

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN
FACULTAD DE INGENIERÍA MECÁNICA Y ELÉCTRICA
SUBDIRECCIÓN DE ESTUDIOS DE POSGRADO




**“ANÁLISIS Y PREDICCIÓN DE ACCIDENTES AUTOMOVILÍSTICOS
MEDIANTE LA APLICACIÓN DE LA RED NEURONAL ARTIFICIAL DE
MÁXIMA SENSIBILIDAD Y UN PROTOTIPO DE SISTEMA WEB PARA LA
VISUALIZACIÓN DE LA INFORMACIÓN”**

Por:
ERIKA ELIZABETH CONTRERAS SOSA

EN OPCIÓN AL GRADO DE:
**DOCTORADO EN INGENIERÍA CON ORIENTACIÓN EN TECNOLOGÍAS DE
LA INFORMACIÓN**

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN
FACULTAD DE INGENIERÍA MECÁNICA Y ELÉCTRICA
SUBDIRECCIÓN DE ESTUDIOS DE POSGRADO



**“ANÁLISIS Y PREDICCIÓN DE ACCIDENTES AUTOMOVILÍSTICOS
MEDIANTE LA APLICACIÓN DE LA RED NEURONAL ARTIFICIAL DE
MÁXIMA SENSIBILIDAD Y UN PROTOTIPO DE SISTEMA WEB PARA LA
VISUALIZACIÓN DE LA INFORMACIÓN”**


Por:
ERIKA ELIZABETH CONTRERAS SOSA

EN OPCIÓN AL GRADO DE:
**DOCTORADO EN INGENIERÍA CON ORIENTACIÓN EN TECNOLOGÍAS DE
LA INFORMACIÓN**


UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN
FACULTAD DE INGENIERÍA MECÁNICA Y ELÉCTRICA
SUBDIRECCIÓN DE ESTUDIOS DE POSGRADO

Los miembros del Comité de Tesis recomendamos que la Tesis "Análisis y Predicción de Accidentes Automovilísticos mediante la aplicación de la Red Neuronal Artificial de Máxima Sensibilidad y un Prototipo de Sistema Web para la Visualización de la Información" realizada por el alumno(a) M.I. Erika Elizabeth Contreras Sosa, con número de matrícula 1107779, sea aceptada para su defensa como opción al grado de Doctorado en Ingeniería con orientación en Tecnologías de la Información.


El Comité de Tesis




Dr. Francisco Torres Guerrero
Asesor



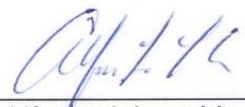
Dr. Luis Martín Torres Treviño
Revisor



Dra. Leticia A. Neira Tovar
Revisor




Dra. María Teresa Pérez Morales
Revisor



Dr. Alfonso López Lira Arjona
Revisor

Vo. Bo.



Dr. Simón Martínez Martínez
Subdirector de Estudios de Posgrado



San Nicolás de los Garza, Nuevo León, agosto 2019

Agradecimientos

Gracias a Dios y a toda mi familia, en especial a mis padres Antonio y Silvia, por su apoyo incondicional durante la realización de este proyecto.

De manera especial agradezco a mi asesor Dr. Francisco Torres por su supervisión y contribuciones en el desarrollo de esta tesis, al Dr. Luis Martin Torres Treviño por su asesoría y atención especial al tema de investigación, así como a mis revisores, Dra. Leticia Amalia Neira Tovar, Dra. María Teresa Pérez Morales y Dr. Alfonso López Lira Arjona, por el tiempo dedicado y sus comentarios para mejorar esta tesis. Agradezco a mis profesores de doctorado por sus significativos conocimientos y experiencias compartidas.

A la Facultad de Ingeniería Mecánica y Eléctrica de la Universidad Autónoma de Nuevo León, y a todas las personas que he conocido en nuestra institución durante este tiempo: amigos, compañeros y alumnos, que de diversas maneras me motivaron para concluir este grado.

Dedicatoria

*A mis sobrinas Fatima Liliana y Angela Elizabeth,
y a mi ahijado Derek Damian,
quienes son mi constante inspiración.*

Contenido

CAPÍTULO 1 INTRODUCCIÓN.....	7
1.1 Fundamentos.....	7
1.2 Planteamiento del problema.....	8
1.2.1 Problemática Nacional.....	8
1.2.2 Problemática Estatal.....	9
1.3 Motivación	10
1.4 Preguntas de Investigación	10
1.5 Objetivos.....	11
1.5.1 Objetivo General.....	11
1.5.2 Objetivos Específicos	11
1.6 Hipótesis	12
1.7 Justificación.....	13
1.7.1 Relevancia del trabajo	13
1.7.2 Aporte a la sociedad	13
1.7.3 Elección del modelo.....	13
CAPÍTULO 2 MARCO TEÓRICO.....	15
2.1 Computación neuronal	15
2.1.1 Red neuronal biológica.....	15
2.1.2 Inteligencia artificial y redes neuronales artificiales.....	16
2.2 Arquitectura de una RNA	17
2.2.1 Introducción.....	17
2.2.2 Funciones de transferencia	19
2.2.3 Elementos.....	21
2.3 Procesos de aprendizaje.....	22
2.3.1 Aprendizaje supervisado.....	23
2.3.2 Aprendizaje no supervisado	24
2.3.3 Patrones de entrenamiento	24
2.4 Aplicaciones de las RNA.....	24
2.5 Algunos tipos de arquitecturas.....	25
2.5.1 Perceptron Simple (PS).....	25
2.5.2 Perceptron Multicapa (PM)	26
2.5.3 Retro Propagación (RP).....	26

2.5.4	Contra Propagación (CP).....	27
2.5.5	Máxima Sensibilidad (MS)	29
2.6	Modelos predictivos	29
2.6.1	Modelos de RNA contra modelos convenciones.....	29
2.6.2	Uso de modelos de RNA en la predicción.....	30
2.7	Red Neuronal de Máxima Sensibilidad (RNMS).	31
2.7.1	Características del algoritmo RNMS	31
2.7.2	Arquitectura de la red RNMS.....	31
2.7.3	Fases de la RNMS	32
2.8	Visualización de la Información.....	39
2.8.1	Técnicas de Visualización.....	39
2.8.2	Prototipo para la visualización de la información	41
2.8.3	Pruebas de usabilidad	41
CAPÍTULO 3 ESTADO DEL ARTE.....		42
3.1	Patentes.....	42
3.1.1	Implementación física sobre el automóvil.....	42
3.1.2	Sistema de sensores	46
3.1.3	Software.....	48
3.2	Investigaciones.....	50
3.2.1	Análisis de tráfico automovilístico	50
3.2.2	Análisis por variables presentes en problemas de tráfico.....	50
3.2.3	Métodos de IA para predicción de accidentes automovilísticos y tráfico .	51
3.3	Productos comerciales	54
3.3.1	Simulación de accidentes automovilísticos.....	54
3.3.2	Análisis del tráfico	57
3.3.3	Prevención de accidentes automovilísticos	58
CAPÍTULO 4 METODOLOGÍA.....		60
4.1	Tipo de diseño	60
4.2	Muestra o participantes	60
4.3	Fuentes de información.....	60
4.4	Variables.....	61
4.4.1	Variables dependientes.....	61
4.4.2	Variables independientes.....	61

4.5	Instrumentos	66
4.6	Arquitectura propuesta para el modelo.....	66
4.6.1	Arquitectura	66
4.6.2	Factor de Máxima Sensibilidad	67
4.6.3	Capa de entradas.....	67
4.6.4	Capa de Salidas	68
4.7	Implementación de la RNMS en un Sistema Web.....	69
4.8	Metodología para la realización del modelo predictivo en el prototipo de sistema web	70
4.8.1	Preparación de Datos	71
4.8.2	Análisis y Predicción	71
4.8.3	Visualización de Resultados.....	72
4.8.4	Re-alimentación de Datos.....	73
4.9	Limitaciones	74
4.9.1	Limitaciones espaciales	74
4.9.2	Limitaciones temporales.....	74
CAPÍTULO 5 DESARROLLO DEL EXPERIMENTO		75
5.1	Caso de estudio: Accidentes Automovilísticos en Monterrey y su Área Metropolitana, Nuevo León, México.....	75
5.1.1	Descripción de la zona de estudio.....	75
5.1.2	Zonas elegidas para realizar el análisis y predicción	77
5.2	Obtención de valores estadísticos.....	77
5.3	Diseño de los experimentos con RNMS.....	78
5.4	Nomenclatura de las variables	79
5.5	Preparación de patrones de entrada para ejecución de RN	79
5.5.1	Diagrama de patrones de entrada.....	79
5.5.2	Clave de identificación de patrones de entrada	81
5.6	Prototipo del sistema web para ejecución de la RN y visualización de los datos generados por IA.....	82
5.6.1	Funcionalidad.....	83
5.6.2	Prototipo inicial	84
5.6.3	Cuestionario de prueba de usabilidad	87
CAPÍTULO 6 RESULTADOS.....		91
6.1	Estadística descriptiva de los accidentes automovilísticos en Nuevo León	91

6.1.1	Gráficas comportamiento individual de las variables	91
6.1.2	Resultados de estadística descriptiva.....	105
6.1.3	Resultados del comportamiento por pares de variables	106
6.2	Resultados del Experimento 1	128
6.2.1	Gráficas de resultados.....	128
6.2.2	Evaluación de la eficiencia de predicción.....	140
6.3	Resultados del Experimento 2	141
6.3.1	Gráficas de resultados.....	141
6.3.2	Evaluación de la eficiencia de predicción.....	149
6.4	Resumen de los resultados de los experimentos 1 y 2.....	150
6.5	Prototipo del sistema web para ejecución de la RN y visualización de información.....	153
6.5.1	Pruebas de usabilidad del prototipo inicial	153
6.5.2	Visualización	155
6.5.3	Pruebas de usabilidad del prototipo final.....	161
CAPÍTULO 7 CONCLUSIONES.....		164
REFERENCIAS.....		168
ANEXOS		182

Resumen

Con la motivación de generar información, que permita mejorar la toma de decisiones sobre la prevención de accidentes automovilísticos y dado que, según las estadísticas de INEGI, es Nuevo León quien en los últimos años se mantiene entre los Estados donde se concentran la mayor cantidad de accidentes, se realizó este trabajo de investigación. Con el uso de información histórica de Monterrey, Nuevo León y su área metropolitana, y mediante la aplicación de técnicas de Inteligencia Artificial (IA) con la implementación Redes Neuronales Artificiales (RNA), en específico con el modelo de Red Neuronal de Máxima Sensibilidad (RNMS) se realizó el análisis y predicción de accidentes automovilísticos. La información resultante de la aplicación de IA requiere de cierta experiencia para su interpretación, por lo tanto, se diseñó un prototipo de sistema web, que facilite la interacción del usuario con los datos históricos, y principalmente con los datos resultantes de la predicción.

Se utilizan dos bases de datos abiertos: la de INEGI para accidentes terrestres y de Axa Seguro para accidentes viales, con las que se logró recabar información sobre el total de accidentes automovilísticos ocurridos bajo factores específicos en lugares, fechas, climas, horarios, causa del accidente y tipo de accidentes.

La RNMS es un modelo de red auto-organizada que utiliza mecanismos de aprendizaje en línea, por lo cual se puede ejecutar en cualquier momento. De los datos históricos con que es alimentada la RNMS, el 80% de la información se usa en la fase de aprendizaje de la red, mientras el 20% restante se usa en la fase de pruebas.

La metodología sugerida para la predicción de accidentes automovilismos es:

1. Preparación de Datos

2. Análisis y Predicción con la ejecución de la RNMS
3. Visualización de Resultados mediante el prototipo de sistema web
4. Re-alimentación de Datos

Del análisis se identificó un efecto de valores atípicos y tendencias no lineales en los valores resultantes de la combinación de las variables Clima, Lugar, Horario, Fecha, Tipo de accidente y Causa del accidente sobre la Cantidad de accidentes automovilísticos ocurridos. Sin embargo, la adaptación de la RNMS permitió el diseño de los patrones de entrada usando las variables mencionadas.

Usando las variables Clima, Lugar, Horario, Fecha, Tipo de accidente y Causa del accidente, con que se alimentó la RNMS, se seleccionaron los valores de salida con mejor resultado, de entre los resultados promedios que se encuentran entre 82% y 99% de efectividad en la predicción de accidentes automovilísticos.

En el prototipo de sistema web se usaron diferentes tipos de graficas que permiten la visualización para llevar acabo el análisis del comportamiento de las variables estudiadas y otras que permiten ver los resultados de la predicción contra los eventos que sucedieron en la misma línea de tiempo. Para la visualización de la proyección de cantidad y posibilidades de los accidentes se recurrió al uso de mapas de calor y con marcadores, acompañados con información detalla del evento en análisis y de los datos históricos relacionados.

CAPÍTULO 1

INTRODUCCIÓN

1.1 Fundamentos

En el presente trabajo se aplica un modelo matemático para obtener la predicción de accidentes automovilísticos, también llamados accidentes de tránsito terrestre. Tomando como caso de estudio las zonas urbanas de Nuevo León: Monterrey y su área metropolitana; mediante el uso de herramientas técnicas de Inteligencia Artificial (IA) como son las Redes Neuronales Artificiales (RNA) y técnicas de reconocimiento de patrones, con el fin de crear conocimiento para los usuarios: autoridades de tránsito, conductores automovilísticos y transeúntes, mediante la visualización de información sobre puntos de la ciudad con mayores posibilidades de sufrir este tipo de accidentes.

La IA propone que las máquinas podrían tener mentes propias, razonar como seres humanos y resolver problemas [1]. Por lo tanto, se puede modelar el conocimiento y aplicarlo en áreas como educación, salud, neurociencias, finanzas, leyes, entrenamiento, biología y gestión de la información [2].

Con la inclusión de variables de tipo cualitativas y cuantitativas, se utilizan diversos modelos de IA emulando el funcionamiento de las redes neuronales de los seres vivos, en el manejo de información [3]. Las áreas de reciente aplicación, van desde predicciones financieras [4] donde se realiza un análisis comparativo buscando el impacto que las variables tienen sobre los fallos financieros; predicciones del comportamiento en el precio del oro [5] y dar referencias al Banco central de Colombia; hasta aplicaciones en la salud, donde se utilizan las

RNA en la predicción de morfología mandibular con variables de importancia morfológica en el campo forense [6].

En [7] se realiza una predicción a través de RNA, de cargas a corto plazo para energía eólica, con intervalos de predicción y una combinación de los métodos: Estimación de Límite Superior Inferior y Optimización de Enjambre de Partículas, para el ajuste de los parámetros, buscando así contar con un modelo que permita la mejor toma de decisión mediante los resultados arrojados por los modelos.

1.2 Planteamiento del problema

1.2.1 Problemática Nacional

En México, el estado que encabeza la lista de con mayor cantidad de accidentes viales, resulta ser Nuevo León. El Consejo Nacional para la Prevención de Accidentes (CONAPRA) por medio del Observatorio Nacional de Lesiones y con la información recabada en los años 2009-2013 a través de bases de datos oficiales del Instituto Nacional de Estadística y Geografía, Policía Federal y Secretaria de Salud, difundió en el año 2015, información detallada sobre accidentes viales a nivel nacional y estatal. Según las estadísticas para accidentes de tránsito terrestre en zonas urbanas y suburbanas, son 6 los estados que concentran el 53% de estos accidentes (Figura 1). La lista es encabezada por Nuevo León con 19%, seguido por Jalisco con 14%, Chihuahua con 7%, Guanajuato con 5%, Baja California con 4% y Distrito Federal con 4%.




Figura 1. Estadísticas INEGI 2013 para accidentes de tráfico terrestre en México

1.2.2 Problemática Estatal

Son 75,005 los accidentes que ocurrieron en Nuevo León en el año 2013, de los cuales 74,112 fueron en zonas urbanas y suburbanas con 647 personas fallecidas y 12,939 heridas a causa de estos accidentes. Más detalladamente la CONAPRA ofrece indicadores y comparativos por estado, en los cuales resulta que el 95% de los accidentes de tránsito terrestre en zonas urbanas y suburbanas de Nuevo León ocurren en la zona metropolitana. Siendo Monterrey con 36%, San Nicolás de los Garza con 13% y San Pedro Garza García con 13%, los municipios con mayores incidencias (Figura 2). Los vehículos con mayor participación en estos accidentes son el automóvil, transporte de pasajeros y transporte de carga ligera.




Figura 2. Estadísticas INEGI 2013 para accidentes de tráfico terrestre en Nuevo León

1.3 Motivación

Son las cifras de este tipo de accidentes las que nos motivan a buscar una solución, donde mediante el uso de técnicas dentro de las Tecnologías de la Información, se ofrezca una visualización de los accidentes automovilísticos que suceden en el día a día y de los que podrían suceder en días futuros, ofreciendo a los automovilistas un conocimiento que le permita prevenir o disminuir estos eventos.

Si bien contamos con variedad de herramientas para la predicción, es la IA quien ofrece herramientas no paramétricas como las RNA para diseñar modelos de predicción y reconocimiento de patrones [8], compitiendo contra modelos de estadística convencional, para los cuales resultan de igual y en algunos casos mejor rendimiento [9] al tratar con información, procesarla y convertirla en un sistema de predicción.

Nos encontramos diversas versiones de RNA [10] con las que podemos trabajar para lograr un modelo de predicción de eventos futuros, gracias a la capacidad que esta herramienta tiene para modelar una relación no lineal especificada entre variables y para el reconocimiento de patrones [11] que determinan los factores presentes en un evento ocurrido.

1.4 Preguntas de Investigación

¿Qué efecto tienen las variables clima, lugar, horario, fecha, tipo de accidente y causa del accidente que permiten proyectar la posibilidad que ocurran accidentes automovilísticos aplicando una RN?

¿Cuál es la efectividad de formar patrones de entrada con las variables clima, lugar, horario, fecha, tipo de accidente y causa del accidente, para el uso

en la RN de Máxima Sensibilidad, que realiza la predicción generalizada sobre la cantidad y posibilidad de que ocurran accidentes automovilísticos?

¿En qué medida se puede degradar el resultado arrojado por la predicción al reducir la zona de análisis a zonas más pequeñas?

¿Con que facilidad los usuarios pueden interpretar la información obtenida mediante la aplicación de IA con el uso de un sistema web?

1.5 Objetivos

1.5.1 Objetivo General

Analizar el efecto de las variables: clima, lugar, horario, fecha, tipo de accidente y causa del accidente, en la formación de patrones de entrada aplicados a un modelo RNA, en diferentes tamaños de zonas de estudio, y presentar de manera visual la información generada, propiciando una fácil interpretación de datos.

1.5.2 Objetivos Específicos

- Identificar el efecto que tienen las variables clima, lugar, horario, fecha, tipo de accidente y causa del accidente como factores determinantes en los accidentes automovilísticos.
- Aplicar un modelo de RNA que permita la predicción de accidentes automovilísticos a través de patrones de entrada contruidos con las variables: clima, lugar, horario, fecha, tipo de accidente y causa del accidente.

- Validar la efectividad de predicción basada en el error cuadrático medio de los resultados obtenidos.
- Estudiar los patrones de predicción en base al agrupamiento por lugar o zona.
- Visualizar con técnicas de representación del conocimiento el análisis y los datos generados por la aplicación de IA.

1.6 Hipótesis

- Las variables clima, lugar, horario, fecha, tipo de accidente y causa del accidente tienen el efecto suficiente para distinguir y construir los patrones de entrada de la RNA.
- Todos los patrones de entrada contruidos con las variables presentadas en el modelo tienen entre 85% y 90% de efectividad en la predicción de accidentes automovilísticos.
- El resultado de predicción de accidentes automovilistas en zonas más pequeñas, como son los cuadrantes, se conservará entre 85% y 90% de efectividad en la predicción.
- Al implementar técnicas de visualización de la información, tales como mapas caloríficos, mapas con marcadores, gráfica, tablas y cuadros informativos, el usuario mejorará su interacción con los datos obtenidos mediante la aplicación de IA.

1.7 Justificación

1.7.1 Relevancia del trabajo

El tema de investigación en este trabajo es relevante para prevención de accidentes automovilísticos usando como muestra del experimento los accidentes ocurridos en el estado de Nuevo León, México. Las estadísticas históricas demuestran que los eventos de tránsito en zonas urbanas y suburbanas del estado se encuentran concentrados en el área metropolitana de Monterrey [12]. Buscando una forma de crear conciencia entre los conductores y transeúntes es a través de la información para que puedan actuar con responsabilidad y precaución al encontrarse en zonas de riesgo.

1.7.2 Aporte a la sociedad

La predicción de accidentes combate el riesgo de pérdidas humanas y materiales, con la predicción podemos prevenir que ocurran estos accidentes, ya sean laborales o viales. Contamos con una extensa lista de técnicas matemáticas que nos pueden ayudar, a través de modelos, a predecir eventos que siguen un patrón [13] o que se generan por la intervención de diversos factores climáticos, geográficos y culturales entre otros.

1.7.3 Elección del modelo

En la literatura estudiada se encontraron diversas investigaciones que hablan de la relación de los accidentes automovilísticos con la distancia en el mapeo de accidentes [11] obtenido mediante algoritmos inteligentes; otros que hablan el impacto de variables climáticas como la lluvia sobre los accidentes automovilísticos en Reino unido [14] mediante radares de clima, sin usar inteligencia artificial. Y se encontró una cantidad significativa de artículos de investigación que hablan de las RNA en el tema de predicción, sin embargo, no

se encontró literatura donde se relacionen en una misma investigación las variables temporales, geográficas y climatológicas con alguna RNA para la predicción de futuros eventos automovilísticos. El nuevo conocimiento que se pretende aportar con la presente investigación corresponde a la predicción de accidentes teniendo los parámetros del clima, lugar y hora en que suceden los accidentes automovilísticos para que por medio de un modelo de Red Neuronal de Máxima Sensibilidad se obtengan datos útiles a los conductores, transeúntes o autoridades correspondientes.

CAPÍTULO 2

MARCO TEÓRICO

2.1 Computación neuronal

2.1.1 Red neuronal biológica

La estructura de las redes neuronales biológicas fue situada en 1911 por Santiago Ramón y Cajál como parte del sistema nervioso del ser humano y estableció que está compuesta por un núcleo, un cuerpo, las dendritas, el axón y otras terminaciones nerviosas (Figura 3). En la actualidad se calcula que el cerebro humano contiene más de 100 mil millones de estas células, interconectadas entre sí de forma paralela, formando la red de neuronas. Son las encargadas de procesar la información y convertirla en aprendizaje mediante la conexión entre una neurona y otra [15].




Figura 3. Modelo básico de una Neurona Biológica

Cada neurona funciona como una unidad de procesamiento, al estar conectadas una con otra, la información que se procesa de manera individual será compartida, haciendo un trabajo en conjunto. Es la conexión entre neuronas, llamada sinapsis, quien definirá la fuerza en la capacidad de procesamiento, esta fuerza es conocida como peso y estos a su vez, se adaptan al aprendizaje y mejoran si siguen un patrón de entrenamiento. La sinapsis se realiza por medio de impulsos eléctricos de corta duración y se logra gracias a las ramas de la neurona también conocidas como dendritas. Las conexiones de una neurona se pueden contar por miles, lo que permite compartir el conocimiento, es que otras neuronas envían los impulsos eléctricos, los cuales son recibidos como una señal de entrada por medio del axón, y si esta señal logra superar cierto umbral la neurona reaccionara enviando un impulso eléctrico como respuesta, a través de cada axón que la conecta con el resto de la red. Algo muy importante a destacar, es que la neurona cuenta con dos tipos de efectos: puede ser excitada y se envíe la señal de salida o inhibida y entonces no se envía la señal [16].

Todas estas redes de neuronas permiten al ser humano ser capaz de procesar la información y realizar el aprendizaje, el reconocimiento de patrones, definir la percepción e interacción del entorno que lo rodea y un control motor del cuerpo, entre otras muchas actividades, resolviendo problemas a gran escala [17]. Es esta habilidad del cerebro la que inspira a convertirlo en un modelo computacional, para que la maquina simule la resolución de problemas complejos tratando de imitar la manera en que lo haría el ser humano.

2.1.2 Inteligencia artificial y redes neuronales artificiales

Inteligencia Artificial (IA) es como se le conoce al área que intenta hacer que las computadoras resuelvan problemas como los seres humanos [18], está relacionada con la teoría de la computación y sus aplicaciones más habituales son el tratamiento de información, reconocimiento de patrones e identificación de sistemas [19].

Las Redes Neuronales Artificiales (RNA) son una rama de la IA que tratan de imitar el comportamiento del cerebro humano, imitando como las personas logramos un aprendizaje por medio de la red de neuronas biológicas. En las RNA, una red está formada por tres tipos de neuronas divididas en capas: las neuronas de entrada, las neuronas ocultas y las neuronas de salida, como podemos ver en la Figura 4. Las neuronas de entrada reciben información del exterior o de otras neuronas donde están almacenados los patrones de aprendizaje, las neuronas ocultas no tienen contacto con el exterior y son las encargadas de procesar la información, por ultimo las neuronas de salida transmiten en resultado de la información tratada [20].




Figura 4. Diagrama de capas de neuronas

2.2 Arquitectura de una RNA

2.2.1 Introducción

En la Figura 5 podemos observar el modelo básico de la arquitectura de una RNA, en la cual se expresa que para tener una salida por parte de la neurona se deben seguir tres etapas: primero la conexión sináptica donde se contiene la entrada y su peso; segundo se realiza la sumatoria de todas las entradas y como última etapa, contar con una función que tenga la capacidad de activar la salida o limitarla [17].




Figura 5. Modelo básico de una neurona artificial

El modelo matemático de la Figura 5 se describe con las siguientes ecuaciones, en la Ecuación 1 se obtiene la activación potencial representada con v_k mediante la sumatoria de cada una de las entradas x_i multiplicadas por su peso w_{ki} correspondiente. En esta misma ecuación se tiene la opción de utilizar un sesgo conocido como umbral o bias b_k el cual puede ser positivo o negativo generando un incremento o decremento en la entrada a la función de activación.

$$v_k = \sum_{i=1}^n w_{ki}x_i + b_k$$

Ecuación 1

La Ecuación 2 describe la salida resultante de la neurona representada por y_k que se obtiene aplicando la función de activación f sobre la activación potencial v_k .

$$y_k = f(v_k)$$

Ecuación 2

Las salidas se normalizan con un intervalo entre 0 y 1 o -1 y 1, donde 1 significa que la neurona se activó. Más adelante en este documento se detalla sobre los diferentes tipos de funciones de activación que existen.

Una vez que se conoció y trabajó con el modelo básico comienzan a surgir diferentes modelos, por ejemplo, los que utilizan una sola capa de neuronas, otros con múltiples capas, modelos adaptativos, recurrentes, con múltiples salidas, de auto-organización, con procesamiento paralelo o lineal. Todas estas variedades de modelos dan origen a las primeras arquitecturas reconocidas como Perceptron, Perceptrón multicapa, Adaline, Retro Propagación, Red ART, Red Hopfield, entre muchas otras. Es entonces que se abre al campo de IA una variada lista de técnicas para aplicar en temas de reconocimiento, categorización, clasificación, análisis de datos, predicción y control [16].

2.2.2 Funciones de transferencia

La función de transferencia o también llamada función de activación, es la encargada de enviar el impulso de salida de una neurona según el problema que se está tratando de resolver, y busca llegar a una salida acotada [17]. Existen diferentes tipos de funciones para estimular la señal de salida, las típicas son: Lineal a tramos, escalón, sigmoidea y gaussiana [15].

Función Lineal a tramos. Es usada en problemas que buscan aproximaciones lineales y se ilustra en la Figura 6, esta función establece un límite, luego se suman las señales de entrada y si esto sobrepasa el límite entonces se genera la estimulación en la neurona. En este tipo de función como se puede observar en la Ecuación 3 la salida corresponde directamente a la entrada.




Figura 6. Función lineal a tramos

$$Y = \begin{cases} -1, & \text{si } v < -1 \\ v, & \text{si } -1 \leq v \leq 1 \\ 1, & \text{si } v > 1 \end{cases}$$

Ecuación 3

Función Escalón. Se usa principalmente para resolver problema de clasificación, con un tipo de activación que genera salidas binarias, es decir 0 o 1, redes como Adaline y el Perceptron utilizan este tipo de función de transferencia que tiene capacidades limitadas y un diseño más sencillo, como se ilustra en la Figura 7. La Ecuación 4 corresponde a esta función de transferencia donde y representa la salida, que será un 1 si la v es mayor o igual que 0 y un 0 si la v es menor que cero.




Figura 7. Función escalón

$$y = H(v)$$

Ecuación 4

Función Sigmoidea. Es un tipo de función continua como se ve en la Figura 8 que define un intervalo de valores, utilizada en redes multicapa y permite que durante el aprendizaje se pueda realizar un ajuste de intervalo propuesto para generar la activación. La Ecuación 5 corresponde a la función de

trasferencia sigmoidea donde y representa la salida de la neurona, el incremento con a y v es la resultante del producto de las entradas con los pesos.




