31. EGYSZERŰ MINTAILLESZTÉS

A *mintaillesztés* feladata az, hogy egy *szövegben* egy *szövegminta* (szövegrészlet, string) *előfordulását* vagy előfordulásait megkeressük. A mintaillesztés elnevezés mellett találkozunk a *stringkeresés* elnevezéssel is.

A feladat *általánosítható*: valamely alaptípus feletti sorozatban keressük egy másik (általában jóval rövidebb) sorozat előfordulásait (például egy DNS láncban keresünk egy szakaszt).

31.1. A mintaillesztés feladata

A továbbiakban egyszerűsítjük a feladatot a minta *első* előfordulásának a megkeresésére, amelynek segítségével az összes előfordulás megkapható. (Keressük meg a minta első előfordulását, majd a hátralévő szövegben ismét keressük az első előfordulást stb.)

Vezessük be a fejezet egészére az alábbi jelöléseket:

- Legyen H egy tetszőleges alaptípus feletti véges halmaz, a szöveg *ábécéje*.
- Legyen a *szöveg*, amelyben a mintát keressük: $S[1..n] \in H^*$, azaz egy n hosszú H feletti véges sorozat.
- Legyen a *minta*, amelyet keresünk a szövegben: $M[1..m] \in H^*$, egy m hosszú szintén a H feletti véges sorozat.

Továbbá, tegyük fel, hogy S-en és M-en megengedett művelet az indexelés, azaz hivatkozhatunk a szöveg vagy a minta egy i-edik elemére $S[i]$ ($i \in [1..n]$), $M[i]$ ($i \in [1..m]$).

A tárgyalt algoritmusok némelyike lényeges módosítás nélkül átírható *szekvenciális fájlokra* is (ahol az indexelés nem megengedett), míg a más tárgyalt algoritmusok csak *puffer* használatával alkalmazhatók a csak szekvenciálisan olvasható hosszabb szövegekre.

31.1.1. Az illeszkedés fogalma

Bevezetjük a *minta előfordulásának* fogalmát, több szóhasználatot is megemlítve. Legyen $k \in N, k \in [0..n-m]$. Azt mondjuk, hogy

- az M minta a k+1-dik pozíción *illeszkedik* az S szövegre (előfordul a szövegben), vagy
- az M minta k *eltolással* illeszkedik S-re, illetve
- k *érvényes eltolás*,

ha $S[k+1..k+m] = M[1..m]$, azaz $\forall j \in N, j \in [1..m] : S[k+j] = M[j]$.

Továbbá, az M mintának a (k+1)-edik pozíción való illeszkedése az M *első* előfordulása az S szövegben, ha $\forall i \in N, i \in [0..k-1] : S[i+1..i+m] \neq M[1..m]$.

Legyen például a szövegünk S = "ABBABCAB", és a keresett minta pedig M = "ABC". A fenti definíció szerint az M minta a 4-edik pozíción, $k = 3$ eltolással illeszkedik az S szövegre, ahogyan ez a 31.1. ábrán is látható.

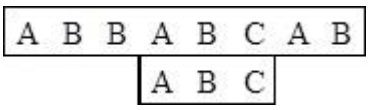

31.1. ábra. Az M minta illeszkedése

31.1.2. A mintaillesztési feladat egyszerű megoldási elve

Tekintsük *megengedett műveletnek* az azonos méretű sorozatok egyenlőségének a vizsgálatát, azaz esetünkben az $S[k+1..k+m]=M[1..m]$ vizsgálatot.

Ekkor az a feladat, hogy keressük meg az első olyan k pozíciót ($k \in N, k \in [0..n-m]$), amelyre igazat ad a fenti vizsgálat. Ezt megtehetjük egy lineáris kereséssel.

A fejezett további részeiben is használt paraméterek jelentése legyen: $u = igaz \Leftrightarrow \exists k \in N, k \in [0..n-m]$: M a $(k+1)$-edik pozíción illeszkedik S-re, továbbá $u = igaz$ esetén k visszatérési értéke az első érvényes eltolás. A lineáris keresésre épülő elvi megoldást, összhangban a most bevezetett paraméterekkel, a 31.2. ábrán láthatjuk.

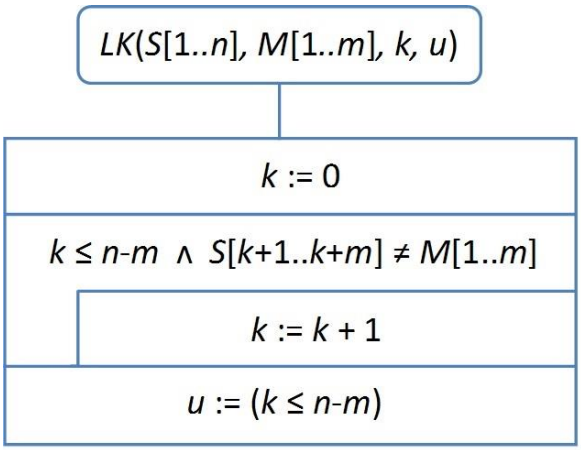

31.2. ábra. Mintaillesztés lineáris kereséssel

31.2. Az egyszerű mintaillesztés algoritmusa

A stringkeresési feladat naiv megoldást *egyszerű mintaillesztésnek* fogjuk nevezni. Ehhez a „nyers erő” (brute force) algoritmushoz könnyen eljuthatunk a már tanult „programozási tételekre” való visszavezetéssel.

