

Universal Multiple-Octet Coded Character Set
International Organization for Standardization
Organisation internationale de normalisation
Международная организация по стандартизации

Doc Type: Working Group Document

Title: Archaic Komi Cyrillic characters for the BMP of the UCS

Source: Michael Everson, (EGT, IE), Klaas Ruppel (Kotus, FI), Trond Trosterud (Finsk institutt, NO)

Status: Expert Contribution

Action: For consideration by JTC1/SC2/WG2 and UTC

Date: 2000-06-09

This document requests additional characters to be added to the UCS and contains the proposal summary form.

A. Administrative

1. Title

Archaic Komi Cyrillic characters for the BMP of the UCS

2. Requester's names

Michael Everson, (EGT, IE), Klaas Ruppel (Kotus, FI), Trond Trosterud (Finsk institutt, NO)

3. Requester type

Expert contribution.

4. Submission date

2000-06-09

5. Requester's reference

6a. Completion

This is a complete proposal.

6b. More information to be provided?

No.

B. Technical -- General

1a. New script? Name?

No.

1b. Addition of characters to existing block? Name?

Yes. To the Cyrillic block or possibly a new Extended Cyrillic block.

2. Number of characters

16

3. Proposed category

Category A though they are not used in current (post-1940) Komi orthography.

4. Proposed level of implementation and rationale

Level 1; no combining characters are used.

5a. Character names included in proposal?

Yes.

5b. Character names in accordance with guidelines?

Yes.

5c. Character shapes reviewable?

Yes (see below).

6a. Who will provide computerized font?

Michael Everson, EGT.

6b. Font currently available?

Yes.

6c. Font format?

TrueType.

7a. Are references (to other character sets, dictionaries, descriptive texts, etc.) provided?

Yes, see bibliography below.

7b. Are published examples (such as samples from newspapers, magazines, or other sources) of use of proposed characters attached?

Yes, see below.

8. Does the proposal address other aspects of character data processing?

Yes, see Unicode properties below.

C. Technical -- Justification

1. Contact with the user community?

Yes. The Library community (Library of Congress, ISO TC46/SC4); Kotimaisten kielten tutkimuskeskus, Helsinki; Finsk Institutt, Universitetet i Tromsø.

2. Information on the user community?

Specialists in Uralics and the Komi language, libraries.

3a. The context of use for the proposed characters?

Used to write the Komi language in the former Soviet Union, between 1919 and *ca.* 1940.

3b. Reference

See bibliography.

4a. Proposed characters in current use?

They are no longer part of current orthographies, but they are certainly found in literature and are used in library records and linguistic citations.

4b. Where?

Documents printed during the period in question.

5a. Characters should be encoded entirely in BMP?

Yes.

5b. Rationale

All Cyrillic characters should be encoded in the BMP.

6. Should characters be kept in a continuous range?

No.

7a. Can the characters be considered a presentation form of an existing character or character sequence?

No. Erroneous unifications do exist: (cf. the *ALA-LC romanization tables*).

7b. Where?

7c. Reference

8a. Can any of the characters be considered to be similar (in appearance or function) to an existing character?

No. Superficial resemblances which caused earlier unifications have been shown not to reflect actual usage and identity of these characters.

8b. Where?

8c. Reference

9a. Combining characters or use of composite sequences included?

No.

9b. List of composite sequences and their corresponding glyph images provided?

No.

10. Characters with any special properties such as control function, etc. included?

No.

E. Proposal

Komi Cyrillic characters are missing from the UCS. Document N1744 proposes the addition of 55 Cyrillic letters from ISO 10754:1996 which are not present in ISO/IEC 10646. Of those, 12 have since been added to the UCS. This proposal deals with 16 of the remaining 43 letters, which 16 were used in Komi Cyrillic orthography from 1919–ca. 1940. These letters use glyphs which differ structurally from other characters in the UCS that represent similar sounds, namely Serbian *њ* and *њ*, which are ligatures of base letters *њ* and *њ* with a palatalizing front-*yer* *њ*. Unification of *њ* and *њ* with *њ* and *њ* would imply that the other Komi letters *đ*, *ڻ*, *ڻ*, and *ڻ* could also be represented with *њ*-based glyphs, which is not supported by Komi texts using this orthography. The palatalization hook used in the Molodcov orthography is unrelated to the front *yer*.

