

Programmierung und Modellierung

Benutzerdefinierte Datentypen

Martin Wirsing

in Zusammenarbeit mit
Moritz Hammer

Inhalt

- Kap. 7 Benutzerdefinierte Datentypen
 1. Aufzählungstypen
 2. Typen mit zusammengesetzten Werten
 3. Binärbäume
 4. Rekursive Datentypen in SML
 5. Linearisierung von Binärbäumen
 6. Tiefendurchlauf und Breitendurchlauf
 7. Anwendung: Repräsentation und Auswertung von Termen
 8. Binärer Suchbaum

7.1 Aufzählungstypen

- Ein Typ `Farbe` bestehend aus der Wertemenge `{Rot, Gelb, Blau}` kann in SML wie folgt definiert werden:
 - `datatype Farbe = Rot | Gelb | Blau;`
 - `datatype Farbe = Blau | Gelb | Rot`
 - `Rot;`
 - `val it = Rot : Farbe`
- Diese Deklaration legt das Folgende fest:
 - Mit dem Schlüsselwort `datatype` können in SML neue Datentypen deklariert werden.
 - Der Name `Farbe` ist eine **Typkonstante**.
 - Die Typkonstante `Farbe` wird an die Wertemenge `{Rot, Gelb, Blau}` gebunden.
 - Die Namen `Rot`, `Gelb` und `Blau` sind 0-stellige **(Wert-)Konstruktoren**.
- Ein Datentyp `dt`, der aus endlich vielen Konstanten besteht, wird **Aufzählungstyp** genannt und in SML folgendermaßen deklariert:
 - `datatype dt = c1 | ... | cn;`Dadurch werden `n` Konstanten (0-stellige Konstruktoren) `ci : dt` deklariert.

Aufzählungstypen

- Operationen über Aufzählungstypen können durch Pattern Matching bzgl. der Wertkonstruktoren definiert werden:

```
- fun farbname(Rot) = "rot"  
  | farbname(Gelb) = "gelb"  
  | farbname(Blau) = "blau";  
val farbname = fn : Farbe -> string  
- farbname(Gelb);  
val it = "gelb" : string  
- [Rot, Blau];  
val it = [Rot,Blau] : Farbe list
```

- Die Gleichheit wird implizit bei der datatype-Deklaration mitdefiniert:

```
- Blau = Blau;  
val it = true : bool  
- Blau = Rot;  
val it = false : bool
```

7.2 Typen mit zusammengesetzten Werten

- Typen mit zusammengesetzten Werten können folgendermaßen definiert werden

```
datatype Preis = DM of real | Euro of real;
datatype Preis = DM of real | Euro of real
```

- Diese Deklaration legt das Folgende fest:

- Der Name `Preis` ist eine Typkonstante.
- Die Typkonstante `Preis` wird an die folgende Wertemenge gebunden:

$$\{DM(x) \mid x \in \mathbb{R}\} \cup \{Euro(x) \mid x \in \mathbb{R}\}$$

- Die Namen `DM` und `Euro` sind unäre (einstellige) (Wert-)Konstruktoren, beide vom Typ `real` \rightarrow `Preis`.

- Bemerkung

- Man beachte die Syntax `conj of typj` in der Definition eines Wertkonstruktors für einen benutzerdefinierten Datentyp `dt`:

```
datatype dt = ... | conj of typj | ...
```

- Dadurch werden Wertkonstruktoren `ci: typj \rightarrow dt` deklariert.
- [Die Syntax unterstreicht, dass ein Wertkonstruktor eines Typs keine gewöhnliche Funktion ist.]

Typen mit zusammengesetzten Werten

- Pattern Matching ist die bevorzugte Weise, Funktionen auf benutzerdefinierten Typen mit zusammengesetzten Werten zu definieren:

```
- fun wechseln(DM(x)) = Euro(0.51129 * x)
| wechseln(Euro(x)) = DM(1.95583 * x);
val wechseln = fn : Preis -> Preis
```

- Es ist empfehlenswert, die Fälle beim Pattern Matching in der Reihenfolge der Typdefinition aufzulisten.
- Unter Verwendung der vordefinierten Funktionen `real` und `round` kann `wechseln` verbessert werden, um auf die zweite Nachkommastelle zu runden:

