

1. Datu-Meatzaritzarako sarrera

Irakasgaia: **Datu Meatzaritza**
Especialitatea: **Konputazioa**, hirugarren ikasmaila
Titulazioa: **Informatika Ingeniarietako Gradua**
Konputazio Zientzia eta Adimen Artifiziala saila
Universidad de Pais Vasco - Euskal Herriko Unibertsitatea

Aurkibidea

Datu-Meatzaritza

Knowledge Discovery from Databases (KDD): datubaseetan ezagutza aurkitzea

Aurkibidea

Datu-Meatzaritza

Knowledge Discovery from Databases (KDD): datubaseetan ezagutza aurkitzea

Definizio batzuk

- ▶ **Data mining**. Aurretik ezezaguna den ezagutza erabilgarri eta ulergarria erautzea formatu desberdinetan gordeta dauden datu-multzo handietatik (Witten eta Frank, 2000)
- ▶ **Knowledge discovery in databases**. Datubaseetan ezagutza aurkitzea, datuetatik abiatuz eredu baliagarriak, berriak eta azken batean ulergarriak identifikatuz (Fayyad eta lag. 1996)

Eredu-motak

- ▶ **Datuetatik ezagutza** lortzea eredu konputazionalak erabiliz
- ▶ **Eredu deskribatzaileak**: datuak deskribatzen edo laburtzen dira
 - ▶ **Erregelak**: datuen portaera-ereduak erakusten dira
 - ▶ **Clustering**: homogenoak diren kasuak multzokatzan dira
- ▶ **Eredu iragarleak**: aldagai iragarleen balioetatik abiatuz iragarri beharreko beste aldagai batzuren balioak estimatzen dira
 - ▶ **Erregresioa**: Iragarri beharreko aldagaia jarraia da
 - ▶ **Gainbegirautako sailkapena**: Iragarri beharreko aldagaia diskretua da (ordinala edo nominala)

Datu-motak

- ▶ **Datubase erlazionalak**
 - ▶ Errazio-multzoak (taulak). Ezaugarri-multzo baterako (aldagaiak, zutabeak, eremuak) n -koteak gordezen dira (kasuak, errenkadak, erregistroak)
 - ▶ Taula moduko aurkezpena: ezaugarri-balo
- ▶ **Datubase espazialak**: geografik-datuak, medikuntza-irudiak, garraio-sareak,
- ▶ **Datubase tenporalak**: denborazko une edo tarte desberdinak
- ▶ **Datubase dokumentalak**: Objektuak testu-dokumentuak dira, aldagaiak hitzak adierazi ditazkete, edo laburpenak...
- ▶ **Multimedia datubaseak**: Irudiak, soinua, bideoa
- ▶ **World Wide Web**: gaurregun dagoen informaziorako gunerik handiena eta anitzena
 - ▶ Edukiaren analisia: web orrietan ereduak aurkitzea
 - ▶ Egituraren analisia: hipertestekak eta URL-ak aztertzea
 - ▶ Erabileraren analisia: nabigazioa aztertzea

Erlazioa beste zenbait arloarekin

- ▶ **Estatistika**. Datu-meatzaritzaren " ama "
- ▶ **Ikasketa automatikoa**. Konputagailuak adibideetatik ikasten du
- ▶ **Ereduen ezaugarria**. Clustering. Sailkapen-gainbegiratua
- ▶ **Erabakiak hartzeko sistemak**. Zuzendaritzari laguntzeko tresnak eta sistemak
- ▶ **Datuen bistaratzea**. Grafiken bidez datuetatik ateratako ereduak ikusten eta ulertzen laguntzea
- ▶ **Datubaseak**. Datuen biltegiak. Atzipen eraginkorra
- ▶ **Informazioaren erauzketa**. Testuak. Liburutegi digitalak. Bilaketak Interneten
- ▶ **Konputazio paraleloa eta banatua**. Datu-meatzaritzak dakarren kostu konputazionala banatu egiten da prozesamendu paraleloa eta banatua erabiliz

Aplikazioak

Finantza-aplikazioak

- ▶ Kreditu-txartelen iruzurrezko erabilerak hautematea
- ▶ Kreditu-txartelaren bidezko gastuaren iragarpena
- ▶ Kreditua ematerakoan arriskua aztertzea
- ▶ Datu historikoetatik merkatu-erregelak identifikatzea
- ▶ " Fidelak" ez diren bezeroak identifikatzea

Aplikazioak

Merkataritza

- ▶ Erosketa-saskiaren analisia
- ▶ Publizitate-kanpainen ebaluazioa
- ▶ Bezeroen sailkatzea
- ▶ Salgaien, kostuen edota salmenten estimazioak egitea

Aplikazioak

Aseguruak

- ▶ Garesti gerta daitezkeen bezeroak identifikatzea
- ▶ Poliza berriak kontratatzen dituzten bezero-motak identifikatzea
- ▶ Arrisku egoeran egon daitezkeen bezeroen portaera-ereduak identifikatzea
- ▶ Iruzurrerako portaerak identifikatzea

Aplikazioak

Hezkuntza

- ▶ Ikasleen aukeraketa
- ▶ Eskola-porrota hautematea
- ▶ Ikasleek ikastegian emango duten denboraren estimazioa egitea

Aplikazioak

Medikuntza

- ▶ Gaixotasunak diagnostikatzea
- ▶ Gaixotasun jakin bat jasateko arriskuan egon daitezkeen pazienteak identifikatzea
- ▶ Ospitale-kudeaketarako. Baliabideen erabilera hobetzeko asmoz osasun-zentroetarako denbora-iragarpenak egitea
- ▶ Mediku-irudien tratamendua egitea