Unification of *њ* with *њ* and *њ* with *њ* has been made in the *ALA-LC romanization tables* where the Serbian letters are given in parentheses following the Komi letters. The evidence shows this to be an error. The *ALA-LC romanization tables* also transliterate Serbian *њ* and *њ* as *lj* and *nj*, but Komi *њ* and *њ* as *l̄* and *n̄*.

Research clearly indicates that the number of Cyrillic characters in the UCS will continue to be augmented. The Current Cyrillic block does not contain enough unused positions to accept the 16 characters proposed here; accordingly, we suggest the extension of the Cyrillic block to include the next three free columns: U+0500–U+052F

Unicode Character Properties

Spacing letters, category “Lu” (uppercase), bidi category “L” (strong left to right)

0500, 0502, 0504, 0506, 0508, 050A, 050C, 050E

Spacing letters, category “Ll” (lowercase), bidi category “L” (strong left to right)

0501, 0503, 0505, 0507, 0509, 050B, 050D, 050F

Bibliography

- Barry, Randall K. 1997. *ALA-LC romanization tables: transliteration schemes for non-Roman scripts*. Washington, DC: Library of Congress Cataloging Distribution Service. ISBN 0-8444-0940-5
- Гиляревский, Р. С., & В. С. Грибнин. 1964. *Определитель языков мира по письменностям*. Москва: Наука.
- Микушев, А. К., ed. 1979. *История коми литературы*. 3 томов. Сыктывкар: Коми книжное издательство.
- Шахов, Н. А. 1924. *Краткий коми-русский словарь. С приложением статьи А. С. Сидорова „Морфологическая структура коми языка“*. Устьсыольск: Коми Издательство.

TABLE XXX - Row 05: CYRILLIC EXTENDED B

	050	051	052
0	Ԁ		
1	Ԁ		
2	Ԁ		
3	Ԁ		
4	Ԇ		
5	Ԇ		
6	Ԇ		
7	Ԇ		
8	Ӣ		G = 00 P = 00
9	Ӣ		
A	Ӣ		
B	Ӣ		
C	Ӯ		
D	Ӯ		
E	Ӯ		
F	Ӯ		

TABLE XXX - Row 05: CYRILLIC EXTENDED B

dec	hex	Name	dec	hex	Name
	00	CYRILLIC CAPITAL LETTER KOMI DE			
	01	CYRILLIC SMALL LETTER KOMI DE			
	02	CYRILLIC CAPITAL LETTER KOMI DJE			
	03	CYRILLIC SMALL LETTER KOMI DJE			
	04	CYRILLIC CAPITAL LETTER KOMI ZJE			
	05	CYRILLIC SMALL LETTER KOMI ZJE			
	06	CYRILLIC CAPITAL LETTER KOMI DZJE			
	07	CYRILLIC SMALL LETTER KOMI DZJE			
	08	CYRILLIC CAPITAL LETTER KOMI LJE			
	09	CYRILLIC SMALL LETTER KOMI LJE			
	0A	CYRILLIC CAPITAL LETTER KOMI NJE			
	0B	CYRILLIC SMALL LETTER KOMI NJE			
	0C	CYRILLIC CAPITAL LETTER KOMI SJE			
	0D	CYRILLIC SMALL LETTER KOMI SJE			
	0E	CYRILLIC CAPITAL LETTER KOMI TJE			
	0F	CYRILLIC SMALL LETTER KOMI TJE			
	10	(This position shall not be used)			
	11	(This position shall not be used)			
	12	(This position shall not be used)			
	13	(This position shall not be used)			
	14	(This position shall not be used)			
	15	(This position shall not be used)			
	16	(This position shall not be used)			
	17	(This position shall not be used)			
	18	(This position shall not be used)			
	19	(This position shall not be used)			
	1A	(This position shall not be used)			
	1B	(This position shall not be used)			
	1C	(This position shall not be used)			
	1D	(This position shall not be used)			
	1E	(This position shall not be used)			
	1F	(This position shall not be used)			
	20	(This position shall not be used)			
	21	(This position shall not be used)			
	22	(This position shall not be used)			
	23	(This position shall not be used)			
	24	(This position shall not be used)			
	25	(This position shall not be used)			
	26	(This position shall not be used)			
	27	(This position shall not be used)			
	28	(This position shall not be used)			
	29	(This position shall not be used)			
	2A	(This position shall not be used)			
	2B	(This position shall not be used)			
	2C	(This position shall not be used)			
	2D	(This position shall not be used)			
	2E	(This position shall not be used)			
	2F	(This position shall not be used)			

