EESTI
KEELE
INSTITUUT

Näitelausete korpuspõhine automaattuvastus

Kristina Koppel, vanemarvutileksikograaf
Eesti Keele Instituut | EKI

LV Veski päev „Mitmekesistuv eesti keel“
27. juuni 2022

Doktoritöö

Koppel, Kristina (2020). Näitelausete korpuspõhine automaattuvastus eesti keele õppesõnastikele. (Doktoritöö, Tartu Ülikool). Tartu: Tartu Ülikooli Kirjastus.

Juhendajad: Jelena Kallas, PhD (EKI), Raili Pool, PhD (TÜ)

Teema sünd

„Eesti keele naabersõnade“ sõnastiku baasi täisautomaatne genereerimine 2014. aastal

- B2–C1 keeleoskustasemel eesti keele õppijale
- Kogu sõnastiku sisu tekstikorpusest sõnastikusüsteemi
    - Märksõnad
    - Kollokatsioonid
    - Sagedus
    - **Näitelaused**

→ Järeltoimetamine

Korpusleksikograafia ja automaatne leksikograafia

Töö põhilised eesmärgid

- Välja selgitada hea näitelause formaalsed parameetrid eesti õppesõnastikele
- Luua meetod eesti keele jaoks, mis valib korpusest välja eri keeleoskustasemetele sobivaid autentseid lauseid
- Luua tasemekohaseid lauseid sisaldav õppekorpus
- Evalveerida automaatselt valitud näitelausete kvaliteeti
- Rakendada õppekorpust keeleõppekeskkonnas SkELL ja keeleportaalis Sõnaveeb

Analüüsimaterjal

Eesti Keele Instituudis koostatud **sõnastikud**:

- "Eesti keele põhisõnavara sõnastik" (2014)
- "Eesti keele sõnaraamat 2019"
- "Eesti keele naabersõnad 2019"

Korpused:

- "Eesti keele A1−C1 õpikute korpus 2018"

Testimiseks:

- "Eesti keele ühendkorpus 2013"
- "Eesti keele ühendkorpus 2017"

Uurimismeetod

Reeglipõhine lähenemine: GDEX ehk **G**ood **D**ictionary **EX**amples

1. Funktsioon Sketch Engine'is
2. Keskmes universaalne reeglipõhine valem, mida on täiendatud keelespetsiifiliste parameetritega (lause pikkus, sõnade sagedus korpuses, märksõna asukoht, märksõna kordumine jm)
3. Töötab "sõelana": sorteerib välja sobimatud kandidaadid ja reastab ülejäänud paremuse järjekorda
4. Hindab parameetrite abil korpuslause komponente ja määrab igale lausele **skoori**

Rank	Sentence	Score
1	Ettekannetega esinesid mõlema kõrgkooli üliõpilased.	0.99
2	Toimusid mitmed huvitavad ettekanded ja kontserdid.	0.98
3	Alustan oma ettekannet inimeste arvamustest.	0.98
4	Ma ei lahkunud enne oma ettekande ega küsimuste lõppu.	0.97
5	Ma tänan teid veel kord põhjalike ettekannete eest!	0.97
6	Ettekandeks on sõna justiitsministril.	0.95
7	Praktilisi ettekandeid ja töötube jätkus pikaks päevaks, kasulikke näiteid sai pea iga aine õpetaja.	0.95

GDEXi poolt pakutud näitelause kandidaadid lemmale *ettekanne*.

Tulemused

6 konfiguratsioonifaili:

- GDEX 1.2
- GDEX 1.3
- **GDEX 1.4**
- etBasic-v1
- etIndependent-v1
- etProfocient-v1

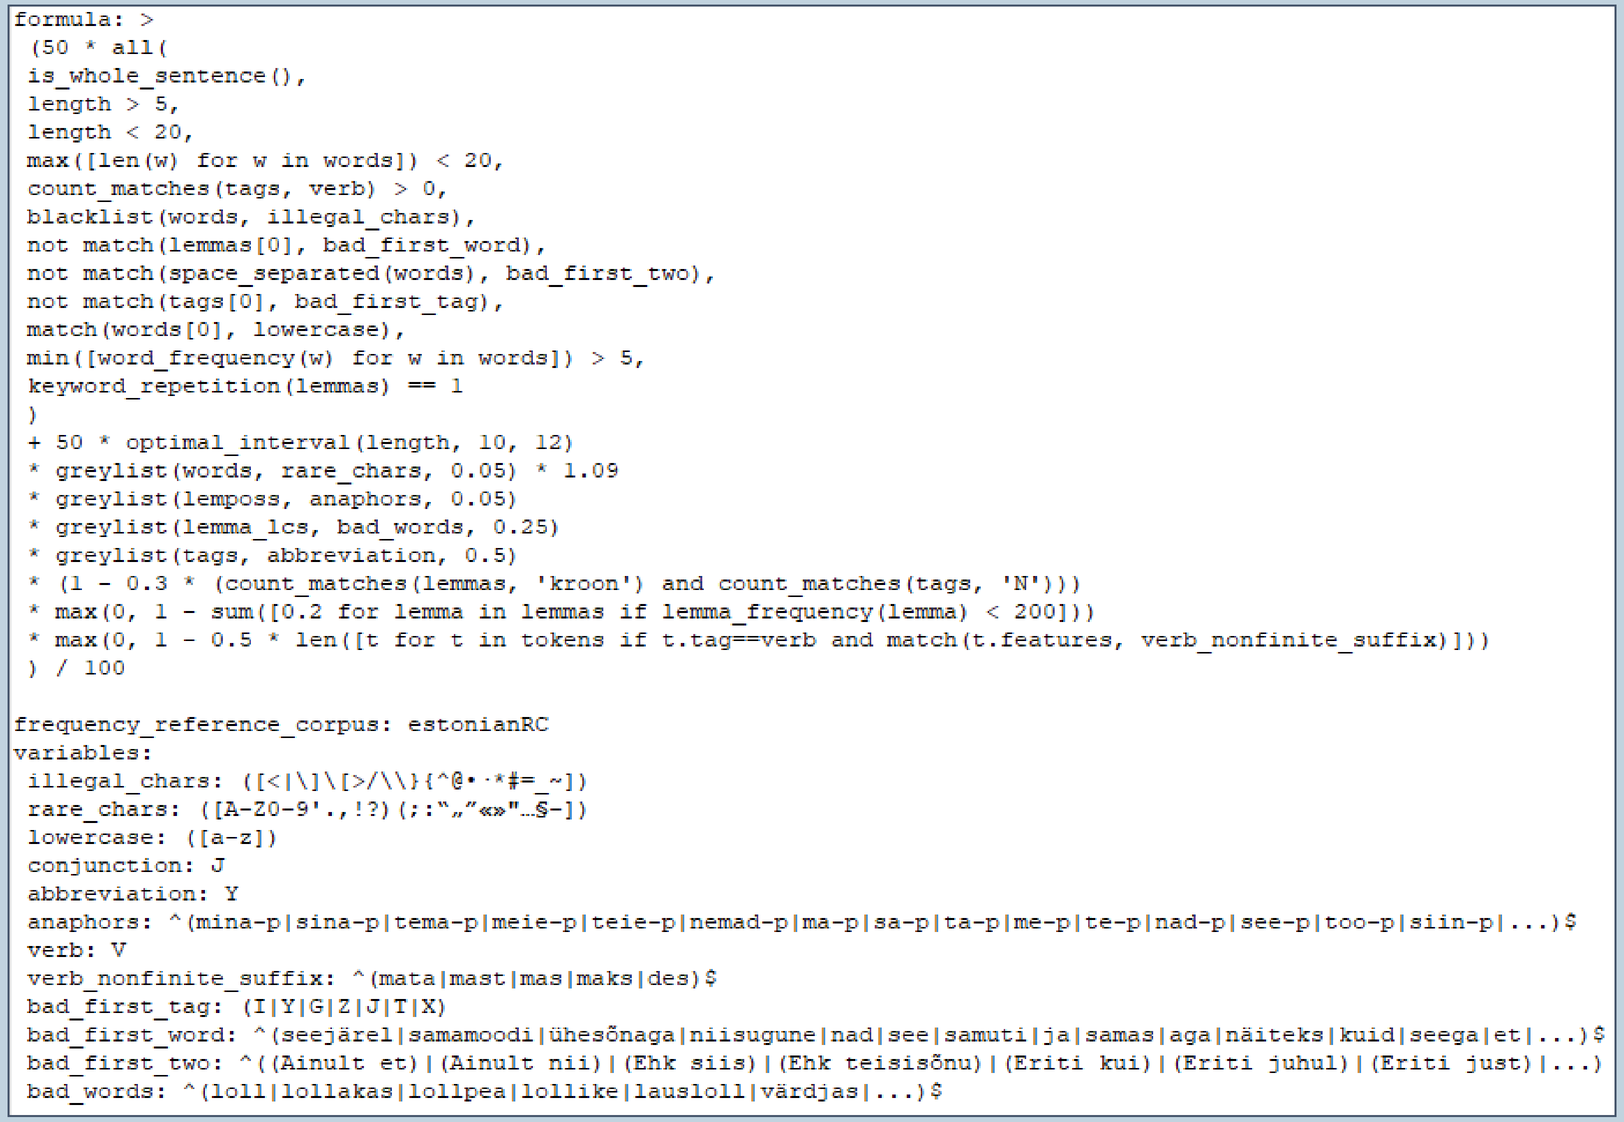

```
formula: >
 (50 * all(
 is_whole_sentence(),
 length > 5,
 length < 20,
 max([len(w) for w in words]) < 20,
 count_matches(tags, verb) > 0,
 blacklist(words, illegal_chars),
 not match(lemmas[0], bad_first_word),
 not match(space_separated(words), bad_first_two),
 not match(tags[0], bad_first_tag),
 match(words[0], lowercase),
 min([word_frequency(w) for w in words]) > 5,
 keyword_repetition(lemmas) == 1
 )
 + 50 * optimal_interval(length, 10, 12)
 * greylist(words, rare_chars, 0.05) * 1.09
 * greylist(lemposs, anaphors, 0.05)
 * greylist(lemma_lcs, bad_words, 0.25)
 * greylist(tags, abbreviation, 0.5)
 * (1 - 0.3 * (count_matches(lemmas, 'kroon') and count_matches(tags, 'N')))
 * max(0, 1 - sum([0.2 for lemma in lemmas if lemma_frequency(lemma) < 200]))
 * max(0, 1 - 0.5 * len([t for t in tokens if t.tag==verb and match(t.features, verb_nonfinite_suffix)]))
 ) / 100

frequency_reference_corpus: estonianRC
variables:
 illegal_chars: ([<|\]\[>/\\}{^@•·*#=_~])
 rare_chars: ([A-Z0-9'.,!?)(;:"„”«»"…§-])
 lowercase: ([a-z])
 conjunction: J
 abbreviation: Y
 anaphors: ^(mina-p|sina-p|tema-p|meie-p|teie-p|nemad-p|ma-p|sa-p|ta-p|me-p|te-p|nad-p|see-p|too-p|siin-p|...)$
 verb: V
 verb_nonfinite_suffix: ^(mata|mast|mas|maks|des)$
 bad_first_tag: (I|Y|G|Z|J|T|X)
 bad_first_word: ^(seejärel|samamoodi|ühesõnaga|niisugune|nad|see|samuti|ja|samas|aga|näiteks|kuid|seega|et|...)$
 bad_first_two: ^((Ainult et)|(Ainult nii)|(Ehk siis)|(Ehk teisisõnu)|(Eriti kui)|(Eriti juhul)|(Eriti just)|...)
 bad_words: ^(loll|lollakas|lollpea|lollike|lausloll|värdjas|...)$
```

