



## هوش مصنوعی پیشرفته

فصل ۱۴

# استدلال احتمالاتی

Probabilistic Reasoning

کاظم فولادی

دانشکده مهندسی برق و کامپیووتر

دانشگاه تهران

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

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<br><i>Bayesian Network</i>                        |                                      |
|---|--------------------------------------|
| گره‌ها<br><i>Nodes</i>  | پیوند‌ها<br><i>Links</i>             |
| نشان‌دهنده‌ی<br>متغیرهای تصادفی                               | نشان‌دهنده‌ی<br>رابطه‌ی تأثیر مستقیم |
| توزيع شرطی<br><i>Conditional Distribution</i>                 | (link ≈ “directly influences”)       |
| برای هر گره، توزیع شرطی آن گره<br>به شرط والدهای آن را داریم: |                                      |
| $P(X_i   Parents(X_i))$<br>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*

توبولوژی شبکه‌ی بیزی بیان استقلال شرطی را کدگذاری می‌کند.



## شبکه های بیزی

مثال: سیستم هشدار سرقت منزل

### BAYESIAN NETWORKS

شما دو همسایه به نام های **مری** و **جان** دارید.

آنها قول داده اند 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.

بایته گاهی **زمین لرزه** خفیف هم باعث به صدا در آمدن زنگ هشدار میشود.

میخواهیم با دانستن فرد تماس گیرنده، احتمال **سرقت** را تخمین بزنیم.

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

|      |           |       |          |          |
|------|-----------|-------|----------|----------|
| سرقت | زمین لرزه | هشدار | تماس جان | تماس مری |
|------|-----------|-------|----------|----------|



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

- وقوع یک سرقت میتواند زنگ هشدار را به صدا درآورد.

- وقوع یک زمین لرزه میتواند زنگ هشدار را به صدا درآورد.


- زنگ هشدار میتواند باعث شود مری تماس بگیرد.

- زنگ هشدار میتواند باعث شود جان تماس بگیرد.

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

$$O(2^n)$$



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

برای توزیع‌های توأم کامل  
 (نمایی بر حسب  $n$ )


برای توزیع‌های شرطی  
 (خطی بر حسب  $n$ )

## شبکه‌های بیزی


مفهوم «تراکم»: مثال

### COMPACTNESS

برای مثال سیستم هشدار سرقت



$$O(2^n)$$



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

برای توزیع‌های توأم کامل  
(نمایی بر حسب  $n$ )

$$2^5 = 32$$

برای توزیع‌های شرطی  
(خطی بر حسب  $n$ )

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

# هوش مصنوعی

استدلال احتمالاتی

۳

معناشناسی  
شبکه‌های  
بیزی

## معناشناسی شبکه‌های بیزی

THE SEMANTICS OF BAYESIAN NETWORKS

## معناشناسی شبکه‌های بیزی

## معناشناسی محلی

*Local Semantics*

## معناشناسی سراسری

*Global Semantics*

## معناشناسی شبکه‌های بیزی

معناشناسی سراسری

### THE SEMANTICS OF BAYESIAN NETWORKS

## معناشناسی شبکه‌های بیزی

معناشناسی سراسری  
Global Semantics

معناشناسی سراسری  
*Global Semantics*

توزیع توان کامل = حاصل ضرب توزیع‌های شرطی محلی

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

## معناشناسی شبکه‌های بیزی

معناشناسی سراسری: مثال

### THE SEMANTICS OF BAYESIAN NETWORKS

#### معناشناسی شبکه‌های بیزی


#### معناشناسی سراسری *Global Semantics*

توزیع توان کامل = حاصل ضرب توزیع‌های شرطی محلی

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

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

$$\begin{aligned} &= P(j|a)P(m|a)P(a|\neg b, \neg e)P(\neg b)P(\neg e) \\ &= 0.9 \times 0.7 \times 0.001 \times 0.999 \times 0.998 \\ &\approx 0.00063 \end{aligned}$$



## معناشناسی شبکه‌های بیزی

### معناشناسی محلی


#### THE SEMANTICS OF BAYESIAN NETWORKS

### معناشناسی شبکه‌های بیزی

#### معناشناسی محلی *Local Semantics*

#### معناشناسی کلی *Global Semantics*

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



## معناشناسی شبکه‌های بیزی

قضیه‌ی همارزی معناشناسی سراسری با معناشناسی محلی

### THE SEMANTICS OF BAYESIAN NETWORKS

#### معناشناسی شبکه‌های بیزی

##### معناشناسی محلی

*Local Semantics*

##### معناشناسی سراسری

*Global Semantics*

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 روشهای 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  $M, J, A, B, E$




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

## ساختن شبکه‌های بیزی

مثال (۲ از ۶)

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




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

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

## 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  $M, J, A, B, E$



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

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

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

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


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

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

## ساختن شبکه‌های بیزی

(مثال ۵ از ۶)

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



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

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

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


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

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

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

## 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)


سنجه احتمالات شرطی در جهت‌های غیرعلی دشوار است.

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

## ساخت شبکه‌های بیزی

مثال: تشخیص عیب خودرو

### EXAMPLE: CAR DIAGNOSIS



شاهد آغازین: **خودرو روش نمی‌شود**

متغیرهای آزمون پذیر (**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: بیمه‌ی 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

مشکل

**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 یکتابع چگالی شرطی

حل

مشکل

متغیرهای گسسته، والدهای پیوسته

استفاده از یکتابع چگالی شرطی

## 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

حل  
مشکل

(uncertain relationships)

استفاده از درجات مبتدا (noisy-OR rule)

مشکل


آنچه می‌دانیم از گره‌هایی که در مورد گره مورد بررسی قرار دارند

استفاده از یک تابع پیش‌گیری شدنی



آنچه می‌دانیم از گره‌هایی که در مورد گره مورد بررسی قرار دارند

استفاده از یک تابع پیش‌گیری شدنی



## توزیع‌های شرطی متراکم

برای گره‌های قطعی

### DETERMINISTIC NODES

مقدار گرهی قطعی از روی مقدار والدھای 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 گیرنده‌های مطمئن (deterministic nodes)

استفاده از روابط نامطمئن بین گردها

مشکل حل

برای روابط نامطمئن (uncertain relationships)

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

مشکل


استفاده از مدل noisy-OR برای گردهای مطمئن

استفاده از یک تابع جیگرانی مشترک



استفاده از مدل noisy-OR برای گردهای غایب

استفاده از یک تابع جیگرانی مشترک



## توزیع‌های شرطی متراکم

برای رابطه‌های نامطمئن

### UNCERTAIN RELATIONSHIPS

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

$$\text{Child} \Leftarrow \text{Parent}_1 \vee \text{Parent}_2 \vee \dots \vee \text{Parent}_k$$

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

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

۱ والدها شامل همهٔ علتها باشند:

همیشه می‌توان سایر علتها را با اضافه کردن یک گرهٔ نشتشی (leak node) پوشش داد.