Folytassuk az előző részben elkezdett, lineáris keresésre épülő gondolatot. A vázolt megoldásban megengedett műveletnek tekintettük az $S[k+1..k+m] = M[1..m]$ vizsgálatot. Ennek a kifejezésnek az eredményét megkaphatjuk *karakterenkénti* összehasonlítással is, amelynek során a minta minden karakterét összehasonlítjuk a szövegdarab megfelelő karakterével; és ha az összes vizsgált karakter egyezik, akkor a kifejezés értéke legyen igaz, különben hamis.

Az $S[k+1..k+m] = M[1..m]$ vizsgálat előbb említett megvalósítása javítható, ha visszavezetjük *lineáris keresésre*, amelynek során keressük az első olyan $j \in N, j \in [1..m]$ pozíciót, amelyre $S[k+j] \neq M[j]$.

Amennyiben nem találunk ilyen j pozíciót, azaz $\forall j \in N, j \in [1..m]: S[k+j] = M[j]$, akkor az M illeszkedik S-re k eltolással, tehát $S[k+1..k+m] = M[1..m]$ vizsgálat eredménye legyen igaz, különben pedig hamis. Ezt a megoldást nevezzük az *egyszerű mintaillesztés* algoritmusának, amely nem más, mint egy lineáris keresésbe ágyazott lineáris keresés.

Az algoritmust szemléletesen úgy lehet elképzelni, mintha a mintát tartalmazó "sablont" tolnánk végig a szövegen, és balról jobbra ellenőrizzük, hogy a minta karakterei egyeznek-e a "lefedett" szöveg karaktereivel. Amennyiben nem egyező karakterpárt találunk, a mintát egy pozícióval jobbra "toljuk" a szövegen, és újra elkezdjük a minta elejéről az összehasonlítást. Az így kapott eljárás algoritmusát a 31.3. ábra tartalmazza.

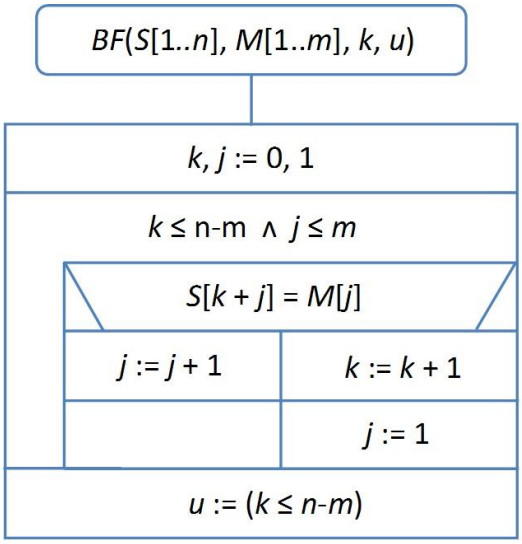

31.3. ábra. Az egyszerű mintaillesztés algoritmusa

Nézzük meg egy példán az algoritmus *működését*. A 31.4. ábra első sorában szerepel a szöveg, alatta a minta a megfelelő eltolásokkal. A mintán ritka pontozású háttérrel jelöltük, azokat a karaktereket, amelyeknél az összehasonlítás igaz értéket adott, és sűrű mintázatú háttérrel, ahol az illeszkedés elromlott.

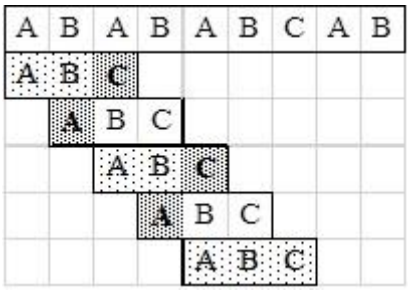

31.4. ábra. Az egyszerű mintaillesztés működése

Először mintát a szöveg első pozíciójára illesztjük, majd a mintán balról jobbra haladva vizsgáljuk a karakterek egyezését a szöveg megfelelő karaktereivel. A minta első illetve második karaktere ('A' és 'B') megegyezik a szöveg első és második karakterével, azonban a minta harmadik karaktere ('C') nem azonos a szöveg harmadik karakterével, tehát a minta nem illeszkedik az első pozícióra. "Toljuk el" a mintát egyel, majd a minta elejétől kezdve balról jobbra haladva ismét vizsgáljuk a karakterek egyezését a lefedett szövegrész megfelelő karaktereivel. Már a minta első karakterénél ('A') elromlik az illeszkedés. Ismét "toljuk el" eggyel jobbra a mintát, és a már ismertetett módon vizsgáljuk az illeszkedést.