Figura 8. Función sigmoidea

$$y = \frac{1}{1 + e^{(-av)}}$$

Ecuación 5

Función Gaussiana. Es una función (Ecuación 6) de tipo campana como se ilustra en la Figura 9, con características adaptativas y se usa en redes de base radial, generalmente las entradas y los pesos deben estar normalizados, en este tipo de función las capas ocultas pueden ser simplificadas.




Figura 9. Función gaussiana

$$y = Ae^{-Bv^2}$$

Ecuación 6

2.2.3 Elementos

Capas de entrada. Las entradas a la neurona, son representadas comúnmente con una x , desde x_1 hasta x_n . Puede ser que una arquitectura de red tenga entradas simples o múltiples. La capa de entrada está compuesta por

el grupo de entradas provenientes del entorno, es el elemento que recibe la señal desde las variables del sistema o sensores [21].

Los pesos sinápticos son los encargados de modular las señales de entrada. Los pesos iniciales se calculan de manera aleatoria, después se realiza el aprendizaje y se mide el error, entonces algunos tipos de redes regresan a modificar los pesos [22].

Las capas ocultas, están también formadas por grupos de entradas, sin embargo, este tipo de capas no tienen conexión directa con el entorno, son encargadas de realizar el procesamiento de las capas de entrada [21].

Las capas de salida, son el grupo de salidas generadas por la red neuronal. Es la última etapa de la red, aquí se mide si el objetivo fue encontrado, es decir si la red logro la resolución del problema planteado. Según la salida esperada, se debe plantear el tipo de función de activación a utilizar [16].

2.3 Procesos de aprendizaje

El proceso de aprendizaje en la IA, según Haugeland (1988) “debe empezar por tratar de entender el conocimiento (y la destreza y todo lo que se puede adquirir) y después, sobre esa base, abordar el aprendizaje”.

Las RNA están basadas en los modelos biológicos de aprendizaje del ser humano traducido a un modelo matemático, donde las redes neuronales son interconectadas masivamente para interactuar entre sí [23].

Las redes deben ser entrenadas para realizar una tarea determinada, por medio de un ajuste en los pesos y el umbral que se desea alcanzar para activar la neurona. Este proceso de aprendizaje debe seguir unas reglas establecidas por el algoritmo en uso y en base a un conjunto de vectores o patrones de entrada,

puede tener o no los patrones de salida esperados, esto último determinara el tipo de aprendizaje de la red [16].

Al igual que las neuronas biológicas, las neuronas artificiales deben recorrer un proceso de aprendizaje mediante un modelado de sinapsis a lo que se le conoce como establecer pesos, el cual puede ser de dos formas: *off-line* y *on-line*. En las redes *off-line* se puede separar el aprendizaje de la ejecución, no así en las redes *on-line* donde la red puede aprender y modificar el aprendizaje al momento de la ejecución [20]. Se conocen dos tipos de aprendizaje como se muestra en la Tabla 1, supervisado y no supervisado.

Tabla 1. Tipos de aprendizaje, adaptado de Flórez & Fernández, pág. 33-36

Supervisado	No supervisado
Aprendizaje por corrección	Aprendizaje hebbiano
Aprendizaje por refuerzo	Aprendizaje competitivo y comparativo
Aprendizaje estocástico	

2.3.1 Aprendizaje supervisado

En el aprendizaje supervisado, el entrenamiento es controlado, ya que se cuenta con una salida en particular, en caso de obtener una salida diferente, se realiza un ajuste hasta acercarse lo más posible a esa salida deseada. Dentro de este tipo de aprendizaje se encuentra el aprendizaje por corrección donde los pesos son ajustados de acuerdo a la diferencia entre la salida deseada y la resultante; aprendizaje por refuerzo, limitándose a indicar si la salida fue correcta o no; y el aprendizaje estocástico, donde los pesos se reajustan de manera aleatoria. La mayoría de las RNA utilizan este tipo de aprendizaje [20].

2.3.2 Aprendizaje no supervisado

Por otra parte, el aprendizaje no supervisado no tiene un control sobre la salida resultante, en este caso las salidas representan las características de las entradas. Dentro del aprendizaje no supervisado encontramos el aprendizaje hebbiano, que trata de identificar la conexión más fuerte entre neuronas, mientras que el aprendizaje competitivo y comparativo, como su nombre lo dice, las neuronas compiten entre sí por encontrar el máximo valor de respuesta. [20].

2.3.3 Patrones de entrenamiento

El patrón de entrenamiento corresponde a la etapa cuando la RNA se encuentra aprendiendo y es útil para establecer los pesos iniciales, genera parámetros que serán utilizados por la red. Los patrones de entrenamiento son vectores compuestos por las variables que forman la entrada del sistema [21].

2.4 Aplicaciones de las RNA

Existen una gran cantidad de RNA, más de 50 y cada red tiene características sobresalientes o mejoras inspiradas en redes antecesoras [24], sus aplicaciones más comunes son:

- Procesamiento de señales
- Sistemas de decisión
- Problemas complejos
- Predicciones
- Reconocimiento de texto escrito a mano
- Visión
- Lenguaje natural
- Control en tiempo real
- Clasificación de patrones

2.5 Algunos tipos de arquitecturas

2.5.1 Perceptron Simple (PS)

El Perceptron Simple (PS) es una de las RNA más antiguas, diseñada por Rosenblatt en 1958 para la identificación y reconocimiento de patrones, una de las debilidades de esta red es que no puede clasificar clases no separables linealmente. El funcionamiento del PS se muestra en la Figura 10 y su modelo corresponde a la Ecuación 1 que se ve previamente.




Figura 10. Organización del Perceptrón, adaptado de Rosenblatt (1958), pág. 389

Este tipo de RN usa la función de activación conocida como escalón y las capas de entrada se limitan a enviar información a las neuronas de salida sin realizar computo, con señales binarias (0, 1) la neurona responderá con 0 si el elemento no corresponde a la clasificación y con un 1 si sí corresponde, por lo tanto se utiliza para discriminar solo entre dos clases [21].

A pesar de ser una arquitectura muy sencilla, el PS tiene la capacidad de resolver problemas complejos, como en el reconocimiento de escrita que fue hecha a mano sobre una hoja de papel, con las reglas de aprendizaje apropiadas se puede descomponer el problema en partes menos complejas [25].

2.5.2 Perceptron Multicapa (PM)

En cambio, el Perceptrón Multicapa (PM) son utilizados contra modelos de regresión logística y análisis discriminante en concreto para las tareas de clasificación definiendo así a las RNA como técnicas no paramétricas al no cumplir con los supuestos teóricos de los modelos convencionales [8].

La Ecuación 7 explica la salida que le PM, donde las j salidas de las k capas están representadas por y_{jk} y el bias por β_{jk} , los pesos w_{ijk} se seleccionan al inicio del entrenamiento de manera aleatoria y en f_k puede implementar la función de transferencia que considere adecuada, puede ser sigmoidea, gaussiana u otra [26].

$$y_{jk} = f_k \left(\sum_{i=1}^{n_{k-1}} w_{ijk} y_{i(k-1)} + \beta_{jk} \right)$$

Ecuación 7

A la fecha el PM sigue siendo una técnica muy utilizada en problemas de clasificación, dado que la estructura de red puede ser combinada con diversos algoritmos de entrenamiento que dan dinamismo a la selección de pesos y mejoran significativamente el rendimiento de este clasificador [27].

2.5.3 Retro Propagación (RP)

La Red Neuronal de Retro Propagación (RNRP) es diseñada por Rumelhart en 1985, como una solución a las limitaciones del PM. El algoritmo RP es utilizado para el entrenamiento de la RN multidisciplinaria de tipo multicapa con conexiones hacia adelante, mediante un método de aprendizaje supervisado. Lo más sobresaliente del algoritmo es que al generar un resultado de salida, este se compara con la salida deseada, lo cual origina un error de gradiente cuadrático

mismo que será utilizado para reajustar los pesos del aprendizaje y lograr una mejor clasificación de la información como se puede observar en la Figura 11.

El algoritmo de RP se volvió muy popular debido a realiza una minimización global del costo funcional cual generalización del algoritmo adaptativo de mínimos cuadrados medios, con la diferencia que el algoritmo de RP trabaja con la estructura del PM y por incluir el estudio del error para la corrección de los pesos [28].




Figura 11: Arquitectura básica de RNCP

Prácticamente este algoritmo inicializa los pesos y el bias en 0 y para cada patrón de entrenamiento calcula las señales de error, con lo que calcula un incremento total para todos los patrones, que actúan sobre los pesos. El procedimiento se realiza de manera iterativa hasta conseguir el objetivo satisfactorio [29].

2.5.4 Contra Propagación (CP)

La Red Neuronal Contra Propagación (RNCP) es diseñada por Hecht-Nielsen en 1987 para la clasificación adaptativa de patrones entre sus capas ocultas y de salida, resultante de la combinación entre redes de tipo Kohonen y Grossberg. Al dar un patrón de entrada, las capas de neuronas ocultas compiten

entre sí y solo una neurona será la ganadora. Una vez seleccionada la neurona ganadora, se realiza un ajuste de pesos de esta neurona, mientras el modelo continua reajustando los pesos hasta obtener la salida deseada [30].

La esta RNCP se destaca su arquitectura (Figura 12) donde capas ocultas son no supervisadas y las capas de salida son supervisadas por lo tanto el entrenamiento queda dividido entre los dos tipos de aprendizaje, logrando mayor rapidez en su convergencia [31].

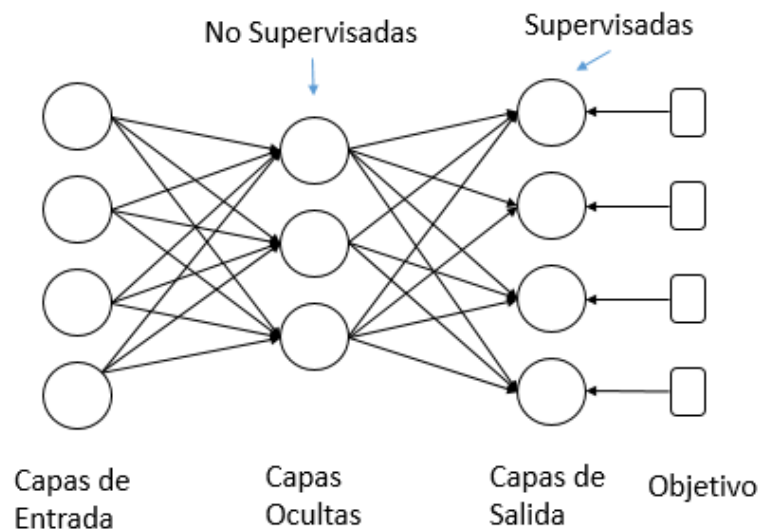


Figura 12. Arquitectura de la RNCP

Dentro de las aplicaciones que podemos realizar con la RNCP se encuentran la de clasificación, predicción y análisis, para problemas complejos a resolver, destacando que pueden usar en tiempo real, mayor capacidad de aprendizaje, construcción y agrupación de la información, este tipo de arquitectura acepta la alimentación con parámetros inusuales sin afectar el rendimiento del modelo [32].

Se aplican también en lugar de algunas técnicas tradicionales para análisis complicados cuando se usan datos incompletos, con ruido o dañados, generando diferentes escenarios para construir los vectores de entrada que darán lugar al

nuevo conjunto de entrenamiento, lo cual se repetirá hasta que se logre la salida deseada [33].

2.5.5 Máxima Sensibilidad (MS)

La Red Neuronal de Máxima Sensibilidad (RNMS) se basa en el diseño de RP y CP, la RNMS busca maximizar las ventajas de estas dos redes. Su capa de entrada consta de múltiples neuronas, mientras la capa oculta sigue una función de activación de tipo gaussiana, y en la capa de salida se selecciona la neurona con mayor ponderación como neurona ganadora. La sensibilidad de la red puede ser ajustada para lograr predicciones de lo general a lo especializado [34]. En la página 31 se explica a detalle esta red.

2.6 Modelos predictivos

2.6.1 Modelos de RNA contra modelos convencionales

“En ingeniería la predicción está encaminada al control, a la optimización y a la seguridad de operación. Las técnicas usadas involucran en la mayoría de los casos modelos formulados como ecuaciones en diferencias.” [35]. Obteniendo modelos que permiten realizar predicciones a corto plazo, mediano y largo plazo.

Las RNA han sido ampliamente comparadas con los modelos estadísticos convencionales donde, aplicándose bajo el mismo ambiente, muestran resultados similares e incluso significativamente superiores, “otra ventaja adicional de las RN sobre los modelos estadísticos que admiten como variables de entrada conjuntos mixtos de variables cuantitativas y cualitativas” [9], entre sus desventajas se encuentra el aumento en costo computacional y recursos involucrados al hacerse el entrenamiento de la red, además de ser cajas negras. Los modelos de cajas negras pueden representar cualquier sistema, estos

modelos no necesariamente aplican leyes y no dan explicación del proceso realizado para obtener un resultado en concreto [35].

Las RNA además de ser buenas en las predicciones, sobre salen de otras técnicas que son más costosas o difíciles para quienes desean implementarlas, aplicar redes y algoritmos para calcular la presión real de vapor de agua, a través de datos meteorológicos de humedad relativa y temperaturas máximas y mínimas para la capa de entrada, considerando combinaciones de estas variables, con cuatro neuronas para la capa oculta y la presión real o actual para la capa de salida, resulta ser más accesible y de bajo costo comparado con métodos convencionales [36].

2.6.2 Uso de modelos de RNA en la predicción

Con la inclusión de RNA se pueden mejorar las técnicas de predicción y realizar automatización de sistemas. Se utilizan factores determinantes según la naturaleza del problema para formar bases de patrones de aprendizaje en el entrenamiento de la red de neuronas, se ajusta una función matemática para el pronóstico de resultados buscando tener el menor error y contar con opciones para la eliminación de variables que puedan causar alguna distorsión a la predicción [10].

Podemos realizar modelos que caractericen y comparen más de un tipo de estas técnicas, en busca del más adecuado. El PM y la Función de Base Radial (FBR) son topologías de RNA, caracterizados por tener una capa de entrada, una capa oculta y una capa de salida, que realizan diagnósticos precisos en ambientes virtuales, para la detección de problemas, en donde el PM se acerca más a los resultados esperados, es más rápida y menos compleja que la RBF [37].

2.7 Red Neuronal de Máxima Sensibilidad (RNMS).

2.7.1 Características del algoritmo RNMS

LA RNMS fue elegida para realizar este estudio por sus propiedades adaptativas a los datos y situaciones generados por suceso de los accidentes automovilísticos. Dentro de las características destacadas de la RNMS [38] encontramos las siguientes:

- Se clasifica como una red auto-organizada.
- Tiene mecanismos de aprendizaje muy simples y no son iterativos, por lo que pueden ser utilizados para el aprendizaje en línea.
- Es la RNA ideal para poder realizar el aprendizaje, entrenamiento y ejecución de la red en cualquier momento.

2.7.2 Arquitectura de la red RNMS

La RNMS sigue la arquitectura como se puede ver en la Figura 13, donde se representa con $x_1, x_2, x_3, \dots, x_n$ como la capa entradas, con w para los pesos sinápticos, c_n es la capa oculta que utiliza la función de activación de tipo Gaussiana, *ac* es la capa donde se activan las neuronas, donde se espera una neurona ganadora, y se genera la salida y [39].




Figura 13: Arquitectura de la RNMS

La RNMS se basa en el principio de máxima sensibilidad donde se carga un patrón con las variables de entrada y todas las neuronas de la red se activan en diferentes grados. Mediante el mecanismo del "ganador toma todo", se establece una neurona ganadora y si su nivel de activación excede la señal de umbral de sensibilidad preestablecida, entonces la neurona de accionamiento asociada se activa y su señal es emitida, de lo contrario, si la neurona no excede el umbral de sensibilidad entonces todas las neuronas aportan sus señales de activación y la capa de neuronas siguiente arroja una salida generalizada [39].

2.7.3 Fases de la RNMS

Las fases que sigue la RNMS son cuatro: Entrenamiento de la red, activación de neuronas, aprendizaje de la red y las pruebas del entrenamiento.

Fase de Entrenamiento. Es la fase donde se crea la estructura de la RN, se asignan la cantidad de neuronas de entrada y de neuronas de salida, y se ejecutan el resto de las fases, como se puede observar en Figura 14. En esta

fase se alimentan los datos históricos que serán utilizados para que la red pueda ejecutar la predicción [39] [34] [38].

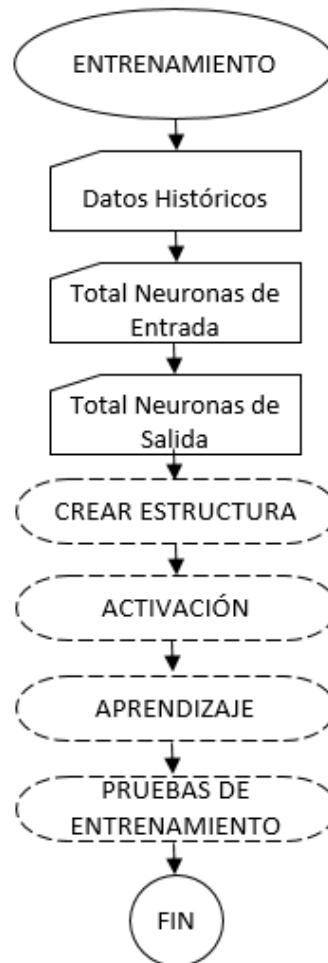


Figura 14. Diagrama fase entrenamiento de RNMS

En la fase de entrenamiento se ejecuta la Ecuación 1, donde se establecen los valores de la cantidad de neuronas ntn que pueden usarse en la RN, el factor de aprendizaje de las neuronas λ en el rango de $[0, 1]$ y umbral o margen de sensibilidad ms en el rango de $[0, 1]$. En esta fase se obtiene el vector con las salidas resultantes y_{nn} , los pesos w finales obtenidos y el error cuadrático medio $error_{nn}$ (Ecuación 9) en relación a la variable $etotal$, que se obtienen en la fase de pruebas (Algoritmo 4) y el número total de patrones $ntPat$. El $error_{nn}$

permite conocer el error promedio del error entre la salida generada por la RN, es decir valor de predicción y el valor de salida esperado o valor real [40] [34].

$$[ynn, errornn, w] \leftarrow \text{TrainNNMS}(ntn, \lambda, ms)$$

Ecuación 8

$$errornn = \sqrt{etotal/ntPat}$$

Ecuación 9

En la estructura de entrenamiento del Algoritmo 1 se crean los vectores que guardaran los pesos w , las neuronas de activación ac , el factor de aprendizaje λ , el cual será el mismo para todas las neuronas, pu es el vector de datos en uso. En esta fase se generan los patrones de entrenamiento, como valor constante la RNMS utiliza el 80% de las entradas (datos) para la fase de entrenamiento y el 20% restante para la fase de pruebas, sin embargo, los porcentajes pueden ser modificados según se requiera, antes de generar los patrones los datos son normalizados en un rango de [0, 1] y mezclados [41] [34].

Algoritmo 1: Crear estructura

Entrada: ntn, nti, nto, l

Salida: w, ac, l, pu

inicio

 inicializar vectores $w[], ac[], l[], pu[]$

 generar datos de entrenamiento

 mezclar datos históricos

 normalizar datos

fin

Algoritmo 1. Fase Entrenamiento - crear estructura de la RNMS

La sensibilidad de predicción de la RN puede ir desde salidas generales hasta especializadas, para esto se asignan los valores en λ y ms . Si se desean

salidas muy especializadas se deben asignar a λ valores muy cercanos a 0 y a ms valores muy cercanos a 1, de lo contrario las salidas son más generalizadas [39] [40] [42].

Fase de Activación. En esta fase se valida si se aplicará el método donde una sola neurona genera la salida o si se usaran varias neuronas para una salida generalizada. Siguiendo el Algoritmo 2, en esta fase se considera la λ y el ms para conocer si la neurona esta activada [43] [40] [39] [34].

Algoritmo 2: Activación

Entrada: vi , ms , l , w , ac , pu

Salida: vector de salidas y la neurona de activación

Inicio

inicializar los vectores $w[]$, $ac[]$, $l[]$, $pu[]$

para cada neurona **hacer**

sumatoria de w

ejecutar $funAct$

fin

si $valMax > ms$ **entonces**

se activa la neurona

si no

se genera ao

fin

fin

Algoritmo 2. Fase Activación de la RNMS

Primero se inicializan los vectores de peso w , activación ac , factor de aprendizaje l y datos en uso pu , después para cada una de las salidas de la neurona sn se obtiene la sumatoria de su los pesos w_k respecto a las entrada x_i con la Ecuación 10, y se obtiene el error err con la Ecuación 11 [43] [40] [39] [34].

$$sn = \sum_{k=1}^n (w_k - x_i)^2$$

Ecuación 10

$$err = \sqrt{\sum_{k=1}^n (w_k - x_i)^2}$$

Ecuación 11

Si $\lambda > 0$ se ejecuta la función de activación, en esta estructura estamos utilizando la función de transferencia Gaussiana (ver Ecuación 6) para establecer el resultado de la neurona, de lo contrario se asigna el resultado como 1, con esto lo que se valida si la neurona logra superar el *ms*, de ser así la neurona se activa en estado de máxima sensibilidad, de lo contrario se genera una salida aproximada *ao* [43] [40] [39] [34].

Adicionalmente en esta fase se puede aplicar el factor de olvido, esto es, de los patrones de entrenamiento generados se usan los últimos y se olvidan los primeros, puede cambiar este factor a que los olvidados sean los primeros o como mejor nos convenga para darle más importancia a los patrones nuevo o a los más antiguos [43] [40] [39] [34].

Fase de Aprendizaje. Una vez que es establecido el estado de activación de las neuronas, se aplica el Algoritmo 3 como aprendizaje de la RNMS, alimentado por los vectores de: pesos *w*, la activación *ac*, datos en uso *pu*, entradas *x*, los valores de *maxSen* y *posMax* obtenidos en la fase de entrenamiento y el vector de salidas esperadas *vdo* [41] [44] [34] [39].

Algoritmo 3: Aprendizaje

Entrada: w , ac, pu, maxSen, posMax, x, vdo

Salida: w, ac, pu

Inicio

si maxSen > 1 **entonces**

para cada valor de entrada **hacer**
 se obtiene el w promedio

fin

para cada valor de salida **hacer**

si ac > 0 **entonces**

 obtener ac promedio

si no

 ac = vdo

fin

fin

si no

 localizar posMin y valMin

para cada valor de entrada **hacer**

 w = x

fin

para cada valor de salida **hacer**

 ac(np) = vdo

fin

fin

fin

Algoritmo 3. Fase de aprendizaje RNMS

Si la máxima sensibilidad está contenida en una neurona $maxSen = 1$, se obtienen los pesos w promedios (Ecuación 12) para cada uno de los valores de entrada. Para cada valor de salida si cuando el vector de neuronas de acción $ac > 0$ se obtiene el promedio de ac (Ecuación 13), si no se cumple la condición $ac > 0$ entonces el vector ac toma los valores del vector vdo [41] [44] [34] [39].

$$w_{posMax,i} = \frac{w_{posMax,i} + x_i}{2}$$

Ecuación 12

$$ac_{posMax,j} = \frac{ac_{posMax,j} + vdo_j}{2}$$

Ecuación 13

En caso de que no se encuentre una sola neurona con el estado de máxima sensibilidad, entonces se crea una nueva neurona o se toma la neurona que tenga menor uso, recorriendo el vector pu buscando los valores de $posMin$ y $valMin$. De ser lo anterior, el vector de pesos w toma los mismos valores de entrada x y la activación ac toma los valores del vector de salidas deseadas vdo [41] [44] [34] [39] [38].

Al igual que la fase anterior, en esta fase puede aplicarse el factor de olvido para manejo los patrones nuevos o antiguos [40].

Fase de Pruebas. Es esta fase, como su nombre lo dice, se realizan las pruebas con el 20% de los datos de entrada y los patrones de entrenamiento, para validar la eficiencia de los resultados obtenidos tras la ejecución de la RN. Como se puede observar en el Algoritmo 4 esta fase genera el vector de salida y_{nn} y el total de error $etotal$ que son llamados en la fase de entrenamiento, y_{nn} para mostrar las salidas resultantes de la RN y $etotal$ para obtener el error cuadrático medio [41] [34] [39] [40].

Algoritmo 4: Pruebas

Entrada: vectores con los patrones de entrenamiento, x y do

Salida: vector de salidas resultantes y $etotal$

Inicio

inicializar vectores x_{nn} , y y y_{nn}

leer el vector de patrones para pruebas

para cada w en $ntPat$ **hacer**

asignar a x las entradas x_{nn}

asignar a do las salidas y

llamar la función de activación

calcular el error $e = do - vo$

$aux = [do \ vo]$

obtener $y_{nn} = [y_{nn}; a]$

calcular el error total $etotal += e * e$

fin

fin

Algoritmo 4. Fase de pruebas de la RNMS

En esta fase se usan los patrones de entrenamiento, las entradas reales y las salidas esperados do , con los w encontrados se crean los nuevos vectores de entrada y salida resultante mediante el uso del algoritmo visto de la fase de activación. Una vez que se tienen con los vectores de salida real vo y salida esperada do , se calcula el error e y el error total $etotal$ [41] [34] [39] [40].

2.8 Visualización de la Información

Mediante la visualización se transmite información de manera sencilla para lograr asimilar gran cantidad de datos y facilitar la toma de decisiones [45]. Por medio de gráficos y mapas, se explora y analiza la información con el fin de comunicar e interpretar los resultados. La visualización permite contar la historia que se encuentra detrás de los eventos ocurridos [46].

Bajo la premisa, de que diferentes tipos de datos requieren de diferentes tipos de visualización, tenemos los siguientes [47]:

- Cuadros informativos
- Tablas
- Gráficos
- Mapas
- Infografías
- Tableros de control

2.8.1 Técnicas de Visualización

De entre las diferentes técnicas para visualización de información nos centraremos en las que competen en este trabajo: gráficas, tablas, cuadros de contenido, mapas con marcadores y mapas caloríficos. Las primeras tres técnicas mencionadas pueden usarse tanto para mostrar información generada

por la estadística y la predicción de eventos, los mapas se usarán solo en la predicción de eventos.

Gráficas. Son la manera visual de entregar grandes cantidades de datos que serán sometidos a estudios, ya que facilitan la comprensión de la información. Existen diferentes tipos de gráficas como las de barras, de líneas, circulares, histogramas, entre otros, según cada tipo grafica es finalidad diferente que va desde comparar entre dos conjuntos de valores, presentar un resumen, que la información tenga más impacto, categorizar y agrupar datos, mostrar tendencias o correlación entre variables [47].

Tablas. Guardan los datos generados y permiten organizar la información de manera tabular, son menos atractivas que las gráficas, sin embargo, proporcionan de una mayor información. Están compuestas por columnas que son el equivalente a las variables de las que se hace el análisis y filas con los resultados de cada variable [46] [47].

Cuadro de contenido. Son herramientas más simples que se enfocan en presentar poca información como fechas o datos numéricos, utilizan colores llamativos que los hagan destacar del resto de los elementos [47].

Mapas con marcador. Las visualizaciones pueden ser agrupadas por categoría, el color de cada punto equivaldrá a una categoría. Pueden manejar y comunicar grandes cantidades de datos, y son utilizados para identificar tendencias, relaciones y puntos atípicos [48].

Mapas caloríficos. En este tipo de visualización la información es del mismo tipo de dato, y permiten la búsqueda de puntos calientes siguiendo un patrón de densidad, separando puntos oscilantes o puntos fríos [49]. El máximo de colores utilizados en un mapa es de 12, sin embargo, la recomendación es el uso de 6 colores [50].

2.8.2 Prototipo para la visualización de la información

El prototipo de sistema web de la visualización de la información es un modelo del diseño para entender el resultado final, que permite una ejecución simulada en las páginas web que lo conforman, con el fin de mostrar el uso y respuesta que tendrá el sistema web resultante. El prototipo puede ser diseñado a mano en una hoja de papel o mediante algún software por computadora, este segundo método permite una simulación más cercana al funcionamiento [51].

2.8.3 Pruebas de usabilidad

Una vez que es diseñado el prototipo, se recomienda ponerlo a prueba mediante alguna técnica de usabilidad. En las pruebas de usabilidad se llevan a cabo diversos procedimientos para determinar si el producto es fácil de usar e intuitivo y pueden medir tiempo y exactitud con que se realiza una actividad o respuestas emocionales y capacidad de recuerdo. Una vez que se cuenta con los resultados de las pruebas se obtiene una retroalimentación y posibles mejoras para evitar errores en el prototipo y mejorar la experiencia del usuario. Los tipos de pruebas de usabilidad para prototipos de sistema web más comunes son: Pensar en voz alta, cuestionario de usabilidad, evolución heurística, modelo de co-descubrimiento, entrevistas y seguimiento ocular [52] [53].

