



Uso De Un Enfoque Híbrido Montecarlo-Neutrosófico Para Reducir Los Tiempos De Espera En La Atención Médica Rural.

Use of a Hybrid Monte Carlo-Neutrosophic Approach to Reduce Waiting Times in Rural Healthcare.

Erick Alfredo Saa-Litardo¹, Lorenzo Cevallos-Torres^{1,2}, Dayron Rumbaut-Rangel³

¹ Universidad Bolivariana Del Ecuador (Ube), Easaal@Ube.Edu.Ec,

² Universidad De Guayaquil, Ljcevallost@Ube.Edu.Ec

³ Universidad Bolivariana del Ecuador, Guayaquil, Ecuador, drumbautr@ube.edu.ec

RESUMEN

Reducir las estancias hospitalarias y mejorar los sistemas de salud proporciona una base sólida para la toma de decisiones ante la ambigüedad. Los hospitales públicos aún enfrentan desafíos para implementar políticas que cumplan con los acuerdos de nivel de servicio (ANS) y hagan un uso eficiente de los recursos debido a las estancias prolongadas, la considerable imprevisibilidad en las llegadas/servicios y la insuficiencia de datos sobre la calidad percibida. Para mejorar la eficiencia, recortar gastos y evaluar la satisfacción del paciente, un centro de salud en una zona rural construye una simulación de Montecarlo. Se utiliza una capa neutrosófica para simular la incertidumbre y la indeterminación en la demanda, los tiempos de servicio y la satisfacción mediante las tripletas $\langle T, I, F \rangle$. La metodología detalla las variables, las distribuciones y el plan de muestra. Los tiempos de espera, la utilización, el rendimiento, el cumplimiento de los ANS y la satisfacción se miden en el experimento, que analiza las estrategias de enrutamiento interno y la asignación de recursos en escenarios estocásticos y neutrosóficos. Los resultados muestran que las decisiones operativas son más resilientes y pueden aplicarse a diversos entornos de atención médica cuando la evaluación neutrosófica se combina con Montecarlo.

Palabras Claves: Simulación de Montecarlo, Evaluación Neutrosófica, Toma de decisiones bajo incertidumbre, Reducción de tiempos de espera, Asignación de recursos en salud

ABSTRACT

Reducing hospital stays and improving healthcare systems provide a strong foundation for decision-making in the face of ambiguity. Public hospitals still face challenges in implementing policies that meet service level agreements (SLAs) and make efficient use of resources due to protracted stays, considerable unpredictability in arrivals/services, and insufficient perceived quality data. To improve efficiency, cut expenses, and gauge patient happiness, a healthcare facility in a rural area builds a Montecarlo simulation. A neutrosophic layer is used to simulate uncertainty and indeterminacy in demand, service times, and satisfaction using the triples $\langle T, I, F \rangle$. Methodology details the variables, distributions, and sample plan. Wait times, utilization, throughput, SLA compliance, and satisfaction are measured in the experiment, which analyzes internal routing strategies and resource allocation under stochastic and neutrosophic scenarios. The results show that operational decisions are more resilient and can be applied to various healthcare settings when neutrosophic evaluation is combined with Montecarlo.

Keywords: Montecarlo simulation, Neutrosophic evaluation, Decision-making under uncertainty, Waiting time reduction, Health resource allocation.

1. INTRODUCTION

Debido a la naturaleza crítica de la optimización de los procesos de atención médica, es necesario desarrollar instrumentos para convertir la incertidumbre médica en decisiones operativas fiables. En este proyecto, cada parámetro importante (demanda, tiempos de servicio y satisfacción) se representó

mediante los tripletes (T, I, F), combinando la simulación de Montecarlo con una capa neutrosófica. Gracias a esto, podemos registrar no solo la variación aleatoria, sino también la incertidumbre causada por datos confusos o faltantes. Reducir los tiempos de espera y los costos, aumentar la calidad percibida y mantener el cumplimiento de los SLA “Acuerdo de Nivel de Servicio” se puede lograr mediante el uso de esta técnica híbrida, que permite una evaluación rigurosa y trazable de la asignación de recursos y las políticas de enrutamiento interno en los centros de atención médica, incluso en entornos rurales. [1]

