



Certificación ISO 9001:2008 ‡

RED NEURONAL *FEEDFORWARD* COMO ESTIMADOR DE PATRONES DE CORRIENTES EN EL INTERIOR DEL PUERTO DE MANZANILLO SUJETO A LA ACCIÓN DE TSUNAMIS

Juan Pedro Vásquez López

**Publicación Técnica No. 406
Sanfandila, Qro, 2014**

SECRETARÍA DE COMUNICACIONES Y TRANSPORTES

INSTITUTO MEXICANO DEL TRANSPORTE

**RED NEURONAL *FEEDFORWARD*
COMO ESTIMADOR DE PATRONES
DE CORRIENTES EN EL INTERIOR
DEL PUERTO DE MANZANILLO
SUJETO A LA ACCIÓN DE
TSUNAMIS**

**Publicación Técnica No.406
Sanfandila, Qro, 2014**

Esta investigación fue realizada en la Coordinación de Ingeniería Portuaria Y Sistemas Geoespaciales del Instituto Mexicano del Transporte, por el M. en C. Juan Pedro Vásquez López.

Se agradece la colaboración del Ing. José Miguel Montoya, Jefe de la División de Ingeniería de Puertos y Costas del IMT, quien proporcionó los datos para este estudio.

Contenido

Resumen	iv
Abstract	vi
Resumen Ejecutivo	viii
Introducción.	1
Capítulo 1. Metodología	5
Capítulo 2. Datos	11
Capítulo 3. Estrategias de cómputo	15
Capítulo 4. Búsqueda de la RNAf óptima	25
Capítulo 5. Resultados	31
Capítulo 6. Conclusiones	39
Bibliografía	41
Anexo 1 Estado del arte	45
Anexo 2 Coordenadas UTM de los puntos de modelación	49

Resumen

En el presente estudio se elaboró un breve estado del arte que guardan las redes neuronales artificiales *feedforward* en el campo de la ingeniería portuaria e hidráulica marítima, en lo relativo a los Tsunamis y, específicamente, a los efectos que se originan en los puertos.

Se exploró la posibilidad de aplicar esta novedosa metodología para conseguir un estimador de patrones de corrientes litorales en el interior del Puerto de Manzanillo en Colima, sujeto a la acción de tsunamis.

Se logró el diseño, codificación y optimización de dos redes neuronales artificiales que aprendieron una el patrón de rapidez máxima y otra el patrón de rapidez media. Con un error porcentual absoluto medio menor al 19% en ambos casos.

Abstract

Present study begins with a brief state of the art kept by *feedforward* artificial neural networks in the field of maritime port and hydraulic engineering, with regard to Tsunamis and specifically to the effects that originate into ports.

Also we explored the possibility of applying this new methodology to get an estimate of patterns of coastlines currents in the interior of the port of Manzanillo in Colima, subject to the action of tsunamis.

Achieving the design, coding and optimization of two artificial neural networks, one learned the maximum speed pattern and another for the pattern of average speed. With one absolute percentage error means less than 19% in both cases.

Resumen ejecutivo

El presente trabajo comenzó por hacer una breve investigación bibliográfica en el campo de la ingeniería portuaria e hidráulica marítima en lo relativo a la aplicación de redes neuronales artificiales. Hallando que, si bien se reportan muy ilustrativas aplicaciones de esta novedosa metodología de la inteligencia artificial a diversos retos ingenieriles del ramo, nada se halló para tsunamis en cuanto sus efectos en el interior de los puertos. Este trabajo promete, entonces, ser de los pioneros en tan particular tema.

Las redes neuronales artificiales (RNA) son algoritmos computacionales que han ganado popularidad en la ciencia y tecnología, donde los métodos matemáticos y numéricos tradicionales hallaban serias dificultades en problemas que involucraban muchas variables y de naturaleza no lineal, en el más extremo de los casos, cuando no existía un modelo previo que describiera las relaciones funcionales entre dichas variables.

Estas RNA son sistemas de procesamiento cuyo funcionamiento simula el de un cerebro biológico real. Tienen la capacidad de procesar en paralelo grandes cantidades de información, aun cuando ésta sea parcial y difusa. Pueden aprender y memorizar información muy variada y formalizarla y, desde luego, hacer predicciones a partir de los datos con los que ha sido entrenada.

Así, proveen de una poderosa herramienta de interpolación no lineal y multidimensional. Por lo que se les ha empleado principalmente en identificación y predicción de patrones.

Las RNA de topología *feedforward* se caracterizan por ejecutar el procesamiento de datos en una sola dirección. Distinguiéndose tres capas principales de unidades independientes de cómputo llamadas neuronas: la capa de entrada, donde se reciben los datos a procesar; la capa intermedia, donde se da el procesamiento propiamente dicho y la capa de salida. Las redes neuronales artificiales tipo *feedforward* (RNAf) son relativamente fáciles de programar, por lo que son muy populares entre la comunidad científica.

Los datos proporcionados para el presente estudio proceden de un estudio previo realizado en la misma división del IMT, con un modelo hidráulico a escala. Contándose con un conjunto de 21 casos de elevación inicial de tsunami local y sus respectivas corrientes litorales generadas en 423 puntos de modelación en el interior del Puerto de Manzanillo, Col.

Ante tan incipiente cantidad de datos y elevada complejidad, se decidió tomar los 21 casos de elevación inicial de tsunami local pero considerar la rapidez máxima y la rapidez media de las corrientes litorales en sólo 50 puntos de modelación en el interior del puerto y proponer sendas RNAf.

Para hallar la RNAf óptima que aprenda los patrones de rapidez máxima y media, hace falta tomar en cuenta todas las posibles combinaciones de parámetros propios de la red neuronal (como número de neuronas en la capa

intermedia, tasa de aprendizaje, etc.). Enfrentándose a, cuando menos, 2^{14} ejecuciones de algoritmo. Para completarlas todas y hallar la combinación que haga que la respuesta de la RNAf tenga el mínimo error porcentual absoluto medio (MAPE) respecto de los datos de validación, o sea, la RNAf óptima para cada patrón propuesto, se implementaron estrategias de cómputo paralelo y de registro y seguimiento de la ejecución de algoritmos largos en una base de datos relacional.

La RNAf óptima, en ambos casos de patrones, tiene cinco neuronas de entrada cuyas variables son referentes al punto de modelación, sin variables sintéticas adicionales, a saber: número del punto de modelación, elevación inicial, latitud, longitud y profundidad del punto de modelación. Con una sola variable de salida: la rapidez máxima en cada punto de modelación para una RNAf y la rapidez media para la otra. Ambas también con 14 neuronas en la capa intermedia, es decir, 2.8 veces el número de neuronas en la capa de entrada. En ambos casos la mejor convergencia se logró al tomar 21 casos dato para entrenamiento y 1 para predicción y validación de la respuesta de la red.

Hallándose que el aprendizaje del patrón para ambas RNAf se dio con una precisión de la predicción y un error porcentual absoluto medio menor al 19%.

Futuros desarrollos pueden buscar abarcar la complejidad completa del problema o incluir la evolución temporal del tsunami; lo que evidentemente requerirá de un mayor número de casos dato.

Finalmente, ese trabajo tomó ventaja de la plataforma estadística R que, respecto de los lenguajes de programación tradicionales, mostró prestaciones muy superiores y simplicidad de codificación.

Introducción

Los tsunamis son series de ondas oceánicas largas, las cuales se caracterizan por tener una longitud de onda mucho mayor que su altura y que se forman al ocurrir alguna alteración de corta duración, pero de gran extensión, en su superficie libre. Tienen diversas causas, pudiéndose clasificar en naturales, como los sismos grandes pero con poca profundidad focal; los deslizamientos del suelo submarino y las erupciones volcánicas e impactos de meteoritos; o bien, generadas por el hombre, como son las explosiones nucleares.

En aguas profundas la longitud de estas ondas alcanzan cientos de metros y su amplitud es del orden de apenas un metro. Pero su rapidez alcanza cientos de kilómetros por hora. A medida que el tsunami se acerca a la costa, su velocidad disminuye, pero ya que es un solitón, su disipación es relativamente poca, y por conservación energética, su altura se ve incrementada. En algunos casos alcanzando decenas de metros [5].

Por lo que la actividad comercial, industrial y turística que se desarrolla en zonas costeras, particularmente en los puertos, se ve amenazada por tan grande peligro. De ahí el capital interés de su estudio y modelación. La altura que alcanzan los tsunamis en la costa depende de las características de sus olas en mar abierto, pero también de las características de la zona en tierra donde llega, por lo que se deben considerar: la resonancia, difracción y refracción, junto con la pendiente y la configuración batimétrica de la costa.

En México, los estados de Colima, Guerrero, Oaxaca y Michoacán son los que han presentado mayor incidencia de tsunamis locales a lo largo de la historia reciente [7].

El recuento documental de afectaciones por tsunamis en el país comprende casos a lo largo de la Costa Occidental desde el año 1787 al 2003. Teniéndose verificados 60 tsunamis en 250 años.

Se distinguen dos tipos: los de origen lejano, como por ejemplo los recientes tsunamis originados en Sumatra en el año 2004, Chile 2010 y Japón 2011; cuyas consecuencias incluyen alturas de ola de un máximo de 2.5 m. Y, por otra parte, los tsunamis de origen cercano, que han llegado a tener alturas de ola de 5 y 10 metros; como los que se registraron en las costas de Oaxaca en 1787 y en el estado de Guerrero en 1925.

Los tsunamis ocurridos en México han tenido una mediana de 2m de altura de ola, pero algunos casos extremos llegan a superar la barrera de los 10 m. y, por lo

general, son generados por sismos grandes, mayores de 7.0, en particular, de mediana 7.7 grados en la escala sísmica de Richter.

Por otra parte, la ciencia y la tecnología se están enfrentando a problemas de complejidad cada vez más profunda y que se dan cada vez con mayor frecuencia. Entonces se crean nuevos desarrollos teóricos y tecnologías computacionales que coadyuven en la solución de tales retos.

Recientemente, los métodos computacionales de inteligencia artificial han ganado terreno en donde los métodos matemáticos y numéricos tradicionales hallaban serias dificultades para resolver problemas que involucraban muchas variables y eran de naturaleza no lineal, o estaban centrados en el procesamiento de una enorme cantidad y variedad de datos y, en el caso más extremo, donde se carecía de un modelo matemático previo que describiera la esencia del problema mismo [16].

Uno de dichos métodos son las redes neuronales artificiales (RNA). Son sistemas de procesamiento de datos e información modelados en similitud del funcionamiento de un cerebro biológico real.