Tizenegy összehasonlítás után eljutunk a végeredményhez, amely szerint a minta az 5. pozíción illeszkedik először a szövegre.

31.2.1. Műveletigény

Műveletigény szempontjából a legjobb eset, amikor a minta az első pozíción illeszkedik a szövegre, ekkor az összehasonlítások száma minden mintaillesztő algoritmusnál *m* lesz. Ezt az esetet joggal tekinthetjük érdektelennek, mivel nem ad az algoritmus sebességére vonatkozóan valósághű jellemzést. Továbbiakban a mintaillesztési algoritmusok vizsgálata során mindig feltesszük, hogy a minta *nem fordul elő* a szövegben, így az algoritmusnak fel kell dolgoznia a "teljes" szöveget.

A különböző algoritmusok hatékonysága abban fog különbözni, hogy ebben az esetben mennyire "gyorsan" tudnak "végig menni" a szövegen. Tegyük fel még azt is, hogy a minta hossza nagyságrendben kisebb vagy egyenlő, mint a szöveg hossza, azaz $m = O(n)$ (a gyakorlatban a minta hossza jóval kisebb, mint a szöveg hossza).

Ezek előre megadjuk az egyszerű mintaillesztés *műveletigényét*. A *legjobb esetben* a minta első karaktere egyáltalán nem szerepel a szövegben, így minden *k* eltolásnál már *j*=1 esetben mindig elromlik az illeszkedés. Tehát minden eltolásnál csak egy összehasonlítás történik, így az összehasonlítások száma megegyezik az eltolások számával, (*n*-*m*+1)-gyel. Tehát $mÖ(n,m) = n - m + 1 = \Theta(n)$.

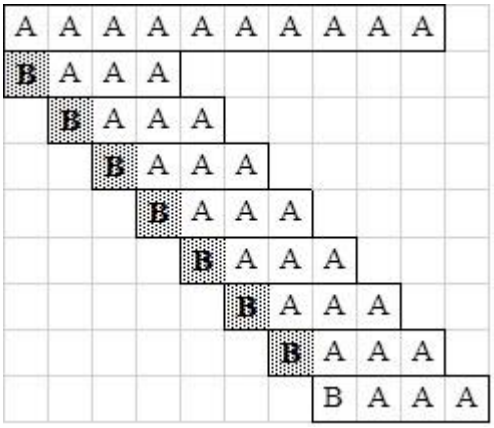

31.5. ábra. Példa az egyszerű mintaillesztés legjobb esetére

A *legkedvezőtlenebb esethez* akkor jutunk, ha minden eltolásánál csak a minta utolsó karakterénél romlik el az illeszkedés. Ekkor minden eltolásnál *m* összehasonlítást végzünk, így a műveletigény az eltolások számának *m*-szeresével jellemezhető. Tehát $MÖ(n,m) = (n - m + 1) * m = \Theta(n * m)$.

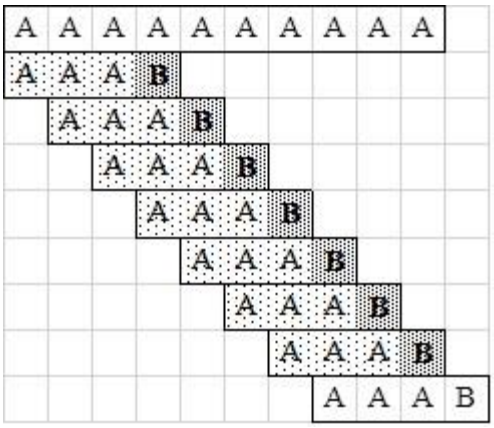

31.6. ábra. Példa az egyszerű mintaillesztés legrosszabb esetére

31.2.2. Szekvenciális sorozatokra, fájlokra való alkalmazhatóság

A gyakorlatban az általunk szövegnek nevezett sorozat nem egyszer igen *nagyméretű* is lehet, emiatt csak olyan *szekvenciális* formában áll rendelkezésünkre, amelyen az *indexelés nem megengedett* művelet. Hasznos lehet annak vizsgálata, hogy az ismertetett algoritmust mennyire egyszerű átírni szekvenciális sorozatokra, illetve fájlokra. Az egyszerű mintaillesztő algoritmus szekvenciális sorozatokra történő átírásánál kénytelenek vagyunk *puffert* használni, mivel a szövegben időnként vissza kell "ugrani" (akkor, ha az illeszkedés nem a minta első karakterénél romlik el).