

Representación del Conocimiento

Sistemas Expertos

Dr. Alejandro Guerra-Hernández

Instituto de Investigaciones en Inteligencia Artificial
Universidad Veracruzana

*Campus Sur, Calle Paseo Lote II, Sección Segunda No 112,
Nuevo Xalapa, Xalapa, Ver., México 91097*

`mailto:aguerra@uv.mx`
`https://www.uv.mx/personal/aguerra/rc`

Maestría en Inteligencia Artificial 2023



Universidad Veracruzana

Definición

- ▶ Se trata del primer **producto** de éxito de la IA.
- ▶ Un SE [2] es un programa que se comporta como un **experto** humano en algún **dominio específico**, resolviendo problemas mediante el conocimiento.
- ▶ **Tareas** comunes:
 - ▶ Diagnóstico: Médico, fallo equipos, etc.
 - ▶ Interpretación de datos cuantitativos.
 - ▶ Toma de decisiones.



Casos de estudio I

MYCIN. Shortliffe et al. [9] presentan un sistema para consultas en **terapia anti-microbial**. Posteriormente especializado en infecciones de la sangre y meningitis [10]. El libro de Buchanan y Shortliffe [3] presenta el sistema basado en reglas tras MYCIN.

DENDRAL. Lindsay et al. [5] proponen un sistema para deducir la **estructura molecular** de un compuesto químico a partir de datos obtenidos con un espectometro de masas. Lindsay et al. [6] ofrecen una panorámica de las dos décadas de desarrollo del sistema.



Casos de estudio II

PROSPECTOR. Hart, Duda y Einaudi [4] proponen un sistema para la evaluación de sitios con posibles **reservas minerales**.

R1/XCON. Desarrollado por McDermott [7], es un sistema para la **configuración de computadoras VAX-11/780**, conforme a las ordenes de los clientes. El sistema fue renombrado como XCON y se uso en la compañía DEC [1].



Desiderata

- ▶ Usa **conocimiento** para llevar a cabo sus tareas en el dominio de aplicación.
- ▶ Por ello se les conoce también como **Sistemas Basados en el Conocimiento** (KBS).
- ▶ Capaz de **explicar** sus decisiones y su manera de razonar.
- ▶ Capaz de contender con la **incertidumbre** y la **falta de información** inherentes a esta tarea.
- ▶ La explicación es útil para garantizar la **confianza del usuario** en las recomendaciones del sistema; o para **detectar un fallo** flagrante en su razonamiento.



Incertidumbre e Incompletez

- ▶ Son **inherentes** a los SE. La información sobre el problema a resolver puede ser incompleta o no fiable.
- ▶ Las relaciones entre los objetos del dominio pueden ser **aproximadas**.
- ▶ **Ejemplo**. En el dominio médico, no estamos seguros si un síntoma se ha presentado en un paciente, o que la medida de un dato es absolutamente correcta: Ciertos fármacos **pueden** presentar reacciones adversas secundarias, pero éste no **suele** ser el caso. Este tipo de conocimiento requiere un manejo explícito de la incertidumbre.



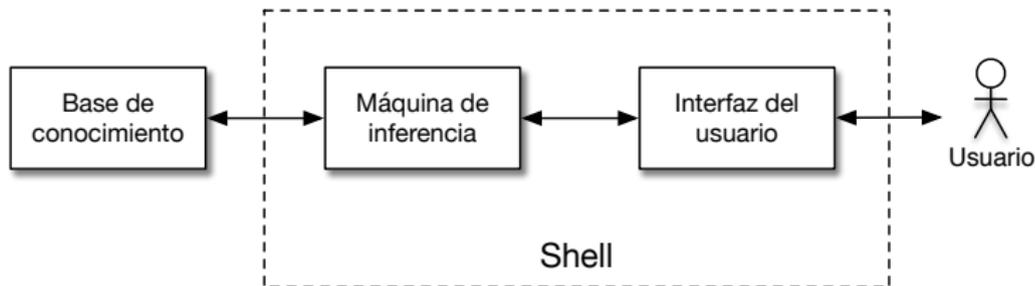
Funciones de un Sistema Experto

- Solución del problema.** Una función capaz de usar conocimiento sobre el dominio específico del sistema, incluyendo el manejo de incertidumbre.
- Interfaz del usuario.** Una función que permita la interacción entre el usuario y el sistema experto, incluyendo la capacidad de explicar las decisiones y el razonamiento del sistema.



Arquitectura de un Sistema Experto

- ▶ Es conveniente dividir el SE en tres **módulos**, como se muestra a continuación:



Módulos de un Sistema Experto I

- Base de conocimientos.** Todo el conocimiento específico sobre un dominio de aplicación: **Hechos**, **reglas** y/o **restricciones** que describen las relaciones en el dominio. Puede incluir también métodos, **heurísticas** e ideas para resolver los problemas en un dominio.
- Máquina de inferencia.** Todos los procedimientos para **usar** activamente la base de conocimientos.



Módulos de un Sistema Experto II

Interfaz del usuario. Toda la **comunicación** entre el usuario y el sistema experto, debe proveer la información suficiente para que el usuario entienda el funcionamiento de la máquina de inferencia a lo largo del proceso.



Shell de un Sistema Experto

- ▶ Conformado por la Máquina de inferencia y la interfaz del usuario.
- ▶ Es **independiente** del conocimiento del sistema.
- ▶ La separación provee **modularidad**.



Referencia complementaria

- ▶ Negrete-Martínez, González-Pérez y Guerra-Hernández [8] nos presentan un **texto** sobre los SE.
- ▶ La diferencia con este curso es que aquí implementaremos los SE en Prolog, mientras que el texto lo hace en **Lisp**.
- ▶ La segunda parte del libro da una **panorámica histórica** de los SE bastante completa.



Reglas de producción

- ▶ Se les conoce también como reglas **si-entonces**.
- ▶ Son por mucho el **formalismo** de representación de conocimiento más utilizado en los SE.
- ▶ Pueden tener interpretaciones diversas:
 - ▶ Si condición P entonces conclusión C .
 - ▶ Si situación S entonces acción A .
 - ▶ Si las condiciones C_1 y C_2 son el caso, entonces la condición C no lo es.



Características deseables

- Modularidad.** Cada regla define una pequeña, relativamente independiente, pieza de información.
- Agregación.** Es posible agregar nuevas reglas al sistema, de forma relativamente independiente al resto de sus reglas.
- Flexibilidad.** Como una consecuencia de la modularidad, las reglas del sistema pueden modificarse con relativa independencia de las otras reglas.
- Transparencia.** Facilitan la explicación de las decisiones tomadas por el sistema experto. Es posible automatizar la respuesta a preguntad del tipo ¿Cómo se llegó a esta conclusión? y ¿Porqué estás interesado en tal información?



Tipos de conocimiento

Categorico. Se refiere a las reglas de producción que definen relaciones puramente lógicas entre conceptos del dominio de un problema. Son siempre absolutamente **verdaderas**.

Soft o Probabilístico. Prevalece en dominios como el médico, donde las relaciones no son siempre verdaderas y se establecen con base en su regularidad empírica, usando **grados de certidumbre**. Las reglas de producción deben ajustarse para contender con enunciados del tipo: Si condición A entonces conclusión C con un grado de certeza F .



Ejemplo médico

- ▶ Aquí la regla se muestra en un pseudo-código más cercano a lo que haremos en Prolog:

Regla 037:

IF

paciente(hipertermia,si), paciente(tos,si), paciente(insufResp,si)

;

paciente(estertoresAlveolares,si), paciente(condensacionPulmonar,si)

THEN

paciente(neumonia,[si,80]).

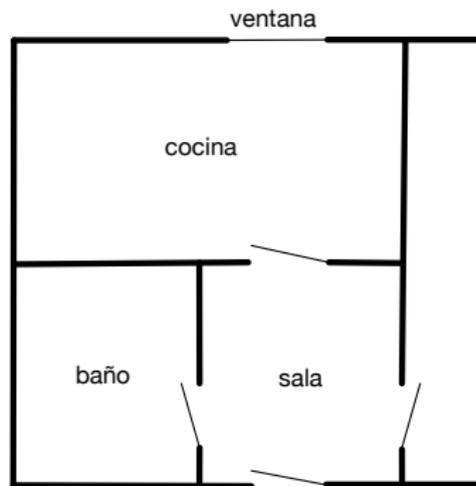


Expertos humanos y validación

- ▶ Por lo general, si se quiere desarrollar un SE, será necesario **consultar** a un experto humano en el dominio del problema y **estudiar** el dominio de aplicación uno mismo.
- ▶ Al proceso de extraer conocimiento de los expertos y la literatura de un dominio dado, para acomodarlo a un formalismo de representación se le conoce como **ingeniería del conocimiento** (*knowledge elicitation*).



Dominio para nuestros ejemplos ¹



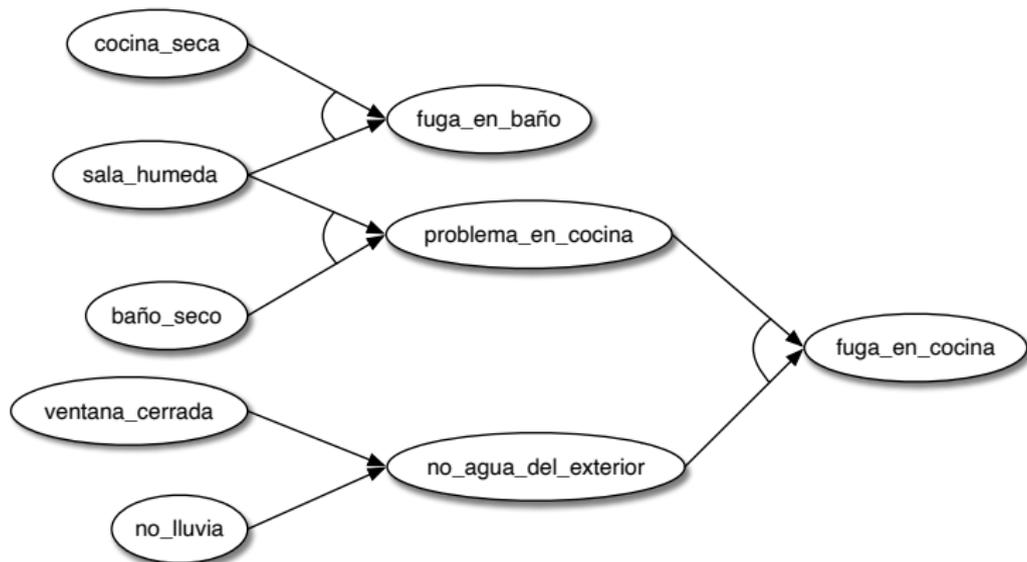
¹Adaptado de Bratko [2].

