



PONTIFICIA
UNIVERSIDAD
CATÓLICA DE
VALPARAÍSO



Juan Carlos Castro Arredondo

Predicción del Índice de Choques a Postes por Calle

Informe Proyecto de Título de Ingeniero Eléctrico



**Escuela de Ingeniería Eléctrica
Facultad de Ingeniería**

Valparaíso, 28 de mayo de 2019



Predicción del Índice de Choques a Postes por Calle

Juan Carlos Castro Arredondo

Informe Final para optar al título de Ingeniero Eléctrico,

aprobada por la comisión de la

Escuela de Ingeniería Eléctrica de la

Facultad de Ingeniería de la

Pontificia Universidad Católica de Valparaíso

conformada por

Sr. Jorge Mendoza Baeza

Profesor Guía

Sr. Luis Toledo Campos

Correferente

Sra. Cecilia Montt Veas

Correferente

Sr. Sebastián Fingerhuth Massmann

Secretario Académico

Valparaíso, 28 de mayo de 2019

Agradecimientos

Agradezco a mi padre y madre, Carlos y Carolina, por el apoyo y paciencia que han tenido estos años, todo esto se los debo a ustedes. Gracias Fefi por tu cariño.

Deseo también agradecer a mi abuela Sara y tata Fernando, por las historias y anécdotas con las cuales nos nutren como personas.

Me falta solo a los del montón; rama, parada, mago, pancho, negro, seba, erik, el dinovio, martín, fredy, pabliu y a los olvidados, gracias por su amistad.

Gracias a todos por su apoyo.

Valparaíso, 11 de marzo del 2019

Juan Castro

Resumen

La red eléctrica de la Región de Valparaíso ya está próxima a cumplir un siglo de funcionamiento, por lo que se ha visto envuelta en un sinnúmero de eventos, tanto desafortunados y problemáticos como evolutivos, aumentando su eficiencia a través de mejoras considerables, gracias al crecimiento tecnológico.

En el presente estudio se analizó una de las problemáticas que posee la Distribuidora Eléctrica de la Región de Valparaíso, Chile, ésta corresponde a choques de vehículos a postes de distribución y alumbrado eléctrico, por lo que se propuso un modelo para identificar la criticidad de las calles y que variables inciden en los choques a postes.

En primera instancia, se describió la geografía y especificaciones técnicas de la red de distribución y luego los problemas comunes a los que se ve enfrentada. Con el fin de contextualizar la problemática principal. Posteriormente se analizará un conjunto de estudios relacionados con esta temática, para así abordar de la forma eficiente, la recolección de variables, desarrollo del modelo, analizar alternativas tentativas, y posibles inconvenientes durante el desarrollo del estudio. Finalmente se planteó y ejecuto el desarrollo de un modelo de predicción de choques a postes anual por calle, a través de Redes Neuronales Artificiales y el modelamiento de una función a través de regresiones no lineales. Tanto para la red neuronal como el como el modelo matemático fueron tratados con distintas estrategias y metodologías de optimización para obtener la mejor predicción de choques a postes en la Región Valparaíso, Valparaíso Chile.

Finalmente se realizó una comparación entre modelos, respecto a su factibilidad en la predicción de choques en calles desconocidas para los estos, donde se obtuvo un coeficiente de correlación de 0,64 para el modelo de predicción con Redes Neuronales Artificiales y un 0,56 en el modelo no lineal.

Palabras claves: Redes neuronales artificiales, modelo de predicción, Modelo de regresión no lineal.

Abstract

The electrical network of the Valparaíso Region is already close to reaching a century of operation, has been involved in a myriad of events, both unfortunate and problematic as evolutionary, increasing its efficiency through considerable improvements, thanks to technological growth

In the present study a problem was analyzed that has the Electric Distributor of the Region of Valparaíso, Chile, which is a publication of distribution and an electric lighting, in which a model was proposed to identify the criticality of the streets and variables they affect posts to posts.

In the first instance, the geography and technical specifications of the distribution network are described and then the common problems they face. In order to contextualize the main problem. Subsequently, a set of studies related to this topic will be analyzed, for the management of variables, the development of the model, the analysis of the tentative alternatives and the possible inconveniences during the development of the study. Finally, the development of a prediction model of postal and annual publications by the street, through Artificial Neural Networks and the mode of a function through non-linear regressions were developed and developed. Both the neural network and the mathematical model were used with different strategies and optimization methodologies to obtain the best prediction of publications in the Valparaíso Region, Valparaíso, Chile.

Finally, a comparison between models was made, regarding its feasibility in the prediction of road crashes unknown to these, where a correlation coefficient of 0.64 was obtained for the prediction model with Artificial Neural Networks and 0.56 in the non-linear model

Keywords: Artificial neural networks, prediction model, Non-linear regression model.

Índice general

Introducción.....	1
Objetivos generales.....	2
Objetivos específicos	2
1 Sistema Eléctrico de Distribución.....	3
1.1 Descripción	4
1.1.1 Geografía	5
1.1.2 Especificaciones Técnicas	8
2 Sucesos.....	10
2.1 Índices de calidad	10
2.1.1 Índices de calidad de suministro	11
2.2 Libro de Novedades	13
2.2.1 Tipos de fallas	14
2.2.2 Análisis porcentual de fallas	18
3 Revisión Bibliográfica.....	19
3.1 Evaluación de Colocación de Poste Público y el Impacto en las Tasas de Colisión	19
3.1.1 Descripción.....	19
3.1.2 Estrategia.....	19
3.1.3 Variables Utilizadas.....	20
3.1.4 Desarrollo de Modelo utilizado.....	24
3.1.5 Conclusiones del Modelo	25
3.2 Estudio en profundidad de accidentes que involucran colisiones con postes de servicio públicos	26
3.2.1 Descripción.....	26
3.2.2 Estrategia.....	26
3.3 Predicción de Accidentes de Tránsito utilizando Redes Neuronales Artificiales y Cuckoo Search	35
3.3.1 Estrategia.....	35
3.4 Espectativa Nacional	39
4 Solución Propuesta.....	41

4.1 Variables Adquiridas	41
4.2 Redes Neuronales	43
4.3 Matlab RNN	43
4.3.1 Configuración y trabajo de la red neuronal	44
4.4 Python RNN	48
4.4.1 Sigmoide.....	48
4.4.2 Desarrollo del Código de Entrenamiento.....	49
5 Simulación y Análisis.....	53
5.1 Imprevisto.....	53
5.2 Simulación Matlab.....	55
5.3 Simulación Spyder (Python)	57
5.4 Resumen	60
6 Propuestas de Optimización de Resultados	61
6.1 Adición de calles sin registro de choques	61
6.2 Adición de nuevas variables.....	61
6.2.1 Google Earth	62
6.2.2 ITO Map	63
6.2.3 Número de escuelas por calle	64
6.2.4 Límites de velocidad	65
6.3 Variables discretas y continuas.....	65
6.3.1 Material calzada.....	66
6.3.2 Tipo del poste y estado de la Calzada	66
6.4 Proporción de datos a entrenar	66
7 Segunda Vista a MATLAB.....	68
7.1 Flujo de trabajo por MATLAB	68
7.1.1 Arquitectura de red neuronal superficial de múltiples capas	68
7.1.2 Preparar datos para redes neuronales de múltiples capas	70
7.1.3 Creación, Configuración e Inicialización de la Red Neuronal	70
7.1.4 Entrenar y Aplicar Redes Neuronales de Múltiples Capas	71
7.1.5 Rendimiento de la Red Neuronal.....	73
7.1.6 Limitaciones y Precauciones	73
7.1.7 Funciones de Procesamiento de Entrada y Salida.....	73
7.1.8 Tener en Cuenta	74
8 Resultados Obtenidos MatLab	75
8.1 Tablas Resumen de Entrenamientos y Simulaciones Realizadas.....	75
8.1.1 Levenberg-Marquardt	75
8.1.2 Gradiente Conjugado Resistente	76
8.1.3 Retro-propagación Resistente.....	77
8.2 Finalistas	77

9 Entrenamiento con librerías Keras	82
9.1 Código utilizado	82
9.2 Resultados obtenidos	84
9.2.1 Mejor configuración en predicción del grupo A.....	84
9.2.2 Mejor configuración en predicción del grupo B.....	86
10 Análisis de sensibilidad	89
10.1 Matriz de pesos	89
10.2 Método de Garson	90
10.2.1 Resultados obtenidos.....	91
10.3 Método de enfoque de peso en conexión.....	92
10.3.1 Resultados obtenidos.....	93
10.4 Comprobación de la obtención de variables mas sensibles	94
10.4.1 Resumen de índices de calidad de predicción.....	94
11 Modelo de regresión no lineal.....	95
11.1 Regresión no lineal	95
11.1.1 Comportamiento de variables con respecto a la salida del modelo	95
11.1.2 Obtención de coeficientes	100
11.2 Calidad de la predicción.....	103
11.2.1 Predicciones realizadas.....	104
11.3 Modelo de regresión No Lineal VS Red Neuronal Artificial	107
Discusión y Conclusiones.....	108
12 Bibliografía	111

Introducción

Durante el siglo XIX la energía que movía al mundo era el carbón, ya que se usaba en barcos, ferrocarriles, y artefactos domésticos, pero en el año 1879 el estadounidense Thomas Alva Edison inventó la bombilla eléctrica, que revolucionaría la época

En 1883 la energía eléctrica hizo su aparición en Chile, cambiando la noche santiaguina, con la instalación de 2 faros de 5 luces cada uno en plena plaza de Armas Santiago. Esto incentivó a grandes empresarios a emplear esta nueva energía. Ya para el siglo XX la gran demanda de energía promovió la instalación de nuevos generadores de energía y creación de una empresa que se encargara de su distribución. En 1921 la Compañía Nacional de Fuerza Eléctrica se fusionó con la Chilena Electric Tramway and Light Co., surgiendo de esta manera la Compañía Chilena de Electricidad Limitada, la empresa encargada de la generación y la distribución de la energía eléctrica que conocíamos como Chilectra [1]. Esta fusión no solo abarcó las necesidades de los santiaguinos, sino además ofrecería servicio en zonas como Valparaíso y el valle de Aconcagua.



Figura 0-1 Instalación tendido Eléctrico Alameda, Santiago [1]

Desde entonces la red de distribución de Valparaíso tiene casi un siglo de historia, por lo que es de imaginarse, su estructura ha sufrido un sinnúmero de negligencias y eventos, en donde destaca uno de los sucesos de mayor frecuencia, el cual corresponde al choque de vehículos contra postes, esto debido a la gran cantidad de postes distribuidos por la red de distribución. En la actualidad se sobrealora la importancia de solucionar este problema, no tan solo debido a las pérdidas materiales, sino que a las pérdidas humanas.

Especialistas en accidentes automovilísticos descubrieron, ya hace bastante tiempo, que los accidentes no son en absoluto acontecimientos fortuitos, inevitables, impredecibles y dependientes de la suerte, sino que por el contrario de la inmensa mayoría de los casos siguen parámetros característicos de la red de distribución [2]; es decir, el accidente globalmente es siempre una consecuencia de algún fallo evitable y hasta cierto punto predecible del sistema. Por

lo que, para combatir el problema, lo primordial será comprender como el entorno refleja la reacción ante un problema de conducción automovilística.

La empresa de distribución eléctrica de Valparaíso, diariamente registra y archiva todo tipo de acontecimientos desafortunados ocurridos en la red de distribución, en una base de datos, detallando hora, fecha, alimentador involucrado, carga involucrada, los sucesos en cuestión, en los que podemos encontrar; postes chocados, tensores de postes chocados, pelotazos a líneas, fallas del tendido eléctrico en general, en fin, una gran cantidad de sucesos que están en constante evaluación para mejorar la predicción de estos y así evitar que sean reiterativos.

Durante los últimos 13 años se han desarrollado diversas investigaciones relacionadas a accidentes de tránsito en distintas ciudades del Mundo utilizando técnicas de Inteligencia Computacional (IC), ya que anteriormente (30 años) se desarrollaban estudios con modelos matemáticos, lo que en la actualidad permite visualizar variables y patrones significativos que ayudan a identificar de mejor manera las condiciones en las que ocurren los accidentes de tránsito, considerando que cada siniestro implica la conjugación de un gran número de variables, que determinan la cantidad de accidentes [2] [3] [4].

Una de estas técnicas de IC son las Redes Neuronales Artificiales (RNA), que consisten en un algoritmo que emula el comportamiento del sistema nervioso animal. Este tipo de técnicas ha demostrado tener buenos resultados tanto en la predicción como la clasificación de series de datos. Esta cumplirá la labor principal para el desarrollo del modelo a emplear en este estudio.

Objetivos generales

- Predicción del riesgo a choques de postes en puntos de interés en la Región de Valparaíso mediante un modelo matemático clásico y otro basado en redes neuronales.

Objetivos específicos

- Identificar factores o variables descritas en las calles de la Región de Valparaíso que involucran a la tasa de choques a postes anuales por calle para el desarrollo del modelo predictivo.
- Estudiar métodos matemáticos y de heurística que permitan desarrollar el modelo de predicción de choques a postes en la región de Valparaíso.
- Estudiar el lenguaje de programación Python, con el fin de desarrollar un modelo computacional de redes neuronales que pueda aprender por sí mismo.
- Evaluar el rendimiento de los modelos, comparando las respuestas obtenidas con datos reales.

1 Sistema Eléctrico de Distribución

Un sistema eléctrico de potencia incluye las etapas de generación, transmisión, distribución y utilización de la energía eléctrica, y su función primordial es la de llevar esta energía desde los centros de consumo y por último entregarla al usuario en forma segura y con los niveles de calidad exigidos.

Aproximadamente las 2/3 partes de la inversión total del sistema de potencia, están dedicados a la parte de distribución, lo que implica necesariamente un trabajo cuidadoso en el planteamiento, diseño y construcción y en la operación del sistema de distribución, lo que requiere manejar una información voluminosa y tomar numerosas decisiones, lo cual es una tarea compleja, pero de gran trascendencia.

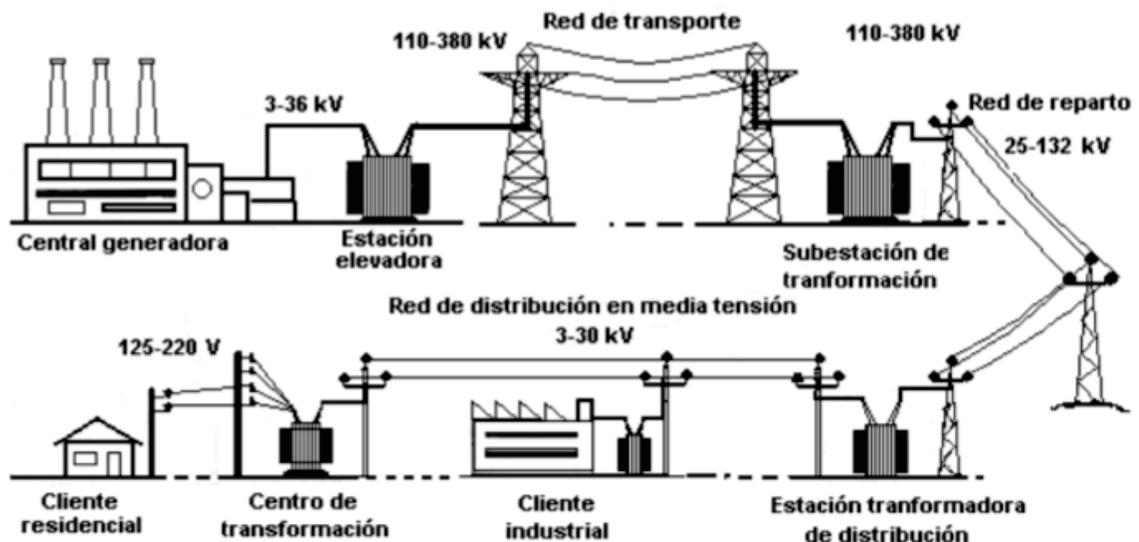


Figura 1-1 Ubicación de sistemas de distribución dentro un sistema de potencias [5]

De acuerdo a su construcción, clasifican 2 tipos más comunes; las redes de distribución aéreas, que poseen el conductor usualmente desnudo, el que va soportado a través de aisladores

instalados en crucetas, en postes de madera o de concreto; y las redes de distribución subterráneas, las cuales son empleadas en zonas donde por razones de urbanismo, estética, congestión o condiciones de seguridad no es aconsejable el sistema aéreo. Actualmente el sistema subterráneo es competitivo frente al sistema aéreo en zonas urbanas céntricas [5].

Si se compara el sistema aéreo con el sistema subterráneo tiene las siguientes ventajas:

- Consto inicial más bajo
- Son las más comunes y materiales de fácil consecución
- Fácil mantenimiento
- Fácil localización de fallas
- Tiempos de construcción más bajos

Y tiene las siguientes desventajas:

- Mal aspecto estético
- Menor confiabilidad
- Menor seguridad (ofrece más peligro para los transeúntes)
- Son susceptibles de fallas y cortes de energía ya que están expuestas a: descargas atmosféricas, lluvias, granizo, polvo, temblores, gases contaminantes, brisa salina, vientos, contactos con cuerpos extraños, choques de vehículos y vandalismo.



Figura 1-2 Red Aérea, calle Diego Portales, Valparaíso [10]

El sistema subterráneo tuene las siguientes ventajas:

- Mucho más confiable ya que la mayoría de las contingencias mencionadas en las redes aéreas no afectan a las redes subterráneas
- Son más estéticas, pues no están a la vista
- Son mucho más seguras
- No están expuestas al vandalismo

Tienen las siguientes desventajas:

- Un alto costo de inversión inicial
- Se dificulta la localización de fallas
- El mantenimiento más complicado por lo que requiere mayor tiempo
- Están expuestas a la humedad y a la acción de los roedores

1.1 Descripción

La distribución de energía eléctrica ha evolucionado a través de los años, tanto ya sean discusiones sobre el uso de corriente alterna o continua, hasta el avance tecnológico de las máquinas y las diferentes fuentes de generación de energía eléctrica. Sin embargo, en la actualidad mencionar el aspecto geográfico en donde se encuentra la red de distribución no es un detalle despreciable, en donde un énfasis en sus zonas críticas, y como esta influye en el

comportamiento de la red. Un análisis geográfico de las diferentes zonas que presenta la red de distribución es indispensable para identificar las restricciones y problemáticas que se tienen para la distribución de la energía en condiciones normales.

1.1.1 Geografía

Valparaíso cuenta con una superficie de 16396 Km² y una población de 1.815.902 de habitantes según el instituto nacional de Estadísticas. Su capital llamada del mismo nombre, y es sede de uno de los principales puertos de Chile.

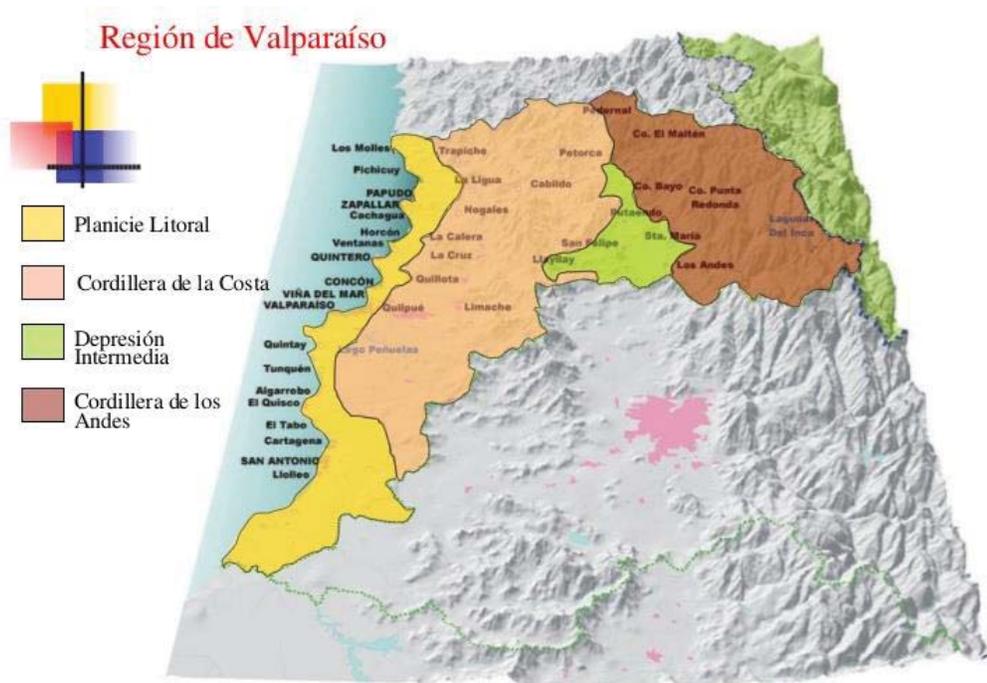


Figura 1-3 Macroforma Región de Valparaíso [20]

Su cordillera de los andes mantiene su altura y se pueden apreciar cumbres que van desde los 5000 hasta los 6000 metros sobre el nivel del mar. Al norte la Cordillera de los Andes y la de la Cordillera de la Costa forman una sola unidad, ya que están unidas a los cordones transversales.

La depresión intermedia en esta región se pueden observar los últimos valles trasversales, que corresponden a las cuencas de los ríos Aconcagua, La Ligua y Petorca. El cordón transversal Chacabuco marca el límite entre la región de Valparaíso y la región metropolitana. La depresión intermedia solo está presente en algunas cuentas interior, como Catapilco y La Ligua, delimitadas por las serranías (sistema de montañoso)

Por el norte la cordillera de la costa y la de los Andes llegan a fusionarse. Al sur del río Aconcagua recién empiezan a diferenciarse (depresión intermedia). Es recalable que la cordillera de la costa alcanza gran altura donde destacan el cerro La Campana y El Roble que superan los 2000 metros de altura.

Las planicies litorales comienzan a ampliarse desde la desembocadura del río Aconcagua hacia el sur, variando su ancho desde 100 [m] hasta 15 [Km]. Estas suelen estar interrumpidas por cursos de agua, que se originan en la cordillera de la costa como el estero Marga Marga. Son características sus dunas costeras como Longotoma y las dunas de Concón. Solo falta describir a Valparaíso característico de sus colinas o cerros.

Ecenarios

La red de distribución eléctrica de Valparaíso recorre una gran cantidad de escenarios, cada uno con múltiples variables que describen en cierta manera su funcionamiento, por lo que para una mejor descripción y así lograr identificar cualquier imprevisto dentro de la red. Por esto se describieron para luego ser analizados.

Existe un problema de heterogeneidad al momento de clasificar un sector, en cuanto a rural o urbano, por lo que se investigó como se hace esta referencia en la Región de Valparaíso.

Tabla 1-1 Descripción del año 2016 entre número de siniestros o fallecidos entre zonas rurales y urbanas

Zona de siniestro	Siniestros	Fallecidos	Lesionados		Total lesionados	
Rural	15.147	1.110	2.733	1.521	13.721	17.975
Urbana	76.564	565	6.097	2.823	36.668	45.588

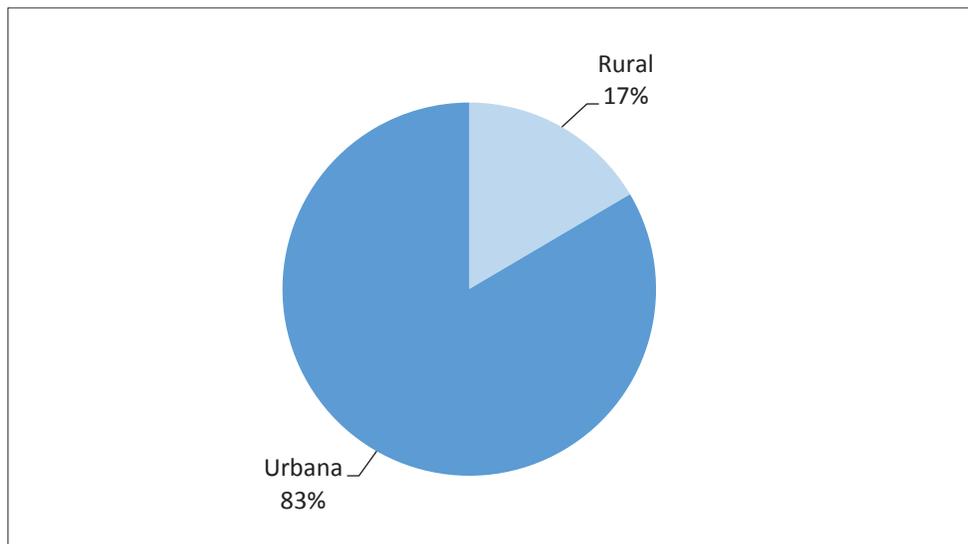


Figura 1-4 Porción de siniestros de tránsito por zona [6]

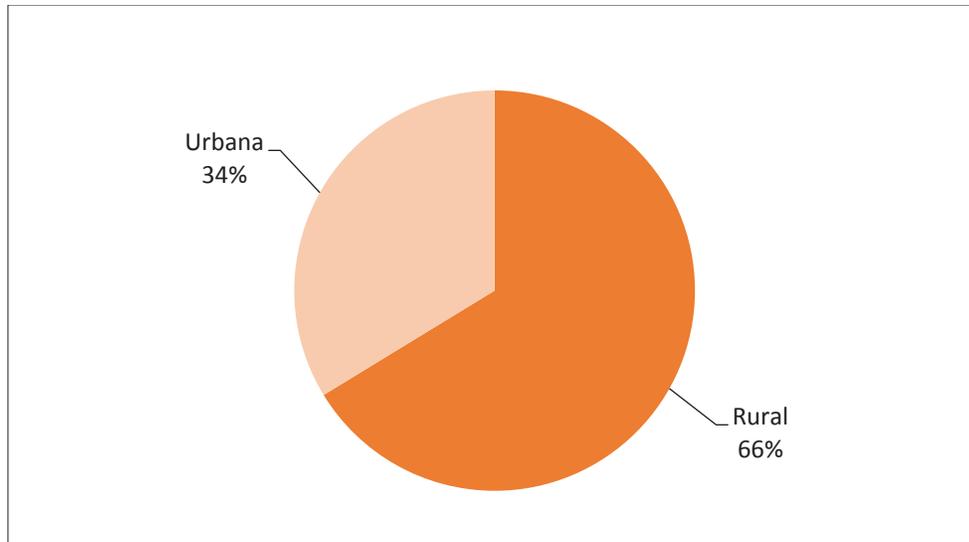


Figura 1-5 Porción de fallecidos en siniestros de tránsito por zona [6]

En la Tabla 1-1 y Figura 1-4 y 1-5 se muestra la cantidad de siniestros de tránsito, y que cantidad de estos siniestros fueron mortales, en dos zonas, ya sea rurales y urbanas. Esto refleja claramente que existe una diferencia en ambos casos, la que se puede atribuir como primera influyente, las velocidades exigidas en estas dos zonas. La porción de sucesos de tránsito es mayor en zonas urbanas que en rurales ya que en esta existe una mayor cantidad de vehículos a pequeñas velocidades y en grandes atochamientos, sumados al estrés en horas pick de tráfico aumenta las posibilidades de accidentes con una baja tasa de mortalidad. En lado contrario las tasas de mortalidad en zonas rurales son mayor, teniendo de referencia el total de sucesos debido a que si bien los sucesos son menores a los de zonas urbanas estos tienen mayor probabilidad de ocurrir con un impacto mayor.

Urbano

Una zona urbana se caracteriza por poseer una densidad de población alta, su tamaño es mayor que en los núcleos rurales; con viviendas concentradas; existe un predominio de paisaje humanizado, la división de terrenos es intensa; lo que conforma manzanas y lotes; en su actividad económica predomina son las secundarias y terciarias; industrias, comercio y servicios; también cuenta con una infraestructura de servicios compleja en donde se incluyen; servicios educativos, sanitarios, recreativos, transporte, comunicaciones, etc.; dentro del equipamiento y servicios consta de; provisión de agua, asfaltos, cloacas, alumbrado, gas, electricidad, etc.

Las principales comunas, de la región de Valparaíso, que forman el núcleo urbano son las comunas de Viña del Mar, Quilpué, Villa Alemana, Concón y Valparaíso.

Rural

Una zona rural se caracteriza por poseer una densidad de población baja, presentar viviendas aisladas o en pequeños asentamientos, el hombre mantiene una relación directa con el medio ambiente; en donde los terrenos presentan menor divisiones o subdivisiones, la actividad económica predominante es la agrícola, posee servicios básicos, en la mayoría de los casos los pobladores deben viajar a las ciudades para acceder a servicios más especializados

1.1.2 Especificaciones Técnicas

Se propone clasificar las redes de distribución eléctrica de media y baja tensión de acuerdo a su ubicación y densidad de población, por lo que se clasificaran en sistemas de distribución urbano o rural, si existen sistemas mixtos, se clasificaran dependiendo de su densidad de población.

Sistema de Distribución Urbano

Alimenta la distribución de energía eléctrica a poblaciones y centros urbanos de gran consumo. Las siguientes características describen mejor este sistema:

- Usuarios muy concentrados, por ende bajos costos de operación y mantenimiento por usuario.
- Cargas monofásicas, bifásicas y trifásicas.
- Facilidad de accesos
- Se usan conductores de aluminio, cobre y ACSR
- Facilidad de transporte desde los proveedores de materiales y quipos de sitio de obra
- Transformadores generalmente trifásicos en áreas de alta densidad de carga y monofásicos en áreas de carga moderada
- El trabajo puede ser mecanizado
- La separación entre conductores y estructuras de baja y media tensión son menores
- El caso de remodelaciones y arreglos es necesario coordinar con la empresa de energía los cortes y servicios.

Sistema de distribución Rural

En este sistema existe la problemática de largas distancias y pequeñas cargas, a las que se les debe entregar a energía, por lo que se requieren soluciones especiales en cuanto a equipos. Elevando el costo de las instalaciones, la operación y el mantenimiento, esto a consecuencia del valor del costo de la energía

Se pueden describir las siguientes características de este sistema:

- Usuarios ubicados dispersamente
- Dificultad de acceso en las zonas montañosas lo que implica extra costo en el transporte y manejo de materiales
- En zonas de difícil acceso se emplean postes de madera inmunizada
- Los transformadores por lo general son monofásicos

2 Sucesos

A diario, en las distribuidoras eléctricas del país, se ven involucrada con un sinnúmero de sucesos, en donde los inesperados e indeseables no tardan en ocurrir, a consecuencia de esto un déficit de su servicio eléctrico si no es atendido a tiempo este traerá como consecuencia, energía no vendida a sus clientes, pérdida en materiales de reposición, posibles daños a la comunidad y estructuras, y grandes multas por el incumplimiento de los índices de calidad establecidos.

2.1 Índices de calidad

La distribución y generación de electricidad, se encuentra regulada en la legislación chilena, en aspectos técnicos y económicos. Respecto de este estudio podemos comentar que existen una serie de decretos, reglamentos y normas que describen como una distribuidora debe entregar suministros a sus clientes respecto de cómo se entrega el suministro las normas establecen una serie de indicadores que se deben cumplir o se corren riesgos de sanciones que van desde multas o compensaciones a clientes y en casos más extremos comprenden la caducidad de concesión. Todo esto con el objetivo de permitir el correcto funcionamiento del sector eléctrico

De hecho, como lo dice la norma técnica de calidad de servicio para sistemas de distribución su objetivo es permitir el correcto funcionamiento de sector eléctrico, para lo cual deberá regular los aspectos técnicos, de seguridad, coordinación, calidad, información y económicos del funcionamiento de dicho sector.

De esta manera la norma técnica establece las exigencias que deberán cumplir los concesionarios de servicio público de distribución de electricidad y las empresas que sean propietarias, arrendatarias, usufructuarias o que operen, a cualquier título, instalaciones de distribución de energía eléctrica, respecto de:

- La calidad del producto
- La calidad de suministro
- La calidad comercial

Como primera impresión, los choques a postes podrían influir negativamente en los índices de calidad de suministro, esto no corresponde debido a que este evento se califica como un evento

de Fuerza Mayor, ya que escapa del control de la distribuidora, por lo que si se justifica ante la autoridad no será considerada.

2.1.1 Índices de calidad de suministro

Interrupciones de suministro a clientes finales

Para caracterizar las interrupciones de suministro que afecten a clientes conectados en sistemas de distribución en estado norma, se definen los siguientes indicadores:

FIC: frecuencia de interrupciones a clientes

$$FIC = \sum_i Int_{I,c} \tag{2-1}$$

TIC: tiempo de interrupciones a clientes

$$TIC = \sum_i Int_{i,c} * t_{i,c} \tag{2-2}$$

Donde Int es el número de Interrupciones y t es el tiempo de duración de las interrupciones

Para la aplicación de las expresiones anteriores se deben considerar todas las interrupciones de suministro generadas por fallas o desconexiones que hayan sido mayores a 3 minutos, incluyendo aquellas que afecten inicialmente a un cliente. También se deben considerar desconexiones programadas. Y excluir aquellas interrupciones solicitadas por el usuario, aquellas que hayan sido calificadas por la superintendencia como eventos de Fuerza mayor o caso Fortuito.

En aplicación de lo señalado en el inciso anterior, los indicadores TIC y FIC, para cualquier Cliente, no deberán exceder los límites siguientes durante cualquier periodo de doce meses consecutivos:

Tabla 2-1 Límite expresados en horas para el Tiempo de Interrupciones de Suministro Clientes Finales (TIC) exigibles durante los años 2018 a 2019

Tensión de la red / Densidad de la red	Alta	Media	Baja	Muy Baja
Baja Tensión	13	14	18	22
Media Tensión	8	10	14	20

Tabla 2-2 Límites para la Frecuencia de Interrupciones de Suministro Clientes Finales (FIC) exigibles durante los años 2018 y 2019

Tensión de la red / Densidad de la red	Alta	Media	Baja	Muy Baja
Baja Tensión	12	14	18	22
Media Tensión	8	9	10	14

Interrupciones de suministros globales

Para caracterizar las Interrupciones de Suministro en los Sistemas de Distribución en estado normal, se definen los siguientes indicadores globales:

SAIDI: Tiempo de medio de interrupción por clientes por año (System Average Interruption Durations Index [N° de interrupciones/año])

$$SAIDI_j = \frac{\sum_i^N Clien_{fsi_j} * t_{i,c}}{client_{inst_j}} \quad (2-3)$$

SAIFI: Frecuencia media de interrupciones por cliente por año (System Average Interruption Frequency Index) [Horas/año].

$$SAIFI_j = \frac{\sum_i^N Clien_{fsi_j}}{Client_{inst_j}} \quad (2-4)$$

$Clien_{fsi_j}$: Corresponde a la cantidad total de Clientes conectados al sistema de distribución en el área de control j , que hayan sufrido una Interrupción de Suministro mayor a 3 minutos producto de las fallas o desconexiones i , ocurridas durante el periodo de evaluación de 12 meses consecutivos.

