

Stochastic Logic Programs



TECHNISCHE
UNIVERSITÄT
DARMSTADT

Johannes Lerch

Seminar aus maschinellem Lernen

Agenda

- Motivation
- Definition
- Wahrscheinlichkeitsverteilungen
- Anwendungsbeispiele
- Parameter Estimation

Kontextfreie Sprachen

- Ausdruck:

$$a^n b^n$$

- Grammatik:

$$S \rightarrow \emptyset$$
$$S \rightarrow aSb$$

Transformation zu Prolog

- Grammatik G:

$S \rightarrow \emptyset$

$S \rightarrow aSb$

- Prolog:

`s([]).`

`s(S) :- a(A), append(A,X,S), b(B), append(S1,B,X), s(S1).`

`a([a]).`

`b([b]).`

Stochastisch kontextfreie Grammatik

- Grammatik G:

$$0.5: S \rightarrow \emptyset$$

$$0.5: S \rightarrow aSb$$

$$P(\emptyset|G) = 0.5$$

$$P(ab|G) = 0.25$$

$$P(aabb|G) = 0,125$$

Stochastisch Logische Programme



TECHNISCHE
UNIVERSITÄT
DARMSTADT

- Modellierung einer Münze:
 `coin(head).`
 `coin(tail).`

- Eigentlich gemeint:
 0.5: `coin(head).`
 0.5: `coin(tail).`

Stochastisch Logische Programme



TECHNISCHE
UNIVERSITÄT
DARMSTADT

- Definition von SLP:
 - Eindeutig definiertes logisches Programm
 - Klauseln mit positiven Zahlen parametrisiert
- Pure SLP:
 - Alle Klauseln parametrisiert
- Impure SLP:
 - Nicht alle Klauseln parametrisiert
- Normalised SLP:
 - Parameter aller Klauseln mit gleichem Head summieren zu 1
→ Parameter entsprechen Wahrscheinlichkeiten

Beispiele für SLP



0.5: coin(head).

0.5: coin(tail).

1/6: roll_dice(1).

1/6: roll_dice(2).

1/6: roll_dice(3).

1/6: roll_dice(4).

1/6: roll_dice(5).

1/6: roll_dice(6).


Wahrscheinlichkeitsverteilung auf Ableitungen



- $S = \{l_1:C_1, \dots, l_n:C_n\}$
- $\lambda = (\ln l_1, \dots, \ln l_n)$
- $D(G) = \{x: x \text{ Ableitung, die bei } G \text{ beginnt}\}$
- $v_i(x)$ Anzahl Anwendungen C_i in x

$$\forall x \in D(G): \quad \psi_{(\lambda, S, G)}(x) = \prod_{i=1}^n l_i^{v_i(x)} = e^{\lambda v(x)}$$

Wahrscheinlichkeitsverteilung auf Ableitungen



- C_1 0.4: $s(X) :- p(X), p(X).$
- C_2 0.6: $s(X) :- q(X).$
- C_3 0.3: $p(a).$
- C_4 0.7: $p(b).$
- C_5 0.2: $q(a).$
- C_6 0.8: $q(b).$

$$\psi_{(\lambda, S, G)}(x) = \prod_{i=1}^n l_i^{v_i(x)} = e^{\lambda v(x)}$$

$$\psi_{(\lambda, S, :-s(X))}(C_1 C_3 C_3) = 0.4 * 0.3 * 0.3 = 0.036$$

$$\psi_{(\lambda, S, :-s(X))}(C_2 C_5) = 0.6 * 0.2 = 0.12$$

Wahrscheinlichkeitsverteilung auf Beweisen




- $S = \{l_1:C_1, \dots, l_n:C_n\}$
- $\lambda = (\ln l_1, \dots, \ln l_n)$
- $R(G) = \{x: x \text{ Beweis mit Anfang } G\}$
- $v_i(x)$ Anzahl Anwendungen C_i in x

$$\psi_{(\lambda, S, G)}(x) = \prod_{i=1}^n l_i^{v_i(x)} = e^{\lambda v(x)}$$

$$Z_{(\lambda, S, G)} = \sum_{x \in R(G)} \psi_{(\lambda, S, G)}(x)$$

$$\forall r \in R(G): \quad f_{(\lambda, S, G)}(r) = \frac{1}{Z_{(\lambda, S, G)}} \psi_{(\lambda, S, G)}(r)$$