۲ هر علت به تنهایی دارای احتمال شکست مستقل  $q_i$  باشد (مستقل از سایر والدها).

(individual inhibition probabilities) : احتمال ممانعت فردی  $q_i$

$$q_i = P(\neg \text{Child} \mid \neg \text{Parent}_1, \neg \text{Parent}_2, \dots, \neg \text{Parent}_i, \dots, \neg \text{Parent}_k)$$

در این صورت داریم:

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

## توزیع‌های شرطی متراکم

برای رابطه‌های نامطمئن: مثال

### UNCERTAIN RELATIONSHIPS

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

| <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                                 |
| F           | T          | F              | 0.8        | 0.2                                 |
| F           | T          | T              | 0.98       | $0.02 = 0.2 \times 0.1$             |
| T           | F          | F              | 0.4        | 0.6                                 |
| T           | F          | T              | 0.94       | $0.06 = 0.6 \times 0.1$             |
| T           | T          | F              | 0.88       | $0.12 = 0.6 \times 0.2$             |
| T           | T          | T              | 0.988      | $0.012 = 0.6 \times 0.2 \times 0.1$ |

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

بر اساس احتمالات ممانعت فردی،

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

می‌توان کل CPT را کامل کرد.

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

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

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

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



## توزیع‌های شرطی متراکم

برای متغیرهای پیوسته، والدهای گسته + پیوسته

### COMPACT CONDITIONAL DISTRIBUTIONS

برای گرهای قطعی (deterministic nodes)

استثنایه از روابط قطعی بین گرهای



برای روابط نامطمئن (uncertain relationships)

استثنایه از روابط منطقی (logically) باشد مدل noisy-OR



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

متغیرهای پیوسته، والدهای گسته + پیوسته

استفاده از یک تابع چگالی شرطی

حل  
مشکل

مشکل

مشکل

استثنایه از یک تابع چگالی شرطی


استثنایه از یک تابع چگالی شرطی

## توزيعهای شرطی متراکم

برای شبکه‌های بیزی هیبرید (گسته + پیوسته)

### HYBRID (DISCRETE+CONTINUOUS) NETWORKS

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



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

گزینه ۲) استفاده از خانواده‌های کانونیک توزیعهای پارامتری متناهی

چگونگی برخورد با  
متغیرهای پیوسته



## توزيعهای شرطی متراکم

برای شبکه‌های بیزی هیبرید (گسته + 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 گسته

معمولًاً **مدل گاوی خطی** برای تابع چگالی شرطی متدائل‌ترین گزینه است، مثلاً:

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




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 گاوی خطی

### HYBRID (DISCRETE+CONTINUOUS) NETWORKS



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




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

## توزيعهای شرطی متراکم

برای شبکه‌های بیزی هیبرید (گستته + پیوسته): برای متغیرهای پیوسته فرزند: توزیع گاوی خطی

### HYBRID (DISCRETE+CONTINUOUS) NETWORKS



شبکه‌ی گاوی خطی گستته + پیوسته، یک شبکه‌ی گاوی شرطی است.




یعنی: یک گاوی چندمتغیره بر روی همه‌ی متغیرهای پیوسته

برای هر ترکیب از مقادیر متغیرهای گستته 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 ۰.۵  
حاصل با متوسطگیری روی دو  
مقدار ممکن متغیر بولی

مجموع دو توزیع گاوسی، یک گاوسی است.

## توزیع‌های شرطی متراکم

برای متغیرهای گسته، والدهای پیوسته

### COMPACT CONDITIONAL DISTRIBUTIONS

برای گره‌های قابل تبلیغ (deterministic nodes)

استفاده از روابط فلسفی بین گره‌ها



برای نویمکن‌های دامنه‌ای (uncertain relationships)

استفاده از روابط مستقل و تردیدی همان‌دل OR



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

## مشکل

نمایش گره‌های پیوسته، والدهای گسته

استفاده از یک تابع جیگانی نشانه‌گذاری



متغیرهای گسته، والدهای پیوسته

استفاده از یک تابع چگالی شرطی

حل  
مشکل


## توزيعهای شرطی متراکم

برای شبکه‌های بیزی هیبرید (گسته + پیوسته): برای متغیرهای گسته فرزند و والدahای پیوسته

### HYBRID (DISCRETE+CONTINUOUS) NETWORKS


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

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



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

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 پربویت (Probit) از انتگرال تابع توزیع گاووسی استفاده می‌کند:

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

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


## توزیع‌های شرطی متراکم

برای شبکه‌های بیزی هیبرید (گسته + پیوسته): برای متغیرهای گسته 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.



## توزيعهای شرطی متراکم


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

### HYBRID (DISCRETE+CONTINUOUS) NETWORKS


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

مشابه پربویت (آستانه‌ی نرم) اما دُم‌های آن طولانی‌تر است.

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



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



استدلال احتمالاتی

۴

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

پرسش‌های عطفی  
*Conjunctive Queries*

شبکه‌های تصمیم حاوی اطلاعات سودمندی؛ استنتاج احتمالاتی لازم برای:  
 $P(\text{outcome} | \text{action}, \text{evidence})$

تصمیم‌های بهینه  
*Optimal Decisions*

به دنبال چه شاهدی برای بعد باید باشیم؟

ارزش اطلاعات  
*Value of Information*

کدام مقادیر احتمال، حیاتی‌ترین آنها هستند؟

تحلیل حساسیت  
*Sensitivity Analysis*

مثال: 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 دقیق

*Exact Inference*

### برشمارش

*Enumeration*

برآورد احتمالات پس از آنکه  
مشاهده شد

*Approximate Inference*

برآورد احتمالات پس از آنکه  
مشاهده شد

Markov Chain Monte Carlo

Stochastic Simulation

برآورد احتمالات پس از آنکه  
مشاهده شد

Variable Elimination

## استنتاج با برشماری

INFERENCE BY ENUMERATION


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

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

پرسوچو

## استنتاج با برنامه‌ریزی

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 برنامه


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 می‌شود!

