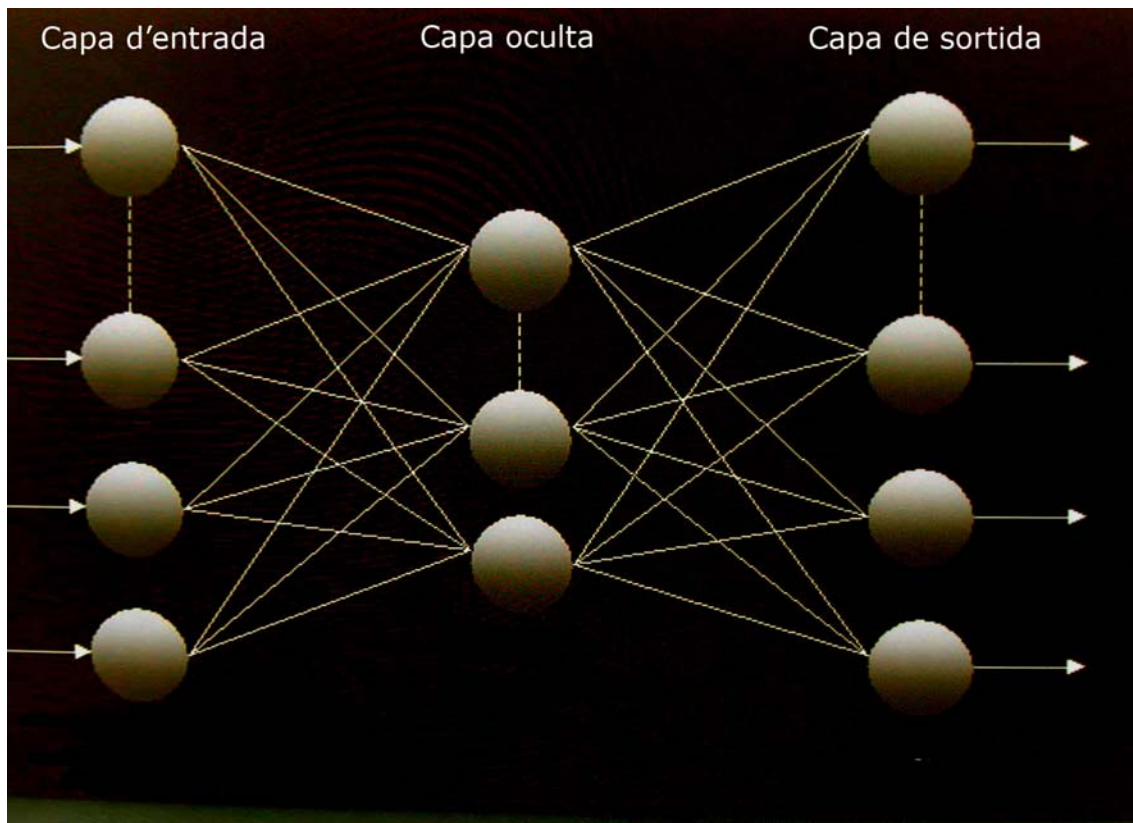


Un grup d'investigadors de la UIB aconsegueixen que una xarxa neuronal artificial tingui més rendiment en la predicció de sèries temporals que el model més emprat des dels anys setanta

Els resultats obtinguts pel grup de Recerca d'Anàlisi de Dades (GRAD) acaben de ser publicats a *Methodology*, la revista europea de referència en el camp de la metodologia de les ciències del comportament



Uns investigadors del grup de Recerca d'Anàlisi de Dades (GRAD) han desenvolupat una versió millorada d'un model de xarxa neuronal artificial que ha demostrat tenir més rendiment en la predicció de sèries temporals que el model més conegut i àmpliament emprat en diverses branques de la ciència des dels anys setanta, el model ARIMA (Models Autoregressius Integrats de Mitjanes Mòbils).

Els investigadors ho han aconseguit, entre d'altres coses, gràcies a la implementació en el mateix model de xarxa neuronal d'un sistema d'anàlisi de sensibilitat que detecta quines variables són les més importants amb vista al resultat final i quin és el pes de cada variable que permet un error menor.

