

Enfoque probabilístico en Inteligencia Artificial aplicado al Análisis en Inteligencia

Francisco Andrés Pérez, Coordinador Oficina Proyectos, Real Instituto Elcano

1. Introducción

La teoría de la probabilidad es la rama de las matemáticas que estudia fenómenos aleatorios, es decir aquellos cuyo resultado es impredecible, y estocásticos, aquellos sobre los que existe una secuencia cambiante de eventos que, en principio, no son deterministas. Lo que subyace, pues, en dicha teoría, es la aspiración de gestionar y comprender algo tan difícil de delimitar como la incertidumbre.

El analista de inteligencia se enfrenta en su quehacer diario a un esfuerzo cognitivo que traducir en decisiones racionales la inaprensible naturaleza de la incertidumbre. Sin embargo, en este combate mental, que solamente puede apoyarse en la información disponible a partir de fuentes muy diversas, el analista se encuentra en desventaja cuando dicha información es compleja, ambigua o escasa. Es en dichas situaciones donde “la máquina” puede servir de extensión o complemento de la capacidad cognitiva del analista.

La presente comunicación trata de presentar los últimos avances del enfoque probabilístico en inteligencia artificial como líneas de investigación con potencial aplicación en el análisis en inteligencia.

2. Enfoque probabilístico

El enfoque probabilístico ocupa un lugar importante en los últimos desarrollos en inteligencia artificial, robótica o aprendizaje automático. Aunque en muchos de estos avances la incertidumbre juega un papel primordial hay otros enfoques en los que su representación no es primordial. Algunas aplicaciones, por ejemplo, de reconocimiento de patrones tales como clasificación de imágenes o reconocimiento de voz utilizan redes neuronales no aplican la teoría de la probabilidad en la determinación de sus parámetros. Sin embargo, dichos problemas están caracterizados por la disponibilidad de grandes cantidades de datos. Algunos problemas, en cambio, a los que se enfrentan los analistas de inteligencia están caracterizados por la escasez de datos o en los que la decisión a tomar está afectada por un alto grado de incertidumbre. Pensemos, por ejemplo, en la localización de un objetivo relacionado con una célula terrorista del que sólo se conocen algunos datos biográficos y del que no se tienen ningún rastro digital o físico. O el análisis de una

operación de inversión en un sector estratégico español del que sólo se conocen ciertos datos de intermediación legal y financiera.

Las decisiones que los humanos consideramos racionales están basadas en inferencias consistentes con nuestra experiencia o con un conocimiento adquirido. Así, por ejemplo, es racional pensar que si acerco mi mano al fuego experimentaré calor. Y lo es pensar que el agua siempre fluye hacia el punto de menor altura. Ambas inferencias son basadas en la experiencia sobre fenómenos físicos y deterministas donde la incertidumbre no tiene ningún papel. Sin embargo, cuando los fenómenos que observamos cambian de una manera aleatoria y con múltiples estados, como la propagación de un fuego avivado por el viento, nos es mucho más difícil realizar tales inferencias. Entonces no podemos echar mano de la experiencia sino de nuestro conocimiento basado en modelos. Un modelo es una representación de la realidad sobre la que podemos hacer inferencias. En el ejemplo anterior un modelo puede ser las ecuaciones de combustión-conducción-radiación aplicadas a la materia vegetal del bosque. Pero también, una red neuronal que aprendiera a partir de una base de datos reales para entrenar cómo se propaga un incendio. El problema quizás vendría en que la red neuronal aprendió de un tipo de bosque o vegetación que no es aplicable a nuestro problema real. Pero esa es otra historia. Lo relevante aquí es un modelo debe permitirnos hacer predicciones sobre datos no observados (cualquier bosque) a partir de unos ciertos datos (un bosque de entrenamiento o el modelo físico de combustión aplicado a un punto de nuestro bosque problema). Un modelo puede ser muy simple o muy complejo. El frente del incendio lo podemos modelizar con una circunferencia o una curva más compleja que dependa de parámetros que nos informen del tipo de vegetación, altitud, el tipo de suelo, humedad, dirección y velocidad del viento, etc.

Si aplicamos el enfoque del “bosque de entrenamiento” la incertidumbre jugará un papel fundamental tanto en las características del bosque a quemar (datos no observados) como en el tipo de bosque que utilicemos para entrenar (modelización). La incertidumbre en la modelización puede ser detectada desde diferentes perspectivas: ruido en los datos observados, diseño de los parámetros o el patrón matemático a utilizar (regresión lineal, autómatas celulares, algoritmo genético, red neuronal, etc.).

