



Ingeniería de tráfico en redes dinámicas periódicas en tiempo continuo con eras de duración estocástica.

Diego Bosch Ayala

Universidad Católica “Nuestra Señora de la Asunción”
Asunción, Paraguay
diegojbosch@gmail.com

Benjamín Barán

Universidad Nacional de Asunción
Universidad Católica “Nuestra Señora de la Asunción”
Asunción, Paraguay
bbaran@pol.una.py

Uri Yael Rozenworcel

Universidad Católica “Nuestra Señora de la Asunción”
Asunción, Paraguay
ing.uriyael@gmail.com

Resumen— Una red dinámica se compone de nodos, que pueden estar conectados o desconectados durante un lapso de tiempo en la red. La red puede ser representada mediante un Grafo Evolutivo, que es un formalismo para modelar la conectividad en cualquier instante. Otros trabajos han destacado el conjunto de mejores soluciones teniendo en cuenta la optimización de varias funciones objetivo en forma simultánea. Una solución incluye al conjunto de tablas de ruteo que utiliza cada nodo. En particular, el presente trabajo utiliza las funciones objetivo, considerando por primera vez no solo tiempo continuo, sino también, la variabilidad del tiempo que dura cada era. Esta variabilidad de tiempo continuo implica que la duración de una era está definida por un proceso estocástico dentro de un rango específico. Al diferenciarse la duración de las eras, las soluciones halladas pueden ser más realistas, ya que en los trabajos existentes las eras consideradas eran determinísticas.

Palabras Claves— Grafo evolutivo; redes dinámicas; redes periódicas; tiempo continuo; proceso estocástico.

INTRODUCCIÓN

Una red dinámica se compone de nodos. Dichos nodos pueden estar conectados o desconectados por un lapso de tiempo en la red. Estos lapsos de desconexión pueden ser planificados, tener un comportamiento conocido o desconocido. La red puede ser centralizada o ad-hoc [1]. La periodicidad de una red se define cuando existe un período T tal que en los instantes t y $t + T$, la red se compone de exactamente los mismos nodos y enlaces [1].

Para transmitir un paquete se necesita un camino desde el nodo fuente (remitente) hasta el nodo destino (destinatario); este camino se puede calcular. En el camino, existen nodos intermedios que actúan reenviando el paquete hasta llegar al destino. Si un nodo intermedio está temporalmente ausente, el nodo predecesor en el trayecto debe almacenar el paquete hasta que el enlace entre ellos se active y el paquete pueda continuar su camino, o alternativamente puede

tomar la decisión de cambiar el camino, según sea la política de encaminamiento (en adelante, *ruteo* o *routing*).

Un Grafo Evolutivo (*Evolving Graph* - EG) es un formalismo que representa la conectividad de una red en cualquier instante [13, 14, 9]. El EG es una secuencia indexada de subgrafos de un grafo dado, donde el subgrafo en un índice corresponde a la conectividad de la red en el intervalo de tiempo indicado por el índice referido. El índice es también conocido como “era”, aunque deben diferenciarse las eras de distintos ciclos.

El EG modela el dominio del tiempo a través de los subíndices. De esta forma, un camino se define como un conjunto de pares ordenados $\langle n, e \rangle$, donde n es el siguiente nodo al que el paquete debe ser enviado en la era e . Para esto, debe existir un enlace activo en la era e entre el nodo en que se encuentra el paquete y el siguiente nodo n .

El presente trabajo aborda las redes dinámicas cíclicas, por lo que existe una cantidad definida de subgrafos (uno por era), y la cuenta del subíndice es reiniciada al finalizar cada ciclo, por lo que el número de eras diferentes resulta finito.

ALGORITMO EVOLUTIVO MULTI-OBJETIVO

Para resolver el problema planteado en un contexto multi-objetivo, es decir, considerando simultáneamente varios objetivos diferentes, puede utilizarse un algoritmo evolutivo multi-objetivo (*Multi-Objective Evolutionary Algorithm* - MOEA) [4], como el propuesto en [16, 17], donde Yael utiliza un *Strength Pareto Evolutionary Algorithm* - SPEA. Como todo algoritmo evolutivo, el SPEA utiliza un conjunto de soluciones P denominado población evolutiva, que se va modificando generación a generación

```

/*
Variables:

P: población de individuos, de tamaño constante  $P_{max} = ||P||$ 
P': externa de individuos no dominados, de tamaño  $||P'|| \leq P'_{max}$ 
 $P_i$ : individuos pertenecientes a la población P
 $P_j$ : individuos pertenecientes a la población P'
 $I_{max}$ : cantidad de iteraciones a realizar
 $I_k$ : cada una de las iteraciones considerando  $0 < k \leq I_{max}$ 

*/
1. Inicializar  $P' = \emptyset$ 
2. Generar  $P_i$ ,  $0 < i \leq P_{max}$ , conformando la población inicial
3.  $k = 1$ 
4. Mientras  $k \leq I_{max}$  hacer:
  a. Actualizar  $P'$  con los individuos no dominados de P
  b. Mientras  $||P'|| > P'_{max}$ 
    • Elegir al azar  $j$ ,  $0 < j \leq ||P'||$ 
    • Eliminar  $P_j$  de  $P'$ 
  c. Fin
  d.  $\forall P_i \in P$  calcular  $fitness_i$ ,  $\forall P_j \in P'$  calcular  $fitness_j$ 
  e. Inicializar  $P_{nuevo} = \emptyset$ , una nueva población
  f. Repetir  $P_{max}$  veces
    •  $P_{nuevo}$  - cruzamiento de dos individuos elegidos de  $P \cup P'$ 
    • Aplicar mutación y rectificación a  $P_{nuevo}$ 
    • Agregar  $P_{nuevo}$  a  $P_{nuevo}$ 
  g. Fin
  h.  $k = k + 1$ 
  i.  $P = P_{nuevo}$ 
5. Retornar la población  $P'$  encontrada
6. Fin

