Kapitel 4

Tableau-Algorithmen

Ziel des Kapitels

Automatisches Schlussfolgern spielt zentrale Rolle für BLen:

- ermöglicht die Entwicklung intelligenter Anwendungen
- die Ausdrucksstärke von BLen ist stark darauf zugeschnitten

Wichtig für automatisches Schlussfolgern:

1. Entscheidbarkeit der relevanten Schlussfolgerungsprobleme
2. möglichst geringe Komplexität
3. Algorithmen, die sich in der Praxis performant verhalten

Dieses Kapitel: $1 + 3$

Ziel des Kapitels

Wir konzentrieren uns auf Erfüllbarkeit (vergl. Lemma 2.8)

Dabei betrachten wir

- sowohl Konzepte ohne TBoxen als auch generelle TBoxen;
- $\mathcal{ALC}$ und die Erweiterungen $\mathcal{ALCI}$ und $\mathcal{ALCQ}$

Kapitel 4

Tableau-Algorithmen

Entscheidbarkeit

Entscheidbarkeit 1

- Kapitel 2: C erfüllbar bzgl. $\mathcal{T}$ gdw $\underbrace{\mathcal{T}^{\#} \wedge \exists x.C^{\#}(x)}_{\text{FO Satz mit 2 Variablen}}$ erfüllbar ($\mathcal{ALCI}$).

Erfüllbarkeit im 2-Var. Fragment von FO entscheidbar

[GrädelKolaitisVardi97]

$\Rightarrow$ Erfüllbarkeit in $\mathcal{ALCI}$ bzgl. genereller TBoxen entscheidbar

Komplexität: NExpTime.

Konstruktion von $C^{\#}$ und $\mathcal{T}^{\#}$ linear,

Erfüllbarkeit im 2-Var. Fragment von FO NExpTime-vollständig.

Entscheidbarkeit 2

- Kapitel 3: $\mathcal{ALCQI}$ hat Baummodelleigenschaft.

  Es folgt:

  C erfüllbar bzgl. $\mathcal{T}$ gdw. $\mathcal{T}^{\#} \wedge \exists x.C^{\#}(x)$ erfüllbar in Baummodell

  Erfüllbarkeit von FO Formeln über Bäumen entscheidbar.

  (Satz von Rabin)

  $\Rightarrow$ Erfüllbarkeit in $\mathcal{ALCQI}$ bzgl. genereller TBoxen entscheidbar.

  Komplexität: nicht-elementar.

  Konstruktion von $C^{\#}$ und $\mathcal{T}^{\#}$ linear,

  Erfüllbarkeit von FO über Bäumen vollständig für nicht-elementare Zeit.

Entscheidbarkeit 3

- Kapitel 3:

  Wenn C erfüllbar bzgl. $\mathcal{T}$, dann haben C und $\mathcal{T}$ Modell der Grösse 2^n.

  (beschränkte Modelleigenschaft, gilt für $\mathcal{ALCI}$ und $\mathcal{ALCQ}$)

  Algorithmus für Erfüllbarkeit:

  Gegeben C und $\mathcal{T}$ so dass $|C| + |\mathcal{T}| = n$,

  - erzeuge alle Interpretation $\mathcal{I}$ mit $|\Delta|^{\mathcal{I}} \leq 2^n$
    (es gibt "nur" $2^{2^{n^3+2}}$ viele davon) T4.0
  - überprüfe, ob $\mathcal{I}$ Modell von C und $\mathcal{T}$
    (in Zeit polynomiell in $\mathcal{I}$, C und $\mathcal{T}$)

Entscheidbarkeit 3

Lemma 4.1. Gegeben sei $\mathcal{ALCQI}$-Konzept C, endl. Interpretation $\mathcal{I}$ und $d \in \Delta^{\mathcal{I}}$. Man kann in polynomieller Zeit (in $|C| + |\Delta^{\mathcal{I}}|$) entscheiden ob $d \in C^{\mathcal{I}}$.

