TECNOLÓGICO DE ESTUDIOS SUPERIORES DE COACALCO

UNIDAD DE ESTUDIOS DE POSGRADO E INVESTIGACIÓN
MAESTRIA EN CIENCIAS EN INGENIERA INDUSTRIAL

T E S I S

ÁRBOL BAYESIANO DE DECISIÓN PARA LA SELECCIÓN ENTRE MATERIALES PARA LA PRODUCCIÓN SUSTENTABLE DE NANOHÍBRIDOS

QUE PARA OBTENER EL GRADO DE:

MAESTRA EN CIENCIAS
EN INGENIERÍA INDUSTRIAL

LÍNEA DE INVESTIGACIÓN:

ANÁLISIS DE DECISIONES

PRESENTA:
CECILIA MERCADO ZÚÑIGA

No. MATRICULA:

102220049

DIRECTOR DE TESIS:
DR. JOSÉ ROBERTO PÉREZ TORRES

COACALCO DE BERRIOZÁBAL DICIEMBRE 2024.

ÍNDICE

Contenido

RESUMEN 7
ABSTRACT 8
1. MARCO REFERENCIAL 9
1.1 INTRODUCCIÓN 9
1.2 JUSTIFICACIÓN 11
1.3 PLANTEAMIENTO DEL PROBLEMA 12
1.4 ANTECEDENTES DEL PROBLEMA 12
1.5 OBJETIVOS E HIPÓTESIS 14
2. MARCO TEÓRICO 16
2.1 REVISIÓN DE LA LITERATURA 16
2.2 INCERTIDUMBRE 17
2.2.1 Origen de la Incertidumbre 18
2.2.1.1 Incertidumbre Aleatoria (Estocástica) 19
2.2.1.2 Incertidumbre Epistémica (De Conocimiento) 19
2.2.1.3 Incertidumbre en la Medición 20
2.2.1.4 Incertidumbre en el Modelo 20
2.2.1.5 Incertidumbre en los Parámetros 20
2.2.1.6 Incertidumbre en la Variabilidad Humana 21
2.3 TOMA DE DECISIONES 21
2.3.1 Tipos de Decisiones 22
2.3.2 Modelos de toma de decisiones 23
2.3.3 Factores que influyen en la toma de decisiones 25
2.3.4 Implementación y evaluación de decisiones 25
2.4 ÁRBOLES DE DECISIÓN 27
2.4.1 Componentes y construcción de un árbol de decisión 28
2.4.2 Evaluación de riesgos y probabilidades 30
2.4.4 Evaluación de Probabilidades en Árboles de Decisión 31
2.4.5 Incertidumbre y sensibilidad en los árboles de decisión 32
2.5 ÁRBOLES BAYESIANOS 33

2.5.1 Inferencia bayesiana 33
2.5.2 Estructura de los árboles bayesianos 34
2.5.3 Construcción de un árbol bayesiano 35
2.5.4 Aplicaciones prácticas de los árboles bayesianos 36
2.6 DECISIÓN DE LOS EXPERTOS 36
2.6.1 Decisión Experta 37
2.6.2 Modelos y métodos para la decisión experta 38
2.7 NANOTUBOS DE CARBONO 38
2.7.1 Definición y estructura 39
2.7.2 Propiedades electrónicas, mecánicas y térmicas. 39
2.7.3. Clasificación de los nanotubos de carbono 40
2.7.4 Métodos de Síntesis de Nanotubos de Carbono 41
2.7.4 Aplicaciones de los Nanotubos de Carbono 42
2.7.4.1 Uso en dispositivos electrónicos y sensores 42
2.7.4.2 Aplicaciones en la industria de materiales compuestos 42
2.7.4.3 Usos en almacenamiento de energía (baterías y supercondensadores) 44
2.8 NANOHÍBRIDOS 45
2.8.1 Definición de nanohíbrido. 45
2.8.2 Funcionalización de nanotubos de carbono con moléculas de plata. 45
2.8.3 Propiedades y sinergia entre nanotubos y partículas de plata. 46
2.8.4 Métodos de Fabricación de Nanohíbridos 47
2.8.4.1 Compatibilidad y estabilidad de los nanohíbridos 47
2.8.4.2 Control de las propiedades del material a través de la modificación de nanotubos 48
3. DESARROLLO 50
3.1 Síntesis de Nanotubos de Carbono (NTC) 51
3.2 Síntesis de nanopartículas metálicas (NPM) 52
3.3 Síntesis de compuestos tipo NTC/NPs 54
3.4 Desarrollo del árbol de decisión 56
3.4.1. Nodo raíz: Decisión inicial 56
3.4.2. Selección del estabilizador orgánico 57

3.4.3. Probabilidad de los factores (costo relativo, su disponibilidad, y la eficiencia del proceso) 57
3.4.4. Resultado del proceso 59
3.4.5 Representación en el árbol 59
3.4.6 Ejemplo práctico 59
3.4.6 Visualización 60
4. RESULTADOS 61
5. CONCLUSIONES 99
6. BIBLIOGRAFÍA 100

ÍNDICE DE FIGURAS

Figura 1. Ejemplo de árbol de decisión 27
Figura 2. Esquema del reactor utilizado para la síntesis de NTC 52
Figura 3. Esquema simple del proceso de utilizado para la formación de NPsAg 54
Figura 4. Proceso de formación de nanohibridos 56
Figura 5. Árbol para la variable costo de la cáscara de naranja 62
Figura 6. Árbol para la variable costo de la cáscara de plátano 63
Figura 7. Árbol para la variable costo del hueso de aguacate 64
Figura 8. Árbol para la variable costo del ajo 65
Figura 9. Árbol para la variable costo de hoja de eucalipto 66
Figura 10. Rama del árbol bayesiano para la variable costo con los 5 materiales orgánicos sin prueba previa 67
Figura 11. Rama del árbol bayesiano para la variable costo con los 5 materiales orgánicos con prueba previa 68
Figura 12. Rama del árbol bayesiano con prueba previa considerando la variable costo usando cáscara de naranja 69
Figura 13. Rama del árbol bayesiano con prueba previa considerando la variable costo usando cáscara de plátano 70
Figura 14. Rama del árbol bayesiano con prueba previa considerando la variable costo usando hueso de aguacate 71
Figura 15. Rama del árbol bayesiano con previa considerando la variable costo usando ajo 72
Figura 16. Rama del árbol bayesiano con prueba previa considerando la variable costo usando hojas de eucalipto 73
Figura 17. Árbol para la variable disponibilidad de la cáscara de naranja 74
Figura 18. Árbol para la variable disponibilidad de la cáscara de plátano 75
Figura 19. Árbol para la variable disponibilidad del hueso de aguacate 76
Figura 20. Árbol para la variable disponibilidad del ajo 77
Figura 21. Árbol para la variable disponibilidad de las hojas de eucalipto 78
Figura 22. Rama del árbol bayesiano para la variable disponibilidad con los 5 materiales orgánicos sin prueba previa 79
Figura 23. Rama del árbol bayesiano para la variable disponibilidad con los 5 materiales orgánicos con prueba previa 80
Figura 24. Rama del árbol bayesiano con prueba previa considerando la variable disponibilidad del estabilizador usando cáscara de naranja 81
Figura 25. Rama del árbol bayesiano con prueba previa considerando la variable disponibilidad del estabilizador usando cáscara de plátano 82
Figura 26. Rama del árbol bayesiano con prueba previa considerando la variable disponibilidad del estabilizador usando hueso de aguacate 83
Figura 27. Rama del árbol bayesiano con prueba previa considerando la variable disponibilidad del estabilizador usando ajo 84

Figura 28. Rama del árbol bayesiano con prueba previa considerando la variable disponibilidad del estabilizador usando hojas de eucalipto 85
Figura 29. Árbol para la variable eficiencia del proceso con la cáscara de naranja 86
Figura 30. Árbol para la variable eficiencia del proceso con la cáscara de plátano 87
Figura 31. Árbol para la variable eficiencia del proceso con el hueso de aguacate 88
Figura 32. Árbol para la variable eficiencia del proceso con ajo 89
Figura 33. Árbol para la variable eficiencia del proceso con hojas de eucalipto 90
Figura 34. Rama del árbol bayesiano para la variable eficiencia del proceso con los 5 materiales orgánicos sin prueba previa 91
Figura 35. Rama del árbol bayesiano para la variable eficiencia del proceso con los 5 materiales orgánicos con prueba previa 92
Figura 36. Rama del árbol bayesiano con prueba previa considerando la variable eficiencia del proceso con el estabilizador cáscara de naranja 93
Figura 37. Rama del árbol bayesiano con prueba previa considerando la variable eficiencia del proceso con el estabilizador cáscara de plátano. 94
Figura 38. Rama del árbol bayesiano con prueba previa considerando la variable eficiencia del proceso con el estabilizador hueso de aguacate 95
Figura 39. Rama del árbol bayesiano con prueba previa considerando la variable eficiencia del proceso con el estabilizador ajo 96
Figura 40. Rama del árbol bayesiano con prueba previa considerando la variable eficiencia del proceso con el estabilizador hojas de eucalipto 97

ÍNDICE DE TABLAS

Tabla 1. Probabilidades asignadas para la variable Costo 58
Tabla 2. Probabilidades asignadas para variable Disponibilidad 58
Tabla 3. Probabilidades asignadas para la variable Eficiencia. 58

RESUMEN

El presente trabajo de investigación desarrolla un modelo basado en un árbol bayesiano que emplea la opinión de expertos para reducir la incertidumbre en la síntesis de nanohíbridos compuestos por nanotubos de carbono y nitrato de plata, utilizando estabilizadores orgánicos. El estudio considera dos escenarios principales: realizar pruebas experimentales previas o proceder sin estas, y evalúa la efectividad de cinco estabilizadores orgánicos: cáscara de naranja, cáscara de plátano, hueso de aguacate, ajo y hojas de eucalipto.

La metodología integra datos experimentales y el juicio de expertos para construir un árbol bayesiano que modela las probabilidades de éxito de los nanohíbridos bajo diferentes combinaciones de condiciones y estabilizadores. Los resultados muestran que los estabilizadores desempeñan roles significativos en la estabilidad y calidad del producto final, destacando patrones específicos para cada material evaluado. Además, el árbol bayesiano desarrollado se caracteriza por su adaptabilidad, lo que permite incorporar nuevos estabilizadores orgánicos sin necesidad de reconstruir completamente el modelo.

Este enfoque ofrece una herramienta versátil para la optimización del diseño de nanohíbridos, al reducir costos y tiempo en el laboratorio, y fomenta la exploración de alternativas sostenibles mediante el uso de materiales orgánicos abundantes y económicos. La metodología y los resultados representan un avance en la nanotecnología al facilitar procesos de síntesis más predecibles y adaptables a diversas aplicaciones.

ABSTRACT

This research presents a model based on a Bayesian tree that uses expert opinions to reduce uncertainty in the synthesis of nanohybrids composed of carbon nanotubes and silver nitrate, using organic stabilizers. The study considers two main scenarios: conducting preliminary experimental tests or proceeding without them and evaluates the effectiveness of five organic stabilizers: orange peel, banana peel, avocado seed, garlic, and eucalyptus leaves.

The methodology integrates experimental data and expert judgment to build a Bayesian tree that models the probabilities of success of the nanohybrids under different combinations of conditions and stabilizers. The results show that stabilizers play significant roles in the stability and quality of the final product, highlighting specific patterns for each material tested. Additionally, the developed Bayesian tree is adaptable, allowing for the incorporation of new organic stabilizers without the need to completely rebuild the model.

This approach provides a versatile tool for optimizing nanohybrid design by reducing costs and laboratory time, while encouraging the exploration of sustainable alternatives through the use of abundant and cost-effective organic materials. The methodology and results represent an advancement in nanotechnology by enabling more predictable synthesis processes adaptable to various applications.

1. MARCO REFERENCIAL

El marco referencial de esta investigación se centra en la aplicación de nanotecnología para el diseño de nanohíbridos, específicamente en la interacción entre nanotubos de carbono y nanopartículas de plata, estabilizadas mediante compuestos orgánicos. Estudios previos han demostrado que los estabilizadores naturales no solo son sostenibles, sino que también influyen significativamente en las propiedades fisicoquímicas del material final. En este contexto, la incertidumbre en los procesos de síntesis puede abordarse eficazmente mediante modelos probabilísticos como los árboles bayesianos, que integran tanto datos experimentales como la experiencia de expertos para optimizar resultados.

1.1 INTRODUCCIÓN

La agricultura en el Estado de México es una actividad económica fundamental que contribuye significativamente al desarrollo regional y al abastecimiento de alimentos a nivel nacional. La agricultura en el Estado de México no solo sustenta la economía local, sino que también juega un papel crucial en la seguridad alimentaria y en la generación de empleo.

Por otro lado, la contaminación en el Estado de México afecta gravemente las tierras de cultivo. Los residuos industriales y urbanos, junto con el uso excesivo de agroquímicos, contaminan los suelos y las fuentes de agua, disminuyendo su fertilidad. Esto lleva a la pérdida de biodiversidad y a la reducción de la productividad agrícola, afectando la calidad y cantidad de los cultivos. Además, los contaminantes tóxicos pueden ingresar a la cadena alimentaria, representando un riesgo para la salud humana.

Los nanohíbridos pueden ofrecer soluciones innovadoras y efectivas para la reducción de la contaminación de suelos de cultivo en el Estado de México, abordando problemas como la presencia de metales pesados, pesticidas y otros contaminantes orgánicos e inorgánicos. La producción de nanohíbridos es crucial debido a que combinan las propiedades excepcionales de los nanotubos, como su alta conductividad y resistencia mecánica, con otras sustancias para crear compuestos con características únicas. Sin embargo, el proceso es complejo y requiere una toma de decisiones adecuada para optimizar la compatibilidad, dispersión y funcionalidad de los nanotubos dentro del híbrido. La selección de métodos de síntesis,

materiales complementarios y condiciones de procesamiento es clave para asegurar un rendimiento óptimo y aplicaciones eficientes del nanohíbrido.

La selección de componentes para generar nanohíbridos con nanotubos de carbono (NTCs) y compuestos orgánicos es una tarea compleja que implica considerar múltiples factores y propiedades deseadas. Un árbol bayesiano puede ser una herramienta poderosa para ayudar en este proceso de toma de decisiones, proporcionando una metodología estructurada y basada en probabilidades para evaluar y seleccionar los mejores componentes.

Los árboles bayesianos representan un medio para la toma de decisiones informadas, al combinar las capacidades de los árboles de decisión con los principios de la estadística bayesiana. Esta integración permite no solo estructurar decisiones de manera jerárquica sino también manejar la incertidumbre y actualizar las probabilidades a medida que se dispone de nueva información.

Un árbol bayesiano, al igual que un árbol de decisión, organiza la toma de decisiones en una estructura jerárquica de nodos, ramas y hojas. Cada nodo interno representa una pregunta o prueba basada en un atributo del problema en cuestión, mientras que cada hoja representa una posible decisión o clasificación. La diferencia clave radica en que los árboles bayesianos incorporan probabilidades condicionales en cada nodo, calculadas y actualizadas mediante el teorema de Bayes. Esta capacidad de integrar probabilidades condicionales permite a los árboles bayesianos manejar la incertidumbre de manera más efectiva que los árboles de decisión tradicionales.

Además, la estructura jerárquica de los árboles bayesianos facilita la descomposición de problemas complejos en decisiones más manejables y comprensibles. Esto no solo ayuda a clarificar el proceso de toma de decisiones, sino que también permite una interpretación más intuitiva de cómo se alcanzan las conclusiones.

El presente trabajo aborda el desarrollo de un árbol bayesiano como herramienta para la toma de decisiones en el proceso de fabricación de nanohíbridos empleando nanotubos de carbono y precursores orgánicos. Dicho modelo permite evaluar y predecir la eficacia de distintos compuestos orgánicos y nanotubos de carbono, considerando factores como el costo del material orgánico, su disponibilidad y la eficiencia en la fabricación de nanohíbridos. Al

integrar datos experimentales, el árbol bayesiano ayuda a identificar combinaciones óptimas y a minimizar riesgos, lo que mejora la eficiencia en el desarrollo de soluciones descontaminantes adaptadas a las condiciones locales del suelo.

1.2 JUSTIFICACIÓN

La actividad agrícola en el Estado de México es vital por varias razones. En primer lugar, es una fuente importante de ingresos y empleo para una gran parte de la población rural. La producción agrícola proporciona materias primas esenciales para la industria alimentaria y otras industrias relacionadas. Además, los productos agrícolas del Estado de México, como el maíz, el frijol, el trigo, la cebada, las hortalizas y las flores, son fundamentales para el abastecimiento de mercados locales y nacionales. La floricultura, en particular, es una actividad destacada, con municipios como Villa Guerrero y Tenancingo conocidos por su producción de flores ornamentales.

A pesar de su importancia económica, la agricultura en el Estado de México enfrenta serios desafíos ambientales. La contaminación del suelo y del agua es un problema creciente, derivado del uso intensivo de agroquímicos como fertilizantes y pesticidas. Estos productos, aunque necesarios para aumentar la productividad, pueden tener efectos adversos a largo plazo, como la degradación del suelo, la pérdida de biodiversidad y la contaminación de cuerpos de agua.

Los nanohíbridos tienen el potencial de ser una herramienta poderosa para la reducción de la contaminación de suelos de cultivo, a través de la adsorción y retención de contaminantes, la degradación catalítica de compuestos orgánicos, la mejora de la fertilidad del suelo, la biorremediación mejorada y el monitoreo en tiempo real. Estas tecnologías innovadoras pueden contribuir significativamente a la sostenibilidad y productividad agrícola en la región.

Un árbol bayesiano de decisión puede tener un papel importante en la creación de nanohíbridos para descontaminación de suelos agrícolas, ya que permite evaluar múltiples variables y escenarios de forma probabilística. Este enfoque ayuda a predecir el comportamiento de diferentes combinaciones de materiales en condiciones específicas del suelo, optimizando el proceso de selección de nanohíbridos. Al considerar diferentes factores, se pueden tomar decisiones informadas y reducir la incertidumbre en el desarrollo

de tecnologías más efectivas. Esto es especialmente importante para adaptar soluciones a las características particulares de los suelos agrícolas afectados.

1.3 PLANTEAMIENTO DEL PROBLEMA

La creación de nanohíbridos es un de gran importancia debido a su potencial para innovar en áreas como la descontaminación, la medicina y la energía, combinando materiales con propiedades complementarias para lograr soluciones más eficaces. Sin embargo, este proceso es complejo, ya que requiere la selección óptima de componentes y condiciones de síntesis. Un árbol bayesiano de decisión puede ser de gran ayuda al permitir la evaluación probabilística de diferentes combinaciones y escenarios, minimizando la incertidumbre y optimizando la toma de decisiones. Esto facilita la identificación de factores ideales para la creación de nanohíbridos con las mejores propiedades para aplicaciones específicas, mejorando la eficiencia y eficacia del desarrollo.

1.4 ANTECEDENTES DEL PROBLEMA

La contaminación de suelos y agua en el Estado de México es un problema grave causado por la actividad industrial, el crecimiento urbano descontrolado y la mala gestión de residuos. Los desechos tóxicos y las aguas residuales se vierten en ríos y cuerpos de agua, afectando su calidad y contaminando el suelo adyacente. Esto impacta la agricultura, la fauna y la salud humana, ya que los contaminantes se infiltran en acuíferos y cadenas alimenticias. La falta de infraestructura adecuada y de políticas ambientales efectivas agrava la situación, poniendo en riesgo los recursos naturales y la vida de los habitantes.

La agricultura en el Estado de México es una actividad vital que sustenta a la población local y contribuye al desarrollo económico regional. Sin embargo, es esencial abordar los desafíos ambientales asociados con la producción agrícola para garantizar la sostenibilidad a largo plazo y proteger los recursos naturales del estado.

La nanotecnología ofrece soluciones innovadoras para la descontaminación de suelos y agua mediante el uso de nanomateriales que interactúan con contaminantes a nivel molecular. Los nanofiltros, por ejemplo, pueden eliminar metales pesados y sustancias tóxicas de cuerpos de agua, mientras que las nanopartículas catalíticas descomponen compuestos orgánicos

peligrosos en suelos. Estos materiales tienen alta reactividad y superficie específica, lo que les permite capturar y neutralizar contaminantes de manera más eficiente que los métodos convencionales. Además, pueden ser diseñados para actuar de forma selectiva, minimizando el impacto ambiental. Así, la nanotecnología mejora la remediación ambiental de manera más rápida y eficaz.

La producción de nanomateriales puede generar contaminación debido al uso intensivo de energía, productos químicos tóxicos y emisiones durante su fabricación. En particular, los procesos como la síntesis química y física de nanopartículas pueden liberar residuos peligrosos al aire, agua y suelo, además de generar subproductos no deseados. El manejo inadecuado de estos materiales puede causar su liberación en el medio ambiente, afectando la salud humana y la biodiversidad. También existe el riesgo de bioacumulación y toxicidad a largo plazo, ya que algunos nanomateriales pueden interactuar de manera impredecible con organismos vivos y los ecosistemas, exacerbando la contaminación ambiental.

Los nanohíbridos con partículas orgánicas reducen la contaminación en la producción de nanomateriales al combinar propiedades de materiales orgánicos e inorgánicos, lo que minimiza el uso de sustancias tóxicas y procesos altamente energéticos. Al incorporar componentes orgánicos biodegradables, se disminuye la generación de residuos peligrosos y la huella ambiental del proceso. Además, los nanohíbridos orgánicos suelen requerir condiciones de síntesis más suaves, reduciendo la emisión de gases y productos secundarios contaminantes. Este enfoque promueve una producción más limpia y sostenible de nanomateriales, optimizando sus propiedades sin comprometer el medio ambiente o la salud humana.

El uso de nanohíbridos en la producción de nanomateriales para la descontaminación de suelos y agua es beneficioso porque combina la alta eficiencia de las nanopartículas inorgánicas con la biodegradabilidad y funcionalidad de materiales orgánicos. Estos nanohíbridos pueden diseñarse para captar y neutralizar contaminantes específicos, como metales pesados o compuestos orgánicos, con menor impacto ambiental. Además, la integración de componentes orgánicos reduce la toxicidad y el riesgo de bioacumulación, lo que los hace más seguros para el entorno natural. Al ser más sostenibles y efectivos, los nanohíbridos mejoran los procesos de remediación sin generar contaminantes adicionales.

El proceso de creación de nanohíbridos es crucial para desarrollar materiales más eficientes y sostenibles en la descontaminación ambiental. Los árboles bayesianos pueden apoyar en este proceso al modelar y predecir combinaciones óptimas de materiales, acelerando la identificación de propiedades clave y mejorando la precisión en el diseño, optimización y aplicación de los nanohíbridos, mejorando la eficiencia y reduciendo errores en el proceso de síntesis y caracterización.

Los árboles bayesianos al combinar la estructura clara y jerárquica de los árboles de decisión con la capacidad de actualización dinámica de las probabilidades bayesianas, proporcionan una metodología robusta y flexible para abordar problemas complejos. Su capacidad para manejar la incertidumbre, actualizar información y descomponer problemas en decisiones más simples los hace especialmente útiles en una amplia gama de aplicaciones, incluyendo el proceso de producción de nanomateriales.

1.5 OBJETIVOS E HIPÓTESIS

Objetivo general

- Desarrollar un modelo utilizando árboles bayesianos y la decisión del experto para optimizar el proceso de producción de nanohíbridos usando nanotubos de carbono, nitrato de plata como precursor, y partículas orgánicas como estabilizadores, maximizando su eficiencia y sostenibilidad.

Objetivos específicos

- Establecer los factores que intervienen en el proceso de elaboración de nanohíbridos usando partículas orgánicas como estabilizadores.
- Desarrollar un árbol bayesiano que considere los factores que intervienen en el proceso de elaboración de nanohíbridos con partículas orgánicas y que sirva como herramienta para la toma de decisión para dicho proceso.
- Implementar la decisión del experto en el árbol bayesiano para minimizar la incertidumbre en el proceso de producción de nanohíbridos con partículas orgánicas.

Hipótesis

Es posible el desarrollo de un árbol bayesiano que en combinación con la decisión del experto reduzca la incertidumbre en el proceso de producción de nanohíbridos con NTCs y partículas de plata.

2. MARCO TEÓRICO

El presente capítulo aborda los temas necesarios para establecer el contexto y la relevancia del estudio objeto de esta investigación. En él se revisa la literatura existente, se definen los conceptos clave, y se proporciona el fundamento teórico que sustente la investigación.

2.1 REVISIÓN DE LA LITERATURA

El presente proyecto aborda el tema de creación de nanohíbridos empleando nanotubos de carbono y partículas orgánicas como son cáscara de naranja, cáscara de plátano, hueso de aguacate, ajo y hoja de eucalipto, proponiendo el uso de un árbol bayesiano que, empleando la opinión del experto, permita tomar la decisión que mejores resultados produzca al momento de decidir en el proceso de producción de nanohíbridos. A continuación, se abordan los trabajos más recientes relacionados con árboles bayesianos y los nanohíbridos.

En (Afrabandpey et al., 2019; Afrabandpey et al., 2020) se presenta el trabajo desarrollado para integrar la interpretabilidad en los modelos bayesianos mediante una perspectiva de teoría de decisión. Este trabajo propone un enfoque que separa la creación de un modelo predictivo complejo del diseño de un modelo proxy interpretable, para representar el proceso de generación de datos de manera precisa sin comprometer la claridad en la interpretación.

Este enfoque utiliza un modelo de referencia para obtener alta precisión, mientras que el modelo interpretable funciona como una aproximación que maximiza la comprensión humana. El método permite además ajustar entre la fidelidad de la explicación y la simplicidad, produciendo modelos estables y más interpretables en comparación con los enfoques tradicionales, como los árboles de clasificación y regresión (CART). El método ha sido probado en modelos de árboles aditivos bayesianos y redes neuronales gaussianas, superando enfoques previos al ofrecer mayor estabilidad y precisión en los modelos interpretables resultantes.

En el área de desarrollo de nanohíbridos (Yahyazadeh, 2024) aborda la creación de estos con nanotubos de carbono (NTCs) y su potencial en aplicaciones avanzadas gracias a sus propiedades únicas como alta relación superficie-volumen, conductividad y resistencia mecánica, haciéndolos excelentes plataformas para formar nanohíbridos al combinarse con

materiales orgánicos e inorgánicos. Estos nanohíbridos pueden ajustarse para aplicaciones específicas mediante técnicas de funcionalización química, que mejoran su compatibilidad y estabilidad en diversas matrices. En el trabajo se subraya el papel crucial de los NTCs en el desarrollo de materiales funcionales para aplicaciones en electrónica, energía y biomedicina.

Por otro lado, (Tao et al., 2024) analiza los avances en la tecnología de nanotubos de carbono NTCs y el desarrollo de nanohíbridos, explicando que aquellos, al combinarse con materiales como polímeros, metales y cerámicas, forman nanohíbridos con propiedades mejoradas, tales como mayor resistencia mecánica, conductividad eléctrica y estabilidad térmica. Estos materiales híbridos son altamente versátiles y han mostrado un gran potencial en áreas como almacenamiento de energía y dispositivos electrónicos entre otros. En dicha investigación se destaca la importancia de la funcionalización y los métodos de ensamblaje en la optimización de las propiedades de los nanohíbridos.

(Alali et al., 2022) presenta el trabajo de desarrollo de nanohíbridos a partir de nanotubos de carbono (NTCs), alcohol polivinílico (PVA) y otras especies orgánicas con el propósito de eliminar metales pesados del agua en condiciones extremas. Estos nanohíbridos combinan la alta resistencia mecánica y la estabilidad térmica de los NTCs con la compatibilidad y la capacidad de enlace de las moléculas orgánicas y el PVA. El trabajo destaca cómo la estructura y funcionalización de estos nanohíbridos potencian su eficiencia en la adsorción de metales pesados, debido a las interacciones entre los grupos funcionales del PVA y las partículas de metal. También se resalta que el diseño de estos nanomateriales mejora su rendimiento en ambientes adversos, haciéndolos ideales para aplicaciones de remediación ambiental en tratamiento de agua.

2.2 INCERTIDUMBRE

La incertidumbre se refiere a la falta de certeza o conocimiento completo sobre un evento, resultado o condición. En el contexto científico y de ingeniería, la incertidumbre puede surgir debido a varias razones, como la variabilidad inherente en los sistemas naturales, limitaciones en el conocimiento o en la capacidad de medir y predecir con precisión ciertos fenómenos. La incertidumbre puede afectar la toma de decisiones, ya que puede dificultar la previsión de resultados y la evaluación de riesgos.

Lumbreras 2024 explica la incertidumbre como un factor clave en la toma de decisiones dentro del ámbito de la ingeniería. Según Lumbreras, la incertidumbre surge cuando los ingenieros enfrentan situaciones con información incompleta, ambigua o imprecisa. Esto afecta tanto los procesos técnicos como los resultados finales de los proyectos. La incertidumbre no solo abarca aspectos cuantitativos (falta de datos precisos), sino también cualitativos, como la percepción del riesgo y las variables sociales, lo que exige un enfoque multidisciplinario para gestionar eficientemente estos desafíos.

Por otro lado (Blanco-Mesa, 2017) destaca que la incertidumbre es inherente a muchos procesos de decisión, especialmente cuando se trabaja con información incompleta o imprecisa. Se puede abordar la incertidumbre al incorporar no solo datos cuantitativos, sino también elementos subjetivos y cualitativos, lo que ayuda a mejorar la precisión y flexibilidad en la toma de decisiones bajo condiciones inciertas.

(Luna, 2022) aborda la incertidumbre como un factor crítico que impacta la planificación de la producción en el sector manufacturero e indica que la incertidumbre influye directamente en la toma de decisiones, especialmente en la capacidad de respuesta ante cambios de demanda y condiciones del mercado en el sector manufacturero, lo que hace necesario el uso de enfoques flexibles y robustos para la planificación.

2.2.1 Origen de la Incertidumbre

El origen de la incertidumbre puede atribuirse a múltiples factores, como la falta de información completa o precisa, la complejidad inherente a los sistemas estudiados y las limitaciones en la capacidad humana para predecir eventos futuros. La incertidumbre también surge de la variabilidad natural en fenómenos, errores de medición, y la interpretación subjetiva de datos. En contextos de toma de decisiones, esta incertidumbre puede complicar la evaluación de riesgos y resultados, llevando a decisiones subóptimas. Por lo tanto, comprender y gestionar la incertidumbre es esencial en campos como la ciencia, la economía y la ingeniería.

2.2.1.1 Incertidumbre Aleatoria (Estocástica)

Esta se debe a la variabilidad inherente en los sistemas y procesos. Por ejemplo, las fluctuaciones naturales en la temperatura, presión, y otras condiciones ambientales pueden causar variabilidad en los resultados experimentales.

La incertidumbre estocástica se define como la situación en la que hay variabilidad o aleatoriedad en los parámetros del modelo, lo que significa que no se pueden predecir con certeza los resultados de un proceso (Rios, 2004). A diferencia de los modelos determinísticos, donde se asume que todos los parámetros son conocidos y fijos, los modelos estocásticos incorporan elementos aleatorios que representan la incertidumbre inherente a diversas situaciones en la toma de decisiones. Esto permite a los analistas considerar diferentes escenarios y evaluar cómo la variabilidad en ciertos factores puede afectar el resultado de las decisiones.

Los modelos estocásticos son útiles para resolver problemas en los que los parámetros pueden describirse a través de distribuciones de probabilidad, lo que permite realizar análisis más realistas y efectivos en contextos como la gestión de inventarios, la planificación de la producción, la logística y otros ámbitos dentro de la ingeniería industrial.

2.2.1.2 Incertidumbre Epistémica (De Conocimiento)

La incertidumbre epistémica es definida en (Spiegelhalter, 2023) como el tipo de incertidumbre que surge debido a la falta de conocimiento o información sobre un sistema o fenómeno. A diferencia de la incertidumbre aleatoria, que se relaciona con la variabilidad inherente a los procesos, la incertidumbre epistémica se refiere a las limitaciones en nuestra comprensión o en la información disponible.

Esta forma de incertidumbre puede resultar de múltiples factores, como la falta de datos, la insuficiencia de modelos para describir adecuadamente un fenómeno, o la imprecisión en las mediciones. Para abordar la incertidumbre epistémica, es crucial utilizar enfoques estadísticos adecuados, como la construcción de intervalos de confianza y la aplicación de métodos bayesianos, que permiten incorporar y cuantificar nuestra incertidumbre sobre los parámetros del modelo.

2.2.1.3 Incertidumbre en la Medición

Esta se relaciona con las limitaciones y errores en los instrumentos de medición y técnicas utilizadas para recopilar datos. Factores como la precisión del instrumento, el ruido en los datos y las condiciones de medición pueden contribuir a esta incertidumbre. La incertidumbre es una estimación de la duda sobre el resultado de una medición y es crucial para interpretar adecuadamente los resultados experimentales (Taylor, 2018).

2.2.1.4 Incertidumbre en el Modelo

Los modelos utilizados para predecir o simular fenómenos pueden tener limitaciones debido a simplificaciones, suposiciones y aproximaciones. La incertidumbre en el modelo refleja las diferencias entre las predicciones del modelo y la realidad. Esto incluye dudas sobre la elección del modelo, los supuestos subyacentes y cómo se traducen los datos en conclusiones.

