

Framework basado en minería de datos para el apoyo de los procesos en la gestión del  
riesgo en la cadena de suministro hospitalaria

Magda Lorena Rangel Granados

Trabajo de investigación para optar al título de Magíster en Ingeniería Industrial

Director:

Henry Lamos Díaz

PhD. Matemática - Física

Grupo de investigación:

Organización y Optimización de Sistemas Productivos, Administrativos y Logísticos

OPALO

Universidad Industrial de Santander

Facultad de Ingenierías Físico-Mecánicas

Escuela de Estudios Industriales y Empresariales

Maestría en Ingeniería Industrial

Bucaramanga

2026

**Tabla de contenido**

Introducción .....	9
1. Objetivos .....	11
1.1 Objetivo general.....	11
1.2 Objetivos específicos .....	11
2. Hipótesis .....	11
3. Planteamiento del problema.....	12
4. Metodología .....	15
4.1. Etapa 1: Descripción cualitativa del problema .....	16
4.2. Etapa 2: Integración y recopilación .....	16
4.3. Etapa 3: Selección, limpieza y transformación.....	17
4.4. Etapa 4: Minería de datos .....	17
4.5. Etapa 5: Evaluación e interpretación .....	18
4.6. Etapa 6: Difusión y uso.....	18
5. Revisión de literatura .....	18
6. Minería de texto para identificar riesgos y sus factores.....	35
6.1. Fase 1: Definición de factores de riesgo a partir de literatura académica .....	36
6.2. Fase 2: Reconocimiento de patrones de riesgo a partir de noticias online .....	38
6.3. Guía para la gestión del riesgo.....	43
7. Modelo de decisión multicriterio .....	54
7.1. Fase I: Ponderación de criterios mediante AHP .....	55
7.1.1. <i>Encuesta Juicio de expertos</i> .....	55

7.2.	Fase II: Jerarquización de Riesgos mediante TOPSIS.....	62
8.	Framework para la gestión del riesgo de la CSH basado en MD .....	66
8.1.	Fase I: Identificación y fuentes de datos (Data Sources).....	66
8.2.	Fase II: Almacenamiento y preprocesamiento (Risk Data Warehouse).....	72
8.3.	Fase III: Módulo de evaluación y priorización (MCDM).....	72
8.4.	Fase IV: Módulo de minería de datos (The data mining core) .....	73
8.5.	Fase V: Soporte a la decisión y mitigación.....	74
8.6.	Fase VI: Monitoreo y aprendizaje continuo.....	75
8.7.	Validación del Framework mediante simulación de escenarios con datos sintéticos	77
8.7.1.	<i>Generación e ingreso de datos (Validación de Fases I y II) .....</i>	<i>77</i>
8.7.2.	<i>Filtrado y Priorización de Riesgos (Validación de Fase III) .....</i>	<i>78</i>
8.7.3.	<i>Aplicación de Algoritmos de Minería de Datos (Validación de Fase IV) .....</i>	<i>78</i>
8.7.4.	<i>Soporte a la decisión y retroalimentación (Validación de Fases V y VI).....</i>	<i>81</i>
9.	Conclusiones.....	82
10.	Recomendaciones .....	86
	Referencias bibliográficas.....	87

### Lista de tablas

Tabla 1 Investigaciones en salud que utilizan minería de datos .....	19
Tabla 2 Modelos asociados a las interrupciones de las SC.....	24
Tabla 3 Aplicaciones de Blockchain en salud .....	32
Tabla 4 Técnica de IA/ML/PLN.....	34
Tabla 5 Aplicación de tecnologías en gestión de riesgos hospitalarios .....	34
Tabla 6 Escala probabilidad.....	48
Tabla 7 Escala impacto .....	49
Tabla 8 Atributos para el diseño de los controles .....	50
Tabla 9 Tratamiento de los riesgos según la zona .....	53
Tabla 10 Escala Saaty .....	57
Tabla 11 Probabilidad vs Impacto .....	57
Tabla 12 Probabilidad vs. Detectabilidad .....	58
Tabla 13 Impacto vs Detectabilidad .....	58
Tabla 14 Calificación de riesgos.....	60
Tabla 15 Matriz de juicios de los criterios.....	61
Tabla 16 Vector de pesos.....	62
Tabla 17 Ratio de consistencia .....	62
Tabla 18 Cálculos riesgos .....	64
Tabla 19 Resumen de resultados MCDM.....	65
Tabla 20 ¿Cómo convertir problemas de gestión del riesgo en problemas de MD? .....	73

**Lista de figuras**

Figura 1 Etapas KDD.....	15
Figura 2 Métodos de minería de datos para la gestión del riesgo.....	22
Figura 3 Riesgos y factores de la CS global .....	23
Figura 4 Nube de palabras de términos relevantes .....	36
Figura 5 Resultados análisis de correlación y bi gramas .....	37
Figura 6 Nube de palabras modelado de temas .....	38
Figura 7 Resultados análisis noticias .....	40
Figura 8 Riesgos de la cadena de suministro hospitalaria .....	42
Figura 9 Metodología para la gestión del riesgo.....	46
Figura 10 Mapa de calor de riesgos .....	49
Figura 11 Movimiento en el mapa de calor .....	52
Figura 12 Stakeholders y factores.....	67
Figura 13 Matriz AVES.....	68
Figura 14 Matriz AVIP .....	69
Figura 15 Matriz AFOR para variables externas .....	70
Figura 16 Matriz AFOR para variables internas.....	71
Figura 17 Framework para la gestión del riesgo basado en MD .....	76
Figura 18 Validación de detectabilidad: Fallas en equipos médicos .....	78
Figura 19 Segmentación de riesgo de proveedores (Clustering) .....	79
Figura 20 Validación para identificar riesgos del entorno.....	81
Figura 21 Tablero de control de riesgos .....	81
Figura 22 Retroalimentación.....	82

## **Lista de apéndices**

Los apéndices están disponibles en el Repositorio Institucional.

**Apéndice A.** Análisis bibliométrico

**Apéndice B.** Códigos de programación en Google Colab

**Apéndice C.** Formato Matriz de Riesgos

**Apéndice D.** Resultados Juicio de expertos

**Apéndice E.** Código de validación del Framework

## Resumen

**Título:** Framework basado en minería de datos para el apoyo de los procesos en la gestión del riesgo en la cadena de suministro hospitalaria\*

**Autor:** Magda Lorena Rangel Granados\*\*

**Palabras Clave:** Minería de datos, cadena de suministro hospitalaria, gestión del riesgo.

**Descripción:** La gestión eficiente de la cadena de suministro hospitalaria se constituye como un componente estratégico para asegurar la continuidad y la calidad en la prestación de servicios de salud en Colombia. Sin embargo, este entorno se caracteriza por una alta complejidad y la presencia de incertidumbres operativas que amenazan constantemente la logística sanitaria. Para abordar estos desafíos, el presente trabajo propone y desarrolla un modelo de decisión integral orientado a la identificación, priorización y mitigación de riesgos en el contexto hospitalario, consolidando un enfoque innovador basado en datos.

La estructura metodológica del estudio se fundamenta en la integración sistemática de análisis de datos y modelos de decisión cuantitativa. Inicialmente, se aplicaron técnicas de minería de texto para procesar información no estructurada, lo que permitió descubrir y categorizar factores de riesgo críticos que suelen pasar desapercibidos en análisis convencionales, con un enfoque particular en la seguridad de datos, riesgos tecnológicos y aquellos derivados del entorno (tanto interno como externo). Estos factores fueron posteriormente evaluados mediante un modelo de Toma de Decisiones Multicriterio (MCDM); específicamente, se utilizó el Proceso de Jerarquía Analítica (AHP) para determinar la importancia relativa de cada criterio, y el método TOPSIS para priorizar los riesgos según su nivel de criticidad y probabilidad de ocurrencia.

Finalmente, el resultado central de la investigación se materializa en la construcción de un Framework metodológico. Este modelo proporciona una ruta clara para diagnosticar vulnerabilidades y seleccionar estrategias de respuesta basadas en evidencia. Se concluye que la combinación propuesta ofrece una solución práctica y adaptable para mejorar la toma de decisiones y la resiliencia operativa de las instituciones de salud.

---

\* Tesis de Maestría

\*\* Facultad de Ingeniería Físico - Mecánicas Escuela de Estudios Industriales y Empresariales.  
Director: Henry Lamos Díaz, PhD. Matemática

### Abstract

**Title:** A Data Mining-Based Framework for Supporting Risk Management Processes in the Hospital Supply Chain\*

**Author:** Magda Lorena Rangel Granados<sup>1</sup>

**Key Words:** Data mining, hospital supply chain, risk management.

**Description:** Efficient management of the hospital supply chain constitutes a strategic component to ensure continuity and quality in the provision of health services in Colombia. However, this environment is characterized by high complexity and the presence of operational uncertainties that constantly threaten health logistics. To address these challenges, this paper proposes and develops an integral decision-making model aimed at the identification, prioritization, and mitigation of risks in the hospital context, consolidating an innovative data-driven approach.

The methodological structure of the study is based on the systematic integration of data analysis and quantitative decision models. Initially, text mining techniques were applied to process unstructured information, enabling the discovery and categorization of critical risk factors often overlooked in conventional analyses, with a particular focus on data security, technological risks, and those derived from the environment (both internal and external). These factors were subsequently evaluated using a Multi-Criteria Decision-Making (MCDM) model; specifically, the Analytic Hierarchy Process (AHP) was used to determine the relative importance of each criterion, and the TOPSIS method was employed to prioritize risks according to their level of criticality and probability of occurrence.

Finally, the central result of the research materializes in the construction of a methodological Framework. This model provides a clear path to diagnose vulnerabilities and select evidence-based response strategies. It is concluded that the proposed combination offers a practical and adaptable solution to improve decision-making and operational resilience in health institutions.

---

\* Master thesis

<sup>1</sup> Faculty of Physico-Mechanical Engineering. School of Industrial and Business Studies.  
Advisor: PhD. Henry Lamos Díaz.

## Introducción

En 2.024 se registraron más de 9.000 emergencias por fenómenos naturales, la mayoría fueron incendios forestales, seguido por inundaciones y movimientos en masa (Prensa Presidencia, 2024); mientras que en 2.025 la Unidad Nacional para Gestión del Riesgo de Desastres informa que el primer semestre del año dejó más de 1.200 eventos (*UNGRD*, 2025); lo anterior evidencia que a lo largo de los años Colombia ha sido afectada por varias emergencias y desastres, donde los hospitales han puesto a prueba la capacidad de respuesta en cuanto a la atención de múltiples víctimas y las estrategias para afrontar su vulnerabilidad estructural, no estructural y funcional (Ministerio de Salud et al., 2017). Estas situaciones han dado lugar a determinadas investigaciones orientadas a mitigar los riesgos y evitar las interrupciones en la gestión de la cadena de suministro para soportar la toma de decisiones en las organizaciones del sector salud. Una disrupción en la cadena no permite la prestación adecuada de los servicios médicos provocando saturación en el sistema e incapacidad para suplir las necesidades de la población afectada durante las crisis. Por lo tanto, se requieren hospitales seguros frente a los desastres, como una política de reducción de riesgos para evitar el colapso del sistema en los diferentes países (E.S.E HUS, 2018).

La pandemia del Covid-19 ha dejado en evidencia las múltiples falencias en el funcionamiento de los sistemas de salud. Existe una serie de interrogantes sobre las formas de organización social y económica de los procesos sanitarios; a nivel mundial se ha demostrado que las reacciones inmediatas y las decisiones basadas en salud pública no han sido eficientes (Ministerio de Salud y Protección Social, 2020a). Lo anterior debido principalmente a que las decisiones reposan en la intuición y experiencia de los decisores, lo que repercute en la eficiencia de la cadena de suministro. En consecuencia, es de vital importancia el uso de técnicas que permitan tomar mejores decisiones que se basen en datos reales como es la analítica de datos

(Benzidia et al., 2021; Hofmann, 2017); se ha demostrado que los beneficios de utilizar la analítica están relacionados con una mejor toma de decisiones (Power, 2016), mayor visibilidad, mejor gestión del riesgo, disminución en los costos, y por lo tanto, mayor eficiencia en la cadena de suministro (Schoenherr & Speier-Pero, 2015); la innovación es parte fundamental para la resiliencia de la cadena pues fortalece la capacidad de respuesta de las organizaciones ante futuras disrupciones (Ozdemir et al., 2022). En el sector salud en diversas situaciones se requiere que las decisiones sean tomadas en corto tiempo, lo que aumenta el riesgo de tomar decisiones en varios casos no acertadas, afectando la integridad de los pacientes o incrementando los costos de funcionamiento (Giraldo Villada & Perilla Aristizabal, 2016). La implementación de nuevas técnicas de análisis enmarcadas en la cultura del dato, y apoyada por el uso de técnicas de minería de datos es la medida más efectiva para lograr cadenas de suministro más flexibles y resilientes, porque permite maximizar los beneficios, mediante la optimización de los procesos y la reducción de riesgos asociados a la incertidumbre (EAE Business School, 2018a, 2018b). Considerando lo anterior, se observa la posibilidad de realizar la gestión del riesgo en la cadena de suministro hospitalaria mediante un enfoque de minería de datos holístico y sistemático para analizar los diferentes flujos de información.

El documento comienza con los objetivos, la hipótesis, el planteamiento del problema y su justificación. A continuación, la sección 4 describe la metodología del proyecto, seguida por la revisión de literatura en la sección 5. El desarrollo empírico inicia en la sección 6 con la aplicación de minería de texto para la identificación de riesgos, cuyos resultados alimentan el modelo de decisión multicriterio presentado en la sección 7. La sección 8 detalla el paso a paso en la construcción y validación del Framework propuesto. Por último, las secciones 9 y 10 presentan las conclusiones y recomendaciones del estudio y el listado de referencias bibliográficas.

## 1. Objetivos

### 1.1 Objetivo general

Diseñar un Framework basado en minería de datos estructurados y no estructurados para el apoyo de los procesos en la gestión del riesgo en la cadena de suministro hospitalaria.

### 1.2 Objetivos específicos

- Recopilar información sobre modelos, técnicas y herramientas de minería de datos aplicados a la gestión del riesgo en la cadena de suministro hospitalaria a través de una revisión de literatura.
- Identificar los factores de riesgo que afectan la cadena de suministro hospitalaria mediante minería de texto.
- Formular un modelo de decisión multicriterio para la evaluación de los riesgos en Colombia.
- Validar el Framework mediante datos sintéticos construidos a partir de información disponible en la web.

## 2. Hipótesis

La minería de datos estructurados y no estructurados permite identificar los eventos críticos e inciertos que afectan la cadena de suministro hospitalaria, adicional a esto, apoya al mejoramiento de la gestión en lo que respecta a la vulnerabilidad y resiliencia de la cadena.

### 3. Planteamiento del problema

Las interrupciones en las cadenas de suministro son generadas por agentes externos disruptivos como: el clima, regulaciones regionales o nacionales, epidemias, desastres, entre otros, ante estos eventos las organizaciones se ven afectadas, ya que se enfrentan a situaciones excepcionales y anormales en comparación con sus actividades diarias, ocasionando así entornos impredecibles e inciertos en el que las empresas y sus cadenas de suministro globales operan (Wagner & Bode, 2006). Estas situaciones críticas afectan la gestión del riesgo de la cadena de suministro hospitalaria, aumentan la demanda de necesidades médicas y de atención de salud de forma incierta. En los últimos años los eventos catastróficos en el mundo han aumentado, la mitigación de los desastres en relación con las víctimas o pérdidas humanas depende en gran medida de la logística eficaz y eficiente de las actividades sanitarias (Syahrir et al., 2015).

Con el Covid-19, se ha evidenciado que las actividades estratégicas a nivel mundial están fallando, lo que ha afectado el tiempo de mitigación, preparación, respuesta y superación de la crisis, generando múltiples pérdidas humanas, desplome económico de la mayoría de los países, fuga de capitales, devaluación de las monedas (BBC News, 2020a) y adicionalmente interrupciones de las cadenas de producción y servicios a nivel global. En condiciones de emergencia es importante que las cadenas de suministro no se interrumpan y aún más en el sector salud al estar relacionado directamente con el bienestar humano. Para atender esta situación, los países se preocuparon por incrementar la capacidad del sistema hospitalario, pero estas acciones por sí solas no son suficientes, por lo tanto, es necesario considerar la logística hospitalaria y así fortalecer la capacidad de respuesta a las emergencias (Universidad de los Andes, 2020).

La emergencia del Covid-19 ha puesto al límite los sistemas sanitarios, Estados Unidos, un país con riqueza y capacidad, no ha escapado a los problemas de desabastecimiento, hasta la reserva gubernamental de tapabocas, guantes y otros suministros médicos ha estado a punto de agotarse (BBC News, 2020b). Colombia al igual que muchos países presentó escasez en insumos médicos en general, pero según los profesionales de la salud faltan con mayor frecuencia los medicamentos para las UCI (Ministerio de Salud y Protección Social, 2020b) y los insumos de bioseguridad (El Heraldo, 2020).

Adicional a esto, Colombia es un país que presenta alta complejidad geológica, resultado de la interacción de tres placas tectónicas, que generan la ocurrencia de sismos, erupciones volcánicas y movimientos en masa (Servicio Geológico Colombiano, 2020). Estos desastres naturales han afectado fuertemente a los habitantes y a la economía del país (ArcGIS, 2021), mencionando dentro de estos, la tragedia de Armero (1985), varios terremotos en las ciudades de Cúcuta (1875), Tumaco (1979), Popayán (1983) y Armenia (1999), y el desbordamiento de los ríos en Mocoa (2017). Todo lo anterior, en conjunto con las pérdidas sufridas por el fenómeno de la niña (2010-2011), han propiciado una evaluación integral de las políticas de gestión del riesgo, así como la formulación de recomendaciones estratégicas, que contribuyan a reducir la afectación de la población y el impacto económico de los desastres (Campos et al., 2012).

Con base en lo mencionado anteriormente y aunado a las epidemias, y al desfinanciamiento de los centros médicos se aumenta la probabilidad de producir un colapso en la Cadena de Suministro Hospitalaria (CSH), debido al aumento en la demanda de recursos para atender estos eventos y la posterior incapacidad de satisfacer dichos requerimientos. Por ejemplo, en la ciudad de Cúcuta, se enfrentó el Covid-19 simultáneamente con la atención a la población migrante

venezolana lo que ha contribuido al colapso del sistema de salud (Semana, 2019); el cual presenta una deuda por atención a población migrante en hospitales y clínicas superior los 67.000 millones de pesos (León, 2021).

Por la complejidad que caracteriza las cadenas de servicios, en la literatura se encuentran pocos estudios sobre cadena de suministro hospitalaria, es por esto que es pertinente abordar casos de situaciones críticas e inciertas para tener conocimiento de cómo mitigar los riesgos y evitar las interrupciones, adicional a eso poco se relaciona la gestión de riesgos hospitalarios mediante minería de datos, la cual permite crear un equilibrio entre la oferta y la demanda que facilita la gestión de la incertidumbre en la cadena de suministro (EAE Business School, 2018a). La minería de datos permite resolver problemas logísticos como la ubicación óptima de los centros de distribución, la selección de los mejores proveedores y la monitorización de patrones de consumo. La minería de datos además impulsa la eficiencia del sistema pues utiliza un enfoque basado en el descubrimiento en el que se emplean algoritmos de coincidencia de patrones para determinar las relaciones clave en los datos.

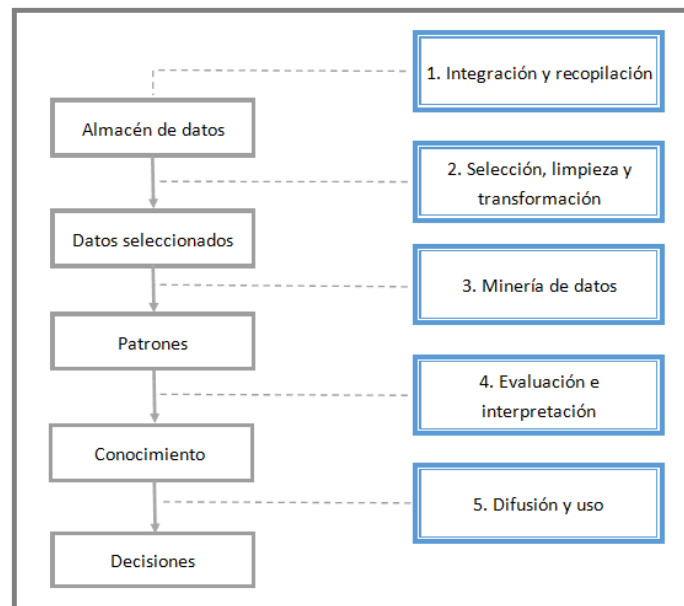
El presente trabajo de investigación tiene por objetivo contribuir al sector salud y a la sociedad en general al proponer un Framework basado en métodos de minería de datos que aborde situaciones de riesgo y reduzca la incertidumbre para la toma de decisiones en los procesos de la cadena de suministro hospitalaria, ya que las situaciones de crisis ponen en riesgo un bien público global esencial, como lo es la salud humana, por tal razón es importante asegurar que la logística en las organizaciones hospitalarias sea eficiente para lograr satisfacer las necesidades de las personas afectadas.

#### 4. Metodología

La posición epistemológica de este proyecto es de tipo objetivista con un diseño de investigación cuantitativo a partir de técnicas de Minería de Datos (MD). Esta investigación sigue la metodología propuesta por Fayyad, Piatetsky-Shapiro, & Smyth (Fayyad et al., 1996) para el descubrimiento de conocimiento en bases de datos (*Knowledge Discovery in Databases, KDD*). Se define KDD como “el proceso no trivial de identificar patrones válidos, novedosos potencialmente útiles y, en última instancia, comprensibles a partir de los datos”. En la Figura 1 se detallan las etapas del KDD (Hernández Orallo et al., 2004).

**Figura 1**

*Etapas KDD*



*Nota.* Adaptado de: (Hernández Orallo et al., 2004)

El Framework se construye mediante la integración de múltiples actividades tales como, identificación, recopilación y almacenamiento de datos de riesgo, traducción del problema de

gestión del riesgo en un problema de MD, análisis de los datos mediante el uso de algoritmos de MD e interpretación de los resultados para identificar estrategias inteligentes de mitigación de riesgos. Para dar cumplimiento a los objetivos se siguen seis etapas que se describen a continuación:

#### **4.1.Etapa 1: Descripción cualitativa del problema**

Frecuentemente se incluye una etapa previa de análisis de los requerimientos de la organización y definición del problema; en este estudio se desea abordar la gestión de riesgos de la cadena de suministros hospitalaria mediante un nuevo enfoque basado en técnicas de minería de datos, dado que estas herramientas y técnicas tienen el potencial de convertir datos de riesgo en información útil para decisiones de gestión de riesgo más efectivas, inteligentes y oportunas. La capacidad única de detectar y evaluar riesgos, descubrir fuentes de riesgo, identificar patrones y relaciones de riesgo, predecir eventos de riesgo y clasificar elementos de riesgo a través del análisis de datos históricos y el procesamiento de datos en tiempo real hace que la minería de datos sea un enfoque valioso (Er Kara et al., 2020).

#### **4.2.Etapa 2: Integración y recopilación**

En esta etapa se determinan las fuentes de información útiles para la investigación y también como acceder a estas. Se continua con la transformación de todos los datos a un formato común, frecuentemente mediante un almacén de datos que unifica de manera operativa toda la información recogida, detectando y resolviendo las inconsistencias. Este almacén de datos facilita la navegación y visualización previa de los datos, para así discernir los aspectos clave del estudio. La identificación de los factores de riesgo y el desarrollo de un almacén de datos de riesgo que afectan la cadena de suministro hospitalaria en Colombia proporciona la base principal para el análisis de datos de riesgo.

### **4.3.Etapa 3: Selección, limpieza y transformación**

La calidad de los datos es fundamental para la generación de conocimiento, dado que los datos provienen de diferentes fuentes, pueden contener valores erróneos o faltantes, estas situaciones se tratan en esta etapa, en la que se eliminan o corrigen los datos incorrectos y se decide la estrategia a seguir con los datos incompletos. Se realiza una exploración previa para transformar a los datos identificando correlaciones, patrones y datos atípicos. También, se proyectan los datos para considerar únicamente aquellas variables o atributos que van a ser relevantes para la correcta gestión del riesgo, con el objetivo de hacer más fácil la tarea propia de la minería y para que los resultados de esta sean más útiles.

