

**NJSZT**

MŰSZAKI ÉS TERMÉSZETTUDOMÁNYI EGYESÜLETEK SZÖVETSÉGE

**NEUMANN JÁNOS SZÁMÍTÓGÉPTUDOMÁNYI TÁRSASÁG**

Budapest. V., Báthory u. 16.

Levél cím: Budapest 5. Postafiók 240 1368

---

## II. NEUMANN KONGRESSZUS

### 3. SEKCIÓ ELŐADÁSAI

**Székesfehérvár,**

1983. november 14–17.



Dr. Halassy Béla:

ADAM&EVA - Adat- és eljárásmodellezési segédeszköz

1. Általános háttér

Az utóbbi időben felgyorsultak azok a kísérletek, amelyek az információs rendszerek fejlesztésének számítógépes támogatására irányulnak. Ezeknek a próbálkozásoknak az egyre inkább kikristályosodó strukturált tervezési elvek, a mind szélesebb körben terjedő adatszótár-rendszerek /pl. az IDMS IDD/ és a rendszerek leírására és elemzésére szolgáló nyelvek /mint amilyen az MTA SZTAKI-ban kifejlesztett SDLA, vagy a nálunk is alkalmazott PSL/PSA/ teremtettek alapot.

A rendszerfejlesztés számítógépes támogatásának gyakorlati lehetőségei tovább nőttek azáltal, hogy újabb elvi eredmények születtek a fejlesztés módszerét illetően. Két, meglehetősen újszerű tervezési elv került előtérbe:

- az adatok és eljárások párhuzamos fejlesztésének lehetősége és követelménye;
- a fogalmi-logikai-fizikai tervezési szintek szétválasztásának igénye.

Mindkét újszerű elv az adatbázisok tervezését szolgáló adatmodellezésben alakult ki és bizonyította érvényességét.

Az elvi lehetőségek ellenére mégsem születtek széleskörűen elterjedt rendszerfejlesztési segédeszközök. Ugyanis az ilyen jellegű programrendszerek tervezésének és alkalmazásának több feltétele van. Ki kellene alakítani egy olyan fogalmi rendszert, amelyet következetesen alkalmaznának a segédeszköz fejlesztésénél és használatánál. Egyértelműen meg kellene alapozni egy olyan szabályrendszert, amely rögzitené, hogy az adat- és eljárásmodell felépítését milyen feltételek mellett tekintik optimálisnak. Össze kellene állítani egy eljárásrendszert, amely meghatározná azt, hogy milyen tevékenység-sorozatban, milyen dokumentációval, milyen fejlesztési ellenőrzőpontokkal kell kialakítani az adat- és eljárásmodellt.

A fogalmi-, a szabály- és az eljárásrendszer egyenként is igen összetett. Az újszerű elvek nemcsak a felhasználó, hanem még a viszonylag széleskörűen tájékoztatott szakember számára is alapos átgondolást igényelnek a megértéshez. A tájékozott szakemberek között pedig éles a vita az említett elveket, fogalmakat illetően. Nem csoda, hogy a fejlesztési segédeszközök mindennapos alkalmazása még várat magára.

## 2. Az ADAM&EVA fogalmi rendszere

Mellékelt ábránk a modellező segédeszköz adattárát, szótárának felépítését mutatja. A tervezett adatmodellben a valós rendszer jelenségeit egyedekkel /2/, azok sajátosságait tulajdonságokkal /1/, összefüggéseit kapcsolatokkal /5/ tükrözzük a fogalmi elemzés szintjén. Minden egyed tetszőleges tulajdonsággal írható le. A tulajdonságok közül egyesek hordozzák a kapcsolatokat /16/. Mód van az egyed-altípusok modellezésére is /12/. Többszörös, önmagába visszamutató, családfa, halmaz /szinguláris/ és hierarchikus kapcsolatszerkezetek építhetők fel /15/.

A meglévő rendszer adatforrásainak /bizonylatainak, nyilvántartásainak stb./ elemzéséhez szolgál az eredet fogalma/3/. Minden eredet adott számú tulajdonság származási helye /17/. Modellezhetjük az összetett adatforrások belső szerkezetét is /13/. Az eredet fogalmat használjuk az információfeldolgozási műveletek eseményeinek jelölésére is, hiszen minden esemény tulajdonságokkal írható le.

Az eljárásmodell az információs tevékenységeket megindító és befejező eseményekből /3/ illetve az események között végrehajtott eljárásokból /4/ áll. Az események-eljárások összefüggései /18/ adják a tevékenység-események hálós szerkezetét. Az eljárások hierarchikus lebontására is van mód /14/. Az információfeldolgozási műveleteket két csoportba soroltuk:

- Felhasználói műveleteknek hívjuk az információátalakító tevékenységeket. A tulajdonságokon /adatokon/ végzett feltételes vagy feltétel nélküli algoritmusok külön is leírhatók /20/. A tulajdonságok származtatási összefüggéseit, az ugynevezett előzményhálót /11/ lehet részletezni a számítás leírásával.
- Adatkezelési műveleteknek nevezzük azokat a tevékenységeket, amelyek az adatoknak az adatszerkezetekből való előkeresésére szolgálnak. Az egyedekben lévő tulajdonságok előkereséséhez egyedeket és kapcsolatokat kell kezelnünk adott logikai sorrendben. Ezt a műveletsorozatot rögzíti a navigáció /19/.

A szótárban megadhatjuk a modell-elemek szinonimáit. Mindezek az elemek másodlagos névkulcsokon keresztül is elérhetők. A tulajdonságoknál külön specifikálható az általános értékhalmoz /"domén"/ és annak sajátos alhalmozai /"attributumok"/. A tervező meghatározhatja a szótárban azokat a feltételeket /korlátokat/ is, amelyek esetén az elemek és szerkezetek érvényesülnek.

### 3. Az ADAM&EVA modellezési szabályai

Az adat- és eljárásmodellt akkor tekintjük optimálisnak, ha

- valóságú,
- teljes,
- minimális /nem-redundáns/
- és egyértelmű.

A tulajdonságok elemzésénél kizárjuk a homonimákat. Ezzel biztosítjuk a tulajdonságok egyértelműségét és fokozzuk azok teljességét illetve javítjuk a valóságúságot. A tulajdonság-egyed viszonyok elemzésével szűrjük ki a szinonimákat, ezzel csökkentve a tulajdonságok számát.

Az egyedek elemzésénél a rendszer egyértelmű neveket generál.

Rendszerünk az ismert ötödik normál formán tulmutató egyed-szerkezetek képzésére alkalmas, hogy a lehető legtökéletesebb képet adhassuk a valóságról minimális tulajdonság-egyed viszony, vagyis a legkevesebb adat segítségével. Rendszerünk felhívja a figyelmet a normál formák ellentmondásaira /a szerkezeti egyértelműség hiányosságaira/.

A kapcsolatok elemzésénél kiszűrjük a tranzitív és ciklikus szerkezeteket /minimalitás/. A neveket itt is a rendszer generálja /egyértelműség/. A kapcsolhatóság vizsgálata utal bizonyos hiányzó kapcsolatokra /teljesség/. A kapcsolatokat a rendszer a tulajdonság-egyed viszonyok alapján generálja. Vagyis az egyedek valóságghűsége a biztosítéka a kapcsolatok valóságghűségének. Rendszerünk a legbonyolultabb kapcsolati viszonyok elemzésére is alkalmas, hogy ezzel fokozzuk a valóság modellezésének tökéletességét.

A tulajdonságok előzményhálójának elemzése /megszakítás- és ciklusszűrés/ a felhasználói műveletek egyértelműségét és teljességét garantálja. Hasonló előzményháló elemzést végezhetünk az események-eljárások összefüggéseire is. Az eredetek tulajdonságainak átfedésével csökkenthetjük a feldolgozási műveletek eseményeinek /input-output/ számát, fokozva azok egyértelműségét. Az adott kimenetek előállításához szükséges navigációs utvonal alternatíváit, az adott eljárás által érintett adatmodell-részeket /az adatmodell/ a rendszer automatikusan generálja. Mivel minden egyedre, tulajdonságra és kapcsolatra megfelelő létrehozási, törlési, karbantartási és feldolgozási műveletnek kell vonatkoznia, rendszerünk képes kimutatni, hogy a tervező által megadott eljárásrendszer teljes-e ebben az értelemben, vagyis azt, hogy valamilyen adatmodell-elemre nem hiányzik-e valamilyen eljárás.

Az adatmodell-korlátok karbantartásához és keresztellenőrzéséhez illetve a már megtervezett adat- és eljárásmodell újrastrukturálásához megfelelő karbantartó rendszer; a létrehozott modell elemeinek, szerkezetének és korlátainak lekérdezéséhez szelektív lekérdezőrendszer áll rendelkezésre. A tervező, karbantartó és lekérdező programok sorrendjét eljárásrendszerünk határozza meg. A rendszer szabványos bemeneti és kimeneti formátumai garantálják, hogy a rendszertervezőnek mindig rendelkezésére álljon a fogalmi szintű rendszerdokumentáció.

#### 4. Technikai megvalósítás

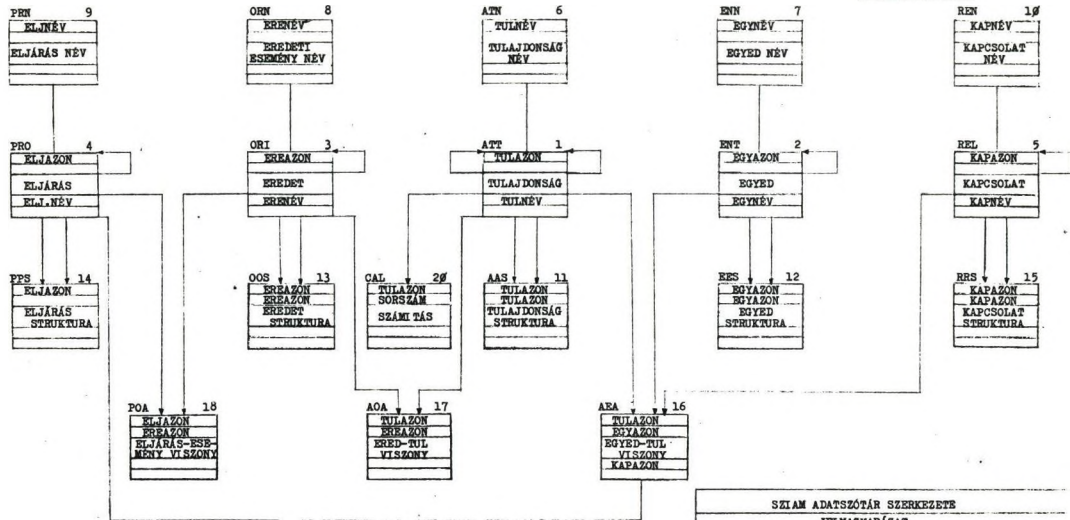
Már az előzőekből is sejthető, hogy az ADAM&EVA segédeszköz kialakításánál nem terveztünk SDLA, PSL/PSA, DDL vagy egyéb típusu modellező nyelvet. Inkább a strukturális kezelés mellett döntöttünk. Tapasztalataink szerint az ilyen nyelvek alkalmazása esetén rendkívüli mértékben megnövekszik az adatrögzítési igény.

Maga a modellező rendszer ESZR és kompatibilis gépekre készült. Mivel a rendszerszótárt a VSAM-ra bíztuk, csakis a virtuális kezelést biztosító gépek jöhetnek szóba. A rendszer - szemben elődjével, a SZIAM-mal - OS és DOS operációs rendszerek alatt egyaránt működik. Programjai kivétel nélkül PLIOPT forrásnyelvben íróttak.

A rendszer működtetéséhez kártyaolvasóra /vagy megfelelő más input berendezésre/, nyomtatóra, egy szalagra és két lemezegységre van szükség. A központi valós memóriaigény 256 Kbyte. A tényleges lemezigény a modellezendő probléma nagyságától függ. Elvileg a rendszer 100 ezer adat és ugyanennyi eljárás modellezésére alkalmas.

A segédeszköz bárki által bérelhető vagy megvásárolható. Használatát Modellezési Kézikönyv és Programozási Kézikönyv írja le. A modellezéssel kapcsolatos ismereteket a terméktől független tanfolyamokon is el lehet sajátítani.

1. melléklet



**SIEM ADATSZÓTÁR SZERKEZETE**  
**JELMAGYARÍZÁS**

1. SZINT NÉVKULCSOK	→	* AZONOSÍTÓ
2. SZINT ELEMREKORDOK	→	* EGYEDNÉV
3. SZINT STRUKTURA REKORDOK	→	* KAPCSOLÓ
4. SZINT VISZONY REKORDOK	→	
5. SZINT NAVIGÁCIÓ	→	1:1 FOKU
PRO RÖVID EGYENÉV	→	1:N FOKU
10 EGYED SORSZÁMA	→	TÖBBSZÖRÖS
	←	VISSZA-MUTATÓ

\* FÜGGŐSÉNY



dr. Budavári Elemér

Marx Károly Közgazdaságtudományi Egyetem Matematikai  
és Számítástudományi Intézet

META-INFORMÁCIÓRENDSZERREL TÁMOGATOTT RENDSZERFEJLESZTÉS  
ÉS ADATBÁZISTERVEZÉS

1. A rendszerfejlesztést és az adatbázistervezést támogató  
software eszközök helyzete

Az adatbázis technika magyarországi alkalmazásának fő problémája, hogy a tervezési, fejlesztési módszerek, segéd-eszközök szintje elmaradt az alkalmazható software eszközök színvonalától. Sem elméletileg sem gyakorlatilag nincs pontosan tisztázva, hogy az adatbázis-alapú információrendszerek adat - és eljárásmodellezési folyamata miként illeszkedik a rendszerfejlesztés klasszikus munkafázisaihoz. Ezért a tervezők alapvetően csak az adatmodellezésre, pontosabban a séma kialakítására koncentrálnak és elhanyagolják az eljárásmodellezést, a felhasználói rendszer működési jellemzőinek a vizsgálatát.

A két modellezési munka párhuzamos végzésének követelménye a szervezés tárgyáról teljes képet igényel mind az adat-szerkezet, mind annak használatát vonatkozásában. A teljes kép viszont csak folyamatosan, a fejlesztési folyamat előrehaladtával áll össze, egyre mélyebb és részletesebb formában.

A kialakítandó információrendszerre vonatkozó ismeretek, dokumentációk alapvetően két fő csoportra tagolhatók aszerint, hogy a logikai vagy a fizikai tervezés körébe tartoznak. Az adatbázis tervezés módszereiből következően a logikai tervezés a teljes rendszerre vonatkozó információigénnyel lép fel. Ezzel szemben a fizikai tervezés, illetve megvalósítás rendszerint alrendszerenként, több éves időszak alatt történik.

Igy egy nagyméretű számítástechnikai fejlesztési program sikeressége elsősorban a logikai tervezés stabilitásán, dokumentáltságán és koordinálhatóságán múlik.

A rendszerfejlesztés egyes munkafázisainak elősegítésére és dokumentálására már hoztak létre számítógépes segéd-eszközöket, azonban ezek között nincs kapcsolat, nem ölelik fel a fejlesztés és üzemeltetés teljes folyamatát.

Ezért egy olyan számítógépes támogatású rendszerfejlesztési eszköz kialakításához fogtunk hozzá, amely egyaránt alkalmas a kialakítandó információrendszer tartalmának, működési rendjének, számítástechnikai alkotóelemeinek egységes elvek szerinti meghatározására, kezelésére és dokumentálására. A módszer alapjául egy kétszintű információrendszer szolgál, amelyben:

- \* az alsó szint: a kialakítandó tárgy - információrendszer,
- \* a felső szint: a meta - információrendszer, mely adatokat tartalmaz a tárgy - információrendszernek a fejlesztés és működtetés szempontjából fontos jellemzőiről, így:
  - a tárgy - információrendszer szervezeti felépítéséről, tevékenységi rendszeréről;
  - az egyes rendszerekben szereplő adatok köréről, azok jelentéséről, jellemzőiről;
  - az adatok szerkezetéről, az adatokhoz való hozzáférés jellegéről, módjáról;
  - az adatok származási és rendeltetési helyéről;
  - a tárgy - információrendszer fejlesztési fázisairól, gépesítettségi állapotáról, stb.

## 2. A meta - információrendszer koncepciója

A meta - adat fogalmát, szűkebb értelemben, az adatbázistechnika alkalmazása során vezették be az adatbázisban tárolandó adattípusok azonosító és leíró adatainak megnevezésére. E szemlélet általánosításával jutottak el a rekordtípusok, file-ok, programok, majd pedig az információrendszer egyéb, nem számítástechnikai alkotóelemeit leíró meta - adatokhoz. A nagytömegű meta - adat tárolásának és kezelésének bonyolultsága ezen a területen is az adatbázistechnika alkalmazásához illetve az adatútmutató / adatszótár rendszerek kialakításához vezetett.

Az adatszótárak készítői egyrészt az adatbázis - kezelő software igényeit, másrészt a legáltalánosabb számítástechnikai és információi rendszerbeli kategóriákat, jellemzőket és kapcsolatokat vették figyelembe, s nem a rendszertervezés illetve az adatbázistervezés adatigényét. Ezért többségük meghatározott adatbázis - kezelő rendszer működésének alapja, s nem a rendszerfejlesztés teljes életciklusa alatt alkalmazható segédeszköz.

Az adatbázistervezéshez kapcsolódó elméleti kutatások feltárták azon információk körét, amelyek nélkül a tervezés nem végezhető el. A gyakorlati, vállalati munkák viszont azok összegyűjtésének és kezelésének problémáira, valamint a fejlesztési munkafázisokkal való szoros összefüggésre világítottak rá. Az elméleti és gyakorlati szempontok ütköztetése és szintézise a számítógépes meta - információrendszer koncepciójának kidolgozásához vezetett.

A meta - információrendszer

- a meta - adatbázisból és
- az azt kezelő meta - programrendszerből áll.

### 3. A meta - adatbázis tartalma

A meta - adatbázis tartalmának meghatározásához a számítógépes tárgy - információrendszer fejlesztésének munkafázisait vettük elemzés alá, s megvizsgáltuk a hagyományos, illetve az adatbázison alapuló fejlesztés közös és specifikus adatigényét. Megvizsgáltuk továbbá, hogy az adatbázis-tervezés három fő modellezési lépése

- a koncepcionális modellezés,
- a logikai számítástechnikai modellezés és
- a fizikai számítástechnikai modellezés

miként illeszthető a rendszerszervezés hagyományos munkaszakaszaihoz.

A meta - adatbázis tervezése módszertanilag azonos bármely más adatbázissal, tehát meg kell határozni:

- a META - EGYEDEKET,
- a META - ISMÉRVEKET és
- a META - KAPCSOLATOKAT.

\* A META - EGYEDEK a tárgy - információrendszerben megfigyelt objektumok, jelenségek típusait definiálják (pl.: SZERVEZET, TEVÉKENYSÉG, PROGRAM, TÁRGY-EGYED, stb.).

\* A META - ISMÉRVEK egy adott META - EGYED típus előfordulásainak azonosítására, leírására és jellemzésére, valamint a META - KAPCSOLATOK létrehozására szolgálnak;

\* A META - KAPCSOLATOK a META - EGYEDEK közti természetes adatkapcsolatok, adatkezelési funkciók realizálására szolgálnak.

A tárgy - információrendszer fejlesztése folyamán egyes META - EGYEDEK csak meghatározott fázisban, mások viszont

több vagy valamennyi modellezési fázisban szerepelnek, s így META - ISMÉRVEIK köre fokozatosan bővül.

A META - ISMÉRVEK specifikálása különösen fontos feladat volt, minthogy az adatszótár rendszerek nem léptek túl az azonosító és leíró (definiáló) META - ISMÉRVEK körén, tehát a felhasználóra, elsősorban az adatbázis adminisztrátorra hártották a feladatot.

A META - ISMÉRVEK nagyobb része kötelező minthogy azonosító, kapcsolatteremtő és osztályozó funkciót töltenek be. Kisebb részük választható, elhagyásuk nem érinti a meta - adatbázisra épülő programrendszer működését. Arra is van lehetőség, hogy a felhasználó a rendszer generálásakor, általa fontosnak ítélt új META - ISMÉRVEKET vegyen fel.

A META - ISMÉRVEK egy része kimondottan az adatbázis tervező információ igényeit hivatott kielégíteni, illetve a tervezés eddigi eredményét kívánja rögzíteni. Így specifikálásuk bizonyos mértékig kényszerpályára tereli a tervezőt.

#### 4. A meta - programrendszer funkciói

A meta - programrendszer alapvetően négy részből áll:

\* az előkészítő, definiáló, ellenőrző programrendszerből, amely:

- létrehozza a meta - adatbázis definíciót,
- elvégzi a meta - adatbázisba kerülő adatok szintaktikai és szemantikai ellenőrzését (off - line adatbevitel esetén);

\* a betöltő, aktualizáló programrendszerből, amely:

- elvégzi az elsődleges betöltést, illetve
- a folyamatos bővitést, módosítást;

- \* a visszanyerő, tájékoztató, elemző - tervező programrendszerből, amely szolgáltatja:
  - a tárgy - információ rendszerre vonatkozó aktuális fejlesztési információkat,
  - az adatbázis tervezési segédleteket és
  - az egyéb software vagy tervezési eszközökhöz szükséges alapadatokat;
- \* a karbantartó és helyreállító programrendszerből, amely felhasználói vagy rendszerszintű hibák elhárítására szolgál.

## 5. A meta - információ rendszer működése

A rendszerfejlesztési munkát a szakaszosság és az iterativitás jellemzi. Ebből következően a meta - adatbázis csak fokozatosan töltődik, tartalma állandó változás alatt áll. E változások jelenthetik;

- új META - EGYED előfordulásainak betöltését,
- új meta - adatbázis rekord bevitelét,
- meglévő meta - adatbázis rekord adott mezőinek elsődleges megadását, vagy módosítását,
- új kapcsolatok létesítését, vagy meglévő kapcsolatok módosítását.

A meta - adatok elsődleges rögzítésére megfelelő bizonylat típusok szolgálnak, amelyekről off - line bevitel esetén az adatrögzítés, on - line bevitel esetén pedig a terminál kezelés történhet. Mindkét megoldási módot a mezőnkénti bevitel jellemzi, minthogy a meta - adatok keletkezésének és folyamatos bővülésének, változásának leginkább ez felel meg, s a végfelhasználó számára is ez biztosítja a legnagyobb kényelmet.

A visszanyerő, tájékoztató meta - programrendszer elsődleges betöltés, változások esetén standard reportokkal látja el a tervezőket, melyek alapidokumentációként funkcionálnak, de ad hoc igények kielégítésére is lehetőséget nyújt.

#### 6. A rendszerfejlesztés és az adatbázis tervezés folyamata

A meta - információrendszer alkalmazása esetén a tervezők az adatbázis tervezés korábban említett három modellezési fázisát követik. Ezen belül azonban több elemi lépés található, mely mindegyikéhez önálló meta - adatnyerési eljárás tartozik. A főbb elemi lépések a következők:

- 1./ A tárgy - információrendszer a statikus tevékenység modelljének megállapítása és dokumentálása,
- 2./ A tárgy - információrendszer dinamikus tevékenységi modelljének feltárása és tárolása a meta - adatbázisban,
- 3./ Az elemi tevékenységekhez tartozó egyed típusok meghatározása és definiálása,
- 4./ Az elemi tevékenységi kapcsolatok ismérvtartalmának egyedenkénti meghatározása, definiálása és tárolása,
- 5./ Az egyedtipusok ismérvlistájának összeállítása, az ismérvek elemzési, csoportképző kódjainak a meghatározása, az adatbázis várható tartalmának a körülhatárolása.
- 6./ A koncepcionális szintű egyedkapcsolatok definiálása és tárolása,
- 7./ A koncepcionális ismérvkapcsolatok elemzése az információs rekordok és csoportok képzése a funkcionális függőség alapján (egyedtipusonként).
- 8./ Logikai adatbázis rekordtípusok képzése a koncepcionális adatmodellből,

- 9./ A tevékenységek számítástechnikai egységekre, program funkciókra bontása,
- 10./ A tevékenységi kapcsolatok programfunkciókra vetítése, a program kapcsolatok meghatározása,
- 11./ A program kapcsolatok adattartalmának a definiálása, az adatigények csoportosítása (adatbázis, külső file-ok),
- 12./ A logikai adatelérési igények meghatározása, a logikai adatbázis szerkezet megfelelő finomítása,
- 13./ A tárgy - információrendszer adatbázis sémájának definiálása,
- 14./ A programok, rekordtipusok, file-ok végleges formájának a meghatározása,
- 15./ A fizikai megvalósítás, programozás, tesztelés,
- 16./ A fizikai megvalósítás, üzemeltetés paramétereinek rögzítése a meta - adatbázisban.

#### 7. A meta - információrendszer megvalósítása

A megvalósítási lehetőségek mérlegelésekor elsősorban az IDMS adatbázis kezelőrendszer szolgáltatásait vettük figyelembe. A meta - adatbázis tartalmának megtervezése után világossá vált, hogy az IDD 1.2. változattal ez nem valósítható meg, a magasabb verzió számú változatok pedig még nem álltak rendelkezésre, így a saját fejlesztésű meta - adatbázis kialakítása és meta - programrendszer kidolgozása mellett döntöttünk.

Jelenleg a meta - információrendszert támogató software egy része rendszertervezési, más része programtervezési és programozási fázisban van.



Statisztikai adatállományok megőrzésének és  
forgalmának jogi szabályozása

---

Bevezetés

Az 1973. évi V. törvény az állami statisztika egységes rendszerének megvalósítása és működtetése érdekében előírja a különböző statisztikai tevékenységek összehangolását, és ennek irányítását a KSH elnökének feladatává teszi.

A statisztikai tevékenységek összehangolása mellett a KSH-nak e tevékenységekről nyilvántartást is kell vezetnie, amelyek egyik célja az érdekeltek - a statisztikai tevékenységet végző szervek és a statisztikai adatok felhasználói - tájékoztatása az adatgyűjtésekről, a rendelkezésre álló adatokról és az igénybevehető adatátadási szolgáltatásokról.

A törvény 7. §-a szerint az összehangolás során el kell érni a számítástechnika hatékony alkalmazását a statisztikai tevékenységben, gondoskodni kell arról, hogy a statisztikai tevékenységet végző szervek a statisztikai adatokat megőrizzék és egymásnak kölcsönösen átadják.

Az állami statisztikai rendszer a legtöbb országban, így Magyarországon is erősen strukturált. Olyan részrendszerekre bomlik, amelyek többé-kevésbé önállóak. Szervezetileg és a feladatok szempontjából elkülönülnek egymástól a központi állami és az igazgatási statisztikai rendszerek, tematikusan az önmagukban is összetett társadalom- és a gazdaságstatisztika. Mindehhez hozzájárul még az is, hogy egymással párhuzamosan számtalan önálló adatfeldolgozási rendszer működik. A részrendszerek összehangolása - integrálása - az egyik legfontosabb eredményt ígérő fejlesztési irány, amely azonos cél felé mutató különböző tevékenységeket, módszereket foglal magába. A részrendszerek együttműködésének egyik legfontosabb megnyilvánulási formája a statisztikai adatok többszörös, különböző felhasználó által történő hasznosítása. Ennek egyaránt vannak tartalmi, szervezeti és technikai feltételei.

Tartalmi szempontból alapvető a fogalmak, osztályozások egyezményes használata.

Az adatforgalom biztosítása érdekében egységes szabályozást igénylő technikai és szervezeti jellegű kérdéseket a következőképpen határozhatjuk meg: gondoskodni kell a közérdekű, gépi adathordozón tárolt elemi szintű adatállományok megőrzéséről, karbantartásáról, az adatállományokról való tájékoztatásról, az adatátadások hatásköri és szervezeti feltételeinek meghatározásáról.

A korábbi szabályozás eredményei és a felmerült fontosabb problémák

Az így körülhatárolt problémakör első jogi szabályozására 1977-ben került sor. A lépés akkori időszerűségét mi sem bizonyítja jobban, mint hogy egybeesett a statisztikai adatok számítástechnikai eszközök útján történő forgalmának fellendülésével.

A 2/1977/VII.30./KSH sz. rendelkezés kötelezővé tette a számítástechnikai eszközökkel rögzített és javított statisztikai adatok megőrzését, dokumentálását és az adatállományok bejelentését nyilvántartás céljából a KSH-nak. Előírta továbbá a selejtezési eljárás módját, valamint az átadási kötelezettséget.

A jogszabály teremtette rendezett keretek nyában hozzájárultak az együttműködés elterjedéséhez. Általánossá vált a szemlélet, hogy az egyes minisztériumok, országos hatáskörű szervek nem csak saját célra gyűjtenek statisztikai adatokat, azok mások számára történő megőrzése, átadása közös érdek.

Mindezt jól bizonyítja a statisztikai adatok számítástechnikai adathordozón /mágnesszalagon/ történő forgalmának folyamatos bővülése. A bővülés, fejlődés több szempontból is jól megfigyelhető.

A forgalomban átadóként vagy átvevőként érdekelt szervek köre ma már magába foglalja szinte az összes, statisztikai tevékenységet folytató államigazgatási szervet. Megjelentek átvevőként olyan, e körön kívül eső szervek is, amelyek kutatásaikhoz, döntésselőkeztéseikhez ilyen módon biztosítják a szükséges adatokat.

Az adatforgalom tartalom szempontjából is egyre változatosabb képet mutat. A rendelkezésre álló adatállományok egyre nagyobb hányada hasznosul így többszörösen.

A kezdeti szakaszra egy-egy statisztikai felmérés adatait tartalmazó mágnesszalagok másolatainak átadása volt jellemző. Ma már fokozatosan terjednek a hatékonyabb megoldások, ahol az átadott adatállomány az igényeknek megfelelően szelektált. Erre elsősorban az ad lehetőséget, hogy több szerv kiépítette adatbázisait.

Jól érzékelteti az előzőeket néhány adat a KSH Számítóközpont tevékenységéről, amely külső megrendelésre 1979-ben 116, 1980-ban 132, 1981-ben 220, 1982-ben 312 adatátadást teljesített. Az igénylők közel 70 %-a az állami statisztika egységes rendszerébe tartozó szerv, a többi azon kívüli kutatóintézet, vállalat. Bár az átadások többsége ma még mindig egyszerű másolat, 1982-ben 18 esetben történt szelekció, 34 esetben az adatok forrása a statisztikai adatbázis rendszer volt. A megőrzésre kerülő /archivált/ adatállományok száma is dinamikusan növekszik, melynek egyik oka az, hogy a KSH SZK belső szabályozása szerint éves, vagy annál nagyobb periodicitással gyűjtött adatokat nem selejteznek. Jelenleg kb. 1300 archivált alapadat-állomány van, ez a szám tartalmazza a statisztikai adatállományokon kívül az ezek értelmezéséhez szükséges segédállományokat is. A megőrzött adatok mennyiségének és az adatforgalomnak minden szempontból hasznos növekedése azonban az elmúlt években fokozatosan felszintre hozott egy sor problémát is, melyek közül a leglényegesebbek a következők:

- nincs kellő áttekintés az átadott adatok további sorsáról, felhasználásáról;
  - nincsenek rögzítve az adatok átadásának feltételei, elvei;
  - túl bonyolult az adatállományok nyilvántartása, de egyuttal még sincs azokról megfelelő tájékoztatás;
  - nem megoldott az adatok utólagos javítása, illetve annak dokumentálása;
  - nem biztosított az adatállományok hosszútávú megőrzése, stb.
- A problémák elemzése kimutatta, hogy ezek jelentős része megoldható a 2/1977 /VII.30./ KSH sz. rendelkezés korszerűsítése, átdolgozása útján. Javaslatot tettünk tehát egy, ennek helyébe lépő új rendelkezésre.

Jogszállal azonban nem minden baj orvosolható. A koordináció változatos eszköztárának több egyéb elemére is szükség van, amelyek közül - kívül esvén témakörünkön - csupán a kölcsönös adathasznosításban érdekelt szervezetek két és többoldalú megállapodásait, szoros együttműködését említjük.

#### A nemzetközi tapasztalatok

A munka megalapozása érdekében az előkészítési során igyekeztünk megismerni a nemzetközi tapasztalatokat, azt, hogy az egyes országokban miként szabályozzák a statisztikai adatok számítástechnikai feldolgozásával kapcsolatos tevékenységeket.

Vizsgálódásaink során sok országban talákoztunk hasonló jogi előírásokkal. Általános tapasztalat, hogy a jogi keretek a kapitalista illetve a szocialista országokban lényeges eltérést mutatnak.

Míg az előbbi országcsoporthoz általában átfogó "adatvédelmi" szabályozást dolgozott ki, addig a szocialista országokban hozzánk hasonlóan részleges előírásokkal találkozhatunk.

Az adatok rögzítésével és feldolgozásával kapcsolatban az általunk javasoltak a megismert külföldi gyakorlattal, szabályozásokkal összhangban vannak, sőt a KSH által megjelentetett, az adatgyűjtéseket ismertető katalógus tekintetében a legtöbb ország előtt járunk. Néhány esetben azonban találkozunk szigorubb, több megköveteltséget tartalmazó előírásokkal is.

Az NDK-ban és Csehszlovákiában a számítógéppel feldolgozott beszámolójelentések rögzítése kötött, szabványos formában történik. Ennek megfelelően a kérdőívek felépítésére is egységes követelmények érvényesülnek.

A lengyel statisztikai rendszer az egysátozás adatszolgáltatás megvalósítására törekszik. Az NDK statisztikai törvénye explicit módon tiltja, hogy a központi statisztika beszámolójelentéseit más szervek rögzítsék. Ez gyakorlatilag mindkét esetben azt jelenti, hogy más felhasználók feldolgozási igényüket csak az elrendelőn keresztül, a mágnesszalagon lévő állomány átvétele útján elégeithetik ki.

A statisztikai adatok tárolását /megőrzését, archiválását/ és dokumentálását több országban szintén különböző jogi előírások szabályozzák. Szásztriában, NDK-ban, Lengyelországban hozzánk hasonlóan az irattározás, levéltározás előírásainak e területre vonatkozó konkretizálásával oldják meg a problémát.

Külön fel kell hívni a figyelmet egy, a legtöbb nyugat-európai országban érvényes előírásra. Az adatvédelmi törvények szerint a gépi adathordozón tárolt, személyekre vonatkozó adatokat tilos archíválni. A konkrét felhasználási cél teljesülése, vagy meghatározott idő letelte után az adatokat minden esetben törölni kell.

Az adatok átadása területén a nemzetközi helyzetet a következő néhány példával kívánjuk illusztrálni. Az 1978. évi osztrák adatvédelmi törvény szerint a számítógéppel feldolgozott adatok átadása csak abban az esetben lehetséges, ha /1/ ezt a törvényt kifejezetten megengedi, /2/ ehhez az érintett /akire vonatkozik/ írásban hozzájárul, /3/ biztosítva van, hogy az érintett nem azonosítható, /4/ az adatok banki pénzforgalom céljait szolgálják, /5/ az átvevő a Statisztikai Hivatal, ahol az adatokat személytelenül, kizárólag statisztikai célból használják fel.

Az Európa Tanács konvenciója szerint az adatok forgalmában is biztosítani kell, hogy a személyi adatokat kizárólag eredeti, törvényes céljuknak megfelelően lehessen felhasználni.

A lengyel statisztikai törvény garantálja a statisztikai információkhoz való széles körű hozzáférést, amit kizárólag az állami és gazdasági titok, valamint a polgárok személyes jogi szférájának védelme korlátoz.

Az NDK-ban a felhasználók a központi adatgyűjtések adataihoz szintén csak az ÁKSH-tól juthatnak hozzá. Átvevőként kizárólag az adatszolgáltatók felügyeletét gyakorló minisztérium jöhet számításba, kivétel csak néhány funkcionális szerv /terv, pénzügy, munkaügy/ képez. Az adatok átadásáról és átvételéről az állami szervek egymással szerződést kötnek, amelyben az átvevő vállalja az adatok jövőbeli kezelésével kapcsolatos részletezett kötelezettségeket. Rendelkezés-tervezetünkben az engedély-kérésnél és az átadás engedélyezésénél kötelezően szerepeltetett témakörök meghatározásánál nagyon támaszkodtunk az NDK előírásaira.

## Az előkészítő munka menete, módszerei, tapasztalatai

Az előbbieken ismertetett indokok alapján, amelyeket a feltárt nemzetközi tapasztalatok is elátámasztottak, a KSH vezetése 1982-ben elhatározta a 2/1977/VII.30./KSH sz. rendelkezés felülvizsgálatát és átdolgozását.

Annak érdekében, hogy a különböző állami szerveknél felhalmozódott tapasztalatokat és kialakult igényeket a munkában hasznosítani lehessen, a Statisztikai Koordinációs Bizottság ideiglenes adatkoordinációs munkabizottságot hozott létre. Ez az új rendelkezés előkészítésében folyamatosan részt vett. Az igazgatási statisztikai rendszerek gyakorlatának és a képviselt 11 állami szerv véleményének megismerése a KSH számára igen sok segítséget jelentett.

Az egyetértés az új rendelkezés kibocsájtásának időszerezésével teljeskörű volt. A munkabizottság helyeselte a KSH elképzelései szerinti egyszerűsítéseket, az adminisztráció csökkentését. Néhányan viszont - az általuk képviselt állami szerv sajátosságaira, gyakorlatára tekintettel - túl sok megkötöttséget tartalmazónak ítélték meg az adatok átadására, továbbadására vonatkozó korlátozásokat, túl hosszúnak tartották bizonyos adatállományok megőrzésének időtartamát.

A munkabizottság működésének eredményeire is támaszkodva, a KSH főosztályvezetői értekezlete 1983. júniusában elfogadta az új jogszabály azon változatát, amely az előadás írásának időpontjában hivatalos véleményezésen van az érintett szerveknél, sőt azok legnagyobb részével az egyeztetés már be is fejeződött. Számítani lehet arra, hogy az új jogszabály az elképzeléseknek megfelelően még 1983-ban megjelenik.

### Az új szabályozás alapelvei

A hátralévő végső egyeztetések során az új szabályozás alapvető elvei, előírásai már feltehetőleg nem fognak változni. A következőkben áttekintjük, hogy az új rendelkezés milyen, a korábbitól eltérő lényeges mozzanatokat tartalmaz:

1. A számítástechnika statisztikai alkalmazásával összefüggő tevékenységek szabályozásának hatályát kiterjeszti minden szervekre, amely ilyen tevékenységeket végez.
2. Kifejezésre juttatja a statisztikai adatokat tartalmazó iratok tartalmától és minősítésétől függő és a számítástechnikai rendszerek általános titok-, vagyon- és tűzvédelméről szóló hatályos jogszabályok, iratkezelési szabályzatok alkalmazásának jelentőségét, a szabályozott statisztikai tevékenységekkel való összefüggéseit.
3. A korábbi kettős - központi és helyi - alakilag is egységes nyilvántartást és dokumentációt megszünteti. Helyette a tárolt statisztikai adatállományokról - asekéd és másodlagos adatállományokat is ide sorolva - a tárolás helyén ir elő tartalmilag egységes dokumentációt és nyilvántartást.
4. Biztosítja az érdekeltek széles körű tájékoztatását a KSH által kiadásra kerülő, az összes statisztikai adatgyűjtést tartalmazó katalógus megfelelő kiegészítésével. A jövőben ebben szerepelni fog, ha az adott adatgyűjtés adatait valamely szerv számítástechnikai eszközökkel feldolgozza és az így átvehető.
5. Kiterjeszti és a fontosabb adatállományok esetében minimum 15 évben határozza meg a megőrzési időt. A szabályok egyuttal biztosítják, hogy a történeti értéket képező adatállományok 15 év elteltével levéltári megőrzésre kerüljenek.

6. Szabályozza és egységesíti az adatátadás-átvétel engedélyezési, végrehajtási eljárását, a jogokat és kötelezettségeket, erősítve a magánszemélyek és a jogi személyek érdekeinek védelmét is. Lényeges előírás az átvett adatok továbbadásának és a magánszemélyekre vonatkozó, személyi azonosítóval ellátott statisztikai adatok átadásának megtiltása, valamint a szervezetek azonosítóval ellátott adataihoz való hozzáférés korlátozása.
7. Kifejezésre juttatja, hogy a számítástechnikai és a járulékos munka, illetve szolgáltatás költségeinek a megtérítésére az adatfeldolgozásra megbízást adó szerv kötelezett.

#### További feladatok

Az államtitkári rendelkezés megjelenésével a szabályozási tevékenység nem zárul le. A rendelkezés által szabott kereteken belül az adatátadásokkal kapcsolatos tevékenységeket és jogköröket minden ilyen tevékenységet folytató állami szervnek, így a KSH-nak is ügyrendben kell rögzítenie. Az ügyrend készítését és annak a felhasználókkal való megismertetését azért tartjuk szükségesnek, mert csak így látjuk biztosítotttnak az adatforgalom zökkenőmentes lebonyolítását. A felhasználó már igényének felmerülésekor tudja, hogy az adott állami szervben belül kihez kell fordulnia, milyen feltétellel számíthat az adatok átvételére.

A jogszabály előkészítésével párhuzamosan, tulajdonképpen annak előbe menve kétoldalú kapcsolatokon keresztül megkezdjük és jelenleg is folytatjuk azoknak az információknak a begyűjtését, amelyek majd az adatgyűjtési katalógusokban fognak megjelenni. Ezek arra vonatkoznak, hogy az egyes állami szervek milyen saját és átvett adatállományokat tárolnak mágneses adathordozón. Ahol lehet, az adatállományok konkrét lelőhelyét /pl. számítóközpont/ is közölni kívánjuk.

Lényeges feladat lesz a továbbiakban a jogszabály érvényesülésének ellenőrzése és támogatása. Az előbbit a KSH Ellenőrzési osztálya, az utóbbit a KSH adatforgalmának koordinálása céljából létrehozott Információs Szolgálat végzi.

#### Fontosabb források:

1. Az 1982. évi lengyel statisztikai törvény
2. Iszkowszki, J.: Az új állami statisztikáról. Wiadomosci Statyczne, 1983. május
3. Az NDK statisztikai és számviteli törvénye
4. Rendelet a statisztika és számvitel szabályszerűségeiről /NDK/
5. Ajánlás a központi állami szervek közötti mágnesszalagos adatcserére vonatkozó megállapodásra /NDK/
6. Az Országos Statisztikai Hivatal határozata a társadalmi-gazdasági információk írásos adathordozóinak módosításáról és gépi adathordozókra való viteléről /Csehszlovákia/
7. A japán statisztikai törvény és végrehajtási utasításai
8. Az Egyesült Királyság hivatalos statisztikai szolgálata /tájékoztató anyag/
9. Az osztrák és NSZK adatvédelmi törvények

10. Javaslat az Egyesült Királyság adatvédelmi törvényére
11. Az Európa Tanács konvenciója automatikus eszközökkel fel-  
dolgozott személyi adatok védelmére
12. Edgar Dunn: Social Information Processing and Statistical  
Systems, New York, 1974.

Kovács András-Sugár Péter-Vig Ervin-Kormos Kornélia-  
Apor György:

## KSH Államigazgatási Számítógépes Szolgálat

### Az IFP szöveges információkezelő rendszer és alkalmazásai

A szöveges rendszerek logikai alapegysége a dokumentum. A dokumentum mezőkből áll, amelyek az adatokat - az esetek nagy részében - kódolatlan formában tartalmazzák. A mezők csoportosítása fix, és egy adatbázisban csak egyféle dokumentumtípus lehet. A dokumentumok egyenrangúak, közöttük semmiféle strukturális kapcsolat nem áll fenn. A feldolgozás fő célja a dokumentumok egy olyan részhalmozának visszakeresése és megjelenítése, amelyben a mezők értékei megfelelnek a kereső kérdésben specifikált összetett feltételeknek.

Mivel a dokumentumok egyenrangúak, szükségtelen rendezési kulcsokat képezni, nem kell az adatokat kódolni, hanem elegendő az ember számára a legérthetőbb /egyben a gép számára legbonyolultabb/ formában az élő beszéd szavainak képében tárolni. Különösen előnyös az könyvek, cikkek, szakirodalmi tájékoztatók vagy akár személyek esetében, ahol a hagyományos kódolás csak igen nehézkes módon volna lehetséges. Gondoljunk csak el milyen egyszerűvé vált így egy könyv tartalmát néhány keresetlen szóval vagy akár egy kis rövid összefoglalóval jellemezni. Megtartva az általánosság igényét példánkat folytathatjuk a könyvnél. A könyvről szóló dokumentum egyéb mezője lehet még a szerző vagy a szerzők neve, a mű címe, a megjelenés éve stb...

A visszakeresés tipikus esete: melyek azok a könyvek, amelyek tartalma ezzel és ezzel a szóval jellemezhető, szerzője ez és ez stb... További szűkítő feltételtként szerepelhet még a megjelenési intervallum, a hozzáférhetőség nyelve és így tovább.

A jellemző szavakat /deszkriptorokat/ az adatbázis invertált file-ban tárolja. Egy szóhoz hozzárendeli mind azon dokumentumok azonosítóit, amelyek ezt a szót tartalmazzák. Így az összetett feltételű keresés ezeknek az azonosító halmazoknak a megfelelő összeválogatását jelenti. Az invertált file-ok alapján történő visszakeresést elsődleges visszakeresésnek nevezik. További szűrés végezhető még azon mezők alapján, amelyekből nem készült invertált file. Ez a szűrés már szekvenenciális és ugyancsak összetett feltétel alakjában fogalmazható meg. Ezt nevezik másodlagos visszakeresésnek.

A szöveges rendszereknek két jellemző irányzata terjedt el.

- a kötött és szabad szöveges rendszerek.

A kötött szöveges rendszereknél a deskriptorokat diszkrét szavak, esetleg kifejezések formájában kell megadni. Szabad szöveges rendszereknél az élő szöveg minden sava deskriptornak minősül. Ez utóbbinál az adatok előkészítése egyszerűbb, az adatbázis szerkezete bonyolultabb és különösen a ragozott nyelveknél nehéz a kereső kérdést jól megfogalmazni.

Az IFP /Invertált File Processor/ adatbázisának alapegysége a dokumentum. A dokumentum egy könyv, egy cikk, egy személy stb... jellemző adatait tartalmazza. A dokumentum mezőkből áll. Egy mező tartalma lehet pl. könyv esetén a könyv címe vagy tartalma /Annotáció/, szerzőjének neve, megjelenésének éve, a tartalomra jellemző szavak stb... Ez utóbbit deskriptoroknak nevezzük. Ebből látszik, hogy az IFP, u. n. kötött szöveges adatbáziskezelő rendszer. Az adatbázis file-jai a dokumentumokat és azok mezőit a visszakeresés és a megjelenítés szempontjából célszerű módon tárolják.

Bizonyos mezők tartalmából készíthetünk invertált file-okat. Ezek a file-ok egy mező egy bizonyos értékéhez kapcsolva tartalmazzák azon dokumentumok azonosítóit, amelyek ezt az értéket az adott mezőben tartalmazzák. Invertált file-ok alapján elsődleges visszakeresést végezhetünk, és az olyan mezőt, amelynek tartalmából invertált file készült, elsődleges mezőnek nevezzük. Ilyen minden esetben a deskriptorokat tartalmazó mező, de ilyen lehet pl. a szerző neve is könyv esetén, vagy minden olyan mező, amit az adott alkalmazási rendszer szervezője elsődlegesnek definiál. Az elsődleges visszakeresés kérdését a Boole algebra szabályaiból ismert és, vagy, nem operátorokkal lehet felállítani.

Az adatbázis logikai szekciókra bontható. Létrehozásakor minden dokumentumhoz hozzárendelhetünk egy  $\emptyset$  és 4095 közötti szekciószámot. Elsődleges visszakeresésnél megadható az u.n. szekció feltétel, mely szerint az elsődleges visszakeresés feltételrendszerén túlmenően csak azok a dokumentumok relevánsak, amelyek szekciószáma a megadott intervallumok valamelyikébe beleesik. Ez a lehetőség egy igen gyors szűrést tesz lehetővé.



Az elsődleges visszakeresés eredménye egy eredményhalmaz, amelyben további szűrés - másodlagos visszakeresés - végezhető. A másodlagos mezők értékeiből nem készült invertált file. Ezeket az értékeket a rendszer dokumentumként egyenként végigvizsgálja. A másodlagos visszakeresés kérdését is a Boole algebra szabályaival lehet felállítani. Az elsődleges és a másodlagos visszakeresés egyetlen visszakeresési ciklusban is megadható.

A visszakeresés lépcsőzetesen is végezhető. A megelőző eredményhalmaz szűkíthető vagy bővíthető. Ha a keresőkérdést túlszűkítettük, akkor a közvetlenül megelőző állapothoz vissza tudunk lépni, és új kérdést tehetünk fel.

A másodlagos visszakeresés után kellőképpen leszűkített eredményhalmazt megjeleníthetjük. Ezt nevezzük harmadlagos visszakeresésnek. Harmadlagos mezőt csak megjeleníteni lehet.

Másodlagos mezőt is lehet megjeleníteni. Ha ilyen szándékunk az elsődleges mezőkkel kapcsolatban is van, akkor az invertált file-okon kívül harmadlagos módon is tárolhatjuk. Meg lehet jeleníteni egy dokumentum megjeleníthető mezői közül az összeset vagy a tetszés szerint kiválasztottakat.

A harmadlagos mezők formázott módon is tárolhatók. Egy egy közbeiktatott !-jel azt jelenti, hogy megjelenítéskor új sor következik.

Az IFP adatbázishoz tartozhat még egy monohierarchikus tezaurusz is, mely tetszés szerint megjeleníthető. Egy fogalomnak lehet egy generikusa /főlérendeltje/, több specifikusa /alárendeltje/, több szinonimája és több rokona.

A rokoni kapcsolat kommutatív, de nem tranzitív. Elsődleges visszakeresésnél a kereső deszkriptorhoz opcionális módon hozzárendelhetjük azok szinonimáit is.

Az IFP-ben az adatbiztonság dokumentum és mező szinten valósítható meg. Minden dokumentumhoz, mezőtípushoz és felhasználóhoz hozzárendelhető egy 0 és 63 közötti szám. Ha a felhasználó biztonsági kódja kisebb, mint a dokumentumé vagy a mezőé, akkor az számára nem létezik.

Az IFP lehetőségei és elvi felépítése megegyezik a fejlett szöveges információkezelő rendszerekével - STAIRS, GOLEM, MISTRAL - de további előnyös tulajdonságokkal is rendelkezik:

- Az Államigazgatási Számítógépes Szolgálat /ÁSZSZ/ Honeywell számítógépén kis memóriában, gyorsan, olcsón üzemeltethető,
- terminálhálózaton keresztül hozzáférhető,
- használata rendkívül egyszerű.

Nézzünk meg egy alkalmazási példát.  
Keressük meg azokat a cikkeket, amelyek Magyarország valamint a Szovjetunió és a KGST kapcsolataival foglalkoznak és magyar vagy orosz nyelven hozzáférhetők.

```
SEARCH ("MAGYARORSZAG" OR "SZOVJETUNIO") AND "KGST"  
SELECT NYELV = "MAGYAR" OR NYELV = "OROSZ"
```

```
*IFP/RETR  
>>RETRIEVE ENGAGED .  
>>SEARCH ENGAGED 03/02/82 16:47:49:612
```

```
MAGYARORSZAG 000330  
SZOVJETUNIO 000507  
KGST 000201  
MINTERM 01 000036
```

```
>>RESULT AT END OF SEARCH = 000036  
>>SELECT ENGAGED 03/02/82 16:47:49:477  
>>RESULT AT END OF SELECT = 000011  
>>RESULT FILE = RB  
>>RETRIEVE FINISHED 03/02/82 16:47:50:116  
>>RETRIEVE FINISHED
```

Az adatbázis 6000 cikk adatait tartalmazza. Ebből 507 szól a Szovjetunióról, 30 Magyarországról és 201 a KGST-ről. A Szovjetunióval vagy Magyarországgal és a KGST-vel 36 cikk foglalkozik. Ebből tizenegynek a nyelve magyar vagy orosz.

Az eredmény nem egész 2 másodperc alatt megjelent a képernyőn.

Nézzük meg e 11 cikkből az első kettő nyelvét és rövid tartalmi kivonatát:

FIELD NYELV, ANNOTACIO  
11:11 - 2

\*IFP/DISPL

IFP PARLIODARY - OGYK TESZT 03/02/82 DISPLAY

000761 K003627

A MU NYELVE

OROSZ

TARTALMI KIVONAT

1976-80 SZOCIALISTA GAZDASAGI INTEGRACIO MECHANIZMUSA, SZOVJET  
OSSZEFOGLALO ERTEKELES, TERVKOORDINACIO ES ARUVISZONYOK,  
PENZVISZONYOK SZOCIALISTA GAZDASAGBAN, TUDOMANYOS, TECHNIKAI,  
TERMELESI EGYUTTMUKODES SZOCIALISTA INTEGRACIOBAN, SZOCIALISTA  
INTEGRACIO NEMZETKOZI SZERVEI ES KGST NEMZETKOZI KAPCSOLATAI,  
SZOVJETUNIO KULGAZDASAGI SZERVEINEK IRANYITASA, KGST TAGORSZAGOK  
GAZDASAGI KAPCSOLATAI, FEJLETT TOKES, FEJLEDO ORSZAGOKKAL,  
SZOCIALISTAKONYV

000652 K003660

A MU NYELVE

OROSZ

TARTALMI KIVONAT

1973-80 KGST, TERMELÉS KONCENTRALASA ES SPECIALIZALASA, 1977-80,  
NDK ERTEKELES, NDK ES SZOVJETUNIO, EXPORT, IMPORT ARUSZERKEZETE,  
STATISZTIKA, 1976-80, NDK ES KELET-EUROPAI SZOCIALISTA ORSZAGOK  
ARUCSERLEFORGALMA, 1973-76, SZOCIALISTASAJTO

Egyéb alkalmazási lehetőségek, amelyekre a rendszert  
kipróbáltuk:

- tudományos cikkek gyűjteménye a számítógépes szimuláció témaköréből;
- kóreset- és betegnyilvántartás;
- szabványok nyilvántartása;
- jogszabálynyilvántartás

Csicsman József: A SOLAR Adatszótára  
Központi Statisztikai Hivatal

A KSH Számítóközpontjában fejlesztettük ki a Statisztikai On-line Adatbázislekérdező Rendszert a SOLART-t.

A rendszer alapvető célja, hogy a KSH adatbázisrendszerének a leggyakrabban használt részét interaktív módon elérhesse a statisztikus felhasználó. Az adatok a rendszerbe a több éves tapasztalatok alapján kerülnek. Csoportosításuk alapvető szempontja az összehasonlíthatóság, azaz az, hogy általában az adatok nem rendezhetők hierarchikus rendbe.

A feladat specialitása miatt nem volt lehetséges az ismert adatbázislekérdező rendszerek bevezetése, azaz miképp a teljes rendszert, az annak szerves részét képező Adatszótárát ujszerű alapokon kellett létrehozni.

A SOLAR felhasználója statisztikai fogalmak segítségével kommunikál a rendszerrel. Az adatbázis lekérdezése és karbantartása egymástól minden szinten független módon történik. Az adatelérés nem rekordszinten, hanem a relációs modelleknek megfelelően modul szinten történik. /A modul egy adott statisztikai mutató adatainak összessége./ A lekérdezések hatékonysága legnagyobb mértékben az adattár és a szótár elérésétől függ.

Az imént felsorolt feltételek határozták meg az Adatszótár tervezését, mely két egymástól elkülönülő részből a Logikai és a Fizikai Adatszótárból áll.

A Logikai Adatszótár megfelel a SOLAR metainformációs rendszerének, mely létrehozása és karbantartása batch üzemmódban történik. Az alrendszer 16 fogalomra épülő rekordtipust és azok kapcsolatait kezeli, s eredményül a hibátlan rekordokat tartalmazó un. R- és a rekordok kapcsolatait leíró K-file-t szolgáltatja. Ennek a rendszerkomponensnek összefüggésellenőrző és a file-ok karbantartó részének programozását a SZÁMKI munkatársai készítették el.

A Fizikai Adatszótár a már on-line környezetben használt Adatszótárból és az un. Modul-címtárból áll.

Az Adatszótár speciális szerkezetű adatállomány, mely tartalmazza az egészében hálószerkezetnek megfelelő szótárrekordokat és az elérést meggyorsító indextáblákat.

