

(08-001) - Dynamic risk assessment in complex projects

Alvarez-Espada, Juan-Manuel ¹

¹ Dpto. Ciencias de la Computación e Inteligencia Artificial. Escuela Ingeniería Técnica Superior de Ingeniería Informática. UNIVERSIDAD DE SEVILLA

The risk study, conducted by a project manager, especially in predictive approaches and depending on their experience, involves a thorough examination of risks in the tasks outlined in the Work Breakdown Structure (WBS). Risk assessment is based on correlating the likelihood of the risk occurring with the severity of its damage or benefit.

However, in complex projects, project managers face broad, diverse, and often unknown risks. Technical aspects under development, involvement of different technologies, some of them innovative, multiple cultures, numerous stakeholders, etc., may fall outside the scope of a conventional risk assessment by the project manager.

Probabilistic analysis has traditionally formed the basis for risk evaluation in conventional or complicated projects, which were the prevalent approaches until recently. Nevertheless, new approaches for managing complex projects require a different risk assessment: Bayesian networks or fuzzy cognitive maps are two ways to evaluate risks, but not the only ones.

Keywords: Project management; Complexity; Risks; Bayesian networks; Fuzzy Cognitive maps.

Evaluación dinámica de riesgos en proyectos complejos.

El estudio de los riesgos, realizado por un director de proyecto, sobre todo en enfoques predictivos, y dependiendo de su experiencia, conlleva un sesudo estudio de riesgos en las tareas obtenidas en la estructura de desglose EDT. La valoración del riesgo se basa en relacionar la probabilidad de que ocurra el riesgo con la severidad de su daño o de su beneficio.

Sin embargo, cuando se tienen proyectos de carácter complejo, los riesgos a los que se enfrenta un director de proyecto, son amplios, diversos y, casi siempre, desconocidos. Aspectos técnicos que puedan estar en desarrollo, o que involucren diferentes tecnologías, algunas de ellas novedosas, múltiples culturas, gran cantidad de interesados, etc.... que pueden quedar fuera del ámbito de una evaluación convencional de riesgos por parte del director de proyecto.

El análisis probabilístico ha proporcionado, en la gestión de riesgos, la base para la evaluación de estos en proyectos convencionales o complicados, que eran hasta fechas recientes los enfoques que se utilizaban. Sin embargo, los nuevos enfoques para gestionar proyectos complejos requieren evaluar riesgos de forma diferente: redes bayesianas o mapas cognitivos difusos son dos maneras de evaluar riesgos, pero no las únicas.

Palabras clave: Gestión de proyectos; Complejidad; Riesgos; Redes bayesianas; Mapas cognitivos difusos

Correspondencia: Juan Manuel Álvarez Espada, jaespada@us.es



©2024 by the authors. Licensee AEIPRO, Spain. This article is licensed under a Creative Commons Attribution-NonCommercial-NoDerivatives 4.0 International License (<https://creativecommons.org/licenses/by-nc-nd/4.0/>).

1. Introducción

La Estructura de Desglose del Trabajo (EDT) y la gestión de riesgos están estrechamente interrelacionadas, especialmente en proyectos complejos. La EDT descompone el proyecto en componentes detallados, facilitando la identificación y análisis de riesgos específicos. Esto permite una evaluación precisa y la planificación de respuestas adecuadas, detectando puntos críticos que requieren mayor atención y recursos. La criticidad en sistemas complejos a menudo reside en puntos de cambio significativos que deberían detectarse.

Los riesgos, sobre todo aquellos que pueden tener un efecto negativo sobre uno o más objetivos del proyecto, pueden ser considerados como atributos de la incertidumbre sobre los sistemas complejos (Pich et al., 2002).

Respecto a los riesgos, uno de sus principales problemas es su identificación, y también, la evaluación de estos. Se exponen diferentes metodologías, dando mayor importancia al sistema de evaluación "Bow-Tie" y a la aplicación de redes bayesianas discretas en su análisis para encontrar la probabilidad de ocurrencia.

Se desarrolla a continuación un programa en Python del análisis de un "Bow-Tie", donde se presentarán los resultados obtenidos al aplicarlo a una pequeña red bayesiana que lo modela.

Por último, se verá como la aplicación de redes bayesianas a los análisis de "Bow-Tie" no son suficientes para la evaluación de riesgos complejos y se verá como la complejidad lo dificulta.

2. Objetivos

Son dos los objetivos del presente trabajo: el primero, analizar la evaluación de riesgos en sistemas complejos, el método "Bow-Tie" y su modelización mediante redes bayesianas.

El segundo objetivo es realizar un programa informático en lenguaje Python analizando los resultados obtenidos.

3. Metodología

La metodología seguida en esta comunicación ha sido la revisión del concepto de riesgo en proyectos complejos, la enumeración de diferentes metodologías y el análisis del método "Bow-Tie".

Dicho análisis se ha estructurado en varias fases. En la primera, se repasan individualmente los conceptos de árboles de fallos (Fault Tree, en inglés) y de árboles de sucesos o eventos (Event Tree, en inglés) para luego modelar dichos conceptos mediante redes bayesianas.

En una segunda fase se aplica la modelación creada por la red bayesiana a un formato de programación mediante el lenguaje Python donde se analizan brevemente los resultados obtenidos.

Por último, se intenta encontrar algunas soluciones a los problemas planteados por la modelización de los riesgos complejos mediante redes bayesianas aportándose varios conceptos como el de las redes bayesianas dinámicas, los modelos ocultos de Markov y la complejidad.

4. Riesgos en proyectos complejos

Una de las características fundamentales de los sistemas complejos y, por ende, de los proyectos complejos, es la necesidad de poder actuar a pesar de la incertidumbre, la volatilidad, la ambigüedad y la complejidad que se desprenden de su propia forma de ser.

Para ello, la mejor garantía de actuación es poder adaptar la gestión de dichos proyectos y su resultado al medio ambiente en cuestión.