La ventaja del enfoque probabilístico es que esos diferentes tipos de incertidumbre se pueden representar bajo los mismos axiomas y reglas. Cuando este enfoque es utilizado en el Aprendizaje Máquina se habla de Aprendizaje Bayesiano. Dicho aprendizaje consiste al transformar las distribuciones de probabilidad definidas antes de observar los datos en distribuciones condicionadas por dichas observaciones. Además de por su simplicidad conceptual el aprendizaje bayesiano permite su representación mediante grafos, lo que facilita una comprensión más

intuitiva y visual de los modelos. Otra característica es su flexibilidad en la composición de modelos más complejos para muchos datos a partir de modelos simples probabilísticos de pocos datos. Dicha arquitectura es más comprensible a escala humana que el acoplamiento de sistemas no lineales complejos (como las redes neurales recurrentes). Además, un modelo probabilístico siempre permite generar datos a partir del modelo. Dichos datos “imaginados” permiten comprender mejor cómo funciona la “mente” del modelo probabilístico y cómo aprende a partir de los datos (Ghahramani, Z., 2015).

En el campo de la inteligencia artificial, las leyes de la probabilidad permiten una representación lógica de la racionalidad, que también sigue el comportamiento humano y que se basa en la probabilidad de aceptar un postulado como cierto a partir de recompensas futuras (Teorema de Dutch-Book). Esta línea arroja algo de luz a la interpretabilidad humana de las decisiones tomadas por máquinas, uno de los principales retos éticos de la Inteligencia Artificial.

Sin embargo, esta aparente simplicidad del enfoque bayesiano no puede eludir el reto computacional inherente en el Aprendizaje Máquina que exige aproximaciones numéricas para problemas no resolubles de forma exacta. En el caso del enfoque bayesiano son, en general, problemas de integración resueltos mediante métodos de aproximación tipo Monte Carlo o cadenas de Markov. Una de las claves es lograr el equilibrio entre el coste computacional y la flexibilidad necesaria para mejorar la precisión de las inferencias. Tal flexibilidad se consigue a partir de numerosos parámetros (redes neuronales) o a través de métodos no paramétricos que crecen a en complejidad a partir de pocos parámetros (procesos Gaussianos, Dirichlet, ...).

3. Caso de uso

Consideremos un posible caso de estudio en inteligencia extraído de datos reales y la imaginación del autor y tratemos de modelizarla desde el enfoque probabilístico:

“Tras la retirada territorial del ISIS en Irak y Siria, la organización adoptará una estructura de red encubierta con potencial para actuar en Europa. Conservará, sin embargo, cierta organización central en torno a su aparato de inteligencia (الأمان), Emni en inglés). Dicha unidad podrá planificar nuevos ataques en suelo europeo si obtiene cierta cobertura y protección en un entorno seguro. Se barajan diferentes destinos para dicha unidad:

- *Opción A: los alrededores de Sabha (sudeste de Libia),*
- *Opción B: las montañas de Hamrin en las provincias de Diyala, Salah ab Din y Kirkuk (Irak);*

También existe la posibilidad de que tales movimientos no tengan lugar y la situación sea similar a la actual”

Supongamos que el cambio de emplazamiento de la unidad Emni puede ser monitorizada mediante el seguimiento de un objetivo clave para la logística. Además se tienen informadores en Sabha que

pueden corroborar la llegada de altos mandos de la inteligencia de ISIS. Finalmente, mediante imágenes via satélite es posible verificar la llegada de efectivos de seguridad vinculados al Emni en las montañas de Hamrim.

Si aplicamos el enfoque probabilístico a este caso de estudio deberíamos modelizar mediante las variables de predicción

Y_1 : “Cambio de Emplazamiento actual”;

Y_2 : ”Establecimiento en Sabha (Libia)”;

Y_3 : “Establecimiento en Hamrim (Irak)”

Análogamente, se considerarían variables de observación:

X_1 : “Confirmación por seguimiento de objetivo logístico”

X_2 : “Confirmación por informadores de Sabha”

X_3 : ”Confirmación por satélite de movimientos en Hamrim”

En este caso todas las variables consideradas (observadas o no) son binarias con valores “VERDADERO” o “FALSO”. Si representamos gráficamente a través de una red bayesiana las relaciones de inferencia y observación, la red quedaría representada en la siguiente figura:

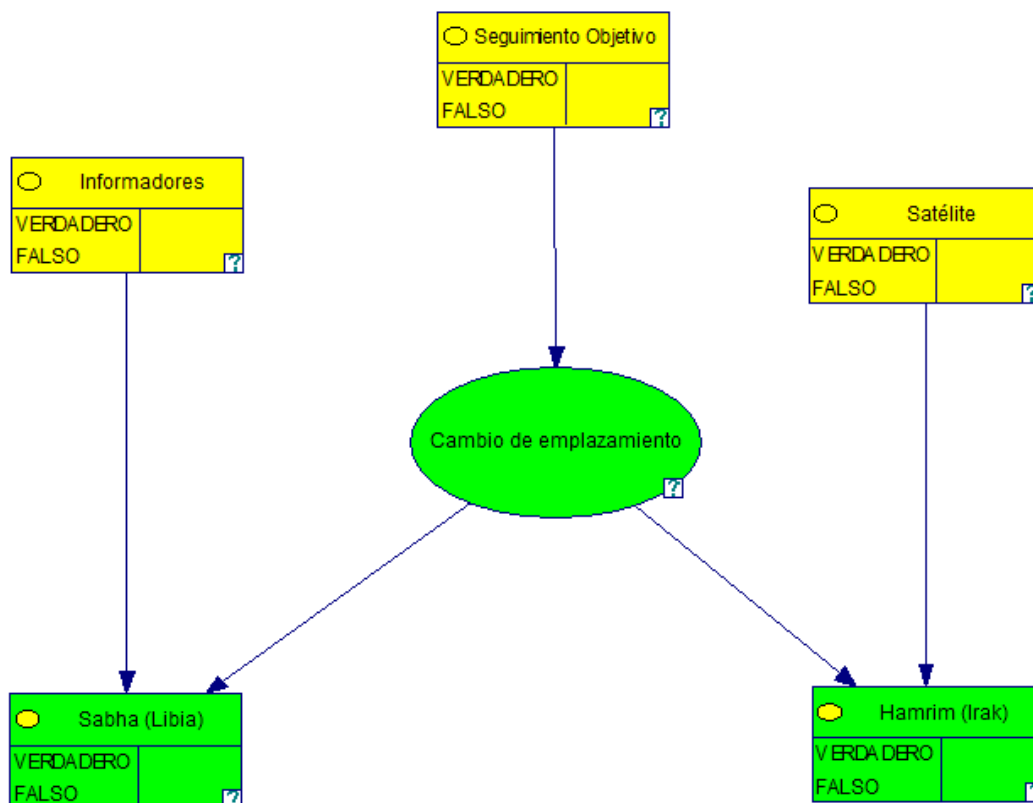


Figura 1. Red Bayesiana (desarrollada con el software GeNIe)

Cada inferencia sobre la incertidumbre de una variable “no observada” en función de las observaciones se puede expresar, a partir del Teorema de Bayes, según la igualdad:

$$\mathcal{P}(y|x) = \frac{\mathcal{P}(x, y)}{\mathcal{P}(x)} = \frac{\mathcal{P}(x|y)\mathcal{P}(y)}{\sum_{y \in Y} \mathcal{P}(x, y)}$$

A partir de juicio experto se podrían estimar las probabilidades $\mathcal{P}(x|y), \mathcal{P}(x, y), \mathcal{P}(y)$ de modo que siguiendo la evolución de las observaciones pudiéramos inferir la probabilidad de los sucesos inciertos. En este caso, si existe o no desplazamiento de la unidad EMNI y hacia qué lugar. Supongamos que sólo tenemos evidencia de ciertos movimientos en las montañas de Hamrim a través del satélite y queremos averiguar la probabilidad de que se vaya a producir el cambio de emplazamiento. En tal caso (a partir de valores iniciales asignados) el resultado es de un 55% de que no se haya dado tal cambio de emplazamiento y de un 38% de que se haya dado hacia las montañas de Hamrim (ver Figura 2).

