

De rij van unieke bladwaarden van een boom

Maarten Folkinga, 27 mei 1986

We behandelen het probleem om bij gegeven willekeurige boom de rij van ^{die} bladwaarden op te leveren die precies éénmaal in de boom (als bladwaarde) voorkomen.

* * *

Zonder verlies van algemeenheid stellen we dat bomen gedefinieerd zijn volgens het type

$$T^* ::= A^* \mid C(T^*) (T^*)$$

Hierin staat A voor Atom en C voor Constructie-van. Gevraagd wordt een functie f zo dat $f t$ = de lijst van bladwaarden (Atoms) die precies éénmaal in t voorkomen (als Atom, dus) en wel zo dat de volgorde der elementen in (ft) gelijk is aan die in t . Een formele specificatie voor f luidt bijvoorbeeld als volgt.

leaves

Er moet gelden $\text{sub}(ft, t)$ en $\forall x \in ft. \#_x t = 1$
waarbij
 $\text{sub}([], X) \leftarrow \text{true}.$

$\text{sub}(X + [y] + Z, X' + [y] + Z') \leftarrow \text{sub}(X + Z, X' + Z')$
en
 $\text{sub}(X + Z, X' + Z') \leftarrow \text{sub}(X, X') \wedge \text{sub}(Z, Z')$

leaves $\forall x = (x)$
leaves $(C t t') = \text{leaves } t \uplus \text{leaves } t'$

*Mf
werkeenvoud*

$$\begin{aligned} f(y) &= 0, \quad y \neq x \\ &= 1, \quad y = x \\ f_x(C t t') &= \#_x t + \#_x t' \end{aligned}$$

(Hierbij is sub gespecificeerd middels Horn clause logic (Prolog), en $\#_x$ middels een functioneel programma.)

De eerste stap in de programma-ontwikkeling is om te proberen een inductieve definitie voor f samen te stellen. Zonder aan te geven hoe we uit de specificatie tot hetvolgende zijn gekomen, geven we hier het resultaat van die poging.

$$\begin{aligned} f(Ax) &= [x] \\ f(C t t') &= (f t - g t') \uplus (f t' - g t') \end{aligned}$$

waarbij $g t$ = een lijst van alle bladwaarden van t , en de formeler, waarbij g is gespecificeerd door

$$(\forall x \in gt. \quad x \in t) \wedge (\forall x \in t. \quad x \in gt)$$

We moeten dus ook g uit programmeren. Als eerste stap proberen we ook voor g een inductieve definitie af te leiden uit de (informele) specificatie. Dat geeft:

$$g(Ax) = [x]$$

$$g(Ct') = gt + g t'$$

De tweede stap in de programma-ontwikkeling is nu om f en g tot één functie h te combineren. De efficientieverbetering hiervan is tweeledig. Enerzijds voorkomen we dat de bomen tweemaal aan een ontleding (inductie) worden onderworpen. Anderzijds, en dit is veel belangrijker, voorkomen we veelvuldige berekening van (gt) voor identieke t -waarden. Tummers, bekijk eens (ft, gt) :

$$(f(Ax), g(Ax)) = ([x], [x])$$

$$(f(Ct'), g(Ct')) = ((ft - gt') + (ft' - gt), gt + gt')$$

de berekeningen van

We zien hierbij dat (gt) en (gt') tweemaal worden opgeroepen. Dit wordt voorkomen door de functie h met $ht = (ft, gt)$ gedefinieerd als volgt:

$$h(Ax) = ([x], [x])$$

$$h(Ct') = ((ft - gt') + (ft' - gt), gt \oplus gt')$$

where $(ft, gt) = ht$

$$(ft', gt') = ht'$$

F Omdat g recursief is, versterkt dit proces zich: zij t een subboom op diepte n van het oorspronkelijke argument, dan wordt de berekening van (gt) 2^n maal opgeroepen.

(Er is overigens ook een andere manier om de veelvuldige oproep van identieke berekeningen te voorkomen: lazy memoisation. Door alles onveranderd te laten berekenen en alleen het directief lazymemo g toe te voegen, worden berekeningen op identieke argumenten niet herhaald maar opgezocht in een tabel van argument-resultaat paren. Zie [Hughes 1985].)

