

Lek. Václav ČERNÝ
VŠB Ostrava - Budavanice

MOŽNOSTI Využití TECHNIK INGENIEROVÝCH ZABULEK z řešení ve vědeckotechnických výpočtech

1. Úvod

Počítače 3. generace používají již jako samozřejmost vnější paměti s přímým přístupem jako jsou např. mg. disky, které nezpravidla obohacují možnosti programátora.

Ve vědeckotechnických výpočtech (dále VTV) je prakticky nejpoužívanějším jazykem FORTRAN. Ve verzích, které jsou implementovány na počítačích 3. generace (např. FORTRAN IV G a H na počítačích řady IBM 360 a 370, případně FORTRAN pro řadu JSEP) už jsou zahrnutý i výroky pro práci s magnetickými disky. Příslušné výroky umožňují přímý přístup k jednotlivým záznamům souboru. Programátor deklaruje počet záznamů (oblastí) v souboru, jejich maximální velikost, případně zde jde o záznam s konverzí nebo přímo ve vnitřním zobrazení a jiného tzv. odružené proměnné. Jednotlivé oblasti (v maximální velikosti) jsou systémem jakoby očíslovány a touto adresou je možno se na ně přímo odvolávat a to jak při zápisu, tak při čtení. Adresa může být zadána prostřednictvím libovolné proměnné nebo hodnoty aritmetického výrazu. Sdružená proměnná udává po provedené operaci adresu záznamu následujícího po právě spracovaném. Metoda odpovídá prakticky metodě REGIONAL 1 v PL/I.

Použití souboru s přímou organizací je výhodné u VTV např. v těchto případech:

- uchovávání velkých tabulek na vnějších pamětech,
- uchovávání velkých matic u nichž se požaduje možnost náhodného výběru prvků,
- tabulky skupin parametrů,
- parametry zpracování pro programové systémy pro různé druhy opakujícího se zpracování,
- soubory, jejichž věty mají proměnlivou strukturu i délku,
- jedno z nejvýhodnějších použití je soubor, jejichž věty jsou často měněny,
- při opravách vstupních dat,
- atd.

Při adresování záznamů jsou v podstatě tyto možnosti:

- přímé adresování, kdy adresa je dána přímo pořadacím kritériem souboru,
- nepřímé, kdy se k adrese dospívá oklikou, buď přepočtem nebo různými randomizačními technikami, případně pomocí tabulek nebo pomocí jiných záznamů.

U nepřímého adresování může dojít k tomu, že pro tužší hodnotu pořadacího kritéria se vyskytuje záznam více. To jsou tzv. synonyma, v takovém případě je nutno zajistit uložení do tzv. oblasti přeplnění a zajistit propojení synonym. Při přímém adresování je přístup rychlejší, ale prostor vyhrazený na disku pro soubor bývá využit značně neekonomicky. Na proti tomu nepřímé adresování šetří prostor, ale ze zřejmých důvodů prodlužuje dobu přístupu k záznamu. V praxi se většinou setkáváme s nejrůznějšími technikami nepřímého adresování.

2. Technika řetězení a technika indexových tabulek.

Obě patří k technikám nepřímého adresování, většinou si jich podrobněji s to sejmeme s ohledem na praktické použití.

Řetězením lze spojit záznamy, které k sobě logicky pří-

sluší, i když jsou fyzicky uloženy na různých místech souboru. Spojení je provedeno pomocí tzv. směrniků, které jsou připojeny ke každému záznamu. Udávají všudy adresu následujícího nebo předchozího záznamu - článku řetězu. Definovaný obsah směrniku (např. 0) udává, že jde o konec řetězu. Celý řetěz je pak tvořen záznamy s touto vlastností. Řetěz může být v souboru několik, pak musí každý záznam obsahovat příslušný počet směrniků. Adresa prvního článku řetězu musí být někde uchována. Př. řetěz mohou tvořit záznamy parametrů všech vzorků křemene v souboru vzorků všech typů hornin. Příklady použití této techniky:

- u zmíněného účelu přeplňání u nepřímého adresování,
- není-li předem znám počet parametrů příslušející např. určitému vzorku, lze dodatečně pomocí řetězení připojit prakticky libovolný počet dalších parametrů.
- seřidění záznamů podle určitého kritéria bez změny jejich uložení
- atd.

Řetěz je více typů, podrobný rozbor však přesahuje rámcem tohoto příspěvku (jinak viz /2-4/).

Indexové tabulky umožňují zajistit přístup k záznamům dodatečně, aniž by bylo nutno brát přítom ohled na způsob a techniku ukládání, případně na jeho časovou náveznost. Ta-to technika nevyžaduje další vyhrazení místa v záznamu. Každá indexová tabulka přísluší pořadací kritérium, jehož hodnoty nebo intervaly hodnot jsou argumentem tabulky. Tabulkovými hodnotami jsou pak adresy záznamů, které se vyznačují příslušnou hodnotou pořadacího kritéria. Pro hledání v tabulce existují různé, často velmi složité techniky. Někdy se tabulky nevejdou do paměti, která je k dispozici, takže se setkáváme s vícstupňovými indexy, řetězením možnosti adres záznamů příslušejících danému argumentu tabulky atd. Podobně jako u řetězení lze vytvořit více indexových tabulek pro různé pořadací kritéria - mnohonásobné indexování. Problémem se pak ale stává údržba souboru, poněvadž kromě změny záznamů je třeba aktualizovat i indexové tabulky.

Oba techniky lze kombinovat, takže např. v indexové tabulce jsou uloženy polohy jednotek souboru nebo přímo indexová tabulka je z nejrůznějších důvodů řetězena apod. Jejich pomocí lze zajišťit i propojení mezi soubory.

Tyto techniky česce souvisejí s principy uložení a struktury dat v počítačích dat. V této literatuře jsou také podrobně popsány /1-5/.

