

REDES NEURONALES EN PLANIFICACIÓN Y OPERACIÓN DEL TRANSPORTE

Violeta S. Depiante y Jorge J. Galarraga

Investigadores del Instituto Superior de Ingeniería del Transporte
Casilla de Correo 624 Correo Central - Córdoba - Argentina. Email:isit@com.uncor.edu

Resumen

Los modelos de redes neuronales artificiales (ANN's) intentan imitar el comportamiento del sistema biológico de neuronas. Procesan la información de una manera totalmente diferente, en donde la misma se ajusta y mantiene dentro de una estructura o arquitectura de interconexiones generalizando sobre la base de la información disponible.

Los autores han realizado estudios que permiten afirmar que los modelos de redes neuronales se pueden aplicar con resultados satisfactorios a problemas de planificación y operación del transporte. El presente trabajo reporta los resultados obtenidos en el caso específico de predicción de viajes inducidos por la creación de una nueva infraestructura vial y en la estimación de demoras promedio en intersecciones semaforizadas.

En lo que se refiere al caso de planificación, el trabajo considera la estimación de viajes inducidos por la creación de una nueva conexión y compara los resultados obtenidos empleando redes neuronales con los datos obtenidos mediante la aplicación de un procedimiento tradicional. Queda demostrado que pronostica de manera similar al modelo gravitatorio, que fue la metodología clásica utilizada.

En lo que se refiere al caso de operación, el trabajo considera intersecciones aisladas y compara los resultados obtenidos empleando redes neuronales con los relevados en campaña y con los calculados empleando la metodología propuesta por el Manual Capacidad de Carreteras en su versión 1994. Se reportan los procedimientos y resultados alcanzados en las etapas de aprendizaje y validación de la red. Se efectúan también consideraciones sobre el empleo de redes neuronales para calcular demoras en intersecciones semaforizadas con flujos coordinados, mediante el análisis de relevamientos y modelaciones efectuadas en el centro de la ciudad de Córdoba, cuyo control se realiza a través de un sistema centralizado.

Los resultados de las comparaciones indican que los modelos de redes neuronales pueden emplearse para resolver razonablemente problemas de planificación y operación de transporte, en particular las estimaciones realizadas por esta metodología, tanto de viajes inducidos como de demoras medias en intersecciones semaforizadas, resultaron similares, y en algunos casos superiores, a las realizadas mediante procedimientos tradicionales.

1. INTRODUCCIÓN

El sistema nervioso humano está constituido por células llamadas neuronas. Se estima que alrededor de 10^{11} neuronas están interconectadas entre sí por probablemente 10^{15} interconexiones. Una neurona biológica acepta entradas de un gran número de neuronas similares, procesa esas entradas, y manda copias de su única salida a otras neuronas sobre una red de interconexiones llamadas axones; éstos a su vez se desdoblan generando muchas ramificaciones llamadas axones colaterales. Cada punta de ese colateral termina en la entrada de otra neurona en una conexión especial llamada sinapsis. Las partes de la neurona a las cuales generalmente se conectan estas sinapsis se llaman dendritas. Muchas, pero no todas las sinapsis son adaptativas o plásticas; o sea pueden incrementar o disminuir su fuerza, bajo condiciones adecuadas. Como resultado pueden tener diferentes activaciones o pesos sinápticos. Tienen también efectos de excitación o inhibición en la activación de su neurona asociada. Por último son unidireccionales, la señal pasa en una sola dirección.

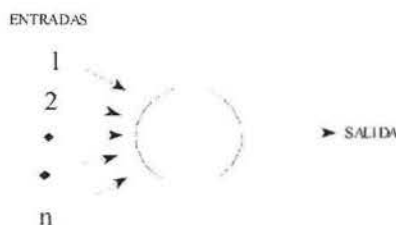


Figura 1. Neurona artificial típica.

En las redes neuronales artificiales, una neurona artificial fue diseñada para recibir una serie de entradas, procesarlas y generar una sola salida (ver Figura 1).

