

Systemtheorie 1

Formale Systeme 1

#342234

<http://fmv.jku.at/fs1>

WS 2006/2007

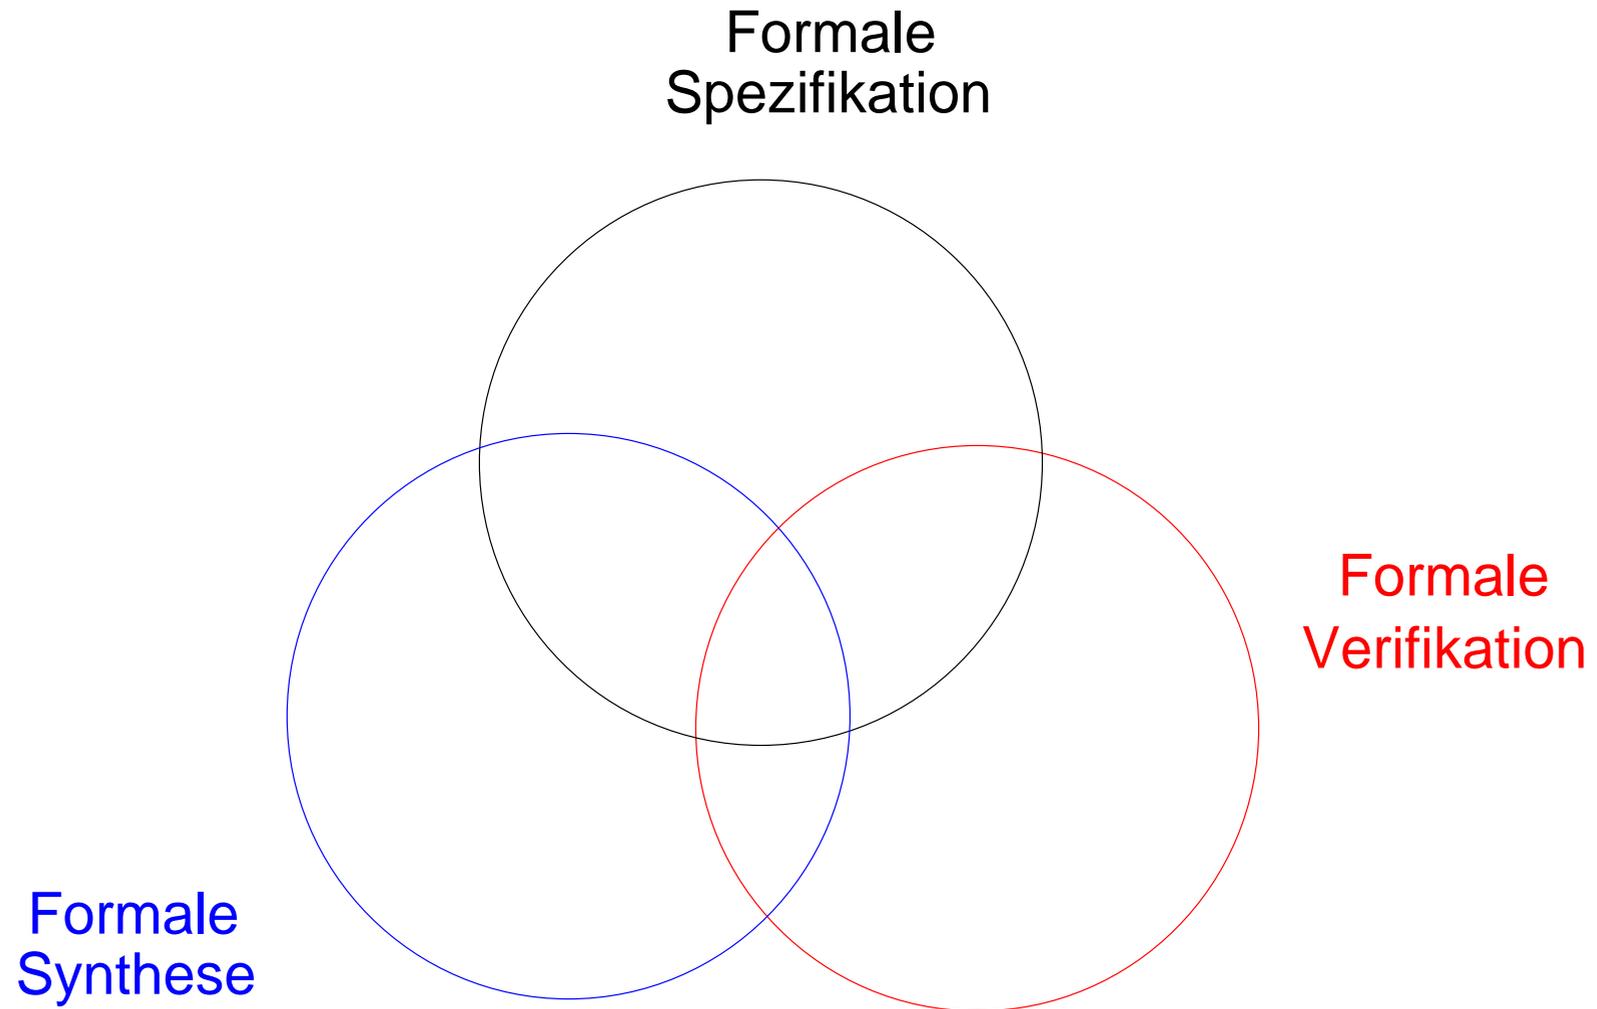
Johannes Kepler Universität

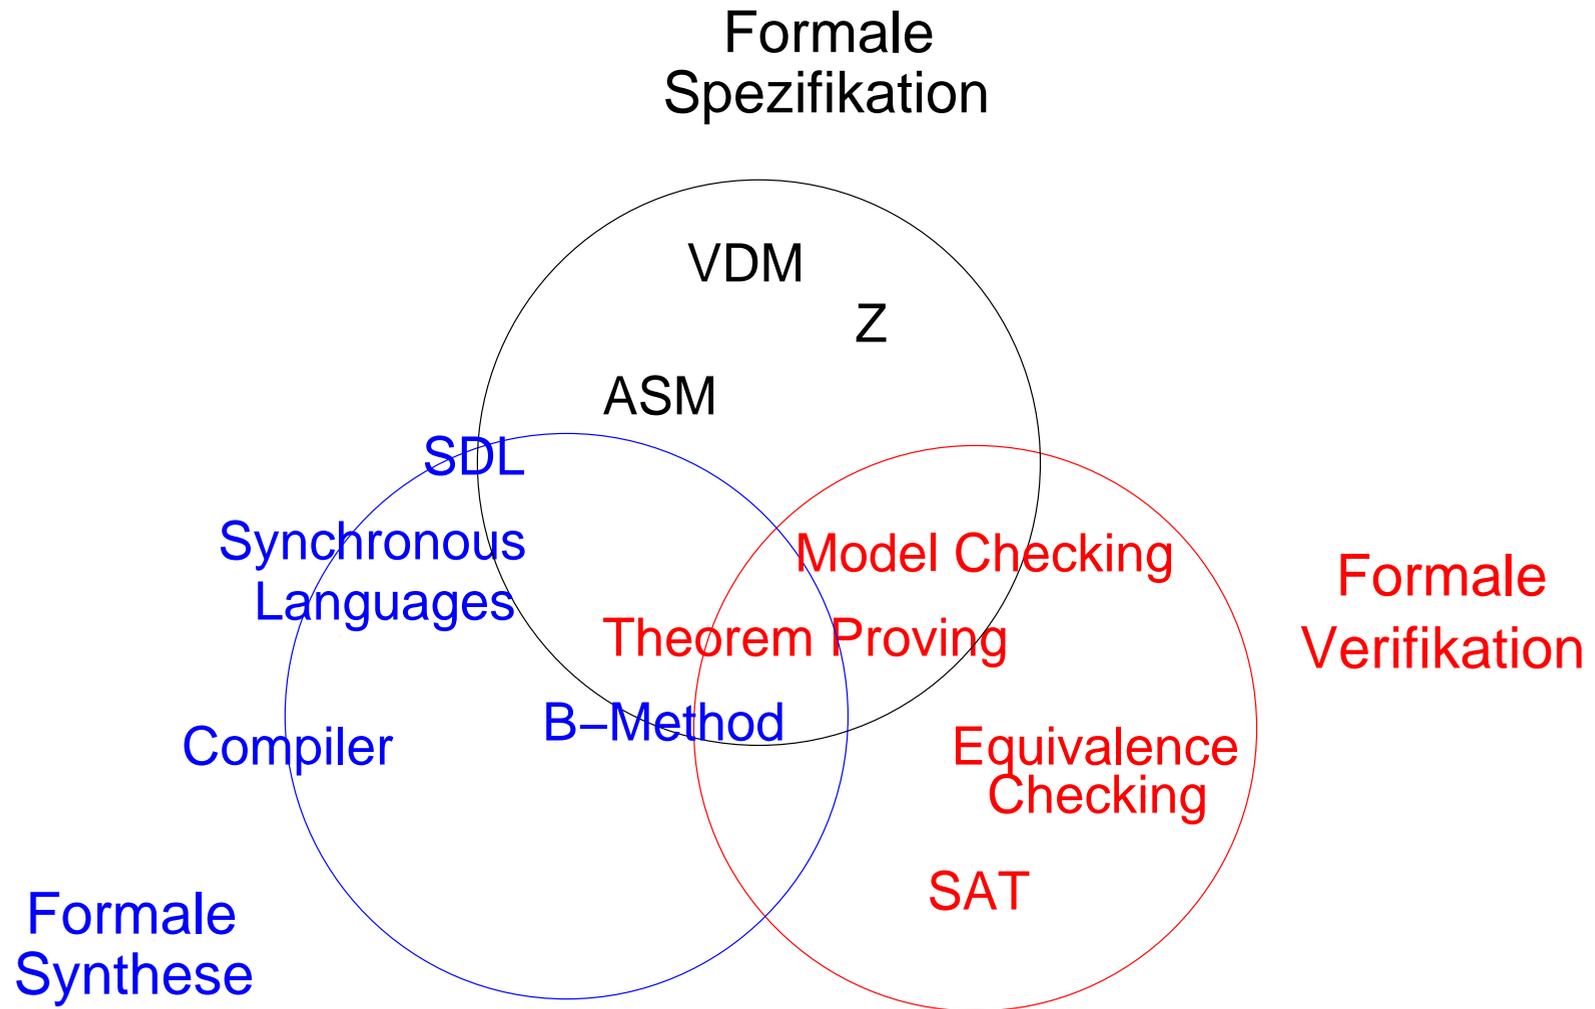
Linz, Österreich

Univ. Prof. Dr. Armin Biere

Institut für Formale Modelle und Verifikation

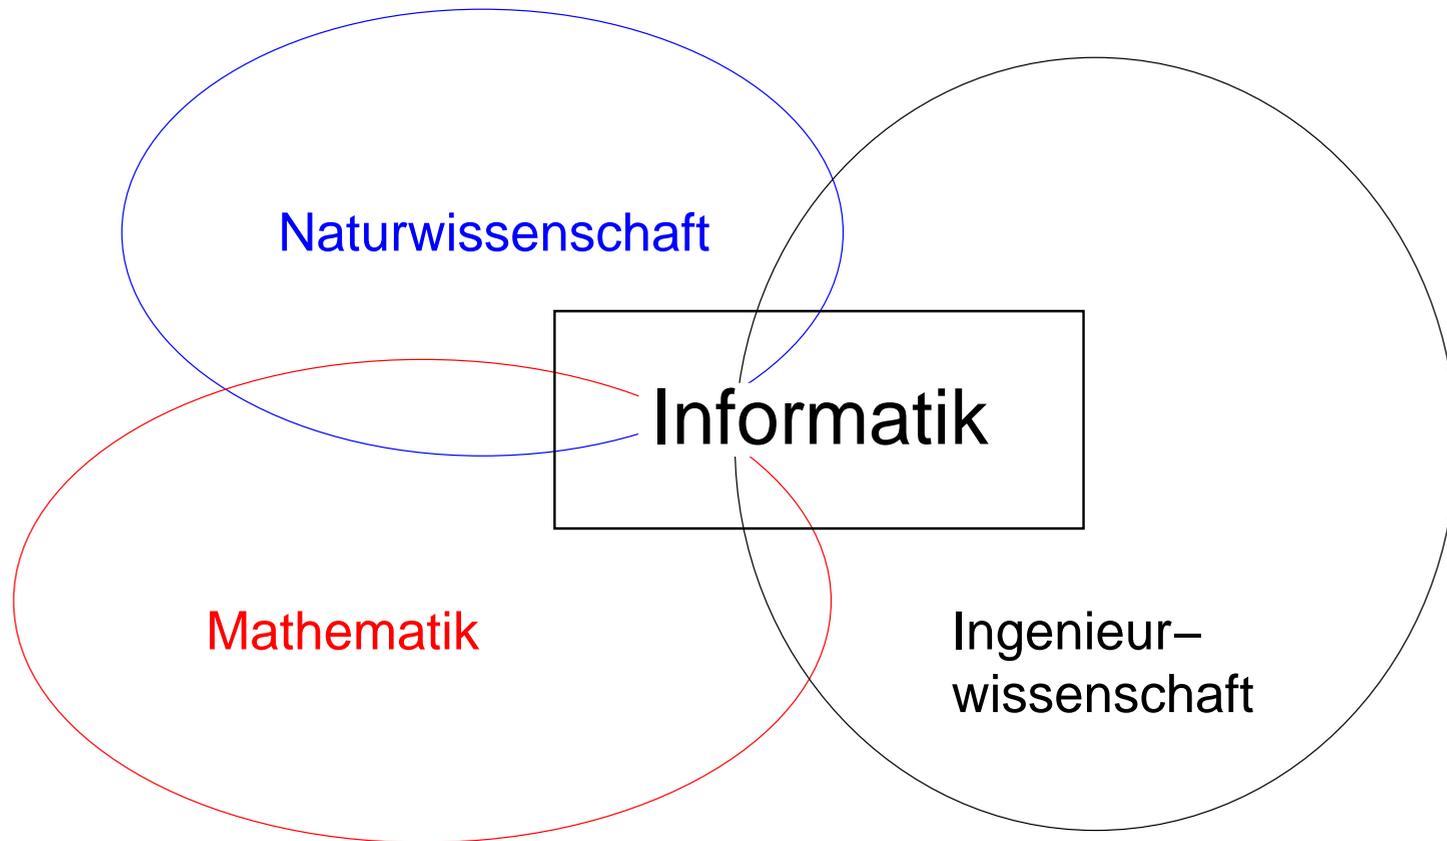
<http://fmv.jku.at>



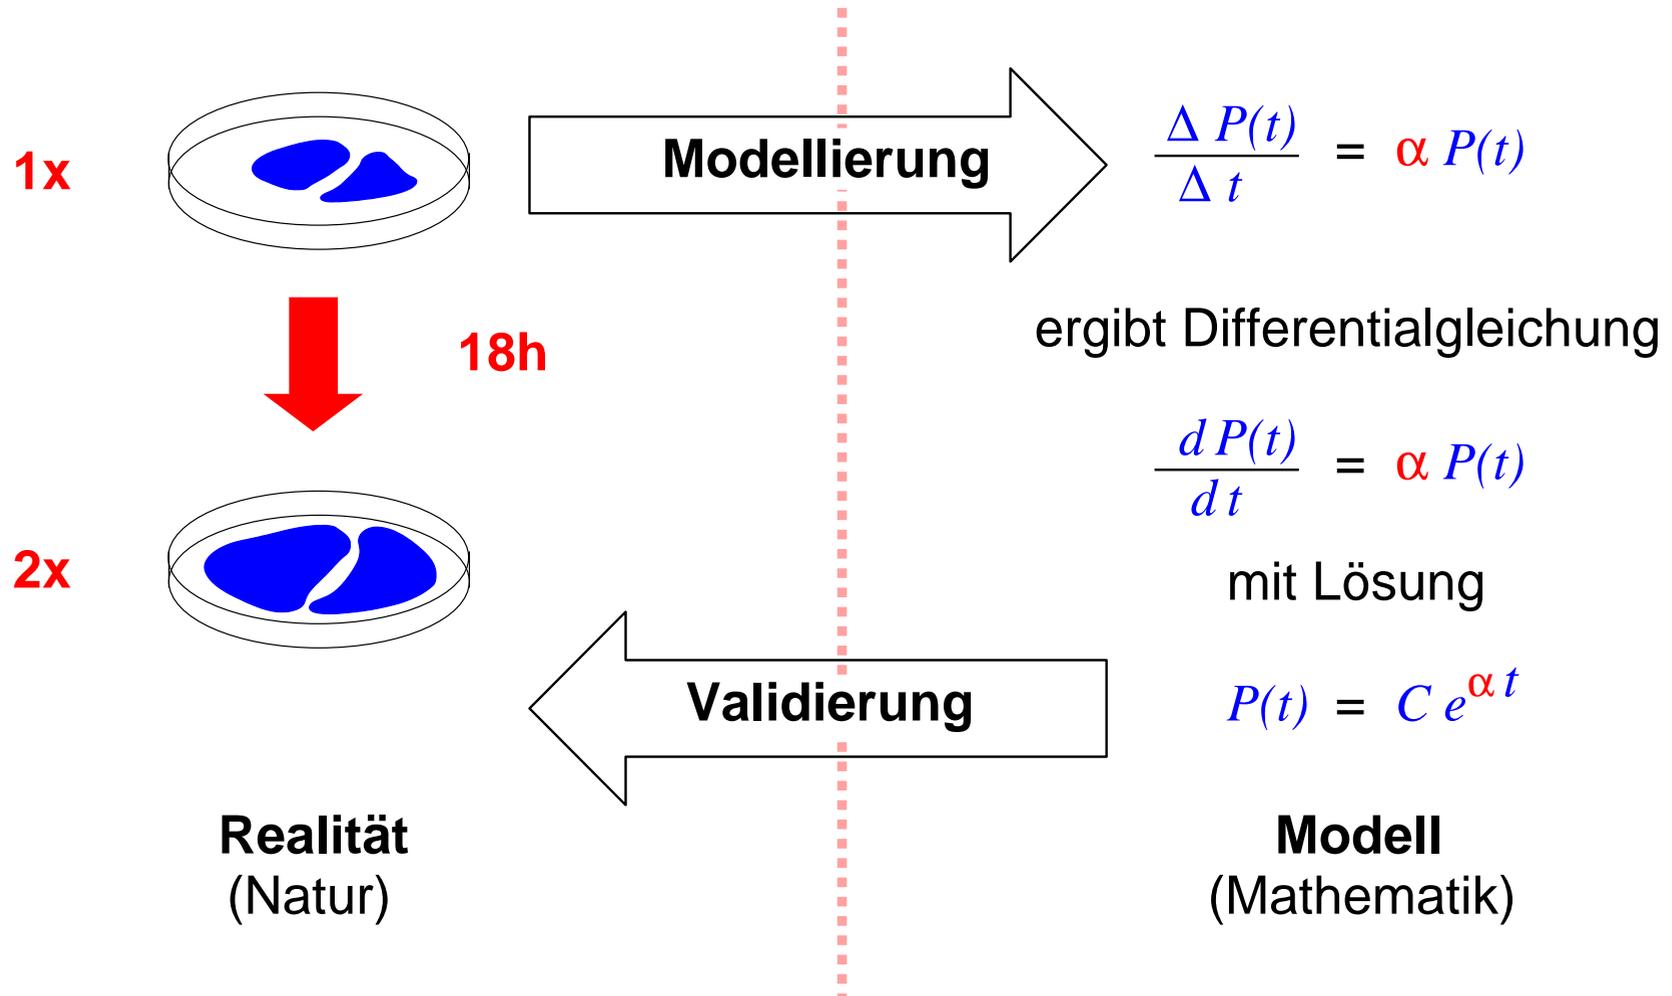


- Formale Grundlagen III (4. Semester)
 - Formale Modellierung von Informatik-Systemen (meist diskret)
- Systemtheorie I (Formale Systeme I, 5. Semester)
 - Algorithmische Aspekte der Verifikation inkl. Simulation im Allgemeinen
- Systemtheorie II (Formale Systeme II, Model Checking, > 5. Semester)
 - Spezifische Algorithmische Aspekte des Model Checking mit SAT

- Formale Methoden als Rückrat der Informatik
 - Abstraktion ist das Kern-Geschäft eines Informatikers
 - Informatik-Systeme **sind** mathematische Gebilde
 - Abstraktionen stellen sich als formale Modelle dar
- Formale Technologien breiten sich in der Praxis aus
 - Simulation abstrakter Modelle zur Validierung oder Optimierung
 - Beispiel: tagtäglicher Gebrauch von Equivalence Checking beim Chip-Design



Größenwachstum einer Bakterienpopulation



- Modellierung und Auswertung von Computer-Modellen
 - von Phänomenen der Natur- aber auch Ingenieurwissenschaften
 - erlaubt Projektion in die Zukunft ...
z.B. **Wettervorhersage**
 - ... und Optimierung, wenn der Mensch eingreifen kann
z.B. **Umkehr der Klima-Erwärmung durch weniger Kohlendioxid-Ausstoß**
- Beschreibung der Zusammenhänge wiederum durch Gleichungen
 - Gleichungen können i.Allg. **nicht geschlossen** gelöst werden
 - Validierung durch Simulation mit numerischen Methoden
- **Computational Science als Teil der Informatik (!?)**

am Beispiel Cocomo nach [Boehm81]

Wieviel kostet die Herstellung eines Programmes einer bestimmter Größe?

$$\text{Applikations-Programme: } PM = 2.4 \cdot (KDSI)^{1.05}$$

$$\text{Hilfs-Programme: } PM = 3.0 \cdot (KDSI)^{1.12}$$

$$\text{System-Programme: } PM = 3.6 \cdot (KDSI)^{1.20}$$

PM = Personen-Monate
(Kosten)

KDSI = Kilo Delivered Source Instructions
(Größe)

Typische Verwendung **empirischer Methoden** gerade im Software Engineering

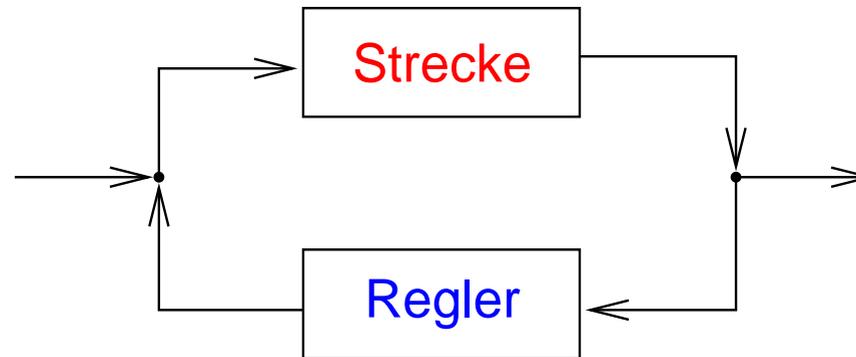
- Gegenstand der Mathematik sind eigentlich keine Modelle
 - die Natürlichen Zahlen sind “einfach da”
Zahlen hat der liebe Gott gemacht, alles andere ist Menschenwerk [Kronecker]
 - keine Interpretation notwendig: Untersuchungsgegenstand = Realität
- Modellbegriff in der Mathematischen Logik
 - Lässt sich Mathematik durch Mathematik exakt modellieren?
Nein, nicht im Allgemeinen [Gödel]
 - gewisse Formalisierung sind dennoch möglich:
eine Vielzahl von Sätzen läßt sich **formal herleiten**
(d.h. durch symbolisches Schließen in einem formalen Kalkül)

- Programme und Digitale Systeme sind formale Objekte
 - besitzen exakte mathematische Modelle (denotational oder operational)
 - Realität = Modell
(modulo komplexer Semantik, Compilerbugs, Hardwareversagen, ...)
 - **Eigenschaften der Modelle gelten auch für die Realität**

- Eigenschaften von Modellen zu beweisen ist aufwendig
 - für Software i.Allg. **unentscheidbar**
 - für Hardware i.Allg. in **NP** oder **PSPACE**

- gilt nur für **Funktionale Eigenschaften**, nicht für **Quantitative Aspekte**
 - Verfügbarkeit, Durchsatz, Latenzzeit etc. sind schwer exakt zu modellieren