Su mayor mérito es la habilidad de procesar grandes volúmenes de información, parcial y difusa, cuya relación funcional no es del todo clara. Pues, por ejemplo, experiencias tan cotidianas para el cerebro humano como el reconocimiento de voz o de grafías, son epítomes de la complejidad para la programación tradicional de sistemas informáticos. A la vez que soluciones notables logradas mediante este novedoso método.

Una RNA es capaz de aprender y ajustarse a su ambiente informático exterior. El entrenamiento de dicha red es el proceso de aprendizaje, el cual se lleva a cabo mediante el procesamiento repetido de ejemplos específicos conocidos y validados. Dándole la capacidad de aprender y memorizar grandes cantidades de información muy variada y formalizarla. Adicionalmente, es capaz de hacer predicciones a partir de los datos con los que ha sido entrenada. Tal como el cerebro biológico aprende a base de experiencias repetidas y hace inferencias a partir de ellas.

Internamente, las RNA se componen de algoritmos que representan unidades simples de cómputo llamadas neuronas, interconectadas en una topología dada, y el masivo procesamiento paralelo de información que llevan a cabo emula el funcionamiento de una red neuronal biológica real, dando lugar a procesos de aprendizaje y veloz síntesis de información. Sus salidas tienen las ventajas de no estar sujetas a un modelo matemático específico, ser tolerantes a fallas localizadas de los datos de entrada y no necesitan de condiciones externas a los datos mismos [8, 14].

Así, son capaces de desarrollar relaciones funcionales entre datos y proveer una poderosa herramienta de interpolación no lineal y multidimensional; por lo que se

les ha empleado principalmente en la resolución de problemas que involucran tareas de predicción e identificación de patrones. Sus aplicaciones se extienden a diversos campos de la actividad humana, como son: Econometría, Electrónica, Física, Medicina, Automatización, por citar algunos [17].

En el campo de la ingeniería marítima y de costas, se reconoce que las RNA se han aplicado exitosamente en problemas que involucran la estimación o predicción de parámetros ambientales, cargas estructurales y comportamiento de estructuras; llevando a cabo tareas de aproximación de funciones, optimización, modelado de sistemas y aprendizaje de patrones. También en predicción de niveles de marea, olas costeras, olas de viento, predicción de la licuefacción del suelo marino inducido por el oleaje, predicción de tormentas y morfología de costas [6, 11].

Finalmente, se debe hacer énfasis en el trabajo realizado por la Dra. Barbara Zanuttigh, de la Universidad de Boloña. Como extensión del desarrollo de la famosa herramienta para el cálculo de *overtopping* de estructuras *CLASH-project*, implementó una solución de RNA para la predicción de coeficientes de reflexión de olas para una gran variedad de estructuras de protección. Entrenó y validó la red con una gigantesca base de datos con 6×10^3 casos registrados. Logrando que la red haga predicciones con una asombrosa precisión de apenas 0.04 de rmse [19].

1 Metodología

Ante tan prometedor panorama, se planteó la necesidad de revisar el estado del arte que guardan las redes neuronales artificiales *feedforward* en el campo de la ingeniería portuaria e hidráulica marítima, en lo relativo a los Tsunamis y específicamente a los efectos que se originan en los puertos. Además, explorar la posibilidad de aplicar esta novedosa metodología de las RNA en conseguir un estimador de patrones de corrientes litorales en el interior de un puerto sujeto a la acción de un tsunami, en este caso el del Puerto de Manzanillo, en el estado mexicano de Colima.

1.1 Las RNA tipo *feedforward*

Profundizando en el ámbito de las RNA, si se utiliza una de especial arquitectura llamada *feedforward*, el Dr. George Cybenko [4] demostró que con una configuración de dos capas y un número suficiente de neuronas, se puede aproximar cualquier función continua a un grado de precisión arbitrario. Por lo tanto, no sorprende ver a lo largo de la literatura que el tipo de red neuronal artificial más utilizado sea el RNAf.

Es de notarse que, si bien se han buscado en la inteligencia artificial nuevos enfoques para lidiar con los problemas de predicción e identificación de patrones, los profesores Warner y Misra [18] han demostrado también que hay bastante similitud en los fundamentos sobre los que operan el análisis generalizado de regresión y las RNA del tipo multicapa *feedforward* (RNAf).

Una RNAf se caracteriza por ser un conjunto de neuronas que reciben información multivariable, la procesan y dan una respuesta que puede ser multivariable también. En la arquitectura *feedforward* la topología del arreglo de neuronas y sus interconexiones hace fluir la información de forma unidireccional para que nunca pueda pasar más de una vez a través de una neurona antes de generarse la respuesta de salida. Tal como muestra la figura 1.1.




Figura 1.1 Diagrama de la estructura típica de una red neuronal artificial tipo *feedforward* (RNAf).

A muy grandes rasgos, el trabajo de la red es ingresar los datos a través de las neuronas de la capa de entrada, y al pasar la información a la siguiente capa, llamada oculta, cada una de las neuronas receptoras recibe la suma ponderada de todas las entradas conectadas a ella. Pues cada conexión entre neuronas representa un peso de conexión. Lo que matemáticamente se puede resumir como:

$$\sum_j w_{ij}x_j$$

Donde w_{ij} son los pesos de cada conexión de las x_j neuronas a la neurona receptora. Pero, al igual que sucede con las neuronas biológicas reales, a menos que el estímulo tenga cierta magnitud, la información se procesa, de lo contrario se ignora. En las RNAf se logra mediante un valor umbral m_i , y a menos que la suma ponderada supere un valor dado, se considera la salida efectiva de la información procesada. Nuevamente, se puede expresar como:

$$\sum_j w_{ij}x_j - m_i$$

El cerebro biológico aprende mediante la modificación de la intensidad de las conexiones sinápticas mismas. En los algoritmos se emula añadiendo también una función de activación. Se han considerado muchas a lo largo de la literatura; sin embargo, la más famosa, junto con la tangente hiperbólica, es la función sigmoideal que tiene la forma:

$$g: \mathbb{R} \rightarrow (0,1) \mid g(\text{entrada}) = \frac{1}{1 + e^{-\text{entrada}}}$$

Y sus propiedades se muestran en la figura 1.2.




Figura 1.2. Sigmoideal como función de activación.

El proceso de aprendizaje de la neurona puede ser del tipo conocido como **entrenamiento supervisado**. Esencialmente es un ciclo donde se cuenta con un conjunto de valores objetivo el cual sirve de patrón de comparación para la salida que arroja la RNAf. La diferencia entre éstas dos se utiliza para modificar, en la próxima iteración, los valores peso en las interconexiones de las neuronas de la red, a fin de minimizar dicha diferencia (minimizar el error).

Diversos algoritmos se utilizan para el aprendizaje de las RNAf. Sin embargo, el más popular es el de propagación reversa (*backpropagation algorithm*), y se fundamenta en una estrategia simple para reducir el error cuadrático medio, similar al método generalizado de regresión.

1.2 La plataforma estadística R

Históricamente programar una RNAf representaba un gran esfuerzo de codificación de complejas y largas recetas en lenguaje C/C++ o, aún peor, en el eficiente pero críptico FORTRAN [12].

Afortunadamente, en la actualidad se cuentan con robustas plataformas de lenguaje de más alto nivel y generación que permiten una codificación más breve, eficiente, estructurada y legible. Como lo es el software de análisis estadístico R, de código abierto y licencia libre [15].

Cuenta, además, con diversas extensiones, provistas a manera de paquetes adicionales de fácil instalación al cuerpo principal del programa, que proveen de funciones y métodos específicos de diversas áreas del conocimiento. En cuanto Inteligencia Artificial, AMORE es un paquete para diseño, programación y entrenamiento de RNAf para esta plataforma [10].


1.3 Ejemplo de una RNAf simple

Por ejemplo, una RNAf de topología 1-3-1, es decir, de 1 sola neurona de entrada, 3 neuronas en la única capa oculta y 1 neurona de salida; puede aprender con bastante facilidad (apenas 500 iteraciones) un patrón polinómico de grado 3 sumado a ruido gaussiano del 10 %y en unas cuantas líneas de código, como muestra la siguiente sesión de R:

Algoritmo 1.1 Sesión en R: ejemplo de una RNAf simple

```
# INICIO DE SESIÓN EN R
set.seed(12) # semilla para consistencia de aleatorios
require(AMORE) # paquete para RNAf
# población de datos: 5000 números entre -1 y 1
universo <- seq(-1, 1, length.out = 5000)
# datos de entrada: una muestra aleatoria de 500 números
entrada <- matrix(sample(x = universo, size = 500, replace =
FALSE),
ncol = 1)
# patrón de aprendizaje: una función cúbica con ruido normal
objetivo <- entrada^3 - 0.5 * entrada^2 + 0.1 *
rnorm(length(entrada),
mean = 0, sd = 1)
# gráfica objetivo ~ entrada
plot(entrada, objetivo, pch = "+")
```

```
grid()
# armado de la RNAf
RNAf <- newff(n.neurons = c(1, 5, 1), learning.rate.global = 0.02,
  momentum.global = 0.05, error.criterium = "LMLS", Stao = NA,
  hidden.layer = "sigmoid", output.layer = "purelin", method =
  "ADAPTgdwm")
# entrenamiento usando sólo 80% de los datos
entrada.frac <- entrada[1:400, ]
objetivo.frac <- objetivo[1:400, ]
# y 500 repeticiones con reporte de 5 líneas
resultado <- train(RNAf, entrada.frac, objetivo.frac,
  error.criterium = "LMLS",
  report = TRUE, show.step = 500, n.shows = 5)
# simulación con todos los datos
y <- sim.MLPnet(resultado$net, entrada)
# gráfica original objetivo ~ entrada (puntos grises)
titulo = "Respuesta de una RNAf 1-5-1"
plot(entrada, objetivo, pch = "+", cex = 0.7, col = "darkgrey",
  main = titulo)
# respuesta de la red entrenada (puntos azules)
points(entrada, y, col = "blue", pch = "o", cex = 0.5)
grid()
graphviz.MLPnet(net = resultado$net, filename = "RNAf-
ejemplo.dot") #diagrama
# FIN DE SESIÓN EN R
```



Como se puede observar en esta última gráfica de la sesión, los puntos indicados con '+' en color gris forman el patrón que real que debe aprender la red, la función polinómica con ruido añadido. En círculos azules se indican los puntos dados como respuesta de la RNAf.

Es evidente que la RNAf aprendió efectivamente el patrón, a pesar de haber sido entrenada con sólo una fracción de los datos y, además, con ruido añadido a los mismos.

Los pesos y conexiones de la red se muestran en el diagrama generado con la última línea de código de la sesión R, en la figura 1.3.




Figura 1.3 Estructura de la RNAf de ejemplo.