Pese a que una simple neurona pueda realizar ciertas funciones sencillas, el poder que poseen las neuronas radica en las interconexiones entre las mismas dentro de una red.

La **estructura de una red neuronal artificial** (ANN) trata de imitar la arquitectura biológica neuronal. Una ANN posee:

- **Nodos** o unidades de procesamiento (PE)
- **Interconexiones** (caminos, pasos o vinculaciones entre neuronas)
- **Sinapsis** (la unión donde se encuentra la conexión con el nodo)

que se corresponden con las neuronas, los axones y las sinapsis de los sistemas biológicos.

El modelo de red neuronal que más amplía y extensamente se utiliza es el modelo de retropropagación (BP). Algunos estiman (referencias bibliográficas 1, 2, 3, 4,5) que el 90% de todas las aplicaciones sobre modelos neuronales se basan en este tipo de red. Esta red es la que predice el movimiento en los mercados, reconoce la escritura manual, de texto escrito puede generar texto hablado y puede conducir un camión.

2. CÁLCULO DE LOS VIAJES INDUCIDOS POR EL PROCEDIMIENTO TRADICIONAL

La distribución de viajes (o transferencias interzonales) es parte del planeamiento del transporte que relaciona un número dado de orígenes de viaje para cada zona del área sometida a estudio, con un número dado de destinos ubicados dentro de otras zonas del área. No está necesariamente referida al medio de transporte utilizado para un viaje dado, ni a los trayectos que podrían tomarse para completar el viaje. Más bien se refiere al establecimiento de conexiones entre un número de zonas.

Muchos han sido los procedimientos matemáticos desarrollados para este fin, pero en general caen dentro de dos grupos: métodos analógicos y sintéticos. Los métodos sintéticos intentan entender la relación causal que existe entre las características de los movimientos y las supone similares a ciertas leyes del comportamiento físico como es el modelo gravitatorio, que es uno de los más usados debido a que es simple para entender y aplicar. Éste se basa en la hipótesis de que el intercambio de viajes entre zonas es directamente proporcional a la atracción relativa de cada zona e inversamente proporcional a cierta función de la separación espacial (distancia entre zonas) es decir a la resistencia entre zonas.

El Instituto Superior de Ingeniería del Transporte (I.S.I.T.) de la Universidad Nacional de Córdoba participó en el estudio del tránsito potencial de la futura conexión vial sobre el río Paraná entre las ciudades de Rosario y Victoria (referencia bibliográfica N° 6).

Dentro de las modificaciones de la demanda de desplazamientos inducidos por la creación de la conexión Rosario - Victoria se planteó la utilización de un modelo. Mediante la utilización de este modelo de simulación se reorganizaron los trayectos al momento de la creación de la nueva conexión pero se dejaron de lado las modificaciones de orígenes y destinos autorizadas por la nueva conexión y la generación de nuevos trayectos.

Este tipo de problema puede tratarse considerando que la intensidad de las relaciones entre las zonas es proporcional a las características de las generadoras de tránsito e inversamente proporcional al alejamiento de ellas, o sea un caso especial de modelo de distribución de viajes.

Se utilizó un ajuste gravitatorio para obtener una estimación de los vehículos livianos, siendo la relación empleada la siguiente:

$$T_{ij} = k (P_i \cdot P_j)^a / D_{ij}^b \quad (1)$$

en donde:

T_{ij} : intensidad de la relación

P_i, P_j : población de las zonas i, j

D_{ij} : distancia más corta por la ruta entre las dos zonas

Se buscó el mejor ajuste de los parámetros a , b y k en ausencia de la nueva conexión.

3. ESTIMACIÓN DE LOS VIAJES INTERZONALES MEDIANTE REDES NEURONALES

Se estudio este tránsito inducido mediante un modelo de red neuronal (referencia bibliográfica N° 7). Para ello se consideró una red compuesta de tres nodos de entrada en correspondencia con los datos disponibles de población en las dos zonas y el tercero referido a la distancia entre ambas zonas; y un sólo nodo de salida correspondiente a la intensidad de la relación entre los dos lugares expresada en desplazamientos entre ambos.