### **4.4.Etapa 4: Minería de datos**

Principal etapa del KDD para descubrir conocimiento que sea útil para la toma de decisiones en la gestión del riesgo de la cadena de suministros hospitalaria. En la fase de minería de datos, se decide cuál es la tarea de minería (clasificación, agrupación, regresión, predicción, asociación etc.) a realizar, se eligen las técnicas que se va a utilizar y se construye un modelo con base en los datos recolectados. Para este estudio, se debe traducir la gestión de riesgos hospitalarios en un problema de minería de datos; existen varias tareas de minería de datos descriptivas y predictivas que pueden usarse para analizar el riesgo, cada tarea tiene su propia funcionalidad, por lo tanto, la selección debe basarse en la salida esperada y las necesidades de la solución. Algunos usos de las herramientas y técnicas de minería de datos son: detectar problemas, predecir riesgos y sus consecuencias, identificar relaciones entre riesgos y otros factores (por ejemplo, factores desencadenantes), identificar las causas fundamentales de los riesgos, agrupar elementos de riesgo, etc.

#### **4.5.Etapa 5: Evaluación e interpretación**

Con la interpretación de los resultados, es posible, la creación de patrones. Idealmente, los patrones descubiertos deben tener tres cualidades: ser precisos, comprensibles (es decir, inteligibles) e interesantes (útiles y novedosos). En esta etapa se desarrollarán las estrategias de mitigación proactivas y reactivas basadas en la evaluación de los datos de riesgo, lo anterior con el apoyo de un grupo de expertos. La evaluación consiste en la validación del Framework mediante el uso de datos sintéticos.

#### **4.6.Etapa 6: Difusión y uso**

En esta última fase se hace uso del nuevo conocimiento y se hace participe de el a todos los posibles usuarios, lo anterior se realiza mediante el reporte de los resultados del análisis de base de datos y manejo de la gestión de riesgos.

### **5. Revisión de literatura**

La revisión de literatura se lleva a cabo con el propósito de profundizar y ampliar conocimientos sobre las técnicas de minería de datos que se han utilizado en la gestión del riesgo de la cadena de suministros hospitalaria (GRCSH). Se realizó en dos momentos, la primera búsqueda (2021) con la siguiente ecuación: TITLE-ABS-KEY ((hospital OR healthcare) AND (“supply chain”) AND (“data mining” OR analytics OR “big data” OR “machine learning” OR “artificial intelligence” OR “text mining” OR “mathematical model”)); la pandemia aumentó la producción intelectual razón por la cual, se simplifico la ecuación de búsqueda en el año 2025 para obtener mejores resultados: TITLE-ABS-KEY ((hospital) AND (“supply chain” OR “risk management”) AND (“data mining” OR “data analytics” OR “machine learning” OR “artificial intelligence” OR “text mining”)). En el apéndice A se presentan los análisis bibliométricos

correspondientes a cada revisión de literatura, junto con los resultados obtenidos de las ecuaciones de búsqueda empleadas en las diferentes bases de datos consultadas. A continuación, se presenta la síntesis de los artículos estudiados.

La CSH tiene por objetivo brindar un servicio óptimo para la calidad y seguridad de la atención al paciente, se puede definir como el conjunto de actividades de diseño, planificación, gestión de adquisiciones, fabricación (bienes y servicios), gestión de entrega y devolución, desde el proveedor hasta el beneficiario (pacientes), teniendo en cuenta todos los recorridos de los pacientes en el hospital. El desempeño de la CSH debe medirse en respuesta a la seguridad del paciente y la eficiencia del proceso de atención (Supeekit et al., 2016).

La MD es “un campo multidisciplinario que se encuentra en la intersección de la estadística, el aprendizaje automático, la gestión de bases de datos y la visualización de los datos” (Feelders et al., 2000). La mayoría de las investigaciones del sector de la salud se relacionan con la CS de sangre y la CS farmacéutica. La Tabla 1 resume algunas investigaciones que han utilizado técnicas de MD para la gestión de procesos hospitalarios. Las siguientes secciones detallan dichos estudios.

**Tabla 1**

*Investigaciones en salud que utilizan minería de datos*

<b>Minería de datos</b>	<b>Objetivo</b>
-Red neuronal MLP -Árboles de regresión y clasificación, algoritmo CART -Random Forest -KNN	Los modelos de aprendizaje automático se seleccionan para ser capacitados en imitar el comportamiento del modelo de optimización estocástico de transbordo para la GCS de sangre (Abbasi et al., 2020).

Tabla 1. Continuación

<b>Minería de datos</b>	<b>Objetivo</b>
-N-gram -Lightgbm	Sistema de recomendación automática de medicamentos que se desarrolla utilizando técnicas de procesamiento de lenguaje natural y aprendizaje automático (Abbas et al., 2020) .
- Análisis de contenido y sistema de extracción de información CAINES - Análisis de texto y sistema de minería TAMS	Sistema de extracción de información para analizar el contenido de las prácticas de la CS ecológica en organizaciones de salud (Balan & Conlon, 2018).
-Red neuronal artificial -Algoritmo genético -Optimización por enjambre de partículas (PSO)	Métodos de solución al modelo multiobjetivo de la CS farmacéutica para dar respuesta a desastres naturales (Zavvar Sabegh et al., 2017).
-Red LSTM -Algoritmo ADAM -MAPE	Modelo de red LSTM multicapa para pronosticar eficazmente la cantidad de equipos respiratorios y camas de cuidados intensivos necesarios debido a la pandemia de Covid-19 (Koç & Türkoğlu, 2021).
-Reglas de asociación ARM	Técnica de MD para evaluar el impacto de las ausencias en la calidad del servicio mediante la predicción de las probabilidades de que los pacientes no se presenten (Marbouh et al., 2020).
-Minería de opinión	Enfoque de métodos mixtos que combina las capacidades del análisis de redes sociales y el análisis cualitativo, para identificar temas, opiniones y recomendaciones sobre el Covid-19 publicados por profesionales médicos (Wahbeh et al., 2020)
-Red LSTM -Árboles de decisiones -Random Forest -Máquinas de vectores de soporte	Enfoque de aprendizaje automático para detectar publicaciones de Instagram relacionadas con el tráfico ilegal de drogas por Internet (Li et al., 2019)

La gestión del riesgo en la cadena de suministro en salud incluye: previsión de demanda, selección de productos, compras, almacenamiento y distribución, para estas actividades se han propuestos diferentes modelos de simulación como, por ejemplo: modelos multiobjetivo para distribución de medicamentos, modelos basados en procesos de decisión de Markov o en programación por restricciones para gestión de inventarios, modelos de red basado en teorías de grafos y algoritmos heurísticos para ubicar centros de almacenamiento y movilización de productos; dentro de las tecnologías emergentes para apoyar estas actividades se encuentran:

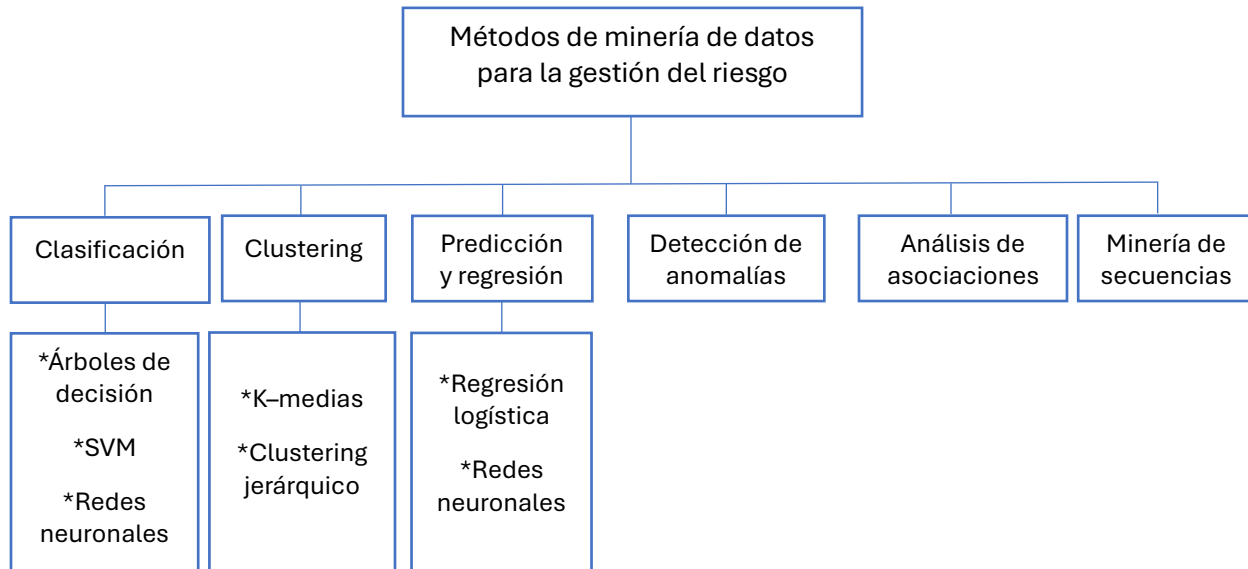
simulación basada en agentes, computación en la nube e internet de las cosas, web semántica y sistemas expertos (Abukhousa et al., 2014).

Las ineficiencias en la logística hospitalaria generan rupturas de stock y afectan la atención del paciente, la inteligencia artificial (IA) puede reducir costos, mejorar tiempos y aumentar la eficiencia operativa, pero para esto, se requiere mayor educación y capacitación del personal, así como inversión en tecnologías de la industria 4.0 (Bas et al., 2023). La IA se concibe como una herramienta de transformación organizacional que mejora los procesos, ofrece sostenibilidad, promueve la innovación social, mitigando riesgos operativos, reputacionales y ambientales (Adel et al., 2024).

La globalización, las altas expectativas de los clientes, los ciclos de vida más cortos de los productos y eventos inesperados como ciberataques, desastres naturales, inestabilidad política entre otros, hacen que las CS sean más vulnerables. El riesgo amenaza tanto la sostenibilidad como la competitividad de las CS; se conoce como inteligencia del riesgo a la capacidad de una organización para identificar, medir, evaluar y predecir amenazas mediante el uso de datos relevantes del pasado y la experiencia. La MD ayuda a descubrir información oculta y útil a partir de datos de riesgos para tomar decisiones inteligentes en relación con la GRCS, mediante la recolección de información de posibles factores de riesgo de la CS, sus fuentes, sus impactos e interrelaciones. Al transformar problemas de GR en problemas de MD, es posible aplicar técnicas y algoritmos que, al interpretar los resultados, permiten definir estrategias de mitigación del riesgo. (Er Kara et al., 2020). En la Figura 2 se muestran las técnicas de MD aplicadas a GRCS.

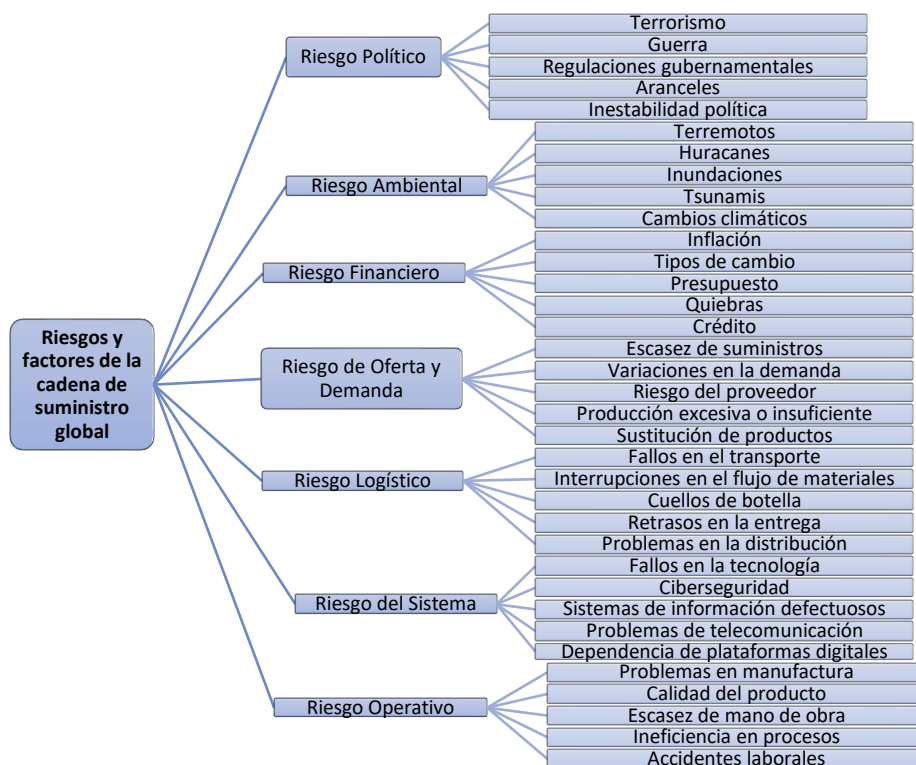
**Figura 2**

*Métodos de minería de datos para la gestión del riesgo*



*Nota.* Adaptado de “A data mining-based framework for supply chain risk management” (Er Kara et al., 2020).

La vulnerabilidad en las CS se da por los riesgos, existen múltiples clasificaciones de riesgos mediante minería de texto la cual permite analizar grandes cantidades de datos no estructurados (noticias, redes sociales, entre otros), se han generado categorizaciones de riesgos de la CS global con sus respectivos factores como se muestra en la Figura 3 (Chu et al., 2020). Es evidente que es posible identificar los riesgos regionales de una CS global mediante un enfoque basado en datos; por lo tanto, esta área de investigación es un tema interesante y desafiante para estudiar en Colombia.

**Figura 3***Riesgos y factores de la CS global*

*Nota.* Adaptado de “A global supply chain risk management framework: An application of text-mining to identify region-specific supply chain risks”(Chu et al., 2020).

En la Tabla 2 se relacionan algunas investigaciones de los eventos críticos e inciertos que se han presentado, la mayoría se basan en el modelamiento para respaldar la toma de decisiones, gestionar los riesgos de forma eficiente y evaluar soluciones que eviten las interrupciones en las CS. En esta tabla también se relacionan algunos artículos que estudian los problemas de desabastecimiento con métodos de toma de decisiones multicriterio (MCDM por sus siglas en inglés), donde se tienen en cuenta diferentes técnicas: técnica del proceso de jerarquía analítica AHP, técnica para el orden de preferencia por semejanza a la solución ideal TOPSIS, eliminación y elección de traducción de la realidad ELECTRE, análisis relacional gris (GRA) y métodos simples de ponderación aditiva (SAW).

**Tabla 2***Modelos asociados a las interrupciones de las SC*

<b>Disrupción</b>	<b>Contexto</b>
Brotos epidémicos: Pandemia Covid-19	Modelo que perfila las existencias críticas y mejora la eficiencia de la producción a través de nuevas tecnologías como la analítica avanzada y blockchain (Bhaskar et al., 2020a).
	Modelo matemático lineal novedoso para minimizar los costos totales de entrega de ayuda humanitaria para el socorro pandémico (Malmir & Zobel, 2021).
	Metodología basada en la simulación para examinar y predecir los impactos de la epidemia (Ivanov, 2020).
	MCDM y TOPSIS, determinación de un índice de vulnerabilidad pandémica (PVI) mediante la creación de una medida cuantitativa de la salud global potencial (Shrestha et al., 2020)
Desastres naturales	Modelo de programación lineal de enteros mixtos de ubicación de inventario para la distribución de la vacuna contra la influenza en los países en desarrollo durante la pandemia (Rastegar et al., 2020)
	Modelo matemático de enteros mixtos, biobjetivo y de múltiples períodos se desarrolla bajo un escenario múltiple, con el objetivo de minimizar la demanda de sangre insatisfecha, así como el costo total de la CS (Terremoto de Estambul) (Farrokhizadeh et al., 2021).
	Marco teórico para explicar la resiliencia en la oferta en las redes de la CS para la sostenibilidad utilizando Big Data (Terremoto de Nepal). La validación del marco teórico se hizo mediante análisis de contenido y análisis confirmatorio de numerosas fuentes de texto (es decir, tweets, noticias y otras redes sociales) (Papadopoulos et al., 2017)
Desabastecimiento	Modelo matemático multiobjetivo para el problema del diseño de la CS humanitario (Fuente de datos: Gestión de desastres Teherán) (Mansoori et al., 2020)
	MCDM para la gestión sostenible de la escasez de medicamentos (Irán) (Moosivand et al., 2021)
	MCDM híbridos (AHP-TOPSIS, AHP-ELECTRE, AHP-GRA y AHP-SAW) para resolver el problema de selección de proveedores (Akcan & Güldeş, 2019)
	Modelo de simulación para la gestión de inventarios en el desabastecimiento de medicamentos esenciales (Clínicas Zambia) (Leung et al., 2016)
	Enfoque de simulación para mejorar el nivel de servicio en la red de la CS de sangre en la India (Selvakumar et al., 2019)
	Modelo matemático simple compuesto por ecuaciones diferenciales ordinarias destinadas a capturar las variaciones en las existencias y los flujos involucrados en la CS de medicamentos. Sistema de seguimiento (Jbaily et al., 2020)

La IA mediante el análisis predictivo, el procesamiento del lenguaje natural (PLN) y el aprendizaje automático (ML) tiene un gran potencial para transformar la gestión de riesgos hospitalarios pues permite: la detección temprana de riesgos y eventos adversos; errores de medicación; perfilado, estratificación y monitoreo continuo pacientes; apoyo a decisiones clínicas; optimización de recursos; mejoras en la calidad y seguridad asistencial; análisis poblacional; control de infecciones y/o vigilancia de brotes (Guerra, 2024; Akingboye et al., 2021). La pandemia impulsó el uso de tecnologías digitales en salud como telemedicina y aplicaciones de la IA, aunque los beneficios son claros como la reducción de errores humanos y mejora de diagnósticos y tratamientos, existe resistencia al cambio, siendo evidente que se requiere mayor capacitación en todo el personal para lograr gestionar de manera más eficiente grandes volúmenes de datos que permitan realizar predicciones a través del ML (Văduva et al., 2023), para regular la implementación de la IA en la atención sanitaria y en diferentes sectores se han creado normas como la ISO 42001(Ranjbar et al., 2024).

Se han desarrollado tecnologías emergentes como respuesta al COVID-19, por ejemplo:

- Robots que implementan redes neuronales convolucionales para detectar el uso correcto del tapabocas e identificar si hay distanciamiento social, se usa también un sistema de lógica difusa para evitar colisiones con sensores ultrasónicos (Ponce et al., 2022).
- Sistema de soporte de decisiones que emplean análisis geoespacial, datos satelitales e IA por su capacidad para modelar comportamientos dinámicos y no lineales del fenómeno pandémico, lo anterior, mediante el uso de distintos modelos de predicción: RNA/LSTM para series temporales como casos nuevos y hospitalizaciones; KNN para clasificaciones y predicciones de consumo médico; regresión lineal para predecir asistencia a urgencias (Atek et al., 2023).

- Plataformas de respuesta operativa como solución digital a la pandemia basada en análisis avanzados, IA y visualizaciones centradas en el usuario para gestionar la operación hospitalaria (capacidad, uso de recursos limitados, demanda proyectada, etc.) en tiempo real (Alswailem et al., 2021).
- La integración de modelos estocásticos, algoritmos de optimización basados en IA y la simulación de sistemas dinámicos permite construir una CS de vacunas robusta y adaptativa, capaz de anticipar y mitigar riesgos operativos, sociales y sanitarios durante una pandemia (Kamran et al., 2023).
- La combinación de IA y simulación de eventos discretos permite la gestión de la capacidad de las unidades de cuidados intensivos durante pandemias reduciendo los tiempos de espera y prediciendo duración en urgencias y estancia en UCI (Ortiz-Barrios et al., 2023).
- Los enfoques de enrutamiento y programación de vehículos de servicios médicos de emergencia mejoraron después de la pandemia con modelos de programación entera no lineal que: usan predicciones del modelo Random Forest para tomar decisiones en tiempo real, asignan vehículos a los pacientes, determinan a que hospital enviar al paciente según disponibilidad y severidad e integran datos de Google Maps para optimizar rutas y tiempos (Rathore et al., 2022).
- Modelos teóricos (teoría de orquestación de recursos) que involucran análisis estadísticos robustos para apoyar la gestión de riesgos en situaciones de alta incertidumbre, teniendo en cuenta como se estructuran (adquisición, acumulación y eliminación de recursos), agrupan (integración para generar capacidades) y utilizan estratégicamente (despliegue de recursos para generar valor) para generar capacidad de respuesta ante la crisis (Baltas et al., 2022).

- Modelo basado en redes neuronales multicapa para estimar el tiempo de entrega de cilindros de oxígeno durante la pandemia (Ghaithan et al., 2022).

Con la experiencia de la pandemia COVID-19 se propone un nuevo modelo de Gestión Sistemática del Riesgo Clínico, fundamentado en la teoría sistemática y la ética del “trabajo bien hecho” que introduce el concepto de Gestión del Riesgo del Algoritmo de Aprendizaje apoyado por redes bayesianas ofreciendo un enfoque sistemático, ético y sostenible que responde a la complejidad de los desafíos actuales y futuros en salud pública; su mayor característica es que es proactivo pues anticipa riesgos a partir de múltiples fuentes de información, permitiendo: mejorar la calidad del cuidado y la seguridad del paciente, incrementar la eficiencia del sistema sanitario, reducir litigios legales, promover la confianza en la tecnología y facilitar la colaboración entre ciencia y política; además el marco ético se basa en la planificación, intención, medios y evaluación de la acción clínica, propone la cooperación bioética en tiempo real, más que emitir juicios retrospectivos, así, la ética guía la acción desde el inicio, integrando ciencia y conciencia moral (De Micco et al., 2022).

El modelo XGBoost (Extreme Gradient Boosting) es un algoritmo de ML basado en árboles de decisión y ampliamente utilizado por su alto rendimiento en tareas de clasificación y regresión se ha utilizado en salud para:

- Predecir el riesgo de tromboembolia venosa adquirida en el hospital en pacientes de diferentes departamentos clínicos, antes que se realicen pruebas de imágenes diagnósticas, haciendo uso de técnicas PLN para extraer variables tanto estructuradas como no estructuradas (Ma et al., 2021).

- Predecir abortos espontáneos en mujeres embarazadas con anomalías inmunológicas, lo cual permite la detección temprana de las pacientes de alto riesgo para priorizar tratamientos preventivos (Wu et al., 2024).
- Predecir la escasez de medicamentos con alta precisión usando solo datos de farmacias y registro públicos optimizando decisiones logísticas y minimizando el impacto clínico y operativo ocasionado por desabastecimientos (Pall et al., 2023).

Para mantener la calidad y mejorar el rendimiento financiero y operativo de la CS de salud se ha construido un modelo de programación bi-nivel no lineal de enteros mixtos que representa la interacción entre los hospitales y sus proveedores de medicamentos, se emplean tres algoritmos metaheurísticos para resolver el modelo: BIFOA (Bi-level Improved Fruit Fly Optimization Algorithm), BAJOA (Bi-level Artificial Jellyfish Optimization Algorithm), BFBIOA (Bi-level Forensic-Based Investigation Optimization Algorithm), siendo este último el que mejor desempeño general mostró en cuanto a la identificación de políticas de precios y diseño de red que maximizan la utilidad del sistema (Kamali et al., 2024).

Las caídas de pacientes en entornos de atención médica son las que más se reportan y son causa importante de morbilidad y mortalidad especialmente en mayores de 70 años, actualmente se usa el PLN que integrados con modelos de ML permiten detectar y predecir estos eventos mediante el análisis de textos clínicos no estructurados como notas médicas y/o registros de enfermería (Trinh et al., 2023; Nakatani et al., 2020). Dentro de las técnicas de PLN usadas se encuentran: Bag of words, TF-IDF y representación binaria y algunos modelos construidos son: Random Forest, SVM y Naive Bayes, que clasifican automáticamente los reportes de incidentes según severidad (Liu et al., 2021; Ong et al., 2012), mientras que la categorización de los tipos se

caídas se puede realizar mediante modelado de temas (Lorenzoni et al., 2021). La clasificación multiclase usando SVM con kernel RBF es también viable y efectiva para identificar incidentes comunes y extremos en reportes clínicos, pues permite una clasificación precisa, escalable y útil para filtrar automáticamente reportes de seguridad del paciente. Esto constituye una herramienta potente de MD clínica para mejorar la vigilancia de eventos adversos y priorizar intervenciones en la gestión del riesgo hospitalario (Wang et al., 2017). Para mejorar los análisis se hace uso del PLN con sistemas unificados de lenguaje médico porque extraer el significado clínico de reportes narrativos y los convierte en vectores de conceptos médicos, más interpretables que simples palabras, detectando de manera más precisa los eventos adversos críticos y raros, facilitando una gestión de riesgos más efectiva en los sistemas de salud (Wang et al., 2020).