## استنتاج در شبکه‌های بیزی

استنتاج دقیق با حذف متغیر

## استنتاج در شبکه‌های بیزی

استنتاج دقیق

*Exact Inference*

پیش‌بینی تقریبی

*Approximate Inference*

حذف متغیر

*Variable Elimination*

تعدادیابی

*Enumeration*

متغیر مارکوف مونت کارلو

*Markov Chain Monte Carlo*

رسانیدن شبیه‌سازی

*Forward Simulation*

## استنتاج با حذف متغير

### INFERENCE BY VARIABLE ELIMINATION

#### حذف متغير:

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

#### مثال

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

## استنتاج با حذف متغير

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 متغير

## فاکتورها

## INFERENCE BY VARIABLE ELIMINATION

فاکتورهای آغازین، CPT‌های محلی هستند:

$$\underbrace{P(B)}_{f_B(B)} \quad \underbrace{P(J|A)}_{f_J(A, J)} \quad \underbrace{P(A|B, E)}_{f_A(A, B, E)}$$



در طول حذف، فاکتورهای جدیدی ساخته می‌شوند.

4 numbers, one  
for each value  
of D and E

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

متغیرهای  
Variables  
introduced  
وارد شده

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 متغير

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 متغير

عمليات پايه: الحق فاكتورها (ضرب نقطه به نقطه): مثال

## JOIN FACTORS

| $A$ | $B$ | $\mathbf{f}_1(A, B)$ | $B$ | $C$ | $\mathbf{f}_2(B, C)$ | $A$ | $B$ | $C$ | $\mathbf{f}_3(A, B, C)$ |
|-----|-----|----------------------|-----|-----|----------------------|-----|-----|-----|-------------------------|
| 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:  $\mathbf{f}_1(A, B) \times \mathbf{f}_2(B, C) = \mathbf{f}_3(A, B, C)$ .

## 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 متغير

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

مجموع یابی یک متغیر از ضرب یکسری از فاکتورها:

- هر فاکتور ثابت را به خارج مجموع انتقال می‌دهیم.
- برای باقیماندهٔ فاکتورها:

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

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

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

Pointwise product of factors  $f_1$  and  $f_2$ :

$$\begin{aligned} f_1(x_1, \dots, x_j, y_1, \dots, y_k) \times f_2(y_1, \dots, y_k, z_1, \dots, z_l) \\ = f(x_1, \dots, x_j, y_1, \dots, y_k, z_1, \dots, z_l) \end{aligned}$$

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

## استنتاج با حذف متغير

استفاده از عملیات پایه: محاسبه: مثال

### INFERENCE BY VARIABLE ELIMINATION

$$P(b, j, m)$$

$$= \underbrace{P(b)}_B \sum_e \underbrace{P(e)}_E \sum_a \underbrace{P(a|b, e)}_A \underbrace{P(j|a)}_J \underbrace{P(m|a)}_M$$

$$= f_B(b) \sum_e f_E(e) \sum_a f_A(a, b, e) f_J(a) f_M(a)$$

$$= f_B(b) \sum_e f_E(e) \sum_a f_{AJM}(a, b, e)$$

$$= f_B(b) \sum_e f_E(e) f_{\bar{A}JM}(b, e)$$

$$= f_B(b) \sum_e f_{\bar{A}EJM}(b, e)$$

$$= f_B(b) f_{\bar{A}\bar{E}JM}(b)$$

$$= f_{\bar{A}B\bar{E}JM}(b)$$

## 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 CPT‌های 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.

همهی 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 متغير

مثال (١ از ٢)

## INFERENCE BY VARIABLE ELIMINATION

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



$$\frac{P(B)}{f_B(B)} \cdot \frac{P(E)}{f_E(E)} \cdot \underbrace{P(A|B, E)}_{f_A(A, B, E)} \cdot \underbrace{P(j|A)}_{f_J(A)} \cdot \underbrace{P(m|A)}_{f_M(A)}$$


Choose A

$$f_A(\underline{A}, B, E)$$

الحاقة


حاشیه‌سازی

$$f_J(\underline{A})$$



$$f_{AJM}(A, B, E)$$

$$f_M(\underline{A})$$




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

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

## استنتاج با حذف متغير

مثال (٢ از ٢)

## INFERENCE BY VARIABLE ELIMINATION



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

Choose E

$$f_E(\underline{E}) \quad \text{الحاق} \quad \text{حاشیه‌سازی}$$

$$f_{\bar{A}JM}(B, \underline{E}) \quad \times \quad f_{\bar{A}EJM}(B, E) \quad \Sigma \quad f_{\bar{A}\bar{E}JM}(B)$$

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

Finish

$$f_B(\underline{B}) \quad \text{الحاق} \quad \text{نرمال‌سازی}$$

$$f_{\bar{A}\bar{E}JM}(B) \quad \times \quad f_{\bar{A}B\bar{E}JM}(B) \quad \text{Normalize} \quad P(B|j, m)$$

## استنتاج با حذف متغير

شبہ 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(POINTWISE-PRODUCT( $factors$ ))

```

## استنتاج با حذف متغير


متغيرهای نامربوط

### IRRELEVANT VARIABLES

Consider the query  $P(JohnCalls | Burglary = true)$

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

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



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

قضیه

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

مثال

اگر یک متغير، جد یک متغير پرس و جو یا مشاهده نباشد، به آن پرس و جو نامربوط است.  
⇒ در الگوریتم حذف متغير، می‌توان این متغير نامربوط را پیش از ارزیابی پرس و جو حذف کرد.

## استنتاج با حذف متغير

متغيرهای 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  $P(JohnCalls | Alarm = true)$ , both *Burglary* and *Earthquake* are irrelevant

مثال

## استنتاج دقیق

پیچیدگی

## شبکه‌های بیزی

## شبکه‌های همبند چندتایی

*Multiply Connected Networks*

می‌توان 3SAT را به استنتاج دقیق کاهش داد  
**NP-hard**  $\Leftarrow$

معادل با شمارش مدل‌های  
**#P-complete**  $\Leftarrow$


## شبکه‌های همبند تنها (چند درختی)

*Singly Connected Networks (Polytrees)*

هر دو گره حداکثر با یک مسیر (بی‌جهت) به هم متصل می‌شوند.

هزینه‌ی زمان و فضای حذف متغیر  
 $O(d^k n)$


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




## استنتاج با حذف متغير

خوشبندی برای افزایش کارآیی (الگوریتم درخت مشترک)

## CLUSTERING (JOIN TREE ALGORITHMS)



(a)



(b)

**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*

شبکه‌های بیزی مارکوف  
Markov Chain Monte Carlo

شبیه‌سازی اتفاقی  
*Stochastic Simulation*

شبکه‌های بیزی مارکوف  
Markov Chain Bayesian

شبکه‌های بیزی متغیر  
Variable Elimination

شبکه‌های بیزی جمع‌آوری  
Enumeration

## استنتاج با شبیه‌سازی اتفاقی

### INFERENCE BY STOCHASTIC SIMULATION



#### ایده‌ی پایه

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.

#### 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 ایستان 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  $\mathbf{P}(X_1, \dots, X_n)$ 
   $\mathbf{x} \leftarrow$  an event with n elements
  for i = 1 to n do
     $x_i \leftarrow$  a random sample from  $\mathbf{P}(X_i \mid \text{Parents}(X_i))$ 
  return  $\mathbf{x}$ 


```

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


نمونه برداری 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  $\text{True } P(Cloudy) = <0.5, 0.5>$  برگرداند.