Les xarxes neuronals artificials (XNA)

Les xarxes neuronals artificials (XNA) constitueixen una de les línies de recerca més prometedores en el camp de la intel·ligència artificial (IA), l'objectiu principal de la qual és el desenvolupament de màquines intel·ligents. Les XNA són sistemes de processament de la informació inspirats en l'estructura i el funcionament de les xarxes neuronals del cervell i consisteixen en un conjunt d'elements simples de processament anomenats nodes o neurones connectats mitjançant connexions que tenen un valor numèric modificable anomenat pes.

Les XNA es caracteritzen per tres trets essencials que els diferencien de qualsevol altre sistema de processament de la informació. En primer lloc tenen un processament en paral·lel, és a dir, hi ha moltes unitats de processament que treballen simultàniament. En segon lloc, disposen d'una memòria distribuïda, no tenen una ubicació concreta i física de la memòria com en el cas d'un ordinador, sinó que es distribueixen en les diferents connexions -"sinapsis"- que uneixen cada neurona artificial. I, en tercer lloc, són sistemes adaptatius, que aprenen de l'experiència; és a dir, que aprenen a dur a terme determinades tasques mitjançant un entrenament amb exemples il·lustratius. Mitjançant aquest aprenentatge, les XNA creen la seva pròpia representació interna del problema mitjançant un algorisme matemàtic. Per aquest motiu hom diu que són autoorganitzades. Dit d'una altra manera, les XNA són capaces de generalitzar de casos anteriors a casos nous. Aquesta característica és fonamental, ja que permet a la xarxa respondre correctament, no solament davant informacions absolutament noves, sinó també davant informacions distorsionades o incompletes.

Les XNA són sotmeses, doncs, a un procés d'aprenentatge que no té res a veure amb la programació, a través d'indicacions precises sobre el valor a atorgar per la xarxa quan es troba amb un determinat conjunt de valors. Així, per exemple, si volem que la XNA aprengui a predir el quocient d'intel·ligència dels subjectes a partir de les respostes a un test de rendiment, li presentarem en el procés d'aprenentatge les respostes al test com a entrada o input i indicant a la xarxa la puntuació d'intel·ligència que ha de donar com a sortida o output per a cada subjecte.

El més interessant és que a diferència de qualsevol sistema de processament convencional, una XNA és capaç de generalitzar, és a dir que, partint d'un conjunt

d'exemples il·lustratius que li serveixen per aprendre, pot després enfrontar-se a situacions desconegudes, mai no processades, i proporcionar una sortida adaptativa. Un exemple ens servirà per il·lustrar aquesta capacitat. Si considerem un sistema de processament convencional d'imatges obtingudes via satèl·lit, que ha de reconèixer una determinada forma -per exemple un determinat símbol- en un conjunt d'imatges, el sistema discriminarà sempre de la mateixa manera i segons les instruccions del programa, de tal manera que qualsevol alteració sobre les característiques del símbol que segons el programa hauria de tenir, provocarà que el sistema el rebutgi com a bo. En canvi, una XNA serà capaç de donar per correcte i reconèixer un símbol malgrat que tingui algun tret deficitari.

D'altra banda, les XNA permeten abordar problemes d'alta complexitat en els quals s'involucren gran nombre de variables i en els quals no existeix una relació lineal entre aquestes i el resultat. Per exemple, emprant un símil borsari, hom pot registrar cada cert temps l'IBEX i establir una sèrie temporal de l'índex, però un sistema de procediment convencional que vulgui establir una relació lineal entre diverses variables i el valor de l'IBEX fracassarà, ja que en les fluctuacions hi tenen a veure elements aliens a les pròpies variables, com per exemple, a curt termini, factors de tipus social com el comportament gregari dels agents borsaris, la propagació de rumors, etc.



El grup de Recerca d'Anàlisi de Dades (GRAD)

La recerca sobre diversos sistemes i mètodes de processament de la informació amb l'objectiu de trobar, per a cada aplicació concreta, el que s'adapti més bé a la naturalesa de les dades, és la línia principal de treball del Grup de Recerca d'Anàlisi de Dades (GRAD), que encapçala el doctor Alfons Lluís Palmer, professor del Departament de Psicologia de la UIB, i del qual forma part el doctor Juan José Montaña. Des de l'any 1998, el grup aplica models de xarxes neuronals artificials a diferents àmbits de l'anàlisi de dades.