Modellierung eines Reglers im Einsatz

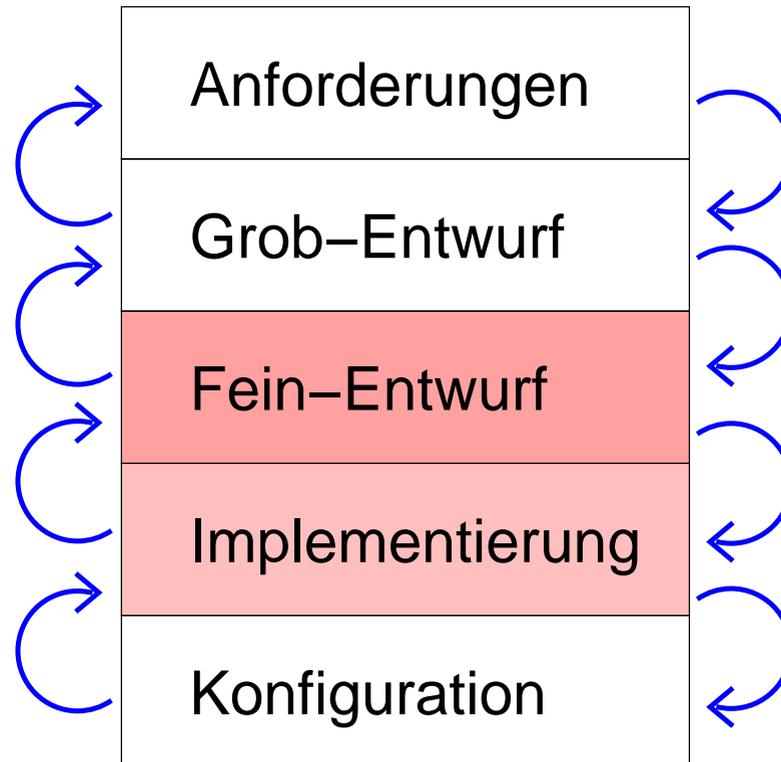


- der Eingriff des Menschen bzw. das technische System wird mitmodelliert
- Modellierung ist Approximation der Realität
 - reales System verhält sich nicht exakt wie das Modell
- Ziel ist Konstruktion und Optimierung des Reglers

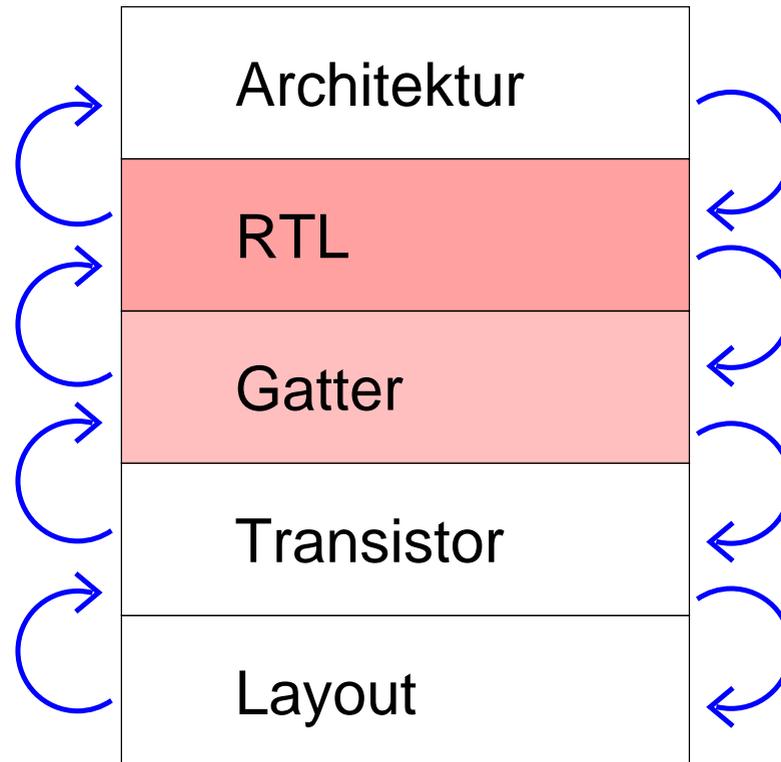
- Ziel ist Konstruktion und Optimierung von **Informatiksystemen**
- Modelle zur **quantitativen** Analyse/Optimierung
 - Warteschlangensysteme, Markov-Chains etc.
 - Simulation von Szenarien
- High-Level Modelle
 - schrittweise Verfeinerung/Synthese (z.B. Code-Erzeugung, Compiler)
 - Beispiel: Model Driven Architecture (MDA) = ausführbare UML Modelle
 - Beispiel: Behavioural Models und Synthesis für Digitale Systeme

- Modelle im Sinne der Naturwissenschaft
 - Computational Science, Modellierung mit dem Computer
- Weitere Empirische Modelle
 - empirische Methoden im Software Engineering
- Mathematische Modelliermethodik
 - Logik als Basis, SW/HW als Formel, Realität = Modell
- High-Level Modelle
 - qualitativ (funktional) oder quantitativ, Verfeinerung/Synthese

am Beispiel Software-Entwurf

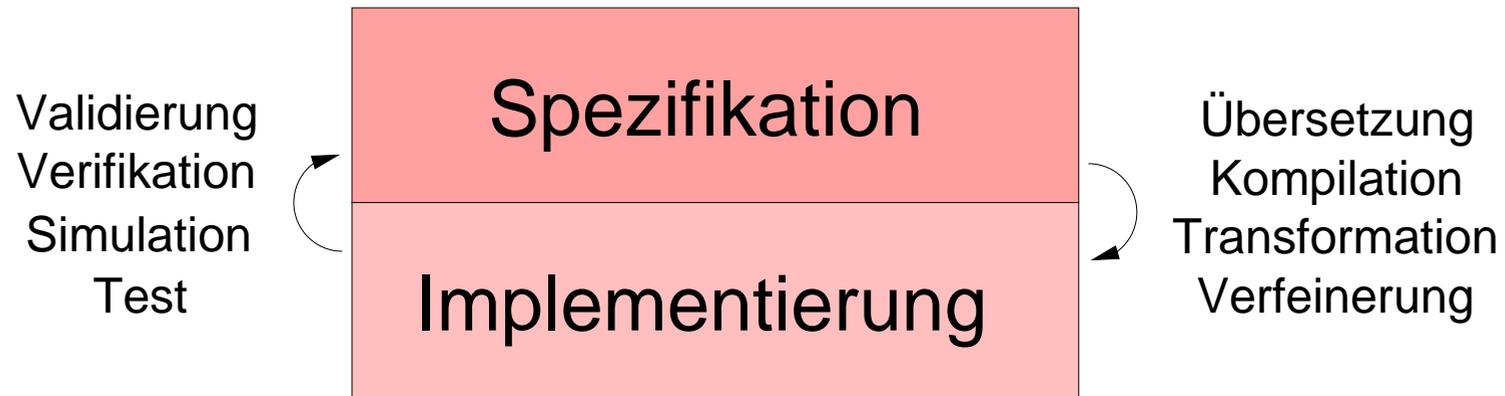


am Beispiel Hardware-Entwurf



Verifikation

Synthese



formal

oder

adhoc

siehe auch Formale Grundlagen 3

Motivation: Automaten für die Modellierung, Spezifikation und Verifikation verwenden!

Definition Ein *Endlicher Automat* $A = (S, I, \Sigma, T, F)$ besteht aus

- Menge von Zuständen S (normalerweise endlich)
- Menge von Initialzuständen $I \subseteq S$
- Eingabe-Alphabet Σ (normalerweise endlich)
- Übergangsrelation $T \subseteq S \times \Sigma \times S$
schreibe $s \xrightarrow{a} s'$ gdw. $(s, a, s') \in T$ gdw. $T(s, a, s')$ "gilt"
- Menge von Finalzuständen $F \subseteq S$

Definition Ein EA A akzeptiert ein Wort $w \in \Sigma^*$ gdw. es s_i und a_i gibt mit

$$s_0 \xrightarrow{a_1} s_1 \xrightarrow{a_2} s_2 \xrightarrow{a_3} \dots \xrightarrow{a_{n-1}} s_{n-1} \xrightarrow{a_n} s_n,$$

wobei $n \geq 0$, $s_0 \in I$, $s_n \in F$ und $w = a_1 \cdots a_n$ ($n = 0 \Rightarrow w = \varepsilon$).

Definition Die Sprache $L(A)$ von A ist die Menge der Wörter die er akzeptiert.

- Benutze Automaten oder reguläre Sprachen zur Beschreibung von Ereignisströmen!
- “Konformität” der Ereignisströme der Implementierung zu denen der Spezifikation!
- Konformität kann präzisiert werden als Teilmengenbeziehung der Sprachen

Definition Der Produkt Automat $A = A_1 \times A_2$ von zwei EA A_1 und A_2 mit gemeinsamen Eingabealphabet $\Sigma_1 = \Sigma_2$ hat folgende Komponenten:

$$S = S_1 \times S_2$$

$$I = I_1 \times I_2$$

$$\Sigma = \Sigma_1 = \Sigma_2$$

$$F = F_1 \times F_2$$

$$T((s_1, s_2), a, (s'_1, s'_2)) \quad \text{gdw.} \quad T_1(s_1, a, s'_1) \text{ und } T_2(s_2, a, s'_2)$$

Satz Seien A , A_1 , und A_2 wie oben, dann $L(A) = L(A_1) \cap L(A_2)$

Beispiel: Konstruktion eines Automaten Wörter mit Prefix ab und Suffix ba akzeptiert.

(als regulärer Ausdruck: $a \cdot b \cdot \mathbf{1}^* \cap \mathbf{1}^* \cdot b \cdot a$, wobei $\mathbf{1}$ für alle Buchstaben steht)

Definition Zu $s \in S$, $a \in \Sigma$ bezeichne $s \xrightarrow{a}$ die Menge der Nachfolger von s definiert als

$$s \xrightarrow{a} = \{s' \in S \mid T(s, a, s')\}$$

Definition Ein EA ist *vollständig* gdw. $|I| > 0$ und $|s \xrightarrow{a}| > 0$ für alle $s \in S$ und $a \in \Sigma$.

Definition ... *deterministisch* gdw. $|I| \leq 1$ und $|s \xrightarrow{a}| \leq 1$ für alle $s \in S$ und $a \in \Sigma$.

Fakt ... deterministisch und vollständig gdw. $|I| = 1$ und $|s \xrightarrow{a}| = 1$ für alle $s \in S$, $a \in \Sigma$.

Definition Der Power-Automat $A = P(A_1)$ eines EA A_1 hat folgende Komponenten

$$S = P(S_1) \quad (P = \text{Potenzmenge})$$

$$I = \{I_1\}$$

$$\Sigma = \Sigma_1$$

$$F = \{F' \subseteq S \mid F' \cap F_1 \neq \emptyset\}$$

$$T(S', a, S'') \text{ gdw. } S'' = \{s'' \mid \exists s' \in S' \text{ mit } T(s', a, s'')\}$$

Satz A, A_1 wie oben, dann $L(A) = L(A_1)$ und A ist deterministisch und vollständig.

Beispiel: Spam-Filter basierend auf der White-List “abb”, “abba”, und “abacus”!

(Regulärer Ausdruck: “abb” | “abba” | “abacus”)

Definition Der Komplementär-Automat $A = K(A_1)$ eines endlichen Automaten A_1 hat dieselben Komponenten wie A_1 , bis auf $F = S \setminus F_1$.

Satz Der Komplementär-Automat $A = K(A_1)$ eines deterministischen und vollständigen Automaten A_1 akzeptiert die komplementäre Sprache $L(A) = \overline{L(A_1)} = \Sigma^* \setminus L(A_1)$.

Beispiel: Spam-Filter basierend auf der Black-List “abb”, “abba”, und “abacus”!

(Regulärer Ausdruck: $\overline{\text{“abb”} \mid \text{“abba”} \mid \text{“abacus”}}$)

- Modellierung und Spezifikation mit Automaten:
 - Ereigniströme einer Implementierung modelliert durch EA A_1
 - Partielle Spezifikation der Ereigniströme als EA A_2
- Konformitäts-Test:
 - $L(A_1) \subseteq L(A_2)$
 - gdw. $L(A_1) \cap \overline{L(A_2)} = \emptyset$
 - gdw. $A_1 \times K(P(A_2))$ keinen erreichbaren Finalzustand hat
- **Beispiel:** Spezifikation $S = (cs | sc | ss)^*$, Implementierung $I = ((s | c)^2)^*$

- Temporale Eigenschaften: (**1** steht für ein beliebiges Zeichen)
 - jeden dritten Schritt gilt a : $(\mathbf{1} \cdot \mathbf{1} \cdot a)^*$
 - genau jeden dritten Schritt gilt a : $(\bar{a} \cdot \bar{a} \cdot a)^*$
 - einem a (acknowledge) muss ein r (request) vorangehen: $\overline{(\bar{r})^* \cdot a}$
 - jedem a muss ein r vorangehen: $\overline{(\mathbf{1}^* \cdot a)^* \cdot (\bar{r})^* \cdot a}$

- Verfeinerung: (am Beispiel Scheduling dreier Prozesse a , b und c)
 - abstrakter Round-Robin Scheduler: $(abc \mid acb \mid bac \mid bca \mid cab \mid cba)^*$
 - Round-Robin Scheduler mit Vorrang a vor b : $(abc \mid acb \mid cab)^*$
 - Round-Robin Scheduler mit Vorrang a vor b und c vor b : $(acb \mid cab)^*$
 - deterministischer Round-Robin Scheduler der Implementierung: $(cab)^*$

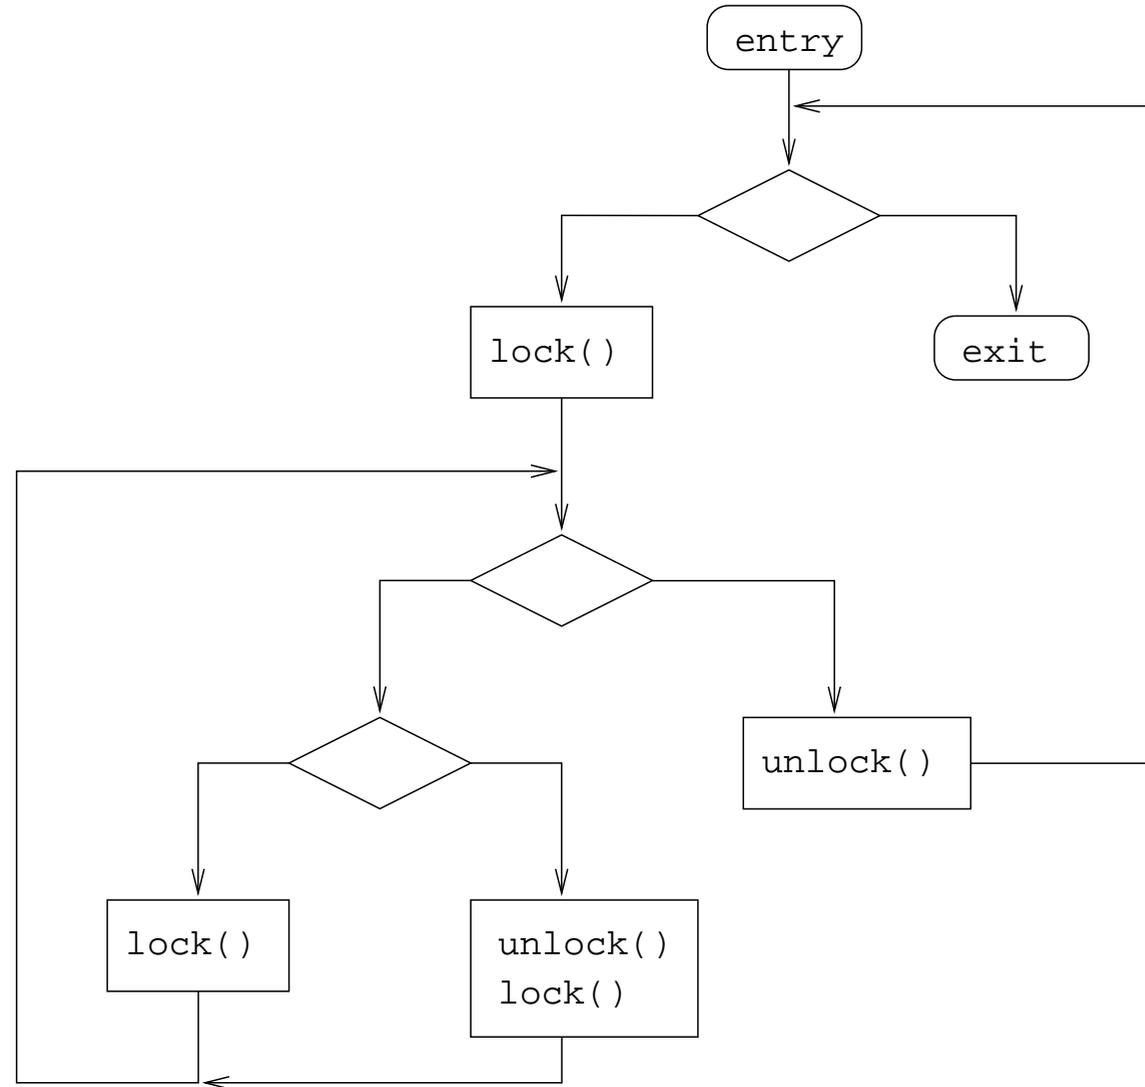
- ähnliche Vorgehensweise:
 - geg. aussagenlogische Formel f über den booleschen Variablen $V = \{x_1, \dots, x_n\}$
 - Expansion $E(f) \subseteq 2^n$ ist die Menge der erfüllenden Belegungen von f
$$(a_1, \dots, a_n) \in E(f) \quad \text{gdw.} \quad f[x_1 \mapsto a_1, \dots, x_n \mapsto a_n] = 1$$
 - z.B. $E(f) \neq \emptyset$ gdw. f erfüllbar (engl. satisfiable)

- Modellierung und Spezifikation:
 - f_1 charakterisiert die für die Implementierung möglichen Konfigurationen
 - f_2 beschreibt eine partielle Spezifikation der gültigen Konfigurationen

- Konformitäts-Test: $f_1 \Rightarrow f_2$ gdw. $E(f_1) \subseteq E(f_2)$ gdw. $E(f_1) \cap \overline{E(f_2)} = \emptyset$
(oder in der Praxis: ... gdw. $f_1 \wedge \neg f_2$ unerfüllbar)

```

while (...) {
  lock ();
  ...
  while (...) {
    if (...) {
      lock ();
      ...
    } else {
      unlock ();
      ...
      lock ();
    }
    ...
  }
  ...
  unlock ();
}
    
```



$$(l \cdot (l \mid u \cdot l)^* \cdot u)^*$$

```
assert (i < n);  
lock ();  
do {  
    ...  
    i++;  
    if (i >= n)  
        unlock ();  
    ...  
} while (i < n);
```

$l \cdot (\varepsilon|u)^*$ verletzt partielle Spezifikation $\overline{\mathbf{1}^* \cdot l \cdot \bar{u}^*}$

(“...” führt weder zu einem lock noch unlock und lässt i und n unberührt)

verfeinerte Abstraktion zu EA durch Einführung einer Prädikats-Variable:

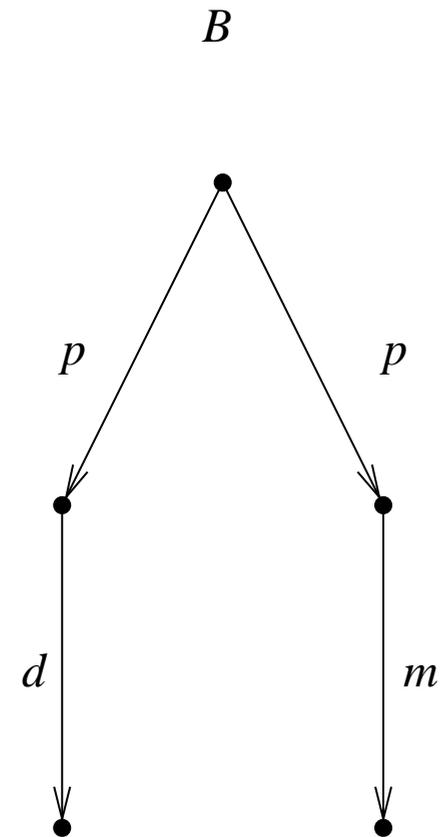
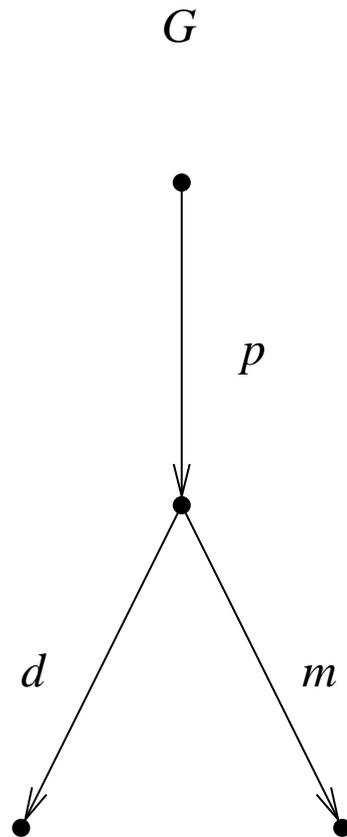
$b == (i < n)$

<pre>assert (i < n); lock (); do { ... i++; if (i >= n) unlock (); ... } while (i < n);</pre>	abstrahiert zu	<pre>assert (b); lock (); do { ... if (b) b = *; if (!b) unlock (); ... } while (b);</pre>
--	----------------	---

$l \cdot \varepsilon^* \cdot u$ erfüllt partielle Spezifikation $\overline{\mathbf{1}^* \cdot l \cdot \bar{u}^*}$

(“...” führt weder zu einem lock noch unlock und lässt i und n unberührt)

- semantisches Modell im Kontext von **Process Algebra**
 - Fokus auf **Reaktive Systeme** oder **Offene Systeme**
 - dabei Konzept der **Umgebung** mit **externen** Ereignissen
 - Implementierung (auf einer Abstraktionsebene) bestimmt die **internen** Ereignisse
- ein LTS $A = (S, I, \Sigma, T)$ ist im wesentlichen ein EA:
 - das Verhalten, die Möglichkeit von Übergängen zählt
 - ohne Final-Menge, d.h. auch ohne “explizite” Sprache
 - “implizite” Sprache $L(A)$ durch $F = S$



p = Einwurf des Geldbetrages (pay)

d = Auswahl und Ausgabe der dunklen Schokolade

m = Auswahl und Ausgabe der Milch-Schokolade

- sicherlich sollte die Semantik der beiden LTS “unterschiedlich” sein
 - G erlaubt nach dem Geldeinwurf Wahl der Schokoladenart
 - B setzt nicht-deterministisch beim Geldeinwurf die Schokoladenart fest
- aber B und G sind **sprachäquivalent**:
 - $L(B) = p \cdot (d \mid m) = L(G)$
- Problem überträgt sich auf Konformitäts-Test:
 - Sprach-basierter Konformitäts-Test identifiziert B und G
 - Sprach-Konformität ignoriert das “Branching-Verhalten”

- Verhalten der Implementierung A_1 sollte gültiges Verhalten der Spezifikation A_2 sein
 - jeder **Übergang** in A_1 hat eine Entsprechung in A_2
 - A_2 **simuliert** A_1
 - A_2 kann möglicherweise mehr
- Vereinfachung der formalen Notation durch Vereinigung zu einem LTS A
 - gemeinsames Alphabet Σ
 - (disjunkte) Vereinigung der anderen Komponenten:
$$S = S_1 \dot{\cup} S_2, I = I_1 \dot{\cup} I_2, T = T_1 \dot{\cup} T_2$$
 - Schreibweise: $A = A_1 \dot{\cup} A_2$

Definition eine Relation $\lesssim \subseteq S \times S$ über LTS A ist eine **Simulation** gdw.

