

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ



هوش مصنوعی پیشرفته

فصل ۱۴

استدلال احتمالاتی

Probabilistic Reasoning

کاظم فولادی
دانشکده مهندسی برق و کامپیوتر
دانشگاه تهران

<http://courses.fouladi.ir/ai>

استدلال احتمالاتی

۱

بازنمایی
دانایی
در یک
دامنه‌ی
نامطمئن

شبکه‌های بیزی

BAYESIAN NETWORKS

شبکه‌ی بیزی

Bayesian Network

یک نمادگذاری ساده و گرافیکی برای بیان استقلال شرطی
(و در نتیجه برای مشخص‌سازی متراکم توزیع‌های توأم کامل)

شبکه‌های بیزی

نحو

BAYESIAN NETWORKS

شبکه‌ی بیزی <i>Bayesian Network</i>	
یک گراف جهت‌دار بدون دور	
گره‌ها <i>Nodes</i>	پیوندها <i>Links</i>
نشان‌دهنده‌ی متغیرهای تصادفی	نشان‌دهنده‌ی رابطه‌ی تأثیر مستقیم
توزیع شرطی <i>Conditional Distribution</i>	(link \approx "directly influences")
برای هر گره، توزیع شرطی آن گره به شرط والد‌های آن را داریم:	
$P(X_i Parents(X_i))$	
در قالب جدول احتمال شرطی (CPT)	

شبکه‌های بیزی

جدول احتمال شرطی

CONDITIONAL PROBABILITY TABLE (CPT)

توزیع شرطی به طور ساده در قالب **جدول احتمال شرطی** بازنمایی می‌شود.

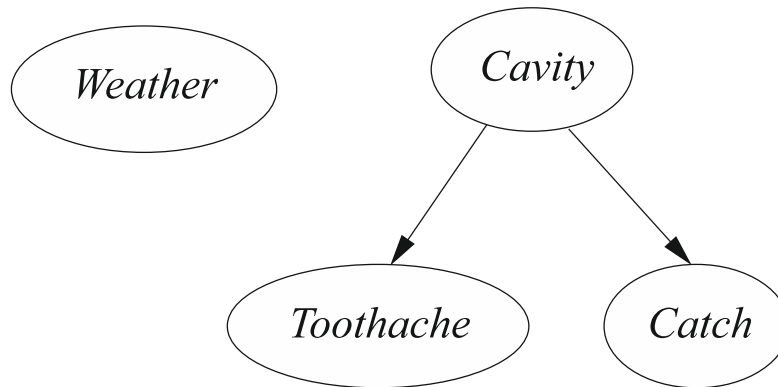
توزیع برای متغیر X_i برای هر ترکیب از مقادیر والد‌های آن

جدول احتمال شرطی
Conditional Probability Table

CPT

شبکه‌های بیزی

مثال

BAYESIAN NETWORKS

Weather is independent of the other variables

Toothache and *Catch* are conditionally independent given *Cavity*

توپولوژی شبکه‌ی بیزی بیان استقلال شرطی را کدگذاری می‌کند. 

شبکه‌های بیزی

مثال: سیستم هشدار سرقت منزل

BAYESIAN NETWORKS

شما دو همسایه به نام‌های **مری** و **جان** دارید. آن‌ها قول داده‌اند که در صورت شنیدن صدای زنگ هشدار سرقت با شما در محل کارتان تماس بگیرند. **جان** همیشه وقتی تماس می‌گیرد که صدای زنگ هشدار را بشنود، اما گاهی صدای زنگ هشدار را با صدای زنگ تلفن اشتباه می‌گیرد و با شما تماس می‌گیرد. **مری** موسیقی با صدای بلند گوش می‌دهد و گاهی صدای زنگ هشدار را نمی‌شنود. البته گاهی **زمین‌لرزه‌ی** خفیف هم باعث به صدا در آمدن زنگ هشدار می‌شود. می‌خواهیم با دانستن فرد تماس‌گیرنده، احتمال **سرقت** را تخمین بزنیم.

Variables: *Burglar, Earthquake, Alarm, JohnCalls, MaryCalls*


سرقت

زمین‌لرزه

هشدار

تماس جان

تماس مری



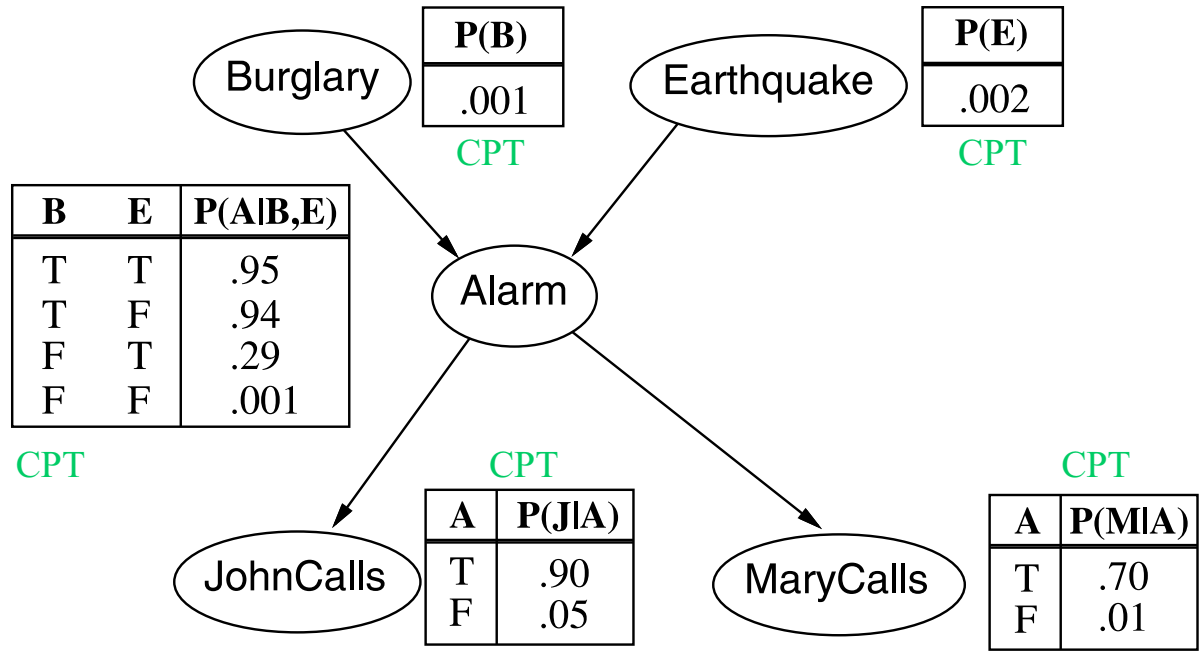
توپولوژی شبکه‌ی بیزی، دانایی «علی» را منعکس می‌کند:

- وقوع یک سرقت می‌تواند زنگ هشدار را به صدا درآورد.
- وقوع یک زمین‌لرزه می‌تواند زنگ هشدار را به صدا درآورد.
- زنگ هشدار می‌تواند باعث شود مری تماس بگیرد.
- زنگ هشدار می‌تواند باعث شود جان تماس بگیرد.

شبکه‌های بیزی

مثال: سیستم هشدار سرقت منزل

BAYESIAN NETWORKS



Variables: *Burglar, Earthquake, Alarm, JohnCalls, MaryCalls*

B E A J M

شبکه‌های بیزی

مفهوم «تراکم»

COMPACTNESS


یک CPT برای متغیر تصادفی بولی X با k والد بولی دارای 2^k سطر برای ترکیب‌های مختلف مقادیر والد‌هاست.

هر سطر یک عدد p برای $X = \text{true}$ نیاز دارد.
(عدد $1-p$ برای $X = \text{false}$ مشخص است)

اگر هر یک از n متغیر حداکثر k والد داشته باشد، کل شبکه به $O(n \cdot 2^k)$ عدد برای CPT‌ها نیاز دارد.

$$O(2^n)$$

برای توزیع‌های توأم کامل
(نمایی بر حسب n)



$$O(n \cdot 2^k)$$


برای توزیع‌های شرطی
(خطی بر حسب n)

شبکه‌های بیزی

مفهوم «تراکم»: مثال

COMPACTNESS


برای مثال سیستم هشدار سرقت



$$O(2^n)$$

برای توزیع‌های توأم کامل
(نمایی بر حسب n)

$$2^5 = 32$$



$$O(n \cdot 2^k)$$

برای توزیع‌های شرطی
(خطی بر حسب n)

$$1 + 1 + 4 + 2 + 2 = 10$$

۲

معناشناسی شبکه‌های بیزی

معناشناسی شبکه‌های بیزی

THE SEMANTICS OF BAYESIAN NETWORKS



معناشناسی شبکه‌های بیزی

معناشناسی سراسری

THE SEMANTICS OF BAYESIAN NETWORKS

معناشناسی شبکه‌های بیزی

معناشناسی محلی
*Local Semantics*معناشناسی سراسری
Global Semantics

توزیع توأم کامل = حاصل ضرب توزیع‌های شرطی محلی

$$P(x_1, \dots, x_n) = \prod_{i=1}^n P(x_i | \text{parents}(X_i))$$

معناشناسی شبکه‌های بیزی

معناشناسی سراسری: مثال

THE SEMANTICS OF BAYESIAN NETWORKS

معناشناسی شبکه‌های بیزی

معناشناسی محلی
*Local Semantics*معناشناسی سراسری
Global Semantics

توزیع توأم کامل = حاصل ضرب توزیع‌های شرطی محلی


$$P(x_1, \dots, x_n) = \prod_{i=1}^n P(x_i | \text{parents}(X_i))$$

$$\text{e.g., } P(j \wedge m \wedge a \wedge \neg b \wedge \neg e)$$

$$= P(j|a)P(m|a)P(a|\neg b, \neg e)P(\neg b)P(\neg e)$$

$$= 0.9 \times 0.7 \times 0.001 \times 0.999 \times 0.998$$

$$\approx 0.00063$$



معناشناسی شبکه‌های بیزی

معناشناسی محلی


THE SEMANTICS OF BAYESIAN NETWORKS

معناشناسی شبکه‌های بیزی

معناشناسی محلی
Local Semantics

معناشناسی سراسری
Global Semantics

هر گره با داشتن والد‌هایش از گره‌های غیرنواده‌اش مستقل شرطی است.