Otras técnicas de IA utilizadas son: ANFIS (Adaptive Neuro-Fuzzy Inference System) un sistema híbrido de RNA y lógica difusa para predecir caídas y su gravedad; y CBR (Case-Based Reasoning) que reutiliza casos pasados para personalizar los planes de atención mediante recuperación, adaptación y actualización de casos (Wan & Chin, 2021). Enfoques data-driven que combinan datos y el juicio de expertos permiten identificar más factores de riesgos asociados con las caídas en los hospitales mediante modelos como regresión paso a paso (Stepwise Regression) porque selecciona las variables más predictivas de forma automatizada, pero guiadas por conocimiento clínico (Lucero et al., 2019). Actualmente, se utiliza el aprendizaje por refuerzo profundo en el control de robots destinados a prevenir caídas de pacientes hospitalizados con modelos como el Deep Q-Network que aprende mediante ensayo y error a través de recompensas, toma decisiones óptimas en escenarios hospitalarios complejos y cambiantes y adicionalmente, considera múltiples entradas: datos de sensores, condición del paciente, historial médico, ubicación del personal, etc. (Namba & Yamada, 2018).

Cerca del 25% de las caídas no son reportadas de manera oficial en sistemas de incidentes por esto se hace necesario detectarlas por medio de minería de texto a los registros clínicos ayudando así a la gestión de riesgos (Toyabe, 2015), por otra parte, los incidentes de seguridad del paciente por tipo (caídas, errores de medicación, agresión, etc.) y gravedad se pueden identificar con redes neuronales convolucionales entrenadas con Word embeddings (Wang et al., 2019). Dentro de las aplicaciones de PLN integrado con ML se encuentra la construcción de bases de datos nacionales con información clínica estandarizada y útil para investigaciones, predicción de riesgos y toma de decisiones (Samaras et al., 2023).

También, se ha usado ML para identificar correlaciones entre eventos adversos relacionados con la atención sanitaria durante las hospitalizaciones y procedimientos de los pacientes logrando construir modelos predictivos usando datos para caracterizar el riesgo de cada paciente hospitalizado, demostrando que el análisis de big data puede mejorar la seguridad y calidad hospitalaria (Artemova et al., 2023). Se ha demostrado que el PLN combinado con ML permite predecir niveles de riesgo a partir de texto libre en registros clínicos electrónicos sin intervención humana, al automatizar este proceso se obtienen beneficios como: reducción de cargas de trabajo, detección de señales tempranas de peligro y se mejora la personalización de los tratamientos (Le et al., 2018). Sistemas de alerta temprana como DeepCARS basado en IA y aprendizaje profundo predicen el riesgo de paro cardíaco intrahospitalario porque logra detectar el deterioro clínico antes de que ocurra una emergencia dando respuesta rápida a estos eventos (Cho et al., 2023).

La preparación del sistema de salud para adoptar Big Data se ha evaluado mediante modelos de ecuaciones estructurales analizando variables como complejidad, compatibilidad, ventaja relativa e innovación (Ghaleb et al., 2023), la integración de MD y big data en la gestión

de riesgos de enfermería en urgencias es altamente efectiva porque mejora: la precisión del monitoreo, la asignación de personal (tanto médico como de enfermería) y la calidad de los cuidados, y en simultaneo reduce eventos adversos y fortalece la relación médico-paciente (Han et al., 2022). El uso de CART permite identificar un perfil claro de pacientes en alto riesgo de reingreso, superando las limitaciones de modelos tradicionales que no se ajustan bien a contextos locales o a poblaciones vulnerables, lo anterior mediante datos específicos de registros electrónicos de salud para crear intervenciones clínicas personalizadas y más efectivas, especialmente lideradas por personal de enfermería (Brom et al., 2020).

El algoritmo CHAID permite generar árboles de múltiples ramas, lo que facilita segmentaciones más detalladas, se ha utilizado para determinar perfiles de desempeño financiero en hospitales, por tal razón se enmarca en una aplicación de Business Intelligence (BI) para soporte de toma de decisiones, combinando conceptos de IA con análisis estadístico (Ozgulbas & Koyuncugil, 2009). Con BI también es posible analizar el uso real de los insumos en las distintas áreas y optimizar la distribución de los mismos durante las crisis, reduciendo el impacto logístico del desabastecimiento sin comprometer la atención urgente (Bammer & Amukotuwa, 2022).

Blockchain es una base de datos distribuida como una cadena de bloques organizada, se considera como un software de contabilidad digital que almacena los registros de datos y los registros de las transacciones en forma ordenada dentro de bloques, cuenta con propiedades como transparencia, robustez y seguridad. Esta tecnología permite mejorar y rastrear el proceso de la GCS de manera eficiente pues proporciona una mejor gestión de la información en cuanto a visibilidad, optimización y demanda, logrando así CS automatizadas (Abbas et al., 2020; Casino et al., 2019). En la CSH se ha demostrado que utilizar Blockchain como conector en la integración hospital-proveedor ha mejorado el rendimiento de la cadena, debido a que funciona como un

ecosistema que sincroniza los datos transaccionales en toda la red; las cadenas de bloques también pueden tener un gran impacto en la transparencia de los procesos, además mejora la eficiencia y entrega del servicio en periodos prolongados de crisis (Bhaskar et al., 2020b). Esta cadena de bloques construida a partir de algoritmos inteligentes, datos y asegurada por técnicas de codificado (Justinia, 2019) ha beneficiado al sector de la salud con aplicaciones que generan ventajas en áreas como: gestión de registros, gestión de la CS farmacéutica, monitoreo remoto de pacientes, análisis de datos médicos, procesamiento de reclamos entre otros (Agbo & Mahmoud, 2020).

Blockchain maneja un enfoque descentralizado y seguro que reduce ineficiencias, fraudes y desigualdades en salud en la Tabla 3 se muestran algunas de sus aplicaciones en este sector (Vervoort et al., 2021). Blockchain mejora la confianza de los sistemas de salud al garantizar que los datos no se modifiquen, puedan rastrearse y sean accesibles solo por actores autorizados (Elangovan et al., 2022).

**Tabla 3**

*Aplicaciones de Blockchain en salud*

<b>Aplicación</b>	<b>Método involucrado</b>	<b>Riesgo mitigado</b>
Predicción de eventos médicos: Monitoreo remoto de pacientes, pronóstico de eventos clínicos adversos, generación de alertas tempranas en plataformas de telemedicina.	IA + Blockchain	Emergencias no detectadas
Trazabilidad de medicamentos y análisis de rutas logísticas	Minería de datos	Falsificación, condiciones de la cadena de frío
Automatización de seguros	Contratos inteligentes	Errores administrativos, fraudes
Validar la integridad de datos en ensayos clínicos	Blockchain + Minería de datos	Manipulación de datos
Identificación de profesionales (Validar títulos médicos, licencias profesionales y certificados de vacunas)	Validación con Blockchain	Fraudes institucionales

El modelo omnicanal combina canales físicos y digitales para ofrecer servicios más integrados. Las empresas pueden usar datos recopilados de múltiples fuentes para optimizar la experiencia del paciente y mejorar la gestión de inventarios, distribución de productos y atención personalizada, logrando la anticipación de interrupciones en la CS (Chang et al., 2023).

Actualmente son más comunes los sistemas de detección de errores de medicamentos mediante el uso de PLN y redes neuronales profundas por medio del análisis de informes de incidentes clínicos en texto libre relacionados con los 5 correctos: paciente correcto, medicamento correcto, dosis correcta, vía correcta y momento correcto, estos enfoques contribuyen al desarrollo de sistemas de IA para la mejora de la seguridad del paciente (Wong et al., 2020); se han creado software que integran IA automatizada basada en PLN, Clustering, análisis cualitativo y modelado conceptual para clasificar las opiniones de los reportantes de incidentes de medicación, encontrando 4 categorías temáticas principales: tratamiento (dosis, listas, medicamentos), trabajo (recursos humanos, supervisión), prácticas (documentación, guías) y entorno (tecnología, salas, sistemas) (Härkänen et al., 2021). Se destaca el papel fundamental de la IA y big data como apoyo a la farmacovigilancia haciéndola más proactiva, predictiva y personalizada (Fermont, 2019).

En la Tabla 4 se muestra como en la era de la IA se realiza gestión de riesgos para apoyar a la seguridad del paciente, esta gestión responde a la necesidad de crear programas sólidos que tengan herramientas proactivas y reactivas para prevenir errores (Ferrara et al., 2024).

En Japón se ha evaluado la importancia clínica de los informes de tomografías computarizadas mediante algoritmos de PLN: regresión logística (modelo basado en frecuencia de palabras), BiLSTM (modelo secuencial bidireccional basado en RNA), BERT general

(preentrenado con Wikipedia), BERT médico (preentrenado con textos clínicos); con los cuales se detectan hallazgos urgentes y se previenen omisiones clínicas (Wataya et al., 2024).

**Tabla 4**

*Técnica de IA/ML/PLN*

<b>Técnica IA/ML/PLN</b>	<b>Aplicación principal</b>
Árboles de decisión / KNN / Conjuntos de clasificadores binarios	Clasificación de riesgos, predicción de infecciones
Redes neuronales profundas	Análisis de imágenes y textos clínicos
PLN + Sistema unificado de lenguaje médico	Estandarización de reportes de eventos
Sistemas de soporte de decisión clínica con ML	Apoyo a decisiones médicas y prevención de errores
Modelos de detección de outliers	Alerta de errores inusuales en medicamentos
Sistemas activos de aprendizaje	Análisis de eventos con ausencia de datos
IA en imágenes (visión por computadora)	Identificación de dispositivos médicos y medicamentos similares

Para hacer sistemas de salud más resilientes es indispensable el uso de tecnologías disruptivas como IA, Big Data o el internet de las cosas, en la tabla 5 se visualizan aplicaciones típicas en gestión de riesgos hospitalarios (Vargas et al., 2023).

**Tabla 5**

*Aplicación de tecnologías en gestión de riesgos hospitalarios*

<b>Tecnología</b>	<b>Aplicación típica en gestión de riesgos hospitalarios</b>
ML / DL	Predicción de eventos adversos, clasificación de pacientes de alto riesgo, detección de anomalías.
Big Data	Análisis de grandes volúmenes de datos clínicos y administrativos para identificar patrones de riesgo.
IA	Soporte a decisiones clínicas y logísticas bajo incertidumbre.
IoT / Sensores	Monitoreo continuo de signos vitales, ubicación de equipos críticos, rastreo de contacto.
Blockchain	Trazabilidad y seguridad en registros médicos y cadena de suministro.
Wearables	Seguimiento remoto de pacientes y alertas de riesgo.
Cloud Computing	Acceso ágil a datos y recursos para respuesta rápida a crisis.

Ante los desastres que pueden ocurrir se hace necesaria la evacuación inmediata de víctimas a centros de atención, Austria es una zona propensa a inundaciones por tal razón, se han

usado tanto RNA para predecir niveles de agua y modelar caudales como SVM para clasificar y predecir flujos máximos del río (Munawar et al., 2022). Boosted Regression Tree (BRT) permite modelar la susceptibilidad a inundaciones y evaluar los riesgos de infraestructuras (Pourghasemi et al., 2021)

La minería de procesos (MP) es una técnica que combina MD y modelado de procesos, mejora, análisis y registros de eventos lo que permite: detectar desviaciones o incumplimientos de protocolos clínicos, mejorar procesos para aumentar la seguridad del paciente y eficiencia, identificar cuellos de botella, retrasos o comportamientos anómalos, lo anterior es posible mediante las técnicas asociadas a la MP que son: descubrimiento, conformidad, mejora, análisis de variantes, rendimiento, monitoreo predictivo, Clustering y visualización (Erdogan & Tarhan, 2018). Dentro de las técnicas de descubrimiento de procesos MP se encuentran:

- **Heuristic Miner:** Útil para datos con ruido, permite identificar patrones de procesos comunes.
- **Fuzzy Miner:** Se adapta bien a procesos clínicos complejos y variables, simplifica la visualización.
- **Alpha Miner:** Uno de los primeros algoritmos, genera modelos tipo Petri net.
- **Inductive Miner:** Detecta desviaciones, comportamiento infrecuente y permite análisis visuales.

## 6. Minería de texto para identificar riesgos y sus factores

La identificación de los riesgos de la cadena suministro hospitalaria en Colombia se realiza mediante minería de texto en dos fases (Chu et al., 2020):



**Análisis de correlación:** Se calcularon las correlaciones para encontrar términos que a menudo aparecen junto con la palabra “riesgo”, ayudando a identificar factores directamente relacionados.

**Análisis de bi gramas:** Se examinaron pares de palabras consecutivas para descubrir las frases más comunes.

En la Figura 5 se presentan los resultados de la correlaciones y bi gramas encontrados.

### Figura 5


*Resultados análisis de correlación y bi gramas*

Correlation with "risk"		Top 20 Bi-gramas más frecuentes		Bi-gramas clave relacionados con 'risk':	
			bigram count		bigram count
risk	1.000000	878	supply chain 5031	790	risk management 396
also	0.651499	187	covid pandemic 782	118	chain risk 343
research	0.543899	111	chain management 541	789	risk factor 207
supply	0.489993	790	risk management 396	784	risk assessment 194
may	0.463603	118	chain risk 343	244	disruption risk 105
increase	0.430276	848	smart contract 289	335	foodborne risk 94
chain	0.426863	194	creative common 261	239	disaster risk 88
need	0.419103	494	literature review 260	791	risk mitigation 74
case	0.409250	73	blockchain technology 254	369	high risk 69
impact	0.405362	984	world organization 247	787	risk event 67
use	0.404154	669	pharmaceutical supply 231	799	risk supply 65
used	0.400253	332	food safety 210	208	cyber risk 64
work	0.399542	978	wiley online 208	788	risk exposure 63
part	0.397308	789	risk factor 207	786	risk covid 60
challenge	0.396529	610	online library 207	190	covid risk 58
different	0.388190	672	plo one 207	785	risk associated 54
approach	0.381335	944	united state 203	418	infection risk 52
based	0.374603	117	chain resilience 200	638	pandemic risk 49
level	0.374603			796	risk reduction 49
due	0.370167			682	potential risk 49
strategy	0.367718			745	reduce risk 48
area	0.363326			797	risk risk 45
management	0.363306			595	normal lowrisk 41
review	0.362782			687	preparedness risk 39
science	0.362077			883	supply risk 39
available	0.359164			740	readmission risk 39
				509	lowrisk delivery 37
				554	mitigate risk 37
				793	risk perception 33
				56	associated risk 33
				794	risk rating 32
				480	level risk 31
				513	main risk 31
				312	exposure risk 30
				293	epidemic risk 30
				406	increased risk 29
				792	risk pandemic 29
				795	risk reduct 28
				798	risk source 27
				404	increase risk 26
				372	hiv risk 26
				841	shared risk 26
				824	security risk 25

**Modelado de tópicos (LDA):** Se utilizó un modelo de agrupación no supervisado para identificar los principales temas dentro de los documentos. En la Figura 6 se visualizan la nube de palabras para cada uno de los 5 temas encontrados:

**Figura 6**

*Nube de palabras modelado de temas*



## 6.2.Fase 2: Reconocimiento de patrones de riesgo a partir de noticias online

En este paso la configuración del corpus son artículos en línea, se empleó la interfaz de programación de aplicaciones API de Google News para buscar noticias de interés, se realizaron las mismas técnicas de minería de texto de la fase anterior. Los tipos de riesgo definidos y los

factores de riesgo subyacentes estructurados a partir del análisis anterior sirvieron como diccionario de factores de riesgo. Este diccionario ayuda a filtrar noticias sobre temas específicos para analizar más a fondo los riesgos de la cadena de suministro hospitalaria en Colombia.

La búsqueda para la extracción de noticias se realizó con las siguientes palabras clave: query = (f"{termino}" AND (hospital OR clínica OR salud OR EPS OR "riesgos cadena suministro hospitalaria Colombia" OR "problemas logísticos hospitales Colombia" OR "desabastecimiento medicamentos Colombia" OR "crisis insumos médicos Colombia" OR "problemas en la cadena de suministro de salud en Colombia" OR "riesgos hospitalarios en Colombia" OR "riesgos en salud en Colombia" OR "riesgos sanitarios en Colombia" OR "gestión de riesgos en salud en Colombia").

El diccionario de factores de riesgo creado en la fase anterior es:

- De origen natural: desastres, terremoto, tsunamis, inundaciones, derrumbes, heladas, sequías.
- Producidos por el hombre: incendios, huelgas, explosiones, accidentes, derrame de sustancias peligrosas.
- Sanitarios: epidemias, pandemias, plagas.
- Oferta y demanda: escasez de suministros, escasez de medicamentos, falta de insumos médicos, falla equipo médico, saturación de urgencias, variación de demanda.
- Gestión de datos: datos, información.
- Proceso: fallos en tecnología, ciberseguridad.
- Financiero: crisis financiera hospital, deuda de EPS con hospitales, aumento de costos en salud, quiebra de clínica, costos.

Al finalizar la recopilación se encontraron 1427 noticias, se continua con la limpieza del texto, se eliminaron los números, las palabras vacías y las puntuaciones. En la Figura 7, se observan los 50 términos más frecuentes, así como los bi gramas encontrados y las palabras más correlacionadas con la palabra “riesgo”.

## Figura 7

### Resultados análisis noticias

Top 50 most frequent terms:	Top 50 most frequent bi-grams:	Correlación
salud: 36	medicamentos colombia: 11	heladas 0.294009
colombia: 31	desabastecimiento medicamentos: 9	alto 0.282038
medicamentos: 22	sistema salud: 8	ponen 0.265035
infobae: 18	ministerio salud: 6	inundaciones 0.257643
riesgo: 14	escasez medicamentos: 4	friaje 0.251298
desabastecimiento: 13	riesgo financiero: 4	enfermedades 0.233466
consultorsalud: 13	salud colombia: 4	distritos 0.216804
minsalud: 10	escasez insulina: 3	declaran 0.216804
logística: 10	colombia minsalud: 3	millones 0.176353
gobierno: 10	logística farmacéutica: 3	médica 0.176353
eps: 10	farmacéutica hospitalaria: 3	prevenir 0.176353
sistema: 10	hospitalaria sector: 3	españa 0.176353
escasez: 9	sector alza: 3	afectan 0.176353
hospitales: 9	alza exige: 3	pandemias 0.176353
crisis: 9	exige inversión: 3	
hospitalaria: 8	inversión desarrollo: 3	
sector: 7	desarrollo logística: 3	
deuda: 7	logística profesional: 3	
radio: 7	opsoms organización: 3	
farmacéutica: 6	organización panamericana: 3	
ministerio: 6	panamericana salud: 3	
demanda: 6	salud pan: 3	
billones: 5	pan american: 3	
financiero: 5	american health: 3	
colombiano: 5	health organization: 3	
nacional: 5	organization paho: 3	
seguridad: 4	caracol radio: 3	
pdf: 4	corte constitucional: 3	
researchgatenet: 4	pdf logística: 3	
pone: 4	logística hospitalaria: 3	
país: 4	hospitalaria revisión: 3	
hospital: 4	revisión bibliográfica: 3	
corte: 4	bibliográfica researchgatenet: 3	
revisión: 4	industria farmacéutica: 3	
centro: 4	nueva eps: 3	
larepublicaco: 4	hospitales públicos: 3	
decreto: 4	clínicas hospitales: 3	
atención: 4	mil millones: 3	
social: 4	demanda gobierno: 3	
clínicas: 4	millonaria deuda: 3	
laboral: 4	seguridad vacunas: 2	
infraestructura: 4	vacunas opsoms: 2	
alerta: 3	pone riesgo: 2	
insulina: 3	miles pacientes: 2	
alza: 3	medicamentos demandados: 2	
exige: 3	demandados colombia: 2	
inversión: 3	colombia autoridades: 2	
desarrollo: 3	autoridades aclaran: 2	
profesional: 3	colombia infobae: 2	
opsoms: 3	infobae minsalud: 2	

Este estudio incorpora un análisis de sentimientos (método para calcular la polaridad de las emociones de las palabras) basado en léxicos para capturar los patrones de variación del riesgo de la CSH. Los resultados fueron:

--- Conteo de Noticias por Sentimiento ---

NEU 731

NEG 665

POS 31

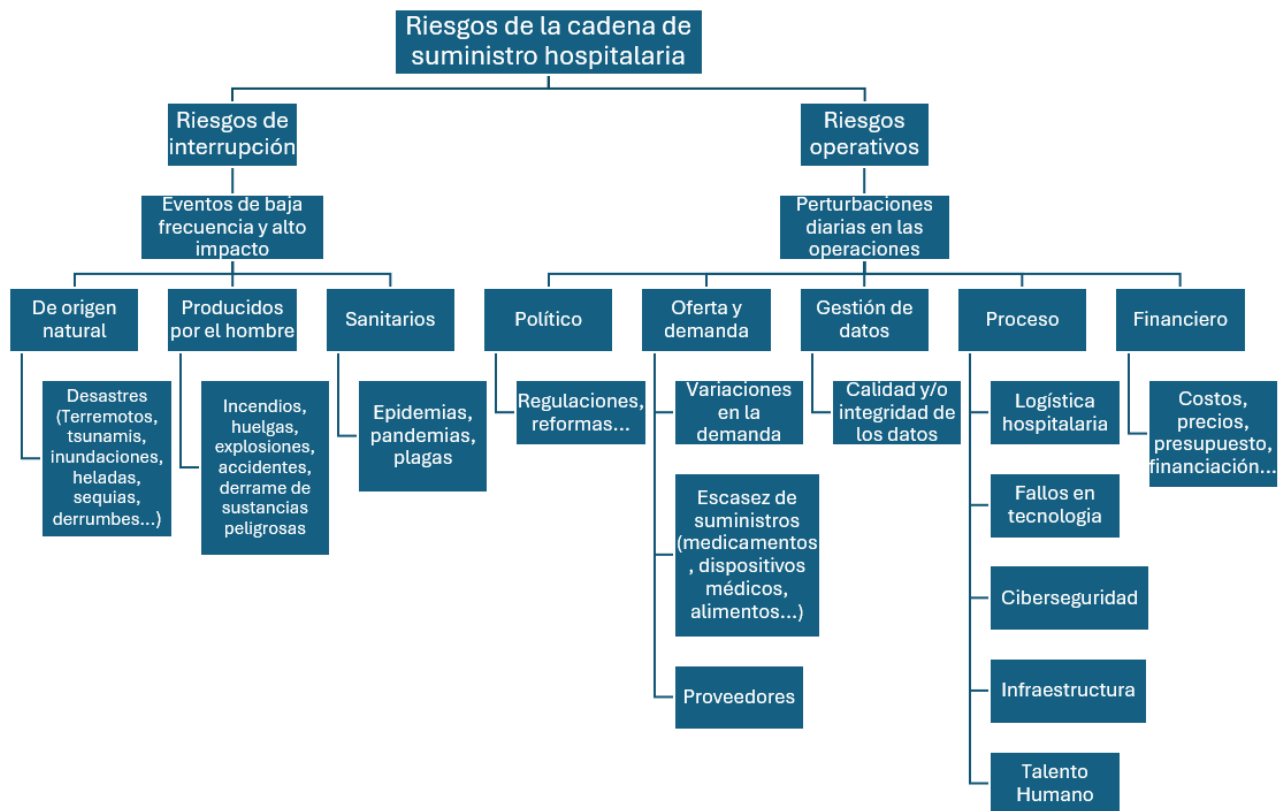
Con 731 ocurrencias, la mayoría de las noticias analizadas fueron clasificados como neutros. Con 665 ocurrencias, hay un número muy significativo de textos clasificados como negativos. Solo 31 argumentos fueron clasificados como positivos, lo que representa una minoría muy pequeña.

