

## 5. fejezet

# Algebrai és logikai lekérdező nyelvek

A jelen fejezet során a relációs adatbázisok modellezése helyett a programozásra fektetjük a hangsúlyt. A tárgyalást két absztrakt programozási nyelv leírásával kezdjük: egy algebraival, illetve egy logikán alapulóval. Az algebrai programozási nyelvet (vagy relációs algebrát) már a 2.4. alfejezetben bemutatottuk, amely során láthattuk, milyen műveletek szerepelnek a relációs modellben. Most azonban többről van szó, mint az ott bemutatott algebráról, ezért a 2.4. alfejezetben tárgyalt **halmaz alapú algebrát kiterjesztjük multihalmazokra**. Ez a megfogalmazás már jobban fogja tükrözni a relációs modell gyakorlatban használt megvalósítási módjait. A kiterjesztés miatt a korábbiakon felül lesz még néhány újabb művelet is, mint például a reláció oszlopainak összegzése (például átlag).

A fejezetet egy másik, logikán alapuló lekérdező nyelvnek a formalizmusával zárjuk le. Ezt *Datalog*-nak fogjuk nevezni. Ebben a nyelvben már megfogalmazhatunk a kívánt eredménynek megfelelő lekérdezéseket is anélkül, hogy az eredményt kiszámító olyan algoritmust adnánk, amely a relációs algebrai megközelítésnél elhanyagolhatatlan volt.

### 5.1. Relációs műveletek multihalmazokon

Ebben az alfejezetben a relációkat inkább multihalmaznak tekintjük, mint halmaznak. Éppen ezért ugyanaz a sor többször is megjelenhet egy adott relációban. Néhány relációs műveletet azonban át kell fogalmaznunk, amennyiben a relációkra multihalmazokként tekintünk. Első lépésben tekintsük az alábbi egyszerű példát, amelyben a reláció egy valódi multihalmaz, azaz nem egy halmaz.

**5.1. példa.** Az 5.1. ábrán látható reláció tulajdonképpen sorokból álló multihalmaz, amelyben az  $(1, 2)$  sor háromszor és a  $(3, 4)$  sor egyszer szerepel. Ha az 5.1. ábra relációját halmaznak tekintenénk, akkor ki kellene küszöbölni az  $(1, 2)$  sor két megjelenését. A multihalmazként kezelt relációban megengedjük

ugyan, hogy ugyanazon sor többször szerepeljen, viszont a sorok sorrendje itt sem számít, éppúgy, mint a halmazként kezelt relációk esetén.  $\square$

A	B
1	2
3	4
1	2
1	2

5.1. ábra. Egy multihalmaz

### 5.1.1. Mire jók a multihalmazok?

A forgalomban lévő ABKR-ek a relációkat multihalmazként valósítják meg (nem pedig halmazként), mint ahogy azt már korábban is említettük. A relációk hatékony megvalósítása szempontjából a relációk multihalmazokként való kezelése több módon is gyorsíthatja a relációs műveleteket. Például

1. Ha két multihalmazként értelmezett reláció unióját vesszük, akkor az egyik reláció sorait egyszerűen lemásoljuk, és ehhez a másolathoz hozzáadjuk a másik reláció összes sorát. Ebben az esetben nem kell megszüntetnünk azon ismétlődő sorokat sem, amelyek mind a két relációban szerepelnek.
2. Ha a reláció vetítését halmazként fogjuk fel, akkor minden vetített sort össze kell hasonlítanunk az összes többi vetített sorral azért, hogy meggyőződjünk arról, hogy a vetítésben minden sor csak egyszer szerepel. Ezzel szemben, hogyha az eredményt multihalmaznak tekintjük, akkor minden sort levetítünk, és egyszerűen hozzáadjuk ezeket az eredményhez. Így egyetlen összehasonlítást sem kell végeznünk a vetítésből származó sorok között.

