

UNIVERSIDAD NACIONAL DE SAN CRISTÓBAL DE
HUAMANGA

FACULTAD DE INGENIERÍA DE MINAS GEOLOGÍA Y CIVIL

ESCUELA PROFESIONAL DE INGENIERÍA CIVIL



DISEÑO DE UN MODELO METAHEURÍSTICO PARA LA
DETERMINACIÓN DE CAUDALES DE MÁXIMA AVENIDA
EN CUENCAS URBANAS

TESIS:

PARA OPTAR EL TÍTULO PROFESIONAL DE INGENIERO CIVIL

ELABORADO POR:

OIVER EDWAR CALDERÓN PILLACA

ASESOR:

ING. EDMUNDO CANCHARI GUTIÉRREZ

AYACUCHO - PERÚ

AGOSTO, 2016

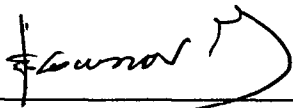
“DISEÑO DE UN MODELO METAHEURÍSTICO PARA LA DETERMINACIÓN DE CAUDALES DE MÁXIMA AVENIDA EN CUENCAS URBANAS”

RECOMENDADO : 21 DE JUNIO DE 2016

APROBADO : 19 DE AGOSTO DE 2016



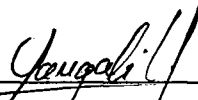
Ing. JAIME L. BENDEZU PRADO
(PRESIDENTE)



Ing. EDWARD LEON PALACIOS
(MIEMBRO)

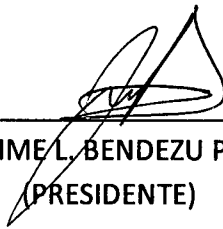


Ing. EDMUNDO CANCHARI GUTIERREZ
(MIEMBRO)

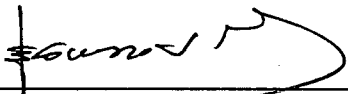


Ing. FLORO N. YANGALI GUERRA
(SECRETARIO DOCENTE)

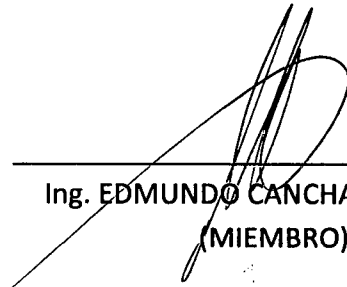
Según el acuerdo constatado en el Acta, levantado el 19 de Agosto de 2016, en la sustentación de la Tesis presentado por el Bachiller en Ciencias de la Ingeniería Civil Sr. **OIVER EDWAR CALDERÓN PILLACA**, con la Tesis Titulado "**DISEÑO DE UN MODELO METAHEURÍSTICO PARA LA DETERMINACIÓN DE CAUDALES DE MÁXIMA AVENIDA EN CUENCAS URBANAS**", fue calificada con la nota de DIECISÉIS (16) por lo que se da la respectiva APROBACIÓN.



Ing. JAIME L. BENDEZU PRADO
(PRESIDENTE)



Ing. EDWARD LEON PALACIOS
(MIEMBRO)



Ing. EDMUNDO CANCHARI GUTIERREZ
(MIEMBRO)



Ing. FLORO N. YANGALI GUERRA
(SECRETARIO DOCENTE)

DISEÑO DE UN MODELO METAHEURÍSTICO PARA LA DETERMINACIÓN
DE CAUDALES DE MÁXIMA AVENIDA EN CUENCAS URBANAS

OIVER EDWAR CALDERÓN PILLACA

Presentado a la Escuela Profesional de Ingeniería Civil de la Facultad de
Ingeniería de Minas, Geología y Civil, en cumplimiento parcial de los
requerimientos para obtener el título de:

INGENIERO CIVIL

2016

Autor : Oiver Edwar Calderón Pillaca
Recomendado : Ing. Edmundo Canchari Gutiérrez
Asesor de Tesis
Aceptado por : M.Sc. Ing. Carlos Prado Prado
Decano de la FIMGC

© 2015; Universidad Nacional de San Cristóbal de Huamanga (UNSCH), todos los
derechos reservados. El autor de la investigación autoriza a la UNSCH - Facultad de
Ingeniería de Minas, Geología y Civil (FIMGC), la reproducción de la tesis en su
totalidad o en partes.

En especial a mis padres Fidel y Anselma, a mi hermano Víctor, a mi esposa Nelly Berrocal Ventura.

Agradecimientos

A la Universidad Nacional de san Cristóbal de Huamanga, centro de mi formación profesional. A la Facultad de Ingeniería de Minas, Geología y Civil. A todos los docentes de la prestigiosa Escuela de la Ingeniería Civil.

UNIVERSIDAD NACIONAL DE SAN CRISTÓBAL DE HUAMANGA.

Ayacucho, 19 de agosto de 2016.

Oiver Edwar Calderón Pillaca.

Índice general

Dedicatoria	II
Agradecimientos	III
Índice general	IV
Índice de tablas	VIII
Índice de figuras	IX
Resumen	XI
Introducción	1
1. Generalidades	2
1.1. Introducción	2
1.2. Planteamiento del Problema	3
1.2.1. Antecedentes	3
1.2.2. Problema	5
1.2.2.1. Problema Central	5
1.2.2.2. Problema Específicos	5
1.2.3. Objetivos	5
1.2.3.1. Objetivo General	5
1.2.3.2. Objetivo Específico	6
1.2.4. Hipótesis	6

1.2.4.1.	Hipótesis General	6
1.2.4.2.	Hipótesis Específico	6
1.2.5.	Justificación	7
1.2.6.	Metodología y Plan de trabajo	7
2.	Marco teórico y marco conceptual, desarrollo de la teoría y variable	9
2.1.	Sistemas de información geográfica	9
2.1.1.	Fundamentos de los SIG	10
2.1.2.	Representación de datos	11
2.1.2.1.	Modelos raster	11
2.1.2.2.	Modelos vectoriales	12
2.1.3.	Sistemas de referencia	13
2.2.	Cuencas hidrográficas	15
2.3.	Método racional	16
2.3.1.	Limitaciones del método racional	17
2.3.2.	Coefficiente de escorrentía	18
2.3.2.1.	Coefficiente de escorrentía para cuencas rurales	19
2.3.2.2.	Coefficiente de escorrentía para cuencas urbanas	19
2.3.3.	Coefficiente de escorrentía ponderado	20
2.3.4.	Tiempo de concentración en cuencas	21
2.3.5.	Análisis Estadístico de las curvas IDF	22
2.4.	Redes neuronales artificiales	23
2.4.1.	Fundamentos biológicos de las RNA	24
2.4.2.	Modelo Artificial de las Redes Neuronales Biológicas	25
2.4.3.	Evolución histórica	27
2.4.4.	Clasificación de las RNA	27
2.4.5.	Arquitectura de RNA de base radial	29
2.4.6.	Elementos de la neurona artificial	30
2.4.7.	Funciones de entrada, activación y de transferencia	31
2.4.8.	Algoritmos y paradigmas de aprendizaje	33

2.4.9.	Método de aprendizaje híbrido	34
2.4.10.	Evaluación del aprendizaje	36
3.	Desarrollo del trabajo de la tesis	37
3.1.	Generación de los registros	37
3.1.1.	Drenaje pluvial urbano OS.060	38
3.1.2.	Registro de los coeficientes de escorrentía	38
3.1.3.	Intensidad de la precipitación	39
3.1.4.	Superficie de drenaje	43
3.1.5.	Caudales máximos	43
3.2.	Diseño del modelo ANNMF	44
3.2.1.	Registros de entrenamiento, validación y prueba final	45
3.2.2.	Arquitectura del modelo ANNMF	47
3.2.2.1.	Capa de entrada	47
3.2.2.2.	Capa oculta	47
3.2.2.3.	Capa de salida	48
3.2.2.4.	Arquitectura seleccionada	49
3.2.3.	Parámetros iniciales	49
3.2.4.	Proceso de aprendizaje	50
3.2.5.	Evaluación del aprendizaje	51
3.2.6.	Validación del modelo	54
3.2.7.	Prueba final (test)	54
4.	Análisis de los resultados	56
4.1.	Resultados obtenidos	56
4.1.1.	Modelo ANNMF	56
4.1.2.	Arquitectura del modelo ANNMF	57
4.1.2.1.	Capa de entrada	57
4.1.2.2.	Capa oculta	58
4.1.2.3.	Capa de salida	58

4.1.3.	Funciones de entrada, activación y de transferencia	58
4.1.4.	Parámetros	59
4.1.4.1.	Centros de los funciones de base radial	59
4.1.4.2.	Amplitud de las funciones de base radial	60
4.1.4.3.	Pesos de las conexiones	60
4.1.4.4.	Umbrales	60
4.1.5.	Limitaciones del modelo ANNMF	60
4.2.	Análisis del modelo ANNMF	62
4.2.1.	Confiabilidad	62
4.2.2.	Validez	63
4.2.3.	Objetividad	64
4.3.	Aplicación práctica	64
5.	Conclusiones y recomendaciones	66
5.1.	Conclusiones	66
5.2.	Recomendaciones	67
	Referencias bibliográficas	68
	Anexo A. Código fuente MATLAB	73
A.1.	Generación de coeficientes de escorrentía	73
A.2.	Generación de tiempos de concentración	74
A.3.	Generación del periodo de retorno	74
A.4.	Generación de las superficies	75
A.5.	Datos de entrenamiento, validación y prueba	76
A.6.	Entrenamiento del modelo	77
A.7.	Validación gráfica	78
A.8.	Prueba final	80
	Anexo B. Planos	83

Índice de tablas

2.1. Coeficiente de escorrentía zonas urbanas	19
2.2. Evolución de las RNA 1910-1970	26
2.3. Evolución de las RNA 1970-2000	27
3.1. Coeficientes de escorrentía generados aleatoriamente	39
3.2. Parámetro regional b	40
3.3. Duración de la precipitación (horas)	41
3.4. Tiempos de retorno (años)	42
3.5. Intensidades de precipitación	43
3.6. Superficies de cuencas (en km^2)	44
3.7. Caudales de máxima avenida	45
3.8. Registros de entrenamiento, validación y prueba	46
3.9. Arquitectura seleccionada	49
4.1. Centro de las funciones de base radial del ANNMF	59
4.2. Pesos de las conexiones	61
4.3. Coeficientes de confiabilidad	62
4.4. Fuente: Elaboración propia	62
4.5. Caudales máximos y mínimos	63
4.6. Caudales obtenidos	64

Índice de figuras

2.1. Información en capas temáticas	10
2.2. Representación ráster y vectorial, a) representación vectorial. b) representación ráster	12
2.3. Conversión de ráster a vectorial	13
2.4. Las tres familias de proyecciones cartográficas. Pueden ser representadas por a) proyecciones cilíndricas, b) proyecciones cónicas o c) proyecciones planas.	14
2.5. Cuenca hidrográfica.	15
2.6. Coeficiente de escurrimiento cuencas urbanas	20
2.7. Red neuronal biológica	23
2.8. Neurona biológica y elementos a detalle	24
2.9. Neurona biológica y elementos básicos	26
2.10. Clasificación de las RNA de acuerdo al algoritmo de aprendizaje utilizado	28
2.11. Red neuronal artificial de base radial	29
2.12. Neurona artificial	30
2.13. Funciones de activación de base radial	32
2.14. Métodos de aprendizaje de las RNA	33
3.1. Arquitectura general de redes neuronales artificiales de base radial . . .	48
3.2. Implementación para la etapa de entrenamiento desde MATLAB	50
3.3. Variación del error cuadrático medio (20 neuronas en la capa oculta) .	52
3.4. Variación del error cuadrático medio (22 neuronas en la capa oculta) .	52

3.5. Variación del error cuadrático medio (dependencia de la variación del número de neuronas de la capa oculta)	53
3.6. Etapa de validación del modelo	54
3.7. Prueba final	55
4.1. Arquitectura del modelo ANNMF	57

Resumen

El propósito de la investigación es diseñar un modelo meta-heurístico basado en las redes neuronales artificiales de base radial para la determinación de los caudales de máxima avenida en cuencas urbanas y proyectos de drenaje pluvial en general, se sigue un enfoque de investigación cuantitativa y su alcance está definido como correlacional, basado en una fundamentación sobre el conocimiento teórico necesario, los datos y resultados requeridos para el diseño del modelo son generados en base al método racional; el modelo obtenido, ANNMF (Artificial Neural Network and Maximum Flow), es evaluado a nivel de confiabilidad, validez y objetividad, encontrando indicadores adecuados; se tiene especial consideración en la selección adecuada del número de neuronas en la capa oculta, varios modelos responden adecuadamente evaluados teniendo en cuenta el error cuadrático medio, sin-embargo, son incapaces de reproducir los registros reservados en la etapa de entrenamiento y etapa de prueba final, los componentes del modelo de la capa de entrada y la capa de salida se encuentran condicionados al fenómeno físico analizado.

Palabras clave: caudal, ANN, RNA

Introducción

Se desarrolla, diseña un modelo de redes neuronales artificiales de base radial para la determinación de caudales de máxima avenida para proyectos de drenaje pluvial en general, el modelo ANNMF (Artificial Neural Network an Maximun Flow) es una alternativa al método racional para la generación de caudales de máxima avenida, basado en las recomendaciones y limitaciones establecidas por el Reglamento Nacional de Edificaciones, en consideración a los datos de ingreso se explora distintas alternativas, tomando en cuenta el uso del suelo de la cuenca analizada, que queda expresado en el coeficiente de escorrentía, tomando distintos periodos de retorno, duraciones de las precipitaciones variadas, pero siempre equivalentes al tiempo de concentración de la cuenca, teniendo en cuenta el uso generalizado del método racional en la obtención de los caudales de máxima avenida y sus argumentos de ingreso, cuando no se dispone de registros pluviográficos, necesariamente se emplea los registros pluviométricos, obteniendo las intensidades requeridas en base a modelos que muchas veces no refleja la realidad física. Los modelo de redes neuronales artificiales da la posibilidad de explorar otras alternativas para los datos requeridos, como alternativa, no requerir de las intensidades de las precipitaciones para una duración igual al tiempo de concentración de la cuenca, sino ingresar de argumento directamente la precipitación para un tiempo de retorno dado; además, en el territorio nacional es posible encontrar estaciones pluviométricas más a menudo y muy pocas estaciones pluviográficas. La fundamentación teórica se basa en los modelos de redes neuronales artificiales, incidiendo particularmente en los modelos de base radial.

Capítulo 1

Generalidades

El presente capítulo contiene las generalidades del desarrollo del trabajo: importancia del tema desarrollado, antecedentes, planteamiento del problema objetivos e hipótesis, tipo y alcance de investigación.

1.1. Introducción

En el presente trabajo se diseñará un modelo específico para la determinación de caudales de máxima avenida en cuencas urbanas, mediante la aplicación de modelos clasificados dentro de la inteligencia artificial, específicamente se tomarán los modelos de redes neuronales artificiales en su arquitectura correspondiente al PERCEPTRON multicapa; el modelo basado en Redes Neuronales Artificiales (RNA) se desarrolla como una alternativa a los muchos modelos existentes, clasificados como modelos determinísticos e empíricos, el modelo diseñado en el desarrollo de la tesis será de aplicación general a toda cuenca urbana, con fines de uso en proyectos del diseño estructuras hidráulicas en drenajes pluviales, como lo establece el Reglamento Nacional de Edificaciones. La aplicación práctica del modelo se efectuará en una cuenca de la ciudad de Ayacucho (Distrito de Carmen Alto).

1.2. Planteamiento del Problema

1.2.1. Antecedentes

Los modelos de redes neuronales artificiales es una metodología que imita el aprendizaje humano, razón por el cual es aplicado en todas las áreas del conocimiento del hombre, muchos estudios en todo el mundo se esfuerzan en diseñar modelos específicos para cada propósito, alguno de ellos se menciona seguidamente:

- El artículo *Aplicación de Redes Neuronales Artificiales a la Modelización y Previsión de Caudales Medios Mensuales del Río Huancané*, publicado por la Revista Peruana Geo-Atmosférica en el año 2010, cuyos autores Wilber fermín Laqui Vilca, obtiene un modelo basado en redes neuronales artificiales específicamente para la previsión de caudales medios mensuales aplicado al río Huancané y concluye: Los modelos de redes neuronales artificiales desde la previsión de caudales medios mensuales muestran un excelente comportamiento en términos de las estadísticas de los errores de previsión; más aún cuando de manera comparativa con un modelo autorregresivo periódico de primer orden-PAR muestra grados superiores de eficiencia en las previsiones, ya que presenta un porcentaje de ajuste de 72 %, en comparación al 59 % que presenta el modelo de serie de tiempo estocástica.
- Otro artículos titulado *Red Neuronal aplicada a la generación de caudales mensuales estocásticos*, publicado por el *XII Congreso de la Sociedad Peruana de Computación* en el año 2013, cuyos autores José Herrena Quispe y otros, trabajos en los que concluyen - Los modelos construidos para las diferentes configuraciones de la Red Neuronal reproducen las principales características estadísticas de la serie temporal histórica. Tal semejanza se entiende en el sentido estadístico. Esto no quiere decir que una serie generada basada en el modelo tiene que tener exactamente las mismas características, como se muestra en el registro histórico. Por desgracia, no es fácil saber qué características deben ser reproducidos por

el modelo y cómo estas características deben ser interpretadas. Esto se atribuye principalmente al hecho de que las series hidrológicas son representadas en muestras anuales, y las verdaderas características estadísticas de población no son conocidas. Otro problema es la definición y la interpretación de las características estadísticas derivadas de la muestra. Por lo general, la media y la desviación estándar son las características de menos incerteza. Por el contrario, la asimetría es muy incierta y su importancia depende de la aplicación de la serie hidrológica generada. Del mismo modo, la autocorrelación es muy incierta, especialmente para pequeños tamaños de muestra.

- El proyecto libro digital titulado *Pronóstico de caudales medios mensuales del río Caplina, aplicando redes neuronales artificiales (rna) y modelo autorregresivo periódico de primer orden par (1)*, publicado en *Encuentro Científico Internacional revista ACIPERU* en el año 2012, cuyos autores Pino Vargas Edwin y otros, obtienen modelos específicos mediante redes neuronales artificiales para el pronóstico de caudales medios mensuales y concluyen -Las redes neuronales artificiales desde el punto de vista de predicción o pronóstico de caudales mensuales, muestra un comportamiento excelente en términos de las estadísticas de los errores de predicción; mas aun cuando de manera comparó con un modelo autorregresivo periódico de primer orden - PAR (1), mostrando un grado superior de eficiencia en las predicciones realizadas, ya que presentan porcentajes de ajuste superiores al 80 %, en comparación al 62 % que presenta el modelo de serie de tiempo estocástica.

Tomando como trabajos previos las citadas con anterioridad, se creará un modelo específico para obtener los caudales correspondientes a eventos extremos en cuencas hidrográficas urbanas.

1.2.2. Problema

1.2.2.1. Problema Central

¿Cómo plantear un diseño metaheurístico basado en redes neuronales artificiales para la determinación de caudales de máxima avenida en cuencas urbanas?

1.2.2.2. Problema Específicos

- ¿Es necesario obtener los parámetros morfométricos de la cuenca hidrográfica en el proceso de diseño del modelo metaheurístico para la determinación de caudales de máxima avenida en cuencas urbanas?.
- ¿Cómo influye la intensidad de la precipitación en un modelo metaheurístico basado en redes neuronales artificiales para la determinación de caudales de máxima avenida en cuencas urbanas?.
- ¿Cómo influye el coeficiente de escurrimiento en el modelo metaheurístico basado en redes neuronales artificiales para la determinación de caudales de máxima avenida en cuencas urbanas?.
- ¿Cual es el grado de aproximación de los resultados obtenidos mediante el modelo del método racional y las obtenidas mediante el modelo metaheurístico basado en redes neuronales artificiales?.

1.2.3. Objetivos

1.2.3.1. Objetivo General

Diseñar un modelo metaheurístico basado en redes neuronales artificiales para la determinación de caudales de máxima avenida en cuencas urbanas.

1.2.3.2. Objetivo Específico

- Obtener las características morfométricas de la cuenca hidrográfica como parámetros primordiales en el diseño del modelo metaheurístico para la determinación de caudales de máxima avenida en cuencas urbanas.
- Evaluar la influencia de la precipitación durante la ocurrencia de la intensidad en un modelo metaheurístico basado en redes neuronales artificiales para la determinación de caudales de máxima avenida en cuencas urbanas.
- Determinar la influencia del coeficiente de escurrimiento en el modelo metaheurístico basado en redes neuronales artificiales para la determinación de caudales de máxima avenida en cuencas urbanas.
- Contrastar los resultados obtenidos mediante el modelo del método racional y las obtenidas mediante el modelo metaheurístico basado en redes neuronales artificiales.