3. Příklad použití diskutovaných technik.

3.1. Formulace zadání.

Při seismických měřeních a pak vyhodnocených nejrůznějším typu jsou používána měřičská pásmá lišící se např. délkom, vlastnostmi tepelnými, deformačními atd., celkem asi 10 typů parametrů. K tomu ještě přistupují tabulky komparací pro každé pásmo (desítky až stovky hodnot). Pásma jsou čas od času vyřazována, nahrazována novými nebo po poškození může dojít ke zkrácení a tedy změně parametrů. Údaje o pásmech mají sloužit jako jeden ze vstupů pro různé programy, které zpracovávají měření. Vzhledem k počtu údajů a frekvenci zpracování nepřipadá v úvahu zadávání z děrých štítků. Požaduje se, aby byly parametry pásm zpřístupněny vyhodnocujícímu programu uvedením identifikačního kódu pásm. Počet pásem je cca 30.

3.2. Analýza úlohy, návrh řešení.

Nejvhodnější se této situaci jeví přímo organizace souboru pásem vzhledem k častým změnám v souboru a k rychlosti výběru hledaného pásmu ze souboru.

Soubor bude obsahovat indexovou tabulku pásem, kde každém existujícím identifikačnímu kódu pásmu bude přišlušet adresa počátku parametrů pásmu. V označování pásem není žádána zákonitost, nemá smysl je tedy řídit. Parametry i jiné logické celky v souboru mohou být děleny do segmentů, které jsou navzájem propojeny řetězením. Vhodným stanovením veli-

kosti segmentu, tj. vlastně i maximální velikostí souboru, lze optimálně řešit kompromis mezi úlohou místa na disku a rychlostí výběru. Parametry mohou být identifikovány buď pořadím ve zřetězení segmentů nebo jsou indikovány typem segmentů a pak pořadím v nich, případně může být u každého údaje uveden typ a v případě potřeby i počet údajů náležejících témuž typu. Poslední způsob umožňuje přidávat kdykoli další parametry zcela libovolně - je zcela obecný. Vyžaduje však více paměti. Stejně lze zajistit i "rostačitelnost" indexové tabulky. Předpokládejme-li u ní segmentovou strukturu, lze uchovávat prakticky libovolný počet pásem. Právomocnost dohodnutých zvláštních znaků indikuje konec řetězu nebo přímočrou část záznamu. Při zněních nebo vypouštění pásem může dojít ke zrušení některých záznamů, a tedy k jejich uvolnění pro další zápis. Registrace těchto volných záznamů může být prováděna různě např. těmito způsoby:

- ve zvláštním řetězu uchováme volné adresy souboru vzniklé zrušením, přičemž pro rychlejší orientaci můžeme někde poznamenáno, kolik těchto adres je,
- vyčkáme, až je celý soubor "popán" (včetně zrušených záznamů) a pak provedeme reorganizaci.

Ukazuje se nutnost vytvoření dalšího významného souboru (dále úvodní), kde by byla uložena adresa posledního obsaženého záznamu souboru (myšleno nejvyšší číslo, kterého dosud adresa nabyla). Další záznam se pak provede na adresu vyšší o 1 nebo se obnoví poslední adresa řetězu volných adres. Zmíněný úvodní záznam by tedy mohl obsahovat i adresu posledního segmentu řetězu volných adres. Směrníky řetězu volných adres tento propojí od posledního segmentu k prvnímu (výběr z téhoto řetězu se děje podle pravidla LIFO). Jde o tzv. spětaj řetěz. Podobně je organizován i řetěz segmentů indexové tabulky, úvodní záznam může tedy obsahovat adresu posledního segmentu indexové tabulky. Při vypouštění pásem z indexové tabulky je pak možno postupovat např. těmito způsoby:

- vyzále se příslušná položka v indexové tabulce
- pak je možné buď z poledního segmentu indexové tabulky přepsat poslední položku na upravené místo
- nebo je možno kontrolovat při prohledávání segmentů idaj, který by udával, zda jsou v segmentu ještě nějaké nezrušené položky (to by bylo pro tento idaj další místa v segmentu navíc).

Výhodněji se jeví první způsob, nemže tak dojít k velkým "díram" v tabulce a hledání bude tedy dospornější a rychlejší. Řetěz segmentů indexové tabulky musí být ovšem zpětný.

Nad tímto souborem musí pracovat program nebo programy, které zajistí funkce uložení, zrušení a opravy pásm a reorganizaci souboru, kterou je vhodné čas od času provést. Indexová tabulka by měla být bez "dér" a stejně tak by měly na sebe navezovat segmenty parametrů jednotlivých pásem.

Vyhledávání je v takovém souboru jednoduché. V úvodním zápisu zjistíme adresu koncového segmentu indexové tabulky a začneme tabulkou prohledávat. Vzhledem k počtu pásem nemá smysl používat speciálních hledacích technik. Po nalezení daného identifikačního kódu pásma může začít na příslušné adrese čtení parametrů pásmu.

Výhodou tohoto uspořádání je, že veškeré údaje potřebné pro operace nad souborem jsou v souboru samém přímo obsaženy.

Na následujícím obrázku jsou uvedeny první zápismy souboru v situacích a) po uložení prvního pásmu,
b) po uložení druhého pásmu,
c) po uložení třetího pásmu.

Je přitom použito těchto označení a dán tento rozsah úloh: Délka segmentu je 5 slov, počet stálých parametrů pásm 3 (jsou označeny PAR1, PAR2, PAR3) - mohou být tedy identifikovány pořadím v prvním segmentu parametrů; PASM01, PASM02 a PASM03 jsou identifikační kódy pásem - počet pásem je 3. Nepoužívá se řetězu volných adres. KOM1, KOM2, KOM3 atd označuje komparece pro jednotlivá pásmá. Počet komparecí je

dán ve 4.slově prvního segmentu parametrů. V každém segmentu je 5.slově adresa na odpovídající následující segment.
V úvodním segmentu je v prvním slově poslední obsahová adresa souboru, ve druhém slově adresa posledního segmentu indexové tabulky. Prázdný znak je *.