(man liebt $s \lesssim t$ als t simuliert s)

$$s \lesssim t \quad \text{dann} \quad \forall a \in \Sigma, s' \in S [s \xrightarrow{a} s' \Rightarrow \exists t' \in S [t \xrightarrow{a} t' \wedge s' \lesssim t']]$$

Fakt es gibt genau eine maximale Simulation über jedem LTS A

Beweisskizze (S endlich)

- die Vereinigung zweier Simulationen ist wiederum eine Simulation
- die Menge der Simulationen über A ist nicht leer (enthält die Identität)

- Ausgangspunkt: $\approx_0 = S \times S$ (normalerweise keine Simulation)

- verfeinere \approx_i zu \approx_{i+1} wie folgt

$$s \approx_{i+1} t \text{ gdw. } s \approx_i t \text{ und } \forall a \in \Sigma, s' \in S [s \xrightarrow{a} s' \Rightarrow \exists t' \in S [t \xrightarrow{a} t' \wedge s' \approx_i t']]$$

- bei endlichem S gibt es ein n mit $\approx_n = \approx_{n+1}$

- \approx_n ist offensichtlich eine Simulation

- Maximalität schwerer einzusehen

- kann als Fixpunkt-Prozess reformuliert werden

Sei \lesssim eine Simulation. Zeige $\lesssim \subseteq \lesssim_i$ durch Induktion über i .

Induktionsanfang ist trivial, Induktionsschritt folgt.

Annahme (indirekter Beweis): $\lesssim \not\subseteq \lesssim_{i+1}$.

Dann gibt es s und t mit $s \lesssim t$ aber $s \not\lesssim_{i+1} t$.

Somit muss es s' und a geben mit $s \xrightarrow{a} s'$, aber $t \not\xrightarrow{a} t'$ oder $t \not\lesssim_i t'$ für alle t' .

Mit der Induktionshypothese $\lesssim \subseteq \lesssim_i$ folgt: $t \not\xrightarrow{a} t'$ oder $t \not\lesssim_i t'$ für alle t' .

Widerspruch zur Voraussetzung \lesssim Simulation.

Fakt maximale Simulation ist eine Halb-Ordnung (insbesondere transitiv)

Beweisskizze

- Reflexivität siehe vorige Beweisskizze
- Transitivität folgt aus unterem Lemma

Lemma transitive Hülle einer Simulation ist wieder eine Simulation

Beweisskizze folgender Operator erhält die Simulationseigenschaft

$$\Psi: P(S \times S) \rightarrow P(S \times S) \quad \Psi(\lesssim)(r, t) \quad \text{gdw.} \quad r \lesssim t \quad \text{oder} \quad \exists s [r \lesssim s \wedge s \lesssim t]$$

Definition LTS A_2 simuliert LTS A_1 gdw. es eine Simulation \lesssim über $A_1 \cup A_2$ gibt, so dass für jeden Anfangszustand $s_1 \in S_1$ von A_1 , es einen Anfangszustand $s_2 \in S_2$ von A_2 gibt, mit $s_1 \lesssim s_2$. Man schreibt dann auch $A_1 \lesssim A_2$.

Fakt Simulation von LTS ist eine Halb-Ordnung (insbesondere transitiv)

Beweisskizze

- bilde maximale Simulationsrelation über alle drei LTS
- zeige Existenz von simulierenden Anfangszuständen
- Projektion auf äussere LTS liefert gewünschte Simulation

Definition Ein *Trace* eines LTS A ist ein Wort $w = a_1 \cdots a_n \in \Sigma^*$ mit

$$s_0 \xrightarrow{a_1} s_1 \xrightarrow{a_2} \cdots \xrightarrow{a_{n-1}} s_{n-1} \xrightarrow{a_n} s_n,$$

wobei $s_0 \in I$ und $n \geq 0$.

Fakt $L(A) = \{w \mid w \text{ Trace von } A\}$

Satz (Simulation ist eine konservative Abstraktion)

LTS A_2 simuliere A_1 via Simulation \lesssim (also $A_1 \lesssim A_2$), dann gilt $L(A_1) \subseteq L(A_2)$.

Anwendung $P \lesssim A \leq S \Rightarrow L(P) \subseteq L(S)$

(P = Programm, A Abstraktion, S Spezifikation)

Wenn man nur an der Sprache bzw. den Traces interessiert ist, kann man dennoch die Abstraktion immer so konstruieren, dass das Programm simuliert wird.

- $\tau \in \Sigma$ bezeichnet ein nicht beobachtbares *internes Ereignis*

- vorherige Definition der Simulation ist dann eine **starke Simulation**

$$s \lesssim t \quad \text{dann} \quad \forall a \in \Sigma, s' \in S [s \xrightarrow{a} s' \Rightarrow \exists t' \in S [t \xrightarrow{a} t' \wedge s' \lesssim t']]$$

- man schreibe $s \xrightarrow{\tau^* a} t$ falls es s_0, \dots, s_n gibt mit

$$s = s_0 \xrightarrow{\tau} s_1 \xrightarrow{\tau} \dots \xrightarrow{\tau} s_{n-1} \xrightarrow{a} s_n = t$$

- eine Relation \lesssim ist eine **schwache Simulation** gdw.

$$s \lesssim t \quad \text{dann} \quad \forall a \in \Sigma \setminus \{\tau\}, s' \in S [s \xrightarrow{\tau^* a} s' \Rightarrow \exists t' \in S [t \xrightarrow{\tau^* a} t' \wedge s' \lesssim t']]$$

- Man verwende τ für *abstrahierte* Ereignisse
 - z.B. nebensächliche Berechnungen/Datenfluss im Programm
- **τ -bereinigtes LTS** A für ein LTS A_1 mit $\tau: \Sigma = \Sigma_1 \setminus \{\tau\}$, $T(s, t)$ gdw. $s \xrightarrow{\tau^* a} t$ in A_1 .
 - τ -Bereinigung macht aus schwacher Simulation eine starke (und umgekehrt)
 - damit lassen sich die vorherigen Algorithmen auch hier anwenden
- Transitivität und Anwendungen wie im starken Fall
- **Divergenz** $s \xrightarrow{\tau^+} s$ wird noch unzulänglich behandelt
 - $A_1 \lesssim A_2$ erlaubt A_1 divergent und A_2 nicht

Idee: Implementierung des spezifizierten Verhaltens **und nicht mehr!**

Definition eine Relation \approx ist eine **starke Bisimulation** gdw.

$$s \approx t \quad \text{dann} \quad \forall a \in \Sigma, s' \in S [s \xrightarrow{a} s' \Rightarrow \exists t' \in S [t \xrightarrow{a} t' \wedge s' \approx t']] \quad \text{und} \\ \forall a \in \Sigma, t' \in S [t \xrightarrow{a} t' \Rightarrow \exists s' \in S [s \xrightarrow{a} s' \wedge s' \approx t']]$$

Definition eine Relation \approx ist eine **schwache Bisimulation** gdw.

$$s \approx t \quad \text{dann} \quad \forall a \in \Sigma \setminus \{\tau\}, s' \in S [s \xrightarrow{\tau^* a} s' \Rightarrow \exists t' \in S [t \xrightarrow{\tau^* a} t' \wedge s' \approx t']] \quad \text{und} \\ \forall a \in \Sigma \setminus \{\tau\}, t' \in S [t \xrightarrow{\tau^* a} t' \Rightarrow \exists s' \in S [s \xrightarrow{\tau^* a} s' \wedge s' \approx t']]$$

Insbesondere die schwache Bisimulation bei Abstraktion von internen Ereignissen der Implementierung durch τ ist in der Praxis sehr nützlich!

Theorie-Anwendung: bisimulations-äquivalente LTS haben die gleiche Eigenschaften

Geg. deterministischer und vollständiger EA $A = (S, I, \Sigma, T, F)$

- Ausgangspunkt: $\sim_0 = (F \times F) \cup (\overline{F} \times \overline{F})$
 - Partitionierung bezüglich “Endzustands-Flag”
 - Äquivalenzrelation

- verfeinere \sim_i zu \sim_{i+1}

$s \sim_{i+1} t$ gdw. $s \sim_i t$ und

$$\forall a \in \Sigma, s' \in S [s \xrightarrow{a} s' \Rightarrow \exists t' \in S [t \xrightarrow{a} t' \wedge s' \sim_i t']] \quad \text{und}$$

$$\forall a \in \Sigma, t' \in S [t \xrightarrow{a} t' \Rightarrow \exists s' \in S [s \xrightarrow{a} s' \wedge s' \sim_i t']]$$

- Terminierung $\sim_{n+1} = \sim_n$ spätestens für $n = |S|$
- Äquivalenzrelation $\sim = \sim_n$ erzeugt minimalen Automaten A/\sim

Definition Unter *Erreichbarkeitsanalyse* versteht man

- Berechnung aller erreichbaren Zustände
 - Resultat kann explizit oder symbolisch repräsentiert werden
 - wird für weitere Algorithmen oder Optimierung der Systeme benötigt
- Überprüfung, ob gewisse Zustände erreichbar sind
 - entspricht Model Checking von Sicherheitseigenschaften (Safety)

explizit = jeder Zustand/Übergang wird einzeln repräsentiert

symbolisch = Mengen-Repräsentation von Zuständen/Übergängen durch Formeln

	Explizites Modell	Symbolisches Modell
Explizite Analyse	Graphensuche	Explicit Model Checking
Symbolische Analyse	—	Symbolic Model Checking

klassisch: Symbolic MC für HW, explicit MC für SW

(Praxis heute: symbolic und explicit für SW+HW)

- für die Theorie reicht explizite Matrix-Darstellung von T

Übergangsmatrix		0	1	2	3	4	5	6	7
Anfangszustand: 0	0	0	0	1	0	1	0	0	0
	1	0	0	0	1	0	1	0	0
	2	0	0	0	0	1	0	1	0
	3	0	0	0	0	0	1	0	1
	4	1	0	0	0	0	0	1	0
	5	0	1	0	0	0	0	0	1
	6	1	0	0	0	0	0	0	0
	7	0	1	0	1	0	0	0	0

- in der Praxis ist T in einer Modellierungs- oder Programmiersprache beschrieben

```
initial_state = 0;
```

```
next_state = (current_state + 2 * (bit + 1)) % 8;
```

- symbolische Repräsentation kann exponentiell kompakter sein

- Symbolische Travesierung des Zustandraumes
 - von einer Menge von Zuständen werden in einem Schritt die Nachfolger bestimmt
 - Nachfolger werden symbolisch berechnet und repräsentiert
 - legt Breitensuche nahe
 - im allgemeinen schon nicht berechenbar
- Resultat ist eine symbolische Repräsentation aller erreichbaren Zustände
 - z.B. `0 <= state && state < 8 && even (state)`

- symbolische Repräsentation hat oft einen “Paralleloperator”
 - z.B. Produkt von Automaten, der einzelne Automat wird explizit repräsentiert

$$G = K_1 \times K_2$$

- Komponenten des Systems werden separat programmiert

```
process A begin P1 end || process B begin P2 end;
```

- Additives Eingehen der Größe der symbolischen Komponenten
 - Programmgröße des Systems: $|K_1| + |K_2|$, bzw. $|P1| + |P2|$

- Multiplaktives Eingehen der Anzahl Komponentenzustände in Systemzustandszahl:

$$|S_G| = |S_{K_1}| \cdot |S_{K_2}|$$

- offensichtlich bei sequentieller Hardware:
 - n -Bit Zähler läßt sich mit $O(n)$ Gattern implementieren, hat aber 2^n Zustände
- Hierarchische Beschreibungen führen zu einem weiteren exponentiellen Faktor
- bei Software noch komplexer:
 - in der Theorie nicht primitiv rekursiv (siehe Ackerman-Funktion)
 - in der Praxis ist der Heap (dynamisch allozierte Objekte) das Problem

- explizite Repräsentation reduziert sich auf Graphensuche
 - suche erreichbare Zustände von den Anfangszuständen
 - linear in der Grösse **aller** Zustände
- symbolische Modellierung
 - Berechnung der Nachfolger eines Zustandes ist das Hauptproblem
 - **on-the-fly** Expansion von T für einen konkreten erreichten Zustand
 - damit Vermeidung der Berechnung von T für unerreichbare Zustände
 - alternativ symbolische Berechnung/Repräsentation der Nachfolgezustände

- Markiere besuchte Zustände
 - Implementierung abhängig davon, ob Zustände **On-the-fly** generiert werden
- Unmarkierte Nachfolger besuchter Zustände kommen auf den Suchstack
- Nächster zu bearbeitender Zustand wird oben vom Stack genommen
- Falls “Fehlerzustand” erreicht wird hat man einen Weg dorthin
 - der Pfad bzw. Fehlertrace findet sich auf dem Stack
 - der Einfachheit wegen breche die Suche ab

```
recursive_dfs_aux (Stack stack, State current)
{
    if (marked (current))
        return;

    mark (current);
    stack.push (current);

    if (is_target (current))
        stack.dump_and_exit ();    /* target reachable */

    forall successors next of current
        recursive_dfs_aux (stack, next);

    stack.pop ();
}
```

```
recursive_dfs ()
{
    Stack stack;

    forall initial states state
        recursive_dfs_aux (stack, state);

    /* target not reachable */
}
```

- Abbruch beim Erreichen des Zieles ist schlechter Programmierstil!
- Effizienz verlangt nicht-rekursive Variante
- Markieren sollte durch Hashen ersetzt werden
 - damit Zustände on-the-fly *erzeugt* werden können

```
#include <stdio.h>

void
f (int i)
{
    printf ("%d\n", i);
    f (i + 1);
}

int
main (void)
{
    f (0);
}
```

dieses C-Programm stürzt nach “wenigen” Rekursionsschritten ab

```
non_recursive_dfs_aux (Stack stack)
{
  while (!stack.empty ())
  {
    current = stack.pop ();
    if (is_target (current))
      dump_family_line_and_exit (current);
    forall successors next of current
    {
      if (cached (next)) continue;
      cache (next);
      stack.push (next);
      next.set_parent (current);
    }
  }
}
```

```
non_recursive_dfs ()
{
    Stack stack;

    forall initial states state
        stack.push (state);

    non_recursive_dfs_aux (stack);

    /* target not reachable */
}
```

```
non_recursive_buggy_dfs_aux (Stack stack)
{
  while (!stack.empty ())
  {
    current = stack.pop ();
    if (is_target (current))
      dump_family_line_and_exit (current);
    if (cached (current)) continue;
    cache (current);
    forall successors next of current
    {
      stack.push (next);
      next.set_parent (current);
    }
  }
}
```

```
non_recursive_but_also_buggy_aux (Stack stack)
{
  while (!stack.empty ())
  {
    current = stack.pop ();
    forall successors next of current
    {
      if (cached (next)) continue;
      cache (next);
      stack.push (next);
      next.set_parent (current);
      if (is_target (next))
        dump_family_line_and_exit (next);
    }
  }
}
```

```
bfs_aux (Queue queue)
{
  while (!queue.empty ())
  {
    current = queue.dequeue ();
    if (is_target (current))
      dump_family_line_and_exit (current);
    forall successors next of current
    {
      if (cached (next)) continue;
      cache (next);
      queue.enqueue (next);
      next.set_parent (current);
    }
  }
}
```

```
bfs ()
{
    Queue queue;

    forall initial states state {
        cache (state);
        queue.enqueue (state);
    }

    bfs_aux (queue);

    /* target not reachable */
}
```

- Tiefensuche
 - einfach rekursiv zu implementieren
(was man aber sowieso nicht sollte)
 - erlaubt Erweiterung auf Zyklenerkennung \Rightarrow Liveness
- Breitensuche
 - erfordert nicht-rekursive Formulierung
 - kürzeste Gegenbeispiele
 - * findet immer kürzesten Pfad zum Ziel

- Vorwärtstraversierung bzw. Vorwärtsanalyse
 - Nachfolger sind die als nächstes zu betrachtenden Zustände
 - analysierte Zustände sind alle erreichbar

- Rückwärtstraversierung bzw. Rückwärtsanalyse
 - Vorgänger sind die als nächstes zu betrachtenden Zustände
 - manche untersuchten Zustände können unerreichbar sein
 - meist nur in Kombination mit symbolischen Repräsentationen von Zuständen
 - symbolische Darstellungen bei Rückwärtsanalyse meist “zufällig” und komplex
 - **manchmal terminiert Rückwärtsanalyse in wenigen Schritten**

- Globale Analyse
 - anwendbar auf Rückwärts- oder Vorwärtstraversierung
 - arbeitet mit *allen* globalen Zuständen (inklusive nicht erreichbaren)
 - Kombination mit expliziter Analyse skaliert sehr schlecht
- Lokale oder On-The-Fly Analyse
 - arbeitet nur auf den erreichbaren Zuständen
 - generiert und analysiert diese on-the-fly ausgehend von Anfangszuständen
- gemischte Vorgehensweise möglich:
 - bestimme vorwärts erreichbare Zustände, darauf dann globale Analysen

```
process A {  
  int count;  
  run() {  
    while (true)  
      if (b.count != this.count)  
        count = (count + 1) % (1 << 20);  
  }  
}
```

```
process B {  
  int count;  
  run() {  
    while (true)  
      if (a.count == this.count)  
        count = (count + 1) % (1 << 20);  
  }  
}
```

A a;

B b;

- bei globaler Analyse wird jedem Zustand ein *Markierungsbit* hinzugefügt

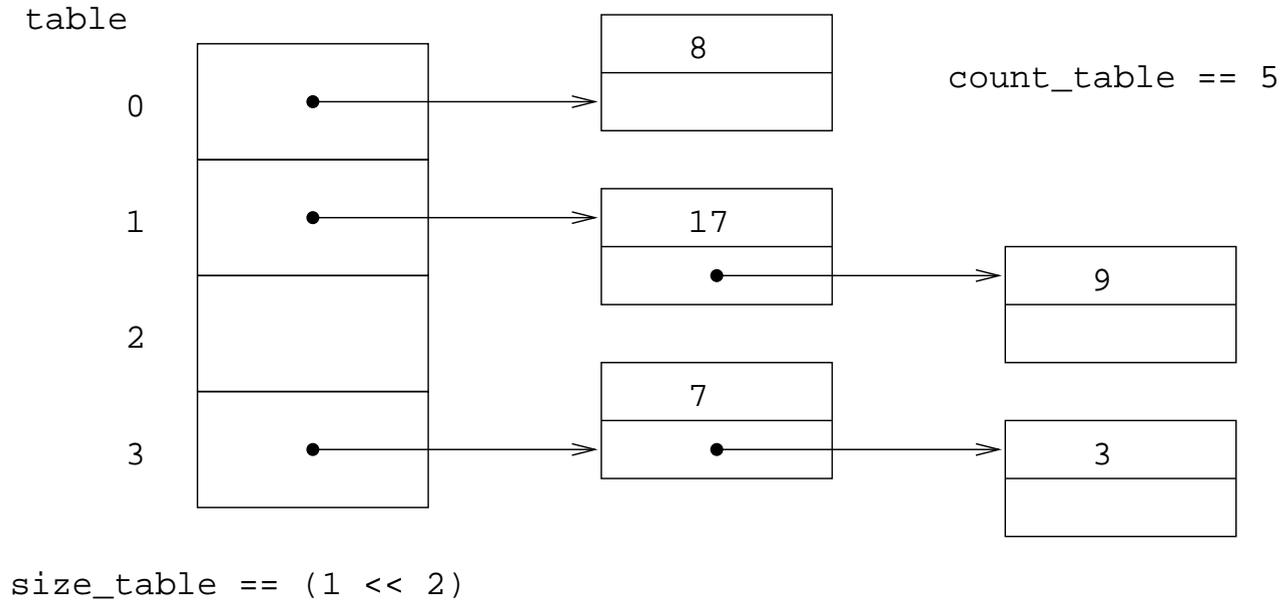
```
bool cached (State state) { return state.mark; }
```

```
void cache (State state) { state.mark = true; }
```

- bei globaler Analyse **ohne** On-the-fly Zustandsgenerierung
 - $2^{64} = 2^{32} \cdot 2^{32}$ **mögliche** Zustände können nicht vorab alloziert werden
- bei lokaler Analyse **mit** On-the-fly Zustandsgenerierung
 - $2 \cdot 2^{20} = 2097152$ **erreichbare** Zustände
 - ergeben 8-fache Menge an Bytes ≈ 16 MB
 - (plus Overhead diese zu Speichern, $<$ Faktor 2)

- Anforderungen an Datenstruktur zur Speicherung von Zuständen:
 - besuchte Zustände müssen markiert/gespeichert werden (cache)
 - ⇒ pro neuem Zustand eine Einfügeoperation
 - neue Nachfolger werden auf “schon besucht” getestet (cached)
 - ⇒ pro Nachfolger eine Suche auf Enthaltensein
- Alternative Implementierungen:
 - Bit-Set: pro *möglichem* Zustand ein Bit (im Prinzip wie bei globaler Analyse)
 - Suchbäume: Suche/Einfügen logarithmisch in Zustandsanzahl
 - **Hashtabelle:** Suche/Einfügen konstant in Zustandsanzahl

- Laufzeit kann als konstant angesehen werden
 - in der Theorie weit komplexere Analyse notwendig
- “gute” Hashfunktion ist das Wesentliche
 - Randomisierung bzw. Verteilung der Eingabebits auf Hashindex
- Anpassung der Grösse der Hashtabelle:
 - entweder durch dynamische (exponentielle) Vergrößerung
 - oder Maximierung und Anpassung an den verfügbaren Speicher



```
unsigned hash (unsigned data) { return data; }
```

```
struct Bucket *  
find (unsigned data)  
{  
    unsigned h = hash (data);  
    h &= (size_table - 1);  
    ...  
}
```

```
unsigned
bad_string_hash (const char * str)
{
    const char * p;
    unsigned res;

    res = 0;

    for (p = str; *p; p++)
        res += *p;

    return res;
}
```

```
unsigned
very_bad_string_hash (const char * str)
{
    const char * p;
    unsigned res;

    res = 0;

    for (p = str; *p; p++)
        res = (res << 4) + *p;

    return res;
}
```

[Dragonbook]

```
unsigned
classic_string_hash (const char *str)
{
    unsigned res, tmp;
    const char *p;

    res = 0;

    for (p = str; *p; p++)
        {
            tmp = res & 0xf0000000;    /* unsigned 32-bit */
            res <<= 4;
            res += *p;
            if (tmp)
                res ^= tmp >> 28;
        }

    return res;
}
```

- empirisch sehr gute Randomisierung bei Bezeichnern von Programmiersprachen
 - relative Anzahl Kollisionen als Maßzahl für die Qualität
- **schnell:** maximal 4 logisch/arithmetische Operationen pro Zeichen
- bei längeren Strings von 8 Zeichen und mehr gute Bit-Verteilung
- Überlagerung der 8-Bit Kodierungen der einzelnen Zeichen
(man beachte aber die ASCII Kodierung)
- Klustering bei vielen kurzen Strings (z.B. in automatisch generiertem Code)

`n1, ..., n99, n100, ..., n1000`

```
static unsigned primes [] = { 2000000011, 2000000033, ... };  
#define NUM_PRIMES (sizeof (primes) / sizeof (primes[0]))
```

```
unsigned
```

```
primes_string_hash (const char * str)
```

```
{  
    unsigned res, i;  
    const char * p;  
  
    i = 0;  
    res = 0;  
    for (p = str; *p; p++)  
    {  
        res += *p * primes[i++];  
        if (i >= NUM_PRIMES)  
            i = 0;  
    }  
  
    return res;  
}
```

```
static unsigned primes [] = { 2000000011, 2000000033, ... };  
#define NUM_PRIMES (sizeof(primes)/sizeof(primes[0]))
```

```
unsigned
```

```
hash_state (unsigned * state, unsigned words_per_state)
```

```
{
```

```
    unsigned res, i, j;
```

```
    res = 0;
```

```
    i = 0;
```

```
    for (j = 0; j < words_per_state; j++)
```

```
    {
```

```
        res += state[j] * primes [i++];
```

```
        if (i >= NUM_PRIMES)
```

```
            i = 0;
```

```
    }
```

