу және оларға сипаттама беру. Қазақ тілінде буын сөздің құрамындағы дауысты дыбыстардың санына қарай анықталады. Сөз құрамында қанша дауысты дыбыс бар, сөзде сонша буын болады. Мысалы:

Әліппе. 3 дауысты дыбыс бар, соған сәйкес 3 буын құрайды: *Ә-lin-pe*

Ана. 2 дауысты дыбыс бар, соған сәйкес 2 буын құрайды: *A-na*

Бала. 2 дауысты дыбыс бар, соған сәйкес 2 буын құрайды: *Ba-la*

Жаңбыр. 2 дауысты дыбыс бар, соған сәйкес 2 буын құрайды: *Жаң-быр*

Құттықтауды. 4 дауысты дыбыс бар, соған сәйкес 4 буын құрайды: *Құт-тық-та-ды*

Фонетика саласындағы буын теориясы ен күрделі және маңызды мәселелердің бірі деуге болады. Осыған байланысты қазақ тілінің теориялық негізін қалаушы ғалым проф. Құдайберген Жұбанов: «Қазақ тілінің табиғатын дұрыс тану үшін буын

жүйесін жете білу керек. Буынды жақсы білмесен, емлені де білмейсің: сөз тудыру, сөз түрлендіру сияқты морфология негізін де ұға алмайсың, буынды білмейінше, сөз екпіні (ударение), сөз сазы (интонация) секілді сөйлем жүйесіне қатысты тіл құбылыстарының да сырына қана алмайсың, «ајарлап сөйлеу», «әсерлеп оқу» сияқты сабактарды да дұрыс алып бара алмайсың; буын жайына қанық болмасаң, елең құрылышының негізімен дұрыс таныс бола алмайсың...» – дейді [1].

Буын құрылышын сипаттау үшін халықаралық жүйедегі дауысты/дауыссыз дыбыстың белгісін аламыз. Олар: **V(вокализм)** – дауысты дыбыстар; **C (кон-сонантизм)** – дауыссыз дыбыстар. Фонетикалық белгіленім қоюдың компьютерлік бағдарламасы дыбыстарға (эріптеге) карай буындарды аныктау үшін қазақ әліпбійндегі әріптегерді жогарыда аталған **V, C** сипатына қарайтізмделіп белгіленуі қажет. Мысалы: **A - V; Ә - V; Ы - V** т.б. Сол сияқты дауыссыз дыбыстар **P - C; Б - С; М - С** т.б.

Қазақ тілінде буынның әдетте 3 түрі бар дейміз: ашық буын, тұйық буын, бітеш буын. А.Байтұрсынұлы сөйлеу мен сөйлем, сөйлем мен сөз, сөз бен буын, буын мен дыбыс желсін бір-бірінен туындағып, арасын үзбей өзара байланыстырып қарайды. Сөздерді буынға бөлудің жолын қарастыра келіп, «Буыншы әріп басқа-лардың ортасында қамауда тұрса, ол буынға «бітеш» деп ат қойындар; буын аяғы буыншы әріпке тірелсе, ол буынға «ашық» деп ат қойындар; буын буыншыдан басқа әріпке тірелсе, ол буынға «тұйық» деп ат қойындар» деп, буын түрлерін сарапалап береді [2, 344-345 б]. Соңдағы «буыншы» әріптеріміз дауысты дыбыстар болып шығады. Буын құраудағы дауысты әріптердің мәнін «әлгі әріптер кіріспейтін буын» болмайды дейді.

Ә.Жұнісбек сөз басында келетін бір дауыстыдан тұратын ашық буынды – дауысты буын деп атайды [3]. Сөйтіп, қазақ тілінде 4 буын түрін көрсетеді: **дауысты, ашық, тұйық, бітеш**.

Буын жігін автоматты түрде табуға қатысты қазақ тіл білімінде алғаш пікір айтқан ғалым Қ.Жұбанов болды. Қ.Жұбановтың «Буын жігін қалай табуға болады?» атты мақаласында буын түрлерінің өнергін беруде дыбыс аттары мынадай қыскартылған пішінде жазылған: **Ды** – дауысты дыбыс; **Дз** – дауыссыз дыбыс; **сДЗ** – созымды дауыссыз дыбыс; **қДЗ** – қатаң дауыссыз.

