

Escuela Superior de Guerra Conjunta de las Fuerzas Armadas



Tema.

ALGORITMOS GENÉTICOS Y SANIDAD EN COMBATE

Título.

**ALGORITMOS GENÉTICOS APLICADOS A
SOLUCIONES LOGÍSTICAS DE SANIDAD:
SIMULACIÓN DE UN MODELO DE EVACUACIÓN DE HERIDOS
DEL TEATRO DE OPERACIONES**

Trabajo Final Integrador

**Capitán de Fragata Carlos Aníbal Petriv
2012**

RESUMEN

La rápida asistencia a los heridos del Teatro de Operaciones, la selección y clasificación según sus prioridades de atención médica (Triage) y su posterior evacuación a hospitales de campaña, son de vital importancia para la disminución de la tasa de mortalidad de los combatientes.

Mediante la concepción de un modelo matemático, puede replicarse este proceso bajo diferentes escenarios, con la posibilidad de modificar las variables que influyen en el funcionamiento de la simulación, que servirán para evitar los errores resultantes y permitir la introducción de correcciones.

La generación de modelos experimentales, como los algoritmos genéticos, han colaborado con el ser humano a mejorar el proceso de toma de decisiones, con el propósito de entender el comportamiento de los sistemas del mundo real o evaluar estrategias con las cuales puedan operar.

Los algoritmos genéticos son, de este modo, una herramienta útil para la detección de soluciones optimizadas. Están inspirados en la evolución biológica y su base genética, evidenciada en los rasgos evolutivos de una población. Estos individuos son sometidos a acciones aleatorias semejantes a las que actúan en la naturaleza (recombinaciones genéticas y mutaciones), desarrollándose mediante iteraciones denominadas generaciones. En cada generación, los cromosomas son evaluados utilizando una función de aptitud, que determinará cuales son los exponentes más aptos que pasarán a las siguientes generaciones, luego de las cuales el algoritmo determinará el resultado óptimo.

Podemos señalar que, en esta investigación, se ha confirmado la hipótesis de factibilidad del desarrollo simulado de evacuación de heridos de un Teatro de Operaciones, mediante la aplicación de modelos matemáticos y heurísticos. Además, la calidad de la solución generada y optimizada por el algoritmo genético, basada en estimaciones probabilísticas y determinadas sobre la base de supuestos, ha concebido una nueva representación para la toma de decisiones ante incertidumbres.

PALABRAS CLAVE

Sanidad en combate; Triage; Evacuación de heridos; Modelo de simulación;
Algoritmos genéticos; Teoría de Colas

TABLA DE CONTENIDOS

Resumen	ii
Palabras clave	iii
Tabla contenidos	iv
Índice de figuras	viii
Índice de tablas	ix
Introducción	1
Capítulo 1 Introducción a la Investigación Operativa	3
1.1 Teoría de Colas o Líneas de Espera	4
1.2 Algoritmos genéticos	5
Capítulo 2 Simulación aplicada a la logística de sanidad	9
2.1 Introducción	9
2.2 La atención sanitaria en combate	9
2.3 Medidas de desempeño en el sistema de colas	11
2.3.1 <i>Variables iniciales</i>	11
2.4 Determinación del centro de gravedad en un área de combate	12
2.5 Estudio del problema	13
2.6 Resolución mediante la utilización del software WinQSB	15
2.7 Análisis de sensibilidad	16
Capítulo 3 Modelo heurístico con algoritmos genéticos	18
3.1 Generación de la población inicial (Pi)	18
3.2 Determinación de la función objetivo y puntaje cromosomático	20
3.3 Evolución generacional	21
3.3.1 <i>Selección</i>	21
3.3.2 <i>Crossover (cruza)</i>	21
3.3.3 <i>Mutación</i>	22
Conclusiones	32
Bibliografía	33
Anexo A Factores de planeamiento	37

A.1	Cálculo de bajas de personal del Ejército	37
A.2	Porcentaje de bajas mensuales de personal	37
A.3	Discriminación de bajas	37
Anexo B	Selección y clasificación del Método Triage	39
B.1	Definición de Triage	38
B.2	Tiempos de clasificación de heridos en combate	40
B.3	Sistema de clasificación Mettag	40
Anexo C	Modelos de líneas de espera	42
C.1	Introducción a la Teoría de Colas o Líneas de Espera	42
C.2	Medidas de desempeño en un sistema de colas	42
C.3	Estructuras básicas de un sistema de colas	43
C.3.1	<i>Una línea y un servidor</i>	43
C.3.2	<i>Una línea y múltiples servidores</i>	44
C.3.3	<i>Múltiples líneas y servidores</i>	44
C.3.4	<i>Una línea y servidores secuenciales</i>	44
C.4	Costos en un sistema de colas	45
C.4.1	<i>Costo de espera</i>	45
C.4.2	<i>Costo de servicio</i>	45
C.4.3	<i>Costo óptimo</i>	45
C.5	Tiempos en un sistema de colas	46
C.5.1	<i>Tiempo de llegada</i>	46
C.5.2	<i>Tasa media de llegadas (λ)</i>	46
C.5.3	<i>Tiempo esperado entre llegadas ($1/\lambda$)</i>	46
C.5.4	<i>Tiempo esperado de servicio ($1/\mu$)</i>	46
C.6	Distribución de llegadas en un sistema de colas	46
C.6.1	<i>Distribución exponencial</i>	47
C.6.2	<i>Distribución de Poisson</i>	47
C.7	Notación de Kendall (A/B/c)	48
C.7.1	<i>Distribución del tiempo de llegada</i>	48
C.7.2	<i>Distribución del tiempo de servicio</i>	49
C.7.3	<i>Número de servidores</i>	49
C.7.4	<i>Capacidad del sistema</i>	49
C.7.5	<i>Tamaño de población o fuente de clientes</i>	49

C.7.6	<i>Disciplina en la cola</i>	50
C.7.7	<i>Medidas de desempeño general del sistema de colas</i>	50
C.7.8	<i>Modelos de una cola y un servidor</i>	50
C.7.8.1	<i>Modelo M/M/1</i>	50
C.7.8.2	<i>Modelo M/G/1</i>	51
C.7.8.3	<i>Modelo M/D/1</i>	51
C.7.8.4	<i>Modelo M/Ek/1</i>	52
C.7.9	<i>Modelos de múltiples servidores</i>	52
C.7.9.1	<i>Modelo M/M/S</i>	52
C.7.9.2	<i>Modelo M/D/S</i>	53
C.7.9.3	<i>Modelo M/Ek/S</i>	53
Anexo D	Estructura y componentes de Algoritmos Genéticos	54
D.1	La evolución natural en la Investigación Operativa	54
D.2	Esquema general de un algoritmo simple	54
D.3	Métodos de selección	55
D.3.1	<i>Método elitista</i>	55
D.3.2	<i>Método proporcional a la aptitud</i>	55
D.3.3	<i>Método de rueda de ruleta</i>	55
D.3.4	<i>Método de escalada</i>	55
D.3.5	<i>Método de estado estacionario</i>	55
D.3.6	<i>Método por torneo</i>	56
D.3.7	<i>Método por rango</i>	56
D.3.8	<i>Método generacional</i>	56
D.3.9	<i>Método por jerarquía</i>	56
D.4	Codificación de las variables	56
D.4.1	<i>Cadena binaria</i>	56
D.4.2	<i>Cadena de números enteros o reales</i>	57
D.4.3	<i>Cadena de letras</i>	57
D.4.4	<i>Picos de Hamming</i>	57
D.4.5	<i>Códigos de Gray o código binario reflejado</i>	57
D.5	Operadores genéticos	58
D.5.1	<i>Crossover</i>	58
D.5.2	<i>Crossover monopunto</i>	58

D.5.3	<i>Crossover multipunto</i>	58
D.5.4	<i>Crossover uniforme</i>	58
D.5.5	<i>Crossover asimétrico (de 2 puntos)</i>	61
Anexo E	Resultados experimentales del modelo	63

ÍNDICE DE FIGURAS

Figura 1	Fases de atención en Protocolos TEPT	10
Figura 2	Cuadrícula del área de combate para una GUC de Infantería	12
Figura 3	Cantidad aleatoria de combatientes heridos en un mes	14
Figura 4	Tasa de ocupación (ρ) y probabilidad de espera (P_w) para S entre 1 y 5	16
Figura 5	Modelo evolutivo (generaciones 1 a 30)	29
Figura 6	Estabilización del sistema (250 generaciones)	30
Figura 7	Modelo evolutivo de valores máximos	30
Figura 8	Modelo evolutivo de valores promedios	31
Figura 9	Estructura de un sistema de cola (línea y un servidor)	43
Figura 10	Estructura de un sistema de cola (una línea y múltiples servidores)	44
Figura 11	Estructura de un sistema de cola (múltiples líneas y servidores)	44
Figura 12	Estructura de un sistema de cola (una línea y servidores secuenciales)	44
Figura 13	Costos de un sistema de colas	45
Figura 14	Curva de distribución exponencial	47
Figura 15	Curva de distribución de Poisson	48
Figura 16	Esquema general de un algoritmo genético	54
Figura 17	Comportamiento evolutivo de generaciones 1 a 25	63
Figura 18	Comportamiento evolutivo de generaciones 26 a 50	63
Figura 19	Comportamiento evolutivo de generaciones 51 a 75	63
Figura 20	Comportamiento evolutivo de generaciones 76 a 100	63
Figura 21	Comportamiento evolutivo de generaciones 101 a 125	64
Figura 22	Comportamiento evolutivo de generaciones 126 a 150	64
Figura 23	Comportamiento evolutivo de generaciones 151 a 175	64
Figura 24	Comportamiento evolutivo de generaciones 176 a 200	64
Figura 25	Comportamiento evolutivo de generaciones 201 a 225	65
Figura 26	Comportamiento evolutivo de generaciones 226 a 250	65

ÍNDICE DE TABLAS

Tabla 1	Analogía entre teoría evolutiva y Algoritmos Genéticos	8
Tabla 2	Análisis de sensibilidad para valores de S entre 1 y 5	16
Tabla 3	Porcentaje mensual de bajas para largos períodos de tiempo	37
Tabla 4	Discriminación de bajas de combate	38
Tabla 5	Tiempos de clasificación según el método Triage	39
Tabla 6	Clasificación del sistema Mettag	41

INTRODUCCIÓN

Considerando el potencial riesgo de vulnerabilidad de las víctimas de combate en un Teatro de Operaciones y la consiguiente tasación del número de heridos debido a tales sucesos, es de considerar la necesidad de encontrar una respuesta oportuna que minimice los efectos colaterales ocasionados a estos.

Surge entonces un interrogante: ¿Es posible la modelación de un sistema de evacuación de heridos mediante la aplicación de algoritmos genéticos¹, que permita contribuir a una eficaz y eficiente gestión sanitaria en el Teatro de Operaciones?

Mediante la aplicación de algoritmos genéticos, es posible realizar un modelo de simulación² que permita una gestión sanitaria eficaz y eficiente para el rescate de víctimas en el Teatro de Operaciones. Por lo expuesto, en esta investigación nos proponemos:

- Identificar los elementos componentes que puedan satisfacer los requerimientos, para simular en forma discreta³ la recuperación de heridos de un Teatro de Operaciones.
- Determinar una metodología que permita generar una representación basándose en la Teoría de Colas⁴, para aplicarla posteriormente a la simulación del modelo mediante la utilización de algoritmos genéticos.
- Analizar y valorar el desempeño del algoritmo implementado, con el objeto de determinar la calidad de las soluciones obtenidas.
- Proponer un modelo que permita analizar el comportamiento de indicadores de desempeño ante cambios en los parámetros variables de entrada y documentar los resultados obtenidos para identificar sus ventajas y desventajas prácticas, como base para futuras mejoras en éste u otro tipo de escenario.

Para ello se desarrollará una metodología cualitativa en base al análisis bibliográfico de fuentes primarias y secundarias, y cuantitativa mediante el proceso matemático de la Teoría de Colas y algoritmos genéticos aplicados al modelo.

El aporte teórico de este trabajo, significará introducir al ámbito de la

¹ Ver Anexo D

² La simulación “es una amplia colección de métodos y aplicaciones, que permiten imitar el comportamiento de un sistema real.” (Kelton, Sadowski & Sadowski, 2008)

³ La simulación discreta es una técnica para el tratamiento de problemas complejos que se apoya en la potencia de los equipos informáticos y en software, para el desarrollo de modelos de sistemas.

⁴ Ver Anexo C

investigación, no solo un conocimiento del tema, sino posibilitar nuevas líneas de investigación con la aplicación de esta herramienta o el diseño de técnicas no convencionales para futuros proyectos.

Capítulo 1

INTRODUCCIÓN A LA INVESTIGACIÓN OPERATIVA

En el presente capítulo, daremos una breve descripción de la evolución e importancia que ha generado la Investigación Operativa en diferentes ámbitos científicos, particularmente en la toma de decisiones. Entre los medios de proceso de resolución, utilizaremos la Teoría de Colas o Líneas de Espera para determinar el comportamiento de un sistema de evacuación de heridos, basándonos en un desarrollo matemático y emplearemos su resultado en la concepción de un modelo computacional a través de la aplicación de algoritmos genéticos, limitándonos al nivel operacional, centrado en el ambiente terrestre de un Teatro de Operaciones.

La Investigación Operativa (IO) es un enfoque científico en la toma de decisiones que, mediante el diseño optimizado de un modelo matemático y estadístico, un sistema integrado por componentes interdependientes, trabajan fusionados en la resolución de problemas complejos para el logro de un objetivo.

El término IO se acuñó en Inglaterra durante la Segunda Guerra Mundial, cuando se le encomendó a un grupo de científicos la toma de decisiones acerca de la mejor utilización de materiales bélicos⁵. Posteriormente, sus técnicas fueron adaptadas a la mejora de eficiencia de la productividad en el sector civil.

Sin embargo, su auge se debe, en su mayor parte, al gran desarrollo de la informática, gracias a la cual es posible resolver problemas en la práctica y obtener soluciones que de otra forma conllevarían un enorme tiempo de cálculo. Debido al gran éxito de la Investigación Operativa en el campo militar, esta se extendió a otros campos tales como la industria, la física, la informática, la economía, ecología, educación, ingeniería civil, ingeniería química y otras, siendo hoy en día utilizada prácticamente en todas las áreas.

Existen diversos métodos de utilizados en la Investigación Operativa para la optimización de los diversos problemas planteados:

Determinísticos: Programación lineal, programación entera, probabilidad de

⁵ En la II Guerra Mundial, durante la batalla de Inglaterra, la Luftwaffe estaba sometiendo a los británicos a un duro ataque aéreo. Por ello, el gobierno británico, buscando algún método para defender su país, convocó a varios científicos de diversas disciplinas para tratar de resolver el problema de sacar el máximo beneficio de los radares que disponían. Gracias a su trabajo determinando la localización óptima de las antenas y la mejor distribución de las señales, consiguieron duplicar la efectividad del sistema de defensa aérea (<http://www.phpsimplex.com/historia.htm>)

transporte, programación no lineal, teoría de localización o redes, probabilidad de asignación, programación por metas, teoría de inventarios, etc.

- Probabilísticos:** Cadenas de Markov, programación estocástica, teoría de juegos, líneas de espera, teoría de inventarios, etc.
- Híbridos:** Conjugan métodos determinísticos y probabilísticos.
- Heurísticos:** Son soluciones basadas en la experiencia, tales como algoritmos genéticos, redes neuronales y sistemas de lógica difusa.

1.1 Teoría de Colas o líneas de espera

El sistema de colas o líneas de espera, es un aspecto de la vida moderna que se nos presenta continuamente en nuestras actividades diarias, ya sea en un cajero automático, en un banco, un supermercado, un peaje, en el aterrizaje o despeje de aviones, en la carga de combustible en estaciones de servicio, en la espera de un ómnibus, etc., y surge por la necesidad que tienen los clientes de recibir un determinado servicio.

La Teoría de Colas es el estudio matemático del comportamiento de las líneas de espera que se presenta cuando un cliente llega a un lugar demandando un servicio a un servidor, el cual posee determinada capacidad de atención. Si éste no se encuentra disponible inmediatamente, el cliente pasa a formar parte de una cola o línea de espera⁶.

Antes de iniciar el proceso de modelaje, es necesario aclarar el significado de determinada simbología utilizada en Investigación Operativa y que será aplicada al diseño:

Cliente	Combatiente herido
Servidor	Transporte sanitario
Servicio	Traslado de heridos desde la zona de combate hasta el hospital de campaña y regreso
Costo de espera	Pérdida del recurso humano por muerte del combatiente herido, consecuencia de una deficiente o inoportuna atención hospitalaria

⁶ Según un estudio del Massachusetts Institute of Technology (MIT), un adulto promedio pierde entre dos y tres años de su vida haciendo colas. TOMINO PABLO, artículo “Trámites, esperas y otras pesadillas de la vida urbana”; Diario “La Nación”, 31 Julio 2012.

Costo del servicio Cantidad de medios de transporte sanitario (siendo éste un recurso escaso)

En un Teatro de Operaciones (TO) la rápida intervención y evacuación de heridos (clientes) mediante un servicio adecuado de transporte sanitario fuera de la zona de combate, con los recursos disponibles (servicios), determinará la tasa de bajas producidas, con sus correspondientes secuelas al personal, tanto en el aspecto físico como en la moral.