Fugas de agua

- ▶ Luego de consultar con nuestro **plomero** favorito y consultar en internet los manuales de **plomería para dummies**, llegamos a la **conclusión** de que:
 - ▶ La fuga puede presentarse en el baño o en la cocina.
 - ▶ En cualquier caso, la fuga causa que haya agua en el piso de la sala.
 - ▶ Si la sala está húmeda y el baño seco, entonces el problema está en la cocina.
 - ▶ Asumimos que la fuga solo se da en un sitio, no en ambos al mismo tiempo.
 - ▶ etc.
- ▶ ¿Cómo **representamos** este conocimiento?



Red de inferencias (Gráfico AND/OR)



Reglas

- ▶ Que se pueden representar como **reglas de producción**:
IF baño_seco AND sala_humeda THEN problema_en_cocina.



Tipos de razonamiento

- ▶ Hay dos **formas** básicas de razonamiento con reglas de producción:
 - Hacia atrás.** De la meta hacia los datos.
 - Hacia adelante.** De los datos hacia la meta.



Razonamiento hacia atrás

- ▶ Partimos de una **hipótesis**: Que hay una fuga en la cocina; y razonamos hacia atrás sobre la red de inferencias. Para resolver esta hipótesis necesitamos que `no_agua_en_el_exterior` y `problema_en_la_cocina` sean verdaderas.
- ▶ La primera es el caso si no llueve o la ventana está cerrada, etc.
- ▶ El razonamiento se conoce como **hacia atrás**, porque forma una cadena de las hipótesis (problema en la cocina) hacia las **evidencias** (ventana cerrada).



Implementación en Prolog

▶ ¡Por default!



Reglas à la Prolog I

```
1  % Base de conocimientos para fuga en casa
2
3  % Conocimiento previo
4
5  fuga_en_bano :-
6      sala_seca,
7      cocina_seca.
8
9  problema_en_cocina :-
10     sala_humeda,
11     bano_seco.
12
13 no_agua_del_exterior :-
14     ventana_cerrada
15     ;
16     no_lluvia.
17
18 fuga_en_cocina :-
19     problema_en_cocina,
20     no_agua_del_exterior.
21
```



Reglas à la Prolog II

```
22 % Evidencia
23
24 sala_humeda.
25 bano_seco.
26 ventana_cerrada.

1 ?- fuga_en_cocina. true
```



Desventajas de usar Prolog directamente

1. La **sintaxis** de estas reglas no es la más adecuada para alguien que no conoce Prolog. Este es el caso de nuestros expertos humanos, que deben especificar nuevas reglas, leer las existentes y posiblemente modificarlas, sin saber Prolog.
2. La base de conocimientos es sintácticamente **indistinguible** del resto del sistema experto. Esto, como se mencionó, no es deseable.



Intérprete de encadenamiento hacia atrás I

```

3 :- op( 800, fx, if).
4 :- op( 700, xfx, then).
5 :- op( 300, xfy, or).
6 :- op( 200, xfy, and).
7
8 is_true( P) :-
9     fact( P).
10
11 is_true( P) :-
12     if Cond then P,           % Una regla relevante,
13     is_true( Cond).         % cuya condición Cond es verdadera.
14
15 is_true( P1 and P2) :-
16     is_true( P1),
17     is_true( P2).
18
19 is_true( P1 or P2) :-
20     is_true( P1)
21     ;
22     is_true( P2).

