

МРНТИ 16.21.37

**А.К. Жұбанов**

А. Байтұрсынұлы атындағы Тіл білімі институтының бас ғылыми  
қызметкері, филология ғылымдарының докторы, профессор  
Алматы, Казахстан

**ЛАТЫН ГРАФИКАСЫНА КӨШУДЕГІ ҚАЗАҚ  
ТІЛІ ӘРІПТЕРІНІҢ СТАТИСТИКАЛЫҚ ДЕРЕКТЕРИ**

**Аннотация:** Жазу мен әліпби мәселесі бір-бірімен тығыз байланысты болатындықтан, ең алдымен, әр тілдің дыбыс қорын анықтаپ, содан кейін әр дыбыстың әріптермен таңбалаша қажет болады. Жазбаша тілді аудиоза тілдің графикалық бейнесі деуге болады.

Макалада қазақ әліпбійнің кирилден латын әліпбійне көшу қажеттілігі және көшу барысында кездесетін қындықтар, сондай-ақ латын графикасына көшу жолдары туралы айтылады. Қазақ әліпбій графемаларының кездесу жиілігіне және олардың мәтіндегі қамтылу пайызына қазақ тіліндегі үш мәтіннің мысалында статистикалық талдау жүргізіледі. Қазақ әліпбійнің кирилден латын графикасына көшуі кезінде статистикалық деректер ескерілуі тиіс.

**Типек сөздер:** мәтін, латын, әліпби, әріп, тіркес, графема, фонема, орфоэпия, орфография, дыбыс қоры, генерация, жиілік, абсолютті жиілік, қатынастық жиілік, компьютер, компьютерлік бағдарлама, бағдарламалық жасақтама, ақпарат.

**А.К.Жұбанов**

главный научный сотрудник Института языкоznания имени А. Байтұрсынова,  
доктор филологических наук, профессор, Алматы, Казахстан

**СТАТИСТИЧЕСКИЕ ДАННЫЕ ОТНОСИТЕЛЬНО ПЕРЕХОДА  
КАЗАХСКОГО АЛФАВИТА НА ЛАТИНСКУЮ ГРАФИКУ**

**Аннотация.** Поскольку проблема письма и алфавита тесно связана между собой, прежде всего, необходимо будет определить звуковой фонд каждого языка, а затем маркировать каждый звук буквами. Письменный язык можно назвать графическим изображением устного языка.

В статье говорится о необходимости перехода казахского алфавита с кириллицы на латиницу и о возможных трудностях такого перехода, а также о путях перехода на латинскую графику. Проводится статистический анализ частоты встречаемости графем казахского алфавита и процентов их покрытия на примере 3-х текстов казахского языка. Статистические данные должны быть учтены при переходе казахского алфавита с кириллицы на латинскую графику.

**Ключевые слова:** текст, латиница, алфавит, буква, фраза, графема, фонема, орфоэпия, правописание, звуковой фонд, генерация, частота, абсолютная частота, частота связи, компьютер, компьютерная программа, программное обеспечение, информация.

**A.K.Zhubanov**

Chief Researcher of the Institute of Linguistics named after A. Baitursynov,  
doctor of philological sciences, professor

## **STATISTICAL DATA ON THE TRANSITION OF THE KAZAKH ALPHABET TO LATIN GRAPHICS**

**Annotation.** Since the problem of writing and the alphabet is closely related, first of all, it will be necessary to determine the sound foundation of each language, and then label each sound with letters. Written language can be called a graphic representation of the spoken language.

The article discusses the necessity of the transition of the Kazakh alphabet from Cyrillic script to Latin graphics and possible difficulties of such transition, as well as possible ways of the transition to Latin graphics. The statistical analysis of frequency of occurrence of graphemes of the Kazakh alphabet and the percent of their coverage by example of 3 written texts of the Kazakh language has been conducted. Statistical data should be taken into account in the process of the transition of the Kazakh alphabet from Cyrillic script to Latin graphics

**Keywords:** text, Latin script, alphabet, letter, phrase, graphics, phoneme, orthoepy, spelling, sound fund, generation, frequency, absolute frequency, communication frequency, computer, computer program, software, information.

Латын әліпбіне көшу, сайып келгенде, ана тіліміздің болашағын ойлап, қолданыс аясын одан әрі кеңейте түсуге мүмкіндік жасап, тіліміздің ішкі табиғи әліпбіміз арқылы жазудың қазақы айтылым (орфоэпия) мен жазылым (орфография) талаптарын жүйеге түсіру деп түсіну керек.

