

IMPLEMENTACIÓN DE REDES NEURONALES ARTIFICIALES Y SERIES
TEMPORALES PARA LA GENERACIÓN DE PRODUCTOS DE MÁSCARAS DE
NUBES EN IMÁGENES MODIS

GABRIELA LUCIA CHAMORRO YELA
JUAN DAVID SIERRA ORDOÑEZ

UNIVERSIDAD DEL VALLE
FACULTAD DE INGENIERÍA
ESCUELA DE INGENIERÍA CIVIL Y GEOMÁTICA
PROGRAMA ACADÉMICO DE INGENIERÍA TOPOGRÁFICA
SANTIAGO DE CALI
2015

IMPLEMENTACIÓN DE REDES NEURONALES ARTIFICIALES Y SERIES
TEMPORALES PARA LA GENERACIÓN DE PRODUCTOS DE MÁSCARAS DE
NUBES EN IMÁGENES MODIS

GABRIELA LUCIA CHAMORRO YELA

JUAN DAVID SIERRA ORDOÑEZ

Propuesta de trabajo de tesis para optar el
Título Profesional de Ingeniero Topográfico

Director

Francisco Luis Hernández Torres

Topógrafo

UNIVERSIDAD DEL VALLE

FACULTAD DE INGENIERÍA

ESCUELA DE INGENIERÍA CIVIL Y GEOMÁTICA

PROGRAMA ACADÉMICO DE INGENIERÍA TOPOGRÁFICA

SANTIAGO DE CALI

2015

Nota de Aceptación:

Francisco Luis Hernández

Jurado 1

Jurado 2

Santiago de Cali Junio de 2015

DEDICATORIA

A Dios por darme la oportunidad de estudiar en la universidad que deseaba, por la fortaleza, la sabiduría de cada día para superar las dificultades y la perseverancia que deposito en mí para salir adelante. A mi padre por su apoyo y esfuerzos para regalarme siempre lo mejor; a mi madre por sus oraciones, su dedicación, entrega y por trasmitirme siempre su paz y la confianza en Dios, gracias a ellos porque con su ejemplo complementaron mi formación como profesional. A mis hermanas por estar siempre a mi lado, por sus palabras de aliento, por enseñarme a salir adelante ante cualquier circunstancia y por creer siempre en mí. A mi novio por sus consejos y paciencia, por su apoyo incondicional y por respaldarme en todo momento. Gracias a todas las personas que de una u otra manera contribuyeron para culminar esta etapa de mi vida.

Gabriela Chamorro

Dedico este trabajo a mis padres por apoyarme incondicionalmente y darme la oportunidad de estudiar; a mi novia por escucharme y levantarme el ánimo en los momentos difíciles; a mis hermanos Carlos Andres y Yuliana a quienes quiero enormemente; y a mis demás familiares y amigos que estuvieron siempre pendientes de mi situación y no dudaron de mis capacidades.

Juan David Sierra

AGRADECIMIENTOS

A nuestro director de trabajo de grado Francisco Luis Hernández por su respaldo en todo este proceso, compartirnos su conocimiento, alentarnos a salir adelante y por su excelente disposición para permitir la culminación de este trabajo.

Al profesor Wilfredo Morales, Eduardo Caicedo de la Escuela de Ingeniería Eléctrica y Electrónica y Roberto Behar del área de Estadística de la Universidad del Valle por sus valiosas observaciones.

CONTENIDO

DEDICATORIA	2
AGRADECIMIENTOS.....	3
CONTENIDO	4
LISTA DE FIGURAS	6
LISTA DE TABLAS	10
LISTA DE ANEXOS	1
SIGLAS	2
RESUMEN	3
1. INTRODUCCIÓN.....	1
2. PLANTEAMIENTO DEL PROBLEMA.....	2
3. OBJETIVOS.....	4
3.1. Objetivo General	4
3.2. Objetivos Específicos.....	4
4. JUSTIFICACIÓN.....	5
5. MARCO TEÓRICO	6
5.1. MARCO CONCEPTUAL	6
5.1.1. Nubes	6
5.1.2. Sensores remotos	8
5.1.3. Análisis de componentes principales	11
5.1.4. Métodos de Detección de Nubes	12
5.2. MARCO REFERENCIAL	18
5.3. MARCO TEÓRICO	19
5.3.1. Análisis de Componentes Principales	20
5.3.2. Filtros espaciales.....	22
5.3.3. Métodos para la detección de nubes.....	24
5.3.4. Validación.....	36
6. METODOLOGÍA.....	39
6.1. ZONA DE ESTUDIO	39
6.1.1. PERIODO DE ESTUDIO.....	40
6.2. MATERIALES	40
6.2.1. MOD09A1	40
6.2.2. Información cartográfica de la zona de estudio	42

6.3. PROCEDIMIENTO	43
6.3.1. Pre-procesamiento de los datos.....	44
6.3.2. Selección de variables de entrada	44
6.3.3. Algoritmo de detección de nubes basado en la inflexión de series temporales.....	45
6.3.4. Algoritmo de detección de nubes usando la Redes Neuronal Artificiales MLP (Perceptron Multicapa).....	50
6.3.5. Validación.....	54
7. RESULTADOS	55
7.1. Selección de variables - Análisis de Componentes Principales.....	55
7.1.1. Matrices de correlación	55
7.1.2. Test de KMO	56
7.1.3. Determinación del número de factores.....	56
7.1.4. Matriz de factores.....	57
7.2. Máscara de nubes usando series temporales basado en la inflexión	59
7.2.1. Evaluación de la suposición del punto de inflexión	59
7.2.2. Máximo global de B3 y R37	64
7.2.3. Factibilidad de la aplicación del algoritmo IBCM	65
7.3. Máscara de nubes usando redes neuronales artificiales	67
7.3.1. Extracción de características	67
7.3.2. Configuración de la red	69
7.4. Validación de los algoritmos	70
7.4.1. Análisis Visual	70
7.4.2. Índices Globales respecto a MODIS	76
7.4.3. Índices globales respecto a datos muestreados	79
7.4.4. Evaluación de la incertidumbre de la detección de nubes.....	80
8. DISCUSIÓN.....	85
9. CONCLUSIONES Y RECOMENDACIONES.....	87
10. BIBLIOGRAFÍA	89
ANEXOS.....	97
ANEXO A. Productos de máscaras de nube implementado los métodos de RNAe IBCM para la zona de estudio en el año 2010	97
ANEXO B. MANUAL DE LA INTERFAZ GRÁFICA DE USUARIO.....	143

LISTA DE FIGURAS

Figura 1. Matriz resultante de filtrado en el dominio espacial	11
Figura 2. Estructura Topológica de la Red Neuronal.	15
Figura 3. Forma matricial del filtro de media aritmética	23
Figura 4: Distancia del punto a la recta.....	24
Figura 5: Ángulo comprendido entre dos rectas	25
Figura 6. Localización de la zona de estudio.	39
Figura 7. Diagrama del proceso metodológico General.....	43
Figura 8: Diagrama del proceso metodológico de series temporales basados en la inflexión.....	45
Figura 9: Esquema de la extracción de la información temporal por pixel	46
Figura 10. Serie temporal del porcentaje de reflectancia en la banda 3 en las coordenadas 3°26'42"N -76°30'46"W	47
Figura 11: Serie temporal ordenada	47
Figura 12: Cálculo de cada punto se la serie temporal a la recta	48
Figura 13: Ángulo entre el punto libre de nube, el punto de inflexión y punto con presencia de nube.	49
Figura 14: Estructura de una red multicapa MLP.....	50
Figura 15. Diagrama del proceso metodológico de Redes Neuronales.....	51
Figura 16: Rendimiento de los algoritmos de aprendizajes de la red respecto a número de iteraciones y el RMC.....	54
Figura 17: Gráfico de sedimentación de los autovalores	57
Figura 18: Valores de la banda 3 para el bosque tropical en la zona de coordenadas 2°32'47" S y 69°51'59" W	60
Figura 19: Valores R37 para el bosque tropical en la zona de coordenadas 2°32'47" S y 69°51'59" W	60
Figura 20: Valores de la banda 3 para la cobertura de desierto de coordenadas 12°9'34" N y 71°44'31" W.....	61
Figura 21: Valores R37 para la cobertura de desierto de coordenadas 12°9'34" N y 71°44'31" W	61
Figura 22: Valores de la banda 3 para la cobertura de zona urbana de coordenadas 4°36'15" N y 74°07'19" W	61
Figura 23: Valores R37 para la cobertura de zona urbana de coordenadas 4°36'15" N y 74°07'19" W.....	62
Figura 24: Valores de la banda 3 para la cobertura de agua de coordenadas 3°53'39" N y 76°29'51" W	62
Figura 25: Valores R37 para la cobertura de agua de coordenadas 3°53'39" N y 76°29'51" W.....	63
Figura 26: Valores de la banda 3 para la cobertura de rio de coordenadas 1°06'24" S y 71°05'47" W	63
Figura 27: Valores R37 para la cobertura de rio de coordenadas 1°06'24" S y 71°05'47" W.....	63
Figura 28: Distribución espacial de los valores máximos de reflectancia de B3 para la zona de estudio.....	64

Figura 29: Distribución espacial de los valores máximos de reflectancia de R37 para la zona de estudio.....	65
.....	65
Figura 31: Distribución espacial de los ángulos con R37 para la zona de estudio.....	67
Figura 32: Resultados obtenidos a partir de los filtros de realce aplicados	68
Figura 33: Comportamiento del EMC respecto al número de neuronas en la capa de entrada y la capa oculta.....	69
Figura 34: Configuración final de la red para el enmascaramiento de nubes con RNA	70
Figura 35: Análisis visual de la detección de nubes de los productos de máscaras de RNA e IBCM respecto al producto de MODIS.	71
Figura 36: Porcentaje de nubosidad para cada imagen.....	72
Figura 37: Gráfico de dispersión del porcentaje de nubosidad detectado por la máscara de MODIS y RNA	73
Figura 38: Gráfico de dispersión del porcentaje de nubosidad detectado por la máscara de MODIS e IBCM.....	74
Figura 39: Gráfico de dispersión del porcentaje de nubosidad detectado por la máscara de RNA e IBCM.....	74
Figura 40: Distribución espacial de la presencia de nubes en el país.....	76
Figura 41: Errores de omisión y comisión en función del porcentaje de nubosidad entre las máscaras de MODIS y RNA.....	77
Figura 42: Errores de omisión y comisión en función del porcentaje de nubosidad entre las máscaras de MODIS e IBCM	78
Figura 43: Coeficiente Kappa para los métodos RNA e IBCM respecto a la máscara de MODIS en función del porcentaje de nubosidad	79
Figura 44: Promedio de la distribución de los datos correspondiente al sesgo de la banda 3 en cada uno de los métodos	81
Figura 45: Distribución del sesgo de la B3 para el día 17	82
Figura 46: Distribución del sesgo de la B3 para el día 97	82
Figura 47: Distribución del sesgo de la B3 para el día 313.....	82
Figura 48: Promedios del sesgo del NDVI en cada uno de los métodos	83
Figura 49: Distribución del sesgo del NDVI en la B3 para el día juliano 17	84
Figura 50: Distribución del sesgo del NDVI en la B3 para el día 97.....	84
Figura 51: Distribución del sesgo del NDVI en la B3 para el día 313.....	84
Figura 52. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Enero 1 de 2010	97
Figura 53. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Enero 9 de 2010	98
Figura 54. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Enero 17 de 2010	99
Figura 55. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Enero 25 de 2010	100
Figura 56. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Febrero 2 de 2010	101

Figura 57. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Febrero 10 de 2010	102
Figura 58. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Febrero 18 de 2010	103
Figura 59. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Febrero 26 de 2010	104
Figura 60. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Marzo 6 de 2010.....	105
Figura 61. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Marzo 14 de 2010.....	106
Figura 62. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Marzo 22 de 2010.....	107
Figura 63. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Marzo 30 de 2010.....	108
Figura 64. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Abril 7 de 2010	109
Figura 65. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Abril 15 de 2010	110
Figura 66. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Abril 23 de 2010	111
Figura 67. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Mayo 1 de 2010.....	112
Figura 68. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Mayo 09 de 2010.....	113
Figura 69. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Mayo 17 de 2010.....	114
Figura 70. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Mayo 25 de 2010.....	115
Figura 71. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Junio 2 de 2010	116
Figura 72. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Junio 10 de 2010.....	117
Figura 73. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Junio 18 de 2010	118
Figura 74. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Junio 26 de 2010	119
Figura 75. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Julio 4 de 2010	120
Figura 76. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Julio 12 de 2010	121
Figura 77. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Julio 20 de 2010	122
Figura 78. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Julio 28 de 2010	123

Figura 79. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Agosto 5 de 2010	124
Figura 80. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Agosto 13 de 2010	125
Figura 81. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Agosto 21 de 2010	126
Figura 82. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Agosto 29 de 2010	127
Figura 83. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Septiembre 6 de 2010	128
Figura 84. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Septiembre 14 de 2010	129
Figura 85. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Septiembre 22 de 2010	130
Figura 86. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Septiembre 30 de 2010	131
Figura 87. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Octubre 8 de 2010.....	132
Figura 88. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Octubre 16 de 2010.....	133
Figura 89. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Octubre 24 de 2010.....	134
Figura 90. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Noviembre 1 de 2010	135
Figura 91. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Noviembre 9 de 2010	136
Figura 92. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Noviembre 17 de 2010	137
Figura 93. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Noviembre 25 de 2010	138
Figura 94. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Diciembre 3 de 2010	139
Figura 95. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Diciembre 11 de 2010	140
Figura 96. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Diciembre 19 de 2010	141
Figura 97. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Diciembre 27 de 2010	142
Figura 98 Interfaz gráfica creada que implementa la RNA entrenada	143
Figura 99 Interfaz gráfica con la imagen MOD09A1 del Valle del Cauca	144
Figura 100 Interfaz gráfica con imagen MOD09A1 del Valle del Cauca y su respectiva máscara de nubes	145

LISTA DE TABLAS

Tabla 1. Tipos de Nubes	7
Tabla 2. Nivel atmosférico de las Nubes.....	8
Tabla 3. Modelos de Redes Neuronales.....	16
Tabla 4: Matriz de datos	20
Tabla 5. Modelos para la identificación del número de neuronas	26
Tabla 6. Matriz de confusión	37
Tabla 7. Valoración del coeficiente kappa	38
Tabla 8. Características del Producto MOD09A1	40
Tabla 9. Capas del Producto MOD09A1 (500 m).....	41
Tabla 10. Descripción del estado de datos QA MOD09A1	41
Tabla 11: Umbrales de clasificación para método IBCM	49
Tabla 12: Configuraciones para la capa de entrada	53
Tabla 13: Matrices de correlación entre las bandas espectrales del muestreo realizado para cada imagen.....	55
Tabla 14: Resultado del test KMO del muestreo realizado en cada imagen.....	56
Tabla 15: Porcentaje de varianza acumulada para las muestras obtenidas en cada imagen.....	56
Tabla 16: Matriz de factores.....	58
Tabla 17: Matriz de componentes rotados con el método VARIMAX	58
Tabla 18: Extensión de la zona en coordenadas geográficas.....	70
Tabla 19: Épocas establecidas para el análisis de la presencia de nubes en el país	75
Tabla 20: Mínimo, máximo, promedio y desviación estándar de la exactitud global de los métodos propuestos con respecto a las máscaras de MODIS	77
Tabla 21. Matriz de confusión para los datos muestreados de la máscara de MODIS.....	79
Tabla 22. Matriz de confusión para los datos muestreados de la máscara de RNA	79
Tabla 23. Matriz de confusión para los datos muestreados de la máscara de IBCM	80
Tabla 24. Error global de clasificación, los errores de omisión y comisión y el coeficiente kappa para los tres métodos.....	80

LISTA DE ANEXOS

ANEXO A. PRODUCTOS DE MÁSCARAS DE NUBE IMPLEMENTADO LOS MÉTODOS DE RNA E IBCM PARA LA ZONA DE ESTUDIO EN EL AÑO 2010..	97
ANEXO B. MANUAL DE LA INTERFAZ GRÁFICA DE USUARIO.....	143

SIGLAS

ALS: Scanner Laser Aerotransportado
BDRF: Función de distribución de la reflectancia bidireccional, por sus siglas en inglés.
BID: Banco Interamericano de Desarrollo
CCM: Complejos Convectivos de Mesoescalas
CEPAL: Comisión Económica para América Latina y el Caribe
CVC: Corporación Autónoma Regional del Valle del Cauca
DEM: Modelo de Elevación Digital, por sus siglas en inglés.
EMC: Error Medio Cuadrático
ENOS: El Niño Oscilación del Sur
FPAR: Fracción de radiación activa fotosintética, por sus siglas en inglés.
IBCM: Algoritmo de máscara de nubes basado en la inflexión, por sus siglas en inglés
IDEAM: Instituto de Hidrología, Meteorología y Estudios Ambientales
IGAC: Instituto Geográfico Agustín Codazzi
INVEMAR: Instituto de Investigaciones Marinas y Costeras “José Benito Vives De Andreis”
LIDAR: Light Detection and Ranging o Laser Imaging Detection and Ranging
LPDAAC: Land Processes Distributed Active Archive Center
LST: Temperatura de la Superficie del Terrestre
MLP: Red Neuronal de Perceptron Multicapa
MODIS: Espectroradiómetro de Imágenes de Mediana Resolución, por sus siglas en inglés.
NASA: Administración Nacional de Aeronáutica y del Espacio, por sus siglas en inglés
NDVI: Índice de Vegetación de Diferencia Normalizada
NOAA: La Administración Nacional Oceánica y Atmosférica de Estados Unidos, por sus sigla en inglés
Radar: Detección y localización por radio, por sus siglas en Inglés
RNA: Redes Neuronales Artificiales
SAR: Radar de Apertura Sintética
SGC : Servicio Geológico Colombiano
SIGOT: Sistema de Información Geográfica para el Ordenamiento Territorial
SST: Temperatura de la Superficie del Mar
ZCIT: Zona de Convergencia Intertropical

RESUMEN

Las máscaras de nubes son productos que discriminan la cobertura nubosa presente en las imágenes satelitales, facilitando la interpretación y el análisis de las coberturas terrestres en diferentes estudios de teledetección espacial. Se han propuesto diferentes métodos para el enmascaramiento de las nubes, sin embargo presentan variaciones en cuanto a precisión, tiempo de procesamiento y su facilidad de implementación. En este sentido, para el presente proyecto se propone la aplicación de dos métodos correspondientes a Redes Neuronales Artificiales de Perceptrón Multicapa (RNA-MLP) y el algoritmo de máscaras de nubes basado en la inflexión de una serie temporal (IBCM). La metodología se compone por cinco fases correspondientes a: pre-procesamiento, selección de variables, desarrollo del algoritmo de IBCM, desarrollo del algoritmo de RNA y por último la comparación y validación de los resultados. Los resultados muestran que los métodos propuestos presentan errores globales del 1.75% y 12.71% para RNA e IBCM y concordancias con la máscara de la MOD09A1 de 0.87 y 0.72 respectivamente.