El estudio de las colas proporciona tanto la base teórica del tipo de servicio que podemos esperar de un determinado recurso, como la forma en la cual dicho recurso puede ser diseñado para proporcionar un determinado grado de servicio a sus clientes.

Si existen múltiples servidores y la tasa de clientes es baja, los primeros estarán ociosos. Caso contrario, si el tiempo entre llegadas es bajo comparado con el tiempo de atención del servicio, la cola aumentará. Para ello es necesario establecer la capacidad o tasa de servicio que proporciona el equilibrio adecuado entre el momento de llegada de los clientes, el tiempo de espera y el tiempo que demande el servicio, debido a que no es posible determinar en la mayoría de los casos, el momento exacto de llegada de cada cliente ni el tiempo de servicio de cada uno de ellos. La Teoría de Colas trata de predecir el comportamiento del sistema, logrando minimizar no solo el tiempo que el cliente pasa en el mismo, sino también los costos de aquellos que los prestan.

1.2 Algoritmos genéticos

El algoritmo genético (AG) es una técnica de programación que utiliza métodos matemáticos de optimización basados en la simulación de los mecanismos de evolución natural, formulados por Charles Darwin en la teoría de la evolución y expuestos en su obra⁷ (Darwin, 1859), donde el principio de la selección natural es el motor más importante del proceso evolutivo por los cuales las especies mutan con el transcurso de las generaciones, obligadas por la supervivencia del más apto.

Los algoritmos genéticos fueron elaborados en la década del 70's por el Dr. John

⁷ El título completo de la primera edición fue "On the Origin of Species by Means of Natural Selection, or the Preservation of Favoured Races in the Struggle for Life" ("El origen de las especies por medio de la selección natural, o la preservación de las razas favorecidas en la lucha por la vida"), que en su sexta edición fuera modificado a "The Origin of Species" ("El origen de las especies"). En el libro, Darwin introdujo la teoría científica de que las poblaciones evolucionan durante el transcurso de las generaciones mediante un proceso conocido como selección natural. Presentó evidencias de que la diversidad de la vida surgió de la descendencia común a través de un patrón ramificado de evolución.

Holland⁸ como un modelo para el desarrollo de mecanismos que permitieran incorporar esta técnica a los sistemas de cómputo. Alcanzan popularidad más de una década después con aplicaciones en problemas prácticos.

Actualmente, dentro de las áreas de la inteligencia artificial⁹, son numerosos los ámbitos de aplicación de los AG's. Entre ellos pueden citarse los siguientes: acústica¹⁰, comunicaciones¹¹, ingeniería aeroespacial¹², astronomía¹³, química¹⁴, ingeniería eléctrica¹⁵, mercados financieros¹⁶, ingeniería informática¹⁷, matemática¹⁸, ingeniería civil¹⁹, biología molecular²⁰, reconocimiento de patrones²¹, logística²², robótica²³, ingeniería en sistemas²⁴ y militar²⁵, entre otros ejemplos.

⁸ Dr. John Henry Holland (2 de febrero de 1929) pionero en sistemas complejos y ciencia no lineal. También es conocido como el padre del Algoritmo genético. Profesor de Filosofía, de Ingeniería Eléctrica y de Ciencias de la computación en la Universidad de Michigan

⁹ La inteligencia artificial (IA), consiste en el diseño de procesos que, al ejecutarse sobre una arquitectura física, producen resultados que maximizan una cierta medida de rendimiento. Estos procesos se basan en secuencias de entradas que son percibidas y almacenadas por la mencionada arquitectura. También puede definirse a la Inteligencia Artificial (IA) como la rama de las ciencias de la computación que se ocupa de construir sistemas que permitan exhibir un comportamiento cada vez más inteligente. Loaiza Roger, "De la información a la informática"

¹⁰ Sato, S., K. Otori, A. Takizawa, H. Sakai, Y. Ando y H. Kawamura. "Applying genetic algorithms to the optimum design of a concert hall." *Journal of Sound and Vibration*, vol.258, no.3, p. 517-526, 2002

¹¹ Nesmachnow Sergio, "Algoritmos genéticos paralelos y su aplicación al diseño de redes de comunicaciones confiables". Instituto de comunicación, Facultad de Ingeniería, Universidad de la República de Montevideo, Uruguay. Julio 2004

¹² Alonso Zotes Fernando, "Aplicación de algoritmos inteligentes en problemas aeroespaciales". Departamento Arquitectura de Computadores y Automática, Facultad de Informática, Universidad Complutense de Madrid, España. 2010

¹³ Fernández Pérez-Rendón Antonio Luis, "Formulación generalizada de la interferometría estelar de Speckles. Reconstrucción en el dominio espacial mediante algoritmos genéticos". Universidad de La Laguna, España, 1993

¹⁴ Cravo Cristifer, "Diseño y optimización de columnas de pared dividida extractivas utilizando algoritmos genéticos". Universidad de Guanajuato, México, 13 marzo 2009

¹⁵ Castro Mora José, "Optimización global de parques eólicos mediante algoritmos genéticos". Departamento de Ingeniería Eléctrica, Universidad de Sevilla, España. 22 septiembre 2008

¹⁶ Parisi Antonino, "Modelos de algoritmos genéticos y redes neuronales en la predicción de índices bursátiles asiáticos". Universidad de Chile. Cuadernos de Economía, Vol. 43 (noviembre), N° 128, pp. 251-284, 2006

¹⁷ Bertona Luis, "Entrenamiento de redes neuronales basado en algoritmos genéticos". Facultad de Ingeniería, Universidad de Buenos Aires. Noviembre 2005. <http://www.monografias.com/trabajos-pdf/entrenamiento-redes-neuronales-algoritmos-evolutivos/entrenamiento-redes-neuronales-algoritmos-evolutivos.pdf>

¹⁸ Juárez Morales Raúl, "Exponenciaciones modulares usando algoritmos genéticos con representación entera". Facultad de Matemáticas, Universidad Autónoma de Guerrero, México. 13 octubre 2006

¹⁹ Coello Coello Carlos, Santos Hernández Filiberto, Alonso Farrera Francisco, "Diseño óptimo de vigas de concreto reforzado mediante algoritmos genéticos". Escuela de Ingeniería Civil, Universidad Autónoma de Chiapas, México.

²⁰ Morato Izquierdo María del Carmen, "Algoritmos genéticos. Aplicación al análisis de secuencias en biología molecular". Universidad Politécnica de Madrid, España, 1999

²¹ Colmenares Adriana, "Reconocimiento de patrones aplicando algoritmos genéticos y redes neuronales aleatorias". Escuela de Ingeniería de sistemas, Facultad de Ingeniería, Universidad de Los Andes, Venezuela. 16 octubre 2008

²² Castillo Ignacio, "Algoritmos genéticos aplicados a la gestión de inventarios de artículos no perecederos". Universidad de Morón, Buenos Aires, Argentina, 2004.

²³ Chavolla Canal Edgar, "Algoritmos genéticos modificados para el balance de robots humanoides". Departamento de Electrónica, Centro Universitario de Ciencias Exactas de Ingenierías, Universidad de Guadalajara, Jalisco, México. Febrero 2010

²⁴ Fiszlelew Abel, "Generación automática de redes neuronales con ajuste de parámetros basado en algoritmos genéticos". Facultad de Ingeniería, Universidad de Buenos Aires, Argentina. Febrero 2002

²⁵ Mora García Antonio, "Resolución del problema militar de búsqueda de camino óptimo multiobjetivo mediante el uso de algoritmos de optimización basados en colonias de hormigas". Departamento de Arquitectura y Tecnología de Computadores, Universidad de Granada, España, 2009

Los algoritmos genéticos (AG) o también denominados evolutivos, trabajan con una población de individuos, que representan posibles soluciones a un problema. Esta población se somete a determinadas transformaciones y posteriormente a un proceso de selección, que favorece a los mejores individuos. Cada ciclo de transformación y selección constituye una generación, de manera que, después de un cierto número de generaciones, se espera que el mejor individuo de la población se aproxime al valor de solución deseado. Los algoritmos evolutivos combinan la búsqueda aleatoria, dada por las transformaciones de la población, con una búsqueda dirigida dada por la selección.

Comparando la evolución natural con los AG, pueden verificarse los siguientes componentes análogos:

Evolución	Algoritmos genético
Evolución	Transformaciones sucesivas de los cromosomas ²⁶ . Iteraciones ²⁷
Población	Conjunto de cromosomas (individuos) soluciones al problema
Generación	Población resultante de cada iteración
Cromosoma	Cadena de genes ²⁸ . Individuo de potencial solución al problema
Gen	Bloque/s componente/s del cromosoma
Locus	Posición del gen
Alelo ²⁹	Valor del gen
Genotipo	Solución codificada (estructura interna)
Fenotipo	Solución decodificada (estructura externa)
Fitness	Función evaluadora ³⁰ de la calidad de un individuo de la población
Crossover	Operador genético ³¹ . Cruza de 2 genes posteriores a la selección

²⁶ Los algoritmos genéticos trabajan manipulando cromosomas, que son estructuras que codifican las distintas soluciones de un determinado problema. La forma en que se codifican los cromosomas es dependiente de cada problema en particular, y suele variar de problema en problema. Un cromosoma está compuesto por un conjunto de genes. Cada gen representa una característica particular del individuo y ocupa una posición determinada en el cromosoma, llamada locus. A cada uno de los valores que puede tomar un gen se lo conoce como alelo (Bertona Luis Fewderico, “Entrenamiento de redes neuronales basado en algoritmos evolutivos”, Tesis de Grado en Ingeniería Informática, Facultad de Ingeniería de la Universidad de Buenos Aires, Laboratorio de Sistemas Inteligentes (noviembre 2005))

²⁷ (Del lat. iterāre) 1. Repetir (Diccionario de la Lengua Española, Vigésima segunda edición) 2. mat. Método que permite obtener un resultado con una aproximación deseada, repitiendo un cálculo con datos cada vez más aproximados, obtenidos generalmente en el cálculo anterior al que se está realizando (Diccionario Enciclopédico Vox, Ed. Larousse, 2009)

²⁸ El término cromosoma se refiere a un candidato a solución del problema, que a menudo se codifica como una cadena de bits. Los genes son tanto un bit como bloques cortos de bits adyacentes que codifican un elemento particular del candidato a solución. Los bits que codifican un parámetro particular, se considera un gen.

²⁹ Un alelo en una cadena de bits será un 0 o un 1 (para alfabetos largos cada lugar puede tener más alelos)

³⁰ La función de evaluación generalmente es la función objetivo, es decir, es lo que se quiere llegar a optimizar (ej: número de aciertos, número de movimientos, etc.). Es necesario decodificar la solución presente en el cromosoma para evaluarla. La función de aptitud (fitness) es la que permite valorar la aptitud de los individuos y debe tomar siempre valores positivos.

³¹ El cruce consiste, normalmente, como en su espejo biológico, en un intercambio de material genético entre dos cromosomas de dos padres haploides.

Mutación	Operador genético ³² . Selección y modificación de un individuo
----------	--

Tabla 1 – Analogía entre Teoría evolutiva y Algoritmos genéticos

Fuente: Elaboración propia

³² La mutación es una permutación en un bit en un lugar aleatorio (o, en el caso de alfabetos largos, reemplazar el símbolo de un lugar escogido aleatoriamente con un símbolo nuevo escogido también aleatoriamente)

Capítulo 2

SIMULACIÓN APLICADA A LA LOGÍSTICA DE SANIDAD

2.1 Introducción

En este capítulo introduciremos la importancia de la logística sanitaria, su influencia en la moral del combatiente y la necesidad de desarrollar modelos computacionales que nos permitan realizar un proceso de toma de decisiones lo más aproximado a la realidad. Para ello, estableceremos un primer paso mediante la asignación de variables aleatorias iniciales para la determinación de indicadores de desempeño.

2.2 La atención sanitaria en combate

La historia sobre la atención médica en combate es muy vasta y ha sido uno de los avances que más ha colaborado en mantener elevada la moral de los soldados en el campo de batalla. Hasta la Primera Guerra Mundial, este sistema funcionó sin grandes variaciones. Se limitaba a recoger a los heridos tras una batalla e intentaba atenderlos lo mejor posible, a sabiendas que el tiempo transcurrido entre que el soldado era herido en combate y la atención era tan grande, que muchas vidas se perdían por el camino y otras muchas heridas acababan agravándose, dando por resultado un elevado número de víctimas.

A partir de la Segunda Guerra Mundial, fundamentalmente durante las guerras de Corea y Vietnam, se empezaron a desarrollar los protocolos TEPT³³ (Trastorno de Estrés Post-Traumático) para la atención de heridos, en el mismo terreno de operaciones, elevando aún más la moral de la tropa.

Posteriormente, la evacuación médica mediante el uso de helicópteros y otros medios de transporte sanitario hacia un hospital de campaña, tuvo otro impulso más significativo aún.

Es importante señalar que un buen porcentaje de heridos en combate sucumbían

³³ El TEPT o Trastorno de Estrés Post-Traumático, fue iniciado por el Naval Special Warfare Command (Mando de Guerra Naval Especial) en 1993, con el proyecto Tactical Combat Casualty Care (TCCC) y posteriormente se amplió al U.S. Special Operations Command (Mando de Operaciones Especiales de los Estados Unidos). Son un conjunto de protocolos para la atención al trauma en combate táctico, que proporcionan a los médicos y personal sanitario en combate, las estrategias de manejo del trauma.

antes de recibir una eficaz atención médica en un establecimiento sanitario, pues la supervivencia de éstos, dependía únicamente de aquel combatiente que le proporcionaba la atención básica en primeros auxilios.

El personal médico en combate debe actuar no solo mediante el conocimiento, sino además con la premura del caso y ante situaciones restringidas por el entorno desfavorable.

Esta situación es un indicador que los prolongados períodos de evacuación deben reducirse al mínimo, de acuerdo a la disponibilidad de recursos existentes, pero tratando siempre de lograr una mayor optimización de éstos, a fin de obtener el mayor número posible de bajas, además de una rápida recuperación del combatiente al Teatro de Operaciones.

Los Protocolos TEPT, se estructuran en 3 fases^{34 35 36}de atención:



Fig. 1 – Fases de atención en Protocolos TEPT

Fuente: Elaboración propia

Para esta última fase de evacuación táctica que se desarrollará en el trabajo de investigación, el resultado se obtendrá mediante un proceso de simulación, recurriendo al método Triage para la selección y clasificación de los heridos basándose en las prioridades de atención, privilegiando la posibilidad de supervivencia, de acuerdo a las necesidades terapéuticas y los recursos disponibles (ambulancias y hospitales de campaña) aplicando posteriormente la Teoría de Colas como método de investigación de operaciones para luego, mediante algoritmos genéticos, obtener un marco referencial significativo en la resolución del problema.

Si bien es difícil que éste procedimiento contemple todas las posibles

³⁴ Fase de atención bajo fuego enemigo: Care under Fire. La atención médica es prestada al momento de la lesión, mientras tanto el médico como el herido se encuentran bajo fuego enemigo.

³⁵ Fase de atención en el campo táctico: Tactical Field Care. La atención prestada por el médico al herido se realiza cuando no se encuentran bajo una situación hostil. El equipo médico dispone de un período de tiempo determinado para su evacuación, que puede variar desde minutos hasta horas.

³⁶ Fase de atención en la evacuación sanitaria: Tactical Evacuation Care. Es la atención prestada al paciente traumatizado, una vez recogido por un vehículo de transporte sanitario, mediante personal médico organizado.

situaciones, proporciona a futuro el desarrollo de determinadas condiciones y variables para su posterior apreciación y que, de otro modo, sería muy complejo de establecer en la realidad. A su vez, estos resultados pueden ser analizados y comparados detenidamente, para incluirlos en un Plan de Campaña o evaluarlos durante su evolución en el Teatro de Operaciones.

Para éste trabajo se analizaron los factores de planeamiento para el cálculo de bajas de una Gran Unidad de Combate (GUC) de Infantería del Ejército (Anexo A), para largos períodos de tiempo (más de 5 días)

2.3 Medidas de desempeño en el sistema de colas

Para obtener las medidas de desempeño del sistema, debemos indicar las variables que permitirán, mediante la modificación de sus valores, obtener los resultados esperados.

2.3.1 Variables iniciales

Pi (Población inicial)	Cantidad de combatientes heridos
μ (Tasa promedio de servicio)	Tiempo de atención sanitaria, dependiente de la distancia al centro de atención sanitaria y la velocidad de traslado del transporte sanitario
λ (Tasa promedio de llegada)	Cantidad de heridos por unidad de tiempo que llegan al Cg (Centro de gravedad) donde se localizan los transportes sanitarios
S (Cantidad de servidores)	Cantidad de transportes sanitarios
Dcg (Distancia del Cg)	Distancia del Cg (ubicación de los transportes sanitarios) al hospital de campaña
Cg (Centro de Gravedad)	Centro geométrico del área de la Zona de Combate
Rm (Máx. radio de acción)	Máxima distancia del Cg al perímetro de la Zona de Combate
Dt (Distancia total)	Sumatoria algebraica de la máxima distancia perimetral (Rm) al Cg y la distancia del Centro de gravedad (Dcg) al hospital de campaña.

2.4 Determinación del centro de gravedad en un área de combate

La siguiente cuadrícula supone la Zona de Combate para una Brigada de Infantería Mecanizada (GUC³⁷), donde cada uno de los cuadrados representa una área de 7,5 kms² (2,5 kms x 3,0 kms), obteniéndose una superficie total de 900 kms² (30 kms de frente x 30 kms de profundidad). A partir de la misma figura, se localizan los medios de transporte sanitario en el centro de gravedad (Cg) de la superficie dada.

