

## הסקה בתנאי אי ודאות



## ייצוג ידע לא ודאי

- ייצוג ידע בלוגיקה מסדר ראשון הינו בעיתי: בד"כ אין לסוכן גישה לכל הידע על הסביבה שלו.
- חלק מהידע של הסוכן על העולם הינו לא ודאי כתוצאה מחיישנים לא מושלמים.
- חלק אחר אינו ודאי מכיוון שלא ידועים לסוכן כל הפרמטרים המשפיעים על נכונותו.
- על כן עלינו לצייד את הסוכן האינטליגנטי ביכולת לייצג ידע לא ודאי ולהסיק באמצעותו מסקנות.

## דוגמא: דיאגנוסטיקה רפואית

- נניח שברצוננו לייצג מערכת לדיאגנוסטיקה רפואית באמצעות לוגיקה.
- מערכת זו תכיל חוקים כגון:  
$$\forall p \text{ Symptom}(p, \text{Toothache}) \Rightarrow \text{Disease}(p, \text{Cavity})$$
- חוק זה כמובן אינו נכון: יתכנו פציינטים עם כאב שיניים אבל ללא חור.
- נוכל להוסיף אפשרויות נוספות:  
$$\forall p \text{ Symptom}(p, \text{Toothache}) \Rightarrow \text{Disease}(p, \text{Cavity}) \vee \text{Disease}(p, \text{GumDisease}) \vee \dots$$
- אולם כדי להפוך פסוק זה לנכון עלינו לפרט בחוק את כל הסיבות האפשריות לכאב שיניים.
- ניתן להפוך את החוק:  
$$\forall p \text{ Disease}(p, \text{Cavity}) \Rightarrow \text{Symptom}(p, \text{Toothache})$$
- אולם גם חוק זה אינו נכון: יתכן חור ללא כאבים. יתכן שניהם מתקיימים אולם אינם קשורים.

## בעייתיות בשימוש בלוגיקה

- כתיבה **ממצה** של כל הסיבות האפשריות לכל הסימפטומים האפשריים מערבת עבודה רבה מידי.
- השימוש בחוקים סבוכים כל כך אינו יעיל.
- ברוב התחומים (כמו בתחום הדיאגנוסטיקה הרפואית) אין למומחה תיאוריה שלמה על התחום.
- קיימת אי-ודאות לגבי חלק מהעובדות הידועות לנו (לדוגמא: הפציינט אינו בטוח היכן בדיוק כואב לו, צילום השן אינו ברור וכו')



## שימוש בתורת ההסתברות

- המצב שתיארנו הינו מצב אופייני בו איננו מסוגלים לתאר את הידע שלנו בתחום באמצעות היסקים לוגיים.
- תחת זאת נעדיף לתאר את **מידת האמונה** של הסוכן בפסוקים על העולם.
- הכלי הידוע ביותר למטרה זו הינה תורת ההסתברות המצמידה לפסוקים מספר המבטא את הודאות של הסוכן לגבי נכונותם.
- תורת ההסתברות מאפשרת לנו **לסכם** בצורה חסכנית את אי הודאות הנובעת מהסיבות שתיארנו למעלה.
- לדוגמא, יתכן שאיננו בטוחים ממה נובע כאב השיניים של פצינט מסוים, אולם הננו מאמינים שבהסתברות 0.8 יש לפצינט חור אם יש לו כאב שיניים.
- 20% הנותרים מסכמים את כל הסיבות האחרות לכאב שיניים אותן איננו יודעים או שאנו עצלנים מידי לציין במפורש.

