

MODELO PREDICTIVO DE TRÁFICO DE VOZ PARA UNA RADIO BASE DE TELEFONÍA MÓVIL 3G MEDIANTE REDES NEURONALES

PREDICTIVE MODEL FOR VOICE TRAFFIC IN A 3G MOBILE BASE STATION USING NEURAL NETWORKS

Washington Giovanny Amancha Punina ^{1*}

¹ Ingeniero en Electrónica y Comunicaciones. Máster Universitario en Inteligencia Artificial. Instituto Superior Tecnológico Tungurahua, Ecuador. ORCID: <https://orcid.org/0009-0005-6511-5970>. Correo: wamancha@institutos.gob.ec

Sara Isabel Loza Morán ²

² Doctora en Gerencia Educativa. Mg. en Gerencia y Liderazgo Educacional. Unidad Educativa Nuevo Mundo. Ecuador. ORCID: <https://orcid.org/0000-0003-1413-431X>. Correo: isa3174@hotmail.com

Gabriel Alejandro Vaca Ortega ³

³ Ingeniero en Electrónica y Comunicaciones, Máster en Gerencia de Sistemas. Instituto Superior Tecnológico Tungurahua. Ecuador. ORCID: <https://orcid.org/0000-0002-6192-7868>. Correo: gvaca@institutos.gob.ec

Andrea Libertad Alarcón Ortiz ⁴

⁴ Ingeniera en Electrónica y Comunicaciones. Máster en Telecomunicaciones. Instituto Superior Tecnológico Tungurahua. Ecuador. ORCID: <https://orcid.org/0000-0003-1392-0343>. Correo: alalarcon@institutos.gob.ec

* Autor para correspondencia: wamancha@institutos.gob.ec

Resumen

El objetivo de la presente investigación es diseñar un modelo predictivo basado en Redes Neuronales para el pronóstico del tráfico de voz y horas de congestión de una Radio Base de telefonía móvil 3G. Para esto se desarrollaron dos modelos de tipo RNA y RRN, aplicando la siguiente metodología para cada caso: análisis inicial de datos de la Radio base, normalización y regresión aplicadas a redes neuronales para la estimación de la variable a predecir. Como resultado final de la evaluación de los modelos se seleccionó como el mejor modelo a una Red Neuronal de tipo “*Feed Forward fully conected*” de arquitectura perceptrón

multicapa entrenada mediante aprendizaje *backpropagation*. De acuerdo a los excelentes resultados obtenidos con el modelo seleccionado para la predicción del tráfico de voz en cada prueba y experimento realizado se puede manifestar que las Redes Neuronales si son factibles aplicarlas en el campo de las telecomunicaciones.

Palabras clave: Tráfico de voz; congestionamiento; perceptrón; backpropagation

Abstract

The objective of this research is to design a predictive model based on Neural Networks for forecasting voice traffic and congestion hours of a 3G mobile telephony Base Station. For this purpose, two models of RNA and RRN types were developed, applying the following methodology for each case: initial analysis of Base Station data, normalization, and regression applied to neural networks for the estimation of the variable to be predicted. As a final result of the model evaluation, a Feed Forward fully connected Neural Network of multilayer perceptron architecture trained through backpropagation learning was selected as the best model. According to the excellent results obtained with the selected model for voice traffic prediction in each test and experiment conducted, it can be stated that Neural Networks are feasible to be applied in the field of telecommunications.

Keywords: Voice traffic; congestion; perceptron; backpropagation

Fecha de recibido: 02/03/2023

Fecha de aceptado: 25/05/2023

Fecha de publicado: 05/06/2023

Introducción

En los últimos años los grandes avances y descubrimientos sobre Inteligencia Artificial (IA) ha generado un alto interés en las personas por investigar sobre este tipo de tecnología y su aplicación en diferentes campos para la solución de problemas cotidianos. Si bien es cierto es una de las áreas de estudio que permite imaginar hechos que probablemente solo se encuentren en películas de ciencia ficción, el estudio a fondo de esta área del conocimiento puede causar que muchos se desmotiven con el fundamento teórico de la IA.

