

Modelo de enrutamiento dinámico en redes inalámbricas ad-hoc basado en aprendizaje de máquina

Dynamic routing model in ad-hoc wireless networks based on machine learning

Danelly Desiree Arévalo Saavedra, Ing.
darevalo@gmail.com
Colombia

Jhon Hegel Gutiérrez Gutiérrez, Ing.
jhgutierrez@gmail.com
Colombia

Universidad de los Llanos

Recibido: 16 de enero 2012
Aprobado: 18 de marzo 2012

Resumen

Una red inalámbrica *ad-hoc* consiste en un conjunto de nodos móviles inalámbricos que forman una red sin ayuda de ninguna infraestructura o administración centralizada. Los protocolos de enrutamiento usados en las redes *ad-hoc* deben ajustarse automáticamente a entornos donde aspectos como el ancho de banda y la movilidad son muy variables. Este trabajo busca medir el impacto en el desempeño de los protocolos de enrutamiento para redes móviles *ad-hoc* (MANET), si estos pudieran involucrar técnicas inteligentes en vez de algorítmicas en su proceso de asignación y evaluación de ruta. Se tiene como propósito plantear un modelo teórico que permita realizar el enrutamiento en una MANET con la implementación de técnicas propias de aprendizaje de máquina y evaluar el desempeño de la red mediante la simulación del modelo propuesto en comparación con uno de los algoritmos de enrutamiento actuales DSR.

Palabras clave: Ad-hoc, MANET, enrutamiento, aprendizaje de máquina, Hopfield.

Abstract

A wireless ad-hoc network consists of a set of mobile wireless nodes that form a network without the aid of any infrastructure or centralized administration. Routing protocols used in ad-hoc networks must automatically adjust to environments where aspects, such as bandwidth and mobility, are highly variable. This paper seeks to measure the impact on performance of routing protocols for mobile *ad-hoc* networks (MANET), if these could involve intelligent techniques instead of algorithmic ones in its evaluation process and route assignment. It is intended to propose a theoretical model that allows routing in a MANET by implementing techniques from learning machine and assess the network performance by simulating the proposed model compared with one of the existing routing algorithms, DSR.

Keywords: Ad-hoc, MANET, routing, learning machine, Hopfield.

1. Introducción

El auge en las telecomunicaciones inalámbricas en las últimas décadas unido a la movilidad que ofrecen los dispositivos portátiles y que requieren los usuarios de hoy día permitió que se presente un nuevo escenario de operación, el enmarcado dentro de lo que se conoce como *redes móviles inalámbricas ad-hoc* (MANET: Mobile Ad-hoc NETWORKS, Corson & Macker, 1999). Estas redes nacen bajo el concepto de autonomía e independencia, al no requerir el uso de infraestructura pre-existente ni la necesidad de soportar su administración en esquemas centralizados como lo hacen las redes cableadas actuales. Por supuesto los retos técnicos y funcionales que deben afrontar estas redes son aún muchos y muy exigentes.

Al no existir infraestructura cableada en las redes ad-hoc, las labores de enrutamiento dependen dramáticamente de factores claves como la movilidad y el ancho de banda. La movilidad hace que el tiempo de vida de un enlace entre dos nodos pueda variar y el ancho de banda limitado hace que la red se congestione fácilmente debido a la señalización de control. Los esquemas de enrutamiento desarrollados para las redes cableadas raramente consideran restricciones de este tipo; en cambio, asumen condiciones más estables y que el tamaño de los encabezados de los mensajes de enrutamiento es despreciable.

Considerando las diferencias existentes entre las redes cableadas y las inalámbricas, se plantea el desarrollo de un modelo de enrutamiento dinámico en redes inalámbricas ad-hoc basado en aprendizaje de máquina, que reaccione congruentemente a los cambios de la topología de la red y permita evaluar la hipótesis planteada de: *“si el costo computacional del enrutamiento se ve mejorado con la aplicación de los métodos de aprendizaje de máquina, en comparación con los algoritmos de enrutamiento actuales”*.

La motivación principal de la investigación es evaluar la forma de suministrarle a la red la capacidad de tomar las decisiones de enrutamiento usando técnicas basadas en *sistemas inteligentes* (Se entiende por *sistemas inteligentes* los modelos de *intelligen-*

cia inspirados en los sistemas biológicos, los cuales tienen capacidades emergentes dentro de su dinámica evolutiva) para proponer esquemas generales que soporten un modelo de toma de decisiones de enrutamiento inteligente para una red móvil ad-hoc.

El tema de la computación móvil es muy amplio y existen múltiples aspectos en los cuales investigar y mejorar, si le adicionamos las bondades de la computación inteligente, las ventajas pueden mejorar considerablemente. Estas razones motivan el desarrollo del actual proyecto como *un primer intento por integrar estas dos ramas*.