Con base en los resultados del análisis de correlación y frecuencia de términos, el análisis de bi-gramas y el análisis de modelado de temas, el riesgo de la CSH en Colombia se clasificó en 8 tipos y cada tipo contiene factores de riesgo potenciales derivados de términos críticos como se muestra en la Figura 8. En la categorización jerárquica propuesta, el riesgo de la CSH se descompone en aspectos de origen natural, producidos por el hombre, sanitarios, políticos, de oferta y demanda, de gestión de datos, de procesos y financieros. Cada aspecto tiene sus términos representativos como factores de riesgo. Por ejemplo, la categorización origen natural el riesgo aumentaría cuando una región sufra un desastre natural como un terremoto o un tsunami. La frecuencia de un desastre natural en particular en una región también afectaría el riesgo de origen natural potencial. Si una región está acostumbrada a tener terremotos, inundaciones, derrumbes... las empresas manufactureras y de servicios locales tendrían altos riesgos de origen natural y, por lo tanto, probablemente tomarían acciones para mitigar los posibles daños que pudieran imponer los desastres. Esto implica que, aunque los tipos y factores de riesgo de la CSH están categorizados

por una estructura jerárquica en este estudio, estos tipos y factores de riesgo pueden no ser independientes. En otras palabras, varios factores de riesgo o eventos de riesgo tendrían reacciones en cadena que afectarían a la totalidad o parte de una cadena de suministro.

### Figura 8

#### *Riesgos de la cadena de suministro hospitalaria*



En el Apéndice B se encuentran todos los códigos de programación realizados para el análisis de minería de texto tanto de la literatura académica como de las noticias para poder llegar a la jerarquización anterior.

A continuación, se presenta la guía para gestión del riesgo propuesta:

### 6.3. Guía para la gestión del riesgo

**Objetivo:** Establecer la metodología para la gestión integral del riesgo, abarcando su identificación, análisis y evaluación, así como el seguimiento de las acciones de mejora implementadas para su minimización.

**Alcance:** Aplica a todos los procesos del sistema de gestión de la calidad de la institución.

#### Definiciones

**Riesgo:** Es la posibilidad de que suceda algo que tendrá impacto en los procesos asistenciales, en la prestación del servicio y/o en el cumplimiento de los objetivos. Se mide en términos de impacto y probabilidad de ocurrencia.

**Gestión de Riesgo:** Cultura, procesos y estructuras que se dirigen hacia la gestión efectiva de las oportunidades potenciales y efectos adversos.

**Causa:** Es la raíz, procedencia y/o el fundamento de la falla potencial e indica una debilidad en el proceso.

**Consecuencias:** Son las consecuencias o resultados potenciales que producen los riesgos; esta actividad se puede realizar a través de la lluvia de ideas y una vez identificadas estas consecuencias, deben introducirse en el modelo como efectos. Son los efectos, tales como los percibiría el paciente.

**Probabilidad:** Se entiende como la posibilidad de ocurrencia del riesgo, es decir, es la frecuencia con la cual una falla potencial puede presentarse en la institución. Está asociada a la exposición al riesgo del proceso o actividad que se esté analizando.

**Impacto:** Son la(s) consecuencia(s) que puede ocasionar a la institución la materialización del riesgo, califica la afectación (severidad) en los aspectos críticos (prestación del servicio, seguridad del paciente, partes interesadas, entre otros).

**Riesgo inherente:** Nivel de riesgo propio de la actividad. El resultado de combinar la probabilidad con el impacto nos permite determinar el nivel del riesgo inherente, dentro de unas escalas de severidad.

**Riesgo residual:** El resultado de aplicar la efectividad de los controles al riesgo inherente.

**Nivel de riesgo:** Es el valor que se determina a partir de combinar la probabilidad de ocurrencia de un evento potencialmente dañino y la magnitud del impacto que este evento traería sobre la capacidad institucional de alcanzar los objetivos.

**Control:** Medida que permite reducir o mitigar el riesgo.

**Acción Correctiva:** Conjunto de acciones tomadas para eliminar la(s) causa(s) de una no conformidad y evitar que vuelva a ocurrir.

**Acción de Mejoramiento o Barrera de Seguridad:** Una(s) acción(es) o circunstancia(s) que reduce(n) la probabilidad de presentación del riesgo.

**Condiciones generales:** La metodología de riesgos para la institución fue adaptada teniendo en cuenta los lineamientos de la Guía de Gestión del Riesgo del DAFP.

### **Clasificación de riesgos**

En primer lugar, se debe generar una lista de posibles eventos y consecuencias que podrían afectar la gestión de su proceso. Para facilitar esta labor a continuación se enuncian diferentes tipos de riesgos que pueden estar presentes en institución:

**Riesgos Operativos:** Comprende los riesgos relacionados tanto con la parte operativa como técnica de la institución, incluye los riesgos provenientes de deficiencias en los sistemas de información, en la definición de los procesos, en la estructura de la entidad, la desarticulación de los procesos.

**Riesgos Tecnológicos:** Se asocian con la capacidad de la entidad para que la tecnología disponible satisfaga las necesidades actuales y futuras de la institución y soporte el cumplimiento de la misión.

**Riesgos de Cumplimiento:** Se asocian con la capacidad de la institución para cumplir con los requisitos legales, contractuales, de ética y en general con su compromiso ante la comunidad.

**Riesgos Financieros:** Se relacionan con el manejo de los recursos de la institución que incluye, la ejecución presupuestal, la elaboración de estados financieros, los pagos, el manejo sobre los bienes de la organización, entre otros.

**Riesgos estratégicos:** Se asocian con la forma en que se administra la institución, se enfocan en temas relacionados con el cumplimiento de la misión, los objetivos estratégicos y las políticas. Se obtienen del análisis de contexto interno y externo.

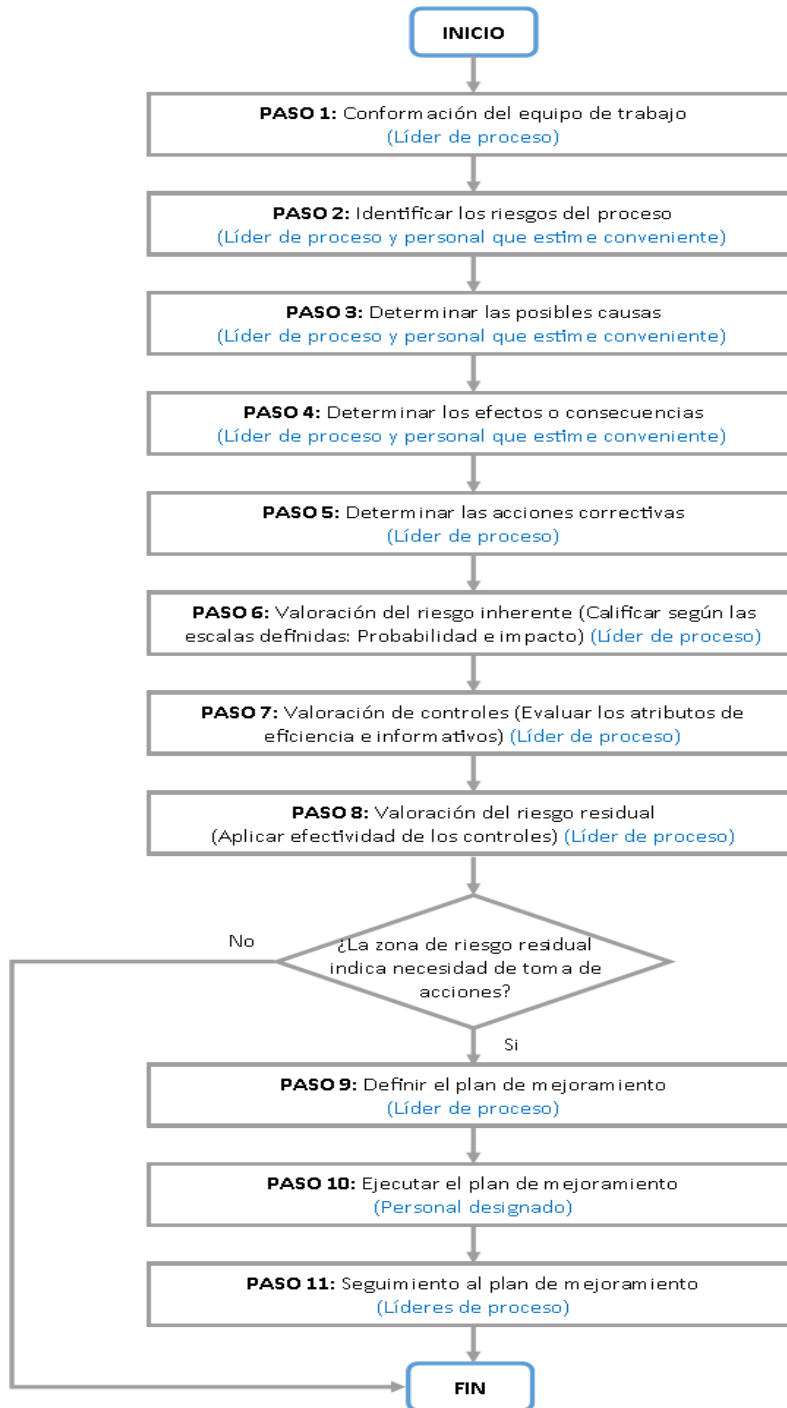
**Riesgos de imagen:** Están relacionados con la percepción y la confianza por parte de la ciudadanía hacia la institución.

**Riesgos asistenciales:** Relacionados con el incumplimiento de las “Buenas Prácticas para la Seguridad del Paciente en la Atención en Salud”.

Para la categorización de los riesgos en el Apéndice C. Formato Matriz de riesgos también se debe tener en cuenta la jerarquización propuesta en este estudio que se encuentra en la Figura 8 de este documento.

## **Desarrollo**

A continuación, se presenta el resumen de la metodología aplicada en para la gestión del riesgo. En la Figura 9 se visualizan los pasos a seguir para la gestión del riesgo, a continuación, se describe en que consiste cada uno de ellos:

**Figura 9***Metodología para la gestión del riesgo*

**Paso 1. Conformación de equipo o grupo de trabajo para análisis de riesgos:** El análisis de riesgos es realizado por el líder del proceso con todo el personal que estime conveniente.

**Paso 2. Identificación de los riesgos:** Se recomienda tener en cuenta los siguientes criterios al momento de identificar los riesgos: determinar aquellos que si se materializan afectan el cumplimiento de los objetivos, los indicadores de gestión, generan fallas en la comunicación interna y externa, la afectación de la prestación del servicio y de las partes interesadas, tales como: quejas y reclamos, salidas no conformes, cambios en el contexto, incidentes y eventos adversos (es general, ya sea por incumplimiento de requisitos de ley, del cliente y los establecidos por la institución). Adicionalmente y en respuesta al Decreto 441 de 2022, se deben identificar y gestionar los riesgos previsibles propios del acuerdo de voluntades entre las partes.

Enumerar todos los pasos del proceso de manera muy específica: Se enumeran las actividades del proceso y se registran en el Formato Matriz de Riesgo. Pueden apoyarse en los documentos del proceso (caracterización, procedimientos, entre otros).

Los participantes del análisis de riesgos del proceso en estudio tienen la responsabilidad de generar una lista de posibles riesgos que pueden afectar la seguridad del paciente o causar daño a alguna de las partes interesadas o a la organización. Diligenciar los riesgos en el Formato Matriz de Riesgos.

**Paso 3. Determinar las posibles causas:** Para cada riesgo se deben identificar sus posibles causas, para cuyo análisis se recomienda la aplicación de técnica estadística como la “Lluvia de Ideas”, y para la definición de las causas (ocurrencia) se recomienda tener presente las variables de las 5M (Mano de Obra, Método, Medición, Medio Ambiente y Maquinaria: Infraestructura, Hardware / Software, Equipos).

Diligenciar las posibles causas en el Formato Matriz de Riesgos.

**Paso 4. Determinar los efectos o consecuencias del riesgo:** Para cada riesgo determinar los efectos o consecuencias que se generarían en las partes interesadas o en la institución si se materializa el evento, diligenciar el Apéndice C. Formato Matriz de Riesgos.

**Paso 5. Determinar las acciones correctivas:** Se definen las acciones correctivas a tener en cuenta en caso de que el riesgo se materialice. Por lo anterior, se definen las acciones a implementar para eliminar las causas raíz de este, con el fin de que no vuelva a ocurrir.

**Paso 6. Valoración del riesgo inherente:** Calificar el impacto (severidad o consecuencia) y la probabilidad de ocurrencia de las causas de acuerdo con las siguientes escalas, diligenciando esta calificación asignada a cada riesgo en el Formato Matriz de Riesgos.

**Probabilidad:** Calificar la posibilidad de ocurrencia del riesgo según la siguiente escala:

**Tabla 6**

*Escala probabilidad*

PROBABILIDAD		
Criterio	%	Descripción
RARO	10%	El suceso solo podría ocurrir en circunstancias excepcionales
IMPROBABLE	30%	Suceso no es habitual, pero podría producirse en algún momento
POSIBLE	50%	Suceso que puede ocurrir en algunas circunstancias o se presenta de forma esporádica
PROBABLE	80%	Suceso que se presenta con cierta regularidad
CASI CON CERTEZA	100%	Se sabe que el suceso ocurre de forma reiterada

*Nota.* Adaptado de “Guía para la administración del riesgo” (*Departamento Administrativo de la Función Pública et al., 2022*).

**Impacto:** Calificar de acuerdo con la siguiente escala la gravedad del efecto o consecuencia:

**Tabla 7***Escala impacto*

IMPACTO			
Criterio	%	Descripción	ASPECTOS CRÍTICOS IPS
INSIGNIFICANTE	20%	Muy baja o nula afectación en:	*Seguridad del paciente. *La prestación de los servicios de salud.
MENOR	40%	Baja afectación en:	*El logro de los objetivos institucionales y de los entes de control.
MODERADO	60%	Mediana afectación en:	*La variación del presupuesto e indicadores financieros.
MAYOR	80%	Alta afectación en:	*Indicadores de gestión *Impactos ambientales. *Partes interesadas
CATASTROFICO	100%	Alarmante afectación en:	*El cumplimiento legal. *Los aspectos laborales. *Credibilidad y confianza de la institución.

*Nota. Adaptado de “Guía para la administración del riesgo” (Departamento Administrativo de la Función Pública et al., 2022)*

**Evaluación de riesgos:** Se determina los niveles de severidad a través de la combinación entre la probabilidad y el impacto se definen 4 zonas de severidad en el mapa de calor (Figura 10):

**Figura 10***Mapa de calor de riesgos*

<b>Probabilidad</b>	100%	<i>Casi con certeza</i>	Moderada	Alta	Extrema	Extrema	Extrema
	80%	<i>Probable</i>	Moderada	Alta	Alta	Extrema	Extrema
	50%	<i>Posible</i>	Baja	Moderada	Alta	Alta	Extrema
	30%	<i>Improbable</i>	Baja	Moderada	Moderada	Alta	Alta
	10%	<i>Raro</i>	Baja	Baja	Baja	Moderada	Moderada
<b>MAPA DE RIESGOS</b>			<i>Insignificante</i>	<i>Menor</i>	<i>Moderado</i>	<i>Mayor</i>	<i>Catastrófico</i>
			20%	40%	60%	80%	100%
			<b>Impacto</b>				

*Nota. Adaptado de “Guía para la administración del riesgo” (Departamento Administrativo de la Función Pública et al., 2022)*

A partir del análisis de la probabilidad de ocurrencia del riesgo y sus consecuencias o impactos, se busca determinar la zona de riesgo inicial (RIESGO INHERENTE).

**Paso 7. Valoración de controles:** Se tendrán en cuenta las siguientes tipologías de controles:

**Control preventivo:** Control accionado en la entrada del proceso y antes de que se realice la actividad originadora del riesgo, se busca establecer las condiciones que aseguren el resultado final esperado.

**Control detectivo:** Control accionado durante la ejecución del proceso. Estos controles detectan el riesgo, pero generan reprocesos.

**Control correctivo:** Control accionado en la salida del proceso y después de que se materializa el riesgo. Estos controles tienen costos implícitos.

Así mismo, de acuerdo con la forma como se ejecutan los controles puede ser:

**Control manual:** Controles que son ejecutados por personas.

**Control automático:** Son ejecutados por un sistema.

Los atributos informativos de los controles no tienen incidencia en la efectividad, pero si permiten conocer el entorno del control y complementar el análisis de los elementos cualitativos, de esta forma se puede conocer como fortalecer los controles existentes.

**Tabla 8**

*Atributos para el diseño de los controles*

ATRIBUTOS PARA EL DISEÑO DEL CONTROL			
CARACTERÍSTICAS		DESCRPCIÓN	%
Atributos de eficiencia	Tipo	Preventivo	Va hacia las causas del riesgo, aseguran el resultado final esperado.
		Detectivo	Detecta que algo ocurre y devuelve el proceso a los controles preventivos. Se pueden generar reprocesos.
			25%
			15%

Tabla 8. Continuación

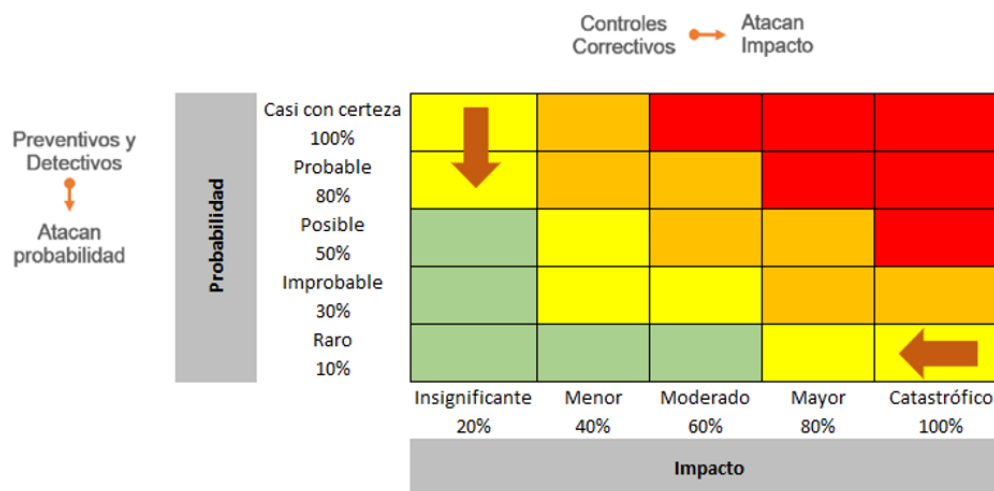
<b>ATRIBUTOS PARA EL DISEÑO DEL CONTROL</b>					
<b>CARACTERÍSTICAS</b>		<b>DESCRPCIÓN</b>	<b>%</b>		
<b>Atributos de eficiencia</b>	Tipo	Correctivo	Dado que permiten reducir el impacto de la materialización del riesgo, tienen un costo en su implementación.	10%	
		Implementación	Automático	Son actividades de procesamiento o validación de información que se ejecutan por un sistema y/o aplicativo de manera automática sin la intervención de personas para su realización	25%
	Manual		Controles que son ejecutados por una persona, tiene implícito el error humano.	15%	
	Efectividad del control		Muy efectivo	40%	
			Efectivo	30%	
			Poco efectivo	10%	
			Nada efectivo	0%	
	<b>Atributos informativos</b>	Documentación	Documentado	Controles que están documentados en el proceso, ya sea en manuales, procedimientos, flujogramas o cualquier otro documento propio del proceso.	-
			Sin documentar	Identifica a los controles que pese a que se ejecutan en el proceso no se encuentran documentados en ningún documento propio del proceso.	-
		Frecuencia	Permanente/Semanal/Mensual/Bimensual/Trimestral/Semestral	-	
Evidencia		Con registro	El control deja un registro permite evidencia la ejecución del control.	-	
		Sin registro	El control no deja registro de la ejecución del control.	-	

*Nota:* Adaptado de “Guía para la administración del riesgo” (Departamento Administrativo de la Función Pública et al., 2022)

**Paso 8. Valoración del riesgo residual:** En la Figura 11 se refleja el movimiento en la matriz de calor de acuerdo con al tipo de control:

**Figura 11**

*Movimiento en el mapa de calor*



*Nota.* Adaptado de “Guía para la administración del riesgo” (*Departamento Administrativo de la Función Pública et al., 2022*)

**Pasos 9 y 10. Definir y ejecutar el plan de mejoramiento:** Para el manejo del riesgo se podrá tener en cuenta alguna de las siguientes opciones, cada una de ellas independientemente, interrelacionadas o en conjunto:

- **Evitar el riesgo:** Es siempre la primera alternativa a considerar. Se logra cuando al interior de los procesos se genera cambios sustanciales de mejoramiento, rediseño del proceso, entre otros.
- **Reducir el riesgo:** Si el riesgo no puede ser evitado porque crea grandes dificultades en la operación del proceso, se genera el siguiente paso es reducirlo o minimizarlo al más bajo nivel posible.

- **Transferir el riesgo:** Hace referencia a compartir o trasladar físicamente a otro proceso o a la Gerencia parte o todo el riesgo. Así mismo, el riesgo puede ser minimizado compartiéndolo con otro proceso.
- **Asumir el riesgo:** Luego de que el riesgo ha sido reducido o transferido puede quedar un riesgo residual que se mantiene, en este caso el líder del proceso simplemente acepta la pérdida residual probable y elabora planes de contingencia para su manejo.

En la tabla 9, se describen las acciones a seguir de acuerdo con la zona de riesgo residual obtenida:

**Tabla 9**

*Tratamiento de los riesgos según la zona*

ZONA DE RIESGO	TRATAMIENTO	
<b>Baja</b>	Asumir el riesgo	**
<b>Moderada</b>	Asumir el riesgo, Reducir el riesgo	Plan de acción (opcional)
<b>Alta</b>	Reducir el riesgo, Evitar el riesgo, Compartir o transferir.	Plan de acción
<b>Extrema</b>	Evitar el riesgo, Reducir el riesgo, Compartir o transferir.	Plan de acción

*Nota: Adaptado de “Guía para la administración del riesgo” (Departamento Administrativo de la Función Pública et al., 2022)*

De acuerdo con lo anterior, se determina que a partir de la zona moderada y según se consideren la efectividad de los controles, se debe implementa un plan de mejoramiento para reducir el daño potencial.

Los líderes de proceso definen el plan de mejoramiento, el responsable de ejecución de cada acción y la fecha límite de cumplimiento, con el fin de minimizar la probabilidad de ocurrencia de los riesgos. Diligenciar el plan en el Formato Matriz de Riesgos.

Es responsabilidad del líder de proceso informar al personal las actividades del plan asignadas, para la ejecución de estas en la fecha límite definida.

**Paso 11. Efectuar seguimiento al plan de mejoramiento:** Es responsabilidad del líder de proceso efectuar seguimiento al cumplimiento del Plan de Mejoramiento. Evidenciar la ejecución de este seguimiento en el Formato Matriz de Riesgos.

**Riesgos:** Mínimo una vez al año se debe aplicar nuevamente la metodología expuesta anteriormente o cuando se requiera por un cambio que afecte o impacte en el sistema de gestión de calidad, proceso o el servicio prestado (incluyendo quejas y reclamos, incidentes y eventos adversos, desviaciones, cambios en el contexto interno/externo, entre otros), con el fin de volver a evaluar el riesgo y determinar si se minimizó el riesgo o para detectar la presencia de otros.

## 7. Modelo de decisión multicriterio

Para la formulación del modelo de decisión multicriterio se diseñó un modelo híbrido secuencial que integra el proceso analítico jerárquico (AHP) y la técnica TOPSIS (Technique for Order of Preference by Similarity to Ideal Solution). La elección de este enfoque se fundamenta en:

**Manejo de la subjetividad (Rol del AHP):** La evaluación de riesgos implica juicios subjetivos de expertos. El método AHP (Saaty, 1987) es ideal para descomponer el problema y fundamentalmente, para ponderar los criterios (probabilidad, impacto, detectabilidad) verificando matemáticamente la consistencia lógica de dichos juicios a través del ratio de consistencia (CR).

**Eficiencia en la Evaluación de Alternativas (Rol de TOPSIS):** Dado que el modelo contempla un alto número de riesgos específicos (25), utilizar AHP puro habría requerido cientos de comparaciones pareadas, fatigando a los expertos. TOPSIS (Hwang et al., 1980) permite evaluar un gran número de alternativas de manera directa y objetiva, basándose en la distancia matemática hacia una “solución ideal”.

**Sinergia metodológica:** El modelo utiliza los “pesos” ( $w_j$ ) calculados rigurosamente con AHP como input para alimentar al algoritmo de TOPSIS, eliminando la arbitrariedad en la asignación de importancia a los criterios.