$Client_{inst_j}$: Corresponde al promedio de la cantidad total de Clientes conectados al SD en el área de control j , durante en el periodo de evaluación de 12 meses consecutivos.

N : Corresponde al número total de interrupciones, en el periodo de evaluación de 12 meses consecutivos, que hayan afectado a Clientes conectados en el área de control j .

$t_{i,c}$: Corresponde al tiempo total en que el Cliente c se vio afectado por una Interrupción de Suministro mayor a 3 minutos producto de la falla o desconexión i . Este tiempo puede diferir entre interrupciones producidas por una misma falla, en función de los bloques de reposición de suministro que se hayan implementado.

Se deben considerar también las desconexiones programadas. Asimismo, se considerarán incumplimientos a los estándares establecidos para SAIDI y SAIFI, y se deberán considerar en su cálculo, los siguientes casos:

- Si en un determinado mes, el SAIDI y/o SAIFI exceden los límites establecidos en la presente norma técnica, siempre y cuando no se hayan detectado incumplimientos de dichos indicadores en los 12 meses anteriores
- Si en un determinado mes, el SAIDI y/o SAIFI exceden los límites establecidos en la presente norma técnica y, adicionalmente, el indicador presenta un alza respecto del mes inmediatamente anterior a aquel en que se excedió el o los indicadores.

Por el contrario, se deben excluir aquellas interrupciones solicitadas por el usuario, aquellas que hayan sido calificadas por la Superintendencia como eventos de Fuerza Mayor o Caso Fortuito, como choques de postes, y aquellas asociadas a un Estado Anormal o a un Estado Anormal Agravado del par Comuna-Empresa respectivo, de conformidad con lo establecido en la presente NT.

Para efectos de determinar el número de clientes afectados en el caso de Interrupciones de Suministro, la Superintendencia emitirá el Documento Técnico “Consideraciones para Cálculo de SAIDI y SAIFI”, en el cual se establecerá la metodología a aplicar en cada caso. De acuerdo a la Clasificación de Redes establecida en el Anexo de la presente NT, los indicadores SAIDI y SAIFI no deberán superar los límites siguientes durante cualquier periodo de doce meses consecutivos [7]:

Tabla 2-3 Límites para los indicadores SAIDI y SAIFI exigibles durante los años 2018 y 2019

Tensión de la red / Densidad de la red	Alta	Media	Baja	Muy Baja
SAIDI (en horas)	8.5	9.5	12	16
SAIFI	6	7	9	10

2.2 Libro de Novedades

Es un medio de registro en el cual los despachadores y operadores del sistema eléctrico registran los hechos acontecimientos en la red.

Este libro no puede ser corregido. Cualquier novedad, explicación u otra situación de importancia, el despachador deberá dejar constancia de ello en el libro de novedades. De acuerdo a lo anterior, debido a la importancia del libro de novedades, ya que es un medio de registro oficial, debemos tener en cuenta que la información plasmada en este, debe ser clara y concisa.

Para el desarrollo de los objetivos se empleará la sección de fallas del Libro de novedades, que cómo dice su nombre, involucra todas las fallas en la red de distribución y las acciones que ocasionaron estas fallas.

2.2.1 Tipos de fallas

Tabla 2-4 Ranking de fallas más frecuentes

	Nombre Causa	Frecuencia
1	Obras nuevas o modificación de ingeniería	1851
2	Choque de vehículo a poste	1499
3	Envejecimiento de materiales	1368
4	Municipalidad no efectúa poda propia o no la permite	1219
5	Temporal o viento fuerte	773
6	Desequilibrio de cargas	752
7	Corrosión	565
8	Caída de gancho o rama	491
9	Choque de vehículo a tirante	397
10	Pelotazos	390
11	Otros	293
12	Hurto energía	291
13	Caída de árbol	285
14	Cliente no efectúa poda propia o no la permite	281
15	Crecimiento de la demanda del sector	276
16	Intempestivas de Subtransmisión	271
17	Vehículo > 4,50 m de altura bota cable ajeno	247
18	Operación (maniobra), media tensión	213
19	Cliente efectúa poda propia indebida	211
20	Operación imprevista de equipo	211
21	Objeto, alambre o cadena lanzada	205
22	Aves	204
23	Movimientos Telúricos	187
24	Falla en artefacto eléctrico	165
25	Volantines	146
26	Daño debido a faena en propiedad particular	136
27	Cable ajeno a baja altura apoyado en red concesionaria	132
28	Vehículo > 4,50 m de altura bota empalme o acometida	128
29	Municipalidad efectúa poda propia indebida	108
30	Causa fugaz o no determinado	107
31	Intempestivas de Transmisión	99
32	Maquinaria pesada	88
33	Falla en trabajo con línea viva	70
34	Vehículo > 4,50 m de altura bota cable de distribución	70

35	Mantenimiento preventivo	57
36	Falla de material	52
37	Lluvia	52
38	Operación de bloque de baja frecuencia	52
39	Intervención a solicitud de bomberos	51
40	Programadas Subtransmisión	37
41	Robo conductor o equipos	37
42	Construcción deficiente	36
43	Incendios	36
44	Daño directo en la red por ejecución de podas	30
45	Descarga eléctrica (Rayo)	30
46	Falla en equipo (no debida a 2401 ni a 2402)	29
47	Falta de mantenimiento	23
48	Calor excesivo debido a incendio	22
49	Deslizamientos de suelo o de tierra	22
50	Corte programado (excluido 2607)	21
51	Daño por faena ajena a la concesionaria	20
52	Deslizamiento de suelo por trabajos	15
53	Fuerte Neblina	15
54	Aumento de carga en faena de construcción	14
55	Error de operación	11
56	Pérdida de aislación	9
57	Red de distribución a baja altura	9
58	Capacidad insuficiente por nueva urbanización	8
59	Acometidas fuera de norma (baja altura)	7
60	Disturbios en la zona	7
61	Sector sin podar o mal podado, por parte de la Concesionaria	7
62	Quemas de Pastizales	6
63	Sabotaje	5
64	Ambiente Salino	4
65	Blackout del Sistema	4
66	Daño de aisladores	4
67	Nieve	4
68	Pérdida de aislación de transformador particular	4
69	Problema neutro o puesta a tierra	4
70	Falla por contaminación industrial en el área	3
71	Atentado / explosivos	2
72	Capacidad insuficiente de S/E	2
73	Colocación de lienzos	2
74	Desconexión a solicitud del cliente	2
75	Incorporación de nuevos clientes	2
76	Inundaciones	2
77	Traslado medidor por terceros	2

78	Falla en cliente no regulado o libre (Gx)	1
79	Falla por contacto personal	1
80	Insectos	1
81	Mamíferos	1
82	Operación (maniobra), baja tensión	1
83	Poste cliente inclinado / quebrado	1
84	Roedores	1

A continuación, se nombran causas de interrupción de suministro ocurridos desde la fecha 01/01/2016 hasta el 18/01/2018 en la quinta región. Estas interrupciones son enumeradas de mayor a menor frecuencia.

Choque a postes

El choque a poste se encuentra en el segundo lugar en la tabla de fallas de la red, lo que mantiene en constante atención de los ingenieros de las distribuidoras eléctricas, ya que si se adapta una solución que disminuya la tasa de estas fallas, eliminaría grandes sumas de dinero en costos de reposición y energía no consumida por sus clientes.

Como se puede observar en las siguientes imágenes, tanto la posición del poste como la pendiente son factores críticos al momento de tener en cuenta, si se desea disminuir el índice de choques por calle anuales. Si bien el poste se repuso (Figura 2-2), no se realizó ninguna modificación para prevenir un próximo choque en el mismo lugar.



Figura 2-1 Choque de micro a poste calle Parque, Playa Ancha [9]



Figura 2-2 Poste reinstalado tras choque [10]

2.2.2 Análisis porcentual de fallas

Para una mejor percepción de las frecuencias de fallas con respecto a su totalidad se graficaron las frecuencias de las causas de fallas, para tener una mejor perspectiva de la concentración global de fallas y enfocarse en las que tengan una mayor frecuencia

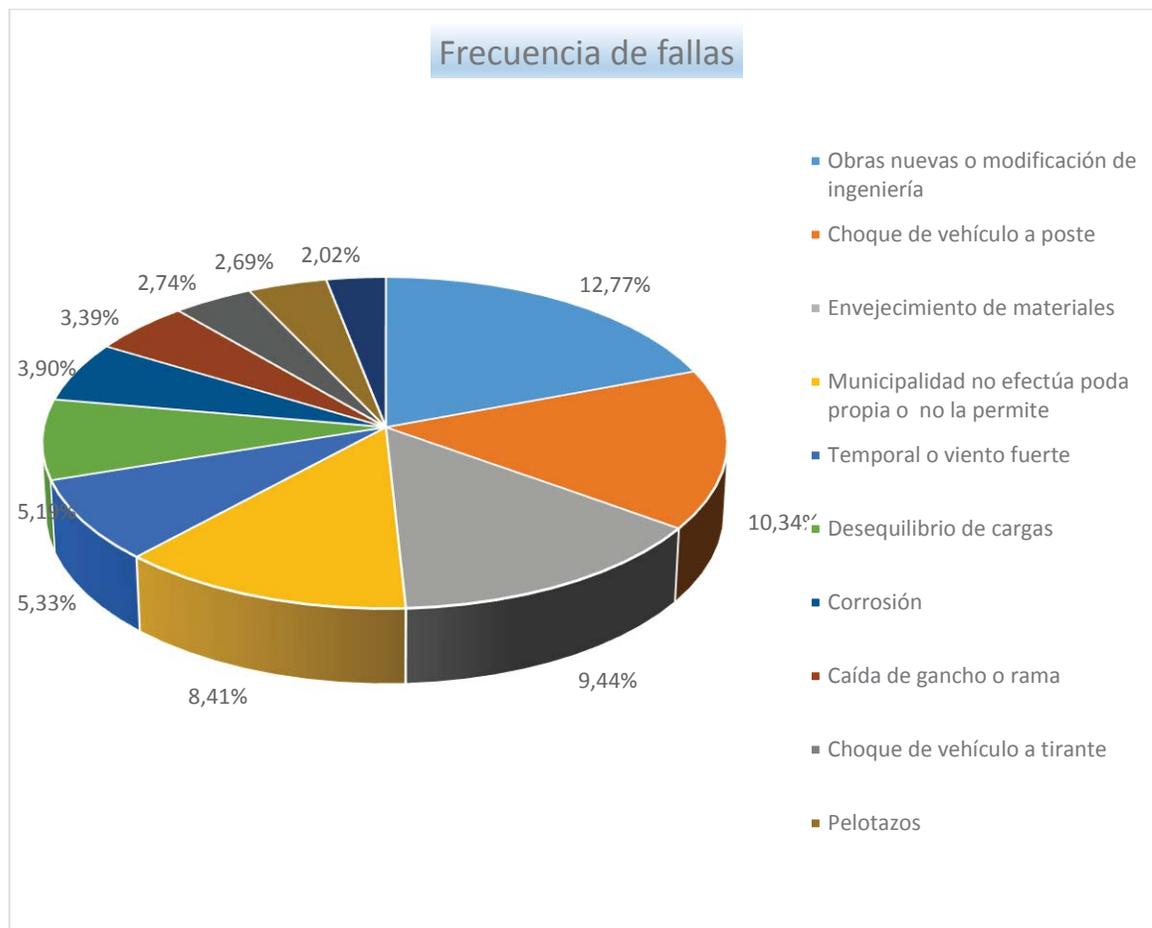


Figura 2-3 Porcentaje de Ocurrencia de Fallas [8]

Como primera impresión la causa de falla con mayor frecuencia, con un 12.77% en el periodo descrito, es el ocasionado por obras nuevas o modificaciones de ingeniería, esto implica cambio en instalación de postes, reconfiguración de protecciones, reconexiones para la alimentación de nuevos proyectos, etc.

En segundo lugar, se encuentran los choques a postes, que concentran un 10.34% de la totalidad de fallas registrada en los últimos 3 años. En este lugar cabe agregar que el choque a tirantes de postes, normalmente terminan derribando el poste en sí, dependiendo de la intensidad del choque, por lo que es conveniente para este estudio adicionarles los choques a los tirantes de postes a los choques a postes ya que al final el causante es el choque de un vehículo en contra la red de distribución. Por lo tanto, el porcentaje se adiciona dejando un 13.08% del total de sucesos en la red de distribución.

3 Revisión Bibliográfica

A continuación, se describe una serie de estudios, con el propósito de rescatar sus mejores aspectos así hacer un filtro de variables, zonas, metodologías, etc., son más eficientes al instante de emplear en la Región de Valparaíso.

3.1 Evaluación de Colocación de Poste Público y el Impacto en las Tasas de Colisión .

3.1.1 Descripción

Informe de tesis presentado a la Facultad del WORCESTER POLYTECHNIC INSTITUTE en cumplimiento parcial de los requisitos para el Grado de Maestro en Ciencias, 23 de abril del año 2008 [2].

3.1.2 Estrategia

El objetivo principal de este proyecto fue validar o desarrollar un modelo de predicción que se podría utilizar para identificar postes de alto riesgo en función de la geometría de la carretera y las características del poste. El estudio primero necesitaba identificar un área de estudio y luego recolectar datos a lo largo de esta ruta.

Una vez que se identificó el área de estudio, se determinaron las características viales necesarias y un método de recopilación de datos. Además, es importante tanto la recopilación de datos para los postes chocados como los no chocados. Con el fin de identificar los sitios críticos, se ordenó una base de datos exhaustiva de los accidentes a nivel estatal proporcionados por Massachusetts Highway Department (división de carreteras del Departamento de Transporte). Solo se consideraron las colisiones que involucraban a los postes como el evento más dañino, todos los bloqueos que involucraban otros objetos fijos se descartaron. La evaluación se realizó utilizando tres años de datos obtenidos de los años 2003, 2004 y 2005. Con la ubicación de los sitios de accidentes previos disponibles, la atención se centró en decidir los campos de datos necesarios y desarrollar un método para recopilar los datos. Se determinó que sería necesario recopilar: geometría de la carretera como curvatura horizontal y pendiente, desplazamiento lateral, límite de velocidad, ubicación del poste en relación con la alineación horizontal (dentro o fuera de la curva o en el punto de tangencia), ubicación del poste relativo a la alineación vertical (en la parte

superior, media o inferior de la colina), Densidad de polos de servicios públicos, Tipo de intersección (señalizado o no), Proximidad a otros objetos fijos (principalmente barandilla), deficiencias del pavimento (es decir, surcos, baches, grietas), la escarcha arrecia), el ancho de la carretera y el tráfico diario promedio anual.

3.1.3 Variables Utilizadas

Según este estudio las variables que mejor describen el área a tratar son:

- Distancia lateral promedio en pies
- Tráfico diario promedio, por año (AADT)
- Densidad, numero de postes por milla
- Curvatura horizontal en pies
- Pendiente
- Velocidad limite en millas por hora

Distancia lateral promedio en pies

Se realizó la medición, empleado una cinta métrica Lufkin Tuffboy de 100 pies de decimales mostrada en la Figura 3-1, desde el borde del camino recorrido hasta la parte delantera del poste de red pública. El borde del camino recorrido se definió como el borde de la línea blanca única donde existía; si no había, los frentes del borde del pavimento marcaban el borde del camino recorrido. Si el poste de la red se encontraba detrás de una barrera de protección, la medición se tomó desde el borde del camino recorrido hasta la parte delantera de la barrera de protección, y se tomó otra medición al frente del poste de la red pública. Las mediciones siempre se tomaron perpendiculares al borde de la carretera, por lo que se registró el desplazamiento lateral mínimo.



Figura 3-1 Cinta Métrica Topográfica [2]

Trafico diario promedio, por año

Los datos del tráfico diario promedio anual (AADT) se obtuvieron del centro de Massachusetts, Agencia de planificación regional y el sitio web de MassHighway.

Alineación horizontal y vertical

Debido al equipo y las limitaciones de tiempo que examinan ella longitud del camino no era una opción factible. La única otra alternativa era usar datos existentes. Las fotografías aéreas con referencias espaciales están disponibles en la página principal de MassGIS, que fueron descargados e importados a Autodesk Civil3D. Una vez que se abrieron las imágenes en Civil3D, por trazando la línea central de la carretera y creando las mejores curvas de ajuste, una alineación horizontal podría ser creado. Consulte la Figura 3-4 para ver una parte de la alineación horizontal.



Figura 3-2 Parte de la alineación horizontal y las fotografías aéreas

Una vez que la alineación horizontal fue creada, las coordenadas x e y estaban disponibles, pero para obtener el grado de la carretera, Todavía era necesario obtener las coordenadas z. La superficie del área fue creada y exportada de Google Earth, estas coordenadas luego se importaron a Civil3D. Al superponer la alineación horizontal en la superficie, fue posible extrapolar la z correspondiente coordenadas. Con las coordenadas z se creó un perfil y bajo el supuesto de que el camino aproximadamente siguiendo la forma de la elevación de la superficie, se colocó una curva suave a lo largo del perfil.

Una porción de la alineación vertical se muestra a continuación en la Figura 3-3. Los datos de alineación se tabularon y se exportaron a Microsoft Excel. Esto produjo dos hojas de cálculo, el primero con las curvas horizontales y el otro con el grado de su pendiente.

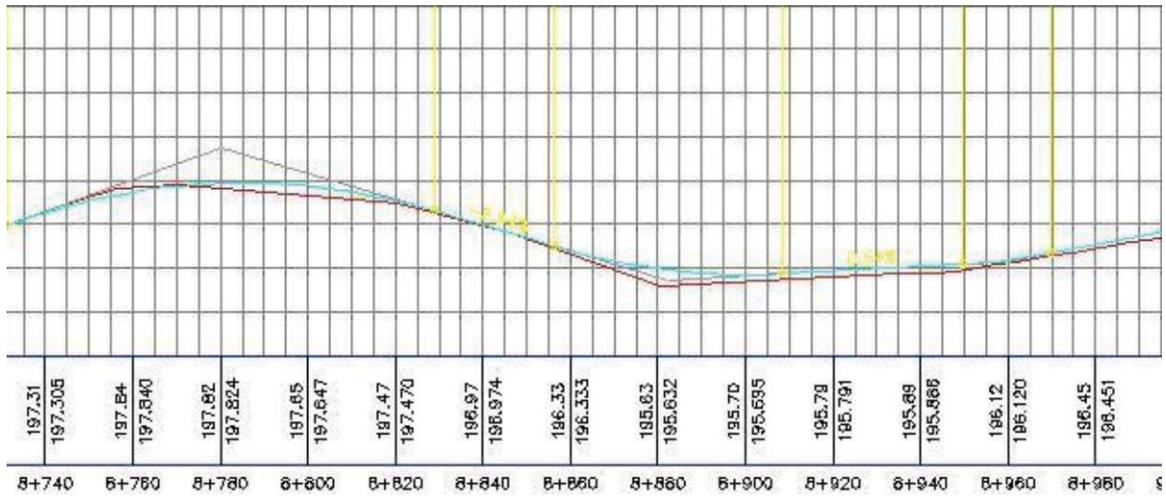


Figura 3-4 Porción de la Alineación Vertical

Varibales restantes

Los campos de datos como el límite de velocidad, las deficiencias del pavimento, la ubicación del poste en relación con la alineación horizontal (por ejemplo, dentro, fuera o tangente a la curvatura) y alineación vertical (por ejemplo, arriba, abajo o en medio de una colina), el número de postes y el tipo de intersección se obtuvieron de observaciones de la zona

Tomar en cuenta

Inicialmente, cada poste se contabilizó y dado que las mediciones solo se tomaron en las estaciones, los postes situados detrás de la barandilla se incluyeron en la densidad. Con el desplazamiento lateral fue posible identificar todos los postes que se encuentran detrás de la barandilla. Sin embargo, los postes detrás de la barandilla no podían descartarse simplemente porque varios de los postes de la red pública se ubicaron a menos de tres pies detrás de la barrera de protección y en algunos casos justo detrás, como se puede comprobar en la Figura 3-5, que no permite que la baranda se desvíe correctamente y el vehículo todavía entraría en contacto con el poste de la red pública. Además, algunos postes fueron ubicados detrás de la barandilla, pero la barandilla no estaba a la altura necesaria para desviar un vehículo (Figura 3-6). La densidad se ajustó para incluir postes que no estaban detrás de barandillas y postes que estaban a menos de tres pies de la parte delantera de la barandilla.



Figura 3-5 Poste Ubicado justo detrás de la barandilla



Figura 3-6 Barandilla termina antes del postes

3.1.4 Desarrollo de Modelo utilizado

Utilizando el análisis de regresión múltiple en Matlab, se creó el modelo de ajuste de mínimos cuadrados de la ecuación 3-1 para estimar los choques a postes por milla por año utilizando las características del sitio, expresado con la letra y . O dicho de otra forma se utilizó una Regresión Matemática Lineal, donde X_1, X_2, X_3, X_4, X_5 y X_6 corresponden a las variables; distancia lateral promedio en pies, AADT, Cantidad de postes por milla, curvatura horizontal en pies, pendiente y límite de velocidad, respectivamente; y a, b, c, d, e, f los coeficientes de la Regresión Matemática Lineal y por último el coeficiente de error de la regresión expresado con la letra g .

$$y = a * X_1 + b * X_2 + c * X_3 + d * X_4 + e * X_5 + f * X_6 + g \quad (3-1)$$

Gracias a la herramienta virtual Matlab y la recopilación de todas las variables en cuestión se lograron obtener todos los coeficientes de la regresión lineal, a, b, c, d, e y f , junto con su error g .

Para el modelo, los valores promedio de distancia lateral, AADT, límite de velocidad, pendiente y horizontal curvatura se utilizaron como variables, así como la suma de los postes por milla. Además de utilizando el valor promedio para la pendiente, se asumió que era absoluto ya que el signo de la pendiente dependía de la dirección del viaje del vehículo. Dado que los vehículos viajan en ambas direcciones y se cuelga podría ocurrir de cualquier manera, se decidió considerar solo cuán pronunciada era la calificación y no su dirección.

Muchas de las variables se comportaron según lo previsto en función de las tendencias reales, por ejemplo, como la curvatura horizontal aumenta los choques estimados por milla por año disminuye, a medida que la calificación aumenta, también lo hace la estimación, y el aumento en la velocidad resulta en una disminución en el tiempo de reacción y subsecuentemente más fallas por milla por año.

El aumento en la distancia lateral debería resultar en un menor número de fallas, este es el caso con los datos reales. También se espera que el número de bloqueos aumente a medida que el número de postes de servicios públicos aumenta.

Fue inesperado que los bloqueos previstos disminuyan con el aumento de AADT. Lógicamente, a medida que aumenta el número de vehículos en la carretera, los accidentes también aumentarían, pero el modelo puede no es compatible con esto debido a la cantidad limitada de datos de fallas disponibles.

Evaluación del Modelo

Para validar un modelo, debe ser comparado con un punto de referencia. Los valores calculados usando el modelo de predicción, se comparó directamente con los accidentes reales por milla por año (utilizando datos de 2003 a 2005). Cuando se compararon los accidentes por milla por año de esta manera la correlación fue pobre. Esto no es completamente inesperado porque Gange sugieren enfáticamente que su modelo se use únicamente con fines de priorización, sin prever el número esperado de accidentes, por lo tanto, en lugar de intentar comparar directamente los

accidentes por milla por año, los segmentos de milla se priorizaron usando tanto los datos de choque reales como del modelo.

Limitaciones

Hay varias razones posibles por las que este modelo no puede realizar una predicción aceptable de choques a postes de servicios públicos a lo largo de la Ruta 31 en Spencer o en zonas geográficamente distintas a las utilizadas en el entrenamiento. Inicialmente, se utilizaron tres años de datos en accidentes para determinar los choques reales por milla por año, donde se registraron 16 choques a postes en total, corroborando una magnitud de muestras insuficiente. Es posible una mejor predicción con una mayor cantidad de muestras en el entrenamiento. El modelo de Gange se desarrolló utilizando datos de Washington, Carolina del Norte, Michigan y Colorado, esta podría ser la causa de la discrepancia por muchas razones. El terreno en estos estados es muy diferente de Massachusetts, por lo que el grado y la curvatura horizontal también pueden variar mucho, ya que son estados considerablemente más jóvenes; los caminos en Massachusetts son en muchos casos más antiguos o tuvieron que construirse alrededor de estructuras preexistentes, además, cada Departamento de Transporte tiene su propio conjunto de normas y directrices, por lo que las normas y políticas estándar pueden ser más estrictas. Otra posible explicación es que el modelo prioriza segmentos de una milla, puede ser un segmento demasiado largo para una carretera como esta donde la geometría y las características de la carretera varían en segmentos más pequeños. Una buena alternativa sería que los segmentos deberían haberse dividido en función de dónde cambiaron sus características en lugar de dónde empezaron en relación con la línea de la ciudad.

3.1.5 Conclusiones del Modelo

Este estudio no pudo validar o desarrollar un modelo estadísticamente significativo. El modelo de predicción no pudo priorizar con precisión los segmentos de carretera que necesitan medidas correctivas. Hay muchas razones posibles para esto: el modelo es demasiado simplista y no tiene en cuenta los efectos de la geometría del camino, no se usaron suficientes datos de choque para obtener accidentes exactos por milla por año para la longitud de la carretera de 9,8 millas, o no es aplicable a las carreteras de Massachusetts ya que se desarrolló utilizando datos de Washington, Carolina del Norte, Michigan y Colorado, donde rigen diferentes normas y políticas. Aunque el modelo desarrollado en Matlab utilizando los datos recopilados para el área de estudio da prioridad a los sitios en el mismo orden que los datos de choques reales, los valores pronosticados para accidentes por milla por año no son estadísticamente significativos debido al tamaño de muestra pequeño y al gran margen de error. Si bien el desplazamiento lateral y la densidad de los postes de servicios públicos son características importantes para determinar el riesgo de que se golpee un poste de servicios públicos, no son los únicos factores que deben considerarse. En función de las observaciones realizadas en el campo y de los datos de bloqueo existentes, aún se producen bloqueos en ubicaciones con grandes compensaciones o bajas densidades. La geometría de la carretera afecta la probabilidad de que se produzca una fuga de la colisión y, en consecuencia, debe considerarse al determinar la posibilidad de que se produzca una colisión con un poste de electricidad. Por ejemplo, un poste colocado en la parte exterior de la curva en

una pendiente descendente es más probable que sea golpeado que un poste con el mismo desplazamiento lateral en una sección recta nivelada de la carretera. Por lo tanto, aunque no sea posible ajustar la geometría de la carretera al aplicar medidas correctivas, aún es importante tener en cuenta la geometría al identificar y priorizar los polos peligrosos. A pesar de que este estudio es incapaz de identificar ubicaciones de polos de alto riesgo utilizando un modelo, es posible reconocer sitios que necesitan remedio basados en observaciones de campo y choque real.

Recomendaciones a futuro

Se recomienda una recopilación de datos más extensa para validar el modelo de regresión múltiple lineal desarrollado por este estudio. Se sugiere que los datos se usen para crear un modelo estadísticamente significativo que sea aplicable a las calles aplicando una clasificación inicialmente. El modelo desarrollado por este estudio trató las variables como independientes; sin embargo, parece haber muchas relaciones entre las variables y cierta dependencia. Una forma diferente de ecuación puede expresar mejor estas relaciones y, por lo tanto, el riesgo.

Finalmente, se debe desarrollar un procedimiento operativo estándar para la colocación de nuevos postes de servicios públicos, así como para la reubicación de los postes existentes que se consideran peligrosos.

3.2 Estudio en profundidad de accidentes que involucran colisiones con postes de servicio públicos

En una revisión de los datos de accidentes disponibles en el momento, Good y Joubert [1973] buscaron encontrar las reducciones en accidentes, lesiones y muertes que podrían esperarse por medio de tratamientos de ingeniería apropiados de riesgos fijos en la carretera. Descubrieron que las estadísticas de accidentes publicadas eran inadecuadas para este propósito, pero que para el único Estado australiano para el que se disponía de datos, el 9.5% de las muertes no peatonales se produjeron en colisiones con postes de servicios públicos. Además, las colisiones de postes representaron el 24% de las colisiones de objetos fijos informadas (pero produjeron el 42% de las muertes por este tipo de accidentes), y los postes fueron la clase de objeto más frecuentemente involucrada en choques de un solo vehículo. Se observó también que este tipo de choque ocurrió mayoritariamente en áreas urbanas, un hecho que reduce la tarea de investigar posibles acciones correctivas.

3.2.1 Descripción

Autores M. C. Good, J.C. Fox y P. N. Joubert, Departamento de Ingeniería Mecánica e Industrial, Universidad de Melbourne, Parkville, Vie. 3052, Australia, 17 de diciembre del año 1984 [9]

3.2.2 Estrategia

El estudio tenía los siguientes objetivos generales:

- Llevar a cabo una encuesta de accidentes que proporcionaría la información detallada en accidentes de poste que no está disponible en las estadísticas de accidentes informadas regularmente.
- Desarrollar un modelo de predicción estadística que permita la identificación del riesgo de accidente a partir de mediciones de las características del sitio.
- Investigar más las medidas de reducción de pérdidas disponibles para colisiones de postes de servicios públicos.
- Obtener datos de costos para aplicar a los análisis costo-beneficio de la propuesta de remedio medidas.

Para asegurar que la encuesta de accidentes abarcara todos los accidentes de incapacitación de vehículos con severidades que van desde daño a la propiedad hasta lesiones fatales, se estableció una red de notificación rápida basada en operadores de camiones de remolque. En comparación con los servicios de policía y ambulancia, las grúas son generalmente el primer servicio de emergencia que llega a una escena de choque, y son el único grupo que atiende prácticamente todos los accidentes lo suficientemente severos como para que se deshabilite un vehículo. Por lo que se realizaron muestras durante un año (1976-1977), sumando a éste 879 choques de postes. El equipo de investigación centralizado pudo cubrir toda el área de la encuesta, una tarea que de otro modo hubiera sido imposible debido al tamaño del área y la frecuencia de los accidentes. Además, la información suministrada por los operadores de remolque, generalmente fue obtenida en cuestión de minutos tras el accidente, incluido el lugar del accidente, la hora del día, las condiciones climáticas y si se requirió la asistencia de la ambulancia. Los servicios de las ambulancias proporcionaron detalles de los accidentados, datos importantes para el costo provocado por el accidente.

Durante la inspección inicial del sitio y una fotografía tomada por cada vehículo accidentado, la secuencia del accidente se reconstruyó a partir de la evidencia física (daño del vehículo y del poste, marcas de deslizamiento, escombros, etc.) y de los informes de los operadores de grúas.

La información de control sobre las características del vehículo y del sitio se obtuvo repitiendo las mediciones apropiadas para muestras seleccionadas al azar de 795 postes y 627 vehículos. Sin estos datos, podrían haberse hecho pocas inferencias útiles sobre los factores que determinan la ocurrencia.

Es importante tener en cuenta que se generó una muestra estratificada de sitios de postes seleccionados al azar a partir de un inventario de segmentos de carretera, de modo que la proporción de postes en cada grupo de datos fue la misma que para la muestra de accidentes.

Debido a que la "densidad" de los postes a lo largo de los segmentos de la carretera varía, la selección del poste aleatorio idealmente debería haber sido de un inventario de postes, en lugar de segmentos de camino. Sin embargo, tal inventario no estaba disponible, y el efecto de descuidar la densidad del poste se mostró posteriormente como mínimo. La muestra aleatoria de vehículos se obtuvo de vehículos que paraban en cinco estaciones de gasolina en una variedad de áreas socioeconómicas alrededor de Melbourne, Australia. Esta muestra proporcionó

principalmente información sobre la distribución de las características de los neumáticos en la población de vehículos.

Características Generales de Accidentes de Postes

La muestra del accidente se clasificó según si el impacto del poste fue el colisión primaria o secundaria, y de acuerdo con el nivel de lesión del peor herido ocupante. La Figura 3-7 muestra este desglose, con la gravedad del accidente descrita como fatal, lesión personal solamente o daño a la propiedad solamente. La clasificación de la muestra del accidente por características de la carretera y secuencia de impacto se muestra en la Figura 3-8. La distribución de accidentes de postes por clase de carretera y características de la carretera en los cinco grupos de datos utilizados para el análisis estadístico se muestra en Figura 3-9. Las calles principales se refieren a caminos arteriales y colectores, mientras que las calles secundarias se refieren a calles residenciales.

