

Medical Knowledge Resources for Text-Mining of Health Records in Czech, Polish, and Slovak

Krištof Anetta

xanetta@fi.muni.cz

Natural Language Processing Centre

Faculty of Informatics, Masaryk University

December 10, 2022

What we want

Resekát levá mamma: resekát mléčné žlázy o rozměrech 80-79-45 mm. Ventrálně je volně pohyblivá fascie. Na řezu je mamma prostoupena hrubou fibrózou, v níž se nachází ostře ohraničené suspektní ložisko, obdobného vzhledu jako fibrosa, s patrnými prokrvácenými punkčními kanály, které má přibližné rozměry 19-20 mm. Mediální okraj je cca 5 mm, ventrální a kraniální 12 mm, kaudálně navazuje hrubá fibróza.

(fabricated text closely following the structure of a real health record)

Difficulties

- Related to the state of the art in low-resourced languages
 - No annotated biomedical corpora
 - No machine learning models for this purpose

Interim orientation

- Vocabulary text lookup needs to play a major role
- But the vocabulary concepts need to have a globally recognizable identifier so that UMLS concept connections can be leveraged

Difficulties with vocabulary lookup

- Related to health records
 - Widely varying wordings of concepts
 - Abbreviations
 - Typos
- Related to concepts
 - Specific concepts often longer than 3 words => almost never found literally in health records

Interim orientation

Many vocabularies need major pre-processing to be useful

Long vocabulary entry example

ICD-10: V30.34

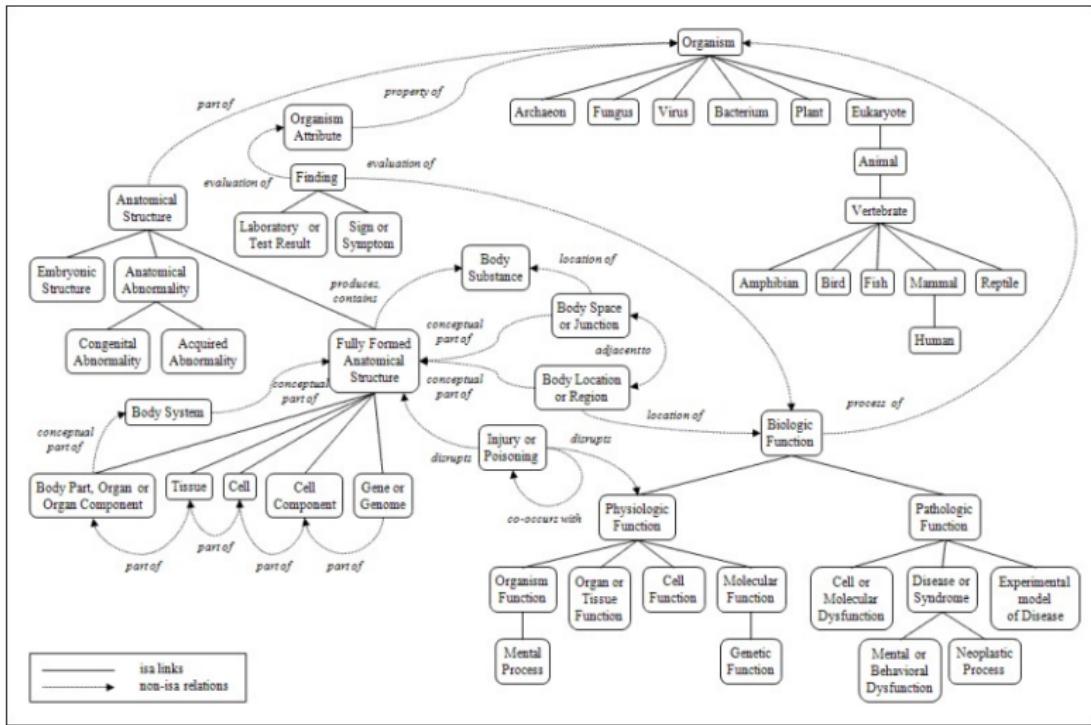
Člen osádky tříkolového motorového vozidla zraněný při srážce s chodcem nebo zvířetem; neurčený člen osádky tříkolového motorového vozidla zraněný při neprovozní (mimosilniční) nehodě; odpočinek, spánek, jídlo

