


Hírek, aktualitások

- Hír** Horváth Ildikó: Akkor működik jól az egészségügy, ha nem is látszik >>
- Hír** Tíz éve nem néztünk szembe a valósággal, ezért duplán fizetünk az egészségünkért >>
- Hír** Beavatkozás előtt az egészségügy - Mi sül ki ebből? >>

Egészség- és gyógyszerfinanszírozás makró szemléletben


Az Egészségbiztosítási Alap egyenlegének alakulása, 2018 szeptember




Forrás: NEAK adatok, Healthware elemzés

A vényköteles patikai gyógyszerforgalom dinamikája

Patikai forgalom terápiás napokban (DOT)




Patikai társadalombiztosítási támogatásforgalom




Támogatott gyógyszer-törzs-változások, 2018 szeptember


Jelmagyarázat



Törzskönyvezett készítmények száma



Támogatás iránti kérelmek száma



Befogadott készítmények száma



Forrás: NEAK adatok, Healthware elemzés

Forgalmi adatok a Medalyse információs rendszerben

Medalyse szolgáltatásunk évek óta elérhetővé teszi ügyfeink számára a NEAK által publikált forgalmi adatokat, valamint lehetőséget biztosít azok idősoros elemezhetőségére.

A NEAK forgalmi adatokat jellemzően a tárgyhónapot követő hónap 16-18. napján teszi elérhetővé.

A Healthware vállalja, hogy a publikált adatokat lehetőségéhez mérten 1 munkanapon belül betölti a Medalyse információs rendszerébe.

Így ügyfeink a NEAK forgalmi adataihoz akár a tárgyhónapot követő 20. napon belül hozzáfuthatnak, azokat szabadon elemezhetik.

Leírás a NEAK forgalmi adatairól: [link](#)


Részletesen a Medalyseről: [link](#)



Piaci adatok


Támogatáskiáramlási és betegszám toplisták, 2018 szeptember

A 10 legnagyobb támogatáskiáramlást generáló hatóanyag




Forrás: Patikai vényforgalmi adatok, Healthware elemzés

A 10 legnagyobb támogatáskiáramlást generáló brand




Forrás: Patika vényforgalmi adatok, Healthware elemzés

A 10 legnagyobb támogatáskiáramlást generáló forgalmazó




Forrás: Patikai vényforgalmi adatok, Healthware elemzés

Orvoslátogatók átlagos létszáma



Forrás: NEAK adatok, Healthware elemzés



Betegút-csoportosítás — Esettanulmány

Jelen esettanulmányunkban arra a gyakran felmerülő problémára mutatunk megoldást, hogy egy első ránézésre nagyon kaotikusnak tűnő betegút trajektória rendszert (pl. betegként fix időablakonként mért laborértékek) hogyan tudunk hatékonyan homogén csoportokba, klaszterekbe rendezni.

A módszert szimulált adatokon szemléltettük. A besorolástól azt várjuk, hogy egy-egy csoporton belül olyan betegutak legyenek, melyek tulajdonságai hasonlóak, másképp, a betegutak közel legyenek egymáshoz (bizonyos, a betegutak közt értelmezett távolságfogalom szerint). A kapott csoportok típus jellemzői, időbeli trendjei tárják fel a csoportok közti lényeges különbségeket. A klaszterezés várható előnye, hogy az eljárás végrehajtása után könnyebb az egyes csoportokat összehasonlítani, valamint a kapott betegút típusokat további modellekben is fel tudjuk használni.


A klaszterek két fő tulajdonsága:

- ♦ az egy csoportba tartozó betegutak hasonlóan
- ♦ a különböző csoportok betegútjai lényegesen eltérnek.


Az R kml csomagját alkalmaztuk longitudinális adatok klaszterezésére¹. A csomagban implementált algoritmus képes az optimális csoportszám kiválasztására is, ami előnyös tulajdonság, hiszen túl sok csoport esetén elveszik az elemzés értelme, míg a túl kevés csoport hátránya, hogy nagyon eltérő (nagyon távoli) betegutak is egy klaszterbe kerülhetnek.

Illusztrációként szimulált idősorokon mutatjuk be az eljárást. Két betegút csoportot szimuláltunk, mindegyikben 200 beteggel. Az első csoport trendje időben a négyzetgyök függvény szerint növekszik, a második trendje csökkenő, az eltelt idővel fordítottan arányos. Az egyes betegutak a trendtől egyedi, betegspecifikus, időben korrelált zajfolyamatokkal térnek el. (A zajfolyamatok úgynevezett elsőrendű autoregresszív folyamatok voltak.)

A szimulált betegutakat az első ábra mutatja be, az alábbi korrelációs mintázatok szerint:



Ha ezekre a szimulált adatokra alkalmazzuk a kml longitudinális klaszterező eljárást, akkor az eredmény:



Összességében azt tapasztaltuk, hogy a klaszterező eljárás extrém erősen korrelált és igen nagy szórású zajfolyamatok mellett is stabilan megtalálja a kiindulási betegút-csoportokat.

A klaszterező eljárás jól teljesített már valós jellegű probléma esetében is. Az idei ISPOR konferencián bemutatásra került poszterünkön² reumatoid arthritisben szenvedő betegeket klasztereztünk, a betegség aktivitási index (DAS28) trajektóriáik alapján. Az eredményül kapott csoportok között szignifikáns különbséget tapasztaltunk az első biológiai terápia hosszában, a remissziót elérő betegek arányában, a térd- és csípőműtétek előfordulásának arányában, valamint az ellátási költségeikben.

¹ Genolini Christophe; kml: K-Means for Longitudinal Data. R package version 2.4.1; [link](#)

² Tamás Balázs, Péter Juhász, Andrea Radnai, Károly Dede, Miklós Bacsai, Gyula Poór; Categorising Patients with Rheumatoid Arthritis Using Trajectories of Disease Activity Score in Hungary; [link](#)