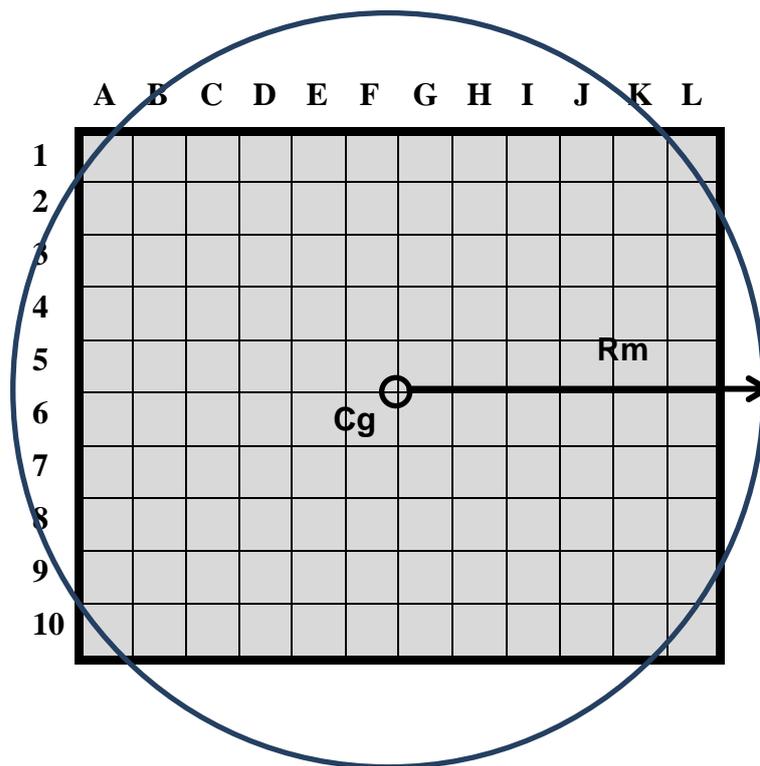


Fig. 2 - Cuadrícula del área de combate para una GUC de Infantería

Fuente: Elaboración propia

Por lo tanto, la distancia total (Dt) al hospital de campaña estará dada por:

$$Dt = \sum (Rm + DCg)$$

donde Dm es la máxima distancia perimetral al Cg y DCg es la distancia de éste punto al hospital de campaña.

Consideraremos únicamente la llegada al Centro de Gravedad (Cg), de heridos graves y muy graves, especificando para nuestro problema, la estructura básica del

³⁷ GUC: Gran Unidad de Combate

sistema, como la correspondiente a una línea de espera con múltiples servidores.

2.5 Estudio del problema

Como método de resolución utilizaremos el Módulo Queuing Analysis (Sistemas de Cola) del software WinQSB³⁸ (Quantitative System Business)

Los datos iniciales a ingresar son:

1. Formato de entrada	Entry format
2. Unidad de tiempo	Time unit
3. Número de servidores	Number of servers
4. Tasa de servicio (por servidor, por hora)	Service rate (per server per hour)
5. Tasa de llegada de clientes (por hora)	Customer arrival rate (per hour)
6. Capacidad de la cola (Capacidad máxima) space)	Queue capacity (Maximum waiting space)
7. Tamaño de población de clientes	Customer population

Dado que no es posible determinar los costos económicos de los clientes (combatientes heridos), no se incluirán los siguientes datos relacionados:

1. Costo del servidor ocupado	Busy server cost per hour
2. Costo del servidor desocupado	Idle server cost per hour
3. Costo de espera de los clientes	Customer waiting cost per hour
4. Costo de los clientes siendo servidos	Customer being served cost per hour
5. Costo de los clientes siendo despachados	Cost of customer being balked
6. Costo unitario de capacidad de la cola	Unit queue capacity cost

De los factores de planeamiento (Anexo A), obtenemos que, el porcentaje de bajas de personal del Ejército para una Gran Unidad de Combate (GUC) de Infantería compuesta por 3.000 hombres³⁹, durante períodos de tiempo mayores a cinco días, es del 10% mensual. De este, a su vez, se desprende que: el 34% son heridos leves; el 28% heridos graves y el 34% heridos muy graves, completando el porcentaje con un 4% de muertos.

³⁸ WinQSB: Quantitative System Business. Software para uso en Investigación Operativa.

³⁹ A los fines prácticos, se determinó en 3.000 hombres la composición de la GUC de Infantería, si bien la misma puede estar compuesta por 3.000 a 5.000 combatientes.

Podemos afirmar entonces que, mensualmente, una Gran Unidad de Combate de Infantería sufre una baja de 300 combatientes aproximadamente, de los cuales 102 son heridos leves, 84 son graves, 102 son heridos muy graves y 12 son combatientes muertos.

A fin de simplificar el problema, tendremos en cuenta únicamente a los heridos graves y muy graves, considerándolos además en una única cola.

Así, nuestra población inicial (P_i) será de 186 combatientes. Con este valor de P_i , determinamos aleatoriamente la cantidad diaria de combatientes heridos para un período de 30 días⁴⁰:

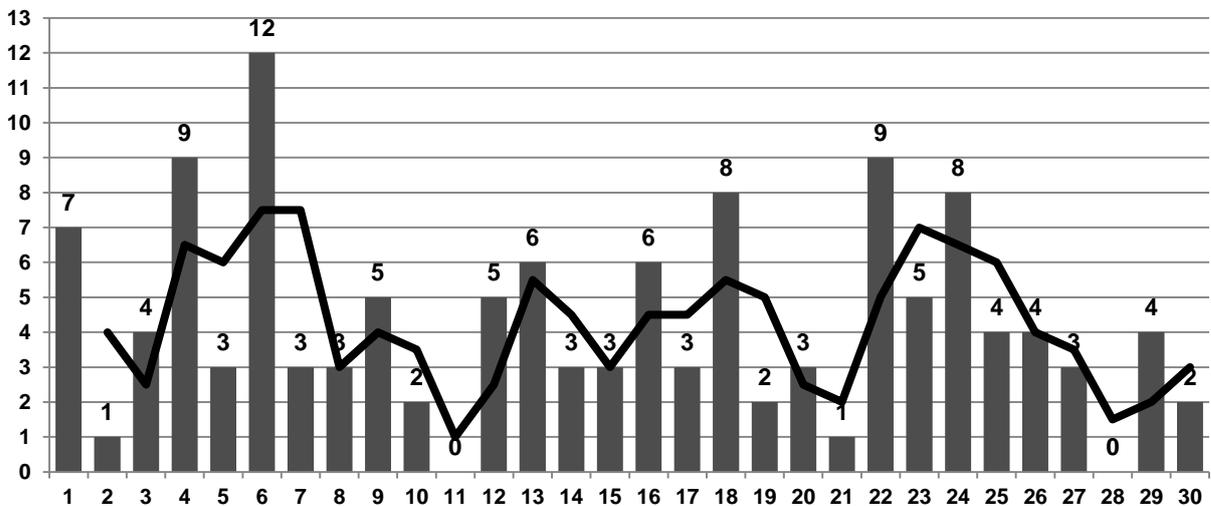


Fig. 3 – Cantidad aleatoria de combatientes heridos en un mes

Fuente: Elaboración propia

Por lo tanto, la tasa media de llegadas (λ) será estar dada por el promedio diario de heridos:

$$\lambda = P_i / \text{período tiempo (T)}$$

$$\lambda = 186 / 30 \text{ días}$$

$$\lambda = \mathbf{6,2 \text{ heridos / día}}$$

Vamos a considerar además, que la distancia total (D_t) del centro de gravedad (C_g) al hospital de campaña es de 50 kilómetros y la velocidad promedio de los vehículos sanitarios (V_c) es de 40 kms/h. De esto nos surge que la tasa media de

⁴⁰ Para determinar los valores, se utilizó la función “aleatorio.entre” de Excel.

servicio (μ) será:

$$Dt = \sum (Dm + DCg) \Rightarrow Dt = 30 \text{ km} + 20 \text{ km} \Rightarrow Dt = 50 \text{ km}$$

$$\mu = Dt / Vc$$

$$\mu = 50 \text{ kms} / 40 \text{ kms/hs}$$

$$\mu = 1,25 \text{ hs (ida)}$$

$$\mu = 2,5 \text{ hs (tiempo total de servicio)} \Rightarrow \mu = \mathbf{9,6 \text{ día}}$$

Es necesario resaltar que, para la obtención de μ , la distancia y velocidad son variables y consecuentemente pueden modificarse.

Aplicamos los datos de μ y λ al programa WinQSB, proponiendo un valor S (cantidad de servidores) igual a 2.

1. Formato de entrada	M/M/S ⁴¹
2. Unidad de tiempo	Día
3. Número de servidores (S)	2
4. Tasa de servicio (μ)	9,6
5. Tasa de llegada de clientes (λ)	6,2
6. Capacidad de la cola	M ⁴²
7. Tamaño de población de clientes	M

2.6 Resolución mediante la utilización del software WinQSB

Realizada la simulación de acuerdo a los datos ingresados, obtuvimos los siguientes resultados:

1. Tasa de ocupación del sistema (ρ)	32,29 %
2. Promedio de clientes en el sistema (L_s)	0,7210
3. Promedio de clientes en la cola (L_q)	0,0752
4. Promedio de clientes en la cola para un sistema ocupado (L_b)	0,4769
5. Tiempo promedio que un cliente pasa en el sistema (W_s)	0,0116

⁴¹ Distribución del tiempo de llegada: Poisson (M); Distribución del tiempo de servicio: Exponencial (M) y Múltiples servidores (S)

⁴² M indica un valor infinito (∞) o muy grande

6. Tiempo promedio que un cliente pasa en la cola (Wq) 0,0012
7. Promedio que un cliente pasa en la cola para un sist ocupado (Wb) 0,0077
8. Probabilidad que todos los servidores estén libres (Po) 51,18 %
9. Probabilidad que un cliente espere al llegar al sistema (Pw) 15,76 %
10. Promedio de clientes que no serán atendidos por el sistema (por día) 0

2.7 Análisis de sensibilidad

Si realizamos un análisis de sensibilidad, seleccionando como parámetro de análisis al número de servidores (S) para valores de 1 a 5, podemos observar como reacciona el sistema:

S	ρ	Ls	Lq	Lb	Ws	Wq	Wb	Po	Pw
1	64,6 %	1,8235	1,1777	1,8235	0,0294	0,0190	0,0294	0,3542	64,6 %
2	32,3 %	0,7210	0,0752	0,4769	0,0116	0,0012	0,0077	0,5118	15,8 %
3	21,5 %	0,6540	0,0082	0,2743	0,0105	0,0001	0,0044	0,5231	3,0 %
4	16,1 %	0,6467	0,0009	0,1925	0,0104	0,0000	0,0031	0,5241	0,4 %
5	12,9 %	0,6459	0,0001	0,1483	0,0104	0,0000	0,0024	0,5242	0,1 %

Tabla 2 – Análisis de sensibilidad para valores de S entre 1 y 5

Fuente: Elaboración propia

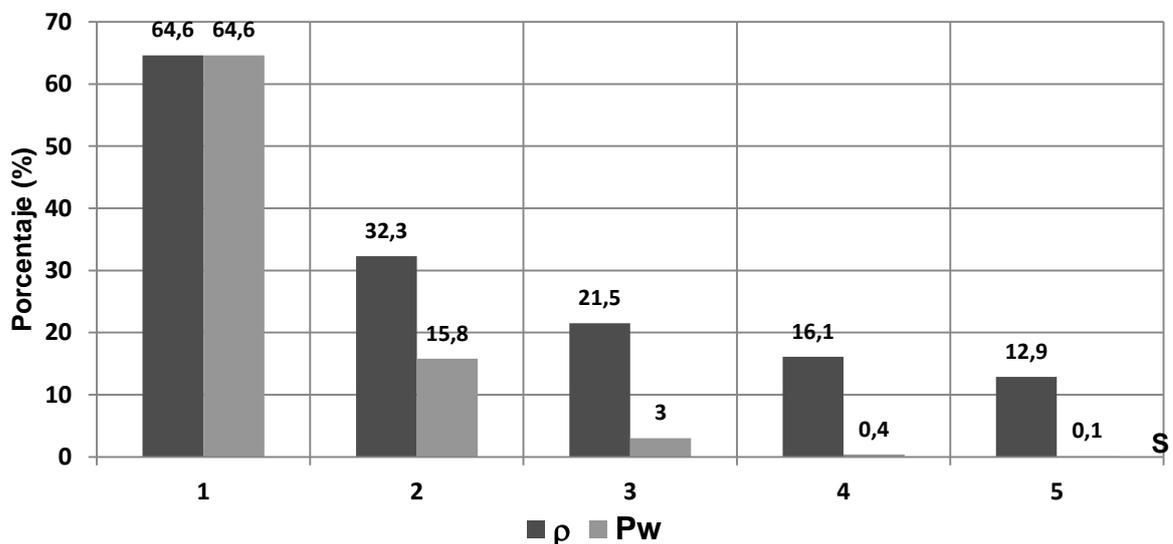


Fig. 4 – Tasa de ocupación (ρ) y probabilidad de espera (Pw) para S entre 1 y 5

Fuente: Elaboración propia

Analizados los datos resultantes y efectuado un análisis de sensibilidad, podemos concluir que:

- i. Para $S = 2$; $\mu = 9,6$ y $\lambda = 6,2$; la tasa de ocupación (ρ) del sistema (cola + servicio), es del 32,29 %, con una probabilidad de que todos los servidores estén libres (P_0) del 51,18 %. Esto es indicador que la cantidad de servidores en el sistema es elevada, pudiendo optimizarse aún más, reduciendo el valor de S a 1, siempre que éste no sea en detrimento otras medidas de desempeño a consideración.
- ii. El tiempo promedio que un cliente pasa en la cola, es de 1,7 minutos.
- iii. El promedio de clientes sin atender por el sistema por día es cero, si bien existe una probabilidad del 15,76 % de espera por parte de un herido al llegar.
- iv. Para una misma población, estos resultados podrán variar, modificando las variables tales como el número de servidores, la distancia de la zona de combate al hospital de campaña o la cantidad de camillas disponibles en el transporte sanitario.
- v. A medida que aumenta el número de servidores, disminuye la tasa de ocupación del sistema del 64,6 % para $S = 1$ a 12,9 % para $S = 5$; si bien la probabilidad que al arribo de un herido el sistema se encuentre ocupado (sin transporte sanitario) también disminuye del 64,6 % al 0,1 % para $S = 1$. Este dato es un indicador para decidir la cantidad de vehículos sanitarios necesarios para evitar el deceso de un combatiente herido.

Capítulo 3

MODELO HEURÍSTICO CON ALGORITMOS GENÉTICOS

En este capítulo nos proponemos demostrar la factibilidad de la aplicación de los algoritmos genéticos en la optimización de un problema logístico en el Teatro de Operaciones, como es la evacuación de heridos.

Mediante el análisis realizado con la Teoría de Colas, determinamos que, con una elevada tasa de ocupación, podíamos obtener una eficiente optimización del sistema, pero en desmedro de una baja probabilidad que esto podría generar en la espera de un herido por un medio de transporte sanitario.

Pudimos observar también que, del análisis de sensibilidad efectuado para valores de S entre 1 y 5, a mayor número de servidores, si bien el valor de probabilidad que un herido deba esperar al llegar al sistema (P_w), disminuye del 64,6 % al 0,1 %, también lo hace la tasa de ocupación (ρ), del 64,6 % al 12,9 %, indicándonos pues que, la solución de incluir 5 servidores en el sistema, no es la más apropiada. Por eso, trataremos de optimizar el modelo mediante la inclusión de algoritmos genéticos.

De manera similar al proceso evolutivo, primero generaremos aleatoriamente una población inicial de cromosomas⁴³ que, para nuestra simulación, será igual a 12.

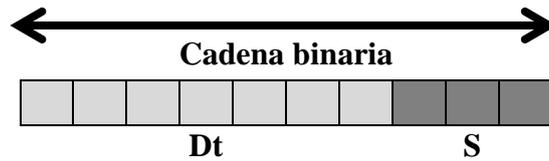
Cada cromosoma estará formado por genes que contendrán la información genética necesaria para evaluar el proceso. Luego se seleccionarán los más aptos para su reproducción, mediante la función fitness o ajuste.

La función objetivo será establecer un valor óptimo de S y D_t , para un $\rho > 70$ % y una probabilidad $P_w < 5$ %, esto es, la solución más adecuada a la cantidad de transportes sanitarios necesarios para una determinada distancia total (D_t) del centro de gravedad (C_g) al hospital de campaña.

3.1 Generación de la población inicial (P_i)

Cada cromosoma estará formado por dos cadenas binarias de 3 y 7 genes respectivamente, creando un cromosoma de 10 genes: los 3 primeros de la derecha indicarán el número de servidores (S) y los siguientes 7 genes, la distancia total (D_t).

⁴³ Potencial solución al problema.



Por lo tanto, la cadena binaria S contendrá valores entre 0 (0 0 0) y 7 (1 1 1) y la cadena Dt, entre 0 (0 0 0 0 0 0 0) y 128 (1 1 1 1 1 1 1).