Wahrscheinlichkeitsverteilung auf Beweisen



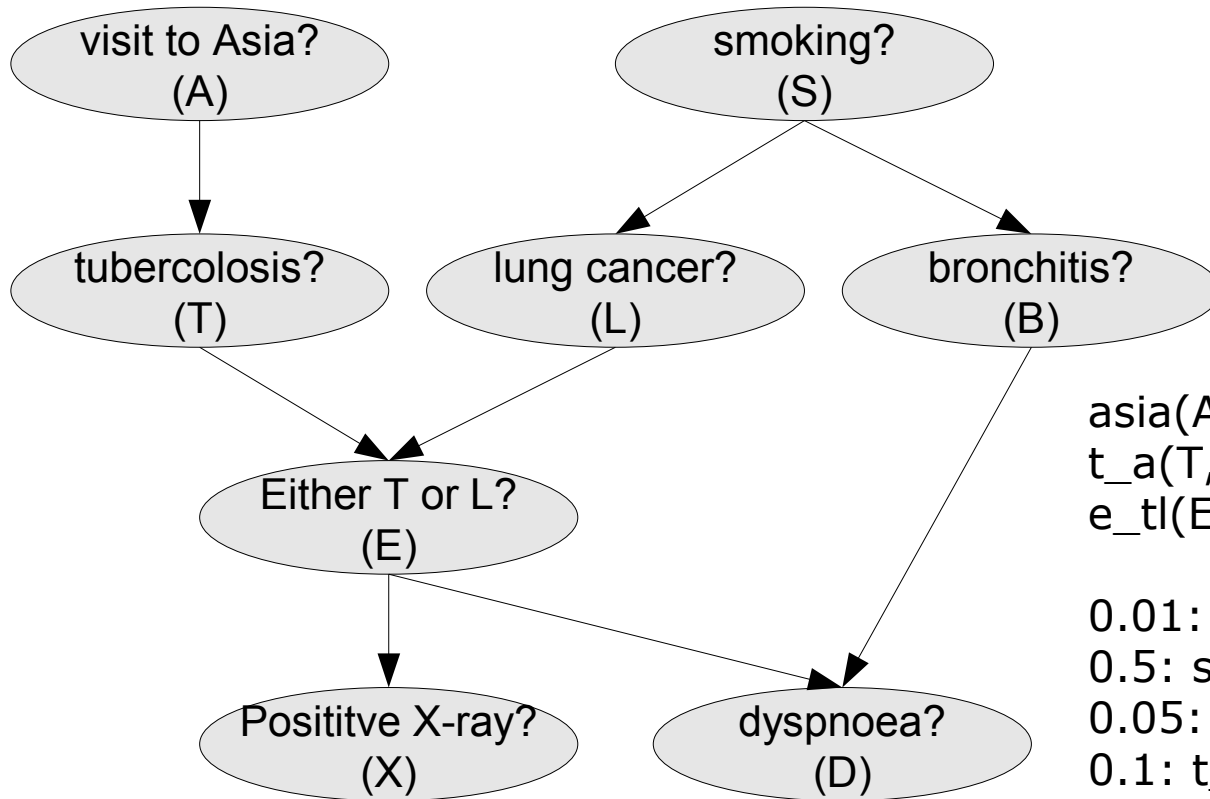
- C_1 0.4: $s(X) \text{ :- } p(X), p(X).$
- C_2 0.6: $s(X) \text{ :- } q(X).$
- C_3 0.3: $p(a).$
- C_4 0.7: $p(b).$
- C_5 0.2: $q(a).$
- C_6 0.8: $q(b).$

$$Z_{(\lambda, S, \text{:-s(X)})} = \sum_{x \in R(\text{:-s(X)})} \psi_{(\lambda, S, \text{:-s(X)})}(x) = 0.832$$

$$f_{(\lambda, S, \text{:-s(X)})}(C_1 C_3 C_3) = \frac{0.4 * 0.3 * 0.3}{0.832} = 0.043$$

