



هوش مصنوعی

فصل ۱۳

کمی‌سازی عدم اطمینان

Quantifying Uncertainty

کاظم فولادی

دانشکده مهندسی برق و کامپیووتر

دانشگاه تهران

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

هوش مصنوعی

کمی‌سازی عدم اطمینان

۱

کنش
تحت
عدم اطمینان

مشکلات روش‌های مبتنی بر منطق قطعی در عمل

مشکلات روش‌های مبتنی بر منطق قطعی در عمل

عدم وجود تضمین در طرح	بزرگ شدن طرح اقتضائی	تفسیر مشاهده‌پذیری جزئی
<p>کاهی طرحی وجود ندارد که تضمین کند به هدف می‌رسیم؛ اما عامل باید کش کند! ↓ باید راهی برای مقایسه‌ی مزایای طرح‌هایی که تضمین نمی‌شوند، داشته باشیم</p>	<p>یک طرح اقتضائی درست که همه‌ی سرانجام‌ها را در نظر می‌گیرد، می‌تواند بسیار بزرگ شود و باید اقتضائات غیرمحتمل را نیز در نظر بگیرد.</p>	<p>هنگام تفسیر اطلاعات حسگری جزئی، یک عامل منطقی باید همه‌ی توضیحات منطقی ممکن برای مشاهدات را بررسی کند (بدون توجه به میزان شانس آنها) ↓ بازنمایی‌های حالت باور بزرگ و بیچیده‌ی غیر ممکن</p>

مشکلات روش‌های مبتنی بر منطق قطعی در عمل

مثال: رسیدن به پرواز هوایپما با تاکسی خودکار

$A_t = \text{کنش حرکت به سمت فرودگاه } t \text{ دقیقه قبل از پرواز}$

آیا A_t من را به موقع می‌رساند؟

مشکلات

مشاهده‌پذیری جزئی	حسگرهای نویزی	عدم اطمینان از برآمد کنش‌ها	دشواری پیش‌بینی ترافیک
وضعیت جاده طرح سایر رانندها، ...	گزارش‌های ترافیکی رادیو	مثلاً پنجر شدن تایر، ...	پیچیدگی بالای مدل‌سازی و پیش‌بینی ترافیک

بنابراین، روی کرد منطقی خالص، منجر به یکی از این دو مورد می‌شود:

ریسک نادرست بودن	رسیدن به نتایج بسیار ضعیف برای تصمیم‌گیری
من را به موقع می‌رساند.	A_{25} من را به موقع می‌رساند اگر هیچ تصادفی روی پل رخ نداده باشد و باران نیاید و تایرهای ماشین سالم باقی بمانند و ...

می‌توان گفت قاعدهٔ A_{1440} من را به موقع می‌رساند؛ اما باید کل شب را در فرودگاه بمانم!

مشکلات روش‌های مبتنی بر منطق قطعی در عمل

مثال: دامنه‌ی دندان‌پزشکی

تشخیص دلیل دندان‌درد یک بیمار دندان‌پزشکی

نوشتمن قواعد برای **تشخیص** دندان‌پزشکی با استفاده از منطق گزاره‌ای:

Toothache \Rightarrow *Cavity*. علت دندان‌درد کرم‌خوردگی است

مشکل این است که این قاعده غلط است!

همه‌ی بیماران دارای دندان‌درد دارای کرم‌خوردگی نیستند؛

برخی بیماری لثه دارند، برخی آبسه دارند، یا یکی از مشکلات متعدد دیگر ...

Toothache \Rightarrow *Cavity* \vee *GumProblem* \vee *Abscess* ...

متاسفانه برای درست کردن این قاعده،

باید تقریباً یک لیست نامحدود از مشکلات ممکن را اضافه کنیم!

اگر سعی کنیم این قاعده را در قالب قاعده‌ی علی هم بنویسیم:

Cavity \Rightarrow *Toothache*. کرم‌خوردگی موجب دندان‌درد می‌شود

باز هم نادرست است: همه‌ی کرم‌خوردگی‌ها موجب درد نمی‌شود!

تنها راه برای درست نوشتمن این قاعده: باید آن را به لحاظ منطقی جامع کنیم (که عملاً نمی‌شود!).

مشکلات روش‌های مبتنی بر منطق قطعی در عمل

دلایل شکست روی‌کرد منطقی

دلایل شکست روی‌کرد منطقی در مسئله‌ای مانند تشخیص پزشکی

نااگاهی عملی <i>Practical Ignorance</i>	نااگاهی نظری <i>Theoretical Ignorance</i>	تبنی <i>Laziness</i>
عدم امکان آزمون همه‌ی شرایط	ناقص بودن نظریه‌های علمی	کار زیاد لازم برای تنظیم قواعد
حتی اگر تمامی قواعد را هم بشناسیم، باز هم ممکن است نتوانیم در مورد بیمار نظر قطعی ارائه بدھیم، مثلاً ممکن است نتوانیم همه‌ی آزمایش‌های لازم را انجام بدھیم.	دانش پزشکی هیچ نظریه‌ی کامل و جامعی برای این زمینه ندارد!	فهرست کردن مجموعه‌ی کاملی از مقدمات و تالیه‌های مورد نیاز برای ایجاد قواعد بدون استثناء، کار و زمان بسیاری می‌برد و به کارگیری چنین قواعدی بسیار مشکل است.

روش‌های برخورد با عدم اطمینان

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

روش‌های برخورد با عدم اطمینان

منطق غیریکنوا / منطق پیش‌فرض

روش‌های برخورد با عدم اطمینان (استدلال نامطمئن)				
منطق غیریکنوا/پیش‌فرض	منطق کیفی	منطق ترجیح	منطق قاعده	منطق غیریکنوا/پیش‌فرض
استدلال‌های کیفی <i>Qualitative Reasoning</i>	منطق غیریکنوا/پیش‌فرض <i>Default/Nonmonotonic Logic</i>	منطق قاعده <i>Rule-based</i>	منطق ترجیح <i>Preference logic</i>	منطق کیفی <i>Fuzzy Logic</i>

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: به فرض، ماشین من لاستیک پنچر ندارد،
به فرض، A_{25} من را به موقع 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)					
پیش‌بینی احتمالی	مغایل	تئوری کامپیوتر-شناختی	مبتنی بر قاعده	مغایل پیش‌بینی احتمالی	استدلال از پیش‌بینی
Probabilistic Theory	Fuzzy Logic	Computer-Science Theory	Rule-based	Probabilistic Reasoning	Neuromimetic Logic
پیش‌بینی احتمالی برای هر قاعده، برای مجموعه از مثال‌ها	مغایل ممکن است در مجموعه از مثال‌ها	نمایش اثبات برای مجموعه از مثال‌ها	با فاکتور فاج	استدلال از پیش‌بینی احتمالی	استدلال از پیش‌بینی
Relief Function for Each Rule	Representing Fuzziness	Representing Evidence	Using Fudge Factor	Neuromimetic Reasoning	Inductive Reasoning

