



النظم الخبيرة Expert Systems

- بعد دراسة استعمال المنطق لتمثيل المعرفة والمحاكاة، نتساءل فيما إذا كان بالإمكان استخدامه في مسائل العالم الحقيقي حولنا؟

- لقد وجد الباحثون في الذكاء الصناعي أن هناك تطبيقات تتطلب كمّاً هائلاً من المعرفة لحلها مثل التشخيص الطبي وحسابات الضرائب وغيرها، فنشأت برمجيات تسمى نظم المعرفة Knowledge Based Systems لتصف البرمجيات التي تستعمل كمّاً هائلاً من المعرفة في محاكاتها.

تعريف: يمكن تعريف النظم الخبيرة بأنها برمجيات تحاول إنتاج سلوك الخبراء البشر، لتحقيق بعض المهام الفكرية في مجالات خاصة. ويمكن ذكر النقاط المهمة الثلاثة التالية:

- تصمم النظم الخبيرة عموماً لحل مسائل التصنيف واتخاذ القرارات مثل (التشخيص الطبي، الوصفات العلاجية، تنظيم البورصات، وغيرها..)
- النظم الخبيرة هي أدوات ذكاء صناعي، وهذا يعني أننا لا نستعملها إلا في المسائل التي ليس لها أي خوارزمية واضحة أكيدة لحلها.
- تتطلب النظم الخبيرة وجود خبرة نودّ نمذجتها، أي أنه لا معنى للنظم الخبيرة إلا في المجالات التي توجد فيها خبرة بشرية. والخبير هو الشخص الذي يعرف مجال التطبيق، ويعرف نوعاً ما كيف ينقل معرفته للآخرين.

مكونات النظام الخبير:

- ١- قاعدة المعرفة Knowledge Base: تتكون من مجموعة من القواعد Rules، تنمذج المعرفة في المجال قيد الدراسة، وقاعدة حقائق Facts تتضمن معلومات تتعلق بالحالة قيد المعالجة، مثل عبارات توصيف الحالة.
- ٢- محرك استدلال Inference Engine: قادر على المحاكاة Reasoning بدءاً من معلومات مضمنة في قاعدة المعرفة، وعلى القيام باستنتاجات وغير ذلك، اعتماداً على تلك القواعد.

المعرفة غير المؤكدة:

- إن من أهم المسائل التي تواجه مصممي النظم الخبيرة هي أن الخبراء في بعض الحالات لديهم القدرة على المحاكاة حتى باستعمال معرفة غير مؤكدة، في حين لا نمتلك إلا القليل من الأدوات التي تمكننا من أخذ خبرة الخبير في هذه الحالات في الحساب - ذلك لأننا نعلم أن النظام الخبير يجب أن يفكر أو يتصرف مثلما يتصرف الإنسان الخبير عندما يواجه القضايا والمسائل.-

- على سبيل المثال، لا يمكن لطبيب أن يكون واثقاً كلياً من أن بعض الأعراض المرضية المعينة تدل على وجود مرض معين، وأن بعض الأدوية المعينة يمكن أن يتحملها المريض بسهولة وأن المريض سيشفى إذا تناولها. كذلك فإن مراقبة الطقس لا تسمح لنا بمعرفة أكيدة حول ما إذا كانت ستمطر بعد ساعة أم لا.

- لذلك يمكننا أن نستعمل نظريات الاحتمالات لتعريف درجة احتمال حدوث الفعل، فهناك العديد من الحالات التي تواجه الإنسان ككل (سواء خبير أم لا) لا يستطيع فيها تحديد معرفته بشكل تام 100%.

تعريف: مما سبق نستطيع تعريف **عدم التأكد Uncertainty** بأنه النقص في قواعد وحقائق معرفية مؤكدة (lack of exact knowledge) والتي تؤدي بنا إلى استنتاجات مؤكدة وموثوقة (reliable conclusions)، حيث أن المنطق الكلاسيكي ينص على وجود فقط حقائق أكيدة وتامة غير ناقصة، ولكن في المسائل الواقعية لا يمكن الحصول دوماً على هذه الحقائق الأكيدة والتامة، لذلك يجب تحديد مقدار التأكد من الحقائق والقواعد التي تحويها قاعدة المعرفة Knowledge Base.