2 Datos

Las velocidades de corrientes litorales en el Puerto de Manzanillo (bajo el efecto de tsunamis) que se tienen como datos para el presente trabajo, proceden de los resultados aportados por un estudio previo. Dicha investigación fue realizada por personal del Instituto Mexicano del Transporte en su División de Ingeniería de Puertos y Costas, mediante un modelo hidráulico a escala 1:150 [13]. Los puntos de modelación (enumerados en detalle en el Anexo 2) y algunas fotos del modelo físico pueden observarse en la figura 2.1 y 2.2 respectivamente.





Figura 2.1 Puntos modelados del interior del Puerto de Manzanillo, Col. ('+' rojas) en el estudio IMT-VE-12/13.

Es importante recalcar que para los fines del presente trabajo, dichos datos se consideran debidamente calibrados y validados.



**Figura 2.2 Modelo hidráulico utilizado en el estudio IMT-VE-12/13.
(a) Generador de olas, (b) modelo a escala y (c) sensores.**

Sus respectivos archivos tienen la siguiente nomenclatura: *corr_NNNN.dat*, donde *NNNN* es la elevación inicial de la superficie al momento de originarse el tsunami (η_0) dada en milímetros. Por lo que en la siguiente sesión R se cuentan y listan todos los casos dato y con la elevación inicial en metros, como se resume en la tabla 2.1.

Algoritmo 2.1. Conteo y listado de casos dato de elevaciones iniciales.

```
archisV <- list.files(path = "datos/", pattern = "corr_")
ETHA0 <- matrix(nrow = length(archisV), ncol = 1)
for (i in 1:length(archisV)) {
  ETHA0[i, 1] <- as.numeric(substr(archisV[i], start = 6, stop =
    9))/100
}
# t(ETHA0)[1,]
```

Tabla 2.1. Casos dato de elevaciones iniciales.

Caso	1	2	3	4	5	6	7	8	9
η_0	1.07	1.08	1.24	1.42	1.46	1.60	1.78	2.49	2.58

Caso	10	11	12	13	14	15	16	17	18
η_0	2.66	2.84	3.02	3.20	3.37	3.44	3.55	4.30	6.02

Caso	19	20	21
η_0	8.60	12.05	15.50

La estructura interna de cada uno de los archivos es una matriz de números reales. Como se expresa en la ecuación siguiente:

$$\eta_0: \begin{matrix} v_{x_{11}} & \cdots & v_{x_{1k}} \\ \vdots & \ddots & \vdots \\ v_{x_{n1}} & \cdots & v_{x_{nk}} \\ v_{y_{11}} & \cdots & v_{y_{1k}} \\ \vdots & \ddots & \vdots \\ v_{y_{n1}} & \cdots & v_{y_{nk}} \end{matrix} \mid \begin{cases} n \in [t_i = 1, \dots, t_f = 59] \\ k \in [1, \dots, 423] \end{cases}$$

Donde, dada una elevación inicial η_0 por cada archivo, hay n pasos de tiempo (59 en total) y k puntos de modelación (en total 423, ver fig. 2.1). La mitad de los renglones corresponde a la componente x de la velocidad en cada paso y en cada punto; así la segunda mitad corresponde a las de la componente y.

La lectura de un archivo se ejemplifica en la siguiente sesión R:

Algoritmo 2.2. Lectura de un archivo de datos típico.

```
# LEE UN ARCHIVO DE DATOS TÍPICO
d <- read.table("datos/corr_0107.dat")
dim(d) # IMPRIME EL NÚMERO DE RENGLONES Y COLUMNAS

## [1] 118 423

# DONDE LOS PRIMEROS RENGLONES SON PASOS DE TIEMPO DE LA
# COMPONENTE X
vx <- d[1:(dim(d)[1]/2), ]
# Y LOS RESTANTES RENGLONES SON PASOS DE TIEMPO DE LA
# COMPONENTE Y
vy <- d[(1 + dim(d)[1]/2):dim(d)[1], ]
dim(vx)

## [1] 59 423

dim(vy)

## [1] 59 423
```


3 Estrategias de cómputo

Así entonces, se tienen apenas 21 elevaciones iniciales para 59 pasos de tiempo por cada uno de los 423 puntos de modelación. Significando que en tan sólo 21 casos ejemplo una RNAf debiera aprender un patrón de casi 215 elementos; evidentemente se debe concluir que resultan insuficientes [4, 14, 16, 17, 19].

3.1 Limitando la complejidad de los patrones

Por lo anteriormente explicado se decidió reducir la complejidad del estudio de manera que la baja cantidad de casos experimentados pueda servir para entrenar una RNAf satisfactoriamente, adoptando las siguientes medidas:

1. La complejidad proveniente de los pasos de tiempo se puede evitar considerando funciones de agregación sobre ellos, como por ejemplo:

a) el valor máximo y

b) el promedio de la rapidez (magnitud de la velocidad) sobre cada punto de modelación.

2. Se pueden considerar sólo los primeros 50 del total de puntos de modelación.

Mismo que son mostrados en la figura 3.1.



Figura 3.1 Puntos de modelación efectivos para el presente estudio en el interior del puertode Manzanillo, Col.

3.2 Definición de variables de entrada y salida

En ausencia de relaciones funcionales ya conocidas, o de variables sintéticas adicionales, proponen como variables de entrada a la RNAf todo lo que se conoce de cada punto de modelación:

1. Elevación inicial: (ver Tabla 2.1).
2. Número de punto de modelación: $k = [1; :::; 50]$ (ver capítulo 2).
3. Coordenada x (longitud) del punto de modelación.
4. Coordenada y (latitud) del punto de modelación.
5. Coordenada z (profundidad en positivo) del punto de modelación.

Y respecto de las variables de salida de la RNAf, como se mencionó anteriormente, hay un par de funciones de agregación interesantes, por lo que se tendrán dos RNAf distintas, a saber:

1. RNAf para modelar la rapidez máxima en los puntos modelados.
2. RNAf para modelar el promedio de la rapidez en los puntos modelados.

3.3 Normalización de los datos

Cuando se trabaja con datos continuos y de rangos muy variados como variables de entrada es recomendable normalizarlos antes de procesarlos en una RNAf, de lo contrario, el algoritmo tiene pocas posibilidades de converger [14, 12]. Empleándose para tal propósito la fórmula de la ecuación siguiente:

$$\phi(y(x)) = \frac{y - \bar{y}}{\sigma_y}$$

Donde y es el valor original a normalizar, $\bar{y}$ es el promedio de las mediciones que se quieren normalizar y σ_y su desviación estándar.

El efecto sobre la función $y(x)$ es únicamente sobre su rango, pues la forma misma de la función no es afectada, si bien se pierde la dimensión de la función y queda en unidades absolutas (u. a.), como se muestra en la figura 3.2.




Figura 3.2 Efecto de la normalización sobre una porción de los datos.

Este procedimiento se aplicará a todas las variables de entrada de las RNAf que se programen. Dándose posteriormente una desnormalización a la variable de salida de la RNAf para recuperar su rango y dimensiones.

Como se puede observar en la primera sesión R en el algoritmo 1.1, hay parámetros propios de la RNAf cuyos valores óptimos deben hallarse para cada problema en particular, éstos son:

1. Las variables de entrada,
2. las variables de salida.
3. el número de neuronas intermedias, al menos el doble de las de entrada según la literatura (ver fig. 1.1),
4. la tasa de aprendizaje de la red (sensibilidad al patrón),

5. el *momentum* global (para evitar los mínimos locales y converger al mínimo global),
6. número de pasos de entrenamiento y
7. la fracción de los datos que servirán para entrenamiento y el resto para validación de la predicción.

Debiéndose encontrar la combinación que resulte en la RNAf óptima, es decir, en la que tenga el mínimo error porcentual absoluto medio (MAPE) que se expresa como:

$$MAPE = \frac{100}{N} \sum \left| \frac{RNAf - observados}{observados} \right|$$

es decir, el promedio del valor absoluto del cociente de la diferencia de los valores predichos por la red RNAf y los datos de validación *observados* entre los valores *observados*.

3.4 Cómputo paralelo y registro de avance

Con tener apenas 4 opciones por cada uno de los parámetros de la red que se deben optimizar al aplicarse sobre el problema, aún con la complejidad reducida, se tienen casi 2^{14} ejecuciones del algoritmo para cada una de las RNAf.

Si *a priori* se considerara que cada iteración pudiera tomar en promedio unos 10 segundos en ejecutarse, una corrida completa fácilmente pudiera superar las 45hrs. Lo que requiere de un enfoque de cómputo paralelo simple que aproveche todo el poder que ofrecen los actuales procesadores multinúcleo de 64-bit (como el Intel® Core i5 donde se llevaron a cabo las corridas). La plataforma estadística R, cuenta con los paquetes *doMc* y *foreach* para tal propósito [1, 2], cuando se tienen, como en esta ocasión, iteraciones independientes del ciclo de búsqueda de la combinación óptima de parámetros de la red.

Por otra parte, también, para tan largas corridas, se debe contar con un sistema de registro de resultados y seguimiento del algoritmo, para que ante una eventualidad como un corte de energía eléctrica (tan comunes en los países subdesarrollados), se pueda reanudar la corrida donde se interrumpió. Por este motivo, se elaboró una base de datos relacional en MySQL® para el registro del avance de la corrida, enlazada a R mediante el paquete RMySQL [9].

3.5 Código de pre-proceso

Todas las estrategias de cómputo previamente descritas, se aplican en las siguientes sesiones R, que pueden considerarse formalmente como la primera parte del código definitivo.

El pre-proceso comprende tres etapas:

1. Lectura de datos, normalización y disminución de la complejidad. La salida es el archivo que alimentará las entradas de la RNAf.
2. Creación de una base de datos relacional para el registro y seguimiento del algoritmo que buscará la RNAf óptima.
3. Población de la base de datos con todas las posibles combinaciones de parámetros de la red neuronal propuestos.