$$f_{(\lambda, S, \text{:-s(X)})}(C_2 C_5) = \frac{0.6 * 0.2}{0.832} = 0.144$$

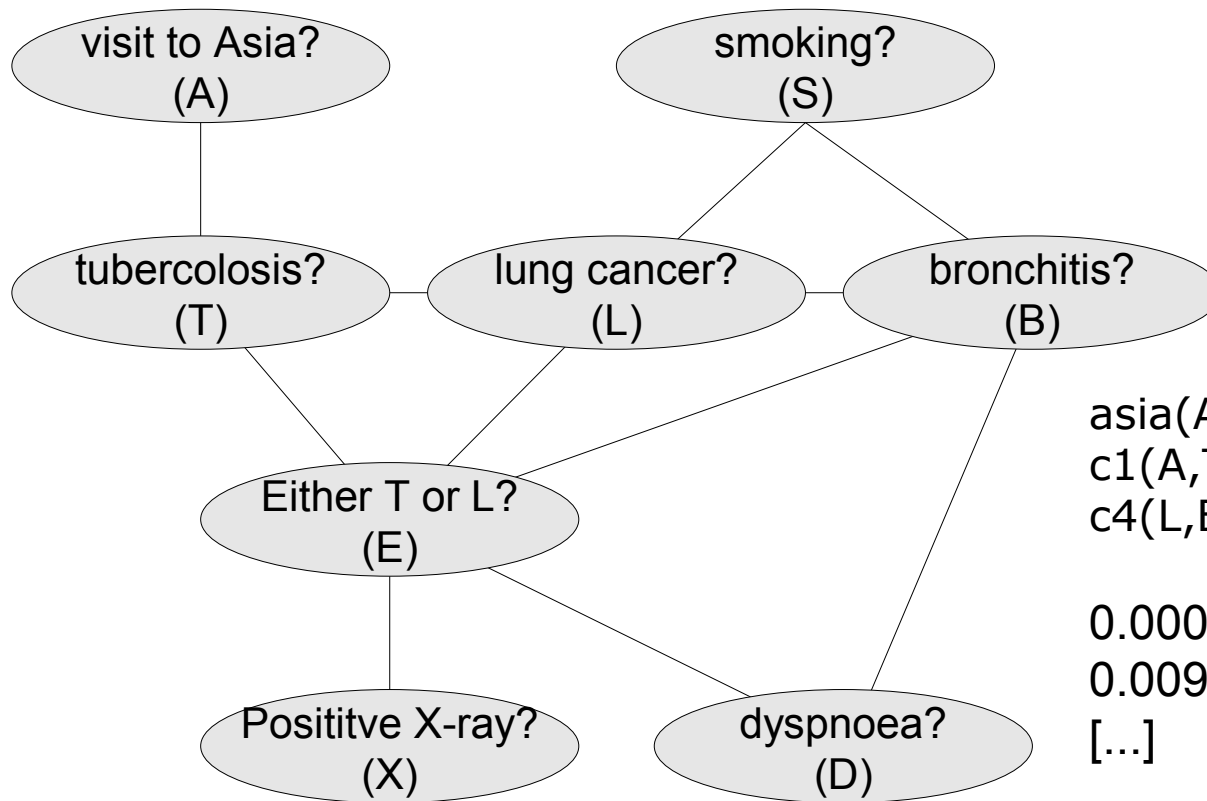
Anwendungsbeispiel: Bayes Netz



```
asia(A,T,E,S,L,B,X,D) :- a(A), s(S),  
t_a(T,A), l_s(L,S), b_s(B,S),  
e_tl(E,T,L), d_eb(D,E,B), x_e(X,E).
```

```
0.01: a(1).           0.99: a(0).  
0.5: s(1).           0.5: s(0).  
0.05: t_a(1,1).     0.95: t_a(0,1).  
0.1: t_a(1,0).     0.9: t_a(0,0).  
e_tl(0,0,0).       e_tl(1,0,1).  
e_tl(1,1,0).       e_tl(1,1,1).  
[...]
```

Anwendungsbeispiel: Markov Netz



asia(A,T,E,S,L,B,X,D) :-
c1(A,T), c2(L,S,B), c3(T,E,L),
c4(L,B,E), c5(E,D,B), c6(X,E).

0.0005: c1(1,1). 0.0095: c1(1,0).
0.0099: c1(0,1). 0.9801: c1(0,0).
[...]