CAPÍTULO 3

ESTADO DEL ARTE

3.1 Patentes

En la búsqueda de patentes relacionados con los accidentes automovilísticos, se encontraron y dividieron en tres tipos, aquellas patentes que se dedican a mejorar físicamente los automóviles por medio de implementaciones, otras patentes están enfocadas en sensores que detecten peligro y se encontró una patente que por medio de software trata de solucionar esta problemática.

3.1.1 Implementación física sobre el automóvil

La patente ES2416130T3 [54] se preocupa por capacitar el automóvil con un panel que busca una mayor resistencia a los impactos, el panel se hace con materiales plásticos y de fibra llamado Panel FRP. La finalidad del panel es darle al conductor, el resto de los ocupantes y al peatón, en caso de ser un atropello, una protección más eficaz al momento de una colisión automovilística. Algunas de las partes donde se puede implementar el panel se muestran en la Figura 15. Dado que la estructura del panel se localiza tanto en el interior como en el exterior, a parte de las personas, también se pretende cuidar el automóvil y disminuir las pérdidas materiales.

La patente US4641136 [55] presenta un mecanismo que debe ser instalado al frente y detrás del automóvil, con lo cual se busca la prevención de colisiones automovilísticas. El aparato se instala en las llantas del automóvil

buscando un frenado seguro e incluso la detención total. Parte de la seguridad que ofrece es evitar que al momento de maniobrar se encuentre drásticamente con vehículos en los carriles próximos. La Figura 16 muestra parte de los dibujos que forman parte de esta patente.

Otra técnica aplicada para seguridad de los automóviles, es la que presenta la patente US5098124 [56] sobre un tipo de acolchado en las puertas de los automóviles que busca proteger a los ocupantes en caso de un impacto lateral. El acolchado está compuesto por celdas llenas de aire, con lo cual se genera un flujo que proporciona amortiguación que absorbe el impacto. La técnica puede aplicarse en las puertas de los pasajeros, en los reposacabezas, apoyabrazos, techos y asientos. El dibujo en la Figura 17 es algunos de los que forman parte de la patente.

Enfocándose en el volante la patente WO98/22310 [57] trata de un módulo de control que pone en funcionamiento el claxon y luces del automóvil como se puede observar en la Figura 18, como sistema preventivo de los accidentes de automóviles. El perfeccionamiento se realiza por medio de un de resortes en las secciones de retención que valora la presión ejercida por el conductor sobre las piezas del volante.




Figura 15. "Panel FRP para automóvil". Imágenes tomadas de [54]




Fig. 2

Figura 16. "Security eyes for prevention of car accidents". Imagen tomada de [55]




Figura 17. "Padding to reduce injuries in automobile accidents", tomada de [56]

WO 98/22310

PCT/ES97/00284

2/3




Figura 18. "Perfeccionamientos introducidos en los sistemas preventivos de accidentes en vehículos automóviles". Imagen tomada de [57]

3.1.2 Sistema de sensores

Pensando en los peatones, la patente ES2276302T3 [58] implementa en los automóviles unos sensores para vigilar el recorrido del automóvil con medidores por radar de objetos y ópticos. La Figura 19 muestra el dibujo del diagrama de estos sensores, que al detectar un objeto genera un procesamiento de imagen controlado por un circuito y realiza una reacción electrónica en el vehículo.

ES 2 276 302 T3




Figura 19. “Sistema para protección de peatones para vehículos a motor”. Imagen tomada de [58]

Siguiendo en la prevención de colisiones, la patente US5594413 [59] presenta un método de prevención de colisiones de automóviles mediante el uso de sensores, que igualmente reciben y transmiten señales, donde se procesan

distancias entre un automóvil y otro, como la velocidad en que se dirigen ambos, para generar una alarma al encontrar una corta distancia. La Figura 20 muestra un dibujo con parte del diagrama de esta patente.

Preocupados por los accidentes automovilísticos que ocurren cuando el conductor se duerme al ir manejando, en la patente WO96/22897 [60] se utilizan sensores que buscan reducir esta causa de accidente el cual está constituido por un sensor colocado en el volante como se muestra en la Figura 21, que mantiene cerrado un interruptor mientras el conductor ejerce presión sobre él, y al dejarlo de hacer, el interruptor se abre emitiendo una alarma con luces y sonido para alertar al conductor.




Figura 20. "Car collision prevention apparatus and method using dual processor and automatic sensor switching function". Imagen tomada de [59]




Figura 21. "Sistema automático para evitar accidentes en vehículos automóviles por efecto del sueño en el conductor". Imagen tomada de [60]

3.1.3 Software

En lo referente al software, la patente US 9491420 B2 [61] que mediante el uso de cámaras e Internet, provee a los usuarios información sobre los accidentes, como el lugar donde sucedió, la gravedad y la cantidad de pasajeros. La técnica es grabar audio y video, que además realiza una detección temprana de la posibilidad de que ocurra el accidente, al enfocarse en reconocimiento de imágenes fáciles y aplicarlo en la detección del estado del conductor, por si este se encuentra distraído o con sueño. La información generada se guarda en

Internet y permite conectividad directa con los servicios de asistencia, lo cual puede reducir la demora al evitar la intervención de terceros, cuando el video del accidente es enviado como petición de auxilio. La Figura 22 muestra parte de los diagramas usados en la patente con los procesos desde el reconocimiento facial, la detección del accidente y protección del automóvil, que posteriormente es almacenado usando Internet.

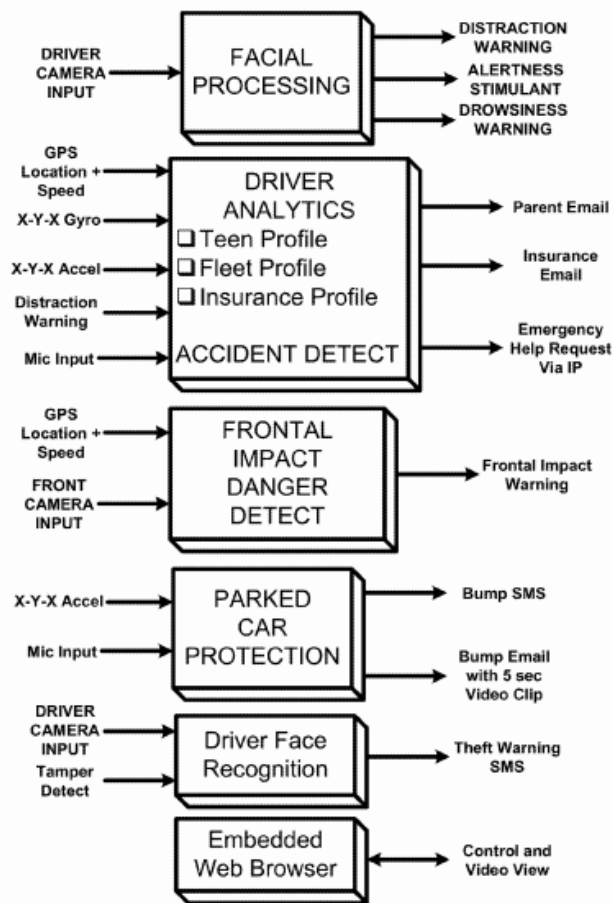


FIG. 13

Figura 22. "Vehicle security with accident notification and embedded driver analytics". Imagen tomada de [61]

3.2 Investigaciones

En esta sección, según la literatura revisada, se realiza el resumen de los trabajos con mayor relación al estudio aquí presentado, categorizados primero en tres grupos: análisis de tráfico automovilísticos, variables presentes en problemas de tráfico y métodos de inteligencia IA para predicción de accidentes automovilísticos; luego de manera grupal cronológicamente según fueron publicados.

3.2.1 Análisis de trafico automovilístico

En el estudio de la gravedad de los accidentes de tránsito se aplican técnicas como los Árboles de Decisión (AD), con este método se generan más de 70 reglas de decisión para identificar problemas de seguridad y establecer medidas de desempeño [62]. Un algoritmo PS es aplicado al reconocimiento de patrones basados en la distancia creando un mapeo de accidentes a nivel de red, es decir la ubicación de los accidentes en los segmentos correctos de la carretera donde ocurrieron, con el objetivo de desarrollar un nuevo algoritmo de mapeo de accidentes [11]. Las Redes Bayesianas (RB) también son empleadas en el análisis de la gravedad de las lesiones en carreteras de alta velocidad valiéndose de datos en tiempo real como la cantidad de tráfico y el clima en autopistas [63].

3.2.2 Análisis por variables presentes en problemas de tráfico

Aplicando técnicas de Minería de Datos (MD) se puede llegar a conocer la relación entre las características de los accidentes causados por conductores mayores, con edades entre los 55 y 75 años, mediante la extracción de información en una colección de datos [64]. Por otro lado, se estudian las circunstancias por las que se aumenta la posibilidad de perder la vida o salir gravemente herido en accidentes automovilísticos, mediante entradas demográficas, factores ambientales, condiciones de la carretera y

comportamiento humano, con modelos de RNA y reducciones binarias que permiten identificar la importancia de los factores relacionados [65].

Otra variable que puede tener impacto en los accidentes automovilísticos es el clima, por lo tanto, conociendo el cambio en las condiciones climáticas, se estudia el impacto que genera sobre el aumento de accidentes de tránsito con modelos de Regresión Lineal (RL) mediante una estimación espacio-temporal [66] y con datos en tiempo real sobre el flujo de tráfico, identificando un efecto combinado entre las variables [67].

3.2.3 Métodos de IA para predicción de accidentes automovilísticos y tráfico

Más detalladamente sobre estudios de predicción, como el que realiza Durduran en [68] donde auxiliándose con un sistema de georreferenciación, de los accidentes ocurridos en las autopistas por vehículos de motor, se toma datos como son el lugar, la humedad, la temperatura y el estado del tiempo, clasificándolos mediante un algoritmo de Máquinas de Vectores de Soporte (MVS) y alimentar una RNA. Otra manera seria, con el uso de controladores difusos desarrollar dos sistemas, uno de advertencia de colisión y otro para evitar la colisión, del cual como salida se emite una alerta en tiempo real a los conductores, sobre la posibilidad de accidentes automovilísticos mediante una señal en el volante del automóvil para evitar la colisión [69].

En otra investigación Jadaan et al. [70] los estudios se centran en la simulación de accidentes de tránsito mediante un modelo de PM para predecir eventos futuros, usando las variables del número de vehículos matriculados, la población, longitud total de los caminos pavimentados y el producto interno bruto como parámetros utilizando el software de Matlab para formación, validación y pruebas de la RNA y mientras que para el análisis estadístico utiliza SPSS.

Ogwueleka et al. en [71] también realizan un estudio y predicción de accidentes de tránsito utilizando RNA, sin embargo ellos se valen de una función Sigmoidea y otra Lineal como funciones de activación para el algoritmo de RP con parámetros como el número de vehículos, número de accidentes y población.

Un estudio más reciente realizado por Yasin et al. en [72] presenta un modelo de RNA para la predicción de accidentes en autopistas en Turquía, en base a un conjunto de datos históricos de 8 años y teniendo como variables los tramos de la carretera, la longitud del tramo medido en kilómetros, el tráfico diario, los grados de las curvas de la autopista, el porcentaje de accidentes de vehículos pesados y el porcentaje de accidentes ocurridos en el verano, donde el modelo la RNA sigue las reglas del algoritmo Levenberg-Marquardt.

Schimbinschi et al. en [73] pensando que a futuro los automóviles autónomos comenzaran a invadir las zonas urbanas, generando con esto nuevos requerimientos en el estudio del tráfico vehicular, proponen el algoritmo de Autoregresión Vectorial TRU-VAR para la realización de un Sistema Experto (SE) que genere pronósticos de tráfico en grandes áreas urbanas, comparando resultados de su algoritmo contra herramientas como ARIMA.

La Tabla 2 es una comparativa, entre el enfoque de estudio y las variables usadas dentro del análisis de los accidentes automovilísticos. En la primera columna se marca con una “x” si se realiza predicción en el estudio o solo análisis; la segunda muestra las variables relacionadas con el accidente automovilístico, por ejemplo: tipo, causa, gravedad, edad del conductor, entre otras variables como se puede observar en la tabla, y en la tercera columna el lugar de donde se realiza el estudio, no necesariamente de donde son originarios los autores, si no de donde se extrajo el conjunto de datos.

Tabla 2. Comparativa de estudios de Accidentes Automovilísticos

Modelo	Predicción de accidentes	Variables destacadas	Lugar estudiado
AD		Severidad del accidente, edad del conductor, velocidad del vehículo	Granada, España
PS		Nombre de la carretera, dirección de movimiento del vehículo, lugar del accidente	Reino Unido
RB		Gravedad de las lesiones, tráfico y clima	Colorado y Orlando, Estados Unidos
RL		Cambio climático, datos del conductor, antigüedad del automóvil	Canadá
Controles difusos	x	Condiciones del tráfico y datos del vehículo extraídos de un sensor	Madrid, España
MVS y RNA	x	Día, temperatura, humedad y mes	Turquía
PM	x	Número de vehículos matriculados, la población, longitud total de los caminos pavimentados y el producto interno bruto	Jordania
RP	x	Número de vehículos, número de accidentes y población	Estados Unidos
RNA con algoritmo Levenberg-Marquardt	x	Historial de 8 años, tramos de la carretera, longitud del tramo, tráfico diario, curvas de la autopista y porcentajes de accidentes	Turquía
SE	x	Volumen de tráfico, datos obtenidos de sensores en el automóvil	Melbourne, Australia California, Estados Unidos

3.3 Productos comerciales

En una revisión realizada principalmente en páginas web sobre productos relacionados con los accidentes automovilísticos, se encontraron en su mayoría simulaciones de accidentes ocurridos, otros más enfocados en el análisis de tránsito y una minoría dedicados a la prevención de accidentes automovilísticos.

3.3.1 Simulación de accidentes automovilísticos

En la revisión sobre productos de software interesados de alguna manera en los accidentes automovilísticos, se encuentran muchos productos interesados en la reconstrucción y simulación de los accidentes, que incluso son usados por las autoridades de tránsito, agencias de seguros y agencias de automóviles para recrear los eventos sucedidos y generar información para asuntos legales, de forenses y de seguridad.

Un ejemplo de este software es “Virtual CRASH” dedicado a la reconstrucción de accidentes automovilísticos por medio de animación, tanto de los vehículos como de las personas involucradas. El producto crea la animación usando leyes de física y software de diseño computacional logrando ayuda visual realista, como se puede ver en la Figura 23, esto mediante la construcción de objetos y terrenos tridimensionales que provienen de mediciones y fotografías de las escenas donde ocurrieron los eventos [74]. En su sitio web <https://www.vcrashusa.com/> ofrecen citas para hacer demostraciones y tienen sus oficinas físicas en Newberry, Florida.

Otro software similar es “AccidentSketch”, el cual recrea los accidentes automovilísticos por medios de bocetos y ofrece una interface de usuario muy sencilla que lo hace muy accesible, aunque la visualización es menos realista (Figura 24) y se basa en objetos predefinidos que el usuario puede utilizar para

el armado de la simulación, como son los vehículos, carreteras y señales de tráfico, simplemente se tiene que arrastrar los objetos hacia el área de dibujo, luego puede personalizarlos y se puede complementar el boceto con líneas, flechas, cuadros y textos. Además, que permite el almacenamiento de fotografías, documentos e informes para complementar el archivo digital a manera que cumpla con los requerimientos solicitados por los tribunales o las agencias de seguros que así lo soliciten [75].



Figura 23. Imagen tomada de <https://www.vcrashusa.com/vc4> en enero 2018



Figura 24. Imagen tomada de <http://www.accidentsketch.com/> en enero 2018

Un producto con soporte en lenguaje español para la reconstrucción analítico de colisiones de tránsito terrestre es “RACTT” que ofrece el análisis de la ocurrencia de accidentes que facilite la creación de los reportes periciales mediante el desarrollo de cálculos de velocidad, posición y tiempo con hasta dos incertidumbres. Ofrece una interface de usuario enfocada en menús donde se va capturando la información y el software ofrece ecuaciones para los cálculos de las matemáticas, cinemática, centro de masa, trabajo y energía, variación de la velocidad y otros datos del accidente y dibujos ilustrativos como se puede ver en la Figura 25 y la Figura 26 [76].

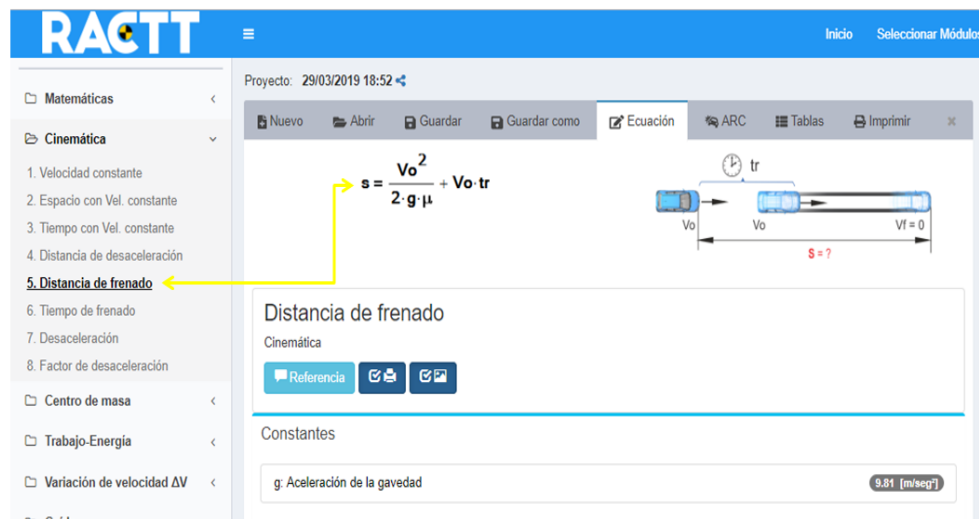


Figura 25. Imagen tomada de <https://ractt.com> en enero 2018



Figura 26. Imagen tomada de <https://ractt.com> en enero de 2018

3.3.2 Análisis del tráfico

Existen diferentes versiones de software para el estudio de tráfico en las ciudades, entre los cuales destacan dos, pertenecientes a la empresa Google dedicada al desarrollo de diferentes servicios digitales.

Google Maps es una app tanto para sitio web como para teléfonos inteligentes, perteneciente a la compañía Alphabet quien es la principal subsidiaria de Google, que ofrece a sus usuarios imágenes de mapas para navegación, donde pueden consultar puntos de interés como lugares, comercios, transporte público, tiempos de desplazamiento de un lugar a otro, entre otras funciones. El sistema tiene una opción para que desarrolladores de software puedan diseñar mapas para sus propias apps. El usuario de mapa puede fácilmente cambiar entre diferentes tipos de vista como mapa, satélite o relieve. Permite conseguir un detalle del punto analizado, como se ve en la Figura 27, por medio de fotografías que los mismos usuarios suben y por imágenes propias de la app mediante la opción de Street View donde se pueden ver imágenes de las calles, aunque no es en tiempo real [77].

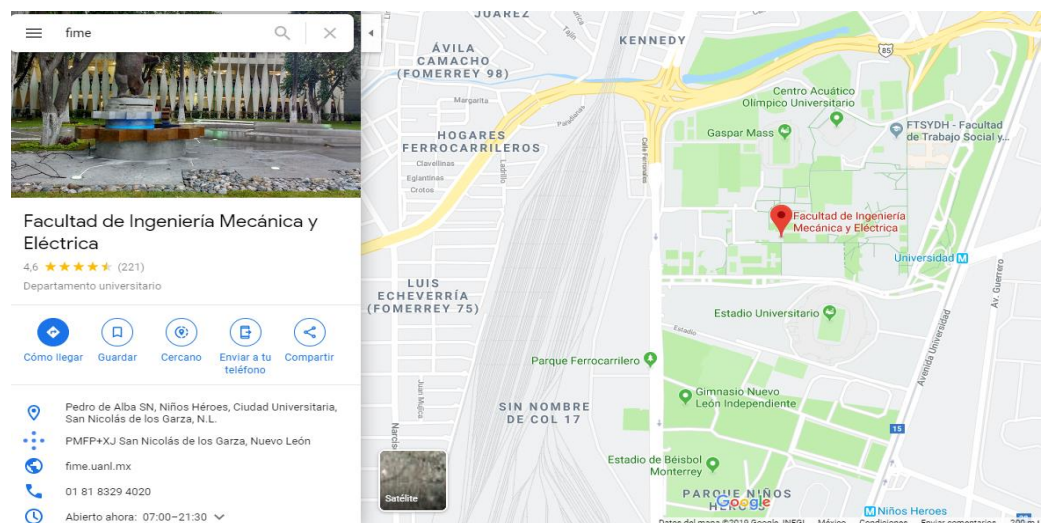


Figura 27. Imagen ejemplo de Google Maps

Waze es una app para teléfonos inteligentes creado en el año 2006 y adquirido por Google en el 2013. La aplicación es una fuente de información para el conductor de automóvil, como se ve en la Figura 28. Muestra detalles sobre el tráfico, ubicación de accidentes sobre el camino que sigues al manejar y otra información como condiciones meteorológicas o cierres de carreteras, que los mismos usuarios van reportando. A su vez funciona como un sensor, que al iniciar la aplicación toma datos de manera automática por medio del GPS del teléfono y lo manda a los servidores de Waze, con lo que el sistema puede calcular el flujo del tráfico y diseños de las vías siguiendo el trayecto de cada usuario [78].

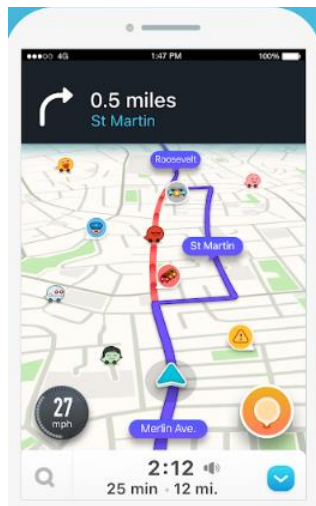


Figura 28. Imagen tomada de <https://play.google.com> en enero 2018

3.3.3 Prevención de accidentes automovilísticos

En cuanto al software para prevención de accidentes fue menor el hallazgo resultante en la búsqueda de productos con este fin, se encontraron notas en sitios web sobre software que utilizan las agencias de tránsito en el país Estados Unidos para la prevención de accidentes automovilísticos, por ejemplo, en el estado Tennessee, sin embargo, no se encontró evidencia sustentable sobre esto.

Por otro lado, se encontró un producto disponible en internet, muy similar al estudio en el presente trabajo. Se trata de “waycare”, software con su interface de usuario en lenguaje inglés (Figura 29) y que ofrece conexión con datos y diversos sensores de los automóviles autónomos como una manera de prevenir accidentes futuros mediante la predicción y el procesamiento de esta información. El usuario debe dar entrada de la información y el modelo de IA que utiliza el software hace todo el trabajo, decidiendo que es mejor mostrar. Es usado en ciudades de Estados Unidos como Tampa, Nevada, condado de Pinellas y Walnut Creek, y cuenta con socios como las marcas y empresas: Cisco, Mojo, Waze, Geotab y Ticketmaster, entre otros [79].

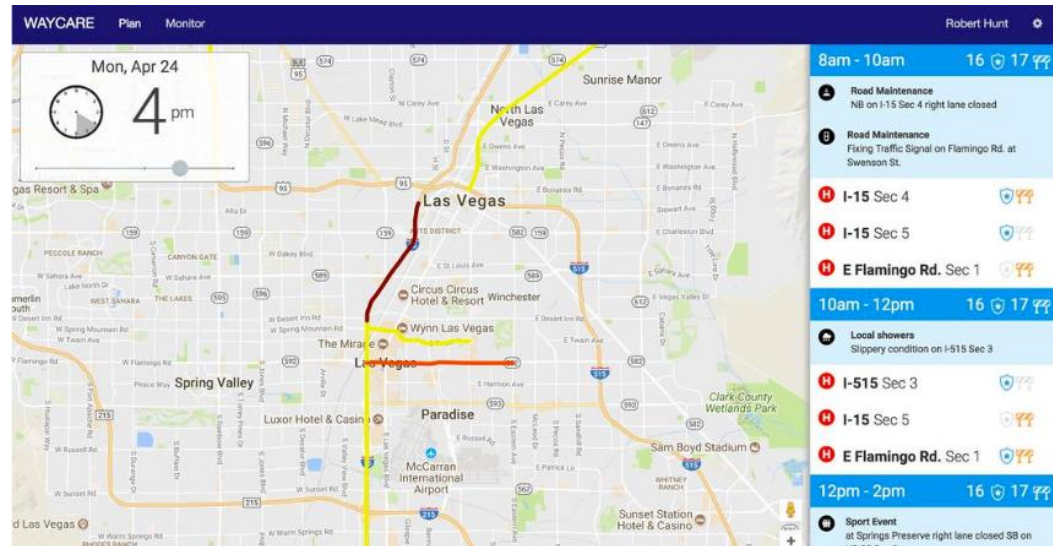


Figura 29. Imagen tomada de <https://www.reviewjournal.com/traffic/las-vegas-uses-artificial-intelligence-to-reduce-i-15-crashes-1531260> en mayo 2019

CAPÍTULO 4

METODOLOGÍA

4.1 Tipo de diseño

La investigación es del corte exploratorio ex postfacto ya que estamos tratando de averiguar, a través de una recopilación de datos históricos, los eventos ocurridos en diferentes fechas y con esto realizar un modelo predictivo de eventos futuros.

4.2 Muestra o participantes

Se utiliza el 100% de los accidentes ocurridos y reportados en el municipio de Monterrey y su área metropolitana, en una línea de tiempo (ver anexo 1). El modelo de predicción por redes neuronales utiliza un 80% de los datos totales para la predicción y el 20% restante para la validación de resultados.

Para el análisis de los resultados del prototipo web para visualización de la información se entrevista a 5 personas en la primer fase y 5 personas en la fase final con conocimientos de tránsito terrestre.

4.3 Fuentes de información

En la realización de este trabajo se consultan dos bases datos públicas, en listadas a continuación:

- ▶ Base de datos 1: Accidentes terrestres en zonas urbanas y suburbanas por INEGI
- ▶ Base de datos 2: Acceso a información de accidentes viales por Axa seguros

4.4 Variables

Se estudian dos variables dependientes: la cantidad de accidentes y la posibilidad de evento, y seis variables independientes: horario, fecha, lugar, clima, tipo de accidente y causa del accidente.

4.4.1 Variables dependientes

- **Cantidad de accidentes.** Es el número de accidentes automovilísticos sucedidos, que se contabiliza de acuerdo a una o varias de las variables independientes. Se obtiene tanto de los datos histórico (lo que ocurrió) como de la ejecución de la RN (lo que ocurrirá). Por ejemplo, la cantidad de accidentes automovilísticos ocurridos en el mes de enero.
- **Posibilidad de evento.** Es probabilidad de que ocurra un accidente en el futuro. Se obtiene con la ejecución de la RN y se mide con los valores de: alta, media y baja.

4.4.2 Variables independientes

A continuación, se describen las variables recopiladas a través de la base de datos 1 y 2, además de las variables que son calculadas como el clima ya que no vienen en la información original.

Base de datos 1. Accidentes terrestres en zonas urbanas y suburbanas por INEGI: se describen las variables que serán usadas en la realización del experimento: Tipo de Accidente, Causa del Accidente, Hora, Día, Mes, Año, Día de la semana.

- **Tipo de accidente.** Es el tipo de accidente de tránsito terrestre (véase la Tabla 3), considerando desde la caída del pasajero, colisiones con diferentes objetos y/o personas, incendios, volcaduras, salidas del camino y otros.
- **Causa accidente.** La causa presunta o determinante (véase Tabla 4) puede considerarse como: El motivo principal que causó el accidente, ya sea por condiciones inseguras o actos irresponsables potencialmente prevenibles, atribuidos a conductores de vehículos, así como a peatones o pasajeros, falla de vehículos, condiciones del camino, circunstancias climatológicas, etc.
- **Hora.** Es la hora en formato de 24 horas en que sucedió el accidente de tránsito terrestre. Incluye minutos y segundos.
- **Día, Mes y Año.** Se usa formato numérico para el día (01-31), mes (01-12) y año (2015-2017) en que sucede el accidente de tránsito terrestre.
- **Día de la semana.** Corresponde al nombre del día de la semana en que sucede el accidente de tránsito terrestre, iniciando con el día domingo y terminando en sábado.
- **Estado y Municipio.** Son las variables que definen el lugar donde sucede el accidente de tránsito terrestre, la base de datos contiene todos los Estado pertenecientes a México con sus respectivos municipios.