El proyecto planteado es abordado desde tres ángulos: el primero, la investigación de los protocolos actuales de enrutamiento para redes móviles ad-hoc y de técnicas de aprendizaje de máquinas; el segundo es el planteamiento teórico del modelo de enrutamiento a proponer su criterio de evaluación y desempeño obtenido, y el tercero, la simulación computacional del modelo.

2. Técnicas de evaluación y desempeño

Métricas para la evaluación de un protocolo

Demora y rendimiento de procesamiento de extremo a extremo: las medidas estadísticas del desempeño en el enrutamiento de datos (por ejemplo, medias, varianzas y distribuciones) son importantes. Estas son las medidas de eficacia de las políticas de enrutamiento —que tan bien hacen su trabajo— según la medición desde una perspectiva “externa” de otras políticas que hacen uso del enrutamiento.

Porcentaje de entregas fallidas: una medida externa del desempeño sin conexión del enrutamiento, de interés particular para los protocolos de la capa de transporte, tales como TCP, que prefieren la entrega de datos en orden.

También se debe considerar el “contexto de red” en el cual se mide el desempeño del protocolo. Los parámetros esenciales que se deberían variar son: tamaño de la red, medido en el número de nodos; conectividad de la red, el grado de un

nodo (por ejemplo, el número promedio de vecinos de un nodo); tasa de cambios de topología, es la velocidad con la cual la topología de la red está cambiando; capacidad del enlace, la velocidad eficaz del enlace medida en bits por segundo después de contar las pérdidas debido a acceso múltiple, codificación, enmarcado, etc.; patrones de tráfico, ¿qué tan efectivo es el protocolo para adaptarse a patrones de tráfico no uniforme o exponencial?; movilidad, ¿cuándo y bajo qué circunstancias, existe una relación topológica espacial y temporal relacionada con el desempeño del protocolo de enrutamiento? En ese caso, ¿cuál es el modelo más apropiado para simular la movilidad del nodo en las MANET?

Técnicas de evaluación

Lo primero que se necesitó para desarrollar el modelo era tener como referencia un entorno inalámbrico que nos brindara información sobre la topología de la red, los modelos de movilidad de los nodos, los modelos de tráfico de la red, su comportamiento en el tiempo, y en general toda la información de enrutamiento del algoritmo seleccionado para el análisis: DSR, para extraer de ahí la información que alimentaría nuestra red neuronal. Por esta razón, la simulación de los algoritmos de enrutamiento se hizo mediante la herramienta de software NS2 ([http://www.isi.edu/nsnam/ns/Network Simulator 2 \(NS2\)](http://www.isi.edu/nsnam/ns/Network%20Simulator%20(NS2))), herramienta desarrollada por el Information Sciences Institute de la University of Southern California, cuya validez y desempeño ya ha sido probada y ratificada por investigaciones similares (Maltz, 2001; Broch *et al.*, 1998; CMU Monarch Project, 2012).

Es importante advertir las limitaciones de los modelos de simulación y entender que una simulación no puede capturar la interacción completa de los componentes que suceden en un sistema real dentro de un entorno real.

3. Planteamiento del modelo

Como ya se ha dicho, la mayoría de los algoritmos de enrutamiento actuales se ocupan de des-

cubrir una ruta y mantienen dicha comunicación siempre que la conexión no se pierda, sin evaluar si existe una nueva ruta en el tiempo que preste mejor desempeño a nivel de longitud de ruta, confiabilidad del enlace, o si la ruta establecida se ha congestionado con las demás comunicaciones existentes en la red.

El presente trabajo se centró fundamentalmente en cuestionar variables como la movilidad, la congestión y la confiabilidad de la ruta del algoritmo de enrutamiento utilizado para establecer las comunicaciones, en comparación con el manejo actual de los algoritmos de enrutamiento dada la necesidad de implementar algoritmos que sean congruentes con los cambios del entorno, característica importante de los sistemas móviles.

El trabajo radica en plantear el problema de enrutamiento en una red inalámbrica móvil ad-hoc, en la que se desarrollan múltiples comunicaciones, como un problema de optimización, el cual será solucionado utilizando un modelo de red neuronal, de manera similar a como lo realizaron Hopfield y Tank (1985) para resolver el problema del agente viajero.

La red planteada se define como un conjunto de nodos interconectados en forma inalámbrica, cada uno de ellos con características móviles. En dicho entorno, se establecen múltiples comunicaciones entre los diferentes nodos (parejas fuente-destino); la idea es proveerle a la red los parámetros necesarios para que pueda decidir las rutas que conectarán a todas las parejas fuente-destino, aprovechando las características inherentes de los sistemas de aprendizaje. La figura 1 presenta el esquema general de la propuesta de este artículo.

3.1. Simulación de protocolos

Configuración de nodos y topología: Script principal OTCL.

Definición de tipos de antenas y modelos de propagación: Script principal OTCL.

Paquetes y formatos: archivo de salida simulación.

