

Parametrisierte Algorithmen

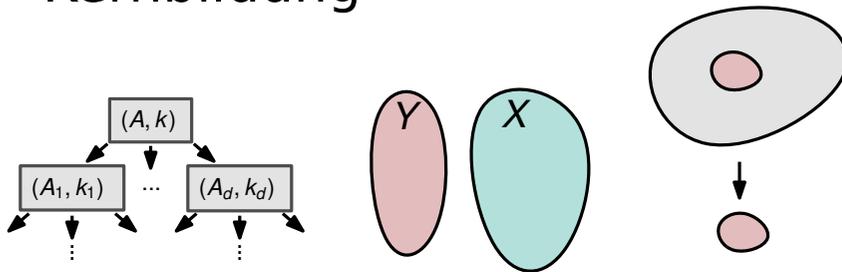
Untere Schranken: parametrisierte Komplexität und Datenbanken



Inhalt

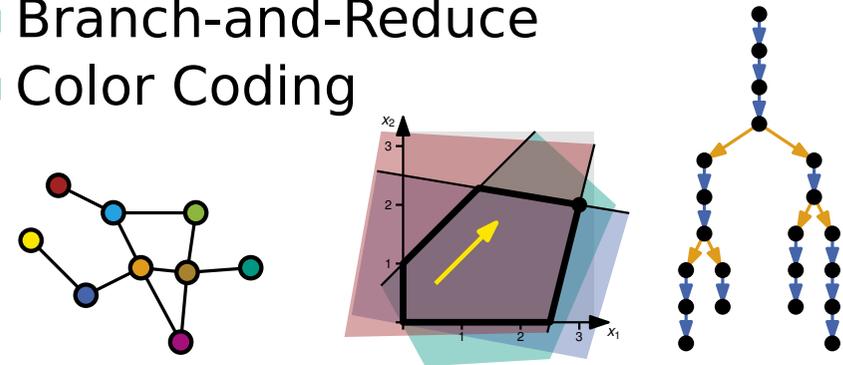
Basic Toolbox

- beschränkte Suchbäume
- iterative Kompression
- Kernbildung



Erweiterte Toolbox

- lineare Programme
- Branch-and-Reduce
- Color Coding



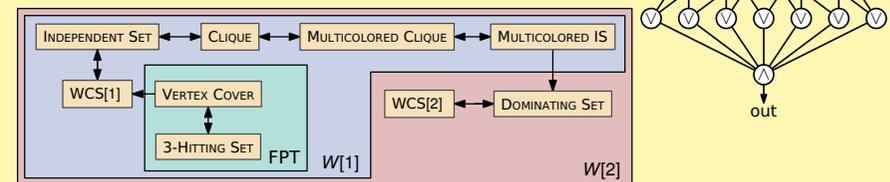
Baumweite

- dynamische Programme
- chordale & planare Graphen
- Courcelles Theorem



Untere Schranken

- parametrisierte Reduktionen
- boolesche Schaltkreise und die W-Hierarchie
- ETH und SETH



Wiederholung: Boolesche Schaltkreise

Definition

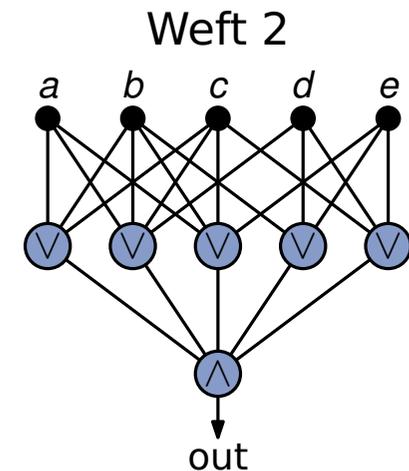
Der **Weft** eines Booleschen Schaltkreises ist die maximale Anzahl an Knoten mit Eingangsgrad > 2 auf einem gerichteten Pfad.

Problem

WCS $[t]$ ist WCS eingeschränkt auf Schaltkreise mit konstanter Tiefe und Weft maximal t .

Definition

Die Klasse **W** $[t]$ enthält die Probleme, die eine parametrisierte Reduktion auf WCS $[t]$ zulassen.



Bemerkungen

- Problem \mathcal{L} ist $W[t]$ -vollständig, wenn
 - $\mathcal{L} \in W[t]$
 - \mathcal{L} $W[t]$ -schwer (jedes $\mathcal{L}' \in W[t]$ lässt sich parametrisiert auf \mathcal{L} reduzieren)
- WCS $[t]$ ist per Definition $W[t]$ -vollständig
- Vermutung: $FPT \subset W[1] \subset W[2] \subset W[3] \subset \dots$

Leichte und schwere Reduktionen

Wie zeigen wir $W[t]$ -Vollständigkeit?