Algoritmo 3.1 Pre-proceso con estrategias de cómputo implementadas (1ª Parte).

```
# FUNCIÓN PARA NORMALIZAR ----
norma <- function(original) {
  normalizado <- (original - mean(original))/sd(original)
  return(normalizado)
}

numPuntos <- 50 #reduce complejidad del problema
# CARGA DE DATOS ----
archisV <- list.files(path = "../datos/", pattern = "corr_")
# LISTADO DE ELEVACIONES INICIALES ----
ETHA0 <- matrix(nrow = length(archisV), ncol = 1)
for (i in 1:length(archisV)) {
  ETHA0[i, 1] <- as.numeric(substr(archisV[i], start = 6, stop =
    9))/100
}
# MATRICES VACÍAS ----
rMax <- matrix(nrow = numPuntos, ncol = dim(ETHA0)[1])
rMedia <- matrix(nrow = numPuntos, ncol = dim(ETHA0)[1])
e0 <- matrix(nrow = numPuntos, ncol = dim(ETHA0)[1])
# LEE LAS COORDENADAS DE LOS PUNTOS DE MODELAC. ----
cc <- read.table("../datos/TranspuestasXYZ.dat")
cc <- cc[1:numPuntos, ] #sólo los puntos efectivos
# CICLO PRINCIPAL QUE PROCESA CADA ARCHIVO DE DATOS ----
for (i in 1:dim(ETHA0)[1]) {
  a <- paste("../datos/", archisV[i], sep = "")
  d <- read.table(a)
  d <- d[, 1:numPuntos] #sólo los puntos efectivos
  vx <- d[1:59, ] #componente x
  vy <- d[60:118, ] #componente y
  v <- sqrt(vx * vx + vy * vy) #rapidez
  # RAPIDEZ EN CADA PUNTO (REGLON) POR CADA EXPERIMENTO
  # (COLUMNA) ----
  rMedia[, i] <- matrix(sapply(v, mean), ncol = 1)
  rMax[, i] <- matrix(sapply(v, max), ncol = 1)
  e0[, i] <- matrix(rep(ETHA0[i], numPuntos), ncol = 1)
  if (i <= (dim(ETHA0)[1] - 1)) {
    # repite lectura de coordenadas
```

```
cc0 <- read.table("../datos/TranspuestasXYZ.dat")
cc0 <- cc0[1:numPuntos, ]
cc <- rbind(cc, cc0)
}

}
# TRANSFORMACIÓN MATRICES A VECTORES ----
rapMax <- matrix(as.vector(rMax), ncol = 1)
rapMedia <- matrix(as.vector(rMedia), ncol = 1)
names(cc) <- c("lon", "lat", "z")
puntos <- matrix(rep(1:numPuntos, dim(ETHA0)[1]), ncol = 1)
elevac0 <- matrix(as.vector(e0), ncol = 1)
# JUNTA VECTORES ----
P <- cbind(puntos, elevac0, cc, rapMax, rapMedia)
P <- P[order(P[, 2], P[, 1]), ] #ordena por elevac. inic. y núm.
pto. modelac.
normP <- P #copia la matriz P
for (j in 1:dim(P)[2]) {
  # normaliza cada columna
  normP[, j] <- matrix(norma(P[, j]), ncol = 1)
}
# ESCRIBE ARCHIVOS PARA ALIMENTAR A LA RNAf ----
write.table(P, "../datos/P.txt", row.names = FALSE) #sin
normalizar
write.table(normP, "../datos/normP.txt", row.names = FALSE)
#NORMALIZADO
```

Ahora ya se tiene el archivo que ha de alimentar a la RNAf llamado *normP.txt*. Contiene 1050 renglones (50 puntos de modelación por 21 casos de elevación inicial) y 7 columnas:

1. el número de punto de modelación;
2. la elevación inicial (repetida para los 50 puntos en cada ocasión);
3. longitud,
4. latitud,
5. la profundidad (z) del punto de modelación;
6. rapidez máxima,
7. y rapidez media.

Para la siguiente etapa es necesario contar con la base de datos relacional y su respectiva tabla creada, planeada para hacer en ella el registro y seguimiento de la rutina que buscará la RNAf óptima. Como se describe en el algoritmo siguiente:

Algoritmo 3.2 Creación de la base de datos en MySQL para seguimiento del algoritmo.

```
# CREA Y SELECCIONA LA BASE DE DATOS
CREATE DATABASE corridas ; USE corridas ;
# CREA LA ÚNICA TABLA DE LA BD
CREATE TABLE ` combinaciones ` (
`nCP` int (11) DEFAULT NULL,
` colsP ` varchar (50) DEFAULT NULL,
` colsQ ` varchar (50) DEFAULT NULL,
` hidden ` int (11) DEFAULT NULL,
` l r ` double DEFAULT NULL,
`mg` double DEFAULT NULL,
` ss ` double DEFAULT NULL,
` picked ` int (11) DEFAULT NULL,
`done ` int (11) DEFAULT NULL )
ENGINE=InnoDB DEFAULT CHARSET= latin1 ;
# CREA EL USUARIO CON CONTRASEÑA Y DA ACCESO A LA BD EN EL SERVIDOR
ACTUAL
CREATE USER ' userRNAf '@' localhost ' IDENTIFIED BY ' imt123 ' ;
GRANT ALL ON corridas . * TO ' userRNAf '@' localhost ' ;
```

La siguiente parte del pre-proceso es, pues, la generación de todas las combinaciones posibles de los parámetros de la red. Las variantes propuestas, es decir, los conjuntos dominio, se enumeran a continuación:

Fracción de los 21 casos de elevación inicial que se usan para entrenamiento:

- 2 casos para entrenamiento, 19 para para validación de la RNAf.
- 7 casos para entrenamiento, 14 para para validación de la RNAf.
- 20 casos para entrenamiento, 1 para para validación de la RNAf.

Columnas de entrada:

- Número de punto de modelación y elevación inicial.
- Número de punto de modelación, elevación inicial y profundidad del punto de modelación.
- Número de punto de modelación, elevación inicial, longitud, latitud y profundidad del punto de modelación.

Columnas de salida:

- Sólo la objetivo: rapidez máxima o media, según el caso.
- La columna objetivo y el número de punto de modelación.
- La columna objetivo, el número de punto de modelación y la elevación inicial.

Tasa de aprendizaje: desde 2×10^{-2} hasta 2×10^{-5} en 4 pasos.

Momentum global: desde 5×10^{-2} hasta 5×10^{-5} en 4 pasos.

Pasos de entrenamiento: desde 100 hasta 9000 en 4 pasos.

Factores para multiplicar el número de neuronas de la capa de entrada y determinar el número de neuronas en la capa oculta: desde 2.0 hasta 3.25 en 4 pasos.

Y su implementación se describe en el algoritmo siguiente.

Algoritmo 3.3 Pre-proceso con estrategias de cómputo implementadas (2ª parte)

```
# LIBRERIAS Y REGISTRO DE NÚCLEOS ----
set.seed(12) #fija la semilla de aleatorios
library(RMySQL) #para conectarse con la BD
library(doMC) #para cómputo paralelo
registerDoMC(cores = 4) #bueno para Core-i5
# VALORES INICIALES ----
tope <- 21 #número de casos de elevación inicial
numPuntos <- 50 #puntos de modelación reducidos
colObj <- 6 #rapMax o 7 para rapMedia
n <- 4 #divisiones de parámetros propios de la RNAf
archiDatos <- "../datos/normP.txt"
# CONJUNTOS DOMINIO ----
numCasosP <- rev(c(2, 7, 20)) #casos de aprendizaje

colsP <- rev(list(c(1, 2), c(1, 2, 5), c(1, 2, 3, 4, 5)))
#columnas de entrada
colsQ <- rev(list(c(colObj), c(colObj, 1), c(colObj, 1, 2),
c(colObj,
2, 5))) #cols. de salida
LR <- c(0.02, 0.002, 2e-04, 2e-05) #tasas de aprendizaje
MG <- c(0.05, 0.005, 5e-04, 5e-05) #momenta
SS <- c(100, 500, 1000, 9000) #pasos de entrenamiento
FF <- c(2, 2.25, 2.5, 2.75, 3, 3.25) #factores p/núm. neuronas
capa oculta
picked <- 0 #bandera: combinación en proceso
done <- 0 #bandera: combinación ya procesada
# CONEXION CON BD EN MYSQL ----
```

```

base <- "corridas"
usuario <- "userRNAf"
passw <- "imtl23"
bd <- dbConnect(MySQL(), user = usuario, password = passw, dbname
= base,
host = "localhost")
dbSendQuery(bd, "TRUNCATE combinaciones") #borra registros pasados

# CICLOS PARALELIZADOS ----
for (nCP in numCasosP) {
  for (cP in colsP) {
    for (cQ in colsQ) {
      for (factor in FF) {
        foreach(k = 1:n) %dopar% {
          for (j in 1:n) {
            foreach(i = 1:n) %dopar% {
              bd <- dbConnect(MySQL(), user = usuario,
                password = passw, dbname = base, host =
                "localhost")
              lr = LR[k]
              mg = MG[j]
              ss = SS[i]
              orden <- paste("INSERT INTO combinaciones VALUES
                (",
                nCP, ", '", paste(as.character(cP), collapse =
                  "-"),
                "'", ", '", paste(as.character(cQ), collapse =
                  "-"),
                "'", ", (floor(length(cP) * factor + 1)),
                ", ", lr, ", ", mg, ", ", ss, ", ", picked,
                ", ", done, ")", sep = "")
              dbSendQuery(bd, orden)
            }
          }
        }
      }
    }
  }
}
dbDisconnect(bd)

```


4 Búsqueda de la RNAf óptima

Una vez poblada la base de datos con las posibles combinaciones de parámetros de la red neuronal y teniéndose el archivo de datos de entrada completado, se procede a la búsqueda de la RNAf que converge con menor MAPE o RMSE, es decir, la RNAf en sí.