Enlaces y agentes: Script principal OTCL.

Modelos de movilidad: Script OTCL con los parámetros de movilidad.

Modelos para generación de tráfico: Script OTCL que establece el flujo de datos entre los nodos.

3.2. Extracción de variables e información relevante

Las rutas o conjunto de rutas por cada pareja de nodos que se están comunicando en la red son cargados desde el archivo trace, (*Archivo plano con extensión *.tr generado por el Software NS2, el cual contiene de manera secuencial el Log de toda la simulación, representado por cada uno de los paquetes generados por cada nodo*) que es generado como salida del simulador. De estos datos se determina:

- Características del escenario de simulación.
- Número de parejas de nodos que se están comunicando.
- Rutas descubiertas y establecidas durante la simulación del protocolo de enrutamiento.
- Modelo de movilidad, el cual define la posición de cada nodo en el tiempo.
- Registro secuencial de todos los paquetes generados durante la simulación.
- Métricas del algoritmo de enrutamiento seleccionado.

Los campos de interés para el análisis son:

- Identificador único de nodo
- Identificador único de flujo
- Tiempo del evento
- Identificador de nodo actual
- Identificador de nodo del próximo salto

El objetivo es coordinar la selección de rutas y la sincronización de enlaces de tal manera que se satisfagan los requerimientos de comunicación. Se ha implementado una red neuronal de Hopfield, que escoge rutas basándose en el criterio de minimización de la congestión. A esta red ingresan rutas seleccionadas previamente con un criterio de depuración, a saber, del conjunto de rutas generadas por el simulador NS2 se seleccionan las mejores de acuerdo con una métri-

ca de evaluación cuantificada matemáticamente a partir de dos variables:

- *Longitud de la ruta*: Medida en función del número de saltos entre nodo fuente y destino.
- *Confiabilidad de la ruta*: Medida en función del número de paquetes perdidos.

La confiabilidad de la ruta se define como la sumatoria del número de paquetes perdidos por cada nodo que conforma cada ruta por parejas que se van a comunicar.

La definición matemática de la métrica M_{ij} se expresa en la siguiente ecuación, donde i es la cantidad de parejas fuente/destino (SD, por sus siglas universales *source/destination*), y j la cantidad de rutas existentes por pareja.

$$M_{ij} = \alpha \left(\frac{L_{ij}}{\tau_i} \right) + (1 - \alpha) \left(\frac{C_{ij}}{\varsigma_i} \right) \quad 0 \leq \alpha \leq 1$$

(Ecuación 1)

Donde,

α = constante que indica el porcentaje de prioridad de la variable en la métrica (longitud/confiabilidad).

L_{ij} = Longitud de la ruta $j^{\text{ésima}}$ para la pareja SD i .

τ_i = Cantidad máxima de saltos, de todas las rutas disponibles para la pareja i .

C_{ij} = Confiabilidad de la ruta $j^{\text{ésima}}$ para la pareja SD i .

ς_i = Máximo valor de confiabilidad de todas las rutas disponibles para la pareja i .

El umbral en la siguiente ecuación establece un criterio de selección de ruta, siendo un valor por ruta, es decir, las rutas seleccionadas por pareja serán aquellas que cumplan dicho valor. Siendo la ruta elegida siempre que $M_{ij} \leq U_i$ se cumpla

Se define el umbral como sigue:

$$U_i = \text{Min}(M_{ij}) + \gamma [\text{Max}(M_{ij}) - \text{Min}(M_{ij})] \quad 0 \leq \gamma \leq 1$$

(Ecuación 2)

Donde,

γ = indica el porcentaje o intervalo de la métrica que se establecerá como valor límite, es decir, si el valor de γ se acerca a uno, se considerará el valor máximo de la métrica como umbral; si decrece, el umbral se acercará al valor mínimo de la misma.