ad a) první pásmo má 4 komparace

adresa segment
segmentu

úvodní segment	1	4	2	4	*	*
	2	PASMO1	3	*	*	*
	3	PASMO1	PASMO2	PASMO3	4	4
	4	KOM1	KOM2	KOM3	KOM4	*

ad b) druhé pásmo má 2 komparace

1	6	2	*	*	*	*
2	PASMO1	3	PASMO2	3	4	
3	via bod a					
4	via bod a				4	
5	PASMO1	PASMO2	PASMO3	2	6	
6	KOM1	KOM2	*	*	*	*

ad c) třetí pásmo má 5 komparací

1	10	7	*	*	*	*
---	----	---	---	---	---	---

2	PASMO1	3	PASMO2	5	*
3	vis	boda)			
4	vis	bod a)			*
5	vis	bod b)			
6	vis	bod b)	*	*	*
7	PASMO3	8	*	*	2
8	PAR1	PAR2	PAR3	5	9
9	KOM1	KOM2	KOM3	KOM4	10
10	KOM5	*	*	*	*

Segment 1 je úvodní segment, indexová tabulka písma je v segmentech 2 a 7, parametry 1.pásmu v segmentech 3 a 4, parametry 2.pásmu v segmentech 5 a 6, parametry 3. pásmu v segmentech 8, 9 a 10.

Tento příklad se řeší pomocí jednoduchého zadání do detailu, cílem bylo spíše ukázat možnosti, které se v takovém případě naskytají. S výhodou tu bylo použít jak indexové tabulky, tak řetězové záznamy.

4. Metoda třídění jako příklad použití elektronických technik

4.1. Úvodní úvahy.

Výsouzení dílby je takové:

- jako programovací jazyk PASCAL
- jde o řetězové třídění

- klíče jsou paměti krátké (do 20 znaků)
- tříděné soubory mají maximálně 5000 vět

Jak sevímo, FORTRAN není vybaven výroky pro detailní operace se znaky, znakovými řetězci apod. Nejde rovněž pracovat přímo s byty. Metoda musela tyto okutečnosti respektovat a bylo proto nutné najít cesty, jak tato emocevní objevit.

Hrubé schéma vypadá asi takto:

1. Na magnetickou diskovou paměť se zasunutá tříděný soubor a to v přímé organizaci.

2. Z vět souboru jsou čteny klíče vět do hlavní paměti počítače. Je přitom vytvářen řetěz klíčů v pořadí, jak jsou čteny, tzn. v paměti musí být také směrníky příslušející každému klíči.

3. Je provedeno třídění klíčů do požadované posloupnosti, přičemž se nepřepisují a nezměňují klíče, ale směrníky. Ty pak po ukončení třídění vytvářejí s klíči řetěz, který odpovídá požadovanému předpisu o pořadí klíčů.

4. Ze souboru se disku (viz bod 1) jsou čteny věty souboru podle směrníků utříděného řetězu klíčů a zapisovány na jiné médium buď v sekvenční nebo přímé organizaci. V posledním případě je možné tato varianta: původní soubor obsahuje směrníky už ve svých větách, takže po třídění mohou být převedeny směrníky utříděného řetězu klíčů. Soubor na disku lze pak procházen v pořadí utřídění.

Třídění je prováděno v paměti, celý soubor najednou. Vzhledem k požadavkům zadání je to nejlépe i při maximálním rozsahu. V případě větších dílů je nutné provést další zabezpečení, které všeck na vlastní metodu třídění nemají podstatný vliv. Tyto možnosti budou diskutovány dále.

4.2. Vlastní metoda třídění.

Tato metoda se týká vlastního bodu 3 uvedeného postupu.

Předpokládám, že klíč vět je tvořen jen jedním znakem, až je jen jedna pozice. Pak po projití všech klíčů je

mohlo vytvořit dílčí řetězy, které spojí klíče se stejným znakem. Vytvoříme si tabulku, ve které bude zaznamenáno pro každý možný znak počátek a konec dílčího řetězu (pomocí adresy klíče - tj. jejího pořadí od počátku souboru), případně kolik článků každý dílčí řetěz obsahuje. Tabulku rozšiřujeme dále tabulkou dílčích řetězů (TDR). Pořadí znaků v tabulce je údajně pořadím podle pořadovků na třídění (vzestupně, sestupně, obecně určené pořadí). Propojením dílčích řetězů v pořadí, jak za sebou následují v tabulce lze získat řetěz přes celý soubor, který pak bude odpovídat pořadovánemu pořadí.

Vzhledem k principu metody je možné pracovat s libovolnou množinou znaků (které jsou ovšem pro daný počítač definovány) a volit i libovolné pořadí pro třídění. Prostředkem, který to umožní prakticky, bude konverzní tabulka, která provede jednoznačné přiřazení mezi znaky zvolené množiny a jejich pořadím v TDR. Konverzní tabulku lze vytvořit pro každé zadání přesně podle jeho pořadovků.