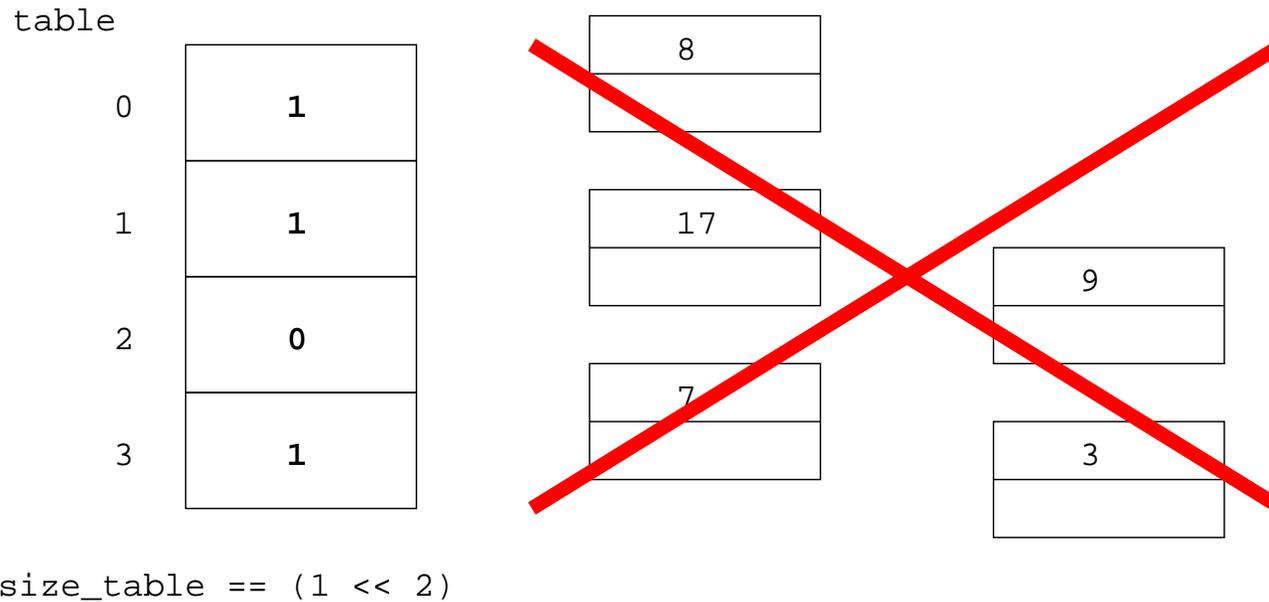
```
    return res;
```

```
}
```

```
#define CRC_POLYNOMIAL 0x82F63B78
static unsigned
crc_hash_bit_by_bit (const char * str)
{
    unsigned const char * p;
    unsigned res = 0;
    int i, bit;
    for (p = str; *p; p++) {
        res ^= *p;
        for (i = 0; i < 8; i++) {
            bit = res & 1;
            res >>= 1;
            if (bit)
                res ^= CRC_POLYNOMIAL;
        }
    }
    return res;
}
```

- lässt sich leicht parametrisieren
 - durch verschiedene Primzahlen oder Anfangspositionen
- heutzutage ist Integer-Multiplikation sehr schnell
 - durch mehr Platz für die Multiplizierer auf der ALU
 - und durch Vorhandensein mehrerer Integer-Functional Units
- was noch fehlt ist Anpassung an Tabellengröße
 - bei Zweierpotenzgröße: einfache Maskierung
 - sonst Primzahlgröße und Anpassung durch Modulo-Bildung

- Probleme mit expliziter **vollständiger** Zustandsraum-Exploration:
 1. wegen Zustandsexplosion oft zu viele Zustände
 2. ein einziger Zustand braucht oft schon viel Platz (dutzende Bytes)
- Ideen des Super-Trace Algorithmus:
 1. behandle Zustände mit demselben Hash-Wert als identisch
 2. speichere nicht die Zustände, sondern Hash-Werte erreichter Zustände
- Super-Trace wird auch **Bit-State-Hashing** genannt

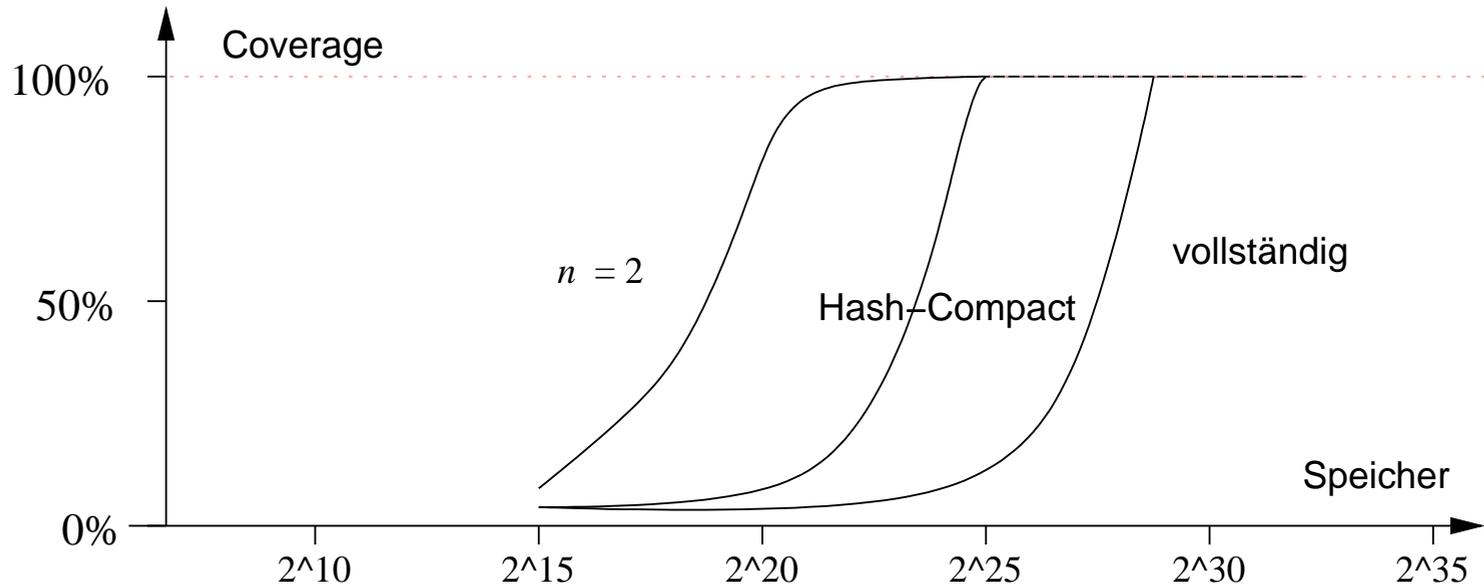


Falls Zustand mit gleichem Hash-Wert früher schon besucht wurde, dann gilt momentaner Zustand als besucht!

- Vorteile:
 - drastische Reduktion des Speicherplatzes auf ein Bit pro Zustand
 - Reduktion um mindestens 8 mal Größe des Zustandes in Bytes
 - Anpassung der Größe der Hash-Tabelle/Bit-Set an vorhandenen Speicher
 - Ausgabe einer unteren Schranke der Anzahl besuchten Zustände
 - Parametrisierung der Hash-Funktion erlaubt unterschiedliche Exploration
- Nachteile:
 - bei nicht-kollisionsfreier Hash-Funktion (der Normalfall) Verlust der Vollständigkeit
 - nur vage Aussage über Abdeckung möglich

- berechne zwei Hashwerte mit unterschiedlichen Hashfunktionen
 - Speichern von Zuständen durch Eintrag jeweils eines Bits in zwei Hashtabellen
 - Zustand wird als schon erreicht angenommen gdw. beide Bits gesetzt
 - z.B. $h_1, h_2: Keys \rightarrow \{0, \dots, 2^{32} - 1\}$
 - zwei Hashtabellen mit jeweils 2^{32} Bits = 2^{29} Bytes = 512 MB
- lässt sich auch leicht auf n Hashfunktionen ausbauen
 - $n = 4$ mit 2 GB Speicher für Hashtabellen ist durchaus realistisch
 - vergl. Parameterisierung der Hashfunktion basierend auf Primzahlmultiplikation

- statt n Bits zu setzen kann man auch einfach den n -Bit Hash-Wert speichern
 - bei 256 MB = 2^{28} Bytes Platz für die Hashtabelle bis zu 2^{26} Hashwerte/Zustände (32-Bit Hashfunktion $h: Keys \rightarrow \{0, \dots, 2^{32} - 1\}$, 4 Bytes Hashwert pro Zustand)
- beliebige Varianten ergeben ungefähr folgendes Bild:



(schematisch nach [Holzmann 1998], 427567 erreichbare Zustände, 1376 Bits)

- Idealisierte Best-Case Annahmen:
 - verwendete Hash-Funktion ist möglichst kollisionsfrei
 - Hashtabelle wird solange wie möglich ohne Kollisionen gefüllt
- m Speicherplatz in Bits, s Zustandsgrösse in Bits, r erreichbare Zustände

$$coverage_{n=2}(m) = \frac{m}{r \cdot 2}$$

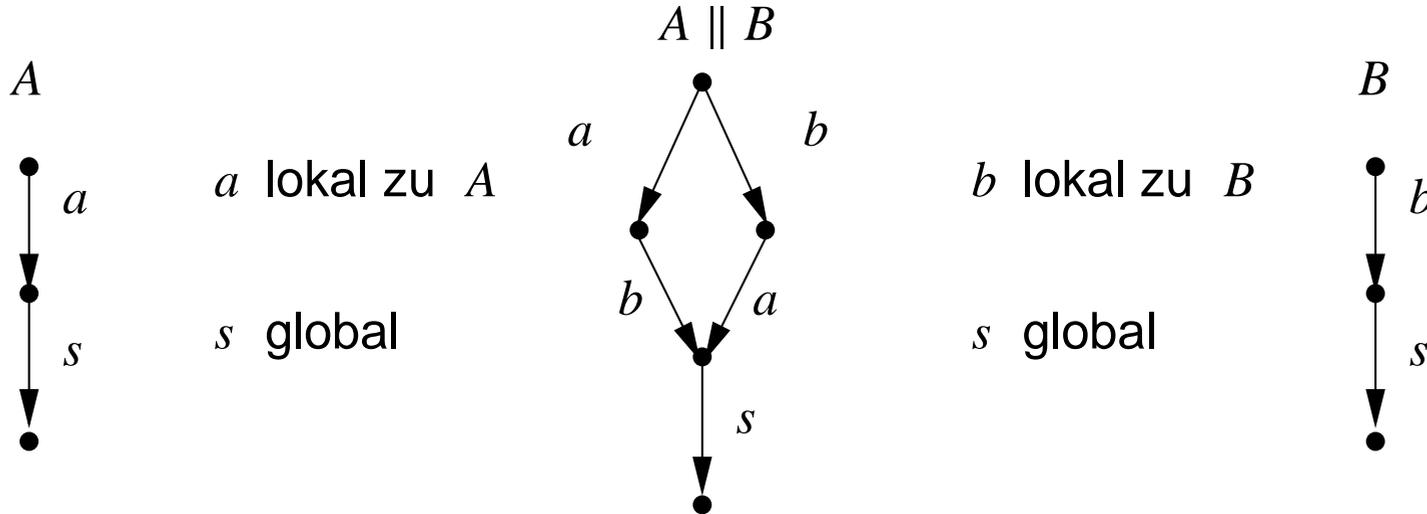
$$coverage_{\text{hashcompact}}(m) = \frac{m}{r \cdot w} \quad w = \text{Wordgröße in Bits, z.B. 32 Bit, } w \leq \lceil \log_2 r \rceil$$

$$coverage_{\text{complete}}(m) = \frac{m}{r \cdot s}$$

(im vorigen Schaubild ist die x-Achse logarithmisch dargestellt)

- in der Praxis gibt es Kollisionen und die unvollständigen brauchen mehr Speicher

- Synchrone Komposition
 - Gleichschritt aller Komponenten zu einem globalen Takt
 - entspricht der Konstruktion des Produkt-Automaten
 - typische Modellierung von Sequentieller **Hardware**
(obwohl auf Transistor-Ebene eigentlich alles asynchron)
- Asynchrone Komposition
 - Komponenten laufen im Wesentlichen unabhängig nach eigenem Takt
 - typische Modellierung für Kommunikationsprotokolle und Verteilte **Software**
 - Synchronisation: Systemcalls/Interrupts/Signale/Nachrichten/Kanäle/RPC
 - geeignete Vereinfachung: **Interleaving**



- jeder Prozess kommt **abwechselnd** dran mit seinen **lokalen** Aktionen
- auf **globale** Aktionen wird per **Rendezvous** synchronisiert
- Standard-Parallel-Komposition in Prozess-Algebra

Definition Zu zwei LTS A_1 und A_2 besteht die parallele Komposition $A = A_1 \parallel A_2$ aus folgenden Bestandteilen:

$S = S_1 \times S_2$, $\Sigma = \Sigma_1 \cup \Sigma_2$, $I = I_1 \times I_2$, T wird wie folgt definiert:

$s \xrightarrow{a} s'$ in A_1 und $t' = t$ falls $a \in \Sigma \setminus \Sigma_2$

$(s, t) \xrightarrow{a} (s', t')$ in A gdw. $t \xrightarrow{a} t'$ in A_2 und $s' = s$ falls $a \in \Sigma \setminus \Sigma_1$

$s \xrightarrow{a} s'$ in A_1 und $t \xrightarrow{a} t'$ in A_2 falls $a \in \Sigma_1 \cap \Sigma_2$

Interleaving mit Synchronisation auf gemeinsamen Aktionen

Definition In $A_1 \parallel A_2$ ist ein Symbol a **lokal** für A_i gdw. $a \in \Sigma_i$ und $a \notin \Sigma_j$ für alle $i \neq j$. Die Menge der lokalen Symbole für A_i wird mit Λ_i bezeichnet.

Definition Ein Symbol heißt **lokal** falls es lokal für ein A_i ist. Allen lokalen Symbole sind in $\Lambda = \bigcup \Lambda_i$ zusammengefasst.

Definition Übergang $(s_1, s_2) \xrightarrow{a} (s'_1, s'_2)$ in $A_1 \parallel A_2$ ist lokal (für A_i), falls a lokal (für A_i).

Definition **Globale** Symbole bzw. Übergänge sind solche, die nicht lokal sind. Die Menge der globalen Symbole zu A_i wird mit Γ_i bezeichnet und deren Zusammenfassung als $\Gamma = \bigcup \Gamma_i$.

Falls $i = 1$ so sei $\sigma(i) = 2$ und umgekehrt.

Fakt $(s_1, s_2) \xrightarrow{a} (s'_1, s'_2)$ in A gdw.

$s_i \xrightarrow{a} s'_i$ in A_i und $s'_{\sigma(i)} = s_{\sigma(i)}$	falls a lokal für A_i
$s_j \xrightarrow{a} s'_j$ in A_j für alle $j = 1, 2$	falls a global

Fakt Die asynchrone parallele Komposition \parallel ist assoziativ.

(die Schreibweise $A_1 \parallel A_2 \parallel \dots \parallel A_n$ ist also wohldefiniert)

Fakt ... und kommutativ modulo Bisimulation: $A_1 \parallel A_2 \approx A_2 \parallel A_1$

Fakt Für die Übergangsrelation von $A_1 \parallel A_2 \parallel \dots \parallel A_n$ gilt:

Sei $\Psi(a) \subseteq \{1, \dots, n\}$ die Menge der Indizes i mit $a \in \Sigma_i$ und $\overline{\Psi(a)}$ deren Komplement.

$(s_1, \dots, s_n) \xrightarrow{a} (s'_1, \dots, s'_n)$ gdw. $s_i \xrightarrow{a} s'_i$ für alle $i \in \Psi(a) \neq \emptyset$ und $s'_j = s_j$ für alle $j \in \overline{\Psi(a)}$.

Definition Zu zwei LTS A_1 und A_2 besteht die *voll asynchrone* parallele Komposition $A = A_1 ||| A_2$ aus folgenden Bestandteilen:

$S = S_1 \times S_2$, $\Sigma = P(\Sigma_1 \cup \Sigma_2)$, $I = I_1 \times I_2$, T wird wie folgt definiert:

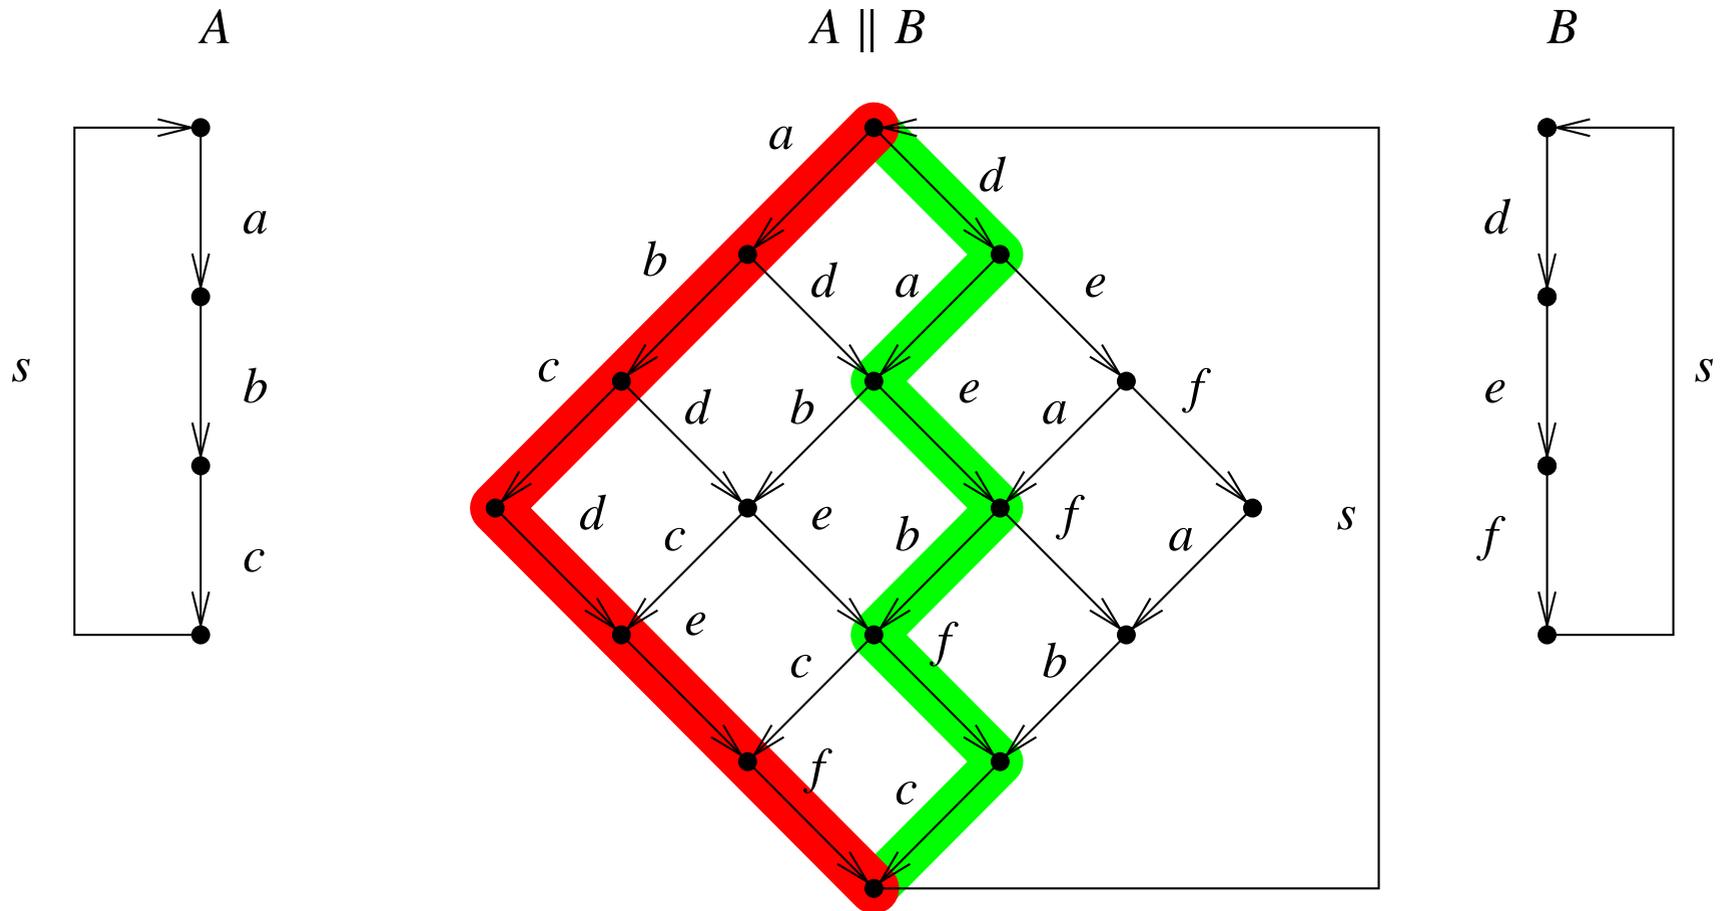
$s \xrightarrow{a} s'$ in A_1 und $t' = t$ falls $M = \{a\} \subseteq \Sigma_1 \setminus \Sigma_2$

$t \xrightarrow{b} t'$ in A_2 und $s' = s$ falls $M = \{b\} \subseteq \Sigma_2 \setminus \Sigma_1$

$(s, t) \xrightarrow{M} (s', t')$ in A gdw. $s \xrightarrow{a} s'$ in A_1 und $t \xrightarrow{a} t'$ in A_2 falls $M = \{a\} \subseteq \Sigma_1 \cap \Sigma_2$

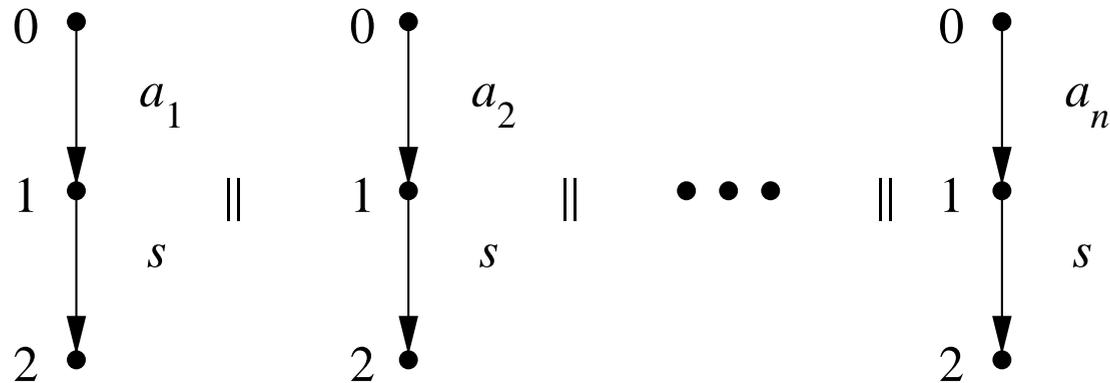
$s \xrightarrow{a} s'$ in A_1 und $t \xrightarrow{b} t'$ in A_2 falls $a \in \Sigma_1 \setminus \Sigma_2$
und $b \in \Sigma_2 \setminus \Sigma_1$
und $M = \{a, b\}$

- Erweiterung der Vollen Asynchronen Komposition auf n LTS:
 - $\Sigma = P(\Sigma_1 \cup \dots \cup \Sigma_n)$, $T = \dots$
(Möglichkeit der gleichzeitigen Synchronisation auf mehrere globale Symbole)
 - insgesamt also exponentielles Aufblasen des Alphabetes!
- Interleaving ist eine Vereinfachung
 - **Fakt** gleiche Menge erreichbarer Zustände
 - Länge von Pfaden zwischen zwei Zuständen kann sich unterscheiden, aber ...
 - ... Modellierung nicht exakt bez. relativer Geschwindigkeit von Komponenten