مصادر عدم التأكد Uncertainty Sources:

١ - **الافتراضات الضعيفة Weak Implications:** نعلم أن النظم الخبيرة التي نقوم بنمذجتها تتكون من قاعدة المعارف (KB)، وقاعدة المعارف تتكون من حقائق (Facts) ومن قواعد (Rules)، وفي الحقيقة مجموعة القواعد Rules هي أفضل تعبير أو صيغة يمكن استخدامها من قبل النظم الخبيرة من أجل نمذجة كل من الأسباب (التي تسمى الحالات conditions) والنتائج (التي تحدث عند تحقق الحالات وتسمى الأفعال actions)، وبالتالي يمكن صياغة جميع القواعد على الشكل:

IF (condition) THEN (action)

والتي يمكن التعبير عنها رياضياً بالشكل:

Condition \Rightarrow action
implication

ومن أهم الصعوبات التي تواجه الخبراء والنظم الخبيرة هي عملية تحديد الترابط بين الـ conditions والـ actions، نقصد هنا بالترابط (correlation) مقدار يحدد لنا مدى تحقق هذا الافتضاء، ويمكن التعبير عن هذا الترابط بمقدار يسمى Certainty Factor (CF) ويمكن أن نقول أنها معاملات ثقة بالقواعد. وكمثال كلامي لنفهم ما المقصود بذلك:

بالعربي: إذا كان الجو غائماً فإن ذلك يعني أن تساقط المطر قريب

In English: IF (weather is cloudy) THEN (it will rain soon)

logic syntax: Cloudy_weather \Rightarrow rainy_weather

في هذا المثال نلاحظ أننا قد قلنا شيئاً صحيحاً، ولكنه غير دقيق، ذلك أن وجود الغيوم في السماء لا يعني دوماً هطول المطر، لذلك هذه العبارة تفتقر إلى الدقة ولا يمكن الثقة بها بشكل تام 100%، لذلك يتم التعبير عن مقدار الثقة بالقاعدة السابقة (الافتضاء السابق) بالـ Certainty Factor، وحينها يمكن الكتابة:

Cloudy_weather \Rightarrow rainy_weather ,cf=0.7

وهذا يعني أن معامل الثقة بهذه القاعدة هو 0.7 ويقابل النسبة المئوية 70% مثلاً.

٢ - اللغة غير الواضحة (الغامضة) Imprecise Language: يوجد بعض العبارات التي نستخدمها في

كلامنا البشري والتي تعطي معاني غير محددة وواضحة، مثل استخدام الكلمات often, sometimes... فكل هذه الكلمات لا تعطينا معنى محدد يمكن ترجمته إلى قواعد واقتضاءات موثوق بها، لذلك هي أيضاً مصدر من مصادر عدم التأكد.

٣ - البيانات غير المعروفة Unknown Data: في بعض الحالات يوجد معارف لم تعرف أو تحدد بعد، لذلك يمكن أن نقبل القيمة Unknown في العديد من المسائل التي تحلها النظم الخبيرة مما يؤدي إلى اقتضاءات ذات ثقة أقل، وهي مصدر لعدم التأكد.

٤ - الاختلاف في آراء الخبراء: في عملية تصميم النظم الخبيرة يتم الاستفادة عادةً من خبرة العديد من الخبراء (أكثر من طبيب، أكثر من مهندس..) من أجل الحصول على قاعدة معارف (KB) أكثر دقة وأقرب إلى الصحة، ولكن عند القيام بهذا الدمج بين المعلومات المحصلة من الخبراء نلاحظ وجود بعض الخبرات المتعاكسة والمتضادة بين الخبراء، وذلك نتيجة للاختلافات بين معارفهم وآرائهم ومعتقداتهم وربما نتائج التجارب التي قاموا بها، لذلك ينتج لدينا قواعد متعاكسة (conflicting rules) في قاعدة معارف النظام الخبير، مما يؤدي بمصمم هذا النظام الخبير إلى أن يقوم بإعطاء معاملات ثقة (CFs) لكل من واحد من القواعد ومن ثم يقوم بدمج هذه المعاملات وحساب المحصلة منها للحصول على قاعدة واحدة فقط غير مكررة في الـ KB بمعامل ثقة محصل.

:Reasoning In Expert Systems

٤ - سبق وأن تعرفنا عند دراستنا لكل من المنطقين (PL) و (FOL) إلى ما يسمى بعملية الـ Inference، وهي التي يتم استخدامها من أجل الحصول على هدف ما من خلال استخدام القواعد والحقائق التي نعلمها في الـ KB ويتم بعد ذلك استنتاج قواعد جديدة باستخدام طرق مختلفة تم شرحها مسبقاً.