Parameter Estimation

- Umkehrung des Problems:
 - Klauseln bekannt
 - Fakten bekannt durch Beobachtung von Daten
 - Parameter unbekannt
 - Schätze λ :
 - $S = \{I_1:C_1, \dots, I_n:C_n\}$
 - $\lambda = (\ln I_1, \dots, \ln I_n)$

Parameter Estimation

Vereinfachte Problemstellung

- Zunächst Vereinfachung:
 - Annahme: Jeder Fakt hat nur eine Herleitung

- Bekannte Klauseln:

C_1 $l_1: s(X,p) :- p(X),p(X).$

C_2 $l_2: s(X,q) :- q(X).$

C_3 $l_3: p(a).$

C_4 $l_4: p(b).$

C_5 $l_5: q(a).$

C_6 $l_6: q(b).$

Parameter Estimation

Vereinfachte Problemstellung

Beobachtung in den Daten

C_1	$l_1: s(X,p) :- p(X),p(X).$
C_2	$l_2: s(X,q) :- q(X).$
C_3	$l_3: p(a).$
C_4	$l_4: p(b).$
C_5	$l_5: q(a).$
C_6	$l_6: q(b).$



Fakt	\tilde{f}	Ableitung	f_λ
$s(a,p)$	1/3	$C_1 C_3 C_3$	$Z_\lambda^{-1} l_1 l_3^2$
$s(b,p)$	1/6	$C_1 C_4 C_4$	$Z_\lambda^{-1} l_1 l_4^2$
$s(a,q)$	1/4	$C_2 C_5$	$Z_\lambda^{-1} l_2 l_5$
$s(b,q)$	1/4	$C_2 C_6$	$Z_\lambda^{-1} l_2 l_6$

$$\begin{aligned}
 Z_\lambda &= l_1 l_3^2 + l_1 l_4^2 + l_2 l_5 + l_2 l_6 \\
 &= l_1 (l_3^2 + l_4^2) + l_2 (l_5 + l_6)
 \end{aligned}$$

Parameter Estimation

Vereinfachte Problemstellung

Fakt	\tilde{f}	Ableitung	f_λ	Klausel	$\tilde{f}[v_i]$	$f_\lambda[v_i]$
s(a,p)	1/3	$C_1 C_3 C_3$	$Z_\lambda^{-1} 1_1 1_3^2$	C_1	1/2	$Z_\lambda^{-1} 1_1 (1_3^2 + 1_4^2)$
s(b,p)	1/6	$C_1 C_4 C_4$	$Z_\lambda^{-1} 1_1 1_4^2$	C_2	1/2	$Z_\lambda^{-1} 1_2 (1_5 + 1_6)$
s(a,q)	1/4	$C_2 C_5$	$Z_\lambda^{-1} 1_2 1_5$	C_3	2/3	$Z_\lambda^{-1} 2 (1_1 1_3^2)$
s(b,q)	1/4	$C_2 C_6$	$Z_\lambda^{-1} 1_2 1_6$	C_4	1/3	$Z_\lambda^{-1} 2 (1_1 1_4^2)$
				C_5	1/4	$Z_\lambda^{-1} 1_2 1_5$
				C_6	1/4	$Z_\lambda^{-1} 1_2 1_6$



Löse Gleichungssystem nach $1_1, \dots, 1_n$ auf

Improved Iterative Scaling

- Initialisiere $\lambda^{(0)}$ beliebig
- 1.) Bestimme für jede Klausel C_i den Wert $y_i^{(h)} \in [-\infty, \infty]$ für:
$$f_{\lambda^{(h)}}[v_i e^{y_i^{(h)} v_{\#}}] = \tilde{f}[v_i]$$
- 2.) Setze $\lambda^{(h+1)} = y^{(h)} + \lambda^{(h)}$
- 3.) Setze $h \leftarrow h+1$ und mache weiter mit 1. bis $f_{\lambda^{(h)}}$ konvergiert