A szótárrekordok 18 típusba sorolhatók, mely típusok az egyes statisztikai fogalmaknak és a tárolt adatmoduloknak feleltethetők meg. Minden rekord két részből áll

- az egyik az információs rész, mely tartalmazza az adott adatbázis elem felhasználói és az adatlekérdezéshez szükséges információit
- a másik a kapcsolatrészt, mely azt adja meg, hogy az adott rekord, mely más rekordokkal van kapcsolatban, azaz ezekkel a részekkel adható meg az adatbáziselemek kapcsolatrendszerét.

A Modul-címtár az adatmodulok fizikai címét tartalmazza, mely elérése az Adatszótáron keresztül történik. Rekordjai az egyes adatok időszakonkénti csoportosításában adják meg, hogy az Adatszótárban a definiált időszakokra létezik-e egy adott modul és ha igen, akkor az milyen fizikai címen található.

A Fizikai Adatszótár létrehozása a Szótár-betöltő és címtár inicializáló, a Modul-címtár karbantartása az Adatbetöltő alrendszer feladata.

Az Adatszótár használata a SOLAR Kommunikációból felhívható Runtime rutinok és az Adatbetöltés adatmodul információ lekérdező rutinja segítségével történik. A Runtime rutinok két részre, a felhasználó informálódását elősegítő és a lekérdezés végrehajtását támogató rutinokra bonthatók.

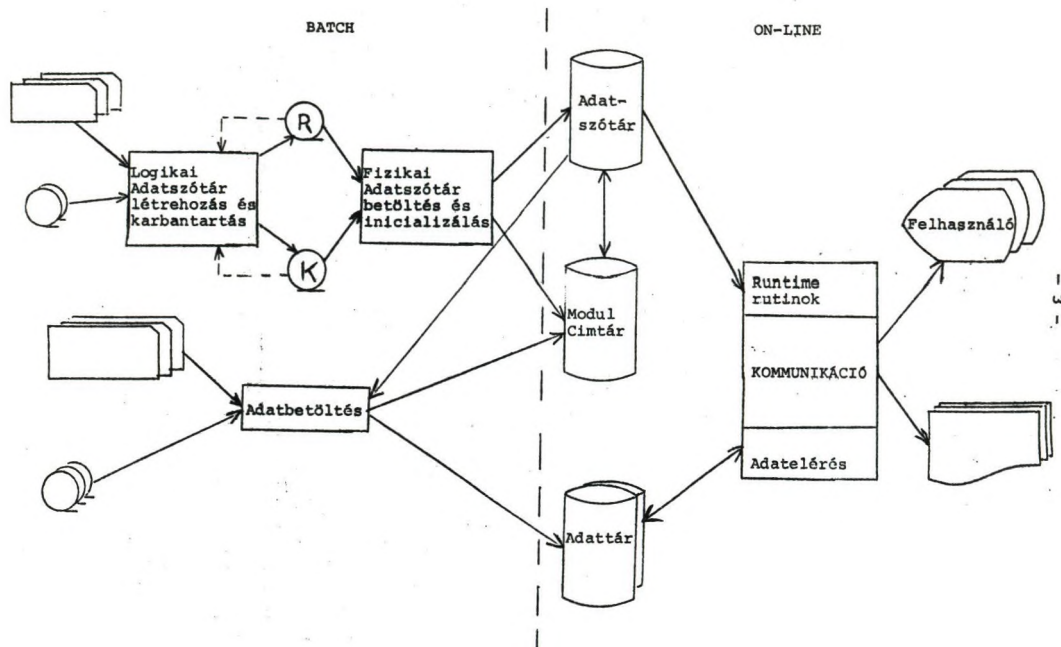
A felhasználó informálódását a SOLAR Kommunikáció külön részeként működő ún. Tájékoztató segíti elő, mely a munkavégzés bármely fázisában felhívható. A Tájékoztató Runtime rutinjai az adott rekord - adatbázis elem - szöveges leírását és a vele kapcsolatban levő többi elem típusát és azonosítóját adja meg. A rekord-információ és a kapcsolat lista egymás utáni kérésével egyszerűen

módon a teljes Adatszótár bejárható. Külön lehetőség az úgynevezett Vezérszavas keresés az egyes statisztikai mutatók "megtalálását" szolgálja, oly módon, hogy a mutatókat jellemző vezérszavak halmazán ad lehetőséget művelet végzésre.

A lekérdezés végrehajtását támogató Runtime rutinok, melyek száma 12, a Kommunikáció egyes fázisaiban szolgáltatják a végrehajtást kiszolgáló speciális információkat.

Az itt igen szűk keretekben ismertetett rendszerben elértük, hogy az Adatszótár bármely adata maximum két olvasással elérhető, és sikerült a szükséges tárolóhely minimalizálása is, amely fontos technikai feltétel volt ugyanis a jövőben cél, hogy a statisztikai adatbázisrendszer egyre nagyobb része elérhető legyen interaktív módon.

A mellékelt ábra a SOLAR egyes rendszerkomponenseit és azok kapcsolatát szemlélteti.



A SOLAR rendszer vázlata

TELEDATA rendszer - általános ismertető

1. Bevezetés

Világviszonylatban új típusú számítástechnikai eszköz és szolgáltatás hódít, mely Angliában PRESTEL, a Német Szövetségi Köztársaságban BILDSCHIRMTEXT, más európai országokban VIEWDATA néven terjedt el és vált az üzleti és gazdasági - sőt számos helyen a privát - élet mindennapi eszközévé. Magyarországon ez a rendszer és szolgáltatás TELEDATA néven kerül bevezetésre.

Milyen új lehetőségeket nyújt a TELEDATA?

A TELEDATA rendszer lehetővé teszi, hogy egyszerű TV-szerű terminálok ról nyilvános póstai telefonhálózaton keresztül u.n. menüszerű lekérdezéssel számítógépes szolgáltatások választhatók, adatbázisok információi lekérdezhetők, megjeleníthetők, esetleg módosíthatók.

Hangsúlyoznunk kell, hogy a TELEDATA a számítógépes adatbázisok kezelésének egy újszerű lehetőségét biztosítja. Az adatbázisoknak a TELEDATA rendszeren keresztüli kezelése rendkívül egyszerű, az adatok információhordozó erejét megsokszorozzák a színek és grafikus lehetőségek. Minimális számítástechnikai ismeretekkel rendelkező egyének is könnyedén elsajátíthatják használatát. A terminálok, melyekre a TELEDATA rendszer támaszkodik, Európa nagy területén csereszabatosak és természetesen jóval olcsóbbak, mint a hagyományos terminálok.

E tulajdonságok alapján számos olyan területen is lehetővé teszik a számítógépes szolgáltatások - köztük az adatbázisok - elérését, ahol a korábbi eseteken belül még nem volt mód a korszerű információs technika módszereinek alkalmazására.



A fent vázolt feladatok végrehajtását, megvalósítását támogatja az SzKI-nál kifejlesztett eszköz és programrendszer, amely SZKITA néven került bevezetésre.

## 2. Az R-15/16 alapu zártkörű TELEDATA rendszer

Intézetünkben '82-ben indult meg az R-15/16 számítógép köré kiépített zártkörű TELEDATA rendszer - SZKITA - kifejlesztése.

A rendszer kialakításakor kettős cél lebegett előttünk:

- A rendszer hardware/software komponensei kulcsrakészen legyenek telepíthetők, bármely megfelelő távadatfeldolgozási /TAF/ lehetőségekkel ellátott ESzR felhasználói környezetbe;
- A rendszer, mint szolgáltatás legyen igénybevehető az SzKI számítógépein.

### 2.1. A SZKITA hardware eszközei

Az SzKI zártkörű TELEDATA rendszere az R-15/16 számítógépen került először alkalmazásra, de más ESzR sorozatu számítógépre is egyszerűen adaptálható.


Milyen eszközök szükségesek ahhoz, hogy a SzKITA rendszer valamely felhasználói igény kielégítésére konkrét alkalmazói környezetben kiépítsük?

- . Teledata terminál
- . Teledata koncentrátor
- . telefonvonal
- . Teledata szolgáltatást nyújtó számítógép /1. ábra/.


# SZKITA

zártkörű  
TELEDATA rendszer.

TD adatbázis



TD Host (ESZR-II. számítógép)



### 2.1.1. A TELEDATA terminál

A TELEDATA terminál az alábbi elemekből áll:

- Színes televízió készülék /pl. ORION/, amelynek segítségével a felhasználó nemcsak a normál TV műsor vételére képes, hanem igénybe veheti a TELEDATA szolgáltatásokat is.
- Viewdata adapter, amely magában foglalja a TELETEXT és a TELEDATA üzemmódot biztosító kiegészítő áramköröket, tápegységet és a telefonvonalra való kapcsoláshoz szükséges beépített modemet /ORION termék/.
- Távvezérlő, mely lehetővé teszi vezérlő információk és parancsok, valamint numerikus input adatok bevitelét.
- Alfnumerikus billentyűzet, mellyel igény szerint ki lehet egészíteni a TD-terminált, s amely a teljes ABC-nek megfelelő alfnumerikus bevittelt teszi lehetővé /64 billentyűs változat, SzKI termék/.

A TD-terminál olcsó, ára kiépítéstől függően harmada, negyede egy hagyományos terminál árának.

### 2.1.2. A TELEDATA koncentrátor

A TD-koncentrátor az SzKI-nál kifejlesztett Teledata célberendezés, amely az IBM 3274-es control unit emulációjára támaszkodva szinkron adatátviteli vonalon kapcsolódik a TELEDATA feldolgozást végző számítógéphez. A számítógép és a koncentrátor közti logikai kapcsolatot az európai normákkal egyező BTX protokoll biztosítja. A protokoll kompatibilis

a nyilvános TELEDATA rendszerben a központ és a külső csatlakozó számítógépek között rögzített protokollal.

A koncentrátor egyidejűleg 16 TD-terminál kiszolgálására képes, melyek helyi kábelen, vagy kapcsolt telefonhálózaton keresztül kapcsolódnak hozzá.

Az adatátviteli sebesség a terminál felé 1200 vagy 4800 baud, a számítógép felé 75 baud.

### 3. A SZKITA programrendszer

A SZKITA rendszer célja a TD funkciók megvalósítása, alkalmazói interface képzése. A programrendszer a korábban vázalt hardware eszközökkel az operációs rendszer /pl. DOS/VS/ és az adott alkalmazói környezetben működő TAF keretrendszer /pl. SHADOW, NIP/ szolgáltatásaira épülve oldja meg a feladatot. Ennek során a klasszikus rendszer lehetőségeit a TD műveletek elvégzésének lehetőségével bővíti ki. A programrendszer felépítését a 2. ábra szemlélteti. Az ábrán feltüntetett rendszerben a TELEDATA szolgáltatás nem jelent kizárólagos szerepet, éppen ellenkezőleg, lehetővé teszi a távadatfeldolgozási alkalmazások egyidejű jelenlétét, üzemeltetését.


A TELEDATA alkalmazások kialakítását, üzembevitelét az alábbi komponensek teszik lehetővé:

- . TELEDATA vezérlőprogram, amely a menü és a képek alapján gondoskodik a felhasználói választásnak megfelelő képek megjelenítéséről, felhasználói tranzakciók indításáról, ezenkívül a felhasználói tranzakciókban igényelt TELEDATA I/O műveletek végrehajtásáról.

A TELEDATA vezérlő struktúra /menü/ a vezérlési séma /gráf/, amely alapvetően meghatározza egy alkalmazás működési mechanizmusát.

# SZKITA

programrendszer



A vezérlő gráf csomópontokból és az ezeket összekötő vezérlési utakból áll. Egy csomópontot a tetszőlegesen választott azonosító, vagy a generálásnál kapott numerikus érték egyértelműen meghatároz.

A csomópont, funkcióját tekintve:

- belépési pont jellegű /gate típus/ - szerepe az alkalmazás azonosítása, titkosítás, speciális képek /üdvözlő-, bucsu-kép/ megjelenítésének hozzárendelése;
- informatív jellegű /menü típus/ - a vezérlést kapva megjelenít egy csupán statikus /állendő/ információt tartalmazó képet; a választékban definiálja a vezérlésátadás irányát;
- aktív jellegű /tranzakció típus/ - a vezérlést kapva tranzakciót indít, az indítást megelőzően vagy a tranzakcióból egy dinamikus /változtatható/ adatmezőket tartalmazó képet küld. A tranzakció kijelölheti a vezérlésátadás irányát.

A választékban a vezérlő gráf bármely csomópontja megcímmezhető.

A vezérlő struktúra ezáltal lehet hierarchikus, vagy hálós típusú.

- A TELEDATA vezérlési struktúra - menü - kialakítását, változtatását és archiválását végző programok.
- TELEDATA képek előállítását, változtatását és archiválását végző programok.

A SZKITA programrendszer adatai három adatbázisban helyezkednek el:

- A kép file, amely a terminálon megjeleníthető képeket és az azokat leíró információkat tartalmazza.
- Menü file, amely tárolja a vezérlési struktúrát, mely a képek egymásközi és a képek és tranzakciók közti kapcsolatot írja le.

. A harmadik a felhasználói adatbank, melynek tételeit a felhasználók lekérdezhetik, tranzakciók segítségével módosíthatják.

Az alkalmazások kialakítása a SZKITA rendszerben három egymástól jól elkülönülő tevékenységből áll:

- az adott TELEDATA alkalmazás vezérlő strukturájának /u.n. menüjének/ meghatározása,
- felhasználói programok /tranzakciók/ előállítása az adott alkalmazáshoz tartozó adatok eléréséhez,
- a TELEDATA terminálon megjelenő képek összeállítása.

Ha az alkalmazás megfogalmazható oly módon, hogy egy felhasználói választástól függően csak a megfelelő informatív kép megjelenítésére van szükség, akkor a tranzakciók előállítása elmarad. Így egy adott alkalmazásra vonatkozóan a rendszerprogram/alkalmazói program arány a hagyományos technikával megvalósított rendszerrel szemben a rendszerprogram javára változik. Másképpen fogalmazva az alkalmazás kialakításához szükséges funkciók nagyobb hányada érhető el "készen",

#### 4. Professzionális személyi számítógépeken működő zártkörű TELEDATA rendszer

Az előzőekben ismertetett alapelveket betartva Intézetünkben kifejlesztették a professzionális személyi számítógépen /PSzSz/ működő zártkörű TELEDATA rendszert.

A PSzSz méreteinek megfelelően, szerényebb alkalmazások kialakítására megfelelő.

Az egyidejűleg kezelt terminálok száma: maximum 4.

A PSzSz-n alapuló alkalmazói rendszerek természetesen a protokoll betartása mellett kapcsolódhatnak a nyilvános TELEDATA rendszerhez.

## PÁRBESZÉDES PROGRAMGENERÁLÁS ADATBÁZIS LEKÉRDEZÉSRE

### 1. Bevezetés

Az adatbázis lekérdezéseknél jogos igény, hogy bármilyen adatot el lehessen érni, ez az elérés gyors legyen, ne emésszen fel felesleges erőforrásokat és esetleg a felhasználó maga kezelje az egész eljárást. A Magyarországon használatos adatbázisokhoz általában van interaktív lekérdező rendszer, de ezek a fenti igényeknek csak többé-kevésbé felelnek meg, mivel alkalmazásuk nagy erőforrást és speciálisan képzett programozókat igényel. Az előadás egy olyan rendszert mutat be, amely gépi erőforrást és jelentős programozói munkát takarít meg.

### 2. A gépi erőforrás-igény optimalizálása

Ha egy adatbázist úgy akarunk lekérdezni, hogy megfelelő paraméterezéssel bármely rekordot visszanyerhessük, akkor az azt megvalósító program meglehetősen terjedős és sok ismétlődő részt tartalmaz. Másrészt az elkészült program futtatása nem gazdaságos, mert feleslegesen sok erőforrást igényel. /Pl. akkor, ha csak a hierarchia felső részén elhelyezkedő rekordokat akarjuk visszakeresni./ Ezzel szemben célszerű olyan programozási segédeszközt kifejleszteni, amellyel egyrészt min. memóriaigényű program állítható elő - lehetőleg interaktívan -, másrészt programozási ismeretekkel nem rendelkezők is használhassák. Azaz inputként használhatók legyenek a hétköznapi nyelvből vett szövegdarabok, outputként pedig adatbázis lekérdező utasításokat, utasításcsoportokat kapjunk, amelyekből végül komplett program álljon össze.

### 3. A programozói munka megtakarítása

Ilyen programozói segédeszköz megírására többféle lehetőség kínálkozik. Elterjedt software-es gyakorlat, hogy ilyenkor speciális új rendszert hoznak létre, némi többletszolgáltatással. Viszonylag ritkán fordul elő, hogy már




meglévő software eszközökre támaszkodó megoldást keresnek.

Az előzőekben vázolt probléma megoldására is lehetett volna egy szövegkezelő rendszert kidolgozni, vagy egy preprocesszort írni. Ezzel szemben mi a makrogenerátornak mint szövegkezelőnek és preprocesszornak alkalmazása mellett döntöttünk. Makrogenerátor ugyan a legtöbb számítógépen van, de felhasználása a programozók körében nem szokásos. Ez azért is sajnálatos, mert a legegyszerűbb adatfeldolgozó programok is tartalmaznak ismétlődő részeket. Ezeknek makrokkal való kiváltása mindenképpen élőmunka megtakarításával járna.

4. Adatbázisbeli rekord visszakeresésére utasítás helyett makrohívás

Nézzük pl. az



láncot. Ha vissza akarnánk keresni az adott ország összes városát, azt a következő utasításokkal tehetnénk meg:

```
MINDEN-VÁROS.
  FIND NEXT VÁROS WITHIN OV.
  IF DB-STATUS = 0502100 DISPLAY "ORSZÁG VÉGE"
  GO TO VEGE ELSE
  IF DB-STATUS NOT = 0 DISPLAY "HIBA AZ OV LÁNCON"
  DISPLAY DB-STATUS GO TO HIBAFELDOLGOZÁS.
  GET VÁROS.
```

Ugyanez makrohívással a következő lehet:

```
NEXT/MINDEN-VÁROS,VÁROS,OV,ORSZÁG,VÉGE,HIBAFELDOLGOZÁS/
```

vagyis csak az utasítás változó részeit kell leírni. Példánkkal azt akartuk megmutatni, hogy adatbázist lekérdező programok irásakor érdemes makrokat alkalmazni, az általánosan használt makrodefiníciókat makrokönyvtárba tenni és a makrogenerátort mint preprocesszort alkalmazni.

## 5. Szöveges inputból makrohívás

A makrokönyvtárunkat más, programozási ismeretekkel, nem rendelkező felhasználó számára is elérhetővé tehetjük. Ehhez gondoskodni kell arról, hogy egy adott adatbázis- struktúra adott szintjén a felhasználótól kapott szöveges információ alapján egy FIND makrohívás generálódjon. Ez a

- kérdéskiirás
- válaszfogadás
- válasz elemzés, FIND generálás
- folytatás, a következő kérdés kiírása

lánc automatizálását igényli.

Ennek a láncnak az elemeire makrokat lehet definiálni, amely definíciók makrohívásokat, főleg dinamikusakat tartalmazhatnak.

A mellékletben példán szemléltetjük a láncot megvalósító programrészlet működését.

## 6. Virtuális rekord kialakításának lehetősége

Software-ünk felhasználási lehetőségeit tovább szélesíti az a tény, hogy saját programrészletek is beépíthetők az inter-aktiv módon generált jobba az alábbi helyeken:

I-O SECTION-ben

DATA DIVISION-ben

file-ok megnyitásánál

az adatbázisstruktúra bármely szintjén

az adatbázis rekord visszakereső utasítások után

a file-ok lezárásánál

az EXECUTE aktivitás file hozzárendelésénél.

Lényeges szempont, hogy ezeken a helyeken elég megadni egy file leírást. /A Honeywell gépen ~~§§~~ SELECT-tel./ Gondoljunk arra, hogy milyen fontos ez. pl: DATA DIVISION-ben, ahol a virtuális rekordot definiáljuk, vagy az egész software inter-aktivitásának megítélésénél.

A saját programrészlet beépítésének a lehetősége biztosítja azt is, hogy a visszanyert adatokon műveletek végezhetők, egyéb input file-ok is feldolgozhatók, az output pedig tetszőleges adathordozóra irányítható. Itt hívjuk fel a figyelmet arra, hogy a felhasználó a generált programot for- rásnyelven saját területén tárolhatja, a későbbiekben pedig tetszés szerint tovább is fejlesztheti.

## 7. A módszer alkalmazhatósága

A módszer tetszőleges adatbázis lekérdező nyelvre, tetsző- leges makrogenerátorral megvalósítható. A megvalósítás

mellett szól az is, hogy a software vásárlásoknál gyakran nem jut keret a lekérdezőrendszer megvásárlására, S ha van is ilyen lekérdező rendszer, azt még az adatbázissal dolgozó programozók közül is csak kevesen használják, mivel saját ismereteket feltételez.

Az adatbázis lekérdező rendszert Honeywell 66-os gépen IDS II adatbázisra készítettük el IMP-66 makrogenerátor alkalmazásával. Az IDS II a CODASYL koncepció alapján készült, ezért módszerünk könnyen adaptálható más, szintén ezen koncepció alapján készült adatbázisokra /pl: IDMS/. Az a dán B.Svejgaard és P. Lindblad által GIER gépre készített IMP-IV /Interpretative Macro Processor/ meglehetősen pontos adaptációja. Ezt az adaptációt Zsombok Zoltán készítette.

A makrogenerátor adatbázisokon kívül egyéb programozási segédeszközök kidolgozásában is hasznosnak bizonyult.

Többek között felhasználói rendszerek üzemeltetésére olyan job-indító rendszert dolgoztunk ki, amelyet szöveges információ adásával a felhasználó maga kezelhet. Tapasztalataink szerint egyre több felhasználó igényli ezt az átfutási időt lényegesen csökkentő szolgáltatást. Makrogenerátor bármely programnyelvre preprocessorként alkalmazható. /Lásd [2] -ben FORTRAN preprocessor, mely ALGOL típusu utasítások használatát teszi lehetővé/.

#### Irodalom

- [1] Peter Lindblad: IMP-IV Kobenhavns Universitets Matematiske Institut Afd. for Inform. KUAIB 23.
- [2] Zsombok Zoltán: IMP-66 1982.

Melléklet

IDS II adatbázisra IMP-66 makrogenerátorral kialakított programozási segédeszközből a dialógust megvalósító részlet:

```

DIALOG(CASE,99,,,,
(CMP,97,
(CALL,ASK,"A FOLYTATÁS TÍP (TALAJMINTA) VAGY IA (TALAJATLAG)
VAGY TAK (ALLUKULTURA) VAGY TE (TECHNOLÓGIA) LESZ ?")
,TR,TA,TAK,IE)
(AID,99,(CASE,97,256,30,31,32,33),99),,,,
(CMP,97,
(CALL,ASK,
"A FOLYTATÁS TÍP (TALAJMINTA) VAGY "
"TR (TRAGYAZÁS) VAGY "
"NY (NOVENYVÉDELME) VAGY "
"GYR (GYEP RÉTAKARÍTÁS) LESZ ?"),
TR,TR,TR,TR,TR,TR,TR,TR)
(AID,99,(CASE,97,,30,31,32,33),99))
(CMP,23,
(CALL,ASK,"A KIVÁRT "
(CASE,99,,
MEGYE,
GAZDASÁG,
TÁBLA,
TALAJLELT,
TALAJATLAG,
ALLUKULTURA,
"TECHNOLÓGIA ALAP",
TALAJMINTA,
TRAGYAZÁS,
NOVENYVÉDELME,
"GYEP RÉTAKARÍTÁS")
"REKORD? (VÁLASZ: OSSZES VAGY BTZONYOS)",
OSSZES,BTZONYOS)
(CASE,25,,
(CALL,TEXT,MINDEFR(CASE,99,,13,15,17,18,14,16,32,33,34,35),
P(CASE,99,,13,15,17,18,14,16,32,33,34,35),
(CASE,99,,MG,GT,TR,TA,IA,TR,RR,RR,RR),
(CASE,99,,MEGYE,GAZDASÁG,
TÁBLA,TÁBLA,TÁBLA,TÁBLA,
TECHNOLÓGIA,TECHNOLÓGIA,TECHNOLÓGIA,TECHNOLÓGIA),
(CASE,99,,VEGF,
BTZONR13,BTZONR15,BTZONR15,BTZONR15,BTZONR15,
BTZONR16,BTZONR16,BTZONR16,BTZONR16),
VEGF),
(CALL,ANY,BTZONYOSR(CASE,99,,12,13),
P(CASE,99,,12,13),
(CASE,99,,MEGYE,GAZDASÁG),VEGF))
(CALL,INCL,"SAJÁT PROGRAMRÉSZELET AZ ELLP) SZINTEN")
(CMP,99,(CALL,ASK,KITRATJA?),IGEN)
(CASE,99,,
(CALL,BTSP,(CASE,99,,12,13,15,17,18,14,16,32,33,34,35)))

```

Iványi Antal, Luderer Bernd, Szotnyikov A. N.  
ELTE, Karl-Marx-Stadt Műszaki Főiskola, Moszkvai  
Állami Egyetem

Deszkriptoros információvisszakereső rendszerek paramé-  
tereinek optimális megválasztásáról

Az információvisszakereső rendszerek nagy részében /pé-  
ldül bizonyos könyvtári rendszerekben/ a tárolt dokumentu-  
mok tartalmát deszkriptorok segítségével jellemzik. Az elő-  
adásban ismertetünk egy egyszintes és két kétszintes desz-  
kriptoros rendszert, majd a hasonló rendszerek Saltontól  
[1] származó matematikai modelljét. Ezután a kétszintes  
rendszer paramétereinek megválasztására javasolt algoritmu-  
sokat mutatunk be, majd ezen algoritmusok hatékonyságát e-  
lemezzük szélsőséges esetekben, végül az egyik közelítő al-  
goritmust hasonlítjuk össze az optimálissal átlagos esetben.

1. §. Konkrét rendszerek

Az INF nevű könyvtári információvisszakereső rendszer  
a Magyar Állami Földtani Intézet megbízásából készült 1971-  
72-ben az ELTE-n. Feladata a MAFI könyvtárában lévő doku-  
mentumok /könyvek, folyóiratcikkek, jelentések stb./ tartal-  
om szerinti nyilvántartása, indexek készítése és adott tar-  
talmu dokumentumok visszakeresése volt.

A dokumentumok tartalmát egy körülbelül 1000 deszkriptort  
tartalmazó tezausz segítségével jellemeztük. A deszkripto-  
rok közül mintegy 70 hierarchikusan kapcsolatban álló föld-  
rajzi deszkriptor volt. A rendszer 10 programból állt, melyek  
néhány jellemző adatát az 1. táblázat tartalmazza

Program neve,	nyelve,	memóriaigénye	szóban,	teljesítménye
INF1	PLAN	390		5 db/perc
INF2	FORTRAN	13600		
INF3	"	8100		
INF4	"	23450		52 db/perc
INF5	"	23250		20 db/perc
INF6	"	8370		
INF7	"	8640		
INF8	"	3840		
INF9	"	13820		
INF10	"	14230		

1. táblázat. Az INF rendszer programjainak néhány adata

Az INF2 az új dokumentumok leírásának szintaktikus el-  
lenőrzését és a hibátlan leírásoknak az állományhoz csatolá-  
sát végezte. Az INF3 az állomány adott részére vonatkozó  
szerzői, témaszerinti és földrajzi indexeket készítette. Az  
INF5 KWIC-indexeket generált. Az INF6 segítségével a deszkrip-  
torok logikai kifejezésével /AND, OR és NO műveletek megenge-  
dettek/ jellemezhető dokumentumok visszakeresésére volt lehe-  
tőség. Az INF7 a dokumentumok angol címe alapján automatikus  
tárgyszavazást végzett. Az INF9 a tezausz karbantartását,  
fejlesztését biztosította. A többi program listázást és más  
segédfunkciókat látott el.

Az INF a visszakeresést a szekvenciális állományban lineá-  
risan végezte [2].

A következő két rendszerben a dokumentumokat hasonló doku-  
mentumokból álló zónákra osztják, és minden zónához meghatá-  
rozják az odatartozó dokumentumok tartalmát jellemző karakter-  
isztikus vektort, és az igényvektornak a karakterisztikus

vektorokkal való összehasonlítása után csak a releváns zónákban való lineáris keresésre van szükség.

A RASZT nevű rendszer egy moszkvai kutatóintézet részére készült 1981-82-ben. Növényekkel kapcsolatos megfigyelési adatok kezelését végzi. A rendszer kb. 90000 megfigyelés adatait tartalmazza, melyek kb. 300 zónára oszlanak. A visszakeresési igények kb. 100 számot tartalmazó vektorok. Ezekben a vektorokban az AND, OR és NO logikai operátorok használhatók.

A BOL nevű rendszer egy moszkvai klinika részére készült a Moszkvai Allami Egyetemen, 1982-83-ban, és betegek öt éves megfigyelésére vonatkozó adatokat tartalmaz. A rendszer célja, hogy a betegség fejlődésének, a különböző gyógyítási módszerek hatásának elemzését elősegítse.

A BOL 10000 megfigyeléssorozat eredményeit kezeli, melyek 100 azonos méretű, a visszakeresési igények figyelembe vételével kialakított zónában helyezkednek el.

## 2. §. Matematikai modell (igények $Q = \{q_0, \dots, q_{z-1}\}$ )

Adott dokumentumok  $T = \{t_0, \dots, t_{n-1}\}$ , /deszkriptorok  $D = \{d_0, \dots, d_{m-1}\}$  halmaza, ahol  $Q = 2^D$ . Továbbá, adott a dokumentumok leírásának mátrixa  $[t_{ij}]_{n \times m}$ , ahol  $t_{ij} = 1$ , ha a  $d_j$  deszkriptor jellemzi a  $t_i$  dokumentum tartalmát, és  $t_{ij} = 0$ , ha nem /  $i = \overline{0, n-1}$ ,  $j = \overline{0, m-1}$  /.

Tegyük fel, hogy  $T$  a  $T_0, \dots, T_{z-1}$  /  $z \leq n$  / zónákra van bontva, ahol  $\bigcup_{k=0}^{z-1} T_k = T$  és  $T_{k_1} \cap T_{k_2} = \emptyset$  /  $0 \leq k_1 < k_2 \leq z-1$  / . Ilyen felbontás megadható például az  $X = [x_{ik}]_{n \times z}$  tartalmazási mátrix segítségével, ahol  $x_{ik} = 1$ , ha  $t_i \in T_k$  és  $x_{ik} = 0$ , ha  $t_i \notin T_k$  /  $i = \overline{0, n-1}$ ,  $k = \overline{0, z-1}$  /.

Adott  $X$  felbontás  $[u_{kj}]_{z \times m}$  karakterisztikus mátrixát / amely a karakterisztikus vektorokat mint sorvektorokat tartalmazza / így definiáljuk:  $u_{kj} = 0$ , ha egyetlen  $t_i \in T_k$  dokumentum leírásában sem szerepel  $d_j$ , és  $u_{kj} = 1$ , ha  $T_k$ -ban legalább egy elem leírása tartalmazza  $d_j$ -t. Ekkor

$$u_{kj} = \max_{0 \leq i \leq n-1} t_{ij} x_{ik} \quad / j = \overline{0, m-1}, k = \overline{0, z-1} /.$$

A visszakeresés úgy történik, hogy a  $q_l$  igényt összehasonlítjuk minden zóna karakterisztikus vektorával, majd a releváns zónákban / ahol minden igénybeli deszkriptor megtalálható / lineáris keresést végzünk.

A paraméterek / zónák száma és mérete, dokumentumok szétosztása a zónák között / megválasztásának hatékonyságát az visszakeresési idővel jellemezzük, melyet a következőképpen definiálunk. A  $q_l \in Q$  igényhez tartozó keresési időt  $X$  tartalmazási mátrix esetén  $C_{lX}$  -szel jelöljük, és

$$C_{lX} = z + \sum_{k=0}^{z-1} g_k L_{kl} + a \sum_{k=0}^{z-1} L_{kl}$$

ahol  $a$  egy új zónában való visszakeresés előkészítésének / memóriába töltésének / ideje,  $g_k$  a  $k$ -ik zóna mérete, azaz  $g_k = \sum_{i=0}^{n-1} x_{ik}$ ,  $L_{kl}$  pedig logikai változó, melynek értéke "igen"

/1/, ha  $\bar{u}_k > \bar{q}_k$ , és "nem" /0/ ellenkező esetben, azaz

$$L_{kl} = \begin{cases} 1, & \text{ha } u_{ki} > q_{li} \quad / j=0, m-1 / \\ 0, & \text{ha van olyan } / 0 \leq j \leq m-1 / , \text{ melyre } u_{kj} < q_{lj} \end{cases}$$

Legyen most  $Q$  valószínűségi tér  $A$   $\sigma$ -algebrával és  $P/A/$  valószínűségi mértékkel. A  $C_{EX}$  keresési idő várható értékét  $M_X$ -szel jelöljük. Ekkor

$$M_X = \sum_{k=0}^{r-1} P(q_k) C_{EX}$$

Ennek az  $M_X$  mennyiségnek, mint hatékonysági mértéknek az alapján fogjuk a paraméterek megválasztására javasolt különböző algoritmusokat összehasonlítani.

Ha a zónák számára és méretére vonatkozó  $Z_{min}$ ,  $Z_{max}$ ,  $q_{min}$ ,  $q_{max}$  korlátok adottak, feltesszük, hogy  $0 \leq q_{min} \leq q_{max}$  és  $1 \leq Z_{min} \leq Z_{max}$ . Ha ilyen korlátok nincsenek, akkor a  $q_{min} = 0$ ,  $Z_{min} = 1$ ,  $q_{max} = Z_{max} = n$  értékeket alkalmazzuk. Ekkor a paraméterek optimális megválasztása a következő egészértékű programozási feladatra vezet.

Adott  $n, m, Z_{min}, Z_{max}, q_{min}, q_{max}$  számok,  $[t_{ij}]_{n \times m}$  mátrix és  $P/q/$  eloszlásfüggvény esetén határozzuk meg azt az  $X^* = [x_{ik}]_{n \times z}$  mátrixot, amelyre

$$\begin{aligned} x_{ik} &\in \{0, 1\} \quad / i=0, n-1, \quad k=0, z-1 / , \\ \sum_{k=0}^{z-1} x_{ik} &= 1 \quad / i=0, n-1 / \\ q_{min} &= q_k \leq q_{max} \quad / k=0, z-1 / \\ M_X^* &\leq M_X \quad / \text{minden lehetséges } X \text{-re} / . \end{aligned}$$

Megjegyezzük, hogy ez a feladat egy [3]-ban kitűzött feladat továbbfejlesztett változata /ott  $Z$  rögzített, és az  $X$ -ben levő egyesek számát kell minimalizálni/.

### 3. §. A paraméterek meghatározására szolgáló algoritmusok

Az irodalomban a következő algoritmusokat találtuk.

Salton bebizonyította, hogy ha a dokumentumhalmaz rendezett, minden lehetséges dokumentumleírásnak pontosan egy dokumentum felel meg és az igénnyel azonos leírásu /elegenden/ dokumentumot keressük, akkor  $M_X$  minimalizálásának feltétele  $Z = q_k = \sqrt{n/k} = 0, z-1 /$ . Ezen az eredményen alapul  $A_{SZIM}$

Szimmetrikus algoritmus  $A_{SZIM}$  [4]

$$Z \approx q_0 \approx \dots \approx q_{z-1} \approx \sqrt{n}$$

A következő algoritmus adott  $q_{max}$  esetén a zónák számát a lehető legkisebbre választja /a zónaméret így maximális/.

Maximális algoritmus  $A_{MAX}$  [3]

$$Z = \lceil n / q_{max} \rceil$$

A [3]-beli optimalizálási feladattal kapcsolatos  $A_{MIN}$ .  
Minimális algoritmus  $A_{MIN}$  [3]. Adott  $Z$  és  $q_{max}$  esetén úgy osztja szét a zónák között a dokumentumokat, hogy az  $X$ -ben lévő egyesek száma minimális legyen.

Optimális algoritmus  $A_{OPT}$  [5]. Az előző rész végén leirt optimalizálási feladat megoldását szolgáltató algoritmus.

Kvázioptimális algoritmus  $A_{KV}$  [5]. A zónák számát úgy határozza meg, mint  $A_{OPT}$ , majd a zónák között az  $X$ -beli egyesek számát minimalizálva osztja szét a dokumentumokat.

Rendező algoritmus  $A_{REND}$  [5]. A zónák számát és méretét a  $Z = \lceil \sqrt{n} \rceil$ ,  $q_k = \lceil n/z \rceil / k = 0, z-2 /$ ,  $q_{z-1} = n - (z-1) \lceil n/z \rceil$  formulák alapján határozza meg, majd rendezi a dokumentumokat a leírások, azaz a  $t_{i0}, \dots, t_{i, m-1}$  vektorok alapján, és  $T_0$ -ba az első  $q_0$ ,  $T_1$ -be a soron következő  $q_1$  dokumentumot teszi, és így tovább.

#### 4. §. Az algoritmusok hatékonysága szélsőséges esetekben

Tegyük fel, hogy adott  $m$ ,  $n$ ,  $q_{max}$ ,  $P(q)$  és  $[t_{ij}]_{n \times m}$  esetén  $X_{MIN}$ -nel jelöljük azt a tartalmazási mátrixot, amelyet  $A_{MAX}$  és  $A_{MIN}$  segítségével, és  $X_{KV}$ -vel azt, amelyet  $A_{KV}$  segítségével kaptunk. Továbbá tegyük fel, hogy  $X_{SZIM}$ -hez úgy jutottunk, hogy a zónák számát  $A_{OPT}$ , a zónák méretét  $A_{SZIM}$ , majd a dokumentumok zónákra osztását  $A_{MIN}$  segítségével végeztük. Ekkor érvényesek a következő állítások.

1. TÉTEL [5]. Minden valós  $B$ -hez megadhatók olyan  $m$ ,  $n$ ,  $P/q$ ,  $q_{max}$  és  $[t_{ij}]_{m \times n}$  paraméterek, hogy teljesüljön

$$M(X_{MIN})/M(X^*) > B. \quad \square$$

2. TÉTEL [5]. Minden valós  $E$ -hez megadhatók olyan  $m$ ,  $n$ ,  $P/q$ ,  $q_{max}$  és  $[t_{ij}]_{m \times n}$  paraméterek, hogy teljesüljön

$$M(X_{MIN})/M(X^*) > E. \quad \square$$

3. TÉTEL 5. Minden valós  $F$ -hez megadhatók olyan  $m$ ,  $n$ ,  $P/q$ ,  $q_{max}$  és  $[t_{ij}]_{m \times n}$  paraméterek, hogy teljesüljön

$$M(X_{MIN})/M(X^*) > F. \quad \square$$

Tegyük fel, hogy rendszerünk paraméterei a következő tulajdonságokkal rendelkeznek.  $\tau \geq 1$  egész szám,  $m = 2^{\tau}$ ,  $n = 2^m$ ,  $\tau = 2^m$ ,  $q_{max} = 2^{\tau}$  és

$$i = \sum_{j=0}^{m-1} t_{ij} 2^j, \quad l = \sum_{j=0}^{m-1} q_{lj} 2^j \quad / i = 0, n-1, \quad l = 0, \tau-1 /,$$

azaz a dokumentumleírások és igények mint kettes számrendszerbeli számok megadják a megfelelő leírás ill. igény indexét.



Ekkor a zónák száma illetve mérete a különböző közelítő algoritmusok szerint azonos:

$$Z(A_{SZIM}) = Z(A_{MAX}) = Z(A_{REND}) = \sqrt{n} = 2^y,$$

$$g_k(A_{SZIM}) = g_k(A_{REND}) = n/z = 2^y \quad (k = 0, z-1).$$

Ezek a számszerű adatok azt mutatják, hogy bizonyos körülmények között az említett közelítő algoritmusok azonos paraméterértékeket adnak.

#### 5. §. A rendező algoritmus vizsgálata átlagos esetben

Tegyük fel, hogy a deszkriptorok száma  $m$ ,  $n=2^m$ ,  $r=2^y$ ,  $y$  adott egész szám  $0 \leq y \leq m$ ,  $Z=2^{m-y}$ ,  $g_k = 2^y / k = 0, z-1$ . Továbbá az igények egyenletes eloszlásuak, azaz  $P(g_k) = 1/2^m / z = 0, r-1$ , és a dokumentumleírások, igények mint kettes számrendszerbeli számok megadják a megfelelő leírás ill. igény indexét.

Ilyen feltételek mellett érvényes a következő állítás.

**4. TÉTEL [6]**. Ha az  $X_{REND}$  tartalmazási mátrixot az  $A_{REND}$  rendező algoritmus állította elő, akkor

$$M/X_{REND} / = (1/2)^y 2^m + (4/3)^y (3/2)^m + \alpha (2/3)^y (3/2)^m \quad \square$$

Említést érdemelnek a tétel következő következményei.

**1. Következmény.** Ha a 4. tétel feltételei mellett  $\alpha=0$ , akkor  $y$  optimális értéke  $y_{opt} \approx C_1 m + C_2$ , ahol  $C_1 = \frac{\log 4/3}{\log 3/2} \approx 0,3$  és  $C_2 = \{\log[(\log 2)/(\log 4/3)] / \log 3/2\}$ , ahonnan  $Z_{opt} \approx 0,5 n^{0,7}$  és  $(g_k)_{opt} \approx 2 \cdot n^{0,3} \quad (k = 0, z-1)$ .  $\square$

**2. Következmény.** Ha a 4. tétel feltételei mellett  $m=2^y$ ,  $y=\lambda$ , akkor legyen  $X_{SQRT}$  a  $Z=\sqrt{n} = 2^{\lambda}$  zónaszámhoz tartozó tartalmazási mátrix. Ekkor

$$M/X_{SQRT} / = 2^y + 3^y + \alpha (3/2)^y \quad \text{és} \quad \lim_{y \rightarrow \infty} M(X^*) / M(X_{SQRT}) = 0. \quad \square$$

Az  $A_{REN}$  által előállított  $X_{REN}$ -re vonatkoznak a következő állítások is.

**5. TÉTEL [7]**. Ha a zónák száma  $Z=2^w$  alakban rögzített, és  $w \leq 2$ , akkor  $M(X_{REND}) = M(X^*)$ .  $\square$

**6. TÉTEL [7]**. Ha a zónák száma  $Z=2^w$  alakban rögzített, és  $w \geq C_1 m$ , akkor  $M/X_{REND} / \leq C_2 M/X^* /$ , ahol  $C_2$  az 1. következményben szereplő állandó.  $\square$

#### 6. §. Összefoglalás

A kétszintes zónás deszkriptoros információviszakereső rendszerek Saltontól származó matematikai modellje alapján vizsgáltuk a paraméterek meghatározására szolgáló algoritmusokat.

Mivel az optimalizálási feladat nagyon műveletigényes egészértékű programozási feladatra vezet, vizsgáltuk a különböző közelítő algoritmusoknak az átlagos válaszidőre gyakorolt hatását.

Megállapítottuk, hogy bizonyos ideális feltételek mellett a közelítő algoritmusok azonos eredményre vezetnek, míg szélsőségesen kedvezőtlen esetben a közelítő algoritmusok az optimálisnál sokkal rosszabb eredményt adnak.

Az utolsó két tétel azt mutatja, hogy bizonyos feltételek mellett a rendező algoritmus optimális, vagy ahhoz közeli visszakeresési időt eredményez.

Az elméleti vizsgálatokat gyakorlati tapasztalatok is alátámasztják. Korábban széles körben elterjedt az  $\approx\sqrt{n}$  zónaszám alkalmazása. A RASZT és a BOL rendszereken végzett kísérletek azt mutatták, hogy az 1. következménynek megfelelő  $z \approx \sqrt{0,5n}$  zónaszám alkalmazásával körülbelül egy nagyságrenddel csökkent az átlagos visszakeresési idő.

### Irodalomjegyzék

- 1 Салтон Г., Автоматическая обработка, хранение и поиск информации. Москва, Советское радио, 1973.
- 2 Iványi A., Nyirádi L., Library information retrieval systems INF and FARMDOC, In: Conference on systems for information servicing of professionally linked computer users /Varna, May 23-29, 1977/, Bulgarian Academy of Science, p. 307-313.
- 3 Белобродский А. В., Решетников В. Н., Об одном способе поиска релевантных векторов, В кн.: Вопросы оптимизации и управления, Москва, Изд. МГУ, 1979, с. 59-63.
- 5 Ивани А. М., Сотников А. Н., Оценка эффективности некоторых поисковых алгоритмов в АИПС, Программирование, 1983 /в печати/.
- 4 Решетников В. Н., Сотников А. Н., Алгебраические свойства  $\mathcal{L}$ -структуры и псевдорелевантные векторы., Вестник Московского Университета, Сер. Вычисл. мат. и кибернетики, 1982, No. 1, с. 70-75.
- 6 Ивани А. М., Сотников А. Н., Об оптимизации дескрипторных зонно-иерархических информационно-поисковых систем, Вестник Московского Университета, Сер. Вычисл. мат. и кибернетики, 1983 /в печати/.
- 7 Ивани А. М., Лудерер Б., Об одной задаче целочисленного программирования, связанной с информационным поиском, Изв. АН СССР, Серия Техническая кибернетика, 1983 /в печати/.

Adatbázisadminisztráció a statisztikai  
információrendszerben

A statisztikai szervezetek fő feladata a begyűjtött adatok feldolgozása és információk szolgáltatása a lehető leg rövidebb idő alatt.

A hetvenes évek elején alakult ki Hivatalunkban az a nézet, hogy a váratlan - ad hoc - információ igények kielégítésére a legjobb eszköz az adatbáziskezelő rendszer alkalmazása.

A statisztikai információ rendszerre a statisztikai mutatók és azok előfordulásának igen nagy száma, valamint a lehetséges kapcsolatok sokfélesége jellemző. Az információ igények állandóan változnak, szinte minden mindennel kapcsolatban lehet. Az adatbázis kezelésére az INFORMATICS cég által forgalmazott MARK IV rendszer alkalmazása látszott célszerűnek, mivel a MARK IV az adatstrukturák rugalmas kezelését teszi lehetővé.

1. Az adatbázisadminisztráció kialakulása

A hetvenes évek elején az adatbázis fejlesztése, karbantartása és az adatbázisból való lekérdezés egyetlen, körülbelül 15 fős szervezet keretén belül történt. Az igények növekedése mind az adatbázisban tárolt témák számának, mind az ad hoc lekérdezések számának növekedésében jelentkezett; a régi szervezet nem volt alkalmas a feladatok ellátására.

Hivatalunkban az adatbázis környezetében működő szervek a szakirodalomban leirtaktól némileg eltérően alakultak ki. Egy-egy statisztikai adatgyűjtés adatbázisba vitele 1-2 emberévnyi előkészítő tevékenységet igényel a témáért felelős statisztikai főosztály /továbbiakban adatbázisgazda/ munkatársainak bevonásával. A gyakorlatban hasznosnak bizonyult ezt a fázist az adatbázisadminisztrációtól elválasztani, oly módon, hogy az ujonnan bekerülő témák adatbázisba szervezését az Adatbázisfejlesztési osztály végzi.

Miután tisztázódott az adatbázis tartalma és a bekerülő adatok rendelkezésre állnak, az Adatbázisfejlesztési osztály elkészíti a Rendszertervet. A Rendszerterv tartalmazza az input adatok leírását, az adatbázis tartalmát, és tervezett fizikai szerkezetét. A kész Rendszertervet az Adatbázisadminisztráció megkapja véleményezésre. Az Adatbázisadminisztráció változtatási javaslatai általában az adatbázis fizikai szerkezetét érintik, hiszen az ezzel kapcsolatos tapasztalatok itt csapódnak le.

Általános igény, hogy az adatbázisba régebbi időszakok adatai is bekerüljenek. Ezekkel az adatokkal gyakran jelentkeznek kon-

zisztencia problémák. Előfordulhat az is, hogy az adatbázis gazda a betöltés után megváltoztatja igényeit - az ezt követő módosításokat szintén az Adatbázisfejlesztés hajtja végre. Az első betöltéstől számított 1/2-1 évig az adatbázis kisérleti üzemmódban működik az Adatbázisfejlesztési osztály felügyelete alatt. Ezen időszakban az adatbázist csak az adatbázis gazda használhatja. Ekkor készül el az információrendszer érintett részének tartalmi leírása, vagyis a témára vonatkozó meta-adatbázis-rész.

Az Adatbázisadminisztráció a kezdeti problémák kiderülése és kiküszöbölése után veszi át az adatbázist rendeltetésszerű használatra.

Az adatbázis jelenleg csak batch üzemmódban érhető el, s a statisztikusok nem látnak el számítástechnikai feladatokat - így az adatbázisra vonatkozó ad hoc információ igények ki-elégítését az Adatbázis-lekérdezési osztály végzi.

A jelenlegi szervezetben tehát Számítógéppontunkban az ugynevezett adatbázissszolgálat három osztályból áll:

- Adatbázisfejlesztés,
- Adatbázisadminisztráció,
- Adatbázis-lekérdezés.

## 2. A Statisztikai Adatbázis Rendszer /STAR/ felépítése

A STAR két részből áll, a tárgy-adatbázisból és a meta-adatbázisból. A tárgy-adatbázis a tárgy-információ rendszerről tartalmaz adatokat, a meta-adatbázis pedig a meta-információ rendszerről.

### 21. A tárgy-adatbázis

Adatbázis rendszerünk 10 év óta működik, néhány témában 13 éves idősoraink vannak. Az adatbázis főleg a gazdaságstatisztika területéről tartalmaz adatokat, a társadalomstatisztikai adatok hányada alacsony.

Az adatokat két szinten - elemi /mikro/ és  
- aggregált /makro/  
szinten tároljuk. Az aggregálás célja a gyorsabb lekérdezési lehetőségek biztosítása.

Az adatbázis utolsó 6 évének adatai mágneslemezen a régebbi évek adatai a mágnesszalagos archivumban található meg. /A mágneslemezen levő adatok mintegy 600Mbyte területet foglalnak el./ Az éves adatgyűjtések idősorainak hossza korlátlan. Az évközikeket 3 évig tároljuk. A STAR-ban kb. 2400 statisztikai mutató van adatszolgáltatónként. Az adatszolgáltatók száma 1600-tól 8500-ig terjed. Az egyes mutatók előfordulása egy adatszolgáltatónál 1-től 5-600 lehet, mindezt még a témában rendelkezésre álló idő-sor hosszával is meg kell szorozni, hogy a STAR-ban található mutató előfordulások számáról képet kapjunk.

Az adatbázisok betöltése, karbantartása és lekérdezése a MARK IV segítségével történik. A MARK IV segítségével a többnyire hierarchikus adatstruktúrák kezelése igen rugalmasan oldható meg - a file-ok /adatbázis témák vagy azok részei/ automatikus koordinálásával - a lekérdezések során.

A STAR-ban nincsenek pointerek, mivel a felhasználó minden elképzelhető aspektusban kérhet adatokat - minden lehetséges kapcsolatot pedig szinte lehetetlen, jobban mondva túl költséges lenne ábrázolni.

A file-ok koordinálása, azaz a kapcsolatok lekérdező futás során történő létrehozása a minden adatbázis file-ban megtalálható adatbázis-kulcs segítségével történik.

## 22. A meta-adatbázis

A statisztikai információ rendszerben mind az információ források mind az információ felhasználók száma igen nagy. A felhasználók nem minden esetben az információ gazdái - így az "információra vonatkozó információ", vagyis a meta-információ nélkülözhetetlen.

Esetünkben a tárgy-információ rendszert leíró adatok, vagyis a meta-adatok

- egységes rendszert alkotnak,
- számítógéppel kezeltek,
- naprakészek,
- a felhasználó számára elérhetők, vagyis meta-adatbázist képeznek.

A meta-adatbázis háromféle leírást tartalmaz:

- az információk szöveges leírása statisztikus felhasználók számára,
- adatszótár a software és a programozók számára,
- fizikai file-ok leírása a programozók számára.

## 221. A felhasználókat három szöveges leírás,

- a Tájékoztató Katalógus,
- a Mutató Katalógus és
- a Nomenklatura Katalógus segíti az információkérésben.

A Tájékoztató Katalógus KWOC<sup>\*k</sup> indexes, minden vezérszóhoz hozzá van rendelve az összes érintett mutató és nomenklatura.

A Mutató Katalógus idősor szemléletű, a mutató azonosítójával együtt megadja az adatbázisban tárolt mutatók szöveges leírását, az idősor kezdetét /és végét, ha lezárult/, a mutató mértékegységét, vonatkozási idejét, periodicitását, valamint azon nomenklaturák azonosítóit, amelyek szerint a mutatót megfigyelik /pl. a létszámot gazdálkodó

\*KEY WORD ON CONTEXT

szervezetenként a foglalkoztatottak korcsoportjai szerint./

A Nómenklatura Katalógus a Mutatókatalógusban hivatkozott nómenklaturák elemeinek szöveges felsorolását, valamint a nómenklaturák összefüggéseit tartalmazza.

A katalógusok alapján a statisztikus felhasználó kiválaszthatja az együtt feldolgozható mutatókat és ezekből az ugynevezett STAR Adatkérő Lapon tetszésszerűen táblákat kérhet az Adatbázislekérdezési osztálytól.

222. Az adatszótár a mutatókat és a kapcsolatokat tartalmazó file-ok leírását, valamint a nómenklaturák szövegeit és a karbantartáshoz szükséges tranzakciók definícióit tartalmazza. Az adatszótár hidat képez a statisztikusoktól a programozókon keresztül az adatbázishoz egy igen szigorú névkonvenció segítségével. /A katalógusban szereplő mutató vagy nómenklatura azonosító megegyezik az adatszótárbeli adatnévvel, és ebből egy egyszerű algoritmussal képezhető a mutatót tartalmazó fizikai file azonosítója is./
223. A fizikai file-ok leírását a Fizikai File-ok Katalógusa tartalmazza. Ez a következőkből áll:
- file azonosítója,
  - egység típusa,
  - egység sorszáma,
  - adatszervezés,
  - elfoglalt lemezterület,
  - rekord forma,
  - rekord hossz,
  - blokkméret,
  - archiválás megtörtént-e,
  - a biztonsági másolatok szalagszáma,
  - jelszóval védett-e.

### 3. Az adatbázisadminisztrátor feladatai

Az adatbázisadminisztrátor /jelenleg 6 fő/ alapvető feladata a tárgy-, és a meta-adatbázis karbantartása.

#### 31. A tárgy-adatbázis karbantartása

A tárgy-adatbázis karbantartása főként az adatbázis új időszak adataival való kiegészítését jelenti. Ennek előkészületei már jóval az adatbázis betöltése előtt megkezdődnek, amikor az adatbázisgazda bejelenti az adatgyűjtésben történt változásokat. A változás jelenthet új mutatókat, megszünt mutatókat, vagy előfordulhat, hogy egy mutató tartalmi szempontból nem hasonlítható össze az előző évi mutatóval. Ezekben az esetekben az adatbázisadminisztrátor a régi mutatót lezárja, az ujnak pedig új mutató-azonosítót ad.

Ezután az alábbiakat kell megváltoztatni:

- az adatbázis-rész felépítése /esetleges/,
- a file definíciók,
- a tranzakció definíciók,
- betöltő programok,

- szöveg file-ok /esetleges/,
- Mutató Katalógus,
- Nómenklatura Katalógus.

/A Tájékoztató Katalógus ritkábban kerül karbantartásra./

Az adatbázisba ellenőrzött, javított adatok kerülnek, ezért utólagos adatjavításra ritkán van szükség. Gyakori problémát okoz viszont az egyes adatbázis témák között jelentkező inkonzisztencia, mely abból ered, hogy a különböző forrásokból származó, különböző adatgyűjtések csak külön-külön vannak ellenőrizve és eltérés jelentkezik az egyes adatgyűjtések adatszolgáltatói körében vagy az adatszolgáltatók azonosításában. A STAR központi része az adatszolgáltatói regiszter, melynek segítségével való ellenőrzés a konzisztencia problémákat hivatott kiszűrni. A problémák kiküszöbölése, az egyes adatbázis témák gazdáival való egyeztetés szintén az adatbázisadminisztrátor feladata.

A gazdaságstatisztikában a megfigyelések nagy része szakágazat orientált, ami azt jelenti, hogy ha egy gazdálkodó szervezet szakágazata megváltozik, akkor az egyes évek szakágazati adatai többé nem hasonlíthatók össze. A probléma megoldása a szervezeti változások kiszűrése, az eredeti adatbázis homogenizálása. Az adatbázis két formában áll a felhasználók rendelkezésére: eredeti és következő év szerkezetére homogenizált. Így láncindexek képezhetők minden év eredeti adatainak a megelőző év homogenizált adataival való összevetésével.