De derde stap in de programma-ontwikkeling is de eliminatie van de linkernesting van $++$. We passen de motivatie en techniek van [Fokkinga 1986] toe, en vinden

$$ht = jt([], [])$$

where

$$\begin{aligned} jt(Ax)(ft', gt') &= (x: ft', gt') \quad ? \\ &= (ft' - [x], x: gt') \quad , \text{ singleton-}x \\ &= (ft' - [x], y: gt') \quad , \text{ otherwise} \end{aligned}$$

where

$$\begin{aligned} \text{singleton-}x &= \text{and } [y \neq x \mid y \leftarrow ft'] \& \\ &\text{and } [y \neq x \mid y \leftarrow gt'] \end{aligned}$$

$$jt(Ct_1t_2)(ft', gt') = jt_1(jt_2(ft', gt'))$$

De functie j voldoet aan $jt(Ct')(ft', gt') = h(Ct')(ft', gt') = (f(Ct'), g(Ct'))$. We kunnen nu definieren

$$ft = ft \quad \text{where} \quad (ft, gt) = ht \quad ||= jt([], [])$$

We kunnen de efficiëntie nog iets opvoeren door in de functie f de test of x in $f t'$ voorkomt te vermengen met het verwijderen van x uit $f t'$ (in de otherwise-clause). Maar de grootte-orde van de tijdscomplexiteit verandert hiervoor niet: die blijft kwadratisch in het aantal bladeren van de boom. (Jimmers,^{voor} ieder blad Ax moet singleton- x berekend worden, dit kost, gesommeerd over alle bladeren, ongeveer een aantal vergelijkingen dat ligt in de orde van grootte van n , met $n =$ aantal bladeren in de boom.)

Bovenstaande efficiëntie overweging suggerent onmiddellijk nog een alternatieve oplossing. Heel vaak is het zo dat voor gesorteerde rijen een oplossing lineair is in de lengte van de rij, terwijl er sorteermethoden zijn die $n \log n$ -stappen kosten met $n =$ lengte van de rij. Dus sorteren-en-dan-triviaal-oplossen kost $n + n \log n$ stappen, en dat is minder dan n^2 .

Zonder enig probleem vinden we de volgende oplossing

$f = \text{single} \circ \text{quicksort} \circ \text{flatten}$

where $\text{single} [] = []$

$\text{single}[x] = [x]$

$\text{single}(x:y:z) = x: \text{single}(y:z), x \neq y$
 $= \text{single}(y:z), x=y$

Fout: oorspronkelijke volgorde gaat verloren

Beter: ~~$f t = \text{single} [] (\text{flatten } t)$~~

~~met~~
 ~~$\text{single } Y [] = []$~~
 ~~$\text{single } Y (x:Y) = x: \text{single } (x:Y) X, x \notin Y$~~
 ~~$= \text{single } Y X, x \in Y$~~

$f t = \text{single} (\text{flatten } t)$

when $\text{single } (x:X) = x: \text{single } X, x \notin X$
 $= (\text{single } X - [x]), x \in X$ (of: $\text{single } (X - \{x\}), x \in X$)

Zoogau dat single heelal oplost: $s'X = (\text{single } X, \text{set } X)$ zodat test $x \in X$ werkt: $x \in \text{set } X$ (efficiency).

Hiermee is onze programma-ontwikkeling voltooid. Hetzelfde probleem wordt ook behandeld in [Henderson 1981].

Literatuur

↙ Fokkinga, M.M., Eliminatie van leestnesting. Manuscript, 27 mei 1986.

Henderson, P., Functional Programming - Application and Implementation, Prentice-Hall, 1981

Hughes, J., Lazy memo-functions. In Functional programming languages and Computer Architecture, (ed. JP Jouannaud), Springer-Verlag, LNCS 201 (1985) pp 129-146.

↖ Fokkinga, M.M., Elimination of list nesting - an example of the style of functional programming. Memorandum INF-86-??, T.H. Twente, 1986