

## Optimització en l'empresa

Aleix Ruiz de Villa  
*Data scientist*

Hi ha branques de les matemàtiques que han estat tradicionalment molt properes a les aplicacions en les empreses. L'optimització n'és, per naturalesa, una. Malgrat que actualment no té la popularitat social que té el *data science* o la que van tenir les matemàtiques financeres fa uns anys, l'optimització està i estarà present a les empreses per un llarg temps.

Per aquest motiu, hem preguntat a tres persones del món acadèmic quina és la seva experiència amb l'optimització i l'empresa, i què opinen del seu estat actual:

**Aureli Alabert [AA]** és professor titular de l'àrea d'Estadística i Investigació Operativa del Departament de Matemàtiques de la UAB i, actualment, és investigador del Grup de Recerca en Aplicacions i Models Matemàtics. Dirigeix, des del 2003, el Servei de Consultoria Matemàtica, un dels Laboratoris de Prestació de Serveis de la UAB. Va ser fundador, i vicepresident del 2011 al 2013, de la Red Española Matemática-Industria. També ha estat coordinador local a la UAB del màster internacional Mathematical Modelling in Engineering (2008–2019).

**Jordi Castro [JC]** és catedràtic d'universitat del Departament d'Estadística i Investigació Operativa de la Universitat Politècnica de Catalunya (UPC). El seu camp de recerca és l'optimització matemàtica. Va obtenir una llicenciatura en Informàtica per la UPC el 1991 (millor nota de la promoció). El 1995 va obtenir un doctorat a la mateixa UPC. Ha estat, entre d'altres, investigador principal de dos projectes europeus (programes marc V i VII de la UE) i de set projectes del pla estatal d'R+D (cinc de matemàtiques, un de TIC i un de tecnologies avançades de la producció). També ha estat investigador principal de nou contractes amb diverses empreses i entitats. És membre de la BGSMath i autor de més de 60 articles científics, publicats en revistes d'optimització i investigació operativa, com per

exemple *Mathematical Programming*, *SIAM Journal on Optimization*, *Operations Research*, *Management Science*, *INFORMS Journal on Computing* o *European Journal of Operations Research*.

**Victor Martínez de Albéniz [VMA]** és catedràtic a l'IESE's Department of Production, Technology and Operations Management, i també és director de la Divisió de Recerca de l'IESE. Es va incorporar a aquest centre després d'obtenir el doctorat a l'Operations Research Center de l'Institut de Tecnologia de Massachusetts (MIT) i el grau a l'École Polytechnique de França. La seva recerca es focalitza en el *supply chain management*, localització de les compres, producció i distribució perquè les companyies puguin competir amb més èxit de manera global. Ha publicat en revistes com *Management Science*, *Operations Research*, *Manufacturing and Services Operations Management* o *Production and Operations Management*. Ha rebut el suport de l'European Research Council (ERC), el Ministeri d'Economia i Competitivitat i la Fundació La Caixa. El 2015 va obtenir el premi Sabadell Herrero per recerca en economia, i el 2018, l'MSOM Young Scholar Prize.

### En quins camps es fan servir les tècniques d'optimització/investigació operativa? I en quins camps tenen potencial, però actualment encara no tenen gaire adopció?

[AA] L'optimització és, segons la meua percepció, el camp de la matemàtica amb aplicacions en àmbits més diversos, seguit, segurament, de les equacions diferencials. La transversalitat és gairebé absoluta a tots els sectors industrials i administracions. Sempre que hi ha alternatives diferents per prendre una decisió, i un criteri que fa unes decisions millors que altres (encara que estigui formulat vagament), tenim entre mans un problema d'optimització.

Això no vol dir que sapiguem resoldre'l de manera eficient. De fet, des del punt de vista aplicat, el que interessa no és trobar la millor opció absoluta, sinó trobar la millor solució possible en un temps limitat donat. Qualsevol millora de l'*statu quo* pot ser important per als interessats.

