

Megértéstámogatás: a nyelvi információ és környezete

Prószéky Gábor
proszeky@morphologic.hu

MorphoLogic
<http://www.morphologic.hu>

Pázmány Péter Katolikus Egyetem
Információs Technológiai Kar
<http://www.itk.ppke.hu>

Tartalom

- A megértés fogalmáról
- A környezet fogalmáról
- A jelentésről
- A szótárról
- A többszavas kifejezésekről
- A gépi szövegelemzésről
- A környezetről mint a gépi nyelvészet egyik kulcsfogalmáról
- A megszorítás-alapú rendszerekről
- ... és a fordításról

A megértés fogalmáról

- Megértés = (nyelvi) információ + megfelelő „méretű” környezet
- Az életben a környezet a három dimenzióból és az időből áll
- A nyelvben a tárgyalási univerzumból
- Példa:
 - Minden kutya háziállat.*
 - Minden kutya ugat.*
 - A kutya háziállat.*
 - A kutya ugat.*
- Ha valamire azt mondja valaki: „*Nem értem*”, az azt jelenti, hogy „*Nem elég a környezet*”

A környezet fogalmáról

- Szintaxis = szó a környezetében
- A szó a mondatban vagy alá- vagy fölé van rendelve más szavaknak
- ... azoknak a szavaknak, melyek a környezetét alkotják
- Következmény:
nincs szó önmagában, csak a többiek között
- A szó csak a többiek között jelenti azt, amit jelent
- Más környezetben mást jelent:
csak azért, mert más szavak vannak körülötte
- Mi van, ha nem minden ismert a környezetében?
- Nyelven kívüli-e az információ, ha ez lexikális kérdés?

A jelentésekről

- Összegyűjtjük a jelentéseket: ez (lenne) a szótár
- Jelöljük is, hogy melyik jelentés mire vonatkozik valójában?
- Nem.
- Pontosabban csak a harmadik-negyedik jelentést jelölik, de miért csak azt?
- A szótár = a szó használatának más (hasonló kultúrkörbe tartozó) emberek számára történő leírása
- Milyenek is a szótárak?

Egy szótári címszónak (és környezetének) elemzése

- Ilyenek a szótári szócikkek a nyomtatott szótárakban:

manavelins [mə'nævəlɪnz] *fn / ts*
felszerelési tárgy

Manchester ['lɪvəpu:l || -ər -] *t*

Manchester goods ['mæntʃɪstə
tex pamutárúk, pamutszövetek

man-child *fn tsz* **-children** fiúgy

- Kérdés: kinek készül a szótár?
- Válasz: akinek a fejében ott a teljes szövegkörnyezet
- Ilyen eddig csak az ember volt: a kocsit is csak a ló húzhatta - egészen az autó feltalálásáig!

A szótár kifordításáról

- Szótár-kifordítás: egyirányú szótár „környezettel”
- Ez a környezet a jelentések mentén alakul, nem az ábécérend mentén
- A hasonló szavak „tere” is környezet
- A többszavas kifejezések több helyről „szedendők össze”
- Többszavas kifejezések: idiómák, kollokációk, -izmusok

A többszavas kifejezések felismerésének problémája

- Mi „szokott” mivel együtt járni?
- Együtt gyakoribb, mint külön (kölcönös információ)
- A webkorpusz segít (korábban ilyen nem volt)
- Kell-e hozzájuk morfo-szintaktikai leírás?
- Történetileg alakultak ki: együtt állnak – és kész!
- Aadekvát (szinkron) nyelvészeti leírásuk:
a konstrukció
- A pszichológusok ezt eddig is ismerték:
Gestalt
- Pszicholingvisztika:
egészleges és analitikus hozzáférés
- Mesterséges intelligencia:
a forgatókönyv magasabb szintű leírásai

Az aktuális elemzés mélységéről

- Miért akar a nyelvészet „lemenni” elemzéskor a legalsó szintre is?
- A nyelvi elemzés „granularitása” más a mondatszerkezetben, mint az etimológiában
- Példák:
 - Ki „hallja meg” ma a katonai szakkifejezéseket a viták szóhasználatában? Pl. „állást foglal”, „ütközteti a véleményeket”, „védekezés”, „lefedgyverző”, ...
 - Korpusznyelvészeti evidencia: a melléknévi igeneves szerkezetek sokkal kevesebb bővítményt tartalmazhatnak, mint ugyanezek az igék állítmányi szerepben

A nyelvi információ környezetei – a gépi nyelvészet szemszögéből

- A nyelvi környezet:
konkrét, „megfogható”
- A 3D-környezet:
konkrét, gépen kívüli
- Az időbeli környezet:
konkrét, „megfogható, ha kell”
- A világismereti környezet:
általános, részben modellálható
- A kulturális környezet:
általános, még ember számára is nehezen modellálható
(pl. japán meghívás)

Ami géppel modellálható

- A világismeret egy része
- A pragmatikai viselkedés egy része
- A nyelvi környezet viszont teljesen!
- Eddig még nem volt ilyen (!), ui. „valaki más” is ugyanazt látja, mint az adott kommunikációs helyzetben levő ember
- Ott a képernyőn az a szöveg, amit én is meg szeretnék érteni, és a gép is

A környezet felismerése más ismert környezetek alapján

- A gépi tevékenység: a keresés
- Ismét a korpusznyelvészet
- Nyelvi anyagban keresünk: nyelvi intelligencia kell
- Melyik szöveg hasonló – és miért?
- Mértékek a hasonlóságra
- Webes keresés, fordítómemóriabeli keresés