La adaptación implica comprender los objetivos de los interesados y el entorno operativo del proyecto complejo, aplicando, cuando sea necesario, un enfoque ágil o híbrido (Álvarez-Espada et al., 2022) para entregar valor lo antes posible, optimizándolo y adaptándolo al cambio. Para también, cuando sea preciso, escoger un enfoque predictivo para tener un control de costes y de planificación a través de herramientas tradicionales, estableciendo un análisis causa-efecto en aquellas partes donde el proyecto no sea complejo. En definitiva, aplicar un sistema de gestión híbrida adaptativa que explote lo mejor de cada tipo de enfoque (Arellano et al., 2016)

Si se considera cuál es la gran diferencia entre un proyecto convencional y un proyecto complejo es que el riesgo asociado a la complejidad aumenta significativamente (Kerzner & Belack, 2010).

Existen diferentes modelos de gestión de proyectos complejos que integran el riesgo asociado a varios atributos del proyecto, analizados desde un punto específico o desde un punto de vista general. Así, Hass asocia el riesgo con aspectos específicos del proyecto (Hass, 2009): coste, duración, claridad sobre los entregables a realizar, volatilidad en los requisitos, etc. Sin embargo, otros autores asocian el riesgo con elementos generales, ya sean internos o externos del proyecto. Así, Remington / Pollack en (Remington & Pollack, 2016) considera que los riesgos están asociados a: aspectos técnicos en el desarrollo de soluciones, aspectos direccionales de la organización, aspectos estructurales de los equipos de trabajo y estructura y adaptabilidad organizacional.

Cualquiera que sea el ámbito de asociación, es claro que hay diferencias de gestión en cuanto al manejo de estos. Así, en los proyectos convencionales, la gestión de riesgos es un proceso que se limita a identificar, analizar y administrar riesgos que, en la mayoría de los casos, pueden considerarse previsibles, y en aquellos casos en los que estos se conviertan en imprevistos, se abordan mediante reservas de contingencia, perfectamente estudiadas (Culp, 2002).

Sin embargo, en proyectos complejos, los riesgos a los que se enfrenta un director de proyectos son diversos, extensos, y en su mayoría desconocidos. Muchos de estos riesgos pueden derivar de aspectos en los que tanto los directores como los miembros de sus equipos tienen escasa o nula experiencia. Ejemplos de ello puede ser proyectos con particularidades técnicas en desarrollo, inclusiones de nuevas tecnologías, desafíos en la comunicación y comprensión de normas interculturales, extenso número de interesados con necesidades, a veces, contrapuestas, o intereses políticos. Estos factores pueden requerir enfoques no previstos inicialmente. (Béatrix, 2018).

Existe, adicionalmente, otro condicionante en cuanto a la gestión de riesgos en proyectos convencionales, y es que, de forma general, la interdependencia entre los riesgos que pueden darse suele ser pequeña. Sin embargo, esto no es lo normal en los proyectos complejos, dado que muchos riesgos pueden aparecer durante el ciclo de vida del proyecto debido al carácter emergente y de autoorganización de los proyectos complejos, de tal forma que si la dirección del proyecto no detecta estos riesgos se puede dar el caso que, a medida que pasa el tiempo sin ser detectados, puedan interrelacionarse y aumentar su dependencia, evitando una terminación exitosa del proyecto (Rahman, 2018).

Quizás, el problema más importante a la hora de tratar los riesgos sea su evaluación completa dadas las posibles interdependencias que puedan provocarse.

4.1. Evaluando riesgos complejos.

En todas las metodologías de gestión de proyectos convencionales consultadas: PMI (PMI, 2017, 2023), PM2 (Kourounakis & Maraslis, 2017) o PRINCE2 (Vila Grau & Capuz Rizo, 2020), la revisión de los requisitos en la fase de planificación, la experiencia del equipo de gestión de proyectos y las lecciones aprendidas han aportado la base para la evaluación de los riesgos en los proyectos convencionales o predictivos.

Sin embargo, en proyectos complejos, suelen utilizarse metodologías no bien estudiadas, y particularizadas según el sector al que esté adscrito el proyecto. Sirva como ejemplo la utilización de una matriz VUCA (volatilidad, incertidumbre, complejidad y ambigüedad) donde se reflejan en cada cuadrante los riesgos adscritos a cada característica para su clasificación (Szpitter & Sadkowska, 2016).

Existen numerosas metodologías para poder encontrar riesgos complejos: Combinación de matrices VUCA con cuestionarios a expertos (Fridgeirsson et al., 2021); realización de "Focus Groups" (Garrett, 2005); estudio de variabilidad de riesgos mediante aplicación de probabilidad directa modelándose mediante funciones de distribución (variables discretas) o funciones de densidad (variables continuas) (Dubois, 2010); concepción de los riesgos mediante valoraciones cualitativas y cuantitativas combinadas (Willumsen et al., 2019), o bien mediante diferenciación de riesgos según su complejidad, dándose estos últimos a especialistas en riesgos para su gestión (Mitchell, 2005).

Sin embargo, del repaso realizado a las distintas metodologías, se denota una incapacidad para poder analizar o establecer métodos de evaluación de riesgos autoorganizados o emergentes (riesgos conocidos – consecuencias desconocidas o riesgos desconocidos – consecuencias desconocidas).

Para poder detectar "Riesgos desconocidos – Consecuencias desconocidas" parece, también, básico una cultura de gestión de riesgos en proyectos bien asentada. Tener una visión de gestión de riesgos, desde un punto de vista organizacional, abona esta tesis. Sobre todo, en la revisión de posibles alertas tempranas, con indicadores apropiados para ello (Paté-Cornell, 2012). Sin embargo, tampoco se puede garantizar al máximo el reconocimiento de posibles riesgos y sus interrelaciones, dado que las mismas se estudian por medio de datos históricos, árboles causales y modelados físicos establecidos en lecciones aprendidas, y no se tiene en cuenta que algunos sistemas sometidos a estrés pueden evolucionar hacia la posibilidad de registrar nuevos riesgos o nuevas relaciones entre los riesgos existentes en sus procesos. Estas circunstancias no suelen tenerse en cuenta en las planificaciones (Aven, 2015; Derbyshire & Wright, 2014).