- reduziere auf und von anderem vollständigen Problem
- für $W[1]$: INDEPENDENT SET oder CLIQUE
- für $W[2]$: DOMINATING SET oder HITTING SET
- für $t > 2$: hier haben wir nur $WCS[t]$ zur Verfügung

Reduktion nach $WCS[t]$

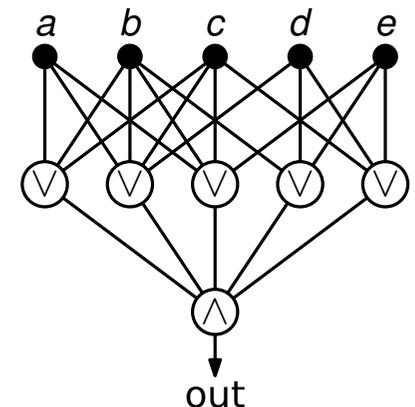
(Enthaltensein in $W[t]$)

- WCS ist eine mächtige Modellierungssprache
- Reduktion ist üblicherweise relativ einfach

Reduktion von $WCS[t]$

- dieser Teil ist meist deutlich schwerer
- ein Grund: der Schaltkreis kann sehr wüst aussehen
(nicht so, wie der da →)
- Idee: verbiete wüste Schaltkreise → Normalisierung
- zeige $W[t]$ -Schwere für normalisierte Schaltkreise
- und reduziere dann von diesen weiter

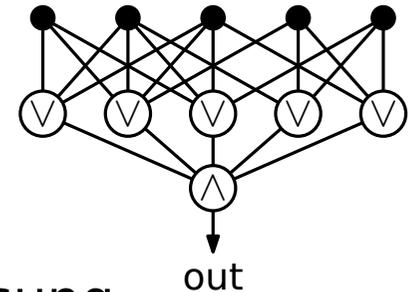
($W[t]$ -Schwere)



Normalisierte Schaltkreise

Der Schaltkreis für DOMINATING SET

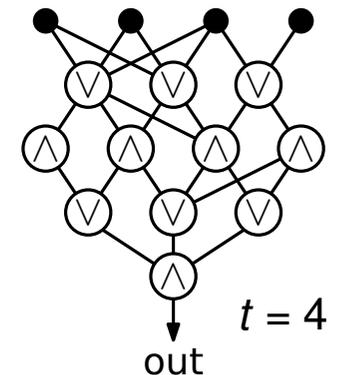
- auf jedem Pfad alternieren \wedge - und \vee -Knoten
- Ausgabeknoten (unterste Lage) ist ein \wedge -Knoten
- nur positive Variablen \Rightarrow Schaltkreis ist **monoton**
- Implikation: Supermenge einer Lösung ist ebenfalls Lösung



WEIGHTED MONOTONE t -NORMALIZED SATISFIABILITY

- t Lagen alternierender \wedge - und \vee -Knoten
- \wedge -Knoten als Ausgabeknoten
- keine \neg -Knoten erlaubt
- also: Konj. von Disj. von Konj. ... von positiven Literalen

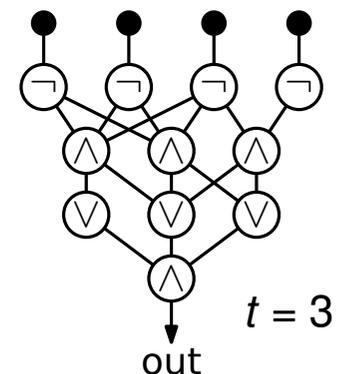
$\underbrace{\hspace{15em}}$
 t „von“s



WEIGHTED ANTIMONOTONE t -NORMALIZED SATISFIABILITY

- jetzt muss jeder Eingangsknoten negiert werden
- also: Konj. von Disj. von Konj. ... von negativen Literalen

$\underbrace{\hspace{15em}}$
 t „von“s



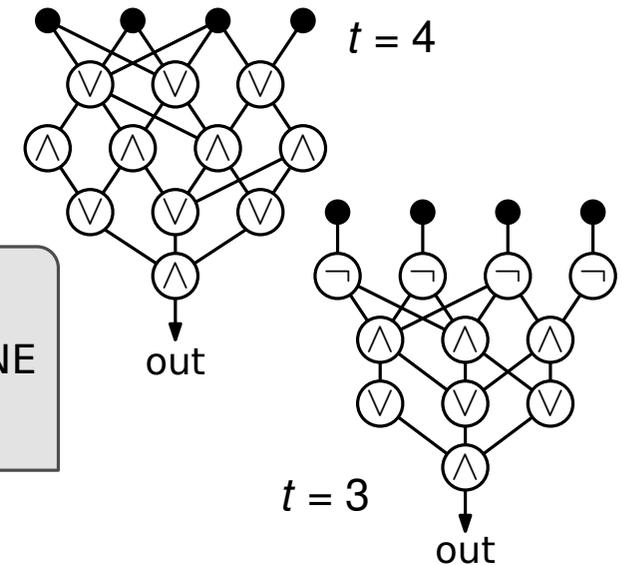
Normalisierte Schaltkreise

Theorem

Für jedes gerade $t \geq 2$ ist WEIGHTED MONOTONE t -NORMALIZED SATISFIABILITY $W[t]$ -vollständig.

Theorem

Für jedes ungerade $t \geq 3$ ist WEIGHTED ANTIMONOTONE t -NORMALIZED SATISFIABILITY $W[t]$ -vollständig.