## הסתברות - תזכורת

- נעסוק כאן במשתנים אקראיים בדידים.
- לשם פשטות נצמצם את הדיון למשתנים בוליאניים בעלי שני הערכים True ו-False. הדיון ניתן להרחבה בקלות למשתנים אקראיים בעלי יותר ערכים.
- לשם קיצור נכתב את  $P(Cavity = True)$  בצורה  $P(Cavity)$ .
- $P(A)$  הינה ההסתברות הבלתי מותנית (unconditional או prior) ש-A אמיתי.
- $P(A|B)$  הינה ההסתברות המותנית של A ב-B. (conditional או posterior).
- חוק המכפלה:  $P(A|B) = P(A \wedge B) / P(B)$  לכל  $P(B) > 0$ .
- ההתפלגות של משתנה (ההסתברויות של כל ערכיו האפשריים תסומן ב-  $P(X) = \langle 0.7, 0.3 \rangle$ )

## הסתברות - תזכורת (המשך)

- ההתפלגות המשותפת של קבוצת משתנים (joint probability distribution) מצמידה הסתברות לכל איבר במכפלה הקרטזית של תחומי המשתנים.
- עבור  $n$  משתנים ההתפלגות המשותפת הינה טבלה בת  $2^n$  כניסות.
- לדוגמא:

	Toothache	Not Toothache
Cavity	0.04	0.06
Not Cavity	0.01	0.89

- ההתפלגות המשותפת של קבוצת המשתנים המתארים תחום מסוים יכולה לשמש לענות על כל שאילתא הסתברותית בתחום.
- לתחומים מעשיים המתוארים ע"י עשרות או מאות משתנים לא ניתן לבנות את טבלת ההתפלגות המשותפת.

## חוק בייס (Bayes' Rule)

$$P(B|A) = \frac{P(A|B)P(B)}{P(A)}$$

דוגמא:

-  $M$ : דלקת קרום המוח.

-  $S$ : צוואר נוקשה

$$P(S|M) = 0.5$$

$$P(M) = 1/50000$$

$$P(S) = 1/20$$

- נפעיל את חוק בייס ונקבל את ההסתברות שפצינט בעל צוואר נוקשה חולה בדלקת קרום המוח:

$$P(M|S) = \frac{P(S|M)P(M)}{P(S)} = \frac{0.5 \times 1/50000}{1/20} = 0.0002$$

## דוגמת האזעקה



- נניח שהתקנו אזעקה חדשה נגד גנבים.
- האזעקה מגיבה באמינות גבוהה לנוכחות גנבים.
- האזעקה מגיבה לעתים גם לרעידות אדמה קלות.
- ביקשנו משני שכנים, ג'ון ומרי להתקשר אלינו לעבודה במקרה שהם שומעים אזעקה.
- ג'ון תמיד מצלצל כשיש אזעקה אולם לעתים מצלצל בטעות כאשר הוא שומע את הטלפון מצלצל.
- מרי מקשיבה למוסיקה בעצמה רבה ולכן לעתים לא שומעת את האזעקה.
- בהינתן שג'ון צלצל ומרי לא, מה ההסתברות שאירעה פריצה?



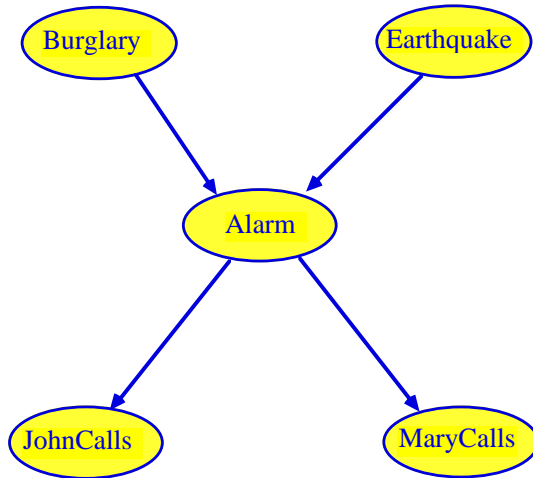
## רשתות בייס (Bayesian Networks)

- רשת בייס הינה דרך חסכנית לציין את ההתפלגות המשותפת של משתני התחום.
- הרשת הינה גרף מכוון.
- הצמתים ברשת הינם המשתנים האקראיים בתחום.
- קיימת קשת מכוונת בין הצומת המייצג את  $X$  לבין הצומת המייצג את  $Y$  אם ל- $X$  יש השפעה ישירה על  $Y$ .
- לכל צומת צמודה טבלה המתארת את ההסתברות המותנית של המשתנה בהוריו הישירים.