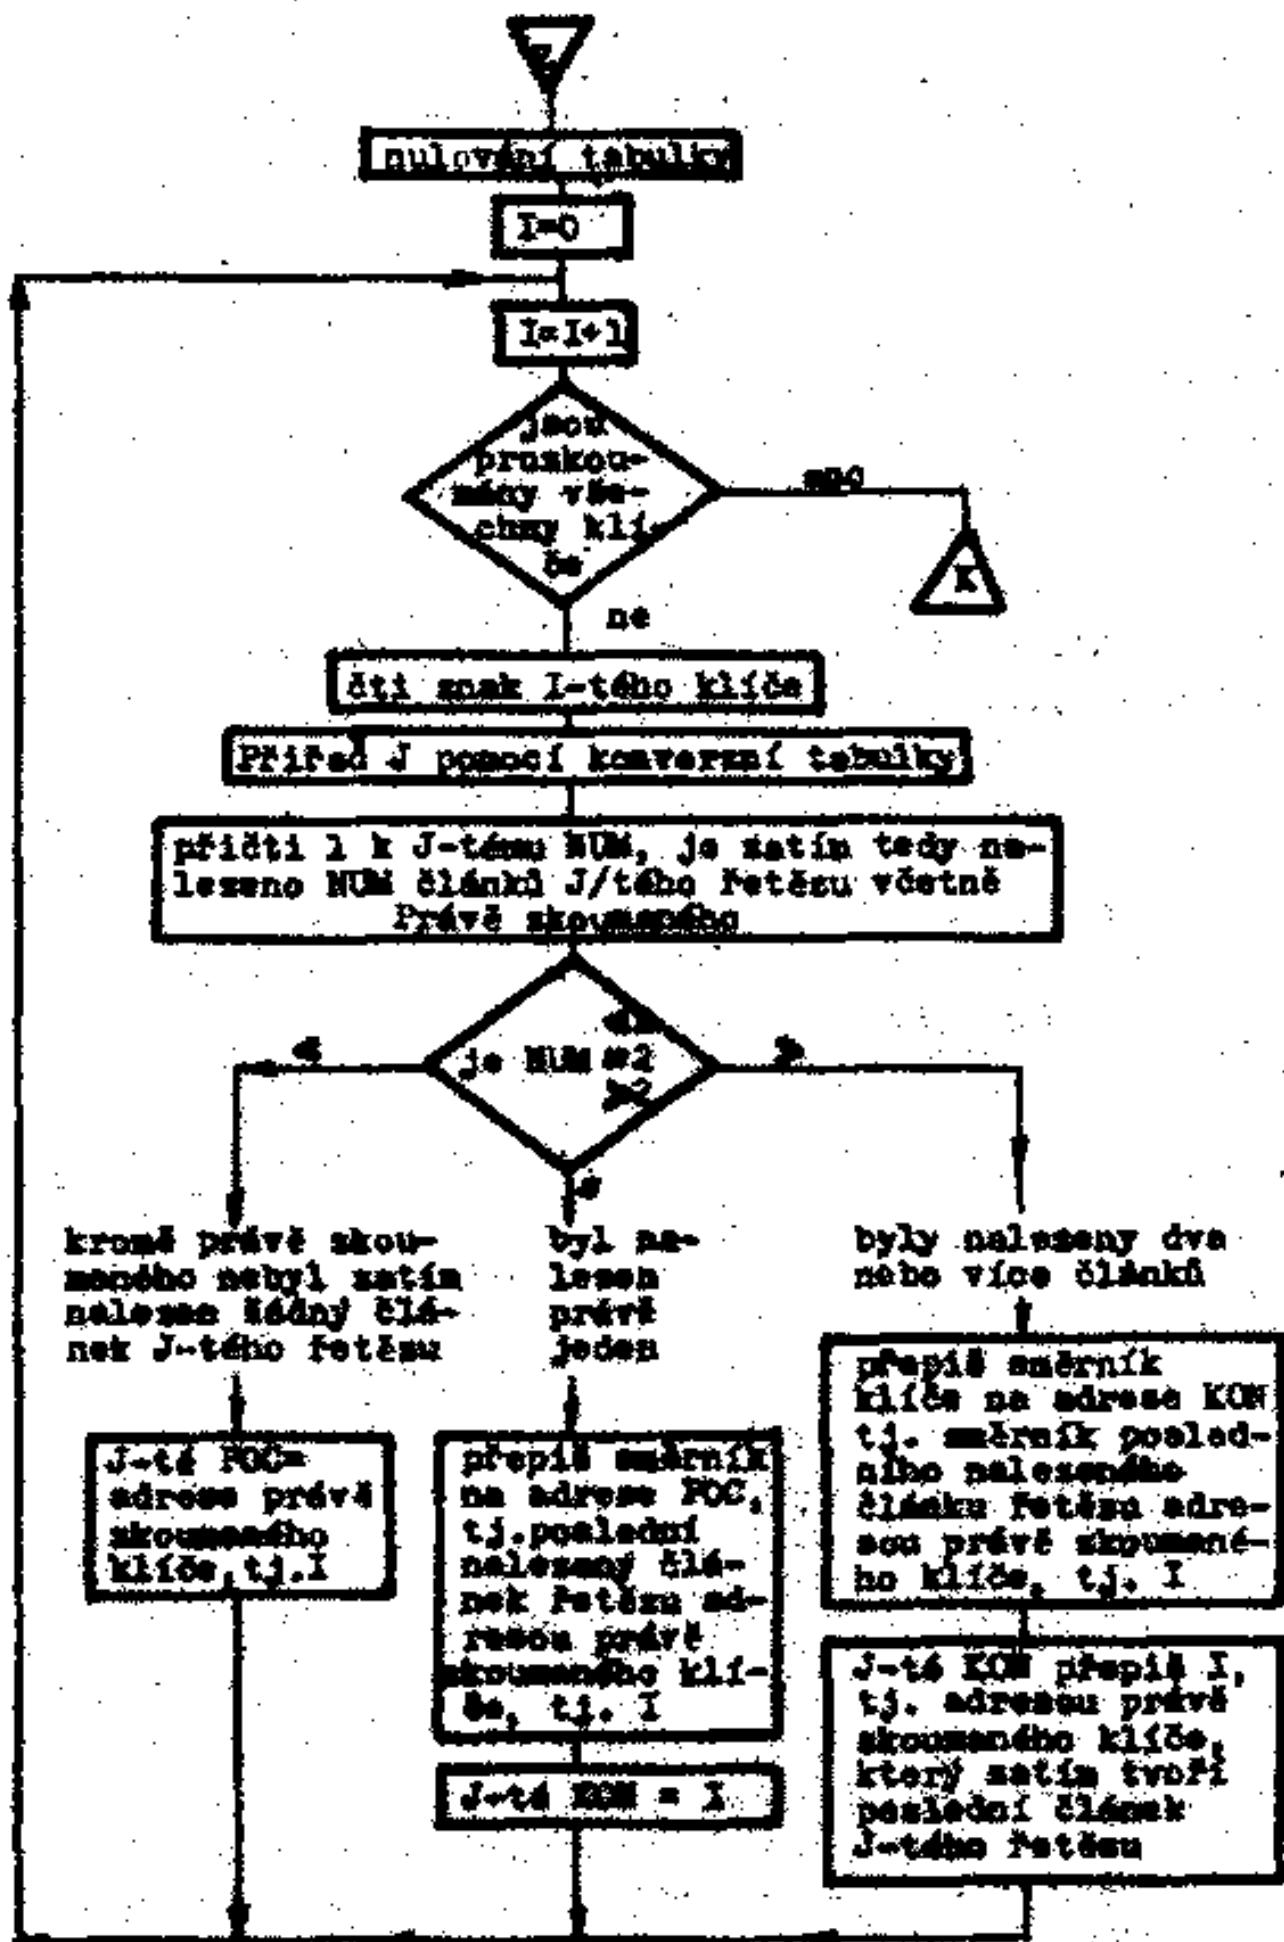
Tabulka dílčích řetězů bude mít tuto formu: např.:

	odpovídá znaku1	značku2	značku3	...	značku N
počátky dílčích řetězů	2	0	18	...	11
konce dílčích řetězů	9	0	0	...	35
počet článků	17	0	1	...	2