Base de datos 2. Acceso a información de accidentes viales por Axa seguros:

- **Causa del siniestro.** Es la causa presunta o determinante, la base de datos 2 maneja diferentes valores para esta variable, por lo que en este caso categorizadas como atropellos, colisiones, fenómenos naturales y otros, ver la Tabla 7
- **Hora, Día, Mes y Año.** Al igual que la base de datos 1, esta base de datos contiene campos con información para la hora en formato 24hrs., día, mes y año en formato numérico, para los accidentes viales sucedidos.
- **Latitud.** Contiene el valor correspondiente al punto de la latitud de la superficie terrestre donde ocurre el accidente vial en formato de coordenada.
- **Longitud.** Contiene el valor correspondiente al punto de la longitud de la superficie terrestre donde ocurre el accidente vial en formato de coordenada.
- **Estado y Municipio.** Son las variables que definen el lugar donde sucede el accidente de tránsito terrestre, la base de datos contiene todos los Estado pertenecientes a México con sus respectivos municipios.

Variables calculadas. Son las variables calculadas por concatenación o extracción de las variables en las bases de datos 1 y 2:

- **Fecha.** La variable fecha será compuesta por la concatenación de las variables día, mes y año ya sea de la base de datos 1 o 2.

- **Horario.** La variable de horario se calcula usando la variable hora, para informar si el evento sucedió en el día, tarde, noche o madrugada. Véase la Tabla 5 con los rangos de horarios.
- **Clima.** Clasificación del conjunto de condiciones atmosféricas calculado al día en que ocurrió el accidente automovilístico y agrupado en cuatro categorías como se muestra en la Tabla 6.
- **Lugar.** Es la ciudad, cuadrante, zona o grupo de calles y/o colonias municipales basándose en los valores de la latitud y longitud del lugar donde sucede el accidente automovilístico.

Tabla 3. Tipos de accidentes

ID	VALOR
1	Caída de pasajero
2	Colisión con animal
3	Colisión con ciclista
4	Colisión con ferrocarril
5	Colisión con motocicleta
6	Colisión con objeto fijo
7	Colisión con peatón (atropellamiento)
8	Colisión con vehículo automotor
9	Incendio
10	Salida del camino
11	Volcadura
12	Otro

Tabla 4. Causas de accidentes

ID	VALOR
1	Conductor
2	Falla del vehículo
3	Mala condición del camino
4	Peatón o pasajero
5	Otra

Tabla 5. Horario

ID	RANGO	VALOR
1	6:00 – 11:59	Día
2	12:00 – 17:59	Tarde
3	18:00 – 23:59	Noche
4	24:00 – 5:59	Madrugada

Tabla 6. Clima

ID	VALOR
1	Despejado
2	Lluvioso
3	Nublado
4	Otros

Tabla 7. Causa del siniestro

ID	VALOR
1	Atropello
2	Colisión y/o vuelco
3	Daños por la carga
4	Fenómenos de la naturaleza
5	Huelgas y alborotos
6	Incendio, rayo o explosión
7	Transportación

4.5 Instrumentos

- La RN diseñada bajo el modelo/algoritmo Máxima Sensibilidad en el software científico Scilab con detección de promedio del error cuadrático entre lo predicho y lo sucedido.
- Cuestionario de usabilidad para el prototipo Web de la visualización de la información generada por estadística convencional y por el modelo de la RNA.

4.6 Arquitectura propuesta para el modelo

4.6.1 Arquitectura

La arquitectura consiste en una red de 6 entradas y 2 salida que corresponde a la cantidad y posibilidad de accidentes de tránsito terrestre que pueden presentarse en las condiciones originadas por la combinación de las variables de entrada como se ve en Figura 30.

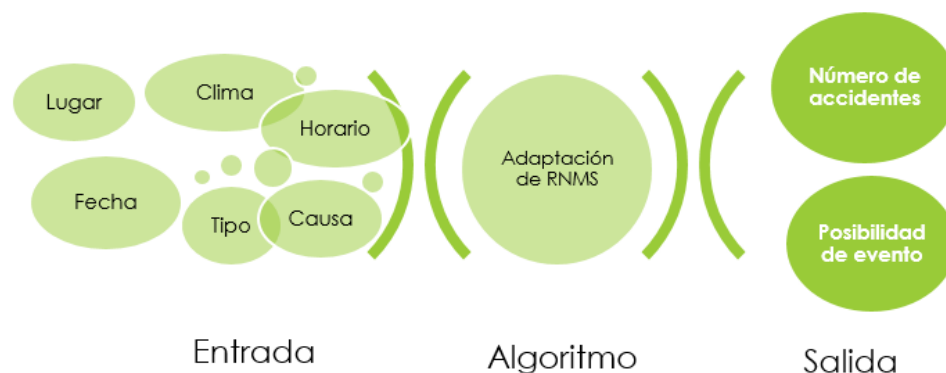


Figura 30. Arquitectura utilizada por el sistema predictivo

El mecanismo de aprendizaje de la red neuronal máxima sensibilidad, le permite a la arquitectura propuesta un aprendizaje muy rápido, por lo que si se tiene información histórica correcta y suficiente se tendrá una buena eficiencia en el desempeño. Es importante destacar que la red tiende a especializarse por lo

que puede modelar el efecto que pueden tener ciertas políticas o leyes sobre la ocurrencia de ciertos accidentes de tránsito terrestre. En otras palabras, la herramienta adquiere una “personalidad” adecuada a las situaciones de la región donde se utiliza o se alimenta la red.

4.6.2 Factor de Máxima Sensibilidad

Dado que en este trabajo se busca alcanzar una salida entre lo general, sin llegar a ser tan especializados, de los valores de predicción de accidentes automovilísticos sobre los datos en las ciudades que se usan de prueba, y en dado momento puedan usarse para datos en otras ciudades, por lo tanto, los valores asignados para determinar la sensibilidad de la RNMS, en todos los experimentos de este documento serán los siguientes:

- Cantidad de neuronas, NTN = 100
- Margen de sensibilidad, $ms = 0.85$
- Factor de aprendizaje, $\lambda = 0.25$

4.6.3 Capa de entradas

Se propone una combinación de las variables disponibles en el modelo para la construcción de patrones de entradas mediante datos con los que se cuenta, y posteriormente analizar los resultados de las diferentes combinaciones como se puede ver en la **Figura 31.**




Figura 31. Ejemplo arquitectura RN con variables propuestas

4.6.4 Capa de Salidas

Las salidas que devuelve la RNMS se presentan en forma de vector y siguen en estado normalizado con rangos de [0, 1], por lo tanto, para obtener las salidas esperadas en el estudio se deben transformar. La Tabla 8 es un ejemplo de un vector de salidas normalizado.

Tabla 8. Vector de Salidas de la RNMS

X1	X2	Y
0	0	0.7940944
0	0.25	0.005256
0	0.5	0.0241798
1	0.5	0.0140348
1	1	0.0025229
1	0.75	0
0.6666667	0	0.5085315
0.6666667	0.25	0.0075174
0.6666667	0.5	0.025544
0.6666667	1	0.0074635
0.6666667	0.75	0.0076198
0.3333333	0	1
0.3333333	0.25	0.0085659
0.3333333	0.5	0.0241774
0.3333333	1	0.0107222
0.3333333	0.75	0.0056737

Para obtener la **cantidad de accidentes automovilísticos** se deben desnormalizar los resultados en el mismo rango de [0,1] en que fueron normalizados con la Ecuación 14, donde *dd* es el dato desnormalizado, *dn* el dato normalizado que deseamos transformar, *LimMax* es el dato más grande de los datos originales y *LimMin* es el dato menor de los datos originales antes de ser normalizados.

$$dd = dn * Lmax + Lmin * (1 - dn)$$

Ecuación 14

Por otro lado, para obtener las **posibilidades de que ocurra un evento**, se deben obtener los valores de media μ y desviación estándar σ con respecto de las últimas predicciones y comparar el dato d de predicción, con la Ecuación 15 resultará la Posibilidad P en: baja b , media m o alta a .

$$P = \begin{cases} b, & \text{si } d < \mu - \sigma \\ m, & \text{si } \mu - \sigma \leq d \leq \mu + \sigma \\ a, & \text{si } d > \mu + \sigma \end{cases}$$

Ecuación 15

4.7 Implementación de la RNMS en un Sistema Web

La predicción con la RNSM sobre accidentes automovilísticos mediante los patrones de entrada compuestos por las variables analizadas en este estudio, tiene una salida para cada uno de los patrones de entrada, resultando n cantidad de vectores cargados de información

En la Tabla 9 con dos entradas x_1 y x_2 , una salida y para la cantidad de accidentes y una salida p para la posibilidad de que ocurran eventos, se muestra información de un solo patrón de entrada y se requiere de cierta de experiencia para interpretarla, por lo tanto, se propone el diseño de un prototipo web que permita una mejor interacción del usuario con los datos generados por la IA.

De tal modo que, el modelo predictivo será ejecutado a través de un prototipo de sistema web propuesto. Facilitando la interacción del usuario, ya sean conductores, personal de tránsito o encargado en la toma de decisiones para la prevención de accidentes. Por medio de las técnicas de visualización como son las gráfica, tablas y mapas, se presentará la información resultante del modelo.

El prototipo de sistema web relacionará la causa del accidente con el lugar, el horario, la fecha y el clima. Este tipo de relaciones funcionales las puede

realizar en tiempo real y es posible incorporar nueva información sin esperar una etapa prolongada de “entrenamiento” o “aprendizaje” del modelo predictivo, por lo que es posible usar la herramienta y cambiar al entrenamiento de manera rápida.

Tabla 9. Ejemplo de Resultado de la Predicción

X₁	X₂	CANTIDAD	POSIBILIDAD
1	1	8092	alta
1	2	66	alta
1	3	261	baja
1	4	73	alta
2	1	9480	baja
2	2	102	media
2	3	241	media
2	4	89	media
3	1	6517	alta
3	2	78	baja
3	3	254	baja
3	4	98	alta
4	1	1918	baja
4	2	34	baja
4	3	135	alta
4	4	16	media

4.8 Metodología para la realización del modelo predictivo en el prototipo de sistema web

En la realización del prototipo de sistema web para la predicción de accidentes automovilísticos por medio del uso de la IA deben seguirse los siguientes pasos:

5. Preparación de Datos
6. Análisis y Predicción
7. Visualización de Resultados
8. Re-alimentación de Datos

4.8.1 Preparación de Datos

Se realiza la preparación de los datos iniciales con que arrancara el sistema predictivo:

Paso 1: Se realiza la creación de cuadrantes mediante el dibujo de los polígonos a mano alzada.

Paso 2: Se carga por primera vez la información del histórico de los accidentes automovilísticos y a cada evento se le asigna el clima y cuadrante según le corresponda.




Figura 32. Diagrama de Preparación de datos

4.8.2 Análisis y Predicción

En esta etapa se ejecuta el análisis estadístico y el modelo de predicción con la RNMS, siguiendo tres pasos y diagrama como la muestra la Figura 33.

Paso 1: Validar cuadrantes, es decir, se verifica cuadrante por cuadrante si cada uno cuenta con datos históricos, de no ser así, el cuadrante será descartado.

Paso 2: Análisis estadístico, por medio de estadística convencional se obtiene información de las variables del modelo predictivo para mostrar estos datos a través de cuadros informativos, gráficas y tablas en el sistema web.

Paso 3: Ejecución del modelo de predicción mediante la selección de las fechas en que se desea realizar la predicción, el lugar (ya sea un cuadrante o todos), y se asignan los patrones de entrada.



Figura 33. Diagrama de análisis y predicción

4.8.3 Visualización de Resultados

Para garantizar el entendimiento de los datos del modelo predictivo por parte de un usuario, se agrega a este trabajo, técnicas de visualización de la información.

Visualización del histórico por medio de cuadros, graficas comparativas entre diferentes series temporales del mismo histórico y tablas. Se usa un mapa con marcadores con la cantidad de eventos ocurridos, categorizados según la causa del accidente automovilístico.

Visualización del análisis estadístico por medio de gráficas para cada una de las variables y otras graficas mediante el conjunto de variables.

Visualización de la IA según los datos arrojados por la ejecución del modelo predictivo con la RNMS por medio de un cuadro informativo del porcentaje de error de la predicción, además de una gráfica comparativa entre los datos de predicción contra los datos que realmente ocurrieron. Un mapa de calor para mostrar la predicción en modo de posibilidad de que ocurra un evento categorizado en alta, media y baja.

4.8.4 Re-alimentación de Datos

Una vez puesto en marcha el prototipo de sistema web, se recomienda una alimentación de los eventos ocurridos de manera semanal según la Figura 34, para darle al modelo predictivo información nueva que pueda utilizar en la futura ejecución de la RNMS. Al igual que cuando se alimentó el histórico por primera vez, las cargas semanales tendrán asignación del cuadrante y clima correspondiente a cada evento, ya que esta información no viene en las bases de datos utilizadas.




Figura 34. Diagrama de re-alimentación de datos

4.9 Limitaciones

4.9.1 Limitaciones espaciales

La presente investigación esta limita espacialmente a los accidentes de tránsito terrestre ocurridos en la zona metropolitana de Monterrey, Nuevo León, México, sin considerar las zonas suburbanas del Estado u otras zonas de México.

4.9.2 Limitaciones temporales

Respecto a las limitaciones temporales, cabe recalcar que la información utilizada corresponde a los años disponibles y más recientes posibles tomados de las bases de datos del INEGI y datos públicos de AXA seguros, pudiendo ser hasta tres años anteriores a la fecha en que se escribe este documento.

CAPÍTULO 5

DESARROLLO DEL EXPERIMENTO

5.1 Caso de estudio: Accidentes Automovilísticos en Monterrey y su Área Metropolitana, Nuevo León, México

5.1.1 Descripción de la zona de estudio

En este trabajo se toma como caso de estudio el histórico de los accidentes automovilísticos sucedidos en el Estado de Nuevo León, más en específico en las Ciudades de Monterrey y las del área metropolitana.

Nuevo León es un Estado perteneciente a México que se encuentra al noreste del país y colinda con los Estados de Tamaulipas, Coahuila, Zacatecas y San Luis Potosí. Su capital es Monterrey y cuenta con 51 municipios, de los cuales las ciudades que conforman el área metropolitana son:

- Apodaca
- Benito Juárez
- Cadereyta Jiménez
- García
- General Escobedo
- Guadalupe
- Monterrey
- Salinas Victoria
- San Nicolás de los Garza
- San Pedro Garza García
- Santa Catarina
- Santiago

Según datos obtenidos de INEGI, del Estado de Nuevo León podemos identificar las siguientes cifras:

- ✓ El clima en el Estado es en general es seco y semiseco, con 20°C como temperatura promedio anual, 32°C como temperatura máxima promedio y 5°C de temperatura mínima promedio.
- ✓ En cuanto a territorio, representa el 3.27% del territorio nacional.
- ✓ La actividad principal es el comercio y dado al clima seco, la agricultura no es muy favorable, sin embargo, se destaca la producción de fruta citrícola como la Mandarina y el cultivo mediante riego de trigo, maíz, cebada, frijol, sorgo y avena.
- ✓ En el año 2015 contaba con 5,119,504 habitantes, de los cuales 2,577,647 son mujeres y 2,541,857 son hombres.
- ✓ Con referencia a cantidad de vehículos de motor en circulación, se tiene registro de 2,129,728 vehículos en el año 2017.



Figura 35. Nuevo León. Imagen tomada de cuentame.inegi.org.mx en 2019

5.1.2 Zonas elegidas para realizar el análisis y predicción

Análisis. En este estudio se usan como parámetros en el análisis primero todo Nuevo León y después individualmente los municipios: Monterrey, por ser el municipio donde se concentran la mayoría de los accidentes automovilísticos, y al azar se seleccionaron dos municipios más del área metropolitana, Apodaca y Guadalupe.

Predicción. En la predicción de accidentes automovilísticos, en general, se usan los datos históricos del año 2017 en las ciudades: Monterrey, Apodaca y Guadalupe. Más a detalle, en la predicción que se visualizará en el prototipo web se crearán 11 cuadrantes, mediante trazo a mano alzada sobre la ciudad de Monterrey, por ser esta la zona que concentra más accidentes automovilísticos de todo el Estado. El trazo de los cuadrantes no sigue ninguna regla y se hacen polígonos al azar.

5.2 Obtención de valores estadísticos

Análisis estadístico por variable individual. Con el fin de conocer el comportamiento de las variables se obtendrán valores de promedio, moda, mediana, desviación estándar y de ser posible la correlación, de cada una de las variables independientes, así como sus gráficas correspondientes.

Análisis estadístico por pares de variables. Posteriormente se obtienen gráficas que permitan visualizar el comportamiento de la combinación de algunas variables independientes analizadas en el modelo.

Todos los análisis se hacen en relación con la variable Lugar, primero con la información de todas las ciudades del Estado de Nuevo León, después por las Ciudades Monterrey, Apodaca y Guadalupe, de la información histórica en base de datos 1 y 2.

5.3 Diseño de los experimentos con RNMS

En búsqueda de las respuestas que atiendan a las preguntas de investigación, objetivos e hipótesis de este trabajo, se diseña el experimento de la siguiente manera.

Experimento 1. Se ejecuta la RNMS para evaluar la eficiencia en la predicción de accidentes automovilísticos por medio de los patrones de entrada que se generan con las variables de la base de datos 1 según los datos históricos del año 2017.

Experimento 2. Se ejecuta la RNMS para evaluar la eficiencia en la predicción de accidentes automovilísticos por medio de los patrones de entrada que se generan con las variables de la base de datos 2 según los datos históricos del año 2017. Este experimento se divide en dos secciones:

- Sección 1: La RN se ejecuta usando las ciudades como entrada de la variable Lugar.
- Sección 2: La RN se ejecuta usando todos los cuadrantes como parte de los patrones de entrada.

Los detalles, como las variables que forman la arquitectura y los factores de sensibilidad, de los experimentos 1 y 2 pueden ser consultados en la página 66.

Efectividad de los resultados. El porcentaje de efectividad pe del uso de las variables para la predicción con la RNMS se obtiene con respecto al Error Cuadrático Medio $error_{nn}$ calculado al ejecutar la RN, según la Ecuación 16.

$$pe = (1 - error_{nn}) * 100$$

Ecuación 16

5.4 Nomenclatura de las variables

Las variables que serán usada en el experimento son descritas en Tabla 10. Las variables horario, clima y lugar son calculadas dos veces, según la base de datos en uso. Para conocer la descripción de cada una ver el capítulo de “variables” en la página 61 de este documento.

Tabla 10. Nombre de las variables en los experimentos

Variable	Nombre	Base de Datos
Tipo del Accidente	tipoBD1	1
Causa del Accidente	causaBD1	1
Horario en que ocurre el accidente	horario	calculada
Mes que ocurre el accidente	fechaMes	1 y 2
Día de la semana que ocurre el accidente (domingo = 1)	fechaDia	1 y 2
Clima del día que ocurre el accidente	clima	calculada
Causa del accidente	causaBD2	2
Lugar según municipio ciudad	lugarCiudad	1 y 2
Lugar según el cuadrante	lugarCuadrante	calculada

5.5 Preparación de patrones de entrada para ejecución de RN

5.5.1 Diagrama de patrones de entrada

Para la ejecución de la RNMS se preparan los patrones de entrada con las variables disponibles en las bases de datos 1 y 2, además de las variables calculadas.

Ejemplos de los patrones de entrada propuestos para salida de cantidad de accidentes automovilísticos ocurridos según las variables de la base de datos 1, se ven en la Figura 36, Figura 37, Figura 38 y Figura 39; y en la posibilidad de

que ocurran accidentes en el futuro, usando la base de datos 2, como se ve en la Figura 40 Figura 41 y Figura 42.




Figura 36. Patrón de entrada 1




Figura 37. Patrón de entrada 2




Figura 38. Patrón de entrada 3




Figura 39. Patrón de entrada 4




Figura 40. Patrón de entrada 5




Figura 41. Patrón de entrada 6




Figura 42. Patrón de entrada 7

5.5.2 Clave de identificación de patrones de entrada

En la Tabla 11 se muestran las claves para identificar las variables involucradas en la creación de los patrones de entrada, facilitando la identificación los resultados arrojados por los experimentos.

Donde:

- BD identifica el número de base de datos usada
- P es el número de patrón
- L identifica el lugar
 - L1 corresponde a Monterrey
 - L2 corresponde a Apodaca
 - L3 corresponde a Guadalupe
 - L9 corresponde a todos los cuadrantes

Tabla 11. Claves de patrones de entrada

CLAVE DEL PATRON	VARIABLES INVOLUGRADAS
BD1P1L1	lugarCiudad, horario, causaBD1
BD1P1L2	lugarCiudad, horario, causaBD1
BD1P1L3	lugarCiudad, horario, causaBD1
BD1P2L1	lugarCiudad, horario, tipoBD1
BD1P2L2	lugarCiudad, horario, tipoBD1
BD1P2L3	lugarCiudad, horario, tipoBD1
BD1P3L1	lugarCiudad, causaBD1, fechaMes
BD1P3L2	lugarCiudad, causaBD1, fechaMes
BD1P3L3	lugarCiudad, causaBD1, fechaMes
BD1P4L1	lugarCiudad, causaBD1, fechaDia
BD1P4L2	lugarCiudad, causaBD1, fechaDia
BD1P4L3	lugarCiudad, causaBD1, fechaDia
BD1P5L1	lugarCiudad, tipoBD1, fechaMes
BD1P5L2	lugarCiudad, tipoBD1, fechaMes
BD1P5L3	lugarCiudad, tipoBD1, fechaMes
BD1P6L1	lugarCiudad, tipoBD1, fechaDia

BD1P6L2	lugarCiudad, tipoBD1, fechaDia
BD1P6L3	lugarCiudad, tipoBD1, fechaDia
BD1P7L1	lugarCiudad, causaBD1, clima
BD1P7L2	lugarCiudad, causaBD1, clima
BD1P7L3	lugarCiudad, causaBD1, clima
BD1P8L1	lugarCiudad, tipoBD1, clima
BD1P8L2	lugarCiudad, tipoBD1, clima
BD1P8L3	lugarCiudad, tipoBD1, clima
BD2P1L1	lugarCiudad, causaBD2, horario
BD2P1L2	lugarCiudad, causaBD2, horario
BD2P1L3	lugarCiudad, causaBD2, horario
BD2P2L1	lugarCiudad, causaBD2, fechaDia
BD2P2L2	lugarCiudad, causaBD2, fechaDia
BD2P2L3	lugarCiudad, causaBD2, fechaDia
BD2P3L1	lugarCiudad, causaBD2, fechaMes
BD2P3L2	lugarCiudad, causaBD2, fechaMes
BD2P3L3	lugarCiudad, causaBD2, fechaMes
BD2P4L1	lugarCiudad, causaBD2, clima
BD2P4L2	lugarCiudad, causaBD2, clima
BD2P4L3	lugarCiudad, causaBD2, clima
BD2P5L9	lugarCuadrante, causaBD2, horario
BD2P6L9	lugarCuadrante, causaBD2, fechaDia
BD2P7L9	lugarCuadrante, causaBD2, fechaMes
BD2P8L9	lugarCuadrante, causaBD2, clima

5.6 Prototipo del sistema web para ejecución de la RN y visualización de los datos generados por IA

El sistema web tiene dos objetivos, el primero el de realizar una ejecución de la RNMS de manera muy transparente, donde solo se tengan que seleccionar los parámetros (variables con que se espera realizar la predicción) y presionar un botón, para que de manera interna se ejecute la red; el segundo es dar una presentación visual por medio de mapas y graficas sobre los datos de los accidentes viales, tanto los de la información histórica, pero con énfasis en los

datos obtenidos por la IA, propiciando un entendimiento y fácil interacción con posibles usuarios del sistema.

5.6.1 Funcionalidad

Dicho lo anterior, el prototipo de sistema web debe cumplir con ciertos requisitos y funcionalidad que le permitan lograr sus objetivos, como se enumeran a continuación:

1. Contener una pantalla que permita ejecutar la RN, con opciones para que el usuario seleccione las variables que quiere incluir en el modelo y las fechas de predicción. Permitiendo además ejecutar aprendizaje y predicción o solo predicción.
2. Permitir al usuario la creación de lugares – cuadrantes a su gusto en tamaño de la zona y cantidad de divisiones, que sean tomados en cuenta para la predicción.
3. Permitir una carga masiva de datos históricos, carga masiva semanal y que guarde en la base de datos la información generada por la ejecución de la RN.
4. Contener con un tablero de control donde se visualicen las gráficas y tablas obtenidas en el análisis estadístico, además de contener cuadros informativos con las fechas en que se actualizó la información histórica, la fecha de la última vez que se ejecutó la red para la predicción de eventos futuros, la probabilidad de que ocurran accidentes en cada zona y la cantidad de eventos ocurridos la semana anterior a la fecha actual.
5. Contener con un mapa interactivo que permita visualizar la información por cuadrante o zona, donde se muestren cantidades de accidentes por medio

de marcadores o puntos de color para cada categoría de las causas del accidente automovilístico y posibilidades de que ocurran en un futuro por cuadrante en colores rojo para posibilidad alta, naranja para posibilidad media y amarillo para posibilidad baja.

6. Contener un mapa táctico que permita hacer un análisis a detalle de un cuadrante o zona seleccionada.

5.6.2 Prototipo inicial

Para cumplir las especificaciones del prototipo final del sistema web, se diseñó un primer prototipo a mano, que contiene un menú principal para el tablero y los mapas; un menú secundario donde se encuentra la carga de datos y ejecución de predicción, configuración y otros temas de ayuda. Las pantallas propuestas se muestran en la Figura 43, Figura 44, Figura 45, Figura 46 y Figura 47.

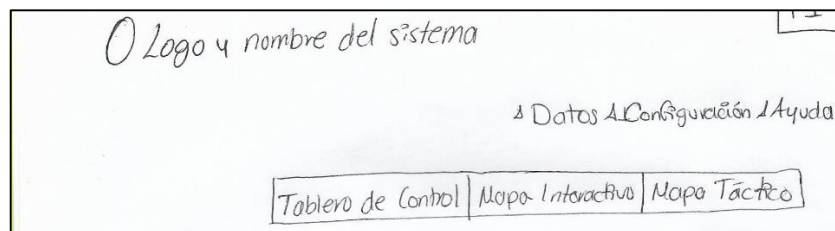


Figura 43. Prototipo a mano, encabezado




Figura 44. Prototipo a mano, tablero de control

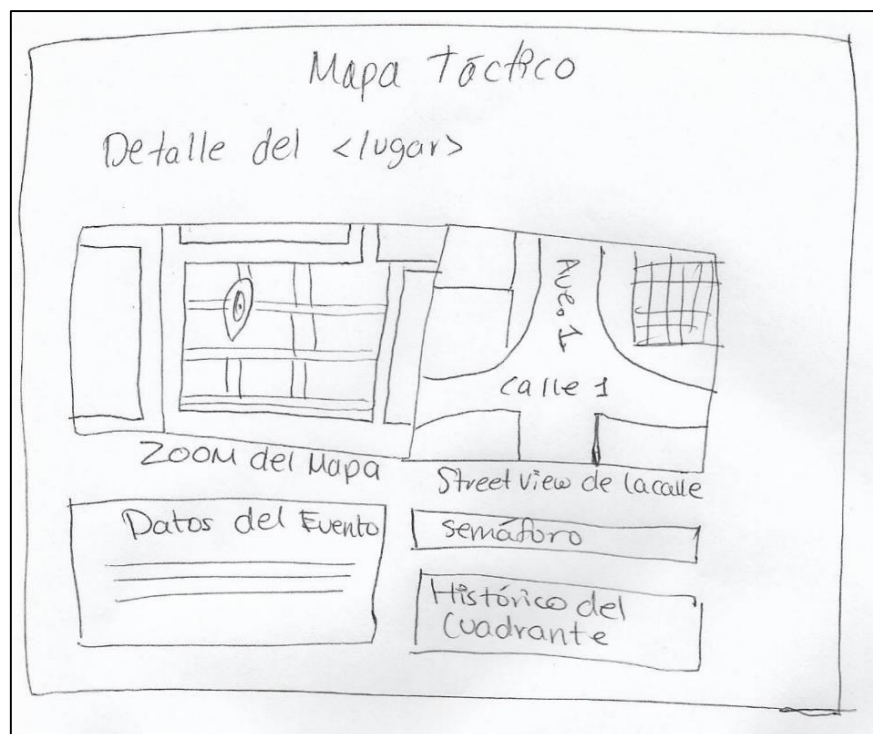


Figura 45. Prototipo a mano, mapa táctico




Figura 46. Prototipo a mano, mapa interactivo




Figura 47. Prototipo a mano, datos

5.6.3 Cuestionario de prueba de usabilidad

La aprobación del prototipo del sistema web para la visualización del análisis y predicción de accidentes automovilísticos se basará en los resultados del cuestionario diseñado para realizar las pruebas de usabilidad del sistema.