A l'enquesta Transmath, que vam fer fa deu anys a Espanya dins el projecte Consolider i-MATH, vam preguntar a 6.700 empreses d'un univers de 195.000, entre altres coses, les necessitats de tècniques de l'àrea d'Estadística i la Investigació Operativa que creien necessitar. Les sis primeres en quantitat de cites van ser:

- Estudis de mercat
- Estratègia, decisió, logística i planificació
- Control de qualitat
- Control i optimització de processos de producció
- Control i optimització d'estocs
- Anàlisi de riscos.

Només el sector de la construcció donava per sota d'un 40% d'empreses que citaven alguna d'aquestes tècniques.

[JC] Les tècniques d'optimització o investigació operativa tenen aplicació i es fan servir en molts camps de la ciència i l'enginyeria. Sense ser exhaustiva, i amb un cert biaix personal, la llista podria incloure:

Entre els usos més tradicionals, trobem les aplicacions en logística i planificació de la producció, com ara problemes de rutes òptimes i localització de plantes. Com a casos concrets, podem esmentar el Commonwealth Scientific and Industrial Research Organisation (CSIRO), que va desenvolupar un sistema per a la gestió dels recursos hidràulics d'Austràlia que utilitzava un paquet d'optimització de fluxos en xarxes desenvolupat a la UPC, o la companyia Google, que utilitza el paquet d'optimització Ceres (<http://ceres-solver.org>) per fusionar amb Google Maps les dades obtingudes dels seus sensors (<https://www.youtube.com/watch?v=z000Ru4bU-A>).

En enginyeria elèctrica es fa servir per optimitzar la generació d'electricitat (per exemple,

en problemes d'assignació d'unitats) i optimitzar ofertes en les subhastes del mercat elèctric liberalitzat.

L'optimització també es fa servir en el disseny d'estructures en camps com l'enginyeria civil, mecànica i òptica. Per exemple, G. Casanellas i J. Castro a *Using interior point solvers for optimizing progressive lens models with spherical coordinates* (una publicació derivada del doctorat industrial de la primera autora) dissenyen lents progressives òptimes utilitzant tècniques d'optimització.

En economia i finances l'optimització s'ha usat en problemes clàssics com el de la cartera de valors òptima (*portfolio problem*), presentat per H. J. Markowitz i pel qual va rebre el Premi Nobel d'Economia el 1990.

L'optimització també s'ha usat recentment en camps tan específics com la confidencialitat de dades, en particular en el control de la revelació estadística. Aquest problema apareix, per exemple, quan un institut nacional d'estadística publica taules de dades agregades a partir d'un cens, i d'aquestes dades es pot derivar informació confidencial dels individus del cens. Instituts d'estadística de tot Europa, entre els quals l'Eurostat (agència estadística de la Comissió Europea), eviten la revelació d'informació solucionant un (difícil i de gran dimensió) problema d'optimització (combinatòria, en aquest cas).

En els darrers anys, el gran camp d'aplicació de l'optimització ha estat en ciència de dades i aprenentatge automàtic (*machine learning*). Molts problemes d'aquest camp es formulen i requereixen la solució d'un model d'optimització. Entre els problemes concrets de ciència de dades que es formulen com a problemes d'optimització trobem, per exemple, la regressió LASSO, la *ridge regression*, els mètodes de vectors de suport (*support vector machines*, SVM) i les xarxes neuronals.

És difícil dir què ens oferirà el futur. De la mateixa manera que fa uns anys no es podia preveure que algunes de les aplicacions en ciència de dades esmentades abans se solucionarien per tècniques d'optimització. Els avenços recents en optimització han permès desenvolupar tècniques per resoldre nous problemes, com ara l'optimització cònica, quan les restriccions defineixen cons convexos; l'optimització semidefinida, quan les variables a optimitzar són matrius semidefinides, i l'optimització de

dimensió molt gran, per la qual s'han pogut solucionar eficientment problemes de milers de milions de variables. És d'esperar que aquests avenços teòrics i algorísmics siguin usats en noves aplicacions.