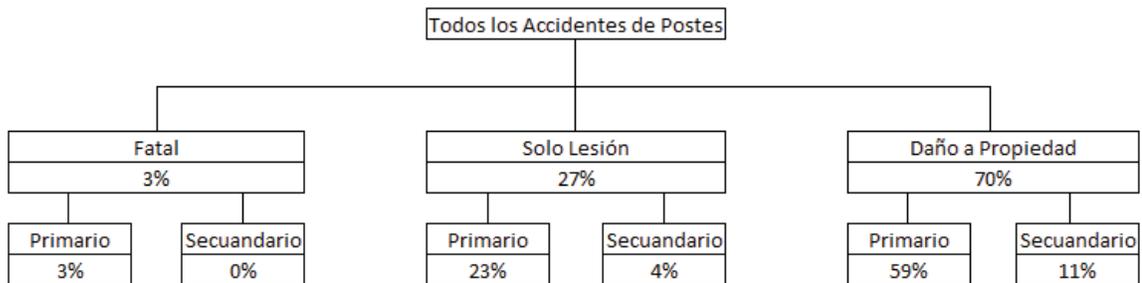


Figura 3-7 Distribución de accidentes de postes por gravedad de accidentes y secuencia de accidentes. En una colisión de poste primario, un polo es el primer objeto alcanzado por un vehículo errante. Una colisión de polos posterior a una colisión vehículo-vehículo

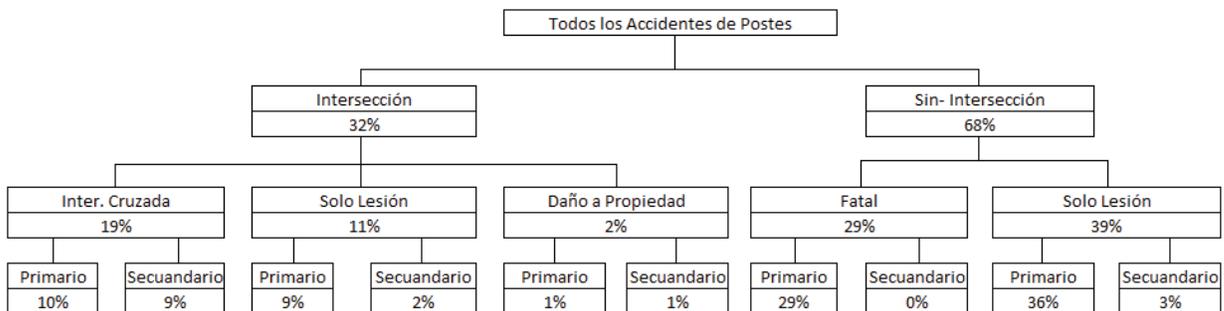


Figura 3-8 Distribución de accidentes de polos por características de carretera y secuencia de impacto

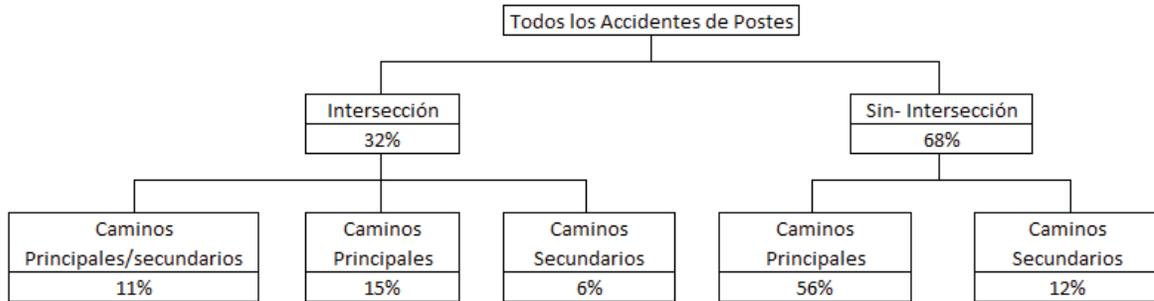


Figura 3-9 Distribución de accidentes de polos por clase de carretera

Una serie de características de los accidentes de poste que surgieron del accidente muestra son:

- La mayoría de la muestra del accidente provino de las carreteras principales
- El 68 % de los accidentes ocurrieron en sitios que no eran intersecciones; cercano a la mitad de estos implica la curvatura horizontal de la carretera.
- La mayoría de los sitios de accidentes (el 90% de los principales sitios de tránsito y el 99% de los sitios secundarios) se encontraban en zonas de límite de velocidad de 60 km/h. El ocho por ciento de los principales sitios de accidentes de tránsito se encontraban en zonas de límite de velocidad de 75 km/h, mientras que el 2 % restante se encontraba en zonas de 100 km/h.
- Por lo general, dos de cada tres vehículos que salen de la carretera no chocan con postes. Por lo tanto, no se puede considerar que los postes proporcionan una "protección" efectiva para los peatones o las propiedades colindantes. A pesar de esto, menos de 1 en 200 muertes de peatones ocurren fuera de la calzada. Por lo tanto, la eliminación de postes, o su reemplazo con diseños frangibles, no daría lugar a un aumento perceptible en el peligro para los peatones. Cabe señalar que es más probable que ocurran accidentes de postes a horas del día (y bajo condiciones climáticas) cuando el tránsito de peatones es más liviano.
- Los accidentes con postes tienen cuatro veces más probabilidades de ocurrir cuando las carreteras están mojadas que cuando están secos. 38% de la muestra del accidente surgió de un camino mojado accidentes.
- La mayoría de los postes golpeados en los caminos curvos se encontraban en el exterior de la curva. La proporción se redujo cuando las carreteras estaban mojadas, aparentemente debido a un cambio en el mecanismo de pérdida de control.

Modelo de Predicción Estadística

Relación entre Características del Lugar y su Ocurrencia de Choques a Postes

Las mediciones de carreteras, tráfico y variables de ubicación de postes se realizaron en una muestra de sitios en los que se produjeron accidentes de postes, y en un grupo de control de postes seleccionados al azar (obtenidos de una base de datos de inventario de carreteras). Para

garantizar que el análisis estadístico posterior fuera posible, la muestra "aleatoria" se estratificó de acuerdo con la descripción del sitio y la clase de camino.

El análisis estadístico se basó en el concepto de "riesgo relativo" que mide la participación accidental de postes con un atributo de sitio dado en relación con sus números en la población de todos los postes. Por ejemplo, la Figura 3-10 muestra la variación del riesgo relativo con el atributo "desplazamiento lateral". Los postes en la línea de acera tienen más del triple de probabilidades de verse implicados en un accidente que aquellos a más de 3 m de distancia.

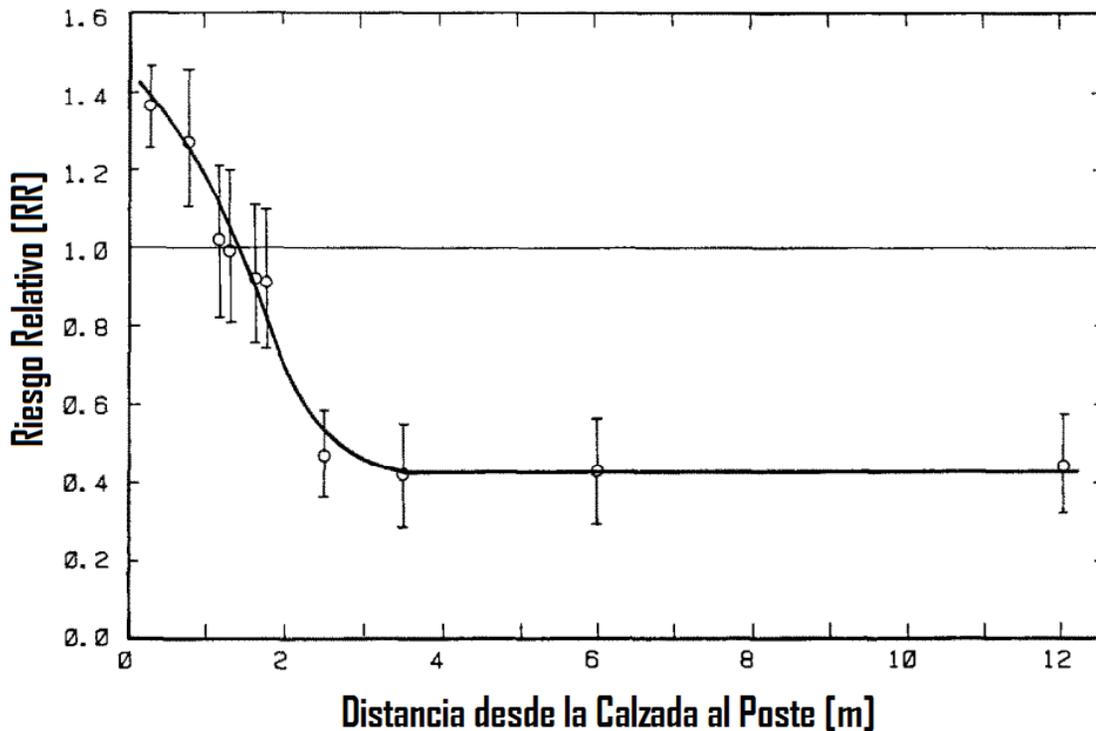


Figura 3-10 Riesgo Relativo VS Distancia del Postes a la Calzada [9]

La estimación del riesgo relativo asociado con un atributo de sitio A (RRA) se calculó así:

$$RR^A = \frac{\text{Proporción de postes en la muestra del accidente el atributo A}}{\text{Proporción de postes en la muestra aleatoria con el atributo A}} \quad (3-2)$$

Las posibles correlaciones e interacciones entre las variables se investigaron con pruebas de Chi-cuadrado para tablas de contingencia de dos y tres vías. Se derivaron las relaciones entre el riesgo relativo y las variables de sitio individuales, teniendo en cuenta las correlaciones e interacciones (que, afortunadamente, fueron pocas en número y de efecto débil).

Dentro de un grupo de datos Estadísticos, un RF de "factor de riesgo", representa el efecto combinado sobre el riesgo de los valores de las variables predictoras seleccionadas, este podría calcularse para cualquier poste como producto de los riesgos relativos individuales asociados con las características particulares de su sitio, siempre que estos fueran mutuamente independientes. Por ejemplo, para el grupo de datos MNI:

$$RF_{MNI} = \prod_i RR_{MNI}^{V_i} \quad (3-3)$$

donde $RR_{MNI}^{V_i}$ representa el riesgo relativo asociado con la variable predictora V_i dada la pertenencia al grupo de datos MNI.

El factor de riesgo así calculado es una representación compuesta de las características del sitio, y su valor puede considerarse como un atributo del sitio, al igual que la curvatura máxima o la resistencia al deslizamiento son atributos. Para seleccionar la combinación independiente más discriminatoria de variables predictoras e investigar la posibilidad de "saturación" del riesgo (a niveles de riesgo altos y bajos), se calculó la variación del riesgo relativo asociado con el atributo RF para varios modelos candidatos. Idealmente, cualquier riesgo relativo y la RF a partir de la cual se calculó deberían ser numéricamente iguales. Los modelos alternativos se evaluaron sobre la base del rango de RR producidos y qué tan cercanos coincidían con los RF. Figura 3-11 muestra la variación cercana a la ideal del RRs de riesgo relativo RR_{MNI}^{RF} con factor de riesgo RF_{MNI} para el modelo de grupo de datos MNI finalmente seleccionado. El riesgo relativo total (TRR) para un poste (relacionando su peligro con el promedio de todos los postes de la población) se obtuvo como el producto de su factor de riesgo dentro de un grupo de datos y el riesgo relativo asociado con la pertenencia a ese grupo. Por ejemplo, para un polo en el grupo de datos MNI,

$$TRR = RR^{MNI} \times RF_{MNI} \quad (3-4)$$

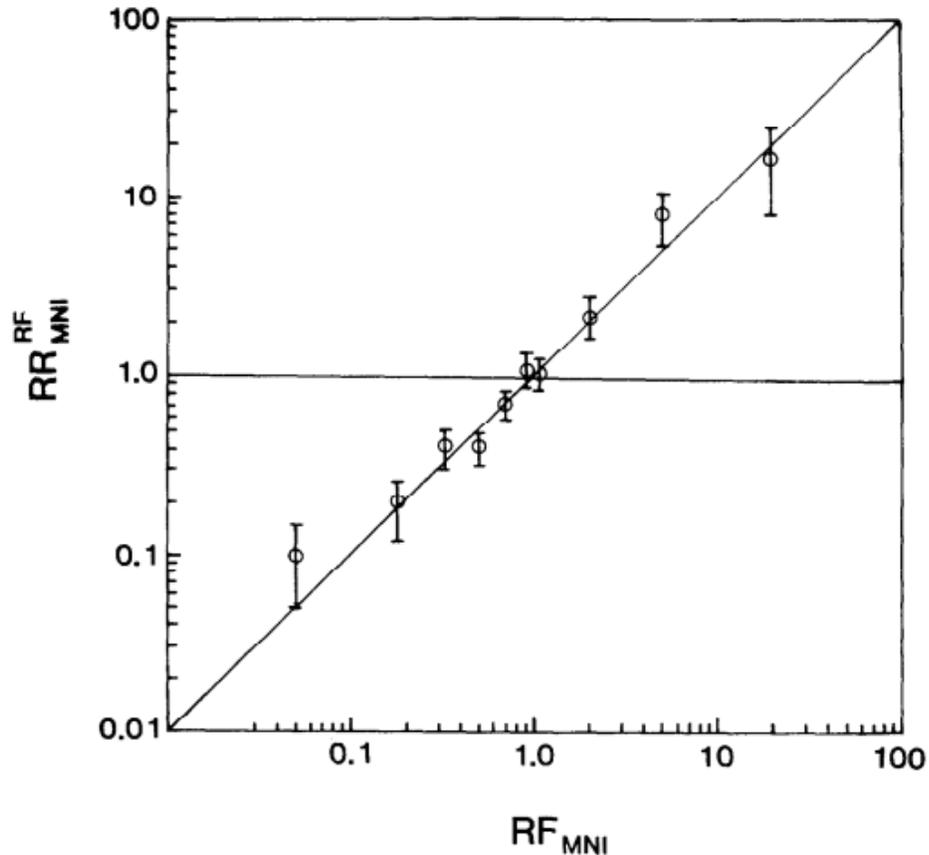


Figura 3-11 Prueba del modelo de factor de riesgo para el grupo de datos MNI: el riesgo relativo RR_{MNI}^{RF} para el atributo de poste RF_{MNI} , debe ser numéricamente igual al factor de riesgo RF_{MNI} .

A partir de una estimación del número total de postes en el área de estudio, se dedujo la probabilidad media de accidente. Dado esto, y el TRR para un sitio determinado, se puede calcular el número esperado de accidentes de postes en el sitio. Como se indicó anteriormente, el modelo final permite calcular la tasa de accidentes anual esperada para un sitio dado en función del sitio medido características. Para el modelo principal de no-intersección de carreteras, se requieren los siguientes datos:|

$|K_{max}|$ Curvatura horizontal máxima aguas arriba del polo

$AADT$ Tráfico diario promedio anual

ST Resistencia al deslizamiento en el pavimento (medida mediante prueba de péndulo)

LO Desplazamiento lateral del poste

W Ancho de la carretera (solo para caminos no divididos)

DC Distancia entre el polo y el inicio de la curva

PD Deficiencias del pavimento (corrugaciones, etc.)

- e* Súper elevación en la curva
OIB Poste en el exterior / interior de la curva

Los grupos de postes que posteriormente se muestran como los que brindan la mayor oportunidad para acciones correctivas costo-efectivas son los que se encuentran en los principales sitios de tránsito no-intersecciones y en la intersección de las carreteras principales. Para este último grupo, los datos requeridos para el modelo de predicción son:

- AADT* Tráfico diario promedio anual para ambas carreteras
ST Prueba de deslizamiento pendular
G Grado en la intersección
DV Caminos divididos / indivisos
LO Desplazamiento lateral del polo
IT Tipo de intersección

Se presentan tres estudios de casos que cubren el rango de la mayoría de las aplicaciones posibles, y se resuelven paso a paso. El primero de estos estudios de caso se puede resumir de la siguiente manera.

El estudio de este caso involucra el diseño de la carretera que se muestra en la *Figura 3-12*. El vehículo que se muestra viaja en una dirección tal que debe sortear una curva hacia la derecha (la conducción está a la izquierda en Australia). Claramente, hay una serie de postes en riesgo en una situación como esta, y todos los postes en las cercanías de la curva deben ser examinados. El riesgo cambia para cada poste en función de su posición en relación con la curva. El modelo debe aplicarse a cada poste por turno, produciendo un riesgo relativo total para cada uno. Estos pueden ser utilizados en los cálculos de probabilidad de accidente que se requieren para las decisiones sobre el posible tratamiento correctivo para esta sección de la carretera.

Para este ejemplo, se analiza el poste marcado con una "X" en la *Figura 3-12*, con dirección de viaje del vehículo como se muestra. El poste sujeto no está cerca de una intersección y, como está adyacente a una carretera principal, se clasifica como un miembro del grupo de datos MNI. Como tal, tiene un riesgo relativo de accidente de 4.36. Esto se muestra en la *Tabla 3-1*, junto con el riesgo relativo determinado a partir de las figuras y tablas del Manual del Usuario indicadas para cada una de las características del sitio. Se obtiene un riesgo relativo total (TRR) como producto de todos los riesgos relativos individuales: $TRR = 141.6$. Es decir, el poste sujeto tiene 141,6 veces más probabilidades de estar involucrado en una colisión que el promedio.

La frecuencia promedio de accidentes para todos los postes en Melbourne se estima en 3.785×10^{-3} por año. Por lo tanto, la tasa de accidentes esperados para el polo sujeto es:

$$E[a] = 141.6 \cdot 3.785 \cdot 10^{-3} = 0.536 \text{ [accidentes por año]}$$

(3-5)

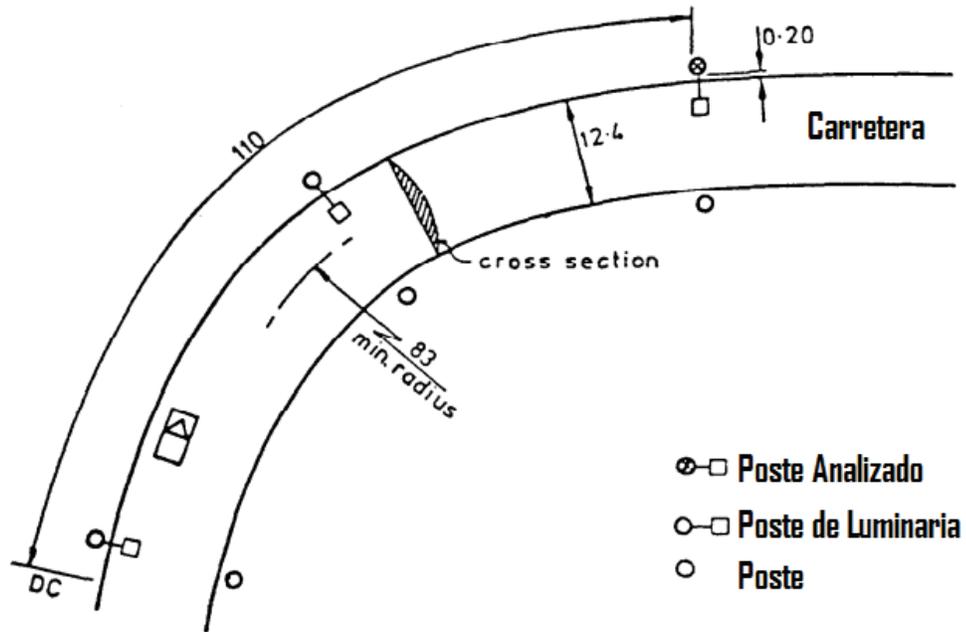


Figura 3-12 Diseño del sitio para el estudio del caso [9]

Tabla 3-1 Estudio del caso

Variable	Valor	RR
Grupo de datos	MNI	4.36
Kmax	0.012	3.10
AADT	17500	1.24
ST	45	1.50
LO [m]	0.2	1.38
W [m]	12.4	1.32
DC [m]	110	1.12
PD	Corrugaciones	2.00
e	Negativo	1.20
OIB	Fuera de	1.15

3.3 Predicción de Accidentes de Tránsito utilizando Redes Neuronales Artificiales y Cuckoo Search

Informe final de proyecto para optar al Título de Profesional de Ingeniero Civil en Informática, Pontificia Universidad Católica de Valparaíso, abril 2015. Por el Alumno Mauricio Roberto Rojas Godoy.

3.3.1 Estrategia

Las redes neuronales artificiales en predicción, se utilizan desde los años 90, sin embargo, sólo desde la última década se empezaron a utilizar en problemas de predicción y clasificación de accidentes de tránsito en distintas ciudades del mundo. Por lo que el departamento de investigación de la Escuela de Ingeniería en Transporte de la Pontificia Universidad Católica de Valparaíso, utilizando una gran cantidad de datos para el análisis de accidentes de tránsito, obteniendo buenos resultados, sin embargo, se han encontrado escasos trabajos de predicción de los accidentes en Chile. En base a lo anterior, surge la idea de la aplicación de técnicas de predicción de accidentes de tránsito, con el fin de construir un modelo que pronostique la cantidad de accidentes ocurridos y comparar éste aplicando las meta heurísticas CS (Cuckoo Search) y PSO (Optimización por Enjambre de Partículas), obteniendo como mejor opción la meta heurística CS [4].

La Neurona Artificial

La neurona artificial fue diseñada para imitar las características del funcionamiento básico de una neurona biológica. Básicamente se aplica un conjunto de entradas a la neurona, cada una de las cuales puede representar la salida de otra neurona. Cada entrada se multiplica por su peso o ponderación, análogo al grado de conexión de la sinapsis [3].

La neurona artificial posee un estado interno, el que se conoce como nivel de activación. El nivel de activación está determinado por las entradas y por los pesos sinápticos que posea, si bien las entradas son externas a la neurona, los pesos pueden cambiar para así poder adaptar el nivel de activación.

Como se desea calcular el nivel de activación, se hace necesario primero calcular la entrada total de la célula a . Este valor se calcula mediante la Ecuación 3-6, en donde se suma cada entrada $X = x_1, x_2, \dots, x_j, \dots, x_n$, que representan las señales de la sinapsis en el caso de una neurona biológica, multiplicada por un peso sináptico $W = w_{i1}, w_{i2}, \dots, w_{ij}, \dots, w_{in}$, que representa la fuerza de conexión sináptica [4].

$$a = (X^T \times W) = x_1 \times w_1 + \dots + x_n \times w_n = \sum_{i=1}^n w_i + x_i \quad (3-6)$$

Aprendizaje de Una Red Neuronal

Corresponde a la parte de un conjunto de pesos sinápticos aleatorios, con el fin de buscar un conjunto de pesos que permitan a la red desarrollar correctamente una tarea en particular. El

proceso de aprendizaje es un proceso iterativo, en el cual se va refinando la solución hasta alcanzar un nivel de operación que de conformidad.

Uno de los métodos de entrenamiento más utilizados en las redes es el Backpropagation (retropropagación). Es un método de aprendizaje supervisado, en el que se aplica un patrón de entrada, el cual se propaga por las distintas capas que componen la red hasta producir la salida de la misma. La salida se compara con la salida deseada y se calcula el error cometido por cada neurona de salida. Estos errores se transmiten hacia atrás, partiendo de la capa de salida, hacia todas las neuronas de las capas intermedias. Cada neurona recibe un error que es proporcional a su contribución sobre el error total de la red. Basándose en el error recibido, se ajustan los errores de los pesos sinápticos de cada neurona. Por lo general una forma de entrenar redes neuronales es mediante la raíz del error cuadrático medio, especialmente para fines predictivos y está dada por la ecuación (3-7):

$$E = \sqrt{\frac{1}{N} \times \sum_{i=1}^N (d_i(n) - y_i(n))^2} \quad (3-8)$$

Donde N es el número de patrones para entrenar la red, d_i es el valor deseado para el i – esimo patrón de entrenamiento e y_i es el valor que entrega la red para el i -ésimo patrón de entrenamiento.

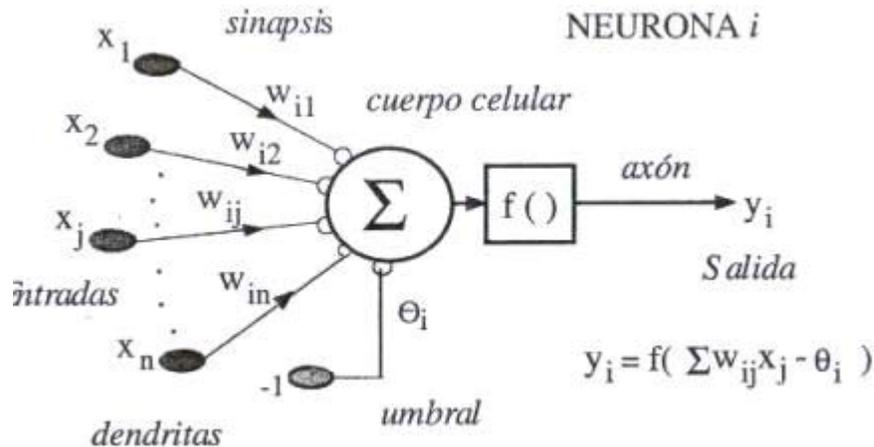


Figura 3-13 Red Neurona Artificial [3]

En la Figura 3-13 se puede observar una Neurona i con sus respectivas entradas, pesos, umbral; que es el encargado de ponderar la importancia del actuar de la neurona i ; y la salida y_i . Cabe recalcar que si la neurona corresponde a la última capa de neuronas esta salida se refleja como y_i , pero si la neurona i corresponde a una capa interna esta se le da el nombre de axón (nombre biológico) y normalmente se representa con la letra a .

Como se mencionó en un comienzo, antes de realizar el aprendizaje de la red neuronal, y así obtener mejores resultados, se utilizaron algoritmos de optimización, por ejemplo, Algoritmos Genéticos (GA), Optimización por Enjambre de partículas (PSO) o Cuckoo Search (CS), los dos últimos mencionados fueron los utilizados en estudio descrito.

La validación de los modelos propuestos se realizó mediante la técnica de Validación Cruzada. Este método consiste en dividir los datos en dos partes, una para pruebas y otra para entrenamiento de la red neuronal.

Actuar de la RED

Las Redes Neuronales Artificiales (RNA) son sistemas entrenables, capaces de realizar un determinado tipo de procesamiento a partir de un conjunto de ejemplos denominados patrones de entrenamiento.

En una RNA se distinguen dos fases de operación:

- Fase de aprendizaje y entrenamiento: En esta fase se presentan a la red un conjunto de patrones de entrenamiento de forma iterativa. La red adaptará los pesos de las conexiones de forma que la respuesta a cada uno de los patrones tenga un error cada vez menor. En general el entrenamiento concluye cuando se alcanza un error determinado.

Interesa más una buena generalización que un error pequeño en el entrenamiento, pues ello indicará que la red ha capturado correctamente las regularidades en los datos. Si se intenta alcanzar un error pequeño en la fase de entrenamiento, se puede provocar que la red memorice los patrones de entrenamiento, con lo que sólo dará una respuesta muy buena para estos.

- Fase de recuerdo o ejecución: Los pesos de las conexiones permanecen fijos (excepto en algunos modelos de red) y la red generará una salida para cada entrada que se le presente. En este momento la red está preparada para procesar datos.

Perceptrón Multicapa

El Perceptrón Multicapa (MLP) es una aproximación universal, dado que cualquier función continua puede ser aproximada mediante él, con al menos una capa oculta de neuronas, aun cuando no implica que sea necesariamente el mejor aproximador universal. Las redes MLP es una de las más utilizadas en la resolución de problemas, debido a su característica de ser un aproximador universal, su fácil uso y su fácil aplicabilidad.

La arquitectura de la red MLP agrupa las neuronas en C capas, normalmente cada neurona de la capa t está conectada con todas las neuronas de la capa $t + 1$, por esta razón se conocen como redes feed forward (conectadas hacia adelante), además estas conexiones tienen un determinado peso que se va ajustando en la etapa de entrenamiento.

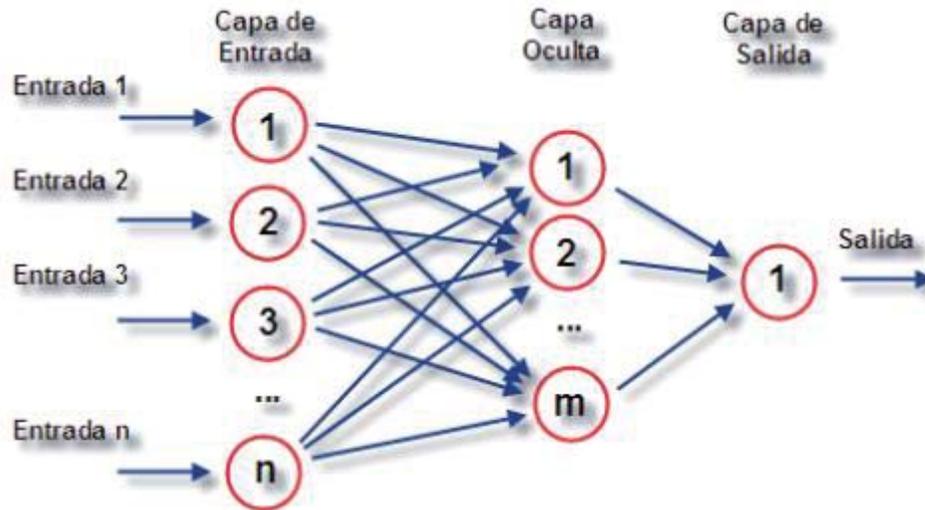


Figura 3-14 Perceptrón Multicapa

Algoritmos de Optimización

Modernos algoritmos de optimización han sido desarrollados para realizar búsquedas globales, por ejemplo, Algoritmos Genéticos y Optimización de Enjambre de Partículas (PSO) y Cuckoo Search (CS). La eficiencia de estos algoritmos ha sido atribuida a que imitan las mejores características de la naturaleza, que han evolucionado por la selección natural durante millones de años. Como en el estudio de Mauricio Rojas el mejor postulante resulto ser el CS, éste será descrito.

Cuckoo Search

Recientemente se ha desarrollado un nuevo algoritmo de optimización, llamado Cuckoo Search (CS) [10].

Algunas especies de aves Cuckoo presentan una agresiva estrategia de reproducción, ponen sus huevos en nidos de otras aves, e incluso pueden remover los huevos del ave propietaria del nido, para que sus crías tengan una mayor probabilidad de incubación [11]. Si el ave propietaria del nido descubre que el huevo no es suyo, puede lanzarlo fuera, o simplemente abandonar el nido y construir uno nuevo en otro lugar. Algunas especies Cuckoo han evolucionado de una increíble manera, pueden cambiar el color y características de sus huevos para imitar los huevos del ave propietaria del nido, esto reduce la probabilidad de que su huevo sea abandonado y aumenta su reproductividad.

Para simplificar el algoritmo, se idealizan las siguientes 3 reglas [10]:

1. Cada Cuckoo pone un huevo a la vez, y lo deja en un nido escogido al azar.
2. Los mejores nidos, con los huevos (soluciones) de mejor calidad, se trasladarán a la siguiente generación.
3. El número de nidos disponibles es fijo, y el ave propietaria puede descubrir a un huevo ajeno con una probabilidad de SI ó NO $p_a \in [0,1]$. En este caso el ave puede lanzar el huevo fuera del nido, o abandonarlo y construir uno completamente nuevo en otro lugar.

Por simplicidad, el último punto puede ser aproximado por la fracción p_a de los n nidos que son reemplazados por nuevos nidos (con soluciones aleatorias). Además, se utilizará la representación simple, en que cada huevo en un nido representa una solución, y los huevos Cuckoo representan una nueva solución, para así utilizar estas nuevas soluciones (Cuckoo) para reemplazar las soluciones que no son buenas en los nidos. Por supuesto, el algoritmo puede ser extendido para el caso en que cada nido tiene múltiples huevos representando un set de soluciones [12].

Análisis de comportamientos principales

Esta técnica estadística permite la síntesis o reducción de la dimensión de variables de entrada, sin la pérdida de información posible.

Los nuevos componentes principales o factores serán una combinación lineal de las variables originales, y además serán independientes entre sí.

Un aspecto clave en ACP es la interpretación de los factores, ya que ésta no viene dada a priori, sino que será deducida tras observar la relación de los factores con las variables iniciales (habrá, pues, que estudiar tanto el signo como la magnitud de las correlaciones). Esto no siempre es fácil, y será de vital importancia el conocimiento que el experto tenga sobre la materia de investigación [12].

Para un desarrollo más ágil se realizará esta técnica estadística con algún software como MiniTab.

3.4 Espectativa Nacional

En cuanto a la obtención de variables, en ambos modelos, serán empleadas y adquiridas gracias a la base de datos de la Distribuidora Eléctrica de la zona, más las entregadas por Vialidad y por la Escuela de transporte de la Pontificia Universidad Católica de Valparaíso. Luego a estas variables se les hará un análisis estadístico llamado Análisis de componentes principales (ACP) como en el estudio de RNA, para así tener un modelo más liviano sin perder su comportamiento propio. Cabe mencionar que el ACP se empleara para cada escenario, así las variables escenario describirán de una mejor manera cada zona.

En cuanto a los modelos escogidos:

1. Modelo de Regresiones No lineales: Esta se asemeja al estudio de Gange [2], pero debido a que la configuración de calles en su geografía es distinta, normalmente son rectas, se necesitara un modelo no lineal para su desarrollo.
2. Redes neuronales: A pesar de que se analizó un solo estudio de este tipo [4], se asemeja de gran forma a la solución que se requiere para predecir la cantidad de choques de postes por calle, y más aun con la meta heurística Cucko Search proporcionando un error menor que con otras meta heurísticas. Otro recurso que se valora de este modelo es que es capaz de aprender, por lo que entregaría una valiosa información con el transcurso de los años y los cambios que sufra las distintas calles de la Quinta Región.

4 Solución Propuesta

Como primera instancia para interactuar con el desempeño de una Red Neuronal, se desarrollarán entrenamientos para distintas configuraciones de estas, llevadas a cabo con las herramientas de simulación Matlab y Spyder (Python)

4.1 Variables Adquiridas

Para el desarrollo de modelo en primer lugar, se debe tener un conjunto de variables considerable, con la finalidad de describir en lo posible su totalidad, de la calle en análisis, de tal forma que la red neuronal en el proceso de aprendizaje sea capaz de comprender como estas variables determinan la problemática en cuestión y posteriormente evaluar su desempeño con variables de calles no utilizadas en el proceso de aprendizaje.

Libro de novedades de la Distribuidora Eléctrica de la Región de Valparaíso

La base de datos en trabajar fue el libro de novedades de la distribuidora Eléctrica de Valparaíso, se esta se extrajeron datos de vital importancia como:

- Fecha y Hora de la novedad ocurrida desde el año 2014 al año 2016
- Nombre de calle donde ocurrió el choque
- Causa: choque de postes o tirante
- Nivel de Tensión: poste afectado de media o baja tensión
- La comuna y ciudad donde ocurrió la novedad

Se filtraron datos como solo choques a postes, descartando los relacionados a choques de tirantes, para efecto de puntualidad en el problema.

Escuela de Transporte

La Escuela de Transporte de la Universidad Católica de Valparaíso, poseía la base de datos, obtenida a su vez desde la Corporación Nacional de Seguridad de Transito, de accidentes automovilísticos en su poder, lo que sirvió de complemento a nuestra base de datos.

En este caso se extrajeron los siguientes datos:

- Fecha y Hora del accidente automovilístico.
- Lugar: región y comuna.
- Zona: urbana o rural.
- Calzada: unidireccional, bidireccional o bidireccional con bandejón.
- Tipo de calzada: adoquín, asfalto, concreto, mixto, ripio o de tierra.
- Estado de la calzada: bueno, malo, o regular

Dentro de esta base de datos algunas variables no se tomaron en cuenta, como, por ejemplo, la causa del choque, estado atmosférico o ubicación relativa de la calle, ya que no describen la calle proporcionalmente y estas pueden variar en un periodo menor de un año.