## טופולוגית הרשת

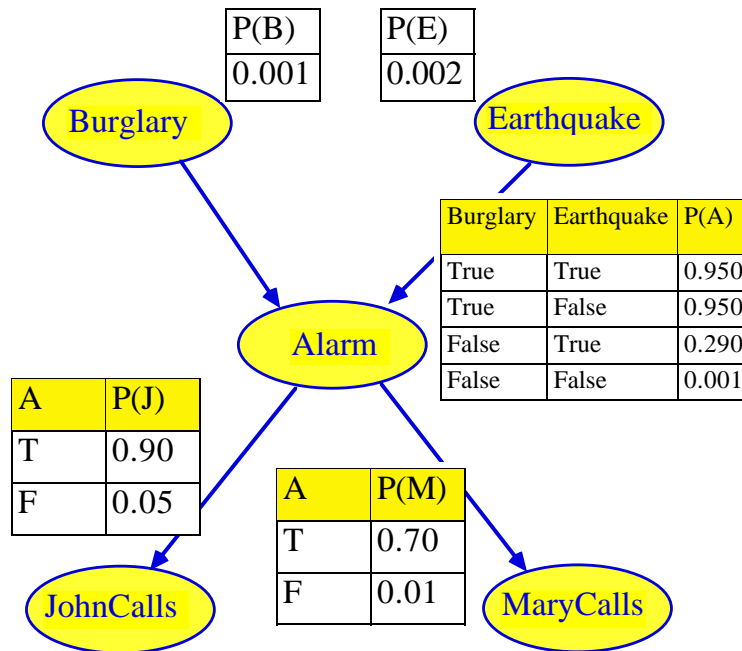
- טופולוגית הרשת משקפת את הידע שלנו על הסיבתיות בתחום.
- במקרה שלנו, לפריצה ורעידת אדמה השפעה סיבתית ישירה על הפעלת האזעקה.
- להפעלת האזעקה השפעה סיבתית ישירה על צלצול ע"י ג'ון ומרי.
- אנו מניחים שג'ון ומרי לא מרגישים ברעידות אדמה קלות ולא בפריצה ולכן אין קשר סיבתי ישיר בין המאורעות.



## טבלאות ההסתברות המותנה

- אנו מוסיפים את ההסתברויות לרשת באמצעות טבלאות ההסתברויות המותנות המוצמדות לצמתים.
- טבלה כזו מגדירה את ההתפלגות של ערכי המשתנה המיוצג ע"י הצומת כתלות בכל צירוף של ערכי הוריו
- ההסתברויות בכל שורה מסתכמות ל-1.0
- עבור משתנה בוליאני עם  $n$  הורים בוליאנים מכילה הטבלה  $2^n$  ערכים ( $2^n$  הערכים האחרים נגזרים מיידיית)

Burglary	Earthquake	$P(A B,E)=\text{True}$	$P(A B,E)=\text{False}$
True	True	0.950	0.050
True	False	0.950	0.050
False	True	0.290	0.710
False	False	0.001	0.999



## חישוב ההתפלגות המשותפת

- מכיוון שהסתברות של כל מאורע תלויה רק בהוריו הישירים ניתן לחשב את ההתפלגות המשותפת לפי הנוסחה (1):

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

- נחשב למשל את ההסתברות של המאורע הבא: "נשמעה אזעקה, ג'ון ומרי צלצלו, אולם לא היתה פריצה ולא היתה רעידת אדמה".

$$\begin{aligned}
 &P(J \wedge M \wedge A \wedge \neg B \wedge \neg E) \\
 &= P(J|A)P(M|A)P(A|\neg B \wedge \neg E)P(\neg B)P(\neg E)
 \end{aligned}$$

$$= 0.9 \times 0.7 \times 0.001 \times 0.999 \times 0.998 = 0.00062$$

- ההתפלגות המשותפת יכולה לשמש לענות על כל שאילתה בתחום.
- ניתן לכן לחשב אותה לפי הרשת ולענות על שאילתות. בהמשך נראה אלגוריתם יעיל יותר.