La utilització de les XNA està orientada en dues direccions: o bé a la simulació de processos cognitius o fisiològics del sistema nerviós, o bé a la resolució de problemes pràctics de caire estadístic: classificació i tipologia de patrons, predicció de variables, etc. És a aquesta segona direcció que el grup ha dedicat els seus esforços, aplicant models de XNA a diferents camps de l'estadística. Els últims anys els investigadors s'han centrat en la utilització de models de XNA per a la previsió de sèries temporals de dades.

Ara fa dos anys, els investigadors empraren les dades de la despesa turística anual, des de l'any 1986 fins a l'any 2000, per tal de construir un model de xarxa neuronal artificial aplicat a sèries de dades temporals amb vista a predir situacions futures. En aquest cas, la xarxa a desenvolupar havia de ser capaç de predir la despesa turística d'anys posteriors, només comptant amb les dades aportades. Les dades de despesa turística entre els anys 1986 i 1996 s'empraren com a dades d'entrenament pel model neuronal construït. La xarxa en aquesta primera fase aprèn a detectar les relacions existents entre el conjunt de dades en un determinat temps (termes retardats) i la següent data passat el temps. En una segona fase, les dades dels anys 1999 i 2000 serviren per provar el correcte funcionament de la xarxa artificial. L'experiment demostrà que la xarxa féu una previsió molt ajustada a la realitat.

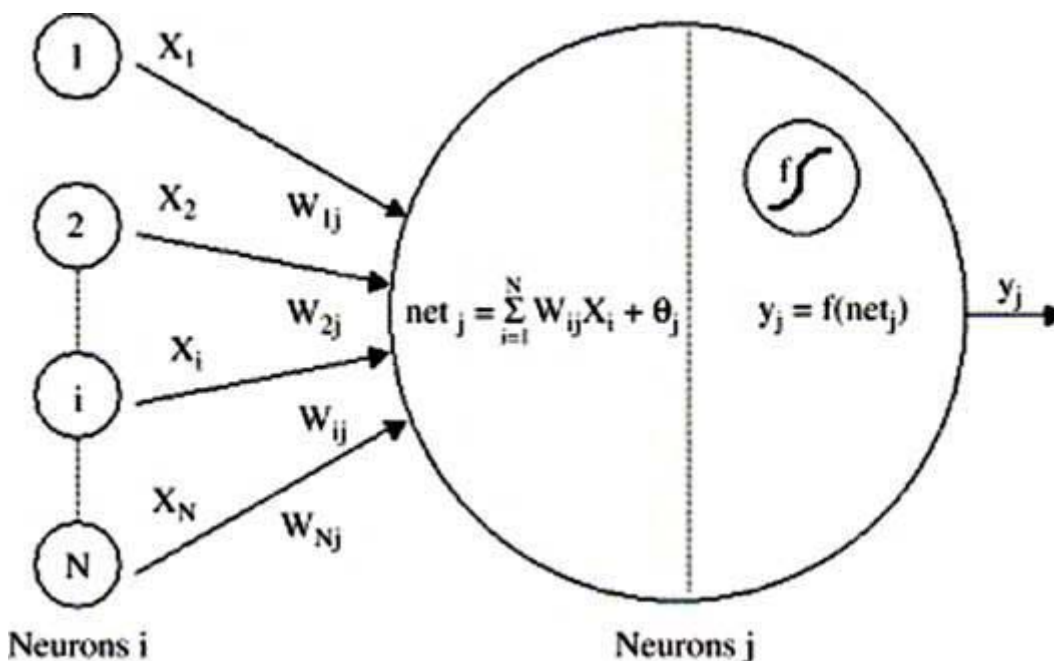


Figura 1.

A la figura 1 s'hi representa esquemàticament el model de xarxa neuronal bàsic emprat pels investigadors de la UIB al treball esmentat. Una neurona artificial qualsevol rep senyals de les veïnes (1,2,3,...,N). Aquests senyals són ponderats mitjançant un pes, un valor numèric que determina la magnitud de la connexió. La neurona integra tots els senyals ponderats i hi aplica una funció matemàtica que

permet obtenir un senyal de sortida que es transmet a d'altres neurones. D'aquesta manera la neurona emula les característiques funcionals d'una neurona real. Normalment la funció aplicada és no lineal, la qual cosa diferencia els models de neurones artificials dels models estadístics clàssics. En aquests models se solen donar relacions directes o indirectes a l'hora de comparar dues variables, però en tot cas relacions lineals (és a dir, a major o menor valor d'una variable correspon major o menor valor en una altra variable). La introducció de funcions no lineals a les xarxes neuronals artificials els permet, sempre que es disposi de suficients neurones i dades, treballar com un teixit neuronal real.