Se consideraron en un principio los datos en su forma original. Se propagaron los mismos por redes de diferentes arquitecturas (una, dos y tres capas intermedias), con cantidad variable de nodos no obteniéndose resultados congruentes. Se analizaron los datos en mayor profundidad observando la gran dispersión que existía en los mismos (valores de población origen entre 41 y 12268 habitantes, valores de TMDA entre 0 y 1765 vehículos por día; y valores de los volúmenes ajustados entre 1,2 y 1403 vehículos por día). Tales diferencias hacían que por más que la red tratara de modelar el sistema y los errores fueran pequeños (por ejemplo 20 vpd.) éstos eran muy grandes para valores pequeños de tránsito y generaban incongruencia. Se pensó en descartar algunos conjuntos de datos pero analizándolos más en detalle (se representaron gráficamente cada una de las variables como se observa en los Gráficos 1 y 2) se observó que una transformación matemática de los mismos los presentaría en una forma mas adecuada para la red. Es así que se tomó el logaritmo de los datos a fin de disminuir dicha dispersión durante el análisis.

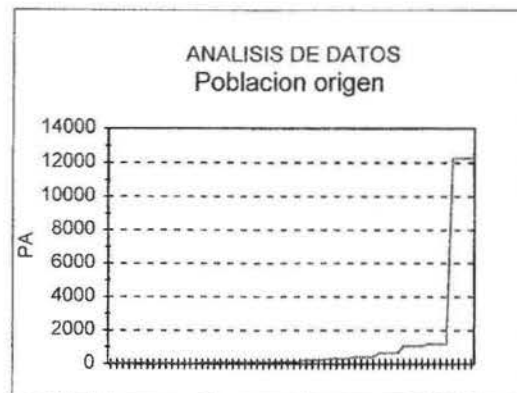


Gráfico 1. Estudio de dispersión de datos de población origen.

Se trabajó originalmente con los 60 datos en la situación actual para la etapa del entrenamiento. Primeramente se consideró una red conformada de tres entradas (P_A , P_B , D_{AB}) y una salida (TMDA). Se analizaron dos capas de cuatro y dos nodos cada una y de una capa con cuatro nodos. El funcionamiento con una capa superó al de dos capas por lo que se procedió a considerar en esa única capa de uno a cinco nodos. La red constituida por un sólo nodo en la capa intermedia fue la de mejor ajuste y fue la arquitectura que se adoptó.

El valor de tránsito total pronosticado por la red superaba en un 17% al volumen ajustado por el modelo de gravedad (513 contra 438,5 vpd).

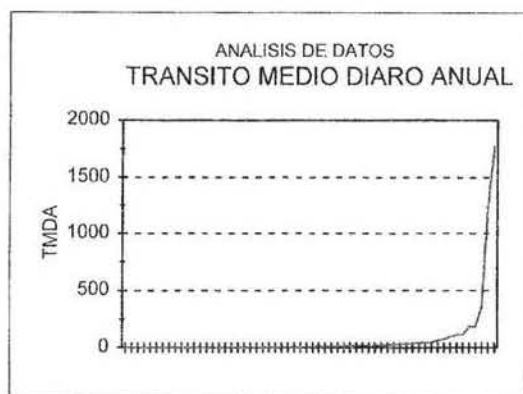


Gráfico 2. Estudio de dispersión de datos del Tránsito Medio Diario Anual (TMDA).