El modelo de decisión se define formalmente como una función compuesta que busca jerarquizar un conjunto de riesgos  $A = \{A_1, A_2, \dots, A_m\}$  evaluados bajo un conjunto de criterios  $C = \{C_1, C_2, \dots, C_n\}$ .

El índice de prioridad de riesgo ( $C_i$ ) se obtiene en dos fases:

### 7.1.Fase I: Ponderación de criterios mediante AHP

En esta fase se determinó la importancia relativa ( $w_j$ ) de los criterios: Probabilidad, impacto y detectabilidad.

- **Paso 1: Construcción de la Jerarquía:** Se estructuró el problema situando el objetivo global en la cima, seguido de los criterios de evaluación.
- **Paso 2: Juicio de expertos y matriz de comparación:** Se construye la encuesta donde se especifican los criterios, riesgos y escalas con las que se evalúa.

#### 7.1.1. Encuesta Juicio de expertos

**Definir los criterios de evaluación:** El estándar en gestión de riesgos es:

- **Probabilidad (P):** ¿Qué tan probable es que ocurra el riesgo?
- **Impacto (I):** Si ocurre, ¿cuál sería la severidad de las consecuencias?

- **Detectabilidad (D):** ¿Qué tan fácil es detectar el riesgo antes de que ocurra o en sus etapas iniciales? (A menor detectabilidad, mayor prioridad).

### **Estructura de la jerarquía completa**

**Objetivo:** Priorizar riesgos de la cadena de suministro hospitalaria.

**Criterios:** Probabilidad, Impacto, Detectabilidad.

### **Alternativas (Riesgos):**

- Riesgos de Interrupción:
  - Naturales (Terremotos, Sequías...)
  - Accidentes (Incendios, Huelgas...)
  - Sanitarios (Epidemias, Plagas...)
- Riesgos Operativos:
  - Políticos (Regulaciones...)
  - Oferta/Demanda (Escasez de suministros...)
  - Gestión de Datos (p.ej., Fuga de información)
  - Proceso (Ciberseguridad, Fallos en tecnología...)
  - Financiero (Costos, Presupuesto...)

### **Diseño del Instrumento (Juicio de expertos)**

El AHP funciona cuantificando juicios subjetivos. Se crea una encuesta para expertos en la cadena de suministro hospitalaria de Colombia.

En la encuesta, los expertos compararán cada elemento "por pares". Por ejemplo:

- **Comparación de Criterios:** "¿Qué es más importante al evaluar un riesgo: ¿la probabilidad o el impacto? ¿Y cuánto más importante?" (Usando la escala 1-9 de Saaty).



**Probabilidad vs. Detectabilidad** "Al evaluar un riesgo, qué criterio considera más importante: ¿la Probabilidad de que ocurra o la Detectabilidad (facilidad para detectarlo a tiempo)?"

**Tabla 12**

*Probabilidad vs. Detectabilidad*

Criterio A	9	7	5	3	1	3	5	7	9	Criterio B
Probabilidad	0	0	0	0	0	0	0	0	0	Detectabilidad

**Impacto vs. Detectabilidad** "Al evaluar un riesgo, qué criterio considera más importante: ¿el Impacto que tendría si ocurre o la Detectabilidad (facilidad para detectarlo a tiempo)?"

**Tabla 13**

*Impacto vs Detectabilidad*

Criterio A	9	7	5	3	1	3	5	7	9	Criterio B
Impacto	0	0	0	0	0	0	0	0	0	Detectabilidad

**Calificación de riesgos:** En esta sección, le pedimos que utilice su experiencia para calificar una lista de riesgos identificados para la cadena de suministro hospitalaria en Colombia.

**Instrucciones:** Por favor, evalúe cada riesgo de la siguiente tabla de forma independiente. Asigne un valor de 1 (el nivel más bajo) a 5 (el nivel más alto) para cada uno de los tres criterios: **PROBABILIDAD, IMPACTO y DETECTABILIDAD.**

A continuación, se define lo que significa cada valor de la escala para cada criterio.

**Criterio: PROBABILIDAD (Frecuencia)**

Por favor, evalúe la probabilidad de que este riesgo ocurra y afecte significativamente a la cadena de suministro hospitalaria en Colombia, en un horizonte de tiempo de los próximos 5 años.

**Escala de calificación (1-5):**

**1 = Muy Baja:** Evento extremadamente raro o teóricamente imposible en el contexto colombiano.

**2 = Baja:** Evento poco probable, no ha sucedido en el pasado reciente.

**3 = Media:** Evento posible, ha ocurrido ocasionalmente o existen condiciones para que ocurra.

**4 = Alta:** Evento probable, se espera que ocurra al menos una vez en el período.

**5 = Muy Alta:** Evento casi seguro, ocurre con regularidad o es inminente.

**Criterio: IMPACTO (Severidad)**

Si este riesgo llegara a materializarse, por favor evalúe la severidad del impacto (daño) que tendría sobre la cadena de suministro hospitalaria (ej. interrupción del servicio, costos, seguridad del paciente, etc.).

**Escala de Calificación (1-5):**

**1 = Muy Bajo:** Impacto insignificante, no requiere ajustes en la operación normal.

**2 = Bajo:** Impacto menor, requiere ajustes menores en la operación.

**3 = Medio:** Impacto moderado, causa una interrupción notable y requiere recursos dedicados para la recuperación.

**4 = Alta:** Impacto severo, causa una interrupción grave del servicio y amenaza los objetivos clave de la cadena.

**5 = Muy Alto:** Impacto catastrófico, puede llevar al colapso de la cadena, con graves consecuencias para la seguridad del paciente y/o los objetivos de la cadena.

**Criterio: DETECTABILIDAD (Capacidad de detección)**

Por favor, evalúe la facilidad con la que este riesgo puede ser detectado o previsto *antes* de que ocurra, usando los sistemas de alerta y monitoreo actuales en Colombia.

**Escala de Calificación (1-5):**

**1 = Muy Difícil:** Prácticamente indetectable; ocurre sin ninguna advertencia.

**2 = Difícil:** Pocos o ningún mecanismo de alerta temprana; la detección es tardía.

**3 = Media:** La detección es posible, pero los sistemas de alerta no son robustos.

**4 = Fácil:** Se puede detectar con antelación; existen sistemas de monitoreo confiables.

**5 = Muy Fácil:** Sistemas de alerta temprana muy efectivos y ampliamente implementados;

el riesgo es visible con mucha antelación.

#### Tabla 14

##### *Calificación de riesgos*

RIESGO	PROBABILIDAD	IMPACTO	DETECTABILIDAD
Terremotos			
Tsunamis			
Inundaciones			
Heladas			
Sequias			
Derrumbes			
Incendios			
Huelgas			
Explosiones			
Accidentes			
Derrame de sustancias peligrosas			
Epidemias			
Pandemias			
Plagas			
Regulaciones, reformas...			
Variaciones en la demanda			
Escasez de suministros (medicamentos, dispositivos médicos, alimentos...)			
Problemas con los proveedores			
Calidad y/o integridad de los datos			
Logística hospitalaria			
Fallos en tecnología			
Ciberseguridad			
Infraestructura			
Talento Humano			
Costos, precios, presupuestos, financiación...			

- Paso 3: Agregación de Juicios (Consenso):** Participaron tres expertos (Apéndice D. Respuesta Juicio de Expertos), un médico general que labora en el hospital de Pamplona, una ingeniera industrial con experiencia en calidad y gestión del riesgo que labora en una IPS especializada de Bucaramanga y por último un gerente operacional que trabaja en una empresa de distribución de medicamentos a nivel de Norte de Santander, a partir de sus respuestas se construye una matriz de consenso unificada (Tabla 15) utilizando la media geométrica de las respuestas individuales de la ecuación (1) para preservar la propiedad de reciprocidad de la matriz:

$$a_{ij}^{consenso} = \sqrt[k]{a_{ij}^{(1)} \times a_{ij}^{(2)} \times \dots \times a_{ij}^{(k)}} \quad (1)$$

**Tabla 15**

*Matriz de juicios de los criterios*

<b>MATRIZ DE JUICIOS DE LOS CRITERIOS</b>			
	<b>Probabilidad</b>	<b>Impacto</b>	<b>Detectabilidad</b>
<b>Probabilidad</b>	1	1,57256466	0,333333333
<b>Impacto</b>	0,6359039	1	0,120820041
<b>Detectabilidad</b>	3	8,27677253	1
<b>Total</b>	4,6359039	10,8493372	1,454153375

- Paso 4: Cálculo del Vector de Prioridad (Pesos):** Se normalizó la matriz de consenso y se calculó el promedio aritmético por filas para obtener el vector de pesos  $W = \{w_P, w_I, w_D\}$ .

Se identificó que la detectabilidad es el criterio preponderante  $w_D \approx 0.70$  seguido de probabilidad e impacto. Los expertos opinan que lo *más crítico* en la cadena de suministro hospitalaria en Colombia no es que ocurra un riesgo, sino la capacidad de detectarlo.

En la Tabla 16 se encuentra el vector de pesos.

**Tabla 16***Vector de pesos*

<b>MATRIZ NORMALIZADA DE JUICIOS DE LOS CRITERIOS</b>				
	<b>Probabilidad</b>	<b>Impacto</b>	<b>Detectabilidad</b>	<b>Peso (Promedio)</b>
<b>Probabilidad</b>	0,21570766	0,14494569	0,229228456	0,19662727
<b>Impacto</b>	0,13716934	0,09217153	0,083086175	0,10414235
<b>Detectabilidad</b>	0,64712299	0,76288278	0,687685369	0,699230381

- **Paso 5: Validación de Consistencia:** Se calculó el ratio de consistencia (CR) con la ecuación (2).

$$CR = \frac{CI}{RI} \quad (2)$$

**Tabla 17***Ratio de consistencia*

	<b>Vector suma ponderada</b>	<b>Lambda</b>	<b>Lambda máx.</b>	<b>Índice de consistencia</b>	<b>Relación de consistencia</b>
<b>Probabilidad</b>	0,59347464	3,0182723	3,035484077	0,017742039	0,030589722
<b>Impacto</b>	0,31365944	3,01183373			
<b>Detectabilidad</b>	2,15107473	3,07634621			

El modelo obtuvo un CR=3% menor al 10% lo que valida la coherencia lógica de los pesos asignados.

## 7.2.Fase II: Jerarquización de Riesgos mediante TOPSIS

Una vez obtenidos los pesos  $w_j$  del AHP, se procedió a la clasificación de los riesgos.

- **Paso 1: Construcción de la matriz de decisión inicial:** Se calificó cada riesgo en una escala de Likert (1-5). Los valores de los expertos se agregaron mediante promedio aritmético.

- **Paso 2: Normalización vectorial:** Se transformaron las calificaciones  $x_{ij}$  para normalizar las escalas mediante la norma euclidiana de la ecuación (3):

$$C = \frac{x_{ij}}{\sqrt{\sum_{i=1}^m x_{ij}^2}} \quad (3)$$

- **Paso 3: Construcción de la matriz normalizada ponderada (V):** Se incorporaron los pesos del AHP al modelo TOPSIS multiplicando cada valor normalizado por su peso correspondiente, como se muestra en la ecuación (4):

$$v_{ij} = w_j^{AHP} \times r_{ij} \quad (4)$$

- **Paso 4: Determinación de soluciones ideales:** Se definieron los puntos de referencia para maximizar el riesgo:

Solución Ideal Positiva ( $A^+$ ): El escenario de máximo riesgo (Máximos valores de  $v_{ij}$ ).

Solución Ideal Negativa ( $A^-$ ): El escenario de mínimo riesgo (Mínimos valores de  $v_{ij}$ ).

- **Paso 5: Cálculo de distancias euclidianas:** Se calculó la separación geométrica de cada riesgo respecto a los ideales por medio de las ecuaciones (5) y (6):

$$D_i^+ = \sqrt{\sum_{j=1}^n (v_{ij} - v_j^+)^2} \quad (5) \quad \text{y} \quad D_i^- = \sqrt{\sum_{j=1}^n (v_{ij} - v_j^-)^2} \quad (6)$$

- **Paso 6: Cálculo del coeficiente de proximidad relativa:** Se obtuvo el puntaje final utilizando la ecuación (7) que determina el ranking:

$$C_i = \frac{D_i^-}{D_i^+ + D_i^-}, \quad 0 \leq C_i \leq 1 \quad (7)$$

Un valor de  $C_i$  cercano a 1 indica que el riesgo tiene una alta prioridad (es muy cercano al peor escenario posible y lejano al escenario seguro), mientras que un valor cercano a 0 indica un riesgo bajo o despreciable.

En la Tabla 18 se observan todos los cálculos realizados a los riesgos.

**Tabla 18***Cálculos riesgos*

<b>RIESGO</b>	<b>PROB</b>	<b>IMP</b>	<b>DET</b>	<b>Distancia ideal</b>	<b>Distancia Anti-ideal</b>	<b>Coefficiente de proximidad</b>
Terremotos	0,027197919	0,0242432	0,133565865	0,055453412	0,03670162	0,398259563
Tsunamis	0,016998699	0,02101077	0,183653065	0,03415072	0,08386889	0,710635214
Inundaciones	0,037397139	0,01939456	0,133565865	0,052126467	0,03965956	0,432087118
Heladas	0,020398439	0,01292971	0,133565865	0,05977407	0,03356409	0,359596667
Sequias	0,040796878	0,01616213	0,133565865	0,05174993	0,0411314	0,442838179
Derrumbes	0,044196618	0,01777835	0,116870132	0,067438767	0,03227977	0,323708826
Incendios	0,033997399	0,01939456	0,100174399	0,085329671	0,01818654	0,175687817
Huelgas	0,040796878	0,01616213	0,116870132	0,06803887	0,02924978	0,300649433
Explosiones	0,033997399	0,01777835	0,100174399	0,085436747	0,01767668	0,171429485
Accidentes	0,044196618	0,01616213	0,116870132	0,067612844	0,03207683	0,321766812
Derrame de sustancias peligrosas	0,040796878	0,02262699	0,133565865	0,051140627	0,04213527	0,451727281
Epidemias	0,040796878	0,02101077	0,133565865	0,051217187	0,04179291	0,449337322
Pandemias	0,027197919	0,0242432	0,100174399	0,086804614	0,01523218	0,149281225
Plagas	0,037397139	0,01454592	0,116870132	0,06883988	0,02640939	0,277266076
Regulaciones, reformas...	0,050996098	0,02262699	0,133565865	0,050113269	0,04862973	0,492487866
Variaciones en la demanda	0,040796878	0,02262699	0,150261598	0,03495177	0,05629492	0,616953011
Escasez de suministros	0,040796878	0,0242432	0,133565865	0,051115082	0,04253632	0,454198429
Problemas con los proveedores	0,040796878	0,02262699	0,133565865	0,051140627	0,04213527	0,451727281
Calidad y/o integridad de los datos	0,040796878	0,01939456	0,183653065	0,011293068	0,08704502	0,885160789
Logística hospitalaria	0,037397139	0,02262699	0,183653065	0,013694665	0,08648018	0,863292375
Fallos en tecnología	0,044196618	0,02262699	0,150261598	0,034115027	0,05781429	0,628899354
Ciberseguridad	0,047596358	0,0242432	0,133565865	0,050202448	0,04668192	0,481831303
Infraestructura	0,040796878	0,0242432	0,183653065	0,01019922	0,08753877	0,895647335
Talento Humano	0,040796878	0,02101077	0,166957332	0,01982978	0,07135557	0,782533265
Costos, precios, presupuestos, financiación...	0,050996098	0,0242432	0,133565865	0,050087199	0,04897763	0,494399783
Solución ideal positiva	0,050996098	0,0242432	0,183653065			
Solución ideal negativa	0,016998699	0,01292971	0,100174399			

El modelo propuesto se formula como una función de decisión multicriterio  $M(A, C, W)$ , donde el conjunto de alternativas de Riesgo ( $A$ ) es evaluado frente al conjunto de Criterios ( $C$ ), ponderados por un vector de Pesos ( $W$ ) derivado de la metodología AHP. La solución del modelo se obtiene mediante el algoritmo TOPSIS, cuya ecuación gobernante es el Coeficiente de Proximidad Relativa ( $C_i$ ). Se aplicó la metodología híbrida AHP-TOPSIS. El AHP determinó que la detectabilidad es el criterio preponderante (69.9%).

Consecuentemente, el ranking TOPSIS priorizó los riesgos operativos (Infraestructura, datos, logística) sobre los riesgos de interrupción como los desastres naturales tradicionales, proporcionando una guía clara para la gestión preventiva en las instituciones de salud colombianas.

La Tabla 19 muestra un consenso de los resultados obtenidos.

**Tabla 19**

*Resumen de resultados MCDM*

<b>Nivel del Riesgo</b>	<b>Rango del coeficiente (<math>C_i</math>)</b>	<b>Acción gerencial sugerida</b>	<b>Riesgos</b>
Riesgo crítico	0,60-1	<b>Mitigación Inmediata:</b> Requieren planes de contingencia y monitoreo continuo.	Infraestructura, datos, logística, talento humano, tsunamis, fallos tecnología, demanda.
Riesgo moderado	0,30-0,59	<b>Monitoreo Periódico:</b> Se deben establecer indicadores de alerta temprana.	Costos, regulaciones, ciberseguridad, escasez, derrames, proveedores, epidemias, sequias, inundaciones, terremotos, heladas, derrumbes, accidentes, huelgas etc.
Riesgo aceptable	0,00-0,29	<b>Aceptación/Control Rutinario:</b> Se gestionan con procedimientos estándar.	Plagas, incendios, explosiones, pandemias.

## 8. Framework para la gestión del riesgo de la CSH basado en MD

Esta sección presenta el desarrollo del Framework para la gestión del riesgo de la CSH basado en MD. La realización del marco de trabajo propuesto toma como guía el artículo: “*A data mining-based framework for supply chain risk management*” (Er Kara et al., 2020) que ha sido adaptado a la CSH y principalmente con los hallazgos realizados en esta investigación. Este Framework tiene un enfoque holístico que integra metódicamente principios clave de MD, almacenamiento de datos y gestión de riesgos.

El objetivo del Framework es transformar los datos (estructurados y no estructurados) en “inteligencia del riesgo”, dado que los expertos determinaron que la detectabilidad es el factor preponderante (69,9%), el núcleo de este Framework no es solo evaluar el impacto y la probabilidad, sino aumentar la visibilidad y la capacidad de alerta temprana mediante MD.

### 8.1.Fase I: Identificación y fuentes de datos (Data Sources)

Lo primero que se debe conocer es la información del hospital para esto es necesario indagar sobre cada una de las características que componen la institución, incluyendo como es el funcionamiento de sus procesos y como está constituida su CS, una vez se tenga la visión clara de cómo está organizado el hospital se debe identificar como es la actitud de riesgo y nivel de tolerancia para poder así evaluar el nivel de resiliencia de la CS.

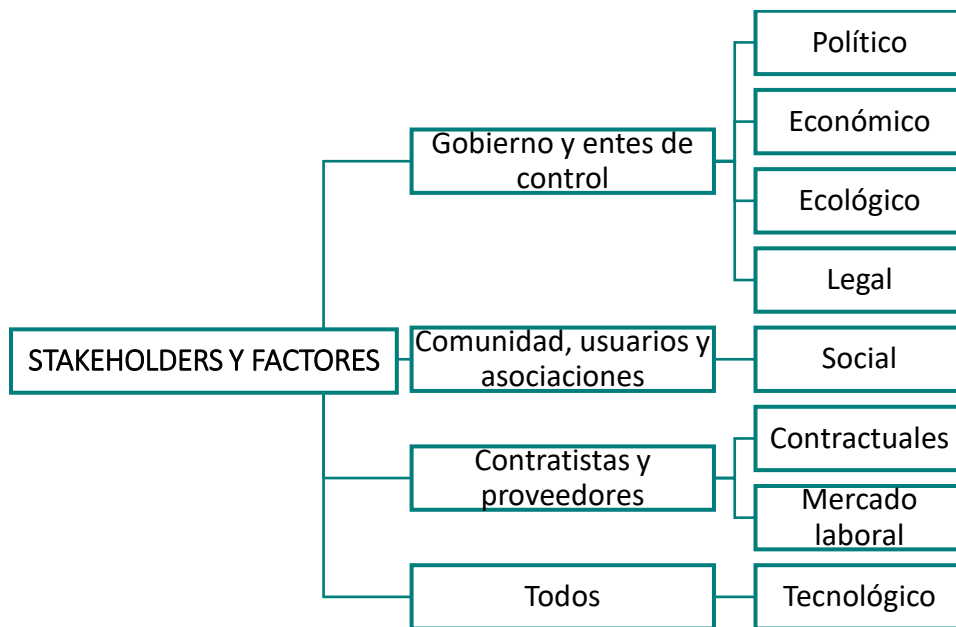
Es necesario, crear un equipo de expertos en gestión de riesgos para lograr guiar a otros miembros en la identificación, evaluación y mitigación de estos, adicional a esto también se requieren especialistas en TI y MD para el manejo de las múltiples herramientas y técnicas que se utilizan en cada uno de los módulos para el análisis de los datos.

Para recolectar la información mencionada anteriormente se recomienda seguir una metodología que involucra direccionamiento y riesgos: “*Dirección estratégica hospitalaria para IPS públicas*” (Castro Páez & Barreto Bernal, 2022), se inicia con un estudio del contexto estratégico que involucra un análisis de los factores internos y externos que influyen en el desarrollo de la institución, de esta manera se obtiene un diagnóstico respecto a los recursos y las capacidades con las que cuenta la IPS.

**Análisis externo:** El análisis de factores externos se realiza con la matriz de Análisis de Variables Externas de los Stakeholders (AVES) (o partes interesadas), a través de los grupos de interés se identifican los siguientes factores (Figura 12):

**Figura 12**

*Stakeholders y factores*



*Nota.* Adaptado de “*Dirección estratégica hospitalaria para IPS públicas. Metodología para el desarrollo de la planeación y direccionamiento estratégico*”, (Castro Páez & Barreto Bernal, 2022).

Esta metodología facilita la descripción en detalle del contexto en el que opera la institución y ayuda a comprender el crecimiento o declive de un mercado, las dificultades, retos y riesgos que puede presentar, así como a orientar la dirección y la posición del negocio de forma sencilla, sistemática y pautada.

Después de definir los factores externos que influyen en el sector salud de la matriz AVES (Figura 13) se realiza la ponderación de los factores de 1 a 100%, (la sumatoria de todos los factores deben ser de 100%). Posteriormente, para cada uno de estos factores externos, se distribuye el porcentaje (%) asignado entre las variables que lo conforman, adicionalmente se califica para cada variable, si representa una oportunidad o un riesgo para la institución, de acuerdo con la escala.

**Figura 13**

*Matriz AVES*

STAKEHOLDERS	FACTOR	VARIABLE	CUMPLIMIENTO					OBSERVACIONES
			5	4	3	2	1	
COMUNIDAD Y USUARIOS	EFFECTOS DE SALUD	Mortalidad infantil						
	DEMOGRÁFICOS	Tasa de natalidad						
	GEOGRÁFICOS	Estado de las vías rurales						
	MEDIO AMBIENTAL	Variaciones climáticas influyentes en la salud						
	ASPECTOS MICROECONÓMICOS	Ingreso per cápita por hogar						
GOBIERNO Y ENTES DE CONTROL	ASPECTOS MACROECONÓMICOS	Flujo de recursos de las IPS						
	POLÍTICO - LEGALES	Número de demandas interpuestas a la IPS						
	REQUERIMIENTOS	Requerimientos solicitados y enviados						
CONTRATISTAS Y PROVEEDORES	CONTRACTUALES	Pago oportuno de las EPS						
	FINANCIEROS	Rotación de cartera						
	TECNOLÓGICOS	Plataformas tecnológicas eficientes						
	LOGÍSTICOS	Entrega eficiente de pedidos						
ASOCIACIONES	MERCADO LABORAL	Oferta de profesionales de la salud						
	FOMENTO ASOCIATIVO	Conformación y estructuración social						
	PARTICIPACIÓN	Participación ciudadana						

CRITERIOS CUMPLIMIENTO		
RIESGOS	1	Deficiente
	2	Regular
	3	Aceptable
OPORTUNIDADES	4	Bueno
	5	Óptimo

*Nota.* Adaptado de “Dirección estratégica hospitalaria para IPS públicas. Metodología para el desarrollo de la planeación y direccionamiento estratégico”, (Castro Páez & Barreto Bernal, 2022).