Del prototipo inicial hecho a mano, se aplicará el cuestionario de usabilidad a cinco personas que fungirán como usuarios del sistema, con el fin de recabar comentarios y una primera evaluación.

Una vez que se tengan los resultados se harán las correcciones para el prototipo final y se volverá a aplicar el mismo cuestionario a cinco personas diferentes de las ya evaluadas.

En primer lugar, se asignarán seis tareas a resolver, para que posteriormente se contesten quince preguntas, las que aparecen en Figura 48, Figura 49 y Figura 50, las cuales pertenecen a las categorías siguientes:

- Contenido: corresponden las preguntas 1, 2, 3, 4, 6, 12, 13 y 15
- Utilidad: corresponden las preguntas 5 y 11
- Navegación: corresponden las preguntas 7, 8, 9, 10 y 14

<p>Prueba de usabilidad</p> <p>"Prototipo del Sistema Web de Visualización del Análisis y Predicción de Accidentes Automovilísticos"</p> <hr/> <hr/> <p>INSTRUCCIONES. Realizar las tareas asignadas de identificación y después contestar las preguntas en el cuestionario</p> <p>I. TAREAS A RESOLVER</p> <p>A continuación, se presentan las tareas de identificación que debe realizar en el prototipo inicial.</p> <ul style="list-style-type: none">a) Identificar el menú donde se encuentran las gráficas para realizar un análisis visual de los datos de accidentes ocurridos en el transcurso del tiempo.b) Identificar el menú que permite acceder a la pantalla donde se realiza la predicción de accidentes automovilísticos.c) Identificar el menú que le permita conocer los detalles de un accidente ocurrido en un lugar en específico.d) Identificar los cuadrantes (divisiones) en los que se encuentra dividida la ciudad.e) Identificar el menú donde puede cargar la información histórica y demás datos de los accidentes automovilísticos.f) Identificar las variables con las que puede realizar una predicción de accidentes para la siguiente semana. <p>II. CUESTIONARIO</p> <p>Conteste los siguientes cuestionamientos marcando con una X la respuesta que considere más adecuada según su experiencia en el uso de prototipo, en una escala de muy bueno a muy malo.</p> <p>1. ¿El prototipo cuenta con espacios para logotipo y nombre del sistema?</p> <p><input type="checkbox"/> Muy Bueno <input type="checkbox"/> Bueno <input type="checkbox"/> Regular <input type="checkbox"/> Malo <input type="checkbox"/> Muy Malo</p> <p>2. ¿Cómo es la distribución de los menús?</p> <p><input type="checkbox"/> Muy Bueno <input type="checkbox"/> Bueno <input type="checkbox"/> Regular <input type="checkbox"/> Malo <input type="checkbox"/> Muy Malo</p> <p>3. ¿Es fácil distinguir los contenidos que presenta el sitio web?</p> <p><input type="checkbox"/> Muy Bueno <input type="checkbox"/> Bueno <input type="checkbox"/> Regular <input type="checkbox"/> Malo <input type="checkbox"/> Muy Malo</p> <p>1</p>

Figura 48. Cuestionario de usabilidad pág. 1

Prueba de usabilidad				
"Prototipo del Sistema Web de Visualización del Análisis y Predicción de Accidentes Automovilísticos"				
4. ¿Existen elementos dentro de las páginas, que le permitan saber exactamente dónde se encuentra dentro de este sitio?	<input type="checkbox"/> Muy Bueno	<input type="checkbox"/> Bueno	<input type="checkbox"/> Regular	<input type="checkbox"/> Malo <input type="checkbox"/> Muy Malo
5. ¿El sitio cuenta con gráficos y/o animaciones?	<input type="checkbox"/> Muy Bueno	<input type="checkbox"/> Bueno	<input type="checkbox"/> Regular	<input type="checkbox"/> Malo <input type="checkbox"/> Muy Malo
6. ¿Con claros los objetivos del sitio?	<input type="checkbox"/> Muy Bueno	<input type="checkbox"/> Bueno	<input type="checkbox"/> Regular	<input type="checkbox"/> Malo <input type="checkbox"/> Muy Malo
7. ¿Con que facilidad identificó el menú donde se encuentran las gráficas para realizar un análisis visual de los datos de accidentes ocurridos en el transcurso del tiempo?	<input type="checkbox"/> Muy Bueno	<input type="checkbox"/> Bueno	<input type="checkbox"/> Regular	<input type="checkbox"/> Malo <input type="checkbox"/> Muy Malo
8. ¿Con que facilidad Identificó el menú que permite acceso a la pantalla donde se realizar la predicción de accidentes automovilísticos?	<input type="checkbox"/> Muy Bueno	<input type="checkbox"/> Bueno	<input type="checkbox"/> Regular	<input type="checkbox"/> Malo <input type="checkbox"/> Muy Malo
9. ¿Con que facilidad Identificó el menú que le permita conocer los detalles de un accidente ocurrido en un lugar en específico?	<input type="checkbox"/> Muy Bueno	<input type="checkbox"/> Bueno	<input type="checkbox"/> Regular	<input type="checkbox"/> Malo <input type="checkbox"/> Muy Malo
10. ¿Con que facilidad identificó los cuadrantes (divisiones) en los que se encuentra dividida la ciudad?	<input type="checkbox"/> Muy Bueno	<input type="checkbox"/> Bueno	<input type="checkbox"/> Regular	<input type="checkbox"/> Malo <input type="checkbox"/> Muy Malo
11. ¿Con que facilidad identificó el menú donde puede cargar la información histórica y demás datos de los accidentes automovilísticos?	<input type="checkbox"/> Muy Bueno	<input type="checkbox"/> Bueno	<input type="checkbox"/> Regular	<input type="checkbox"/> Malo <input type="checkbox"/> Muy Malo
12. ¿Qué tan enriquecido es el contenido de información de los accidentes automovilísticos?	<input type="checkbox"/> Muy Bueno	<input type="checkbox"/> Bueno	<input type="checkbox"/> Regular	<input type="checkbox"/> Malo <input type="checkbox"/> Muy Malo

2

Figura 49. Cuestionario de usabilidad pág. 2

Prueba de usabilidad

"Prototipo del Sistema Web de Visualización del Análisis y Predicción de
Accidentes Automovilísticos"

13. ¿Con que facilidad identificó las variables con las que puede realizar una predicción de accidentes para la siguiente semana?

☐ Muy Bueno ☐ Bueno ☐ Regular ☐ Malo ☐ Muy Malo

14. ¿Con que facilidad identificó el botón para ejecutar la Red Neuronal?

☐ Muy Bueno ☐ Bueno ☐ Regular ☐ Malo ☐ Muy Malo

15. ¿La distribución de los datos históricos se diferencia de la distribución de los datos de predicción?

☐ Muy Bueno ☐ Bueno ☐ Regular ☐ Malo ☐ Muy Malo

III. Comentarios

Figura 50. Cuestionario de usabilidad pág. 3

CAPÍTULO 6

RESULTADOS

En los anexos 2, 3 y 4 se pueden observar los diferentes extractos de información del año 2017 con los valores para obtener los resultados del análisis y predicción de accidentes automovilísticos, constituyendo la información de las gráficas, tablas y patrones de entrada en el entrenamiento de la RN.

6.1 Estadística descriptiva de los accidentes automovilísticos en Nuevo León

6.1.1 Gráficas comportamiento individual de las variables

Variable: fechaMes

Base de datos: 1




Figura 51. Gráfica de Accidentes Automovilísticos en Nuevo León por Mes, 2017




Figura 52. Gráfica de Accidentes Automovilísticos en Monterrey por Mes, 2017




Figura 53. Gráfica de Accidentes Automovilísticos en Apodaca por Mes, 2017




Figura 54. Gráfica de Accidentes Automovilísticos en Guadalupe por Mes, 2017

Variable: fechaDia

Base de datos: 1




Figura 55. Gráfica de Accidentes Automovilísticos en Nuevo León por Día, 2017



Figura 56. Gráfica de Accidentes Automovilísticos en Monterrey por Día, 2017




Figura 57. Gráfica de Accidentes Automovilísticos en Apodaca por Día, 2017




Figura 58. Gráfica de Accidentes Automovilísticos en Guadalupe por Día, 2017

Variable: tipoBD1

Base de datos: 1




Figura 59. Gráfica de Accidentes Automovilísticos en Nuevo León por Tipo, 2017




Figura 60. Gráfica de Accidentes Automovilísticos en Monterrey por Tipo, 2017




Figura 61. Gráfica de Accidentes Automovilísticos en Apodaca por Tipo, 2017




Figura 62. Gráfica de Accidentes Automovilísticos en Guadalupe por Tipo, 2017

Variable: causaBD1

Base de datos: 1




Figura 63. Gráfica de Accidentes Automovilísticos en Nuevo León por Causa, 2017




Figura 64. Gráfica de Accidentes Automovilísticos en Monterrey por Causa, 2017




Figura 65. Gráfica de Accidentes Automovilísticos en Apodaca por Causa, 2017




Figura 66. Gráfica de Accidentes Automovilísticos en Guadalupe por Causa, 2017

Variable: horario

Base de datos: 1




Figura 67. Gráfica de Accidentes Automovilísticos en Nuevo León por Horario, 2017




Figura 68. Gráfica de Accidentes Automovilísticos en Monterrey por Horario, 2017




Figura 69. Gráfica de Accidentes Automovilísticos en Apodaca por Horario en, 2017




Figura 70. Gráfica de Accidentes Automovilísticos en Guadalupe por Horario, 2017

Variable: causaBD2

Base de datos: 2




Figura 71. Gráfica de Accidentes Automovilísticos en Nuevo León por Causa del siniestro, 2017




Figura 72. Gráfica de Accidentes Automovilísticos en Monterrey por Causa del siniestro, 2017




Figura 73. Gráfica de Accidentes Automovilísticos en Apodaca por Causa del siniestro, 2017




Figura 74. Gráfica de Accidentes Automovilísticos en Guadalupe por Causa del siniestro, 2017

Variable: clima

Base de datos: 1




Figura 75. Gráfica de Accidentes Automovilísticos en Nuevo León por Clima, 2017




Figura 76. Gráfica de Accidentes Automovilísticos en Monterrey por Clima, 2017




Figura 77. Gráfica de Accidentes Automovilísticos en Apodaca por Clima, 2017




Figura 78. Gráfica de Accidentes Automovilísticos en Guadalupe por Clima, 2017

6.1.2 Resultados de estadística descriptiva

La Tabla 12 muestra los resultados obtenidos de la estadística descriptiva de las variables estudiadas presentes en el modelo respecto al total de accidentes automovilísticos ocurridos en Nuevo León en el año 2017.

Tabla 12. Estadística descriptiva de las variables

Variable	Promedio	Mediana	Moda	Máximo	Mínimo	Factor de Correlación
<i>fechaMes</i>	6468	6474	-	7065	5727	0.6844
<i>fechaDia</i>	11089	11305	-	12635	8607	0.7001
<i>tipoBD1</i>	8624	695	-	61790	55	NA
<i>causaBD1</i>	15524	2339	-	67704	364	NA
<i>horario</i>	19405	21686	-	25497	8752	-0.9008
<i>causaBD2</i>	5545	32	-	38340	12	NA

6.1.3 Resultados del comportamiento por pares de variables

Variables: horario y causaBD1
Base de datos: 1




Figura 79. Gráficas de Horario y Causa del accidente en Nuevo León, 2017




Figura 80. Gráfica de Horario y Causa del accidente en Monterrey, 2017




Figura 81. Gráfica de Horario y Causa del accidente en Apodaca, 2017




Figura 82. Gráfica de Horario y Causa del accidente en Guadalupe, 2017

Variables: horario y tipoBD1

Base de datos: 1




Figura 83. Gráfica de Horario y Tipo de accidente en Nuevo León, 2017




Figura 84. Gráfica de Horario y Tipo de accidente en Monterrey, 2017




Figura 85. Gráfica de Horario y Tipo de accidente en Apodaca, 2017




Figura 86. Gráfica de Horario y Tipo de accidente en Guadalupe, 2017

Variables: causaBD1 y fechaMes

Base de datos: 1




Figura 87. Gráfica de Causa y Mes del accidente en Nuevo León, 2017




Figura 88. Gráfica de Causa y Mes del accidente en Monterrey, 2017




Figura 89. Gráfica de Causa y Mes del accidente en Apodaca, 2017




Figura 90. Gráfica de Causa y Mes del accidente en Guadalupe, 2017

Variables: causaBD1 y fechaDia

Base de datos: 1




Figura 91. Gráfica de Causa y Día del accidente en Nuevo León, 2017




Figura 92. Gráfica de Causa y Día del accidente en Monterrey, 2017




Figura 93. Gráfica de Causa y Día del accidente en Apodaca, 2017




Figura 94. Gráfica de Causa y Día del accidente en Guadalupe, 2017

Variables: tipoBD1 y fechaMes

Base de datos: 1




Figura 95. Gráfica de Tipo y Mes del accidente en Nuevo León, 2017




Figura 96. Gráfica de Tipo y Mes del accidente en Monterrey, 2017




Figura 97. Gráfica de Tipo y Mes del accidente en Apodaca, 2017




Figura 98. Gráfica de Tipo y Mes del accidente en Guadalupe, 2017

Variables: tipoBD1 y fechaDia

Base de datos: 1




Figura 99. Gráfica de Tipo y Día del accidente en Nuevo León, 2017




Figura 100. Gráfica de Tipo y Día del accidente en Monterrey, 2017




Figura 101. Gráfica de Tipo y Día del accidente en Apodaca, 2017




Figura 102. Gráfica de Tipo y Día del accidente en Guadalupe, 2017

Variables: causaBD1 y clima

Base de datos: 1




Figura 103. Gráfica de Causa y Clima del accidente en Nuevo León, 2017




Figura 104. Gráfica de Causa y Clima del accidente en Monterrey, 2017




Figura 105. Gráfica de Causa y Clima del accidente en Apodaca, 2017




Figura 106. Gráfica de Causa y Clima del accidente en Guadalupe, 2017

Variables: tipoBD1 y clima

Base de datos: 1




Figura 107. Gráfica de Tipo y Clima del accidente en Nuevo León, 2017




Figura 108. Gráfica de Tipo y Clima del accidente en Monterrey, 2017




Figura 109. Gráfica de Tipo y Clima del accidente en Apodaca, 2017




Figura 110. Gráfica de Tipo y Clima del accidente en Guadalupe, 2017

Variables: causaBD2 y horario

Base de datos: 2




Figura 111. Gráfica de Causa y Horario del accidente en Nuevo León, 2017




Figura 112. Gráfica de Causa y Horario del accidente en Monterrey, 2017




Figura 113. Gráfica de Causa y Horario del accidente en Apodaca, 2017




Figura 114. Gráfica de Causa y Horario del accidente en Guadalupe, 2017

Variables: causaBD2 y fechaDia

Base de datos: 2




Figura 115. Gráfica de Causa y Día del accidente en Nuevo León, 2017




Figura 116. Gráfica de Causa y Día del accidente en Monterrey, 2017




Figura 117. Gráfica de Causa y Día del accidente en Apodaca, 2017




Figura 118. Gráfica de Causa y Día del accidente en Guadalupe, 2017

Variables: causaBD2 y fechaMes

Base de datos: 2




Figura 119. Gráfica de Causa y Mes del accidente en Nuevo León, 2017




Figura 120. Gráfica de Causa y Mes del accidente en Monterrey, 2017




Figura 121. Gráfica de Causa y Mes del accidente en Apodaca, 2017




Figura 122. Gráfica de Causa y Mes del accidente en Guadalupe, 2017

6.2 Resultados del Experimento 1

Se muestran los resultados del experimento 1 mediante representación gráfica y con la evaluación de eficiencia de la RNMS.

6.2.1 Gráficas de resultados




Figura 123. Gráfica resultante del patrón de entrada BD1P1L1




Figura 124. Gráfica resultante del patrón de entrada BD1P1L2




Figura 125. Gráfica resultante del patrón de entrada BD1P1L3




Figura 126. Gráfica resultante del patrón de entrada BD1P2L1




Figura 127. Gráfica resultante del patrón de entrada BD1P2L2




Figura 128. Gráfica resultante del patrón de entrada BD1P2L3




Figura 129. Gráfica resultante del patrón de entrada BD1P3L1




Figura 130. Gráfica resultante del patrón de entrada BD1P3L2




Figura 131. Gráfica resultante del patrón de entrada BD1P3L3




Figura 132. Gráfica resultante del patrón de entrada BD1P4L1




Figura 133. Gráfica resultante del patrón de entrada BD1P4L2




Figura 134. Gráfica resultante del patrón de entrada BD1P4L3




Figura 135. Gráfica resultante del patrón de entrada BD1P5L1




Figura 136. Gráfica resultante del patrón de entrada BD1P5L2




Figura 137. Gráfica resultante del patrón de entrada BD1P5L3




Figura 138. Gráfica resultante del patrón de entrada BD1P6L1




Figura 139. Gráfica resultante del patrón de entrada BD1P6L2




Figura 140. Gráfica resultante del patrón de entrada BD1P6L3




Figura 141. Gráfica resultante del patrón de entrada BD1P7L1




Figura 142. Gráfica resultante del patrón de entrada BD1P7L2




Figura 143. Gráfica resultante del patrón de entrada BD1P7L3




Figura 144. Gráfica resultante del patrón de entrada BD1P8L1




Figura 145. Gráfica resultante del patrón de entrada BD1P8L2




Figura 146. Gráfica resultante del patrón de entrada BD1P8L3

6.2.2 Evaluación de la eficiencia de predicción

La Tabla 13 muestra la eficiencia de predicción entre la corrida de la RNM con los patrones de entrada propuestos de entrenamiento y la eficiencia de la red obtenida de la comparación entre los datos reales y los datos generados de predicción, además de resultados promedios obtenidos de 10 corridas.

Tabla 13. Eficiencia de predicción, Experimento 1

CLAVE DE PATRON	ERROR DEL MEJOR RESULTADO	% EFICIENCIA DE PREDICCIÓN	PROMEDIO DE ERROR DE 10 CORRIDAS	% EFICIENCIA DE PREDICCIÓN (10 CORRIDAS)
BD1P1L1	0.0036723	99.633	0.1068265	89.317
BD1P1L2	0.0433531	95.665	0.2929618	70.704
BD1P1L3	0.0423644	95.764	0.1014658	89.853
BD1P2L1	0.1180408	88.196	0.3391123	66.089
BD1P2L2	0.1191025	88.090	0.3999731	60.003
BD1P2L3	0.1574006	84.260	0.4687686	53.123
BD1P3L1	0.0372485	96.275	0.0655556	93.444
BD1P3L2	0.0331647	96.684	0.0640150	93.599

BD1P3L3	0.0389818	96.102	0.1476407	85.236
BD1P4L1	0.0030968	99.690	0.0494205	95.058
BD1P4L2	0.0109386	98.906	0.0519025	94.810
BD1P4L3	0.0249465	97.505	0.0603425	93.966
BD1P5L1	0.1008525	89.915	0.4209162	57.908
BD1P5L2	0.1400130	85.999	0.3453958	65.460
BD1P5L3	0.0690767	93.092	0.4727462	52.725
BD1P6L1	0.1798345	82.017	0.4166694	58.333
BD1P6L2	0.1224147	87.759	0.4879108	51.209
BD1P6L3	0.1615905	83.841	0.4174264	58.257
BD1P7L1	0.0045100	99.549	0.2414110	75.859
BD1P7L2	0.0005852	99.941	0.1149817	88.502
BD1P7L3	0.0867682	91.323	0.0544299	94.557
BD1P8L1	0.0712250	92.878	0.3563828	64.362
BD1P8L2	0.0628175	93.718	0.3006620	69.934
BD1P8L3	0.0422124	95.779	0.4157361	58.426

6.3 Resultados del Experimento 2

Se muestran los resultados de las dos secciones del experimento 2 mediante representación gráfica y con la evaluación de eficiencia de la RNMS.

6.3.1 Gráficas de resultados

Sección 1




Figura 147. Gráfica resultante del patrón de entrada BD2P1L1




Figura 148. Gráfica resultante del patrón de entrada BD2P1L2




Figura 149. Gráfica resultante del patrón de entrada BD2P1L3




Figura 150. Gráfica resultante del patrón de entrada BD2P2L1




Figura 151. Gráfica resultante del patrón de entrada BD2P2L2




Figura 152. Gráfica resultante del patrón de entrada BD2P2L3




Figura 153. Gráfica resultante del patrón de entrada BD2P3L1




Figura 154. Gráfica resultante del patrón de entrada BD2P3L2




Figura 155. Gráfica resultante del patrón de entrada BD2P3L3




Figura 156. Gráfica resultante del patrón de entrada BD2P4L1




Figura 157. Gráfica resultante del patrón de entrada BD2P4L2




Figura 158. Gráfica resultante del patrón de entrada BD2P4L3

Sección 2




Figura 159. Gráfica resultante del patrón de entrada BD2P5L9




Figura 160. Gráfica resultante del patrón de entrada BD2P6L9




Figura 161. Gráfica resultante del patrón de entrada BD2P7L9




Figura 162. Gráfica resultante del patrón de entrada BD2P8L9

6.3.2 Evaluación de la eficiencia de predicción

Sección 1

La Tabla 14 muestra la eficiencia de predicción entre la corrida de la RNMS en baja sensibilidad con los patrones propuestos y la eficiencia de la red obtenida de la comparación entre los datos reales y los datos generados de predicción, además de resultados promedios obtenidos de 10 corridas..

Tabla 14. Eficiencia de predicción, Experimento 2-1

CLAVE DE PATRON	ERROR DEL MEJOR RESULTADO	% EFICIENCIA DE PREDICCIÓN	PROMEDIO DE ERROR DE 10 CORRIDAS	% EFICIENCIA DE PREDICCIÓN (10 CORRIDAS)
BD2P1L1	0.0011127	99.889	0.1373917	86.261
BD2P1L2	0.0013702	99.863	0.1501031	84.990
BD2P1L3	0.0007178	99.928	0.0871992	91.280
BD2P2L1	0.0046143	99.539	0.0148126	98.519

BD2P2L2	0.0048769	99.512	0.0184788	98.152
BD2P2L3	0.0073340	99.267	0.0107937	98.921
BD2P3L1	0.0339524	96.605	0.0296032	97.040
BD2P3L2	0.0480677	95.193	0.0848927	91.511
BD2P3L3	0.0351048	96.490	0.0740742	92.593
BD2P4L1	0.0164899	98.351	0.0866802	91.332
BD2P4L2	0.0022496	99.775	0.0317078	96.829
BD2P4L3	0.0280502	97.195	0.0894596	91.054

Sección 2

La Tabla 15 muestra la eficiencia de predicción entre la corrida de la RNMS en alta sensibilidad con los patrones propuestos y la eficiencia de la red obtenida de la comparación entre los datos reales y los datos generados de predicción.

Tabla 15. Eficiencia de predicción, Experimento 2-2

CLAVE DE PATRON	ERROR DEL MEJOR RESULTADO	% EFICIENCIA DE PREDICCIÓN	PROMEDIO DE ERROR DE 10 CORRIDAS	% EFICIENCIA DE PREDICCIÓN (10 CORRIDAS)
BD2P5L9	0.0493409	95.066	0.0906001	90.940
BD2P6L9	0.0695309	93.047	0.2684799	73.152
BD2P7L9	0.0599183	94.008	0.0908578	90.914
BD2P8L9	0.0383817	96.162	0.1401660	85.983

6.4 Resumen de los resultados de los experimentos 1 y 2

La Figura 163 muestra los promedios de los Porcentajes de Efectividad por Patrón de Entrada en el experimento 1.




Figura 163. Gráfica de promedio de Efectividad por Patrón exp 1

La Figura 164 muestra el Porcentaje de Efectividad de los patrones de entrada creados por la variable Causa del accidente en conjunto con el Lugar, Horario, Fecha y Clima en el experimento 1.




Figura 164. Gráfica de Efectividad patrones de entrada de Causa del Accidente

La Figura 165 muestra el Porcentaje de Efectividad de los patrones de entrada creados por la variable Tipo de accidente en conjunto con el Lugar, Horario, Fecha y Clima en el experimento 1.




Figura 165. Gráfica de Efectividad patrones de entrada del Tipo de Accidente

La Figura 166 muestra los promedios de los Porcentajes de Efectividad por Patrón de Entrada en el experimento 2 sección 1.




Figura 166. Gráfica de promedio de Efectividad por Patrón exp 2-1

La Figura 167 muestra los Porcentajes de Efectividad por Patrón de Entrada en el experimento 2 sección 2.




Figura 167. Gráfica de promedio de Efectividad por Patrón exp 2-2

6.5 Prototipo del sistema web para ejecución de la RN y visualización de información

6.5.1 Pruebas de usabilidad del prototipo inicial

Del cuestionario aplicado para evaluar el prototipo inicial hecho a mano, se obtuvieron los siguientes resultados: según el contenido en la Figura 168, funcionalidad en la Figura 169 y navegación en la Figura 170. La aplicación del cuestionario arrojó, los siguientes comentarios y retroalimentación:

- Utilizar cámaras públicas en las calles para mejorar el detalle de los lugares donde ocurre el accidente.
- Poner en ventanas separas la información que se obtiene con la predicción y la información que se sube de los accidentes que sucedieron.
- Color un menú separado para predicción.
- Colocar más información de la predicción, como la efectividad y datos de predicciones anteriores.




Figura 168. Resultados preliminares pruebas de usabilidad. Contenido




Figura 169. Resultados preliminares pruebas de usabilidad. Utilidad




Figura 170. Resultados preliminares pruebas de usabilidad. Navegación

6.5.2 Visualización

Del prototipo final del sistema web de visualización de análisis y predicción de accidentes automovilísticos, las pantallas son mostradas en esta sección.