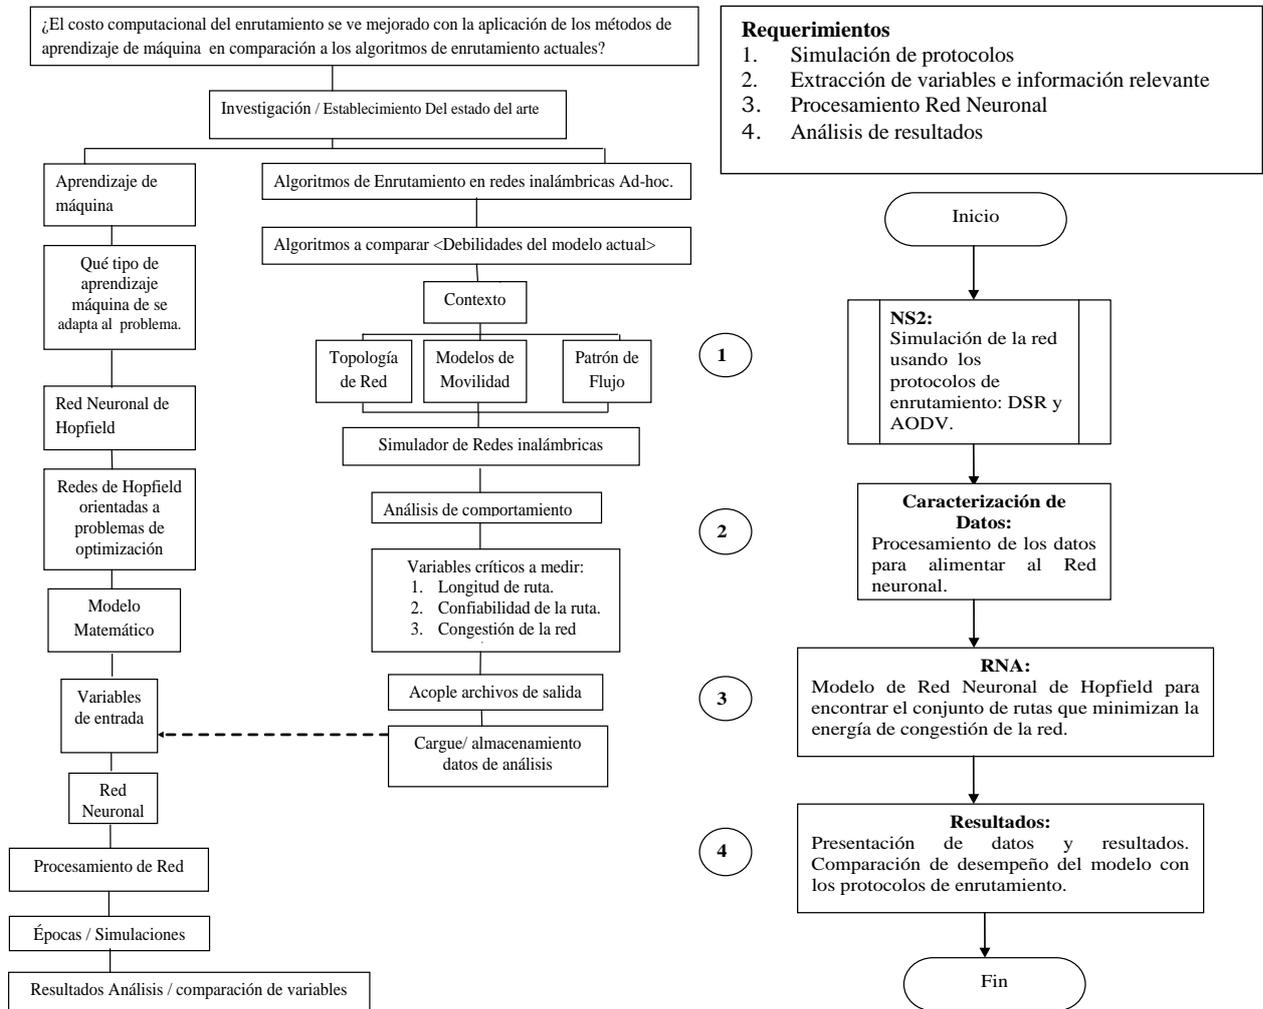


Figure 1. Esquema general de trabajo

Modelo de red neuronal

Red de Hopfield para minimizar la congestión

Se presenta el modelo matemático de una red de Hopfield usado en [5], para la selección de rutas entre múltiples parejas fuente-destino *SD*

que se comunican en un entorno inalámbrico. Además, se presenta la función de energía básica y las ecuaciones de movimiento desarrolladas para el modelo.

El modelo de neurona por ruta

En el modelo, cada neurona representa una ruta para cada pareja *SD*. Se usa un doble índice para

identificar las neuronas, es decir, la neurona ij representa la $j^{\text{ésima}}$ ruta de la pareja i . En la práctica, y debido a que se usan neuronas análogas, una solución admisible tendrá solo una neurona por cada pareja SD con un valor de salida cercano a 1, mientras que las otras neuronas tendrán valores cercanos a 0.

La red evoluciona de un estado inicial hacia un estado final de equilibrio, representado por un mínimo (no necesariamente global) de la función de energía de Lyapunov, la cual puede ser escrita en términos de la matriz de pesos de conexión, los voltajes de salida de las neuronas, como se muestra continuación:

$$E_{total} = -\frac{1}{2} \sum_{i=1}^{Nsd} \sum_{k=1}^{Nsd} \sum_{j=1}^{N_p(i)} \sum_{l=1}^{N_p(k)} T_{ij,kl} V_{ij} V_{kl} - \sum_{i=1}^{Nsd} \sum_{j=1}^{N_p(i)} V_{ij} I_{ij}$$

(Ecuación 3)

El número total de neuronas del modelo, N , está dado por:

$$N = \sum_{i=1}^{Nsd} N_p(i)$$

(Ecuación 4)