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

$$A_{25} \mapsto_{0.3} \text{At Airport On Time}$$

$$\text{Sprinkler} \mapsto_{0.99} \text{Wet Grass}$$

$$\text{Wet Grass} \mapsto_{0.7} \text{Rain}$$

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

روش‌های برخورد با عدم اطمینان (استدلال نامطمئن)

نظريه دمپستر-شاfer

روش‌های برخورد با عدم اطمینان (استدلال نامطمئن)				
نظریه احتمال Probability Theory	منطق فازی Fuzzy Logic	نظريه دمپستر-شاfer Dempster-Shafer theory	نظریه بندهای Evidence-based	منطق دیجیتالی Digital Fuzzy Logic
درستگیری احتمال Belief Degree for Truth	نمایش غمغایبی Representing Vagueness	بازنایی ناکاهی Representing Ignorance	پرسیدن پرسش Owing Pudge Factor	گزینه‌گذاری کیفی Qualitative Reasoning

استفاده از درجه‌های باور با مقادیر بازه‌ای (کران بالا، کران پایین)
برای بازنایی 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 احتمال	منطق فازی	Hempster-Shaffer theory	منطق ران	منطق راموناتوریک
منطق احتمال Probability Theory	منطق فازی Fuzzy Logic	Hempster-Shaffer theory	منطق ران Rain-based	منطق راموناتوریک Ramonantastic Logic

منطق احتمال
Probability Theory

منطق فازی
Fuzzy Logic

منطق راموناتوریک
Ramonantastic Logic

منطق ران
Rain-based

منطق احتمال
Probability Theory

منطق فازی
Fuzzy Logic

منطق راموناتوریک
Ramonantastic Logic

هست‌شناصی منطق فازی: اجازه دادن به سربستگی
یک 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

نظريه احتمال

روش‌های برخورد با عدم اطمینان (استدلال نامطمئن)				
نظريه احتمال Probability Theory	لOGIC شماست Fuzzy Logic	دampener-Shifter theory	معتمدشون هم هستند Evidence-based	گوآرماتیک شماست Normative Logic
درجه‌ی باور به درستی رویداد Belief Degree for Truth	دیگر ندانیدنی سیستمی Representing Ignorance	پاچیده‌گویی دانندگویی Representing Ignorance	پاچکنی پایان Using Judge Factor	اسندگاری‌گذاری قیمتی Quiditative Reasoning

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

احتمالات، روشی برای جمع‌بندی عدم اطمینان ناشی از تنبی 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؟

انواع منطق‌ها

منطق احتمالات

تعهدات منطق

تعهدات معرفت‌شناختی
*Epistemological Commitment*تعهدات هستی‌شناختی
Ontological Commitment

منطق گزاره‌ای <i>Propositional Logic</i>	منطق مرتبه اول <i>First-Order Logic</i>	منطق زمانی <i>Temporal Logic</i>	نظریه‌ی احتمال <i>Probability Theory</i>
درست / نادرست / ناشناخته <i>True / False / Unknown</i>	واقعیت‌ها <i>Facts</i>	واقعیت‌ها، اشیا، رابطه‌ها <i>Facts, Objects, Relations</i>	واقعیت‌ها، اشیا، رابطه‌ها، زمان‌ها <i>Facts, Objects, Relations, Times</i>
درست / نادرست / ناشناخته <i>True / False / Unknown</i>	واقعیت‌ها، اشیا، رابطه‌ها <i>Facts, Objects, Relations</i>	واقعیت‌ها، اشیا، رابطه‌ها، زمان‌ها <i>Facts, Objects, Relations, Times</i>	واقعیت‌ها <i>Facts</i>
درجه‌ی باور بین صفر تا یک <i>Degree of Belief 0...1</i>	واقعیت‌ها <i>Facts</i>		
بازه‌ی معلومی از مقادیر <i>Known interval value</i>	واقعیت‌هایی با درجه‌ی درستی بین ۰ و ۱ <i>Facts with Degree of Truth in [0,1]</i>		منطق فازی <i>Fuzzy Logic</i>

منشا احتمالات

فلسفه احتمال

منشا احتمالات		
موقع سوبژکتیو <i>Subjective Position</i>	موقع ابژکتیو <i>Objective Position</i>	موقع فراوانی‌گرا <i>Frequentist Position</i>
<p>احتمالات روشی برای بیان باور عامل است</p> <p>احتمالات، گزاره‌ها را به حالت دانایی شخصی یک عامل مرتبط می‌کند.</p>	<p>احتمالات نمودهای واقعی جهان هستند</p> <p>اشیا به طور طبیعی تمایل به رفتار غیرمطئن دارند (نه اینکه احتمالات فقط توصیفی از درجه‌ی باور مشاهده‌کننده باشد).</p>	<p>اعداد احتمال حاصل تجربه است</p> <p>احتمالات برخاسته از فراوانی نسبی پدیده‌هاست.</p>

احتمال

مثال

احتمال بیزی (سوبژکتیو):

احتمالات، گزاره‌ها را به حالت دانایی شخصی یک عامل مرتبط می‌کند.

$$P(A_{25}|\text{no reported accidents}) = 0.06$$

مقدار احتمال می‌تواند از تجربیات گذشته در وضعیت‌های مشابه، یاد گرفته شود.

احتمالات گزاره‌ها با آمدن شاهد جدید، تغییر می‌کند:

$$P(A_{25}|\text{no reported accidents, 5 a.m.}) = 0.15$$

(قابل مقایسه با استلزم منطقی $KB \models \alpha$ ، نه درستی گزاره)

تصمیم‌گیری رسیوئال تحت عدم اطمینان

مثال

فرض می‌کنیم باورهای زیر را داریم:

$$P(A_{25} \text{ gets me there on time} | \dots) = 0.04$$

$$P(A_{90} \text{ gets me there on time} | \dots) = 0.70$$

$$P(A_{120} \text{ gets me there on time} | \dots) = 0.95$$

$$P(A_{1440} \text{ gets me there on time} | \dots) = 0.9999$$

کدام کنش باید انتخاب شود؟

تصمیم‌گیری در مورد کنش فقط به احتمال وابسته نیست؛

بلکه به ترجیح ما در مورد اهمیت پرواز، میزان معطلی در فرودگاه و ... هم وابسته است.