Idee Verfolge nur einen der 8 möglichen Pfade, z.B. den roten oder den grünen

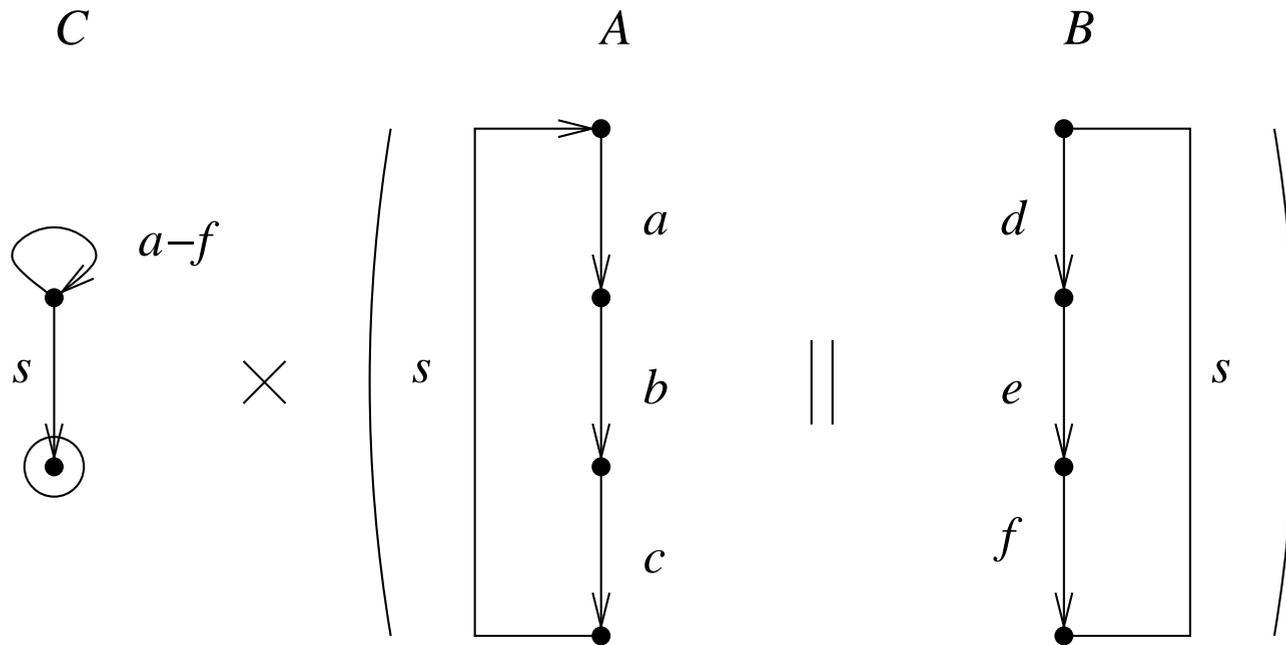
$$\Sigma_i = \{a_i, s\}, \quad \Sigma = \{a_1, \dots, a_n, s\}, \quad \Lambda_i = \{a_i\}, \quad \Gamma = \Gamma_i = \{s\}$$



Anzahl Zustände: $|S| = |\{0, 1, 2\}^n| = 3^n.$

Anzahl erreichbarer Zustände: $|\{0, 1\}^n \cup \{2\}^n| = 2^n + 1$

Anzahl notwendiger Zustände: $|(1^*0^* \cap \{0, 1\}^n) \cup \{2\}^n| = (n + 1) + 1$

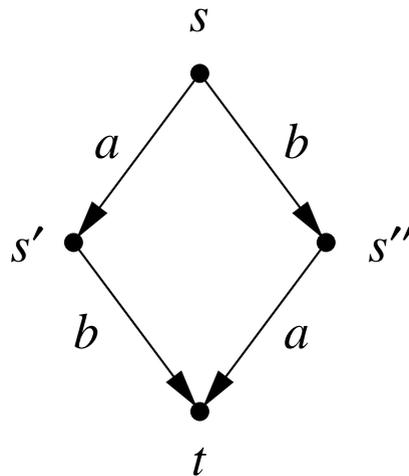


$$C \times (A \parallel B)$$

- Checker muss “invariant” gegenüber weggelassenen Übergängen sein
 - Auslassen von Übergängen darf Erreichen von Finalzuständen nicht verhindern
 - Reduktion ist abhängig vom Checker!
- Maximal viele Übergänge wegzulassen geht nicht:
 - nur möglich wenn man schon die Erreichbarkeit von Finalzuständen kennt
 - damit wäre kein Gewinn möglich!
- Ziel ist möglichst einfaches Kriterium zum Weglassen von Übergängen
 - welches im besten Fall statisch überprüft werden kann
 - oder effizient dynamisch während der Suche

Definition Ein Zustand $s = (s_1, \dots, s_n)$ in $A_1 \parallel \dots \parallel A_n$ heißt **lokal** zu A_i gdw. alle Übergänge in A_i ausgehend von s_i lokal für A_i sind und ein solcher existiert.

Definition Ein Symbol a kommutiert mit dem Symbol b im Zustand s gdw. es für alle s', s'' mit $s \xrightarrow{a} s'$ und $s \xrightarrow{b} s''$ einen Zustand t gibt, mit $s' \xrightarrow{b} t$ und $s'' \xrightarrow{a} t$.



Fakt Sei s lokal zu A_i , dann kommutieren alle Λ_i mit allen andere $\Sigma \setminus \Lambda_i$.

Partial Order Reduction = Partielle Ordnungs-Reduktion

Definition Eine *Expansion* eines Zustandes ist eine Teil-Menge seiner Nachfolger.

BFS/DFS iteriert nur noch über die Expansion von `current` in der inneren Schleife

```
partial_order_recursive_dfs_aux (Stack stack, State current)
{
    ...

    forall next in expansion (current)
        partial_order_recursive_dfs_aux (stack, next);

    ...
}
```

Definition Eine *partielle* Expansion ist eine **echte** Teil-Menge der Nachfolger.

Definition Die *Lokale Partielle Ordnungs-Reduktion* wählt als möglicherweise partielle Expansion eines Zustandes s eine Teil-Menge seiner Nachfolger wie folgt aus:

- genau die lokalen Übergänge von A_i , falls s lokal zu A_i ist
(in diesem Fall hat man eine partielle Expansion)
- bei mehreren solchen A_i wird ein beliebiges i gewählt
- falls kein solches A_i existiert, besteht die Expansion aus allen Nachfolgern

auch “stutter equivalent”

Definition zwei Traces w und w' sind **lokal äquivalent**, geschrieben $w \approx_l w'$, gdw. wenn sie nach Herausstreichen aller lokalen Symbole identisch sind.

Fakt die lokale Äquivalenz \approx_l ist tatsächlich eine Äquivalenzrelation

Beweis

- Reflexivität, Symmetrie folgen unmittelbar
- Schreibweise $w|_{\Sigma'}$ für den Trace w eingeschränkt auf Symbole aus Σ'
- Transitivität: aus $w_1 \approx_l w_2$, $w_2 \approx_l w_3$ folgt $w_1|_{\Gamma} = w_2|_{\Gamma} = w_3|_{\Gamma}$ und somit $w_1 \approx_l w_3$

Definition Checker C ignoriert lokale Symbole gdw.

$$s \xrightarrow{a} = \{s\} \quad \text{in } C \text{ für alle lokalen } a \in \Lambda$$

(auch “ a ist unsichtbar für C ”)

Fakt C ignoriere lokale Symbole und $w \approx_l w'$, dann $w \in L(C) \Leftrightarrow w' \in L(C)$

Beweis Sei $w \in L(C)$. Zustandssequenz, die w akzeptiert, akzeptiert auch w' und umgekehrt.

Suche mit Partieller Ordnungs-Reduktion muss also nur für jede Äquivalenzklasse von \approx_l mindestens einen Repräsentanten ablaufen.

Problem

- eine partielle Expansion “verzögert” Ausführung Übergänge anderer A_j
- diese könnten für immer verzögert werden

Lösung

- Zyklus mit nur partiellen Expansionen muss an einer Stelle voll expandiert werden
- lässt sich leicht in Tiefensuche (DFS) einbauen:
 - jeder Zyklus wird durch “Backedge” zu einem Knoten auf Suchstack geschlossen
 - bei einer “Backedge” wird `current` einfach voll expandiert
- Approximation bei BFS: volle Expansion bei Kanten zu Knoten früherer Generation

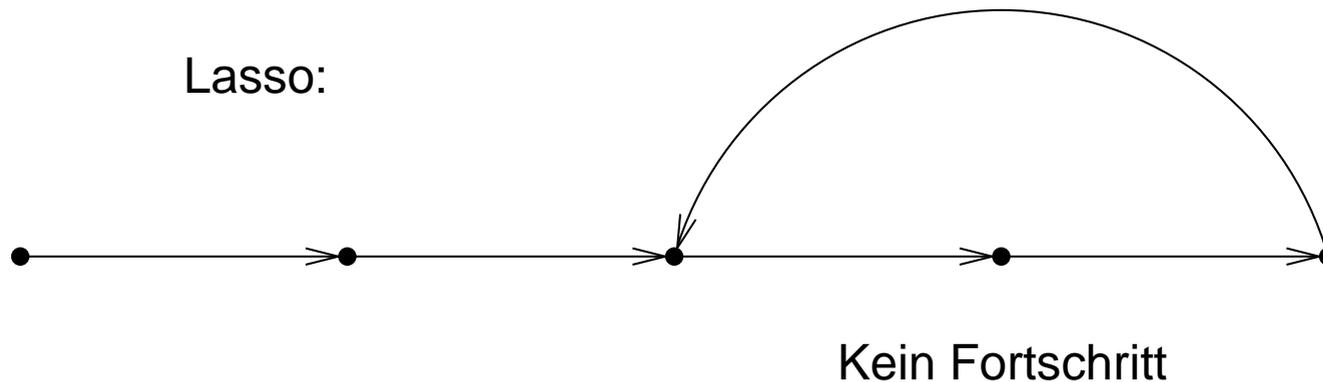
- statt Synchronisation durch Aktionen:
 - Synchronisation durch gemeinsame globale Variable
 - und/oder Synchronisation durch Monitore/Semaphoren
 - und/oder Synchronisation durch Nachrichten/Kanäle
- Partielle Ordnungs-Reduktion lässt sich mit folgenden Konzepten anwenden:
 - Unabhängigkeit bzw. Kommutieren von Befehlen
 - * Read/Write und Write/Read abhängig, Read/Read unabhängig
 - * analog für Nachrichten (Read = Receive, Write = Send)
 - Unsichtbarkeit von lokalen Befehlen

- Message Passing
 - Kommunikation durch Nachrichtenaustausch über Kanäle/Puffer/FIFO
 - beachte: endliche Modelle haben immer Kanäle endlicher Kapazität
- Unabhängige oder lokale Operationen (2 Prozesse, 1 Kanal):
 - Lesen von einem **nicht vollem** Kanal
 - Schreiben in einen **nicht leeren** Kanal
- Abhängige oder globale Operationen (2 Prozesse, 1 Kanal):
 - Lesen von einem **vollem** Kanal
 - Schreiben in einen **leeren** Kanal

- Liveness – Lebendigkeit
 - im Gegensatz zu Safety- bzw. Sicherheitseigenschaften
 - beschreibt **unausweichbares** Verhalten
 - macht wiederum nur Sinn bei Abstraktion vom konkretem Zeitverhalten:
Konzentration auf mögliche Ereignisfolgen ohne “Timing”
- **Deadlock** ist noch eine Sicherheitseigenschaft:
 - “keine Zustand ohne Nachfolger ist erreichbar”
- **Livelock** als prototypische Lebendigkeitseigenschaft:
 - “System verfängt sich nie in einer Endlosschleife ohne *echten* Fortschritt”

- Terminierung von Programmen/Prozessen/Protokollen:
 - z.B. Quicksort terminiert
 - z.B. IEEE Firewire: Initialisierungsphase terminiert mit einer korrekten Topologie
- Erwartete Ereignisse treten auch tatsächlich ein:
 - z.B. Befehle in superskalaren Prozessoren werden “Retired”
 - z.B. der Aufzug kommt wenn er gerufen wird
- in allen Beispielen werden **keine konkreten** Zeitschranken angegeben

- Endliche Systeme:



- Unendliche Systeme:

- “Divergenz” möglich: Gegenbeispiel muss kein Lasso sein
- z.B. Zähler über natürlichen Zahlen hochzählend erreicht nie wieder Anfangswert

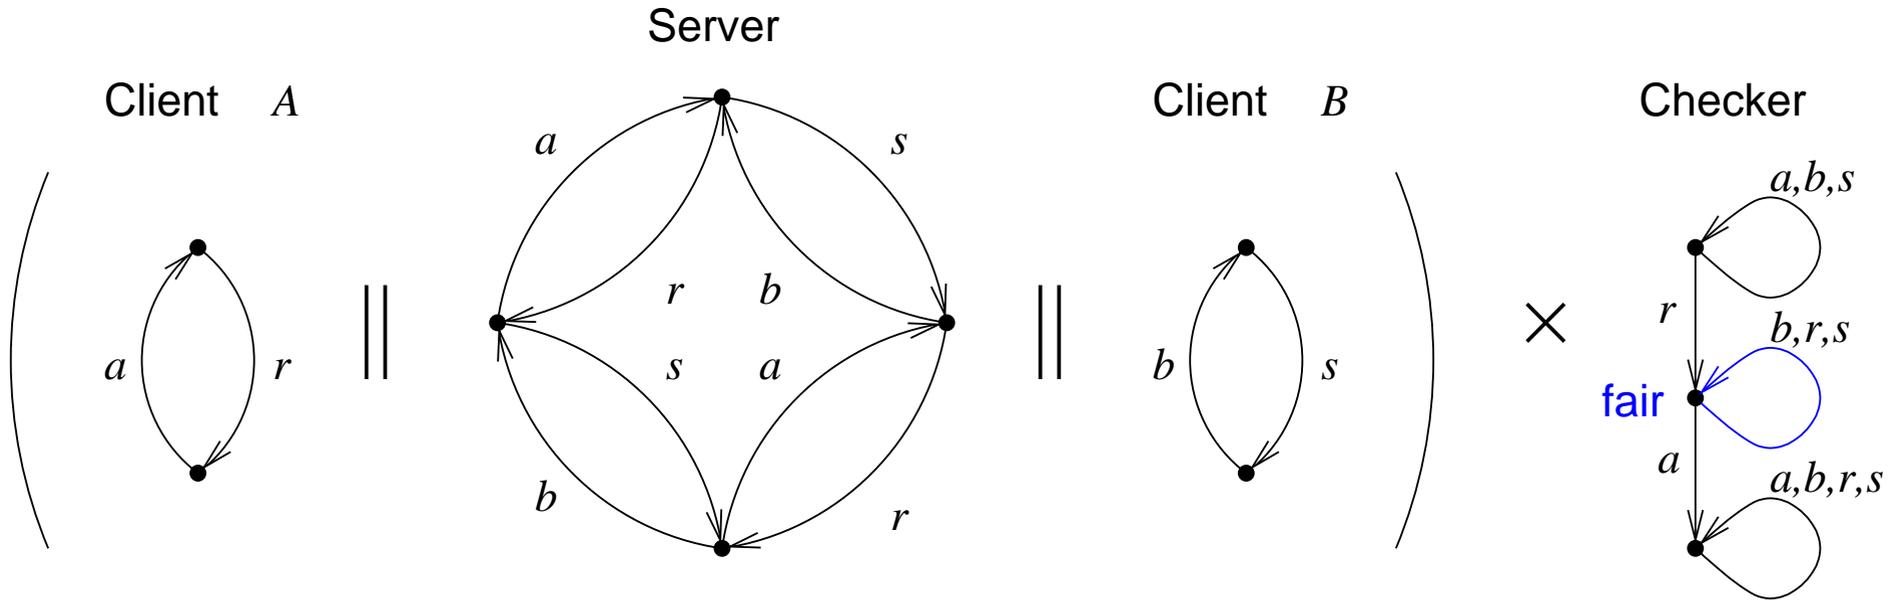
- Abstraktion vom konkreten “Scheduler”:
 - Reihenfolge der Ausführung von Prozessen ist im Modell beliebig
 - z.B. bei Interleaving oder voll asynchroner Parallelkomposition
- dadurch Artefakte bzw. unrealistische Gegenbeispiele zu Lebendigkeitseigenschaften:
 - Livelock durch permanentes Ignorieren eines Prozesses
- **Fairness** im Prinzip:
 - Scheduling **vernachlässigt** keinen (ausführbaren) Prozess für immer ...
 - ... ohne einen konkreten Scheduler anzugeben
(letzteres oftmals nicht möglich, da relative Geschwindigkeit nicht bekannt)

Definition ein *fares LTS* $A = (S, I, \Sigma, T, F)$ ist ein gewöhnliches LTS (S, I, Σ, T) , mit $F \subseteq T$ die Menge der *fairen Übergänge* von A .

(ein Übergang ist einfach eine Trippel (s, a, s'))

Definition ein unendlicher Pfad $\pi = s_0 \xrightarrow{a_0} s_1 \rightarrow \dots$ in einem fairen LTS ist *fair* gdw. π unendlich viele faire Übergänge enthält: $|\{i \mid (s_i, a_i, s_{i+1}) \in F\}| = \infty$.

Beispiel wähle für F die Menge der Übergänge in denen eine deterministische Komponente A_j einen lokalen oder globalen Übergang macht, oder aber “disabled” ist ($s \not\xrightarrow{a}$ für alle $a \in \Sigma_j$). Ein dadurch gegebener fairer Pfad in $A_1 \parallel \dots \parallel A_n$ muss A_j immer wieder “ausführen”.

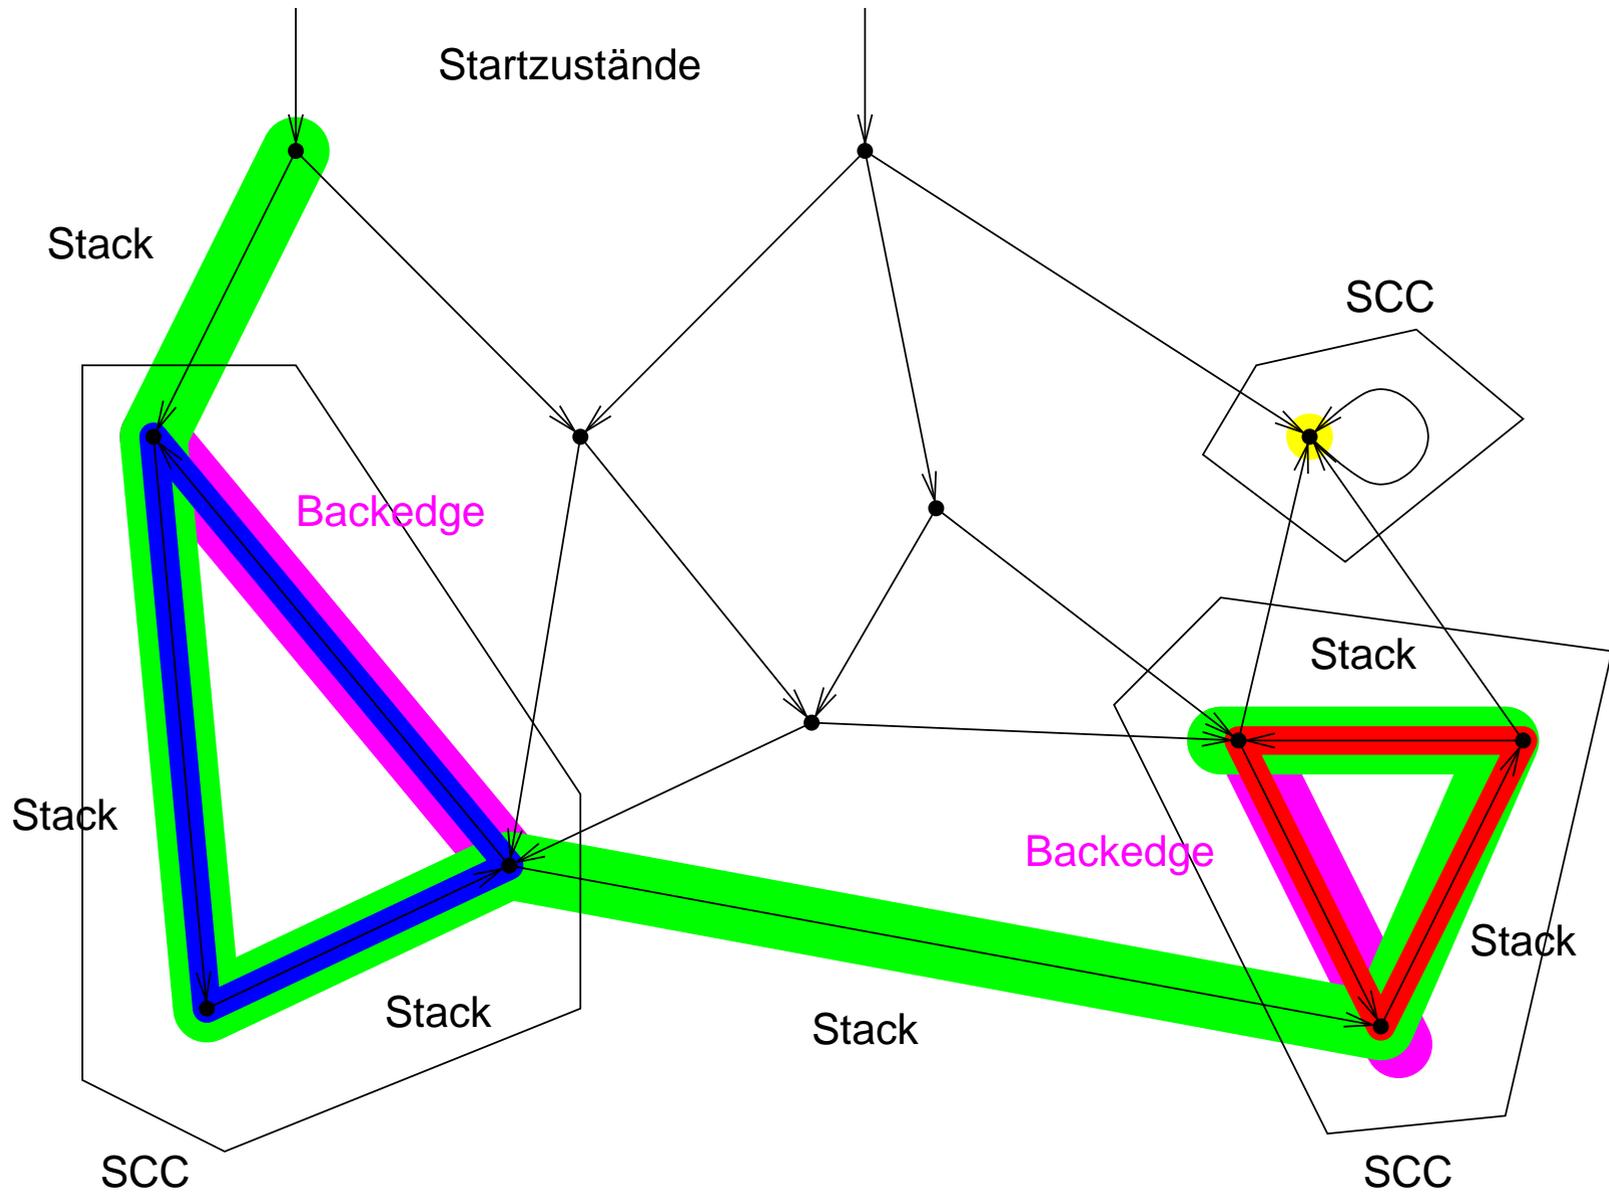


$F =$ alle $\{b, r, s\}$ -Übergänge, bei denen der Checker im unteren Zustand ist
(Gegenbeispiel dazu, dass ein a nach einem r irgendwann erfolgen muss)

es gibt einen fairen Pfad mit dem Trace $r(bs)^\omega = rbsbsbs \dots$

(bei dem A genau einmal ausgeführt wird)

- Im Prinzip (führt aber zu quadratischem Aufwand):
 - Backedge: Kante von `current` zu Knoten auf dem Stack der rekursiven DFS
 - Zyklus geschlossen durch Backedge ist fair gdw. er einen fairen Übergang hat
- SCC = strongly connected component
 - maximale Menge von Unterknoten eines Graphen (= Zustandsraum),
in der jeder Knoten von jedem anderen erreichbar ist
- jeder Zyklus (also auch der Zyklus eines Lasso) ist vollständig in einer SCC enthalten
 - SCC's lassen sich leicht in DFS finden:
linearer Algorithmus von Tarjan zur Zerlegung eines Graphen in seine SCC



- für jeden Knoten/Zustand merke
 1. *Depth First Search Index* (DFS_I): ordnet Knoten wie sie gefunden werden
 2. minimal zu erreichender DFS_I durch Backedge (MRDFS_I)
(auch über noch nicht besuchte Nachfolger)
- bestimme DFS_I in der Prefix-Phase
(bevor Nachfolger besucht werden)
- minimiere MRDFS_I rekursiv über MRDFS_I der Nachfolger
(in der Suffix-Phase)
- `pop` in rekursiver DFS erst dann wenn und solange MRDFS_I = DFS_I
- all die Knoten mit demselben MRDFS_I bilden eine SCC

Problem im Beispiel ist der Scheduler nicht *fair*

Definition ein *verallgemeinertes faires LTS* $A = (S, I, \Sigma, T, F_1, \dots, F_n)$ ist ein LTS (S, I, Σ, T) , mit $F_i \subseteq T$ eine Familie von Fairness Constraints.