GDEXi konfiguratsioonifail

Eesti keele õppekorpus 2018 (etSkELL)

- Sisaldab GDEXi abil filtreeritud lauseid eesti keele ühendkorpusest 2017

Tulemuste evalveerimine

1. Hindajad: EKI leksikograafid ja TÜ/TLÜ üliõpilased
2. Andmestik: 40 juhuslikku märksõna, 160 juhuslikku lauset
    - juhuslik GDEX 1.4 parameetritele vastav korpuslause
    - juhuslik GDEX 1.4 parameetritele mittevastav korpuslause
    - juhuslik filtreerimata korpuslause
    - juhuslik "Eesti keele sõnaraamatu 2019" näitelause
3. Tulemused:
    1. 96% sõnastiku näitelausetest hinnati sobivaks
    2. **85% GDEX 1.4 parameetritele vastavatest korpuslausetest hinnati sobivaks**
    3. 94% GDEX 1.4 parameetritele mittevastavatest korpuslausetest hinnati sobimatuks
    4. 60% filtreerimata korpuslausetest hinnati sobimatuks

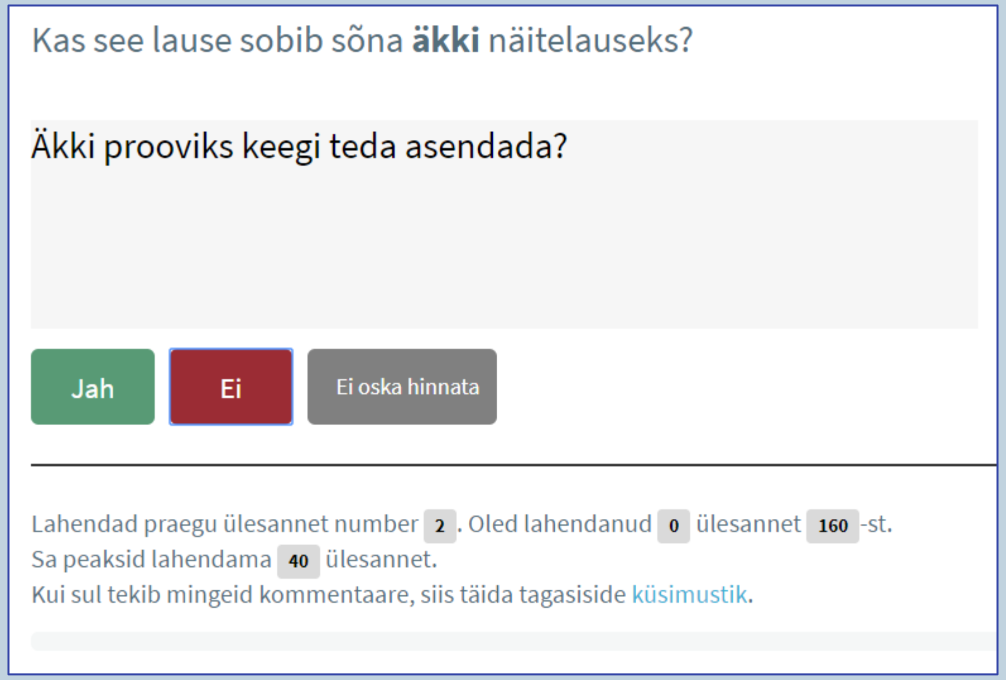

Kas see lause sobib sõna **äkki** näitelauseks?

Äkki prooviks keegi teda asendada?

Lahendad praegu ülesannet number 2. Oled lahendanud 0 ülesannet 160-st.
Sa peaksid lahendama 40 ülesannet.
Kui sul tekib mingeid kommentaare, siis täida tagasiside küsimustik.

Lause hindamine Pybossa platvormis

EESTI
KEELE
INSTITUUT

Rakenduslik väljund I

[SkELL](#) ehk Sketch Engine for Language Learning

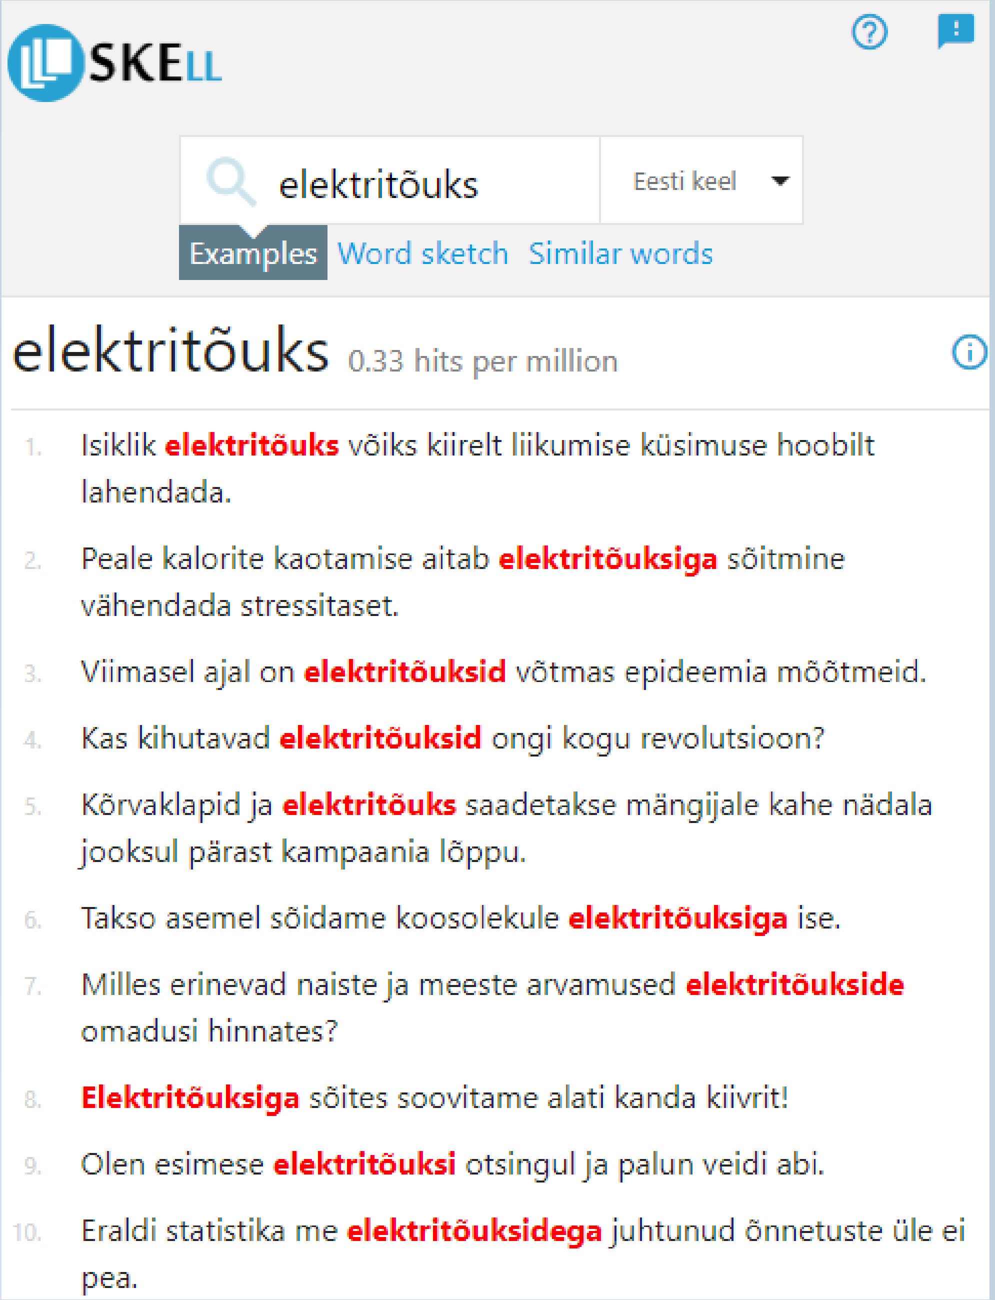

elektritõuks 0.33 hits per million

1. Isiklik **elektritõuks** võiks kiirelt liikumise küsimuse hoobilt lahendada.
2. Peale kalorite kaotamise aitab **elektritõuksiga** sõitmine vähendada stressitaset.
3. Viimasel ajal on **elektritõuksid** võtmas epideemia mõõtmeid.
4. Kas kihutavad **elektritõuksid** ongi kogu revolutsioon?
5. Kõrvaklapid ja **elektritõuks** saadetakse mängijale kahe nädala jooksul pärast kampaania lõppu.
6. Takso asemel sõidame koosolekule **elektritõuksiga** ise.
7. Milles erinevad naiste ja meeste arvamused **elektritõukside** omadusi hinnates?
8. **Elektritõuksiga** sõites soovitame alati kanda kiivrit!
9. Olen esimese **elektritõuksi** otsingul ja palun veidi abi.
10. Eraldi statistika me **elektritõuksidega** juhtunud õnnetuste üle ei pea.