Además de proporcionar resiliencia a los cambios en la demanda o la información disponible, la combinación Montecarlo-neutrosófica facilita la realización de comparaciones justas entre soluciones comparables y facilita la comprensión de las fronteras de Pareto (costo-tiempo-calidad). Por lo tanto, la toma de decisiones clínicas y logísticas puede respaldarse con el marco sugerido, que proporciona una base metodológica sólida y fácil de transportar. El problema radica en que la satisfacción del paciente se mide con frecuencia con registros incompletos, y los centros médicos, en particular los de zonas públicas y rurales, suelen lidiar con largos tiempos de espera, tiempos de llegada impredecibles y heterogeneidad en los tiempos de servicio. En estas circunstancias, resulta difícil elegir políticas que, con recursos limitados, logren un equilibrio entre eficiencia y calidad. Resolvemos este problema simulando el sistema como una red interna de flujo y colas. [2, 3]

Para crear escenarios plausibles con datos de campo, utilizamos la transformada inversa junto con una distribución triangular. Los parámetros importantes que miden la veracidad, la indeterminación y la falsedad de la información se encapsulan en tripletes neutrosóficos (T, I, F). Se examinan el tiempo de espera, el uso, el rendimiento, la satisfacción y el cumplimiento del SLA, así como los efectos del enrutamiento interno, la dotación de personal por turnos y la prioridad (triaje). En resumen, el desafío radica en determinar, dados los datos disponibles y la falta de certeza, la combinación óptima de políticas para optimizar el rendimiento operativo y evitar comprometer la experiencia del paciente. [4]

En el contexto de esta investigación, la atención especializada y personalizada es un objetivo operativo que debe estar en consonancia con las cuatro características de la atención primaria de Barbara Starfield: accesibilidad y primer contacto, longitudinalidad, integralidad y coordinación. Un modelo híbrido de Montecarlo-neutrosófico las transforma en métricas útiles. Por consiguiente, el tiempo de reacción en el primer contacto y el cumplimiento del acuerdo de nivel de servicio operacionalizan la accesibilidad. La continuidad de la relación paciente-equipo, que incluye la frecuencia de la reprogramación planificada y la probabilidad de ver al mismo profesional, es una medida de longitudinalidad. El porcentaje de necesidades que se atienden sin derivar a los pacientes a recursos externos y el rendimiento por vía de atención son dos medidas de la integralidad. Los tiempos de transferencia entre departamentos, la tasa de éxito de las transferencias y la eficacia de la derivación interna son los últimos indicadores de coordinación. [10]

Los tripletes neutrosóficos (V, I, F) se utilizan para estudiar cada indicador con incertidumbre e indeterminación, lo que facilita la evaluación de la calidad de la evidencia y su impacto en la decisión. Nuestro análisis utiliza la simulación de Montecarlo [5] para determinar la distribución óptima de citas, prioridades y recursos en zonas rurales. Calculamos el impacto de estas variables en los tiempos de espera, la utilización de recursos, la satisfacción del paciente y los gastos. Incluso en casos de escasez o falta de datos, la base matemática de este marco para seleccionar la combinación de políticas que optimice la eficiencia y la calidad puede derivarse de la integración de información clínica valiosa con un sólido análisis operativo. [9]

En contraste, los sistemas de salud están cambiando de maneras que minimizan la satisfacción con los recursos invertidos y obstaculizan la justicia social o la equidad. El diagrama a continuación muestra datos como la tasa de llegada de pacientes (λ), la tasa de servicio (μ) del personal/equipo y la disciplina de atención (p. ej., FCFS o triaje prioritario). [11] El modelo de colas (M/M/1, M/M/c o G/G/1), definido por estas entradas, tiene como parámetro esencial la utilización $\rho = \lambda/c\mu$. El sistema se mantiene estable cuando ρ es menor que 1, pero las colas y los tiempos de espera aumentan a medida que se acerca a 1. Decisiones como el número de servidores (c), las reglas de prioridad y las regulaciones de asignación de franjas horarias se reflejan en este modelo desde una perspectiva operativa. La llegada, la espera, el servicio y la salida son los pasos del comportamiento dinámico de la cola en el que se transforma este bloque central según la demanda y la capacidad.