Cruzamiento de bases de datos

Posteriormente se cruzaron las fechas y horas del evento descritos, pudiendo detectar la calle donde ocurrió, y algunas de sus características, como lo son:

- Nombre de la calle donde ocurrió el suceso.
- La comuna del suceso.
- Poste afectado: media o baja tensión.
- Zona: rural o urbana.
- Calzada: unidireccional, bidireccional o bidireccional con bandejón.
- Tipo calzada: adoquín, asfalto, concreto, mixto, ripio o de tierra.
- Estado de la calzada: buena, intermedia, mala.
- Numero de choques por calle

Para obtener el número de choques por calle ocurridos en este periodo de tiempo (2014-2016) solamente se utilizó la función CONTAR.SI que provee la herramienta Excel y así obtener la frecuencia de eventos en el conjunto de datos. Durante el conteo eventos por calle hubo una serie de imprevistos:

1. Se presentaron sucesos en los que las calles no tenían nombre o simplemente venían con los caracteres “*Sin nombre*”, por lo que, en su defecto, se eliminaron. Si bien esta información descuenta el número de choques en algunas calles, este cambio es mínimo.
2. Para el entrenamiento y aprendizaje de una red neuronal es necesario que esta identifique las variables literales, por ejemplo; la comuna, estado de la calzada, zona o nivel de tensión; como una variable cuantitativa, por lo que se le asignaron las id establecidas ya en las bases de datos obtenidas.

Así se obtuvieron 1186 calles pertenecientes a la región de Valparaíso junto con las variables mencionadas anteriormente y su registro de choques de postes durante 3 años. Posteriormente las calles se ordenaron aleatoriamente y se dividieron en dos grupos, uno llamado grupo A con 700 calles y el grupo B con 486 calles. Todo esto con la intención de utilizar el grupo A para el aprendizaje y el entrenamiento de la red neuronal. Una vez ya entrenada la red se utilizará el grupo B para evaluar la predicción del modelo con datos nuevos (no utilizados en la de aprendizaje).

4.2 Redes Neuronales

Uno de los algoritmos más comunes en una red neuronal es la Back Propagation o en español Propagación hacia Atrás, en donde se utiliza la estimulación hacia adelante o en el "frente" para restablecer los pesos de las unidades neuronales y esto a veces se realiza en combinación con una formación en la que se conoce el resultado correcto

El objetivo de la red neuronal es resolver los problemas de la misma manera que el cerebro humano, aunque las redes neuronales son más abstractas. Los proyectos de redes neurales modernas suelen trabajar desde unos miles a unos pocos millones de unidades neuronales y millones de conexiones que, si bien son muchas órdenes, siguen siendo de una magnitud menos compleja que la del cerebro humano, más bien cercana a la potencia de cálculo de un gusano.

Nuevas investigaciones sobre el cerebro a menudo estimulan la creación de nuevos patrones en las redes neuronales. Un nuevo enfoque está utilizando conexiones que se extienden mucho más allá y capas de procesamiento de enlace en lugar de estar siempre localizado en las neuronas adyacentes. Otra investigación está estudiando los diferentes tipos de señal en el tiempo que los axones se propagan, como el Aprendizaje Profundo, interpola una mayor complejidad que un conjunto de variables booleanas que son simplemente encendido o apagado.

Las redes neuronales se basan en los números reales, con el valor del núcleo y del axón siendo típicamente una representación entre 0,0 y 1,0.

Un aspecto interesante de estos sistemas es que son impredecibles en su éxito con el auto-aprendizaje. Después del entrenamiento, algunos se convierten en grandes solucionadores de problemas y otros no funcionan tan bien. Con el fin de capacitarlos, se necesitan varios miles de ciclos de iteración [13].

4.3 Matlab RNN

Neural Network Toolbox TM proporciona algoritmos, modelos preprogramados y aplicaciones para crear, entrenar, visualizar y simular redes neuronales superficiales y profundas. Puede realizar la clasificación, la regresión, la agrupación, la reducción de dimensionalidad, el pronóstico de series de tiempo y el modelado y control de sistemas dinámicos.

Las redes de aprendizaje profundo incluyen redes neuronales convolucionales (ConvNets, CNN), topologías de red de gráfico acíclico dirigido (DAG) y autoencoders para clasificación de imágenes, regresión y aprendizaje de características. Para la clasificación y regresión de series de tiempo, la caja de herramientas proporciona redes de aprendizaje profundo a largo plazo de memoria a corto plazo (LSTM). Puede visualizar capas intermedias y activaciones, modificar la arquitectura de la red y supervisar el progreso del entrenamiento.

Para conjuntos de entrenamiento pequeños, puede aplicar rápidamente el aprendizaje profundo mediante la realización de aprendizaje de transferencia con modelos pre tratados de redes profundas (incluidos Inception-v3, ResNet-50, ResNet-101, GoogLeNet, AlexNet, VGG-16 y VGG-19) y modelos importados de TensorFlow [®] -Keras o Caffe [14].

Para el desarrollo de esta etapa se utilizó Matlab 2018

4.3.1 Configuración y trabajo de la red neuronal

Se ingresa, al Toolbox de Matlab, el conjunto de datos de entrenamiento, estos son la matriz de datos de entrada, matriz de predicción esperada, previamente normalizados como se muestra en la Ecuación 4-1 (matricial). La normalización se realiza por variable, y esta permitirá mantener el conjunto de datos en un rango de 0 a 1, con la intención de que las magnitudes elevadas de algunos casos no fluctúen en tendencias equivocadas.

$$X' = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (4-1)$$

Además, se debe tener cuidado de transponer la matriz de datos, debido a que el Toolbox requiere esta configuración, posicionando las variables de entrada en las filas y las calles muestreadas en las columnas.

Una vez ya ingresada las matrices de entrada (variables descriptivas de las calles) y de salida (Numero de choques por calle) del grupo A, se accede a la interfaz de creación de red neuronal de Matlab con el comando `>nntool`, esta se muestra en la Figura 4-1

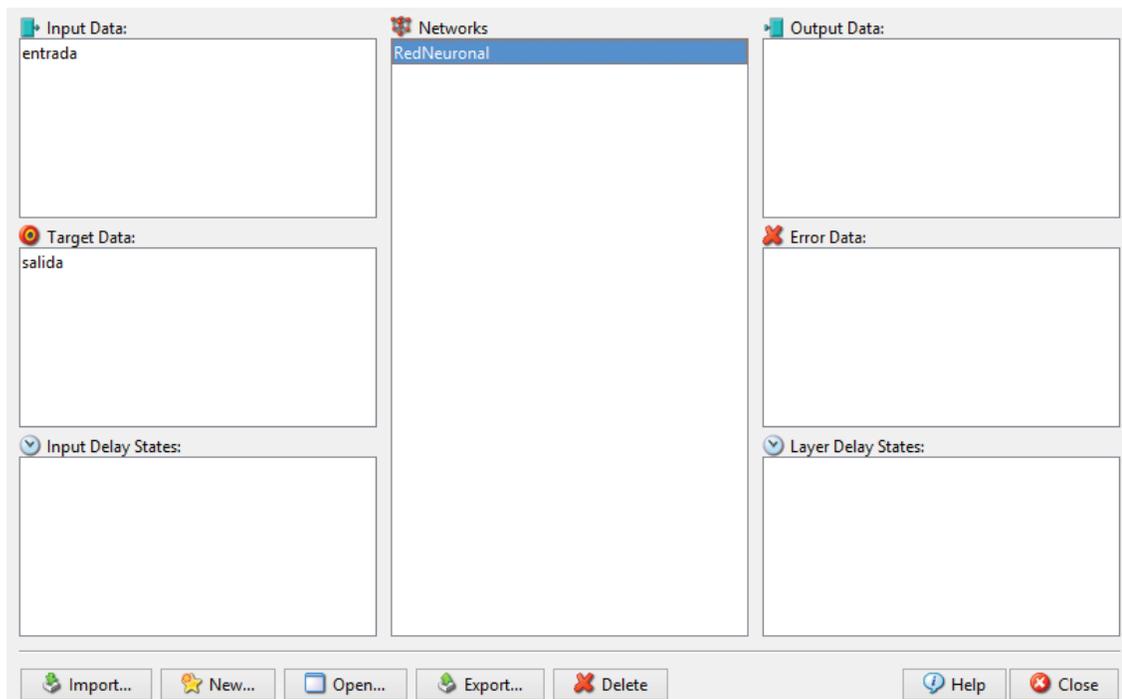


Figura 4-1 Interfaz Toolbox nntool

Dentro del Toolbox se importaron las variables entrada y de salida y se crea la red neuronal. Para la creación de la red neuronal esta herramienta propone distintas opciones, como se muestra en Figura 4-2.

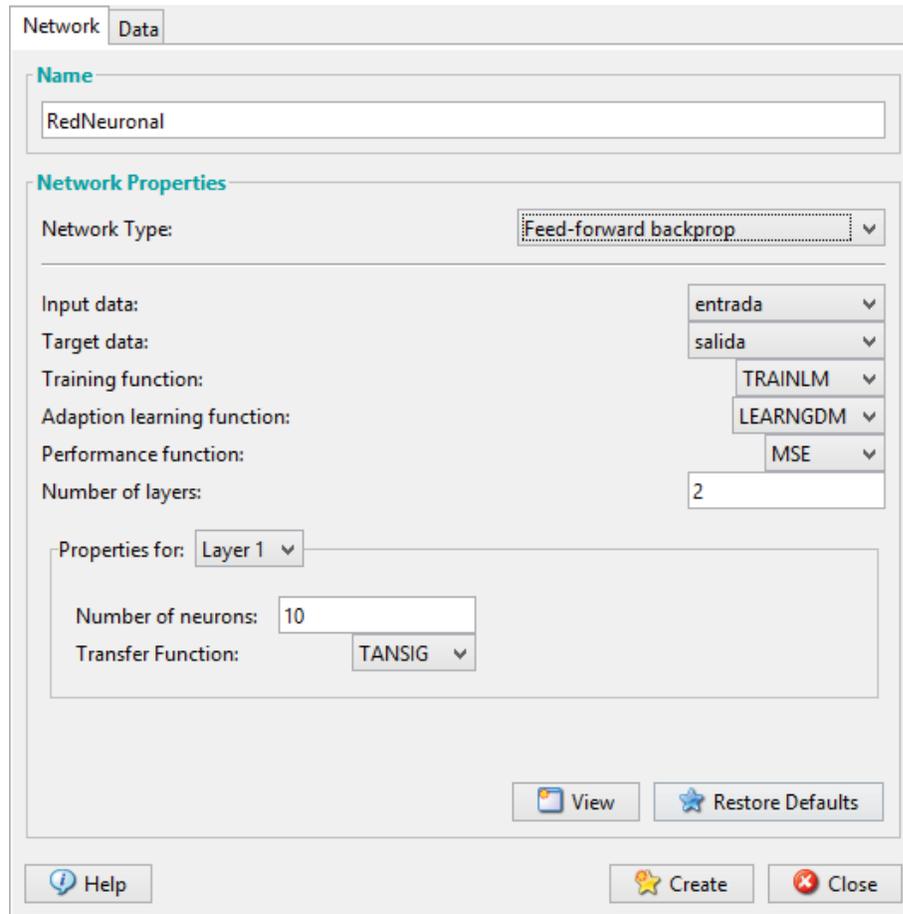


Figura 4-2 Creación red neuronal nntool

En donde se definen:

- Tipo de Red: Retro-propagación
- Las entradas y salidas deseadas
- Funciones de entrenamiento y aprendizaje
- Error utilizado para la simulación con el grupo B, numero: Error Cuadrático Medio
- Numero de capas ocultas
- Numero de neuronas en las capas ocultas
- Función de activación: Sigmoide

En primera instancia para este capítulo se mantuvo constante el Tipo de Red, las funciones de entrenamiento y aprendizaje para analizar desempeño, variando su número de capas ocultas y numero de neuronas de las capas ocultas, entre otros factores.

Posteriormente al abrir la red neuronal creada, se abre una ventana donde podemos observar pestañas de vista previa de la red, parametros de entrenamiento, parametros de simulacion (grupo B) y visualizacion y reiniciacion de los pesos.

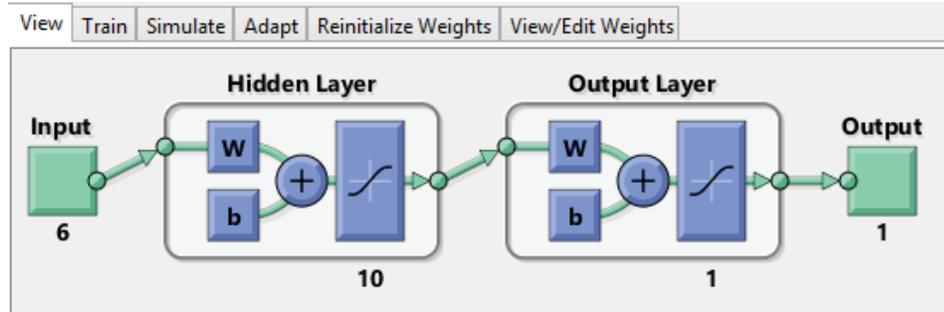


Figura 4-3 Diagrama de capas de la red neuronal creada

En la Figura 4-3 se puede verificar el número de entradas, correspondientes al número de variables de entrada obtenido, el número de neuronas en las capas ocultas, la función Sigmoide de activación por neurona y la capa de salida que corresponde a una sola salida; correspondiente a la cantidad de choques de postes en la calle ingresada.

Training Info		Training Parameters	
showWindow	<input type="checkbox"/> true	mu	<input type="text" value="0.001"/>
showCommandLine	<input type="checkbox"/> false	mu_dec	<input type="text" value="0.1"/>
show	<input type="text" value="25"/>	mu_inc	<input type="text" value="10"/>
epochs	<input type="text" value="1000"/>	mu_max	<input type="text" value="10000000000"/>
time	<input type="text" value="Inf"/>		
goal	<input type="text" value="0"/>		
min_grad	<input type="text" value="1e-07"/>		
max_fail	<input type="text" value="6"/>		

Train Network

Figura 4-4 Parámetros de Entrenamiento

En la pestaña de entrenamiento algunos parámetros interesantes de delimitar son, el número de Iteraciones (Epochs), mínimo gradiente; correspondiente a la diferencia promedio de todas las predicciones con la cantidad de choques deseada (Tarjet), Figura 4-4.

Prosiguiendo, al iniciar el entrenamiento, se despliega una ventana donde se visualiza; la red neuronal, el número de iteraciones, el tiempo que demora el entrenamiento, y el gradiente obtenido en cada iteración, como se muestra en la figura 4-5. El entrenamiento se detendrá en el instante que llegue al número de Iteraciones, al sobrepasar el gradiente establecido y al oprimir Stop Training (detener entrenamiento). Al instante del término del entrenamiento esta herramienta permite visualizar el Coeficiente de Correlación de Pearson (Plot regression) para obtener una perspectiva de cómo se comporta la predicción con respecto al número de choques real.

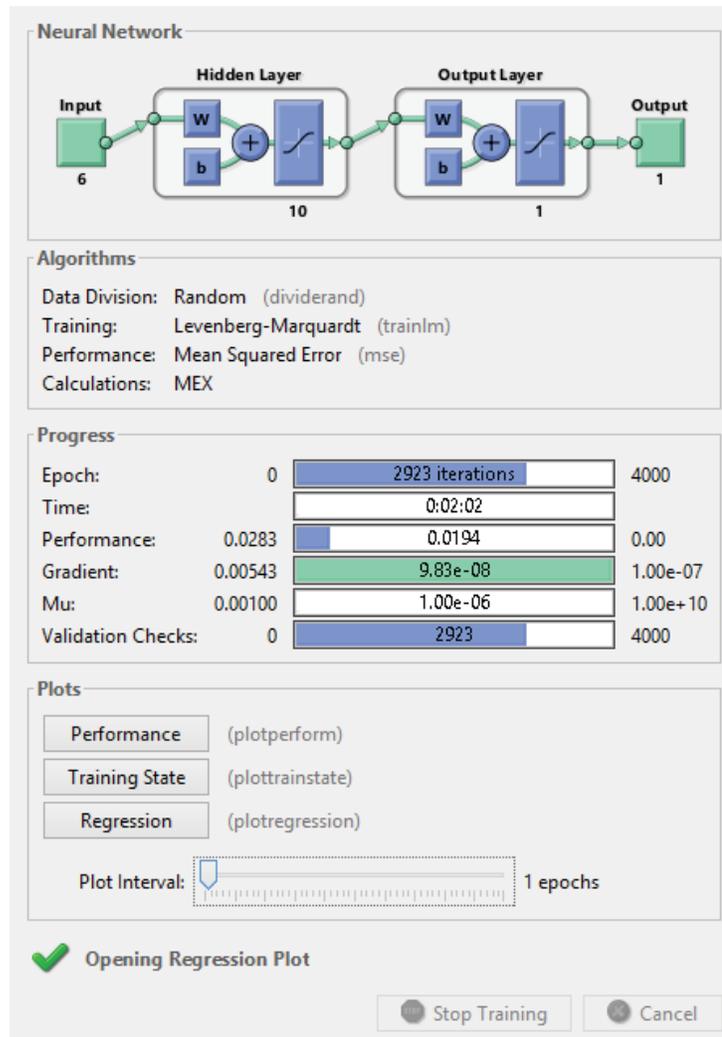


Figura 4-5 Proceso de aprendizaje y entrenamiento de la red neuronal

Si el coeficiente de Pearson no es suficientemente bueno, una opción es reiniciar los valores iniciales de los pesos de la red neuronal, esto se puede realizar con la opción Reinitialize Weights, y posteriormente reiniciar el entrenamiento.

Una vez ya entrenada la Red Neuronal, con un Coeficiente de Pearson aceptable, se prosigue con la simulación de una predicción. Esta se lleva a cabo con el segundo grupo de datos que se poseen, con el fin de evaluar su rendimiento, con entradas conocidas (grupo A) y desconocidas (grupo B). Finalmente se exportan las predicciones al espacio de trabajo de Matlab.

4.4 Python RNN

Además de Matlab, como herramienta virtual para el desarrollo y entrenamiento de una Red Neuronal, se utilizó Spyder 3.6, este es un poderoso entorno de desarrollo interactivo para el lenguaje Python con funciones avanzadas de edición, pruebas interactivas, depuración e introspección. Spyder es un entorno de computación numérica gracias al soporte de IPython y las populares bibliotecas de Python como NumPy, SciPy o matplotlib [15].

Repasando, una típica Red Neuronal, suele tener una capa de entrada, una capa de salida, y una o varias capas intermedias que se consideran ocultas. Cada capa está compuesta por un número finito de neuronas que recoge por un lado los valores de salida de la capa anterior, multiplicado por pesos y devuelve su salida. Estas neuronas suelen modelarse con funciones de activación no-lineales como las funciones sigmoideas, que permiten transformar las entradas de cualquier dominio a valores entre 0 y 1, perfecto para calcular probabilidades.

4.4.1 Sigmoide

Muchos procesos naturales y curvas de aprendizaje de sistemas complejos muestran una progresión temporal desde unos niveles bajos al inicio, hasta acercarse a un clímax transcurrido un cierto tiempo; la transición se produce en una región caracterizada por una fuerte aceleración intermedia. La función sigmoide permite describir esta evolución. Su gráfica tiene una típica forma de "S", como se muestra en la *figura 4-6*. A menudo la función sigmoide se refiere al caso particular de la función logística, y que viene definida por Ecuación 4-2 [16] .

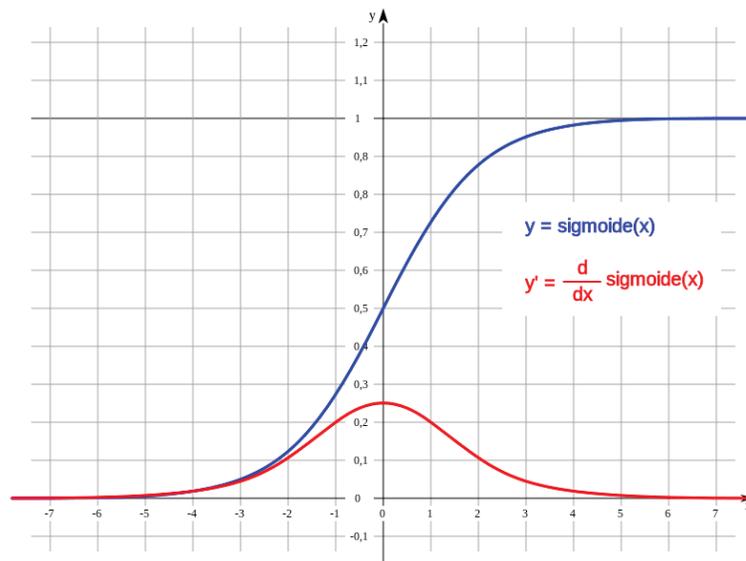


Figura 4-6 Función Sigmoide y su Derivada [16]

$$y(t) = \frac{1}{1 + e^{-t}} \quad (4-2)$$

Una particularidad y razón por la que es común utilizar esta función en este tipo de procesos, es debido a que su derivada tiene la siguiente forma descrita por la Ecuación 4-3 lo que simplifica los cálculos y el código de programación para el entrenamiento de la red neuronal.

$$y' = y(1 - y) \quad (4-3)$$

4.4.2 Desarrollo del Código de Entrenamiento

El entrenamiento de red neuronal, aplicado con este software requiere el desarrollo del código de programación en lenguaje Python que permita este trabajo. Por lo que a continuación se describirán las librerías utilizadas y la lógica aplicada en su funcionamiento.

Librerías Python utilizadas

- numpy: la librería numpy permite realizar todo tipo de operatoria matricial, necesaria para la ponderación, activación, corrección y acumulación de pesos matriciales en la Red Neuronal
- xlrd: esta librería permite abrir y leer tablas de trabajo, todo tipo de caracteres, en este caso se utilizó para abrir formatos .xlsx.
- xlwt: esta librería permite crear y guardar tablas de trabajo, en este caso se utilizó para guardar formatos .xlsx.

Logica y Código

Para facilitar la comprensión se presenta la Figura 4-7 en donde se visualizan los pesos y las salidas matriciales de cada capa, con las variables asignadas en el código de programación.

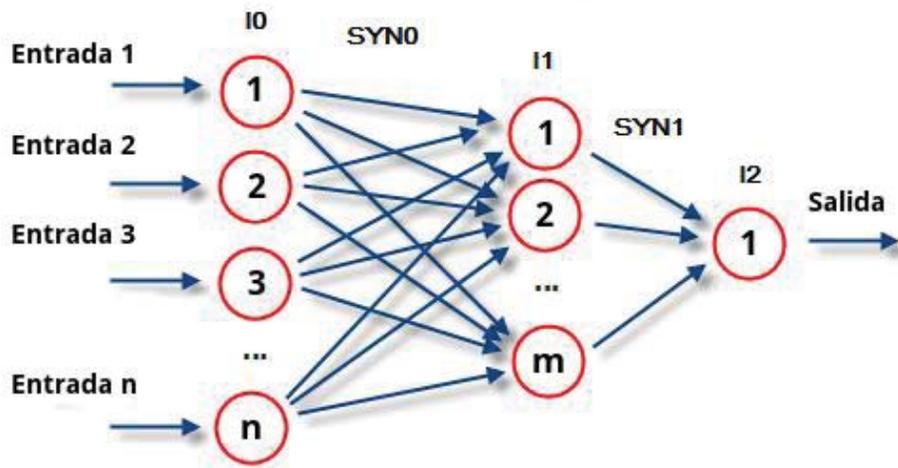


Figura 4-7 Diagrama visual de red neuronal con variables utilizadas en Código Python

Una red neuronal, es representada principalmente por el conjunto aleatorio de pesos matriciales, estos conjuntos pueden ser alterados, para obtener una respuesta deseada. La cantidad y dimensiones de pesos matriciales dependerán de la cantidad de capas y neuronas por capa de la red. En la Figura 4-8 se puede observar la sección principal del código empleado, en donde se puede hacer énfasis en:

- Creación de la función Sigmoide y su derivada inversa (8).
- Creación de pesos matriciales aleatorios (17-18).
- Bucle de iteraciones: este finalizara en dos condiciones; cuando el número de iteraciones termine y cuando alcance un mínimo error promedio, con respecto a la salida deseada (22-40).
- Evaluaciones de entradas por iteraciones (25-27).
- Cálculo de porción de error que se retro propaga y acumular en pesos matriciales, para la obtención de la salida deseada. (29-39)

```

7 #define funcion sigmoide
8 def sigmoid(x, deriv=False):
9     if deriv:
10         return x*(1-x)
11         return 1/(1+np.exp(-x))
12 #Matriz aleatoria
13 np.random.seed(0)
14 #numero de neuronas en capa oculta
15 N_DIM=20
16 #creacion de Matrices de peso
17 SYN0=2*np.random.random((7,N_DIM))-1
18 SYN1=2*np.random.random((N_DIM,1))-1
19 #numero de Iteraciones
20 N_ITER=1000000
21 #constante de error
22 alpha=0.5
23 while not done and count<N_ITER:
24     #definimos matrices de salidas de todas las capas
25     l0=INPUT_X
26     l1=sigmoid(np.dot(l0,SYN0))
27     l2=sigmoid(np.dot(l1,SYN1))
28     #calculo del error de la capa final
29     l2_error=EXPECTED_RESULT-l2
30     #aplicacion de la derivada multiplicada por el error para obtener el cambio
31     #necesario para minimizar el error
32     l2_delta=l2_error*alpha*sigmoid(l2,True)
33     l1_error=np.dot(l2_delta,SYN1.T)
34     l1_delta=l1_error*alpha*sigmoid(l1,True)
35     #las primeras conexiones las corregimos con aun contador de pesos
36     SYN0+=np.dot(l0.T,l1_delta)
37     SYN1+=np.dot(l1.T,l2_delta)
38     #se define el error
39     c_error=np.mean(np.abs(l2_error))

```

Figura 4-8 Sección principal del código de entrenamiento de la red neuronal

Si se desea agregar N capas más, solo se es necesario declara pesos matriciales “SYNn” y especificar las variables de salida “ln”. Cabe mencionar que alpha corresponde a una constante de error, esta permite que el error disminuya a mayor velocidad por iteración.

El total de funciones que cumple el código son:

- Extraer matrices de entradas y salidas deseadas de un archivo Excel.
- Entrenar una Red Neuronal, con un número fijo de iteraciones o mínimo Error Promedio.
- Imprime en pantalla cada 10000 iteraciones el error promedio en ese instante
- Imprimir en pantalla y exportar a una tabla de trabajo, la predicción por la que fue entrenada, y el número de iteraciones que recorrió en su entrenamiento.
- Imprimir en pantalla y exportar a una tabla de trabajo, la predicción con datos de entrada con la que no fue entrenada.
- El código puede ser modificado fácilmente para agregar capas internas y número de neuronas en capas internas.

5 Simulación y Análisis

Las simulaciones realizadas en este capítulo tuvieron de parámetros; la Retro-propagación, como tipo de red; la función sigmoide, como función de activación; y para distintos números de capas ocultas y neuronas en las capas ocultas. Debido a que Matlab no permite otra opción, el número de neuronas entre capas ocultas siempre será el mismo.

5.1 Imprevisto

Durante la primera y segunda simulación (Matlab) se utilizaron modelos de redes neuronales de 10 neuronas por capas ocultas, con una capa oculta y 2 capas ocultas. Estos resultados no fueron certeros, demostrado por los bajos coeficientes de Pearson, como se visualiza en la Figura 5-1 y 5.2 por lo que se propuso la incorporación de nuevas variables, estas fueron; El número de curvas y cruces que posee la calle. Cabe mencionar que el bajo índice de Pearson demostró que las variables obtenidas hasta el momento no describían en un buen porcentaje las condiciones que proceden a choques de postes por calle.

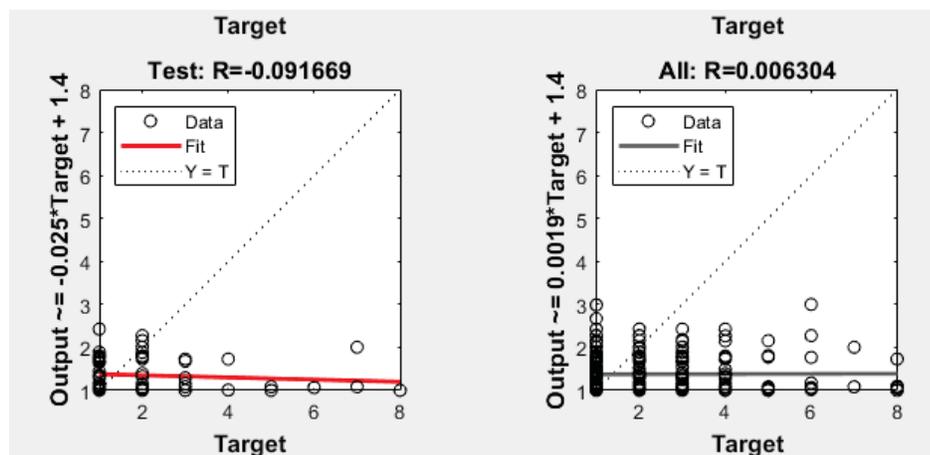


Figura 5-1 Coeficiente de Pearson en predicción de red neuronal compuesta de 10 neuronas y una capa oculta.

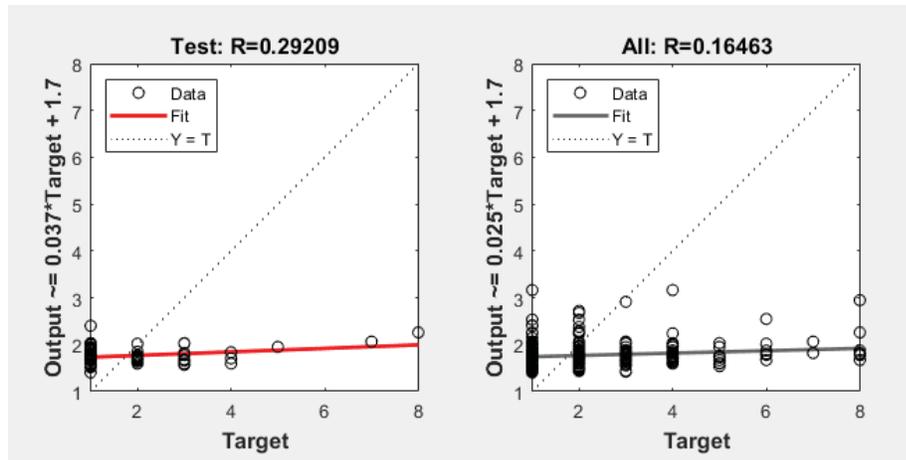


Figura 5-2 Coeficiente de Pearson en predicción de red neuronal compuesta de 10 neuronas y 2 capas ocultas.

Nuevas variables

Debido a la basta cantidad de datos a obtener estas variables, las 1186 calles fueron filtradas por comuna y se hizo el conteo de curvas y cruces por calle de la Comuna de Valparaíso. Este conteo se realizó visualmente con la herramienta virtual GoogleMaps.

Finalmente, se cuenta con 7 variables que describen las calles de la comuna de Valparaíso y que sufrieron choques de postes en el periodo del 2014 al 2016, en donde se descontaron las calles sin nombre, y las calles que poseen redes subterráneas. Esto tomo el recuento de 200 calles en la comuna, posteriormente se dividió en dos porciones de 100 calles, un Grupo A y Grupo B, para utilizar un grupo de entrenamiento y el otro de simulación con calles nuevas para la red neuronal.

Se puede verificar con la Figura 5-3 que los índices de Pearson mejoraron considerablemente en relación las primeras simulaciones, lo que confirma una mejora en la predicción con la adición de estas dos nuevas variables.

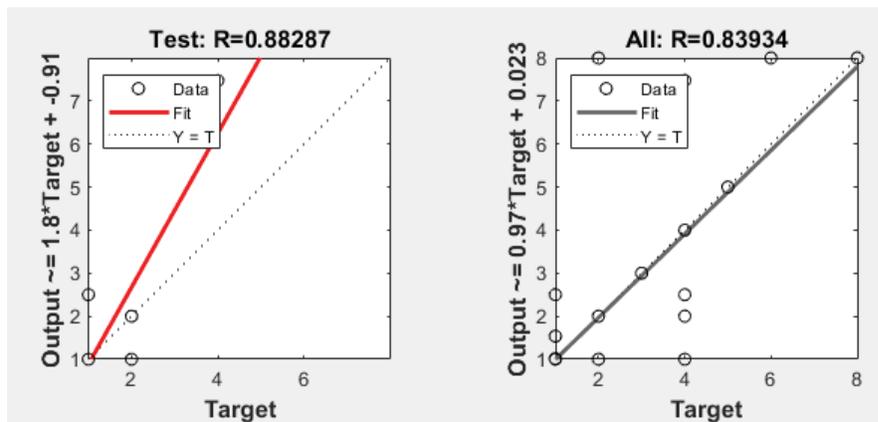


Figura 5-3 Coeficiente de Pearson en entrenamiento de R. N. de 40 neuronas en una capa oculta

5.2 Simulación Matlab

A continuación, se describirán los parámetros de las redes entrenadas y sus errores promedios de predicción. Estos serán los obtenidos con la evaluación del grupo A; conjunto de datos utilizados en el entrenamiento, y grupo B; conjunto de datos desconocidos para la red neuronal.

Una Capa Oculta

Tabla 5-1 Resumen de errores promedio obtenidos de redes neuronales con una capa oculta

Nº de neuronas	Nº de iteraciones	Error Datos Entrenados	Datos No Entrenados
7	2537	33.9%	60.5%
10	6771	37.2%	135.6%
40	4000	13.8%	164.8%

Se puede apreciar en la tabla que la mejor predicción se obtendrá con una Red Neuronal de 40 neuronas en la capa oculta, con un error de 13.8%, sin embargo, la Red al enfrentarse a datos desconocidos, el error aumenta más de 10 veces por lo que no es una buena opción. Sí lo es una Red de 7 neuronas y una capa oculta, pero podría mejorar.