Del model ARIMA a les xarxes neuronals

Recentment el grup ha depurat el procediment emprat per predir la despesa turística, aplicant un model de XNA en aquest cas a una sèrie temporal referida al nombre de passatgers en trànsit a les Illes Balears. Els resultats d'aquesta recerca acaben de ser publicats a *Methodology*, la revista europea de referència en el camp de la metodologia de les ciències del comportament.

Una sèrie temporal és un conjunt de dades ordenades respecte del temps. Ho són les sèries de precipitació mitjana per anys, les dades de despesa turística per mesos, etc. En la predicció basant-se en una sèrie temporal es tracta, doncs, d'establir les dades futures sobre les dades històriques. Són diverses les tècniques per predir els valors futurs d'una determinada sèrie temporal. Els anomenats Models Autoregressius Integrats de Mitjanes Mòbils (ARIMA) o models Box-Jenkins són els més comunament emprats des dels anys setanta. Fou a començaments d'aquesta dècada quan G. E. P. Box, professor d'Estadística de la Universitat de Wisconsin, i G. M. Jenkins, professor d'Enginyeria de Sistemes de la Universitat de Lancaster, introduïren un nou enfocament en l'anàlisi de sèries temporals en un treball sobre la contaminació a la badia de San Francisco. El seu treball, un llibre publicat l'any 1976, s'ha convertit en un clàssic i els seus procediments metodològics són els més àmpliament emprats en diverses branques de la ciència.

La predicció és basa en el fet que, sota condicions determinades, tota variable es pot expressar com una combinació lineal dels seus valors passats més un terme d'error. Això és perquè entre aquestes condicions determinades es preveu que la sèrie de dades és estacionària, això vol dir que ni la mitjana, ni la variància ni les autocorrelacions depenen del temps. El que fa aquest model és, per tant, primer establir la sèrie eliminant-ne tot efecte atzarós o dependent de variables que no s'hagin tingut en compte. Una vegada que això s'ha fet, s'analitza quines regularitats apareixen a la sèrie i se n'extreu un model matemàtic que permeti predir valors futurs. Es tracta, per tant, d'un procediment lineal del qual s'ha eliminat tot tipus d'influència aliena a la funció lineal entre variables.

El model ARIMA incorpora una fase per poder seleccionar els termes autoregressius (o passats) més importants, que és anomenada fase d'identificació. Es tracta d'estimar quins d'aquests valors del passat tenen més pes a l'hora de predir el valor futur. Per exemple, el valor de temperatura enregistrat ahir, tindrà a la força més

valor que el registrat fa dos mesos. Així és fixa un pes per a cada variable d'entrada a la funció matemàtica, que ens donarà el valor cercat. Finalment el model s'analitza en funció dels valors observats a la realitat per establir l'error i fer les correccions necessàries.



En els models neuronals artificials aquesta fase d'identificació s'anomena anàlisi de sensibilitat. També es tracta d'aclarir quines de les variables introduïdes tenen més pes a l'hora de processar tota la informació. Un d'aquests sistemes ha estat desenvolupat pel GRAD per al cas d'un dels models més emprats de xarxa neuronal artificial, el perceptró multicapa. Va ser implementat en un programa informàtic sota el títol Sensitivity Neural Network publicat l'any 2003 i distribuït gratuïtament entre la comunitat científica. En aquest cas, la xarxa neuronal processa les diverses variables, els atribueix un pes determinat i recull un valor final. Això ho fa moltes vegades i per a distints pesos inicials. Al mateix temps compara els seus resultats (del model) amb els resultats reals, observats. I la mateixa xarxa detecta amb quins pesos obté el mínim error de comparar el resultat del model amb el resultat realment observat.

Els investigadors de la UIB decidiren, doncs, comparar el seu model de xarxa neuronal artificial, millorat amb un programa d'anàlisi de sensibilitat, amb el model clàssic emprat per predir sèries temporals, el model ARIMA. La comparació es realitzà en un àmbit molt concret: els passatgers en trànsit a les Illes Balears (amb dades mensuals dels aeroports de l'arxipèlag des de 1990 a 2005). Juntament amb

els dos models esmentats, els investigadors introduïren un tercer model a efectes comparatius: la xarxa neuronal artificial sense la millora de l'anàlisi de sensibilitat.