T4.1

Korollar 4.2. Gegeben sei C, $\mathcal{T}$ in $\mathcal{ALCQI}$ und endl. Interpretation $\mathcal{I}$. Man kann in polynomieller Zeit (in $|C| + |\mathcal{T}| + |\Delta^{\mathcal{I}}|$) entscheiden ob $\mathcal{I}$ ein Modell von C und $\mathcal{T}$ ist.

(Model checking in Polynomialzeit)

Entscheidbarkeit 3

$\Rightarrow$ Erfüllbarkeit in $\mathcal{ALCI}$ und $\mathcal{ALCQ}$ bzgl. genereller TBoxen entscheidbar

Komplexität: 2-ExpTime

2-exponentiall viele Interpretationen müssen geprüft werden

jede Prüfung braucht polynomielle Zeit.

Kann leicht auf NExpTime verbessert werden.

Algorithmen in der Praxis

Geschilderte Ansätze kaum tauglich für die Praxis:

- Das 2-Variablen Fragment von FO und FO auf Bäumen sind komplizierter als $\mathcal{ALC}$, schwieriger im Sinne der Komplexitätstheorie, und kaum implementierbar

- Das Aufzählen aller Modelle ist ebenfalls nicht praktikabel: zu wenig zielorientiert!

Praktikable Algorithmen

In der Praxis haben sich hauptsächlich als effizient herausgestellt:

- Tableau-Algorithmen wie in RACER, FaCT++, Pellet, Hermit
- Resolutionsverfahren wie in KAON2

Tableau Algorithmen:

- werden heute in den meisten BL-Systemen eingesetzt
- wurden ursprünglich für FO und andere Logiken entwickelt
- versuchen, ein (Baum)modell für Eingabe zu konstruieren
- basieren auf der Anwendung von Regeln.

Kapitel 4

Tableau-Algorithmen

ALC ohne TBoxen

Tableau Algorithmus

Ziel:

Entwicklung eines Tableau Algorithmus für Erfüllbarkeit von $\mathcal{ALC}$ Konzepten (ohne TBoxen)

Negationsnormalform

Definition 4.3. (Negationsnormalform)
Konzept ist in *Negationsnormalform (NNF)* gdw. Negation nur auf atomare Konzepte angewendet wird.

Lemma 4.4.
Jedes Konzept kann in Linearzeit in ein äquivalentes Konzept in NNF umgewandelt werden.

T4.2

Wir nehmen an, dass Eingabekonzept C_0 in NNF ist.

I-Baum

Zugrundeliegende Datenstruktur repräsentiert (partielles) Baummodell

Definition 4.5 (I-Baum)
I-Baum für C_0 ist knoten- und kantenbeschrifteter Baum $(V, E, \mathcal{L})$ mit

- V Knotenmenge;
- $E \subseteq V \times \mathbf{N_R} \times V$ Menge beschrifteter Kanten;
- $\mathcal{L} : V \rightarrow \mathbf{2}^{\mathsf{sub}(C_0)}$ Knotenbeschriftung

T4.3

I-Baum

Definition 4.6 (Realisierbarkeit)
Sei $\boldsymbol{B = (V, E, \mathcal{L})}$ ein I-Baum. Baummodell $\boldsymbol{\mathcal{I}}$ *realisiert* $\boldsymbol{B}$ gdw. es gibt Funktion

$$\boldsymbol{\pi : V \to \Delta^{\mathcal{I}}}$$

so dass

- $\boldsymbol{(v, r, v') \in E}$ impliziert $\boldsymbol{(\pi(v), \pi(v')) \in r^{\mathcal{I}}}$;
- $\boldsymbol{C \in \mathcal{L}(v)}$ impliziert $\boldsymbol{\pi(v) \in C^{\mathcal{I}}}$.

$\boldsymbol{B}$ ist *realisierbar* wenn es Interpretation $\boldsymbol{\mathcal{I}}$ gibt, die $\boldsymbol{B}$ realisiert.

T4.4

Tableau Algorithmus

Tableau Algorithmus berechnet Sequenz

$$\boldsymbol{M_0, M_1, \ldots}$$

von Mengen von I-Bäumen.