Anmerkungen

- WMNS[t] und WANS[t] sind offensichtlich in $W[t]$ enthalten
- die Schwierigkeit besteht darin $W[t]$ -Schwere zu zeigen
- wir können jetzt also von WMNS[t] bzw. WANS[t] reduzieren um $W[t]$ -Schwere zu zeigen
- Tendenz: wähle gerades t für Minimierungs- und ungerades t für Maximierungsprobleme

Schlüsselkandidaten in Datenbanken

Definition

Eine Spaltenmenge A ist eine **Unique Column Combination**, wenn die Einschränkung auf A kein Tupel mehrfach enthält.

Beispiel

- keine einzelne Spalte ist unique
- {Vorname, Nachname} ist unique
- {Geburtstag, Wohnort} nicht

	Vorname	Nachname	Geburtstag	Wohnort
	Max	Mustermann	1.6.	Karlsruhe
r_2	Bob	Mustermann	7.10.	Berlin
	Bob	Baumeister	4.3.	Hamburg
	Alice	Liddell	4.5.	Wunderland
r_5	Alice	Musterfrau	7.10.	Berlin

Problem: UNIQUE

Gegeben eine Datenbank und ein Parameter k . Gibt es eine Unique Column Combination der Größe maximal k ?

Leicht andere Sichtweise

- Zeilenpaar $(r_2, r_5) \Rightarrow$ **Vor-** oder **Nachname** muss enthalten sein
- jedes Zeilenpaar (r_i, r_j) liefert Spaltenmenge $A_{i,j}$ aus der mindestens ein Element gewählt werden muss

Was ist das für ein Problem? \rightarrow HITTING SET

UNIQUE ist $W[2]$ -vollständig

Gerade gesehen

- parametrisierte Reduktion von UNIQUE auf HITTING SET
- HITTING SET ist $W[2]$ -vollständig \Rightarrow UNIQUE $\in W[2]$

Zeige: Reduktion von HITTING SET auf UNIQUE

Instanz von HITTING SET

$U = \{a, b, c, d, e\}$

$S_1 = \{a, b, c\}$

$S_2 = \{a, d, e\}$

$S_3 = \{b, d, e\}$

$S_4 = \{b, c\}$

Instanz von UNIQUE

	A	B	C	D	E
r_0	0	0	0	0	0
r_1	1	1	1	0	0
r_2	2	0	0	2	2
r_3	0	3	0	3	3
r_4	0	4	4	0	0

- verwende eine Spalte pro Element
 - jedes S_i muss von einem Zeilenpaar repräsentiert werden
 - Benutze die 0-Zeile s_0 für jedes Paar
 - Paar (r_0, r_i) stellt sicher, dass ein Element aus S_i gewählt wird
 - also: Lösung für UNIQUE \Rightarrow Lösung für HITTING SET
 - **Achtung:** andere Paare liefern auch Bedingungen
 - aber: (r_i, r_j) liefert $S_i \cup S_j$
 - r_i von r_0 unterscheidbar $\Rightarrow r_i$ von r_j unterscheidbar
 - also: Lösung für HITTING SET \Rightarrow Lösung für UNIQUE
- \Rightarrow UNIQUE ist $W[2]$ -schwer

Funktionale Abhängigkeiten

Beobachtung

- {Nachname} ist kein Unique
- der Nachname identifiziert also nicht das gesamte Tupel
- aber: der Nachname identifiziert den Wohnort

Vorname	Nachname	Geburtstag	Wohnort
Max	Mustermann	7.10.	Karlsruhe
Bob	Mustermann	1.6.	Karlsruhe
Bob	Baumeister	7.10.	Karlsruhe
Alice	Liddell	4.5.	Wunderland
Alice	Musterfrau	4.3.	Berlin
	X		A

Definition

(Grundsätzliche Annahme: $A \notin X$)

Für eine Spaltenmenge X und eine Spalte A ist $X \rightarrow A$ eine **Funktionale Abh.**, wenn $r_i[A] \neq r_j[A] \Rightarrow r_i[X] \neq r_j[X]$ für alle Zeilenpaare (r_i, r_j) .

Welche der folgenden Abhängigkeiten gelten?

- {Vorname} \rightarrow {Geburtstag}
- {Geburtstag} \rightarrow {Vorname}
- {Geburtstag} \rightarrow {Wohnort}
- {Vorname} \rightarrow {Wohnort}
- {Vorname, Geburtstag} \rightarrow {Wohnort}
- {Wohnort, Geburtstag} \rightarrow {Vorname}

Funktionale Abhängigkeiten

Problem: FD

Gegeben eine Datenbank und ein Parameter k . Gibt es eine funktionale Abhängigkeit $X \rightarrow A$ mit $|X| \leq k$?