1.2.4. Hipótesis

1.2.4.1. Hipótesis General

El modelo metaheurístico basado en redes neuronales artificiales permitirá determinar caudales de máxima avenida en cuencas urbanas.

1.2.4.2. Hipótesis Específico

- La superficie de la cuenca hidrográfica es fundamental en el diseño del modelo metaheurístico para la determinación de caudales de máxima avenida en cuencas urbanas.

- La intensidad de la precipitación en un modelo metaheurístico basado en redes neuronales artificiales para la determinación de caudales de máxima avenida en cuencas urbanas es primordial y forma parte de los datos requeridos por el modelo.
- El coeficiente de escurrimiento en el modelo metaheurístico basado en redes neuronales artificiales para la determinación de caudales de máxima avenida en cuencas urbanas es necesaria, forma parte de los datos requeridos por el modelo.
- Los resultados obtenidos mediante el modelo del método racional y las obtenidas mediante el modelo metaheurístico basado en redes neuronales artificiales son equivalentes.

1.2.5. Justificación

El desarrollo de la tesis propuesta es necesaria por las siguientes razones: se implementa un modelo alternativo basado en procedimientos de inteligencia artificial, específicamente se utiliza las redes neuronales artificiales para el diseño de un modelo específico para la determinación de caudales de máxima avenida en cuencas urbanas -modelo que es una alternativa a los muchos modelos empíricos existentes, por tanto, esta razón la justifica técnicamente; se justifica de igual manera porque constituye un aporte en los proyectos concernientes a la defensa contra eventos extremos de precipitaciones, ya que los resultados del modelo son requeridos para diseños de las estructuras hidráulicas con fines de evacuación de los caudales generados por las precipitaciones -comunmente conocido como sistemas de drenaje pluvial, ésta particularidad constituye una justificación social.

1.2.6. Metodología y Plan de trabajo

La tesis, teniendo en cuenta el enfoque de investigación, se encuentra clasificada dentro del enfoque cuantitativo, para ello se requiere un método formal de investigación

de carácter cuantitativo, en la que la recolección de los datos es de tipo numérico, estandarizado y cuantificable mediante los procedimientos estadísticos.

En el plan de trabajo se tiene el siguiente procedimiento:

- Inicia con la documentación de la fundamentación teórica de los temas requeridos para el desarrollo de la tesis, específicamente el método racional y el método de las redes neuronales artificiales.
- Desarrollo de la tesis correspondiente al capítulo de materiales y métodos, la delimitación de la zona de estudio mediante la aplicación de sistemas de información geográfica y la determinación de los parámetros morfométricos necesarios, determinación de los usos del suelo y el diseño del modelo para la determinación de caudales de máxima avenida en cuencas urbanas mediante modelos metaheurísticos.
- Análisis del modelo obtenido, sujetos al análisis de la confiabilidad, validez y objetividad y la contrastación de los resultados con otros modelos empíricos.

Capítulo 2

Marco teórico y marco conceptual, desarrollo de la teoría y variable

En el presente capítulo se presenta la fundamentación teórica necesaria para el desarrollo de la tesis, trata sobre los sistemas de información geográfica, las cuencas hidrográficas, el método racional para la determinación de caudales de máxima avenida y las redes neuronales artificiales.

2.1. Sistemas de información geográfica

Un Sistema de Información Geográfica ¹ (SIG o GIS, en su acrónimo inglés [Geographic Information System]) es una integración organizada de hardware, software y datos geográficos diseñada para capturar, almacenar, manipular, analizar y desplegar en todas sus formas la información geográficamente referenciada con el fin de resolver problemas complejos de planificación y de gestión.

¹Tomado desde <https://langleruben.wordpress.com/>


2.1.1. Fundamentos de los SIG

Un SIG [3] es un software específico que permite a los usuarios crear consultas interactivas, integrar, analizar y representar de una forma eficiente cualquier tipo de información geográfica referenciada asociada a un territorio, conectando mapas con bases de datos.

El uso de este tipo de sistemas [9] facilita la visualización de los datos obtenidos en un mapa con el fin de reflejar y relacionar fenómenos geográficos de cualquier tipo, desde mapas de carreteras hasta sistemas de identificación de parcelas agrícolas o de densidad de población. Además, permiten realizar las consultas y representar los resultados en entornos web y dispositivos móviles de un modo ágil e intuitivo, con el fin de resolver problemas complejos de planificación y gestión, conformándose como un valioso apoyo en la toma de decisiones.

Los fundamentos de los sistemas de información geográfica se basan en:

Figura 2.1: Información en capas temáticas



Fuentes: Tomado desde <http://volaya.github.io>

1. Localización: preguntar por las características de un lugar concreto.
2. Condición: el cumplimiento o no de unas condiciones impuestas al sistema.
3. Tendencia: comparación entre situaciones temporales o espaciales distintas de alguna característica.

4. Rutas: cálculo de rutas óptimas entre dos o más puntos.
5. Pautas: detección de pautas espaciales.
6. Modelos: generación de modelos a partir de fenómenos o actuaciones simuladas.

El campo de aplicación de los sistemas de información geográfica [33] es muy amplio, en el presente trabajo su uso será exclusivamente en la determinación de las cuencas hidrográficas.

2.1.2. Representación de datos


Los sistemas de información geográfica [39, 34, 34] representa la información por capas, de la misma forma que representa la figura 2.1. Se basa en el uso de dos tipos de archivos: archivos tipo ráster y vectoriales.

2.1.2.1. Modelos raster

En el modelo ráster, la zona de estudio [12, 35, 46] se divide de forma sistemática en una serie de unidades mínimas (denominadas habitualmente celdas), y para cada una de estas se recoge la información pertinente que la describe. Se puede ver esto en detalle en la figura 2.2 -b, que muestra aumentada una porción la malla ráster de elevaciones de la figura 2.2 -a, de modo que los límites de las celdas se hacen patentes y puede además representarse en cada una de ellas su valor asociado.

Los archivos tipo ráster [11, 16] están formados por celdas que forman una matriz de una determina cantidad de filas y columnas, al tamaño de una celda específica se le conoce como resolución de los archivos ráster, son usualmente, para la representación de las alturas sobre el nivel del mar, celdas cuadradas de $axb m^2$, donde a y b representan los lados de la celda. Los archivos ráster [37, 30] están formadas por celdas de la misma resolución y cada celda contiene información específica.

Figura 2.2: Representación ráster y vectorial, a) representación vectorial. b) representación ráster



Fuentes: Tomado desde <http://volaya.github.io>

2.1.2.2. Modelos vectoriales


El otro modelo principal de representación [6, 36, 18] es el modelo vectorial. En este modelo, no existen unidades fundamentales que dividen la zona recogida, sino que se recoge la variabilidad y características de esta mediante entidades geométricas, para cada una de las cuales dichas características son constantes. La forma de estas entidades (su frontera), se codifica de modo explícito, a diferencia del modelo ráster, donde venía implícita en la propia estructura de la malla.

Los modelos vectoriales [31, 41] representan los objetos del mundo real mediante elementos geométricos: puntos, líneas, polígonos.

- Mediante los puntos queda representado elementos particulares, como las estaciones meteorológicas, ubicaciones de las estructuras hidráulicas, estaciones de monitoreo en general, etc.
- Mediante los elementos lineales son representados las vías (caminos), redes hidrológicas y todo aquel elementos que puede ser representado tomando como propiedad primordial su longitud.
- Las superficies están encerradas por polígonos, puede representar alta variedad

de elementos, en lo referente a la hidrología determina las cuencas hidrográficas.

Figura 2.3: Conversión de ráster a vectorial



Fuentes: Tomado desde <http://volaya.github.io>

2.1.3. Sistemas de referencia

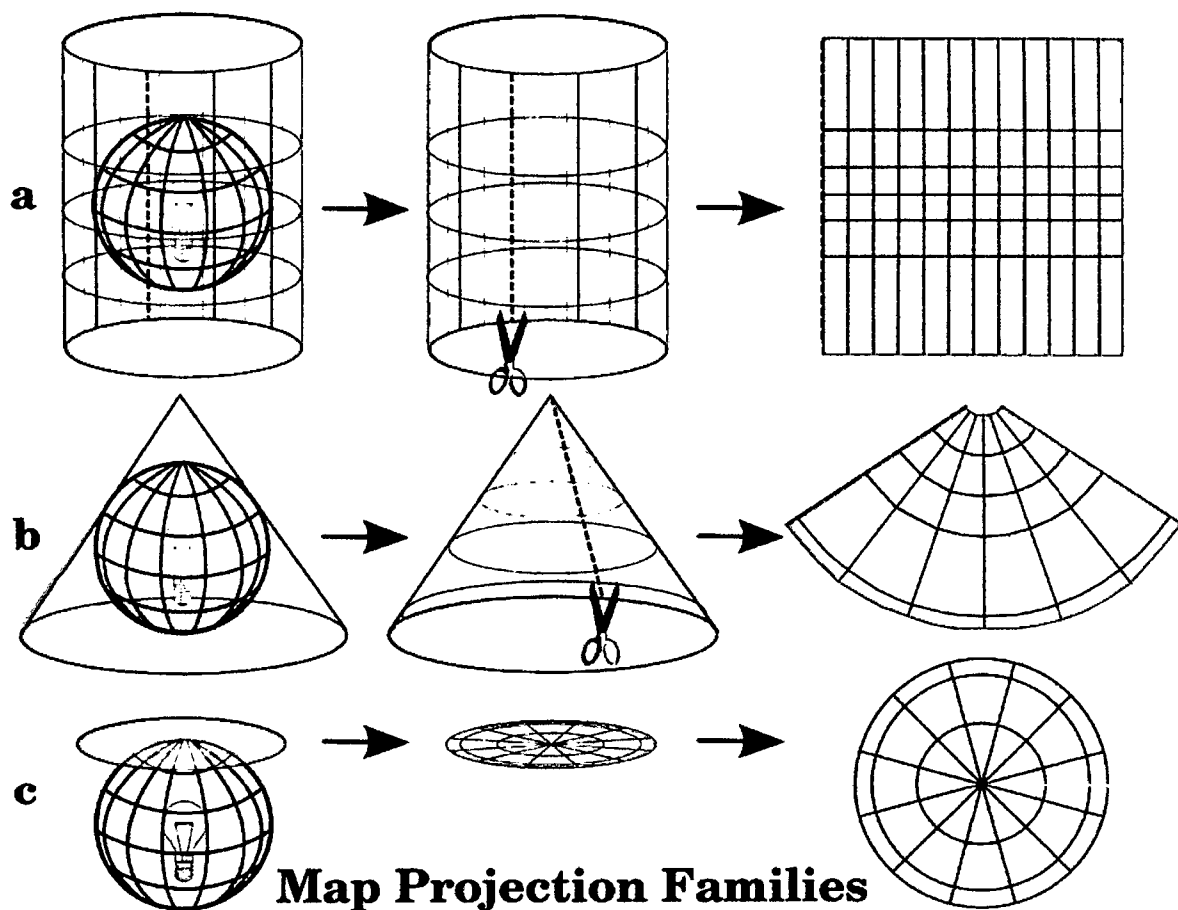
En general todos los archivos tratados en los sistemas de información geográfica [45, 10, 8] implícitamente están geo-referenciados, sea en un sistema de referencia geográfica o un sistema de referencia proyectado, quiere decir que cada archivo queda definido en puntos o regiones específicas sobre la superficie terrestre. Los archivos que no dispongas con sistema de referencia implícito, antes necesariamente deben quedar definidos y todas las aplicaciones se encuentran implementadas con estas capacidades.

El proceso de crear mapas cartográficos² se puede imaginar como colocar una fuente de luz dentro de una esfera transparente en la que las zonas terrestres son opacas. Entonces,

²Tomado desde <https://docs.qgis.org/>

se proyectan los contornos en una hoja bidimensional de papel. El papel imaginario se puede colocar de distintas formas alrededor del globo; cilíndrica, cónica o incluso como una superficie plana. Cada uno de estos métodos produce lo que se denomina familia de mapas cartográficos. Por lo tanto, existe una familia de proyecciones planas, una familia de proyecciones cilíndricas y otra denominada proyecciones cónicas

Figura 2.4: Las tres familias de proyecciones cartográficas. Pueden ser representadas por a) proyecciones cilíndricas, b) proyecciones cónicas o c) proyecciones planas.



Fuentes: Tomado desde <https://docs.qgis.org/>

Hoy en día, por supuesto, el proceso de proyectar la esfera terrestre sobre el papel se realiza utilizando los principios matemáticos de la geometría y la trigonometría. Este procedimiento recrea la proyección de la luz a través del globo.

2.2. Cuencas hidrográficas

Se entiende por cuenca hidrográfica [29, 2], hoya hidrográfica, cuenca de drenaje o cuenca imbrífera³ el territorio drenado por un único sistema de drenaje natural, es decir, que drena sus aguas al mar a través de un único río, o que vierte sus aguas a un único lago endorreico. Una cuenca hidrográfica es delimitada por la línea de las cumbres, también llamada divisoria de aguas. El uso de los recursos naturales se regula administrativamente separando el territorio por cuencas hidrográficas, y con miras al futuro las cuencas hidrográficas se perfilan como las unidades de división funcionales con más coherencia, permitiendo una verdadera integración social y territorial por medio del agua. Una cuenca hidrográfica y una cuenca hidrológica se diferencian en que la cuenca hidrográfica se refiere exclusivamente a las aguas superficiales, mientras que la cuenca hidrológica incluye las aguas subterráneas (acuíferos).

Figura 2.5: Cuenca hidrográfica.



Fuentes: Imagen de dominio público

Una cuenca hidrográfica [2, 44, 27] es toda el área de terreno que contribuye al flujo de agua en un río o quebrada. También se conoce como el área de captación o área

³Tomado desde www.ana.gob.pe

de terreno de donde provienen las aguas de un río, quebrada, lago, laguna, humedal, estuario, embalse, acuífero, manantial o pantano.

Las cuencas hidrográficas [49] se clasifican en: cuencas hidrográficas naturales y cuencas urbanas. Las cuencas hidrográficas naturales son aquellas donde quedan delimitadas por sus propias características topográficas, mientras las cuencas hidrográficas urbanas ya fueron alteradas por el cambio de uso de suelo y su determinación obedece a condiciones topográficas locales.

La figura 2.5 muestra la delimitación de una cuenca hidrográfica natural, las propiedades morfométricas importantes con fines de obtener el potencial hídrico son los siguientes: superficie, perímetro, pendiente promedio de la superficie delimitada por la cuenca, longitud del curso de la red hídrica principal, pendiente de la red hídrica principal. Todas estas propiedades requeridas serán obtenidas mediante aplicaciones para sistemas de información geográfica.

2.3. Método racional

El Método Racional es uno de los más utilizados para la estimación del caudal máximo asociado a determinada lluvia de diseño. Se utiliza normalmente en el diseño de obras de drenaje urbano y rural. Y tiene la ventaja de no requerir de datos hidrométricos para la Determinación de Caudales Máximos.

$$Q = \frac{C * I * A}{360} \quad (2.1)$$

La expresión utilizada por el Método Racional está representado por la ecuación 2.1, donde cada término representa:

- Q, Caudal máximo, en m^3/s

- C, Coeficiente de escorrentía, dependiendo si son cuencas Rurales o Urbanas.
- I, Intensidad de la Lluvia de Diseño, con duración igual al tiempo de concentración de la cuenca y con frecuencia igual al período de retorno seleccionado para el diseño (Curvas de I-D-F), en mm/h
- Área de la cuenca, en Ha

2.3.1. Limitaciones del método racional

Entre las limitaciones del Método Racional se tienen:

- Proporciona solamente un caudal pico, no el hidrograma de creciente para el diseño.
- Supone que la lluvia es uniforme en el tiempo (intensidad constante) lo cual es sólo cierto cuando la duración de la lluvia es muy corta.
- El Método Racional también supone que la lluvia es uniforme en toda el área de la cuenca en estudio, lo cual es parcialmente válido si la extensión de ésta es muy pequeña.
- Asume que la escorrentía es directamente proporcional a la precipitación. En la realidad, esto no es cierto, pues la escorrentía depende también de muchos otros factores, tales como precipitaciones antecedentes, condiciones de humedad antecedente del suelo, etc.
- Ignora los efectos de almacenamiento o retención temporal del agua escurrida en la superficie, cauces, conductos y otros elementos (naturales y artificiales).
- Asume que el período de retorno de la precipitación y el de la escorrentía son los mismos, lo que sería cierto en áreas impermeables, en donde las condiciones de humedad antecedente del suelo no influyen de forma significativa en la Escorrentía

Superficial.

Pese a estas limitaciones, el Método Racional se usa prácticamente en todos los proyectos de drenaje vial, urbano o agrícola, siempre teniendo en cuenta que producirá resultados aceptables en áreas pequeñas y con alto porcentaje de impermeabilidad, por ello es recomendable que su uso se limite a Cuencas con extensiones inferiores 13 km^2 de superficie, en concordancia al Reglamento Nacional de Edificaciones.

2.3.2. Coeficiente de escorrentía

Representa la porción de la precipitación que se convierte en caudal, es decir, la relación entre el volumen de Escorrentía superficial y el de precipitación total sobre un área (cuenca) determinada, queda establecida por la ecuación 2.2

$$C = \frac{\text{Volumen Escorrenta Superficial}}{\text{Volumen Precipitacion Total}} \quad (2.2)$$

El Coeficiente de Escorrentía no es un factor constante, pues varía de acuerdo a la magnitud de la lluvia y particularmente con las condiciones fisiográficas de la Cuenca Hidrográfica (Cobertura vegetal, pendientes, tipo de suelo), por lo que su determinación es aproximada. En general, los cálculos de este coeficiente se efectúan a partir de los valores anuales de precipitación y caudal.

Para la selección del Coeficiente de Escorrentía, es necesario conocer (además del tipo de cobertura vegetal) dos parámetros específicos del área en estudio: la pendiente promedio del terreno (la cual es la resultante del estudio morfológico de la cuenca) y el tipo de suelo predominante en el área de estudio, de esta forma poder estimar su nivel de permeabilidad, la cual deberá ser determinada a partir de muestreos, inspección directa o estudios geológicos.

Como referencia, los tres niveles de permeabilidad utilizados pueden ser asociados a

los tipos de suelos de la siguiente manera:

- Suelo Impermeable: Rocas, arcillas, limos arcillosos.
- Suelo Semipermeable: Arenas limosas o arcillosas, gravas finas con alto contenido de arcillas.
- Suelo permeable: Arenas, gravas, en general suelos de alto contenido arenoso.

2.3.2.1. Coeficiente de escorrentía para cuencas rurales

En la bibliografía relativa al tema de la Hidrología superficial se disponen de coeficientes de escorrentía para distintas condiciones de usos de suelo. En esta Tabla 2.2 queda reproducido algunos valores comunes del Coeficiente de Escorrentía utilizados para el cálculo de Cuencas Rurales (no urbanizadas).

2.3.2.2. Coeficiente de escorrentía para cuencas urbanas

De la misma manera a las cuencas rurales, se cuenta con diversas fuentes para la selección del Coeficiente de Escorrentía en Zonas Urbanas, la tabla 2.1 representa algunos valores típicos de los coeficientes de escorrentía para cuencas urbanas.

Tabla 2.1: Coeficiente de escorrentía zonas urbanas

Tipo de área	Valor de C
Áreas de viviendas unifamiliares	0.3-0.5
Viviendas multifamiliares	0.6-0.75
Zonas industriales densidad baja	0.5-0.8
Zonas industriales densidad alta	0.6-0.9
Pavimentos	0.70-0.95
Ladrillo	0.70-0.85
Techos	0.75-0.95

Figura 2.6: Coeficiente de escorrentía cuencas urbanas

Cobertura Vegetal	Permeabilidad del Suelo	Pendiente del Terreno				
		Pronunciada	Alta	Media	Suave	Despreciable
		>50%	>20%	>5%	>1%	<1%
Sin Vegetación	Impermeable	0,80	0,75	0,70	0,65	0,60
	Semipermeable	0,70	0,65	0,60	0,55	0,50
	Permeable	0,50	0,45	0,40	0,35	0,30
Cultivos	Impermeable	0,70	0,65	0,60	0,55	0,50
	Semipermeable	0,60	0,55	0,50	0,45	0,40
	Permeable	0,40	0,35	0,30	0,25	0,20
Pastos, Vegetación ligera	Impermeable	0,65	0,60	0,55	0,50	0,45
	Semipermeable	0,55	0,50	0,45	0,40	0,35
	Permeable	0,35	0,30	0,25	0,20	0,15
Hierba, Grama	Impermeable	0,60	0,55	0,50	0,45	0,40
	Semipermeable	0,50	0,45	0,40	0,35	0,30
	Permeable	0,30	0,25	0,20	0,15	0,10
Bosque Vegetación Densa	Impermeable	0,55	0,50	0,45	0,40	0,35
	Semipermeable	0,45	0,40	0,35	0,30	0,25
	Permeable	0,25	0,20	0,15	0,10	0,05

Fuentes: Imagen de dominio público

2.3.3. Coeficiente de escorrentía ponderado

En general las cuencas receptoras presentarán variedad de suelos, con coberturas, pendientes y permeabilidades variables, en estos casos el coeficiente de escorrentía ponderado se obtiene mediante la ecuación 2.3.

$$C_{ponderado} = \frac{\sum C_i A_i}{\sum A_i} \quad (2.3)$$

2.3.4. Tiempo de concentración en cuencas

El tiempo de concentración de una cuenca, se define como el tiempo mínimo necesario para que todos los puntos de una cuenca estén aportando agua de escorrentía de forma simultánea al punto de salida, punto de desagüe o punto de cierre. Está determinado por el tiempo que tarda en llegar a la salida de la cuenca el agua que procede del punto hidrológicamente más alejado, y representa el momento a partir del cual el caudal de escorrentía es constante.