Шындығында, бір жазудан екіншісіне көшу халықтың осы рухани байлықтан сусындауына қосымша киындық келтіруі де мүмкін. Сондықтан әліпби мен жазу мәселесіне әлеуметтік лингвистика тұрғысынан жете назар аударған жөн. Жазу мен әліпби мәселесі бір-бірімен тығыз байланысты болатындықтан, ен алдымен, әр тілдің дыбыс қорын анықтап, содан кейін әр дыбысты әріптегмен таңбалau қажет болады. Жазбаша тілді ауызша тілдің графикалық бейнесі деуге болады. Жазудың қандай түрі болмасын олар белгілі бір таңбалар арқылы жасалады. Әліпби жасау үшін алдымен графикалық лингвистика теориясын терең танып, тілдің дыбыс жүйесіндегі фонемалардың өзіндік фонологиялық ерекшеліктеріне жете назар аударып, бөгде тілдерден енген сөздерге қатысты фонемаларды қалай таңбалau керек деген мәселелерді шешіп алу керек, одан кейін тілдің болмысын танытатын негізгі заңдылықтарын білп, тілдің табиғатына сай келетін, өзіндік дыбысталу ерекшеліктеріне көрі әсер етпейтіндей мәселелер ескерілуі керек. Жазу барысында әр әріптің өзара кездесу жиілігі де назарға алыныу тиіс деп білеміз.

Латын графикасына (таңбасына) негізделген қазақ әліпбін жасау ісінде тіліміз дыбыс жүйесіндегі төл дыбыстар мен өзге тілден енген кірме дыбыстарды жеке-жеке қарастырып, әрқайсысының өзіндік ерекшеліктері мен жазу барысында туындаітын әртүрлі заңдылықтары ескерілуі тиіс.

Әліпби өзгерту мәселесі тек кірме сөздерге ғана қатысты емес, өз тіліміздегі төл сөздерімізді де жауда кеткен олқылықтарды жөнге келтіруге көмектеседі. Адам жазу арқылы білім алады, жазу арқылы бір-бірімен байланыс жасайды. Осы жазулар бүгінгі

ұрпақтың орфөпия (айтылым) заңдылықтарын ұмытып, айтуын да, жазуын да орфография (жазылым) заңдылықтарымен жүруіне итермеледі. Осы орайда, тілміздегі әріптегерді қысқартып, компьютерге икемдеу, яғни тілміздегі бар дыбыстарды орынсыз қысқартып жіберуге де болмайтынын ескеруіміз қажет. Компьютерді тілмізге икемдеудін орнына, тілмізді компьютерге икемдегеніміз дұрыс болмайды. Олай болса, қазақ тіліндегі 28 фонеманы компьютер пернетақтасына орналастыруға әбден болады демекпіз.

Тілдің қоғаммен бірге дамып, ғылым мен техника дамыған сайын көршілес елдерден және басқа да шетелдерден жаңа сөздер кіруі арқылы да толығып отыратыны табиғи заңдылық болып табылады. Сондыктан тілміздің табиғи айтылымына қайшы келетін кемшіліктерімізден арылатын кез келді.

Қазіргі таңда латын әліпбі үлкен беделге ие болып, қолданыс аясы да, мүмкіндігі де зор екенідігін танытып отыр. Жер бетінде латын әліпбі барлық салада қолданылатыны анық. Барлық дәрі-дәрмек атаулары, математика, физика, химия формуулалары, көптеген терминдер, мамандықтарға қатысты ғылыми әдебиеттер – барлығы да латын әліпбімен байланысты екенін байқауға болады. Латын графикасын қолданатын барлық елдердің әліпбіндегі әріп саны тілдегі фонемалар санынан әлдеқайда аз болуы да оның жетістігі болып табылады.

Ғылыми қауым латын әліпбіне көшкен түркі халықтарының жағдайына да жеке зерттеу жүргізіп келеді. Осы бағытта арнайы компьютерлік бағдарлама да бар.

Жазба тілдің сөйлеу тілі сияқты практикалық және теориялық тұрғыдан аса маңызды зерттеу нысаны екені мәлім. Мысалы, акпарағты автоматты түрде өндөу мен шартты белгілермен таңбалашу (кодтау) кезеңінде сол тілдің графемаларының статистикалық сипаттамаларын білу керек болады. Графемаларды статистикалық әдіспен талдау арқылы алғынған нәтижелер баспа ісін жетілдіруде және компьютерді қазақ тілін кирилден латынға ұтымды көшу шараларында да аса қажет. Жазба тіліне тән ерекшеліктер, яғни жазба мәтіннің сандық және сапалық қатынастары қазақ тілінің әртүрлі әдеби жанрларынан орын алады.