Aunque la IA es un campo amplio, su crecimiento reciente se debe en gran medida a los nuevos avances y mejoras en el aprendizaje automático. La inteligencia artificial, específicamente el aprendizaje automático, ha encontrado numerosas aplicaciones en la actualidad. El aprendizaje automático representa un subconjunto de la IA, e incluye potentes algoritmos que brindan a los sistemas la capacidad de explorar y encontrar patrones dentro de los datos, clasificar y predecir resultados mediante el aprendizaje a través de la experiencia. Diferentes algoritmos de aprendizaje automático se muestran prometedores para resolver problemas cotidianos.

El presente trabajo tiene como propósito hacer uso de esta tecnología, para la generación de un modelo de predicción de tráfico de voz y las horas de congestión de llamadas de una Radio base de telefonía móvil 3G, esto con el objetivo de optimizar y asignarle recursos para elevar su rendimiento y de esa manera garantizar un excelente servicio de calidad a los usuarios. Para realizar esto se utilizó una de las técnicas de IA conocida como Red Neuronal la cual consiste en un modelo computacional que está compuesto por un conjunto de unidades, llamadas neuronas artificiales, conectadas entre sí para la transmisión de señales de entrada y en base a ello producir una salida deseada.

Trabajos relacionados

En la investigación realizada por Belandria, Paredes & Vilorio (2006) con el tema “Localización de móviles en telefonía celular usando redes neuronales” evidencia otra aplicación de las redes neuronales como propuesta a variados trayectos y canales de recorrido en las comunicaciones de telefonía móvil, mediante el manejo de una metodología tradicional que determine la localización y el desempeño de una llamada a través de dispositivos móviles, que refleja ciertos procesos que orientan al desarrollo del tema de estudio.

Otro aporte a la presente investigación es el realizado por Salgado, Márquez & Gómez (2016) con el tema “Técnicas inteligentes en la asignación de espectro dinámica para redes inalámbricas cognitivas” cuyo manejo de las técnicas inteligentes depende exclusivamente de las necesidades de cada usuario acorde a la señal, disponibilidad, capacidad de almacenamiento, capacidad de aprendizaje entre otros. La aplicación de una o varias técnicas de IA a las comunicaciones inalámbricas dependen específicamente de los requerimientos específicos del objetivo y de los resultados deseados, así como de las ventajas y las desventajas que provean cada una de ellas.

El aporte emitido por Urdaneta en su artículo “Análisis de tráfico en una red LAN aplicando la tecnología de redes neuronales” en Telematique. (2005) se asocia que las Redes Neuronales son utilizadas para caracterizar y pronosticar el comportamiento de variables que dependen de otras variables tales como aplicación y funcionamiento, que visualiza la importancia de obtener modelos de predicción efectivos empleados por el hombre en su constante intento de reproducción de su propia imagen, estipulando un contingente a la presente investigación.

Según García y Rojas en su artículo “Evaluación de tráfico de voz y datos en las redes celulares” (2006) hace énfasis en la importancia de la aplicación de evaluaciones estadísticas sobre el índice de tráfico en las operadoras de telefonía móvil, ya que este procedimiento permitirá conocer y observar el desempeño de ciertos componentes, los cuales deben estar enmarcados dentro de ciertos niveles y estándares de operacionalización óptima, que parten de ciertos símiles que involucra el nivel de exigencia y el nivel de operacionalización de manera acertada.

La teoría de tráfico está basada en el estudio de la congestión, las llamadas perdidas y el grado de servicio. El Erlang es la unidad utilizada para medir la intensidad de tráfico, esto en honor al matemático A. K. Erlang quien estableció la teoría del tráfico en telefonía, 1 Erlang es equivalente a un circuito en uso por 3600 segundos, es decir una hora. La intensidad de tráfico se puede medir también en CCS (“Circuit Centum Seconds”), 1 CSS es equivalente a un circuito en uso por 100 segundos. La relación que existe entre Erlangs y CCS’s es: 1 Erlang = 3600 Segundos = 36 CCS.