## استنتاج با شبیه‌سازی اتفاقی

نمونه‌برداری از یک شبکه‌ی خالی: مثال (۳ از ۸)


**F**  
**T**



## استنتاج با شبیه‌سازی اتفاقی

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

**F**  
**T**




فرض می‌کنیم نمونه‌برداری از  $\mathbf{P}(\text{Sprinkler} | \text{Cloudy} = \text{True}) = <0.1, 0.9>$  برگرداند.

## استنتاج با شبیه‌سازی اتفاقی

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

**F**  
**T**




فرض می‌کنیم نمونه‌برداری از  $\text{True}$   $\mathbf{P}(\text{Rain}|\text{Cloudy} = \text{True}) = <0.8, 0.2>$  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  $P(WetGrass|Sprinkler = False, Rain = True) = <0.9, 0.1>$  برگرداند.

## 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:

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

یعنی: احتمال پیشین واقعی

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

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 استخراج شده 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:

- $[c, \neg s, r, w]$
- $[c, s, r, w]$
- $[\neg c, s, r, \neg w]$
- $[c, \neg s, r, w]$
- $[\neg c, s, \neg r, w]$



:  $\mathbf{P}(W)$  برای محاسبه‌ی

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

$\mathbf{P}(W) = \langle w: 0.8, \neg w: 0.2 \rangle$  با نرمال‌سازی به‌دست می‌آوریم:


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:

- $[c, \neg s, r, w]$
- $[c, s, r, w]$
- $[\neg c, s, r, \neg w]$
- $[c, \neg s, r, w]$
- $[\neg c, s, \neg r, w]$



:  $\mathbf{P}(C|s)$  برای محاسبه‌ی

برآمده‌ای  $C$  را شمارش می‌کنیم،  
اما نمونه‌هایی که در آنها  $S = s$  نیست را نادیده می‌گیریم (رد می‌کنیم: (reject

\* به این روش رد کردن نمونه‌برداری می‌گوییم.

## استنتاج با شبیه‌سازی اتفاقی

رد کردن نمونه برداری

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:  $N$ , a vector of counts over  $X$ , initially zero
  for  $j = 1$  to  $N$  do
     $x \leftarrow$  PRIOR-SAMPLE( $bn$ )
    if  $x$  is consistent with  $e$  then
       $N[x] \leftarrow N[x] + 1$  where  $x$  is the value of  $X$  in  $x$ 
  return NORMALIZE( $N[X]$ )

```

## استنتاج با شبیه‌سازی اتفاقی

رد کردن نمونه برداری : مثال

REJECTION SAMPLING

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

27 samples have  $\text{Sprinkler} = \text{true}$

Of these, 8 have  $\text{Rain} = \text{true}$  and 19 have  $\text{Rain} = \text{false}$ .

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

مشابه با یک روال تخمین تجربی در دنیای واقعی

## استنتاج با شبیه‌سازی اتفاقی

رد کردن نمونه‌برداری: تحلیل

### REJECTION SAMPLING

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

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


**مشکل:** این روش به طور نامیدکننده‌ای 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: وزن دهی درست‌نمایی (تنها نمونه‌های هماهنگ با شاهد  $e$  را تولید می‌کند.)

## استنتاج با شبیه‌سازی اتفاقی

وزن دهی درست‌نمایی

### LIKELIHOOD WEIGHTING



بدون وزن دهی با درست‌نمایی، تخمین‌های پسین حاصل **سازگار** نخواهد بود.

## استنتاج با شبیه‌سازی اتفاقی

وزن دهنی درست‌نمایی: الگوریتم

### LIKELIHOOD WEIGHTING

```

function LIKELIHOOD-WEIGHTING( $X, e, bn, N$ ) returns an estimate of  $P(X|e)$ 
  local variables:  $\mathbf{W}$ , a vector of weighted counts over  $X$ , initially zero
    for  $j = 1$  to  $N$  do
       $\mathbf{x}, w \leftarrow$  WEIGHTED-SAMPLE( $bn$ )
       $\mathbf{W}[x] \leftarrow \mathbf{W}[x] + w$  where  $x$  is the value of  $X$  in  $\mathbf{x}$ 
    return NORMALIZE( $\mathbf{W}[X]$ )
  
```