Znamená to, že řetěz spojující klíče "značku1" sečíná na adrese 2 od počátku souboru, končí na adrese 9 a má 17 článků, které jsou propojeny směrníky. Pro "značku2" neexistuje žádnej klíč, pro "značku3" jeden klíč na adrese 18 a pro "značku N" 2 klíče na adresách 11 a 35.

4.3. Algoritmus pro vytvoření tabulky dílčích řetězů.

Uvedeme blokové schéma (příloha bude používány skratky POC pro adresu počátku dílčího řetězu, KON pro jeho konec,



J pro pořadí znaku v tabulce, pro N znaků zvolené možností nebyvá tedy J hodnot 1 až N; (také možnost počet článků J-tého řetezku).

4.4. Úloha s možností konverzní tabulky.

Je zřejmé, že jednou z nejdůležitějších činností v předchozím algoritmu je stanovení pořadí v tabulce tj. určení J. Jak už bylo řečeno, jako prostředek zde slouží konverzní tabulka. Rozebereme si jednu z možností realizace takové tabulky.

Vycházíme přitom z takové představy tabulky:

znak1	znak2	znak3	...	znakN
J_1	J_2	J_3	...	J_N

kde znak1, znak2, ..., znakN znamená hodnotu reprezentující tento znak a J_1, J_2, \dots, J_N jsou hodnoty udávající pořadí znaku v tabulce dřížek řetezů. Každá J_i přitom může nabívat hodnot 1, 2, ..., N. Pokud je $J_i \neq J_j$ pro i ≠ j znamená to, že každému odpovídajícímu znaku přísluší jiné pořadí v tabulce dřížek řetezů, je-li $J_i = J_j$ pro i ≠ j znamená to, že odpovídající znaky mají totéž pořadí v tabulce řetezů a jsou tedy z hlediska tridiční povahovány za stejné. Tuto úvahu lze rozšířit i na více znaků než na dva.

Tak např. tabulka

A	B	C	N	K	R
2	1	5	3	6	4

udává pro tridiční pořadí B, A, N, R, C, K.

Naškýtá se ovšem otázka určení argumentu tabulky pro daný znak, tj. prakticky vyhledání znaku v tabulce. Nejvhodnější by bylo pracovat přímo s byty, do nichž se u počítačů 3. generace s bytovou strukturou ukládá právě jeden znak. Podle hodnoty uložené v bytu by pak bylo možno určit přímo

argument tabulky a to ve formě čísla udávajícího pořadí znaku v tabulce. Tabulka by pak měla při plném rozsahu bez omezení $2^8=256$ argumentů. FORTRAN však není schopen přímo s když provést, aproto je nutno volit jinou cestu. Nejkratší provedení ve FORTRANU IV má délku pásového tj. 2 byty. Při ukládání klíčů do prošaných se pak nabízejí tyto možnosti:

1. zápis - do obou bytů prošané jsou formátem A2 uloženy po sobě jdoucí znaky klíče. Počet možných kombinací přitom je 256^2 , což by znamenalo, že konverzní tabulka by musela mít tento počet argumentů (podobně i tabulka dílčích řetězů). To je ovšem z praktického hlediska k nepotřebě. I při omezení jen na alfanumerické znaky je to nejméně 27^2 argumentů (ve skutečnosti vzhledem k vnitřnímu zobrazení 42^2), což je stále ještě hodně, zohledět ke komplikacím při lichém počtu pozic klíče.

2. zápis - znak je do prošané ukládán formátem Al, je tedy v prvním bytu vyššího řádu, zatímco v bytu nižšího řádu je nulové (hexadecimálně XX 40, kde X je číslice 1 až F). I když jsme při ukládání do prošané použili znakové konverze (A), můžeme myslí prošanou považovat za číslo typu INTEGER. Bude mít hodnoty obecně jak kladné, tak i záporné, což by se dalo snadno odstranit posunutím počátku, přičemž současně vyloučíme nulovou z bytu nižšího řádu (odečtením čísla 40 hexadecimálně tj. 64). Pokud bychom však takto získané číslo chtěli využít k určení argumentu, nevyhneme se operaci dělení tohoto čísla 256-ti. Výsledný rozsah by byl v mezech 0-255 (1-256). Operace jsou však posledně číslově náročné (dělení).

3. zápis - klíč je v tomto případě zápisován v původním soubohu tak, že je preložen napravmi (první znakem rozšířeného klíče je nulová, pak první znak původního klíče, nulová, druhý znak). Tento klíč je pak ukládán do prošané formátem A2. V prvním bytu prošané je tedy nulová, ve druhém nulové řádu znak klíče. Hexadecimálně je to 40 IX. Stále tedy dělit (st nulovu z 1. bytu tj. dekádické číslo 16384 ($4 \cdot 16^3$)). Získáme tak páté číslo v rozsahu 0-255, které určí

argument konverzní tabulky. Jedinou nevýhodou je větší spotřeba paměti při ukládání klíčů, což ovšem u moderních počítačů již není tak kritická náležitost. Zavedeme-li navíc zkrácení tabulky posunutím počátku, což se provede současně s eliminováním mezery v prvním bytu, lze např. pro alfabetické třídění použít tabulky pouze o 42 argumentech (odpovídá 26 znakům a mezere). V konverzní tabulce je v tomto případě 15 "dér", které nemá smysl nijak eliminovat, poněvadž na průběh výpočtu nemají žádný vliv.