```



Nuevas reglas I

```

3  %%% Conocimiento previo
4
5  if sala_humeda and cocina_seca
6  then fuga_en_bano.
7
8  if sala_humeda and bano_seco
9  then problema_en_cocina.
10
11 if ventana_cerrada or no_lluvia
12 then no_agua_del_exterior.
13
14 if problema_en_cocina and no_agua_del_exterior
15 then fuga_en_cocina.
16
17 %%% Evidencias
18
19 fact(sala_humeda).      % Cambiar a sala_seca para que falle la meta
20 fact(bano_seco).
21 fact(ventana_cerrada). % Comentar para probar explicaciones por que
22
23
24
25
26
27
28
29
30
31
32
33
34
35
36
37
38
39
40
41
42
43
44
45
46
47
48
49
50
51
52
53
54
55
56
57
58
59
60
61
62
63
64
65
66
67
68
69
70
71
72
73
74
75
76
77
78
79
80
81
82
83
84
85
86
87
88
89
90
91
92
93
94
95
96
97
98
99
100
101
102
103
104
105
106
107
108
109
110
111
112
113
114
115
116
117
118
119
120
121
122
123
124
125
126
127
128
129
130
131
132
133
134
135
136
137
138
139
140
141
142
143
144
145
146
147
148
149
150
151
152
153
154
155
156
157
158
159
160
161
162
163
164
165
166
167
168
169
170
171
172
173
174
175
176
177
178
179
180
181
182
183
184
185
186
187
188
189
190
191
192
193
194
195
196
197
198
199
200
201
202
203
204
205
206
207
208
209
210
211
212
213
214
215
216
217
218
219
220
221
222
223
224
225
226
227
228
229
230
231
232
233
234
235
236
237
238
239
240
241
242
243
244
245
246
247
248
249
250
251
252
253
254
255
256
257
258
259
260
261
262
263
264
265
266
267
268
269
270
271
272
273
274
275
276
277
278
279
280
281
282
283
284
285
286
287
288
289
290
291
292
293
294
295
296
297
298
299
300
301
302
303
304
305
306
307
308
309
310
311
312
313
314
315
316
317
318
319
320
321
322
323
324
325
326
327
328
329
330
331
332
333
334
335
336
337
338
339
340
341
342
343
344
345
346
347
348
349
350
351
352
353
354
355
356
357
358
359
360
361
362
363
364
365
366
367
368
369
370
371
372
373
374
375
376
377
378
379
380
381
382
383
384
385
386
387
388
389
390
391
392
393
394
395
396
397
398
399
400
401
402
403
404
405
406
407
408
409
410
411
412
413
414
415
416
417
418
419
420
421
422
423
424
425
426
427
428
429
430
431
432
433
434
435
436
437
438
439
440
441
442
443
444
445
446
447
448
449
450
451
452
453
454
455
456
457
458
459
460
461
462
463
464
465
466
467
468
469
470
471
472
473
474
475
476
477
478
479
480
481
482
483
484
485
486
487
488
489
490
491
492
493
494
495
496
497
498
499
500
501
502
503
504
505
506
507
508
509
510
511
512
513
514
515
516
517
518
519
520
521
522
523
524
525
526
527
528
529
530
531
532
533
534
535
536
537
538
539
540
541
542
543
544
545
546
547
548
549
550
551
552
553
554
555
556
557
558
559
560
561
562
563
564
565
566
567
568
569
570
571
572
573
574
575
576
577
578
579
580
581
582
583
584
585
586
587
588
589
590
591
592
593
594
595
596
597
598
599
600
601
602
603
604
605
606
607
608
609
610
611
612
613
614
615
616
617
618
619
620
621
622
623
624
625
626
627
628
629
630
631
632
633
634
635
636
637
638
639
640
641
642
643
644
645
646
647
648
649
650
651
652
653
654
655
656
657
658
659
660
661
662
663
664
665
666
667
668
669
670
671
672
673
674
675
676
677
678
679
680
681
682
683
684
685
686
687
688
689
690
691
692
693
694
695
696
697
698
699
700
701
702
703
704
705
706
707
708
709
710
711
712
713
714
715
716
717
718
719
720
721
722
723
724
725
726
727
728
729
730
731
732
733
734
735
736
737
738
739
740
741
742
743
744
745
746
747
748
749
750
751
752
753
754
755
756
757
758
759
760
761
762
763
764
765
766
767
768
769
770
771
772
773
774
775
776
777
778
779
780
781
782
783
784
785
786
787
788
789
790
791
792
793
794
795
796
797
798
799
800
801
802
803
804
805
806
807
808
809
810
811
812
813
814
815
816
817
818
819
820
821
822
823
824
825
826
827
828
829
830
831
832
833
834
835
836
837
838
839
840
841
842
843
844
845
846
847
848
849
850
851
852
853
854
855
856
857
858
859
860
861
862
863
864
865
866
867
868
869
870
871
872
873
874
875
876
877
878
879
880
881
882
883
884
885
886
887
888
889
890
891
892
893
894
895
896
897
898
899
900
901
902
903
904
905
906
907
908
909
910
911
912
913
914
915
916
917
918
919
920
921
922
923
924
925
926
927
928
929
930
931
932
933
934
935
936
937
938
939
940
941
942
943
944
945
946
947
948
949
950
951
952
953
954
955
956
957
958
959
960
961
962
963
964
965
966
967
968
969
970
971
972
973
974
975
976
977
978
979
980
981
982
983
984
985
986
987
988
989
990
991
992
993
994
995
996
997
998
999
1000
1001
1002
1003
1004
1005
1006
1007
1008
1009
1010
1011
1012
1013
1014
1015
1016
1017
1018
1019
1020
1021
1022
1023
1024
1025
1026
1027
1028
1029
1030
1031
1032
1033
1034
1035
1036
1037
1038
1039
1040
1041
1042
1043
1044
1045
1046
1047
1048
1049
1050
1051
1052
1053
1054
1055
1056
1057
1058
1059
1060
1061
1062
1063
1064
1065
1066
1067
1068
1069
1070
1071
1072
1073
1074
1075
1076
1077
1078
1079
1080
1081
1082
1083
1084
1085
1086
1087
1088
1089
1090
1091
1092
1093
1094
1095
1096
1097
1098
1099
1100
1101
1102
1103
1104
1105
1106
1107
1108
1109
1110
1111
1112
1113
1114
1115
1116
1117
1118
1119
1120
1121
1122
1123
1124
1125
1126
1127
1128
1129
1130
1131
1132
1133
1134
1135
1136
1137
1138
1139
1140
1141
1142
1143
1144
1145
1146
1147
1148
1149
1150
1151
1152
1153
1154
1155
1156
1157
1158
1159
1160
1161
1162
1163
1164
1165
1166
1167
1168
1169
1170
1171
1172
1173
1174
1175
1176
1177
1178
1179
1180
1181
1182
1183
1184
1185
1186
1187
1188
1189
1190
1191
1192
1193
1194
1195
1196
1197
1198
1199
1200
1201
1202
1203
1204
1205
1206
1207
1208
1209
1210
1211
1212
1213
1214
1215
1216
1217
1218
1219
1220
1221
1222
1223
1224
1225
1226
1227
1228
1229
1230
1231
1232
1233
1234
1235
1236
1237
1238
1239
1240
1241
1242
1243
1244
1245
1246
1247
1248
1249
1250
1251
1252
1253
1254
1255
1256
1257
1258
1259
1260
1261
1262
1263
1264
1265
1266
1267
1268
1269
1270
1271
1272
1273
1274
1275
1276
1277
1278
1279
1280
1281
1282
1283
1284
1285
1286
1287
1288
1289
1290
1291
1292
1293
1294
1295
1296
1297
1298
1299
1300
1301
1302
1303
1304
1305
1306
1307
1308
1309
1310
1311
1312
1313
1314
1315
1316
1317
1318
1319
1320
1321
1322
1323
1324
1325
1326
1327
1328
1329
1330
1331
1332
1333
1334
1335
1336
1337
1338
1339
1340
1341
1342
1343
1344
1345
1346
1347
1348
1349
1350
1351
1352
1353
1354
1355
1356
1357
1358
1359
1360
1361
1362
1363
1364
1365
1366
1367
1368
1369
1370
1371
1372
1373
1374
1375
1376
1377
1378
1379
1380
1381
1382
1383
1384
1385
1386
1387
1388
1389
1390
1391
1392
1393
1394
1395
1396
1397
1398
1399
1400
1401
1402
1403
1404
1405
1406
1407
1408
1409
1410
1411
1412
1413
1414
1415
1416
1417
1418
1419
1420
1421
1422
1423
1424
1425
1426
1427
1428
1429
1430
1431
1432
1433
1434
1435
1436
1437
1438
1439
1440
1441
1442
1443
1444
1445
1446
1447
1448
1449
1450
1451
1452
1453
1454
1455
1456
1457
1458
1459
1460
1461
1462
1463
1464
1465
1466
1467
1468
1469
1470
1471
1472
1473
1474
1475
1476
1477
1478
1479
1480
1481
1482
1483
1484
1485
1486
1487
1488
1489
1490
1491
1492
1493
1494
1495
1496
1497
1498
1499
1500
1501
1502
1503
1504
1505
1506
1507
1508
1509
1510
1511
1512
1513
1514
1515
1516
1517
1518
1519
1520
1521
1522
1523
1524
1525
1526
1527
1528
1529
1530
1531
1532
1533
1534
1535
1536
1537
1538
1539
1540
1541
1542
1543
1544
1545
1546
1547
1548
1549
1550
1551
1552
1553
1554
1555
1556
1557
1558
1559
1560
1561
1562
1563
1564
1565
1566
1567
1568
1569
1570
1571
1572
1573
1574
1575
1576
1577
1578
1579
1580
1581
1582
1583
1584
1585
1586
1587
1588
1589
1590
1591
1592
1593
1594
1595
1596
1597
1598
1599
1600
1601
1602
1603
1604
1605
1606
1607
1608
1609
1610
1611
1612
1613
1614
1615
1616
1617
1618
1619
1620
1621
1622
1623
1624
1625
1626
1627
1628
1629
1630
1631
1632
1633
1634
1635
1636
1637
1638
1639
1640
1641
1642
1643
1644
1645
1646
1647
1648
1649
1650
1651
1652
1653
1654
1655
1656
1657
1658
1659
1660
1661
1662
1663
1664
1665
1666
1667
1668
1669
1670
1671
1672
1673
1674
1675
1676
1677
1678
1679
1680
1681
1682
1683
1684
1685
1686
1687
1688
1689
1690
1691
1692
1693
1694
1695
1696
1697
1698
1699
1700
1701
1702
1703
1704
1705
1706
1707
1708
1709
1710
1711
1712
1713
1714
1715
1716
1717
1718
1719
1720
1721
1722
1723
1724
1725
1726
1727
1728
1729
1730
1731
1732
1733
1734
1735
1736
1737
1738
1739
1740
1741
1742
1743
1744
1745
1746
1747
1748
1749
1750
1751
1752
1753
1754
1755
1756
1757
1758
1759
1760
1761
1762
1763
1764
1765
1766
1767
1768
1769
1770
1771
1772
1773
1774
1775
1776
1777
1778
1779
1780
1781
1782
1783
1784
1785
1786
1787
1788
1789
1790
1791
1792
1793
1794
1795
1796
1797
1798
1799
1800
1801
1802
1803
1804
1805
1806
1807
1808
1809
1810
1811
1812
1813
1814
1815
1816
1817
1818
1819
1820
1821
1822
1823
1824
1825
1826
1827
1828
1829
1830
1831
1832
1833
1834
1835
1836
1837
1838
1839
1840
1841
1842
1843
1844
1845
1846
1847
1848
1849
1850
1851
1852
1853
1854
1855
1856
1857
1858
1859
1860
1861
1862
1863
1864
1865
1866
1867
1868
1869
1870
1871
1872
1873
1874
1875
1876
1877
1878
1879
1880
1881
1882
1883
1884
1885
1886
1887
1888
1889
1890
1891
1892
1893
1894
1895
1896
1897
1898
1899
1900
1901
1902
1903
1904
1905
1906
1907
1908
1909
1910
1911
1912
1913
1914
1915
1916
1917
1918
1919
1920
1921
1922
1923
1924
1925
1926
1927
1928
1929
1930
1931
1932
1933
1934
1935
1936
1937
1938
1939
1940
1941
1942
1943
1944
1945
1946
1947
1948
1949
1950
1951
1952
1953
1954
1955
1956
1957
1958
1959
1960
1961
1962
1963
1964
1965
1966
1967
1968
1969
1970
1971
1972
1973
1974
1975
1976
1977
1978
1979
1980
1981
1982
1983
1984
1985
1986
1987
1988
1989
1990
1991
1992
1993
1994
1995
1996
1997
1998
1999
2000
2001
2002
2003
2004
2005
2006
2007
2008
2009
2010
2011
2012
2013
2014
2015
2016
2017
2018
2019
2020
2021
2022
2023
2024
2025
2026
2027
2028
2029
2030
2031
2032
2033
2034
2035
2036
2037
2038
2039
2040
2041
2042
2043
2044
2045
2046
2047
2048
2049
2050
2051
2052
2053
2054
2055
2056
2057
2058
2059
2060
2061
2062
2063
2064
2065
2066
2067
2068
2069
2070
2071
2072
2073
2074
2075
2076
2077
2078
2079
2080
2081
2082
2083
2084
2085
2086
2087
2088
2089
2090
2091
2092
2093
2094
2095
2096
2097
2098
2099
2100
2101
2102
2103
2104
2105
2106
2107
2108
2109
2110
2111
2112
2113
2114
2115
2116
2117
2118
2119
2120
2121
2122
2123
2124
2125
2126
2127
2128
2129
2130
2131
2132
2133
2134
2135
2136
2137
2138
2139
2140
2141
2142
2143
2144
2145
2146
2147
2148
2149
2150
2151
2152
2153
2154
2155
2156
2157
2158
2159
2160
2161
2162
2163
2164
2165
2166
2167
2168
2169
2170
2171
2172
2173
2174
2175
2176
2177
2178
2179
2180
2181
2182
2183
2184
2185
2186
2187
2188
2189
2190
2191
2192
2193
2194
2195
2196
2197
2198
2199
2200
2201
2202
2203
2204
2205
2206
2207
2208
2209
2210
2211
2212
2213
2214
2215
2216
2217
2218
2219
2220
2221
2222
2223
2224
2225
2226
2227
2228
2229
2230
2231
2232
2233
2234
2235
2236
2237
2238
2239
2240
2241
2242
2243
2244
2245
2246
2247
2248
2249
2250
2251
2252
2253
2254
2255
2256
2257
2258
2259
2260
2261
2262
2263
2264
2265
2266
2267
2268
2269
2270
2271
2272
2273
2274
2275
2276
2277
2278
2279
2280
2281
2282
2283
2284
2285
2286
2287
2288
2289
2290
2291
2292
2293
2294
2295
2296
2297
2298
2299
2300
2301
2302
2303
2304
2305
2306
2307
2308
2309
2310
2311
2312
2313
2314
2315
2316
2317
2318
2319
2320
2321
2322
2323
2324
2325
2326
2327
2328
2329
2330
2331
2332
2333
2334
2335
2336
2337
2338
2339
2340
2341
2342
2343
2344
2345
2346
2347
2348
2349
2350
2351
2352
2353
2354
2355
2356
2357
2358
2359
2360
2361
2362
2363
2364
2365
2366
2367
2368
2369
2370
2371
2372
2373
2374
2375
2376
2377
2378
2379
2380
2381
2382
2383
2384
2385
2386
2387
2388
2389
2390
2391
2392
2393
2394
2395
2396
2397
2398
2399
2400
2401
2402
2403
2404
2405
2406
2407
2408
2409
2410
2411
2412
2413
2414
2415
2416
2417
2418
2419
2420
2421
2422
2423
2424
2425
2426
2427
2428
2429
2430
2431
2432
2433
2434
2435
2436
2437
2438
2439
2440
2441
2442
2443
2444
2445
2446
2447
2448
2449
2450
2451
2452
2453
2454
2455
2456
2457
2458
2459
2460
2461
2462
2463
2464
2465
2466
2467
2468
2469
2470
2471
2472
2473
2474
2475
2476
2477
2478
2479
2480
2481
2482
2483
2484
2485
2486
2487
2488
2489
2490
2491
2492
2493
2494
2495
2496
2497
2498
2499
2500
2501
2502
2503
2504
2505
2506
2507
2508
2509
2510
2511
2512
2513
2514
2515
2516
2517
2518
2519
2520
2521
2522
2523
2524
2525
2526
2527
2528
2529
2530
2531
2532
2533
2534
2535
2536
2537
2538
2539
2540
2541
2542
2543
2544
2545
2546
2547
2548
2549
2550
2551
2552
2553
2554
2555
2556
2557
2558
2559
2560
2561
2562
2563
2564
2565
2566
2567
2568
2569
2570
2571
2572
2573
2574
2575
2576
2577
2578
2579
2580
2581
2582
2583
2584
2585
2586
2587
2588
2589
2590
2591
2592
2593
2594
2595
2596
2597
2598
2599
2600
2601
2602
2603
2604
2605
2606
2607
2608
2609
2610
2611
2612
2613
2614
2615
2616
2617
2618
2619
2620
2621
2622
2623
2624
2625
2626
2627
2628
2629
2630
2631
2632
2633
2634
2635
2636
2637
2638
2639
2640
2641

```

Desventajas

- ▶ El usuario debe incluir en la base de conocimientos **toda la evidencia** con la que cuenta, en forma de hechos, antes de poder iniciar el proceso de razonamiento.