Definition Übergang (s, a, s') heißt *fair* für das Fairness Constraint F_i gdw. $(s, a, s') \in F_i$.

Definition ein unendlicher Pfad $\pi = s_0 \xrightarrow{a_0} s_1 \rightarrow \dots$ in einem verallgemeinerten fairen LTS ist *fair* gdw. π für jedes Fairness Constraint F_j unendlich viele faire Übergänge enthält:
 $|\{i \mid (s_i, a_i, s_{i+1}) \in F_j\}| = \infty$.

Voriges Beispiel wähle als zweites Fairness Constraint alle Übergänge, bei denen A beteiligt ist. Dann gibt es keinen fairen Pfad, also auch kein Gegenbeispiel, dem “Request” r folgt also immer ein “Acknowledge” a .

- analog zum Algorithmus mit nur einem Fairness Constraint:
 - Teste beim Schließen eines Zyklus *alle* Fairness Constraints
 - oder überprüfe ob gefundene SCC alle Fairness Constraints “erlaubt”
- Alternative Konstruktion:
 - reduziere mehrere Fairness Constraints auf eines
 - zunächst lineare Ordnung der Fairness Constraints, z.B. $F_1 < \dots < F_n$
 - Kreuzprodukt mit modulo n Zähler welcher von i nach $(i + 1) \bmod n$ wechselt gdw. der Übergang im LTS das Fairness Constraint F_{i+1} erfüllt
 - einziges neues Fairness Constraint beim Zählerübergang von $n - 1$ nach 0

- Abstrakter Datentyp Boolesche Logik:
Konstruktoren: Erzeugung von boolesche Konstanten und Variablen
Operationen: Konjunktion, Disjunktion, Negation, ...
Abfragen: Test auf Erfüllbarkeit, Tautologie, ...
- Basis-Datentyp in EDA-Werkzeugen:
Simulatoren, Optimierer, Compiler
- Trade-Off zwischen effizienten Operationen und Platzverbrauch

0	0	0	0
0	0	1	1
0	1	0	1
0	1	1	0
1	0	0	1
1	0	1	0
1	1	0	0
1	1	1	1

 f

0	0	0	1
0	0	1	0
0	1	0	0
0	1	1	1
1	0	0	0
1	0	1	1
1	1	0	1
1	1	1	0

 g

0	0	0	1
0	0	1	1
0	1	0	1
0	1	1	1
1	0	0	1
1	0	1	1
1	1	0	1
1	1	1	1

 $f \vee g$

0	0	0	1
0	0	1	0
0	1	0	0
0	1	1	1
1	0	0	0
1	0	1	1
1	1	0	1
1	1	1	0

 $\neg f$

Operationen einfach Punktweise ausführen

- Funktionstabelle ist immer 2^n Zeilen gross bei n Variablen
- Operationen sind alle linear in der Grösse der Argumente:
z.B. Konjunktion ergibt Funktionstabelle gleicher Grösse
- Darstellung ist kanonisch:
zwei äquivalente boolesche Formeln haben dieselbe Funktionstabelle
- Abfragen sind auch linear:
Tautologie: überprüfe Zeilen auf Gleichheit
Erfüllbarkeit: suche 1-Zeile

- potentiell kompakter als Funktionstabelle
nur Anzahl Kernprimimplikanten bestimmt Grösse
- unmittelbare Implementierung als minimale 2-stufige Schaltung (PLA)
- Disjunktion linear (ohne Minimierung)
- Konjunktion linear und Negation exponentiell (auch ohne Minimierung)
- Erfüllbarkeit mit konstantem Aufwand:
DNF erfüllbar gdw. mind. ein Monom vorhanden

	b				
a	0	1	0	1	c
	1	0	1	0	
	0	1	0	1	
	1	0	1	0	
	d				
$a \oplus b \oplus c \oplus d$					

- keine Zusammenfassung von Min-Termen im KV-Diagramm möglich
- nur *volle* Min-Terme als Primimplikanten (bestehend aus maximaler Anzahl von Literalen)
- DNF für Parity von n Variablen hat 2^{n-1} Monome

$$\underbrace{(a \cdot \bar{b} \vee \bar{a} \cdot b \cdot \bar{c})}_{1. \text{ Operand}} \wedge \underbrace{(a \cdot \bar{b} \vee \bar{b} \cdot \bar{c})}_{2. \text{ Operand}}$$

Ausmultiplizieren

$$a \cdot \bar{b} \cdot a \cdot \bar{b} \vee a \cdot \bar{b} \cdot \bar{b} \cdot \bar{c} \vee \bar{a} \cdot b \cdot \bar{c} \cdot a \cdot \bar{b} \vee \bar{a} \cdot b \cdot \bar{c} \cdot \bar{b} \cdot \bar{c}$$

Vereinfachen der einzelnen Min-Terme

$$a \cdot \bar{b} \vee a \cdot \bar{b} \cdot \bar{c}$$

Minimierung (z.B. mit Quine-McCluskey)

$$a \cdot \bar{b}$$

$$\underbrace{(a \vee b \vee c)}_{\text{1. Operand}} \wedge \underbrace{(d \vee e \vee f)}_{\text{2. Operand}}$$

Ausmultiplizieren

$$a \cdot d \vee a \cdot e \vee a \cdot f \vee b \cdot d \vee b \cdot e \vee b \cdot f \vee c \cdot d \vee c \cdot e \vee c \cdot f$$

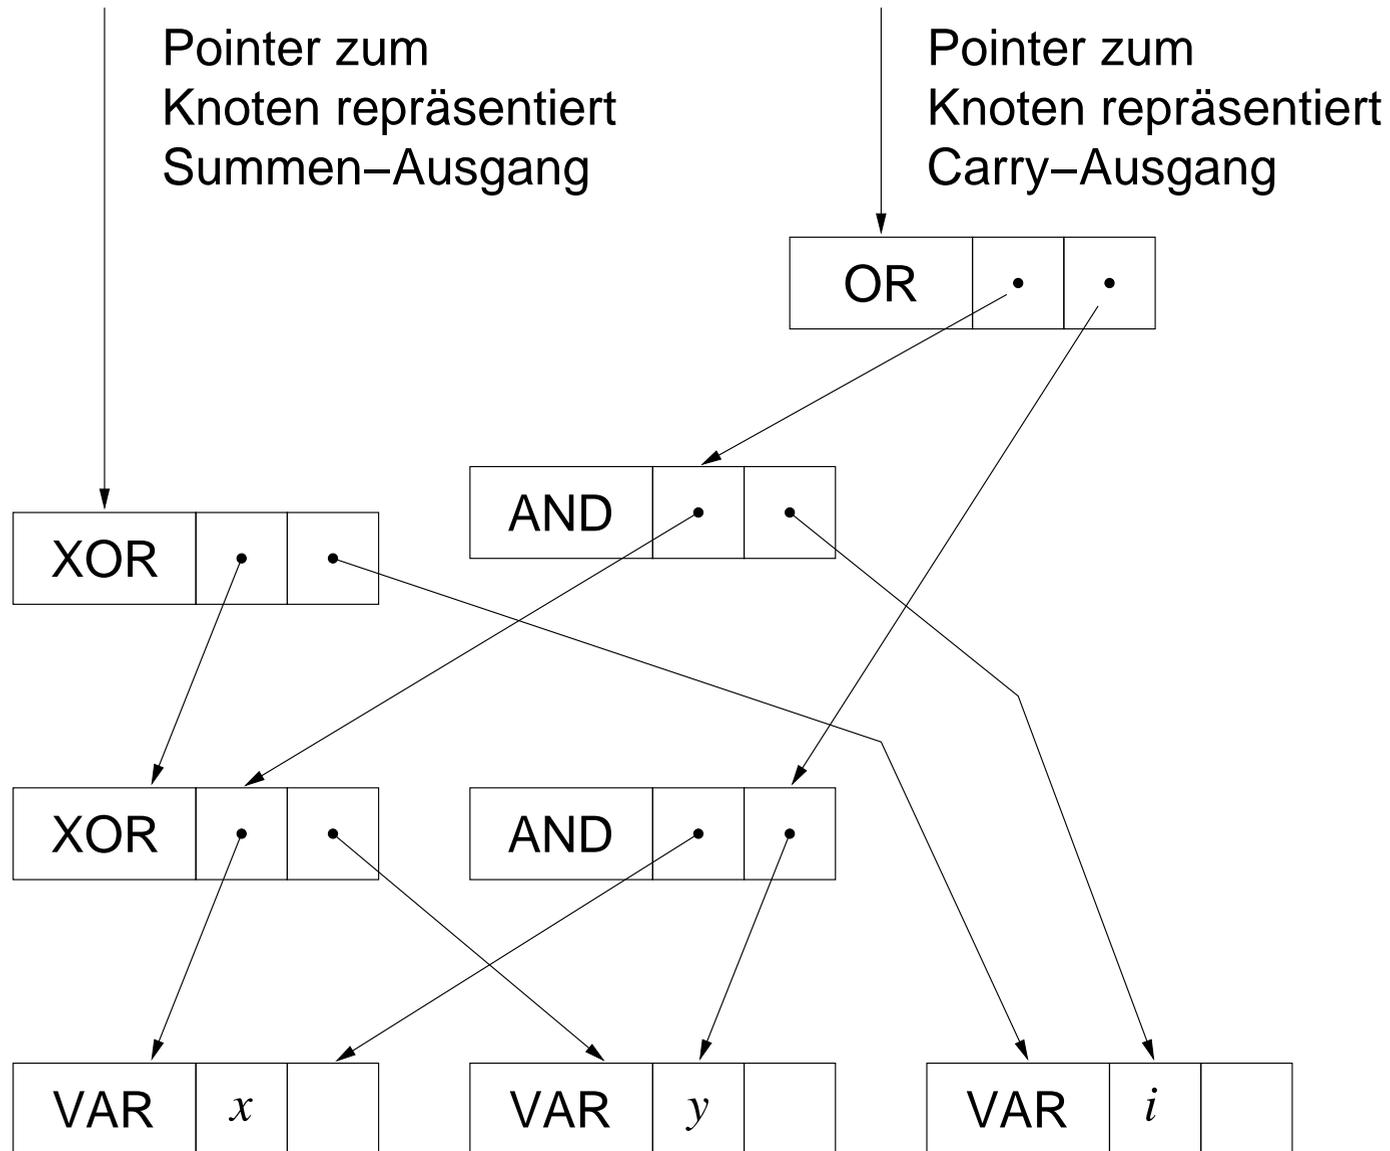
Keine weitere Vereinfachung möglich!

Beispiel lässt sich leicht generalisieren:

Konjunktion zweier DNF mit n und mit m Monomen hat $O(n \cdot m)$ Monome

- maximal linear grösseres Ergebnis (in beiden Argumenten)
- man verliert Minimalität:
Ausmultiplizieren min. DNF ergibt nicht notwendigerweise min. DNF
- anschliessende Minimierung hätte wiederum exponentiellen Aufwand
- auch implizite Generierung der Monome der Konjunktion möglich

- z.B. Netzliste der kombinatorischen Schaltung:
Hypergraph aus Gattern (Knoten) und Signalen (Hyper-Edges)
(Hyper-Edge: Menge von mit der Kante verbundenen Knoten)
- z.B. Parse-Tree einer booleschen Formel
- Sharen gemeinsamer Teil-Formeln ist kompakter:
Carry-Out eines Ripple-Adders als Baum ist exponentiell gross
Carry-Out eines Ripple-Adders als Netzliste ist nur linear gross
- z.B. Parse-DAG (Directed Acyclic Graph) für kombinatorische Logik



```
enum Tag
{
    OR, AND, XOR, NOT, VAR, CONST
};

typedef struct Node Node;
typedef union NodeData NodeData;

union NodeData
{
    Node *child[2];
    int idx;
};

struct Node
{
    enum Tag tag;
    NodeData data;
    int mark; /* traversal */
};
```

- Ähnliche Darstellung wie von Symbolen in einem Compiler
- Variablen werden durch Integer-Indizes dargestellt
- Boolesche Konstanten werden durch den 0 bzw. 1 Index dargestellt
- Operations-Knoten haben Pointer auf Kinder
- Knoten können mehrfach referenziert werden
(Speicherverwaltung: Referenz-Counting oder Garbage Collection)
- Keine Zyklen (DAG)!

```
Node *
new_node_val (int constant_value)
{
    Node *res;

    res = (Node *) malloc (sizeof (Node));
    memset (res, 0, sizeof (Node));
    res->tag = CONST;
    res->data.idx = constant_value;

    return res;
}
```

üblicherweise nur 0 und 1 als Werte für constant_value

```
Node *
new_node_var (int variable_index)
{
    Node *res;

    res = (Node *) malloc (sizeof (Node));
    memset (res, 0, sizeof (Node));
    res->tag = VAR;
    res->data.idx = variable_index;

    return res;
}
```

Variable werden an Hand ihres Index unterschieden

```
Node *
new_node_op (enum Tag tag, Node * child0, Node * child1)
{
    Node *res;

    res = (Node *) malloc (sizeof (Node));
    memset (res, 0, sizeof (Node));
    res->tag = tag;
    res->data.child[0] = child0;
    res->data.child[1] = child1;

    return res;
}
```

Operations-Typ wird als erstes Argument mitübergaben

(Annahme: child1 ist 0 für Negation)

```
Node *x, *y, *i, *o, *s, *t[3];

x = new_node_var (0);
y = new_node_var (1);
i = new_node_var (2);
t[0] = new_node_op (XOR, x, y);
t[1] = new_node_op (AND, x, y);
t[2] = new_node_op (AND, t[0], i);
s = new_node_op (XOR, t[0], i);
o = new_node_op (OR, t[1], t[2]);
```

Explizites Sharen durch temporäre Pointer $t[0]$, $t[1]$ und $t[2]$

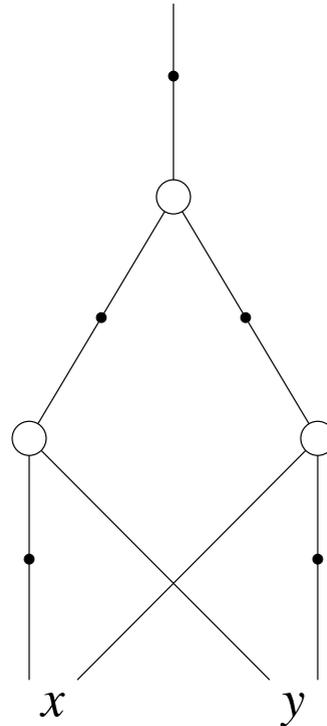
```
void
input_cone_node (Node * node)
{
    if (node->mark)
        return;
    node->mark = 1;
    switch (node->tag)
    {
        case CONST:
            break;
        case VAR:
            printf ("variable %d in input cone\n", node->data.idx);
            break;
        case NOT:
            input_cone_node (node->data.child[0]);
            break;
        default:
            /* assume binary operator */
            input_cone_node (node->data.child[0]);
            input_cone_node (node->data.child[1]);
            break;
    }
}
```

```
void
mark_node (Node * node, int new_value)
{
    if (node->mark == new_value)
        return;

    node->mark = new_value;
    switch (node->tag)
    {
        case VAR:
        case CONST:
            return;
        case NOT:
            mark_node (node->data.child[0], new_value);
            break;
        default:
            mark_node (node->data.child[0], new_value);
            mark_node (node->data.child[1], new_value);
            break;
    }
}
```

- Algorithmen basieren auf Depth-First-Search
- Vermeidung von Mehrfach-Traversierung mit `mark`-Flag
- Meist zwei Phasen: Traversierung, Wiederherstellung `mark`-Flag
- Konjunktion, Negation sind schnell (verwende `op`)
- Tautologie und Erfüllbarkeit schwierig
- Nur explizites Sharen: keine kanonische Darstellung

- logische Basis-Operationen: Konjunktion und Negation
- DAG-Darstellung:
 - Operations-Knoten sind alles Konjunktionen
 - Negation/Vorzeichen als Kanten-Attribut (daher *signed*)
 - (platzsparend als LSB im Pointer)
- automatisches Sharen syntaktisch isomorpher Teilgraphen
- Vereinfachungs-Regeln mit konstantem Look-Ahead



Negationen/Vorzeichen sind Kantenattribute
(gehören nicht zu den Knoten)

```
typedef struct AIG AIG;

struct AIG
{
    enum Tag tag;           /* AND, VAR */
    void *data[2];
    int mark, level;       /* traversal */
    AIG *next;             /* hash collision chain */
};

#define sign_aig(aig) (1 & (unsigned) aig)
#define not_aig(aig) ((AIG*)(1 ^ (unsigned) aig))
#define strip_aig(aig) ((AIG*)(~1 & (unsigned) aig))
#define false_aig ((AIG*) 0)
#define true_aig ((AIG*) 1)
```

Annahme für Korrektheit:

```
sizeof(unsigned) == sizeof(void*)
```

- Alignment moderner Prozessoren “verschwendet” sowieso mehrere LSBs

Alignment ist typischerweise 4 oder 8 Bytes \Rightarrow 2 oder 3 LSBs übrig

`malloc` liefert *aligned blocks* (z.B. 8 Byte aligned auf Sparc)

- negierte und unnegierte Formel entspricht einem Knoten

(potentiell Halbierung des Speicherplatzes)

- maximale Reduktion auf einen einzigen Operations-Typ (AND)

- Negation extrem effizient (Bit im Pointer umsetzen)

- erlaubt zusätzliche Vereinfachungsregeln

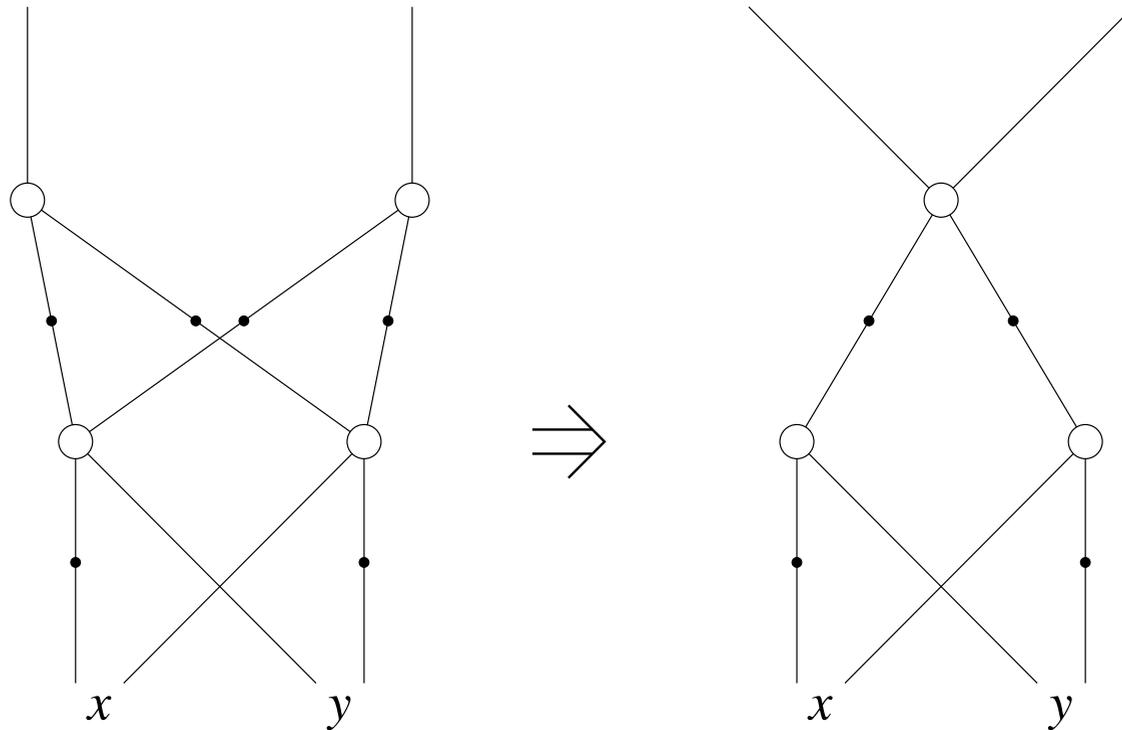
direkte Erkennung von Argumenten unterschiedlichem Vorzeichens

```
int
simp_aig (enum Tag tag, void *d0, void *d1, AIG ** res_ptr)
{
    if (tag == AND)
    {
        if (d0 == false_aig || d1 == false_aig || d0 == not_aig (d1))
            { *res_ptr = false_aig; return 1; }

        if (d0 == true_aig || d0 == d1)
            { *res_ptr = d1; return 1; }

        if (d1 == true_aig)
            { *res_ptr = d0; return 1; }
    }

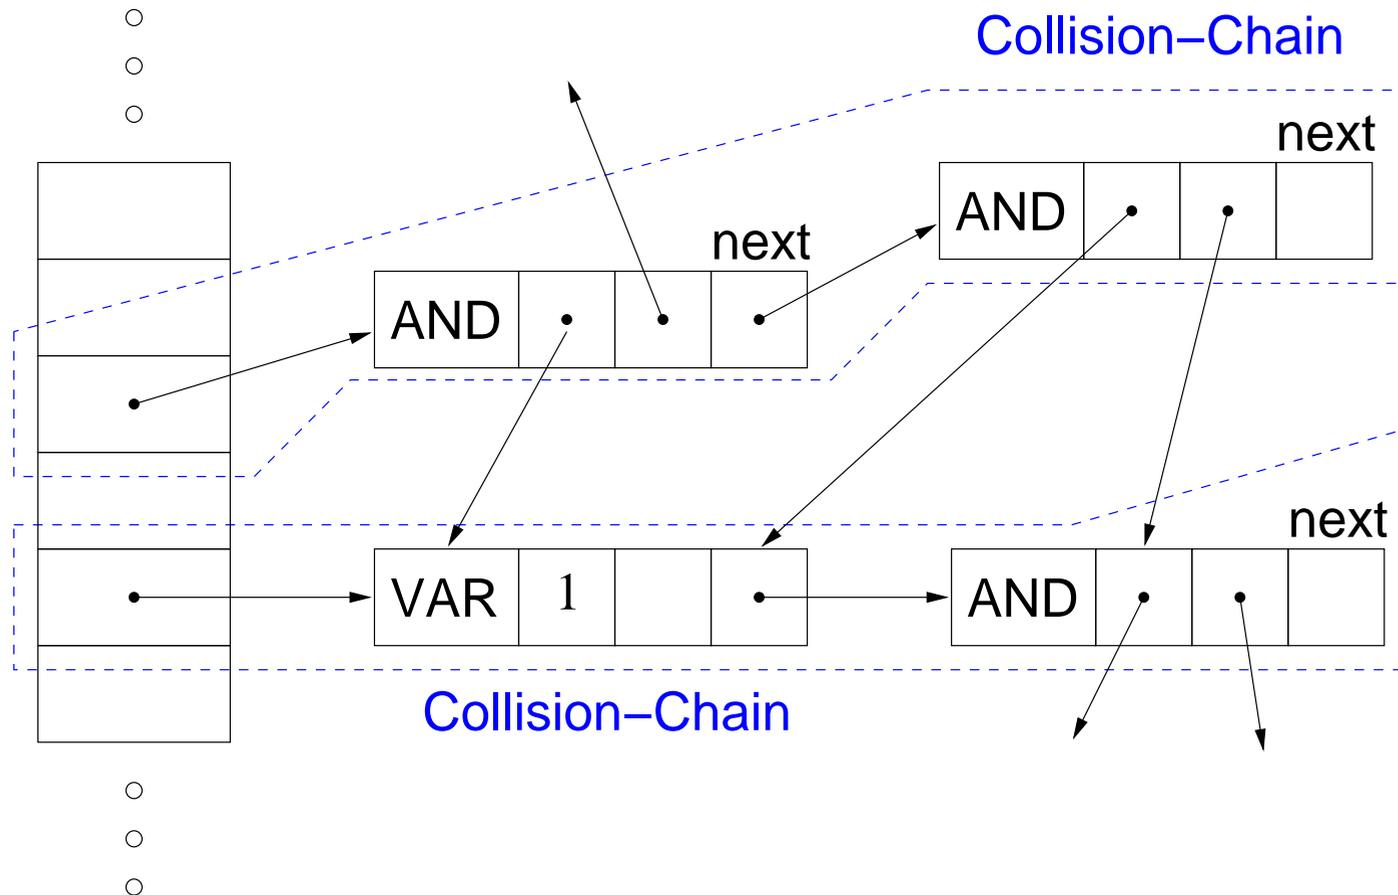
    return 0;
}
```