1. INTRODUCCIÓN

Un obstáculo significativo en los estudios de superficie del suelo es la presencia de nubes en las imágenes satelitales provenientes de sensores ópticos (Alainet et al., 2006). Esto se debe principalmente a que el brillo que las nubes generan, causan valores atípicos en los datos de reflectancia que no corresponden a los de la superficie. Además, en algunas ocasiones las nubes son tenues, y aunque es posible detectar la superficie terrestre, los datos presentan ruidos considerables. Por tanto, al emplear imágenes satelitales para estudios relacionados con la superficie terrestre, es necesario detectar las nubes de forma precisa para eliminar los valores afectados por su presencia.

Se han desarrollado diferentes métodos para la discriminación de las nubes, los cuales principalmente varían en complejidad y en las características espaciales, espectrales, temporales o radiométricas del sensor. Entre los más utilizados se encuentran los métodos radiométricos y geométricos (Martinuzzi et al., 2007), que emplean información de la geometría del sensor como su altura y ángulo de visión; métodos de umbrales (Kennedy et al., 2010; Sano et al., 2007), que excluyen ciertos intervalos en las bandas espectrales donde se supone que hay nubes; métodos basados en análisis de series de tiempo (Goodwin et al., 2013; Lyapustin et al., 2008), cuyo fin es componer una imagen de referencia sin nubes de muchas épocas para comparar con las imágenes con presencia de estas; y métodos que utilizan redes neuronales artificiales (Alain et al., 2006; Bankert, 1994; Lissens et al., 2000), que también se han implementado en clasificación de coberturas del suelo.

Para el desarrollo de este estudio se propone el uso de dos metodologías que corresponden a la aplicación de Redes Neuronales Artificiales (RNA) (del inglés *Artificial Neural Network*) y análisis de series de tiempo. Las RNA son un método robusto de clasificación, el cual se basa en el funcionamiento de las neuronas del cerebro humano permitiendo que se realice un aprendizaje que va mejorando la clasificación. Por otro lado está el método de series de tiempo, que utiliza tanto la información espacial como temporal que permite la identificación de las nubes.

El motivo de proponer este Trabajo de Grado corresponde principalmente a las dificultades que generan las nubes en los procesos de teledetección espacial. Con lo que se pretende dar criterios de decisión a los usuarios de imágenes satelitales para identificar cuál de los métodos propuestos se ajusta de acuerdo a las necesidades.

Este documento contiene una descripción de la problemática, los objetivos que se pretenden alcanzar, una justificación del por qué este tema debe ser tratado, un marco teórico, la metodología propuesta, los resultados, así como las discusiones y conclusiones del proyecto.

2. PLANTEAMIENTO DEL PROBLEMA

Colombia presenta características físicas diversas y complejas en su territorio. Un tercio de su suelo corresponde a relieves montañosos, los cuales, provienen desde el suroeste del país, dividiéndose en tres cordilleras, haciendo que sea un sitio con variedad de pisos térmicos, definidos en cinco niveles denominados cálido, templado, frío, páramo y nieves perpetuas (Instituto Geográfico Agustín Codazzi & Corpoica, 2002).

Su posición geográfica se encuentra en una Zona de Convergencia Intertropical (ZCIT), la cual, es visible como una franja nubosa cercana al ecuador. La ZCIT es probablemente el mecanismo productor de lluvia de mayor influencia sobre esta región, ya que son zonas de calentamiento y evaporación superficiales que aumentan la posibilidad de generación de nubes por condensación y por ende precipitaciones (Poveda, 2011). Esto hace que Colombia se encuentre entre los primeros diez países con mayor precipitación (2612 mm anuales) superando el doble del promedio mundial de 1160 mm anuales entre los años 2009 y 2013 (Banco Mundial, 2014).

Adicionalmente, Colombia cuenta con un 35% de superficie cubierta por bosque húmedo tropical, principalmente en la Amazonía y el occidente del país (Parques Nacionales Naturales de Colombia, 2014). Estas zonas son frecuentemente afectadas por Complejos Convectivos de Mesoescalas (CCM), siendo estas largas agrupaciones de nubes cúmulus (Hurtado, 2009).

Las nubes necesitan de tres ingredientes para su formación tales como: condiciones termodinámicas de la atmósfera, vapor de agua debido a la evaporación de los bosques y de las partículas de aerosoles como polvo, hollín entre otros (Tapakis & Charalambides, 2013). Estas condiciones se presentan en gran parte del territorio colombiano, afectando el uso de imágenes satelitales debido a que la radiación registrada por los sensores realiza trayectorias a través de la atmósfera sufriendo varios efectos que dependen de su recorrido, de las condiciones atmosféricas presentes y de la longitud de onda de la radiación. El efecto que se genera en las nubes es conocido como la dispersión no selectiva, que se produce cuando los diámetros de las partículas atmosféricas como el vapor de agua afectan por igual a todas las longitudes de onda (Gandia & Mejia, 1993).

En las imágenes satelitales, las nubes y sus sombras asociadas limitan la cantidad de información de la superficie terrestre, causando valores atípicos en el análisis de las observaciones de reflectancia en el tiempo y afectando los procedimientos de recuperación de aerosoles (Fisher et al, 2009; Sano et al., 2007). Además, estas complican el uso de datos en el dominio óptico de los satélites de observación de la tierra. El efecto de su brillo, influye en la detección de cambios o inversión de las variables biofísicas, en el análisis de los datos causando corrección atmosférica inexacta, sesgando los valores del Índice de Vegetación de Diferencia Normalizada (NDVI), errores en la clasificación supervisada y no supervisada de la cubierta terrestre y confusión en los cambios de coberturas vegetales (Hagolle et al, 2010).

La información proporcionada por las bandas espectrales de las imágenes no es suficiente para determinar con certeza qué píxeles corresponden a zonas de nube y cuáles no. Además, el perfil espectral de los píxeles de agua toma valores similares a los píxeles de sombra y es por esto que pueden generar confusión al momento de identificar y clasificar los diferentes tipos de objetos presentes en la imagen (Goodwin et al., 2013).

Bajo este escenario existe una evidente necesidad de evaluar diferentes métodos de detección de nubes mediante sensores remotos, dado que las condiciones geográficas y climatológicas de Colombia hacen que el procesamiento y análisis de las imágenes satelitales se vean afectadas con mayor frecuencia que en otras latitudes.

3. OBJETIVOS

3.1. OBJETIVO GENERAL

Desarrollar una metodología para la generación de productos de máscaras de nubes en imágenes satelitales MODIS.

3.2. OBJETIVOS ESPECÍFICOS

- Identificar la cobertura nubosa presente en las imágenes de la zona de estudio.
- Calcular las máscaras de nubes a partir de series de tiempo y redes neuronales artificiales.
- Evaluar los métodos empleados para la construcción de máscaras de nubes.

4. JUSTIFICACIÓN

El uso de imágenes de satélite para la generación de información a escala nacional, regional y local ha tenido gran importancia para entender los fenómenos que intervienen en distintas áreas como la agricultura (Mulla, 2013), la geología (van der Meer et al., 2012), las ciencias forestales (Qi et al., 2014), la gestión del medio ambiente (Martin, 2008) y gestión del riesgo (Van Westen, 2013) e incluso en la planificación urbana (Behling et al., 2015). Para llegar a resultados aplicables en las diferentes áreas antes mencionadas es necesario desarrollar una serie de técnicas que disminuyan los errores en las imágenes. Entre estas se encuentran la identificación y clasificación de la cubierta nubosa a partir de imágenes satelitales, la cual tiene como objetivo discriminar estos elementos del resto de la imagen puesto que generan valores atípicos que no corresponden a la superficie. Esta técnica se concibe como el primer paso en la mayoría de las actividades de sensores remotos (Zhu & Woodcock, 2014).

Con esta investigación se pretende evaluar la precisión de las redes neuronales artificiales y las series temporales para el enmascaramiento de nubes, con el fin de determinar cuál es el más adecuado a las condiciones climáticas y geográficas presentes en el país. Este estudio facilitará en gran medida parte del pre-procesamiento de imágenes de sensores remotos en futuros proyectos que utilicen técnicas de teledetección, ya que agilizará el proceso de corrección de los datos y mejorará la precisión de la información obtenida.

Las máscaras de nubes es un producto que es usado como parámetro de entrada para diferentes métodos de procesamiento de imágenes satelitales ya que permite excluir aquellos píxeles contaminados por estas, como ejemplo se pueden mencionar el Índice de Vegetación de Diferencia Normalizada (NDVI), Temperatura de la Superficie del Terrestre (LST), entre otras (Kussul et al., 2005). También las máscaras de nubes pueden ser usadas de forma independiente en aplicaciones como vuelos aéreos y planeamiento de fotografías satelitales (Kussul et al., 2005).

Mediante los resultados obtenidos en el proyecto se podrán obtener criterios para decidir qué método se adapta mejor a las condiciones de cualquier estudio que implemente imágenes de sensores remotos. Dichos criterios se basan en indicadores prácticos como tiempo de procesamiento, requerimiento del sistema, nivel de automatización y precisión.

Este producto se constituye un insumo fundamental para el pre-procesamiento de estas imágenes y su posterior análisis, dado que permite tener un acercamiento preciso del comportamiento del fenómeno de interés en particular, discriminar “satisfactoriamente” la respuesta espectral de los elementos de la imagen, identificar los diferentes tipos de objetos presentes en la imagen en el momento de clasificar. Además, será un apoyo no solo para los entes que utilizan información capturada mediante sensores remotos a nivel nacional, como el Instituto Geográfico Agustín Codazzi (IGAC), el Instituto de Hidrología, Meteorología y Estudios Ambientales (IDEAM), el Instituto de Investigaciones Marinas y Costeras

“José Benito Vives De Andréis” (INVEMAR), Servicio Geológico Colombiano (SGC), sino también para otras zonas tropicales.

5. MARCO TEÓRICO

5.1. MARCO CONCEPTUAL

A continuación se describen los conceptos relacionados con el desarrollo de esta investigación, correspondientes a las nubes, el sensor empleado, el análisis de componentes principales y los métodos de detección propuestos.

5.1.1. Nubes

Conjunto o agrupación de diminutas partículas de agua, hielo, o nieve que se encuentran suspendidas en la atmósfera, producto de un proceso de condensación. Las masas que estas forman se presentan con los más variados colores, aspectos y dimensiones, según las altitudes en que aparecen y las características particulares de la condensación.

El tamaño de las gotas que integran una nube varía desde 0.2 hasta 100 micrones. Estas pequeñas gotas, al principio son casi esféricas, dependiendo su crecimiento del calibre y composición del núcleo de condensación, así como de la humedad del aire. Cuando estas crecen, pierden su forma esférica, tornándose en forma de pera, hasta el momento en que ya no pueden sostenerse en la atmósfera y es entonces cuando descienden hacia la tierra.

5.1.1.1. Formación de la cubierta nubosa

Su formación se da durante el ciclo hidrológico, el cual se refiere al movimiento y circulación natural que el agua tiene en toda la superficie terrestre y su atmósfera. Este movimiento se presenta cuando el sol calienta la superficie terrestre y con esto parte del agua de los ríos, los lagos, mares y océanos, los cuales se evaporan y al estar a mayor temperatura que el aire normal, se desplaza hacia la parte superior de la atmósfera. Una parte del vapor de agua que sube se va enfriando hasta llegar a una altura en la que se condensa formando nubes. El agua contenida en ellas regresa por precipitación hacia la tierra y a las distintas cubiertas de agua.

5.1.1.2. Clasificación de la cubierta nubosa

A continuación se muestran las diferentes categorías en las que se puede clasificar las nubes:

5.1.1.2.1. Origen

Existen *nubes frontales* que se encuentran en los frentes cálidos, ocluidos y fríos, las *nubes orográficas* son aquellas que están ligadas en su génesis a la orografía o accidentes del terreno y las *nubes convectivas* se forman por la convección atmosférica en los días cálidos e inestables.

5.1.1.2.2. Naturaleza

Corresponden a las *nubes naturales* y *artificiales*. Las primeras se originan de forma natural, formadas por cristales de hielo y agua. Las segundas se forman por la acción directa o indirecta de los seres humanos (penachos de humo, nubes asociadas a la contaminación, etc.). También existen las *nubes estáticas* o *cuasi estacionarias* y nubes *móviles*, definidas por la naturaleza de su desplazamiento.

5.1.1.2.3. Forma

Las nubes se dividen en diez tipos (Ahrens, 2012; Cotton et al., 2010; Rogers & Yau, 1989) con diferentes dimensiones, opacidad y propiedades, como resultado de un efecto diferente en la irradiación solar. Los diferentes tipos de nubes se describen en la Tabla 1.

Tabla 1. Tipos de Nubes

GENERO	CARACTERISTICAS
NUBES ALTAS	
Cirros.	Nubes de aspecto filamentosos, no provocan precipitación
Cirrocumulos	Nubes de aspecto de glóbulos, no provocan precipitación
Cirrostratos	Nubes con aspecto de velo, provocan el halo solar y lunar
NUBES MEDIAS	
Alto cumulos	Con forma de glóbulos, que no dan precipitación
Alto estratos	Forman un manto que opaca al sol, no produce lluvias, provocan la corona solar y lunar
Nimbostratos	Capa nubosa gris de tipo estable que oculta al sol y provoca las precipitaciones de tipo continuas e intermitente.
NUBES BAJAS	
Estrato cumulos	Bancos de nubes cumuliformes que producen lluvias ligeras continuas y lloviznas
Estratos	Manto de nubes grises que pueden provocar lloviznas al espesarse mucho
Cúmulos	Nube aislada y densa, que se desarrolla verticalmente con protuberancias, no producen lluvias
NUBES DE DESARROLLO VERTICAL	
Cumulonimbus	Nube densa y potente, de considerable desarrollo vertical que produce chubascos y tormentas eléctricas.

Fuente: Tapakis & Charalambides (2013)

5.1.1.2.4. Nivel atmosférico

Las nubes están divididas en 4 grandes grupos, cada grupo depende de la altura a la que se encuentre la base de las nubes. La Tabla 2 describe el nivel atmosférico en el que se encuentran los diferentes grupos de nubes

Tabla 2. Nivel atmosférico de las Nubes

GRUPO	ALTURA DE LA BASE DE LAS NUBES
NUBES ALTAS	Trópicos: 6000-18000m Latitudes medias: 5000-13000m Región polar: 3000-8000m
NUBES MEDIAS	Trópicos: 2000-8000m Latitudes medias: 2000-7000m Región polar: 2000-4000m.
NUBES BAJAS	Trópicos: superficie-2000m Latitudes medias: superficie-2000m Región polar: superficie-2000m.
NUBES CON DESARROLLO VERTICAL	Trópicos: hasta los 12000m Latitudes medias: hasta los 12000m Región polar: hasta los 12000m.

Fuente: Tapakis & Charalambides (2013)

5.1.1.3. Sombras

Es una silueta bidimensional o una proyección invertida del objeto que bloquea la luz. Cuanto mayor es el ángulo entre la dirección de la luz y un objeto alargado que la obstaculice, más corta será su sombra. Por otro lado, cuanto menor sea el ángulo entre la dirección de la luz y la superficie en la que aparece la sombra, más larga será ésta. Si el objeto está cerca de la fuente luminosa, la sombra será mayor que si el objeto se encuentra lejos. Si la superficie está curvada, habrá más distorsiones. Cuanto más ancha es la fuente de luz, más difuminada o borrosa será la sombra.

Las sombras son uno de los mayores problemas en las imágenes capturadas por sensores remotos ya que dificulta la extracción de información de forma precisa y la detección de cambios (Shahtahmassebi et al, 2013). En teledetección espacial existen básicamente tres categorías de sombras que son las sombras generadas por objetos urbanos, montañas (sombras topográficas) y por las nubes. Tanto las sombras topográficas como las generadas por las nubes no presentan diferencias espectrales significativas que permitan clasificarlas (Martinuzzi et al., 2007). No obstante, pueden ser diferenciadas mediante su posición geográfica. La dirección de ocurrencia de la sombra correspondiente a la nube es igual para toda la imagen, ya que depende del ángulo de iluminación del sol, lo cual es constante sobre toda la imagen (Martinuzzi et al., 2007).

5.1.2. Sensores remotos

Son una herramienta que permite la obtención de información a distancia de los objetos sin tener un contacto físico con ello, a través de la energía electromagnética emitida. De esta manera es posible estudiar y analizar los

fenómenos que tienen implicaciones para la construcción de conocimiento en contextos disciplinarios como en la gestión del medio ambiente, la gestión del riesgo, la planeación territorial entre otras (Liang, 2005).

Esta información puede estar codificada en la frecuencia, intensidad o polarización de la onda y es transmitida directamente desde el objeto o indirectamente por *reflexión, dispersión o reemisión* hasta el sensor. Los sensores remotos cuentan con una resolución que se refiere a la capacidad para discriminar información de detalle en un objeto detectado (Fernandez et al., 2011). A continuación se describen los diferentes tipos de resolución:

La resolución espacial corresponde al tamaño del pixel, el cual, determina el nivel de detalle que se puede obtener de una imagen, entre menor sea el tamaño del pixel, mayor será la resolución espacial y viceversa. Este tamaño se puede calcular al conocer la altura en la que se encuentra el sensor y el campo instantáneo de visión (IFOV). *La resolución espectral* depende de la cantidad y el ancho de las bandas que contenga el sensor, entre más bandas espectrales tenga, mayor será la resolución espectral. *La resolución radiométrica* determina que tan sensible es el sensor, es decir, su capacidad de discriminar las variaciones en la radiación, se determina mediante el número de bits necesarios que se utilizan para el almacenamiento de cada pixel. Finalmente la resolución temporal establece el intervalo entre cada imagen obtenida por la plataforma, es decir la periodicidad con que el sensor puede adquirir una imagen del mismo punto de la superficie terrestre (Fernandez et al., 2011).

Liang (2005) señala que existen dos tipos de sensores:

Sensor activo: Son sensores que emiten microondas que son reflejadas por la superficie y son capturadas por antenas de radar, SAR (*Synthetic Aperture Radar*) o ALS (*Airborne Laser Scanning*) por sus siglas en inglés. Entre estos se encuentran de tipo radar y LIDAR (*Light Detection and Ranging o Laser Imaging Detection and Ranging*).

Sensor pasivo: Son sensores que reciben ondas electromagnéticas emitida o reflejada por la Tierra. Dentro de estos sensores están los sensores fotográficos, óptico-electrónicos, espectrómetros de imagen y de antena.

5.1.2.1. Plataformas satelitales

5.1.2.1.1. MODIS

El sensor MODIS está a bordo de los satélites Terra o EOS-AM (lanzado en diciembre de 1999) y Aqua o EOS-PM (lanzado en mayo de 2002). La órbita de ambas plataformas es helio-sincrónica y cuasi-polar con una inclinación de 98.2° y 98° y una altitud media de 708 y 705 km respectivamente (NASA, 2014a). Ambas plataformas monitorean la totalidad de la superficie terrestre cada 1 o 2 días dependiendo de la latitud.