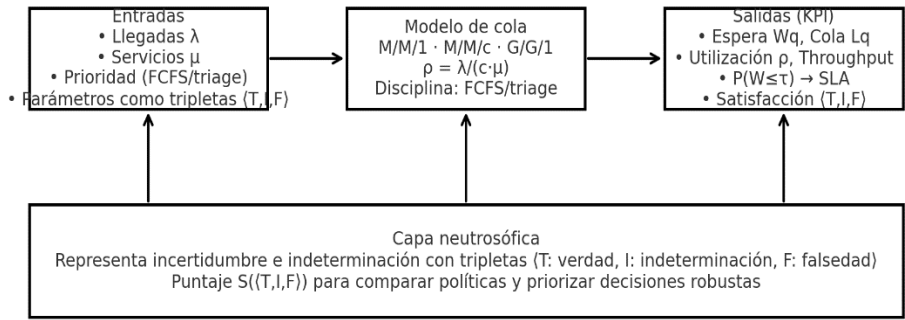


Figura 1. Teoría de colas y Aplicación Neutrosófica

Así, el modelo produce las siguientes métricas: tiempo de espera promedio (Wq), longitud de cola promedio (Lq), utilización (ρ), rendimiento y la probabilidad de alcanzar un umbral de tiempo $P(W \leq \tau)$, que está relacionado con el SLA; además, una medida de la satisfacción del paciente. Cuando se trata de parámetros e indicadores, la capa neutrosófica es como un triplete: T para el grado de verdad/apoyo de los datos, I para la indeterminación debido a datos incompletos o ruidosos, y F para el grado de falsedad/contradicción. Esta capa interactúa con todos los niveles. Las puntuaciones $S((T, I, F))$ permiten comparar políticas (p. ej., agregar un servidor, modificar el triaje) al castigar las soluciones que se basan en evidencia débil (I alta). Por lo tanto, λ , μ y los KPI no son enteros simples sino intervalos valorados por la incertidumbre y la indeterminación. Al proporcionar información al sistema, la capa neutrosófica guía la selección operativa más confiable al priorizar decisiones que disminuyen Wq y mejoran $U(W \leq \tau)$ con mejor robustez en situaciones donde falta información.

2. MATERIALES Y MÉTODOS

2.1 Método de Montecarlo

El método de Montecarlo es muy utilizado para la simulación de muestreos mediante algún algoritmo [6], se podrá simular con la ayuda de cualquier algoritmo probabilístico que existen actualmente y que son para cada situación y dependerá de cuál es el apropiado para la distribución que se empleará en la investigación. El método de Montecarlo es clasificado como un método de muestreo, porque las cantidades de entradas se generan aleatoriamente a partir de una función de densidad de probabilidad para simular el proceso de toma de muestras a partir de una población real.

$$\mu = EX \sim f\theta[g(X)] \tag{1}$$

en lugar de resolver la esperanza de forma analítica, simulamos N réplicas $X^{(1)}, \dots, X^{(N)} \sim f\theta$ y usamos el estimador de Montecarlo:

$$\hat{\mu}_N = \frac{1}{N} \sum_{n=1}^N g(X^{(n)}), \quad \text{Var}(\hat{\mu}_N) = \frac{\text{Var}(g(X))}{N}. \tag{2}$$

Por la LLN y el CLT, $\hat{\mu}_N \rightarrow \mu$ y un IC ~95% es:

$$\mu^N \pm 1.96 \frac{S_g}{\sqrt{N}} \tag{3}$$

Donde s_g^2 es la varianza muestral de $g(X^{(n)})$.

Para generar X se usan esquemas como transformada inversa, según la PDF/CDF $f\theta, F\theta$



Ejemplo (triangular $a < m < b$, muy usada en salud cuando hay pocos datos):

Si $U \sim U(0, 1)$ y $p = \frac{m-a}{b-a}$

$$f(x) = \frac{2}{b-a} \begin{cases} \frac{x-a}{m-a}, & a \leq x \leq m, \\ \frac{x-b}{m-b}, & m \leq x \leq b. \end{cases} \quad (4)$$

$$F^{-1}(\alpha) = x_\alpha = \begin{cases} a + \sqrt{\alpha(b-a)(m-a)} & 0 < \alpha \leq \frac{m-a}{b-a}, \\ b - \sqrt{(1-\alpha)(b-a)(b-m)}, & \frac{m-a}{b-a} < \alpha < 1, \end{cases} \quad (5)$$

2.2 Algoritmo de Montecarlo

El algoritmo de Montecarlo transforma la incertidumbre de entrada (llegadas λ , servicios μ) en millas de escenarios simulados, muestreando las distribuciones definidas (p. ej., triangular). En cada réplica ejecuta la lógica de colas (*FCFS/triage*) y calcula los KPI: espera, utilización, rendimiento y el cumplimiento $P(W \leq 15)$ del SLA.

Al repetir muchas veces, obtenemos la distribución empírica de cada KPI; la media estima el desempeño esperado y los percentiles cuantifican el riesgo. Por la Ley de los Grandes Números/CLT, las estimaciones convergen y permiten construir intervalos de confianza para decidir si el $SLA \geq 80\%$ se sostiene.

En el enfoque híbrido, además ponderamos parámetros y resultados con tripletas neutrosóficas $\langle T, I, F \rangle$, priorizando la política más robusta (p. ej., $c=3$ en horas pico).