Algoritmo 4.1 Búsqueda de la RNAf óptima

```
# COMENTAR LÍNEAS EN CASO DE REINICIAR TRAS APAGÓN ----
file.remove("status.txt") #borra resultados anteriores
x <- cbind("colObj", "nCP", "colsP", "colsQ", "hidden", "lr",
"mg", "ss", "mape", "sigma", "lmls", "tp", "tt")
write.table(x, file = "status.txt", row.names = FALSE, col.names =
FALSE,
sep = "|")
# LIBRERIAS, VALORES INICIALES Y REGISTRO DE NÚCLEOS ----
t0 <- proc.time() #inicia cronómetro
set.seed(12) #semilla para aleatorios
library(AMORE) #para RNAf
library(RMySQL) #para conexión con BD
library(doMC) #cómputo paralelo
registerDoMC(cores = 4) #bueno para Core-i5
tope <- 21 #casos de elevación inicial
numPuntos <- 50 #complejidad reducida
colObj <- 6 #rapMax o 7 para rapMedia
archiDatos <- "../datos/normP.txt"
# VALORES DE CONEXION CON BD EN MYSQL ----
base <- "corridas"
usuario <- "userRNAf"
passw <- "imt123"
# CICLOS RESTANTES ----
bd <- dbConnect(MySQL(), user = usuario, password = passw, dbname
= base,
host = "localhost")
Q0 <- "UPDATE combinaciones SET picked=0 WHERE picked=1 AND
done=0"
dbGetQuery(bd, Q0) #repara interrupción
Q1 <- "SELECT * FROM combinaciones WHERE picked=0 AND done=0"
combinacs <- dbGetQuery(bd, Q1) #faltan por procesar
dbDisconnect(bd)

# CICLO PARALELIZADO ----
foreach(k = 1:dim(combinacs)[1], .inorder = FALSE, .combine =
rbind) %dopar%{
  set.seed(12) #homologa semilla aleatoria
```

```
caso <- combinacs[k, ] #cada una de las combinaciones
bd <- dbConnect(MySQL(), user = usuario, password = passw,
  dbname = base, host = "localhost")
marcaPicked <- paste("UPDATE combinaciones SET picked = 1 WHERE
  nCP=",
  caso$nCP, " AND colsP='", caso$colsP, "' AND colsQ='",
  caso$colsQ, "' AND hidden=", caso$hidden, " AND lr=",
  caso$lr, " AND mg=", caso$mg, " AND ss=", caso$ss,
  sep = "")
dbGetQuery(bd, marcaPicked) #asegura para procesar
t1 <- proc.time() #inicia cronómetro local del caso
P1 <- read.table(archiDatos, header = TRUE) #lee los datos
nCP <- caso$nCP #fracción de casos para entrenamiento

# LEE LAS COLUMNAS DE ENTRADA ----
A <- as.character(caso$colsP)
B <- strsplit(A, "-")[1]
D <- paste(B, collapse = ",")
E <- paste("c(", D, ")")
cP <- eval(parse(text = as.character(E)))

# LEE LAS COLUMNAS DE SALIDA ----
A <- as.character(caso$colsQ)
B <- strsplit(A, "-")[1]
D <- paste(B, collapse = ",")
E <- paste("c(", D, ")")
cQ <- eval(parse(text = as.character(E)))
hidden = caso$hidden #núm. neuronas capa oculta
lr = caso$lr #tasa de aprendizaje
mg = caso$mg #momentum
ss = caso$ss #pasos de entrenamiento

# MATRIZ DE ENTRADA DE DATOS A LA RNAf ----
P <- as.matrix(P1[1:(nCP * numPuntos), cP])
# PATRON DE ENTRENAMIENTO ----
Q <- as.matrix(P1[1:(nCP * numPuntos), cQ])

# armado de la RNAf ----
net.start <- newff(n.neurons = c(dim(P)[2], hidden,
  length(cQ)), learning.rate.global = lr, momentum.global =
  mg,
  error.criterium = "LMLS", Stao = NA, hidden.layer =
  "tansig",
  output.layer = "purelin", method = "ADAPTgdwm")

# entrenamiento con fracción de datos ----
result <- train(net.start, P, Q, error.criterium = "LMLS",
  report = TRUE, show.step = ss, n.shows = 3)

# simulación con el resto de datos ----
sim <- sim.MLPnet(result$net, as.matrix(P1[(numPuntos *
```

```

nCP + 1):(numPuntos * tope), cP]))

# valores observados (resto de datos) ----
obs <- as.matrix(P1[(numPuntos * nCP + 1):(numPuntos *
  tope), cQ])

# modelo lineal simulados vs observados ----
fit <- lm(sim[, 1] ~ obs[, 1])

# cálculo del MAPE ----
mape <- mean(abs((sim[, 1] - obs[, 1])/obs[, 1]))

tf <- round((proc.time() - t1)[[3]], 4) #tiempo de cómputo RNAf
tff <- round((proc.time() - t0)[[3]], 4) #t total del programa

# MATRIZ DE RESULTADOS
params <- as.character(cbind(colObj, nCP,
  paste(as.character(cP),
    collapse = "-"), paste(as.character(cQ), collapse = "-"),
  hidden, lr, mg, ss, mape, round(summary(fit)$sigma,
    4), round(result$Merror[3], 4), tf, tff))

# REGISTRO DE RESULTADOS AL ARCHIVO status.txt
write.table(matrix(params, nrow = 1), file = "status.txt",
  append = TRUE, row.names = FALSE, col.names = FALSE,
  sep = "|", quote = F)
marcaDone = paste("UPDATE combinaciones SET done = 1 WHERE
  nCP=",
  caso$nCP, " AND colsP='", caso$colsP, "' AND colsQ='",
  caso$colsQ, "' AND hidden=", caso$hidden, " AND lr=",
  caso$lr, " AND mg=", caso$mg, " AND ss=", caso$ss,
  " AND picked=", 1, sep = "")
dbGetQuery(bd, marcaDone) #marca la combinación de 'procesada'

# DESCONECTA LA BD ----
dbDisconnect(bd)
}

```

Una vez ejecutadas todas las corridas programadas en la sección anterior, se registran los resultados en el archivo *status.txt*, uno para cada RNAf. Su estructura consta de:

- 13825 renglones correspondientes a todas las posibles combinaciones de parámetros y casos dato.
- 13 columnas separadas entre sí por el símbolo pipe '|':
 1. Columna objetivo: correspondiente al número de columna del archivo *normP.txt* que simula la RNAf, a saber, 6 para rapidez máxima y 7 para rapidez media.
 2. nCP: la fracción de casos que sirven para entrenamiento.

3. colsP: las columnas de entrada a la RNAf.
4. colsQ: las columnas de salida de la RNAf.
5. hidden: número de neuronas en la capa oculta de la RNAf.
6. lr : tasa de aprendizaje.
7. mg: momentum global.
8. ss: número de pasos de entrenamiento.
9. mape: error MAPE entre la predicción de la RNAf y los casos reservados para validación.
10. sigma: error RMSE entre la predicción de la RNAf y los casos reservados para validación.
11. lmls: error de convergencia del entrenamiento de la red.
12. tp: tiempo de cómputo ocupado por la combinación particular.
13. tt: tiempo total del programa transcurrido hasta el momento.

4.1 RNAf óptima

Basta entonces con hacer una ordenación de los datos contenidos en el archivo *status.txt* de acuerdo a la columna 9 (MAPE) y se podrá recuperar la RNAf óptima para cada caso, la rapidez máxima o la rapidez media para cada punto de modelación.

Dicha red neuronal artificial se puede reconstruir mediante un algoritmo parecido al que hizo la búsqueda (las modificaciones son obvias). Haciendo énfasis en que, hay que adaptarlo para ambos casos de RNAf: rapidez máxima y rapidez media.

Algoritmo 4.2 RNAf óptima para aprendizaje del patrón de rapidez máxima.

```
set.seed(12) #homologa la semilla de aleatorios
# MODIFICAR RUTA PARA CADA RNAf
d <- read.table("rapidezMaxima/status.txt", header = TRUE, sep =
"|")
d1 <- d[order(d$mape, d$ss), ] #ordena por menor MAPE
dd <- head(d1)[1, ] #toma el mínimo
write.table(dd, "rapidezMaxima/min.txt", col.names = TRUE,
row.names = FALSE)
# LIBRERIAS ----
colObj <- 6 #6 para rapMax o 7 para rapMedia
tope <- 21 #casos de elevac. inic.
numPuntos <- 50 #ptos. de modelac.
archiDatos <- "datos/normP.txt" #datos normalizados
archiParam <- "rapidezMaxima/min.txt" #params. de RNAf optima
require(AMORE) #para modelar RNAf
pmin <- read.table(archiParam, header = TRUE) #vector de params.
lr <- pmin$lr #tasa de aprendizaje
mg <- pmin$mg #momentum global
ss <- pmin$ss #núm. de pasos de entrenam.
nCP <- pmin$nCP #fracc. de datos de entrenam.

# LEE LAS COLUMNAS DE ENTRADA ----
```



```

A <- as.character(pmin$colsP)
B <- strsplit(A, "-")[[1]]
D <- paste(B, collapse = ",")
E <- paste("c(", D, ")")
cP <- eval(parse(text = as.character(E)))
# LEE LAS COLUMNAS DE SALIDA ----
A <- as.character(pmin$colsQ)
B <- strsplit(A, "-")[[1]]
D <- paste(B, collapse = ",")
E <- paste("c(", D, ")")
cQ <- eval(parse(text = as.character(E)))
P1 <- read.table(archiDatos, header = TRUE) #archivo de datos
P <- as.matrix(P1[1:(nCP * numPuntos), cP]) #matriz de entrada
Q <- as.matrix(P1[1:(nCP * numPuntos), cQ]) #patrón de entenam.
# armado de la RNAf ----
net.start <- newff(n.neurons = c(dim(P)[2], pmin$hidden,
length(cQ)),
  learning.rate.global = lr, momentum.global = mg,
error.criterium = "LMLS",
  Stao = NA, hidden.layer = "tansig", output.layer = "purelin",
  method = "ADAPTgdwm")
# entrenamiento ----
result <- train(net.start, P, Q, error.criterium = "LMLS", report
= TRUE,
  show.step = ss, n.shows = 3)
# simulación ----
sim <- sim.MLPnet(result$net, as.matrix(P1[(nCP * numPuntos +
1):(numPuntos * tope), cP]))
# fracción de datos para validación ----
obs <- as.matrix(P1[(nCP * numPuntos + 1):(numPuntos * tope), cQ])
# modelo lin. simulados vs observados ----
fit <- lm(sim[, 1] ~ obs[, 1])
mape <- mean(abs((sim[, 1] - obs[, 1])/obs[, 1])) #MAPE
rmse <- round(sqrt(mean(resid(fit)^2)), 4) #RMSE

```


5 Resultados

La RNAf óptima para aprendizaje del patrón de rapidez máxima en los 50 puntos de modelación en el interior del puerto de Manzanillo, Col. tiene las siguientes características:

5.1 RNAf estimador del patrón de rapidez máxima

Se describe a continuación la topología de la RNAf estimador del patrón de rapidez máxima. Como entrada tiene las 5 variables conocidas del punto de modelación:

1. Número del punto de modelación,
2. elevación inicial (η_0),
3. latitud,
4. longitud,
5. y profundidad z del punto de modelación.

Y una sola variable de salida: la rapidez máxima. Como se ilustra en el diagrama de la RNAf óptima en la figura 5.1

Sus parámetros se enumeran a continuación:

- Los casos de entrenamiento son 20, y 1 de validación de respuesta de la red neuronal.
- Cuenta con 14 neuronas en la capa oculta.
- La tasa de aprendizaje es: 2×10^{-4} .
- El *momentum* global: 0.05.
- Se requirieron de 9000 pasos de entrenamiento en los 20 casos primeros designados.

El error MAPE entre los valores observados y los predichos por la RNAf, es de apenas 17.6% (RMSE de 0.48). Con una distribución normal en los residuales, se reconoce que la cantidad variables de entrada en la red es suficiente y que aprende el patrón satisfactoriamente. Como atestiguan los resultados del modelo lineal entre valores observados y simulados en la tabla 5.1, así como las gráficas e histograma de la figura 5.2 y la gráfica del patrón de rapidez máxima observado junto con el predicho por la red con bandas de confianza de la figura 5.3.




Figura 5.1 Diagrama de la RNAf óptima para el patrón de rapidez máxima.