Una vez evaluado el macroentorno para identificar riesgos y oportunidades exógenas que impactan la CSH, se obtiene la **salida para el modelo**: identificación de riesgos exógenos (variables con calificación baja, 1-3) que requieren monitoreo externo (por ejemplo: cambios en regulaciones, inflación, desastres naturales)

**Análisis interno:** Se evalúa la capacidad operativa de la institución mediante la Matriz de Análisis de Variables Internas por Procesos (AVIP). Esta herramienta examina los procesos estratégicos, misionales (urgencias, farmacia, etc.) y de apoyo, calificando las variables como "Fortalezas" o "Oportunidades de Mejora" como se muestra en la Figura 14.

**Salida para el modelo:** Identificación de debilidades internas que pueden convertirse en riesgos operativos (ej. fallas en infraestructura, falta de insumos, rotación de personal).

**Figura 14**

*Matriz AVIP*

TIPO	PROCESO	SUB PROCESO	VARIABLES	CUMPLIMIENTO					OBSERVACIONES
				5	4	3	2	1	
ESTRATÉGICOS	Gerencial	NA	Evaluación de resultados						
	Financieros	Presupuesto	Seguimiento presupuestal						
		Facturación	Gestión de glosas						
		Tesorería	Informes antes de control						
		Contabilidad	Estados financieros						
		Costos	Gestión de costos						
MISIONALES	Consulta externa	Medicina	Cumplimiento de metas de PyR.						
		Odontología	Convenio docente						
	Urgencias	NA	Eventos adversos						
	Laboratorio clínico	NA	Infecciones nosocomiales						
	Farmacia	NA	Gestión de medicamentos						

CRITERIOS CUMPLIMIENTO		
Oportunidades de mejora	1	Deficiente
	2	Regular
	3	Aceptable
Fortalezas	4	Bueno
	5	Óptimo

*Nota.* Adaptado de “Dirección estratégica hospitalaria para IPS públicas. Metodología para el desarrollo de la planeación y direccionamiento estratégico”, (Castro Páez & Barreto Bernal, 2022).

**Análisis de fortalezas, oportunidades y riesgos:** La información recolectada en las etapas anteriores se cruza en la Matriz de Análisis de Fortalezas, Oportunidades y Riesgos (AFOR). Esta matriz es el punto crítico de integración donde se definen explícitamente:

- Riesgos Exógenos: Amenazas del entorno que se materializan si no se aprovechan las fortalezas internas (Figura 15).

### Figura 15

*Matriz AFOR para variables externas*

MATRIZ AFOR					
VARIABLES EXTERNAS			APOYO A LA FORTALEZA	OPORTUNIDAD	RIESGO EXÓGENO
STAKEHOLDER	FACTOR	VARIABLE			
Gobierno y entes de control	Político				
	Económico				
	Ecológico				
	Legal				
Comunidad, usuarios y asociaciones	Social				
Contratistas y proveedores	Contractuales				
	Mercado laboral				
Todos	Tecnológico				

*Nota.* Adaptado de “Dirección estratégica hospitalaria para IPS públicas. Metodología para el desarrollo de la planeación y direccionamiento estratégico”, (Castro Páez & Barreto Bernal, 2022).

- Riesgos Endógenos: Peligros internos derivados de no gestionar las oportunidades de mejora o perder fortalezas actuales (Figura 16).

Los riesgos encontrados se analizan y evalúan como se explicó anteriormente en el Apéndice C. Formato Matriz de riesgos.

**Figura 16***Matriz AFOR para variables internas*

MATRIZ AFOR					
VARIABLES INTERNAS			FORTALEZA	OPORTUNIDAD	RIESGO ENDÓGENO
TIPO	PROCESO	VARIABLES			
Procesos de dirección	Gerencial				
	Comercial				
Procesos misionales	Investigación				
	Laboratorio clínico				
	Servicio farmacéutico				
	Atención Integral				
	Vacunación				
Procesos de apoyo	Compras				
	Talento humano				
	Mantenimiento, calibración e infraestructura				
	Sistemas e información				
	Financiera				
	Gestión integral				

*Nota.* Adaptado de “Dirección estratégica hospitalaria para IPS públicas. Metodología para el desarrollo de la planeación y direccionamiento estratégico”, (Castro Páez & Barreto Bernal, 2022).

El Framework se va a alimentar de dos flujos:}

- Flujo estructurado (Datos internos)

Origen: ERP hospitalario, CRM (bases de datos operativas), sistemas de información del hospital, RIPS, inventarios, informes y/o reportes...

Indicadores de riesgo: tiempos de entrega, niveles de stock, costos de los insumos, rotación del personal, fallas reportadas tanto de la infraestructura física como tecnológica...

- Flujo no estructurado (Datos externos)

Origen: Portales de noticias (para riesgo político/reformas), alertas del Invima, boletines climáticos (IDEAM para riesgo natural), redes sociales, quejas de los usuarios...

### **8.2.Fase II: Almacenamiento y preprocesamiento (Risk Data Warehouse)**

El Risk Data Warehouse es el repositorio central que recopila y almacena datos de riesgo de la cadena de suministro actuales e históricos de diferentes fuentes de datos internas y externas. Puede verse como la memoria de riesgos de la institución y brinda la oportunidad de procesamiento analítico, monitoreo y reporte de datos de riesgo para respaldar la toma de decisiones basada en datos. Los pasos de preprocesamiento de datos incluyen la limpieza, integración, reducción y transformación de datos. En esta fase se centraliza la información.

- ETL Híbrido: Procesos para limpiar datos numéricos y métodos de procesamiento de lenguaje natural para estructurar tanto los datos estructurados como los no estructurados.
- Repositorio de metadatos de riesgo: Aquí se almacena la jerarquización de riesgos creada en la Figura 8.

### **8.3.Fase III: Módulo de evaluación y priorización (MCDM)**

No todos los datos que entran son críticos, En este módulo se filtra la información entrante basándose en la Tabla 19, que presenta la jerarquización obtenida mediante los métodos MCDM.

Este paso funciona como un "trriage inteligente": asegura que los algoritmos de MD (que consumen más recursos computacionales) se enfoquen únicamente en los riesgos significativos, evitando el ruido de datos irrelevantes.

Según esto, la lógica del modelo etiqueta los flujos de datos entrantes:

- Riesgo Crítico: Pasa a análisis prioritario y detección de anomalías en tiempo real.
- Riesgo Moderado: Pasa a monitoreo periódico y reportes de tendencia.

- Riesgo Aceptable: Se almacena para control histórico sin activar alertas inmediatas.

#### 8.4.Fase IV: Módulo de minería de datos (The data mining core)

El objetivo principal de este módulo de MD es convertir los datos de riesgo en información/conocimiento para tomar decisiones inteligentes para la gestión del riesgo de la institución, es decir, en esta fase se traduce el “problema de gestión del riesgo” en un “problema de MD”. En la Tabla 20 se presenta un conjunto de preguntas que pueden ayudar a los tomadores de decisiones a convertir los problemas de gestión del riesgo en un problema de MD. La estructura incluye categorías de problemas de gestión de riesgos, ejemplos de preguntas de guía que pueden ayudar a seleccionar la tarea de MD más útil y tareas de DM alternativas que pueden proporcionar respuestas a dichos problemas de riesgo.

**Tabla 20**

*¿Cómo convertir problemas de gestión del riesgo en problemas de MD?*

<b>Categoría de riesgo</b>	<b>Problema de la institución</b>	<b>Técnica de minería sugerida</b>	<b>Algoritmo sugerido</b>	<b>Objetivo (Detectabilidad)</b>
Infraestructura y tecnología (Crítico)	¿Cuándo fallará un equipo médico crítico?	Predicción / Detección de anomalías	Isolation Forest / One- Class SVM	Mantenimiento predictivo antes de la falla
Talento humano (Crítico)	¿Qué personal es propenso a renunciar o a cometer errores?	Clasificación / Asociación	Random Forest / Árboles de decisión	Identificar patrones de rotación o fatiga
Demanda / Escasez (Crítico/Moderado)	Variación abrupta en necesidad de insumos	Series de tiempo / Regresión	LSTM / Regresión lineal	Alertar picos de demanda
Ciberseguridad y Datos (Crítico)	¿Existe un intento de intrusión o corrupción de datos en el sistema del hospital?	Detección de intrusiones / Clasificación	Redes Neuronales (ANN) / Naïve Bayes / Isolation Forest	Detectar patrones de acceso inusuales en tiempo real

Tabla 20. Continuación

<b>Categoría de riesgo</b>	<b>Problema de la institución</b>	<b>Técnica de minería sugerida</b>	<b>Algoritmo sugerido</b>	<b>Objetivo (Detectabilidad)</b>
Logística Hospitalaria (Crítico)	¿Qué rutas o entregas de insumos críticos sufrirán retrasos?	Optimización / Clustering Espacial	Algoritmo Genético / K-Means	Re-ruteo dinámico ante bloqueos o tráfico
Político/Regulaciones (Moderado)	Impacto de nuevas reformas	Minería de texto	Análisis de sentimiento (NLP)	Evaluar la incertidumbre en el entorno legal
Proveedores (Moderado)	¿Qué proveedor es riesgoso?	Clustering (K-means)	K-means / Árboles de decisión	Agrupar proveedores por nivel de cumplimiento
Financiero / Costos (Moderado)	¿Cómo afectará la volatilidad de precios al presupuesto?	Regresión / Predicción	Regresión Múltiple / Holt-Winters	Predecir sobrecostos por inflación o TRM
Sanitarios / Epidemias (Moderado)	¿Dónde surgirá el próximo brote (dengue/gripa) que sature la urgencia?	Análisis Espacio-Temporal	DBSCAN / ST-DBSCAN	Detectar clústeres geográficos de infección
Físicos / Incendios (Aceptable)	¿Con qué frecuencia ocurren incidentes menores de seguridad física?	Estadística Descriptiva / Resumen	Análisis de Pareto / Histogramas	Control rutinario de incidentes históricos
Ambientales / Plagas (Aceptable)	¿Existe estacionalidad en la pérdida de esterilidad de insumos almacenados por plagas?	Asociación / Patrones Secuenciales	Apriori / GSP (Generalized Sequential Patterns)	Identificar temporadas de fumigación preventiva

### 8.5.Fase V: Soporte a la decisión y mitigación

La interpretación y evaluación de los resultados de los algoritmos de MD proporcionan la transformación de la información de riesgo en conocimiento de riesgo. La MD puede proporcionar los siguientes tipos de información sobre riesgos: Predicción de eventos de riesgo, descubrimiento de patrones de riesgo, relación entre riesgos y, entre riesgos y sus factores desencadenantes, clasificación de diferentes partidas según riesgos, agrupaciones de diferentes ítems basados en factores de riesgo, resumen de los datos de riesgo, visualización de los datos de riesgo... Este

paso es crucial porque un marco de gestión del riesgo basado en MD depende en gran medida de la elección de la aplicación de MD y la evaluación de los resultados del análisis.

La salida del Framework debe coincidir con la columna de la tabla 19 “Acción gerencial sugerida”, dando así alertas en tiempo real, informes semanales, controles rutinarios y planes de mitigación apropiados para todos los riesgos detectados.

### **8.6.Fase VI: Monitoreo y aprendizaje continuo**

La gestión del riesgo en CSH es un proceso dinámico y no lineal. Por tanto, se requiere de un cierre de ciclo que permita al sistema "aprender" de sus propios resultados.

Esta fase tiene como objetivo capturar el desenlace de los eventos gestionados en la Fase V y reincorporar esa información al Risk Data Warehouse (Fase II). Este proceso cumple dos funciones críticas:

**Validación del Modelo:** Permite contrastar la predicción realizada por los algoritmos de MD (Fase IV) contra la realidad operativa. Por ejemplo, si el modelo predijo un pico de demanda y este ocurrió, se valida la precisión; si no ocurrió, se registra como un "falso positivo".

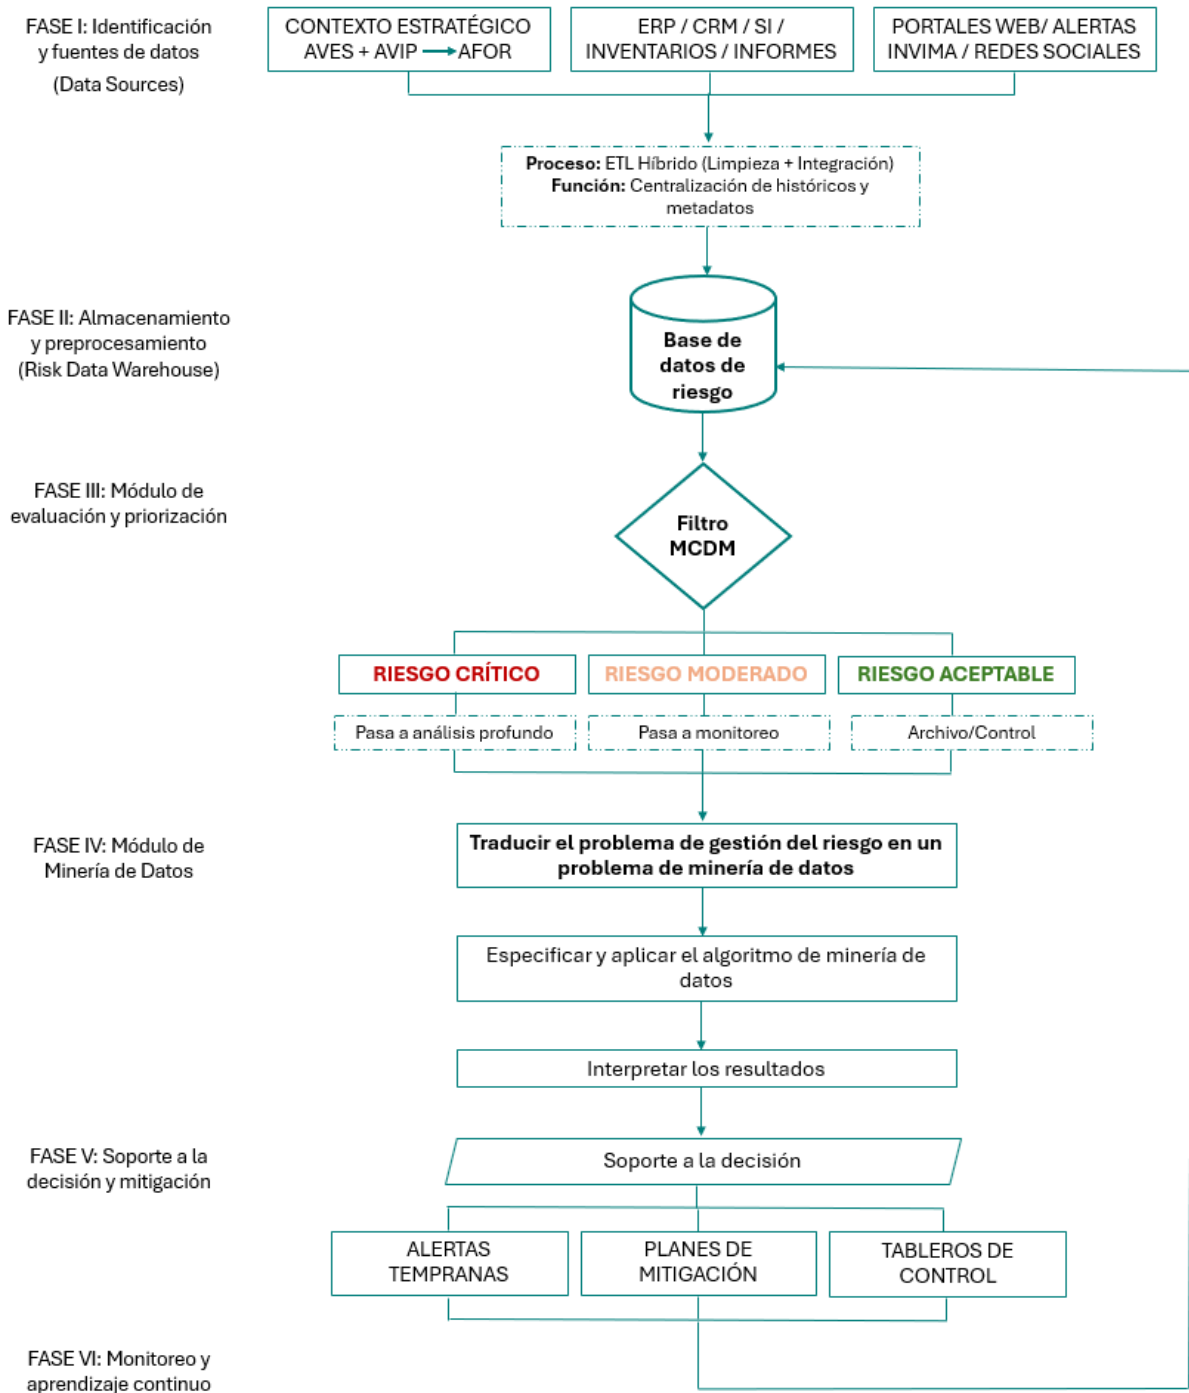
**Reentrenamiento y Calibración:** Los nuevos datos generados (acciones tomadas y sus resultados) sirven de insumo para reentrenar los algoritmos periódicamente. Esto asegura que el sistema se adapte a cambios en el entorno (nuevas regulaciones, cambios en el comportamiento de proveedores, etc.), mejorando progresivamente la precisión de la detectabilidad y reduciendo la incertidumbre futura.

De esta manera, la "inteligencia del riesgo" de la institución evoluciona constantemente, transformando la experiencia operativa en una base de conocimiento robusta para la toma de decisiones futuras.

El enfoque paso a paso para el desarrollo del Framework para la gestión del riesgo basado en MD se presenta en la Figura 17.

**Figura 17**

*Framework para la gestión del riesgo basado en MD*



### **8.7. Validación del Framework mediante simulación de escenarios con datos sintéticos**

Para verificar la consistencia lógica y la viabilidad técnica del Framework propuesto es esta investigación, se desarrolló una prueba de concepto computacional utilizando el lenguaje de programación Python y como entorno Google Colab. Dado que los datos reales de riesgos hospitalarios suelen ser sensibles y confidenciales, se optó por la generación de datos sintéticos controlados que replican los comportamientos descritos en la literatura y en la Fase I del modelo.

A continuación, se detalla la correlación entre cada bloque del código ejecutado y las fases del Framework:

#### ***8.7.1. Generación e ingreso de datos (Validación de Fases I y II)***

El código simula la existencia de un entorno de datos híbrido, tal como se plantea en la arquitectura del sistema:

**Datos No Estructurados:** Se generó un corpus de noticias simuladas relacionadas con el sector salud en Colombia (por ejemplo: reformas, paros, escasez). Esto valida la capacidad del sistema para procesar fuentes externas, es decir, flujo no estructurado descritas inicialmente en el diseño.

**Datos Estructurados:** Se crearon registros numéricos simulando sensores de equipos médicos (IoT) e históricos de desempeño de proveedores. Esto representa el flujo de datos internos provenientes de sistemas ERP y mantenimiento.

**Centralización:** La estructura de datos en DataFrames (pandas) valida funcionalmente el concepto del Risk Data Warehouse, actuando como repositorio central previo al análisis.

### 8.7.2. Filtrado y Priorización de Riesgos (Validación de Fase III)

El algoritmo implementa reglas de negocio para validar el componente MCDM. En el módulo de análisis de texto, el código no procesa todas las noticias por igual; aplica un filtro condicional: si detecta palabras clave de riesgo y un sentimiento negativo, clasifica el evento como "ALTO (CRÍTICO)". Esta lógica computacional valida la aplicación de la Tabla 19, demostrando cómo el sistema discrimina entre riesgos aceptables y críticos antes de activar alertas mayores.

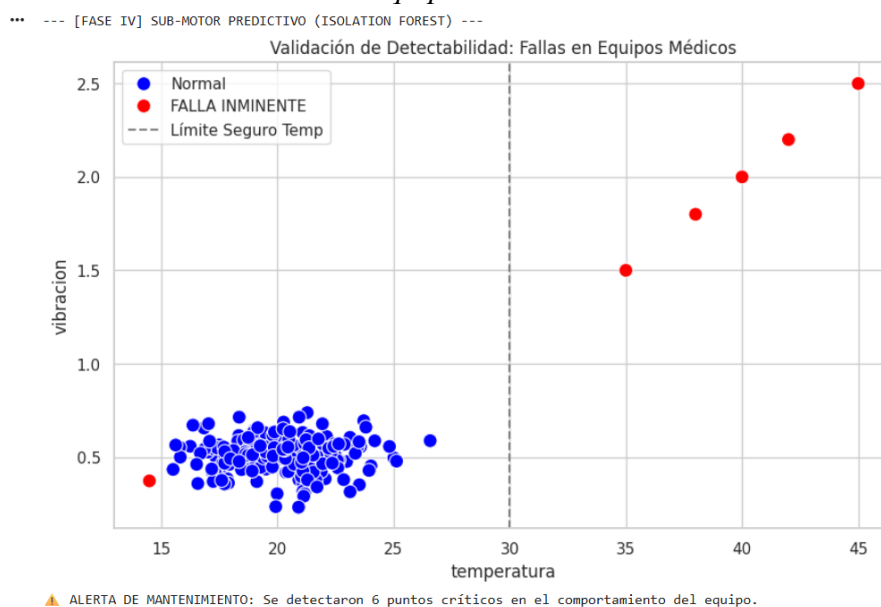
### 8.7.3. Aplicación de Algoritmos de Minería de Datos (Validación de Fase IV)

Esta es la sección central de la validación de Framework. El código ejecuta tres algoritmos distintos para demostrar la adaptabilidad del "Módulo de Minería de Datos" propuesto:

**Escenario de Infraestructura (Isolation Forest):** Se aplicó este algoritmo de detección de anomalías sobre los datos de temperatura y vibración de un equipo médico. El resultado gráfico (ver Figura 18) muestra cómo el modelo aisló exitosamente los puntos de datos inyectados como fallas (puntos rojos), validando la capacidad de "mantenimiento predictivo antes de la falla".

**Figura 18**

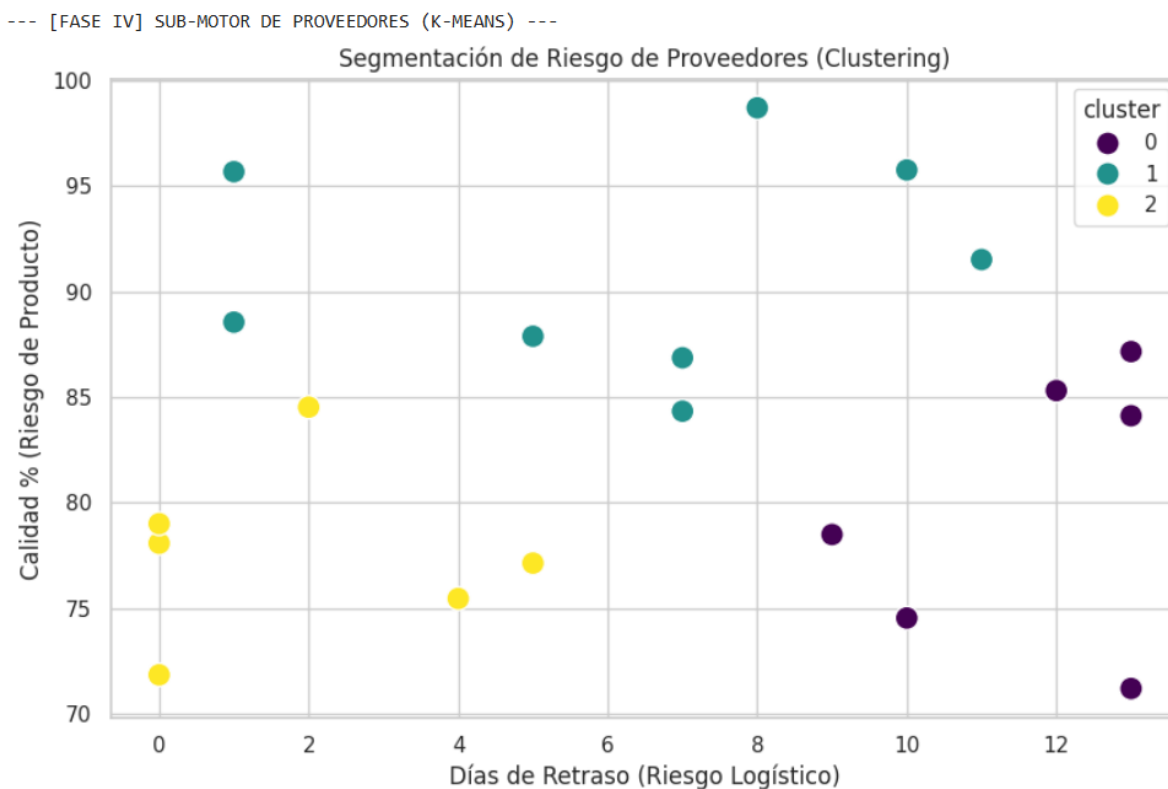
*Validación de detectabilidad: Fallas en equipos médicos*



**Escenario de Proveedores (K-Means Clustering):** Se utilizó el algoritmo de agrupamiento no supervisado para segmentar a los proveedores según sus tiempos de entrega y calidad. El código logró identificar automáticamente clústeres de proveedores riesgosos, validando la tarea de "Agrupar proveedores por nivel de cumplimiento".