Dos Capas Ocultas

Tabla 5-2 Resumen de errores promedio obtenidos de redes neuronales con dos capas ocultas

Nº de neuronas	Nº de iteraciones	Error Datos Entrenados	Datos No Entrenados
5	1321	36%	48.5%
10	2750	58.3%	62%
40	2121	32.1%	64.3%

En el caso de desarrollar una red neuronal con dos capas ocultas a menor número neuronas en las capas ocultas, mejor será su desempeño en una predicción de datos no entrenados, y si el número de neuronas aumenta la predicción de los datos entrenados será más certera.

Debido a que la complicación de predicción que tiene el modelo es correspondiente al grupo de datos no entrenados, el menor error de predicción la obtuvo la red neuronal de dos capas con 5 neuronas en capas ocultas. En la Tabla 5-3 se presentan las primeras 20 predicciones realizadas con el grupo A de esta red neuronal y en la Tabla 5-4

Tabla 5-3 Predicción realizada a primeras 20 calles, y grupo A

calle	N° Curvas	Nivel de tensión	Zona	Calzada	Tipo calzada	Estado calzada	N° cruces	N° Choques	Choques pronosticados
ELOY ALFARO	1	1	1	2	2	1	3	2	1.681
AVENIDA JOSE TOMAS RAMOS	4	1	1	2	1	1	3	2	1.000
AVENIDA SANTA ELENA	4	2	1	1	2	1	6	4	2.189
CHACABUCO	0	1	1	1	2	1	13	2	2.344
JOSE MORA	0	1	1	2	1	1	3	2	1.000
UNION AMERICANA	4	1	1	2	2	1	0	1	1.148
BADEN POWELL	3	1	1	2	2	1	13	4	2.561
MARTINEZ CRUZ	1	1	1	2	2	1	5	5	1.996
AVENIDA SUAREZ	1	2	1	2	1	1	2	1	1.000
AVENIDA NORUEGA	2	1	1	2	1	1	5	1	1.000
INGLATERRA	1	1	1	2	2	1	0	1	1.218
IRENE FREI	2	2	1	1	1	1	5	1	1.000
TERCERA DEL SUR	0	1	1	2	2	1	5	2	2.034
AVENIDA BAQUEDANO	5	1	2	1	1	1	7	3	4.422
RAFAEL BUSTOS	0	1	1	3	1	1	1	1	1.000
PASAJE RUDOLPH	3	1	2	2	2	1	1	1	1.244
AGUA POTABLE	1	1	1	2	1	1	4	2	1.000
AVENIDA GRAN BRETANA	5	1	1	2	2	1	7	1	2.811
AVENIDA TAQUEADERO	4	1	1	2	2	1	2	1	1.380

Tabla 5-4 Predicción realizada a primeras 20 calles, y grupo B

Calle	N° Curvas	Nivel de tensión	Zona	Calzada	Tipo calzada	Estado calzada	N° cruces	N° Choques	Choques pronosticados
BARROS ARANA	5	1	2	2	1	1	9	3	4.171
PASAJE F	0	1	1	2	2	1	0	1	1.260
POCURO	1	1	2	1	1	1	6	1	5.392
CORONEL ROBERTO SOUPER	0	1	1	2	2	1	4	1	1.905
AVENIDA BERNARDO O'HIGGINS	3	1	2	1	2	1	22	8	2.770
MARINA	0	1	1	2	2	1	1	2	1.398
CARMELA CARVAJAL	0	1	1	1	1	1	3	1	1.000
GUILLERMO RIVERA	1	1	2	2	1	2	2	2	1.338
JUAN FARIAS	2	1	1	2	2	1	1	1	1.293
EL MELON	2	2	1	2	2	1	2	2	1.294
LOS OLIVOS	2	1	1	2	2	1	0	1	1.184
ALMIRANTE BARROSO	0	1	1	2	2	1	3	1	1.745
EL BOSQUE	4	1	1	3	2	1	1	1	1.093
RIO ITATA	0	1	1	2	2	1	0	1	1.260
ARTURO PRAT	2	1	1	1	2	1	2	3	1.990
DUODECIMA	1	1	1	1	1	1	8	1	1.001
VALLE PRIMAVERA	4	1	1	2	1	1	2	1	1.000
TUCAPEL	2	1	1	1	2	1	2	1	1.990
LUIS BAHAMONDES ALVEAR	3	1	1	1	1	1	7	1	1.000

5.3 Simulación Spyder (Python)

A continuación, se describen un total de 9 entrenamientos y simulaciones. Estas se realizaron con el programa Spyder en lenguaje Python, con el fin de obtener la mejor predicción, y finalmente contrastar con el trabajo realizado en el software MatLab.

La Tabla 5-5 muestra los errores promedio obtenidos de las predicciones con respecto a los choques registrados de todas las calles del Grupo A, grupo correspondiente al cual se vio enfrentada la Red Neuronal para el entrenamiento y aprendizaje. En cuanto a la Tabla 5-6 refleja los errores promedio obtenidos de las predicciones con respecto a los choques registrados de todas las calles del grupo B, grupo correspondiente a datos nuevos a los que se enfrentó la red neuronal

Grupo A

Al visualizar la Tabla 5-5 se puede concluir, que a medida aumenta el número de capas ocultas, la predicción es más exacta, por lo que en futuras simulaciones se recomienda buscar el óptimo número de capas.

La red neuronal que mejores predicciones obtuvo en este grupo fue la red neuronal de tres capas ocultas y 20 neuronas, realizando predicciones con un 10.8% de error promedio. Aunque esta tendrá que evaluar su desempeño con un conjunto de datos desconocidos para la red,

Tabla 5-5 Resumen de errores obtenidos de simulaciones con grupo A

Capas Ocultas\Número de Neuronas	5	10	20
1	32.4%	20.7%	16.8%
2	22.1%	14.9%	11.5%
3	21.2%	14.9%	10.8%

Grupo B

Al igual que en el grupo A, a mayor cantidad de capas ocultas, la red neuronal es capaz de perfeccionar su aprendizaje, disminuyendo el error promedio.

La red neuronal mejor calificada en evaluación con los datos desconocidos (grupo B) es la de 3 capas ocultas y 10 neuronas. Lo que confirma, llegar al óptimo aprendizaje para la red neuronal significa un aprendizaje “de memoria” lo que lleva a una predicción con datos nuevos deficiente, como ocurre en el caso de la red neuronal de tres capas y 20 neuronas; esta al obtener un 10.8% de error en su predicción (la mejor en grupo A), aprendió el comportamiento de una muestra de datos fijo y al enfrentarse al grupo B, este aumento su error promedio a un 52.5%.

Tabla 5-6 Resumen de errores obtenidos de simulaciones con grupo B

Capas Ocultas\Número de Neuronas	5	10	20
1	66.7%	73.2%	64.4%
2	56.6%	53.6%	54.4%
3	56%	49.1%	52.5%

Las predicciones realizadas con la red neuronal que mejor desempeño tubo al grupo A esta en la Tabla 5-7 y la de mejor desempeño en simulación con el grupo B en la Tabla 5-8.

Tabla 5-7 Predicción realizada a primeras 20 calles, y grupo A

Calle	N° curvas	Tensión	Zona	Calzada	Calzada	Estado calzada	N° cruces	N° Choques	Choques pronosticados
ELOY ALFARO	1	1	1	2	2	1	3	2	2.992
AVENIDA JOSE TOMAS RAMOS	4	1	1	2	1	1	3	2	2.044
AVENIDA SANTA ELENA	4	2	1	1	2	1	6	4	3.000
CHACABUCO	0	1	1	1	2	1	13	2	2.078
JOSE MORA	0	1	1	2	1	1	3	2	2.025
UNION AMERICANA	4	1	1	2	2	1	0	1	1.004
BADEN POWELL	3	1	1	2	2	1	13	4	3.000
MARTINEZ CRUZ	1	1	1	2	2	1	5	5	3.000
AVENIDA SUAREZ	1	2	1	2	1	1	2	1	1.008
AVENIDA NORUEGA	2	1	1	2	1	1	5	1	1.058
INGLATERRA	1	1	1	2	2	1	0	1	1.020
IRENE FREI	2	2	1	1	1	1	5	1	0.986
TERCERA DEL SUR	0	1	1	2	2	1	5	2	2.044
AVENIDA BAQUEDANO	5	1	2	1	1	1	7	3	2.994
RAFAEL BUSTOS	0	1	1	3	1	1	1	1	1.035
PASAJE RUDOLPH	3	1	2	2	2	1	1	1	1.017
AGUA POTABLE	1	1	1	2	1	1	4	2	2.018
AVENIDA GRAN BRETANA	5	1	1	2	2	1	7	1	3.000
AVENIDA TAQUEADERO	4	1	1	2	2	1	2	1	1.019

Tabla 5-8 Predicción realizada a primeras 20 calles, y Grupo B

Calle	N° curvas	Tensión	Zona	Calzada	Calzada	Estado calzada	N° cruces	N° Choques	Choques pronosticados
BARROS ARANA	5	1	2	2	1	1	9	3	2.878
PASAJE F	0	1	1	2	2	1	0	1	1.474
POCURO	1	1	2	1	1	1	6	1	2.077
CORONEL ROBERTO SOUPER	0	1	1	2	2	1	4	1	1.011
AVENIDA BERNARDO O'HIGGINS	3	1	2	1	2	1	22	8	1.986
MARINA	0	1	1	2	2	1	1	2	1,011
CARMELA CARVAJAL	0	1	1	1	1	1	3	1	1.326
GUILLERMO RIVERA	1	1	2	2	1	2	2	2	0.983
JUAN FARIAS	2	1	1	2	2	1	1	1	0.979
EL MELON	2	2	1	2	2	1	2	2	0.986
LOS OLIVOS	2	1	1	2	2	1	0	1	0.980
ALMIRANTE BARROSO	0	1	1	2	2	1	3	1	0.974
EL BOSQUE	4	1	1	3	2	1	1	1	0.988
RIO ITATA	0	1	1	2	2	1	0	1	1.474
ARTURO PRAT	2	1	1	1	2	1	2	3	1.132
DUODECIMA	1	1	1	1	1	1	8	1	1.930
VALLE PRIMAVERA	4	1	1	2	1	1	2	1	1.441
TUCAPEL	2	1	1	1	2	1	2	1	1.132
LUIS BAHAMONDES ALVEAR	3	1	1	1	1	1	7	1	3.000

5.4 Resumen

Finalmente se presenta una tabla resumen con las mejores predicciones obtenidas, según tipo de software utilizado al momento de aprendizaje de la Red Neuronal y según el grupo de entrada, al momento de simular una predicción (grupo A y grupo B).

Tabla 5-9 Resumen de mejores predicciones según grupo de simulación y Software.

Software	Error Promedio	
	Grupo A	Grupo B
MatLab	36%	48.5%
Spyder	14.9%	49.1%

6 Propuestas de Optimización de Resultados

En el presente capítulo se desarrollaron propuestas de optimización de procesos y factores que influyen en el rendimiento del modelo de predicción.

6.1 Adición de calles sin registro de choques

Este factor proporcionará al modelo la capacidad de destacar calles con un riesgo nulo a las que califiquen como tal, y a su vez el proyectista podrá estimar la mejor vía de instalación y distribución de la energía eléctrica. Tras la suma de estas muestras se obtuvo un registro de 225 calles, descritas por las variables correspondiente. En la Figura 6-1 se puede visualizar la comuna de Valparaíso y las calles registradas con y sin choques a postes, de color rojo y verde respectivamente, durante los 3 años del muestreo.

La participación de este nuevo registro también permitirá visualizar si las variables ya obtenidas describen realmente la ausencia, presencia o nivel de riesgo de choques en las calles de Valparaíso.

6.2 Adición de nuevas variables

Se adicionaron 4 nuevas variables a los registros obtenidos. Estas se rescataron individualmente en todas las calles ya registradas de la Comuna de Valparaíso, gracias al software Google Earth y la aplicación web ITO Map [17].

Estas Variables corresponden a:

- Longitud de la calle
- Inclinação máxima de la calle
- Inclinação promedio de la calle
- Numero de colegios en la calle

La adicción de nuevas variables al modelo de redes neuronales nunca tendrá un aporte negativo para esta, ya que tiene la capacidad de definir la ponderación en cada neurona (umbral), involucrando cada variable de entrada, por lo que la inclusión de nuevas variables permite una

mejor participación entre ellas, por si solas, en conjunto con otras o excluyéndolas totalmente. El “¿por qué la elección de estas variables?”, es simplemente la asequibilidad que se tiene de estas y la hipótesis de que estén directamente relacionadas con la problemática.

6.2.1 Google Earth

Dentro del software Google Earth la herramienta de interés para la obtención de longitud de calles, las inclinaciones máximas e inclinaciones promedio, es el Perfil de Elevación. En primera instancia se recorrieron tanto las calles que registran choques a postes (color rojo) como las sin registro de choques a postes (color verde) reflejado en la Figura 6-1

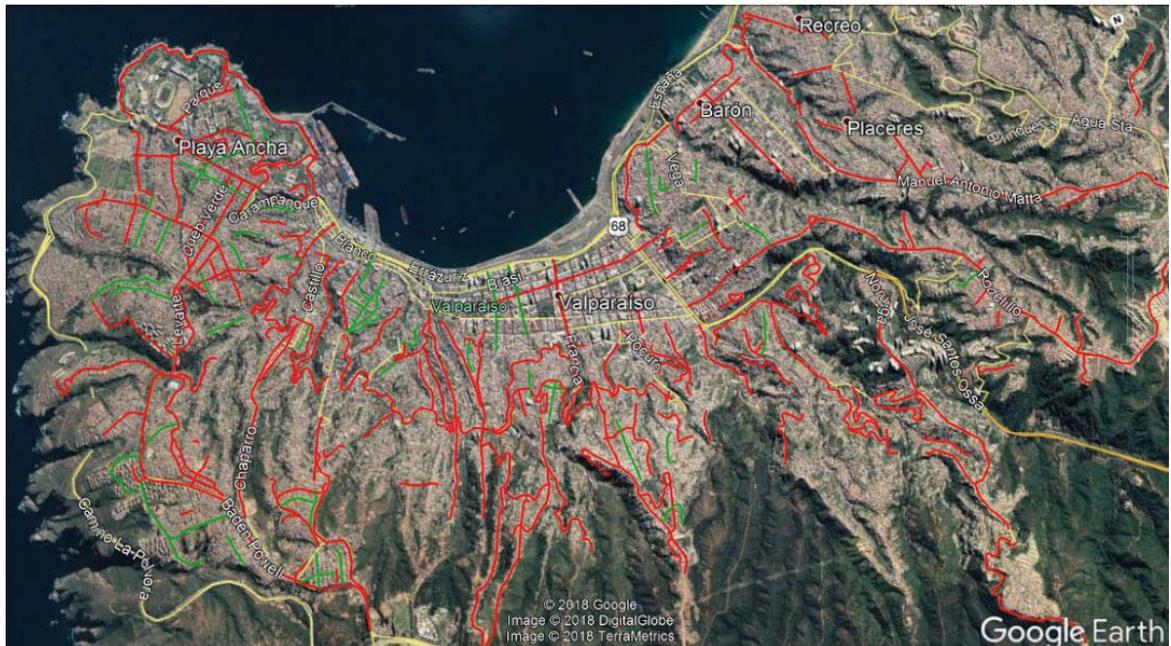


Figura 6-1 Calles con y sin registro de choques a postes, Google Earth.

Posteriormente, esta herramienta permite visualizar y medir rutas dibujadas sobre el mapa, en este caso la comuna de Valparaíso. Así se rescataron tanto la longitud de las calles como la inclinación máxima y promedio. Como como muestra la Figura 6-2, en donde se refleja que la Calle Av. Playa ancha posee una elevación máxima de 16,9 °, una elevación promedio de 7,2 ° y una longitud de 1,07 [Km].



Figura 6-2 Perfil de elevación de la calle Av. Playa Ancha, Valparaíso, Google Earth

6.2.2 ITO Map

Ito Map es un servicio global de mapas de superposición deslizante de Ito World que ofrece una variedad de vistas de mapas para resaltar muchas capas de datos 'ocultas' dentro de OpenStreetMap.

Ito Map se lanzó para el Reino Unido y partes del norte de Europa el 18 de marzo de 2011 y se extendió para cubrir los EE. UU., Canadá y el Caribe el 23 de marzo de 2011. Se globalizó el 31 de marzo de 2011 y se agregaron cuatro capas adicionales relacionadas con el ferrocarril. 7 de abril de 2011. El 12 de abril de 2011 se lanzó una capa de "altura de edificio". Desde entonces, se han agregado nuevas capas. En agosto de 2012 se agregaron nodos de las Islas Británicas con algunas capas nuevas con soporte para ellas. En septiembre de 2012 se agregó la capacidad de hacer clic en los mapas y obtener información adicional. Ito Map fue desarrollado por Ito World con el apoyo de Ideas in Transit, un proyecto de investigación financiado por cinco gobiernos del Reino Unido [18].

Ito Map es el proveedor de datos en aplicaciones Maps como Google Map, por lo que en su diversidad de capas podemos encontrar del tipo:

- Edificios y Direcciones
- Aparcamientos
- Límites de velocidad
- Agricultura
- Alumbrado y Carreteras
- Vías Férreas
- Deporte
- Escuelas
- Entre otros.

6.2.3 Número de escuelas por calle

Aprovechando que Ito Map posee una capa del mapa de la posición de escuelas de la Comuna de Valparaíso, se realizó el conteo de número de escuelas por calles, en donde se obtuvo una cantidad de 54 escuelas, dentro del registro de calles registradas. Esta variable fue incorporada ya que este factor involucra directamente a la normativa relacionada con la velocidad en las calles, estableciendo que, tanto en caso urbano como rural, los vehículos no deben circular a más de 30[km/h] en zonas de escuela en los horarios de entrada de salida de los alumnos [19]. Hipotéticamente se puede afirmar que una mayor cantidad de escuelas en una calle, menor cantidad de choques de postes anuales en la calle, ya que además de un límite de velocidad más severo, esta refleja una mayor exigencia del cumplimiento con implementos de seguridad como pasos de cebra, semáforos, lomos de toro, carteles luminosos, etc. En la Figura 6-3 se observa la capa de escuelas georreferenciadas en la comuna de Valparaíso.

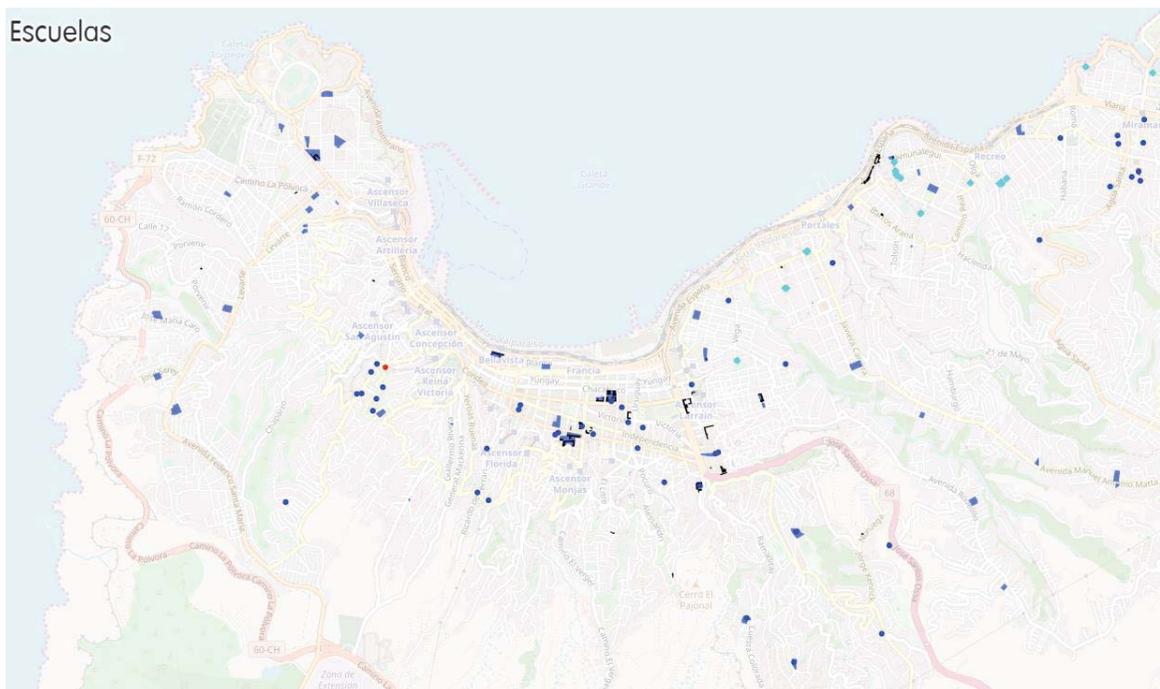


Figura 6-3 Escuelas de la Comuna de Valparaíso

6.2.4 Límites de velocidad

Gracias a que la herramienta Ito Map proporciona una capa con los límites de velocidad, se propuso hacer lectura de las calles registradas en la comuna de Valparaíso y agregar esta variable, pero al momento de lectura, se detectó que todos los límites de velocidad estaban estandarizados a zona urbana, por lo que proporciono un registro de 50 Km/h en todas las calles de la comuna, por lo que se optó por no incluir esta variable que no aportaría ninguna influencia en la predicción.

También se intentó obtener las velocidades de las calles con el editor de mapas que posee la aplicación Waze, ya que esta es modificada por lo mismo usuarios de esta aplicación, no obstante, las calles siguen estandarizadas en su totalidad a 50 Km/h, por el poco uso que le dan los usuarios a este editor en esta zona. En la Figura 6-4 se puede observar el editor de mapas Waze en los tramos de calle son seleccionados y el indicador de velocidades establecida para la calle Sierra, Playa Ancha, Valparaíso.

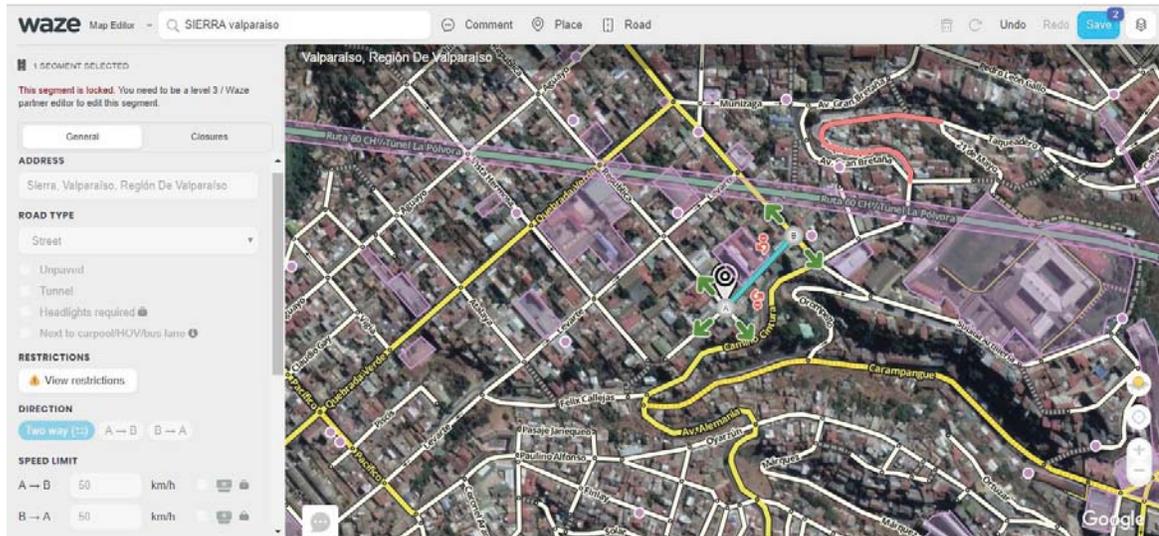


Figura 6-4 Editor de Mapas Waze, Calle Sierra, Playa Ancha

6.3 Variables discretas y continuas

Las participaciones de variables utilizadas en la etapa de aprendizaje se pueden clasificar en dos grupos, variables discretas y continuas, estas definidas como las variables que pueden tomar un solo valor finito y entero, y las que pueden tomar valores infinitos y reales.

Para mejorar el rendimiento del aprendizaje se propone en lo posible transformar las variables discretas a continuas, o en el peor de los casos eliminarlas, para así eliminar la sobreestimación de un parámetro de una variable.

6.3.1 Material calzada

Esta Variable se clasifica como una variable descriptiva y discreta por lo que trae consigo el problema de una asignación al azar del valor a tomar, esto proporciona un valor erróneo al momento de ser ponderado por los pesos de la red neuronal, generando conflictos en la real influencia de predicción. Como solución se propone cuantificar los parámetros del material calzada con el coeficiente de roce para cada uno de estas superficies, lo que permitiría un exitoso cambio de variable descriptiva a continua.

Anteriormente los valores asignados para los parámetros de estas variables fueron:

- Concreto (1)
- Asfalto (2)
- Adoquín (3)
- Mixto (4)
- Ripio (5)
- Tierra (6)

Por lo que el siguiente paso será asignar los valores correspondientes a los coeficientes de roce promedio de cada uno de los parámetros [20]:

- Concreto (0,775)
- Asfalto (0,750)
- Adoquín (0,775)
- Mixto (0,766)
- Ripio (0,650)
- Tierra (0,600)

6.3.2 Tipo del poste y estado de la Calzada

Esta variable opto por eliminarse debido a que, además de ser una variable descriptiva, no describe parámetros de la calle en si, por lo que no involucra la ocurrencia del choque a postes en las calles. En otras palabras, que el poste sea de media o baja tensión no involucra que este poste sea chocado o no, lo que sí podría involucrar es la existencia de postes y la cantidad de estos por calle.

El estado de la calzada también se eliminó debido a que corresponde a una variable descriptiva, discreta y además ésta varía en el tiempo, por lo que la predicción anual se vería afectada según el cambio temporal que presente la calzada.

6.4 Proporción de datos a entrenar

Anteriormente en el capítulo 5, como primeras simulaciones, se realizaron entrenamientos a distintas configuraciones de redes neuronales multi perceptrón, en donde se evaluó el rendimiento del entrenamiento, con la predicción, tanto en calles de entrada conocidas para la red (calles utilizadas en el proceso de entrenamiento “grupo A”) como en calles desconocidas

para la Red Neuronal (calles no utilizadas en el proceso de entrenamiento “grupo B”). Las porciones tanto del grupo A como grupo B fueron a la razón de 1:1.

Por lo que en este capítulo se reorganizaron las porciones del grupo de entrenamiento en donde se utilizó un 90% de la totalidad datos registrados destinados al grupo A y un 10 % al grupo B. Esto se planteó y desarrollo con la intención de que la red neuronal abarque el mayor número eventualidades causales de choques a postes.

7 Segunda Vista a MATLAB

Debido a que se modificaron las variables de entradas, será necesario repetir y perfeccionar algunos puntos en el entrenamiento de la red neuronal en MATLAB. Además, implementar nuevos procesos de aprendizaje para encontrar el mejor entrenador del modelo de predicción de choques a postes por calle en la Comuna de Valparaíso.

7.1 Flujo de trabajo por MATLAB

El flujo de trabajo para el proceso de diseño de la red neuronal general tiene siete pasos principales:

1. Recolectar datos
2. Crear la red
3. Configurar la red
4. Inicializar los pesos y sesgos
5. Entrenar la red
6. Validar la red (análisis post-entrenamiento)
7. Usar la red

Los detalles de este flujo de trabajo se discuten en los siguientes puntos [21].

7.1.1 Arquitectura de red neuronal superficial de múltiples capas

Retomando lo ya aprendido una neurona elemental con un número natural de entradas se muestra a en la Figura 7-1. Cada entrada está ponderada con una w apropiada. La suma de las entradas ponderadas y el sesgo o umbral forman la entrada a la función de Activación f . Las neuronas pueden usar cualquier función de Activación diferenciable f para generar su salida. Generalmente las más usadas son las logística Sigmoide, tangente hiperbólica y la lineal de pendiente 1.

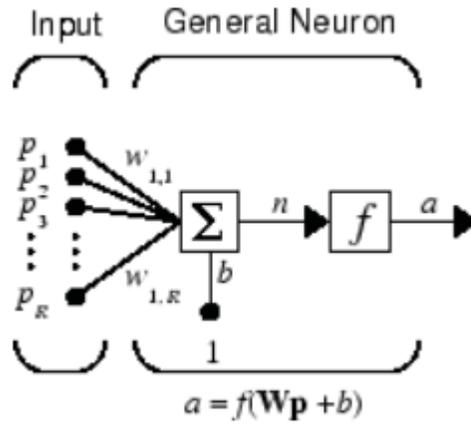


Figura 7-1 Neurona Artificial

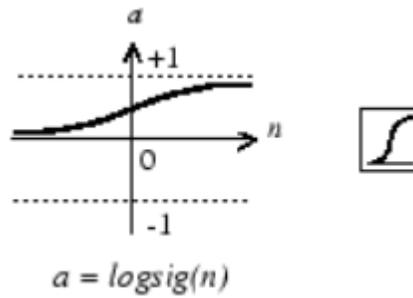


Figura 7-2 Función Logística Sigmoide

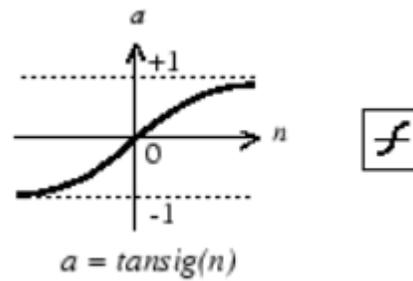


Figura 7-3 Función Tangente Hiperbólica

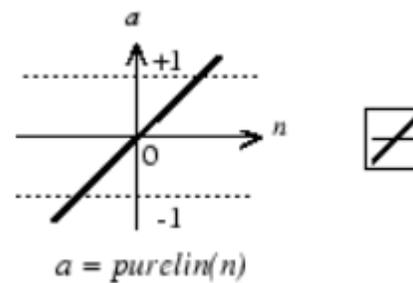


Figura 7-4 Función Lineal m=1

Las redes neuronales a menudo tienen una o más capas ocultas de neuronas sigmoides seguidas de una capa de salida de neuronas lineales. Las múltiples capas de neuronas con funciones de transferencia no lineal permiten a la red aprender relaciones no lineales entre los vectores de entrada y salida. La capa de salida lineal se usa con más frecuencia para problemas de ajuste de función (o regresión no lineal).

Por otro lado, si desea restringir las salidas de una red (como entre 0 y 1), la capa de salida debería usar una función de activación Sigmoide. Este es el caso cuando la red se usa para problemas de reconocimiento de patrones (en los que la red está tomando una decisión).

En el modelo de predicción de choques a postes a causa de los rangos en sus parámetros de cada variable, las capas ocultas utilizarán funciones de activación logística Sigmoide (previamente normalizadas) y en la capa de salida se usará una activación lineal.

7.1.2 Preparar datos para redes neuronales de múltiples capas

Antes de comenzar el proceso de diseño de la red, primero se deben recopilar y preparar los datos de muestra. Por lo general, es difícil incorporar el conocimiento previo en una red neuronal, por lo tanto, la red sólo puede ser tan precisa como los datos que se usan para entrenar la red.

Es importante que los datos cubran el rango de entradas para las cuales se utilizará la red. Las redes multicapa pueden capacitarse para generalizar bien dentro del rango de entradas para las cuales han sido entrenadas. Sin embargo, no tienen la capacidad de extrapolar con precisión más allá de este rango, por lo que es importante que los datos de entrenamiento abarquen todo el rango del espacio de entrada. Para el modelo actual se utilizarán 9 entradas correspondientes a las 9 variables que describen las calles

Una vez que se han recopilado los datos, hay dos pasos que deben realizarse antes de que se utilicen los datos para capacitar a la red: los datos deben procesarse previamente y deben dividirse en subconjuntos, uno para entrenar la red y otro para simular el comportamiento de la red con datos desconocidos.

7.1.3 Creación, Configuración e Inicialización de la Red Neuronal

Una vez que se han recopilado los datos, la creación de esta es lo próximo a realizar, donde su configuración trae los siguientes parámetros, Figura 4-2:

- Tipo de Red Neuronal: Multiperceptron
- Tipo de Aprendizaje: Levenberg-Marquardt, Gradiente Conjugado Resistente y Backproagation Resistente
- Error utilizado en el aprendizaje: Error cuadrático medio
- Número de Capas Ocultas: 1, 2 y 4 Numero de capas
- Número de Neuronas por Capas Ocultas: 5, 10, 30 y 50 número de neuronas en capas ocultas.
- Tipo de Función de Activación: la función de activación en las capas ocultas serán la Sigmoidea y en la capa de salida se utilizará la función de activación lineal.

Todos estos parámetros fueron combinados logrando así el entrenamiento y simulación de 36 distintas redes neuronales, todo esto con el objetivo de encontrar la mejor red de predicción de choques a postes en la Comuna de Valparaíso (Ver capítulo 8).

Antes de entrenar una red, se debe inicializar o reinicializar los pesos y umbrales, para evitar utilizar pesos de las redes creadas anteriormente. Ya configurada la red neuronal esta lista para ser entrenada.

7.1.4 Entrenar y Aplicar Redes Neuronales de Múltiples Capas

El proceso de entrenamiento implica ajustar los valores de los pesos y sesgos de la red para optimizar el rendimiento.

Desde la ventana de entrenamiento (Figura 4-5), es posible acceder a cuatro gráficos: rendimiento, estado de entrenamiento, histograma de errores y regresión. La gráfica de rendimiento muestra el valor de la función de rendimiento frente al número de iteración. Traza entrenamientos, validaciones y pruebas de rendimiento. La gráfica de estado de entrenamiento muestra el progreso de otras variables de capacitación, como la magnitud del gradiente, el número de verificaciones de validación, etc. La gráfica de histograma de errores muestra la distribución de los errores de red, esto permitirá encontrar la iteración y donde se alcanzó el error mínimo en casos oscilatorios (Figura 7-5) o en situaciones en donde el error converja (Figura 7-6). El gráfico de regresión muestra una regresión entre las salidas de red y los objetivos de red (Figura 5-3). Puede usar el histograma y los gráficos de regresión para validar el rendimiento de la red.