- يطبق ذلك أيضاً في النظم الخبيرة، ذلك أن النظام الخبير لا يعلم كل شيء، ويجب أن يقوم بعمليات استنتاج مكررة لقواعد جديدة حتى يصل إلى هدفه المنشود، وهذه العملية في النظم الخبيرة تسمى Reasoning.

- تختلف عملية الـ Reasoning عن سابقتها الـ Inference بشيء مهم هنا هو أن القواعد والحقائق التي نتعامل معها هنا ليست صحيحة 100% وإنما يوجد فيها Uncertainty وهذا ما يؤدي فينا إلى استخدام الاحتمالات أو الـ CFs.

← يوجد منهجان أساسيان لعملية الـ Reasoning:

١ - Bayesian Reasoning: وفي هذا المنهج يتم افتراض أن جميع القواعد التي يملكها النظام في الـ KB الخاصة به تحمل الشكل التالي:

IF (Hypothesis) Then (Evidence), with a probability of x ; $x \in [0,1]$

وهذا يعني أنه عندما نفترض فرضية ما نستطيع الإقرار بأننا قد لاحظنا الشاهد Evidence باحتمال مقداره x. (أي إذا افترضنا أن المريض مصاب بالانفلونزا (الكريب) نستطيع القول أن درجة حرارته مرتفعة باحتمال 80% مثلاً)

٢- **Evidential Reasoning**: وفي هذا المنهج يتم افتراض أن جميع القواعد التي يملكها النظام في الـ KB الخاصة به تحمل الشكل التالي:

IF (Evidence) THEN (Hypothesis), with certainty factor of x ; $x \in [-1, 1]$

ونلاحظ هنا أن القواعد تحمل الشكل المعاكس للمنهج السابق لبايز، وهذا المنهج منطقي أكثر ذلك لأن العقل البشري يفكر بنفس الطريقة، فمن أجل المثال السابق للانفلونزا هنا تصبح القاعدة هي من الشكل (إذا لاحظنا أن درجة حرارة المريض مرتفعة فهذا يعني أنه مصاب بالانفلونزا ودرجة صحة ذلك هي 80%)..... بتصور لاحظتو الفرق ☺.

○ Bayesian Reasoning:

- يعتمد هذا المنهج على الاحتمالات، حيث سنقوم باستخدام قوانين الاحتمالات من أجل الحصول على الهدف وتحديد الفرضية الأقوى، كوننا قد افترضنا أصلاً أن جميع القواعد تحمل الشكل:

IF (Hypothesis) Then (Evidence), with a probability of x ; $x \in [0, 1]$

فيجب أن نوجد الفرضية H التي تحقق أكبر احتمال وعندها يمكن الإقرار بأنها أقرب ما يمكن إلى الصحة، لنفهم العملية سنحل المسائل القادمة على هذا المنهج، ولكن قبل ذلك سنقوم بالتذكير بأهم قوانين الاحتمالات التي تعرفنا عليها في السنة الماضية:

$$(1) p(\text{success}) = \frac{\text{the number of successes}}{\text{the number of possible outcomes}} = \frac{s}{s + f}$$

$$(2) p(\text{fail}) = \frac{\text{the number of fails}}{\text{the number of possible outcomes}} = \frac{f}{s + f}$$

$$(3) p(A|B) = \frac{p(A \cap B)}{p(B)} \quad (4) p(B|A) = \frac{p(A \cap B)}{p(A)}$$

$$(5) p(A \cap B) = p(A|B) \cdot p(B) = p(B|A) \cdot p(A)$$

$$(6) p(A|B) = \frac{p(B|A) \cdot p(A)}{p(B)} \text{ which called Bayes rule}$$

If the occurrence of event A depends on only two mutually exclusive (مستقلين خطياً) events, A and NOT A:

$$(7) p(B) = p(B|A) \cdot p(A) + p(B|\neg A) \cdot p(\neg A)$$

Substituting this equation into the Bayesian rule yields:

$$(8) p(A|B) = \frac{p(B|A) \cdot p(A)}{p(B|A) \cdot p(A) + p(B|\neg A) \cdot p(\neg A)}$$

But all of that was only for two events, and for multiple A and multiple B:

$$(9) p(A_i | B_1 B_2 \dots B_n) = \frac{p(B_1 B_2 \dots B_n | A_i) \cdot p(A_i)}{\sum_{k=1}^m p(B_1 B_2 \dots B_n | A_k) \cdot p(A_k)}$$