UMLS: Mother of all ontologies



- 10+ million of concepts and synonyms for English and several other languages
- Interconnected through a system of unique identifiers
- Available free of charge after registration
- MRCONSO.RRF - a 2.1 GB text file with all concepts in all included languages

UMLS Semantic network



MRCONSO.RRF

C0086741 CZE S L8078046 PF S10105604 Y A26210537 10005693 MDRCZE LLT 10031133 Osmolalita 3 N
C0086743 CZE S L8067284 PF S10079911 Y A26392675 10031161 MDRCZE LLT 10049594 Deformující osteoartritida 3 N
C0086768 CZE S L15092004 PF S18357353 Y A29959395 10047430 MDRCZE LLT 10047318 Verner-Morrisonův syndrom 3 N
C0086769 CZE S L8055556 PF S10107125 N A26240463 10033664 MDRCZE LLT 10033664 Panická ataka 3 N
C0086769 CZE S L8055557 PF S10107133 Y A26330883 10033664 MDRCZE LLT 10033665 Panické ataky 3 N
C0086795 CZE S L8024981 PF S10101653 Y A33548993 10056886 MDRCZE LLT 10020470 Nemoc Hurlerové 3 N
C0086795 CZE S L8031938 PF S10097132 Y A26360753 10056886 MDRCZE LLT 10028048 MPS IH 3 N
C0086795 CZE S L8064840 PF S10120563 Y A26299620 10056886 MDRCZE LLT 10020471 Syndrom Hurlerové 3 N
C0086809 CZE S L13331630 PF S16292358 Y A29335149 10012426 MDRCZE LLT 10047907 Trichilemální cysta 3 N
C0086809 CZE S L14153574 PF S17205929 Y A28360070 10012426 MDRCZE LLT 10035034 Cysta z vlasového folikulu 3 N
C0086818 CZE S L8027570 PF S10122221 Y A15802694 10035543 MDRCZE PT 10035543 Transfuze krevních destiček 3 N
C0086839 CZE S L8042164 PF S10119465 N A26392574 10048738 MDRCZE LLT 10048738 Stav po porodu 3 N
C0086873 CZE S L16606122 PF S20089377 Y A32203573 10001764 MDRCZE LLT 10083950 Jizevnatá alopecie 3 N
C0086879 CZE S L10428486 PF S13003883 Y A26305122 10037325 MDRCZE LLT 10072345 Kapilární plicní tlak v zaklínění 3 N
C0086890 CZE P L8056545 PF S10114795 N A26423043 10037056 MDRCZE LLT 10050994 Quickův test 3 N
C0086904 CZE S L8048190 PF S10108157 N A26389540 10061858 MDRCZE LLT 10016805 Perorální náhrada tekutin 3 N
C0086904 CZE S L8063338 PF S10108158 Y A26240373 10061858 MDRCZE LLT 10031012 Perorální rehydratace 3 N
C0086922 CZE S L8056741 PF S10116469 Y A26242438 10019617 MDRCZE LLT 10052589 Revmatická purpura 3 N
C0086966 CZE S L8041909 PF S10117489 N A26214435 10067499 MDRCZE LLT 10067499 Selektivní potrat 3 N
C0086981 CZE S L8056918 PF S10117835 N A26422127 10040767 MDRCZE LLT 10042844 Sicca syndrom 3 N
C0087012 CZE S L8057074 PF S10118996 Y A32152848 10062002 MDRCZE LLT 10057660 Spinocerebelární ataxie 3 N
C0087031 CZE S L8072189 PF S10119680 N A28360087 10042061 MDRCZE LLT 10042061 Stillova nemoc 3 N

