

APRENENTATGE AUTOMÀTIC NO-SUPERVISAT PER ALS FONS ARXIVÍSTICS: possibilitats i límits dels models temàtics i la representació distribuïda

Seth van Hooland i Mathias Coeckelbergs,
Universitat Lliure de Brussel·les

1. PRESENTACIÓ

Des de la detecció de tumors fins als cotxes autònoms: creiem que mitjans com *The New York Times*, la intel·ligència artificial (IA) i les tècniques d'aprenentatge automàtic tenen la capacitat d'automatitzar un gran nombre de reptes socials.¹ Si se'ls proporciona contingut suficient per analitzar i entrenar, els algorismes poden desenvolupar models estadístics per substituir activitats amb presa de decisions que hom creu que requereixen intel·ligència humana, com ara conduir un vehicle o interpretar una radiografia. Actualment tant els distribuïdors comercials com els informàtics tenen la vareta màgica de l'estadística i l'aprenentatge automàtic per donar sentit a grans volums d'arxius no-estructurats. Cada vegada s'estan contractant més enginyers de dades per explotar els continguts i les metadades escampats per unitats compartides i aplicacions de llegat per de-

tectar tendències i anomalies de la intel·ligència empresarial. En aquest context, els arxivers poden «exercir de col·laboradors del procés analític, proporcionar informació sobre la ubicació de les dades i ajudar l'analista visual a comprendre millor les dades i confiar-hi tot explicant-li el context de creació, la història de l'estructura i la semàntica i la cadena de vigilància d'aquestes» (Lemieux, 2014).

Tanmateix, entre els arxivers circulen molts equívocs i falses esperances sobre com l'aprenentatge automàtic es pot utilitzar en els arxius.² Per això, en aquest article es vol ajudar els professionals a comprendre millor les possibilitats i els límits de l'automatització, centrant-se en dos mètodes específics de les tècniques d'aprenentatge automàtic: els models temàtics (MT) i els *word embeddings* (WE). Aquests mètodes d'aprenentatge automàtic són molt utilitzats en projectes digitals d'humanitats per a l'anàlisi de grans corpus no-estructurats. Els arxius s'enfronten cada vegada més a grans volums de continguts poc o gens estructurats que es troben en servidors de fitxers amb metadades escasses o inexistentes. Tal com es demostrarà en l'estudi de cas, els MT i els WE permeten obtenir resultats d'una manera relativament ràpida, la qual cosa pot propiciar que es plantegi l'aplicació d'una política de dades connectades per crear un accés per temes que abasti diversos fons o per experimentar amb mètodes d'aprenentatge automàtic més complexos i que requereixin més recursos amb relació a la classificació automàtica.

A fi d'aclarir una part de la confusió i la vaguetat actuals pel que fa a l'aprenentatge automàtic i l'automatització, en la primera meitat de l'article s'estableix una tipologia dels diferents mètodes que s'han utilitzat durant dècades per automatitzar uns aspectes concrets del cicle de vida de la informació. L'última meitat de l'article està dedicada a descriure amb més detall els MT i els WE. Perquè la presentació d'aquestes tècniques sigui el més pragmàtica possible, els MT i els WE s'il·lustren amb exemples d'un estudi de cas experimental sobre el corpus arxivístic de la Comissió Europea. L'article acaba amb una exposició d'idees sobre com els resultats dels MT i els WE es poden utilitzar com a base de partida per a un accés per temes a grans volums d'arxius no-estructurats per mitjà de dades connectades.

2. QUÈ I COM CAL AUTOMATITZAR?

Malgrat l'ús generalitzat de termes com ara «aprenentatge automàtic», «web semàntic» o «dades connectades», la bibliografia arxivística encara no ha proporcionat gaire orientació sobre què diferencia aquests mètodes i com poden

interactuar. La directriu «Automated Electronic Records Management Report/Plan» (informe/pla per a la gestió automatitzada d'arxius electrònics) dels NARA ha estat un document de referència, en què es reconeix la necessitat d'integrar l'automatització com un aspecte essencial de l'estratègia per a la gestió d'arxius.³ En l'informe es distingeixen cinc mètodes d'automatització diferents: automatització inexistent (gestió manual), automatització basada en regles, automatització orientada als processos empresarials i el flux de treball, instruments modulars i reutilitzables per a la gestió d'arxius i classificació automàtica.

A més, en l'informe s'ofereix un resum molt necessari de la urgència de l'automatització. Això no obstant, la tipologia dels NARA barreja mètodes (manual, basat en regles), aplicació (instruments modulars i reutilitzables per a la gestió d'arxius) i funcionalitats (classificació automàtica).

Amb l'objectiu d'aclarir quins mètodes d'automatització es poden utilitzar segons el tipus de funcionalitat, en els dos apartats següents es resumeix com dues branques diferents de la informàtica tenen la capacitat de fer aportacions significatives per als arxius:

- **Regles:** basades en un model abstracte dels continguts i el seu domini d'aplicació, es poden automatitzar les decisions sobre els continguts. El mètode Capstone dels NARA per als correus electrònics n'és un exemple senzill: a partir del moment en què algú arriba a una determinada posició en la jerarquia d'una empresa, el seu correu electrònic es captura automàticament, per exemple.

