

Egy tanítóval történő alakfelismerő eljárás adaptációja, továbbfejlesztése és vizsgálatának eredményei.

/Tanulmány/

Alakzatok, jelek, objektumok, folyamatok, helyzetek felismerése és egy már előzetesen megismertek valamelyikéhez történő azonosítása, egy olyan megnyilvánulása az emberi észnek, amely tevékenységet az embernek naponta, óránként sőt másodpercenként végre kell hajtania /1/. Ezzel a feladattal az ember idegsejtjei milliárdjainak segítségével születése pillanatától haláláig foglalkozik.

Emberi ész ezirányú tevékenysége mesterséges uton történő végrehajtásával foglalkozik az alakfelismerés névvel elnevezett tudományos diszciplína. Az alakfelismerés a gyakorlati alkalmazások terén már régen átlépte azt a határt, ami tényleg az alak, vagy valamilyen más hasonló típusu tulajdonság felismerése volt a feladat. Hagyomány tisztelőből az irodalomban általában kitartanak a szokásos elnevezés mellett.

"Felületesen fogalmazva azt lehet mondani, hogy az alakfelismerő automaták a jelenségek egy jól körülhatárolt területével kapcsolatos tulajdonságok felismerésére, tehát fogalomalkotásra képesek, és ezzel olyan összefüggések megfogalmazásához jutnak el, amelyek előzetesen nem voltak ismertek. Ezt a képességüket annak köszönhetik, hogy az ember számára áttekinthetetlenül nagymértű adathalmazok érdemi feldolgozását is el tudják végezni" /2/.

A fogalomalkotás kifejezése helyett, a tények esetleges filozófiai problémákat keltő félremagyarázhatóságának érdekében célszerűbb azt mondani, hogy ezen automaták osztályokat alakítanak ki, amibe aztán besorolják a megfigyelt objektumokat. Minden osztály egy tulajdonságot, vagyis egy "fogalmat" reprezentál. Az osztályok pontos körülhatárolása egy tanulási folyamat eredménye /innen származik az eljárás "Tanuló algoritmusok" elnevezése/, aminek két fő típusa használatos.

A tanítóval történő tanuláskor az automatának a később osztályozandó objektumok egy reprezentatív csoportját - a tananyagot - mutatják be, és a tanítás annyit jelent, hogy minden egyes esetben azt az osztályt is megnevezik, amibe az illető objektum tartozik, az osztályok kialakítását a gép a megfelelő tanuló algoritmus segítségével, ennek az információnak alapján végzi. A tanító nélküli tanulásnál /cluster analízis/ az osztályok kialakítása kizárólag a tananyag felhasználásával történik, valamilyen előre megadott osztályozási kritérium alapján.

Itt a gép csak olyan tananyagot /mintákat/ kap, ahol a tanítás, vagyis a szóbanforgó minta minősítése nincs mellékelve, és a minták felhasználásával kell a vizsgált objektumok típusait kialakítani. Tekintettel, hogy ebben az esetben a felhasználható információ lényegesen kevesebb, a lehetőségek is korlátozottabbak. Ha például eleve ismert típusok felismerése a feladat, akkor a tanuló algoritmus által kialakított típusok és az eredetiek egyezését végső soron semmi sem garantálja.

Egészen más a helyzet olyankor, amikor kiinduláskor semmit sem tudunk arról, hogy milyen típusok vannak, csak

egy hatalmas és teljesen áttekinthetetlen adathalmaz adott mindenféle értékelés nélkül. Ilyenkor a tanító nélkül tanuló algoritmus a tananyag sűrűsödési pontjainak, a clustereknek a lokalizálásával típusok /osztályok/ megalkotását teszi lehetővé, amikről aztán részletesebb elemzéssel lehet megállapítani, hogy milyen szemléletes tulajdonságok jellemzik őket. Ez a módszer olyankor is alkalmazható, amikor a vizsgált probléma természetéről nagyon keveset tudunk, és a vizsgálat tulajdonképpen a feldolgozandó adathalmaz elemzése első lépésének tekinthető.