Tabla 5.1 Regresión lineal entre la predicción de la RNAf y los datos de validación en el patrón de rapidez máxima.

```
Call:
lm(formula = sim[, 1] ~ obs[, 1])

Residuals:
    Min       1Q   Median       3Q      Max
-1.2449 -0.3283 -0.0088  0.2510  1.3799

Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept)  0.23460    0.17793   1.319   0.194
obs[, 1]     0.87262    0.07399  11.793 8.74e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.4911 on 48 degrees of freedom
Multiple R-squared:  0.7434, Adjusted R-squared:  0.7381
F-statistic: 139.1 on 1 and 48 DF,  p-value: 8.737e-16
```




Figura 5.2 Gráfica del modelo lineal entre la predicción de la RNAf y los datos de validación en el patrón de rapidez máxima. Junto con el histograma y el gráfico normal q-q que muestran que los residuales tienen una distribución normal.




Figura 5.3 Patrón de rapidez máxima observado ('+' negras) junto con el predicho por la red (línea azul) con bandas de confianza (sombra azul claro).

5.2 RNAf estimador del patrón de rapidez media

Por otra parte, la RNAf óptima para aprendizaje del patrón de rapidez media en los puntos de modelación en el interior del Puerto de Manzanillo, Col. tiene las siguientes características:

Como entrada tiene las 5 variables conocidas del punto de modelación:

1. Número del punto de modelación,
2. elevación inicial (η_0),
3. latitud,
4. longitud,
5. y profundidad z del punto de modelación.

Y una sola variable de salida: la rapidez media.

Como se ilustra en el diagrama de la RNAf óptima en la figura 5.4.




Figura 5.4 Diagrama RNAf óptima para patrón de rapidez media.

Sus parámetros se enumeran a continuación:

- Los casos de entrenamiento son 20 y 1 de validación de respuesta de la red neuronal.
- Cuenta con 14 neuronas en la capa oculta.
- La tasa de aprendizaje es: 2×10^{-3} .
- El *momentum* global: 5×10^{-5} .
- Se requirieron tan sólo de 500 pasos de entrenamiento en los 20 casos primeros designados.

El error MAPE entre los valores observados y los predichos por la RNAf, es de apenas 18.7% (RMSE de 0.39). Con una distribución normal en los residuales, se reconoce que la cantidad variables de entrada en la red es suficiente y que aprende el patrón satisfactoriamente. Como atestiguan los resultados del modelo lineal entre valores observados y simulados en la tabla 5.2, así como las gráficas e histograma de la figura 5.5 y la gráfica del patrón de rapidez media observado junto con el predicho por la red con bandas de confianza de la figura 5.6.

Tabla 5.2 Regresión lineal entre la predicción de la RNAf y los datos de validación en el patrón de rapidez media.

```
Call:
lm(formula = sim[, 1] ~ obs[, 1])

Residuals:
    Min       1Q   Median       3Q      Max
-0.72542 -0.31442  0.02915  0.22389  1.06892

Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept)  0.65255     0.17647   3.698 0.000558 ***
obs[, 1]     0.68575     0.06992   9.808 4.76e-13 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.4012 on 48 degrees of freedom
Multiple R-squared:  0.6671, Adjusted R-squared:  0.6602
F-statistic: 96.2 on 1 and 48 DF, p-value: 4.76e-13
```





Figura 5.5 Gráfica del modelo lineal entre la predicción de la RNAf y los datos de validación en el patrón de rapidez media. Junto con el histograma y el gráfico normal q-q que muestran que los residuales tienen una distribución normal.




Figura 5.6 Patrón de rapidez media observado ('+' negras) junto con el predicho por la red (línea azul) con bandas de confianza (sombra azul claro).

6 Conclusiones

El presente trabajo muestra que es posible construir dos redes neuronales artificiales tipo *feedforward* como estimadores de corrientes en el interior del Puerto de Manzanillo, Col. bajo la acción de tsunamis, uno para el patrón de rapidez máxima y otro para el patrón de rapidez media.

Bastaron, en ambos casos, considerar 5 variables de entrada, todas referentes al punto de modelación, y una única variable de salida, la rapidez máxima o media según el caso de la red construida. La aparente distribución normal de los residuales del modelo lineal, entre la respuesta de la red y los datos de validación, es un buen indicador de que las redes neuronales artificiales programadas aprendieron en su totalidad los patrones a los que fueron aplicadas.

Con incipientes 21 casos dato, se halló que para ambos estimadores, la red óptima se tiene utilizando 20 casos para entrenamiento y 1 para validación de la respuesta de la red neuronal. En ambos casos se logró una respuesta de la red con un error porcentual absoluto medio menor al 19 %.

Ambas redes neuronales óptimas utilizaron una capa intermedia con 2.8 veces más neuronas que en su capa de entrada; tal como indica la literatura. Respecto de las tasas de aprendizaje son similares en ambos casos. Sin embargo, el que el *momentum* global sea 10^3 veces menor en el caso del patrón de rapidez media, puede indicar la ausencia de mínimos locales, que es congruente con el hecho de que se requirieron casi 10^2 veces menos pasos de entrenamiento también.

Futuros desarrollos pueden involucrar técnicas que acorten aún más el error de la predicción de la red neuronal artificial, abarquen la complejidad completa del problema o incluyan la evolución temporal del fenómeno del tsunami entrando al puerto. Para lo que evidentemente se requerirá de un mayor número de casos dato.

Por otra parte, este trabajo tomó ventaja de la plataforma R, que respecto de los lenguajes de programación tradicionales, mostró prestaciones superiores y simplicidad de codificación.

Bibliografía

- [1] ANALYTICS, REVOLUTION. 2013. doMC: Foreach parallel adaptor for the multicore package. R package version 1.3.0.
- [2] ANALYTICS, REVOLUTION, & WESTON, STEVE. 2014. foreach: Foreach looping construct for R. R package version 1.4.2.
- [3] BIVAND, ROGER, KEITT, TIM, & ROWLINGSON, BARRY. 2014. rgdal: Bindings for the Geospatial Data Abstraction Library. R package version 0.8-16.
- [4] CYBENKO, GEORGE. 1989. Approximation by Superpositions of a Sigmoidal Function. *Mathematics of control, signals, and systems*, **2**, 303–314.
- [5] DEAN, R.G., & DALRYMPLE, R.A. 1991. *Water Wave Mechanics for Engineers and Scientists*. Advanced series on ocean engineering. World Scientific.
- [6] DEO, M. C. 2010. Artificial neural networks in coastal and ocean engineering. *Indian journal of geomarine science*, **39**(4).
- [7] DÉVORA, ANTONIO J. SÁNCHEZ, & SANZ, SALVADOR F. FARRERAS. 1993. Catálogo de Tsunamis (Maremotos) en la Costa Occidental de México. World Data Center A for Solid Earth Geophysics Publication SE-50.
- [8] HAYKIN, SIMON S. 1994. *Neural Networks: A comprehensive foundation*. Macmillan College Publishing Company.
- [9] JAMES, DAVID A., & DEBROY, SAIKAT. 2012. RMySQL: R interface to the MySQL database. R package version 0.9-3.
- [10] LIMAS, MANUEL CASTEJÓN, MERÉ, JOAQUÍN B. ORDIERES, MARCOS, ANA GONZÁLEZ, ASCACIBAR, FRANCISCO JAVIER MARTÍNEZ DE PISÓN, ESPINOZA, ALPHA V. PERNÍA, & ELÍAS, FERNANDO ALBA. 2010. AMORE: A MORE flexible neural network package. R package version 0.2-12.
- [11] MANDAL, SUBHENDU, PATIL, SANJAY G., MANHUNATHA, Y. R., & HEGDE, A. V. 2008. Application of Neural Networks in Coastal Engineering – an Overview. The 12th international conference of international association for computer methods and advances in geomechanics, Oct.

- [12] MASTERS, TIMOTHY. 1993. Practical Neural Network Recipes in C++. Academic Press.
- [13] MONTOYA, JOSÉ MIGUEL, FLORES ÁLVAREZ, JUAN ESTÉBAN, CASAS VALENCIA, CINDY, et al. 2013. Estudio en modelo hidráulico para determinar el patrón de velocidades originado por tsunamis locales en el Puerto de Manzanillo, Col. Rep Tec. VE-12/13. Instituto Mexicano del Transporte.
- [14] ORR, GENEVIEVE. 2007 (Apr.). Neural Networks (lecture notes). http://www.willamette.edu/_gorr/classes/cs449/intro.html.
- [15] R CORE TEAM. 2013. R: A Language and Environment for Statistical Computing. R Foundation for Statistical Computing, Vienna, Austria.
- [16] TURBAN, E., ARONSON, J.E., & LIANG, T.P. 2005. Decision support systems and intelligent systems. Pearson/Prentice Hall.
- [17] VASQUEZ-LOPEZ, JUAN P. 2013 (Apr.). Las redes neuronales artificiales feedforward como identificadoras de regresiones espurias entre caminatas aleatorias. Tesis de grado de Maestría en Ciencias en Cómputo Aplicado.
- [18] WARNER, BRAD, & MISRA, MANAVENDRA. 1996. Understanding Neural Networks as Statistical Tools. The american statistician, **50**(4), 284–293.
- [19] ZANUTTIGH, BARBARA, FORMENTIN, SARA MIZAR, & BRIGANTI, RICCARDO. 2013. A neural network for the prediction of wave reflection from coastal and harbor structures. Coastal engineering, **80**(0), 49–67.

Anexo 1.Estado del arte

Libros

Dean & Dalrymple [5] Los doctores Dean y Dalrymple, de las Universidades de Florida y Delaware respectivamente, escriben este libro como una introducción a la teoría clásica de olas con un enfoque teórico riguroso. Haciéndolo una referencia clásica de la ingeniería hidráulica marítima.

Dévora & Sanz [7] Los Maestros Antonio Sánchez Dévora y Salvador Farreras arman este catálogo histórico de los tsunamis ocurridos en México. Aportando datos útiles para hacer algunas estadísticas básicas como fecha, intensidad sísmica, máximo de altura de ola registrado y localidad de origen. Dando cuenta de más de 60 tsunamis considerables y documentados entre los años 1787 a 2003.

Haykin [8] Éste es uno de los libros de texto de referencia obligada y más popular en los trabajos relacionados con redes neuronales artificiales e inteligencia artificial. Abarca tópicos con ejemplos concretos como: proceso de aprendizaje, perceptrones de una y multicapa; además del procesamiento temporal con redes tipo *feedforward*.

Masters [12] El Dr. Timothy Masters se especializa en estadística matemática y cómputo numérico. Este libro es la referencia obligada para el programador experto que quiere “reinventar la rueda” al aplicar técnicas de algoritmos de redes neuronales artificiales en la solución de problemas, pero con control detallado de la totalidad del código.