Group 00

Plane 00

Row XX

Annex




Figure 1. Cover of *Mуртёса да муртёстём лыddöгјас: вөзза-ныига*, by Тима Вен (V. Чисталов) (Tima Veń (V. Čistalov)), 1928 (modern orthography *Муртёса да муртёстём лыддяньяс: воддза-ныига*, by Тима Вен (V. Чисталёв) (Tima Ven' (V. Čistalëv)). (Микушев 1979)



Figure 3. Cover of „Чурка ньина“: *вит-торја драма*, by Жугыль (Žugyl'), 1928 (modern orthography „Чурка ньина“: *вит-торја драма*, by Жугыль (Žugyl')). Note the specifically Latin-shaped lower-case *d* in the subtitle. Note also the extremely reduced but connected form of the palatalization glyph in the stylized font in the main title – but note also that it does not have the form one would expect if it were a front *yer*; in which case it should show a broad square glyph like the bowl of the *P* (*cf. B* and Serbian *H* with Komi *H*). The transliteration into modern orthography is as given in Микушев 1979 which gives *нина* not *ньина* (presumably because of the palatalization inherent in the letter *u*).



Figure 4. Cover of *Кык повесть*, by Пед Ген (Ped Gen), 1936 (modern orthography *Кык повесть*, by Педъ Генъ (Ped' Gen')). Note the reduced non-front-yer form of the palatalization mark in ы, Нъ, Г, and Т. Note also the shape of capital letter дъ as in the other examples in this annex. Modern orthography writes *повесть* rather than *повесть*, transferring the palatalization to the entire consonant cluster as opposed to marking each of the consonants explicitly (as in Roman orthographic practice). (Микушев 1979)



Figure 5. Cover of *доменъён мыж*, by Издур Иван (Izjur Ivan), 1936 (modern orthography *Доменъён мыж*, by Изьюр Иван (Iz"jur Ivan)). Note the extremely reduced size of the non-yer-like palatalization stroke in нъ and compare it with the shape of the yer in ы. (Микушев 1979)



Figure 5. Cover of *Komi фольклор: важ мојдкывјас да сыланкывјас*, 1938 (modern orthography *Komi фольклор: важ мойдъяс да съыланкывъяс*). Note the very specific form of the *я*, which is clearly unrelated to the shape of the front yer *ѣ*: it is not the Serbian *ѧ* (compare it with the yer in *ы* in *мојдкывјас*). Note also the special shape of the capital *d*; this alternates with small *d*. Despite the resemblance of Latin *d* and Komi Cyrillic *d*, the capital can certainly not be unified with Latin *D*, especially because of its relation to the palatalized pair *đ* and *d*. (With regard to the transliteration of *мојдкывјас* into *мойдъяс* in modern orthography, it is as given in Микушев 1979 and is possibly a question of lexical choice, if it is not an error for *мойдкывяс*.)

Figure 6. Komi orthography as used in 1964. Additional characters for Molodcov's orthography are also identified, with the text "To the end of the 1930s the supplementary letters д, д̄, ѿ, л, нъ, г, т̄, ж, з were used." The text also notes that the Komi language had 230,000 speakers in 1964. (Гиляревский & Грибинин 1964:36)

Алфавит

Аа, Бб, Вв, Гг, Дд, Ее, Ёё, Жж, Зз, Ии, і, Йй, Кк, Лл, Мм, Нн, Оо, Ѫѫ, Пп, Рр, Сс, Тт, Уу, Фф, Хх, Цц, Чч, Шш, Щщ, ъ, ы, ь, Ээ, Юю, Яя.

В алфавите имеются дополнительные буквы

Характерны окончания

-ыс, -иc, -ic.

До конца 30-х годов употреблялись дополнительные буквы

Коми (зырянский) язык распространен в Коми АССР; на нем говорят около 230 тыс. человек. Принадлежит к финно-угорским языкам.