De acuerdo con (Evans, 2018), la incertidumbre en el modelo es un aspecto fundamental de la probabilidad y la estadística, ya que impacta directamente la interpretación de los datos y la calidad de las decisiones basadas en modelos estadísticos. La comprensión y el manejo de esta incertidumbre son esenciales para realizar análisis robustos y fiables en diversas aplicaciones científicas y prácticas.

2.2.1.5 Incertidumbre en los Parámetros

Incluso si el modelo es preciso, los valores de los parámetros utilizados en el modelo pueden ser inciertos. Esto puede deberse a la variabilidad natural, errores en la estimación de los parámetros o falta de datos precisos.

(Evans, 2018) define a los parámetros como características numéricas que describen una población, como la media o la varianza. Dado que estas características no se conocen con certeza en la práctica, la incertidumbre en los parámetros es un aspecto fundamental del análisis estadístico por su relevancia en la inferencia estadística y la toma de decisiones basadas en datos. En este trabajo se hace énfasis en el uso de enfoques bayesianos, que permiten incorporar información previa sobre los parámetros, ayudando a ajustar la incertidumbre de manera más adecuada a la realidad del problema en cuestión

2.2.1.6 Incertidumbre en la Variabilidad Humana

La variabilidad en las habilidades, conocimientos y decisiones de las personas que realizan experimentos o análisis también puede introducir incertidumbre. Diferentes operadores pueden obtener resultados ligeramente diferentes debido a sus técnicas y experiencias (Taylor, 2018). Este tipo de incertidumbre tiene impacto en las mediciones por lo que existe una necesidad de emplear métodos estadísticos y un diseño experimental riguroso para minimizar su efecto.

Considerando lo anterior, se puede decir que la incertidumbre es una parte inherente del conocimiento científico y técnico. Reconocer y cuantificar la incertidumbre es crucial para la toma de decisiones informadas, la evaluación de riesgos y la mejora continua de los métodos y modelos utilizados en la investigación y el desarrollo tecnológico.

2.3 TOMA DE DECISIONES

La toma de decisiones es un proceso fundamental que implica identificar y seleccionar la mejor alternativa entre varias opciones disponibles. Este proceso es crucial tanto en contextos personales como institucionales, y se basa en una serie de técnicas y enfoques que buscan optimizar los resultados de las decisiones tomadas (Rodríguez, 2005).

Es de suma importancia adoptar actitudes y técnicas adecuadas que faciliten el manejo eficaz de problemas y decisiones, ya que la toma de decisiones no solo se basa en la lógica y la razón, sino también en la experiencia y las intuiciones de los individuos. Este enfoque integral es clave para abordar situaciones complejas y generar soluciones efectivas.

Factores como la capacitación en la toma de decisiones tiene una amplia relevancia, ya que el aprendizaje de métodos adecuados puede mejorar significativamente la calidad de las decisiones, minimizando errores y optimizando resultados.

En (Guerrero, 2014) la toma de decisiones se presenta como un proceso fundamental que involucra la selección de una opción entre varias alternativas, considerando tanto la incertidumbre como el riesgo. En dicho trabajo se enfatiza en la importancia de aplicar modelos de decisión que ayuden a los tomadores a evaluar las posibles consecuencias de sus

elecciones. Esto incluye el uso de teorías de probabilidad y análisis de riesgos para maximizar los beneficios esperados y minimizar las pérdidas.

2.3.1 Tipos de Decisiones

(Rodríguez, 2005) identifica diversos tipos de decisiones que se pueden clasificar según distintos criterios.

- Decisiones según el nivel de incertidumbre: Estas se dividen en decisiones seguras, donde se conocen todas las alternativas y sus consecuencias, y decisiones bajo incertidumbre, donde no se dispone de información completa sobre las consecuencias de cada **opción**.
- Decisiones individuales y grupales: Se distingue entre decisiones que toma una sola persona y aquellas que involucran a un grupo. Las decisiones grupales pueden ser más complejas debido a la necesidad de consenso y la influencia de dinámicas grupales.
- Decisiones estratégicas y operativas: Las decisiones estratégicas son de largo plazo y afectan la dirección general de una organización, mientras que las decisiones operativas son más inmediatas y se refieren a la ejecución de tareas diarias.
- Decisiones rutinarias y no rutinarias: Las decisiones rutinarias son aquellas que se toman con frecuencia y pueden automatizarse, mientras que las no rutinarias requieren un análisis más profundo y atención particular.

Por otro lado, en (Guerrero, 2014), se abordan varios tipos de decisiones en el contexto de la toma de decisiones bajo incertidumbre, riesgo, y mediante la aplicación de teoría de juegos, clasificando las decisiones en las siguientes categorías:

- Decisiones bajo incertidumbre: Estas decisiones se toman cuando el resultado es incierto y no se pueden predecir los eventos futuros. El libro describe cómo se utilizan modelos para estimar posibles resultados y evaluar las opciones disponibles.
- Decisiones bajo riesgo: En esta categoría, el autor discute decisiones donde los resultados son inciertos, pero las probabilidades de cada resultado son conocidas. Se

enfatiza el uso de técnicas estadísticas y probabilísticas para evaluar los riesgos asociados a cada opción.

- Teoría de juegos: Se presenta como una herramienta para analizar situaciones donde las decisiones de varios tomadores influyen en los resultados. Aquí, se examinan estrategias óptimas en contextos competitivos y cooperativos.
- Cadenas de Markov: Este enfoque se utiliza para modelar decisiones donde el futuro depende del estado actual, proporcionando un marco para analizar sistemas que evolucionan en el tiempo bajo incertidumbre.

2.3.2 Modelos de toma de decisiones

(Parnell, 2008) propone un enfoque integral para la toma de decisiones en sistemas complejos, utilizando el Systems Decision Process (SDP). Este proceso abarca desde la identificación y definición del problema hasta la implementación de soluciones, destacando la importancia de involucrar a las partes involucradas y evaluar alternativas mediante un enfoque basado en valor.

El SDP consta de cuatro fases: definición del problema, modelado de valor, diseño de soluciones y toma de decisiones finales. En la primera fase, se establecen los requerimientos del sistema y se realiza un análisis de las necesidades de la parte interesada. A partir de ahí, se emplean técnicas cualitativas y cuantitativas, como el análisis multicriterio, la evaluación de riesgos y la optimización, para generar y evaluar posibles alternativas.

Un punto de importancia es la distinción entre el pensamiento centrado en valor y el pensamiento centrado en alternativas. El primero se enfoca en maximizar el valor total del sistema en función de los objetivos, mientras que el segundo examina varias opciones de manera comparativa. La clave para tomar decisiones efectivas radica en utilizar modelos que integren los valores de la parte interesada, optimicen costos y riesgos, y maximicen el rendimiento del sistema dentro de un espacio de diseño viable (Parnell, 2008).

Análisis multicriterio (MCDM): se presenta como un enfoque clave para tomar decisiones cuando existen múltiples criterios conflictivos. Este modelo permite evaluar diferentes alternativas considerando tanto los objetivos cuantitativos como cualitativos. El MCDM

ayuda a los ingenieros a estructurar el proceso de decisión mediante la asignación de pesos a cada criterio y la comparación de las alternativas con base en estos pesos. Es particularmente útil en sistemas complejos donde múltiples factores deben equilibrarse para lograr una solución óptima.

Tradespace Analysis: se describe como una herramienta fundamental para comparar diversas alternativas en función de múltiples criterios, como costo, rendimiento y riesgo. Este análisis permite visualizar las compensaciones entre diferentes soluciones y cómo los cambios en un criterio afectan a otros. El proceso ayuda a identificar opciones óptimas o cercanas a óptimas, al tiempo que se consideran las preferencias de las partes involucradas. Es particularmente útil en la ingeniería de sistemas para gestionar la complejidad y la incertidumbre de los diseños.

Simulación Monte Carlo: es una técnica esencial para la toma de decisiones en situaciones de incertidumbre. Este método permite simular diferentes escenarios al generar múltiples iteraciones de variables aleatorias basadas en distribuciones estadísticas. A través de estas simulaciones, es posible evaluar el impacto de la incertidumbre en variables críticas como costos, tiempos o riesgos, proporcionando una visión más completa y probabilística del desempeño esperado de un sistema. La simulación Monte Carlo se utiliza ampliamente en ingeniería de sistemas para modelar comportamientos inciertos y tomar decisiones más informadas. Es particularmente útil cuando se trabaja con modelos complejos que incluyen muchas variables interdependientes y es difícil predecir los resultados de manera determinista. Además, ayuda a identificar las probabilidades de éxito o fracaso de diferentes alternativas, lo que mejora la gestión de riesgos en los proyectos de ingeniería

Árboles de decisión: son una herramienta visual eficaz para descomponer decisiones complejas en una serie de opciones más simples y manejables. Un árbol de decisión permite mapear diferentes cursos de acción, mostrando posibles decisiones, eventos inciertos (como riesgos o contingencias), y los resultados esperados asociados a cada combinación de decisiones y eventos. Cada nodo del árbol representa un punto de decisión o una incertidumbre, y las ramas que se despliegan de los nodos muestran las alternativas o posibles eventos que siguen. Estas estructuras son especialmente útiles cuando se trata de decisiones secuenciales, ya que permiten a los tomadores de decisiones visualizar las implicaciones a

largo plazo de sus elecciones y los diferentes caminos que pueden seguir según cómo se desarrollen los eventos. Además, esta técnica facilita la identificación de la mejor estrategia global, incluso en condiciones de incertidumbre, ya que permite calcular el valor esperado de cada posible camino. Esto implica asignar probabilidades a los eventos inciertos y utilizar estas probabilidades para comparar las diferentes alternativas, basándose en un enfoque cuantitativo. Por lo anterior los árboles de decisión son herramientas importantes en el análisis de riesgos, ya que ayudan a gestionar la incertidumbre y a evaluar el impacto potencial de diversas opciones

2.3.3 Factores que influyen en la toma de decisiones

Para una adecuada toma de decisiones se deben identificar los objetivos claramente, ya que las decisiones deben alinear las soluciones con los fines deseados, como maximizar beneficios o minimizar costos. También se debe considerar la importancia de los criterios múltiples, ya que muchas decisiones requieren equilibrar factores que podrían entrar en conflicto, como calidad, tiempo y costo (Taha, 2011).

Otro factor clave es la incertidumbre, que puede influir en los resultados de las decisiones. Para mitigar esto, se emplean herramientas como el análisis probabilístico o la programación estocástica. Además, el papel de las restricciones, que limitan las opciones disponibles; por ejemplo, los recursos limitados de tiempo, dinero o personal pueden afectar las decisiones.

Por otro lado, los modelos matemáticos son considerados un soporte esencial para tomar decisiones informadas, proporcionando una base lógica y cuantitativa para evaluar diferentes alternativas. A través de técnicas como la programación lineal, el análisis de inventarios o la teoría de colas, los modelos ayudan a evaluar las mejores opciones de manera sistemática, permitiendo decisiones más eficientes y óptimas.

2.3.4 Implementación y evaluación de decisiones

(Goodwin, 2014) resalta el empleo de principios cuantitativos y cualitativos para mejorar la calidad de sus decisiones en entornos de incertidumbre, y para el proceso de implementación de decisiones hace énfasis en puntos clave como:

- Factores humanos: La implementación de decisiones no es solo un proceso técnico, sino que depende en gran medida de los aspectos humanos y organizacionales. La resistencia al cambio, la comunicación ineficaz y la falta de compromiso pueden obstaculizar la implementación exitosa.
- Planificación cuidadosa: La toma de decisiones no termina una vez que se ha seleccionado una opción. Es crucial tener un plan claro y detallado sobre cómo implementar la decisión. Este plan debe incluir pasos concretos, asignación de responsabilidades y un cronograma claro.
- Alineación con los objetivos: La decisión debe estar alineada con los objetivos estratégicos de la organización. Si no existe esa alineación, es probable que la implementación enfrente obstáculos o no produzca los resultados esperados.
- Adaptación y flexibilidad: Durante el proceso de implementación, pueden surgir imprevistos que requieran ajustar la estrategia. Es importante que el equipo sea flexible y esté dispuesto a modificar el enfoque según sea necesario.

Respecto a la evaluación de decisiones, (Goodwin, 2014) indica que se deben de considerar los siguientes elementos:

- Monitoreo continuo: Una vez implementada, la decisión debe ser monitoreada continuamente para evaluar su efectividad. El uso de indicadores de desempeño es clave para determinar si la decisión está generando los resultados esperados.
- Retroalimentación y ajustes: La retroalimentación es esencial para aprender de la decisión implementada. Si se descubren problemas o si los resultados no son los esperados, es necesario hacer ajustes oportunos.
- Evaluación del proceso: Además de evaluar los resultados, es igualmente importante evaluar el proceso de toma de decisiones en sí. Esto incluye analizar si se utilizaron correctamente las herramientas de análisis, si se consideraron todas las alternativas relevantes y si se evitaron sesgos cognitivos.
- Lecciones aprendidas: Después de evaluar el resultado y el proceso, la organización debe extraer lecciones para mejorar futuras decisiones. Esto contribuye a una cultura de aprendizaje continuo dentro de la empresa.

Tanto la implementación como la evaluación son componentes críticos del proceso de toma de decisiones. No basta con elegir una buena opción; es necesario gestionarla adecuadamente y aprender de la experiencia para mejorar la toma de decisiones en el futuro.

2.4 ÁRBOLES DE DECISIÓN

Un árbol de decisión se describe como una herramienta gráfica utilizada para representar y analizar decisiones que implican una serie de alternativas y resultados posibles. Los árboles de decisión permiten visualizar las opciones disponibles, los eventos que pueden ocurrir y sus probabilidades asociadas, facilitando así la evaluación de las posibles consecuencias de cada elección. Cada nodo del árbol representa una decisión o un evento incierto, y las ramas conectan las decisiones con los posibles resultados. En ingeniería industrial, los árboles de decisión son útiles para problemas complejos que involucran múltiples criterios y escenarios, ayudando a los ingenieros a estructurar el proceso de toma de decisiones de manera lógica y cuantitativa. Además, el libro destaca cómo los árboles de decisión se integran con otros métodos de análisis multicriterio para optimizar decisiones en entornos industriales (Eiselt, 2013) (Evans, 2016).

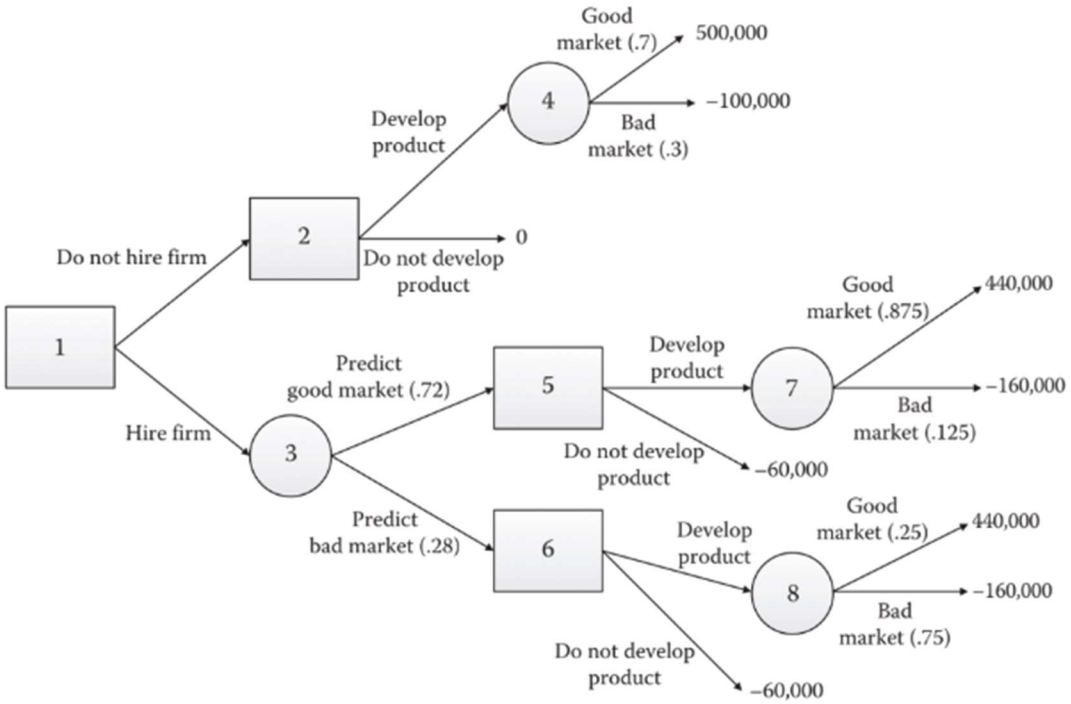

Figura 1. Ejemplo de árbol de decisión (Evans, 2016).

2.4.1 Componentes y construcción de un árbol de decisión

A continuación, se describen los componentes clave de un árbol de decisión:

- Nodos de Decisión: Representan los puntos en los que se debe tomar una decisión. En un diagrama de árbol de decisión, estos nodos generalmente se representan como cuadrados. En cada nodo de decisión, se enumeran las alternativas o acciones disponibles que pueden tomarse.
- Nodos de Evento o Azar: Representan puntos donde ocurren eventos aleatorios o situaciones fuera del control del decisor. Se muestran como círculos. Estos nodos describen los resultados inciertos que pueden suceder tras una decisión, junto con sus probabilidades asociadas.
- Ramas: Las ramas conectan los nodos de decisión y los nodos de azar, representando las diversas opciones que se pueden tomar en un nodo de decisión y los posibles resultados de los eventos inciertos. Cada rama que sale de un nodo de azar está asociada con una probabilidad que indica la probabilidad de ocurrencia de un resultado en particular.
- Resultados o Pagos: Al final de cada rama, se encuentran los resultados finales o valores de pago. Estos indican los beneficios, costos o utilidades que se obtendrán al seguir un determinado camino de decisiones y resultados. Los resultados pueden cuantificarse en función de criterios de decisión múltiples. Esto implica no solo un análisis de costos y beneficios, sino también otros criterios relevantes.
- Análisis Retroactivo (Backwards Induction): Una vez que se ha trazado el árbol de decisión, el análisis implica evaluar el árbol hacia atrás (desde los nodos finales hacia los nodos iniciales), utilizando las probabilidades y los pagos para seleccionar el mejor curso de acción en cada nodo de decisión. En este análisis, se combinan tanto los factores probabilísticos como los múltiples criterios de decisión.

Los árboles de decisión permiten estructurar problemas complejos, evaluar varias alternativas y tomar decisiones fundamentadas bajo incertidumbre, integrando la probabilidad de ocurrencia y múltiples criterios de análisis (Evans, 2016).

El proceso de construcción de un árbol de decisión involucra los siguientes pasos:

- Definir el Problema de Decisión: El primer paso es identificar claramente el problema que se va a resolver. Esto implica definir el objetivo, las alternativas disponibles, y los criterios relevantes que se utilizarán para evaluar esas alternativas.
- Identificar las Decisiones y Alternativas: Se deben identificar los puntos de decisión clave, es decir, los momentos en los que el decisor tiene que elegir entre varias alternativas. Estos se representan como nodos de decisión en el árbol. Cada alternativa posible debe estar claramente definida, ya que será una rama que sale del nodo de decisión.
- Determinar los Resultados Aleatorios: Es crucial identificar los factores o eventos inciertos que pueden influir en los resultados después de tomar una decisión. Estos eventos se modelan como nodos de azar o probabilísticos en el árbol de decisión. Para cada nodo de azar, se deben enumerar los posibles resultados que pueden ocurrir, junto con sus probabilidades estimadas.
- Asignar Probabilidades a los Eventos: Para los nodos de azar, es necesario asignar probabilidades a cada uno de los posibles resultados. Estas probabilidades deben estar basadas en datos históricos, simulaciones o juicios expertos. En el caso de múltiples criterios, las probabilidades pueden estar relacionadas con diferentes escenarios, lo que influye en la selección del criterio más adecuado.
- Determinar los Valores de Pago o Resultados Finales: En cada rama terminal (es decir, al final del árbol), se deben especificar los valores de pago o resultados finales para cada combinación de decisiones y eventos. Estos pueden incluir costos, ingresos, utilidades, o cualquier otro criterio de decisión relevante. Desde el enfoque de análisis de decisiones multicriterio, los pagos pueden incluir múltiples factores, como el tiempo, el costo y la eficiencia, que deben ser ponderados adecuadamente.
- Una vez que se han definido todos los nodos, ramas y resultados, el árbol de decisión se puede representar gráficamente. Se empieza con un nodo de decisión inicial y se trazan las ramas correspondientes a las alternativas y los eventos aleatorios. Cada nodo se conecta a sus respectivos nodos subsiguientes (nodos de decisión o de azar), y el árbol se ramifica hasta llegar a los resultados finales.

- Análisis Retroactivo (Evaluación del Árbol): El siguiente paso es evaluar el árbol mediante el proceso de análisis retroactivo (backward induction). Se comienza desde los nodos finales y se procede hacia atrás, calculando los valores esperados en cada nodo de azar (combinando los pagos y las probabilidades). El decisor elige la alternativa que maximice el valor esperado en cada nodo de decisión. En un contexto multicriterio, el análisis puede involucrar la comparación de diferentes criterios y el uso de técnicas como la ponderación de criterios** para seleccionar la mejor alternativa.

Es común que en el proceso de toma de decisiones haya múltiples criterios en juego, como costos, calidad, tiempo, riesgo y otros factores relevantes. Durante la construcción del árbol, es necesario tener en cuenta estos criterios a la hora de asignar los resultados finales y analizar el árbol. Se pueden aplicar métodos de ponderación o incluso técnicas de optimización multicriterio para ayudar a identificar el camino que maximice el rendimiento general en función de varios factores simultáneamente.

El proceso de construcción de un árbol de decisión implica una cuidadosa planificación, modelado y análisis de las decisiones y los eventos inciertos. El uso de árboles de decisión no solo ayuda a estructurar y visualizar decisiones complejas, sino que también permite evaluar alternativas considerando múltiples criterios de rendimiento.

2.4.2 Evaluación de riesgos y probabilidades

Dentro del contexto de los árboles de decisión, la evaluación de riesgos y el cálculo de probabilidades es fundamental para la toma de decisiones. (Parnell, 2008) indica que para la evaluación de riesgos se debe:

- Identificar riesgos: Un aspecto crítico en la toma de decisiones es la identificación de los riesgos asociados a cada alternativa. En un árbol de decisión, estos riesgos se modelan en los nodos de azar, que representan eventos inciertos que pueden tener un impacto significativo en el resultado final. Los riesgos pueden surgir de diversos factores: fallos técnicos, incertidumbres económicas, fluctuaciones en los tiempos de entrega, entre otros.

- Cuantificación del Impacto del Riesgo: Una vez identificados los riesgos, es necesario cuantificar su impacto. Esto se hace determinando el efecto de los eventos inciertos en los resultados finales del árbol de decisión. El impacto puede expresarse en términos de costos, retrasos, pérdidas de rendimiento, o cualquier otro criterio relevante. La cuantificación multicriterio es particularmente importante en sistemas de ingeniería, donde múltiples objetivos, como costos, calidad y tiempo, deben ser evaluados de manera simultánea.
- Gestión de Riesgos: Una vez que los riesgos han sido identificados y cuantificados, se pueden desarrollar medidas preventivas, o bien plantear un plan de contingencias o bien, la selección de alternativas, que minimicen la exposición a riesgos críticos.

2.4.4 Evaluación de Probabilidades en Árboles de Decisión

Durante la construcción de un árbol de decisión, se deben considerar los siguientes elementos para la evaluación de probabilidades:

1. Asignación de Probabilidades a Nodos de Azar: Para cada nodo de azar (nodos que representan eventos inciertos), es crucial asignar probabilidades que reflejen la incertidumbre en el sistema. Estas probabilidades son fundamentales para calcular el valor esperado de cada decisión. Las probabilidades pueden obtenerse de datos históricos, juicios de expertos, simulaciones o modelos estadísticos. En la ingeniería de sistemas, el uso de modelos de simulación o análisis de datos probabilísticos puede ser clave para obtener estimaciones precisas.

2. Uso de Probabilidades Condicionales: En sistemas complejos, los eventos pueden no ser independientes. En estos casos, se utiliza el concepto de probabilidades condicionales, donde la probabilidad de que ocurra un evento puede depender del resultado de decisiones anteriores o de otros eventos. Los árboles de decisión permiten modelar estas relaciones condicionales de forma estructurada, lo que mejora la capacidad para evaluar escenarios múltiples y cómo se desarrollan en función de decisiones previas.

3. Valor Esperado y Utilidad Esperada: Después de asignar las probabilidades y los valores de pago, se puede plasmar el valor esperado como criterio para evaluar y comparar alternativas. El valor esperado es una medida que combina tanto los pagos esperados como las probabilidades de ocurrencia de los distintos resultados. En situaciones donde se involucran preferencias o actitudes hacia el riesgo, el análisis del valor esperado de la utilidad puede ser más adecuado. La utilidad mide el grado de satisfacción o preferencia que un decisor tiene por un resultado, lo que permite incorporar consideraciones de aversión o tolerancia al riesgo en el análisis.

2.4.5 Incertidumbre y sensibilidad en los árboles de decisión

(Parnell, 2008) destaca la importancia de realizar un análisis de sensibilidad sobre las probabilidades asignadas y los valores de pago. Esto ayuda a evaluar qué tan robustas son las decisiones tomadas frente a cambios en las estimaciones de probabilidades o impactos. Un análisis de sensibilidad puede revelar si una decisión óptima bajo ciertas condiciones sigue siendo válida si cambian las probabilidades de ciertos eventos o los costos asociados.

En el contexto de la ingeniería, la evaluación de riesgos y probabilidades es particularmente crítica porque los sistemas complejos involucran múltiples niveles de incertidumbre, como en el diseño de grandes infraestructuras, sistemas tecnológicos o procesos de fabricación. Los árboles de decisión proporcionan una estructura clara para integrar incertidumbres técnicas, financieras y operativas y para tomar decisiones que maximizan el rendimiento general del sistema bajo análisis.

La evaluación precisa de los riesgos y las probabilidades empleando árboles de decisión es de gran importancia ya que permite tomar decisiones más informadas y optimizar los resultados en situaciones de incertidumbre, integrando tanto el análisis probabilístico como las estrategias de gestión de riesgos en sistemas complejos.

2.5 ÁRBOLES BAYESIANOS

De acuerdo con (Gerlman, 2014) los árboles bayesianos pueden considerarse como una extensión de los métodos de clasificación y regresión, aplicando el marco bayesiano para manejar incertidumbres en modelos jerárquicos. Se utilizan para modelar relaciones complejas entre variables mediante la estructuración de datos en forma de árbol, donde cada nodo representa una división basada en decisiones probabilísticas. El enfoque bayesiano permite incorporar distribuciones previas y actualizar las creencias sobre los parámetros del modelo conforme se dispone de nuevos datos.

Por otro lado, en (Nielsen, 2013) los árboles bayesianos son descritos como una representación gráfica y probabilística que combina las ventajas de los árboles de decisión con las redes bayesianas. Los árboles bayesianos permiten descomponer problemas complejos en estructuras jerárquicas más simples, facilitando el cálculo eficiente de probabilidades.

Los árboles bayesianos son de utilidad en la toma de decisiones bajo incertidumbre, además de que tienen gran capacidad para manejar datos incompletos.

2.5.1 Inferencia bayesiana

La inferencia bayesiana es considerada una técnica clave para actualizar la certidumbre sobre parámetros a partir de datos observados, ya que combina una distribución previa sobre los parámetros con la verosimilitud basada en datos para obtener una distribución posterior, que refleja el conocimiento actualizado tras observar los datos. Este enfoque es especialmente útil en situaciones de incertidumbre, ya que permite incorporar conocimientos previos de forma explícita. También la inferencia bayesiana permite la regularización y la prevención del sobreajuste, debido a que la inclusión de distribuciones previas puede moderar las estimaciones de parámetros extremos, particularmente en modelos complejos o con conjuntos de datos pequeños (Hastie,2009).

La inferencia bayesiana permite tomar decisiones óptimas bajo incertidumbre al integrar nueva evidencia con conocimientos previos.

2.5.2 Estructura de los árboles bayesianos

Un árbol bayesiano es una estructura donde las decisiones se representan como nodos, y las ramas que salen de esos nodos reflejan probabilidades condicionales que siguen la lógica bayesiana. En lugar de simplemente tomar decisiones secuenciales, los árboles bayesianos permiten asignar distribuciones de probabilidad a cada nodo, permitiendo incorporar la incertidumbre inherente a la estructura de los datos. Esto distingue a los árboles bayesianos de los métodos clásicos de árboles de decisión, donde cada decisión es definitiva (Gelman, 2014).

La estructura de un árbol bayesiano combina la lógica de los árboles de decisión y la potencia probabilística de las redes bayesianas. En lugar de un enfoque determinista, en el que cada rama de un árbol de decisión clásico representa una elección definitiva, un árbol bayesiano utiliza nodos y ramas para expresar distribuciones de probabilidad condicional, modelando la incertidumbre en cada paso.

En cada etapa del árbol se pueden ajustar las probabilidades de acuerdo con distribuciones previas y nueva evidencia obtenida. La estructura de los árboles en el marco bayesiano es flexible y permite regularización, lo que los convierte en una herramienta poderosa para evitar el sobreajuste en datos complejos. Esto se logra a través de la incorporación de distribuciones previas, que funcionan como un medio para controlar los parámetros del modelo y suavizar el impacto de decisiones extremas (Nielsen, 2013).

Un aspecto clave que se debe destacar sobre los árboles bayesiano y su estructura es que se pueden implementar algoritmos eficientes, como la propagación de creencias, para realizar inferencias en árboles y redes bayesianas complejas. La estructura jerárquica y probabilística del árbol permite modelar relaciones no triviales entre las variables, y la inferencia bayesiana facilita la actualización de las probabilidades posteriores conforme se observan nuevas evidencias.

Además, los **árboles bayesianos** permiten manejar datos incompletos y realizar inferencia predictiva al integrar evidencias observadas con los conocimientos previos del modelo. En (Nielsen, 2013) se subraya que los árboles bayesianos son útiles en aplicaciones que requieren la representación explícita de dependencias causales, como el diagnóstico médico o los sistemas de toma de decisiones autónomas, enfatizando la estructura gráfica y

probabilística de los árboles, donde las relaciones entre las variables están claramente definidas por las probabilidades condicionales y las dependencias causales.

Por otro lado, (Hastie, 2009) indica que los árboles bayesianos se presentan como una extensión bayesiana de los árboles de decisión clásicos. En contraste con los árboles de decisión convencionales, los árboles bayesianos permiten incorporar distribuciones de probabilidad y, por tanto, manejar la incertidumbre de manera más robusta.

Los árboles bayesianos se destacan por su capacidad para dividir el espacio de características en regiones más manejables, similar a los árboles de decisión, pero con la diferencia crítica de que cada partición incluye una distribución de probabilidad sobre los resultados.

En términos de estructura, los árboles bayesianos se construyen utilizando particiones sucesivas del espacio de entrada, donde cada partición lleva asociada una distribución predictiva. Esto los hace particularmente efectivos para manejar datos ruidosos o incompletos, ya que pueden representar explícitamente la incertidumbre en las predicciones.

2.5.3 Construcción de un árbol bayesiano

(Gelman, 2014) plantea la construcción de un árbol bayesiano con un enfoque gráfico y jerárquico para representar problemas de inferencia bayesiana. Un árbol bayesiano combina nodos que representan variables y probabilidades condicionadas para modelar la relación entre ellas. El proceso comienza definiendo distribuciones previas para las variables iniciales y luego, con datos observados, se ajustan las distribuciones posteriores a través de reglas bayesianas. Estos árboles son útiles para descomponer problemas complejos en estructuras más manejables y visuales dentro del enfoque probabilístico.

Por otro lado (Nielsen, 2013) propone para la creación de un árbol bayesiano, comenzar identificando las variables relevantes y las relaciones de dependencia causal entre ellas. Luego, se representa gráficamente, con nodos que simbolizan variables y arcos que indican las relaciones de dependencia condicional entre ellas. Cada nodo contiene una distribución de probabilidad condicional que se ajusta en base a la información disponible. Las probabilidades condicionales se asignan basándose en datos empíricos, investigaciones previas y el juicio experto.

Toda vez que el árbol bayesiano ha sido estructurado, y se desea calcular la probabilidad de que suceda un evento determinado, el cálculo de lleva a cabo utilizando la regla de la cadena y las probabilidades condicionales. Con las probabilidades calculadas, se puede comparar la efectividad de qué sucedan diferentes eventos.

2.5.4 Aplicaciones prácticas de los árboles bayesianos

Las aplicaciones prácticas de los árboles bayesianos se centran en la representación de dependencias probabilísticas en problemas complejos. Estas estructuras jerárquicas son útiles en áreas como la biología, la ingeniería para modelar incertidumbres y actualizar creencias con nueva evidencia. Los árboles permiten desglosar problemas en subcomponentes más simples, facilitando la inferencia de variables ocultas y el cálculo de probabilidades posteriores, lo que mejora la toma de decisiones en sistemas con incertidumbre (Gelman, 2014).

Otras áreas de aplicación de los árboles son la inteligencia artificial, diagnóstico médico, y análisis de riesgos. Los modelos permiten representar relaciones de dependencia probabilística entre variables, lo que es útil para tomar decisiones en entornos inciertos. Se emplean en la toma de decisiones bajo incertidumbre, por ejemplo, en medicina para diagnosticar enfermedades basándose en síntomas, o en ingeniería para evaluar fallos en sistemas complejos. También destacan su capacidad para integrar datos incompletos y proporcionar resultados robustos a través de simulaciones.

