

MTA Központi Fizikai Kutató Intézet

EKG morfológiai változásainak vizsgálata cluster eljárással

Wolf Tamás, Bolyky János, B. Nagy András

1. Bevezetés

A számítógépes EKG diagnosztikai rendszerek döntésüket vagy az orvosi gondolkodás szimulálásával, vagy valamilyen matematikai modell alkalmazásával, esetleg a kétféle megközelítés kombinációjával hozzák meg. A KFKI-ban, az OTKI-val együttműködésben fejlesztés alatt álló kis-számítógépes EKG diagnosztikai rendszerben [4] az algoritmus részben matematikai eljárásokon, részben tradicionális orvosi döntési ismereteken alapul. A clusterezési vizsgálat során elemeztük, hogy a döntési eljárásban alkalmazott matematikai módszer, illetve annak alapját képező referencia mintavektor halmoz milyen inherens tulajdonságokkal rendelkezik.

2. Az EKG diagnosztikai rendszerben alkalmazott döntési algoritmus

A jelenlegi számítógépes rendszerben a diagnózis alkotásnak három fő része van:

- a./ QRS komplexum analizise
- b./ ST-T szakasz analizise
- c./ aritmia analizis

Jelen vizsgálat célja a QRS hullámmal kapcsolatos döntési eljárás elemzése volt.

A paciens Frank elvezetési rendszerrel felvett EKG jeleit az algoritmus adatelőkészítés - zajszűrés, műtermék mentesség ellenőrzés, kalibráció, stb. - és lényegkiemelés - tipikus szivciklus és karakterisztikus pontok meghatározása - után egy rendezett diagnosztikai mintakészlettel jellemzi. Ez a mintakészlet a QRS komplexum 8, időben ekvidisztáns momentán vektorának polárkoordinátáit tartalmazza, összesen tehát 24 paramétert. Az algoritmus ezután ezt a 24 elemű mintavektort egy, az OTKI kardiológusai által összeállított referencia mintavektor halmazhoz hasonlítja. Ez a referencia mintavektor halmaz 25 betegség-osztály adatait tartalmazza. A betegség-osztályokat az 1. táblázatban soroltuk fel. /Az egyes osztályok mellett feltüntetett rövidítések az ábrák megértését segítik./ Az algoritmus azt a betegség-osztályt választja döntésként, amelyhez az adott diagnosztikai mintakészlet a legjobban "hasonlít".

A clusterezési vizsgálat célja az volt, hogy információt kapjunk az ismertetett döntési eljárás várható

1. táblázat

Osztály neve	Rövidítés
ANTERO-SEPTAL MYOCARDIAL INFARCTION	ASMI
NORMAL	NORM
EXTENSIVE-ANTERIOR MYOCARDIAL INFARCTION	AMI
ANTERO-LATERAL MYOCARDIAL INFARCTION	AIMI
POSTERO-DIAPHRAGMATICAL MYOCARDIAL INFARCTION	PDMI
POSTERO-BASAL MYOCARDIAL INFARCTION	PBMI
POST.-DIAPHR.+POSTERO-BASAL MYOCARDIAL INFARCTION	PD + PBMI
DOUBLE ELECTRICAL LOC. ANT.+POST.-DIAPHR. MYOC. INF.	DMI
LEFT /TAWARA/ BUNDLE BRANCH BLOCK OF IN- FREQUENT TYPE	LB BB I
LEFT /TAWARA/ BUNDLE BRANCH BLOCK OF FREQUENT TYPE	LB BB II
LEFT ANTERIOR HEMIBLOCK	LAH
RIGHT /TAWARA/ BUNDLE BRANCH BLOCK I. /WILSON BLOCK/	RB BB I
RIGHT /TAWARA/ BUNDLE BRANCH BLOCK II. /WILSON BLOCK VAR./	RB BB II
RIGHT /TAWARA/ BUNDLE BRANCH BLOCK III. /CLASSIC/	RB BB III
RIGHT /TAWARA/ BUNDLE BRANCH BLOCK+LEFT ANT. HEMIBL.	RB BB + LAH
WPW SYNDROME TYPE A	WPW A
WPW SYNDROME TYPE B	WPW B
WPW SYNDROME TYPE C1	WPW C1
WPW SYNDROME TYPE C2	WPW C2
LEFT ANT. HEMIBLOCK+ANTERO-SEPTAL MYOCARD. INFARCTION	LAH + ASMI
LEFT ANT. HEMIBLOCK+POST.-DIAPHR. MYOCARD. INFARCTION	LAH + PDMI
WILSON BLOCK+ANTERO-SEPTAL MYOCARDIAL INFARCTION	W.BL. + ASMI
LENEGRE'S SYNDROME+ANTERO-SEPTAL MYOCARDIAL INFARCTION	LEN + ASMI
LEFT VENTRICULAR HYPERTROPHY	LVH
RIGHT VENTRICULAR HYPERTROPHY	RVH