معناشناسی شبکه‌های بیزی

قضیه‌ی هم‌ارزی معناشناسی سراسری با معناشناسی محلی

THE SEMANTICS OF BAYESIAN NETWORKS

Theorem: Local semantics \Leftrightarrow global semantics

معناشناسی شبکه‌های بی‌زی


پتوی مارکوف

MARKOV BLANKET

هر گره از سایر گره‌ها مستقل شرطی است به شرط داشتن پتوی مارکوف آن گره

پتوی مارکوف برای هر گره = والد‌های آن + فرزندان آن + والد‌های فرزندان آن

پتوی مارکوف
Markov Blanket



ساختن شبکه‌های بیزی

CONSTRUCTING BAYESIAN NETWORKS

به روشی نیاز داریم که
با بررسی یک سری از بیان‌های آزمون‌پذیر به طور محلی در مورد استقلال شرطی
بتواند معناشناسی سراسری مورد نیاز را تضمین کند.

1. Choose an ordering of variables X_1, \dots, X_n
2. For $i = 1$ to n
add X_i to the network
select parents from X_1, \dots, X_{i-1} such that
$$\mathbf{P}(X_i | Parents(X_i)) = \mathbf{P}(X_i | X_1, \dots, X_{i-1})$$

انتخاب والد‌ها، معناشناسی سراسری را تضمین می‌کند:

$$\begin{aligned} \mathbf{P}(X_1, \dots, X_n) &= \prod_{i=1}^n \mathbf{P}(X_i | X_1, \dots, X_{i-1}) \quad (\text{chain rule}) \\ &= \prod_{i=1}^n \mathbf{P}(X_i | Parents(X_i)) \quad (\text{by construction}) \end{aligned}$$

ساختن شبکه‌های بی‌زی

مثال (۱ از ۶)

Suppose we choose the ordering M, J, A, B, E

MaryCalls


JohnCalls

$$P(J|M) = P(J)?$$

ساختن شبکه‌های بی‌زی

مثال (۲ از ۶)

Suppose we choose the ordering M, J, A, B, E




$P(J|M) = P(J)$? No

$P(A|J, M) = P(A|J)$? $P(A|J, M) = P(A)$?

ساختن شبکه‌های بی‌زی

مثال (۳ از ۶)

Suppose we choose the ordering M, J, A, B, E



$$P(J|M) = P(J)? \quad \text{No}$$


$$P(A|J, M) = P(A|J)? \quad P(A|J, M) = P(A)? \quad \text{No}$$

$$P(B|A, J, M) = P(B|A)?$$

$$P(B|A, J, M) = P(B)?$$

ساختن شبکه‌های بی‌زی

مثال (۴ از ۶)

Suppose we choose the ordering M, J, A, B, E 

$$P(J|M) = P(J)? \quad \text{No}$$

$$P(A|J, M) = P(A|J)? \quad P(A|J, M) = P(A)? \quad \text{No}$$

$$P(B|A, J, M) = P(B|A)? \quad \text{Yes}$$

$$P(B|A, J, M) = P(B)? \quad \text{No}$$


$$P(E|B, A, J, M) = P(E|A)?$$

$$P(E|B, A, J, M) = P(E|A, B)?$$

ساختن شبکه‌های بی‌زی

مثال (۵ از ۶)

Suppose we choose the ordering M, J, A, B, E



$$P(J|M) = P(J)? \quad \text{No}$$

$$P(A|J, M) = P(A|J)? \quad P(A|J, M) = P(A)? \quad \text{No}$$

$$P(B|A, J, M) = P(B|A)? \quad \text{Yes}$$


$$P(B|A, J, M) = P(B)? \quad \text{No}$$

$$P(E|B, A, J, M) = P(E|A)? \quad \text{No}$$

$$P(E|B, A, J, M) = P(E|A, B)? \quad \text{Yes}$$

ساختن شبکه‌های بیزی

مثال (۶ از ۶)



تصمیم‌گیری در مورد استقلال شرطی در جهت‌های غیرعلی دشوار است.
 (به نظر می‌رسد مدل‌های علی و استقلال شرطی برای انسان‌ها سیم‌بندی سخت شده است)

سنجش احتمالات شرطی در جهت‌های غیرعلی دشوار است.

* در این مثال تراکم شبکه کم است: فقط $13 = 1 + 2 + 4 + 2 + 4$ عدد لازم داریم.

ساخت شبکه‌های بیزی

مثال: تشخیص عیب خودرو

EXAMPLE: CAR DIAGNOSIS

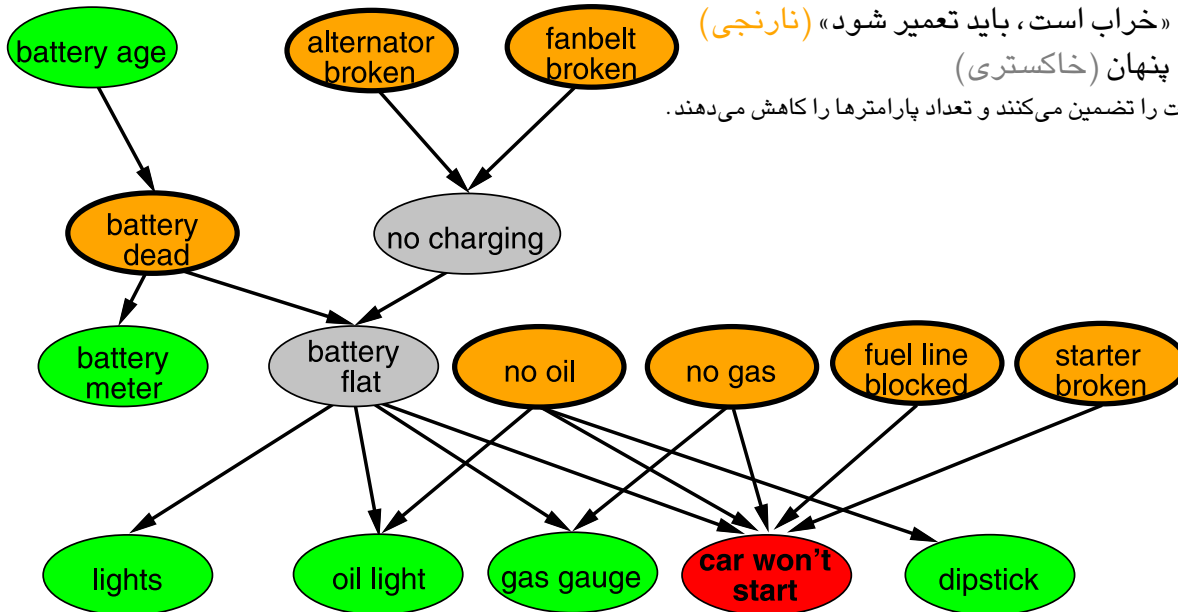
شاهد آغازین: خودرو روشن نمی‌شود

متغیرهای آزمون‌پذیر (سبز)

متغیرهای «خراب است، باید تعمیر شود» (نارنجی)

متغیرهای پنهان (خاکستری)

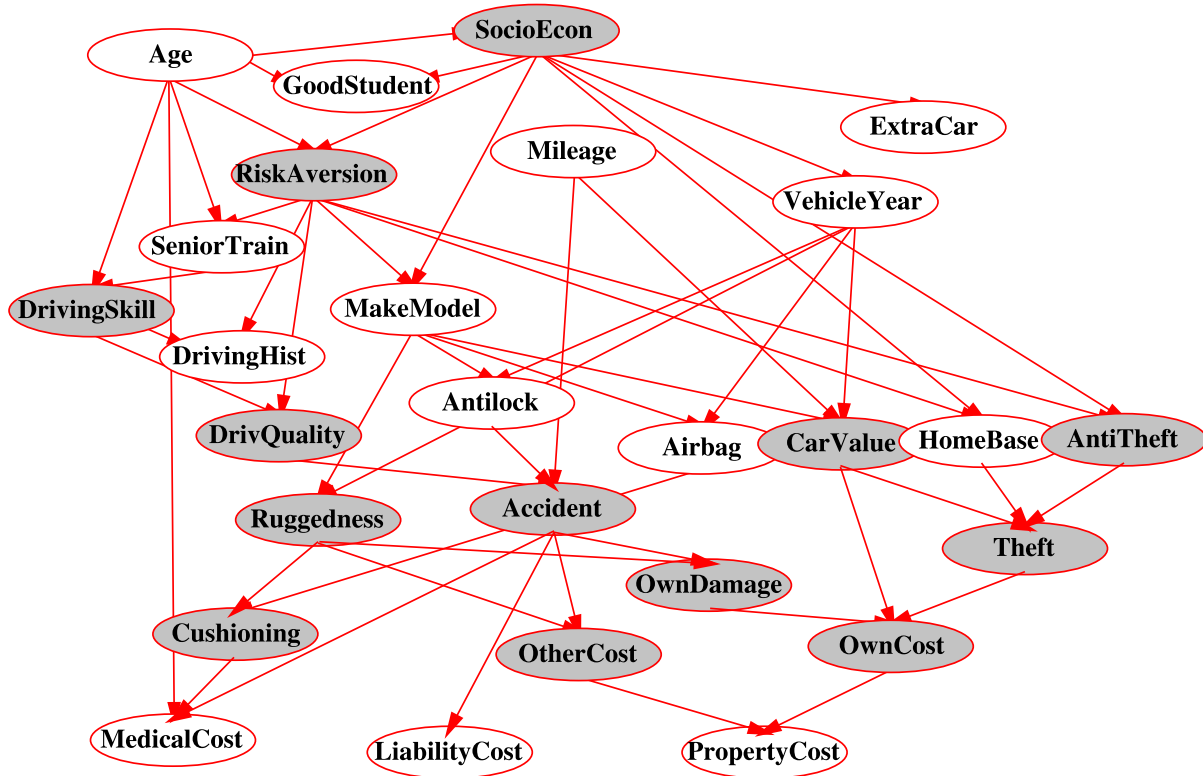
ساختار خلوت را تضمین می‌کنند و تعداد پارامترها را کاهش می‌دهند.