Мақалада қазақ тілінің жазба мәтінін әріптегік (графемалық) деңгейде статистикалық әдіспен зерттеуге әрекет жасалған. Себебі, әріп – табиғи тілді жазба мүмкіндігі арқылы бейнелейтін ең бір қарапайым түрдегі көрнекі тілдік бірлік болып саналады. Зерттеу нәтижелері қазақ тілін фонологиялық және фонетикалық деңгейде тілдің морфемдік құрылымын талдау мен тілдік бірліктерді синтагматикалық тұрғыда қарастыру жағдайларында аса маңызды. Әріптегердің, әріп тіркестерінің жалпы және шептік орналасу мүмкіндіктерінің статистикасын анықтауда профессор А.Қ.Жұбановтың «Задача получения на ЭВМ частотных списков лингвистических единиц» [1] атты мақаласында көлтірілген алгоритмдік сырбасы компьютерлік программа жазуға негіз болды. Сонымен бірге, аталған автордың «К вопросу о графемной статистике казахского текста» [2] атты еңбегіндегі әріптегердің статистикасы жайлы мәліметтер де осы мақаланы жазуға ықпал етті.

Әріптегердің жиілік сөздіктерін құрастыруда қазақ тілінің үш түрлі стильдер мәтіндері зерттеу нысаны ретінде алынды. Олар:

1) М.О.Әуезовтің «Абай жолы» романы мәтіні (51290 сөзқолданыс немесе 280812 әріп);

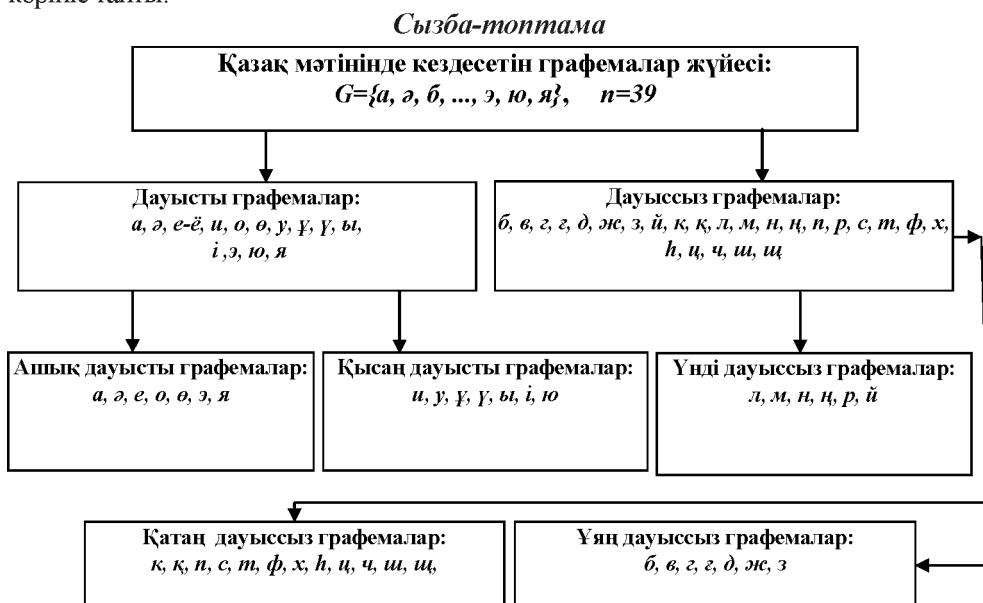
2) математика пәніне арналған мектеп оқулықтарының мәтіні (19467 сөзқолданыс немесе 130388 әріп);

3) қазақ тілінің екі томдық түсіндірме сөздігінің мәтіні (17585 сөзқолданыс немесе 116317 әріп).

Тәжірибе түрінде альянгандар мәтіндерінің тен көлемді болмауы, олардың толық түрдегі шығармалар болуымен түсіндіріледі. Соңдықтан мәтіндер ішіндегі тілдік бірліктердің (эріптердің) сандық сипаттары жайлы мәлімет алу үшін олардың катынастық жиіліктері (немесе пайыздық салмактары) пайымдалды.

Мәтін әріптегін статистикалық әдіспен талдаудан бұрын олардың графемалық құрамын анықта алған жөн. Мысалы, егер қазақ тілі әліпбійндең барлық әріптегі (графемаларды)  $G$  жиыны деп белгілесек, жиын элементтерінің саны  $n$ -те тең болады.