Para establecer la posibilidad de poder evaluar dinámicamente riesgos, una de las herramientas más potentes es la sistematización de nuevos riesgos a raíz de alertas tempranas en procesos de proyecto o industriales que puede utilizarse con los debidos cambios, a la gestión de riesgos en proyectos complejos. La metodología se denomina DyPASI (Procedimiento dinámico para evaluación de escenarios atípicos) y se basa en la combinación de análisis "Bow-Tie", recuperación de riesgos mediante herramientas de búsqueda inteligentes, priorización, evaluación de escenarios de riesgo, evaluación de barreras de seguridad y seguimiento de la evaluación de riesgos (Paltrinieri et al., 2013).

La base de este proceso, quizás algo complicado, es la evaluación "Bow-Tie". Se analiza a continuación.

4.2. Una "Pajarita" acude en nuestro auxilio.

En (Khakzad et al., 2012), se propone un enfoque combinando los árboles de posibles riesgos con los árboles de consecuencias que pueden producirse si se activa el llamado, por los autores, riesgo superior, como se verá a continuación. En (Khan et al., 2016), se amplía este

enfoque con la gestión integral tanto de las causas como de las consecuencias. Se trata del modelo “Bow-Tie” o de “pajarita” que se describe a continuación.

El modelo en cuestión consta de una zona central donde se representa el riesgo superior, que puede ser considerado también como el riesgo del sistema, objeto de estudio. A su izquierda se introduce un árbol de riesgos enlazados mediante puertas lógicas que representarán si los riesgos interactúan, son interdependientes o actúan en cascada. A la derecha del riesgo superior se coloca el árbol de sucesos o eventos que puede causar la aparición de dicho riesgo. La representación gráfica de este modelo se muestra a continuación en la **figura 1**:

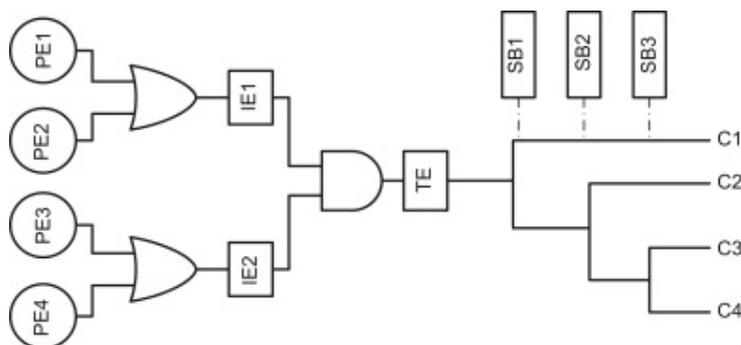


Figura 1. Modelo Bow-Tie (Fuente: Khakzad et al, 2012).

A la izquierda, en el **árbol de riesgos (AR)**, PE, IE y TE son los riesgos principales, intermedios y superior (riesgo sistémico, RS), objeto del estudio. A la derecha, en el **árbol de sucesos o eventos (AE)** están SB y C que significan barreras de seguridad y consecuencias. Mediante este modelo se representa totalmente el riesgo superior a analizar, los riesgos que pueden desencadenarlo, actuando como alertas tempranas, y las consecuencias. Una vez establecido el modelo, debe poder actualizarse a medida que se observan nuevos datos constituyendo un ente dinámico. Es necesario, por tanto, plantear los riesgos como una red compleja para poder analizarlos, sobre todo a nivel de riesgo sistémico.

Especial incidencia, en el árbol de sucesos, a la colocación de las diferentes consecuencias (Ci) que pueden producirse a raíz de la materialización del riesgo, y cuáles serán las circunstancias que deberán ser consideradas. Habitualmente, se colocan en orden cronológico esperado, con la posibilidad de repercutir un valor de probabilidad de materialización. La posibilidad de que se produzca una determinada consecuencia está definida por la probabilidad de éxito o fallo de las barreras de seguridad que se impongan en el riesgo considerado (Bestratén Belloví, 1991). Ver un ejemplo en la **figura 2**:

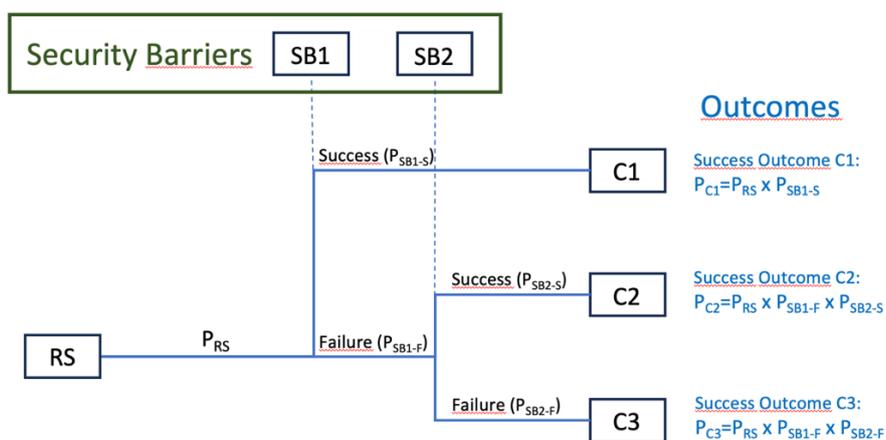


Figura 2. Ejemplo de árbol de sucesos (Fuente: Autor).

Cada bifurcación en el árbol de sucesos proviene de que la barrera de seguridad planteada tenga éxito o no. En este caso, un sentido ascendente en la bifurcación, indica que la barrera planteada ha tenido éxito. Un sentido descendente en la bifurcación, indica que la barrera no ha tenido éxito. Cada barrera tiene dos probabilidades asignadas, una probabilidad de éxito, y una probabilidad de fallo. La consecuencia final de la materialización del riesgo será la probabilidad total de su ocurrencia, que vendrá definida por las operaciones aritméticas de las bifurcaciones.

Así en el ejemplo de la **figura 2**, la probabilidad de que ocurra la consecuencia **C2** debido a la probabilidad de materialización del riesgo **RS** (Riesgo superior o sistémico), será igual a la probabilidad P_{RS} , por la probabilidad de fallo de la barrera de seguridad SB1, P_{SB1-F} , y por la probabilidad de éxito de la barrera de seguridad SB2, P_{SB2-F} . De igual manera, la probabilidad de que ocurra la consecuencia **C3** debido a la probabilidad de materialización del riesgo **RS** (Riesgo superior o sistémico), será igual a la probabilidad P_{RS} , por la probabilidad de fallo de la barrera de seguridad SB1, P_{SB1-F} , y por la probabilidad de fallo de la barrera de seguridad SB2, P_{SB2-F} .