Razonamiento hacia adelante

- ▶ En el razonamiento hacia atrás partíamos de las hipótesis para ir hacia la evidencia.
- ▶ Algunas veces resulta más natural razonar en la dirección opuesta: A partir de nuestra **evidencia** y nuestro **conocimiento previo** disponible, explorar que conclusiones podemos obtener.
- ▶ **Ejemplo:** Una vez que hemos confirmado que la sala está mojada y que el baño está seco, podríamos concluir que hay un problema en la cocina.



Un interprete de razonamiento hacia adelante I

```

3 forward :-
4     new_derived_fact(P),      % Se deriva un nuevo hecho.
5     !,
6     write('Nuevo hecho derivado: '), write(P), nl,
7     assert(fact(P)),
8     forward % Buscar más hechos nuevos.
9     ;
10    write('No se derivaron más hechos.'). % Terminar, no más hechos
    ↪ derivados.
11
12 new_derived_fact(Concl) :-
13     if Cond then Concl,      % Una regla
14     \+ fact(Concl),          % cuya conclusión no es un hecho
15     composed_fact(Cond).    % Su condición es verdadera?
16
17 composed_fact(Cond) :-
18     fact(Cond).              % Un hecho simple
19
20 composed_fact(Cond1 and Cond2) :-
21     composed_fact(Cond1),
22     composed_fact(Cond2). % Ambos operandos verdaderos.

```



Un interprete de razonamiento hacia adelante II

```
23
24 composed_fact(Cond1 or Cond2) :-
25     composed_fact(Cond1)
26     ;
27     composed_fact(Cond2). % Al menos un operando verdadero.
```



Consultas

- ▶ Se parte de la evidencia conocida, especificada mediante el predicado `fact`, se derivan los hechos que se pueden **inferir** mediante las reglas de producción y se agregan a la base de conocimiento, mediante el predicado `assert` (lo cual nos lleva a definir `fact` como **dinámico**).

```
1 ?- forward.  
2 Nuevo hecho derivado: problema_en_cocina  
3 Nuevo hecho derivado: no_agua_del_exterior  
4 Nuevo hecho derivado: fuga_en_cocina  
5 No se derivaron más hechos.  
6 true.
```



Interfaz

- ▶ Una interfaz `loadSystem.pl` para cargar los módulos definidos hasta ahora, se implementa como sigue:

```
1  % Cargar el sistema basado en conocimiento.
2
3  :- dynamic(fact/1).
4
5  :- [encadenamientoAtras].
6  :- [encadenamientoAdelante].
7  :- [kbFugasIfThen].
```



Comparando ambos razonamientos

- ▶ Las cadenas de inferencia conectan varios tipos de información como:

Datos	→ ... →	Metas
Evidencia	→ ... →	Hipótesis
Observaciones	→ ... →	Diagnósticos
Descubrimientos	→ ... →	Explicaciones
Manifestaciones	→ ... →	Causas



¿Qué tipo de razonamiento es mejor?

- ▶ Si lo que queremos es verificar si **una hipótesis** determinada es verdadera, entonces el razonamiento hacia atrás resulta más natural.
- ▶ Si es el caso que tenemos **numerosas hipótesis** y ninguna razón para comenzar con una de ellas en particular, entonces el encadenamiento hacia adelante es más adecuado.
- ▶ En general, el razonamiento hacia adelante es más adecuado en situaciones de **monitoreo**, donde los datos se adquieren continuamente.



Red de inferencias revisitada

- ▶ Si solo hay unos pocos **nodos de datos** (el flanco izquierdo de la gráfica) y muchos **nodos meta** (el flanco derecho), entonces el encadenamiento hacia adelante sería el más apropiado;
- ▶ y viceversa.

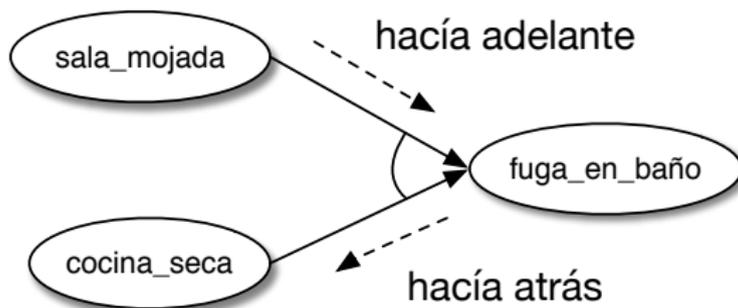


Razonamiento bi-direccional

- ▶ En medicina, por ejemplo, normalmente algunas observaciones iniciales disparan razonamientos del médico hacia **adelante**, para generar una **hipótesis** de diagnóstico inicial.
- ▶ Ésta debe ser **confirmada** o **rechazada** con base en evidencia adicional, la cual se obtiene mediante procesos de razonamiento hacia atrás.



Ejemplo en nuestro dominio



Tipos de explicación

- ▶ Existen formas estándar de generar explicaciones en los sistemas basados en **reglas de producción**.
- ▶ Los **tipos** de explicación computables son respuestas a las preguntas de tipo:
 - ▶ ¿Cómo?
 - ▶ ¿Porqué?



Ejemplo de explicación tipo ¿Cómo?

- ▶ Supongamos que la última respuesta computada por nuestro sistema es que hay una fuga en la cocina. La explicación sería como sigue, por que:
 1. Hay un problema en la cocina, lo cual fue concluído a partir de que la sala está mojada y el baño seco.
 2. El agua no provino del exterior, lo cual fue concluído a partir de que la ventana estaba cerrada.
- ▶ Tal explicación es de hecho el **árbol de derivación** de la meta, es decir, el árbol-SLD de Prolog.



Algoritmo para explicaciones ¿Cómo?

- ▶ Definamos \leq como un operador infijo, para poder representar el árbol de prueba de una proposición P de la siguiente manera:
 1. Si P es un hecho, entonces el árbol de prueba es P mismo.
 2. Si P fue derivado usando una regla: *if* $Cond$ *then* P , el árbol de prueba es $P \leq PruebaCond$; donde $PruebaCond$ es a su vez, el árbol de prueba de $Cond$.
 3. Sean P_1 y P_2 proposiciones cuyos árboles de prueba son A_1 y A_2 , entonces el árbol de prueba de P_1 and P_2 es A_1 and A_2 . El caso de *or*, se resuelve análogamente.



Implementación I

```
1  % is_true(P,A) A es el árbol de prueba de la meta proposicional P
2
3  :- op(800, xfx, <=).
4
5  is_true(P,P) :-
6      fact(P).
7
8  is_true(P, P <= CondA) :-
9      if Cond then P,
10     is_true(Cond,CondA).
11
12 is_true(P1 and P2, A1 and A2) :-
13     is_true(P1,A1),
14     is_true(P2,A2).
15
16 is_true(P1 or P2, A1 or A2) :-
17     is_true(P1,A1)
18     ;
19     is_true(P2,A2).
```



Interfaz V2

```
1  % Cargar el sistema basado en conocimiento.
2
3  :- dynamic(fact/1).
4
5  :- [encadenamientoAtras].
6  :- [encadenamientoAdelante].
7  :- [explicacionesComo].
8  :- [kbFugasIfThen].
```



Ejemplo consulta con explicaciones ¿Cómo?

```
1 ?- [loadSystemV2]. true.  
2  
3 ?- is_true(fuga_en_cocina,A). A =  
4 (fuga_en_cocina<=(problema_en_cocina<=sala_humeda and  
5 bano_seco)and(no_agua_del_exterior<=ventana_cerrada or _66))
```



Formatear la explicación I

```
21 % show_tree(A): Imprime el árbol de derivación A.
22
23 show_tree(A) :-
24     show_tree(A,0).
25
26 % show_tree(A,N): Imprime el árbol de derivación A,
27 % al nivel de indentación N.
28
29 show_tree(A,N) :-
30     var(A), tab(N), writeln('cualquier_cosa').
31
32 show_tree(A1 <= A2,N) :- !,
33     tab(N), write(A1), writeln(' <='),
34     show_tree(A2,N).
35
36 show_tree(A1 and A2,N) :- !,
37     N1 is N + 2,
38     show_tree(A1,N1), tab(N1), writeln('and'),
39     show_tree(A2,N1).
40
41 show_tree(A1 or A2,N) :- !,
```



Formatear la explicación II

```
42     N1 is N + 2,  
43     show_tree(A1,N1), tab(N1), writeln('or'),  
44     show_tree(A2,N1).  
45  
46 show_tree(A,N) :-  
47     tab(N),writeln(A).
```



Consulta mejorada

```
1  ?- [loadSystemV2].
2  true.
3
4  ?- is_true(fuga_en_cocina,A), show_tree(A).
5  fuga_en_cocina <=
6    problema_en_cocina <=
7      sala_humeda
8      and
9      bano_seco
10   and
11   no_agua_del_exterior <=
12     ventana_cerrada
13     or
14     cualquier_cosa
15
16  A = (fuga_en_cocina<=(problema_en_cocina<=sala_humeda and
↪   bano_seco)and(no_agua_del_exterior<=ventana_cerrada or _))
```



Explicaciones del tipo ¿Porqué?