El instrumento MODIS cuenta con una alta sensibilidad radiométrica (12 bit) en 36 bandas espectrales, en un rango de longitud de onda que va de los 0.4 μm a los

14.4 μm . Las primeras 19 bandas están posicionadas en la región del espectro electromagnético situado entre 0.405 nm y 2.155 nm. Las bandas de la 1 a la 7 son útiles para las aplicaciones terrestres; las bandas 8 a la 16 para las observaciones oceánicas y las bandas 17 a 19 para las mediciones atmosféricas. Las bandas 20 a la 36, cubren la porción del infrarrojo térmico del espectro de (3,660-14,385 nm) (NASA, 2014b). Dos bandas son tomadas a una resolución nominal de 250 m al nadir, cinco bandas a 500 m y las 29 bandas restantes a 1 km.

Producto MOD09: Es un grupo de productos derivado del satélite MODIS Terra, el cual contiene la evaluación de la reflectancia de las cubiertas terrestres, es decir la relación entre el flujo luminoso reflejado y el flujo luminoso incidente.

El producto de reflectancia de la superficie es utilizado para generar varios productos como los índices de vegetación, la función de distribución de la reflectancia bidireccional (BDRF), las coberturas del suelo, la cobertura de nieve, los puntos de calor así como el índice de área foliar y la fracción de radiación activa fotosintética (FPAR).

Este producto se encuentra disponible en varias resoluciones temporales y espaciales. Las capas de información difieren para cada producto. De manera general indican el número de observaciones, el valor de reflectancia en las diferentes bandas, los ángulos de observación y de inclinación solar. La capa de calidad indica la fiabilidad general, la presencia de nubes, la falla de algún detector, la ejecución o no de las correcciones atmosféricas.

5.1.2.2. Técnicas de realce de imágenes

Una de las principales técnicas que componen el procesamiento digital de imágenes es la de realce o mejora de las mismas. Esta técnica comprende un conjunto de operaciones tendientes a mejorar su calidad visual, permitiendo realzar las características de brillo y contraste, reducir su contenido de ruido, o agudizar o intensificar detalles presentes en ella (Aldalur & Santamaría, 2002). Las operaciones que componen la técnica de realce son ajuste de contraste aplicaciones en color, cambios de escala y filtrado.

5.1.2.2.1. Filtrado

Los filtros son una transformación que se realiza a la imagen por medio de un operador local, empleada para aislar o destacar elementos de interés transformando los niveles digitales originales, ya sea para aproximar los valores a los de sus vecinos o para diferenciarlos aún más, (Figura 1), (García, 2009; Pinilla et al., 1997). Entre ellos se destacan:

Filtro de paso bajo: Su objetivo es suavizar la imagen, son útiles cuando se supone que la imagen tiene gran cantidad de ruido y se quiere eliminar. También pueden utilizarse para resaltar la información correspondiente a una determinada escala.

Filtro de paso alto: Su objetivo es resaltar las zonas de mayor variabilidad eliminando la componente media, precisamente la que detectan los filtros de paso bajo. Por otra parte la respuesta de cada píxel está contaminada por la de los píxeles vecinos ya que, considerando la superficie terrestre como lambertiana, la radiación reflejada por un píxel se reparte hacia los píxeles vecinos. Los filtros de paso alto consiguen también eliminar en parte esta contaminación.

Filtros direccionales: Se utilizan para detectar estructuras que siguen una determinada dirección en el espacio resaltando el contraste entre los píxeles situados a ambos lados de la estructura.

Filtros para la detección de bordes: El operador realiza la diferencia en todas las direcciones entre los niveles digitales de un píxel y los vecinos. Como su nombre lo indica permite resaltar los bordes de todo los elementos presentes en de la imagen.




Figura 1. Matriz resultante de filtrado en el dominio espacial
Fuente: Pinilla et al. (1997)

5.1.3. Análisis de componentes principales

El Análisis de Componentes Principales (ACP) es un método de reducción de dimensionalidad cuyo supuesto es que un conjunto dado de variables iniciales se convierte en otro grupo de variables por medio de una transformación lineal, y estas nuevas variables se ordenan secuencialmente de acuerdo con la varianza en orden descendente (Lin et al., 2012; Zhao et al., 2012).

5.1.3.1. Análisis de matriz de correlaciones

La utilización de esta técnica de reducción de variables como ACP se debe desarrollar si existen altas correlaciones entre las variables. Por tanto, es necesario realizar un análisis de la matriz de correlaciones con el fin de establecer

si existe información redundante y si con pocos factores se puede explicar gran parte de la variabilidad total.

5.1.3.2. Determinación del número de factores

Los factores o también llamados componentes principales son los que retienen la mayor variabilidad contenida de los datos. Por tanto, la identificación de la cantidad de factores a seleccionar se realiza teniendo en cuenta el primer factor, el cual, agrupa la mayor proporción posible de la variabilidad original, el siguiente factor agrupará la parte de la variabilidad que el primero no pudo agrupar y así sucesivamente cada componente se hace cargo de parte de la variabilidad global. De todos estos factores, se escogen solo los que recojan un porcentaje de variabilidad considerado como suficiente, siendo estos los componentes principales.

5.1.3.3. Análisis de la matriz factorial

Posterior a la identificación del número de factores, se realiza una representación de estos en forma matricial. Esta nueva matriz representa los coeficientes factoriales de las variables, es decir, las correlaciones entre las variables y los componentes principales. El tamaño de la matriz depende del número de componentes principales y el número de variables.

En general con el análisis factorial se pretende condensar la información contenida en un número original de variables en una cantidad menor de nuevas dimensiones (factores) con una pérdida de información mínima.

5.1.3.4. Rotación de los ejes

Consiste en una transformación de la matriz factorial original en otra más simple que adecúa mejor los ejes al aproximarlos a las variables correlacionadas. Esto facilita la interpretación de la estructura de los datos, puesto que no se altera la bondad de ajuste de la solución factorial, ni los porcentajes de varianza, simplemente se redistribuye la varianza explicada entre los factores (Bernal et al, 2004). El efecto de la rotación es redistribuir la varianza para obtener un patrón de factores con mayor significado.

5.1.4. Métodos de Detección de Nubes

En la presente sección se establecen los conceptos relacionados con los métodos de detección de nubes a implementar, siendo estos el método de máscaras de nubes basado en la inflexión de series temporales (Goodwin et al 2013, Liu et al 2013) y el método de redes neuronales artificiales de perceptrón multicapa (Taravat et al 2015).

5.1.4.1. Series de Tiempo

Una serie tiempo es una secuencia de observaciones, medidos en determinados momentos del tiempo, ordenados cronológicamente y, espaciados entre sí de manera uniforme, así los datos usualmente son dependientes entre sí.

Las series de tiempo resultan especialmente útiles cuando se requiere realizar un pronóstico sobre el comportamiento futuro que puede tener una variable

determinada. Sin embargo, también pueden ser empleadas para observar el comportamiento en el tiempo de un fenómeno, identificando cambios abruptos que no corresponden a la normalidad de los datos.

5.1.4.1.1. Herramientas de análisis temporal

Autocovarianza: Se define como una herramienta de análisis de series de tiempo. Su estructura matemática es similar a la covarianza entre dos variables aleatorias, solo que en este caso se calcula la covarianza entre dos copias de la misma serie de tiempo desplazando una con respecto a la otra por un intervalo o regazo.

Autocorrelación: Se define como una herramienta de análisis de series de tiempo. Describe la correlación entre los valores del proceso en diferentes momentos, como una función de los dos tiempos o de la diferencia de tiempo. Se define como la normalización de la función de autocovarianza.

5.1.4.1.2. Componentes

El análisis clásico de las series temporales se basa en la suposición de que los valores que toma la variable de observación es la consecuencia de tres componentes, cuya actuación conjunta da como resultado los valores medidos, estos componentes son:

Componente tendencia: Se puede definir como un cambio a largo plazo que se produce en la relación al nivel medio, o el cambio a largo plazo de la media. La tendencia se identifica con un movimiento suave de la serie a largo plazo.

Componente estacional: Muchas series temporales presentan cierta periodicidad o dicho de otro modo, variación de cierto período (semestral, mensual, etc.).

Componente aleatoria: Esta componente no responde a ningún patrón de comportamiento, sino que es el resultado de factores fortuitos o aleatorios que inciden de forma aislada en una serie de tiempo.

5.1.4.1.3. Clasificación

Las series temporales se pueden clasificar en:

Estacionarias: Una serie es estacionaria cuando es estable a lo largo del tiempo, es decir, cuando la media y varianza son constantes en el tiempo. Esto se refleja gráficamente en que los valores de la serie tienden a oscilar alrededor de una media constante y la variabilidad con respecto a esa media también permanece constante en el tiempo.

No estacionarias: Son series en las cuales la tendencia y/o variabilidad cambian en el tiempo. Los cambios en la media determinan una tendencia a crecer o decrecer a largo plazo, por lo que la serie no oscila alrededor de un valor constante.

5.1.4.2. Redes Neuronales Artificiales

Es un modelo matemático que inspirado en el comportamiento biológico de las neuronas y en la estructura del cerebro, implementada para la solución de una gran variedad de problemas.

Debido a su constitución y a sus fundamentos, las redes neuronales artificiales presentan un gran número de características semejantes a las del cerebro. Por ejemplo, son capaces de aprender de la experiencia, de generalizar de casos anteriores a nuevos casos, de abstraer características esenciales a partir de entradas que representan información relevante, etc.

5.1.4.2.1. Ventajas

Las principales ventajas que representan son:

Aprendizaje Adaptativo: Capacidad de aprender a realizar tareas basadas en un entrenamiento o en una experiencia inicial.

Auto-organización: Una red neuronal puede crear su propia organización o representación de la información que recibe mediante una etapa de aprendizaje.

Tolerancia a fallos: La destrucción parcial de una red conduce a una degradación de su estructura; sin embargo, algunas capacidades de la red se pueden retener, incluso sufriendo un gran daño.

Operación en tiempo real: Los cálculos neuronales pueden ser realizados en paralelo; para esto se diseñan y fabrican máquinas con hardware especial para obtener esta capacidad.

Fácil inserción dentro de la tecnología existente: Se pueden obtener chips especializados para redes neuronales que mejoran su capacidad en ciertas tareas. Ello facilitará la integración modular en los sistemas existentes.

5.1.4.2.2. Estructura

La estructura de una red neuronal consiste básicamente de tres partes: Una capa de entrada, una capa o varias capas ocultas donde se aplican funciones de activación, y una capa de salida que muestra las respuestas de la red a una entrada.

Capa de entrada: Esta capa recibe las señales desde el entorno, en donde son presentados los datos a la red. Las variables que conforman estos datos de entrada reciben el nombre de *inputs*.

Capa oculta: Del mismo modo que el cerebro está constituido por neuronas, la unidad básica constituyente de la red neuronal es el nodo, neurona o elemento de procesado. Un nodo es un elemento de cálculo interconectado con otros muchos elementos, imitando las sinapsis nerviosas. A un nodo llegan conexiones desde

muchas otras neuronas, proporcionando una respuesta se muestra en la capa de salida (Figura 2).




Figura 2. Estructura Topológica de la Red Neuronal.

Fuente: Caicedo & Lopez (2009)

El nodo de la capa oculta condensa las variables de la capa de entrada con los respectivos pesos asignados aleatoriamente, estos reflejan la conexión entre las neuronas. Posteriormente se aplica una función que recibe el nombre de función de transferencia o de activación; la cual es en parte responsable de la bondad del comportamiento de la red neuronal. De esta manera se obtiene la salida del nodo, que a su vez podrá ser la entrada de algún otro nodo.

Capa de salida: En ella se muestra las respuestas de la red a una entrada, que reciben el nombre de *outputs*.

5.1.4.2.3. Clasificación

Para la clasificación de las redes neuronales se distinguen dos tipos de clasificaciones, según su arquitectura y su aprendizaje.

La arquitectura de una red consiste en la disposición y conexionado de las neuronas. Se puede distinguir en una red, 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

Redes Monocapa: cuentan con una capa de neuronas, que intercambia señales con el exterior y que constituyen a un tiempo la entrada y la salida del sistema.

Redes Multicapa: están formadas por dos o más capas de neuronas conectadas entre ellas. Dependiendo de cómo sean estas conexiones se pueden hacer otra subdivisión entre las redes con conexiones hacia delante y las redes con conexiones hacia atrás. Las primeras contienen solo conexiones entre capas hacia delante, esto implica que una capa no puede tener conexiones a una que reciba la señal antes que ella en la dinámica de la computación. Las segundas realizan

conexiones de capas hacia atrás y por tanto la información puede regresar a capas anteriores en la dinámica de la red (Serrano et al., 2009).

El aprendizaje se basa en el entrenamiento de la red con patrones. El proceso de aprendizaje se basa en que la red ejecute los patrones de forma iterativa hasta que se muestren respuestas satisfactorias. Es decir, los pesos sinápticos se ajustan para dar respuestas óptimas para el conjunto de patrones de entrenamiento. Se distingue tres tipos de aprendizaje:

Aprendizaje Supervisado: la red dispone de los patrones de entrada y de salida que queremos obtener para esa entrada, y en función de ellos se modifican los pesos de las sinopsis para ajustar la entrada a la salida.

Aprendizaje No Supervisado: consiste en no proporcionar a la red los patrones de salida, sino sólo los de entrada y dejar que la red los clasifique en función de características comunes que encuentre entre ellos.

Aprendizaje Híbrido: No se proporcionan los patrones objetivo, sino que sólo se dice si la respuesta acierta o falla ante un patrón de entrada.

5.1.4.2.4. Modelos

Existen varios modelos de redes neuronales, cada una de ellos ha sido diseñado para fines específicos, no obstante, existen varios que han ganado gran popularidad. En la Tabla 3, se presentan los modelos más conocidos junto a sus características (Anegón, 1998):

Tabla 3. Modelos de Redes Neuronales

Nombre	Aplicaciones	Comentarios	Limitaciones
Avalancha	Reconocimiento de habla continúa. Control de robots.	Ninguna red sencilla realiza estas tareas	No es fácil alterar la velocidad o interpolar el movimiento
Teoría de resonancia adaptativa (ART)	Reconocimiento de patrones (radar, sonar, etc.)	Sofisticada, poco utilizada	Sensible a la translación, distorsión y escala
ADALINE/MADALINE	Filtrado de señales. Ecualizador adaptativo. Modems	Rápida, fácil de implementar con circuitos analógicos	Sólo es posible clasificar espacios linealmente separados
Perceptrón Multicapa	Síntesis de voz desde texto. Control de robots. Predicción Reconocimiento de patrones	La red más popular. Numerosas aplicaciones con éxito. Facilidad de aprendizaje. Potente.	Necesita mucho tiempo para el aprendizaje y muchos ejemplos

Nombre	Aplicaciones	Comentarios	Limitaciones
Memoria asociativa bidireccional	Memoria heteroasociativa de acceso por contenido.	Aprendizaje y arquitectura simples	Baja capacidad almacenamiento. Los datos deben ser codificados
Máquinas de Boltzmann y Cauchy	Reconocimiento de patrones (imágenes, sonar y radar). Optimización	Redes simples Capacidad de representación óptima de patrones	La máquina de Boltzmann necesita un tiempo muy largo de aprendizaje
Bratn-State-in-a-Box	Extracción de conocimiento de bases de datos	Posiblemente mejor realización que las redes de Hopfield	Realización potenciales aplicaciones no estudiadas totalmente
Cerebellatron	Control del movimiento de brazos de un robot	Semejante a Avalancha	Requiere complicadas entradas de control
Counterpropagation	Comprensión de imágenes	Combinación de Perceptron y TPM	Numerosas neuronas y conexiones
Hopfield	Reconstrucción de patrones y optimización	Puede implementarse en VLSI. Fácil de conceptualizar	Capacidad y estabilidad
Neocognitron	Reconocimiento de caracteres manuscritos	Insensible a la translación, rotación y escala	Requiere muchos elementos de proceso, niveles y conexiones
Perceptrón Monocapa	Reconoce y aprende patrones sencillos con una superficie de separación lineal	La red más antigua	Incapacidad para separar regiones que no son linealmente separables
Self-Organizing- Map (SOM)	Reconocimiento de patrones, codificación de datos, optimización	Realiza mapas de características comunes de los datos aprendidos	Requiere mucho entrenamiento

Fuente: Anegón (1998)

Para el desarrollo de la metodología se hará uso del modelo de la Red Neuronal de Perceptrón Multicapa (MLP). El uso de esta red permite la combinación de las variables preparatorias, el cálculo de sus pesos traen muchas ventajas, puesto que ofrecen una manera objetiva de clasificación y asignación de pesos ya que

tienen una mínima intervención humana. Además, requieren menos datos de entrenamiento para realizar un análisis preciso.

5.2. MARCO REFERENCIAL

Las nubes son uno de los principales problemas para la medición de parámetros físicos de la superficie terrestre mediante sensores remotos (Zhu & Woodcock, 2014). El brillo de las nubes y el efecto de oscurecimiento de sus sombras, influyen significativamente en la reflectancia de diferentes bandas espectrales, causando distorsión e incertidumbre durante el análisis en la información (Alain et al., 2006). Resultados recientes sugieren que parte de esta incertidumbre en estudios basados en sensores remotos, se debe a la inadecuada corrección atmosférica y de los modelos del enmascaramiento de nubes (Hilker et al., 2012).

La observación de la tierra mediante la teledetección depende en gran medida de la disponibilidad de máscaras de nubes precisas (Sedano et al., 2011). Estas son un producto para el procesamiento de datos satelitales muy importante, el cual es usado como parámetro de entrada para varios algoritmos de procesamiento de la información, con el fin de evitar que estos píxeles contaminados sean utilizados. Como ejemplo se pueden mencionar el cálculo del Índice de Vegetación de Diferencia Normalizado (NDVI), estimación de la Temperatura de la Superficie del Mar (SST), detección de cambios en la superficie del suelo, generación de mapas de vectores de vientos, entre otros (Kussul et al., 2005).

En los últimos años, varios estudios han propuesto diversas estrategias para adaptar y mejorar los métodos de detección de nubes a partir de imágenes satelitales. Estos métodos incluyen técnicas basadas en información espectral, geométrica y temporal.

Por lo general, los métodos que emplean información espectral corresponden a clasificaciones supervisadas y no supervisadas (Kennedy et al., 2010; Sano et al., 2007), árboles de clasificación (Hansen et al., 2008), umbrales empíricos aplicados a una o más bandas espectrales / o indicadores derivados (Martinuzzi et al., 2007; Oreopoulos & Wilson, 2011), el algoritmo de detección de nubes modificada *Luo-Trishchenko-Khlopenkov* del algoritmo MODIS (Oreopoulos & Wilson, 2011), y las modificaciones o Incorporación del algoritmo de Automático de Evaluación de Nubosidad (ACCA).

Además, se han implementado métodos de clasificación estadística que son frecuentemente usados para asignar la clase a la que pertenecen cada uno de los píxeles de nubes de una imagen de satélite (Sanchez, 2003). Uno de los aspectos más destacados de estos algoritmos es que producen resultados de probabilidad de pertenencia. De hecho, algunos de ellos se basan en la clasificación de cada píxel a la clase a la que pertenece con mayor probabilidad. También pueden dar como resultado imágenes clasificadas en donde cada clase, incluso cada píxel tiene su nivel de confianza estimado. Para la aplicación de estos algoritmos se necesita asumir una serie de hipótesis estadísticas a priori como funciones de probabilidad o como funciones de distribución (Carvajal et al., 2004).