CE Slavic languages in UMLS: Numbers

Table: UMLS Metathesaurus entry counts for relevant languages

Language	Entry count	Relative size
English	11,855,838	100%
Spanish	1,839,491	15.5%
German	265,553	2.2%
Czech	212,304	1.8%
Polish	57,682	0.5%
Slovak	0	0%

CE Slavic languages in UMLS

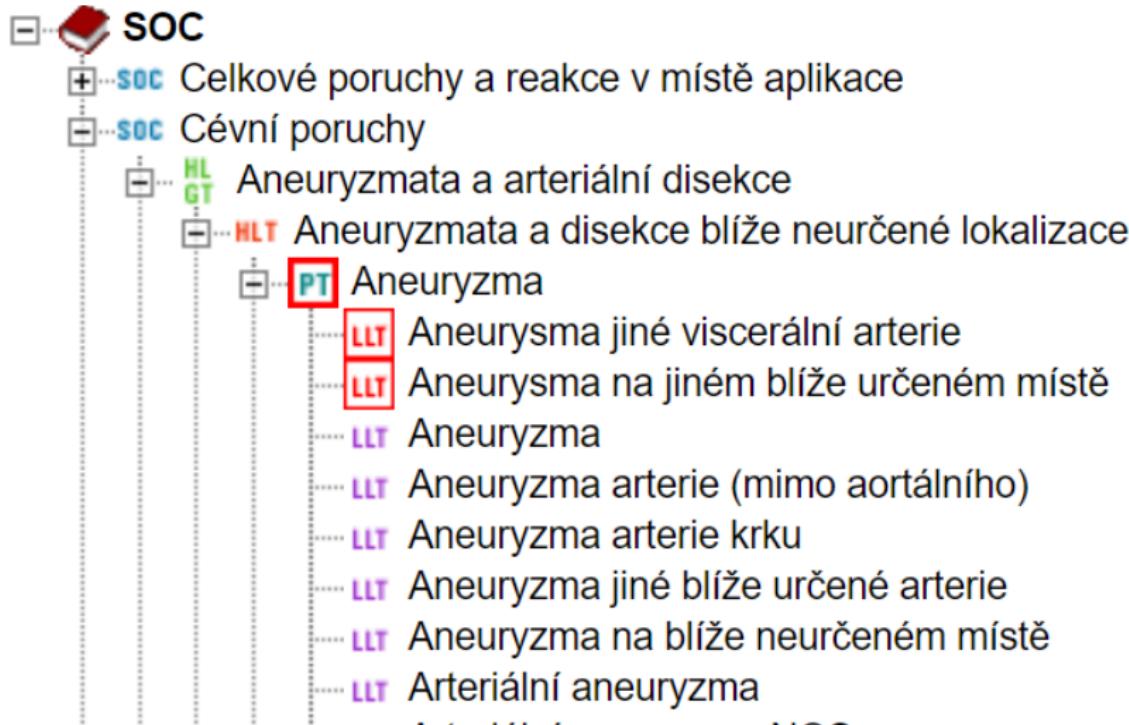


- Available for Czech (76,255 unique strings)
- Medical terminology dictionary-thesaurus (concepts related to clinical research of medicinal products)
- Avg length: 3.74 words



- Available for Czech (100,618) and Polish (53,537)
- Controlled and hierarchical vocabulary for indexing journal articles and books in life sciences
- Avg length: 2.28 words
- Czech MeSH overlap with MedDRA: 5%

Czech MedDRA



Czech MeSH

[A] **Anatomie**

[A01] tělní krajiny

[A01.378] končetiny

[A01.378.610] dolní končetina

[A01.378.610.050] kotník

[A01.378.610.100] hýzdě

[A01.378.610.250] noha (od hlezna dolů)...