- ▶ Se necesitan en tiempo de ejecución, no al final de una consulta.
- ▶ Requieren que el usuario pueda **interactuar** con la máquina de inferencia del sistema experto, a través de la interfaz.
- ▶ Será necesario especificar que proposiciones pueden ser preguntadas al usuario, mediante el predicado `askable/1`. Agregar a la base de conocimientos:

```
23 %%% Hechos que se pueden preguntar la usuario
```

```
24
```

```
25 askable(no_lluvia).
```

```
26 askable(ventana_cerrada).
```



Algoritmo

- ▶ Dado $askable(P)$, cada vez que la meta P se presente, el sistema preguntará si P es el caso, con tres **respuestas** posibles: si, no, y porque.
- ▶ En caso de respuesta si al sistema, la proposición P es **agregada** a la base de conocimientos, usando `assert(fact(P))`.
- ▶ Debemos agregar también una cláusula al estilo de `already_asked(P)`, para **evitar preguntar** de nuevo por P cuando esto ya no es necesario.
- ▶ La respuesta a porque debería ser una **cadena de reglas** que conectan la evidencia P con la meta original



Implementación de explicaciones tipo ¿Porqué? I

```
1  :- dynamic already_asked/1.
2
3  % iis_true(P,A): P es el caso con la explicación A.
4  % Versión interactiva con el usuario.
5
6  iis_true(P,A) :-
7      explore(P,A, []).
8
9  % explore(P,A,T): A es una explicación de porque P es verdadera, H
10 % es una cadena de reglas que liga P con las metas anteriores.
11
12 explore(P, P, _) :-
13     fact(P).
14
15 explore(P1 and P2, A1 and A2, T) :-
16     explore(P1, A1, T),
17     explore(P2, A2, T).
18
19 explore(P1 or P2, A1 or A2, T) :-
20     explore(P1, A1, T)
21     ;
```



Implementación de explicaciones tipo ¿Porqué? II

```
22     explore(P2, A2, T).
23
24 explore(P, P <= ACond, T) :-
25     if Cond then P,
26     explore(Cond, ACond, [if Cond then P | T]).
27
28 explore(P,A,T) :-
29     askable(P),
30     \+ fact(P),
31     \+ already_asked(P),
32     ask_user(P, A, T).
33
34 % ask_user(P,A,T): Pregunta al usuario si P es el caso,
35 % generando las explicaciones A y T.
36
37 ask_user(P, A, T) :-
38     nl, write('Es cierto que: '), write(P),
39     writeln(' Conteste si/no/porque:'),
40     read(Resp),
41     process_answer(Resp,P,A,T).
42
```



Implementación de explicaciones tipo ¿Porqué? III

```
43 process_answer(si,P, P <= preguntado,_) :-  
44     asserta(fact(P)),  
45     asserta(already_asked(P)).  
46  
47 process_answer(no,P,_,_) :-  
48     asserta(already_asked(P)),  
49     fail.  
50  
51 process_answer(porque,P,A,T) :-  
52     display_rule_chain(T,0), nl,  
53     ask_user(P,A,T).
```



Formato de la explicación I

```
55 % display_rule_chain(R,N): Despliega las reglas R,  
56 % indentando a nivel N.  
57  
58 display_rule_chain([],_).  
59  
60 display_rule_chain([if Cond then P | Reglas], N) :-  
61     nl, tab(N), write('Para explorar si '),  
62     write(P), write(' es el caso, usando la regla '),  
63     nl, tab(N), write(if Cond then P),  
64     N1 is N + 2,  
65     display_rule_chain(Reglas,N1).
```



Interfaz V3

```
1  % Cargar el sistema basado en conocimiento.
2
3  :- dynamic(fact/1).
4
5  :- [encadenamientoAtras].
6  :- [encadenamientoAdelante].
7  :- [explicacionesComo].
8  :- [explicacionesPorque].
9  :- [kbFugasIfThen].
```



Observaciones

- ▶ El predicado principal se llama ahora `iis_true/2`, para indicar que es la versión **interactiva** del anterior `is_true/2`
- ▶ De otra forma hay un **conflicto de nombres**, que Prolog resuelve definiendo nuevamente el predicado en cuestión a partir del último archivo cargado.



Preliminares a la consulta

- ▶ Antes de ejecutar la consulta, verifique que ha **comentado** la línea correspondiente a `fact(ventana_cerrada` en la base de conocimientos original, para que el sistema experto deba preguntar por este hecho o por `no_lluvia`.
- ▶ El usuario puede pedir explicaciones al respecto en ambos casos.



Ejemplo de consulta con explicación ¿Porqué? I

```
1  ?- [loadSystemV3].
2  true.
3
4  ?- iis_true(fuga_en_cocina,A), show_tree(A).
5
6  Es cierto que: ventana_cerrada Conteste si/no/porque:
7  |: porque.
8
9  Para explorar si no_agua_del_exterior es el caso, usando la regla
10 if ventana_cerrada or no_lluvia then no_agua_del_exterior Para
11 explorar si fuga_en_cocina es el caso, usando la regla if
12 problema_en_cocina and no_agua_del_exterior then fuga_en_cocina
13
14 Es cierto que: ventana_cerrada Conteste si/no/porque:
15 |: si.
16
17 fuga_en_cocina <=
18     problema_en_cocina <=
19         sala_humeda
20     and
```



Ejemplo de consulta con explicación ¿Porqué? II

```
21     bano_seco
22     and
23     no_agua_del_exterior <=
24     ventana_cerrada
25     or
26     cualquier_cosa
27
28 A = (fuga_en_cocina<=(problema_en_cocina<=sala_humeda and
29     bano_seco)and(no_agua_del_exterior<=(ventana_cerrada<=preguntado)or
    ↪ _6410))
```



Limitaciones

- ▶ Obviamente el módulo de explicaciones del tipo ¿Porqué? solo funciona con reglas **proposicionales**.
- ▶ Si usásemos variables, habría que preguntar también por los **valores** de estas.
- ▶ No verificamos que las respuestas del usuario sean **válidas**. Ver el tutorial de prolog E/S.



Grados de certeza

- ▶ Mucha de la experticia humana no es categórica. Tanto los datos como las reglas asociadas a un dominio de problema, pueden ser **parcialmente** ciertos.
- ▶ Tal incertidumbre se puede **modelar** si asignamos alguna calificación, otra que no sea verdadero o falso. **Por ej.**, un valor entre 0 y 1.
- ▶ Tales valores reciben diversos nombres como **grados de certeza**, o grados de creencia, o probabilidad subjetiva.
- ▶ **No están** basados estrictamente en la teoría de probabilidad.



Esquema de certeza

- ▶ Cada **proposición** P será asociada a un número FC entre 0 y 1, que representará su **grado de certeza**. Usaremos un par $P : FC$ para esta representación.
- ▶ La notación adoptada para las nuevas **reglas** será:

if Cond then $P : FC$.



Combinación de factores de certeza

- ▶ El esquema de combinación será el siguiente

$$c(P_1 \text{ and } P_2) = \text{mín}(c(P_1), c(P_2)) \quad (1)$$

$$c(P_1 \text{ or } P_2) = \text{máx}(c(P_1), c(P_2)) \quad (2)$$

- ▶ En el caso de una regla *if* P_1 *then* P_2 : FC , entonces:

$$c(P_2) = c(P_1) \times FC \quad (3)$$



Simplificaciones

- ▶ Por simplicidad asumiremos que las reglas tienen implicaciones **únicas**.
- ▶ Si ese no fuese el caso, las implicaciones pueden escribirse como **disyunciones** para satisfacer esta restricción de formato.



Nueva base de conocimientos I

```
1  %%% base de conocimiento para fugas, en fomato de reglas if-then
2
3  %%% Conocimiento previo con certidumbre
4
5  if sala_humeda and cocina_seca
6  then fuga_en_bano.
7
8  if sala_humeda and bano_seco
9  then problema_en_cocina:0.9.
10
11 if ventana_cerrada or no_lluvia
12 then no_agua_del_exterior.
13
14 if problema_en_cocina and no_agua_del_exterior
15 then fuga_en_cocina.
16
17 % Evidencia con certidumbre
18
19 given(sala_humeda, 1).      % verdadero
20 given(bano_seco, 1).
21 given(cocina_seca, 0).     % falso
```



Nueva base de conocimientos II

```
22 given(no_lluvia, 0.8).      % muy probable
23 given(ventana_cerrada, 0).
```



Implementación I

```
1  % Interprete basado en reglas con incertidumbre
2
3  % cert(P,C): C es el grado de certeza de la proposición P
4
5  cert(P,C) :-
6      given(P,C).
7
8  cert(P1 and P2, C) :-
9      cert(P1,C1),
10     cert(P2,C2),
11     min(C1,C2,C).
12
13 cert(P1 or P2, C) :-
14     cert(P1,C1),
15     cert(P2,C2),
16     max(C1,C2,C).
17
18 cert(P, C) :-
19     if Cond then P:C1,
20     cert(Cond,C2),
21     C is C1 * C2.
```



Implementación II

```
22
23 cert(P, C) :-
24     if Cond then P,
25     cert(Cond,C1),
26     C is C1.
27
28 % max y min
29
30 max(X,Y,X) :- X>=Y,! .
31 max(_,Y,Y) .
32
33 min(X,Y,X) :- X<=Y,! .
34 min(_,Y,Y) .
```



Interfaz V4

```
1  % Cargar el sistema basado en conocimiento.
2
3  :- dynamic(fact/1).
4
5  :- [encadenamientoAtras].
6  :- [encadenamientoAdelante].
7  :- [incertidumbre].
8  :- [kbFugasIncert].
```



Consulta con incertidumbre

```
1 ?- cert(fuga_en_cocina,FC). FC = 0.8
```



Limitaciones

- ▶ Los factores de certeza **no son probabilidades**, en el sentido estricto del término.
 - ▶ Asumamos que:
 - ▶ el factor de certeza de a es 0.5 y el de b es 0.
 - ▶ Entonces, el factor de certeza de a or b es 0.5.
 - ▶ Ahora, si el factor de certeza de b se incrementa a 0.5, esto **no tiene efecto** en el factor de certeza de la disyunción, que sigue siendo 0.5.
- lo cual resulta, al menos, **contra intuitivo**.



Objeciones transnochadas

- ▶ Los expertos humanos parecen tener **problemas** para razonar basados realmente en la teoría de probabilidad. La verosimilitud que usan, no se corresponde con la noción de probabilidad definida matemáticamente.
- ▶ El procesamiento con base en la teoría de probabilidad, parece requerir de información que no siempre está **disponible**; o asumir simplificaciones que no siempre se **justifican**.



Redes Bayesianas

- ▶ También se les conoce como **Redes de creencias** [2].
- ▶ Usan el **cálculo de probabilidades** para manejar la **incertidumbre** inherente a las representaciones de conocimiento.
- ▶ Proveen mecanismos eficientes para manejar las **dependencias probabilísticas**, mientras explotan las independencias;
- ▶ Resultando en una representación “natural” de la **causalidad**.



Supuestos

- ▶ El **estado** del medio ambiente puede representarse por medio de un **vector de variables**.
- ▶ Nuestras variables tienen un **dominio booleano**, es decir, podrán tener como valor falso o verdadero.
- ▶ **Ejemplo:** ladron y alarma.
- ▶ Se puede generalizar a dominios **no booleanos**, pero discretos.



Eventos

- ▶ Cuando las variables son booleanas, es normal pensar en ellas como si representasen **eventos**.
- ▶ **Ejemplo:** Si la alarma **suen**a en el mundo real, es de esperar que la variable **alarma** se vuelve verdadera.