Por tanto, queda definido, mediante probabilidades, las consecuencias que se pueden tener si un fallo se produce con las barreras planteadas.

La aplicación de un análisis exhaustivo de los riesgos, y sus consecuencias mediante la herramienta “Bow-Tie” (B-T) es bastante eficaz para poder determinar todos los riesgos que se pueden presentar, así como el denominado riesgo sistémico.

Sin embargo, sería manifiestamente mejorable, poder analizar un modelo B-T no solamente interconectado y con probabilidades parciales condicionadas, sino que podamos interactuar con el modelo, sus eventos y sus consecuencias. Las redes bayesianas son una gran ayuda para todo ello.

5. Modelizando las redes bayesianas.

Una red bayesiana (RB) es un modelo gráfico probabilístico que permite descubrir distribuciones conjuntas complejas (modelos, por ejemplo) a partir de distribuciones condicionales locales simples. Es la forma más básica y robusta de obtener conocimientos en incertidumbre.

La representación más habitual de una red bayesiana es la de un grafo acíclico dirigido (GAD) en el que cada nodo está comentado con información probabilística cuantitativa siendo su especificación simple la siguiente:

- Conjunto de variables aleatorias, X_i que forman los nodos de red. Pueden ser discretas o continuas.
- Conjunto de enlaces dirigidos que conectan pares de nodos. Se dice que X es padre de Y si hay una flecha que va del nodo X al nodo Y.
- Cada nodo X_i tiene una distribución / densidad de probabilidad condicionada $P(X_i | \text{Padres } X_i)$ que cuantifica el efecto de los padres del nodo.

En la de toma de decisiones en ambiente de incertidumbre, un tipo de red bayesiana que puede utilizarse es la red causal donde el requisito esencial es que la relación establecida mediante enlaces exprese que la relación sea causal y no estrictamente condicional, formalizando la intervención de factores que determinan un resultado.

El enfoque de RB es muy útil para el análisis de modelos B-T debido a (Teimourikia, 2017):

- La creación de un *modelo probabilístico* de eventos y variables perfectamente trasplantable a un programa de software, lo que facilita la evaluación de riesgos al considerar la incertidumbre y la variabilidad en los datos.

- Consigue una *actualización cuasi dinámica* al poder actualizar las probabilidades en tiempo real de forma, en este caso manual (se verá en un punto posterior de este mismo trabajo), que se pueda identificar y evaluar dinámicamente los riesgos.
- Representa las causas y efectos entre los diferentes eventos y variables.
- Puede *analizar escenarios* y la propagación de las probabilidades a lo largo de la red bayesiana y obtener por inferencia la probabilidad de poder darse un riesgo sistémico.

La transformación de un modelo de B-T a RB sigue las recomendaciones indicadas en (Khakzad et al., 2013) tal como se representa en la **figura 3**:

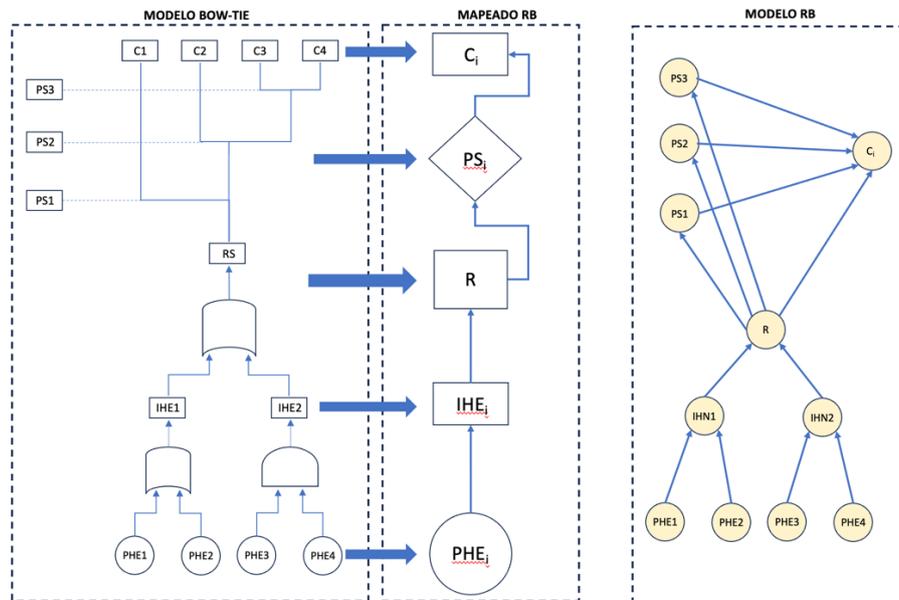


Figura 3. Transformación de un modelo B-T a RB (Fuente: Autor)

A continuación, se va a realizar un ejemplo de un análisis mediante software utilizando el lenguaje de programación Python.

6. Un ejemplo en Python.

Para el ejemplo que se va a desarrollar en este punto se ha considerado que el B-T que se va a modelar está compuesto por cuatro riesgos principales: **PH11**; **PH12**; **PH21**, y **PH22**. Estos serán los riesgos observables de entrada. Dos riesgos intermedios: **EH1** y **EH2**, estos serán riesgos ocultos y un riesgo superior, sistémico, y observable de salida, **RS**. Este RS será el punto de unión con el árbol de sucesos donde tendremos tres consecuencias: **C1**, **C2** y **C3**. Se tendrá dos barreras de seguridad: **S1** y **S2**, observables de entrada, que establecerán las bifurcaciones necesarias para que puedan darse cada una de las consecuencias C_i , observables de salida.