**Figura 19**

*Segmentación de riesgo de proveedores (Clustering)*



Los tres clústeres visualizados en la Figura 19, se interpretan así:

- Clúster 1 (Puntos verde azulado) - "Proveedores Estratégicos / Alta Calidad"

Características: Este grupo se distingue por mantener los estándares más altos de calidad (superior al 85% y llegando casi al 100%). Aunque sus tiempos de entrega varían (algunos rápidos, otros con retrasos medios), la consistencia de su producto es su mayor fortaleza.

Nivel de Riesgo: Moderado (riesgo logístico). El riesgo de calidad es mínimo.

Acción Gerencial Sugerida: Estos son socios clave para insumos médicos vitales donde la calidad no es negociable (por ejemplo, medicamentos, material quirúrgico). La estrategia debe ser colaborativa, trabajar conjuntamente para optimizar sus tiempos de entrega (logística), pero asegurando su retención mediante contratos a largo plazo.

- Clúster 2 (Puntos amarillos) - "Proveedores Ágiles / Calidad Estándar"

Características: Este grupo se ubica en la zona izquierda del gráfico, caracterizándose por tiempos de respuesta muy rápidos (retrasos cercanos a 0 días). Sin embargo, su nivel de calidad es medio-bajo (entre 70% y 80%), inferior al del Clúster 1.

Nivel de Riesgo: Aceptable (Riesgo de calidad). Son eficientes, pero no excelentes.

Acción Gerencial Sugerida: Son proveedores ideales para compras de contingencia o insumos no críticos (por ejemplo: papelería, ropa de cama) donde la disponibilidad inmediata es prioritaria sobre la calidad premium. Se sugiere implementar controles de calidad a la entrada para mitigar el riesgo de defectos.

- Clúster 0 (Puntos morados) - "Proveedores Críticos / Alto Riesgo"

Características: Ubicados en la zona inferior derecha, estos proveedores presentan el peor escenario posible: altos tiempos de retraso (superiores a 8 días) combinados con una calidad variable a baja (dispersa entre 70% y 87%).

Nivel de Riesgo: CRÍTICO. Representan una amenaza para la continuidad operativa del hospital.

Acción Gerencial Sugerida: Mitigación Inmediata / Sustitución. No son confiables ni en tiempo ni en forma. La recomendación del Framework es iniciar la búsqueda de proveedores alternativos y, mientras tanto, no asignarles pedidos de insumos críticos.

**Escenario Político (NLP - Sentiment Analysis):** Se procesaron textos como se visualiza en la Figura 20 para cuantificar la incertidumbre regulatoria, validando el uso de minería de texto para identificar riesgos del entorno externo, adicionalmente, al calcular la polaridad de los textos analizados se logra cuantificar el impacto y así se generan estrategias de mitigación basadas en datos.

## Figura 20

### Validación para identificar riesgos del entorno

```

--- [FASE IV] SUB-MOTOR DE INTELIGENCIA DE ENTORNO (NLP) ---

```

	Noticia	Sentimiento	NIVEL_ALERTA	ACCION_GERENCIAL
0	El MinSalud anuncia nueva reforma que podría r...	-0.8	ALTO (CRÍTICO)	MITIGACIÓN INMEDIATA (Plan de Contingencia)
2	Protestas y bloqueos afectan la vía al llano, ...	-0.8	ALTO (CRÍTICO)	MITIGACIÓN INMEDIATA (Plan de Contingencia)
4	Incertidumbre en el sector salud por cambio de...	-0.8	ALTO (CRÍTICO)	MITIGACIÓN INMEDIATA (Plan de Contingencia)
5	Escasez de insumos médicos preocupa a gremios ...	-0.8	ALTO (CRÍTICO)	MITIGACIÓN INMEDIATA (Plan de Contingencia)

### 8.7.4. Soporte a la decisión y retroalimentación (Validación de Fases V y VI)

Salida Gerencial: La ejecución finaliza con la generación de un "Tablero de Control" simulado (ver Figura 21). Las alertas emitidas por el código (por ejemplo: "alerta roja en resonancia magnética") coinciden con la columna de "Acción gerencial sugerida" del Framework, demostrando que los datos procesados se traducen en instrucciones claras para la mitigación.

## Figura 21

### Tablero de control de riesgos

```

=====
          FASE V: TABLERO DE CONTROL DE RIESGOS
=====
1. RIESGO POLÍTICO: 4 alertas críticas detectadas.
   -> Acción: Revisar liquidez ante posibles retrasos regulatorios.
2. INFRAESTRUCTURA: Alerta Roja en Resonancia Magnética.
   -> Acción: Programar técnico de mantenimiento HOY.
3. PROVEEDORES: Segmentación completada.
   -> Acción: Renegociar con proveedores del Clúster de bajo desempeño.
=====

```

Cierre del Ciclo: El código incluye un paso final que simula el almacenamiento de los resultados validados (ver Figura 22). Esto confirma la viabilidad técnica de la Fase VI, donde el sistema se retroalimenta para calibrar futuros modelos y reducir la incertidumbre a largo plazo.

## Figura 22

### *Retroalimentación*

```

=====
          FASE VI: RETROALIMENTACIÓN (FEEDBACK LOOP)
=====
[SISTEMA]: Guardando incidentes validados (Fallas Reales vs Predichas) en BD Histórica...
[SISTEMA]: Ejecutando rutina de calibración de modelos...
[SISTEMA]: El modelo 'Isolation Forest' ha actualizado sus umbrales con los nuevos datos.
✅ VALIDACIÓN DEL FRAMEWORK COMPLETADA EXITOSAMENTE.

```

## 9. Conclusiones

El COVID-19 funcionó como un punto de inflexión que obligó a los sistemas de salud a adoptar tecnologías emergentes para sobrevivir a la incertidumbre. Se observó un aumento significativo en la producción intelectual y en la aplicación de modelos matemáticos y de simulación para manejar la demanda de recursos críticos y la distribución de vacunas. En este contexto, se validó el uso de modelos de aprendizaje profundo (como redes LSTM) para pronosticar demandas hospitalarias y expansión de brotes en tiempo real, superando a los métodos estadísticos tradicionales en contextos de alta volatilidad. Evidenciando que no solo se trata de reaccionar ante las interrupciones de la CSH, sino de desarrollar capacidades predictivas transformando la gestión tradicional a una “inteligencia del riesgo” que permita identificar, medir, y predecir amenazas utilizando datos históricos y experiencia.

Mediante la revisión se puede concluir cuáles son las técnicas más efectivas según el tipo de riesgo abordado:

- Machine Learning (ML): Algoritmos como Random Forest, XGBoost y SVM son los más utilizados para clasificación de riesgos y predicción de eventos (como errores de medicación o caídas) debido a su alto rendimiento.
- Procesamiento de Lenguaje Natural: Existe una tendencia creciente a explotar datos no estructurados (notas clínicas, reportes de incidentes, redes sociales) para detectar riesgos que los sistemas estructurados ignoran.
- Minería de Procesos: Se destaca como una técnica clave para identificar cuellos de botella y desviaciones en los protocolos clínicos, mejorando la eficiencia operativa.

Mediante minería de texto se logró construir una base teoría sólida analizando 244 artículos científicos, para luego validarla y contextualizarla con la realidad colombiana mediante el análisis de 1.427 noticias, lo que permitió estructurar una clasificación jerárquica robusta que divide los riesgos de la CSH en dos grandes ramas: riesgos de interrupción (eventos con alto impacto y baja frecuencia) y riesgos operativos (perturbaciones diarias). Esta estructura derivó en 8 tipos de riesgos específicos: De origen natural, producidos por el hombre, sanitarios, políticos, de oferta y demanda, gestión de datos, de proceso y financieros; esta categorización no es estática; los factores no son independientes y pueden desencadenar "reacciones en cadena", donde un evento (como por ejemplo un desastre natural) impacta múltiples eslabones de la cadena.

El análisis de noticias online reveló las preocupaciones más urgentes del sector salud en Colombia, los términos más frecuentes en las noticias, como "desabastecimiento", "medicamentos", "deuda" y "crisis", evidencian que los riesgos financieros y de oferta/demanda son los más prevalentes en la discusión pública nacional. Adicionalmente, la correlación de la palabra "riesgo" con términos climáticos como "heladas" e "inundaciones" en las noticias locales resalta la vulnerabilidad de la infraestructura logística colombiana ante factores climáticos.

El proyecto formuló con éxito un modelo de decisión multicriterio híbrido para la gestión de riesgos en la cadena de suministro hospitalaria en Colombia. La integración secuencial de las metodologías AHP y TOPSIS demostró ser una estrategia robusta, permitiendo descomponer la complejidad del problema en factores medibles. La validación del modelo quedó demostrada matemáticamente a través del Índice de Consistencia (CR) del AHP, el cual se mantuvo por debajo del umbral del 0.10, confirmando que los juicios de los expertos fueron lógicos, coherentes y libres de contradicciones significativas. El análisis jerárquico reveló un cambio de paradigma en la percepción del riesgo dentro del sector salud colombiano. Contrario a la creencia tradicional de que el "Impacto" es el factor dominante, los resultados mostraron una preponderancia decisiva del criterio "Detectabilidad", al cual los expertos asignaron un peso aproximado del 70%, superando ampliamente a la Probabilidad (~20%) y al Impacto (~10%). Esto concluye que, para los gestores de la cadena de suministro hospitalaria, la mayor vulnerabilidad no reside necesariamente en la severidad del evento, sino en la incapacidad de los sistemas actuales para identificar y monitorear las amenazas a tiempo. La aplicación del algoritmo TOPSIS permitió generar un ranking priorizado de los riesgos, arrojando resultados concluyentes sobre la realidad operativa en Colombia.

Con la construcción del Framework, se logró diseñar una arquitectura holística que supera la desconexión tradicional entre la planeación estratégica y la gestión de datos operativos. Herramientas cualitativas como las matrices AVES, AVIP y AFOR no son elementos aislados, sino que constituyen la fuente primaria de metadatos de riesgo. Al transformar estos análisis estratégicos en insumos para el Risk Data Warehouse, el Framework garantiza que la "inteligencia

del riesgo" esté alineada con el contexto real de la institución y no solo basada en históricos transaccionales.

La incorporación del módulo de evaluación y priorización validó la importancia de aplicar métodos de Decisión Multicriterio (MCDM) como paso intermedio de "triage" o filtrado. Mediante la validación se demostró que discriminar los riesgos en niveles (Crítico, Moderado y Aceptable) permite optimizar los recursos computacionales y gerenciales, dirigiendo los algoritmos de Minería de Datos más complejos y costosos únicamente hacia las amenazas que comprometen la continuidad operativa, evitando la saturación por falsos positivos o eventos triviales.

La prueba de concepto realizada mediante simulación computacional confirmó la viabilidad técnica de traducir problemas de gestión de riesgo en tareas de Minería de Datos, tal como se propuso en la Tabla 20. Los resultados obtenidos evidenciaron que: El algoritmo Isolation Forest fue eficaz para incrementar la detectabilidad en infraestructura, identificando anomalías (fallas inminentes) antes de que se materialicen. Las técnicas de Procesamiento de Lenguaje Natural demostraron ser capaces de cuantificar la incertidumbre del entorno externo (riesgo político/regulatorio) a partir de datos no estructurados. Por último, el agrupamiento mediante K-Means permitió segmentar proveedores exitosamente, transformando datos planos de desempeño en perfiles de riesgo accionables.

El Framework propuesto facilita una transición fundamental en la gestión del riesgo hospitalario, pasando de un enfoque reactivo (gestión del impacto) a uno proactivo basado en la detectabilidad. Al integrar fuentes de datos híbridas (estructuradas y no estructuradas) y algoritmos predictivos, el sistema proporciona alertas tempranas y soporte a la decisión, permitiendo a los gestores activar planes de mitigación (reabastecimiento preventivo, mantenimiento anticipado)

antes de que la cadena de suministro sufra rupturas. Finalmente, la inclusión de la Fase VI (Monitoreo y Aprendizaje) asegura la sostenibilidad del Framework en el tiempo, confirmando que un sistema de gestión de riesgos no es estático; la capacidad de retroalimentar el almacén de datos con los resultados de las predicciones (validación de falsos positivos/negativos) permite el reentrenamiento de los modelos. Esto otorga a la institución de una herramienta evolutiva que "aprende" de su propia operación, reduciendo progresivamente la incertidumbre y aumentando la resiliencia de la cadena de suministro hospitalaria frente a entornos inciertos.

## **10. Recomendaciones**

Se recomienda validar el Framework en un entorno hospitalario real. Esto permitiría contrastar los resultados de los algoritmos con la operación diaria, permitiendo ajustar los modelos de MD según el comportamiento de una institución de salud.

Para hospitales públicos con sistemas digitales básicos se sugiere simplificar la metodología del Framework manteniendo las bases de inteligencia del riesgo.

Para fortalecer la representatividad y validez del modelo (AHP-TOPSIS), se propone ampliar la base de expertos consultados. Futuras investigaciones podrían incluir una muestra más diversa que incluya: gestores de hospitales públicos, actores de entes reguladores y gubernamentales, y personal de todos los eslabones de la CSH.

Se sugiere desarrollar protocolos específicos para el reentrenamiento automatizado de los modelos. La investigación futura debería centrarse en cómo la retroalimentación de los falsos positivos y negativos puede integrarse de manera autónoma en el Framework, asegurando que la herramienta evolucione a la par de la volatilidad del entorno sanitario colombiano.

**Referencias bibliográficas**

- Abbas, K., Afaq, M., Khan, T. A., & Song, W. C. (2020a). A blockchain and machine learning-based drug supply chain management and recommendation system for smart pharmaceutical industry. *Electronics (Switzerland)*, *9*(5), 1–31. <https://doi.org/10.3390/electronics9050852>
- Abbasi, B., Babaei, T., Hosseini-fard, Z., Smith-Miles, K., & Dehghani, M. (2020). Predicting solutions of large-scale optimization problems via machine learning: A case study in blood supply chain management. *Computers and Operations Research*, *119*, 104941. <https://doi.org/10.1016/j.cor.2020.104941>
- Abukhousa, E., Al-Jaroodi, J., Lazarova-Molnar, S., & Mohamed, N. (2014). Simulation and modeling efforts to support decision making in healthcare supply chain management. *The Scientific World Journal*, *2014*. <https://doi.org/10.1155/2014/354246>
- Adel, H. M., Khaled, M., Yehya, M. A., Elsayed, R., Ali, R. S., & Ahmed, F. E. (2024). Nexus among artificial intelligence implementation, healthcare social innovation, and green image of hospitals' operations management in Egypt. *Cleaner Logistics and Supply Chain*, *11*. <https://doi.org/10.1016/j.clscn.2024.100156>
- Akcan, S., & Güldeş, M. (2019). Integrated Multicriteria Decision-Making Methods to Solve Supplier Selection Problem: A Case Study in a Hospital. *Journal of Healthcare Engineering*, *2019*. <https://doi.org/10.1155/2019/5614892>
- Alswailem, O. A., Horanieh, B. K., Alabbad, A., Almuhaideb, S., Almuhanha, A., Alquaid, M., Elmoaqet, H., Abuzied, N., & Abusalah, A. (2021). Covid-19 intelligence-driven operational response platform: Experience of a large tertiary multihospital system in the middle east. *Diagnostics*, *11*(12). <https://doi.org/10.3390/diagnostics11122283>

ArcGIS. (2021). *Desastres Naturales En Colombia*, ArcGIS.  
<https://www.arcgis.com/apps/MapTour/index.html?appid=4f811859b56f492d94cb879d43b853da#info>

Artemova, S., Von Schenck, U., Fa, R., Stoessel, D., Nowparast Rostami, H., Madiot, P. E., Januel, J. M., Pagonis, D., Landelle, C., Gallouche, M., Cancé, C., Olive, F., Moreau-Gaudry, A., Prieur, S., & Bosson, J. L. (2023). Cohort profile for development of machine learning models to predict healthcare-related adverse events (Demeter): clinical objectives, data requirements for modelling and overview of data set for 2016-2018. *BMJ Open*, *13*(8).  
<https://doi.org/10.1136/bmjopen-2022-070929>

Atek, S., Bianchini, F., De Vito, C., Cardinale, V., Novelli, S., Pesaresi, C., Eugeni, M., Mecella, M., Rescio, A., Petronzio, L., Vincenzi, A., Pistillo, P., Giusto, G., Pasquali, G., Alvaro, D., Villari, P., Mancini, M., & Gaudenzi, P. (2023). A predictive decision support system for coronavirus disease 2019 response management and medical logistic planning. *Digital Health*, *9*. <https://doi.org/10.1177/20552076231185475>

Balan, S., & Conlon, S. (2018). Text analysis of green supply chain practices in healthcare. *Journal of Computer Information Systems*, *58*(1), 30–38.  
<https://doi.org/10.1080/08874417.2016.1180654>

Baltas, K., Jayasekera, R., Uddin, G. S., & Papadopoulos, T. (2022). The role of resource orchestration in humanitarian operations: a COVID-19 case in the US healthcare. *Annals of Operations Research*. <https://doi.org/10.1007/s10479-022-04963-2>

Bammer, R., & Amukotuwa, S. A. (2022). Navigating Supply Chain Disruptions of Iodinated Contrast Agent for Neuroimaging and How Business Intelligence Can Help the Decision

Process. *American Journal of Neuroradiology*, 43(7), 944–950.  
<https://doi.org/10.3174/ajnr.A7544>

Bas, T. G., Astudillo, P., Rojo, D., & Trigo, A. (2023). Opinions Related to the Potential Application of Artificial Intelligence (AI) by the Responsible in Charge of the Administrative Management Related to the Logistics and Supply Chain of Medical Stock in Health Centers in North of Chile. *International Journal of Environmental Research and Public Health*, 20(6).  
<https://doi.org/10.3390/ijerph20064839>

BBC News. (2020a). *Coronavirus: cómo te puede afectar el desplome de las monedas en América Latina por el covid-19 - BBC News Mundo*. <https://www.bbc.com/mundo/noticias-51775304>

BBC News. (2020b, April 3). *Coronavirus en Estados Unidos: la escasez de equipos médicos cruciales en el país más rico del mundo (y la “batalla” por hacerse con estos materiales) - BBC News Mundo*. <https://www.bbc.com/mundo/noticias-internacional-52115495>

Benzidia, S., Makaoui, N., & Bentahar, O. (2021). The impact of big data analytics and artificial intelligence on green supply chain process integration and hospital environmental performance. *Technological Forecasting and Social Change*, 165.  
<https://doi.org/10.1016/j.techfore.2020.120557>

Bhaskar, S., Tan, J., Bogers, M. L. A. M., Minssen, T., Badaruddin, H., Israeli-Korn, S., & Chesbrough, H. (2020a). At the Epicenter of COVID-19—the Tragic Failure of the Global Supply Chain for Medical Supplies. *Frontiers in Public Health*, 8(November), 1–9.  
<https://doi.org/10.3389/fpubh.2020.562882>

Bhaskar, S., Tan, J., Bogers, M. L. A. M., Minssen, T., Badaruddin, H., Israeli-Korn, S., & Chesbrough, H. (2020b). At the Epicenter of COVID-19—the Tragic Failure of the Global

- Supply Chain for Medical Supplies. *Frontiers in Public Health*, 8(November), 1–9.  
<https://doi.org/10.3389/fpubh.2020.562882>
- Brom, H., Margo Brooks Carthon, J., Ikeaba, U., & Chittams, J. (2020). Leveraging Electronic Health Records and Machine Learning to Tailor Nursing Care for Patients at High Risk for Readmissions. *Journal of Nursing Care Quality*, 35(1), 27–33.  
<https://doi.org/10.1097/NCQ.0000000000000412>
- Campos, A., Holm-Nielsen, N., Díaz, C., Rubiano, D. M., Costa, C. R., Ramírez, F., & Dickson, E. (2012). *Un aporte para la construcción de políticas públicas BANCO MUNDIAL COLOMBIA Coordinadores y editores Fondo Mundial para la Reducción y Recuperación de Desastres.*
- Casino, F., Dasaklis, T. K., & Patsakis, C. (2019). A systematic literature review of blockchain-based applications: Current status, classification and open issues. *Telematics and Informatics*, 36(November 2018), 55–81. <https://doi.org/10.1016/j.tele.2018.11.006>
- Castro Páez, H. Adrian., & Barreto Bernal, P. Carolina. (2022). *Dirección Estratégica Hospitalaria para IPS Públicas : Metodología para el Desarrollo de la Planeación y el Direccionamiento Estratégico.*
- Chang, V., Doan, L. M. T., Ariel Xu, Q., Hall, K., Anna Wang, Y., & Mustafa Kamal, M. (2023). Digitalization in omnichannel healthcare supply chain businesses: The role of smart wearable devices. *Journal of Business Research*, 156. <https://doi.org/10.1016/j.jbusres.2022.113369>
- Cho, K. J., Kim, J. S., Lee, D. H., Lee, S. -M, Song, M. J., Lim, S. Y., Cho, Y. J., Jo, Y. H., Shin, Y., & Lee, Y. J. (2023). Prospective, multicenter validation of the deep learning-based cardiac arrest risk management system for predicting in-hospital cardiac arrest or unplanned intensive

care unit transfer in patients admitted to general wards. *Critical Care*, 27(1).  
<https://doi.org/10.1186/s13054-023-04609-0>

Chu, C. Y., Park, K., & Kremer, G. E. (2020). A global supply chain risk management framework: An application of text-mining to identify region-specific supply chain risks. *Advanced Engineering Informatics*, 45. <https://doi.org/10.1016/j.aei.2020.101053>

De Micco, F., De Benedictis, A., Fineschi, V., Frati, P., Ciccozzi, M., Pecchia, L., Alloni, R., Petrosillo, N., Filippi, S., Ghilardi, G., Campanozzi, L. L., & Tambone, V. (2022). From syndemic lesson after covid-19 pandemic to a “systemic clinical risk management” proposal in the perspective of the ethics of job well done. *International Journal of Environmental Research and Public Health*, 19(1). <https://doi.org/10.3390/ijerph19010015>

Departamento Administrativo de la Función Pública, Myrian Cubillos Benavides, Sandra Patricia Avellaneda Avendaño, Eva Mercedes Rojas Valdés, & Damián Camilo Vargas Vargas. (2022). *Guía para la Administración del riesgo y el diseño de controles en entidades*. <https://www.funcionpublica.gov.co/documents/34645357/34702994/Guia-externa-administracion-riesgo-direccinamiento-estrategico-v6.pdf/0330fa64-0a6a-4772-887f-27aae325afa5?t=1685979801107>

EAE Business School. (2018). *Minería de datos en la cadena de suministro: gestionando la incertidumbre* | EAE. <https://retos-operaciones-logistica.eae.es/20664-2/>

EAE Business School. (2018, November 15). *Minería de datos y otros almacenes de la cadena de suministro* | EAE. <https://retos-operaciones-logistica.eae.es/mineria-de-datos-y-los-otros-almacenes-de-la-cadena-de-suministro/>