ساخت شبکه‌های بیزی

مثال: بیمه خودرو

EXAMPLE: CAR INSURANCE



استدلال احتمالاتی

۳

بازنمایی
کارآمد
توزیع‌های
شرطی

توزیع‌های شرطی متراکم

COMPACT CONDITIONAL DISTRIBUTIONS

اندازه‌ی CPT با تعداد والد‌ها به صورت نمایی رشد می‌کند.

برای گره‌های قطعی (deterministic nodes)

استفاده از روابط قطعی بین گره‌ها

حل

برای روابط نامطمئن (uncertain relationships)

استفاده از روابط منطقی «نویزی» مانند مدل noisy-OR

مشکل

اندازه‌ی CPT با والد‌ها یا فرزندان پیوسته-مقدار، بی‌نهایت می‌شود.

متغیرهای پیوسته، والد‌های گسسته + پیوسته

استفاده از یک تابع چگالی شرطی

حل

متغیرهای گسسته، والد‌های پیوسته

استفاده از یک تابع چگالی شرطی

مشکل

مشکل

توزیع‌های شرطی متراکم

برای گره‌های قطعی

COMPACT CONDITIONAL DISTRIBUTIONS

اندازه‌ی CPT با تعداد والد‌ها به صورت نمایی رشد می‌کند.

برای گره‌های قطعی (deterministic nodes)

استفاده از روابط قطعی بین گره‌ها

برای روابط نامطمئن (uncertain relationships)

استفاده از روابط منطقی «توری» مانند مدل noisy-OR

حل

مشکل

مشکل

اندازه‌ی CPT با والد‌ها یا غیر فعال یا پیوسته مقدار، از تعاریف منتهی به

متغیرهای پیوسته، والد‌های گسسته + پیوسته

استفاده از یک تابع چگالی شرطی

حل

مشکل

متغیرهای گسسته، والد‌های پیوسته

استفاده از یک تابع چگالی شرطی

توزیع‌های شرطی متراکم

برای گره‌های قطعی

DETERMINISTIC NODES

مقدار گرهی قطعی از روی مقدار والد‌های آن به صورت قطعی مشخص می‌شود.

$$X = f(\text{Parents}(X)) \text{ for some function } f$$

برای مثال: توابع بولی:

$$\text{NorthAmerican} \Leftrightarrow \text{Canadian} \vee \text{US} \vee \text{Mexican}$$

برای مثال: روابط عددی بین متغیرهای پیوسته

$$\frac{\partial \text{Level}}{\partial t} = \text{inflow} + \text{precipitation} - \text{outflow} - \text{evaporation}$$

توزیع‌های شرطی متراکم

برای روابط نامطمئن

COMPACT CONDITIONAL DISTRIBUTIONS

اندازه‌ی CPT با تعداد والد‌ها به صورت نمایی رشد می‌کند.

برای گره‌های قطعی (deterministic nodes)
استفاده از روابط قطعی بین گره‌ها

حل

برای روابط نامطمئن (uncertain relationships)

مشکل

استفاده از روابط منطقی «نویزی» مانند مدل noisy-OR

مشکل

اندازه‌ی CPT با تعداد والد‌ها به صورت نمایی رشد می‌کند.

متغیرهای پیوسته، والد‌های گسسته + پیوسته
استفاده از یک تابع چگالی شرطی

حل

متغیرهای گسسته، والد‌های پیوسته
استفاده از یک تابع چگالی شرطی

مشکل

توزیع‌های شرطی متراکم

برای رابطه‌های نامطمئن

UNCERTAIN RELATIONSHIPS

رابطه‌های غیرقطعی را می‌توان

با استفاده از روابط منطقی «نویزی» مانند مدل **noisy-OR** مشخص کرد.

$$Child \Leftarrow Parent_1 \vee Parent_2 \vee \dots \vee Parent_k$$

در اینکه والد‌ها می‌توانند موجب درست شدن فرزند شوند، عدم اطمینان مجاز شمرده می‌شود.

توزیع‌های **noisy-OR** علت‌های غیرمتعامل چندگانه را مدل می‌کنند؛ با دو شرط

$$U_1, U_2, \dots, U_k$$

والدها شامل همه‌ی علت‌ها باشند: U_1, U_2, \dots, U_k
همیشه می‌توان سایر علت‌ها را با اضافه کردن یک گره‌ی نشستی (**leak node**) پوشش داد.هر علت به تنهایی دارای احتمال شکست مستقل q_i باشد (مستقل از سایر والد‌ها). q_i : احتمال ممانعت فردی (**individual inhibition probabilities**)

$$q_i = P(\neg Child \mid \neg Parent_1, \neg Parent_2, \dots, Parent_i, \dots, \neg Parent_k)$$

در این صورت داریم:




$$P(X|U_1 \dots U_j, \neg U_{j+1} \dots \neg U_k) = 1 - \prod_{i=1}^j q_i$$

توزیع‌های شرطی متراکم

برای رابطه‌های نامطمئن: مثال

UNCERTAIN RELATIONSHIPS

در منطق گزاره‌ای می‌توان گفت $Fever \Leftrightarrow Cold \vee Flu \vee Malaria$

<i>Cold</i>	<i>Flu</i>	<i>Malaria</i>	$P(Fever)$	$P(\neg Fever)$
F	F	F	0.0	1.0
F	F	T	0.9	0.1  داده شده
F	T	F	0.8	0.2  داده شده
F	T	T	0.98	0.02 = 0.2 × 0.1
T	F	F	0.4	0.6  داده شده
T	F	T	0.94	0.06 = 0.6 × 0.1
T	T	F	0.88	0.12 = 0.6 × 0.2
T	T	T	0.988	0.012 = 0.6 × 0.2 × 0.1

$$q_{cold} = P(\neg fever | cold, \neg flu, \neg malaria) = 0.6,$$

$$q_{flu} = P(\neg fever | \neg cold, flu, \neg malaria) = 0.2,$$

$$q_{malaria} = P(\neg fever | \neg cold, \neg flu, malaria) = 0.1.$$

بر اساس احتمالات ممانعت فردی،
می‌توان کل CPT را کامل کرد.

$$P(x_i | parents(X_i)) = 1 - \prod_{\{j: X_j = true\}} q_j$$

تعداد پارامترهای مورد نیاز بر حسب تعداد والد‌ها، خطی است.

$$O(2^k) \rightsquigarrow O(k)$$



توزیع‌های شرطی متراکم

برای متغیرهای پیوسته، والد‌های گسسته + پیوسته

COMPACT CONDITIONAL DISTRIBUTIONS

اندازه‌ی CPT با مقدار والد‌ها به صورت ثابتی را محدود می‌کند

برای گره‌های قطعی (deterministic nodes)
استفاده از روابط قطعی بین گره‌ها

حل

برای روابط نامطمئن (uncertain relationships)
استفاده از روابط منطقی «**نویزی**» مانند مدل noisy-OR

مشکل

اندازه‌ی CPT با والد‌ها یا فرزندان پیوسته-مقدار، بی‌نهایت می‌شود.

متغیرهای پیوسته، والد‌های گسسته + پیوسته

استفاده از یک تابع چگالی شرطی

حل

متغیرهای گسسته، والد‌های پیوسته
استفاده از یک تابع چگالی شرطی

مشکل


مشکل

توزیع‌های شرطی متراکم

برای شبکه‌های بی‌زی هیبرید (گسسته + پیوسته)

HYBRID (DISCRETE+CONTINUOUS) NETWORKS

Discrete (*Subsidy?* and *Buys?*); continuous (*Harvest* and *Cost*)



گزینه ۱) استفاده از گسسته‌سازی: * مشکل خطای احتمالی بالا * مشکل CPT‌های بزرگ

گزینه ۲) استفاده از خانواده‌های کانونیک توزیع‌های پارامتری متناهی 

چگونگی برخورد با
متغیرهای پیوسته

توزیع‌های شرطی متراکم

برای شبکه‌های بیزی هیبرید (گسسته + پیوسته): برای متغیرهای پیوسته فرزند


HYBRID (DISCRETE+CONTINUOUS) NETWORKS

نیاز داریم به یک تابع چگالی شرطی

برای متغیر فرزند پیوسته با داشتن **والدهای پیوسته** به ازای هر انتساب ممکن برای والد‌های گسسته

معمولاً **مدل گاوسی خطی** برای تابع چگالی شرطی متداول‌ترین گزینه است، مثلاً:

$$\begin{aligned} P(\text{Cost} = c | \text{Harvest} = h, \text{Subsidy?} = \text{true}) \\ &= N(a_t h + b_t, \sigma_t)(c) \\ &= \frac{1}{\sigma_t \sqrt{2\pi}} \exp\left(-\frac{1}{2} \left(\frac{c - (a_t h + b_t)}{\sigma_t}\right)^2\right) \end{aligned}$$




متوسط فرزند (*Cost*) به صورت خطی با والد (*Harvest*) تغییر می‌کند؛ واریانس ثابت است.


تغییر خطی بر روی یک بازه‌ی بزرگ غیرمنطقی است، اما به خوبی کار می‌کند اگر بازه‌ی احتمالی *Harvest* باریک باشد.

توزیع‌های شرطی متراکم

برای شبکه‌های بی‌زی هیبرید (گسسته + پیوسته): برای متغیرهای پیوسته فرزند: توزیع گاوسی خطی

HYBRID (DISCRETE+CONTINUOUS) NETWORKS

$P(\text{Cost}|\text{Harvest}, \text{Subsidy?}=\text{true})$




یک شبکه که تنها از متغیرهای پیوسته با توزیع گاوسی خطی تشکیل شده است دارای یک توزیع توأم کامل با **گاوسی چندمتغیره** است.