```

Algoritmo 1. Pseudocódigo del SPEA

mediante operadores genéticos hasta cumplir con un criterio de parada [4]. Este algoritmo evolutivo multi-objetivo implementa elitismo guardando las mejores soluciones encontradas en una población externa P' , conformada por el conjunto de mejores soluciones encontradas. Esta población P' se compone así de las soluciones no dominadas que se van encontrando a medida que el algoritmo es ejecutado. Existen otros algoritmos evolutivos similares como el *Non-dominated Sorting Genetic Algorithm* (NSGA), el *Vector-Evaluated Genetic Algorithm* (VEGA), y el *Pareto Archived Evolution Strategy* (PAES) entre otros [4], que también podrían utilizarse para resolver este problema.

El algoritmo SPEA arriba presentado como Algoritmo 1, utiliza el concepto de dominancia Pareto [4, 12]. Una solución domina a otra en el sentido Pareto si y solo si todos sus elementos son mejores o iguales a los elementos respectivos de la solución dominada, y es estrictamente mejor en al menos un objetivo. Para el caso de las soluciones x' y x'' donde lo que se busca es una maximización de k objetivos $f_i(x)$, con $i = 1, \dots, k$; una solución x' domina a otra x'' si y solo si:

$$\forall i_{0 < i \leq k} f_i(x') \geq f_i(x'') \quad \text{y} \quad \exists j_{0 < j \leq k} f_j(x') > f_j(x'') \quad (1)$$

Es importante notar que si entre dos soluciones x e y ninguna domina a la otra en el sentido Pareto, entonces ambas son no-dominadas y no puede sentenciarse que una solución sea mejor que la otra, por lo que también se las conoce como *indiferentes* o *no-comparables* [4].

La cantidad de soluciones en la población externa P' puede llegar a ser muy grande, por lo que se podría necesitar reducir el número de individuos y para ello puede utilizarse la técnica de *clustering* [4]. Dicha técnica es un análisis cuya función es agrupar conjuntos de soluciones muy similares de forma tal que un único individuo represente a todo un conjunto de individuos cercanos, conocido como *cluster*. Este agrupamiento se basa en la idea de distancia o similitud entre las soluciones consideradas. La obtención de dichos grupos depende del criterio o distancia considerado. Como resultado, esta técnica logra disminuir el tamaño de la población y, al mismo tiempo, intenta preservar su diversidad. La técnica de agrupamiento permite reducir el tamaño de la población sin perder las características

del frente Pareto [4]. No obstante, en el truncamiento de dicha población se pueden perder las soluciones de frontera.

La fuerza de cada individuo j perteneciente a la población externa P^* , conocida como $strength_j$, se define en [4] como:

$$strength_j = \frac{\| \{ i \mid 0 < i \leq P_{max}, f_i \prec f_j \} \|}{P_{max} + 1} \quad (2)$$

donde $\| \cdot \|$ indica la cardinalidad del conjunto.

La fuerza de cada miembro de la población evolutiva P puede ser calculada como uno más la sumatoria de la fuerza de todas las soluciones de la población externa que lo dominan.

$$strength_i = 1 + \sum_{\forall j, 0 < j \leq \|P^*\| \mid f_j \succ f_i} strength_j \quad (3)$$

El valor de adaptabilidad (*fitness*) de los individuos puede ser definido como la inversa de su fuerza (*strength*). El *fitness* juega un papel fundamental en la selección del individuo para reproducción [15].

Existen diversos métodos de selección en el proceso de creación de una nueva generación. En este caso, participan en el proceso de selección tanto los individuos la población evolutiva P como los individuos de la población externa P^* ; es decir, del conjunto externo de soluciones no dominadas.

COMPARACIÓN DE EFICIENCIA ENTRE ALGORITMOS CON ERAS DE DURACIÓN 'T'

En [16] se realizaron simulaciones con las topologías representadas en las Figuras 1, 2 y 3 utilizando los siguientes algoritmos:

1. Destination-Sequenced Distance-Vector (DSDV).
2. Dynamic Source Routing (DSR).
3. Ad-Hoc Distance-Vector (AODV).
4. EG shortest (EGs).
5. EG foremost (EGf).
6. Strength Pareto Evolutionary Algorithm (SPEA) adaptado.

En todas las simulaciones realizadas con tiempo discreto, el SPEA encontró buenas soluciones. Cabe destacar que el tiempo de cómputo requerido para realizar las simulaciones utilizando el algoritmo SPEA

es varios órdenes de magnitud mayor al requerido por cualquiera de los otros cinco algoritmos citados anteriormente. En general, el número de buenas soluciones encontradas con el SPEA depende principalmente de dos factores: (1) tamaño de la población y (2) cantidad de iteraciones [16].