Energía de congestión

La meta es minimizar E_b , sujeto a múltiples restricciones. Este problema de optimización restringida puede convertirse en uno de optimización sin restricciones, incorporando tales restricciones a la función objetivo mediante el uso de los multiplicadores de Lagrange. La función de energía para la minimización de la congestión se asume entonces de la siguiente forma:

$$E_{total} = bE_b + \sum_{c=1}^3 \lambda_c E_c - I \sum_{i=1}^{Nsd} \sum_{j=1}^{N_p(i)} V_{ij}$$

(Ecuación 5)

En el estudio los valores de los λ_c se determinaron mediante ensayo y error, durante las simulaciones del software (A diferencia del modelo original de Ephremides et al, en [29] donde los coeficientes λ_c son variables y se determinan mediante una versión modi-

ficada de los multiplicadores de Lagrange). El último término de la Ecuación 5, representa el impacto de los pesos adicionales a las neuronas (sesgo), que en nuestra formulación son aplicados por igual a todas las neuronas para ayudar a las restricciones del sistema. Los coeficientes b , λ_c e I son positivos.

Incorporación de las restricciones a la función de energía

Las restricciones del problema y los términos correspondientes para la ecuación de energía (los cuales deben ser iguales a 0 para satisfacer las restricciones) son resumidos a continuación:

1. *Activar o seleccionar no más de una ruta por cada pareja SD:*

$$E_1 = \frac{1}{2} \sum_{i=1}^{Nsd} \sum_{j=1}^{N_p(i)} \sum_{\substack{l=1 \\ l \neq j}}^{N_p(i)} V_{ij} V_{il} = 0$$

(Ecuación 6)

2. *Activar un total de Nsd rutas en toda la red:*

$$E_2 = \frac{1}{2} \left(\sum_{i=1}^{Nsd} \sum_{j=1}^{N_p(i)} V_{ij} - N_{sd} \right)^2 = 0$$

(Ecuación 7)

3. *Activar exactamente una sola ruta por cada pareja SD: (Aunque esta restricción puede parecer redundante (ya que el cumplimiento de las primeras dos restricciones garantiza el cumplimiento de la misma), su inclusión en la ecuación de energía es útil para lograr la convergencia a soluciones admisibles. El uso de este tipo de restricciones cuasi-redundantes es común en los modelos de NN de Hopfield).*

$$E_3 = \frac{1}{2} \sum_{i=1}^{Nsd} \left(\sum_{j=1}^{N_p(i)} V_{ij} - 1 \right)^2 = 0$$

(Ecuación 8)

Determinación de los pesos de conexión y los pesos propios de las neuronas (sesgo)

Substitución de las expresiones E_b y E_c en la ecuación 5:

$$E_{total} = \frac{b}{2} \sum_{i=1}^{N_{sd}} \sum_{k=1}^{N_{sd}} \sum_{j=1}^{N_s(i)} \sum_{l=1}^{N_s(k)} [P_{ij} \cap P_{kl} | V_{ij} V_{kl}] + \frac{\lambda_1}{2} \sum_{i=1}^{N_{sd}} \sum_{j=1}^{N_s(i)} \sum_{l=1}^{N_s(j)} V_{ij} V_{il} + \frac{\lambda_2}{2} \left(\sum_{i=1}^{N_{sd}} \sum_{j=1}^{N_s(i)} V_{ij} - N_{sd} \right)^2 + \frac{\lambda_3}{2} \sum_{i=1}^{N_{sd}} \left(\sum_{j=1}^{N_s(i)} V_{ij} - 1 \right)^2 - I \sum_{i=1}^{N_{sd}} \sum_{j=1}^{N_s(i)} V_{ij}$$

(Ecuación 9)

destino, que desde el primer tiempo intentan encontrar rutas para mantener un flujo constante de datos CBR con una velocidad de 0,1 segundos por paquete y un tamaño de 512 bytes por paquete, a través de conexiones TCP entre los distintos nodos de la red. Las parejas son:

4. Resultados

Ejemplo: análisis escenario de diez nodos

Este escenario tiene un diámetro de nueve nodos y una longitud promedio de ruta, es decir, la distancia esperada entre un par de nodos arbitrarios, 5,9 nodos. Se analizaron 107 tiempos en total, en los cuales se evaluó las rutas asignadas y activas en cada momento por DSR, las posibles rutas alternas en cada uno de estos 107 tiempos, las rutas preseleccionadas por el aplicativo bajo los criterios de longitud de ruta y congestión de ruta explicados anteriormente, las rutas escogidas por el modelo neuronal de Hopfield y por último, las rutas óptimas en términos de energía de congestión encontradas mediante el método de búsqueda exhaustiva.