$\boldsymbol{M_0 = \{B_{\text{ini}}\}}$ mit $\boldsymbol{B_{\text{ini}}}$ *initialer I-Baum* für $\boldsymbol{C_0}$:

$$\begin{aligned} \boldsymbol{V} &:= \{\boldsymbol{v_{\text{ini}}}\} \\ \boldsymbol{E} &:= \emptyset \\ \boldsymbol{\mathcal{L}(v_{\text{ini}})} &:= \{\boldsymbol{C_0}\} \end{aligned}$$

$\boldsymbol{M_{i+1}}$ aus $\boldsymbol{M_i}$ durch Anwendung von Tableau Regel

(Transformiert I-Baum in einen oder mehrere neue I-Bäume)

Tableau Regeln

Sei $(V, E, \mathcal{L})$ I-Baum.

$\sqcap$-Regel:

- wähle $v \in V$ und $C \sqcap D \in \mathcal{L}(v)$ so dass $\{C, D\} \not\subseteq \mathcal{L}(v)$
- erweitere $\mathcal{L}(v)$ um C und D

$\sqcup$-Regel:

- wähle $v \in V$ und $C \sqcup D \in \mathcal{L}(v)$ so dass $\{C, D\} \cap \mathcal{L}(v) = \emptyset$
- erweitere $\mathcal{L}(v)$ um C oder um D (ergibt zwei I-Bäeume)

Tableau Regeln

∃-Regel:

- wähle $v \in V$ und $\exists r.C \in \mathcal{L}(v)$ so dass

  es kein $v' \in V$ gibt mit $(v, r, v') \in E$ und $C \in \mathcal{L}(v')$

- erweitere V um neuen Knoten v' und E um (v, r, v'),

  setze $\mathcal{L}(v') = \{C\}$

∀-Regel:

- wähle $v, v' \in V$ und $\forall r.C \in \mathcal{L}(v)$ so dass

  $(v, r, v') \in E$ und $C \notin \mathcal{L}(v')$

- erweitere $\mathcal{L}(v')$ um C

Tableau Algorithmus

Berechnung von M_{i+1} aus M_i:

- Auswahl eines $B \in M_i$ und Anwendung einer der 4 Regeln
- Regelanwendung: ersetzen von B durch neuen I-Baum bzw. zwei neue I-Bäume ($\sqcup$-Regel)

Intuition: Regeln machen implizites Wissen explizit.

I-Baum ist *vollständig*, wenn keine Regel darauf anwendbar ist.

Ergebnis

Algorithmus stoppt, wenn keine Regel mehr anwendbar ist.

Rückgabe von

- "erfüllbar" wenn I-Baum gefunden wurde, der keinen *offensichtlichen Widerspruch* enthält:

$$\{A, \neg A\} \in \mathcal{L}(v) \text{ für ein } v \in V,\ A \in \mathbf{N_C}$$

- "unerfüllbar" sonst

T4.5

Lokale Korrektheit

Notation:

- Menge M von I-Bäumen ist *realisierbar* gdw. ein $B \in M$ realisierbar;
- Wir schreiben $M \rightarrow_{\mathsf{tab}} M'$, wenn M' aus M durch Anwendung von Tableau-Regel generiert werden kann.

Lemma 4.7 (Lokale Korrektheit)
Wenn $M \rightarrow_{\mathsf{tab}} M'$, dann M realisierbar gdw. M' realisierbar. T4.6

Terminierung

Proposition 4.8 (Terminierung)
Der Tableau Algorithmus stoppt nach endlicher Zeit. T4.7

Rollentiefe

Intuitiv: $\mathsf{rd}(C)$ ist Schachtelungstiefe von $\exists/\forall$-Konstruktoren in C,

Rollentiefe $\mathsf{rd}(C)$ von Konzepten $C \in \mathsf{sub}(C_0)$ induktiv definiert:

- $\mathsf{rd}(A) = \mathsf{rd}(\neg A) = 0$;
- $\mathsf{rd}(C \sqcap D) = \mathsf{rd}(C \sqcup D) = \max(\mathsf{rd}(C), \mathsf{rd}(D))$;
- $\mathsf{rd}(\exists r.C) = \mathsf{rd}(\forall r.C) = 1 + \mathsf{rd}(C)$.