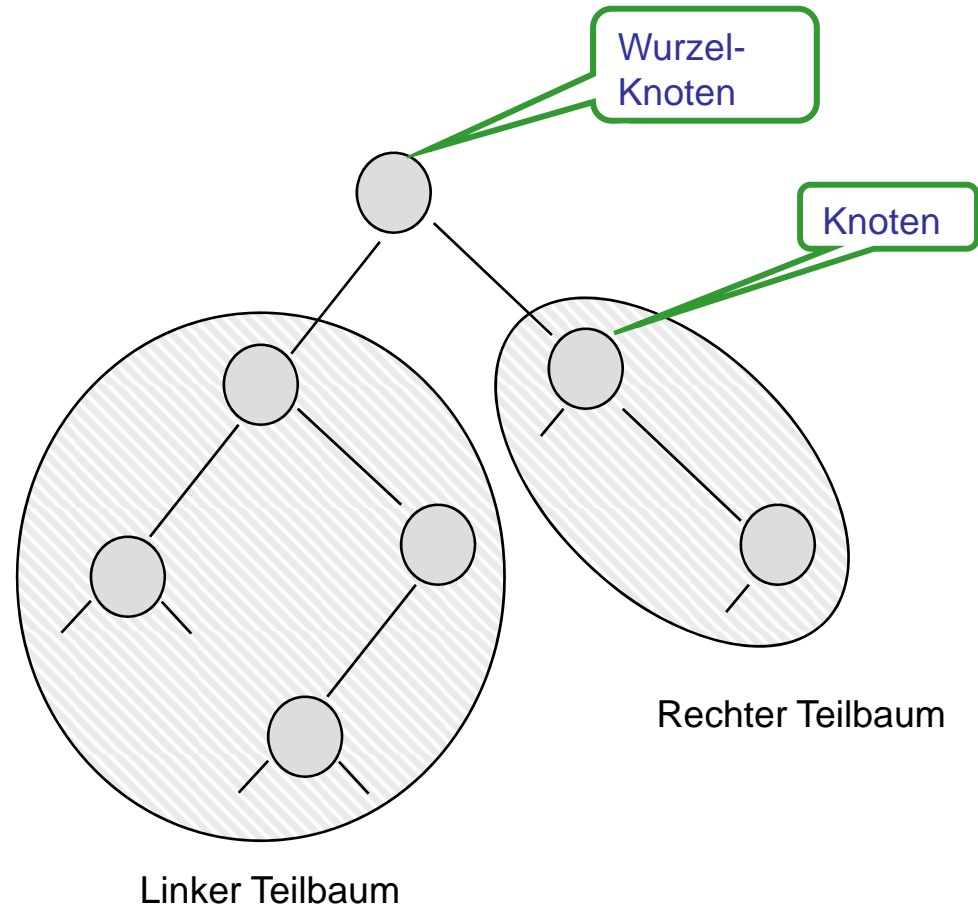
```
fun wechseln(DM(x)) =
    Euro(real(round(0.51129 * x * 1e5)) * 1e~5)
| wechseln(Euro(x)) =
    DM(real(round(1.95583 * x * 1e5)) * 1e~5);
```

Typen mit zusammengesetzten Werten

- Die Gleichheit für benutzerdefinierte Typen ist komponentenweise definiert:
 - `datatype zeitpunkt = Sek of int | Min of int | Std of int;`
 - `datatype zeitpunkt = Min of int | Sek of int | Std of int`
 - `Sek(30) = Sek(20+10);`
 - `val it = true : bool`
 - `Min(60) = Std(1);`
 - `val it = false : bool`
 - `Euro(2.0) = Euro(2.0);`
 - `Error: operator and operand don't agree [equality type required]`
 - `operator domain: 'Z * 'Z`
 - `operand: Preis * Preis`
 - `in expression: Euro(2.0) = Euror(2.0);`
- Zwei Werte sind gleich, wenn
 - ihre (Wert-)Konstruktoren gleich sind (was für `Min(60)` und `Std(1)` nicht der Fall ist) und
 - der Argumenttyp des Wertkonstruktors eine Gleichheitsoperation besitzt u.
 - die Argumente der (Wert-)Konstruktoren gleich sind.

7.3 Bäume (abstrakt)

- Bäume sind **hierarchische Strukturen**.
- Bäume bestehen aus
 - **Knoten** und
 - **Teilbäumen**.
- Der oberste Knoten heißt **Wurzel**.
- Bei **Binärbäumen** hat jeder Knoten zwei Unterbäume:
 - den **linken Unterbaum**,
 - den **rechten Unterbaum**.
- In den Knoten kann Information gespeichert werden.