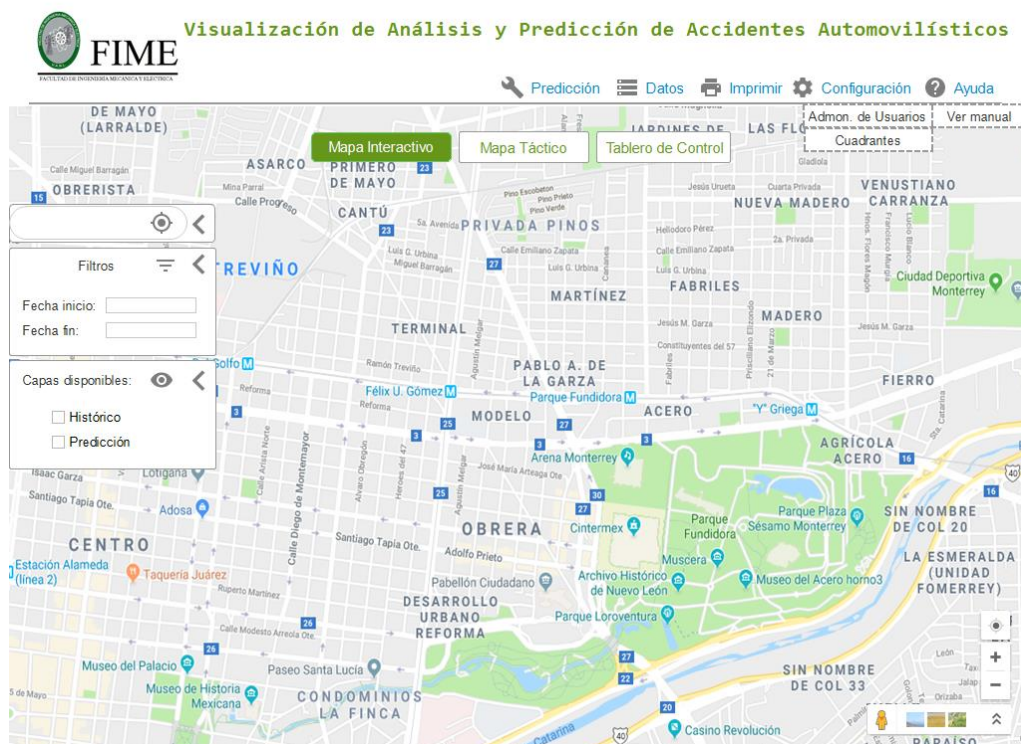
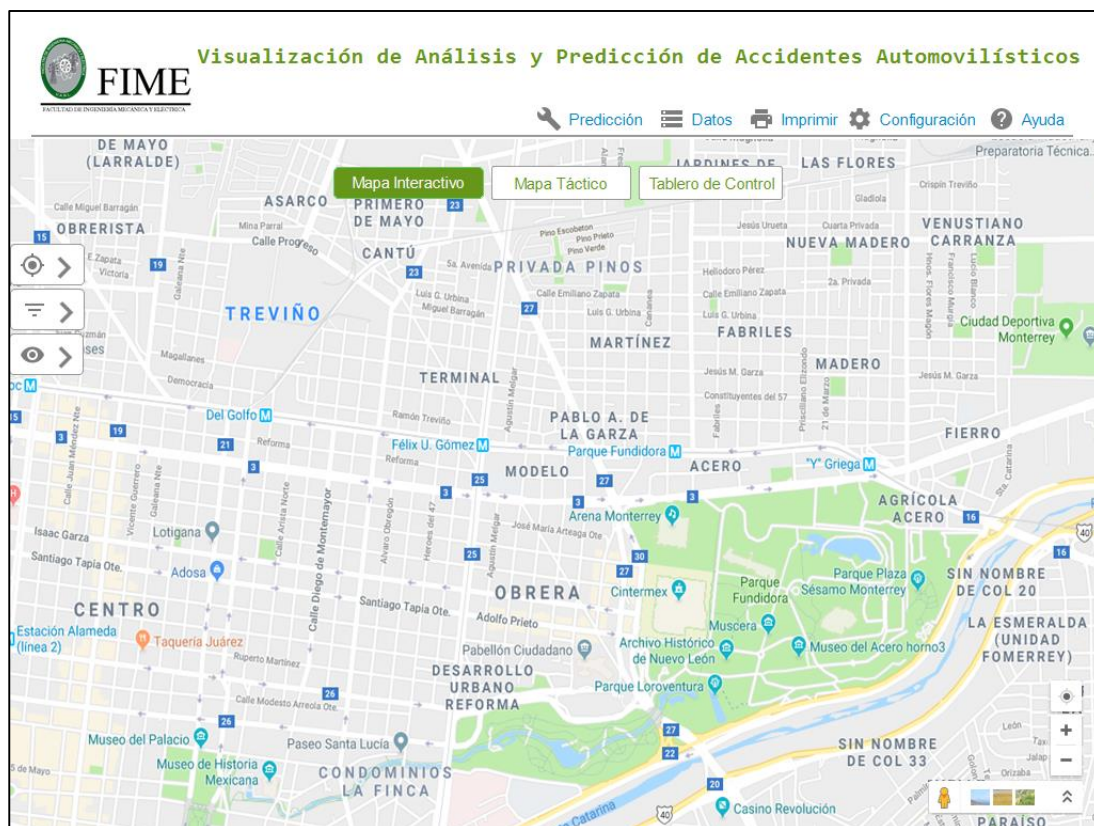


Figura 172. Mapa Interactivo con menús desplegados

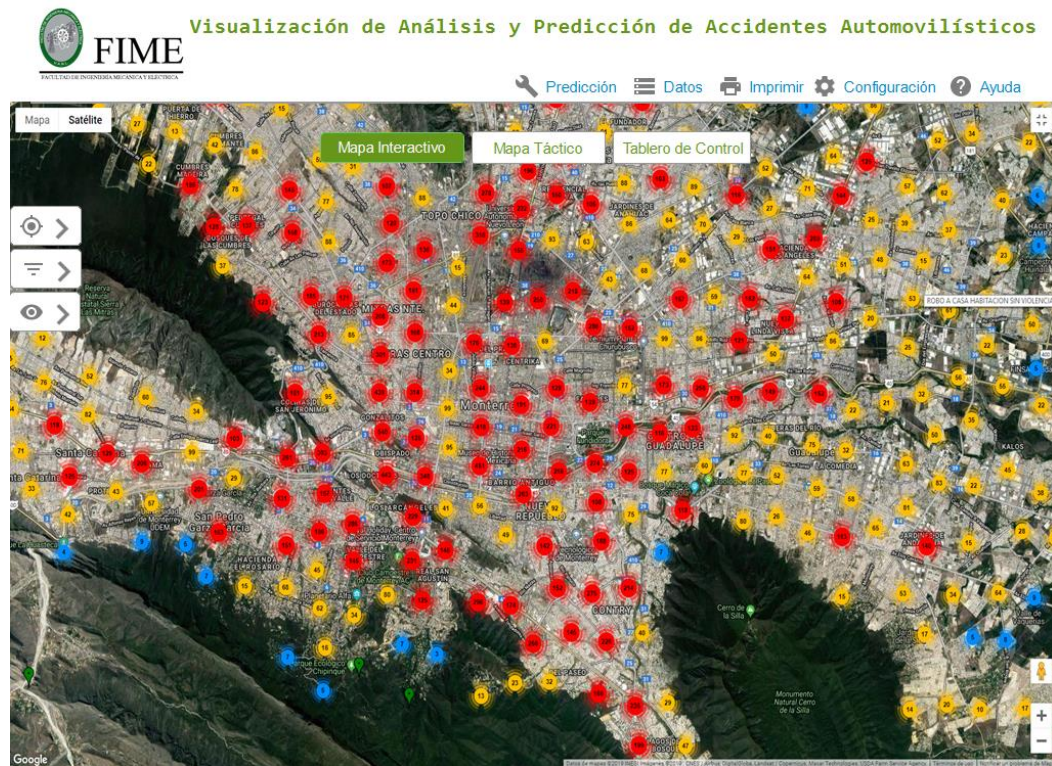


Figura 173. Mapa con histórico de datos

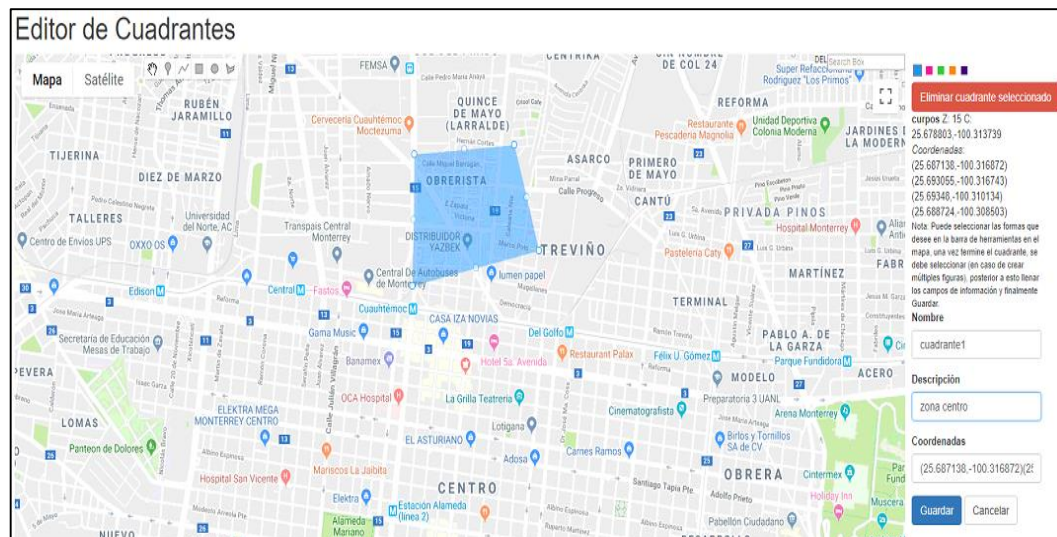


Figura 174. Crear cuadrantes

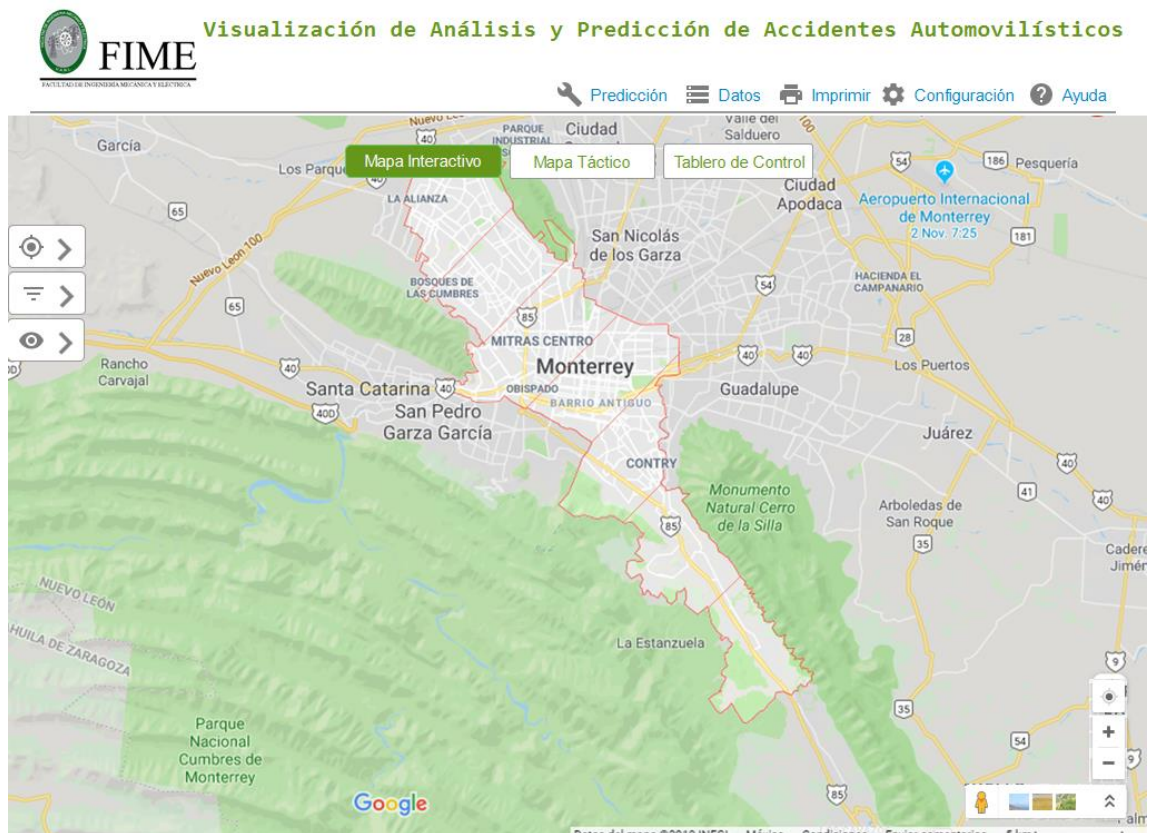


Figura 175. Monterrey dividido en once cuadrantes

[Mapa Interactivo](#)
[Mapa Táctico](#)
[Tablero de Control](#)
Datos históricos de eventos: Accidentes Automovilísticos
Carga masiva de la información

Seleccione el archivo:

Subir archivo

Últimos eventos cargados a la base de datos

Clave	Causa	Tipo	Fecha	Lugar
3	Conductor	Volcadura	08/05/2019	MTY2034
2	Falla del	Falla del	07/05/2019	MTY2034
1	Otra	Salida del	06/05/2019	MTY2034

Fecha de última actualización: 11/05/2019

Figura 176. Carga de Datos

[Mapa Interactivo](#)
[Mapa Táctico](#)
[Tablero de Control](#)
Predicción de eventos: Accidentes Automovilísticos
Inteligencia Artificial

La predicción se realiza por cuadrante y puede seleccionar una variable o todas como parámetro de entrada:

- ☐ Fecha (mes)
- ☐ Fecha (día)
- ☐ Horario
- ☐ Clima
- ☐ Causa
- ☐ Todas

Seleccione rango de fechas

Fecha inicio:

Fecha fin:

Seleccione opciones de Predicción

☐ Aprendizaje

☐ Predicción

Ejecutar Red Neuronal

Datos generados

Últimas 10 predicciones realizadas:

Se usaron las variables de:

Lugar - Causa

En las fechas:

06/05/2019 al 12/05/2019

Con opciones de predicción:

Aprendizaje, Predicción

% de Efectividad:

98.01%

tabla de resultados

Cuadrante	Causa	Posibilidad
1	Colisión y/o vuelco	Baja
2	Colisión y/o vuelco	Media

Fecha de última ejecución: 05/05/2019

Figura 177. Ejecución de NR para Predicción

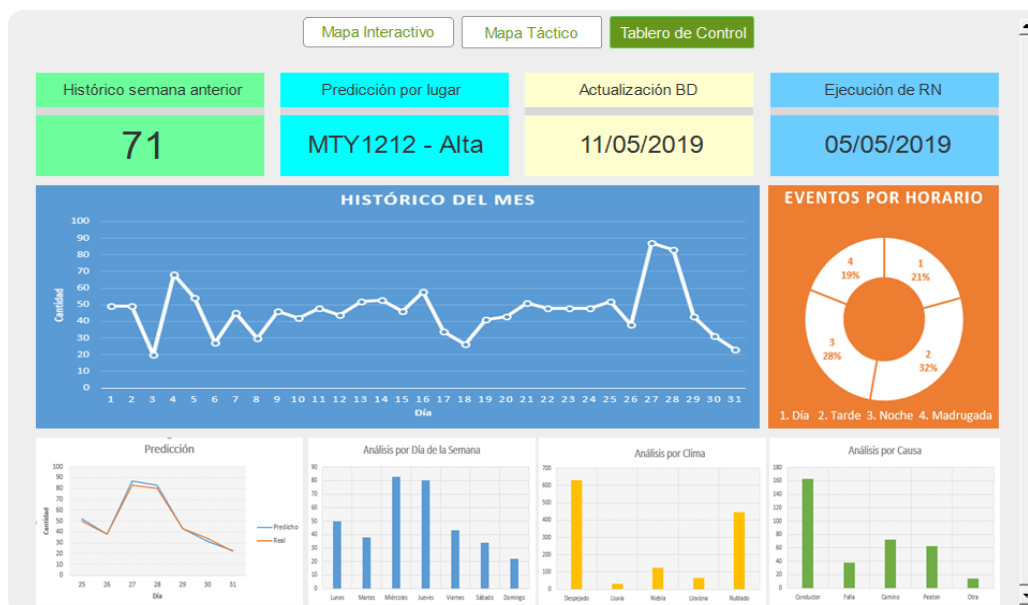


Figura 178. Tablero de Control

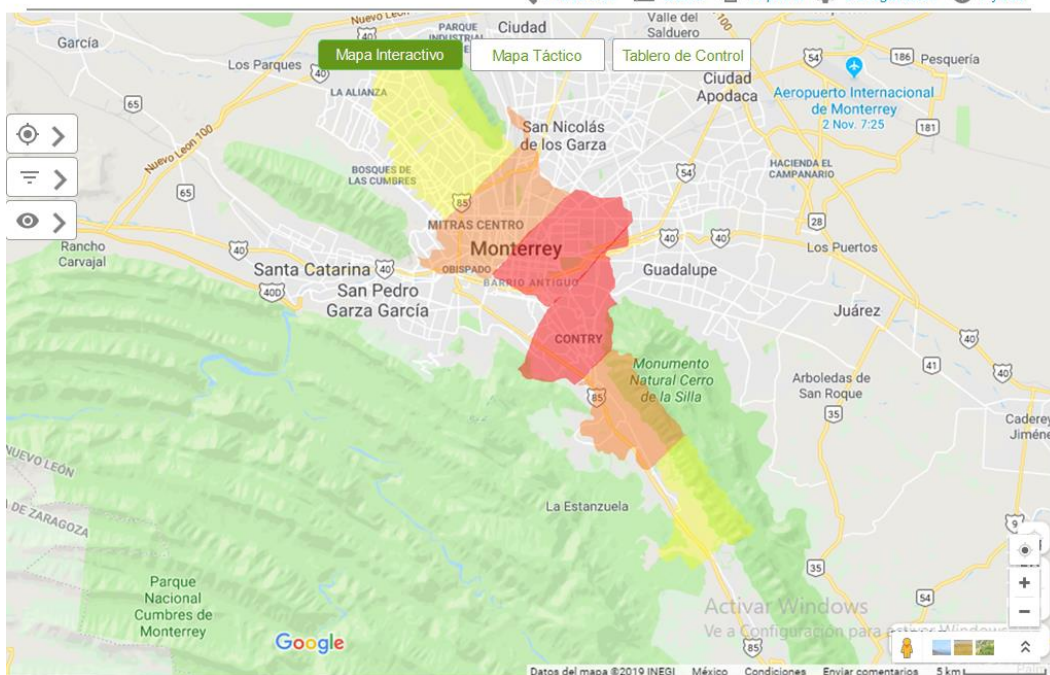

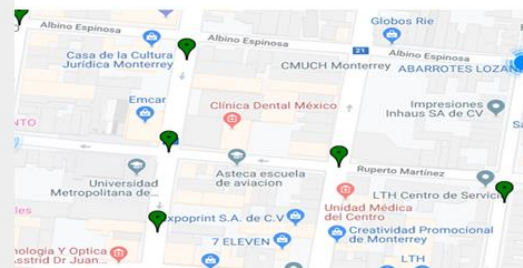


Figura 179. Mapa con predicción sobre cuadrantes

[Mapa Interactivo](#)
[Mapa Táctico](#)
[Tablero de Control](#)
Vista a Detalle del Lugar: MTY234
Monitoreo

Datos del Evento

Lugar: MTY234 Fecha: 7 de Mayo de 2019
 Clima: Lluvioso Horario: Tarde
 Causa: Falla del vehículo Tipo: Colisión con objeto fijo


Histórico

Clave	Causa	Tipo	Fecha
3	Conductor	Volcadura	08/05/2019
2	Falla del vehículo	Falla del vehículo	07/05/2019
1	Otra	Salida del camino	06/05/2019

Figura 180. Mapa táctico detalle del evento

6.5.3 Pruebas de usabilidad del prototipo final

Los resultados del cuestionario de la prueba de usabilidad para el prototipo final, por categorías según las preguntas, son los siguientes: contenido en la Figura 181, utilidad en la Figura 182 y navegación en la Figura 183.




Figura 181. Resultados finales pruebas de usabilidad. Contenido




Figura 182. Resultados finales pruebas de usabilidad. Utilidad




Figura 183. Resultados finales pruebas de usabilidad. Navegación

CAPÍTULO 7

CONCLUSIONES

Se realizó un análisis del efecto de las variables: Clima, Lugar, Horario, Fecha, Tipo de accidente y Causa del accidente, en la formación de patrones de entrada que fueron aplicados a un modelo RNA, usando diferentes tamaños de zonas de estudio, y se presenta la información generada por la RN de manera visual, con lo que se propició una fácil interpretación de datos.

Con el histórico de accidentes automovilísticos sucedidos en Nuevo León del año 2017 y las variables del modelo, se diseñaron de patrones de entrada que alimentaron la RNMS y se realizaron las predicciones con el uso de 100 neuronas, un margen de sensibilidad de 0.85 y un factor de aprendizaje de 0.25. Mediante el mismo histórico se obtuvieron gráficas de cada una de las variables y combinadas entre sí.

Al analizar el histórico se identificó un efecto de valores atípicos y tendencias no lineales de la combinación de las variables Clima, Lugar, Horario, Fecha, Tipo de accidente y Causa del accidente sobre la cantidad de accidentes automovilísticos ocurridos, concluyendo que todas forman información suficiente y justifican el uso de la RN para proyectar la posibilidad que ocurran nuevos eventos. Ejemplos de lo anterior, son los valores de Tipo de accidente en Monterrey, donde de los ocho tipos de accidentes, la mayoría de los datos se concentran el tipo “Colisión con vehículo automotor” y datos de Horario y Causa del accidente en Monterrey, donde los datos de la causa “Conductor” en el horario de “Madrugada” generan datos muy por debajo del promedio.

El diseño de los patrones de entrada con las variables Clima, Lugar, Horario, Fecha, Tipo de accidente y Causa del accidente, con que se alimentó la RNMS, permitió ejecutar la predicción sobre la cantidad y posibilidad de que ocurran accidentes automovilísticos, manteniéndose resultados promedios entre 82% y 99% de efectividad, de los cuales se tomaron las mejores salidas como prototipos. El tipo de datos que se analizan en esta investigación propiciaron que el mejor resultado de salida sea muy alto, en comparación del promedio de resultados obtenidos con el mismo patrón, pero con 10 corridas de la RNA.

De los resultados los patrones generados, con la combinación de la variable Causa del accidente fueron los que presentaron mejor efectividad y la combinación con la variable Tipo de accidente presento una menor efectividad.

Al reducir la zona de análisis de ciudad a cuadrante como valores para la variable Lugar y con la división de la ciudad de Monterrey en once cuadrantes se logra mantener la efectividad de la predicción, dado que se obtuvieron porcentajes de efectividad de la RNMS muy altos, entre 93% y 96%. Por lo tanto, once cuadrantes no hicieron la diferencia, en un trabajo futuro sería interesante, dividir la ciudad en cuadrantes aún más pequeños, al menos una división de mil cuadrantes para validar si los datos permiten seguir obteniendo alta efectividad en la predicción.

El prototipo de sistema web que se diseñó, siguiendo técnicas de visualización del conocimiento por medios como mapas caloríficos, mapas con marcadores, gráficas, tablas y cuadros informativos. La información histórica se carga en una pantalla y en otra se crean cuadrantes a mano alzada sin límite de tamaño o número de divisiones, después se asignan los accidentes a su cuadrante correspondiente.

Se aplicaron dos pruebas de usabilidad a través de cuestionarios a usuarios expertos en tránsito terrestre, con la finalidad de comprobar la facilidad de interpretación e interacción con la información obtenida del análisis y predicción de los accidentes automovilísticos.

El usuario logró ejecutar la RNMS de una manera transparente y fácil, solo seleccionando las variables y fechas que desea incluir en la predicción, y visualizó las predicciones realizadas con anterioridad, además de tener información sobre el porcentaje de efectividad de la predicción que acaba de ejecutar.

La toma de decisiones se facilitó mediante la pantalla de tablero de control con datos estadísticos de accidentes ocurridos y posible cantidad accidentes a ocurrir, con graficas de los históricos de cada una de las variables y una gráfica comparativa entre lo ocurrido y la predicción.

Los mapas con marcadores permitieron al usuario una fácil interpretación sobre la predicción de los accidentes automovilísticos en determinados lugares. Los mapas caloríficos con cuadrantes de color para las posibilidades de que ocurran eventos: rojo para alta, naranja para media y amarillo para baja posibilidad le permitió identificar puntos calientes, puntos fríos o puntos recurrentes. La pantalla del detalle de evento le facilitó la identificación de las características de la zona donde ocurre el accidente, además de visualizar información sobre los detalles del accidente y los accidentes que ocurrieron anteriormente en la misma zona.

Trabajo futuro

Seguir enriqueciendo el trabajo de investigación que aporte solución a la prevención de accidentes automovilísticos, incluyendo más variables al modelo

de análisis y predicción, como condiciones del pavimento y señalamientos o algunas variables adquiridas por sensores del automóvil o cámaras en las calles.

Se tiene la intención de realizar la implementación del Sistema Web propuesto en este trabajo en estaciones de monitoreo de tránsito que permitan estudiar el impacto que tiene en las tomas de decisiones, tanto en el Estado de Nuevo León como en el resto del país.

Crear una versión móvil de la visualización del análisis y predicción que permita poner la información generada a disposición de los conductores de automóvil y conectar con otros sistemas de análisis de tráfico.

Diseñar un modelo que permita la creación de cuadrantes dinámicos que permitan una predicción más detallada sobre una zona aún más pequeña que las estudiadas, y experimentar con esos cuadrantes de un mismo tamaño o de tamaños diferentes.

Estudiar aquellos lugares que no tienen histórico, dado que nunca ha sucedido un accidente automovilístico en la zona, pero que puedan ser propensos a que en un futuro cambie la situación, por ejemplo, debido al hecho que el pavimento comenzara a desgastarse, aumento de tráfico o pérdida de un señalamiento.

REFERENCIAS

- [1] R. González, «Descartes: las intuiciones modales y la inteligencia artificial clásica,» *Alpha*, pp. 181-198, 2011.
- [2] D. Martínez, *El yo y la máquina: Cerebro, mente e inteligencia artificial*, Madrid: Ediciones Palabra, 2013.
- [3] S. Medina, J. Moreno y J. P. Gallego, «Pronóstico de la demanda de energía eléctrica horaria en Colombia mediante redes neuronales,» *Revista Facultad de Ingeniería Universidad de Antioquia*, núm. 59, pp. 98-107, 2011.
- [4] P. De Llanos, C. Piñeiro y M. Rodríguez, «Business failure prediction. A contribution to the synthesis of a theory, through comparative analysis of different prediction techniques.,» *Estudios de Economía. Vol. 43 - N° 2*, pp. 163-198, 2016.
- [5] F. Villada, N. Muñoz y E. García, «Redes Neuronales Artificiales aplicadas a la Predicción del Precio del Oro,» *Información Tecnológica Vol. 27*, pp. 143-150.
<http://dx.doi.org/10.4067/S0718-07642016000500016>., 2016.
- [6] T. Niño, S. Guevarra, F. González, R. Jaque y C. Infante, «Uso de redes neuronales artificiales en predicción de morfología mandibular a través de variables craneomaxilares en una vista posteroanterior.,» p. <http://dx.doi.org/10.11144/Javeriana.uo35>, 2016.
- [7] H. Quan, D. Srinivasan y A. Khosravi, «Short-Term Load and Wind Power Forecasting Using Neural Network-Based Prediction Intervals,» *IEEE TRANSACTIONS ON NEURAL NETWORKS AND LEARNING SYSTEMS*, vol. 25, nº 2, pp. 303-315, 2014.
- [8] A. Pitarque, J. C. Ruiz y J. F. Roy, «Las redes neuronales como herramientas estadísticas no paramétricas de clasificación,» *Psicothema*, pp. 459-463, 2000.
- [9] A. Pitarque, J. F. Roy y J. C. Ruiz, «Redes neurales vs modelos estadísticos: Simulaciones sobre tareas de predicción y clasificación,» *Revista de metodología y psicología experimental, ISSN 0211-2159, Vol. 19, N° 3*, pp. 387-400, 1998.
- [10] L. Pérez, L. Garriga y M. Benítez, «Sistema de predicción financiera para hoteles mediante Redes Neuronales Artificiales,» *Retos Turísticos, Vol. 14 No. 1*, 2015.

- [11] L. Deka y M. Quddus, «Network-level accident-mapping: Distance based pattern matching,» *Accident Analysis and Prevention*, pp. 105-113, 2014.
- [12] CONAPRA, *Consejo Nacional para la Prevención de Accidentes*, 2016.
- [13] C. Montt, N. Rodríguez, A. Valencia y A. Contreras, «Predicción de accidentes de tránsito en la región metropolitana de Chile basado en Redes Neuronales,» de *XVII Congreso Chileno de Ingeniería de Transporte*, Concepción, Chile, 2015.
- [14] D. Jaroszweski y T. McNamara, «The influence of rainfall on road accidents in urban areas: A weather radar approach,» *Travel Behaviour and Society*, pp. 15-21, 2014.
- [15] M. Hagan, H. Demuth, M. Beale y O. De Jesús, *Neural Network Design*, 2002.
- [16] K. Gurney, *An introduction to neural networks*, Londres: UCL Press, 1997.
- [17] S. Haykin, *Neural Networks. A comprehensive Foundation*, Prentice Hal, Inc, 1999.
- [18] J. Haugeland, *La inteligencia artificial*, Siglo XXI, 1988.
- [19] R. Benítez, G. Escudero, S. Kanaan y D. Masip, *Inteligencia artificial avanzada*, Barcelona: Editorial UOC, 2014.
- [20] R. Flórez y J. M. Fernández, *Las Redes Neuronales Artificiales*, Netbiblo, 2008.
- [21] B. Martín y A. Sanz, *Redes Neuronales y Sistemas Borrosos 3ra Ed.*, México: Alfaomega, 2011.
- [22] R. Pino, A. Gómez y N. de Abajo, *Introducción a la inteligencia artificial: sistemas expertos, redes neuronales artificiales y computación evolutiva*, Oviedo: Servicios de Publicaciones Universidad de Oviedo, 2001.
- [23] F. Rosenblatt, «The Perceptron: A probabilistic model for information storage and organization in the brain,» *Psychological Review*, pp. 386-408, 1958.
- [24] J. R. Hilera y V. J. Martínez, *Redes neuronales artificiales: fundamentos, modelos y aplicaciones.*, Ra-ma, 1995.
- [25] S. Knerr, L. Personnaz y G. Dreyfus, «Single-layer learning revisited: a stepwise procedure for building and training a neural network,» *Neurocomputing*, pp. 41-50, 1990.
- [26] E. Heidari, M. A. Sobati y S. Movahedirad, «Accurate prediction of nanofluid viscosity using a multilayer perceptron artificial neural network (MLP-ANN),» *Chemometrics and intelligent laboratory systems*, vol. 155, pp. 73-85, 2016.