```

function WEIGHTED-SAMPLE( $bn, e$ ) returns an event and a weight
   $\mathbf{x} \leftarrow$  an event with  $n$  elements;  $w \leftarrow 1$ 
  for  $i = 1$  to  $n$  do
    if  $X_i$  has a value  $x_i$  in  $e$ 
      then  $w \leftarrow w \times P(X_i = x_i | Parents(X_i))$ 
      else  $x_i \leftarrow$  a random sample from  $P(X_i | Parents(X_i))$ 
  return  $\mathbf{x}, w$ 
  
```

درست‌نمایی هر شاهد برای هر نمونه =

حاصل ضرب احتمالات شرطی آن متغیر شاهد با فرض معلوم بودن والدهای آن




## استنتاج با شبیه‌سازی اتفاقی

وزن دهنده درست نمایی: مثال (۱ از ۸)

LIKELIHOOD WEIGHTING $F$  $T$ 

| C | $P(S C)$ |
|---|----------|
| T | .10      |
| F | .50      |



$$w = 1.0$$


## استنتاج با شبیه‌سازی اتفاقی

وزن دهنی درست نمایی: مثال (۲ از ۸)

LIKELIHOOD WEIGHTING

*F*  
*T*

| C | P(S C) |
|---|--------|
| T | .10    |
| F | .50    |



$w = 1.0$

فرض می‌کنیم نمونه‌برداری از  $P(Cloudy) = <0.5, 0.5>$  برگرداند.

$$w \leftarrow w \times P(Cloudy = True) = 0.5$$


## استنتاج با شبیه‌سازی اتفاقی

وزن دهنده درستنمایی: مثال (۳ از ۸)

LIKELIHOOD WEIGHTING

*F*  
*T*

| C | P(S C) |
|---|--------|
| T | .10    |
| F | .50    |




## استنتاج با شبیه‌سازی اتفاقی

وزن دهنی درست نمایی: مثال (۴ از ۸)

LIKELIHOOD WEIGHTING**F****T**

| C | P(S C) |
|---|--------|
| T | .10    |
| F | .50    |



$$w = 0.5$$


یک متغیر شاهد نیست، پس از  $P(\text{Sprinkler} | \text{Cloudy} = \text{True}) = <0.8, 0.2>$  نمونه برداری می‌کنیم.  
 فرض می‌کنیم مقدار **False** برمی‌گرداند.

## استنتاج با شبیه‌سازی اتفاقی

( وزن دهنده درست نمایی : مثال (۵ از ۸) )

LIKELIHOOD WEIGHTING**F****T**

| C | P(S C) |
|---|--------|
| T | .10    |
| F | .50    |



$$w = 0.5$$


فرض می‌کنیم نمونه برداری از  $\text{Rain} | \text{Cloudy} = \text{True}$  مقدار  $\mathbf{P}(\text{Rain} | \text{Cloudy} = \text{True}) = <0.8, 0.2>$  برگرداند.

## استنتاج با شبیه‌سازی اتفاقی

وزن دهی درست نمایی: مثال (۸ از ۱۶)

LIKELIHOOD WEIGHTING $F$  $T$ 


| C | $P(S C)$ |
|---|----------|
| T | .10      |
| F | .50      |



$$w = 0.5$$

## استنتاج با شبیه‌سازی اتفاقی

وزن دهنی درست نمایی: مثال (۷ از ۸)

LIKELIHOOD WEIGHTING

یک متغیر شاهد است که مقدار آن *True* است، پس قرار می‌دهیم:


$$w \leftarrow w \times P(WetGrass = True \mid Sprinkler = False, Rain = True) = 0.5 \times 0.90 = 0.45$$

## استنتاج با شبیه‌سازی اتفاقی

( وزن دهنی درست نمایی : مثال (۸ از ۸) )

LIKELIHOOD WEIGHTING

*F*  
*T*



نمونه‌ی [True, False, True, True] را با وزن 0.45 برمی‌گرداند:

با توصیف Rain = True هماهنگ است (زیرا نمونه یک روز بارانی را توصیف می‌کند که بعید است آب‌پاشی صورت گیرد).


## استنتاج با شبیه‌سازی اتفاقی

وزن دهنده درست‌نمایی: تحلیل


### LIKELIHOOD WEIGHTING

احتمال نمونه‌برداری برای WEIGHTED-SAMPLE عبارت است از:

$$S_{WS}(\mathbf{z}, \mathbf{e}) = \prod_{i=1}^l P(z_i | parents(Z_i))$$



تذکر: تنها به شواهد در جدّها توجه کنید  
← جایی «در میان» توزیع پیشین و پسین



وزن برای نمونه‌ی داده شده‌ی  $\mathbf{z}$ ,  $\mathbf{e}$  عبارت است از:

$$w(\mathbf{z}, \mathbf{e}) = \prod_{i=1}^m P(e_i | parents(E_i))$$

احتمال نمونه‌برداری وزن دهنی شده عبارت است از:

$$\begin{aligned} S_{WS}(\mathbf{z}, \mathbf{e})w(\mathbf{z}, \mathbf{e}) \\ &= \prod_{i=1}^l P(z_i | parents(Z_i)) \prod_{i=1}^m P(e_i | parents(E_i)) \\ &= P(\mathbf{z}, \mathbf{e}) \quad (\text{بر اساس معناشناسی سراسری شبکه‌ی بیزی}) \end{aligned}$$

بنابراین، وزن دهنده درست‌نمایی تخمین‌های سازگار را بر می‌گرداند،

اما: کارآیی هنوز با تعداد زیاد متغیرهای شواهد تنزل می‌یابد

(زیرا نمونه‌های اندکی تقریباً همه‌ی وزن مجموع را دارند)

## استنتاج در شبکه‌های بیزی

استنتاج تقریبی با زنجیره‌ی مارکوف مونت کارلو

### استنتاج در شبکه‌های بیزی

#### استنتاج تقریبی *Approximate Inference*

زنجیره‌ی مارکوف مونت کارلو  
*Markov Chain Monte Carlo*

التجھیزات الستھانی  
*Stochastic Simulation*

التجھیزات الاعدادی  
*Variable Elimination*

التجھیزات الگوریتمی  
*Algorithmic*

التجھیزات الگوریتمی  
*Algorithmic*

التجھیزات الگوریتمی  
*Algorithmic*

التجھیزات الگوریتمی  
*Algorithmic*

## استنتاج با شبیه‌سازی اتفاقی

استنتاج تقریبی با استفاده از «زنجیره‌ی مارکوف مونت کارلو» MCMC

تولید هر نمونه با ایجاد یک تغییر تصادفی در نمونه‌ی تولید شده‌ی قبلی

### ایده‌ی پایه

متغیرهای شواهد را ثابت می‌گیریم.

حالت بعدی را با نمونه‌برداری یک متغیر با داشتن پتوی مارکوف تولید می‌کنیم.

متغیرها را به نوبت نمونه‌برداری می‌کنیم.

حالت شبکه: انتساب فعلی به همه‌ی متغیرها

## استنتاج با شبیه‌سازی اتفاقی

استنتاج تقریبی با استفاده از «زنگیره‌ی مارکوف مونت کارلو» MCMC: الگوریتم