Näitelaused

elektritõuks

automobiil kõnnikepp laadimispistik jooksuking laadimisjuhe nibin šokolaadivabrik Nibin-nabin nibin-nabin hobukaarik pisimopeed pulmakink mikker telksaun pöidlaküüt lapsekäru rattakiiver lastevanker välihospidal suusaprill hiirematt msi puutepliiats laadimiskarp sahtlikapp tõuks torbik surfilaud mant surfivarustus

Tesaurus

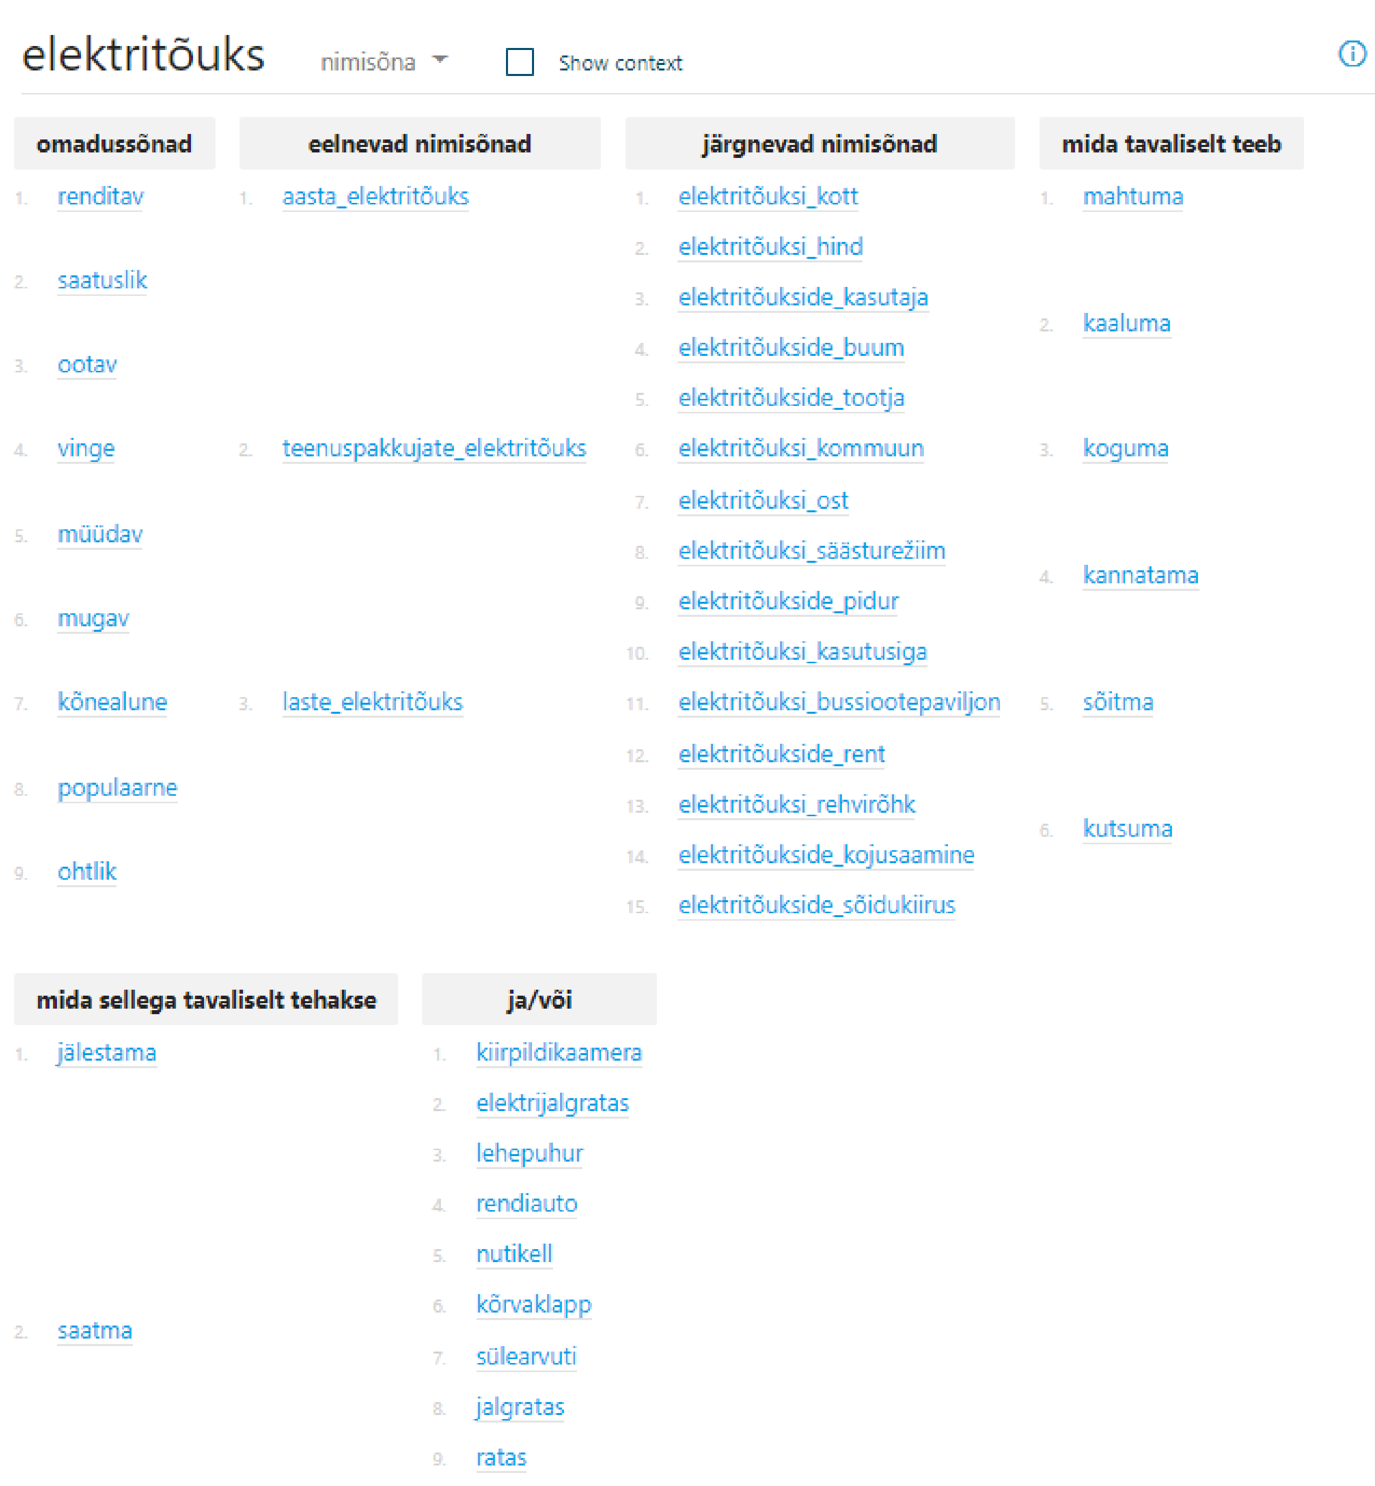

elektritõuks

omadussõnad

1. renditav
2. saatuslik
3. ootav
4. vinge
5. müüdav
6. mugav
7. kõnealune
8. populaarne
9. ohtlik

eelnevad nimisõnad

1. aasta_elektritõuks
2. teenuspakkujate_elektritõuks
3. laste_elektritõuks

järgnevad nimisõnad

1. elektritõuksi_kott
2. elektritõuksi_hind
3. elektritõukside_kasutaja
4. elektritõukside_buum
5. elektritõukside_tootja
6. elektritõuksi_kommuun
7. elektritõuksi_ost
8. elektritõuksi_säästurežiim
9. elektritõukside_pidur
10. elektritõuksi_kasutusiga
11. elektritõuksi_bussiootepaviljon
12. elektritõukside_rent
13. elektritõuksi_rehvirõhk
14. elektritõukside_kojusaamine
15. elektritõukside_sõidukiirus

mida tavaliselt teeb

1. mahtuma
2. kaaluma
3. koguma
4. kannatama
5. sõitma
6. kutsuma

mida sellega tavaliselt tehakse

1. jälestama
2. saatma

ja/või

1. kiirpildikaamera
2. elektrijalgratas
3. lehepuhur
4. rendiauto
5. nutikell
6. kõrvaklapp
7. sülearvuti
8. jalgratas
9. ratas