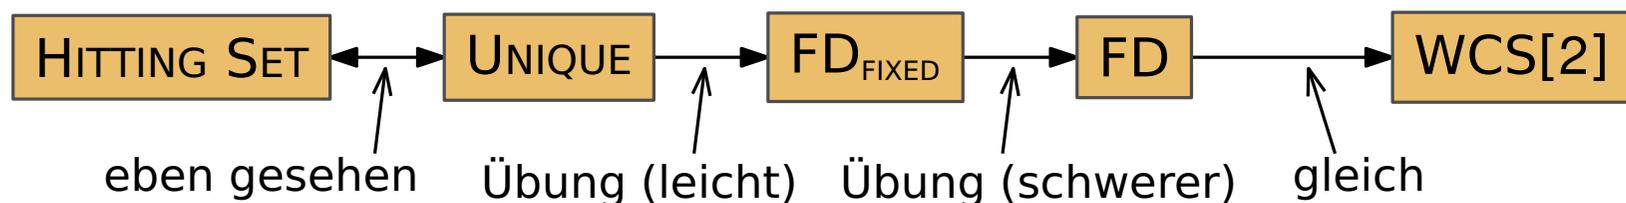
Zeige $W[2]$ -Schwere für FD

- reduziere von UNIQUE
- leichter, wenn im Problem FD die rechte Seite A feststeht

Problem: FD_{FIXED}

Gegeben eine Datenbank, eine Spalte A und ein Parameter k . Gibt es eine funktionale Abhängigkeit $X \rightarrow A$ mit $|X| \leq k$?

Reduktionen



- HITTING SET und WCS[2] sind $W[2]$ -vollständig
 \Rightarrow FD_{FIXED} und FD sind $W[2]$ -vollständig

FD \rightarrow WCS[2]

Definition

(Grundsätzliche Annahme: $A \notin X$)

Für eine Spaltenmenge X und eine Spalte A ist $X \rightarrow A$ eine **Funktionale Abh.**, wenn $r_i[A] \neq r_j[A] \Rightarrow r_i[X] \neq r_j[X]$ für alle Zeilenpaare (r_i, r_j) .

Grober Plan

- modelliere die Bedingungen von FD mittels Boolescher Formeln
- verwende für jede Bedingung nur \vee und ein \wedge am Ende (CNF)
 - (\Rightarrow Schaltkreis wird 2-normalisiert und damit Weft-2 (wenn auch nicht monoton))

Was sind die Bedingungen? Welche Variablen benutzen wir?

- **RHS** besteht aus genau einer Spalte
- **LHS** und **RHS** sind disjunkte Spaltenmengen
- wenn $r_i[A] \neq r_j[A]$ für ein Zeilenpaar (r_i, r_j) und $A \in \text{RHS}$, dann: es gibt Spalte B mit $r_i[B] \neq r_j[B]$ und $B \in \text{LHS}$
- Indikatorvariablen x_A und x'_A für $A \in \text{LHS}$ bzw. $A \in \text{RHS}$

RHS besteht aus genau einer Spalte

- mindestens eine Spalte: $\bigvee_{\text{Spalte } A} x'_A$
- nicht zwei Spalten A und B in der RHS: $\neg x'_A \vee \neg x'_B$

FD \rightarrow WCS[2]

Definition

(Grundsätzliche Annahme: $A \notin X$)

Für eine Spaltenmenge X und eine Spalte A ist $X \rightarrow A$ eine **Funktionale Abh.**, wenn $r_i[A] \neq r_j[A] \Rightarrow r_i[X] \neq r_j[X]$ für alle Zeilenpaare (r_i, r_j) .

Grober Plan

- modelliere die Bedingungen von FD mittels Boolescher Formeln
- verwende für jede Bedingung nur \vee und ein \wedge am Ende (CNF)
 - (\Rightarrow Schaltkreis wird 2-normalisiert und damit Weft-2 (wenn auch nicht monoton))

Was sind die Bedingungen? Welche Variablen benutzen wir?

- **RHS** besteht aus genau einer Spalte
- **LHS** und **RHS** sind disjunkte Spaltenmengen
- wenn $r_i[A] \neq r_j[A]$ für ein Zeilenpaar (r_i, r_j) und $A \in \text{RHS}$, dann:
 - es gibt Spalte B mit $r_i[B] \neq r_j[B]$ und $B \in \text{LHS}$
- Indikatorvariablen x_A und x'_A für $A \in \text{LHS}$ bzw. $A \in \text{RHS}$

LHS und RHS sind disjunkt

- für jede Spalte A : $\neg x_A \vee \neg x'_A$

FD \rightarrow WCS[2]

Definition (Grundsätzliche Annahme: $A \notin X$)
 Für eine Spaltenmenge X und eine Spalte A ist $X \rightarrow A$ eine **Funktionale Abh.**, wenn $r_i[A] \neq r_j[A] \Rightarrow r_i[X] \neq r_j[X]$ für alle Zeilenpaare (r_i, r_j) .

Grober Plan

- modelliere die Bedingungen von FD mittels Boolescher Formeln
- verwende für jede Bedingung nur \vee und ein \wedge am Ende (CNF)
 (\Rightarrow Schaltkreis wird 2-normalisiert und damit Weft-2 (wenn auch nicht monoton))

Was sind die Bedingungen? Welche Variablen benutzen wir?

- **RHS** besteht aus genau einer Spalte
- **LHS** und **RHS** sind disjunkte Spaltenmengen
- wenn $r_i[A] \neq r_j[A]$ für ein Zeilenpaar (r_i, r_j) und $A \in \text{RHS}$, dann:
 es gibt Spalte B mit $r_i[B] \neq r_j[B]$ und $B \in \text{LHS}$
- Indikatorvariablen x_A und x'_A für $A \in \text{LHS}$ bzw. $A \in \text{RHS}$

LHS und RHS bilden funktionale Abhängigkeit

- für jede Spalte A , und jedes Paar (r_i, r_j) mit $r_i[A] \neq r_j[A]$:

$$\neg x'_A \vee \bigvee_{\substack{\text{Spalte } A \neq B \\ r_i[B] \neq r_j[B]}} x_B$$

FD \rightarrow WCS[2]

Definition

(Grundsätzliche Annahme: $A \notin X$)

Für eine Spaltenmenge X und eine Spalte A ist $X \rightarrow A$ eine **Funktionale Abh.**, wenn $r_i[A] \neq r_j[A] \Rightarrow r_i[X] \neq r_j[X]$ für alle Zeilenpaare (r_i, r_j) .