Binärbäume

- **Definition:** Sei A eine Menge. Die Menge A^Δ der **Binärbäume über A** ist induktiv definiert wie folgt:
 - A^Δ enthält den **leeren Binärbaum** ε
 - Sind x in A und $l, r \in A^\Delta$, so ist das 3-Tupel $(x, l, r) \in A^\Delta$
- Man kann die induktive Definition wie folgt umgehen:
Die Menge A_n^Δ der **Binärbäume der Höhe (Tiefe) höchstens n** ist rekursiv (über n) definiert durch
 - $A_0^\Delta = \{\varepsilon\}$
 - $A_{n+1}^\Delta = A_n^\Delta \cup \{(x, l, r) \mid x \in A, l \in A_n^\Delta, r \in A_n^\Delta\}$.Es ist dann $A^\Delta = \bigcup \{A_n^\Delta \mid n \in \mathbb{N}\}$
- Die **Höhe** (Tiefe) eines Binärbaumes $t \in A^\Delta$ ist das kleinste n , so dass $t \in A_n^\Delta$.


Binärbäume Terminologie

- x heißt **Wurzel** oder **Wurzelbeschriftung** von (x, l, r) .
- l, r heißen **linker, bzw. rechter Unterbaum** von (x, l, r) . Ein Binärbaum der Form $(x, \varepsilon, \varepsilon)$ heißt **Blatt**. Ein von ε verschiedener Binärbaum heißt **nichtleer**.
- Die **Knoten** und **Teilbäume** eines Binärbaums sind rekursiv definiert wie folgt:
 - ε hat keine Knoten und nur ε als Teilbaum.
 - Die Knoten von (x, l, r) sind x und die Knoten von l und die Knoten von r . Die Teilbäume von (x, l, r) sind (x, l, r) und die Teilbäume von l und von r .



Binärbäume Beispiel

- $t_0 = (6,$
 $(3, (2, \varepsilon, \varepsilon), (8, (5, \varepsilon, \varepsilon), \varepsilon)),$
 $(8, \varepsilon, (4, \varepsilon, \varepsilon)))$.
- Knoten von t_0 :
 $\{6, 3, 2, 8, 5, 4\}$.
- Teilbäume von t_0 :
 $\{t_0, (3, (2, \varepsilon, \varepsilon), (8, (5, \varepsilon, \varepsilon), \varepsilon)),$
 $(2, \varepsilon, \varepsilon),$
 $(8, (5, \varepsilon, \varepsilon), \varepsilon),$
 $(5, \varepsilon, \varepsilon),$
 $(8, \varepsilon, (4, \varepsilon, \varepsilon)),$
 $(4, \varepsilon, \varepsilon), \varepsilon\}$



7.4 Rekursive Datentypen in SML

- Ein **benutzdefinierter Datentyp** in SML hat die Form

```
datatype dt = ... | ci | ... | conj of typj | ...
```

wodurch die (0-stelligen) Wertkonstruktoren $c_i : dt$ und die Wertkonstruktoren $con_j : typ_j \rightarrow dt$ deklariert werden.

- Man nennt den deklarierten Typ dt einen **rekursiven Datentyp, wenn** dt auf der rechten Seite der Deklaration in mindestens einem der Typausdrücke typ_j auftritt.

- Beispiel Binärbäume**

```
datatype 'a bintree =
  Empty | Build of 'a * 'a bintree * 'a bintree;
```

- Nun können wir Binärbäume bilden und Funktionen darauf definieren:

```
val t0 =
  Build(6, Build(3, Build(2, Empty, Empty),
    Build(8, Build(5, Empty, Empty), Empty)),
  Build(8, Empty, Build(4, Empty, Empty))
  );
```

- Bemerkung**

Polymorphe Datentypen haben die Form $'a dt$ (oder $('a, 'b) dt$ oder ...)

Funktionen für Binärbäume in SML

```
fun root (Build(x,_,_)) = x; (* unvollst
    Mustervergleich *)
fun left (Build(_,l,_)) = l;
fun right (Build(_,_,r)) = r;

fun isempty t = (t = Empty);

fun anzahl_knoten Empty = 0
  | anzahl_knoten (Build(_,l,r)) =
      1 + anzahl_knoten l + anzahl_knoten r;

fun max x y = if x>y then x else y;
fun tiefe Empty = 0
  | tiefe (Build(_,l,r)) = 1 + max (tiefe l) (tiefe r);
```

Binärbäume als Rechenstruktur

■ **Bemerkung**

- Der Datentyp `'a bintree` und
- die Operationen `Empty`, `Build`, `isempty`, `root`, `left`, `right` bilden die **Rechenstruktur der Binärbäume**.