Probabilidades

- ▶ Un agente, natural o artificial, normalmente **no está** completamente seguro de cuando estos eventos son verdaderos o falsos.
- ▶ El agente razona acerca de la **probabilidad** de que la variable en cuestión sea verdadera.
- ▶ Las probabilidades en este caso, son usadas como una medida del **grado de creencia**.
- ▶ Este grado depende de qué tanto el agente conoce su medio ambiente.
- ▶ Tales creencias se conocen también como **probabilidades subjetivas**, que no arbitrarias.



Notación

- ▶ Sean X e Y dos variables, entonces, como de costumbre:
 - ▶ $X \wedge Y$ denota la conjunción de X e Y .
 - ▶ $X \vee Y$ denota la disyunción de X e Y .
 - ▶ $\neg X$ denota la negación de X .
- ▶ La expresión $p(X)$ denota la **probabilidad** de que la proposición X sea verdadera.
- ▶ La expresión $p(X|Y)$ denota la **probabilidad condicional** de que la proposición X sea verdadera, dado que la proposición Y lo es.



Nuevas metas

- ▶ Un **meta** típica es este contexto toma esta forma: Dado que los valores de ciertas variables han sido observados ¿Cuales son las probabilidades de que otras variables de interés tomen cierto valor específico?
- ▶ O: Dado que ciertos eventos han sido observados ¿Cual es la probabilidad de que sucedan otros eventos de interés?
- ▶ **Ejemplo:** Si observamos que la alarma suena ¿Cual es la probabilidad de que un ladrón haya entrado en la casa?



Problemas

- ▶ La mayor dificultad para resolver estas metas está en manejar la **dependencia** entre las variables del problema.
- ▶ Si nuestro problema contempla n variables booleanas, necesitamos $2^n - 1$ números para definir la **distribución de probabilidad** completa entre los 2^n estados posibles del medio ambiente!
- ▶ Esto no sólo es costoso y nada práctico, sino que suele ser **imposible**, dada la **disposición** de esta información.
- ▶ Afortunadamente, suele ser el caso que **no es necesario** contar con todas esas probabilidades.

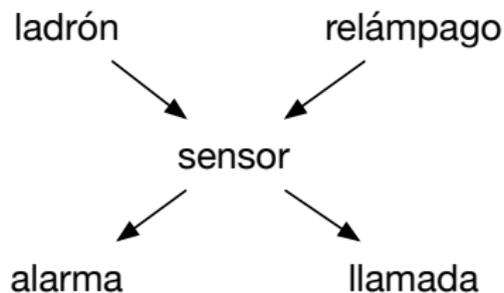


Dependencia, independencia y redes bayesianas

- ▶ La distribución de probabilidades completa, **no asume** nada acerca de la independencia entre variables.
- ▶ Afortunadamente, **algunos** eventos son independientes de otros.
- ▶ Las redes bayesianas proveen una forma elegante para **declarar** la dependencia e independencia entre variables.



Ejemplo de red bayesiana



- ▶ La **estructura** de esta red indica dependencias e independencias probabilistas.
- ▶ **Ejemplo:** ladrón no es dependiente de relámpago. Sin embargo, si se llega a saber que alarma es verdadera, entonces bajo las condiciones dadas, ladrón y relámpago ya no son independientes.



Un ejemplo más elaborado

- ▶ Las ligas en la red bayesiana sugieren **causalidad**.
- ▶ **Ejemplo:** El ladrón es causa de que el sensor se dispare. El sensor por su parte, es la causa de que la alarma se encienda.
- ▶ La estructura de la red permite **razonamientos** como el siguiente:
- ▶ **Ejemplo:** Si alarma es verdadero, entonces un ladrón pudo entrar en casa, puesto que esa es una de las causas de que la alarma suene.
- ▶ Si nos enteramos de que hay una tormenta, la presencia del ladrón debería volverse **menos** probable.



Tipos de razonamiento

- ▶ En el ejemplo anterior, el razonamiento es de diagnóstico y predictivo al mismo tiempo.
- ▶ Al sonar la alarma, podemos **diagnosticar** que la causa posible es la presencia de un ladrón.
- ▶ Al enterarnos de la tormenta, podemos **predecir** que la causa real fue un relámpago.



Notación

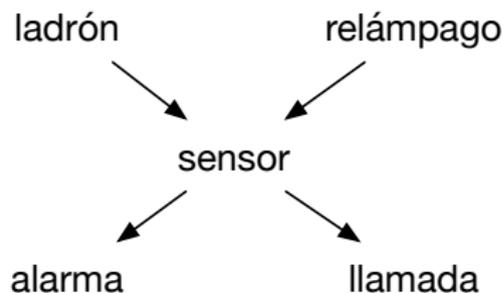
- ▶ Un nodo Z es **descendiente** de X si hay un camino en la red, siguiendo las ligas desde X hasta Z .
- ▶ Los nodos Y_1, Y_2, \dots son **padres** de X en la red, si tienen una liga directa hacia X .
- ▶ X es **independiente** de los nodos que no son sus descendientes, dados sus padres (y nada más que ellos).
- ▶ De forma que, para **computar** $P(X)$, basta con tomar en cuenta los descendientes de X y sus padres (Y_1, Y_2, \dots).
- ▶ El **efecto** de las demás variables en X se acumula en sus padres.



Ejemplo

- ▶ Supongamos que sabemos que *sensor* es verdadera, y queremos saber $P(\text{alarma})$.
- ▶ Dado que ningún nodo en la red es descendientes de *alarma*, y que el valor de *sensor*, único padre de *alarma*, es conocido:

$$p(\text{alarma} \mid \text{ladrón} \wedge \text{relampago} \wedge \text{sensor} \wedge \text{llamada}) = p(\text{alarma} \mid \text{sensor})$$



Probabilidades de la red

- ▶ Para completar la representación de un modelo probabilístico con una red bayesiana, debemos definir algunas **probabilidades**.
- ▶ Para los nodos que no tienen padres (**nodos raíz**), se especifican sus **probabilidades a priori**.
- ▶ Para los demás nodos debemos especificar **su probabilidad condicional** dado estado de sus padres: $p(X \mid \text{padres de } X)$.



Nuestra red en Prolog

```
1  %%% Red bayesiana alarma-ladron
2
3  % Estructura de la Red
4
5  padre(ladron, sensor).    % el ladrón tiende a disparar el sensor
6  padre(relampago, sensor). % un relámpago fuerte también
7  padre(sensor, alarma).
8  padre(sensor, llamada).
9
10 % Probabilidades
11
12 p(ladron, 0.001). % Probabilidad a priori
13 p(relampago, 0.02).
14 p(sensor, [ladron, relampago], 0.9). % Probabilidad condicionada
15 p(sensor, [ladron, not relampago], 0.9).
16 p(sensor, [not ladron, relampago], 0.1).
17 p(sensor, [not ladron, not relampago], 0.001).
18 p(alarma, [sensor], 0.95).
19 p(alarma, [not sensor], 0.001).
20 p(llamada, [sensor], 0.9).
21 p(llamada, [not sensor], 0.0).
```



Observaciones

- ▶ Observen que hay dos nodos raíz en la red: *ladron* y *relampago*, por lo que es necesario especificar sus probabilidades *a priori*.
- ▶ El nodo *sensor* tiene dos padres, por lo que sus probabilidades condicionadas dado el estado de sus padres forman una tabla de cuatro entradas (2^n , donde n es el número de padres).
- ▶ Las variables *alarma* y *llamada* sólo tienen un padre, por lo que sus tablas de probabilidad condicional tienen dos entradas.
- ▶ 10 probabilidades, en lugar de $2^5 - 1 = 31$ probabilidades!



Cálculo de probabilidades

▶ Sean X e Y dos proposiciones, entonces:

▶ $p(\neg X) = 1 - p(X)$

▶ $p(X \wedge Y) = p(X) \times p(Y)$

▶ $p(X \vee Y) = p(X) + p(Y) - p(X \wedge Y)$

▶ $p(X) = p(X \wedge Y) + p(X \wedge \neg Y) = p(Y)p(X | Y) + p(\neg Y)p(X | \neg Y)$



Eventos independientes

- ▶ Las proposiciones X es Y se dice **independientes** si $p(X | Y) = p(X)$ y $p(Y | X) = p(Y)$.
- ▶ Esto es, si Y no afecta mi creencia sobre X y viceversa.
- ▶ Si X e Y son independientes, entonces:
 - ▶ $p(X \wedge Y) = p(X) \times p(Y)$



Eventos disjuntos

- ▶ Se dice que las proposiciones X e Y son **disjuntas** si no pueden ser verdaderas al mismo tiempo, en cuyo caso: $p(X \wedge Y) = 0$ y $p(X | Y) = 0$ y $p(Y | X) = 0$.



Generalización de eventos conjuntos

- ▶ Sean X_1, \dots, X_n proposiciones, entonces:

$$p(X_1 \wedge \dots \wedge X_n) = p(X_1)p(X_2 | X_1)p(X_3 | X_1 \wedge X_2) \dots p(X_n | X_1 \wedge \dots \wedge X_{n-1})$$

- ▶ Si todas las variables son independientes, esto se reduce a:

$$p(X_1 \wedge \dots \wedge X_n) = p(X_1)p(X_2)p(X_3) \dots p(X_n)$$



Teorema de Bayes

- ▶ Finalmente, necesitaremos el **teorema de Bayes**:

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



Aplicación del Teorema de Bayes

- ▶ Consideremos que un ladrón es una causa de que la alarma se encienda, es natural razonar en términos de que proporción de ladrones disparan alarmas, es decir $p(\text{alarma} \mid \text{ladron})$.
- ▶ Pero cuando oímos la alarma, estamos interesados en saber la probabilidad de su causa, es decir $p(\text{ladron} \mid \text{alarma})$. Aquí es donde entra el teorema de Bayes en nuestra ayuda:

$$p(\text{ladron} \mid \text{alarma}) = p(\text{ladron}) \frac{p(\text{alarma} \mid \text{ladron})}{p(\text{alarma})}$$



Conocimiento previo

- ▶ Una variante del teorema de Bayes, toma en cuenta el **conocimiento previo** B .
- ▶ Esto nos permite razonar acerca de la probabilidad de una **hipótesis** H , dada la **evidencia** E , bajo el supuesto del conocimiento previo B :

$$p(H \mid E \wedge B) = p(H \mid B) \frac{p(E \mid H \wedge B)}{p(E \mid B)}$$



Un intérprete para redes bayesianas

- ▶ Dada una red, queremos que este intérprete responda a preguntas del estilo de: ¿Cual es la probabilidad de una proposición dada, asumiendo que otras proposiciones son el caso?
- ▶ Algunas **preguntas** al intérprete de razonamiento Bayesiano, podrían ser:
 - ▶ $p(\text{ladron} \mid \text{alarma}) = ?$
 - ▶ $p(\text{ladron} \wedge \text{relampago}) = ?$
 - ▶ $p(\text{ladron} \mid \text{alarma} \wedge \neg \text{relampago}) = ?$
 - ▶ $p(\text{alarma} \wedge \neg \text{llamada} \mid \text{ladron}) = ?$