لنفرض أن الجدول التالي يحوي فرضيات (Hypothesis) وهي أمراض، وملاحظات (Evidences) وهي أعراض:

لنفرض أننا قد شاهدنا المشاهدة E_3 في البداية. ماذا يكون المرض؟
 إن الناظر إلى الجدول يمكن أن يقوم بقراءة السطر الخاص بالمشاهدة E_3 مباشرةً وأن يقر بأن المرض المقابل هو H_3 ذلك لأنه يحقق أكبر احتمال في السطر 0.9. ولكن هذا الكلام ليس دقيقاً، لأنه يجب الموازنة بين الاحتمال H_3 واحتمال $p(E_3|H_3)$ ، حيث نلاحظ أصلاً أن احتمال الإصابة بالمرض H_3 هو 0.25 فقط مما يجعلنا نشك في أمراض أخرى.

إذا للحصول على المرض الصحيح يجب القيام بعملية Inference وذلك باستخدام قانون بايز:

$$p(H_i|E_3) = \frac{p(E_3|H_i) \times p(H_i)}{\sum_{k=1}^3 p(E_3|H_k) \times p(H_k)}, \quad i = 1, 2, 3$$

ومن أجل الأمراض الثلاثة:

$$p(H_1|E_3) = \frac{0.6 \cdot 0.40}{0.6 \cdot 0.40 + 0.7 \cdot 0.35 + 0.9 \cdot 0.25} = 0.34$$

$$p(H_2|E_3) = \frac{0.7 \cdot 0.35}{0.6 \cdot 0.40 + 0.7 \cdot 0.35 + 0.9 \cdot 0.25} = 0.34$$

$$p(H_3|E_3) = \frac{0.9 \cdot 0.25}{0.6 \cdot 0.40 + 0.7 \cdot 0.35 + 0.9 \cdot 0.25} = 0.32$$

Probability	Hypothesis		
	i = 1	i = 2	i = 3
$p(H_i)$	0.40	0.35	0.25
$p(E_1 H_i)$	0.3	0.8	0.5
$p(E_2 H_i)$	0.9	0.0	0.7
$p(E_3 H_i)$	0.6	0.7	0.9

والآن اذا لاحظنا المشاهدة الأولى E_1 نقوم بالحساب أيضاً باستخدام قانون بايز من أجل المشاهدين الأولى والثالثة:

$$p(H_i|E_1E_3) = \frac{p(E_1|H_i) \times p(E_3|H_i) \times p(H_i)}{\sum_{k=1}^3 p(E_1|H_k) \times p(E_3|H_k) \times p(H_k)}, \quad i = 1, 2, 3$$

ومن أجل الأمراض الثلاثة:

$$p(H_1|E_1E_3) = \frac{0.3 \cdot 0.6 \cdot 0.40}{0.3 \cdot 0.6 \cdot 0.40 + 0.8 \cdot 0.7 \cdot 0.35 + 0.5 \cdot 0.9 \cdot 0.25} = 0.19$$

$$p(H_2|E_1E_3) = \frac{0.8 \cdot 0.7 \cdot 0.35}{0.3 \cdot 0.6 \cdot 0.40 + 0.8 \cdot 0.7 \cdot 0.35 + 0.5 \cdot 0.9 \cdot 0.25} = 0.52$$

$$p(H_3|E_1E_3) = \frac{0.5 \cdot 0.9 \cdot 0.25}{0.3 \cdot 0.6 \cdot 0.40 + 0.8 \cdot 0.7 \cdot 0.35 + 0.5 \cdot 0.9 \cdot 0.25} = 0.29$$

نلاحظ هنا أن احتمال إصابة المريض بالمرض الثاني قد زادت، ولكن ماذا يحدث ان لاحظنا وجود العَرَض (مفرد أعراض symptoms) الثاني E_2 :

$$p(H_i|E_1E_2E_3) = \frac{p(E_1|H_i) \times p(E_2|H_i) \times p(E_3|H_i) \times p(H_i)}{\sum_{k=1}^3 p(E_1|H_k) \times p(E_2|H_k) \times p(E_3|H_k) \times p(H_k)}, \quad i = 1, 2, 3$$