## הערות

- שימו לב שהרשת אינה כוללת מאורעות שונים שנראים רלוונטיים לבעיה כגון המאורע שמרי מקשיבה למוסיקה חזקה.
- מאורעות אלו מבוטאים ע"י אי הודאות שתוצמד לקשר בין הפעלת האזעקה וצלצול ע"י מרי.
- ההסתברויות **מסכמות** למעשה קבוצה גדולה מאוד (אולי אינסופית) של מאורעות אפשריים.
- לדוגמא, יתכן שהאזעקה לא תפעל בשל תקלה אלקטרונית.

- אם מתקיים  $Parent(X_i) \subseteq \{x_{i-1}, \dots, x_1\}$  אזי נוסחא 1 למעלה

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

שקולה לטענה:  $P(x_i | x_{i-1}, \dots, x_1) = P(x_i | Parents(X_i))$

- על כן בחירת ההורים נעשית כך שתתקיים תכונה זו.

## בניית רשתות

- ההתפלגות המשותפת ניתנת להכתב בצורה:

$$P(x_1, \dots, x_n) =$$

$$P(x_n | x_{n-1}, \dots, x_1) P(x_{n-1}, \dots, x_1)$$

- נמשיך את הפיתוח:

$$P(x_1, \dots, x_n) = P(x_n | x_{n-1}, \dots, x_1) P(x_{n-1} | x_{n-2}, \dots, x_1)$$

$$\dots P(x_2 | x_1) P(x_1)$$

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

- עלינו להחליט מי יהיו ההורים של הצומת MaryCalls  
 - ברור שהמאורע MaryCalls מושפע ע"י המאורעות Earthquake  
 ו-Burglary.

- אולם השפעה זו אינה ישירה. היא מגיעה דרך המאורע Alarm

- גם המאורע JohnCalls אינו משפיע על MaryCalls בהינתן Alarm

$$P(MaryCalls | JohnCalls, Alarm, Earthquake, Burglary)$$


- מסקנות אלו שקולות לנוסחא:

$$= P(MaryCalls | Alarm)$$

- על כן אנו מחליטים ש-  $Parents(maryCalls) = \{Alarm\}$

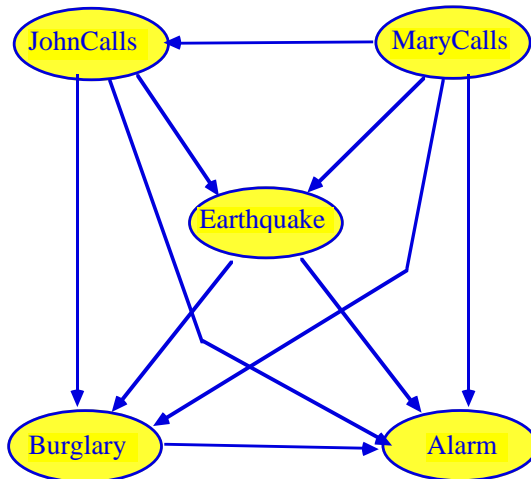
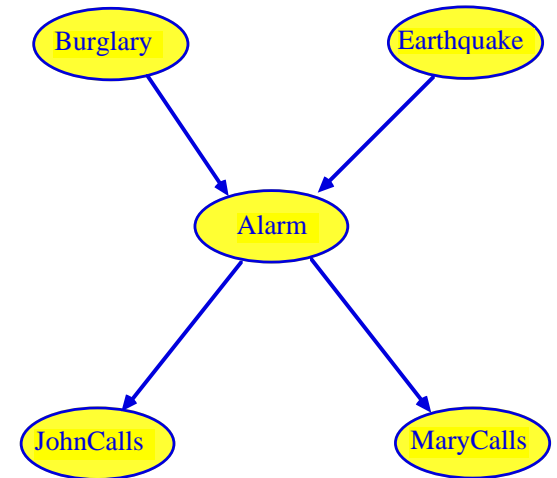
## דוגמא

- נניח שכבר בנינו את הרשת הבאה:



## פרוצדורה כללית לבנית רשת

- בחר קבוצת משתנים אקראיים המתארים את התחום.
- בחר סדר עליהם.
- לכל משתנה  $X_i$  (לפי הסדר):
  - הוסף צומת עבור  $X_i$  ברשת
  - בחר קבוצת  $Parent(X_i)$ : קבוצה מינימלית מהמשתנים שכבר הוכנסו המקיימת את השוויון למעלה.
  - הגדר את טבלת ההסתברות המותנה עבור  $X_i$
- מאחר ואנו מחברים צומת רק לצמתים קודמים לא יוצרו מעגלים.
- ניתן להוכיח שלא ניתן לבנות רשת שמפירה את אקסיומות תורת ההסתברות.