De igual manera se han desarrollado métodos para el enmascaramiento de nubes en los que interviene la posición del sol y el sensor del satélite. Este es el caso de los modelos geométricos que incluyen el cálculo de las variables de la declinación solar, el ángulo cenital, azimut solar y altura entre la nube y la sombra para definir las coordenadas del pixel sombra en el plano tangente a la tierra (Hagolle et al., 2010; Martinuzzi et al., 2007), después emplear los modelos radiométricos, los cuales permiten la caracterización de las nubes. Huang et al (2010) también incluyó un modelo de elevación digital (DEM) para mejorar la proyección de la nube en la superficie de la tierra.

Por otro lado una de las variables más importantes para la caracterización de las sombras de las nubes es el cálculo de la altura existente entre ellas, dado que de esta manera no se utiliza la respuesta espectral de las sombras en la imagen, que puede ser similar entre los elementos de la zona, sino que se emplea la posición de sus coordenadas y su área sobre el terreno. Para determinar estos factores se emplean diversas metodologías como es el caso de los modelos geométricos y radiométricos propuestos por (Lissens et al., 2000).

El uso de algoritmos de inteligencia artificial como las redes neuronales ha abierto nuevas perspectivas para clasificar imágenes satelitales y datos auxiliares porque no hacen hipótesis sobre la distribución de los datos (Atkinson & Tatnall, 1997; Civco, 1993; Foody et al., 1995). Ofrecen un excelente potencial para mejorar la precisión de la clasificación de los datos geofísicos y a diferencia de algunos algoritmos como por ejemplo el algoritmo del vecino más cercano, son computacionalmente más eficiente (Lee et al., 1990). Además, tienen la capacidad de integrar información necesaria desde múltiples fuentes para mejorar la clasificación.

También se han implementado algoritmos que permiten incorporar datos de dimensiones espaciales y temporales para el proceso de enmascaramiento de nubes y sombras (Lyapustin et al., 2008). Enfoques como el de series de tiempo tiene ventaja sobre los métodos que trabajan sobre fechas individuales, puesto que destacan los píxeles que cambian de brillo o un indicador derivado en el tiempo (Kennedy et al., 2010). Uno de los aspectos más destacados de estos algoritmos es que busca dejar una imagen de referencia libre de nubes con el fin de ser comparada con la imagen original (Goodwin et al., 2013).

La exactitud de la máscara de nubes se determina a partir de la coincidencia entre valores reales y observados, utilizando una matriz de contingencia (Sedano et al., 2011) o el coeficiente kappa, a partir de los cuales se comparan las áreas bajo la curva en donde las más cercanas a uno, corresponden a modelos mejor clasificados para ambos métodos.

5.3. MARCO TEÓRICO

En la presente sección se aborda en detalle los modelos teóricos para el desarrollo del proyecto. Entre estos se menciona el análisis de componentes principales para la identificación de las variables más representativas del fenómeno de estudio, las técnicas de realce de imagen para eliminar los ruidos

presentes en ellas, los modelos matemáticos que estructuran los métodos propuestos y su validación.

5.3.1. Análisis de Componentes Principales

El Análisis de Componentes Principales (ACP) transforma el conjunto de variables originales en un conjunto más pequeño, donde esas nuevas variables son combinación lineal de las primeras, que contienen la mayor parte de la variabilidad presente en el conjunto inicial (Ahmad & Quegan, 2012).

El ACP tiene como objetivo:

- Generar nuevas variables que expresan la información contenida en un conjunto de datos.
- Reducir la dimensión del espacio donde están los datos.
- Eliminar las variables (si es posible) que aporten poco al estudio del problema.
- Facilitar la interpretación de la información contenida en los datos.

El ACP tiene como propósito principal la determinación de unos pocos factores llamados componentes principales, los cuales retienen la mayor variabilidad contenida en los datos. Estas componentes tienen la característica de que son incorrelacionadas. Si las variables originales no están correlacionadas, entonces no tiene sentido realizar un análisis de componentes principales.

Sean $(X_1, X_2, \dots, X_p)$ las p variables objeto de análisis, que deben estar clasificadas. En caso de que no lo estén, el análisis se realizaría de forma similar pero la matriz utilizada para calcular los factores no sería la matriz de correlación sino la de varianzas y covarianzas.

El investigador mide estas variables sobre n individuos, obteniéndose la siguiente matriz de datos (Tabla 4):

Tabla 4: Matriz de datos

Sujetos	Variables			
	X_1	X_2	$\dots$	X_p
1	x_{11}	x_{12}	$\dots$	x_{1p}
2	x_{21}	x_{22}	$\dots$	x_{2p}
$\dots$	$\dots$	$\dots$	$\dots$	$\dots$
n	x_{n1}	x_{n2}	$\dots$	x_{np}

Fuente: Lózares & López (1991)

El modelo del Análisis Factorial viene dado por las ecuaciones:

$$X_1 = a_{11}F_1 + a_{12}F_2 + \dots + a_{1k}F_k + u_1 \quad (1)$$

$$X_2 = a_{21}F_1 + a_{22}F_2 + \dots + a_{2k}F_k + u_2 \quad (2)$$

$$X_p = a_{p1}F_1 + a_{p2}F_2 + \dots + a_{pk}F_k + u_p \quad (3)$$

Donde:

$(F_1, F_2, \dots, F_k)$ ($k < p$) Son los factores comunes

$(u_1, u_2, \dots, u_p)$ Son los factores únicos o específicos

$(a_{ij}) = \{i = 1, \dots, p; j = 1, \dots, k\}$ Son las cargas factoriales

Los factores comunes están a su vez estandarizados, mientras que los factores específicos tienen una media igual a cero y están correlacionados. Si los factores comunes no están correlacionados, se dice que es un modelo con factores ortogonales, en caso contrario, el modelo corresponde a factores oblicuos, expresado de forma matricial según la Ecuación (4):

$$x = Af + u \leftrightarrow X = FA' + U \quad (4)$$

Donde:

$X \equiv$ Matriz de datos

$A \equiv$ Matriz de cargas factoriales

$F \equiv$ Matriz de puntuaciones factoriales

$$x = \begin{pmatrix} x_1 \\ x_2 \\ \dots \\ x_p \end{pmatrix}, f = \begin{pmatrix} F_1 \\ F_2 \\ \dots \\ F_p \end{pmatrix}, u = \begin{pmatrix} u_1 \\ u_2 \\ \dots \\ u_p \end{pmatrix}, A = \begin{pmatrix} a_{11} & a_{12} & \dots & a_{1k} \\ a_{21} & a_{22} & \dots & a_{2k} \\ \dots & \dots & \dots & \dots \\ a_{p1} & a_{p2} & \dots & a_{pk} \end{pmatrix}, F = \begin{pmatrix} f_{11} & f_{12} & \dots & f_{1k} \\ f_{21} & f_{22} & \dots & f_{2k} \\ \dots & \dots & \dots & \dots \\ f_{p1} & f_{p2} & \dots & f_{pk} \end{pmatrix} \quad (5)$$

Utilizando las hipótesis anteriores, se tiene:

$$Var(X_i) = \sum_{j=1}^k a_{ij}^2 + \Psi_i = h_i^2 + \Psi_i \quad (i = 1, 2, \dots, p) \quad (6)$$

Donde:

$h_i^2 = Var(\sum_{j=1}^k a_{ij} F_j)$: Comunalidad de la variable x_i

$\Psi_i = Var(u_i)$: Especificidad de la variable x_i

En consecuencia, la varianza de cada una de las variables analizadas se puede descomponer en dos partes: la comunalidad h_i^2 que representa la varianza explicada por los factores comunes y la especificidad Ψ_i que representa la parte de la varianza específica de cada variable. Por este motivo, los factores comunes tienen un gran aporte, además de ser susceptibles de interpretación experimental. Los factores únicos se incluyen en el modelo dado la imposibilidad de expresar, en general, p variables en función de un número más reducido k de factores.

El índice definido para el conjunto de los coeficientes es el de Kaiser-Meyer-Olkin (KMO) que compara el sumatoria de los coeficientes de correlación simples con los de correlación parcial, para las variables j, j' según la expresión (Lózares & López, 1991):

$$KMO = \frac{\sum \sum r_{jj'}^2}{\sum \sum r_{jj'}^2 + \sum \sum a_{jj'm}^2} \quad (8)$$

Donde:

$r_{jj'}$ = coeficientes de correlación simples entre las variables j, j'

$a_{jj'}$ = coeficientes de correlación parcial entre las variables j, j' eliminado el efecto de las m variables restantes incluidas en el análisis.

El test KMO se basa precisamente en la relación existente entre el conjunto de coeficientes de correlación y de correlación parcial. Se entiende que si el conjunto de los coeficientes de correlación parcial son de valores reducidos, la parte específica de las variables será menor con relación a la parte común, lo que hará más pertinente la realización del ACP (Lózares & López, 1991). En últimas, este test mide la idoneidad de los datos para realizar un análisis factorial comparando los valores de los coeficientes de correlación observados con los coeficientes de correlación parcial.

La rotación VARIMAX tiene como fin redistribuir la varianza para obtener un patrón de factores con mayor significado, la cual expresa mediante la Ecuación (9) (Lózares & López, 1991).

$$V(Y_k) = \sum_{j=1}^p \frac{(a_{jk}^2 - a_{0k}^2)^2}{p} = \frac{(p \sum_{j=1}^p a_{jk}^4 - (\sum a_{jk}^2)^2)}{p^2} \quad (9)$$

Para el conjunto $V = \sum_{j=1}^p V(Y_k)$

Donde a_{0k}^2 , es la media de las a_{jk}^2 del conjunto de valores $j= 1, \dots, p$.

5.3.2. Filtros espaciales

La aplicación de filtros consiste en un proceso de transformación a partir de un estímulo o señal de entrada generando un estímulo de la misma naturaleza. Este toma una o varias imágenes para crear otra en la que se han resaltado o atenuado ciertas características (Gómez, 1995). El proceso de transformación consiste en definir una matriz cuadrada con los coeficientes del filtro y desplazarla a través de la imagen.

Para la aplicación del filtro se requiere de una matriz W de dimensiones $n \times m$, la cual contiene $n \times m$ coeficientes que recorren la imagen. Por lo general, en el procesamiento de imágenes se utilizan matrices de tamaño 3×3 o 5×5 , sin embargo esto depende del tipo de detalle que se quiera resaltar. La Ecuación (10) muestra una generalización de un filtro de tamaño $n \times m$.

$$W = \begin{bmatrix} w_{1,1} & w_{1,2} & \dots & \dots & w_{1,m} \\ w_{2,1} & w_{2,2} & \dots & \dots & w_{2,m} \\ \dots & \dots & \dots & \dots & \dots \\ w_{n-1,1} & w_{n-1,2} & \dots & w_{n-1,m-1} & w_{n-1,m} \\ w_{n,1} & w_{n,2} & \dots & w_{n,m-1} & w_{n,m} \end{bmatrix} \quad (10)$$

La aplicación del filtro se realiza sobre un segmento de la imagen de igual tamaño al filtro, en la que en la mayoría de los casos se utiliza la posición del centro del filtro como la posición de salida en dicho segmento. Para ilustrar lo anterior, en las Ecuaciones (11) y (12) se empleará un filtro de tamaño 3x3 para identificar la salida en una posición definida de la imagen.

$$W = \begin{bmatrix} w_{1,1} & w_{1,2} & w_{1,3} \\ w_{2,1} & w_{2,2} & w_{2,3} \\ w_{3,1} & w_{3,2} & w_{3,3} \end{bmatrix} \quad (11)$$

$$O_{x,y} = W_{1,1} * I_{(x-1,y-1)} + W_{1,2} * I_{(x-1,y)} + W_{1,3} * I_{(x-1,y+1)} + W_{2,1} * I_{(x,y-1)} + W_{2,2} * I_{(x,y)} + W_{2,3} * I_{(x,y+1)} + W_{3,1} * I_{(x+1,y-1)} + W_{3,2} * I_{(x+1,y)} + W_{3,3} * I_{(x+1,y+1)} \quad (12)$$

Donde:

W = Matriz de filtro con sus respectivos coeficientes.

$O_{x,y}$ = Valor de salida en la posición x e y de la imagen.

$I_{(x,y)}$ = Valor de la imagen de entrada en la posición x e y.

Filtro de media aritmética

El filtro de media permite el suavizado de imágenes reduciendo la variación de intensidad entre un píxel y los píxel vecinos. Se utiliza para reducir el ruido en las imágenes (Aldalur & Santamaría, 2002; Garcia, 2009). Se visita cada píxel de la imagen y se reemplaza por la media de los píxeles vecinos. Esta se expresa mediante la Figura 3.

$$\frac{1}{9} * \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix}$$

Figura 3. Forma matricial del filtro de media aritmética

Filtro de Sobel

Es el resultado de aplicar la teoría del cuadrado del binomio, en este caso, se pondera la fila y la columna en la cual se calcula el gradiente. La máscara de este filtro es una matriz de 3x3 (Al-Amri et al., 2010). Ésta se define mediante la siguiente expresión:

$$S_{i,j} = \sqrt{C^2 + F^2} \quad (14)$$

Siendo:

$$\begin{bmatrix} S_0 & S_1 & S_2 \\ S_7 & [S_{i,j}] & S_3 \\ S_6 & S_5 & S_4 \end{bmatrix} \quad (15) \quad \begin{aligned} C &= (S_2 + 2S_3 + S_4) - (S_0 + 2S_7 + S_6) \\ F &= (S_0 + 2S_1 + S_2) - (S_6 + 2S_5 + S_4) \end{aligned}$$

Donde:

C y F : Corresponden a los gradientes de columnas y filas respectivamente

5.3.3. Métodos para la detección de nubes

5.3.3.1. Algoritmo de detección de nubes basado en la inflexión de una series Temporal (IBCM)

A continuación se muestran los modelos generales para la implementación del algoritmo de máscaras de nubes basado en la inflexión de series temporales.

5.3.3.1.1. Distancia de un punto a una recta

La distancia del punto $C(x,y)$ hacia la recta AB con coordenadas (x_1,y_1) y (x_2,y_2) respectivamente, es la longitud del segmento perpendicular a la recta (Figura 4). A partir de la Ecuación (16), se determina el punto de inflexión de las observaciones, el cual, es el fundamento de la aplicación del algoritmo.




Figura 4: Distancia del punto a la recta

$$d = \frac{(x - x_1) * (y_1 - y_0) + (y - y_1) * (x_0 - x_1)}{\sqrt{(y_1 - y_0)^2 + (x_0 - x_1)^2}} \quad (16)$$

Donde:

x, y = Coordenadas del punto C.

x_0, y_0 = Coordenadas del punto A

x_1, y_1 = Coordenadas del punto B

5.3.3.1.2. Ángulo formado entre tres puntos

El ángulo existente entre las rectas AC y CB se calcula mediante la Ecuación (17), (Figura 5). La identificación del ángulo entre las observaciones limpias o libres de nubes y las observaciones nubosas brinda información importante con respecto a la viabilidad del método.




Figura 5: Ángulo comprendido entre dos rectas

$$\alpha = \cos^{-1} \left[\frac{(x_1 - x_3) * (x_0 - x_3) + (y_1 - y_3) * (y_0 - y_3)}{\sqrt{(x_1 - x_2)^2 + (y_1 - y_3)^2} \sqrt{(x_0 - x_3)^2 + (y_0 - y_3)^2}} \right] \quad (17)$$

Donde:

α = Ángulo comprendido entre las dos rectas

x_0, y_0 = Coordenadas del punto A

x_1, y_1 = Coordenadas del punto B

x_3, y_3 = Coordenadas del punto de inflexión C

5.3.3.1.3. Factor de escala

El factor de escala permite asignar una igual proporcionalidad a los datos, de tal forma que sus mínimos y máximos coincidan. La Ecuación (18) presenta el cálculo del factor de escala sobre un vector cualquiera de tamaño n.

$$\text{Factor Escala} = (\max(x) - \min(x)) * n \quad (18)$$

Donde:

$\max(x)$ = Valor máximo del vector x.

$\min(x)$ = Valor mínimo del vector x.

n = Tamaño del vector x.

5.3.3.2. Redes Neuronales

A continuación se muestran los modelos que permiten estructurar una red neuronal. Esta estructura se compone de tres capas (de entrada, oculta y de salida), las cuales cumplen una función específica dentro de la red. En la capa de entrada se presentan los datos a la red, en la capa oculta se condensan cada una de las variables con los pesos asignados aleatoriamente por la red y la capa de salida se encarga de dar respuesta ante una entrada.

5.3.3.2.1. Número de nodos de la capa oculta

La determinación del número de neuronas que componen la red ha sido un tema ampliamente investigado, por lo que existen diferentes propuestas que permiten su estimación (Tabla 5). No existe un límite para definir la cantidad de nodos, pero se ha demostrado que se requiere de un mínimo de 3 para solucionar problemas complejos (Delgado & Quintín, 2003) .

Tabla 5. Modelos para la identificación del número de neuronas

Autor	Modelo
(Hecht-Nielsen, 1987)	$2 \cdot Ni + 1$
(Kanellopoulos & Wilkinson, 1987)	$2 \cdot Ni$
(Hush, 1989)	$3 \cdot Ni$
(Wang, 1994)	$2 \cdot Ni / 3$
(Ripley, 1993)	$(Ni + No) / 2$
(Kaastra & Boyd, 1996)	$\sqrt{Ni \cdot No}$
(Paola & Schowengerdt, 1994)	$\frac{2 + No \cdot Ni + \frac{1}{2} \cdot No \cdot (Ni^2 + Ni) - 3}{Ni + No}$

Fuente: Kavzoglu (2001)

Donde:


N_i = es el número de variables explicativas o entradas (inputs). Coincide con el número de nodos de la capa de entrada.

N_o = es el número de nodos de la capa de la capa de salida.


5.3.3.2.2. Estructura de la red

Para definir la estructura de la red se debe tener una función de activación, la cual asocia aleatoriamente un peso a cada una de las variables de entrada. Algunas de las funciones más usadas son:


Función escalón o signo: Sus aplicaciones se restringen a problemas binarios entre (0,1) ó (-1,1)). En este caso, si la activación de la neurona es inferior a un determinado umbral, la salida se asocia con un determinado output, y si es igual o superior al umbral se asocia con el otro output. Entre las redes que utilizan este tipo de función se utiliza en redes como Perceptrón Simple, la red de Hopfield discreta y la neurona clásica de McCulloch-Pitts. Esta función se define mediante la Ecuación (19) (Flórez & Fernández 2008).