توزیع‌های شرطی متراکم

برای شبکه‌های بیزی هیبرید (گسسته + پیوسته): برای متغیرهای پیوسته فرزند: توزیع گاوسی خطی


HYBRID (DISCRETE+CONTINUOUS) NETWORKS



$$a_f, b_f, \sigma_f$$



$$a_t, b_t, \sigma_t$$




شبکه‌ی گاوسی خطی گسسته + پیوسته، یک شبکه‌ی گاوسی شرطی است.
یعنی: یک گاوسی چندمتغیره بر روی همه‌ی متغیرهای پیوسته
برای هر ترکیب از مقادیر متغیرهای گسسته وجود دارد.

توزیع‌های شرطی متراکم

برای شبکه‌های بیزی هیبرید (گسسته + پیوسته): برای متغیرهای پیوسته فرزند: توزیع گاوسی خطی

HYBRID (DISCRETE+CONTINUOUS) NETWORKS



مثال با فرض احتمال پیشین 0.5
 حاصل با متوسط‌گیری روی دو
 مقدار ممکن متغیر بولی

مجموع دو توزیع گاوسی، یک گاوسی است.

توزیع‌های شرطی متراکم

برای متغیرهای گسسته، والد‌های پیوسته

COMPACT CONDITIONAL DISTRIBUTIONS

اندازه‌ی CPT با مقدار والد‌ها به صورت قطعی رفتار می‌کند

برای گره‌های قطعی (deterministic nodes)
استفاده از روابط قطعی بین گره‌ها

حل

برای روابط نامطمئن (uncertain relationships)
استفاده از روابط منطقی «تورزی» مانند مدل noisy-OR

مشکل

اندازه‌ی CPT با والد‌ها یا فرزندان پیوسته-مقدار، بی‌نهایت می‌شود.

متغیرهای پیوسته، والد‌های گسسته - پیوسته
استفاده از یک تابع چگالی شرطی

حل

متغیرهای گسسته، والد‌های پیوسته
استفاده از یک تابع چگالی شرطی

مشکل

مشکل


توزیع‌های شرطی متراکم

برای شبکه‌های بیزی هیبرید (گسسته + پیوسته): برای متغیرهای گسسته فرزند و والد‌های پیوسته


HYBRID (DISCRETE+CONTINUOUS) NETWORKS

احتمال فرزند گسسته به شرط والد پیوسته باید یک مقدار آستانه‌ای نرم باشد (مثل توزیع پروبیت).
(نباید تغییر ناگهانی داشته باشد)

Probability of *Buys?* given *Cost* should be a “soft” threshold:



$P(\text{Buys?}=\text{false}|\text{Cost}=c)$



مشتری در صورتی خرید می‌کند که قیمت پایین باشد و در صورت بالا بودن قیمت خرید نخواهد کرد؛ اما تغییرات احتمال خرید در ناحیه‌ی میانی ملایم است.

توزیع پروبیت (**Probit**) از انتگرال تابع توزیع گاوسی استفاده می‌کند:

$$\Phi(x) = \int_{-\infty}^x N(0, 1)(x)dx$$

$$P(\text{Buys?} = \text{true} \mid \text{Cost} = c) = \Phi((-c + \mu)/\sigma)$$


توزیع‌های شرطی متراکم

برای شبکه‌های بیزی هیبرید (گسسته + پیوسته): برای متغیرهای گسسته فرزند و والد‌های پیوسته: توزیع پروبیت

HYBRID (DISCRETE+CONTINUOUS) NETWORKS

ویژگی توزیع پروبیت (Probit)

فرآیند تصمیم‌گیری دارای مقدار آستانه‌ی سخت است، اما مکان دقیق آستانه در معرض نویز گاوسی تصادفی قرار دارد.



توزیع‌های شرطی متراکم



برای شبکه‌های بیزی هیبرید (گسسته + پیوسته): برای متغیرهای گسسته فرزند و والد‌های پیوسته: توزیع لوگیت

HYBRID (DISCRETE+CONTINUOUS) NETWORKS

ویژگی توزیع لوگیت (Logit) (یا سیکموئید (Sigmoid))

مشابه پروبیت (آستانه‌ی نرم) اما دم‌های آن طولانی‌تر است.

$$P(\text{Buys?} = \text{true} \mid \text{Cost} = c) = \frac{1}{1 + \exp\left(-2\frac{-c+\mu}{\sigma}\right)}$$



استدلال احتمالاتی

۴

استنتاج
دقیق در
شبکه‌های
بیزی

وظیفه‌های استنتاج

INFERENCE TASKS

محاسبه‌ی توزیع‌های پسین حاشیه‌ای $P(X_i | \mathbf{E} = \mathbf{e})$

$$P(\text{NoGas} | \text{Gauge} = \text{empty}, \text{Lights} = \text{on}, \text{Starts} = \text{false})$$

پرسش‌های ساده

Simple Queries

محاسبه‌ی توزیع‌های پسین حاشیه‌ای شامل چند متغیر

$$P(X_i, X_j | \mathbf{E} = \mathbf{e}) = P(X_i | \mathbf{E} = \mathbf{e})P(X_j | X_i, \mathbf{E} = \mathbf{e})$$

پرسش‌های عطفی

Conjunctive Queries

شبکه‌های تصمیم‌حاری اطلاعات سودمندی؛ استنتاج احتمالاتی لازم برای:

$$P(\text{outcome} | \text{action}, \text{evidence})$$

تصمیم‌های بهینه

Optimal Decisions

به دنبال چه شاهی برای بعد باید باشیم؟

ارزش اطلاعات

Value of Information

کدام مقادیر احتمال، حیاتی‌ترین آنها هستند؟

تحلیل حساسیت

Sensitivity Analysis

مثلاً: چرا من به یک استارتر موتور جدید نیاز دارم؟

تبیین

Explanation

استنتاج در شبکه‌های بیزی

استنتاج در شبکه‌های بیزی

استنتاج تقریبی
Approximate Inference

استنتاج دقیق
Exact Inference

زنجیره‌ی مارکوف مونت کارلو
Markov Chain Monte Carlo

شبیه‌سازی اتفاقی
Stochastic Simulation

حذف متغیر
Variable Elimination

برشمارش
Enumeration

استنتاج در شبکه‌های بیزی

استنتاج دقیق با برشماری

استنتاج در شبکه‌های بیزی

استنتاج تقریبی
Approximate Inference

استنتاج دقیق
Exact Inference

زنجیره‌ی مارکوف مونت کارلو
Markov Chain Monte Carlo

شبیه‌سازی استochastic
Stochastic Simulation

حذف متغیر
Variable Elimination

برشماری
Enumeration

استنتاج با برشماری

INFERENCE BY ENUMERATION


روشی با هوشمندی اندک برای مجموع‌گیری متغیرها از توزیع توأم، بدون ساخت واقعی بازنمایی صریح آن

$$P(X | e) = \alpha P(X, e) = \alpha \sum_y P(X, e, y)$$

پرس‌وجو

استنتاج با برشماری

مثال

INFERENCE BY ENUMERATION

Simple query on the burglary network:

مثال

$$\begin{aligned}
 & \mathbf{P}(B|j, m) \\
 &= \mathbf{P}(B, j, m) / P(j, m) \\
 &= \alpha \mathbf{P}(B, j, m) \\
 &= \alpha \sum_e \sum_a \mathbf{P}(B, e, a, j, m)
 \end{aligned}$$

Rewrite full joint entries using product of CPT entries:

$$\begin{aligned}
 & \mathbf{P}(B|j, m) \\
 &= \alpha \sum_e \sum_a \mathbf{P}(B) P(e) \mathbf{P}(a|B, e) P(j|a) P(m|a) \\
 &= \alpha \mathbf{P}(B) \sum_e P(e) \sum_a \mathbf{P}(a|B, e) P(j|a) P(m|a)
 \end{aligned}$$

استنتاج با برشماری

الگوریتم

INFERENCE BY ENUMERATION

function ENUMERATION-ASK(X, e, bn) **returns** a distribution over X

inputs: X , the query variable

e , observed values for variables E

bn , a Bayesian network with variables $\{X\} \cup E \cup Y$

$Q(X) \leftarrow$ a distribution over X , initially empty

for each value x_i of X **do**

 extend e with value x_i for X

$Q(x_i) \leftarrow$ ENUMERATE-ALL(VARS[bn], e)

return NORMALIZE($Q(X)$)

function ENUMERATE-ALL($vars, e$) **returns** a real number

if EMPTY?($vars$) **then return** 1.0

$Y \leftarrow$ FIRST($vars$)

if Y has value y in e

then return $P(y | Pa(Y)) \times$ ENUMERATE-ALL(REST($vars$), e)

else return $\sum_y P(y | Pa(Y)) \times$ ENUMERATE-ALL(REST($vars$), e_y)



 where e_y is e extended with $Y = y$

Recursive depth-first enumeration: $O(n)$ space, $O(d^n)$ time

استنتاج با برشماری

درخت ارزیابی



EVALUATION TREE



$$\begin{aligned}
 & \mathbf{P}(B|j, m) \\
 & = \alpha \sum_e \sum_a \mathbf{P}(B)P(e)\mathbf{P}(a|B, e)P(j|a)P(m|a) \\
 & = \alpha \mathbf{P}(B) \sum_e P(e) \sum_a \mathbf{P}(a|B, e)P(j|a)P(m|a)
 \end{aligned}$$

استنتاج با برشماری

مشکل ناکارآمدی



برشماری ناکارآمد است: به دلیل محاسبات تکراری

برای مثال: $P(j|a)P(m|a)$ برای هر مقدار e محاسبه می شود!

استنتاج در شبکه‌های بیزی

استنتاج دقیق با حذف متغیر

استنتاج در شبکه‌های بیزی

استنتاج تقریبی
Approximate Inference

استنتاج دقیق
Exact Inference

زنجیره‌های مارکوف مونت کارلو
Markov Chain Monte Carlo

شبیه‌سازی احتمالی
Stochastic Simulation

حذف متغیر
Variable Elimination

برش‌شماری
Enumeration

استنتاج با حذف متغیر

INFERENCE BY VARIABLE ELIMINATION

حذف متغیر:

انجام مجموعیابی‌ها از سمت راست به چپ،
 نتایج میانی (فاکتورها) ذخیره می‌شوند تا از محاسبه‌ی مجدد آنها اجتناب شود.