- **Estadística:** basada en una anàlisi dels continguts en si, amb tècniques d'aprenentatge automàtic supervisat o no. Els instruments de classificació automàtica per separar els correus electrònics que tenen valor empresarial dels que no en tenen, basats en un conjunt d'entrenament, són un exemple típic d'aprenentatge automàtic supervisat.

Ambdós mètodes presenten avantatges i limitacions, que s'assenyalaran a continuació. En aquest article ens centrem en una presentació de l'aprenentatge automàtic que entra en la categoria de l'«estadística». A la pràctica, les regles i l'estadística es poden combinar, tal com s'exposarà cap al final de l'article.

2.1 DEFINICIÓ DE REGLES: DEL CAMÍ DE LA INTEL·LIGÈNCIA ARTIFICIAL ALS MOTORS DE REGLES I LES DADES CONNECTADES

Des de la dècada dels seixanta, el món de la intel·ligència artificial ha desenvolupat mètodes per representar el coneixement i algorismes que poden deduir coneixements nous a partir d'un conjunt predeterminat de regles. Els sistemes basats en regles requereixen que l'usuari defineixi les regles perquè el programari pugui deduir què ha de fer en una situació determinada. El perill d'aquest mètode és que si en les regles no es té en compte un escenari es produeix soroll i, per tant, calen encara més regles per poder descriure cada escenari possible. Als anys vuitanta aquesta branca de la recerca va culminar amb la creació dels que aleshores es van anomenar sistemes experts. Aquest tipus de programari constava de bases de dades o ontologies amb una gran quantitat de fets i enunciats connectats per mitjà de la lògica formal. L'inconvenient d'aquest mètode és la falta d'adaptabilitat: el sistema només pot funcionar basant-se en la informació de què disposa. Això implica que aquests sistemes només poden ser operatius en uns dominis d'aplicació especialitzats i ben delimitats, com ara una especialitat mèdica concreta. A més, el cost de crear i mantenir les regles acostuma a ser prohibitiu.

La complexitat de desenvolupar i aplicar ontologies a gran escala als diferents dominis d'aplicació ha quedat reflectida en les dificultats d'executar la visió del web semàntic. Impulsat per Tim Berners-Lee des del 2001, el web semàntic pretén aconseguir que la informació a Internet sigui llegible per una màquina formalitzant el significat de les dades publicades a Internet per mitjà del model de dades RDF i ontologies de suport. Per la dificultat d'aplicar ontologies complexes a gran escala, el 2006 Berners-Lee va replantejar la seva visió d'un web més estructurat d'una manera més pragmàtica, batejant el web semàntic amb el nom de dades connectades.⁴ Al llarg dels segles XX i XXI, les biblioteques sempre han estat més avançades que els arxius pel que fa al nivell d'interoperabilitat de les dades i les innovacions tecnològiques. Per això, és interessant que els arxivers observin com els bibliotecaris han aplicat el paradigma de les dades connectades. Per exemple, la Biblioteca del Congrés dels EUA ha invertit molts esforços a promoure Bibframe, un format que ha de permetre la conversió de fitxers MARC en RDF. Malgrat els grans esforços que s'han fet els darrers anys, en l'àmbit bibliotecari encara no hi ha consens internacional sobre la importància i la viabilitat de la iniciativa per la complexitat de crear des de zero i mantenir grans volums de dades en RDF. La dificultat de desenvolupar i aplicar

ontologies es reflecteix en els esforços que els arxius han fet recentment per avançar lentament cap al territori de les dades connectades. L'ICA ha iniciat el projecte Records in Context (RiC, arxius en context), que pretén integrar la semàntica de normes de l'ICA ja existents, com la ISAD(G) i la ISAAR(CPF), en una ontologia global. Fer un comentari extens sobre aquest projecte queda fora de l'abast d'aquest article, però Ross Spencer destaca encertadament la complexitat del mètode tot fent referència a les 73 possibles relacions d'arxiu a arxiu (Spencer, 2017). La iniciativa de W3C anomenada Architypes ofereix un altre mètode: el projecte prova de reutilitzar etiquetes existents de Schema.org per reduir al mínim la creació de definicions noves. Totes aquestes iniciatives estan en marxa i, de moment, no es pot dir que hi hagi una manera àmpliament acceptada de traduir les eines tradicionals de cerca d'arxius en l'àmbit de les dades connectades.

2.2 CONFIANÇA EN LES ESTADÍSTIQUES: APRENETATGE AUTOMÀTIC

En les dues últimes dècades, hem vist com augmentaven no només la quantitat de dades disponibles i el volum de documents, sinó també la varietat dels tipus de dades, la complexitat de les fonts i la falta d'estructuració de la informació. El canvi de panorama ha fet que els mètodes basats en regles que triomfaven al segle XX quedin antiquats en el millor dels casos i fins i tot obsolets en el context de l'auge de les dades massives, cosa que ha portat Guruswamy a anomenar-los «dinosauris al món de les dades massives».⁵ Així doncs, veiem una substitució dels mètodes basats en els coneixements pels mètodes basats en les dades, la qual cosa significa que, en general, les regles tradicionals queden enrere i deixen espai als sistemes estadístics que intenten trobar una estructura en l'abundància d'informació disponible avui dia. L'enorme avantatge en comparació amb el mètode basat en regles anterior és que no cal desenvolupar un model a priori d'un domini d'aplicació que després s'utilitza per aplicar les regles. Chris Andersons va formular aquest canvi de paradigma amb audàcia quan va dir que «amb dades suficients, els números parlen per si sols».⁶