En el artículo de la Revista CSIC que presenta Manuel Díaz (2001), “Los impactos de las estaciones de telefonía móvil”, aquí se detalla sobre una estación de base de telefonía móvil, la cual ocupa un espacio de dimensiones pequeñas, entre 80 y 120 m², y consta de una caseta con equipos de radio frecuencia y equipos auxiliares, una torre de 30 a 40 m de altura aproximadamente en cuya parte superior se encuentra ubicada una estructura sobre la que se instalan las antenas. El área de construcción para la caseta oscila entre 6 y 10 m² y una altura de 3m aproximadamente, y se la fábrica comúnmente de estructura metálica o de hormigón con vías de acceso desde el exterior.

Materiales y métodos

Se propuso como objetivo de la investigación desarrollar un modelo de predicción de tráfico de voz para una Radio base de telefonía móvil 3G fundamentado en un algoritmo de aprendizaje automático, la opción más viable fue la aplicación de regresión de Redes Neuronales debido a que esta técnica es un modelo matemático usado para aproximar la relación de dependencia entre una variable dependiente Y , con las variables independientes X_i y un término aleatorio ε , siendo el que mejor se ajustaba para la predicción del tráfico de voz, aplicando para ello el siguiente procedimiento:

1. El desarrollo del modelo se lo realizó en el Lenguaje de Programación Python con el toolbox Scikit-Learn, debido a su versatilidad y a la gran cantidad de herramientas y librerías de machine learning que ofrece para el desarrollo de algoritmos de Inteligencia Artificial.
2. Uso de la plataforma libre Google Colaboratory para el desarrollo del algoritmo, porque al ser una herramienta online adecuada para este tipo de trabajos, ofrece características técnicas de funcionamiento de alto rendimiento para la simulación.
3. Análisis inicial de los datos que se utilizaron en el desarrollo del modelo en el cual se obtuvieron las características generales como: valores máximos y mínimos, desviación estándar media, percentiles.
4. Aplicación de gráficos estadísticos como histogramas y densidad de probabilidad para la identificación del intervalo de tiempo en horas de mayor congestionamiento de llamadas.
5. Uso de la técnica de correlación para determinar la relación existente entre columnas (variables), esto con el objetivo de seleccionar las variables de entrada que estaban relacionadas directamente con el tráfico de voz.
6. Se realizaron pruebas con 3 tipos de herramientas de normalización de datos considerando para ello las siguientes: respecto al máximo, minmax. y standar scaler. De ellas se utilizaron solo las dos primeras debido a que la última generó un offset en los datos.
7. Se desarrollaron dos tipos de Redes Neuronales RNA y RNN aplicando la técnica de regresión en los cuales se utilizaron diferentes tipos de optimizadores como: Adam, sgd, lbfgs, entre otros. Para los dos casos se realizaron los entrenamientos con cuatro diferentes sets de datos: usando las variables con correlación mayor a 0.7 y correlación mayor a 0.8. Además de todos los datos se utilizó el 80% para entrenamiento y el 20% para test.
8. Como parte final del procedimiento se realizó el análisis de los resultados de los modelos desarrollados, los cuales se fundamentaron en la precisión y efectividad determinada por el mejor valor de r^2_score que fue la métrica utilizada para su evaluación.

Resultados y discusión

Análisis de datos

Previo al desarrollo del modelo se inició con el cargado de la base de datos con la cual se trabajó en el proyecto.

Características generales

Primer acercamiento con los datos y su análisis respectivo, esto con el fin de dejarlos en óptimas condiciones para su uso en el desarrollo del modelo. La Figura 1 muestra el análisis estadístico de los datos permitió observar que existía un margen muy amplio de valores entre los diferentes parámetros en la variable a predecir, como la media, el máximo y el mínimo, además según el valor máximo y los percentiles se evidenció que era necesario realizar una normalización de los datos.