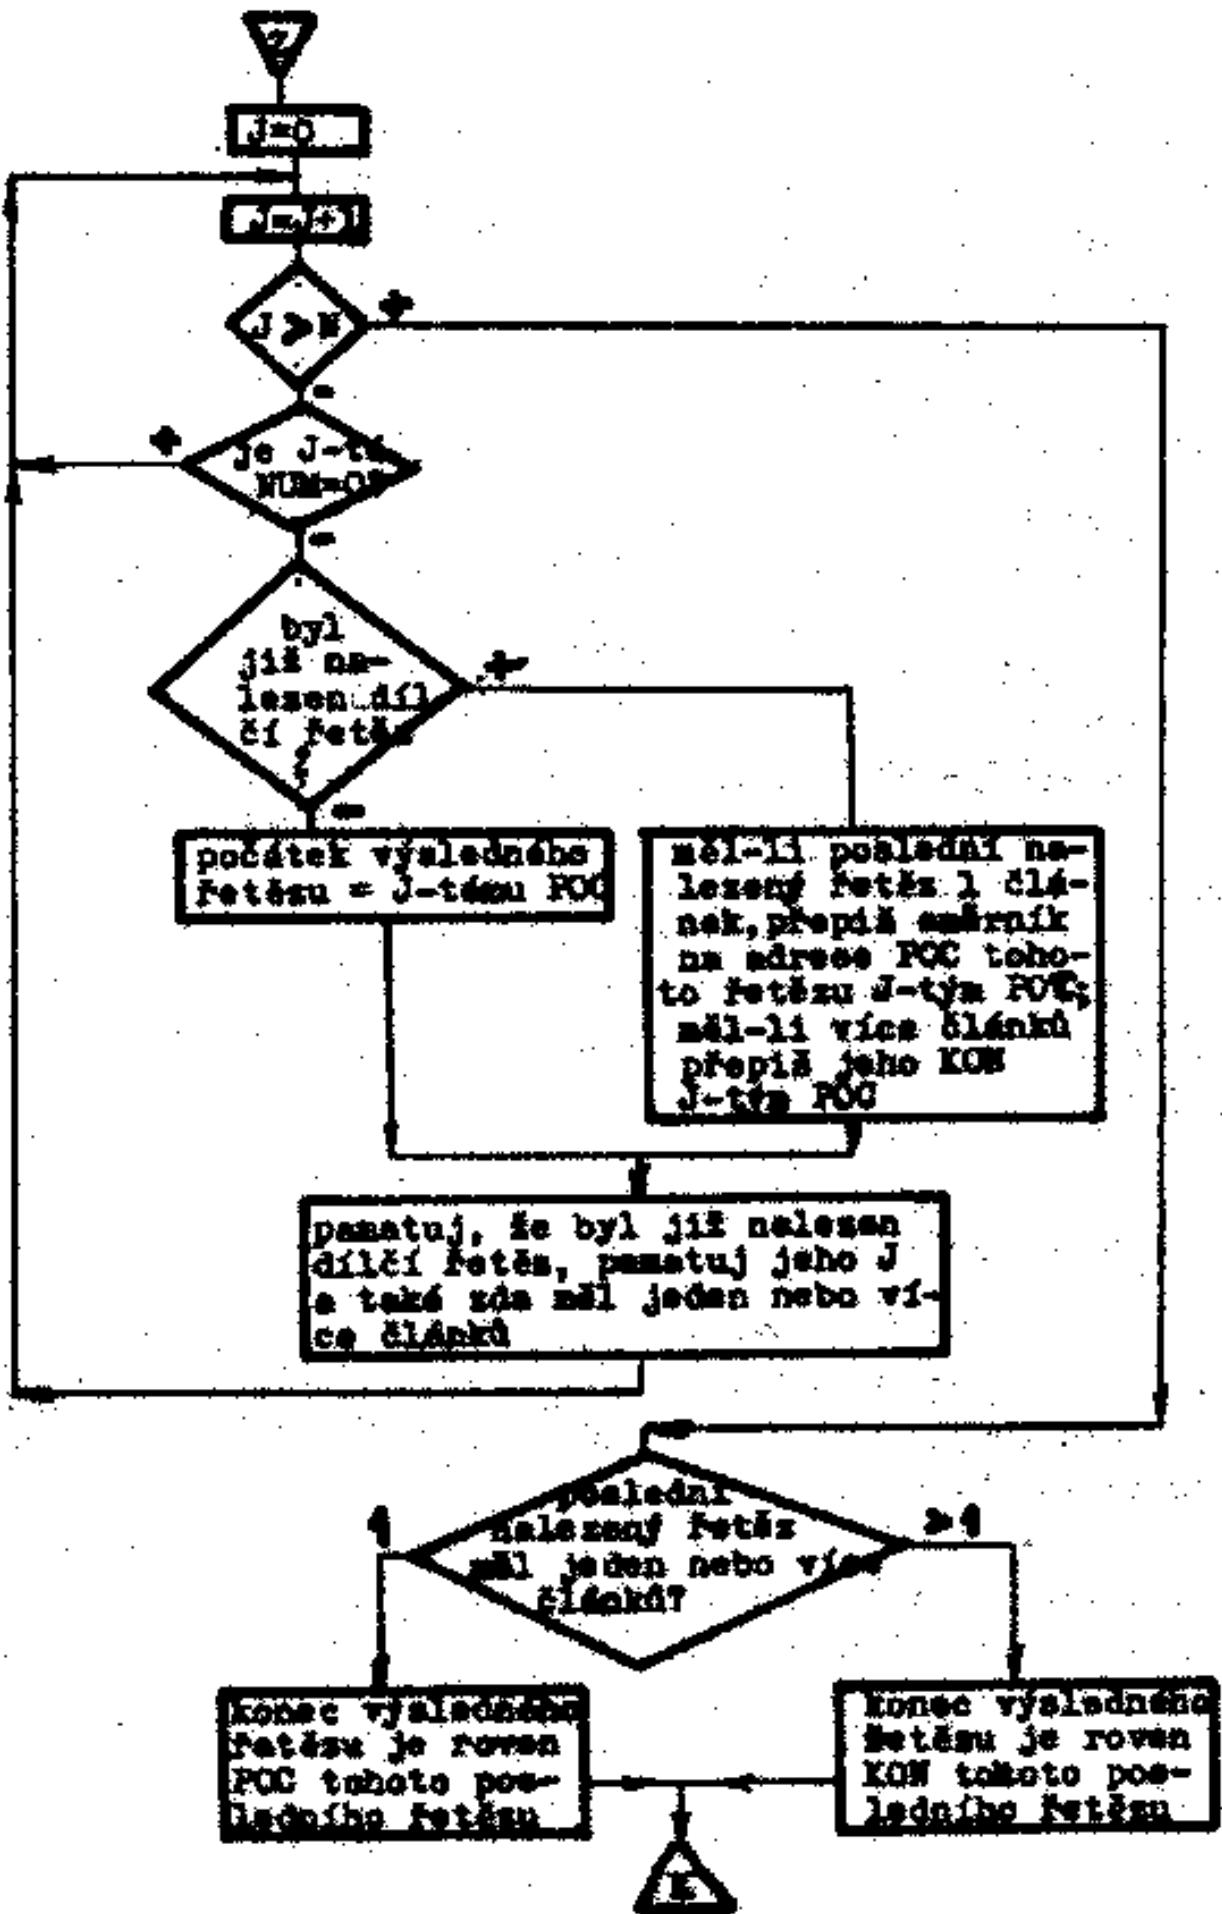
Konverzní tabulka tedy může být vytvořena jako jednorozměrné pole. Ze znaku klíče lze jednoduchou operací (odečtením) určit přímo index příslušející určitému znaku. Prvek pole odpovídající tomuto indexu pak udává pořadí v tabulce dílčích řetězů.