Зерттеу барысында мәтінде кездесетін әріптер жиынтығы топ-тобымен ірлі-ұсақты бөліктеге бөлініп (шартты түрде – дауысты, дауыссыз), сыйба-топтама түрінде көрініс тапты.



Болашақ зерттеу жоспарымызда сыйбада көрсетілген графемалар (әріппер) мен олардың түркестерінің мәтінде қолданылу мүмкіншіліктерінің статистикасы, әртүрлі стильге қатысты мәтіндер бойынша және олардың сөздегі шептік орналасу тәртібіне қарай да (сөз басында, сөз ішінде, сөз сонында) зерделенеді. Ал қазіргі ұсынып отырған мақаламызда біз тек қазақ әріпперінің белгілі қөлемдегі мәтін бойын қамту мүмкіндіктерінің пайызына байланысты ғана жайттардың статистикасына тоқталамыз.

Теменде **1-кестеде** қазақ тілінің үш стилі бойынша компьютер көмегімен түзілген қазақ әрптерінің (графемаларының) жиілік сөздігінен үзінді келтірілді. Қысқаша пайымдағанда, атапған кестеде ең жиі кездесетін графемалар олардың жиіліктерінің кему тәртібімен орналаскан. Эрі қарайғы пайымдауымызда графемалардың үш түрлі стиль бойынша түзілген жиілік сөздіктеріндегі алғашқы он орынына қатысты статистикалық мәліметтер, яғни әрбір әрптің және олардың жиынтықтарының мәтінді қамту мүмкіндіктерінің пайыздық салмақтары сөз болады. Кестедегі мәліметтерге

сүйенсек, қазақ әліпбіндегі 39 графеманың тек 10-ы ғана әр стиль бойынша алынған мәтіндердің 64-66 пайызын қамтитынын байқаймыз. Ал көркем әдебиет (роман) стилі мен ғылыми-техникалық (математика) стильде ең жиі қолданатын төрт графема ғана (*a, e-ë, ы, н*) барлық мәтіннің 35-36 пайызын қамтиды екен. Бұл жерде әмбебап дауыстылар қатарына жататын 4-ші “*i*” дауысты графема аталған стильдерде 5-ші және 6-шы орындарға (іргелес орындарға) ие болып тұр.

**1-кестедегі** сөздік мәтіні (қазақ тілінің екітомдық түсіндірме сөздігі) бойынша алынған әріптердің жиілік сөздігіндегі ең жиі қолданыстағы әріптердің алғатын орны мен статистикасы жоғарыда қысқаша қарастырылған екі стиль бойынша алынған мәліметтерден белгілі дөрежеде айырым табады. Әсіресе, сөздіктегі тұйықраймен берілген етістіктердің әсерінен «*у*» әрпінің 3-орынға ие болуы және «*қ*» әрпінен басталатын қазақ сөздерінің сөздіктегі басымдылығы бірден көзге түседі. Ал жиілік сөздіктегі алғашқы ең жиі кездесетін «*у*» мен «*қ*»-дан басқа 8 графема орналасу орындарымен ғана айырым тапканымен, мәтінді қамтудағы пайыздық салмағы жағынан айтарлықтай айырым таптайды.

Біз бұл мақалада жиілік сөздік үзіндісіндегі мәліметтермен бірге, қазақ тілінің дауысты және дауыссыз графемалар топтарының қысқаша статистикасын да беруді жөн көрдік (2-кесте және 3-кестені кара).

#### 1-кесте

Стиль-дердегі әріптің алғатын орны	Әріптердің мәтінді қамту пайызы (%)								
	Роман			Математика			Сөздік		
	Әріп аты	Әріптің %	Жиынтық %	Әріп аты	Әріптің %	Жиынтық %	Әріп аты	Әріптің %	Жиынтық %
1	а	13,2	13,2	а	11,0	11,0	а	13,0	13,0
2	е-ë	8,1	21,3	е- ë	8,3	19,3	т	7,1	20,1
3	ы	7,5	28,8	н	8,2	27,5	у	7,0	27,1
4	н	7,1	35,9	ы	7,4	34,9	е-ë	6,3	33,4
5	і	6,0	41,9	д	5,4	40,3	ы	6,1	39,5
6	т	5,0	46,9	і	5,3	45,6	р	6,0	45,5
7	р	4,8	51,7	р	5,3	50,9	л	6,0	51,5
8	д	4,6	56,3	т	5,2	56,1	с	4,5	56
9	л	4,2	60,5	л	5,1	61,2	қ	4,1	60,1
10	с	4,1	64,6	с	4,4%	65,6	н	4,1	64,2
Косындысы:		65%		66%		64%			