Debido a las diferentes formas como fueron concebidas estas expresiones, la variabilidad de los resultados entre una y otra puede ser bastante alta, razón por la cual el criterio del analista juega un papel fundamental en la definición del tiempo de concentración de una determinada cuenca.

Según Témez: T_c : Tiempo de concentración en horas, L : Longitud del cauce principal en kilómetros, S_o : Diferencia de cotas sobre L en porcentaje.

$$T_c = 0.3 \left(\frac{L}{S_o^{0.25}} \right)^{0.75} \quad (2.4)$$

Según Williams: A : área de la cuenca en millas cuadradas, L : distancia en línea recta desde el sitio de interés al punto mas alto en millas, S_o : diferencia de cotas entre los puntos más extremos dividida por L en porcentaje, d : diámetro de una cuenca circular con área A en millas.

$$T_c = \frac{LA^{0.4}}{DS_o^{0.2}} \quad (2.5)$$

Según Kirpich. Desarrollada a partir de información del SCS en siete cuencas rurales de Tennessee con canales bien definidos y pendientes empinadas (3 a 10%), donde: L : longitud desde la estación de aforo hasta la divisoria siguiendo en cauce principal en kilómetros, S_o : diferencia de cotas entre los puntos extremos de la corriente en m/m .

$$T_c = 0.066 \left(\frac{L}{\sqrt{S}} \right)^{0.77} \quad (2.6)$$

Según California Culverts Practice. Esencialmente es la ecuación de Kirpich; desarrollada para pequeñas cuencas montañosas en California. L = longitud del curso de agua más largo (m), H = diferencia de nivel entre la divisoria de aguas y la salida (m).

$$T_c = 0.0195 \left(\frac{L^3}{H} \right)^{0.385} \quad (2.7)$$

2.3.5. Análisis Estadístico de las curvas IDF

Las curvas IDF (Intensidad, Duración y frecuencia) es posible obtenerlo a partir de un modelo de regresión lineal, de modo de extrapolar la ecuación generada, a zonas que carezcan de registros pluviográficos y que se encuentren relativamente cerca. Por lo que, se procede a analizar el comportamiento de las variables involucradas en este estudio, relacionando simultáneamente las tres variables en una familia de curvas, para lo cual se utiliza la ecuación 2.8 propuesta por Aparicio (1997).


$$I = \frac{kT^m}{D^n} \quad (2.8)$$

Donde k, m y n son constantes de regresión lineal múltiple, donde T es el período de retorno en años, D la duración en minutos u horas, e I la intensidad de precipitación en *mm/hr*.

2.4. Redes neuronales artificiales

Las redes de neuronas artificiales [13, 21, 23] son un paradigma de aprendizaje y procesamiento automático inspirado en la forma que funciona el sistema nervioso del hombre, son modelos que se clasifican dentro de la Inteligencia Artificial (IA) y su aplicación está extendida prácticamente en todos los campos de la investigación, y más específicamente, en áreas donde no se dispone de modelos determinísticos que representen el comportamiento del fenómeno analizado. La estrategia de las Redes Neuronales Artificiales (RNA) consiste en imitar (emular) el proceso de aprendizaje del hombre, de allí su aplicación universal, para diseñar un modelo específico basta con disponer de un registro de datos y sus resultados respectivos.

Figura 2.7: Red neuronal biológica

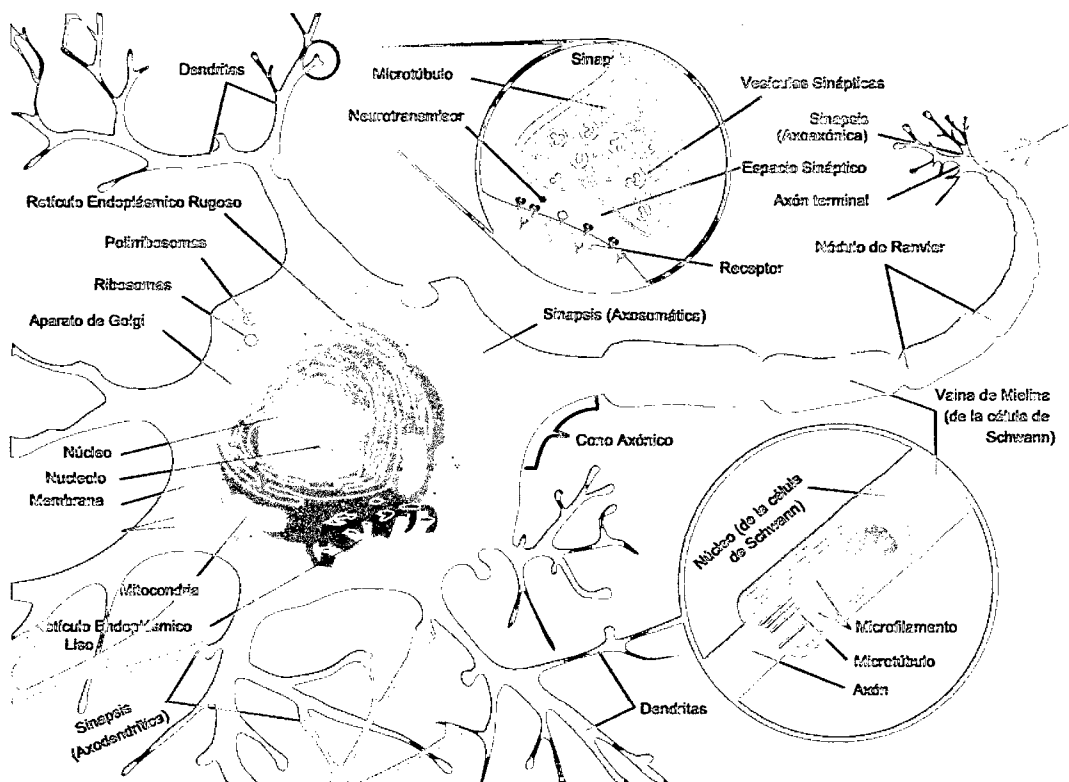


Fuente: Figura tomada desde [26]

2.4.1. Fundamentos biológicos de las RNA

El hombre está dotado de forma natural de la capacidad para tomar decisiones a voluntad, aprender(asimilar) nuevas actividades y retenerlos estas experiencias si es de su interés, todo es posible gracias al aparato de comunicación neural, formado [24] por el Sistema Nervioso y Hormonal, en conexión con los órganos de los sentidos y órganos efectores (músculos, glándulas).

Figura 2.8: Neurona biológica y elementos a detalle



Fuente: Figura tomada desde [7]

El sistema de comunicación neural, figura 2.9, se compone de tres partes:

1. Los receptores: formado por las células sensoriales, especializado en recoger la información en forma de estímulos (estos estímulos provienen del ambiente donde interactúa el hombre o desde el propio organismo).
2. El sistema nervioso: encarga de recibir la información registrada por los receptores, las elabora y transforma en señales electroquímicas y parte de la información

lo almacena, luego envía dicha información elaborada a los órganos efectores y otras zonas del sistema nervioso.

3. Órganos efectores: que reciben la información elaborada por el sistema nervioso y la interpretan en forma de acciones motoras, hormonales, etc. Los sistemas en ésta categoría son los músculos y glándulas.

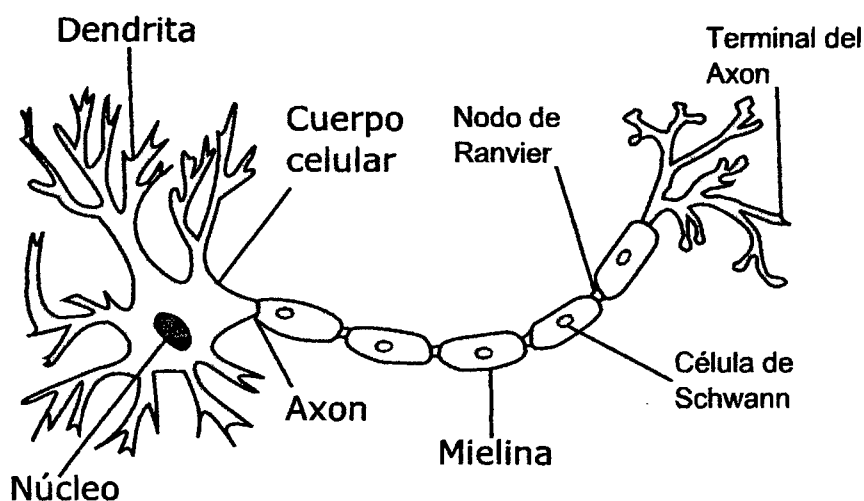
Las células encargadas de almacenar el aprendizaje o la experiencia, son las neuronales [7], células que conforman el sistema nervioso y actúan en conjunto, Figura 2.9, y en comunicación entre miles de ellos. La Figura 2.8 muestra la célula primordial del sistema nervioso indicando todas sus componentes.

Los componentes de interés [32] de la célula del sistema nervioso y el cerebro son: las dendritas, el cuerpo de la célula o soma, el axón y la sinapsis (terminal de axón). Las sinapsis son elementos [22] terminales de axón que se conectan con otras neuronas; las dendritas son elementos que llevan la información al cuerpo celular o núcleo [14] y el axón es el elemento por el cual la información es propagada a otras células, de la forma establecida en la Figura 2.8.

2.4.2. Modelo Artificial de las Redes Neuronales Biológicas

Las *Redes Neuronales Artificiales* son modelos simplificados de las *Redes Neuronales Naturales* [42] cuya finalidad es imitar el proceso de aprendizaje humano. La Figura 2.9 muestra los elementos básicos de una neurona biológica (el núcleo, cuerpo celular, dendrita, axón, terminal del axón, la sinapsis) que son necesarias para generar una neurona artificial.

Figura 2.9: Neurona biológica y elementos básicos



Fuente: Figura tomada desde [38]

Los modelos artificiales de las neuronas biológicas utilizan elementos fundamentales para su representación, Figura 2.12 se consideran los datos de entrada, los pesos sinápticos, el núcleo de la neurona es representado generalmente mediante un círculo y es optativo considerar el valor de la umbral, la información fluye de acuerdo a la orientación del grafo dirigido; para su funcionamiento, las neuronas artificiales, imitando a las biológicas, se agrupan entre ellos formando un sistema de redes neuronales artificiales, donde el elemento fundamental es la neurona artificial.

Tabla 2.2: Evolución de las RNA 1910-1970

Modelo	Autor - Año
Red neuronal	Ramón y Cajal (1911)
Modelo	McCulloch-Pitts (1943)
Filtros no lineales adaptables	Gabor (1954)
Perceptrón	Rosenblatt (1958)
Adaline	Widrow-Hopf (1960)
Limitaciones Perceptrón	Minsky-Papert (1969)

Fuente: Adaptado desde [40]

2.4.3. Evolución histórica

La historia de las redes neuronales artificiales [40] inicia desde a principios del siglo XIX, en la Tabla 2.2 se muestra los diferentes modelos que se crearon desde el año 1910 hasta el año de 1970.

Entre los años de 1970 y 1980 existe poca actividad, centrándose en los modelos de aprendizaje competitivo de las redes neuronales artificiales y la auto-organización. La Tabla 2.3 contiene la evolución de los modelos de redes neuronales progresivamente tomando en cuenta el año de su creación, desde el año 1970 hasta el año 2000.

Tabla 2.3: Evolución de las RNA 1970-2000

Modelo	Autor - Año
Resonancia adaptable	Grossberg (1980)
Redes dinámicas	Hopfield (1982)
Mapas auto organizados	kohonen (1982)
Aprendizaje por reforzamiento	Barto (1983)
Aprendizaje por retropropagación	Werbos (1986)
Redes de base radial	1988
Control neuronal con redes estáticas	Narendra (1991)
Control neuronal con redes recurrentes	1994
Caos en redes	1995
Máquinas en vector soporte	a
Redes pulsadas o impulsadas	1999

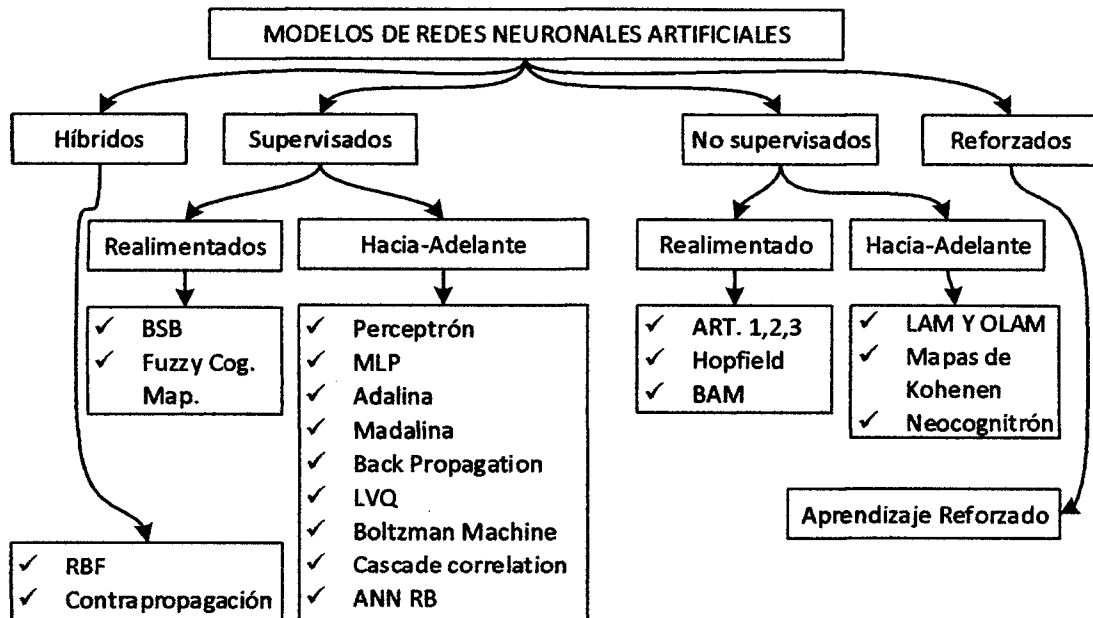
Fuente: Adaptado desde [40]

2.4.4. Clasificación de las RNA

Para su clasificación de los distintos tipos de redes neuronales, se realiza en función de sus características más notables:

La clasificación según su topología o estructura de la red, se considera el número de capas, el tipo de las capas (que pueden ser ocultas o visibles, de entrada o de salida) y la direccionalidad de las conexiones de las neuronas (modelos de redes neuronales

Figura 2.10: Clasificación de las RNA de acuerdo al algoritmo de aprendizaje utilizado




Fuente: Adaptado desde [42] y [47]

conectadas todas hacia⁴ adelante o las redes que consideran sus conexiones con neuronas de capas anteriores).

La clasificación más extendida considera el tipo de aprendizaje o como la red aprende los patrones, se distinguen los siguientes algoritmos: aprendizaje supervisada, no supervisada, competitiva o por refuerzo. La Figura 2.10 muestra los modelos de redes neuronales artificiales clasificadas teniendo en cuenta el tipo de aprendizaje.

⁴ Indica la dirección del movimiento con respecto a su punto de destino

Figura 2.11: Red neuronal artificial de base radial



Fuente: Adaptado desde [40] y [20]

2.4.5. Arquitectura de RNA de base radial

Es un modelo de redes neuronales artificiales que se caracteriza por su arquitectura simple [17], las conexiones entre sus neuronas son todos hacia adelante y utilizan las funciones de activación del tipo radial. Los enlaces entre la capa de entrada y la capa oculta no disponen de pesos de ponderación, sólo los enlaces entre la capa oculta y la capa de salida, las funciones de activación afecta solamente a las neuronas de la capa oculta y el umbral de las neuronas artificiales solamente los dispone la capa de salida; ésta son las características principales de las redes neuronales de base radial y éste modelo se utilizará para la obtención de la contaminación acústica por tránsito vehicular.

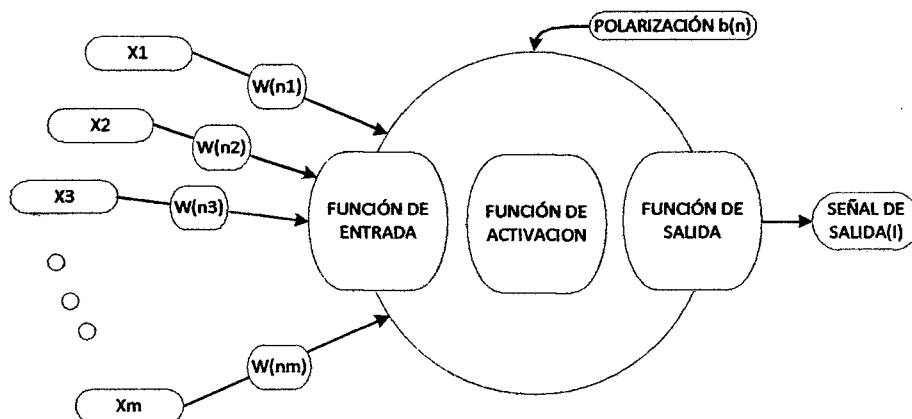
Las redes neuronales artificiales de base radial solamente poseen tres niveles de neu-

ronas, la capa de entrada, la capa oculta que está conformada solamente por una sola capa de neuronas y finalmente la capa de salida. El número de neuronas de la capa de entrada está determinado por el número de datos considerados en cada muestra, ejemplo o patrón de entrenamiento y el número de neuronas de la capa de salida se corresponde con el número de resultados esperados para el mismo patrón de aprendizaje, los únicos elementos neuronales que permite variar son las neuronas de la capa oculta, desde la Figura 2.11, se define p neuronas en la capa de entrada, m neuronas en la capa oculta y r neuronas en la capa de salida.

2.4.6. Elementos de la neurona artificial

Para mostrar los elementos básicos de una neurona artificial se aísla una neurona de toda la red. En correspondencia a los componentes principales de una neurona biológica, Figura 2.9, en el modelo de una neurona artificial, Figura 2.12, se establece los siguientes componentes:

Figura 2.12: Neurona artificial



Fuente: Figura tomada desde [4]

- Las señales (impulsos) electroquímicos que son transportados al núcleo de la neurona por medio de las dendritas en una neurona biológica, son representadas por las variables $x_1, x_2 \dots x_n$ para una neurona artificial, es su expresión simplificada.
- Las expresiones $w_{n1}, w_{n2} \dots w_{nm}$ representa el grado de conexión existente entre

las neuronas artificiales (llamado enlaces de conexión), los w_{nm} representan la memoria, donde se almacena lo aprendido, característica fundamental de una neurona natural.