A fent vázolt elvek rendkívül széles körben alkalmazhatóak. A teljesség igénye nélkül az alafelismerés alkalmazási területei:

- orvosi és műszaki diagnosztika,
- légi, buborék kamerás és röntgenfelvételek kiértékelése,
- tapasztalati uton kapott görbék elemzése,
- rendszer azonosítási és optimális szabályozási feladatok megoldása,
- szociológiai felmérések kiértékelése,
- katonai alkalmazások.

Végül soron azt lehet mondani, hogy nagy adattömeg igényes kiértékelésére mindig tanuló algoritmusokat célszerű használni, mert így elkerülhetők a tárolással járó nehézségek.

Bármilyen tanuló algoritmus megtervezésénél az első lépés a felismeréshez alkalmazható jellemzők kiválasztása. Egy adott felismerési feladat végrehajtásakor nyilván azokat a jellemzőket kell kiválasztani és alkalmazni, amelyek az adott probléma szempontjából a legtöbb információt hordozzák.

Az alakfelismerésnek ezt az előkészítő lépését lényegkiemelésnek nevezzük. Könnyen belátható, hogy a tanulás eredményessége a lényegkiemeléstől függ. A lényegkiemelés az alakfelismerő folyamat legfontosabb mozzanata.

Az alakfelismerés végrehajtása különféle módszerekkel történhet. Ezen módszerek osztályozása irodalom forrásonként változó /1/, /3/, /4/. A cluster analízis az /5/ irodalomnál például mint a komplex többváltozós elemzési módszerek egyikeként van megemlítve.

Az egyik /3/ osztályozás a következő alakfelismerő módszereket tartalmazza:

1. Geometriai módszerek.
 - 1.1. Lineáris módszerek.
 - 1.2. Nem lineáris módszerek.
2. Statisztikus döntési módszerek /Bayes módszer/.
 - 2.1. Normál eloszlások módszere.
 - 2.2. Szabad eloszlások módszere.
3. Diszkrimináns függvények módszere.
 - 3.1. F-függvény módszere.
 - 3.2. Lineáris függvények módszere.
 - 3.3. Nem lineáris függvények módszere.
 - 3.4. Szakaszosan lineáris függvények módszere.
4. Egyéb módszerek.
 - 4.1. Korrelációs módszer.
 - 4.2. Regressziós módszer.
 - 4.3. Sztochasztikus megközelítés módszere.
 - 4.4. Nyelvészeti módszer.
 - 4.5. Logikai összefüggéseken alapuló módszerek.

Nagy tömegű, mért adatokból felépített adatbázis esetén általában valamilyen statisztikus döntési módszer alkalmazása célszerű.

Jelen tanulmányban vizsgált alakfelismerő eljárás kiválasztása a következő szempontok alapján történt:

- 1./ Az eljárás matematikailag jól megalapozottnak látszott.
- 2./Bemeneti adatként egy Fourier transzformáció, illetve egy spektrumanalizátor által szolgáltatott jellemzők szerepeltek.
- 3./ Az adatredukció matematikai eszközökkel, a Korhunen-Loeve sorfejtés alkalmazásával történik.
- 4./ A döntésre felhasznált Bayes-döntés aránylag jól ismert és egyszerű eljárás.

A bő irodalom ellenére /6-11/, az eljárás megvalósítása során két jelentős pontnál:

1. Az osztályok különbözőségét kifejező korrelációs mátrix képzésénél.

2. Az osztályba besorolási döntésnél alkalmazott tényezők kiválasztásánál, mind az elméleti alapok, mint a közölt számpéldák ezeken a pontokban mutatkozó elnagyolása és következetlensége miatt nehézségek támadtak és egy aránylag jó eredményt adó algoritmus megalkotása és az algoritmus alapján működő program megírása lényegesen túlhaladta egy adott eljárás adaptálásának feladatát.