## בחירת סדר טוב

- ניתן לייצג תחומים אמיתיים רבים באמצעות רשת קומפקטית (יחסית להתפלגות המשותפת המלאה)
- אם בתחום בין  $N$  משתנים מושפע כל משתנה ישירות מלכל היותר  $K$  משתנים ו  $K \ll N$  אזי נזדקק למספר הסתברויות קטן בהרבה  $(2^K)$  עבור משתנים בוליאניים במקום  $(2^N)$
- חשוב לבנות את הרשת בסדר טוב: להתחיל בגורמים משפיעים לעבור לגורמים עליהם הם משפיעים וכו'. כלומר סדר התואם את הסיבתיות.
- בחירת סדר לא טוב תגרום לרשתות מסורבלות יותר ולטבלאות פחות אינטואיטיביות למילוי.
- לדוגמא, בחירת הסדר  $\langle MaryCalls, JohnCalls, Earthquake, Burglary, Alarm \rangle$  תביא לרשת הזורשת 31 הסתברויות - בדיוק כמו ההתפלגות המשותפת המלאה.

## סוגי הסקה ברשת בייס


- הסקה דיאגנוסטית [מתוצאות לסיבות].  $P(Burglary|JohnCalled)$



- הסקה סיבתית [מסיבות לתוצאות]  $P(JohnCalled|Burglary)$



- הסקה בין סיבות משותפות [סיבות לאותה תוצאה]  
 $P(Burglary|Alarm, Earthquake)$



## הסקה ברשתות בייס

- בדרך כלל הסוכן מקבל ערכים עבור קבוצת משתני **עדות** (evidence).
- ערכים אלו מגיעים ממקור חיצוני (למשל חישנים).
- מטרת הסוכן להסיק את התפלגות הפוסטריר של משתני השאילתא
- $P(Query|Evidence)$  (query variables) בהנתן הראיות:
- בדוגמת האזעקה סביר שמשתנה השאילתא יהיה *Burglary* ומשתני העדות יהיו *JohnCalls* ו-*MaryCalls*
- אולם הרשת מאפשרת גמישות מוחלטת בקביעת משתני השאילתא ומשתני העדות.


## הסקה הסתברותית

- הסקה בייסינית מאפשרת לנו לחמוק מטעויות הנפוצות אצל בני אדם.
- לדוגמא, מה ההסתברות של *Burglary* בהנתן *JohnCalls* ?
- מכיון שהפעלת האזעקה גורמת ב-90% מהמקרים לטלפון מג'ון ומכיון שב-95% מהמקרים בהם יש גניבה מופעלת האזעקה, אנו מתפתים להסיק ש  $P(Burglary|JohnCalls) \approx 0.9$
- אולם חישוב באמצעות הרשת מביאה לתוצאה מפתיעה:  
 $P(Burglary|JohnCalls) = 0.016$
- הסיבה: ההסתברות לפריצה היא נדירה - פעם ב-1000 ימים.
- ההסתברות שג'ון מצלצל כשאינן אזעקה הינה 0.05 (כלומר 50 פעם ב-1000 ימים).
- כלומר רוב צלצוליו של ג'ון הינם אזעקות שווא.
- בנוסף יתכן שהאזעקה לא מופעלת בזמן פריצה.

- הסקה מעורבת [של שני סוגים]  $P(Alarm|JohnCalled \wedge Burglary)$




## Polytree



## אלגוריתם הסקה ברשת בייס

- האלגוריתם הבסיסי מתאים רק ל-polytree: רשת בה יש לכל היותר מסלול אחד (לא מכוון) בין שני צמתים.
- האלגוריתמים לרשתות כלליות מושתתות על האלגוריתם להסקה ב-polytree.
- האלגוריתם עובד ע"י הסקה "אחורנית" ממשתנה השאילתא למשתני העדות (evidence).
- האלגוריתמים לגרף כללי מושתתים על האלגוריתם ל-polytree.