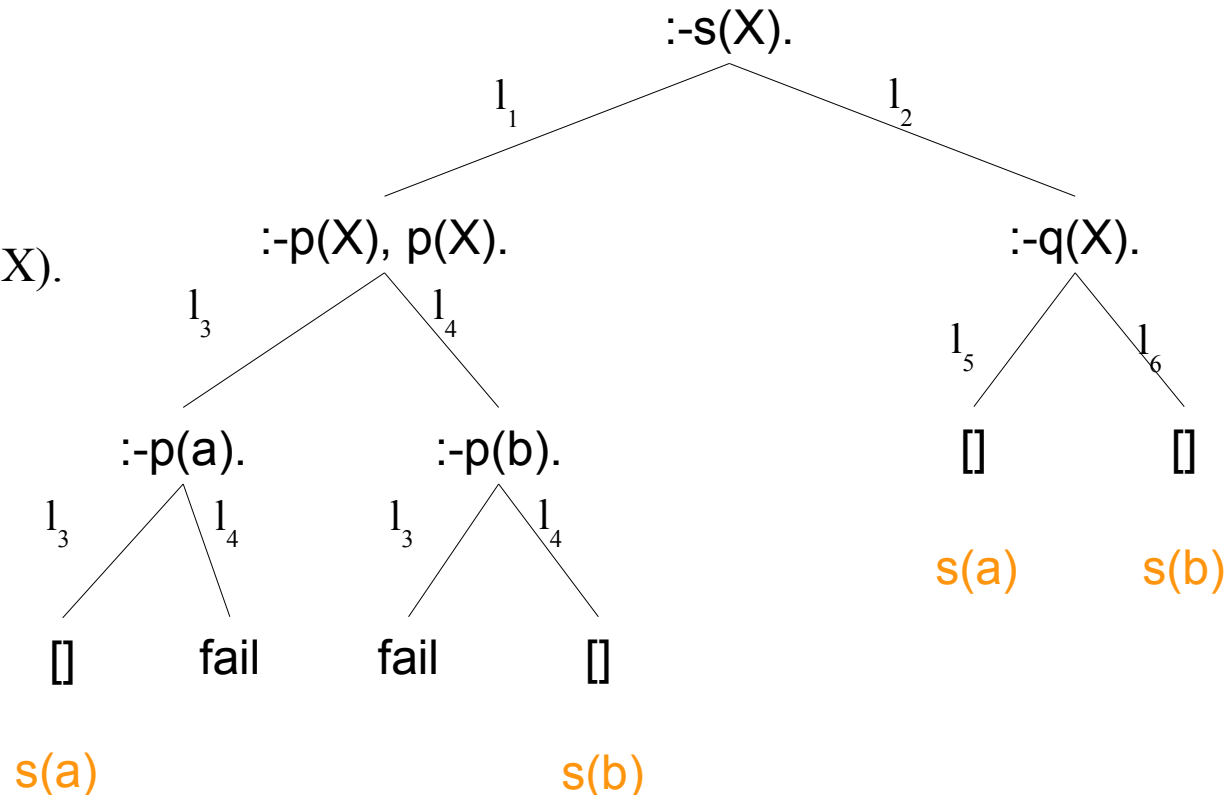
$$v_{\#}(r) = \sum_i v_i(r)$$

Parameter Estimation Verallgemeinerung

- Nun ohne Vereinfachung:
 - Fakt kann mehrere Ableitungen haben

- Bekannte Klauseln:

C_1	$l_1: s(X) :- p(X), p(X).$
C_2	$l_2: s(X) :- q(X).$
C_3	$l_3: p(a).$
C_4	$l_4: p(b).$
C_5	$l_5: q(a).$
C_6	$l_6: q(b).$



Parameter Estimation Verallgemeinerung

- Beobachtung in den Daten:

	s(a)	s(b)
Anzahl	7	5
\tilde{p}	7/12	5/12

y	r	$f_{\lambda}(r y)$	$f_{\lambda}(r)$
s(a)	$C_1 C_3 C_3$	$\frac{7}{12} \frac{l_1 l_3^2}{l_1 l_3^2 + l_2 l_5}$	$Z_{\lambda}^{-1} l_1 l_3^2$
s(a)	$C_2 C_5$	$\frac{7}{12} \frac{l_2 l_5}{l_1 l_3^2 + l_2 l_5}$	$Z_{\lambda}^{-1} l_2 l_5$
s(b)	$C_1 C_4 C_4$	$\frac{5}{12} \frac{l_1 l_4^2}{l_1 l_4^2 + l_2 l_6}$	$Z_{\lambda}^{-1} l_1 l_4^2$
s(b)	$C_2 C_6$	$\frac{5}{12} \frac{l_2 l_6}{l_1 l_4^2 + l_2 l_6}$	$Z_{\lambda}^{-1} l_2 l_6$

$$\begin{aligned}
 Z_{\lambda} &= l_1 l_3^2 + l_1 l_4^2 + l_2 l_5 + l_2 l_6 \\
 &= l_1 (l_3^2 + l_4^2) + l_2 (l_5 + l_6)
 \end{aligned}$$