مثال

$$\begin{aligned}
 \mathbf{P}(B|j, m) &= \alpha \underbrace{\mathbf{P}(B)}_B \sum_e \underbrace{P(e)}_E \sum_a \underbrace{\mathbf{P}(a|B, e)}_A \underbrace{P(j|a)}_J \underbrace{P(m|a)}_M \\
 &= \alpha \mathbf{P}(B) \sum_e P(e) \sum_a \mathbf{P}(a|B, e) P(j|a) f_M(a) \\
 &= \alpha \mathbf{P}(B) \sum_e P(e) \sum_a \mathbf{P}(a|B, e) f_J(a) f_M(a) \\
 &= \alpha \mathbf{P}(B) \sum_e P(e) \sum_a f_A(a, b, e) f_J(a) f_M(a) \\
 &= \alpha \mathbf{P}(B) \sum_e P(e) f_{\bar{A}JM}(b, e) \text{ (sum out } A) \\
 &= \alpha \mathbf{P}(B) f_{\bar{E}\bar{A}JM}(b) \text{ (sum out } E) \\
 &= \alpha f_B(b) \times f_{\bar{E}\bar{A}JM}(b)
 \end{aligned}$$

استنتاج با حذف متغیر

فاکتور

INFERENCE BY VARIABLE ELIMINATION

$$f_M(A) = \begin{bmatrix} P(m|a) \\ P(m|\neg a) \end{bmatrix}$$

وابستگی فاکتور به M


استنتاج با حذف متغیر

فاکتورها

INFERENCE BY VARIABLE ELIMINATION

فاکتورهای آغازین، CPTهای محلی هستند:

$$\begin{array}{ccc}
 \underbrace{P(B)} & \underbrace{P(J|A)} & \underbrace{P(A|B, E)} \\
 f_B(B) & f_J(A, J) & f_A(A, B, E)
 \end{array}$$



در طول حذف، فاکتورهای جدیدی ساخته می شوند.

4 numbers, one for each value of D and E

$$f_{A\bar{B}\bar{C}D}(D, E)$$

متغیرهای وارد شده
Variables introduced

متغیرهای جمع بسته شده
Variables summed out

آناتومی یک فاکتور

Argument variables, always non-evidence variables

متغیرهای آرگومان: همیشه غیر از شواهد

استنتاج با حذف متغیر

عملیات پایه: الحاق فاکتورها (ضرب نقطه به نقطه)

JOIN FACTORS

ترکیب دو فاکتور

(مشابه عمل Join در پایگاه داده‌ی رابطه‌ای):

ایجاد یک فاکتور بر روی اجتماع دامنه‌ها

$$f_1(A, B) \times f_2(B, C) \longrightarrow f_3(A, B, C)$$

$$f_3(a, b, c) = f_1(a, b) \cdot f_2(b, c)$$

$$"P(a, b|c) = P(a|b) \cdot P(b|c)"$$

استنتاج با حذف متغیر

عملیات پایه: الحاق فاکتورها (ضرب نقطه به نقطه): مثال

JOIN FACTORS

A	B	$f_1(A, B)$	B	C	$f_2(B, C)$	A	B	C	$f_3(A, B, C)$
T	T	.3	T	T	.2	T	T	T	$.3 \times .2 = .06$
T	F	.7	T	F	.8	T	T	F	$.3 \times .8 = .24$
F	T	.9	F	T	.6	T	F	T	$.7 \times .6 = .42$
F	F	.1	F	F	.4	T	F	F	$.7 \times .4 = .28$
						F	T	T	$.9 \times .2 = .18$
						F	T	F	$.9 \times .8 = .72$
						F	F	T	$.1 \times .6 = .06$
						F	F	F	$.1 \times .4 = .04$

Figure 14.10 Illustrating pointwise multiplication: $f_1(A, B) \times f_2(B, C) = f_3(A, B, C)$.

استنتاج با حذف متغیر

عملیات پایه: حاشیه‌ای‌سازی

MARGINALIZATION

گرفتن یک فاکتور و مجموع‌گیری روی یک متغیر
(مشابه عمل Projection در پایگاه داده‌ی رابطه‌ای):
تبدیل یک فاکتور به یک فاکتور کوچک‌تر

$$f_{\bar{A}B}(b) = \sum_a f_{AB}(a, b)$$

$$"P(b) = \sum_a P(a, b)"$$

استنتاج با حذف متغیر

عملیات پایه: حاشیه‌ای‌سازی: مثال

MARGINALIZATION

$$\begin{aligned} \mathbf{f}(B, C) &= \sum_a \mathbf{f}_3(A, B, C) = \mathbf{f}_3(a, B, C) + \mathbf{f}_3(\neg a, B, C) \\ &= \begin{pmatrix} .06 & .24 \\ .42 & .28 \end{pmatrix} + \begin{pmatrix} .18 & .72 \\ .06 & .04 \end{pmatrix} = \begin{pmatrix} .24 & .96 \\ .48 & .32 \end{pmatrix} . \end{aligned}$$

استنتاج با حذف متغیر

عملیات پایه

INFERENCE BY VARIABLE ELIMINATION

مجموعیابی یک متغیر از ضرب یکسری از فاکتورها:

- هر فاکتور ثابت را به خارج مجموع انتقال می دهیم.
- برای باقیماندهی فاکتورها:

زیرماتریسهای آنها را نقطه به نقطه (pointwise) ضرب می کنیم و حاصل آنها را با هم جمع می کنیم.

$$\sum_x f_1 \times \cdots \times f_k = f_1 \times \cdots \times f_i \sum_x f_{i+1} \times \cdots \times f_k = f_1 \times \cdots \times f_i \times f_{\bar{X}}$$

assuming f_1, \dots, f_i do not depend on X

Pointwise product of factors f_1 and f_2 :

$$f_1(x_1, \dots, x_j, y_1, \dots, y_k) \times f_2(y_1, \dots, y_k, z_1, \dots, z_l) \\ = f(x_1, \dots, x_j, y_1, \dots, y_k, z_1, \dots, z_l)$$

E.g., $f_1(a, b) \times f_2(b, c) = f(a, b, c)$

استنتاج با حذف متغیر

استفاده از عملیات پایه: محاسبه: مثال

INFERENCE BY VARIABLE ELIMINATION

$$\begin{aligned}
P(b, j, m) &= \underbrace{P(b)}_B \sum_e \underbrace{P(e)}_E \sum_a \underbrace{P(a|b, e)}_A \underbrace{P(j|a)}_J \underbrace{P(m|a)}_M \\
&= f_B(b) \sum_e f_E(e) \sum_a f_A(a, b, e) f_J(a) f_M(a) \\
&= f_B(b) \sum_e f_E(e) \sum_a f_{AJM}(a, b, e) \\
&= f_B(b) \sum_e f_{\bar{A}JM}(b, e) \\
&= f_B(b) \sum_e f_{\bar{A}EJM}(b, e) \\
&= f_B(b) f_{\bar{A}\bar{E}JM}(b) \\
&= f_{\bar{A}B\bar{E}JM}(b)
\end{aligned}$$

استنتاج با حذف متغیر

الگوریتم عمومی

INFERENCE BY VARIABLE ELIMINATION

پرس و جو:

$$P(Q|E_1 = e_1, \dots, E_k = e_k)$$

الگوریتم استنتاج با حذف متغیر

با فاکتورهای آغازین شروع می‌کنیم.
همان CPT های محلی اما نمونه‌سازی شده با شواهد

تا زمانی که هنوز متغیرهای پنهان وجود دارند (غیر از Q یا شواهد)

یک متغیر پنهان H را انتخاب می‌کنیم.

همه فاکتورهایی که به H اشاره دارند را join می‌کنیم.


برای حذف H حاشیه‌سازی می‌کنیم (project).

فاکتورهای باقیمانده را join و نرمال‌سازی می‌کنیم

استنتاج با حذف متغیر

مثال (۱ از ۲)

INFERENCE BY VARIABLE ELIMINATION



$$P(B|j, m) \propto P(B, j, m)$$

$P(B)$	$P(E)$	$P(A B, E)$	$P(j A)$	$P(m A)$
$f_B(B)$	$f_E(E)$	$f_A(A, B, E)$	$f_J(A)$	$f_M(A)$

Choose A


$f_A(\underline{A}, B, E)$	الحاق	$f_{AJM}(A, B, E)$	حاشیه‌سازی	$f_{\bar{A}JM}(B, E)$
$f_J(\underline{A})$	$\times \rightarrow$	$\rightarrow \Sigma$		
$f_M(\underline{A})$				

$f_B(B)$	$f_E(E)$	$f_{\bar{A}JM}(B, E)$
----------	----------	-----------------------

استنتاج با حذف متغیر

مثال (۲ از ۲)

INFERENCE BY VARIABLE ELIMINATION



$$f_B(B) \quad f_E(E) \quad f_{\bar{A}JM}(B, E)$$

Choose E

$$\begin{array}{c}
 f_E(\underline{E}) \\
 f_{\bar{A}JM}(B, \underline{E})
 \end{array}
 \xrightarrow{\text{الحاق}}
 \begin{array}{c}
 \text{حاشیه‌سازی} \\
 f_{\bar{A}EJM}(B, E)
 \end{array}
 \xrightarrow{\Sigma}
 f_{\bar{A}\bar{E}JM}(B)$$

$$f_B(B) \quad f_{\bar{A}\bar{E}JM}(B)$$

Finish

$$\begin{array}{c}
 f_B(\underline{B}) \\
 f_{\bar{A}\bar{E}JM}(\underline{B})
 \end{array}
 \xrightarrow{\text{الحاق}}
 \begin{array}{c}
 \text{نرمال‌سازی} \\
 f_{\bar{A}\bar{B}\bar{E}JM}(B)
 \end{array}
 \xrightarrow{\text{Normalize}}
 P(B|j, m)$$