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

5.2. ábra. Az 5.2. példában szereplő multihalmaz

**5.2. példa.** Az 5.1. ábrán látható multihalmaz, akár az 5.2. ábrán látható reláció  $A$  és  $B$  attribútumokra történő vetítésének eredménye is lehetne, feltéve, ha megengednénk, hogy az  $(1, 2)$  sor többször is szerepeljen az eredményben, azaz az eredményt multihalmazként kezeljük. Ha a hagyományos relációs algebrai vetítési operátort használnánk, és ily módon kiküszöbölnénk az azonos sorokat az eredményből, akkor a következő relációt kapnánk:

$A$	$B$
1	2
3	4

Figyeljük meg, annak ellenére, hogy a multihalmazként kezelt eredmény nagyobb méretű, mégis gyorsabban ki lehet számolni, hiszen nem kell összehasonlítani az összes  $(1, 2)$ , illetve  $(3, 4)$  sort a megelőző lépésben megkapott sorokkal.  $\square$

Egy másik motiváció a relációk multihalmazként történő kezelésére: előfordulhat olyan helyzet, mikor a kívánt választ csak úgy kaphatjuk meg, ha legalább is átmenetileg multihalmazos megközelítést használunk. A következő példa ezt mutatja be.

**5.3. példa.** Ha például az 5.2. ábrán lévő halmazként kezelt reláció  $A$  oszlopára vonatkozó átlagot akarjuk venni, akkor nem használhatjuk a halmaz modell  $A$ -ra vonatkozó vetítését, mivel ez esetben az átlagra 2-t kapunk. Ugyanis az 5.2. ábrán az  $A$ -nak csak két különböző értéke van (a 3 és az 1), ezeknek az átlaga pedig 2. Ha viszont az  $A$  oszlopokra mint multihalmazra  $\{1, 3, 1, 1\}$  tekintünk, akkor a valódi átlagot kapjuk, amelynek értéke – az 5.2. ábra 4 sorának felhasználásával számolva – 1.5 lesz.  $\square$

### 5.1.2. Multihalmazok egyesítése, metszete, különbsége

Mind a három műveletnek új értelmezése lesz multihalmazok esetén. Tegyük fel, hogy  $R$  és  $S$  multihalmazok, és legyen  $t$  az  $R$   $n$ -szer, illetve az  $S$   $m$ -szer előforduló sora. Megengedve azt is, hogy akár  $n$ , akár  $m$ , akár mindkettő 0 legyen. Ekkor:

- Az  $R \cup S$  multihalmazon értelmezett egyesítésben a  $t$  sor  $n + m$ -szer fog előfordulni.
- Az  $R \cap S$ , tuple  $t$  multihalmazon értelmezett metszetben a  $t$  sor  $\min(n, m)$ -szer fog előfordulni.
- Az  $R - S$  multihalmazon értelmezett különbségben a  $t$  sor  $\max(0, n - m)$ -szer fog előfordulni. Azaz ha a  $t$  többször fordul elő  $R$ -ben, mint  $S$ -ben, akkor  $t$  az  $R - S$ -ben annyiszor fordul elő, mint ahányszor előfordult  $R$ -ben mínusz ahányszor előfordul  $S$ -ben. Amennyiben viszont  $S$ -ben legalább annyiszor előfordul a  $t$ , mint  $R$ -ben, akkor  $t$  nem lesz benne  $R - S$

különbségben. Informálisan tehát  $t$  minden egyes előfordulása  $S$ -ben „semlegesíti”  $t$  egy előfordulását  $R$ -ben.

**5.4. példa.** Legyen az  $R$  az 5.1. ábrán látható reláció, amely valójában egy multihalmaz, amelyben az  $(1, 2)$  sor kétszer és a  $(3, 4)$  sor egyszer szerepel. Legyen az  $S$  a következő multihalmaz:

$A$	$B$
1	2
3	4
3	4
5	6

Ebben az esetben az  $R \cup S$  egyesítés eredménye az a multihalmaz, amelyben az  $(1, 2)$  négyszer (háromszor az  $R$  miatt és egyszer az  $S$  miatt), a  $(3, 4)$  háromszor és az  $(5, 6)$  egyszer szerepel.