2.6 DECISIÓN DE LOS EXPERTOS

Un experto es una persona que ha adquirido un nivel avanzado de conocimiento y habilidades en un área específica a través de años de práctica y experiencia sistemática. Los expertos suelen reconocer patrones y tomar decisiones intuitivas basadas en su experiencia, lo que les permite evaluar y actuar en situaciones complejas de manera rápida y precisa (Hardman, 2009).

La experticia implica un proceso continuo de aprendizaje y adaptación; el experto no solo acumula información, sino que también organiza y aplica su conocimiento de manera que

otros no expertos no pueden. Esto se traduce en una capacidad para identificar información relevante, descartar la irrelevante y procesar los datos eficientemente, lo que los distingue de quienes tienen solo un conocimiento superficial en el mismo campo.

Los expertos toman decisiones de manera diferente a los no expertos y, aunque los expertos suelen tomar decisiones más precisas y confiables en sus campos, también son susceptibles a ciertos sesgos y limitaciones. Los expertos desarrollan intuición basada en patrones observados a lo largo de sus experiencias. Esta intuición permite una toma de decisiones más rápida y, a menudo, acertada en contextos específicos, aunque puede fallar en situaciones inusuales o novedosas.

Los expertos utilizan su conocimiento especializado para filtrar la información relevante y reducir la complejidad en sus decisiones. Sin embargo, su especialización también puede limitar su capacidad para considerar perspectivas fuera de su área de conocimiento.

Por otro lado, (Bolger, 2007) destaca que los expertos se caracterizan por su capacidad para manejar situaciones inciertas y dinámicas, aplicando heurísticas y estrategias que les permiten hacer frente a problemas complejos. Este conocimiento, sin embargo, está limitado al ámbito de su especialización, ya que fuera de este contexto sus habilidades pueden no ser tan efectivas o incluso fallar.

2.6.1 Decisión Experta

La toma de decisiones expertas es un proceso que requiere el uso de modelos estructurados y herramientas analíticas para evaluar opciones en entornos complejos. Este tipo de decisiones se basa en un conocimiento especializado y en la capacidad de aplicar métodos avanzados, como la optimización y el análisis multicriterio, para manejar factores múltiples y variables inciertas (Bautista, 2020).

La decisión experta implica también una evaluación rigurosa de los riesgos y beneficios asociados a cada alternativa. Los modelos, como la teoría de juegos o los métodos de decisión bajo incertidumbre, son fundamentales para que los expertos tomen decisiones informadas y reduzcan la subjetividad, maximizando la precisión en sus resultados

(Bolger, 2007) define la "decisión experta" como un proceso en el cual los expertos proporcionan juicio cualitativo y cuantitativo para apoyar predicciones y decisiones en condiciones de incertidumbre. Las decisiones expertas son especialmente relevantes cuando los datos históricos son limitados o el entorno es incierto, lo que requiere una integración de experiencia y métodos de apoyo a decisiones que puedan manejar la complejidad y anticipar escenarios futuros. La efectividad de la decisión experta depende de factores como la precisión del juicio de incertidumbre y la claridad de la tarea.

2.6.2 Modelos y métodos para la decisión experta

El uso de modelos y métodos matemáticos y computacionales en la toma de decisiones es frecuente para el apoyo en entornos complejos. (Bautista, 2020) indica que los modelos se construyen para simplificar y estructurar problemas complejos, permitiendo a los tomadores de decisiones analizar múltiples alternativas y evaluar riesgos asociados. Dentro de los modelos de decisión que pueden aplicarse en contextos de decisión experta, donde se requiere un alto nivel de análisis y precisión se encuentran el Modelo de decisión multicriterio, los Modelos de decisión bajo incertidumbre, la Teoría de juegos, la Programación dinámica y las Metaheurísticas. Cada uno de estos modelos está diseñado para ayudar a los expertos a estructurar, analizar y tomar decisiones en contextos técnicos y organizacionales.

2.7 NANOTUBOS DE CARBONO

Lo nanotubos de carbono (CNTs) forma parte de una gama de materiales que se destacan por su estructura única y sus excepcionales propiedades, como la alta resistencia mecánica y la conductividad eléctrica. Los nanotubos de carbono han adquirido importancia en años recientes debido a sus diversas aplicaciones tecnológicas en las que tienen aplicación, desde la electrónica hasta la medicina, por lo que tienen un papel destacado en el desarrollo de nuevos compuestos y dispositivos innovadores (O'Leary, 2018).

2.7.1 Definición y estructura

Los nanotubos de carbono son definidos como estructuras cilíndricas formadas por átomos de carbono dispuestos en una red hexagonal (Álvarez, 2014). Estas estructuras pueden considerarse como una forma de grafito en forma de tubo, y presentan propiedades excepcionales como alta resistencia mecánica y conductividad eléctrica. Los nanotubos se clasifican generalmente en nanotubos de carbono de una sola pared (SWNT) y de múltiples paredes (MWNT), cada uno con aplicaciones potenciales en nanocompuestos, electrónica y materiales avanzados (Poole, 2023).

La estructura de los nanotubos de carbono tiene una configuración cilíndrica compuesta por átomos de carbono dispuestos en una red hexagonal similar a la del grafeno. Esta estructura puede ser de tipo "zig-zag" o "quiral", dependiendo de cómo se enrolla la hoja de grafeno para formar el tubo.

Por otro lado, en (O'Leary, 2018) se indica que los nanotubos de carbono se componen de capas de átomos de carbono dispuestas en una forma tubular. Su estructura es esencial para entender sus propiedades únicas, como la conductividad eléctrica y la resistencia mecánica, además de que los nanotubos pueden ser de diferentes tipos, como los semiconductores o conductores, dependiendo de su disposición atómica y la forma en que están enrollado

2.7.2 Propiedades electrónicas, mecánicas y térmicas.

Las propiedades electrónicas, mecánicas y térmicas de los nanotubos de carbono (CNT) son características fundamentales que determinan su aplicabilidad en diversas tecnologías y que permiten comprender su potencial en diversas aplicaciones (O'Leary, 2018). A continuación se abordan cada una de ellas:

- Propiedades Electrónicas: Los CNT pueden actuar como conductores o semiconductores, dependiendo de su estructura y forma de enrollamiento. Esta dualidad se debe a la forma en que los átomos de carbono están dispuestos y su capacidad para permitir el movimiento de electrones a lo largo de su longitud, lo que los hace prometedores para aplicaciones en electrónica avanzada.

- Propiedades Mecánicas: Los nanotubos de carbono son extremadamente fuertes, superando al acero en resistencia a la tensión. Esto se debe a la robustez de los enlaces covalentes que forman su estructura tubular, lo que les confiere una alta rigidez y elasticidad. Pueden ser doblados o torcidos sin romperse, lo que los hace útiles en materiales compuestos y estructuras que requieren alta resistencia con bajo peso.
- Propiedades Térmicas: Los CNT son excelentes conductores de calor, permitiendo una eficiente transferencia de energía térmica. Esto los hace valiosos en aplicaciones que requieren gestión térmica, como en dispositivos electrónicos donde el calentamiento puede ser un problema.

En resumen, las propiedades únicas de los nanotubos de carbono los hacen altamente versátiles, con aplicaciones que van desde la electrónica hasta la ingeniería de materiales.

2.7.3. Clasificación de los nanotubos de carbono

(Poole, 2023) describe a los nanotubos de carbono como estructuras cilíndricas de carbono que pueden ser de una sola pared (SWCNT) o de múltiples paredes concéntricas (MWCNT). Los nanotubos de una sola pared se componen de una única capa de átomos de carbono organizados en una estructura tubular, mientras que los de múltiples paredes constan de varias capas enrolladas unas sobre otras. Ambos tipos exhiben propiedades únicas, con aplicaciones en electrónica y materiales debido a su alta resistencia mecánica, conductividad térmica y, en algunos casos, conductividad eléctrica dependiente de la estructura atómica. Estas características diferencian y potencian a cada tipo de nanotubo según sus aplicaciones potenciales en distintos campos.

- **SWCNT (Single-Walled Carbon Nanotubes)**: Los nanotubos de una sola pared consisten en una capa única de átomos de carbono enrollada en un cilindro. Debido a su estructura, tienen propiedades electrónicas únicas que pueden variar entre semiconductoras y metálicas. Estas características los hacen valiosos para aplicaciones en electrónica, como transistores y sensores, debido a su alta conductividad y pequeño tamaño.
- **MWCNT (Multi-Walled Carbon Nanotubes)**: Los nanotubos de múltiples paredes constan de varias capas concéntricas de grafeno enrolladas en forma de cilindros. Su

estructura les otorga una mayor resistencia mecánica en comparación con los SWCNT. Sin embargo, suelen tener propiedades electrónicas menos versátiles, siendo predominantemente conductores. Son útiles en aplicaciones que requieren durabilidad y resistencia, como refuerzos en materiales compuestos.

2.7.4 Métodos de Síntesis de Nanotubos de Carbono

Entre los métodos clave para la síntesis de nanotubos de carbono, se puede mencionar ablación láser, la descarga de arco y la deposición química de vapor (CVD). Estos métodos permiten crear nanotubos con diversas propiedades estructurales y electrónicas. La técnica de CVD es popular por su capacidad de producir nanotubos de una sola pared (SWCNT) y múltiples paredes (MWCNT) en condiciones controladas, siendo útil en aplicaciones industriales y en la investigación avanzada de materiales nanoscópicos (Hornyak,2018).

- Síntesis por deposición de vapor químico (CVD): El método de deposición química de vapor es una técnica clave para la síntesis de nanotubos de carbono. Este método utiliza gases hidrocarbonados descompuestos en presencia de un catalizador metálico y calor para formar nanotubos en superficies específicas. La técnica CVD permite producir nanotubos de una o varias paredes (SWCNT y MWCNT) de manera controlada, siendo efectiva en la producción a escala industrial debido a su precisión y adaptabilidad en el ajuste de parámetros para lograr propiedades deseadas en los nanotubos.
- Síntesis por arco eléctrico y métodos de láser: La síntesis por arco eléctrico y la síntesis mediante láser son técnicas pioneras para producir nanotubos de carbono. La síntesis por arco eléctrico utiliza un arco de alta corriente para vaporizar carbono en presencia de un catalizador, formando nanotubos en condiciones de alta temperatura. En la síntesis por láser, un láser de alta energía vaporiza un blanco de grafito con catalizadores, generando nanotubos con alta pureza y control en las dimensiones estructurales. Ambos métodos son efectivos para producir nanotubos de carbono con propiedades avanzadas para aplicaciones tecnológicas.

2.7.4 Aplicaciones de los Nanotubos de Carbono

Las aplicaciones de los CNTs incluyen electrónica, materiales compuestos y dispositivos médicos. En electrónica, se usan en transistores, sensores y pantallas debido a su conductividad excepcional. En materiales compuestos, mejoran la resistencia mecánica y reducen el peso de polímeros y metales, siendo útiles en la industria aeroespacial. En medicina, los nanotubos se exploran como vehículos de administración de fármacos y en terapias de cáncer debido a su capacidad para penetrar células.

2.7.4.1 Uso en dispositivos electrónicos y sensores

Las propiedades eléctricas y mecánicas de los nanotubos de carbono permite usarlos en dispositivos electrónicos y sensores avanzados como, por ejemplo, actuando como conductores o semiconductores, lo que les permite reemplazar al silicio en transistores de tamaño nanométrico. Esto mejora la velocidad de los circuitos y reduce el consumo de energía en dispositivos electrónicos. Por otro lado, la excelente conductividad y estabilidad de los nanotubos facilitan su integración en pantallas OLED y dispositivos LED, donde ofrecen alta luminosidad y bajo consumo energético.

Finalmente, los nanotubos son extremadamente sensibles a cambios en su entorno, lo que los hace ideales para detectar gases, compuestos químicos y variaciones de temperatura. Estos sensores pueden identificar sustancias en concentraciones muy bajas y son aplicables en monitoreo ambiental, seguridad y dispositivos médicos. Los nanotubos de carbono siguen ampliando su aplicación en áreas como almacenamiento de energía y procesamiento de datos, debido a su adaptabilidad y rendimiento a nanoescala.

2.7.4.2 Aplicaciones en la industria de materiales compuestos

La estructura de los nanotubos les proporciona propiedades únicas: alta resistencia mecánica, bajo peso, excelente conductividad eléctrica y térmica, y estabilidad química. Esto los convierte en un componente de gran interés en la industria de materiales compuestos, donde suelen emplearse como refuerzos o aditivos en matrices poliméricas, cerámicas y metálicas para mejorar diversas propiedades (Singh, 2003).

Los CNTs se utilizan como refuerzos en materiales compuestos debido a su resistencia a la tracción, que es aproximadamente 100 veces mayor que la del acero, pero con solo una fracción de su peso. Cuando se incorporan en matrices poliméricas, pueden mejorar la resistencia y rigidez del material sin incrementar su densidad. estos refuerzos son ideales para aplicaciones en las industrias aeroespacial y automotriz, donde reducir el peso y mejorar la resistencia son factores clave. Los vehículos y aviones fabricados con materiales compuestos reforzados con CNTs pueden lograr un rendimiento energético superior, debido a la reducción de peso y a la mayor resistencia a la deformación (Tao, 2024).

Por otra parte, los CNTs poseen una excelente conductividad eléctrica, lo que los convierte en aditivos atractivos para crear materiales compuestos conductores. Estos compuestos pueden aplicarse en electrónica, como pantallas táctiles, sensores, y dispositivos de almacenamiento de energía. En cuanto a la conductividad térmica, los nanotubos de carbono pueden mejorar la transferencia de calor en materiales compuestos, lo cual es valioso para disipar el calor en dispositivos electrónicos y en aplicaciones donde la gestión térmica es crucial, como en celdas solares y baterías de ion de litio.

En la industria de la electrónica, es importante evitar la acumulación de electricidad estática, que puede dañar componentes sensibles. Los CNTs pueden añadir propiedades antiestáticas a los materiales compuestos, permitiendo el flujo de carga y reduciendo la acumulación estática. Los CNTs también son útiles en aplicaciones de blindaje electromagnético. Los compuestos con CNTs pueden bloquear o desviar señales electromagnéticas, lo que es beneficioso para proteger equipos electrónicos y evitar interferencias. Esto es particularmente relevante en la industria de las telecomunicaciones y en dispositivos médicos.

En medicina, los compuestos con CNTs están siendo explorados para desarrollar materiales biomédicos con propiedades avanzadas, como implantes y prótesis. Los CNTs pueden mejorar la biocompatibilidad y la resistencia mecánica de estos dispositivos. Además, los CNTs pueden funcionar como plataformas para la administración controlada de fármacos. Al modificar su superficie, los CNTs pueden transportar y liberar medicamentos de forma dirigida, lo que mejora la eficacia de los tratamientos y reduce efectos secundarios (Dubey et al., 2021).

En aplicaciones donde el desgaste y la fricción son factores críticos, los materiales compuestos con CNTs muestran una resistencia al desgaste y una durabilidad superiores, ya que los CNTs pueden actuar como un agente de autolubricación a nivel nanométrico. Esto es especialmente útil en piezas de maquinaria, componentes de motores y aplicaciones donde se requiere una vida útil prolongada y un mantenimiento mínimo.

Los CNTs nanotubos de carbono se utilizan en materiales de construcción para aumentar la resistencia a la compresión y la durabilidad de ciertos compuestos de cemento y hormigón. Al integrar CNTs, los materiales de construcción pueden obtener mayor resistencia a las fracturas y mejor capacidad de resistencia sísmica, lo cual es ventajoso en infraestructuras sometidas a vibraciones o en zonas con alta actividad sísmica.

Finalmente, los CNTs pueden formar parte de materiales compuestos empleados en la filtración de agua y purificación de aire. Debido a su alta relación de área superficial y sus propiedades hidrofóbicas, los CNTs permiten una mayor eficiencia en la captura de contaminantes y toxinas. Estas membranas son especialmente útiles en la industria de tratamiento de aguas y en la fabricación de filtros de aire de alta eficiencia, como los utilizados en laboratorios, entornos industriales y hospitales.

2.7.4.3 Usos en almacenamiento de energía (baterías y supercondensadores)

Los NTCs se utilizan en almacenamiento de energía debido a su alta conductividad eléctrica, gran área superficial, y propiedades mecánicas excepcionales, que los hacen ideales para aplicaciones en baterías de iones de litio, supercondensadores y celdas de combustible. En las baterías de iones de litio, los NTCs se emplean como aditivos en los ánodos para mejorar la conductividad electrónica, o como parte de los propios electrodos, ofreciendo una estructura ligera y estable que facilita el almacenamiento y liberación de energía con mayor eficiencia. Asimismo, los NTCs contribuyen a aumentar la densidad energética y la vida útil de estas baterías, lo que es crucial para dispositivos de alta demanda energética como vehículos eléctricos y sistemas de almacenamiento en redes energéticas (Amin, 2020).

En el caso de los supercondensadores, los NTCs permiten una mayor densidad de energía y una vida útil prolongada, además de una respuesta rápida de carga/descarga debido a su estructura porosa y conductividad. Su integración en celdas de combustible también potencia

la reactividad y estabilidad de los electrodos, lo cual resulta en un rendimiento más eficiente en la conversión de energía

2.8 NANOHÍBRIDOS

Un nanohíbrido compuesto con nanotubos de carbono (NTCs) pueden combinarse conpor favor profundiza nanopartículas metálicas, como las de plata, para desarrollar nanohíbridos con propiedades mejoradas. Este tipo de material híbrido resulta particularmente útil en aplicaciones de almacenamiento y conversión de energía debido a las sinergias entre los componentes individuales. Los NTCs actúan como soportes estructurales que mejoran la estabilidad de las nanopartículas de plata, mientras que las propiedades conductoras y la alta área superficial de los NTCs maximizan la eficiencia electroquímica.

2.8.1 Definición de nanohíbrido.

Los nanohíbridos entre nanotubos de carbono (NTCs) y nanopartículas metálicas, incluidas las de plata, son materiales avanzados que combinan las propiedades únicas de ambos componentes para diversas aplicaciones industriales y científicas. Los nanohíbridos NTC-Ag consisten en nanopartículas de plata dispersas sobre la superficie de nanotubos de carbono. Este diseño maximiza la interacción entre las nanopartículas y el soporte de NTC, lo que resulta en propiedades mejoradas para aplicaciones específicas (Amin, 2020; Yahyazadeh et al., 2024).

2.8.2 Funcionalización de nanotubos de carbono con moléculas de plata.

La funcionalización de nanotubos de carbono (NTCs) con moléculas de plata mejora sus propiedades y amplía sus aplicaciones. La funcionalización implica la introducción de grupos funcionales o nanopartículas en la superficie de los NTCs, lo que puede reducir las fuerzas de atracción entre ellos y mejorar su dispersión en matrices o solventes.

En el caso de las moléculas de plata, esta funcionalización aporta una mayor solubilidad y estabilidad en disolventes orgánicos. Además, las nanopartículas de plata en la superficie de los NTCs proporcionan características antimicrobianas y mejoran la capacidad de adsorber

iones metálicos. Esto es especialmente útil en aplicaciones como la purificación de agua y en áreas biomédicas, donde estas propiedades se aprovechan para eliminar contaminantes o desarrollar sistemas avanzados de liberación de medicamentos (Dubey et al., 2021; Yahyazadeh et al., 2024)

2.8.3 Propiedades y sinergia entre nanotubos y partículas de plata.

La combinación de nanotubos de carbono (NTCs) con nanopartículas de plata resulta en una sinergia única que mejora las propiedades de ambos materiales para diversas aplicaciones tecnológicas.

Los NTCs, por su naturaleza altamente conductora, actúan como matrices ideales para la dispersión de nanopartículas de plata, permitiendo un transporte eficiente de electrones en aplicaciones electroquímicas. Por su parte, las nanopartículas de plata no solo mantienen, sino que mejoran la estabilidad de los NTCs en condiciones extremas, como temperaturas elevadas o medios químicos agresivos.

Los NTCs ofrecen una estructura tridimensional que permite la dispersión uniforme de las nanopartículas de plata, lo que incrementa el área activa para reacciones químicas o interacciones físicas.

La plata es conocida por sus propiedades catalíticas en reacciones de reducción y oxidación. Su combinación con NTCs no solo potencia estas capacidades, sino que también proporciona un soporte físico estable que evita la aglomeración de las nanopartículas, maximizando su eficiencia. Las nanopartículas de plata ancladas en los NTCs tienen mayor capacidad para interactuar con iones metálicos o moléculas, lo que es beneficioso en sensores y dispositivos de detección.

En baterías avanzadas y supercapacitores, la combinación NTC-Ag facilita un mejor rendimiento electroquímico debido a su alta conductividad y capacidad para almacenar carga. La funcionalización con plata dota a los NTCs de propiedades antimicrobianas, siendo efectivos en aplicaciones biomédicas y de purificación de agua (Yahyazadeh et al., 2024).

La sinergia entre los NTCs y las nanopartículas de plata permite el desarrollo de materiales funcionales de alto rendimiento, aprovechados en catalizadores, sensores y almacenamiento

de energía. La estabilidad, conductividad y propiedades catalíticas conjuntas de estos nanohíbridos abren oportunidades innovadoras en múltiples industrias.

2.8.4 Métodos de Fabricación de Nanohíbridos

(Yahyazadeh et al., 2024) describe varios métodos de síntesis de nanotubos de carbono (NTCs) y destaca su integración con nanopartículas, como las de plata, para formar nanohíbridos. Estos nanohíbridos aprovechan las propiedades sinérgicas de los NTCs y las partículas de plata, como la alta conductividad eléctrica de los nanotubos y las capacidades catalíticas y antimicrobianas de la plata. A continuación de abordan los principales enfoques para fabricar estos nanohíbridos:

- **Deposición Química en Fase de Vapor (CVD):** Este método permite el control preciso del crecimiento de los NTCs al utilizar catalizadores metálicos, como níquel, cobalto o hierro, que facilitan la incorporación de nanopartículas metálicas como la plata. Este enfoque es eficiente para la producción de nanohíbridos con propiedades específicas como conductividad eléctrica mejorada y resistencia mecánica.
- **Métodos de Dispersión y Funcionalización**: Los NTCs pueden funcionalizarse mediante tratamientos químicos (como oxidación en medio ácido) que introducen grupos funcionales en su superficie, facilitando la unión de nanopartículas de plata. Este método resulta esencial para aplicaciones donde la interacción entre los NTCs y las nanopartículas es clave, como sensores y catalizadores.
- **Método de Ablación por Láser y Descarga de Arco**: Estos métodos tradicionales se combinan con la adición de precursores metálicos (como sales de plata) durante el proceso, formando NTCs decorados con nanopartículas de plata. Aunque menos comunes, permiten obtener materiales de alta pureza y propiedades específicas.

2.8.4.1 Compatibilidad y estabilidad de los nanohíbridos

En analiza (Díez-Pascual, 2021) se aborda cómo la funcionalización química de nanotubos de carbono (NTCs) puede mejorar significativamente su compatibilidad y estabilidad, especialmente al combinarse con polímeros y otros compuestos, como partículas metálicas.

En este contexto, los nanohíbridos con NTCs y partículas de plata se benefician de las técnicas de funcionalización, ya que estas introducen grupos funcionales que mejoran la interacción química y mecánica entre los componentes

La funcionalización covalente y no covalente de NTCs con polímeros y otros materiales permite modificar la química superficial de los nanotubos, lo que puede reducir la tendencia de los NTCs a agruparse por interacciones de Van der Waals. Esto facilita su dispersión en solventes y matrices poliméricas, aumentando su compatibilidad química con otros componentes, incluidas las partículas de plata.

La funcionalización mejora la estabilidad física y química de los NTCs. Los grupos funcionales añadidos durante procesos como la oxidación y el injerto polimérico pueden fortalecer la adhesión entre los NTCs y las partículas de plata, lo que resulta en nanocompuestos más estables, tanto en el estado sólido como en soluciones. Este refuerzo es clave para aplicaciones en materiales avanzados y biomedicina

Además, se resalta que las propiedades sinérgicas de estos nanohíbridos, como la conductividad térmica y eléctrica, pueden potenciarse mediante estas modificaciones, ofreciendo un gran potencial para aplicaciones tecnológicas y científicas

2.8.4.2 Control de las propiedades del material a través de la modificación de nanotubos

La funcionalización química de nanotubos de carbono (NTCs) permite controlar y ajustar sus propiedades para optimizar su desempeño en diversas aplicaciones. Mediante la adición de grupos funcionales específicos a la superficie de los NTCs, es posible modificar sus características físicas, químicas y mecánicas, lo cual permite personalizar sus propiedades según las necesidades del material compuesto o del sistema en el que se vayan a emplear (Díez-Pascual, 2021).

Este control sobre las propiedades del material se logra ajustando factores como la dispersión, la interacción con la matriz polimérica y la reactividad superficial. Por ejemplo, la funcionalización covalente puede mejorar la dispersión de los NTCs en matrices poliméricas y, al mismo tiempo, modificar sus propiedades mecánicas y térmicas. Además, este proceso

permite el ajuste de la conductividad eléctrica y térmica del material final, así como su resistencia y rigidez, haciéndolo adecuado para aplicaciones específicas.

(Díez-Pascual, 2021) indica que la funcionalización química es una estrategia eficaz para el control y la optimización de las propiedades del material compuesto, lo que abre oportunidades en campos como la electrónica, la biomedicina y la ingeniería de materiales avanzados.

3. DESARROLLO

El desarrollo y aplicación de un árbol bayesiano es útil en el proceso de creación de nanohíbridos con nanotubos de carbono y partículas orgánicas porque permite integrar el conocimiento del experto en un modelo probabilístico que gestiona la incertidumbre inherente a las variables del sistema. Mediante la red bayesiana, se pueden evaluar múltiples factores (como la disponibilidad de los precursores, su costo o la eficiencia del proceso) y su impacto en el proceso de creación del nanohíbrido. Esto facilita la toma de decisiones informada y optimiza el diseño experimental al identificar las combinaciones de variables más prometedoras, reduciendo costos y tiempo de ensayo-error en la investigación experimental.

La presente investigación plantea una herramienta de decisión útil para el proceso de creación de nanihíbridos, compuestos por un lado por nanotubos de carbono y del otro, partículas de plata. Para dicho proceso en la actualidad de emplean agentes como el borohidruro de sodio, dióxido de silicio o fosfatos inorgánicos, lo que le da al proceso un carácter contaminante, por lo que se ha puesto atención en investigar métodos que permitan la obtención de los nanohíbridos mediante procesos menos contaminantes y más sustentables

En años recientes se ha puesto especial atención en plantear métodos que permitan la creación de nanihíbridos empleando en el proceso partículas orgánicas como, por ejemplo, cáscara de naranja, cáscara de plátano, hueso de aguacate, ajo y hojas de eucalipto, haciendo el proceso más sustentable y amigable con el medio ambiente a contaminar menos.

El uso de las partículas orgánicas mencionadas previamente ofrece una amplia gama de posibilidades en el proceso de fabricación de nanohíbridos. Dado que estas partículas se derivan de diversos materiales, las propiedades que aportan generan resultados que varían según la eficiencia y el costo del proceso.

Antes de plantear el desarrollo del árbol bayesiano, se abordará el proceso de desarrollo de nanohíbridos.

3.1 Síntesis de Nanotubos de Carbono (NTC)

A partir de la década de los 80´s, con el descubrimiento de los Nanotubos de Carbono (NTC), se comenzaron a realizar una gran cantidad de investigaciones acerca de estos materiales que presentaban extraordinarias características y que gracias a ellas se hacía alarde de sus prometedoras aplicaciones en diferentes campos de la industria. Estas investigaciones estuvieron enfocadas en un principio, al desarrollo de metodologías que permitieran su obtención, por lo cual se implementaron diferentes técnicas de síntesis, dentro de las cuales se destacan técnicas como: descarga de arco eléctrico, ablación láser, electrólisis y deposición química en fase vapor. Cada una de ellas permitió obtener nanoestructuras base carbono con diferentes características, esto es, cada técnica de síntesis promovía la obtención de nanotubos de carbono con ciertas características, además, la eficiencia y los costos de los equipos aunado a los costos de operación de cada una de ellas muestran diferencias significativas, lo que dificultaba la obtención de este nanomaterial.

Con el paso de los años, se implementaron técnicas de producción de nanotubos de carbono basadas en el uso de dispositivos microondas con atmósferas inertes, sin embargo, esta metodología no tuvo el impacto que técnicas derivadas de la deposición química en fase vapor tuvieron, como lo es la síntesis por rocío pirolítico o mejor conocida por su nombre en inglés como “spray pyrolisys”. En esta técnica de síntesis, una mezcla de reactivos precursores (hidrocarburos y metalocenos, principalmente), es nebulizada e inyectada dentro de un horno de pirolisis con la ayuda de un gas inerte (argón), para la obtención de las nanoestructuras base carbono. Para esta técnica de crecimiento de NTC, se ha reportado el uso de benceno, xileno y tolueno como precursores de carbono. Sin embargo, la solución entre ferroceno y tolueno manejado como mezcla precursora, es la más comúnmente utilizada para obtener una gran cantidad de material de alta calidad y de forma comparativamente más simple y económica debido a las relativamente bajas temperaturas de evaporación que requiere el precursor de carbono.

Para la obtención de los NTC utilizados en este trabajo de investigación, se preparó una mezcla de 1.34 g de Ferroceno ($C_{10}H_{10}Fe$; Merck; 98% pureza) con 30 ml de Tolueno (C_7H_8; Fermont, 99% de pureza), la cual fue nebulizada e inyectada a un horno horizontal

Carbolite, con la ayuda de un flujo de Argón (Infra, 99.999% pureza) como gas de arrastre (figura 1). La mezcla nebulizada fue inyectada durante 40 min, después de este tiempo de rección, el horno fue llevado hasta temperatura ambiente para que pudiera ser manipulable y se pudiera recolectar el material resultante a través de un raspado en las paredes internas del tubo de cuarzo.

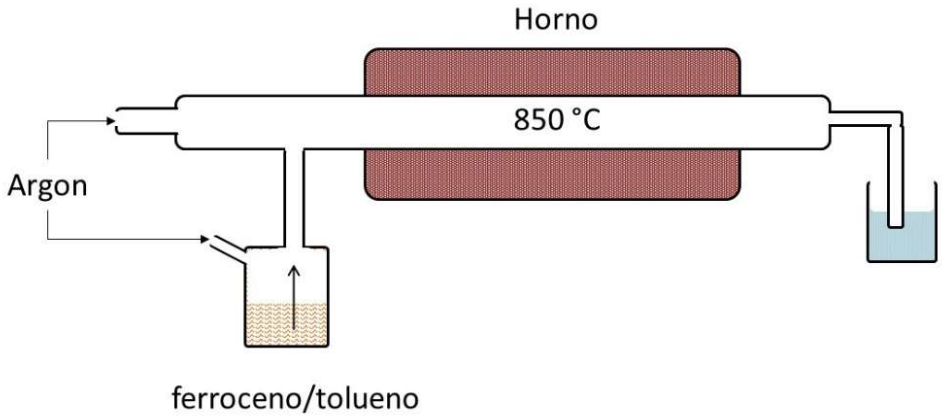

Figura 2. Esquema del reactor utilizado para la síntesis de NTC. Fuente: Elaboración propia.

3.2 Síntesis de nanopartículas metálicas (NPM)

Derivado de la gran importancia que presentan las nanopartículas metálicas generadas por sus propiedades, se han desarrollado diferentes métodos de síntesis que permiten su obtención tratando de controlar su tamaño y morfología. Dentro de los cuales se pueden nombrar metodologías como la implantación de iones, mecanosíntesis, co-precipitación, sol-gel y solvotermal. Sin embargo, se siguen desarrollando metodologías experimentales para obtener NPM en donde los tiempos de reacción sean más cortos, los procesos más eficientes (obtención de mayores cantidades de nanomaterial), y particularmente, que los procesos sean más amigables con el medio ambiente, es decir, que los subproductos generados sean menos nocivos con el medio ambiente (eco-friendly).

Debido a lo anterior, recientemente se han desarrollado metodologías experimentales como la Biosíntesis o mejor conocida como Síntesis Verde en la cual se utilizan plantas, hongos o residuos orgánicos para reducir sales que sirven como reactivos precursores de metales. Nanopartículas metálicas como Au, Ag, Cu y Fe son obtenidos por ésta técnica de síntesis,

así como nanopartículas de óxidos metálicos como Ti, Zn, Si, utilizando una gran variedad de bioreductores como extractos de eucalipto, jamaica, aloe vera, ajo, cúrcuma, residuos de café, etc. Sin embargo, por la importancia a nivel industrial y comercial que presentan las nanopartículas de Ag, esta investigación se centra en este extraordinario material.

De acuerdo con información encontrada en la base de datos llamada STATNANO, de 3114 productos desarrollados hechos con nanomateriales y que ya se encuentran en el mercado, 1093 están hechos con nanopartículas de plata (NPsAg), los cuales se encuentran dispersos en diferentes campos industriales como en la Medicina (264 productos), Textil (190 productos), Cosmética (145 productos), Electrodomésticos (102 productos), Ambiental (91 productos), Construcción (86 productos) y otras (76 productos). Estos productos han sido desarrollados por 42 diferentes países en donde México tiene participación con la generación de 1 de ellos por el momento, sin embargo, se prevé que esta cifra aumente considerablemente ya que diversos grupos de investigación se encuentran trabajando para ello.