TMDA	Gravitatorio V_{AB}	Red Neuronal ANN
3.3	4.2	3.3
5.3	9.2	6.5
34.9	84.3	69.4
1	3.6	3.0
3.9	5.7	3.7
1.5	2.5	2.6
1	4.6	4.4
4.4	14.4	17.0
45.4	150.9	201.3
1.2	3.9	4.0
3.6	4.3	3.4
3.3	15.1	6.1
1	7.4	4.1
4.6	15.6	8.1
1	2.8	2.5
1.6	4.1	3.4
1.3	9.4	7.3
26.6	87.8	80.9
1	3.5	3.1
5.5	5.2	3.5
151.4	438.5	437.9

Cuadro 1. Comparación de pronóstico neuronal y gravitatorio

Se trabajó también con las poblaciones destino que poseían similar valor (30 datos) durante la fase de entrenamiento y una sola capa intermedia con un nodo oculto. El valor del tránsito total entrenado para la red de un nodo y 30000 iteraciones fue de 2202 vpd, mientras que con el ajuste gravitatorio ascendió a 3355 vpd. y el TMDA correspondía a 2528 vpd. Lo que reflejaría un entrenamiento adecuado.

Los valores referidos al pronóstico del tránsito inducido por la nueva infraestructura fueron prácticamente iguales a los pronosticados por el ajuste gravitatorio (si se consideran 150000 iteraciones como óptimo para el pronóstico) y el 5% superiores si se considera la óptima entrenada. El Cuadro 1 muestra los resultados obtenidos en el pronóstico.

Se realizó una predicción de los viajes totales inducidos suponiendo que exista un incremento de la población de un 2%. Se presentan los resultados obtenidos con las dos metodologías en el Cuadro 2. Puede observarse que los viajes totales pronosticados por la red son un 5% inferiores a los del ajuste gravitatorio.

TMDA	Red Neuronal	Ajuste Gravitatorio	La red pronostica un:
5.3	6.8	10.0	-32%
34.9	72.4	92.1	-21%
1.0	3.1	3.9	-21%
3.9	3.8	6.3	-39%
1.5	2.6	2.7	-4%
1.0	4.6	5.0	-8%
4.4	17.8	15.7	13%
45.4	207.6	164.7	26%
1.2	4.1	4.2	-4%
3.6	3.5	4.7	-26%
3.3	6.3	16.5	-62%
1.0	4.3	8.1	-47%
4.6	8.5	17.0	-50%
1.0	2.6	3.1	-16%
1.6	3.5	4.4	-21%
1.3	7.6	10.2	-26%
26.6	84.3	95.9	-12%
1.0	3.2	3.8	-16%
5.5	3.6	5.6	-35%
148.1	450.2	474.0	-5%

Cuadro 2 Comparación de metodologías considerando un incremento de población.

Se muestran también los valores porcentuales de diferencia relativos al ajuste gravitatorio.

Debido a la falta de datos reales es que se dispone de dos métodos de pronósticos que sólo pueden compararse entre sí, pero no realizar una valoración del que mejor ajusta a la realidad. Sí queda

demostrado que la red pronostica de manera similar al modelo gravitatorio que es la metodología clásica utilizada normalmente.

También se analizaron los resultados de propagar 50 datos a través de la red. Los Cuadros 3 y 4 muestran los tránsitos totales obtenidos para cada aproximación y las relaciones entre los resultados encontrados.

Puede apreciarse que en el pronóstico, los valores que se estiman al ponerse en funcionamiento la nueva conexión predichos por el modelo de gravedad superan en un 22%, 2% y 6% a los predichos por la red para 30, 50 y 60 datos de entrenamiento considerados.

Datos	Salida	Entrenamiento			Verificación			Pronóstico		
		TMDA	RED	GRAV.	TMDA	RED	GRAV.	TMDA	RED	GRAV.
30	TMDA	2529	2193	3355.9	2153.9	854	1323	151.4	358	438.5
50	TMDA	2791.2	2512	3712.9	1892.5	561	966	151.4	432	438.5
60	TMDA	4638.3	3644	4678.9				151.4	414	438.5