	Cell ID	CS_TRAFFIC_Volume_GUL_NEW2	PS Traffic Volume_GUL (MB)	PS Drop Call_GUL	HSDPA User Throughput_GUL	HSPA User Throughput_GUL	VS.RAC.DLEqUserNum	VS.RAC.DLEq
count	7773.000000	7773.000000	7.773000e+03	7773.000000	7.773000e+03	7.773000e+03	7773.000000	7.773000e+03
mean	45297.206670	128163.594622	3.726629e+06	25.217478	1.290518e+07	5.894709e+05	181223.190238	4.461111e+05
std	13910.128653	100723.830133	2.540067e+06	556.823476	7.168703e+06	4.325580e+05	152404.959805	2.891111e+05
min	26007.000000	6025.000000	8.967000e+01	0.000000	4.855600e+02	4.046000e+01	0.468400	3.491111e+01
25%	39132.000000	47667.000000	1.572688e+06	0.098900	8.769848e+06	4.551490e+05	60268.000000	2.031111e+05
50%	39137.000000	104278.000000	3.613525e+06	0.180000	1.232881e+07	5.327640e+05	142717.000000	4.201111e+05
75%	63212.000000	183167.000000	5.427667e+06	0.276800	1.856577e+07	6.552240e+05	257621.000000	6.531111e+05
max	63216.000000	575945.000000	2.926384e+07	17021.000000	8.724355e+07	9.562158e+06	940998.000000	1.481111e+06

Figura 1. Parámetros estadísticos generales de la base de datos.

Se utilizaron dos tipos de gráficas: histogramas y de densidad de probabilidad para observar cómo se encontraba la distribución de los datos en la variable a predecir, en los cuales se identificó la existencia de un gran conjunto de datos que se encontraban dentro de un rango de valores establecidos entre 0 y 2000000 como se observa en la Figura 2.




Figura 2. Histograma de datos.

Congestionamiento de llamadas

De la base de datos se utilizó una columna con información sobre las horas en las que se realizó el monitoreo de la Radio base para la obtención de las muestras, con esto se realizó un análisis estadístico para determinar en qué periodo de tiempo existía un congestionamiento de llamadas producto del tráfico de voz, por ello partiendo de la columna con esta información, se desarrolló un gráfico (Figura 3) en el que se proyecta el tráfico de voz con respecto a las horas del día, así como también el tráfico de datos (Figura 4).




Figura 3. Tráfico de voz.




Figura 4. Tráfico de descarga de datos.

Relación entre columnas y variables

Del total de variables de la base de datos se identificó dos grupos con índice de correlación mayor a 0,7 y a 0,8 (Figura 5 y 6) descartando así al resto de variables que tenían valores inferiores, esto para que el modelo sea lo más exacto posible.

```
Index(['VS.RAC.DL.EqvUserNum', 'VS.RAC.UL.EqvUserNum',
      'VS.RAB.SuccEstabCS.AMR', 'VS.RAB.AttEstab.AMR',
      'RRC.SuccConnEstab.OrgConvCall', 'RRC.SuccConnEstab.TmConvCall',
      'RRC.AttConnEstab.OrgConvCall', 'RRC.AttConnEstab.TmConvCall',
      'RRC.SuccConnEstab.OrgBkgCall', 'RRC.SuccConnEstab.TmBkgCall',
      'RRC.AttConnEstab.OrgBkgCall', 'VS.RAB.SuccEstabPS.Bkg',
      'VS.RAB.AttEstabPS.Bkg', 'VS.RAB.NormRel.AMR', 'VS.RAB.NormRel.PS',
      'VS.RAB.NormRel.PS.PCH', 'VS.DCCC.Succ.D2U',
      'VS.HSDPA.64QAM.UE.Mean.Cell', 'CNBAP', 'VS.TP.UE.0', 'VS.TP.UE.1',
      'RRC.AttConnEstab.TmBkgCall', 'VS.HSDPA.RAB.64QAM.AttEstab',
      'VS.HSDPA.RAB.64QAM.SuccEstab', 'HSDPA Users',
      'VS.LC.DLCreditUsed.Mean', 'VS.LC.ULCreditUsed.Mean', 'VS.CellDCHUES',
      'VS.HSUPA.UE.Mean.Cell', 'DCH User Num', 'MultiRAB Setup SuccRate_DEN',
      'MultiRAB Setup SuccRate_NUM', 'VS.U2L.FastReturn.Redirect.CSFBUE',
      'VS.HSUPA.UE.Mean.TTI10ms'],
      dtype='object')
```