- El Herald. (2020, March 31). *Médicos denuncian falta de elementos e incertidumbre laboral en medio de crisis por coronavirus*. <https://www.elheraldo.co/colombia/medicos-denuncian-falta-de-elementos-e-incertidumbre-laboral-en-medio-de-crisis-por>
- Elangovan, D., Long, C. S., Bakrin, F. S., Tan, C. S., Goh, K. W., Yeoh, S. F., Loy, M. J., Hussain, Z., Lee, K. S., Idris, A. C., & Ming, L. C. (2022). The Use of Blockchain Technology in the Health Care Sector: Systematic Review. In *JMIR Medical Informatics* (Vol. 10, Number 1). JMIR Publications Inc. <https://doi.org/10.2196/17278>
- Er Kara, M., Oktay Fırat, S. Ü., & Ghadge, A. (2020). A data mining-based framework for supply chain risk management. *Computers and Industrial Engineering*, 139. <https://doi.org/10.1016/j.cie.2018.12.017>
- Erdogan, T. G., & Tarhan, A. (2018). Systematic Mapping of Process Mining Studies in Healthcare. *IEEE Access*, 6, 24543–25567. <https://doi.org/10.1109/ACCESS.2018.2831244>
- E.S.E HUS. (2018). *Plan hospitalario de emergencias*.
- Farrokhizadeh, E., Seyfi-Shishavan, S. A., & Satoglu, S. I. (2021). Blood supply planning during natural disasters under uncertainty: a novel bi-objective model and an application for red crescent. In *Annals of Operations Research* (Number 0123456789). Springer US. <https://doi.org/10.1007/s10479-021-03978-5>
- Fayyad, U., Piatetsky-Shapiro, G., & Smyth, P. (1996). From Data Mining to Knowledge Discovery in Databases. *IA MAGAZINE*, 9078(3), 637–648. <https://doi.org/10.1609/aimag.v17i3.1230>

- Feelders, A., Daniels, H., & Holsheimer, M. (2000). *Methodological and Practical Aspects of Data Mining in the Product Development Process*. 37, 271–281. [http://www.value-eng.org/knowledge\\_bank/attachments/Data Mining in Product Development Process.pdf](http://www.value-eng.org/knowledge_bank/attachments/Data Mining in Product Development Process.pdf)
- Fermont, I. (2019). Pharmacovigilance strategy: Opportunities for cross-national learning. In *Israel Journal of Health Policy Research* (Vol. 8, Number 1). BioMed Central Ltd. <https://doi.org/10.1186/s13584-019-0319-3>
- Ferrara, M., Bertozzi, G., Di Fazio, N., Aquila, I., Di Fazio, A., Maiese, A., Volonnino, G., Frati, P., & La Russa, R. (2024). Risk Management and Patient Safety in the Artificial Intelligence Era: A Systematic Review. In *Healthcare (Switzerland)* (Vol. 12, Number 5). Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/healthcare12050549>
- Ghaithan, A. M., Alarfaj, I., Mohammed, A., & Qasim, O. (2022). A neural network-based model for estimating the delivery time of oxygen gas cylinders during COVID-19 pandemic. *Neural Computing and Applications*, 34(13), 11213–11231. <https://doi.org/10.1007/s00521-022-07037-3>
- Ghaleb, E. A. A., Dominic, P. D. D., Singh, N. S. S., & Naji, G. M. A. (2023). Assessing the Big Data Adoption Readiness Role in Healthcare between Technology Impact Factors and Intention to Adopt Big Data. *Sustainability (Switzerland)*, 15(15). <https://doi.org/10.3390/su151511521>
- Giraldo Villada, J. A., & Perilla Aristizabal, F. A. (2016). *Procesos logísticos internos en la cadena de Suministros Hospitalaria: enfoque en la Sala de operaciones*. 1–14. [https://repository.unicatolica.edu.co/bitstream/handle/20.500.12237/1154/PROCESOS\\_LO](https://repository.unicatolica.edu.co/bitstream/handle/20.500.12237/1154/PROCESOS_LO)

GÍSTICOS\_INTERNOS\_CADENA\_SUMINISTROS\_HOSPITALARIA\_ENFOQUE\_SA  
LA\_OPERACIONES.pdf?sequence=1&isAllowed=y

Guerra, R. (2024). Enhancing risk management in hospitals: leveraging artificial intelligence for improved outcomes. *Italian Journal of Medicine*, 18(2). <https://doi.org/10.4081/itjm.2024.1721>

Han, W., Wang, S., & Gao, J. (2022). Application of Data Mining Technology-Based Nursing Risk Management in Emergency Department Care. *Mathematical Problems in Engineering*, 2022. <https://doi.org/10.1155/2022/2561072>

Härkänen, M., Haatainen, K., Vehviläinen-Julkunen, K., & Miettinen, M. (2021). Artificial intelligence for identifying the prevention of medication incidents causing serious or moderate harm: An analysis using incident reporters' views. *International Journal of Environmental Research and Public Health*, 18(17). <https://doi.org/10.3390/ijerph18179206>

Hernández Orallo, J., Ramírez Quintana, M. J., & Ferri Ramírez, C. (2004). *Introducción a la minería de datos*. Pearson.

Hofmann, E. (2017). Big data and supply chain decisions: the impact of volume, variety and velocity properties on the bullwhip effect. *International Journal of Production Research*, 55(17), 5108–5126. <https://doi.org/10.1080/00207543.2015.1061222>

Hwang, C. L., Paidy, S. R., Yoon, K., & Masud, A. S. M. (1980). Mathematical programming with multiple objectives: A tutorial. *Computers & Operations Research*, 7(1–2), 5–31. [https://doi.org/10.1016/0305-0548\(80\)90011-8](https://doi.org/10.1016/0305-0548(80)90011-8)

- Ivanov, D. (2020). Predicting the impacts of epidemic outbreaks on global supply chains: A simulation-based analysis on the coronavirus outbreak (COVID-19/SARS-CoV-2) case. *Transportation Research Part E: Logistics and Transportation Review*, 136(March), 101922. <https://doi.org/10.1016/j.tre.2020.101922>
- Jbaily, A., Feldhaus, I., Bigelow, B., Kamareddine, L., Tolla, M. T., Bouvier, M., Kiros, M., & Verguet, S. (2020). Toward health system strengthening in low- And middle-income countries: Insights from mathematical modeling of drug supply chains. *BMC Health Services Research*, 20(1), 1–12. <https://doi.org/10.1186/s12913-020-05549-z>
- Kamali, A. H., Taleizadeh, A. A., & Toloo, M. (2024). A novel approach to optimize an integrated network design and pricing of a healthcare supply chain. *Expert Systems with Applications*, 252. <https://doi.org/10.1016/j.eswa.2024.123976>
- Kamran, M. A., Kia, R., Goodarzian, F., & Ghasemi, P. (2023). A new vaccine supply chain network under COVID-19 conditions considering system dynamic: Artificial intelligence algorithms. *Socio-Economic Planning Sciences*, 85. <https://doi.org/10.1016/j.seps.2022.101378>
- Koç, E., & Türkoğlu, M. (2021). Forecasting of medical equipment demand and outbreak spreading based on deep long short-term memory network: the COVID-19 pandemic in Turkey. *Signal, Image and Video Processing*, (0123456789). <https://doi.org/10.1007/s11760-020-01847-5>
- Le, D. Van, Montgomery, J., Kirkby, K. C., & Scanlan, J. (2018). Risk prediction using natural language processing of electronic mental health records in an inpatient forensic psychiatry

setting. *Journal of Biomedical Informatics*, 86, 49–58.  
<https://doi.org/10.1016/j.jbi.2018.08.007>

León, E. (2021, April 11). *Norte de Santander ha invertido 67.000 millones de pesos en migrantes* | *RCN Radio*. RCN Radio. <https://www.rcnradio.com/colombia/santanderes/deuda-por-atencion-migrantes-en-norte-de-santander-asciende-67000-millones-de>

Leung, N. H. Z., Chen, A., Yadav, P., & Gallien, J. (2016). The impact of inventory management on stock-outs of essential drugs in sub-Saharan Africa: Secondary analysis of a field experiment in Zambia. *PLoS ONE*, 11(5), 1–18.  
<https://doi.org/10.1371/journal.pone.0156026>

Li, J., Xu, Q., Shah, N., & Mackey, T. K. (2019). A machine learning approach for the detection and characterization of illicit drug dealers on instagram: Model evaluation study. *Journal of Medical Internet Research*, 21(6). <https://doi.org/10.2196/13803>

Liu, J., Wong, Z. S. Y., So, H. Y., & Tsui, K. L. (2021). Evaluating resampling methods and structured features to improve fall incident report identification by the severity level. *Journal of the American Medical Informatics Association*, 28(8), 1756–1764.  
<https://doi.org/10.1093/jamia/ocab048>

Lorenzoni, G., Rampazzo, R., Buratin, A., Berchiolla, P., & Gregori, D. (2021). Does the integration of pre-coded information with narratives improve in-hospital falls' surveillance? *Applied Sciences (Switzerland)*, 11(10). <https://doi.org/10.3390/app11104406>

Lucero, R. J., Lindberg, D. S., Fehlberg, E. A., Bjarnadottir, R. I., Li, Y., Cimiotti, J. P., Crane, M., & Prospero, M. (2019). A data-driven and practice-based approach to identify risk factors associated with hospital-acquired falls: Applying manual and semi- and fully-automated

- methods. *International Journal of Medical Informatics*, 122, 63–69.  
<https://doi.org/10.1016/j.ijmedinf.2018.11.006>
- Ma, H., Sheng, W., Li, J., Hou, L., Yang, J., Cai, J., Xu, W., & Zhang, S. (2021). A novel hierarchical machine learning model for hospital-acquired venous thromboembolism risk assessment among multiple-departments. *Journal of Biomedical Informatics*, 122.  
<https://doi.org/10.1016/j.jbi.2021.103892>
- Malmir, B., & Zobel, C. W. (2021). An applied approach to multi-criteria humanitarian supply chain planning for pandemic response. *Journal of Humanitarian Logistics and Supply Chain Management*. <https://doi.org/10.1108/JHLSCM-08-2020-0064>
- Mansoori, S., Bozorgi-Amiri, A., & Pishvaei, M. S. (2020). A robust multi-objective humanitarian relief chain network design for earthquake response, with evacuation assumption under uncertainties. *Neural Computing and Applications*, 32(7), 2183–2203.  
<https://doi.org/10.1007/s00521-019-04193-x>
- Marbough, D., Khaleel, I., Shanqiti, K. Al, Tamimi, M. Al, Simsekler, M. C. E., Ellahham, S., Alibazoglu, D., & Alibazoglu, H. (2020). Evaluating the impact of patient no-shows on service quality. *Risk Management and Healthcare Policy*, 13, 509–517.  
<https://doi.org/10.2147/RMHP.S232114>
- Ministerio de Salud, OPS, & OMS. (2017). *Guía Hospitalaria para la Gestión del Riesgo de Desastres*. 39–89.  
<https://www.minsalud.gov.co/sites/rid/Lists/BibliotecaDigital/RIDE/DE/GT/guia-hospitalaria-gestion-riesgo-desastres.pdf>

- Ministerio de Salud y Protección Social. (2020a). *El reto del covid-19 para los sistemas de salud en el mundo*. <https://www.minsalud.gov.co/Paginas/El-reto-del-covid-19-para-los-sistemas-de-salud-en-el-mundo.aspx>
- Ministerio de Salud y Protección Social. (2020b, December 30). *Colombia adelanta reabastecimiento de medicamentos para atención en UCI*. <https://www.minsalud.gov.co/Paginas/Colombia-adelanta-reabastecimiento-de-medicamentos-para-atencion-en-UCI.aspx>
- Moosivand, A., Rangchian, M., Zarei, L., Peiravian, F., Mehralian, G., & Sharifnia, H. (2021). An application of multi-criteria decision-making approach to sustainable drug shortages management: evidence from a developing country. *Journal of Pharmaceutical Health Care and Sciences*, 7(1), 1–11. <https://doi.org/10.1186/s40780-021-00200-3>
- Munawar, H. S., Mojtahedi, M., Hammad, A. W. A., Ostwald, M. J., & Waller, S. T. (2022). An AI/ML-Based Strategy for Disaster Response and Evacuation of Victims in Aged Care Facilities in the Hawkesbury-Nepean Valley: A Perspective. *Buildings*, 12(1). <https://doi.org/10.3390/buildings12010080>
- Nakatani, H., Nakao, M., Uchiyama, H., Toyoshiba, H., & Ochiai, C. (2020). Predicting inpatient falls using natural language processing of nursing records obtained from Japanese electronic medical records: Case-control study. *JMIR Medical Informatics*, 8(4). <https://doi.org/10.2196/16970>
- Namba, T., & Yamada, Y. (2018). Risks of deep reinforcement learning applied to fall prevention assist by autonomous mobile robots in the hospital. *Big Data and Cognitive Computing*, 2(2), 1–14. <https://doi.org/10.3390/bdcc2020013>

- Ong, M. S., Magrabi, F., & Coiera, E. (2012). Automated identification of extreme-risk events in clinical incident reports. *Journal of the American Medical Informatics Association*, *19*(E1). <https://doi.org/10.1136/amiajnl-2011-000562>
- Ortiz-Barrios, M., Arias-Fonseca, S., Ishizaka, A., Barbati, M., Avendaño-Collante, B., & Navarro-Jiménez, E. (2023). Artificial intelligence and discrete-event simulation for capacity management of intensive care units during the Covid-19 pandemic: A case study. *Journal of Business Research*, *160*. <https://doi.org/10.1016/j.jbusres.2023.113806>
- Ozdemir, D., Sharma, M., Dhir, A., & Daim, T. (2022). Supply chain resilience during the COVID-19 pandemic. *Technology in Society*, *68*. <https://doi.org/10.1016/j.techsoc.2021.101847>
- Ozgulbas, N., & Koyuncugil, A. S. (2009). Financial profiling of public hospitals: An application by data mining. *International Journal of Health Planning and Management*, *24*(1), 69–83. <https://doi.org/10.1002/hpm.883>
- Pall, R., Gauthier, Y., Auer, S., & Mowaswes, W. (2023). Predicting drug shortages using pharmacy data and machine learning. *Health Care Management Science*, *26*(3), 395–411. <https://doi.org/10.1007/s10729-022-09627-y>
- Papadopoulos, T., Gunasekaran, A., Dubey, R., Altay, N., Childe, S. J., & Fosso-Wamba, S. (2017). The role of Big Data in explaining disaster resilience in supply chains for sustainability. *Journal of Cleaner Production*, *142*, 1108–1118. <https://doi.org/10.1016/j.jclepro.2016.03.059>
- Ponce, P., Mata, O., Perez, E., Lopez, J. R., Molina, A., & McDaniel, T. (2022). S4 Features and Artificial Intelligence for Designing a Robot against COVID-19—Robocov. *Future Internet*, *14*(1). <https://doi.org/10.3390/fi14010022>

- Pourghasemi, H. R., Amiri, M., Edalat, M., Ahrari, A. H., Panahi, M., Sadhasivam, N., & Lee, S. (2021). Assessment of Urban Infrastructures Exposed to Flood Using Susceptibility Map and Google Earth Engine. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, *14*, 1923–1937. <https://doi.org/10.1109/JSTARS.2020.3045278>
- Power, D. J. (2016). Data science: supporting decision-making. *Journal of Decision Systems*, *25*(4), 345–356. <https://doi.org/10.1080/12460125.2016.1171610>
- Prensa Presidencia, U. (2024, December 27). *Informe emergencias 2024*. <https://www.presidencia.gov.co/prensa/Paginas/En-2024-se-registraron-mas-de-9000-emergencias-por-fenomenos-naturales-la-mayoria-incendios-forestales-241227.aspx>
- Ranjbar, A., Mork, E. W., Ravn, J., Brøgger, H., Myrseth, P., Østrem, H. P., & Hallock, H. (2024). Managing Risk and Quality of AI in Healthcare: Are Hospitals Ready for Implementation? *Risk Management and Healthcare Policy*, *17*, 877–882. <https://doi.org/10.2147/RMHP.S452337>
- Rastegar, M., Tavana, M., Meraj, A., & Mina, H. (2020). *An inventory-location optimization model for equitable influenza vaccine distribution in developing countries during the COVID-19 pandemic*. (January).
- Rathore, N., Jain, P. K., & Parida, M. (2022). A Sustainable Model for Emergency Medical Services in Developing Countries: A Novel Approach Using Partial Outsourcing and Machine Learning. *Risk Management and Healthcare Policy*, *15*, 193–218. <https://doi.org/10.2147/RMHP.S338186>
- Saaty, R. W. (1987). *THE ANALYTIC HIERARCHY PROCESS-WHAT IT IS AND HOW IT IS USED* (Vol. 9, Number 5).

- Samaras, A., Bekiaridou, A., Papazoglou, A. S., Moysidis, D. V., Tsoumakas, G., Bamidis, P., Tsigkas, G., Lazaros, G., Kassimis, G., Fragakis, N., Vassilikos, V., Zarifis, I., Tziakas, D. N., Tsioufis, K., Davlouros, P., & Giannakoulas, G. (2023). Artificial intelligence-based mining of electronic health record data to accelerate the digital transformation of the national cardiovascular ecosystem: Design protocol of the CardioMining study. *BMJ Open*, *13*(4). <https://doi.org/10.1136/bmjopen-2022-068698>
- Schoenherr, T., & Speier-Pero, C. (2015). Data science, predictive analytics, and big data in supply chain management: Current state and future potential. *Journal of Business Logistics*, *36*(1), 120–132. <https://doi.org/10.1111/jbl.12082>
- Selvakumar, S., Shahabudeen, P., & Paul Robert, T. (2019). An Analysis of Re-configured Blood Transfusion Network of Urban India to Improve the Service Level: a Simulation Approach. *Journal of Medical Systems*, *43*(2). <https://doi.org/10.1007/s10916-018-1141-0>
- Semana. (2019, August 17). *La migración venezolana golpea la salud colombiana*. <https://www.semana.com/nacion/articulo/consecuencias-en-salud-de-la-migracion-venezolana-en-colombia/628373/>
- Servicio Geológico Colombiano. (2020). *Evaluación y Monitoreo de Actividad Sísmica*. <https://www2.sgc.gov.co/ProgramasDeInvestigacion/geoamenazas/Paginas/actividad-sismica.aspx>
- Shrestha, N., Shad, M. Y., Ulvi, O., Khan, M. H., Karamehic-Muratovic, A., Nguyen, U. S. D. T., Baghbanzadeh, M., Wardrup, R., Aghamohammadi, N., Cervantes, D., Nahiduzzaman, K. M., Zaki, R. A., & Haque, U. (2020). The impact of COVID-19 on globalization. *One Health*, *11*, 100180. <https://doi.org/10.1016/j.onehlt.2020.100180>

- Supeekit, T., Somboonwiwat, T., & Kritchanchai, D. (2016). DEMATEL-modified ANP to evaluate internal hospital supply chain performance. *Computers and Industrial Engineering*, *102*, 318–330. <https://doi.org/10.1016/j.cie.2016.07.019>
- Syahrir, I., Suparno, & Vanany, I. (2015). Healthcare and Disaster Supply Chain: Literature Review and Future Research. *Procedia Manufacturing*, *4*(December), 2–9. <https://doi.org/10.1016/j.promfg.2015.11.007>
- Toyabe, S. ichi. (2015). Characteristics of Inpatient Falls not Reported in an Incident Reporting System. *Global Journal of Health Science*, *8*(3), 17–25. <https://doi.org/10.5539/gjhs.v8n3p17>
- Trinh, V. Q. N., Zhang, S., Kovoor, J., Gupta, A., Chan, W. O., Gilbert, T., & Bacchi, S. (2023). The use of natural language processing in detecting and predicting falls within the healthcare setting: a systematic review. In *International Journal for Quality in Health Care* (Vol. 35, Number 4). Oxford University Press. <https://doi.org/10.1093/intqhc/mzad077>
- UNGRD . (2025, July 14). Más de 100 Mil Familias Afectadas Por Lluvias: UNGRD Urge Recursos y Activa Plan de Preparación Para El Segundo Semestre. <https://portal.gestiondelriesgo.gov.co/Paginas/Noticias/2025/Mas-de-100-mil-familias-afectadas-por-lluvias-UNGRD-urge-recursos-y-activa-plan-de-preparacion-para-el-segundo-semester.aspx>
- Universidad de los Andes. (2020). *Productos esenciales en medio de la cuarentena* | Uniandes. <https://uniandes.edu.co/es/noticias/salud-y-medicina/covid19-una-mirada-a-los-productos-y-servicios-esenciales>
- Văduva, L. L., Nedelcu, A. M., Stancu, D., Bălan, C., Purcărea, I. M., Gurău, M., & Cristian, D. A. (2023). Digital Technologies for Public Health Services after the COVID-19 Pandemic: A

Risk Management Analysis. *Sustainability (Switzerland)*, 15(4).  
<https://doi.org/10.3390/su15043146>

Vargas, V. B., De Oliveira Gomes, J., Fernandes, P. C., Vallejos, R. V., & De Carvalho, J. V. (2023). Influential Factors for Hospital Management Maturity Models in a post-Covid-19 scenario - Systematic Literature Review. In *Journal of Information Systems Engineering and Management* (Vol. 8, Number 1). IADITI? International Association for Digital Transformation and Technological Innovation. <https://doi.org/10.55267/iadt.07.12868>

Vervoort, D., Guetter, C. R., & Peters, A. W. (2021). Blockchain, health disparities and global health. In *BMJ Innovations* (Vol. 7, Number 2, pp. 506–514). BMJ Publishing Group.  
<https://doi.org/10.1136/bmjinnov-2021-000667>

Wagner, S. M., & Bode, C. (2006). An empirical investigation into supply chain vulnerability. *Journal of Purchasing and Supply Management*, 12(6 SPEC. ISS.), 301–312.  
<https://doi.org/10.1016/j.pursup.2007.01.004>

Wahbeh, A., Nasralah, T., Al-Ramahi, M., & El-Gayar, O. (2020). Mining physicians' opinions on social media to obtain insights into COVID-19: Mixed methods analysis. *JMIR Public Health and Surveillance*, 6(2), 1–10. <https://doi.org/10.2196/19276>

Wan, H. C., & Chin, K. S. (2021). Exploring internet of healthcare things for establishing an integrated care link system in the healthcare industry. *International Journal of Engineering Business Management*, 13. <https://doi.org/10.1177/18479790211019526>

Wang, Y., Coiera, E., & Magrabi, F. (2019). Using convolutional neural networks to identify patient safety incident reports by type and severity. *Journal of the American Medical Informatics Association*, 26(12), 1600–1608. <https://doi.org/10.1093/jamia/ocz146>

- Wang, Y., Coiera, E., & Magrabi, F. (2020). Can unified medical language system–based semantic representation improve automated identification of patient safety incident reports by type and severity? *Journal of the American Medical Informatics Association*, *27*(10), 1502–1509. <https://doi.org/10.1093/jamia/ocaa082>
- Wang, Y., Coiera, E., Runciman, W., & Magrabi, F. (2017). Using multiclass classification to automate the identification of patient safety incident reports by type and severity. *BMC Medical Informatics and Decision Making*, *17*(1). <https://doi.org/10.1186/s12911-017-0483-8>
- Wataya, T., Miura, A., Sakisuka, T., Fujiwara, M., Tanaka, H., Hiraoka, Y., Sato, J., Tomiyama, M., Nishigaki, D., Kita, K., Suzuki, Y., Kido, S., & Tomiyama, N. (2024). Comparison of natural language processing algorithms in assessing the importance of head computed tomography reports written in Japanese. *Japanese Journal of Radiology*, *42*(7), 697–708. <https://doi.org/10.1007/s11604-024-01549-9>
- Wong, Z. S. Y., So, H. Y., Kwok, B. S. C., Lai, M. W. S., & Sun, D. T. F. (2020). Medication-rights detection using incident reports: A natural language processing and deep neural network approach. *Health Informatics Journal*, *26*(3), 1777–1794. <https://doi.org/10.1177/1460458219889798>
- Wu, Y., Yu, X., Li, M., Zhu, J., Yue, J., Wang, Y., Man, Y., Zhou, C., Tong, R., & Wu, X. (2024). Risk prediction model based on machine learning for predicting miscarriage among pregnant patients with immune abnormalities. *Frontiers in Pharmacology*, *15*. <https://doi.org/10.3389/fphar.2024.1366529>

Zavvar Sabegh, M. H., Mohammadi, M., & Naderi, B. (2017). Multi-objective optimization considering quality concepts in a green healthcare supply chain for natural disaster response: neural network approaches. *International Journal of Systems Assurance Engineering and Management*, 8(s2), 1689–1703. <https://doi.org/10.1007/s13198-017-0645-1>