- [27] B. T. Pham, D. T. Bui, I. Prakash y M. B. Dholakia, «Hybrid integration of Multilayer Perceptron Neural Networks and machine learning ensembles for landslide susceptibility assessment at Himalayan area (India) using GIS,» *Catena*, vol. 149, pp. 52-63, 2017.
- [28] H. Leung y S. Haykin, «The complex backpropagation algorithm,» *IEEE Transactions on signal processing*, vol. 39, nº 9, pp. 2101-2104, 1991.
- [29] N. Benvenuto y F. Piazza, «On the complex backpropagation algorithm,» *IEEE Transactions on Signal Processing*, vol. 40, nº 4, pp. 967-969, 1992.
- [30] R. Hecht-Nielsen, «Counterpropagation networks,» *Applied optics*, vol. 26, nº 23, pp. 4979-4984, 1987.
- [31] V. Sakhre, S. Jain, V. S. Sapkal y D. P. Agarwal, «Fuzzy counter propagation neural network control for a class of nonlinear dynamical systems,» *Computational intelligence and neuroscience*, p. 82, 2015.
- [32] F.-J. Chang y Y.-C. Chen, «A counterpropagation fuzzy-neural network modeling approach to real time streamflow prediction,» *Journal of hydrology*, vol. 245, nº 1-4, pp. 153-164, 2001.
- [33] Y. Zeinali y B. Story, «Structural impairment detection using deep counter propagation neural networks,» *Procedia Engineering*, vol. 145, pp. 868-875, 2016.
- [34] D. Cabrera, L. Torres-Treviño y A. Rodríguez, «Control by Learning in a Temperature System using a Maximum Sensibility Neural Network,» *In Artificial Intelligence (MICAI)*, pp. 109-113, 2013.
- [35] M. R. Arahál, M. Berenguel y F. Rodríguez, *Técnicas de predicción con aplicaciones en Ingeniería*, Sevilla: Secretariado de Publicaciones de la Universidad de Sevilla, 2006.
- [36] R. Cervantes, R. Arteaga, M. A. Vázquez, W. Ojeda y A. Quevedo, «Comparación de modelos para estimar la presión real de vapor de agua,» *Tecnología y Ciencias del Agua*, vol. IV, núm.2, pp. 37-54, 2013.
- [37] S. Mateus, N. González y J. Branch, «Aplicación de Redes Neuronales Artificiales en Entornos Virtuales Inteligentes,» *Información tecnológica Vol. 25 No. 5 versión on-line*, pp. 103-111. <http://dx.doi.org/10.4067/S0718-07642014000500015>, 2014.
- [38] I. Escamilla, L. Torres-Treviño, P. Perez y P. Zambrano, «A Comparison between Back Propagation and the Maximum Sensibility Neural Network to Surface Roughness Prediction in Machining of Titanium (Ti 6Al 4V) Alloy,» *en MICAI 2008 Lecture notes of Artificial Intelligence*, vol. 5713, pp. 1009-1019, 2008.
- [39] G. Sanmiguel, L. Gonzalez, L. Torres-Treviño y C. Guerra, «On-line learning in an embedded maximum sensibility neural network,» *en Artificial Intelligence (MICAI), 2012 11th Mexican International Conference*, pp. 75-79, 2012.

- [40] L. L. González Estrada, *Redes neuronales embebidas con aprendizaje en línea*, San Nicolás de los Garza: Doctoral dissertation, Universidad Autónoma de Nuevo León, 2013.
- [41] F. Torres, L. Neira y L. Torres-Treviño, «Análisis Criminal Inteligente Usando Eventos Geográficos y Temporales con la Red Neuronal de Máxima Sensibilidad,» *Daena: International Journal of Good Conscience*, pp. 92-100, 2015.
- [42] M. Aguilera-Ruiz, L. M. Torres-Treviño y J. A. R. Liñan, «Control by online learning using a maximum sensibility neural network,» *13th Mexican International Conference on Artificial Intelligence*, pp. 118-120, 2014.
- [43] E. Ordaz-Rivas, L. Torres-Treviño y A. Rodriguez-Liñan, «Control by Imitation Using a Maximum Sensibility Neural Network,» *Mexican International Conference on Artificial Intelligence*, pp. 306-315, 2015.
- [44] M. O. Salazar y L. M. Torres-Treviño, «Reconfigurable Logical Cells Using a Maximum Sensibility Neural Network,» *13th Mexican International Conference on Artificial Intelligence*, pp. 112-117, 2014.
- [45] A. M. MacEachren, *How maps work: representation, visualization, and design*, London: The Guilford Press, 2004.
- [46] S. Rendgen, J. Wiedemann, P. Ciuccarelli, R. S. Wurman, S. Rogers y N. Holmes, *Information graphics*. Cologne, Alemania: Taschen, 2012.
- [47] N. Yau, *Visualize this: the FlowingData guide to design, visualization, and statistics*, John Wiley & Sons, 2011.
- [48] C. N. Knaflic, *Storytelling with data: A data visualization guide for business professionals*, John Wiley & Sons, 2015.
- [49] Z. Gu, R. Eils y M. Schlesner, «Complex heatmaps reveal patterns and correlations in multidimensional genomic data,» *Bioinformatics*, pp. 2847-2849, 2016.
- [50] C. Perez-Llamas y N. Lopez-Bigas, «Gitoools: analysis and visualisation of genomic data using interactive heat-maps,» *PloS one*, 2011.
- [51] S. Putman, *Using Prototyping in Instructional Design*, TD at Work, 2014.
- [52] J. Nielsen, *Designing web usability: The practice of simplicity*, 1999.
- [53] J. Nielsen, «Usability inspection methods. In Conference companion on Human factors in computing systems,» *ACM*, pp. 413-414, 1994.
- [54] Y. Kimoto, H. Kiyama, S. Kawashima y Y. Enomoto, «Panel FRP para automóvil». Madrid, España Patente 2,416,130, 2013.

- [55] T. Kowalczyk, «SECURITY EYES FOR PREVENTION OF CAR ACCIDENTS». Dearborn Heights, Mich., United States Patente 4,641,136, 1987.
- [56] D. Breed, B. Township, M. County y F. Shokoohi, «Padding to reduce injuries in automobile accidents». Denville, N.J., United States Patente 5,098,124, 1992.
- [57] A. Colubi, «PERFECCIONAMIENTOS INTRODUCIDOS EN LOS SISTEMAS PREVENTIVOS DE ACCIDENTES DE VEHICULOS AUTOMOVILES». Madrid, España Patente WO 98/22310, 1998.
- [58] C. Steeg, «Sistema para protección de peatones para vehículos a motor». Madrid, España Patente 2,276,302, 2007.
- [59] J. Cho y J. Song, «CAR COLLISION PREVENTION APPARATUS AND METHOD USING DUAL PROCESSOR AND AUTOMATIC SENSOR SWITCHING FUNCTION». Rep. de Korea Patente 5,594,413, 1997.
- [60] F. Roldan, «SISTEMA AUTOMATICO PARA EVITAR ACCIDENTE EN VEHICULOS AUTOMOVILES POR EFECTO DEL SUEÑO EN EL CONDUCTOR». Madrid, España Patente WO 96/22897, 1996.
- [61] T. Mimar, «VEHICLE SECURITY WITH ACCIDENT NOTIFICATION AND EMBEDDED DRIVER ANALYTICS». Sunnyvale, CA, United States Patente US 9,491,420 B2, 2016.
- [62] J. Abellán, G. López y J. De Oña, «Analysis of traffic accident severity using decision rules via decision trees,» *Expert Systems with Applications*, vol. 40, nº 15, pp. 6047-6054, 2013.
- [63] R. Yu y M. Abdel-Aty, «Using hierarchical Bayesian binary probit models to analyze crash injury severity on high speed facilities with real-time traffic data,» *Accident Analysis & Prevention*, vol. 62, pp. 161-167, 2014.
- [64] E. Bayam, J. Liebowitz y W. Agresti, «Older drivers and accidents: A meta analysis and data mining application on traffic accident data,» *Expert Systems with Applications*, vol. 29, nº 3, pp. 598-629, 2005.
- [65] D. Delen, R. Sharda y M. Bessonov, «Identifying significant predictors of injury severity in traffic accidents using a series of artificial neural networks,» *Accident Analysis & Prevention*, vol. 38, nº 3, pp. 434-444, 2006.
- [66] M. S. R. Amin, A. Zareie y L. E. Amador-Jiménez, «Climate change modeling and the weather-related road accidents in Canada,» *transportation research part D: transport and environment*, vol. 32, pp. 171-183, 2014.
- [67] A. Theofilatos y G. Yannis, «A review of the effect of traffic and weather characteristics on road safety,» *Accident Analysis & Prevention*, vol. 72, pp. 244-256, 2014.

- [68] S. S. Durduran, « A decision making system to automatic recognize of traffic accidents on the basis of a GIS platform.,» *Expert Systems with Applications*, vol. 37, nº 12, pp. 7729-7736, 2010.
- [69] V. Milanés, J. Pérez, J. Godoy y E. Onieva, «A fuzzy aid rear-end collision warning/avoidance system,» *Expert Systems with Applications*, vol. 39, nº 10, pp. 9097-9107, 2012.
- [70] K. Jadaan, M. Al-Fayyad y H. Gammoh, «Prediction of Road Traffic Accidents in Jordan using Artificial Neural Network (ANN),» *Journal of Traffic and Logistics Engineering*, vol. 2, nº 2, pp. 92-94, 2014.
- [71] F. Ogwueleka, S. Misra, T. Ogwueleka y L. Fernandez-Sanz, «An Artificial Neural Network Model for Road Accident Prediction: A Case Study of a Developing Country,» *Acta Polytechnica Hungarica*, vol. 11, nº 5, pp. 177-197, 2014.
- [72] M. Yasin Çodur y A. Tortum, «An artificial neural network model for highway accident prediction: A case study of Erzurum, Turkey,» *PROMET-Traffic&Transportation*, vol. 27, nº 3, pp. 217-225, 2015.
- [73] F. Schimbinschi, L. Moreira-Matias, V. X. Nguyen y J. Bailey, «opology-regularized universal vector autoregression for traffic forecasting in large urban areas,» *Expert Systems with Applications*, vol. 82, pp. 301-316, 2017.
- [74] A. I. vCRASH, «Virtual CRASH Accident Reconstruction Software,» [En línea]. Available: <https://www.vcrashusa.com>. [Último acceso: Enero 2018].
- [75] C. GmbH, «AccidentSketch,» ClaimMS GmbH, [En línea]. Available: <http://www.accidentsketch.com/>. [Último acceso: Enero 2018].
- [76] D. Consultora, «Reconstructor Analítico de Colisiones de Tráfico,» [En línea]. Available: <https://ractt.com/>. [Último acceso: Enero 2018].
- [77] Google, «Google support,» [En línea]. Available: <https://support.google.com/maps>. [Último acceso: Enero 2018].
- [78] Waze, «Waze Local,» 2006-2018. [En línea]. Available: <https://www.waze.com>. [Último acceso: Enero 2018].
- [79] «Waycare,» Waycare, 2018. [En línea]. Available: <http://waycaretech.com>. [Último acceso: Mayo 2019].
- [80] J. M. Rubio, J. Pérez y N. Rodríguez, «Predicción de la gravedad de accidentes de tránsito utilizando redes neuronales artificiales,» de *III Conferencia Internacional en Ciencias Computacionales e Informáticas*, La Habana, Cuba, 2016.
- [81] CONAPRA, *Consejo Nacional para la Prevención de Accidentes*, 2016.

- [82] «An Artificial Neural Network Model for Road Accident Prediction: A Case Study of a Developing Country,» *Acta Polytechnica Hungarica*, vol. 11, nº 5, pp. 177-197, 2014.
- [83] S. Yau-Ren, T. Ching-Hsing, H. Yung-Hsiang y K. Yu-Ting, «The Application of Data Mining Technology to Build a Forecasting Model for Classification of Road Traffic Accidents,» *Mathematical Problems in Engineering*, p. 8, 2015.
- [84] S. Sikka, «Prediction of Road Accidents in Delhi using Back Propagation Neural Network Model,» *International Journal of Computer Science & Engineering Technology (IJCSET)*, vol. 5, nº 8, pp. 798-804, 2014.
- [85] K. Mohiuddin, J. Mao y A. K. Jain, «Artificial Neural Networks: A Tutorial,» *Computer*, pp. 31-44, 1996.
- [86] S. K. Esser, R. Appuswamy, P. Merolla, J. V. Arthur y D. S. Modha, «Backpropagation for energy-efficient neuromorphic computing. En Advances in Neural Information Processing Systems,» *En Advances in Neural Information Processing Systems*, pp. 1117-1125, 2015.
- [87] S. Shanmuganathan, Artificial neural network modelling: An introduction. En Artificial neural network modelling, Cham: Springer, 2016.
- [88] J. Tang, C. Deng y G.-B. Huang, «Extreme learning machine for multilayer perceptron,» *IEEE transactions on neural networks and learning systems*, vol. 27, nº 4, pp. 809-821, 2015.
- [89] W. Fuhl, T. Santini, G. Kasneci y E. Kasneci, «Pupilnet: Convolutional neural networks for robust pupil detection,» *arXiv*, 2016.
- [90] M. Prezioso, F. Merrih-Bayat, B. D. Hoskins, G. C. Adam, K. K. Likharev y D. B. Strukov, «Training and operation of an integrated neuromorphic network based on metal-oxide memristors,» *Nature*, vol. 521, nº 7550, p. 61, 2015.
- [91] D. G. Bhalke, C. R. Rao y D. S. Bormane, «Automatic musical instrument classification using fractional fourier transform based-MFCC features and counter propagation neural network,» *Journal of Intelligent Information Systems*, pp. 425-446, 2016.

Lista de abreviaturas utilizadas

AD	Arboles de Decisión
APPs	Aplicación de software
CP	Contra propagación
FBR	Función de Base Radial
GPS	Sistema de Posicionamiento Global
IA	Inteligencia Artificial
MD	Minería de Datos
MS	Máxima Sensibilidad
MVS	Máquinas de Vectores de Soporte
PM	Perceptrón Multicapa
PS	Perceptrón Simple
RB	Redes Bayesianas
RN	Red Neuronal
RNA	Red Neuronal Artificial
RNCP	Red Neuronal Contra Propagación
RNMS	Red Neuronal de Máxima Sensibilidad
RNRP	Red Neuronal de Retro Propagación
RP	Retro propagación
SE	Sistemas Expertos

Índice de Tablas

Tabla 1. Tipos de aprendizaje, adaptado de Flórez & Fernández, pág. 33-36	23
Tabla 2. Comparativa de estudios de Accidentes Automovilísticos	53
Tabla 3. Tipos de accidentes	64
Tabla 4. Causas de accidentes	65
Tabla 5. Horario	65
Tabla 6. Clima	65
Tabla 7. Causa del siniestro	65
Tabla 8. Vector de Salidas de la RNMS	68
Tabla 9. Ejemplo de Resultado de la Predicción	70
Tabla 10. Nombre de las variables en los experimentos	79
Tabla 11. Claves de patrones de entrada	81
Tabla 12. Estadística descriptiva de las variables	105
Tabla 13. Eficiencia de predicción, Experimento 1	140
Tabla 14. Eficiencia de predicción, Experimento 2-1	149
Tabla 15. Eficiencia de predicción, Experimento 2-2	150

Índice de Figuras

Figura 1. Estadísticas INEGI 2013 para accidentes de tráfico terrestre en México	9
Figura 2. Estadísticas INEGI 2013 para accidentes de tráfico terrestre en Nuevo León	9
Figura 3. Modelo básico de una Neurona Biológica	15
Figura 4. Diagrama de capas de neuronas	17
Figura 5. Modelo básico de una neurona artificial	18
Figura 6. Función lineal a tramos	20
Figura 7. Función escalón	20
Figura 8. Función sigmoidea	21
Figura 9. Función gaussiana	21
Figura 10. Organización del Perceptrón, adaptado de Rosenblatt (1958), pág. 389	25
Figura 11: Arquitectura básica de RNCP	27
Figura 12. Arquitectura de la RNCP	28
Figura 13: Arquitectura de la RNMS	32
Figura 14. Diagrama fase entrenamiento de RNMS	33
Figura 15. “Panel FRP para automóvil”. Imágenes tomadas de [54]	43
Figura 16. “Security eyes for prevention of car accidents”. Imagen tomada de [55]	44
Figura 17. “Padding to reduce injuries in automobile accidents”, tomada de [56]	45
Figura 18. “Perfeccionamientos introducidos en los sistemas preventivos de accidentes en vehículos automóviles”. Imagen tomada de [57]	45
Figura 19. “Sistema para protección de peatones para vehículos a motor”. Imagen tomada de [58]	46

Figura 20. “Car colision prevention apparatus and method using dual processor and automatic sensor switching function”. Imagen tomada de [59].....	47
Figura 21. “Sistema automático para evitar accidentes en vehículos automóviles por efecto del sueño en el conductor”. Imagen tomada de [60]	48
Figura 22. “Vehicle security with accident notification and embedded driver analytics”. Imagen tomada de [61]	49
Figura 23. Imagen tomada de https://www.vcrashusa.com/vc4 en enero 2018	55
Figura 24. Imagen tomada de http://www.accidentsketch.com/ en enero 2018	55
Figura 25. Imagen tomada de https://ractt.com en enero 2018.....	56
Figura 26. Imagen tomada de https://ractt.com en enero de 2018	56
Figura 27. Imagen ejemplo de Google Maps.....	57
Figura 28. Imagen tomada de https://play.google.com en enero 2018	58
Figura 29. Imagen tomada de https://www.reviewjournal.com/traffic/las-vegas-uses-artificial-intelligence-to-reduce-i-15-crashes-1531260 en mayo 2019	59
Figura 30. Arquitectura utilizada por el sistema predictivo	66
Figura 31. Ejemplo arquitectura RN con variables propuestas.....	67
Figura 32. Diagrama de Preparación de datos.....	71
Figura 33. Diagrama de análisis y predicción.....	72
Figura 34. Diagrama de re-alimentación de datos.....	73
Figura 35. Nuevo León. Imagen tomada de cuentame.inegi.org.mx en 2019	76
Figura 36. Patrón de entrada 1	80
Figura 37. Patrón de entrada 2	80
Figura 38. Patrón de entrada 3	80
Figura 39. Patrón de entrada 4	80
Figura 40. Patrón de entrada 5	80
Figura 41. Patrón de entrada 6	80
Figura 42. Patrón de entrada 7	80
Figura 43. Prototipo a mano, encabezado	84
Figura 44. Prototipo a mano, tablero de control	85
Figura 45. Prototipo a mano, mapa táctico	85
Figura 46. Prototipo a mano, mapa interactivo.....	86
Figura 47. Prototipo a mano, datos	86
Figura 48. Cuestionario de usabilidad pág. 1	88
Figura 49. Cuestionario de usabilidad pág. 2	89
Figura 50. Cuestionario de usabilidad pág. 3	90
Figura 51. Gráfica de Accidentes Automovilísticos en Nuevo León por Mes, 2017	91
Figura 52. Gráfica de Accidentes Automovilísticos en Monterrey por Mes, 2017	92
Figura 53. Gráfica de Accidentes Automovilísticos en Apodaca por Mes, 2017.....	92
Figura 54. Gráfica de Accidentes Automovilísticos en Guadalupe por Mes, 2017.....	93
Figura 55. Gráfica de Accidentes Automovilísticos en Nuevo León por Día, 2017	93
Figura 56. Gráfica de Accidentes Automovilísticos en Monterrey por Día, 2017	94
Figura 57. Gráfica de Accidentes Automovilísticos en Apodaca por Día, 2017	94
Figura 58. Gráfica de Accidentes Automovilísticos en Guadalupe por Día, 2017	95
Figura 59. Gráfica de Accidentes Automovilísticos en Nuevo León por Tipo, 2017.....	95
Figura 60. Gráfica de Accidentes Automovilísticos en Monterrey por Tipo, 2017	96

Figura 61. Gráfica de Accidentes Automovilísticos en Apodaca por Tipo, 2017	96
Figura 62. Gráfica de Accidentes Automovilísticos en Guadalupe por Tipo, 2017.....	97
Figura 63. Gráfica de Accidentes Automovilísticos en Nuevo León por Causa, 2017... 97	97
Figura 64. Gráfica de Accidentes Automovilísticos en Monterrey por Causa, 2017	98
Figura 65. Gráfica de Accidentes Automovilísticos en Apodaca por Causa, 2017.....	98
Figura 66. Gráfica de Accidentes Automovilísticos en Guadalupe por Causa, 2017.....	99
Figura 67. Gráfica de Accidentes Automovilísticos en Nuevo León por Horario, 2017 .	99
Figura 68. Gráfica de Accidentes Automovilísticos en Monterrey por Horario, 2017...	100
Figura 69. Gráfica de Accidentes Automovilísticos en Apodaca por Horario en, 2017	100
Figura 70. Gráfica de Accidentes Automovilísticos en Guadalupe por Horario, 2017 .	101
Figura 71. Gráfica de Accidentes Automovilísticos en Nuevo León por Causa del siniestro, 2017.....	101
Figura 72. Gráfica de Accidentes Automovilísticos en Monterrey por Causa del siniestro, 2017.....	102
Figura 73. Gráfica de Accidentes Automovilísticos en Apodaca por Causa del siniestro, 2017.....	102
Figura 74. Gráfica de Accidentes Automovilísticos en Guadalupe por Causa del siniestro, 2017.....	103
Figura 75. Gráfica de Accidentes Automovilísticos en Nuevo León por Clima, 2017 ..	103
Figura 76. Gráfica de Accidentes Automovilísticos en Monterrey por Clima, 2017.....	104
Figura 77. Gráfica de Accidentes Automovilísticos en Apodaca por Clima, 2017	104
Figura 78. Gráfica de Accidentes Automovilísticos en Guadalupe por Clima, 2017	105
<i>Figura 79. Gráficas de Horario y Causa del accidente en Nuevo León, 2017</i>	<i>106</i>
Figura 80. Gráfica de Horario y Causa del accidente en Monterrey, 2017	106
Figura 81. Gráfica de Horario y Causa del accidente en Apodaca, 2017	107
Figura 82. Gráfica de Horario y Causa del accidente en Guadalupe, 2017	107
Figura 83. Gráfica de Horario y Tipo de accidente en Nuevo León, 2017	108
<i>Figura 84. Gráfica de Horario y Tipo de accidente en Monterrey, 2017</i>	<i>109</i>
Figura 85. Gráfica de Horario y Tipo de accidente en Apodaca, 2017	109
Figura 86. Gráfica de Horario y Tipo de accidente en Guadalupe, 2017	110
<i>Figura 87. Gráfica de Causa y Mes del accidente en Nuevo León, 2017.....</i>	<i>110</i>
<i>Figura 88. Gráfica de Causa y Mes del accidente en Monterrey, 2017</i>	<i>111</i>
<i>Figura 89. Gráfica de Causa y Mes del accidente en Apodaca, 2017.....</i>	<i>111</i>
<i>Figura 90. Gráfica de Causa y Mes del accidente en Guadalupe, 2017.....</i>	<i>112</i>
Figura 91. Gráfica de Causa y Día del accidente en Nuevo León, 2017	112
Figura 92. Gráfica de Causa y Día del accidente en Monterrey, 2017	113
Figura 93. Gráfica de Causa y Día del accidente en Apodaca, 2017	113
Figura 94. Gráfica de Causa y Día del accidente en Guadalupe, 2017	114
Figura 95. Gráfica de Tipo y Mes del accidente en Nuevo León, 2017.....	114
Figura 96. Gráfica de Tipo y Mes del accidente en Monterrey, 2017	115
Figura 97. Gráfica de Tipo y Mes del accidente en Apodaca, 2017	115
Figura 98. Gráfica de Tipo y Mes del accidente en Guadalupe, 2017.....	116
Figura 99. Gráfica de Tipo y Día del accidente en Nuevo León, 2017	116
Figura 100. Gráfica de Tipo y Día del accidente en Monterrey, 2017	117
Figura 101. Gráfica de Tipo y Día del accidente en Apodaca, 2017	117

Figura 102. Gráfica de Tipo y Día del accidente en Guadalupe, 2017	118
Figura 103. Gráfica de Causa y Clima del accidente en Nuevo León, 2017	118
Figura 104. Gráfica de Causa y Clima del accidente en Monterrey, 2017	119
Figura 105. Gráfica de Causa y Clima del accidente en Apodaca, 2017	119
Figura 106. Gráfica de Causa y Clima del accidente en Guadalupe, 2017	120
Figura 107. Gráfica de Tipo y Clima del accidente en Nuevo León, 2017	120
Figura 108. Gráfica de Tipo y Clima del accidente en Monterrey, 2017	121
Figura 109. Gráfica de Tipo y Clima del accidente en Apodaca, 2017	121
Figura 110. Gráfica de Tipo y Clima del accidente en Guadalupe, 2017	122
Figura 111. Gráfica de Causa y Horario del accidente en Nuevo León, 2017	122
Figura 112. Gráfica de Causa y Horario del accidente en Monterrey, 2017	123
Figura 113. Gráfica de Causa y Horario del accidente en Apodaca, 2017	123
Figura 114. Gráfica de Causa y Horario del accidente en Guadalupe, 2017	124
Figura 115. Gráfica de Causa y Día del accidente en Nuevo León, 2017	124
Figura 116. Gráfica de Causa y Día del accidente en Monterrey, 2017	125
Figura 117. Gráfica de Causa y Día del accidente en Apodaca, 2017	125
Figura 118. Gráfica de Causa y Día del accidente en Guadalupe, 2017	126
Figura 119. Gráfica de Causa y Mes del accidente en Nuevo León, 2017	126
Figura 120. Gráfica de Causa y Mes del accidente en Monterrey, 2017	127
Figura 121. Gráfica de Causa y Mes del accidente en Apodaca, 2017	127
Figura 122. Gráfica de Causa y Mes del accidente en Guadalupe, 2017	128
Figura 123. Gráfica resultante del patrón de entrada BD1P1L1	128
Figura 124. Gráfica resultante del patrón de entrada BD1P1L2	129
Figura 125. Gráfica resultante del patrón de entrada BD1P1L3	129
Figura 126. Gráfica resultante del patrón de entrada BD1P2L1	130
Figura 127. Gráfica resultante del patrón de entrada BD1P2L2	130
Figura 128. Gráfica resultante del patrón de entrada BD1P2L3	131
Figura 129. Gráfica resultante del patrón de entrada BD1P3L1	131
Figura 130. Gráfica resultante del patrón de entrada BD1P3L2	132
Figura 131. Gráfica resultante del patrón de entrada BD1P3L3	132
Figura 132. Gráfica resultante del patrón de entrada BD1P4L1	133
Figura 133. Gráfica resultante del patrón de entrada BD1P4L2	133
Figura 134. Gráfica resultante del patrón de entrada BD1P4L3	134
Figura 135. Gráfica resultante del patrón de entrada BD1P5L1	134
Figura 136. Gráfica resultante del patrón de entrada BD1P5L2	135
Figura 137. Gráfica resultante del patrón de entrada BD1P5L3	135
Figura 138. Gráfica resultante del patrón de entrada BD1P6L1	136
Figura 139. Gráfica resultante del patrón de entrada BD1P6L2	136
Figura 140. Gráfica resultante del patrón de entrada BD1P6L3	137
Figura 141. Gráfica resultante del patrón de entrada BD1P7L1	137
Figura 142. Gráfica resultante del patrón de entrada BD1P7L2	138
Figura 143. Gráfica resultante del patrón de entrada BD1P7L3	138
Figura 144. Gráfica resultante del patrón de entrada BD1P8L1	139
Figura 145. Gráfica resultante del patrón de entrada BD1P8L2	139

Figura 146. Gráfica resultante del patrón de entrada BD1P8L3.....	140
Figura 147. Gráfica resultante del patrón de entrada BD2P1L1.....	142
Figura 148. Gráfica resultante del patrón de entrada BD2P1L2.....	142
Figura 149. Gráfica resultante del patrón de entrada BD2P1L3.....	142
Figura 150. Gráfica resultante del patrón de entrada BD2P2L1.....	143
Figura 151. Gráfica resultante del patrón de entrada BD2P2L2.....	143
Figura 152. Gráfica resultante del patrón de entrada BD2P2L3.....	144
Figura 153. Gráfica resultante del patrón de entrada BD2P3L1.....	144
Figura 154. Gráfica resultante del patrón de entrada BD2P3L2.....	145
Figura 155. Gráfica resultante del patrón de entrada BD2P3L3.....	145
Figura 156. Gráfica resultante del patrón de entrada BD2P4L1.....	146
Figura 157. Gráfica resultante del patrón de entrada BD2P4L2.....	146
Figura 158. Gráfica resultante del patrón de entrada BD2P4L3.....	147
Figura 159. Gráfica resultante del patrón de entrada BD2P5L9.....	147
Figura 160. Gráfica resultante del patrón de entrada BD2P6L9.....	148
Figura 161. Gráfica resultante del patrón de entrada BD2P7L9.....	148
Figura 162. Gráfica resultante del patrón de entrada BD2P8L9.....	149
Figura 163. Gráfica de promedio de Efectividad por Patrón exp 1	151
Figura 164. Gráfica de Efectividad patrones de entrada de Causa del Accidente	151
Figura 165. Gráfica de Efectividad patrones de entrada del Tipo de Accidente	152
Figura 166. Gráfica de promedio de Efectividad por Patrón exp 2-1	152
Figura 167. Gráfica de promedio de Efectividad por Patrón exp 2-2	153
Figura 168. Resultados preliminares pruebas de usabilidad. Contenido	154
Figura 169. Resultados preliminares pruebas de usabilidad. Utilidad.....	154
Figura 170. Resultados preliminares pruebas de usabilidad. Navegación	155
Figura 171. Mapa Interactivo.....	156
Figura 172. Mapa Interactivo con menús desplegados	157
Figura 173. Mapa con histórico de datos	157
Figura 174. Crear cuadrantes	157
Figura 175. Monterrey dividido en once cuadrantes	158
Figura 176. Carga de Datos	159
Figura 177. Ejecución de NR para Predicción.....	159
Figura 178. Tablero de Control	160
Figura 179. Mapa con predicción sobre cuadrantes	160
Figura 180. Mapa táctico detalle del evento	161
Figura 181. Resultados finales pruebas de usabilidad. Contenido	162
Figura 182. Resultados finales pruebas de usabilidad. Utilidad	162
Figura 183. Resultados finales pruebas de usabilidad. Navegación	163

