

2.4. Egy algebrai lekérdező nyelv

Ebben a részben bevezetjük a relációs modell adatmanipulációs részeit. Emlékezzünk, hogy az adatmodell nem csupán egy struktúra, hanem kellene módszerek az adat lekérdezésére és módosítására is. A relációkon értelmezett műveletek tárgyalása előtt be kell vezetnünk egy speciális algebrát, a *relációs algebrát*, amely egyszerű (de hatékony) lehetőségeket tartalmaz az adott relációkból új relációk létrehozására. Ha a relációk tárolt adatok, akkor az előállított reláció lehet egy, az adatokon történt lekérdezésre a válaszreláció. A relációs algebra a forgalomban lévő ABKR-ek manapság már nem használják lekérdező nyelvként annak ellenére, hogy a kezdeti próbaverziók viszont direkt módon használták ilyen célokra. Az SQL, a „valódi” lekérdező nyelv, a relációs algebrára épül, és sok SQL-program valójában „szintaktikailag fűszerezett” relációs algebra. Sőt, mikor az ABKR egy lekérdezést dolgoz fel, akkor az első dolog, ami az SQL-lekérdezéssel történik, hogy lefordítják vagy relációs algebrába vagy egy hozzá nagyon hasonló belső formára. Azaz rengeteg oka van, hogy a relációs algebra tanulmányozásával kezdjük a tanulást.

2.4.1. Miért kell egy speciális lekérdező nyelv?

A relációs algebra műveleteinek bevezetése előtt megkérdezhetnénk, hogy miért is van szükségünk egy új típusú programozási nyelvre az adatbázisokhoz. Nem lenne elegendő a legelterjedtebb (mint C, illetve Java) nyelvek használata, hogy kérdéseket fogalmazzunk meg, illetve hogy kiszámoljuk a kérdéshez tartozó relációt? Mindemellett a reláció egy sora kifejezhető struktúraként (C-ben) vagy objektumként (Javában), és így a relációt megadhatnánk ilyen elemek tömbjeként is. A meglepő válasz, hogy a relációs algebra azért hasznos, mivel *kevésbé* kifejezőbb, mint a C vagy a Java. Vagyis vannak számítások, amelyek megvalósíthatóak ezen nyelvekben, de a relációs algebrában nem. Egy példa erre, hogy ha meg akarjuk határozni, hogy egy relációnak páros vagy páratlan sora van-e. Azzal, hogy korlátozzuk, hogy mit tudunk kifejezni, illetve csinálni a lekérdező nyelvünkben, két nagy előnyre teszünk szert: kényelmes programozást és a fordító által magas szinten optimalizált kódok előállítását. Ezeket a 2.1.6. résznél tárgyaltuk.

2.4.2. Mit nevezünk algebrának?

Egy algebra általában műveleteket és atomi operandusokat tartalmaz. Például egy számtani algebra esetén az x -hez hasonló változók és a 15-höz hasonló konstansok lesznek az atomi operandusok. A műveletek általában számtani műveletek lesznek: összeadás, kivonás, szorzás és osztás. Az algebra lehetővé teszi *kifejezések* megfogalmazását az atomi operandusokon és/vagy algebrai kifejezéseken végzett műveletek alkalmazásával. Gyakran zárójeleket is kell használnunk a műveletek operandusainak különválasztásához, mint például a következő kifejezéseknél: $(x + y) * z$ vagy $((x + 7)/(y - 3)) + x$.

A relációs algebra is példa egy algebrára. Az **atomi operandusok a következők:**

1. A relációkhoz tartozó változók.
2. Konstansok, amelyek véges relációt fejeznek ki.

A következőkben megmutatjuk a relációs algebra műveleteit.

2.4.3. A relációs algebra áttekintése

A hagyományos relációs algebrai **műveletek** négy osztályba sorolhatóak:

- a) A hagyományos **halmazműveletek** – egyesítés, metszet és különbség – relációkra alkalmazva.
- b) Műveletek, amelyek a reláció egyes részeit eltávolítják: a „**kiválasztás**” kihagy bizonyos sorokat, a „**vetítés**” bizonyos oszlopokat hagy ki.
- c) Műveletek, amelyek két reláció sorait kombinálják: a „**Descartes-szorzat**”, amely a relációk sorait párosítja az összes lehetséges módon és a különböző típusú „**összekapcsolási**” műveletek, amelyek szelektíven párosítják össze a két reláció sorait.
- d) Egy művelet, az „**átnevezés**”, amelyik nem befolyásolja a reláció sorait, de megváltoztatja a reláció sémáját, azaz az attribútumok neveit és/vagy a reláció nevét.

A relációs algebrai kifejezésekre általában *lekérdezések*ként hivatkozunk.