Cuadro 3. Comparación de tránsitos totales inducidos

Datos	Salida	Entrenamiento			Verificación			Pronóstico		
		TMDA	RED	GRAV.	TMDA	RED	GRAV.	TMDA	RED	GRAV.
30	TMDA	1	0.87	1.33	1	0.40	0.61	1	2.36	2.90
50	TMDA	1	0.90	1.33	1	0.30	0.51	1	2.85	2.90
60	TMDA	1	0.79	1.01				1	2.73	2.90

Cuadro 4. Comparación de las relaciones entre los resultados encontrados

4. CALCULO DE LA DEMORA PROMEDIO POR EL PROCEDIMIENTO TRADICIONAL

El nivel de servicio de una intersección con semáforo *se define a través de las demoras, las cuales representan para el usuario una medida del tiempo perdido de viaje, del consumo de combustible, de la incomodidad y de la frustración*. Específicamente, el nivel de servicio se expresa en términos de la demora media por vehículo debida a detenciones para un período de 15 minutos.

Según el Manual de Capacidad de Carreteras (referencia bibliográfica N° 8), la demora total para un grupo de carriles i , de una intersección aislada se expresa como la suma de una componente uniforme y una incremental:

$$d_i = d_u + d_a \quad (2)$$

donde :

d_i es la demora total para el grupo de carriles i (seg./veh.)

d_u es la **demora uniforme** para el grupo de carriles i (seg./veh.)

d_a es la **demora incremental** para el grupo de carriles i (seg./veh.)

La demora uniforme es la que ocurriría si los vehículos llegaran uniformemente distribuidos, tal que no existiera saturación durante ningún ciclo. La demora incremental toma en consideración las llegadas aleatorias que ocasionan que algunos ciclos se sobresaturen.

Según el manual la demora promedio por vehículo es dependiente de la longitud del ciclo considerado, de la longitud de verde, de la capacidad del acceso y del grado de saturación del mismo, es decir de cuatro variables. La función que las vincula es:

$$d = 0.38C((1-g/C)^2 / [(1-(g/C)\min(X,1)] + 173X^2((X-1) + \text{Sqrt}[(X-1)^2 + mX/c]) \quad (3)$$

donde

d: demora promedio por vehículo [seg]

C: longitud de ciclo [seg]

g: verde efectivo [seg]

X: grado de saturación

c: capacidad [vph]

m: término de calibración de la demora incremental que representa el tipo de llegada

En la mayoría de los casos las llegadas de los vehículos no son del todo aleatorias, sino en forma agrupada como resultado de la progresión en los semáforos y otros factores. Es decir la calidad de la progresión es una de las características más críticas a cuantificar para completar el análisis de la circulación de una intersección regulada con semáforos. El parámetro que mejor describe esta característica es el tipo de llegada para cada grupo de carriles. Este parámetro es una clasificación general que indica de forma aproximada la calidad de la progresión.

La mejor manera de determinar el tipo de llegada es mediante su observación en el campo, pero puede aproximarse examinando los diagramas de tiempo - espacio de la arteria o calle en estudio. Se debe determinar el tipo de llegada lo más exactamente posible, porque tendrá un impacto significativo en las estimaciones de la demanda y en la determinación del nivel de servicio.

La aplicación de un factor de ajuste por progresión requiere de un conocimiento detallado de los desfases, velocidades de recorrido, y la semaforización de las intersecciones. Este factor se aplica sobre la demora uniforme y se obtiene la demora ajustada adicionando la componente aleatoria.

$$d = d_u \cdot FP + d_a \quad (4)$$

donde:

d es la demora ajustada para el grupo de carriles,

FP es el factor de ajuste por efecto de la progresión de los semáforos

5. ESTIMACION DE DEMORAS PROMEDIO MEDIANTE REDES NEURONALES

En 1996 mediante el empleo del nuevo sistema de control centralizado instalado por la municipalidad de Córdoba, se realizaron numerosas filmaciones de intersecciones semaforizadas del centro de la

ciudad (referencia bibliográfica N° 9), en las cuales se determinó la demora realmente experimentada por los vehículos utilizando la metodología descripta propuesta en el Manual de Capacidad.