Reglas de cómputo I

1. Probabilidad de una **conjunción**:

$$p(X_1 \wedge X_2 \mid Cond) = p(X_1 \mid Cond) \times p(X_2 \mid X_1 \wedge Cond)$$

2. Probabilidad de un **evento cierto**:

$$p(X \mid Y_1 \wedge \dots \wedge X \wedge \dots) = 1$$

3. Probabilidad de un **evento imposible**:

$$p(X \mid Y_1 \wedge \dots \wedge \neg X \wedge \dots) = 0$$

4. Probabilidad de una **negación**:

$$p(\neg X \mid Cond) = 1 - p(X \mid Cond)$$



Reglas de cómputo II

5. Si la condición involucra un **descendiente** de X , usamos el teorema de Bayes. Si Y es un descendiente de X en la red, entonces:

$$p(X | Y \wedge Cond) = p(X | Cond) \frac{p(Y | X \wedge Cond)}{p(Y | Cond)}$$

6. Si la condición no involucra **descendientes** de X , hay dos casos:

6.1 Si X es una **causa raíz**, entonces $p(X | Cond) = p(X)$.

6.2 Si X tiene **padres**, entonces:

$$p(X | Cond) = \sum_{S \in \text{estadosPosibles(Padres)}} p(X | S) p(S | Cond)$$



Ejemplo I

- ▶ ¿Cual es la probabilidad de un ladrón dado que sonó la alarma?
- ▶ Primero, por la regla 5:

$$p(\text{ladron} \mid \text{alarma}) = p(\text{ladron}) \frac{p(\text{alarma} \mid \text{ladron})}{p(\text{alarma})}$$

- ▶ y por la regla 6:

$$p(\text{alarma} \mid \text{ladron}) = p(\text{alarma} \mid \text{sensor}) p(\text{sensor} \mid \text{ladron}) + p(\text{alarma} \mid \neg \text{sensor}) p(\neg \text{sensor} \mid \text{ladron})$$



Ejemplo II

- ▶ y por la misma regla 6:

$$\begin{aligned}
 p(\text{sensor} \mid \text{ladron}) &= p(\text{sensor} \mid \text{ladron} \wedge \text{relampago})p(\text{ladron} \wedge \text{relampago} \mid \text{ladron}) + \\
 & p(\text{sensor} \mid \neg \text{ladron} \wedge \text{relampago})p(\neg \text{ladron} \wedge \text{relampago} \mid \text{ladron}) + \\
 & p(\text{sensor} \mid \text{ladron} \wedge \neg \text{relampago})p(\text{ladron} \wedge \neg \text{relampago} \mid \text{ladron}) + \\
 & p(\text{sensor} \mid \neg \text{ladron} \wedge \neg \text{relampago})p(\neg \text{ladron} \wedge \neg \text{relampago} \mid \text{ladron})
 \end{aligned}$$

- ▶ Aplicando las reglas 1,2,3 y 4 como corresponde, esto se reduce a:

$$\begin{aligned}
 p(\text{sensor} \mid \text{ladron}) &= 0,9 \times 0,02 + 0 + 0,9 \times 0,98 + 0 = 0,9 \\
 p(\text{alarma} \mid \text{ladron}) &= 0,95 \times 0,9 + 0,001 \times (1 - 0,9) = 0,8551
 \end{aligned}$$

- ▶ Usando las reglas 1,4 y 6 obtenemos:

$$p(\text{alarma}) = 0,00467929$$



Ejemplo III

► Finalmente

$$p(\text{ladron} \mid \text{alarma}) = 0,001 \times 0,8551 / 0,00467929 = 0,182741$$



En Prolog I

```

1  % Motor de inferencia para Red Bayesiana
2
18
19  prob( [X|Xs], Cond, P) :- !,    % Prob de la conjunción
20     prob(X, Cond, Px),
21     prob(Xs, [X|Cond], PRest),
22     P is Px * PRest.
23
24  prob([], _, 1) :- !.           % Conjunción vacía
25
26  prob(X, Cond, 1) :-
27     member(X, Cond), !.        % Cond implica X
28
29  prob(X, Cond, 0) :-
30     member(not X, Cond), !.    % Cond implica X es falsa
31
32  prob(not X, Cond, P) :- !,    % Negación
33     prob(X, Cond, P0),
34     P is 1 - P0.
35
36  % Usa la regla de Bayes si Cond0 incluye un descendiente de X

```



En Prolog II

```

37
38 prob(X,Cond0,P) :-
39     select(Y,Cond0,Cond),
40     pred(X,Y), !,           % Y es un descendiente de X
41     prob(X,Cond,Px),
42     prob(Y,[X|Cond], PyDadoX),
43     prob(Y,Cond,Py),
44     P is Px * PyDadoX / Py.           % Asumiendo Py > 0
45
46 % Casos donde Cond no involucra a un descendiente
47
48 prob(X,_, P) :-
49     p(X, P), !.           % X una causa raíz - prob dada
50
51 prob(X, Cond, P) :- !,
52     findall((Condi,Pi), p(X,Condi,Pi), CPlist), % Conds padres
53     suma_probs(CPlist, Cond, P).
54
55 % suma_probs(CondsProbs, Cond, SumaPond)
56 % CondsProbs es una lista de conds y sus probs
57 % SumaPond suma de probs de Conds dada0 Cond

```



En Prolog III

```
58
59 suma_probs([], _, 0).
60
61 suma_probs([(Cond1,P1)|CondsProbs], Cond, P) :-
62     prob(Cond1, Cond, PC1),
63     suma_probs(CondsProbs, Cond, PResto),
64     P is P1 * PC1 + PResto.
65
66 % pred(var1,var2). var1 es predecesora de var2 en la red.
67
68 pred( X, not Y) :- !,           % Y negada
69     pred( X, Y).
70
71 pred( X, Y) :-
72     padre( X, Y).
73
74 pred( X, Z) :-
75     padre( X, Y),
76     pred( Y, Z).
```



Consultas

```
1  ?- prob(ladron,[alarma],P).
2  P = 0.182741321476588.
3
4  ?- prob(alarma,[],P).
5  P = 0.00467929198.
6
7  ?- prob(ladron,[llamada],P).
8  P = 0.23213705371651422.
9
10 ?- prob(ladron,[llamada,relampago],P).
11 P = 0.008928571428571428.
12
13 ?- prob(ladron,[llamada,not relampago],P).
14 P = 0.47393364928909953.
```

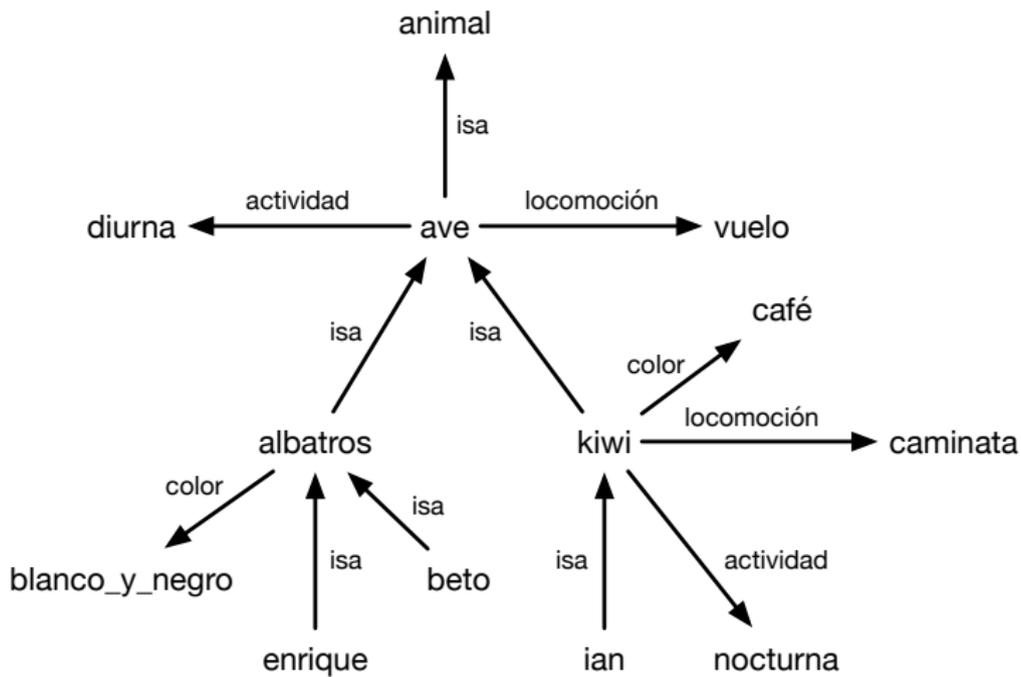


Redes semánticas y Marcos

- ▶ Están diseñados para representar, de manera **estructurada**, grandes cantidades de hechos.
- ▶ Este conjunto de hechos es normalmente **compactado**: Se obvian algunos hechos, cuando estos pueden ser inferidos.
- ▶ Utilizan la **herencia**, de manera similar a como se utiliza en los lenguajes de programación orientados a objetos.



Red semántica



Relaciones y herencia

- ▶ La relación especial isa denota la relación **es un**. La red del ejemplo representa los siguientes hechos:
 - ▶ Un ave es un tipo de animal.
 - ▶ El vuelo es el medio de locomoción de las aves.
 - ▶ Un albatros es un ave.
 - ▶ Enrique y Beto son albatros.
 - ▶ Un kiwi es un ave.
 - ▶ La caminata es el medio de locomoción de un kiwi.
 - ▶ etc.