Quan es parla dels algorismes de l'aprenentatge automàtic, és important fer una distinció entre mètodes supervisats i no-supervisats. A diferència del que succeeix amb els infants, per a qui es desenvolupen mètodes per supervisar-los abans que ells adquireixin mètodes propis per fer front al món, en el desenvolupament

lupament de l'aprenentatge automàtic els mètodes supervisats serien anteriors als no-supervisats. És difícil determinar amb exactitud en quin moment van començar les pràctiques d'aprenentatge automàtic, però molts el situen en la teoria de Hebb (Hebb, 2005), publicada originalment el 1949, en què s'explicava l'adaptació de les neurones cerebrals durant un procés d'aprenentatge. Hebb descriu un procés no-supervisat, resumit amb la màxima «les cèl·lules que es disparen juntes romanen connectades», que subratlla directament una de les principals característiques dels mètodes no-supervisats, concretament la generació ascendent de resultats, per la qual cosa no se sap amb antelació quin forma prendran els resultats. En canvi, en el cas dels mètodes supervisats, primer cal proporcionar exemples correctes per a l'entrenament, la qual cosa determina l'estructura dels resultats en el nombre de categories que s'assignen a les dades introduïdes. Per això, una de les tasques més importants de l'aprenentatge supervisat és la classificació en categories dissenyades amb anterioritat, mentre que en els mètodes supervisats es tracta d'agrupar les dades sense saber amb antelació què representaran aquests grups. Gràcies a això, els mètodes no-supervisats —entre els quals els models temàtics són una de les sèries d'algorismes més utilitzades per a les dades textuals— són adequats per tractar grans quantitats de dades desconegudes i ajudar en tasques com ara la recuperació o la síntesi d'informació. Així mateix, és evident que, com que no s'han donat «exemples correctes» a un algorisme d'aprenentatge no-supervisat, és difícil avaluar els resultats, la qual cosa també queda clara amb els exemples que es presenten més endavant en aquest article.

En els darrers anys, en la gestió dels arxius s'ha experimentat gairebé en exclusiva amb els mètodes d'aprenentatge automàtic supervisat. A més, grans proveïdors de programari, com ara OpenText, han ofert eines que poden classificar automàticament documents en categories predeterminades. El programari ofereix interfícies fàcils d'utilitzar que permeten als arxivers seleccionar un corpus de prova, classificar manualment documents en un nombre limitat de categories i, a continuació, comprovar la qualitat de la classificació automàtica basada en mostres. Això no obstant, els proveïdors no proporcionen cap estudi de referència ni cap mètode clar per valorar la qualitat de les seves eines d'una manera objectiva. Vellino i Alberts van publicar un estudi recent i molt detallat sobre les possibilitats i els límits de l'avaluació automàtica dels correus electrònics (Vellino, 2016; Hengchen, 2016). En l'article se subratlla la necessitat de formalitzar el context organitzatiu duent a terme entrevistes semiestructurades i consultes cognitives, seguides d'una anàlisi de les dades. Amb aquesta informació, es va crear un model abstracte de classificació que consistia en dues categories

superiors, correus amb valor empresarial i sense, que després es dividien en 13 subcategories. En aquest estudi es deixa molt clar que l'aplicació de la classificació automàtica requereix uns esforços considerables i no és tan fàcil com els proveïdors suggereixen.

Com que l'aplicació de l'aprenentatge automàtic supervisat no és tan senzill com molts pensen, en aquest article es vol subratllar les possibilitats de dos mètodes d'aprenentatge automàtic no-supervisat per als fons arxivístics: els models temàtics (MT) i els *word embeddings* (WE). El terme «no-supervisat» s'utilitza perquè el procés no implica utilitzar un corpus entrenat prèviament. Primer presentarem els models temàtics (MT), que els darrers anys han agafat força en l'àmbit de les humanitats digitals per explorar i interpretar corpus molt grans de documents amb textos íntegres (Klein, 2015). Aquest model probabilístic generatiu agrupa un nombre determinat de paraules clau extretes d'una col·lecció de documents en el que s'anomenen temes. Un exemple de tema (tema 33 dels nostres resultats) basat en els fons de la CE, que presentarem tot seguit, és aquest grup de deu termes:

Gas combustible energia electricitat carbó potència
nuclear subministrament indústria producció

