

Mewnbliadau Geiriau ar gyfer y Gymraeg

Geraint Palmer¹, Padraig Corcoran², Laura Arman³, Dawn Knight³, ac Irena Spasic²

¹Yr Ysgol Mathemateg, Prifysgol Caerdydd

²Yr Ysgol Cyfrifiadureg a Gwybodeg, Prifysgol Caerdydd

³Yr Ysgol Saesneg, Cyfathrebu ac Athroniaeth, Prifysgol Caerdydd

Ariennir gan Lywodraeth Cynulliad Cymru

04/11/2020

Cynnwys

1. Beth yw mewnbliadau geiriau?
2. Defnydd mewnbliadau geiriau
3. Hyfforddi mewnbliadau geiriau Cymraeg
4. Arddangos mewnbliadau geiriau Cymraeg

Beth yw mewnbliadau geiriau?

Diffiniad

Mapiad o'r gofod lecsio-semantig i ofod fector real.

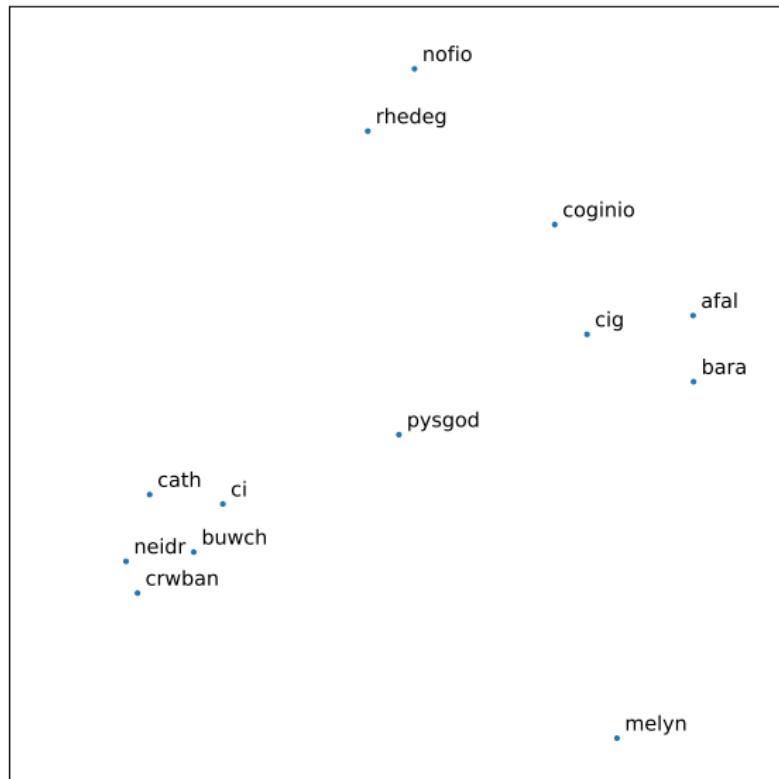
$$f(\text{cath}) = (24.5, 0.4, -8.4, \dots, -9.9)$$

