

Una red bayesiana para la cuantificación de la incertidumbre para modelos de planeación de la distribución

A bayesian network for quantifying uncertainty for distribution planning model

Humberto García¹, Alberto Ochoa-Zezzatti² y Adrián Loera¹

¹ Tecnológico Nacional de México (México)

² Universidad Autónoma de Cd. Juárez (México)

DOI: <http://dx.doi.org/10.6036/9764>

La incertidumbre es un tema clave en el diseño de ingeniería [1]: las soluciones óptimas generalmente no implican márgenes de seguridad, pero los sistemas reales implican tener incertidumbre, variabilidad y error. Por ejemplo, la geometría, los parámetros del material, las condiciones de contorno o incluso el modelo en sí, incluyen incertidumbre. Para proporcionar diseños seguros, se debe considerar la incertidumbre en los modelos de optimización.

Existen diferentes formas de introducir incertidumbre en el diseño de modelos: las más populares son los métodos de intervalo, las variables difusas y el modelado probabilístico. Cada enfoque tiene sus particularidades, ventajas e inconvenientes. Aquí, nos enfocamos en el enfoque probabilístico basado en el teorema de Bayes, que se usa en las situaciones en las que se dispone de información estadística cuantitativa sobre la variabilidad. Cuando se utiliza el enfoque probabilístico, la variabilidad se modela mediante variables aleatorias.

En el contexto de la toma de decisiones es importante tener en cuenta la incertidumbre que existe en el contexto de la planeación de la distribución. Por ejemplo, si la demanda es más alta de lo esperado, puede haber una capacidad de distribución insuficiente para satisfacerla, o si es más pequeña, algunos activos pueden considerarse en retrospectiva varados. Un modelo de planeación puede ser difícil de resolver, debido a su alto nivel de complejidad y número de soluciones óptimas posibles en un gran conjunto de datos.


Cuando estos grandes conjuntos de datos se combinan con algoritmos complejos, como redes neuronales profundas, aprendizaje máquina, algoritmos genéticos. Sin embargo, a pesar del éxito de estos modelos, no se ha prestado mucha atención a la cuantificación de la incertidumbre (UQ); es decir, cuantifique la confianza de un modelo en sus predicciones. En algunas situaciones, UQ puede no ser una alta prioridad, por ejemplo, en la recomendación de títulos de películas, guanteletes [3] o cualquier

otra situación personal. Pero en situaciones donde la predicción incorrecta es una cuestión de vida o muerte, UQ es crucial. Por ejemplo, si el personal del ejército en combate usa un algoritmo Modelos de programación lineal mixta (MILP) para tomar decisiones, es vital saber qué tan seguro es el algoritmo en sus predicciones.

Existe una manera productiva para realizar una UQ y obtener resultados confiables y con amplias aplicaciones, es la aplicación de una red Bayesiana. Aquí la idea de cuantificar con la aplicación a partir de una Red Bayesiana (BN), ya que la visión de la probabilidad como expresión de un estado de conocimiento tiene profundas consecuencias. Esta perspectiva de probabilidades se llama probabilidad condicional o probabilidad bayesiana. Las redes probabilísticas causales, son un formato gráfico bien establecido para codificar relaciones probabilísticas condicionales entre variables inciertas. Los nodos de un BN representan variables y los arcos representan relaciones causales o influyentes entre ellos. Los BN se basan en bases sólidas de causalidad y teoría de la probabilidad; a saber, la probabilidad bayesiana [4] ver figura 1.

Una fortaleza del BN es que incluye explícitamente el elemento de incertidumbre relacionado con cualquier estrategia o decisión. Los enlaces se basan en los datos disponibles. Este puede ser un conjunto de datos grande, la salida de un modelo o, en ausencia de datos, puede basarse en la opinión de expertos. Y representa una nueva forma de cuantificar la incertidumbre.

Hay estudios que concluyen que con esta técnica permite de manera rápida y



eficiente realizar la UQ en un modelo de programación lineal entera-mixta (MILP) [5] para problemas de la planeación de la distribución de bienes de consumo, ahorrando tiempo y recursos informáticos, haciendo el proceso de toma de decisiones eficiente, además contribuye en el proceso a que quien toma las decisiones, lo haga con certeza y confianza objetiva del error asociado a tomar la decisión, es decir, de la probabilidad de tomar una decisión óptima erróneamente de un modelo de programación lineal. Una decisión óptima dentro del modelo que depende en gran medida de la elección particular de los escenarios en lugar de la incertidumbre subyacente en las entradas del modelo. En conclusión a partir de una BN se puede estimar la UQ de un problema de distribución, independientemente de la cantidad de demanda y productos así como de instalaciones.

REFERENCIAS

- [1] Cursi, Eduardo Souza De, and Rafael Holdorf Lopez. "Uncertainty Quantification in Optimization." *Advances in Intelligent Systems and Computing Optimization of Complex Systems: Theory, Models, Algorithms and Applications*, 2019, 557-66. https://doi.org/10.1007/978-3-030-21803-4_56.
- [2] Opathella, Chandrabhanu, Ayman Elkasrawy, Amr Adel Mohamed, and Bala Venkatesh. "MILP Formulation for Generation and Storage Asset Sizing and Siting for Reliability Constrained System Planning." *International Journal of Electrical Power & Energy Systems* 116 (2020): 105529. <https://doi.org/10.1016/j.ijepes.2019.105529>.
- [3] Mishra, Srikanta, and Akhil Datta-Gupta. "Uncertainty Quantification." *Applied Statistical Modeling and Data Analytics*, 2018, 119-67. <https://doi.org/10.1016/b978-0-12-803279-4.00006-7>.
- [4] Constantinou, Anthony Costa; Fenton, Norman; Neil, Martin: Integrating Expert Knowledge with Data in Bayesian Networks. *Expert systems with applications*, ISSN: 0957-4174, Vol: 56, Page: 197-208. (2016)
- [5] Loera-Castro, Adrian-Francisco; García-Castellanos Humberto; and ocho-zezzatti, Alberto. "Quantification of uncertainty in the planning of the distribution of consumer goods using a Bayesian network". *DYNA Management*, January-December 2020, vol. 8, no. 1, [14 p.]. DOI: <http://dx.doi.org/10.6036/MN9571>