Métricas de eficiencia utilizadas

Existen diversas métricas que pueden ser utilizadas para valorar las bondades de una solución. El presente trabajo adopta las métricas utilizadas en [13, 16], de forma a tomar en cuenta la optimización de varias funciones objetivos (FO): (a) la cantidad promedio de saltos efectuados por los paquetes para llegar al nodo destinatario; (b) la cantidad promedio de eras vividas por los paquetes hasta que todos ellos culminan su camino; y (c) la cantidad promedio de eras durante las cuales los paquetes viajan a través de la red hasta llegar

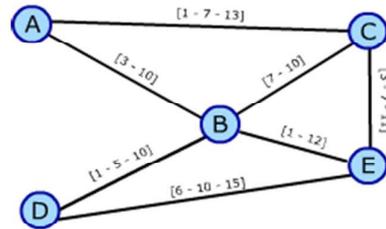


Figura 1. Un EG que representa una red

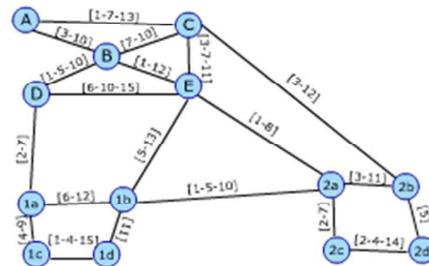


Figura 2. Un EG que representa una red mediana.

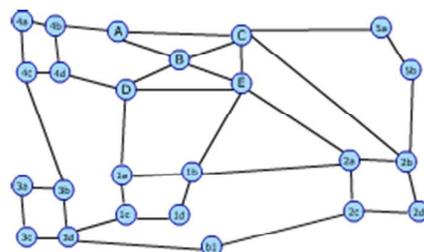


Figura 3. Un EG que representa una red grande.

a destino. Lógicamente, se trata de un problema multi-objetivo que considera simultáneamente estos 3 objetivos [16].

La cantidad de saltos mide cuántos enlaces fueron atravesados por un paquete para llegar desde el nodo remitente hasta el nodo destinatario. El conjunto de caminos más cortos es el de los caminos cuya cantidad de saltos es mínima, lo cual se puede calcular con el algoritmo de Dijkstra [16].

La cantidad de eras de vida es la suma de eras durante las cuales un paquete se encuentra almacenado en algún nodo. Es decir, es la diferencia entre el índice de la era en que el paquete arribó al destinatario y la era en que inicialmente fue creado por el nodo remitente.

La cantidad de eras de viaje es la suma de eras durante las cuales el paquete se encuentra atravesando efectivamente los nodos intermedios, es decir, el número de eras en la red dinámica considerada. Se contabiliza desde la era en que el paquete realiza el primer salto, hasta su recepción por el destinatario.

Simulaciones con una red pequeña

Las simulaciones realizadas en [16] con la red presentada en la Figura 1, obtuvieron las soluciones

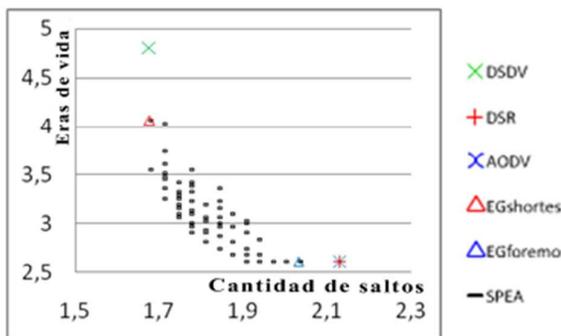


Figura 4. Ejemplo del conjunto de soluciones de una red pequeña.

Algoritmo	Cantidad de saltos	Eras de vida	Eras viajadas	Comentario
EG Foremost	2.03	2.61	1.32	Dominado por SPEA 1
EG Shortest	1.68	4.07	1.16	Dominado por SPEA 2
SPEA 1	1.90	2.61	0.94	Domina a EG f
SPEA 2	1.68	3.55	0.90	Domina a EG s

Tabla 1. Valores promedio en las distintas FO para las soluciones obtenidas por los algoritmos SPEA, EG shortest y EG Foremost, en una red pequeña.

mostradas en la Figura 4. Para facilitar la comprensión del lector, la Figura 4 muestra un promedio de sólo dos funciones objetivo: (a) cantidad promedio de saltos, y (b) eras vividas en promedio por los paquetes. La tercera función objetivo (c) eras viajadas, no se muestra por simplicidad, pero se puede apreciar dado el gran número de soluciones de compromiso encontradas por el algoritmo SPEA.

La Tabla 1 presenta un resumen breve de las 3 funciones objetivo calculadas para el algoritmo *EG Shortest*, el algoritmo *EG Foremost*, y para dos de las 168 soluciones encontradas por el algoritmo SPEA.

Como se puede ver en la columna de observaciones de la Tabla 1, una solución calculada con el SPEA, denominada *SPEA 1* domina a la solución encontrada utilizando *EG Foremost*. Esto es debido a que ambas soluciones tienen igual promedio de eras vividas (de 2,61), pero la solución *SPEA 1* tiene valores menores en las otras dos funciones objetivo. Al mismo tiempo, otra solución calculada utilizando SPEA, denominado *SPEA 2*, domina la solución encontrada con el algoritmo *EG shortest*, dado que ambas soluciones requirieron en promedio 1,68 saltos para llegar a destino, pero la solución *SPEA 2* necesitó en promedio un menor número de eras.