Figure 7. (Below and following three pages) From *Краткий коми-русский словарь*, 1924. Molodcov's orthography, introduced into Komi schools in 1919, is used here. On page iii, the alphabetic repertoire of this orthography is given (retyped with our translation following):

Для коми языка т. Молодцов установил следующие 33 буквы: а, б, в, г, д, дъ, е, ж, з, зъ, з, і, ј, к, л, лъ, м, н, нъ, о, ё, п, р, с, съ, т, тъ, у, ч, ш, щ, ы. Основою для коми шрифта послужил русский шрифт с привнесением 3-х букв (д, і, ј), из латинского шрифта. Для мягких согласных выработаны свои особые обозначения: дъ = дъ, зъ = зъ, лъ = лъ, нъ = нъ, съ = съ, тъ = тъ. Буква е произносится как русское э, щ – как тш (африкат). Для обозначения особых звуков, не имеющихся русском языке, введены буквы ж, з, ё. Первые два из них африкаты, которые приблизительно можно обозначить русскими буквами следующим образом: ж = дж; з = дзь. При произнесении ё рот уже, чем при произнесении русского э.

For the Komi language Comrade Molodcov established the following 33 letters: а, б, в, г, д, дъ, е, ж, з, зъ, з, і, ј, к, л, лъ, м, н, нъ, о, ё, п, р, с, съ, т, тъ, у, ч, ш, щ, ы. Basically the Komi script followed the Russian script with the introduction of 3 letters (д, і, ј) from the Latin script. For soft consonants Komi-specific symbols were created: дъ = дъ, зъ = зъ, лъ = лъ, нъ = нъ, съ = съ, тъ = тъ. The letter е is pronounced like э, and щ like тш (affricate). For the designation of special sounds, not found in Russian, the letters were introduced ж, з, ё. The first two of these are affricates, which can be represented approximately by Russian letters in the following manner: ж = дж; з = дзь. For the pronunciation of ё the mouth is something like the pronunciation of Russian э.

Дополнение.

Б.

бажук *ым.*—ласкательное слово.
бас—украшение; багітны — украсить,
украшать; багітчыны—наряжаться,
щеголять; багітчыс, басук—щеголь,
щеголиха.
брунган—навозный жук.

В.

вев—фон.
вежертеш *неч.*—интерес.
веслун—будничный день.
вішкины—хныкать в тихомолку.
воjkыа—северное сияние.
ворч (пож ворч)—ободок.
вöлд, вöлдja—свеже выпавший снег
(пороша).
вöрач—юркий, подвижный.
вужас—переправа через реку.

Г.

гуза—парный кому нибудь.
гулыд—гладкий, ровный.
гурјув, гурјів *в.в.*—открытый до отказу.

д.

діныш—комель.
дружка—шафер.

дъ.

давöл—дьявол.

дад—дядя.
дак— псаломщик.
дакён—дьякон.
дед—домовой; дед лычкіс—домовой душит (кошмар).
денга, сём— деньги, монета.
дерт, герт—конечно.
детіна—мальчик.
діван—диван.
дівја—не удивительно, с удовольствием.
дівö—диво.
дöб—оставшийся последний при игре.
дöгöд—деготь; дöгöдавны—намазать
дегтем.

Е.

ежа—дерн, новина (патина).

Ж.

жырñік—светильня из пропитанного
салом фитиля.

З.

запањ—запонь.
зуркыд—трэсий.
зурыд—крепкий, не поддающийся.
зыбуч—трясина.

З.

зоргыны, зöргіні *в.в.*—смотреть при-
стально.

Here we see samples from the 1924 dictionary where entries are given in a lower-case Latinski font, and the letter headings in an upper-case Bastion font. Note the distinct capital д (not Д) and the distinctly non-yer shapes of the palatalization modifier in дъ, Лъ, Нъ, Г, and Тъ.

J.

јамас—осадок, речной ил (остающийся от половодья).
јонтны—надсадить; јонтом—отдача от удара.
јёрыш—об'ем.

K.

керас—расчистка под покос или пашню.
кесjödlom—назидание, приказывание.
клонгыны—стукнуться твердым о твердое.
којзан—приспособление на ремне для привешивания топора.
којбед—охотничье копье.
крапкыны—сильно стукнуть.

L.

лапкышты—вспрыгнуть вниз.
лача—надежда; сы-вылö лачаён—надеясь на него.
лöнöд—защищенное от ветра место.

Ль.

љанöд (пу)—сыроватое дерево.
љуžгыны—идти вереницей без перевала.

M.

мајышмыны, мајітчині в.в.—маяться.
мущкыны—оседать от тяжести.

Н.

nymön—едва, чуть-чуть.

Нь.

њылöм—пот; њылöдны—пропотеть.

О.