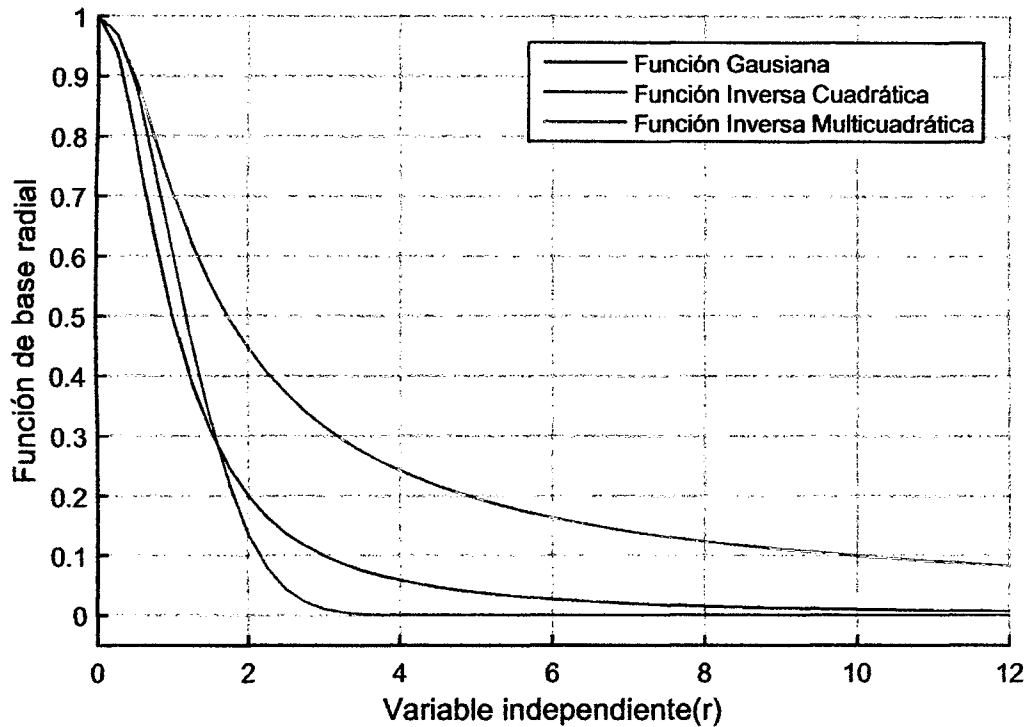
- En una red neuronal natural [22], todas las señales transmitidas a una determinada neurona es procesado en su núcleo y la señal resultante es transmitido a otras neuronas de la red mediante las terminales del axón, en un modelo equivalente para una neurona artificial el núcleo es representado generalmente por un círculo, al cual ingresan las entrada x_n ponderados por los pesos w_{nm} . La información es procesado en una neurona artificial según las funciones de entrada, las funciones de activación y genera un resultado de acuerdo a las funciones de salida.
- El valor de la umbral o entrada ponderada constante, representa el grado de excitación de la neurona, medido tomando como referencia para el cual la neurona se encuentra en su estado de equilibrio.

2.4.7. Funciones de entrada, activación y de transferencia

El flujo de datos sobre la red en un modelo de redes neuronales artificiales de base radial difiere comparado con un modelo perceptrón multicapa de múltiples capas, la red se caracteriza porque las conexiones de la capa de entrada a la capa oculta no llevan asociada ningún peso [20], pero las conexiones de la capa oculta a la capa de salida si disponen de pesos asociados y los umbrales de las neuronas únicamente está disponible para las neuronas de la capa de salida [28], en consecuencia las funciones de activación de base radial están asociadas a la capa oculta y son las que se muestran en las ecuaciones 2.9 a la Ecuación 2.11, asociado a la función gaussiana, función inversa cuadrática y función inversa multicuadrática; respectivamente, la la Figura 2.13 muestra la representación gráfica de las funciones de activación radial.

$$\phi(r) = e^{\left(-\frac{r^2}{2}\right)} \quad (2.9)$$

Figura 2.13: Funciones de activación de base radial



Fuente: Adaptado desde la referencia [32] y [1]

$$\phi(r) = \frac{1}{1 + r^2} \quad (2.10)$$

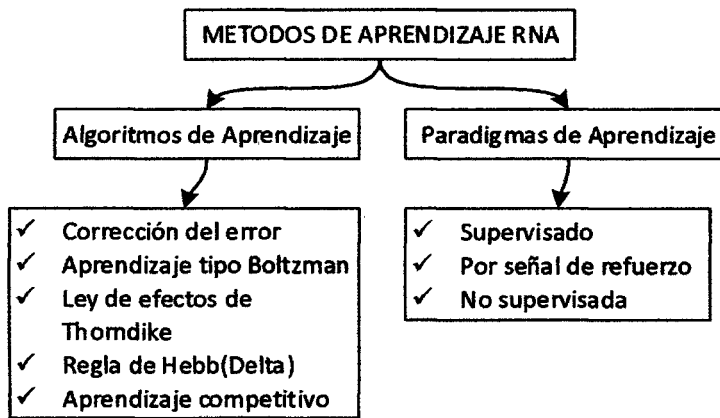
$$\phi(r) = \frac{1}{\sqrt{1 + r^2}} \quad (2.11)$$

Las funciones de entrada [17] para las neuronas de la capa de salida están dadas por la Ecuación 2.12, es la suma de todos los valores de entrada desde la capa oculta a la capa de salida, multiplicados por sus correspondientes pesos.

$$u_n = \sum_{j=1}^{j=m} (w_{nj}x_j) \quad (2.12)$$

Donde: u_n es el umbral de la neurona n correspondiente a la capa de salida, j es un número entero, que varía desde 1 hasta m , w_{nj} son los pesos de las conexiones, X_j son

Figura 2.14: Métodos de aprendizaje de las RNA



Fuente: Adaptado desde [32] y [15]

las señales de entrada a la neurona.

Las funciones de salida [28] toman como argumento el valor generado por las funciones de activación, procesan dicha información de acuerdo a una función de activación elegida cuyo resultado representa la señal de salida de la neurona. Las neuronas de la capa de salida [22] generan los resultados mediante la función $f(x) = x$, éste es el tipo de función más sencillo, tal que la salida es la misma que la entrada.

2.4.8. Algoritmos y paradigmas de aprendizaje

La red neuronal artificial aprende variando sus pesos asociadas a cada conexión entre neuronas y el umbral de polarización (los parámetros de las redes neuronales artificiales). Existen diferentes algoritmos y paradigmas mediante los cuales la red neuronal artificial modifica sus parámetros para cada patrón de los ejemplos suministrados, la Figura 2.14 muestra la clasificación de los algoritmos y paradigmas de aprendizaje.

- **Algoritmos de aprendizaje:** conjunto de reglas [25] para resolver el problema de aprendizaje, se diferencian [28] en como determinan la variación de los pesos de las conexiones para cada patrón de aprendizaje.

- **Paradigmas de aprendizaje:** es la forma como la red neuronal interactúa con el medio ambiente.

2.4.9. Método de aprendizaje híbrido

Uno de los métodos de aprendizaje utilizado por las redes neuronales artificiales de base radial [24] es el *método híbrido*, que dispone en el aprendizaje de las redes de dos fases: una fase no supervisada (determina los centros y las distancias euclídeas - centros y amplitudes) y otra fase supervisada (determina pesos y umbrales).

Fase no supervisada:

Para la determinación de los centros se utiliza el *Algoritmo de K-medias*, es un algoritmo de clasificación no supervisada que permite dividir el los datos de entrada en clases, el número de clases será equivalente al número de neuronas de la capa oculta de la red. El algoritmo de K-medias, clasifica el espacio de las muestras en K clases o regiones con centro C_i , correspondiente a la neurona oculta i , los centros se obtienen para minimizar las distancias euclídeas entre los argumentos de entrada y el centro más cerca, según la Ecuación 2.13.

$$J = \sum_{i=1}^K \sum_{j=1}^N M_{in} \|X(n) - C_i\| \quad (2.13)$$

Donde N , $X(n)$ es el patrón de entrada n y M_{in} es la función de pertenencia y su valor es uno si en centro C_i es el más cercano a la entrada $X(n)$ y cero en otro caso. $\| \quad \|$ es la distancia euclídea.

La determinación de las amplitudes o desviaciones d_i , el espacio que gobierna cada centro C_i correspondiente a cada neurona de la capa oculta, para su obtención se utiliza la media uniforme de las distancias euclídeas del centro C_i a los p centros más cercanos, mediante la Ecuación 2.14.

$$d_i = \frac{1}{p} \sum_p \|C_i - C_p\| \quad (2.14)$$

Otra alternativa para obtener la amplitud de la función de base radial es mediante la relación mostrada en la Ecuación 2.15, donde C_t y C_s los dos centros más cercanos al centro C_i .

$$d_i = \sqrt{\|C_i - C_t\| \|C_i - C_s\|} \quad (2.15)$$

Fase supervisada:

Se obtienen los pesos $W_{i,k}$ de las conexiones de la capa oculta y la capa de salida y los umbrales U_k de las neuronas de la capa de salida, se obtiene minimizando el error E cometido a la salida de la red neuronal para la totalidad de los patrones de entrenamiento o ejemplos, mediante la Ecuación 2.16.

$$E = \frac{1}{N} \sum_{n=1}^N e(n) \quad (2.16)$$

N es el número de patrones o muestras y $e(n)$ es el error cometido por la red para el patrón $X(n)$, representado por la Ecuación 2.17.

$$e(n) = \frac{1}{2} \sum_{k=1}^r (s_k(n) - y_k(n))^2 \quad (2.17)$$

Donde $S(n)$ son los vectores de salida de la red y $Y(n)$ son las salidas esperadas provenientes de los registros de datos, para cada patrón de entrada $X(n)$. Para resolver el problema de optimización se utiliza la técnica basada en la corrección del error (mínimos cuadrados), las relaciones para adaptar los pesos y umbrales de una red neuronal de base radial están representadas mediante las Ecuaciones 2.18 y 2.19.

$$w_{ik}(n) = w_{i,k}(n-1) + \alpha (s_k(n) - y_k(n)) \phi_i(n) \quad (2.18)$$

$$u_k(n) = u_k(n-1) + \alpha (s_k(n) - y_k(n)) \phi_i(n) \quad (2.19)$$

para: $k = 1, 2, 3, \dots, r$ y para $i = 1, 2, 3, \dots, m$,

2.4.10. Evaluación del aprendizaje

Existe múltiples alternativas para evaluar el aprendizaje de un modelo [19] de red neuronal artificial: el más extendido, cuando se trata de paradigmas de aprendizaje supervisado, es la evaluación del error cuadrático medio (E_m), para considerar que la red aprendió es necesario evaluar el valor (E_m) menor que un error de aproximación considerado; otra alternativa [5] es considerar en no evaluar ningún tipo de aproximación en cuanto al error para los registros de aprendizaje y se establece un número máximo de iteraciones, la aproximación alcanzada se evalúa con los datos de validación y prueba del modelo; otra alternativa es evaluar la variación de los parámetros de la red neuronal, se considera que la red neuronal artificial aprende al modificar sus parámetros (pesos y umbrales) para cada patrón de entrenamiento, cuando el modelo aprendió los pesos y umbrales se modifican cada vez con valores muy pequeños, alcanza un valor de equilibrio, en este caso se puede considerar que la red neuronal aprendió.

En ocasiones estas consideraciones no son suficientes [43], pueda que el error al que se quiera llegar (E_m), no sea en ningún momento obtenido por la red, en consecuencia, tampoco obtendrán un valor de equilibrio los parámetros de la red, la aplicación entraría en un proceso infinito; para evitar este inconveniente es necesario siempre considerar en combinación con las otras alternativas un máximo número de iteraciones, y la evaluación posterior [48] de la red entrena con los registros de la validación y prueba del modelo.

Capítulo 3

Desarrollo del trabajo de la tesis

El capítulo presente se corresponde con los materiales y métodos en el proceso del desarrollo de la tesis, comprende la determinación de los argumentos requeridos y la obtención de los caudales máximos en concordancia al método racional, luego, el diseño del modelo basado en redes neuronales artificiales para la obtención de los caudales obtenidos mediante el modelo empírico denominado método racional.

3.1. Generación de los registros

Los modelos de redes neuronales artificiales, para su entrenamiento, validación y prueba final requieren de registros tanto a nivel de los datos requeridos y los resultados obtenidos; por tanto, como se persigue diseñar un modelo específico de redes neuronales artificiales de base radial para la obtención de caudal de máxima avenida, los datos y resultados requeridos son generados considerando múltiples alternativas en base al método racional.

3.1.1. Drenaje pluvial urbano OS.060

En consideración al *Reglamento Nacional de Edificaciones*, Título II.3 Obras de Saneamiento y específicamente la norma técnica OS.060 Drenaje Pluvial Urbano, especifica que para el cálculo de caudales de escurrimiento en cuencas urbanas se recomienda el uso del método racional con fines de estimar los caudales de máxima avenida, aplicado hasta áreas de drenaje no mayores a 13km^2 -el modelo a considerar para generar los registros de datos y resultados necesarios está dado por la ecuación 3.1 y sus parámetros descritos detalladamente en la sección 2.3, de la página 16.

$$Q = \frac{C * I * A}{360} \quad (3.1)$$

A partir de la ecuación 3.1 se obtendrán los registros necesarios para el diseño del modelo meta-heurístico con fines de obtención de caudales de máxima avenida en cuencas urbanas.

3.1.2. Registro de los coeficientes de escorrentía

La selección del valor del coeficiente de escorrentía se sustenta en considerar los efectos siguientes:

- Características de la superficie de la cuenca hidrográfica urbana.
- Tipo de área urbana.
- Intensidad de la precipitación (para tiempos de retorno específicos).
- Pendiente del terreno.
- Horizonte de vida del proyecto.

En tal sentido, es necesario considerar todos los valores del coeficiente de escorrentía,

que abarque todas sus condiciones necesarias para su selección y se tenga numéricamente todo el rango de valores posibles.

Con la finalidad de disponer los valores del coeficiente de escorrentía, éstas se generarán aleatoriamente, disponiendo cada característica de uso de suelo igual posibilidad de ser seleccionado, estos valores son generados para un determinado rango, donde queda establecido el coeficiente de escorrentía. La tabla 3.1 muestra los coeficientes de escorrentía generados.

Tabla 3.1: Coeficientes de escorrentía generados aleatoriamente

Nro	C	Nro	C
1	0.37	17	0.76
2	0.54	18	0.73
3	0.43	19	0.65
4	0.62	20	0.75
5	0.52	21	0.73
6	0.92	22	0.42
7	0.90	23	0.38
8	0.33	24	0.95
9	0.78	25	0.41
10	0.47	26	0.32
11	0.57	27	0.66
12	0.66	28	0.87
13	0.91	29	0.73
14	0.57	30	0.42
15	0.94	31	0.54
16	0.50	32	0.60

Fuente: Elaboración propia

3.1.3. Intensidad de la precipitación

Las precipitaciones e intensidades máximas de tormentas fueron estudiados y regionalizados para todo el territorio nacional por el *Instituto Italiano Latino Americano IILA* (Convenio Internacional IILA-SENAMHI-UNI) en el *Estudio de la Hidrología del Perú 1983*, en el año 1983, cuyas relaciones precipitación - intensidad duración y periodo de retorno son expresadas en las ecuaciones siguientes:

para $3 \leq t \leq 24$ horas

$$P_{t,T} = a(1 + K \log T)t^n \quad (3.2)$$

$$i_{t,T} = a(1 + K \log T)t^{n-1} \quad (3.3)$$

para $t < 3$ horas

$$P_{t,T} = a(1 + K \log T)(t + b)^{n-1}t \quad (3.4)$$

$$i_{t,T} = a(1 + K \log T)(t + b)^{n-1} \quad (3.5)$$

Donde $P_{t,T}$ y $i_{t,T}$ son las precipitaciones e intensidades de tormenta para una duración t (en horas) y el periodo de retorno T (en años), y las variables a , K , n son constantes regionales. El parámetro b se clasifica según las regiones naturales del Perú y queda establecida en la tabla 3.2.

Actualmente, el *Reglamento Nacional de Edificaciones* vigente a la fecha, aprobado mediante Decreto Supremo N° 011 – 2006 Vivienda y sus Modificaciones Normas del RNE - D.S N° 010 – 2009, en su apartado *Obras de Saneamiento e Instalaciones Sanitarias* recomienda el uso del modelo IILA para la obtención de las precipitaciones e intensidades máximas en proyectos de drenaje.

Tabla 3.2: Parámetro regional b

Región	Parámetro b
Costa, centro y sur	0.5
Sierra	0.4
Costa, norte, selva	0.2

Reglamento Nacional de Edificaciones

La duración t para obtener la intensidad máxima en las microcuencas se corresponde con el tiempo de concentración, y dado que estos tiempos de concentración para la cuencas urbanas son bajos, en consecuencia para obtener la precipitación de diseño se utilizarán las relaciones mostradas anteriormente, correspondientes para $t < 3$. Los parámetros para la zona de estudio (Ayacucho) son: $b = 0.4$, $a = 32.2$, $K = 1.3$, $n = 0.242$, cuya relación final obtenida es (para la precipitación en mm y la intensidad en mm/h):

$$P_{t,T} = 32.2(1 + 1.3\log(T))(t + 0.4)^{0.242-1}t \quad (3.6)$$

$$I_{t,T} = 32.2(1 + 1.3\log(T))(t + 0.4)^{0.242-1} \quad (3.7)$$

Tabla 3.3: Duración de la precipitación (horas)

Nro	t (horas)	Nro	t (horas)
1	1.71	17	0.69
2	1.41	18	2.74
3	0.04	19	0.46
4	1.01	20	2.48
5	0.49	21	1.62
6	2.38	22	2.99
7	0.94	23	0.24
8	1.59	24	1.33
9	0.50	25	0.32
10	1.81	26	2.89
11	0.79	27	0.02
12	1.96	28	2.33
13	2.07	29	2.45
14	2.25	30	2.61
15	1.35	31	0.26
16	0.26	32	1.20

Fuente: Elaboración propia

Las consideraciones para la generación de las intensidades son los siguientes:

- La duración de la precipitación es generado teniendo en cuenta que la máxima es de tres horas.

- El tiempo de retorno en proyectos de drenaje pluvial urbano puede ser considerado entre dos y diez años, en consideración a las Recomendaciones del Reglamento Nacional de Edificaciones, el mismo reglamento recomienda evaluar la importancia de los proyectos y por ende el tiempo de retorno puede ser ampliado hasta 50 años, evaluando la sensibilidad e importancia y seguridad del proyecto elabora, en consecuencia se tomarán tiempos de retorno entre 10 y 50 años para la obtención de las intensidades.

Los tiempos de concentración generados (que son los mismos que la duración de la precipitación) se muestran en la tabla 3.3 y los periodos o tiempos de retorno considerados quedan establecidos en la tabla 3.4.

Tabla 3.4: Tiempos de retorno (años)

Nro	T (años)	Nro	T (años)
1	20	17	26
2	42	18	13
3	27	19	20
4	46	20	15
5	17	21	17
6	21	22	20
7	16	23	27
8	15	24	12
9	45	25	46
10	33	26	48
11	32	27	30
12	16	28	30
13	44	29	24
14	35	30	46
15	24	31	25
16	31	32	14

Fuente: Elaboración propia

Disponiendo de los tiempos de retorno y las duraciones de la precipitación igual al tiempo de concentración de la cuenca, se obtienen las intensidades de la precipitación, mostradas en la tabla 3.5.

Tabla 3.5: Intensidades de precipitación

Nro	I (mm/h)	Nro	I (mm/h)
1	49.43	17	85.65
2	63.85	18	33.13
3	171.76	19	96.62
4	78.39	20	36.50
5	91.70	21	49.40
6	40.11	22	34.22
7	66.12	23	129.04
8	48.69	24	51.04
9	109.63	25	130.04
10	52.59	26	41.60
11	83.30	27	181.43
12	42.91	28	43.85
13	50.93	29	40.48
14	46.29	30	44.19
15	58.78	31	124.37
16	129.87	32	56.49

Fuente: Elaboración propia

3.1.4. Superficie de drenaje

El tamaño de la cuenca hidrográfica urbana está limitado por las recomendaciones establecidas en el Reglamento Nacional de Edificaciones, así el método racional es aplicado para cuencas cuya superficie sea menor o igual de km^2 -estos valores igualmente son generados aleatoriamente en un rango de $0.01km^2$ (01 hectarea) hasta $13km^2$, los valores así obtenidos se muestran en la tabla 3.6.

3.1.5. Caudales máximos

Dispuesto los coeficientes de escorrentía, definido las intensidades de precipitaciones para una duración igual a los tiempos de concentración de las cuencas y definido las superficies y pendientes de las cuencas hidrográficas urbanas, se obtienen los caudales de máxima avenida a partir del modelo racional, expresado por la ecuación 3.8.

Tabla 3.6: Superficies de cuencas (en km^2)

Nro	A (km2)	Nro	A (km2)
1	10.15	17	8.44
2	5.07	18	9.52
3	3.15	19	8.42
4	5.26	20	5.87
5	1.26	21	7.12
6	1.72	22	3.86
7	12.25	23	9.68
8	12.43	24	2.46
9	7.48	25	8.93
10	0.79	26	2.39
11	3.06	27	4.80
12	4.60	28	8.14
13	10.68	29	10.15
14	0.21	30	1.06
15	0.57	31	12.08
16	2.21	32	10.09

Fuente: Elaboración propia

$$Q = \frac{C * i * A}{3.6} \quad (3.8)$$

Donde Q es el caudal de máxima avenida (en m^3/s), C es el coeficiente de escorrentía, i es a intensidad de la precipitación para una duración igual al tiempo de concentración de la cuenca (en mm/h), A es la superficie de la cuenca (en km^2).

Los caudales máximos obtenidos tomando como coeficiente de escorrentía las mostradas en la tabla 3.1, la intensidad de la precipitación determinada en la tabla 3.5 y las superficies de la cuenca, tabla 3.6. La tabla 3.7 muestra los caudales así obtenidos.