Els tres models havien de contestar a la pregunta següent: Quins seran els passatgers en trànsit el més vinent si les dades dels mesos passats han estat aquestes? Després es comparava els resultats del model amb els resultats reals per saber l'errada comesa.

Els resultats

El primer model, un perceptró multicapa, rebé les dades dels dotze mesos anteriors. El segon model fou un model ARIMA, el model lineal més emprat, que es fonamentà en la relació de dues variables: les dades de dos mesos i dos paràmetres (coeficients). El tercer model fou la xarxa neuronal artificial però millorat amb una anàlisi de sensibilitat aplicada directament al model. Finalment el tercer model emprà les dades de dos mesos anteriors i cinc paràmetres o coeficients.

El model lineal especialitzat i més àmpliament emprat, l'ARIMA, registrà una errada percentual del 5,48 (MAPE: Mean Absolute Percentage Error) i un error que penalitza en funció del nombre de paràmetres del model (BIC: Bayesian Information Criterion) de 578,35.

El model de xarxa neuronal artificial no millorat amb l'anàlisi de sensibilitat registrà un errada percentual del 4,29, mentre que el BIC fou de 605,75 (molt superior perquè el model emprà més paràmetres, i això és penalitzat).

Finalment, el model de xarxa neuronal artificial millorat amb l'anàlisi de sensibilitat registrà un error percentual de 4,13, inferior, per tant, als altres dos models. D'altra banda, l'error BIC fou de 579,02, gairebé igual que el del model ARIMA.

Cal destacar que una errada percentual inferior a cinc punts es considera com a resultat excel·lent per a un model de predicció de sèries temporals.

Com es pot observar dels resultats obtinguts, la xarxa neuronal artificial presenta una més gran eficiència a l'hora de predir la sèrie temporal que no un model especialitzat i àmpliament emprat des de l'any 1976 en aquest tipus de recerca predictiva. Ambdós models comparteixen senzillesa, ja que solament tenen en compte el valor de dues variables (dades de dos mesos anteriors) per calcular el resultat. Difereixen, però, en el nombre de paràmetres (coeficients) involucrats. En el cas del model ARIMA els coeficients són dos, un per a cada variable emprada. En el cas de la xarxa neuronal artificial els coeficients són cinc, atesa la seva arquitectura en xarxa.

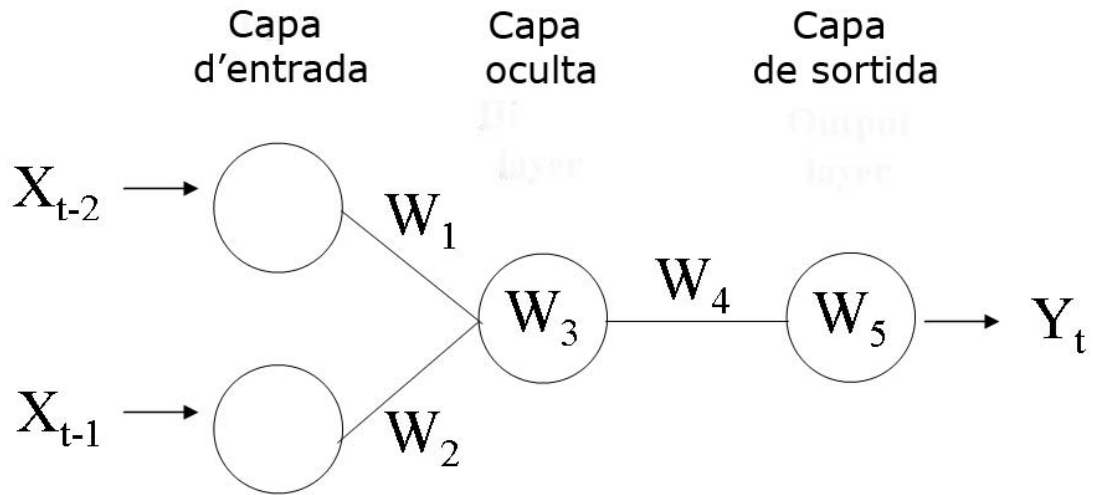


Figura 2.