Respecto al esquema representado en la **figura 1**, y para facilitar los resultados se han realizado unas leves modificaciones que consisten, en el árbol de riesgos, considerar las puertas lógicas como los riesgos resultados de las entradas y en el árbol de sucesos considerar las probabilidades de las barreras de seguridad o bien 0 o bien 1 para el caso falso o verdadero, según el caso. El modelo quedaría establecido tal como se representa en la **figura 4**:

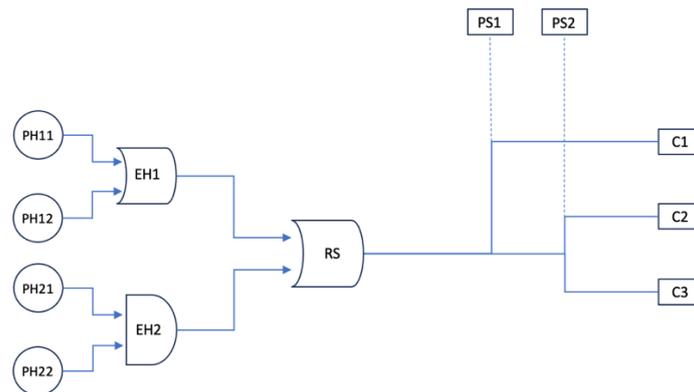


Figura 4. Red B-T a modelar en Python (Fuente: Autor)

6.1. Un entorno para empezar.

El desarrollo de la red bayesiana se realizará en Python. Python es un lenguaje de programación interpretado, de tipado dinámico y multiparadigma. Tiene una amplia biblioteca estándar y dispone de paquetes de terceros que lo hacen muy versátil, permitiendo desarrollar desde aplicaciones web hasta procesamiento de datos complejos y de inteligencia artificial. Se integra bien con otros lenguajes pudiendo ser combinado. La versión utilizada en este artículo ha sido la 3.11.6

El IDE de programación utilizado fue **Anaconda** (v. 2.5.3) y el entorno fue **JupyterLab** (v.4.0.13). El paquete utilizado de gestión de redes bayesianas fue **pgmpy**¹. Este paquete es una implementación de Python para redes bayesianas que implementa tipos abstractos de datos y algunos algoritmos de aprendizaje de estructuras, estimación de parámetros e inferencias exacta, aproximada y causal. La manera más fácil de instalar **pgmpy** es utilizar el hiperpaquete **bap3.yml**² donde se incluyen los elementos necesarios evitando que haya problemas de compatibilidad cuando se haga la importación y utilización de las librerías de **pgmpy**.

Por último, hay que indicar que, para este desarrollo, aunque podría haberse utilizado redes causales, por comprensión y comodidad se ha utilizado tipos de datos discretos e inferencia probabilística y no causal.

6.2. Desarrollando la red bayesiana.

En este apartado se desarrolla el programa de software. Dado lo limitado del espacio, se pondrán pantallas capturadas de las operaciones principales. Durante el congreso, aquellos congresistas interesados, tendrán acceso al programa completo a través de la organización.

Lo primero es indicar que significan algunas definiciones de probabilidad que se van a observar. Así:

- Cuando se vea, para una determinada variable de riesgo, por ejemplo, **PH11(0)** = 0,9 quiere decir que la probabilidad de que el riesgo PH11 sea **falso** será del 90%.
- Cuando, por el contrario, **PH11(1)** = 0,1 quiere decir que la probabilidad de que el riesgo PH11 sea **verdadero** será del 10%.
- Es evidente que la probabilidad total de **PH11** será **PH11(0) + PH11(1) = 1**.

Las probabilidades utilizadas en este artículo, para los riesgos observables de entrada y de las barreras de seguridad, son sintéticas y no están basados en la realidad. Las probabilidades

¹ <https://pgmpy.org/index.html> (visitado el 8/4/24)

² <https://github.com/alocavodia/BAP3> (visitado el 2/12/23)

de las puertas lógicas que darán lugar a los riesgos intermedios y al riesgo sistémico RS son valores de probabilidad comunes. De todas formas, para los objetivos de este artículo no es determinante que las probabilidades sean sintéticas o reales.

Paso 1. Importación de librerías y creación de la estructura del modelo.

Lo primero a realizar es la importación de las librerías necesarias para la creación de la red y su funcionamiento, ver **figura 5**:

```
from pgmpy.models import BayesianNetwork
from pgmpy.factors.discrete import TabularCPD
import matplotlib.pyplot as plt
import networkx as nx

# Definir la estructura del modelo de red bayesiana
model = BayesianNetwork([('PH11', 'EH1'),
                        ('PH12', 'EH1'),
                        ('PH21', 'EH2'),
                        ('PH22', 'EH2'),
                        ('EH1', 'RS'),
                        ('EH2', 'RS'),
                        ('RS', 'S1'),
                        ('S1', 'S2'),
                        ('S1', 'C1'),
                        ('S2', 'C2'),
                        ('S2', 'C3'),])
```

Figura 5. Definición de la estructura del modelo (Fuente: Autor)

La estructura de la RB creada por BayesianNetwork() es la que viene reflejada en la **figura 4**.

Paso 2. Definir las probabilidades de los riesgos observables.

Este es el paso más complicado y largo del proceso dado que se deben colocar las probabilidades más adecuadas, bien por la experiencia o bien por la opinión de expertos. Un pequeño ejemplo viene definido en la **figura 6**.

```
# Definir las probabilidades para las causas
cpd_ph11 = TabularCPD(variable='PH11', variable_card=2, values=[[0.2], [0.8]])
cpd_ph12 = TabularCPD(variable='PH12', variable_card=2, values=[[0.8], [0.2]])
cpd_ph21 = TabularCPD(variable='PH21', variable_card=2, values=[[0.2], [0.8]])
cpd_ph22 = TabularCPD(variable='PH22', variable_card=2, values=[[0.2], [0.8]])

# Definir la compuerta lógica OR para EH1
cpd_eh1 = TabularCPD(variable='EH1', variable_card=2,
                    values=[[0.9, 0.1, 0.1, 0.1],
                          [0.1, 0.9, 0.9, 0.9]],
                    evidence=['PH11', 'PH12'],
                    evidence_card=[2, 2])
```

Figura 6. Ejemplo de definición de probabilidades (Fuente: Autor)

Se utiliza la función **TabularCPD ()**, para definir las probabilidades. En este caso, los riesgos observables **PH11**, **PH12**, **PH21** y **PH22** tienen 2 posibles estados definidos en **'values'**. El primero para el estado 'falso' y el segundo para el estado 'verdadero'.