نظریه‌ی سودمندی

UTILITY THEORY

نظریه‌ای برای بازنمایی و استدلال برای ترجیح‌ها

نظریه‌ی سودمندی

Utility Theory

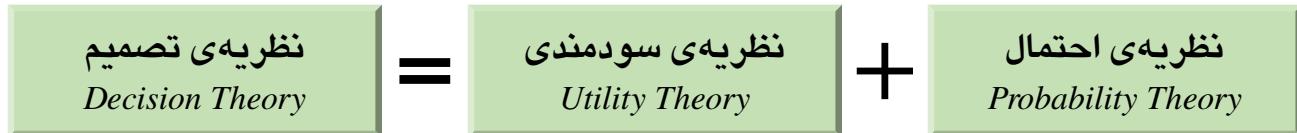
این نظریه بیان می‌کند که هر حالت برای یک عامل درجه‌ای از سودمندی را دارد و عامل حالتی که سودمندی بیشتری دارد را ترجیح می‌دهد.

عامل باید بین **برآمدهای ممکن مختلف طرح‌های گوناگون**، **ترجیح‌هایی preferences** **outcome** داشته باشد.

نظريه‌ي تصميم

نظريه‌ي عمومي تصميم‌های رسيونال

DECISION THEORY



يك عامل رسيونال است

اگر و فقط اگر

کنشی با بالاترین سودمندی مورد انتظار را انتخاب کند.

ميانگين روی همه‌ي برآمدهای ممکن آن کنش

(متوسط آماری)

اصل حداکثر اميد سودمندی

maximum expected utility (MEU)

عامل نظریه تصمیمی

DECISION THEORETIC AGENT (DT-AGENT)

یک عامل نظریه تصمیمی که کنش‌های رسیونال را انتخاب می‌کند.

function DT-AGENT(*percept*) **returns** an *action*

persistent: *belief_state*, probabilistic beliefs about the current state of the world
 action, the agent's action

 update *belief_state* based on *action* and *percept*

 calculate outcome probabilities for actions,

 given action descriptions and current *belief_state*

 select *action* with highest expected utility

 given probabilities of outcomes and utility information

return *action*

حالات باور عامل نظریه تصمیمی نه تنها امکان‌ها، بلکه احتمال‌های حالت‌های دنیا را بازنمایی می‌کند.
 probabilities possibilities

هوش مصنوعی

کمی‌سازی عدم اطمینان

۳

مبانی
نمادگذاری
احتمال

پایه‌های احتمال

PROBABILITY BASICS

مجموعه‌ی همه‌ی پرآمدهای ممکن
(مثلًاً ۶ برآمد ممکن در انداختن یک تاس)

 Ω

فضای نمونه
Sample Space

یکی از پرآمدها
(مثلًاً برآمد ۴ در انداختن یک تاس)

 $\omega \in \Omega$

رویداد اتمیک
Atomic Event

دنیای ممکن
Possible World

نقطه‌ی نمونه
Sample Point

یک فضای نمونه + انتساب احتمال به هر نقطه‌ی نمونه

 (Ω, P)

مدل احتمال
Probability Model

فضای احتمال
Probability Space

an assignment $P(\omega)$ for every $\omega \in \Omega$ s.t.

$$0 \leq P(\omega) \leq 1$$

$$\sum_{\omega} P(\omega) = 1$$

مثالاً : $P(1) = P(2) = P(3) = P(4) = P(5) = P(6) = 1/6$.

هر زیرمجموعه‌ای از فضای نمونه Ω

 A

پیشامد
Event

رویداد
Event

$$P(A) = \sum_{\{\omega \in A\}} P(\omega)$$

مثالاً : $P(\text{die roll} < 4) = P(1) + P(2) + P(3) = 1/6 + 1/6 + 1/6 = 1/2$

متغیرهای تصادفی

RANDOM VARIABLES

تابعی از فضای نمونه به یک برد
(مثلًاً اعداد حقیقی، یا بولی)

 X

متغیر تصادفی
Random Variable

مثلاً : $Odd(1) = true$.

هر متغیر تصادفی X یک تابع توزیع احتمال دارد.

توزیع احتمال
Probability Distribution

$$P(X = x_i) = \sum_{\{\omega: X(\omega) = x_i\}} P(\omega)$$

مثلاً : $P(Odd = true) = P(1) + P(3) + P(5) = 1/6 + 1/6 + 1/6 = 1/2$

گزاره‌ها به عنوان رویدادها

به هر گزاره‌ی منطقی به عنوان یک رویداد (مجموعه‌ای از نقاط نمونه) نگاه می‌کنیم که در آنها گزاره **true** است.

Given Boolean random variables A and B :

event a = set of sample points where $A(\omega) = \text{true}$

event $\neg a$ = set of sample points where $A(\omega) = \text{false}$

event $a \wedge b$ = points where $A(\omega) = \text{true}$ and $B(\omega) = \text{true}$

در کاربردهای هوش مصنوعی، نقاط نمونه به وسیله‌ی مقادیر مجموعه‌ای از متغیرهای تصادفی تعریف می‌شود؛ یعنی: فضای نمونه ضرب دکارتی پردهای متغیرهای است.

برای متغیرهای بولی، نقطه‌ی نمونه = مدل منطق گزاره‌ای

e.g., $A = \text{true}$, $B = \text{false}$, or $a \wedge \neg b$.

گزاره = فصل رویدادهای اتمیک که **true** هستند.

e.g., $(a \vee b) \equiv (\neg a \wedge b) \vee (a \wedge \neg b) \vee (a \wedge b)$

$$\Rightarrow P(a \vee b) = P(\neg a \wedge b) + P(a \wedge \neg b) + P(a \wedge b)$$

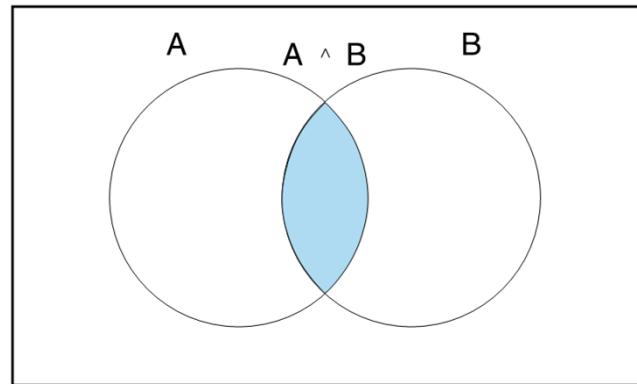
چرا از احتمال استفاده می‌کنیم؟

تعریف احتمال ایجاب می‌کند که رویدادهای خاص مرتبط به صورت منطقی، باید احتمال‌های مرتبط داشته باشند.