Sobre la base de la información disponible, se emplearon redes neuronales para calcular las demoras y comparar los resultados obtenidos con la metodología tradicional provista por el manual.

Los datos disponibles correspondieron a cinco intersecciones en el centro de la ciudad. Todos medidos sobre el acceso principal pues las cámaras instaladas así lo permitían. En cada intersección se tomaron datos en tres horarios y sólo en una se lo realizó en cuatro horarios resultando un total de 16 grupos de datos a analizar. Se obtuvieron datos de intensidad (I), flujo de saturación (S), longitud de ciclo (C) y verde efectivo (g) para cada uno de los conjuntos de datos.

Estos datos fueron subdivididos en tres grupos a fin de utilizarlos en las distintas fases de entrenamiento, verificación y pronóstico; y también se los dividió según el factor de progresión involucrado en cada intersección en cuatro grupos (dos de entrenamiento y dos de verificación correspondientes a los factores existentes). En ambos casos se entrenó la red propagando estos datos a través de la misma a fin de que representaran la realidad medida en campaña.

Los datos se prepararon para poderlos propagar por la red. Se estudiaron casos de una y dos capas intermedias. La red de una sola capa resultó más eficiente. Se analizaron dentro de esta entre tres y seis nodos ocultos. La capa intermedia con cinco nodos resultó la que mejor representaba la demora real considerando los datos en su conjunto (sin subdividirlos por el factor de progresión).

Se propagaron también por la red ya entrenada los datos correspondientes a cada grupo de factores de progresión a fin de ver que resultados se obtenían. Pudo observarse que se obtenían mayores errores cuadráticos medios (RMS) para los datos con mayor factor de progresión (FP).

Parecía más razonable la subdivisión de los datos en función del factor de progresión por lo que se entrenaron dos redes por separado. Los resultados obtenidos arrojaron errores menores a los obtenidos considerando una única red. Cada red entrenó más rápidamente siendo necesarios sólo tres nodos en una sola capa intermedia para representar adecuadamente las demoras.

Una vez entrenadas también se propagaron por las mismas los archivos correspondientes a los restantes casos. Se comprobó que para los datos con los cuales no se entrenó la red (por ejemplo para un FP dado) correspondieron los mayores errores como es de esperar.

En general los resultados obtenidos permiten ser optimistas en cuanto a la utilización de esta herramienta de manera alternativa a la clásica.

Los resultados obtenidos con cada red se compararon con los datos que se obtienen del cálculo según el manual. Si se entrena con factores de progresión menores los errores de propagar otros datos son menores que entrenando con factores de progresión mayores (el máximo error es de 46% a 155% respectivamente).

A los fines de poder realizar una comparación con la metodología clásica se estimó el error total para cada una de las predicciones como:

$$\text{Error} = \text{Sum} [(\text{medido}(j) - \text{Simulado}(j))^2 \quad (5)$$

Los valores observados permiten mostrar que para factores de progresión pequeños las redes predicen la realidad de una manera adecuada, mientras que los errores totales obtenidos mediante la estimación por el método del Manual de Capacidad son elevados (70 veces mayor). No ocurre lo mismo para los casos de factores de progresión mayores en donde la metodología del Manual es más acertada.

Ante los resultados obtenidos se consideró como entrada a la red el valor del factor de progresión y se modificó la forma en que los datos eran presentados a la misma (el conjunto de datos de entrada quedó conformado como: FP, X, g/C, S y d). Se consideró óptima la arquitectura de la red anteriormente presentada y se obtuvieron los resultados comparativos con las demoras efectivamente medidas.

Puede observarse una mejora en los pronósticos por redes del orden del 10%. Cabe aclarar que no se hizo un estudio de la elección de la red óptima por lo que quizás los resultados sean aún mejores.

De lo expuesto surge que para flujos coordinados el factor de progresión resulta de capital importancia para el cálculo de la demora y que, en consecuencia, debe ser uno de los parámetros de entrada a la red o bien entrenarla y emplearla para casos que correspondan al mismo factor de progresión.