Grober Plan

- modelliere die Bedingungen von FD mittels Boolescher Formeln
- verwende für jede Bedingung nur \vee und ein \wedge am Ende (CNF)
 - (\Rightarrow Schaltkreis wird 2-normalisiert und damit Weft-2 (wenn auch nicht monoton))

Was sind die Bedingungen? Welche Variablen benutzen wir?

- **RHS** besteht aus genau einer Spalte
- **LHS** und **RHS** sind disjunkte Spaltenmengen
- wenn $r_i[A] \neq r_j[A]$ für ein Zeilenpaar (r_i, r_j) und $A \in \text{RHS}$, dann: es gibt Spalte B mit $r_i[B] \neq r_j[B]$ und $B \in \text{LHS}$
- Indikatorvariablen x_A und x'_A für $A \in \text{LHS}$ bzw. $A \in \text{RHS}$

Theorem

Die Probleme UNIQUE, FD_{FIXED} und FD sind $W[2]$ -vollständig.

Inclusion Dependency

Ziel: finde Daten in einer Datenbank, die in einer anderen enthalten sind

Schema R

Schema S

A	B	C	D	E	F	G
1	1	1	4	1	3	1
3	1	2	3	3	4	1
1	2	1	3	3	3	2
2	3	3	4	2	1	3
3	4	4	2	4	1	3
			4	4	4	3

- betrachte Spalten $X = \{A, C\} \subseteq R$

- und Abbildung $\sigma: X \rightarrow S$ mit $\sigma(A) = G$ und $\sigma(C) = E$

- Tupel für X : $\{11, 32, 23, 34\}$

\cap

- Tupel für $\sigma(X)$: $\{11, 13, 23, 32, 34\}$

Definition

Betrachte die Instanzen r und s zweier Schemata R bzw. S . Eine Teilmenge $X \subseteq R$ zusammen mit einer injektiven Abbildung $\sigma: X \rightarrow S$ ist eine **Inclusion Dependency**, wenn $r[X] \subseteq s[\sigma(X)]$.

Problem: IND

Gegeben seien zwei Datenbanken r und s sowie ein Parameter k . Gibt es eine Inclusion Dependency der Größe k ?

Problem: IND_{FIXED}

Gegeben seien r und s mit gleichem Schema und ein Parameter k . Gibt es eine Inclusion Dependency der Größe k mit der Identität als σ ?

Finde die größte Inclusion Dependency

5	M	I	N	P	A	U	S	E
1	1	4	3	3	3	1	1	3
4	1	2	4	4	3	3	1	3
2	4	3	2	3	1	3	4	2
1	3	4	4	2	3	2	2	4
2	3	4	1	1	2	3	2	3
4	1	1	4	2	2	2	3	1
2	3	1	1	2	1	4	2	2
				4	4	1	4	4

Lösung

- $X = \{5, M, N\}$
- $\sigma(5) = S, \sigma(M) = U$ und $\sigma(N) = P$

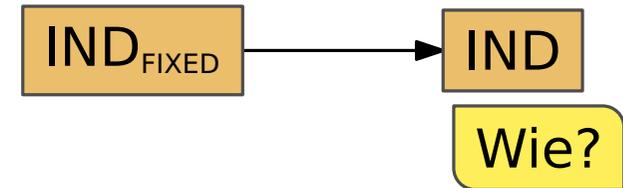
Definition

Betrachte die Instanzen r und s zweier Schemata R bzw. S . Eine Teilmenge $X \subseteq R$ zusammen mit einer injektiven Abbildung $\sigma: X \rightarrow S$ ist eine **Inclusion Dependency**, wenn $r[X] \subseteq s[\sigma(X)]$.

IND ist $W[3]$ -Vollständig

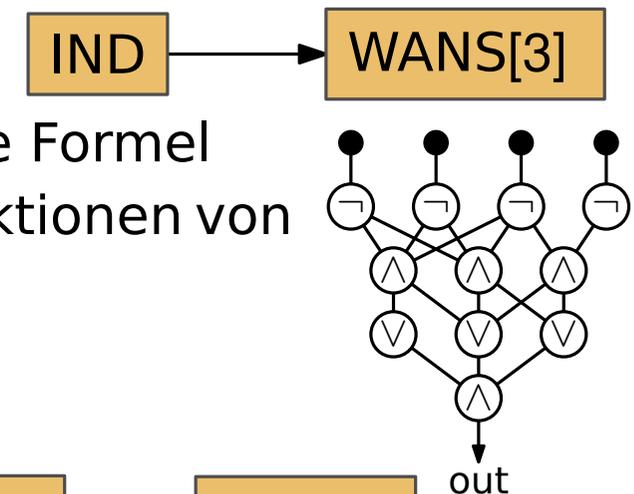
IND_{FIXED} und IND

- Reduktion von IND_{FIXED} auf IND ist einfach



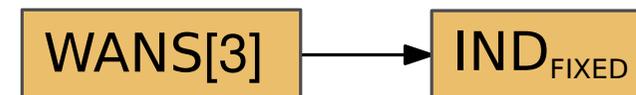
IND und $WANS[3]$

- Reduktion von IND auf $WANS[3]$
- modelliere die IND-Bedingungen als Boolesche Formel
- stelle sicher: es ist eine Konjunktion von Disjunktionen von Konjunktionen von negierten Variablen