En este escenario existen cinco parejas fuente-

Tabla 1. Parejas fuente-destino en escenario diez nodos

Nodo fuente	Nodo destino
7	1
4	5
4	6
6	7
1	7

La tabla 1 muestra los resultados obtenidos para el tiempo 2,91843. En este tiempo se encontraron cuatro rutas para la primera pareja, siete rutas para la segunda pareja, dos rutas para la tercera pareja, tres rutas para la cuarta pareja y cuatro rutas para la quinta pareja. Existen un total de 672 soluciones admisibles, para las cuales el valor mínimo de energía de congestión es de 1.100.

Tabla 2. Simulación diez nodos

Nodo inicio	Nodo fin	Rutas DSR	Rutas descubiertas	Rutas RNA	Rutas óptimas
7	1	[7-5-3-2-4-1]	[7-5-3-2-4-1]	7.5.3.2.4.1	
			[7-5-9-3-2-8-1]		7.5.9.3.2.8.1
			[7-5-9-3-2-4-1]		
			[7-5-3-2-0-4-1]		
4	5		[4-2-0-9-5]		
			[4-0-9-5]	4.0.9.5	4.0.9.5
			[4-0-9-3-5]		
			[4-0-9-3-7-5]		
			[4-0-2-3-9-5]		
			[4-0-2-3-5]		
		[4-2-3-5]	[4-2-3-5]		
4	6	[4-8-6]	[4-8-6]	4.8.6	4.8.6

Nodo inicio	Nodo fin	Rutas DSR	Rutas descubiertas	Rutas RNA	Rutas óptimas
			[4-1-8-6]		
6	7	[6-8-4-2-3-7]	[6-8-4-2-3-7] [6-8-4-0-2-3-9-5-7] [6-8-4-0-2-3-5-7]	6.8.4.2.3.7	6.8.4.2.3.7
1	7	[1-4-2-3-7]	[1-4-2-3-5-7] [1-4-2-3-7] [1-4-0-2-3-5-7] [1-4-0-2-3-9-5-7]	1.4.2.3.7	1.4.2.3.7

La tabla 2 muestra que para tres de las cinco parejas fuente-destino, tanto DSR como el modelo neuronal de Hopfield seleccionaron la ruta óptima en términos de energía de congestión. Para la pareja 4-5, DSR escogió la ruta 4-2-3-5, y la ruta óptima (escogida por el modelo neuronal de Hopfield) era 4-0-9-5, y en la pareja 7-1 DSR y el modelo neuronal de Hopfield seleccionaron la ruta 7-5-3-2-4-1 y la ruta óptima era 7-5-9-3-2-8-1. Esta diferencia representó un incremento del 18,18% en valor de la energía de congestión con respecto al óptimo para DSR y del 4,5% para el modelo neuronal de Hopfield.

De este tiempo, es necesario señalar que aunque ni DSR ni el modelo de neuronal de Hopfield seleccionaron todas las rutas óptimas, el valor obtenido por la red de Hopfield es significativamente mejor que el obtenido por DSR. Por otra parte, la ruta óptima para la pareja 7-1 fue descartada en el proceso de pre-selección de rutas, debido a que en dicha evaluación no solo importa la longitud de la ruta, sino también la confiabilidad de la misma. Lo anterior sugiere que, aunque en términos de energía de congestión de la red es mejor la ruta 7-5-9-3-2-8-1, desde el punto de vista de la confiabilidad es mejor la ruta 7-5-3-2-4-1, seleccionada por la red de Hopfield.

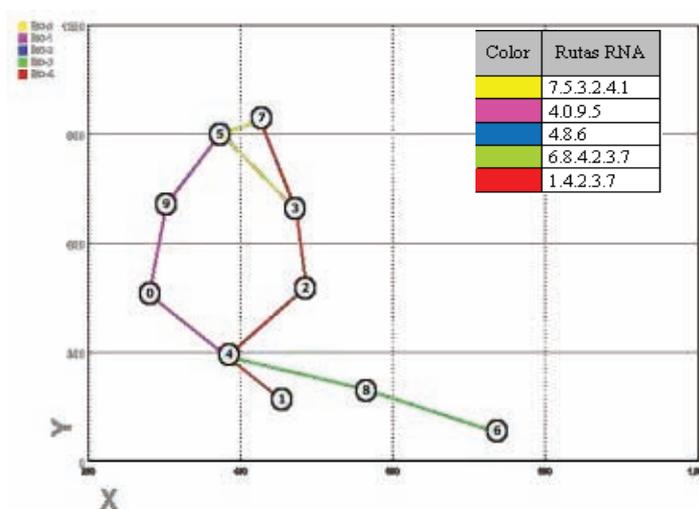


Figure 2. Rutas óptimas escenario un nodo

Influencia de los parámetros alfa, beta, yeta y teta

Debido a que el tiempo y costo computacional que requiere el modelo neuronal de Hopfield para poder seleccionar el mejor conjunto de rutas para todas las parejas del escenario, es directamente proporcional a la cantidad de rutas que se preseleccionen, pues cada ruta significa una neurona para el modelo, los parámetros *alfa*, *beta*, *yeta* y *teta* cumplen una labor importante en el desempeño de este.