Otra ventaja del algoritmo SPEA propuesto es su capacidad de presentar al tomador de decisiones, un conjunto de buenas soluciones (conjunto Pareto). En el caso de la simulación presentada en la Tabla 1, el tomador de decisiones podrá seleccionar cualquiera de las 168 soluciones encontradas, según cuál se adapte mejor a las necesidades específicas del caso.

Cantidad de saltos

El algoritmo *EG Shortest* utiliza el algoritmo de Dijkstra para caminos mínimos. Por lo tanto, *EG Shortest* siempre encuentra el viaje más corto en cantidad de saltos para entregar un paquete. En la Tabla 1 se muestra que el SPEA encontró una solución, denominada *SPEA 2*, que actúa tan bien como el algoritmo *EG Shortest* considerando el número de saltos (Figura 5) y, sin embargo, se comporta mejor que el *EG Shortest* al hacer los trayectos en una menor cantidad promedio de eras de vida. De esta forma, la solución *SPEA 2* es una solución mejor que la calculada por el *EG Shortest*. Además, aplicando la fórmula 1, la solución *SPEA 2* domina a la solución encontrada por *EG Shortest*.

Eras de vida

El algoritmo *EG Foremost* es una adaptación del algoritmo de Dijkstra de caminos mínimos, pero

aplicado a minimizar la vida del paquete en lugar de la cantidad de saltos durante el viaje [14]. Si se observara esta función objetivo en forma exclusiva, la solución provista por *EG Foremost* sería óptima.

La Figura 6 muestra una comparación entre los 5 algoritmos mono-objetivo enumerados en la leyenda del gráfico. Como era de esperar, la solución encontrada por el algoritmo *EG Foremost* se comporta mejor que la encontrada por el *EG Shortest* y el DSDV. Cabe mencionar que la eficiencia de las soluciones calculadas por los algoritmos DSR y AODV es la misma para la topología indicada en la Figura 1.

El algoritmo SPEA encontró una solución, denominada *SPEA 1*, que funciona tan bien como la solución encontrada por *EG Foremost* cuando sólo es considerado el número promedio de eras hasta el

destino (Figura 8). Sin embargo, como se muestra en la Tabla 1, se comporta mejor que el *EG Foremost* cuando las otras dos funciones objetivo se consideran, realizando los recorridos en menor cantidad de eras promedio y reduciendo el promedio de saltos. De esta manera la solución *SPEA 1* es mejor que la propuesta por el algoritmo *EG Foremost*.

Eras viajadas

Un viaje es más rápido que otro, si necesita atravesar un menor número de eras hasta llegar a destino. La cantidad de eras viajadas se calcula como la era de llegada menos la era en que el paquete sale desde su origen. Si el paquete es trasladado desde el emisor hasta el receptor en la misma era y período, se dice que la cantidad de eras viajadas es cero.

Las tres soluciones de SPEA mostradas en la Figura 8, se desempeñan mejor que las soluciones encontradas por los algoritmos *EG Shortest*, *EG Foremost*, DSDV, DSR y AODV. Se destaca además que dichos algoritmos superados, encuentran una única solución y no un conjunto de soluciones como es el caso del algoritmo SPEA.

Simulaciones con una red mediana

Las simulaciones realizadas con la red de tamaño mediano, ilustrada en la Figura 2, se resume en la Figura 9.

La Tabla 2 presenta los valores promedio de las funciones objetivo calculadas considerando las soluciones encontradas por los algoritmos *EG Shortest* y *EG Foremost*, así como dos de las 53 soluciones encontradas por el SPEA. Estas dos soluciones del SPEA son denotados como *SPEA 1* y *SPEA 2*. En este caso, las soluciones *SPEA 2* y la encontrada por *EG Foremost* tienen los mismos valores en el espacio objetivo. Tanto *SPEA 1* como *EG Shortest* tienen el mismo valor de saltos realizados en promedio (de 2.927), pero la solución *SPEA 1* tiene valores inferiores en las eras promedio vividas y de viaje.

La Figura 8 muestra las soluciones de los algoritmos mencionados en la leyenda del gráfico. El conjunto de 53 soluciones no dominadas calculadas por el algoritmo SPEA, incluye la solución encontrada por *EG Foremost* y una solución que domina a la encontrada por *EG Shortest*.

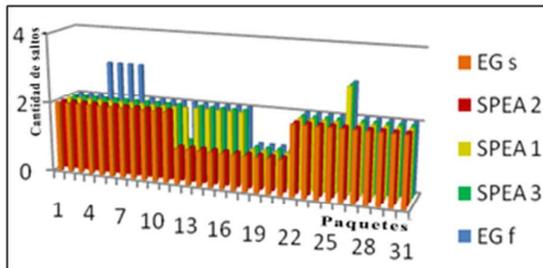


Figura 5. Cantidad de saltos con soluciones SPEA, EGs y EGf.