3.2. Diseño del modelo ANNMF

Disponiendo de los registros mostrados en la tabla 3.8 se procede con el diseño del modelo basado en redes neuronales artificiales de base radial, con fines de establecer

Tabla 3.7: Caudales de máxima avenida

Nro	Q(m ³ /s)	Nro	Q(m ³ /s)
1	51.41	17	151.78
2	48.77	18	64.20
3	64.43	19	147.07
4	70.78	20	44.85
5	16.75	21	71.59
6	17.65	22	15.25
7	202.03	23	133.01
8	56.19	24	33.17
9	177.63	25	132.67
10	5.46	26	8.88
11	40.70	27	160.70
12	35.96	28	86.54
13	137.87	29	83.84
14	1.54	30	5.53
15	8.72	31	225.33
16	39.45	32	94.87

Fuente: Elaboración propia

este diseño los datos disponibles se dividen en tres categorías, considerando en una primera etapa para el entrenamiento del modelo, datos requeridos para la validación del modelo y otro porcentaje de los datos iniciales para la prueba final.

El modelo ANNMF es el acrónimo de *Artificial Neural network and Maximum Flow*.

3.2.1. Registros de entrenamiento, validación y prueba final

De esta manera los registros obtenidos se dividen para cada etapa de la siguiente proporción:

- Para la etapa de entrenamiento se considera el 70 % de los registros disponibles.
- En la etapa de validación del modelo, se considera el 15 % del registro total.
- Para la prueba final se considera el 15 % restante del registro total de datos.

La selección de los registros de entrenamiento, validación y prueba final son selecciona-

dos aleatoriamente, teniendo cuidado que ninguno de los registros se repita en alguna etapa, garantizando de esta manera que el modelo siempre dispondrá de registros nuevos en las tres etapas definidas.

Tabla 3.8: Registros de entrenamiento, validación y prueba

Nro	C	I(mm/h)	A(km ²)	Q(m ³ /s)
1	0.37	49.43	10.15	51.41
2	0.54	63.85	5.07	48.77
3	0.43	171.76	3.15	64.43
4	0.62	78.39	5.26	70.78
5	0.52	91.70	1.26	16.75
6	0.92	40.11	1.72	17.65
7	0.90	66.12	12.25	202.03
8	0.33	48.69	12.43	56.19
9	0.78	109.63	7.48	177.63
10	0.47	52.59	0.79	5.46
11	0.57	83.30	3.06	40.70
12	0.66	42.91	4.60	35.96
13	0.91	50.93	10.68	137.87
14	0.57	46.29	0.21	1.54
15	0.94	58.78	0.57	8.72
16	0.50	129.87	2.21	39.45
17	0.76	85.65	8.44	151.78
18	0.73	33.13	9.52	64.20
19	0.65	96.62	8.42	147.07
20	0.75	36.50	5.87	44.85
21	0.73	49.40	7.12	71.59
22	0.42	34.22	3.86	15.25
23	0.38	129.04	9.68	133.01
24	0.95	51.04	2.46	33.17
25	0.41	130.04	8.93	132.67
26	0.32	41.60	2.39	8.88
27	0.66	181.43	4.80	160.70
28	0.87	43.85	8.14	86.54
29	0.73	40.48	10.15	83.84
30	0.42	44.19	1.06	5.53
31	0.54	124.37	12.08	225.33
32	0.60	56.49	10.09	94.87

Fuente: Elaboración propia

3.2.2. Arquitectura del modelo ANNMF

La arquitectura de los modelos de redes neuronales artificiales de base radial está dividido en tres categorías o capas: capa de entrada, capa oculta y la capa de salida. Cada capa está formado por neuronas y la selección del número de éstas es a prueba y error, seleccionado la arquitectura que responda mejor a las solicitudes requeridas.

3.2.2.1. Capa de entrada

El número de neuronas de la capa de entrada están condicionadas por el número de datos a procesar por el modelo, así los datos considerados para diseñar el modelo meta-heurístico son:

- X_1 : Coeficiente de escurrentía.
- X_2 : Intensidad de precipitación (en mm/h).
- X_3 : Superficie de la cuenca (en km^2 .)


Los registros generados y ordenados se muestran en la tabla 3.8, cada fila representa una muestra completa de datos requeridos y resultados a obtener. La figura 3.1 muestra la arquitectura general de un modelo de redes neuronales artificiales de base radial, en este caso particular será restringido a tres neuronas en la capa de entrada, siendo: $[X_1, X_2, X_3]$.

3.2.2.2. Capa oculta

Las redes neuronales artificiales de base radial se caracterizan por disponer de una única capa oculta, el número de neuronas en esta capa se elige a prueba y error, aquel arquitectura que responda de forma adecuada a los resultados requeridos, se efectuará varias pruebas incrementado sucesivamente el número de neuronas de la capa oculta,

es seleccionado el modelo que disponga el menor error cuadrático medio. La figura 3.1 muestra una única capa oculta y ésta sus componentes, las neuronas varían desde 1, 2, ..., m , siendo m el número máximo de neuronas donde error cuadrático medio es la más baja.

Figura 3.1: Arquitectura general de redes neuronales artificiales de base radial



Fuente: Elaboración propia

3.2.2.3. Capa de salida

El número de neuronas de ma capa de salida está condicionada por el número de resultados a obtener por el modelo, en este caso el único resultado perseguido es el caudal de máxima avenida, lo que se corresponde con una única neurona.

3.2.2.4. Arquitectura seleccionada

La arquitectura seleccionada queda establecida en la tabla 3.9, donde los únicos elementos que varían son las neuronas de la capa oculta.

Tabla 3.9: Arquitectura seleccionada

Descripción	Elementos
Capa de entrada	03 neuronas
Capa oculta	m neuronas
Capa de salida	01 neurona

Fuente: Elaboración propia

3.2.3. Parámetros iniciales

Los parámetros iniciales considerados para el modelo a diseñar son:

- Las funciones de entrada, activación y de transferencia se prueban con distintas funciones especificados en la sección 2.4.7 de la página 31, estas pruebas con distintas funciones se efectúan con la finalidad de obtener el mejor modelo basado en la evaluación del error medio cuadrático.
- Los pesos y los umbrales del modelo considerado son inicializados aleatoriamente, estos valores se corrigen para cada muestra considerada en el proceso de entrenamiento, y si es necesario se considera de igual manera los registros de la etapa de validación, los pesos y los umbrales se estabilizan cuando el modelo logró abstraer el fenómeno físico considerado.

Se considera en los modelos de redes neuronales artificiales de base radial, las conexiones que disponen de pesos son aquellas que unen las neuronas de la capa oculta y las neuronas de la capa de salida y únicamente disponen de umbrales las neuronas que se encuentran en la capa de salida.

Figura 3.2: Implementación para la etapa de entrenamiento desde MATLAB

```

EDITOR
4 - clear;
5 - clc;
6 - % PASO 01: btener los datos
7 - X= xlsread('ANNMFtraining.xlsx',1);
8 - Y= xlsread('ANNMFtraining.xlsx',2);
9 - %datos= xlsread('rrr.xlsx',1);
10
11 %X=X(:,1)+X(:,2)+X(:,3)+X(:,4)+X(:,5);
12
13 %PASO 04: configurar red de base radial y ejecutar
14 - P=X'; % patrones de entrada
15 - T=Y'; % patrones de salida deseadas
16 - GOAL= 0; % error cuadrático medio objetivo
17 - SPREAD=12; %difusión de las funciones de base radial
18 - MN=20; % máximo número de neuronas en la capa oculta
19 - n=1; % incremento de neuronas
20 - net = newrb(P,T,GOAL,SPREAD,MN,n);
21
22
23
script Ln 25 Col 16

```

Fuente: Elaboración propia

3.2.4. Proceso de aprendizaje

Definido la arquitectura y los parámetros del modelo ANNMF, el siguiente paso es obtener el modelo definitivo, para ello se utiliza las rutinas implementadas en *MATLAB R2016a*, aquellas correspondientes al diseño y análisis de las redes neuronales artificiales de base radial. El código fuente 3.1 muestra la implementación realizada para el diseño del modelo ANNMF (Artificial Neural Network and Maximun Flow).

Listing 3.1: Entrenamiento del modelo

```

1 % nntool
2 % nnstart
3 clear;
4 clc;
5 % PASO 01: btener los datos
6 X= xlsread('ANNMFtraining.xlsx',1);
7 Y= xlsread('ANNMFtraining.xlsx',2);
8 %datos= xlsread('rrr.xlsx',1);

```

```

9  %X=X(:,1)+X(:,2)+X(:,3)+X(:,4)+X(:,5);
10 %PASO 04: configurar red de base radial y ejecutar
11 P=X'; % patrones de entrada
12 T=Y'; % patrones de salida deseadas
13 GOAL= 0; % error cuadratico medio objetivo
14 SPREAD=12; %difusion de las funciones de base radial
15 MN=20; % maximo numero de neuronas en la capa oculta
16 n=1; % incremento de neuronas
17 net = newrb(P,T,GOAL,SPREAD,MN,n);

```

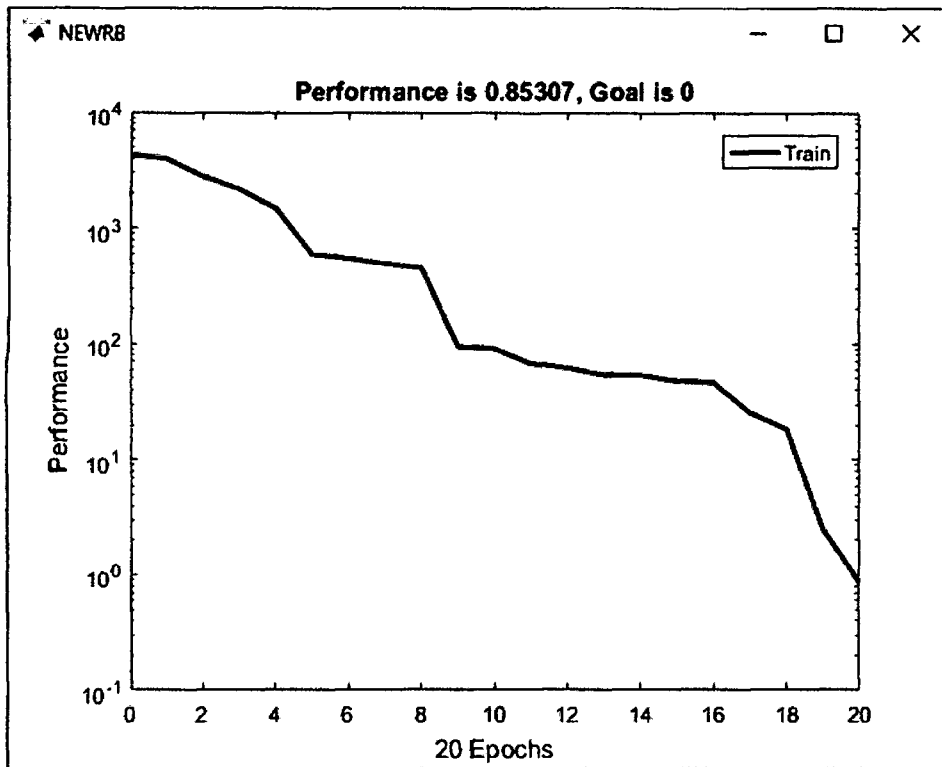
La figura 3.2 muestra la implementación del script (guión) en MATLAB, el diseño se efectúa a prueba y error, se inicia con una mínima cantidad de neuronas en la capa oculta, incrementando cada vez y evaluando el error cuadrático medio para cada modelo así definido, la figura 3.3 muestra la variación del error cuadrático medio para cada incremento de neuronas en la capa oculta, obteniendo para 20 neuronas que componen la capa oculta un error medio cuadrático de 0.85307. La arquitectura y los parámetros del modelo obtenidos serán sometidos a pruebas a nivel de confiabilidad, validez y objetividad con la finalidad verificar objetivamente el modelo obtenido.

3.2.5. Evaluación del aprendizaje

Definido los argumentos de ingreso y los resultados requeridos, el siguiente procedimiento es el entrenamiento del modelo, nos interesa particularmente medir el aprendizaje del modelo con la arquitectura seleccionada previamente; en la presente tesis se evalúa únicamente el aprendizaje mediante la variación de la medida del error cuadrático medio, así se disponen de diferentes errores para distintas configuraciones variando el número de neuronas de la capa oculta de la red neuronal artificial de base radial.

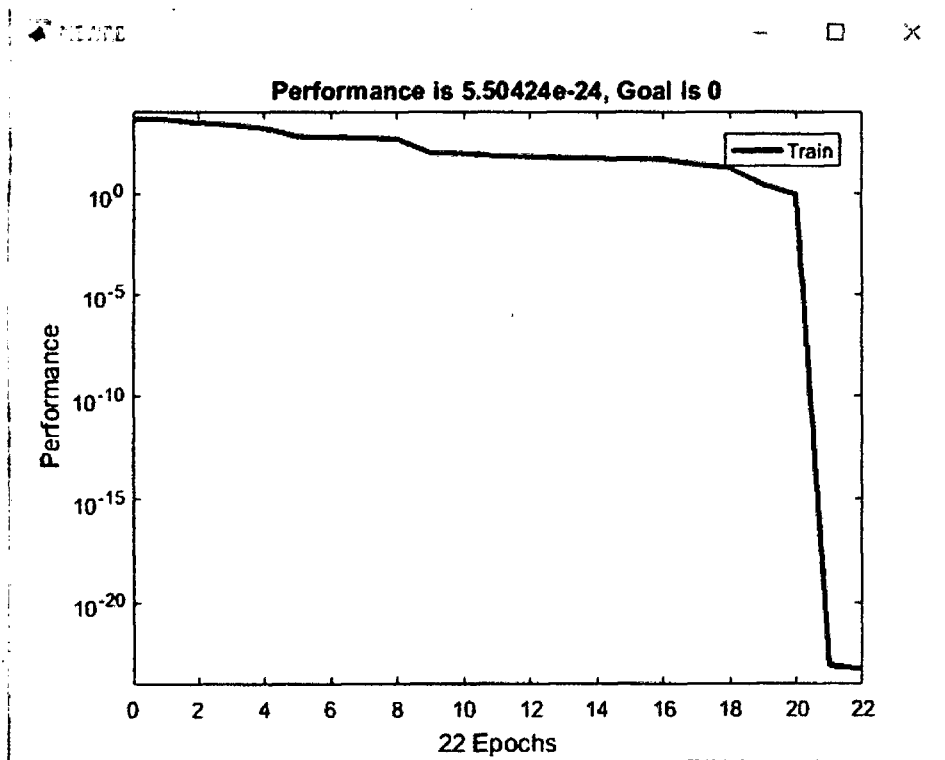
- La figura 3.3 muestra la variación del error cuadrático medio en función del número de neuronas en la capa oculta (en este caso se corresponde con el número de ciclos de aprendizaje); encontrándose para veinte épocas (epochs) con veinte

Figura 3.3: Variación del error cuadrático medio (20 neuronas en la capa oculta)



Fuente: Elaboración propia

Figura 3.4: Variación del error cuadrático medio (22 neuronas en la capa oculta)



Fuente: Elaboración propia

neuronas en la capa oculta un error cuadrático medio igual a 0.85307.

- La figura 3.4 muestra la evolución del aprendizaje para determinado para 22 ciclos (épocas), encontrándose un error cuadrático medio a nivel de $5.50424 \cdot 10^{-24}$, que representa un grado de aprendizaje superior, dado que este valor es muy pequeño.

Figura 3.5: Variación del error cuadrático medio (dependencia de la variación del número de neuronas de la capa oculta)

```
Command Window
NEWRB, neurons = 0, MSE = 4261.99
NEWRB, neurons = 2, MSE = 2801.79
NEWRB, neurons = 3, MSE = 2190.06
NEWRB, neurons = 4, MSE = 1491.93
NEWRB, neurons = 5, MSE = 596.013
NEWRB, neurons = 6, MSE = 547.173
NEWRB, neurons = 7, MSE = 492.44
NEWRB, neurons = 8, MSE = 449.965
NEWRB, neurons = 9, MSE = 94.1383
NEWRB, neurons = 10, MSE = 89.6717
NEWRB, neurons = 11, MSE = 67.3527
NEWRB, neurons = 12, MSE = 61.7162
NEWRB, neurons = 13, MSE = 53.7576
NEWRB, neurons = 14, MSE = 53.252
NEWRB, neurons = 15, MSE = 47.6894
NEWRB, neurons = 16, MSE = 46.0024
NEWRB, neurons = 17, MSE = 25.3969
NEWRB, neurons = 18, MSE = 18.3078
NEWRB, neurons = 19, MSE = 2.49983
NEWRB, neurons = 20, MSE = 0.85307
NEWRB, neurons = 21, MSE = 8.05706e-24
NEWRB, neurons = 22, MSE = 5.50424e-24
fx >> |
```

Fuente: Elaboración propia


- La figura 3.4 muestra la evolución del aprendizaje del modelo ANNMF (Artificial Neural Network and Maximun Flow), mostrando para cada ciclo de aprendizaje el error cuadrático medio, en este modelo, el número de los ciclos de aprendizaje

se encuentran en correspondencia con el número de neuronas de la capa oculta.

3.2.6. Validación del modelo

La validación del modelo se efectúa con los registros reservados con esta finalidad, representando el 15% de los registros generados totales, la figura 3.1 muestra la evaluación del modelo gráficamente con fines de comparación de los resultados obtenidos y generados (registrados).

Figura 3.6: Etapa de validación del modelo




Fuente: Elaboración propia

3.2.7. Prueba final (test)

La prueba final se realiza con los registros reservados con esta finalidad, la figura 3.7 muestra la evaluación del modelo evaluado con los registros de prueba final, donde se

observa en algunos casos una discrepancia considerable comparando los resultados obtenidos con los caudales generados (o registrados), en consecuencia es necesario buscar otra arquitectura para el modelo ANNMF considerando en la etapa de entrenamiento los datos de la propia etapa de entrenamiento y validación.

Figura 3.7: Prueba final



Fuente: Elaboración propia

El mejor modelo se obtiene a prueba y error, el modelo obtenido en un primer momento puede tener el error medio cuadrático muy bajo, señal de buen aprendizaje del modelo, pero muy a pesar de este indicador el modelo es incapaz de generar los resultados adecuados a nivel de las etapas de validación y la prueba final, es necesario buscar otro modelo que cumpla todas las condiciones.

Capítulo 4

Análisis de los resultados

Este capítulo contiene la descripción detallada del modelo obtenido y su análisis a nivel de confiabilidad, validez y objetividad, seguidamente se efectúa una aplicación práctica para la obtención de caudales máximos en cuencas urbanas.

4.1. Resultados obtenidos

El resultado de la investigación es el modelo ANNMF (Artificial Neural Network an Maximun Flow), modelo basado en redes neuronales artificiales de base radial, seguidamente se describe todos sus componentes del modelo meta-heurístico.


4.1.1. Modelo ANNMF

El modelo ANNMF es el acrónimo de *Artificial Neural Network an Maximun Flow*, modelo basado en la meta-heurística, específicamente en las redes neuronales artificiales en su modelo de base radial, la finalidad del modelo es obtener los caudales de máxima avenida en cuencas urbanas, aquellas definidas y consideradas en proyectos de drenaje pluvial en concordancia al Reglamento Nacional de Edificaciones.

4.1.2. Arquitectura del modelo ANNMF

La arquitectura del modelo final queda definido en la figura 4.1, las capas de entrada y de salida son condicionadas por el fenómeno físico analizado, datos necesarios y resultados requeridos.

Figura 4.1: Arquitectura del modelo ANNMF



Fuente: Elaboración propia

4.1.2.1. Capa de entrada

Condicionado por el número de datos que recibe el modelo, en este caso tres datos por cada muestra y son: Coeficiente de escorrentía, Intensidad de la precipitación (para una duración igual al tiempo de concentración de la cuenca) y la superficie de la cuenca

analizada. La capa de entrada del modelo final considerado se muestra en la figura 4.1.

4.1.2.2. Capa oculta

La capa oculta del modelo ANNMF contiene 20 neuronales ($m = 20$), la cantidad de las neuronas que componen la capa oculta del modelo se elige en consideración al adecuado comportamiento en la evaluación de la validación del modelo y la prueba final, además considerando el mínimo error cuadrático medio. La figura 4.1 muestra las neuronas dispuestas en la capa oculta.

4.1.2.3. Capa de salida

Que corresponde con el número de resultados esperado, en este caso el único resultado buscado es el caudal máximo en cuencas urbanas, por tanto queda constituido por una sola neurona como queda especificado en la figura 4.1.