Al azar, mediante la función “aleatorio.entre” de Excel, generamos una población inicial de 12 cromosomas:

Población inicial (Pi)													
Cromosoma	Distancia (kms)							Serv.	S	Distancia	Decodificación		
C ₁	0	0	0	1	1	1	0	0	1	0	2	14 kms	114
C ₂	0	0	0	1	1	1	1	0	1	0	2	15 kms	122
C ₃	0	0	1	0	0	0	1	1	1	0	6	17 kms	142
C ₄	0	1	1	0	1	1	0	1	0	1	5	54 kms	437
C ₅	0	1	1	1	0	0	1	1	0	0	4	57 kms	460
C ₆	0	1	1	1	0	0	1	1	1	1	7	57 kms	463
C ₇	1	0	0	0	1	0	1	0	0	0	0	69 kms	552
C ₈	1	0	1	0	0	1	1	0	0	0	0	83 kms	664
C ₉	1	1	0	1	0	0	1	1	0	1	5	105 kms	845
C ₁₀	1	1	0	1	1	0	0	0	0	0	0	108 kms	864
C ₁₁	1	1	0	1	1	1	1	1	0	1	5	111 kms	893
C ₁₂	1	1	1	0	1	0	0	0	1	0	2	116 kms	930

Recordamos que μ es la tasa media de servicio diaria, ρ es la tasa de ocupación del sistema y P_w es la probabilidad que un cliente espere al llegar al sistema. Esos valores fueron sometidos a la función objetivo, para determinar el puntaje de cada uno de ellos y definir su evolución a la siguiente generación (aptitud):

Cromosoma	μ	ρ	P_w	Función objetivo	Puntaje
C ₁	16,8	18,45%	5,75%	52,3	68,303 ⁴⁴
C ₂	18	99,99%	99,99%	124,98	24,255
C ₃	20,4	5,07%	0%	69,93	57,618
C ₄	64,8	1,91%	0%	73,09	55,703
C ₅	68,4	2,27%	0%	72,73	55,921
C ₆	68,4	1,29%	0%	73,71	55,327

⁴⁴ En gris oscuro: máximo puntaje poblacional.

C ₇	82,8	-----	-----	-----	-----
C ₈	99,6	-----	-----	-----	-----
C ₉	126	9,84%	0,08%	65,08	60,558 ⁴⁵
C ₁₀	129,6	-----	-----	-----	-----
C ₁₁	133,2	0,93%	0%	74,07	55,109
C ₁₂	139,2	2,28%	0,08%	72,64	55,976
Promedio Pi					54,308⁴⁶

3.2 Determinación de la función objetivo y puntaje cromosómico

Para determinar la función objetivo, nos basamos en la obtención de un valor de tasa de ocupación del sistema (ρ) mayor al 70%, lo cual nos permite evitar, mediante la redundancia de medios de evacuación, la capacidad ociosa de los medios de transporte, considerando que, en logística, los recursos son escasos; pero también establecimos una probabilidad que un cliente espere al llegar al sistema (P_w) menor al 5%, o sea, que riesgo bajo para un herido que llegué a la zona de traslado y se encuentre sin medios.

A su vez, el puntaje de cada cromosoma se determinó obteniendo el valor absoluto de la máxima diferencia entre 0 y 100 a los valores de referencia ρ y P_w respectivamente:

$$\text{Para } \rho \Rightarrow |70 - 0| = 70 \text{ (máxima diferencia)}$$

$$\text{Para } P_w \Rightarrow |5 - 100| = 95 \text{ (máxima diferencia)}$$

Sumando ambos valores tendremos:

$$\rho + P_w = 70 + 95 = 165$$

Entonces, para un valor de 100 puntos, la diferencia deberá ser igual a cero, obteniendo el puntaje óptimo. Contrariamente, una diferencia de 165 nos dará un puntaje igual a cero.

Ejemplificando, para el cromosoma C₁ de la tabla anterior, el valor de la función objetivo será:

⁴⁵ En gris claro: segundo mayor puntaje de la población

⁴⁶ En negro: puntaje medio de la población.

$$C_1 = (|70 - 18,45|) + (|5 - 5,75|) = 51,55 + 0,75 \Rightarrow C_1 = 52,30$$

Por lo tanto, si para un valor de 165 el puntaje es igual a cero, para $C_1 = 52,30$ el puntaje será:

Puntaje $C_1 = 31,70$ puntos

3.3 Evolución generacional

A continuación, se presentan únicamente las tablas con los cálculos realizados para la determinación de las generaciones 1, 5, 10, 15, 20, 25 y 30, no así las intermedias, a fin de no hacer engorrosa la presentación del trabajo. Las mismas se efectuaron introduciendo manualmente los datos en una planilla de cálculo en Excel.

Las siguientes generaciones (31 a 250) se confeccionaron con el software EVOLVER⁴⁷ de Palisade.

3.3.1 Selección

El método de selección optado para la evolución de las generaciones, es el método por rango, donde los individuos más aptos, o sea, los 2 cromosomas con mayor puntaje, luego de ser filtrados mediante la función objetivo, pasan a la siguiente generación.

3.3.2 Crossover (cruza)

Como veremos en la formación de la 1^a. Generación, luego de concebir aleatoriamente una nueva población de igual número de cromosomas, los 2 más aptos (mayor puntaje) de la población inicial (P_i) ingresarán en el intercambio de material genético de la siguiente población, mediante el operador crossover o recombinación.

Para realizar este paso, se ha seleccionado el crossover uniforme con 2 puntos de corte. Una vez determinado aleatoriamente estos 2 puntos, los genes incluídos entre

⁴⁷ El software Evolver realiza una optimización basada en algoritmos genéticos en Microsoft Excel. Esta herramienta está especialmente adaptada para encontrar la mejor solución global en problemas no-lineales complejos (<http://www.palisade-lta.com/evolver/5/tips/es/gs/>)

1ª. Generación

Cromosoma	Distancia (kms)					Serv.	S	Distancia	Decodificación				
C ₁	0	0	0	1	1	1	1	0	1	0	2	15 kms	122
C ₂	0	0	0	1	0	1	0	0	1	0	2	10 kms	82
C ₃	0	0	0	1	0	1	0	1	1	0	6	10 kms	86
C ₄	0	1	0	1	0	1	1	1	0	1	5	43 kms	349
C ₅	0	1	0	1	1	0	1	1	0	0	4	45 kms	364
C ₆	0	1	0	1	0	0	0	1	1	1	7	40 kms	327
C ₇	1	0	0	1	0	1	1	0	0	0	0	75 kms	600
C ₈	1	0	0	1	0	1	0	0	0	0	0	74 kms	592
C ₉	1	1	0	1	1	0	1	1	0	1	5	109 kms	877
C ₁₀	1	1	0	1	0	1	1	1	1	0	6	107 kms	862
C ₁₁	1	1	0	1	0	0	0	0	1	1	3	104 kms	835
C ₁₂	1	1	0	1	1	1	0	0	1	0	2	110 kms	882

Cromosoma	μ	ρ	Pw	Función objetivo	Puntaje
C ₁	18	99,99%	99,98%	124,97	24,261
C ₂	12	99,99%	99,99%	124,98	24,255
C ₃	12	86,11%	64,9%	76,01	53,933
C ₄	51,6	2,4%	0%	72,6	56,000
C ₅	54	28,7%	3,21%	43,09	73,885
C ₆	48	18,45%	0,04%	56,51	65,752
C ₇	90	-----	-----	-----	-----
C ₈	88,8	-----	-----	-----	-----
C ₉	130,8	0,95%	0%	74,05	55,121
C ₁₀	128,4	0,8%	0%	-----	-----
C ₁₁	124,8	1,66%	0%	73,34	55,552
C ₁₂	132	23,48%	8,93%	50,45	69,424
Promedio 1G					53,131

Luego de realizar las generaciones 2 a 4, obtuvimos la 5ª. Generación, con padres provenientes de la 4ª. Generación. Posteriormente, se muestran las tablas para las generaciones 10, 15, 20, 25 y 30.

5ª. Generación

Padre C ₃ (4G)											
0	0	0	1	0	0	1	1	0	0	1	5
Madre C ₁₀ (4G)										9	12
1	1	0	1	0	0	1	1	0	1	6	10

Cromosoma	Distancia (kms)	Serv.	S	Distancia	Decodificación
C ₁	0 1 0 1 0	1 1 1 0 0	4	43 kms	348
C ₂	1 0 0 1 0	1 1 1 1 0	6	75 kms	606
C ₃	0 0 0 1 0	0 1 1 0 0	4	9 kms	76
C ₄	1 1 0 1 0	0 1 1 0 0	4	105 kms	844
C ₅	0 1 0 1 0	1 1 1 1 0	6	43 kms	350
C ₆	0 1 0 1 0	0 1 1 1 0	6	41 kms	334
C ₇	1 1 0 1 0	1 1 1 0 0	4	107 kms	860
C ₈	0 1 0 1 0	0 1 1 0 0	4	41 kms	332
C ₉	0 0 0 1 0	1 1 1 0 1	5	11 kms	93
C ₁₀	0 1 0 1 0	0 1 1 0 0	4	41 kms	332
C ₁₁	1 0 0 1 0	1 1 1 1 0	6	75 kms	606
C ₁₂	1 0 0 1 0	1 1 1 0 1	5	75 kms	605

Cromosoma	μ	ρ	Pw	Función objetivo	Puntaje
C ₁	51,6	3%	0%	72	56,364
C ₂	90	11,48%	0,01%	63,51	61,509
C ₃	10,8	14,35%	0,3%	60,35	63,424
C ₄	126	12,3%	0,17%	62,53	62,103
C ₅	51,6	2%	0%	73	55,758
C ₆	49,2	2,1%	0%	72,9	55,818
C ₇	128,4	1,21%	0%	73,79	55,279
C ₈	49,2	3,15%	0%	71,85	56,455
C ₉	13,2	9,39%	0,01%	65,6	60,242
C ₁₀	49,2	3,15%	0%	71,85	56,455
C ₁₁	90	11,48%	0,01%	63,51	61,509
C ₁₂	90	13,78%	0,08%	61,14	62,945
				Promedio 5G	58,988

10ª. Generación

Padre C ₇ (9G)											
1	0	0	1	0	1	1	1	0	0	2	10
Madre C ₃ (9G)											
0	0	0	1	0	0	1	1	0	0	9	10

Cromosoma	Distancia (kms)	Serv.	S	Distancia	Decodificación
C ₁	0 0 0 1 0 0 1 1 0 0		4	9 kms	76
C ₂	0 0 0 1 0 0 1 1 1 1		7	9 kms	79
C ₃	0 0 0 1 0 1 1 1 0 0		4	11 kms	92
C ₄	0 0 0 1 0 0 1 1 0 0		4	9 kms	76

C ₅	0	0	0	1	0	0	1	1	0	0	4	9 kms	76
C ₆	0	0	0	1	0	0	1	1	0	0	4	9 kms	76
C ₇	1	0	0	1	0	1	1	1	0	0	4	75 kms	604
C ₈	1	0	0	1	0	1	1	1	1	1	7	75 kms	607
C ₉	1	0	0	1	0	1	1	1	0	0	4	75 kms	604
C ₁₀	1	0	0	1	0	1	1	1	0	0	4	75 kms	604
C ₁₁	1	0	0	1	0	1	1	1	0	0	4	75 kms	604
C ₁₂	1	0	0	1	0	0	1	1	0	0	4	73 kms	588

Cromosoma	μ	ρ	Pw	Función objetivo	Puntaje
C ₁	10,8	14,36%	0,3%	60,34	63,430
C ₂	10,8	8,2%	0%	66,8	59,515
C ₃	13,2	11,74%	0,14%	63,12	61,745
C ₄	10,8	14,36%	0,3%	60,34	63,430
C ₅	10,8	14,36%	0,3%	60,34	63,430
C ₆	10,8	14,36%	0,3%	60,34	63,430
C ₇	90	17,22%	0,57%	57,21	65,327
C ₈	90	9,84%	0%	65,16	60,509
C ₉	90	17,22%	0,57%	57,21	65,327
C ₁₀	90	17,22%	0,57%	57,21	65,327
C ₁₁	90	17,22%	0,57%	57,21	65,327
C ₁₂	87,6	1,77%	0%	73,23	55,618
Promedio 10G					62,702

15ª. Generación

Padre C₅ (14G)											
1	0	0	1	0	1	1	1	0	0	4	10
Madre C₁₂ (14G)											
1	0	1	0	1	0	1	1	0	0	5	9

Cromosoma	Distancia (kms)			Serv.	S	Distancia	Decodificación						
C ₁	1	1	1	0	0	0	1	1	1	0	6	113 kms	910
C ₂	0	1	1	0	1	1	1	1	0	0	4	55 kms	444
C ₃	0	1	0	0	1	0	1	1	0	0	4	37 kms	300
C ₄	0	0	0	0	0	0	1	1	0	0	4	1 kms	12
C ₅	0	0	0	1	1	1	1	1	0	0	4	15 kms	124
C ₆	0	1	0	0	0	0	1	1	0	0	4	33 kms	268
C ₇	1	0	1	0	0	0	1	1	0	0	4	81 kms	652
C ₈	0	1	0	0	1	0	1	1	1	0	6	37 kms	302
C ₉	1	0	0	1	1	0	1	1	0	0	4	77 kms	620

C ₁₀	0	0	1	0	0	1	1	1	0	0	4	19 kms	156
C ₁₁	1	1	1	1	0	0	1	1	0	0	4	121 kms	972
C ₁₂	1	0	1	1	0	1	1	1	0	0	4	91 kms	732

Cromosoma	μ	ρ	Pw	Función objetivo	Puntaje
C ₁	135,6	0,76%	0%	74,24	55,006
C ₂	66	23,48%	1,66%	49,86	69,782
C ₃	44,4	3,49%	0%	71,51	56,661
C ₄	1,2	99,98%	99,97%	124,95	24,273
C ₅	18	86,11%	71,07%	82,18	50,194
C ₆	39,6	3,91%	0%	71,09	56,915
C ₇	97,2	1,59%	0%	73,41	55,509
C ₈	44,4	2,33%	0%	72,67	55,958
C ₉	92,4	1,68%	0%	73,32	55,564
C ₁₀	22,8	6,8%	0,02%	68,18	58,679
C ₁₁	145,2	1,07%	0%	73,93	55,194
C ₁₂	109,2	1,42%	0%	73,58	55,406
Promedio 15G					54,095

20ª. Generación

Padre C₁₂ (19G)												
1	0	0	0	1	1	0	0	1	0		2	3
Madre C₄ (19G)											3	9
0	0	0	1	1	1	0	0	1	0		2	7

Cromosoma	Distancia (kms)										Serv.	S	Distancia	Decodificación
C ₁	1	0	0	1	0	0	1	0	0	0	0	0	73 kms	584
C ₂	1	0	0	1	0	1	1	0	0	0	0	0	75 kms	600
C ₃	0	1	0	1	1	1	0	1	0	0	4	4	46 kms	372
C ₄	1	0	0	1	0	1	1	0	1	0	2	2	75 kms	602
C ₅	0	0	0	0	0	0	0	1	1	1	7	7	0 kms	7
C ₆	1	0	0	1	1	1	1	0	1	1	3	3	79 kms	635
C ₇	1	0	0	1	0	0	1	0	1	0	2	2	73 kms	586
C ₈	0	0	0	1	1	0	0	0	1	1	3	3	12 kms	99
C ₉	0	1	0	1	0	1	1	1	1	1	7	7	43 kms	351
C ₁₀	0	0	0	0	1	1	1	0	1	0	2	2	7 kms	58
C ₁₁	1	0	0	1	0	1	0	0	0	0	0	0	74 kms	592
C ₁₂	1	0	0	1	1	0	1	0	1	0	2	2	77 kms	618

Cromosoma	μ	ρ	Pw	Función objetivo	Puntaje
C ₁	87,6	-----	-----	-----	-----
C ₂	90	-----	-----	-----	-----
C ₃	55,2	2,8	0	72,2	56,242
C ₄	90	34,4	17,7	48,3	70,727
C ₅	0	-----	-----	-----	-----
C ₆	94,8	2,18	0	72,82	55,867
C ₇	87,6	3,54	0,24	71,22	56,836
C ₈	14,4	14,35	1	59,65	63,848
C ₉	51,6	1,72	0	73,28	55,588
C ₁₀	8,4	36,9	19,9	48	70,909
C ₁₁	88,8	-----	-----	-----	-----
C ₁₂	92,4	3,36	0,22	71,42	56,715
Promedio 20G					60,842

25ª. Generación

Padre C ₁₁ (24G)												
0	0	1	0	0	0	0	0	1	1		2	5
Madre C ₉ (24G)												
0	0	1	0	0	0	0	0	0	1		1	2

25ª. Generación													
Cromosoma	Distancia (kms)					Serv.			S	Distancia	Decodificación		
C ₁	0	0	1	0	0	0	1	0	0	1	1	17 kms	137
C ₂	1	1	1	0	0	1	0	0	1	1	3	114 kms	915
C ₃	0	0	1	0	0	0	1	0	1	1	3	17 kms	139
C ₄	1	0	1	0	0	0	1	0	1	1	3	81 kms	651
C ₅	0	0	1	0	0	1	1	1	1	0	6	19 kms	158
C ₆	1	0	1	0	0	1	1	1	1	0	6	83 kms	670
C ₇	0	1	1	0	0	1	1	1	0	0	4	51 kms	412
C ₈	1	0	1	0	0	1	1	0	1	1	3	83 kms	667
C ₉	1	0	1	0	0	0	0	1	0	0	4	80 kms	644
C ₁₀	1	0	1	0	0	1	1	0	0	0	0	83 kms	664
C ₁₁	1	0	1	0	0	0	1	0	0	0	0	81 kms	648
C ₁₂	1	0	1	0	0	0	0	0	0	1	1	80 kms	641