Az  $R \cap S$  metszet eredménye a következő multihalmaz:

$A$	$B$
1	2
3	4

Mind az  $(1, 2)$ , mind a  $(3, 4)$  sor csak egyszer szerepel az  $R \cap S$  eredményben. Az  $(1, 2)$  háromszor szerepel az  $R$ -ben és egyszer az  $S$ -ben és  $\min(3, 1) = 1$ . Hasonló módon a  $(3, 4)$  sorra  $\min(1, 2) = 1$ . Az  $(5, 6)$  sor egyszer szerepel az  $S$ -ben és nem szerepel az  $R$ -ben,  $\min(0, 1) = 0$ , tehát az  $R \cap S$  eredményben ez a sor nem szerepel.

Az  $R - S$  különbség eredménye a következő multihalmaz:

$A$	$B$
1	2
1	2

Az  $(1, 2)$  háromszor szerepel az  $R$ -ben és egyszer az  $S$ -ben,  $\max(0, 3 - 1) = 2$ , ezért az  $R - S$  különbségben ez a sor kétszer jelenik meg. A  $(3, 4)$  sor egyszer szerepel az  $R$ -ben és kétszer szerepel az  $S$ -ben,  $\max(0, 1 - 2) = 0$ , tehát ez a sor nem szerepel az  $R - S$  különbségben. Mivel az  $R$ -nek nincs más sora, ezért az  $R - S$  eredmény sem tartalmazhat más sort.

Az  $S - R$  különbség a következő multihalmaz:

$A$	$B$
3	4
5	6

A  $(3, 4)$  sor egyszer jelenik meg, hiszen ki kell vonni az  $S$ -beli előfordulások számából az  $R$ -beli előfordulások számát. Az  $(5, 6)$  sor ugyanilyen okból szerepel egyszer az eredményben. Ebben az esetben a multihalmazként kezelt eredmény történetesen halmaz.  $\square$

### Multihalmaz-műveletek halmazokon

Képzeld el, hogy van két halmazunk, az  $R$  és az  $S$ . Bármely halmaz tekinthető multihalmaznak, olyan multihalmaznak, amelynek történetesen mindegyik sora különböző. Tegyük fel, hogy az  $R \cap S$  metszetet akarjuk kiszámolni, de  $R$ -et és  $S$ -t multihalmaznak tekintjük és az ennek megfelelő szabályt alkalmazzuk. Ebben az esetben ugyanazt az eredményt kapjuk, mintha az  $R$ -et és  $S$ -t halmaznak tekintettük volna. Ha  $R$ -et és  $S$ -t multihalmaznak tekintjük, akkor egy  $t$  sor annyiszor szerepel majd az  $R \cap S$  eredményben, amennyi a két multihalmazban található előfordulások minimuma. Mivel az  $R$  és  $S$  halmazok, ezért a  $t$  előfordulási száma 0 vagy 1. Azaz mindegy, hogy halmaz- vagy multihalmazszabállyal számoljuk ki a metszetet, a  $t$  sor legfeljebb egyszer szerepelhet az  $R \cap S$  eredményben, és pontosan egyszer akkor fog megjelenni, ha mind az  $R$ -ben, mind az  $S$ -ben szerepel a  $t$  sor. Hasonló módon, ha az  $R - S$  vagy az  $S - R$  kiszámításához multihalmaz-különbséget használunk, akkor ugyanazt az eredményt kapjuk, mintha halmazkülönbséget használtunk volna.

Az egyesítés azonban **különböző eredményt ad attól függően, hogy az  $R$ -et és az  $S$ -t halmaznak vagy multihalmaznak tekintjük**. Ha multihalmazszabályt alkalmazunk az  $R \cup S$  kiszámításához, akkor előfordulhat, hogy az eredmény nem halmaz lesz annak ellenére, hogy mind az  $R$ , mind az  $S$  halmaz. Azaz, ha a  $t$  sor az  $R$ -ben és az  $S$ -ben is szerepel, akkor multihalmazszabályt alkalmazva a  $t$  sor kétszer jelenik meg az  $R \cup S$  eredményben, ha viszont halmazszabályt alkalmazunk, akkor a  $t$  sor csak egyszerre jelenik meg az  $R \cup S$  eredményben.