Función lineal o identidad: Devuelve directamente el valor de activación de la neurona. Este tipo de función se utiliza en redes de baja complejidad, como el modelo Adaline (Widrow et al., 1987). Esta función se define mediante la Ecuación (20):




Función mixta o lineal a tramos: Es una variante progresiva de la función escalón. Si la activación de la unidad es menor que un límite inferior preestablecido, la salida se asocia con un determinado valor; si la activación es igual o superior que un límite superior, la salida se asocia con otro valor. Si el nivel de activación se encuentra comprendido entre ambos límites, se aplica la función lineal o identidad. Esta alternativa puede considerarse como una función lineal saturada en sus extremos, siendo de gran sencillez computacional. Esta función se define mediante la Ecuación (21) (Flórez & Fernández 2008).




Función sigmoidea: Definida en un determinado intervalo monótonico con límites superiores e inferiores. Entre las funciones sigmoideas de transferencia más aplicadas destacan la función sigmoidea, logística o la función tangente hiperbólica. Las funciones sigmoideas se caracterizan por presentar una derivada siempre positiva e igual a cero en sus límites asintóticos, que toma su valor máximo cuando $x=0$. Así, estas funciones admiten la aplicación de las reglas de aprendizaje típicas de la función escalón, con la ventaja adicional que la derivada se encuentra definida en todo el intervalo, lo que permite emplear algoritmos de


entrenamiento más avanzados. La función tangente hiperbólica se define mediante la Ecuación (22) (Flórez & Fernández 2008).



Función Gaussiana: Son funciones muy versátiles puesto que su centro, radio y apuntamiento son susceptibles de adaptación. Se pueden aplicar a redes complejas con m capas ocultas que requieren reglas de propagación basadas en el cálculo de distancias cuadráticas entre los vectores de entrada y los pesos de la red (por ejemplo, la distancia euclídea al cuadrado). Esta función se define mediante la Ecuación (23) (Flórez & Fernández 2008).



Función sinusoidal: Genera salidas continuas en el intervalo [-1,+1]. Estas funciones suelen emplearse en los casos en los que se requiere explícitamente una periodicidad temporal. Esta función se define mediante la Ecuación (24) (Flórez & Fernández, 2008).



Donde:

$Y_n, f(x)$: Respuesta ante la entrada x

x : Valor de entrada al nodo

n : es el número que identifica la capa correspondiente a la neurona

5.3.3.2.3. Algoritmos de aprendizaje

5.3.3.2.3.1. Algoritmo de Backpropagation

A continuación se presenta los pasos que se deben llevar a cabo para entrenar un red multicapa con el método de aprendizaje *Backpropagation* señalado por Caicedo & Lopez (2009)

Paso 1:

Se presenta un vector de entrada x_p a la red.

$$x_p = [x_{p1}, x_{p2}, \dots, x_{pi}, \dots x_{pn}]^T \quad (25)$$

Donde x_p es el patrón de entrada, x_{pi} entrada i -ésima del vector de entrada x_p

Paso 2:

Se calculan los valores de las entrada netas para la capa oculta

$$Neta_{pj}^h = \sum_i^N w_{ji}^h + x_{pi} + \theta_j^h \quad (26)$$

Donde w_{ji}^h es el peso de interconexión entre la neurona i -ésima de la entrada y la j -ésima de la capa oculta, θ_j^h es el termino de tendencia de la neurona j -ésima de la capa oculta, $Neta_{pj}^h$ entrada neta de la j -ésima neurona de la capa oculta.

Paso 3:

Se calculan la salida de la capa oculta.

$$i_{pj}^h = f_j^h(Neta_{pj}^h) \quad (27)$$

Donde i_{pj}^h es la salida de j -ésima neurona de la capa oculta, f_j^h es la función de activación de la j -ésima unidad oculta h .

Paso 4:

Se calculan los valores netos de entrada para la capa de salida.

$$Neta_{pk}^o = \sum_{j=1}^L w_{kj}^o i_{pj}^o + \theta_k^o \quad (28)$$

Donde $Neta_{pk}^o$ es la entrada neta de la k -ésima neurona de la capa de salida, w_{kj}^o es el peso de interconexión entre la j -ésima neurona de la capa oculta y k -ésima neurona de la capa de salida y θ_k^o es el termino de tendencia de la k -ésima neurona de la capa de salida.

Paso 5:

Se calculan las salidas de la red.

$$y_{pk}^o = f_k^o(Neta_{pk}^o) \quad (29)$$

Donde y_{pk} es la salida de la k-ésima unidad de salida y f_k^o es función de activación de k-ésima unidad de salida.

Paso 6:

Se calculan los términos de error para las unidades de salida.

$$\delta_{pk}^o = (d_{pk} - y_{pk}^o) f_k^o(Neta_{pk}^o) \quad (30)$$

Donde δ_{pk}^o término de error para la k-ésima neurona de la capa de salida, f_k^o es la derivada de la función de activación la k-ésima neurona de la capa de salida, d_{pk} es el valor de salida deseado para la k-ésima neurona de la capa de salida.

Paso 7:

Se estiman los términos de error para las unidades ocultas.

$$\delta_{pj}^h = f_j^h(Neta_{pj}^h) \sum_{k=1}^M \delta_{pk}^o w_{kj}^o \quad (31)$$

Donde δ_{pj}^h es el término de error para la j-ésima neurona de la capa oculta h y f_j^h es la derivada de la función de activación de la j-ésima neurona de la capa oculta.

Paso 8:

Se actualizan los pesos en la capa de salida como se muestra en la Ecuación 32 y en la capa oculta, como se muestra en la Ecuación 33.

$$w_{kj}^o(t+1) = w_{kj}^o(t) + \alpha \delta_{pk}^o i_{pj}^h \quad (32)$$

Donde α es la tasa de velocidad de aprendizaje.

$$w_{ji}^h(t+1) = w_{ji}^h(t) + \alpha \delta_{pj}^h x_{pi} \quad (33)$$

Donde w_{ji}^h es el peso de interconexión entre la i-ésima neurona de la capa oculta y j-ésima neurona de la capa de salida.

Paso 9:

Por último se verifica si el error global cumple con la condición de finalizar.

$$E_p = \frac{1}{2} \sum_{p=1}^P \sum_{k=1}^M (d_{pk} - y_{pk})^2 \quad (34)$$

Donde E_p es el valor del error para el p-ésimo patron de aprendizaje.

5.3.3.2.3.2. Algoritmo de gradiente descendente con eta variable

A continuación se presenta los pasos que se deben llevar a cabo para entrenar un red multicapa con el método de aprendizaje de gradiente descendente con eta variable explicado por Caicedo & Lopez (2009).

Paso 1:

Se define los pesos iniciales de la red de forma aleatoria. **Condición_parar** = Falsa

Paso 2:

Se establece si la **Condición_parar** =Falsa entonces se ejecuta los pasos 3 a 12.

Paso 3:

Se aplica un vector de entrada

$$x_p = [x_{p1}, x_{p2}, \dots, x_{pi}, \dots x_{pn}]^T \quad (35)$$

Paso 4:

Se calcula los valores de las entradas netas para la capa oculta.

$$eta_{pj}^h = \sum_i^N w_{ji}^h + x_{pi} + \theta_j^h \quad (36)$$

Paso 5:

Se calcula la salida de la capa oculta.

$$i_{pj}^h = f_j^h(Neta_{pj}^h) \quad (37)$$

Paso 6:

Se calcula los valores netos de entrada para la capa de salida.

$$Neta_{pk}^o = \sum_{j=1}^L w_{kj}^o i_{pj}^o + \theta_k^o \quad (38)$$

Paso 7:

Se calcula las salidas de la red.

$$y_{pk} = f_k^o(Neta_{pk}^o) \quad (39)$$

Paso 8:

Se calcula el error para las unidades de salida.

$$\delta_{pk}^o = (d_{pk} - y_{pk}^o) f_k^o(Neta_{pk}^o) \quad (40)$$

Paso 9:

Se estima el error para las unidades ocultas.

$$\delta_{pj}^h = f_j^h(Neta_{pj}^h) \sum_{k=1}^M \delta_{pk}^o w_{kj}^o \quad (41)$$

Paso 10:

Se calcula el error.

$$E_p = \frac{1}{2P} \sum_{p=1}^P \sum_{k=1}^M (d_{pk} - y_{pk})^2 \quad (42)$$

Paso 11:

Se hace

$$E_{prev} = E_p \quad (43)$$

Paso 12:

Se establece la condición de $E_{prev} < E_{min}$ entonces se dice que la **Condición_parar** = Verdadera y salir de lo contrario la **Condición_parar** = Falsa

Paso 13:

Se actualiza los pesos en la capa de salida.

$$w_{kj}^o = (t + 1) = w_{kj}^o(t) + \alpha \delta_{pk}^o i_{pj} \quad (44)$$

Paso 14:

Se actualizar los pesos en la capa oculta,

$$w_{ji}^h(t + 1) = w_{ji}^h(t) + \alpha \delta_{pj}^h x_{pi} \quad (45)$$

Paso 15:

Se calcula el error E_p

Paso 16:

Se establece la condición

$$E_p < E_{prev} \quad (46)$$

$$E_{prev} = E_p \quad (47)$$

$$\alpha_{k+1} = \rho \alpha_k \text{ Donde } \rho > 1$$

Entonces se vuelve al paso 3 sino

$$\alpha_{k+1} = \sigma \alpha_k \text{ Donde } 0 < \sigma < 1$$

Entonces se vuelve al paso 13. Donde α es la tasa o velocidad de aprendizaje.

5.3.3.2.3.3. Algoritmo de Levenberg Marquart

A continuación se presenta los pasos que se deben llevar a cabo para entrenar un red multicapa con el método de aprendizaje de Levenberg Marquart explicado por Caicedo & Lopez (2009)

Paso 1:

Se inicializar los parámetros de la red:

- Se definen los valores iniciales de los pesos y el Bias de la red.
- Se define el valor inicial del parámetro de aprendizaje α .
- Se define el error mínimo deseado E_{min} .
- Se define la **Condición_ parar** = falsa y **RESET**= Falso.

Paso 2:

Se define si **RESET**= Falso se ejecutan los pasos del 3 a la 13, sino debe continuar dirigirse al 14.

Paso 3:

Se presentan todos los patrones de entrenamiento a la red

$$x_p = [x_{p1}, x_{p2}, \dots, x_{pi}, \dots x_{pn}]^T \quad (48)$$

Paso 4:

Se calculan los valores de las entradas netas para la capa oculta.

$$Neta_{pj}^h = \sum_i^N w_{ji}^h + x_{pi} + \theta_j^h \quad (49)$$

Paso 5:

Se calcula la salida de la capa oculta.

$$i_{pj}^h = f_j^h(Neta_{pj}^h) \quad (50)$$

Paso 6:

Se calculan los valores netos de entrada para la capa de salida

$$Neta_{pk}^o = \sum_{j=1}^L w_{kj}^o i_{pj}^o + \theta_k^o \quad (51)$$

Paso 7:

Se calcula la salida de la red neuronal.

$$y_{pk} = f_k^o(Neta_{pk}^o) \quad (52)$$

Paso 8:

Se calcula el error global de la red y se almacena en E_{prev} (Error previo).

$$E_{prev} = E = \frac{1}{2} \sum_{p=1}^P \sum_{k=1}^M (d_{pk} - y_{pk})^2 \quad (53)$$

Paso 9:

Se calcula el gradiente total promedio G_{save} (para la capa de salida y la capa oculta).

$$G_{save} = -\nabla E(0) \quad (54)$$

Paso 10:

Se calcula la matriz Hessiana total promedio H_{save} .

$$H_{save} = H \quad (55)$$

Paso 11:

Se tiene en cuenta si $E_{prev} > E_{min}$ (el error previo es mayor al error mínimo deseado), se ejecutan los pasos 12 a 18, si no se hace la **Condición parar** = Verdadera y se sale del algoritmo

Paso 12:

Se inicializa el parámetro λ , como se muestra en la Ecuación 56. Además, se define la diagonal la matriz al extraer solo los valores donde la posición de la fila i es igual a la columna j .

$$\lambda = H_{ijmax} \quad (56)$$

$$i = j$$

Paso 13:

Se inicializa el indicador *RESET* a verdadero y volver a paso 2.

Paso 14:

Si *RESET* = verdadero, se guarda el vector gradiente **G** y la matriz Hessiana **H**

$$\mathbf{H} = \mathbf{H}_{save} , \quad \mathbf{G} = \mathbf{G}_{save}$$

Paso 15:

Se incrementa cada elemento de la diagonal de **H** en λ .

$$\mathbf{H} = \mathbf{H} + \lambda \mathbf{I} \quad (57)$$

Paso 16:

Se resuelve el sistema de ecuaciones para Δ .

$$(\mathbf{H} + \lambda \mathbf{I})\Delta = \mathbf{G} \quad (58)$$

Donde **I** es la matriz identidad.

Paso 17:

Se adiciona Δ al actual vector de pesos para actualización.

$$\mathbf{W}(t + 1) = \mathbf{W}(t) - \Delta \quad (59)$$

Paso 18:

Se calcula el error *E*, el gradiente **G** y la matriz Hessiana **H** con el nuevo vector de pesos.

$$E = \frac{1}{2P} \sum_{p=1}^P \sum_{k=1}^M (d_{pk} - y_{pk})^2 \quad (60)$$

Paso 19:

Se aplica la condición que si $E_{prev} \leq E_{min}$. De lo contrario hacer las siguientes igualaciones y se debe volver al paso 14:

Paso 20:

Se verificar el error. Entonces se aplica la condición que Si $E < E_{prev}$, entonces **Condición _ papar** = Verdadera. De lo contrario se debe hacer las siguientes igualaciones y volver al paso 14:

$$\lambda = \lambda * \rho \text{ Donde } \rho < 1 \quad (61)$$

Paso 21:

Se aplica la condición que si $E > E_{prev}$ se hace los siguientes ajustes y se retorna al paso 14.

RESET = Falso

$$\lambda = \lambda * \sigma \quad (62)$$

$$H_{save} = H \text{ donde } \sigma > 1 \quad (63)$$

$$G_{save} = G \quad (64)$$

5.3.4. Validación

5.3.4.1. Índice de Diferencia de Vegetación Normalizado (NDVI)

El Índice de vegetación normalizado, NDVI se utiliza ampliamente para mejorar la discriminación de cubiertas vegetales, medir el vigor de las plantas y la producción de la biomasa (Gitelson, Peng, & Huemmrich, 2014). Además, caracteriza la evolución de su estado a lo largo del tiempo debido a los cambios en el uso del suelo, estación fenológica, situación hídrica del territorio y ambiente climático de la zona. Este índice es derivado de la combinación de bandas captadas en la zona del rojo y del infrarrojo cercano del espectro y se define a partir de la siguiente ecuación:

$$NDVI = \frac{\rho_{NIR} - \rho_{RED}}{\rho_{NIR} + \rho_{RED}} \quad (65)$$

Donde:

NDVI: Índice de vegetación de diferencia normalizado

NIR: Reflectancia de la Banda infrarrojo cercano.

R: Reflectancia de la Banda roja

Los valores obtenidos del NVDI varían entre -1 y 1 de los cuales los valores positivos corresponden a zonas de vegetación puesto que las plantas absorben fuertemente la radiación en la región visible del espectro mientras que los valores negativos generados por una mayor reflectancia en el infrarrojo cercano, pertenecen a nubes, nieve, agua, zonas de suelo desnudo y rocas (Hmimina et al., 2013).

5.3.4.2. Matriz de confusión

Es una matriz cuadrada, que indica el número de píxeles asignados a una clase respecto a los que se consideran como verdad de campo (François Mas et al., 2003). En esta matriz, las columnas representan generalmente las clases de referencia y las filas el mapa que va a ser evaluado (Tabla 6). La diagonal de la matriz expresa el número de sitios de verificación para los cuales hay

concordancia entre el mapa y los datos de referencia, mientras los marginales indican errores de asignación.

Tabla 6. Matriz de confusión

Referencia	Mapa				Total
	1	2	...	q	
1	p_{11}	p_{12}	...	p_{1q}	p_{1+}
2	p_{21}	p_{22}	...	p_{2q}	p_{2+}
...	...	...	...	...	...
q	p_{q1}	p_{q2}	...	p_{qq}	p_{q+}
Total	p_{+1}	p_{+2}	...	p_{+q}	

Fuente: François Mas et al. (2003)

La Matriz genera tres tipos de error que son: Error global, error de omisión y error de comisión (Li, Wu, & Zhang, 2009).

5.3.4.3. Índices Globales

5.3.4.3.1. Exactitud global

Determina la exactitud del método a evaluar en todas las clases.

$$EG = \left(\frac{\sum_{i=1}^q p_{ii}}{Q} \right) \quad (66)$$

Donde

EG= Exactitud global

p_{ii}= Es la diagonal mayor de la matriz

Q= Total de puntos de muestreo

5.3.4.3.2. Error de Omisión

Corresponde al porcentaje de datos clasificados incorrectamente en otras clases diferente al que pertenecen (Aronoff, 1982). Su complemento se define como la precisión del productor.

$$EO_k = \left(1 - \frac{p_{kk}}{\sum_{i=1}^q p_{ki}} \right) * 100 \quad (67)$$

Donde

EO = Error de omisión

k = Es la posición de la clase

p_{kk} = Total de aciertos en la clase k

$\sum_{i=1}^q p_{ki}$ = Total de datos de la clase k del mapa de referencia

5.3.4.3.3. Error de Comisión

Corresponde al porcentaje de datos clasificados en una clase a la que no pertenecen. Su complemento es la precisión del usuario.

$$EC_k = \left(1 - \frac{p_{kk}}{\sum_{i=1}^q p_{qk}}\right) * 100 \quad (68)$$

Donde

EC = Error de comisión

k = Posición de la clase

p_{kk} = Total de aciertos en la clase k

$\sum_{i=1}^q p_{qk}$ = Total de datos de la clase k del mapa clasificado

Estas medidas se fundamentan exclusivamente en resultados parciales de la matriz, por lo que no hay un aprovechamiento de todos los datos. Con el fin de corregir esto, se realiza la implementación del coeficiente Kappa.

5.3.4.3.4. Índice Kappa

Este coeficiente es un clasificador multinomial (para más de dos categorías), el cual mide el grado de acuerdos entre los observadores, no la “calidad” de la observación, por lo que no considera a uno de los observadores como patrón o modelo, es decir, calcula el porcentaje de valores que son clasificados correctamente entre las observaciones. Éste puede expresarse a partir del siguiente modelo (Cohen, 1960):

$$k = \frac{p_0 - p_e}{1 - p_e} \quad (69)$$

Siendo:

$$p_0 = \frac{N^\circ \text{ de acuerdos}}{N^\circ \text{ de acuerdos} - N^\circ \text{ de desacuerdos}} \quad (70)$$

$$p_e = \sum_{i=1}^n (p_{i1} \cdot p_{i2}) \quad (71)$$

Donde:

n = número de categorías

i = número de la categoría (de 1 hasta n)

p_{i1} = proporción de ocurrencia de la categoría i para el observador 1.

p_{i2} = proporción de ocurrencia de la categoría i para el observador 2.

El coeficiente kappa puede tomar valores entre -1 y +1, su interpretación se realiza correlacionando su valor con una escala cualitativa que incluye seis niveles de concordancia como lo indica la Tabla 7.