Després de llegir el grup de paraules clau, comprenem que el subconjunt de documents del nostre corpus amb aquest tema probablement tracta de com la CE va afrontar l'ús i el subministrament de recursos energètics. Aquest exemple mostra la potència, però també un dels aspectes problemàtics, dels MT: la interpretació dels temes. Tal com (Chang, 2009) va indicar, és difícil presentar normes objectives per controlar quines interpretacions del model temàtic són vàlides i quines no ho són. La dificultat interpretativa es deu al fet que, quan se'ls posa una llista de paraules al davant, per als éssers humans és psicològicament atractiu donar-li una interpretació significativa. Fins i tot en alguns casos clars —que sovint s'han seleccionat— es pot veure que de vegades es pot fer una interpretació sòlida, però és difícil discernir on es troba la zona grisa de la interpretació. Això es deriva d'una dificultat interpretativa inherent als models temàtics: que ens agradaria descobrir que representen conceptes ocults en el text. Malgrat que sabem que els grups de paraules clau són una mera representació de la seva aparició en la col·lecció de documents, tenim l'expectativa que aquestes paraules es corresponguin amb conceptes precisos per la hipòtesi distributiva en el camp de la semàntica lingüística, segons la qual el significat d'una paraula està determinat pel que l'acompanya. Dit d'una altra manera, d'acord amb

aquesta hipòtesi, les paraules que apareixen en el mateix document tenen un vincle semàntic. A la pràctica, sovint els temes són difícils d'interpretar, ja que no es poden assignar fàcilment a un únic concepte sinó que són una combinació de dos o més conceptes.

A diferència dels models temàtics, que ens permeten comprendre com els documents estan relacionats entre si segons els temes identificats, els WE s'utilitzen per entendre les relacions semàntiques entre les paraules. El terme es va popularitzar amb l'article fonamental de Mikolov (Mikolov, 2013), en què es descriu Word2Vec, un joc d'eines gratuït en línia per entrenar WE en un corpus o bé per utilitzar els seus vectors de paraules entrenats prèviament basats en el corpus de Google Press. Mitjançant una anàlisi estadística d'un corpus enorme, es pot determinar, per exemple, que els termes «Londres» i «Anglaterra» tenen la mateixa relació entre si que, per exemple, «París» i «França». L'algorisme desconeix la semàntica de la relació, però ens permet controlar com aquests termes interactuen en l'espai vectorial i, així, extreure relacions semàntiques com l'esmentada («és la capital de»). Gràcies a la representació vectorial d'aquestes paraules, podem respondre preguntes com ara «Quina és la capital de França?» simplement començant amb el vector de «Londres», traient el vector d'«Anglaterra» i afegint el vector de «França». El vector corresponent s'ha de situar prop de «París» i, per tant, respondre la nostra pregunta correctament. A continuació, els exemples d'un estudi de cas experimental mostraran com s'ha creat un mètode original per aplicar els WE als resultats dels MT, la qual cosa permet als arxivers aprofitar l'ús de l'aprenentatge automàtic no-supervisat per als fons arxivístics. En aquest article, els autors volen fer una presentació global de les possibilitats i els límits dels diferents mètodes d'aprenentatge automàtic per a l'arxivística sense fixar-se en els detalls d'una avaluació a gran escala dels resultats.

3. ESTUDI DE CAS EXPERIMENTAL: ARXIUS DE LA COMISSIÓ EUROPEA

Quan i com les qüestions mediambientals van començar a influir sobre l'elaboració de polítiques agrícoles a la Comissió Europea (CE)? Quins són els documents clau per analitzar el debat sobre la producció d'energia nuclear des dels anys seixanta? Aquests són dos exemples típics de preguntes que els historiadors es poden plantejar amb relació als fons arxivístics de la CE. En aquest context, la digitalització massiva dels arxius de la CE ofereix possibilitats noves

i interessants de consultar i analitzar el corpus arxivístic de manera automatitzada. Això no obstant, hi ha una gran diferència entre les promeses dels defensors de les dades massives, que es basen en l'estadística per descobrir patrons i tendències en grans volums de dades no-estructurades, i la manera en què els historiadors poden arribar a beneficiar-se de les metadades generades automàticament a l'hora d'estudiar arxius i trobar respostes a les seves preguntes. Actualment, els investigadors només poden realitzar consultes de text complet per entendre aquest corpus enorme, tal com s'il·lustra en la figura 1. En el context d'una col·laboració en recerca, els autors vam rebre una còpia local del corpus dels arxius de la CE que ens va permetre processar i aplicar diversos mètodes d'aprenentatge automàtic.⁷



Figura 1. Interfície de cerca dels arxius COM del fons arxivístic de la CE, disponible a http://ec.europa.eu/historical_archives/archisplus/

3.1 CONJUNT DE DADES I TREBALL PREVI

El conjunt de dades, que abraça el període que va del 1958 al 1982, és multilingüe: conté documents en francès, neerlandès, alemany, italià, danès, anglès i grec, que aleshores eren les llengües oficials del que ara s'anomena Unió Europea. Per a aquest estudi de cas experimental, només s'ha tingut en compte el corpus en anglès, que representa un total d'11.868 documents. En el context del primer estudi exploratori de Hengchen (Hengchen, 2016), es va aplicar el model

Latent Dirichlet Allocation (LDA), que és l'algorisme d'MT d'ús més generalitzat, al corpus. Com ja s'ha assenyalat, el conjunt de dades pràcticament no presenta metadades, a part d'un fitxer XML per a cada PDF que conté informació bàsica com un identificador únic, una data de creació, el número d'un volum de referència, la llengua i el títol del document i poca informació més. No hi ha cap informació sobre el contingut dels documents en termes d'especialitats i temes, la qual cosa dificulta que els historiadors utilitzin el conjunt de dades. En el context d'aquest primer estudi exploratori, els autors van interpretar manualment les especialitats amb l'objectiu d'afegir un descriptor del tesaurus EuroVoc. En la figura 2 es presenten tres exemples d'especialitats i els descriptors de l'EuroVoc que es van afegir manualment als temes.