2.4.4. Relációkon értelmezett halmazműveletek

Halmazokon a három leggyakoribb művelet az egyesítés, metszet és különbség. Feltételezzük, hogy az olvasó ismeri ezeket a műveleteket, amelyeket a következő módon definiálunk tetszőleges R és S halmazok esetén:

- $R \cup S$, R és S **egyesítése**, azon elemek halmaza, amelyek vagy az R -ben vagy az S -ben vannak. Egy elem csak egyszer szerepel az egyesítésben, még akkor is, ha jelen van az R -ben is és az S -ben is.
- $R \cap S$, R és S **metszete**, azon elemek halmaza, amelyek az R -ben és az S -ben is benne vannak.
- $R - S$, R és S **különbsége**, azon elemek halmaza, amelyek benne vannak R -ben, de nincsenek S -ben. Figyeljük meg, hogy $R - S$ nem ugyanaz, mint $S - R$; az utóbbi azon elemek halmaza, amelyek benne vannak S -ben, de nincsenek R -ben.

Ezen műveletek relációkra történő alkalmazásakor néhány feltételt kell szabnunk:

1. Az R és S relációk sémája ugyanazt az attribútumhalmazt kell tartalmazza, illetve a típusok (értéktartományok) az összes megfelelő attribútum-párra megegyeznek R -ben és S -ben.
2. Mielőtt kiszámolnánk a halmazelméleti egyesítését, metszetét vagy különbségét a sorhalmazoknak, az R és S oszlopait rendezni kell úgy, hogy az attribútumok sorrendje egyforma legyen mindkét reláció esetén.

Néha szeretnénk kiszámolni két olyan reláció egyesítését, metszetét vagy különbségét, amelyek attribútumainak a száma megegyezik, viszont az attribútumok neve különbözik. Ebben az esetben az egyik vagy mindkét reláció sémájának megváltoztatásához használhatjuk a 2.4.11. alfejezetben bemutatott átnevezés operátort, és így ugyanazt az attribútumhalmazt tudjuk adni a relációknak.

<i>név</i>	<i>cím</i>	<i>nem</i>	<i>születésidátum</i>
Carrie Fisher	123 Maple St., Hollywood	N	9/9/99
Mark Hamill	456 Oak Rd., Brentwood	F	8/8/88

Az R reláció

<i>név</i>	<i>cím</i>	<i>nem</i>	<i>születésidátum</i>
Carrie Fisher	123 Maple St., Hollywood	N	9/9/99
Harrison Ford	789 Palm Dr., Beverly Hills	F	7/7/77

Az S reláció**2.12. ábra.** Két reláció

2.8. példa. Tegyük fel, hogy van két relációnk, az R és az S , amelyek a 2.2.8. alfejezetben található FilmSzínész reláció előfordulásai. Az R és S aktuális előfordulásait a 2.12. ábrán láthatjuk. Az R és S egyesítése, $R \cup S$, a következő reláció:

<i>név</i>	<i>cím</i>	<i>nem</i>	<i>születésidátum</i>
Carrie Fisher	123 Maple St., Hollywood	N	9/9/99
Mark Hamill	456 Oak Rd., Brentwood	F	8/8/88
Harrison Ford	789 Palm Dr., Beverly Hills	F	7/7/77

Figyeljük meg, hogy a Carrie Fisher adatait tartalmazó sor csak egyszer jelenik meg az eredményben annak ellenére, hogy mindkét relációban szerepelt.

Az $R \cap S$ metszet:

<i>név</i>	<i>cím</i>	<i>nem</i>	<i>születésidátum</i>
Carrie Fisher	123 Maple St., Hollywood	F	9/9/99

Most csak a Carrie Fisher adatait tartalmazó sor jelenik meg, mert csak ez a sor szerepel mindkét relációban.

Az $R - S$ különbség:

<i>név</i>	<i>cím</i>	<i>nem</i>	<i>születésidátum</i>
Mark Hamill	456 Oak Rd., Brentwood	M	8/8/88

Az R -ben a Fisher és Hamill adatait tartalmazó sorok szerepelnek, ezért ők mindketten szerepelhetnének az $R - S$ különbségben. Viszont a Fisher adatait tartalmazó sor szerepel az S -ben is, ezért nem szerepelhet az $R - S$ különbségben. \square

2.4.5. Vetítés

A **vetítés** operátorral a régi R relációból olyan új reláció hozható létre, amelyik csak az R bizonyos oszlopait tartalmazza. A $\pi_{A_1, A_2, \dots, A_n}(R)$ kifejezés értéke az a reláció, amelyik az R relációnak csak az A_1, A_2, \dots, A_n attribútumokhoz tartozó oszlopait tartalmazza. Az eredmény sémája az $\{A_1, A_2, \dots, A_n\}$ attribútumhalmaz, amelyet mi megegyezés szerint egy rendezett listával jelölünk.