Az eljárás két szakaszra bontható:

1. Tanulási szakasz.
2. Felismerési szakasz.

A Tanulási szakasz folyamatai:

1. Adatbevitel.

Egy adott osztályt $/X/^{i_0}$ o számu x_j vektor jellemez,
ahol $j = 1, 2, 3, \dots, o$ és $i = 1, 2, 3, \dots, M_1$

o = a bemeneti jellemzők /elsődleges ismérvek/ száma.

M_1 = az osztályok száma.

Az egyes osztályokat reprezentáló vektorok s számu mintavétel alapján adódnak és így egy-egy osztályt a következő adathalmaz reprezentál:

X^1 osztály

$X_{111}, X_{112} \dots X_{11o}$

$X_{121}, X_{122} \dots X_{12o}$

.

.

.

$X_{1s1}, X_{1s2} \dots X_{1so}$

X^M osztály

$X_{M11}, X_{M12} \dots X_{M1o}$

$X_{M21}, X_{M22} \dots X_{M2o}$

.

.

.

$X_{Ms1}, X_{Ms2} \dots X_{MsO}$

2. A változók speciális korrelációs mátrixának kiszámítása.

2.1. Az osztályok átlag vektorainak számítása.

Kiszámítjuk az egyes osztályokat reprezentáló vektorok számtani középértékeit a mintavételek adatai alapján.

2.2. Kiszámítjuk az egyes osztályok kovariancia mátrixait.

2.3. Az egyes osztályok kovariancia mátrixainak összegezésével megkapjuk a változók speciális korrelációs mátrixát.

3. A speciális korrelációs mátrix sajátértékeinek és saját-vektorainak kiszámítása.

4. "B" mátrix előállítása.

A "B" mátrix a nagyságrendben sorba rendezett v számú másodlagos ismérvek számának megfelelő sajátértékekhez tartozó saját-vektorból jön létre, nagysága $v \times o$.

5. A "Mü" vektorok előállítása.

A "Mü" vektorok előállítása a "B" mátrix és az egyes osztályok átlagvektorainak összeszorozása útján.

6. Az adatmátrixok transzformációja a redukáló vektortérbe.

Az adatmátrixok ortonormális v dimenzióju vektortérbe történő transzformációja az adatmátrixok és a "B" mátrix összeszorozásával és az eredmény mátrixok invertálásával történik.

7. Az inverz mátrixok determinánsainak előállítása.

8. A kiszámított értékek tárolása.

Felismerési szakasz végrehajtásához szükséges számítási eredmények a következők:

- 8.1. "B" mátrix $/V \times O$ nagyságu tömb/
- 8.2. Determinánsok értékei $/M1$ darab/
- 8.3. "Mü" vektorok $/M1 \times V$ nagyságu tömb/
- 8.4. Inverz mátrixok $/M1 \times V \times V$ nagyságu tömb/

A felismerési szakasz folyamatai:

1. Adatbevitel.

A Felismerési szakasz a Tanulási szakasztól elkülöníthető, végrehajtásánál csak a tanulási szakasz eredményeire, valamint a felismerendő osztály elsődleges ismérv vektoraira van szükség.

2. Az osztályba-besorolás döntéséhez szükséges számítások elvégzése.

2.1. Az elsődleges ismérv vektorok transzformációja a másodlagos ismérvek terébe.

A transzformációt az elsődleges ismérv vektorok és a "B" mátrix összeszorzása hajtja végre.

2.2. Bayes-döntéshez szükséges részeredmények előállítás.

3. Osztálybasorolás döntésének elvégzése az egyes osztályokhoz tartozó számítási eredmények legkisebb eltéréseinek megkeresésének útján.

Az algoritmus egyszerűsített blokkvázlata az 1.sz.ábrán látható.

Az eljárás megvalósítása személyi számítógép alkalmazásával és az eddigi tapasztalatok.


Az eljárás kezdetben egy CBM 3032 /PET/ típusu személyi számítógéppel lett megvalósítva. A BASIC nyelvű programok legutóbbi változatai egy COMMODORE 64 /C-64/ típusu számítógépen futnak. A közölt futásidő adatok nagyjából azonosak mindkét típusnál. A memória hely szükségletéről közölt adatok a C-64 típusra vonatkoznak.