[A01.378.610.400] kyčel

[A01.378.610.450] koleno

[A01.378.610.500] běrec

[A01.378.610.750] stehno

Other resources for Czech



- Most widely known medical categorization system
- 39,000+ entries
- Average length: 4.65 words
- List of registered drugs
- 63,066 entries, ca. 7,500 unique
- Easily discoverable in text, mostly 1 word, if more than in a fixed order

SÚKL databases

8949	EZETROL	10MG	TBL NOB	100
9709	SOLU-MEDROL	40MG/ML	INJ PSO LC 40MG+1M	
9710	SOLU-MEDROL	62,5MG/M	INJ PSO LC 125MG+2M	
9711	SOLU-MEDROL	62,5MG/M	INJ PSO LC 500MG+7,	
9712	SOLU-MEDROL	62,5MG/M	INJ PSO LC 1000MG+1	
9844	TORECAN	6,5MG	TBL OBD	50
10032	PIRACETAM AL	800MG	TBL FLM	60
10033	PIRACETAM AL	800MG	TBL FLM	120
10045	AGNUCASTON		TBL FLM	30
10046	AGNUCASTON		TBL FLM	60
10047	AGNUCASTON		TBL FLM	100
10052	AGNUCASTON		TBL FLM	300
10055	TABACUM	31CH-2000 GRA	4G	
10063	BROMHEXIN KM	8MG/ML	POR GTT S 1X30ML	
10073	ECHINACEA ANGUSTIFOLIA	31CH-2000 GRA	1X4G	
10087	LOBELIA INFLATA	31CH-2000 GRA	1X4G	
10111	DHC CONTINUS	120MG	TBL MRL	56

Czech ICD-10 (MKN-10)

A984	A98.4	Horečka ebola
A985	A98.5	Hemoragická horečka s renálním syndromem
A988	A98.8	Jiná určená virová hemoragická horečka
A99	A99	Neurčená virová hemoragická horečka
B00	B00	Infekce virem Herpes simplex
B000	B00.0	Herpetický ekzém
B001	B00.1	Vezikulární dermatitida, původce: virus Herpes simplex
B002	B00.2	Herpet.gingivostomat.a faryngotonzilit., původce: virus Herpes simplex
B003	B00.3	Herpetická meningitida(G02.0*), původce: virus Herpes simplex
B004	B00.4	Herpetická encefalitida(G05.1*), původce: virus Herpes simplex
B005	B00.5	Oční onemocnění, původce: virus Herpes simplex
B007	B00.7	Diseminované herpetické onemocnění, původce: virus Herpes simplex
B008	B00.8	Jiné formy herpetické infekce, původce: virus Herpes simplex
B009	B00.9	Infekční onemocnění, původce: virus Herpes simplex NS
B01	B01	Plané neštovice [varicella]
B010	B01.0	Varicelová meningitida (G02.0*)
B011	B01.1	Varicelová encefalitida (G05.1*)

Czech ICD-10 (MKN-10): Index

Level 1	Level 2	Level 3	Level 4	ICD-10
Absorpce	bílkovin, porucha	dusíkatých látek		K90.4
	glycidů, sacharidů, porucha			K90.4
	chemikálie			T65.9
	transplacentární			P04.9
		látky z výživy		P04.5