A fin de poder independizarse de la influencia de un factor tan predominante en el cálculo de la demora promedio, se realizaron relevamientos manuales de ciclo, verde efectivo, flujos de saturación, volúmenes circulantes y demoras totales en diferentes intersecciones aisladas (en donde la llegada del flujo era aleatoria) de la ciudad de Córdoba, para evaluar la eficiencia de los modelos de redes neuronales en estos casos y poder compararlas con los resultados obtenidos mediante la aplicación de la metodología del Manual.

Se realizaron mediciones de demoras, intensidades circulantes, flujos de saturación, ciclos y verdes efectivos en diez intersecciones totalizando quince accesos (referencia bibliográfica N° 10). Se consideraron los datos recogidos en una hora obteniéndose un total de diecisiete conjuntos de datos para entrenamiento y verificación. Se realizaron las mediciones sobre la Avda. Velez Sarsfield al 1800, 3200 y 3300; sobre Avda. Valparaiso y J.J.Diaz; sobre calle Friuli y Naciones Unidas y sobre las intersecciones de Estrada con Obispo Trejo, Buenos Aires, Independencia e Ituzaingo. El Cuadro 5 resume los datos recolectados de intensidad (I), flujo de saturación (S), longitud de ciclo (C), verde efectivo (g), demora real medida (dreal) y también presenta el resultado de calcular la demora mediante la fórmula provista por el Manual de capacidad (dmanu).

Las longitudes de ciclo medidas estuvieron comprendidas entre 40 a 100 segundos y el grado de saturación de los accesos entre 0.21 y 0.95.

Los datos fueron subdivididos en dos grupos aleatoriamente para entrenar y verificar posteriormente la red. Se utilizaron trece conjuntos para entrenarla y cuatro para verificarla. Se estudiaron redes de una y

dos capas. Se consideró en cada capa de uno a seis nodos intermedios y la red que resultó más eficiente fue la de una capa intermedia con un sólo nodo oculto.

Intensidad I	Flujo Sat. S	Ciclo C	Verde Ef. g	D. Medida d_{real}	D.s/Manual d_{manu}
1811	3400	70	48	3.70	6.84
149	1665	70	15	18.27	18.51
805	3400	70	48	4.01	3.48
942	3400	70	48	3.61	3.70
247	1779	70	38	9.55	6.49
172	1712	70	26	16.21	11.74
87	1665	70	15	19.53	17.39
479	1779	70	38	8.37	7.95
504	1520	40	23	8.10	4.81
538	1585	65	23	22.00	36.25
531	1779	65	22	21.42	25.53
658	1784	100	39	19.24	38.32
1020	3380	65	42	4.82	4.55
134	1712	70	26	13.66	11.43
350	1742	85	29	25.37	18.68
1082	3380	65	42	4.37	4.70
450	1370	40	19	11.60	8.42

Cuadro 5. Datos relevados en intersecciones aisladas.

Los resultados obtenidos de propagar los datos de entrenamiento a través de la red se presentan en el Cuadro 6.

Demora Medida d_{real}	Demora s/Red d_{red}
3.7	5.30
18.3	21.41
4.0	2.95
3.6	3.34
9.6	8.30
16.2	14.99
19.5	20.61
8.4	11.20
8.1	8.68
22.0	19.53
21.4	19.31
19.2	19.54
4.8	4.12

Cuadro 6. Resultados de entrenamiento en intersecciones aisladas.

El Cuadro 7 muestra las estimaciones realizadas con los datos de verificación, los resultados obtenidos mediante la utilización de la fórmula del Manual de capacidad y los errores porcentuales respecto de la demora realmente medida en campaña.