مثلًا:

$$P(a \vee b) = P(a) + P(b) - P(a \wedge b)$$

True



نحو برای گزاره‌ها

متغیر تصادفی بولی

Boolean Random Variable

متغیر تصادفی گزاره‌ای

Propositional Random Variable

e.g., *Cavity* (do I have a cavity?)

Cavity = true is a proposition, also written *cavity*

(finite)

(infinite)

متغیر تصادفی گستته

Discrete Random Variable

e.g., *Weather* is one of *sunny, rain, cloudy, snow*

Weather = rain is a proposition

مقادیر، باید جامع و دو به دو متمایز (مانعه الجموع) باشند.

(bounded)

بی‌کران (unbounded)

متغیر تصادفی پیوسته

Continuous Random Variable

e.g., *Temp = 21.6*; also allow, e.g., *Temp < 22.0*.

هر ترکیب بولی دلخواه از گزاره‌های پایه قابل استفاده است.

احتمال پیشین

PRIOR PROBABILITY

احتمال غیرشرطی

Unconditional Probability

احتمال پیشین

Prior Probability

e.g., $P(Cavity = \text{true}) = 0.1$ and $P(Weather = \text{sunny}) = 0.72$

احتمال پیشین هر گزاره، متناظر باور پیشین به آمدن هر شاهد (جدید) است.

توزيع احتمال توأم

JOINT PROBABILITY DISTRIBUTION

مقادیر احتمال را برای همهٔ انتساب‌های ممکن به متغیر تصادفی مشخص می‌کند.

$$\mathbf{P}(\text{Weather}) = \langle 0.72, 0.1, 0.08, 0.1 \rangle \text{ (normalized, i.e., sums to 1)}$$

توزيع احتمال

Probability Distribution

برای یک مجموعهٔ متغیر تصادفی، احتمال هر رویداد اتمنیک بر روی آن متغیرهای تصادفی را مشخص می‌کند.

توزيع احتمال توأم

Joint Probability Distribution

$$\mathbf{P}(\text{Weather}, \text{Cavity}) = \text{a } 4 \times 2 \text{ matrix of values:}$$

$\text{Weather} =$	$\begin{array}{cccc} \text{sunny} & \text{rain} & \text{cloudy} & \text{snow} \end{array}$
$\text{Cavity} = \text{true}$	0.144 0.02 0.016 0.02
$\text{Cavity} = \text{false}$	0.576 0.08 0.064 0.08

هر پرسشی در مورد یک دامنه، می‌تواند به کمک توزیع توأم آن پاسخ داده شود، زیرا هر رویداد، مجموعی از نقاط نمونه است.



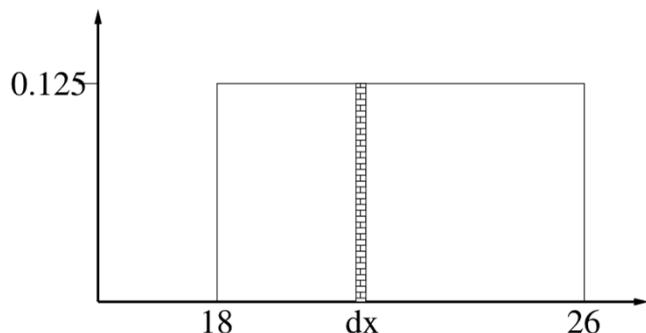
احتمال برای متغیرهای پیوسته

PROBABILITY FOR CONTINUOUS VARIABLES

برای متغیرهای پیوسته، توزیع احتمال به صورت یک تابع پارامتری از یک مقدار بیان می‌شود.

$$P(X = x) = U[18, 26](x) = 26$$

چگالی یکنواخت بین 18 و 26



در اینجا P ، یک تابع چگالی احتمال (density) است که انتگرال آن 1 می‌شود.

معنای

$$P(X = 20.5) = 0.125$$

در واقع عبارت است از:

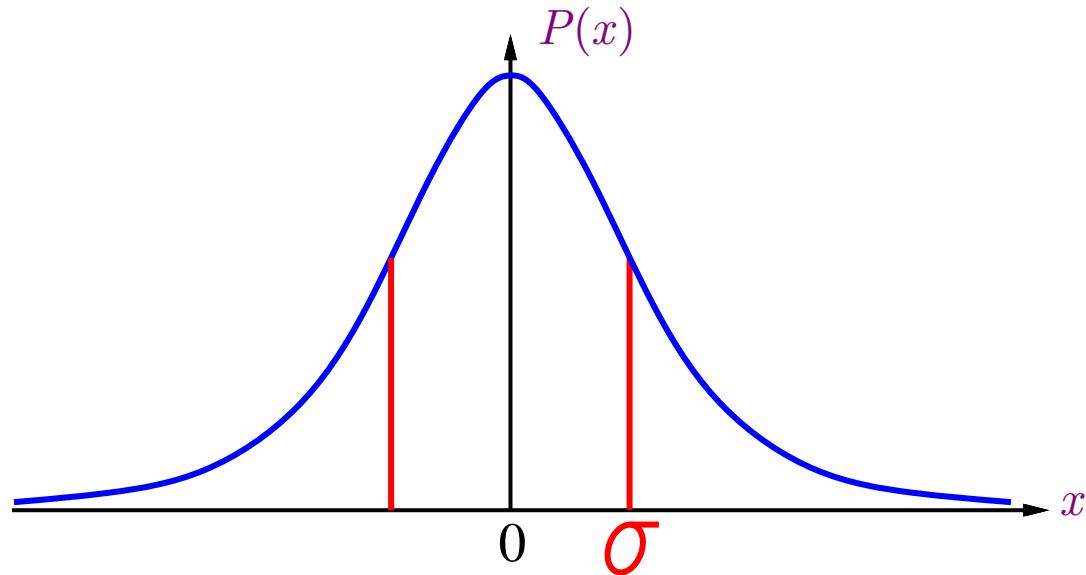
$$\lim_{dx \rightarrow 0} P(20.5 \leq X \leq 20.5 + dx) / dx = 0.125$$