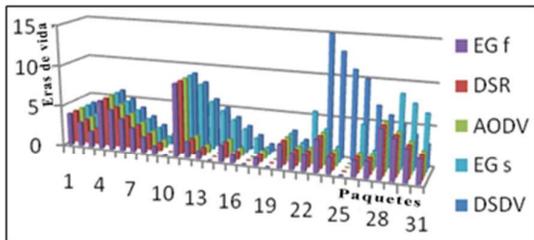


Figura 6. Eras vividas por cada paquete para algoritmos mono-objetivos.

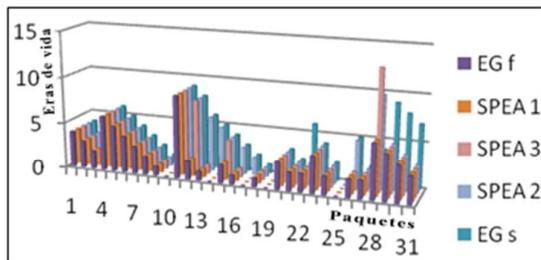


Figura 7. Eras vividas por cada paquete para soluciones SPEA, EGs y EGf.

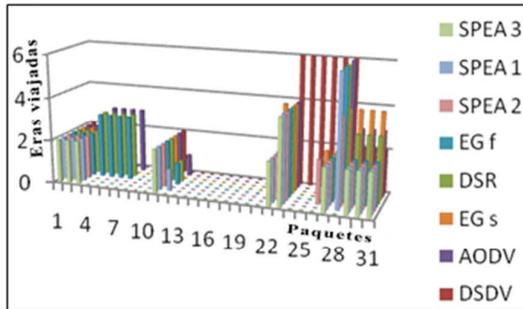


Figura 8. Número de eras viajadas por cada paquete utilizando distintos algoritmos.

Simulaciones con una red grande

Para otras simulaciones se utilizó la red mostrada en la Figura 3. El algoritmo *EG Shortest* funcionó tan bien como el DSDV en la cantidad promedio de saltos realizados. El algoritmo *EG Foremost* superó en rendimiento a DSR y AODV con el promedio de eras vividas por los paquetes. En este caso, el enfoque SPEA encontró 22 soluciones no dominadas, dos de ellas denotados como *SPEA 1* y *SPEA 2*. Los valores promedio de las funciones objetivo se resumen brevemente en la Tabla 3.

TIEMPO CONTINUO.

Trabajos anteriores [13, 14, 16] solo consideran la duración de las eras con una variable t y no asignan un valor en

Algoritmo	Cantidad de saltos	Eras de vida	Eras viajadas	Comentario
EG Foremost	3.526	6.482	4.897	
EG Shortest	2.927	10.667	7.449	Dominado por SPEA 1
SPEA 1	2.927	10.517	7.376	Domina a EG f
SPEA 2	3.526	6.482	4.897	

Tabla 2. Valores promedio de FO calculadas para las soluciones obtenidas por los algoritmos SPEA, *EG Shortest* y *EG Foremost*, en una red mediana.

Algoritmo	Cantidad de saltos	Eras de vida	Eras viajadas	Comentario
EG Foremost	4.379	0.548	4.897	
EG Shortest	3.033	8.927	3.27	
SPEA 1	3.033	8.297	3.27	
SPEA 2	4.379	0.548	4.897	

Tabla 3. Valores promedio de FO calculadas para las soluciones obtenidas por los algoritmos SPEA, *EG shortest* y *EG Foremost*, en una red grande.

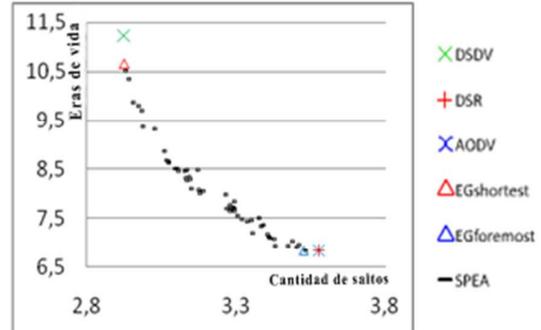


Figura 9. Conjunto de soluciones de una red mediana.

segundos a dicha variable. Esto resulta en que las soluciones son comparadas, entre otras formas, por la cantidad de eras transcurridas y, por lo tanto, dichos trabajos asumen implícitamente que la duración en segundos de dos eras cualesquiera, es siempre la misma.

Los trabajos [13, 14, 16] utilizan Grafos Evolutivos que permiten implementar el concepto de camino (o viaje) compuesto por pares ordenados $\langle n, e \rangle$, donde n es un nodo y e una era en la que el nodo se encuentra conectado a la red. La era está delimitada como un lapso de tiempo. En trabajos anteriores se consideraba que todas las eras duraban un mismo tiempo t . En consecuencia, el presente trabajo propone por primera vez asignar a cada era una duración específica en segundos, considerando para ello un proceso estocástico pues en la mayoría de los casos prácticos este valor no es necesariamente constante. De esta forma, la misma era en ciclos distintos, puede tener distinta duración, al ser una variable aleatoria. Esto permite simular márgenes de error en los cronogramas y fenómenos atmosféricos que impactan sobre la conectividad real de la red al momento efectivo de su utilización.

En el trabajo propuesto, las eras son consideradas con un tiempo continuo asignado de acuerdo a un proceso estocástico; un proceso donde su comportamiento está regido por el azar, por lo que se puede aplicar técnicas de simulación basadas en el método de Monte Carlo. En esencia, el método simula valores que toman las variables aleatoria que forman parte del proceso, simulando lo que podría ocurrir al experimentar u observar la realidad.