#### 5.1.3. Multihalmazok vetítése

A multihalmazok vetítéséről már volt szó. Amint az 5.2. példában láthattuk, a vetítés során mindegyik sort külön kezeljük. Ha az  $R$  reláció az 5.2. ábrán látható multihalmaz, akkor a  $\pi_{A,B}(R)$  eredménye az 5.1. ábrán látható multihalmaz.

Ha vetítés során különböző sorokból egy vagy több attribútum elhagyásával egyforma sorokat kapunk, akkor ezeket **az egyforma sorokat nem kell kiküszöbölni a multihalmaz vetítésének eredményéből**. Ha az 5.2. ábra  $R$  relációjának  $(1, 2, 5)$ ,  $(1, 2, 7)$  és  $(1, 2, 8)$  sorait levetítjük az  $A$  és  $B$  attribútumokra, akkor mindhárom sor ugyanazt az  $(1, 2)$  sort eredményezi. Ez azt jelenti, hogy a multihalmaz-eredményben az  $(1, 2)$  sor háromszor szerepel, míg a hagyományos vetítéssel csak egyszer szerepelne.

### Algebrai azonosságok multihalmazok esetén

Az algebrai azonosság két relációs algebrai kifejezés közötti ekvivalencia. A kifejezések argumentumai relációk. Az ekvivalencia szerint mindig, hogy milyen relációkat helyettesítünk be, a két kifejezés ugyanazt az eredményt adja. Egy jól ismert példa az egyesítésre vonatkozó azonosság:  $R \cup S = S \cup R$ . Ez az azonosság fennáll, ha az  $R$  és  $S$  relációkat halmazként kezeljük, de akkor is fennáll, ha a relációkat multihalmazként kezeljük. **Létezik** azonban **számos olyan azonosság**, amely fennáll abban az esetben, ha a relációs algebrai műveleteket a hagyományos halmazelméleti módon értelmezzük, viszont **nem érvényesek, ha a relációkat multihalmazként kezeljük**. Ilyen azonosság például a különbség és az egyesítés disztributív volta:  $(R \cup S) - T = (R - T) \cup (S - T)$ . Ez az azonosság érvényes halmazokra, viszont nem érvényes multihalmazokra. Hogy lássuk, miért is nem igaz multihalmazok esetén, tegyük fel, hogy a  $t$  sor egyszer szerepel mindhárom relációban, az  $R$ -ben, az  $S$ -ben és a  $T$ -ben. Ebben az esetben a bal oldali kifejezés eredményében egyszer szerepel a  $t$  sor, a jobb oldali kifejezés eredményében viszont nem szerepel a  $t$  sor. Ha halmazszabályt alkalmazunk, akkor egyik oldal eredményében sem szerepel a  $t$  sor. Az 5.1.4. és 5.1.5. feladatokban megvizsgáljuk további algebrai azonosságok érvényességét multihalmazok esetén.

#### 5.1.4. Multihalmazokon értelmezett kiválasztás

A multihalmazon végzett kiválasztás azt jelenti, hogy a kiválasztás feltételét minden egyes sorra alkalmazzuk. A multihalmazoknál megszokott módon **itt sem küszöböljük ki az azonos sorokat**.

**5.5. példa.** Legyen  $R$  a következő multihalmaz:

$A$	$B$	$C$
1	2	5
3	4	6
1	2	7
1	2	7

a  $\sigma_{C \geq 6}(R)$  multihalmazos kiválasztás eredménye:

$A$	$B$	$C$
3	4	6
1	2	7
1	2	7

Azaz, az első sor kivételével mindegyik sor teljesíti a feltételt. A két utolsó sor az  $R$ -ben is megegyezik, így mindkettő szerepel az eredményben is.  $\square$

### 5.1.5. Multihalmazok szorzata

A multihalmazok Descartes-szorzatára vonatkozó szabály pontosan az, amit vártunk: az első reláció minden egyes sorát össze kell párosítanunk a második reláció mindegyik sorával függetlenül attól, hogy az adott sor hányszor szerepel az adott relációban. Következésképpen, ha az  $r$  sor  $m$ -szer szerepel az  $R$  relációban és az  $s$  sor  $n$ -szer szerepel az  $S$  relációban, akkor az  $rs$  sor  $mn$ -szer szerepel az  $R \times S$  szorzat eredményében.