احتمال برای متغیرهای پیوسته

مثال: تابع چگالی گاوی

GAUSSIAN DENSITY

$$P(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-(x-\mu)^2/2\sigma^2}$$



احتمال شرطی

CONDITIONAL PROBABILITY

احتمال شرطی

Conditional Probability

احتمال پسین

Posterior Probability

$$\text{e.g., } P(\text{cavity}|\text{toothache}) = 0.8$$

به معنی احتمال با فرض اینکه «*toothache* همه‌ی آن چیزی است که من می‌دانم»
نه اینکه «اگر *toothache* باشد، آن‌گاه *cavity* ۸۰٪ شанс وجود دارد»

نمادگذاری برای توزیع‌های شرطی:

$$\mathbf{P}(\text{Cavity}|\text{Toothache}) = \text{2-element vector of 2-element vectors}$$

اگر بیشتر بدانیم، مثلاً *cavity* هم داده شده باشد، در این صورت داریم:

$$P(\text{cavity}|\text{toothache}, \text{cavity}) = 1$$

تذکر: باوری که کمتر خاص است، پس از رسیدن شاهد بیشتر، معتبر باقی می‌ماند؛
اما این همیشه مفید نیست. 

شاهد جدید، ممکن است نامربوط باشد؛ در این صورت می‌توان ساده‌سازی کرد، مثلاً:

$$P(\text{cavity}|\text{toothache}, \text{49ersWin}) = P(\text{cavity}|\text{toothache}) = 0.8$$

احتمال شرطی

تعریف

CONDITIONAL PROBABILITY

$$P(a|b) = \frac{P(a \wedge b)}{P(b)} \text{ if } P(b) \neq 0$$

قاعده‌ی بیز
Bayes' Rule

$$P(a \wedge b) = P(a|b)P(b) = P(b|a)P(a)$$

فرمول‌بندی جایگزین برای قاعده‌ی بیز:

قاعده‌ی ضرب
Product Rule

نسخه‌ی عمومی برای کل توزیع، به صورت زیر است:

$$\mathbf{P}(Weather, Cavity) = \mathbf{P}(Weather|Cavity)\mathbf{P}(Cavity)$$

(View as a 4×2 set of equations, **not** matrix mult.)

استخراج با به‌کارگیری پیداپی قاعده‌ی ضرب:

$$\begin{aligned} \mathbf{P}(X_1, \dots, X_n) &= \mathbf{P}(X_1, \dots, X_{n-1}) \mathbf{P}(X_n|X_1, \dots, X_{n-1}) \\ &= \mathbf{P}(X_1, \dots, X_{n-2}) \mathbf{P}(X_{n-1}|X_1, \dots, X_{n-2}) \mathbf{P}(X_n|X_1, \dots, X_{n-1}) \\ &= \dots \\ &= \prod_{i=1}^n \mathbf{P}(X_i|X_1, \dots, X_{i-1}) \end{aligned}$$

قاعده‌ی زنجیره‌ای
Chain Rule

هوش مصنوعی

کمی‌سازی عدم اطمینان

۳

استنتاج
با استفاده
از
توزيع توأم
کامل

استنتاج با شمارش

مثال (۱ از ۵)

INFERENCE BY ENUMERATION

شروع با توزيع توأم:

	<i>toothache</i>	\neg <i>toothache</i>		
	<i>catch</i>	\neg <i>catch</i>	<i>catch</i>	\neg <i>catch</i>
<i>cavity</i>	.108	.012	.072	.008
\neg <i>cavity</i>	.016	.064	.144	.576

برای هر گزاره ϕ ، احتمال رویدادهای اتمیک که ϕ در آنها درست است را جمع کنید:

$$P(\phi) = \sum_{\omega: \omega \models \phi} P(\omega)$$

استنتاج با شمارش

(مثال ۲ از ۵)

INFERENCE BY ENUMERATION

شروع با توزیع توأم:

	<i>toothache</i>	\neg <i>toothache</i>		
	<i>catch</i>	\neg <i>catch</i>	<i>catch</i>	\neg <i>catch</i>
<i>cavity</i>	.108	.012	.072	.008
\neg <i>cavity</i>	.016	.064	.144	.576

برای هر گزاره ϕ ، احتمال رویدادهای اتمیک که ϕ در آنها درست است را جمع کنید:

$$P(\phi) = \sum_{\omega: \omega \models \phi} P(\omega)$$

$$P(\text{toothache}) = 0.108 + 0.012 + 0.016 + 0.064 = 0.2$$

استنتاج با شمارش

مثال (۳ از ۵)

INFERENCE BY ENUMERATION

شروع با توزیع توأم:

	<i>toothache</i>	\neg <i>toothache</i>		
	<i>catch</i>	\neg <i>catch</i>	<i>catch</i>	\neg <i>catch</i>
<i>cavity</i>	.108	.012	.072	.008
\neg <i>cavity</i>	.016	.064	.144	.576

برای هر گزاره ϕ ، احتمال رویدادهای اتمیک که ϕ در آنها درست است را جمع کنید:

$$P(\phi) = \sum_{\omega: \omega \models \phi} P(\omega)$$

$$P(cavity \vee toothache) = 0.108 + 0.012 + 0.072 + 0.008 + 0.016 + 0.064 = 0.28$$

استنتاج با شمارش

(۵ از ۴) مثال

INFERENCE BY ENUMERATION

شروع با توزيع توأم:

	<i>toothache</i>	\neg <i>toothache</i>		
	<i>catch</i>	\neg <i>catch</i>	<i>catch</i>	\neg <i>catch</i>
<i>cavity</i>	.108	.012	.072	.008
\neg <i>cavity</i>	.016	.064	.144	.576

می‌توانیم احتمال‌های شرطی را نیز محاسبه کنیم:

$$\begin{aligned}
 P(\neg cavity | toothache) &= \frac{P(\neg cavity \wedge toothache)}{P(toothache)} \\
 &= \frac{0.016 + 0.064}{0.108 + 0.012 + 0.016 + 0.064} = 0.4
 \end{aligned}$$

استنتاج با شمارش

(مثال ۵ از ۵)

INFERENCE BY ENUMERATION

شروع با توزیع توأم:

	<i>toothache</i>		\neg <i>toothache</i>	
	<i>catch</i>	\neg <i>catch</i>	<i>catch</i>	\neg <i>catch</i>
<i>cavity</i>	.108	.012	.072	.008
\neg <i>cavity</i>	.016	.064	.144	.576