- אם קבוצת צמתים  $X$  מופרדת מקבוצת צמתים  $Y$  ע"י קבוצת צמתים  $E$  אזי  $X$  ו- $Y$  בלתי תלויים בהנתן  $E$ .

## d-separation

- קבוצת צמתים  $E$  מפרידה 2 קבוצות צמתים  $X$  ו- $Y$  אם כל מסלול לא מכוון ביניהם חסום בהנתן  $E$ .
- מסלול חסום בהנתן קבוצת צמתים  $E$  אם קיים בו צומת  $Z$  עבורו מתקיים אחד משלושת התנאים:
- $Z$  נמצא ב- $E$  ויש במסלול חץ אחד שנכנס אליו וחץ אחד שיוצא ממנו.
- $Z$  נמצא ב- $E$  ושני החצים מצביעים ממנו.
- $Z$  וצאצאיו אינם ב- $E$  ושני החצים מובילים לתוכו.

## נורמליזציה

- חוק בייס בצורתו המוכללת מחזיר טבלת התפלגות:

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

- אם למשל  $Domain(Y) = \{y_1, y_2\}$   $Domain(X) = \{x_1, x_2, x_3\}$  אזי

	$Y = y_1$	$Y = y_2$
$X = x_1$	0.7	0.3
$X = x_2$	0.1	0.9
$X = x_3$	0.5	0.5

$P(Y|X)$  תראה לדוגמא כך:

- שימו לב שבכל שורה  $X$  הינו קבוע.

- ניתן לכן לכתוב  $P(Y|X) = \alpha P(X|Y)P(Y)$  ולחשב את  $\alpha$  כך שיגרום

שהשורות יסתכמו ל-1. לתהליך כזה קוראים נורמליזציה

- פעמים רבות, כאשר רוצים להשוות את היחס בין שתי הסתברויות, אין

צורך לחשב את  $\alpha$ .

## סימונים

-  $X$  הינו משתנה השאילתא.

-  $Y = \{Y_1, \dots, Y_n\}$  הינם ההורים של  $X$

-  $U = \{U_1, \dots, U_n\}$  הינם הילדים של  $X$

-  $E$  היא קבוצה של משתני עדות (נתון לנו ערכו של כל אחד מהם).

-  $E_X^+$  הינם התמיכה הסיבתית: משתני העדות מעל  $X$  הקשורים להוריו.

-  $E_X^-$  הינם התמיכה התוצאתית: משתני העדות מתחת ל-  $X$  הקשורים לילדיו.

-  $E_{Y_i \setminus X}^+$  כל משתני העדות (ב- $E$ ) הקשורים ל-  $Y_i$  שלא דרך  $X$

## הפרדת השפעות ההורים והילדים

- אנו מעוניינים ב-  $P(X|E) = P(X|E_X^-, E_X^+)$

- קיימת הרחבה לחוק בייס המאפשרת משתני "רקע":

$$P(Y|X, B) = \frac{P(X|Y, B)P(Y|B)}{P(X|B)}$$

- נפעיל את החוק ונקבל:  $P(X|E_X^-, E_X^+) = \frac{P(E_X^-|X, E_X^+)P(X|E_X^+)}{P(E_X^-|E_X^+)}$

-  $X$  מפריד בין  $E_X^-$  ל- $E_X^+$  לכן  $P(E_X^-|X, E_X^+) = P(E_X^-|X)$

- נשתמש ב-  $1/P(E_X^-|E_X^+)$  כקבוע נרמול ונקבל:

$$P(X|E_X^-, E_X^+) = \alpha P(E_X^-|X)P(X|E_X^+)$$

## מבנה האלגוריתם

- מטרת האלגוריתם למצוא את  $P(X|E)$  כאשר  $X$  הינו משתנה השאילתא ו- $E$  הינם משתני העדות (evidence).

- כצעד ראשון מפרידים בין השפעה של  $E_X^+$  ו- $E_X^-$ .