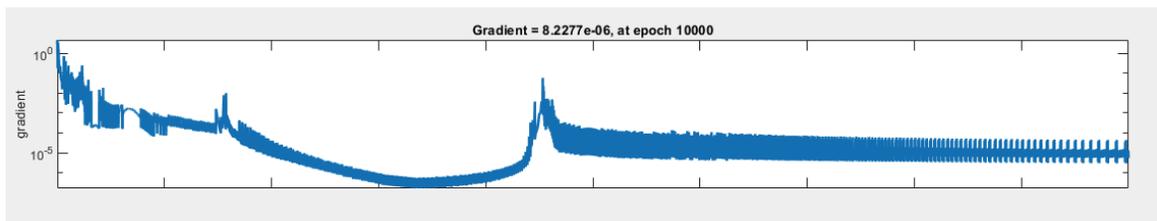


Figura 7-5 Gradiente durante el aprendizaje

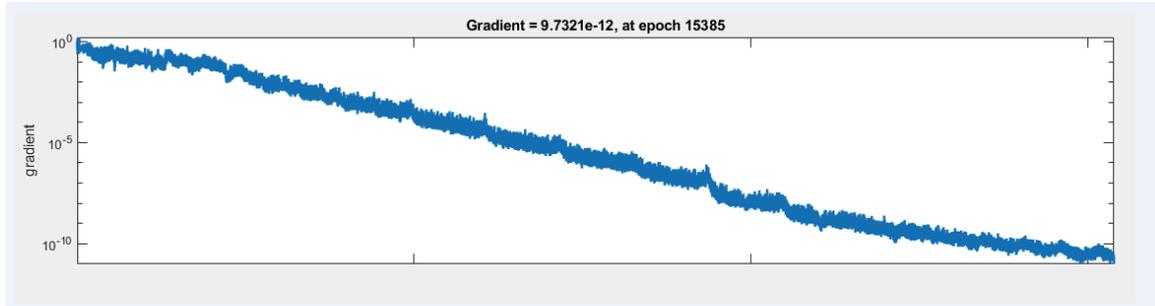


Figura 7-6 Gradiente durante el aprendizaje

La capacitación también se detendrá si hace clic en el botón Detener capacitación en la ventana de capacitación (Figura 4-5). Es posible que desee hacer esto si la función de rendimiento no disminuye significativamente en muchas iteraciones o si se detecta que el error comienza a oscilar, este proceso se denomina *early stopping* (detención temprana) y se realiza al momento de detectar el mínimo error alcanzado en un periodo finito de iteraciones.

Cada vez que se entrena una red neuronal, puede resultar en una solución diferente debido a los diferentes valores de sesgo y peso iniciales y diferentes divisiones de datos en entrenamiento, validación y conjuntos de pruebas. Como resultado, diferentes redes neuronales entrenadas en el mismo problema pueden dar diferentes salidas para la misma entrada. Para asegurarse de que se ha encontrado una red neuronal de buena precisión, es recomendable entrenarla más de una vez.

Función de Entrenamiento de la Red Neuronal

Hay varias características de algoritmo que pueden deducirse de los experimentos descritos. En general, en los problemas de aproximación de funciones, para las redes que contienen hasta unos cientos de pesos, el algoritmo de Levenberg-Marquardt (LM) tendrá la convergencia más rápida. Esta ventaja es especialmente notable si se requiere un entrenamiento muy preciso. En muchos casos, LM es capaz de obtener errores cuadráticos medios más bajos que cualquiera de los otros algoritmos probados. Sin embargo, a medida que aumenta el número de pesos en la red, la ventaja LM disminuye. Además, el rendimiento de LM es relativamente bajo en los problemas de reconocimiento de patrones. Los requisitos de almacenamiento de LM son mayores en otros algoritmos probados.

La Retro-Propagación Resistente (RP) función es el algoritmo más rápido en problemas de reconocimiento de patrones. Sin embargo, no funciona bien en problemas de aproximación de funciones. Su rendimiento también se degrada a medida que se reduce el objetivo de error. Los requisitos de memoria para este algoritmo son relativamente pequeños en comparación con los otros algoritmos considerados.

Por otro lado los algoritmos de gradiente conjugado, en particular Gradiente Conjugado Escalado (SCG), parecen funcionar bien en una amplia variedad de problemas, particularmente para redes con un gran número de ponderaciones. El algoritmo SCG es casi tan rápido como el algoritmo LM en problemas de aproximación de funciones (más rápido para redes grandes) y es casi tan rápido como RP en problemas de reconocimiento de patrones. Su rendimiento no se degrada tan rápido

como el RP rendimiento cuando se reduce el error. Los algoritmos de gradiente conjugado tienen requisitos de memoria relativamente modestos.

7.1.5 Rendimiento de la Red Neuronal

El siguiente paso para validar la red es crear un gráfico de regresión, que muestre la relación entre las salidas de la red y los objetivos. Si la capacitación fuera perfecta, los resultados de la red y los objetivos serían exactamente iguales, pero la relación rara vez es perfecta en la práctica

En la Figura 5-3 la línea discontinua en cada gráfica representa el resultado perfecto: salidas = objetivos. La línea continua representa la mejor línea de regresión lineal de ajuste entre salidas y objetivos. El valor R es una indicación de la relación entre las salidas y los objetivos. Si $R = 1$, esto indica que existe una relación lineal exacta entre las salidas y los objetivos. Si R está cerca de cero, entonces no hay una relación lineal entre las salidas y los objetivos. Este diagrama es útil para mostrar que ciertos datos tienen ajustes inadecuados, por lo que demuestra una ineficiente configuración de la red o que es necesaria la recopilación de datos adicionales para utilizarlos en el conjunto de prueba.

7.1.6 Limitaciones y Precauciones

Las redes multicapa son capaces de realizar casi cualquier cálculo lineal o no lineal, y pueden aproximarse a cualquier función razonable arbitrariamente bien. Sin embargo, mientras que la red que está siendo entrenada puede ser teóricamente capaz de funcionar correctamente, la propagación hacia atrás y sus variaciones no siempre pueden encontrar una solución.

Las redes también son sensibles al número de neuronas en sus capas ocultas. Muy pocas neuronas pueden llevar a la insuficiencia. Demasiadas neuronas pueden contribuir al sobreajuste, en el que todos los puntos de entrenamiento están bien ajustados, pero la curva de ajuste oscila violentamente entre estos puntos. Las formas de tratar varios de estos problemas se analizan en mejorar la generalización de la red neuronal superficial y evitar el exceso de equipamiento, ya sea de capas ocultas y neuronas.

7.1.7 Funciones de Procesamiento de Entrada y Salida

La capacitación de la Red Neuronal puede ser más eficiente si realiza ciertos pasos de pre-procesamiento en las entradas y los objetivos de la red. Esta sección se describen algunas rutinas de pre-procesamiento que puede utilizar. (Los más comunes se proporcionan automáticamente al crear una red, y se convierten en parte del objeto de la red, de modo que cada vez que se utiliza la red, los datos que ingresan a la red se procesan de la misma manera).

Por ejemplo, en redes multicapa, las funciones de transferencia sigmoidea se usan generalmente en las capas ocultas. Estas funciones se saturan esencialmente cuando la entrada neta es mayor que tres. Si esto sucede al comienzo del proceso de capacitación, los gradientes serán muy pequeños y la capacitación de la red será muy lenta. En la primera capa de la red, la entrada de la red es un producto de la entrada multiplicada por el peso más el sesgo. Si la entrada es muy

grande, entonces el peso debe ser muy pequeño para evitar que la función de transferencia se sature. Es una práctica estándar normalizar las entradas antes de aplicarlas a la red.

En general, el paso de normalización se aplica tanto a los vectores de entrada como a los vectores de destino en el conjunto de datos. De esta manera, la salida de la red siempre cae dentro de un rango normalizado. La salida de la red se puede transformar a la inversa en las unidades de los datos de destino originales cuando la red se utiliza en el campo.

Es más fácil pensar que la red neuronal tiene un bloque de pre-procesamiento que aparece entre la entrada y la primera capa de la red y un bloque de post-proceso que aparece entre la última capa de la red y la salida, como se muestra en la Figura 7-7.

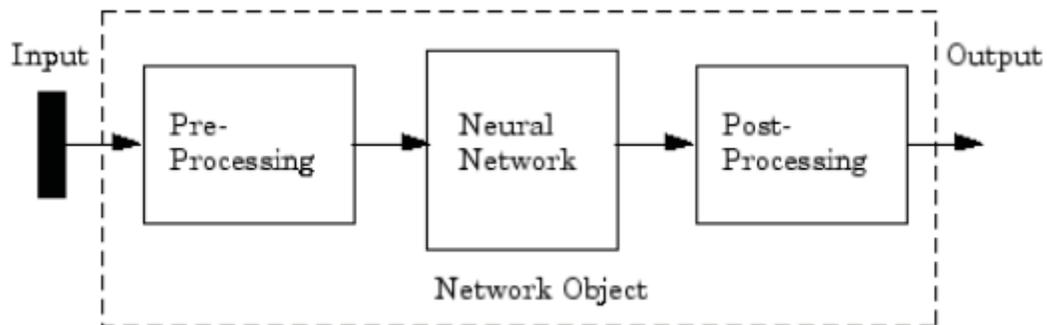


Figura 7-7 Bloque de Normalización en entradas y salidas

7.1.8 Tener en Cuenta

Normalmente, cada sesión de entrenamiento de propagación hacia atrás comienza con diferentes ponderaciones y sesgos iniciales, y diferentes divisiones de datos en entrenamiento, validación y conjuntos de pruebas. Estas diferentes condiciones pueden llevar a soluciones muy diferentes para el mismo problema.

Es una buena idea capacitar a varias redes para asegurar que se encuentre una red con buena generalización. Luego se carga un conjunto de datos y se divide en dos partes: 90% para diseñar redes y 10% para probarlas todas.

Cada red se capacitará a partir de diferentes pesos iniciales y sesgos, y con una división diferente del primer conjunto de datos en entrenamiento, validación y conjuntos de pruebas. Tenga en cuenta que los conjuntos de pruebas son una buena medida de la generalización para cada red respectiva, pero no para todas las redes, ya que los datos que son un conjunto de pruebas para una red probablemente serán utilizados para la capacitación o validación por otras redes neuronales. Esta es la razón por la que el conjunto de datos original se dividió en dos partes, para garantizar que se conserva un conjunto de prueba completamente independiente.

8 Resultados Obtenidos MatLab

Luego de una optimización en las entradas del modelo y detallados a fondo los pasos a realizar en el entrenamiento neuronal, en el Capítulo 8 se analizarán los rendimientos de 36 distintas redes neuronales, en donde el Coeficiente de Pearson será el indicador de la mejor red. Con el objetivo de abarcar una cantidad consistente de Redes Neuronales y optar por la mejor opción, se planteó y crear 3 grupos de redes neuronales con distintos procesos de entrenamiento; LM, SCG y RP, además de los entrenamientos, se variaron la cantidad de capas ocultas; 1, 2 y 4 capas; y el número de neuronas en las capas ocultas; 5, 10, 30 y 50 neuronas.

8.1 Tablas Resumen de Entrenamientos y Simulaciones Realizadas

De la totalidad de los datos adquiridos un 90% de ellos fueron utilizados en el entrenamiento de las siguientes redes neuronales y el 10% para simular la predicción con entradas desconocidas para la red.

La elección de Red con mejor rendimiento será tanto en el entrenamiento como en la simulación.

8.1.1 Levenberg-Marquardt

A continuación, se presentan los Coeficientes de Pearson Obtenidos (CP) de 12 Redes Neuronales entrenadas con el método Levenberg- Marquardt (Tabla 8-1) y posteriormente simuladas (Tabla 8-2).

Tabla 8-1 Coeficientes de Pearson en Entrenamientos

Levenberg-Marquardt Muestras Entrenadas				
N° Capas\N° Neuronas	5	10	30	50
1	0.7051	0.8469	0.8712	0.8172
2	0.8424	0.8153	0.8475	0.8389
4	0.7248	0.8619	0.8181	0.7937

Tabla 8-2 Coeficientes de Pearson en Simulaciones

Levenberg-Marquardt Muestras No Entrenadas				
N° Capas\N° Neuronas	5	10	30	50
1	0.5801	0.4848	0.5963	0.4625
2	0.4294	0.4560	0.2616	0.3966
4	0.3285	0.5721	0.4574	0.4559

La Red Neuronal mejor entrenada con LM fue la configurada con 1 capas ocultas y 30 neuronas por capas oculta, esta con un CP de 0.87, desarrollando una excelente aproximación a los choques de postes registrados. En cuanto a la predicción, para calles desconocidas para la red, la misma configuración obtuvo el mejor índice (0.59) de aproximación con esta función de aprendizaje (Levenberg-Marquardt).

8.1.2 Gradiente Conjugado Resistente

A continuación, se presentan los coeficientes de Pearson obtenidos de 12 Redes Neuronales entrenadas con el método Gradiente Conjugado Resistente (Tabla 8-3) y posteriormente simuladas (Tabla 8-4).

Tabla 8-3 Coeficientes de Pearson en Entrenamientos

Gradiente de Conjugado Resistente Muestras Entrenadas				
N° Capas\N° Neuronas	5	10	30	50
1	0.6151	0.8324	0.7578	0.8484
2	0.7597	0.8309	0.8030	0.8464
4	0.8444	0.8363	0.7938	0.6657

Tabla 8-4 Coeficientes de Pearson en Simulaciones

Gradiente de Conjugado Resistente Muestras No Entrenadas				
N° Capas\N° Neuronas	5	10	30	50
1	0.3031	0.4519	0.4816	0.5538
2	0.5067	0.3692	0.5487	0.4160
4	0.3537	0.3016	0.6092	0.4409

Dentro del grupo de entrenamiento con SCG la mejor simulación de la red con entradas desconocidas para ella, es de 4 capas ocultas y 30 neuronas, con un CP de 0.60 en la simulación y un CP de 0.79 en su entrenamiento, por lo que esta será la elegida con mejor rendimiento.

8.1.3 Retro-propagación Resistente

A continuación, se presentan los Coeficientes de Pearson Obtenidos de 12 Redes Neuronales entrenadas con el método Retro-propagación Resistente (Tabla 8-5) y posteriormente simuladas (Tabla 8-6).

Tabla 8-5 Coeficientes de Pearson en Entrenamientos

Backpropagation Resistente Muestras Entrenadas				
N° Capas \ N° Neuronas	5	10	30	50
1	0.7736	0.8434	0.8465	0.7204
2	0.7345	0.8186	0.7650	0.8337
4	0.4596	0.7121	0.8214	0.8517

Tabla 8-6 Coeficientes de Pearson en Simulaciones

Backpropagation Resistente Muestras No Entrenadas				
N° Capas \ N° Neuronas	5	10	30	50
1	0.6455	0.1758	0.4779	0.4518
2	0.5715	0.4828	0.5110	0.3315
4	0.2786	0.2778	0.4492	0.4847

Dentro del grupo de entrenamiento con Retro-propagación (RP) la mejor simulación de la red con entradas desconocidas para ella, es de 1 capas ocultas y 5 neuronas, con un CP de 0.63 en la simulación y un 0.77 en su entrenamiento, por lo que esta será la elegida con mejor rendimiento.

8.2 Finalistas

Debido a que el objetivo practico que tiene este modelo de predicción, que es el de presentar un nivel de riesgo hacia los postes de distribución eléctrica en futuros proyectos, el enfoque en rendimiento debe enfocarse en las simulaciones del comportamiento de la red con entradas desconocidas, por lo tanto, el mejor rendimiento lo obtuvo la red neuronal de 1 capas ocultas y 5 neuronas por capa oculta utilizando el método de aprendizaje de Retro-Propagación.

Cabe mencionar que esta elección puede variar según la cantidad de información que se posea, el tipo de variables agregadas, el entorno donde se realiza el muestreo, etc., por lo que esta red solo tiene como óptima elección el modelo de predicción en la Comuna de Valparaíso.

Tabla 8-7 Predicción realizada en Grupo de Entrenamiento

Calle	N° de Curvas	Zona	Calzada	Material Calzada	N° de Cruces	Inclinación Máxima[°]	Inclinación Promedio[°]	longitud [km]	N° Escuelas	N° de Choques	Predicción
LOS CASTAÑOS	1	1	1	0.775	4	18.5	10.6	0.336	0	0	0.651
AVENIDA NORUEGA	2	1	2	0.775	5	12.3	7.5	0.657	1	1	0.963
JOSE MORA	0	1	2	0.775	3	13.1	11.8	0.3	0	2	0.739
CHORRILLOS	1	1	1	0.775	4	23	18.1	0.222	0	0	0.625
TIERRAS ROJAS	1	1	1	0.775	1	14.7	9.2	0.263	0	0	0.191
DECIMA	0	1	3	0.75	0	20	16	0.197	0	2	1.820
ERNESTO MAZZEY	1	1	2	0.775	3	15.4	12.7	0.152	0	3	1.040
HELSINSKY	1	1	1	0.775	1	8.1	6.2	0.284	1	0	0.535
ALFREDO VARGAS STOLLER	3	1	2	0.775	8	25.1	10.1	0.758	1	2	2.043
CORONEL ROBERTO SOUPER	0	1	2	0.75	4	20.8	15.2	0.454	1	1	1.184
AVENIDA PALAZUELOS	1	1	2	0.75	8	27.2	9.2	0.57	0	1	1.2493
MIGUEL SEMIR	2	1	1	0.775	1	19.2	19.1	0.131	0	1	0.536
EL LITRE	3	1	2	0.775	2	28.7	18.4	0.494	0	2	1.009
GUILLERMO MUNNICH	1	1	2	0.75	6	22	11.9	0.734	4	0	2.218
TEMPLEMAN	0	1	1	0.775	9	16.1	10	0.486	0	0	0.332
NAYLOR	0	1	2	0.75	5	24.5	18.6	0.799	0	2	1.900
QUINTA DEL SUR	0	1	3	0.75	2	9.9	4.8	0.342	0	1	1.191
EMERSON	1	1	2	0.75	1	21.9	18.4	0.165	0	1	1.103

FEDERICO COSTA	5	2	1	0.775	1	26.6	11.8	0.553	0	1	0.960
EL SAUCE	0	1	2	0.75	11	4.7	2.4	1.6	0	1	1.110
DEL CABO	0	1	1	0.775	2	20	20.1	0.18	0	1	0.382
BERNARDO RAMOS	1	1	2	0.775	3	28	14.3	0.277	0	0	0.291
CARRERA	0	1	1	0.766	7	15	5.1	0.663	2	0	1.244
ANTICLEA	2	1	2	0.775	0	18.6	14.7	0.117	0	1	0.881
ARTURO PRAT	0	1	1	0.75	3	3.5	1.5	0.83	0	3	2.982
SANTOS TORNERO	1	1	3	0.75	6	21.7	14	0.617	0	1	0.906
MELIPILLA	1	1	1	0.775	0	9.1	4.1	0.234	0	1	0.431
HAMBURGO	0	1	1	0.775	13	14.3	8.1	0.497	0	2	1.766
AVENIDA SANTA ELENA	4	1	1	0.75	6	10.8	6.3	0.803	1	4	0.651

Se puede Observar en la Tabla 8-7 el gran rendimiento que tiene la red neuronal en predecir choques a postes con un coeficiente de Pearson de 0.85, en las primeras 28 calles entrenadas. Esta predicción fue realizada con una red neuronal artificial compuesta de 4 capas ocultas, con 50 neuronas por capa y un algoritmo de aprendizaje de retro propagación. En esta predicción se registraron un total de 6 calles en las que la predicción sobre paso el error de a lo menos 2 choques a postes, con respecto al total de calles del grupo A.

Tabla 8-8 Predicción en Grupo se Simulación

Calle	N° de Curvas	Zona	Calzada	Material Calzada	N° de Cruces	Inclinación Máxima[°]	Inclinación Promedio[°]	longitud [km]	N° Escuelas	N° de Choques	Predicción
AVENIDA BAQUEDANO	5	2	1	0.775	7	26	11.6	1.34	1	3	4.190
ANTONIO VARAS	1	1	2	0.75	2	8.8	4.4	0.374	0	1	1.930

AVENIDA JOSE MARIA CARO	1	1	2	0.775	7	17.6	8.1	0.875	1	1	1.625
IBERIA	2	1	2	0.775	1	22.5	17.1	0.287	0	1	0.701
AV TUPUNGATO	1	1	1	0.775	4	8.2	3.7	1.72	0	2	0.941
JORGE KENRICK	1	1	2	0.775	4	10.3	7.8	0.517	0	1	0.849
VICTOR PIVET	0	1	2	0.775	1	12.9	9.4	0.338	0	1	0.801
AVENIDA SUAREZ	1	1	2	0.775	2	14.6	14.4	0.235	0	1	0.809
RODOLFO PHILIPPI	6	1	2	0.775	3	22	9.4	0.842	0	4	1.826
HUASCO	2	1	3	0.775	5	11.6	7.8	0.45	0	1	0.946
CHACABUCO	0	1	1	0.75	13	2.6	0.9	1.44	1	2	2.641
AVENIDA QUEBRADA VERDE	1	1	1	0.775	7	10.3	8.5	0.899	1	2	1.035
EL BOSQUE	4	1	3	0.75	1	27.7	15.5	0.69	0	1	0.965
RIO BUENO	2	2	2	0.75	3	15.8	10.4	0.444	0	1	2.154
TRINQUETE	8	1	2	0.75	8	27.9	15.9	1.223	0	3	3.146
LAS CAMELIAS	5	1	2	0.775	3	19.2	9.2	0.931	0	1	1.395
BOYACA	3	1	1	0.775	3	15.5	7	0.571	0	1	1.046
SANTO DOMINGO	2	1	2	0.75	1	20.9	14.3	0.32	0	1	1.322
IRENE FREI	2	1	1	0.775	5	23	12.8	0.75	0	1	1.235
PASAJE TREINTA Y DOS	1	1	2	0.775	0	20	20	0.152	0	1	0.684
NECOCHEA	0	1	2	0.775	7	8.7	6.6	0.524	0	0	0.897
JIMÉNEZ	1	1	2	0.775	4	16	10	0.232	0	0	0.925
STA MARÍA	0	1	1	0.775	2	22.3	12	0.247	0	0	0.700

En la Tabla 8-8 se aprecia el rendimiento de predicción de la red finalista al enfrentarse a calles desconocidas en su entrenamiento, lo que la hace una herramienta muy útil en la toma de decisión de futuros proyectos de distribución eléctrica. Para ser predicciones a calles desconocidas (grupo B) se presentaron solo 1 error de a lo más 2 postes de diferencia. La configuración que realizó esta predicción para calles desconocidas en su entrenamiento fue una de 1 capas ocultas y 5 neuronas por capa oculta.

9 Entrenamiento con librerías Keras

En el capítulo 4 sección 4.4.2 se desarrolló un código en lenguaje Python, este utiliza la matemática interna en el proceso de reajustes de las matrices de pesos en la RNA, por lo que sus cálculos se basan en operatoria matricial, esto puede resumirse y complementarse con las librerías Keras.

Keras es una librería de Python que proporciona de manera limpia y sencilla la creación de una gama de modelos de Deep Learning encima de otras librerías TensorFlow, Theano o CNTK. Keras fue desarrollado y es mantenido por François Chollet, un ingeniero de Google, y su código ha sido liberado bajo la licencia permisiva del MIT [22].

Es correcto afirmar que los componentes de un modelo de Deep Learning son elementos discretos que se pueden combinar de manera arbitraria, lo que conlleva a la necesidad de utilizar nuevos componentes con facilidad de agregar y modificar, todo tipo de parámetros, dentro del marco diseñado para que los ingenieros prueben y exploren nuevas ideas rápidamente.

En el presente capítulo se realizaron los entrenamientos de algunas redes neuronales con esta librería, con el propósito de compararla con los resultados obtenidos en la caja de herramientas nntool de Matlab y concluir tanto ventajas como desventajas de cada herramienta, en las etapas de importar registro de calles, creación de la red, compilación, ajustes y herramientas para la evaluación del modelo configurado.

9.1 Código utilizado

A continuación, se presenta el código utilizado para el entrenamiento de la red neuronal artificial. Y una pequeña descripción.

```
1 from keras.models import Sequential
2 from keras.layers import Dense
3 import matplotlib.pyplot as plt
4 import numpy as np
```

Figura 9-1 Librerías utilizadas para el desarrollo del Entrenamiento

La función *Sequential* será la encargada de crear y agrupar todas las capas configuradas posteriormente. La función *Dense* describirá parámetros como el número de neuronas en la capa,

número de entradas (solo en la primera capa) y la función de activación de la capa. Los parámetros de la función de activación fueron escogidos en relación a las configuraciones realizadas con `nntool` de Matlab, aun así, la librería Keras permite utilizar tales como sigmoidea, exponencial, lineal, lineal positiva, tangente hiperbólica, funciones avanzadas, etc. Esto es posible ver desde la línea de código 239 a la 243 de la Figura 9-2. Si bien la función `Dense` genera la configuración de una sola capa, se pueden repetir las veces que el usuario estime conveniente para generar capas en cascada para la configuración de la red neuronal artificial.

Las librerías de *Numpy* como fueron mencionadas en el Capítulo 4, tiene de finalidad todo tipo de operatoria matricial o transformación de vectores a matrices. Y la librería *matplotlib* cumplirá como herramienta para la generación de gráficas.

```

233 dataset = np.array(matriz)
234 X=dataset[:,0:9]
235 Y=dataset[:,9]
236
237 #crea la red neuronal
238 model=Sequential()
239 model.add(Dense(50,input_dim=9,activation='sigmoid'))
240 model.add(Dense(50,activation='sigmoid'))
241 model.add(Dense(50,activation='sigmoid'))
242 model.add(Dense(50,activation='sigmoid'))
243 model.add(Dense(1,activation='relu'))
244 #compilacion del modelo
245 model.compile(loss='mean_squared_error', optimizer='rmsprop', metrics=['accuracy'])
246 #ajuste el modelo
247 history=model.fit(X,Y,validation_split=0.1,epochs=5500 ,batch_size=10)
248 #Evaluación del modelo de La RNA
249 scores=model.evaluate(X,Y)
250 print("\n%s: %.2f%%" % (model.metrics_names[1], scores[1]*100))
251 #realizacion de grafica de 1 precision
252 plt.plot(history.history['acc'])
253 plt.plot(history.history['val_acc'])
254 plt.title('Precisión del modelo')
255 plt.ylabel('Coeficiente de correlación')
256 plt.xlabel('Iteraciones')
257 plt.legend(['Entrenamiento', 'test'], loc='upper left')
258 plt.show()
259 # hacemos las grafica 2 perdidas
260 plt.plot(history.history['loss'])
261 plt.plot(history.history['val_loss'])
262 plt.title('Error del modelo')
263 plt.ylabel('Error')
264 plt.xlabel('Iteraciones')
265 plt.legend(['Grupo A', 'Grupo B'], loc='upper left')
266 plt.show()
267

```

Figura 9-2 Código Python para el desarrollo una RNA

Posteriormente se agrega a *Sequential* la función *Compile*, en esta se especificarán los parámetros de compilación en el proceso de aprendizaje, donde se detalla la pérdida (loss) o error calculado en cada iteración, la optimización, que corresponde a la función de aprendizaje utilizada, y la métrica, en este se utilizó la como índice de exactitud el coeficiente de correlación. Tanto el error

cuadrático medio como el coeficiente de correlación serán calculados en cada iteración realizada como loss y acc, Figura 9-3.

El ajuste del modelo se realiza gracias a la función *fit*, sus parámetros permiten especificar a la RNA las matrices de entrada y salidas del modelo, número de iteraciones (epoch) y el porcentaje de datos de entrada a no entrenar y así validar una predicción con datos desconocidos para la red (parámetro: *validation_split*); al igual que el capítulo anterior, se utilizó un grupo B del 10% del total de calles registradas. Si se establece *validation_split* las validaciones tanto de loss como acc saldrán por cada iteración como *val_loss* y *val_acc*, Figura 9-3.

```
Epoch 5495/5500
202/202 [=====] - 0s 698us/step - loss: 0.6657 - acc: 0.5545
- val_loss: 0.9242 - val_acc: 0.4783
Epoch 5496/5500
202/202 [=====] - 0s 708us/step - loss: 0.6666 - acc: 0.5693
- val_loss: 0.9479 - val_acc: 0.5652
Epoch 5497/5500
202/202 [=====] - 0s 678us/step - loss: 0.6667 - acc: 0.5693
- val_loss: 0.9457 - val_acc: 0.5652
Epoch 5498/5500
202/202 [=====] - 0s 683us/step - loss: 0.6619 - acc: 0.5792
- val_loss: 0.9386 - val_acc: 0.5652
Epoch 5499/5500
202/202 [=====] - 0s 703us/step - loss: 0.6672 - acc: 0.5495
- val_loss: 0.9534 - val_acc: 0.5652
Epoch 5500/5500
202/202 [=====] - 0s 733us/step - loss: 0.6677 - acc: 0.5891
- val_loss: 0.9312 - val_acc: 0.4783
225/225 [=====] - 0s 147us/step

acc: 56.00%
```

Figura 9-3 Últimas iteraciones realizadas en un proceso de aprendizaje

Final mente desde la línea de código 252 a la 266 se utilizan las funciones de la librería *matplotlib* la que recolecta todas las perdidas y coeficientes de correlación por iteración, ya sea para las validaciones (grupo B) como las obtenidas en el proceso de entrenamiento (grupo A). Para así generar gráficos, tanto de error como de exactitud del modelo configurado.

9.2 Resultados obtenidos

Si bien las simulaciones realizadas pueden abarcar distintas configuraciones de parámetros para definir la RNA, en este caso solo se realizaron entrenamientos en las configuraciones ya realizadas en el Capítulo anterior, todo esto para analizar las ventajas y desventajas de estas herramientas. Las configuraciones escogidas a simular en el código Python fueron la red con mejor coeficiente de correlación en la Tabla 8-5 y Tabla 8-6.

9.2.1 Mejor configuración en predicción del grupo A

Esta configuración corresponde a una red neuronal con 4 capas ocultas, 50 neuronas por capa oculta y función de aprendizaje de retro-propagación, en donde gracias a su entrenamiento con

Matlab alcanza un rendimiento de 0.85 en coeficiente de correlación, en la predicción a datos de entrenamiento. Tras entrenar esta configuración de RNA, se puede apreciar el tanto el error como su coeficiente de exactitud en cada iteración de aprendizaje, Figura 9-4 y Figura 9-5 respectivamente.

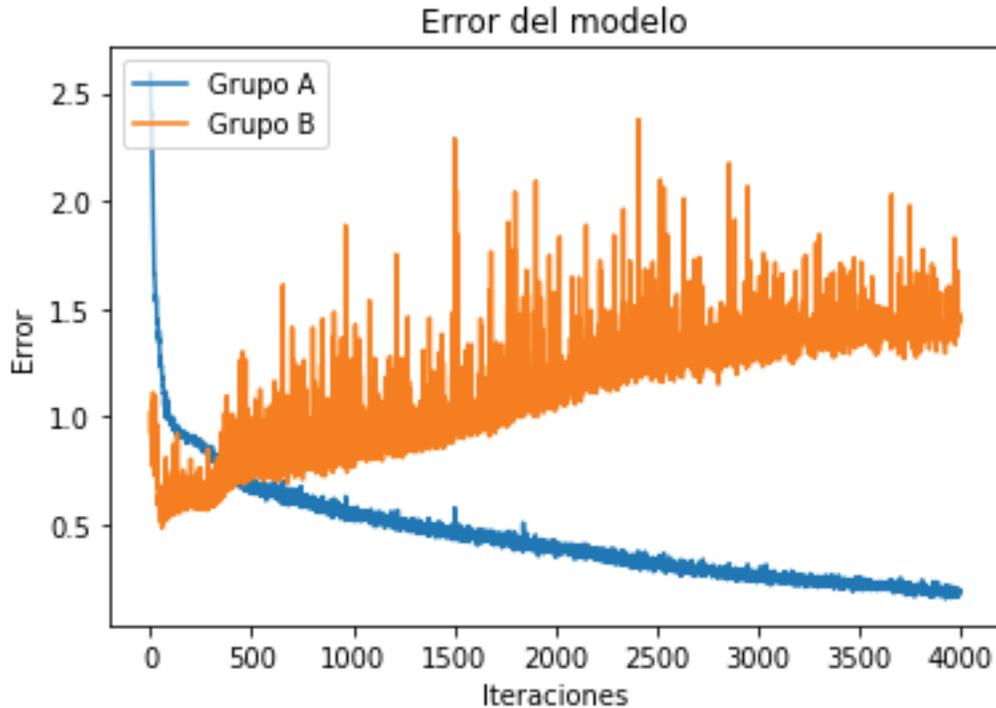


Figura 9-4 Error cuadrático medio por Iteración

Para esta configuración se realizaron 4000 iteraciones, debido a su convergencia alcanzada para este número.

Como primer comentario se puede visualizar que el error disminuye a mayor número de iteraciones la predicción para el grupo A, o sea, se ajusta cada vez más al registro de entrenamiento, no así en el grupo B. Dicho de otra manera, se puede comprobar que la RNA está aprendiendo de memoria cada caso en sus registros de aprendizaje, estableciendo un modelo muy específico, lo que para casos desconocidos las predicciones serán de baja calidad. Por lo tanto, al igual que en los capítulos pasados se concluye que la RNA debe optar por un aprendizaje generalizado, para no afectar la calidad de predicción en experiencias desconocidas.