Sõnavisandid

Rakenduslik väljund II

Veebilaused
Sõnaveebis

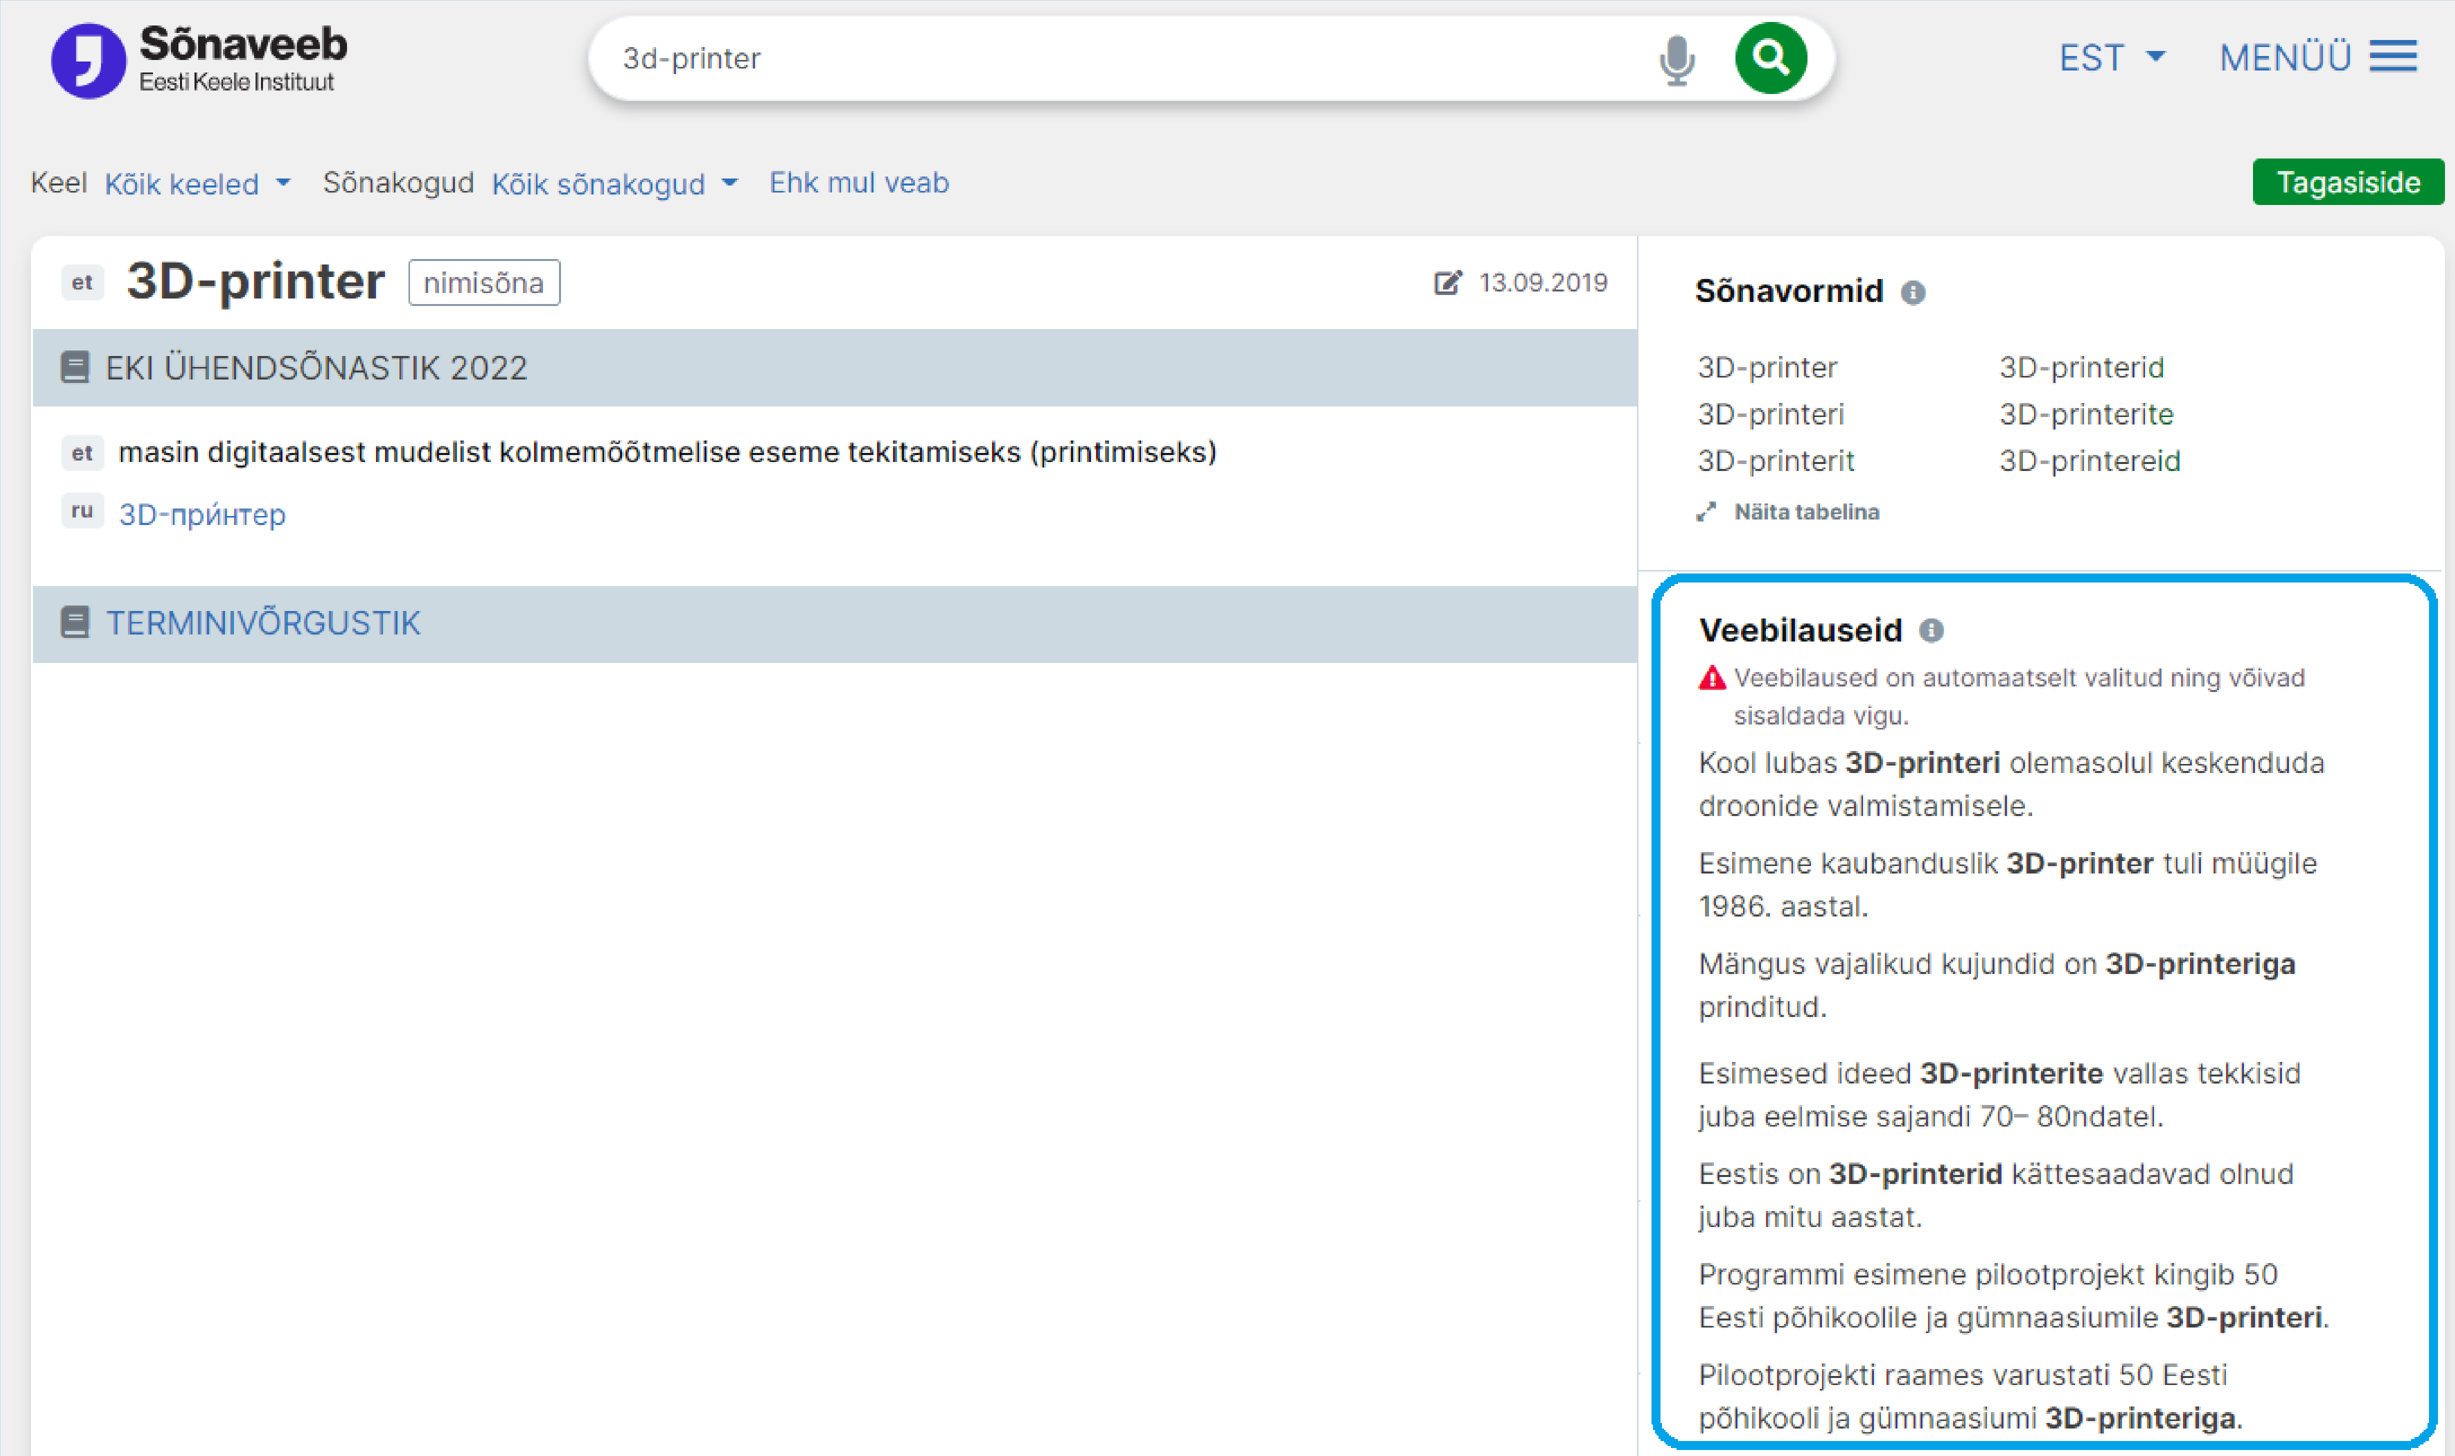

3d-printer

et 3D-printer nimisõna 13.09.2019

EKI ÜHENDSÕNASTIK 2022

et masin digitaalsest mudelist kolmemõõtmelise eseme tekitamiseks (printimiseks)

ru 3D-при́нтер

TERMINIVÕRGUSTIK

Sõnavormid

3D-printer	3D-printerid
3D-printeri	3D-printerite
3D-printerit	3D-printereid

Veebilauseid

Veebilaused on automaatselt valitud ning võivad sisaldada vigu.