- מחשבים את השפעה של  $E_X^+$  על כל אחד מההורים של  $X$  (רקורסיבית) ומעבירים את שקלול השפעה ל- $X$

- מחשבים את השפעה של  $E_X^-$  על כל אחד מהילדים של  $X$  (רקורסיבית) ומעבירים את שקלול השפעה ל- $X$

**function Evidence-Except(X,V,E)**

**input:** X, a Random variable.  
V and E, sets of random variables.

**output:**  $P(E_{X \setminus V}^- | X)$

[probability of downstream evidence (except evidence reachable via V) for each value of X]

$U \leftarrow \text{Children}[X] - V$

**if** Y is empty then return a vector of 1s

;No downstream evidence - true for all X

**else**

**for** each  $Y_i$  in Y do

**if**  $Y_i \notin E$  then

calculate  $P(E_{Y_i}^- | Y_i) = \text{Evidence-Except}(Y_i, \{\}, E)$

$Z_i \leftarrow \text{Parents}[Y_i] - X - E$

$Z'_i \leftarrow (\text{Parents}[Y_i] - X) \cap E$

**for** each  $Z_{ij}$  in  $Z_i$  do calculate

$P(Z_{ij} | E_{Z_{ij} \setminus Y_i}) = \text{Support-Except}(Z_{ij}, \{Y_i\}, E)$



**function Ploytree-Ask(X,E)**

**input:** X, A random variable  
E, A set of random variables with known values

**output:**  $P(X|E)$  A distribution over X given evidence E

**return** Support-Except(X,{},E)

**function Support-Except(X,V,E)**

**input:** X, a Random variable. V and E, sets of random variables.

**output:**  $P(X|E_{X \setminus V})$

[A distribution over X given evidence variables E except that reachable via V]

**if**  $X \in E$  then **return** observed point distribution for X.

**else** calculate  $P(E_{X \setminus V}^- | X) = \text{Evidence-Except}(X, V, E)$

$U \leftarrow \text{Parents}[X]$

**if** U is empty then **return** Normalize ( $P(E_{X \setminus V}^- | X)P(X)$ )

**else for** each  $U_i$  in U

calculate and store  $P(U_i | E_{U_i \setminus X}) = \text{Support-Except}(U_i, \{X\}, E)$

**return** Normalize ( $P(E_{X \setminus V}^- | X) \sum_u P(X|u) \prod_i P(U_i | E_{U_i \setminus X})$ )



## הסברים

**function Ploytree-Ask(X,E)**

- אם נניח שמשנתני העדות הינם *Burglary* ו-*MaryCalls* אזי הקלט יראה כך:  $Burglary = True, MaryCalls = False$  או בקיצור  $Burglary, \neg MaryCalls$

- הקלט יהיה ווקטור של ערכים שסכומו 1. אם למשל משתנה האילתא הינו  $P(Alarm = True) = 0.8,$

$Alarm$  אזי הפלט יראה כך:  $P(Alarm = False) = 0.2$

או בקיצור  $\langle 0.8, 0.2 \rangle$

**if**  $X \in E$  then **return** observed point distribution for X.

- זהו אחד מתנאי העצירה של הרקורסיה. אם הגענו למשתנה עדות אזי ידוע לנו ערכו. אין צורך להמשיך לטפס למעלה (או לרדת למטה) מכיון שהוא חוסם את הוריו (או ילדיו)

calculate  $P(E_{X \setminus V}^- | X) = \text{Evidence-Except}(X, V, E)$

- זוהי הקריאה לחישוב ההשפעה של הילדים. אמנם בקריאה הראשונה



**return**  $\prod_i$  **if**  $Y_i \in E$  then

$\sum_{Z_i} P(Y_i | X, Z_i, Z'_i) \prod_j P(Z_{ij} | E_{Z_{ij} \setminus Y_i})$

**else**

$\sum_{Y_i} P(E_{Y_i}^- | Y_i) \sum_{Z_i} P(Y_i | X, Z_i, Z'_i) \prod_j P(Z_{ij} | E_{Z_{ij} \setminus Y_i})$



if  $U$  is empty

then return **Normalize** ( $P(E_{X \setminus V}^- | X)P(X)$ )

- זהו תנאי שני לעצירת הרקורסיה. הגענו לשורש (שאינו משתנה עדות).