[VMA] La investigació operativa (IO) té una llarga història, des dels seus inicis a la Segona Guerra Mundial. Els sectors industrials van ser tradicionalment els primers usuaris d'aquestes tècniques, amb l'optimització de recursos i processos, sobretot al sector de l'automòbil però ràpidament a la resta de les empreses industrials: *scheduling* a metal·lúrgia, programació matemàtica a empreses de producció (alimentació, incloent-hi agricultura), assignació de màquines a feines a tallers (mobles, moda), gestió d'estocs i ruteig a logística, etc.

El camp de les finances també va adoptar tècniques d'IO per optimitzar estratègies d'inversió, potser amb un toc més estadístic.

El sector que ha adoptat menys la IO ha estat el dels serveis. Les empreses de serveis són normalment menys centralitzades (per exemple, banca o *retail*), i això ha fet més difícil utilitzar tècniques d'optimització, ja que la decisió després es trasllada a una gran quantitat d'agents amb la discreció de variar la decisió suggerida. Però amb l'emergència del *big data analytics*, aquestes empreses estan invertint en tecnologia per millorar l'eficiència dels seus processos, i això molts cops passa per prescriure decisions als seus agents repartits pel territori.

**Per què la investigació operativa, tot i ser transversal i aplicada per naturalesa, no ha tingut la popularitat del *machine learning* / *data science*? Què caldria fer perquè se'n fés més ús?**

[AA] En efecte, malgrat que les empreses mencionen molt els problemes d'investigació operativa entre llurs necessitats, no sembla que tingui la mateixa popularitat que la *data science*. No sé què cal fer. He explicat diverses vegades les coses que poden fer les matemàtiques per la indústria en trobades empresarials, amb especial èmfasi en l'optimització del procés productiu. Sempre m'han escoltat atentament, però quan es tracta de millorar processos interns, hi ha una certa resistència a invertir-hi els recursos necessaris; el màrqueting sempre té prioritat.

En principi, l'anàlisi d'una situació real que es vol millorar hauria de passar, seguint una cadena lògica, per tres etapes: una de descriptiva (què està passant), una de predictiva (què passarà a partir d'ara) i una de prescriptiva (què volem que passi a partir d'ara i com fem que passi). *Grosso modo*, la *data science* treballa la primera etapa; el *machine learning* pertany sobretot a la segona, i de vegades també a la tercera, i l'optimització és clarament part de la tercera. Des d'aquest punt de vista, molt simplificat, l'optimització l'aplicaran indústries que han arribat a una certa maduresa en l'estudi del seu propi funcionament.

A més, l'etapa prescriptiva pot implicar una recollida de dades addicional que no estava prevista en les etapes descriptiva o predictiva. Per exemple, no és el mateix fer una predicció de la demanda que optimitzar el moment del proveïment tenint en compte la capacitat d'inventari, els costos de transport, els financers, els d'oportunitat, etc. I el funcionament òptim de la cadena de valor involucra sempre diversos actors de la cadena; no és cosa d'una sola empresa.

[JC] Opino que l'optimització i el *machine learning* no són directament comparables: l'optimització / investigació operativa és una eina (matemàtica) transversal per a la solució de problemes de diferents camps; *machine learning* / *data science* és un dels camps particulars (actualment el més important) que generen problemes solucionables per optimització. De fet, com indica Yann LeCun (*silver professor* del Courant Institute of Mathematical Sciences de la Universitat de Nova York i vicepresident i cap d'Intel·ligència Artificial de Facebook) *machine learning* = *function optimization*.