A homogenizálás végrehajtása mind az adatbázisadminisztrátor mind az adatbázisgazda számára igen sok nehézséggel jár. Az adatbázisgazdának pótlólagos adatokat kell begyűjtenie a szétvált szervezetekből, ami gyakran okoz problémát; az adatbázisadminisztrátor számára pedig a homogenizálás végigvezetése jóval időigényesebb és bonyolultabb feladat, mint az eredeti adatbázis betöltése.

Másfajta homogenizálási módszer szolgál a termék és település orientált adatbázisrész homogenizálására - itt csak összevonásokra van szükség, ezért a teljes idősor homogenizálható /pótdatok nélkül/ az utolsó év szerkezetére.

Az adatbázis helyes működését az adatbázis karbantartása és védelme biztosítja.

Az adatbázis jelszóval védett, módosításra csak az adatbázisadminisztráció jogosult, a lekérdező programozók csak olvasási jogosultsággal rendelkeznek, Jogosulatlan személyek nem érhetnek el az adatbázist.

Az adatbázis biztonságát a mágnesszalagos archivumba elhelyezett másolatok szavatolják.

### 32. A meta-adatbázis karbantartása

Az adatbázisadminisztrátor legfontosabb segédeszköze a meta-adatbázis.

A metaadatok változásainak igen rövid idő alatt rendelkezésre kell állnia, hisz a különböző szintű felhasználók - Hivatalon kívüliek, hivatalbeli statisztikusok és programozók - ennek alapján tudják megfogalmazni adatkéréseiket, illetve programjaikat. Vagyis

- az adatszótár listák,
- a Fizikai File-ok Katalógusa,
- a Mutató Katalógus és
- a Nómenklatura Katalógus időben való szétküldése nélkülözhetetlen.

- . -

Összefoglalva: az adatbázisadminisztrátor a Hivatal adatainak jó őrzője és gondozója kell legyen. Az adatbázis megfelelő üzemeltetése az adatbázis helyes használatának alapvető feltétele.

A meta-adatbázis pontossága és könnyű használhatósága jó elemzési lehetőségeket biztosít.



Márkus Gábor

MTA SzTAKI

1111 Budapest, Kende u. 13-17.

## BEVEZETÉS

A time-sharing számítógéprendszer alkalmazásakor rendkívül fontos, hogy a rendszert megóvjuk az illetéktelen felhasználóktól; ezért szükséges a felhasználók autentikusságának vizsgálata (azonosítása). Természetesen a bevitt adatok, programok ellenőrzésére is szükség van — adat-azonosítás —, ennek vizsgálata azonban külön ezen előadás keretein. A védelem szükségességét alátámasztják a számítástechnikailag fejlett országok számítógépes bűnözéssel foglalkozó statisztikái (az anyagban előforduló adatok, eredmények referenciáit illetően ld. Márkus G.: *Megbízható felhasználó-azonosító eljárások* MTA SzTAKI Working Paper AF/21 Budapest, 1983).

## MÓDSZEREK A FELHASZNÁLÓK AZONOSÍTÁSÁRA

Egyik legelterjedtebb módszer a *password*-ökkel való azonosítás. Minden felhasználó, amikor először kapcsolódik be a rendszerbe, választ egy jelsorozatot (*password*) és ezt a felhasználó nevével együtt elhelyezik a rendszerben egy táblázatban, a *password directory*-ban. Minden alkalommal, amikor a felhasználó be akar kapcsolódni, a rendszer megkérdezi tőle a *password*-öt, és akkor és csak akkor engedí őt bekapcsolódni, ha ismeri a nevéhez tartozó *password*-öt.

A *password directory*-hoz csak az azonosítást végző program férhet hozzá, a felhasználók nem. Természetesen van egy személy, a *rendszeradminisztrátor*, aki jogosult a file tartalmát nemcsak olvasni, hanem megváltoztatni is.

E rendszerben a rendszeradminisztrátor ismeri a *password*-öket, bár semmi sem indokolja még azt sem, hogy módja legyen ismerni őket. Egy illetéktelen személy a következő módokon férhet hozzá egy felhasználó *password*-jéhez (feltéve, hogy ezt az információt a rendszeradminisztrátor nem árulja el):

- (i) a felhasználó gondatlanságából (pl. továbbadja a password-öt, vagy könnyen kitalálható password-öt választ),
- (ii) hozzájut a rendszerben tárolt információkhoz (pl. elolvassa, kinyomtatja a password-file-t),
- (iii) lehallgatja a felhasználó terminálját a rendszerrel összekötő vonalat.

Mint hogy a rendszer nem tud különbséget tenni két, ugyanazzal a password-del jelentkező személy közt, az (i) lehetőség semmiféle password-rendszerrel sem védhető ki. Más, a felhasználó biológiai jellemzőit (hang, ujjlenyomat, stb.) felhasználó rendszerekkel ez a probléma is kiküszöbölhető.

A továbbiakban foglalkozunk először (ii)-vel. Ez volt az a gyengesége a hagyományos password-rendszereknek, amely arra a képtelennek tűnő követelményre vezetett, hogy a rendszerben ne tároljuk a password-öt, de mégis biztonsággal el tudjuk dönteni, hogy a felhasználó valóban a password-jével kísérelt-e meg bekapcsolódni. De ha a felhasználók neve mellett nem a password-jüket tároljuk, akkor mit? Először Needham javasolta, hogy a  $PW$  password helyett annak egy alkalmas transzformáltját,  $f(PW)$ -t tároljuk. (Itt megjegyezzük, hogy arra is lehetőség nyílik, hogy — megfelelő  $f$  transzformáció esetén — a rendszerben ne tároljuk a felhasználók nevét.) Az  $f$  függvényt úgy kell megválasztani, hogy  $f(PW)$  ismerete esetén se lehessen  $PW$ -t meghatározni. Az ilyen tulajdonságu függvényeket nevezik egyirányú függvényeknek. Pontosabban: egy  $f$  függvényt *egyirányú függvénynek* nevezünk, ha minden, az  $f$  értelmezési tartományába eső  $x$  argumentumra könnyen ki tudjuk számítani az  $f(x)$  értéket, de majdnem minden, az  $f$  értékészletébe tartozó  $y$ -ra *számítástechnikailag megoldhatatlan* az  $y=f(x)$  egyenlet  $x$  ismeretlenének meghatározása.

Vegyük észre, hogy a fenti definícióban megkövetelt nem-invertálhatóság alapvetően különbözik a matematikában általában használt fogalomtól, hiszen itt nem arról van szó, hogy az inverz kép ne legyen egyértelmű, hanem arról, hogy egy inverz képet gyakorlatilag ne lehessen meghatározni. A két fogalom közötti különbséget jól mutatja egy konszans függvény, amely a szokott értelemben természetesen (ha  $|D(f)| > 1$ ) nem invertálható, számítástechnikai szempontból pedig a legegyszerűbben invertálható függvények egyike (a keresett  $x$  argumentum az értelmezési tartomány bármely pontja lehet).

Figyelmet érdemel a definícióban a következő három meghatározás is: *könnyen*, *majdnem minden* és *számítástechnikailag megoldhatatlan*. Mindhárom fogalmat definiálhatjuk precízen, a konvencionális módon. Pl. a *könnyű* és *megoldhatatlan* esetében a fogalmakhoz — definícióként — számítás- és memória-igény korlátokat rendelhetünk; a *majdnem minden* definiálásához pedig definiálhatunk az  $f$  értékészletén  $\sigma$ -gyűrűt vagy  $\sigma$ -algebrát és mértékeket, és így e fogalom is precízen definiálható lenne. Azonban nem célszerű ez a konzervatív eljárás, mert esetleg jól használható egyirányú függvényeket zárna ki. *Könnyű* számításon értsük azt, amit ma könnyen végre tudunk hajtani (ez később sem lesz nehezebb); a *majdnem minden* esetében maradjunk meg a szemléletes, köznapi jelentésnél; *megoldhatatlannak* pedig tartjuk azt a számítást, amely megalapozott becslések szerint az elkövetkező néhány évtizedben megoldhatatlan lesz (ilyen számítás- és memória-korlátok:  $10^{30}$  művelet és  $2^{100}$  bit memória). Ez utóbbi definícióhoz kapcsolódóan két dolgot kell megemlíteni. Először: a *megoldhatatlan* definiálható a szokott módon, "örökérvényűen" is, ekkor a korlátok lehetnek pl.  $10^{70}$  művelet és  $10^{60}$  bit memória (vannak olyan függvények, amelyek még e konzervatív definíció értelmében is egyirányúak). Másodsor: előfordulhat, hogy egy addig egyirányúnak tartott függvény inverzének kiszámítására egyszerű módot fedeznek fel. Ekkor a függvény természetesen már nem lesz többé egyirányú függvény, és így minden e függvény egyirányúságára épülő rendszer egyik napról a másikra használhatatlanná válik.

Említésre érdemes az is, hogy még ha a függvény inverzének meghatározására nem is áll rendelkezésre direkt eljárás, a teljes halmozat kimerítő próbálgatást (teljes leszámolásnak is nevezhetjük) minden függvény esetében megkísérelhetjük. Itt van szerepe a G.B. Purdy által definiált fogalomnak, a függvény degenerációjának:

$$d := \max_{y_j \in \mathbb{R}(f)} \{x_i \in D(f) : f(x_i) = y_j\}$$

(feltételezzük, hogy létezik maximum). Purdy igazolta, hogy minél nagyobb egy függvény degenerációja, annál nagyobb valószínűséggel vezethet eredményre a teljes leszámolás.

Egyirányú függvény lehet pl. egy bitmanipulációk sorozatával előállított függvény (Evans, Kantorowitz, Weiss); egy prim-modulusu nagyfokszámú polinom-kongruencia (Purdy):

$$f(x) \equiv x^n + a_1 x^{n-1} + \dots + a_n \pmod{P};$$

GF( $q$ )-beli primitív elem hatványozása (Pohling–Hellman); egységelemes gyűrű feletti mátrix-hatványozás (ez az előbbi általánosítása – Márkus).

[Ez utóbbi esetben a felhasználó password-je az  $n \times n$ -es mátrixból és a kitevőből álló rendezett pár:  $(A, e)$ ; feltétel: az  $A$  mátrix különböző hatványainak száma nagy legyen és előforduljon hatványai között a megfelelő egységmátrix. Alkalmas mátrixokat viszonylag könnyen találhatunk. Legyen most a gyűrű pl.  $R = GF(2^{521})$ . Ekkor a hatványozás 1042 mátrix-szorzást igényel  $R$  felett, míg az inverz (a gyűrű feletti mátrix alapu logaritmus) kiszámításához  $2,6 \times 10^{78}$  – szor ennyi számítás szükséges.  $10^6$  művelet/sec sebességet feltételezve a logaritmus meghatározásához  $n=1$  esetén több, mint  $8,66 \times 10^{66}$  év,  $n=20$  esetén pedig több, mint  $3,58 \times 10^{70}$  év lenne szükséges (a hatványozás még ez utóbbi esetben is csak mitegy 0,5 másodpercet igényelne). E választással a mátrix-hatványozás a konvencionális definíció szerint is egyirányú függvény.

A felsorolt egyirányú függvények felhasználásával konstruálható olyan felhasználó-azonosító eljárás, amelyben a password egy számpár. E rendszer azt is lehetővé teszi, hogy ne tároljuk a felhasználók neveit.

A password-rendszerek (iii) gyengesége akkor jelentkezik, amikor a központi rendszer és a felhasználói terminál távol van egymástól. Ekkor az őket összekötő vonal (ez legtöbbször telefonvonal) fizikai védelme nem gazdaságos, így lehetőség van a továbbított információ lehellgatására, meghamisítására, a továbbítás megszakítására. (Itt van különös jelentősége az adatazonosításnak.) Az ilyen password-rendszerekben password-ök sorozatát szokás alkalmazni. A sorozat megválasztására két mód kínálkozik: (1) mindjárt az elején meghatározzuk az összes  $PW_i$ -t, és  $f(PW_i)$ -t a rendszer mindvégig tárolja – ekkor a felhasználónak is, a rendszernek is sok információt kell tárolnia; (2) a felhasználó az  $i$ -edik bekapcsolódáskor küldi el a következő bekapcsolódásnál azonosítóul szolgáló  $f(PW_{i+1})$ -et – ekkor lehetséges, hogy (kommunikációs hiba vagy illetéktelen beavatkozás miatt)  $f(PW_{i+1})$  helyes értéke nem jut el a rendszerbe. L.Lampert olyan rendszert dolgozott ki, amely mentes e hátrányoktól.

Legyen  $f$  egy olyan egyirányú függvény, amelynek  $N$ -szeri szukszcessziv alkalmazása is könnyű, és legyen  $PW$  egy password. Ekkor a password-sorozat  $i$ -edik eleme:

$$PW_i = f^{N-i}(PW), \quad (1 \leq i \leq N)$$

(ahol  $f^k$  az  $f$  függvény  $k$ -szori szukszcessziv alkalmazását jelöli – feltételezzük, hogy ez értelmes). A sorozat elemei mind különbözőek (így nem lehet egy esetleg lehallgatott password-del később a rendszerbe kapcsolódní), és  $i > 1$  esetén éppen a password szükséges a következő password azonosításához. Sőt  $PW_i$  értéke alkalmas bármely további  $PW_j$ ,  $j > i$  password azonosítására is, miáltal lehetővé válik, hogy akkor se kelljen egyetlen password-öt se ismételtlen használni, ha valamilyen okból a rendszert újra kell indítani; tehát még ilyenkor sem tud egy illetéktelen személy felhasználni egyetlen lehallgatott password-öt sem.

Az említett egyirányú függvények közül csak az utolsó nem használható itt közvetlenül, de alkalmas módosítással az is megfelelővé tehető (ha pl.  $R$  elemei megfeleltethetők egész számoknak (a megfeleltetés legyen  $\psi$ ), akkor  $PW_i = A^e$  esetén lehet  $PW_{i+1} = A^r$ , ahol  $r = e \cdot g(A^e)$  egy alkalmas  $g$  függvénnyel –  $g$  lehet pl.  $\psi(A^e)$  legnagyobb eleme abszolút értékének vagy  $\psi(\det|A^e|)$ -nek egy polinom-kongruenciája, stb.).

## ZÁRÓ MEGJEGYZÉSEK

Az eddig kidolgozott eljárások megbízhatósága a hosszú és teljesen értelmetlen password-ökön múlott (általában annál megbízhatóbbak, minél hosszabb a password). Egy felhasználó azonban a könnyen megjegyezhető (rövid és értelmes) password-öket szereti: a hosszut és értelmetlent elfelejti, ha pedig leírja vagy rögzíti valamilyen (egy vagy több) adathordozón, akkor azt elveszítheti, lemásolhatják, ellophatják. Ugy tűnik, ez az ellentmondás egyelőre nem oldható fel. Részleges megoldására szolgálhat a fent leírt mátrix-hatványozásra épülő felhasználó-azonosító eljárás, mert ott – igaz hosszabb, de – értelmes szöveg is lehet password a megfelelő szintű biztonság megőrzése mellett.

A megvalósítást illetően az *intelligens terminál* tűnik a legígéretesebbnek. Ez magában foglal egy mágneskártya/kazetta olvasó egységet és egy mikroszámítógépet, és így elvégzi a felhasználó (adat) azonosítását, pontosabban annak egy részét. Így egy rendszerbe különböző felhasználók különböző módokon kapcsolódhatnak be, egy felhasználó pedig akár több rendszerbe is ugyanugy. Ekkor nem jelent nagy problémát a távoli terminál sem.

Bármiféle implementációra is fennáll azonban, hogy minél megbízhatóbb egy rendszer, annál költségesebb is. Ezért mindig az igényeket és lehetőségeket figyelembe véve, a veszélyeket mérlegelve egy kompromisszumos optimumot kell megvalósítani.

## Kiegészüllyozott adatbázis alkalmazások

### 1./ Bevezetés

Az ÁSZSZ számítógépein részben ÁSZSZ fejlesztéssel is kialakított államigazgatási adatbázis alkalmazási rendszerek tapasztalatai fontos jelenségekre hívják fel a figyelmet. Ezek a rendszerek kiegyensúlyozottságával függnek össze. Kiegészüllyozottságon azt értjük, hogy a rendszer különféle vonatkozásokban mennyire azonos, vagy eltérő szinten kerül megtervezésre és kivitelezésre. A kiegyensúlyozatlanság mindig kihaszánlatlansággal és gazdaságtalansággal jár.

A következőkben néhány fontos vonatkozást, tényezőt sorolunk fel, és pár konkrét adatbázisnál rámutatunk, hogy a kiegyensúlyozatlanság milyen törekvések következménye lehet és az mennyire a hatékonyság és gazdaságosság rovására megy.

Az elmondottak triviálisnak tűnhetnek, mégis számos konkrét példa bizonyítja, hogy komoly törekvések formájában is élnek olyan elképzelések - elsősorban a döntéshozók körében, akik csupán a rendszer egyes vonatkozásait ismerik kellően - melyek kiegyensúlyozott rendszer létrehozását megakadályozzák.

### 2./ Alapvető tényezők

A számítógépesítésnél az alkalmazási rendszer valódi színvonalát és eredményességét egy sor tényező határozza meg. Ezek közül soroljuk fel - véleményünk szerint - a legfontosabbakat. Ezek:


1. Hardver eszközök mennyisége és minősége.  
Ebbe beleértjük a háttértárak minőségét, mennyiségét, egyidejűségét, megbízhatóságát is.
2. Szoftver eszközök színvonala és erőforrásigénye.  
Meghatározó a szoftver programozásának, üzemeltetésének, a felhasználásának komfortja és ára. Adatbáziskezelő nyelv, lekérdező nyelv léte, ill. alkalmazhatósága, stb.
3. Elérési eszközök léte és színvonala.  
Ebbe értjük a diszpécserozést, a hálózat létét, a vonalak és végberendezések megbízhatóságát. A postai szolgáltatást úgyszintén.
4. A szolgáltatás szervezettségének foka.  
Ez a potenciális lehetőségek hasznosíthatóságának színvonalát jelenti, szakértelmet, gyorsaságot, kényelmet.

5. Alkalmazásfejlesztési felkészültség és kapacitás.  
Ez a fejlesztők ismereteit, tapasztaltságát, felhasználó-orientáltságát és hatékonyságát is magába foglalja.
6. Felhasználói igény valódisága, eltökéltsége.  
Az igény divatból, objektív kényszerből származik-e, a felismerés tudatossága, érdekek egyensúlya ide értendő.
7. Felhasználói felkészültség és fogadó készség.  
Itt a ténylegesen felhasználó és a felhasználást biztosító, pl. adatszolgáltató, személyek képzettsége, fegyelme és hozzáállása mutatkozik meg.
8. Megvalósítási költségsszint és fedezet.  
Itt beleértjük a helyes költségbecslést, a fedezet kellő időben való rendelkezésre állását a fejlesztéshez, valamint a költség viszonyát az elért felhasználói hozamhoz. Itt kell számításba venni a célberuházásokat is, beleértve a hardver és szoftver eszközöket.
9. Üzemeltetési költség és fedezet.  
Hosszútávon biztosítható üzemeltetési költségsszintet kell betartani és azt összevetni alternatív megoldásokéval. Itt hardver és szoftver bérleti költség is felléphet.
10. Üzemeltetési készség és felkészültség.  
Államigazgatásban a számítógép üzemeltetés, a rendszerfejlesztés és a végfelhasználás független intézmények keretében valósul meg. Közöttük az alkalmazási rendszer egyedi kapcsolatot, koordinációt igényel, mind a létrehozás, mind a tartós üzemeltetés keretében. Főleg az üzemeltetés hosszútávú közös tevékenységének színvonalára lehet döntő az alkalmazási rendszer "beválásában".
11. Az alkalmazás célkitűzései.  
A különféle szempontok, tényezők elérhető szintjei determinálják az elérhető célokat. A "feszítő", de még elérhető, az igényes, de hosszútávon gazdaságos célkitűzések, illetve az azoktól elmaradó, vagy azokat meghaladó célkitűzések fokozatai lépnek itt fel.  
Az egeret szülő vajúdó hegyek, az asztalfiókba temett csodarendszerek, a csodaváró kiábrándulások a tipikus jelzők a rossz és az egyre inkább beváló, a változó igényekhez rugalmasan alkalmazkodó a tipikus jelzők a jó rendszerekre.

A felsorolt tényezők bármelyike többféle szinten tervezhető és valósulhat meg. A mérés nehézségeitől eltekintve képzelhetjük a tényezőket egy sugársor sugarain ábrázolva egy pókhálószerű alakzattal, amelynek határát a maximális lehetőségek tűzik ki. Koncentrikus körök mentén az azonos tényezősszintek helyezkednek el. Egy konkrét megvalósított alkalmazási rendszer annál kiegyensúlyozottabb,



minél közelebb áll egy koncentrikus körhöz az a vonal, amelyet az egyes tényezők kihasznált szintjei által kijelölt pontok összekötése eredményez a sugársornál. A rendszer annál magasabb szintű, minél nagyobb a kör sugara. Kiegyensúlyozatlan rendszer tényleges színvonalát azonban a tényezők közül a minimális szintű határozza meg. Ugyanakkor általában a rendszer költségeit a legmagasabb tényezőszint szabja meg. Az optimális rendszer jellemzője az, hogy az alacsonyszintű tényezőknél a fokozatos továbbfejlesztésével válik egyre kiegyensúlyozottabbá.



### 3./ Kiegyensúlyozottságot gátló körülmények

Könnyen tudunk példát mondani arra, hogy egy tényező alacsonyszintű megvalósulása miatt a rendszer elérhető hozama jelentősen lecsökken, ami a relatív költség magas szintjét eredményezi. Csak néhány tipikus problémát említek, amely az, egyébként legnagyobb, rendszer szintjét is jelentősen leszállítja, ezáltal a kiegyensúlyozottságot gátolja:

- gyakori számítógép üzemzavar eszköz vagy üzemeltetési egyengeségek miatt,
- üzemeltetési nehézségek az aránytalanul nagy erőforrásigény vagy a programrendszer terjedelmessége miatt,
- a nehézkes, késedelmes, pontatlan adatszolgáltatás,
- a sokszorosítás elhúzódnása, az információtovábbítás lassúsága,
- a fejlesztés elhúzódnása miatti elavulás,
- az információk visszatartása, a rendszer használatbavételének halogatása vagy takaréklángon való használat.

Az előzőekben kiemelt tényezők még maguk is összetettek, alkalmazási területenként eltérően jelentkezhetnek és további tényezők válhatnak kritikussá. A felsorolás célja inkább a mondanivalók illusztrálása volt.

Egy államigazgatási adatbázis létrehozása csak akkor célszerű, ha

- ésszerű fejlesztési ráfordításokkal elfogadható időn belül elkészül,
- ésszerű és rendelkezésre álló erőforrások használatával eléggé megbízhatóan üzemeltethető,
- reális igényt elégít ki, amelyet a felhasználók is felismertek és készek lesznek annak használatára.

Optimális rendszer kialakításánál még egy fontos szempontot figyelembe kell venni, éspedig azt, hogy az egyes tényezők lehetséges szintjel fokozatosan változnak, növekednek. Itt két hibát követhetünk el:

- csak a mai szinttel számolunk és a növekedést nem fogjuk tudni kihasználni /befagyasztott rendszer/
- előrebecsült jövőbeni szinttel számolunk, amely nem valószínű, így rendszerünk legfeljebb "Télárbocon" lesz használható és örökre kiegyensúlyozatlan marad.

#### 4./ Néhány konkrét alkalmazás

A különböző tényezők különféle alkalmazási rendszereknél más-más formában jelennek meg. A kiegyensúlyozatlanság gyakran annak a következménye, hogy nem veszik tekintetbe a rendszer sajátos jellegzetességeit és ebből irreális tervek, elvárások fogalmazódnak. Három államigazgatási adatbázisnál szeretném példaként a - véleményem szerint - fő jellegzetességeket felsorolni:

- a népszégnnyilvántartási rendszernél,
- a jogszabálynyilvántartásnál,
- a nyugdíjmegállapító rendszernél.

A népszégnnyilvántartó rendszer fő jellegzetessége, hogy

- nagyszámú objektum /személyek/ meghatározott adatait kell tárolni, karbantartani, ami sok száz millió karaktert jelent,
- rendszeres nagytömegű adatváltozás történik területileg szétszórótan keletkező adatokkal,
- a tipikus adatszolgáltatás átfogó, a teljes adatbázis áttekintését igényli.

A reális hazai adottságok mellett ezekből következik, hogy kiegyensúlyozott rendszert célul tűzve

- a teljes adatállomány nem lehet egyszerre on-line
- az adatbázis aktualitási fokát nem elsősorban az adatbázisba való bevitel számítógépközeli gyorsasága dönti el,
- a szolgáltatásokat lehetőleg egy feldolgozási menetben kell teljesíteni /leválogatások egyszerre/,

- egyedi adatok hibavalószínűsége avulás miatt jelentős lehet.

A jogszabálynyilvántartási rendszer fő jellegzetessége, hogy

- szöveges objektumokat /jogszabályi tartalom/ kell tárolni,
- az adatigénylés egyedi, széles igénylőkörrel,
- spontán igények, gyors válaszidő igényvel.

A kiegyensúlyozott rendszer megvalósításához a következőket is meg kell fontolni az erőforrások függvényében:

- a teljes jogszabály szöveget tároljuk-e, vagy csak tartalmi utalásokat /mit nyerünk a teljes szöveggel/,
- a jogalkalmazó közvetlenül fordul a géphez, vagy közvetve /mire képes, ill. hajlandó/,
- a jogalkalmazónak az információra /válasz/ maradandó formában van-e szüksége /nyomatva/,
- a jogalkalmazónak valójában milyen hozzáférési mód és válasz-gyorsaság szükséges.

Nyilvánvaló, hogy

- ha nem nélkülözhető a jogszabályok nyomtatott gyűjteménye a jogalkalmazók asztalán, akkor felesleges a teljes szöveg tárolása;
- ha a válasz írásban kell és nyomtató lehetetlen minden jogalkalmazó szobájában, akkor jobb a közvetett gépfordulás;
- amikor az adatbázis on-line, az intenzív lekérdezés optimális és nem a minél kevesebb számú;
- a terminál "ha maga használja" új technikai szemléletet kíván a jogalkalmazótól, a nyomtató pedig zajos és "kényes" és számítani kell a gyakori üzemzavarra is.

A nyugdíjmegállapító rendszer fő jellegzetessége, hogy

- vegyes jellegű adatokat kell tárolni /szövegesek, nem szövegesek, algoritmusok, programok, stb./,
- az adatok jelentős része átmenetileg /a nyugdíjmegállapítás időszakára/ kell, hogy közvetlenül elérhető legyen,
- az adatokkal meghatározott körben üggyintézők, ellenőrök/ foglalkoznak, akik megfelelően felkészíthetők,

A fenti sajátosságokból következik, hogy

- a rendszer jellegzetes használata párbeszédese, tehát interaktív;
- a terminálok száma és a rendszer terhelése jól tervezhető, kihasználás optimalizálható;

- a kiegyensúlyozottsághoz fontos elhatárolni a rendszer on-line végrehajtandó és elhalasztva /pl. éjszaka/ végrehajtható tevékenységeit, mert a jelentős adatmanipulációs háttértevékenység esetén a számítógép hamar telítődhet és a válaszidők megnövekedhetnek.

## 6./ Összefoglalás

A példákban felsorolt tényezők és szempontok figyelmen kívül hagyása, vagy helytelen számításbavétele kiegyensúlyozatlan rendszerekhez vezetne, amelynek következményeként a rendszerek hozamai nem lennének arányban a ráfordításokkal és az egyáltalán lehetséges használhatóság is veszélybe kerülhetne. A nagyigényű, csábító célkitűzések csalódásra vezethetnek, miután más tényezők hiánya valóráválásukat megakadályozhatja.

Az igénytelen megoldások viszont eleve csalódást okoznak a felhasználónak, aki többet vár a korszerű számítástechnikától. A lehető legmagasabb szinten megvalósított, de kiegyensúlyozott, továbbfejleszthető rendszerek váltják csak be a hozzájuk fűzött reményeket.

Osztott adatbázis kialakítása CII Honeywell

Bull és TPA 11/40 számítógépeken

BEVEZETÉS

Az előadás egy országos hatáskörű intézet anyagforgalmazási rendszeréről, annak most folyó fejlesztéséről kíván beszámolni. A rendszerrel szemben - az intézet speciális helyzete miatt - támasztott igények egyenként is nehezen megvalósíthatóak, összességükben pedig egymással ellentmondásosak. A legkevesebb kompromisszumot tartalmazó megoldás osztott rendszerben megvalósuló adatbázis alkalmazására vezet.

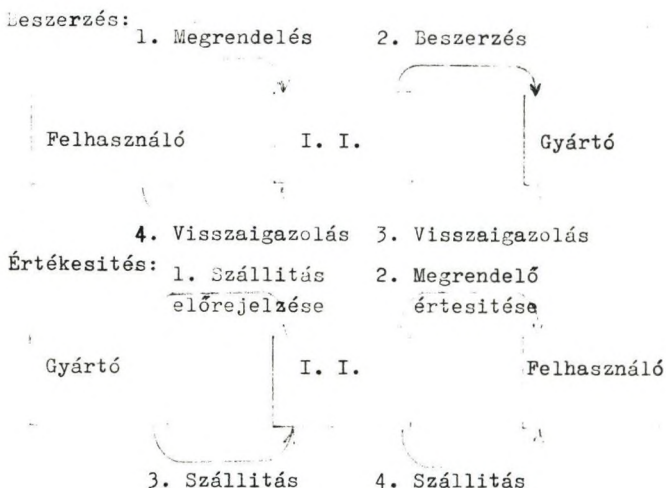
Az alábbiakban ismertetjük a rendszer fő funkcióit, ezek két gép közötti megosztásának szempontjait, a CII Honeywell Bull 66/20D és a TPA 11/40 számítógépeken rendelkezésre álló eszközöket, a kapcsolattartás módszerét és korlátait, és a megvalósítás eddigi tapasztalatait. Az előadásban részletesebben kitérünk a TPA - Honeywell kapcsolat által nyújtott, osztott rendszerek kialakítását támogató, távadatátviteli lehetőségekre.

A RENDSZER FŐ FUNKCIÓI

Az országban a rádióaktív készítmények nyilvántartása és forgalmazása az MTA Izotóp Intézetének /a továbbiakban I.I./ feladata. A forgalom rohamos növekedése, a gyors, pontos ügyintézés igénye szükségessé tette az ügyvitel számítógépes automatizálását. A megvalósítás három, egymástól időben jól elkülöníthető részből áll. Alapja egy alapadatnyilvántartó adatbázis /a továbbiakban OINY/. A második rész, jelen témánk, az izotópforgalmazás /továbbiakban IZOPOR/ elkészítése most folyik az ÁSZSZ kivitelezésében. A rendszer teljessé a számlázás automatizálásával válik.

Az OINY adatbázis tartalmazza az I.I. által, fennállása óta forgalmazott valamennyi szállitmány jellemzőit, és feladata, hogy a jövőben szállított termékeket is nyilvántartsa. Így ez egy állandóan bővülő állomány. Az adatok közötti kapcsolatok bonyolultsága igen nagy, szükség van a Honeywell IDS adatbáziskezelő nyelvének lehetőségeire.

A nyilvántartási rendszerhez kell illeszkednie az általunk tárgyalt forgalmazási rendszer<sup>nek</sup>, amely a beszerzés és értékesítés alábbi vázolt ügymenetéből áll:



A számítógépes rendszer készíti az ügyvitelhez szükséges űrlapok, bizonylatok kitöltését, naprakész információszolgáltatást, statisztikai és leltári kimutatásokat, a forgalmazott termékekről, göngyölegekről, ügyfelekről.

A rendszerrel szemben támasztott kritériumok szigorúak, összetettek, és egymással gyakran ellentétes hatásúak voltak. Lehetetlen volt a hagyományos, centralizált rendszer keretében történő megvalósításuk. Példaként felsorolunk néhány ilyen, egymással ellentétes kritériumot:

- a rendszer interaktivitásigénye oly nagy, hogy feltétlenül szükségessé teszi több terminál állandó on-line használatát;
- az adatbázis fizikai mérete oly nagy, hogy lehetetlen a tartós, nappali, on-line hozzáférés a lemezkapacitás szűkössége miatt;
- a nyilvántartás egy állandóan bővülő állomány, míg a forgalmazás évente megújuló állományokat igényel;
- az adatok közötti kapcsolatok annyira összetettek, - ez a kódok és kulcsok felépítésében is tükröződik - , hogy csak igen megbízható adatrögzítéssel működtethető a rendszer;
- az izotópforgalmazásra vonatkozó előírások változnak, az ügymenet nem eléggé tisztázott, gyakoriak a kivételes eljárások, így csak rugalmas, könnyen változtatható rendszer fogadható el;
- a rendszer erőforrásigénye egyes szűk keresztmetszetek esetében az üzemelés során kritikus terhelést okozhat, ezért csak gondosan megtervezett, és optimálisan kivitelezett működhet üzemszerűen;
- gyakori a többpéldányos, előre nyomtatott leprellők használata, így a nyomtatás a központi

nagyszámítógépen csak igen rossz hatékonysággal oldható meg.

A fenti követelmények ellentmondásossága miatt csak olyan kompromisszum valósítható meg, amely több, egymással laza kapcsolatban álló részrendszerből áll. A részrendszerek adatbázisainak illetve adatállományainak kapcsolatát célprogramok valósítják meg: karbantartó, válogató, és átviteli programok.

A rendszer kialakításához kedvező lehetőséget az intézetünkben kifejlesztett TPA 11/40 CII Honeywell Bull kapcsolat nyújtott. Az I. I.-ben működő kishaszámítógépen nemcsak a távoli futtatásuk és távoli nyomtatás valósítható meg, hanem fájlok átvitele is. Ezenkívül a TPA termináljairól dolgozhatunk a Honeywell tetszőleges interaktív rendszereivel is. Ezek a különböző TAF módok egyszerre is használhatók a TPA különböző termináljairól, rugalmas összeköttetést teremtve a két számítógép között. Kényelmes lehetőség van a távoli nagygép és a helyi kishaszámítógép közötti funkciómegosztás kialakítására.

#### A KÉT GÉP KÖZÖTTI MEGOSZTÁS

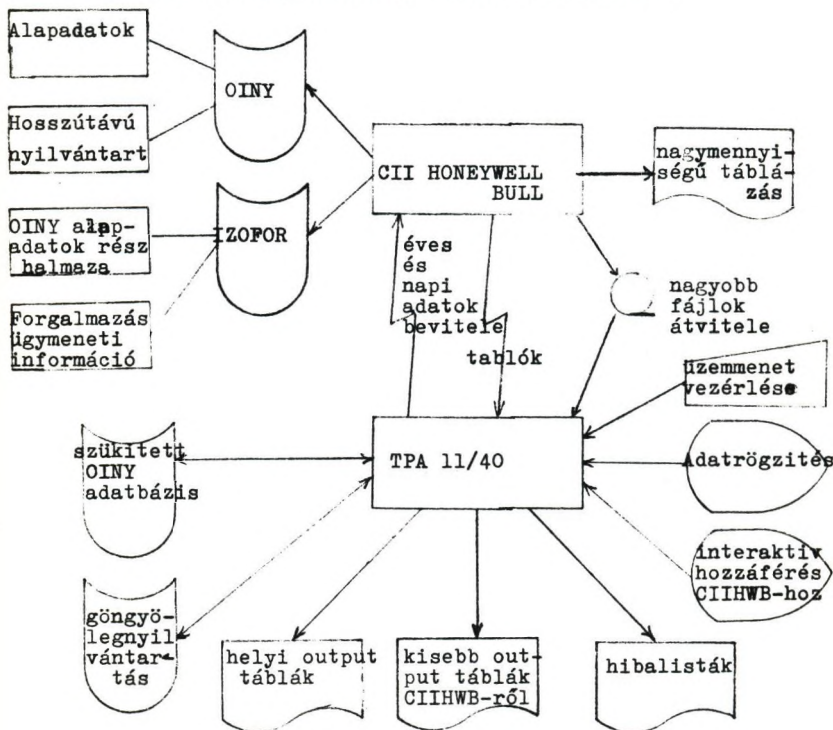
A nyilvántartási és a forgalmazási rendszereket az archiválás idejének különbözősége miatt két független adatbázisban valósítjuk meg. Az alapadatnyilvántartásban /OINY/ végzett javítások után automatikusan átvesszük a módosításokat az IZOFOR adatbázison is. Mindkét adatbázis a Honeywell-en van, tekintettel a jelentős háttértároló igényre.

Míg a nagy kapacitást /háttértároló, CPU idő/ igénylő műveletek a Honeywell-en futnak, a TPA-n valósulnak meg a nagy interaktivitást igénylő műveletek. Ezek során



gyakran van szükség felhasználói döntésekre, és így leghatékonyabban a felhasználó környezetében végezhető. Ilyen műveletek az adatbevitel, adatellenőrzés, részállományok listázása, nyomtatás többpéldányos, vagy előre nyomtatott bizonylatokra. A TPA 11/40 szoftver-ellátottsága /DECPORM/ lehetővé teszi, hogy az adatbázisba történő bevitel előtt már a kulcshibákat, és az adatok közötti tartalmi ellentmondásokat is kiküszöbölhetjük. Megjegyezzük, hogy korábban, csoportos adatrögzítéssel /INTERSCAN 2100/ történő bevitelnél ilyen nem lehetett megvalósítani, mert nem volt lehetőség a bevitel során az alapadatokhoz való hozzáférésre.

A feladatok megosztásának sémája a következő:



Az év végére tervezzük az IZOPOR adatbázis rendszer-tesztjét. Jelenleg a programozási munkák folynak.

Fontos tapasztalatokat szereztünk az egyes feladatok erőforrásigényeire vonatkozóan. Sajnos lényeges döntések és eszközök hiányában előzetes számításokat és kísérleteket csak késve tudtunk elvégezni, és ez az erőforrás-igény szempontjából néhány hátrányos megoldást eredményezett.

A szétosztott rendszerben résztvevő eszközök nagy száma természetesen rontja a rendszer üzembiztonságát, hiszen a teljes rendszer üzemidejét az egyes rendszerek üzemidejének közös része adja. Sok a panasz a postai adatátviteli berendezésekre. Ezen a téren a karbantartás megszervezése a legnehezebb feladat, hiszen mintegy féltucat egymástól távol álló szervezet összehangolt munkája szükséges egy-egy hiba biztonságos elhárításához. Emiatt a két gép közötti kapcsolat laza, sok redundanciát tartalmaz, és a távoli vezérlésen és időnkénti interaktív terminálhasználaton kívül lényegében file-átvitelre korlátozódik.

A fejlesztés során a legnagyobb nehézséget az jelenti, hogy olyan team munkáját kell megszervezni, amelyben nemcsak a szakterületek idegenek, hanem a szakértők is egymástól helyileg és szervezetiileg is igen távoliak. Magas szintű koordináció hiányában az érdekek különbözősége is komoly akadályt jelenthet.

Az eddig szerzett tapasztalatok szerint ezzel a megoldással azonban sikerül kielégíteni egy igen bonyolult követelményrendszert. A feladatoknak a két gép közötti ilyen megosztásával, a helyi adatbevitel és rész-adatbázisok segítségével eleget lehet tenni a pontosság, várakozási idők, adatbiztonság igényeinek is.

PERSONAL DATA MANAGEMENT SYSTEM  
MIKROSZÁMÍTÓGÉPES ADATBÁZISKEZELŐ RENDSZER

Az MTA SZTAKI-ban 3 éve foglalkozunk személyi számítógépeken használható adatbázis kezelő rendszerek fejlesztésével. A célrendszerek készítésén kívül általános célu adatkezelő rendszerek kidolgozásával is foglalkozunk. Ezek egyike a PDMS.

A PDMS kifejlesztésével két célt szeretnénk megvalósítani. Egyfelől egy könnyen megtanulható, egyszerűen kezelhető komplett rendszert adni a felhasználók kezébe, mellyel komolyabb előképzettség nélkül is felépíthetnek és kezelhetnek adatbázisokat. Másrészt a professzionális felhasználók számára szeretnék egy olyan eszköztárat biztosítani, mellyel az adatbázisokkal kapcsolatos tipikus feladatok gyorsan megoldhatók, s így bonyolult célrendszerek készíthetők.

A rendszer rövid ismertetése

A PDMS elsősorban olyan területeken használható jól, ahol sok szempont /kulcsok, feltételek szerint kell tudni egy nagy adatbázisállományban gyorsan keresni, és a kiválasztott információkat változatos módon megjeleníteni.

A rendszer egyszerre akárhány független adatbázis kezelését képes ellátni. Minden adatbázis egy fő adat file-ből, 1-9 "segéd file"-ből, tetszőleges számu, a fő file rekordjainak rendezését és kulcs szerinti közvetlen elérését biztosító VSAM strukturából, tetszőleges számu, a felhasználó által definiált szelekciós kitériumból, report formátumból, a PDMS nyelvén irt speciális tranzakcióból áll.

Az adatok között egyirányu hierarchikus kapcsolat valósítható meg: a főfile rekordjaiból a segédfile-ok rekordjai ponterek segítségével elérhetők.

A rendszer által kezelt adattípusok:

string /max. 250 char/  
egész szám /max. 12 jegy/  
valós szám /max. 15 jegy/  
dátum /1900 jan. 1.-1999. dec. 31./  
pointer /fő file-beli adat  
segéd file-beli adat/

Egy-egy file azonos szerkezetű rekordokból áll. A fő file maximális rekordhossza 1020 byte, a segédfile-oké 250 byte. Az egyes file-ok rekordszáma max. 65535. A főfile szükség esetén több diszken is átnyulhat. A mezők számának összege az összes file-okon nem haladhatja meg a 128-at. A nem string típusu mezők értékét mindig tömörítve tároljuk.

A rekordok kulcs szerinti elérését egy VSAM /Virtual Sequential Access Method/ rendszer biztosítja. Kulcsként a fő file bármely mezője /string, szám, dátum, pointer típusu/ vagy annak valamely része használható. Ha a kulcs nem azonosítja egyértelműen a rekordokat, használhatunk 1-3 kiegészítő kulcsot is, de ezeknek sem kell egyértelműeknek lenni.

Minden rendezéshez egy index file tartozik. A kiválasztott rendezés index file-jának egy - az adatbázis méretétől függő - része memória rezidens, a maradékot egy speciális page-elési eljárás kezeli. A kulcs szerinti elérés sebessége a kulcstól egyáltalán nem függ, egy bizonyos rekordmennyiségen túl pedig a rekordszám növekedése sem befolyásolja, lényegében állandónak tekinthető. Közel egyértelmű kulcsok esetén a keresés /beszúrás/ átlagos ideje - sok ezres rekordszám mellett - 1-2 másodperc. Nem egyértelmű kulcsok a rekordelérést lassítják, a szükséges idő arányos az azonos kulcsu rekordok átlagos számával.

Egy adatbázisban egyszerre akárhány ilyen rendezést definiálhatunk, ezeket a rendszer automatikusan karbantartja, és bármikor választhatunk közülük. Ezzel biztosíthatjuk a különböző szempont szerinti keresések egyforma hatékonyságát.

Lehetőség van az adatbázisban nem tárolt változók használatára is. Ezek - az adatbázis adataiból és a már definiált változókból képzett - adatok elsősorban riportok készítésénél hasznosak.

Az adatok felvitelére, módosítására, megjelenítésére standard eljárások vannak, melyeket a felhasználó szükség szerint átparaméterezhet, ezzel számára egyszerűbbé, saját céljainak megfelelőbbé tehet.

Listák készítéséhez egy riport generátort használhat, mellyel tetszőleges formátumu printout-ot /oszlopos lista, levél, boríték címzés, stb./ készíthet. A riportban report-, page- és control header, ill. footer, valamint tetszőleges számítások definiálhatók.

Egy feltétel generáló program segítségével készíthet szelekciós rutinokat, melyek a riportok készítésénél használhatók.

A válogatás használhat egy VSAM strukturát, mely kívánt kulcs szerinti elérést biztosítja. A feltételekben szerepelhetnek a kulcs(ok)/ra, az adatbázis mezőire és a definiált változókra vonatkozó logikai kifejezések.

Az adatbázis minden tranzakciójának van alapértelmezés szerinti input és output egysége /pl. adatfelvitel: klaviatúra input, diszk file output, stb./ de ezek átdefiniálására is lehetőség van.

Az egységek:

```
klaviatúra /input/
képernyő /output/
printer /output/
diszk /input, output/
RST 232/V24/ /input, output/
```

A fenti funkciók megvalósításakor a felhasználónak semmilyen programozási vagy adatbáziskezelési ismeretekkel nem kell rendelkeznie, ezek a rendszerrel folytatott dialógus segítségével definiálhatók.

A pDMS parancsokkal vezérelhető, teljesen interaktív rendszer. Egy parancs parancs-szóból, paramétereiből és opció(k)ból álló sorozat. A parancs-szó általában a végzendő tevékenységre utal, a paraméterek a tevékenység tárgyára, az opciók pedig a végrehajtás módjára vonatkozó információkat tartalmaznak.

Részletes magyarázat nélkül felsoroljuk a pDMS parancsait, használatuk szerint csoportosítva:

parancsszó	paraméter	opció
HELP	-	[P]
DIR	[n]	[P]
STAT	-	
DEF	{ DBS VSAM VAR REP COND CHAIN AUTO NEW MOD DISP }	[I=input file]
FIX		[O=output file]
SHOW	{ FILE VSAM VAR CHAIN USER }	[P]

DBS	[adatbázis név]	[;N]
FILE	file név	-
ADD	-	[;I=input file] [;u]
MODIFY	{ · n [-] [m] -n }	[;u] [;I=input file]
DELETE	{ · n [-] [m] -n }	-
RESTORE	{ · n [-] [m] -n }	-
LIST	-	[;P] [;u]
QUERY	{ · n [-] [m] -n }	[;P] [;u] [;O=output file]
CLOSE	-	-
VSAM	[VSAM név]	-
GET	-	[;u] [;P] [;O=output file]
INSERT	-	[;u] [;I=input file]
REPORT	[riport név]	[;C=feltételnév], [;O=output file]
AUTO	-	-
CHAIN	parancslánc név	-
END	-	-

A parancsokkal /vagy parancsláncokkal/ nem megoldható...  
/feladatok megvalósításához saját tranzakciók írása  
szükséges, melyhez a pDMS adatbáziskezelő parancsai-  
val kiegészített BASIC nyelv használható.

A pDMS néhány felhasználása:

Gyógyszernyilvántartási rendszer  
Raktári számlázó és készletnyilvántartó rendszer.  
Vezetői információs rendszer  
Munkaközvetítő rendszer

A rendszer környezete

Hardware: SYSTER, VARYTER, TRS-80 64 kbyte /z80/  
2-4 floppy drive  
printer

Software: CP/M, NEWDOS, PASCAL, BASIC

I R O D A L O M

Hannák L. - Kovács K. - Lengyel Tamás: A personal computerek alkalmazási lehetőségei a kórházi adatnyilvántartásban és egyéb egészségügyi területen, 10. Neumann Kollokvium, Szeged, 1980, pp. 77-84.

Kerékfy P. - Ruda M.: Mikrogépek alkalmazása kórházi és rendelőintézeti információs rendszerekben /megjelenőben/, 11. Neumann Kollokvium, Szeged, 1982. dec. 6-8.

Kerékfy P. - Ruda M.: Microcomputer Application in Data Processing Systems /megjelenőben/, 8 th Winterschool of Operating Systems, Visegrád, 1983.jan. 31-febr.4.  
/Abstracts: p 18./

Kerékfy P. - Ratkó I. - Ruda M.: Microcomputer - based medical information systems /elfogadott előadás/, MEDINFO'83, Amsterdam, 1983, aug. 21-26.

Lengyel T.: A MEDICOR kötés- és terméknilyvántartási rendszere közlés alatt, 1983.

A GÉPI SZÖVEGFELDOLGOZÁS SZEREPE  
A JAPÁN 5. GENERÁCIÓS PROJEKT  
REALIZÁLÁSÁBAN

Sokan keresik arra a választ világszerte, hogy mennyire megalapozottak a japánok ambiciozus tervei egy új, "intelligens" számítógépgeneráció létrehozására. A mesterséges intelligencia megteremtése /értsd: az értelmes viselkedés szimulációja, az intelligens válaszreakciók biztosítása/ igencsak a kutatás stádiumában van ma még. Nem az elért eredmények lebecsülését jelenti, ha elismerjük, hogy méreteiben ezek a kutatások egyelőre csak nagyon korlátozott gyakorlati alkalmazást tesznek lehetővé.

A japánok célul tűzték, hogy az évtized végére a világszerte elért "laboratóriumi" eredmények birtokában /nem utolsósorban saját intenzív kutatásaik felhasználásával/ a számítástechnika alapjává tegyék a mesterséges intelligencia alap gondolatait, egységbe ötvözve a különböző területeken elért részeredményeket.

A laboratóriumi méretekől az üzemszerű alkalmazásokig legfőképpen nem azért nehéz eljutni, mintha elvi akadályai volnának a bevált módszerek szélesebbkörű alkalmazásának, még csak nem is a technikai lehetőségek növekedési iramával vannak problémák /a rohamos technikai fejlődés inkább elébeszad a lehetőségek mindenkori kihasználásának/. A "szűk keresztmetszetet" sokkal inkább a technikailag kiépíthető rendszereknek megfelelő tudásanyaggal való feltöltése jelenti. Így van ez még a mesterséges intelligencia kutatások eddig talán leg-



eredményesebb, a gyakorlatban leginkább bevált területén, az un. szakértői rendszerek kialakításában is. A felhalmozódott emberi tudásanyag döntő többsége emberi nyelven leírva, zótárakban, enciklopédiákban, szakkönyvekben, szakcikkekben szunnyad, s csak részleges megoldást jelent az, hogy a hozzáférésben, a szöveges információk kikeresésében igénybe lehet venni a számítógép segítségét. Jelenlegi formájában az a tudásanyag a számítógép számára "élvezhetetlen", és óriási emberi munkaráfordítással lehet csak hasznosíthatóvá tenni.

A japán számítógép projekt sikerének kulcsa - s ezt ők igen világosan felismerték - az, hogy létre tudnak-e hozni egy emberi nyelven tanítható rendszert, amely egy "nyers", előzetes előkészítés nélküli inputból, addigi ismereteire támaszkodva, ki tudja hámozni az újabb és újabb ismereteket, s asszimilálni tudja addigi tudásanyagához. Az emberi segítséget, beavatkozást természetesen, nem zárja ki egy ilyen rendszer alkalmazása - feltéve, hogy arra nem túlságosan gyakran kerül sor. Az alapvető kérdés tehát egy természetes nyelvi interface rendszer megteremtésének lehetősége, beleértve a természetes nyelv alkalmazásából származó pontatlanságok pontosítását, a többértelműségek kiszűrését, a hiányos információk kiegészítését, stb./Az emberi közbeavatkozás is emberi nyelven feltett kérdésekre választási alternatívákra adott válaszok formájában történhet./

Néhány adat arra vonatkozóan, hogy mennyire intenzív kutatómunka folyik Japánban egy /vagy több/ ilyen rendszer megteremtésére:

- Az 1982-ben Prágában megrendezett 9. Nemzetközi Gépi Nyelvészeti konferencián igen rangos mezőnyben az előadók 23 %-a japán volt /a társszerzőket nem számítva is 16 %/. /Egyedül az Egyesült Államokból volt több előadás; Japán után következett az NSZK, a Szovjetunió, Franciaország és Csehszlovákia./

- A Kyoto-i egyetemen kísérleti jelleggel ugyan, de rendszeresen folyik az INSPEC adatbázisából fizikai és matematikai témájú cikkek címeinek gépi fordítása, 93 %-os pontossággal, s egy japán nyelvű adatbázisrendszer gépi előállítására.

- Ugyancsak a Kyoto-i egyetemen implementáltak egy olyan rendszert, amely az elemzés hatékonyságának javítására nagy mennyiségű szöveg feldolgozásából tanulja a szabályok alkalmazásának optimális sorrendjét.

- 1978 óta sikeres kísérletek folynak Kyoto-ban egy LISP-nyelvű személyi számítógépre kialakított rendszerrel, amely egy egyszerűsített Montague-grammatika alapján elkészíti a lefordítandó angol mondat  $\lambda$ -kalkulusát, és ennek kiértékelésével létrehozza a mondat japán nyelvű fordítását.

- Az Osaka-i egyetemen japán szabadalmi bejelentések angolra fordítását végzik egy interaktív tanulórendszerrel, amely relációs adatbázisba gyűjti a kihámozott ismereteket, és hasznosítja a további feldolgozásnál. /A rendszer sebessége jelenleg 3 japán szó/mp./

- A Hitachi cég heurisztikus angol-japán fordítórendszer kifejlesztésén dolgozik. A prototípus rendszer egyelőre 10 ezer alapszót használ, ezekből felépített idiómáttárral és többszavas kifejezéstárral továbbá mintegy ezer számítógépes terminussal. A rendszer jelenleg haladó nyelvtanuló diákokkal veszi fel a versenyt számítógépes folyóiratcikkek fordításában, de remélik, hogy rövidesen eléri a szakértői szintet.

Az eddig elért eredmények fényében talán kevésbé tűnnek elérhetetlennek 1990-re a japánok által kitűzött célok:

- a gépi fordítás olyan szintű megvalósítása, amely 100 ezer szavas szótárral 90 %-os fordítási pontosságot ér el, és nyomdakész szöveget állít elő 70 %-os megtakarítással;

- a gépi beszédmegértés segítségével fonetikus "írógép" kifejlesztése, továbbá szöveges /írott vagy szintetizált/ válasszadás, és 50-60 beszélő azonosítása, 10 ezer szavas fonetikus szótárt használva az értelem elemzésre és a félrehallások kijavítására;

- a kérdés-válasz rendszerek olyan prototípusának létrehozása, amely 5000 szó és 10 ezer következtetési szabály alkalmazásával szakterületenként képes a felhasználók igényeit kielégíteni.

Az előadás konkrét példán mutatja be a japánok által alkalmazott egyik elemző-fordító módszert.

SIKBELI ÉS TÉRBELI PONTHALMAZOK STRUKTURÁLT TÁROLÁSÁNAK  
MATEMATIKAI ÉS SZÁMÍTÁSTECHNIKAI KÉRDÉSEI

Bevezetés

Tekintsük a következő kérdést: "Mennyi információ van egy gépkocsiban?". Azt hihetnénk, hogy erre a többszörösen határozatlan és sokszorosán pongyola kérdésre meg akkor sem lehet érdemleges választ adni, ha a gépkocsiba felejtett ismeretlen tartalmú aktatáskákat, újságokat és más egyéb információhordozókat már eleve kihagyjuk a számításból. Akadt azonban még 1959-ben valaki, aki a fenti kérdést csak kicsit pontosítva, de a vele kapcsolatos fogalmakat már nagyon absztrahálva, a gépkocsi ún. szerkezeti információtartalmának számításához meglehetősen egyszerű elemi összefüggéseket kapott. /Jacobson, H.: The information content of mechanisms and circuits. Information and Control. Vol.2. 1959. 285-296/ Ha ugyanis feltételezzük, hogy egy gépkocsi nem más, mint  $m_1$  darab  $l$ -es típusú,  $m_2$ -es és  $m_n$   $n$ -es típusú /ismert szerkezetű/ alkatrész célirányosan elhelyezett kombinációja, majd az egyes alkatrészeket súlypontjaikkal helyettesítjük, akkor gépkocsi helyett az előadás címében is szereplő olyan térbeli pontthalmazhoz jutunk, melyben az azonos típusú alkatrészeket azonos, a különbözőket színes pontok jelképezik. Jobb azonban, ha geometriai pont helyett egy-egy fizikai pontot /pl. egy kicsiny téglatestet/ képzelünk el minden alkatrész súlypontjában, hogy ezek megfelelő beállításával a szóbanforgó alkatrész térbeli tájékozását is szemléltetni tudjuk, hacsak nem akarunk mindenáron a hatdimenziós tér geometriai pontjaihoz fordulni. A szerkezeti információ bitekben kifejezett értékét végülis a színes pontthalmaz /alkatrészthalmaz/ összeszerelés előtti és összeszerelés utáni rendezetlenségi mérőszámainak különbsége fogja megadni.