Lemma 4.9. Für alle $C \in \mathsf{sub}(C_0)$ gilt $\mathsf{rd}(C) \leq |C|$.

Multimengen

Multimengen sind Mengen, in denen Elemente mehrfach vorkommen dürfen:

$$\{a, a, b, b, b\},\ \{1, 1, 2, 3, 4, 4, 5, 6, 6, 6\},\ \{\emptyset, \emptyset, \{\emptyset, \emptyset\}\}$$

Formal: Multimenge über Menge S ist Abbildung

$$M : S \to \mathbb{N}$$

die die Anzahl des Vorkommens der Elemente beschreibt

Die meisten Begriffe übertragen sich von Mengen auf Multimengen:

- Leere Menge $\emptyset$: $s \mapsto 0$ für alle $s \in S$
- Vereinigung: $(M_1 \cup M_2)(s) := M_1(s) + M_2(s)$
- Element: $s \in M$ gdw. $M(s) > 0$

Multimengen

- Differenz: $(M_1 \setminus M_2)(s) = \begin{cases} M_1(s) - M_2(s) & \text{wenn } M_1(s) \geq M_2(s) \\ 0 & \text{sonst} \end{cases}$
- Endlich: $\{s \in S \mid M(s) > 0\}$ endlich

$MM(S)$ bezeichnet die Menge aller endlichen Multimengen über S

Gegeben partielle Ordnung $(S, <)$ ist *Multimengenerweiterung* $(MM(S), <_{\text{mul}})$ definiert als:

$M_1 <_{\text{mul}} M_2$ gdw. $\exists X, Y \in MM(S)$ so dass:

- $\emptyset \neq X \subseteq M_1$;
- $M_2 = (M_1 \setminus X) \cup Y$;
- $\forall y \in Y \exists x \in X : x > y$.

Multimengen

Also: M_2 erhält man aus M_1 indem man einige Elemente entfernt und durch endlich viele kleinere ersetzt.

$$\{3,1\} >_{\text{mul}} \{2,2,2\} >_{\text{mul}} \{2,2\} >_{\text{mul}} \{2,1,1,1\}$$

Theorem.
Wenn $(S, <)$ fundiert ist, dann auch $(MM(S), <_{\text{mul}})$.

Korrektheit und Vollständigkeit

Proposition 4.10 (Korrektheit)
Wenn der Algorithmus "erfüllbar" zurückgibt, so ist C_0 erfüllbar. T4.8

Proposition 4.11 (Vollständigkeit)
Wenn C_0 erfüllbar, so gibt der Algorithmus "erfüllbar" zurück. T4.9

Komplexitätsanalyse

Beobachtungen:

- die I-Bäume können höchstens exponentiell gross werden (Beweis von Proposition 4.8)
- es gibt doppelt exponentiell viele I-Bäume dieser Größe

Erfüllbarkeitstest von

$$\forall r^i.C = \underbrace{\forall r.\cdots.\forall r.C}_{i \text{ mal}}$$

$$\bigsqcap_{i<n} \forall r^i.(\exists r.B \sqcap \exists r.\neg B)$$

$$\sqcap \forall r^n.(A' \sqcup A'')$$

generiert alle diese 2^{2^n} Bäume. T4.10

Also: doppelt exponentieller Zeit- und Platzverbrauch (Worst case).

Praktikabilität

Naive Implementation ist nicht effizient.

Implementierungsgrundlagen:

- Es wird nur ein Baum zur Zeit generiert, keine Menge
- bei der $\sqcup$-Regel muss man sich also entscheiden (Heuristik) ggf. Entscheidung revidieren (Backtracking)
- es wird nur ein Teil des Baumes (Pfad) im Speicher gehalten

Darüber hinaus gibt es zahlreiche effektive Optimierungstechniken.