Debido a lo anterior, es necesario implementar metodologías que permitan obtener NPsAg para abastecer la cantidad de material requerido, a través de metodologías amigables con el medio ambiente, para lo cual, en este proyecto se ha establecido utilizar la Síntesis Verde para la obtención de NPsAg. Para ello, se siguió con la siguiente metodología (Figura 2):

1. Se preparó una solución de AgNO3 al 0.1M con agua destilada.

2. Por otra parte, se obtuvo el extracto de los bioreductores (cáscara de plátano, cáscara de naranja y hueso de aguacate a través de ponerlos en contacto directo con agua caliente durante 2 min, para ello se utilizaron 4 g de cada bioreductor en 40 ml de agua destilada, después de la ebullición se filtró al vacío.

3. En un vaso de precipitado se agregaron 40 ml de solución precursora y 5 ml del extracto obtenido por cada bioreductor, la cual se mantuvo en agitación constante hasta obtener una solución homogénea. La cual fue caracterizada para evaluar la obtención de NPsAg.

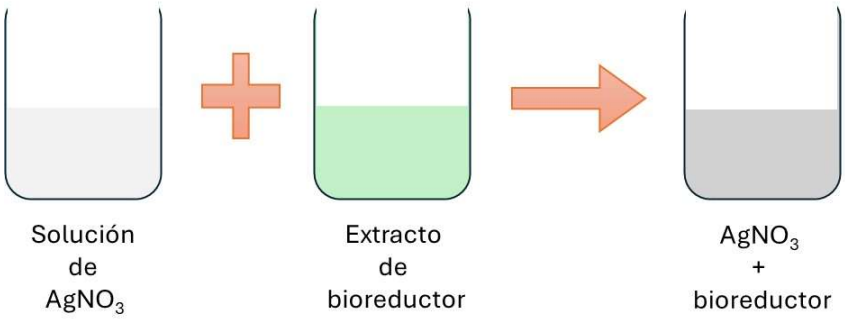

Figura 3. Esquema simple del proceso de utilizado para la formación de NPsAg. Fuente: Elaboración propia.

3.3 Síntesis de compuestos tipo NTC/NPs

El descubrimiento de los NTC trajo consigo un sin número de investigaciones enfocadas en su uso, sin embargo, la aplicación de estos extraordinarios nanomateriales ha sido limitada debido a que son insolubles en medios acuosos, por lo cual, muchas de éstas investigaciones fueron dirigidas hacia su "modificación superficial", lo que pudiera permitir que, a través de la generación de "puntos o sitios de anclaje", obtenidos a partir de tratamientos ligeramente agresivos (tratamientos con ácidos), se tuviera una interacción física (fuerzas de Van Der Walls, puentes de hidrógeno), o química (a través de enlaces), con otro tipo de nanopartículas (NPs) tanto de origen orgánico como inorgánico y de esta manera poder obtener un nanomaterial "híbrido" o "compuesto" en donde las propiedades de los materiales involucrados (NTC y moléculas o NPs), se combinen para brindar un material con propiedades mejoradas, dando origen a una nueva clase de nanomateriales del tipo NTC/NPs con propiedades dependientes del tipo de nanoestructura o nanoarquitectura formada, considerando además, las propiedades de las NPs incorporadas.

Para lograr lo anterior, se han desarrollado diversas técnicas de síntesis que permiten la combinación de NTC con NPs, específicamente la deposición de nanopartículas metálicas (NPM) sobre la superficie de NTC, para lo cual se conocen dos diferentes rutas; en la primera, las NPM se hacen crecer directamente sobre las paredes externas (y previamente modificadas) de los NTC a través de metodologías que utilizan los sitios de anclaje generados por la modificación superficial para que sirvan como templete para el crecimiento "in situ" de las partículas metálicas deseadas, de esta manera se pueden obtener nanoestructuras híbridas ya que debido a que los NTC que se utilizan como soporte o templete, son

previamente modificados con tratamientos ácidos generando grupos funcionales del tipo carbonilo, carboxilo, etc, que son justamente las que interactúan con las NPM haciendo entre los NTC y ellas un enlace químico. Este tipo de nanohibrido permite su uso en aplicaciones donde se requiere que exista una fuerte interacción entre el NTC y las NPM.

La otra ruta de síntesis considera la formación de nanoestructuras compuestas del tipo NTC/NPM ya que la interacción entre estos dos materiales está únicamente basada en fuerzas electrostáticas como fuerzas de Van Der Walls o puentes de Hidrógeno, ya que las metodologías utilizadas para su formación considera la obtención de cada uno de sus componentes por separado para su posterior unión a través de metodologías muy sofisticadas como haz de electrones hasta el uso de métodos más sencillos como co-precipitación.

Debido a lo anterior, en este proyecto de investigación se considera la obtención de nanoestructuras del tipo NTC/NMP obtenidas de la forma más simple, sustentable y amigable con el medio ambiente, por lo tanto, se aplicó una metodología que tratara de combinar las bondades de las dos rutas anteriormente descritas, esto es:

1. Los NTC que se obtuvieron a partir del proceso de rocío pirolítico utilizando una mezcla de ferroceno/tolueno como precursores fueron sometidos a un tratamiento utilizando una mezcla de ácido nítrico y ácido sulfúrico con el objetivo de crear sitios de anclaje sobre las paredes externas del mismo a través de la generación de grupos funcionales tales como hidroxilo, carbonilo y carboxilo (NTC funcionalizados).

2. Los NTC funcionalizados (0.05 g) se pusieron en contacto directo con la solución de precursor y bioreductor. Esta mezcla se mantuvo en agitación magnética durante 5 min.

En la Figura 3 se representa el proceso llevado a cabo experimentalmente para la formación de nanohíbridos. Los materiales obtenidos de este proceso fueron caracterizados por diferentes métodos para confirmar la formación del nanohíbrido.

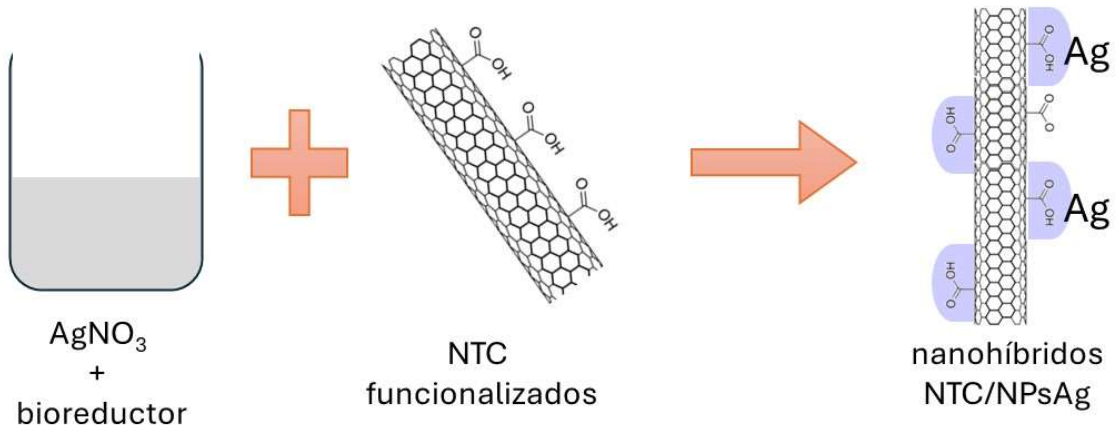

Figura 4. Proceso de formación de nanohibridos. Fuente: Elaboración Propia

3.4 Desarrollo del árbol de decisión

A continuación, se plantea del desarrollo de un árbol bayesiano de decisión que, empleando la opinión de los expertos, serviría como herramienta para la toma de decisiones en el proceso de creación de nanohíbridos NTCs y partículas de plata. Además, dicha herramienta podría ser fácilmente adaptada para considerar nuevos compuestos orgánicos y/o variables

Un árbol bayesiano de decisión para diseñar nanohíbridos usando nanotubos de carbono (NTC) y nitrato de plata como precursor con estabilizadores orgánicos puede estructurarse en varios niveles jerárquicos que representen las decisiones y probabilidades asociadas. Este modelo permite incorporar la incertidumbre y los costos relativos de cada estabilizador.

3.4.1. Nodo raíz: Decisión inicial

- Prueba previa (Sí/No): El primer paso consiste en decidir si se llevará a cabo el proceso de creación de nanohíbridos con prueba previa (empleando una cantidad reducida de materiales, lo que incrementa el costo, pero se obtiene mayor certeza en el resultado), o sin prueba previa (que implica un costo menor, pero mayor incertidumbre):

- Si se realiza una prueba previa, existe un costo asociado (por ejemplo, para optimizar el proceso).
- Si no se realiza, se procede directamente a la selección del estabilizador orgánico.

3.4.2. Selección del estabilizador orgánico

- Opciones: cáscara de naranja, cáscara de plátano, hueso de aguacate, ajo, y hojas de eucalipto.
- Cada estabilizador tiene una probabilidad asignada basada en su costo relativo, su disponibilidad, y la eficiencia del proceso:
  - Costo de conseguir la materia prima del precursor:
    - Bajo
    - Medio
    - Alto
  - Disponibilidad del precursor:
    - Alta
    - Media
    - Baja
  - Eficiencia en la obtención de nanohíbridos:
    - Alta
    - Moderada
    - Baja

3.4.3. Probabilidad de los factores (costo relativo, su disponibilidad, y la eficiencia del proceso)

Para cada estabilizador seleccionado, se evalúa la probabilidad de que su costo, su disponibilidad y eficiencia en el proceso sea bajo, mediano o alto. Las probabilidades condicionales se asignan basándose en datos el juicio experto e investigaciones previas, así como datos empíricos. A continuación, se presentan las tablas 1, 2 y 3 con las probabilidades condicionales para cada variable con sus respectivas características:

Tabla 1. Probabilidades asignadas para la variable Costo. Fuente: Elaboración Propia.

		Variable: Costo		
		Bajo	Medio	Alto
Precursor	Naranja	0.5	0.3	0.2
	Plátano	0.1	0.3	0.6
	Aguacate	0.7	0.2	0.1
	Ajo	0.1	0.1	0.8
	Eucalipto	0.9	0.05	0.05

Tabla 2. Probabilidades asignadas para variable Disponibilidad. Fuente: Elaboración Propia.

		Variable: Disponibilidad		
		Baja	Media	Alta
Precursor	Naranja	0.05	0.05	0.9
	Plátano	0.1	0.1	0.8
	Aguacate	0.05	0.05	0.9
	Ajo	0.05	0.05	0.9
	Eucalipto	0	0	1

Tabla 3. Probabilidades asignadas para la variable Eficiencia. Fuente: Elaboración Propia.

		Variable: Eficiencia del proceso		
		Baja	Moderada	Alta
Precursor	Naranja	0.1	0.2	0.7
	Plátano	0.1	0.4	0.5
	Aguacate	0.05	0.15	0.8
	Ajo	0.1	0.3	0.6
	Eucalipto	0.1	0.5	0.4

3.4.4. Resultado del proceso

- La probabilidad final de éxito del proceso puede depender de:
    - La estabilidad del nanohíbrido logrado con el estabilizador.
    - Los costos acumulados en función de las probabilidades previas.

3.4.5 Representación en el árbol

Cada rama del árbol refleja las decisiones posibles y sus probabilidades:

- Nivel 1: Decisión de realizar prueba previa.
- Nivel 2: Costo estimado del estabilizador seleccionado (bajo, mediano, alto).
- Nivel 3: Éxito final del proceso.

3.4.6 Ejemplo práctico

Sin prueba previa: Se considera que la Probabilidad de éxito es calculada en función de datos obtenidos con la opinión de los expertos para obtener 10 mg de nanohíbridos.

1. Estabilizador: Cáscara de naranja

- Costo bajo: 50%, mediano: 30%, alto: 20%.
- Resultado: Beneficio económico de $2,000 cuando el costo es bajo dado que la información perfecta indicó que sería bajo.

2. Estabilizador: Hojas de eucalipto

- Costo bajo: 90%, mediano: 5%, alto: 3%.
- Resultado: Beneficio económico de $3,600 cuando el costo es bajo dado que la información perfecta indicó que sería bajo.

Con prueba previa: Para el desarrollo con prueba previa también se considera que la Probabilidad de éxito es calculada en función de datos obtenidos con la opinión de los expertos para obtener 10 mg de nanohíbridos.

1. Estabilizador: Cáscara de naranja

- Costo bajo: 50%, mediano: 30%, alto: 20%.
- Resultado: Beneficio económico de $3,986.6 cuando el costo es bajo dado que la información perfecta indicó que sería bajo.

2. Estabilizador: Hojas de eucalipto

- Costo bajo: 90%, mediano: 5%, alto: 3%.
- Resultado: Beneficio económico de $9,891.32 cuando el costo es bajo dado que la información perfecta indicó que sería bajo.

Tomando en consideración los datos anteriores, se puede observar que la mejor opción para el factor costo, es el producir el nanohíbrido usando como estabilizador hojas de eucalipto dado que el proceso origina un mayor beneficio económico.

Una ventaja de este modelo es que se pueden ajustar las probabilidades basadas en datos empíricos de la prueba, mejorando la predicción del estabilizador óptimo.

Utilizando el teorema de Bayes, se actualizan las probabilidades en función de:

1. Datos históricos o empíricos sobre cada estabilizador.

2. Resultados de pruebas previas si se realizaron.

3. Consideraciones de costo y eficiencia.

3.4.6 Visualización

El árbol puede representarse gráficamente, y cada nodo contiene las decisiones, probabilidades y posibles resultados. El árbol de decisión bayesiano integra conocimiento experto con probabilidades cuantificables, permitiendo elegir el mejor estabilizador basado en costos y resultados esperados del proceso. Esto facilita una toma de decisiones más informada y adaptable.

En la siguiente sección (resultados) se muestran el árbol bayesiano con todos los valores considerados para las diferentes decisiones y probabilidades condicionales.

4. RESULTADOS

Los resultados de la investigación revelaron que el modelo de árbol bayesiano construido con la opinión de expertos y datos experimentales logró reducir significativamente la incertidumbre en la síntesis de nanohíbridos de nanotubos de carbono y nanopartículas de plata. Entre los estabilizadores orgánicos evaluados, la cáscara de naranja y las hojas de eucalipto mostraron la mayor efectividad, optimizando la estabilidad y distribución uniforme de las nanopartículas en los nanotubos. El modelo también permitió identificar que realizar pruebas experimentales previas incrementa las probabilidades de éxito, pero en escenarios donde esto no es posible, el árbol bayesiano proporciona predicciones confiables basadas en el historial de los estabilizadores y las condiciones del proceso. Además, la adaptabilidad del modelo facilita su aplicación para evaluar nuevos estabilizadores, haciendo de este enfoque una herramienta escalable y versátil para la nanotecnología.

Analizando los valores obtenidos del árbol bayesiano se encuentra que la mejor opción para la variable costo es realizar prueba previa con hojas de eucalipto.

En la figura 2 se muestra el árbol desarrollado con los valores de probabilidad para la variable costo usando como estabilizador del proceso cáscara de naranja, y a la derecha dentro de la misma figura se encuentran los valores provenientes de la evidencia del experto proporcionando valores conocidos como información perfecta.

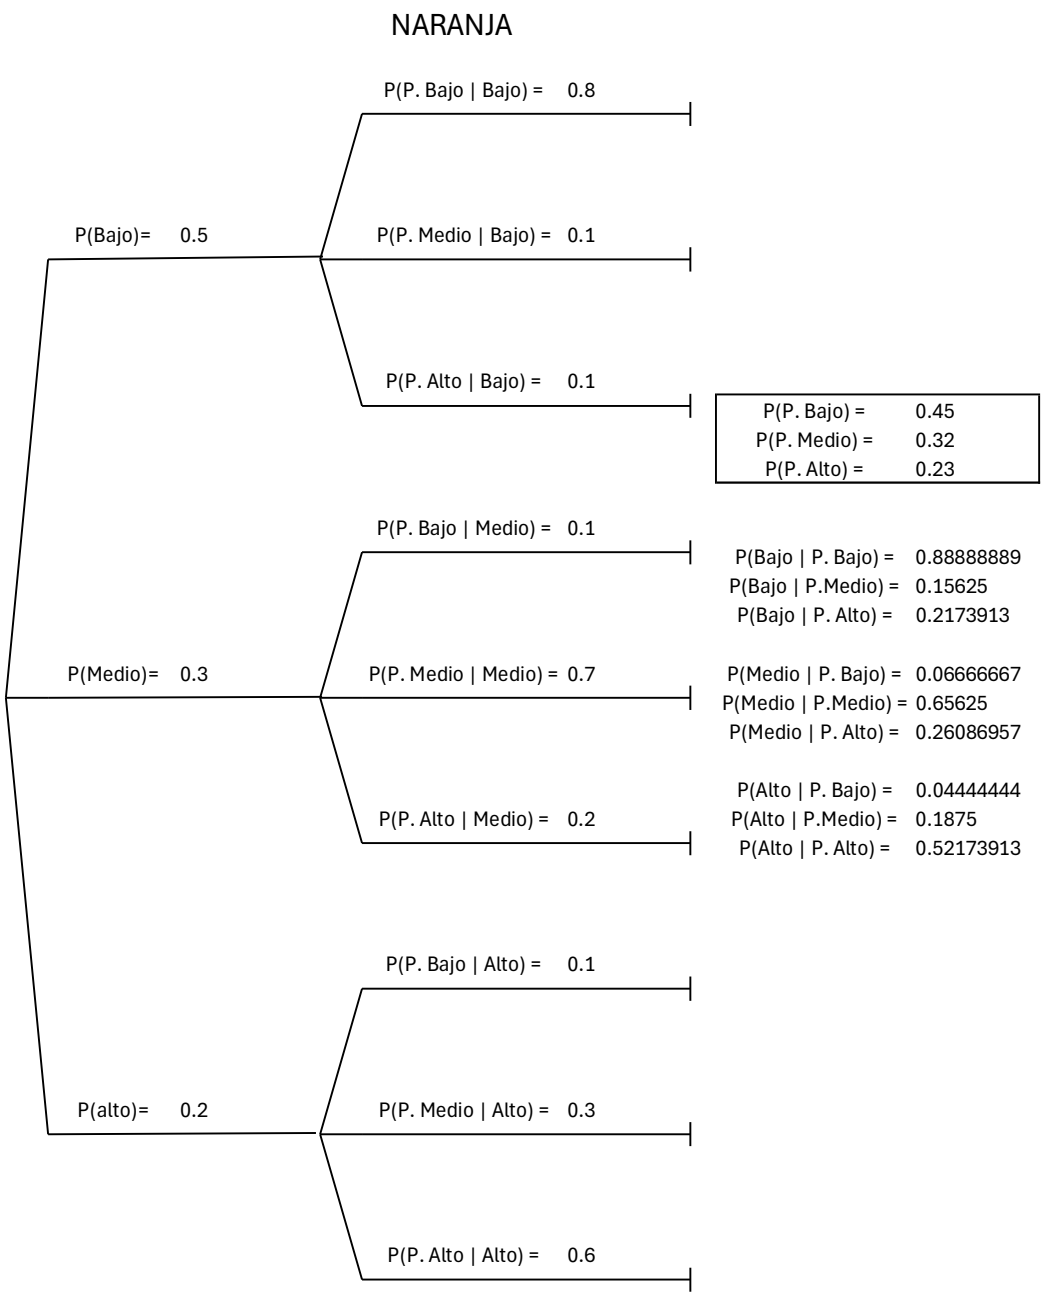

Figura 5. Árbol para la variable costo de la cáscara de naranja. Fuente: Elaboración propia.

En la figura 3 se muestra el árbol desarrollado con los valores de probabilidad para la variable costo usando como estabilizador del proceso cáscara de plátano, y a la derecha dentro de la misma figura se encuentran los valores provenientes de la evidencia del experto proporcionando valores conocidos como información perfecta.

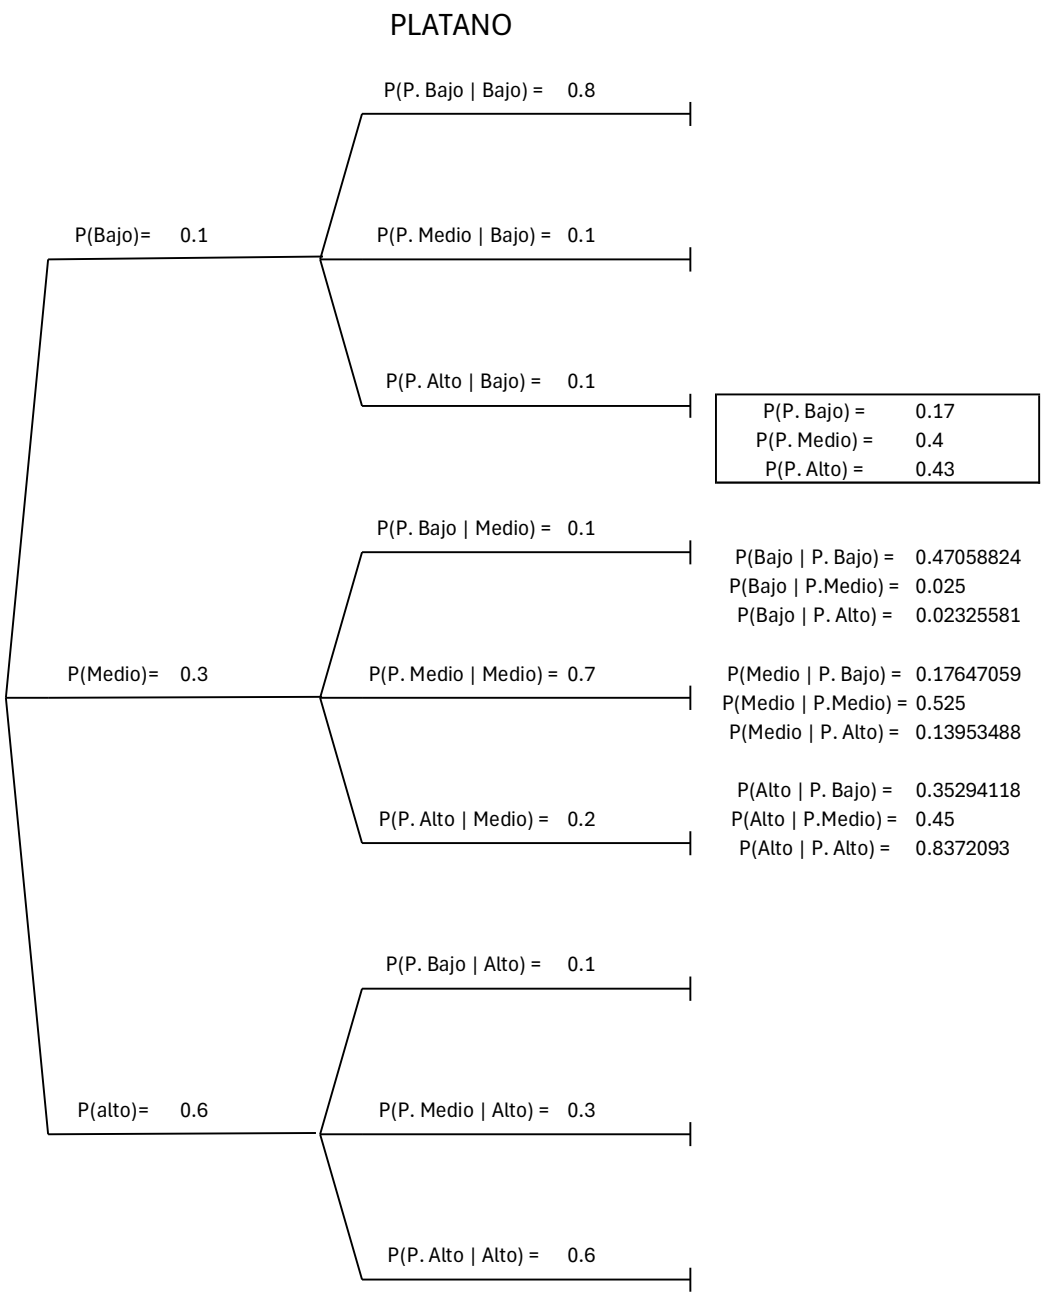

Figura 6. Árbol para la variable costo de la cáscara de plátano. Fuente: Elaboración propia.

En la figura 4 se muestra el árbol desarrollado con los valores de probabilidad para la variable costo usando como estabilizador del proceso hueso de aguacare, y a la derecha dentro de la misma figura se encuentran los valores provenientes de la evidencia del experto proporcionando valores conocidos como información perfecta.

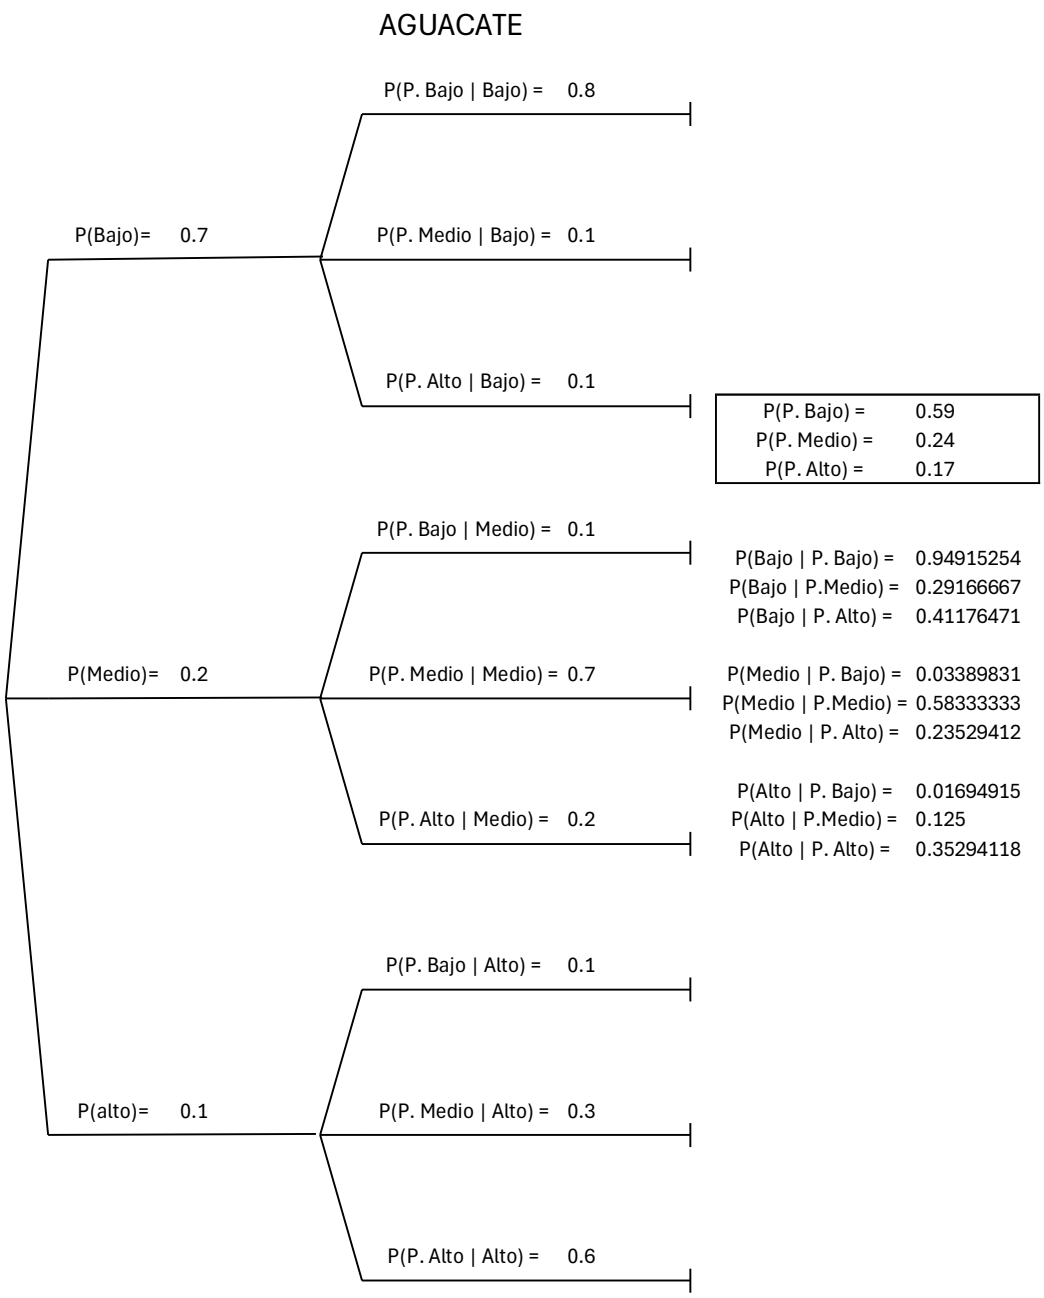

Figura 7. Árbol para la variable costo del hueso de aguacate. Fuente: Elaboración propia.

En la figura 5 se muestra el árbol desarrollado con los valores de probabilidad para la variable costo usando como estabilizador del proceso ajo, y a la derecha dentro de la misma figura se encuentran los valores provenientes de la evidencia del experto proporcionando valores conocidos como información perfecta.

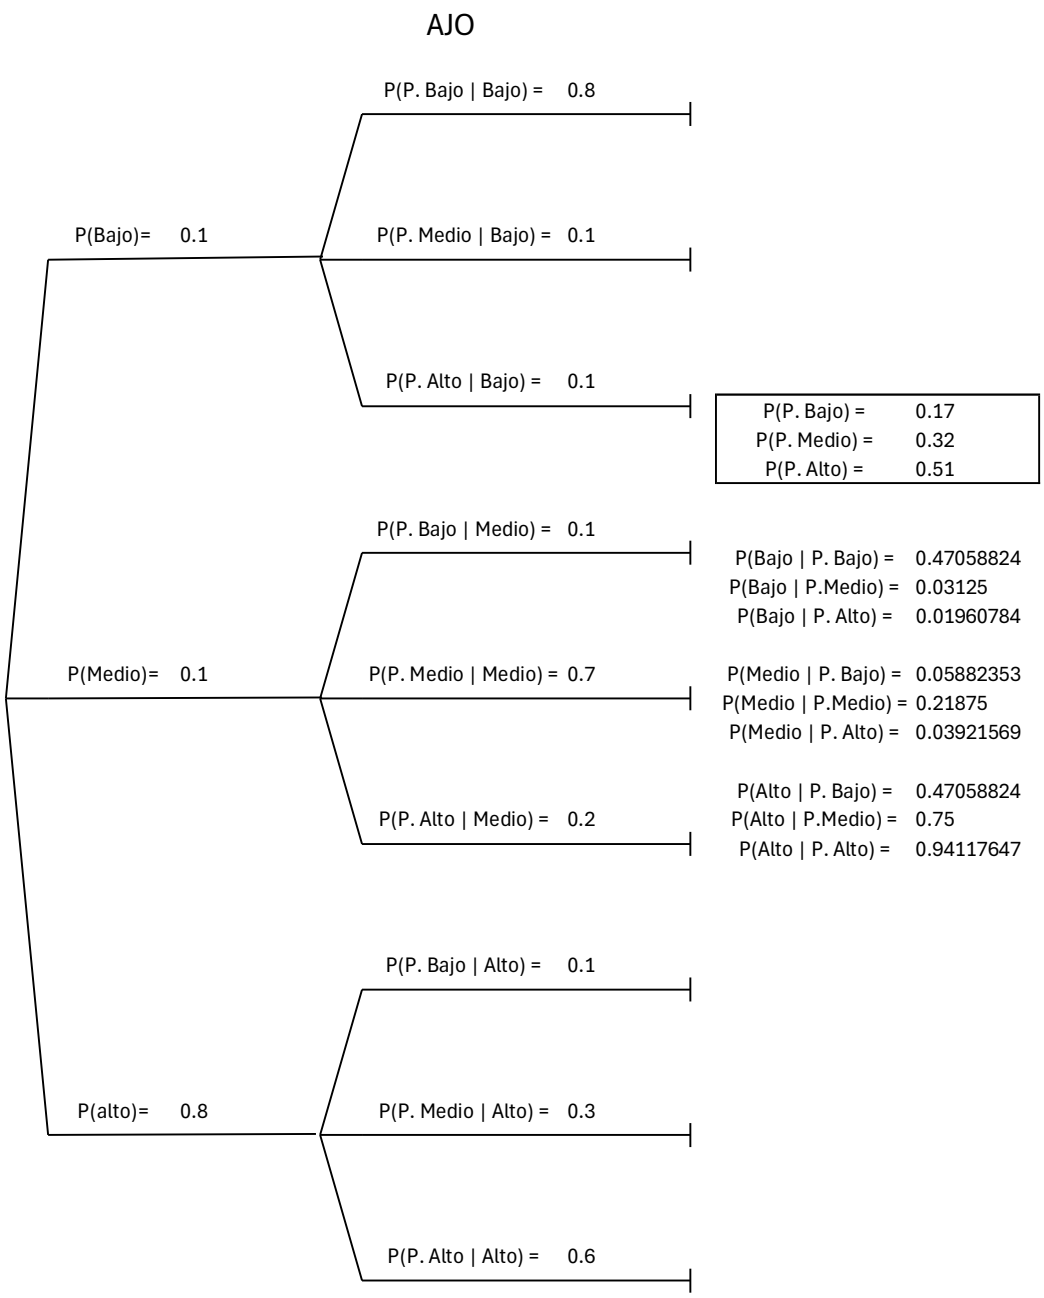

Figura 8. Árbol para la variable costo del ajo. Fuente: Elaboración propia.