Figura 5. Conjunto de variables con correlación mayor a 0.7.


```
Index(['VS.RAB.SuccEstabCS.AMR', 'VS.RAB.AttEstab.AMR',
      'RRC.SuccConnEstab.OrgConvCall', 'RRC.SuccConnEstab.TmConvCall',
      'RRC.AttConnEstab.OrgConvCall', 'RRC.AttConnEstab.TmConvCall',
      'VS.RAB.SuccEstabPS.Bkg', 'VS.RAB.AttEstabPS.Bkg', 'VS.RAB.NormRel.AMR',
      'VS.RAB.NormRel.PS', 'CNBAP', 'VS.LC.DLCreditUsed.Mean',
      'VS.CellDCHUES', 'DCH User Num', 'MultiRAB Setup SuccRate_DEN',
      'MultiRAB Setup SuccRate_NUM', 'VS.U2L.FastReturn.Redirect.CSFBUE'],
      dtype='object')
```

Figura 6. Conjunto de variables con correlación mayor a 0.8.

Normalización de los Datos

Se realizaron diferentes pruebas aplicando varios tipos de normalización de las cuales por sus excelentes resultados se seleccionaron los siguientes: respecto al máximo (máx), respecto al mínimo – máximo (minmax) y al standar scaler, de la cual se descartó la normalización estándar scaler porque generó un offset (desplazamiento) en los datos.

Red Neuronal Artificial

Se desarrollaron dos tipos de modelos de Redes Neuronales Artificiales:

- Red Neuronal Feed Forward (RNA)
- Red Neuronal Recurrente (RNN)

Definición de variables

Los entrenamientos de las redes se las realizaron utilizando cuatro diferentes conjuntos de datos: el primero caso usando las variables con correlación mayor a 0.7 y normalización al máximo, el segundo caso usando las variables con correlación mayor a 0.7 y normalización minmax, el tercer caso usando las variables con correlación mayor a 0.8 y normalización al máx. y el cuarto caso en el que se utilizaron las variables con correlación mayor a 0.8 y normalización minmax. Además, es importante señalar que la base de datos utilizada para el modelo se la dividió de la siguiente manera: 80% para train (entrenamiento) y 20% para test (prueba).

Red Neuronal Artificial Feed Forward

En el entrenamiento del modelo de regresión basado en una red neuronal feed forward se realizaron varias pruebas para obtener los valores más óptimos respecto a los parámetros de medición, además para asegurar que se obtuvo la mejor optimización en el entrenamiento, el parámetro de parada de la red fue definido mediante un número máximo de iteraciones, para ello se configuró el error deseado como 0, de esta manera se garantizó que el modelo no se detenga en un valor mínimo local, y con esto se controló el desarrollo correcto del entrenamiento garantizando así que no se produzca un overfitting (memorización o sobre entrenamiento) por la condición de error 0.

Red Neuronal Recurrente

En este modelo de igual forma se realizaron varias pruebas con el fin de optimizar sus hiper parámetros, razón por la cual se realizó un cambio en el tamaño de la variable debido al tipo de configuración que requiere el modelo, pero esto no influyó en los datos con los que se entrena, además se utilizaron dos o más capas lstm y una capa final densa con una neurona para la obtención de la predicción del tráfico de voz usando las variables que tienen mayor correlación con la salida del modelo.

Para el entrenamiento de los modelos de redes recurrentes se utilizaron los dos tipos de normalización seleccionados y además las variables con mayor correlación con respecto a la variable a predecir. Durante el entrenamiento se modificó la arquitectura del modelo cambiando el número de capas lstm así como los valores de drop out. Con respecto a la cantidad de épocas utilizadas, se utilizaron 30 porque después de varias pruebas realizadas, la tasa de error no tuvo ninguna variación considerable por lo cual era innecesario incrementarlas. Para establecer esto, se realizaron varios experimentos utilizando un número mayor de épocas y en función de ello identificar cuando no existía un cambio.