Polish in UMLS

- MeSH translation
- 53,537 unique entries, average length 2.29 words

```
)16606|MSHPOL|MH|D016606|Guzki tarczycy|3|N||  
 )18828|MSHPOL|MH|D018828|Immunoglobuliny stymulowane przez tarczycę|3|N||  
 )18828|MSHPOL|SY|D018828|Przeciwciała stymulowane przez tarczycę|3|N||  
 )13965|MSHPOL|MH|D013965|Tyroidektomia|3|N||  
 )13965|MSHPOL|SY|D013965|Wycięcie tarczycy|3|N||  
 )13966|MSHPOL|MH|D013966|Zapalenie tarczycy|3|N||  
 )13968|MSHPOL|MH|D013968|Zapalenie tarczycy podostre|3|N||  
 )13969|MSHPOL|MH|D013969|Zapalenie tarczycy ropne|3|N||  
 )13970|MSHPOL|MH|D013970|Tyroniny|3|N||  
 )13971|MSHPOL|MH|D013971|Tyreotoksykoza|3|N||  
 )13972|MSHPOL|MH|D013972|Tyretropina|3|N||  
 )13972|MSHPOL|SY|D013972|Hormon tyreotropowy|3|N||  
 )13972|MSHPOL|SY|D013972|TSH|3|N||  
 )13973|MSHPOL|MH|D013973|Tyreoliberyna|3|N||  
 )13973|MSHPOL|SY|D013973|Hormon uwalniający tyreotropinę|3|N||  
 )13974|MSHPOL|MH|D013974|Tyroksyna|3|N||  
 )13974|MSHPOL|SY|D013974|Sól sodowa lewotyroksyny|3|N||  
 )13974|MSHPOL|SY|D013974|Lewotyroksyna|3|N||
```

Polish: centralized e-Health resource

The screenshot shows a web browser window with the URL <https://rejestrymedyczne.ezdrowie.gov.pl>. The page title is "Rejestry medyczne". A red header bar contains the Polish coat of arms and the text "Rejestry medyczne". To the right, there are links for "Nie masz konta? [Utwórz je](#)" and "Zaloguj". Below the header, there are six cards representing different medical registries:

- Rejestr Produktów Leczniczych**
Rejestr produktów leczniczych (ludzkich i weterynaryjnych) zarejestrowanych na terenie RP.
[Informacje o rejestrze >](#)
[Idź do rejestru ▾](#)
- Lista Surowców Farmaceutycznych**
Lista Surowców Farmaceutycznych zarejestrowanych na terenie RP.
[Informacje o rejestrze >](#)
[Idź do rejestru ▾](#)
- Centralny Rejestr Farmaceutów**
Centralny Rejestr Farmaceutów zarejestrowanych na terenie RP.
[Informacje o rejestrze >](#)
[Idź do rejestru ▾](#)
- Rejestr Diagnostów Laboratoryjnych**
Rejestr diagnostów laboratoryjnych zarejestrowanych na terenie RP.
[Informacje o rejestrze >](#)
[Idź do rejestru ▾](#)
- Rejestr Ośrodków i Banków**
Rejestr Ośrodków Medycznie Wspomaganej Prokreacji i Banków Komórek Rozrodczych i Zarodków.
[Informacje o rejestrze >](#)
[Idź do rejestru ▾](#)
- Rejestr Systemów Kodowania**
Zbiór słowników medycznych. Ma eliminować nieporozumienia wynikające ze stosowania terminów medycznych.
[Idź do rejestru ▾](#)