Cromosoma	μ	ρ	Pw	Función objetivo	Puntaje
C ₁	20,4	30,39	30,39	65	60,606
C ₂	136,8	1,51	0	73,49	55,461
C ₃	20,4	10,13	0,38	64,49	60,915

C ₄	97,2	2,13	0	72,87	55,836
C ₅	22,8	4,53	0	70,47	57,291
C ₆	99,6	1,04	0	73,96	55,176
C ₇	61,2	2,53	0	72,47	56,079
C ₈	99,6	2,07	0	72,93	55,800
C ₉	96	16,15	0,45	58,4	64,606
C ₁₀	99,6	-----	-----	-----	-----
C ₁₁	97,2	-----	-----	-----	-----
C ₁₂	96	64,58	64,58	65	60,606
Promedio 25G					58,238

30^a. Generación

Padre C₄ (29G)												
0	1	0	1	0	1	1	0	0	1		2	3
Madre C₇ (29G)											2	6
0	1	0	1	0	1	0	1	1	0		1	3

30 ^a . Generación														
Cromosoma	Distancia (kms)										Serv.	S	Distancia	Decodificación
C ₁	0	0	0	1	0	1	1	0	0	1	1	11 kms	89	
C ₂	1	1	0	0	0	0	1	1	0	0	4	97 kms	780	
C ₃	1	0	0	0	1	0	0	0	1	1	3	68 kms	547	
C ₄	0	1	0	0	1	1	0	1	1	0	6	38 kms	310	
C ₅	1	1	0	1	1	1	1	1	1	0	6	111 kms	894	
C ₆	0	0	1	0	1	1	1	0	0	0	0	23 kms	184	
C ₇	1	0	1	0	0	1	0	0	0	0	0	82 kms	656	
C ₈	1	1	1	1	0	1	0	1	1	0	6	122 kms	982	
C ₉	0	1	0	0	0	1	0	0	1	1	3	34 kms	275	
C ₁₀	1	1	1	1	1	1	1	0	1	1	3	127 kms	1019	
C ₁₁	0	0	1	1	1	0	0	1	0	0	4	28 kms	228	
C ₁₂	0	1	0	0	0	1	1	1	0	1	5	35 kms	285	

Cromosoma	μ	ρ	Pw	Función objetivo	Puntaje
C ₁	13,2	46,97	46,97	65	60,606
C ₂	116,4	1,33	0	73,67	55,352
C ₃	81,6	2,53	0	72,47	56,079
C ₄	45,6	2,27	0	72,73	55,921
C ₅	133,2	0,78	0	74,22	55,018
C ₆	27,6	-----	-----	-----	-----
C ₇	98,4	-----	-----	-----	-----

C ₈	146,4	0,71	0	74,29	54,976
C ₉	40,8	5,07	0,05	69,88	57,648
C ₁₀	152,4	1,36	0	73,64	55,370
C ₁₁	33,6	4,61	0	70,39	57,339
C ₁₂	42	29,52	1,89	43,59	73,582
Promedio 30G					48,491

El gráfico siguiente, nos muestra el modelo evolutivo de los 2 puntajes más altos y la media, para las 30 primeras generaciones. Aquí puede observarse que la evolución aún no muestra signos de optimización debido al escaso proceso iterativo⁴⁹.

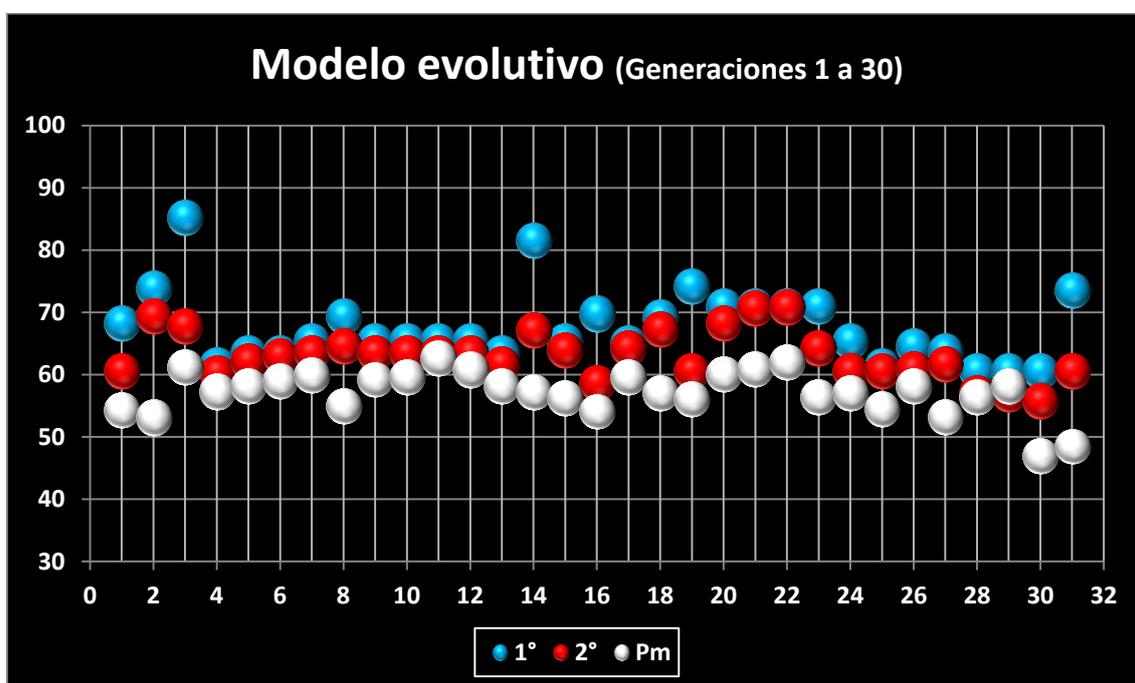


Fig. 5 – Modelo evolutivo (Generaciones 1 a 30)

Fuente: Elaboración propia

Por ello, como se indicó anteriormente, las soluciones a las sucesivas generaciones (31 a 250) se realizaron mediante el software EVOLVER, con un criterio de finalización en 250 generaciones.

En el gráfico de estabilización podemos observar como, a medida que el proceso genético evolutivo avanza, el sistema adquiere una tendencia a la optimización, permitiéndonos satisfacer la ecuación a nuestro problema.

⁴⁹ Un proceso iterativo, trata de resolver un problema (como una ecuación o un sistema de ecuaciones) mediante aproximaciones sucesivas a la solución, empezando desde una estimación inicial.

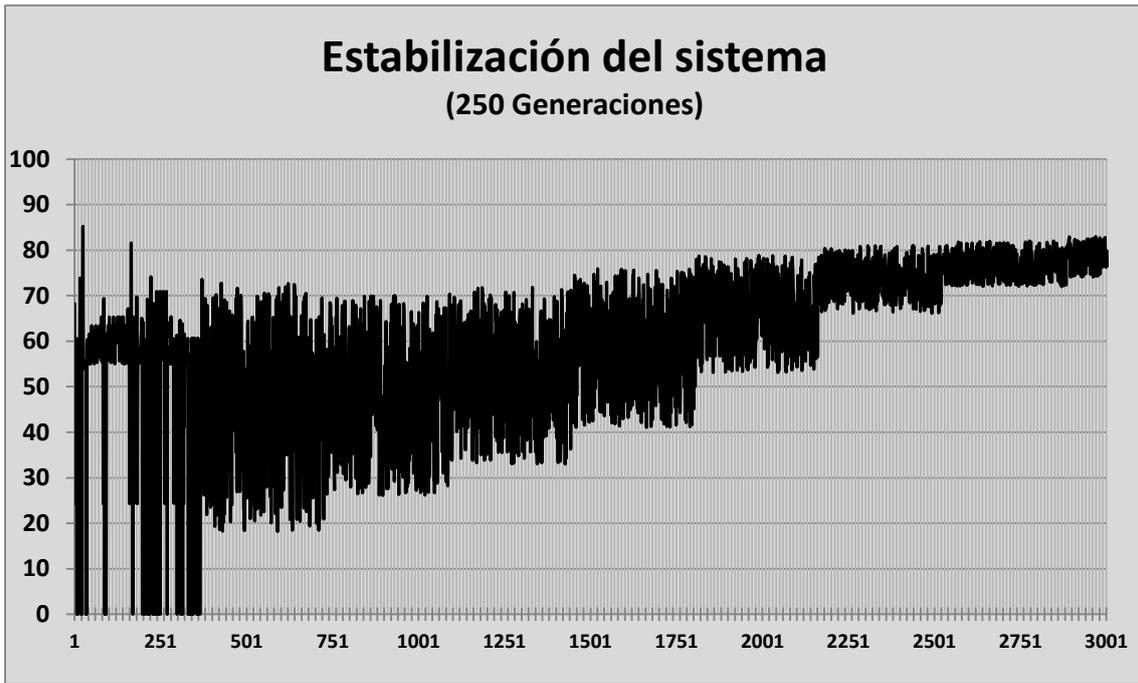


Fig. 6 – Estabilización del sistema (250 generaciones)

Fuente: Elaboración propia

Del mismo modo, se pueden distinguir el proceso evolutivo de los valores máximos y medios, en las 250 generaciones concebidas.

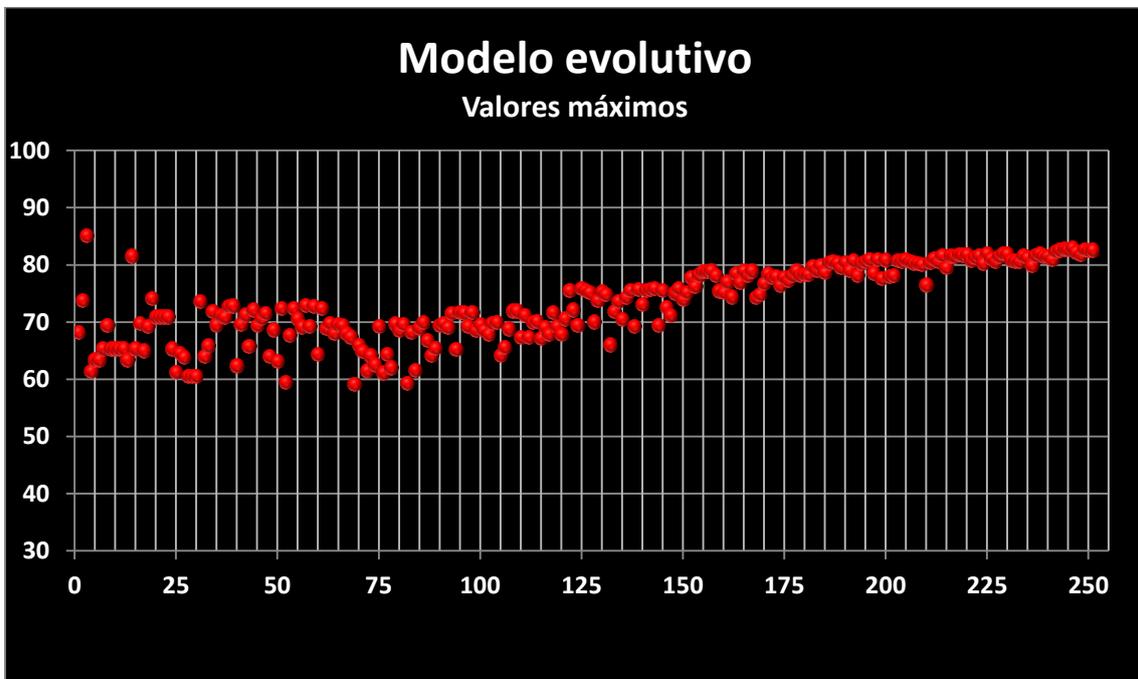


Fig. 7 – Modelo evolutivo de valores máximos

Fuente: Elaboración propia



Fig. 8 – Modelo evolutivo de valores promedios

Fuente: Elaboración propia

CONCLUSIONES

Este trabajo nos permitió, mediante la inclusión de factores de planeamiento logístico, diseñar un modelo de simulación mediante la aplicación de la Teoría de Colas y Algoritmos Genéticos y evaluar así el comportamiento temporal de los elementos de sanidad en un Teatro de Operaciones.

La Teoría de Colas y los algoritmos genéticos, son herramientas poderosas para la resolución de problemas de optimización y desarrollo, a través de la modelación de sistemas de simulación de procesos que, aunque inexactas, se aproximan bastante a las reales. Esta factibilidad, permite resolver situaciones, en ocasiones, de alta complejidad.

Este trabajo ha pretendido demostrar la eficiencia y ventajas de la utilización de técnicas de investigación operativa, específicamente la heurística, trabajando con poblaciones de potenciales soluciones, para resolver problemas difusos e indefinidos. Un sencillo ejemplo ha sido utilizado para demostrar la validez del algoritmo y sus múltiples aplicaciones, acompañada de una adecuada herramienta computacional.

De esta manera, se ha tratado de resolver un problema complejo real, mediante el diseño de un modelo de simulación evolutivo, para la obtención óptima del número de medios de transporte sanitarios terrestres desde la zona de combate hacia un hospital de campaña, teniendo en consideración la prioridad de evacuación de heridos, seleccionados mediante el método Triage.

Como conclusión, podemos señalar que éste tipo de procedimiento, concibe una opción para la resolución de problemas militares, mediante un nuevo método para la toma de decisiones, ante incertidumbres en un Teatro de Operaciones, como alternativa a los métodos tradicionales.

Esta situación particular se centra en el hecho que, a través de la simulación, no se pone en riesgo factores tan importantes como el humano y económico, con la posibilidad además, de realizar todas las modificaciones a los parámetros y variables que logren adaptarse a las necesidades temporales, a fin de obtener el resultado óptimo más adecuado.

Por último, debemos indicar que, además de cumplirse los objetivos estipulados, los resultados obtenidos mediante la experimentación y escenarios propuestos, han sido de valor para la apertura de nuevas líneas de investigación, no solo dentro del área logística, sino también operativa y específica del ámbito militar.

BIBLIOGRAFÍA

Libros

- CHASE, “*Administración de producción y operaciones*”, Cap. 5. 8ª. Edición, Ed. Irwin McGraw Hill
- DARWIN CHARLES, “*On the origin of species by means of natural selection or the preservation of favoured races in the struggle for life*”.1ª. Edición, Ed. John Murray, UK, 24 de noviembre de 1859.
- JOLY F., “*La cartografía*”. Ed. Oikos-Tau, Barcelona, España. 1988
- MOTTOX K., “*Trauma*”, 4ª. Edición, Ed. McGraw Hill, New York, EU, 2000
- RÍOS S., “*La modelización*”. Alianza Ediciones, Madrid, España, 1995
- TAHA HAMDY, “*Investigación de operaciones*”, 7ª. Edición, Ed. Pearson Educación, México, 2004
- VÉNTSEL E., “*Elementos de la teoría de los juegos*”, Ed. Mir, Moscú, 1977
- VERGARA SCHMALBACH JUAN CARLOS; FONTALBO HERRERA TOMÁS; MORELOS GÓMEZ JOSÉ, “*Simulación de líneas de espera empleando dinámica de sistemas*”, Ed. Eumed, 2011
- WINSTON WAYNE, “*Investigación de operaciones*”, 4ª. Edición, Ed. Thompson, México, 2005

Manuales

- MUÑOZ DAVID, “*Manual de estadística*”, Ed. Eumed, 2004
- ORGANIZACIÓN PANAMERICANA PARA LA SALUD (OPS/OMS), “*Manual para la implementación de un sistema de triage para los cuartos de urgencia*”. Washington DC. Diciembre 2010
- ROJAS JAIRO, “*Manual de atención prehospitalaria (APH)*”. Yopal, Colombia, 2003

Monografías

- BARCELÓ JAIME, “*Simulación de sistemas discretos*”, 1ª. Edición, Ed. Isdefe, Madrid, España, 1996.
- BERTONA LUIS, “*Entrenamiento de redes neuronales basado en algoritmos*”

- genéticos*”. Facultad de Ingeniería, Universidad de Buenos Aires. Noviembre 2005.
- CASTILLO IGNACIO, “*Algoritmos genéticos aplicados a la gestión de inventarios de artículos no perecederos*”. Universidad de Morón, Buenos Aires, Argentina, 2004.