Többszínű /vagy egyszínű/ pontthalmazok persze nemcsak gépkocsi-alkatrészekből szülehetnek és nemcsak arra valók, hogy valaki információtartalmukat kiszámítsa. A legkülönbözőbb mozgó vagy mozdulatlan térbeli objektumok alakjának, méretének, kölcsönös vagy abszolút helyzetének ismerete annyira fontos dolog, hogy az ún. geometriai modellezés, ill. a geometriai alrendszer csaknem minden adatbázis nélkülözhetetlen elemévé válik. A pontthalmaz-modell ez esetben az egyes objektumok geometriai jellemzőit kívánja kiemelni, minden egyéb, más tulajdonságát elhanyagolva. A geometriai modellezés egyik főkérdése: a pontthalmazok egyértelmű leírásához szükséges ún. helyzeti vagy koordináta-információ hatékony tárolásának és visszakeresésének elvi és módszertani tisztázása. Ehhez a feladathoz kívánunk majd előadásunkkal is hozzájárulni, szemelvényeket mutatva be az e téren végzett kísérleteinkből. A kérdéskör azonban annyi új és szokatlan probléma vizsgálatával jár együtt, hogy itt kénytelenek vagyunk csupán ezek felsorolására szorítkozni.

Az alábbiakban megpróbáljuk mondanivalónkat a címnek megfelelően két csoportra: matematikai és számítástechnikai kérdések csoportjára bontani, habár tisztában vagyunk azzal, hogy közöttük éles határvonal nem húzható, hiszen a számi-

tástechnika kis túlzással kísérleti, ill. gyakorlati matematikának, a matematika pedig a számítástechnika elméleti oldalának is tekinthető. Munkánkat gondolatébresztésre, vitára ingerlésre szántuk, ezt pedig csak úgy érhetjük el, ha nem kész, nem kerek, nem tévedhetetlenek tartott gondolatokat közlünk, hanem hipotéziseket, elképzeléseket vegyítünk tapasztalatokkal, kísérleti eredményekkel, véleményekkel úgy, ahogy az életben is mindig megelőzi, sőt kiváltja a fejlődést az alkotó fantázia, az óhaj, az igény és általában csak sokkal később követi a megoldás és a megvalósítás.

#### Matematikai kérdések, hipotézisek, tapasztalatok, vélemények és eredmények

1. Az információtartalom egy közlemény terjedelmének, hosszának alsó határa. Elméleti fogalom, de a gyakorlat számára megközelítendő és megközelíthető célt mutat, memóriahelymegtakarításra, sőt néha feldolgozási idő-csökkentésre is ösztönöz. Végtelen sok úton közelíthető meg, nyelvtől, kódrendszertől, mondanivalónk sorrendjétől teljesen függetlenül. Az a tény, hogy végtelen sok optimális nyelv létezik, még korántsem jelenti, hogy minden nyelv optimális. Csupán arra figyelmeztet, hogy nincs "egyedül üdvözítő út", nincs olyan "legjobb nyelv" /kódrendszer, számrendszer, koordinátarendszer, struktúra stb./, mely egyeduralomra tarthatna számot változó körülmények mellett is. Lehet, hogy adott viszonyok egyértelműsíthetik a választást, de a mai világban vagy a tervezett jövőben hol vannak, hol lesznek adott, változatlan viszonyok?

Egy térbeli ponthalmaz teljes információtartalmát felölelő leírás, közlemény hossza, memóriaigénye - optimális kódolás esetén - nem függ attól, hogy milyen /derékszögű, poláris, görbevonalú stb./ koordinátarendszert használunk, hogy a koordinátarendszert hogyan tájékozunk, hogy a koordinátákat milyen számrendszerben adjuk meg, hogy egy-egy pont rögzítéséhez egy, két vagy három koordinátát használunk, hogy differenciált vagy integrált tárolási strukturát alkalmazunk stb. Az optimális kódolás ugyanis egy olyan "csodaszter", mely minden ellentmondást fel képes oldani.

2. Ponthalmazok részére három alapeloszlás /alapstatisztika/ ismeretes. /Vilenkin, N.J.: Kombinatorika. Bp. 1971. 102./ Az egyenletes eloszlás és a függetlenség mindhárom alapfeltétele. A Maxwell-Boltzmann /vagy KK/ statisztika: különböző /vagyis egyedi azonosítókkal ellátott, például sorszámozott/ pontoknak ugyancsak különböző /koordinátájú/ ponthelyekre vonatkozó eloszlása, pontosabban az eloszlás sűrűségfüggvénye, melynél az ugyanazon ponthelyen lévő /azonos koordinátájú/ pontok számát semmi sem korlátozza. A Bose-Einstein /vagy NK/ statisztika: egyféle /egyedi azonosítóval nem rendelkező/ pontoknak különböző ponthelyekre vonatkozó eloszlása, ahol az azonos koordinátájú pontok mennyiségét az előbbi statisztikához hasonlóan semmi sem korlátozza. A Fermi-Dirac /vagy NK1/ statisztika: mint az előző, de egy ponthely legfeljebb egy pontot tartalmazhat, vagyis azonos koordinátájú pontokat nem tűrő eloszlás.

Fenti statisztikák a statisztikus mechanikában leggya-

koribb jelenségek általánosításaként születtek, és korántsem merítik ki az összes hasznos esetet. Kiegészítésül ide kíván-  
kozik még három statisztika. A KN-statisztika értelem szerűen  
a Bose-Einstein statisztika duálisa, melynél különböző pon-  
tok meg-nem-különböztetett ponthelyekkel kerülnek kapcsolat-  
ba minden megkötés nélkül. A KNL-statisztika esetében egy  
- egyébként ismeretlen ponthelyre - legfeljebb egy azonosí-  
tott pont kerülhet, vagyis semmivel sem ad több információt,  
mint mikor a pontok  $n$  és a ponthelyek  $m$  számát megadjuk, az  
NN-statisztika tartalma nem más, mint a ponthelyek gyakori-  
ságeloszlásának leírása a bennük lévő pontok darabszáma sze-  
rint.

A nagyszámú hasznos értelmezés és alkalmazás közül itt  
csak néhányat említünk meg. Az NK-statisztika a népsűrűség-  
térkép tartalmával egyenértékű, míg az NKL ugyanennek maxi-  
malista változata. A KN-statisztika pl. az egy helyen /közös  
lakásban/ élés relációjának leírására vagy a társtulajdonosi  
reláció megadására szolgálhat. A hatféle statisztika közül  
maximális információkapacitással a KK-statisztika rendelke-  
zik, mely pl. már egyedi /népesség-, lakás-, ingatlan- stb./  
nyilvántartásnak is alapjául szolgálhat. Az eddig még nem  
említett KKL-statisztika a KK azon maximalista megoldása,  
melynél a ponthelyek finomításával elérhető, hogy a nyilván-  
tartott személynek, dolognak, tárgynak külön-külön helye,  
címe, koordinátája legyen. Az NNL-statisztika tartalma sem  
többet, sem kevesebbet nem mond a KNL-nél, amennyiben a pon-  
tok azonosítása folyamatos sorszámozással történik.

Érdemes lenne a ponthalmaz-statisztikákat még tovább,  
olyan mélységig kiépíteni, hogy reális célként lehessen ki-  
tűzni: minden statisztikai nyilvántartás az egyre bővülő i-  
gény mértékében egyre inkább egyedi nyilvántartássá nőhessen  
át és fordítva. A lehetőségtípusok modellezése /a fenti  
nyolc alapstatisztika tovább-bővítése/ a "fix pontokat" rö-  
gzítené ehhez a munkához.

3. "Amikor a tizes számrendszerben felírt többjegyű  
szám értelmét magyarázni akarjuk, ezt polinom alakban szo-  
kás felírni. Ilyenkor a számot a 10 alapú hatványoknak egy-  
egy számjegyvel szorzott szorzatösszegeként állítjuk elő, a  
kisevők foggyó sorrendjében felírva. A polinomalakból úgy  
kapjuk meg a helyiértékes alakot, hogy a számjegyeket szoro-  
san egymás mellé írjuk, s minden mást elhagyunk. A polinom-  
alakot és a helyiértékes alakot összehasonlítva észrevehet-  
jük, hogy a tizes rendszerben leírt többjegyű számok valójá-  
ban három műveletet rejtnek magukban: összeadást, szorzást  
és hatványozást, ezeket pótolja a sorrend és az a megállapo-  
dás, hogy a hatványalap mindig 10. De a műveleti jelek hiánya  
ellenére itt valóságos műveletek szerepelnek." /Ruzsa I.: A  
matematika és a filozófia határán. Bp. 1968. 55./

Az algebrában az előjel, a zárójelek, a többjegyű szá-  
mokat szétválasztó szóköz, vessző, pont vagy pontosvessző  
mind-mind mellőzhetők, mivel ezek funkciója külön jel alkal-  
mazása nélkül is biztosítható, betölthető ahhoz hasonlóan,  
ahogy a többjegyű számok pozíciós írásmódjánál a ténylege-  
sen ki nem írt, de értelmezett helyiértékek, műveleti jelek  
- fenti idézet szerint - hallgatólagosan értelmezhetők. Így

jönnek létre a sign-free /előjel-mentes/, bracket-free /zárójel-mentes/, comma-free /változó kódhosszúságú/, coordinate-free /koordináta nélküli/ stb. rendszerek. Azt a tényt, hogy minden sokjegyű szám egy-egy fastruktúra, fordítva is lehet értelmezni, vagyis minden fastruktúrát egy-egy sokjegyű számmal lehet kódolni. Ez a megállapítás akkor is érvényes, ha a fastruktúra egy egész ponthalmazt kíván ábrázolni, sőt akkor is, ha pontok helyett más geometriai alakzatok /pl. egyenes szakaszok, egyszerű síkidomok vagy térbeli alakzatok/ szerepelnek.

Megtehetjük például azt is, hogy a fastruktúra pontonkénti /és nem - ahogy szokásos - koordinátánkénti/ összeállítására előtt a sík vagy a tér pontjait a közöttük értelmezett geometriai vagy vektorműveletekkel együtt homomorf módon leképezzük a számegyenesre. A sokjegyű szám képzése ezután ugyanugy történhet, mint valódi skaláris számok esetében. De eljárhatunk úgy is, hogy a síkot vagy teret közvetlenül paraktázzuk /azaz számsíkot ill. számsíkot hozunk létre/ és skaláris mennyiségeket vagy koordinátákat egyáltalán nem használunk.

"Maguk a matematikai és logikai törvények sem immunisak a revízióval szemben, ha egész fogalmi sémánk lényeges egyszerűsítése válik azükségesé. Így a matematika és a logika törvényei minden "szükségyszerűségeik" ellenére hatálytalaníthatók." /Quine, W.O.: A logika módszerei. Bp. 1968. 18-19./

Számítástechnikai kérdések, tapasztalatok, lehetőségek, vélemények és eredmények

1. Egy ponthalmaz információtartalmát sokféleképpen írhatjuk le. A leírás módszerétől függetlenül minden esetben pontok és ponthelyek viszonyát adjuk meg többé vagy kevésbé áttekinthető formában. A hagyományos leírásnak két - egymással ellentétes, de egymást kiegészítő - alaptípusa a következő. A "mi-hol-van" nyelv mindegyik mondata egy-egy pont helyzetét egy vagy több koordinátával /ponthely-sorszámával/ adja meg, ezért a leírás hossza a pontok számával és a ponthelyek számának logaritmusával arányos, azonban a pontok /egyedi vagy csoportos/ azonosítóinak számától független. A "hol-mi-van" nyelv mindegyik mondata egy-egy ponthely tartalmát a pontok azonosítóival adja meg, ezért a leírás hossza a ponthelyek számával és a pontazonosítók számának logaritmusával arányos, azonban a pontok számától független.

Ha semmit sem tudunk a ponthalmazról, akkor a fenti leírások mellett még bizonyos rendszerparamétereket /eloszlások sűrűségfüggvényeit stb./ is tárolni szükséges, és pedig másokat az első és másokat a második nyelv esetében. Ezek figyelembevételével igazolható - ami egyébként az információakkumuláció alaptörvényéből is következik -, hogy a kétféle nyelven megfogalmazott ponthalmaz-leírás információ-tartalma pontosan egyenlő, ennél fogva optimális kódolás /optimális azonosító- és koordinátarendszer/ esetén a közlemény hossza is közel egyenlő kell legyen. A gyakorlatban kialakult eljárások azonban messze esnek az optimumtól, ezért e két nyelv hatékonysága is erősen különbözik.

A "mi-hol-van" nyelv a geodézia, a "hol-mi-van" nyelv

a kartográfia évszázadok óta használt nyelve. Volt idő tehát megmerevednie. Egyébként is a memóriahellyel való takarékosság a számítógépek megjelenése előtt a papírral való takarékosságot jelentette, és hol van az a hivatal, amelyik a papírral takarékoskodik? Az igazat megvallva, a kartográfia esetében nem is szabad a papírral takarékoskodni, mert ez általában csak a szemléletesség, a kifejezőkészség kárára történhet. De vajon helytálló-e ez a megállapítás a digitális papír, a számítógépmemória, a digitális térkép esetében?

Lehet a memóriát digitális számítógép esetében is "rajztáblának" tekinteni, és az analitikus vagy koordinátageometria számítási módszerrel helyett ábrázoló geometriai eljárásokat, szerkesztéseket alkalmazni. /Frolov, Sz.A.: Kibernetika i inzsenernaja grafika. 2. kiad. Moszkva. 1974. / Ilyenkor a pontthalmazt és az ugyancsak pontthalmaznak tekintett egyenes vagy görbe vonalakat két /esetleg három/ dimenziós logikai tömbként tárolják, ahol az egyes pontokat zérus háttérben elhelyezett 1-es számjegyek /logikai értékek/ képviselik. Különböző színű vagy színfokozatú pontok esetén már aritmetikai tömbre és kettőnél több kódszámra van szükség. A grafikus képernyők és a grafikus tervező rendszerek megjelenésével az ábrázolás fenti módja terjed, sőt a képfeldolgozásban input nyelvként csaknem egyedüli, output nyelvként is nagy jelentősége van.

A rajztáblán ábrázolt pontok, vonalak mögött lévő háttérszint /vagyis az üres papírt/ csaknem teljes egészében meg lehet takarítani, ha az előbb tárgyalt "hol-mi-van" nyelvről a "mi-hol-van" nyelvre térünk át. Előbbinél ugyan a szükséges memória mértéke csak a ponthelyek számától függ és a pontok, vonalak mennyiségétől független, míg utóbbinál fordított a helyzet: a memóriai igény a pontok számával egyenesen arányos. Azok a külföldi és hazai tapasztalatok, amelyek nagyterjedelmű pontthalmazokkal, ill. az azokban lévő nagyszámú /millió nagyságrendű/ pontokkal végzett kísérletekből származnak, azt mutatják, hogy a fenti két alapszint mind hatékonyság, mind kezelhetőség szempontjából szélsőségesen rossz tulajdonságú. Közös hibájuk, hogy struktúrátlanok és hogy a pontthalmazok információs strukturájához nehezen illeszthetők. Ezért a gyakorlatban gombamódra fejlődtek ki az olyan kompromisszumos nyelvek, melyeknél a társzükséglet sem a ponthelyek, sem a pontok számával nem arányos, de nem is független tőlük. A síkban a 4-es fa /quadtree /, térben a 8-as fa /octtree/ a legkézenfekvőbb megoldás, mindkettőnél igaz, hogy a tárigény a ponthelyek ill. pontok számának csak a logaritmusával arányos. Mi a 9-fa és a 27-fa megoldást részesítve előnyben, ezekhez fejlesztettük ki az ún. nanovektoriális ill. alfa-vektoriális /koordinátamentes/ síkbeli ill. térbeli szárendszereinket és ezekben végeztünk struktúrált pontthalmaztárolási kísérleteket.

2. Ahogy az anyag jelenléte befolyásolja a tér geometriai szerkezetét, úgy kell hogy befolyásolja egy-egy új pont bevonása vagy régi elhagyása a pontthalmaz "koordinátajegyzékének" nemcsak a hosszát /sorainak számát/, hanem maguknak a koordinátáknak a szerkezetét, számszerű értékét is. A befolyás persze lokális kell legyen, mely alatt azt értjük,

hogy a változás helyétől távolodva, a változás hatásának statisztikai értelemben egyre inkább gyengülni kell. Einstein tanítása szerint anyag tér nélkül és tér anyag nélkül nem létezik, hisz a tér az anyagnak egy bizonyos vonatkozású absztrakciója. Az is következik ebből, hogy kisebb anyag kisebb, nagyobb méretű pedig nagyobb teret kíván. Ettől függetlenül azonban adathordozó adat nélkül, ill. adat információ nélkül nagyon jól elképzelhető, sőt az is igaz, hogy nagy adathordozón a kevés adat is elfér, hisz "az információ sem nem anyag, sem nem energia ..." - mondaná Wiener Norbert. Azonban ez esetben Einsteinnek van igaza Wiener Norberttel szemben. Lehet ugyanis olyan véges koordinátarendszert /véges teret/ szerkeszteni és a gyakorlatban előnyösen alkalmazni, melynek információkapacitása a benne ábrázolt pontok információigénye szerint változik. Ha például egy újabb pont valamelyik régebbi pont közelében születik meg, kevesebb teret, vagyis információt kér maga számára, mint az, amelyik távolabb lát napvilágot. Ez teljesen érthető is azok számára, akik sohasem tanultak geodéziát és nem fertőzte meg őket a maradiság szelleme /Taylor, E.F.-Wheeler, J.A.: Tér-idő-fizika. Bp. 1974. Mese a földmérőkről c. fejezet/, hisz a közelebbi pontot kevesebb számjegyből álló koordinátával lehet bekapcsolni a legközelebbi régi ponthoz, mint a távolabbit. Az ilyen "anarchikus"nak nevezett megoldást azonban utasítások és szabályzatok tiltják még a számítógép részére is, márpedig változtatási szabadság nélkül sose lesz "rend" az "anarchiából". Mert tudvalevő dolog, hogy csak addig anarchia a "káosz", amíg szük-ségességét fel nem ismerjük és el nem ismerjük, de felismerése és elismerése után a káoszt anarchia helyett rendnek nevezük. A gondolatmenet tanulsága: az anyag és a tér viszonyát még tudati szinten, koordinátarendszerek tervezésénél és üzemeltetésénél sem szabad megsérteni.

A dolgok belső logikáját bántjuk meg azzal, ha a sikot nem sikkal és a teret nem térrel, illetve az eseményeket nem eseményekkel mérjük. A terület, a térfogat ill. az űrtartalom-mérés jól bevált mértékegységei követendő példát szolgáltatnak a korszerű helymérés azaz helymeghatározás struktúrájára, sőt ennek kialakítása érdekében közvetlenül általánosíthatók. Ugyanis a terület- és térfogatmérés szokásos formáját /struktúráját/ változtatlanul átvéve, csupán információtartalmának gazdagításával egy objektum területén és térfogatán kívül annak alakját, méretét, helyzetét stb. egyetlen sokjegyű számmal integrált módon le lehet írni.

A meglévő rendszerekkel szembeni aggályainkat az alábbi kérdésekben foglaljuk össze:

Mennyire takarékos egy olyan rendszer /antilakótelep vagy antitemető/, ahol egy nemlétező /még meg sem született vagy már elpusztult/ pont számára is /azaz hazánk minden négyzetcentiméternyi darabkájára/

ugyanannyi számjegyből álló koordinátapár ill. -hármas van fenntartva /tartálékolva/, mint a létező /élő/ pontok számára?

Mennyire gazdaságos egy olyan rendszer, ahol az igen gyakran használt pontok számára is

ugyanannyi számjegyből álló azonosítók, sorszámkok vannak használatban, mint az igen ritkán használt



pontok számára?

Mennyire illeszített egy olyan rendszer információ- és adatstruktúrája, ahol geometriai azonosítók gyanánt kicsiny objektumok esetében is

ugyanannyi számjegyből álló geokódot terveznek, mint az igen nagy objektumok esetében?

Mennyire következetes egy olyan rendszer, ahol skalár, vektor ill. mátrixmennyiségek kódolásához nem a legtermészetesebb megoldást: skalár, vektor ill. mátrix számjegyeket alkalmaznak, hanem még a számítógépek korában is

ugyanazon skalár számjegyekből alkotott, megkövesedett skalár számrendszerekhez ragaszkodnak?

### Befejezés

Korunkban nem feltétlenül az az igazi tragédia, ha az ember olyan valamit akar, ami eleve lehetetlen. Épp ellenkezőleg: az, ha olyasmit akar, ami eleve lehetséges. Éspedig azért, mert a lehetséges többnyire nem más, mint elfogadott szabvány, futószalagon gyártott tömegcikk, nincs belőle testre és lélekre szabott méret, egyetlen konkrét igényt sem elégít ki. Ezért nem lehet igazán rendeltetésszerűen használni. És ahelyett, hogy a lehetetlen /értsd: ez idő szerint lehetetlen/ elérésére sarkallana, olykor még a lehetséges utáni vágyat is kiontja. Holott a lehetetlen akarása nélkül éppenséggel lehetetlen az a valami, aminek közkeletien haladás a neve.

Ezért a realizmus csak a megalkuvók, a maradiak értelmezésében lesz azonos a fennálló elfogadásával. Mert aki a fennállót elfogadja, az az adott valóságot tiszteli, másszóval "megkövült véleményeket" tisztel. A valóság azonban minden alkotó számára a lehetőség határán túl kezdődik, ezért a realizmus nem más, mint tisztelet helyett irónia.

Nagy állami nyilvántartásaink nemcsak tudománytalanok, hanem egyenesen tudományellenesek. A kivételek igen ritkák. A bevallott /deklarált/ célkitűzések és a helyi, csoportérdekek között a dilatáció egyre mélyül, és ezt a végtermékek is erősen megsínylik. A korszerűsítést legtöbbször a forma kicserélésével hajtják végre és jó, ha a tartalom megmarad. Rosszabbik esetben ugyanis a formaváltás a tartalom rovására történik. Néha csak a cégtáblát cserélik ki "adatbázis"-ra - mint pl. az ingatlan-nyilvántartásnál - de a régi forma, régi tartalom megmarad, ill. megmaradna, ha különféle ürügyek címén - gépi, anyagi, személyi korlátok - tovább nem szegényedik. Csak rá kell nézni egy 50-100 évvel ezelőtti térképre és egy korszerűnek nevezett mai-ra; a pontosságromlás ill. -rontás mellett a tartalom szegényesége mindenki számára nyilvánvaló. A tudomány öntörvényű fejlődése persze akkor sem szakad meg, ha a pragmatikus gyakorlat teljesen figyelmen kívül hagyja, viszont a mulasztások halmozódása végső soron súlyos lemaradáshoz vezet.

Nyilvántartásaink másik rákfenéje az egység, egységesség fogalmának hamis, káros értelmezése. Mielőbb vissza kellene adni ezeknek eredeti, hasznos értelmezésüket. "Harcolni kell az ellen, hogy mindent egy kaptafára húzzunk, és harcolni kell minden olyan kísérlet ellen, amely felülről akar egyformaságot bevezetni. ... Az egységet az alapvető, a fontos, a lényeges kérdésekben nemcsak nem zavarja, hanem biztosítja a változatoság a részletekben, a helyi sajátosságokban ..." /Bozsik V.: Emberszabású szervezet. Bp. 1983. 7./

MICRO - SHIVA  
NÉHÁNY MIKROGÉPES ADATFELDOLGOZÁSI ESZKÖZ  
ISMERTETÉSE

E dolgozatban néhány mikrogépalkalmazási tapasztalat felvázolása mellett bemutatunk egy konkrét mikrogépes adatfeldolgozási rendszert /micro-SHIVA/. Tapasztalataink elsősorban egészségügyi információs rendszerek köréből származnak /1-3, 5, 6/, de más mikrogépes fejlesztésekre is hivatkozhatunk /4,7,8/.

A mikrogépes adatfeldolgozás - és általában a mikrogépfelhasználás - a személyes hozzáférhetőség miatt lényegesen különbözik a hagyományos számítógépfelhasználás módjától. Éppen ezért a mikrogépfelhasználás módjától. Éppen ezért a mikrogépfelhasználók számára a klasszikus számítástechnikai eszközökön túl olyan lehetőségeket kell létrehozni, amelyek kihasználhatóvá teszik a személyes gépfelhasználás előnyeit, figyelembe véve a jelenleg elérhető mikroszámítógépek kis kapacitását.

A szerzők által fejlesztett Micro-SHIVA rendszer /mikrogépes Sokoldalú, Hatékony, Intelligens, Vizualis Adattár/, ezeknek a szempontoknak a figyelembevételével készült.

Fő célkitűzéseink a következők voltak:

Olyan rendszert kívántunk létrehozni, amely különböző számítástechnikai ismeretek nélkül is biztonságosan kezelhető. Ugyanakkor az ember-gép kapcsolat lehetőleg egyszerű és gyors legyen. Emellett arra is törekedtünk, hogy a kis gépkapacitásból - viszonylag kis sebesség, kis térkapacitás - adódó hátrányokat semlegesítsük.

1. A kényelmes és biztonságos munka támogatása

A munka hatékonyságának egyik legjobb biztosítója egy "vizuális ember-gép kapcsolat" lehet. A felhasználó és a számítógép kapcsolatát jól áttekinthető, képernyőre vetített formátumok /adatlapok, táblázatok, ábrák/ segítik. Ha ezek a formátumok "full screen" módban kezelhetők, akkor egy valóban dinamikus ember-gép kapcsolat eszközeivé válhatnak.

## Néhány példa:

Az adatfeldolgozás egyik legfontosabb momentuma az adatok gépre vitele. Ha az adatok nem valamilyen közvetlenül gépre vihető formában jönnek létre, akkor legcélszerűbb, ha az adatokat szolgáltató személy - pl. kódlapok kitöltése helyett - közvetlenül egy a képernyőre vetített "kódlapra" viszi az adatokat. Így közvetlenül részt vehet a gépi feldolgozásban, ami az adatszolgáltatás pontosságát, értékét nagymértékben növeli.

Ugyanugy egy rendszer futtatása, az elvégzendő feladatok kijelölése is segíthető. Egy bonyolult feltételrendszer kijelölése és a számítógép számára történő pontos leírása igen munkaigényes és sok hibalehetőséget magában rejtő feladat. Ha azonban ez egy jól áttekinthető adatlapnak /képernyőn történő, ellenőrzött/ kitöltésével történik, akkor a feladat nagymértékben leegyszerűsödik.

Egy számítógép feldolgozásban szereplő adatok megjelenítéséről /printer, képernyő/ is fontos szempont a megfelelő, könnyen kezelhető formátum biztosítása. Képernyő esetén ez a formátum mozgását, a képernyőnél nagyobb méretű formátumon történő navigálást is szükségessé teszi.

A felsorolt célok érdekében létrehoztunk egy képernyőformátum szerkesztő és megjelenítő rendszert. Ez a Micro-SHIVA egyik alapvető eleme. A képernyőszerkesztő alrendszer egy full screen editor, amely adatmezők kijelölését is lehetővé teszi. A megszerkesztett és lemezen tárolt képernyőformátum felhasználását, a formátumon keresztül megvalósuló ember-gép kapcsolat létrehozását egy formátummegjelenítő alrendszer biztosítja. Ez teszi lehetővé az ellenőrzött adatbevitelt, a futtatási feltételrendszerek - szintén ellenőrzött - leírását, a tárolt adatok megjelenítését.

## 2. A hatékony működésmód biztosítása

Az ember-gép kapcsolat hatékonyabbá tétele mellett a számítógép működés hatékonyságának fokozása is fontos cél. A mikrogépek központi egységének viszonylag kis sebessége személyes használat esetén elfogadhatóvá válik, ha gépi kódra fordított programokat használunk. Kritikusabb kérdés a szokásos floppy háttér kis sebessége és kis kapacitása. A kis átvételi sebesség miatt - ha gyors működést kívánunk elérni - le kell mondanunk a bonyolultabb file-szervezési lehetőségekről.

Egy másik szűk keresztmetszetet a floppy lemezek kis tárkapacitása. /A több Mbyto-os hajlékony lemezek és a winchester táruk jelenleg még nem hozzáférhetők./ A kisteljesítményű olcsó mikrogépeknél néhány száz kbyte háttérkapacitással kell számolni. Különösen fontosá válik így a tömör adattárolás.

A Micro-SHIVA rendszerben a gyors működés érdekében a programok Z80 assemblerben készültek. A file-kezelést leegyszerűsítettük, kulcstáblázatokat csak a memóriában tárolunk. A tárterület optimális kihasználása érdekében intenzív adattömörítést alkalmazunk. Ez a tömörítés adatfüggő. Az adat típusától és értékétől függően más és más módon történik.

### 3. Összetett rendszerek problémái

A kiskapacitású floppy tár hátránya talán a több file-os /egy lemez terjedelmét meghaladó/ rendszerek-nél mutatkozik meg a legjobban. A terjedelmes rendszerek feldolgozása megoldható az adatbázis több lemezen történő elhelyezésével úgy, hogy egy-egy munkafázishoz szükséges adatok egyidejűleg elérhetők legyenek. Meg kell azonban szervezni a nem egyidejűleg elérhető adatbázis-részek módosításainak szinkronizálását. A micro-SHIVA egy központi adatnyilvántartó file segítségével biztosítja a változók szükséges átvitelét a különböző adatbázis-részek között. Így lehetővé válik, hogy egymástól független felhasználók, különböző időpontokban bevitt adatai valamennyi /illetékes/ felhasználó számára hozzáférhetők legyenek.

### Hivatkozások

1. Alexits Gy., Kerékfy, P., Rákóczi F., Ruda M., Egy többkomponensű kardiológiai gondozási rendszer megvalósítása kisteljesítményű mikroszámítógépen. I. Egészségügyi Informatikai Vándorgyűlés, Szekszárd, 1983. május 5-6.
2. Hannák L., Kovács K., Lengyel T., A personal computer alkalmazási lehetőségei a kórházi adatnyilvántartásban és egyéb egészségügyi területeken. 10. Neumann-kollokvium, Szeged, 1980. Előadás kivonatok, 77-84.

3. Kerékfy P., Ruda M. Mikrogepek alkalmazása kórházi és rendelõitnézeti információs rendszerekben /megjelenõben/. 11. Neumann-kollokvium, Szeged, 1982. dec. 6-8.
4. P. Kerékfy, M. Ruda: Microcomputer Application in Data Processing Systems, 8 th Winterschool of Operating Systems, Visegrád, 1983. jan. 31-febr. 4., Abstracts, p. 18.
5. P. Kerékfy, I. Ratkó, M. Ruda, Microcomputer-Based Medical Information Systems, MEDINFO 83, Amsterdam, 1983. aug. 21-26.
6. P. Kerékfy, M. Ruda, Medical Information Systems on Desktop computers, Conference on Computer-Based Information Servicing, Várna, 1983. okt. 3-8.
7. Kovács K., pDMS mikroszámítógépes adatbáziskezelõ rendszer, II. Neumann Kongresszus, Székesfehérvár, 1983. nov.
8. Lengyel T., A MEDICOR kötés- és terméknilyvántartási rendszere a HP85A professzionális personal computeren, II. Neumann Kongresszus, Székesfehérvár, 1983. nov.

Ungár János  
VIDEOTON Elektronikai Vállalat  
Számítástechnikai Gyár  
Fejlesztési Intézete (VFI)

Szoftver eszközök adatbázis kezelő rendszerek megbízhatóságának  
javítására és adatai integritásának megőrzésére

Tartalom:

1. Bevezető
2. Párhuzamos program futtatás
- 2.1. Zár mechanizmus
- 2.2. Kölcsonös kizárás felfedése
3. Ujraindítás
- 3.1. Adatbiztonsági naplózás
- 3.2. Visszagörgetés, hideg és meleg ujraindítás
4. Hivatkozások

1. Bevezető

Valamely számítástechnikai rendszer megbízhatóságát meghatározhatjuk a berendezéseknél, készülékeknél szokásos módon: azaz úgy, hogy mennyire folyamatosan képes nyújtani a felhasználó által elvárt szolgáltatásokat /1./.

Az adatbázis kezelő rendszerek (ABKR) legjellemzőbb sajátága, hogy egy szervezet teljes - általában igen nagy értéket képviselő - adat erőforrását teszik hozzáférhetővé a szervezet valamennyi érdekelt felhasználója számára.

Nyilvánvaló, hogy ezért az ABKR-től a felhasználók magasfoku megbízhatóságot várnak el.

Már az ABKR tervezésekor nagy figyelmet kell szentelni a megbízhatósági kérdéseknek. Számba kell venni a lehetséges hibákat, előfordulásuk gyakoriságát, kezelésük lehetséges módzatait.

Csak kellően megbízható hardverre és alapszoftverre /2.2/ szabad ABKR-et felépíteni.

Az ABKR szerkezetét úgy kell megválasztani, hogy az alkalmas legyen a megbízhatósági követelmények kielégítésére (pl. program és adat redundancia) /1./

Itt kell megemlíteni, a teljesség kedvéért, hogy a megbízhatóságnak része a programok helyessége is.

A továbbiakban kizárólag az ABKR szoftverének sajátos megbízhatósági igényeiről lesz szó.

A megbízhatósági követelmények nagy mértékben függenek attól, hogy egyidejűleg egy vagy több felhasználó dolgozik-e az adatbázison, és hogy kötegelte vagy tranzakciós üzemmódban történik-e a feldolgozás.

Különös figyelmet érdemel a megbízhatósági szempontból legkényesebb többfelhasználós tranzakciós üzem, amely egyre inkább előretör az ABKR alkalmazásában.

Az ABKR legfontosabb megbízhatósági kritériuma az adatok épségének fenntartása.

Az adatok épségével kapcsolatban a következő meghatározásokra lesz szükség:

Az adatok "helyes" állapota azt jelenti, hogy az adatbázis a legfrissebb adatokat tartalmazza, és törlött adatok már nincsenek benne.

Ennél szűkebb fogalom a "konzisztens" állapot, ami eltér az ép állapotéhoz képest bizonyos adatvesztést, de megköveteli a felhasználói (1) konzisztencia feltételek teljesülését /3./.

Az adatok még helyes felhasználói programok futtatása esetén is megsérülhetnek, ha párhuzamosan futó programok azonos adat egyedeken írási ütközésbe kerülnek, illetve ha valamilyen hiba következtében a program vagy az ABKR működése félbeszakad.

Az ABKR-nek tehát kezelnie kell a párhuzamos programfuttatásból származó ütközéseket, és képesnek kell lennie arra is, hogy a félbeszakadt program vagy üzem az adatok épségének kézbentartásával újraindítható legyen.

A párhuzamosság és az újraindíthatóság problémaköre tehát az adatok épségének megővésán keresztül szorosan kapcsolódik egymáshoz, és így tervezésüket is össze kell hangolni.

A továbbiakban szeretném röviden bemutatni a két problémakört, és algoritmus választást javasolni kisszámítógépes esetre.

## 2. Párhuzamos programfuttatás

Ha egy felhasználói program egyedül és hibátlanul lefut, akkor az adatbázist konzisztens állapotból konzisztens állapotba viszi át.

Ha azonban nem egyedül fut, összeütközésbe kerülhet más programokkal, amelyek ugyanazon adat objektumot érik el, és legalább egyikük írni kíván.

Ilyenkor a műveletek között tisztázatlan versenyhelyzet alakulhat ki, ami a következő konzisztencia sérülésekre vezethet:

Írás- olvasás ütközéskor nem lehet tudni, hogy az olvasó a módosítás előtt, vagy utáni értéket kapta-e meg.

Írás-írási ütközéskor pedig csak az utolsó módosítás jut érvényre, a korábbiak elvesznek.

Szükség van tehát valamilyen ütemezőre, amely gondoskodik arról, hogy a programok párhuzamosan, átlapoltan futva se sérthessék meg a konzisztenciát, azaz a soros futással egyenértékű eredményt adjanak.

Az ütemezésnek két alapvető módszere van: a zár /4./ és az időbélyeg /5./ kezelés, de javasoltak egyes megoldásokat is /6./.

A zár módszer lényege a következő:

A programnak írási, illetve olvasás előtt az elérni kívánt adat objektumra írási, illetve olvasási zárat kell kérnie. Az ütemező a zárat csak akkor adja meg, ha az nem ütközik a már megadott zárral, ellenkező esetben a program az illető adatobjektumhoz rendelt várakozási sorba kerül.

Az ütemező csak akkor működik helyesen, ha a program az első zár felszabadítási művelet után nem kér több új zárat (kétfázisú zár) /4./.

A zár módszernek az a legnagyobb előnye, hogy a zár szorosan kapcsolódik az általa védett adat objektumhoz.

Ez lehetővé teszi az ütközések pontos felfedését, és ezen keresztül a lehető legmagasabb fokú párhuzamosság elérését.

Hátránya a zármódszernek a költsönös kizárás lehetősége, azaz előfordulhat, hogy programok egymás által lefoglalt adat objektumokra kérnek zárat.

Az időbélyeg módszer lényege abban áll, hogy az ütemező a programokat indulásukkor szigorúan monoton növekvő számozással látja el - ezt a számozást az órához szokás kötni -, és az ütköző műveleteket a számozás sorrendjében engedí érvényre jutni /6./.

Az időbélyeg módszernél költsönös kizárás nem fordulhat elő.

Komoly problémát jelent viszont, az ütközések felfedése. Az erre a célra publikált algoritmusok (pl. SDD-1) igen bonyolultak, az alkalmazási tapasztalat még kevés.

Az időbélyegek tárolása és kezelése súlyos többletterhet ró a rendszerre.

Kisszámítógépes rendszereknél ezért véleményem szerint a zármódszert érdemes alkalmazni.



## 2.1. Zár mechanizmus

A párhuzamos program futtatás tehát a kétfázisú zár algoritmusra épül.

Az algoritmus könnyen kiterjeszthető elosztott ABKR-re is, de ilyenkor a többszörös előfordulású adatokra bizonyos kiegészítéseket kell bevezetni /6./.

Az algoritmus kényes pontja a záruk hatóköre, azaz az általuk védett adat objektum nagysága.

Kis hatókör a záruk tulszaporodására vezethet, nagy hatókör pedig csökkentheti a párhuzamosságot.

Érdemesnek látszik többféle hatókörü zár alkalmazása (rekord, állomány, stb.), így a felhasználói programok tervezésekor a lehető legkedvezőbb választódót lehet elérni.

A különféle hatókörü záruk hierarchiája ugyancsak kihasználható /7./.

A záruk alkalmasak arra is, hogy sérült adatbázis részt a teljes helyreállításig védjenek, lehetővé téve ezáltal más, ép részek elérését, a csökkentett értékű szolgáltatás folyamatosságát.

## 2.2. Kölcsönös kizárás felfedése

Az ABKR-re az a jellemző, hogy a programok által igényelt adat objektumok meghatározása nem a programok indulásakor, hanem futás közben történik /8./.

Igy nincs mód a kölcsönös kizárás megelőzésére, vagy elkerülő stratégiák alkalmazására.

Marad tehát a felfedés és feldolgozás.

Kölcsönös kizárás felfedésére egyszerű, elosztott esetre is kiterjeszhető algoritmus létezik.

Fel kell venni a rendszer egynevezett állapot gráfját. A gráf csomópontjai a programok és az adat objektumokat képviselő erőforrások. Ha egy erőforrás egy programé, az erőforrás csomópontból élet vezetünk a program csomópontjába. Ha egy program egy erőforrásra vár, élet vezetünk a program csomópontjából az erőforrásba.

Könnyen belátható, hogy ha az irányított gráfban gyűrűt találunk, akkor ez kölcsönös kizárást jelent.

A kölcsönös kizárást úgy oldhatjuk fel, hogy a gyűrűben levő valamelyik programot visszagörgetjük, azaz módosításait töröljük.(ld.3.2.), és

lefoglalt adat objektumait felszabadítjuk.

A vizsgálgörgetendő áldozat kijelölésére sokféle módszer született: a legkisebb költséggel visszagörgethető, a legfiatalabb (időbéllyeg módszer), a legalacsonyabb prioritásu program, stb.

Az áldozat ujraindítása lehet az ABKR vagy a felhasználó (operátor) feladata.

### 3. Ujraindítás

Ha valamely program vagy az egész rendszer futása hiba következtében (feszültség kimaradás, hardver vagy szoftver hiba, kölcsönös kizárás, stb.) félbeszakad, a program vagy a teljes rendszer futását úgy kell ujraindítani, hogy az adatok épsége közben tartható legyen.

Az adatok épsége a legtöbb esetben elsőbbséget élvez a szolgáltatás folyamatosságával szemben, azaz el kell fogadni az adatok helyreállításával kapcsolatos többletterheket. Kívánatos, hogy a helyreállítás a lehető legkevesebb adatvesztéssel járjon.

Nagybiztonságú ABKR-től elvárható, hogy a helyreállítás konzisztens állapotot eredményezzen.

Egy program az adatbázis konzisztenciáját definíció szerint megörzi.

Ez azt jelenti, hogy a programnak vagy valamennyi módosítása érvényes, vagy egyetlen egy sem (kétfázisu módosítás). A félbeszakadt programnak tehát valamennyi módosítását törölni kell.

Előfordulhat azonban, hogy a program által módosított adat egyedet közben valamely másprogram is kiolvasta, vagy akár módosította. Ennek az lesz a következménye, hogy az utóbbi programot is törölni kell, és a dominó hatás miatt egyre tetemesebb adat veszteség léphet fel.

Az utemezőnek tehát az ujraindítási követelményeket is figyelembe kell venni /7./!

A dominó hatást kiküszöbölhetjük úgy, hogy előírjuk, hogy ha egy program módosított egy adat objektumot, akkor ezt az adatot más program a módosított program befejeztéig ne módosíthassa.

A zár módszernél ez azt jelenti, hogy írási zár csak a program végén szabadul fel.

Igy is előfordulhat azonban, hogy valamely program olyan adatot olvas, amelyet később más program módosít.

Ennek viszont az a következménye, hogy az ujraindíthatósághoz a rendszer futása közben rendszeresen ellenőrző pontokat kell felvenni.

Ujraindítások vissza kell dolgozni mindazokat a programokat, amelyek a hibás pillanatában, az utolsó ellenőrző pont óta, vagy éppen az ellenőrző pont felvételekor futottak, és újrafuttatni mindazokat, amelyek a hibás

előtt befejeződtek.

Mindez feleslegessé válik, ha azt is megköveteljük, hogy ha egy program beolvasott valamely adat objektumot, akkor azt más program az olvasott program befejeztéig ne módosíthassa.

A zár módszernél ez ugy biztosítható, hogy olvasási zár sem szabaddítható fel a program végéig.

Ezzel a programokat tökéletesen elszigeteltük egymástól, visszagörgetésük egymástól független, és ellenőrző pontok felvételére sincs szükség.

Az előbbieken vázolt újraindítási követelményeket az ismert újraindítási módszerek közül a legteljesebben az adatbiztonsági naplózás elé-gíti ki /3./.

### 3.1. Adatbiztonsági naplózás

Az adatbiztonsági naplót a visszagörgetés, illetve az újraindítás használja fel.

Tartalmaznia kell a program indításokat és befejeződéseket, a zár műveleteket, és az adatbázis módosításokat.

A módosításokat a módosítás előtti és a módosítás utáni mágneslemez kép írja le.

Az előbbire a visszagörgetéshez, az utóbbira a lemez helyreállításához van szükség.

Ha a programokat egymástól teljesen elszigeteltük, akkor a módosítás előtti lemez képekre csak a program indításától annak sikeres befejezéséig, vagy visszagörgetéséig van szükség. Tárolásukra legmegfelelőbb a mágneslemez (elérési idő, adatmennyiség).

A megbízható ABKR-nek fel kell készülnie fizikailag sérült lemez helyreállítására is.

Erre két módszer kínálkozik. Az első az, hogy az új lemezre korábbi, konzisztens állapotú (általában mágnesszalagos) mentést töltünk, majd felvisszük rá az azóta végzett módosításokat a módosítás utáni lemezképek alapján.

A módosítás utáni lemezképekre tehát két adatbázis mentés között akár-mikor szükség lehet. Általában nagytömegű adatról lévén szó, tárolása mágnesszalagon történhet.

A másik módszer a lemez egységek és az adatok fizikai megkettőzése, és a módosítások folyamatos vezetése mindkét adat példányon. Ekkor a helyreállítás lemez másolásra redukálódik, a módosítás utáni lemez képek naplózására nincs szükség.

### 3.2. Visszagörgetés, hideg és meleg újraindítás

Visszagörgetést kezdeményezhet maga a program, ha például a gyűjtött adatokban inkonzisztenciát észlel, de kérhet visszagörgetést az ütemező is, pl. kölcsönös kizárás feloldására. Visszagörgetésre van szükség újraindításkor is, sőt a programok teljes elszigetelése a "meleg" újraindítást a hiba pillanatában futó programok visszagörgetésére egyszerűsíti.

A visszagörgetés maga úgy történik, hogy a programhoz tartozó módosítás előtti lemez képeket fordított időrendben vissza kell írni az adatbázisba.

"Hideg" újraindításra csak akkor van szükség, ha fizikai adathordozó sérülés történt. Ilyenkor helyre kell állítani a sérült lemezt, ezután pedig meleg újraindítás következik.

### 4. Hivatkozások

- /1./ B. Randell et al.:  
Reliability Issues in Computing System Design  
ACM Computing Service (CS) 10/2 1978. pp. 123-166.
- /2./ ACM CS 8/4 1976. Special Issue  
Reliable Software II. Fault-Tolerant Software
- /3./ J.S.M. Verhofstad:  
Recovery Techniques for Database Systems  
ACM CS 10/2 1978. pp. 167-196.
- /4./ K.P.Eswaran et al.:  
The Notions of Consistency and Predicate Locks in a Database System  
Communications of the ACM (CACM) 19/11 1976. pp. 624-633.
- /5./ L. Lamport:  
Time, Clocks and the Ordering of Events in a Distributed System  
CACM 21/7 1978. pp. 558-565
- /6./ P.A.Bernstein, M.Goodman:  
Concurrency Control in Distributed Database Systems  
ACM CS 13/2 1981. pp. 185-222.
- /7./ J.N.Gray et al.:  
Granularity of Locks and Degrees of Consistency in a Shared Data Base  
in G.M.Nijssen (ed.)  
Modelling in Data Base Management Systems  
North Holland Publishing Co. 1976. pp. 365-394.
- /8./ S.S.Isloor, T.A.Marsland:  
The Deadlock Problem: An Overview  
Computer 13/9 1980. pp. 58-72.

### Adatmodellezés a népgazdasági tervezésben

Adatmodell az adatok valamilyen absztrakt képét, az adatok egy meghatározott szemléletmódját értjük.

Közismert, hogy ugyanazon adatokra az aktuális céltól, a modellező izlésétől, a választott gondolati kerettől stb. függően igen különböző modellek adhatók, melyeket többféle-képpen szoktak tipizálni. Ilyen modelltipusokat jelentenek pl. az ANSI/SPARC struktúra külső, belső és fogalmi sémái /mely felosztásban a modellezési cél tükröződik/, vagy pl. a relációs, hálós, entity-relationship stb. modellek /itt a felosztás inkább formai szempontból történik /. Az is közismert, /éppen az ANSI/SPARC jelentés nyomán/, hogy egy alkalmazási környezetben általában több adatmodellre van szükség, mely tény magával hozza a különböző adatmodellek közötti megfeleltetések problémakörét.

Adatmodellezés a továbbiakban az egy alkalmazási környezet-hez tartozó adatmodellek és megfeleltetések megadásának, kezelésének problémakörét értjük.

Nyilvánvaló, hogy a kérdéskört erőteljesen befolyásolja az adatmodellek és kapcsolataik leírásának formája: milyen metafogalmakkal dolgozunk, milyen matematikai modellel képzelünk megéjük. Ebben természetesen tükröződniük kell az alkalmazási környezet sajátosságainak.

Az irodalom [2, 4, 6, 9, 10] szinte kizárólag olyan alkalmazási környezetekkel foglalkozik, ahol a fogalmi séma az entitás, attributum, reláció metafogalmakra támaszkodik, a külső, ill. belső sémák pedig viszonylag egyszerűen feleltethetők meg a fogalmi sémáknak /pl. a tárolás általában valami rekord-szerű egységekben történik, egy entitás-típusnak rendszerint egy rekordtípus felel meg, az attributumoknak mezők, stb./

Vannak azonban olyan alkalmazási környezetek, ahol ezek a konstrukciók nem, vagy csak nehézkesen alkalmazhatók. Előadásunkban azt szeretnénk bemutatni, hogy makroökonomiai környezetben más típusú /más fogalmakra épülő/ adatmodellek a "természetesek"; ezek a modellek a külső, belső és fogalmi sémák leírására egyaránt alkalmasak; kézenfekvő módszereket kínálnak a sémák közötti megfeleltetések leírására; és elég egyszerűek ahhoz, hogy számítógéppel kezelhetők legyenek.

#### Fogalmi sémák

Ha erősen összevont, feldolgozott adatokkal dolgozunk, akkor általában igen nehéz az entitás-típusok feltárása. Ezek az adatok a gazdasági élet heterogenitását elfedő, erős absztrakciók eredményei.

Ha a kézenfekvően felismerhető entitástípusokra akarunk támaszkodni, akkor áttekinthetetlenül sok entitástípusunk lesz /melyek felmérése ráadásul speciális szakértelmet igénylő, igen nagy feladat/. Ahhoz, hogy a modell áttekinthető legyen, első lépésben sokkal absztraktabb entitástípusokkal kell dolgoznunk, és ezek fokozatos konkretizálásával kell eljutni a "köznapi" entitástípusokhoz. Az adekvát általánosítás azonban igen nehéz feladat, melyhez sajnos a közgazdasági elmélet sem ad sok segítséget.

A gyakorlatban az a megoldás alakult ki, hogy csak néhány kézenfekvő entitástípust definiálnak /ezeket szokás nomenklaturákba foglalni/, és a rajtuk /illetve belőlük felépíthető összetett entitásokon/ értelmezett attribútumok értékeinek tekintik az adatokat. Ennek általában az attribútumok elég nagy száma és a köztük fennálló bonyolult összefüggések a következménye /ezeket szokták mutatókatalógusokba foglalni /. A vállalati mérlegbeszámolóknak pl. egy vállalat egy adott évi tevékenységét /összetett entitás/ több ezer attribútum jellemzi.

Az entitástípusok "elrejtését", "elhallgatását" megkönnyíti /illetve lehetővé teszi/ az aggregálás, melynek során entitások /relációik és attribútumaik segítségével képzett/ halmazaira vonatkozó mértékek kiszámításáról van szó.

A gyakorlatban az aggregált adatok definícióját általában nem adják meg explicit módon, hanem valamilyen rövidebb névvel helyettesítik /pl.: x vállalat létszáma t időpontban/. Itt nincs explici hivatkozás a "dolgozó" entitástípusra, ill. a "z dolgozó munkahelye x vállalat a t időpontban" relációra. A "létszám" így önálló attribútumként, és nem egy halmaz számoosságaként jelenik meg.

Az eddigiekben azt bizonygattuk, hogy makroökonomiai környezetben általában igen nehéz egy, a vállalati alkalmazásoknál megkívánt minőségű fogalmi séma /"a vállalat egy modellje"/ kidolgozása.

Más oldalról az is igaz, hogy az adatmodellezés eszköztára sincs kellőképpen felkészítve aggregált, származtatott adatok leírására. Ez a kérdés általában csak a lekérdezéseknél kerül szóba. Az így nyert adatok azonban már nem tartoznak a modellezendő adatbázishoz. Megoldási kísérletek találhatók [4,3] -ben.

Ilyen körülmények között célszerű abból kiindulni, hogyan látják adataikat a felhasználók /közgazdászok, tervezők, statisztikusok/. Fogalmi szinten általában a következőképpen gondolkoznak:

- egy adat nem más, mint egy "tartalom=érték" kifejezés, ahol az érték egyetlen /valós/ szám.

- az adatok tartalma általában több részből tevődik össze. Például:
  - mutató: az entitások, ill. kapcsolataik mely jellemzőjének értékéről van szó /milyen típusu az adat/
  - a szóbanforgó entitást, ill. kapcsolatot leíró ismérvek /attributumok/, ill. ezek értékei
  - egyéb, az egyértelmű meghatározáshoz szükséges információk /pl. a vonatkozási időpont vagy időszak, az adat forrása, mértékegysége, stb./
- adatok bármely halmaza csak akkor nyújthat reális /konzisztens/ képet a valóságról, ha az értékek között fennállnak bizonyos /csak a tartalomtól függő/ konzisztencia feltételek /aritmetikai egyenlőségek és egyenlőtlenések, röviden: egyenletek/.

Egy fogalmi séma definíciójából tehát annak kell egyértelműen kiderülnie, hogy

- mi a megengedett adattartalmak halmaza
- a megengedett adattartalmak /pontosabban: a hozzájuk tartozó értékek/ között milyen konzisztencia-feltételeknek kell fennállniuk.

Ezen fogalmakat a következőképpen tehetjük operatívvá /számítógéppel kezelhetővé:

- az adattartalmat azonosítjuk az adat megnevezésével /mely a fentiek szerint több részből álló, összetett objektum/
- a konzisztencia-feltételeket adatmegnevezésekből felépített aritmetikai egyenletekként reprezentáljuk /ezek szintén összetett objektumok/.

Ez az adatmodell tehát tulajdonképpen nem más, mint egy olyan egyenletrendszer /egyenlőségek és egyenlőtlenések halmaza/, melynek változói az adatmegnevezések. Ezért a továbbiakban egyenletrendszer /ER/ modellnek fogjuk nevezni.

Egy ER modell definíciója tehát nem más, mint egy megnevezés-halmaz és egy egyenlethalmaz definíciója.

A halmazok definiálása általában nem közvetlenül /elemeik explicit felsorolásával/ történik. Ennek két oka van:

- a halmazok elemszáma százezres, milliós nagyságrendben mozoghat: az elemenkénti felsorolás praktikusán lehetetlen
- általában lehetőség van arra, hogy nagyságrendekkel kevesebb információból állítsuk elő őket megfelelő műveletek /generálási szabályok/ felhasználásával.

A kiinduló információkat a megnevezések ill. összefüggések "építőköveiként" felhasználható egyszerű és összetett objektumok halmazaként lehet megadni.

Gyakran előfordul, hogy ezen halmazok közül bizonyosakat nem ismerünk előre /vagy tudjuk, hogy pillanatnyilag adott terjedelmük később változni fog/, de tudjuk, hogy bármely időpontban ki kell hogy elégítsenek bizonyos integritási feltételeket.

Egy ER modell definíciója tehát a következőkből áll:

- absztrakt modell: - generálási szabályok /megnevezésekre és egyenletekre/  
- integritási feltételek
- konkretizálás: az ismert halmazok megadása elemfelsorolással

Ez a leírási mód lényegében nem más, mint a matematikai közgazdasági modellek leírási módjának alkalmazása az adatmodellzésre. Ez persze nem véletlen: modelljeink adatokról "beszélnek", ebben az értelemben tehát adatmodellnek is tekinthetők.

Nézzük meg példaként az input-output elemzés egyszerűsített modelljét /a szokásos leírási módban/:

Változók:

- $x_i$ : az  $i$  szektor bruto outputja /  $i \in I$ ,  $I$  a szektorok halmaza/
- $y_i^f$ : az  $i$  szektor netto outputja az  $f$  felhasználási célra / $f \in F$ ,  $F$  a felhasználási célok halmaza,  $I \cap F = \emptyset$ /
- $x_{ij}$ : a  $j$  szektor inputja  $i$  szektor outputjából / $i, j \in I$ /

Feltételek:

$$x_i = \sum_{j \in I} x_{ij} + \sum_{f \in F} y_i^f ; i \in I$$

$$x_i, y_i^f, x_{ij} \geq 0 ; i, j \in I, f \in F$$

Indexhalmazok:

- $I = \{ba, ko, \dots\}$
- $F = \{fo, fh, \dots\}$

Az itteni változóazonosítók / $x_{ba}, y_{ba}^{fo} \dots$ / a mi terminológiánkban adatmegnevezések, az egyes feltételek pedig egyenletek. A definíció "változók" része /a szóveges magyarázat-tól eltekintve/ nem más, mint a megnevezésekre vonatkozó generálási szabályok együttese: ez alól csak az " $I \cap F = \emptyset$ " kitétel a kivétel, mely viszont integrálási feltétel. A "Feltételek" rész az összefüggésekre vonatkozó generálási szabályok halmaza. A két rész együttesen definiálja az absztrakt modellt.

Az "Indexhalmazok" rész a konkretizálás.