Polish drug list

```
<produktLeczniczy nazwaProduktu="Edelan" rodzajPreparatu="ludzki" nazwaPowszechnieStosowana="Metasolni furoas" moc="1 mg/g" postac="krem" podmiotOdpowiedzialny="Zaklady Farmaceutyczne POLPHARMA S.A." typProcedury="NAR" numerPozwolenia="20899" wzoscPozwolenia="Bezterminowy" kodATC="D07AC13" id="100000020">
  <substancjeCzynne>
    <substancjaCzynna>Metasolni furoas</substancjaCzynna>
  </substancjeCzynne>
  <opakowanie>
    <opakowane wielosc="1" jednostkaWielkosci="tuba 15 g" kodEAN="05909991023683" kategoriaDostepnosci="Rp" skasowane="NIE" numerEu="" dystrybutorRownolegley="" id="5" />
    <opakowane wielosc="1" jednostkaWielkosci="tuba 30 g" kodEAN="05909991023690" kategoriaDostepnosci="Rp" skasowane="NIE" numerEu="" dystrybutorRownolegley="" id="6" />
  </opakowanie>
</produktLeczniczy>
<produktLeczniczy nazwaProduktu="Nalgesin" rodzajPreparatu="ludzki" nazwaPowszechnieStosowana="Naproxenum natricum" moc="275 mg" postac="Tabletki powlekane" podmiotOdpowiedzialny="Krka, d.d., Novo mesto" typProcedury="DCP" numerPozwolenia="20696" wzoscPozwolenia="Bezterminowy" kodATC="M01AE02" id="100000037">
  <substancjeCzynne>
    <substancjaCzynna>Naproxenum natricum</substancjaCzynna>
  </substancjeCzynne>
  <opakowanie>
    <opakowane wielosc="10" jednostkaWielkosci="tabl." kodEAN="05909991023744" kategoriaDostepnosci="Rp" skasowane="NIE" numerEu="" dystrybutorRownolegley="" id="8" />
    <opakowane wielosc="20" jednostkaWielkosci="tabl." kodEAN="05909991023751" kategoriaDostepnosci="Rp" skasowane="NIE" numerEu="" dystrybutorRownolegley="" id="9" />
    <opakowane wielosc="30" jednostkaWielkosci="tabl." kodEAN="05909991023768" kategoriaDostepnosci="Rp" skasowane="NIE" numerEu="" dystrybutorRownolegley="" id="10" />
    <opakowane wielosc="40" jednostkaWielkosci="tabl." kodEAN="05909991066178" kategoriaDostepnosci="Rp" skasowane="NIE" numerEu="" dystrybutorRownolegley="" id="84656" />
    <opakowane wielosc="60" jednostkaWielkosci="tabl." kodEAN="05909991023775" kategoriaDostepnosci="Rp" skasowane="NIE" numerEu="" dystrybutorRownolegley="" id="11" />
  </opakowanie>
</produktLeczniczy>
<produktLeczniczy nazwaProduktu="Nalgesin Forte" rodzajPreparatu="ludzki" nazwaPowszechnieStosowana="Naproxenum natricum" moc="550 mg" postac="Tabletki powlekane" podmiotOdpowiedzialny="Krka, d.d., Novo mesto" typProcedury="DCP" numerPozwolenia="20697" wzoscPozwolenia="Bezterminowy" kodATC="M01AE02" id="100000043">
  <substancjeCzynne>
    <substancjaCzynna>Naproxenum natricum</substancjaCzynna>
  </substancjeCzynne>
  <opakowanie>
    <opakowane wielosc="10" jednostkaWielkosci="tabl." kodEAN="05909991023782" kategoriaDostepnosci="Rp" skasowane="NIE" numerEu="" dystrybutorRownolegley="" id="12" />
    <opakowane wielosc="20" jednostkaWielkosci="tabl." kodEAN="05909991023799" kategoriaDostepnosci="Rp" skasowane="NIE" numerEu="" dystrybutorRownolegley="" id="13" />
    <opakowane wielosc="30" jednostkaWielkosci="tabl." kodEAN="05909991023805" kategoriaDostepnosci="Rp" skasowane="NIE" numerEu="" dystrybutorRownolegley="" id="14" />
    <opakowane wielosc="40" jednostkaWielkosci="tabl." kodEAN="05909991066185" kategoriaDostepnosci="Rp" skasowane="NIE" numerEu="" dystrybutorRownolegley="" id="84657" />
    <opakowane wielosc="50" jednostkaWielkosci="tabl." kodEAN="05909991023829" kategoriaDostepnosci="Rp" skasowane="NIE" numerEu="" dystrybutorRownolegley="" id="15" />
    <opakowane wielosc="60" jednostkaWielkosci="tabl." kodEAN="05909991023836" kategoriaDostepnosci="Rp" skasowane="NIE" numerEu="" dystrybutorRownolegley="" id="16" />
  </opakowanie>
</produktLeczniczy>
```