Desarrollo de software

Como parte final del proyecto se realizó el análisis de los resultados obtenidos en cada una de las pruebas realizadas en los dos modelos, el cual consistió en la comparación del valor obtenido en el $r2_score$ para RNA y RNN que fue la métrica que se utilizó para la evaluación, además de otros factores importantes como la arquitectura de la Red, el tiempo de predicción de datos entre otros, los cuales permitieron seleccionar la solución más óptima para el trabajo propuesto.

El procedimiento que se aplicó para el entrenamiento del modelo fue el de ajustar automáticamente las respuestas de las neuronas cambiando sus pesos de tal manera que los resultados de la RNA se ajusten a los esperados, a continuación, se muestra en la TABLA I un resumen de los resultados obtenidos durante ese proceso.

Tabla 1. Resumen de datos para el entrenamiento del modelo.

Detalle	Tráfico de Voz
Datos históricos (variables)	7331
Conjunto de Entrenamiento	6218
Conjunto de Evaluación	1555
Tasa de Entrenamiento	0.001
Momento	0.9
Iteraciones	1000
$r2_score$	0.9153836005727175

Evaluación Modelo RNA

Después de haber realizado este análisis en cada una de las pruebas realizadas se procedió a elaborar la TABLA II la cual contiene los mejores resultados de $r2_score$ para cada uno de los casos antes mencionados de RNA.

Tabla 2. Resumen de estadísticas de r2_score para RNA.

Normalización	Correlación	Número de Capas	Número de Neuronas	Train r2_score	Test r2_score
Minmáx	0.8	2	200,150	0.9216187708036223	0.904511687117281
Minmáx	0.7	3	600,350,150	0.9321607963012705	0.9153836005727175
Minmáx	0.7	4	700,555,350,200	0.9264987401794356	0.908868565799196
Minmáx	0.8	5	500,400,300,200,100	0.9240169689196283	0.9079482977564823
Máx	0.7	6	1200,1000,800,600,400,200	0.9277236526017512	0.9108865154031903

Evaluación Modelo RNN

Al igual que en el modelo de RNA, aquí se aplicó el mismo procedimiento, como se puede evidenciar en la TABLA III los valores obtenidos en la métrica r2_score utilizada para la evaluación del modelo son muy similares y varían de uno a otro solo por un mínimo valor numérico entre una cantidad y otra.

Tabla 3. Resumen de estadísticas de r2_score para RNN.

Normalización	Correlación	Capas	Neuronas	Train r2_score	Test r2_score
Máx	0.7	2	100,200	0.9058156819307738	0.8932096399491554
Minmáx	0.8	3	100,150,75	0.9064290352357952	0.8938273968180487
Máx	0.8	4	200,150,100,50	0.9057341094802435	0.8935426695174359

Comparación de r2_score

Como procedimiento final lo que se realizó fue la comparación de los resultados obtenidos entre los dos mejores modelos de Redes Neuronales RNA y RNN considerando para ello los parámetros establecidos anteriormente, los cuales permitieron seleccionar al mejor modelo.

Tabla 4. Mejores modelos de redes. (RNA Y RNN).

Tipo de Red	Normalización	Correlación	Capas	Neuronas	Train r2_score	Test r2_score
Feed Forward	Minmáx	0.7	3	600,350,150	0.9321607963012705	0.9153836005727175
Recurrente	Minmáx	0.8	3	100,150,75	0.9064290352357952	0.8938273968180487

Modelo seleccionado

Como se puede observar en la TABLA IV el mejor valor de $r2_score$ que fue la métrica utilizada para la evaluación del modelo es: 0.9153836005727175 que corresponde a una Red Neuronal feed forward fully conected (RNA) con normalización de datos tipo máx., índice de correlación de las variables de entrada de 0,7 entre las variables seleccionadas para la predicción de la variable de tráfico de voz, lo cual muestra que sería el mejor modelo para el proyecto planteado. Los datos finales de la arquitectura del modelo se muestran en la Tabla 5 así como las Figuras 7,8,9 y 10 muestran las gráficas de predicción de datos y las del $r2_score$ para train y test respectivamente.