Určit pořadí v tabulce řetězů by bylo samozřejmě možné i jinými způsoby. V naší metodě jsme použili konverzní tabulky a jejich princip tak, jak byla popsána spolu s 3. způsobem určení jejího argumentu a to zejména z důvodu značné jednoduchosti a tím i rychlosti a z důvodu možnosti, které se naskytají při zadávání množiny tříděných znaků a jejich pořadí.

4.5. Algoritmus propojení dílčích řetězů

Další částí metody je algoritmus, který provádí propojení dílčích řetězů podle tabulky dílčích řetězů. Při označování proměnných použijeme téhož označení jako u předchozího algoritmu. Blokové schéma je na následující straně.

Po ukončení tohoto algoritmu jsou tedy známy adresy prvního článku výsledného řetězu a adresy posledního článku řetězu. Směrniky u jednotlivých klíčů propojují pak klíče podle zadaných požadavků na pořadí znaků.



4.6. Rozšíření metody pro klíč libovolné délky

Tato dosud popsaná metoda pracovala jen s klíči o jedné pozici (jeden znak). Lze ji však snadno rozšířit i na klíče s více pozicemi. Výložime si tu takové rozšíření.

Zavedeme označení dvozeně, které má souvislost s pozicí znaku v klíči. Pro 1. pozici je určena dvozeně 1, pro 2. pozici dvozeně 2 atd., až pro pozici N dvozeně N. Přitom dvozeně 1 pokládáme za nejvyšší, dvozeně N za nejmalošší. Dvozeně budeme označovat U_j pro i-tou pozici klíče.

Pro každou dvozeně pak budeme vytvářet tabulku dílčích řetězů, pokud jde vyšší dvozeně jednoznačně neurčí pořadí klíčů souboru. Postup je přitom takový:

Po vytvoření tabulky dílčích řetězů U_j je testováno, zda tyto řetězy určují jednoznačně pořadí klíčů v souboru. Tabulka je postupně procházena pro $j=1, 2, \dots, N$ -ty dílčí řetěz a je zkoumán počet prvků tohoto řetězu. Mohou nastat tyto výjimečné případy:

a) počet prvků je roven nule - pak tento řetěz "nulové" délky nemá vliv na další tabulku, poněvadž nezahrnuje žádný klíč; provedeme tedy $J=j+1$ a postoupíme s testováním k dalšímu dílčímu řetězu tabulky dvozeně U_j .

b) počet prvků je roven 1. Pořadí je jednoznačné, lze tedy $J=j+1$ a postoupit s testováním k dalšímu dílčímu řetězu tabulky dvozeně U_j .

c) počet prvků je roven 2. Pak je možno jednoduchým testem ověřit, jaké může být pořadí těchto článek řetězu, dotáhneme-li se na hodnoty pozic klíče nejhilze nižší dvozeně, pokud ovšem tato existuje. Pokud ne, nedleží na pořadí těchto článek řetězu. Po zajistění správného pořadí opět $J=j+1$ a pokračujeme v testování tabulky dvozeně U_j .

d) počet prvků je větší než 2. Pak nelze obecně jednoduše určit, jaké může být pořadí článek řetězu a je třeba postoupit do další nižší dvozeně klíče, kde můžeme získat další informace mající vliv na pořadí klíče v tomto dílčím řetězu. Je tedy třeba znova vytvořit tabulku dílčích řetězů.

U_{i+1} (t.j. nížší) a první testovaného dílčího řetězu tabulky dřevně U_i , ověřit testováním, zda je už pořadí jednoznačně určeno a pokud tomu tak je nebo pokud jsou už vyčerpány všechny pozice klíče, tabulku dřevně U_{i+1} propojit a vrátit do původní dřevně U_i správný podátek a konec dílčího řetězu (současně je provedeno i správné propojení jednotlivých článků tohoto řetězu). Pokud by znova ještě nebylo určení pořadí jednoznačné, je nutno pokračovat dále postupováním do dalších dřevní klíče $U_{i+2}, U_{i+3}, \dots, U_j$ kamži kde bude potřeba pro jednoznačné určení pořadí. Pak společným postupem propojováním tabulek od poslední zkoumané dřevně a návratem podávacích a koncových adres dílčího řetězu vyšší dřevně do této úrovně je možno celý proces postupně ukončit. Celý proces končí propojením tabulky nejvyšší dřevně t.j. dřevně 1, které odpovídá první pozici klíče. Výsledkem je pak výsledný řetěz, který je určen směrnicí klíče a obsahuje jeho podávací a koncové adresy.