Polish ICD-10

```
<node code="A80-A89">
  <name>Wirusowe zakażenia ośrodkowego układu nerwowego</name>
  <attributes>
    <attribute name="EN">Viral infections of the central nervous system</attribute>
  </attributes>
  <nodes>
    <node code="">
      <name></name>
      <nodes>
        <node code="">
          <name></name>
          <nodes>
            <node code="A80">
              <name>Ostre nagminne porażenie dziecięce</name>
              <attributes>
                <attribute name="EN">Acute poliomyelitis</attribute>
              </attributes>
              <nodes>
                <node code="A80.0">
                  <name>Ostre nagminne porażenie poszczepienne</name>
                  <attributes>
                    <attribute name="EN">Acute paralytic poliomyelitis, vaccine-associated</attribute>
                  </attributes>
                </node>
                <node code="A80.1">
                  <name>Ostre nagminne porażenie dziecięce, wirus dziki, importowany</name>
                  <attributes>
                    <attribute name="EN">Acute paralytic poliomyelitis, wild virus, imported</attribute>
                  </attributes>
                </node>
                <node code="A80.2">
                  <name>Ostre nagminne porażenie dziecięce, wirus dziki, tubylczy</name>
                  <attributes>
                    <attribute name="EN">Acute paralytic poliomyelitis, wild virus, indigenous</attribute>
                  </attributes>
                </node>
              </nodes>
            </node>
          </nodes>
        </node>
      </nodes>
    </node>
  </nodes>
</node>
```

Slovak

← → C sukl.sk/verejne/

Index of /verejne

Name	Last modified	Size	Description
Parent Directory		-	
Firmy.csv	2022-06-01 13:23	469K	
InternetovyVydaj/	2021-02-03 09:31	-	
Zoznam_SPC_PIL/	2022-12-01 13:32	-	
Zoznam_Zdravotnickych_pomocok/	2022-12-01 14:12	-	
Zoznam_klinickeho_skusania/	2022-12-01 13:30	-	
Zoznam_liiekov/	2022-12-05 09:41	-	
Zoznam_vyrabcov_a_distributorov/	2021-03-02 06:35	-	
me/	2022-06-24 15:28	-	

Apache/2.4.41 (Ubuntu) Server at www.sukl.sk Port 443

■ Drug list

- Entries: 51,314
- Unique: 9,090

■ List of medical aids and devices

The screenshot shows the official website of the National Center for Health Information (NCZI). The top navigation bar includes links for electronic administration, statistics, registration, and statistical reports. The main content area displays the 'MEDZINÁRODNÁ KLASIFIKAČIA CHORÓB - MKCH-10' page. On the left, there are several sidebar boxes: 'PRÁVNY RÁMCE STANDARDOVACIE', 'STANDARDY ZDRAVOTNICKÉJ INFORMATIKY', 'PRACOVNÁ SKUPINA PRE STANDARDY ZDRAVOTNICKÉJ INFORMATIKY', 'STANDARDOVACIE ORGANIZÁCIE A AKTIVITY', 'MEDZINÁRODNÝ FOND A INTEROPERABILITA', 'MEDZINÁRODNÁ KLASIFIKAČIA CHORÓB - MKCH-10', and 'METODICKÉ POVKY V STANDARDOVANÉ ZDRAVOTNICKÉJ INFORMATIKE'. Below these, there are two download links: 'Medzinárodná klasifikácia chorób s účinnosťou 01.01.2023 (XLS, 6,0 MB)' and 'Výkonné zmeny účinné od 01.01.2023 (PDF, 512 kB)'.