[VMA] Igual que amb la *data science*, l'IO necessita gent formada que també sigui bona comunicadora, per convèncer la direcció del seu valor. Per a mi, el gran problema és que hi ha una desconexió entre les habilitats tècniques (requereixen un doctorat en IO i ser capaç de seguir l'estat de la qüestió, anar a conferències, etc.) i les habilitats de gestió (definir i executar projectes, traduir l'IO en valor creat per l'empresa, gestionar la política de les organitzacions, etc.). Poca gent és capaç de reunir totes dues vessants; possiblement, consultors i tècnics que han llançat alguna *start-up*.

Per fer-ne més ús, caldria conscienciar els professionals de l'IO que la millora de decisions ha d'encaixar en una estratègia d'empresa.

### Com ha anat en augment, la mida dels problemes, i com ha motivat nous reptes computacionals, això?

[AA] La possibilitat actual de recopilar moltes dades fàcilment, de manera extremament automatitzada, ofereix oportunitats que abans no existien. Però també requereix més capacitats de magatzematge i de càlcul. El repte computacional no és només la millora del hardware, que com sabem té límits físics, sinó també sobretot la millora dels algorismes.

Com deia abans, no es tracta de trobar les solucions perfectes, sinó de millorar el que s'està fent. Els mètodes heurístics poden proporcionar solucions ràpides, barates i acceptables, encara que estiguin lluny de l'optimalitat. La situació ideal, pel meu gust, és quan pots implementar un algorisme sense fi que vagi trobant solucions cada cop millors, fins que un temps límit o una intervenció humana el faci aturar.

[JC] Si anem 30 anys enrere, problemes d'optimització (lineals) de milers de variables podien considerar-se «de gran dimensió». Això ha canviat radicalment des dels anys noranta, canvi motivat per una combinació de factors, com ara:

- Ordinadors cada cop més potents.
- Nous algorismes (com, per exemple, els mètodes de punt interior per a problemes lineals, quadràtics i no lineals convexos, i variants accelerades del mètode del gradient).
- La necessitat de solucionar problemes cada cop de més dimensió, entre els quals, els dels camps de ciència de dades i *machine learning*.

Tal com s'indica en un article aparegut en un volum especial per celebrar el 50è aniversari

de la revista *Operations Research*, des dels anys noranta fins al 2002, la velocitat dels ordinadors es va multiplicar per mil, i tres ordres de magnitud va ser també l'augment de velocitat en algorismes d'optimització. En total, això suposa un augment de velocitat d'un milió de vegades. Així, un problema que l'any 1990 requeria un any de càlcul el 2002 es podia solucionar en 30 segons.

En l'actualitat, problemes del camp del *machine learning* (com màquines de vector de suport i xarxes neuronals) de milions de dades se solucionen eficientment en pocs minuts usant algorismes d'optimització especialitzats per a aquest tipus de problemes. En camps com l'optimització de fluxos en xarxes, s'han pogut solucionar recentment problemes en grafs dirigits bipartits de fins a mil milions d'arcs en una hora de càlcul.

[VMA] No crec que la mida hagi augmentat; el problema és que, com que tenim ordinadors més potents, ara ens «atrevim» a modelitzar les situacions amb més detall. Per exemple, als problemes de ruteig ara s'hi pot incloure tot el detall de la xarxa sobre la qual ens movem, mentre que en el passat es consideraven xarxes simplificades. No em queda clar que afegir més detall al model ens doni millors resultats. Més aviat de vegades anem massa al detall, i es té la il·lusió que realment podem decidir les accions amb tot el detall que volem. Per exemple, un ruteig òptim no et diu que has d'anar de *A* a *B*, sinó que et dirà quin carrer has d'agafar i en quin moment s'ha de girar. La realitat és que el transportista anirà de *A* a *B*, però agafarà la ruta que li agradi més. Una empresa del sector em va explicar que els transportistes (motoristes, en el seu cas) anaven més ràpid que el que suggeria l'optimització, perquè agafaven rutes en principi no factibles (carrers de vianants, direccions prohibides...).