

Beth yw SameDiff?

Mae SameDiff yn cymharu dau neu fwy o ffeiliau testun ac yn dweud wrthy'ch chi ba mor debyg neu wahanol maen nhw. Mae'n eich helpu i weld gwahaniaethau a thebygrwyddau yn y geiriau sy'n cael eu defnyddio ym mhob ffeil fel y gallwch ddysgu am ddadansoddiad meintiol testun. Mae'r gweithgaredd ymarferol yma'n helpu cyfranogwyr i fagu eu llythrennedd data drwy gymharu geiriau dau gerddor a dyfeisio cân newydd byddan nhw'n ei chyd-ysgrifennu.

Nodau Dysgu

- Mwy o allu i ddadansoddi data testun.
- Deall bod cymharu dau beth yn ffordd rymus o ganfod storïau mewn data.
- Ymwybyddiaeth o'r math o gwestiynau gallwch chi/dylech chi eu gofyn i ddata testun.
- Deall y gall dadansoddiad algorithmig ddatgelu gwybodaeth ddiddorol am eich data.

Cynnal y Gweithgaredd

Datrys Problem

Mae dadansoddi testun mawr yn anodd i'w wneud â llaw. Un ffordd o ddeall "corpws" o destun yw ei gymharu ag un arall, neu i gymharu rhannau ohono. Mae cyfrifiadurwyr wedi dyfeisio dulliau i helpu, gan greu amrywiol ryseitiai, neu "algorithmau", sy'n gallu cymharu dau gorpws. Mae SameDiff yn rhedeg rhai o'r algorithmau hynny i chi fel y gallwch chi geisio cymharu dau ddarn mawr o destun â'i gilydd.

Rhannu Enghreifftiau i Ysbrydoli

Mae data testun mawr ym mhobman o'n cwmpas. Heddiw gallwch chi lawrlwytho holl e-byst Ysgrifennydd Gwladol Hillary Clinton, ceblau diplomataidd gan Wikileaks, neu holl nofelau Sherlock Holmes o Brosiect Gutenberg. Mae dadansoddi a delweddu'r testunau mawr yma'n beth cyffredin i'w wneud erbyn hyn, mewn ffyrdd difrifol neu ddifyr. Dangoswch Jaz Parkinson's "Color Signatures" sy'n cymharu'r lliwiau a enwir mewn llyfrau gwahanol (<http://jazparkinson.tumblr.com>) (Saesneg yn unig), a Tahir Hemphill's "Rap Research Lab" (<http://rapresearchlab.com>) (Saesneg yn unig).

Cyfanswm amser

30 to 45 Munud

Cynulleidfa

3 - 100 o bobl. Oedrannau 12+. Wedi ei ddylunio am raddau 6 - 12, dosbarthiadau Addysg Uwch, Cyrff Newyddion, Cyrff Di-elw, a Gweithdai Cymunedol. Does dim angen unrhyw brofiad blaenorol gyda data.

Gofod

- Taflunydd a chyfrifiadur.
- Gallu i ymrannu'n grwpiau bach o 3 o amgylch cyfrifiadur.
- Byrddau mawr neu lawr, neu dâp i lynu papur wrth walïau fel y gall cyfranogwyr ddarlunio

Cyflenwadau

- Cyfrifiaduron
1 am bob 3 chyfranogwr
- Darnau mawr o bapur
2 droedfedd x 3 droedfedd yn fras
- Crayonau trwchus neu farcwyr

Cynnal y Gweithgaredd (parhau)

Cyflwyno'r Offeryn

Agorwch SameDiff (<https://datacymru.databasic.io/cy/samediff/>)

Yws Gwynedd ac Dafydd Iwan o'r samplau. Ar y dudalen ganlyniadau esbonwch fod y golofn chwith yn dangos geiriau sy'n unigryw i Yws Gwynedd, a'r golofn dde yn dangos geiriau sy'n unigryw i Dafydd Iwan. Dyna eu gwahaniaethau. Mae'r golofn ganol yn dangos y geiriau sydd ganddyn nhw'n gyffredin. Tynnwch eu sylw at frig y dudalen ganlyniadau lle mae'n dweud, "Mae'r ddwy ddogfen yma yn eithaf tebyg". Mae SameDiff yn defnyddio algorithm o'r enw "tebygrwydd cysein" i roi sgôr tebygrwydd i chi. Mae tebygrwydd cysein yn gweithio drwy greu rhestr o eiriau gan Yws Gwynedd a rhestr o eiriau gan Dafydd Iwan. Mae'n cyfrif pa mor aml mae pob term yn ymddangos ym mhob dogfen ac yna'n cymharu ba mor agos mae'r ddwy restr yn cyd-fynd a'i gilydd. Mae'n algorithm defnyddiol i ddadansoddi testunau.

Lansio'r Gweithgaredd

1. Mae gan gyfranogwyr 15 munud.
2. Mae cyfranogwyr yn gweithio mewn timau o dri.
3. Mae pob tîm yn defnyddio SameDiff i gymharu geiriau caneuon dau gerddor. Gan fod cydweithrediadau cerddorol yn boblogaidd iawn, dewiswch ddau artist a dychmygwch sut gân fyddai'r ddau yn ei hysgrifennu gyda'i gilydd. <https://datacymru.databasic.io/cy/samediff>
4. Mae pob tîm yn yn ysgrifennu geiriau eu cân ar ddarn mawr o bapur gyda chrayonau.
5. Mae timau'n ennill pwyntiau bonws os: (a) mae eu cân yn odli a/neu (b) maen nhw'n dyfeisio tŷn i ganu'r gân iddi a/neu (c) maen nhw'n ei pherfformio yn null karaoke ar gyfer y grŵp.

Rhannu Adborth

Cymerwch 1 funud i bob grŵp rannu eu cân newydd. Rhai cwestiynau a themâu i chwilio amdany'n nhw a chanolbwyntio arny'n nhw yn ystod y drafodaeth:

- Wnaethoch chi sylwi ar unrhyw themâu cyffredin?
- Ydy'r geiriau canlyniadol yn fwy diddorol pan maen nhw'n dod o artistiaid â gwaith sy'n wahanol iawn?
- Mae cymharu yn ffordd rymus o ganfod storïau mewn data.
- Gall gweithio gyda data fod yn hwyl!

I'ch atgoffa

- Rydym ni'n rhedeg algorithmau bob dydd. E.e. pan gollwch chi'ch allweddi rydych chi'n rhedeg algorithm i chwilio amdany'n nhw – gwirio'ch pocedi yn gyntaf, y bwrdd wrth ymyl y drws, ac ati
- Mae tebygrwydd cysein o 1.0 yn golygu yn union yr un peth; mae sero yn golygu cwbl wahanol.

Termau i'w Cyflwyno

Algorithm

Set o gamau i chi (neu gyfrifiadur) eu cymryd i ddatrys problem.

Corpws

Casgliad o destunau ysgrifenedig. Er enghraifft, yr holl eiriau yng nghaneuon Katy Perry.

Tebygrwydd Cysein

Mae sgôr Tebygrwydd Cysein yn ceisio dweud wrthy'ch chi pa mor debyg mae dwy ddogfen ar sail nifer y gweithiau mae geiriau'n cael eu defnyddio yn y ddwy.

Brasluniau sampl

Madonna + Elvis
Wyt ti'n ngharu i bobol, dywed
Dwi'n caru dy lygaid glas
Gwrandla arna' i heddiw

Fi yw cariad
Fi yw cariad
Eisiau breuddwydio
fflio'n rhydd
Rhedeg a mane,
fy merch.