En la definición de la puerta lógica OR establecemos **EH1** con dos estados y dos entradas **PH11** y **PH12**, que a su vez tiene cada una dos estados. Por tanto, la salida tendrá $2^3 = 8$ estados. Las probabilidades definidas en **'values'** se entienden mejor en la **figura 7**, dada por el programa:

PH11	PH11(0)	PH11(0)	PH11(1)	PH11(1)
PH12	PH12(0)	PH12(1)	PH12(0)	PH12(1)
EH1(0)	0.9	0.1	0.1	0.1
EH1(1)	0.1	0.9	0.9	0.9

Figura 7. Tabla de prioridades del riesgo intermedio EH1 (Fuente: Autor)

De esta manera estableceremos las probabilidades de todas las variables (riesgos) y consecuencias del modelo. Una vez realizado este paso, se está en condiciones de agregar las CPD (Conditional Probability Distribution) al modelo.

Paso 3. Agregar las CPD al modelo.

Agregar las CPDs al modelo

```
model.add_cpds(cpd_ph11, cpd_ph12, cpd_ph21, cpd_ph22, cpd_eh1, cpd_eh2, cpd_rs,
               cpd_s1, cpd_s2, cpd_c1, cpd_c2, cpd_c3)
```

Figura 8. Agregación de las CPD a la estructura del modelo. (Fuente: Autor).

Con esta instrucción se agrega el modelo de probabilidades a la estructura creada en el paso 1.

Paso 4. Verificar la validez del modelo.

Una vez que se han unido la estructura y las probabilidades de los nodos de la RB, se comprueba que no hay error en el modelo. En este caso, el resultado 'True' nos confirma que el modelo es correcto sintácticamente.

```
# Verificar la validez del modelo
print(model.check_model())
```

True

Figura 9. Comprobación de la validez sintáctica del modelo. (Fuente: Autor)

A partir de este momento, el modelo creado es capaz de inferir, es decir, obtener la probabilidad de ciertas variables a posteriori, a partir, de un conjunto de variables, riesgos, observados a priori. En este caso, vamos a inferir mediante método de aproximación por eliminación de variables, la probabilidad de que pueda darse el riesgo sistémico **RS** a partir de las probabilidades de los riesgos **PH11**, **PH12**, **PH21** y **PH22**. Para ello ejecutamos las siguientes instrucciones:

```
from pgmpy.inference import VariableElimination
infer = VariableElimination(model)
g_dist = infer.query(['RS'])
print(g_dist)
```

RS	phi(RS)
RS(0)	0.3639
RS(1)	0.6361

Figura 10. Proceso de inferencia sobre RS (Fuente: Autor)

En este caso, se obtiene que existe un 63,61% de que pueda darse un riesgo sistémico.

Para el árbol de sucesos, las probabilidades de las barreras **S1** y **S2** se han considerado 1 cuando son verdaderas y 0 cuando son falsas. Así la consecuencia **C1** será cierta si **RS** tiene probabilidad de ser cierta y **S1** tiene probabilidad 1. En este caso, si **C1** tiene probabilidad de ser cierta, **C2** y **C3** deberían tener probabilidades de ser falsas. Si se realizan, con los datos de partida, inferencias sobre **C1**, **C2** y **C3** se obtienen los siguientes resultados:

C1	phi(C1)	C2	phi(C2)	C3	phi(C3)
C1(0)	0.3639	C2(0)	0.6089	C3(0)	0.6089
C1(1)	0.6361	C2(1)	0.3911	C3(1)	0.3911

Figura 11. Probabilidades inferidas en C1, C2 y C3 (Fuente: Autor)

El resultado implica que el modelo creado es semánticamente correcto tal como se había considerado. En este caso al tener una mayor probabilidad de producirse **RS** conlleva a que se activará la consecuencia **C1** según las prioridades inducidas en las barreras **S1** y **S2**.

6.3. Refinando el modelo: Avanzando en el aprendizaje.

El aprendizaje automático es un campo de la Inteligencia Artificial enfocado en el aprendizaje de patrones y predicciones a partir de datos. El aprendizaje puede establecerse sobre los parámetros y/o sobre la estructura.

Sobre los parámetros, el aprendizaje se puede realizar con datos completos, es decir, se tiene valores para cada variable del modelo de probabilidad o sobre datos ocultos o latentes, como puede ser el caso mostrado en este artículo, donde podemos saber los valores que van a tener los riesgos principales **PH11**, **PH12**, **PH21** y **PH22**, pero no sobre los riesgos intermedios **EH1** y **EH2** generados manualmente en el programa. Se utilizará el modelo de aprendizaje de estimación de probabilidad máxima o MLE para datos ocultos.

Lo primero que se debe de realizar es generar datos, en este caso, vamos a generar 1.000.000 de datos aleatorios teniendo en cuenta las tablas de probabilidad de los riesgos:

```
# PASO 1: GENERAR ALGUNOS DATOS.
# Use the model to generate data from it.

from pgmpy.utils import get_example_model
from pgmpy.sampling import BayesianModelSampling

samples = BayesianModelSampling(model).forward_sample(size=int(1e6))
samples.head()
```

Generating for node: C3: 100% ██████████ 12/12 [00:03<00:00, 3.08it/s]

Figura 12. Generación de 1.000.000 de datos para todos los riesgos (Fuente: Autor)

Y lo segundo es lanzar el modelo de aprendizaje sobre cuál va a ser el valor aprendido por el modelo para el riesgo sistémico **RS**

```
from pgmpy.estimate import MaximumLikelihoodEstimator

mle = MaximumLikelihoodEstimator(model=model_struct, data=samples)

# Estimating the CPD for a single node.
print(mle.estimate_cpd(node="RS"))

# Estimating CPDs for all the nodes in the model
mle.get_parameters()::10 # Show just the first 10 CPDs in the output
```

EH1	EH1(0)	...	EH1(1)
EH2	EH2(0)	...	EH2(1)
RS(0)	0.9004074390484327	...	0.09935498708928776
RS(1)	0.09959256095156732	...	0.9006450129107122

Figura 13. Aprendizaje de parámetros mediante el modelo MLE (Fuente: Autor)

Vemos que el proceso de aprendizaje ha dictaminado que, con la estructura dada y las tablas de probabilidad dadas y aprendidas, cuando se den los riesgos intermedios **EH1 y EH2**, la probabilidad de que se dé **RS** será del 90% aproximadamente. Lo cual, por lógica, es correcto.