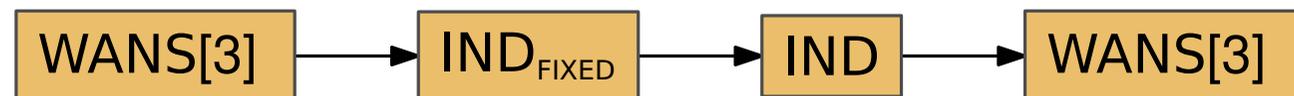


$WANS[3]$ und IND_{FIXED}

- Reduktion von $WANS[3]$ auf IND_{FIXED}
- modelliere antimonotone 3-normalisierte Boolesche Formeln mittels zweier Datenbanken



Gesamtplan:



WANS[3] \rightarrow IND_{FIXED}

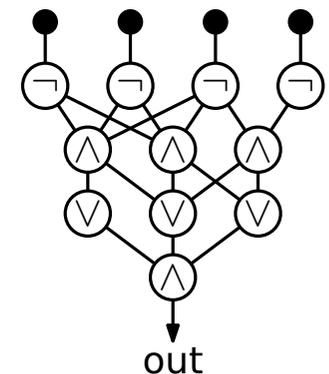
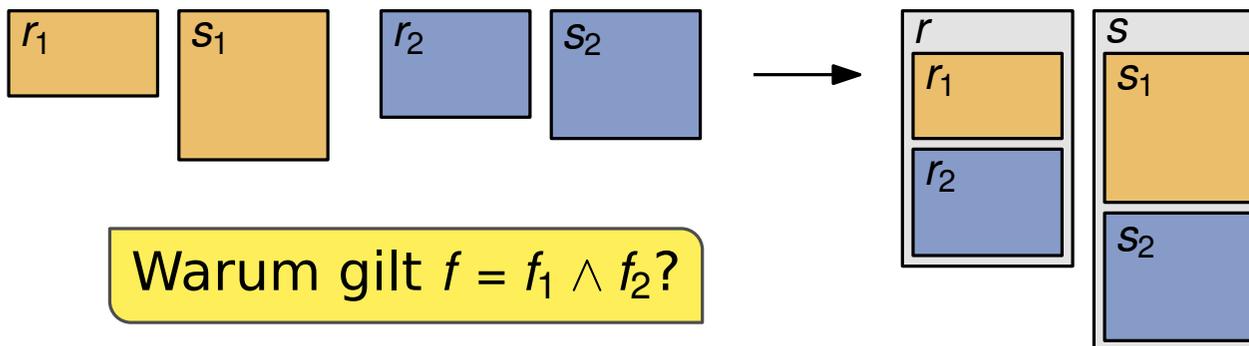
IND_{FIXED} aufgefasst als Boolesche Funktion

- fasse eine Spaltenmenge als 01-String auf
(Bsp: $\{A, C\} \hat{=} 101$)
- betrachte $f: \{0, 1\}^n \rightarrow \{0, 1\}$, mit $f(x) = 1 \Leftrightarrow x$ ist Inclusion Dependency für (r, s)
(Bsp: $f(101) = 1, f(110) = 0$)

Datenbank r			Datenbank s		
A	B	C	A	B	C
1	1	1	1	3	1
3	1	2	1	4	3
1	2	1	2	3	3
2	3	3	3	1	2
3	4	4	3	1	4
			3	4	4

Verundung von zwei Instanzen (über dem gleichen Schema)

- betrachte Instanzen (r_1, s_1) und (r_2, s_2) mit Funktionen f_1 bzw. f_2
- git es Instanz (r, s) , sodass $f = f_1 \wedge f_2$?
- Idee: Sorge dafür, dass (r_1, s_1) und (r_2, s_2) disjunkte Werte haben und schreibe die Instanzen einfach untereinander



WANS[3] \rightarrow IND_{FIXED}

Lemma

Gegeben zwei IND_{FIXED}-Instanzen mit Indikatorfunktionen f_1 und f_2 , dann gibt es eine (nicht zu große) IND_{FIXED}-Instanz mit Indikatorfunktion $f_1 \wedge f_2$.