Verschmelzen von Knoten mit gleichen Kindern

- wird auch *Algebraische Reduktion* genannt
- Hauptvorteil ist automatische Kompaktifizierung
- Implementierung:
Knoten in einer Hash-Tabelle (Unique-Table) gespeichert
- On-The-Fly Reduktion:
Invariante: zwei Knoten haben immer unterschiedliche Kinder
Erzeugung neuer Knoten: zunächst Suche nach äquivalentem Knoten
Suche erfolgreich liefert äquivalenten Knoten als Resultat

Unique-Table



```
#define UNIQUE_SIZE (1 << 20)
AIG *unique[UNIQUE_SIZE];

AIG **
find_aig (enum Tag tag, void *d0, void *d1)
{
    AIG *r, **p;
    unsigned h = (tag + ((int) d0) * 65537 + 13 * (int) d1);
    h = h & (UNIQUE_SIZE - 1);    /* modulo UNIQUE_SIZE */
    for (p = unique + h; (r = *p); p = &r->next)
        if (r->tag == tag && r->data[0] == d0 && r->data[1] == d1)
            break;

    return p;
}
```

1. Bilde Hashwert als Kombination des Tags und der Pointer-Werte
(bzw. der Variablen-Indizes bei Konstanten)
2. Normalisiere Hashwert auf Grösse der Unique-Table
3. Durchsuche Collision-Chain an der Hashwert-Position in der Unique-Table
4. Vergleiche Knoten mit neu zu erzeugendem Knoten
5. Falls gleich gib Pointer auf Link zu diesem Knoten zurück
6. Ansonsten gib Pointer auf letztes leeres Link-Feld in Chain zurück

```
void
insert_aig (AIG * aig)
{
    AIG **p;
    int l[2];

    p = find_aig (aig->tag, aig->data[0], aig->data[1]);
    assert (!*p);
    aig->next = *p;
    *p = aig;

    if (aig->tag == AND)
    {
        l[0] = strip_aig (aig->data[0])->level;
        l[1] = strip_aig (aig->data[1])->level;
        aig->level = 1 + ((l[0] < l[1]) ? l[1] : l[0]);
    }
    else
        aig->level = 0;
}
```

find_aig gibt (neue) Position des gehashten Knotens zurück

```
AIG *
new_aig (enum Tag tag, void *data0, void *data1)
{
    AIG *res;
    if (tag == AND && data0 > data1)
        SWAP (data0, data1);
    if (tag == AND && (simp_aig (tag, data0, data1, &res)))
        return res;
    if ((res = *find_aig (tag, data0, data1)))
        return res;
    res = (AIG *) malloc (sizeof (AIG));
    memset (res, 0, sizeof (AIG));
    res->tag = tag;
    res->data[0] = data0;
    res->data[1] = data1;
    insert_aig (res);

    return res;
}
```

```
AIG *
var_aig (int variable_index)
{
    return new_aig (VAR, (void *) variable_index, 0);
}
```

```
AIG *
and_aig (AIG * a, AIG * b)
{
    return new_aig (AND, a, b);
}
```

```
AIG *
or_aig (AIG * a, AIG * b)
{
    return not_aig (and_aig (not_aig (a), not_aig (b)));
}
```

```
AIG *
xor_aig (AIG * a, AIG * b)
{
    return or_aig (and_aig (a, not_aig (b)), and_aig (not_aig (a), b));
}
```

```
int
count_aig (AIG * aig)
{
    if (sign_aig (aig))
        aig = not_aig (aig);
    if (aig->mark)
        return 0;
    aig->mark = 1;
    if (aig->tag == AND)
        return count_aig (aig->data[0]) + count_aig (aig->data[1]) + 1;
    else
        return 1;
}
```

Man muss explizit die Vorzeichen behandeln
aber sonst genauso DFS-orientiert wie bei DAG-Darstellung

```
void
mark_aig (AIG * aig, int new_value)
{
    if (sign_aig (aig))
        aig = not_aig (aig);
    if (aig->mark == new_value)
        return;
    aig->mark = new_value;
    if (aig->tag == AND)
    {
        mark_aig (aig->data[0], new_value);
        mark_aig (aig->data[1], new_value);
    }
}
```

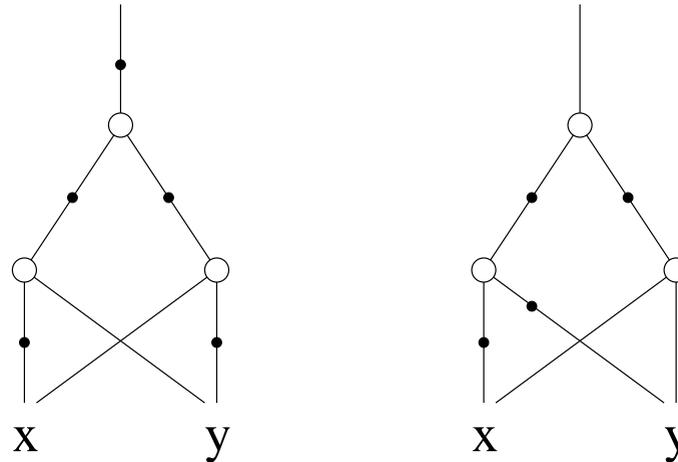
Weniger Fälle und weniger Code als bei DAG Darstellung!

```
AIG *
node2aig (Node * node)
{
    switch (node->tag)
    {
        case VAR:
            return new_aig (VAR, (void *) node->data.idx, 0);
        case CONST:
            return node->data.idx ? true_aig : false_aig;
        case AND:
            return and_aig (node2aig (node->data.child[0]),
                            node2aig (node->data.child[1]));
        case OR:
            return or_aig (node2aig (node->data.child[0]),
                            node2aig (node->data.child[1]));
        case XOR:
            return xor_aig (node2aig (node->data.child[0]),
                            node2aig (node->data.child[1]));
        default:
            assert (node->tag == NOT);
            return not_aig (node2aig (node->data.child[0]));
    }
}
```

```
void
vis_aig_aux (AIG * aig, FILE * file, int max_level)
{
    assert (!sign_aig (aig));
    if (aig->mark)
        return;
    aig->mark = 1;
    switch (aig->tag)
    {
        case VAR:
            fprintf (file, "%p@d:c'%d\n", aig, 2 * max_level, (int) aig->data[0]);
            break;
        default:
            assert (aig->tag == AND); /* TODO: constants */
            vis_aig_edge (aig, aig->data[0], file, max_level);
            vis_aig_edge (aig, aig->data[1], file, max_level);
            vis_aig_aux (strip_aig (aig->data[0]), file, max_level);
            vis_aig_aux (strip_aig (aig->data[1]), file, max_level);
            break;
    }
}
```

Simple DFS: Graph wird rekursiv in Datei geschrieben

- robusterer C-Code notwendig
(z.B. 64 Bit-Anpassung)
- Speicher-Management fehlt ganz
(z.B. Reference-Counting oder GC)
- Eingabe-Format und Parser fehlen
- Vereinfachungsregeln für Enkel fehlen
(z.B. Distributiv-Gesetz)

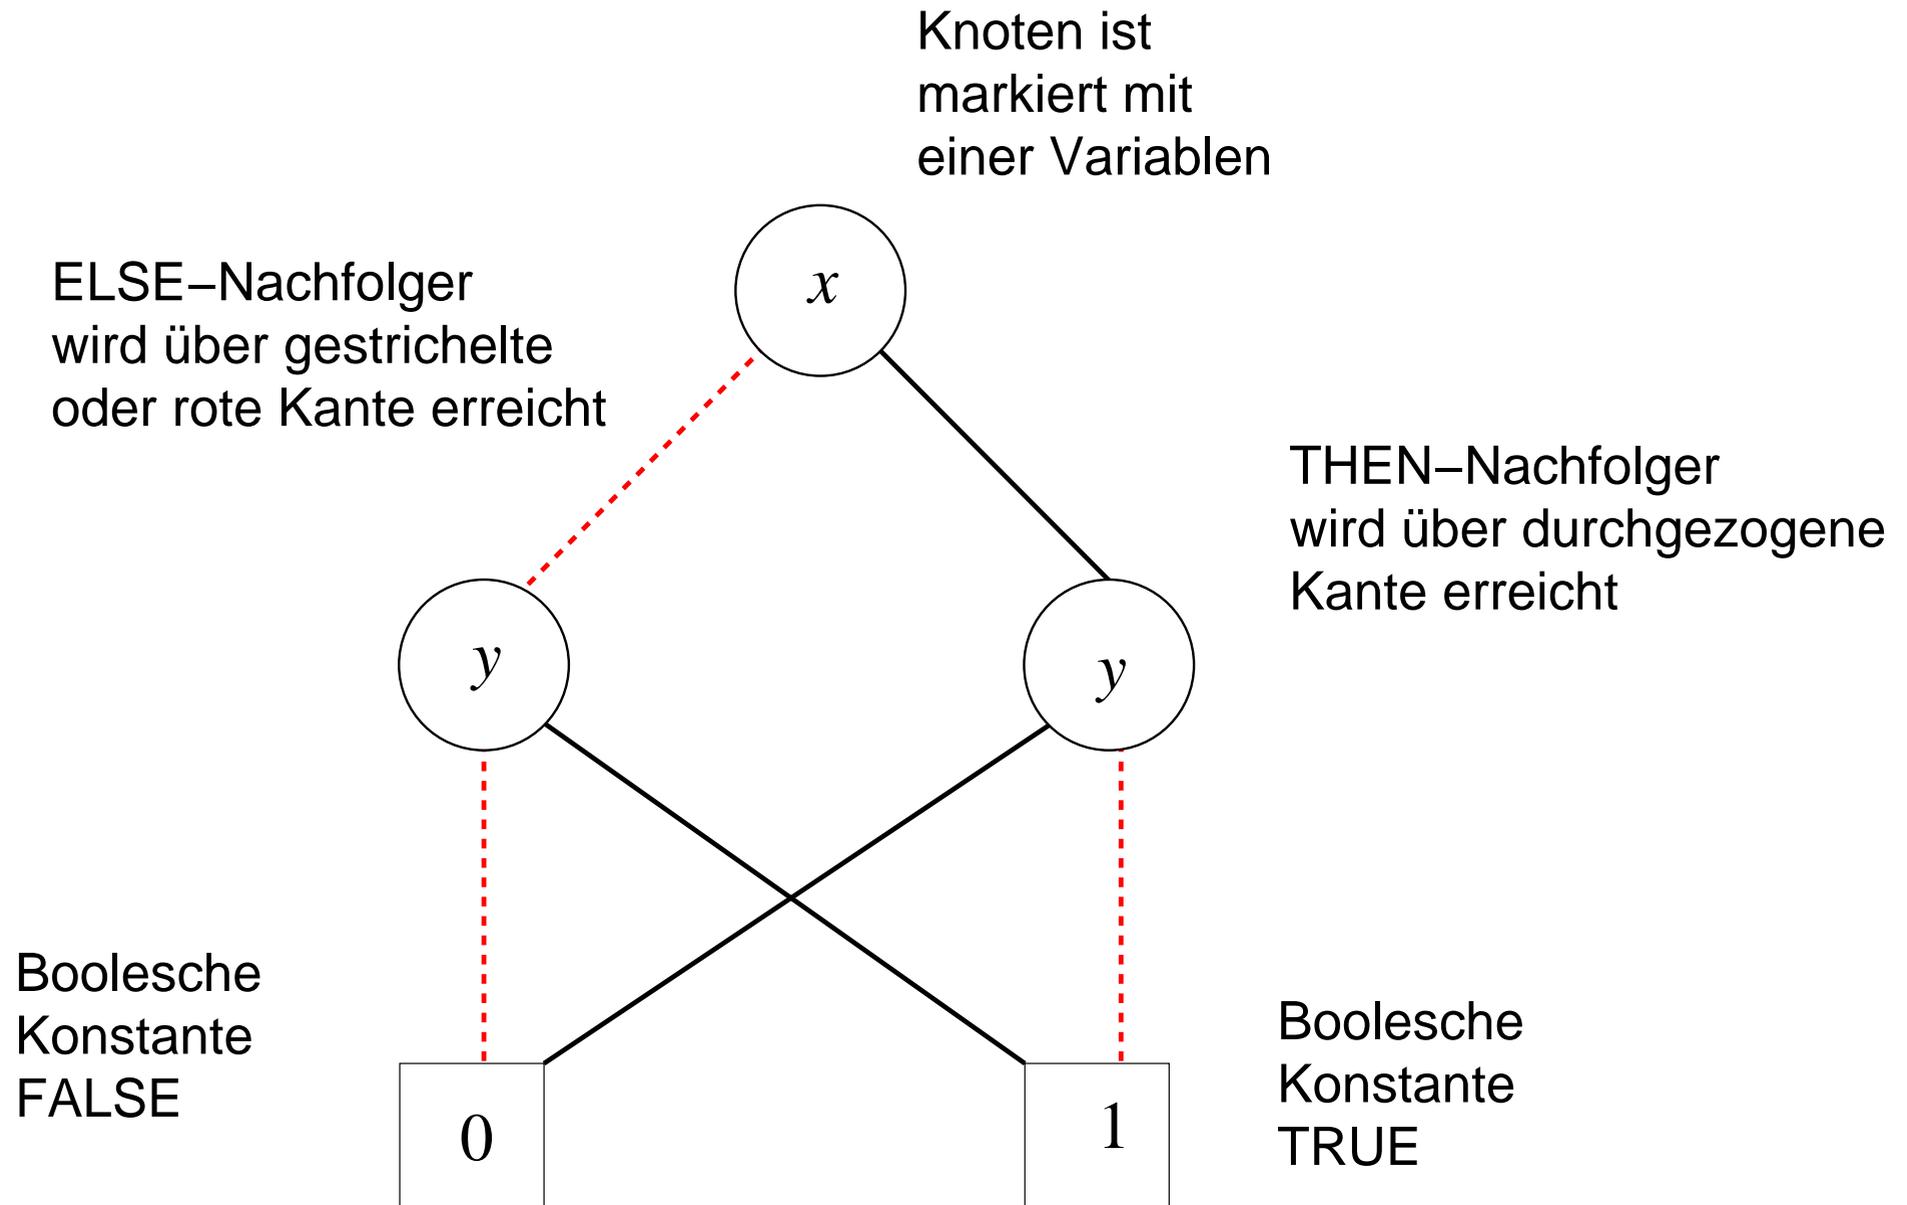


$$\bar{x} \cdot y \vee x \cdot \bar{y} \quad \equiv \quad (\bar{x} \vee \bar{y}) \cdot (x \vee y)$$

beide Formeln und AIGs beschreiben XOR von x und y
(Ausmultiplizieren der rechten Formel ergibt linke Formel)

i.Allg. gibt es mehrere AIGs für dieselbe boolesche Funktion

- neue dreistellige Basis-Operation ITE (if-then-else):
Bedingung ist immer eine Variable
- gehen zurück auf Shannon (deshalb auch Shannon-Graphs)
- meist verwendete Version sind die ROBDDs
Reduced Ordered Binary Decision Diagrams
- [Bryant86] hat Kanonizität von ROBDDs gezeigt:
Jede Boolesche Funktion hat genau einen ROBDD

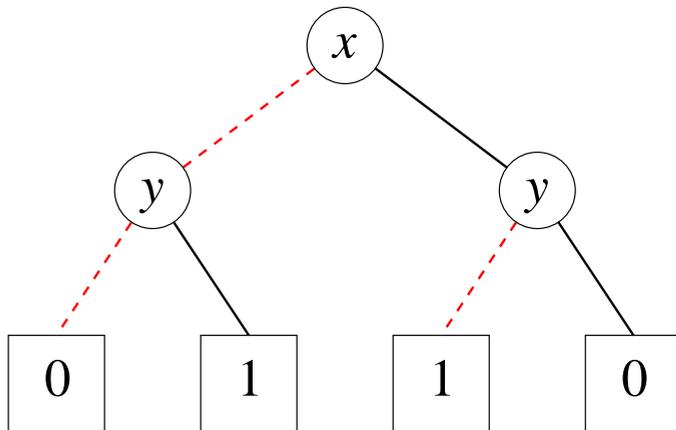


- innere Knoten sind ITE, Blätter sind boolesche Konstante
- Schreibweise $ite(x, f_1, f_0)$ bedeutet *wenn x dann f_1 ansonsten f_0*
(beachte: ELSE-Argument f_0 kommt hinter f_1 trotz umgekehrter Indizierung)
- Semantik $eval$ produziert booleschen Ausdruck aus einem BDD

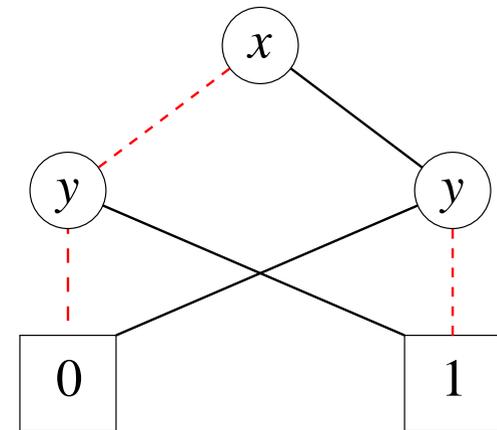
$$\begin{aligned}eval(0) &\equiv 0 \\eval(1) &\equiv 1 \\eval(ite(x, f_1, f_0)) &\equiv x \cdot eval(f_1) \vee \bar{x} \cdot eval(f_0)\end{aligned}$$

- BDDs sind auch wieder algebraisch reduzierte DAG's
(max. Sharen von isomorphen Teil-Graphen wie bei AIGs)
- Negations-Kanten wie bei AIGs möglich

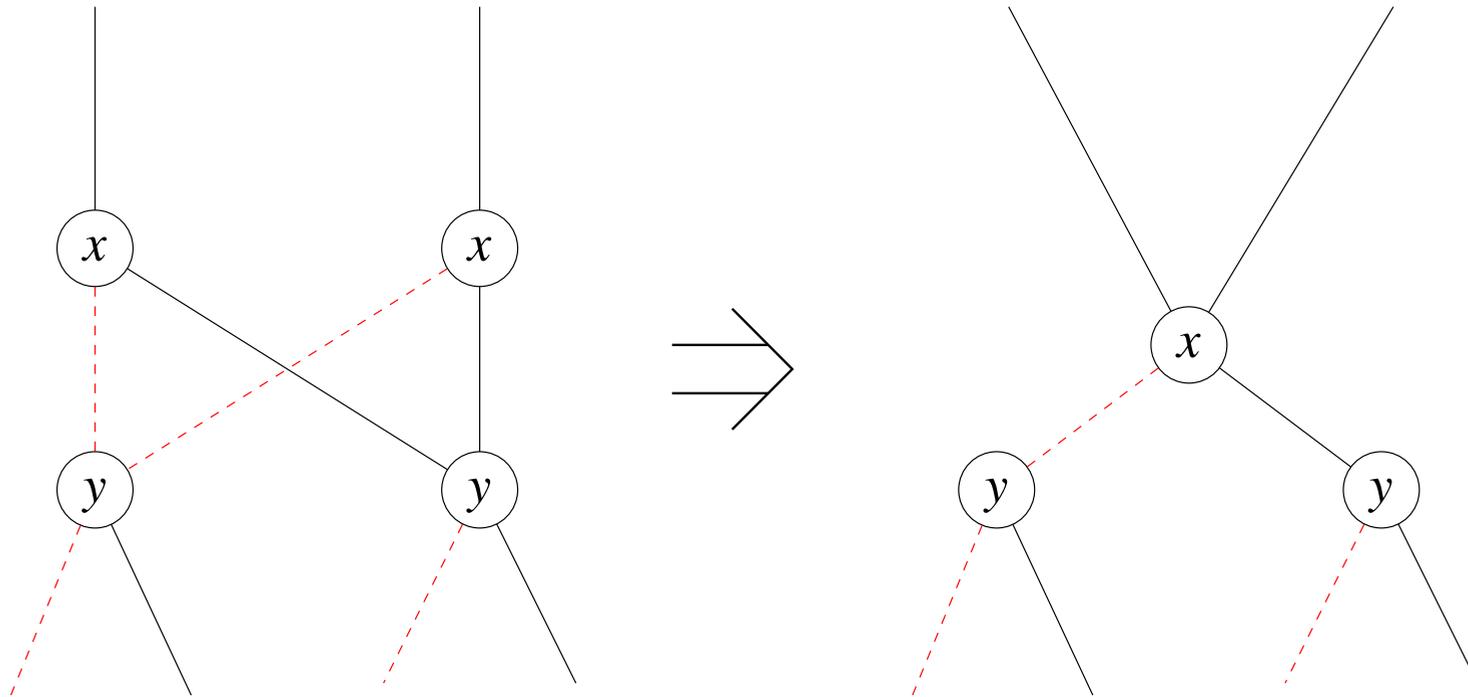
x	y	$x \oplus y$
0	0	0
0	1	1
1	0	1
1	1	0



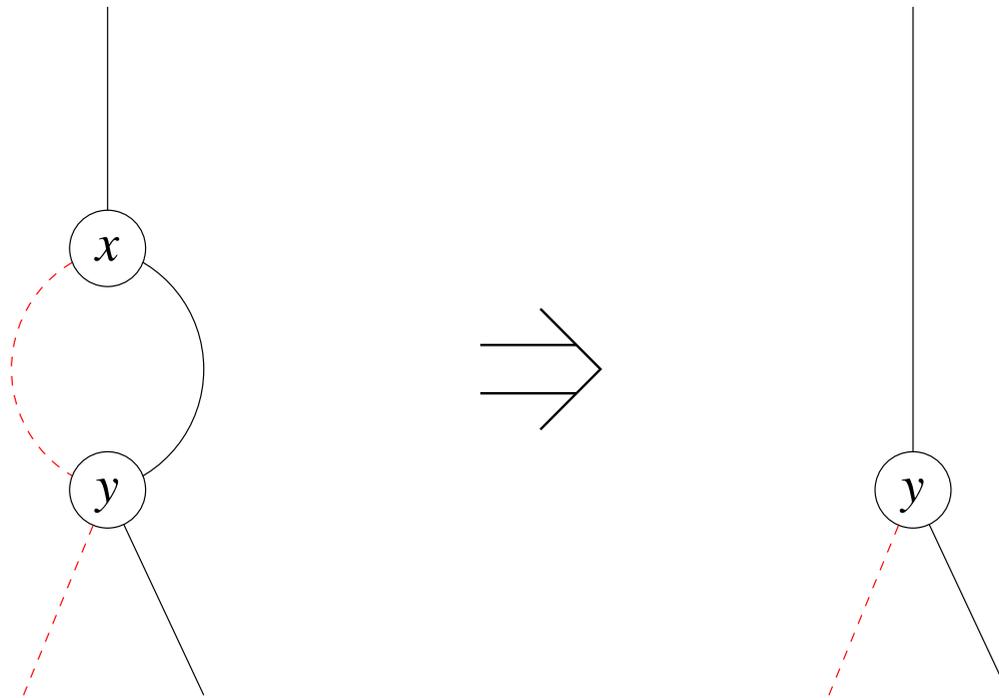
Entscheidungs-Baum



Entscheidungs-Diagramm
(DAG)