ALGORITMO 1: Simulacion MonteCarlo

```

PROCEDIMIENTO FuncionMontecarlo (variable, num_datos)
  ABRIR archivo ← "lista.txt" MODO ESCRITURA
  ESCRIBIR archivo, "\n"
  PARA i ← 1 HASTA num_datos HACER
    r ← UNIFORME (0, 1) // número aleatorio en (0,1)
    x ← - LN(r) / variable // inversa: Exponencial (tasa = variable)
    IMPRIMIR x // mostrar con 12 decimales si se desea
    ESCRIBIR archivo, i, ":", x, "\n"
  FIN PARA
  CERRAR archivo
FIN PROCEDIMIENTO
PROCEDIMIENTO Inicio ()
  IMPRIMIR "Simulación Montecarlo"
  variable ← LEER_REAL ("Ingrese Variable:"). // tasa ( $\lambda$ ) > 0
  num_datos ← LEER_ENTERO ("Cantidad de datos a generar:")
  LLAMAR FuncionMontecarlo (variable, num_datos)
FIN PROCEDIMIENTO
INICIO
  LLAMAR Inicio ()
FIN

```

2.3 Modelo matemático para colas (GI/G/c, FCFS) con Montecarlo.

Para evaluar el flujo de pacientes bajo incertidumbre, utilizamos un modelo de colas GI/G/c con Monte Carlo, donde las inter llegadas y los tiempos de servicio siguen distribuciones generales, existen c servidores en paralelo y la disciplina es FCFS/triage sin interrupciones. Este enfoque muestrea A_i y S_i desde las distribuciones asumidas (p. ej., triangulares), construye los tiempos de llegada y servicio y actualiza recursivamente la disponibilidad de cada servidor para obtener esperas y salidas. Así evitamos las restricciones del M/M/c y estimamos el desempeño en contextos más realistas $\rho = \lambda / (c \mu_{ef}) < 1$.



Los KPI resultantes (Wq, Lq, ρ , throughput y $(W \leq \tau)$) permiten contrastar el SLA ($\leq 15 \text{ min}$ y $\geq 80\%$). Opcionalmente, una capa neutrosófica genera escenarios consistentes con tripletas $\langle T, I, F \rangle$ y un puntaje S para priorizar la política más robusta. [7]

Entradas: interlegadas $A_i \sim FA(\theta A)$, servicios $S_i \sim FS(\theta S)$, c servidores

Tiempos de llegada:

$$T_1 = A_1, \quad T_i = T_{i-1} + A_i$$

Disponibilidad de servidores: R_k = próximo tiempo libre del servidor k (inicial $R_k=0$).

Para el cliente i : el servidor elegido es $k^* = \arg \min_k R_k$

Inicio de servicio: $B_i = \max\{T_i, R_{k^*}\}$.

Espera individual: $W_i = B_i - T_i \geq 0$.

Fin de servicio: $D_i = B_i + S_i$, y actualizamos $R_{k^*} \leftarrow D_i$

Estimadores Monte Carlo (sobre N clientes): (tiempo ocupado del servidor k)

$$\hat{W}_q = \frac{1}{N} \sum_{i=1}^N W_i, \quad \hat{L}_q \approx \lambda_{\text{eff}} \hat{W}_q, \quad \hat{\rho} = \frac{1}{cH} \sum_{k=1}^c \quad (6)$$

2.4 Integración con Neutrosofía.

Antes de formular las ecuaciones, integramos Neutrosofía para capturar no solo la aleatoriedad, sino también la indeterminación y el conflicto de la evidencia (datos faltantes, mediciones ruidosas, opinión experta). Cada parámetro incierto del sistema de colas, p. ej., λ, μ , umbrales de triaje o incluso la satisfacción, se representa como una tripleta $\langle T, I, F \rangle$ que codifica grado de verdad/soporte, indeterminación y falsedad/contradicción. A partir de estas tripletas se generan escenarios consistentes (intervalos, pesos o mezclas) que alimentan la simulación Monte Carlo, propagando la indeterminación hacia los KPI ($Wq, Lq, \rho, P(W \leq \tau)$). Luego, un puntaje $S(\langle T, I, F \rangle)$ permite comparar y penalizar políticas que dependen de evidencia débil o contradictoria, priorizando decisiones robustas. Este andamiaje enlaza los resultados simulados con el SLA y prepara el terreno para las fórmulas de muestreo, agregación y evaluación neutrosóficas para priorizar la política más robusta [6].