```

MCMC-ASK
function GIBBS-ASK( $X, \mathbf{e}, bn, N$ ) returns an estimate of  $\mathbf{P}(X|\mathbf{e})$ 
  local variables:  $\mathbf{N}$ , a vector of counts for each value of  $X$ , initially zero
     $\mathbf{Z}$ , the nonevidence variables in  $bn$ 
     $\mathbf{x}$ , the current state of the network, initially copied from  $\mathbf{e}$ 

  initialize  $\mathbf{x}$  with random values for the variables in  $\mathbf{Z}$ 
  for  $j = 1$  to  $N$  do
    for each  $Z_i$  in  $\mathbf{Z}$  do
      set the value of  $Z_i$  in  $\mathbf{x}$  by sampling from  $\mathbf{P}(Z_i|mb(Z_i))$ 
       $\mathbf{N}[x] \leftarrow \mathbf{N}[x] + 1$  where  $x$  is the value of  $X$  in  $\mathbf{x}$ 
  return NORMALIZE( $\mathbf{N}$ )

```


همچنین می‌توانیم یک متغیر را برای نمونه‌برداری تصادفی در هر زمان انتخاب کنیم.

## استنتاج با شبیه‌سازی اتفاقی

استنتاج تقریبی با استفاده از «زنجیره‌ی مارکوف مونت کارلو» MCMC: زنجیره‌ی مارکوف

### MARKOV CHAIN


چهار حالت وجود دارد:  $Sprinkler = \text{true}$ ,  $WetGrass = \text{true}$  با



برای مدتی نگاه می‌کنیم و از آنجه دیدیم متوسط می‌گیریم.

## استنتاج با شبیه‌سازی اتفاقی

استنتاج تقریبی با استفاده از «زنگیره‌ی مارکوف مونت کارلو» MCMC: مثال



Estimate  $P(Rain | Sprinkler = \text{true}, WetGrass = \text{true})$

Sample *Cloudy* or *Rain* given its Markov blanket, repeat.  
Count number of times *Rain* is true and false in the samples.

E.g., visit 100 states

31 have  $Rain = \text{true}$ , 69 have  $Rain = \text{false}$

$$\hat{P}(Rain | Sprinkler = \text{true}, WetGrass = \text{true}) \\ = \text{NORMALIZE}(\langle 31, 69 \rangle) = \langle 0.31, 0.69 \rangle$$

## استنتاج با شبیه‌سازی اتفاقی

استنتاج تقریبی با استفاده از «زنجیره‌ی مارکوف مونت کارلو» MCMC: قضیه

قضیه

زنجیره‌ی مارکوف، به یک توزیع ایستان میل می‌کند:

کسر مدتی از زمان که در هر حالت صرف می‌شود،  
متناسب است با احتمال پسین آن.

## استنتاج با شبیه‌سازی اتفاقی

استنتاج تقریبی با استفاده از «زنگیرهای مارکوف مونت کارلو» MCMC: نمونه‌برداری پتوی مارکوف

### MARKOV BLANKET SAMPLING

Markov blanket of *Cloudy* is  
*Sprinkler* and *Rain*

Markov blanket of *Rain* is  
*Cloudy*, *Sprinkler*, and *WetGrass*

احتمال با داشتن پتوی مارکوف به صورت زیر محاسبه می‌شود:

$$P(x'_i | mb(X_i)) = P(x'_i | parents(X_i)) \prod_{Z_j \in Children(X_i)} P(z_j | parents(Z_j))$$

به سازگی در «sisteme های موازی با گزندادن پیام» پیاده‌سازی می‌شود (مثل مغز).

مسائل محاسباتی اصلی:

- ۱) دشواری فهمیدن دست‌یابی به همگرایی
- ۲) اتلاف‌کننده است، اگر پتوی مارکوف بزرگ باشد:  
 چندان تغییر نخواهد کرد ( $P(X_i | mb(X_i))$ )

## استنتاج با شبیه‌سازی اتفاقی

استنتاج تقریبی با استفاده از «زنگیره‌ی مارکوف مونت کارلو» MCMC: تحلیل: طرح کلی

Transition probability  $q(\mathbf{x} \rightarrow \mathbf{x})$

Occupancy probability  $\pi_t(\mathbf{x})$  at time  $t$

Equilibrium condition on  $\pi_t$  defines stationary distribution  $\pi(\mathbf{x})$

Note: stationary distribution depends on choice of  $q(\mathbf{x} \rightarrow \mathbf{x})$

Pairwise detailed balance on states guarantees equilibrium

Gibbs sampling transition probability:

sample each variable given current values of all others

$\Rightarrow$  detailed balance with the true posterior

For Bayesian networks, Gibbs sampling reduces to sampling conditioned on each variable's Markov blanket

## استنتاج با شبیه‌سازی اتفاقی

استنتاج تقریبی با استفاده از «زنگیره‌ی مارکوف مونت کارلو» MCMC: توزیع ایستان

### STATIONARY DISTRIBUTION

$\pi_t(\mathbf{x})$  = probability in state  $\mathbf{x}$  at time  $t$

$\pi_{t+1}(\mathbf{x})$  = probability in state  $\mathbf{x}$  at time  $t + 1$

$\pi_{t+1}$  in terms of  $\pi_t$  and  $q(\mathbf{x} \rightarrow \mathbf{x}')$

$$\pi_{t+1}(\mathbf{x}) = \sum_{\mathbf{x}} \pi_t(\mathbf{x}) q(\mathbf{x} \rightarrow \mathbf{x}')$$

Stationary distribution:  $\pi_t = \pi_{t+1} = \pi$

$$\pi(\mathbf{x}) = \sum_{\mathbf{x}} \pi(\mathbf{x}) q(\mathbf{x} \rightarrow \mathbf{x}') \quad \text{for all } \mathbf{x}$$

If  $\pi$  exists, it is unique (specific to  $q(\mathbf{x} \rightarrow \mathbf{x}')$ )

In equilibrium, expected “outflow” = expected “inflow”



## استنتاج با شبیه‌سازی اتفاقی

استنتاج تقریبی با استفاده از «زنگیره‌ی مارکوف مونت کارلو» MCMC: توازن جزئی

### DETAILED BALANCE

“Outflow” = “inflow” for each pair of states:

$$\pi(\mathbf{x})q(\mathbf{x} \rightarrow \mathbf{x}') = \pi(\mathbf{x}')q(\mathbf{x}' \rightarrow \mathbf{x}) \quad \text{for all } \mathbf{x}, \mathbf{x}'$$

Detailed balance  $\Rightarrow$  stationarity:

$$\begin{aligned} \sum_{\mathbf{x}} \pi(\mathbf{x})q(\mathbf{x} \rightarrow \mathbf{x}') &= \sum_{\mathbf{x}} \pi(\mathbf{x}')q(\mathbf{x}' \rightarrow \mathbf{x}) \\ &= \pi(\mathbf{x}') \sum_{\mathbf{x}} q(\mathbf{x}' \rightarrow \mathbf{x}) \\ &= \pi(\mathbf{x}') \end{aligned}$$

MCMC algorithms typically constructed by designing a transition probability  $q$  that is in detailed balance with desired  $\pi$

## استنتاج با شبیه‌سازی اتفاقی

استنتاج تقریبی با استفاده از «زنگیره‌ی مارکوف مونت کارلو» MCMC: نمونه‌برداری گیبس