hibájáról és az optimális döntési stratégia megvalósításának lehetőségeiről. Abban az esetben ugyanis, ha a referencia betegség-osztályok között vannak olyanok, melyek a figyelembe vett paraméterek alapján "nagy mértékben" hasonlítanak egymáshoz, - ami az alkalmazott clusterezési eljárásnál úgy jelentkezik, hogy ezen osztályok "magas" hasonlósági szint mellett alkotnak egy clustercentrumot - az ilyen hasonló betegség-osztályokat az algoritmus gyakrabban összetéveszti. Ezekben az esetekben két lehetőség között választhatunk: vagy további paramétereket keresünk és használunk fel, amelyekkel már szétválaszthatók a szóbanforgó betegség-osztályok, vagy az ilyen hasonló osztályokat egy összetett osztályként kezeljük. A megoldást ezekben az esetekben az orvosi vélemény alapján kell kiválasztani.

Mivel újabb paraméterek bevezetése - azaz a 24 elemű diagnosztikai mintakészlet bővítése - a döntések hibavalószínűségeinek csökkentése érdekében a gépi döntés számításigényét és ezáltal az effektív gépidőt növeli, ha lehetséges, célszerű redukálni a mintakészlet dimenzióját. A redukáláshoz a clusterezési eljárást a mintavektorok elemeire alkalmaztuk, így a változók szignifikanciájára vonatkozó információkat nyertünk. Így eldönthető, hogy mely változókat hagyhatjuk el lényeges információvesztés nélkül.

3. Az alkalmazott clusterezési eljárás

Az ABCL cluster algoritmus [1] hierarchikus eljárás, mely tehát a clusterezendő objektumok természetéről semmiféle a-priori ismeretet nem tételez fel. A megvalósított algoritmus két fő részből áll. Az első rész a kiválasztott hasonlóság kritérium alapján a bemenő adatokból hasonlósági mátrixot számít. A második részben az osztályozási eljárás ezen hasonlósági mátrix elemei alapján clusterez. A megoldandó feladat természetétől függően három összekapcsolási módszer közül választhatunk. A három módszer - legközelebbi szomszéd, legtávolabbi szomszéd és átlagos távolság szerinti összekapcsolás - közös tulajdonsága, hogy az osztályozás során mindig a két leghasonlóbb elemet vonják össze egy osztályba. Az így létrehozott új osztály tulajdonságai azonban a három módszernél eltérőek. A legtávolabbi szomszéd módszernél az új osztály a hozzásorolt minták hasonlóságai közül a kisebbeket tartja meg, a legközelebbi szomszéd módszer a nagyobbakat. Az átlagos távolság szerinti összekapcsolás módszerénél pedig az új osztály és egy másik osztály hasonlósága a hozzátartozó osztályok és a másik osztály hasonlóságainak átlagával egyenlő. A program addig fut, míg végül egyetlen osztályt kapunk, amelybe minden minta beletartozik.

A hasonlósági mátrixot a mintavektorok standard

euklidesi távolsága alapján határoztuk meg. Ha az EKG diagnosztizáló algoritmus is euklidesi távolság alapján határozza meg az adott paciens diagnosztikai mintakészletéhez legjobban hasonlító betegség-osztályt, a clusterezési vizsgálat eredményei, következtetései további transzformáció nélkül adnak felvilágosítást az egyes döntési osztályokba való besorolások hibavalószínűségeire, illetve a megszerkesztendő döntési strukturára vonatkozóan.

Osztályozási eljárásként a legtávolabbi szomszéd /Furthest Neighbour/ összekapcsolási módszert választottuk, mivel célunk az volt, hogy a minták /betegség-osztályok/ szeparálhatóságára, illetve a változók /-QRS komplexus momentán vektorainak polárkoordinátái/ szignifikanciájára vonatkozó adatokat nyerjünk. Ennek a clusterezési típusnak az a sajátossága, hogy az osztályozási folyamat elején a hasonló minta-párokat vonja össze, majd viszonylag kis hasonlósági szint mellett képez ezen összevont minta-párokból bővitéssel illetve osztályok fuziójával új osztályt.

4. Eredmények, következtetések

Az eredmények két csoportba sorolhatók:

- a./ a mintavektor halmaz /betegség-osztályok/ minták szerinti clusterezésekor, a cluster-centrumok


kialakulásából, az ezekhez tartozó hasonlósági szintekből a különböző csoportokba való besorolások hibavalószínűségeire lehet következtetni.

b./ A változók /polárkoordináták/ szerinti clusterezésnél a paraméterek szignifikanciáját határoztuk meg.