URI	label	tokens			
http://eurovoc.europa.eu/2965	agricultural aid	agricultural	areas	aid	measures
		premium	directive	number	eec
		farms	production		
http://eurovoc.europa.eu/852	ECSC aid	coal	steel	ecsc	aid
		industry	production	iron	decision
		measures	community		
http://eurovoc.europa.eu/1418	textile industry	fabrics	textile	woven	knitted
		crocheted	fibres	community	agreement
		products	yarn		

Figura 2. Etiquetatge manual dels resultats dels MT amb l'EuroVoc.

És important subratllar que en aquest primer estudi exploratori els autors van ser incapaços d'assignar una etiqueta a aproximadament el 30% dels temes pel caràcter molt general dels termes (per ex., *agreement* [acord], *community* [comunitat], *parties* [parts], *negotiations* [negociacions]) o bé pel fet que els autors no van poder trobar una relació semàntica entre els termes (per ex., *lights* [llums] *bmw* [bmw] *brazil* [brasil] *eec* [cee] *coffee* [cafè]). Per a algunes especialitats, la causa principal va ser el soroll del ROC (reconeixement òptic de caràcters) traduït en termes com *cf*, *ii* o *ir*.

Malgrat tot, l'etiquetatge manual dels temes amb descriptors del tesaurus EuroVoc és millorable. Un dels problemes clau és la interpretació dels grups de termes que formen un tema. Amb els exemples, es pot observar que en una gran part dels casos els temes no assenyalen un concepte clar, sinó que sovint són una combinació de conceptes. Aquest aspecte fa que el procés d'etiquetatge manual sigui inherentment subjectiu i problemàtic. Seria ideal poder fer un procés automatitzat de reconciliació, com descriuen (van Hooland, Verborgh, De Wilde, & Hercher, 2013). Lamentablement, l'heterogeneïtat semàntica dels

temes també constitueix un obstacle per a aquest procés de reconciliació, ja que no hi ha cap manera d'indicar com es poden tractar per separat els diferents conceptes dins d'un tema.

3.2 APROFITAR ELS WE PER ANALITZAR MILLOR ELS RESULTATS DELS MT

Com hem après de les tecnologies més recents, els MT es poden considerar un mètode per saber més dels temes que es tracten en un extens corpus de documents, mentre que els WE (entrenats prèviament) es poden considerar una representació vectorial de caràcter general del llenguatge mateix que ens permet comprendre la distància entre les paraules. En el context de la seva recerca doctoral, un dels autors va crear una metodologia original que combina ambdues fonts d'informació.⁸ Com que amb els WE es poden generar representacions vectorials del conjunt del llenguatge, això ens permet estimar la relació semàntica dels termes d'un mateix tema. Dit d'una altra manera, volem automatitzar la identificació dels diferents conceptes inclosos en un tema.

Hem observat que, en aplicar els *word embeddings* als resultats dels models temàtics, es produeixen dues situacions, que es tracten en l'apartat següent. Els resultats que es descriuen a continuació il·lustren que alguns temes s'utilitzen per marcar un únic concepte (els temes com a conceptes), mentre que uns altres —amb diferència el major nombre de temes— s'utilitzen per indicar una col·locació de dos o més conceptes (en aquest article, els temes com a col·locacions).

3.3 RESULTATS

L'LDA es va aplicar al corpus en anglès, tal com ja s'ha assenyalat. Els resultats complets es poden analitzar a Github.⁹ Dins del conjunt de dades es fan servir tres codis de color diferents que ajuden a visualitzar els diferents resultats dels WE sobre els resultats dels MT que s'indiquen a continuació:

- Els termes en taronja indiquen un tema que representa un únic concepte

- El blau i el vermell s'utilitzen per assenyalar el primer i el segon concepte d'un tema que consti de dos conceptes diferents

- Els termes de color blau cel són els termes que no mostren una relació clara amb els termes del tema que els envolten

Mitjançant les representacions vectorials de les paraules clau d'un tema, descobrim que alguns temes indiquen un concepte general, representat amb els termes de color taronja. Un bon exemple d'això es troba en el tema 17, que indica l'autoritat territorial. Com que en el nostre corpus es fa referència a l'autoritat de diverses estructures de convivència, les descobrim en forma de termes del nostre tema que mostren una relació semàntica, com *community* (comunitat), *territory* (territori), *national* (nacional), *country* (país), *state* (estat), i *states* (estats). D'altra banda, les diferents maneres en què es pot parlar de la seva autoritat es troben en les paraules que mostren la màxima coherència semàntica, com *authorities* (autoritats), *legal* (jurídic), *rights* (drets), *authority* (autoritat), *undertakings* (projectes), *directive* (directiva), *provisions* (disposicions), *rules* (regles) and *law* (legislació). De passada, observem que les paraules *authorities* i *authority* no es troben l'una al costat de l'altra, tal com esperaríem en el cas de paraules amb el mateix lexema. Tanmateix, en aquest cas és evident que ambdues paraules tenen un ús molt diferent, atès que *authority* indica la facultat de valoració i actuació d'una persona o un organisme, mentre que *authorities* es pot referir a aquesta facultat, però també a les autoritats mateixes, com ara el departament de policia o l'òrgan jurisdiccional.