El proceso estocástico antes mencionado se basa en un sistema dinámico. Según Kofman [10], un sistema dinámico es un sistema cuyos parámetros internos (variables de estado) siguen una serie de reglas temporales. Se llaman sistemas porque están descritos por un conjunto de ecuaciones (sistema), y dinámicos porque sus parámetros varían con respecto a alguna

variable que generalmente es el tiempo. El estudio de los sistemas dinámicos puede dividirse en 3 subdisciplinas:

- *Dinámica aplicada*: modelado de proceso por medio de ecuaciones de estado que relacionan estados pasados con estados futuros.
- *Matemáticas de la dinámica*: se enfoca en el análisis cualitativo del modelo dinámico.
- *Dinámica experimental*: experimentos de laboratorio, simulaciones en computadora de modelos dinámicos.

Este trabajo en particular propone la dinámica experimental. Los sistemas dinámicos pueden clasificarse en dos grandes clases: aquellos en los que el tiempo varía continuamente y aquellos en los que el tiempo transcurre en forma discreta.

No siempre se puede realizar experimentos sobre los sistemas reales por cuestiones particulares (costo, riesgo u otra imposibilidad). Por este motivo se recurre a la experimentación sobre modelos del sistema. Un modelo del sistema es una representación simplificada de un sistema que permite analizar y resolver las interrogantes sin recurrir a la experimentación sobre dicho sistema.

Como se expresa en el trabajo de Kofman antes citado [10], el modelo matemático del sistema es un conjunto de expresiones matemáticas que describen las relaciones existentes entre las magnitudes que caracterizan al sistema. La simulación es la experimentación sobre un modelo matemático de un sistema; esta simulación, además del modelado, también suele requerir la utilización de técnicas de aproximación. La idea es obtener una representación simplificada de algún aspecto de interés de la realidad. Mediante la simulación se puede experimentar con sistemas en casos que tal vez sería imposible o impráctico en la realidad.

Los modelos matemáticos se pueden clasificar según su evolución temporal. Este trabajo destaca en particular el tiempo continuo, donde las variables evolucionan continuamente en el tiempo.

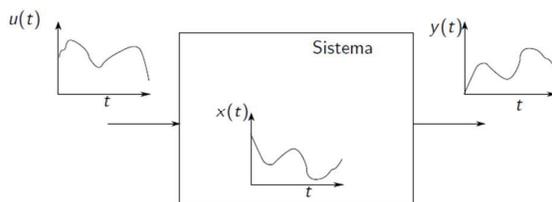


Figura 10. Sistemas de tiempo continuo.

Consecuencias de utilizar tiempo discreto en simulaciones

Las simulaciones realizadas en [13, 14, 16] consideran que todas las eras duran un mismo intervalo de tiempo, aunque no especifican cuál. Debido a que en los trabajos anteriores no se realizaba una correlación entre eras y tiempo en segundos, y como se asumía que el tiempo de viaje de un paquete a través de un enlace es mucho menor a cualquier supuesta duración de eras, no se consideraba el tiempo durante el cual los paquetes atraviesan los enlaces. Es decir, se consideraba un viaje instantáneo dentro de una misma era. La topología puede incluir la distancia en metros entre los nodos. La transmisión de un paquete tendrá una duración que se puede calcular, conociendo la distancia entre nodos y el tipo de tecnología de transmisión. Los trabajos antes citados no toman en cuenta este tiempo de transmisión al momento de decidir enviar o no un paquete en una era particular.

Un paquete simplemente puede esperar a una era posterior si es que el algoritmo así lo decide. En forma novedosa, el presente trabajo dota al algoritmo propuesto con la capacidad de distinguir los beneficios de enviar un paquete en una u otra era, mientras que los algoritmos citados anteriormente no realizan dicha distinción, al considerar que todas las eras tienen idéntica duración.

Se hace notar que la utilización del tiempo discreto en redes de computadoras, implica pérdida de información. Esto es debido a que el mundo real no es necesariamente discreto y podría ser mejor representar la realidad en tiempo continuo. Por ejemplo, las simulaciones con tiempo discreto presentado en la literatura [13, 16] no logran incluir el tiempo de viaje de los paquetes (debido a que la duración de las eras es de varios órdenes de magnitud mayor que el tiempo de transmisión), ni desviaciones en la duración de las eras respecto al cronograma.

Beneficios al utilizar tiempo continuo

Como aporte en este trabajo, se busca que los resultados sean mejores y más precisos considerando que lo que tarda un paquete en llegar a destino pueda ser medido en segundos.

Al realizar simulaciones con tiempo continuo se tiene una mejor aproximación a la realidad ya que en el mundo real las redes pueden sufrir variaciones en el tiempo de envío de paquetes de acuerdo a la carga del tráfico de la red, entre otros motivos.

Simulaciones en tiempo continuo

Este trabajo propone utilizar el método de Monte Carlo [11] como método para simular el problema considerado de las redes periódicas en tiempo continuo.