Eddigi definícióink semmi megszorítást nem tartalmaz az adatmegnevezésekre vonatkozóan, a gyakorlat számára tul általános. Szerencsére vannak olyan egyszerű speciális esetek, melyeket viszonylag széleskörűen alkalmaznak:

- az adatmegnevezések maximált hosszúságu szimbólumsorozatok. Ilyen megnevezésekhez jutunk a szokásos indexes matematikai jelölésmód linearizálásával, vagy hierarchikus elrendezések felhasználásával. Ezt a modellt "klaszszikus ER" modellnek /KER/ nevezzük
- az adatmegnevezések azonos hosszúságu szimbólumsorozatok, tehát az adatok egy /szimbólumokkal indexelt/ tömb elemeinek tekinthetők. Ezt a modellt tömb modellnek /T/ nevezhetjük. A tömb dimenzióit ismérveknék, az indexek értékeit ismérvértéknek szokás nevezni. Általában nem minden indexkombináció értelmes, ezért tulajdonképpen egy "cakkos tömbről" /jagged array/ van szó.

Könnyen belátható, hogy bármely KER modellhez megadható /"természetes módon"/ egy vele ekvivalens T modell, tehát a T modellek nem speciálisabbak a KER modelleknel.

### Külső sémák

A felhasználók adataikat általában általában numerikus táblázatokba, táblázatsorozatokba, táblázatsorozatok sorozataiba, többdimenziós tömbökbe, hipertömbökbe és ehhez hasonló strukturákba elrendezve "látják". A tömbökre, ill. az egyes dimenzióértékekre maguk választotta névvel hivatkoznak. Az adatok közötti összefüggések tömbök, "tömbrészek" közötti aritmetikai egyenletekként jelennek meg. Ezek az adatstrukturák /a dimenziók egymásutániságát rögzítve/ hierarchikus strukturáknak is tekinthetők, a felhasználó adta nevek pedig adatcsopórtok egy nagyobb adatcsopórton belüli "relatív nevének". Minden adat megnevezhető egy, a hierarchián belüli helyét kijelölő névsorozattal. Ha például adatainkat táblázatokból álló állományoknak képzeljük el, akkor egy adatot egy  $\langle$  állománynév, táblázatnév, sornév, oszlopnev  $\rangle$  szimbólumsorozattal tudunk megnevezni. A KER modell tehát alkalmas a külső sémák leírására. A tömbökbe rendezhetőség olyan "szabályosságok" formájában jelenik meg, melyeket generálási szabályok formájában lehet kihasználni. /Ahhoz hasonló dologról van szó, mint amikor tömbök azonosságát vagy a velük végzett műveleteket definiáljuk a tömbelemek felhasználásával./.

### Belső sémák

A belső séma fogalmát a szokásosnál absztraktabb értelemben használjuk. Az adattárolásból csak annyi érdekel bennünket, hogy milyen információk megadásával érhető el egy tárolt numerikus érték /mi az adat "absztrakt címe"/, illetve, hogy

milyen aritmetikai összefüggéseknek kell fennállniuk az egyes "címeken" tárolt adatok között. A tárolás adatstruktúrái - más környezethez hasonlóan - tervezési, makroökonomiai környezetekben is meglehetősen hasonlóan a külső sémák adatstruktúráihoz. Esetünkben tehát általában hierarchikus, ill. "többszerű" struktúrákról van szó. Ilyen tárolási struktúrákkal dolgoznak a szocialista országok tervehivatalaiban kifejlesztett adatkezelő rendszerek, a francia tervezést szolgáló LEDA és ARGOS programcsomagok, de még a vállalati tervezés számára készült un. "pénzügyi tervezési rendszerek" /financial planning systems/ is.

A KER modell alkalmazhatóságáról tehát lényegében ugyanazt lehet elmondani, mint a külső sémák esetén.

#### A sémák közötti megfeleltetések

A sémák megfeleltetése a népgazdasági tervezés körülményei között jóval általánosabb dolog, mint a külső, ill. belső sémák leképzése a fogalmi sémára. Ennek az a fő oka, hogy praktikusán lehetetlen egyetlen, mindent átfogó fogalmi séma kidolgozása. A külső séma - fogalmi séma - belső séma viszonyok helyébe tehát a különböző sémák egymásban való definiálhatóságának viszonya lép. Az  $S_1$  séma akkor definiálható  $S_2$ -ben, ha  $S_1$  minden adatmegnevezéséhez hozzárendelhető egy  $S_2$ -beli aritmetikai kifejezés, oly módon, hogy  $S_1$  egyenletei következményei  $S_2$  egyenleteinek. Magát a megfeleltetést nevezzük definíciófűnek. A definíció speciális egyenletrendszernek tekinthető, megadására tehát ugyanazok a technikák szolgálhatnak, mint az ER modell egyenletrendszerének megadására.

#### A sémák és megfeleltetések leírása, kezelése

Ezeket a kérdéseket a terjedelem adta korlátok között csak futólag érinthetjük. A T modellek és kapcsolataik leírására kézenfekvő a matematikai logika, ezen belül a logikai programozás, konkrétan a PROLOG formalizmusa [7].

A kezelési funkciók egy része /konzisztenciavizsgálat, lekérdezések/ magán a PROLOG-on /mint következtető rendszeren/ megoldható, más részük PROLOG leírások azonos átalakítását igényli. Ez utóbbiak közül egyelőre csak a tárolt adatok visszakeresésének /pontosabban: "címkék" meghatározásának/ problémája terén értünk el eredményeket [8].

Az ER modell esetén ígéretesnek látszik egy nyelvtani megközelítés is [5].

Irodalom

- [1] Asztalos D., Koltai T., Krekó B.: AMETIST: a meta-information system. Proc.of Int. Sem. on DBMS's, Schwerin, GDR, 1981.
- [2] Chen, P.P./szerk./: Entity-Relationship Approach to System Analysis and Design. North-Holland, 1980.
- [3] C.S.Dos Santos, E.J. Neuhold, A.L. Furtado: A Data Type Approach to the Entity-Relationship Model. In [2] .
- [4] Frost, R.A.: SCHEMAL: Yet Another Conceptual Schema Definition Language. The Computer Journal, 3,228-233/1983/
- [5] Gerevich L.: A Keretmodell formalizmusának egy megvalósítása. OTSZK munkaanyag, 1983.
- [6] Halassy B.: Adatmodellezés, adatbázis-tervezés. SZÁMOK, 1980.
- [7] Kiss Z., Krekó B., Őrszigety Gné.: A pénzügyi adattár tartalmi leírása. OTSZK munkaanyag, 1983.
- [8] Krekó B.: Számítógépes adattárak tartalmi nyilvántartása. OTSZK munkaanyag, 1982.
- [9] Nijssen, G.M./szerk./: Modelling in Data Base Management Systems. North-Holland, 1976.
- [10] Nijssen, G.M./szerk./: Architecture and Models in Data Base Management Systems. North-Holland, 1977.

VIDEOTON adatbáziskezelők

számítógéphálózatban

Békéssy Péter - Szalay Imre  
SZÁMALK Kiszámítógép Főosztály<sup>x</sup>

Összefoglaló

A DMS60 és DMS600 adatbáziskezelő rendszerek VIDEOTON számítógéphálózathoz való kapcsolásának megvalósításáról számolunk be az előadásban. Ez egy munkahelyről több távoli adatbázis elérését teszi lehetővé időben megosztva.

Szólunk az illesztések koncepciójáról, munkamódszerünkről és az alkalmazás eddigi tapasztalatairól is.

<sup>x</sup>  
A munka a VIDEOTON megrendelésére készült, a fejlesztés eredménye a VIDEOTON tulajdona.

## 1. Előzmények

A folyóirat publikációk gyakorisága alapján elmondható, az osztott adatbáziskezelés napjaink aktuális témája. Eddig leginkább csak elméleti részeredmények születtek, s a nálunk fejlettebb számítástechnikával rendelkező országokban is ritka a ténylegesen üzemelő, "igazi" osztott adatbázis.

Hazánkban az elosztott adatfeldolgozást alacsonyabb intelligenciával megoldó rendszerek lehetnek csak napirenden. Gyakorlati tapasztalatok szerzhetőek földrajzilag osztott adatbázisokkal /távoli adatbázis elérések/ a számítógéphálózatok megbízhatósága, a végfelhasználók számítástechnikai szervezetsége terén. Erre a bázisra építve lépcsőzetes fejlődés lehetséges: filetranszfer megvalósítása, majd a konzisztencia problémák megoldása után tranzakcióindítás az aktuális adatbázison kívüli adatbázisok lekérdezésére, módosítására. Ezek a résztapasztalatok, az elméleti eredmények beérésével, a külvöldi osztott adatbázisok megismerésével vezethetnek el idővel az igazi osztott adatbáziskezelés problémájának itthoni megoldásához.

E rövid okfejtés mindjárt érthetőbbé válik az alábbi project történetének ismertetésével.

A Videoton Számítástechnikai Gyár és a Számítógéppalkalmazási Kutató Intézet /jogutódja 1982. óta: Számítástechnika - Alkalmazási Vállalat/ 1978-ban elhatározta, hogy a Videoton által gyártott hardver berendezésekre építve közösen kifejleszt egy komplex adatbázis /adatátviteli rendszert/, mely alkalmas földrajzilag elosztott többtelephelyes nagyvállalatok termelésirányítási rendszereinek támogatására.

A fejlesztési koncepció abból indult ki, hogy a termelésirányításhoz szükséges adatok a funkcionális szervezeti egységenként rendelkezésre állnak. A termelésirányításhoz szükséges döntésekhez azonban sokszor nem elegendő a lokális részadatbázis adatainak ismerete, ezért biztosítani kell valamennyi többi részadatbázis elérését. Ezt a távoli elérést kommunikációs alrendszer megvalósításával kívánták megoldani. Mindez találkozott a Videoton számítógépes termelésirányításának rekonstrukciós törekvéseivel, s így lehetővé vált, hogy a létrehozott rendszert a Videoton referencia alkalmazásként üzemeltesse.

A fejlesztés VNS /Videoton Network Service/ néven futott a következő feladatmegosztásban:

- A Videoton vállalta a felelősséget a hardver komponensekért, továbbá a felhasználói adatbázisok és a hozzájuk tartozó tranzakciós rendszerek kidolgozásáért.
- A SZÁMKI /SZÁMALK/ Távadatfeldolgozási Főosztályán dolgozó team alkotta meg a kommunikációs alrendszert, az NSS-t /Network Service Support/.

- Jelen beszámoló szerzőinek feladata volt a francia licenc alapján a VIDEOTON által forgalmazott DMS60, majd DMS600 adatbáziskezelő rendszereknek az NSS-hez való adaptálása.

## 2. Az illesztés

Az NSS X-25 elvek szerinti rétegekből felépülő csomagkapcsolt hálózati szoftver, amely az ún. csomóponti /node/ számítógépeken fut. Az alkalmazások futtatására az ún. host gépek szolgálnak. A DMS60/600 CODASYL típusú hálós strukturájú tranzakcióorientált kiegészítő adatbáziskezelőrendszerek szerepelnek a hálózati alkalmazásokként. Ezek a szoftver termékek a hozzájuk tartozó felhasználói kézikönyvekből, külső specifikációkból ismerhetők meg alaposabban.

A már üzemelő hálózati konfiguráció a géptípusok feltüntetésével az 1. ábrán látható.

A kommunikációs alrendszer az adatbáziskezelő számára meghatározza a terminálokkal való forgalmazás szabályait, és a forgalmazott csomagok formáját, az ún. protokollt.

Az adatbáziskezelő szerkezetének vizsgálata megmutatta, hogy egy adatkezelő és egy adatgyűjtő részrendszerre osztható. Előbbi valósítja meg az adatok változtatását /update/, elhelyezését, utóbbi az interaktív tranzakciók felügyeletét, a több terminál egyidejű kiszolgálását. A földrajzilag osztott adatkezelés megszorítás épp azt jelenti, hogy az adatbáziskezelőnek csak az adatgyűjtő része változik úgy, hogy alkalmazásá válik a hálózatban lévő terminálokon való adatgyűjtésre, tranzakció futtatásra is. Igazi osztott adatbázis esetén az adatkezelő alrendszer sem maradhatna változatlan, hiszen a host gépeken elhelyezkedő adatbázisok között ekkor adatkapcsolatok és összefüggések is lennének.

Esetünkben egymástól független adatbázisok működnek, viszont a hálózatba kapcsolt tetszőleges terminálról e független adatbázisok bármelyike, de egyidejűleg csak egyike, elérhető.

Az adatbáziskezelő szerkezete úgy változik az illesztés következtében, hogy az adatgyűjtő alrendszer helyére egy hálózatkezelő alrendszer kerül.

A hálózatkezelő alrendszer funkciói:

- kapcsolatfelvétel a hálózattal és a terminálokkal
- csomagforgalmazás
- csomagtartalmak összeállítása: konverzió a protokoll szerinti formátumra és vissza.  
/Ez a lényegi változtatás a DMS60/600 strukturájában/

- kapcsolatbontás egy terminállal, a hálózattal és új terminál fogadására való felkészülés

Alapelv volt az illesztés megvalósításakor, hogy a felhasználói interfész minimálisan módosuljon. A valóban nem jelentős változások oka, hogy a terminálokat a hálózatban egy általánosabb célra készült terminálkezelő vezérli.

### 3. Néhány szó a munkamódszerről

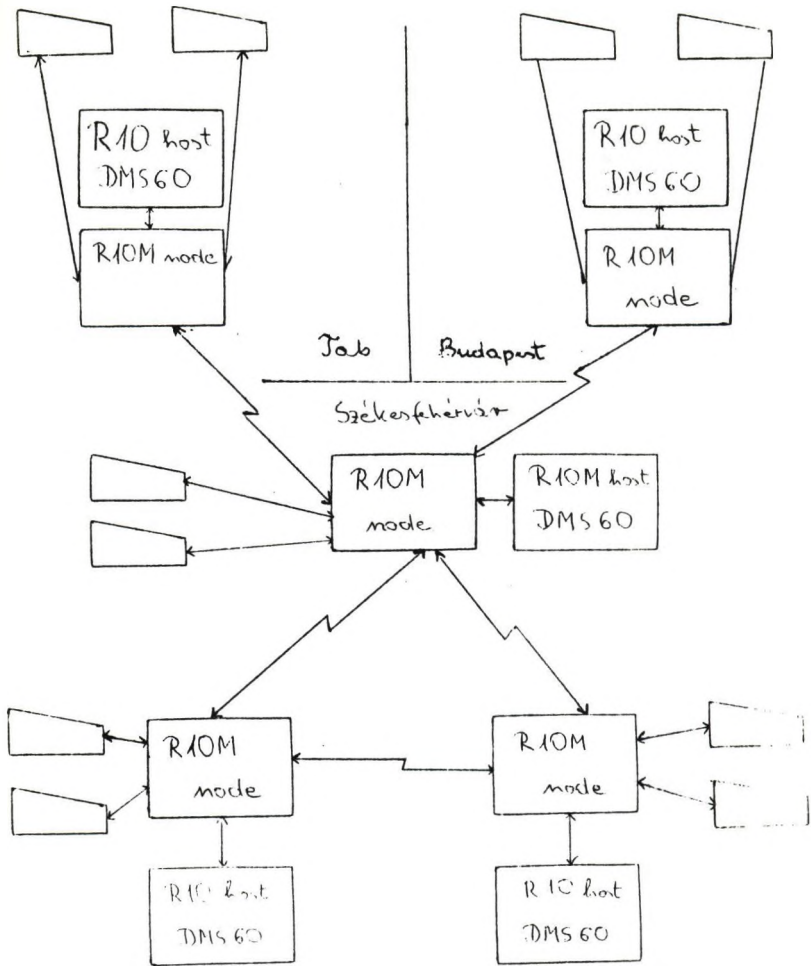
Munkánk végeredménye a távoli terminálokon lefutó adatkezelő tranzakciók formájában csak a hálózat legtulsó végén levő szoftver réteg által jelenik meg ténylegesen. Míg azonban eddig eljut, sok párhuzamosan fejlesztett szoftver rétegen kell a csomagoknak keresztül jutnia. Ettől úgy függetlenítettük magunkat, hogy mindkét alkalommal közvetlenül az adatbáziskezelőre építettünk egy szimulátor réteget, amely a távoli terminálokra érkező csomagokat mind megjelenítette az operátori konzolon, illetve mód volt a terminálokról érkező csomagok összeállítására is az operátori konzolról.

Jól működő részfunkciók egymás utáni sorozatával jutottunk el a kész rendszerhez. Ha egy részcélt beprogramoztunk, akkor csak ennyi változtatást végeztünk a működő rendszeren, a továbbfutó összes ágakat nyomkövetési pontokkal lezártuk. Ha az új részfunkciót sikerült belőnünk, a nyomkövetési pont jelölte ki a következő részcélt. A nyomkövetési pontok segítették a rendszer módosítási helyei teljes halmazának megtalálását.

## Irodalom

1. I. Földvári, P. Rajki, L. Simonfai, R. Szentés:  
COMNET - 2000  
5<sup>th</sup> Conference on the Theory of Operating Systems,  
Visegrád 1979.
2. P. Rajki, R. Szentés, Z. Ujvári:  
An Overview on the VIDEOTON-SZÁMKI Networking  
Project 3<sup>rd</sup> Hungarian Computer Science Conference,  
Budapest, 1981.
3. P. Rajki, R. Szentés, Z. Ujvári:  
VIDEOTON Network System General Overview  
COMNET '81 Conference Working papers /2-21 p./
4. Rajki P., Szentés R., Ujvári Z.:  
VIDEOTON kisszámítógépes hálózat általános ismertetése
5. Ungár János: Adatbázis-kezelő rendszerek a VIDEOTON  
számítógépein  
Információ-Elektronika 1981/6.
6. Baffia L. - Ungár J.: DMS 60 adatbáziskezelő rendszer  
Struktúra, 1979/9. /153-168. o./
7. Békéssy P. - Szalay I.: DMS 60 az NSS 0 verziójában  
SZÁMKI-VIFI Bp. 1981.





A VHS üzemenlő változata

1. ábra

### Dinamikus állományszerkezetek

Előadásunkban nagyméretű, dinamikusan változó adatállományok kezelési módszereiről kívánunk összehasonlító áttekintést adni. Az utóbbi néhány év szakirodalma - elsősorban az általunk is idézett szerzők tollából - néhány, a klasszikus hashing módszerének tovább fejlesztésével kialakított eljárásról ismereteket. Ezek az algoritmusok az egyes rekordok kulcs szerinti közvetlen elérését - az egyes szerzők által választott környezetben - jó tárolókihasználtság mellett biztosítják. Szeretnénk azonban az ismert módszereket egységes szempontok szerint vizsgálni, azonos környezetben összehasonlítani. Ezért a következő alapfeltevésekkel élünk:

1. Az adatállományban előforduló rekordok számáról nincs előzetes információ, és ez a szám az adatállomány élete során tág határok között változhat rekordok törlésével és beszúrásával.
2. A rendelkezésre álló központi memória kicsi az adatállomány méretéhez képest és nem növelhető az adatállomány méretének növekedésével.
3. Minden rekordnak van egy egyértelmű azonosítója, amely alapján a rekordot az állományból ki kell keresni.

Jól érzékelhető, hogy a "klasszikus" adatszerkezési módszerek, pl. az indexszekvenciális, láncolt vagy akár a direkt file-ok ilyen feltételek között nem hatékonyak. A "hatékony" fogalom pontosabb használata érdekében definiáljuk a tárolókihasználás és elérési szám fogalmát egy adott módszerhez a következőképpen:

$T(n)$  =  $n$  rekord átlagos hosszának és az  $n$  rekord tárolásához és a kulcs szerinti elérés megvalósításához szükséges tárolóhelynek hányadosa /kitöltési tényező/

$F(n)$  = egy rekord megkereséséhez átlagosan szükséges hozzáfordulások száma az  $n$  rekordot tartalmazó állományban

Egy adatszerkezési módszer hatékonysága jól jellemezhető azaz, hogyan viselkedik  $F(n)$  és  $T(n)$  a rekordszám valamilyen tartományában. Ha pl. találnánk olyan módszert, amely a rekordok számától függetlenül teljesítené a

$$0 < C_1 < T(n) \quad \text{és} \quad F(n) < C_2$$

feltételeket, ezt valóban dinamikusan - azaz bármilyen méretű állományra egyformán jó hatékonysági mutatókkal - működőnek nevezhetnénk. Ilyen módszert nem sikerült találni, az ismeretetésre kerülők csak a rekordszám valamilyen /a rekordok, kulcsok vagy a központi memória méretéből adódó/ többé-kevésbé elfogadható korlátozása mellett teljesítik a fenti egyenlőtlenségeket "értelmes"  $C_1, C_2$  konstansokkal. Mindazonáltal - korlátaik ismeretében - ezek a módszerek a gyakorlatban jól használhatóak, hogy melyik mikor, az a továbbiakból szándékunk szerint kiderül.

## II.

Az ismertetésre kerülő módszerek közös jellemzői - és ezeket ezért együtt is tárgyaljuk - a következők:

1. A rekordokat a klasszikus hashing-nél is alkalmazott csomagokban /bucket/ tárolják.

2. Ha a file telítődik, új csomagot kapcsolnak hozzá, az új csomag eléréséhez szükséges információkat egy táblázatban tárolják. A táblázat /directory/ minden ismertetésre kerülő módszerben egy bináris fa reprezentációjának tekinthető.

Az egyes algoritmusok közötti különbség a fa tárolási módjában van, ill. abban, hogyan definiálják a file telítődését.

Ha az állományhoz tartozó tartalomjegyzéket egy  $m$  db bináris fából álló erdővel ábrázoljuk, egyelőre eltekintve annak konkrét tárolási módjától, könnyen megérthetjük a dinamikus hashing módszerek közös elvét. A fák levelei a rekordelőfordulásokat tartalmazó csomagokat reprezentálják. Egy adott kulcsból először is /ha az erdő több fából áll/ az

$\{1, 2, \dots, m\}$  halmazra való leképezés segítségével meghatározzuk, hogy a rekordot tartalmazó csomag melyik fa levele. Ezután kiinduló értéként használva a rekord kulcsát, előfordulások egy bináris sorozatát, amely megmondja, hogy milyen csomagok tartoznak a kulcshoz tartozó bináris sorozat /betűlánc/ előforduló algoritmus lehet pl. egy pszeudogenetikus - generátor. / Most már ebben a csomagban megkeresettjük a rekordot - ha ez a feladat -, illetve beillesztettük, ha még elfér. Ha egy beillesztés során a fentiek szerint meghatározott csomag betelik, az alábbi eljárást követjük:

1. nyitunk egy új üres csomagot, ezt hozzáfűzzük a fához, mint az éppen betelt csomagot reprezentáló csucs jobboldali fiát;

2. a betelt csomagot szintén hozzáfűzzük a fához, mint a keletkezett csomag testvérét;

3. a kulcsból meghatározható bináris sorozat alapján minden

rekordról döntünk, hogy átkerül-e a jobboldali új csomagba, vagy marad a helyén /ehhez semmi mászt nem kell tenni, mint a bináris sorozatot egy elemével tovább figyelembe venni - tehát az eddig egy csomagban tárolt rekordokhoz tartozó elérési ut a fán az utolsó előtti lépésig továbbra is közös marad/.

Rekordok törlése során ha két testvérben a rekordok száma együttesen annyira lecsökken, hogy már egy csomagban is elférnek, a két testvért a fenti algoritmus megfordításával összemácsolhatjuk.

Knuth [2]-ben bebizonyította, hogy a csomagok telítettsége  $\ln 2 \approx 0,69$  körül várható. Ha a csomagok nem osztódnak azonos módon beteltek, hanem a klasszikus hashing-ből ismert módon tulcsordulási területeket rendelünk hozzájuk, ez az arány kb. 0,1-el javítható az elérési idő számottevő romlása nélkül.

Az előadásban röviden ismertetésre kerülnek a legalapvetőbb dinamikus hashing módszerek, úgy mint: "dynamic hashing" / [3], [8] /, "extendible hashing" / [4], [6] /, "linear hashing" / [4], [5], [9] / ill. ezek különböző változatai.

### III.

Megvizsgáljuk, hogyan viselkedik az  $F(n)$  és  $T(n)$  függvény n különböző nagyságrendű értékeire.

A gyakorlatban előforduló feladatok illusztrálására három példát dolgoztunk ki /1., 2., 3. táblázatok/. A példák számolása során olyan számítógépet tételeztünk fel, amelynek mind belső -, mind háttérmemóriája 32 biten címezhető.

Az elméleti számításokból ill. számítógépes szimulációk alapján kapott eredményeket a 4. táblázat foglalja össze. A táblázatban szereplő képletek a tárolókihasználás, elérési szám és az indextábla méretének nagyságrendi becslését adják. Már a nagyságrendi becslésekből látszik, hogy a "dynamic hashing" és a "linear splitting" módszerek csak abban az esetben javasolhatók alkalmazásra, ha a tartalomjegyzék kiinduló feltételezéseinkkel ellentétben a központi memóriában tárolható. Ha az elérési szám alacsonyban tartása nem elsőrendű fontosságú, a "linear splitting" módszer még ott is alkalmazható, ahol a "dynamic hashing" már a belső memória korlátai miatt nem. Ha a fenti feltételek nem teljesülnek, marad az "extendible hashing" alkalmazása. Ez konstans elérési számot produkál. A kitöltési tényező értéke elméletileg 0-hoz tart ugyan, mindazonáltal a gyakorlatban, a mai számítógépek mé-

reteit figyelembe véve általában lehet olyan csomagméretet választani, ami megfelelő tárolókihasználást eredményez.

csomagméret rekordszám	b=10	b=20	b=50
	$10^5$	350	175
$10^6$	3500	1750	700
$10^7$	35000	17500	7000

1. táblázat. Példák a "dynamic hashing" indextáblájának méretére /Kbyte/.

csomagméret rekordszám		b=10	b=20	b=50	F(n)
		$\gamma=2$	$10^5$	30	
$10^6$	300		150	60	
$10^7$	3000		1500	600	
$\gamma=3$	$10^5$	20	10	4	
	$10^6$	200	100	40	
	$10^7$	2000	1000	400	

2. táblázat. Példák a "linear splitting" indextáblájának méretére /Kbyte/ és az elérési számokra, ha az indextábla a központi tárban van / a módszer egyik paramétere, l. [9]/.

csomagméret rekordszám	b=10	b=20	b=50
$10^5$	0,68	0,68	0,68
$10^6$	0,57	0,61	0,65
$10^7$	0,47	0,54	0,62
$10^8$	0,39	0,48	0,59

3. táblázat. Példák az "extendible hashing" kiültési tényezőjének alakulására.

	indextábla mérete	$F(n)$	$T(n)$
"dynamic hashing"	$\frac{C_1 n}{b^{\lceil \ln 2 \rceil}}$ [2]	$\log_2 \frac{n}{b}$	$\frac{\ln 2}{\frac{1}{2} + 1}$
"extendible hashing"	$G(n)$ [6]	$< 3$ [1]	$\frac{r}{G(n) + Cn}$
"linear splitting"	$\frac{C_2 n}{\gamma^{\lceil \ln 2 \rceil}}$ [9]	$3n$	$> C(\gamma)$

4. táblázat.

A közölt képletekben szereplő változók jelentése a következő:

- $n$  - rekordszám,
- $b$  - csomagkapacitás,
- $C_1$  - a cím hosszától és a pointerezés megvalósításától függő konstans,
- $C_2$  -  $C/B$ , ahol  $B$  a csomag hossza byte-okban kifejezve,
- $G(n)$  - olyan függvény, amelyre teljesül:  $G(2n) = 2^{1+\epsilon} G(n)$ ,
- $C(\gamma)$  - egy  $\gamma$ -tól függő konstans.

Irodalomjegyzék

- [1] R.Fagin, J.Nievergelt, N.Pippenger, R.Strong, "Extendible hashing - A fast access method for dynamic files", ACM Trans. Database Syst., vol. 4/1979/ pp. 315-344.
- [2] D.E.Knuth, The art of computer programming, vol.3: Sorting and searching. Addison-Wesley, Reading, Mars.,1973.
- [3] P.Larson,"Dynamic hashing", BIT, vol. 18/1978/, pp.184-201.
- [4] P.Larson, "Linear hashing with partial expansions" Proc. 6<sup>th</sup> Int. Conf. on Very Large Data Bases, Montreal 1980, pp. 224-232.
- [5] W.Litwin, "Linear hashing: A new tool for file and table addressing", Proc. 6<sup>th</sup> Int. Conf. on Very Large Data Bases, Montreal 1980, pp. 212-223.
- [6] H.Mendelson, "Analysis of extendible hashing", IEEE Transactions on Software Engineering, vol. 8./1982/, pp.611-619.
- [7] J.K.Mullin, "Tightly controlled linear hashing without separate overflow storage", BIT 21/1981/, pp.390-400.
- [8] K.Ramamohanarao, J.W.Lloyd, "Dynamic hashing schemes", The Computer Journal, vol. 25/1982/, pp.478-485.
- [9] M.Scholl, "New file organizations based on dynamic hashing" ACM Trans. Database Syst., vol. 6/1981/, pp.194-211.

Teledata bázisu alkalmazói rendszerek

Előljáróban meg kell említeni: az előadást azmal a nem titkolt céllal terveztük, hogy a figyelmet a TELEDATA rendszerre irányítsuk, bizonyítva alkalmasságát vállalati információs rendszerek kialakítására.

Meg kívánjuk győzni a szervezőket, hogy további alkalmazásokban számítsanak /építsenek/ a TELEDATA rendszer szolgáltatásaira, s meg kívánjuk győzni az alkalmazókat, hogy igényeljék, mint adott esetben a legalkalmasabb megoldást, a TELEDATA rendszer szolgáltatásait.

A TELEDATA rendszer alkalmassága vállalati környezetben történő felhasználásra

A TELEDATA típusu alkalmazásokat általában mint postai, vagy postai hálózaton elérhető szolgáltatásokat mutatják be. Eddigi fejlesztéseink alapján úgy tűnik, zártkörű TELEDATA rendszerek alkalmazása, belső, vállalati információs rendszerekben hamarabb realizálható, mint a fentiek.

A TELEDATA rendszer biztosította előnyök a ma általánosan elterjedt képi megjelenítéssel szemben:

- az alkalmazás fejlesztési költségei alacsonyabbak, gyorsabban hoz eredményt, mint más rendszerek - a vezérlő program számos funkciót átvállal az alkalmazás vezérlésében. Legszembetűnőbb példája ennek, mikor az alkalmazás csak informatív jellegű statikus információt kezel /népességnyilvántartás, utazási ajánlatok, ... stb./;
- a számítógépes szolgáltatás egyszerű eszközökkel, laikusok számára is, különösebb előképzettség nélkül hozzáférhetővé válik - infra távvezérlő, általánosan elterjedt színes televízió;
- színes képmegjelenítés - a színes kép vizuális élményt jelent /főként laikusok számára meggyőzőbb, fölkelti a figyelmet/; a színekkel a tartalom kiemelhető, hangsúlyozható;
- grafikus megjelenítés - hasonlóan az előbbiekhöz, a grafika a megjelenítés hatását fokozza, grafikonok ábrázolásával a kiértékelhetőséget növeli;
- számítógépes háttér - a működő alaprendszerek fejlettségétől függően a vállalati adatbázisokat bekapcsoló, dinamikus, naprakész információ megjelenítés a fenti formában;



- a terminálok ára alacsony, alkalmasint megjelenése bizonyos helyeken esztétikusabb más berendezéseknél - utazási irodák, pályaudvar, tanácsterem, dolgozó szobák, ... ;
- működtetés távvezérléssel - a színes televízióknál ismert technika felhasználásával.

A felsoroltaknak, főként az egyszerűségnek ára van, ami az alábbiakban jelentkezik:

- költéssek a képszerkesztésben és az információ forgalomban - többnyire az alkalmazott protokollból származó megkötések;
- az ismert képernyős termináloknál szűkebb, egyidejűleg megjeleníthető információ mennyiség.

Mind Ezeket összevetve, az alkalmazási kísérletek alapján megállapítható, hogy számos alkalmazási terület van, ahol az előnyök fokozottan jelentkeznek és a korlátozások igényesebb tervezéssel háttérbe szoríthatók.

#### TELEDATA bázisra épülő alkalmazások tervezésének sajátosságai

TELEDATA alkalmazás esetünkben vállalati adatok megjelenítését jelenti, speciális lehetőségekkel rendelkező színes képernyős terminálokon, előre meghatározott összetételben, egy előre definiált vezérlési séma által meghatározott sorrendben.

Egy TELEDATA alkalmazás tervezése és kiépítése két lépésben történik:

- az alkalmazói rendszer kiszolgáló környezetének tervezése és létrehozása;
- az alkalmazói rendszer tervezése és létrehozása.

Egy TELEDATA környezet az alkalmazói rendszer számára a következő környezeti elemek kialakítását jelenti:

- képfájl tervezése, szerkesztése és feldolgozása,
- vezérlő struktúra /menü/ tervezése és generálása.

A TELEDATA képeket alkalmazói információk alapján grafikus formában tervezni kell. A kép tartalmazhat az információtartalomra, a rend-

szerben elfoglalt szerepére utaló jegyeket /főként grafika, vagy szín, stb./; statikus, a szerkesztésnél föl vitt adatokat és/vagy dinamikusan változtatható adatmezőket: a választékot a választást segítő szövegrésszel, jelezve a vezérlésátadás módját és irányait.

A tervezett képek szerkesztő terminálon n. erik el végleges formájukat. A különböző alkalmazásokban felhasznált képeket a TELEDATA rendszer egy közös kép adatbázisban tárolja. A kép adatbázis töltését, karbantartását szervizprogramok biztosítják.

A TELEDATA vezérlő struktúra /menü/ a vezérlési séma /gráf/, amely alapvetően meghatározza egy alkalmazás működési mechanizmusát. A tervezés egyik legfontosabb lépése a vezérlő gráf szimbólikus leképezése.

Egy alkalmazás vezérlő struktúrája leíró nyelv segítségével definiálható. A menü gépi reprezentációját, a leírás alapján TELEDATA szervizprogramok állítják elő és helyezik el a közös menü adatbázisban.

A vezérlő struktúra tervezése az alkalmazás tervezés fontos eleme. Megfelelő szerkezet kialakításával a tranzakciók logikai felépítése lényegesen egyszerűsíthető. Ez egyrészt előnyt jelent a kivitelezésben /egyszerű, gyors kivitelezés/; másrészt előnyt jelent a végrehajtásban /válaszidők és az erőforrások leterhelésének csökkenése/.

A szűken vett alkalmazói rendszer elemei:

- tranzakciók /programok/,
- alkalmazói adatbázisok.

A tranzakciók olyan alkalmazói programok, amelyek kielégítik a TELEDATA rendszer és annak telekommunikációs környezete által szabott feltételeket, s egyben fölhasználják ezen rendszerek szolgáltatásait.

Az alkalmazói adatbázis állhat egyszerű, hagyományos állományokból, vagy épülhet valamilyen adatbázis kezelő rendszerre. /Több szempontot figyelembevéve a tárgyalt alkalmazás hagyományos állományokra épül./

## TELEDATA bázisra épülő alkalmazás - Borsodi Szénbányák Vezetői Információs rendszere

A Borsodi Szénbányák vezetői információs rendszerének fejlesztése az CMFB - BSz - SzKI között fennálló kutatás-fejlesztési szerződés keretében indult. A rendszer kidolgozásához 1983. februárban u.n. nag.vonalu rendszerterv készült. A nagyvonalu terv alapján kerül sor a vezetői információs rendszer részletes, a Számítástechnikai Koordinációs Intézetben kifejlesztett SZKITA - TELEDATA rendszerben történő kivitelezésére.

A BSz vezetői információs rendszere egy központi adatbázisra épülő TELEDATA bázisú lekérdező rendszer, amely az alábbi modulokból épül fel:

- termelési modul,
- szénbányák jellemzői modul,
- vállalati eredmények modul,
- anyaggazdálkodási modul,
- beszerzések és árváltozások modul,
- létszám-, bér-, műszak-, teljesítmény-modul.

További csoportosításban, a rendszer tartalmaz

- kiszolgáló elemeket, amelyek a központi TELEDATA adatbázis feltöltését, karbantartását végzik /a TELEDATA adatbázis hagyományos állomány-kezelésére épül/,
- lekérdező elemeket, amelyek a TELEDATA szolgáltatásokra épülve, definiált összetételben és kapcsolatrendszerben az információt megjelenítik.

A kivitelezés modulonként, folyamatosan történik. A kivitelezésben a felek együttműködnek oly módon, hogy a software keretek és a lekérdező rendszer elemeinek kidolgozása az SzKI, míg az adatbank karbantartó, feltöltő modulok elkészítése a BSz feladata.

A vezetői információs rendszerből elsőként az anyaggazdálkodási modul készült el.

Az anyaggazdálkodási modul a vállalat gazdálkodása szempontjából lényeges anyagfelhasználás és készlet érték adatokat kezeli.

A kiszolgáló modulok a vezetői döntések alapján és a vállalat egyéb információforrásaiból létrehozzák az adatbázist képező állományokat, valamint gondoskodnak azok folyamatos feltöltéséről és karbantartásáról.

Az anyaggazdálkodási modul elemei:

- anyagfelhasználás ág:  
kezeli a napi-, havi-, üzemenkénti anyagfelhasználás értékeket.
- készletnyilvántartási ág:  
a készletmozgások kvázi naprakész nyilvántartására épülve kezeli az aktuális havi-, raktári- és faterlepi készlet értékeket.
- kiemelt anyagok felhasználása és -készlete, villamosenergia-felhasználás ág:  
kezeli a gazdálkodás szempontjából fontos anyagok havi felhasználás és pillanatnyi készlet érték adatait, valamint a villamosenergia-felhasználást.

Az alkalmazói rendszer havi adatokat az aktuális évben az aktuális hónappal bezárólag és az elmúlt évben a teljes évet tekintve; napi adatokat az aktuális hónapban és az azt megelőző hónapra tárol.

Az alkalmazás jellemző tulajdonsága, hogy közvetlen módon mindig aktuális adatokat szolgáltat, de lehetőséget biztosít egy választott dátum alapján is a lekérdezésre, ha az adott terminusra vonatkozóan létezik tárolt információ.

A rendszer az egyes elemek között időbeli és egyéb logikai kapcsolatot feltételez és ezt a vezérlő grafban tükrözi, pl. vezérlés-átadás történet /választható/ nemcsak készlet →raktári készlet, illetve készlet → faterlepi készlet relációban, hanem aktuális raktári készlet → aktuális faterlepi készlet relációban is.

A TELEDATA rendszer hardware/software alapelemeit és az alkalmazások bizonyos elemeit az SzKI elsőként a '82 BNV-n mutatta be.

A szóbanforgó anyaggazdálkodási modul a felhasználónak 1983. júniusban az SzKI R15/R16 számítógép rendszerén átadtuk.

TELEDATA szolgáltatásra épülő alkalmazói rendszerek erőforrás igényük alapján, különböző kapacitású számítógépekre telepíthetők. Erre építve az SzKI elkészítette személyi számítógépén működő TELEDATA rendszerét. A rendszer megoldását tekintve olyan, hogy ezáltal a személyi számítógép akár önálló-, akár részfeladatok megoldására alkalmas /raktárkészlet nyilvántartás, vagy képszerkesztés... stb./.

Minden egybevetve, egy feladat eldönti, hogy megoldása milyen keretek között legcélszerűbb. A már korábban deklarált célunk az volt, hogy bemutassuk, bizonyos alkalmazásoknál a TELEDATA típusú megoldás a korábbiaknál célravezetőbb, s az erőforrások széles körében /ESZR, IBM, személyi számítógépek.../ van mód ezen lehetőség kihasználására.

Real-time adatbáziskezelő rendszerek teljesítményvizsgálata és tervezése modellezéssel

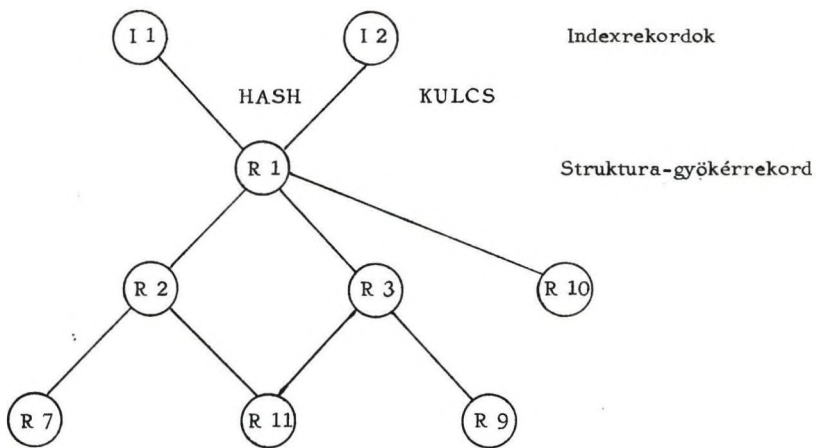
Az ismertetésre kerülő software-teljesítmény vizsgálatok a real-time tranzakciós rendszerek középpontjában álló alapsoftware, az adatbáziskezelő rendszer teljesítményparamétereinek /átbocsátóképesség, válaszidők eloszlása, stb./ elsősorban kísérleti úton történő meghatározását jelentik és a benchmarking fogalomkörébe sorolhatók. Az adatbáziskezelő rendszerek nagy volumenű alkalmazások bevezetése előtt elvégzendő teljesítményvizsgálatát indokoltá teszi az a tény, hogy a dokumentációk általában nem tartalmazzák - az alkalmazás-specifikusság miatt nem is tartalmazhatják - a rendszer valamilyeni ismervét, amely alapján optimalizált rendszerek tervezhetők.

A PSZTI és a KFKI által a TRACCS-11 kommunikációs hálózati tranzakciókezelő rendszer adatbáziskezelő alrendszerében, a DSMS-ben végzett vizsgálatokat kettős cél motiválta.

1. Nyujtsanak támpontot az Állami Biztosítóban tervbevelt országos hálózati tranzakciós rendszer tervezéséhez és méretezéséhez; adjanak becsléseket egy megvalósítható rendszer várható átbecsátóképességéről, szűk keresztmetszeteiről.
2. Ujjonnan forgalmazott és vásárolt software-termékről lévén szó, a vizsgálatok foglalják magukban a software-feltárás munkáit is. Ennek keretében állapítsák meg a DSMS-re általánosan jellemző teljesítménykorlátozókat és azokat a lehetőségeket, amelyekkel a hatékonyság lényegesen befolyásolható.

A vizsgálatok egy részének módszeréül azt a megoldást választottuk, hogy a Biztosító által rendelkezésre bocsátott információk alapján jóval kisebb, laboratóriumi méretekben létrehozunk egy modell-adatbázist, amely strukturá-

jában, a rekordkapcsolatok eloszlásában megfelelt az alkalmazás során elő-  
 álló adatbázisra várható értékekkel, azonban a típuskapcsolatok leírásában  
 jóval egyszerűbb volt.



ÁBRA: A modelladatbázis típuskapcsolatai

Ezt azzal értük el, hogy az eredeti adatbázisban több, a strukturában ha-  
 sonló helyzetben lévő rekordtípust, a kapcsolataik eloszlásával együtt ösz-  
 szevontunk. Ezt az tette lehetővé, hogy vizsgálatainkban elvonatkoztattunk  
 a programfunkcióktól: a felhasználói programok overhead-jét nem vettük

számításba, csak a szigorú értelemben vett, a software által megvalósított adatbázisműveletek műveletigényét és sebességét vizsgáltuk. Ebben a megközelítésben az adatbázis csupán egy "számrendszert" definiált, amely által meghatározott pályákon a tranzakciók "közlekedhetnek". Az adatszűrés során merült fel az a technikai probléma, hogy a kétirányú ponterekekkel adminisztrált rekordkapcsolatoknak az a konzisztenciája, amelyet a rekordok adatbázisba kerülésének "természetes módja" automatikusan megőriz, ne sérüljön meg a generálás során sem.

Kidolgoztunk egy algoritmust és egy programcsomagot, amely a rekordkapcsolatok megadott "független" eloszlásaira, a rekordtípusok közötti kapcsolatok bármely strukturájára megoldja a problémát.

Az így előállított laboratóriumi adatbázist azután kétféleképpen hasznosítottuk mérések elvégzésére:

- A tervbevert adatbázisfunkcióknak megfelelő "tranzakciókeveréket" definiáltunk, amelyekkel részben a várható batch-futtatások, részben az online hálózati futás várható teljesítménykarakteristikáit vizsgáltuk. Mértük a szekvenciális, direkt elérés, módosítás, törlés, beszúrás tranzakciók végrehajtási idejét.
- Modellkísérleteket végeztünk, amelyekkel az egyes izolált adatbázisműveletek műveletvégzési sebességét és a különböző indexszervezési módszerek /hash-kulcs/ hatékonyságát vizsgáltuk; ehhez a modell-adatbázist egy átlagot képviselő mérési környezetként használtuk.

A vizsgálatok eredményeként a rendszerben több meglepő kritikus pontra, potenciális szűk keresztmetszetre bukkantunk, és az adatbázis és program-

tervezés számára megfogalmazhattuk kivédésük lehetséges módszereit. Így pl. a hash-index módszer által kínált elvi hatékonyság csak a kulcs megfelelő ábrázolási módjának megválasztásával használható ki, másképpen alkalmazása nagy kihasználatlan file-területet és többszintű indexstruktúrákat eredményez. Az olyan alkalmazásoknál pedig, ahol az adatbázis olyan rekordjainak törlését kell végrehajtani, amelyek egy másik rekordhoz több szintre hasadt indexhierarchián keresztül kapcsolódnának és a törlés az indexhierarchia inverz végigjárását is igényelné, a törlés a batch feldolgozás szempontjából is reménytelen, rekordonkénti több perces nagyságrendnyi ideig tartana.

A vizsgálat eredménye volt a rekordok közötti kapcsolatok többszintű indexhierarchiáját felépítő és kezelő algoritmus lényeges elemeinek lokalizálása. Ismeretében rögzítettük a rekordok kontroll-területe, a rekordkapcsolatokat adminisztráló pointermezők méretei tervezésének azon módszerét, amellyel a tárgydalkódás és adatelérés szempontjából kiegyensúlyozott, hatékony adatbázisstruktúra alakítható ki.

Az empirikus vizsgálatokról nyert tapasztalataink birtokában általában elmondható, hogy a teljesítménymeghatározásnak ez a szintje a rendszertervezés számára szükséges információk megszerzésének gazdaságos módszere. A kapott eredmények kiindulási paramétereit képezhetik egy teljes hálózati rendszer /- amelynek középpontjában az adatbáziskezelő áll -/ más úton, szimulációs vagy analitikus eszközökkel történő tanulmányozásának.



### A Kutatási Fejlesztési Irányítási Információs Rendszerről

A Magyarországon folyó K+F tevékenységek országos szintű áttekintésének igénye éppúgy mint az egyes K+F helyek relatív "információs elszigeteltsége" sok olyan problémát vet fel, amely indokolttá teszi egy - ezzel a területtel foglalkozó - információs rendszer felállítását. Ahogy azt a Tudománypolitikai Bizottság számára készített egyik jelentés 1979-ben megállapította:

- a meglévő nyilvántartási rendszer bonyolult, megalapozott információs szolgáltatásra nem alkalmas, összetevői /a Kutatási és Fejlesztési Statisztika, az Országos Kutatásnyilvántartás/ az érvényben lévő rendeleteknek ugyan lényegében megfelelnek, de sem egymással, sem a valósággal nincsenek összhangban;
- az adatok feldolgozása decentralizáltan és részben manuálisan, részben számítógépen történik, ezért a kutatás és fejlesztés irányításához és tervezéséhez korlátozott lehetőséget nyújt;
- a K+F tevékenység költségkihatására, az eredmények gyakorlati hasznosításának felmérésére és ellenőrzésére, a gazdasági hatékonyság megítélésére a nyilvántartási rendszer nem ad lehetőséget;
- nem megfelelő az egyes kutatóhelyek, szervezetek adatszolgáltatási felelősségének és kötelezettségének, továbbá adatszolgáltatási területeinek meghatározása és így az információs szervezetek egymástól többé-kevésbé függetlenül - a gyakorlatban megvalósult módszerek szerint - önállóan tevékenykednek /többszörös adatközlési redundancia mellett tájékozatlanok maradnak/;
- nincs biztosítva a K+F tevékenység kívánatos mértékű átfogó áttekintése és ellenőrzése, a felesleges párhuzamos-

ságok kiküszöbölése, illetve a témák kidolgozásával kapcsolatos tárgyi és határidőbeli önkényes eltérések feltárása.

A felsorolt problémák legalább részbeni felszámolása érdekében - több korábbi, hazai és külföldi kísérlet tapasztalatainak felhasználásával - 1979-ben egy új program indult az ebben az előadásban ismertetendő KFIIR rendszer felállítására.

A KFIIR rendszer számára célként volt megfogalmazható, hogy javítani kell az irányítás, a kutató-fejlesztő munka koordinálásának színvonalát. Összehangoltan, az egyes részterületek között kiegyensúlyozottan szükséges gyűjteni a kutatásra, fejlesztésre és irányításra stb. vonatkozó információkat. A lehetséges és megfelelő hatékonyság érdekében megbízható adatok szükségesek a kutatási és fejlesztési tevékenységekről, a fejlesztésre fordított anyagi eszközökről, ezek megoszlásáról, az eredmények hasznosításáról, a kutató-fejlesztő helyek összetételéről, szerkezetéről.

Ennek érdekében a kutatási-fejlesztési tevékenységek információinak feldolgozására olyan rendszert fejlesztünk ki, amely:

- biztosítja a kutatási-fejlesztési feladatok nyilvántartását és megengedi a bővítő értelmű újraszervezést;
- megfelelő aggregáltságú információkat szolgáltat a K+F helyeknek és a tudománypolitika irányítóinak;
- biztosítja a kutatási-fejlesztési tevékenységek pénzügyi-anyagi ráfordításainak áttekintését;
- elősegíti a kutatási-fejlesztési eredmények hasznosítását;
- az eddiginél pontosabban nyilvántartja a kutató-fejlesztő helyek adatait.

A kitűzött célokat - a feldolgozandó információk nagy mennyisége és a közöttük fennálló bonyolult kapcsolatok miatt - egy számítógépes adatfeldolgozó rendszerrel támogatott információs rendszer keretében lehet elérni.

A célokból az információs rendszerre levezethető követelmények két csoportra voltak oszthatók.<sup>1/1</sup> Az első csoportba a K+F szféra információs, vagy pontosabban adatmodelljére, míg a másikba az adatmodell alapján elégségesen működni képes adatfeldolgozó rendszerre vonatkozó tartoztak.

<sup>1/1</sup> A követelményeknek most az informatikai vonatkozásairól van szó. Természetesen nem az államigazgatási, szervezeti, jogi vonatkozások "rovására", és nem az ezekkel szembeni elsőbbséget feltételezve vizsgáljuk tárgyunkat.

Az adatmodell tisztázása érdekében számos K+F intézményben és irányító hatóságnál folytattunk konzultációt. A konzultációk eredményeként nyilvántartásunk objektum típusaiként:

1. A hazai K+F tevékenységek bejelentései,
2. A nemzetközi együttműködésben végzett K+F tevékenységek bejelentései,
3. A licence, know-how vásárlások és eladások,
4. A K+F célú ki- és beutazások,
5. A kutatási dokumentációk,
6. A K+F intézmények,
7. A kutatással-fejlesztéssel foglalkozó személyek

tárgykörei voltak rögzíthetők. Javaslatként, illetve további tisztázás után bővítésként jöhetnek még számba a:

8. A nagyértékű és/vagy egyedi műszerek,
9. A K+F tevékenységek hasznosításai,
10. A K+F témák kapcsán keletkezett publikációk

tárgykörei.

Az 1-7 tárgykör csoportra szorítkozva az 1-5 pontok az általánosanabb értelemben vett K+F tevékenységeket, míg a 6-7 pontok az ún. K+F bázist jelentik. Az egyes tárgykör típusok - de különösebb a K+F tevékenységek csoportba tartozók - elemzése közben az derült ki, hogy:

- a tárgykörök jellemzésére használható egyes adatok nem formalizálhatók, csak szöveges leírásuk adható meg és mint ilyenek, gyakorlatilag végtelen értékészlettel rendelkeznek; /2/
- nagyon sok az egyazon tárgykörön belüli más objektum előfordulásra, és a más tárgykörök előfordulásaira vonatkozó utalás, azaz nagyon sűrű a kapcsolattípusok hálójája;
- az egyes tárgykörök előfordulásai /például egy konkrét hazai K+F téma/ adataikban időfüggőek. Időfüggőkegyrészt abban az értelemben, hogy felbukkanásukkor "tervezet" jellegűek és később "tény" jellegűvé alakulnak, másrészt abban az értelemben, hogy vannak az objektum felbukkanásakor nem

/2/ Ugyancsak a szöveges adatelemek irányába toltta el a rendszert az a tény, hogy a rendszer adatszolgáltatói /és igénylői is/ nem számítástechnikusok. Részükre formalizált előírást vagy kód-könyveket kiadni nemcsak lehetetlen de értelmetlen is. Az ilyen szervezés a K+F szféra nem eléggé előrelátható változásai és rendkívüli tematikus szélessége miatt elvileg nem keresztülvíhető.

értelmezhető vagy nem ismert adatok /például a K+F témák dokumentációira utalók/, amelyek az objektum jellemzőinek csak fokozatos, mozaikszerű felgyűjtését teszik lehetővé.

A felsorolt adattulajdonságok véleményünk szerint eltérőek a hagyományosan megszokottakról, érvényesítésük az adatmodell új vonásaihoz vezetett. Természetesen vannak a felsorolt tulajdonsággal nem rendelkező adatok is, ezek kezelésére a CODASYL modell elvei jól érvényesíthetők. Mivel ez utóbbiak tartalmuk szerint az objektumok állapotára vonatkozó információt hordoznak /jól formalizálható alakban/tényadatoknak/faktografikus adatoknak neveztük. Szembeállítva ezzel az első csoport adatai általános tulajdonságuk szerint a szöveges adatok nevet kapták.

Az eszköz vonatkozásában választásunk az IDMS-re esett, de ennek egyenlőre csak az elveit alkalmaztuk. A fokozatos rendszer-építésre vonatkozó elképzelésünk szerint az IDMS környezetébe továbbvihető, de hagyományos adatkezelési technikával is működtethető adatmodellt és szervezést valósítottunk meg. Ebben érvényesítettük a problematikus új tulajdonságokat:

- az adatmodell bővitéssel való továbbépíthetőségének eszméjét, /a fizikai adatbázis újraszervezésének kényezere nélkül/;
- az automatikus szövegnormalizálás eredményeként a generált adattípusok definiálásának lehetőségét;
- az ideiglenes kapcsolattípusok kezelhetővé tételét.

Az adatmodellünk témavázlatát Bachmann-diagramm formájában az 1. sz. ábra adja.

Az adatmodellről elmondottak /és a szervezeti követelmények/ az adatfeldolgozó rendszer kialakítását eléggé szigorúan determinálták.

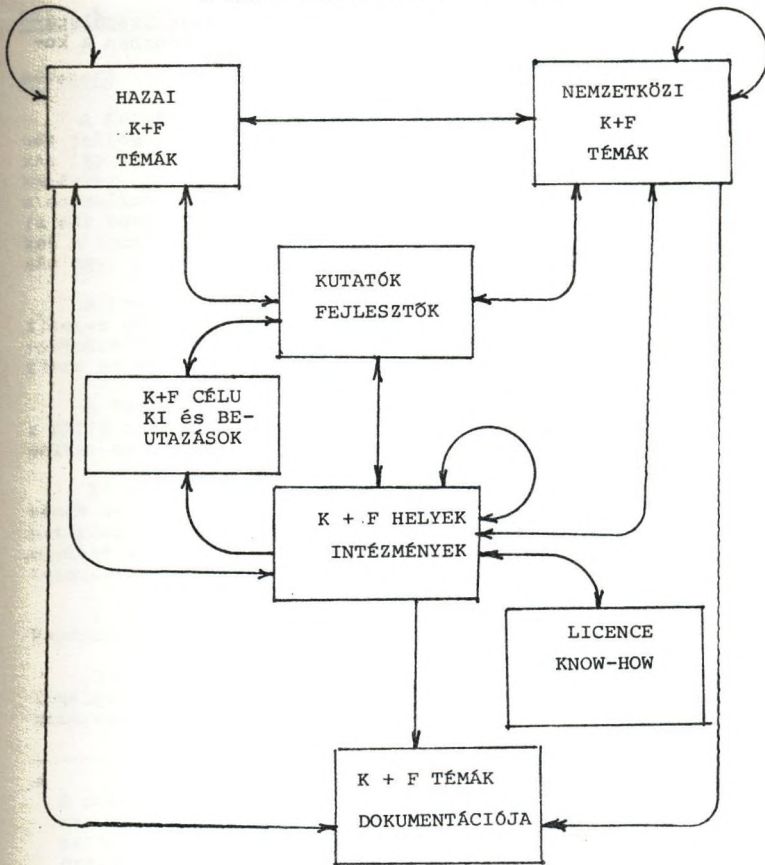
A fokozatos kifejelezhetőség érdekében jelenleg csak az egyes tárgykörök elkülönült feldolgozására alkalmas funkciókat építettük ki. Ezen funkciók azonban a tárgykörön belüli kapcsolatokat kezelik. Elsősorban arra törekedtünk, hogy a szöveg és adatnormalizáláshoz szükséges belső kapcsolatok éljenek. A funkciók IDMS környezetbe való továbbvihetőségének érdekében az adatkezelést egy interface-en keresztül bonyolítjuk, amely cserélhető.