Сөз басында да, сонында да және ішінде де қолданыла беретін әріптерді «сөз ішіндегі» қолданыс деп шартты түрде атауды ұғардық. Міне, осындағы дауысты және дауыссыз дыбыстарды таңбалайтын графемалардың статистикасын анықтауда, олардың қатынастық жиіліктерінің стильдік (жанрлық) айырым-белгі ретінде жүрмейтіндігін **2-ші 3-ши кестедегі деректерден** аңғаруға болады. Әрине, сөздік мәтініндегі реестр сөздердің дыбыс құрамының статистикасы қындастан сөздер тізбегіндегі статистикадан аздал болса да айырым табады.

Жеке графемалардың жиілігін талдай келе, кейбір дауыстылардың және дауыссыздардың басқа графемаларға қарағанда жиі қолданатынын байқау қын емес. Оған мысал ретінде «әмбебап» дауыстылар деп аталатын (*a, e-ë, ы, і*) графемаларды

айтуға болар еді. Мұндай графемалардың мәтін ішінде қолданылуының қосынды нәтижесі: романда – 34,8%; математика – 32,0%; сөздікте – 29,0%. Егер біз қарастырған мәтіндердегі барлық дауысты графемалардың қолданылу жиілігінің пайыздық қосындысы – 43,14%; 43,19% және 44,60% екенін ескерсек, әмбебап аталатын *a, e-ё, ы, i* төрт дауысты графеманың қолданылу дәрежесін өте жоғары деп санауға әбден болады.

## 2-кесте

Дауыссыз графемалардың топтары	Дауыссыз графемалардың мәтінді қамту пайызы (%)		
	Роман	Математика	Сөздік
Үнді	22,60%	24,60%	21,20%
Қатаң	19,95%	17,71%	23,20%
Ұяң	14,31%	14,50%	11,00%
Қосындысы:	56,86%	56,81%	55,40%

## 3-кесте

Дауысты графемалардың топтары	Дауысты графемалардың мәтінді қамту пайызы (%)		
	Роман	Математика	Сөздік
Ашық	25,93%	25,27%	24,40%
Қысанқ	17,21%	17,92%	20,20%
Қосындысы:	43,14%	43,19%	44,60%

Дауыссыз графемалардың статистикасына байланысты айтатынмыз, қазақтың жазба және сөйлеу мәтіні сипатына үнді және жабысынқы-шұғыл графемалардың тән болуы. Ал шұғыл (үзілмелі) графемалар көркем әдебиет мәтінінде 23,5% тән, математика мәтінінде – 22,19 және сөздік мәтінінде 22,2 пайызға тән екен және бұндай пайыздық шамалар барлық графемалардың төрттен біріне ғана жуық деуге болады. Кейбір *ө, х, ҹ, һ, ҹҹ, ҹ, ҹ, ҹҹ, ҹҹҹ, ҹҹҹҹ* – графемалар және *ь-ъ* белгілері басқа тілдерден (орыс, араб-иран) енген кірме сөздерде ғана кездесуіне байланысты, олардың пайыздық салмағы бір пайызға да жетпелтін дәрежеде қолданылған.

1, 2, 3-кестелерде көлтірілген жеке графемалардың статистикалық мәліметтері мен келесі мақаламызда сөз болатын қазақ тілі әліпбийнің әріп тіркестерінің статистикасы латын әліпбийне көшу шаралары кезінде он әсерін тигізеді деген ниеттеміз.

## ӘДЕБИЕТТЕР ТІЗІМІ:

- [1] Джубанов А.Х. Задача получения на ЭВМ частотных списков лингвистических единиц // В кн.: Статистика казахского текста. – Алма-Ата, 1973. – С. 263-299.
- [2] Джубанов А.Х. К вопросу о графемной статистике казахского текста. В кн.: Вопросы казахской фонетики и фонологии. – Алма-Ата: Наука, 1979. – С. 49-52.
- [3] Исенгельдина А.А. Факторы, определяющие относительную частотность фонем // В кн.: Статистика казахского текста. – Алма-Ата, 1973. – С. 659-662.
- [4] Пиотровский Р.Г. Моделирование фонологических систем и методы их сравнения. –М. –Л.: Наука, 1966. – 299 с.