Kool lubas **3D-printeri** olemasolul keskenduda droonide valmistamisele.

Esimene kaubanduslik **3D-printer** tuli müügile 1986. aastal.

Mängus vajalikud kujundid on **3D-printeriga** prinditud.

Esimesed ideed **3D-printerite** vallas tekkisid juba eelmise sajandi 70– 80ndatel.

Eestis on **3D-printerid** kättesaadavad olnud juba mitu aastat.

Programmi esimene pilootprojekt kingib 50 Eesti põhikoolile ja gümnaasiumile **3D-printeri**.

Pilootprojekti raames varustati 50 Eesti põhikooli ja gümnaasiumi **3D-printeriga**.

Longman Dictionary of Contemporary English

ldoceonline.com

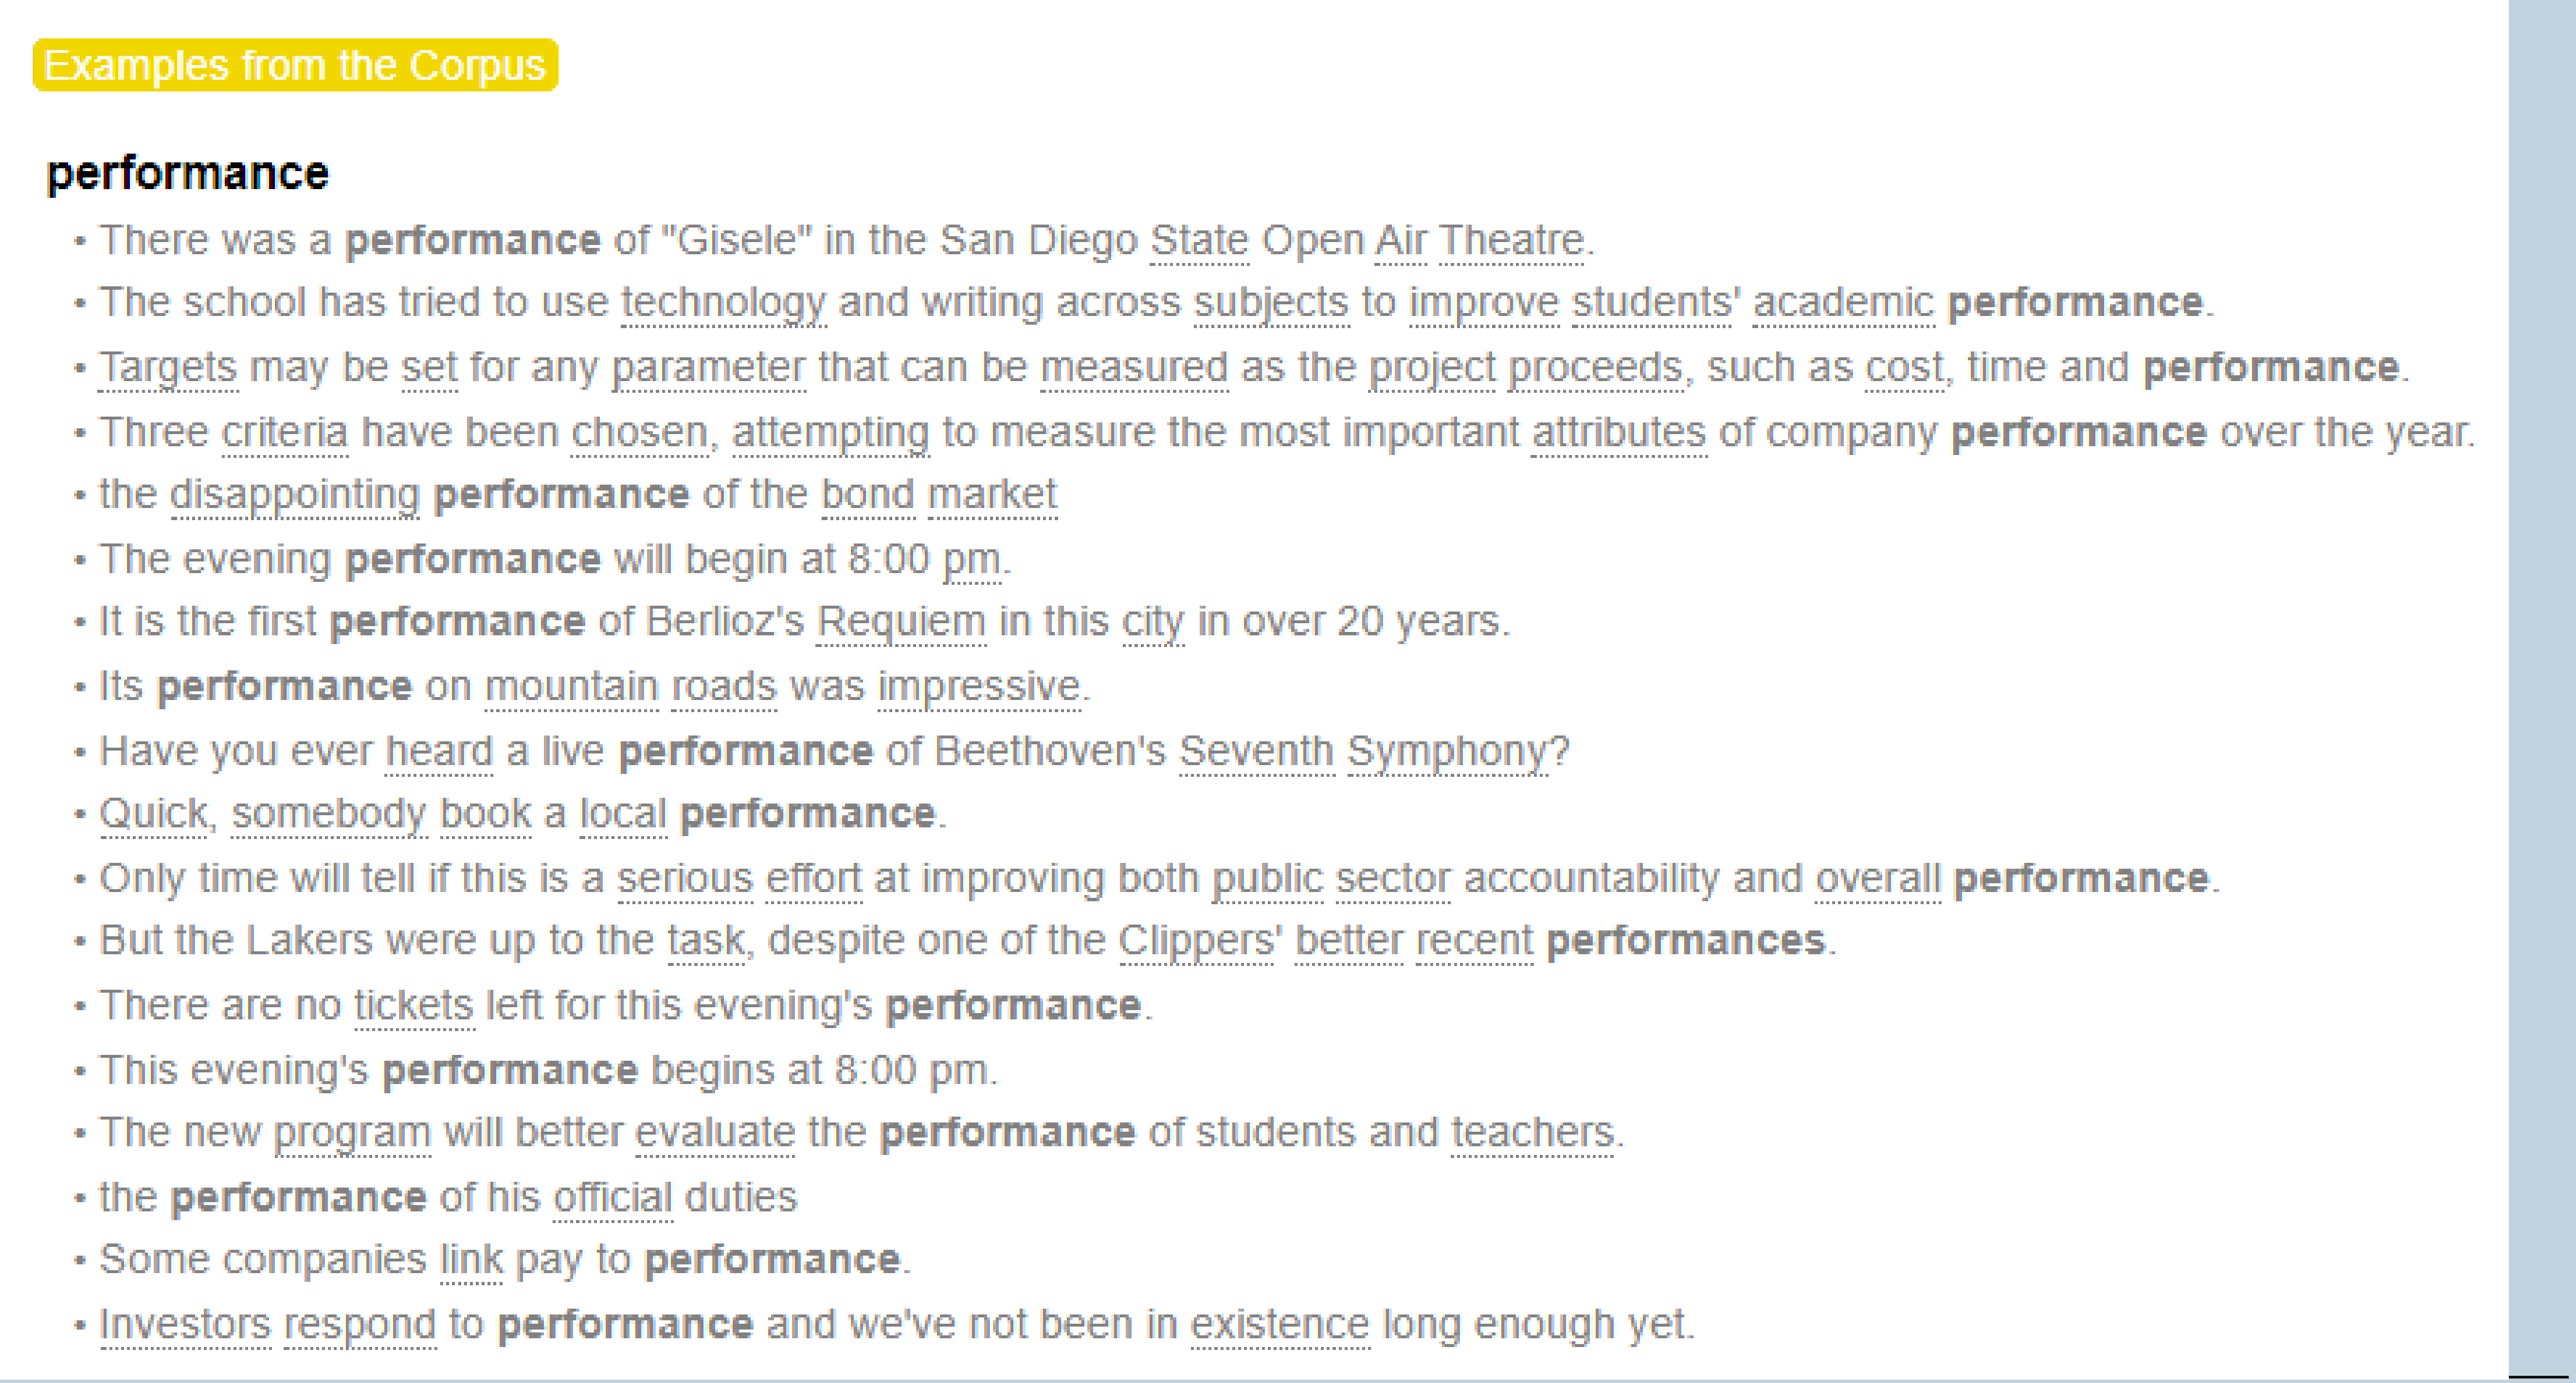

Examples from the Corpus

performance

- There was a **performance** of "Gisele" in the San Diego State Open Air Theatre.
- The school has tried to use technology and writing across subjects to improve students' academic **performance**.
- Targets may be set for any parameter that can be measured as the project proceeds, such as cost, time and **performance**.
- Three criteria have been chosen, attempting to measure the most important attributes of company **performance** over the year.
- the disappointing **performance** of the bond market
- The evening **performance** will begin at 8:00 pm.
- It is the first **performance** of Berlioz's Requiem in this city in over 20 years.
- Its **performance** on mountain roads was impressive.
- Have you ever heard a live **performance** of Beethoven's Seventh Symphony?
- Quick, somebody book a local **performance**.
- Only time will tell if this is a serious effort at improving both public sector accountability and overall **performance**.
- But the Lakers were up to the task, despite one of the Clippers' better recent **performances**.
- There are no tickets left for this evening's **performance**.
- This evening's **performance** begins at 8:00 pm.
- The new program will better evaluate the **performance** of students and teachers.
- the **performance** of his official duties
- Some companies link pay to **performance**.
- Investors respond to **performance** and we've not been in existence long enough yet.