Páginas Web

- ANDALUZ ALFONSO, “*Inteligencia en redes de comunicaciones*”, Universidad Carlos III, Madrid, España (<http://www.it.uc3m.es/jvillena/irc/>)
- COMPUTATION INTELLIGENCE CAR EVOLUTION USING BOX2D PHYSICS (v3.2) (www.boxcar2d.com/index.html)
- NATIONAL INSTITUTE FOR CLINICAL EXCELLENCE, “*Trastorno de estrés postraumático (TEPT)*”, Centro Nacional Colaborador en Salud Mental, London, UK. Guía clínica 26, Marzo 2005 (<http://www.nice.org.uk/CG26>)
- NORTH AMERICAN RESCUE. Tactical Combat Casualty Care (TCCC) (http://www.narescue.com/Tactical_Combat_Casualty_Care.htm)

Reglamentos

- PUBLICACIÓN CONJUNTA PC 14-01. “*Logística personal para la acción militar conjunta*”. Ministerio de Defensa, Estado Mayor Conjunto de las Fuerzas Armadas, Argentina. (1987)
- PUBLICACIÓN CONJUNTA PC 14-02. “*Logística material para la acción militar conjunta*”. Ministerio de Defensa, Estado Mayor Conjunto de las Fuerzas Armadas, Argentina. (2006)
- PUBLICACIÓN CONJUNTA PC 14-04. “*Logística transporte para la acción militar conjunta*”. Ministerio de Defensa, Estado Mayor Conjunto de las Fuerzas Armadas, Argentina. (2007)
- PUBLICACIÓN CONJUNTA PC 24-04. “*Logística personal sanidad para la acción militar conjunta*”. Ministerio de Defensa, Estado Mayor Conjunto de las Fuerzas Armadas, Argentina. (2007)

Revistas

- PARISI ANTONINO, “*Modelos de algoritmos genéticos y redes neuronales en la predicción de índices bursátiles asiáticos*”. Universidad de Chile. Cuadernos de

Economía, Vol. 43 (noviembre), N° 128, pp. 251-284, 2006

- SATO, S., K. Otori, A. Takizawa, H. Sakai, Y. Ando y H. Kawamura. “*Applying genetic algorithms to the optimum design of a concert hall*” Journal of Sound and Vibration, vol.258, no.3, p. 517-526, 2002

Tesis y trabajos de investigación

- ALONSO ZOTES FERNANDO, “*Aplicación de algoritmos inteligentes en problemas aeroespaciales*”. Departamento Arquitectura de Computadores y Automática, Facultad de Informática, Universidad Complutense de Madrid, España. 2010
- CASTILLO ENRIQUE, “*Formulación y resolución de modelos de programación matemática en ingeniería y ciencia*”, España, 2002
- CASTRO MORA JOSÉ, “*Optimización global de parques eólicos mediante algoritmos genéticos*”. Departamento de Ingeniería Eléctrica, Universidad de Sevilla, España. 22 septiembre 2008
- CHAVOLLA CANAL EDGAR, “*Algoritmos genéticos modificados para el balance de robots humanoides*”. Departamento de Electrónica, Centro Universitario de Ciencias Exactas de Ingenierías, Universidad de Guadalajara, Jalisco, México. Febrero 2010
- COELLO COELLO CARLOS, SANTOS HERNANDEZ FILIBERTO, ALONSO FARRERA FRANCISCO, “*Diseño óptimo de vigas de concreto reforzado mediante algoritmos genéticos*”. Escuela de Ingeniería Civil, Universidad Autónoma de Chiapas, México, 1995
- COLMENARES ADRIANA, “*Reconocimiento de patrones aplicando algoritmos genéticos y redes neuronales aleatorias*”. Escuela de Ingeniería de sistemas, Facultad de Ingeniería, Universidad de Los Andes, Venezuela. 16 octubre 2008
- CONTRERAS RICARDO, “*Sistemas de apoyo a procesos productivos en Pymes: un caso de aplicación*”. Departamento de Ingeniería Informática y Ciencias de la Computación, Facultad de Ingeniería, Universidad de Concepción, Chile.
- CRAVO CRISTOFER, “*Diseño y optimización de columnas de pared dividida extractivas utilizando algoritmos genéticos*”. Universidad de Guanajuato, México, 13 marzo 2009
- FERNANDEZ PEREZ-RENDÓN ANTONIO LUIS, “*Formulación generalizada de*

- la interferometría estelar de Speckles. Reconstrucción en el dominio espacial mediante algoritmos genéticos*". Universidad de La Laguna, España, 1993
- FISZELEW ABEL, "*Generación automática de redes neuronales con ajuste de parámetros basado en algoritmos genéticos*". Facultad de Ingeniería, Universidad de Buenos Aires, Argentina. Febrero 2002
 - GESTAL POSE MARCOS, "*Introducción a los algoritmos genéticos*". Universidad da Coruña, España
 - JUÁREZ MORALES RAÚL, "*Exponenciaciones modulares usando algoritmos genéticos con representación entera*". Facultad de Matemáticas, Universidad Autónoma de Guerrero, México. 13 octubre 2006
 - LEGERÉN ÁLVAREZ JAIME, "*Introducción a los algoritmos genéticos*". Madrid, Mayo-Junio 2012
 - MERELO GUERVÓS JUAN, "*Informática evolutiva: algoritmos genéticos*"
 - MORA GARCÍA ANTONIO, "*Resolución del problema militar de búsqueda de camino óptimo multiobjetivo mediante el uso de algoritmos de optimización basados en colonias de hormigas*". Departamento de Arquitectura y Tecnología de Computadores, Universidad de Granada, España, 2009
 - MORATO IZQUIERDO MARÍA DEL CARMEN, "*Algoritmos genéticos. Aplicación al análisis de secuencias en biología molecular*". Universidad Politécnica de Madrid, España, 1999
 - NESMACHNOW SERGIO, "*Algoritmos genéticos paralelos y su aplicación al diseño de redes de comunicaciones confiables*". Instituto de comunicación, Facultad de Ingeniería, Universidad de la República de Montevideo, Uruguay. Julio 2004
 - PINO DE LOS REYES VÍCTOR, "*Algoritmos genéticos con codificación real en la optimización de funciones de una variable real*". Centro Universitario Las Tunas, Las Tunas. Mayo 2009
 - RODRIGUEZ PIEDAD, "*Introducción a los algoritmos genéticos y sus aplicaciones*".
 - WILL ADRIAN, "*Algoritmos genéticos y optimización heurística*". Univ. Tucumán

Anexo A

FACTORES DE PLANEAMIENTO

A.1 Cálculo de bajas de personal del Ejército

La siguiente tabla contiene datos referentes al cálculo de bajas de personal del Ejército, para largos períodos de tiempo (más de cinco días), obtenidos de la Publicación Conjunta PC 24-01 “Normas y procedimientos logísticos para la Acción Militar Conjunta – Área Personal” – Anexo 3, Art. 2.02.3.

A.2 Porcentaje de bajas mensuales de personal

Unidad	% Bajas de combate	% Bajas no producidas en combate
Gran Unidad de Combate (GUC) de Infantería	10,00 %	8,00 %
Gran Unidad de Combate (GUC) Blindada	8,00 %	7,00 %
Formaciones del Cuerpo de Ejército y Ejército	1,25 %	3,00 %

Tabla 3 – Porcentaje mensual de bajas para largos períodos de tiempo

Fuente: PC 24-01 Normas y procedimientos logísticos para la AMC

A.3 Discriminación de bajas

De acuerdo al Apéndice 4 del Anexo 2, Tabla IV de la publicación Publicación Conjunta PC 24-01 “Normas y procedimientos logísticos para la Acción Militar Conjunta – Área Personal”, a continuación se detallan las bajas en combate (heridos), discriminadas según el período de recuperación, y que aplicaremos en la simulación, considerando además, como factor de planeamiento, los siguientes datos:

Alta antes de 30 días	Heridos leves
Alta entre 30 y 90 días	Heridos graves
Alta después de 90 días	Heridos muy graves

Bajas	En combate	Muertos	-----	
		Heridos	Alta antes de 30 días	34 %
			Alta entre 30 y 90 días	28 %
			Alta después de 90 días	34 %
	Muertos		4 %	
	Desaparecidos			
	No producidas en combate	-----		

Tabla 4 - Discriminación de bajas de combate

Fuente: PC 24-04 Logística – Personal – Sanidad para la Acción Militar Conjunta

Anexo B

SELECCIÓN Y CLASIFICACIÓN DEL MÉTODO TRIAGE

B.1 Definición de Triage

El término Triage define al método sanitario utilizado en combate, desastres o en emergencias hospitalarias, para la selección y clasificación de pacientes, basándose en la prioridad de atención de heridos o víctimas de gravedad y la capacidad de recursos disponibles, que posibiliten su supervivencia. Esta valoración clínica preliminar puede realizarse tanto por personal médico como de enfermería quien, de acuerdo al diagnóstico, clasifica a los pacientes mediante un color. Para identificar a los pacientes, se le coloca en el cuello una tarjeta del color correspondiente, que lo acompañará hasta su traslado a la unidad hospitalaria.

El Triage no es una técnica, sino una necesidad determinada por:

- Número de heridos
- Naturaleza de las lesiones
- Probabilidad de supervivencia
- Recursos sanitarios disponibles
- Cantidad de medios de transporte
- Distancia al centro de atención médica

B.2 Tiempos de clasificación de heridos en combate

La clasificación debe ser completa (ninguna víctima puede evacuarse sin ser clasificada), precisa, segura y rápida para no demorar su evacuación. Los tiempos aproximados para esta tarea son:

Clasificación	Tiempo
Muerto	30 segundos
Herido leve	1 minuto
Herido muy grave o grave	3 minutos

Tabla 5 – Tiempos de clasificación según el Método Triage

Fuente: Sociedad Española de Medicina de Urgencias y Emergencias (<http://www.semes.org/>)

El primero en utilizar este término fue el barón Dominique-Jean Larrey (1766-1842), médico cirujano militar, jefe de los servicios sanitarios del ejército de Napoleón, que empezó a utilizarlo como un sistema de clasificación para tratar a los heridos en el campo de batalla.

Durante la Segunda Guerra Mundial, se generalizó el uso de ambulancias motorizadas para desplazar a los heridos más graves, clasificando previamente a las víctimas.

El sistema continuó evolucionando, y en la década del 70', en Estados Unidos, surgió el concepto de "Víctima de trauma mayor" por el cual, a mayor complejidad, mayor debía ser el nivel del centro de atención.

En la década del 90', se establece un verdadero sistema para el manejo del paciente, víctima de un trauma mayor, incluyendo desde la legislación hasta la provisión de los recursos económicos para su desarrollo, además de la interacción de los diferentes niveles de atención.

Actualmente, el método se ha generalizado en todo el mundo, con sutiles diferencias en cuanto a los niveles de clasificación. Nosotros utilizaremos la "Triage Scale Standardization" (TSS) basada en cinco niveles, utilizada en los Estados Unidos por recomendación de la ENA (Emergency Nurses Association) y el ACEP (American College of Emergency Physicians).

B.3 Sistema de clasificación Mettag

La clasificación de los pacientes se efectúa colocando en el cuerpo una tarjeta con un color identificador. Uno de los sistemas de clasificación más comunes es el Mettag⁵⁰, basado en el criterio de prioridad de evacuación a nivel superior de asistencia, desarrollado por un grupo de médicos, enfermeras y bomberos en el año 1984:

⁵⁰ Mettag: Medical Emergency Triage Tag

Color	Nivel de gravedad	Atención
Azúl	Cadáver	-----
Negro	Paciente “exitus”, con nula capacidad de recuperación	-----
Rojo	Pacientes críticos con lesiones muy graves pero con posibilidades de supervivencia	Inmediata
Amarillo	Paciente con lesiones graves, pero sin riesgo vital inmediato	Urgente
Verde	Paciente con lesiones leves, que no precisan asistencia médica inmediata y pueden ser trasladados en vehículos no sanitarios	Menor

Tabla 6 – Clasificación del Sistema Mettag

Fuente: Sociedad Española de Medicina de Urgencias y Emergencias (<http://www.semes.org/>)

Anexo C

MODELOS DE LÍNEAS DE ESPERA

C.1 Introducción a la Teoría de Colas o Líneas de Espera

La Teoría de Colas fue desarrollada por Agner Kraup Erlang (Dinamarca, 1878-1929) en 1909, para analizar la congestión de tráfico telefónico con el objetivo de cumplir la demanda incierta de servicios en el sistema de Copenhague. Sus investigaciones acabaron en una nueva teoría denominada Teoría de Colas o de líneas de espera.

La importancia de un sistema de colas está dada por su comportamiento mediante el estudio matemático. Este se presenta cuando los clientes arriban al lugar, demandando un servicio a un servidor, el cual tiene una cierta capacidad de atención. Si el servidor no está disponible, el cliente decide esperar y por lo tanto se forma una línea de espera.

C.2 Medidas de desempeño en un sistema de colas

Mediante fórmulas y relaciones matemáticas, pueden obtenerse determinadas características de operación:

λ	Tasa media de llegadas (número de llegadas por unidad de tiempo)
$1/\lambda$	Tiempo medio entre llegadas
μ	Tasa media de servicio (número de clientes servidos por unidad de tiempo cuando el servidor está ocupado)
$1/\mu$	Tiempo medio requerido para prestar el servicio
ρ	Factor de utilización del servidor (% de tiempo que el servidor está ocupado)
P_n	Probabilidad que n clientes se encuentren en el sistema
P_0	Probabilidad que no existan clientes en el sistema
L_q	Número promedio de clientes en la cola (longitud de la cola)
L_s	Número promedio de clientes en el sistema (número de clientes que esperan en la cola más el número de clientes que reciben el servicio)
W_q	Tiempo promedio de permanencia en la cola

- W_s Tiempo promedio de permanencia en el sistema
- $W_q(t)$ Probabilidad que un cliente permanezca más de t unidades de tiempo en la cola (antes que comience el servicio)
- $W_s(t)$ Probabilidad que un cliente permanezca más de t unidades de tiempo en el sistema (tiempo total de espera en la cola más el de servicio)

Esta información permitirá desarrollar un procedimiento que proporcione una respuesta adecuada para la toma de decisiones. A efectos de mantener la simbología utilizada en la Teoría de Colas, se referirá a los siguientes términos como se detallan a continuación:

Cliente	Combatiente herido
Servidor	Transporte sanitario
Tiempo servicio	Tiempo de traslado del herido desde la zona de combate al hospital de campaña
Costo capacidad servicio	Cantidad de medios de transporte sanitario

C.3 Estructuras básicas de un sistema de colas

Existen 4 estructuras básicas:

C.3.1 Una línea y un servidor

En general, el primero en llegar es el primero en ser atendido (FIFO – First In, First Out)

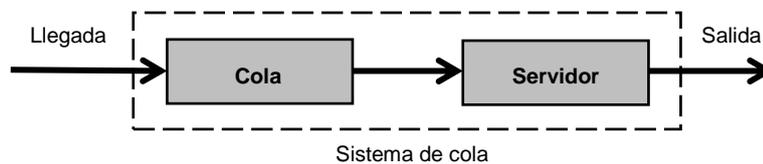
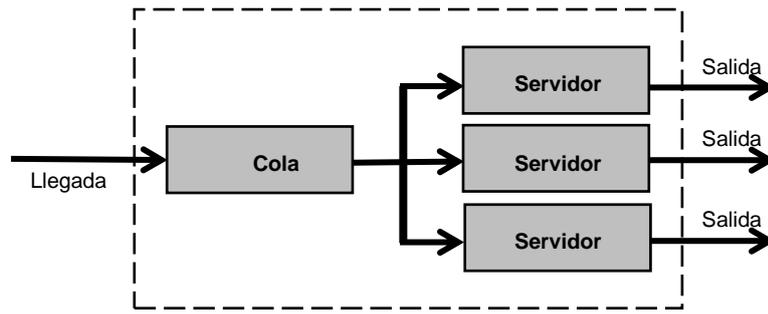


Fig. 9 – Estructura de un sistema de cola (una línea y un servidor)

Fuente: Elaboración propia

C.3.2 Una línea y múltiples servidores

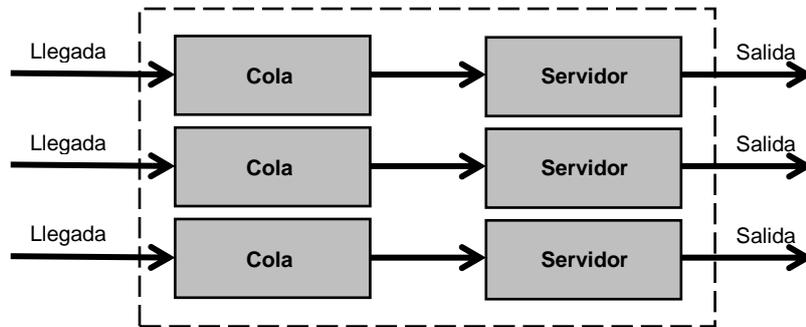


Sistema de cola

Fig. 10 – Estructura de un sistema de cola (una línea y múltiples servidores)

Fuente: Elaboración propia

C.3.3 Múltiples líneas y servidores

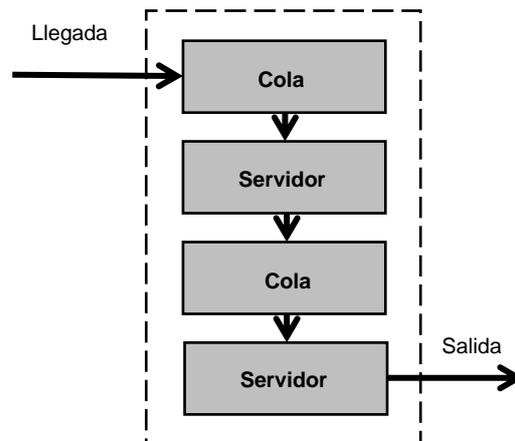


Sistema de cola

Fig. 11 – Estructura de un sistema de cola (múltiples líneas y servidores)

Fuente: Elaboración propia

C.3.4 Una línea y servidores secuenciales



Sistema de cola

Fig. 12 – Estructura de un sistema de cola (una línea y servidores secuenciales)

Fuente: Elaboración propia

C.4 Costos en un sistema de cola

El objetivo de un sistema de cola es determinar el costo total mínimo que permita optimizar los escasos recursos disponibles.