<i>cím</i>	<i>év</i>	<i>hossz</i>	<i>műfaj</i>	<i>stúdióNév</i>	<i>producerAzon</i>
Csillagok háborúja	1977	124	sci-fi	Fox	12345
Galaktitkos küldetés	1999	104	vígjáték	DreamWorks	67890
Wayne világa	1992	95	vígjáték	Paramount	99999

2.13. ábra. A Filmek reláció

2.9. példa. Tekintsük a 2.2.8. alfejezetben megadott sémájú Filmek relációt. A reláció egy előfordulását a 2.13. ábrán láthatjuk. Ezt a relációt a következő kifejezés segítségével vetíthetjük az első három attribútumára:

$$\pi_{\text{cím, év, hossz}}(\text{Filmek})$$

Az eredményül kapott reláció a következő:

<i>cím</i>	<i>év</i>	<i>hossz</i>
Csillagok háborúja	1977	124
Galaktitkos küldetés	1999	104
Wayne világa	1992	95

Megjegyzés az adat minőségéről :-)

Miközben felettébb odafigyeltünk arra, hogy a példáinkban minél pontosabb adatokat adjunk meg, ennek ellenére fiktív értékeket adtunk a lakcímekre és személyes adatokra nézve azért, hogy az előadóművészek személyes jogait ne sértsük meg. Hiszen sokan közülük érzékenyek lehetnek a magánszférájukra.

Másik példaként levetíthetjük a **Filmek** relációt a műfaj attribútumra a $\pi_{\text{műfaj}}(\text{Filmekek})$ kifejezéssel. Ekkor az eredményül kapott reláció csak egyetlen oszlopot tartalmaz:

$\frac{\text{műfaj}}{\text{sci-fi}}$
vígjáték

Figyeljük meg, hogy az eredményben csak két sor található, mivel a 2.13. ábrán látható utolsó két sor műfaj attribútumának értéke ugyanaz. \square

2.4.6. Kiválasztás

Az R relációra alkalmazott **kiválasztás** operátor olyan új relációt hoz létre, amely az R sorainak egy részhalmazát tartalmazza. Az eredménybe azok a sorok kerülnek, amelyek teljesítenek egy adott, az R attribútumaira megfogalmazott C feltételt. Ezt a műveletet a $\sigma_C(R)$ kifejezéssel jelöljük. Az eredményreláció sémája megegyezik az R sémájával, és megegyezés szerint az attribútumokat ugyanabban a sorrendben tüntetjük fel, mint ahogyan az R relációban használtuk.

A C egy olyan feltételkifejezés, amelyet megszoktunk a hagyományos programozási nyelveknél. Például az `if` kulcsszót feltételkifejezés követi mind a C , mind pedig a Java programozási nyelvekben. Az egyetlen különbség az, hogy **a C feltételben levő operandusok vagy konstansok, vagy az R attribútumai.** Alkalmazzuk a C feltételt az R minden egyes t sorára oly módon, hogy a C -ben előforduló minden egyes A attribútumra behelyettesítjük a t sornak az A attribútumhoz tartozó komponensét. Ha a C feltétel összes attribútumát behelyettesítve a C értéke igaz, akkor a t sor egyike azoknak a soroknak, amelyek megjelennek a $\sigma_C(R)$ eredményében; egyébként a t nincs az eredményben.

2.10. példa. Tekintsük a 2.13. ábrán látható **Filmek** relációt. Ebben az esetben a $\sigma_{\text{hossz} \geq 100}(\text{Filmekek})$ kifejezés értéke a következő:

<i>cím</i>	<i>év</i>	<i>hossz</i>	<i>műfaj</i>	<i>stúdióNév</i>	<i>producerAzon</i>
Csillagok háborúja	1977	124	sci-fi	Fox	12345
Galaktitkos küldetés	1999	104	vígjáték	DreamWorks	67890

Az első sor kielégíti a $\text{hossz} \geq 100$ feltételt, hiszen ha behelyettesítjük a **hossz** helyébe az első sor megfelelő komponensét, a 124-et, akkor a feltétel így néz ki: $124 \geq 100$. Ez utóbbi feltétel igaz, ezért az első sort elfogadjuk. Ugyanilyen indokok magyarázzák, hogy a 2.13. ábra második sora miért kerül be az eredménybe.

A harmadik sor **hossz** komponense 95. Ezért, amikor behelyettesítünk a **hossz** attribútumba, a $95 \geq 100$ hamis feltételt kapjuk. Ennélfogva a 2.13. ábra utolsó sora nincs az eredményben. \square

2.11. példa. Tegyük fel, hogy a **Filmek** relációból azon sorok halmazát szeretnénk megkapni, amelyek a Fox stúdió legalább 100 perces filmjeit tartalmazzák. Ezeket a sorokat egy olyan bonyolultabb feltétel segítségével kaphatjuk meg, amelyet két részfeltétel AND összekapcsolásával nyerünk. A keresett kifejezés:

$$\sigma_{\text{hossz} \geq 100 \text{ AND stúdióNév} = \text{'Fox'}}(\text{Filmekek})$$

Az eredmény:

<i>cím</i>	<i>év</i>	<i>hossz</i>	<i>műfaj</i>	<i>stúdióNév</i>	<i>producerAzon</i>
Csillagok háborúja	1977	124	sci-fi	Fox	12345

Az eredményrelációnak egyetlen sora van. \square

2.4.7. Descartes-szorzat

Két halmaz, R és S **Descartes-szorzata** (vagy **direkt szorzata** vagy egyszerűen csak **szorzata**) azon párok halmaza, amelyeknek első eleme az R tetszőleges eleme, a második pedig az S egy eleme. A szorzat jelölése $R \times S$. Amikor R és S relációk, a szorzat lényegéből adódóan szintén reláció. Mivel azonban az R és S elemei sorok, mégpedig általában egynél több komponensből álló sorok, ezért az R egy sorának párosítása az S egy sorával olyan hosszabb sort eredményez, amelyben az alkotó sorok mindegyik komponense megjelenik. Az R (a baloldali operandus) attribútumai megelőzik sorrendben az S attribútumait.