Red semántica en Prolog

```
1  % Red semántica
2
3  isa(ave, animal).
4  isa(albatros, ave).
5  isa(kiwi, ave).
6  isa(enrique, albatros).
7  isa(beto, albatros).
8  isa(ian, kiwi).
9
10 actividad(ave, diurna).
11 actividad(kiwi, nocturna).
12
13 color(albatros, blanco_y_negro).
14 color(kiwi, cafe).
15
16 locomocion(ave, vuelo).
17 locomocion(kiwi, caminata).
```



Inferencias sobre red semántica I

```
1  % Interprete Redes Semánticas
2
3  fact(Hecho) :-
4      Hecho,! .
5
6  fact(Hecho) :-
7      Hecho =.. [Rel,Arg1,Arg2],
8      isa(Arg1,SuperClaseArg1),
9      SuperHecho =.. [Rel,SuperClaseArg1,Arg2],
10     fact(SuperHecho).
11
12
```



Consulta a red semántica

```
1 ?- [seRedSemantica].
2 true.
3 ?- fact(locomocion(ian,Loc)).
4 Loc = caminata.
5 ?- fact(locomocion(enrique,Loc)).
6 Loc = vuelo.
```

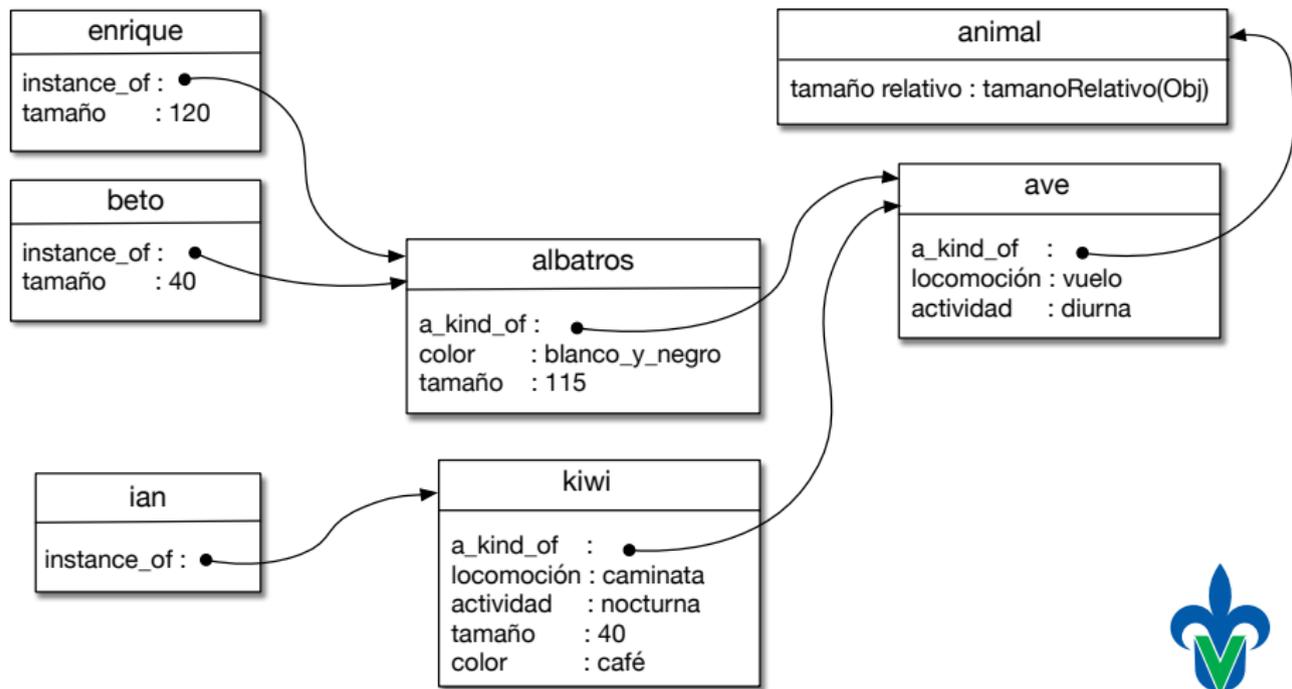


Marcos

- ▶ Predecesor de la programación orientada a objetos.
- ▶ Un **marco** (*frame*) es una estructura de datos, cuyos componentes se llaman **ranuras** (*slots*).
- ▶ Las ranuras pueden guardar información de diferentes **tipos**:
 - ▶ Valores.
 - ▶ Referencias a otros marcos.
 - ▶ Procedimientos para computar valores.
- ▶ También usan **herencia**



Representación basada en marcos.



Marcos en Prolog I

```
1  % Base de conocimiento basada en Marcos
2  % Los hechos se representan como marco(ranura,valor).
3  % El valor puede ser un procedimiento para su cálculo.
4
5  % Marco ave: un ave prototípica
6
7  ave(a_kind_of, animal).
8  ave(locomocion, vuelo).
9  ave(actividad, diurna).
10
11 % Marco albatros: un ave prototípica con hechos extra:
12 % es blanco y negro; y mide 115cm
13
14 albatros(a_kind_of, ave).
15 albatros(color, blanco_y_negro).
16 albatros(tamano, 115).
17
18 % Marco kiwi: un ave prototípica con hechos extra:
19 % camina, es nocturno, café y mide unos 40cm
20
21 kiwi(a_kind_of, ave).
```



Marcos en Prolog II

```
22 kiwi(locomocion,caminata).
23 kiwi(actividad,nocturna).
24 kiwi(tamano,40).
25 kiwi(color,cafe).
26
27 % Marco enrique: es un albatros
28
29 enrique(instance_of,albatros).
30 enrique(tamano,120).
31
32 % Marco beto: es un albatros bebé
33
34 beto(instance_of,albatros).
35 beto(tamano,40).
36
37 % Marco ian: es un kiwi.
38
39 ian(instance_of,kiwi).
40
41 % Marco animal: su tamaño relativo se calcula ejecutando un
42 % procedimiento
```



Marcos en Prolog III

```
43
44 animal(tamanoRelativo,
45         execute(tamanoRelativo(Obj,Val), Obj, Val)).
46
47 % tamanoRelativo(Obj,TamRel): El tamaño relativo TamRel de Obj
48
49 tamanoRelativo(Obj,TamRel) :-
50     value(Obj,tamano,TamObj),
51     value(Obj,instance_of,ClaseObj),
52     value(ClaseObj,tamano,TamClase),
53     TamRel is (TamObj/TamClase) * 100.
```



Inferencia con marcos en Prolog I

```
1  % Motor de inferencia para Marcos
2
3  value(Frame,Slot,Value) :-
4      Query =.. [Frame,Slot,Value],
5      Query, !. % valor encontrado directamente.
6
7  value(Frame,Slot,Value) :-
8      parent(Frame,ParentFrame), % Un marco más general
9      value(ParentFrame,Slot,Value).
10
11
12 parent(Frame,ParentFrame) :-
13     (Query =.. [Frame, a_kind_of, ParentFrame]
14     ;
15     Query =.. [Frame, instance_of, ParentFrame]
16     ),
17     Query.
```



Consultas a los marcos

```
1 ?- value(enrique,actividad,Act). Act = diurna
2
3 ?- value(kiwi,actividad,Act). Act = nocturna.
```



Inferencia con marcos y funciones en Prolog I

```
1  % Motor inferencial para marcos V2: Incluye funciones
2
3  value(Frame,Slot,Value) :-
4      value(Frame, Frame, Slot, Value).
5
6  value(Frame, SuperFrame, Slot, Value) :-
7      Query =.. [SuperFrame, Slot, ValAux],
8      Query,
9      process(ValAux, Frame, Value), !.
10
11 value(Frame, SuperFrame, Slot, Value) :-
12     parent(SuperFrame, ParentSuperFrame),
13     value(Frame, ParentSuperFrame, Slot, Value).
14
15 parent(Frame,ParentFrame) :-
16     (Query =.. [Frame, a_kind_of, ParentFrame]
17     ;
18     Query =.. [Frame, instance_of, ParentFrame]
19     ),
20     Query.
21
```



Inferencia con marcos y funciones en Prolog II

```
22 process(execute(Proc, Frame, Value), Frame, Value) :- !,  
23     Proc.  
24  
25 process(Value,_,Value).  % un valor, no un procedimiento.
```



Consultas

```
1 ?- value(enrique,tamanoRelativo,Tam).
2 Tam = 104.34782608695652
3 ?- value(beto,tamanoRelativo,Tam).
4 Tam = 34.78260869565217
5 ?- value(ian,tamanoRelativo,Tam).
6 Tam = 100
7 ?- value(beto,color,C).
8 C = blanco_y_negro.
```



Interfaz

- ▶ La base de conocimientos basada en marcos y su motor de inferencia, incluyendo funciones, se puede llamar con el *script* `seMarcos.pl`:

```
1 % Sistema Experto basado en marcos.  
2  
3 % :- [inferenciaMarcos].  
4 :- [inferenciaMarcosFunc].  
5 :- [kbMarcos].
```



Referencias I

- [1] VE Barker y O'Connor. "Expert systems for configuration at Digital: XCON and beyond". En: *Communications of the ACM* 32.3 (1989), págs. 298-318.
- [2] I Bratko. *Prolog programming for Artificial Intelligence*. Fourth. Essex, England: Pearson, 2012.
- [3] BG Buchanan y EH Shortliffe. *Rule-Based Expert Systems: The MYCIN Experiments of the Stanford Heuristic Programming Project*. The Addison-Wesley Series in Artificial Intelligence. Reading, MA, USA: Addison-Wesley, 1984.
- [4] PE Hart, RO Duda y MT Einaudi. "PROSPECTOR– A Computer-Based Consultation System for Mineral Exploration". En: *Mathematical Geology* 10.5 (1978), págs. 589-610.
- [5] RK Lindsay et al. *Applications of Artificial Intelligence for Organic Chemistry: The DENDRAL Project*. McGraw-Hill advanced computer science series. New York, NY, USA: McGraw-Hill Book Company, 1980.
- [6] RK Lindsay et al. "DENDRAL: a case study of first expert system for scientific hypothesis formation.". En: *Artificial Intelligence* 61.2 (1993), págs. 209-261.
- [7] J McDermott. "R1: A rule-based configurer of computer systems". En: *Artificial intelligence* 19.1 (1982), págs. 39-88.



Referencias II

- [8] J Negrete-Martínez, PP González-Pérez y A Guerra-Hernández. *Pericia Artificial: Una aproximación incremental a los Sistemas Expertos*. Xalapa, Ver., México: Universidad Veracruzana, 1996.
- [9] EH Shortliffe et al. "An Artificial Intelligence program to advise physicians regarding antimicrobial therapy". En: *Computers and Biomedical Research* 6.6 (1973), págs. 544-560.
- [10] EH Shortliffe et al. "Computer-Based Consultations in Clinical Therapeutics: Explanation and Rule Acquisition Capabilities of the MYCIN System". En: *Computers and Biomedical Research* 8.4 (1975), págs. 303-320.