Índice de Ecuaciones

Ecuación 1	18
Ecuación 2	18
Ecuación 3	20
Ecuación 4	20
Ecuación 5	21
Ecuación 6	21
Ecuación 7	26
Ecuación 8	34
Ecuación 9	34
Ecuación 10	36
Ecuación 11	36
Ecuación 12	37
Ecuación 13	37
Ecuación 14	68
Ecuación 15	69
Ecuación 16	78

Índice de Algoritmos

Algoritmo 1. Fase Entrenamiento - crear estructura de la RNMS	34
Algoritmo 2. Fase Activación de la RNMS	35
Algoritmo 3. Fase de aprendizaje RNMS	37
Algoritmo 4. Fase de pruebas de la RNMS	38

Índice de Anexos

Anexo 1. Ejemplo de los datos recabados INEGI para accidentes de tráfico terrestre	182
Anexo 2. Extractos de información INEGI año 2017 por variable	182
Anexo 3. Ejemplo de los datos recabados Axa Seguros en 2017	184
Anexo 4. Extractos de información Axa Seguros año 2017 por variable	185

ANEXOS

Anexo 1. Ejemplo de los datos recabados INEGI para accidentes de tráfico terrestre

1.	COBERTURA	ID_ENTIDAD	ID_MUNICIPIO	MES	ID_HORA	ID_MINUTO	ID_DIA	DIASEMANA	URBANA	SUBURBANA	TIPACC	CAUSACC	SEJO	ALENT	CONTORON	ID_EDAD	CLASACC	ESTATUS
2	Municipal	02	002	2015 Enero	18	10	9	Viernes	Accidente en Sin accidente	Colisión con Conductor	Parimentada	Mujer	No	Se ignora	Se ignora	53	No fatal	Cifras preliminares
3	Municipal	02	004	2015 Enero	1	40	1	Jueves	Accidente en Sin accidente	Colisión con Conductor	Parimentada	Mujer	No	Se ignora	Se ignora	27	Solo Daños	Cifras preliminares
4	Municipal	02	004	2015 Enero	15	40	3	Sábado	Accidente en Sin accidente	Cada de pas Conductor	Parimentada	Hombre	No	Se ignora	Se ignora	23	No fatal	Cifras preliminares
5	Municipal	02	004	2015 Enero	5	40	3	Sábado	Accidente en Sin accidente	Colisión con Conductor	Parimentada	Hombre	Si	Se ignora	Se ignora	35	Solo Daños	Cifras preliminares
6	Municipal	02	004	2015 Enero	0	0	24	Sábado	Accidente en Sin accidente	Cada de pas Conductor	Parimentada	Hombre	No	Se ignora	Se ignora	27	No fatal	Cifras preliminares
7	Municipal	02	004	2015 Enero	8	10	26	Lunes	Accidente en Sin accidente	Colisión con Conductor	Parimentada	Hombre	No	Se ignora	Se ignora	37	Solo Daños	Cifras preliminares
8	Municipal	02	004	2015 Enero	5	30	24	Sábado	Accidente en Sin accidente	Colisión con Conductor	Parimentada	Hombre	No	No	No	20	No fatal	Cifras preliminares
9	Municipal	02	004	2015 Enero	17	20	15	Jueves	Accidente en Sin accidente	Colisión con Conductor	Parimentada	Hombre	No	Se ignora	Se ignora	43	Solo Daños	Cifras preliminares
10	Municipal	02	004	2015 Enero	14	20	20	Martes	Accidente en Sin accidente	Colisión con Conductor	Parimentada	Hombre	No	Se ignora	Se ignora	36	Solo Daños	Cifras preliminares
11	Municipal	02	004	2015 Enero	18	20	24	Sábado	Sin accidente	Accidente en Sin accidente	Colisión con Conductor	Parimentada	Hombre	Si	Se ignora	45	No fatal	Cifras preliminares
12	Municipal	02	004	2015 Enero	20	55	26	Lunes	Accidente en Sin accidente	Colisión con Conductor	Parimentada	Hombre	No	Se ignora	Se ignora	47	Solo Daños	Cifras preliminares
13	Municipal	02	004	2015 Enero	19	40	24	Sábado	Accidente en Sin accidente	Colisión con Conductor	Parimentada	Hombre	Si	Se ignora	Se ignora	44	Solo Daños	Cifras preliminares
14	Municipal	02	004	2015 Enero	0	20	27	Martes	Accidente en Sin accidente	Invertido Conductor	Parimentada	Hombre	No	Se ignora	Se ignora	20	Solo Daños	Cifras preliminares
15	Municipal	02	004	2015 Enero	21	29	24	Sábado	Accidente en Sin accidente	Cada de pas Conductor	Parimentada	Hombre	Si	Se ignora	Se ignora	35	No fatal	Cifras preliminares
16	Municipal	02	004	2015 Enero	10	10	22	Jueves	Accidente en Sin accidente	Colisión con Conductor	Parimentada	Mujer	No	Se ignora	Se ignora	43	Solo Daños	Cifras preliminares
17	Municipal	02	004	2015 Enero	9	0	27	Martes	Accidente en Sin accidente	Colisión con Conductor	Parimentada	Hombre	No	Se ignora	Se ignora	46	No fatal	Cifras preliminares
18	Municipal	02	004	2015 Enero	3	0	25	Domingo	Accidente en Sin accidente	Colisión con Conductor	Parimentada	Hombre	Si	Se ignora	Se ignora	40	Solo Daños	Cifras preliminares
19	Municipal	02	004	2015 Enero	12	20	27	Martes	Accidente en Sin accidente	Salida del Car Conductor	Parimentada	Hombre	No	Se ignora	Se ignora	48	No fatal	Cifras preliminares
20	Municipal	02	004	2015 Enero	17	2	16	Viernes	Accidente en Sin accidente	Colisión con Conductor	Parimentada	Hombre	No	Se ignora	Se ignora	55	Solo Daños	Cifras preliminares
21	Municipal	02	004	2015 Enero	17	0	3	Sábado	Accidente en Sin accidente	Colisión con Conductor	Parimentada	Hombre	Si	Se ignora	Se ignora	48	Solo Daños	Cifras preliminares
22	Municipal	02	004	2015 Enero	6	15	5	Lunes	Accidente en Sin accidente	Colisión con Conductor	Parimentada	Se fugó	Se ignora	Se ignora	Se ignora	0	No fatal	Cifras preliminares
23	Municipal	02	004	2015 Enero	21	18	27	Martes	Accidente en Sin accidente	Colisión con Conductor	Parimentada	Hombre	No	Se ignora	Se ignora	31	Solo Daños	Cifras preliminares
24	Municipal	02	004	2015 Enero	11	25	22	Jueves	Accidente en Sin accidente	Colisión con Conductor	Parimentada	Hombre	No	Se ignora	Se ignora	20	No fatal	Cifras preliminares
25	Municipal	02	004	2015 Enero	11	35	28	Miércoles	Accidente en Sin accidente	Colisión con Conductor	Parimentada	Hombre	No	Se ignora	Se ignora	36	Solo Daños	Cifras preliminares
26	Municipal	02	004	2015 Enero	12	0	25	Domingo	Accidente en Sin accidente	Colisión con Conductor	Parimentada	Hombre	No	Se ignora	Se ignora	31	Solo Daños	Cifras preliminares
27	Municipal	02	004	2015 Enero	20	20	25	Domingo	Accidente en Sin accidente	Colisión con Conductor	Parimentada	Hombre	Si	Se ignora	Se ignora	22	Solo Daños	Cifras preliminares
28	Municipal	02	004	2015 Enero	18	20	19	Lunes	Sin accidente	Accidente en Sin accidente	Colisión con Conductor	Parimentada	Se fugó	Se ignora	Se ignora	0	No fatal	Cifras preliminares
29	Municipal	02	004	2015 Enero	14	30	17	Sábado	Accidente en Sin accidente	Colisión con Conductor	Parimentada	Hombre	No	Se ignora	Se ignora	51	Solo Daños	Cifras preliminares
30	Municipal	02	004	2015 Enero	10	40	26	Lunes	Accidente en Sin accidente	Colisión con Conductor	Parimentada	Hombre	No	Se ignora	Se ignora	25	Solo Daños	Cifras preliminares
31	Municipal	02	004	2015 Enero	17	20	23	Viernes	Accidente en Sin accidente	Colisión con Conductor	Parimentada	Hombre	No	Se ignora	Se ignora	22	No fatal	Cifras preliminares
32	Municipal	02	004	2015 Enero	13	9	20	Martes	Accidente en Sin accidente	Colisión con Conductor	Parimentada	Mujer	No	Se ignora	Se ignora	28	Solo Daños	Cifras preliminares
33	Municipal	02	004	2015 Enero	15	10	20	Martes	Accidente en Sin accidente	Colisión con Conductor	Parimentada	Mujer	No	Se ignora	Se ignora	45	Solo Daños	Cifras preliminares
34	Municipal	02	004	2015 Enero	22	30	23	Viernes	Accidente en Sin accidente	Colisión con Conductor	Parimentada	Hombre	Si	Se ignora	Se ignora	40	Solo Daños	Cifras preliminares
35	Municipal	02	004	2015 Enero	5	40	27	Martes	Accidente en Sin accidente	Colisión con Conductor	Parimentada	Hombre	No	Se ignora	Se ignora	30	Solo Daños	Cifras preliminares
36	Municipal	02	004	2015 Enero	16	10	20	Martes	Accidente en Sin accidente	Colisión con Conductor	Parimentada	Hombre	No	Se ignora	Se ignora	73	Solo Daños	Cifras preliminares
37	Municipal	02	004	2015 Enero	1	0	4	Domingo	Accidente en Sin accidente	Colisión con Conductor	Parimentada	Hombre	Si	Se ignora	Se ignora	46	Solo Daños	Cifras preliminares
38	Municipal	02	004	2015 Enero	20	0	3	Sábado	Accidente en Sin accidente	Colisión con Conductor	Parimentada	Se fugó	Se ignora	Se ignora	Se ignora	0	No fatal	Cifras preliminares
39	Municipal	02	004	2015 Enero	14	0	3	Sábado	Accidente en Sin accidente	Colisión con Conductor	Parimentada	Mujer	No	Se ignora	Se ignora	19	Solo Daños	Cifras preliminares
40	Municipal	02	004	2015 Enero	16	35	2	Viernes	Accidente en Sin accidente	Colisión con Conductor	Parimentada	Mujer	No	Se ignora	Se ignora	32	Solo Daños	Cifras preliminares
41	Municipal	02	004	2015 Enero	13	45	27	Martes	Accidente en Sin accidente	Cada de pas Conductor	Parimentada	Hombre	No	Se ignora	Se ignora	46	No fatal	Cifras preliminares

Anexo 2. Extractos de información INEGI año 2017 por variable

CIUDAD	(Todas)
MES	total
01	6246
02	6136
03	6626
04	5727
05	6231
06	6444
07	6200
08	6765
09	6503
10	7065
11	6983
12	6694
Total general	77620

Fecha(mes), Nuevo León

CIUDAD	Monterrey
MES	total
01	2286
02	2184
03	2459
04	2109
05	2146
06	2180
07	2145
08	2417
09	2313
10	2646
11	2605
12	2605
Total general	28095

Fecha (mes), Monterrey

CIUDAD	Apodaca
MES	total
01	420
02	388
03	348
04	306
05	302
06	374
07	420
08	368
09	357
10	358
11	400
12	336
Total general	4377

Fecha (mes), Apodaca

CIUDAD	Guadalupe
MES	total
01	612
02	495
03	553
04	463
05	482
06	569
07	591
08	635
09	602
10	715
11	643
12	610
Total general	6970

Fecha (mes), Guadalupe

CIUDAD	(Todas)
DIA	total
Domingo	8607
Lunes	10657
Martes	11755
Miércoles	11443
Jueves	11305
Viernes	12635
Sábado	11218
Total general	77620

Fecha (día), Nuevo León

CIUDAD	Monterrey
DIA	total
Domingo	2487
Lunes	3944
Martes	4391
Miércoles	4317
Jueves	4282
Viernes	4767
Sábado	3907
Total general	28095

Fecha (día), Monterrey

CIUDAD	Apodaca
DIA	total
Domingo	644
Lunes	577
Martes	594
Miércoles	562
Jueves	576
Viernes	681
Sábado	743
Total general	4377

Fecha (día), Apodaca

CIUDAD	Guadalupe
DIA	total
Domingo	916
Lunes	947
Martes	1004
Miércoles	973
Jueves	969
Viernes	1088
Sábado	1073
Total general	6970

Fecha (día), Guadalupe

CIUDAD	(Todas)
TIPO	total
Caída de pasajero	258
Colisión con animal	55
Colisión con ferrocarril	60
Colisión con objeto fijo	11778
Colisión con peatón (atropellamiento)	1979
Colisión con vehículo automotor	61790
Incendio	75
Salida del camino	695
Volcadura	930
Total general	77620

Tipo de accidente, Nuevo León

CIUDAD	Monterrey
TIPO	total
Caída de pasajero	98
Colisión con animal	5
Colisión con objeto fijo	4673
Colisión con peatón (atropellamiento)	745
Colisión con vehículo automotor	22113
Incendio	33
Salida del camino	32
Volcadura	396
Total general	28095

Tipo de accidente, Monterrey

CIUDAD	Apodaca
TIPO	total
Caída de pasajero	29
Colisión con animal	4
Colisión con objeto fijo	916
Colisión con peatón (atropellamiento)	150
Colisión con vehículo automotor	3193
Incendio	4
Salida del camino	37
Volcadura	44
Total general	4377

Tipo de accidente, Apodaca

CIUDAD	Guadalupe
TIPO	total
Caída de pasajero	29
Colisión con ferrocarril	3
Colisión con objeto fijo	1446
Colisión con peatón (atropellamiento)	274
Colisión con vehículo automotor	5153
Salida del camino	43
Volcadura	22
Total general	6970

Tipo de accidente, Guadalupe

CIUDAD	(Todas)
CAUSA	total
Conductor	67704
Falla del vehículo	637
Mala condición del camino	6576
Otra	2339
Peatón o pasajero	364
Total general	77620

Causa, Nuevo León

CIUDAD	Monterrey
CAUSA	total
Conductor	26215
Falla del vehículo	297
Mala condición del camino	923
Otra	372
Peatón o pasajero	288
Total general	28095

Causa, Monterrey

CIUDAD	Apodaca
CAUSA	total
Conductor	4322
Falla del vehículo	11
Mala condición del camino	23
Otra	12
Peatón o pasajero	9
Total general	4377

Causa, Apodaca

CIUDAD	Guadalupe
CAUSA	total
Conductor	1764
Mala condición del camino	5202
Otra	4
Total general	6970

Causa, Guadalupe

CIUDAD	(Todas)
HORARIO	total
DIA	26481
MADRUGADA	10879
NOCHE	14370
TARDE	25890
Total general	77620

Horario, Nuevo León

CIUDAD	Monterrey
HORARIO	total
DIA	9759
MADRUGADA	2713
NOCHE	5288
TARDE	10335
Total general	28095

Horario, Monterrey

CIUDAD	Apodaca
HORARIO	total
DIA	1288
MADRUGADA	738
NOCHE	1029
TARDE	1322
Total general	4377

Horario, Apodaca

CIUDAD	Guadalupe
HORARIO	total
DIA	2022
MADRUGADA	1011
NOCHE	1608
TARDE	2329
Total general	6970

Horario, Guadalupe

Anexo 3. Ejemplo de los datos recabados Axa Seguros en 2017

A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S	T	U	V	
the_geo	relacion	the_geo	sinistro	latitud	longitud	codigo	calle	colonia	causa	tipo_veh	color	modelo	nivel	punto	an	mes	da	num	da	hora	estado	ciudad
0101000021	W	0101000021	381742	54.61007	25.40079	1267	CARRETER CELAYA	COLUSON	Auto	ROJO	2011	Sin	da	Coite	2017	ABRIL	6	JUEVES	19	GUANAJUATO CELAYA		
0101000021	W	0101000021	458089	51.18569	10.45153	99886	ASIGNARF ASIGNARF	COLUSON	Camión	GRIS	2015	Sin	da	Coite	2017	AGOSTO	24	JUEVES	13	MAXIMO TOLUCA		
0101000021	W	0101000021	4144330	48.55739	4.25185	29280	EPHIAN DEL LA ESPERAN	COLUSON	Camión	BLANCO	2007	Sin	da	Coite	2017	AGOSTO	16	MIÉRCOLES	13	QUERÉTARO EL MARQUÍ		
0101000021	W	0101000021	3638052	48.28906	4.070754	10430	LENNIS 33	ANZURES	COLUSON	Auto	AZUL	2000	Bajo	Costado de	2017	ABRIL	20	JUEVES	21	Ciudad de MIGUEL H		
0101000021	W	0101000021	4233897	47.82759	35.16776	69000	PLUTARCO LA JOYA	COLUSON	Auto	BLANCO	2010	Sin	da	Tasero	2017	OCTUBRE	6	VIERNES	1	CIUDAD DE GUADALUPE		
0101000021	W	0101000021	4178377	44.7086	37.63259	353994	PERIFERNCI	Sindato	COLUSON	Auto	NEGRO	2006	Sin	da	Tasero	2017	JULIO	31	LUNES	18	YUCATÁN MÉRIDA	
0101000021	Conductor	0101000021	3948019	43.55491	-5.91948	33402	llano del ce	coliranchito	COLUSON	Auto	GRIS	2016	Bajo	Coite	2017	ABRIL	26	MIÉRCOLES	15	TAMALUPO REYNOSA		
0101000021	Conductor	0101000021	3948019	43.55491	-5.91948	33402	llano del ce	coliranchito	COLUSON	Auto	GRIS	2016	Bajo	Coite	2017	ABRIL	26	MIÉRCOLES	15	TAMALUPO REYNOSA		
0101000021	W	0101000021	4349355	43.07588	-76.1053	13206	REFORMA	W	COLUSON	Auto	BLANCO	2010	Bajo	Costado de	2017	DICIEMBRE	12	MARTES	15	TABASCO CUNDUAC		
0101000021	W	0101000021	381031	42.5972	-5.58822	24006	Calle Ca	do VALLE DEL	COLUSON	Auto	VINO	2014	Bajo	Costado de	2017	FEBRERO	11	SABADO	18	GUANAJUATO LEON		
0101000021	W	0101000021	4084996	42.57847	-5.66434	24381	Autov	Aa RI Enlano Za	COLUSON	Auto	ARENA	2005	Sin	da	Coite	2017	JULIO	14	VIERNES	10	GUANAJUATO LEON	
0101000021	W	0101000021	4150736	42.45951	-2.45018	6550	LA RICA	2 VALLE DEL	COLUSON	Auto	GUINDA	1981	Sin	da	Coite	2017	AGOSTO	19	SABADO	20	CIUDAD DE SALINAS V	
0101000021	W	0101000021	3688930	42.33822	-7.86451	32003	horacio	polanco	COLUSON	Auto	blanca	2015	Bajo	Coite	2017	MARZO	22	MIÉRCOLES	16	Ciudad de MIGUEL H		
0101000021	W	0101000021	4028734	42.32537	-122.872	97501	VALLOPEZ	W	COLUSON	Camión	AMARILLO	2005	Sin	da	Tasero	2017	JUNIO	12	LUNES	10	MAXIMO TOLUCA	
0101000021	W	0101000021	4104071	42.19023	-7.78973	32680	ICD	ATL Del Real	COLUSON	W	BLANCO	2012	Medio	Frontal	2017	JULIO	25	MARTES	0	CHIHUAHUA CO JUAREZ		
0101000021	W	0101000021	4183228	42.19018	-7.78974	32680	Estad	de Del Real	COLUSON	W	W	W	W	W	W	2017	AGOSTO	1	MARTES	6	CHIHUAHUA CO JUAREZ	
0101000021	W	0101000021	4234336	41.82339	1.891082	8650	Carreeta 5	COCEPO	COLUSON	Camión	BLANCO	1980	Sin	da	Tasero	2017	OCTUBRE	6	VIERNES	9	COAHUILA SALTILLO	
0101000021	W	0101000021	3881088	40.96933	-5.66795	37007	Calle Mu	de W	COLUSON	W	W	W	W	W	W	2017	MARZO	17	VIERNES	19	GUANAJUATO SALAMAN	
0101000021	W	0101000021	4363632	40.63249	-3.16077	18005	Calle Zarag	CRUZ DEL	COLUSON	Camión	BLANCO	2012	Sin	da	Costado de	2017	DICIEMBRE	20	MIÉRCOLES	12	JALISCO TLAJUEPA	
0101000021	W	0101000021	3680147	40.43316	-3.68854	28010	RUBEN DAI	POLANCO	COLUSON	Camión	VERDE	2012	Sin	da	Costado de	2017	MARZO	7	MARTES	13	Ciudad de MIGUEL H	
0101000021	Tercero Co	0101000021	3685181	40.4165	-82.4853	43050	ENATENCIO	ENATENCIO	COLUSON	Auto	ROJO	2015	Bajo	Coite	2017	MAYO	7	DOMINGO	14	CAMPECHE CARPEN		
0101000021	Conductor	0101000021	3685181	40.4165	-82.4853	43050	ENATENCIO	ENATENCIO	COLUSON	Auto	ROJO	2015	Bajo	Coite	2017	MAYO	7	DOMINGO	14	CAMPECHE CARPEN		
0101000021	W	0101000021	3823010	39.93365	-105.072	80234	PONIENTE	NEUVIAVAI	COLUSON	Auto	BLANCO	2016	Bajo	Frontal	2017	FEBRERO	18	SABADO	9	Ciudad de AZCAPOTZ		
0101000021	W	0101000021	4157140	39.88446	-5.26947	45580	TD-1288	Salvador P	COLUSON	W	W	W	W	W	W	2017	AGOSTO	5	SABADO	5	JALISCO TLAJUEPA	
0101000021	W	0101000021	3955035	38.92568	-6.37694	68000	MÉRIDA-V	KANASIN	COLUSON	Auto	PLATA	2015	Bajo	Frontal	2017	MAYO	24	MIÉRCOLES	13	YUCATÁN KANASIN		
0101000021	W	0101000021	4050105	37.97155	-122.533	94301	AUTOPIST	SINDATO	COLUSON	Camión	BLANCO	2012	Sin	da	Frontal	2017	JUNIO	23	VIERNES	18	MAXIMO AJLOTEPEC	
0101000021	W	0101000021	4165143	37.64934	-7.2553	27550	W	Neji	COLUSON	W	W	W	W	W	W	2017	AGOSTO	11	VIERNES	14	BAJA CALIF TECAATE	
0101000021	W	0101000021	3684718	37.43811	-4.16344	14800	MESONES	CENTRO	COLUSON	Auto	PLATA	2010	Sin	da	Coite	2017	MARZO	20	LUNES	15	Ciudad de CUAUHTEN	
0101000021	W	0101000021	3742503	37.24662	-121.049	95123	San Lorenz	SINDATO	COLUSON	Auto	BLANCO	2016	Sin	da	Coite	2017	ENERO	2	LUNES	22	CHIHUAHUA FLORES W	
0101000021	Conductor	0101000021	4217016	37.22812	-107.811	81301	BLVD	FRAN Agua Nuev	COLUSON	Auto	BLANCO	2014	Bajo	Frontal	2017	SEPTIEMBRE	26	MARTES	14	DURANGO DURANGO		
0101000021	W	0101000021	4085950	36.97412	-122.031	95080	CARR	ORC LA CRUZ	COLUSON	Camión	ROJO	2011	Sin	da	Tasero	2017	JULIO	14	VIERNES	16	QUERÉTARO QUERETAF	
0101000021	W	0101000021	3651959	36.72831	-4.37373	23018	Mak	Irwin Las Am	COLUSON	W	W	W	W	W	W	2017	MARZO	2	JUEVES	16	CIUDAD DE JUAREZ	
0101000021	W	0101000021	3651959	36.72831	-4.37373	23018	Mak	Irwin Las Am	COLUSON	W	VERDE	2004	Sin	da	Frontal	2017	JUNIO	17	MIÉRCOLES	17	MIÉRCOLES	

Anexo 4. Extractos de información Axa Seguros año 2017 por variable

ciudad	(Todas) ▾
Horario ▾	total
DIA	11287
MADRUGADA	1235
NOCHE	9827
TARDE	16465
Total general	38814

Horario, Nuevo León

ciudad	MONTERREY ▾
Horario ▾	total
DIA	4623
MADRUGADA	413
NOCHE	3780
TARDE	6731
Total general	15547

Horario, Monterrey

ciudad	GUADALUPE ▾
Horario ▾	total
DIA	1231
MADRUGADA	140
NOCHE	1175
TARDE	1701
Total general	4247

Horario, Guadalupe

ciudad	APODACA ▾
Horario ▾	total
DIA	968
MADRUGADA	142
NOCHE	830
TARDE	1289
Total general	3229

Horario, Apodaca

ciudad	(Todas) ▾
Causa ▾	total
ATROPELLO	144
COLISION Y/O VUELCO	38340
DANOS POR LA CARGA	32
FENOMENOS DE LA NATURALEZA	245
HUELGAS Y ALBOROTOS	13
INCENDIO RAYO O EXPLOSION	28
TRANSPORTACION	12
Total general	38814

Causa, Nuevo León

ciudad	MONTERREY ▾
Causa ▾	total
ATROPELLO	60
COLISION Y/O VUELCO	15340
DANOS POR LA CARGA	2
FENOMENOS DE LA NATURALEZA	125
HUELGAS Y ALBOROTOS	3
INCENDIO RAYO O EXPLOSION	11
TRANSPORTACION	6
Total general	15547

Causa, Monterrey

ciudad	APODACA ▾
Causa ▾	total
ATROPELLO	7
COLISION Y/O VUELCO	3184
DANOS POR LA CARGA	15
FENOMENOS DE LA NATURALEZA	19
HUELGAS Y ALBOROTOS	1
INCENDIO RAYO O EXPLOSION	3
Total general	3229

Causa, Apodaca

ciudad	GUADALUPE ▾
Causa ▾	total
ATROPELLO	15
COLISION Y/O VUELCO	4207
DANOS POR LA CARGA	6
FENOMENOS DE LA NATURALEZA	16
INCENDIO RAYO O EXPLOSION	2
TRANSPORTACION	1
Total general	4247

Causa, Guadalupe

ciudad	(Todas) ▾
Día de la Sem ▾	total
1	2742
2	5591
3	6369
4	6284
5	6167
6	6580
7	5081
Total general	38814

Día, Nuevo León

ciudad	MONTERREY ▾
Día de la Sem ▾	total
1	961
2	2336
3	2535
4	2521
5	2515
6	2670
7	2009
Total general	15547

ciudad	APODACA ▾
Día de la Sem ▾	total
1	224
2	461
3	484
4	552
5	488
6	582
7	438
Total general	3229

ciudad	GUADALUPE ▾
Día de la Sem ▾	total
1	384
2	586
3	699
4	658
5	660
6	632
7	628
Total general	4247

Día, Monterrey

ciudad	(Todas) ▾
Día de la Sem ▾	total
1	3638
2	3321
3	3547
4	2860
5	3478
6	3118
7	2822
8	3119
9	3188
10	3253
11	3236
12	3234
Total general 38814	

Mes, Nuevo León

Día, Apodaca

ciudad	MONTERREY ▾
Día de la Sem ▾	total
1	1456
2	1400
3	1403
4	1046
5	1532
6	1215
7	1049
8	1265
9	1195
10	1306
11	1336
12	1344
Total general 15547	

Mes, Monterrey

Día, Guadalupe

ciudad	GUADALUPE ▾
Día de la Sem ▾	total
1	408
2	350
3	349
4	347
5	347
6	368
7	320
8	353
9	371
10	352
11	356
12	326
Total general 4247	

Mes, Guadalupe

ciudad	APODACA ▾
Día de la Sem ▾	total
1	321
2	252
3	291
4	235
5	233
6	260
7	256
8	268
9	293
10	285
11	259
12	276
Total general 3229	

Mes, Apodaca