- מחשבים לפי הנוסחא אולם מכיון שאין הורים אזי  $P(X | E_X^+) = P(X)$

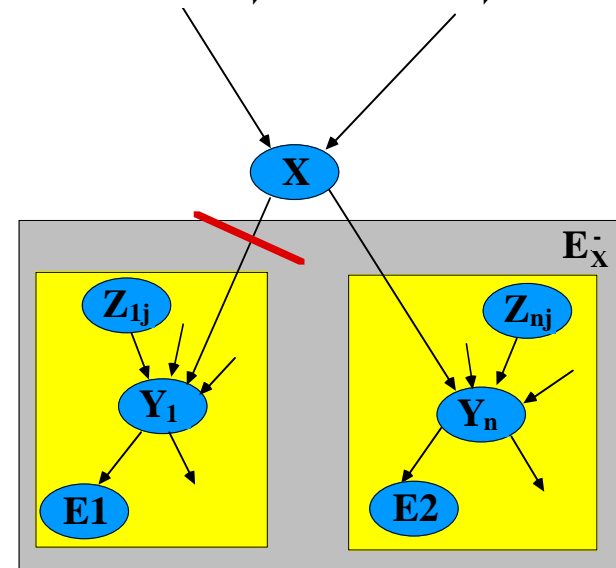
for each  $U_i$  in  $U$

calculate and store

$$P(U_i | E_{U_i \setminus X}) = \text{Support-Except}(U_i, \{X\}, E)$$

- זוהי הקריאה הרקורסיבית. מנתקים את הקשר ל- $X$  ומפעילים את הפרוצדורה על כל אחד מההורים.

יהיה ריק אולם בשאר הקריאות נרצה לחסום את ההשפעה של האחים:



- בחישוב הרקורסיבי של  $Y_1$  נרצה לבלום את ההשפעה של  $E_2$  דרך  $X$ .

### חישוב השפעת ההורים

- אנו מתחילים מ-  $P(X | E_X^+)$

- מכיוון ש  $X$  תלוי רק בהוריו (מהגדרת הרשת) אנו מסכמים את ההסתברויות בהתחשב בכל הצירופים האפשריים של ערכי הורי  $X$

$$P(X | E_X^+) = \sum_u P(X|u)P(u | E_X^+)$$

-  $E_X^+$  מפריד בין ההורים (זכרו את התנאי השלישי) לכן ההסתברויות שלהם בלתי תלויות וניתן לכתוב אותן בצורה:

$$P(X | E_X^+) = \sum_u P(X|u) \prod_i P(u_i | E_X^+)$$

- לבסוף ניתן להפריד את משתני העדות של כל הורה

$$E_X^+ = E_{U_1 \setminus X}^+ \cup \dots \cup E_{U_m \setminus X}^+$$

- קבוצת משתנים כזו מפרידה את ההורה משאר המשתנים:

$$P(X | E_X^+) = \sum_u P(X|u) \prod_i P(u_i | E_X^+)$$

$$\left( P(E_{X \setminus V}^- | X) \sum_u P(X|u) \prod_i P(U_i | E_{U_i \setminus X}) \right)$$

- הביטוי  $P(E_{X \setminus V}^- | X)$  חושב ע"י הקריאה לפרוצדורה המחשבת את ההשפעה מלמטה.

- הביטוי  $P(X|u)$  נלקח מטבלת ההסתברות המותנה של המשתנה  $X$ .

- הביטוי  $P(U_i | E_{U_i \setminus X})$  חושב ע"י הקריאות הרקורסיביות.

- באופן כללי הביטוי  $\sum_u P(X|u) \prod_i P(U_i | E_{U_i \setminus X})$  מסכם את ההסתברויות של  $X$  כתלות בכל צירוף אפשרי של הורי  $X$ .

- ההסתברות של הצירוף כתלות במשתני העדות חושב ע"י חישוב רקורסיבי לכל אחד מההורים והכפלת ההסתברויות שהתקבלו (עקב אי-תלות בין ההורים כפי שיוסבר בהמשך).