ومن أجل الأمراض الثلاثة:

$$p(H_1|E_1E_2E_3) = \frac{0.3 \cdot 0.9 \cdot 0.6 \cdot 0.40}{0.3 \cdot 0.9 \cdot 0.6 \cdot 0.40 + 0.8 \cdot 0.0 \cdot 0.7 \cdot 0.35 + 0.5 \cdot 0.7 \cdot 0.9 \cdot 0.25} = 0.45$$

$$p(H_2|E_1E_2E_3) = \frac{0.8 \cdot 0.0 \cdot 0.7 \cdot 0.35}{0.3 \cdot 0.9 \cdot 0.6 \cdot 0.40 + 0.8 \cdot 0.0 \cdot 0.7 \cdot 0.35 + 0.5 \cdot 0.7 \cdot 0.9 \cdot 0.25} = 0$$

$$p(H_3|E_1E_2E_3) = \frac{0.5 \cdot 0.7 \cdot 0.9 \cdot 0.25}{0.3 \cdot 0.9 \cdot 0.6 \cdot 0.40 + 0.8 \cdot 0.0 \cdot 0.7 \cdot 0.35 + 0.5 \cdot 0.7 \cdot 0.9 \cdot 0.25} = 0.55$$

وهنا نلاحظ أن إصابته بالمرض الثاني مستحيلة بعد أن لاحظنا وجود E_2 ، وإصابته بالمرض الثالث هي أكثرهم احتمالاً.

- في المسألة السابقة لاحظنا أننا قمنا باستخدام الاحتمالات وقوانينها من أجل تحديد الفرضية الأقوى والأقرب للصحة، ولكن في الحقيقة المنطق السابق بعيد جداً عن طريقة تفكير الإنسان الصحيحة، أي أنه يستخدم منطقاً معكوساً.

- يمكن أن يسأل أحدهم عن كيفية حساب كل من الاحتمالات $p(H_i)$ و $p(E_j|H_i)$ الموجودين في جدول معطيات المسألة، في الحقيقة يتم حسابها من خلال قواعد بيانات يتم تخزين الفرضيات والملاحظات فيها وتتم عملية إحصاء لعدد مرات حدوث الفرضيات كل على حدة والملاحظات المقابلة لكل فرضية، كما في الجدول table التالي:

E1	E2	E3	E4	E5	
1	1	0	0	0	H1
0	0	1	1	1	H1
0	1	1	0	0	H2
...

حيث قمنا بكتابة جميع الملاحظات وتخصيص عمود لكل مشاهدة منها، والأسطر تخص الفرضيات، ففي الجدول السابق كنا قد حصلنا على الفرضية H1 أول مرة وذلك عند وجود المشاهدين E1 و E2، وحصلنا عليها أيضاً عند وجود الملاحظات E3, E4, E5 ومن ثم حصلنا على الفرضية H2 وهكذا.. يتم تخزين جميع الحالات التي قمنا بوصفها فيما سبق في جداول خاصة للـ history مما يجعلنا نستطيع حساب الاحتمالات التي نحتاجها في مسائلنا.

○ Evidential Reasoning:

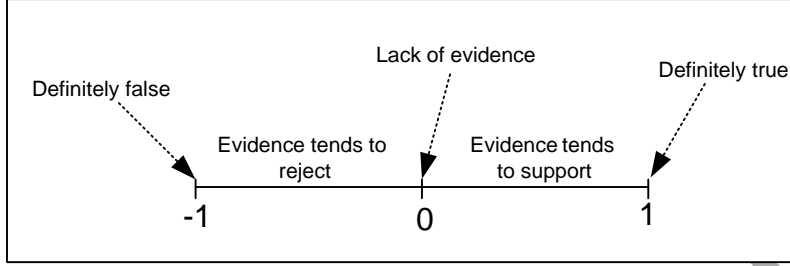
- ذكرنا أننا في هذا المنهج نفترض أن جميع القواعد تحمل الشكل:

IF (Evidence) THEN (Hypothesis), with certainty factor of x; $x \in [-1, 1]$

وهذا المنهج أقرب إلى تفكير الإنسان وطريقته في التعامل مع المسائل ومعطياتها، فبالنسبة للمثال التقليدي عن الأمراض دوماً عندما نشاهد أعراض معينة نشك بمرض معين وعندما نشاهد الأعراض الأخرى لنفس المرض تزيد نسبة إصابة الحالة بهذا المرض، وهكذا...

- وكما قد ذكرنا في فقرة "مصادر عدم التأكد" من هذه المحاضرة مثال المطر والغيوم من أجل شرح مفهوم الـ CF والذي يمثل معامل الثقة بقاعدة معينة rule.