خرج کسر می‌تواند به عنوان یک ثابت نرمال‌سازی α دیده شود:

$$\mathbf{P}(Cavity|toothache) = \alpha \mathbf{P}(Cavity, toothache)$$

$$\begin{aligned}
 &= \alpha [\mathbf{P}(Cavity, toothache, catch) + \mathbf{P}(Cavity, toothache, \neg catch)] \\
 &= \alpha [\langle 0.108, 0.016 \rangle + \langle 0.012, 0.064 \rangle] \\
 &= \alpha \langle 0.12, 0.08 \rangle = \langle 0.6, 0.4 \rangle
 \end{aligned}$$

ایدهی عمومی: توزیع را بر روی متغیر پرسش محاسبه کنید:
 با ثابت کردن متغیرهای شاهد و محاسبه‌ی مجموع روی متغیرهای پنهان

استنتاج با شمارش

قاعده‌ی کلی

INFERENCE BY ENUMERATION

متغیر پرس و جو

Query Variable

متغیر شاهد

Evidence Variable

متغیر پنهان

Hidden Variable

فرض کنیم **X** همه‌ی متغیرها باشد. معمولاً می‌خواهیم توزیع توأم پسین را برای متغیرهای پرسش **Y** به دست آوریم با داشتن مقادیر خاص **e** برای متغیرهای شاهد **E**

$$H = X - Y - E$$

متغیرهای پنهان می‌شود:

در این صورت:

مجموع یابی لازم برای درایه‌های توأم با **مجموعگیری** روی متغیرهای پنهان انجام می‌شود:

$$P(Y|E=e) = \alpha P(Y, E=e) = \alpha \sum_h P(Y, E=e, H=h)$$

جملات موجود در مجموع درایه‌های توأم هستند، زیرا **Y**, **E** و **H** با هم مجموعه‌ی کل متغیرهای تصادفی را پوشش می‌دهند.

استنتاج با شمارش

مشکلات

INFERENCE BY ENUMERATION

۱) پیچیدگی زمانی بدترین حالت $O(d^n)$

۲) پیچیدگی فضایی برای ذخیره‌سازی توزیع توأم $O(d^n)$

۳) چگونه باید اعداد را برای $O(d^n)$ درایه پیدا کرد؟؟؟

d = بزرگترین اندازه‌ی چندتایی‌ها

هوش مصنوعی

کمی‌سازی عدم اطمینان

۱۴

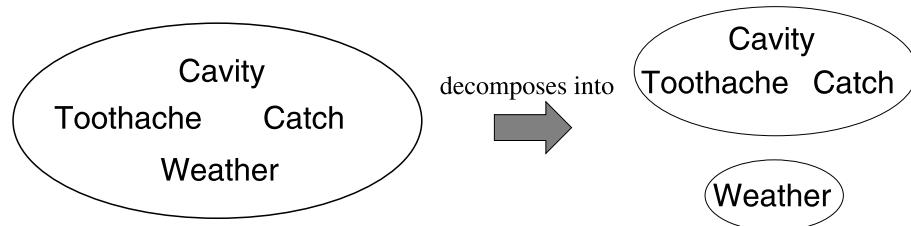
استقلال

استقلال

INDEPENDENCE

دو متغیر تصادفی A و B مستقل هستند، اگر و فقط اگر

$$\mathbf{P}(A|B) = \mathbf{P}(A) \quad \text{or} \quad \mathbf{P}(B|A) = \mathbf{P}(B) \quad \text{or} \quad \mathbf{P}(A, B) = \mathbf{P}(A)\mathbf{P}(B)$$



$$\begin{aligned}\mathbf{P}(\text{Toothache}, \text{Catch}, \text{Cavity}, \text{Weather}) \\ = \mathbf{P}(\text{Toothache}, \text{Catch}, \text{Cavity})\mathbf{P}(\text{Weather})\end{aligned}$$

32 entries reduced to 12; for n independent biased coins, $2^n \rightarrow n$

استقلال مطلق قدرتمند است، اما به ندرت پیش می‌آید

دندانپزشکی یک حوزه‌ی بزرگ با صدها متغیر است،
که هیچ یک از دیگری مستقل نیست ...

پس چه باید کرد؟ استفاده از مفهوم استقلال شرطی

استقلال شرطی

مثال

CONDITIONAL INDEPENDENCE

$P(Toothache, Cavity, Catch)$ has $2^3 - 1 = 7$ independent entries

اگر بیمار کرم خوردگی (*cavity*) داشته باشد، احتمال اینکه میله در آن گیر (*catch*) کند، به اینکه بیمار دندان درد (*toothache*) داشته باشد یا نه، بستگی ندارد:

$$(1) \quad P(catch|toothache, cavity) = P(catch|cavity)$$

شبیه همین استقلال برقرار است، اگر بیمار کرم خوردگی (*cavity*) نداشته باشد:

$$(2) \quad P(catch|toothache, \neg cavity) = P(catch|\neg cavity)$$

Catch is conditionally independent of *Toothache* given *Cavity*:

$$P(Catch|Toothache, Cavity) = P(Catch|Cavity)$$

استقلال شرطی یک متغیر از یک متغیر دیگر، با داشتن (به شرط) یک متغیر دیگر
جملات معادل:

$$P(Toothache|Catch, Cavity) = P(Toothache|Cavity)$$

$$P(Toothache, Catch|Cavity) = P(Toothache|Cavity)P(Catch|Cavity)$$

استقلال شرطی

مثال

CONDITIONAL INDEPENDENCE

نوشتن توزیع توأم کامل با استفاده از قاعده‌ی زنجیره‌ای:

$$\begin{aligned}
 & P(Toothache, Catch, Cavity) \\
 & = P(Toothache|Catch, Cavity)P(Catch, Cavity) \\
 & = P(Toothache|Catch, Cavity)P(Catch|Cavity)P(Cavity) \\
 & = P(Toothache|Cavity)P(Catch|Cavity)P(Cavity)
 \end{aligned}$$

I.e., $2 + 2 + 1 = 5$ independent numbers (equations 1 and 2 remove 2)

در بیشتر موارد، استفاده از استقلال شرطی، اندازه‌ی بازنمایی توزیع توأم n متغیر را از اندازه‌ی نمایی بر حسب n به اندازه‌ی خطی بر حسب n کاهش می‌دهد.

استقلال شرطی، پایه‌ای ترین و مقاوم‌ترین صورت از دانایی ما در مورد محیط‌های نامطمئن است.