C.4.1 Costo de espera

El costo de las líneas de espera, puede ser económico como en un área de producción o traducirse en el período de tiempo entre la supervivencia o la muerte de un combatiente (también se denomina costo de oportunidad)

C.4.2 Costo de servicio

Es el costo de ofrecer un servicio adecuado al cliente (combatiente). Al igual que en el costo de espera, el costo operativo del servicio dependerá de la cantidad de medios disponibles en un lugar y tiempo determinados dentro del Teatro de Operaciones.

C.4.3 Costo óptimo

Inicialmente, con una capacidad de servicio mínima, el costo de la fila de espera se encuentra en su máximo. A medida que aumenta la capacidad de servicio, se presenta una reducción en el número de clientes en la fila y en sus tiempos de espera, lo cual disminuye el costo de la cola. La variación de esta función se representa mediante una curva exponencial negativa (C_1)

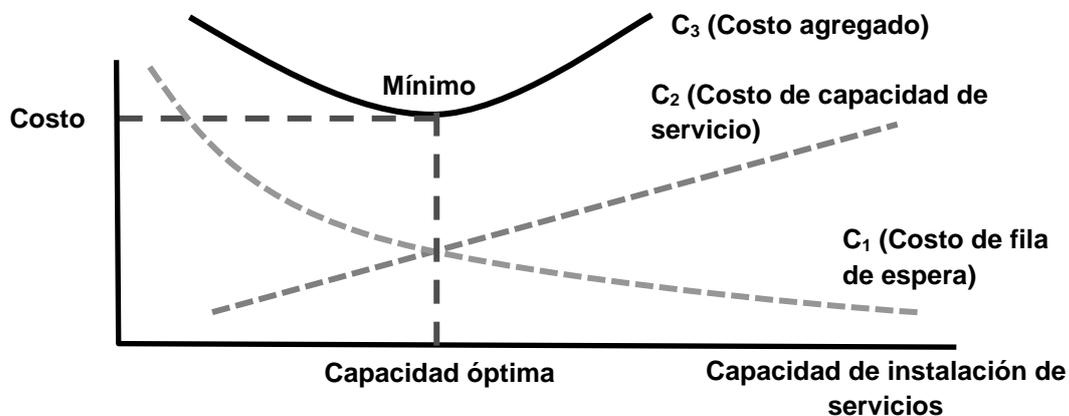


Fig. 13 – Costos de un sistema de cola

Fuente: Vargas Avilés Julio, "Teoría de colas", Universidad Nacional de Ingeniería, Estelí, Nicaragua, 2009

Asimismo, el costo de servicio lo hace a través de una función lineal (C_2) y el costo agregado total aparece como una curva en forma de U (C_3). Por lo tanto, el costo óptimo se ubica en el punto de cruce entre las curvas de capacidad de servicio y filas de espera.

C.5 Tiempos en un sistema de colas

C.5.1 Tiempo de llegada

Es el tiempo que transcurre entre 2 llegadas sucesivas al sistema.

C.5.2 Tasa media de llegadas (λ)

Es el número esperado de llegadas por unidad de tiempo.

C.5.3 Tiempo esperado entre llegadas ($1/\lambda$)

Es la inversa de la tasa media de llegadas.

C.5.4 Tiempo esperado de servicio ($1/\mu$)

El Tiempo Esperado de Servicio ($1/\mu$) depende de la Tasa Media de Servicio (μ). Para determinar los tiempos de servicio, se debe seleccionar una distribución de probabilidad.

C.6 Distribución de llegadas en un sistema de colas

En todo sistema de espera, es imprescindible definir la manera de disponer a los clientes mientras se presta el servicio. Por eso, se requiere una tasa de llegada, o sea, el número de clientes por período de tiempo. Una distribución de llegadas constante es periódica, con el mismo intervalo de tiempo entre cada llegada. Son más comunes las distribuciones de llegadas variables o aleatorias.

En general, el tiempo entre llegadas se distribuye exponencialmente, mientras que el número de llegadas por unidad de tiempo (t) se distribuye mediante Poisson.

C.6.1 Distribución exponencial

Para estimar la distribución de probabilidad de los tiempos de llegada, se supone una distribución exponencial.

Sus características son:

- Supone mayor probabilidad para tiempos entre llegadas pequeños.
- Se considera las llegadas aleatorias (tiempo entre llegadas muy variable)
- La última llegada no influye en la probabilidad de llegada de la siguiente.

La forma algebraica es:

$$f(t) = \lambda e^{-\lambda t} \quad (1)$$

donde λ es el número medio de llegadas por unidad de tiempo (t) y $e = 2,7182818$

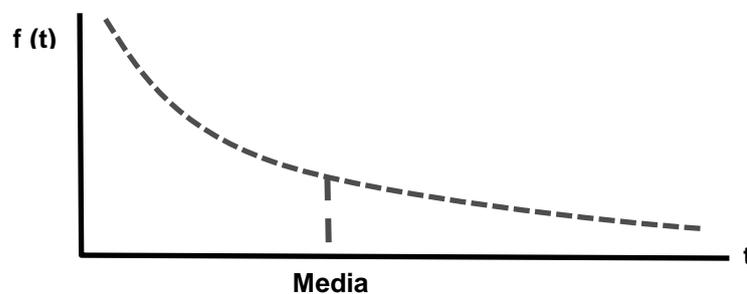


Fig. 14 – Curva de distribución exponencial

Fuente: Vargas Avilés Julio, “Teoría de colas”, Universidad Nacional de Ingeniería, Estelí, Nicaragua, 2009

C.6.2 Distribución de Poisson⁵¹

Sus características son:

- Es una distribución discreta.

⁵¹ En teoría de probabilidad y estadística, la distribución de Poisson es una distribución de probabilidad discreta que expresa, a partir de una frecuencia de ocurrencia media, la probabilidad que ocurra un determinado número de eventos durante cierto periodo de tiempo.

- Para tasas medias de llegadas pequeñas, es asimétrica y se hace más simétrica, aproximándose a la binominal, para tasas de llegadas altas.

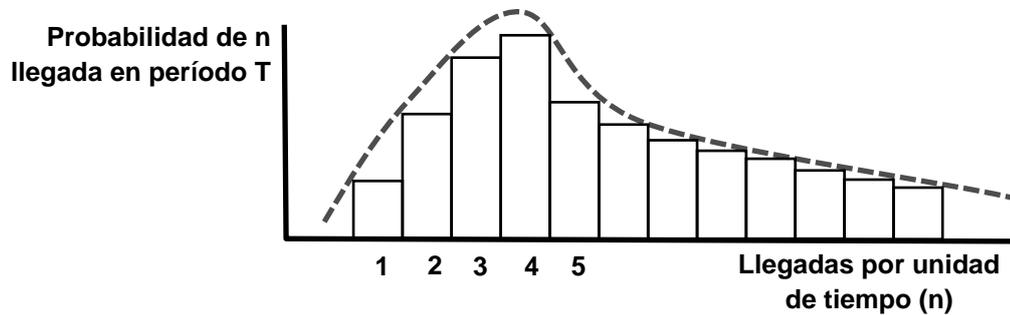


Fig. 15 – Curva de distribución de Poisson

Fuente: Vargas Avilés Julio, “Teoría de colas”, Universidad Nacional de Ingeniería, Estelí, Nicaragua, 2009

La forma algebraica es:

$$f_T(n) = \frac{\lambda T^n e^{-\lambda T}}{n!} \quad (2)$$

donde n es la cantidad de llegadas durante un período de tiempo T

C.7 Notación de Kendall A/B/c

David G. Kendall introdujo una notación de colas A/B/c en 1953 y desde entonces se ha ampliado a 6 dígitos: 1/2/3/(4/5/6) donde estos se reemplazan con códigos:

C.7.1 Distribución del tiempo de llegada

Describe el patrón de llegadas de los clientes al sistema. Si las llegadas son igualmente espaciadas en el tiempo, la distribución será determinista (D) y su valor estará especificado midiendo el número medio de llegadas por unidad de tiempo o tasa media de llegadas (λ) o el tiempo medio entre llegadas consecutivas ($1/\lambda$).

Debido a la incertidumbre en el modelo de llegadas, habrá que especificar la ley de probabilidad que rige el comportamiento aleatorio de llegadas.

Los descriptores más usuales para la distribución del tiempo de llegada son:

M Tasa de llegadas con distribución de Poisson y distribución exponencial para los

tiempos entre llegadas

- D** Tiempos entre llegadas deterministas o constantes
- Ek** Distribución Erlang de k etapas
- Hk** Distribución exponencial de k etapas
- G** Distribución general de los tiempos entre llegadas o arbitraria
- U** Uniforme
- δ** Gamma

C.7.2 Distribución del tiempo de servicio

Se utilizan las mismas abreviaturas que las mencionadas en 1.

C.7.3 Número de servidores

El número de servidores del sistema. Puede ser un número entero positivo ($s= 1, 2, 3, \dots$) o bien infinito ($s=\infty$)

C.7.4 Capacidad del sistema

El número máximo de clientes permitidos en el sistema incluyendo esos en servicio. Cuando el número está al máximo, las llegadas siguientes son rechazadas. Un caso particular de esta situación es el modelo M/M/n/n o Erlang-B, en el cual no hay cola de espera, sino n recursos (servidores) y hasta n usuarios como máximo; si llega el usuario n+1, es rechazado. Otro caso particular es el modelo Erlang-C o M/M/n, donde la capacidad del sistema es ilimitada, aunque haya sólo n recursos; en caso de llegar el recurso número n+1, pasará a una cola de espera, pero no es rechazado.

C.7.5 Tamaño de población o fuente de clientes

El tamaño de la población origen, desde donde los clientes vienen. Esto limita la tasa de llegadas. Puede ser finita (será cero cuando todos los clientes están en el servicio) o infinita. Si la población es finita pero suficientemente grande, se asume infinita.

C.7.6 Disciplina en la cola

Prioridad en la que los trabajos en la cola son servidos:

- **FIFO; PEPS o FCFS** (First In First Out; Primero en Entrar, Primero en Salir o First Come First Served)
- **LIFO; UEPS o LCFS** (Last In First Out; Último en Entrar, Primero en Salir o Last Come First Served)
- **RSS; Aleatorio o SIRO** (Random Selection of Service; Aleatorio o Service In Random Order). Selecciona a los clientes de forma aleatoria, de acuerdo a algún procedimiento de prioridad u orden.
- **PS o PP** (Processor Sharing o Por Prioridades). Sirve a los clientes de igual forma.

C.7.7 Medidas de desempeño general del sistema de colas

$$Ws = Wq + \frac{1}{\mu} \quad (3) \quad Ls = \lambda Ws \quad (4)$$

$$Lq = \lambda Wq \quad (5) \quad Ls = Lq + \frac{\lambda}{\mu} \quad (6)$$

$$P = \frac{\lambda}{\mu s} \quad (7) \quad \rho = \frac{\lambda}{s \mu} \quad (8)$$

C.7.8 Modelos de una cola y un servidor

C.7.8.1 Modelo M/M/1

Distribución del tiempo de llegada M (Poisson)

Distribución del tiempo de servicio M (Exponencial)

Número de servidores 1

$$Ls = \frac{\lambda}{\lambda - \mu} \quad (9) \quad Lq = \frac{\lambda^2}{\mu(\mu - \lambda)} \quad (10)$$

$$W_s = \frac{1}{\mu - \lambda} \quad (11) \quad W_q = \frac{\lambda}{\mu(\mu - \lambda)} \quad (12)$$

$$P_n = (1 - \rho) \rho^n \quad (13) \quad P(L_s > n) = \rho^{n+1} \quad (14)$$

$$\begin{aligned} P(W_s > t) &= e^{-\mu(1-\rho)t} \quad (15) \\ \rho(L_s > t) &= \rho e^{-\mu(1-\rho)t} \quad (16) \end{aligned}$$

$$t >; \rho < 1 \quad (17) \quad (18)$$

C.7.8.2 Modelo M/G/1

Distribución del tiempo de llegada M (Exponencial)

Distribución del tiempo de servicio G (General)

Número de servidores 1

$$L_s = L_q + \rho \quad (19) \quad L_q = \frac{\lambda^2 \sigma^2 + \rho^2}{2(1 - \rho)} \quad (20)$$

$$W_s = W_q + \frac{1}{\mu} \quad (21) \quad W_q = \frac{L_q}{\lambda} \quad (22)$$

$$P_0 = 1 - \rho \quad (23) \quad P_w = \rho \quad (24)$$

$$\rho < 1 \quad (25)$$

C.7.8.3 Modelo M/D/1

Distribución del tiempo de llegada M (Exponencial)

Distribución del tiempo de servicio D (Degenerada)

Número de servidores 1

$$Ls = \lambda Ws \quad (26) \quad Lq = \frac{\rho^2}{2(1-\rho)} \quad (27)$$

$$Ws = Wq + \frac{1}{\mu} \quad (28) \quad Wq = \frac{Lq}{\lambda} \quad (29)$$

$$\rho < 1 \quad (30)$$

C.7.8.4 Modelo M/Ek/1

Distribución del tiempo de llegada M (Exponencial)

Distribución del tiempo de servicio Ek (Erlang)

Número de servidores 1

$$Ls = \lambda Ws \quad (31) \quad Lq = \frac{\rho^2 (k+1)}{2k(1-\rho)} \quad (32)$$

$$Ws = Wq + \frac{1}{\mu} \quad (33) \quad Wq = \frac{Lq}{\lambda} \quad (34)$$

$$\rho < 1 \quad (35)$$

C.7.9 Modelos de múltiples servidores

C.7.9.1 Modelo M/M/S

Distribución del tiempo de llegada M (Poisson)

Distribución del tiempo de servicio M (Exponencial)

Número de servidores 1

$$P_0 = \frac{1}{\frac{\rho^s}{s!} \left(\frac{s \mu}{s \mu - \lambda} \right) + \sum_{n=0}^{s-1} \frac{\rho^n}{n!}} \quad (36)$$

$$P_q = \left(\frac{\rho^s \lambda \mu}{(s-1)! (s \mu - \lambda)^2} \right) P_0 \quad (37)$$

$$L_s = L_q + \frac{\lambda}{\mu} \quad (38) \quad W_q = \frac{L_q}{\lambda} \quad (39)$$

$$W_s = W_q + \frac{1}{\mu} \quad (40)$$

$$P_n = \frac{\rho^n}{n!} P_0; \text{ si } n \leq k \quad (41)$$

$$P_w = \frac{1}{s!} \rho^s \left(\frac{s \mu}{s \mu - \lambda} \right) P_0 \quad (42)$$

$$P_n = \frac{\rho^n}{s! s^{n-s}} P_0; \text{ si } n \leq k \quad (43)$$

C.7.9.2 Modelo M/D/S

Distribución del tiempo de llegada M (Exponencial)

Distribución del tiempo de servicio D (Degenerada)

Número de servidores S

C.7.9.3 Modelo M/Ek/S

Distribución del tiempo de llegada M (Exponencial)

Distribución del tiempo de servicio Ek (Erlang)

Número de servidores S

D.3 Métodos de selección

Existen varios métodos de selección, entre los cuales se encuentran:

D.3.1 Método elitista

Este método garantiza la selección de los individuos más aptos de cada generación. La mayoría de los AG's no utilizan elitismo puro, sino uno modificado, por el cual el mejor o algunos de los mejores individuos son copiados a la siguiente generación, siempre y cuando no exista nada mejor.

D.3.2 Método proporcional a la aptitud

Los individuos más aptos poseen más probabilidades de ser seleccionados (no existe la certeza)

D.3.3 Método de rueda de ruleta

La probabilidad de selección de un individuo, es proporcional a la diferencia entre su aptitud y la de sus competidores.

D.3.4 Método de escalada

Al incrementarse la aptitud media de la población, la presión selectiva también aumenta y la función aptitud se hace más discriminadora. Este método puede ser útil para una futura selección, cuando todos los individuos tengan una aptitud relativamente alta y exista una pequeña diferencia entre ellos.

D.3.5 Método de estado estacionario

La descendencia de los individuos seleccionados en cada generación, reemplazan a algunos individuos menos aptos de la siguiente generación. Se conservan algunos individuos entre generaciones.

D.3.6 Método por torneo

Se eligen subgrupos de individuos de la población y compiten entre ellos. Solo se selecciona a un individuo de cada subgrupo para la reproducción.

D.3.7 Método por rango

A cada individuo de la población se le asigna un rango numérico según su aptitud. La selección se basa en el rango en vez de las diferencias absolutas de aptitud. La ventaja de éste método, es que puede evitar que individuos muy aptos ganen dominio al inicio, a expensas de los menos aptos, lo cual reduciría la diversidad genética de la población, pudiendo obstaculizar la búsqueda de una solución aceptable.

D.3.8 Método generacional

La descendencia de los individuos seleccionados en cada generación se convierte en toda la generación siguiente. No se conservan individuos entre las generaciones.

D.3.9 Método por jerarquía

Los individuos atraviesan varias rondas de selección en cada generación. Las evaluaciones de los primeros niveles son más rápidas y menos discriminatorias y los que sobreviven hasta los niveles más altos, son evaluados más rigurosamente.

La ventaja de éste método es su rapidez en el total del cálculo, al evaluar con menor selectividad y más rápidamente a los individuos poco o nada comprometedores.

D.4 Codificación de las variables

Las variables pueden ser: cadenas binarias, cadenas de números enteros o reales, cadenas de letras.