Si $\theta = (\theta A, \theta S, \dots)$ es indeterminada, represéntala por tripletas $\langle T, I, F \rangle$ (verdad, indeterminación, falsedad). Practicamos un doble muestreo:

1. muestrear un escenario $\theta(s)$ consistente con $\langle T, I, F \rangle$ (intervalos/pesos),
2. correr la simulación y obtener $\mu^{\wedge}(s)$.
Agregamos con un **score** $S(\langle T, I, F \rangle)$ o reportamos bandas $[\min s\mu^{\wedge}(s), \max s\mu^{\wedge}(s)]$, priorizando políticas con buen desempeño y baja indeterminación.

3. ANÁLISIS DE RESULTADO

3.1 Caso de estudio (Centro de salud rural)

En un centro de salud rural se fijó un SLA: al menos 80% de los pacientes debe iniciar atención en ≤ 15 min. Para entender la incertidumbre en las operaciones, se modelaron las llegadas por hora como $\lambda \sim \text{Triangular}$ [5,6,7] y las tasas de servicio de cada profesional como $\mu \sim \text{Triangular}$ [3.6,4.0,4.4], con el sistema de atención FCFS/triage (sin interrupciones). Compararon dos dotaciones: *Política A* ($c = 2$) y *Política B* ($c = 3$). La calidad de datos se representó mediante tripletas neutrosóficas $\langle T, I, F \rangle$: modo $\langle 0.70, 0.20, 0.10 \rangle$, optimista $\langle 0.80, 0.15, 0.05 \rangle$ y pesimista $\langle 0.50, 0.30, 0.20 \rangle$. Para comparar políticas bajo indeterminación, se usó el score $S(\langle T, I, F \rangle) = T - F - 0.5I$ (modo = 0.50; optimista = 0.675; pesimista = 0.15). Con la simulación Montecarlo (escenarios según los percentiles de λ, μ) se calcularon los tiempos de espera, el cumplimiento del SLA y un indicador robusto $S \times P$ (SLA).

Datos

SLA: al menos 80% de los pacientes deben esperar ≤ 15 min para iniciar atención.

Llegadas por hora λ (incertidumbre rural) $\sim \text{Triangular}$ [5, 6, 7].

Tasa de servicio por servidor $\mu \sim \text{Triangular}$ [3.6, 4.0, 4.4] por hora.



Disciplina: FCFS/triage por urgencia (sin preemptivo).

Política A: $c = 2$ profesionales.

Política B: $c = 3$ profesionales.

Neutrosofía (calidad del dato por escenario):

Modo (más probable): $\langle T, I, F \rangle = \langle 0.70, 0.20, 0.10 \rangle$

Optimista: $\langle 0.80, 0.15, 0.05 \rangle$

Pesimista: $\langle 0.50, 0.30, 0.20 \rangle$

Score para comparar políticas: $S(\langle T, I, F \rangle) = T - F - 0.5 I$

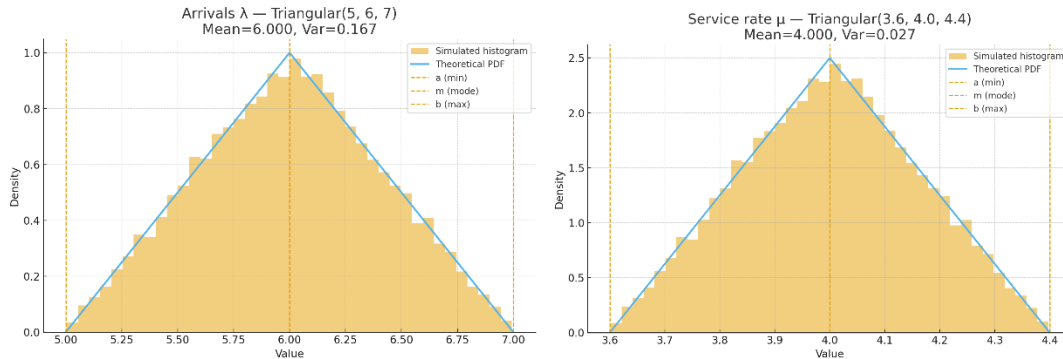


Figura 2. distribuciones triangulares con tasas de llegadas λ y servicio μ

Los resultados muestran que en el escenario modo la Política A alcanza $P(W \leq 15) = 0.610$ con espera media 19.3 min, mientras la Política B logra 0.947 con 2.4 min; el indicador robusto favorece a B (0.474 vs. 0.305). En el escenario pesimista (más demanda y menor servicio), A cae a 0.089 con esperas muy altas, y B mantiene 0.838; el robusto sigue favoreciendo a B (0.126 vs. 0.013). En el optimista, ambas cumplen (A 0.840, B 0.984), pero B conserva ventaja robusta (0.664 vs. 0.567). Conclusión: $c=3$ domina en cumplimiento de SLA y satisfacción; si el presupuesto es limitado, se recomienda activar $c=3$ en horas pico y mantener $c=2$ fuera de pico, o reforzar el triaje para urgencias. La capa neutrosófica permite priorizar decisiones que no solo rinden mejor, sino que siguen siendo confiables cuando la evidencia es incompleta.