4.1.3. Funciones de entrada, activación y de transferencia

Para una mejor organización, las funciones de entrada, activación y de transferencia será clasificado tomando el cuenta las capas del modelo ANNMF, y son:

- La capa de entrada no realiza ninguna función más que transmitir la información recibida a la capa oculta, en consecuencia a este nivel no se requiere de las funciones de entrada activación y transferencia.
- Las neuronas de la capa oculta son activadas y procesan la información en base a las funciones de activación de base radial, el modelo ANNMF utiliza específicamente la función de activación Gausiana, mostrada en la Ecuación 2.9 de la página 31 y estos valores son transferidos sin ningún cambio a las neuronas de la capa de salida.

- Las neuronas de la capa de salida procesan toda la información proveniente desde las capas ocultas de conforme a una función lineal.

4.1.4. Parámetros

Los parámetros del modelo ANNMF son: centros de las funciones de base radial, amplitud e las funciones de base radial, pesos de las conexiones y los umbrales.

4.1.4.1. Centros de los funciones de base radial

Tabla 4.1: Centro de las funciones de base radial del ANNMF

Neurona	C1	C2	C3
1	0.898216	66.11511	12.24724
2	0.539796	124.3738	12.08272
3	0.66478	181.4275	4.796615
4	0.650432	96.62499	8.42422
5	0.734964	40.47699	10.14515
6	0.938984	58.77868	0.568879
7	0.495946	129.8701	2.20518
8	0.520671	91.69692	1.262944
9	0.755714	85.64966	8.44201
10	0.415786	34.21627	3.859207
11	0.33424	48.68661	12.43019
12	0.428777	171.7625	3.14957
13	0.574843	83.30386	3.059791
14	0.599472	56.48524	10.08651
15	0.411229	130.0375	8.931213
16	0.369041	49.43218	10.14547
17	0.321191	41.5998	2.39381
18	0.91856	40.11001	1.724333
19	0.733243	49.39579	7.115646
20	0.873213	43.84824	8.136785
21	0.571534	46.28801	0.210091
22	0.423782	44.19444	1.063824

Fuente: Elaboración propia

Los centros de las funciones de base radial, está representado por una matriz C , de orden $(m * p)$, siendo m el número de neuronas de la capa oculta y p el número de

datos de entrada por cada muestra, que coincide con el número de neuronas de la capas de entrada, estos valores son inicializados aleatoriamente, luego se corrige para cada muestra. Para el modelo ANNMF el centro de las funciones de base radial se muestra en la tabla 4.1.

4.1.4.2. Amplitud de las funciones de base radial

Es un parámetro relacionado con cada neurona de la capa oculta, está representado por un vector d y su orden es $(m * 1)$, siendo m el número de neuronas de la capa oculta. Las amplitudes son obtenidos luego de haber obtenido los centros de las funciones de base radial mostradas en la tabla 4.1 mediante la relación 2.14 de la página 35.

4.1.4.3. Pesos de las conexiones

Es una matriz de orden $W(m * r)$, siendo m el número de neuronas de la capa oculta y r el número de neuronas de la capa de salida, en este caso particular es del orden de $(22 * 1)$, cuyos valores obtenidos se muestran en la tabla 4.2.

4.1.4.4. Umbrales

Otra propiedad de las redes neuronales de base radial y que diferencia de los otros modelos de redes neuronales artificiales es la disponibilidad del umbral únicamente en las neuronas de la capa de salida, para el modelo ANNMF en la única neurona disponible en la capa de salida existe una valor umbral de 756.7617.

4.1.5. Limitaciones del modelo ANNMF

Las limitaciones del modelo ANNMF son las siguientes:

Tabla 4.2: Pesos de las conexiones

Neurona capa oculta	Pesos $\cdot 10^4$	Neurona capa de salida
1	-0.06855	1
2	-0.02864	1
3	-0.02656	1
4	-0.03866	1
5	-0.22992	
6	-0.10336	1
7	-0.07032	1
8	-0.03106	1
9	0.038691	1
10	-0.0594	1
11	0.608349	1
12	-0.0525	1
13	-0.05614	1
14	0.218081	1
15	0.01775	1
16	-1.6544	1
17	-0.209	1
18	0.145756	1
19	0.834139	1
20	0.491646	1
21	-0.18471	1
22	0	1

Fuente: Elaboración propia

- El modelo determinado está sujeto a la confiabilidad, validez y objetividad determinados en la sección 4.2.
- El modelo únicamente obtiene los caudales de máxima avenida para cuenca urbanas, restringido en su aplicación a lo establecido de acuerdo al Reglamento Nacional de Edificaciones.
- Para su uso extendido es conveniente calibrar el modelo ANNMF con registros empíricos (directamente obtenidos).

4.2. Análisis del modelo ANNMF

El análisis del modelo ANNMF (Artificial Neural Network and Maximun Flow), se realiza a nivel de la confiabilidad, validez y objetividad.

4.2.1. Confiabilidad

La confiabilidad de un modelo se refiere al grado que su aplicación repetida al mismo patrón de muestra devolverá siempre los mismos resultados. Se obtendrán los coeficientes de confiabilidad de Pearson, Kendall y Spearman, disponiendo de los resultados obtenidos en base al modelo o método racional y el modelo ANNMF, la tabla 4.4 muestra los coeficientes obtenidos, lo que indica valores adecuados de correspondencia en cuanto a los resultados obtenidos.

Tabla 4.3: Coeficientes de confiabilidad

Descripción	Coefficientes de correlación
Pearson	0.86541
kendall	0.82674
Spearman	0.85562

Tabla 4.4: Fuente: Elaboración propia

La interpretación de estos indicadores de confiabilidad, es dependiendo de los valores obtenidos, cuanto más se acerque a la unidad mejor será la confiabilidad del modelo obtenido.

4.2.2. Validez

La validez, en términos generales, se refiere al grado en que un instrumento mide realmente la variable que pretende medir. Para verificar la validez se debe demostrar que los resultados obtenidos representan realmente los caudales de máxima avenida requeridos, para probar esta incertidumbre existen varios métodos, entre ellos:

- Evidencia relacionada con el contenido.
- Evidencia relacionada con el criterio.
- Evidencia relacionada con el constructo.

Evaluando la evidencia relacionada con el contenido, se refiere a la representación del dominio de existencia de las variables de análisis, en este caso todas las variables que intervienen en el análisis para la obtención del caudal y el caudal mismo, desde la tabla 4.6 se observa que los caudales obtenidos se encuentran dentro del dominio de los resultados obtenidos en base al método racional, la tabla 4.5 muestra el dominio de existencia de los resultados obtenidos.

Tabla 4.5: Caudales máximos y mínimos

Descripción	Caudal (m ³ /s)
Máximo	11.03
Mínimo	0.54

Fuente: Elaboración propia

La evaluación de la validez verificada con la evidencia relacionada con el criterio, se establece al comparar los resultados obtenidos de un modelo con los registros o resultados de otros modelos que mide la misma variable, en este caso se comprara los resultados

obtenidos del modelo ANNMF con los del método racional, encontrándose resultados muy similares, mostrados en la tabla 4.6.

4.2.3. Objetividad

La objetividad se refiere al grado en que el modelo es o no permeable a la influencia de los sesgos y tendencias de los investigadores que lo administran, califican e interpretan. En este caso la objetividad está relacionado con el error que se comete en el entrenamiento del modelo, el error cuadrático medio, a un nivel de $8.05706 * 10^{-24}$.

4.3. Aplicación práctica

El área de estudio está ubicada en la margen derecho del río Alameda en el área urbana del distrito de Carmen Alto y tiene la siguiente ubicación política:

Tabla 4.6: Caudales obtenidos

Microcuenca	C	I(mm/h)	A (Km ²)	Q (m ³ /s)	Q (m ³ /s) INNMF
SC-01	0.87	101.42	0.441	10.81	11.03
SC-02	0.88	105.24	0.246	6.33	5.42
SC-03	0.76	122.18	0.247	6.37	6.01
SC-04	0.95	108.08	0.075	2.14	2.22
SC-05	0.95	131.18	0.038	1.31	1.23
SC-06	0.93	123.32	0.107	3.40	3.46
SC-07	0.93	125.27	0.095	3.06	3.12
SC-08	0.93	128.76	0.079	2.61	2.68
SC-09	0.91	130.81	0.099	3.29	3.24
SC-10	0.93	126.85	0.111	3.64	3.65
SC-11	0.94	141.32	0.019	0.72	0.73
SC-12	0.93	139.48	0.016	0.57	0.54

Fuente: Elaboración propia

- Lugar: Área urbana de Distrito de Carmen Alto.
- Distrito: Carmen Alto.

- Provincia: Huamanga.

- Departamento: Ayacucho.

La delimitación de las sub-cuencas, identificación de los coeficientes de escorrentía, propiedades morfométricas de la cuenca, obtención de todos los datos requeridos fueron procesados en base a los planos actuales adjuntados en los anexos de la presente investigación. Los resultados obtenidos con el modelo ANNMF se muestra en la tabla 4.6, de igual manera se muestran los resultados mediante el método racional para la zonas especificadas.

Capítulo 5

Conclusiones y recomendaciones

En el presente capítulo se establecen las conclusiones del desarrollo de la tesis.

5.1. Conclusiones

En relación al objetivo general planteado:

- Se diseñó el modelo ANNMF (Artificial Neural Network and Maximun Flow), modelo meta-heurístico basado en los modelos de redes neuronales artificiales de base radial, para la determinación de caudales de máxima avenida en cuencas urbanas y todo proyecto de drenaje, el modelo dispone de una confiabilidad medida en correspondencia al coeficiente de Kendall de 0.82674, la validez evaluada en correspondencia a la evidencia de contenido, encontrando los caudales obtenidos dentro del dominio de los registros de entrenamiento y la validez relacionada con el criterio, cuya comparación se efectúa con los resultados del método racional, encontrándose valores muy similares; la objetividad se encuentra asociada al error cuadrático medio que se obtiene en el entrenamiento del modelo, que es igual a $8.05706 * 10^{-24}$.

Teniendo en cuenta los objetivos secundarios:

- Es fundamental obtener las propiedades morfométricas de la cuenca analizada, dado que el modelo ANNMF estima el caudal de máxima avenida asociada a la superficie, intensidad de la precipitación para una duración igual al tiempo de concentración de la cuenca y las propiedades de uso de suelo de la cuenca es estudio.
- El registro de las precipitaciones es determinante, se ha considerado las precipitaciones de corta duración, menores a tres horas, dado que son las que generan mayores intensidades, el modelo ANNMF requiere de la determinación de la intensidad máxima para una determinada tormenta.
- El coeficiente de escurrimiento se encuentra directamente relacionado con los usos de suelo de la cuenca hidrográfica analizada, el modelo ANNMF requiere este parámetro como argumento de entrada con fines de generar los caudales de máxima avenida.
- Los resultados del modelo ANNMF, al ser comparados con las obtenidas por el método racional, se obtienen resultados muy similares.

5.2. Recomendaciones

El uso del modelo ANNMF es general con fines de estimar los caudales de máxima avenida para proyectos de drenaje pluvial, las limitaciones en cuanto a la superficie de la cuenca, se encuentra restringido a lo especificado por el Reglamento Nacional de Edificaciones.

Referencias bibliográficas

- [1] Michael Arbib. *The handbook of brain theory and neural networks*. Cambridge, Mass: MIT Press, 2003. ISBN: 0-262-01197-2.
- [2] Philip B Bedient y Wayne Charles Huber. *Hydrology and floodplain analysis*. Addison-Wesley, 1988.
- [3] Graeme F Bonham-Carter. *Geographic information systems for geoscientists: modelling with GIS*. Vol. 13. Elsevier, 2014.
- [4] Manuel Carchado. *Redes Neuronales Artificiales: Un enfoque práctico*. Universidad de Vigo, 2000. ISBN: 8481581453.
- [5] Hugh Cartwright. *Artificial neural networks*. New York, NY: Springer, 2015. ISBN: 978-1-4939-2238-3.
- [6] Christian W Dawson y Robert Wilby. "An artificial neural network approach to rainfall-runoff modelling". En: *Hydrological Sciences Journal* 43.1 (1998), págs. 47-66.
- [7] Eduardo De Robertis D. P., Jose Hib y Roberto Ponzio. *Biología celular y molecular - Cellular and Molecular Biology (Spanish Edition)*. El Ateneo, 2006. ISBN: 9500203847.
- [8] Derek C Ford y Paul W Williams. *Karst geomorphology and hydrology*. Vol. 601. Unwin Hyman London, 1989.
- [9] Stewart Fotheringham y Peter Rogerson. *Spatial analysis and GIS*. CRC Press, 2013.
- [10] Lynn W Gelhar. *Stochastic subsurface hydrology*. Prentice-Hall, 1993.

- [11] Muriel Gevrey, Ioannis Dimopoulos y Sovan Lek. "Review and comparison of methods to study the contribution of variables in artificial neural network models". En: *Ecological modelling* 160.3 (2003), págs. 249-264.
- [12] Nancy D Gordon, Brian L Finlayson y Thomas A McMahon. *Stream hydrology: an introduction for ecologists*. John Wiley y Sons, 2004.
- [13] Daniel Graupe. *Principles of Artificial Neural Networks (3rd Edition)*. World Scientific Publishing Company, 31 de jul. de 2013. 382 Seiten. ISBN: 9814522732. URL: http://www.ebook.de/de/product/21005002/daniel_graupe_principles_of_artificial_neural_networks_3rd_edition.html.
- [14] Daniel Graupe. *Principles of Artificial Neural Networks (Advanced Series in Circuits and Systems)*. World Scientific Publishing Company, 2007. ISBN: 9812706240.
- [15] Kevin Gurney. *An Introduction to Neural Networks*. CRC Press, 1997. ISBN: 1857285034.
- [16] Charles Thomas Haan. "Statistical methods in hydrology". En: (2002).
- [17] Martin T. Hagan, Howard B. Demuth, Mark H. Beale y col. *Neural network design*. Pws Boston, 1996.
- [18] Martin T Hagan y col. *Neural network design*. Vol. 20. PWS publishing company Boston, 1996.
- [19] Robert Harvey. *Neural network principles*. Englewood Cliffs, NJ: Prentice Hall, 1994. ISBN: 0130633305.
- [20] Mohamad Hassoun. *Fundamentals of Artificial Neural Networks*. A Bradford Book, 2003. ISBN: 0262514672.
- [21] Mohamad H Hassoun. *Fundamentals of Artificial Neural Networks*. MIT University Press Group Ltd, 11 de mar. de 1995. ISBN: 0262514672. URL: http://www.ebook.de/de/product/9606327/mohamad_h_hassoun_fundamentals_of_artificial_neural_networks.html.

- [22] Jose Ramon Hilera Gonzalez. *Redes neuronales artificiales: Fundamentos, modelos y aplicaciones (Serie Paradigma) (Spanish Edition)*. RA-MA, 1995. ISBN: 8478971556.
- [23] Kuo-lin Hsu, Hoshin Vijai Gupta y Soroosh Sorooshian. "Artificial neural network modeling of the rainfall-runoff process". En: *Water resources research* 31.10 (1995), págs. 2517-2530.
- [24] Pedro Isasi Viñuela e Inés M. Galván León. *Redes de Neuronas Artificiales - Un Enfoque Practico (Spanish Edition)*. Ed. por Pearson Prentice Hall. Pearson Educación, 2005. ISBN: 8420540250.
- [25] L. C. Jain. *Recent advances in artificial neural networks : design and applications*. Boca Raton: CRC Press, 2000. ISBN: 0-8493-2268-5.
- [26] Gerald Karp. *Biología Celular y Molecular*. Mc Graw-Hill, 2010. ISBN: 6071505046.
- [27] Ray K Linsley Jr, Max Adam Kohler y Joseph LH Paulhus. "Hydrology for engineers". En: (1975).
- [28] Raquel Flórez López y José Miguel Fernández Fernández. *Las Redes Neuronales Artificiales (Spanish Edition)*. NetBiblo S.L., 2008. ISBN: 8497452461.
- [29] David R Maidment y col. *Handbook of hydrology*. McGraw-Hill Inc., 1992.
- [30] Jacek Malczewski. *GIS and multicriteria decision analysis*. John Wiley & Sons, 1999.
- [31] Helena Mitsova y col. "Modelling spatially and temporally distributed phenomena: new methods and tools for GRASS GIS". En: *International Journal of Geographical Information Systems* 9.4 (1995), págs. 433-446.
- [32] Khare Mukensh y S. M. Shire Nagendra. *Artificial Neural Network in Vehicular Pollution Modeling*. Springer, 2007.
- [33] Markus Neteler y Helena Mitsova. *Open source GIS: a GRASS GIS approach*. Vol. 689. Springer Science & Business Media, 2013.
- [34] Markus Neteler y col. "GRASS GIS: A multi-purpose open source GIS". En: *Environmental Modelling & Software* 31 (2012), págs. 124-130.

- [35] VICTOR Olaya. "A gentle introduction to SAGA GIS". En: *The SAGA User Group eV, Gottingen, Germany* 208 (2004).
- [36] Brandon Plewe. *GIS online: Information retrieval, mapping, and the Internet*. OnWord Press, 1997.
- [37] Jha Raghunath. "Potential erosion map for Bagmati basin using GRASS-GIS". En: *Proceedings of the Open Source GIS-GRASS users conference*. 2002, págs. 11-13.
- [38] Mark Rubin G. y Joseph Safdieh E. *Netter. Neuroanatomía esencial (Spanish Edition)*. Elsevier Masson, 2008.
- [39] GIS SAGA. "System for automated geoscientific analyses". En: *Available at: www.saga-gis.org/en/index.html* (2013).
- [40] Edgar Sánchez Camperos y Alma Yolanda Alanís García. *Redes Neuronales: Conceptos Fundamentales y Aplicaciones a Control Automatico*. PEARSON, 2010. ISBN: 8483222957.
- [41] Vijay P Singh y col. *Computer models of watershed hydrology*. Water Resources Publications, 1995.
- [42] Kenji Suzuki. *Artificial Neural Networks: Architectures and Applications*. Intech, 2014. ISBN: 9535109359.
- [43] Ryszard Tadeusiewicz. *Exploring neural networks with C*. Boca Raton, FL: CRC Press, 2015. ISBN: 1482233398.
- [44] David Keith Todd, Larry W Mays y col. "Groundwater hydrology". En: (1980).
- [45] Baxter E Vieux y Nalneesh Gauer. "Finite-Element Modeling of Storm Water Runoff Using GRASS GIS". En: *Computer-Aided Civil and Infrastructure Engineering* 9.4 (1994), págs. 263-270.
- [46] Michael F Worboys y Matt Duckham. *GIS: a computing perspective*. CRC press, 2004.
- [47] B. Yegnanarayana. *Artificial Neural Networks*. Prentice-Hall of India Pvt.Ltd, 2004. ISBN: 8120312538.

- [48] Daniel Yeung. *Sensitivity analysis for neural networks*. Heidelberg New York: Springer, 2010. ISBN: 978-3-642-02531-0.
- [49] Vujica Yevjevich y col. *Probability and statistics in hydrology*. TC153. Y48 1982. Water resources publications Fort Collins, CO, 1972.

Anexo A

Código fuente MATLAB

El diseño del modelo ANNMF (Artificial Neural Network and Maximun Flow) se realiza desde MATLAB, los script (guiones) necesarios para la etapa de generación de los registros, identificación de los datos de entrenamiento, validación y prueba final, y las etapas de entrenamiento, validación y prueba se presentan en el anexo presente.

A.1. Generación de coeficientes de escorrentía

Los coeficientes de escorrentía son generados aleatoriamente teniendo especial consideración y cuidado que no se repitan los valores ya generados.

Listing A.1: Generación de coeficientes de escorrentía

```
1 n=32;
2 C=zeros(n,1);
3 j=1;
4 while (j <= n)
5     a=rand()*0.65+0.3;
6     if ((C==a)==0)
7         C(j)=a;
```

```
8   j=j+1;
9   end
0 end
```

A.2. Generación de tiempos de concentración

Los tiempos de concentración son generados aleatoriamente, teniendo en cuenta precipitaciones menores a tres horas, estos tiempos de concentración son considerados como duraciones de la precipitación para la obtención de los caudales máximos.

Listing A.2: Generación de tiempos de concentración

```
1 n=32;
2 t=zeros(n,1);
3 j=1;
4 while (j <= n)
5     a=rand()*2.995+0.005;
6     if ((t==a)==0)
7         t(j)=a;
8         j=j+1;
9     end
0 end
```

A.3. Generación del periodo de retorno

Asociado a la seguridad de las estructuras hidráulicas, los tiempos de retorno considerados son entre 10 y 50 años, por tratarse exclusivamente a obras de drenaje.

Listing A.3: Generación de los periodos de retorno

```

1 n=32;
2 T=zeros(n,1);
3 j=1;
4 while (j <= n)
5     a=rand()*40.00+10.00;
6     if ((T==a)==0)
7         T(j)=a;
8         j=j+1;
9     end
10 end

```

A.4. Generación de las superficies

Las superficies asociadas a las cuencas hidrográficas son generadas tomando como mínimo $01ha$ y como máximo $13km^2$, como recomienda el Reglamento Nacional de edificaciones.