Sobre la estructura de una RB también puede realizarse un proceso de aprendizaje. Podría ocurrir, en algunos casos, que el modelo causal representado no estuviera disponible en su totalidad o fuera objeto de controversia. Por lo tanto, pudiera ser interesante que a partir de los datos se estableciera la estructura.

La librería pgmpy utiliza el famoso algoritmo de Chow-Liu para la aprender la estructura de una RB. El algoritmo de Chow-Liu busca encontrar la estructura del árbol de dependencias de una RB que maximiza la verosimilitud conjunta de los datos observados, considerando todas las posibles conexiones entre las variables (Chow & Liu, 1968).

En el ejemplo que se está desarrollando, lo primero que se debe realizar para aplicar el algoritmo de Chow-Liu, y que aprenda la estructura, es generar datos para cada uno de los riesgos tanto observables como ocultos.

```
from pgmpy.sampling import BayesianModelSampling

# sample data from BN
inference = BayesianModelSampling(model)
df_data = inference.forward_sample(size=1000000)
print(df_data)
```

Generating for node: C3: 100% 12/12 [00:05<00:00, 1.79it/s]

	PH11	EH1	PH12	PH21	EH2	PH22	RS	S1	S2	C1	C2	C3
0	1	1	0	1	0	1	0	0	0	0	1	1
1	1	1	0	0	0	1	0	0	0	0	1	1
2	1	1	0	1	1	0	1	1	1	1	0	0
3	1	1	1	0	0	0	0	0	0	0	1	1
4	1	1	0	1	1	0	0	0	0	0	1	1
...
999995	1	1	1	1	1	1	1	1	1	1	0	0
999996	1	1	0	1	1	1	1	1	1	1	0	0
999997	0	1	1	1	1	1	1	1	1	1	0	0
999998	1	0	0	1	1	1	0	0	0	0	1	1
999999	0	0	0	1	1	1	0	0	0	0	1	1

[1000000 rows x 12 columns]

Figura 14. Generación de datos para aplicación de Chow-liu en ejemplo. (Fuente: Autor)

Se quiere saber, con la aplicación de este algoritmo que estructura se tiene para obtener las probabilidades de C1 descritos en la **figura 11**:

```
from pgmpy.estimators import TreeSearch

# learn graph structure
est = TreeSearch(df_data, root_node="C1")
dag = est.estimate(estimator_type="chow-liu")
nx.draw_circular(
    dag, with_labels=True, arrowsize=30, node_size=800, alpha=0.3, font_weight="bold"
)
plt.show()
```

Figura 15. Aplicación del algoritmo de Chow-Liu para encontrar la estructura de la RB desde C1 (Fuente: Autor)

La estructura que ha aprendido a partir de los datos generados por la red bayesiana se muestra en la **figura 16**. Si comparamos el DAG obtenido con el propuesto en la **figura 4** podemos observar que la red causal es prácticamente la misma.

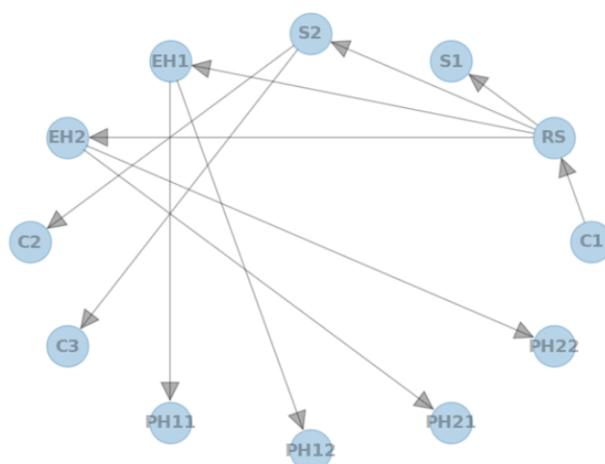


Figura 16. Red causal obtenida a partir de los datos aplicando Chow-Liu. (Fuente: Autor)

7. Conclusiones

Como se ha visto en el punto anterior, la utilización de las RB para evaluar riesgos a través de la modelación de un B-T ayuda a encontrar las probabilidades inferidas a partir de la probabilidad de riesgos observados. Esto ayuda a poder modelar aquellos “riesgos conocidos – consecuencias desconocidas” que se expuso al principio de este trabajo.

Sin embargo, las RB tienen dos problemas en su utilización: el primero es que la adición de nodos a una RB aumenta exponencialmente el número de probabilidades a analizar para obtener los valores inferidos; el segundo es que no tiene en cuenta la evolución temporal que se puede producir por el efecto tiempo.

Una solución al segundo problema enunciado es la utilización de redes bayesianas dinámicas (RBD) que aportan dos importantes conceptos: primero, permiten modelar la evolución de variables a lo largo del tiempo, considerando la dependencia entre las variables en diferentes instantes temporales, pudiendo por tanto capturar cómo las variables cambian y se relacionan entre sí; segundo, las RBD constan de múltiples capas de nodos, donde cada capa representa un instante temporal (Murphy, 2002).

No obstante, las RBD, aunque pueden suponer una importante mejora en la evaluación de riesgos en proyectos complejos tiene dificultades en detectar la emergencia de nuevos elementos, su autoorganización y su criticidad, propiedades clave de los sistemas complejos, y, adicionalmente, la coevolución de los elementos del sistema con ellos mismos y con otros del exterior al sistema complejo, que respecto a este artículo se refiere a los “riesgos desconocidos – consecuencias desconocidas”.

Una importante línea de investigación para resolver lo indicado en el párrafo anterior se basa en la comprensión de las denominadas “mantas de Markov”. En probabilidad, estos elementos ayudan a definir las particiones de estados de un sistema, proporcionando información sobre las dependencias condicionales entre diferentes fragmentos del sistema, claves para entender la autoorganización, y los cambios causales que pueden producirse, su coevolución, analizando además la entropía, cuyo cambio afecta a la emergencia de nuevos elementos (Friston et al., 2021). Eso parece permitir la posibilidad de saber nuevos riesgos a tener en cuenta, o nuevas interacciones no previstas que afecten a riesgos ya definidos aumentando la capacidad de evaluación de riesgos en proyectos complejos.