El método de Monte Carlo es no determinístico, utilizado para aproximar expresiones matemáticas complejas y costosas de evaluar con exactitud. El mismo agrupa una serie de procedimientos que analizan distribuciones de variables aleatorias utilizando la simulación de números aleatorios. Generalmente en estadística los modelos aleatorios se usan para simular fenómenos que poseen algún componente no determinístico. En cambio, en el método de Monte Carlo, el objeto de la investigación es el elemento en sí mismo, un suceso aleatorio o pseudo-aleatorio se usa para estudiar el modelo.

Gracias a la constante evolución de las microcomputadoras en lo que se refiere a su capacidad de procesamiento de la información, el método de Monte Carlo es cada vez más utilizado. Esta metodología provee como resultado aproximaciones para las distribuciones de probabilidades de los parámetros que están siendo estudiados.

La técnica mencionada puede aplicarse tanto a problemas determinísticos (la solución, si existe, es exacta) como a problemas no determinísticos (la solución, si existe, viene caracterizada por un valor medio, una varianza, etc.). De cualquier manera, la solución que aporta este método, sea cual sea el problema considerado, es de tipo aproximado y por lo tanto susceptible de caracterizarse como cualquier variable estadística.

Se deben realizar diversas simulaciones donde, en cada una de ellas, son generados valores aleatorios para el conjunto de variables de entrada y parámetros del modelo que están sujetos a incertidumbre. Tales valores aleatorios generados siguen distribuciones de probabilidades específicas que deben ser identificadas o estimadas previamente.

En este proyecto las eras tienen una duración de naturaleza estocástica, es decir, no se puede prever cuánto tiempo duraría una era. Solamente se puede asignar una probabilidad a cada uno de los posibles sucesos.

Una variable aleatoria es una función del espacio muestral en el conjunto de números que además satisface cierta condición de ser conmensurable. Representa una traducción de cada uno de los resultados

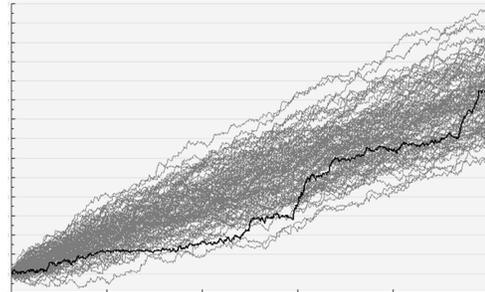


Figura 11. Ejemplo de resultados a través de una simulación utilizando el método Monte Carlo.

del espacio muestral en números reales. Mediante una variable aleatoria uno puede considerar que el posible experimento aleatorio en cuestión no produce como resultados elementos del conjunto arbitrario sino números reales. El concepto de variable aleatoria es fundamental en la teoría de la probabilidad.

En teoría de la probabilidad y la estadística, la distribución de probabilidades de una variable aleatoria es una función que asigna a cada suceso definido sobre la variable aleatoria la probabilidad de que dicho suceso ocurra. La distribución de probabilidades está definida sobre el conjunto de todos los sucesos, cada uno de los sucesos es el rango de valores de la variable aleatoria.

Una distribución de probabilidades indica toda la gama de valores que pueden representarse como resultado de un experimento si éste se llevase a cabo. Es decir, describe la probabilidad de que un evento se realice en el futuro, constituye una herramienta fundamental para la prospectiva, puesto que se puede diseñar un escenario de acontecimientos futuros considerando las tendencias actuales de diversos fenómenos naturales.

Al momento de realizar las simulaciones con redes dinámicas es necesario modelar el error en la duración de las eras, estableciendo un rango de tiempo. De esta forma, la era puede tomar un tiempo cualquiera dentro de dicho rango. Entre las distintas distribuciones de probabilidad, resaltamos la triangular con la media exactamente en el medio de su rango.

Se elige una distribución de probabilidad triangular con la media exactamente en el medio de su rango debido a que su implementación es simple y representa de buena forma el hecho de que la mayoría de los eventos suceden según estaba previsto. Es decir, es más probable que el evento ocurra a medida que se acerca a la moda. El proceso es representado estableciendo límites (máximo y mínimo) y el valor más probable



(moda).

CONCLUSIONES.

Las redes periódicas han llegado a ser muy útiles en el modelado de redes de comunicación. Por citar algunos ejemplos podemos considerar su utilización en el estudio de Satélites de Órbita Baja (*Low Earth Orbit* - LEO), redes de sensores, redes móviles del tipo ad-hoc conocidas como MANET (*mobile ad-hoc network*) [2, 5, 6, 7, 8, 15] entre otras [9]. También el proyecto *One Laptop per Child* (OLPC) utiliza este modelado con un fin educativo [3].

Otros trabajos [16] han resuelto el problema de encaminar paquetes en redes dinámicas periódicas en el contexto de un Problema Multi-objetivo, siendo las funciones objetivo: (1) la cantidad promedio de saltos efectuados por los paquetes para llegar al nodo destinatario, (2) la cantidad promedio de eras vividas por los paquetes hasta culminar su camino, y (3) la cantidad promedio de eras durante las cuales los paquetes viajan a través de la red hasta llegar a destino.

Estos trabajos utilizan el concepto de Grafo Evolutivo, el cual permite implementar el concepto de camino (o viaje) que está compuesto por pares ordenados $\langle n, e \rangle$, donde n es un nodo y e una era en la que el nodo se encuentra conectado a la red. La era está delimitada como un lapso de tiempo 't'. En este trabajo en particular, y por primera vez en la literatura, se propone que las eras ya no duren un tiempo constante 't', sino que cada era en particular pueda durar un tiempo diferente expresado en segundos.