Aplikazioak

Bioinformatika, bioingeniaritza

- ▶ Geneen bilaketa (genoma kodifikatzen duten eremuak)
- ▶ Proteinen bigarren mailako egituraren iragarpena egitea
- ▶ Uholdeen iragarpena
- ▶ Uren kalitatea neurtzeko ereduak sortzea

Aplikazioak

Beste zenbait arlotan

- ▶ Telekomunikabideak: iruzurra identifikatzea
- ▶ Posta elektronikoa eta agenda pertsonalak: postaren sailkapena eta banaketa automatikoa, *spam* mezuak hautematea
- ▶ Ogasuna: zerga-iruzurrak hautematea
- ▶ Web: erabiltzaileen portaeraren analisia egitea
- ▶ Kirolak: datu medikuetatik abiatuz lesioak jasateko arriskua identifikatzea

Aurkibidea

Datu-Meatzaritza

Knowledge Discovery from Databases (KDD): datubaseetan ezagutza aurkitzea

Datubaseetan ezagutza aurkitzea

Prozesu iteratibo eta elkarerragilearen faseak

1. Datuak bildu eta bateratu
2. Aukeratu, garbitu eta eraldatu
3. Datu-meatzaritza egin
4. Ebaluatu eta interpretatu
5. Zabaldu eta erabili

Datubaseetan ezagutza aurkitzea

1. Datuak bildu eta bateratu

- ▶ **Datubaseak** eta **datuen prozesamendu tradizionala** (On-Line Transaction Processing, OLTP): eguneroko beharrik asetzeko nahikoak dira (fakturazioa, inbentarioen kontrola, ...)
- ▶ **Erabaki estrategikoak** analisian, plangintzan eta iragarpenean oinarrituta: datuak sail desberdinetan egon daitezke
- ▶ **Jatorrizko datuak** formatu desberdinetan egoten dira
- ▶ Datubaseen bateratzea: **datuen biltegiak** (data warehousing)
- ▶ Datuen biltegiak gomendagariak dira informazio-kantitatea handia denean. Hala ez denean ez dira beharrezkoak (**testu-fitxategiak**, **kalkulu-orriak**, ...)

Datubaseetan ezagutza aurkitzea

2. Aukeratu, garbitu eta eraldatu

- ▶ Aurkitutako ezagutzaren kalitatea datu-meatzaritzan erabiltako algoritmoaren mende egoteaz gain **aztertutako datuen kalitatearen mende** dago
- ▶ Datuen portaera orokorrera egokitzen ez den zenbait daturen presentzia egon daiteke (**outliers**)
- ▶ Balioak falta dituzten datuak egon daitezke (**missing values**)
- ▶ Aldagai esanguratsuak aukera daitezke (**feature subset selection**)
- ▶ Datubase oso handietan **kasuen auzazko aukeraketa** egin daiteke
- ▶ **Aldagai berriak** modu automatikoan eraiki daitezke
- ▶ Aldagai jarraiak **diskretiza** daitezke

Datubaseetan ezagutza aurkitzea

3. Datu-Meatzaritza

- ▶ **Eredu deskribatzaileak**
 - ▶ Erregelak
 - ▶ Multzokatzea (clustering): partizionala, probabilitikoa, ierarkikoa, kontzeptuala
- ▶ **Eredu iragarleak**
 - ▶ Erregresioa: regresio lineala...
 - ▶ Gainbegiraturako **sailkapena**: sailkapen-zuhaitzak, K-NN, sailkatzaile Bayestarrek, erregelen indukzioa, erregresio logistikoa, sare neuronalak, sailkatzaileen konbinaketa

Datubaseetan ezagutza aurkitzea

4. Ebaluatu eta interpretatu

- ▶ Ebaluazio teknikak: **balidazio sinplea** (entrenamendua + testa), **k-geruzatako balidazio gurutzatua**, **bootstrapping**
- ▶ Erregelak: **estaltzea**, konfiantza
- ▶ Multzokatzea (Clustering): multzo barruko elementuen eta multzoen arteko distantzia
- ▶ Erregresioa: **batazbesteko errore kuadratikoa**
- ▶ Gainbegiraturako sailkapena: ondo sailkatutako **portzentaia**, **erroreen matrizea**, **ROC analisia**
- ▶ Eredu **ulerterrazak** eta **interesgarriak** (erabilgarriak eta berritzaileak)

Datubaseetan ezagutza aurkitzea

5. Zabaldu eta erabili

- ▶ **Zabaldur**: eraikitako eredu erabiltzaileen artean zabaltu eta erabili erabakiak hartzeko
- ▶ **Ereduaren garapena** neurtu behar da denboran zehar:
 - ▶ Berrebaluatu
 - ▶ Berrentrenatu
 - ▶ Berrealki

Oinarrizko bibliografia

- ▶ Liburua: **Introducción a la Minería de Datos**
 - ▶ Capítulo 1: ¿Qué es la minería de datos?
 - ▶ Capítulo 2: El proceso de extracción de conocimiento
- ▶ Egileak: José Hernández Orallo, M^a José Ramírez Quintana, César Ferri Ramírez
- ▶ Departamento de Sistemas Informáticos y Computación, Universidad Politécnica de Valencia
- ▶ Argitaratzailea: Pearson Prentice Hall, 2004
- ▶ ISBN: 84-205-4091-9