Проф. Қ.Жұбанов буынның дыбыс құрамына қарай алты түрін көрсеткен.

- 1) **Ды (Г)** буыны, немесе **жалан** буын (жалғыз-ақ дауысты дыбыстан жасалады).
- 2) **Дз-Ды (СГ)** буыны, немесе **ашық** буын.
- 3) **Ды-Дз (ГС)** буыны, немесе **женіл тұйық** буын.
- 4) **Дз-Ды-Дз (СГС)** буыны, немесе **женіл бітеш** буын.
- 5) **Ды-сДЗ-қДЗ (ГСС)** буыны, немесе **ауыр тұйық** буын.
- 6) **Дз-Ды-сДЗ-қДЗ (СГСС)** буыны, немесе **ауыр бітеш** буын.

Осы келтірілген буын түрлерінің алғашқы төртеуі Қ.Жұбановтың пайымдауынша: «... қазақ тілі буындарының негізгі түрлері болып саналады.

Қ.Жұбанов жоғарыдағыдай буындардың моделі арқылы «буын жігін оңай, механик түрде табуға болады» – дейді [1, 361 б.].

Қазақ тілші-ғалымдарының буын құрамына, түрлеріне қатысты тұжырымдарын негізге ала отырып, біз корпуска енгізілетін фонетикалық белгіленім бағдарламасы үшін буын түрлерін төмендегішке сипаттаймыз (буындар қарайтылып берілген):

Дауысты буын - V (а-на, о-тан, а-та, ә-ліп-пе, е-ді, ө-мір, ы-дыс, і-ні т.б.);

Ашық буын - C+V (ба-ла, қа-ла, бөл-ме, ә-ке, са-бақ т.б.);

Тұйық буын - V+C (ақ-ша, ақ-та-ды, ар-нау, өр-ле-ді, ор-на-лас-қан);

Тұйық буын - V+C+C (ант, айт-ты);

Бітегу буын - C+V+C (бай-лық, қой-ды, бер-ді, ә-кел-ді, та-быс, ең-бек, жазды т.б.);
Бітегу буын - C+V+C+C (бұлт, қант, жалт, жырт-ты, құрт-ты т.б.);
Бітегу буын- C+C+V +C (Өз-бек-стан, Қа-зак-стан т.б.).

Программа корпуста сөздерді автоматты түрде беле алуы үшін осы буындардың тұрақты позициялық шептері туралы нұсқаулық беру керек болады. Мәселен, V дауысты буын (а-на, о-тан, а-та) тек сөз басындаған кездеседі; C+V ашық буын (са-бақ, бер-ме-ді, бөл-ме) сөздің барлық позицияларында ұшырасады; V+C тұйық буын (ақ-ша, ақ-та-ды, ар-нау) тек сөз басында тұрады; V+C+C тұйық буыны (ант, айт-ты) да тек сөз басында кездеседі; C+V+C бітегу буын(қой-ды, бер-ді, ә-кел-ді, та-быс) сөздің барлық шебінде тұра береді; C+V+C+C бітегу буын(бұлт-ты, жаң-ғырт-ты, жаз-дырт) да барлық жерде тұра береді; C+C+V+C бітегу буыны (Өз-бек-стан, Қа-зак-стан-да) сөз басында кездеспейді, сөз ортасы мен сөз сонында тұрады.