En alguns casos, veiem que la coherència semàntica dels termes queda verificada però no identifica un concepte clar. Per exemple, en el tema 31 els WE agrupen deu termes: *vocational* (professional), *labor* (feina), *education* (educació), *employment* (ocupació), *health* (salut), *social* (social), *migrant* (migrant), *worker* (treballador), *work* (treball) i *working* (treballar). Es pot suposar que el tema té relació amb la seguretat social dels treballadors migrants, però els documents agrupats sota aquest tema també poden tenir a veure amb l'impacte de l'educació sobre l'ocupació dels treballadors migrants, per exemple.

Aquesta anàlisi ens porta a la possibilitat que un tema sigui la col·locació de dos conceptes, el primer de color blau i el segon vermell. Aquesta situació és molt més habitual que els temes que representen només un concepte, marcats amb color taronja. Aquestes col·locacions indiquen que hi ha una relació important entre aquests dos conceptes perquè apareixen amb freqüència en la col·lecció

de documents. En les dades es troben alguns exemples clars d'aquestes col·locacions. Per exemple, el tema 30 uneix dos conceptes: indústria i estudis. Per tant, és molt probable que en els documents amb una puntuació elevada per a aquest tema es tractin els estudis de la indústria i s'avaluïn el progrés dels mercats i el treball. La nostra metodologia agrupa els termes relacionats amb la indústria (*project* [projecte], *development* [desenvolupament], *market* [mercat], *industry* [indústria], *industrial* [industrial], *system* [sistema]) i, en segon lloc, termes relacionats amb els estudis (*study* [estudi], *survey* [enquesta], *data* [dades] i *statistic* [estadística]). El concepte d'indústria es pot trobar diverses vegades dins dels temes. Per exemple, a més de trobar-se en el tema 30 al qual acabem de fer referència, en el tema 33 trobem els termes *industry* (indústria), *supply* (subministrament) i *production* (producció), que formen part del concepte d'indústria, en col·locació amb el concepte de recursos, expressat amb les paraules *gas* (gas), *fuel* (combustible), *energy* (energia), *electricity* (electricitat), *coal* (carbó), *power* (potència) i *nuclear* (nuclear).

Això no obstant, els WE no sempre aconsegueixen agrupar els termes d'un tema en un concepte. És el que succeeix, per exemple, amb el tema 27. Hi ha dos conceptes diferents: el primer consta de *price* (preu), *market* (mercat) i *product* (producte); el segon, de *milk* (llet), *sugar* (sucre) i *wine* (vi). A més, es mostren quatre termes de color blau cel, color que indica que aquests termes no tenen una relació clara amb els termes del tema que els envolten: *production* (producció), *quality* (qualitat), *variety* (varietat) i *marketing* (comercialització).

D'acord amb els exemples analitzats, sens dubte hi ha casos en què els WE proporcionen un valor afegit evident a l'hora d'interpretar els resultats dels MT. Com se'n poden beneficiar els arxivistes? En el futur volem experimentar amb un procés de reconciliació entre els termes dels temes i el tesauro EuroVoc. El fet de poder dividir automàticament un tema en dos conceptes diferents ens permetrà augmentar la rellevància dels resultats de la reconciliació, ja que no ens veurem obligats a assignar automàticament una etiqueta a un tema que en realitat representi dos conceptes diferents.

4. CONCLUSIONS I TREBALL EN EL FUTUR

Amb l'ajuda d'un estudi de cas experimental, en aquest article s'ha fet una introducció general a l'automatització dels fons arxivístics i en concret a l'ús de

tècniques d'aprenentatge automàtic no-supervisat. Amb el creixement exponencial del nombre de documents amb textos íntegres digitalitzats dels fons arxivístics, els arxivers necessiten alternatives a la creació manual de metadades. Amb l'enrenou que avui envolta l'ús de l'aprenentatge automàtic, l'arxivística centra gairebé tota la seva atenció en com els mètodes d'aprenentatge automàtic supervisat poden servir per a la classificació automàtica. Tanmateix, tal com s'ha subratllat en aquest article, aquest plantejament requereix molts coneixements i recursos per definir un corpus de prova i ajustar el procés mentre els resultats se sotmeten repetidament a prova. Així doncs, en aquest article s'han explorat les possibilitats que ofereixen mètodes no-supervisats com els MT i els WE, amb un estudi de cas real basat en els fons digitalitzats de la CE.