Az adatszervezésben lehetséges változásokhoz, az adathiányos rekordelőfordulásokhoz, a szöveges adatok terjedelembeli dinamizmusához egy, a KGST országok által elfogadott NME2 rekord szervezési szabvány segítségével alkalmazkodunk.

Az adatnormalizálás céljára - ahol lehetséges- egy olyan ellenőrző tábla kezelő rendszert alkalmazunk, amely az ellenőrző konstansokat logikai kapcsolataik alapján hálós szerkezetben képes kezelni.

1. sz. ábra

A KFIIR adatmodell sémavázlata



Végezetül néhány adatot szeretnénk ismertetni a KFIIR rendszer jelenlegi állapotáról:

- a rendszer nyilvántartó funkciói már működnek,
- végrehajtottuk 25000 hazai K+F téma bejelentésének feldolgozását,
- a témák /bejelentések/ automatikus hasonlóságvizsgálatának végrehajtásával segítséget nyújtunk elsősorban a kutató helyek számára.

KFIIR fogalmi szótár kezelő és karbantartó rendszer

Bevezető

A KFIIR rendszer adatfeldolgozó rendszere elsősorban szöveges jellegű, ún. dokumentum tárgyköröket kezel, az adatfeldolgozás így alapvetően szövegkezelést jelent. A szövegkezelés a rendszer input oldalán normalizáló lépések sorozatára bomlik; a normalizálás célja a dokumentumok olyan átalakítása, amely /a már bevitt dokumentumokat figyelembevéve/ az újonnan bekerülőket a többivel összehasonlíthatóvá teszi. Az összehasonlíthatóság egy, a dokumentumtérben bevezetett kvázimetrikán nyugszik.\*

A normalizáló lépések nyelvfüggő lexikai /szövegelemfeltáró/, illetve részben nyelvfüggetlen szemantikus /fogalomfeltáró/ csoportokra oszthatók. Mind a két csoport támaszkodik a fogalmi szótárra és annak kezelő rendszerére.

A fogalomfeltáró szótárral /FFSZ/ kapcsolatos követelmények a KFIIR rendszer egyéb részeinek függvényében a következőképp voltak megfogalmazhatók:

1/ Az FFSZ tegye lehetővé több nyelv szó- és fogalom készletének kezelését. A többnyelvűség ellenére az FFSZ a lehetőségek határáig támaszkodjon közös /adat-/szervezési elvekre, így minimusként tartsa be az ISO és a KGST többnyelvű információkezelő tezauruszokra vonatkozó előírásait;

2/ engedje meg néhány a lexikai elemzéshez szükséges szókapcsolat ábrázolását /nyelvfüggő módon/;

3/ engedje meg néhány a szemantikai elemzéshez szükséges fogalmi kapcsolat ábrázolását /nyelvfüggetlen módon tezaurusz-  
struktúra formájában/;

\*

A dokumentumtér metrizálása nemcsak egy szabványos matematikai és dokumentumábrázolási /tárolási/ formalizmust tesz lehetővé, hanem segítségével a visszakeresési módszerek egész családja vált kipróbálhatóvá és egymással összehasonlíthatóvá. Így a hagyományos kulcsszavas módszerek is.

4/ automatizáltan biztosítsa a tezaurusz-struktúra ellentmondás- és redundanciamentes /tovább/építésének lehetőségét;

#### 1. Fogalmak és osztályozásuk - a fogalmi szótár

A KFIIR szöveges adatkezelő rendszerében szótári bejegyzés-nek nevezünk minden olyan /1/ a rendszer által ismert nyelvé /2/ szövegrészletet, amely /3/ alkalmas egy vagy több dokumentum jellemzésére. /Számunkra az egyik legkitüntetettebb osztály a fogalom megjelölésre használható névszói kifejezéseké, ezért a szótár neve fogalomfeltáró szótár/.

A fogalomfeltáró szótár bejegyzések strukturált halmaza, amelyben a struktúrát fogalmi és formai kapcsolatok biztosítják.

A szótári bejegyzések értelmezését egészítsük még ki a következő jegyekkel: /4/ a szótári bejegyzések tetszőleges hosszúsága karakter stringek, /5/ amelyeknek kódja van, és /6/ aspektusa/i/ van/nak/. Aspektuson olyan önkényesen kiválasztott osztályozó jelzést értünk, amely a szótárbejegyzés különböző értelmezéseinek megkülönböztetésére szolgál. Az aspektus-típus fogalmilag is, formailag is a bejegyzés részének tekintjük.

A szótári bejegyzések több egymástól független szempont szerint osztályozhatók: a fogalmi szótárbeli létezésük módja, nyelvük, bonyolultságuk és indexelési értékük szerint.

Létezésük módja szerint vannak aktív, a szótáradminisztrátor által szövegelemzésre, indexelésre kijelölt bejegyzések, és inaktív a szövegelemzésből, indexelésből kizárt, azaz logikailag törölt bejegyzések.

A nyelvek szerinti osztályozás nem szorul magyarázatra. Az internacionális alakokat azonban az alkalmazó nyelvek szótáraiban meg kell ismételni. A különböző nyelvé, de azonos értelmű szavak /kifejezések/ szótári bejegyzéseinek kódja szigoruan azonos. Ez a kikötés biztosítja a fogalmi kapcsolatrendszer nyelvügetlen ábrázolhatóságát.

Bonyolultságuk szerint megkülönböztetünk egyszerű /általában egyszavas/ és összetett /általában többszavas/ bejegyzéseket. Az egyszerű alakok elsősorban a lexikai elemzés céljait szolgálják és a szavak töjellegű alakjait adják meg, míg az összetettek lényeges támpontjai a szemantikai elemzésnek. A lexikai egységek tehát alacsonyabb fogalmi szintet képviselnek és biztosan egyszerűek, míg a szemantikus egységek egyszerűek és összetettek egyaránt lehetnek.

Az indexelési érték szerinti osztályozás a szemantikus elemzés eszköze. Megkülönböztetünk deszkriptorokat, amelyek a szöveg tartalmi osztályozásához közvetlenül felhasználhatók, non-deszkriptorokat amelyek közvetve használhatók fel, és stoplista elemeket, amelyek a rendszer szempontjából indexelési értékkel /emberi döntés alapján/ nem bírhatnak.



## 2./ A fogalomfeltáró szótár kapcsolatrendszer

A fogalmi szótárt kapcsolatai teszik strukturált halmazzá. A bejegyzések között feszülő kapcsolatok tipizálhatók, és két fő típusuk különböztethető meg. A felosztás azonban nem diszjunkt, vannak mind a két fő típusba beletartozó kapcsolatok. Az egyik fő típus a lexikai elemzéshez használható típusokat foglalja magába, a másik a szemantikus elemzéshez használhatókat.

A fogalmi szótár bejegyzései közötti kapcsolatokat bináris relációknak tekintjük és azt mondjuk, hogy az A és B szótárbejegyzések R relációban vannak, ha  $A, B \in \text{FFSZ}$  és a szótár biztosítja az  $A, B$  átmenetet. /jelölve:  $A.R.B$  /.

A KFIIR fogalomfeltáró szótárának megengedett kapcsolatait az 1. sz. táblázat definiálja és foglalja össze.

## 3./ A fogalmi szótárbeli kapcsolatok tulajdonságai

A fogalmi szótár építése közben egy új kapcsolat felállítása szabályokhoz van kötve. A szabályok logikájának megértéséhez érdemes a kapcsolatok tulajdonságait külön megvizsgálni.

Reciprok kapcsolatpárok: a kapcsolatok között vannak olyanok, amelyeknek bevezetése automatikusan maga után vonja ellentétes párjuk /inverzük/ bevezetését is. Például, a BT-bővítés NT-szüktés kapcsolatokra az A.BT.B $\in$ FFSZ állítás helyességéből következik a B.NT.A FSZ állítás helyessége. Az ilyen inverz párok teljes listája a következő.

2. sz. táblázat

<u>Direkt kapcsolat</u>	<u>Inverz kapcsolat</u>
BT	NT
USE	UF
SEE	SF
SNR	SNX
RT	RT
CPT	CT

Szimmetrikus kapcsolatok: azokat a kapcsolatokat, amelyekre az  $A.R.B \in \text{FFSZ}$  állítás helyességéből következik a  $B.R.A \in \text{FFSZ}$  állítás helyessége, szimmetrikusoknak nevezzük. A fogalmi szótárban értelmezett kapcsolattípusok között csak a rokonító /RT/ kapcsolat ilyen.

Tranzitív kapcsolatok: Tegyük fel, hogy az  $A.R_1.B \in \text{FFSZ}$  és  $B.R_2.C \in \text{FFSZ}$  kapcsolatok fennállnak. Akkor az A és C szótári bejegyzések egymással is kapcsolatban állnak. Ezt az újabb kapcsolatot nevezzük az  $R_1$  és  $R_2$  kapcsolatok szorzatának. A szorzatot R-rel jelölve  $R=R_1.R_2$  írható. Ha  $A.R.C$  kapcsolat 1. sz. táblázatunk

## 1. sz. táblázat

## A K A P C S O L A T

Csoportja	Neve	Tip.		Jele	Alternatív jele	Értelmezése
		Lex.	Szem.			
Hierarchikus kapcsolatok	Bővebb fogalom	x		BT=BROADER TERM	B /bővítése/	A.BT.B= A bővítése B /B értelmezése tartalmazza A értelmezését/
	Szűkebb fogalom	x		NT=NARROWER TERM	S /szűkítése/	A.NT.B= A szűkítése B /B értelmezése része A értelmezésének/
Utaló kapcsolatok	Használt mint	x	x	USE= REFERENTIAL USE	H /helyes alakja/	A.USE.B= az A helyes alakja B
		x	x	UF=USED FOR	IH /hibás alakja/	A.UF.B= az A hibás alakja B
	Lásd még	x	x	SEE=REFERENTIAL SEE	R /rövidítés/	A.SEE.B=A rövidítése B
		x	x	SF=SEEN FROM	IR /rövidítettje/	A.SF.B=A rövidítettje B-nek
Affinitív kapcsolat	Rokonítás		x	RT=RELATED TERM	K /kapcsolható/	A.RT.B= A kapcsolható B-hez és viszont
Aspektus kapcsolatok	Aspektus hozzárendelés		x	SNR=SCOPE NOTE	A /aspektusa/	A.SNR.B= A aspektusa B
			x	SNX=SCOPE NOTE	IA /aspektus	A.SNX.B=A aspektus B-hez
Összetett-szókapcsolatok	Összetevője	x		CT=COMPONENT TERM	IO /összetevője/	A.CT.B=A összetevője a B-nek
	Összetettje		x	CPT=COMPOSITE TERM	O /összetettje/	A.CT.B=A összetettje a B-nek

szerint értelmes, akkor R-t aktív-nak tekintjük, míg ha A.R.C önmagában nem értelmes, akkor R-t fiktív kapcsolatnak nevezzük. A fiktív kapcsolatok csak formálisan léteznek, értelmük nincs. Ezzel ellentétben aktív szorzatok a kapcsolatokat értelmesen ugyanazon a reláción belül továbbviszik; ezt a tulajdonságukat tranzitivitásnak nevezzük.

A FFSZ aktív szorzatai a következők:

3. sz. táblázat


BT.BT=BT  
 NT.NT=NT  
 USE.BT=USE

CPT.CPT=CPT  
 CT.CT=CT  
 NT.UF=UF


Az aktív szorzatok felhasználásával tranzitív kapcsolatláncok építhetők, amelyek eredménye feltétlenül helyes és értelmes kapcsolat marad.

Ellentmondásos kapcsolatok: szótárbejegyzések szorzatkapcsolaton keresztül értelmetlen relációkba állíthatók. De nemcsak az ilyen kapcsolatok kerülendőek, külön figyelmet kell fordítani az 1.a ábra szerinti helyzetek elkerülésére is. Itt az A.BT.B.BT.C és a C.BT.A kapcsolatok nem lehetnek egyszerre igazak.

1. ábra



a/ Ellentmondásos kapcsolatlánc



b/ Redundáns kapcsolatlánc

Redundáns kapcsolatok: új kapcsolatok bevitele nemcsak ellentmondásos, hanem felesleges is lehet. Ez akkor áll elő, ha az újonnan bevinni kívánt kapcsolat mint szorzat aktív. Az 1.b ábra példáján: az A.BT.B.BT.C kapcsolat aktív volta miatt az FFSZ-nek a A.BT.C kapcsolattal való kiegészítése felesleges.

Ha a szótár egy állapot mentes az ellentmondásos és redundáns kapcsolatoktól akkor ezt a szótárállapotot konzisztensnek mondjuk.

A fogalmi szótár ellentmondás- és redundanciamentes építésének szabályai

A szótárépítéshez szükséges szabályok megadásakor induljunk ki abból, hogy új szótári bejegyzések bevezetése vagy a meglévők attribútumainak módosítása a szótár konzisztens voltán nem változtat. Hibás állapot így csak helytelen kapcsolatépítés követ-

kezménye lehet.

1/ Mivel egyszerre eredményez ellentmondást és redundanciát, tilos a szótárba az A.R.A. típusu, önmagára utaló, kapcsolatok bevitelle.

2/ Mivel két fogalom között ugyanazon kapcsolat bevitelének csak egyszer van értelme, az A.R.B & FFSZ típusu kapcsolatok ismételt bevitele is helytelen. /A működő FFSZ ezt megengedheti, de a kapcsolatrendszerre hatástalan. Az ismételt végrehajtás a kapcsolat megerősítéseként adminisztrálódik./

3/ Két különböző szótári bejegyzés között egyszerre csak egy aktív kapcsolat létezhet. Kivétel: az SNR-aspektus reláció, amely második kapcsolatként is megengedhető.

4/ Hierarchikus és affinitív kapcsolatot stoplista elemhez nem szabad definiálni.

5/ Utaló kapcsolatot csak deskriptorok és nondeskriptorok között szabad értelmezni.

6/ Az új kapcsolat bevezetése nem eredményezhet ellentmondásos vagy redundáns kapcsolatláncot. Mindkét esetben kapcsolat törléssel kell megelőzni a hibahelyzet kialakulását.

#### A fogalomfeltáró szótár és a dokumentációs adatkezelés viszonya

A fogalmi szótár IDMS eszközökkel kerül megvalósításra. Az ismertetés megkönnyítésére nevezzük régióknak az azonos sémában leírt, fogalmilag összetartozó areá-k csoportját.. /A különböző régiókhoz tartozó areákat fizikai adatszerkezési okokból nem célszerű egysíteni/.

A KFIIR adatfeldolgozó rendszere olyan sémára támaszkodik, amelynek régiói a szöveges illetve a faktografikus adatfeldolgozó rendszer régióiból állnak. A fogalmi szótár ezen belül a szöveges típusba ágyazódik. Ezt szemlélteti a 2. sz. ábra:


2. sz. ábra

FOGALOMFELTÁRÓ SZÓTÁR RÉGIÓ	1. DOKUMENTUMVEKTOR ÉS FOGALMI INVERZRÉGIÓ	FAKTOGRAFIKUS RÉGIÓK
	2.	
	3.	
	4.	

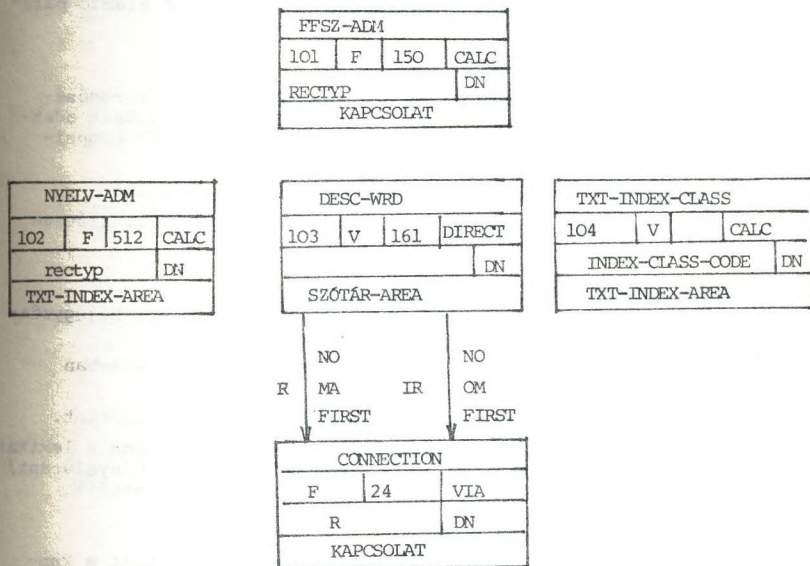
A KFIIR dokumentációs adatbázisában feltételezzük, hogy a fogalomfeltáró szótár olyan közös eszköz, amely egyszerre több dokumentációs adatbázis kiszolgálója. Erre utal a több rétegű dokumentumvektor és fogalmi inverzrégió.

A fogalomfeltáró szótár régiójának egy fokkal mélyebb szerkezetét a 3. sz. ábra mutatja.

3. sz. ábra



A fogalmi kapcsolatokat hordozó area a nemzetközi tezauruszajánlásoknak megfelelően közös az egyes nyelvi szótárak számára. A fogalomfeltáró szótár IDMS-diagrammja, mint a szerkezet kifejtésének következő héja, a 4. sz. ábrán látható.



Az egyes rekordtípusok szerepe és legfontosabb tulajdonságai a következők.

FFSZ-ADM: fogalmi szótár adminisztrációs rekord:

- leírja a fogalomfeltáró szótár egy verziójának általános adatait, /egyetlen példánya létezik minden verzióban/;
- nyelvüggetlen, ezért a KPACSOLAT-AREA-ban található,
- lokalizációs módja CALC.

Általános szótárleíró adatoknak tekintjük a szótár nevét, verziószámát, a verzió dátumát, az utolsó módosítás dátumát, a módosító menetek számát, a laponkénti bejegyzésszámot, a szótár aktuális kapacitáshatárát, a következő kiosztható adatbázis kulcsot, az aktuális fogalom kódszámát, a szöveges indexosztályok számát, a szótár tulajdonosának és felelősének nevét.

NYELV-ADM: nyelv adminisztrációs rekord:

- leírja a szótár egy konkrét nyelvi változatának nyelvészeti tulajdonságait;
- nyelvfüggő, ezért a TXT-INDEX-AREA-ben található,
- lokalizációs módja CALC;
- nyelvenként egy előfordulása van.

Nyelvészeti tulajdonságként tartjuk számon a nyelv nevét, a nyelvhez tartozó lexikai-elemző program/csomag/ nevét, az elemző által használt táblázatok könyvtárbeli neveit, az elemző paramétereinek default értékeit.

TXT-INDEX-CLASS: szöveg index rekord

- a szótárbejegyzések szövegük alapján történő kereséséhez szükséges index táblázat. Az egyes bejegyzések adatbázis kulcsát /kódját/ és szövegét sorolja fel komprimált formában értékpár táblázat szervezéssel.
- nyelvfüggő, ezért a TXT-INDEX-AREA-ban található;
- lokalizációs módja CALC, a bejegyzés komprimált szövege alapján.

DESC-WRD: fogalmi szótár bejegyzés rekord

- a szótár egy bejegyzésének hordozója, leírja a bejegyzésbeli szó/deszriptor tulajdonságait.
- mivel nyelvfüggő, a nyelvhez tartozó SZÓTÁR-AREA-ban található.
- lokalizációs módja DIRECT a bejegyzés KÓD-ja szerint.

A szótár bejegyzések tulajdonságaként tartjuk számon a lexikai elemzéshez szükséges jellemzőket a bejegyzésbeli szótó/nyelvtani/tipizálás kódjait, a szemantikai elemzés szabályazonosítóit.

CONNECTION kapcsolatleíró rekord

- egy konkrét kapcsolat hordozója, amely megnevezi a kapcsolat típusát /BT,NT...../ és a kapcsolat értelmezését segítő aspektust;
- A KAPCSOLAT areában található;
- lokalizációs módja VIA az előremutató R-set alapján.

6/ Jellemző adatok a szótárról

A hozzáférés gyorsasága becslés szerint az IS elérésmódhoz hasonló. A szótár helyigénye 200 000 bejegyzést és 600 000 kapcsolatot, a magyar nyelvet, 48 Byte-os átlagos bejegyzés hosszát és IBM-2314 diák tárolót feltételezve 140 cylinder, 19.8 MB.

Irodalomjegyzék

- MCNT: Pravila razrabotki mnogojazyčnuk informacionno-póis kovuh Tezaurusov, Moszkva, 1976
- 174-75 KGST szabvány: Egy nyelvű információkereső tezausz. "Tartalmi, formai, ábrázolási szabályok."

- Guidelines for establishment and development of multilingual scientific and technical thesauri for information retrieval. UNESCO SC/WS/50. Paris 1971
- A.Chepkasov: INIS: Thesaurus Maintenance System International Atomic Energy Agency, Vienna, 1977
- Varga Dénes: Információs tezauruszok készítésének módszertana OMKDK, Budapest, 1969.
- Horváth Tibor - Varga Dénes: Információs tezauruszok, Budapest, 1978.

Több lépéses duális clusterezési algoritmus alkalmazása  
információs rendszerekben

Bevezető

A szöveges információs rendszerek szempontjából alapvető fontossága a dokumentumok és a fogalmak clusterezése. A clusterezések végrehajthatók manuálisan vagy automatikusan. A manuálisan végzett clusterezés nagyon munkaigényes és ezért nehezen tudja követni a dokumentumok és fogalmak jellegében mutatkozó változásokat. Az automatikus clusterezés teljeskörű végrehajtása még számítógéppel is jelentős ráfordításokat igényel. Ugyanakkor a visszakeresés teljessége és pontossága is csak akkor lesz elfogadható ha a clusterezést a kérdésből kiindulva hajtjuk végre.

A clusterezési eljárással szemben támasztott követelmények a következők:

- legyen korrektül deffiniált, vagyis minden dokumentum vagy fogalom halmazon adjon eredményt;
- az eredmény legyen független az input adatok sorrendjétől;
- az eljárás legyen stabil, vagyis a kiinduló adatok jelentéktelen változása csak jelentéktelen mértékben módosítsa az eredményt;
- az eljárás legyen független a léptéktől, vagyis az objektumok koordinátáinak konstans értékkel történő szorzása nem változtathatja meg az eredményt;
- nagyon hasonló tulajdonságú dokumentumok nem kerülhetnek különböző clusterekbe.



Az általunk választott clusterező eljárás a kérdésből indul ki

-/ez biztosítja a rugalmasságot/ -

a teljes dokumentum állomány statisztikai tulajdonságai alapján

-/ez biztosítja a stabilitást/ -

két osztályba a releváns és nem releváns dokumentumok osztályába

sorolja a dokumentumokat. Az algoritmus többlépcsős végrehajtása kényelmes eszközt biztosít a válasz pontosságának és teljességének hangolására.

#### Dokumentum - Dokumentum tér

Az előbbieken vázolt problémák vizsgálatához vezessük be a következő fogalmakat - definíciókat.

A KFIIR adatfeldolgozó rendszerében dokumentumnak számít a nyilvántartás meghatározott tárgyköreinek kijelölt szöveges kódolású adataiból/rovataiból álló minden rekord. A dokumentumok jele: d.

A dokumentumok nyilvántartott halmazát dokumentum térnek nevezzük és D-vel jelöljük.

A dokumentumokra és a dokumentum térre igazak a következő jellemzők:

- D1. A dokumentumoknak azonos nyelvű rovatok előfordulásából kell állnia.
- D2. A dokumentumok minden egyes rovatának az eredeti rekord-típusa által meghatározott és a rendszer adatmodelljében rögzített súlyt tulajdonítunk.
- D3. A dokumentumok egymás között eltérő nyelvűek lehetnek, ezért a nyelv a dokumentum minősítője.
- D4. A dokumentum térben az egyes dokumentumok egyértelmű /numerikus/ azonosítóval rendelkeznek.

Tételezzük fel, hogy képesek vagyunk a dokumentumok rovatbontásán túl a dokumentumok fogalmainak meghatározására is. A dokumentum térben előforduló összes fogalmak halmazát fogalomtérnek nevezzük.

- T1. A fogalomtérben az egyes fogalmak egyértelmű azonosítóval rendelkeznek.
- T2. A fogalomtér nyelvfüggetlen. A fogalmak tényleges előfordulásának nyelve nem a fogalmak minősítője, hanem az adott dokumentumoké.

Tehát a dokumentumtér alatt az egyes dokumentumokban előforduló fogalmak azonosítóiból képzett vektorok összességét értjük.

$$D = \{ \bar{D}_j \} \quad \text{ahol} \quad \bar{D}_j = (f_{j1}, f_{j2}, \dots, f_{jt_F}) \text{ és}$$

$$f_{ji} = \begin{cases} 0 & \text{ha az } f_i \text{ azonosítóju fogalom nem fordul elő} \\ & \text{a } j\text{-edik dokumentumban} \\ S_{ji} & \text{az } f_i \text{ fogalom sulya a } j\text{-edik dokumentumban} \end{cases}$$

Hasonló módon fogalomtér alatt az egyes fogalmak dokumentumtérbeli előfordulásainak azonosítóiból képzett vektor összességét értjük.

$$F = \{ \bar{F}_i \} \quad \text{ahol} \quad \bar{F}_i = (d_{i1}, d_{i2}, \dots, d_{it_D}) \text{ és}$$

$$d_{ij} = \begin{cases} 0 & \text{ha az } f_i \text{ azonosítóju fogalom nem fordul elő a} \\ & j\text{-edik } i \text{ dokumentumban} \\ S_{ji} & \text{az } f_i \text{ fogalom } D_j \text{ azonosítóju dokumentumban} \\ & \text{való előfordulásának sulya.} \end{cases}$$

Mindkét téren értelmezzünk egy távolságfüggvényt

$$R(D_k, D_j) = \frac{\sum_{i=1}^{t_F} (S_{ki} \cdot S_{ji})}{\sqrt{\sum_{i=1}^{t_F} (S_{ki})^2 \cdot \sum_{i=1}^{t_F} (S_{ji})^2}}$$

valamint

$$R(F_i, F_l) = \frac{\sum_{j=1}^{t_D} (S_{ji} \cdot S_{lj})}{\sqrt{\sum_{j=1}^{t_D} (S_{ji})^2 \cdot \sum_{j=1}^{t_D} (S_{lj})^2}}$$

Ezeket relevancia együtthatóknak nevezzük, segítségükkel bevezethetők mindkét téren a "környezet" a "pont sűrűség" fogalmak.

Tovább menve a keresőkérdéseket is tekintsük dokumentumnak, amelyeket - normalizáljuk és ideiglenesen szintén a dokumentum térbe illesztünk. Egy ilyen kérdés dokumentumhoz /alkalmas hasonlósági kritérium alapján/ meghatározhatjuk a hozzá legközelebb eső dokumentumok halmazát, amit a hasonló dokumentumok "nulladik cluster"-ének nevezhetünk. A 0-clusterbeli dokumentumok azonosítói, mint a fogalomtérbeli koordinátaértékek es, pontot határoznak meg a fogalomtérben. A távolságfüggvény /és alkalmas fogalmi rokonsági

kritérium/ segítségével meghatározhatjuk a fogalmak egy másik, fogalomtérbeli clusterét, amelyek ehhez a ponthoz "legközelebb" helyezkednek el. Ezen fogalmak azonosítói, mint a dokumentumtér koordinátaértékei egy pontot definiálnak a dokumentumtérben. Azt a pontot a "pontosított" kérdésnek nevezhetjük, az eddigi tevékenységet pedig a kérdés "értelmezésének" vagy pontosításának.

A távolságfüggvény segítségével meghatározhatjuk a pontosított kérdéshez legközelebb eső dokumentumok halmazát.

Ezt a halmazt nevezhetjük a dokumentumok "első cluster"-ének. A pontosítási lépés addig ismételhető amíg az előirt tulajdonságokkal rendelkező clustert előállítjuk.

Az ismertetésre kerülő algoritmust természetes nyelvű dokumentumok tartalmi hasonlóságának elemzésére használjuk a KFIIR-ben. A kifejlesztett programcsomag ESZER számítógépen OS/VSI operációs rendszer alatt hatékonyan és megfelelő pontossággal működik.

Az ismertetett eljárást assembler nyelvű keretprogram hajtja végre. A minden lényeges funkciót külön rutin valósít meg. A fejlesztés során a problémás rutinokból több verziót készítettünk el. Ezeket cserélgetve kísérlet sorozatok során hangoltuk rá a rendszerünket a dokumentumterünkben tárolt rendkívül szerteágazó tematikájú szövegekből történő visszakeresésre. Ilyen problémás rutinok:

- clusterek határainak meghatározása,
- a súlyok képzése,
- a pontosítás konvergenciája,
- a zaj leválasztása. Ha van jó válasz könnyebb. Ha nincs jó válasz nagyon nehéz.

A KFIIR hazai kutatási+fejlesztési témák leírásait feldolgozó alrendszerében jelenleg 25.000 dokumentumot tárolunk. Ezek mindegyike 150-200 fogalmat tartalmaz. Az összes előfordult szótövek száma kb. 120 000 ezeket képeztük le a kb. 20 000 fogalmat tartalmazó fogalomtérre. Egy kérdés egyszeri pontosítással történő megválaszolása 35-40 másodperc CPU időt használ fel. Minden további pontosítás 20-25 másodpercet igényel.

A rendszer fejlesztését a leképzés tökéletesítésével, valamint a problémás rutinok további verzióinak kipróbálásával folytatjuk.

#### Irodalom

1. Gerard Salton: Dynamic Information and Library Processing

ETKR: egy általános gráfkezelő rendszer

I. Ha egy számítógépes rendszer ugynevezett emberi tulajdonságait próbálnánk mérni, intelligenciájának kétségtelenül alkotó része lenne a rendszer alkalmazkodóképessége a valós környezethez, alakíthatósága a megváltozott viszonyokhoz. Az is nyilvánvaló, hogy változó ismereteket nem lehet és nem is szabad beleépíteni a rendszer egyetlen programjába se. Ilyen leválasztott tudás pl. modern fordító-értelmező rendszerekben a szótár, illetve szótőtár, amelyhez egy csatolórutin biztosítja a hozzáférést. Az ilyen cserélhető szótárak lehetővé teszik pl. egy rendszer speciális szakterületre leszűkített, viszont ezen területen szinte hibamentes alkalmazását. A fent vázolt probléma felmerült a KFIIR rendszer kifejlesztése során is. Itt is több helyen szükség volt olyan tudás reprezentálására, amely a rendszertől függetlenül létrehozható illetve aktualizálható. Ezt a tudást csatolórutinok teszik hozzáférhetővé a rendszer tetszőleges elemei számára.

Ezeknek az igényeknek a kielégítésére született meg az az általános gráfkezelő rendszer, amely most előadásunk tárgya. Mivel a rendszer első sorban bizonyos triviális visszavezetések és ellenőrzések céljára létrehozott ugynevezett ellenőrző táblák kezelésére jött létre, illetve erre lett elsődlegesen alkalmazva, a neve Ellenőrző Tábla Kezelő Rendszer, röviden ETKR.

II.1. Az ETKR tervezésekor különböző igények merültek fel, mind formai, mind funkcionális szempontból. Ezek közül nézzünk néhányat.

1/ Többféle tartalmu, funkciójú ellenőrző táblákat /gráfokat/ létre tudjon hozni, ezeket tárolja egy erre a célra létesített könyvtárban és innel vissza tudja tölteni a memóriába;

- 2/ Alapvető igény a gyorsaság szempontjából, hogy használatához a táblának teljes mértékben a memóriában kell lennie.
- 3/ A táblák elemei tetszőleges felépítésűek lehessenek, amelyet a felhasználó által megadható rutin kezel. Alapértelmezésben a táblaelemeket a rendszer karaktersorozatként kezeli.
- 4/ Az elemek között többféle kapcsolatot lehessen definiálni, irányítva vagy irányítás nélkül, és ezeket a kapcsolatokat mnemonikkal is lehessen jelezni. Ezek lesznek a gráf "színezett" élei.
- 5/ A gyors elemeléréshez meg lehessen adni egy hash-kód képző függvényt /szintén opcionálisan/, amely az elemek osztálybasorolását végzi.
- 6/ A tábla memóriabeli megszorításoktól eltekintve tetszőlegesen bővíthető legyen a memóriában mind elemekkel, mind köztük definiált kapcsolatokkal.

III.2. Nyilvánvaló, hogy a tábla nem lesz egységes szerkezetű, hiszen optimális helykihasználást fix hosszúságú elemrekeszek nem tesznek lehetővé, másrészt a hashelés miatt egy ugynevezett hash-táblát mindenképpen külön kell választani a tábla más részeitől. Ugyanakkor az is természetes, hogy minden táblának tartalmazni kell speciális, csak rá jellemző információkat, pl. a hash-osztályok száma, a táblában definiált kapcsolatmnemonikok, a felhasználó speciális rutinjainak nevei, stb. Még azt vegyük figyelembe, hogy az elemek között elvileg korlátlanul definiálható kapcsolatok miatt a gráfok csúcspontjait és éleit el kell különíteni egymástól.

A kezelő rendszerre vonatkozóan alapvetően azt kell szem előtt tartani, hogy bár a táblákat más rendszer fogja alkalmazni, mint amelyik létrehozta és aktualizálja, a működés alapelemei, az elemi gráfkezelő funkciókat ellátó primitivek azonosak kell, hogy legyenek.

III.3. Végül az alkalmazói és gépi korlátok adta megszorítások által szabott mederben a rendszer a következő formát öltötte:

1. Táblák; könyvtárbeli formájuk: Minden táblának alapvetően két formája létezik. Egy memóriabeli ábrázolás és egy könyvtárbeli ábrázolás. Azért lehet és kell ezt a két formát szétválasztani, mert a két tárolási formának teljesen más a funkciója. A memó-

riában a gyors hozzáférést kell biztosítani minden elemhez, ugyanakkor a tábláknak rugalmasan bővíthetőeknek kell lenniük. A könyvtárbeli táblánál az a legfontosabb szempont, hogy a háttértárolóra való kivitel és az onnan való beolvasás között a tábla egyes részeire nem történik külön hivatkozás. Tehát a belső ábrázolástól teljesen eltérő formát alakíthatunk ki.

Alapvetően háromféle rekordkép létezik a könyvtárbeli tárolásnál. Az első fajta rekord a tábla fej-részének információit, a második fajta rekord az egyes elemeket és a hozzájuk tartozó kapcsolatláncot, míg a harmadik a hashtáblát tárolja. A könyvtárban természetesen abszolút címek helyett mindenhol relatív címek szerepelnek.

2. A táblák tárbeli felépítése: Minden tábla legfeljebb négy, a memóriában függetlenül elhelyezkedő mezőből áll, melyeket az első mező, a táblafej alapján lehet elérni. Itt tárolódnak a táblát jellemző adatok, az egyes mezők címei, hosszuk, a definiált kapcsolatok memonikjai, kódjai, stb.

A másik mező amelyet mindenképpen tartalmaznia kell a táblának, az elem-mező. Ez az egyetlen olyan mező, amelynél nincsen fix szerkezet, eltekintve persze a szükséges mutatóktól. Az itt levő elemek tetszőleges szerkezettel rendelkezhetnek.

Az ugynevezett pointer-mező az, amely az elemek közötti kapcsolatokat tartalmazza, azaz a gráf éleit reprezentálja, mutatók formájában. Minden élnek egy bejegyzés felel meg, ha kétirányu a kapcsolat, akkor kettő.

Ha nincs megadva a táblához pointer-mező, akkor egy egyszerű hash-elérésű elemtárat kaptunk.

Az utolsó mező a hash-mező, amely szintén opcionális. Hiánya esetén az elemek listába lesznek felfűzve, ugyanugy, mintha hashelő függvényünk egy osztályba sorolná az elemeket. Ez a mező annyi elemű, ahány hash-osztályba soroljuk az elemeket, és egyes elemei vagy üres mutatót /null-pointert/ vagy az adott lánc első elemének címét tartalmazzák.

3. A rendszer felépítése.  
A táblák létrehozására és aktualizálására /update/ alapvetően egy keretrendszer szolgál, mely közbenső csatoló rutinokon keresztül, a rendszer primitívjeivel végzi mű-

ködését. A keretrendszer képes táblák létrehozására, bennük kapcsolatfajta definiálásra, törlésre, illetve elemek beépítésére, illetve törlésére. Ezenkívül az elemek mint csúcspontok között élek /konkrét kapcsolat/ létrehozására illetve megszüntetésére.

A rendszer alapelemei, a primitívek, alapvető gráfkezelő funkciókat valósítanak meg, mint például egy csúcspont vagy él definiálása, illetve megszüntetése, egy csúcspontból kiindulva egy-egy lépés megtétele a gráfban adott színű él mentén stb.

A rendszerben használt primitívek természetesen tetszőleges programból aktivizálhatók, a megfelelő környezet kialakítása révén: ez a környezet egy szabvány felépítésű paramétertábla, amelyen keresztül a rendszerelemek messzemenően képesek egymással kommunikálni. Így az egyetlen paraméter a paramétertábla címe, amelyet a rendszer komponensei átadnak egymásnak.

4. A felhasználó által irt rutinok is ezt az egyetlen paramétert használják. Egy táblához három ilyen, ugynevezett "user-rutin" adható meg, melyeket a primitívek képesek aktivizálni.

Az első rutin melyet kötelező megadni, két tetszőleges táblabeli elem azonosságát kell, hogy eldöntse, természetesen ismerve az elemszerkezetet.

A második rutin végzi a hash kód képzését.

A harmadik felhasználói rutin segítségével megadható az elem ellenőrzése, konvertálása, illetve változtatni lehet az elemek közül /hasonlóan a SORT eljárások rekordmódosító felhasználói eljárásaihoz/. Így pl. ez a rutin végezheti az elem konvertálását a külső /nyomtatási/ illetve belső /memóriabeli/ alak között, illetve a táblakönyvtárba való kivitel előtt, illetve visszahozatal után.

- II/4. Ezek után nyilvánvaló, hogy rendszerünk ellenőrző táblákon kívül, sokkal szélesebb körben alkalmazható. Vegyük például a néhány éve nagyon divatos szemantikai hálók problémáját. Az ilyen ugynevezett mélyszerkezeti struktúrák számítógépes megvalósítása nagyban hozzájárul gyakorlatban történő alkalmazásukhoz és ezzel az elmélet fejlődéséhez. Az ETKR tulajdonképpen egy kész eszköz ilyen jellegű próbálkozások felé, hiszen csupán az elemszerkezetet ismerő felhasználói rutinokat kell

elkészíteni az elmélet létrejötte után és már gyakorlatban lehet a további lépéseket megtenni.

Könnyűszerrel átültethetők az ETKR nyelvére és segítségével kezelhetők bizonyos irányító-vezérlő tevékenységhez tervezett parancs-paraméter táblák is.

Mindössze a rendszer szempontjából szükséges felhasználni rutinokat és csatolórutinokat kell elkészíteni a primitívek használatát megkönnyítő különböző alkalmazásoknál. Ez utóbbihoz makrókészlet áll a felhasználó rendelkezésére.

### III. Az ETKR rendszer használata /alkalmazásai/

A jelenleg megvalósított rendszer a KFIIR információs rendszerünk szerves része, mely PLIOPT és 370-es ASSEMBLER-ben íródott meg, ESZR gépeken OS/VSI operációs rendszerben. Mivel a kezelt ellenőrző táblákat a memóriában tárolja, nagymértékben növeli a feldolgozás sebességét.

A felhasználás során egyidejűleg öt táblát használunk, melyeknek betöltése másfél- két perc, helyfoglalásuk pedig több száz Kbyte. Ezek a táblák egyrészt fastrukturájúak, egyszerű hashelést tartalmaznak, másrészt többféle relációt tartalmazó ún. szegmensellenőrző táblák. Ez utóbbiakban lehetőség van több rovat tartalmának együttes ellenőrzésére, adatok korrekciójára, illetve pótlására hiányos vagy hibás bejelentés esetén. Az ETKR rendszer helyfoglalása attól függően, hogy milyen mértékben használjuk a rendszerelemeket 50-200 Kbyte között van. Jelenleg kb 10 primitívvel és kb ugyanannyi csatoló rutinnal rendelkezik.



Zvara Flórián  
Honvédelmi Minisztérium  
Budapest  
1052. Pf. 117.

## DINAMIKUS LISTÁZÓ

A KFIIR rendszerben, mint szöveges információs rendszerben különleges listakészítési gondok merültek fel. A gondok a szöveges adat és formátum elemek nagy számából, az adatelemek terjedelembeli változékonyságából, a feldolgozandó rekordok adatelem állományának egy elvi maximum alatti rendkívüli mobilitásából, több forrásból való összeszerkeszthetőség igényéből, valamint a sokszorosítható /kézbe adható/ listatermék követelményéből származtak.

Célunk volt egy olyan listázó nyelv és listázó program kifejlesztése, amellyel könnyen áttekinthető lista készíthető úgy, hogy közben minél nagyobb szabadsági fokkal lehessen azt megtervezni és leírni.

Listázási nyelvnek azt a makro-assembler nyelven írt esz-közt tekintjük, ami a listakép kódolására szolgál.

A listatervezés és a listaleírás elkészítése a teljes listázási folyamatnak egy önálló szakaszát jelenti, és teljesen elválasztható a tényleges listázástól /nyomtatástól/. Célja a listaleírás létrehozása.

A listaleírás tartalmazza mindazokat az információkat és adatokat, amik a listakimenet külső formáját írják le. Egy listaleírás csupán egyetlen listakimenet formátum létrehozására szolgál. Ezáltal annyi listaleírást kell készíteni, ahány féle formájú listát elő szeretnénk állítani.

A listaleírásoknak forrás és load modul formájuk létezik, amelyek a szokásos könyvtárkezelő eszközökkel tarthatók karban. A könyvtárazás egyúttal kényelmes lehetőséget nyújt egy "lista-menü" kialakítására, illetve listasorozatokkal operáló összetettebb szolgáltatások szervezésére.

Az alkalmazott listaleírás lényeges vonása, hogy elsősorban az eredményt írja le, az input rekordokra vonatkozóan elvileg semmilyen megszorítást nem tesz. Az inputtal való kapcsolat leírására kizárólag egyetlen eszköz, a nyomtatott adatok neveinek megadása szolgál.

Az implementált listázó változat a KFIIR rekordszervezési szabványának megfelelően az ISO-2709/1971 /KGST NME-2/ előírást használja. De mivel a rekord-szerkezet jellemzőit csupán egy adatkezelő modul tartalmazza, és azt is kizárólag az adatnevek segítségével vezérli, a modul kicserélésével egyszerűen áttérhetünk más rekordszerkezetre.

A listázó további jellemzői:

- egyszerre több rekordból történhet a listázás, s az egyes rekordok adatait párosíthatjuk egymással; csoportosíthatjuk őket.

Kiíratásukat feltételekhez köthetjük. A feltételek megadásával az alábbiakat valósíthatjuk meg:

- . a csoport elemeit csak akkor nyomtatjuk ki, ha az első elem nem üres /azaz tartalmaz kinyomtatandó adatot/.
  - . ha a csoportnak akár egyetlen eleme üres, akkor egyik elemet sem listázzuk ki,
  - . a csoport első elemét csak akkor listázzuk, ha a többi eleme között van nem üres.
- a listára kinyomtathatók előre megadott konkrét szövegek is /amiket nem tartalmaznak a rekordok/. Ezek a szövegek - listázási szempontból - egyenértékűek a rekordok adatalemeivel. Használhatjuk őket a rekord-beli adatalemek feliratozására, meggyararolásra stb.

- automatikus függőleges irányu tömörítés.  
A hiányzó adatok helyét nem hagyjuk üresen a listán, hanem az alákerülő adatokat felfelé toljuk.
- kérhető átmozgathatóság is.  
Ekkor a program kis mértékben megváltoztatja a megtervezett lista képét a nyomtatásra váró adatok számára és méretének megfelelően, úgy, hogy az tömörebb legyen.
- lapszerkesztési lehetőségek:  
Lapdobást irhatunk elő ill. tilthatunk meg.  
A/4-es nagyságu listatervek esetén kérhetjük a lapok egymás mellé ill. egymás alá történő nyomtatását.  
Soremelést adhatunk meg az adatelemek /ill. azok csoportjai/ előtt.
- a sorokra történő tördelés és a szavak soron belüli elhelyezkedése paraméterezhető /jobbra-balra sorkizárás/.
- lehetőség van kiemelésre többszörös ráütéssel. \*\*
- lehetőség van speciális rutinokkal egyedi problémák megoldására, azaz olyan listakép kialakítására, amely a rendelkezésre álló eszközökkel nem érhető el másként.
- külső fejléc rutin csatlakoztatható a listázóhoz, amellyel a mindenkori igénynek megfelelő fejléc alakítható ki.

A listázó Assembler nyelven íródott. Gyorsasága elsősorban a listaleírás nagyságától függ. A/3-as méretű listatervek esetén egy-egy lap 1 sec-nél kevesebb CPU idő alatt készül el.

-----

\*\* Kérhetjük az adatok teljes körű kiemelését, vagy pedig (ha a lista soroknál van minden sor elején egy az egy-két szó, ami a sorok közötti tördelést jelöli).

A KFIIR /általános szöveges-faktografikus információ kezelő rendszerének/ általános programeszközei

A Kutatás-Fejlesztési Irányítási Információs Rendszer fejlesztése során az [1] -ben ismertetett okok miatt törekednünk kellett arra, hogy programeszközeink a lehető legáltalánosabbak legyenek, a különféle követelmény-változásokkal szemben stabilitást mutassanak.

Igyekeztünk ennek megfelelően rendszerünket olyan strukturában megvalósítani, mely módot ad a többcélú alkalmazásra, egy alkalmazáson belül a követelmények változásának követésére, csatlakozásra a nemzetközi információcseréhez, biztosítja a hardware hibákkal szembeni kellő megbízhatóságot.

Ezeket a célokat az előadásban ismertetett szervezési módszerekkel és koncepciókkal valósítottuk meg.

### 1. Módszerek

#### 1.1. Általános, specializálható, de gyors folyamatok szervezése

Az egész rendszert folyamatok összességeként fogjuk fel, melyek lehetnek ciklikusak is. Az egyes folyamatok nagyobb, logikailag összetartozó feldolgozási lépéseket valósítanak meg.

Az egyes folyamatokat jobok sorozata alkotja. Az egyes jobok közötti kapcsolat

- . file-okon keresztül
- . visszatérési kódban
- . üzemeltetői ellenőrzés/beavatkozás

formájában valósul meg.

Az, hogy a folyamatokat sok job alkotja, lehetőséget nyújt a számítógép hardware bizonytalanságainak a leküzdésére, mert a hibásan végrehajtott jobokat meg lehet ismételni.

Az egyes jobok /programok/ szerkezete olyan, hogy a lényegi, minden alkalmazásra vonatkozó, és a külső követelmények változásától nem függő funkciókat a programokba beépítettük, míg az adott alkalmazástól függő speciális ismereteket és feladatokat jól elkülönített modulok tartalmazzák ill. oldják meg. Ennek megfelelően az általános programok önmagukban csak minimális tevékenységet

/mint pl. üres tevékenység vagy file-másolás/ valósítanak meg, és biztosítják potenciálisan korlátlan számú speciális /valódi feldolgozó/ tevékenység csatlakoztatását.

## 1.2. Nemzetközileg elfogadott adatábrázolási előírás

A KFIIR rendszerben tárolt adatokat elsődlegesen a [2] -ben definiált NME2 formátumban tároljuk, mely a nemzetközi műszaki információcsere alapvető formája. Ennek a Műszaki Előírásnak az ISO-megfelelője a [3]. Műszaki információcserében széles körben használják a [2] -n alapuló MEKOF-2 ill. MEKOF-1 Normatív-Műszaki előírást, mely definiálja az egyezményes megengedett adatalemeket, és azok belső azonosítóit /"hívőjeleit"/ is. E két előírásnak a mi ábrázolásunk nem tesz eleget, elsősorban, mert az általunk tárolt információk csak részben esnek egybe azokkal az adatokkal, melyre a MEKOF előírásokat létrehozták. Nem okoz azonban nehézséget a MEKOF előírásokra történő konvertálás vagy ilyen anyagok átalakítása a KFIIR szellemében.

Lényeges különbség, hogy a KFIIR rendszerben az egyes hívőjelek nincsenek örökre definiálva, hanem minden egyes alkalmazásban, vagy akár az idők során egy alkalmazáson belül egy adatalem-azonosító jelentése változtatható, mint ahogy változtatható az adatalemmel kapcsolatban elvégzendő ellenőrző-feldolgozó tevékenység is.

## 1.3. Adatfüggetlenség biztosítása adatkezelő modulok segítségével

Az elemi adatok kezelésére külön adatkezelő programmodulokat alakítottunk ki, az adatokhoz történő hozzáférés csak ezek segítségével történik. Igaz ez az NME2 formátumu, az invertált, szótár- és segédfilejainkra, ellenőrző táblázatainkra egyaránt.

Ez megfelel a modern "információ-elrejtési" elvnek, és lehetőséget nyújt arra, hogy szükség esetén az elemi adatábrázolást megváltoztathassuk anélkül, hogy a feldolgozó programokban változtatni kellene. Ehhez csak azt kell biztosítani, hogy az új szerkezet szerinti adatkezelő eljárások felhasználói képe a régivel azonos legyen.

## 1.4. Speciális információk és funkciók elválasztása, azok algoritmikus megadása

Már az I. pontban utaltunk arra az alapelvre, amit mi "a keretprogramok elvének" nevezünk, éspedig, hogy a folyamatok vezérprogramjai csak olyan általános funkciókat valósítanak meg, melyek adott információhalmaz sajátosságaitól nem függenek.

Egy keretprogram önmagában még nem kész eszköze az információs rendszernek, hanem azt ki kell egészíteni az adott információhalmaz sajátosságait tükröző részekkel. Ezek megadják a halmaz lehetséges adatalemeit, az azokkal kapcsolatos néhány általános tulajdonságot, azok ellenőrzési szempontjait, származtatott adatok esetében a származtatás módját stb.

Lényeges tulajdonsága a rendszernek, hogy nem szab korlátot a lehetséges adatalem-fajták mennyiségének, és a köztük fennálló kapcsolatoknak, illetőleg a lehetséges ellenőrzések bonyolultságának sem.

Ilyen nagy adaptálhatóság célul történő kitűzésekor viszont felmerült az a probléma, hogy nehéz lenne olyan speciális adatle-

író nyelvet kialakítani, mely tükrözné mindazokat a tulajdonságokat, lehetséges feldolgozási módokat, amelyek az adatokkal kapcsolatban egyáltalán előfordulhatnak. Egy ilyen nyelvvel kapcsolatban két fő probléma lépne fel:

- Nem lenne teljes, idővel óhatatlanul felmerülnének újabb, korábban figyelembe nem vett követelmények;
- Nagy munkát jelentene a nyelv implementálása, melynek egy jelentős része kárba veszne: sok olyan tulajdonságot kellene általános formában megvalósítani, melyeket konkrétan nem, vagy csak kis részben hasznosítanánk. Ez kihatna az egész rendszer hatékonyságára is, mert az általános algoritmusok általában kevésbé hatékonyak, mint a konkrét esetre alkalmazottak. Láthatunk erre elegendő példát az univerzális programozási nyelvek implementációi körében is.

Ezek alapján úgy döntöttünk, hogy a konkrét /KFIIR rendszerre jellemző/ sajátosságokat nagyjából algoritmikusan, univerzális programozási nyelvek eszközeivel fejezzük ki. Ennek megfelelően a rendszerben tárolt minden egyes konkrét vagy potenciális, inputból eredő vagy származtatott adatelemmel kapcsolatba hoztunk egy eljárást, mely az adatelemmel kapcsolatos ellenőrző/generáló funkciókat valósítja meg. Megengedjük az adatelemek ismétlődését, ebben az esetben azonos eljárást asszociálunk az összes ismétlődéssel. Ha több adatelemnek együttesen kell valamely kritériumnak eleget tennie, akkor ezeket együtt egy potenciális, aktuálisan meg nem jelenő adatelemnek tekintjük, /adatszégmens/, és egy csoportos ellenőrzést/generálást megvalósító eljárást asszociálunk vele.

A keretprogramok számára azt kellett még biztosítani, hogy össze lehessen őket kapcsolni tetszőleges számú eljárással, meg lehessen adni nekik tetszőleges számú adatelemet. Ez többféle technikával is megvalósítható. Minden esetben a végleges programot egy hármás alkotja: Keretprogram + adatleírás + eljárásgyűjtemény.

#### a/ Preprocesszoros technika.

A leírást a PLIOPT preprocesszor értelmezi; a keretprogramból és a megadott eljárásgyűjteményből egy specializált PL/I nyelvű forrásprogramot kompilál. Ugyanez a módszer alkalmazható PL/I és Preprocesszor helyett Assembly és Makrogenerátorral is.

#### b/ Rutinkapcsolásos technika

A leírás egy táblázat, melyet külön erre szolgáló eszközzel generálunk /Assembly makrók/. A futó keretprogram a leírást értelmezi /triviális értelmezés/, és a linkage editor által a táblázathoz csatlakoztatott eljárásokat aktivizálja, majd azok vége után értelmezi az egyezményes visszatérési kódokat. A specializált program csak bináris kód alakjában áll elő, a linkage editor hozza létre.

## 1.5. Programok moduláris felépítése, strukturált programozás

A modularitásnak és strukturált programozásnak esetünkben igen nagy szerepe van, mivel a környezetben beállott változások általában a speciális tulajdonságokat tükröző eljárásgyűjtemény változtatásával /programmódosítással/ kell követni. Ezért eljárásaink kicsik, a különböző eljárások által használt tevékenységek /adatkezelés, hibáüzenetek, szövegkezelés stb/ közös modulok belépési pontjaiként vannak implementálva, a névkonvenciókat könyvtári forrásprogram-szeletek /INCLUDE-tagok/ használata könnyíti meg, a forrásprogramok strukturáltan, ember számára könnyen olvasható alakban készülnek.

## 2. A KFIIR rendszer folyamatai

Az alább ismertetendő folyamatok mindegyikát a fenti "általános program - speciális tulajdonságok algoritmikus megadása - specializálás - késztermék-használat" koncepció alapján hoztuk létre. Megközelítésünk természetesen nem előzmény nélküli, így pl. az IBM Sort/Merge utility-je is variálható adatbeviteli és kiíratási felhasználói eljárások csatlakoztatásával, és hasonló lehetőségeket találhatunk egyes adatbázis-kezelő rendszerekben is. Nálunk azonban ez a koncepció lényegét képezi: minden speciális ismeretet az eszközspezializálás során adunk meg, a legáltalánosabb /adatelemenként legfeljebb néhány bittel ábrázolható/ tulajdonságokat kivéve mindent algoritmusban, és az így csatlakoztatott felhasználói eljárások a folyamatok legtöbbjében tetszőleges számúak lehetnek. /Természetesen egyszerűbb folyamatoknál erre nincs mindig szükség/.

A KFIIR rendszer az alábbi főbb folyamatokból áll:

- adatfelvitel; karbantartás szövegnormalizálással; rendezések; szótárkezelés; invertált file kezelés; hálós kapcsolatok gráfrepresentációjának kezelése; szöveges- ill. tényadat-visszakeresés; dinamikus szövegszerkesztés és listázás; leválogatások faktografikus kritériumok szerint; szöveges hasonlóság-vizsgálat.

## 3. Komponens-osztályok

- . a folyamatok keretprogramjai
- . speciális ismereteket megtestesítő un. "felhasználói eljárások"
- . a keretprogramok és az eljárások kapcsolatát biztosító tábla; az ezzel kapcsolatos apró, de fontos assembly eszközök;
- . közös adat- ill. szövegkezelő modulok.

### 3.1. A felhasználói eljárások

Két kategóriába sorolhatók:

- egy keretprogram általános, adatelemektől független bővítésményei. Ilyenek lehetnek pl. a címkefeldolgozó ill. rekord-válogató eljárások, parancselemzés, hash algoritmus, tábla-

elemek ekvivalencia-definíciója, rendezések input-és output eljárásai stb.