هوش مصنوعی

کمی‌سازی عدم اطمینان

۵

قاعدگی
بیز
و
کاربرد آن

قاعده‌ی بیز

BAYES' RULE

$$\text{Product rule } P(a \wedge b) = P(a|b)P(b) = P(b|a)P(a)$$

$$\Rightarrow \text{Bayes' rule } P(a|b) = \frac{P(b|a)P(a)}{P(b)}$$

در فرم توزیع:

$$P(Y|X) = \frac{\mathbf{P}(X|Y)\mathbf{P}(Y)}{\mathbf{P}(X)} = \alpha \mathbf{P}(X|Y)\mathbf{P}(Y)$$

مفید برای سنجش احتمال تشخیصی از روی احتمال علی

$$P(Cause|Effect) = \frac{P(Effect|Cause)P(Cause)}{P(Effect)}$$

برای مثال: اگر M بیماری منژیت و S گردن درد باشد:

$$P(m|s) = \frac{P(s|m)P(m)}{P(s)} = \frac{0.8 \times 0.0001}{0.1} = 0.0008$$

قاعده‌ی بیز
Bayes' Rule

قاعده‌ی بیز و استقلال شرطی

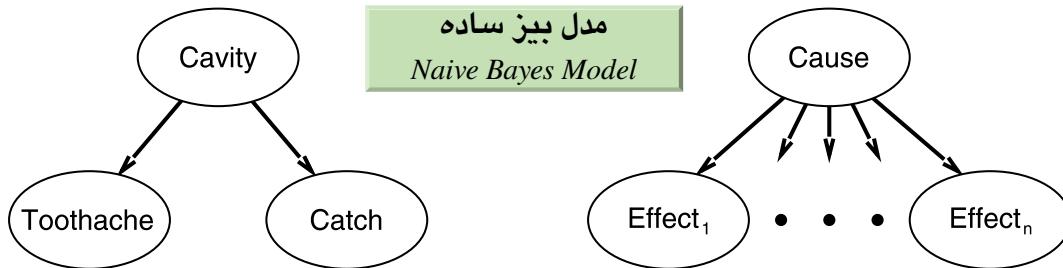
$$P(Cavity | toothache \wedge catch)$$

$$= \alpha P(toothache \wedge catch | Cavity) P(Cavity)$$

$$= \alpha P(toothache | Cavity) P(catch | Cavity) P(Cavity)$$

این مثالی است از مدل بیز ساده

$$P(Cause, Effect_1, \dots, Effect_n) = P(Cause) \prod_i P(Effect_i | Cause)$$



تعداد کل پارامترهای لازم، بر حسب تعداد متغیرها (n) **خطی** است.

هوش مصنوعی

کمی‌سازی عدم اطمینان

ع

بازبینی
دنیای اژدها

دنبای اژدها

WUMPUS WORLD

1,4	2,4	3,4	4,4
1,3	2,3	3,3	4,3
1,2 B OK	2,2	3,2	4,2
1,1 OK	2,1 B OK	3,1	4,1

$P_{ij} = \text{true}$ iff $[i, j]$ contains a pit

$B_{ij} = \text{true}$ iff $[i, j]$ is breezy

Include only $B_{1,1}, B_{1,2}, B_{2,1}$ in the probability model

دنيای اژدها

مشخص‌سازی مدل احتمال

WUMPUS WORLD
 $P_{ij} = \text{true}$ iff $[i, j]$ contains a pit

 $B_{ij} = \text{true}$ iff $[i, j]$ is breezy
Include only $B_{1,1}, B_{1,2}, B_{2,1}$ in the probability model

1,4	2,4	3,4	4,4
1,3	2,3	3,3	4,3
1,2 B OK	2,2	3,2	4,2
1,1 OK	2,1 B OK	3,1	4,1

The full joint distribution is $\mathbf{P}(P_{1,1}, \dots, P_{4,4}, B_{1,1}, B_{1,2}, B_{2,1})$ Apply product rule: $\mathbf{P}(B_{1,1}, B_{1,2}, B_{2,1} | P_{1,1}, \dots, P_{4,4})\mathbf{P}(P_{1,1}, \dots, P_{4,4})$ (Do it this way to get $P(\text{Effect}|\text{Cause})$.)

First term: 1 if pits are adjacent to breezes, 0 otherwise



Second term: pits are placed randomly, probability 0.2 per square:

$$\mathbf{P}(P_{1,1}, \dots, P_{4,4}) = \prod_{i,j=1,1}^{4,4} \mathbf{P}(P_{i,j}) = 0.2^n \times 0.8^{16-n}$$

for n pits.

دنبالهای ازدھا

مشاهدات و پرسش‌ها

WUMPUS WORLD

We know the following facts:

$$b = \neg b_{1,1} \wedge b_{1,2} \wedge b_{2,1}$$

$$\text{known} = \neg p_{1,1} \wedge \neg p_{1,2} \wedge \neg p_{2,1}$$

1,4	2,4	3,4	4,4
1,3	2,3	3,3	4,3
1,2 B OK	2,2	3,2	4,2
1,1 OK	2,1 B OK	3,1	4,1



Query is $\mathbf{P}(P_{1,3}|\text{known}, b)$

Define $\text{Unknown} = P_{ij}$ s other than $P_{1,3}$ and Known

For inference by enumeration, we have

$$\mathbf{P}(P_{1,3}|\text{known}, b) = \alpha \sum_{\text{unknown}} \mathbf{P}(P_{1,3}, \text{unknown}, \text{known}, b)$$



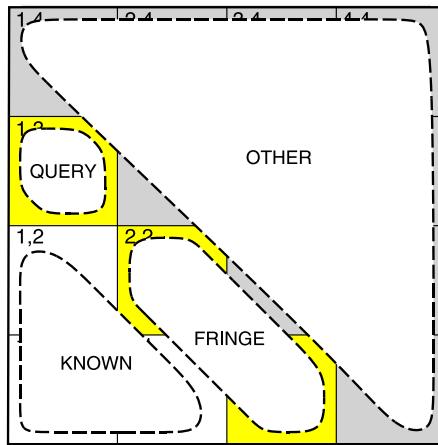
Grows exponentially with number of squares!

دنبالهای ازدھا

استفاده از استقلال شرطی

WUMPUS WORLD

دید پایه: مشاهدات از سایر خانه‌های پنهان مستقل شرطی هستند
با داشتن خانه‌های همسایه‌ی پنهان



Define $Unknown = Fringe \cup Other$

$$\mathbf{P}(b|P_{1,3}, Known, Unknown) = \mathbf{P}(b|P_{1,3}, Known, Fringe)$$

باید پرسش را به گونه‌ای دستکاری کنیم که بتوان از این فرمول استفاده کرد.