Listing A.4: Generación de los periodos de retorno

```

1 n=32;
2 A=zeros(n,1);
3 j=1;
4 while (j <= n)
5     a=rand()*12.99+0.01;
6     if ((A==a)==0)
7         A(j)=a;
8         j=j+1;
9     end
10 end

```

A.5. Datos de entrenamiento, validación y prueba

La selección de los datos de entrenamiento, validación y prueba final se realiza de forma aleatoria

Listing A.5: Datos de entrenamiento validación y prueba

```
1 clear;
2 clc;
3 datosv= xlsread('ANNMFdatos.xlsx',1,'A2:C33');
4 datosns= xlsread('ANNMFdatos.xlsx',1,'D2:D33');
5 n=size(datosv,1);
6 [trainInd,valInd,testInd] = dividerand(n,0.70,0.15,0.15);
7 n=length(trainInd);
8 trainV=zeros(n,3);
9 trainNS=zeros(n,1);
10 for i=1:n
11 a= trainInd(i);
12 trainV(i,1)= datosv(a,1);
13 trainV(i,2)= datosv(a,2);
14 trainV(i,3)= datosv(a,3);
15 trainNS(i,1)= datosns(a,1);
16 end
17 n=length(valInd);
18 valV=zeros(n,3);
19 valNS=zeros(n,1);
20 for i=1:n
21 a= valInd(i);
22 valV(i,1)= datosv(a,1);
23 valV(i,2)= datosv(a,2);
24 valV(i,3)= datosv(a,3);
25 valNS(i,1)= datosns(a,1);
26 end
27 n=length(testInd);
```

```

28 testV=zeros(n,3);
29 testNS=zeros(n,1);
30 for i=1:n
31 a= testInd(i);
32 testV(i,1)= datosv(a,1);
33 testV(i,2)= datosv(a,2);
34 testV(i,3)= datosv(a,3);
35 testNS(i,1)= datosns(a,1);
36 end
37 xlswrite('ANNMFtraining.xlsx',trainV,1);
38 xlswrite('ANNMFtraining.xlsx',trainNS,2);
39 xlswrite('ANNMFvalidation.xlsx',valV,1);
40 xlswrite('ANNMFvalidation.xlsx',valNS,2);
41 xlswrite('ANNMFtesting.xlsx',testV,1);
42 xlswrite('ANNMFtesting.xlsx',testNS,2);

```

A.6. Entrenamiento del modelo

Para el entrenamiento del modelo se utiliza el módulo *neurb*, lo que a partir de los datos, resultados y la arquitectura señalada devuelve el modelo y todos sus parámetros incluido el error cuadrático medio.

Listing A.6: Entrenamiento del modelo

```

1 % nntool
2 % nnstart
3 clear;
4 clc;
5 % PASO 01: btener los datos
6 X= xlsread('ANNMFtraining.xlsx',1);
7 Y= xlsread('ANNMFtraining.xlsx',2);
8 %datos= xlsread('rrr.xlsx',1);

```

```

9
10 %X=X(:,1)+X(:,2)+X(:,3)+X(:,4)+X(:,5);
11
12 %PASO 04: configurar red de base radial y ejecutar
13 P=X'; % patrones de entrada
14 T=Y'; % patrones de salida deseadas
15 GOAL= 0; % error cuadratico medio objetivo
16 SPREAD=1; % difusion de las funciones de base radial
17 MN=12; % maximo numero de neuronas en la capa oculta
18 n=1; % incremento de neuronas
19 net = newrb(P,T,GOAL,SPREAD,MN,n);

```

A.7. Validación gráfica

La validación del modelo gráficamente se efectúa mediante el código fuente A.7.

Listing A.7: Entrenamiento del modelo

```

1 % nntool
2 % nnstart
3 %clear;
4 clc;
5 % PASO 01: btener los datos
6 X= xlsread('ANNMFvalidation.xlsx',1);
7 Y= xlsread('ANNMFvalidation.xlsx',2);
8
9 %X=X(:,1)+X(:,2)+X(:,3)+X(:,4)+X(:,5);
10
11 %PASO 04: configurar red de base radial y ejecutar
12 P=X'; % patrones de entrada
13 T=Y'; % patrones de salida deseadas
14 %GOAL= 0; % error cuadratico medio objetivo
15 %SPREAD=1; %difusion de las funciones de base radial

```

```

16 %MN=862; % maximo numero de neuronas en la capa oculta
17 %n=1; % incremento de neuronas
18 %net = newrb(P,T,GOAL,SPREAD,MN,n);
19
20 Y1=sim(net,P);
21 [f c] = size(X);
22 x=1:f;
23
24 % PLOTS
25 hold on; % graficas anadidas
26 %plot(ts1,'Displayname','Error cuadratico medio','linewidth',2);
27 plot(x,Y,'Displayname','Caudal generado (m^3/s)');
28 plot(x,Y1,'Displayname','Caudal obtenido (m^3/s)');
29
30 % PLOT CONFIGURE
31 % legend
32 legend('show');
33 %legend('show','Location','NorthWest');
34
35 % label
36 title('')
37 xlabel('Registros')
38 ylabel('Caudal maximo (m^3/s)')
39
40 % Limits
41 %miny=min(d6); maxy=max(d6);
42 %axis([0,1232,0,180])
43 %ylim([miny maxy]);
44 xlim([0 5]);
45
46 % gridlines
47 %set(gca,'xtick',[0:50:250])
48 %set(gca,'ytick',linspace(0,100,13))
49 grid on
50 %grid minor

```

```

51
52 % PRINT PDF
53 % plot(1:0.23:100);
54 % grid on;
55 %set(gcf, 'PaperPosition', [0 0 6.1 4]); %Position plot at left hand corner ←
    with width 5 and height 5.
56 %set(gcf, 'PaperSize', [6.1 4]); %Set the paper to have width 5 and height 5.
57 %saveas(gcf, 'apl_validation1', 'pdf') %Save figure

```

A.8. Prueba final

La prueba final del modelo, gráficamente, se efectúa mediante el código fuente A.8.

Listing A.8: Entrenamiento del modelo

```

1 % nntool
2 % nnstart
3 %clear;
4 clc;
5 % PASO 01: btener los datos
6 X= xlsread('ANNMFtesting.xlsx',1);
7 Y= xlsread('ANNMFtesting.xlsx',2);
8
9 %X=X(:,1)+X(:,2)+X(:,3)+X(:,4)+X(:,5);
10
11 %PASO 04: configurar red de base radial y ejecutar
12 P=X'; % patrones de entrada
13 %T=Y'; % patrones de salida deseadas
14 %GOAL= 0; % error cuadratico medio objetivo
15 %SPREAD=1; %difusion de las funciones de base radial
16 %MN=862; % maximo numero de neuronas en la capa oculta
17 %n=1; % incremento de neuronas
18 %net = newrb(P,T,GOAL,SPREAD,MN,n);

```

```

19
20 Y1=sim(net,P);
21 [f c] = size(X);
22 x=1:f;
23
24 % PLOTS
25 hold on; % graficas anadidas
26 %plot(tsl,'Displayname','Error cuadratico medio','linewidth',2);
27 plot(x,Y,'Displayname','Caudal generado (m^3/s)');
28 plot(x,Y1,'Displayname','Caudal obtenido (m^3/s)');
29
30 % PLOT CONFIGURE
31 % legend
32 legend('show');
33 %legend('show','Location','NorthWest');
34
35 % label
36 title('')
37 xlabel('Registros')
38 ylabel('Caudal maximo (m^3/s)')
39
40 % Limits
41 %miny=min(d6); maxy=max(d6);
42 %axis([0,1232,0,180])
43 %ylim([miny maxy]);
44 xlim([0 5]);
45
46 % gridlines
47 %set(gca,'xtick',[0:50:250])
48 %set(gca,'ytick',linspace(0,100,13))
49 grid on
50 %grid minor
51
52 % PRINT PDF
53 % plot(1:0.23:100);

```

```
54 % grid on;
55 %set(gcf, 'PaperPosition', [0 0 6.1 4]); %Position plot at left hand corner ←
    with width 5 and height 5.
56 %set(gcf, 'PaperSize', [6.1 4]); %Set the paper to have width 5 and height 5.
57 %saveas(gcf, 'apl_validation1', 'pdf') %Save figure
```

Anexo B


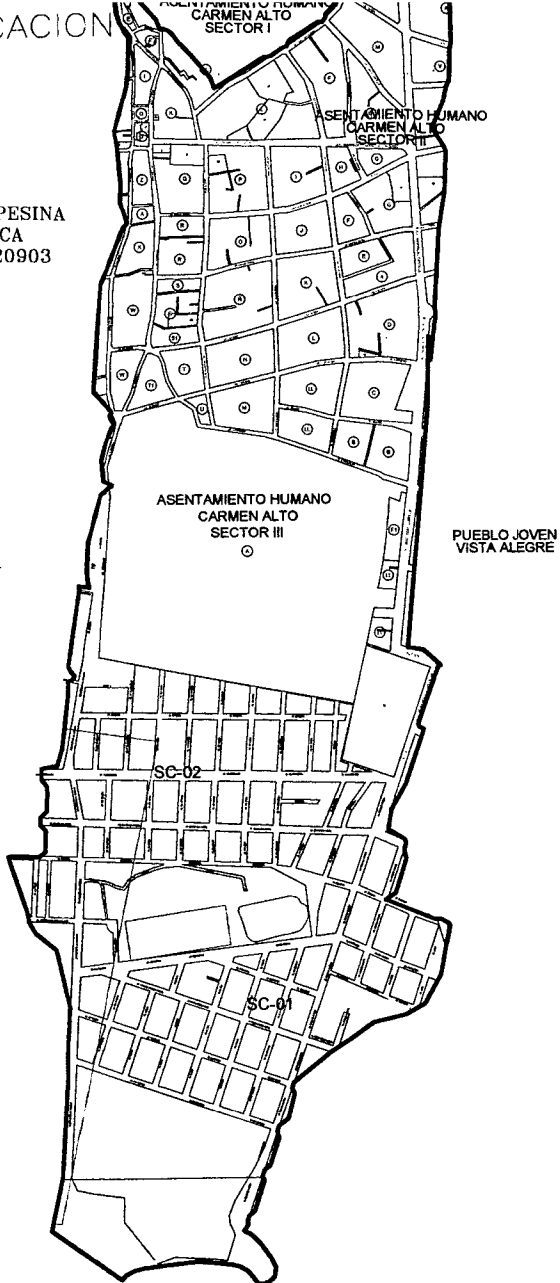
Planos

Se adjunta planos requeridos para la identificación del área de aplicación de la tesis.

- Plano de ubicación.
- Plano de la delimitación de cuencas hidroráficas.

PLANO DE UBICACION


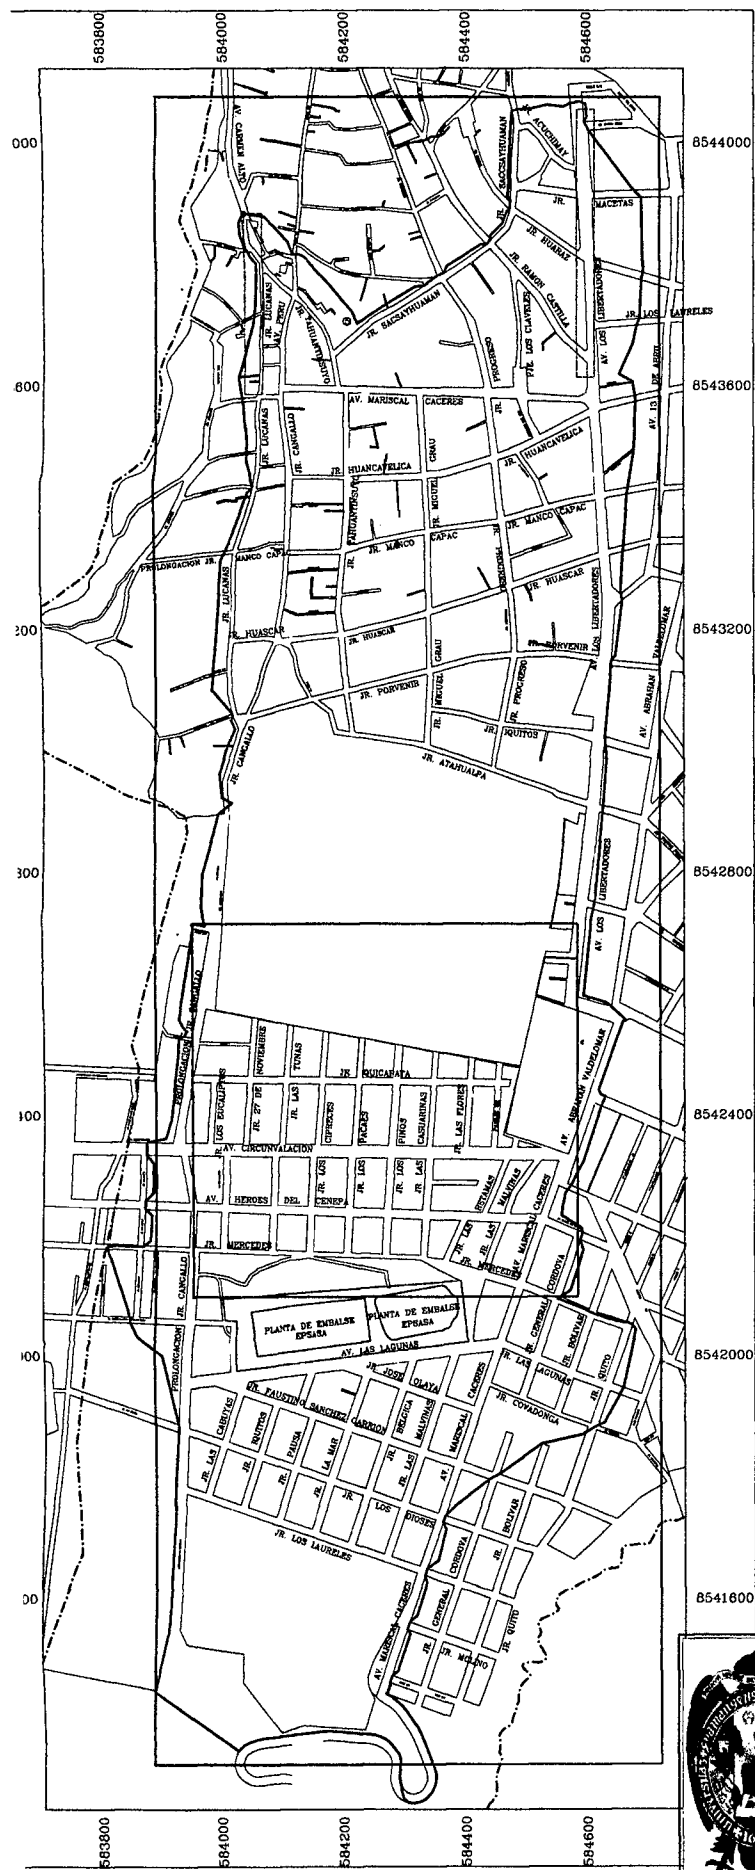
COMUNIDAD CAMPESINA DE ANDAMARCA
 Ficha: 1763-020903



PLANO DE LOCALIZACION



UNIVERSIDAD NACIONAL SAN CRISTÓBAL DE HUAMANGA ESCUELA DE FORMACION PROFESIONAL DE INGENIERIA CIVIL		
TITULO DE TESIS: DISEÑO DE UN MODELO METAEURISTICO PARA LA DETERMINACION DE CAUDALES DE MAXIMAS AVENIDAS EN CUENCAS URBANAS		
PLANO: PLANO DE UBICACION Y LOCALIZACION		
UBICACION: Lugar : Carmen Alto Distrito : Carmen Alto Provincia : Huamanga Departamento : Ayacucho	DISEÑO: Oiver E. Calderon Pillaca	LAMINA N°: UB-01
ASesor DE TESIS: Edmundo Canchari Gutiérrez	DIBUJO: O. Calderon P.	ESCALA: 1/12500
FECHA: Julio - 2016		



LEYENDA

SIMBOL.	DESCRIPCION
	Río y/o Río Seco
	Dirección de flujo
	Limite de la sub cuenca
	Curvas mayores
	Curvas mayores

UNIVERSIDAD NACIONAL SAN CRISTOBAL DE HUAMANGA
ESCUELA DE FORMACION PROFESIONAL DE INGENIERIA CIVIL


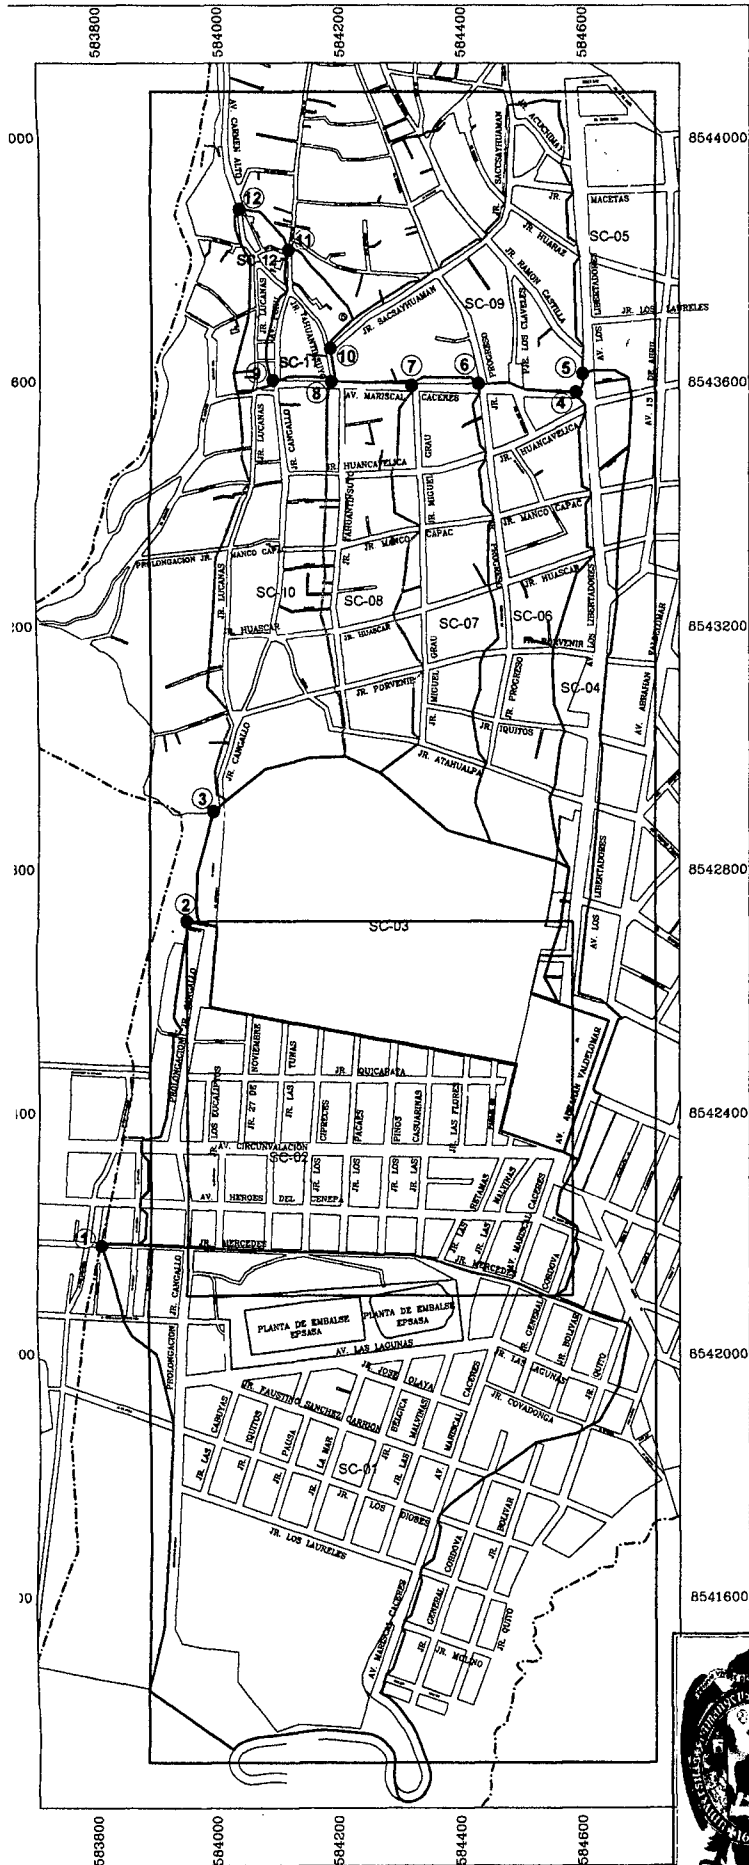
TITULO DE TESIS: DISEÑO DE UN MODELO METAHEURISTICO PARA LA DETERMINACION DE CAUDALES DE MAXIMA AVENIDA EN CUENCAS URBANAS