- az egyes adatelemekkel vagy logikailag összefüggő adatelem-csoportokkal kapcsolatos eljárások. Ugyanaz az eljárás különböző adatelemekkel kapcsolatban is megadható, továbbá az egyik elem eljárása hívható másik elem eljárásából. Adatelem-csoportnak lehetnek közös adatelemei.

### 3.2. Kapcsolattábla /adatleírás, funkcióspecifikálás/

Hasonlóan a felhasználói eljárások két csoportra osztásához, egy állandó és egy változó részből áll. Az állandó részben adhatók meg

- pufferek címei, méretei,
- flagek a felhasználói eljárások és a keretprogram közti vezérlő információk átadására,
- az egyes adatelemektől független felhasználói eljárások belépési pontjai

A változó rész annyi "bejegyzésből" áll, amennyi az elemi adatok, szintetizált adatok és a csoportos ellenőrzések összmenyisége. A bejegyzésekben megadásra kerülő általános tulajdonságok pl: adatelem azonosítója, külső megnevezése, egyes programokban az adatelem maximális hossza, egyedi/csoportos ellenőrzést ir-e elő, inputból származó vagy generált adatelem, részt vesz-e invertált /általában: redundáns/ információ képzésében vagy nem, ismétlődéses-e az adatelem, stb. Ezen felül csak az esetleges ellenőrző/generáló eljárás belépési pontját, ill. az annak hiányát jelző flag-et találjuk a leírásban.

### 3.3. A kapcsolattábla assembly eszközei

A rutinkapcsolásos technika esetében assembly makrók segítségével állítjuk elő a kapcsolattáblát. Assemblálás után ez programmodul formájában található, a felhasználói eljárásokra feloldatlan külső hivatkozásokat tartalmaz. A keretprogramot, a táblát és a felhasználói eljárásokat a linkage editor szerkeszti egységes programmá. Ettől kezdve a keretprogram hol adatmezőnek, hol programkomponensnek tekinti a táblázatot. Pontosabban, a benne szereplő belépési pontokat programcímekként kell értelmeznie, amit a PL/I nyelvben nem lehetne adatelemként kezelni. Így az összeszerkesztett program előre /a forrásprogramban/ definiálatlan számú szubrutint akar hívni. Ezt egy apró assembly rutin felhívásával oldjuk meg /készítette: Bondy István/. A rutin paraméterként megkapja a kapcsolattábla egy bejegyzésének a címét és a felhasználói eljárásnak szánt paramétereket. Ez a bejegyzésben /adatként/ megadott eljárás címet felismeri, és a megfelelő eljárást a PL/I konvencióknak megfelelően aktiválja.



#### 4. Tapasztalatok:

A rendszer fejlesztésekor megtakarítottuk egy bonyolult, de kellőképpen általánossá úgy sem tehető adatleíró nyelv kidolgozását és implementálását. Az egyes ellenőrzések eljárásai többnyire néhány sorosak, de lehetőség van több száz soros, több modulból definiált feldolgozások /leképezések/ felhasználói eljárásokként való megadására /pl. szövegek leképezése lényeges fogalomkódok sorozatára/. Kiváló eszköz módszerünk a dekompozícióra, funkciók külön cserélhetőségének biztosítására.

A karbantartás keretprogramját a KFIIR rendszeren belül két különböző eljáráscsomaggal használjuk. A preprocesszoros technikával egyetlen keretprogramból nagyon sok specializált tényadat-visszakereső és táblázó eljárás készült. A gráfrepresentációju ellenőrző-táblázatokon az ekvivalencia-reláció megadása mindig egyedi, a hashelés algoritmusá az adatok függvényében változik. A dinamikus szövegszerkesztővel igen különböző formájú és tartalmu, sok szöveges leírást tartalmazó, áttekinthető táblát definiáltunk és állítottunk elő.

Az egész rendszert a KFIIR-től teljesen független információrendszer előállítására is alkalmazzuk az államigazgatás területén. Lehetőség van a KFIIR-rel kapcsolatos vállalati ill. ágazati információs rendszerek speciális igényeinek olyan ki-elégítésére, melyek lehetővé teszik az ágazatnál /vállalatnál/ a központi és a helyi adatok együttes kezelését, azokból egyszerű eszközökkel a KFIIR számára szükséges adatok mágneses hordozón történő átadását, mégpedig ellenőrzött adatokkal.

A rendszer jelenleg R35 gépen, OS V51 operációs rendszer alatt működik, a KFIIR rendszer több tízezer K+F bejelentés adatait tartalmazza.

A tervezett szolgáltatások körét tovább bővítjük.

#### Irodalom

- [1] Bertalan József: A Kutatási-Fejlesztési Irányítási Információs Rendszerről NJSZT Kongresszus, Székesfehérvár, 1983
- [2] Коммуникативный формат записи данных на магнитной ленте ИТП МЦНТИ, 1-74, 1974, Москва
- [3] Magnetic tape labelling and file structure for information interchange, ISO/R 100, 1969

Teljes dokumentumok normalizálása természetes nyelvű információs rendszerben

Természetes nyelvű információs rendszerekben a beérkező szöveges információkat valamilyen módon normalizálni kell, azaz alkalmassá kell tenni gépi feldolgozásra. Ennek legelterjedtebb módja a géprevitel előtti kódolás. Hosszabb, természetes nyelvű szövegek kódolása csak gép segítségével történhet hatékonyan.

Rendszerünkben a gépi szövegnormalizálás főbb lépései a következők:

- szórabontás
- kódolás /szótömeghatározás, szótári kód hozzárendelés/
- a kódolt szavak fogalmi visszavezetése főszókódokra /fontos szavak kódjaira/

I. A szórabontás

Egy dokumentum több rovatból áll. Ezek közül csak néhány, a rendszer szempontjából lényeges rovatot kell normalizálni. Kiválogatjuk a szórabontandó rovatokat. Minden rovat külön rekordba kerül. A szórabontás eredményeként keletkező szavak is külön-külön rekordba kerülnek. Minden egyes rekord tartalmazza az eredetre vonatkozó információkat, s így a normalizálás végén ismét összeállnak az egy dokumentumhoz tartozó információk.

A rovatok szórabontásáért három táblát használunk:

- nagyon gyakran előforduló lényegtelen szavak táblázata
- kötőjelel kapcsolható egyes táblázata
- pontos tartalmú rövidítések táblázata

A szó és jelkészletet négy diszjunkt részre osztottuk fel:

- terminológiai jelek
- alfabétikus jelek
- egyéb jelek
- karakterjelek

## A szórabontás elvei a következők voltak:

- Szónak tekintünk egy terminátorjelekkel határolt karaktersorozatot, ha tartalmaz A-beli elemet, de K-beli nem, feltéve, hogy nincs benne a lényegtelen szavak táblázatában.
- Nem szó az /NUK/-beli elemekből álló karaktersorozat.
- A K-beli elemet tartalmazó alfanumerikus karaktersorozatokra környezetfüggő vizsgálatot végzünk. Esetünkben K elemei: a kötőjel, a mínuszjel és a pont.
- Ha egy karaktersorozat csak alfanumerikus jeleket és pontokat tartalmaz, akkor ellenőrzendő, hogy benne van-e a rövidítések táblázatában. Ha igen, akkor egy szónak tekintjük. Ellenkező esetben vesszük a sorozat kezdetétől az első pontig terjedő karaktersorozatot. Ezt szónak tekintjük, ha nincs benne a lényegtelen szavak táblázatában. A csonkolt karaktersorozatra ez az eljárást addig ismételjük míg a karaktersorozat el nem fogy.
- Ha a karaktersorozat kötőjelet /vagy mínuszjelet/ is tartalmaz, akkor az utolsó kötőjelet követő karaktersorozatot megvizsgáljuk, vajon benne van-e a ragok táblázatában. Ha igen, akkor a ragot levágjuk. Ezután kihagyjuk az összes kötőjelet és tömörítjük a karaktersorozatot. Ha az így keletkező sorozat pontot tartalmaz, akkor ugyanugy járunk el mint az előbbi pontban. Ha nem tartalmaz pontot, nem lényegtelen szó és tartalmaz alfabetikus jelet, akkor az előállított karaktersorozatot szónak tekintjük.

## II. Szótárazás, kódolás

A szavak standard alakjának meghatározásához létrehoztunk egy szótárt. Egy szótári bejegyzés - egy szótár rekord - tartalmaz egy szót, a szót egyértelműen azonosító kódot, a szó hosszát, a szó bontástípusát és a szó összetevőinek kódjait.

A szó bontástípusának lehetséges értékei F, N, S, H, R, O, aszerint, hogy fontos szó /főszó/, nem lényeges szó, szinonimája valamely szónak, hibás alakja valamely szónak, rövidítése valamely szónak illetve összetett szó. A szó összetevőinek kódjai S, H, R típusnál a visszavezetett alak kódja, O típusnál a szóösszetevők kódjai.

A szótár jelenleg 110000 szót tartalmaz és folyamatosan bővül a beérkező új dokumentumok alapján.

## II. Szótárazás, kódolás

Szótárazás, kódolás alatt a következőket értjük:

- megnézzük, hogy a szó benne van-e a szótárban az adott alakban. Ha igen, akkor készen vagyunk, mert máris sikerült szótárazni és megvan a szótári kódja is.
- Ha a szót nem találtuk meg a szótárban, akkor elképzelhető, hogy ez csak azért történt, mert valamely szótárbeli szó ragozott vagy igekötős alakjáról van szó. Ezért csonkitjuk a szót egy karakterrel és ellenőrizzük, hogy a csonkított szó benne van-e a szótárban, valamint azt, hogy a csonkolt karakter lehet-e rag vagy végződés, amelyet le szabad vágunk.
- Ez a csonkolási sorozat addig tart, míg a szó két karakternyire fogy vagy valamely közbülső állapotot megtalálunk a szótárban.

Azok a szavak, amelyeket nem sikerült szótárazni, egy listán jelennek meg. Ezt a listát át kell nézni, a szükségessé szótárbővítést el kell végezni és a szótárazást újból lehet indítani a sikertelenül szótárazott szavakra.

A szótárazási folyamat igen sok szótárhoz fordulást követel és ez elég hosszú gépidőt vesz igénybe. Ezért a szótárhoz fordulások számának csökkentésére kidolgoztunk egy módszert, mely jelentősen csökkenti ezt a számot és így a gépidő igényt is. Lényege a következő:

Az ábécé szerint rendezett szavakból egy aránylag nagy adagot /200 Kbyte-nyit/beolvasunk a memóriába. Az azonos karaktorsorozatokból csak egyet olvasunk be. A beolvasással párhuzamosan építünk egy címtáblázatot valamint egy munkatábla építése is megtörténik. A címtáblázat minden eleme 4 byte hosszú: az első byte a szó hossza, az azt követő három byte a szó reaktív címe az első beolvasott szó címéhez képest. A munkatábla felépítése azonos a címtábláéval. A munkatáblában a szavak ábécé szerinti növekvő sorrendjében találjuk a szavakra mutató címtáblabeli bejegyzések címeit.

A szótárazó program megállapítja a táblában levő szavak maximális szóhosszuságát és először a maximális szóhosszúságu szavak szótárazását végzi. A sikeresen szótárazott szavakat megjelöli, ezekkel tovább nem foglalkozik. Ezután csökkenti a maximális szóhosszuságot eggyel. Ez az aktuális szóhossz, és most már csak az aktuális szóhosszúságu vagy annál hosszabb, még nem szótárazott szavakkal foglalkozik. Minden szótárhoz fordulás előtt ellenőrizzük, hogy az adott szó aktuális hosszú kezdete megegyezik-e az előzőleg szótárazott szó kezdetével. Azonosság esetén a szótárhoz fordul-

lás elmarad. Csupán a csonkolt darabról kell még eldönteni, hogy az lehet-e toldalék. Ezt egy olyan táblázatos ellenőrzéssel végezzük, amelyben a keresés hash-kód technikával történik, tehát igen gyors. Miután végeztünk az összes aktuális hosszúságú szóval, ismét csökkentjük eggyel az aktuális hosszatt és ismételjük az előbb leírtakat. Az algoritmus eredményét a két táblázat tartalmazza. A munkatáblában nullától eltérő hosszúsággal rendelkező szavak szótárázása minden tőhossznál sikertelen volt. Ellenkező esetben a szótárban találtunk lehetséges szótövet. Ennek kódját és a szótó hosszát tartalmazza a munkatáblához tartozó címtáblabeli bejegyzés, feltéve, hogy a toldalék is helyes volt. A keletkező output ugyanolyan felépítésű mint az input. Csupán a szótőkód mező és egy jelzőbit változik, ha sikerült a szó kódolása. Így szótár-update után ezt az outputot inputként használva csak a nem-szótárázott szavak szótárázását kell elvégezni.

Két lista készül. Az egyik a sikeresen szótárázott szavakat tartalmazza kódjaikkal együtt, a másik azokat a szavakat, melyeket nem sikerült szótárázni.

Ezzel a módszerrel 200 000 byte-nyi szó /20000-40000 szó/ 50-70 perc CPU idő alatt szótárázható. Ez elég gyors, ha figyelembe vesszük a szótár méretét.

### III. Főszókkódra /fogalomkódra/ való visszavezetés

Ez a lépés a normalizálás utolsó fázisa, melynek eredményeként előálló rekord tartalmazza

- a feldolgozás első fázisából adódó input adatokat, karakteres formában.
- A szövegfeldolgozásra szánt rovatok szótárázása után nyert alapszókkódvektorokat. Minden rovathoz egy alapszókkódvektor tartozik. Az alapszókkódvektor tartalmazza a rovatban előfordult szavak szótőkódjainak a sorozatát.
- A főszókkódra való visszavezetés eredményeként előállítható főszókkód vektorokat /minden szövegfeldolgozásra szánt rovathoz tartozik egy főszókkód vektor is/.
- A főszókkód vektorokból előállítható dokumentumvektort.

A dokumentumvektor tartalmazza egyszeres multiplicitással a szövegfeldolgozásra szánt rovatokból előállt főszókkódokat.

A szótárázás után előállítunk egy olyan állományt, melynek rekordjaiba összegyűjtjük az egy dokumentumhoz tartozó rovatok szótőkódsorozatait, az alapszókkódvektorokat. A főszókkódra való visszavezetés inputját lényegében az alapszókkód vektorok adják.

Az alapszókódvektor elemei szótári szótőkódok. Egy szótőkódhoz tartozó szótári rekord több típusú lehet /F, N; S, H, R, O/. Ha egy szó bontástípusa nem F és nem N, azaz a szó visszavezethető egy vagy több szóra, akkor ezt a 'fogalmi' visszavezetést megteesszük. Mindaddig végezzük ezt a visszavezetést, míg minden egyes szótőkódtól eljutunk olyan szótőkód(ok)ig, amelye(ket) már nem lehet visszavezetni újabb szóra, azaz amíg főszóhoz /F jelű/ vagy nem fontos szóhoz /N-jelű/ értünk. A multiplicitásokat, ciklusokat már menetközben kiszűrjük.

A főszókódvektorból egy összefésüléssel és a multiplikatások kiszűrésével nyerjük a dokumentum vektort. Ezzel a dokumentum normalizálása befejeződött.

Önmagában a normalizált dokumentumokat tartalmazó file-on lassú és nehézkes visszakereséseket végezni hasonlóság, illetve újdonságvizsgálatot produkálni. E tevékenységek elvégzéséhez szükségünk van két, egymás duális párját képező invertált file létezésére. Az egyik az un. dokumentumtér, amely az előbbieken leírt dokumentumvektorokból épül fel. A duális társ, az un. fogalomtér, inverze, azaz a fogalomtérben megtaláljuk az egyes fogalmak dokumentumtérbeli előfordulásainak helyét.

A KFIIR rendszer fentebb leírt komponensei már elkészültek, sőt elfogadható gépidő és periféria igények mellett üzemeltetjük is. Eddig kb. 24000 dokumentum feldolgozása történt meg, ezeken sikeresen folytattunk hasonlóság-vizsgálatot.

## LOGAR ADATBÁZISKEZELŐ RENDSZER

### I. ÁLTALÁNOS ÁTTEKINTÉS

A LOGAR egy mikrogépre épülő, interaktív adatbáziskezelő rendszer.

- mikrogépes: Z80 assembler nyelven íródott, így - különféle feltételek megléte esetén - bármelyik Z80 alapú mikrogépre adaptálható
- interaktív: felhasználói szintű párbeszédés üzemmódban működik
- adatbáziskezelő: tehát egy adatbáziskezelővel szemben támasztott általános követelményrendszert céloz meg. Ezt a fogalomkört nézzük meg közelebbről. Az adatbáziskezelőnek az alábbi főbb követelményeket kell kiélegetnie:
  - összetett logikai adatszerkezet kezelése: a LOGAR egy hálós /összetett hierarchikus/ felépítésű adatállomány kezelését biztosítja
  - minimális redundancia: a többszörös adattárolás elkerülését a LOGAR többféle eszközzel biztosítja /pl. az adatok közötti kapcsolatok pointerrel valóvalószínűsítéssel meg/
  - konkurrens felhasználói hozzáférés: a LOGAR biztosítja, hogy a tárolt és módosítás alatt álló adatokhoz egyidejűleg más felhasználó ne férhessen hozzá; ezen kívül egyidejűleg több terminál kiszolgálását biztosítja azzal, hogy a felhasználó által hívott rutinok reentrant-ak /ujra belépők/,
  - többféle adat-hozzáférési módszert támogat: a LOGAR által kezelt adatok elérhetőek kulcs szerint és kapcsolataikon keresztül is
  - adat-program függetlenség: a LOGAR egy adatbázis-leíró segítségével biztosítja, hogy a felhasználó egy logikai adatstruktúrát lásson, így az adatbázis felépítésének változtatása nem jár feltétlenül programmódosítással is
  - adatbiztonság: a LOGAR rendszer adatállomány másolással, illetve automatikus naplózással, helyreállításal biztosítja az adatok védelmét az esetlegesen fellépő hardware hibák ellen.

Az eddig ismertetett általános szempontok után tekintsük át a LOGAR sajátosságait:

- hardware környezet: a fejlesztés és a tesztelés a VIDEOTON VT20/A rendszerén folyt, de a rendszer - megfelelő alapsoftware megléte esetén - bármilyen Z80 alapú mikrogépre adaptálható. Az adatbázis floppy-n, fix-

vagy mozgófejes diszken, illetve diszkeken helyezkedik el. A software támogatja a többterminálos adatelérést, 4 terminálíg elfogadható hatásfokkal. Követelmény még a 64 kbyte-os memória megléte. A rendszer a mikrogépeken szokásos további perifériaválasztékot /printerék, lyukszalag/ is kiszolgálja.

- software környezet: a VT20/A rendszerre a LOGIC kifejlesztett egy LOGOS nevű, time-sharing operációs rendszert, mely támogatja a LOGAR futtatását. A LOGOS leírása külön dokumentációban szerepel. Más rendszereken is futtatható a LOGAR, ha az ott futó operációs rendszer az alábbi fő szolgáltatásokat nyújtja:

- dinamikus memóriakezelés
- szektorosan címző diszk-handler

/Az adaptálásban a LOGIC szakemberei támogatást nyújtanak./

- a kezelt adatbázis mérete, korlátai:

a file-ok maximális száma	128
a file maximális rekordszáma	$2^{16}-1$
egy rekordban lévő mezők maximális száma	128
az adatterület maximális mérete	kb. 16 Mbyte

A LOGAR területigénye: 14 kbyte.

## II. A LOGAR ISMERTETÉSE

### II.1. Az adattárolás, elérés elve

#### Logikai felépítés

Az adatbázis logikai elemei - a hagyományos terminológiával - file, rekord, mező.  
/A felhasználó szempontjából: adatállomány, tétel, jellemző./

Egy file tehát rekordokból épül fel, a rekordok pedig mezőket tartalmaznak. A hagyományos file-kezelőktől eltérően a LOGAR a file rekordjai közötti kapcsolatok létesítését is lehetővé teszi.

Egy adott rekord elérése kétféle uton valósítható meg:

1. Vagy ismerem a keresett rekord egyedi jellemzőjét /vagyis azt az azonosítót, ami a file-on belül csak ehhez a rekordhoz tartozik; ez különbözteti meg a rekordot a többitől/, pl. a gépkocsi típus file-ban a TRABANT - ez esetben a kért rekordot a rendszer szolgáltatja. Tehát a rekord elérése a file név /gépkocsi típus/ és rekord név /TRABANT/ alapján történik.



2. Vagy a kezembben van egy olyan rekord, melyhez a keresett rekordot rokonl kapcsolat fűzi. Ez esetben a rendszer a kapcsolatokon keresztül éri el a keresett rekordot /illetve rekordokat/.

A LOGAR-ban a különféle rekord-mezőket tartalmuk alapján csoportba soroljuk /rekordok által tartalmazott mezőket tipizáljuk - vagyis csoportokra osztjuk/. A csoportosítást a fizikai tárolás és a kezelés különbözősége indokolja. A csoportosítás szempontjait és az így keletkező 9 különböző típusu mezőt leolvashatjuk a következő táblázatból:

Fizikai tárolás szerint	Kezelési szempont szerint	Mezőtípusok
a mezőt az adat-rekord a direktben tárolja	szöveg	→ SZÓ
	szám	→ NUMERIKUS
	egyéb	→ DQB → DATUM
a mező nem a rekordban található, a rekordban csak egy hivatkozás van	a rekord egyedi jellemzője	→ KULCS
	a jellemző csak meghatározott értéket vehet fel kapcsolat	→ LISTA → REFA → REFF
	szöveg	→ TEXT

#### Fizikai felépítés

A kezelés megkönnyítése és a tárolóhely jobb kihasználása érdekében a LOGAR - egy file-on belül - fix hosszúságu rekordokkal dolgozik. A változó hosszúságu jellemzőket ezért a rendszer a rekordon kívül helyezi el, az úgynevezett szótárakban.

Az egyedi azonosítóval rendelkező adatrekordok eléréséhez a LOGAR az ún. hash-coding eljárást használja. Az eljárás-hoz szükséges, hogy az egyedi azonosítókat egy külön adatállományban - az ún. táblában - helyezzük el. Ugyanilyen okból, ugyanigy táblákban tároljuk a LISTA típusu jellemzők által felvehető egyedi értékeket.

Összefoglalva: a LOGAR három különböző típusu adatállományt kezel, e három file-típus az

adatfile  
a tábla és  
a szótár.

## Adatfile

A felhasználó definiálja, az általa meghatározott adatokat tartalmazza vagy direktben, vagy indirekt módon. Ez utóbbi esetben egy pointer tartalmaz, ami a keresett információra mutat. A rekordokat felépítő mezők - mint már előbb láttuk - 9 típusba sorolhatók. Nézzük meg közelebbről a különféle típusu mezők felépítését:

- szó típusú: szöveges, előre definiált hosszúságú információ. Közvetlenül a mezőben helyezkedik el.
- numerikus típus: max.  $2^{16}-1$ , 2 byte-on ábrázolt bináris egész, szintén a rekordban helyezkedik el.
- DCB típus: előjeles, előre definiált hosszúságú tízes szám. A mező direktben tartalmazza.
- dátum típusu: a századfordulóhoz /1900/ relatív év, hónap, nap. Belső kódolása egy 2 byte-os bináris információ, mely a rekordban helyezkedik el.
- kulcs típus: a kulcs az adott rekord egyedi értéke. Ez az érték egy táblában /az ún. elérési táblában tárolódik. Az adatrekord nem tartalmazza a kulcsot, csak egy pointer az elérési tábla megfelelő rekordjára. A mező így mindig 2 byte hosszú.
- lista típus: szintén táblában /az ún. érték táblában/ tároljuk, így a megfelelő mező csak az érték tábla rekordindexét tartalmazza 2 byte-on. Ezt a jellemző-típust akkor célszerű használni, ha az adott jellemző csak előre meghatározott értéket vehet fel, és ezek az értékek egy táblába előre összegyűjthetők.
- kapcsolat típus: /REFA, REFF/
  - REFA egy fia rekordról az apára mutató pointer.
  - REFF egy apa rekordról lemutat a legfiatalabb /ldőben utóbjára keletkezett/ fiura. A mező ezen kívül tartalmazza a fiulánk hosszát is, 2 byte-on.
- text típus: tetszőleges hosszúságú szöveges információ, mely egy szóban nem kerül elhelyezésre, így a mező csak egy 3 byte-os pointer lehet.

## File

A file típusú mező a rekordban nem tárolja az adatot, hanem csak a

file nevét tárolja.

A file típusú mező

lehetővé teszi az adatok tárolását a file rendszerben.

tartalmaz egy rekordpointert /ez mutat a kulcshoz tartozó adatrekordra/ és egy szótárpointert. Ez ad lehetőséget arra, hogy a rekordok egyedi kulcsához egy tetszőleges hosszú szöveges információ is tartozzék. Ezt a szöveget teszi el a rendszer egy szótárba és a szótárrekord pointerre kerül az elérési tábla mezejébe.

Pl.: a gépkocsi típus file kulcs típusu jellemzői közül a Ø1-es a TRABANT. Így a kulcs=Ø1, a szöveges megnevezés pedig a "TRABANT" string, ami egy szótárba kerül.

az érték tábla: ez is egyedi értékeket tartalmaz, de ez az egyedi érték nem tartozik egy file egy rekordjához, hanem az egész rendszerre vonatkozik. Ezért a táblaelemből hiányzik az adatrekordra mutató pointer.

A különböző típusu tábla-file kezelését a rendszer teljesen automatikusan végzi, a felhasználó számára szükségtelen ismeri azok felépítését és kezelési módját.

#### Szótár file

A rendszer a változó hosszúságú szöveges információt tárolására a szótár file-okat használja. A felhasználói rendszer létrehozásakor meg kell adni a szükségesnek tartott szótárak számát és méretét.

Ezután, ha el kell tárolni egy adott hosszúságú szöveget, a rendszer kikeresi azt a szótárt, amelynek elemhossza megfelel az eltárolandó szöveg hosszának, és ide teszi el a szöveget.

Az információrendszerek felhasználói  
szintű leírása adatbáziskezelő rendszerek  
alkalmazása esetén

A számítástechnika hazai terjedése következtében mind gyakrabban tapasztalhatjuk, hogy a vállalati információrendszerek egyes részeit az adatbázis-technika felhasználásával számítógépesítik. Jól segíti ezt a folyamatot az interaktív feldolgozásokat is lehetővé tevő számítógépek vállalati szintű tömeges terjedése, ami kedvező feltételeket teremt a korábban szinte egyeduralkodó batch rendszerek napi operatívítású on-line rendszerekkel való felváltására és ezen keresztül lehetőség nyílik az adatbázis-technika által nyújtott előnyök realizálására.

A DB-technika hazai alkalmazását illetően azonban egy ellentmondásos folyamatnak lehetünk tanúi: egyfelől öröndetesen növekszik a hazánkban hozzáférhető adatbázis-kezelő rendszerek és az interaktív számítógépek száma, ugyanakkor pedig ezek alkalmazás-technológiája területén alig tapasztalható előrelépés. Erre engednek következtetni az olyan jelenségek, hogy a kidolgozott adatbázis-rendszereket esetenként nem veszik üzemszerű alkalmazásba, az elkészült rendszereket gyakran többször is átdolgozzák, és hogy a felhasználók ritkán nyilatkoznak kedvezően a számukra kidolgozott DB-rendszerekről.

Az adatbázis-kezelő rendszerek alkalmazásával kapcsolatos problémák többsége - véleményem szerint - a számítógépesítés alapját képező felhasználói feladatmeghatározás hiányosságaira vezethető vissza. Kézenfekvő ugyanis, hogy a felhasználói feladat jelenti azt a kiindulási pontot, amiből elindulva az adatbázis szerkezete és működése megtervezhető, és a kialakított rendszerterv ezen a ponton még a felhasználóval is egyeztethető. Nyilvánvaló tehát, hogy amennyiben a hardware és software feltételek megfelelőek - amit kézen kapott DB software esetén eleve feltételezhetünk -, akkor a sikertelenség okát az alkalmazástechnika területén, és ezen belül is a felhasználói feladatmeghatározás pontatlanságaiban kell keresnünk. A következőkben ezért részletesen megvizsgáljuk a felhasználói feladatmeghatározás szerepét és annak változását a számítógép-alkalmazás egyes korszakaiban, elemezzük a feladatmeghatározás tartalmát befolyásoló tényezőket, majd megvizsgáljuk, hogy jelenleg mennyire teszünk eleget a feladatmeghatározással szemben támasztott követelményeknek.

## A felhasználói feladatmeghatározás szerepe

A vállalati számítógéppalkalmazás hazai gyakorlatában a felhasználói feladatmeghatározás nagyon változó szerepet töltött be. Általában nem tekintették a számítógéppalkalmazás önálló munkaszakaszának, habár jelentőségét korszakonként, ezen belül pedig vállalatonként, sőt projektenként is eltérően értékelték. Ennek megfelelően a feladatmeghatározás tartalma és funkciója is tág határok között változott.

A számítógépesítés kezdetén a felhasználói feladatmeghatározás szerepét a részletes rendszerterv töltötte be, mivel a kettő még nem vált szét egymástól. A számítógéptechnika /hardware/ akkori fejlettségi szintjét tekintve a rendszerterv és így szükségképpen a feladatmeghatározás is jórészt csak az input/output adatelemek rekordonkénti felsorolásából és a karakterek számának megadásából állt, amit a programozandó algoritmusok /pl. rekordok száma az egyes file-okban/, eleendőek is voltak, mivel a számítógépi eszközök választéke komolyabb tervezési optimalizálásra nem adott lehetőséget.

A lemezes tárolók megjelenésével és a különböző file-szervezési módszerek terjedésével a felhasználói feladatmeghatározás mind nagyobb szerepet játszott az alkalmazási rendszerek létrehozásában. Az új eszközök ugyanis egyrészt módot adtak arra, hogy az alkalmazás programrendszerét a megoldandó feladat viszonyaihoz igazítsuk, másrészt az erőforrások magas költségei és viszonylagos szűkössége /pl. a tárolóterület/ egy bizonyos határon túl rá is kényszerítette a tervezőket az optimalizálásra, mivel ellenkező esetben a feladatot esetleg nem is tudták volna megoldani.

Ilyen körülmények között a feladatmeghatározás tartalma szükségképpen kiszélesedett. Az adattípusok és a rekordszerkezetek megadása mellett szükségessé vált a lehetséges adatértékek részletes vizsgálata is. Ennek keretében a maximális adatértékek előfordulási gyakoriságát, a többszörös adatértékek előfordulását, a karakterek típusát, valamint a volumenadatokat kellett részletesebben feltárni ahhoz, hogy a programrendszer működését hatékonyabbá tudjuk tenni.

Az adatbáziskezelő rendszerek használatba vétele tovább növelte a felhasználói feladatmeghatározásnak a számítógépi feladatmeghatározásnak a számítógépi alkalmazási rendszerek kidolgozásában játszott szerepét. A DB-kezelő rendszerek ugyanis minden esetben megkivánják az adattípusok /egyed/, a lehetséges adatértékek /tulajdonság/, illetőleg az ezek közötti belső

kapcsolatok szisztematikus feltárását és rendezését, amit csak a felhasználói viszonyok részletekbe menő elvezése útján lehet elvégezni.

Az adatbázisok alkalmazásával a fejlődés tehát végül is oda vezetett, hogy a felhasználói feladatmeghatározás a számítógépal alkalmazás önálló munkaszakaszává vált, olyan értelemben, hogy alapos és részletekbe menő feladatmeghatározás nélkül ma már egyetlen DB-projekt sem számíthat automatikusan sikerre.

#### A felhasználói feladatmeghatározás tartalma

Nézzük meg ezek után, hogy konkrétan milyen tartalommal kell a feladatmeghatározást elkészíteni ahhoz, hogy abból hatékony programrendszer vagy DB-alkalmazás születhessen. Ehhez először is azt kell meghatározni, hogy a feladatmeghatározás hol és milyen helyet foglal el mint munkaszakasz az alkalmazási rendszerek fejlesztésében.

Azzal kell kezdenünk, hogy az előbb vázolt fejlődési folyamat a számítógépal alkalmazás folyamatában és módszerében is jelentős változásokat hozott. Korábban a koncepciókészítés, a nagyvonalú és részletes rendszertervezés képezték a számítógépi alkalmazási rendszerek létrehozásának egyes munkaszakaszait, és ezek a szakaszok a felhasználói, illetőleg a számítógépi oldalon végzendő munkálatokat egyaránt felölelték. Az egyes fázisok munkavolumene, valamint a szükséges ismeretek mélysége és a specializálódási igény szükségessé tette a munkaszakaszok tartalmának átstrukturálását, és magát a folyamat lebonyolítását is megváltoztatta.

Napjainkban a számítógépal alkalmazás leginkább a kétszintű tervezés módszerével történik, amikor is az egyes szinteken zajló munkálatok igen nagymértékben átfedik egymást. Az egyik szintet a felhasználói szint képezi, amelyben a szervező módszeresen összegyűjti mindazokat az ismereteket, amelyek a rendszerre vonatkoznak, majd ezek alapján kidolgozza a felhasználói feladat részletes megoldási tervét. A másik szintet a számítógépi megoldás szintje képezi, amelyben a programrendszer tervezője részletesen megtervezi a felhasználói rendszertervben leírt feladat optimális megoldását. Ezeket a munkálatokat azonban úgy kell elvégezni, hogy a két szinten végzett munkálatok valamilyen módon állandóan kölcsönös kapcsolatban legyenek egymással, mivel csak így lehet biztosítani az egyes szintek munkájához szükséges információkat.

Felhasználói feladatmeghatározáson /vagy felhasználói rendszerterven/ ezek után egy olyan részletes dokumentációt értünk, amely a megoldandó feladatra nézve mindezen ismereteket tartalmazza, amelyekre a feladat számítógépi megoldását végző programrendszer /vagy DB-rendszer/ megtervezéséhez és kivitelezéséhez egyáltalán szükség lehet.

Az ilyen céllal készült felhasználói feladatmeghatározás legáltalánosabban kétféle típusú információkat tartalmaz; olyanokat, amelyek közvetlenül belekerülnek a programrendszerbe és annak részét képezik, valamint olyanokat, amelyek közvetlenül nem kerülnek bele a programrendszerbe, hanem csak annak felépítését, szerkezetét és működését beolvásolják.

Az első csoportot kézenfekvően maguk az input/output adatok, valamint az adatokkal végzendő műveletek /algoritmusok leírása képezik. Ez utóbbiak adatellenőrzési, számítási, csoportosítási és rendszési stb. algoritmusok lehetnek, amelyeket más szempontból adatelőállítási és file-előállítási algoritmusokra bonthatunk. A vállalati rendszerszervezésben szerzett gyakorlati tapasztalatok arra engednek következtetni, hogy az adatok és algoritmusok leírását a felhasználók érdemben akkor tudják támogatni és segíteni, ha az számukra érthető módon, vagyis felhasználói szemléletben készül. Idegenkedést kelt az olyan dokumentáció, amelyben a felhasználó index-szekvenciális file-ok, karakter-stringek leírását találja meg. Felhasználói szempontból azt a dokumentációt tekinthetjük megfelelőnek, amely az adatok és algoritmusok leírását funkcionális bontásban adja meg, és az egész rendszert olyan felépítésben mutatja be, ahogyan azt a felhasználó az általa ellátott tevékenységekbe ágyazottan érzékeli.

A második csoport tulajdonképpen a rendszer működését jellemző technikai paramétereket tartalmazza, amelyek leggyakrabban volumen- és gyakorisági adatok, feldolgozási és válaszadási időkorlátok stb. formájában jelennek meg. Részben ide tartozónak tekinthetjük továbbá az adattípusok, illetőleg az adatértékek közötti kapcsolatokat is, mivel a programrendszer felépítését ez is jelentős mértékben befolyásolja. Maguk a paraméterek azáltal fejtik ki befolyásoló hatásukat, hogy a feladat megoldására számításba vehető hardware/software elemek közül egyeseket kizárnak, másokat illetően pedig azok alkalmazása mellett szólnak. Ezt a hatást természetesen a programrendszer tervező érvényesíti, aki a technikai paraméterek befolyásoló hatását a felhasználó által megadott szempontok szerint értékeli és enne eredményként dönt a hardware/software elemek végső összetételéről.

Lényeges mozzanat, hogy habár a technikai paraméterek mindig a felhasználói feladat jellemzőiként jelennek meg, azok körét mindenkor a számítógépi megoldáshoz igénybe vett hardware/software elemek sajátosságai határozzák meg. Ebből következően a felhasználói feladatmeghatározás mindig eszközfüggetlen, vagyis az egyik adatbázis-rendszer alkalmazásához készült feladatmeghatározás egy másik rendszerhez egyáltalán nem vagy csak korlátozottan használható fel.

## A feladatmeghatározás kidolgozása

Az előzőekből érzékelhető, hogy a felhasználói feladatmeghatározás a programrendszer tervezésnek azonos nagyságrendű feladatot jelent. Ebből kifolyólag röviden azt is célszerű áttekinteni, hogy egy ekkora feladatot hogyan lehet hatékonyan megszervezni és koordinálni. A kidolgozás megszervezésének szempontjai közül véleményem szerint a következő három csoportot kell kiemelni:

- szakmai és tartalmi szempontok
- project-management szempontok
- dokumentálási szempontok.

A szakmai szempontokat tulajdonképpen már kifejtettük akkor, amikor elmondtuk a feladatmeghatározás tartalmát. Ennek kapcsán még egyszer hangsúlyozzuk, hogy a feladatmeghatározás képezi az egyetlen és egyben az utolsó olyan munkaszakaszt, ahol a felhasználó a számára értelmezhető módon, részleteiben látja a készülő rendszer elemeit és működési vázlatát, és itt még olyan fázisban van módja elképzeléseit érvényesíteni /avagy megváltoztatni/, amikor a rendszer kivitelezése még nem kezdődött meg.

A project-management szempontok a feladatmeghatározás kidolgozásával kapcsolatos vezetői elveket tartalmazzák. Nyilvánvaló, hogy a feladatmeghatározás kidolgozása nagyvolumenű feladatot jelent, amelynek során több munkatárs munkáját kell összehangolni és koordinálni. Ennek kapcsán gondoskodni kell a munkafeladatok kiadásáról és számonkéréséről, a kiadott feladatok teljesítésének nyomonkövetéséről, ugyanakkor a feladatok tervezhetőségét is biztosítani kell, egyrészt a határidők, másrészt a ráfordítandó munkavolumen szempontjából is. Vezetési szempont továbbá az is, hogy a munkavégzésben állandó, standard munkarészeket különítsünk el, amelyek a munkatársaknak lehetőséget adnak a specializációra, ami növeli a munkavégzés hatékonyságát.

A dokumentálással kapcsolatos szempontok azt rögzítik, hogy a feladatmeghatározás kidolgozása csak egy közbenső munkafázist jelent, amelynek eredményeit a soronkövetkező munkafázisokat elvégző munkatársak használják majd fel. Ebből következően a feladatmeghatározást írásban dokumentálni kell, amihez megfelelő dokumentálási rendszert kell kidolgozni. A dokumentálási rendszernek egyrészt igazodnia kell a feladatmeghatározás elkészítésével összefüggő tevékenységekhez és ugyanakkor a dokumentáció felhasználása /vagyis a programrendszer tervezés/ során elvégzendő tevékenységekre is tekintettel kell lennie.



Mindezeknek a követelményeknek egy olyan szabványos úrlapokból felépülő dokumentálási rendszerrel lehet eleget tenni, amely előre rögzíti az elvégzendő /és dokumentálandó/ munkafeladatokat, azok elvárt eredményeit, ezeket megfelelően strukturálja, és ugyanakkor kellőképpen rugalmas is ahhoz, hogy alkalmazkodni tudjon a feladatok és eszközök változásához. Az ilyen dokumentálási rendszer is csak akkor tudja betölteni project-management funkcióit, ha a dokumentálás a rendszer kidolgozásával egyidőben és nem utólag történik. Az úrlapos megoldás erre igen kedvező lehetőségeket nyújt.

### A feladatmeghatározás alkalmazási problémái

Az eddigiekben megkiséreltük bemutatni a felhasználói feladatmeghatározásnak az alkalmazási rendszerek szervezésében játszott szerepét és a vele szemben támasztott követelményeket. A gyakorlati rendszerszervezési problémákat és a felhasználói szint jelentőségét tekintve úgy tűnhet, hogy a feladatmeghatározás önálló alkalmazási munkaszakaszként történő felfogása teljesen indokolt, és ennek megvalósítása csupán csak idő kérdése. Szakmai körökben azonban közismert, hogy ez koránt sincs mindig így, és a feladatmeghatározás esetenkénti elkészítése vagy elkészíttetése időnként viszonylag komoly nehézségekbe ütközik.

Az első ilyen gátló tényezőt a kétszintes szervezési tevékenység szükségességének fel nem ismerése képezi. Egyes szervezők tagadják, hogy felhasználói tervezésre egyáltalán szükség van, azal érvelnek, hogy megfelelő szakmai felkészültséggel a felhasználói tervezés kihagyható, és a rendszerterv a felmérési eredmények alapján közvetlenül elkészíthető. Ehhez azonban olyan hatalmas méretű ismeretanyagra lenne szükség /hardware, software, operációs rendszer, DB-rendszer stb. ismeretek/, amelyek megszerzése tömeges méretekben egyetlen szervezőtől vagy szervezői team-től nem várható el reálisan.

A másik gátló tényezőt az egyes hardware/software rendszerek alkalmazása által megkívánt technikai paraméterek körének kidolgozatlansága jelenti. Egyszerűen nem állnak rendelkezésre olyan tájékoztató leírások arról, hogy egy adott eszköz használatához a felhasználói feladatnak milyen paramétereit kell a hatékony alkalmazás érdekében felmérni és a tervező rendelkezésére bocsátani. Ez jobbik esetben a felmérések kiegészítését eredményezi, de rosszabb esetben a szervezés sikerét kockáztatja, ami az egész projektet megkérdőjelezheti.

A harmadik gátló tényezőt a megfelelő dokumentálási rendszer hiányában jelölhetjük meg. A sokirányú kísérletezések ellenére ma sem rendelkezünk olyan dokumentálási rendszerrel, amelynek segítségével egy adott DB-rendszer felhasználói feladatmeghatározása teljeskörűen elvégezhető és dokumentálható lenne. E problémák leküzdése ma az egész szakmai társadalom érdekét szolgálja.



toqrammokat tud rajzolni, de kívülről nem lehet megadni az osztályközöket, illetve az automatikus osztályköz számítás csak egyenlőközű osztályokra vezethet.

- A kiindulási adatok közlésének lehetősége merev, korlátozott. Az input formái kötöttségei általában a felhasználható programcsomagok forrásnyelvére vezethetők vissza. A matematikai statisztikai programok szinte kivétel nélkül FORTRAN nyelven íródtak. A FORTRAN nyelv ilyenirányú korlátozottsága közismert. Különösen zavaróak azonban a komfort hiányosságai az adatbázisok kiértékelése esetén. Az adatbázisok legtöbbször valamilyen specifikus konvenciórendszer szerint épülnek fel, az adatvisszanyerés módszerei ennek megfelelően nem férnek el a FORTRAN nyelv keretei között. Az adatbázisok és a kiértékelő statisztikai programok közötti kapcsolatmegteremtése emiatt sokszor nyugós és pusztán technikai jellegű programozási munkát igényel.
- A paraméterezés korlátai. Természetesen a programok mindig paraméterezhetők, de gyakran olyan paramétereket is kívánnak, amelyek a gépben könnyebben előállíthatók, mint kézzel. Pl. ha a kiértékelés egy adatbázis valamilyen részhalmozása irányul, melyet a megfigyelési egységek kiválasztó feltételeivel határozunk meg, a feldolgozásba bevont megfigyelési egységek számát csak a lekérdezés után tudhatjuk meg, ha kiratjuk a gép memóriájából, s csak ezután tudjuk paraméterként megadni a feldolgozó programnak. Tipikus esete ez az olyan feldolgozási folyamatnak, amelyben két gépi feldolgozási lépés között az ember képezi a kommunikációs felületet.
- A szöveges információk hiánya. Hosszu időn át tartó, sok feldolgozási lépésből álló számítási folyamatoknál /ilyenek általában a tudományos igényű elemzések, melyeknél gyakran a már elért eredmények hozzák meg az igazi étvágvat/ fontos, hogy az egyes számítási eredmények, dokumentumok magukon viseljék mindazon azonosító jegyeket, melyek esetleges későbbi újraelövéteknél a felhasználót megfelelően tájékoztatják /mely megfigyelési mintán milyen változókkal mikor stb. futott a program/. A standard statisztikai programok szolgáltatásai e téren rendkívül szegényesek, a változókat csak sorszámmal jelölik, a minta azonosítására csak minimális, vagy semmilyen lehetőséget nem tartogatnak stb.

- A feladatvariációk ciklikus kezelésének lehetősége hiányzik. A gyakorlatban nagyon gyakori, hogy egy-egy számítási eljárás valamilyen paraméter változtatásával /pl. a minta részhalmazaira vonatkozóan/ többször is le kell futtatni. Ilyen esetben a kívánatos komfortot az jelentené, ha a programot egyszeri indítással többszöri futásra lehetne készíteni. A standard programok jó része erre nem alkalmas, vagy ha alkalmas is, a fentiekben már említett valamely hiányosság miatt a programot újra és újra indítani kell. Anélkül, hogy az e tárgyban még tapasztalható hiányosságokat tovább részleteznénk, összefoglalásul egy példával szeretnénk illusztrálni eddigi mondanivalónkat. Szórásanalízis céljára rendelkezésünkre állt egy standard program, melynek az adatbázisunk adataihoz való kapcsolását megoldottnak tekinthetjük /bár ez sem volt eleve adott/. A program ciklikusan működtethető ugyan, de csak egy változóval tud számolni. A számításokat el kellett végezni a teljes mintára, azon belül ágazatonként, népgazdasági áganként, a kiemelt vállalatok körére, a vállalatok különböző nagyság kategóriáira, összesen 49 változóval, 5 év adataival. Az adatbázis adataihoz való kapcsolást/a lekérdezést/ is figyelembe véve könnyű megbecsülni, hogy a feladat megoldása ezernél több egyedi programfutást igényelt volna. Emiatt a meglévő program használatától el kellett tekintenünk, s helyette más megoldást kellett keresnünk. Anélkül, hogy lebecsülnénk a standard csomagokban közreadott programok óriási jelentőségét, meg kell állapítanunk, hogy a fenti problémák alaposan rontják ugyanezen programok felhasználásának esélyeit, különösen, akkor, ha a program valódi kezelője nem kimondottan számítástechnikai szakember.

Számítóközpontunkban adottságként fogadhatjuk el, hogy vannak adatbankjaink, melyek felépítéséhez és működtetéséhez egyrészt a Siemens cégtől származó SESAM adatbank kezelő rendszert, másrészt számítóközpontunkban kifejlesztett SEDI99 lekérdező rendszert használjuk, ez utóbbit 100 %-os kizárólagossággal. Ebből adódik, hogy a problémáink megoldását is ebben a software környezetben keressük. A fejlesztés alatt álló rendszerünk szorosan kapcsolódik a már meglévő lekérdező - adatfeldolgozó rendszerhez. Így maguk a statisztikai eljárások teljes mértékben mentesülnek az adatbázis kezelés, az adatok előzetes feldolgozása, transzformációja, tömörítése stb. kapcsán adódó problémáktól. A számítások végrehajtásánál jelentkező variációs lehetőségeket messzemenően figyelembe vesszük, úgy, hogy programkomponenseink tudják mindazt, amit az általunk ismert standard programok tudnak, illetve, ami tapasztalataink szerint

ezen kívül szükséges lehet. Az adatbankjaink szervezési sajátosságainak megfelelően rendelkezésre állnak a lekérdezett ill. számított változók-, adatok szöveges megnevezései, a tipikus részminták /ágazati, területi, felügyeleti stb./ megnevezések, melyek a számítások megfelelő pontjainál külön ezirányú intézkedés nélkül is automatikusan megjelennek. A feladatvariációk ciklikus kezelésére több egyenértékű lehetőség is rendelkezésre áll, gyakorlatilag korlátlan számú lekérdező, kiértékelő, számító programlépés fűzhető fel egy programindításon belül többé vagy kevésbé automatizált cikluskezeléssel. Az így előkészített feladat-csomagok az adatbankban tárolhatók, s később változatlanul, vagy újabb variációkká módosítva lefuttathatók. A fejlesztés első ütemeként a leíró statisztika módszereit egyesítő alrendszer készült el. Tapasztalataink igazolják, hogy a korszerű, komfortos software termék előállításánál a munkaigény aránya erősen eltolódik a komfort elemek felé, s egyre kisebb súlya van a tényleges számítási feladatot ellátó matematikai programnak. Esetünkben a matematikai program mag és a körülötte dolgozó komfort "felhő" közötti arány /programsorok száma, munkaigény, futási időigény, stb./ kb. 1:20.

A következő ütemekben rendszerünkbe kívánjuk integrálni a matematikai statisztika minden fontosabb, gyakran használt módszerét. Arra természetesen nem törekedhetünk, hogy rendszerünk "mindent tudjon", amit ezen a téren tudni lehet. De - tapasztalataink szerint - a számítási eljárások használati foka ill. matematikai igényessége bonyolultsága fordított arányban állnak egymással, s a jövőben is arra számíthatunk, hogy az egyszerűbb módszerek alkalmazására kell a nagyobb súlyt helyoznünk. Azon eljárások számára pedig, melyeket rendszerünk nem tartalmaz /s esetleg nem is fog tartalmazni/ most is fennáll a külső programhoz való csatlakozás lehetősége.

Építkező programgenerátor SESAM típusu adatbankok  
kiértékeléséhez

A gépi adatfeldolgozás fő módszerei már évtizedekkel ezelőtt kialakultak, s máig annyira kikristályosodtak, hogy a legkülönbözőbb szintű számítástechnikai oktatási intézményekben alaptantárgyként oktatják. A mindennapos gyakorlat ezzel szemben azt mutatja, hogy még mindig nem születtek meg azok az általános megoldások, melyek programozóinkat megkímélnék a különböző tipikus feldolgozási lépések újra és újra megprogramozásától. Igaz, régebben is és ma is rendszeresen napvilágot látnak programrendszerek, melyek magukat univerzális, végleges, teljesen általános megoldásként árulják. Ezek sikere azonban általában csak átmeneti és korlátozott.

Egy általános igényű programrendszer megalkotásának receptje lényegében ismert. Az adott területen már megoldott problémák elemzésével meg kell keresni a közös vagy többé kevésbé stabil logikai elemeket, s segítségükkel meg kell konstruálni azokat a programkomponenseket, melyek a felmerülő problémák elegendően nagy hányadát megoldják. A programkomponensek lehetnek pl. assembler makrok, melyek egy assembler nyelven írott programba ágyazva a feladat fő terhét viselik, de lehetnek kész modulok, melyeket egy főprogramból szubrutinként hívhatunk. Az általános igényű programrendszerek egy más része futtatható, kész programfázisokból áll, de elképzelhetünk más számítástechnikai realizációkat is.

A makrok ill. szubrutinok adott határok között nagyon jól használható módszert jelentenek, de végülis nem küszöbölik ki a programírást, tesztelést, s ráadásul a rendszer bonyolultságának növekedésével párhuzamosan kezelésük egyre nehezkedőbb.

A kész programfázisok rendkívül praktikusak az azonnali használhatóságuk, futtathatóságuk miatt, de a feladat fokozott bonyolultsága egyre igényesebb paraméterezési eljárást kíván, ami viszont egy határon túl már a programírás nehezességét vonja maga után.

Végül is nem lehet kikerülni a tényt, hogy egy adott bonyolultsági szinten túl bármilyen számítástechnikai technológiát használunk, a programrendszer használata nem lehet egyszerű. Az alábbiakban egy olyan adatbázis kiértékelő rendszerről lesz szó, mely a hagyományos adatfeldolgozás területéhez tartozó feladat típusok igen széles körében nyújt gyors, komfortos megoldási lehetőséget. Rendszerünket, a SEDI99 programrendszert, mely a SIEMENS cég SESAM nevű adatbank rendszerévé létrehozott adatbankok kiértékelésére alkalmas, számítógéppontunkban évek óta 100 %-os kizárólagossággal használjuk feladataink megoldására, de felhasználóinak köre egyre szélesedik belső és külföldön is.

A rendszer koncepciójának teljeskörű ismertetésére itt nincs lehetőség, a legfontosabb sajátosságokat csak a tájékoztatás kedvéért soroljuk fel:

- a rendszer futtatásra kész programfázisokból áll,
- a felhasználó és a rendszer közötti kapcsolat négy önálló, egymástól különböző kommunikációs síkon lehetséges /feladatközlő nyelv, dialog vezérlő parancsok, üzemi paraméterek, batch vezérlő paraméterek/,
- a feladat megfogalmazása a tipikus tevékenységek specifikációja útján történik,
- a feldolgozó ill. outputáló tevékenységek messzemenően függetlenek egymástól,
- az adatok megnevezhetőek /a háttérben a SESAM rendszer adatkatalógusával/,
- a feladat megoldás minden része technológiai egységet képez, a programfutást semmilyen technikai ok miatt nem kell megszakítani,
- batch, enter és dialog üzemmódokban történhet a futás, ezen üzemmódok más és más feldolgozási módokat, más és más kezelési lehetőségekkel támogatnak,
- a végleges feladatmegoldó program a feladat specifikációjának fogadásával párhuzamosan alakul ki, s a rendszer futása során tetszőleges számú alkalommal tudja magát újra "generálni",
- az egymás után futó feladatok, u. n. "lépések" egymáshoz láncolhatók, egymásnak adatot adhatnak át a munkatárolóban, az adatbankban, vagy külső adathordozón.

Témánk szempontjából a fenti elemek közül kettőnek van különös jelentősége, a tipikus tevékenységek elvének ill. a rendszer öngeneráló, önépítő jellegének.

Rendszerünk tipikus tevékenységei ismertek a hagyományos adatfeldolgozás eszköztárából, s ezen a téren semmilyen elvi újdonságról nem beszélhetünk. Olyan tevékenységekről van szó, mint primér és szekundér adatvisszanyerés, szelekció, aggregálás, tételes vagy összesített adatokkal végzett számítások, rendezés, a számított adatok tárolása stb. A tipikus tevékenységekből gyakorlatilag minden olyan feladat megoldása összeállítható, mely adatállományok konvencionális feldolgozását célozza. A tipikus tevékenységek programtechnikai szempontból nézve többé kevésbé vázlatosan megírt programelemek, melyek végleges alakjukat a feladat teljes meghatározása után nyerik el, s melyek végrehajtása azonnal meg is indul. Az egyes tipikus tevékenységek között lényeges különbségek

vannak specifikálhatóságuk, ill. a megvalósításukat végző program-  
elemek előregyárthatósága szempontjából. Az aggregálásnál pl. csak  
két ponton jelentkezik variációs lehetőség, az aggregálandó adatok  
számát, ill. hosszát illetően. Ennek megfelelően az aggregálás spe-  
cifikációja az adatok neveinek egyszerű felsorolásából állhat, végre-  
hajtó programelemként pedig elképzelhető egy szinte teljesen végle-  
gesen megírt programrutin, mely az aggregálandó adatok címét és  
hosszát, valamint egy ciklusszámlálót kivéve kész és változatlan,  
Hasonlóan egyszerű a rendezés kezelése, ahol a szintaktika meg-  
elégedhet a rendező kulcsként szolgáló adatok neveinek felsorolásá-  
val, a végrehajtó rutin pedig nem áll másból, mint a rendező al-  
program felhívó paramétereinek aktualizálását végző néhány utasi-  
tásból.

Más a helyzet pl. a feltételes számításokat részletező specifikációk  
kezelésével. Itt összetett feltételek és bonyolult képletek értelmezé-  
sére kell felkészülni, a végrehajtó programelemek pedig előre még  
vázlatosan sem írhatók meg. Az eddig említett két véglet között az  
átmeneti szituációk sokféleségével találkozhatunk. Így eljutunk az  
önépitő programrendszer fogalmához. Lényege, hogy a végrehajtó  
program azon elemeit, melyek a feladat specifikációjának fogadása  
előtti előre nem láthatóak, a rendszer egyáltalán nem tartalmazza,  
hanem azokat a specifikáció fogadásával párhuzamosan hozza létre.  
Ebben a pillanatban a rendszer mint valamely programnyelv fordító-  
programja viselkedik. A fordítás eredményeként létrejövő program-  
elemeknek futáskor együtt kell működniök a standard, kész, vagy  
menet közben aktualizálódó programelemekkel. Az együttműködés  
biztosítása a szerkesztőprogram funkcióját igényli. Így az önépitő  
program egyesíti magában a fordító és szerkesztő program funkcióit  
is /esetünkben ehhez a "könyvtár" kezelése is járul, de ennek nincs  
köze az önépitő funkciókhoz/.