Optimierungen: Backjumping

Form von dependenzbasiertem Backtracking:

- führe Buch über die "Herkuft" von Knotenbeschriftungen und Kanten mittels Dependenzmenge
- wenn Backtracking nötig (offens. Widerspruch), springe direkt zu einer der Ursachen des Widerspruches zurück.

Hat dramatische Effekte in der Praxis.

T4.11

Optimierungen: Caching

Grundidee:

- verschiedene Unterbäume sehen oft sehr ähnlich aus
  z.B.: alle r-Nachfolger bekommen dieselben Konzepte von $\forall$-Regel
- Anlegen eines Caches, der den Erfüllbarkeitsstatus von Unterbäumen (repräsentiert durch Knotenbeschriftung von Wurzel) speichert
- Wenn $\mathcal{L}(v) \subseteq S$ und S als erfüllbar gecacht,
  dann $\mathcal{L}(v)$ erfüllbar
- Wenn $S \subseteq \mathcal{L}(v)$ und S als unerfüllbar gecacht,
  dann $\mathcal{L}(v)$ unerfüllbar

Interagiert mit Backjumping.

Optimierungen

Es gibt noch viele weitere Optimierungen:

- Semantische Verzweigung (andere $\sqcup$-Regel)
- Lokale Vereinfachung von Knotenbeschriftungen
- Heuristiken für die Entscheidung bei $\sqcup$-Regel
- Normalformen für Konzepte,
- Kombinierte $\exists$- und $\forall$-Regel (Hypertableau)
- etc.

Kapitel 4

Tableau-Algorithmen

ALC mit generellen TBoxen

Tableau-Algorithmus

Ziel:

Entwicklung eines Tableau Algorithmus für Erfüllbarkeit
in $\mathcal{ALC}$ bzgl. genereller TBoxen

Jede generelle TBox $\mathcal{T}$ ist äquivalent zu einer TBox der Form $\{\top \sqsubseteq C_{\mathcal{T}}\}$:

setze $C_{\mathcal{T}} := \bigsqcap_{C \sqsubseteq D \in \mathcal{T}} C \rightarrow D$. T!!

(zur Erinnerung $C \rightarrow D$ ist Abk. für $\neg C \sqcup D$)

Wir nehmen an, dass

- Eingabe C_0 in NNF;
- Eingabe $\mathcal{T}$ hat Form $\{\top \sqsubseteq C_{\mathcal{T}}\}$ mit $C_{\mathcal{T}}$ in NNF.

Tableau-Algorithmus

Modifiziere vorigen Algorithmus durch Hinzufügen folgender Regel:

TBox-Regel:

- wähle $v \in V$ so dass $C_{\mathcal{T}} \notin \mathcal{L}(v)$
- erweitere $\mathcal{L}(v)$ um $C_{\mathcal{T}}$

Problem: Algorithmus terminiert nicht!

T4.12

Blockieren

Problem:

Die Tiefe von Baummodellen kann unendlich sein!

Lösung:

Konstruiere nur endliches Anfangsstück eines Baummodelles,

mittels dessen sich die Existenz eines vollst. Modelles entscheiden lässt.

Dazu müssen wir die Anwendung der $\exists$-Regel einschränken.

Blockieren

Definition 4.12. (Blockiert)
Sei $(V, E, \mathcal{L})$ I-Baum und $v, v' \in V$. Dann wird v' *direkt blockiert* von v wenn

1. v' von v erreichbar ist,
2. $\mathcal{L}(v') \subseteq \mathcal{L}(v)$ und
3. es keinen Knoten $v^* \neq v$ gibt, der 1. und 2. erfüllt und von v' erreichbar ist.

Knoten $v' \in V$ ist *indirekt blockiert* wenn es direkt blockiertes $v \in V$ gibt, von dem v' erreichbar ist.

Knoten $v \in V$ ist *blockiert* wenn v direkt oder indirekt blockiert.