Grundalgorithmen für Binärbäume als Übung

- Gleichheit zweier Binärbäume:

`bbeq : 'a bintree -> 'a bintree -> bool`

- Suchen eines Datenelements in einem Binärbaum:

`enthalten : 'a -> 'a bintree -> bool`

7.5 Linearisierung von Binärbäumen

- Im folgenden definieren wir drei Funktionen

`linvor, linsym, linnach`

jeweils vom Typ


`'a bintree -> 'a list`

welche die Knoten eines Baums in einer bestimmten Reihenfolge als Liste berechnen.

Linearisierung: Vorordnung (Präfix-Schreibweise)

```
fun linvor Empty = []  
| linvor (Build(a,l,r)) =  
  a :: linvor l @ linvor r;
```


```
- linvor t0;  
val it =  
[6, 3, 2, 8, 5, 8, 4]  
  : int list
```



Linearisierung: Symmetrische Ordnung

```
fun linsym Empty = []  
| linsym (Build(a,l,r)) =  
  linsym l @ [a] @ linsym r;
```


```
- linsym t0;  
val it =  
[2, 3, 5, 8, 6, 8, 4]  
: int list
```



Linearisierung: Nachordnung

```
fun linnach Empty = []  
| linnach (Build(a,l,r)) =  
  linnach l @ linnach r @ [a];
```

```
- linnach t0;  
val it =  
[2, 5, 8, 3, 4, 8, 6]  
: int list
```



7.6 Tiefendurchlauf und Breitendurchlauf

- Vorordnung, Nachordnung und symmetrische Ordnung haben gemeinsam, dass die **Teilbäume** des Baums unabhängig voneinander **durchlaufen werden**, d.h. dass alle “Äste” des Baums systematisch durchlaufen werden.
- Der Unterschied der Funktionen liegt nur darin, wie das Ergebnis jeweils zusammengesetzt wird.
- Das gemeinsame Prinzip ist als **Tiefendurchlauf (Depth-First-Durchlauf)** bekannt und kann durch Funktionen höherer Ordnung als gemeinsame Abstraktion definiert werden:

```
fun depth_first c f Empty = c
|   depth_first c f (Build(a, l ,r)) =
      f(a, depth_first c f l,
        depth_first c f r);
```

Tiefendurchlauf

- ```
fun linsym t =
 depth_first nil
 (fn (a,lv,rv) => lv @ [a] @ rv)
 t;
```
- ```
fun linvor t =  
  depth_first nil  
    (fn (a,lv,rv) => a :: lv @ rv)  
  t;
```
- ```
fun linnach t =
 depth_first nil
 (fn (a,lv,rv) => lv @ rv @ [a])
 t;
```

## Tiefendurchlauf

- Aber auch andere nützliche Funktionen auf Binärbäumen lassen sich mit Hilfe des Tiefendurchlaufs leicht implementieren, z.B.

```
fun anzahl_knoten t =
```

```
 depth_first 0
```

```
 (fn (a,lv,rw) => 1 + lv + rw)
```

```
 t;
```

```
fun tiefe t =
```