Az a./ szerinti eredmények az 1. ábrán, a clustercentrumok kialakulásából adódó betegség-csoportok pedig a 2. táblázatban láthatók. Az 1. ábra bal oldalán a betegség-osztályok neveinek rövidítéseit tüntettük fel, a clusterezési dentogram pedig az osztályok kialakulását és a hozzájuk tartozó hasonlósági szinteket mutatja. Mint az ábrán is látható, bizonyos betegségosztályok csak igen kis hasonlósági szint mellett fuzionáltak más betegség-osztályokkal, ezeket tehát indokolt a továbbiakban is különálló osztályként kezelni az EKG diagnosztizáló algoritmusban. Ilyen osztályok a 2. táblázatban az 1-5. osztályok. A KFKI-OTKI EKG diagnosztikai rendszerrel végzett feldolgozások tapasztalatai szerint azokat az EKG jeleket, amelyeket orvosi vélemény szerint ezen osztályok valamelyikébe sorolhatunk, a gépi algoritmus is nagy találati valószínűséggel sorolta a megfelelő osztályba.

A 2. táblázat 6-13. csoportja több betegség-osztályt

Betegség-
osztályok



1. ábra
25 betegség-osztály clusterézési dentogramja

Sorszám	Tartalom
1	ALMI
2	DMI
3	WPW A
4	WPW B
5	LBBB II
6	ASMI, AMI
7	NORM, PBMI, PD+PBMI, RVH
8	PDMI, LAH+PDMI
9	LVH, LBBB I
10	RBBB I, RBBB II
11	RBBB+LAH, LEN.+ASMI
12	RBBB III, W.BL.+ASMI
13	WPW C1, WPW C2

2. táblázat
Betegség-osztályok cluster-centrumai


tartalmazó, összetett osztály. Az 1. ábrán látható, hogy ezekbe a csoportokba viszonylag nagy hasonlósági szint mellett kerültek be az elemek, azaz az egyes betegség-osztályok. Ez másszóval azt jelenti, hogy a jelenleg figyelembe vett paraméterek alapján nem várható, hogy a diagnosztikai algoritmus a 6-13. csoporton belüli egyes betegség-osztályokat kis hibavalószínűséggel elkülöníti



egymástól egyéb, döntést segítő ismeretek implementálása nélkül. A tévesztések elkerülésére további szignifikáns, analóg és bináris paraméterek - pl. időtartamokat jellemző változók, amplitudó küszöbszintek túllépését mérő logikai paraméterek, stb. - bevezetése szükséges. E módszer - analóg és bináris változók együttes figyelembe vétele - hasonló probléma megoldására hasznosnak bizonyult [2], és az EKG diagnosztikai algoritmusoknál is kedvezőek az ilyen irányú első kísérletek eredményei. Azoknál a betegség-csoportoknál, ahol az alkalmazandó therápia szempontjából nem szükséges az azonos clusteren belüli egyes betegség-osztályokat elkülöníteni, indokoltnak látszik ezt a csoportot /csoportokat/ a jövőben egyetlen betegség-osztályként kezelni. /Pl. 2. táblázat 11. cluster./

A változók szerinti clusterezés eredményei a 2. ábrán láthatók. A bemenő adatok - mint az az ábra felső részén látható - a QRS hullámot jellemző 8 momentán vektor polárkoordinátái voltak. Az eredmények szerint a magnitudo /M/ értékek nagy hasonlósági szinten egyesültek egy clusterré. Így közülük elhagyhatók paraméterek a diagnosztizálásnál, lényeges információ veszteség nélkül. A QRS hullám momentán vektorait jellemző szögparaméterek kisebb hasonlósági szinten olvadtak össze. Az azimuth /H/ és eleváció szögek közül ez utóbbiak mutattak egymáshoz nagyobb hasonlóságot. A jelenlegi mintavektor halmaznál te-

QRS momentán
vektorok polár-
koordinátái



2. ábra

QRS momentán vektorok polárkoordinátáinak clusterézési dentogramja

hát az azimuth /H/ szögértékek tartalmazzák a legtöbb információt az egyes betegség-osztályokra vonatkozóan.

A vizsgálat tapasztalatai alapján - megismerve a referencia mintavektor halmaz inheres tulajdonságait - a KFKI-OTKI EKG diagnosztikai rendszerének QRS komplexumot analizáló algoritmusát továbbfejlesztjük.

I r o d a l o m

- [1] B. Nagy A., Wolf T.: Módszer folytonos és bináris változókkal leírt minták osztályozására. 8. Neumann Kollokvium, Szeged, 1977.
- [2] Ghyczy K., B. Nagy A., Wolf T.: Multifaktoriális vizsgálatok cluster analízissel a zsirvérűség kórismezésében. 9. Neumann Kollokvium, Szeged, 1978.
- [3] Bemmell, J. B., Hengereld, S. J.: Clustering Algorithm for QRS and ST-T waveform Typing. Comp. and Biomed. Res. 6, 442-456 /1973/.
- [4] Bolyky J., Kozmann Gy., Szilávik F., Wolf T., Antalóczy Z., Regős L., Bukosza I., Biró S.: A KFKI-OTKI kiszámítógépes EKG diagnosztikai rendszer fejlesztés tapasztalatainak áttekintése. 9. Neumann Kollokvium, Szeged, 1978.