Az algoritmust alapjában véve két program realizálja, a tanulási szakaszt a TANULÁS, a felismerési szakaszt a FELISMERÉS program. Ezen programok változatai TAN+dátum, illetve FEL+dátum nevűek. Az egyes változatok közötti különbség alapvetően a különböző adat be- és kiviteli lehetőségek változásán alapszik.

Az - 1984 ÁPRILIS alnévvel rendelkező változatoknál az adatbevitel történhet billentyűről, floppyról és magnetofonról, valamint a CF-300 típusu spektrumanalizátorról.

A FELISMERÉS programnál a helyes döntés ellenőrzését egy beépített automatikus ellenőrző alprogram végzi, amely azt vizsgálja, hogy a tanulási szakaszban felhasznált mintákra nézve milyen az osztálybesorolási döntés megbízhatósága a különböző nagyságu másodlagos ismérvek alkalmazásakor.

A program hatásossága legelőször önkényesen felvett adat csoportokra lett vizsgálva. Az elsődleges ismérvek száma $o = 10$ volt, a mintavételek száma s 4-6 között változott és maximum 30 volt a vizsgált osztályok száma. A vizsgált 30 osztály 152 mintavételének adatai az 1.sz.mellékletben megtalálhatóak.



1. ábra. A jelfelismerő eljárás folyamatábrája.

A felvett mintaadatakra kapott eredmények:

Az 1-10. adatszoportoknál:

Másodlagos ismerv szám	Tanulási idő /perc/	Felismerési idő /mp/		Döntési megbízhatóság %
		Automa-tánál	Egyedi döntésnél	
2	16	3,6	6	98
3	15	5,6	8	100
+ 10 (1-10) - 3d				

Az 1-30. adatszoportoknál:

Másodlagos ismerv szám	Tanulási idő /perc/	Felismerési idő /mp/		Döntési megbízhatóság %
		Automa-tánál	Egyedi döntésnél	
2	20	9,2	32-37	91,4
3	21	14,7	39-41	98
4	23	21,6	46-49	100

A felvett számcsoportoknál 10 db elsődleges ismervnél az első tíz számcsoportnál /osztálynál/ 100 %-os felismerést kaptunk, amennyiben a másodlagos ismérvek szám $V = 3$ volt, míg a 30 osztálynál ez a felismerési megbízhatóság $V = 4$ -nél jelentkezett. A részletes vizsgálati eredmények a 2-6. mellékletek alapján tanulmányozhatóak.

Az automatikus osztálybasorolás esetén a program a tanulási szakasz²nál a betanításnál alkalmazott mintavételnél vizsgálja automatikusan, hogy az adott mintavételt a felismerési szakasz melyik osztályba sorolja. A hibásan felismert mintavételek adatai külön kiíródnak. Lehetőség van bármilyen minta billentyűről történő bevitelére. Eredményként a képernyőn és/vagy nyomtatásban megjelenik a beadott minta, döntés az adott minta osztályba sorolásáról és egy jelzőszám, aminek relatív értéke a besorolás erősségét mutatja.

A 2.sz. melléklet alapján a CS10/1-CS10/10 jelzésű tíz adatszoportnál /mintavételek száma összesen 50/ amikor 2 volt a másodlagos ismérvek száma egy a CS10/9 tartozó minta /4.sz.mintavétel/ lett hibásan felismerve. Egyedi döntési üzemmódnál bebillentyűzve ennek a mintának értékeit a számítógépbe, a második helyen tüntette fel.

A 3.sz. mellékleten a másodlagos ismérvek $V = 3$ esetén az automatikus felismerő üzemmódnál mind az 50 mintavétel osztálybasorolása az eredeti osztályoknak megfelelően történt. A $V = 2$ esetén hibásan besorolt mintavételnél a döntés erősségére utaló jelzőszámnál látható az algoritmus tapasztalt előnyös tulajdonsága, mivel 100 %-os döntéseknél a hibás döntésekre jellemző jelzőszám és a helyes döntés jelző száma között nagyságrendi különbségek mutatkoznak. Ez a nagyságrendi különbség mutatkozik a 3.sz. melléklet 2.oldalán, ahol az eredeti tanuláshoz felhasznált osztályok egyikére sem jellemző mintákkal történt a besoroláshoz tartozó jelzőszámok tanulmányozhatóak.