оль—болотистый лес на берегу реки.
омра—вид растения из семейства зонтичных.

Ø.

øзын—лодочная пристань.

П.

павкöдны—убеждать.
палак вим.—льдина.
папуркі—лепешка на пресном.
парсавны—высокомерно придиরаться к кому нибудь.
петас—входы.
пік—безвыходное положение; пікё во-ны, матё воны с., пікје воni в.в.— попасть в безвыходное положение.
піла пила; пілтитны—пилить; пілтитчиg—пильщик.
пімі—длинные сапоги до бедер, сшитые из шкуры оленевых лапок; пімі в.с.— катанки.
пін—зуб, зазубрина; пінja, пінjan—десны; пін јірны—скрежетать зубами; пінтом—беззубый.
пінja, агас—борона; піновтны, пінгајны печ., с., агсавны н.в., пінавны н.—боронить.
пінласны, відчыны с.—браниться; пінавны—бранить; пінласом—ссора, ругань.
піновтчыны—скривиться.
піпу—осина.
піпöл л.—см. чельад.
піс—часть саней, служащая для установки основной поверхности саней; піст в.в.—спица колеса, также в санях.
піс—междометие, выражающее презрение.
піскі, кокач н.в., пісті—оспа; піскіавны, кокавны н.в., пістіавны—прививать оспу.
піскöдны—проколоть, проложить (дорогу); пістны—проколоться, найти дорогу.
пішщаљ—ружье.
пішöг, пішег, пі в.с.—пазуха.
племчери, драњеч н.—угорь.
пльеш, кымös н.в.—лоб.
повны—бояться, страшиться, пугаться, трусить; повтöм—бессстрашный; по-

пöч, баб—бабушка.
 празнік—праздник; празнічајтны—
 празновать.
 прок л.—см. вын.
 прöстö, вес н.—даром.
 прöчент—процент.
 пу—дерево.
 пув—брусишка; турíпув, турíмол н.—
 клюква; понпув—толокнянка.
 пуд—жребий; пудјавны, пудјасны—
 бросать жребий.
 пуд—пуд.
 пудлас—куст.
 пудовња, кадуља н.—четверик.
 пуж—заморозок, иней; пужјавны—за-
 морозить.
 пужны—засучить; пужыны—засу-
 читься.
 пузыны, пічины н.—вскипеть; пузёдны,
 пічотны н.—вскипятить.
 пукны, пукавны—сидеть; војпукём—
 посиденка, вечеринка; пукалы—
 сидящий, седок; пуксыны—сесть;
 пукгöдны—посадить.
 пуктас—овошь.
 пуктыны—поставить, положить, садить;
 дон пуктыны—назначить цену; лы-
 дö пуктыны—ставить в число, в
 счет, почитать; мінёмö пуктыны—
 ставить ни во что, презирать.
 пуктысны—работать на сенокосе, са-
 дить овощи н.в.; пуктыгöм—сенокос.
 пуль—пуля.
 пуны—варить; пюöм-пöжалöм—стрип-
 ни; пусны—свариться.
 пыльчины вым.—быстро (торопясь)
 говорить.

P.

распод—подсека, пальник.

C.

снаѓт—снасть.
 став—родовая группа.
 ставöн—все вместе; ставсö—все; став-
 ыс—все, все.
 сускiна—кедровый лес.

G.

сінны—одолеть; сінсыны—бороться.
 сінсыны—гнуться.
 гöрт—крупный лес на долинах рек.
 гöрын—с собой; гöрас бoстic—взял с
 собой.
 гурöс—основа.

T.

тагöс вым.—порог.
 тёкмар—молот из обрубка дерева с
 сучком (рукойткой).
 тёкötö—едва, чуть-чуть.
 тувкыд—упругий.
 тыöд—запруда, лиман.

Б.

тувкнітны—быстро проскользнуть.

У.

үч—верхний сноп в суслоне.
 үз—мягкий, сырватый.
 үзёдны—заранее успеть.

Ч.

чаркi—башмачек.

Ш.

шањ!—довольно, достаточно!
 швучкан тöв—резкий ветер.
 шупкысны—падать на мягкое.
 шуштöм—жутко.
 шывiна—
 шынкнітны—пройти (уйти) не ска-
 завши ни слова.
 шыпурт—меч.
 шытöв—голос.

Щ.

щапкыны—схватить, зажать; щапкыс-
 ны—ухватиться.
 щук—едва.