Para un escenario con tasas λ, μ en $M/M/c$:

$$a = \frac{\lambda}{\mu}, \quad \rho = \frac{a}{c}, \quad P_0 = \left[\sum_{n=0}^{c-1} \frac{a^n}{n!} + \frac{a^c}{c!} \frac{1}{1-\rho} \right]^{-1}, \quad (7)$$

$$P(\text{espera}) = C = \frac{a^c}{c!} \frac{1}{1-\rho} P_0, \quad W_q = \frac{C}{c\mu - \lambda} \text{ (horas)}. \quad (8)$$

Además,

$$P(W_q \leq t) = 1 - C e^{-(c\mu - \lambda)t}. \quad (9)$$

3.1.1 Escenario modo ($\lambda=6, \mu=4$ por hora)

Política A ($c = 2$)

- $a = 1.5, \rho = 0.75$
- $P_0 = \frac{1}{1 + 1.5 + \frac{1.5^2}{2} \frac{1}{1-0.75}} = \frac{1}{7} = 0.1429$
- $C = 4.5 \cdot P_0 = 0.6429$
- $W_q = \frac{0.6429}{8-6} = 0.3214 \text{ h} = 19.29 \text{ min}$



- $P(Wq \leq 15) = 1 - 0.6429 e^{-2 \cdot 0.25} \approx 0.610$ (61%, *no cumple SLA*)
- **Satisfacción** (escala 1-5 por espera media): 2 (entre 15-25 min).
- **Score robusto**: $S = 0.70 - 0.10 - 0.5(0.20) = 0.50 \Rightarrow S \times P(SLA) = 0.50 \times 0.610 = 0.305$.

Acorde a lo que refleja la política A, teóricamente, con $\lambda = 6$ y $\mu = 4$ por hora en $M/M/2$, el tráfico es $a = \lambda/\mu = 1.5$ y la intensidad $\rho = a/c = 0.75$, lo que implica un sistema estable, pero con carga alta. El término Erlang-C $C = 0.6429$ cuantifica la probabilidad de esperar (que los dos servidores estén ocupados al llegar); por eso, aun con $\rho < 1$, la espera media resulta $Wq = C/(c\mu - \lambda) = 0.3214 \approx 19.29$ min. El cumplimiento del SLA se modela como $P(Wq \leq 15) = 1 - C e^{-(c\mu - \lambda) 0.25} \approx 0.610$: solo 61% de los pacientes inicia atención en ≤ 15 min, por debajo del umbral del 80%. Si la satisfacción se ancla a la espera media, este desempeño se ubica en un nivel 2/5 (rango 15-25 min). Incorporando la calidad de evidencia mediante la tripleta $\langle T, I, F \rangle = (0.70, 0.20, 0.10)$, el score neutrosófico $S = 0.50$ y el indicador robusto $S \times P(SLA) = 0.305$ reflejan que, además de bajo cumplimiento, la decisión basada en esta política no es robusta frente a la indeterminación de los datos

Política B (c=3)

- $a = 1.5, \rho = 0.5$
- $P0 = \frac{1}{1+1.5+1.125+1.125 \cdot 2} = 0.2105$
- $C = 1.125 \cdot P0 = 0.2368$
- $Wq = \frac{0.2368}{12-6} = 0.03947$ h = 2.37 min
- $P(Wq \leq 15) = 1 - 0.2368 e^{-6 \cdot 0.25} \approx 0.947$ (94.7%, *cumple SLA*)
- **Satisfacción**: 5 (≤ 5 min).
- **Score robusto**: $0.50 \times 0.947 = 0.474$.

Por otro lado, en el escenario con $\lambda = 6$ y $\mu = 4$ por hora bajo $M/M/3$, la carga ofrecida es $a = \lambda/\mu = 1.5$ y la intensidad por servidor $\rho = a/c = 0.5$, lo que implica servidores ocupados al 50% en promedio y un sistema holgado. La constante de normalización $P0=0.2105$ indica que el sistema está vacío ~21% del tiempo, mientras que el Erlang - C $C = 0.2368$ cuantifica que solo ~24% de las llegadas se encuentran a todos los servidores ocupados y deben esperar. El tiempo medio de espera resultante es muy bajo, $Wq = 0.03947$ h (≈ 2.37 min), y la probabilidad de cumplir el SLA de 15 minutos es alta, $P(Wq \leq 15) = 0.947$ (94.7%), muy por encima del umbral del 80%. Operativamente, esta holgura de capacidad en Política B ($c = 3$) se traduce en satisfacción máxima (5/5) y en una decisión robusta al considerar la calidad de evidencia del escenario modo, con un puntaje $0.50 \times 0.947 = 0.474$. En síntesis, el dimensionamiento con tres profesionales asegura baja espera, alto cumplimiento de servicio y resiliencia frente a la variabilidad típica del entorno rural