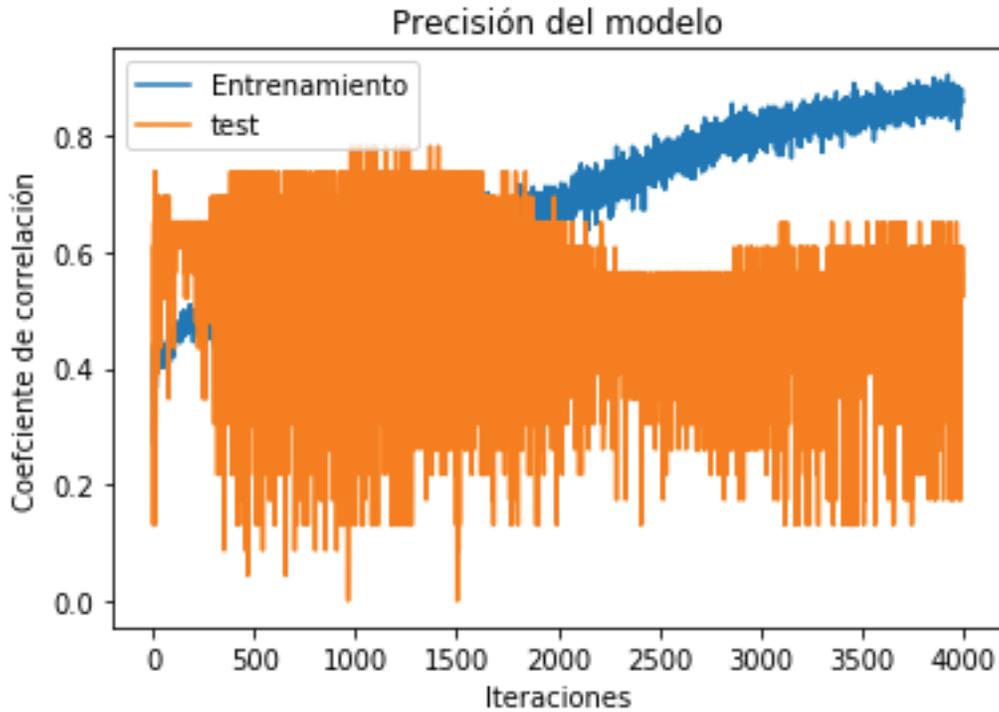


Figura 9-5 Coeficiente de Correlación por Iteración

Se puede afirmar visualizando la Figura 9-5 el comportamiento de la exactitud en la predicción a través del aprendizaje en la RNA, este comportamiento no es imprevisto, ya que como se analizó anteriormente el error cuadrático medio, estos factores reflejan la calidad de la predicción.

Si se comparan los coeficientes de correlación obtenidos con Nntool y librerías Keras en la presente configuración son bastante similares, como se puede apreciar en la Tabla 9-1:

Tabla 9-1 Recuento

coeficiente de correlación		
	Grupo A	Grupo B
Nntool	0.85	0.48
Keras	0.85	0.55

9.2.2 Mejor configuración en predicción del grupo B

Esta configuración corresponde a una red neuronal con 1 capas ocultas, 5 neuronas por capa oculta y función de aprendizaje de retro-propagación, en donde gracias a su entrenamiento con Matlab alcanzo un rendimiento de 0.65 en coeficiente de correlación, en la predicción a datos desconocidos para la RNA. Tras entrenar esta configuración de RNA, se puede apreciar el tanto el

error como su coeficiente de exactitud en cada iteración de aprendizaje, Figura 9-6 y Figura 9-7 respectivamente.

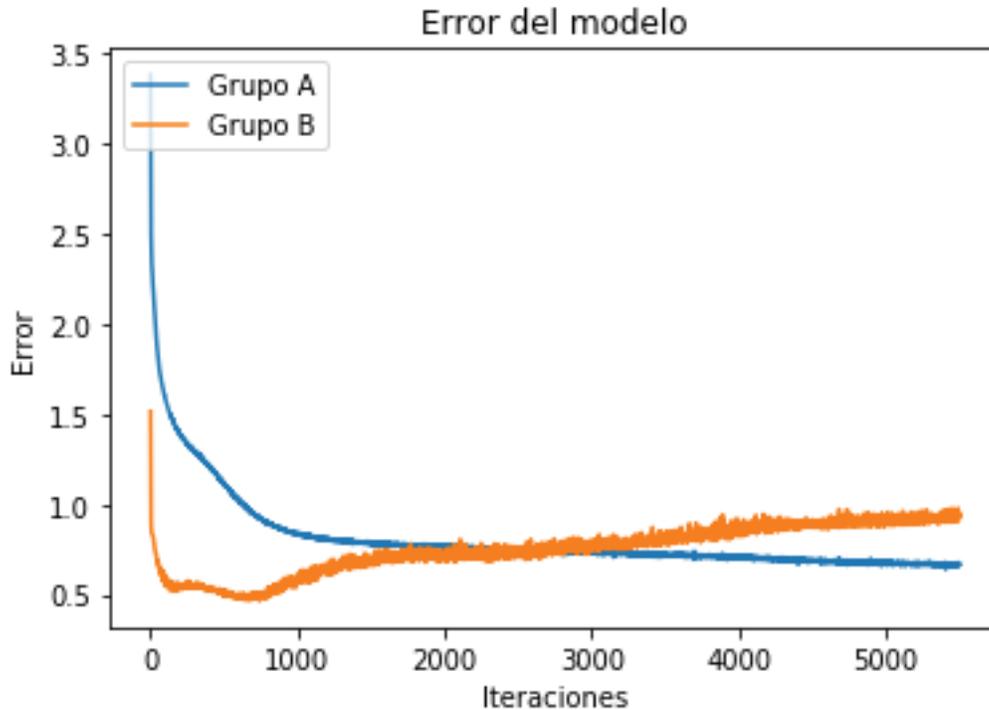


Figura 9-6 Error cuadrático medio por Iteración

Al igual que en la Figura 9-4 la Figura 9-6 presenta una disminución del error tras el proceso de aprendizaje, lo que se rescata, a mayor número de iteraciones la predicción será excesivamente específica para el grupo de datos de entrenamiento y no para el grupo desconocido para ella. En la curva de entrenamiento de la Figura 9-6 una convergencia más rápida que la descrita en la Figura 9-4, esto se puede adjudicar al aumento tanto de capas como neuronas por capa de la configuración en la RNA anterior (punto 9.2.1)

Si se desea realizar un stop learning, o detención de aprendizaje para encontrar un error en específico, será conveniente utilizar una configuración de RNA con más neuronas o capas, para que la convergencia sea más lenta y sencillo de encontrar el error óptimo.

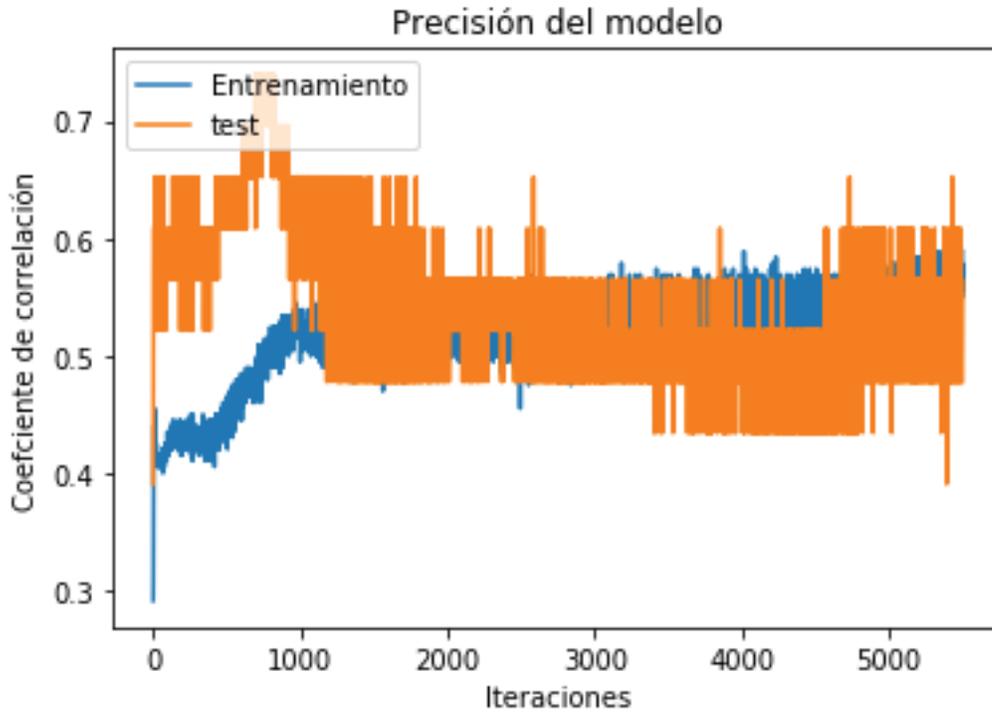


Figura 9-7 Coeficiente de Correlación por Iteración

Se puede afirmar visualizando la Figura 9-7 el comportamiento de la exactitud en la predicción a través del aprendizaje en la RNA, este comportamiento no es imprevisto, ya que como se analizó anteriormente el error cuadrático medio, estos factores reflejan la calidad de la predicción.

Si se comparan los coeficientes de correlación obtenidos con Nntool y librerías Keras en la presente configuración son bastante similares, como se puede apreciar en la Tabla 9-2:

Tabla 9-2 Recuento

coeficiente de correlación		
	Grupo A	Grupo B
Nntool	0.77	0.64
Keras	0.6	0.65

Si bien el grupo B obtuvo una calidad de predicción casi idéntica, comparando Python con Matlab, en el grupo A no ocurrió lo mismo, esto se puede atribuir a tanto a la matriz aleatoria inicial al entrenamiento, o a la variabilidad de gradiente que ocurre en cada iteración de aprendizaje, lo que culmina con distintos índices de exactitud a desarrollar entrenamientos con la misma configuración de RNA.

10 Análisis de sensibilidad

Una queja frecuente sobre los modelos de redes neuronales es que no explican sus resultados de manera útil. El problema no es la falta de información, sino la abundancia de información que es difícil de interpretar. Cuando se entrena, las redes neuronales proporcionan una salida predicha para una entrada pospuesta y pueden proporcionar información adicional en forma de intensidades de conexión entre elementos. Pero esta última información es de poca utilidad para los analistas y gerentes que desean interpretar los resultados que han recibido. En este capítulo, se desarrolló una medida de la importancia relativa de los diversos elementos de entrada y los elementos de capa ocultos, y utilizamos esto para interpretar la contribución de estos componentes a los resultados de la red neuronal.

En primera instancia se describieron los pesos obtenidos tras el entrenamiento en una RNA configurada con 1 capas ocultas, 5 neuronas por capa ocultas con una función de aprendizaje de retro-propagación. Esta red fue escogida debido a que fue la que obtuvo la mejor predicción hacia datos desconocidos para ella, con un 0,65 de coeficiente de correlación.

Ahora, con el fin de determinar el impacto que posee cada una de las variables de entrada sobre las predicciones, se realizaron 2 métodos de sensibilidad, estas se llevaron a cabo utilizando la matriz de pesos obtenida en el proceso de entrenamiento.

10.1 Matriz de pesos

Debido a la configuración obtenida, las matrices serán 2, la primera de dimensión 9 filas y 5 columnas (W), debido a la cantidad de entradas y número de neuronas respectivamente y la segunda de 5 filas y una columna (V), debido a la cantidad de neuronas y a la única salida, respectivamente.

Las matrices se presentan a continuación:

W=

Entradas\Neuronas	1	2	3	4	5
N° curvas	0.0756	3.6317	-1.5855	-0.3583	1.4301
Zona	1.6635	-0.1844	0.3030	2.3081	-0.2481
Calzada	-0.6178	-1.8263	-0.0868	-1.7467	147.5667
Roce	0.6554	2.2465	0.5064	-0.4877	0.8878
N° cruces	-1.4992	8.7887	-1.2609	0.6063	0.1537
P. máxima	-1.1947	3.6686	0.1932	-0.8970	-0.2715
P. media	-1.4550	-0.2326	1.1864	1.2863	8.9316
Longitud	0.9878	-1.1211	-0.6451	-1.2893	1.2803
N° escuelas	1.4524	0.6363	-0.2267	1.5214	-1.2040

V=

Neuronas\Salida	N° de choques
1	-0.9044
2	1.0319
3	-0.7662
4	0.4986
5	0.0805

10.2 Método de Garson

Garson propuso un algoritmo basado en los pesos de conexión de la red neuronal para determinar la importancia relativa de cada variable de entrada, similar al análisis de sensibilidad general, esforzándose por cuantificar las relaciones entre las variables explicativas y de respuesta. Sin embargo, la principal diferencia radica en la consideración de posibles interacciones entre las variables. La magnitud y el signo de la relación entre las variables de entrada se gestionan, de acuerdo con nuestra comprensión conceptual. Por lo tanto, esto es más equivalente a la condición del mundo real. Este modelo se expresa con la Ecuación 10-1

$$C_{ik} = \frac{\sum_{j=1}^J \frac{|w_{ji}| |v_{jk}|}{\sum_{r=1}^I |w_{ri}|}}{\sum_{i=1}^I \sum_{j=1}^J \frac{|w_{ji}| |v_{jk}|}{\sum_{r=1}^I |w_{ri}|}} \quad (10-1)$$

Donde:

- J =número de neuronas ocultas
- i =entrada a la cual se desea saber el Coeficiente de Garson
- I =número de entradas
- k = número de salidas
- w_{ji} =peso sináptico de la entrada i hacia la neurona j
- v_{jk} = peso sináptico de la neurona j hasta la salida
- w_{ri} =todos los pesos sinápticos entre la capa de entradas y la oculta.

A primera vista, se podría esperar que en el enfoque el algoritmo de Garson produzcan buenos resultados, ya que este utiliza una ecuación basada en los pesos de conexión de entrada, oculta y salida al calcular la importancia de la variable. De hecho, esto no es el caso. El problema principal del modelo de Garson es que utiliza los valores absolutos de los pesos, excluyendo todo tipo de flujo negativo a los aportes de las entradas, por lo que puede dar como resultado estimaciones incorrectas de importancia variable [23].

10.2.1 Resultados obtenidos

Los resultados obtenidos tras la realización del análisis de sensibilidad se pueden observar en la Figura 10-1, en ella se aprecia claramente los niveles de concentración

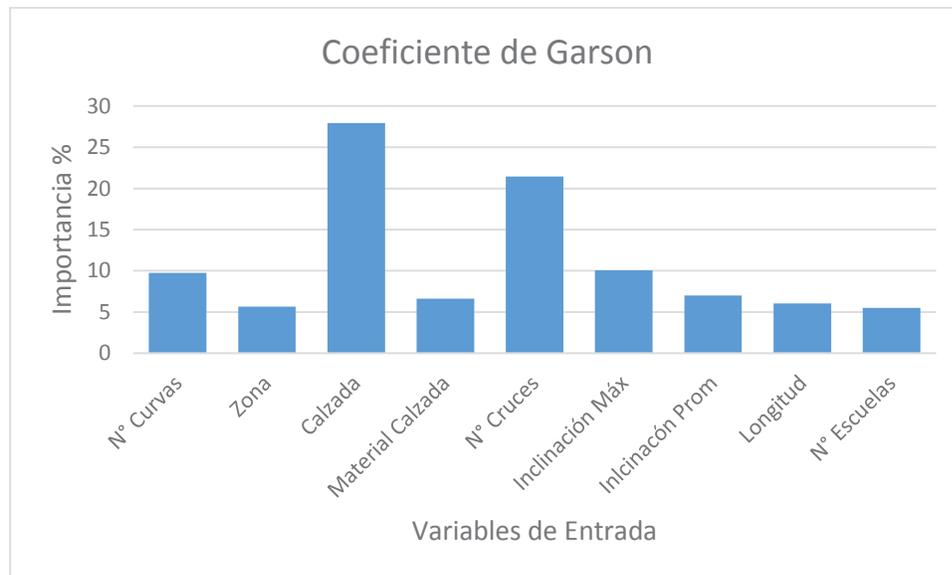


Figura 10-1 Sensibilidad de entradas en el modelo

Tanto con la Figura 10-1 como la Tabla 10-1 se puede establecer un Ranking de las variables más y menos influyentes en el modelo de predicción según el método de Garson. Estableciendo al número de cruces, numero de calzadas e inclinación máxima de la calle, como las variables más influyentes en la predicción de choques a poste. En caso contrario las variables más susceptibles

a ser eliminadas del modelo serian el número de escuelas, la zona de ubicación y la longitud de la calle.

Tabla 10-1 Rancking de sensibilidad

Entrada	Importancia %	Ranking
N° Curvas	9.75	5
Zona	5.67	8
Calzada	27.95	1
Material Calzada	6.62	6
N° Cruces	21.44	2
Inclinación Máx	10.04	3
Inlcinación Prom	7.01	4
Longitud	6.03	7
N° Escuelas	5.49	9

10.3 Método de enfoque de peso en conexión

Este método nació y fue implementado en el estudio “una comparación precisa de los métodos para cuantificar la importancia de una variable en Redes Neuronales Artificiales utilizando datos simulados, del departamento de biología de la Universidad estatal de Colorado” [23], en donde se evaluaron distintos métodos de sensibilidad en variables, teniendo conocimiento, desde un principio, de la importancia de las variables en juego, por lo que su mejor método es el siguiente. Éste a diferencia de Garson si es capaz de tomar en cuenta los flujos negativos descritos en los pesos de la RNA.

El cálculo de las variables más sensibles viene descrito por la siguiente ecuación

$$S_i = \sum_{j=1}^J w_{ij}v_{jk} \quad (10-2)$$

Donde:

- i = variable a analizar sensibilidad
- J =número de neuronas en capa oculta
- K =número de salidas del modelo
- w =pesos entre capa de entrada y capa oculta
- v = pesos entre capa oculta y capa de salida

A sea corresponde al peso final al que se ve afectado la entrada del modelo, por lo que su unidad no es porcentual como lo establece Garson, sino que es la magnitud del peso utilizado.

10.3.1 Resultados obtenidos

Si bien la magnitud del cálculo de sensibilidad viene dada por la unidad del peso, a esta se puede establecer un Rankin de importancia de que variables adopto mayor peso en el proceso de entrenamiento

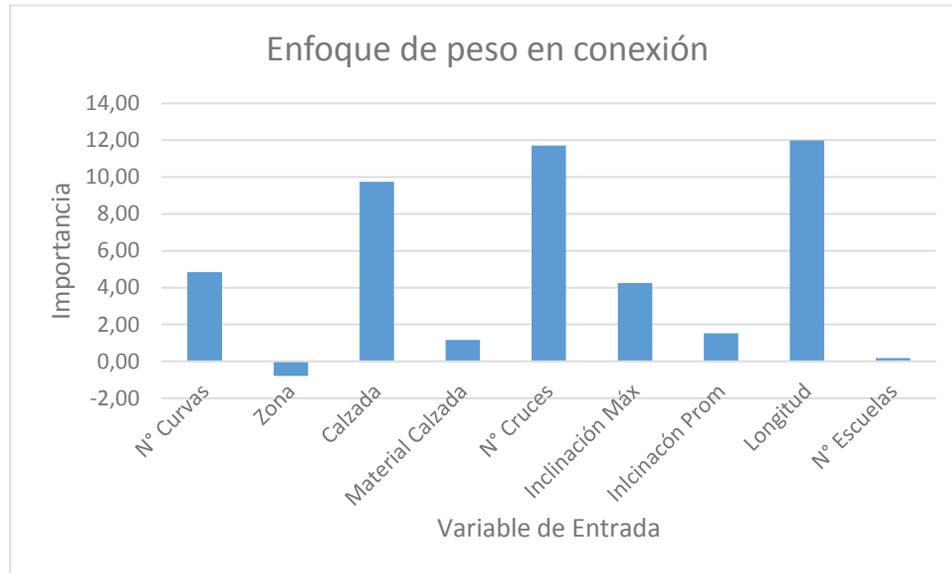


Figura 10-2 Sensibilidad de entradas en el modelo

Tal como describe la Figura 10-2 y Tabla 10-2 las variables con mayor influencia en la predicción son la longitud de la calle, Número de cruces, número de vías en la calzada y el número de curvas de la calle. En caso contrario las variables tentativas a eliminar del modelo, por su poco aporte serian, el número de escuelas, la zona de ubicación, el material de la calzada e inclinación promedio.

Tabla 10-2 Ranking de sensibilidad

Entrada	Importancia	Ranking
N° Curvas	4.83	4
Zona	-0.80	9
Calzada	9.75	3
Material Calzada	1.17	7
N° Cruces	11.71	2
Inclinación Máx	4.25	5
Inclinación Prom	1.53	6
Longitud	11.98	1
N° Escuelas	0.18	8

10.4 Comprobación de la obtención de variables mas sensibles

Para comprobar la efectividad del método enfoque de peso en conexión, se realizó un nuevo entrenamiento para mejor configuración para el grupo B y para la mejor configuración del grupo A. De esto se espera que, al eliminar las variables con menor sensibilidad, la calidad de la predicción sea igual o similar a la obtenida inicialmente.

Las variables más sensibles y utilizadas para el entrenamiento de las RNAs fueron:

- Número de curvas
- Calzada (número de vías)
- Número de cruces
- Inclinación máxima
- Longitud de la calle

Cabe mencionar la configuración de RNA con mejor calidad de predicción en el grupo A es la estructurada de; 4 capas ocultas, 50 neuronas por capa oculta y funcione de entrenamiento retro-propagación; y la configuración con mejor calidad de predicción en el grupo B de datos es la estructurada con; 1 capa oculta, 5 neuronas por capa oculta y función de entrenamiento de retro-propagación.

10.4.1 Resumen de índices de calidad de predicción

Con la Tabla 10-3 se puede visualizar los coeficientes de correlación obtenidos tanto en un enteramiento con las 9 variables de entradas, como para las 5 variables más sensibles del modelo, en relación a su predicción. La casi exacta similitud corrobora la poca participación que desempeñaban las variables; zona, material de la calzada, pendiente promedio, número de escuelas en la calle; en una evaluación de predicción del riesgo de choques a postes. Esta metodología califica como excelente, para encontrar las variables que realmente aportan a una correcta predicción.

Tabla 10-3 Variables totales VS Variables sensibles

Entradas utilizadas en el entrenamiento (cantidad)	Coeficiente de correlación	
	Grupo A	Grupo B
Todas (9)	0.851	0.645
Mas sensibles (5)	0.845	0.638

Si bien las entradas menos sensibles, la zona, el material de la calzada, la inclinación máxima, fueron eliminadas, no siempre será conveniente eliminar estas en particular, ya que el factor que las sensibiliza son el aprendizaje (pesos obtenidos), esto dependerá del lugar donde se recopilaban los datos para el aprendizaje, en consecuente, las sensibilidades de las entradas dependerán del lugar a entrenar y pronosticar.

11 Modelo de regresión no lineal

Como se analizó en el capítulo 3, un método tentativo a utilizar como modelo predictivo de choques a postes, es a través de regresiones matemáticas. A pesar de que se analizó el estudio de Amanda Gange [24], en donde utilizo regresiones lineales para determinar una ecuación, con variables descriptivas de las calles, estas variables eran lineales, no como las utilizadas en éste estudio

11.1 Regresión no lineal

La regresión no lineal genera una ecuación para describir la relación no lineal entre una variable de respuesta continua y una o más variables predictores. Esta ecuación será descrita por funciones propias de cada variable de entrada, ya sean polinomios, logaritmos, parábolas, etc., según sea el análisis individual de cada variable con la cantidad de choques a postes (punto 11.2), y a estas multiplicadas por coeficientes. Esto se puede visualizar en la Ecuación 11-1

$$Y(x_1, x_2, x_3, \dots, x_n) = a + b \cdot f(x_1) + c \cdot f(x_2) + d \cdot f(x_3) + \dots + a_n \cdot f(x_n) \quad (11-1)$$

Donde a, b, c, d, \dots, a_n son coeficientes que ponderan cada función escogida y así proponer una mejor aproximación final. Las funciones $f(x_1), f(x_2), f(x_3), \dots, f(x_n)$ son aquellas que describen cada variable respecto a su índice de choques a postes. Por lo tanto, fue necesario analizar los siguientes gráficos independientemente.

11.1.1 Comportamiento de variables con respecto a la salida del modelo

A continuación, se muestran los gráficos y análisis de las 9 variables en estudio, con el fin de escoger que funciones describen la cantidad de postes chocados al año por calle. Para llevar esto a cabo, se empleó la herramienta Excel, la cual además graficar la dispersión de datos según cada variable, proporciona una línea de tendencia de la dispersión de datos, con su respectiva ecuación y coeficiente de determinación R^2 .

El coeficiente de determinación cumplió la función de indicador a mejor función de aproximación. Dicho de otra forma, mientras su valor sea más cercano a 1 esta función tiene una mejor aproximación al conjunto de datos registrado.

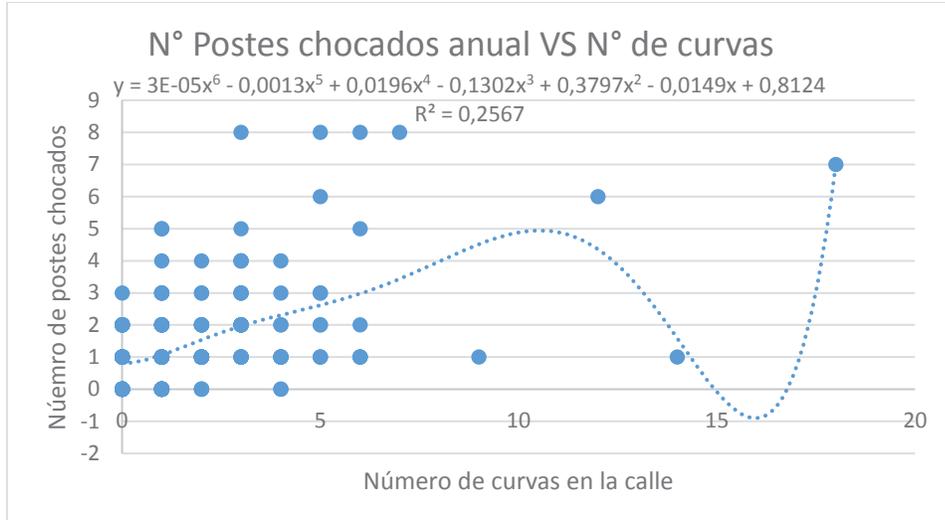


Figura 11-1 Función próxima a representar el número de curvas

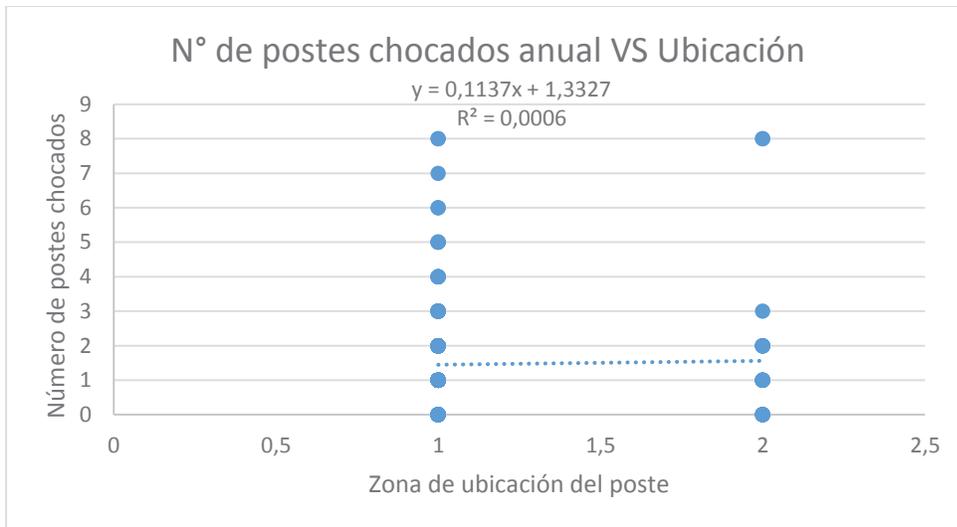


Figura 11-2 Función próxima a representar la ubicación

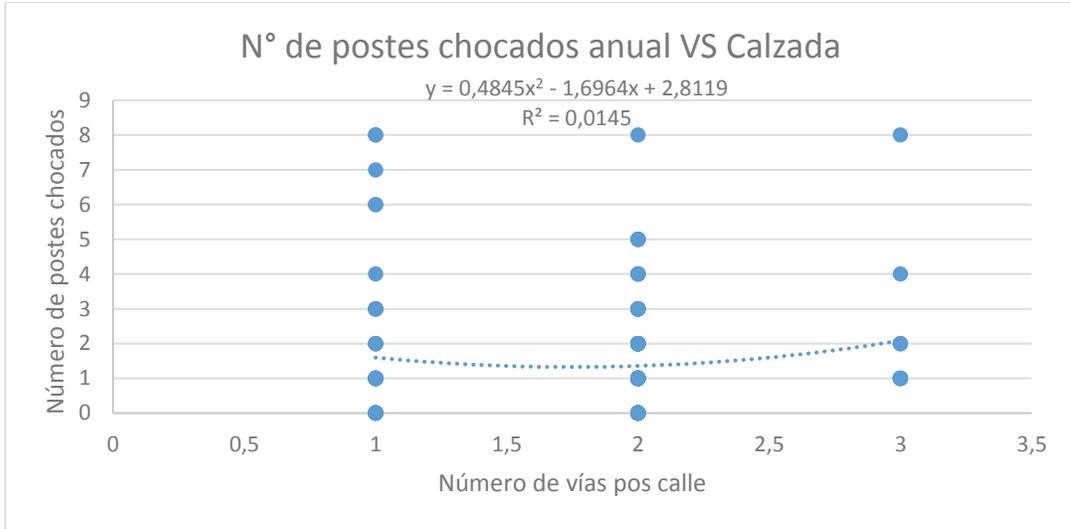


Figura 11-3 Función próxima a representar el número de vías en la calzada

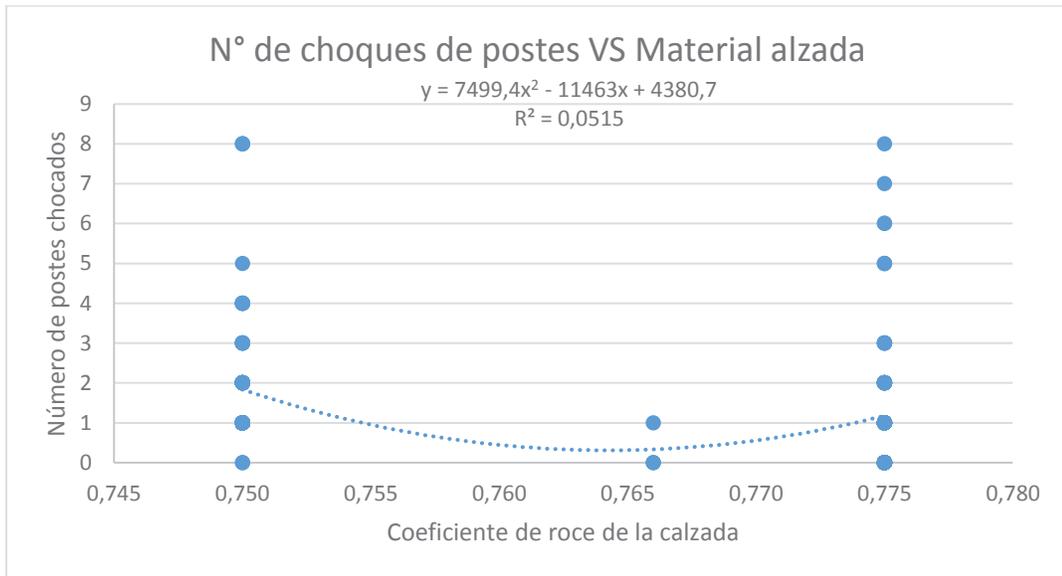


Figura 11-4 Función próxima a representar el material de calzada

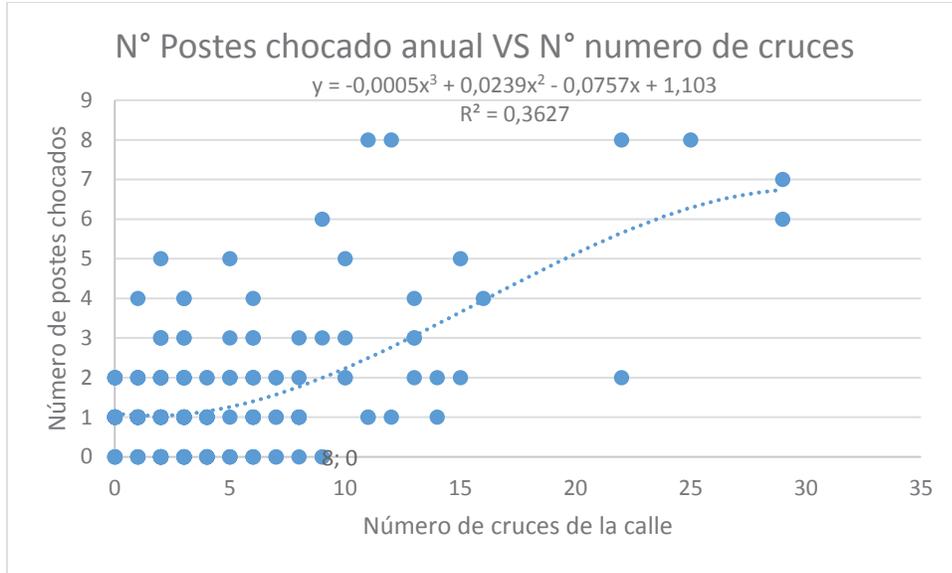


Figura 11-5 Función próxima a representar el número de cruces

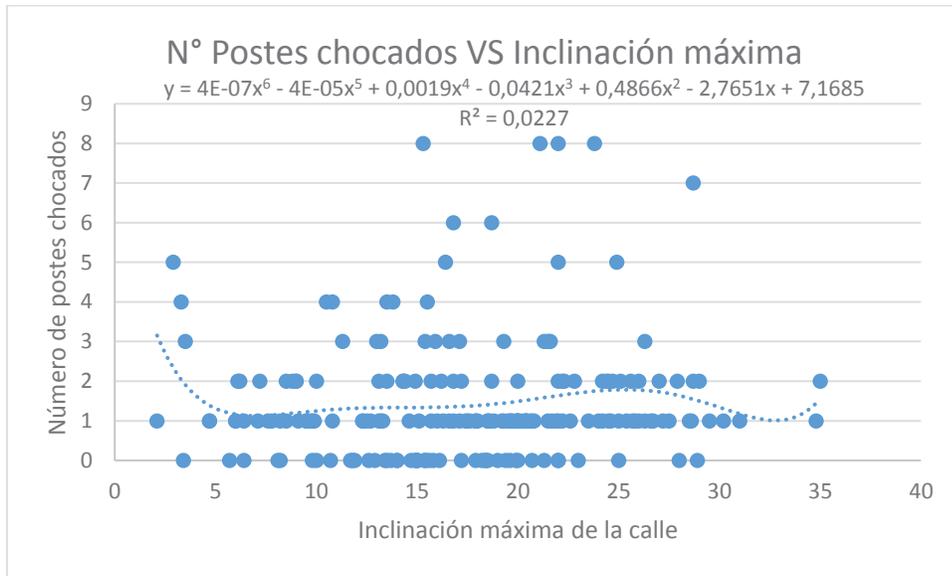


Figura 11-6 Función próxima a representar la inclinación máxima.