### GIBBS SAMPLING

Sample each variable in turn, given **all other variables**

Sampling  $X_i$ , let  $\bar{\mathbf{x}}_i$  be all other nonevidence variables

Current values are  $x_i$  and  $\bar{\mathbf{x}}_i$ ;  $\mathbf{e}$  is fixed

Transition probability is given by

$$q(\mathbf{x} \rightarrow \mathbf{x}') = q(x_i, \bar{\mathbf{x}}_i \rightarrow x'_i, \bar{\mathbf{x}}_i) = P(x'_i | \bar{\mathbf{x}}_i, \mathbf{e})$$

This gives detailed balance with true posterior  $P(\mathbf{x}|\mathbf{e})$ :

$$\begin{aligned} \pi(\mathbf{x})q(\mathbf{x} \rightarrow \mathbf{x}') &= P(\mathbf{x}|\mathbf{e})P(x'_i | \bar{\mathbf{x}}_i, \mathbf{e}) = P(x_i, \bar{\mathbf{x}}_i | \mathbf{e})P(x'_i | \bar{\mathbf{x}}_i, \mathbf{e}) \\ &= P(x_i | \bar{\mathbf{x}}_i, \mathbf{e})P(\bar{\mathbf{x}}_i | \mathbf{e})P(x'_i | \bar{\mathbf{x}}_i, \mathbf{e}) \quad (\text{chain rule}) \\ &= P(x_i | \bar{\mathbf{x}}_i, \mathbf{e})P(x'_i, \bar{\mathbf{x}}_i | \mathbf{e}) \quad (\text{chain rule backwards}) \\ &= q(\mathbf{x}' \rightarrow \mathbf{x})\pi(\mathbf{x}') = \pi(\mathbf{x}')q(\mathbf{x}' \rightarrow \mathbf{x}) \end{aligned}$$

## استنتاج با شبیه‌سازی اتفاقی

کارآیی الگوریتم‌های تقریبی

### PERFORMANCE OF APPROXIMATION ALGORITHMS

Absolute approximation:  $|P(X|e) - \hat{P}(X|e)| \leq \epsilon$

Relative approximation:  $\frac{|P(X|e) - \hat{P}(X|e)|}{P(X|e)} \leq \epsilon$

Relative  $\Rightarrow$  absolute since  $0 \leq P \leq 1$  (may be  $O(2^{-n})$ )

Randomized algorithms may fail with probability at most  $\delta$

Polytime approximation:  $\text{poly}(n, \epsilon^{-1}, \log \delta^{-1})$

Theorem (Dagum and Luby, 1993): both absolute and relative approximation for either deterministic or randomized algorithms are NP-hard for any  $\epsilon, \delta < 0.5$

(Absolute approximation polytime with no evidence—Chernoff bounds)




استدلال احتمالاتی

۴

مدل‌های  
احتمال  
رابطه‌ای  
و  
مرتبه اول

## مدل‌های احتمال رابطه‌ای و مرتبه اول




**Figure 14.17** (a) Bayes net for a single customer  $C_1$  recommending a single book  $B_1$ .  $Honest(C_1)$  is Boolean, while the other variables have integer values from 1 to 5. (b) Bayes net with two customers and two books.

## مدل‌های احتمال رابطه‌ای و مرتبه اول

$$P(\phi) = \sum_{\omega: \phi \text{ is true in } \omega} P(\omega)$$

## مدل‌های احتمال رابطه‌ای و مرتبه اول



**Figure 14.18** Top: Some members of the set of all possible worlds for a language with two constant symbols,  $R$  and  $J$ , and one binary relation symbol, under the standard semantics for first-order logic. Bottom: the possible worlds under database semantics. The interpretation of the constant symbols is fixed, and there is a distinct object for each constant symbol.

## مدل‌های احتمال رابطه‌ای و مرتبه اول

### مدل‌های احتمال رابطه‌ای

#### RELATIONAL PROBABILITY MODELS

$Honest : Customer \rightarrow \{true, false\}$   $Kindness : Customer \rightarrow \{1, 2, 3, 4, 5\}$

$Quality : Book \rightarrow \{1, 2, 3, 4, 5\}$

$Recommendation : Customer \times Book \rightarrow \{1, 2, 3, 4, 5\}$

$Honest(c) \sim \langle 0.99, 0.01 \rangle$

$Kindness(c) \sim \langle 0.1, 0.1, 0.2, 0.3, 0.3 \rangle$

$Quality(b) \sim \langle 0.05, 0.2, 0.4, 0.2, 0.15 \rangle$

$Recommendation(c, b) \sim RecCPT(Honest(c), Kindness(c), Quality(b))$


$Recommendation(c, b) \sim \begin{array}{l} \textbf{if } Honest(c) \textbf{ then } \\ \quad HonestRecCPT(Kindness(c), Quality(b)) \\ \textbf{else } \langle 0.4, 0.1, 0.0, 0.1, 0.4 \rangle . \end{array}$

$Recommendation(c, b) \sim \begin{array}{l} \textbf{if } Honest(c) \textbf{ then } \\ \quad \textbf{if } Fan(c, Author(b)) \textbf{ then } Exactly(5) \\ \quad \textbf{else } HonestRecCPT(Kindness(c), Quality(b)) \\ \textbf{else } \langle 0.4, 0.1, 0.0, 0.1, 0.4 \rangle \end{array}$

## مدل‌های احتمال رابطه‌ای و مرتبه اول

### مدل‌های احتمال رابطه‌ای

#### RELATIONAL PROBABILITY MODELS



**Figure 14.19** Fragment of the equivalent Bayes net when  $Author(B_2)$  is unknown.

استدلال احتمالاتی

۷

# سایر روش‌های استدلال نامطمئن

## روش‌های برخورد با عدم اطمینان

| روش‌های برخورد با عدم اطمینان (استدلال نامطمئن)               |  |  |  |   |
|---|--|--|--|---|
| <b>نظریه احتمال</b><br><i>Probability Theory</i>              | <b>منطق فازی</b><br><i>Fuzzy Logic</i>           | <b>نظریه دمپستر-شاfer</b><br><i>Dempster-Shafer theory</i> | <b>مبتنی بر قاعده</b><br><i>Rule-based</i> | <b>منطق غیریکنوا/بیش‌فرض</b><br><i>Default/Nonmonotonic Logic</i> |
| درجه‌ی باور به درستی رویداد<br><i>Belief Degree for Truth</i> | بازنایی سربستگی<br><i>Representing Vagueness</i> | بازنایی ناآگاهی<br><i>Representing Ignorance</i>           | با فاکتور فاج<br><i>Using Fudge Factor</i> | استدلال‌های کیفی<br><i>Qualitative Reasoning</i>                  |

## روش‌های برخورد با عدم اطمینان

منطق غیریکنوا / منطق پیش‌فرض

| روش‌های برخورد با عدم اطمینان (استدلال نامطمئن)     |                       |                                  |                                       |  |