Az eredményreláció sémája az R és S sémájának egyesítése. Azonban előfordulhat, hogy az R és S relációknak vannak közös attribútumai. Ekkor minden azonos nevű attribútumot tartalmazó pár esetén legalább az egyiknek új nevet kell adni. Egy olyan A attribútum egyértelművé tételéhez, amelyik mind az R ,

A	B
1	2
3	4

(a) Az R reláció

B	C	D
2	5	6
4	7	8
9	10	11

(b) Az S reláció

A	$R.B$	$S.B$	C	D
1	2	2	5	6
1	2	4	7	8
1	2	9	10	11
3	4	2	5	6
3	4	4	7	8
3	4	9	10	11

(c) Az $R \times S$ eredménye**2.14. ábra.** Két reláció és a Descartes-szorzatuk

mind az S sémájában szerepel, a nevek megkülönböztetésére az $R.A$, illetve $S.A$ jelöléseket használjuk attól függően, hogy az R reláció A attribútumáról vagy az S reláció A attribútumáról van szó.


2.12. példa. A tömörség kedvéért használjunk egy absztrakt példát a szorzásművelet szemléltetésére. Tekintsük a 2.14 (a), illetve a 2.14 (b) ábrán látható R és S relációkat, az ábrán megadott sémákkal és sorokkal. Amint az 2.14 (c) ábrán is látható, az $R \times S$ szorzat hat sorból áll. Figyeljük meg, hogyan párosítottuk az R két sorának mindegyikét az S három sorának mindegyikével. Mivel a B mindkét sémának attribútuma, ezért az $R.B$ és $S.B$ jelölést használtuk az $R \times S$ sémájában. A többi attribútum egyértelmű, és ezeknek a nevei változatlanok az eredmény sémájában. \square

2.4.8. Természetes összekapcsolás

Két reláció szorzásánál jóval gyakrabban van szükségünk arra, hogy *összekapcsoljunk* relációkat oly módon, hogy csak azokat a sorokat párosítsuk, amelyek

valamilyen módon összeillenek. Az összeillesztés legegyszerűbb módja két reláció természetes összekapcsolása, amelynek jelölése $R \bowtie S$, és amelyben R -nek és S -nek csak azokat a sorait párosítjuk össze, amelyek értékei megegyeznek az R és S sémájának összes közös attribútumán. Még pontosabban: legyenek A_1, A_2, \dots, A_n azok az attribútumok, amelyek megtalálhatók mind a R , mind az S sémájában. Az R egy r sorának és az S egy s sorának párosítása akkor és csak akkor sikeres, ha az r és s megfelelő értékei megegyeznek az összes A_1, A_2, \dots, A_n attribútumon.

Ha az r és s sorok párosítása az $R \bowtie S$ összekapcsolásban sikeres, akkor a párosítás eredménye egy olyan, összekapcsolt sornak nevezett sor, amelyben az R és S sémájának egyesítésében szereplő összes attribútumhoz egyetlen komponens tartozik. Az összekapcsolt sor megegyezik az r sorral az R összes attribútumán, és megegyezik az s sorral az S összes attribútumán. Mivel az r és s összekapcsolása sikeres volt, így tudjuk, hogy az r és s megegyezik azokon az attribútumokon, amelyek mind az R , mind pedig az S sémájában szerepelnek. Ezért az összekapcsolt sor is megegyezik mind az r , mind az s sorokkal a mindkét sémában szereplő attribútumokon. Az összekapcsolt sorok szerkezetét szemlélteti a 2.15. ábra. Az attribútumok sorrendjének viszont nem feltétlenül kell megegyeznie az R és S attribútumainak a sorrendjével.



2.15. ábra. Sorok összekapcsolása

2.13. példa. A 2.14. ábra (a) és (b) részén látható R és S relációk természetes összekapcsolásának eredménye:

A	B	C	D
1	2	5	6
3	4	7	8

Az R és S egyetlen közös attribútuma a B . Ennek következtében a sorok sikeres párosításához elegendő, hogy a sorok B attribútumán levő értékek megegyezzenek. Ekkor az eredményesornak lesz egy komponense az A attribútumhoz (az

R -ből), a B attribútumhoz (az R -ből vagy S -ből) a C attribútumhoz (az S -ből), és a D attribútumhoz (az S -ből).