D. Medida D_{real}	D. s/ Red d_{red}	D. s/ Manual d_{manu}	Error Red $error_{red}$	Error Manual $error_{manu}$
13.66	13.98	11.43	2%	-16%
25.37	19.21	18.68	-24%	-26%
4.37	4.29	4.70	-2%	8%
11.60	13.37	8.42	15%	-27%

Cuadro 7. Resultados y errores en la fase de verificación

Se aprecia claramente la eficiencia de las redes para predecir la demora promedio por vehículo. En todos los casos del pronóstico los resultados obtenidos mediante el uso de las redes superaron a los obtenidos mediante la fórmula con una diferencia mínima del 8%.

Se dispone por lo tanto de una herramienta alternativa eficiente en la estimación de demoras medias en intersecciones aisladas al contar con la red ya entrenada.

6. CONCLUSIONES

Se presentó una alternativa de trabajo mostrando distintos aspectos en la obtención de viajes interzonas y demoras medias en intersecciones semaforizadas. Se demostró la capacidad que poseen las redes para modelar dichos fenómenos y la importancia de contar con datos reales para entrenar la red como así también para verificarla.

Se estudiaron diferentes arquitecturas de redes, variando la cantidad de capas intermedias y nodos incluidas en los mismos.

Uno de los aspectos importantes a tener muy en cuenta cuando se trabaja con redes neuronales es el análisis o procesamiento de datos. De una buena manipulación de los mismos resulta un beneficioso resultado al trabajar difundiendo estos a través de la red. Tal el caso de la importancia del factor de progresión en el cálculo de las demoras medias en intersecciones semaforizadas.

Otro de los aspectos a tener en cuenta es la correcta capacidad de funcionamiento de la red, la cual debe verificarse sobre la base de un conjunto de patrones distintos de los utilizados para su calibración. Una red sobreentrenada puede ajustar perfectamente los datos de entrenamiento, sin embargo es posible que pierda capacidad de predicción frente a otra, con una arquitectura diferente, que permita reconocer mejor los patrones claves del comportamiento del fenómeno que se pretende representar. De aquí la importancia de medir la bondad de predicción a través de los datos de verificación, como se ha efectuado en este trabajo.

Queda demostrada la eficiencia de las redes en la estimación de demoras como opción frente a la metodología actualmente en uso y la presencia de otra alternativa de trabajo en el caso de la estimación de los viajes interzonales.

BIBLIOGRAFIA

1. Caudill M. and Butler C. (1991): Naturally Intelligent Systems MIT press. Cambridge, Massachusetts.
2. Faghri, A. and Hua, J., (1992): Evaluation of Artificial Neural Network Applications in Transportation Engineering. Transportation Research Record, National Research Council.
3. Stephen T. Welstead, (1994): Neural Network and Fuzzy Logic Applications in C/C++, Wiley.
4. Mohamed H. et al, (1995): Utilization of Neural Networks in Bridge Management Systems.
5. McCord, Marilyn and Illingworth, W. T., (1991): A Practical Guide to Neural Nets. Adison Wesley.
6. Instituto Superior de Ingeniería del Transporte (1995): Tránsito Potencial de la Futura Infraestructura (Conexión Vial sobre el río Paraná entre las ciudades de Rosario (Santa Fe) y Victoria (Entre Ríos).
7. Depiante, Violeta (1994 - 1995): Informe de avance y final sobre Metodologías no convencionales en la solución de problemas de ingeniería del transporte. Modelos de redes neuronales. Presentado al Consejo de Investigaciones Científicas y Tecnológicas de la Provincia de Córdoba, Argentina.
8. Transportation Research Board (1994): Highway Capacity Manual. Special Report 209. U.S.A.
9. Brocanelli, Diego (1996): Trabajo final: Modelo difuso de estimación de demoras en intersecciones semaforizadas. Para el título de grado de Ingeniero Civil. Universidad Nacional de Córdoba.
10. Depiante, Violeta y Galarraga, Jorge (1997): Estimación de la demora promedio en intersecciones semaforizadas mediante modelos de redes neuronales. Publicado en el XII Congreso argentino de Vialidad y Tránsito en Buenos Aires, Argentina.