Tal com mostren els exemples de l'estudi de cas, hi ha motius per a l'entusiasme, però també hi ha zones molt problemàtiques que fan palesa la necessitat de continuar treballant abans que els arxivers puguin començar a aplicar els MT i els WE a gran escala operativa. Començarem per les males notícies. Tal com ja s'ha assenyalat en la bibliografia existent en l'àmbit de la lingüística computacional, la interpretació dels resultats dels MT és complexa i exigeix analitzar manualment com els diversos termes reflecteixen un tema present en un corpus de grans dimensions. A més, la configuració del paràmetre k , el nombre de termes per tema i els termes inclosos com a paraules reservades tenen un fort impacte sobre els resultats. La bibliografia científica disponible no ofereix una anàlisi clara de la influència d'aquests paràmetres sobre els resultats, cosa que subratlla el caràcter de «caixa negra» que té l'ús d'aquests mètodes. Això no obstant, hi ha prou motius perquè els arxivers segueixin molt de prop els mètodes d'aprenentatge automàtic. En aquest article s'ha demostrat com, amb l'ús dels WE, es pot simplificar la complexitat d'interpretar els resultats dels MT, ja que els WE poden ajudar a identificar automàticament els diferents conceptes ocults dins d'un tema. Aquest mètode té el potencial de facilitar, més endavant, l'etiquetatge automatitzat de temes amb encapçalaments d'un vocabulari controlat. A més, és important assenyalar que el mètode és independent del llenguatge i es pot aplicar en una gran varietat de dominis d'aplicació.

En resum, en aquest article se subratlla el caràcter semiautomatitzat de l'aplicació de tècniques d'aprenentatge automàtic. En les etapes crucials del procés, els experts en arxivística han de prendre decisions estratègiques i intervenir manualment. Per tant, podem concloure que l'automatització és una eina que no substitueix els arxivers professionals.

NOTES

1. Vegeu articles com <https://www.nytimes.com/2016/10/17/technology/ibm-is-counting-on-its-bet-on-watson-and-paying-big-money-for-it.html>.
2. En aquest article utilitzem els termes «governança de la informació» i «gestió de documents» indistintament. El debat sobre les definicions i els límits exactes de cada disciplina queda fora de l'abast d'aquest article, però l'automatització té una funció en totes dues.
3. Per consultar l'informe, visiteu <https://www.archives.gov/records-mgmt/prmd/automated-erm.html>.
4. Per obtenir una perspectiva més exhaustiva del desenvolupament de les dades connectades, consulteu l'article «Linked data for libraries, archives and museums», de van Hooland i Verborgh (Facet, 2004).
5. Vegeu <http://bigdata.teradata.com/US/Articles-News/Data-Science--Machine-Learning-Vs--Rules-Based-Systems/>.
6. Vegeu <https://www.wired.com/2008/06/pb-theory/>.
7. El conjunt de dades s'ha creat de conformitat amb el Reglament (CEE, Euratom) núm. 354/83, d'1 de febrer del 1983, relatiu a l'obertura al públic dels arxius històrics de la Comunitat Econòmica Europea i de la Comunitat Europea de l'Energia Atòmica. El text jurídic i totes les esmenes estan disponibles a <http://eur-lex.europa.eu/legal-content/ES/TXT/?qid=1517834735101&uri=CELEX:31983R0354> (en castellà). Després de signar un acord de confidencialitat, el grup de recerca MaSTIC de la Universitat Lliure de Brussel·les va obtenir un corpus de 138,3 GB i 24.787 documents del fons arxivístic de la Comissió Europea.
8. Actualment Mathias Coeckelberghs prepara un article exhaustiu en què presenta l'ús dels WE en la interpretació dels resultats dels MT.
9. Els resultats de la recerca estan disponibles a <https://github.com/MathiasCoeckelbergs/Concepts-within-Topics>.

BIBLIOGRAFIA

CHANG, Jonathan. «Reading tea leaves: How humans interpret topic models». *Advances in neural information processing systems*. 2009, p. 288-296.

HEBB, Donald. *Organization of Behavior*. Psychology Press, 2005.

HENGCHEN, Simon. «Exploring archives with probabilistic models: Topic Modelling for the valorisation of digitised archives of the European Commission». 2016 *IEEE International Conference on Big Data*. IEEE, 2016, p. 3245-3249.

KLEIN, Lauren F. «Exploratory thematic analysis for digitized archival collections». *Digital Scholarship in the Humanities*. Vol. 30, núm. 1 (2015), p. 130-141.

LEMIEUX, Victoria L. «Meeting Big Data challenges with visual analytics: The role of records management». *Records Management Journal*. Vol. 24, núm. 2 (2014), p. 122-141.

MIKOLOV, Tomas. «Linguistic regularities in continuous space word representations». *HLT-NAACL*. Núm. 13 (2013), p. 746-751.

SPENCER, Ross. «Binary trees? Automatically identifying the links between born-digital records». *Archives and manuscripts*. Vol. 45, núm. 2 (2017), p. 77-99.

VAN HOOLAND, Seth; VERBORGH, Ruben; DE WILDE, Max; HERCHER, Johannes. «Evaluating the success of vocabulary reconciliation for cultural heritage collections». *Journal of the American Society for Information Science and Technology*. Vol. 64, núm. 3 (2013), p. 464-479.

VELLINO, André. «Assisting the appraisal of e-mail records with automatic classification». *Records Management Journal*. Vol. 26, núm. 3 (2016), p. 293-313.