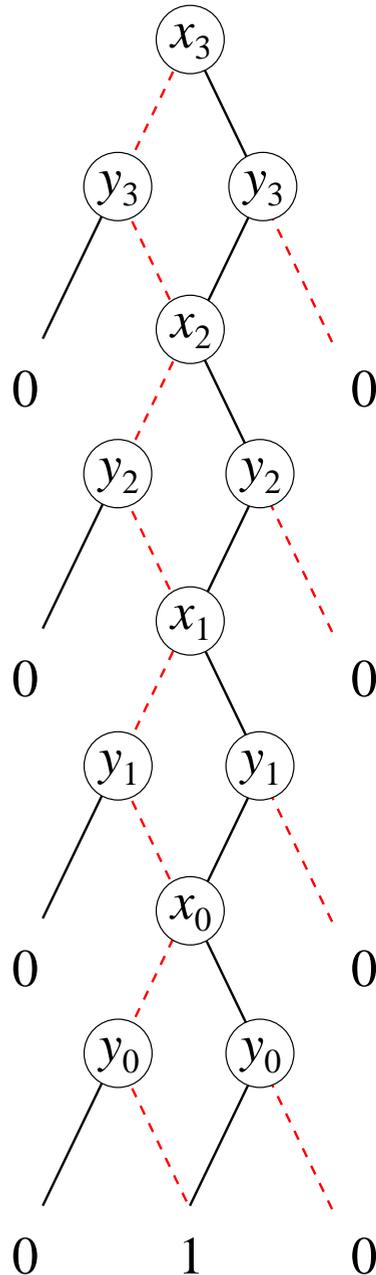


Maximales Sharen isomorpher Teil-Graphen



Elimination redundanter Innerer Knoten

- maximale algebraische und semantische Reduktion
(das **Reduced** in ROBDDs)
- Variablen von der Wurzel zu den Blättern sind gleich geordnet
(das **Ordered** in ROBDDs)
- diesen Annahmen machen BDDs kanonisch modulo Variablenordnung
- unterschiedliche Ordnungen führen i.Allg. zu unterschiedlichen BDDs
- Variablenordnung bestimmt essentiell die Grösse von BDDs
- **im weiteren meinen wir immer ROBDDs, wenn wir BDD sagen**



Boolesche Funktion:

$$\prod_{i=0}^{n-1} x_i = y_i$$

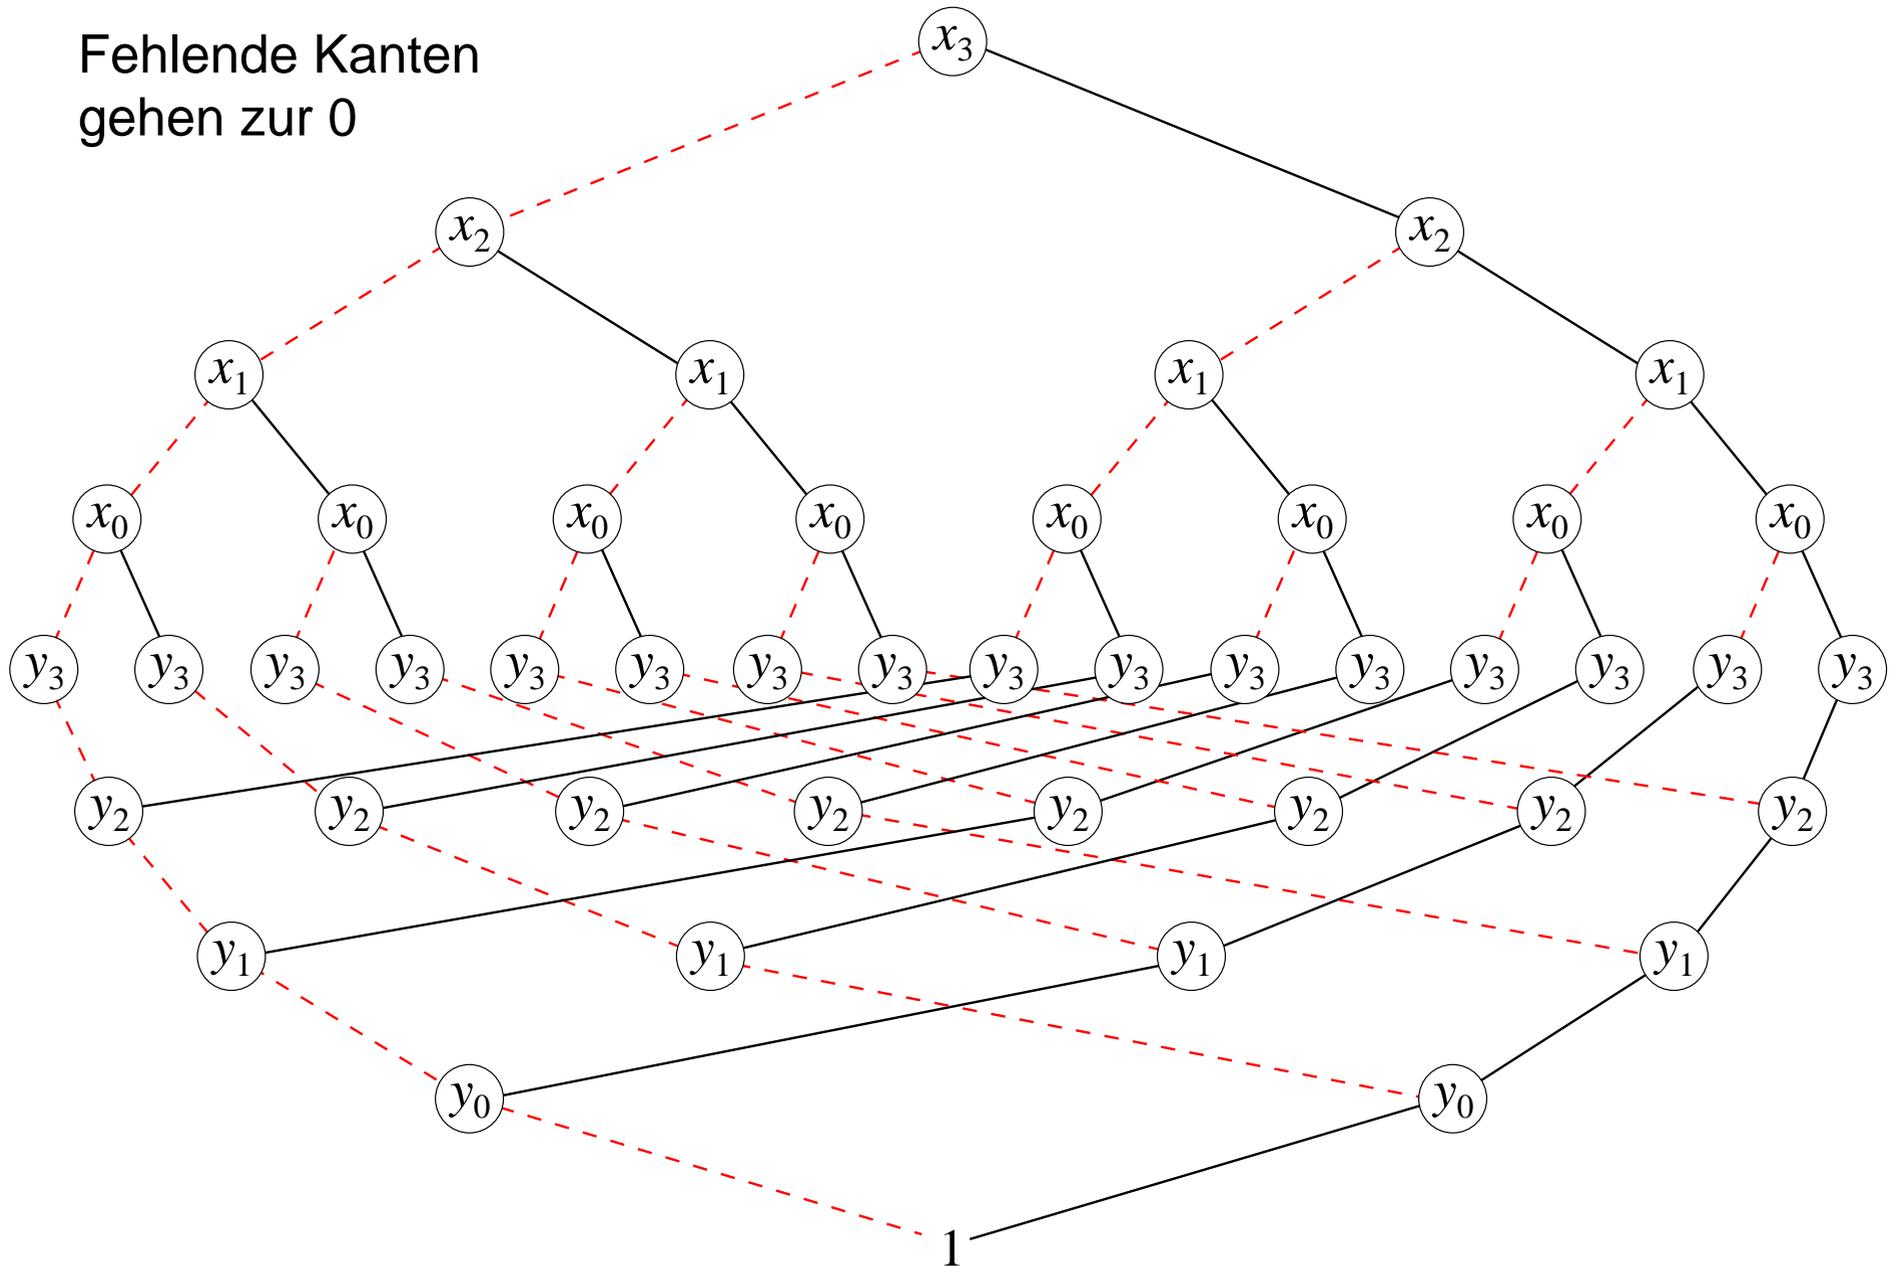
Verschränkte Variablen-Ordnung
(interleaved)

$$x_3 > y_3 > x_2 > y_2 > x_1 > y_1 > x_0 > y_0$$

Allgemein:

Vergleich zweier n -Bit Vektoren braucht bei verschränkter Ordnung $3 \cdot n$ innere Knoten.

Fehlende Kanten
gehen zur 0



- es gibt exponentielle Unterschiede zwischen Variablen-Ordnungen
- es gibt aber leider auch *exponentielle* Funktionen:
BDD ist immer exponentiell, z.B. mittlere Ausgabe-Bits von Multiplizierer
- es gibt Heuristiken zur statischen Variablen-Ordnung:
meist einfache Auflistung der Variablen in DFS des DAG/AIG
(etwa wie in `input_cone_aig`)
- zusätzlich gibt es noch *dynamische Umordnung von Variablen*
basiert auf *in-place* Austausch von benachbarten Variablen

Kanonizität der BDDs für boolesche Funktionen ergibt:

- ein BDD ist eine Tautologie, gdw. er nur aus dem 1-Blatt besteht
- ein BDD ist erfüllbar, gdw. er nicht aus dem 0-Blatt besteht
- zwei BDDs sind äquivalent, gdw. die BDDs sind isomorph
(werden BDDs wie AIGs in der gleichen Unique-Tabelle gespeichert, dann ist der Test auf Äquivalenz ein einfacher Pointer-Vergleich)

Frage: Wo ist die NP-Vollständig der Erfüllbarkeit geblieben?

Antwort: Versteckt sich im Aufwand der Erzeugung eines BDDs.

lautet wie folgt:

$$f(x) \equiv x \cdot f(1) \vee \bar{x} \cdot f(0)$$

Sei nun x die oberste Variable zweier BDDs f und g :

$$f \equiv \text{ite}(x, f_1, f_0) \qquad g \equiv \text{ite}(x, g_1, g_0)$$

mit f_i bzw. g_i die Kinder von f und g für $i = 0, 1$. Dann folgt

$$f(0) = f_0 \qquad g(0) = g_0 \qquad f(1) = f_1 \qquad g(1) = g_1$$

da nach dem **R** in **ROBDD** x nur ganz oben in f und g vorkommt.

$$\begin{aligned} (f@g)(x) &\equiv x \cdot (f@g)(1) \vee \bar{x} \cdot (f@g)(0) \\ &\equiv x \cdot (f(1)@g(1)) \vee \bar{x} \cdot (f(0)@g(0)) \\ &\equiv x \cdot (f_1@g_1) \vee \bar{x} \cdot (f_0@g_0) \end{aligned}$$

wobei $@$ eine beliebige zweistellige boolesche Operation ist (z.B. \wedge , \vee , \oplus , ...)

Rekursives Schema zur Berechnung von Operationen auf BDDs

```
typedef struct BDD BDD;
```

```
struct BDD  
{  
    int idx, mark;  
    BDD *child[2], *next;  
};
```

```
#define sign_bdd(ptr) (1 & (unsigned) ptr)
```

```
#define strip_bdd(ptr) ((BDD*) (~1 & (unsigned) ptr))
```

```
#define not_bdd(ptr) ((BDD*) (1 ^ (unsigned) ptr))
```

```
#define true_bdd ((BDD*) 1)
```

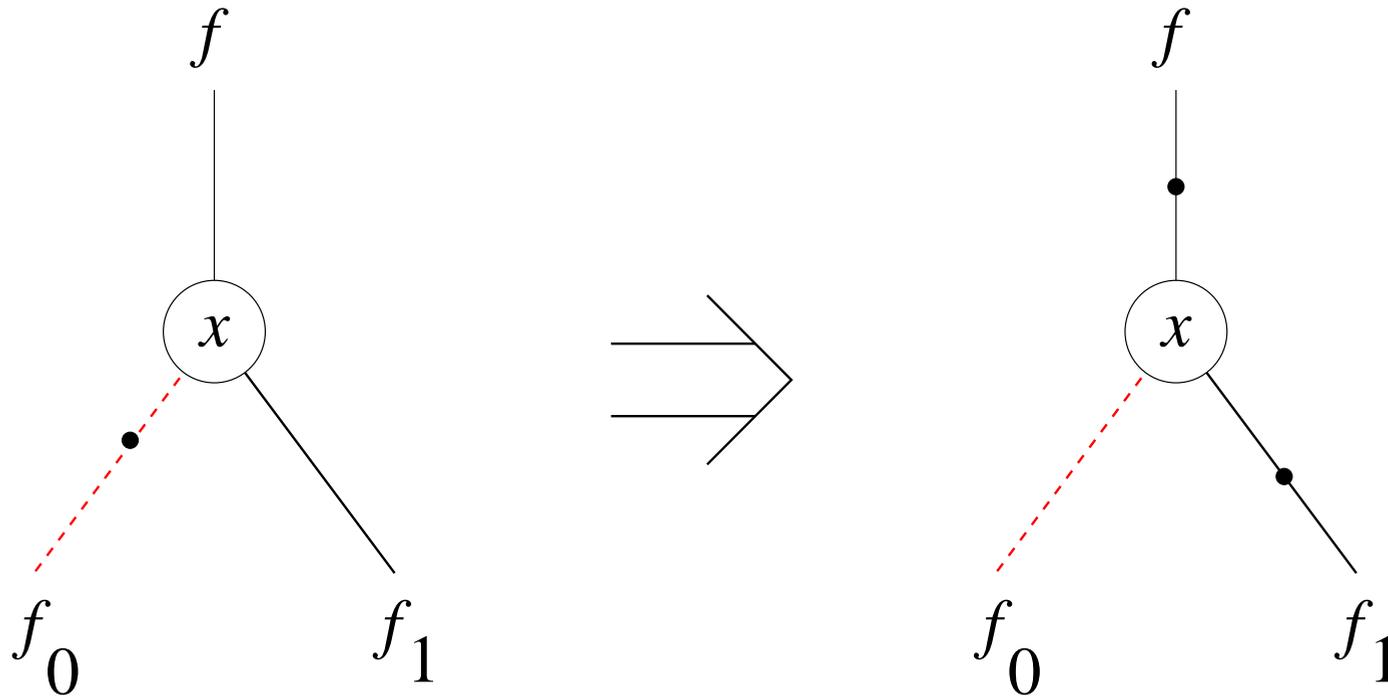
```
#define false_bdd ((BDD*) 0)
```

```
#define is_constant_bdd(ptr) \  
    ((ptr) == true_bdd || (ptr) == false_bdd)
```

```
#define UNIQUE_SIZE (1 << 20)
BDD *unique[UNIQUE_SIZE];

BDD **
find_bdd (int idx, BDD * c0, BDD * c1)
{
    BDD *r, **p;
    unsigned h = (idx + ((int) c0) * 65537 + 13 * (int) c1);
    h = h & (UNIQUE_SIZE - 1);
    for (p = unique + h; (r = *p); p = &r->next)
        if (r->idx == idx && r->child[0] == c0 && r->child[1] == c1)
            break;

    return p;
}
```



$$\begin{aligned}
 \text{ite}(x, f_1, \overline{f_0}) &\equiv x \cdot f_1 \vee \overline{x} \cdot \overline{f_0} \equiv \overline{(\overline{x} \vee \overline{f_1}) \cdot (x \vee f_0)} \\
 &\equiv \overline{x \cdot \overline{f_1} \vee \overline{x} \cdot f_0 \vee \overline{f_1} \cdot f_0} \\
 &\equiv \overline{x \cdot \overline{f_1} \vee \overline{x} \cdot f_0} \equiv \text{ite}(x, \overline{f_1}, f_0)
 \end{aligned}$$

```
BDD *
new_bdd_aux (int idx, BDD * c0, BDD * c1)
{
    BDD *res;

    assert (!sign_bdd (c0));

    if ((res = *find_bdd (idx, c0, c1)))
        return res;

    res = (BDD *) malloc (sizeof (BDD));
    memset (res, 0, sizeof (BDD));
    res->idx = idx;
    res->child[0] = c0;
    res->child[1] = c1;
    *find_bdd (idx, c0, c1) = res;

    return res;
}
```

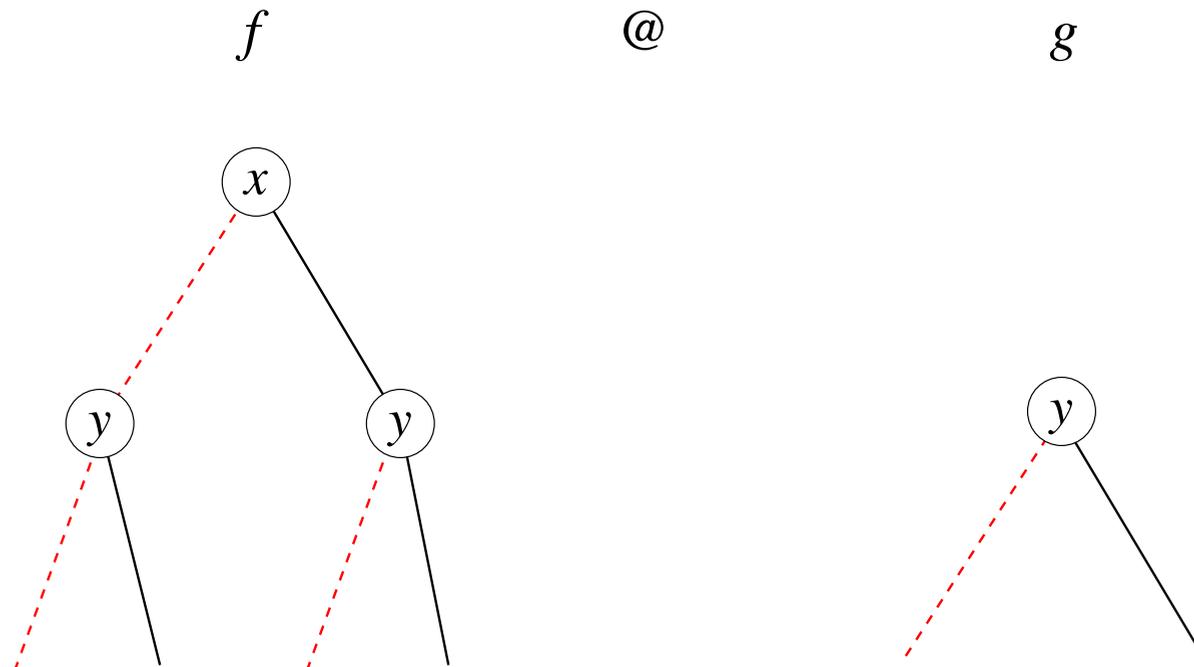
```
BDD *
new_bdd (int idx, BDD * c0, BDD * c1)
{
    BDD *res;
    int sign;

    if (c0 == c1)
        return c0;

    if ((sign = sign_bdd (c0)))
    {
        c0 = not_bdd (c0);
        c1 = not_bdd (c1);
    }

    res = new_bdd_aux (idx, c0, c1);

    return sign ? not_bdd (res) : res;
}
```



$$(f \wedge g)(x) \equiv x \cdot (f_1 \wedge g) \vee \bar{x} \cdot (f_0 \wedge g)$$

bei nicht passenden Indizes wird nur ein Knoten zerlegt

```
int
top_idx_bdd (BDD * a, BDD * b)
{
    int res[2];
    res[0] = (is_constant_bdd (a)) ? -1 : strip_bdd (a)->idx;
    res[1] = (is_constant_bdd (b)) ? -1 : strip_bdd (b)->idx;
    return res[res[0] < res[1]];
}
```

gibt einfach den Index der Variablen im obersten Knoten zurück

(hier kann einer der beiden Argumente eine Konstante sein)

```
BDD *
cofactor (BDD * bdd, int pos, int idx)
{
    BDD *res;
    int sign;
    if (is_constant_bdd (bdd))
        return bdd;
    if ((sign = sign_bdd (bdd))
        bdd = not_bdd (bdd);
    res = (bdd->idx == idx) ? bdd->child[pos] : bdd;
    return sign ? not_bdd (res) : res;
}
```

pos-ter Kofaktor von bdd ist pos-tes Kind wenn Variablen-Index passt

ansonsten wird der gleiche BDD zurückgegeben

(man beachte Propagierung des Vorzeichens)

void

```
cofactor2 (BDD * a, BDD * b, BDD * c[2][2], int *idx_ptr)
{
    int idx = *idx_ptr = top_idx_bdd (a, b);
    c[0][0] = cofactor (a, 0, idx);
    c[0][1] = cofactor (a, 1, idx);
    c[1][0] = cofactor (b, 0, idx);
    c[1][1] = cofactor (b, 1, idx);
}
```

bestimme Top-Index der beiden BDDs a und b und

berechne Kofaktoren bezüglich des Top-Index

```
BDD *
basic_and (BDD * a, BDD * b)
{
    assert (is_constant_bdd (a) && is_constant_bdd (b));
    return (BDD *) (((unsigned) a) & (unsigned) b);
}
```

```
BDD *
basic_or (BDD * a, BDD * b)
{
    assert (is_constant_bdd (a) && is_constant_bdd (b));
    return (BDD *) (((unsigned) a) | (unsigned) b);
}
```

```
BDD *
basic_xor (BDD * a, BDD * b)
{
    assert (is_constant_bdd (a) && is_constant_bdd (b));
    return (BDD *) (((unsigned) a) ^ (unsigned) b);
}
```

```
typedef BDD *(*BasicFunctor) (BDD *, BDD *);

BDD *
apply (BasicFunctor op, BDD * a, BDD * b)
{
    BDD *tmp[2], *c[2][2];
    int idx;
    if (is_constant_bdd (a) && is_constant_bdd (b))
        return op (a, b);
    cofactor2 (a, b, c, &idx);
    tmp[0] = apply (op, c[0][0], c[1][0]);
    tmp[1] = apply (op, c[0][1], c[1][1]);
    return new_bdd (idx, tmp[0], tmp[1]);
}
```

Definition eines Funktions-Pointer-Typ, zur Aufnahme von Operationen

```
BDD *  
and_bdd (BDD * a, BDD * b)  
{  
    return apply (basic_and, a, b);  
}
```

```
BDD *  
or_bdd (BDD * a, BDD * b)  
{  
    return apply (basic_or, a, b);  
}
```

```
BDD *  
xor_bdd (BDD * a, BDD * b)  
{  
    return apply (basic_xor, a, b);  
}
```

```
BDD *  
var_bdd (int idx)  
{  
    return new_bdd (idx, false_bdd, true_bdd);  
}
```

- es fehlt noch ein **Cache**: dann linear in beiden Argumenten
im Cache merkt man sich schon mal durchgeführte Berechnungen
dann können alle Knoten von beiden Argumenten nur einmal auftreten
- **Optimierung**: Spezialalgorithmen für AND und XOR einführen
auch wenn nur ein Argument konstant ist, kann man früher abbrechen
ebenso, wenn beide Argumente bis auf das Vorzeichen identisch sind
- weitere BDD-Algorithmen basieren auf gleichem Schema:
Kofaktoren bestimmen, Rekursion, mit Shannon zusammensetzen

- Kanonische Datenstruktur für boolesche Funktionen
- kein Allheilmittel aber wesentlich besser als DNF
- häufig kompakt für in der Praxis auftretenden Funktionen
- Trade-Off: *Platz statt Zeit*
- Anwendungen:
Synthese, Symbolische Simulation, Equivalence Checking, Model-Checking