**5.6. példa.** Legyen az  $R$  és  $S$  reláció az 5.3. ábrán látható két reláció. Ekkor az  $R \times S$  szorzat hat sorból áll, amint az az 5.3. (c) ábrán is látható. Megjegyezzük, hogy a hagyományos szorzatnál bevezetett, attribútumnevekre vonatkozó jelölés multihalmazokra is kitűnően alkalmazható. Ekképpen az  $R$  és  $S$  relációkban egyaránt megtalálható  $B$  attribútum kétszer jelenik meg a szorzatban, és előtagként a megfelelő reláció neve szolgál.  $\square$

$A$	$B$
1	2
1	2

(a) Az  $R$  reláció

$B$	$C$
2	3
4	5
4	5

(b) Az  $S$  reláció

$A$	$R.B$	$S.B$	$C$
1	2	2	3
1	2	2	3
1	2	4	5
1	2	4	5
1	2	4	5
1	2	4	5

(c) Az  $R \times S$  szorzat

**5.3. ábra.** Multihalmazok szorzatának kiszámítása

### 5.1.6. Multihalmazok összekapcsolása

A multihalmazok összekapcsolása szintén **nem szolgál különösebb meglepetéssel**. Az első reláció minden egyes sorát összehasonlítjuk a második reláció valamennyi sorával, és eldöntjük, hogy az így kapott sorpárok sikeresen összekapcsolhatók-e vagy sem. Ha az összekapcsolás elvégezhető, akkor az eredményből nem kell kiküszöbölni a megegyező sorokat.

**5.7. példa.** Az 5.3. ábrán látható  $R$  és  $S$  reláció természetes összekapcsolásának eredménye,  $R \bowtie S$ :

$A$	$B$	$C$
1	2	3
1	2	3

Az  $R$  reláció  $(1, 2)$  sora összekapcsolható az  $S$   $(2, 3)$  sorával. Mivel az  $R$  relációban az  $(1, 2)$  sor kétszer szerepel és az  $S$  relációban a  $(2, 3)$  sor egyszer szerepel, ezért az eredményben az  $(1, 2, 3)$  kétszer jelenik meg. Az  $R$  és  $S$  egyéb sorai nem kapcsolhatók össze.

Ugyanezeket a relációkon végezzünk most egy théta-összekapcsolást:

$$R \bowtie_{R.B < S.B} S$$

Az eredményül kapott multihalmaz:

$A$	$R.B$	$S.B$	$C$
1	2	4	5
1	2	4	5
1	2	4	5
1	2	4	5

Az összekapcsolást a következő módon végezzük: az  $R$   $(1, 2)$  sora és az  $S$   $(4, 5)$  sora megfelel a feltételnek. Mivel mindkét sor kétszer szerepel a megfelelő relációkban, ezért az összekapcsolt sor  $2 \times 2 = 4$  alkalommal jelenik meg az eredményben. Ezenkívül még összekapcsolhatnánk az  $R$   $(1, 2)$  sorát az  $S$   $(2, 3)$  sorával, de ez a sorpár nem teljesíti a feltételt, így módon az eredményben sem jelenik meg.  $\square$

### 5.1.7. Feladatok

**5.1.1. feladat.** Tekintsük a 2.21. (a) ábrán szereplő PC relációt. Számítsuk ki a  $\pi_{\text{sebesség}}(\text{PC})$  kifejezést. Mi lesz az értéke, ha a relációkat halmazokként kezeljük? És ha multihalmazokként? Mennyi lesz az értékek átlaga ebben a projekcióban, ha a relációkat halmazokként kezeljük? Mennyi, ha multihalmazokként?

**5.1.2. feladat.** Végezzük el az 5.1.1. feladatot a  $\pi_{\text{mervelemez}}(\text{PC})$  kifejezéssel.