Turban et al. [16] El Dr. Efraim Turban de la Universidad de California en Berkeley y su equipo presentan un extenso panorama de casos reales de Cómputo Aplicado, particularmente de sistemas expertos e inteligencia artificial. Acompañados de breves fundamentos teóricos y guías para la implementación de estas nuevas tecnologías. De especial interés son los capítulos dedicados a inteligencia artificial y redes neuronales artificiales.

Artículos

Cybenko [4] El Dr. George Cybenko, del Centro de Investigación y Desarrollo de Supercómputo de la Universidad de Illinois EEUU, demuestra con formalismo topológico que una combinación lineal finita de funciones sigmoidales, como las usadas como funciones de activación en las redes neuronales artificiales, poder aproximar uniformemente cualquier función de n variables reales. Y como corolario: una red de dos capas puede aproximar cualquier región de decisión en precisión arbitraria.

Deo [6] El Profesor Deo, del Indian Institute of Technology de Bombay, hace en su artículo una introducción básica de los fundamentos teóricos que describen el funcionamiento de una red neuronal artificial; procediendo con un recuento de algunas de las aplicaciones que se han dado a estas herramientas de cómputo en el campo de la Ingeniería de costas y marítima. Destacándose la predicción e interpolación de parámetros de oleaje, cálculo de cargas en estructuras de protección marítima y respuesta de las mismas. Advierte de la necesidad de profundizar en la calibración y optimización del proceso de aprendizaje de la red para tener resultados coherentes y efectivos. Mencionando la ventaja de involucrar otras tecnologías además de la sola red, como la lógica difusa y los algoritmos genéticos.

Mandal et al. [11] En este artículo el Dr. Mandal junto con los investigadores del National Institute of Technology Karnataka en India: Dr. Sanjai Patil, Dr. Manhunatha y Dr. Hedge, hacen un recuento del conocimiento básico e introductorio de las bondades y del funcionamiento de una red neuronal *feedforward* y de algunas de las aplicaciones que se han llevado a cabo en el campo de la Ingeniería de Costas. Resaltando: la predicción de parámetros de oleaje, predicción de mareas y daños a estructuras costeras. Donde los resultados predichos por las redes neuronales artificiales superan en precisión a los modelos tradicionales empleados para la solución de esos problemas.

Warner & Misra [18] Los Profesores Brad Warner de la United States Air Force Academy y Manavendra Misra de la Colorado School of Mines, hacen un detallado análisis teórico del funcionamiento de las redes neuronales *feedforward*. Comparándolo con el método estadístico de regresión multivariable, demostrando las fuertes similitudes en sus fundamentos y un desempeño muy similar entre ambas metodologías. Dicho parecido se hace más cercano cuando ambas se aplican a tareas de predicción e identificación de patrones.

Zanuttigh et al. [19] El trabajo que presentan es una extensión de la famosa herramienta para el cálculo de *overtopping* del proyecto CLASH. Este artículo detalla la implementación de una red neuronal artificial para la predicción de coeficientes de reflexión de olas para una gran variedad de estructuras de protección. La red se entrenó y validó con una enorme base de datos con 6×10^3 casos registrados. Lograron una alta precisión de la red, con un rmse de apenas 0.04.

Misceláneos

Analytics [1] Documentación del paquete R que permite que tareas básicas de cómputo paralelo sean llevadas a cabo desde la plataforma R, permitiendo el uso intensivo de todos los núcleos de los nuevos procesadores de 64-bit multinúcleo como el Intel[®] Core i5 y Core i7, o su competidor AMD[®].

Analytics & Weston [2] Documentación del paquete R que paraleliza tareas de cómputo que se puedan reducir a iteraciones independientes de un mismo ciclo.

Bivand et al. [3] Paquete que permite la interacción de R con las utilerías gdal del sistema operativo. Para poder, así, ejecutar el catálogo de funciones, como porejemplo, el de conversión de coordenadas entre diferentes modelos cartográficos.

James & DebRoy [9] Paquete que conecta bases de datos relacionales MySQL® con la plataforma estadística R, para acceso y escritura de datos.

Limas et al. [10] Paquete creado para simulaciones que involucren redes neuronales artificiales *feedforward* en R.

Montoya et al. [13] Estudio que aportó los datos sobre velocidades de corrientes litorales en el interior del Puerto de Manzanillo en presencia de tsunamis, producto de un modelo hidráulico.

Orr [14] La Dra. Orr tiene un curso de redes neuronales artificiales desde 1999 en la Universidad Willamette en Óregon, EEUU. Cuenta con amplio material didáctico disponible en línea, simulaciones y ejercicios. Abarca desde los tópicos básicos, pasando por todos los detalles de la construcción de algoritmos que componen una red neuronal artificial, hasta los procedimientos para la optimización del funcionamiento de las redes, como por ejemplo, estrategias para evitar el *overfitting* y la no-convergencia.

R Core Team [15] Reconocido software estadístico de licencia gratuita y código abierto. Cuenta con diferentes extensiones que facilitan la programación y el análisis en diversas áreas, entre ellas, inteligencia artificial y redes neuronales artificiales.

Vasquez-Lopez [17] En esta tesis de grado el autor aplica una RNAf que discrimina satisfactoriamente las asociaciones ilegítimas que se dan entre caminatas aleatorias. Un tema de gran relevancia para el Cómputo Aplicado, pero también para la Econometría. Los algoritmos empleados se basan en la plataforma estadística R y el paquete AMORE.

Anexo 2

Coordenadas UTM de los 423 puntos de modelación.

##	lon	lat	z
## 1	573199	2107250	15.274
## 2	573199	2107200	16.929
## 3	573199	2107150	17.300
## 4	573199	2107100	16.497
## 5	573249	2107250	12.082
## 6	573249	2107200	16.381
## 7	573249	2107150	17.185
## 8	573249	2107100	14.683
## 9	573299	2107250	12.549
## 10	573299	2107200	16.211
## 11	573299	2107150	16.390
## 12	573299	2107100	13.133
## 13	573349	2107250	15.034
## 14	573349	2107200	16.615
## 15	573349	2107150	16.448
## 16	573349	2107100	11.345
## 17	573399	2107250	14.897
## 18	573399	2107200	16.433
## 19	573399	2107150	16.294
## 20	573399	2107100	10.260
## 21	573449	2107250	14.943
## 22	573449	2107200	16.406
## 23	573449	2107150	15.459
## 24	573499	2107250	16.189
## 25	573499	2107200	16.591
## 26	573499	2107150	15.324
## 27	573549	2107250	16.330
## 28	573549	2107200	16.774
## 29	573549	2107150	15.219
## 30	573599	2107250	16.686
## 31	573599	2107200	17.114
## 32	573599	2107150	15.263
## 33	573649	2107250	15.642
## 34	573649	2107200	16.635
## 35	573649	2107150	14.799
## 36	573699	2107250	16.433
## 37	573699	2107200	16.993
## 38	573699	2107150	13.338
## 39	573749	2107250	16.777
## 40	573749	2107200	16.961
## 41	573749	2107150	16.562
## 42	573749	2107100	12.041
## 43	573799	2107250	16.743
## 44	573799	2107200	16.697
## 45	573799	2107150	16.577
## 46	573799	2107100	16.120
## 47	573799	2107050	15.277
## 48	573799	2107000	14.968
## 49	573799	2106950	14.937
## 50	573849	2107250	16.647
## 51	573849	2107200	17.007
## 52	573849	2107150	16.333
## 53	573849	2107100	15.748
## 54	573849	2107050	15.181
## 55	573849	2107000	15.043
## 56	573849	2106950	14.982
## 57	573849	2106900	14.998
## 58	573849	2106850	14.427
## 59	573849	2106800	11.490
## 60	573899	2107300	14.477
## 61	573899	2107250	16.986
## 62	573899	2107200	16.971
## 63	573899	2107150	16.315
## 64	573899	2107100	15.532
## 65	573899	2107050	15.145
## 66	573899	2107000	15.015
## 67	573899	2106950	15.043
## 68	573899	2106900	14.866
## 69	573899	2106850	14.693
## 70	573899	2106800	14.759
## 71	573949	2107300	13.002
## 72	573949	2107250	16.800
## 73	573949	2107200	17.168
## 74	573949	2107150	16.308
## 75	573949	2107100	15.359
## 76	573949	2107050	15.139
## 77	573949	2107000	14.652
## 78	573949	2106950	14.707
## 79	573949	2106900	14.843
## 80	573949	2106850	14.882
## 81	573949	2106800	14.426
## 82	573999	2107300	15.603
## 83	573999	2107250	16.765

## 84	573999	2107200	17.065	## 141	574199	2106850	15.939
## 85	573999	2107150	16.462	## 142	574199	2106800	15.600
## 86	573999	2107100	15.563	## 143	574249	2107550	10.128
## 87	573999	2107050	15.196	## 144	574249	2107500	13.633
## 88	573999	2107000	15.042	## 145	574249	2107450	16.242
## 89	573999	2106950	14.725	## 146	574249	2107400	16.343
## 90	573999	2106900	14.783	## 147	574249	2107350	16.789
## 91	573999	2106850	15.161	## 148	574249	2107300	17.259
## 92	573999	2106800	15.297	## 149	574249	2107250	17.088
## 93	574049	2107300	16.626	## 150	574249	2107200	16.877
## 94	574049	2107250	17.328	## 151	574249	2107150	15.500
## 95	574049	2107200	16.771	## 152	574249	2107100	15.375
## 96	574049	2107150	15.949	## 153	574249	2107050	15.190
## 97	574049	2107100	15.515	## 154	574249	2107000	15.143
## 98	574049	2107050	15.312	## 155	574249	2106950	15.294
## 99	574049	2107000	15.142	## 156	574249	2106900	15.387
## 100	574049	2106950	15.056	## 157	574249	2106850	15.852
## 101	574049	2106900	15.272	## 158	574249	2106800	11.541
## 102	574049	2106850	15.648	## 159	574299	2107600	8.808
## 103	574049	2106800	16.068	## 160	574299	2107550	11.686
## 104	574099	2107350	16.231	## 161	574299	2107500	16.407
## 105	574099	2107300	16.369	## 162	574299	2107450	16.346
## 106	574099	2107250	17.073	## 163	574299	2107400	16.299
## 107	574099	2107200	16.722	## 164	574299	2107350	16.806
## 108	574099	2107150	15.358	## 165	574299	2107300	16.611
## 109	574099	2107100	15.379	## 166	574299	2107250	16.401
## 110	574099	2107050	15.301	## 167	574299	2107200	15.752
## 111	574099	2107000	15.221	## 168	574299	2107150	15.538
## 112	574099	2106950	15.162	## 169	574299	2107100	15.509
## 113	574099	2106900	15.433	## 170	574299	2107050	15.458
## 114	574099	2106850	15.783	## 171	574299	2107000	15.346
## 115	574099	2106800	15.851	## 172	574299	2106950	15.504
## 116	574149	2107400	14.192	## 173	574299	2106900	15.571
## 117	574149	2107350	16.554	## 174	574299	2106850	15.026
## 118	574149	2107300	16.880	## 175	574349	2107650	8.119
## 119	574149	2107250	17.365	## 176	574349	2107600	13.701
## 120	574149	2107200	16.887	## 177	574349	2107550	16.094
## 121	574149	2107150	15.544	## 178	574349	2107500	16.533
## 122	574149	2107100	15.303	## 179	574349	2107450	16.436
## 123	574149	2107050	15.203	## 180	574349	2107400	16.674
## 124	574149	2107000	15.316	## 181	574349	2107350	16.722
## 125	574149	2106950	15.359	## 182	574349	2107300	16.326
## 126	574149	2106900	15.508	## 183	574349	2107250	16.474
## 127	574149	2106850	15.560	## 184	574349	2107200	15.427
## 128	574149	2106800	15.696	## 185	574349	2107150	15.133
## 129	574199	2107450	13.859	## 186	574349	2107100	15.488
## 130	574199	2107400	16.322	## 187	574349	2107050	15.589
## 131	574199	2107350	16.487	## 188	574349	2107000	15.349
## 132	574199	2107300	17.253	## 189	574349	2106950	15.467
## 133	574199	2107250	17.304	## 190	574349	2106900	15.162
## 134	574199	2107200	16.777	## 191	574399	2107700	12.746
## 135	574199	2107150	15.473	## 192	574399	2107650	14.623
## 136	574199	2107100	15.268	## 193	574399	2107600	16.515
## 137	574199	2107050	15.302	## 194	574399	2107550	16.551
## 138	574199	2107000	15.075	## 195	574399	2107500	16.678
## 139	574199	2106950	15.152	## 196	574399	2107450	16.911
## 140	574199	2106900	15.503	## 197	574399	2107400	16.899