Prueba de hipótesis del SLA (N=100 pacientes)

- $H0: p \leq 0.80$ vs $H1: p > 0.80$
- $A: \hat{p} = 0.610, z = \frac{0.610-0.80}{\sqrt{0.8 \cdot 0.2/100}} = -4.75 \Rightarrow$ rechaza cumplimiento.
- $B: \hat{p} = 0.947, z = 3.68 \Rightarrow$ cumple con holgura

Bajo una prueba unilateral $H0: p \leq 0.80$ vs. $H1: p > 0.80$ con $n = 100$ ($\alpha = 0.05$), la Política A arroja $\hat{p} = 0.610$ y $z = -4.75$, muy por debajo del umbral crítico ($z_{0.95} = 1.645$); por tanto, no hay evidencia para afirmar que el cumplimiento supere 80% y, de hecho, el IC95% aproximado (0.514, 0.706) queda completamente bajo 0.80, confirmando que no cumple el SLA. En contraste, la Política B obtiene $\hat{p} = 0.947$ y $z=3.68$, superando con holgura el umbral crítico; su IC95% (0.903, 0.991) está íntegramente sobre 0.80, lo que aporta evidencia estadística sólida de cumplimiento del SLA, [12]. En términos operativos, A implica un riesgo alto de insatisfacción y demoras, mientras que B garantiza tiempos de inicio de atención acordes al objetivo de calidad. Así, la inferencia estadística respalda la decisión de dimensionar con $c = 3$ (o activar $c = 3$ en horas pico) para sostener el estándar de servicio.

3.1.2 Análisis de escenarios (Monte Carlo por extremos)

Pesimista ($\lambda = 7, \mu = 3.6$)

- A $c = 2: Wq \approx 287$ min, $P(Wq \leq 15) \approx 0.089 \Rightarrow$ mal.
- B $c = 3: Wq \approx 6.59$ min, $P(Wq \leq 15) \approx 0.838 \Rightarrow$ cumple.

Optimista ($\lambda = 5, \mu = 4.4$)

- A $c = 2: Wq \approx 6.50$ min, $P(Wq \leq 15) \approx 0.840 \Rightarrow$ cumple.
- B $c = 3: Wq \approx 0.90$ min, $P(Wq \leq 15) \approx 0.984 \Rightarrow$ sobresaliente.

El análisis por extremos muestra que la capacidad es el factor decisivo frente a la variabilidad de demanda y servicio: en el escenario pesimista ($\lambda = 7, \mu = 3.6$), A ($c = 2$) colapsa operativamente con $Wq \approx 287$



min y solo $P(Wq \leq 15) \approx 0.089$, muy por debajo del SLA, mientras B ($c = 3$) mantiene estabilidad con $Wq \approx 6.6$ min y $P(Wq \leq 15) \approx 0.838$ (cumple). En el optimista ($\lambda = 5, \mu = 4.4$) ambas alternativas cumplen, pero B ofrece desempeño sobresaliente ($Wq \approx 0.9$ min, $P \approx 0.984$) frente a A ($Wq \approx 6.5$ min, $P \approx 0.840$). En síntesis, B es robusta: cumple el SLA tanto en condiciones adversas como favorables, mientras que A es frágil y solo es aceptable cuando el sistema es liviano. Operativamente, esto sugiere dimensionamiento dinámico (activar $c = 3$ en picos) o, si el presupuesto restringe, complementar $c = 2$ con triaje más estricto y mejoras de flujo para mitigar el riesgo de largas esperas

Score neutrosófico

- **Pesimista:** $S = 0.50 - 0.20 - 0.5(0.30) = 0.15 \Rightarrow B: 0.15 \times 0.838 = 0.126 > A: 0.15 \times 0.089 = 0.013$.
- **Optimista:** $S = 0.80 - 0.05 - 0.5(0.15) = 0.675 \Rightarrow B: 0.675 \times 0.984 = 0.664 > A: 0.675 \times 0.840 = 0.567$.