Je zřejmé, že jde o proces svou podstatou rekursivní. Poněvadž FORTRAN nepovoluje rekurse - nelze volat tentýž modul, pokud není jeho provádění z předešlého výpočtu ukončeno, bylo potřeba toto omezení obejít. Možným řešením je rezervoovat pro každou dřevnou klíče jednu tabulku dílčích řetězů současně s údajem, který udává, kamži kde dosud je tabulka už uvedeným postupem otvírána. Poněvadž tyto tabulky nezbírají příliš míst, mohou být trvale v paměti. Tabulky jsou pak dynamicky "otevřeny" a "uzavřeny" podle potřeby. Tohoto postupu bylo možno i při praktické implementaci metody. Je možné i tato varianta: poněvadž pro každou dřevnou je "otevřena" vždy jen jedna tabulka, musí být v paměti přítomen jen první řada. Lze tedy tabulky vyšších dřevní, které jsou již otevřené a ještě neobsahují testované uchovávat na vnější paměti, nejlépe v souhru s přímo organizací tedy na magneticku s ohledem na dobu výběru, a dosud je podle potřeby přepisovat opět do paměti. Tedy při postupu do nižší dřevně by byla první testovaná tabulka "uklinena" na vnější paměť, při návratu do této dřevně by byla "natahena" opět.

4.7. Diskuse na tody

Při třídění dochází k testování klíčů, pokud pak není třídění prováděno v paměti k jejich čtení se souboru. Celý soubor se tak prochází, příběžný počet průchodu u obvyklých metod je většinou silně závislý na rozložení klíčů vzhledem k jejich pořadovanému pořadí a může dosahovat značných čísel. Navíc dochází k přepisování vět nebo záznamů, což se projeví značným zvýšením spotřeby strojového času, ať už jde o třídění v paměti (vyžaduje to pak přesuny dlouhých řetězců znaků) nebo o třídění mimo paměť (operace čtení a zápisu patří k výběru nejdoklějnější).

Uváděná metoda se tomu vyhýbá a odsud plynou také její výhody:

- nezávisí na rozložení klíčů, počet průchodů souborem je prakticky dán počtem pozic klíče; tato vlastnost vynikne zvláště u rozsáhlých souborů a souboru, jejichž klíče jsou zcela náhodně rozloženy
 - díky testování tabulek dílčích řetězů je třídění provedeno jen po pozici klíče, která poslední se nějakým způsobem podílí na určení poradí klíče v souboru; metoda se tedy jakoby dynamicky přispádávuje konkrétněmu zadání dlehy
 - nedochází k přepisování vět, tedy nejdalší strátové časy jsou eliminovány
 - rozsah metody lze snadno "ušít na míru" pro dané zadání
 - stejně tak lze zadat libovolnou možinu znaků pro třídění a jejich pořadí díky konverzaci tabulce
 - různé varianty a způsoby jednotlivých dílčích algoritmů umožňují do jisté míry využevat i požadavkům na maximální rychlosť nebo naproti na maximální úsporu místa v paměti

Je třeba ovšem se zmínit i o nevhodných metodách

- hlavní nevýhodou je poměrně velká spotřeba paměti -
jde o třídění v paměti a tím i omezení velikosti sou-

boru shruba na velikosti uvedené v zadání (při počítání s více než 256K paměti mnoho s virtuální pamětí). Pokud ovšem neuvádeme třídění souboru počátech, které jsou pak slučovány, jak je tomu u většiny metod, je i toto omezení prakticky eliminováno.

- další nevýhodou je nutnost používání proloženého klíče, což sice lze zafidit přímo při vytváření tříděného souboru, ale znamená to nárok na mídia. Využitím ž. způsobu určení argumentu konverzni tabulky by se dalo i toto odstranit, je však třeba ověřit, jak se to projeví na spotřebě str. času.

Pohledneme-li na metodu z hlediska tématu příspěvku, lze konstatovat, že to byly právě technika indexových tabulek (tabulky dílčích řetězů, konverzní tabulka) a zejména technika řetězení (řetězy směrovků klíčů), které umožnily reálnici této myšlenky.

Metoda je v současné době (leden 1975) ve stavu ověřování a změní spracování malých souborů opravňující k závěru, že je vysoko účinná.

5. Závěr

Domnívám se, že uvedené příklady ukázaly některé z možností obou diskutovaných technik, i když nejtypičtějšími případy jejich použití jsou spíše úlohy tzv. hromadných dat a zejména oblast databázových systémů. V dnešní době, kdy i ve VTV se zřetelně projevují tendenze ke zvětšování rozsahu úloh, které v některých směrech mají přímo i vlastnosti charakteristické pro HD, by bylo nezaslužné nepoučit se u "konkurence s hromadnými daty" a doufám, že tento příspěvek poskytne i akademickým programátorům VTV aspoň podněty k zamýšlení.

LITERATURA:

- /1/ FORTRAN IV Language, GC-28-6515-9, manuál fy IBM

- FORTRAN Programmer's Guide, GC-28-6817-3, manual
by IBM
- /2/ Petroušková : Síťová struktura v bance dat, sešity
INOSy, INOSy Praha
- /3/ Databanky v informačních systémech, sborník ČVUT,
1973
- /4/ T.Lutz, H.Klimesch : Die Datenbank im Informationssystem,
R.Oldenbourg Verlag München, Wien 1971
- /5/ F.R.A.Hopgood: Metody komplikovania, ALFA 1973
- /6/ J.M.Foster: Spracovanie zoznamov, ALFA 1973
- /7/ W.M.Turki : Struktury danych, Wydawnictwa Naukovo-
techniczne, Warszawa 1971