Collins Dictionary

collinsdictionary.com

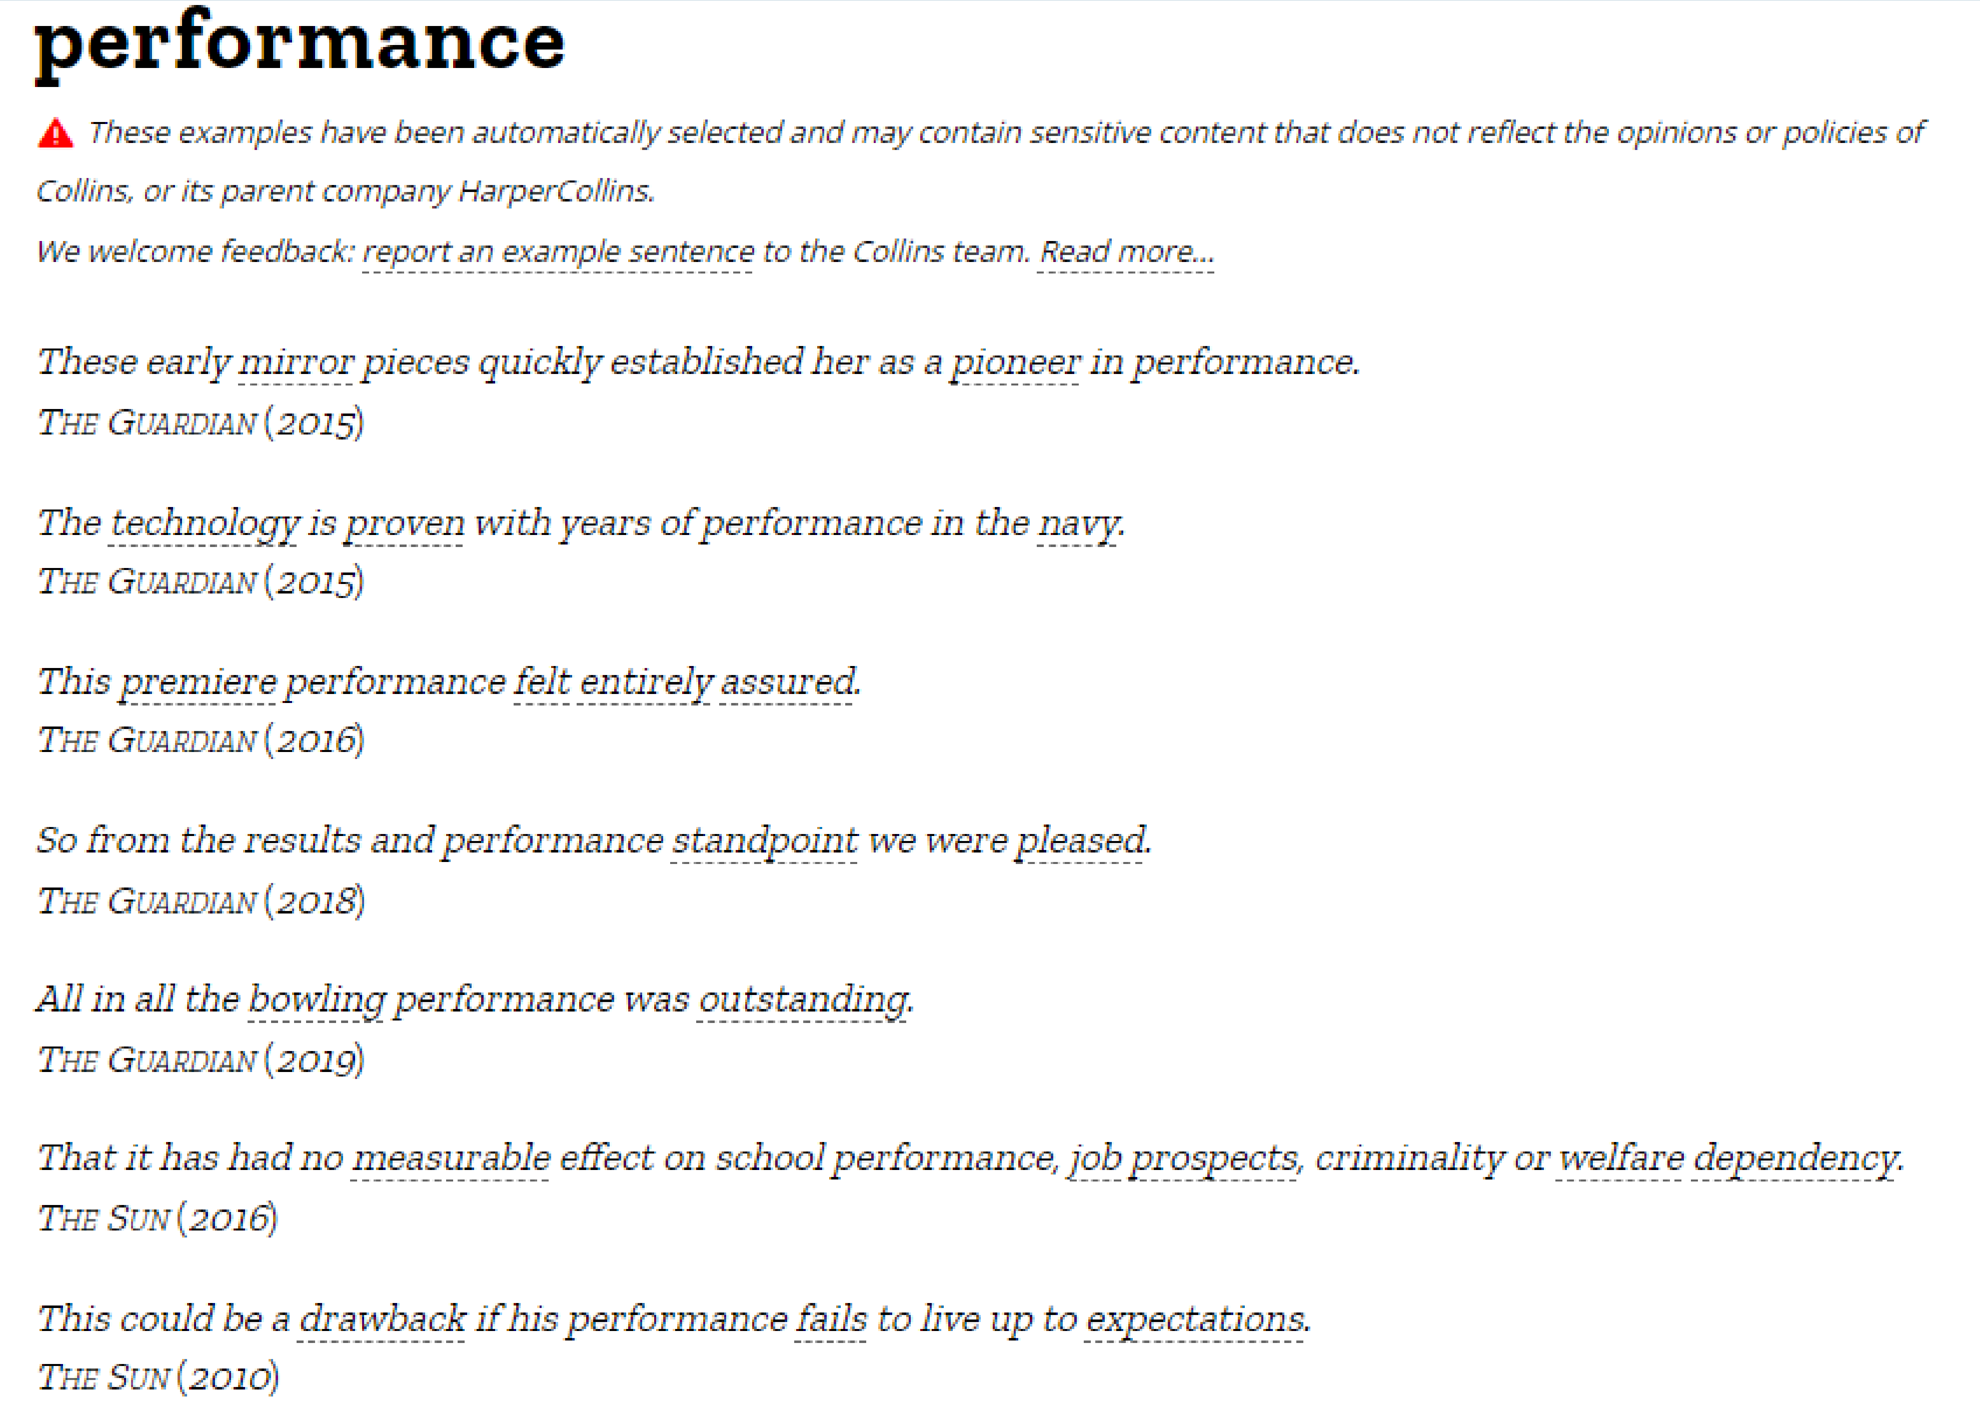

performance

⚠ *These examples have been automatically selected and may contain sensitive content that does not reflect the opinions or policies of Collins, or its parent company HarperCollins.*

We welcome feedback: report an example sentence to the Collins team. Read more...

These early mirror pieces quickly established her as a pioneer in performance.
THE GUARDIAN (2015)

The technology is proven with years of performance in the navy.
THE GUARDIAN (2015)

This premiere performance felt entirely assured.
THE GUARDIAN (2016)

So from the results and performance standpoint we were pleased.
THE GUARDIAN (2018)

All in all the bowling performance was outstanding.
THE GUARDIAN (2019)

That it has had no measurable effect on school performance, job prospects, criminality or welfare dependency.
THE SUN (2016)

This could be a drawback if his performance fails to live up to expectations.
THE SUN (2010)