استنتاج با حذف متغیر

شبه کد الگوریتم

INFERENCE BY VARIABLE ELIMINATION

```

function ELIMINATION-ASK( $X, e, bn$ ) returns a distribution over  $X$ 
  inputs:  $X$ , the query variable
            $e$ , evidence specified as an event
            $bn$ , a belief network specifying joint distribution  $P(X_1, \dots, X_n)$ 

   $factors \leftarrow []$ ;  $vars \leftarrow \text{REVERSE}(\text{VARS}[bn])$ 
  for each  $var$  in  $vars$  do
     $factors \leftarrow [\text{MAKE-FACTOR}(var, e) | factors]$ 
    if  $var$  is a hidden variable then  $factors \leftarrow \text{SUM-OUT}(var, factors)$ 
  return NORMALIZE( $\text{POINTWISE-PRODUCT}(factors)$ )

```

استنتاج با حذف متغیر


متغیرهای نامربوط

IRRELEVANT VARIABLES

Consider the query $P(\text{JohnCalls} | \text{Burglary} = \text{true})$

$$P(J|b) = \alpha P(b) \sum_e P(e) \sum_a P(a|b, e) P(J|a) \sum_m P(m|a)$$

Sum over m is identically 1; M is **irrelevant** to the query



Y is irrelevant unless $Y \in \text{Ancestors}(\{X\} \cup \mathbf{E})$

قضیه

Here, $X = \text{JohnCalls}$, $\mathbf{E} = \{\text{Burglary}\}$, and
 $\text{Ancestors}(\{X\} \cup \mathbf{E}) = \{\text{Alarm}, \text{Earthquake}\}$
 so MaryCalls is irrelevant

مثال

اگر یک متغیر، جد یک متغیر پرس و جو یا مشاهده نباشد، به آن پرس و جو نامربوط است.
 ← در الگوریتم حذف متغیر، می توان این متغیر نامربوط را پیش از ارزیابی پرس و جو حذف کرد.

استنتاج با حذف متغیر

متغیرهای نامربوط

IRRELEVANT VARIABLES


گراف مورال یک شبکه‌ی بی‌زی:
در شبکه‌ی بی‌زی، همه‌ی والد‌ها را به هم پیوند می‌دهیم و پیکان‌ها را حذف می‌کنیم.

گراف مورال
Moral Graph

A is m-separated from B by C iff separated by C in the moral graph

Y is irrelevant if m-separated from X by E

قضیه



For $P(\text{JohnCalls} | \text{Alarm} = \text{true})$, both *Burglary* and *Earthquake* are irrelevant

مثال


استنتاج دقیق

پیچیدگی

شبکه‌های بیزی

شبکه‌های همبند چندتایی <i>Multiply Connected Networks</i>	شبکه‌های همبند تنها (چند درختی) <i>Singly Connected Networks (Polytrees)</i>
<p>می‌توان 3SAT را به استنتاج دقیق کاهش داد NP-hard \Leftarrow</p> <p>معادل با شمارش مدل‌های 3SAT #P-complete \Leftarrow</p>	<p>هر دو گره حداکثر با یک مسیر (بی‌جهت) به هم متصل می‌شوند.</p> <p>هزینه‌ی زمان و فضای حذف متغیر $O(d^k n)$</p>

1. $A \vee B \vee C$
2. $C \vee D \vee \neg A$
3. $B \vee C \vee \neg D$



استنتاج با حذف متغیر

خوشه‌بندی برای افزایش کارایی (الگوریتم درخت مشترک)

CLUSTERING (JOIN TREE ALGORITHMS)

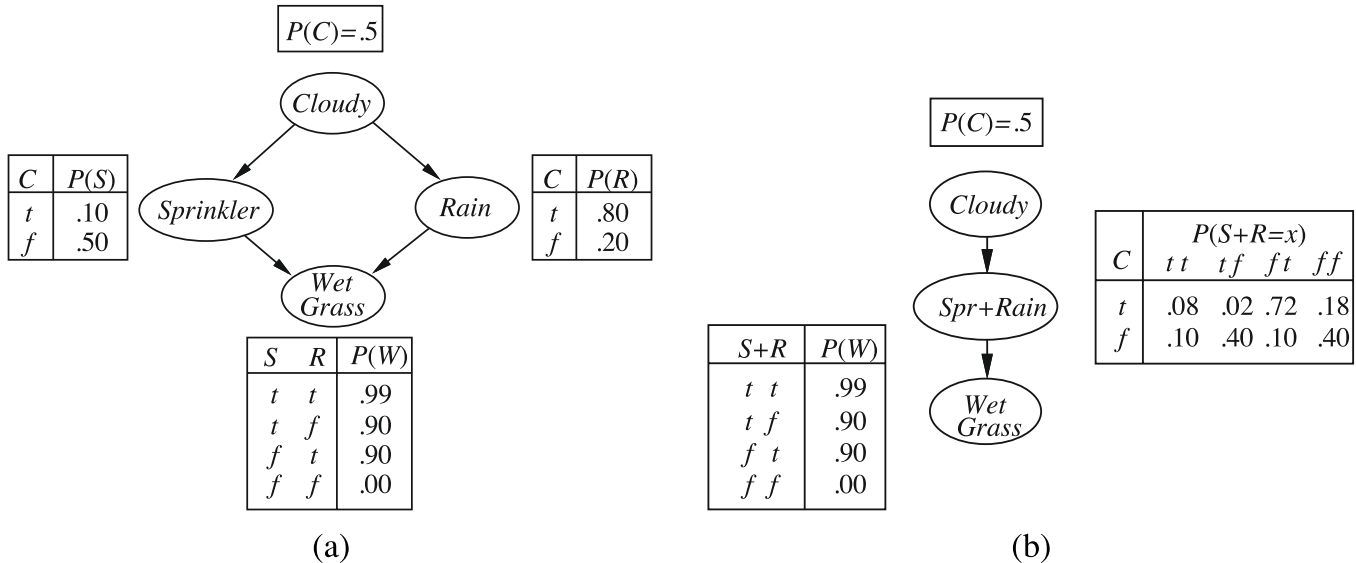


Figure 14.12 (a) A multiply connected network with conditional probability tables. (b) A clustered equivalent of the multiply connected network.

استدلال احتمالاتی

۵

استنتاج
تقریبی در
شبکه‌های
بیزی

استنتاج در شبکه‌های بیزی

استنتاج تقریبی با شبیه‌سازی اتفاقی

استنتاج در شبکه‌های بیزی

استنتاج تقریبی
Approximate Inference

استنتاج دقیق
Exact Inference

زنجیره‌های مارکوف مونت کارلو
Markov Chain Monte Carlo

شبیه‌سازی اتفاقی
Stochastic Simulation

حذف متغیر
Variable Elimination

پرسشگری بیزی
Bayesian Query

استنتاج با شبیه‌سازی اتفاقی

INFERENCE BY STOCHASTIC SIMULATION

ایده‌ی پایه

N نمونه را از یک توزیع نمونه‌برداری S بیرون می‌کشیم.

یک تقریب از احتمال پسین \hat{P} محاسبه می‌کنیم.

نشان می‌دهیم که این تقریب به احتمال واقعی P همگرا می‌شود.

0.5

Coin

طرح بحث:

- نمونه‌برداری از یک شبکه‌ی خالی
- رد کردن نمونه‌برداری: رد کردن نمونه‌های ناموافق با شواهد
- وزن‌دهی درست‌نمایی: استفاده از شواهد برای وزن‌دهی به نمونه‌ها
- زنجیره‌ی مارکوف مونت کارلو (MCMC):
نمونه‌برداری از یک فرآیند اتفاقی که توزیع ایستادن آن، توزیع احتمال پسین واقعی است.

استنتاج با شبیه‌سازی اتفاقی

نمونه‌برداری از یک شبکه‌ی خالی

```

function PRIOR-SAMPLE( $bn$ ) returns an event sampled from  $bn$ 
  inputs:  $bn$ , a belief network specifying joint distribution  $\mathbf{P}(X_1, \dots, X_n)$ 

   $x \leftarrow$  an event with  $n$  elements
  for  $i = 1$  to  $n$  do
     $x_i \leftarrow$  a random sample from  $\mathbf{P}(X_i \mid Parents(X_i))$ 
  return  $x$ 


```

از هر متغیر به نوبت و به ترتیب توپولوژی نمونه‌برداری می‌شود.

توزیع احتمال متغیرهایی که مقادیر آنها نمونه‌برداری شده است،
به مقادیری که از قبل به متغیرهای والد نسبت داده شده است، مشروط می‌شود.

استنتاج با شبیه‌سازی اتفاقی

نمونه‌برداری از یک شبکه‌ی خالی: مثال (۱ از ۸)

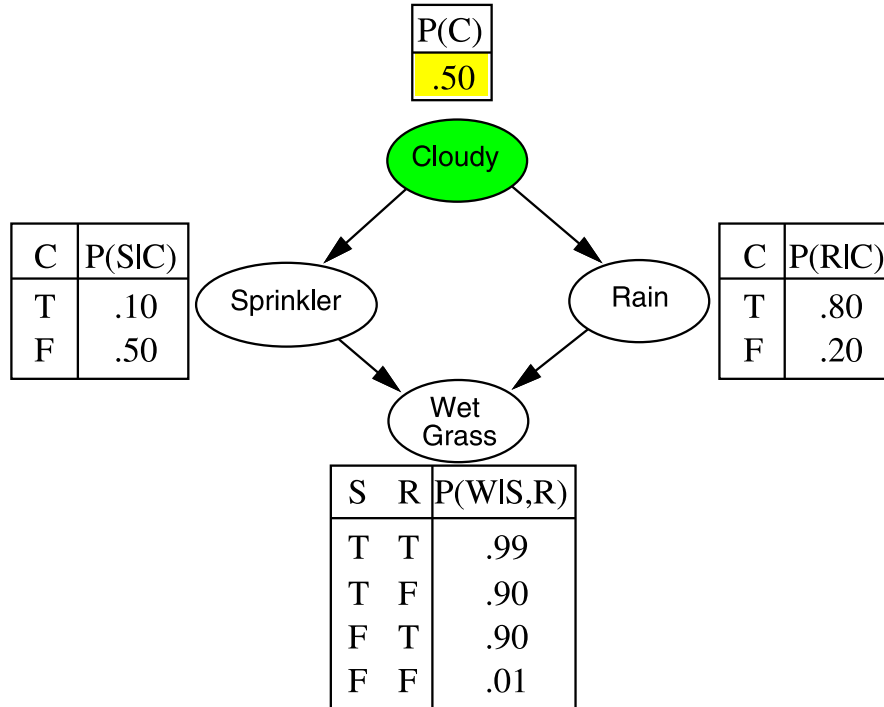


استنتاج با شبیه‌سازی اتفاقی

نمونه‌برداری از یک شبکه‌ی خالی: مثال (۲ از ۸)

F

T




فرض می‌کنیم نمونه‌برداری از $\langle 0.5, 0.5 \rangle = P(Cloudy)$ مقدار *True* برگرداند.