A megértés kulcsai


- A keresés technikai megvalósítása
- Az adott nyelv ismerete (bár olykor anyanyelvünkön is toleránsnak kell lennünk)
- A szótárban való keresés egyedi tulajdonságai
- Tudni kell, hogy amit találunk, az akkor és ott adekvát-e, „ahonnan” és „amikor” keressük (az aktuális környezetből)
- Tehát a kiinduló szöveg interakcióba lép a mi statikus(nak gondolt) tárunkkal

Intelligens szótárak: „környezettárak”


- Speciális belső reprezentációt igényelnek
- Az alszócikkek szerepe a dinamikus szócikk-építésben
- Többszörös keresés: a keresendő szót tartalmazó kifejezések más címszóban is előfordulhatnak (a szónak sokféle környezete lehet!)
- Tövesítve keresünk: egy jó szótárban ugyanis lényegesen több a ragozott szó, mint a ragozatlan (!)

Példák a környezetérzékeny szótár viselkedésére

By 'significant' words
there are **also** 'r'
skipped when fo



Also sprach



Neumann János
születésnapját
alkalom arra, h
körben megism
tudós életútját
élő hatását.

Neumann János
született Budap
amikor Ferenc
nemesi rangot adott a családjának.

Apja, dr. Ma
anyagi jólét
alapotat biz
elsősülött
fiúnak, Mikl
nyugszik az
Amerikában a
élete ezen a néven ismeri.

Akadémiai MoBiMouse Plus

rangot

- nemesi rang** noble rank, nobility
- rang** (-ot, -ja) *fn* rank, grade, degree, *hajó* rating, [*társadalmi*] place, standing, status, state, station, position

Mondatjelentés: szavak környezetekkel

- Kifejezések fordítása minden mondatbeli szóra
- Egy k hosszú mondatban mind a k szónak a többi $k-1$ szó a környezete
- A szavak nem feltétlenül literálisan értendők, olykor jelentésbesorolásuk, szófajuk is elegendő
- Szedjük össze ezeket a részfordításokat, és „rakjuk őket egymásra”

Megszorítások: a környezet használata

- Az informatikában jó ideje jelen van a „constraint” alapú gondolkodás (pl. szakértő rendszerek)
- A nyelvoktatásban:
 - „ez és ez a szerkezet azt jelenti, hogy X, mert az angol (francia, ...) így mondja
 - meg kell tanulni az anglicizmusokat (x-izmusokat), kifejezéseket, idiómákat!”
- Most pedig a szövegek megértésének modellálásában jelenik meg a megszorítás

Megszorítások használata a gépi nyelvészeti

- Karlsson „Constraint Grammar”-ja
- A konstrukciós nyelvtanok
- Koskenniemi kétszintes morfológiája
 - Környezetfüggőség és megszorítás:
 - (a) leíró nyelvészeti szabadság (CS-szabályok) és
 - (b) hatékony számítógépes megvalósítás (reguláris kifejezések)
- Kulcs: a lokális környezet és az általános környezet különbségének felismerése

Mi tehát a fordítás?

- ➔ A mondat jelentése egy másik nyelv szavaival kifejezve
- ➔ Fordítás = megértés + ennek a kifejezése egy másik formalizmusban
- ➔ A számítógéppel való fordítást vissza lehet tehát vezetni E. Bach „rule-to-rule” hipotézisére
- ➔ Ezt eddig csak a logikai szemantika szintaktikai szabályokhoz rendelésénél használták
- ➔ Minden szerkezetnek megvan a maga fordítása: ez a (kissé általánosított) szótár
- ➔ A mondat fordítása a részszerkezetek fordításainak egy függvénye
- ➔ A kifejezés jelentése pedig tényleg annak használati szabálya

Példa: a megszorításos gépi fordítás menete

```

1---2----3---4----5-----6--7-----8
Jim does not sink money in anything.
1--
Jim
  2----
  tesz
    3---
    nem
      4-----
      sülyyed
      süllyeszt
    2----3---4----
    nem sülyyed
    nem süllyeszt
      5-----
      pénz
        7-----
        bármi
          4----5-----6--7-----
          befektet pénzt bármibe
          4----5-----
          pénzt süllyeszt el
          befektet pénzt
            2----3---4----5-----
            nem fektet be pénzt
            2---3---4---5-----6--7-----
            nem fektet be pénzt semmibe
1---2---3---4---5-----6--7-----8
Jim nem fektet be pénzt semmibe.

```

Példa: a megszorításos gépi fordítás a gyakorlatban

Time flies like an arrow.

MoBiCAT 

 **Time flies like an arrow.**

 Az idő repül mint egy nyíl.

 Időzits legyeket mint egy nyíl.

 Az időlegyek kedvelnek egy nyilat.

Visszajelzés: F2

Samuel Johnson was six feet tall, clumsy, partially blind and deaf, leading many people to mistake him.

MoBiCAT 

 **Samuel Johnson was six feet tall, clumsy, partially blind and deaf, leading many people to mistake him.**

 Samuel Johnson hat láb magas volt, ügyetlen, részben vak és süket volt, miközben sok embert készített arra, hogy félreismerje őt.

Visszajelzés: F2

A(z informálisan) javasolt/megvalósított modellek összefoglalása

- **Szótármodell**
ami dinamikus, azaz az aktuális környezetre érzékeny
- **Fordításmodell**
ahol a fordítás a forrásnyelvi rész-szerkezetek fordításainak függvénye
- **Nyelvmodell**
amelyben az ábécé nyílt halmaz, és megoldja az ismeretlen szavak kezelésének problematikáját