Tabla 5. Mejor modelo de red para el proyecto.

Tipo de Red	Normalización	Correlación	Capas	Neuronas	Train $r2_score$	Test $r2_score$
Feed Forward	Minmáx	0.7	3	600,350,150	0.9321607963012705	0.9153836005727175




Figura 7. Predicción del mejor modelo seleccionado con datos de train.




Figura 8. Predicción del mejor modelo seleccionado con datos de test.




Figura 9. r_2_score del modelo seleccionado con datos de train.




Figura 10. r_2_score del modelo seleccionado con datos de test.

Discusión

El mejor valor de $r2_score$ para la selección del mejor modelo lo obtuvo una RNA de 3 fully connected de 3 capas con índice de correlación de 0.7 de las variables que se utilizaron como datos de entrada para el entrenamiento del modelo para la predicción de la variable de salida (Tráfico de voz), a pesar de haberse realizado diferentes pruebas un poco más restrictivas utilizando otro conjunto de datos de entrada con correlación de 0,8 en el que por obvias razones disminuyeron la cantidad de ellas.

Hay que resaltar que los valores de $r2_score$ obtenidos para los dos modelos en las diferentes pruebas realizadas no variaban mucho entre uno y otro, lo cual obligó a efectuar varios experimentos modificando fundamentalmente la arquitectura de los modelos, así como el número de capas y neuronas. Se podría mejorar la exactitud del modelo seleccionado incrementando el número de observaciones, así como el conjunto de datos utilizados para el entrenamiento.

Conclusiones

De los dos tipos de modelos de Redes Neuronales desarrollados en este trabajo a los que se aplicaron la técnica de regresión para la predicción del tráfico de voz de una Radio base de telefonía móvil 3G, la Red Neuronal Artificial (RNA) Feed Forward de 3 capas fue la que obtuvo un mejor valor de $r2_score$ al momento de la evaluación.

El óptimo rendimiento alcanzado por el modelo seleccionado permitió comprobar el potencial uso de las Redes Neuronales para su aplicación en casos reales como la predicción de datos para parámetros importantes que son fundamentales en el funcionamiento correcto de una Radio Base de telefonía celular, los cuales facilitarían la optimización y la asignación de recursos de forma inmediata evitando así posibles congestionamientos en una red de telefonía móvil.

Si bien es cierto que como antecedentes en este trabajo se incluyen algunas investigaciones que se han desarrollado similares al tema propuesto aplicando Redes Neuronales como por ejemplo la predicción del tráfico en redes de datos de computadoras, este proyecto sería el primero al cual se aplica este tipo de técnica de IA para la predicción del tráfico de voz en Redes de telefonía móvil.

El trabajo realizado permite ser fuente de posibles líneas de trabajo en el futuro, al ser analizado el modelo predictivo se intenta generar una mejora en el tráfico de voz de la radio base de la telefonía móvil, que traslade la información estadística al desarrollo de un sistema más operativo con la asignación de recursos y parámetros, que brinde soporte a la gran problemática del congestionamiento de las llamadas en horarios determinados, mermando la inconformidad de los clientes.

Referencias

Álvarez, N. S., Hernández, C., & Pedraza, L. F. (2011, julio). Redes neuronales y predicción de tráfico. T Tecnura, 15(29), 90-97. Obtenido de <http://www.espaciotv.es:2048/referer/secretcode/docview/1868345329?accountid=142712>