Tabla 7. Valoración del coeficiente kappa

Coeficiente kappa	Nivel de Concordancia
< 0,00	Sin concordancia
0,01 - 0,20	Insignificante
0,21 - 0,40	Aceptable
0,41 - 0,60	Moderado

0.61 – 0.80	Bueno
0,81 - 1,00	Muy bueno

Fuente: Landis & Koch (1977)

6. METODOLOGÍA

6.1. ZONA DE ESTUDIO

Colombia se encuentra ubicada al norte de América del Sur, cuenta con una superficie de 1'139,012 km² (Figura 6). Presenta una gran variedad de pisos térmicos, definidos por las tres cordilleras que atraviesan el país de sur a norte.

Una tercera parte de su área está cubierta por bosques húmedos tropicales. Estos forman parte fundamental del ciclo hidrológico debido al proceso de transpiración que estos realizan contribuyendo a la formación de las nubes.

Además, su clima es manejado en gran proporción por la Zona de Convergencia Intertropical (ZCIT), lugar donde los vientos cálidos y húmedos de las latitudes del norte y sur, denominados Alisios, chocan formando un cinturón de nubes que se ubica entre las latitudes de 1°N a 8°N. Esta zona proporciona vientos constantes, los cuales al interactuar con el relieve y definen las temporadas de lluvia y sequía.




Figura 6. Localización de la zona de estudio.

6.1.1. PERIODO DE ESTUDIO

Se determinó como periodo de estudio el año 2010, debido a los eventos extremos de la variabilidad climática interanual (Aristizábal, 2015), con sequías y precipitaciones muy superiores a las observadas históricamente, generando grandes pérdidas económicas, sociales y ambientales, sin precedentes en gran parte del país (BID y CEPAL, 2012).

Esta variabilidad climática se debe principalmente a la componente atmosférica de El Niño Oscilación del Sur (ENOS) conocido como los fenómenos del Niño y La Niña, (J. E. Montealegre, 1996). Estos dos hacen referencia a la aparición, de aguas superficiales relativamente más cálidas (El Niño) o más frías (La Niña) ocasionando debilitamientos en los vientos Alisios del norte (Montealegre, 2007). La presencia de El Niño hace que los vientos Alisios se debiliten de tal forma que las nubes generadas por la evaporación en el océano pacífico no puedan cruzar la barrera orográfica generada por la cordillera occidental, causando sequías en el centro del país; caso contrario ocurre con La Niña donde los vientos toman suficiente fuerza para sobrepasar la barrera orográfica generando lluvias en la mayor parte del país.

De acuerdo con el Centro de Predicciones Climáticas (CPC) para el año 2010 se presentaron estos dos fenómenos, siendo El Niño de Enero hasta Abril y La Niña de Julio a Diciembre, razón por la cual se estableció el período de estudio.

6.2. MATERIALES

6.2.1. MOD09A1

Para el desarrollo de esta metodología se hará uso del producto MOD09A1 del sensor MODIS, el cual proporciona una estimación de la reflectancia espectral de la superficie en 7 bandas con una resolución de 500 metros cada 8 días en una proyección sinusoidal. A continuación se muestran las características del producto (Tabla 8) y sus capas (Tabla 9).

Tabla 8. Características del Producto MOD09A1

Características	
Cobertura temporal	Febrero 24, 2000
Área	~10x10 lat/long
Tamaño del archivo	~64 MB
Proyección	Sinusoidal
Formato del archivo	HDF-EOS
Dimensiones	2400 x 2400 filas/columnas
Resolución	500 metros
Numero de capas	13

Fuente: LP DAAC (2014)

Tabla 9. Capas del Producto MOD09A1 (500 m)

Capas	Unidades
Banda 1 (620–670 nm)	Reflectancia
Banda 2 (841–876 nm)	Reflectancia
Banda 3 (459–479 nm)	Reflectancia
Banda 4 (545–565 nm)	Reflectancia
Banda 5 (1230–1250 nm)	Reflectancia
Banda 6 (1628–1652 nm)	Reflectancia
Banda 7 (2105–2155 nm)	Reflectancia
Calidad de las bandas de Reflectancia 500m	Campo Bit
Ángulo Cenital del sol	Grados
Ángulo Cenital de Visión	Grados
Ángulo Azimutal Relativo	Grados
State Flags 500m	Campo Bit
Día del año	Día Juliano

Fuente: LP DAAC (2014)

El motivo de la selección de este producto se fundamenta en que la resolución temporal que ofrece el producto permite realizar análisis del comportamiento de los fenómenos con intervalos mucho más cortos que los sensores con resoluciones espaciales mayores.

6.2.1.1. *State Flag* MOD09A1

El *State Flag* o bandera de estado es un grupo de datos que viene incluido en el producto MOD09A1. Este contempla información para cada pixel con respecto a las condiciones de nubosidad, presencia de sombras, tipo de cobertura (suelo y agua), cantidad de aerosoles, presencia de cirros, y algoritmos y correcciones aplicadas.

Este producto se encuentra codificado en combinaciones de 16 bits con una resolución espacial de 500 metros. La Tabla 10 muestra la codificación en el *State Flag* del producto de Reflectancia MOD09A1.

Tabla 10. Descripción del estado de datos QA MOD09A1

Bit No.	Nombre del parámetro	Comb. Bit	Sur_refl_state_500m
15	Algoritmo de nube interno	1	Si
		0	No
14	Corrección de BRDF desarrollado	1	Si
		0	No
13	El pixel es adyacente a una nube	1	Si
		0	No
12	MOD35 Nube/Hielo	1	Si
		0	No
11	Algoritmo de fuego interno	1	Fuego
		0	Sin fuego

Bit No.	Nombre del parámetro	Comb. Bit	Sur_refl_state_500m
10	Algoritmo de nube interna	1	Nube
		0	Sin nube
8–9	Detección de cirros	00	Ninguno
		01	Pequeño
		10	Promedio
		11	Alto
6–7	Cantidad de aerosoles	00	Climatología
		01	Baja
		10	Promedio
		11	Alto
3–5	Agua/Suelo	000	Océano superficial
		001	Suelo
		010	Costas de océano y de dalo
		011	Aguas continentales superficiales
		100	Aguas efímeras
		101	Aguas continentales profundas
		110	continental/océano moderado
		111	Océano profundo
2	Sombra de nube	1	Si
		0	No
0–1	Nube MOD35	00	Limpio
		01	Nuboso
		10	Mezclado
		11	Sin grupo, asumido como limpio

Fuente: LP DAAC (2014)

Para generar la máscara de nubes de la imagen se utilizan solo los dos primeros bits (0-1) que contemplan los resultados establecidos por el producto MOD35, que es el producto que implementa el algoritmo de enmascaramiento de nubes propuesto por Ackerman (2010). Dicha codificación se establece para cuatro clases que son Limpio, Nuboso, Mezclado y Sin grupo (que se asume como limpio), las cuales se definirán como 1, 2, 3 y 4 respectivamente. Para este estudio se realizará una combinación de las clases de tal forma que se obtengan solo dos, que son Nuboso o Limpio, en donde Nuboso corresponde a los pixeles clasificados como nubosos o mezclados y el Limpio como Limpio o Sin grupo.

6.2.2. Información cartográfica de la zona de estudio

La cartografía base empleada es de tipo vectorial, disponible en formato shape correspondiente a la zona de estudio que permitirá el recorte de las imágenes para su posterior procesamiento, obtenido mediante los servicios Web que dispone el

Instituto Geográfico Agustín Codazzi (IGAC), siendo el ente encargado de generar la cartografía a nivel nacional.

Además se utilizó cartografía auxiliar también de tipo vectorial de los departamentos, municipios, drenajes, embalses, lagunas y volcanes del país, los cuales facilitaron el proceso de toma de muestras sobre la imagen para las clases establecidas para el presente estudio. Ésta información se encuentra asociada al sistema de coordenadas WGS84 a escala de 1:100,000 disponible en la página virtual del Sistema de Información Geográfica para el Ordenamiento Territorial (SIGOT).

6.3. PROCEDIMIENTO

A continuación se presenta en la Figura 7, el esquema metodológico general para el desarrollo de este estudio, que se compone de 5 fases. La primera corresponde al pre-procesamiento de los datos, la segunda fase es la selección de variables de entrada, la tercera y cuarta corresponden a los métodos de detección de nubes mediante series de tiempo y redes neuronales artificiales respectivamente, y por último una validación de las dos fases anteriores.




Figura 7. Diagrama del proceso metodológico General

6.3.1. Pre-procesamiento de los datos

El territorio colombiano se compone por seis imágenes (Tiles) del producto MOD09A1 en formato *Hierarchical Data Format* (HDF), por tanto es necesario realizar la conversión de formato a GEO-TIFF y un mosaico que permita la unión de estas imágenes, para una sola fecha. Posteriormente, se realiza la reproyección de las imágenes al sistema de referencia UTM Zona 18 con su elipsoide asociado WGS 84. Estas actividades fueron realizadas mediante la herramienta *MODIS Reproyección Tool* (MRTTools), dispuesta por el *Land Processes Distributed Active Archive Center* LPDAAC en su página web¹.

Para delimitar la zona de estudio, se utilizó una cartografía digital de Colombia en formato *shape*, permitiendo definir la zona de interés, excluyendo las islas de San Andrés y Providencia puesto que su distancia respecto al resto del territorio genera gran cantidad de valores nulos que aumenta el tiempo de procesamiento. Después de esto, se hizo un escalamiento de los valores enteros a valores de reflectancia para cada imagen, este factor se obtiene a partir de la descripción del producto MOD09A1 y se realiza la compilación de las siete bandas de Reflectancia en un solo archivo TIFF.

El proceso anteriormente mencionado se implementó para las imágenes *State Flag* del producto MOD09A1 que acompañan a las imágenes de Reflectancia (excepto el escalamiento y compilación).

6.3.2. Selección de variables de entrada

La definición de las variables de entrada desempeña un papel fundamental en el desarrollo de cualquier proceso, puesto que a partir de ellas es posible determinar las variables de mayor significancia en el fenómeno a estudiar y además, omitir información que pueda generar distorsión en los resultados obtenidos. En este caso se implementa el Análisis de Componentes Principales (ACP) para identificar las variables de mayor influencia sobre las nubes mediante la interpretación de sus resultados, los cuales deben ser consistentes en cada una de las imágenes empleadas para el desarrollo de este proceso.

El primer análisis corresponde a interpretar las matrices de correlaciones (ver Ecuaciones 1-7) y el test de Kaiser-Meyer-Olkin (KMO) (Ecuación 8), los cuales determinan el nivel de correlación entre las variables originales e indican si es necesario aplicar ACP. Posteriormente, se realiza la determinación del número de factores, el cual, debe ser menor al total de variables iniciales y su varianza acumulada debe reflejar un alto porcentaje de los datos originales. Por último, se realiza el análisis de la matriz factorial, cuyo fin es identificar la correlación de cada una de las variables con respecto a cada componente y así, determinar las variables (bandas espectrales) que explican más el fenómeno de estudio.

Al realizar el procedimiento antes mencionado, se obtuvo que las bandas que tienen mayor incidencia en las coberturas nubosas corresponden a las bandas 1,3 y 4 del espectro visible y la banda 7 que es un infrarrojo medio de onda corta. La

¹ Página Web: https://lpdaac.usgs.gov/tools/modis_reprojection_tool

primer componente tiene mayor correlación con las bandas del espectro visible (rojo, azul y verde respectivamente), que en la mayoría de los casos explicaba más del 72% de la varianza total. En cuanto a la segunda componente, se presentó una mayor correlación con la banda 7, cuyo porcentaje de variabilidad explica cerca del 14% de la variabilidad total.

Con base a los resultados obtenidos se definió que las bandas a implementar en los algoritmos para la detección de nubes son la banda 3 y la 7 (azul e infrarrojo lejano), determinadas a partir de los resultados estadísticos y las características físicas de sus longitudes de onda.

6.3.3. Algoritmo de detección de nubes basado en la inflexión de series temporales

El uso de información temporal permite mejorar la detección de cambios abruptos en la superficie, ya que, si se observa los cambios en el tiempo de un lugar en específico se puede estimar si corresponde o no a sus condiciones normales. En este caso se pretende aplicar el algoritmo de detección de nubes basado en la inflexión (IBCD, por sus siglas en inglés) propuesto por (Liu & Liu, 2013). A continuación se presenta la metodología (Figura 8) para la detección de nubes implementado información temporal.




Figura 8: Diagrama del proceso metodológico de series temporales basados en la inflexión

El algoritmo a implementar se basa en asumir que hay un punto de inflexión que separa las observaciones libres de nubes de las observaciones con nubosidad al realizar un ordenamiento de los datos contemplados en una serie de tiempo. Dicha serie se construye para cada pixel de la zona de estudio para el año 2010.

6.3.3.1. Extracción de información temporal por pixel

La implementación del algoritmo empieza por la extracción de los datos presentes en todas las imágenes en una fila y columna específica en todo el espectro temporal disponible. Se debe garantizar que las imágenes tengan igual proporcionalidad (igual tamaño) y que sus sistemas de referencia sean iguales, permitiendo que se extraiga la información de dicho pixel en cada imagen, tal como se muestra en la Figura 9.




Figura 9: Esquema de la extracción de la información temporal por pixel

La serie temporal consiste en un vector X de tamaño t , donde t es el número de imágenes de la zona de estudio en diferentes fechas. La Figura 10 muestra el ejemplo de una serie temporal generada en la ciudad de Santiago de Cali para la Reflectancia en la Banda 3 durante el periodo de estudio establecido.




Figura 10. Serie temporal del porcentaje de reflectancia en la banda 3 en las coordenadas 3°26'42"N -76°30'46"W

6.3.3.2. Ordenamiento secuencial de datos de la serie temporal

Al contar con la serie temporal de ese pixel, se procede a realizar un ordenamiento de los datos del vector, de tal forma en que los valores más bajos se encuentren en las primeras posiciones y los más altos en las últimas. El valor que se encuentra en la primera posición será considerado por el algoritmo como libre de nube y el de la última posición como un valor con presencia de nube.




Figura 11: Serie temporal ordenada

En la Figura 11 se observa como fue ordenada la serie temporal correspondiente a la Figura 9. Se puede apreciar que en los primeros datos la pendiente no es muy pronunciada pero al momento de llegar a los valores con nubes dicha pendiente crece abruptamente.

6.3.3.3. Cálculo del punto de inflexión

Para establecer el punto de inflexión en la serie ordenada se debe definir una recta que empiece desde el punto inicial del vector hasta su punto final (Figura 12). Posterior a esto, se debe establecer la distancia perpendicular desde la recta a cada uno de las posiciones del vector (ver Ecuación 16). La posición con mayor distancia será considerada como el punto de inflexión.




Figura 12: Cálculo de cada punto de la serie temporal a la recta

Al identificar el punto de inflexión en ese pixel, se salva esa información en una imagen de referencia. Esta imagen funcionará como criterio de decisión para determinar si hay presencia de nubes o no.

6.3.3.4. Determinación del ángulo del punto de inflexión

Otro criterio de decisión para identificar la presencia de nubes en el pixel será el ángulo que se forma entre el valor de la primera posición del vector (valor asumido como libre de nube), el valor del punto de inflexión y el valor de la última posición (valor asumido como un pixel con presencia de nube), (Figura 13). Sin embargo, antes de calcular el ángulo se debe hacer un escalamiento a los valores del vector ordenado ya que los ejes en X son números enteros de 1 a t correspondientes al número de imágenes para el estudio, mientras que en el eje Y los valores son decimales de 0 a máximo 1.

Para el escalamiento se debe identificar un factor, el cual consiste en establecer la diferencia entre el valor máximo y mínimo del vector ordenado y multiplicarlo por su tamaño, es decir, el número de imágenes que compone la serie temporal (ver Ecuación 18).

Cuando ya se haya realizado el escalamiento del vector ordenado, se procede a implementar la ecuación del ángulo entre tres puntos (Ecuación 17). Esta información se almacenará en otra imagen para hacer parte del criterio de decisión.




Figura 13: Ángulo entre el punto libre de nube, el punto de inflexión y punto con presencia de nube.

6.3.3.5. Generación de imagen de referencia

Como se mencionó anteriormente, se realizó el proceso con las bandas 3 y la fracción banda 3/ banda 7. Con lo que se obtiene por cada banda de entrada, dos imágenes, la primera de ellas correspondiente a los valores de reflectancia a partir del punto de inflexión y la otra con el valor de un ángulo que permitirá establecer la eficiencia del valor de referencia.

6.3.3.6. Umbrales de clasificación

Se establecen seis categorías, cada una definida por un condicional como se muestra en la Tabla 11.

Tabla 11: Umbrales de clasificación para método IBCM

Condicional	Categoría	Reclasificación
Si el ángulo de referencia α de B3 > 150°	Incierto	Libre de nube = 0
Si B3 > B3 de referencia	Nube	Presencia de nube = 1
Si B3 < B3 de referencia & el ángulo α de R37 > 150	Cuerpo de agua libre de nubes	Libre de nube = 0
Si B3 < B3 de referencia & el R37 < R37 de referencia	Libre de nube	Libre de nube = 0
Si B3 < B3 de referencia & el R37 > R37 de referencia	Nubes delgadas	Presencia de nube = 1

Fuente: Liu and Liu (2013)

A partir de las categorías propuestas por el autor se realiza una reclasificación con el fin de obtener una variable de respuesta dicotómica, es decir, se considera solo dos categorías. La primera corresponde a nubes y nubes delgadas con valor de uno y la segunda será el resto de categorías con valores de cero.

Finalmente, con el proceso descrito se obtiene la máscara de nubes implementando el algoritmo IBCD.

6.3.4. Algoritmo de detección de nubes usando la Redes Neuronal Artificiales MLP (Perceptron Multicapa)

La red perceptron multicapa (MLP) se caracteriza por su capacidad de procesamiento porque cuenta con capas de diferentes niveles (entrada, oculta y de salida). Cada una de ellas formada por un conjunto de neuronas.

Las neuronas de la capa de entrada se encargan únicamente de recibir las señales o patrones del exterior y propagar dichas señales a todas las neuronas de la siguiente capa. La capa de salida de la red, proporciona al exterior la respuesta de la red para cada uno de los patrones de entrada, mientras que las neuronas de las capa oculta realizan un procesamiento no lineal de los patrones recibidos (Caicedo & Lopez, 2009). La conectividad del MLP, siempre está dirigida hacia adelante, es decir, las neuronas de una capa están conectadas a todas las neuronas de la siguiente capa, razón por la cual reciben también, el nombre de redes alimentadas o redes *feedforward*, como se observa en la Figura 14.




Figura 14: Estructura de una red multicapa MLP.

Fuente: Taravat et al (2015)

Su potencial reside en su habilidad para entrenar capas ocultas y de este modo superar las posibilidades restringidas de las redes de una única capa. Han demostrado la capacidad de trabajar con éxito en un amplio rango de aplicaciones incluyendo clasificación de imágenes, sistemas de base de conocimiento, codificación de información y muchos otros problemas de clasificación y problemas de percepción (Olabe, 1998). Partiendo de las propiedades y ventajas que ofrece este tipo de red, se desarrolla a continuación la metodología para su aplicación de acuerdo a los requerimientos del proyecto (Figura 15).