Alfa y beta, solo determinan el grado de importancia entre el criterio de longitud y el de confiabilidad de la ruta, es decir, que si $\alpha = 0,5$ y $\beta = 0,5$ significa que para el cálculo del valor de la métrica de cada ruta tiene la misma importancia el valor de longitud que el valor de confiabilidad, en cambio, un valor de $\alpha = 1$ y $\beta = 0$ significaría que para el cálculo de la métrica solo importa la longitud de la ruta (medida en relación con la longitud de las rutas alternas, en un tiempo específico).

Una vez calculadas las métricas para todas las rutas posibles en un tiempo determinado, el parámetro *yeta* determina el valor del umbral de aceptación de ruta por pareja, es decir, las rutas de cada pareja con métricas menores a dicho umbral serán preseleccionadas y analizadas por el modelo neuronal de Hopfield. En caso de que ninguna ruta posea una métrica menor o igual a dicho umbral, el parámetro *teta* especificará la cantidad mínima de rutas por seleccionar, o sea, un valor de $\theta = 0,3$ significará que en caso de que ninguna ruta posea una métrica menor o igual a el umbral, se seleccionará el 30% de las rutas disponibles con los menores valores de métrica.

Después de múltiples simulaciones y de probar con distintos valores para alfa, beta, yeta y teta, para todos los escenarios que se explicarán a continuación, se fijaron los siguientes valores, ya que presentaron un mejor desempeño.

Alfa = 0,6
Beta = 0,4
Yeta = 0,6
Teta = 0,5

Convergencia del modelo neuronal de Hopfield y comportamiento de la función de energía

En todos los escenarios simulados y en especial en la etapa de afinamiento del modelo se buscaron, mediante ensayo y error, los valores para los parámetros b , λ_1 , λ_2 , λ_3 y Δt de tal manera que lograran garantizar la convergencia de la red y a su vez minimizaran la cantidad de épocas necesarias. Así, los valores seleccionados fueron:

$b = 50$
 $\lambda_1 = 100$
 $\lambda_2 = 500$
 $\lambda_3 = 500$
 $\Delta t = 0,0002$

La figura 3 muestra la evolución de la función de energía a lo largo de las 300 épocas simuladas de la red neuronal para el escenario de diez nodos, aunque se corrieron 300 épocas de simulación para la red neuronal de Hopfield, la red converge alrededor de la época 50. Durante la simulación de varios escenarios, se evidenció que el tiempo de convergencia está relacionado con la cantidad de rutas disponibles.

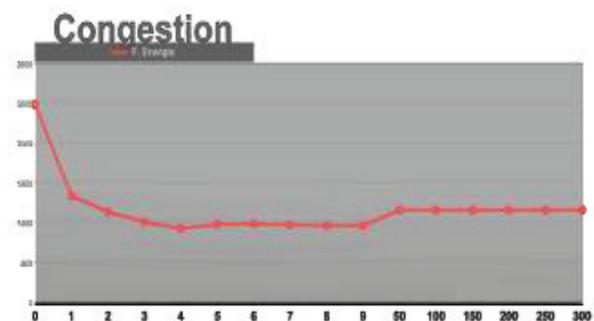


Figure 3. Convergencia función de energía

5. ¿Por qué un sistema inteligente?

Los programas clásicos son primordialmente procedimentales, sofisticados, secuenciales y rígidos, y tienden a reflejar ordenadamente el dominio para el cual fueron escritos. En consecuencia,

son deterministas y no poseen redundancia. Un programa convencional exhibe habitualmente una distinción más bien engañosa entre código y datos. Esto quiere decir entre la receta para manipular estructuras de información.

Los programas basados en algoritmos son inútiles para codificar experiencia o como vehículos para comunicarla. En contraste con los sistemas de procesos de datos tradicionales, los sistemas de aprendizaje de máquinas (ML —*machine learning*—) suelen aplicar características específicas, como son la representación e inferencia simbólica y la búsqueda heurística. En un sistema inteligente base de conocimiento se manipula, por separado, mediante una estrategia de control claramente identificable. Este esquema arquitectónico proporciona una forma conveniente de construir herramientas sofisticadas de solución de problemas en muchos dominios de la ciencia y la técnica.

En resumen, los programas convencionales organizan los conocimientos en dos niveles: datos y programas. Por su parte, los sistemas de aprendizaje organizan sus conocimientos en tres niveles: datos o hechos, reglas operativas o heurísticas, e inferencia y control. Los dos primeros niveles hacen parte de la base de conocimientos: es un programa que toma la decisión sobre cómo usar los conocimientos específicos que se tiene acerca del problema en curso de solución, emplean auto conocimientos para razonar acerca de sus propios procesos de inferencia y proporcionan explicaciones o justificaciones para las conclusiones obtenidas.