- Araya, R. A. (2013). Tecnología móvil: desarrollo de sistemas y aplicaciones para las unidades de información. Revista e Ciencia de la Información. Obtenido de <https://www.redalyc.org/articulo.oa?id=476848738003>
- Arcas, M. (2018, octubre). Inteligencia artificial: desde detectar cáncer hasta prevenir deforestación: INTELIGENCIA ARTIFICIAL (Previsión). EFE News Service.
- Belandria, E., Paredes, J. L., & Vilorio, F. (2006, abril). Localización de móviles en telefonía celular usando Redes Neuronales. Interciencias, 31(4), 300-304. Obtenido de <http://www.espaciotv.es:2048/referer/secretcode/docview/210141726?accountid=142712>
- Bonet Cruz, I., Salazar Martínez, S., Rodríguez Abed, A., & Grau Ábalo, R. (2007). Redes neuronales recurrentes para el análisis de secuencias. Revista Cubana de Ciencias Informáticas, 1(4), 48-57. Obtenido de <http://www.redalyc.org/articulo.oa?id=378343634004>
- Carasila, A. M. (2009). La demanda de telefonía fija y móvil. Dialnet, 9(2), 55-72. Obtenido de https://dialnet.unirioja.es/buscar/documentos?querry=Dismax.DOCUMENTAL_TODO=redes+neuronales+y++telefon%C3%ADa+m%C3%B3vil
- Castro, M. d. (2012, septiembre). Recuperado de <https://e-archivo.uc3m.es/handle/10016/17138#preview>
- Cruz, M. F. (2012). Recuperado de <https://pdfs.semanticscholar.org/85b0/6da80a72432aa87a20159fc4c64d44c76542.pdf>
- Empresario. (2017, noviembre 17). Crear inteligencia artificial que crea inteligencia artificial. THE NEW YORK TIMES. Obtenido de <https://www.elpais.com.uy/el-empresario/crear-inteligencia-artificial-crea-inteligencia-artificial.html>
- Gámez, O. R. (2005, enero). Telefonía móvil celular: origen, evolución, perspectivas. Ciencias Holguín, XI(1), 1-8. Obtenido de <http://www.redalyc.org/articulo.oa?id=181517913002>
- García, R. C., & Rojas, L. (2006). Evaluación de tráfico de voz y datos en las redes celulares. Telematique, 5(2), 57-74. Obtenido de <https://dialnet.unirioja.es/servlet/articulo?codigo=2966855>
- Martín, M. D. (2001). Los impactos de las estaciones de telefonía móvil. Revista CSIC, 53(476), 47-52. Obtenido de <http://informesdelaconstruccion.revistas.csic.es/index.php/informesdelaconstruccion/article/view/649/732>
- Muñoz, R. F. (2009, septiembre). Aplicación de las redes neuronales al modelado de la propagación para la planificación de sistemas de telefonía móvil celular. Dialnet.
- Nelson Piedra, J. L. (2010, octubre). Recuperado el 01 de septiembre de 2019 de <https://nopiedra.files.wordpress.com/2007/10/aplicacion-de-redes-neuronales-artificiales-para-la-ingenieria-de-trafico-de-internet.pdf>
- Olabe, X. B. (1998). Redes Neuronales Artificiales y sus aplicaciones. Publicaciones de la Escuela de Ingenieros.

- Orange. (2016, 16 de agosto). Las Ondas. Obtenido de Las Ondas: <https://radio-waves.orange.com/es/como-funciona-una-red-movil/>
- Pástor, J. B. (1998). Tesis doctoral. España.
- Pons, E. G. (2010). Una sociedad en movilidad: nuevas fronteras. Telos. Obtenido de http://www.revistalatinacs.org/11SLCS/actas_2011_IICILCS/096_Gil.pdf
- Ramirez, R. (1997).
- Salas, R. (2004). Redes Neuronales Artificiales. Departamento de Computación.
- Salgado, C., Márquez, H., & Gómez, V. (2016, julio). Tecnicas inteligentes en la asignacion de espectro dinamica para redes inalambricas cognitivas. Tecnura, 20(49), 135-153. Obtenido de <http://revistas.udistrital.edu.co/ojs/index.php/Tecnura/issue/view/650>
- Sánchez, J. J. (2000). Telefonía móvil digital GSM. Anales de mecánica y electricidad, 77(1), 14-26. Obtenido de https://www.icaei.es/contenidos/publicaciones/anales_get.php?id=856
- Urdaneta Montiel, A. J. (2005). Análisis de tráfico en una red LAN aplicando la tecnología de redes neuronales. Telematique, 5(1). Obtenido de <https://www.redalyc.org/pdf/784/78450107.pdf>