$$f(\text{rhedeg}) = (-5.77, 12.0, 1.38, \dots, 32.6)$$

$$f(\text{melyn}) = (0.1, -0.8, -28.5, \dots, -2.7)$$

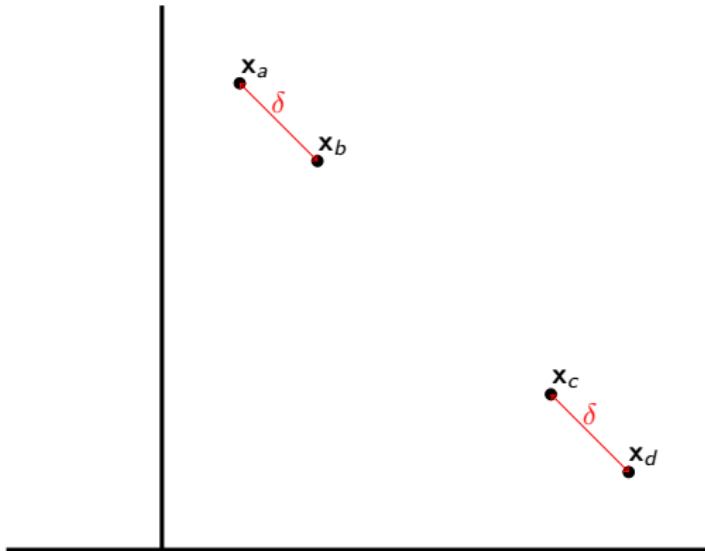
⋮

Priodweddau



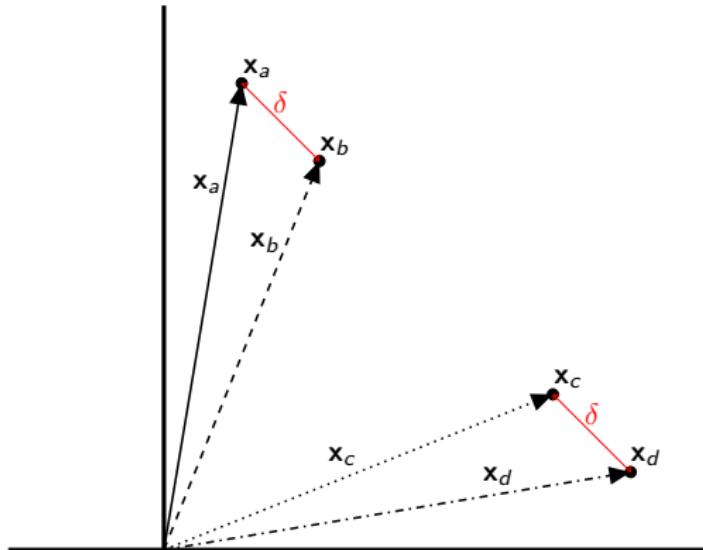
Priodweddau

- $f(\text{brenin}) = \mathbf{x}_a$
- $f(\text{brehines}) = \mathbf{x}_b$
- $f(\text{myfyriwr}) = \mathbf{x}_c$
- $f(\text{myfyrwraig}) = \mathbf{x}_d$



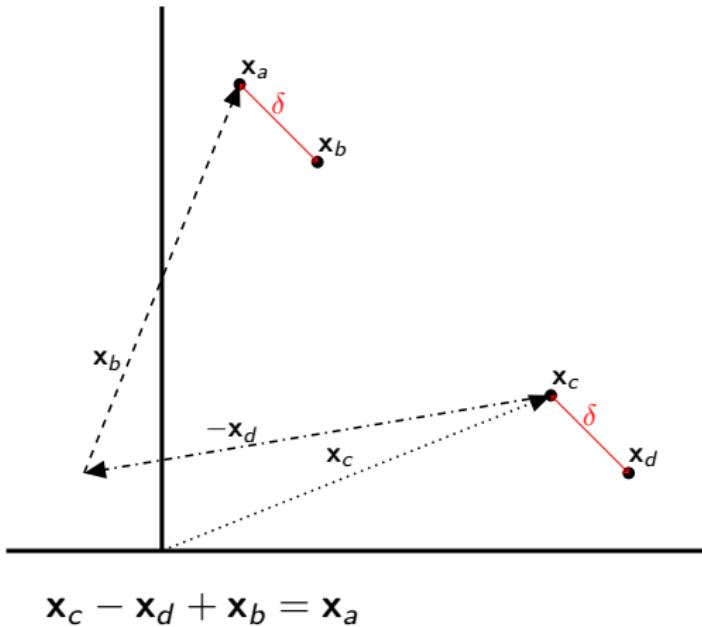
Priodweddau

- $f(\text{brenin}) = \mathbf{x}_a$
- $f(\text{brehines}) = \mathbf{x}_b$
- $f(\text{myfyriwr}) = \mathbf{x}_c$
- $f(\text{myfyrwraig}) = \mathbf{x}_d$