Zwischenstand

- Konjunktionen können wir also schon modellieren
- können wir auf ähnliche Art auch Disjunktionen modellieren?
- falls ja, dann wäre IND_{FIXED} sogar $W[t]$ -schwer, für beliebiges t

Ziel: modelliere Disjunktion von Konjunktionen von negierten Variablen

$$\varphi = c_1 \vee c_2 \vee c_3$$

$$c_1 = (\neg x_1 \wedge \neg x_2 \wedge \neg x_3)$$

$$c_2 = (\neg x_2 \wedge \neg x_4 \wedge \neg x_5)$$

$$c_3 = (\neg x_1 \wedge \neg x_3 \wedge \neg x_4 \wedge \neg x_6)$$

$r:$

$A_1 \ A_2 \ A_3 \ A_4 \ A_5 \ A_6$

0 0 0 0 0 0

$s:$

$A_1 \ A_2 \ A_3 \ A_4 \ A_5 \ A_6$

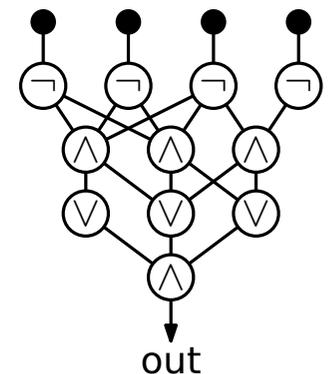
1 1 1 0 0 0

0 1 0 1 1 0

1 0 1 1 0 1

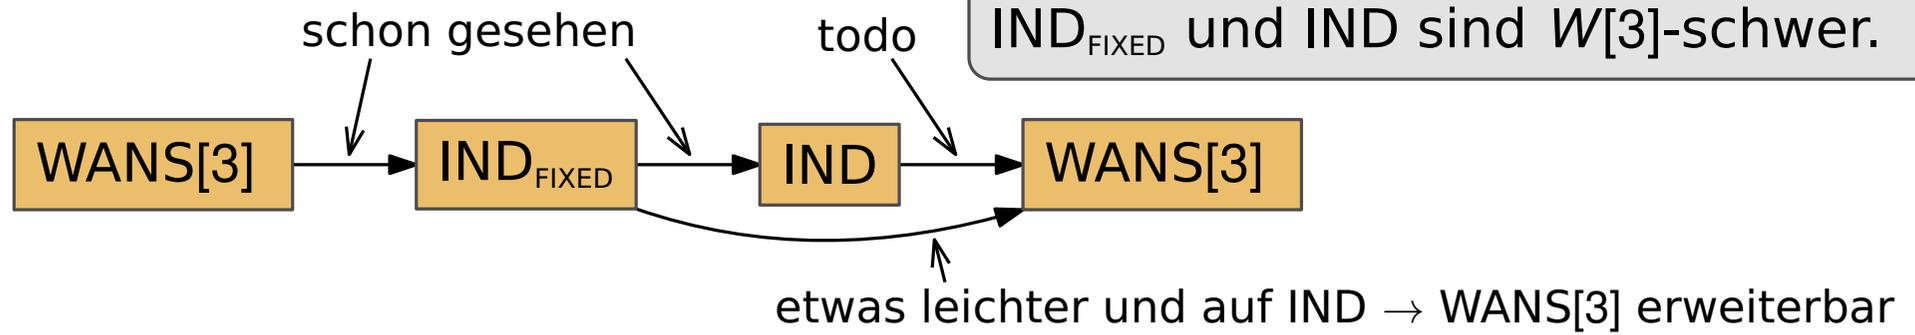
- ein einzelnes c_i darstellen ist leicht
- Veroderung der c_i : biete in s jedes der c_i einmal an

Check: Lösung für φ liefert Lösung für (r, s) und umgekehrt



Zwischenstand

Theorem
 IND_{FIXED} und IND sind $W[3]$ -schwer.



Welche Bedingungen müssen wir modellieren?

- einzelnes Zeilenpaar (r_i, s_j) : wähle gewisse Elemente nicht

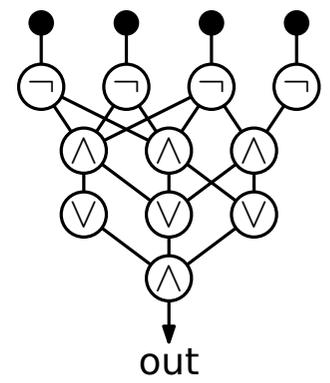
A_1	A_2	A_3	A_4	A_1	A_2	A_3	A_4	→			
r_j	1	0	1	0	s_j	1	1	0	0		$\neg X_2 \wedge \neg X_3$