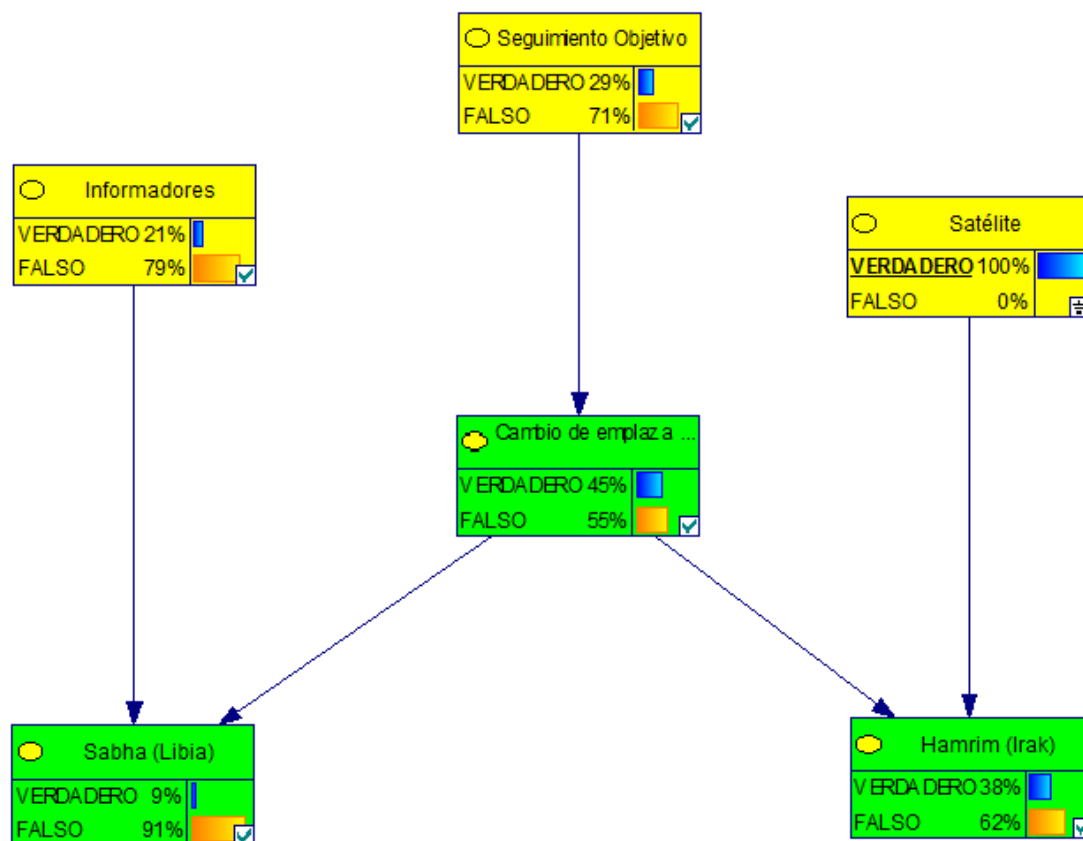


Figura 2. Propagación de evidencia en red bayesiana con software GeNIe

De igual modo que hemos aplicado el enfoque probabilístico a partir de observaciones y juicio experto, el aprendizaje automático permitiría que la red aprendiera a partir de datos de entrenamiento o simulaciones y a partir de ello construir diferentes modelos al propuesto. En este caso:

$$P(\theta|\mathcal{D}, m) = \frac{P(\mathcal{D}|\theta, m)}{P(\mathcal{D}, m)}$$

donde m es el modelo a estudiar dependiente de una serie de parámetros θ y \mathcal{D} es el conjunto de datos de entrenamiento. Por ejemplo, en el caso anterior \mathcal{D} podría representar un conjunto de señales (HUMINT, SIGINT, OSINT...) que puedan ser utilizadas para inferir patrones de movimientos en células terroristas. El modelo m podría ser entrenado a partir de diferentes correlaciones sobre el tiempo y el espacio a partir de los parámetros θ . El proceso de Aprendizaje Máquina consistiría en la transformación del conocimiento adquirido acerca de los parámetros $P(\theta|m)$ a partir de los datos \mathcal{D} en la inferencia posterior sobre los diferentes parámetros $P(\theta|\mathcal{D}, m)$. Este conocimiento adquirido (y artificial) se convierte ahora en el primigenio para ser

usado en datos futuros. Finalmente, se pueden hacer predicciones de nuevos datos test no observados a partir de:

$$\mathcal{P}(\mathcal{D}_{test}|\mathcal{D}, m) = \int \mathcal{P}(\mathcal{D}_{test}|\theta, \mathcal{D}, m)\mathcal{P}(\theta|\mathcal{D}, m) d\theta$$

Ello permitiría hacer análisis de sensibilidad del modelo o evaluar la calidad de los indicadores utilizados.

4. Conclusiones

El enfoque probabilístico aplicado a la gestión de la incertidumbre en el análisis de inteligencia ofrece una perspectiva a medio camino entre la inteligencia humana y la producida por la máquina. Los enfoques probabilísticos aplicados en diferentes ámbitos (inteligencia artificial, aprendizaje automático, programación probabilística, apoyo a la decisión...) auguran un ámbito de investigación muy prometedor para el analista en el descubrimiento de nuevos modelos interpretables y personalizables por el analista. Dicho ámbito permite abordar problemas con pocos datos o en los que la incertidumbre juega un papel fundamental. Abrazar la incertidumbre y el riesgo del cambio en nuestro mundo es el único camino para evitar la parálisis ante la perspectiva del desconocimiento del futuro. De ello dependerá el éxito del trabajo realizada por la futura comunidad de inteligencia.

Referencias

Ghahramani, Z. (2015) Probabilistic machine learning and artificial intelligence. *Nature*, 521:452-459.

GeNIe Modeler USER MANUAL Version 2.3.R4, Built on 2/27/2019 BayesFusion, LLC. Disponible en <https://support.bayesfusion.com/docs/> para uso académico.