Figura 15. Diagrama del proceso metodológico de Redes Neuronales

6.3.4.1. Extracción de características

La extracción de características tiene como fin extraer nueva información que describa de una mejor manera el comportamiento de los datos. Para esto, se implementa dos filtros de realce de imágenes (filtro media aritmética y filtro Sobel).

El filtro de media aritmética (ver Ecuación 13) se emplea como parte del pre-procesamiento de los datos de entrada para el entrenamiento de la red. Esto con el fin de que se obtenga información correspondiente no solo al pixel sino también a sus alrededores, es decir, si un pixel se encuentra rodeado de nubes, es muy probable que este también lo sea, y es ahí donde la red neuronal podrá identificar de manera mucha más eficiente estos casos. Así mismo, el filtro Sobel (ver Ecuaciones 14 y 15) es aplicado con el fin de mejorar la identificación de los bordes de las coberturas presentes en la imagen, brindando también características de los pixeles vecinos que puedan ser relevantes para la clasificación de las nubes.

Estos dos filtros son aplicados sobre las bandas 3 y 7 del producto MOD09A1, tal y como fueron definidas en la sección 6.3.2.

6.3.4.2. Conjunto de aprendizaje de la red

El conjunto de aprendizaje son los datos que, con certeza, corresponden al fenómeno que se desee identificar. En este sentido, se realiza un muestreo de

3000 puntos sobre coberturas con presencia y ausencia de nubes, con el cual se entrena la RNA. Este conjunto corresponde a los valores de los pixeles presentes en las bandas 3 y 7. También se utilizaron los resultados de la aplicación de los filtros de media aritmética y Sobel sobre estas bandas como parte de los datos para un total de seis posibles conjuntos de aprendizaje.

Las muestras fueron obtenidas considerando dos parámetros, que corresponden a tener una igual cantidad por clase para evitar tendencias en la clasificación y que correspondieran a diferentes fechas. Las columnas representa los valores de muestra y las filas son las clases definidas, en este caso Nube y Libre de Nube.

Estos datos de entrenamiento serán separados de forma aleatoria en dos grupos, el primero corresponde a los datos de entrenamiento que equivalen al 70% del total y el segundo grupo restante pertenece a los datos utilizados para el proceso de validación. Mediante estos dos grupos se obtendrán el Error Medio Cuadrático (EMC) (ver Ecuación 42) de entrenamiento y EMC de validación, con los cuales se podrá inferir la capacidad de generalización de aprendizaje de la red y si existen problemas de sobre-entrenamiento.

6.3.4.3. Configuración de la red

Luego de obtener las muestras de entrenamiento, se define los parámetros de la red de perceptron multicapa, entre ellos se encuentra número de capas, número de neuronas por capa, la función de activación y el algoritmo de aprendizaje.

Número de capas

Para una red MLP, es recomendado utilizar tres capas, es decir, una capa de entrada, una capa de salida y una capa oculta (Caicedo & Lopez, 2009). El utilizar más de una capa oculta aumenta drásticamente la carga computacional de la red, sobre todo en los algoritmos de entrenamiento de segundo orden, razón por la cual se plantea una configuración de tres capas.

Funciones de activación

De acuerdo con Caicedo & Lopez (2009), en una red MLP, la función de activación a utilizar en las capas ocultas es de tipo sigmoideal (ver Ecuación 22), pues garantiza la capacidad de procesamiento no lineal y para la capa de salida es recomendable utilizar una función de activación tipo lineal (ver Ecuación 20) con el fin de no saturar la salida de la red. Es por esto que se definieron estas dos funciones de activación para su configuración.

En una red MLP, la función de activación a utilizar en las capas ocultas es de tipo sigmoideal (ver Ecuación 22), pues garantiza la capacidad de procesamiento no lineal y para la capa de salida es recomendable utilizar una función de activación tipo lineal (ver Ecuación 20) con el fin de no saturar la salida de la red. Es por esto que se definieron estas dos funciones de activación para su configuración.

Numero de neuronas en cada capa

Tal y como se mencionó en el apartado 6.3.4.2, son seis los patrones de entrenamiento, por tanto se pueden definir un máximo de seis neuronas en la capa de entrada, puesto que se desconoce si con un valor menor o igual a este se puedan obtener mejores resultados. Para identificar el número de neuronas adecuado se realiza el entrenamiento de varias redes neuronales, definiendo tres configuraciones diferentes (Tabla 12). Donde B3 y B7 hace referencia a la banda 3 y banda 7 del producto MOD09A1, los prefijos FM y FS corresponden a los filtros de Media y Sobel aplicados sobre estas dos bandas.

Tabla 12: Configuraciones para la capa de entrada

Configuración	Numero de neuronas en la capa de Entrada	B3	B7	FMB3	FMB7	FSB3	FSB7
1	2	X	X				
2	4	X	X	X	X		
3	6	X	X	X	X	X	X

En el caso del número de neuronas para la capa oculta, se evaluó su funcionamiento con la mitad de la dimensión del vector de entrada y se fue aumentando este número paulatinamente, verificando si su desempeño mejora utilizando el EMC como indicador. En el momento en el que aunque se incremente el número de neuronas en la capa oculta y los errores no decrecen sustancialmente, se define el número de neuronas que conformarán esta capa.

Para la capa de salida se definen dos neuronas, la primera se especializa en la detección de nubes mientras que la otra se encarga de la clasificación de cualquier otro elemento, es decir, se hace un proceso de exclusión donde si el pixel no satisface las condiciones de la neurona especializada, entonces pasa a ser una observación limpia.

Algoritmos de aprendizaje

Para determinar el algoritmo de aprendizaje se evaluó el rendimiento de los algoritmos *Backpropagation* (ver Ecuaciones 25-34), Gradiente descendente con eta variable (ver Ecuaciones 35-47) y Levenberg-Marquardt (ver Ecuaciones 48-64). El criterio de decisión se fundamenta en la velocidad de convergencia de cada uno de ellos durante el proceso de aprendizaje. La Figura 16, muestra el comportamiento del EMC de validación con respecto al número de iteraciones.




Figura 16: Rendimiento de los algoritmos de aprendizajes de la red respecto a número de iteraciones y el RMC

6.3.4.4. Generación de máscara de nubes

Finalmente se realiza la simulación con cada variable utilizando la red obtenida. Estas variables al estar estructuradas de forma matricial deben ser organizadas en forma de vector para poder realizar la simulación. El resultado de esta simulación es una matriz de 2 columnas por el total de píxeles que componen la imagen con valores de ceros y unos donde el valor cero representa no nube y el valor de uno indica la presencia de nubes. Posterior a esto se reorganizan los datos para recuperar la forma de matriz y una reclasificación de los valores, en la cual, los valores de nube se establecen como uno y el resto de clases se define como cero, obteniendo de esta manera la máscara de nubes.

6.3.5. Validación

La validación de máscaras de nubes es un proceso complejo debido principalmente a la falta de máscaras de nubes confiables para comparar (Zhu & Woodcock, 2012). Debido a esto, la evaluación de la calidad de un producto de máscara de nubes debe considerarse como una comparación de productos en lugar de una validación.

En este estudio, el proceso de validación consiste en la implementación de diversos mecanismos de comparación entre los productos de máscaras de nubes de RNA, IBCM y el suministrado por el producto MOD09A1. Estos corresponden a comparaciones visuales, determinación de porcentaje de nubosidad detectado, e índices de error y concordancia (ver Ecuaciones 66-71). Además, se evaluará la precisión de la detección de nubes en ambos métodos al extraer dos conjuntos de muestras (píxeles) correspondientes a valores con y sin nubosidad, para determinar el error global y otros indicadores. Así mismo, se aplicará el método de

evaluación de incertidumbre de la detección de nubes propuesta por Liu & Liu (2013)

7. RESULTADOS

7.1. Selección de variables - Análisis de Componentes Principales

En esta sección se abordarán los resultados obtenidos del ACP. Para su aplicación se utilizaron 6 de las 46 imágenes, seleccionadas de forma aleatoria, de las cuales se extrajo cerca de 5000 muestras de valores de reflectancia correspondientes a nubes en las siete bandas espectrales para cada imagen. Para cada conjunto de muestras se realizó el ACP con el objeto de identificar si los resultados son consistentes para cada imagen.

7.1.1. Matrices de correlación

La Tabla 13 muestra las matrices de correlación entre las bandas espectrales del muestreo realizado para cada imagen. Se observa que para todas las fechas, las correlaciones son altas en la banda 1 hasta la 6, con valores entre el 0.64 y 0.99. La única banda que presenta correlaciones bajas corresponde a la banda 7, con correlaciones entre 0.04 y 0.26, indicando poca dependencia de las otras bandas.

Tabla 13: Matrices de correlación entre las bandas espectrales del muestreo realizado para cada imagen

Fecha		B1	B2	B3	B4	B5	B6	B7	Fecha		B1	B2	B3	B4	B5	B6	B7
1	B1	1.000	.848	.988	.998	.869	.880	.223	49	B1	1.000	.832	.986	.998	.837	.838	.086
	B2	.848	1.000	.809	.858	.823	.921	.291		B2	.832	1.000	.791	.843	.751	.857	.126
	B3	.988	.809	1.000	.991	.828	.836	.201		B3	.986	.791	1.000	.990	.793	.782	.077
	B4	.998	.858	.991	1.000	.862	.879	.224		B4	.998	.843	.990	1.000	.822	.829	.086
	B5	.869	.823	.828	.862	1.000	.959	.239		B5	.837	.751	.793	.822	1.000	.951	.096
	B6	.880	.921	.836	.879	.959	1.000	.265		B6	.838	.857	.782	.829	.951	1.000	.114
	B7	.223	.291	.201	.224	.239	.265	1.000		B7	.086	.126	.077	.086	.096	.114	1.000
177	B1	1.000	.845	.991	.999	.682	.752	.095	193	B1	1.000	.844	.988	.998	.776	.804	.108
	B2	.845	1.000	.809	.855	.676	.816	.140		B2	.844	1.000	.803	.855	.732	.844	.146
	B3	.991	.809	1.000	.992	.646	.706	.080		B3	.988	.803	1.000	.991	.736	.753	.098
	B4	.999	.855	.992	1.000	.675	.749	.096		B4	.998	.855	.991	1.000	.766	.799	.109
	B5	.682	.676	.646	.675	1.000	.943	.120		B5	.776	.732	.736	.766	1.000	.949	.115
	B6	.752	.816	.706	.749	.943	1.000	.140		B6	.804	.844	.753	.799	.949	1.000	.139
	B7	.095	.140	.080	.096	.120	.140	1.000		B7	.108	.146	.098	.109	.115	.139	1.000
265	B1	1.000	.848	.991	.999	.698	.752	.072	353	B1	1.000	.852	.992	.999	.689	.756	.051
	B2	.848	1.000	.812	.858	.697	.826	.119		B2	.852	1.000	.818	.862	.690	.827	.103
	B3	.991	.812	1.000	.992	.661	.705	.065		B3	.992	.818	1.000	.993	.653	.713	.042
	B4	.999	.858	.992	1.000	.690	.749	.074		B4	.999	.862	.993	1.000	.682	.754	.052
	B5	.698	.697	.661	.690	1.000	.944	.117		B5	.689	.690	.653	.682	1.000	.944	.128
	B6	.752	.826	.705	.749	.944	1.000	.124		B6	.756	.827	.713	.754	.944	1.000	.139
	B7	.072	.119	.065	.074	.117	.124	1.000		B7	.051	.103	.042	.052	.128	.139	1.000

Para las bandas del espectro visible (Banda 1, 3 y 4) se tienen correlaciones muy altas, con coeficientes de correlación superiores a 0.98 con lo que se evidencia que en este espectro, la dispersión de la luz incidente es igual para estas longitudes de onda. En el caso de los infrarrojos de onda corta de las bandas 2, 5 y 6, las correlaciones no son tan altas (coeficientes entre 0.65 y 0.85), pero si se observa una alta correlación entre la 5 y la 6 con valores superiores 0.944. Y por último, para la banda 7 a pesar de que las correlaciones son bajas, se observa que hay mayor similitud con las bandas infrarrojas que con las del espectro visible.

7.1.2. Test de KMO

En la Tabla 14 se observa los resultados del test KMO, cuyos valores para el conjunto de muestras se encuentran entre 0.734 y 0.764. Esto indica que hay una correlación notable entre las variables y que este comportamiento es consistente independientemente del muestreo realizado en cada imagen.

Tabla 14: Resultado del test KMO del muestreo realizado en cada imagen

Fecha	Test KMO
1	0.764
49	0.742
177	0.737
193	0.739
265	0.734
353	0.739

7.1.3. Determinación del número de factores

Para el análisis de los componentes principales se estableció un número de componentes igual al número de variables (bandas espectrales), con el fin de identificar el porcentaje de varianza por cada componente. La Tabla 15 muestra el porcentaje de varianza acumulada para las muestras obtenidas en cada imagen. Para todas las imágenes, las primeras dos componentes acumulan un mínimo del 86% de la varianza total de los datos. El primer componente acumula varianzas entre el 72% y 78%, seguido de la segunda componente cuyo aporte está entre el 14% y el 16%, mientras que las componentes restantes explican menos del 8% de la varianza de los datos.

Tabla 15: Porcentaje de varianza acumulada para las muestras obtenidas en cada imagen

Fecha	Porcentaje de Varianza Acumulada [%]						
	Comp 1	Comp 2	Comp 3	Comp 4	Comp 5	Comp 6	Comp 7
1	78.983	92.329	97.089	99.638	99.87	99.99	100
49	75.973	90.123	95.934	99.488	99.851	99.99	100
177	72.492	86.673	96.2	99.478	99.89	99.992	100
193	74.843	88.898	96.143	99.468	99.863	99.99	100
265	72.806	87.089	96.304	99.474	99.895	99.993	100
353	72.79	87.344	96.396	99.509	99.903	99.992	100

Para la identificación del número de componentes a tener en cuenta, se utiliza la Figura 17 que representa un gráfico de sedimentación de los autovalores. Por regla general se tiene que aquellos componentes con autovalores superiores a 1, deben ser considerados como los componentes que explican en mayor proporción el total de los datos. Se observa que el primer componente presente autovalores mayores a 5, lo cual es consistente con el porcentaje de varianza acumulada. Así mismo, la componente dos muestra valores muy cercanos a 1, por lo que también debe ser considerada. Las demás componentes presentan valores menores a 0.6, indicando que no son lo suficientemente significativas.




Figura 17: Gráfico de sedimentación de los autovalores

De acuerdo a los resultados anteriores, se define los dos primeros componentes, como los de mayor relevancia, por lo que será empleados para posteriores análisis.

7.1.4. Matriz de factores

A partir de los componentes identificados anteriormente, se realiza la matriz de factores o componentes (Tabla 16), en ella se observa la correlación entre cada una de las bandas espectrales con cada componente. Para las bandas B1 hasta la B6, se presentan correlaciones superiores a 0.83 para el primer componente, mientras que para la banda 7 los valores son inferiores a 0.3. En cambio, la segunda componente presenta correlaciones superiores a 0.95 para a banda 7 y para las otras bandas el valor de la correlación es bajo o en algunos casos negativo.

Tabla 16: Matriz de factores

Matriz de factores o componentes												
Fecha	1		49		177		193		265		353	
Bandas	CP1	CP2	CP1	CP2	CP1	CP2	CP1	CP2	CP1	CP2	CP1	CP2
B1	.975	-.089	.974	-.047	.961	-.086	.969	-.057	.961	-.088	.961	-.112
B2	.920	.035	.899	.026	.910	.009	.908	.013	.914	.008	.916	.000
B3	.951	-.112	.949	-.057	.939	-.106	.944	-.067	.939	-.101	.940	-.131
B4	.975	-.088	.973	-.047	.961	-.086	.968	-.056	.962	-.087	.962	-.113
B5	.932	-.036	.912	-.013	.832	.062	.883	-.008	.843	.079	.837	.140
B6	.957	-.007	.930	.009	.897	.064	.918	.014	.896	.073	.900	.126
B7	.303	.950	.127	.991	.150	.979	.157	.986	.127	.981	.114	.970

Para reafirmar los resultados obtenidos con la matriz de factores, se aplica el método de rotación de factores VARIMAX propuesto por Kaiser (1958). Esta rotación permite hacer una mayor distinción entre las correlaciones de las variables con cada uno de los componentes. La Tabla 17 ilustra los resultados de la matriz de factores rotada. Se puede apreciar que para las bandas 1,3 y 4 las correlaciones aumentan en pequeñas proporciones y para las bandas 2,5 y 6 disminuye. Esto indica que el primer componente se encuentra mayormente explicado por las bandas 1, 3 y 4 pertenecientes al espectro visible. Respecto a la segunda componente, tanto en la matriz de factores rotada (Tabla 17), como en la matriz sin rotación (Tabla 16) se evidencia que la banda 7 es la que más explica esta componente.

Tabla 17: Matriz de componentes rotados con el método VARIMAX

Rotación VARIMAX												
Fecha	1		49		177		193		265		353	
Bandas	CP1	CP2	CP1	CP2	CP1	CP2	CP1	CP2	CP1	CP2	CP1	CP2
B1	.975	.090	.975	.026	.965	.002	.970	.034	.965	-.014	.967	-.041
B2	.899	.202	.894	.093	.906	.091	.903	.098	.911	.079	.913	.068
B3	.956	.063	.950	.015	.944	-.020	.946	.021	.944	-.029	.947	-.061
B4	.975	.091	.974	.026	.965	.002	.969	.035	.966	-.013	.967	-.041
B5	.923	.134	.911	.055	.823	.137	.880	.075	.834	.144	.824	.201
B6	.942	.167	.927	.079	.887	.145	.913	.099	.888	.141	.888	.193
B7	.125	.990	.052	.998	.061	.989	.064	.997	.051	.988	.041	.976

Teniendo en cuenta la interpretación de estos componentes, se tiene que las bandas que más identifican las nubes son las bandas del espectro visible (B1, B3 y B4) y la banda 7. Cabe resaltar que las bandas 1,3 y 4 presentan un coeficiente de correlación superior al 0.95, por lo que estadísticamente son iguales. En este sentido, se escogió la banda 3 porque su longitud de onda central (459-479 nm) es mucho menor respecto a las bandas 1 (620-670 nm) y 4(545-565 nm), haciendo que sea más sensible a las partículas más pequeñas que se encuentran en la atmosfera. Así mismo, (Liu & Liu, 2013) establecen que la banda 3 muestra

mayores diferencias entre superficies con nubes y aquellas que no las tienen. Por su parte, la banda 7 es la que presenta una correlación muy baja con respecto a las demás, esto hace que sea una variable independiente por lo que aporta información que no se encuentra en las otras bandas.

7.2. MÁSCARA DE NUBES USANDO SERIES TEMPORALES BASADO EN LA INFLEXIÓN

A continuación se muestran algunos perfiles temporales en diferentes coberturas que ilustran el punto de inflexión entre las coberturas libres de nubes y aquellas que se encuentran cubiertas por estas. También se muestran los valores de inflexión calculados a cada uno de píxeles de la zona de estudio y el ángulo entre las observaciones con el fin de identificar factibilidad de la aplicación del método.