En la figura 6 se muestra el árbol desarrollado con los valores de probabilidad para la variable costo usando como estabilizador del proceso hojas de eucalipto, y a la derecha dentro de la misma figura se encuentran los valores provenientes de la evidencia del experto proporcionando valores conocidos como información perfecta.

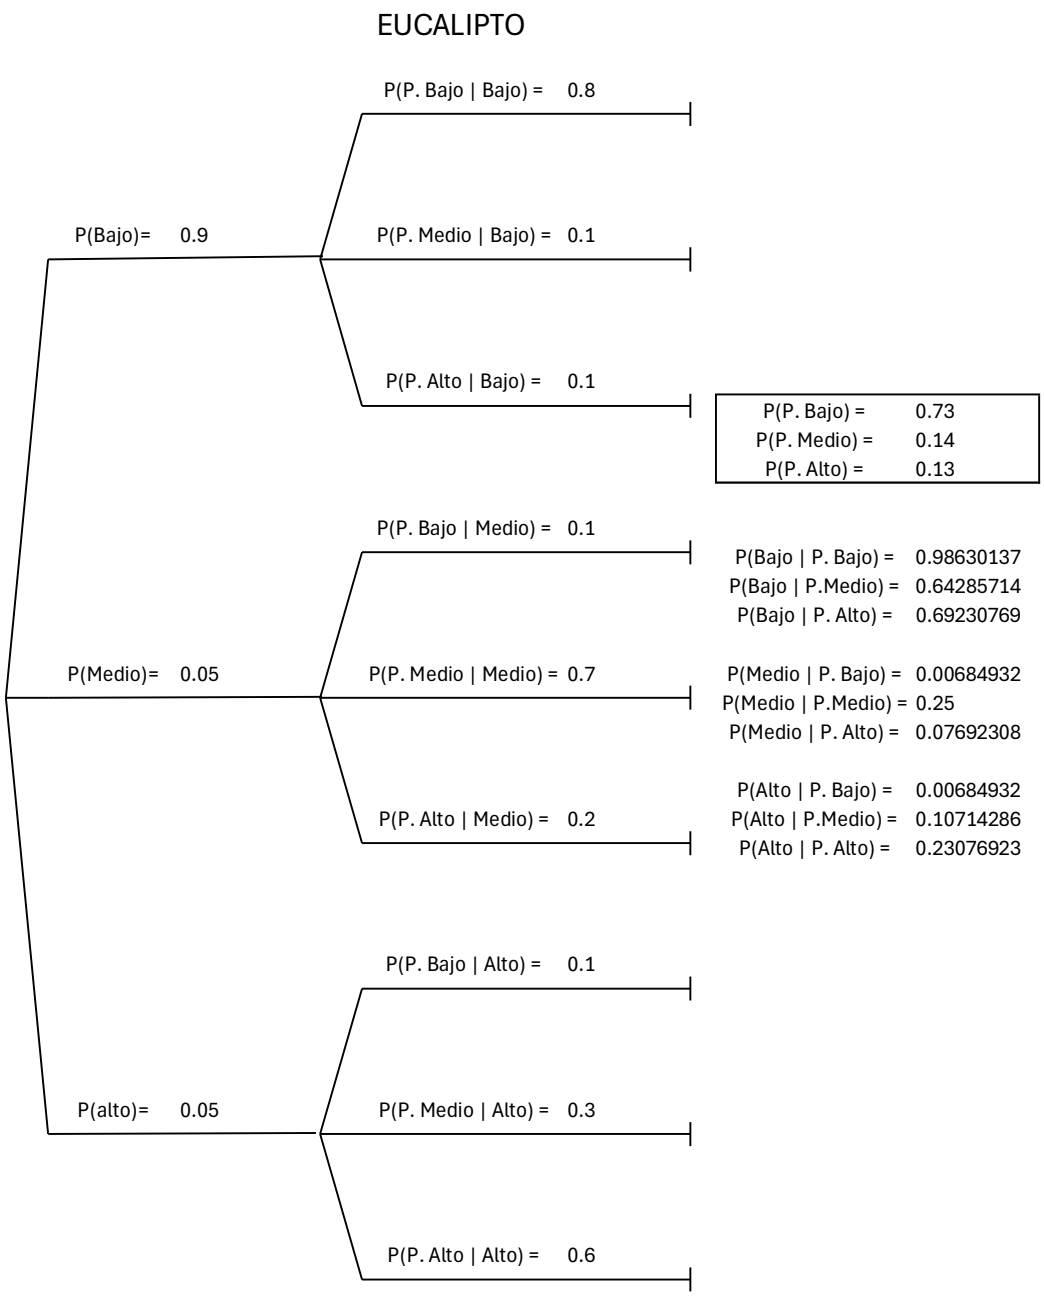

Figura 9. Árbol para la variable costo de hoja de eucalipto. Fuente: Elaboración propia.

A continuación, se desarrolló el árbol bayesiano donde se consideran dos alternativas, con prueba previa y sin ella. Por cuestiones de espacio se ha dividido el árbol. La figura 7 muestra el árbol del proceso de desarrollo sin prueba previa, y la figura 8 con prueba previa.

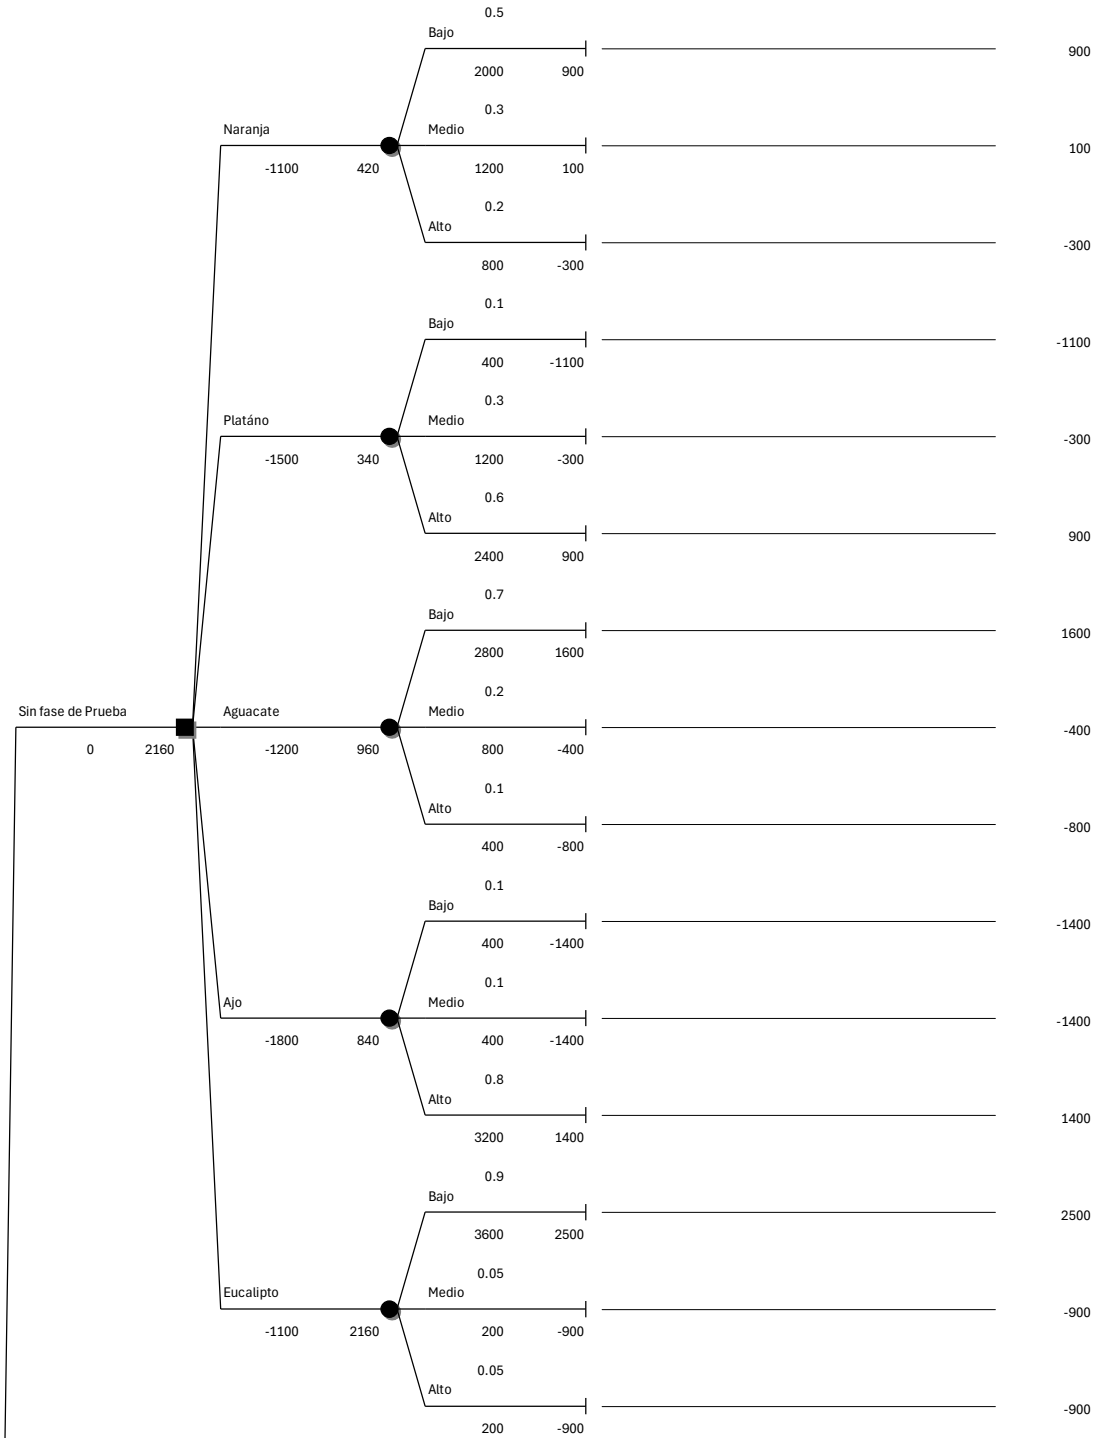

Figura 10. Rama del árbol bayesiano para la variable costo con los 5 materiales orgánicos sin prueba previa. Fuente: Elaboración propia.

La figura 8 muestra la rama del árbol desarrollado para la alternativa de fabricación de nanohíbridos con prueba previa y considerando el costo de los estabilizadores. Por cuestiones

de espacio y presentación, en las siguientes 5 figuras se muestra cada rama del árbol correspondiente a los 5 estabilizadores empleados.

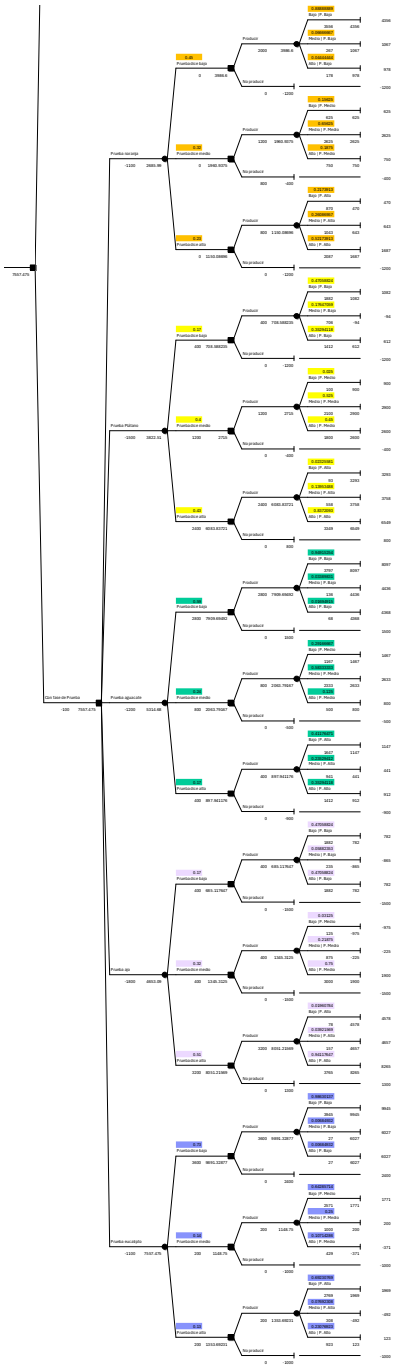

Figura 11. Rama del árbol bayesiano para la variable costo con los 5 materiales orgánicos con prueba previa. Fuente: Elaboración propia.

La figura 9 presenta el detalle para la rama con prueba previa para el proceso de desarrollo de nanohíbridos, considerando la variable costo y usando como estabilizador cáscara de naranja.

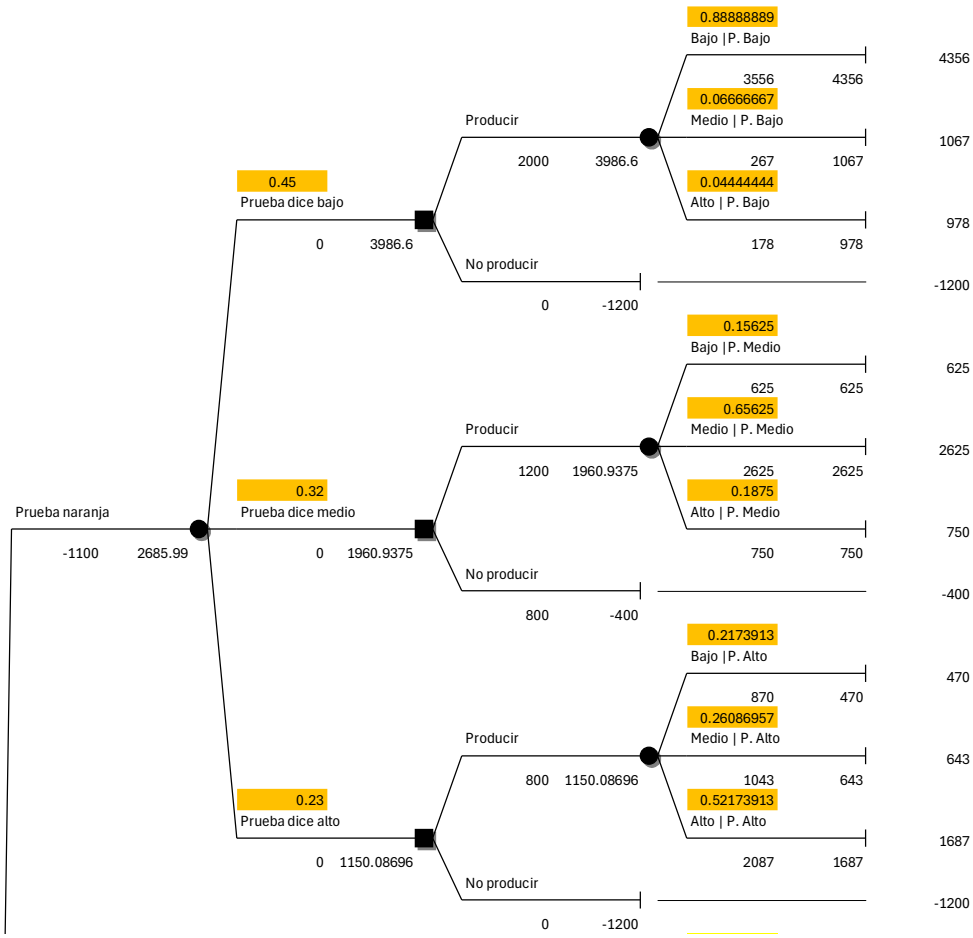

Figura 12. Rama del árbol bayesiano con prueba previa considerando la variable costo usando cáscara de naranja. Fuente: elaboración propia.

La figura 10 presenta el detalle para la rama con prueba previa para el proceso de desarrollo de nanohíbridos, considerando la variable costo y usando como estabilizador cáscara de plátano.

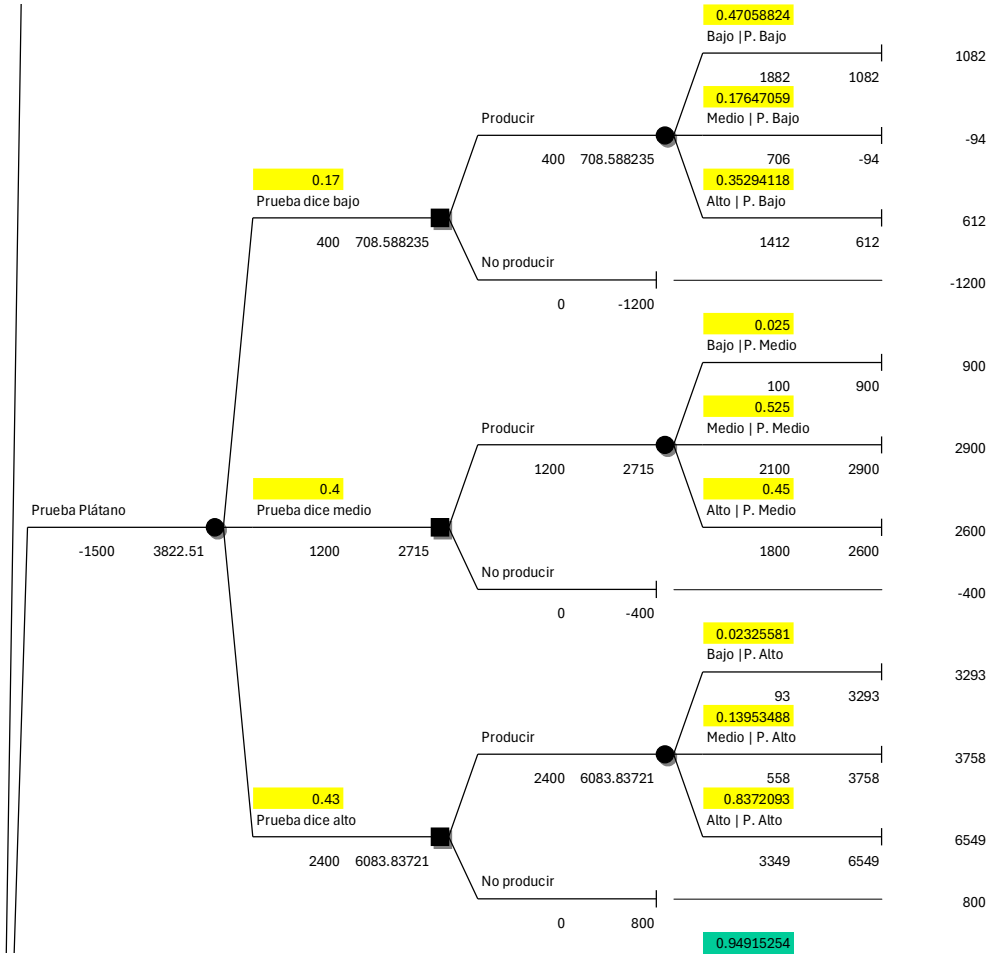

Figura 13. Rama del árbol bayesiano con prueba previa considerando la variable costo usando cáscara de plátano. Fuente: elaboración propia.

La figura 11 presenta el detalle para la rama con prueba previa para el proceso de desarrollo de nanohíbridos, considerando la variable costo y usando como estabilizador hueso de aguacate.

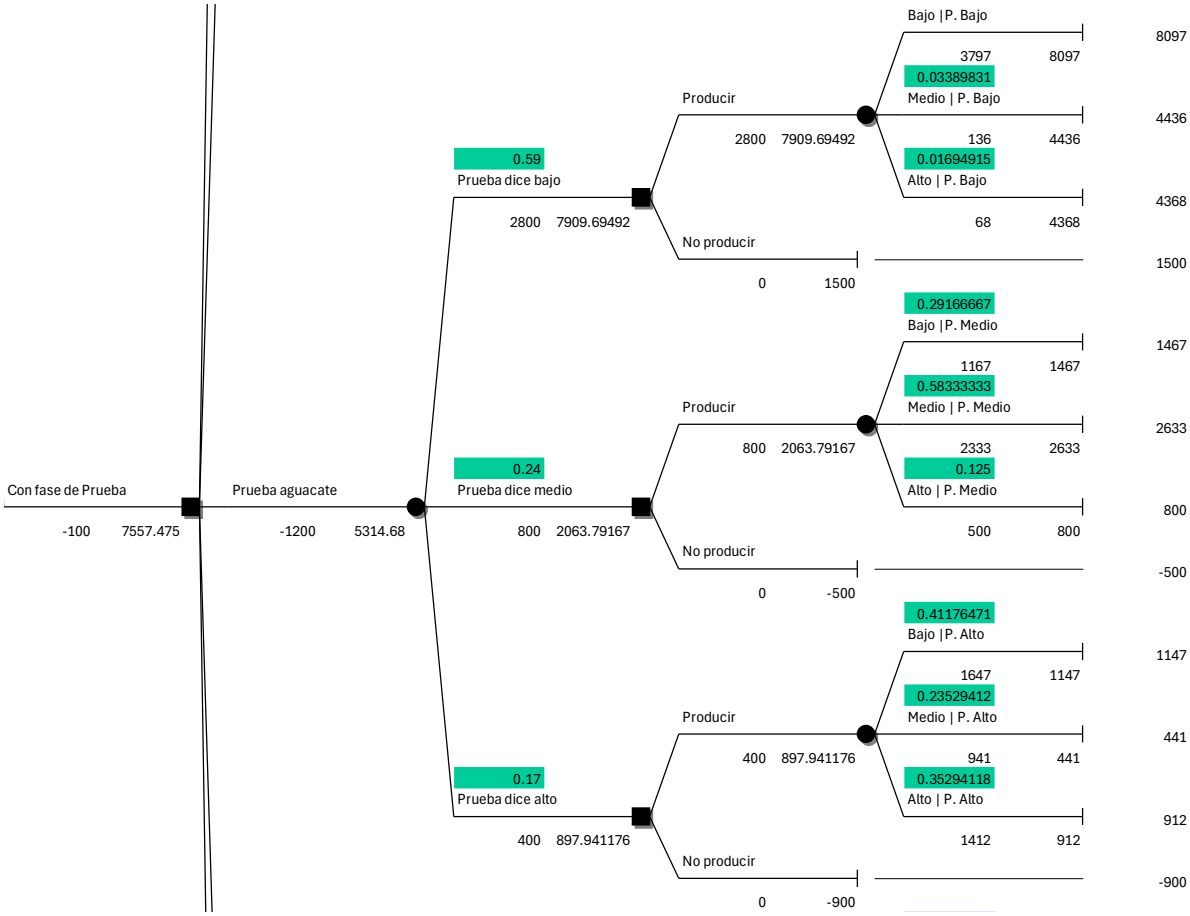

Figura 14. Rama del árbol bayesiano con prueba previa considerando la variable costo usando hueso de aguacate. Fuente: elaboración propia.

La figura 12 presenta el detalle para la rama con prueba previa para el proceso de desarrollo de nanohíbridos, considerando la variable costo y usando como estabilizador ajo.

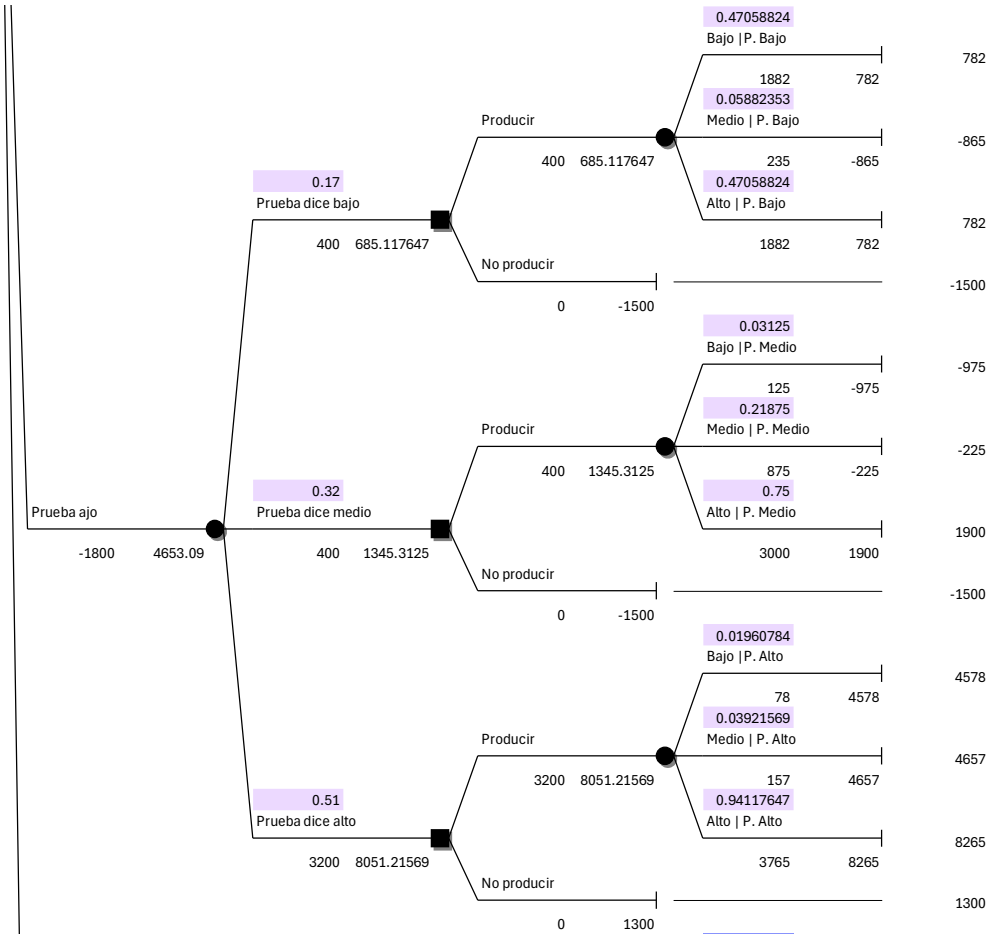

Figura 15. Rama del árbol bayesiano con previa considerando la variable costo usando ajo. Fuente: elaboración propia.

La figura 13 presenta el detalle para la rama con prueba previa para el proceso de desarrollo de nanohíbridos, considerando la variable costo y usando como estabilizador hojas de eucalipto.

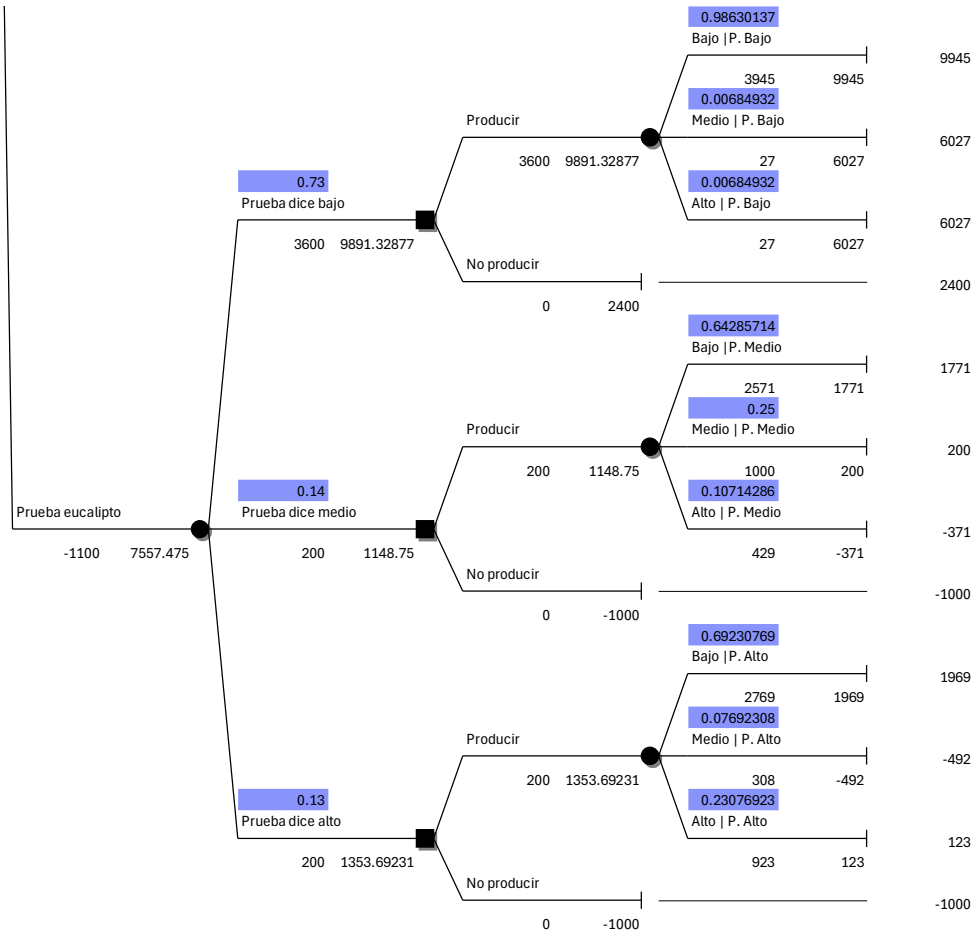

Figura 16. Rama del árbol bayesiano con prueba previa considerando la variable costo usando hojas de eucalipto. Fuente: elaboración propia.

En la figura 14 se muestra el árbol desarrollado con los valores de probabilidad para la variable disponibilidad usando como estabilizador del proceso cáscara de naranja, y a la derecha dentro de la misma figura se encuentran los valores provenientes de la evidencia del experto proporcionando valores conocidos como información perfecta.

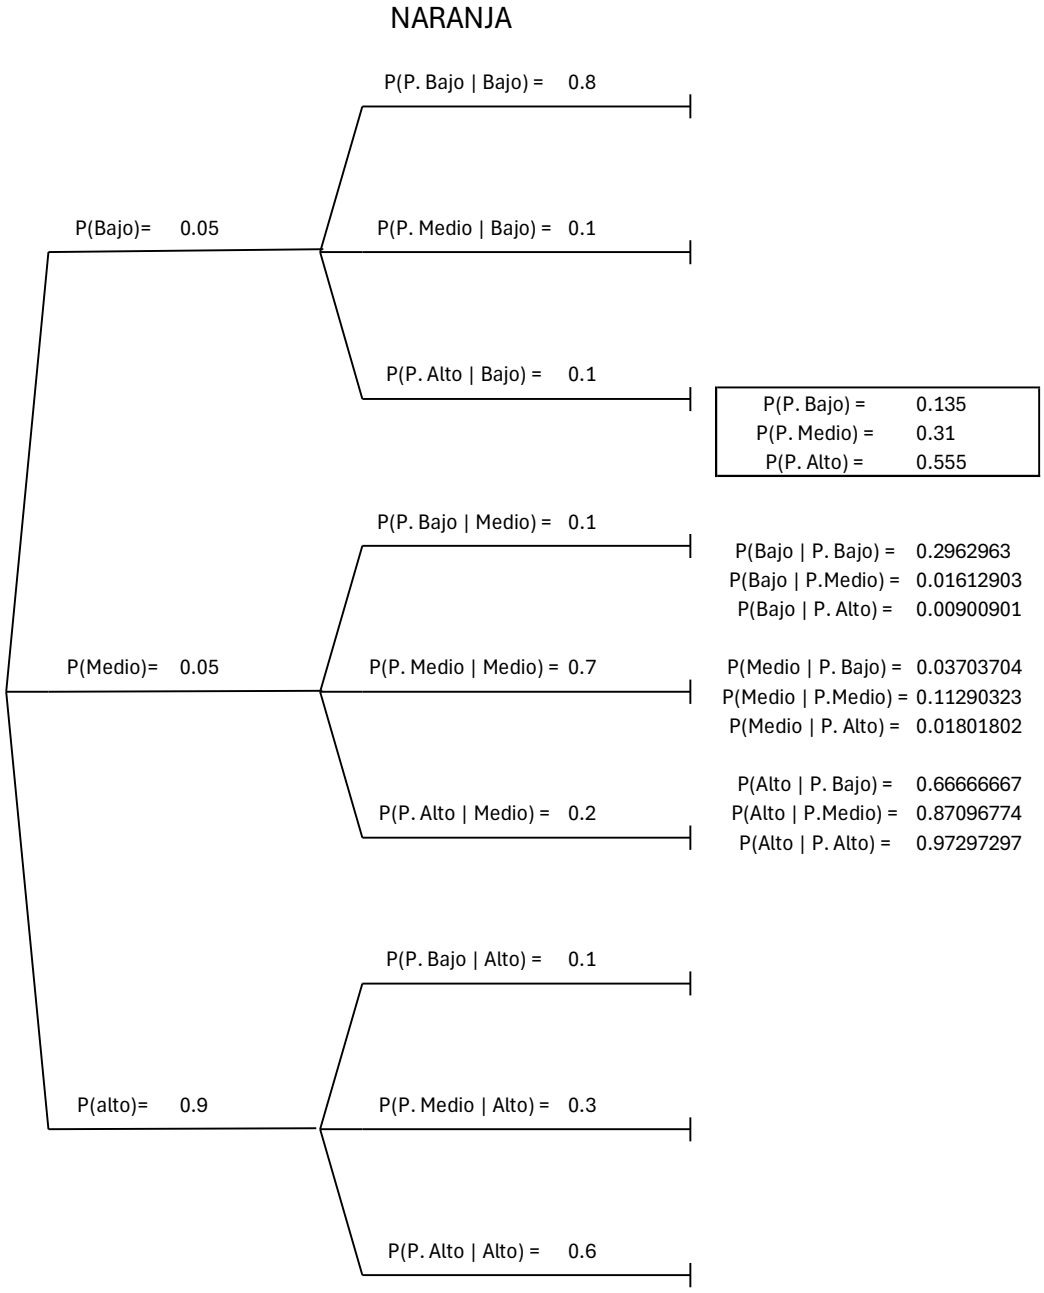

Figura 17. Árbol para la variable disponibilidad de la cáscara de naranja. Fuente: Elaboración propia.