- r_i und mehrere Zeilen in s : erfülle eine der vorherigen Bedingungen

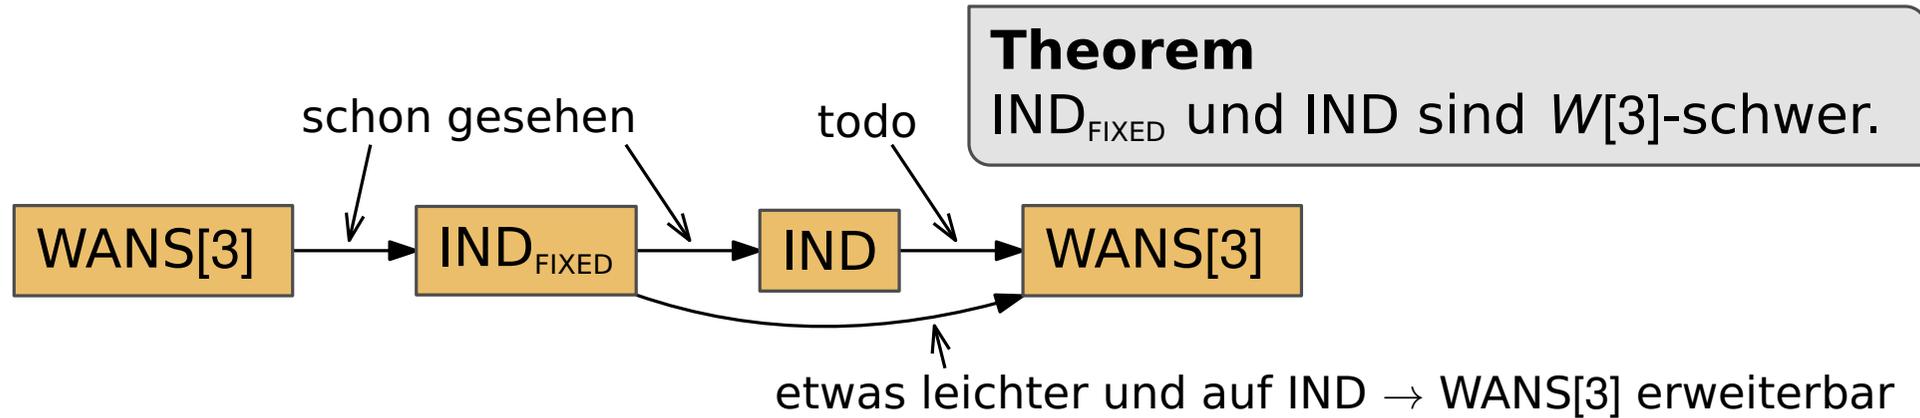
A_1	A_2	A_3	A_4	A_1	A_2	A_3	A_4	→					
r_j	1	0	1	0	s_1	1	1	0	0		$\neg X_2 \wedge \neg X_3$	∨	$\neg X_1 \wedge \neg X_2$
					s_2	0	1	1	0				

- mehrere Zeilen in r : erfülle Bedingungen für jede Zeile

A_1	A_2	A_3	A_4	A_1	A_2	A_3	A_4	→					
r_1	1	0	1	0	s_1	1	1	0	0		$\neg X_2 \wedge \neg X_3$	∨	$\neg X_1 \wedge \neg X_2$
r_2	0	1	0	1	s_2	0	1	1	0		$\neg X_1 \wedge \neg X_4$	∨	$\neg X_3 \wedge \neg X_4$



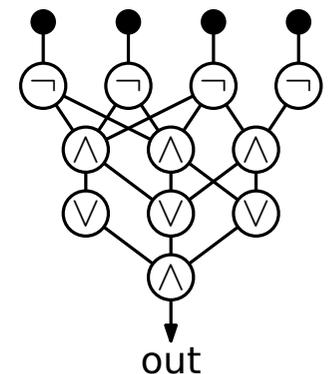
Zwischenstand



Erweiterung auf $IND \rightarrow WANS[3]$

- benutze Variablen $x_{i,j}$ mit der Bedeutung, dass $x_{i,j} = 1 \Leftrightarrow$ Spalte i in R wird ausgewählt und auf Spalte j in S abgebildet
- Sorge dafür, dass man eine Bijektion erhält
- kombiniere das, mit den Bedingungen von vorher

Theorem
 IND_{FIXED} und IND sind $W[3]$ -vollständig.



Zusammenfassung

Normalisierte Schaltkreise

- bei Reduktionen von WCS können wir mit recht aufgeräumten Schaltkreisen starten
- brauchen uns dann nicht mehr um Weft t kümmern (stattdessen: Anzahl alternierender Ebenen)
- gerades t : monoton; ungerades t : antimonoton

Dependency Detection

- es müssen nicht immer nur Graphen sein
- es gibt auch natürliche $W[3]$ -vollständige Probleme
- erklärt nicht, warum funktionale Abhängigkeiten in der Praxis schnell ausgerechnet werden können
(tatsächlich können sogar alle inklusionsminimalen UCCs/FDs aufgezählt werden)

Literaturhinweise

The Parameterized Complexity of Dependency Detection in Relational Databases

- Thomas Bläsius, Tobias Friedrich, Martin Schirneck [2016]
- enthält die eben gesehenen Reduktionen
doi.org/10.4230/LIPIcs.IPEC.2016.6

Profiling relational data: a survey

- Ziawasch Abedjan, Lukasz Golab, Felix Naumann [2015]
- Überblick zum Finden von Abhängigkeiten in Datenbanken
doi.org/10.1007/s00778-015-0389-y

Hitting Set Enumeration with Partial Information for Unique Column Combination Discovery

- Johann Birnick, Thomas Bläsius, Tobias Friedrich, Felix Naumann, Thorsten Papenbrock, Martin Schirneck [2020]
- in der Praxis effizienter Algo zum Aufzählen von Unique Column Combinations
doi.org/10.14778/3407790.3407824

Discovering Functional Dependencies through Hitting Set Enumeration

- Tobias Bleifuß, Thorsten Papenbrock, Thomas Bläsius, Martin Schirneck, Felix Naumann [2024]
- in der Praxis effizienter Algo zum Aufzählen von funktionalen Abhängigkeiten
doi.org/10.1145/3639298