T4.13

Blockieren

Neue $\exists$-Regel:

$\exists'$-Regel:

- wähle $v \in V$ und $\exists r.C \in \mathcal{L}(v)$ so dass

  v nicht blockiert ist und

  es kein $v' \in V$ gibt mit $(v, r, v') \in E$ und $C \in \mathcal{L}(v')$

- erweitere V um neuen Knoten v' und E um (v, r, v'),

  setze $\mathcal{L}(v') = \{C\}$

Tableau-Algorithmus

Folgende Resultate beweist man wie ohne TBoxen:

I-Baum $\boldsymbol{B}$ realisierbar *bzgl. TBox* $\boldsymbol{\mathcal{T}}$ wenn $\boldsymbol{B}$ realisierbar in Modell von $\boldsymbol{\mathcal{T}}$

Lemma 4.13 (Lokale Korrektheit)
Wenn $\boldsymbol{M} \rightarrow_{\mathsf{tab}} \boldsymbol{M'}$, dann
$\boldsymbol{M}$ realisierbar bzgl. $\boldsymbol{\mathcal{T}}$ gdw. $\boldsymbol{M'}$ realisierbar bzgl. $\boldsymbol{\mathcal{T}}$.

Proposition 4.14 (Vollständigkeit)
Wenn $\boldsymbol{C_0}$ erfüllbar bzgl. $\boldsymbol{\mathcal{T}}$, so gibt der Algorithmus "erfüllbar" zurück.

Tableau-Algorithmus

Es bleibt also zu zeigen:

Proposition 4.15 (Terminierung)
Der Tableau Algorithmus stoppt nach endlicher Zeit.

T4.14

Proposition 4.16 (Korrektheit)
Wenn der Algorithmus "erfüllbar" zurückgibt, so ist C_0 erfüllbar bzgl. $\mathcal{T}$.

T4.15

Komplexitätsanalyse

Beobachtungen:

- die I-Bäume können höchstens doppelt exponentiell gross werden (Beweis von Proposition 4.15)
- es gibt dreifach exponentiell viele I-Bäume dieser Größe

Lemma 4.17.
Es gibt Eingabe C_0, $\mathcal{T}$, für die der Tableau Algorithmus einen Baum von doppelt exponentieller Größe generiert.

T4.16

Also: dreifach exponentieller Zeit- und Platzverbrauch (Worst case).

Bemerkung zur TBox-Regel

Generelle TBoxen führen zu Backtracking:

Normalisierung $\mathcal{T}$ zu $\{\top \sqsubseteq \bigsqcap_{C \sqsubseteq D \in \mathcal{T}} C \rightarrow D\}$, also

$$\{\top \sqsubseteq \bigsqcap_{C \sqsubseteq D \in \mathcal{T}} \neg C \sqcup D\}$$

$\sqcup$-Regel für *jede* Konzeptinklusion auf *jeden* Knoten angewendet!

Für effiziente Implementierung braucht man Optimierungstechniken, die die Disjunktionen soweit möglich eliminieren ("Absorption").

Kapitel 4

Tableau-Algorithmen

Erweiterungen von ALC

Erweiterungen

Algorithmus kann auf $\mathcal{ALCI}$, $\mathcal{ALCQ}$ und $\mathcal{ALCQI}$ erweitert werden.

Das ist teilweise subtiler als erwartet!

- $\mathcal{ALCI}$

  Einfach: Hinzufügen von Regeln für $\exists r^-.C$ und $\forall r^-.C$

  Weniger offensichtlich: Blockierungsbedingung muss verschärft werden,

  sonst ist Algorithmus nicht korrekt!

Erweiterungen

- $\mathcal{ALCQ}$

  Einfach: Hinzufügen von Regeln für $(\geqslant n\ r\ C)$ und $(\leqslant n\ r\ C)$

  Identifikation von Knoten

  Weniger offensichtlich:

  - Um Terminierung zu gewährleisten, muss man sich Knotenpaare merken, die nicht identifiziert werden dürfen
  - Um Korrektheit zu gewährleisten, muss man
    - neue Art von "offensichtlichem Widerspruch" hinzufügen
    - eine weitere Verzweigende Regel hinzunehmen ("analytic cut", teuer!)

- $\mathcal{ALCQI}$: noch aufwendigere Blockierungsbedingung nötig.