En la figura 15 se muestra el árbol desarrollado con los valores de probabilidad para la variable disponibilidad usando como estabilizador del proceso cáscara de plátano, y a la derecha dentro de la misma figura se encuentran los valores provenientes de la evidencia del experto proporcionando valores conocidos como información perfecta.

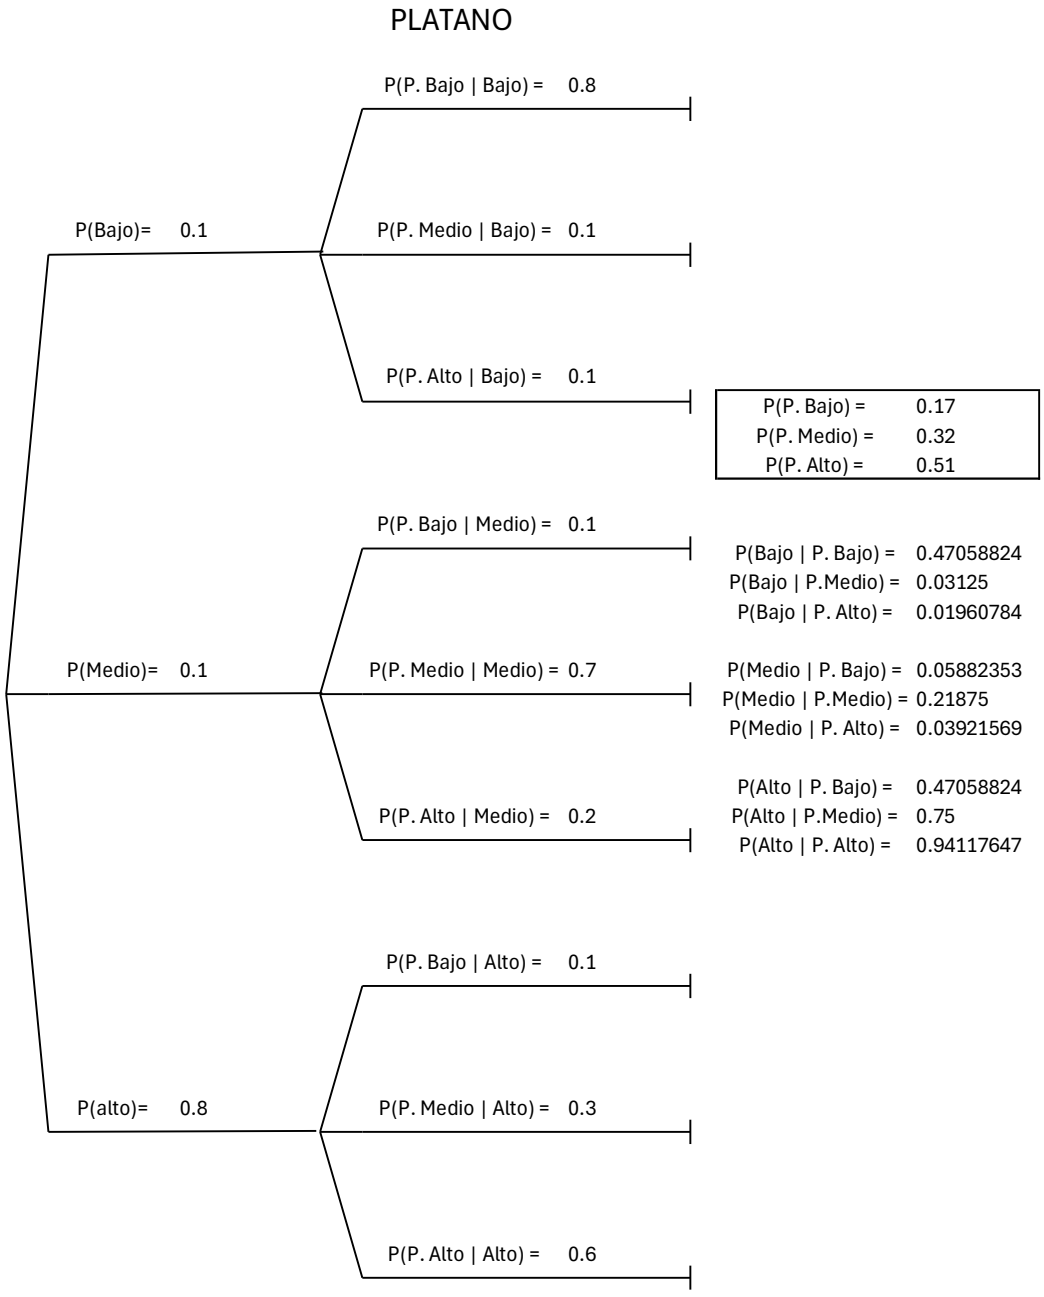

Figura 18. Árbol para la variable disponibilidad de la cáscara de plátano. Fuente: Elaboración propia.

En la figura 16 se muestra el árbol desarrollado con los valores de probabilidad para la variable disponibilidad usando como estabilizador del proceso hueso de aguacate, y a la derecha dentro de la misma figura se encuentran los valores provenientes de la evidencia del experto proporcionando valores conocidos como información perfecta.

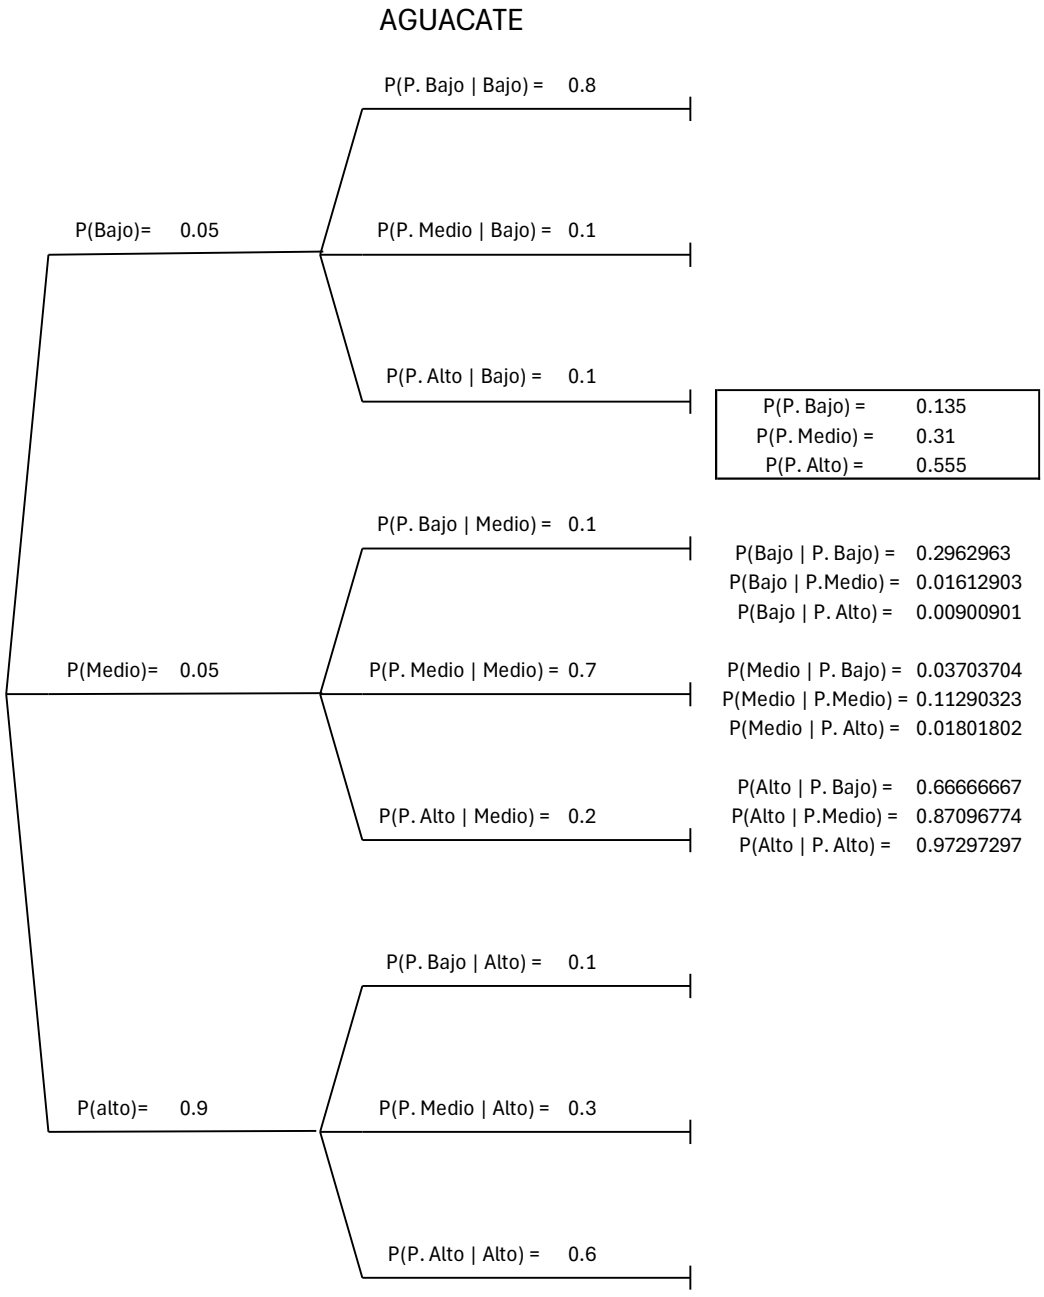

Figura 19. Árbol para la variable disponibilidad del hueso de aguacate. Fuente: Elaboración propia.

En la figura 17 se muestra el árbol desarrollado con los valores de probabilidad para la variable disponibilidad usando como estabilizador del proceso ajo, y a la derecha dentro de la misma figura se encuentran los valores provenientes de la evidencia del experto proporcionando valores conocidos como información perfecta.

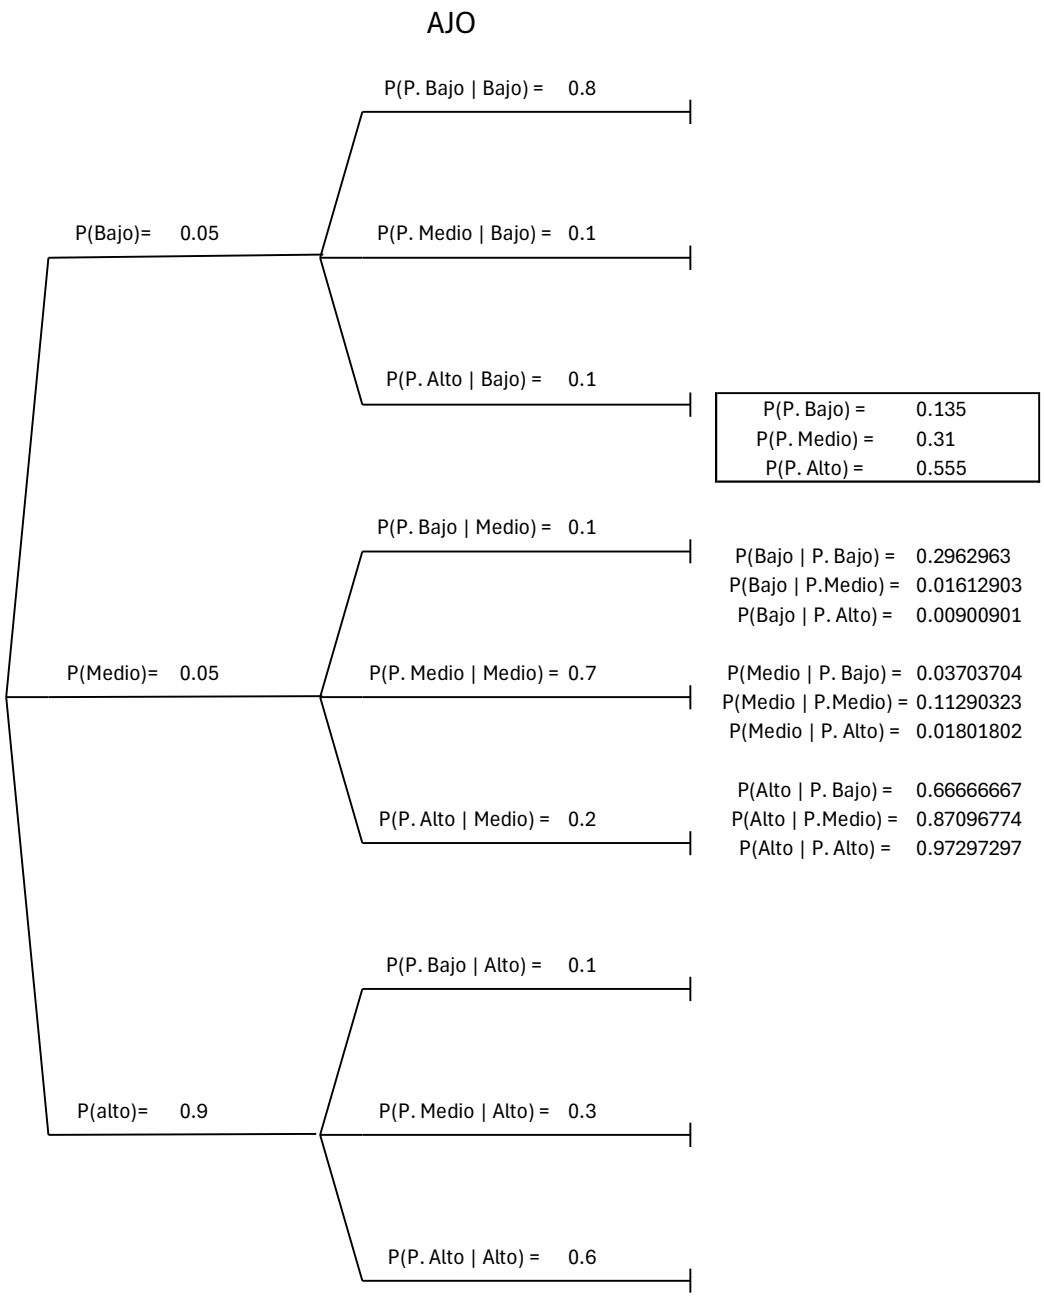

Figura 20. Árbol para la variable disponibilidad del ajo. Fuente: Elaboración propia.

En la figura 18 se muestra el árbol desarrollado con los valores de probabilidad para la variable disponibilidad usando como estabilizador del proceso hojas de eucalipto, y a la derecha dentro de la misma figura se encuentran los valores provenientes de la evidencia del experto proporcionando valores conocidos como información perfecta.

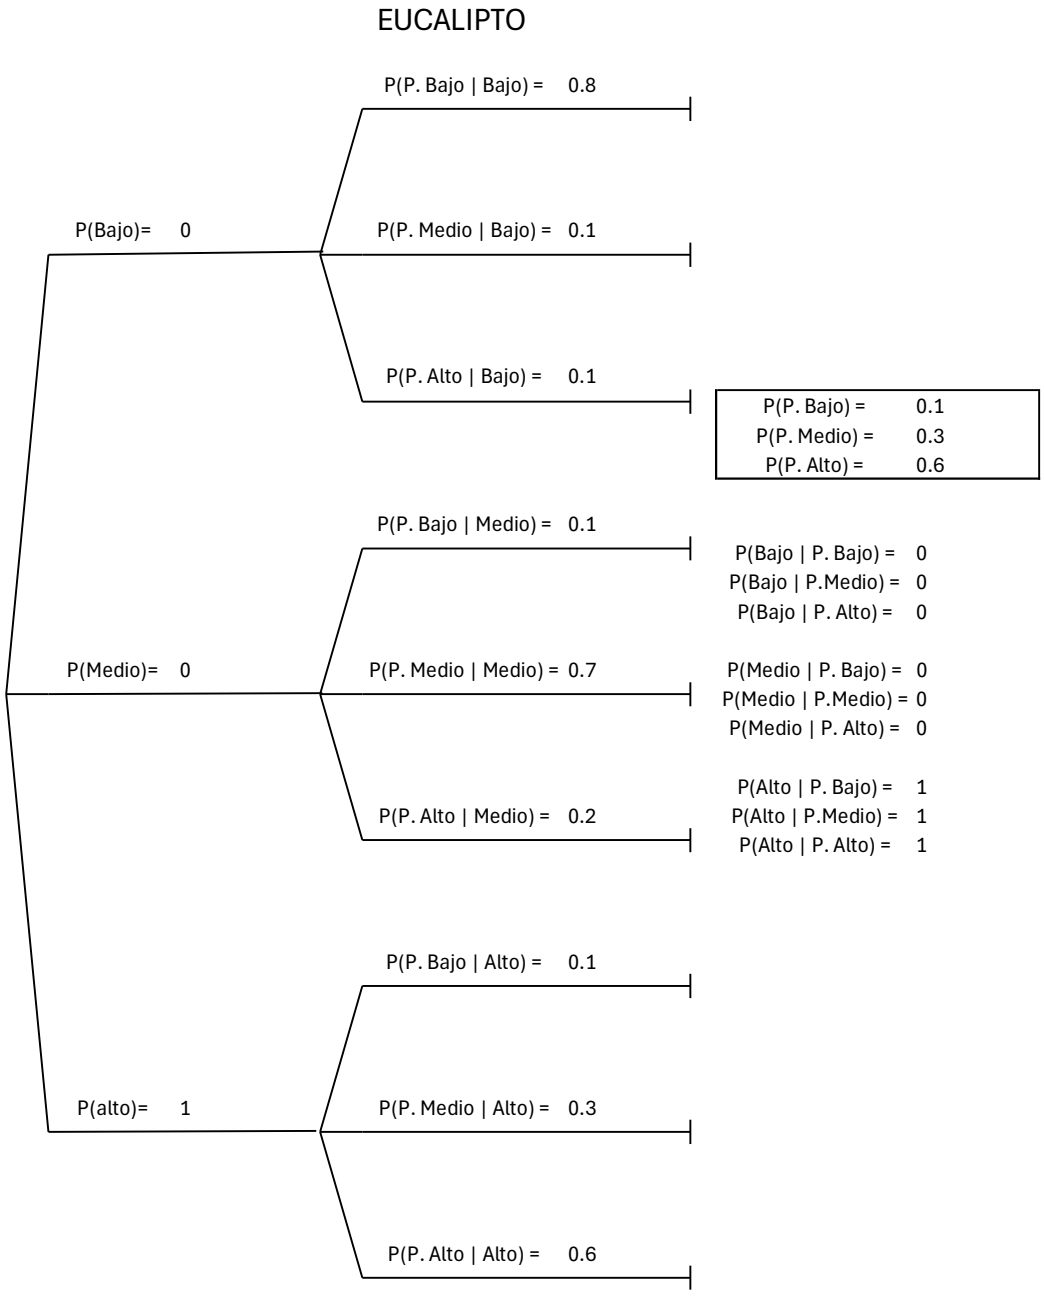

Figura 21. Árbol para la variable disponibilidad de las hojas de eucalipto. Fuente: Elaboración propia.

El árbol bayesiano para la variable disponibilidad donde se consideran dos alternativas, con prueba previa y sin ella, se presenta en las figuras 19 y 20 para cada alternativa, respectivamente.

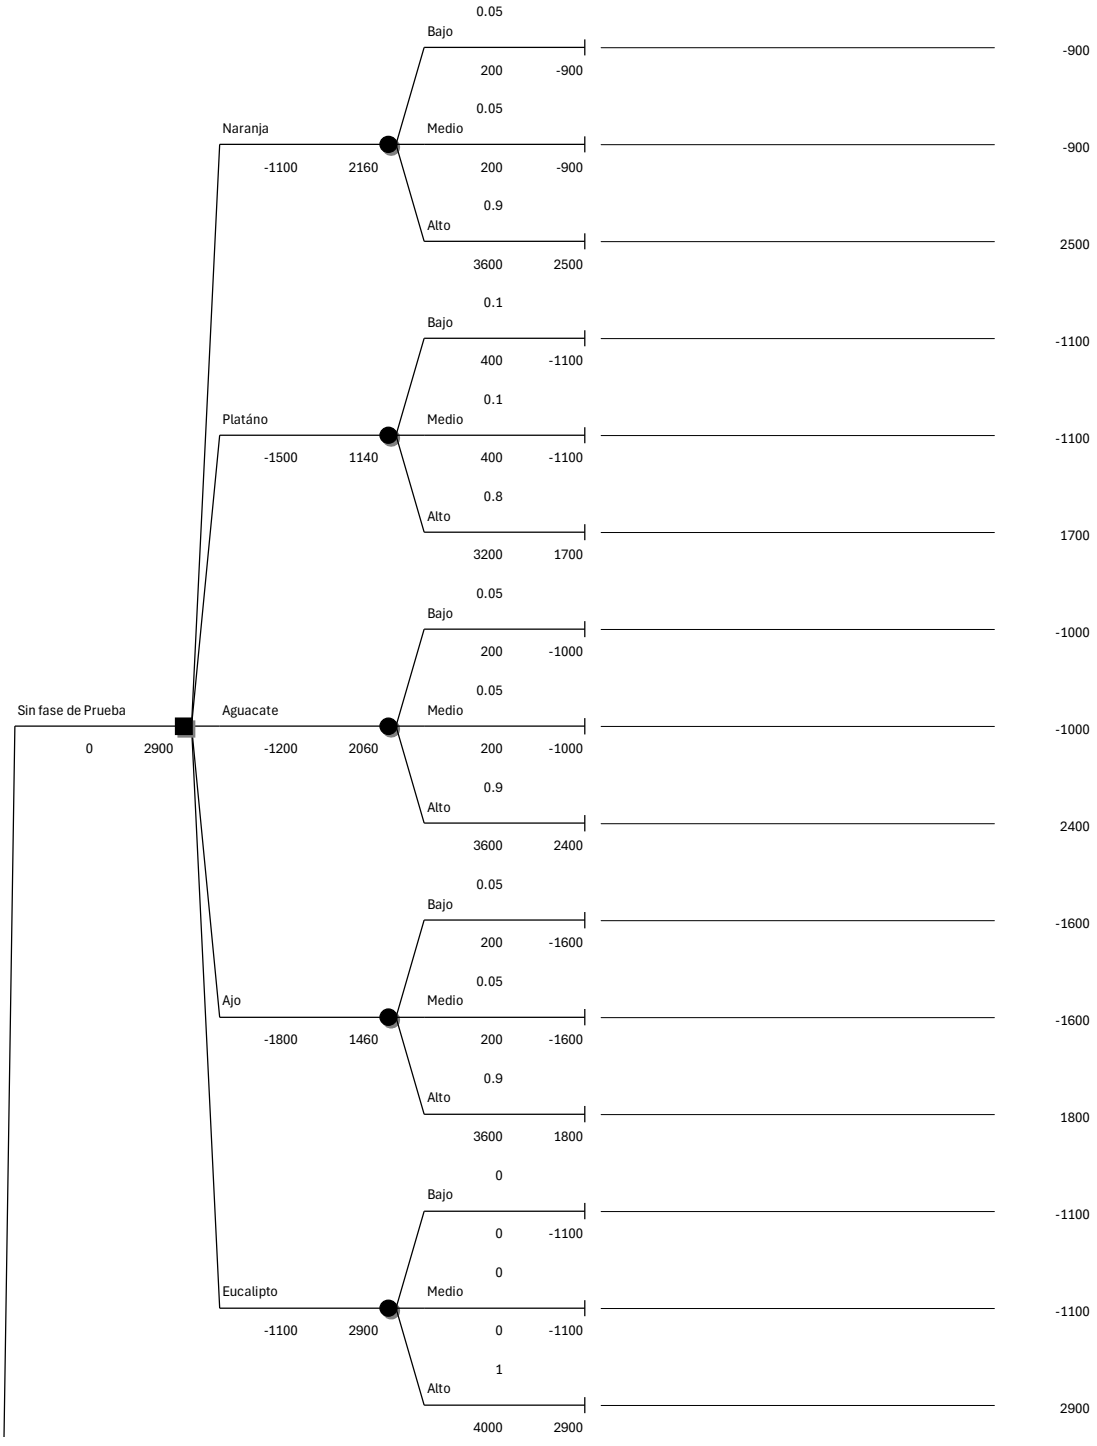

Figura 22. Rama del árbol bayesiano para la variable disponibilidad con los 5 materiales orgánicos sin prueba previa. Fuente: Elaboración propia.

La figura 20 muestra la rama del árbol desarrollado para la alternativa de fabricación de nanohíbridos con prueba previa y considerando la disponibilidad de los estabilizadores. Por cuestiones de espacio y presentación, en las siguientes 5 figuras se muestra cada rama del árbol correspondiente a los 5 estabilizadores empleados.

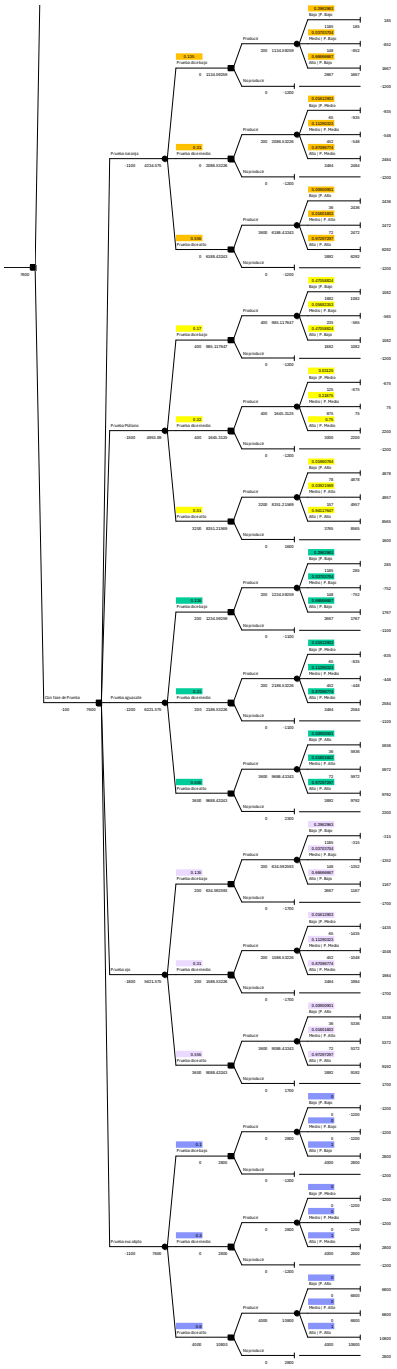

Figura 23. Rama del árbol bayesiano para la variable disponibilidad con los 5 materiales orgánicos con prueba previa. Fuente: Elaboración propia.

La figura 21 presenta el detalle para la rama con prueba previa para el proceso de desarrollo de nanohíbridos, considerando la variable disponibilidad y usando como estabilizador cáscara de naranja.

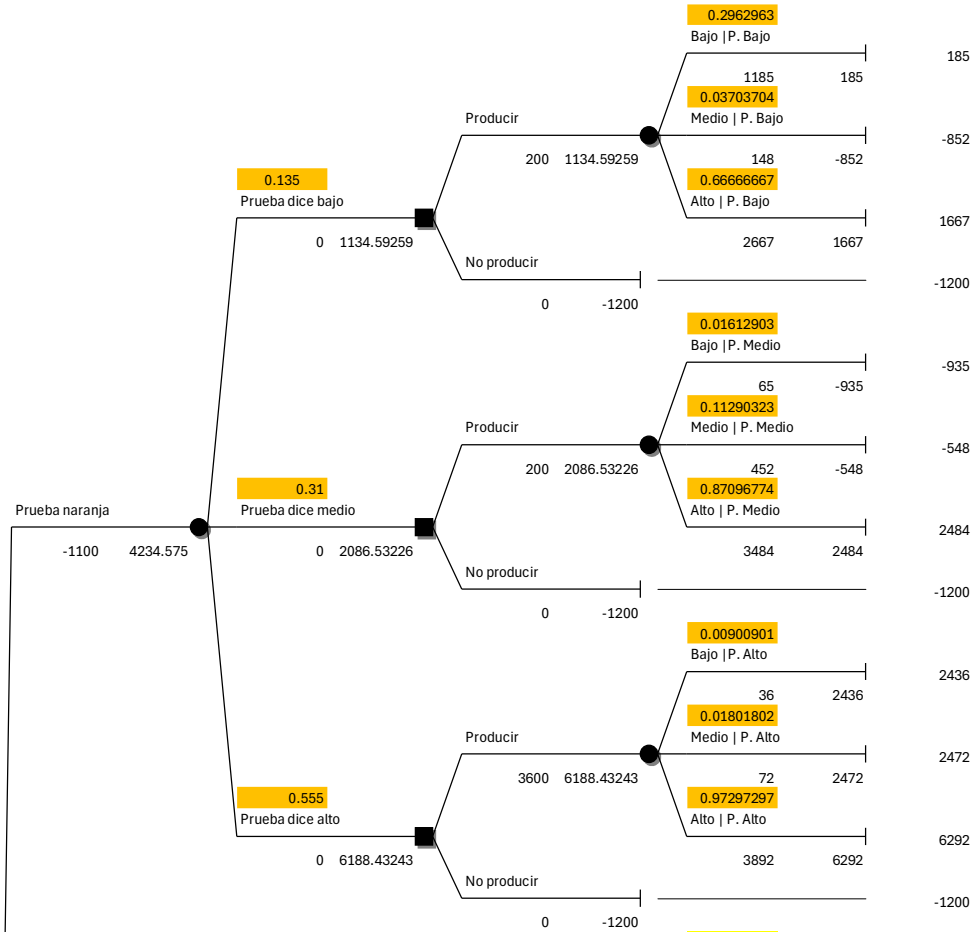

Figura 24. Rama del árbol bayesiano con prueba previa considerando la variable disponibilidad del estabilizador usando cáscara de naranja. Fuente: elaboración propia.

La figura 22 presenta el detalle para la rama con prueba previa para el proceso de desarrollo de nanohíbridos, considerando la variable disponibilidad y usando como estabilizador cáscara de plátano.

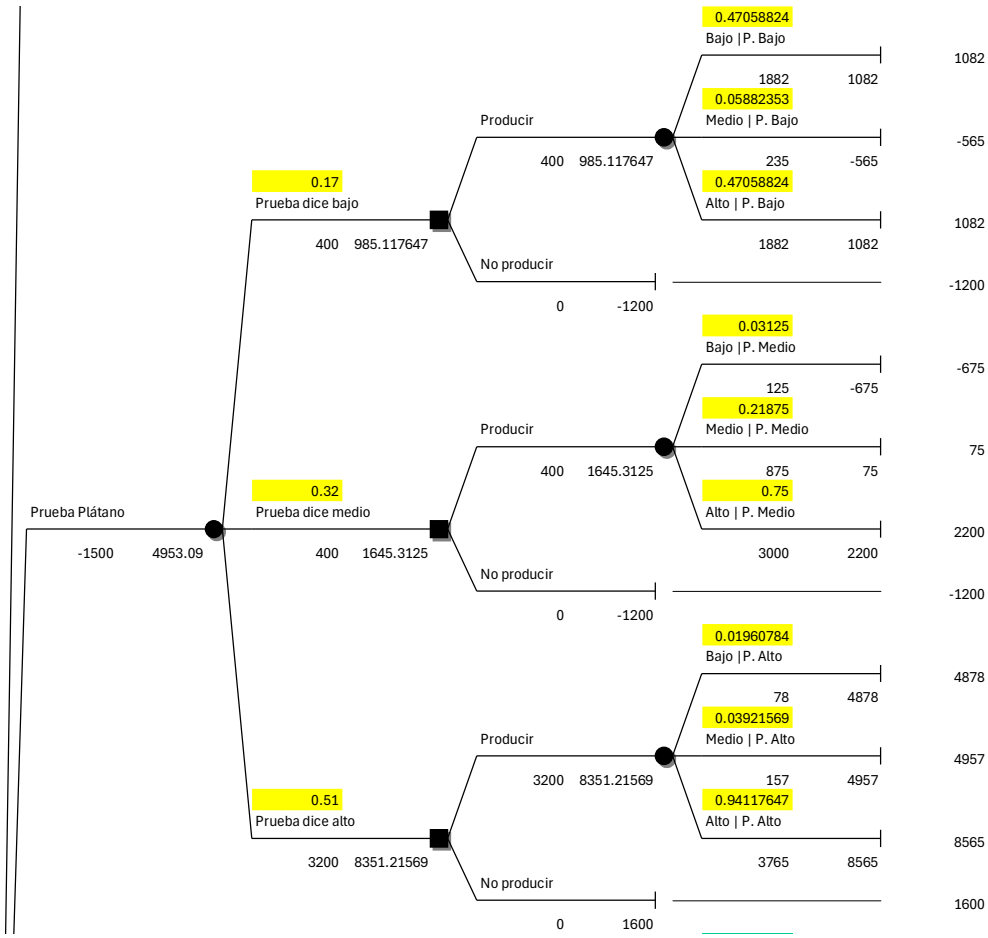

Figura 25. Rama del árbol bayesiano con prueba previa considerando la variable disponibilidad del estabilizador usando cáscara de plátano. Fuente: elaboración propia.

La figura 23 presenta el detalle para la rama con prueba previa para el proceso de desarrollo de nanohíbridos, considerando la variable disponibilidad y usando como estabilizador hueso de aguacate.