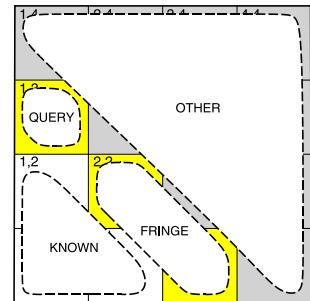
دنيای اژدها

استفاده از استقلال شرطی

WUMPUS WORLDDefine $Unknown = Fringe \cup Other$

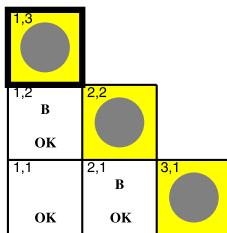
$$P(b|P_{1,3}, Known, Unknown) = P(b|P_{1,3}, Known, Fringe)$$

$$\begin{aligned}
 P(P_{1,3}|known, b) &= \alpha \sum_{unknown} P(P_{1,3}, unknown, known, b) \\
 &= \alpha \sum_{unknown} P(b|P_{1,3}, known, unknown) P(P_{1,3}, known, unknown) \\
 &= \alpha \sum_{fringe} \sum_{other} P(b|known, P_{1,3}, fringe, other) P(P_{1,3}, known, fringe, other) \\
 &= \alpha \sum_{fringe} \sum_{other} P(b|known, P_{1,3}, fringe) P(P_{1,3}, known, fringe, other) \\
 &= \alpha \sum_{fringe} P(b|known, P_{1,3}, fringe) \sum_{other} P(P_{1,3}, known, fringe, other) \\
 &= \alpha \sum_{fringe} P(b|known, P_{1,3}, fringe) \sum_{other} P(P_{1,3}) P(known) P(fringe) P(other) \\
 &= \alpha P(known) P(P_{1,3}) \sum_{fringe} P(b|known, P_{1,3}, fringe) P(fringe) \sum_{other} P(other) \\
 &= \alpha' P(P_{1,3}) \sum_{fringe} P(b|known, P_{1,3}, fringe) P(fringe)
 \end{aligned}$$

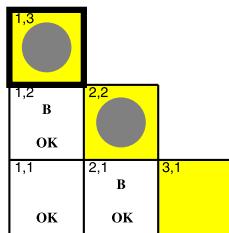


دنیای اژدها

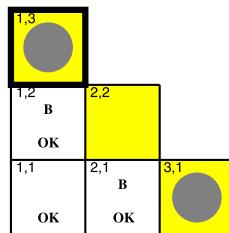
استفاده از استقلال شرطی

WUMPUS WORLD

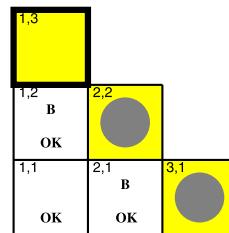
$$0.2 \times 0.2 = 0.04$$



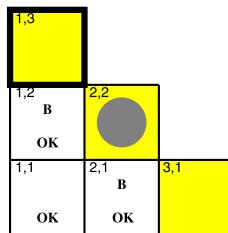
$$0.2 \times 0.8 = 0.16$$



$$0.8 \times 0.2 = 0.16$$



$$0.2 \times 0.2 = 0.04$$



$$0.2 \times 0.8 = 0.16$$

$$\begin{aligned} \mathbf{P}(P_{1,3}|known, b) &= \alpha' \langle 0.2(0.04 + 0.16 + 0.16), 0.8(0.04 + 0.16) \rangle \\ &\approx \langle 0.31, 0.69 \rangle \end{aligned}$$

$$\mathbf{P}(P_{2,2}|known, b) \approx \langle 0.86, 0.14 \rangle$$

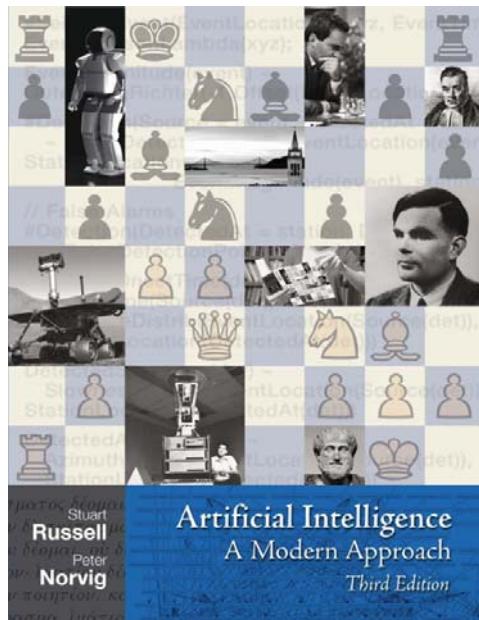
هوش مصنوعی

کمی‌سازی عدم اطمینان

۷

منابع،
مطالعه،
تکلیف

منبع اصلی



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

Chapter 13

13 QUANTIFYING UNCERTAINTY

In which we see how an agent can tame uncertainty with degrees of belief.

13.1 ACTING UNDER UNCERTAINTY

UNCERTAINTY

Agents may need to handle **uncertainty**, whether due to partial observability, nondeterminism, or a combination of the two. An agent may never know for certain what state it's in or where it will end up after a sequence of actions.

We have seen problem-solving agents (Chapter 4) and logical agents (Chapters 7 and 11) designed to handle uncertainty by keeping track of a **belief state**—a representation of the set of all possible world states that it might be in—and generating a contingency plan that handles every possible eventuality that its sensors may report during execution. Despite its many virtues, however, this approach has significant drawbacks when taken literally as a recipe for creating agent programs:

- When interpreting partial sensor information, a logical agent must consider *every logically possible* explanation for the observations, no matter how unlikely. This leads to impossible large and complex belief-state representations.
- A correct contingent plan that handles every eventuality can grow arbitrarily large and must consider arbitrarily unlikely contingencies.
- Sometimes there is no plan that is guaranteed to achieve the goal—yet the agent must act. It must have some way to compare the merits of plans that are not guaranteed.

Suppose, for example, that an automated taxi/automated has the goal of delivering a passenger to the airport on time. The agent forms a plan, A_{90} , that involves leaving home 90 minutes before the flight departs and driving at a reasonable speed. Even though the airport is only about 5 miles away, a logical taxi agent will not be able to conclude with certainty that “Plan A_{90} will get us to the airport in time.” Instead, it reaches the weaker conclusion “Plan A_{90} will get us to the airport in time, as long as the car doesn’t break down or run out of gas, and I don’t get into an accident, and there are no accidents on the bridge, and the plane doesn’t leave early, and no meteorite hits the car, and” None of these conditions can be