D.4.1 Cadena binaria

Es una secuencia de 0 (ceros) y 1 (unos). Cada valor que toma el bit se denomina

alelo.

D.4.2 Cadena de números enteros o reales

Cada posición representa algún aspecto particular de la solución. Este método permite mayor precisión y complejidad que la cadena binaria.

D.4.3 Cadena de letras

Cada letra representa un aspecto específico de la solución.

D.4.4 Picos de Hamming

La elección de la codificación de las variables es un tema delicado si se trata de un problema de optimización. Por ejemplo, una codificación directa de números enteros puede ocasionar que al momento de converger, ya que números consecutivos como 15 y 16, por ejemplo, al convertirlos a binario son muy distintos (01111 y 10000, respectivamente) por lo que una solución con el valor 15 difícilmente llegue a evolucionar a una solución de valor 16, pues deberían mutarse todos los bits.

Para disminuir los Picos de Hamming, se pueden utilizar otras codificaciones, como los códigos de Gray, los cuales aseguran que enteros consecutivos solo se diferencien en un bit.

D.4.5 Códigos de Gray o código binario reflejado

Es un sistema de numeración binaria, en el que 2 valores sucesivos difieren solamente en uno de sus dígitos.

Para convertir un número binario a código Gray, se duplica la cadena binaria pero desplazada un espacio hacia la derecha y se anula el último dígito. Luego se efectúa la suma de ambas cadenas, teniendo en cuenta las siguientes reglas:

$$1 + 1 = 0 \qquad 0 + 0 = 0 \qquad 1 + 0 = 1 \qquad 0 + 1 = 1$$

Ejemplo:

Binario	1	1	0	1	13
+		1	1	0	1
Gray	1	0	1	1	13

D.5 Operadores genéticos

Son dos: crossover (cruza) y mutación

D.5.1 Crossover

Es el intercambio de material genético entre 2 cromosomas (individuos). Para aplicar el crossover, cruza o recombinación, se escogen aleatoriamente 2 cromosomas de la población, pudiendo ser ambos descendientes de los mismos padres.

Existen varios métodos de crossover:

D.5.2 Crossover monopunto

Consiste en separar a los padres en 2 partes para formar 2 hijos, intercambiando las partes de cada padre. Para ello, siendo N la cantidad de alelos (bloques), se elige un número C al azar, tal que:

$$1 \leq C \leq N$$

Ejemplo:

Para N=8 (cromosoma de 8 bits) y C= 5 (al azar)

	1	2	3	4	5	6	7	8	
Padre	1	1	1	0	1	1	0	0	236
Madre	0	0	1	1	1	1	1	1	63
Hijo 1	1	1	1	0	1	1	1	1	239
Hijo 2	0	0	1	1	1	1	0	0	60

D.5.3 Crossover multipunto

En el crossover monopunto, es evidente que el primer y último bit no pueden pasar a los hijos en ningún caso. Esta restricción se elimina con la cruce multipunto, eligiendo M puntos de corte (generalmente se utilizan 2 puntos) y las secciones de cada padre pasan alternativamente a los hijos.

Ejemplo:

Para $M=2$ (par) y $C_1=2$; $c_2=5$

	1	2	3	4	5	6	7	8	
Padre	1	0	0	0	0	0	0	1	129
Madre	0	0	0	0	1	1	0	0	12
Hijo 1	1	0	0	0	1	0	0	1	137
Hijo 2	0	0	0	0	0	1	0	0	4

D.5.4 Crossover uniforme

Si bien la cruce multipunto es más flexible que la monopunto, también presenta inconvenientes.

Para valores impares de M (N° de cortes), impiden que el primer y último alelo pasen a los hijos.

Ejemplo:

Para $M=3$ (impar) y $C_1=1$; $c_2=4$; $C_3=6$

	1	2	3	4	5	6	7	8	
Padre	1	1	0	1	1	1	1	0	222
Madre	1	0	0	0	0	1	0	1	133
Hijo 1	1	0	0	0	1	1	0	1	141

Hijo 2

1	1	0	1	0	1	1	0
---	---	---	---	---	---	---	---

214

Para valores pares de M (N° de cortes), obligan a pasar al primer y último alelo a los hijos.

Ejemplo:

Para M=2 (par) y $C_1=3$; $C_2=6$

	1	2	3	4	5	6	7	8	
Padre	1	1	0	1	1	1	1	0	222
Madre	1	0	0	0	0	1	0	1	133
Hijo 1	1	1	0	0	0	1	1	0	198
Hijo 2	1	0	0	1	1	1	0	1	157

Los bloques (alelos) consecutivos, como 3, 4 ó 6, 7, por ejemplo, poseen mayor probabilidad de pasar juntos, que aquellos que se encuentran distanciados, y esto no es deseable.

El operador de cruza uniforme permite el intercambio de alelos de manera independiente del orden de codificación. Para cada alelo de los hijos se elige al azar que alelo se copia del padre y cual de la madre. Si la codificación es binaria, podría:

a) generarse un patrón aleatorio de 0 y 1, intercambiándose los bits de los cromosomas que coincidan con 1 en el patrón

	1	2	3	4	5	6	7	8	
Padre	1	0	0	0	1	1	0	1	141
Madre	0	0	0	1	1	1	0	0	28
Patrón	1	0	0	0	1	1	1	0	

	1	2	3	4	5	6	7	8	
Hijo 1	0	0	0	0	0	0	1	1	3

	1	2	3	4	5	6	7	8	
Hijo 2	1	0	0	1	0	0	1	0	146

b) copiar el alelo del padre si es 0 y el de la madre si es 1, por ejemplo.

	1	2	3	4	5	6	7	8	
Padre	1	0	0	0	1	1	0	1	141

	1	2	3	4	5	6	7	8	
Madre	0	0	0	1	1	1	0	0	28

	1	2	3	4	5	6	7	8	
Patrón	1	0	0	0	1	1	1	0	

	1	2	3	4	5	6	7	8	
Hijo	0	0	0	0	1	1	0	1	13

D.5.5 Crossover asimétrico (de 2 puntos)

En algunos problemas, aplicar aleatoriamente el crossover puede dar resultados inválidos. Para ello debe aplicarse una extensión del crossover de 2 puntos, en los cuales los puntos de cruce pueden ser diferentes entre padres.

- a) Seleccionar puntos de cruce aleatorios en el cromosoma padre (C_1 y C_2)
- b) Seleccionar un puntos de cruce en la cromosoma madre (C_3)
- c) En el Hijo 1, reemplazar los genes entre C_1 y C_2 del padre con los genes de la madre, empezando en C_3 . Al llegar al último gen, se comenzará nuevamente del gen 1 (para el siguiente ejemplo, genes 8, 1 y 2)
- d) En el Hijo 2, reemplazar los genes entre C_1 y C_2 de la madre, con aquellos correspondientes entre C_1 y C_2 del padre.

Ejemplo:

$C_1=2$; $C_2=5$; $C_3=7$ (C_1-C_2 = genes 3, 4 y 5)

	1	2	3	4	5	6	7	8	
Padre	1	1	0	0	1	1	0	1	205

Madre

0	0	1	1	0	0	1	0
---	---	---	---	---	---	---	---

50

1 2 3 4 5 6 7 8

Hijo 1

1	1	0	0	0	1	0	1
---	---	---	---	---	---	---	---

197

Hijo 2

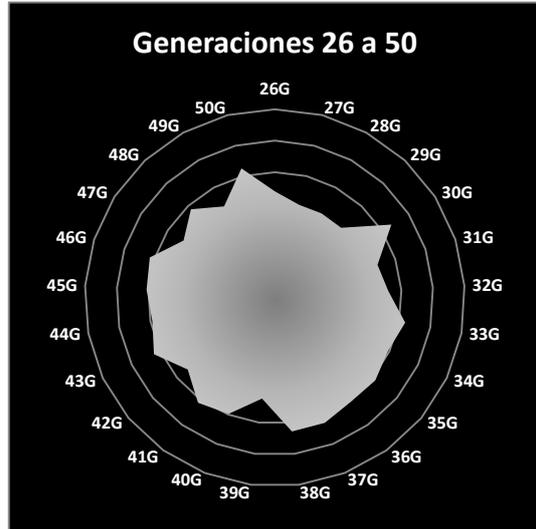
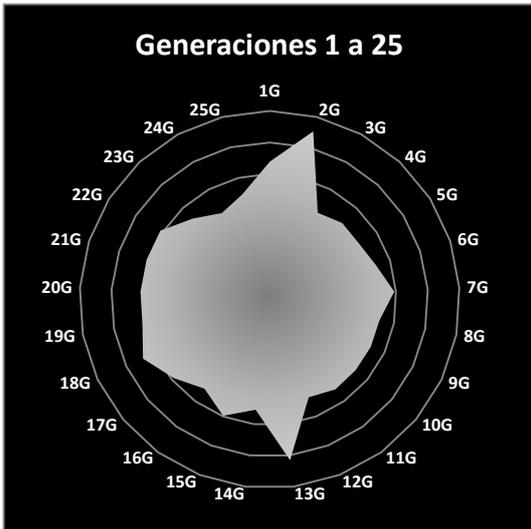
0	0	0	0	1	0	1	0
---	---	---	---	---	---	---	---

10

Anexo E

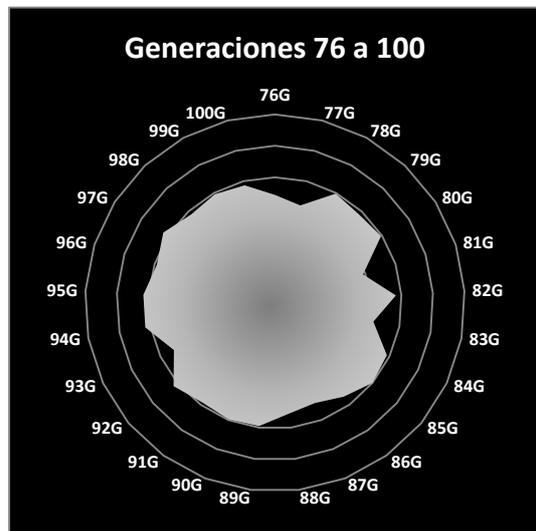
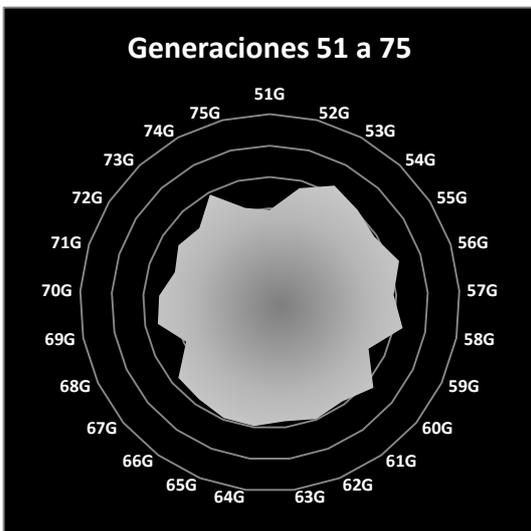
RESULTADOS EXPERIMENTALES DEL MODELO

Estos gráficos nos detallan la evolución del algoritmo cada 25 generaciones, apreciando finalmente su mayor optimización hacia el final del ciclo genético.



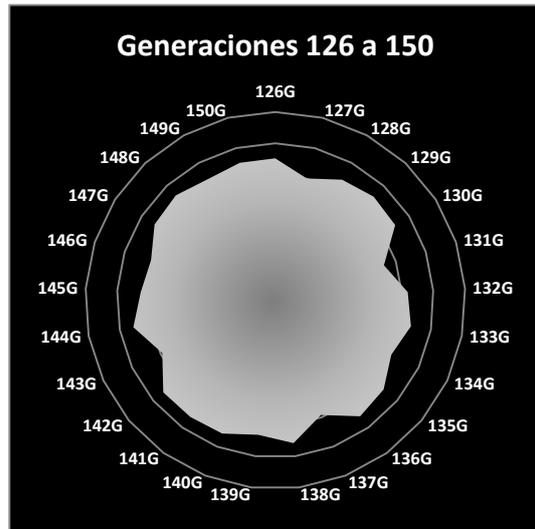
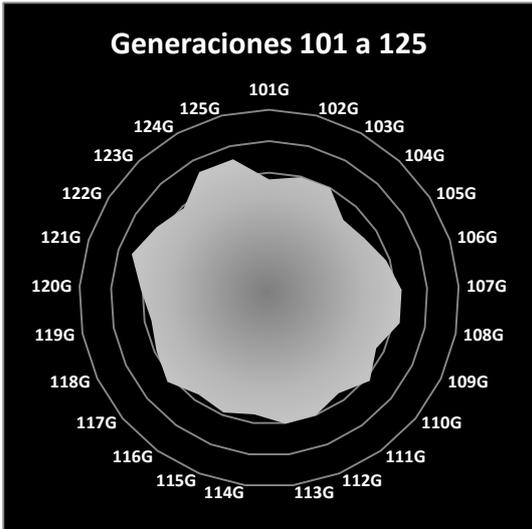
Figs. 17 y 18 – Comportamiento evolutivo de las generaciones 1 a 25 y 26 a 50

Fuente: Elaboración propia



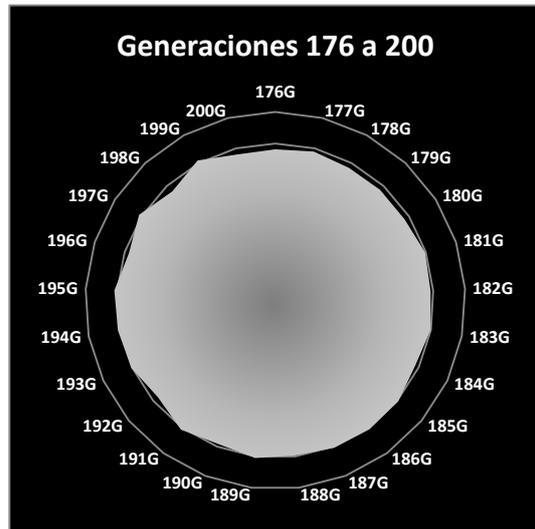
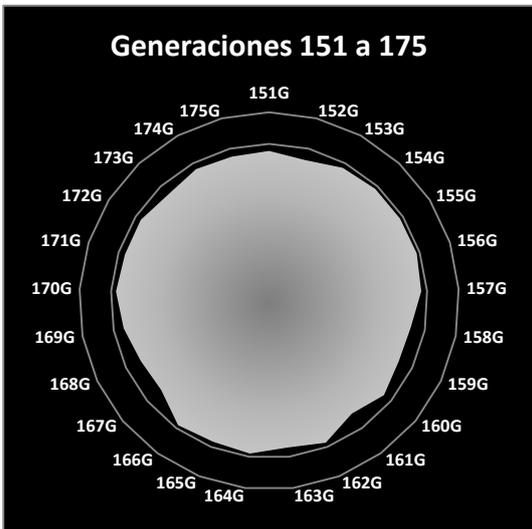
Figs. 19 y 20 – Comportamiento evolutivo de las generaciones 51 a 75 y 76 a 100

Fuente: Elaboración propia



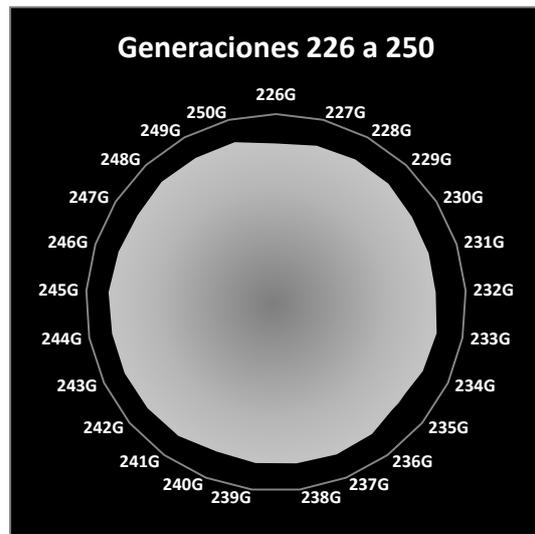
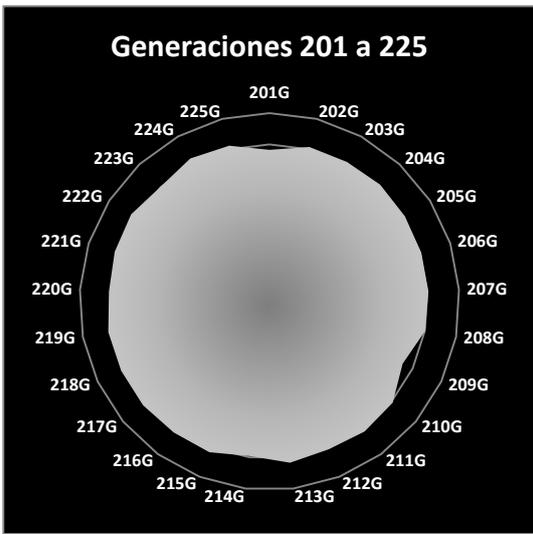
Figs. 21 y 22 – Comportamiento evolutivo de las generaciones 101 a 125 y 126 a 150

Fuente: Elaboración propia



Figs. 23 y 24 – Comportamiento evolutivo de las generaciones 151 a 175 y 176 a 200

Fuente: Elaboración propia



Figs. 25 y 26 – Comportamiento evolutivo de las generaciones 201 a 225 y 226 a 250

Fuente: Elaboración propia