

Lemmatisation of MWEs in Dutch resources

Carole Tiberius, carole.tiberius@ivdnt.org | Lut Colman, lut.colman@ivdnt.org

/instituut
voor de
Nederlandse
taal/

UniDive WG2



Woordcombinaties

MWEs in Woordcombinaties

Woordcombinaties is a relatively new online lexicographic resource for advanced learners of Dutch as a second or foreign language combining access to collocations, idioms, conversational routines and constructions in one tool.

Woordcombinaties distinguishes a number of mwe types, including collocations (*een misdaad begaan* 'commit a crime'), multiword nouns, adjectives, adverbs and adpositions (*blinde muur* 'blank wall', *om en nabij* 'approximately', *baseren op* 'base on'), idioms (*de kat de bel aanbinden* 'bell the cat'), proverbs (*morgenstond heeft goud in de mond* 'the early bird catches the worm'), quotes (*ik denk, dus ik ben* 'I think, therefore I am'), slogans (*twee halen, één betalen* 'get two, pay one'), aphorisms (*gededen te sterven* 'remember to die') and conversational and text formulas (*goede morgen* 'good morning').



Sorteer collocaten op frequentie

subject ⓘ - Wie of wat vindt?

substantief ⓘ Kamerlid, archeoloog, bedrijf, bezoeker, collega, commissie, criticus, deel, heft, hogerlaar, (24 meer)

object ⓘ - Wie of wat vindt men of wordt gevonden?

substantief ⓘ DNA, aandeel, aanpak, aansluiting, aanwijzing, adres, aftrek, afwijking, akkoord, (177 meer)

pronomen ⓘ dat, dit, elkaar, het, iemand, iets, niets; nik, niets; nik, zichzelf

advoot ⓘ

1,1 uitdrukking iemand of iets vindt aansluiting bij iets of iemand

iemand of iets kan zich verenigen met het doel van iets of iemand

We moeten beter aansluiting vinden bij ons publiek. (meer voorbeelden)

1,2 uitdrukking iemand of iets vindt (een tweede adem, een nieuwe adem)

iemand of iets herleeft na een dip

Sinds hij aan de macht is, vindt het nationalisme een nieuwe adem. (meer voorbeelden)

1,3 uitdrukking iets vindt (ergens) (gretig) aftrek

iets wordt graag gekocht of genuttigd

Zijn nieuwste boek vindt in Egypte gretig aftrek.



Arguments and open slots

iem. naar zijn hand zetten 'force **someone** to **one's** will' [1]

iem. of iets naar zijn hand zetten 'force **someone** or **something** to **one's** will' [2]

iets naar je hand zetten 'force **something** to **your** will' [5]

in weewil van ... [1,5]

in weewil van [2]

in weewil van iets [6]

'in spite of'

Position of arguments

geen kaas gegeten hebben van iets [1,2]

er geen kaas van gegeten hebben [5]

ergens geen kaas van gegeten hebben [6]

'not have a clue **about something**'

Lexical variation

een schat van een baby, kind, man, vrouw (entry for **schat**) [1]

een schat van een kind (entry for **een**) [1]

een schat van een [kind] [2]

'a gem of a baby, child, man, woman'

een boom van een /kerel/vent/ 'a great big fellow' [2]

als de dood van of voor iets zijn 'be scared to death of **or** for sth.' [1]

oude (verdronken, dode) koeien uit de sloot halen 'bring up old (drowned, dead) matters' [1]

zich naar/rot lachen & zich ziek lachen 'split one's sides laughing' &

'be in stitches' [2]

botertje tot de boom & botertje aan de boom 'situation with prosperity and welfare or excellent mutual understanding' [3]

NOTE: Syntactic variation is rarely included

Resources

[1] Dikke Van Dale Online (Den Boon & Hendrickx 2015)

[2] Van Dale Onlinewoordenboek hedendaags Nederlands (De Boer 2015),

[3] Algemeen Nederlands Woordenboek (ANW),

[4] Van Dale Idiomwoordenboek (de Groot 1999)

[5] Met zoveel woorden. Gids voor trefzeker taalgebruik (Schutz & Permentier 2016)

[6] Open Dutch WordNet (Postma, M. et al. 2016).

Canonical forms of MWEs in the lexicographic literature

There are no ready-made solutions in lexicography for representing the different types of variation of idioms. (Svensén 2009:199)

Harras and Proost's (2002:289) Citation Form Maxim:

Idioms should basically be entered in their basic or canonical form. This means that the citation form should contain only general pronouns like *someone* or *somebody* and *something*. VP-idioms should basically be entered in the infinitive form of the head verb. Where deviations from the canonical citation form are required, these should be in accordance with the following submaxims:

- (1) The citation form must indicate as many restrictions as possible. [...]
- (2) Morphological restrictions should also be indicated by the citation form. [...]
- (3) The citation form should not be too restrictive. [...]

References

- Hanks, P. (2013). *Lexical analysis: Norms and exploitations*. Cambridge, MA: The MIT Press.
Harras, G., & Proost, K. (2002). The Lemmatisation of idioms. In *Symposium on Lexicography XI, Proceedings of the Eleventh International Symposium on Lexicography*. Copenhagen. 277-291.
Svensén, B. (2009). *A Handbook of Lexicography: The Theory and Practice of Dictionary Making*. Cambridge University Press.

Lemmatising MWEs in Woordcombinaties

A lemmatisation strategy for MWEs that is user-friendly but also compatible with more NLP oriented work. In *Woordcombinaties* a human-friendly form is complemented with a pattern form

Preliminary guidelines:

- MWEs are entered in their canonical form, e.g. infinitive form for verbal MWEs.
- Variable, but obligatory arguments and variable parts of arguments and complements are indicated by means of dummies (e.g. *iemand de ogen openen* 'open someone's eyes') or other generic forms such as *zijn* (e.g. *zijn gezicht laten zien* 'show one's face') and *zich* (e.g. *zich op de vlakte houden* 'not commit oneself').
- A fixed order of components is followed as much as possible: e.g. place and direction complements in verbal MWEs will usually occur before the verb and fixed prepositions after it (e.g. *in de bres springen voor iemand of iets* 'throw oneself into the breach for someone or something').
- Canonical forms, variants and lexical realisations of constructional MWEs will be lemmatised separately and linked.