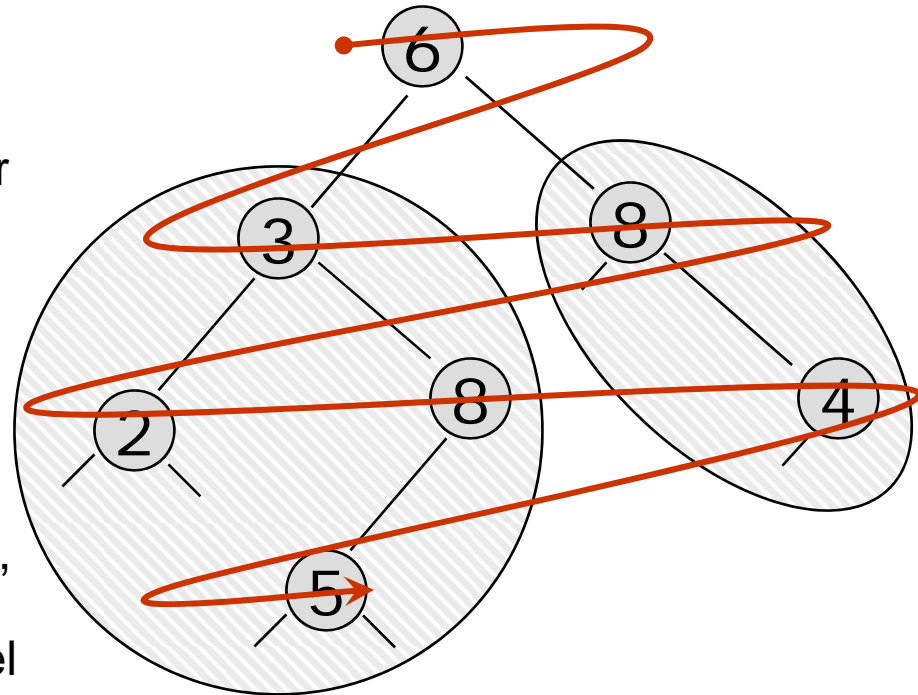
```
 depth_first 0
```

```
 (fn (a,lv,rw) => 1 + Int.max(lv,rw))
```

```
 t;
```

## Breitendurchlauf

- Bei einem **Breitendurchlauf (Breadth-First-Durchlauf)** werden die Knoten nach wachsender Tiefe besucht.
- Zuerst wird die Wurzel aufgesammelt, dann die Wurzeln der Nachfolger, dann die Wurzeln von deren Nachfolgern usw.
- Das Ergebnis des Breitendurchlaufs ist also für Baum  $t_0$  die Liste  $[6,3,8,2,8,4,5]$ .
- Zur Implementierung bedienen wir uns einer Hilfsfunktion `entwurzeln`, die angewandt auf eine Liste von Bäumen von jedem Baum die Wurzel aufammelt und die Nachfolger der Wurzel am Ende der Liste für die spätere Weiterverarbeitung einfügt.



## Breitendurchlauf

```
- fun breadth_first(t) =
 let
 fun entwurzeln nil = nil
 | entwurzeln(Empty :: tl) = entwurzeln(tl)
 | entwurzeln(Build(a,l,r) :: tl) =
 a :: entwurzeln(tl @ [l,r])
 in
 entwurzeln(t :: nil)
 end;
val breadth_first =
 fn : 'a bintree -> 'a list
- breadth_first t0;
val it = [6,3,8,2,8,4,5] : int list
```



## 7.7. Anwendung: Repräsentation und Auswertung von Termen

```
val t =
 Build("-",
 Build("+",
 Build("10", Empty, Empty),
 Build("*", Build("x", Empty, Empty),
 Build("85", Empty, Empty))),
 Build("+",
 Build("124", Empty, Empty),
 Build("y1", Empty, Empty)))
- linnach t;
val it =
["10", "x", "85", "*", "+", "124", "y1", "+", "-"] : string
list
```

- Terme lassen sich als Bäume repräsentieren. Die Nachordnung entspricht der Postfixnotation. Die Nachordnung entspricht der Postfixnotation, die Vorordnung der Präfixnotation und die symmetrische Ordnung der Infixnotation.

# Bessere Repräsentation von Termen

- Nachteile der vorigen Repräsentation:
  - Sehr viel “Empty”,
  - Auch syntaktisch falsche Terme haben Repräsentation:  
Z.B. `Build("x",Build(...),Build(...))`
- Besser ist die Verwendung einer speziellen rekursiven Variante:

```
datatype binop = Plus | Minus | Mal | Geteilt;
datatype expr =
 Var of string | Num of int |
 Op of binop * expr * expr;
```

```
val t =
 Op(Minus,
 Op(Plus, Num 10, Op(Mal, Var "x", Num 85)),
 Op(Plus, Num 124, Var "y1"));
```

- D.h. führt man ein:
  - einstellige Wertkonstruktoren für die Variablen und Konstanten und
  - einen n-stelligen Wertkonstruktor für die n-stelligen Operationen .

## Auswertung von Termen

- Repräsentiere **Umgebung** als Liste von Paaren der Form

**Variable-Zahl**, z.B.:

- Umgebung {<"x", 9>, <"y1", 0>, <"z", 3>}
- repräsentiert als [ ("x", 9), ("y1", 0), ("z", 3) ]

- Einfügen mit ::

- Auslesen mit

```
- fun lookup x ((y,z):: l) =
 if x=y then z else lookup x l;
val it = fn : 'a -> ('a * 'b) list -> 'b
```


- Eine so verwendete Liste von Paaren heißt **Assoziationsliste**.