PLANO: **TOPOGRAFICO**

UBICACION: Lugar : Camen Alto Distrito : Camen Alto Provincia : Huamanga Departamento: Ayacucho	DISEÑO: Oliver E. Calderon Pilleca
ASESOR DE TESIS: Edmundo Cenchari Gutierrez	

LAMINA N°: T-01

DIBUJO: O. Calderon P.	ESCALA: 1/12500	FECHA: Julio - 2016
----------------------------------	---------------------------	-------------------------------



LEYENDA

SIMBOL.	DESCRIPCION
	Rio y/o Rio Seco
	Dirección de flujo
	Limite de la sub cuenca
	Curvas mayores
	Curvas mayores

SUB CUENCA	AREA (m2)	CN
SC-01	441,163.98	87
SC-02	246,108.68	88
SC-03	247,084.13	76
SC-04	75,087.35	97
SC-05	37,903.50	95
SC-06	106,642.79	93
SC-07	94,600.01	93
SC-08	78,579.99	93
SC-09	99,408.12	91
SC-10	111,222.86	93
SC-11	19,427.97	94
SC-12	15,873.25	93
TOTAL	1,573,102.62	91


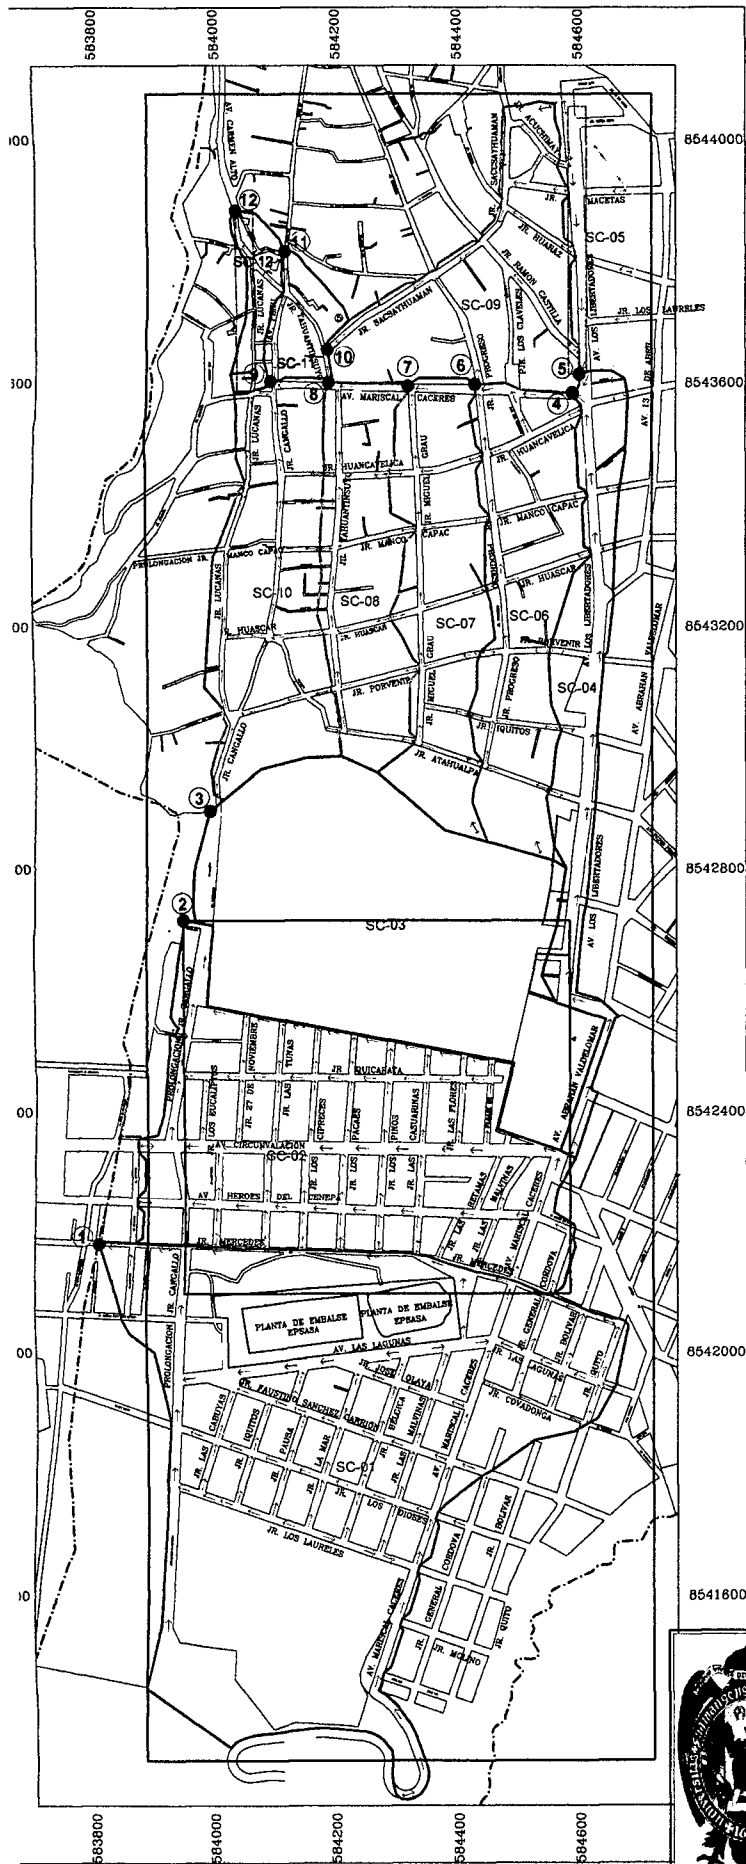
UNIVERSIDAD NACIONAL SAN CRISTOBAL DE HUAMANGA
ESCUELA DE FORMACION PROFESIONAL DE INGENIERIA CIVIL

TITULO DE TESIS: **DISEÑO DE UN MODELO METAEURISTICO PARA LA DETERMINACION DE CAUDALES DE MAXIMA AVENIDA EN CUENCAS URBANAS**

PLANO: **SUB CUENCA DE AREA DE ESTUDIO**

UBICACION:	DISEÑO:	LAMINA N°:
Lugar : Carmen Alto	Oliver E. Calderon Pillaca	SC-01
Distrito : Huamanga	ASESOR DE TESIS:	
Departamento: Ayacucho	Edmundo Canchari Gutierrez	

DEBLUO: O. Calderon P. ESCALA: 1/12500 FECHA: Julio - 2016



LEYENDA

SIMBOL.	DESCRIPCION
	Rio y/o Rio Seco
	Dirección de flujo
	Limite de la sub cuenca
	Curvas mayores
	Curvas mayores

SUB CUENCA	AREA (m2)	CN
SC-01	441,163.88	87
SC-02	246,108.88	88
SC-03	247,084.13	76
SC-04	75,087.35	97
SC-05	37,903.50	95
SC-06	106,642.79	93
SC-07	94,600.01	93
SC-08	78,579.99	93
SC-09	89,408.12	91
SC-10	111,222.86	93
SC-11	19,427.97	94
SC-12	15,873.25	93
TOTAL	1,573,102.62	91




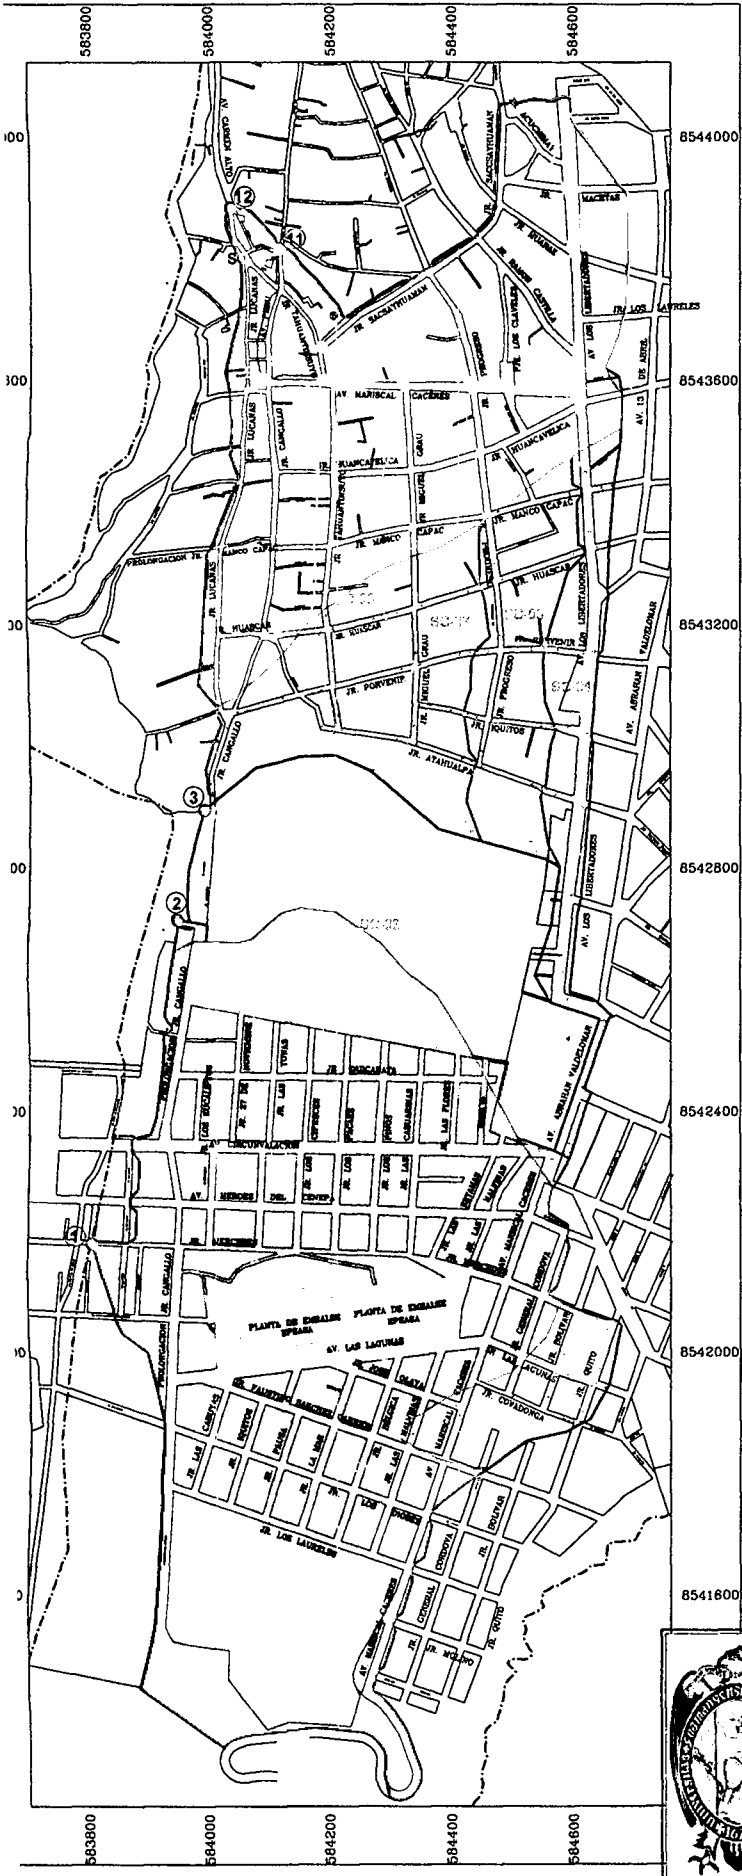
UNIVERSIDAD NACIONAL SAN CRISTOBAL DE HUAMANGA
ESCUELA DE FORMACION PROFESIONAL DE INGENIERIA CIVIL

TITULO DE TESIS: DISEÑO DE UN MODELO METEOROLOGICO PARA LA DETERMINACION DE CAUDALES DE MAXIMA AVENIDA EN CUENCAS URBANAS

PLANO: SENTIDO DE FLUJO

UBICACION: Lugar : Camen Alto Distrito : Carmen Alto Provincia : Huamanga Departamento: Ayacucho	DISEÑO: Oiver E. Calderon Pilla <hr/> ASESOR DE TESIS: Edmundo Canchari Gutierrez	LAMINA N°: SF-01
---	---	--

DEBLADO: O. Calderon P. **ESCALA:** 1/12500 **FECHA:** Julio - 2016



LEYENDA

SIMBOL.	DESCRIPCION
	Rio y/o Rio Seco
	Dirección de flujo
	Limite de la sub cuenta
	Curvas mayores
	Curvas mayores

SUB CUENTA	AREA (m2)	CN
SC-01	441,163.98	87
SC-02	246,108.68	88
SC-03	247,084.13	76
SC-04	75,087.35	97
SC-05	37,903.50	95
SC-06	106,642.79	93
SC-07	94,600.01	93
SC-08	78,579.99	93
SC-09	99,408.12	91
SC-10	111,222.86	93
SC-11	19,427.97	94
SC-12	15,873.25	93
TOTAL	1,573,102.62	91

LEYENDA

ML	Limo inorgánico de baja plasticidad
MH	Limo inorgánico de alta plasticidad
RA	Agglomerado volcánico
RB	Basalto volcánico envuelto en matriz limosa
Aay	Andesita volcánico Acuchimay



UNIVERSIDAD NACIONAL SAN CRISTOBAL DE HUAMANGA
ESCUELA DE FORMACION PROFESIONAL DE INGENIERIA CIVIL

TITULO DE TESIS: **DISEÑO DE UN MODELO METAEURISTICO PARA LA DETERMINACION DE CAUDALES DE MAXIMA AVEIDA EN CUENCAS URBANAS**

PLANO: **TIPO DE SUELO**

UBICACION:
 Lugar : Carmen Alto
 Distrito : Carmen Alto
 Provincia : Huamanga
 Departamento: Ayacucho


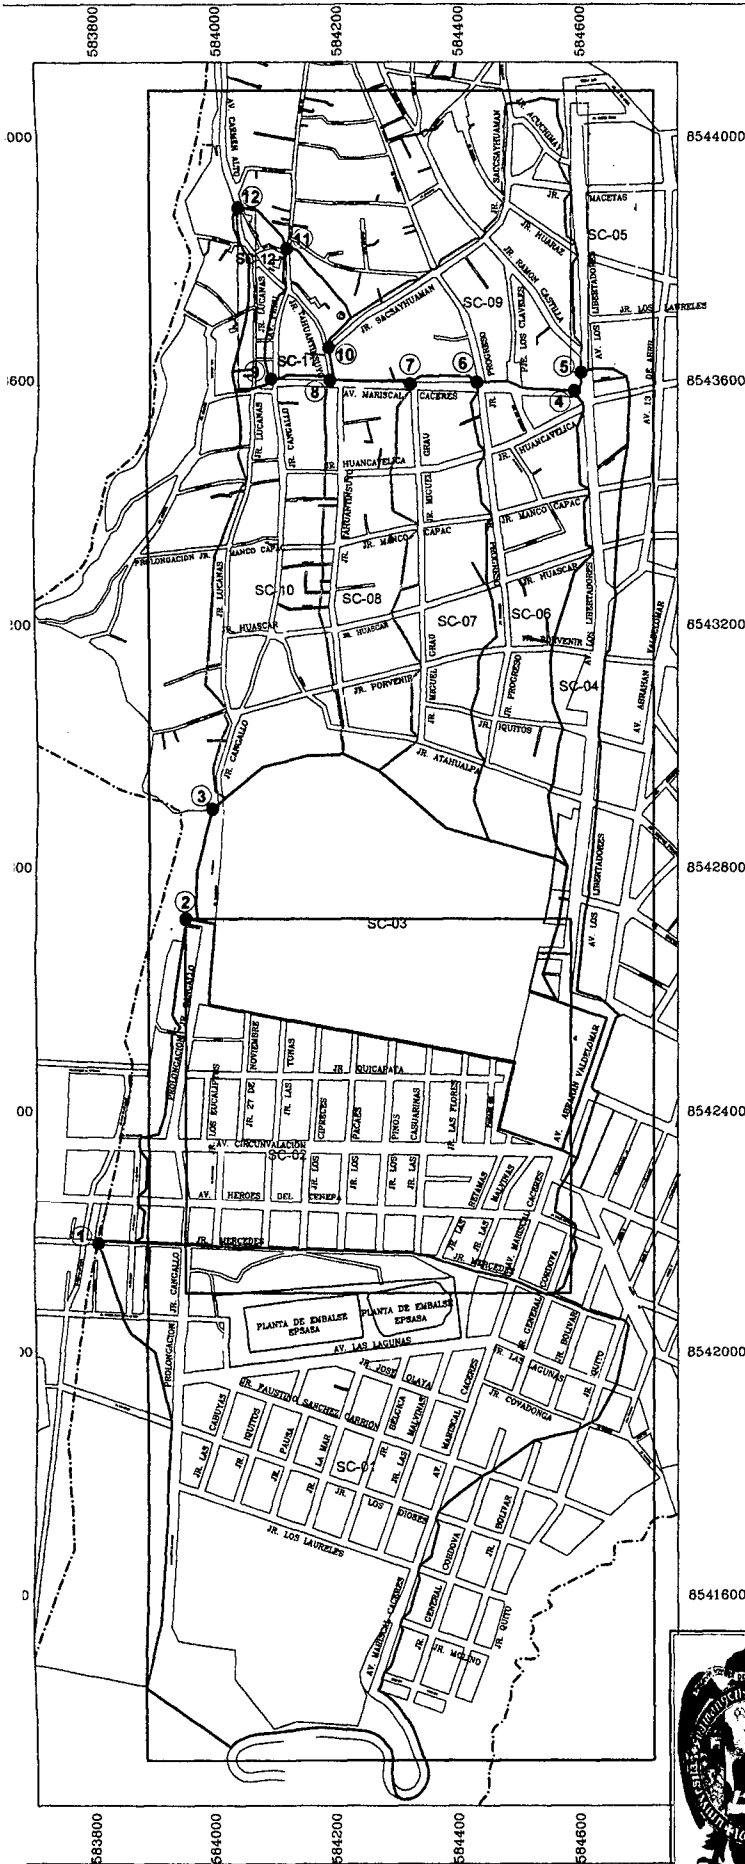
ALUMNO:
 Oliver E. Calderon Piteca

ASISTENTE:
 Edmundo Canchari Gutierrez

FECHA:
 Julio - 2016

ESCALA: 1/2500

LAMINA N°: **TS-01**



LEYENDA

SIMBOL.	DESCRIPCION
	Rio y/o Rio Seco
	Dirección de flujo
	Limite de la sub cuenca
	Curvas mayores
	Curvas mayores

SUB CUENCA	AREA (m2)	CN
SC-01	441,163.98	87
SC-02	246,108.68	88
SC-03	247,084.13	76
SC-04	75,087.35	97
SC-05	37,903.60	95
SC-06	106,642.79	93
SC-07	94,600.01	93
SC-08	78,579.99	93
SC-09	99,408.12	91
SC-10	111,222.66	93
SC-11	19,427.97	94
SC-12	15,873.25	93
TOTAL	1,573,102.62	91

SUB CUENCA	LONGITUD (m)	ΔCOTA (m)	S(m/m)	Tc(min)
SC-01	1,626.32	86.71	0.053	17.87
SC-02	1,186.91	45.82	0.039	15.88
SC-03	674.54	39.48	0.059	8.75
SC-04	1,329.82	81.65	0.061	14.50
SC-05	446.26	33.00	0.074	5.82
SC-06	793.04	72.63	0.092	8.35
SC-07	761.72	79.58	0.104	7.69
SC-08	663.12	79.23	0.119	6.56
SC-09	583.33	70.20	0.120	5.93
SC-10	701.79	74.75	0.107	7.17
SC-11	235.99	26.15	0.111	3.05
SC-12	303.60	38.90	0.128	3.50

UNIVERSIDAD NACIONAL SAN CRISTOBAL DE HUAMANGA
ESCUELA DE FORMACION PROFESIONAL DE INGENIERIA CIVIL

TITULO DE TESIS: **DISEÑO DE UN MODELO METEOROLOGICO PARA LA DETERMINACION DE CAUDALES DE MAXIMA AVENIDA EN CUENCAS URBANAS**

PLANO: **TIEMPO DE CONCENTRACION**

UBICACION:	DISEÑO:
Lugar : Carmen Alto	Oiver E. Calderon Pillaca
Distrito : Carmen Alto	
Provincia : Huamanga	ASESOR DE TESIS:
Departamento: Ayacucho	Edmundo Canchari Gutierrez

DIBUJO: O. Calderon P.	ESCALA: 1/12500	FECHA: Julio - 2016
------------------------	-----------------	---------------------

TC-01