Ebben a példában az R első sora csak az S első sorával párosítható sikeresen; mindkét sor B attribútumának értéke 2. Ennek a párosításnak az eredménye az első sor: (1, 2, 5, 6). Az R második sora csak az S második sorával párosítható sikeresen, és ez a párosítás a (3, 4, 7, 8) sort eredményezi. Megfigyelhetjük, hogy az S harmadik sora nem párosítható az R egyetlen sorával sem, ezért nincs is semmi hatása az $R \bowtie S$ eredményére nézve. Az olyan sort, amelyet nem lehet sikeresen párosítani az összekapcsolásban szereplő másik reláció egyetlen sorával sem, *lógó sornak* is nevezzük. \square

2.14. példa. Az előző példa nem szemlélteti a természetes összekapcsolással felmerülő összes lehetőséget. Így például nem volt olyan sor, amelyik egynél több sorral is párosítható lett volna, és a két reláció sémájának csak egyetlen egy közös attribútuma volt. A 2.16. ábrán látható U és V relációk sémájának két közös attribútuma van, a B és a C . Ráadásul az ábrán szereplő egyik előfordulásnak van egy olyan sora, amelyik több sorral is összekapcsolható. A sikeresen párosítható sorok B és C komponenseinek is egyeznie kell. Ekképpen az U első sora sikeresen párosítható a V első két sorával, viszont az U második és harmadik sora csak a V harmadik sorával párosítható sikeresen. A négy párosítás eredménye a 2.16 (c) ábrán látható. \square

2.4.9. Théta-összekapcsolás

A természetes összekapcsolás előírja, hogy egyetlen speciális feltétel szerint párosítsuk a sorokat. Bár a relációk összekapcsolásának leggyakoribb kiindulási pontja a közös attribútumokban levő értékek egyenlővé tétele, néha szükség lehet két reláció sorainak más szempontból történő párosítására. Ezért bevezetjük a *théta-összekapcsolás* műveletet: a „théta” egy tetszőleges feltételre utal, amit mi θ helyett inkább C -vel jelölünk.

R és S relációknak C feltételre vonatkozó théta-összekapcsolásának jelölése $R \bowtie_C S$. Ennek a műveletnek az eredményét a következő módon kapjuk:

1. Kiszámoljuk R és S szorzatát.
2. Kiválasztjuk a szorzatból azokat a sorokat, amelyek eleget tesznek a C feltételnek.

Éppúgy, mint a szorzat műveletnél, az eredmény sémája itt is az R és S sémáinak az egyesítése. Ha szükséges megjelölni, hogy az attribútumok melyik sémából származnak, akkor használjuk az attribútumokhoz az „ R .”, illetve „ S .” előtagokat.

2.15. példa. Tekintsük az $U \bowtie_{A < D} V$ műveletet, ahol U és V a 2.16. ábra (a) és (b) részében látható két reláció. Figyelembe kell vennünk a relációk sorainak mind a kilenc lehetséges párosítását, és meg kell néznünk, hogy vajon az

A	B	C
1	2	3
6	7	8
9	7	8

(a) Az U reláció

B	C	D
2	3	4
2	3	5
7	8	10

(b) A V reláció

A	B	C	D
1	2	3	4
1	2	3	5
6	7	8	10
9	7	8	10

(c) Az $U \bowtie V$ eredménye**2.16. ábra.** Relációk természetes összekapcsolása

U sorának A komponense kisebb-e mint a V sorának D komponense. Az U első sorában az A komponens értéke 1, és ez a sor sikeresen párosítható a V összes sorával. Az U második és harmadik sorában az A komponens értéke 6, illetve 9, ezért ezek csak a V utolsó sorával párosíthatók sikeresen. Az öt sikeres párosításból eredően az eredménynek öt sora lesz. Az eredményreláció a 2.17. ábrán látható. \square

A	$U.B$	$U.C$	$V.B$	$V.C$	D
1	2	3	2	3	4
1	2	3	2	3	5
1	2	3	7	8	10
6	7	8	7	8	10
9	7	8	7	8	10

2.17. ábra. Az $U \bowtie_{A < D} V$ eredménye

Figyeljük meg, hogy a 2.17. ábrán látható eredmény sémájában mind a hat attribútum szerepel. A B és C attribútumok a megfelelő előtagokkal szerepelnek, megkülönböztetendő, hogy az U vagy a V attribútumai. Tehát a théta-összekapcsolás különbözik a természetes összekapcsolástól, hiszen ez utóbbiban a közös attribútumok csak egyszer szerepelnek. Természetesen ennek csak a természetes összekapcsolásnál van értelme, hiszen ott csak azokat a sorokat párosítjuk, amelyek megegyeznek a közös attribútumokon. A théta-összekapcsolás esetében az összehasonlító operátor más is lehet, mint az $=$, éppen ezért nem biztos, hogy az összehasonlított attribútumok megegyeznek az eredményben.