## 198	574399	2107350	16.492	## 254	574549	2107650	16.720
## 199	574399	2107300	16.514	## 255	574549	2107600	16.603
## 200	574399	2107250	15.070	## 256	574549	2107550	16.299
## 201	574399	2107200	14.946	## 257	574549	2107500	16.141
## 202	574399	2107150	15.156	## 258	574549	2107450	16.221
## 203	574399	2107100	15.640	## 259	574549	2107400	15.616
## 204	574399	2107050	15.528	## 260	574549	2107350	14.646
## 205	574399	2107000	15.251	## 261	574549	2107300	15.320
## 206	574399	2106950	14.892	## 262	574549	2107250	14.241
## 207	574399	2106900	14.632	## 263	574299	2108750	11.665
## 208	574449	2107850	12.594	## 264	574299	2108700	11.524
## 209	574449	2107800	14.560	## 265	574299	2108650	10.793
## 210	574449	2107750	14.864	## 266	574349	2108750	11.887
## 211	574449	2107700	15.922	## 267	574349	2108700	12.083
## 212	574449	2107650	16.364	## 268	574349	2108650	11.973
## 213	574449	2107600	16.540	## 269	574349	2108600	11.757
## 214	574449	2107550	16.689	## 270	574349	2108550	12.901
## 215	574449	2107500	16.885	## 271	574349	2108500	8.753
## 216	574449	2107450	16.630	## 272	574349	2108450	8.223
## 217	574449	2107400	16.356	## 273	574399	2108750	11.982
## 218	574449	2107350	16.339	## 274	574399	2108700	12.652
## 219	574449	2107300	16.351	## 275	574399	2108650	15.510
## 220	574449	2107250	15.237	## 276	574399	2108600	15.326
## 221	574449	2107200	15.037	## 277	574399	2108550	15.286
## 222	574449	2107150	15.046	## 278	574399	2108500	15.483
## 223	574449	2107100	15.270	## 279	574399	2108450	15.548
## 224	574449	2107050	15.376	## 280	574449	2108750	15.499
## 225	574449	2107000	14.711	## 281	574449	2108700	15.749
## 226	574449	2106950	13.821	## 282	574449	2108650	15.979
## 227	574499	2107950	12.906	## 283	574449	2108600	15.918
## 228	574499	2107900	14.597	## 284	574449	2108550	15.750
## 229	574499	2107850	16.144	## 285	574449	2108500	15.641
## 230	574499	2107800	16.051	## 286	574449	2108450	15.955
## 231	574499	2107750	16.140	## 287	574449	2108400	15.501
## 232	574499	2107700	16.301	## 288	574499	2108750	15.812
## 233	574499	2107650	16.819	## 289	574499	2108700	15.769
## 234	574499	2107600	16.789	## 290	574499	2108650	15.927
## 235	574499	2107550	16.568	## 291	574499	2108600	16.058
## 236	574499	2107500	16.662	## 292	574499	2108550	16.347
## 237	574499	2107450	16.211	## 293	574499	2108500	16.310
## 238	574499	2107400	15.983	## 294	574499	2108450	16.182
## 239	574499	2107350	16.069	## 295	574499	2108400	16.196
## 240	574499	2107300	15.082	## 296	574499	2108350	16.230
## 241	574499	2107250	15.286	## 297	574549	2108750	16.054
## 242	574499	2107200	14.825	## 298	574549	2108700	16.012
## 243	574499	2107150	13.571	## 299	574549	2108650	16.119
## 244	574499	2107100	14.324	## 300	574549	2108600	16.195
## 245	574549	2108100	14.368	## 301	574549	2108550	16.765
## 246	574549	2108050	16.272	## 302	574549	2108500	16.650
## 247	574549	2108000	16.287	## 303	574549	2108450	16.668
## 248	574549	2107950	16.184	## 304	574549	2108400	16.545
## 249	574549	2107900	16.149	## 305	574549	2108350	16.295
## 250	574549	2107850	16.529	## 306	574549	2108300	16.368
## 251	574549	2107800	16.454	## 307	574599	2108750	16.266
## 252	574549	2107750	16.478	## 308	574599	2108700	16.220
## 253	574549	2107700	16.265	## 309	574599	2108650	16.529

## 310	574599	2108600	16.362	## 367	574699	2108300	16.676
## 311	574599	2108550	16.432	## 368	574699	2108250	16.864
## 312	574599	2108500	16.625	## 369	574699	2108200	16.516
## 313	574599	2108450	16.625	## 370	574699	2108150	16.549
## 314	574599	2108400	16.142	## 371	574699	2108100	16.465
## 315	574599	2108350	16.456	## 372	574699	2108050	16.414
## 316	574599	2108300	16.643	## 373	574699	2108000	16.545
## 317	574599	2108250	16.574	## 374	574699	2107950	16.444
## 318	574599	2108200	16.755	## 375	574699	2107900	16.110
## 319	574599	2108150	16.378	## 376	574699	2107850	15.749
## 320	574599	2108100	16.286	## 377	574699	2107800	14.470
## 321	574599	2108050	16.425	## 378	574749	2108750	15.988
## 322	574599	2108000	16.765	## 379	574749	2108700	16.021
## 323	574599	2107950	16.509	## 380	574749	2108650	16.237
## 324	574599	2107900	16.315	## 381	574749	2108600	16.290
## 325	574599	2107850	16.449	## 382	574749	2108550	16.271
## 326	574599	2107800	16.537	## 383	574749	2108500	16.369
## 327	574599	2107750	16.477	## 384	574749	2108450	16.615
## 328	574599	2107700	16.646	## 385	574749	2108400	16.746
## 329	574599	2107650	16.110	## 386	574749	2108350	16.390
## 330	574599	2107600	15.705	## 387	574749	2108300	16.697
## 331	574599	2107550	15.788	## 388	574749	2108250	16.517
## 332	574599	2107500	15.920	## 389	574749	2108200	16.327
## 333	574599	2107450	12.022	## 390	574749	2108150	16.580
## 334	574649	2108750	16.065	## 391	574749	2108100	16.766
## 335	574649	2108700	16.350	## 392	574749	2108050	16.695
## 336	574649	2108650	16.666	## 393	574749	2108000	16.403
## 337	574649	2108600	16.853	## 394	574749	2107950	9.743
## 338	574649	2108550	16.407	## 395	574799	2108750	15.782
## 339	574649	2108500	16.625	## 396	574799	2108700	15.757
## 340	574649	2108450	16.526	## 397	574799	2108650	16.424
## 341	574649	2108400	16.323	## 398	574799	2108600	16.391
## 342	574649	2108350	16.611	## 399	574799	2108550	16.188
## 343	574649	2108300	16.933	## 400	574799	2108500	16.429
## 344	574649	2108250	16.552	## 401	574799	2108450	16.640
## 345	574649	2108200	16.680	## 402	574799	2108400	16.639
## 346	574649	2108150	16.419	## 403	574799	2108350	16.696
## 347	574649	2108100	16.687	## 404	574799	2108300	16.764
## 348	574649	2108050	16.607	## 405	574799	2108250	16.533
## 349	574649	2108000	16.816	## 406	574799	2108200	16.412
## 350	574649	2107950	16.791	## 407	574799	2108150	15.876
## 351	574649	2107900	16.307	## 408	574849	2108750	15.855
## 352	574649	2107850	16.260	## 409	574849	2108700	15.896
## 353	574649	2107800	16.314	## 410	574849	2108650	16.050
## 354	574649	2107750	16.053	## 411	574849	2108600	16.268
## 355	574649	2107700	15.955	## 412	574849	2108550	16.398
## 356	574649	2107650	15.719	## 413	574849	2108500	16.248
## 357	574649	2107600	15.036	## 414	574849	2108450	16.461
## 358	574699	2108750	16.061	## 415	574849	2108400	16.383
## 359	574699	2108700	16.078	## 416	574849	2108350	16.442
## 360	574699	2108650	16.110	## 417	574849	2108300	15.234
## 361	574699	2108600	16.279	## 418	574899	2108750	16.048
## 362	574699	2108550	16.227	## 419	574899	2108700	16.653
## 363	574699	2108500	16.547	## 420	574899	2108650	16.417
## 364	574699	2108450	16.147	## 421	574899	2108600	16.686
## 365	574699	2108400	16.396	## 422	574899	2108550	16.534
## 366	574699	2108350	16.479	## 423	574899	2108500	16.139



Carretera Querétaro-Galindo km 12+000
CP 76700, Sanfandila
Pedro Escobedo, Querétaro, México
Tel +52 (442) 216 9777 ext. 2610
Fax +52 (442) 216 9671

publicaciones@imt.mx

<http://www.imt.mx/>