## Rekursive Auswertung von Termen

```
fun eval (Num x) env = x
| eval (Var x) env = lookup x env
| eval (Op(Plus,t1,t2)) env = (eval t1 env) + (eval t2 env)
| eval (Op(Minus,t1,t2))env = (eval t1 env) - (eval t2 env)
| eval (Op(Mal,t1,t2)) env = (eval t1 env) * (eval t2 env)
| eval (Op(Geteilt,t1,t2)) env =
 (eval t1 env) div (eval t2 env);
```

## 7.8 Binärer Suchbaum

- Ein Binärbaum  $b$  heißt **geordnet** (oder auch **Suchbaum**), wenn folgendes für alle nichtleeren Teilbäume  $t$  von  $b$  gilt:
  - Der Schlüssel von  $t$  ist
  - größer (oder gleich) als alle Schlüssel des linken Teilbaums von  $t$  und
  - kleiner (oder gleich) als alle Schlüssel des rechten Teilbaums von  $t$
  
- **Genauer:** Ein binärer Baum  $t$  heißt **binärer Suchbaum** (binary search tree, BST), wenn
  - $t = \varepsilon$  oder  $t = (a, l, r)$  und
    - Für jeden Knoten  $x$  von  $l$  gilt  $x < a$ .
    - Für jeden Knoten  $x$  von  $r$  gilt  $a < x$
    - $l$  und  $r$  sind selbst wiederum binäre Suchbäume.



## Effizientes Suchen in binären Suchbäumen

- Folgende Funktion stellt fest, ob ein Knoten in einem binären Suchbaum enthalten ist:

```
fun enthaltenBST x Empty = false
| enthaltenBST x (Build(y,l,r)) =
 x=y orelse
 if x<y then enthaltenBST x l
 else enthaltenBST x r;
```

- Es werden nur die Knoten auf dem Pfad von der Wurzel zum gesuchten Element, bzw. bis zu einem Blatt angesehen.
- Dagegen werden bei `enthalten` *alle* Knoten angesehen.
- Dafür ist `enthaltenBST` aber nur korrekt für binäre Suchbäume.

## Zusammenfassung (I)

- Ein Datentyp, der aus endlich vielen Konstanten besteht, wird **Aufzählungstyp** genannt.
- Ein **benutzdefinierter Datentyp** in SML hat die Form
$$\text{datatype } dt = \dots | c_i | \dots | \text{con}_j \text{ of } \text{typ}_j | \dots$$
wodurch die Konstanten (0-stelligen Wertkonstruktoren)  $c_i : dt$  und die Wertkonstruktoren  $\text{con}_j : \text{typ}_j \rightarrow dt$  deklariert werden.
- Man nennt den deklarierten Typ  $dt$ 
  - **Aufzählungstyp**, wenn die rechte Seite nur aus Konstanten besteht;
  - **rekursiven Datentyp**, wenn  $dt$  auf der rechten Seite der Deklaration in mindestens einem der Typausdrücke  $\text{typ}_j$  auftritt.
- Ein Baum besteht aus **Knoten** und **Teilbäumen**.
  - Der oberste Knoten heißt **Wurzel**.
  - Bei einem **Binärbaum** hat jeder Knoten zwei Unterbäume:
    - den **linken Unterbaum**,
    - den **rechten Unterbaum**.

## Zusammenfassung (II)

- **Terme** lassen sich als Bäume repräsentieren.
  - Die Nachordnung entspricht der Postfixnotation, die Vorordnung der Präfixnotation und die symmetrische Ordnung der Infixnotation.
  - Typischerweise führt man ein:
    - einstellige Wertkonstruktoren für die Variablen und Konstanten und
    - einen n-stelligen Wertkonstruktor für die n-stelligen Operationen .
  - Zur Auswertung der Terme benötigt man eine Umgebung (Assoziationsliste), die die Werte der (freien) Variablen verwaltet.
- Ein Binärbaum  $b$  heißt **geordnet** (oder auch **Suchbaum**), wenn Folgendes für alle nichtleeren Teilbäume  $t$  von  $b$  gilt:
  - Der Schlüssel von  $t$  ist
  - größer (oder gleich) als alle Schlüssel des linken Teilbaums von  $t$  und
  - kleiner (oder gleich) als alle Schlüssel des rechten Teilbaums von  $t$