Merriam-Webster

merriam-webster.com

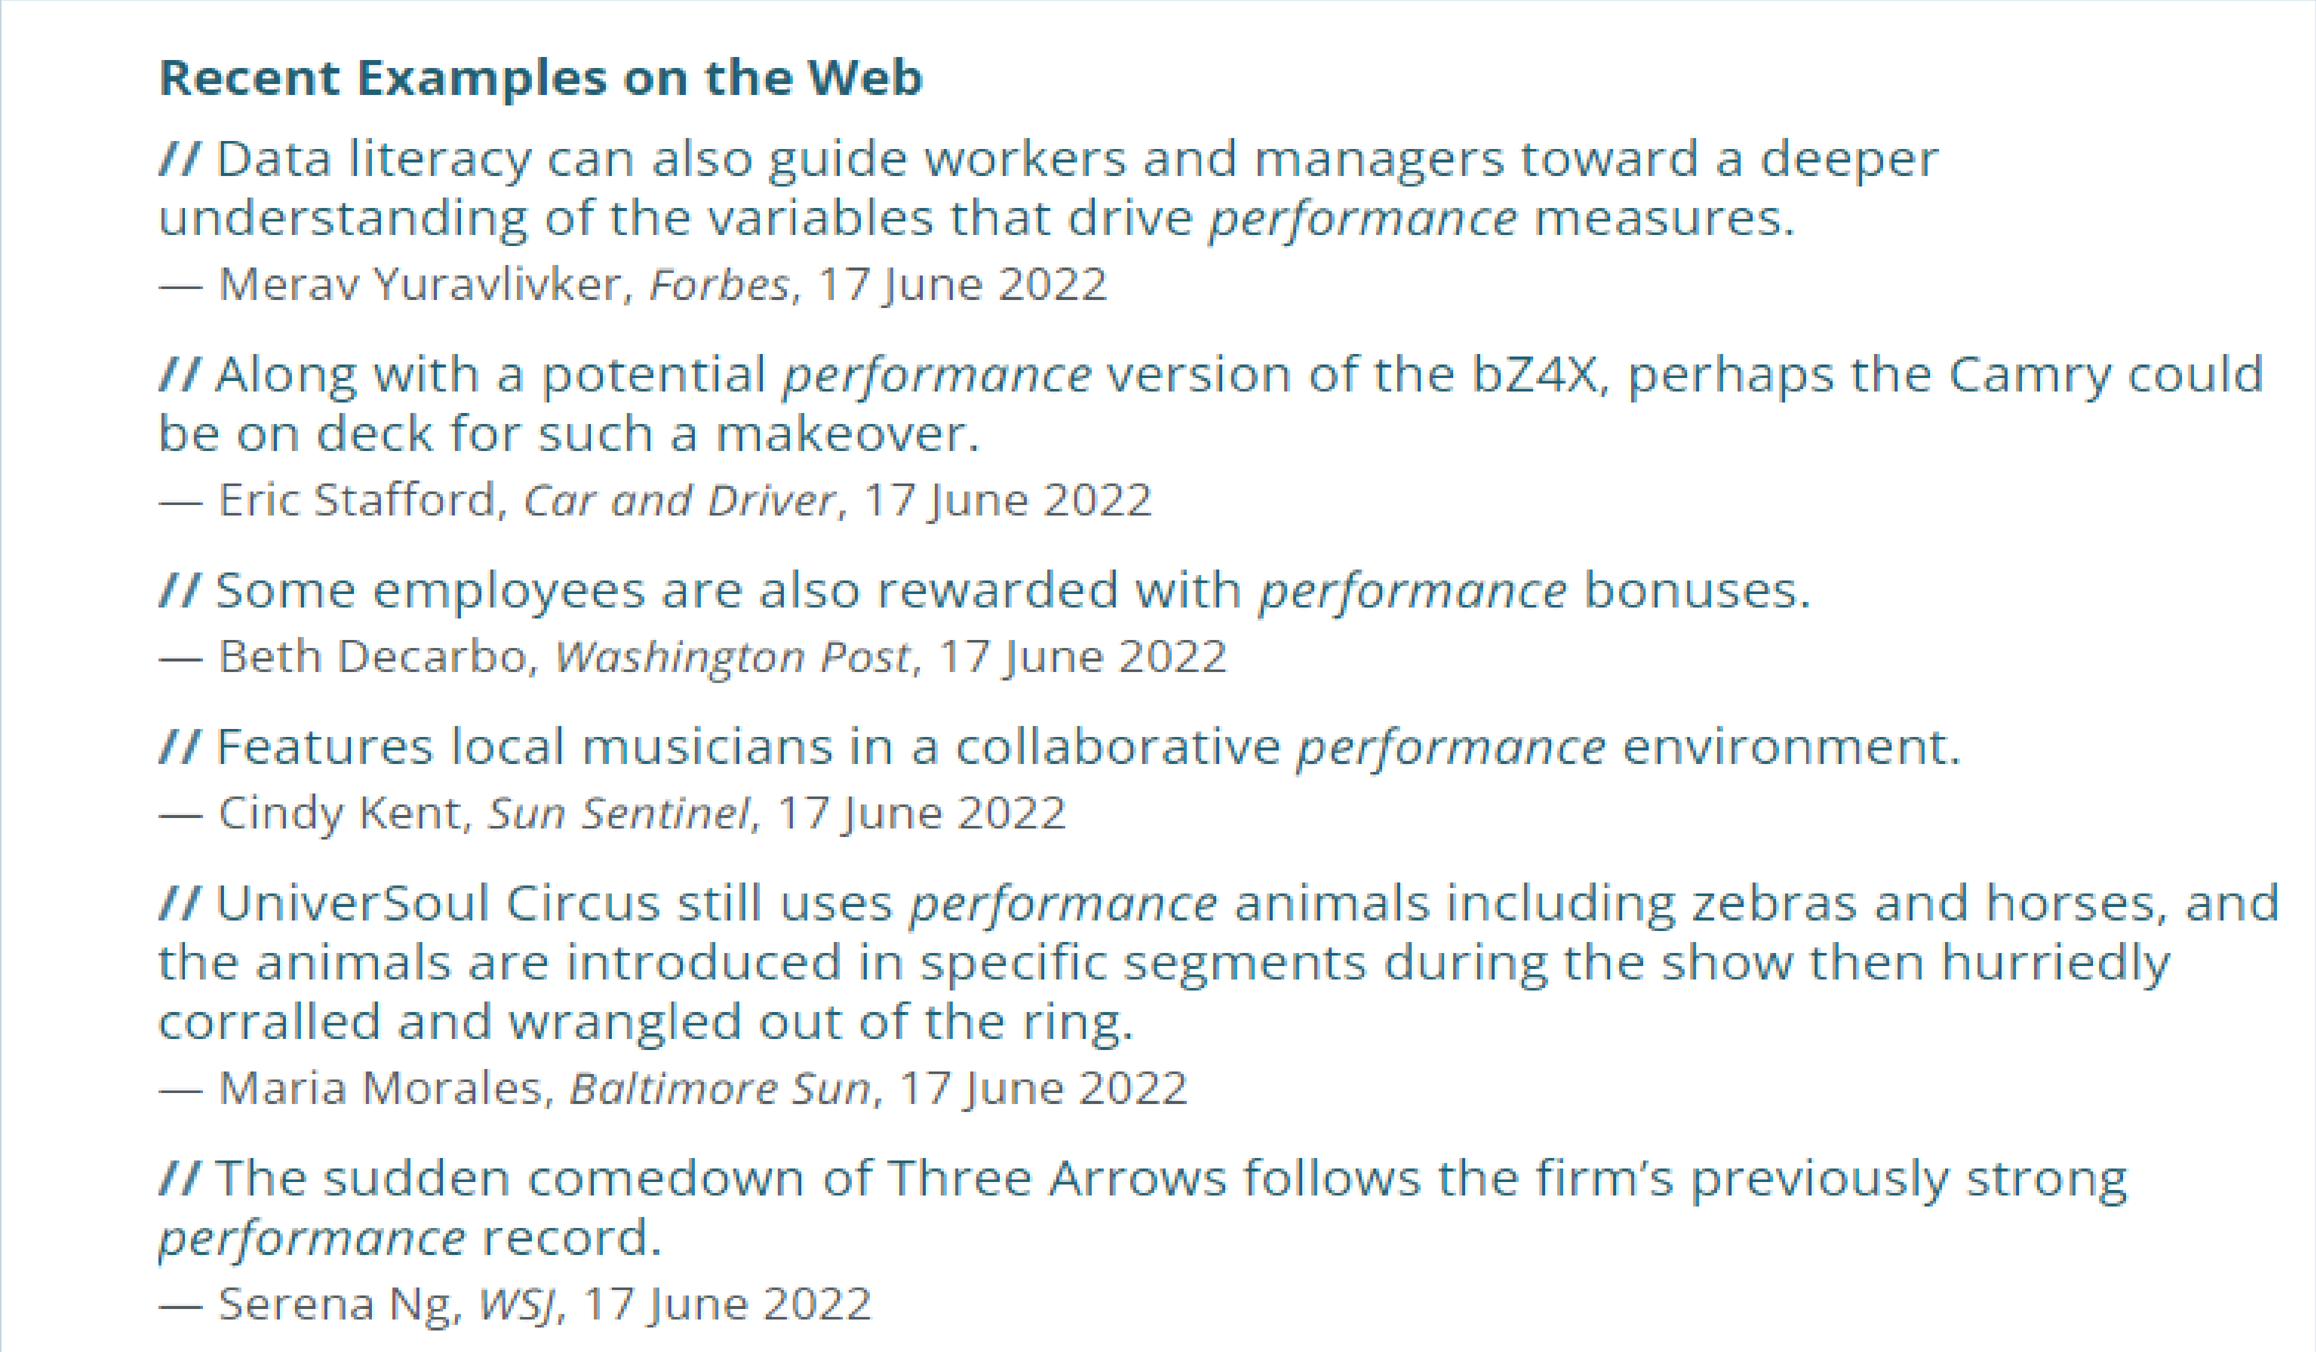

Recent Examples on the Web

// Data literacy can also guide workers and managers toward a deeper understanding of the variables that drive *performance* measures.

— Merav Yuravlivker, *Forbes*, 17 June 2022

// Along with a potential *performance* version of the bZ4X, perhaps the Camry could be on deck for such a makeover.

— Eric Stafford, *Car and Driver*, 17 June 2022

// Some employees are also rewarded with *performance* bonuses.

— Beth Decarbo, *Washington Post*, 17 June 2022

// Features local musicians in a collaborative *performance* environment.

— Cindy Kent, *Sun Sentinel*, 17 June 2022

// UniverSoul Circus still uses *performance* animals including zebras and horses, and the animals are introduced in specific segments during the show then hurriedly corralled and wrangled out of the ring.

— Maria Morales, *Baltimore Sun*, 17 June 2022

// The sudden comedown of Three Arrows follows the firm's previously strong *performance* record.

— Serena Ng, *WSJ*, 17 June 2022

Probleemid

1. Korpuse sisu ja maht
2. Märgendamise kvaliteet
    - lemmatiseerimise ja morfoloogilise märgenduse vead
    - lausestamine
    - mitmesõnalised üksused
    - leksikon
    - trükivead
3. Grammatiline mitmesus
    - lekseemide homonüümia (*tamm*:*tamme*, *tamm*:*tammi*)
    - pradigmaväline vormisisene homonüümia (*teod*: *tigu* ja *tegu*)