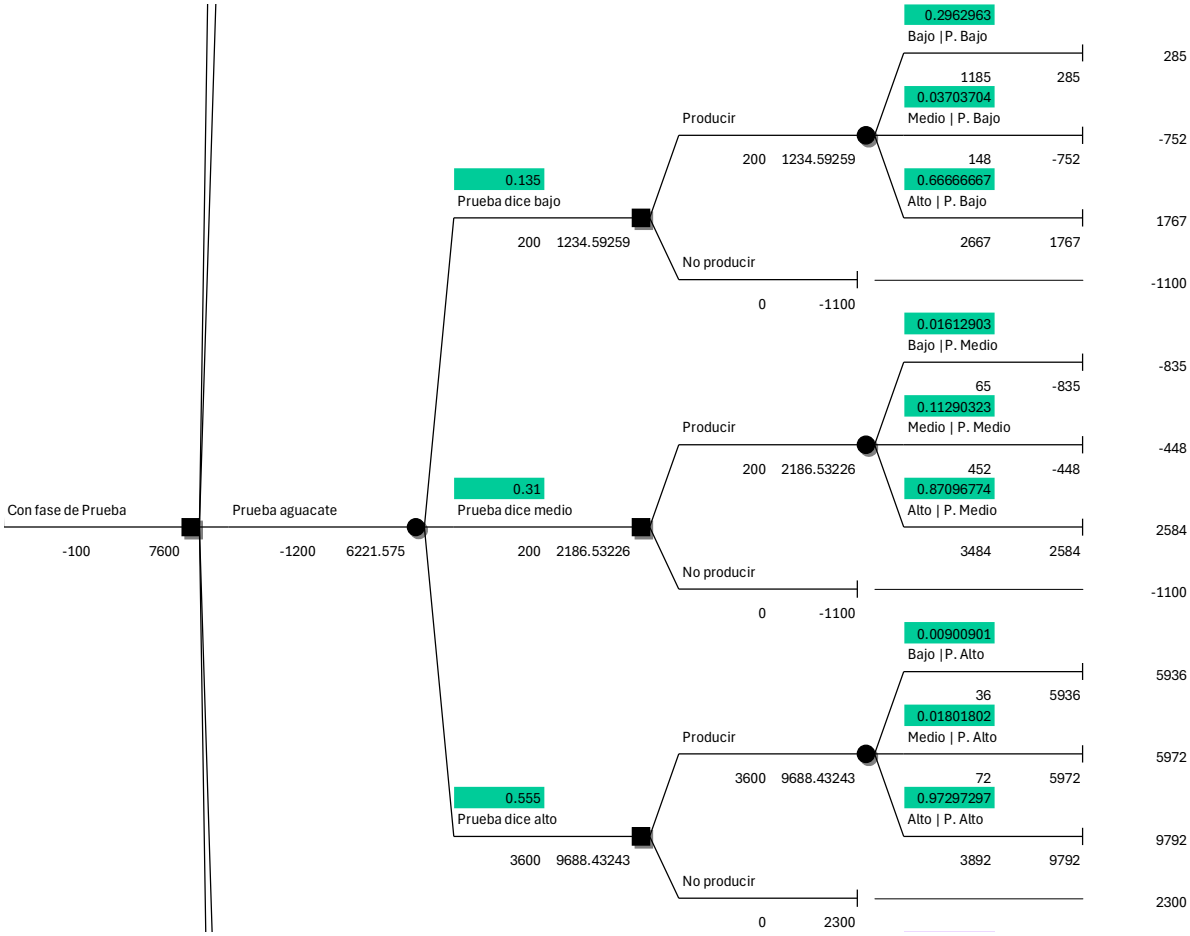

Figura 26. Rama del árbol bayesiano con prueba previa considerando la variable disponibilidad del estabilizador usando hueso de aguacate. Fuente: elaboración propia.

La figura 24 presenta el detalle para la rama con prueba previa para el proceso de desarrollo de nanohíbridos, considerando la variable disponibilidad y usando como estabilizador ajo.

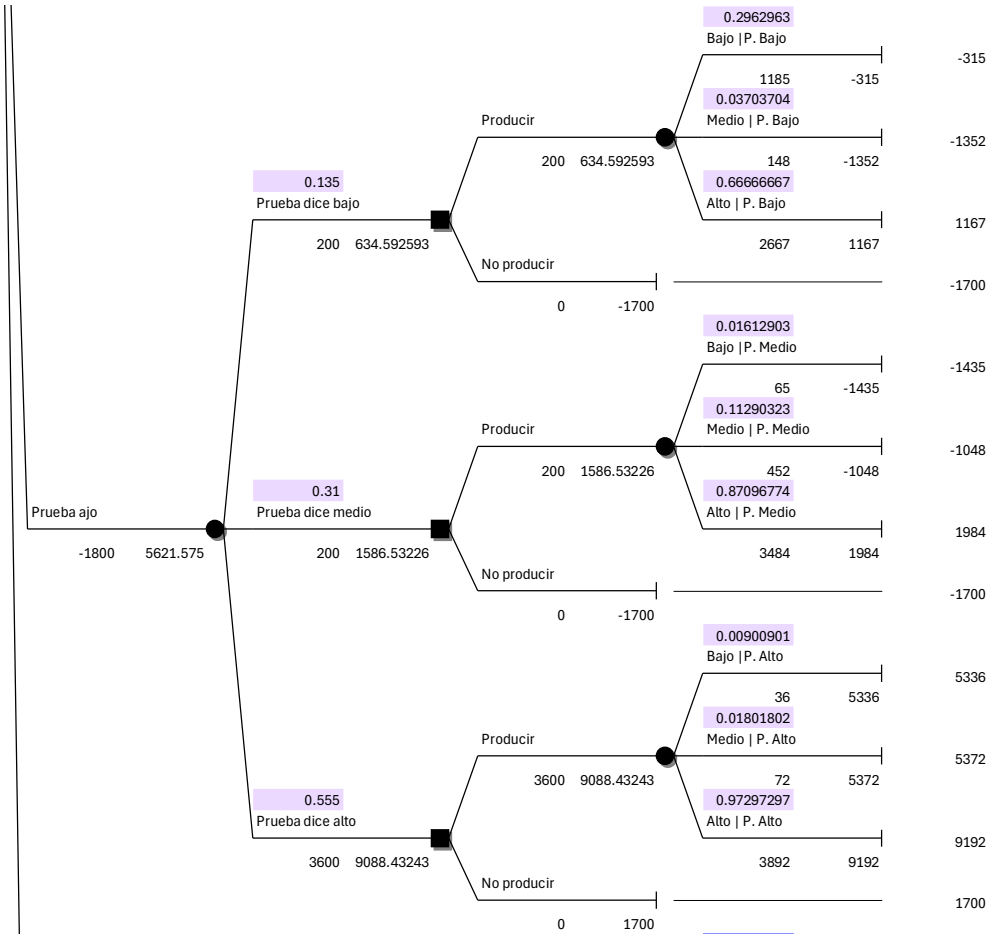

Figura 27. Rama del árbol bayesiano con prueba previa considerando la variable disponibilidad del estabilizador usando ajo. Fuente: elaboración propia.

La figura 25 presenta el detalle para la rama con prueba previa para el proceso de desarrollo de nanohíbridos, considerando la variable disponibilidad y usando como estabilizador hojas de eucalipto.

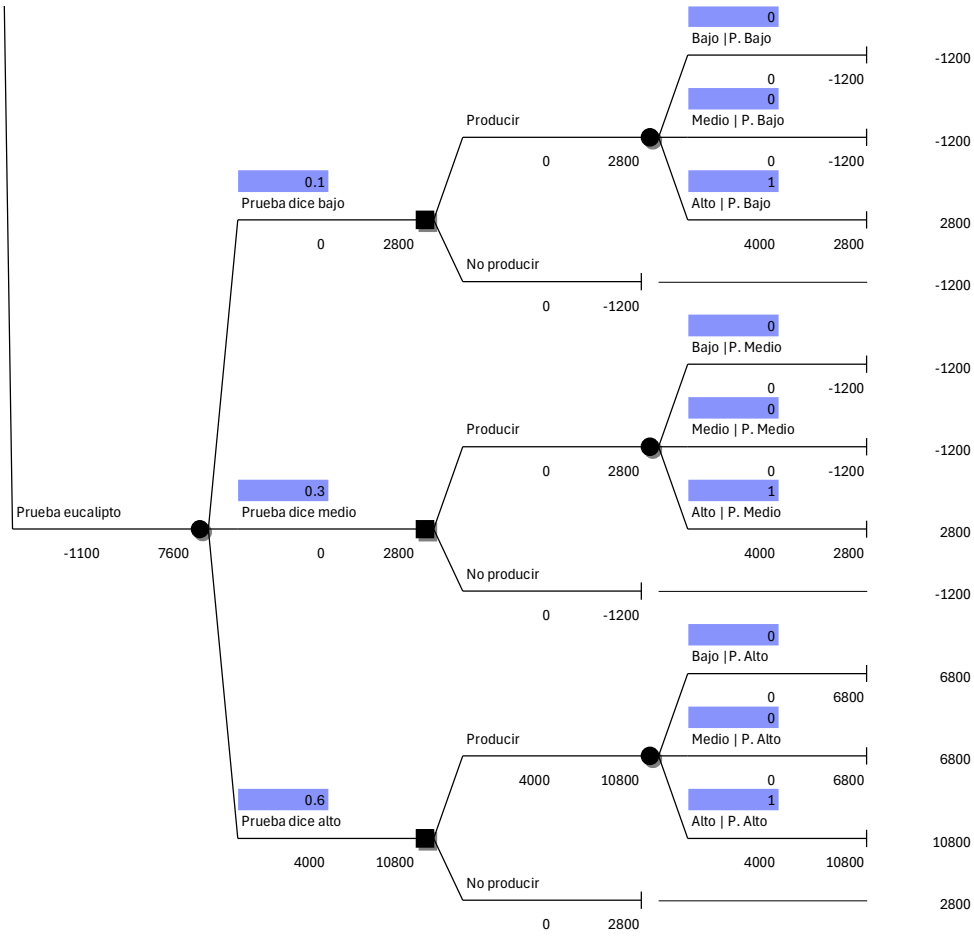

Figura 28. Rama del árbol bayesiano con prueba previa considerando la variable disponibilidad del estabilizador usando hojas de eucalipto. Fuente: elaboración propia.

En la figura 26 se muestra el árbol desarrollado con los valores de probabilidad para la variable eficiencia del proceso usando como estabilizador de este, cáscara de naranja, y a la derecha dentro de la misma figura se encuentran los valores provenientes de la evidencia del experto proporcionando valores conocidos como información perfecta.

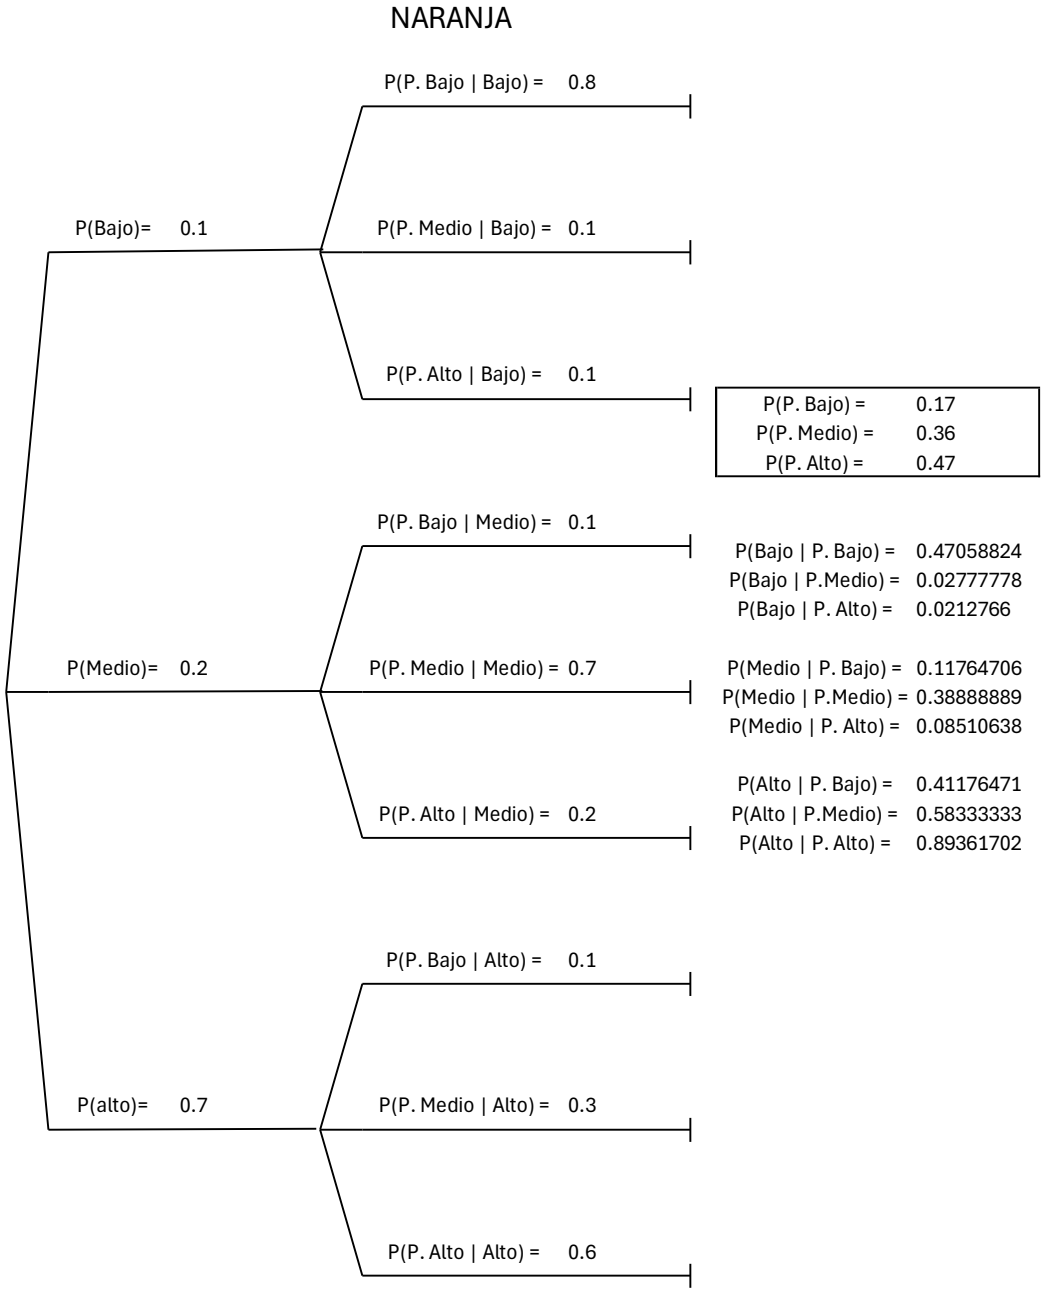

Figura 29. Árbol para la variable eficiencia del proceso con la cáscara de naranja. Fuente: Elaboración propia.

En la figura 27 se muestra el árbol desarrollado con los valores de probabilidad para la variable eficiencia del proceso usando como estabilizador de este, cáscara de plátano, y a la derecha dentro de la misma figura se encuentran los valores provenientes de la evidencia del experto proporcionando valores conocidos como información perfecta.

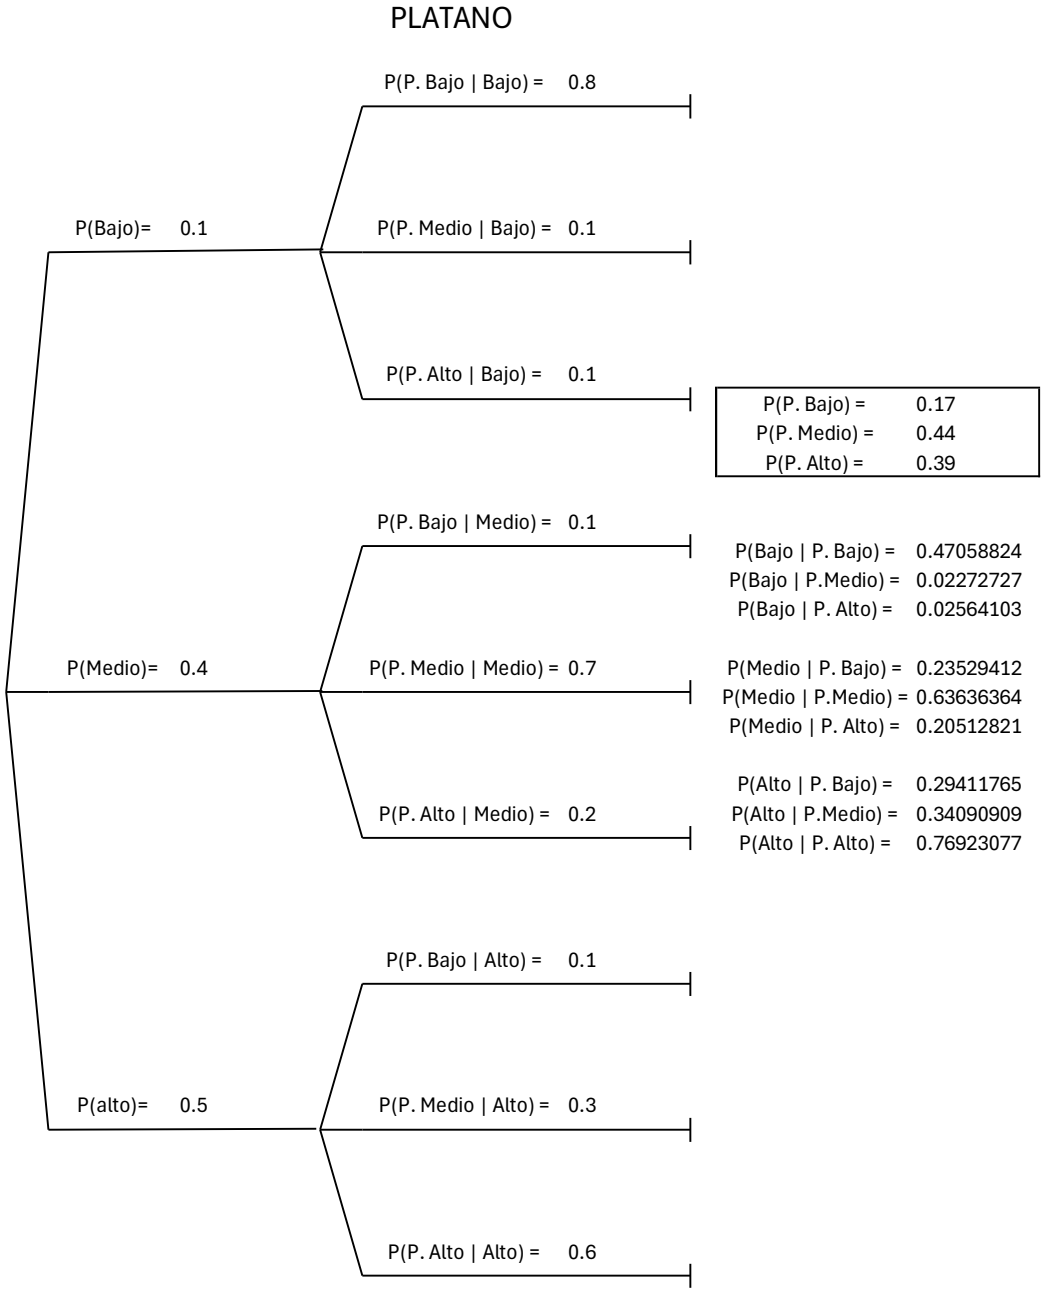

Figura 30. Árbol para la variable eficiencia del proceso con la cáscara de plátano. Fuente: Elaboración propia.

En la figura 28 se muestra el árbol desarrollado con los valores de probabilidad para la variable eficiencia del proceso usando como estabilizador de este, hueso de aguacate, y a la derecha dentro de la misma figura se encuentran los valores provenientes de la evidencia del experto proporcionando valores conocidos como información perfecta.

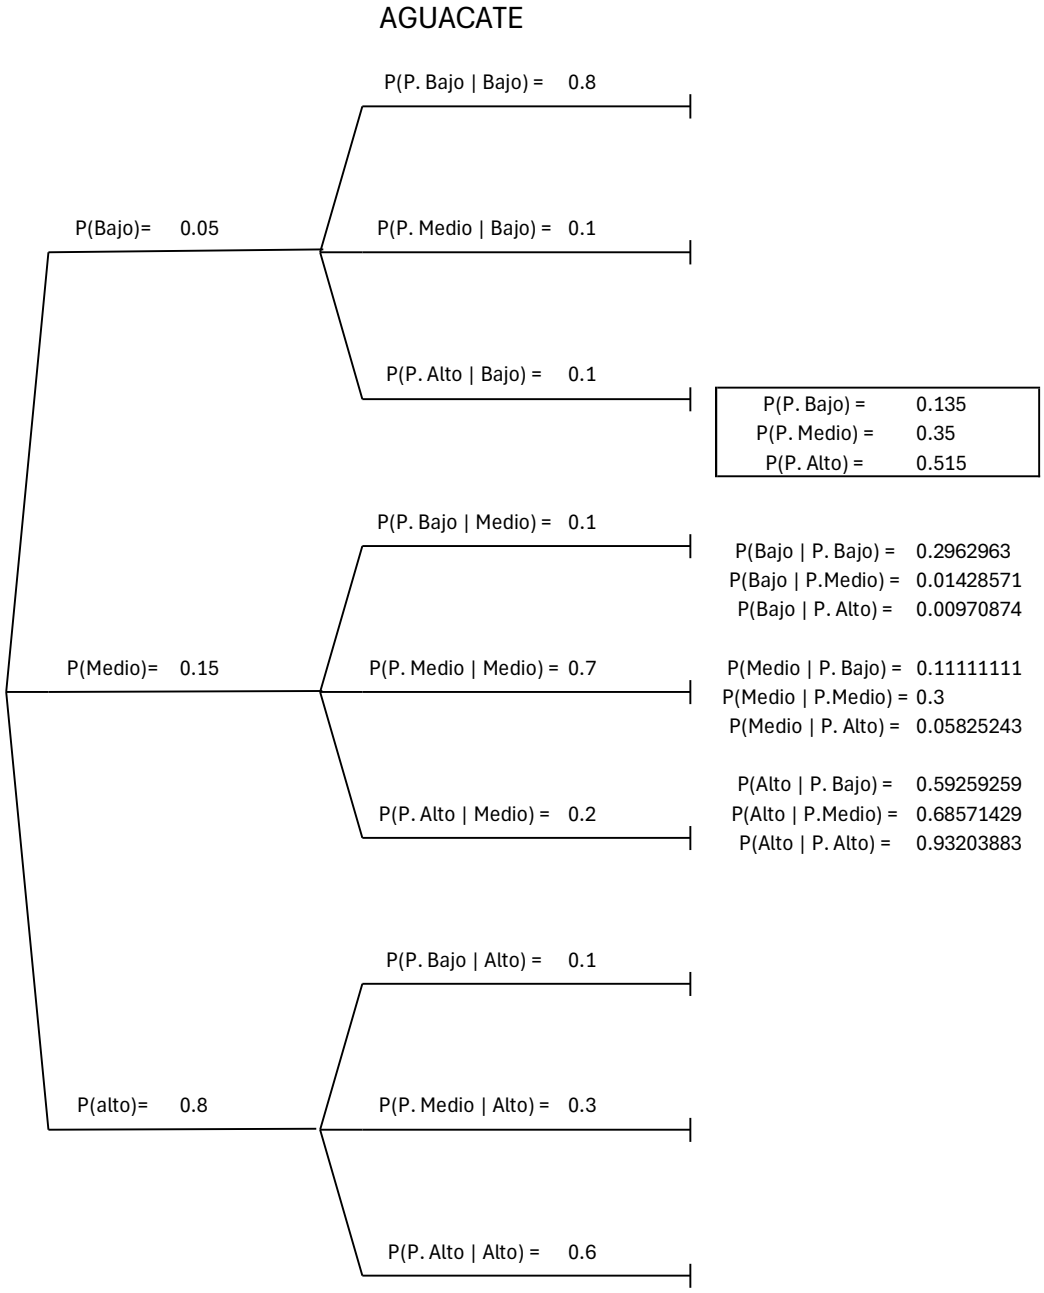

Figura 31. Árbol para la variable eficiencia del proceso con el hueso de aguacate. Fuente: Elaboración propia.

En la figura 29 se muestra el árbol desarrollado con los valores de probabilidad para la variable eficiencia del proceso usando como estabilizador de este, ajo, y a la derecha dentro de la misma figura se encuentran los valores provenientes de la evidencia del experto proporcionando valores conocidos como información perfecta.

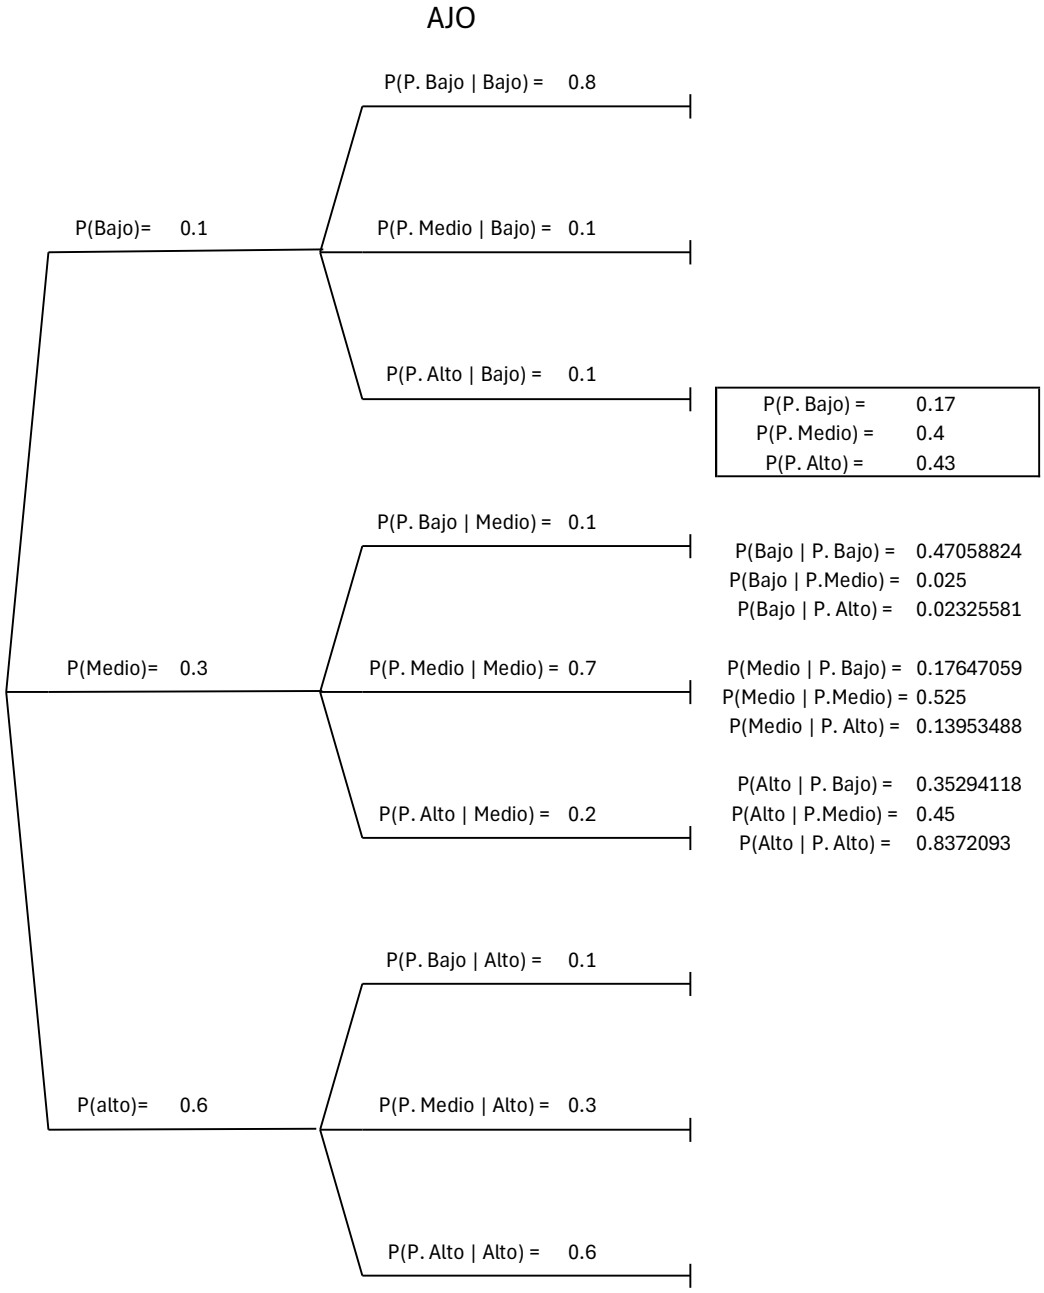

Figura 32. Árbol para la variable eficiencia del proceso con ajo. Fuente: Elaboración propia.

En la figura 30 se muestra el árbol desarrollado con los valores de probabilidad para la variable eficiencia del proceso usando como estabilizador de este, hojas de eucalipto, y a la derecha dentro de la misma figura se encuentran los valores provenientes de la evidencia del experto proporcionando valores conocidos como información perfecta.

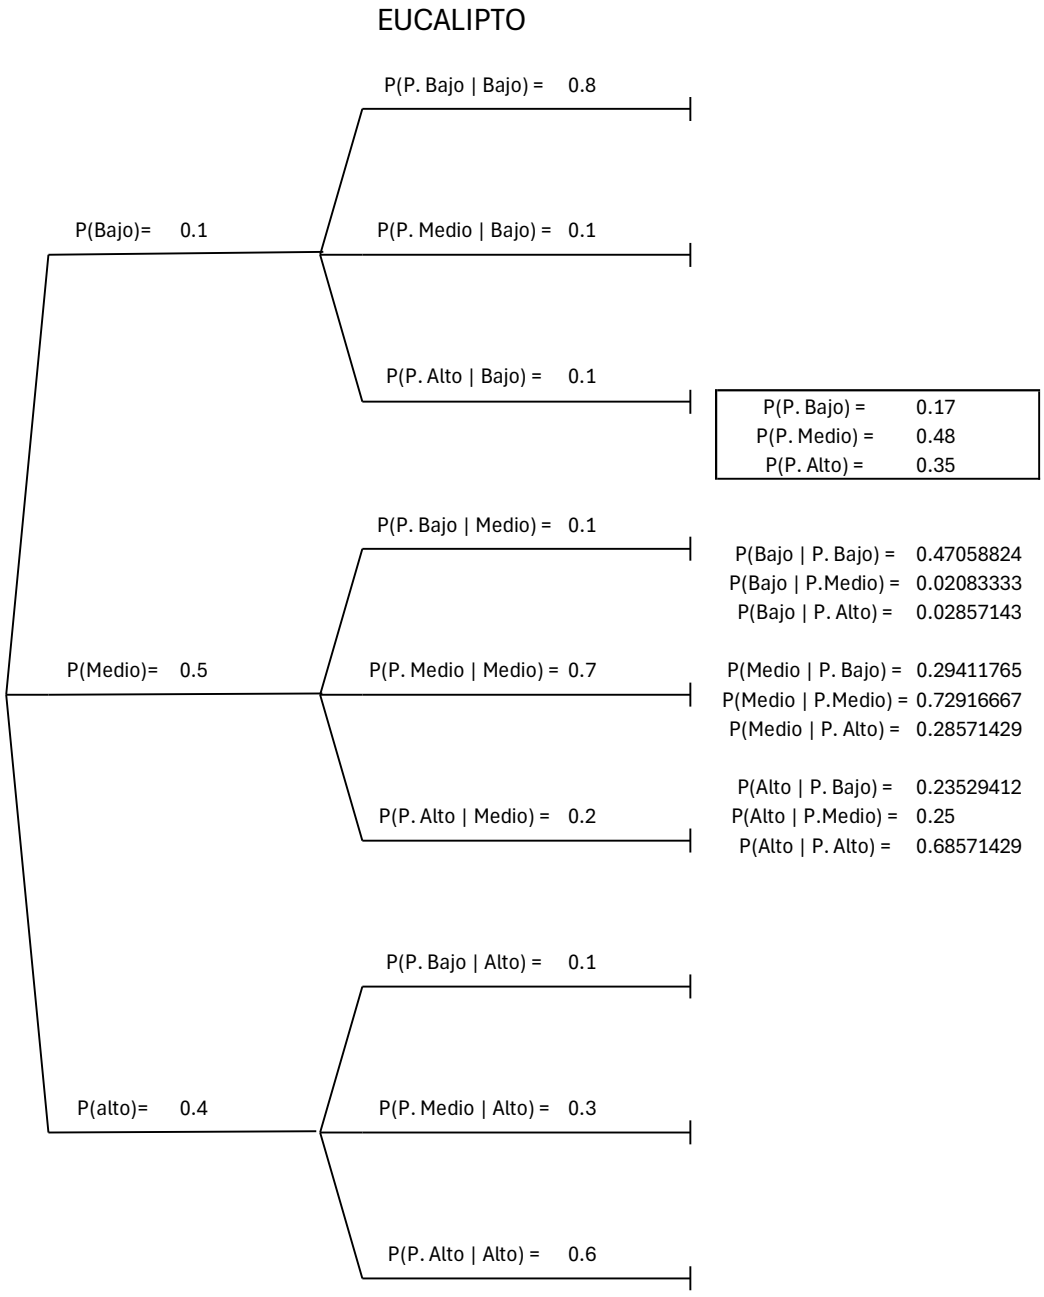

Figura 33. Árbol para la variable eficiencia del proceso con hojas de eucalipto. Fuente: Elaboración propia.