2.16. példa. Vegyük a korábbi U, V relációk théta-összekapcsolását egy összetettebb feltétellel:

$$U \bowtie_{A < D \text{ AND } U.B \neq V.B} V$$

A sikeres párosításhoz már nem elég, hogy az U sorának A komponense kisebb legyen mint a V sorának D komponense, hanem annak is teljesülni kell, hogy a két sor értéke legyen különböző a B attribútumokon. Az egyetlen sor, ami teljesíti ezt a feltételt, a következő:

A	$U.B$	$U.C$	$V.B$	$V.C$	D
1	2	3	7	8	10

Tehát a théta-összekapcsolás eredménye a fenti egyetlenegy sort tartalmazó reláció. \square


2.4.10. Lekérdezések megfogalmazása műveletek segítségével

Ha lekérdezéseket csak a műveletek egy vagy két relációra történő alkalmazásával fogalmazhatnánk meg, akkor a relációs algebra nem lenne annyira hasznos, mint amilyen hasznos valójában. Azonban **a relációs algebra** is, mint minden algebra, **lehetőséget ad arra, hogy tetszőleges bonyolultságú kifejezéseket képezzünk**. Ekkor az operátorokat vagy az adott relációkra alkalmazzuk, vagy olyan relációkra, amelyek más operátorok relációkra történő alkalmazásának eredményei.

Relációs algebrai kifejezések megadásakor, amikor a műveleteket részkifejezésekre alkalmazzuk, használhatunk zárójeleket az operandusok csoportosításának egyértelművé tételére. Lehetséges a kifejezések kifejezésfával történő megadása is: ez utóbbit nekünk könnyebb olvasni, de géppel kevésbé olvasható.

2.17. példa. Tekintsük az általunk megadott **Filmek** relációt. Tegyük fel, hogy a következő kérdésre szeretnénk megkapni a választ: „Melyek a Fox stúdióban készült, legalább 100 perc hosszúságú filmek, és ezek mikor készültek?” A kérdés megválaszolására az egyik lehetőség:

1. Kiválasztjuk a **Filmek** relációból azokat a sorokat, amelyekre a **hossz** ≥ 100 .
2. Kiválasztjuk a **Filmek** relációból azokat a sorokat, amelyekre a **stúdióNév** = 'Fox'.
3. Kiszámoljuk az (1) és (2) metszetét.
4. A (3) lépésben megkapott relációt levetítjük a **cím** és **év** attribútumokra.



2.18. ábra. Egy relációs algebrai kifejezés kifejezészája

A 2.18. ábrán a fenti lépéseknek megfelelő kifejezészát láthatjuk. A kifejezésfa kiértékelése alulról felfelé történik. A belső csúcsokban az argumentumokra (a gyerekekből kapott eredményekre) alkalmazzuk a megfelelő műveleteket. A alulról felfelé kiértékelésnél az argumentumok a megfelelő részeknél mindig rendelkezésre fognak állni. A két kiválasztást tartalmazó csúcs az (1) és (2) lépéseknek felel meg. A metszetet tartalmazó csúcs a (3) lépésnek felel meg, a vetítést tartalmazó csúcs pedig a (4) lépés.

Ugyanezt a kifejezést felírhatjuk zárójelek használatával a hagyományos lineáris jelöléssel is. A következő formula ugyanazt a kifejezést jelenti.

$$\pi_{\text{cím, év}}(\sigma_{\text{hossz} \geq 100}(\text{Filmek}) \cap \sigma_{\text{stúdióNév} = \text{'Fox'}}(\text{Filmek})).$$

Egyébként gyakori, hogy több relációs algebrai kifejezésnek is ugyanaz az eredménye. Például a fenti lekérdezés felírható egyetlen kiválasztás használatával, ha a metszetet az AND operátorral helyettesítjük. A következő kifejezés

$$\pi_{\text{cím, év}}(\sigma_{\text{hossz} \geq 100 \text{ AND stúdióNév} = \text{'Fox'}}(\text{Filmek}))$$

ekvivalens az előző kifejezéssel. \square

Ekvivalens kifejezések és lekérdezések optimalizálása

Minden adatbázisrendszernek van egy lekérdezés-válaszoló rendszere, ahol a lekérdezés legtöbbször olyan nyelvre épül, amely kifejező erejét tekintve hasonló a relációs algebrahoz. Éppen ezért a felhasználó által megfogalmazott **lekérdezéshez létezik több ekvivalens kifejezés** (az ekvivalens kifejezések olyan kifejezések, amelyeket ha ugyanazokon a relációkon értékelünk ki, ugyanazt az eredményt adják). Ezek között vannak olyanok, amelyek gyorsabban kiértékelhetők. Az 1.2.5. alfejezetben vázlatosan tárgyalt lekérdezés-válaszolóknak egyik fontos feladata éppen az, hogy egy relációs algebrai kifejezést olyan ekvivalens kifejezéssel helyettesítsen, amely hatékonyabban értékelhető ki.