- ويمكن لهذا المعامل أن يحمل القيم من -1 إلى 1، ويبين الشكل التالي مجموعة قيمه وما دلالة كل منها:



ويتضح من الشكل السابق دلالة كل قيمة من قيم cf.

- إن الـ Certainty Factor يحدد مقدار الثقة بتحقيق قاعدة معينة rule، ولكن لا يمنع أن يكون لكل حقيقة من الحقائق facts معامل ثقة أيضاً (كونها حالة خاصة من الـ rule)، وكذلك كل رمز أو متحول من متحولات المسألة له Certainty Factor كوننا استبدلنا مفهوم الاحتمال كله ووضعنا مكانه الـ CF.

قاعدة هامة:

R: IF x THEN y, with CF_R

$$CF_y = CF_x * CF_R$$

نتحدث فيه عن قواعد الشكل:

كل الكلام السابق ما زلنا rules بسيطة لها

$$x \Rightarrow y$$

يمكن تحديد قيمة CF_y فيها مباشرةً من قاعدة واحدة.

← في حال كون القواعد rules مركبة وليست بسيطة، أي مثل القواعد التالية:

$$P \Rightarrow Q \quad (cf=0.8)$$

$$R \Rightarrow Q \quad (cf=0.7)$$

$$CF_P=0.9$$

$$CF_R=0.8$$

ما قيمة CF_Q ؟

يوجد قاعدتان يمكن استنتاج قيمتين مختلفتين منهما للمعامل CF_Q لذلك يجب أن يوجد قوانين يمكن باستخدامها تحديد القيمة المحصلة، ومجموعة هذه القوانين هي:

$$cf(cf_1, cf_2) = \begin{cases} cf_1 + cf_2 * (1 - cf_1) & \text{if } cf_1 > 0 \text{ and } cf_2 > 0 \\ \frac{cf_1 + cf_2}{1 - (\min(|cf_1|, |cf_2|))} & \text{if one of them is negative} \\ cf_1 + cf_2 * (1 + cf_1) & \text{if } cf_1 < 0 \text{ and } cf_2 < 0 \end{cases}$$

وبالتالي يمكن حساب CF_Q بسهولة الآن:

$$P1=0.9*0.8=0.72 \text{ (from the first rule)}$$

$$P2=0.8*0.7=0.56 \text{ (from the second rule)}$$

وبما أن كل منهما موجب نستطيع استخدام القانون الأول من قوانين إيجاد CF المحصل:

$$CF_Q=P1+P2*(1-P1)=0.72+0.56*0.28=0.88$$

- في القواعد السابقة نلاحظ عدم وجود عمليات منطقية في كل من القواعد التي تعرضنا لها، ولكن ماذا إن نوجد لدينا في KB معينة هذه rule:

$$A \wedge B \Rightarrow C$$

وكان لدينا CF_A و CF_B ، فكيف سنحسب CF_C ؟

أيضاً يوجد قواعد خاصة من أجل حساب CF المحصل من العمليات المنطقية الأساسية، هذه القواعد هي:

$$cf(cf_1 \text{ and } cf_2) = \min(cf_1, cf_2)$$

$$cf(cf_1 \text{ or } cf_2) = \max(cf_1, cf_2)$$

$$cf(\text{not } cf_1) = -cf_1$$

مثال

بتطبيق جميع القواعد التي كتبناها سابقاً، أوجد CF_X :

$$\text{IF (A and B) or (C and not D) THEN X; } CF=0.6$$

مع العلم أن:

$$CF(A)=0.3 , CF(B)=0.5 , CF(C)=0.4 , CF(D)=-0.7$$

نوجد CF للطرف اليساري (لنسميه E) أولاً:

$$CF(E)=\max(\min(0.3,0.5),\min(0.4,0.7))=\max(0.3,0.4)=0.4$$

وباستخدام القاعدة الهامة في بداية الصفحة 8 من هذه المحاضرة ☺:

$$CF(X)=CF(E)*CF_{Rule}=0.4*0.6=0.24$$

مثال

- نريد حساب CF المحصل عندما تكون قيم CF_1 و CF_2 هي الحالات الثلاثة في الجدول التالي:

Condition	CF_1	CF_2
Both positive	0.4	0.4
One negative only	0.7	-0.4
Both negative	-0.4	-0.4