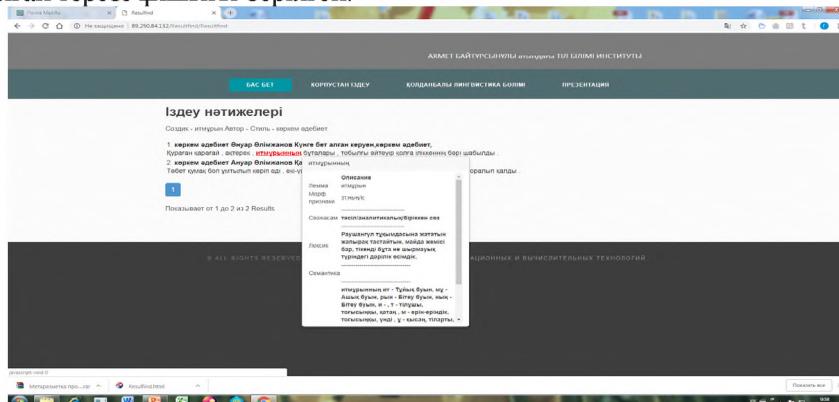
Программа осы нұсқаулық бойынша сөздерді автоматты түрде беледі. Ал қазақ тіліндегі и мен у-мен келетін кейбір сөздерді беле алмайды. Мысалы, баруы, келуі, балуан, алуан т.б. Өйткені бұл сөздерде у, и дыбыстарының алдында тұрған дауыстылар түсірілп жазылған. Егер бұл сөздер барууы, келуу, балуан, алуан болып жазылған болса, автомат мұндаиды буынға берілген нұсқаулық бойынша еркін беле алған болар еді.

Шінші қадам. Корпуска фонетикалық белгіленім енгізуден келесі фонетикалық сипаттама дыбыстардың талданымы. Ол үшін программаға әрбір дыбыстың (әріптің) тілдің, жақтың, еріннің қатысына қарай белгілері сипатталған тізім жасалады. Мысалы: А – ашық, тіларты, езулік; Ә - ашық, тілортасы, езулік; Ы – қысан, тіларты, езулік; т.б. Біз мұндаиды сипаттаманы Ә.Жұнісбектің енбегінен алғып отырмыз.

Сонымен, Ә.Жұнісбек корпусқа енгізілетін сөз құрамының фонетикалық талданымын мына түрде сипаттайық:

ӘЛПІЕ – жіңішке әуезді, ә-ліп-пе: ә – дауысты буын, ліп – бітегу буын, пе – ашық буын; ә – ашық, тілортасы, езулік; л – тілүші, жанама жуысынқы, үнді; і – қысан, тілортасы, езулік; п – ерін-еріндік, тоғысынқы, қатаң; е – құранды, тілортасы, емеурін езулік.

Төмендегі *I-суретте* корпуста жұмыс істеп тұрған фонетикалық белгіленім қойылған терезе ұшырығы берілген.



I-сурет. А.Байтурсынұлы атындағы Тіл білімі институты, Колданбалы лингвистика бөлімі жасаған Матіндер корпусындағы лингвистикалық (фонетикалық та) белгіленімдер көрсетілген терезе ұшырығы

Ұяшықтың төменгі жағында сөз фонетикалық түргыдан жоғарыда берілген Ә.Жұнісбектің үшқадамдық жүйесі бойынша сипатталған. Бірінші – сөздің жуан/жінішкелігіне қарай әуезін (тембр) көрсеткен. Екінші – сөзді автоматты түрде буынға белгендегі және қандай буын екенін сипаттайтын. Ушінші – сөз құрамындағы әрбір дыбыстың фонетикалық талданымын көрсетеді. Қорыта келгенде, корпуска енгізілген бұл фонетикалық сипаттама болашақ буынды автоматты беле алатын программаның интернет желісінде жұмыс істеуін қамтамасыз етеді. Оның арғы жағында мәтіндік (текстовой) редактордың сөздердің тасымалын тексеруге қатысты қызыметтерін жүзеге асыруға, сонымен қатар келешекте лингвистиканың көптеген қолданбалы бағыттағы мәселелерін шешуге септігін тигізбек.

ӘДЕБИЕТТЕР ТІЗІМІ:

- [1] Жұбанов Қ. Қазақ тілі бойынша зерттеулер. – Алматы: Ғылым, 1966.
- [2] Байтұрсынов А. Тіл тағылымы. – Алматы: Ана тілі, 1992.
- [3] Жұнісбек Ә. Қазақ тіл білімінің мәселелері. – Алматы: Абзат-ай, 2018.