2.4.11. Elnevezés és átnevezés

Ahhoz, hogy a relációk attribútumainak nevét szabályozni tudjuk, gyakran szükséges egy olyan operátor használata, amelyik kifejezetten **átnevezi** a relációkat. Egy R reláció átnevezéséhez a $\rho_{S(A_1, A_2, \dots, A_n)}(R)$ operátort használjuk. Az eredményreláció neve S , sorai azonban megegyeznek az R soraival, és attribútumainak neve balról jobbra: A_1, A_2, \dots, A_n . Ha az attribútumok neveit meg akarjuk őrizni és csak a reláció nevét szeretnénk megváltoztatni, akkor egyszerűen csak annyit írunk: $\rho_S(R)$.

2.18. példa. A 2.12. példában kiszámoltuk a 2.14. ábra (a) és (b) részében látható két reláció, R és S szorzatát. Megállapodtunk abban is, hogyha egy attribútum mindkét operandusban szerepel, akkor ezeket az attribútumokat átnevezzük oly módon, hogy az új névben az attribútumokhoz tartozó relációk neve is jelenjen meg előtagként. Tegyük fel azonban, hogy a B attribútum két előfordulását nem $R.B$, illetve $S.B$ névvel szeretnénk illetni, hanem az R reláció B attribútumának a nevét szeretnénk megőrizni, az S reláció B attribútumát pedig X névvel szeretnénk illetni. E célból átnevezhetjük az S attribútumait úgy, hogy az elsőnek a neve legyen X . A $\rho_{S(X, C, D)}(S)$ kifejezés eredménye pontosan egy olyan S nevű reláció, amelyik ugyanolyan, mint a 2.14. ábrán látható S reláció, csak az első attribútumának a neve nem B , hanem X .

Amikor megszorozzuk az R relációt ezzel az új relációval, már nem lesz gond az egyforma attribútumnevekkel, további átnevezésekre így nincs szükség. Vagyis az $R \times \rho_{S(X, C, D)}(S)$ kifejezés eredménye a 2.14(c). ábrán látható $R \times S$ reláció, kivéve, hogy az öt attribútum neve balról jobbra: A, B, X, C és D . A 2.19. ábrán ez a reláció látható.

Egy másik lehetőség az, hogy amint a 2.12. példában is tettük, kiszámoljuk a szorzatot átnevezés nélkül, ezt követően pedig átnevezzük az eredményt. A

$$\rho_{RS(A, B, X, C, D)}(R \times S)$$

kifejezés eredményének ugyanazok az attribútumai, mint a 2.19. ábrán látható

A	B	X	C	D
1	2	2	5	6
1	2	4	7	8
1	2	9	10	11
3	4	2	5	6
3	4	4	7	8
3	4	9	10	11

2.19. ábra. Az $R \times \rho_{S(X,C,D)}(S)$ eredménye

relációnak, viszont a neve RS , míg a 2.19. ábrán látható relációnak nincs neve. \square

2.4.12. Műveletek közötti kapcsolatok

A 2.4. alfejezetben bemutatott műveletek között vannak olyanok, amelyek kifejezhetők más relációs algebrai műveletek segítségével. Például a metszet kifejezhető halmazok különbségével:

$$R \cap S = R - (R - S)$$

Vagyis, ha R és S két, egyforma sémával rendelkező reláció, akkor R és S metszete kiszámolható úgy, hogy először kiszámoljuk azt a T relációt, amelyben mindazok a sorok benne vannak, amelyek az R -ben benne vannak, de S -nek nem sorai. Azaz kivonjuk R -ből az S -t. Ezután kivonjuk az R -ből a T -t, ezáltal R -nek azokat a sorait kapjuk, amelyek S -ben is benne vannak.

A két összekapcsolás szintén kifejezhető más műveletek segítségével. A theta-összekapcsolás szorzás és kiválasztás segítségével fejezhető ki:

$$R \bowtie_C S = \sigma_C(R \times S)$$

R és S természetes összekapcsolásának kifejezéséhez először vegyük az $R \times S$ szorzatot. Ezután alkalmazzuk a kiválasztás operátort a következő alakú C feltétellel:

$$R.A_1 = S.A_1 \text{ AND } R.A_2 = S.A_2 \text{ AND } \dots \text{ AND } R.A_n = S.A_n$$

ahol az A_1, A_2, \dots, A_n olyan attribútumok, amelyek mind az R , mind az S sémájában szerepelnek. Utolsó lépésként pedig mindegyik közös attribútumból csak egy példányt őrizzünk meg. Legyen az L egy olyan attribútumlista, amelyben szerepel az R összes attribútuma és emellett az S -ből mindazok az attribútumok, amelyek nincsenek benne az R sémájában. Ekkor:

$$R \bowtie S = \pi_L(\sigma_C(R \times S))$$

2.19. példa. A 2.16. ábrán látható U és V relációk természetes összekapcsolása felírható szorzás, kiválasztás és vetítés segítségével a következőképpen:

$$\pi_{A,U,B,U,C,D}(\sigma_{U.B=V.B \text{ AND } U.C=V.C}(U \times V))$$

Vagyis vesszük az $U \times V$ szorzatot. Ezután kiválasztjuk azokat a sorokat, amelyekben az egyforma nevű jelen esetben a B és a C – attribútumokhoz tartozó értékek egyenlők. Végül pedig egy vetítést végzünk az összes attribútumra, kivéve egy B és egy C attribútumot: választásunk azon V attribútumok elhagyására esett, amelyek benne vannak az U sémájában.