■ ICD-10 translation

- Entries: 20,029
- Average length: 7.68 words

Slovak drug list

7931C	Caltrate D3 500 mg/1000 IU žuvacie	tbl mnd 60x500 mg/1000 IU (strip)	500 mg/1000	60
7932C	Caltrate D3 500 mg/1000 IU žuvacie	tbl mnd 90x500 mg/1000 IU (strip)	500 mg/1000	90
7933C	Caltrate D3 500 mg/1000 IU žuvacie	tbl mnd 120x500 mg/1000 IU (strip)	500 mg/1000	120
14783	CALTRATE PLUS	tbl flm 15 (fl̄.HDPE)		15
34205	CALTRATE PLUS	tbl flm 30 (fl̄.HDPE)		30
34228	CALTRATE PLUS	tbl flm 60 (fl̄.HDPE)		60
34230	CALTRATE PLUS	tbl flm 2x30 (fl̄.HDPE)		60
0372B	CALTRATE PLUS	tbl flm 90 (fl̄.HDPE)		90
87814	Calypsol	sol inj 5x10 ml/500 mg (liek.skl.hnedá)	50 mg/1 ml	5
1148E	CAMCEVI 42 mg injekčná suspenzia s	sus ijp 1x42 mg (striek.inj.napl. COC)	42 mg	1
4341A	CAMILIA	sol por 10x1 ml (obal LDPE jednodáv.)	-	10
4342A	CAMILIA	sol por 20x1 ml (obal LDPE jednodáv.)	-	20
4343A	CAMILIA	sol por 30x1 ml (obal LDPE jednodáv.)	-	30
56150	CAMPRAL	tbl ent 84x300 mg (blis.AI/PVC/PVDC)	300 mg	84
40776	CANCIDAS 50 mg prášok na infúzny	plc ifc 1x50 mg (liek.inj.skl.)	50 mg	1
40775	CANCIDAS 70 mg prášok na infúzny	plc ifc 1x70 mg (liek.inj.skl.)	70 mg	1
04784	Candesartan HCT ratiopharm 16	tbl 7x16 mg/12,5 mg (blis.PVC/PVDC/AI)	16 mg, 12,5 mg	7
04785	Candesartan HCT ratiopharm 16	tbl 14x16 mg/12,5 mg (blis.PVC/PVDC/AI)	16 mg, 12,5 mg	14

Slovak ICD-10

D50-D53	Nutričné anémie	
D50.-	Anémia z nedostatku železa	<p>Patrí sem:</p> <p>Anémia:</p> <ul style="list-style-type: none">• hypochrómna• sideropenická
D50.0	Anémia z nedostatku železa pri chronických stratách krvi	<p>Posthemoragická anémia (chronická)</p> <p>Nepatrí sem:</p> <p>Anémia zapríčinená akútnym krvácaním (D62)</p> <p>Vrodená anémia zapríčinená fetálnou stratou krvi (P61.3)</p>
D50.1	Sideropenická dysfágia	<p>Kellyho-Patersonov syndróm</p> <p>Plummerov-Vinsonov syndróm</p>
D50.8	Iná anémia z nedostatku železa	
D50.9	Bližšie neurčená anémia z nedostatku železa	
D51.-	Anémia z nedostatku vitamínu B12	<p>Nepatrí sem:</p> <p>Nedostatok vitamínu B12 (E53.8)</p>
D51.0	Anémia z nedostatku vitamínu B12 zapríčinená nedostatkom vnútorného faktora	<p>Anémia:</p> <ul style="list-style-type: none">• Addisonova• Biermerova• perniciózna (vrodená) <p>Vrodený nedostatok vnútorného faktora</p>

Conclusion

- Overall, the conceptual range of
 - the Czech resources is good thanks to MedDRA
 - the Polish resources is satisfactory
 - the Slovak resources is only usable for a narrow subset of knowledge extraction scenarios
- Due to string length, intelligent ways of looking for word clusters need to be developed
 - A probability measure based on
 - How many of the full-meaning words from the original concept are near each other? (e.g. 4 out of 6)
 - How far apart are they? (e.g. a maximum of 2 words in between)
 - Are they in the same sentence? Same grammatical function as in the original?

Thank you for your attention!

MUNI
FACULTY
OF INFORMATICS