El árbol bayesiano para la variable eficiencia del proceso donde se consideran dos alternativas, con prueba previa y sin ella, se presenta en las figuras 31 y 32 para cada alternativa, respectivamente.

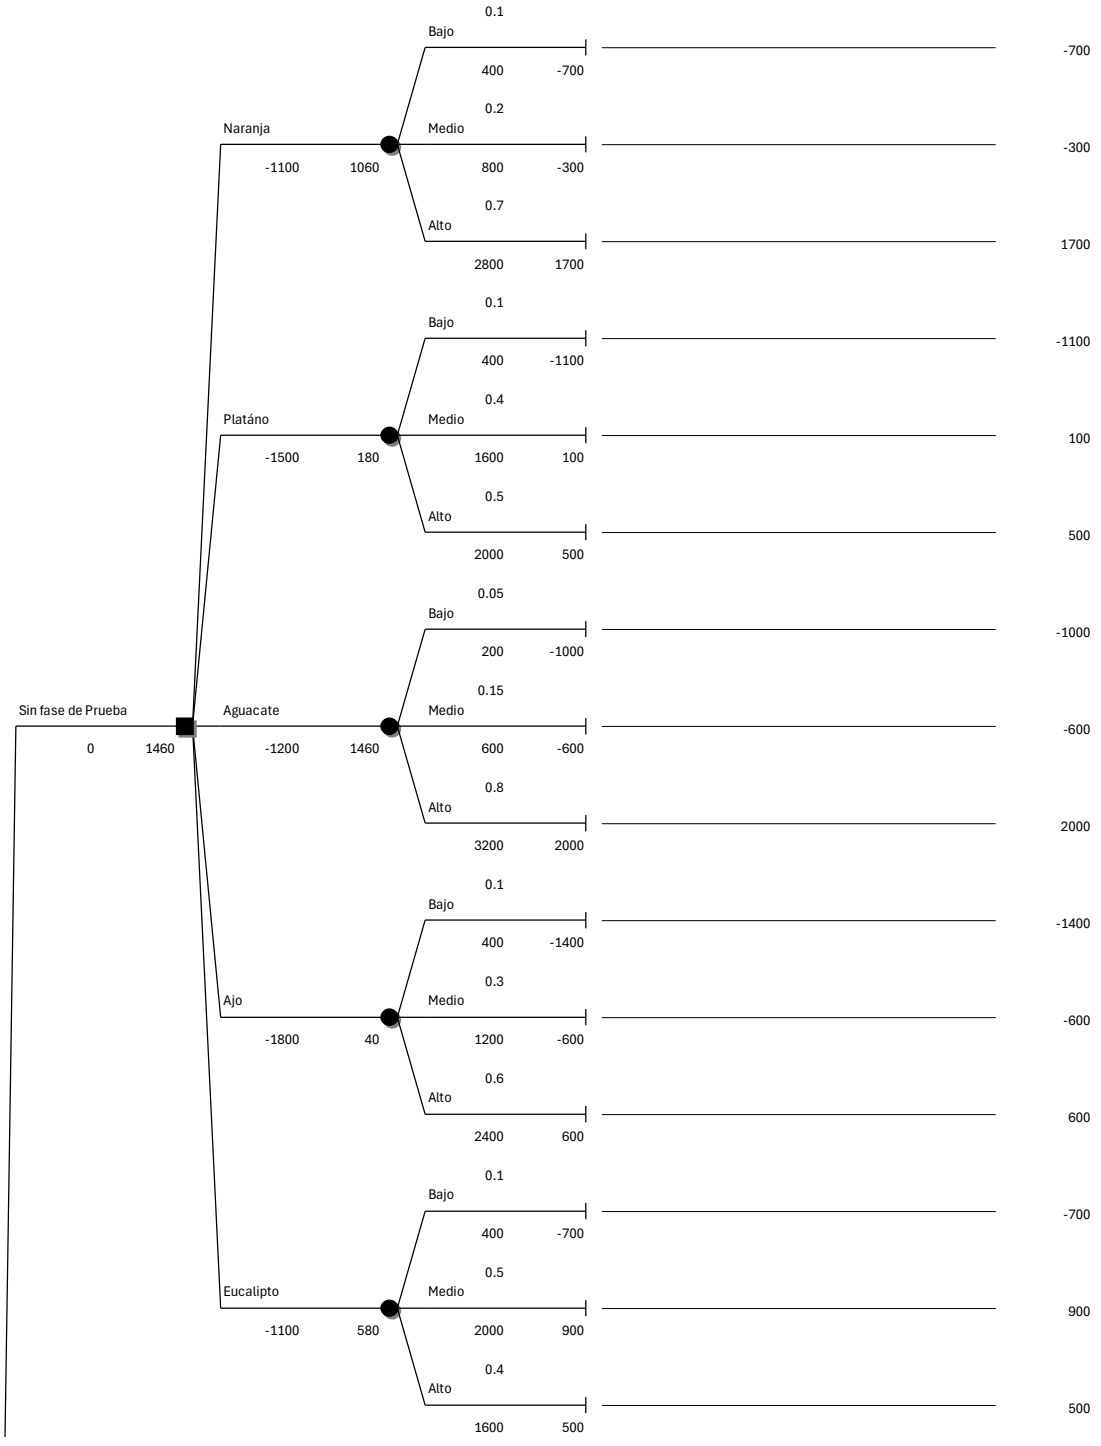

Figura 34. Rama del árbol bayesiano para la variable eficiencia del proceso con los 5 materiales orgánicos sin prueba previa. Fuente: Elaboración propia.

La figura 32 muestra la rama del árbol desarrollado para la alternativa de fabricación de nanohíbridos con prueba previa y considerando la eficiencia del proceso. Por cuestiones de espacio y presentación, en las siguientes 5 figuras se muestra cada rama del árbol correspondiente a los 5 estabilizadores empleados.

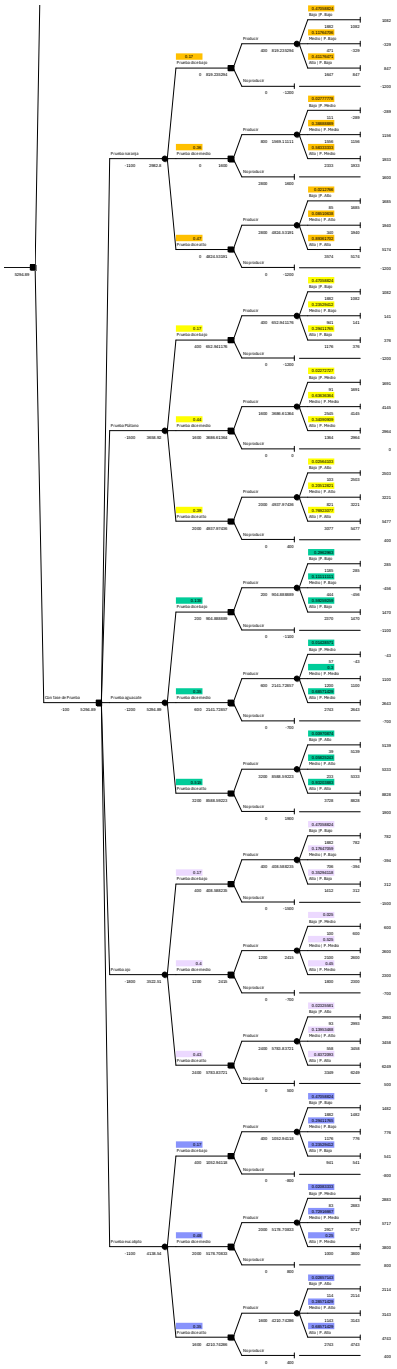

Figura 35. Rama del árbol bayesiano para la variable eficiencia del proceso con los 5 materiales orgánicos con prueba previa. Fuente: Elaboración propia.

La figura 33 presenta el detalle para la rama con prueba previa para el proceso de desarrollo de nanohíbridos, considerando la variable eficiencia del proceso y usando como estabilizador cáscara de naranja.

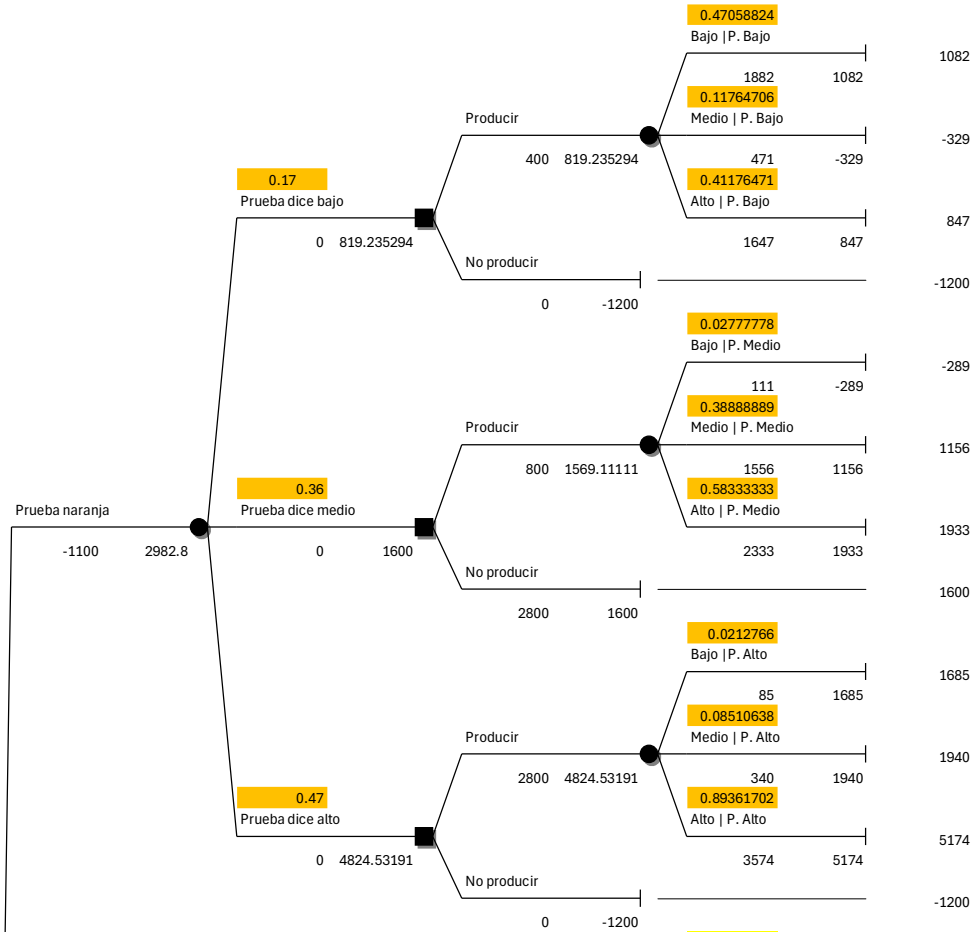

Figura 36. Rama del árbol bayesiano con prueba previa considerando la variable eficiencia del proceso con el estabilizador cáscara de naranja. Fuente: elaboración propia.

La figura 34 presenta el detalle para la rama con prueba previa para el proceso de desarrollo de nanohíbridos, considerando la variable eficiencia del proceso y usando como estabilizador cáscara de plátano.

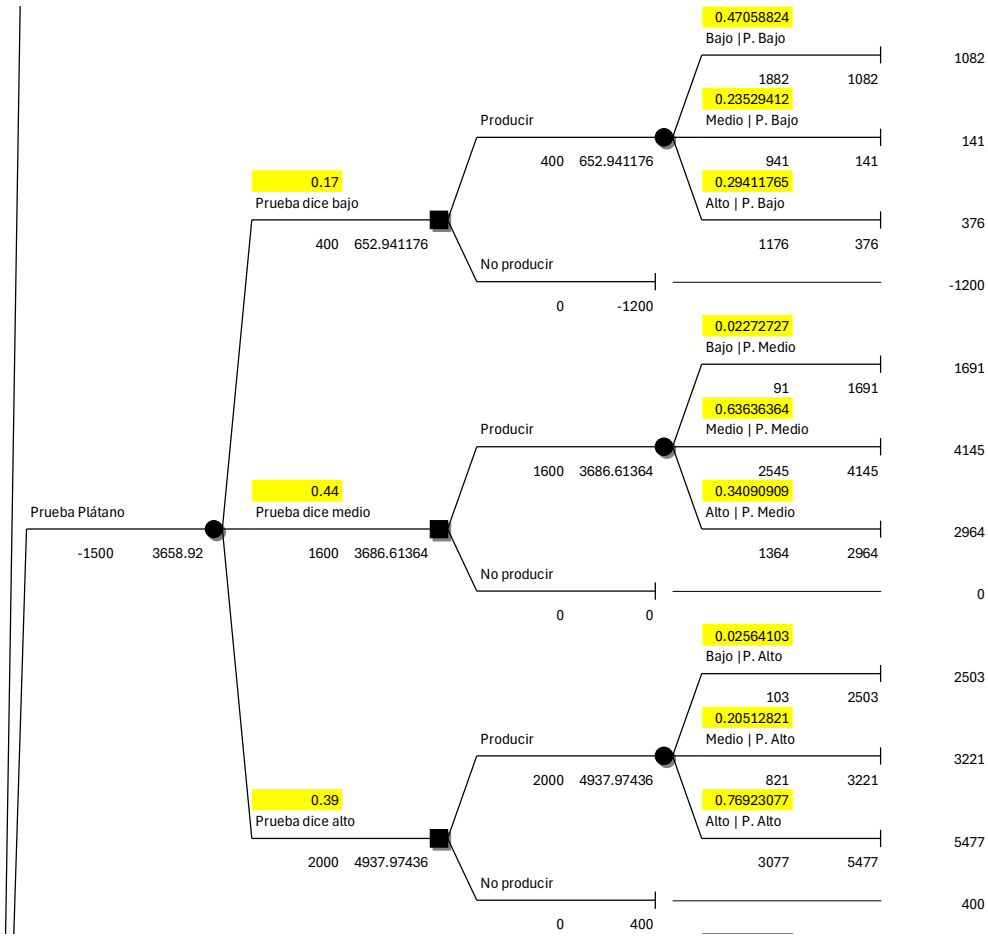

Figura 37. Rama del árbol bayesiano con prueba previa considerando la variable eficiencia del proceso con el estabilizador cáscara de plátano. Fuente: elaboración propia.

La figura 35 presenta el detalle para la rama con prueba previa para el proceso de desarrollo de nanohíbridos, considerando la variable eficiencia del proceso y usando como estabilizador hueso de aguacate.

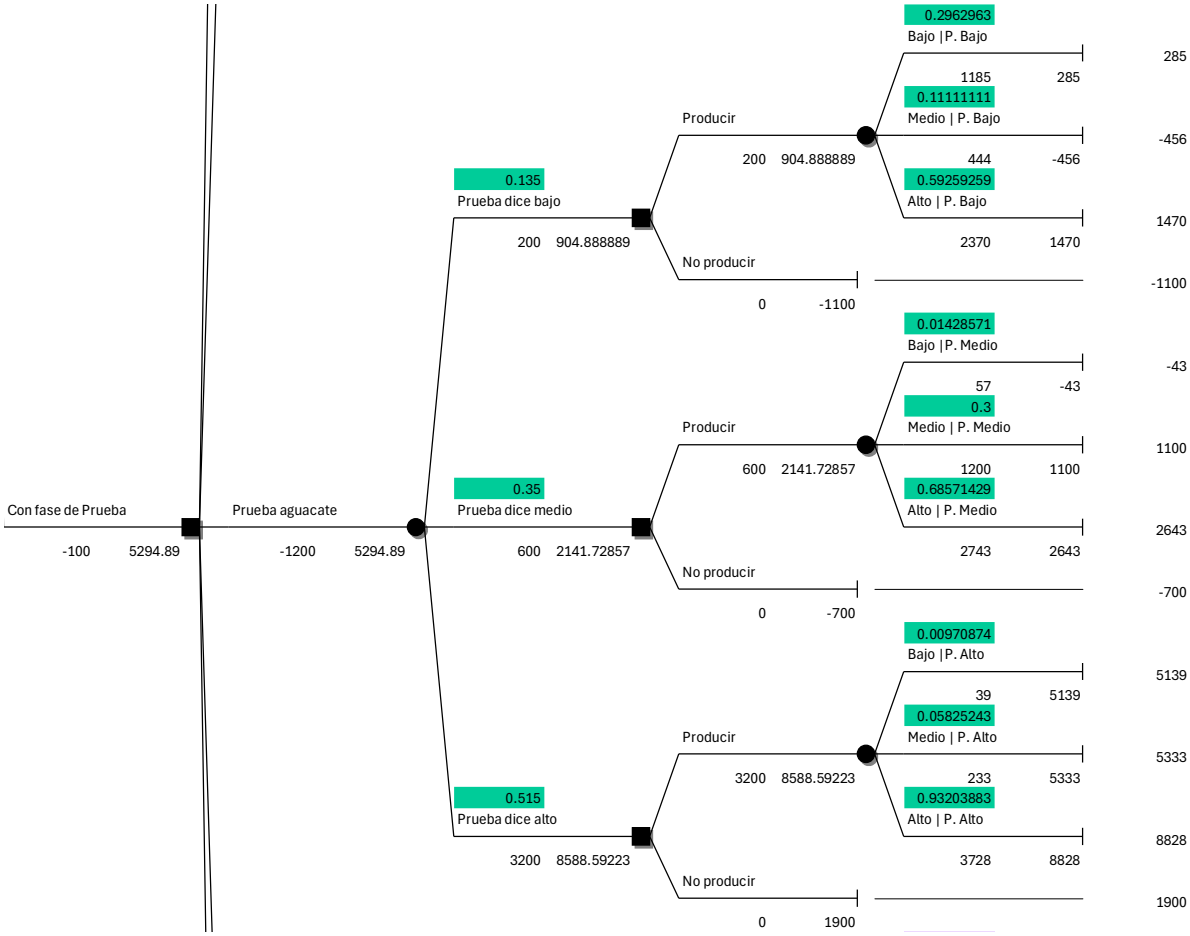

Figura 38. Rama del árbol bayesiano con prueba previa considerando la variable eficiencia del proceso con el estabilizador hueso de aguacate. Fuente: elaboración propia.

La figura 36 presenta el detalle para la rama con prueba previa para el proceso de desarrollo de nanohíbridos, considerando la variable eficiencia del proceso y usando como estabilizador ajo.

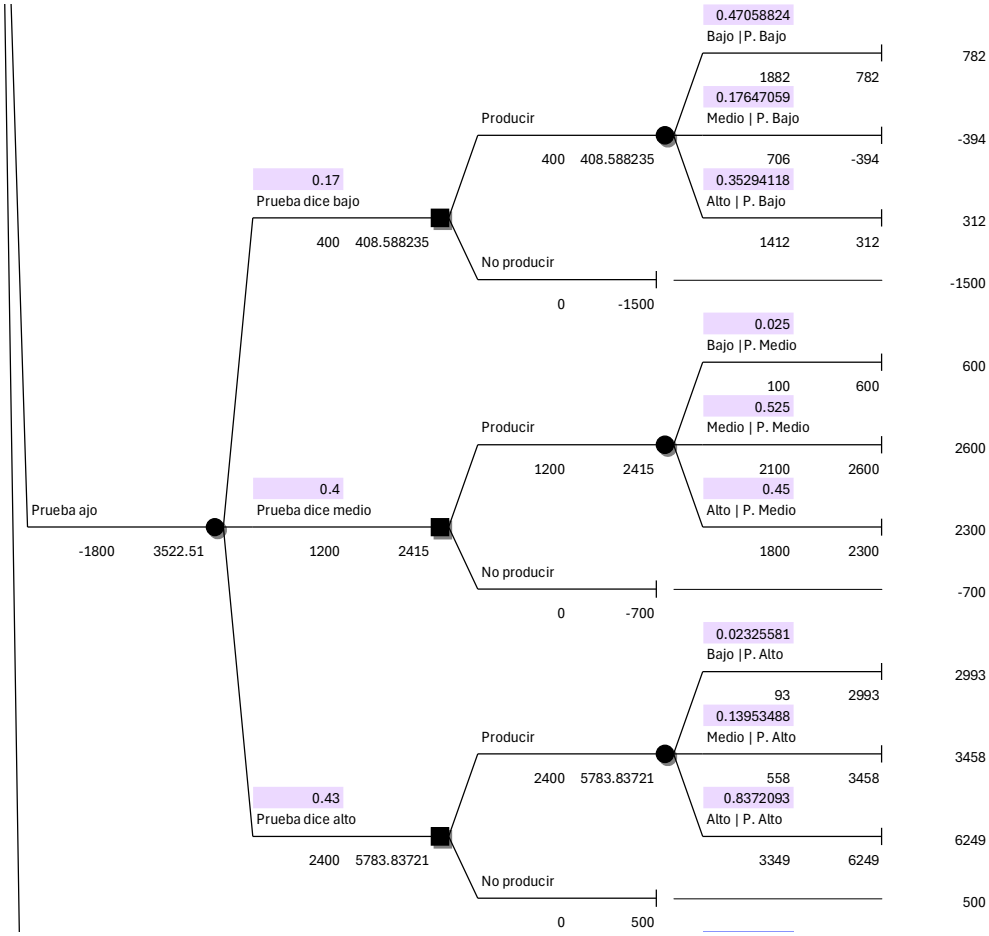

Figura 39. Rama del árbol bayesiano con prueba previa considerando la variable eficiencia del proceso con el estabilizador ajo. Fuente: elaboración propia.

La figura 37 presenta el detalle para la rama con prueba previa para el proceso de desarrollo de nanohíbridos, considerando la variable eficiencia del proceso y usando como estabilizador hojas de eucalipto.

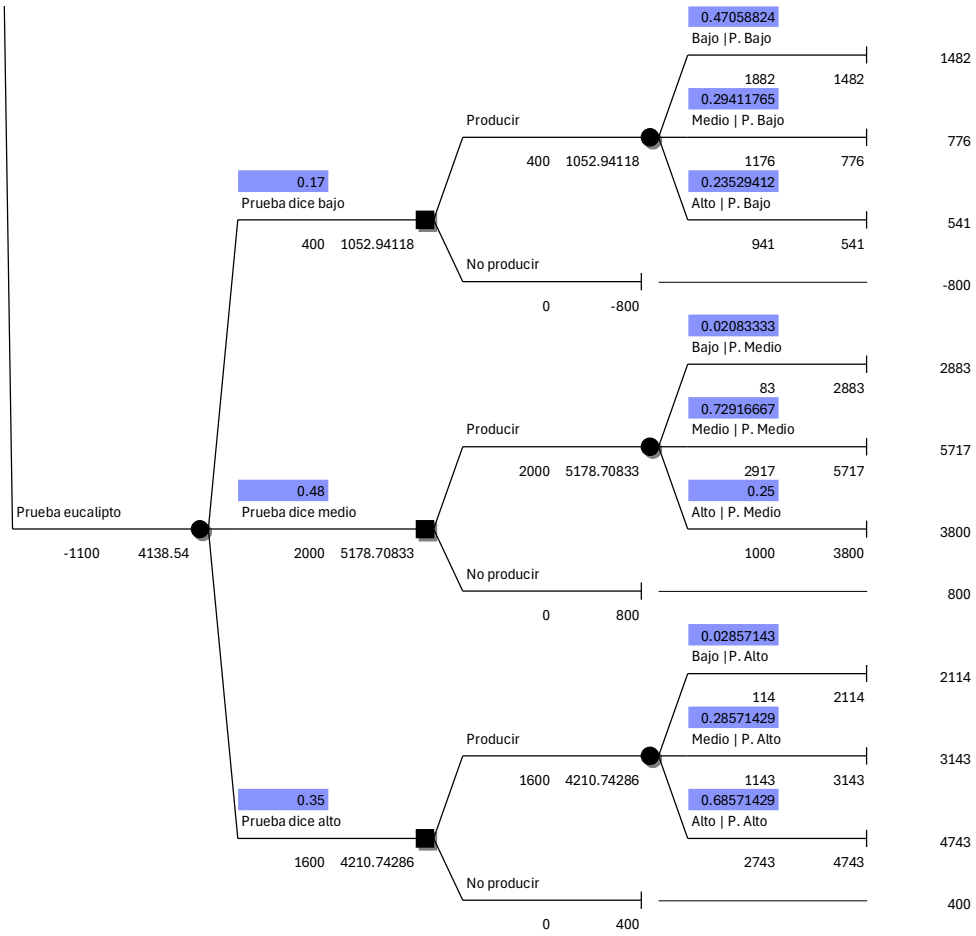

Figura 40. Rama del árbol bayesiano con prueba previa considerando la variable eficiencia del proceso con el estabilizador hojas de eucalipto. Fuente: elaboración propia.

La sección 3.4.6 muestra un ejemplo del uso del árbol bayesiano para el factor costo donde se concluye que la mejor opción de dicho árbol es realizar prueba previa usando como estabilizador hojas de eucalipto.

En el caso del factor disponibilidad del estabilizador se observa que de nueva cuenta la opción con mayor beneficio económico es usar hojas de eucalipto haciendo el proceso de creación de nanohíbridos con prueba previa.

Finalmente, para el factor eficiencia del proceso, el estabilizador con mejor resultado es el uso de hueso de aguacate como estabilizador, con prueba previa.

5. CONCLUSIONES

Un árbol bayesiano de decisión basado en la opinión de expertos es una herramienta poderosa en el proceso de creación de nanohíbridos con nanotubos de carbono, utilizando nitrato de plata como precursor y partículas orgánicas como estabilizadores. Este enfoque combina el conocimiento empírico y experimental con la capacidad analítica de los modelos probabilísticos, permitiendo una toma de decisiones informada y sistemática en un sistema complejo. Al integrar múltiples variables, como son los estabilizadores disponibles, desarrollo de pruebas y el beneficio económico, el árbol bayesiano facilita la identificación de los parámetros óptimos y las rutas más eficientes para lograr materiales con características específicas. Además, su capacidad para manejar incertidumbre y evaluar la influencia de factores interrelacionados lo convierte en una herramienta valiosa para optimizar los procesos de síntesis (que además son menos contaminantes al usar material orgánico), reducir costos y acelerar la innovación en el diseño de nanomateriales avanzados.

Los nanohíbridos de nanotubos de carbono (NTCs) y partículas de plata, sintetizados mediante procesos que emplean estabilizadores orgánicos como cáscaras de frutas o residuos vegetales, presentan un gran potencial para aplicaciones de descontaminación de suelos y aguas en el Estado de México. Estos materiales combinan la elevada capacidad de adsorción y conductividad de los NTCs con las propiedades antimicrobianas y catalíticas de las nanopartículas de plata, logrando así la eliminación eficiente de contaminantes orgánicos, iones metálicos y microorganismos patógenos. El uso de estabilizadores orgánicos, además de reducir los costos y minimizar el impacto ambiental durante la síntesis, aprovecha residuos agrícolas de la región, alineándose con estrategias de economía circular. Este enfoque representa una solución innovadora y sostenible para enfrentar los retos de contaminación en un área con problemas críticos de calidad de agua y suelos, promoviendo la salud ambiental y el bienestar comunitario.

6. BIBLIOGRAFÍA

- Afrabandpey, Homayun & Peltola, Tomi & Piironen, Juho & Vehtari, Aki & Kaski, Samuel. (2019). Making Bayesian Predictive Models Interpretable: A Decision Theoretic Approach. 10.48550/arXiv.1910.09358.
- Afrabandpey, Homayun & Peltola, Tomi & Piironen, Juho & Vehtari, Aki & Kaski, Samuel. (2020). A decision-theoretic approach for model interpretability in Bayesian framework. Machine Learning. 109. 1-22. 10.1007/s10994-020-05901-8.
- Alali, H.A.; Saber, O.; Osama, A.; Ezzeldin, M.F. Fabrication of Effective Nanohybrids Based on Organic Species, Polyvinyl Alcohol and Carbon Nanotubes in Addition to Nanolayers for Removing Heavy Metals from Water under Severe Conditions. Molecules 2022, 27, 5054. https://doi.org/10.3390/molecules27165054
- Álvarez Merino, M. Á., Carrasco Marín, F., & Maldonado Hódar, F. (2014). *Desarrollo y aplicaciones de materiales avanzados de carbón*. Universidad Internacional de Andalucía.
- Amin, M. R., Kumar, P. R., & Belharouak, I. (2020). Carbon Nanotubes: Applications to Energy Storage Devices. *IntechOpen*, 1-23
- Bautista Valhondo, J. (2020). Modelos y herramientas de decisión. Spain: Dextra Editorial S.L..
- Blanco-Mesa, Fabio & Gil-Lafuente, Anna & Merigo, Jose M.. (2017). Fuzzy decision making: A bibliometric-based review. Journal of Intelligent and Fuzzy Systems. 32. 2033-2050. 10.3233/JIFS-161640.
- Bolger, F. & Wright, G. (2007). Expertise and Decision Support. United Kingdom: Springer US.
- Díez-Pascual, A. M. (2021). *Chemical Functionalization of Carbon Nanotubes with Polymers: A Brief Overview*. Macromol, 1(2), 64-83. https://doi.org/10.3390/macromol1020006
- Dubey, R., Dutta, D., Sarkar, A., & Chattopadhyay, P. (2021). Functionalized carbon nanotubes: Synthesis, properties and applications in water purification, drug delivery, and material and biomedical sciences. *Nanoscale Advances, 3*(9), 5722-5744. https://doi.org/10.1039/D1NA00293G

- Eiselt, H. A., Sandblom, C. (2013). Decision Analysis, Location Models, and Scheduling Problems. Germany: Springer Berlin Heidelberg.
- Evans, G. W. (2016). Multiple Criteria Decision Analysis for Industrial Engineering: Methodology and Applications. United States: CRC Press.
- Evans, M. J., Rosenthal, J. S. (2018). Probabilidad y estadística: La ciencia de la incertidumbre. España: Reverte.
- Gelman, A. (2014). Bayesian Data Analysis, Third Edition. United Kingdom: Taylor & Francis.
- Goodwin, P., Wright, G. (2014). Decision Analysis for Management Judgment. United Kingdom: Wiley.
- Guerrero Salas, H., Mayorga Morato, M. A., Antonio Suárez, O. d. (2014). Teoría de la decisión aplicada: Análisis de decisiones bajo incertidumbre, riesgo y teoría de juegos. Colombia: Ecoe Ediciones.
- Hardman, D., Hardman, D. K. (2009). Judgment and Decision Making: Psychological Perspectives. United Kingdom: Wiley.
- Hastie, T., Tibshirani, R., Friedman, J., Friedman, J. H. (2009). The Elements of Statistical Learning: Data Mining, Inference, and Prediction, Second Edition. Netherlands: Springer New York.
- Hornyak, G. L., Moore, J. J., Tibbals, H., Dutta, J. (2018). Fundamentals of Nanotechnology. United Kingdom: CRC Press.
- Lumbreras, S. S. (2024) La incertidumbre desde la ingeniería. Diálogo Filosófico. No. 118., España. ISSN: 0213-1196
- Luna-Victoria-León, Gustavo & Collao-Diaz, Martin & Corzo-Chávez, Jorge & Meza-Ortiz, Richard. (2022). El plan maestro de producción y la incertidumbre en el sector manufactura: una revisión de la literatura. Ingeniería Industrial. 35-59. 10.26439/ing.ind2022.n43.6108.
- Nielsen, T. D., VERNER JENSEN, F. (2013). Bayesian Networks and Decision Graphs. Germany: Springer New York.
- O'Leary, J. (2018). Introducción a la nanotecnología. (n.p.): Creative Media Partners, LLC.

- Parnell, G., Driscoll, P., Henderson, D. Decision Making in Systems Engineering and Management. (2008). United Kingdom: Wiley.
- Poole, C. P. J., Owens, F. J. (2023). Introducción a la Nanotecnología. Spain: Reverte.
- Ríos Insúa, S., Mateos Caballero, A., Bielza Lozoya, M. C., Jiménez Martín, A. (2004). Investigación operativa: modelos determinísticos y estocásticos. España: Editorial Universitaria Ramón Areces.
- Rodríguez Estrada, M. (2015). Manejo de problemas y toma de decisiones. Mexico: Editorial El Manual Moderno.
- Singh, C., Shaffer, M., & Windle, A. H. (2003). Production of controlled architectures of aligned carbon nanotubes by an injection chemical vapour deposition method. *Carbon*, *41*(2), 359-368.
- Spiegelhalter, D. (2023). El arte de la estadística. España: Capitán Swing Libros.
- Taha, H. A. (2011). Operations Research: An Introduction. United Kingdom: Prentice Hall.
- Tao, Z., Zhao, Y., Wang, Y., & Zhang, G. (2024). Recent advances in carbon nanotube technology: Bridging the gap from fundamental science to wide applications. *C*, *10*(3), 69. https://doi.org/10.3390/c10030069
- Taylor, J. R. (2018). Introducción al análisis de errores: El estudio de las incertidumbres en las mediciones físicas. España: Reverte.
- Yahyazadeh, A., Nanda, S., & Dalai, A. K. (2024). Carbon Nanotubes: A Review of Synthesis Methods and Applications. *Reactions,* *5*(3), 429-451. https://doi.org/10.3390/reactions5030022