Priodweddau

- $f(\text{brenin}) = \mathbf{x}_a$
- $f(\text{brehines}) = \mathbf{x}_b$
- $f(\text{myfyriwr}) = \mathbf{x}_c$
- $f(\text{myfyrwraig}) = \mathbf{x}_d$



Defnydd mewnbliadau geiriau

Nifer mawr o modelau dysgu peirianyddol a phrosesu iaith naturiol, gan gynnwys:

- Cyfieithu peirianyddol
- Dadansoddi sentiment
- Adnabod endidau
- Parsio dibyniaethau

Defnydd - Cyfieithu peirianyddol

-  “the distribution function is continuous due to this identity”
-  “mae swyddogaeth y dosbarthiad yn barhaus oherwydd y hunaniaeth hon”

2018 Qi, Ye, et al. **When and Why Are Pre-Trained Word Embeddings Useful for Neural Machine Translation?** Proceedings of the 2018 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 2 (Short Papers).

Defnydd - Cyfieithu peirianyddol

-  “the distribution function is continuous due to this identity”
-  “mae swyddogaeth y dosbarthiad yn barhaus oherwydd y hunaniaeth hon”
-  “mae ffwythiant y dosraniad yn ddi-dor oherwydd yr unfathiant hwn”

2018 Qi, Ye, et al. **When and Why Are Pre-Trained Word Embeddings Useful for Neural Machine Translation?** Proceedings of the 2018 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 2 (Short Papers).

Defnydd - Dadansoddi sentiment

Sylw	Sentiment
“oni'n rili lico'r ffilm”	
“roedd stori'r ffilm yn sôn am long ofod”	
“y ffilm gwaethaf dwi 'di gweld erioed”	
“gor-actio bendigedig can Cameron Diaz”	

Defnydd - Adnabod endidau

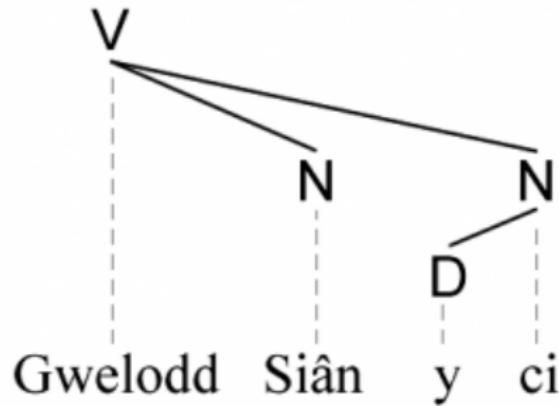
“darganfuwyd y prif weinidog bod
ganddi gancr y fron yr haf
yr oedd hi'n gweithio ar y papur
gwyn dadleuol hwnnw.”

Defnydd - Adnabod endidau

“darganfuwyd y **prif weinidog** bod
ganddi **gancr y fron** yr **haf**
yr oedd hi'n gweithio ar y **papur**
gwyn dadleuol hwnnw.”