الحل:

$$CF(\text{Both positive}) = 0.4 + 0.4 * 0.6 = 0.64$$

$$CF(\text{One negative only}) = \frac{0.3}{1 - 0.4} = \frac{0.3}{0.6} = 0.5$$

$$CF(\text{Both negative}) = -0.4 - 0.4 * 0.6 = -0.64$$

- ولكن السؤال الآن هو: لماذا قمنا بدراسة كيفية حساب CF المحصل بهذا الشكل من التفصيل؟ في الحقيقة جميع هذه القواعد التي درسناها سوف نطبقها في عملية inference التي قمنا بتعلمها في الدروس السابقة، ففي المرات الماضية كنا نطبق طريقة الحل بالنقض مثلاً أو طريقة الحل المباشر للوصول إلى أحد أهدافنا المنشودة، وربما نستخدم Forward Chaining وقد نستخدم Backward Chaining. لكن في جميع المرات السابقة كنا نقول أن الهدف محقق عندما نصل إليه بالـ inference، وكانت نسبة تحققه 100%، ولكن كما ذكرنا في بداية هذه المحاضرة أن الواقع في كثير من المسائل لا يمكن التأكد من تحقق القواعد والرموز بشكل حتمي ويكون التأكد متفاوتاً من مسألة إلى مسألة، لذلك فهنا عندما نصل إلى أحد الأهداف التي نبحث عنها بالاستدلال inference يجب أن نصل أيضاً إلى معامل الثقة CF الخاص به.

مثال سلايد 58-59-60 من الدرس L8-Expert2:

لتكن لدينا الـ KB التالية:

a: $A \wedge B \wedge C \Rightarrow P$	$CF(a)=0.8$
b: $D \Rightarrow A$	$CF(b)=0.75$
c: $E \Rightarrow D$	$CF(c)=0.5$
d: $F \Rightarrow A$	$CF(d)=0.9$
e: $G \wedge H \wedge I \Rightarrow F$	$CF(e)=0.5$
f: $J \Rightarrow B$	$CF(f)=0.8$
g: $K \Rightarrow C$	$CF(g)=0.75$
h: $L \Rightarrow C$	$CF(h)=1$
i: $M \Rightarrow L$	$CF(i)=1$
j: $N \Rightarrow L$	$CF(j)=1$

إذا كنا نملك المعاملات (الاحتمالات) التالية:

$$P(E)=0.8$$

$$P(G)=0.22$$

$$P(H)=P(I)=P(J)=0.9$$

$$P(M)=P(N)=0.5$$

$$P(K)=1$$

الحل:


- لنقم برسم شجرة inference انطلاقاً من الهدف، وهي مرسومة في السلايد 60 ولكن قبل ذلك لنتفق على بعض الأمور في الرسم ☺:

١ - إذا كنا نستطيع الحصول على قيمة المتحول من قاعدة (rule) واحدة فقط مثل الهدف في المسألة السابقة حيث لا نستطيع حساب قيمته إلا من العبارة a، نقوم بتمثيله على الشكل التالي:




٢ - إذا كانت القاعدة تحوي العديد من المتحولات فيها فإنها تنفرع إلى عدد من الأفرع مساوٍ لعدد المتحولات فيها، مثل القاعدة a في المثال السابق فهي تحوي ثلاث متحولات A,B,C وبين كل اثنين منها عملية and، فيتم تمثيلها على الشكل التالي:

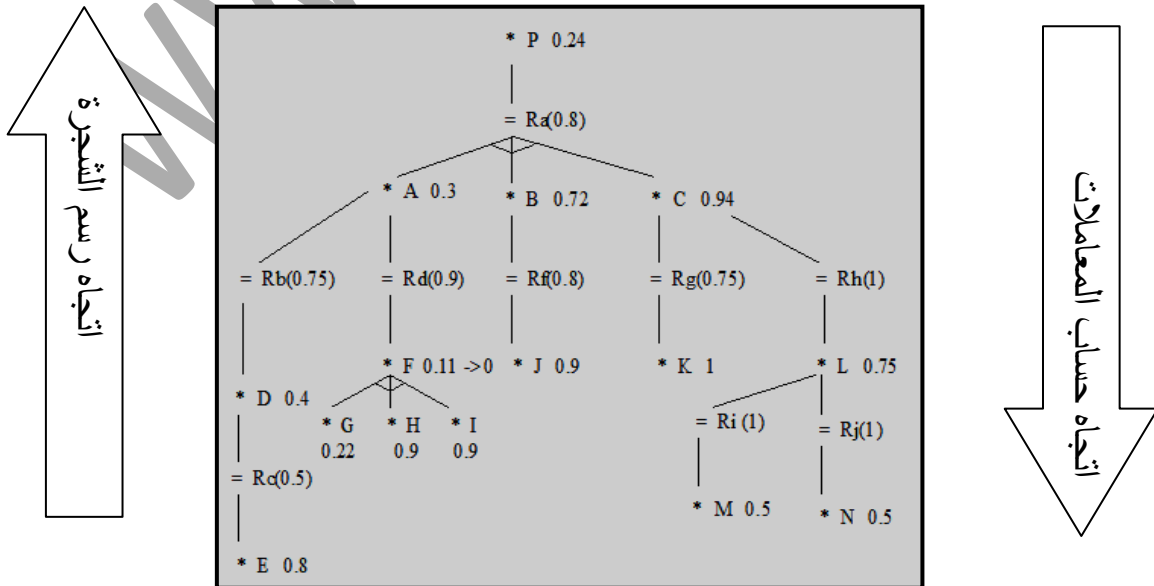
وجود الخط العرضي الصغير دليل وجود and بين أطراف العبارة.



٣ - إذا كان المتحول يمكن حساب قيمته من أكثر من قاعدة مثل المتحول A في المسألة السابقة الذي يمكن حسابه من العبارتين b,d وهذا يعني وجود عملية or بين العبارتين، ويتم تمثيل ذلك في الشجرة على الشكل:



- نعود إلى رسم شجرة المسألة:



- نلاحظ على الشكل أن السهمين على اليمين واليسار يدلاننا على كيفية رسم الشجرة وكيفية حساب المعاملات فيها وصولاً إلى $CF(P)$ والذي يمثل الهدف.

- لنقم الآن بحساب $CF(A)$ من الفرع اليساري للشجرة:
نلاحظ أن المتحول A يمكن الحصول على قيمته من العبارتين b و d ، إذاً لنحسب كلاً من احتمالات أطراف d و b :

• العبارة b : نحن بحاجة إلى $P(D)$ ، والمتحول D نحصل عليه فقط من العبارة c ، العبارة c طرفها اليساري هو المتحول E والذي نملك احتمالته، إذاً:

$$P(D)=P(E)*CF_c=0.8*0.5=0.4$$

- نحسب $P1(A)$ من العبارة b :

$$P1(A)=P(D)*CF_b=0.4*0.75=0.3$$

• العبارة d : نحن بحاجة إلى الاحتمال $P(F)$ ، وهذا لا نحصل عليه إلا من العبارة e ، العبارة e طرفها اليساري مكون من $G \wedge H \wedge I$ وهنا نحن بحاجة إلى $P(G)$ و $P(H)$ و $P(I)$ ، وكلها معطاة في المسألة، إذاً:

$$P(F)=CF_e*\min(P(G),P(H),P(I))=0.5*\min(0.22,0.9,0.9)=0.5*0.22=0.11$$

بعد الحصول على $P(F)$ أصبح بالإمكان الحصول على $P2(A)$ من العبارة d :

$$P2(A)=P(F)*CF_d=0.11*0.9=0.099$$

بعد الحصول على $P1(A)$ و $P2(A)$ يجب حساب المحصلة، والمحصلة هنا تحسب بأخذ \max من القيمتين ذلك لأن العلاقة بين العبارتين b و d هي or ، وبالتالي:

$$P(A)=\max(0.3,0.099)=0.3$$

- وبعد أن قمنا بحساب الاحتمال $P(A)$ ، نقوم بحساب $P(B)$ و $P(C)$ (سأترك عملية حساب الاحتمالين الآخرين إليكم مع العلم أن حساب $P(A)$ أصعب منهما لوجود جميع العلاقات and و or خلال الوصول إليه)، وبعد حسابهم جميعاً، نلاحظ أن العبارة a تحوي علاقة and بينهم، ومن ذلك يمكن أن نقوم بحساب $P(P)$ والذي يمثل الهدف بالعلاقة:

$$P(P)=CF_a*\min(P(A),P(B),P(C))=0.8*\min(0.3,0.72,0.94)=0.8*0.3=0.24$$

وهو الناتج الذي يظهر في أعلى الشجرة ☺.

ملاحظة: قمنا بالرمز إلى Ra في الشجرة بالرمز CF_a بالحسابات وكله يؤدي نفس المعنى...

انتهت المحاضرة