La duración específica en segundos de cada era permite, como aporte de este trabajo, que los resultados buscados sean mejores al considerar lo que realmente tarda un paquete en llegar a destino, medido en segundos.

Como el simulador de este trabajo tiene como tarea manejar el concepto de eras, entonces, pasará la información a los algoritmos y estos indicarán el siguiente salto a ejecutar. Si el algoritmo utiliza u omite la información del tiempo continuo en la era, será una cuestión del algoritmo en sí y de su capacidad de adaptarse a una realidad estocástica. De esta manera, se podrán comparar los resultados de los diversos algoritmos mencionados con el nuevo enfoque de tiempo continuo.

Las eras tendrán así un tiempo continuo de acuerdo a un proceso estocástico que evoluciona a lo largo del tiempo de forma totalmente aleatoria, lo cual se puede conseguir por medio del método Monte Carlo. No se

puede prever cuánto duraría una era, sino que se asigna una probabilidad a cada uno de los sucesos.

Entre todas las distribuciones de probabilidad, este trabajo resalta la distribución de probabilidad triangular con la media exactamente en el medio de su rango, representando así el hecho de que la mayoría de los eventos suceden según estaba previsto.

De esta manera las simulaciones tendrán un enfoque más acorde a la realidad ya que el envío de paquetes en una red no siempre tendrá la misma duración, ya sea por la carga del tráfico en la red o por algún otro problema que conlleve un tiempo de viaje variable de los paquetes en la red.

REFERENCIAS.

- [1] G. Ash. Dynamic Network Evolution, with Examples from AT&T's Evolving Dynamic Network. *IEEE Communications Magazine*, pp. 26-39. Año 1995.
- [2] B. Burns, O Brock y B.N. Levine, MV Routing and Capacity Building in Disruption Tolerant Networks, IEEE INFOCOM 2005. Año 2005.
- [3] R. Campanha, M. Bletsa., L. Claudio y S. Magalhae. Mesh Networks for Digital Inclusion - Testing OLPC's XO Mesh Implementation, Networks Operations and Management Symposium, pp. 38-49. Año 2007.
- [4] C.A. Coello, G.B. Lamort y D.A. Van Veldhuizen, Evolutionary Algorithms for Solving Multi-Objective Problems. 2da. Edición, Editorial Springer. Año 2007.
- [5] S. Corson y J. Macker. Mobile Ad Hoc Networking (MANET): Routing Protocol Performance Issues and Evaluation Considerations. RFC 2501, IETF. Enero 1999.
- [6] A. Davids, A. H. Fagg, y B. N. Levine, Wearable Computers as Packet Transport Mechanisms in Highly-Partitioned Ad-Hoc Networks, Proceedings. International Symposium, Wearable Computers, pp 141-148. Año 2001.
- [7] M. Grossglauser y D. Tse. Mobility Increases the Capacity of Ad Hoc Wireless Networks, INFOCOM, pp. 1360-1369. Año 2001.
- [8] R. Handorean. Accommodating Transient Connectivity in Ad Hoc and Mobile Settings. *Pervasive 2004*, Apr. 21-23, pp. 305-22. Año 2004.
- [9] A. Jarry y Z. Lotker. Connectivity in Evolving Graph with Geometric Properties. Tenth Annual International Conference on Mobile Computing and Networking, pp. 24-30. Año 2004.
- [10] E. Kofman, Modelado y simulación de Sistemas Dinámicos, http://www.fceia.unr.edu.ar/~kofman/files/eci_MyS_1.pdf
- [11] D. P. Kroese, T. Taimre, Z. I. Botev, Handbook of Monte Carlo Methods. New York: John Wiley & Sons. p. 772. ISBN 0-470-17793-4. Año 2011.
- [12] F. J. Martínez. Un Nuevo Enfoque para Resolver Problemas de Optimización Multi-Objetivo Utilizando Programación Genética



Lineal. Tesis de grado, Universidad Católica “Nuestra Señora de la Asunción”. 2008.

[13] J. Monteiro, A. Godman y A. Ferreira. Performance Evaluation of Dynamic Networks using an Evolving Graph Combinatorial Model. *Wireless and Mobile Computing, Networking and Communications (WiMob'06)*, pp. 173-180, Montreal, CA. Año 2006.

[14] J. Monteiro. Uso de Grafos Evolutivos en el ruteamiento de Redes Dinámicas. Tesis de maestría. Instituto de Matemática y Estadística, Universidad de Sao Paulo. Año 2007.

[15] A. Vahdat y D. Becker, Epidemic Routing for Partially Connected Ad Hoc Networks, Tech. Rep. CS-200006, Department of Computer Science, Duke University, Durham, NC, 2000.

[16] U. Yael. Ingeniería de Tráfico en Redes Dinámicas Periódicas Utilizando el Algoritmo SPEA. Tesis de grado, Universidad Católica “Nuestra Señora de la Asunción”. Año 2009.

[17] U. Yael, B. Barán. Routing in Periodic Dynamic Networks using a Multi-Objective Evolutionary Algorithm. *ALIO-INFORMS Joint International Meeting*. Año 2010.