Referencias

- Álvarez-Espada, J.-M., Fuentes-Bargues, J. L., & González-Gaya, C. (2022). *Gestión de riesgos en proyectos complejos. Misiones de paz de la ONU*.
- Arellano, D., Danti, J., & Pérez, M. F. (2016). *Proyectos y sistemas complejos*. PMI Project Management Intitute Madrid. <https://pmi-mad.org/socios/articulos-direccion-proyectos/1225-proyectos-y-sistemas-complejos>
- Aven, T. (2015). The concept of antifragility and its implications for the practice of risk analysis. *Risk Analysis*, 35(3), 476–483. <https://doi.org/10.1111/risa.12279>
- Béatrix, B. (2018). *Integrated risk management process improvement framework in it settings based on iso standards* [Universitat de les Illes Balears]. <https://dspace.uib.es/xmlui/handle/11201/149220>
- Bestratén Belloví, M. (1991). *NTP 328: Análisis de riesgos mediante árbol de sucesos*.
- Chow, C., & Liu, C. (1968). Approximating discrete probability distributions with dependence trees. *IEEE Transactions on Information Theory*, 14(3), 462–467.
- Culp, C. L. (2002). *The risk management process: business strategy and tactics*. John Wiley & Sons.
- Derbyshire, J., & Wright, G. (2014). Preparing for the future: development of an 'antifragile' methodology that complements scenario planning by omitting causation. *Technological Forecasting and Social Change*, 82, 215–225.
- Dubois, D. (2010). Representation, propagation, and decision issues in risk analysis under incomplete probabilistic information. *Risk Analysis: An International Journal*, 30(3), 361–368.
- Fridgeirsson, T. V., Ingason, H. T., Jonasson, H. I., & Kristjansdottir, B. H. (2021). The VUCALity of Projects: A New Approach to Assess a Project Risk in a Complex World. *Sustainability* 2021, Vol. 13, Page 3808, 13(7), 3808. <https://doi.org/10.3390/SU13073808>
- Friston, K., Heins, C., Ueltzhöffer, K., Da Costa, L., & Parr, T. (2021). Stochastic chaos and Markov blankets. *Entropy*, 23(9), 1220.
- Garrett, G. A. (2005). Managing Opportunity & Risk in a Complex Project Environment. *Contract Management*, 45(4), 8–20. <https://search.proquest.com/docview/196309229?accountid=14609>
- Hass, K. (2009). Managing complex Projects. In *Management Concepts* (1st ed.). Management Concepts.
- Kerzner, H., & Belack, C. (2010). Managing Complex Projects. In *Managing Complex Projects*. John Wiley and Sons. <https://doi.org/10.1002/9780470927977>
- Khakzad, N., Khan, F., & Amyotte, P. (2012). Dynamic risk analysis using bow-tie approach. *Reliability Engineering & System Safety*, 104, 36–44. <https://doi.org/https://doi.org/10.1016/j.ress.2012.04.003>
- Khakzad, N., Khan, F., & Amyotte, P. (2013). Dynamic safety analysis of process systems by mapping bow-tie into Bayesian network. *Process Safety and Environmental Protection*, 91(1), 46–53. <https://doi.org/https://doi.org/10.1016/j.psep.2012.01.005>
- Khan, F., Hashemi, S. J., Paltrinieri, N., Amyotte, P., Cozzani, V., & Reniers, G. (2016). Dynamic risk management: a contemporary approach to process safety management.

- Current Opinion in Chemical Engineering*, 14, 9–17.
<https://doi.org/https://doi.org/10.1016/j.coche.2016.07.006>
- Kourounakis, N., & Maraslis, A. (2017). *PM2 Resumen general de la metodología* (Centro de Excelencia en Gestión de Proyectos (CoEPM2), Ed.).
- Mitchell, G. F. (2005). Managing risks in complex projects using compression strategies. In *ProQuest Dissertations and Theses*.
<https://search.proquest.com/docview/305423465?accountid=14609>
- Murphy, K. P. (2002). Dynamic bayesian networks. *Probabilistic Graphical Models*, M. Jordan, 7, 431.
- Paltrinieri, N., Tugnoli, A., Buston, J., Wardman, M., & Cozzani, V. (2013). Dynamic Procedure for Atypical Scenarios Identification (DyPASI): A new systematic HAZID tool. *Journal of Loss Prevention in the Process Industries*, 26(4), 683–695.
<https://doi.org/https://doi.org/10.1016/j.jlp.2013.01.006>
- Paté-Cornell, E. (2012). On “black swans” and “perfect storms”: Risk analysis and management when statistics are not enough. *Risk Analysis: An International Journal*, 32(11), 1823–1833.
- Pich, M. T., Loch, C. H., & Meyer, A. De. (2002). On uncertainty, ambiguity, and complexity in project management. *Management Science*, 48(8), 1008–1023.
- PMI. (2017). *Guía de los fundamentos para la dirección de proyectos. Guía PMBOK* (Inc. Project Management Institute, Ed.; 6th ed.). Project Management Institute, Inc. www.pmi.org
- PMI. (2023). *Process Groups: A Practice Guide* (1st ed.). Project Management Institute, Inc.
- Rahman, M. (2018). *Risk Management and Measurement of Risk Management Performance in Complex Projects*.
- Remington, K., & Pollack, J. (2016). *Tools for Complex Projects*.
<https://doi.org/10.4324/9781315550831>
- Szpitter, A., & Sadkowska, J. (2016). Using VUCA matrix for the assessment of project environment risk. *Zarządzanie i Finanse*, 14(2), 401–413.
- Teimourikia, M. (2017). *Co-engineering safety and security in risk-prone smart work environments*.
- Vila Grau, J. L., & Capuz Rizo, S. (2020). *Análisis del impacto de la Agilidad sobre los modelos de gestión de proyectos PMBoK, PRINCE2 e IPMA*.
- Willumsen, P., Oehmen, J., Stingl, V., & Gerald, J. (2019). Value creation through project risk management. *International Journal of Project Management*, 37(5), 731–749.
<https://doi.org/10.1016/j.ijproman.2019.01.007>

**Comunicación alineada con los
Objetivos de Desarrollo Sostenible**