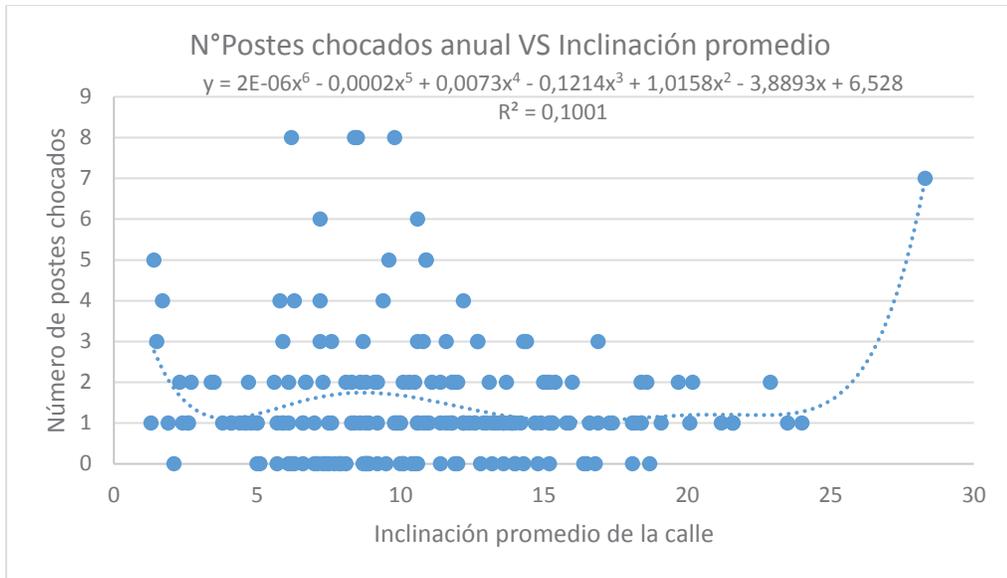


Figura 11-7 Función próxima a representar la inclinación promedio

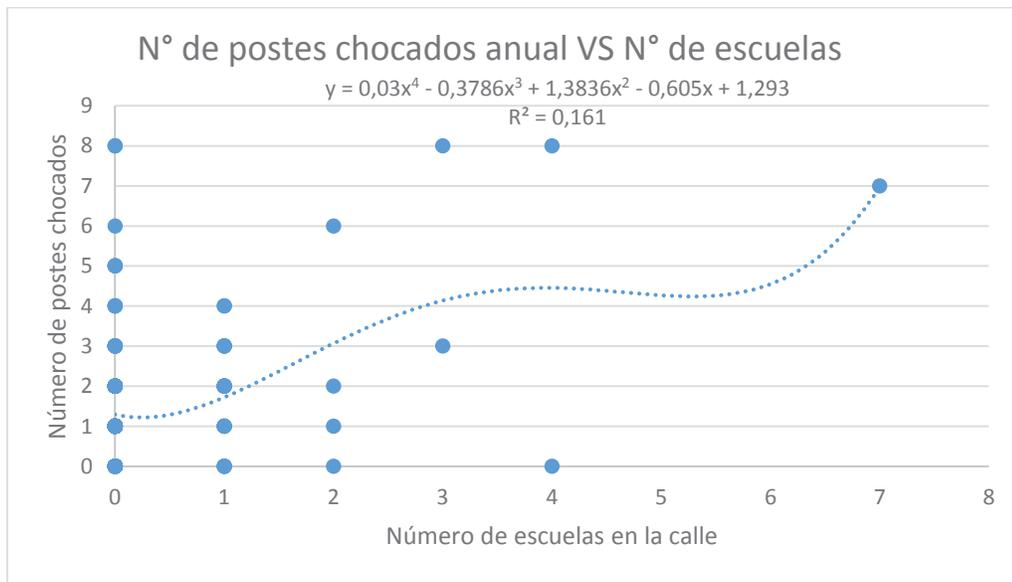


Figura 11-8 Función próxima a representar el número de escuelas

Tras obtener las funciones representativas de cada variable se tabulan en su resumen respectivo, Tabla 11-1. Para disminuir el número de carácter por variable, se les asigno letras mayúsculas desde la “A” a la “I” en las entradas y “J” en la salida.

Tabla 11-1 resumen de funciones descriptivas de variables

	Variable	Función
A	N° de Curvas	polinomio grado 6
B	Zona	lineal
C	Calzada	polinomio grado 2
D	Material Calzada	polinomio grado 2
E	N° de Cruces	polinomio grado 3
F	Inclinación Máxima	polinomio grado 6
G	Inclinación Promedio	polinomio grado 6
H	Longitud	polinomio grado 4
I	N° Escuelas	polinomio grado 4

Sólo resta obtener los coeficientes del modelo final, en donde entro en participación el programa de computadora diseñado para ejecutar funciones estadísticas básicas y avanzadas llamado Minitab.

Nota: Cabe mencionar que cada polinomio tiene sus respectivos coeficientes.

11.1.2 Obtención de coeficientes

El software de Matlab permite en primera instancia cargar la base de datos obtenida durante el estudio así informando al programa las salidas que tendrá el modelo y la salida, como se muestra en la Figura 11-9

↓	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10
	A	B	C	D	E	F	G	H	I	J
1	1	1	1	0,775	4	18,5	10,6	0,336	0	0
2	2	1	2	0,775	5	12,3	7,5	0,657	1	1
3	0	1	2	0,775	3	13,1	11,8	0,300	0	2
4	1	1	1	0,775	4	23,0	18,1	0,222	0	0
5	1	1	1	0,775	1	14,7	9,2	0,263	0	0
6	0	1	3	0,750	0	20,0	16,0	0,197	0	2
7	1	1	2	0,775	3	15,4	12,7	0,152	0	3
8	1	1	1	0,775	1	8,1	6,2	0,284	1	0
9	3	1	2	0,775	8	25,1	10,1	0,758	1	2
10	0	1	2	0,750	4	20,8	15,2	0,454	1	1
11	1	1	2	0,750	8	27,2	9,2	0,570	0	1
12	2	1	1	0,775	1	19,2	19,1	0,131	0	1
13	3	1	2	0,775	2	28,7	18,4	0,494	0	2

Figura 11-9 Base de datos cargada en Minitab

Posteriormente en “estadísticas” se encuentra la instrucción regresiones no lineales, como se muestra en la Figura 11-10, se describe tanto la salida (*J*) como la estructura total del modelo, donde se especifican los polinomios por variable y sus coeficientes como incógnita.

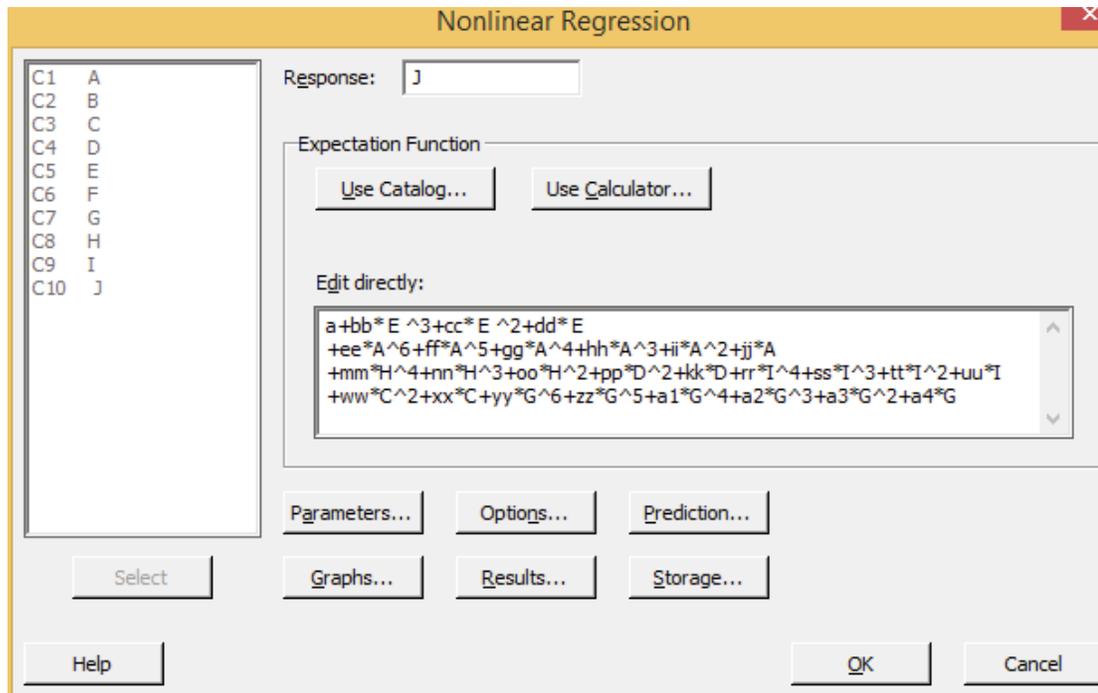


Figura 11-10 Búsqueda de coeficientes

Finalmente, clickeando “OK” Minitab realiza la búsqueda, iterativamente, de los coeficientes del modelo, esto lo realiza de tal forma que la salida del modelo sea lo más cercana al registro cargado inicialmente. Junto con los valores de los coeficientes, Minitab entrega un error promedio calculado con las predicciones del modelo.

¿Qué variables aportan menos error?

Debido a que se planteó la pregunta, ¿Qué variables me aportan error a la predicción?, se realizó la búsqueda de múltiples combinaciones de variables de entrada. Los resultados obtenidos se resumen en la Tabla 11-2. El método de elección fue el de escoger las combinaciones que describan la variable dependiente con un menor error cuadrático promedio, comenzando de sólo una variable e ir agregando variables faltantes. Así fue como se obtuvo la combinación EAHDICF, y si la llevamos a la ecuación final tenemos la Ecuación 11-2

$$\begin{aligned}
 y = & 12889.8 + 0.000211727 E^3 + 0.00872022 E^2 - 0.0168694 * E & (11-2) \\
 & - 0.0000615644 A^6 + 0.00219875 A^5 - 0.0292012 A^4 \\
 & + 0.177945 A^3 - 0.483011A^2 + 0.740802 A - 0.0679519 H^4 \\
 & + 0.187047 H^3 - 0.196681 H^2 + 22136.8 D^2 - 33781.8 D \\
 & + 0.381264 I^4 - 3.34419 I^3 + 8.52782 I^2 - 5.26284 I \\
 & + 0.262374 C^2 - 0.628695 C - 0.00000000987981 F^6 \\
 & - 0.00000086429 F^5 + 0.000150924 F^4 - 0.00683017 F^3 \\
 & + 0.137551 F^2 - 1.27352 F
 \end{aligned}$$

Por lo tanto, evaluando las variables tales como número de curvas, numero de calzadas, tipo de calzada, número de cruces, pendiente máxima, largo de la calle, y número de escuelas, podremos realizar una buena predicción de la cantidad de choques de postes que se verá afectado la calle en un año.

Tabla 11-2 Resumen de Errores en predicción

Opción	MSE	opción	MSE
A	1.87605	EAI	1.39916
B	2.4595	EAHB	1.29512
C	2.43749	EAHC	1.28152
D	2.34599	EAHD	1.20311
E	1.58424	EAHF	1.26264
F	2.46677	EAHG	1.22812
G	2.27134	EAHI	1.31332
H	1.73869	EAHDB	1.22111
I	2.09605	EAHDC	1.21721
EA	1.39475	EAHDF	1.19354
EB	1.59036	EAHDG	1.19296
EC	1.56167	EAHDI	1.19154
ED	1.46859	EAHDIB	1.19286
EF	1.56018	EAHDIC	1.17544
EG	1.53498	EAHDIF	1.23722
EH	1.43976	EAHDIG	1.19567
EI	1.58962	EAHDICB	1.17820
EAB	1.39086	EAHDICF	1.10806
EAC	1.38433	EAHDICG	1.12352
EAD	1.31810	EAHDICFB	2.01252
EAF	1.36224	EAHDICFG	1.12427
EAG	1.34343	EAHDICFGB	2.01507
EAH	1.29828		

11.2 Calidad de la predicción

Para encontrar la estructura óptima del modelo matemático se segmentó un 90% del total de muestras obtenidas en este estudio, con la intención de dejar un 10 % en una predicción de datos desconocidos para el modelo matemático. Para llegar a un consenso de calidad de predicción se utilizó el coeficiente de correlación entre el número de choques de postes registro y el pronosticado en ambos grupos de datos, ver Tabla 11-3

Tabla 11-3 Calidad de predicción

	Coeficiente de correlación
Grupo A	0.778
Grupo B	0.558

11.2.1 Predicciones realizadas

Tabla 11-4 Predicciones del modelo matemático con el grupo A

Calle	N° de Curvas	Zona	Calzada	Material Calzada	N° de Cruces	Inclinacion Maxima[°]	Inclinacion Promedio[°]	longitud [km]	N° Escuelas	N° de Choques	Predicción
LOS CASTAÑOS	1	1	1	0.775	4	18.5	10.6	0.336	0	0	0.612
AVENIDA NORUEGA	2	1	2	0.775	5	12.3	7.5	0.657	1	1	1.215
JOSE MORA	0	1	2	0.775	3	13.1	11.8	0.3	0	2	0.261
CHORRILLOS	1	1	1	0.775	4	23	18.1	0.222	0	0	0.520
TIERRAS ROJAS	1	1	1	0.775	1	14.7	9.2	0.263	0	0	0.505
DECIMA	0	1	3	0.750	0	20	16	0.197	0	2	1.527
ERNESTO MAZZEY	1	1	2	0.775	3	15.4	12.7	0.152	0	3	0.723
HELINSKY	1	1	1	0.775	1	8.1	6.2	0.284	1	0	0.841
ALFREDO VARGAS STOLLER	3	1	2	0.775	8	25.1	10.1	0.758	1	2	1.704
CORONEL ROBERTO SOUPER	0	1	2	0.750	4	20.8	15.2	0.454	1	1	1.195
AVENIDA PALAZUELOS	1	1	2	0.750	8	27.2	9.2	0.57	0	1	1.515
MIGUEL SEMIR	2	1	1	0.775	1	19.2	19.1	0.131	0	1	0.687
EL LITRE	3	1	2	0.775	2	28.7	18.4	0.494	0	2	0.720
GUILLERMO MUNNICH	1	1	2	0.750	6	22	11.9	0.734	4	0	0.386
TEMPLEMAN	0	1	1	0.775	9	16.1	10	0.486	0	0	0.814
NAYLOR	0	1	2	0.750	5	24.5	18.6	0.799	0	2	0.824
QUINTA DEL SUR	0	1	3	0.750	2	9.9	4.8	0.342	0	1	1.466
EMERSON	1	1	2	0.750	1	21.9	18.4	0.165	0	1	1.201
FEDERICO COSTA	5	2	1	0.775	1	26.6	11.8	0.553	0	1	1.389

EL SAUCE	0	1	2	0.750	11	4.7	2.4	1.6	0	1	2.576
DEL CABO	0	1	1	0.775	2	20	20.1	0.18	0	1	0.110
BERNARDO RAMOS	1	1	2	0.775	3	28	14.3	0.277	0	0	0.419
CARRERA	0	1	1	0.766	7	15	5.1	0.663	2	0	0.410
ANTICLEA	2	1	2	0.775	0	18.6	14.7	0.117	0	1	0.861
ARTURO PRAT	0	1	1	0.750	3	3.5	1.5	0.83	0	3	1.963
SANTOS TORNERO	1	1	3	0.750	6	21.7	14	0.617	0	1	2.120
MELIPILLA	1	1	1	0.775	0	9.1	4.1	0.234	0	1	0.484
HAMBURGO	0	1	1	0.775	13	14.3	8.1	0.497	0	2	1.797
AVENIDA SANTA ELENA	4	1	1	0.750	6	10.8	6.3	0.803	1	4	2.279

La Tabla 11-4 describe las predicciones realizadas en las 28 primeras calles del grupo A, este presento un índice de correlación de 0.78. Además se realizó el conteo de 10 calles del grupo A, en donde existió un error de predicción de 2 o más choques a postes

Tabla 11-5 Predicciones redel modelo matemático al grupo B

Calle	Nº de Curvas	Zona	Calzada	Material Calzada	Nº de Cruces	Inclinacion Maxima[°]	Inclinacion Promedio[°]	longitud [km]	Nº Escuelas	Nº de Choques	Predicción
AVENIDA BAQUEDANO	5	2	1	0.775	7	26	11.6	1.34	1	3	2.019
ANTONIO VARAS	1	1	2	0.750	2	8.8	4.4	0.374	0	1	1.229
AVENIDA JOSE MARIA CARO	1	1	2	0.775	7	17.6	8.1	0.875	1	1	1.325
IBERIA	2	1	2	0.775	1	22.5	17.1	0.287	0	1	0.760
AV TUPUNGATO	1	1	1	0.775	4	8.2	3.7	1.72	0	2	0.411
JORGE KENRICK	1	1	2	0.775	4	10.3	7.8	0.517	0	1	0.673
VICTOR PIVET	0	1	2	0.775	1	12.9	9.4	0.338	0	1	0.212
AVENIDA SUAREZ	1	1	2	0.775	2	14.6	14.4	0.235	0	1	0.674
RODOLFO PHILIPPI	6	1	2	0.775	3	22	9.4	0.842	0	4	2.067
HUASCO	2	1	3	0.775	5	11.6	7.8	0.45	0	1	1.604
CHACABUCO	0	1	1	0.750	13	2.6	0.9	1.44	1	2	4.419
AVENIDA QUEBRADA VERDE	1	1	1	0.775	7	10.3	8.5	0.899	1	2	1.077
EL BOSQUE	4	1	3	0.750	1	27.7	15.5	0.69	0	1	2.360
RIO BUENO	2	2	2	0.750	3	15.8	10.4	0.444	0	1	1.450
TRINQUETE	8	1	2	0.750	8	27.9	15.9	1.223	0	3	3.424
LAS CAMELIAS	5	1	2	0.775	3	19.2	9.2	0.931	0	1	1.777
BOYACA	3	1	1	0.775	3	15.5	7	0.571	0	1	0.928
SANTO DOMINGO	2	1	2	0.750	1	20.9	14.3	0.32	0	1	1.380
IRENE FREI	2	1	1	0.775	5	23	12.8	0.75	0	1	0.713
PASAJE TREINTA Y DOS	1	1	2	0.775	0	20	20	0.152	0	1	0.675
NECOCHEA	0	1	2	0.775	7	8.7	6.6	0.524	0	0	0.613
JIMÉNEZ	1	1	2	0.775	4	16	10	0.232	0	0	0.777
STA MARÍA	0	1	1	0.775	2	22.3	12	0.247	0	0	0.048

En la tabla 11-5 se presentan las predicciones realizadas con el modelo matemático hacia el grupo B de datos, en este caso se registraron 3 calles que no cumplieron con el rango de a lo menos 2 choques a postes de error.

11.3 Modelo de regresión No Lineal VS Red Neuronal Artificial

A continuación, se presenta los coeficientes de correlación y la cantidad de errores registrados con un rango de aceptación de a lo menos 2 choques a postes para las predicciones realizadas con el modelo matemático determinado con regresiones no lineales y la red neuronal artificial más eficiente configurada.

Tabla 11-6 Modelo matemático VS RNA

	RNA		Modelo No Lineal	
	Grupo A	Grupo B	Grupo A	Grupo B
Coefficiente de correccion	0.85	0.64	0.78	0.56
N° de fallas en predicción	6(3%)	1(4.3%)	10(5%)	3(13%)

Cabe mencionar que el número de calles que registra el grupo de datos A es de 202, y el grupo B de 23. En la tabla 11-6 se puede apreciar la superioridad en predicción, de la red neuronal, esto tanto su eficiencia tanto para un grupo de datos utilizado en su entrenamiento como para uno nuevo en sus registros.

Hay que repetir y aclarar que la configuración de la RNA utilizada en el grupo A es distinta a la utilizada en el grupo B, ya que su eficiencia es inversa para una buena predicción en el grupo A como para el grupo B, estas configuraciones se presentan en el capítulo 8.

Discusión y Conclusiones

El choque a poste se encuentra en primer lugar en el ranking de fallas más comunes en el libro de novedades, por esto la prioridad de los proyectistas en distribución eléctrica de atacar este problema de forma eficaz. Además, el beneficio toma un giro hacia la comunidad, ayudando al proyectista a discernir el mejor trazado y ubicación de los postes en los bienes nacionales del uso público, agregando la disminución de pérdidas humanas con un adecuado tratamiento de calles con un alto riesgo de choques o futuras calles en la cuales se debe evitar el riesgo.

Un futuro uso de este modelo puede traer beneficios tanto a la sociedad chilena como a las distribuidoras eléctricas del país, ya que, teniendo conocimiento del riesgo vigente en las calles, y cuáles son los factores que la describen, proporcionar un adecuado tratamiento para disminuir el riesgo. Aun que el modelo de predicción utilizado se entrenó con experiencias en calles de Valparaíso, esta predicción también será válida en lugares de geografía y urbanismo similar.

En la realización de esta investigación se indagaron distintas técnicas de predicción de choques de postes, las cuales se han aplicado en distintos países con la intención de guiar y adquirir las mejores alternativas vigentes, para solucionar esta problemática. En donde las Redes Neuronales toman un papel importantísimo, como herramienta innovadora, para dar una predicción de eventos y análisis estadísticos, por lo que una sólida obtención y recopilación de variables, es vital para su aprendizaje y entrenamiento.

Inicialmente la primera base de datos trabajada no tuvo un rendimiento óptimo haciendo alusión a lo mencionado anteriormente. Además, debido a que la predicción debe tener una aceptación importante en calles desconocidas para el modelo, se hizo una distribución de la totalidad de experiencias registradas, con un 90% como grupo A, destinadas al entrenamiento, y un 10% como grupo B destinadas a la evaluación de la predicción en calles desconocidas.

Si bien se realizó un ranking de las mejores redes neuronales, y se obtuvo como ganadora la red de una capa oculta y 5 neuronas por capa, con un 48% de error promedio en grupo de datos desconocidos para la red y un 36% error promedio en la predicción con los datos que se entrenó la red, su desempeño no es aceptable, por lo que se propuso las siguientes medidas para disminuir el error de su predicción; en primera instancia un cambio en la división de grupos de datos para la realización del entrenamiento y simulación (grupo A y B), ya que las porciones utilizadas podrían no ser las óptimas para el aprendizaje de la red neuronal, planteando un 90% para un

grupo de entrenamiento, para entregar la mayor cantidad de experiencias al aprendizaje de la red, y el 10% restante para una evaluación de predicción con datos desconocidos para la red; durante el desarrollo quedo demostrado que la obtención de más variables será vital para la disminución del error en las predicciones.

Tras un trabajo de optimización de variables de entradas y detallado el flujo de trabajo, se logró entrenar la mejor Red Neuronal como modelo de predicción de choques a postes para la comuna de Valparaíso, esta consta de un Multi-perceptrón, una función de aprendizaje Gradiente Conjugada, configurada con 1 capas ocultas y 5 neuronas por capa oculta y con funciones de activación Sigmoide en sus capas ocultas y lineal en su capa de salida. Esta fue escogida gracias al coeficiente de correlación de Pearson, el cual permite comparar la salida real con las predicciones realizadas. Debido a que el objetivo del modelo de predicción es pronostica el riesgo de choques a postes en calles desconocidas para la red neuronal, la elección se realizó específicamente en la simulación (grupo B) de la Predicción.

Además, se comprobó la propiedad efectiva de la red neuronal, de considerar o anular variables que aportan o no, al rendimiento de la predicción respectivamente, esto debido a la función que realizan de los sesgos neuronales (umbral) y al tratamiento que se llevó a cabo con las variables de entrada.

Tras usar la librería Keras se pudo comprobar su sencillez y simplicidad al instante de crear y entrenar una RNA, si bien la librería nntool utilizada con Matlab tiene las mismas funciones, esta requiere un mejor procesador para su funcionamiento, lo que retrasa el tiempo de simulación, factores a tomar en cuenta para un futuro estudio. Además, el lenguaje de programación Python, provee al usuario vincular sus códigos de programación con otros softwares para complementar su función principal, por ejemplo, ArcGIS, esta aplicación permite la creación de capas geo-referenciadas que brindan al proyectista una perspectiva, geográfica y visual de la ubicación de calles y sus índices de riesgo. En cuando a las predicciones realizadas por Keras y Nntool, fueron bastante cercanas si se compara el EMC calculado y su coeficiente de correlación, aunque existe una pequeña diferencia causada probablemente por la matriz de peso aleatoria usada inicialmente y el gradiente calculado en cada iteración.

Se logró encontrar un número de variables ideal de entradas que describan el número de choques a postes y califiquen según su influencia en la predicción, lo que traerá beneficios a los proyectistas que deseen utilizar el modelo, opten por recolectar el mínimo número de factores descritos en la calle y así obtener una predicción factible. En la comuna de Valparaíso las variables con mayor peso en la predicción, en orden descendente son; su longitud, número de cruces, número de carriles, número de curvas y la inclinación máxima de la calle. Esto se obtuvo mediante el método de sensibilidad (Método de enfoque de peso en conexión), y posteriormente, comprobó con el entrenamiento de la misma configuración de RNA, aunque solo con las entradas más sensibles, obteniendo un coeficiente de exactitud idéntico a la realizada con el total de variables iniciales. Si se desea utilizar esta misma red neuronal para la predicción en una zona geográficamente distinta la comuna de Valparaíso, se recomienda realizar una reconfiguración de la red neuronal y por lo tanto un nuevo análisis de sensibilidad de sus variables de entradas.

Esto debido a la interpretación que toma la red neuronal del evento (registro de choques en calles) dependiendo de la zona del muestreo.

Una alternativa tentativa a utilizar para realizar predicciones del riesgo presente en las calles, fue la de plantear un modelo matemático en base de regresiones, por lo que se desarrolló con éxito y una predicción bastante buena, con un bajo error y un coeficiente de correlación 0.56 en referencia al registro real de choques por calle, pero esta no alcanzo el rendimiento que puede alzar una adecuada configuración de RNA, la cual registró un 0.64 de coeficiente de correlación y un 4.3% de casos (calles) fuera del rango mínimo de predicción, de a lo menos 2 choques a postes.

Finalizando, se confirmó fehacientemente que los choques vehiculares a postes de tendidos eléctricos, no califican como sucesos estocásticos, sino como eventos directamente relacionados con las características del entorno donde está situado, esto se verificó con la calidad de las predicciones obtenidas, al utilizar factores descriptivos del habitat del poste (calles). Gracias a esto, el proyectista ya podrá tener certeza al momento de discriminar en que calle instalar o no el poste. Así la problemática ya puede ser tratada eficientemente, con un 93.7% de probabilidad de acertar en la predicción, con un rango de aceptación de 2 choques a postes.

12 Bibliografía

- [1] Dibam, «dibam,» [En línea]. Available: www.memoriachilena.cl. [Último acceso: 10 abril 2018].
- [2] Gagne, Amanda, «Evaluation of Utility Pole Placement and the Impact on Crash Rates,» WORCESTER POLYTECHNIC INSTITUTE, 2008.
- [3] Olabe, Xabier Basogain, «Redes Neuronales Artificiales: Un enfoque Práctico.,» Escuela superior de Ingeniería de Bilbao, EHU.
- [4] Godoy, Mauricio Roberto Rojas, «Predicción de Accidentes de Tránsito Utilizando Redes Neuronales Artificiales y Cuckoo Search,» PUCV, Valparaiso, 2015.
- [5] Castraño, Samuel Ramires, *Redes de Distribución de Energía*, Colombia, 2015.
- [6] Comisión Nacional de Seguridad del Tránsito, «CONASET,» [En línea]. Available: <https://www.conaset.cl/programa/observatorio-datos-estadistica/biblioteca-observatorio/estadisticas-generales/>. [Último acceso: 2018 abril 17].
- [7] Comisión Nacional de Energía, *Norma Técnica de Calidad de Servicio para Sistemas de Distribución*, Valparaiso, 2017.
- [8] Chilquinta, «puntos de fallas,» 2016-2018.
- [9] M.C. Good, J.C.Fox y P.N. Joubert, «Estudio en Profundidad de Accidentes Relacionados a Colisiones de Postes,» Departamento de Ingeniería Industrial y Mecánica, Universidad de Melbourne, Parkville, Australia, 1986.
- [10] Deb., Xin-She Yang y suash, «Cuckoo Search via Levy Flights,» IEEE Publications, 2009.
- [11] Sorenson M.D. Payne, R.B. and K. Klitz., «the Cuckoos,» Oxford University Press, 2005.

-
- [12] Gurrea, Manuel Terrádez, «Análisis de Componentes Principales,» UOC.
- [13] Bohte, Marcel Van Gerven and Sander, Artificial Neural Networks as Models of Neutral Information Processing, *front.comput.Neurisci*.doi:10.3389/fncom.2017.001114, 2017.
- [14] Matlab, «Mathworks,» [En línea]. Available: <https://la.mathworks.com/solutions/deep-learning/convolutional-neural-network.html#matlab>. [Último acceso: 26 07 2018].
- [15] Anaconda.org, «Anaconda Cloud,» [En línea]. Available: <https://anaconda.org/anaconda/spyder>. [Último acceso: 08 Agosto 2018].
- [16] Escolano, Fransisco, Inteligencia artificial, Paraninfo, 2003.
- [17] Product Itoworld, «Mapa de Ito,» [En línea]. Available: <http://product.itoworld.com/map/6?lon=-0.01120&lat=-0.01045&zoom=13>. [Último acceso: 2 9 2018].
- [18] openstreetmap, «Open Street Map Wiki,» [En línea]. Available: https://wiki.openstreetmap.org/wiki/Ito_Map. [Último acceso: 11 10 2018].
- [19] Comisión Nacional de Seguridad de Tránsito, «Normativa Relacionada con Velocidad,» [En línea]. Available: <https://www.conaset.cl/normativa-velocidad/>. [Último acceso: 16 10 2018].
- [20] Reconstructor Analítico Colisiones de Tránsito Terrestre, «Posibles Valores de Factores de Rozamiento del Pavimento para Neumáticos de Goma,» [En línea]. Available: <https://causadirecta.com/especial/calculo-de-velocidades/tablas/tabla-de-factores-de-rozamiento-del-pavimento-para-neumaticos-de-goma>. [Último acceso: 17 10 2018].
- [21] MathLab, «MathWorks,» [En línea]. Available: <https://la.mathworks.com/help/deeplearning/ug/multilayer-neural-networks-and-backpropagation-training.html>. [Último acceso: 18 10 2018].
- [22] Jordy Torres, «Jordy Torres.IA,» [En línea]. Available: <https://torres.ai/primeros-pasos-en-keras/>. [Último acceso: 06 12 2018].
- [23] Julian D. Olden, Michael K. Joy y Russell G. Deth, «una comparación precisa de los métodos para cuantificar la importancia de una variable en RNA utilizando datos simulados,» [En línea]. Available: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.576.9814&rep=rep1&type=pdf>. [Último acceso: 07 Diciembre 2018].

- [24] Gange, Amanda, «Evaluación de Colocación de Poste de Utilidad y el Impacto en las tasas de Colisión,» Worcester Polytechnic Institute, Estados Unidos, 2008.
- [25] G. maps, «Google Street View,» [En línea]. [Último acceso: 2018 abril 24].
- [26] L. Orrego, «Diban,» [En línea]. Available: [http://www.dibam.cl/Recursos/Contenidos/Museo%20Hist%C3%B3rico%20Nacional/archivos/Llegada%20de%20la%20electricidad%20a%20Chile%20\(Febrero%20de%201883\).pdf](http://www.dibam.cl/Recursos/Contenidos/Museo%20Hist%C3%B3rico%20Nacional/archivos/Llegada%20de%20la%20electricidad%20a%20Chile%20(Febrero%20de%201883).pdf). [Último acceso: 2018 abril 20].
- [27] S. Fingerhuth, «Integridad académica,» Pontificia Universidad Católica de Valparaíso, Julio 2014. [En línea]. Available: <http://integridadacademica.cl/>. [Último acceso: 20 10 2015].
- [28] E. P. Wigner, «Theory of traveling wave optical laser,» *Phys. Rev.*, vol. 134, pp. A635-A646, 1965.
- [29] E. T. J. van Weert and R. K. Munro, «Informatics and the Digital Society: Social, ethical and cognitive issues: IFIP TC3/WG3.1&3.2 Open Conference on Social,» de *Ethical and Cognitive Issues of Informatics and ICT*, Dortmund, Germany, 2003.
- [30] M. Shell, «Preparation of papers for IEEE TRANSACTION and JOURNALS,» May 2007.
- [31] A. G. Tsipkin, V. Vodnev, G. G. Tsipkin y A. I. Samojv, *Fórmulas matemáticas: álgebra, geometría, análisis matemático.*, Mir, 1998.
- [32] Oficina Internacional de Pesas y Medidas, «El Sistema Internacional de Unidades SI,» 2006. [En línea]. Available: http://www2.cem.es:8081/cem/es_ES/documentacion/generales/SIU8edes.pdf. [Último acceso: 2 January 2015].
- [33] MiniTabs, «Soporte de Minitabs,» [En línea]. Available: <https://support.minitab.com/es-mx/minitab/18/help-and-how-to/modeling-statistics/regression/supporting-topics/nonlinear-regression/understanding-nonlinear-regression/>. [Último acceso: 7 Febrero 2018].
- [34] alaniuu, «slideshare,» [En línea]. Available: <https://es.slideshare.net/alaniuu/macroformas-de-chile-region-por-region>. [Último acceso: 14 abril 2018].
- [35] Alexander, C. K.; Sadiku, M.N.O., *Circuits, Fundamentals of Electric*, McGraw-Hill College, 2003.

- [36] Terminal de Buses, *Micro Del TMV De Valparaíso Chocó Con Un Poste En Caleta El Membrillo*, pp. <http://www.terminaldebuses.com/2012/04/micro-del-tmv-de-valparaiso-choco-con-un-poste-en-caleta-el-membrillo/>, 3 abril 2012.
- [37] Chilquinta, «www.chilquinta.cl,» [En línea]. Available: <https://www.chilquinta.cl/mi-hogar/nosotros/seccion/41/historia-chilquinta-energia-sa.html>. [Último acceso: 2018 abril 24].
- [38] Council, Applied Technology, Earthquake damage evaluation data for California. Technical report, Seismic Safety Commission, Applied Technology Council (ATC), California, 1995.