|---|-----------------------|----------------------------------|---------------------------------------|--|
| منطق غیریکنوا/پیش‌فرض                               | استدلال‌های کیفی      | منطق بُل                         | منطق فازی                             | منطق احتمال                                    |
| Default/Nonmonotonic Logic<br>Qualitative Reasoning | Qualitative Reasoning | Judge-based<br>Using Judge Boxes | Fuzzy Logic<br>Representing Vagueness | Probability Theory<br>Belief Degrees for Truth |

استفاده از استدلال‌های کیفی (مشابه منطق انسانی) به جای محاسبات عددی

منطق پیش‌فرض:

برخورد با نتایج به صورت باور تا زمانی که دلیل بهتری برای باور به چیز دیگری پیدا شود.

مثال: بهفرض، ماشین من لاستیک پنچر ندارد،  
بهفرض،  $A_{25}$  من را بهموقع می‌رساند مگر اینکه با شاهدی تناقض پیدا کند.

مشکلات: \* چه فرض‌هایی مستدل هستند؟ \* چگونگی با تناقض‌ها برخورد کنیم؟

## روش‌های برخورد با عدم اطمینان

### مبتنی بر قاعده

| روش‌های برخورد با عدم اطمینان (استدلال نامطمئن) |                                       |  |                                  |  |
|---|---------------------------------------|--|----------------------------------|--|
| نظریه احتمال                                    | مدل‌طیق هایزمن                        | مدل‌طیق دمپستر-شالیور                              | مبتنی بر قاعده                   | مدل‌طیق دیامونوماتیک                     |
| Probability Theory<br>Belief Propagation        | Fuzzy Logic<br>Representing Vagueness | Dempster-Shafer Theory<br>Representing Uncertainty | Rule-based<br>Using Fudge Factor | Diagonal Reasoning<br>Circular Reasoning |

ساخت سیستم‌های مبتنی بر قاعده‌ی منطقی،  
با اضافه کردن نوعی **عامل فاج** به هر قاعده، برای برخورد با عدم اطمینان

$$A_{25} \mapsto_{0.3} \text{AtAirportOnTime}$$

$$\text{Sprinkler} \mapsto_{0.99} \text{WetGrass}$$

$$\text{WetGrass} \mapsto_{0.7} \text{Rain}$$

مشکلات: \* چگونگی ترکیب نتایج: مثلاً  $\text{Sprinkler} \mapsto \text{Rain}??$  با چه درجه‌ای؟

## روش‌های برخورد با عدم اطمینان

نظريه دمپستر- شافر

| روش‌های برخورد با عدم اطمینان (استدلال نامطمئن) |  |  |                                       |   |
|---|--|--|---------------------------------------|---|
| نظریه احتمالاتی<br>Probability Theory           | نظریه غازی<br>Fuzzy Logic              | نظريه دمپستر- شافر<br>Dempster-Shafer theory | نظریه قاعده‌گذاری<br>Rule-based       | نظریه ریاضیاتی احتمالی<br>Probabilistic Logic |
| نمایش بیانی<br>Belief Representation            | نمایش غازی<br>Representation Vagueness | نمایش ناگاهی<br>Representing Ignorance       | نمایش قاعده‌گذاری<br>Using Rule-based | نمایش کvantitative<br>Quantitative Reasoning  |

استفاده از درجه‌های باور با مقادیر بازه‌ای (کران بالا، کران پایین)  
برای بازنمایی دانایی عامل در مورد احتمال یک گزاره

مشکلات: \* پیچیدگی بالای محاسباتی

## روش‌های برخورد با عدم اطمینان

### منطق فازی

| روش‌های برخورد با عدم اطمینان (استدلال نامطمئن)   |   |  |                                       |  |
|---|---|--|---------------------------------------|--|
| منطق احتمالی<br>Probability Theory                | منطق فازی<br>Fuzzy Logic                  | منطق پروپرستی<br>Propositional Logic     | منطق قاعده‌بندی<br>Rule-based         | منطق نواماتماتیکی<br>Nonmonotonic Logic  |
| دروجتیگری مبنای حقیقتی<br>Belief Degree for Truth | بازنایی سربستگی<br>Representing Vagueness | پیش‌نمایی دلایل<br>Representing Premises | با هاکتوپر نایج<br>Using Fuzzy Doctor | چارچوب ریسمانی<br>Quantitative Reasoning |

هست‌شناصی منطق فازی: اجازه دادن به سربستگی گزاره می‌تواند تا مرتبه‌ای درست باشد (**درجه‌ی درستی**)

احتمالات و منطق معمولی تعهدات هست‌شناختی یکسانی دارند:  
گزاره‌های دنیا درست یا نادرست هستند،  
حتی اگر عامل نامطمئن باشد که کدام یک است.

\* مناسب برای کار کردن با مفاهیمی که حد و مرز دقیقی ندارند.

## روش‌های برخورد با عدم اطمینان

### نظریه‌ی احتمال

| روش‌های برخورد با عدم اطمینان (استدلال نامطمئن)        |  |  |  |   |
|--|--|--|--|---|
| نظریه احتمال<br>Probability Theory                     | منطق فازی<br>Fuzzy Logic                         | منطق کامپیوتر-شناختی<br>Computer-Shafer theory   | منطق قواعدی<br>Rule-based                    | منطق غایم‌گویی<br>Qualitative Reasoning             |
| درجه‌ی باور به درستی رویداد<br>Belief Degree for Truth | نمایش مغایر سریع‌نمایی<br>Representing Vagueness | نمایش غایم‌گویی شناختی<br>Representing Ignorance | پایه‌گذاری بر اساس قواعد<br>Using Rule-Based | نمایش غایم‌گویی تکیه‌گذاری<br>Qualitative Reasoning |

به هر جمله یک درجه‌ی باور بین صفر و یک نسبت داده می‌شود.

احتمالات، روشی برای جمع‌بندی عدم اطمینان ناشی از تنبلی و ناگاهی است.

مثال:  $A_{25}$  من را به موقع می‌رساند با احتمال 0.04


مشکلات: \* چه فرض‌هایی مستدل هستند؟ \* چگونگی با تناقض‌ها برخورد کنیم؟

استدلال احتمالاتی



# منابع

## منبع اصلی



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**<sup>1</sup> 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.

<sup>1</sup> 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.