A fenti gondolat menetnek megfelelő vizsgálatok eredményei 30 osztálynál /összesen 152 mintavétel/ láthatóak a 4-6.sz. mellékleteken.

Következő lépésként valódi jelek mintáinak vizsgálata lett végrehajtva. Kilenc adó ugyanazokkal a számcsoporthal ellátott lyukszállagról lett megmodulálva A1 üzemmódban WPM-22 sebességgel. Az egyes adók műsorának vétele egy REV-251 típusú vevőkészülékkel, míg a jelek rögzítése kb. 1-1 perc időtartamig NAGRA típusú magnetofonnal történt 19 cm/sec sebességgel.

A kilenc adótól származó felvétel különböző sorrendben 3-6-ig terjedő mintaszámban összesen kétszer 30 minta formájában egy másik NAGRA magnetofon segítségével át lett másolva.

A mintákat tartalmazó magnetofon szalagot megkapta egy kutató intézet jelfeldolgozással foglalkozó részlege feldolgozás és értékelés céljából.

A kutató intézet a kapott mintákat az általuk kifejlesztett NE-400 típusú gyors A/D konverter és az ehhez csatlakozó NE-500 típusú programozható és távvezérelhető adatgyűjtő készülékkel digitalizálta. A digitalizált mintákat /Egy minta = 100 mért adat/ páronként összehasonlítva adatredukciót hajtottak végre. Az adatredukció eredményeképpen kilenc számjegyet kaptak. A kilenc számjegy páronkénti értelmezése a következő volt /12/:

1. Első minta amplitudó hisztogramjának átlagértéke.
2. Második minta amplitudó hisztogramjának átlagértéke.
3. Első minta amplitudó hisztogramjának szórása.
4. Második minta amplitudó hisztogramjának szórása.
5. Első minta amplitudó hisztogramja regressziós egyenesének meredeksége.
6. Második minta amplitudó hisztogramja regressziós egyenesének meredeksége.

7. Első minta amplitudó hisztogramja regressziós egyenesének és az y tengelynek metszés pontja.
8. Második minta amplitudó hisztogramja regressziós egyenesének és az y tengelynek metszés pontja.
9. A két minta amplitudó hisztogramja kereszt korrelációs együtthatója.

A kapott számsorokkal kapcsolatban végzett különböző vizsgálatok az általunk megadott mintákra vonatkoztatva negatív eredménnyel zárultak. Az adók azonosításának feladatát, egy tanító nélküli, vagy öntanuló felismerés végrehajtását nem sikerült végrehajtaniuk.

Más módszert keresve az azonos adókhoz tartozó minták amplitudó hisztogramjainak értékeit /100 érték/ a rendelkezésre álló számítógép kisméretű operatív memóriája miatt tizesével összeadva és ezen értékek számtani átlagaiból képzett számsorok alapján kapott minták és ezekből származtatott tanulási osztályokon végzett vizsgálatok a következő eredményeket adták;

A 8.sz.melléklet tartalmazza a $v = 2$ esetén kapott eredményeket. A $V = 3$ esetén a tanulás szakaszt az E/10 adatcsoport szórása nem elégítette ki az ortonormális transzformáció azon feltételét, hogy létezzenek a determinánsai az osztályhoz tartozó mintavételek korrelációs mátrixának /2/. A fenti feltétel nem teljesülését az amplitudó hisztogramok értékeinek előállításánál elkövetett eljárási hibára tudom visszavezetni. Az amplitudó hisztogramok értékeit lyukszállagon készen megkaptam.