    - paradigmaväline vormidevaheline homonüümia (*kalla*: *kalla* ja *kallama*)
4. Semantiline mitmesus
    - polüseemia ehk mitmetähenduslikkus

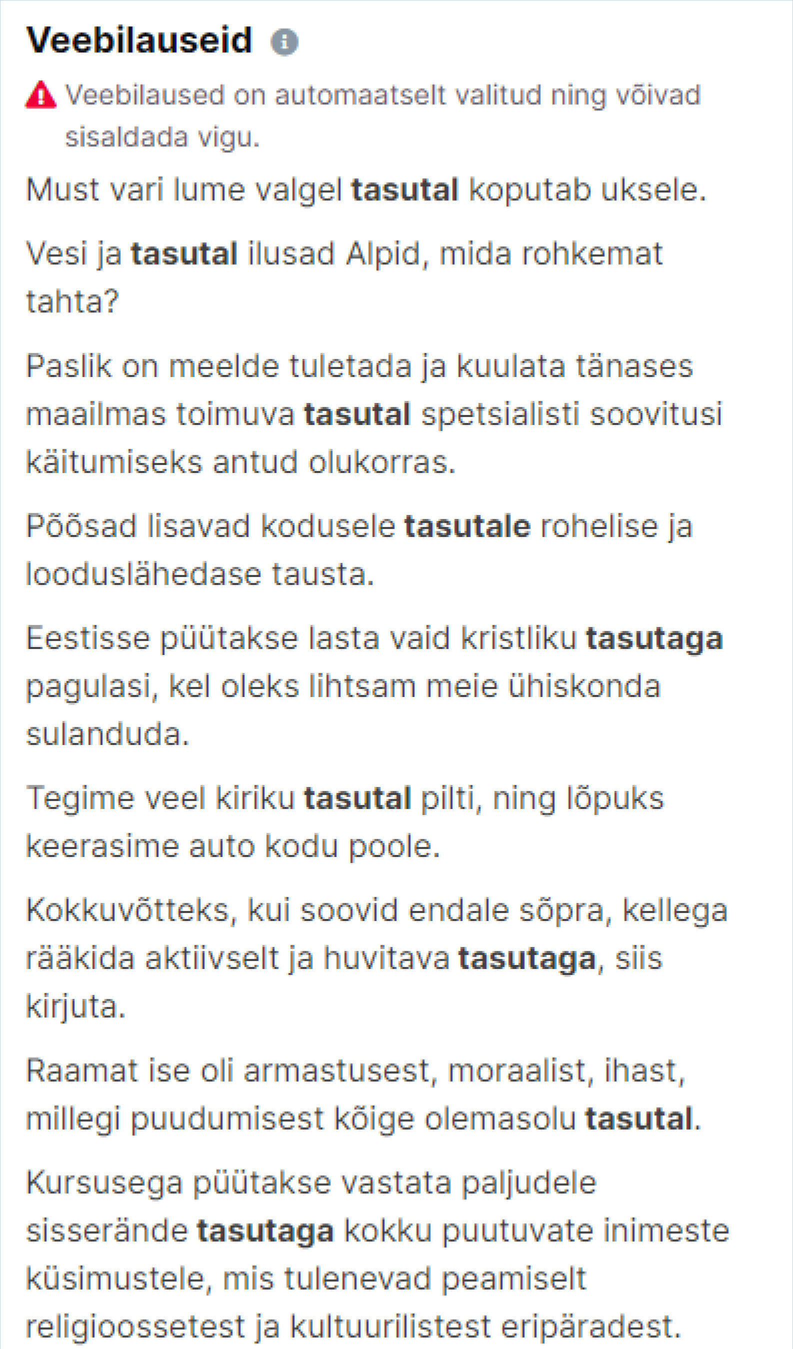

Veebilauseid

Veebilaused on automaatselt valitud ning võivad sisaldada vigu.

Must vari lume valgel **tasutal** koputab uksele.

Vesi ja **tasutal** ilusad Alpid, mida rohkemat tahta?

Paslik on meelde tuletada ja kuulata tänases maailmas toimuva **tasutal** spetsialisti soovitusi käitumiseks antud olukorras.

Põõsad lisavad kodusele **tasutale** rohelise ja looduslähedase tausta.

Eestisse püütakse lasta vaid kristliku **tasutaga** pagulasi, kel oleks lihtsam meie ühiskonda sulanduda.

Tegime veel kiriku **tasutal** pilti, ning lõpuks keerasime auto kodu poole.

Kokkuvõtteks, kui soovid endale sõpra, kellega rääkida aktiivselt ja huvitava **tasutaga**, siis kirjuta.

Raamat ise oli armastusest, moraalist, ihast, millegi puudumisest kõige olemasolu **tasutal**.

Kursusega püütakse vastata paljudele sisserände **tasutaga** kokku puutuvate inimeste küsimustele, mis tulenevad peamiselt religioossetest ja kultuurilistest eripäradest.

Mis tulevik toob?

CrowLL ehk Crowdsourcing for Language Learning

http://www.crowll.org

Rahvusvaheline koostööprojekt viie riigi vahel

- Portugal: Tanara Zingano Kuhn, Ana Luís
- Sloveenia: Špela Arhar Holdt, Iztok Kosem
- Iisrael: Rina Zviel-Girshin
- Holland: Carole Tiberius
- Eesti: Kristina Koppel

AITÄH