Parameter Estimation

Verallgemeinerung



r	$f_\lambda(r y)$	$f_\lambda(r)$	Klausel	$f_\lambda[v_i y]$	$f_\lambda[v_i]$
$C_1 C_3 C_3$	$\frac{7}{12} \frac{l_1 l_3^2}{l_1 l_3^2 + l_2 l_5}$	$Z_\lambda^{-1} l_1 l_3^2$	C_1	$\frac{7}{12} \frac{l_1 l_3^2}{l_1 l_3^2 + l_2 l_5} + \frac{5}{12} \frac{l_1 l_4^2}{l_1 l_4^2 + l_2 l_6}$	$Z_\lambda^{-1} l_1 (l_3^2 + l_4^2)$
$C_2 C_5$	$\frac{7}{12} \frac{l_2 l_5}{l_1 l_3^2 + l_2 l_5}$	$Z_\lambda^{-1} l_2 l_5$	C_2	$\frac{7}{12} \frac{l_2 l_5}{l_1 l_3^2 + l_2 l_5} + \frac{5}{12} \frac{l_2 l_6}{l_1 l_4^2 + l_2 l_6}$	$Z_\lambda^{-1} l_2 (l_5 + l_6)$
$C_1 C_4 C_4$	$\frac{5}{12} \frac{l_1 l_4^2}{l_1 l_4^2 + l_2 l_6}$	$Z_\lambda^{-1} l_1 l_4^2$	C_3	$2 \frac{7}{12} \frac{l_1 l_3^2}{l_1 l_3^2 + l_2 l_5}$	$Z_\lambda^{-1} 2 (l_1 l_3^2)$
$C_2 C_6$	$\frac{5}{12} \frac{l_2 l_6}{l_1 l_4^2 + l_2 l_6}$	$Z_\lambda^{-1} l_2 l_6$	C_4	$2 \frac{5}{12} \frac{l_1 l_4^2}{l_1 l_4^2 + l_2 l_6}$	$Z_\lambda^{-1} 2 (l_1 l_4^2)$
			C_5	$\frac{7}{12} \frac{l_2 l_5}{l_1 l_3^2 + l_2 l_5}$	$Z_\lambda^{-1} l_2 l_5$
			C_6	$\frac{5}{12} \frac{l_2 l_6}{l_1 l_4^2 + l_2 l_6}$	$Z_\lambda^{-1} l_2 l_6$

Anpassung: Improved Iterative Scaling

- Initialisiere $\lambda^{(0)}$ beliebig
- 1.) Bestimme für jede Klausel C_i den Wert $y_i^{(h)} \in [-\infty, \infty]$ für:
$$f_{\lambda^{(h)}}[v_i e^{y_i^{(h)} v_{\#}}] = f_{\lambda^{(h)}}[v_i | y]$$
- 2.) Setze $\lambda^{(h+1)} = y^{(h)} + \lambda^{(h)}$
- 3.) Setze $h \leftarrow h+1$ und mache weiter mit 1. bis $f_{\lambda^{(h)}}$ konvergiert

$$v_{\#}(r) = \sum_i v_i(r)$$

Zusammenfassung

- Verallgemeinerung von stochastisch kontextfreien Grammatiken und Bayesschen Netzen
- Ausdrucksstarke, jedoch einfache Erweiterung logischer Programme
- Beschreibung & Lernen von Wahrscheinlichkeitsverteilungen

SLP Implementierungen

- Progol
 - Regellerner
 - Erzeugt intern SLP
 - Hier definierte Syntax nicht erlaubt
 - <http://www.doc.ic.ac.uk/~shm/progol.html>

- Chen, J., Kelley, L., Muggleton, S.: Protein Fold Discovery Using Stochastic Logic Programs
- Muggleton, S., Pahlavi, N.: Stochastic Logic Programs: A Tutorial
- Muggleton, S.: Stochastic Logic Programs
- Muggleton, S.: Learning Stochastic Logic Programs
- Cussens, J.: Parameter Estimation in Stochastic Logic Programs