A hibásnak mutató E/10 csoportot a vizsgálatból kiiktatva kapott eredmények a 9-10.sz. mellékletekben láthatóak. Nyolc osztály /27 mintavétel esetén/ $V = 2$ másodlagos

A vizsgálati adatszoportoknál az alakfelismerési eljárás megfelelő hatékonyságának bizonyult. Az eljárás nem szereti az olyan osztályokat jellemző adatokat, ahol nem teljesül az ortogonális transzformáció végrehajthatóságának feltétele.

A módszer olyan gyakorlati területeken alkalmazható, ahol adott annak a feltételnek teljesülése, hogy a felismerésre, azonosításra felhasznált adatok ténylegesen reprezentálják a felismerendő osztályokat.

Az eljárás egy matematikai adatredukciót hajt végre és ez a matematikai adatredukció /lényegkiemelés/ jól kiválasztott kiindulási adatok esetén igen hatásosnak ígérkezik.

Az osztályba besorolás döntésénél alkalmazott számok mennyiségi viszonyai alapján téves döntés esetén is lehetőség van bizonyos következtetések levonására egy helyes döntést illetően.

Ez utóbbi pont alapján véve az eddigi kísérletek tapasztalataira alapul. A tapasztalati tényeken alapuló hipotézis matematikai vizsgálata még nem lett végrehajtva.

Tervezem a módszer további vizsgálatát üzemmódok, adók azonosítási feladatainak végrehajthatóságának területein. Az eddigi vizsgálataim és közölt eredményeim úgy érzem előrevivő lépéseknek tekinthetőek az alakfelismerés és a komplex, többváltozós analitikai vizsgálati módszerek alkalmazásának bevezetése érdekében.

Budapest, 1984.

Gerlits Péter
/Gerlits Péter mk. alezredes/

IRODALOM JEGYZÉK

1. A.L. Gorelik, V.A. Szkripkin: Metogü Raszpornavánja.
Moszkva, 1977. Vüzsaja Skolä.
2. Fritz József: Az alafelismerés statisztikus módszerei.
MTA Matematikai Kutató Intézete.
Budapest, 1974.
3. L.T.Kuzin: Osznovü Kibernetiki.
Moszkva, 1979. Energia.
4. J.T.Tov, R.C.Gonzalez: Pattern Prognitron Principls.
Addison-Weslex Publishing Company. 1974.
5. Lőrinc Sándor: Komplex, többváltozós elemzési módszerek.
alkalmazása a műszaki fejlesztő munkában.
Ipargazdaság. 33.kötet 10.sz.
6. V.A.Omelcsenko: Osznovü szpektrolnoj teorii rozpoznanánija
szignalov. Szooobsenie I. Nesztacionarnüe
szignálü.
Rádiótechnika 1976. 38.sz. 44.o.
7. V.A.Omelcsenko: Osznovü szpektrolnoj teorii rozpoznanánija
szignalov. Szooobsenie II. Stacionarnüe
szignálü.
Rádiótechnika 1976. 38.sz. 49.o.
8. V.A.Omelcsenko: Osznovü szpektrolnoj teorii rozpoznanánija
szignalov. Szooobsenie III. Vremennüe i
szpektrálnüe priznaki.
Rádiótechnika, 1976. 39.sz. 31.o.

9. V.A.Omelcsenko: Osznovü szpektrolnoj teorii raszpornanánija szignalov. Szoobsénie IV.Sztacionárnüe Gausszovüe szignálu . pri apriornoj nedosztatocsnosztü.
Rádiótechnika, 1977. 41.sz. 12.o.
10. V.A.Omelcsenko, V.V.Balabanov: Raszpoznavanie szignalov pri szpektru na báze analizátorov parallelno - poszledabatelnovo tipa.
Rádiótechnika, 1977. 41.sz. 37.o.
11. V.A.Omelcsenko, V.V.Balabanov, V.V.Klimenko: Ekszperimetalnoe isszledovanie raszpozanánija szignalov pri szpektru.
Rádiótechnika, 1977. 42.sz. 30.o.
12. O-13. Tudományos kutatási zárójelentés.
Budapest, 1982.