6. Conclusiones y retos

Este artículo propone un nuevo método de enrutamiento en redes ad-hoc basadas en el descubrimiento y mantenimiento de rutas mediante un sistema de procesamiento inteligente, establece un modelo comparativo de la red bajo métodos de enrutamiento actuales en redes móviles ad-hoc. El desempeño de este acercamiento depende de varios factores, como la evaluación de rendimiento en el software, pues no existe el

hardware que corra la configuración requerida, la abstracción del modelo real que supone obviar variables.

Es necesario reiterar que el modelo neuronal de Hopfield se plantea con un modelo teórico, el cual, a la luz de los resultados mostrados, se convierte en una alternativa para solucionar problemas combinatoriales complejos, como el de determinar el valor mínimo de energía de congestión en redes móviles inalámbricas ad-hoc. El hecho de que el valor mínimo de energía no se alcance siempre es una limitación heurística inherente a este tipo de problemas, donde solo mediante una búsqueda exhaustiva se puede garantizar óptimos absolutos. El hecho de que en la mayoría de escenarios, el modelo de Hopfield planteado encontró valores óptimos o cercanos al óptimo sugiere que este modelo puede ser escalable a redes de mayor tamaño.

Los criterios de longitud de ruta y de confiabilidad de ruta implementados a través de los parámetros alfa, beta, yeta y teta demostraron filtrar adecuadamente la totalidad de rutas, además de contribuir enormemente al desempeño del modelo, pues redujeron significativamente los tiempos de convergencia.

Como trabajo futuro se propone plantear el modelo neuronal de Hopfield con un enfoque distinto en el que cada neurona represente no una ruta para cada pareja, sino un enlace nodo a nodo. Dicho enfoque permitiría a la red analizar conjuntamente el problema de asignación y mantenimiento de ruta y el de congestión. Este planteamiento debería considerar todas las interacciones de cada nodo con los posibles nodos alrededor. La complicación más obvia de este planteamiento es el incremento en el número de neuronas y de interconexiones para poder simular el sistema; una complicación adicional es garantizar el establecimiento de rutas completas entre los nodos fuente-destino, condición que podría satisfacerse con la inclusión de una restricción adicional al modelo matemático de Hopfield, la cual provea excitación adicional a las neuronas pertenecientes a una misma ruta.

En el aspecto funcional, se puede admitir que el modelo planteado arroja resultados funcionales

iguales y supera a DSR en muchos escenarios; también se evidenció que debido a la necesidad de recrear el escenario de simulación con criterios cuantificables dentro de las normas estrictas y validadas por los organismos encargados de regular no solo el medio, sino también la comunicación y su calidad de replicarlos hace que:

Primero, se dependa del cargue y migración de información de un sistema a otro, es decir, del simulador de red NS2 al aplicativo del modelo de enrutamiento basado en la red neuronal de Hopfield.

Segundo, que el costo computacional aumente debido al intercambio de información entre la base de datos y el NS2, y no por el procesamiento inherente a la convergencia de la red.

Por lo anterior, se plantea como trabajo futuro migrar el desarrollo como un módulo interno del NS2, soportado en el conocimiento de NS2 y la interacción con el lenguaje de programación que él implementa; de esta manera, se ahorraría tanto el tiempo de máquina utilizado para el cargue de la información como el tiempo utilizado para recuperar y darle el formato requerido para que la red neuronal lo procese.

Referencias

- [1] Broch, J., Maltz, D., Johnson, D., Hu, Y. & Jetcheva, J. (1998). Performance comparison of multi-hop wireless ad hoc network routing protocols. Pittsburgh: Jetcheva, Josh Computer Science Department Carnegie Mellon University.
- [2] CMU Monarch Project. The CMU Monarch Project's ad-hockey Visualization Tool For ns Scenario and Trace Files <http://www.monarch.cs.rice.edu/ftp/monarch/wireless-sim/ad-hockey.ps> [consultado el 15 de marzo de 2012].
- [3] Corson, S. & Macker, J. (1999). Mobile Ad Hoc Networking (MANET): Routing protocol performance issues and evaluation considerations. Network Working Group. RFC 2501.
- [4] Hopfield, J. & Tank, D. (1985). Neural computation of decisions in optimization. *Biological Cybernetics*. vol. 52, pp. 141-152.
- [5] Johnson, D., Maltz, D. & Hu, Y. (2001). The Dynamic Source Routing Protocol for Mobile Ad Hoc Networks. Network Working Group, RFC 4728.
Maltz, D. (2001). On-demand routing in multi-hop wireless mobile ad hoc networks. School of Computer Science Carnegie Mellon University Pittsburgh. Vol. PA 15213. CMU-CS-01-130.
- [6] Wieselthier, J., Barnhart, C. & Ephremides, A. (1994). *A neural network approach to routing without interference in multihop radio networks*. US Naval Research Laboratory, Washington, DC.