4. CONCLUSIONES

En el centro de salud rural (SSC–recinto Las Cañas), el marco Monte Carlo más la neutrosofía mostró que la Política B ($c=3$) cumple con el SLA (≤ 15 min en $\geq 80\%$) de forma consistente y robusta: en el escenario modo alcanzó $P(\text{SLA})=0.947$ (espera media ≈ 2.4 min), frente a 0.610 y 19.3 min de la Política A ($c=2$); el indicador robusto $S \times P(\text{SLA})$ también favoreció a B (0.474 vs. 0.305). En el pesimista, A cae a 0.089 ($Wq \approx 287$ min), mientras que B se mantiene en 0.838 ($Wq \approx 6.6$ min); en el optimista, ambas cumplen (A 0.840, B 0.984), conservando ventaja B (0.664 vs. 0.567 en $S \times P(\text{SLA})$).

La capa neutrosófica permitió ponderar la calidad de la evidencia ($\langle T, I, F \rangle$ modo/optimista/pesimista) y penalizar decisiones sustentadas en datos con alta indeterminación (I), lo que aporta confiabilidad a la selección de políticas. Operativamente, recomendamos: (i) activar $c=3$ en horas pico y $c=2$ fuera de pico (dimensionamiento dinámico); (ii) reforzar el triaje para priorizar urgencias; (iii) mejorar la captura de datos para reducir I y recalibrar parámetros; y (iv) avanzar hacia la optimización en horizonte rodante y simulación–optimización conjunta (ruteo interno/ambulancias), evaluando trade-offs costo–tiempo–calidad y su alineación con atributos de Atención Primaria (accesibilidad, integridad y coordinación). En síntesis, el enfoque híbrido mejora la satisfacción, reduce los tiempos de espera y entrega de decisiones transferibles a otros entornos rurales con restricciones de personal.

5. BIBLIOGRAFÍA

- [1] García Arcal, J., López Álvarez, I., & Folgueras Marcos, A. (2008). La medición de SLAs (Acuerdos de Nivel de Servicio). Los tiempos verticales y horizontales.
- [2] Sánchez-Garrido, A. J., Martínez-Muñoz, D., Navarro, I. J., & Yepes, V. NEUTROSOPHIC LOGIC APPLIED TO THE MULTI-CRITERIA EVALUATION OF SUSTAINABLE ALTERNATIVES FOR EARTH-RETAINING WALLS. In 6 th International Conference on Mechanical Models in Structural Engineering (p. 188).
- [3] Ramos Segura, L. (2021). Métodos de Monte Carlo y sus aplicaciones.
- [4] Barbaro, M. C., Lettiere, A., & Nakano, A. M. S. (2014). Asistencia prenatal a la adolescente y los atributos de la Atención Primaria a la Salud. Revista Latino-Americana de Enfermagem, 22, 108-114.
- [5] Torres, L. C., Gaibor, J. N., & Vazquez, M. L. (2022). Modelo de optimización para inventarios, basado en Simulación Monte Carlo y Algoritmo Metaheurístico Genético. Universidad y Sociedad, 14(S6), 448-458.
- [6] Cevallos-Torres, L., & Botto-Tobar, M. (2019). Monte Carlo simulation method. In Problem-based learning: a didactic strategy in the teaching of system simulation (pp. 87-96). Cham: Springer International Publishing.
- [7] Moreira, CC (2023). Estimación mediante simulaciones de Monte Carlo en una clase de sistemas de colas G/G/C.
- [8] Estupiñán Ricardo, J., Leyva Vázquez, M. Y., Álvarez Gómez, S. D., Alfonso Manzanet, J. E., & Velázquez-Soto, O. E. (2023). La aplicación de la neutrosofía en las ciencias médicas: una revisión bibliográfica narrativa. Revista Cubana de Información en Ciencias de la Salud, 34.
- [9] Smarandache, F. (2024). Fundamentos de topologías de vanguardia (artículo de revisión parcial). Neutrosophic Computing and Machine Learning. ISSN 2574-1101, 31, 01-22.



- [10] Berra, S., Hauser, L., Audisio, Y., Mántaras, J., Nicora, V., Oliveira, M. M. C. D., ... & Harzheim, E. (2013). Validez y fiabilidad de la versión argentina del PCAT-AE para evaluar la atención primaria de salud. *Revista Panamericana de Salud Pública*, 33, 30-39.
- [11] de Arias, L. M. P., Montoya, L. A., & Henao, S. A. F. (2010). Análisis de líneas de espera a través de teoría de colas y simulación. *Scientia et Technica*, 3(46), 56-61.
- [12] Valenzuela Delgado, L. (1980). Desarrollo de un programa computacional para facilitar y ejemplificar la enseñanza y aprendizaje de pruebas de hipótesis.