Egy másik példa a 2.16. példában kiszámolt théta-összekapcsolás átírása:

$$\sigma_{A < D \text{ AND } U.B \neq V.B}(U \times V)$$

Vagyis kiszámoljuk az U és V szorzatát, és utána alkalmazunk egy kiválasztást a théta-összekapcsolásban szereplő feltétel szerint. \square

Ebben az alfejezetben említett redundanciák csak a bevezetett műveletek közötti „redundanciák”. A fennmaradó hat operátor – egyesítés, különbség, kiválasztás, vetítés, szorzat és átnevezés – független halmazt alkot, egyik sem fejezhető ki a másik öt segítségével.

2.4.13. Egy lineáris jelölési mód az algebrai kifejezésekhez

A 2.4.10. alfejezetben a kifejezésfákat használtuk az összetett relációs algebrai kifejezések leírására. Egy másik megközelítés az, hogy a belső csúcsoknak megfelelő ideiglenes relációknak nevet adunk, és **egy értékadási sorozatot adunk meg** az értékeik meghatározására. Az értékadások sorrendje rugalmas abban az értelemben, hogy ha az N csúcs összes gyerekének értéke már adott, akkor már kiszámíthatjuk az N értékét is.

Az értékadó utasításokat a következőképpen jelölhetjük:

1. Először szerepel a reláció neve és a reláció attribútumainak zárójellezett listája. A **Válasz** nevet az utolsó lépés eredményének jelölésére használjuk, azaz a kifejezésfa gyökeréhez tartozó relációnak a nevéként.
2. Ezt követi a $:=$ értékadási szimbólum.
3. A jobb oldalon pedig egy algebrai kifejezés van. Minden értékadásnál használhatunk akár egyetlen műveletet is, ekkor tulajdonképpen a kifejezésfa minden csúcsának pontosan egy értékadás felel meg. Viszont kombinálhatjuk is a jobb oldalon a relációs algebrai műveleteket, ami szintén egy elfogadott módszer.

2.20. példa. Vegyük a 2.18. ábra kifejezésfáját. Az értékadások egy lehetséges sorozata a kiértékeléshez a következő lehetne:

$$\begin{aligned} R(c, \acute{e}, h, m, s, p) &:= \sigma_{\text{hossz} \geq 100}(\text{Filmek}) \\ S(c, \acute{e}, h, m, s, p) &:= \sigma_{\text{stúdióNév} = 'Fox'}(\text{Filmek}) \\ T(c, \acute{e}, h, m, s, p) &:= R \cap S \\ \text{Válasz}(cím, év) &:= \pi_{c, \acute{e}}(T) \end{aligned}$$

Az első lépésben a 2.18. ábra $\sigma_{\text{hossz} \geq 100}$ címkéjű belső csúcsát számítjuk ki. A második lépésben pedig $\sigma_{\text{stúdióNév} = 'Fox'}$ értékét számítjuk. Megjegyeznénk, hogy „ingyen” átnevezést kaphatunk, hiszen az értékadás bal oldalán tetszőleges relációnevet és attribútumnevet is használhatnánk. A fennmaradó két lépésben természetesen a metszetet és a vetítést végezzük el.

A lépések összevonása is megengedett. Például az utolsó két lépést is összevonhatnánk:

$$\begin{aligned} R(c, \acute{e}, h, m, s, p) &:= \sigma_{\text{hossz} \geq 100}(\text{Filmek}) \\ S(c, \acute{e}, h, m, s, p) &:= \sigma_{\text{stúdióNév} = 'Fox'}(\text{Filmek}) \\ \text{Válasz}(cím, év) &:= \pi_{c, \acute{e}}(R \cap S) \end{aligned}$$

Akár az R -t és az S -et is beírhatnánk az utolsó sorba, és így egy egysoros kifejezést kaphatnánk. \square

2.4.14. Feladatok

2.4.1. feladat. Ez a feladat a 2.3.1. feladatban szereplő termékek sémáján alapszik. Itt megismételjük azt az adatbázissémát, amely négy táblán alapult, melyeknek a sémája az alábbi volt:

```
Termék(gyártó, modell, típus)
PC(modell, sebesség, memória, merevlemez, ár)
Laptop(modell, sebesség, memória, merevlemez, képernyő, ár)
Nyomtató(modell, színes, típus, ár)
```

A Termék reláció néhány mintaadata a 2.20. ábrán látható. A másik három reláció mintaadatai a 2.21. ábrán láthatók. A gyártók, illetve a modellszámok fiktív adatok, de a többi adat az 2007. év elejének piacát tükrözi.