استنتاج با شبیه‌سازی اتفاقی

نمونه‌برداری از یک شبکه‌ی خالی: مثال (۲ از ۸)

F

T

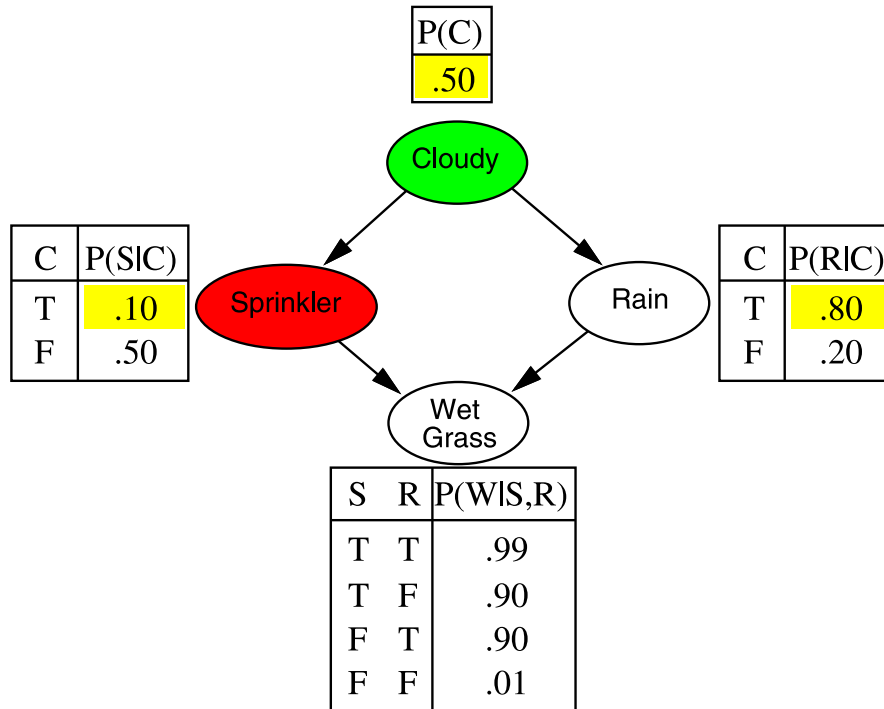


استنتاج با شبیه‌سازی اتفاقی

نمونه‌برداری از یک شبکه‌ی خالی: مثال (۴ از ۸)

F

T



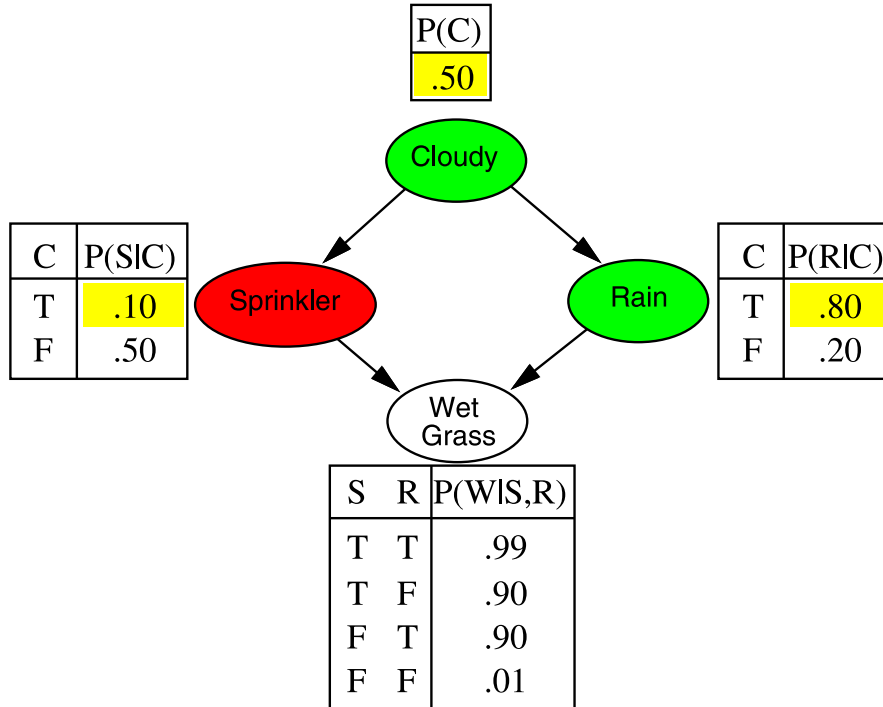
فرض می‌کنیم نمونه‌برداری از $\langle 0.1, 0.9 \rangle$ مقدار $P(\text{Sprinkler} | \text{Cloudy} = \text{True}) = \langle 0.1, 0.9 \rangle$ برگرداند.

استنتاج با شبیه‌سازی اتفاقی

نمونه‌برداری از یک شبکه‌ی خالی: مثال (۵ از ۸)

F

T



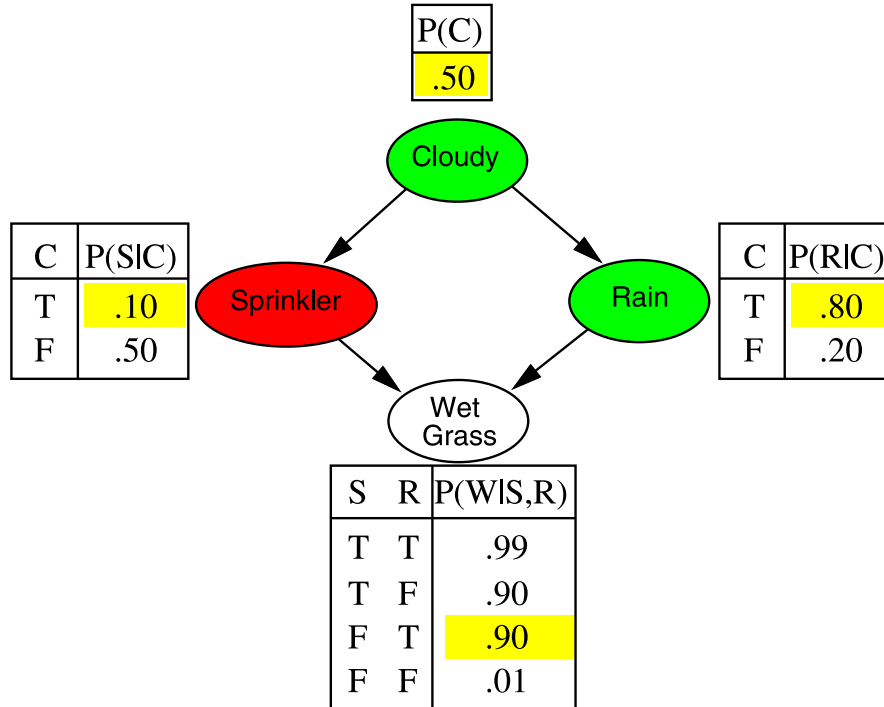
فرض می‌کنیم نمونه‌برداری از $\langle 0.8, 0.2 \rangle = P(\text{Rain} | \text{Cloudy} = \text{True})$ مقدار *True* برگرداند.

استنتاج با شبیه‌سازی اتفاقی

نمونه‌برداری از یک شبکه‌ی خالی: مثال (۶ از ۸)

F

T

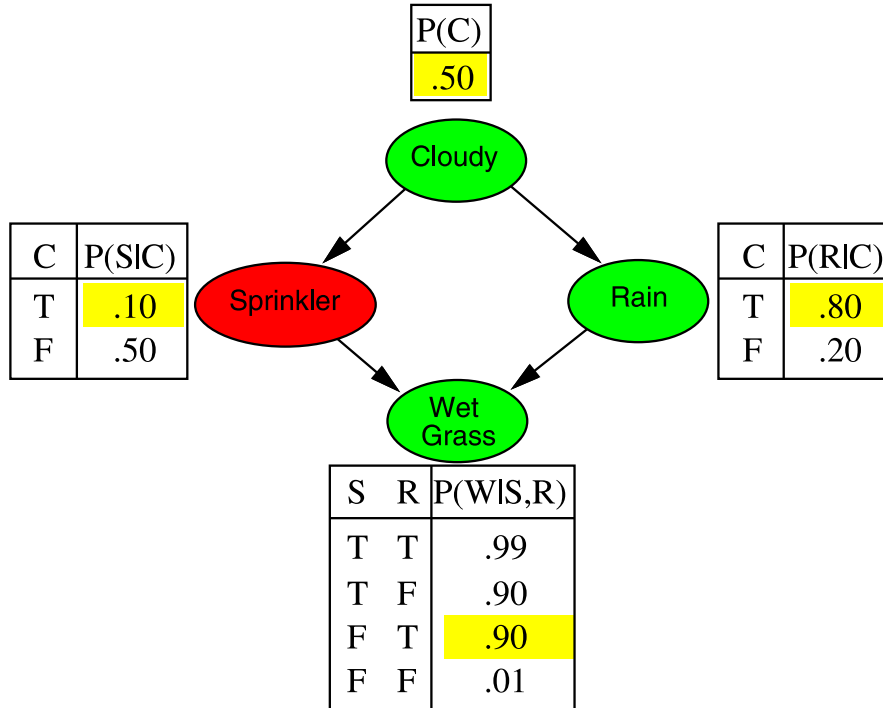


استنتاج با شبیه‌سازی اتفاقی

نمونه‌برداری از یک شبکه‌ی خالی: مثال (۷ از ۸)