Tal com es pot observar a la figura 2, cada senyal d'entrada (variable) a una neurona de la capa d'entrada surt com el resultat d'associar la variable (nombre de passatgers en trànsit en un mes determinat) a un paràmetre o coeficient (W_1 i W_2). Aquesta informació és processada per una neurona situada a la capa oculta de la xarxa que integra la informació mitjançant una funció no lineal, i a més incorpora un nou coeficient o paràmetre (el tercer: W_3). La informació és tramesa mitjançant dos paràmetres o pesos a una neurona de sortida (W_4 i W_5). En total són dues variables d'entrada i cinc paràmetres.

Aquesta diferència arquitectònica i la utilització de funcions no lineals per part de la neurona oculta, expliquen el millor rendiment predictiu de la xarxa neuronal artificial respecte al model lineal ARIMA.

Referència del treball:

PALMER, A., MONTAÑO, J.J., i FRANCONETTI F.J., 2008. Sensitivity Analysis Applied to Artificial Neural Networks for Forecasting Time Series. *Methodology* 4 (2): 80-86.

Grup de Recerca d'Anàlisi de Dades (GRAD)

Doctor Alfons Lluís Palmer Pol
 professor de l'àrea de Metodologia
 de les Ciències del Comportament
 Director del Grup de Recerca d'Anàlisi de Dades (GRAD)
 Edifici Guillem Cifre de Colonya
 Tel.: 971 17 34 32
 E-mail: alfonso.palmer@uib.es



Doctor Juan José Montaña Moreno
 professor de l'àrea de Metodologia
 de les Ciències del Comportament
 Edifici Guillem Cifre de Colonya
 Tel.: 971 17 24 95
 E-mail: vdpsjmm2@uib.es



Altres membres del GRAD

Dra. Berta Cajal Blasco (titular d'universitat)
 Dr. Albert Sesé Abad (titular d'escola universitària)
 Dr. Rafael Jiménez López (professor col·laborador)
 Sra. Elena Gervilla Garcia (professora ajudant)
 Sra. M. José Sospedra Baeza

Projectes de recerca finançats

Títol: Redes neuronales artificiales aplicadas al análisis transversal y longitudinal en el campo de las conductas adictivas
 Referència: BSO2001-0369
 Entitat finançadora: Ministeri de Ciència i Tecnologia
 Període: 2002-2004

Títol: Identificación de factores de riesgo asociados al consumo de alcohol y sustancias psicoestimulantes en adolescentes mediante redes neuronales artificiales
 Entitat finançadora: Ministeri de l'Interior: Delegació del Govern per al Pla Nacional sobre Drogues
 Període: 2003-2005

Publicacions recents

Sesé, A., Palmer, A. i Montaña, J.J. 2004. Psychometric Measurement models and artificial neural networks. *International Journal of Testing*, 4: 253-266.

Palmer, A. i Montaña, J.J. 2004. Redes neuronales artificiales aplicadas al análisis de supervivencia con datos censurados. *Metodología de las Ciencias del Comportamiento*. Volumen especial: 459-464.

Sesé, A., Palmer, A. i Montaña, J.J. 2004. Redes neuronales artificiales autoasociativas y dimensionalidad en los modelos psicométricos de medida. *Metodología de las Ciencias del Comportamiento*. Volumen especial: 567-574.

Palmer, A., Montaña, J.J. i Sesé, A. 2006. Designing an artificial neural network for forecasting tourism time series. *Tourism Management*, 27: 781-790.

Capítols de llibre

Montaña, J.J., Palmer, A., Sesé, A. i Beltrán, M. 2004. Redes neuronales artificiales aplicadas al análisis de datos turísticos. A *Técnicas y métodos estadísticos aplicados al sector turístico*. Editat pel Govern de les Illes Balears, pàg. 278-295.

Patents i models d'utilitat

Sensitivity Neural Network Versió 1.0

Inventors: Montaña, J.J., Palmer, A. i Fernández, C.

Núm. de sol·licitud: PM-196-02 Núm. registre: 00 / 2003 / 9453

Reportatge finançat per:



**Govern
de les Illes Balears**

Conselleria d'Economia,
Hisenda i Innovació
Direcció General de Recerca,
Desenvolupament Tecnològic i Innovació