RESUM

L'enrenou que avui envolta l'aprenentatge automàtic ha provocat una nova onada d'esperança i entusiasme entre els arxiviers, que fan servir algorismes per reduir el nombre d'intervencions manuals en la gestió i la valoració de grans volums de contingut no-estructurat. Els agents comercials promouen instruments ja preparats per a la classificació automàtica, però és tan fàcil integrar l'aprenentatge automàtic en un context de governança dels arxius i la informació com actualment s'assenyala en la premsa generalista i la bibliografia informàtica? D'altra banda, quina relació té l'aprenentatge automàtic amb el debat al voltant de l'ús de dades connectades per a les descripcions arxivístiques? En aquest article tenim l'objectiu d'aportar pragmatisme al debat sobre l'automatització de les descripcions arxivístiques tot oferint una descripció general de les possibilitats i els límits de l'aprenentatge automàtic des de la perspectiva arxivística. En l'àmbit de les humanitats digitals, dos mètodes han esdevingut considerablement populars: els models temàtics (MT) i els word embeddings (WE; representació de paraules com a vectors). En aquest article no només s'introdueixen aquests mètodes d'apre-

mentatge automàtic no-supervisat per al col·lectiu dels professionals de l'arxivística, sinó que també es demostra com es poden aprofitar els WE per interpretar els resultats dels MT d'una manera més efectiva, la qual cosa és una aportació innovadora. Per il·lustrar ambdós mètodes ens basem en un estudi de cas experimental dels fons digitalitzats de la Comissió Europea (CE).

RESUMEN

El actual revuelo en torno al aprendizaje automático ha provocado una nueva ola de esperanza y entusiasmo entre los archiveros, que usan algoritmos para reducir el número de intervenciones manuales en la gestión y la valoración de grandes volúmenes de contenido no estructurado. Los agentes comerciales promueven instrumentos ya preparados para la clasificación automática, pero: ¿es tan fácil integrar el aprendizaje automático en un contexto de gobernanza de archivos e información como actualmente se señala tanto en la prensa generalista como en la literatura informática? Por otra parte, ¿qué relación tiene el

aprendizaje automático con el debate en torno al uso de datos conectados para las descripciones archivísticas? En este artículo tenemos por objetivo aportar pragmatismo al debate sobre la automatización de las descripciones archivísticas ofreciendo una descripción general de las posibilidades y los límites del aprendizaje automático desde una perspectiva archivística. En el ámbito de las humanidades digitales, dos métodos han ganado considerable popularidad: los modelos temáticos (MT) y las word embeddings (WE; 'representación de palabras como vectores'). En este artículo no solo se introducen estos métodos de aprendizaje automático no supervisado para el colectivo de los profesionales de la archivística, sino que también se demuestra cómo se pueden aprovechar las WE para interpretar los resultados de los MT de una manera más efectiva, lo cual es una aportación innovadora. Para ilustrar ambos métodos nos basamos en un estudio de caso experimental de los fondos digitalizados de la Comisión Europea (CE).

ABSTRACT

The current hype surrounding machine learning has spurred a new wave of hope and enthusiasm amongst archivists, who are relying on algorithms to reduce the amount of manual intervention in the management and appraisal of large volumes of non-structured content. Commercial players promote out-of-the-box tools for auto-classification, but is the integration of machine learning within an archival and information governance context as straightforward as it is currently presented in both the popular press and computer science literature? Also, how does machine learning relate to the discussion regarding the usage of linked data for archival descriptions? This paper aims to bring a sense of pragmatism to the debate on the automation of archival descriptions by giving an overview of both the possibilities and the limits of machine learning from an archival perspective. Two methods have gained substantial popularity within the digital humanities: topic modeling (TM) and word embedding (WE). This paper not only introduces these non-supervised machine learning methods to the archival community, but also

demonstrates how WE can be leveraged to interpret the results of TM in a more meaningful manner, which is a novel contribution. Both methods are illustrated based on an experimental case study of digitized archival holdings of the European Commission (EC).

RÉSUMÉ

La forte médiatisation actuelle de l'apprentissage machine a fait naître de nouveaux espoirs et suscité beaucoup d'enthousiasme chez les archivistes, qui s'appuient sur des algorithmes pour réduire le nombre d'interventions manuelles lors de la gestion et de l'évaluation de gros volumes de contenus non structurés. Certaines entreprises proposent des outils clé en main pour la classification automatique, mais l'intégration de l'apprentissage machine dans un environnement d'archivage et de gouvernance de l'information est-il aussi simple que cela est actuellement présenté dans la presse grand public et la littérature de l'informatique ? Par ailleurs, comment l'apprentissage machine s'insère-t-il dans le cadre de la discussion sur l'utilisation du Web des données pour les descriptions

d'archives ? Le présent article vise à contribuer au débat sur l'automatisation des descriptions d'archives avec pragmatisme en proposant un aperçu des possibilités autant que des limites de l'apprentissage machine appliqué à l'archivage. Deux méthodes ont énormément gagné en popularité dans le cadre des sciences humaines numériques : les modèles thématiques (topic modeling, TM) et le plongement lexical (word embedding, WE). Après avoir présenté ces méthodes d'apprentissage machine non supervisé à la communauté des archivistes, le présent article démontre comment le plongement lexical peut être exploité pour interpréter les résultats d'un modèle thématique plus finement, ce qui constitue une contribution inédite. Les deux méthodes sont illustrées par une étude de cas expérimentale portant sur les archives numériques de la Commission européenne (CE).