A feladat megoldása időben két szakaszra oszlik, az értelmezés és  
a végrehajtás szakaszára.

Az értelmezés időszakában a rendszer egymás után olvassa a  
tipikus tevékenységeket specifikáló paramétereket, ezek alapján fel-  
építi a megfelelő tevékenységek végleges programjait. Az utolsó pa-  
raméter értelmezése után készen áll a végrehajtó program, indulhat  
a feldolgozás. A végrehajtás szakaszában az értelmező funkciókat  
ellátó programelemekre nincsen szükség, sőt jelenlétük esetén szük-  
ségtelenül a többszörösére nőne a tárolóigény. Ez a körülmény in-  
dokolja az overlay technika széleskörű alkalmazását.

Miután az önépitő rendszerünk működését az alábbiakban fog-  
lalhatjuk össze.



- a munkatároló három régióra oszlik:  
a rezidens modulok régiójára,  
a szintaktikai elemző modulok régiójára, és  
az adott feladat lépés számára specifikusan  
generált programelemek régiójára.
- a rezidens régió mindegyik tipikus tevékenység számára  
egy modult tartalmaz, mely a végrehajtás idején szükséges,  
vázlatosan megírt programrutinokat hordozza.
- egy adott paraméter értelmezésekor véglegesitődik a rezidens  
modul, s a harmadik régióban megjelennek a generált spe-  
cifikus programelemek.
- az utolsó paraméter értelmezése után a feladat végrehaj-  
tásában résztvevő tevékenységek mindegyike véglegesített  
rezidens modullal és a harmadik régióban kész program-  
elemekkel rendelkezik, ugyanekkor felszabadul a második  
régió. A második régiót a végrehajtás szakaszában az  
output eljárás programmodulja foglalja el.

Láthatjuk, hogy a rendszer indításakor rendelkezésre álló program-  
részek, melyeket az előbbieken vázlatosan megírtunk nevezünk,  
valójában a feladatot megoldó programnak mintegy csontvázát képe-  
zik, melyeket a feladat értelmezésekor tölt meg a rendszer hussal-  
vérrel. A feladat lefutása után a hus elillan, s ismét üres csontváz  
várja a következő feladatot.

Hálós adatbázisok egy matematikai modellje

Legyen adva tulajdonságtípusok /adattételtípusok/ egy  $A$  halmaza. A hálós adatbázisban a tulajdonságtípusokat rekordtípusokba szervezzük és összefüggéseket kapcsolatokat írunk fel az egyes rekordtípusok között, megadva ezzel a tulajdonságtípusok közötti kapcsolatokat is.

A tulajdonságtípusok értékei /előfordulásai, adattételek/ adják meg az adatbázis összes lehetséges kimenetét /nevezzük ezt az adatbázis outputjának/. A tulajdonságtípusok értékeiből állnak össze a rekordtípusok előfordulásai, a rekordtípusok közötti kapcsolatok meghatározzák a tulajdonságtípusok előfordulásainak kapcsolatait is.

Legyen  $R$  a hálós adatbázis  $r_i$  rekordtípusainak halmaza. A rekordtípusok kapcsolatait /és ezen keresztül a tulajdonságtípusok kapcsolatait is/ egy  $G$  irányított gráffal adjuk meg, amelynek csúcspontjai az  $R$  halmaz elemei. A  $G$  gráfot az adatbázis gráffjának hívjuk.

Két szomszédos csúcspontot összekötő él az adatmodellben set-típust alkot.

A gráfnak azokat a csúcsait, amelyekbe nem vezet él, navigációs gyökérelemeknek nevezzük, azokat, amelyekből nem megy ki él navigációs végpontoknak hívjuk. Egy navigációs gyökérelemtől egy navigációs végpontig vezető út a navigációs út /lásd IDMS/. A navigációs utaknak közös részük is lehet. Minden navigációs út a rekordtípusok közötti kapcsolatot /kapcsolat-sorozatot/ fejezi ki.

A navigációs úton a rekordtípusoknak sorrendje van; a gyökérelem kivételével minden rekordtípusnak van előző és a navigációs végpont kivételével követő rekordtípusa. Az előző rekordtípust *owner*-nek, a követőt *member*-nek nevezzük. Ha egy  $p$  rekordtípus bármely navigációs úton megelőzi  $q$ -t, illetve  $q$  követi  $p$ -t /nemcsak közvetlenül/ akkor azt  $p < q$ -val jelöljük.

Az adatbázis egy  $\mathcal{F}$  lekérdezésnek tekinthető, amely a /lehetséges/ kérdések halmazát a válaszalmazba képesi le. Minden válaszhoz /a tulajdonságtípusok előfordulásainhoz/ egy navigációs úton jutunk hozzá.

Az alábbiakban [2] -re támaszkodva egy matematikai modellt adunk a  $G$  gráffal leírt adatbázissal reprezentált  $\mathcal{F}$  lekérdezésre.

Legyen  $K_q = \{p : p < q, \forall p \in \mathbb{R}\}$

$M_q = \{p : q < p, \forall p \in \mathbb{R}\}$

Legyen  $U_k(r_0)$  az  $r_0$  rekordtipust megelőző rekordtipusok által meghatározott  $k$ -adik út, azaz legyen

$$U_k(r_0) = r_{m_k}^k \dots r_{-1}^k r_0^k$$

és legyen  $M_k \subset M_{r_{m_k}}$

Vezessük be az  $r U_k(r_0)$  utak  $101 \ r \in M_k$  az  $M_k U_k(r_0)$  jelölést.

Vegyük az  $r_0$ -t követő utak  $K_{r_0}^k$  halmazát. Legyen ennek  $M_k$  egy részhalmaza. Az  $M_k U_k(r_0)r$  alakú utak halmazát, ahol  $r \in K_{r_0}^k$  az  $r_0$ -ra támaszkodó navigációs útsorozatnak nevezzük, és  $N(r_0)$ -al jelöljük.  $N_k(r_0) \in N(r_0)$  egy navigációs útvonal,  $r_{-m_k}^k$  a navigációs útvonal gyökere.

Egy  $N_k$  útvonal  $\mu(N_k)$  hosszán az úton lévő csomópontok eggyel csökkentett számát értjük. Jellemezzük az adatbázis ponyolultságát a leghosszabb navigációs úttal.

Az adatbázishoz tartozó összes navigációs útvonalak halmazát jelöljük  $N$ -el. Az adatbázis a  $(G, N)$  párral írjuk le.

Az adatbázisnak a  $G$  gráffal illetve az  $N$ -nel a navigációs utak halmazával történő leírása alkalmas arra, hogy egy adott  $\mathcal{F}$  leképezést megvalósító  $(G, N)$  párhoz megszerkesszünk egy ugyancsak az  $\mathcal{F}$  leképezést leíró olyan  $(G', N')$  párt, amely valamilyen szempont szerint kedvezőbb.

Legyenek adva az  $N_k(r_0) \in N(r_0)$  ( $k=1, 2, \dots, \ell$ ) utak, ( $r_0 \in \mathbb{R}$ ) és jelöljük ezek közül  $N_k^{(k)}$ -val azokat ( $k=1, 2, \dots, \ell$ ) amelyekre  $\mu(N_k^{(k)}) = 1$

Definiáljuk az  $N_0(r)$  utat a következő módon:

$$U_0(r_0) = r_0^0 = r_0, \quad M_0 = M_{r_0} \setminus \bigcup_{i=1}^{\ell} M_i, \quad K_0 = K_{r_0}$$

Legyen  $N = (N_0, N)$  és

$$M_k = \bigcap_{j=1}^{\ell} M_j^{k_j} \quad (k=1, \dots, \ell) \text{ ahol ha } M_j^{k_1} \cap M_i^{k_2} \neq \emptyset \text{ akkor } M_j^{k_1} = M_i^{k_2}$$

Bontsuk fel az  $\{M_j^{k_j}\}$  halmazt ( $j=1, 2, \dots, \ell, \quad k=1, 2, \dots, \ell$ )

$C_1^j, C_2^j, \dots, C_w^j$  csoportokra úgy, hogy

$$M_{A_i}^k \in C_i: \text{ ha } M_{A_i}^{k*} = M_i^k, M_i^k \in C_i$$

$$M_{B_i}^k \notin C_i: \text{ ha } M_{A_i}^{k*} \neq M_i^k; M_i^k \in C_i$$

és jelöljük a  $C_j$ -vel a  $C_i$  elemeit. Az  $R$  helyett vegyük az  $R_i = R - \{r\} \cup \tau_i^*$  halmazt, ahol  $\tau_i^* \equiv \tau_0, i=1,2,\dots, \omega$ . Az  $R_i$ -hez szerkesszük meg a  $G_i$  gráfot a következő módon:

$$K_{\tau_i^*}^{(i)} = \begin{cases} K_j & \text{ha } \tau_i \in C_j, \tau_0 \notin K_j, j \leq \omega \\ (K_j \setminus \tau_0) \cup \tau_i^* & \text{ha } C_i \subset M_j, \tau_0 \in K_j, j \leq \omega \end{cases}$$

ahol feltesszük, hogy  $\tau_0 \in C_i$ . Az  $R$  többi elemére legyen:

$$K_r^{(i)} = \begin{cases} K_r & \text{ha } \tau_0 \notin K_r \\ (K_r \setminus \tau_0) \cup \tau_i^* & \text{ha } \tau_0 \in K_r \text{ és } r \in \tau_i \end{cases}$$

Szerkesszük meg az előbbieknél megfelelően  $N$ -ből  $N_i$ -et.

Legyen  $\lambda > l$  esetén és ha  $\forall e_{i+1} \neq \tau_0$  akkor  $s \leq l - r$  is

$$U^{(i)}(v_0^s) = v_{-i}^s \dots v_{-1}^s v_0^s \text{ ahol } v_s = \begin{cases} \tau_s & \text{ha } \tau_s \neq \tau_0^* \\ \tau_s^* & \text{ha } \tau_s = \tau_0, \tau_{s-1} \in C_j \end{cases}$$

$\lambda \leq l$  esetén pedig ha  $v_{e_{i+1}} = \tau_0$  akkor  $v_{e_{i+1}} = \tau_k^*$  ha  $\tau_0 \in C_i$

. Az  $\lambda \leq l$  értékekre legyen  $M_i^{(i)} = U_{\tau_k^*}$  feltéve,

hogy  $U_{C_k} = M_i$

Amennyiben  $\lambda > l$  legyen

$$M_i^{(i)} = \begin{cases} M_i & \text{ha } \tau_0 \notin M_i \\ (M_i \setminus \tau_0) \cup (U_{\tau_k^*})^p, C_k = M_j^p, \tau_{-i}^s \in K_p, p \leq l_1 \end{cases}$$

és  $i > l_1$  esetén

$$K_i^{(i)} = \begin{cases} K_i & \text{ha } \tau_0 \notin K_i \\ (K_i \setminus \tau_0) \cup \tau_k^* & \text{ha } \tau_0 \in K_i, \end{cases}$$

A fenti eljárással megszerkesztettük a  $G_1$  gráf

$N_1 = \{N_1^{\lambda+1}, N_1^{\lambda+2}, \dots, N_1^\lambda\}$  halmazát, ahol  $N_1^\lambda = \{M_i^{(i)} U^{(i)}(v_0^s), K_i^{(i)}\}$

Most megmutatjuk, hogy megadható olyan  $T$  transzformáció, amely  $G_1$  útjait  $G$  útjaiba viszi át.

Legyen  $T\tau = \begin{cases} \tau & \text{ha } \tau \neq \tau_k^* \\ \tau_0 & \text{ha } \tau = \tau_k^* \end{cases} k=1,2,\dots,\omega$

Legyen  $U^{(i)}$  a  $G_1$  gráf  $\tau_1^* \tau_2^* \dots \tau_m^*$  útja és legyen

$TU^{(i)} = \{\tau_1, \tau_2, \dots, \tau_m\}$ . Vegyük a  $TU^{(i)} = \tau_1 \tau_2 \dots \tau_m$  utat és jelöljük ezt  $U$ -val. Megmutatjuk, hogy  $U$  a  $G$  gráf útja.

Legyen  $\tau_i = \tau_i^s$  ( $i=1,2,\dots,m-1$ ) Nyilván  $\tau_{i+1}^s \in K_{\tau_i^s}$ , mivel  $U^{(i)}$  a  $G_1$  gráf útja. Ha  $\tau_{i+1}^s \neq \tau_k^*$  akkor  $\tau_{i+1} = \tau_{i+1}$  és  $\tau_{i+1} \in K_{\tau_i^s}$ . Világos, hogy  $\tau_i \tau_{i+1}$  a  $G$  gráf éle.

Ha  $r_{i+1}^1 = r_k^*$  is teljesül akkor  $r_{i+1}^1 = r_0$ , tehát  $r_{i+1}^1 = r_0 \in K_{r_i^1}$ , azaz  $r_i^1 r_{i+1}^1$  ebben az esetben éle a  $G$  gráfnak.

Ha  $r_i^1 \neq r_i^1$  akkor  $r_i^1 = r_k^*$  és  $r_i^1 = r_0$

Mivel  $r_i^1 r_{i+1}^1$  a  $G_1$  gráf éle ezért nyilván

$r_{i+1}^1 \in K_{r_i^1}^*$  és amennyiben  $r_{i+1}^1 = r_{i+1}^1$  akkor  $r_{i+1}^1 \in K_{r_k^*}$ . Ez azt jelenti, hogy  $r_{i+1}^1 \in K_k \subset K_{r_0}$  azaz  $r_i^1 r_{i+1}^1$  a  $G$  gráf éle.

Ha  $r_{i+1}^1 \neq r_{i+1}^1$  akkor  $r_{i+1}^1 = r_k^*$ ,  $r_0 \in K_k$  vagyis  $r_0 \in K_{r_0}$ .

Azt kaptuk tehát, hogy  $r_i^1 r_{i+1}^1$  a  $G$  gráf éle.

Beláttuk tehát, hogy a  $T$  transzformáció a  $G$  útjait  $G_1$  útjaiba viszi át, azaz  $TU^{(1)} = U$

A hálós adatmodellnek az ismertetetett módszer segítségével történő leírása lehetővé teszi egy adatbázisnak kedvezőbb tulajdonságu adatbázisba való átalakítását.

#### Irodalom

1. D.C Tsichritzis, F.H. Lochovsky: Data Base Management Systems. /Academic Press New York, 1977/
2. Ю.И. Смирнов: О преобразовании операторной схемы. (Сб. "Проблемы кибернетики" Вып. 3, 1960)

Néhány adatbázis alkalmazás tapasztalatai /Az IDMS  
használata alapján

Az IDMS adatbázis-kezelő rendszer nem egészen 3 éve került Magyarországra. Ezalatt az idő alatt igen széles körben elterjedt, ma már több mint 50 számítóközpontban használható. Természetesen az IDMS alapu alkalmazások kidolgozása időt vesz igénybe és ezért még nagytömegű felhasználói tapasztalatról nem beszélhetünk. A rendszer alkalmazását a SZÁMALK az elsők között kezdte meg és ma már üzemelő rendszereket dolgozott ki. Emellett több más intézmény is sikerrel használja az IDMS-t /MÁV, ÉGSZI, SZTAKI, stb./. Az előadás három, már üzemelő alkalmazást tekint át, kitér néhány felhasználói tapasztalatra és kiegészítő program fejlesztési javaslatra.

A SZÁMALK IDMS alkalmazás-fejlesztési tevékenységében az ÁTM /volt OTÁF/ takarmány-nyilvántartási és ellenőrzési rendszere, a csepeli Fémű AFG DB/DC rendszere, valamint a BAGE MEVIR rendszere tekinthetők az első sikeres kísérleteknek. Ezek az alkalmazások már működőképesek, noha további fejlesztésük, kiegészítésük folyamatban van.

Az ÁTMI takarmány-nyilvántartási és ellenőrzési rendszere kb. egy éve működik. Az ÁTMI egy országos laboratóriumi hálózaton keresztül ellenőrzi a felhasználásra kerülő takarmányokat. A laboratóriumi vizsgálatok eredményeit központilag értékelik ki un. "etalon" értékkel való összehasonlítás alapján. A kiértékelés alapján intézkedésekre /pl. a felhasználás megtiltása/ is sor kerül. Ezen felül statisztikai elemzések készülnek a takarmány felhasználás hatékonyságáról. Az évi kb. 50 ezer takarmányminta vizsgálata alapján gyors intézkedésekre és további elemzésekre van szükség. Ennek érdekében a számítógépes rendszer előállítja

- egy adott időszakban vett takarmányminták osztályozását,
- adott gyártóknál vett minták értékelését,
- az előállított takarmány mennyiségét megynként,
- a mérések értékeinek átlagait és
- egyéb statisztikákat.

Ebben az évben viszonylag kis ráfordítással egészítettük a rendszert a vizsgálatok költségeinek ki-

mutatásával és számlázásával.

Az adatbázis 12 rekord típusból és 12 set típusból áll. Az adatbázis mérete 100 ezer rekord, 70 MB. A rendszer üzemeltetése során figyelembe véve a méreteket és a szolgáltatásokat a futási időkkel kedvező tapasztalataink vannak. Jelenleg folyik a rendszernek on-line funkciókkal való kiegészítése. A csepeli Fémmű részére a Csepel ISZI közreműködésével egy on-line anyag-és félkésztermék gazdálkodási rendszer készült. Jelenleg a rendszer próbaüzeme /párhuzamos feldolgozás/ folyik.

A rendszer kezeli a szükséges anyagok és fogyóeszközök adatait. Az adatbázis szerkezetét 17 rekord típus és 13 set típus adja. 25 ezer törzs és 45 ezer készlet rekordot tart nyilván. Az adatbázis mérete kb. 20 MB. A rendszer havi kb. 10 ezer mozgást kezel főként kötegelt üzem módban, de megengedi az on-line karbantartást és lekérdezést is. A feldolgozás 10 naponként történik, a listák az adatbázis valamennyi változását rögzítik. További lekérdezések és változások terminálon keresztül lehetségesek. A felhasználó 7 update listát, valamint 15 elszámolási táblát kap az anyagokról. Az on-line rész elfogadható válaszidőkkel működik, míg a batch feldolgozás futási idői nem haladják meg egy hagyományos file szervezésű rendszerét.

Az IDMS-nek a SZÁMALK-nál folyó legösszetettebb alkalmazása a BAGE által kezdeményezett mezőgazdasági vállalatirányítási rendszer /MEVIR/ kidolgozása. A rendszer az első fázisban /1985-ig/

- a készletgazdálkodás,
- az eszközgazdálkodás,
- a munkaerőnyilvántartás és bérelszámolás,
- termelés- és üzemelszámolás

modulokat tartalmazza.

Ebben az esetben különösen lényeges az adatbázis szemlélet, hiszen itt ugyanazokat az adatokat többféle feldolgozás céljára használjuk. A rendszer ujdonságai közé tartozik, hogy egy erőforrásokkal kapcsolatos művelet valamennyi rendszerbeli következménye - a termelés részletes bontású szűkített önköltségének kimutatásáig - külső beavatkozás nélkül végrehajtható.

Először a készlet modul készült el, év eleje óta 3 gazdaság éles feldolgozása üzemel. A modul kielégíti a könyvelés, az elemzés és a statisztika igényeit,

bizonyos gazdálkodási elemeket is tartalmaz. kb 20 táblát állít elő.

Az adatbázis 32 rekord és 23 settipusból épül fel. Jelenleg mintegy 60 ezer rekord előfordulást tartalmaz, mérete kb 25 MB. Mindez 3 gazdaság adatait tartalmazza, amiből a közös rész kb. 40 ezer /törzs/ rekord, 8 MB. Az üzemeltetési tapasztalatok kedvezők. 10-15 ezer tétel feldolgozása legfeljebb egy R55 műszakot igényel.

Az eszköz modul szintén elkészült. Egy gazdaságra a próbaüzem jelenleg befejezés alatt áll. A modul gondoskodik az eszközök nyilvántartásáról, a gépkartonok aktualizálásáról, az értékcsökkenés elszámolásáról, a táblatörzskönyvek vezetéséről, az eszközök teljesítményének nyilvántartásáról. A modul adatbázisa 14 rekord és 7 set-típusból áll. Egy átlagos gazdaságra 15-20 ezer rekordelőfordulást tartalmaz, mérete mindössze kb. 3 MB. A próbaüzem során azt tapasztaltuk, hogy a feldolgozási költségek nem lesznek számottevők. A további modulok fejlesztés alatt állnak.

Megemlítem még, hogy a SZÁMALK eddigi legnagyobb vállalkozása, a VIDEOTON belső információs és irányítási rendszere is az IDMS felhasználásával készül.

Az IDMS eddigi használata megengedi annak kijelentését, hogy az adatbáziskezelés elég kényelmes és hatékony eszköz az alkalmazási rendszerek fejlesztésére. Az eddigi tapasztalatok azt is sejtetik, hogy a rendszerek üzemeltetése sem különösebben költséges.

Az alkalmazások kidolgozása során kitűnt, hogy az IDD használata támogatja a tervezést, mert gyakorlatilag az első rendszerre vonatkozó információktól kezdve sokmindent nyilvántarthatunk vele, így mindenki számára viszonylag egyértelmű és ugyanaz az információ /mégpedig a legutolsó változat/ áll rendelkezésre. Ezt a lehetőséget teszik kényelmesebbé a SZÁMALK új, kiegészítő fejlesztései /SAID, IFRA/.

A CULPRIT használata igen hatékonynak bizonyult, mert igen gyorsan nagymennyiségű tábla készítését teszi lehetővé. Az OKQ 1.2 változata azonban - bár igen egyszerű lekérdező nyelve van - lényegében csak a fejlesztőknek nyújt hasznos segítséget. Az ESZR gépeken nem vált be a gyorsított segédprogram.

Néhány egyéb tapasztalat:



- a sémában kisebb változtatásokra a program tesztek során is sor kerülhet,
- érdemes az adatszótárból és az adatbázisból legalább egy másolatot is tartani a teszt időszakban, mert a teszt futások gyakran "elronthatják" a szótárt és az adatbázist;
- a programteszteket először csak kis méretű teszt adatbázison érdemes végezni, de szükség van viszonylag nagyméretű tesztadatbázisra is, mert a programok performanciája nehezen becsülhető;
- a sorted láncok használatát nagyon alaposan meg kell gondolni, mert könnyen ronthatják a rendszer működési hatékonyságát,
- betöltés előtt célszerű az adatokat előrendezni, mert a lemezek gyakori mozgatása lassítja a műveletet.

Végül megemlítem, hogy a SZÁMALK az adatbázis alapu rendszerek kidolgozásának technológiáját jeleneg fejlesztí. Ennek keretében támogató szoftver csomagokat dolgoz ki. Ide tartozik a már említett SAID továbbá több kisebb segédprogram jellegű szoftver. A technológia középpontjában az IDD áll.

Egy fájl elérési és mozgatási stratégia lokális  
elosztott rendszerekre

1. Bevezetés

A fájlok elhelyezése és mozgatása minden elosztott rendszernek központi problémája. A stratégiák költség minimalizálásra törekszenek figyelembe véve, hogy mind az elérésnek mind a tárolásnak bizonyos költségei vannak. Átrendezésre akkor kerül sor, ha az elérési költségek tartósan megnövekszenek és található a fájl számára egy olyan új csomópont ahol az elérési költségek lényegesen csökkenthetőek. Tehát a fájlok átrendezéséhez elég sok statisztikai adat összegyűjtése és kiértékelése szükséges.

Az ismertetésre kerülő algoritmus a fájlok átrendezését mindezen bonyolult adatgyűjtő és kiértékelő algoritmusok nélkül végzi, de természetesen csak akkor hatásosan, ha a környezet bizonyos feltételeknek eleget tesz. Feltételeink, főleg a mikrogepek világában, a gyakorlatban rendszerint teljesülnek.

Feltételezzük, a felhasználók tevékenysége olyan, hogy egy-egy fájl halmazon hosszabb ideig dolgoznak s egy fájl halmaz elemei időben csak lassan változnak, azaz a fájl hivatkozásokban létezik bizonyos csomósodás. A fájlok igénybevétele lekérdezés jellegű /pontosabban, intenzív használat esetén ritka a felújítás/. A fájlok nem tulságosan nagy méretűek az egyes csomópontokban lévő tárolókapacitáshoz mérten.

2. Az algoritmus működése

Az osztott fájl rendszerben /ami nem szükségszerűen adatbázis, de lehet az is, mintahogy hálózati szintű katalógus, vagy katalógizált fájl rendszer/ nyugalmi helyzetben /amikor mindenfajta tevékenység szünetel/ a fájlok elhelyezése osztott nem duplikált. Ilyenkor a rendszerben lévő összes fájlnek csak egyetlen péld-

dánya létezik, ezt elsődleges példánynak hívjuk.

Ha egy felhasználó, egy nem a saját csomópontjában lévő fájlra hivatkozik lekérdezés jelleggel, akkor az adott fájlról egy másolat keletkezik a felhasználó csomópontjában egy munkaterületen /ezentul raktár/. A raktár mérete olyan, hogy egyidejűleg több fájl befogadására is alkalmas. A raktár fájljai, lekérdezésre, lokális fájlként viselkednek. A raktár megtelése esetén a selejtezést például LRU algoritmus szerint lehet végrehajtani /a raktár megtelése és ürítése analóg a lapozott memória kezeléssel -a memória a raktár, a lapok a fájlok- és így a lapozásnál használt algoritmusok itt is alkalmazhatóak. Az analógia azonban még messzebb menő: ahogy a lapozás feltételezi, hogy egy program memória hivatkozásai csomósodnak, ugyanúgy mi is feltételezzük, hogy egy felhasználói tevékenység fájl hivatkozásai csomósodnak./.

Elvünk tehát az, hogy egy fájl /első közelítésben legalább olvasásra/ legyen ott, ahol dolgoznak vele. Ez azt jelenti, hogy a fájlok azon csomópontokban duplikálódnak, ahol szükség van rájuk. Ez a duplikáció azonban ideglenes, s egy tevékenység befejeztével, akár automatikusan /selejtezés útján, vagy a felhasználó kijelentkezésével/, akár kifejezett utasításra megszűnik. Azaz alapvetően nem változtatja meg sem az adatbázis elosztott nem duplikált jellegét, sem a fájlok csomópontokhoz rendeltségét.

Felujítás jellegű hozzáférés esetén nem másolat készül, hanem első lépésként a fájl átmozgatásra kerül a hívó csomópontba, s ott nem a raktárnak lesz egy eleme, hanem a lokális fájl rendszerhez kapcsolódik. Ezzel megváltozik a fájlok csomópontokhoz rendeltsége. Mivel feltételezzük, hogy felujítást általában a fájl "tulajdonosa" ad ki, ez egy "jó" irányban történő elmozgatás, mivel várhatóan a tulajdonos csomópont változtatása miatt a legközelebbi felujítás szintén innen indul ki.

Az átmozgatást követően az összes másolatot érvényteleníteni kell mielőtt a felujítást végrehajtanánk, nehogy a többi csomópont alavult adatokon dolgozzon tovább. A fájl megjelölésével egy "elavult" üzenet kibocsátására kerül sor, amely a csomópontok raktáraiból egyszerűen törli az adott fájl másolatait. Mindezek után a fájl felujítható, s az ezt követő hivatkozások a felujított fájlról készítenek másolatot.

Ez az alapalgoritmus, s mielőtt implementációs problémákba bocsátkoznánk vizsgáljuk meg mi az a környezet, amit algoritmusunk számára elképzeltünk.

### 3. Környezet, alkalmazás

Legyen egy személyi számítógépekből álló lokális hálózat. Az egyes gépeken a felhasználók önálló tevékenységet folytatnak, de időről-időre más felhasználók által előállított adatokkal is dolgoznak. Ezek az adatok lehetnek különálló fájlok, de lehetnek egy adatbázis elemei is. Mind az egyes gépek lokális katalógusai, mind az azokat egyesítő globális katalógus szimbólikus hivatkozásokat tartalmaz, hogy mind a katalógus részletek, mind a fájlok maguk a gépek között természetesen áthelyezhetőek legyenek. Az egyes gépeken folyó tevékenységet például programfejlesztésnek képzelhetjük, ahol az egyik fejlesztő által előállított modulokat több más fejlesztő építi be a programjaiba. De lehet ez egy hivatali rendszer is, ahol a különböző osztályok egymás eredményeit használják fel, vagy a titkárnő a főnök feljegyzései alapján készít különböző dokumentumokat, leveleket stb.

A fent vázolt rendszerben algoritmusunk kettős szinten alkalmazható, egyrészt a katalógusra, másrészt a fájlokra. A leggyakrabban használt fa szerű katalógusokra algoritmusunk alapelve /a felhasználási helyre gyűjteni azon adatelemeket, amelyekre a közeljövőben valószínűleg hivatkozás történik/ kétszeresen is érvényes. Egyrészt, hogy az egyszer hivatkozott adatelem

valószínűleg újra felhasználásra kerül, másrészt a hivatkozások nem függetlenek egymástól, hanem a katalógus strukturáját követik, azaz két egymást követő hivatkozás egymás logikai környezetébe esik. Például katalógusok esetén algoritmusunk kiegészíthető azzal, hogy egy elemre való hivatkozásnál, nemcsak az elemről, hanem annak közvetlen logikai környezetéről is másolat készül. Ez Ethernet típusu lokális hálózatok esetén még a hálózat terhelését sem növeli, mivel az optimális csomagméret több katalóguselemet képes magába foglalni.

#### 4. Néhány szó a megvalósításról

Egy lokális hálózatban, akármilyen elosztott rendszer megvalósításánál, a következő problémával kell számolni. A lokális hálózat általában személyi számítógépekből áll amelyeket nem folyamatos üzemben használnak. Egy-egy gép lekapcsolásával vagy számítani kell arra, hogy az elosztott rendszer egy része hozzáférhetetlenné válik, vagy lekapcsolás előtt a gépen tárolt információt a rendszer többi részének át kell venni. Az egyes gépeken tárolt információ kikapcsolás esetén való teljes mentése, különlegesen nagy háttértároló kapacitások nélkül, a kikapcsolások előrehaladtával a rendszer teljes összeomlásához vezet. Mindenképpen kompromisszumot kell kötni a mentendő adatok mennyiségére vonatkozóan. Egy célszerű kompromisszumnak látszik a katalógus mentése és a fájlok "veszni hagyása". Esetleg ez azzal finomítható, hogy a felhasználó bizonyos fájlok mentését is előírhatja. Ezzel a módszerrel arra a kérdésre mindenképpen választ tudunk adni, hogy egy adott fájl létezik-e vagy nem, legfeljebb magát a fájlt nem tudjuk szállítani. Az elosztott rendszer a gépeknek egy kivétellel való kikapcsolásával centrálissá válik, s ezen megmaradt egy gépre hárulna az összes mentendő információ tárolása. Ezért célszerű a hálózatba beiktatni egy folyamatos üzemben

dolgozó csomópontot, viszonylag nagy háttértár kapacitással. Ez a csomópont vehetné át a kikapcsolt gépektől a mentendő információt. Ezzel az archiválás is egyszerűvé válik, hiszen minden mentendő információ egy helyre gyűlik /az osztott rendszerből centrális lesz/ amiről pl. az éjszaka során másolat készíthető.

Egy másik implementációs probléma az elsődleges példányokról készült másolatok nyilvántartása, illetve elérése egy felújítás során. Az egyik véglet, hogy a másolatokról semmiféle nyilvántartás nem készül. Ennek az előnye, hogy a másolatok a hálózat többi csomópontjának értesítése nélkül törölhetőek, s nem kell nyilvántartás vezetni. Hátránya, hogy felújítás esetén a hálózat összes csomópontját értesíteni kell a felújítási szándékról, hiszen nem tudható, hogy melyik tartalmaz másolatot. A másik véglet, hogy minden egyes másolat helyét nyilvántartjuk. Ilyenkor egy másolat eleresztésekor a nyilvántartót vagy nyilvántartókat /pl. láncbafűzés esetén/ értesíteni kell, viszont a felújítás kevesebb üzenettel jár, hiszen csak azon csomópontokat kell értesíteni, ahol tényleges másolat létezik. Egy közbülső változat, ami akkor használható jó hatásokkal, ha két felújítás között a másolatot készítő csomópontok száma nem túl sok. Az elsődleges példánynál nyilvántartjuk a másolatot kérő csomópontokat. Egy másolat törlésekor nem küldünk értesítést, így valamivel több csomópont van nyilvántartva, mint ahány tényleges másolat létezik, de még mindig kevesebb, mint ahálózat összes csomópontja. Felújításkor csak a felsorolt csomópontokkal kell üzenetet váltani a másolatok törléséhez.

##### 5. Irodalomjegyzék

Howard L.Morgan és K. Dan Levin: Optimal Program and Data Locations in Computer Networks  
CACM May 1977 315-322.

Enrique Grapa és Geneva G. Belford; Some Theorems to  
Aid in Solving the File Allocation Problem

CACM Nov 1977 878-882.

Raymond R.Ranko: Facing Basic Issues in Office Auto-  
mation

Computer Networks 5/1981 391-399.

Peter J. Denning: The Working Set Model for Program  
Behavior

CACM May 1968 323-334.





HIRDETÉS MELLÉKLETEK





TELEFONGYÁR  
Budapest  
Hungária krt 126-132.  
1143

# Computerta

## USP - felhasználói programok készítését támogató programcsomag a TAP - 34 számára

Az USP /User Support Package/ programcsomag célja az, hogy megkönnyítse a helyi adatfeldolgozási feladatok megoldását a TAP-34 intelligens terminálon.

A programcsomagot alkotó szubrutinok elsősorban a klaviatúráról történő adatbevitelt, a hajlékony mágneslemezen történő adattárolást és visszakeresést, valamint kisebb adatfeldolgozást igénylő feladatok megvalósításakor alkalmazhatók előnyösen. Ilyen feladat lehet például raktárnyilvántartás, számlázás, személyi adatnyilvántartás stb.

### A programcsomag főbb funkciói

#### ADATBEVITEL

Az USP adatbeviteli rutinjai lehetővé teszik a programozó számára, hogy a felhasználói képernyő bármely sorában egy, legfeljebb 89 karakter hosszúságú input mezőt definiáljon, és azt a kezelővel kitölttesse.

Többek között lehetőség van a mezőbe bevihető karakterek ti-

pusának meghatározására /pl. numerikus mező/, a bevitt karakterek megjelenítésének előírására /pl. aláhúzva/, a mező karaktereinek a mező lezárása utáni igazítására /pl. jobboldali mezőhatárra igazítás/, numerikus mező esetén kezdő zérus feltöltésre vagy elnyomásra, a kitöltött mező tartalmának érték szerinti automatikus ellenőrzésére /pl. minimális érték/, stb.

### ADATTÁRCLÁS

Az USP hajlékony mágneslemezen történő adattárolásra vonatkozó rutinjai jelentősen kibővítik a TAP 34 "SYS" rutinjaival adott lehetőségeket, rugalmasabb file szervezést és kezelést tesznek lehetővé.

Az USP lemezkezelő rutinjai által létrehozott és kezelt file-ok rekordos szervezésűek. A file-okban az adatok logikai rekordokban helyezkednek el, a rutinok segítségével az adatok logikai rekordonként írhatók vagy olvashatók. Az egyes logikai rekordokat nem csak sorosan, hanem véletlenszerűen is el lehet érni. Egy file-on belül az egyes rekordok azonos hosszúságúak. Lehetőség van a file-okban tartalom szerinti keresésre is.

A lemezkezelés megfelel az IBM diskette formátumnak.

### ADATFELDOLGOZÁS

Az USP adatfeldolgozó rutinjaival numerikus adatokon aritmetikai műveleteket, byte-sorozatokon pedig különböző manipulációkat hajthatunk végre.

Numerikus adatok ábrázolására kétféle lehetőséget nyújt a programcsomag. Az egyik esetben egész- és törtrészből álló fixpontos, decimális, karakteres formában tárolt, előjeles számokkal dolgozhatunk. Ekkor a számábrázolás pontossága 14 digit, ami gyakorlatilag minden ügyviteli, gazdálkodási feladat megoldására elegendő. A másik számábrázolási mód 16 bites, előjel nélküli, bináris egész számokkal dolgozik, ez elsősorban a programok belső szervezéséhez és számlálásokra használható.

Tumerikus adatok között a négy alapszűveletet /összeadás, kivonás, szorzás, osztás/, összehasonlítás és kerekítést hajthatunk végre az USP rutinjaival.

A byte-sorozatokon számos műveletet hajthatunk végre, így többek között feltöltés, írás, olvasás, beszűrés, törlés, másolás, összehasonlítás és keresés műveleteket.

### ADATMEGJELENÍTÉS

Az USP formátumvezérelt adatmozgató rutinjai egy egyszerű módon megadható formátum alapján tördelve, rendezve, módosítva és konstans részekkel kiegészítve jelenítik meg a kívánt adatokat. Eközben olyan hasznos segédfunkciókat is ellátnak a rutinok, mint például a nyomtatón a fejléc automatikus nyomtatása lapváltáskor és a lapok számozása.

### HIBAKEZELÉS, ÁLLAPOTJELZÉS

Az USP minden rutinjának egységes, közös hibakezelése van. Az egyes rutinok a program futása közben ellenőrzik a bemenő paramétereket és adatokat, valamint a műveletek során keletkező eredményeket, és jelzik, ha valahol hibát észlelnek.

A hibajelzés rugalmasan alkalmazkodhat a kívánt feladathoz. A standard hibajelzés és hibaűzenet /amely információt ad a hiba keletkezésének helyéről és a hiba jellegéről/ helyett a programozó saját hibaűzenetet definiálhat, vagy akár az egyes hibák kezeléséhez saját hibakezelő programot írhat.

Az USP 1983 elején tapasztalatszerzésre néhány felhasználónak átadásra került, és az első tapasztalatok kedvezőek.



AGROELEKTRONIKAI GT.  
Budaörs, Molnár P. u.1  
2040  
Telefon: 260-612,  
Telex: 22-5962

Új formatervezett kivitelben és megnövelt  
üzembiztonsággal szállítjuk az

#### AIRCOMP-16

személyi számítógépet:

- olcsó,
- kiváló BASIC-interpreter,
- hatékony kiegészítő szoftver:
  - \* dupla pontosságú aritmetika,
  - \* monitorbővítés assembler-rel  
és disassembler-rel

#### AIRCOMP-32

mikroszámítógépet:

- programból történő magnóvezérlés,
- szükség esetén nyomógombos billentyűzettel

#### URD-85

TV-alapú alfanumerikus és grafikus terminált:

- olcsó,
- 24 \* 80 karakteres képernyő
- soros adatátviteli vonalon összeköthető  
számítógéppel
- képfelbontása 256 \* 256 pont

## Hatékonyabb programozás PERSONAL-szoftverrel!

Új kiegészítő SW a VT20 számítógépcsaládhoz:

- **MTDS-80**  
többmunkahelyes adatrögzítő rendszer
- **BASIC-hez assembly-szubroutinesomag**  
- MENÜ  
automatikus képernyőkezelő rendszer
  - \* képernyő létrehozása és eltárolása,
  - \* meződefiníálási lehetőség,
  - \* eltárolt képernyő megjelenítése és ezen belül IO-műveletek
  - \* BASIC- és assembly-rutinok töltése és indítása programból (programláncolás)
- **opcionális szubrutinyűjtemény**  
kiegészíti a BASIC-interpreter lehetőségeit:
  - \* gyors adatbáziskezelő rutinok,
  - \* szekvenciális file-ok törölhetősége,
  - \* diszkterület direkt elérése
  - \* stb.
- **mezőgazdasági programcsomagok**

### VÁLLALUNK

Kisszámítógépes rendszertervezést és komplett felhasználói programrendszerek irását. Szaktanácsadást biztosítunk kisgépes rendszerek létrehozásában és a megfelelő géptípus kiválasztásában.

**BOSCOOP**

Közös Képvisező:

Agrárripari Közös Vállalat, 2040 Budaörs,  
Nefelejcs u. 2. Telefon 260-612, Telex: 22-5962



## PÉNZÜGYI SZÁMÍTÁSTECHNIKAI INTÉZET

### A PÉNZÜGYI INFORMÁCIÓRENDSZER BÁZISINTÉZETE

#### FELADATAI:

- A központi és a tanácsi pénzügyekkel összefüggő szervezési, számítástechnikai és koordinációs feladatok ellátása /rendszerfejlesztés, adatfeldolgozás/
- A gazdasági- pénzügyi szabályozás és irányítás számítástechnikai támogatása /szervezés, adatfeldolgozás, gazdaságmatematikai módszerek/
- Az Állami Biztosító, a pénzintézetek, PM vállalatok és intézmények részére szervezési és számítástechnikai szolgáltatások nyújtása
- A pénzügyi információrendszer központi és hálózati eszközeinek üzemeltetése, műszaki fejlesztése, karbantartása.

A KÖZPONTI NAGYSZÁMÍTÓGÉPEKHEZ CSATLAKOZÓ TPA HÁLÓZATI RENDSZER ÉS VIDEOTON TERMINÁLOK EGYARÁNT LEHETŐVÉ TESZIK AZ ADATFELDOLGOZÁSI FELADATOK MEGOLDÁSÁT KÖTEGELT ÉS INTERAKTIV ÜZEMMÓDBAN.

PÉNZÜGYI SZÁMÍTÁSTECHNIKAI INTÉZET

1023 Budapest, Lajos u. 17-21.

Telefon: 684-020







**ROZMARING**  
**KERTÉSZETI MG. TSZ.**  
**NAGYKOVÁCSI**

1525 BUDAPEST, Pf. 86

MNB: 380-22344

TELEX: központ: 22-6863 kertészet: 22-4262

TELEFON: 165-841, 365-937, 364-562

A RODATA GT.

VIDEOPLEX-3 típusú adatrögzítő

rendszerre

SZERVEZÉST és ADATRÖGZÍTÉST

vállal

1983.IV. negyedévéértől.

Cím: RODATA GT.

Budapest

Pincészer u. 14-16.

1028

Tel.: 251-299/176

165-460

**MEZŐGAZDASÁGI  
ÜGYVITELSZERVEZÉSI IRODA  
BUDAPEST II., Érmelléki u. 13.**

Levélcíme: BUDAPEST Pf. 230

1536

A számítástechnika alkalmazása a mezőgazdaságban

A mezőgazdasági nagyüzemek termelési jellegüket, gazdálkodási formájukat tekintve eltérnek az ipari termelő egységektől. Az eltérés elsősorban abban jelentkezik, hogy alapvető termelési profiljuk lényegében a területi adottságok, - az időjárás, a talajviszonyok, a környezeti infrastruktúra - függvénye. A termelési ciklusok zártsága, a viszonylagosan kevés eszközráfordítással járó profilváltás viszonyt rugalmas, a piaci viszonyokhoz gyorsan alkalmazkodó gazdálkodási módot tesz lehetővé. Az agráripari termelés sajátosságainak elemzésekor nem hagyhatjuk figyelmen kívül a mezőgazdasági szolgáltató ágazatokat, amelyek ma már elsősorban nem azzal tűnnek ki, hogy a munkaerőt helyben foglalkoztatják, hanem az alaptervekenység volumenét megközelítő vagy esetleg meg is haladó termelési értékükkel.

A fejlett termelési rendszerekkel rendelkező mezőgazdasági nagyüzemekben az optimális termék és termelési struktúra kialakítás az adottságok az aktuális gazdasági szabályozók, a várható kül- és belpiaci viszonyok figyelembevétele széleskörű szakmai ismereteket és nagymennyiségű információ kezelését és gyűjtését teszi szükségessé.

A Mezőgazdasági Ügyvitelszervezési Iroda Közös Vállalat Számítástechnikai Főosztálya elsősorban ezen információk gyűjtésében, tárolásában, kezelésében, feldolgozásában, valamint a számítógépes eszközök és rendszerek beszerzésében, telepítésében nyújt segítséget a termelőszövetkezeteknek.

Ebből következően a KÜSZI számítástechnikai tevékenysége ket-

tős: egyrészt adatfeldolgozó rendszerek szervezése, valamint az ezek működtetéséhez szükséges számítástechnikai eszközök kiválasztása, azok beszerzésében, installálásában való közreműködés.

A korábban ismertett információ igényekből kiindulva mindkét tevékenységi kör művelésénél meghatározó, hogy a kapott adatokat milyen célra, milyen szinten használják fel, illetve hogy mely gazdálkodási terület kiszolgálását segíti elő a számítógép.

A termelési rendszerektől, helyi adottságtól független területek - készletgazdálkodási, munkaügyi, bérügyviteli, pénzgazdálkodási, állóeszközgazdálkodási rendszerek - adatainak feldolgozását ún. típusrendszerek alkalmazásával oldottuk meg.

Ezeknél a tulajdonképpen ügyviteli rendszereknél jelenleg még az eseményt regisztráló adatfelvétel, a batch jellegű feldolgozás a meghatározó, de készülnek osztott rendszerű feldolgozások is, amelyek kihasználják a helyben lévő, tehát gyorsan hozzáférhető minigépek előnyét és a nagygépek komolyabb tárhelykapacitását és könnyebb programozhatóságát.

A speciális, ún. profilérzékeny rendszerek általában a termelésirányítással és elszámolással kapcsolatosak, az ezeket feldolgozó programcsomagok kidolgozása összetettebb feladat, ezért a MŰSZI különböző gazdálkodási területeken végzett felméréseket és ezek alapján kezdett hozzá pl. az INRA szarvasmarhatenyésztési, elszámolási programcsomag honosításához.

Az ilyen típusú számítástechnikai rendszerek már on-line feldolgozást, interaktív adatelérést és adatkezelést feltételeznek, ezért szükségesnek érezzük, hogy a fizikailag osztott rendszerek szervezése mellett, felkészüljünk a távadatfeldolgozás, és azzal együtt az on-line adatfeldolgozás alkalmazására is.

1. A mezőgazdasági üzemek információs rendszere

A mezőgazdasági üzemek többségére jellemző, hogy a tényleges működtetést befolyásoló információs rendszerük nem teljes áttekintés alapján tervezett, hanem pillanatnyi állapot rögzítése vagy szokásjog szerint működik. Ennek a gyakorlatnak az oka több irányban is kereshető:

- az üzemek alakulásának módja /összevonások/
- földrajzi tagoltság
- a termelés méretbeli növekedése és az információs rendszer fejlesztése közötti fázis különbség.

Az összevonások alkalmával biztos, hogy eltérő gyakorlatot folytató gazdaságokat vettek egy igazgatás alá, de - érthető módon - meghagyták a nem alapvető jelentésű működési sajátosságokat. Ez az eltérő gyakorlat sok esetben azonos funkciókra különböző bizonylatok, kimutatások készítésének gyakorlatát is jelenti.

A mezőgazdasági üzemek feladataik jellegéből és történelmi okok alapján is viszonylag kiterjedt területen fejtik ki tevékenységüket. A területi tagoltság - erre való igyekezet esetén is - gátolja az egységes információs rendszer kialakulását.

A méretbeli növekedések és a technológiai fejlődés magával hozta az információs igények emelkedését, de ez igen gyakran kielégítetlen igény marad. Az új helyzet esetleg nagyságrendben nagyobb mennyiségű adatfeldolgozást igényli még azonos szintű információnyújtás elérése érdekében is.

## 2. Az adatfeldolgozáshoz igénybe vett eszközök

Az irányításhoz és gazdálkodáshoz szükséges információk előállítására a termelés állapotának megfelelő léptékű ismeretét jelenti, illetve az állapotot mutató adatok feldolgozása révén lehetséges. Az adatok gyűjtése és feldolgozása napjainkban is elsősorban a könyvelés igényei és szempontjai szerint történik. A feldolgozáshoz igénybe vett könyvelőgépek és azok fejlettebb változatainak is közös jellemzője a

- nagy előkészítési igény /bizonylatok rendezése, stb./
- szűkös tároló és feldolgozó kapacitás
- centralizált működtetésük és a gép lehetőségei sem tesznek lehetővé alkalomszerű lekérdezéseket.

Egyre több üzem ismeri fel a fejlettebb adatfeldolgozási technika szükségességét és jelentőségét. Most már több év tapasztalata alapján lehet értékelni és becsülni a Termelőszövetkezetek Számítógépes Fejlesztési Együttműködése /TSZFE/ vállalkozásban résztvevő TSZ-eknek a számítógépes adatfeldolgozás szélesebb körű elterjesztése érdekében tett kezdeményezését.

A pest-környéki TSZ-ek által vásárolt számítógépek /R-22, RC-3600/ és a kialakított rendszerfejlesztő /szervezők, programozók/ szakember-gárda segítségével elértük, hogy ma már számos TSZ-ben támaszkodnak a számítógépek által nyújtott szolgáltatásokra. Az alkalmazási területek a gazdálkodás alapkategóriáinak adatfeldolgozását célozzák:

- anyag-fogyóeszköz
- állóeszköz
- munkaügy-bér
- pénz.

Az eddig megoldott és felsorolt területek közös jellemzője az igen nagy mennyiségű adat /esetleg többször 10.000/ és a havinál nem gyakoribb feldolgozási igény. Az ügyviteli-gazdálkodási rendszereken túl készítettünk és működtetünk állattartó telepek termelésirányítását segítő rendszereket is, melyek szarvasmarhatelepen és csincsilletelepen folyó termelő és te-

nyésztő munkát segítik. Ez utóbbi rendszerek jellemzője, hogy kevesebb adat /legfeljebb néhány ezer/ feldolgozását végzik, de a feldolgozás gyakorisága legalább dekád léptékű kell, hogy legyen. A számítógép szolgáltatása adatok felhasználhatósága és az események rögzítését jelentő adatfelvételezés közötti összefüggés rendkívül szoros, hiszen nincs elavultabb dolog, mint a telepi események megtörténte utáni "prognozsis" a bekövetkező tartási eseményekre. A mezőgazdasági üzem és a feldolgozó számítóközpont közötti nagy távolság /az adatok utaztatása elkerülhetetlen/ egyes területeken az igazán hatékony számítástechnika alkalmazást nehezíti meg, míg más területeken lehetetlenné teszi a számítógép igénybevételét. Könnyen belátható, hogy a "párbeszédés" problémamegoldási kényszer a szakember és a számítógép közvetlen kapcsolatát feltételezi.

### 3./ Uj igények az adatfeldolgozó gép iránt

Az ügyviteli és ehhez kapcsolódó gazdálkodási munkát segítő számítógépes feldolgozások egy területen /pl. állóeszköz/ belül is oszthatók az egyes funkciók ellátásakor megkövetelt operativitási /nap, dekád, hó, stb./ szint szerint. Más területek /pl. pénzgazdálkodás/ nagyrészt napi feldolgozási gyakoriságot igényelnek. Az eddig felsorolt és további most nem részletezett okok új igényeket támasztanak az alkalmazott számítástechnika iránt. Ezek az új szempontok a következők:

- a felhasználók lényegében bármikor hozzáférjenek, vagyis a gép legyen a gazdaságban,
- adjon lehetőséget "párbeszédés" problémamegoldásra /a szakember feldolgozás közben véleményezhesse a részeredményeket/. Ez indokolt például egy takarmányösszetétel optimalizálás esetén,
- a berendezés biztosítsa a közpégek által előállított másodlagos adathordozók /pl. lyukszalag/ feldolgozásának lehetőségét,
- beszerzési ára ne tegye elérhetetlenné a kisebb és közepes méretű üzemeknél sem.

Ezek az igények valamilyen kiszámítógéppel kapcsolatos elvárásokat körvonalazzák. Vállalatunk 1981 óta jelentős erőket mozgósított a mikrogép alkalmazási igény kielégítésére. Tevékenységünk során elsősorban hazai gyártmányú mikrogépekre fejlesztettünk felhasználói rendszereket. Alkalmazott géptípusok: TAP-34, MØØX, FLOPPYMAT-SP. Az egyes géptípusok az üzemi próbákon túljutottak, és 1984. évtől tömeges elterjesztésüket tervezzük.

## TARTALOMJEGYZÉK

Alexits Gy.,Kerékfy P.,Rákóczi F. Ruda M.: Micro - Shiva néhány mikrogépes adatfeldolgozási eszköz ismertetése...	88
Békéssy Péter - Szalay Imre: VIDOTON adatbáziskezelők számítógéphálózatban.....	106
Bertalan József: A Kutatási Fejlesztési Irányítási In- formációs Rendszerről.....	127
Dr.Budavári Elemér: Meta-információrendszerrel támoga- tott rendszerfejlesztés és adatbázistervezés.....	7
Csicsman József: A SOLAR Adatszótára.....	26
Dr.Dajka Miklós: Az információrendszerek felhasználói szin- tű leírása adatbáziskezelő rendszerek alkalmazása esetén.....	170
Demjén Ferenc: Teljes dokumentumok normalizálása természe- tes nyelvű információs rendszerben.....	160
Fogarassy Károly: Logar adatbáziskezelő rendszer.....	165
Garai Péterné - Straub Elek: Statisztikai adatállományok megőrzésének és forgalmának jogi szabályozása.....	15
Götl Győző - Farkas Gabriella: Párbeszédés Programgenerálás adatbázis lekérdezésére.....	38
Dr.Halassy Béla: ÁDÁM és ÉVA - Adat - és eljárásmodellezési segédeszköz.....	1
Iványi Antal,Luderer Bernd, Szotnyikov A.N .: Deszkriptoros információvisszakereső rendszerek paramétereinek optimá- lis megválasztásáról.....	43
Kádár István - Polák István: Sikbéli és térbeli pontthalmazok strukturált tárolásának matematikai és számítástechnikai kérdései.....	81
dr.Kelen Lászlóné - Gilicze László: Osztott adatbázis kiala- kitása CII Honeywell Bull és TPA 11/40 számítógépeken...	67
Kovács András - Sugár Péter - Vig Ervin - Kormos Kornélia- Apor György: Az IFP szöveges információkezelő rendszer és alkalmazásai.....	21
Kovács Kálmán: Personal data management system mikroszámi- tógépes adatbáziskezelő rendszer.....	73



Ifj.Krekó Béla: Adatmodellezés a népgazdasági tervezésben...	99
Locsmándi Miklós: Matematikaai statisztikai módszerek alkalmazása adatbázisok kiértékelésénél.....	176
Locsmándi Miklós: Építkező programgenerátor SESAM típusu adatbankok kiértékeléséhez.....	180
Lovász Attila: Real-time adatbáziskezelő rendszerek teljesítményvizsgálata és tervezése modellezéssel.....	123
Lőrincz István: KFIIR fogalmi szótár kezelő és karbantartó rendszer.....	133
Lőrincz István - Lőrincz János: Több lépéses duális clusterezési algoritmus alkalmazása információs rendszerekben..	142
Lőrincz István - Tóth Lajos: ETKR: egy általános gráfkezelő rendszer.....	146
Majtényi Edit: Adatbázisadminisztráció a statisztikai információrendszerben.....	49
Márkus Gábor: Adatvédelem - felhasználó - azonosítás.....	55
Petényi Andrea Ingeborg: TELEDATA rendszer - általános ismertető.....	30
Pogány András: Egy fájl elérési és mozgatósi stratégiája lokális elosztott rendszerekre.....	192
Dr.Pölöskei Pál: Néhány adatbázis alkalmazás tapasztalatai Az IDMS használata alapján.....	188
Dr.Szelezsán János: Hálós adatbázisok egy matematikai modellje.....	184
Dr.Szőke Péter - Baranyai István: A KFIIR /általános szöveges faktografikus információ kezelő rendszerének/ általános programeszközei.....	154
Dr.Tankó József: Kiegyensúlyozott adatbázis alkalmazások....	61
Ungár János: Szoftver eszközök adatbázis kezelő rendszerek megbízhatóságának javítására és adatai integritásának megőrzésére.....	92
Vargha Dénes: A gépi szövegfeldolgozás szerepe a japán 5. generációs projekt realizálásában.....	78
Várnai Katalin: Dinamikus állományszerkezetek.....	112
Velkei Sándor: Teledata bázisu alkalmazói rendszerek.....	118
Zvara Flórián: Dinamikus listázó.....	151

Kiadja: a Neumann János Számítógéptudományi Társaság  
a Műszaki és Természettudományi Egyesületek  
Szövetsége tagja

Szerkesztette: a II. Országos NJSZT Kongresszus Program-  
bizottsága

ISBN szám: 963 8431 33 4 összkiadás 36 9

Készült: a KSH SZÜV nyomdában