F

T



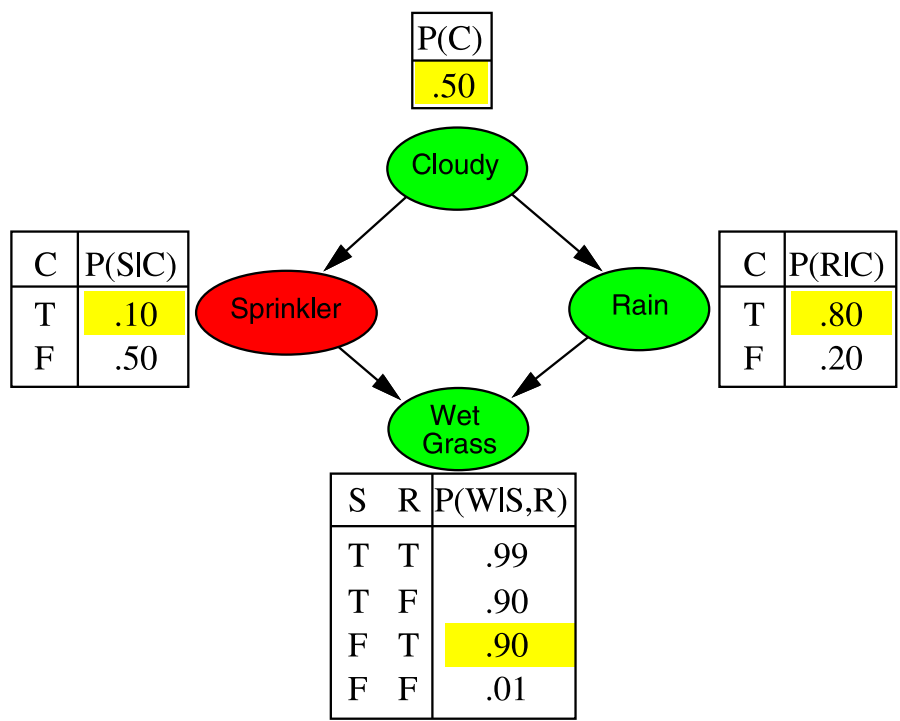
فرض می‌کنیم نمونه‌برداری از $\langle 0.9, 0.1 \rangle$ مقدار $P(WetGrass | Sprinkler = False, Rain = True) = 0.9$ برگرداند. *True*

استنتاج با شبیه‌سازی اتفاقی

نمونه‌برداری از یک شبکه‌ی خالی: مثال (۷ از ۸)

F

T



PRIOR-SAMPLE(*bn*) returns [True, False, True, True]

استنتاج با شبیه‌سازی اتفاقی

محاسبه

احتمال اینکه **PRIOR-SAMPLE** یک پیشامد خاص را تولید کند:

$$S_{PS}(x_1 \dots x_n) = \prod_{i=1}^n P(x_i | \text{parents}(X_i)) = P(x_1 \dots x_n)$$

یعنی: احتمال پیشین واقعی

E.g., $S_{PS}(t, f, t, t) = 0.5 \times 0.9 \times 0.8 \times 0.9 = 0.324 = P(t, f, t, t)$

Let $N_{PS}(x_1 \dots x_n)$ be the number of samples generated for event x_1, \dots, x_n

Then we have

$$\begin{aligned} \lim_{N \rightarrow \infty} \hat{P}(x_1, \dots, x_n) &= \lim_{N \rightarrow \infty} N_{PS}(x_1, \dots, x_n) / N \\ &= S_{PS}(x_1, \dots, x_n) \\ &= P(x_1 \dots x_n) \end{aligned}$$

یعنی: تخمین‌های استخراج‌شده از **PRIOR-SAMPLE** سازگار (**consistent**) هستند.

Shorthand: $\hat{P}(x_1, \dots, x_n) \approx P(x_1 \dots x_n)$

استنتاج با شبیه‌سازی اتفاقی

مثال

فرض کنید دسته‌ای از نمونه‌ها را از شبکه‌ی بیزی زیر گرفته باشیم:


$$[C, \neg S, T, W]$$

$$[C, S, T, W]$$

$$[\neg C, S, T, \neg W]$$

$$[C, \neg S, T, W]$$

$$[\neg C, S, \neg T, W]$$



برای محاسبه‌ی $P(W)$:

با شمارش داریم: $\langle w: 4, \neg w: 1 \rangle$

با نرمال‌سازی به دست می‌آوریم: $P(W) = \langle w: 0.8, \neg w: 0.2 \rangle$

با داشتن نمونه‌های بیشتر، به توزیع واقعی نزدیک‌تر می‌شویم.

استنتاج با شبیه‌سازی اتفاقی

مثال


فرض کنید دسته‌ای از نمونه‌ها را از شبکه‌ی بیزی زیر گرفته باشیم:

$$[C, \neg S, T, W]$$

$$[C, S, T, W]$$

$$[\neg C, S, T, \neg W]$$

$$[C, \neg S, T, W]$$

$$[\neg C, S, \neg T, W]$$


برای محاسبه‌ی $P(C|s)$:

برآمدهای C را شمارش می‌کنیم،

اما نمونه‌هایی که در آنها $S = s$ نیست را نادیده می‌گیریم (رد می‌کنیم: reject)

* به این روش رد کردن نمونه برداری می‌گوییم.

استنتاج با شبیه‌سازی اتفاقی

رد کردن نمونه‌برداری

REJECTION SAMPLING $\hat{P}(X|e)$ estimated from samples agreeing with e

```

function REJECTION-SAMPLING( $X, e, bn, N$ ) returns an estimate of  $P(X|e)$ 
  local variables:  $\mathbf{N}$ , a vector of counts over  $X$ , initially zero
  for  $j = 1$  to  $N$  do
     $\mathbf{x} \leftarrow$  PRIOR-SAMPLE( $bn$ )
    if  $\mathbf{x}$  is consistent with  $e$  then
       $\mathbf{N}[x] \leftarrow \mathbf{N}[x] + 1$  where  $x$  is the value of  $X$  in  $\mathbf{x}$ 
  return NORMALIZE( $\mathbf{N}[X]$ )

```

استنتاج با شبیه‌سازی اتفاقی

رد کردن نمونه‌برداری: مثال

REJECTION SAMPLING

E.g., estimate $\mathbf{P}(Rain|Sprinkler = true)$ using 100 samples

27 samples have *Sprinkler = true*

Of these, 8 have *Rain = true* and 19 have *Rain = false*.

$$\hat{\mathbf{P}}(Rain|Sprinkler = true) = \text{NORMALIZE}(\langle 8, 19 \rangle) = \langle 0.296, 0.704 \rangle$$

مشابه با یک روال تخمین تجربی در دنیای واقعی

استنتاج با شبیه‌سازی اتفاقی

رد کردن نمونه‌برداری: تحلیل

REJECTION SAMPLING

$$\begin{aligned}
 \hat{P}(X|e) &= \alpha N_{PS}(X, e) && \text{(algorithm defn.)} \\
 &= N_{PS}(X, e) / N_{PS}(e) && \text{(normalized by } N_{PS}(e)\text{)} \\
 &\approx P(X, e) / P(e) && \text{(property of PRIORSAMPLE)} \\
 &= P(X|e) && \text{(defn. of conditional probability)}
 \end{aligned}$$

⇐ نمونه‌برداری با رد کردن، تخمین‌های پسین **سازگار** را برمی‌گرداند.


مشکل: این روش به طور ناامیدکننده‌ای گران و پرهزینه است اگر $P(e)$ کوچک باشد.
 (در این صورت تعداد زیادی از نمونه‌ها دور ریخته می‌شود).
 $P(e)$ با تعداد متغیرهای شاهد به صورت نمایی افت می‌کند.

راه حل: وزن‌دهی درست‌نمایی (تنها نمونه‌های هماهنگ با شاهد e را تولید می‌کند).

استدلال احتمالاتی



منابع



Stuart Russell and Peter Norvig,
Artificial Intelligence: A Modern Approach,
 3rd Edition, Prentice Hall, 2010.

Chapter 14

14 PROBABILISTIC REASONING

In which we explain how to build network models to reason under uncertainty according to the laws of probability theory.

Chapter 13 introduced the basic elements of probability theory and noted the importance of independence and conditional independence relationships in simplifying probabilistic representations of the world. This chapter introduces a systematic way to represent such relationships explicitly in the form of **Bayesian networks**. We define the syntax and semantics of these networks and show how they can be used to capture uncertain knowledge in a natural and efficient way. We then show how probabilistic inference, although computationally intractable in the worst case, can be done efficiently in many practical situations. We also describe a variety of approximate inference algorithms that are often applicable when exact inference is infeasible. We explore ways in which probability theory can be applied to worlds with objects and relations—that is, to *first-order*, as opposed to *propositional*, representations. Finally, we survey alternative approaches to uncertain reasoning.

14.1 REPRESENTING KNOWLEDGE IN AN UNCERTAIN DOMAIN

In Chapter 13, we saw that the full joint probability distribution can answer any question about the domain, but can become intractably large as the number of variables grows. Furthermore, specifying probabilities for possible worlds one by one is unnatural and tedious.

We also saw that independence and conditional independence relationships among variables can greatly reduce the number of probabilities that need to be specified in order to define the full joint distribution. This section introduces a data structure called a **Bayesian network**¹ to represent the dependencies among variables. Bayesian networks can represent essentially any full joint probability distribution and in many cases can do so very concisely.

BAYESIAN NETWORK

¹ This is the most common name, but there are many synonyms, including **belief network**, **probabilistic network**, **causal network**, and **knowledge map**. In statistics, the term **graphical model** refers to a somewhat broader class that includes Bayesian networks. An extension of Bayesian networks called a **decision network** or **influence diagram** is covered in Chapter 16.