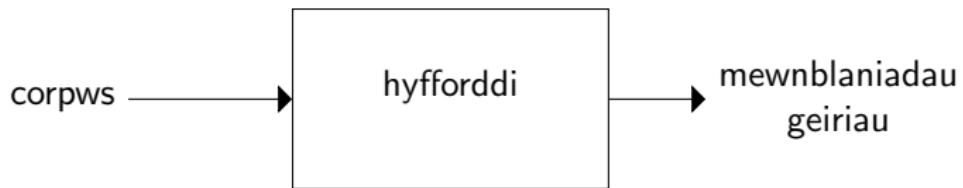
Person
Peth Amser

Defnydd - Parsio dibyniaethau

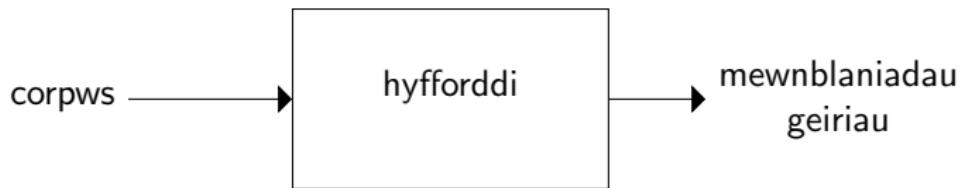


Darlun: 2019 Jones DB., Prys, D., Prys M. a Prys G., **Llawlyfr Technolegau Iaith**

Hyfforddi Mewnbliadau Geiriau



Hyfforddi Mewnblaniadau Geiriau



... aeth y ci i mewn i'r tŷ er mwyn bwyta'r bwyd i gyd ...
↑
gair

CBOW: mwyafsymio cyfanswm $\mathbb{P}(\text{cyd-destun} | \text{gair})$

Skip-gram: mwyafsymio cyfanswm $\mathbb{P}(\text{gair} | \text{cyd-destun})$

Casglu Corpws

<i>Ffynhonnell</i>	<i>Nifer o eiriau</i>
Beibl	749,573
Corpws An Crúbadán Corpws a chasglwyd yn UDA o blogiau, trydar a wefannau Cymraeg	22,572,066
CorCenCC Corpws rhagbaratoawl iaith electroneg CorCenCC	1,875,540
Cronfa Electroneg o Gymraeg Casgliad amrywiol o rhyddiaeth, nofelau, a dogfennau gweinyddol	1,046,800
Google Corpuscrawler Teclyn Google i cael caffael ar corpera nifer o ieithoedd, yn bennaf BBC Cymru Fyw	14,791,835
Gwerddon	767,677
Project DECHE Prosiect Digido, E-gyhoeddi a Chorpws Electronig, gwrslyfrau wedi'u digido	2,126,153
Trafodion Cynulliad Cenedlaethol 1999-2006	11,527,963
Trafodion Cynulliad Cenedlaethol 2007-2011	8,883,970
Wicipedia Cymraeg	21,233,177
Wefannau amrywiol Golwg360, O'r Peward Gwynt, Barn, a PoblCaerdydd	7,388,917
Cyfanswm	92,963,671

Arddangos Mewnbliadau Geiriau Cymraeg

<https://datainnovation.cardiff.ac.uk/is/wecy/index.html>

Arddangos Mewnbliadau Geiriau Cymraeg

ARIAN

- harian
- arian'
- ariannu
- cyllid
- bunnau
- gyllid
- bres
- arianu
- goffrau
- wario

Arddangos Mewnblaniadau Geiriau Cymraeg

CYSGU

- gysgu
- deffro
- llewygu
- cysgai
- chwtsho
- chysgu
- dihuno
- cerdded
- ddihuno
- gysgai

Arddangos Mewnbliadau Geiriau Cymraeg

BLAWD

- blawdog
- flawd
- blawr
- blawdty
- siaradblawd
- menyn
- fenyn
- cyflasynnau
- blaw
- chwstard

Arddangos Mewnblaniadau Geiriau Cymraeg

TONYREFAIL

- donyrefail
- nhonyrefail
- ffosyrefail
- maesyrefail
- trebanog
- tonysguboriau
- tonteg
- tonypandy
- trecynon
- trelaw

Arddangos Mewnblaniadau Geiriau Cymraeg

ACTORES

- actor
- actoresau
- sgriptwraig
- digrifwraig
- berfformwraig
- comediwraig
- chantores
- gantores
- ddigrifwraig
- perfformwraig

- <https://datainnovation.cardiff.ac.uk/is/wecy/index.html>
- <http://www.geraintianpalmer.org.uk/>
- palmergi1@cardiff.ac.uk
- [@GeraintPalmer](https://twitter.com/GeraintPalmer)