7.2.1. Evaluación de la suposición del punto de inflexión

Se presentan los perfiles temporales de la B3 y R37 en diferentes lugares con el fin de identificar de que hay un punto de inflexión entre los sectores libres de nubes y aquellas que no. Estos valores fueron extraídos del producto MOD09A1 para el año 2010, los cuales fueron ordenados de menor a mayor. Además, se muestra la distancia de cada uno de los puntos a la recta entre los valores asumidos como cubierto y libre de nube.

Independiente de la cobertura de estudio, se observa un fraccionamiento de los datos en dos grupos para cada perfil. La primera fracción corresponde a los valores más bajos que inician el gráfico, estos valores tienen como característica que presentan un crecimiento gradual de una observación a otra. Por su parte, la segunda fracción presenta un crecimiento mucho más acelerado. Esto muestra que, evidentemente, existe un punto de inflexión entre las coberturas nubosas y las coberturas limpias ya que los cambios al aparecer una nube son mucho más significativos que los cambios con respecto a las variaciones estacionales o incluso a cambios en el tipo de cobertura del suelo.

Teniendo en cuenta la Figura 18, se observa que los valores de B3 para la vegetación densa, correspondiente a un sector del amazonas, se presenta sus máximos entre 0.1 y 0.2 y que para el R37 los valores máximos son de aproximadamente 0.4 (Figura 19). Además, se observa que el punto de inflexión no es muy claro para la serie de B3, pero en la R37 se observa con mayor claridad.




Figura 18: Valores de la banda 3 para el bosque tropical en la zona de coordenadas 2°32'47" S y 69°51'59" W




Figura 19: Valores R37 para el bosque tropical en la zona de coordenadas 2°32'47" S y 69°51'59" W

En el caso de las superficies brillantes como desiertos y zonas urbanas, los valores de B3 son mucho más grandes que en la vegetación sin embargo no se ven alteradas en gran medida por las variaciones estacionales.

Las Figura 20 y 21 muestran el comportamiento de B3 y R37 en punto del desierto de la Guajira. Para B3, se presentan valores máximas de 0.13 sin presencia de nube. En el caso de R37, los valores máximos son de 0.44 aproximadamente.

Para las zonas urbanas, se presentan las Figuras 22 y 23 para ilustrar los comportamientos de B3 y R37 respectivamente, correspondiente a la ciudad de Santafé de Bogotá D.C. En esta cobertura se presentan dificultades para identificar la inflexión en dicho punto a pesar de que se evidencia la existencia de una curva debido a que la variación de los píxeles es de forma gradual y constante. El valor máximo de B3 es de aproximadamente 0.2 y para R37 de 1.0.




Figura 20: Valores de la banda 3 para la cobertura de desierto de coordenadas 12°9'34" N y 71°44'31" W.




Figura 21: Valores R37 para la cobertura de desierto de coordenadas 12°9'34" N y 71°44'31" W




Figura 22: Valores de la banda 3 para la cobertura de zona urbana de coordenadas 4°36'15" N y 74°07'19" W




Figura 23: Valores R37 para la cobertura de zona urbana de coordenadas 4°36'15" N y 74°07'19" W

Para el desarrollo de los perfiles temporales para coberturas de agua y ríos, se tuvo en cuenta, a manera de ejemplo, el lago Calima Darién (Figura 24) y el Río Caquetá (Figura 25) respectivamente. Se observa que para el lago, el B3 máximo es de 0.1 aproximadamente mientras que para el río es de 0.15. En cuanto al R37, debido a la sensibilidad del infrarrojo en la banda 7, no es de gran ayuda puesto que presenta valores similares en ausencia o presencia de nubes (Figura 26 y 27) respectivamente.




Figura 24: Valores de la banda 3 para la cobertura de agua de coordenadas 3°53'39" N y 76°29'51" W




Figura 25: Valores R37 para la cobertura de agua de coordenadas 3°53'39" N y 76°29'51" W




Figura 26: Valores de la banda 3 para la cobertura de río de coordenadas 1°06'24" S y 71°05'47" W




Figura 27: Valores R37 para la cobertura de río de coordenadas 1°06'24" S y 71°05'47" W

7.2.2. Máximo global de B3 y R37

Los valores máximos de Reflectancia de B3 y R37 se muestran para la zona de estudio con el fin de evaluar la conveniencia del algoritmo IBCM. Estos valores fueron determinados a partir de las observaciones del producto MOD09A1 en el año 2010. La Figura 28 y 29 representan la distribución espacial de los valores obtenidos del punto de inflexión por el algoritmo IBCM en B3 y R37 respectivamente.




Figura 28: Distribución espacial de los valores máximos de reflectancia de B3 para la zona de estudio.

En ella se puede apreciar que los sectores con mayores valores de reflectancia corresponden a los valores cercanos a las cordilleras y a la zona del pacífico. No se observa alta homogeneidad para los sectores de los llanos orientales y la amazonía, puesto que los valores presentan oscilaciones entre 0.01 y 0.15.

Viendo en detalle la región del pacífico sur, se observa que las zonas de cordillera y las zonas aledañas al océano pacífico presentan valores reflectancia superiores a 0.2 mientras que en los sectores del valle entre las cordilleras central y occidental se presentan valores entre 0.01 y 0.1. Así mismo, en la costa caribe se observa que los pixeles que se encuentran en los límites entre los departamentos

de La Guajira, Magdalena y Cesar presentan valores superiores a 0.2 mientras que en el resto de la zona los valores se encuentran entre 0.1 y 0.12.




Figura 29: Distribución espacial de los valores máximos de reflectancia de R37 para la zona de estudio.

En la Figura 29 se presenta un comportamiento similar al de la Figura 28, con la diferencia que en algunos sectores del norte del país presenta valores bajos cercanos a 0 relacionados con humedales y cuerpos de agua, mientras que el resto del país presenta valores cercanos o superiores a 0.4 sin tener relación alguna con otros tipos de coberturas.

7.2.3. Factibilidad de la aplicación del algoritmo IBCM

El método IBCM asume que existe un punto de inflexión entre las observaciones libres de nubes y aquellas que no. Por tanto, es fundamental que el ángulo entre estas observaciones sea cercano a 90° para que esta suposición tenga sentido, ya que si entre las observaciones el ángulo es cercano a 180° , no habrá punto de inflexión y por ende, el método es inviable.

La Figura 30 y 31 muestra la distribución espacial de los ángulos de inflexión en B3 y R37 para la zona de estudio. En el caso de B3 (Figura 30), se observa que

en la totalidad del territorio presenta valores inferiores a 150° , indicando que existe un punto de inflexión entre las observaciones de reflectancia. El sector que se observa más factible para la aplicación del algoritmo corresponde a La Guajira con valores cercanos a 90° mientras que en gran parte del departamento de Boyacá y Norte de Santander presenta ángulos entre 120° y 130° , haciendo que no sea tan factible la aplicación del método.




Figura 30: Distribución espacial de los ángulos con B3 para la zona de estudio.

Para la Figura 31, se observa que la distribución del ángulo de R37 presenta un comportamiento similar a la distribución de los valores de reflectancia en R37, ya que identifica las mismas zonas correspondientes a cuerpos hídricos. En las zonas del sur oriente del país se tiene que los ángulos presentes son superiores al comportamiento general del país con valores entre 110° y 140° .




Figura 31: Distribución espacial de los ángulos con R37 para la zona de estudio.

7.3. MÁSCARA DE NUBES USANDO REDES NEURONALES ARTIFICIALES

Para esta sección se presentan los resultados de la extracción de características implementados para el entrenamiento de la red neuronal artificial MLP. Adicional a esto, se muestra los resultados metodológicos obtenidos que definen la configuración de la red.

7.3.1. Extracción de características

A partir de las bandas espectrales 3 y 7 se aplicó el filtro de media aritmética y el filtro de Sobel para extracción de bordes, ambos filtros de tamaño 3X3. La Figura 32 muestra los resultados obtenidos al aplicar ambas técnicas de realce para la misma zona.




Figura 32: Resultados obtenidos a partir de los filtros de realce aplicados

Las Figuras 32 a y d, corresponden a las bandas espectrales 3 y 7 respectivamente. Se observa que para la banda 3, las nubes presentan mayor realce en comparación con la banda 7, puesto que la primera es mucho más sensible a las partículas pequeñas, facilitando su identificación visual. En relación a las Figuras 32 b y e, el filtro de media aritmética disminuye el ruido presente en las imágenes haciendo contrastar más las nubes respecto a otras superficies y suavizando sus contornos. El Filtro Sobel (Figura 32 c y f), se observa que el realce de los bordes no es solo para las nubes sino también para otras superficies como los ríos y las zonas de cordilleras.

7.3.2. Configuración de la red

Como se mencionó en la sección 6.3.4.3, se definieron tres capas de entrada (Tabla 12). A partir de los datos de entrenamiento, se realizó el proceso de aprendizaje con diferente número de neuronas en la capa oculta, con el fin de identificar qué configuración permite obtener un menor EMC. El cálculo del EMC se realiza a partir del 30% del total de los datos (3 mil muestras) utilizados para el entrenamiento y será el indicador de la eficiencia de la clasificación.

La Figura 33 muestra el comportamiento del EMC de validación con respecto al número de neuronas en la capa de entrada y la capa oculta. Para la configuración de dos neuronas en la capa de entrada (banda 3 y 7), se observa un decrecimiento constante hasta la quinta neurona, a partir de ésta, su EMC no disminuye significativamente, llegando a un mínimo de 0.0378 con 12 neuronas en la capa oculta. En cuanto las configuraciones con 4 (banda 3, banda 7, filtro media banda 3, filtro y media banda 7) y 6 (banda 3, banda 7, filtro media banda 3, filtro media banda 7, filtro Sobel banda 3 y filtro Sobel banda 7) neuronas en la capa de entrada, se observa que el comportamiento es semejante ya que los valores de EMC presentan casi el mismo decrecimiento con cada una de las neuronas en la capa oculta. Este decrecimiento del EMC se presenta hasta la séptima neurona cuyo valor es 0.0339 y a partir de este los decrecimientos no son significativos.




Figura 33: Comportamiento del EMC respecto al número de neuronas en la capa de entrada y la capa oculta

Lo anterior indica que, a pesar de que la configuración con 6 neuronas en la capa de entrada presenta mayor información, su EMC es equivalente a los EMC obtenidos con 4 neuronas en la capa de entrada, por lo que la información que aporta el filtro Sobel no es lo suficientemente significativa para mejorar la clasificación de la red. Por tanto se define que la configuración más adecuada para la detección de nubes corresponde a 4 neuronas en la capa de entrada y 7 neuronas en la capa oculta, como lo indica la Figura (34).




Figura 34: Configuración final de la red para el enmascaramiento de nubes con RNA

7.4. VALIDACIÓN DE LOS ALGORITMOS

7.4.1. Análisis Visual

Para la interpretación visual se seleccionaron tres imágenes aleatorias cuyas coordenadas se muestran en la Tabla 18, para el año 2010. A partir de la Figura 35 se realiza un análisis de la caracterización que hizo cada uno de los métodos (RNA e IBCM) respecto al producto de máscara nubes que ofrece MODIS.

Tabla 18: Extensión de la zona en coordenadas geográficas

Fecha (Día)	Latitud (° ')	Longitud (° ')
Febrero 2	77°18' W	5°51' N
	75°34' W	3°21' N
Septiembre 6	77°18' W	5°51' N
	75°34' W	3°21' N
Diciembre 11	75°50' W	9°22' N
	73°24' W	5°44' N

En la Figura 35 (a, b, c, d), se observa que las tres máscaras presentan un comportamiento similar en la identificación de las nubes, no obstante el método que presentó mayor dificultad fue el de IBCM (Figura 35-d), ya que gran parte de las nubes aún se pueden visualizar en los bordes y en los sectores internos. Por otro lado, los métodos de MODIS y RNA (Figura 35 b c) discriminaron gran cantidad de nubes de la zona, con la claridad de que MODIS presentó dificultades en los contornos de las nubes mientras que RNA fue mucho más preciso.

La Figura 35 (e,f,g,h), evidencia que las máscaras de RNA e IBCM identificaron de forma más detallada las nubes que la máscara de MODIS, debido a que ésta sobrestima la cobertura nubosa. La máscara de MODIS delimita el Rio Meta presente en la zona, considerando a su alrededor gran cantidad de nubes que cubre diferentes elementos de la superficie, cuando en realidad estas coberturas se encuentran libre de nubes, tal como se aprecia en la Figura 35-f.

El caso presente en la Figura 35 (i, j, k, l), tanto MODIS como el método del IBCM tiene dificultad para definir el contorno de las nubes, sobre todo en las zonas donde aparecen nubes muy tenues o delgadas (Figura 35 j y l). Además, se observa que algunos píxeles en el interior de las nubes no fueron detectados por estos dos métodos, caso contrario a la máscara de RNA cuya caracterización tanto al interior de las nubes como en los bordes de las mismas es muy riguroso.




Figura 35: Análisis visual de la detección de nubes de los productos de máscaras de RNA e IBCM respecto al producto de MODIS.

7.4.1.1. Correlación entre métodos

En el siguiente gráfico (Figura 36) se muestra la presencia de nubes en valores de porcentaje sobre la zona de estudio para el año 2010 detectados por cada uno de los métodos. De forma general, se observa que la máscara de nubes de MODIS presenta mayores porcentajes de nubosidad con respecto a las máscaras de RNA e IBCM. Por su parte, el método IBCM detectó menores porcentajes de nubes en 45 de las 46 imágenes.

El porcentaje de nubosidad en la zona de estudio presentó un comportamiento proporcional entre los métodos, ya que a pesar de que no identifican porcentajes de nubosidad iguales, la variación que presentan con respecto al tiempo es similar. Sin embargo, se presentan irregularidades para el día 249 en donde la máscara de MODIS establece porcentajes de nubosidad de más del doble que los otros métodos mientras que para la fecha 345, la máscara de MODIS presentó valores de porcentaje inferiores a las máscaras de RNA e IBCM.




Figura 36: Porcentaje de nubosidad para cada imagen

A continuación se muestra tres gráficos correspondientes a la relación que existe entre los porcentajes de coberturas de nubes estimados por los diferentes métodos, para el año 2010 en zona de estudio.

La Figura 37 muestra el gráfico de dispersión del porcentaje de nubosidad detectado por la máscara de MODIS y la obtenida por el algoritmo de redes neuronales, en donde se obtiene un coeficiente de correlación R^2 de 0.77, una pendiente de 0.77 y un intercepto de 4.3 por ciento. A partir de la línea continua 1 a 1 representada de color rojo, se puede inferir que cuando la máscara de MODIS presenta una cobertura de nubes menor al 15%, la máscara resultante con el método de RNA estima mayores porcentajes mientras que cuando la máscara de MODIS supera este valor, el método RNA tiende a estimar menor porcentaje de

nubosidad, es decir que el método de MODIS tiende a estimar mayor porcentaje de nubosidad respecto a la máscara de RNA.

Por otro lado en la Figura 38, se tiene la misma comparación entre MODIS y los resultados del algoritmo IBCM en donde el coeficiente de correlación R^2 es de 0.76, una pendiente de 0.67 y un intercepto de - 2.9. Estos valores indican que existe una mayor estimación de los porcentajes de nubes en el método de MODIS que en el de IBCM, ya que casi todos los puntos de dispersión de la gráfica están por debajo de la recta uno a uno y la pendiente de la recta que describe la relación entre las dos máscaras, difiere considerablemente.

En cuanto a la Figura 39 se tiene la relación de los porcentajes de nubosidad de los métodos propuestos (RNA e IBCM). En este caso se observa un coeficiente de correlación R^2 de 0.98, una pendiente de 0.87 y un intercepto de - 6.7. Esto muestra que los resultados de los métodos están altamente correlacionados, sin embargo al presentar una pendiente cercana a uno y un intercepto negativo muy alto, se infiere que el método de RNA presenta mayores porcentajes de cobertura de nubes en gran parte de las imágenes, situación que se evidencia al comparar la línea de tendencia y la recta uno a uno.




Figura 37: Gráfico de dispersión del porcentaje de nubosidad detectado por la máscara de MODIS y RNA




Figura 38: Gráfico de dispersión del porcentaje de nubosidad detectado por la máscara de MODIS e IBCM




Figura 39: Gráfico de dispersión del porcentaje de nubosidad detectado por la máscara de RNA e IBCM

7.4.1.2. Distribución espacial de la presencia de nubes por periodo

En esta sección, se divide el periodo de estudio en dos épocas como lo indica la Tabla 19. Estas corresponden a periodos de 4 meses, de Enero a Abril en el que finaliza el fenómeno del niño y de Julio a Octubre en el que inicia La Niña. Cada una de estas imágenes ilustra el porcentaje de nubes detectadas por cada método en 5 clases definidas como Baja (0%-20%), Media Baja (20%-40%), Media (40%-60%), Media Alta (60%-80%) y Alta (80%-100%). Esto permitirá la identificación de las zonas con mayor y menor presencia de nubes.

Tabla 19: Épocas establecidas para el análisis de la presencia de nubes en el país

Fenómeno	Meses	Número de imágenes
Niño	Enero a Abril	16
Niña	Julio a Octubre	16

La distribución espacial de la nubosidad para cada época se muestra en la Figura 39. Se observa que la estimación de la presencia de nubes entre los métodos de RNA y MODIS presenta comportamientos similares mientras que el método de IBCM refleja un comportamiento diferente.

Para el primer periodo (Figura 39 a, b y c), la distribución de la nubosidad en las máscaras de MODIS presentó mayores valores en la costa pacífica y parte de la costa atlántica con nubosidad alta y alta muy alta, para el resto del país se observó una nubosidad media a excepción de algunos sectores del noreste del país. Por su parte, la nubosidad en las máscaras de RNA se enfoca en la costa pacífica y se extiende un poco hacia el noreste con nubosidades altas y muy altas, así mismo se observa que los sectores de los llanos orientales y entre las cordilleras occidental, central y oriental se presenta nubosidad baja y media baja. En cuanto al método de IBCM, se observan nubosidades medias y medias bajas para la costa pacífica y gran parte del sur del país.

El segundo periodo (Figura 39 d, e y f) presenta mayor porcentaje de nubes que el período anterior. Las máscaras de MODIS establecen que los sectores de mayor porcentaje corresponden a la costa pacífica, costa atlántica y parte del centro y oriente del país, con valores altos y muy altos. Por otro lado, los resultados de RNA determinan que los sectores críticos en presencia de nubes son solo la costa pacífica y las cordilleras central y oriental, mientras que el oriente y el sur del país se caracterizan como nubosidad entre media y media baja. Por último, en el método IBCM, se presenta un comportamiento similar al de RNA, sin embargo hacia el sur del país, se encuentran porcentajes medios de nubosidad.




Figura 40: Distribución espacial de la presencia de nubes en el país

7.4.2. Índices Globales respecto a MODIS

En esta sección se realizó una comparación del nivel de clasificación entre las máscaras de MODIS con las de RNA e IBCM utilizando la matriz de confusión. A partir de esta, se realizó el cálculo de los errores de omisión y comisión para las nubes y el coeficiente de concordancia Kappa.

7.4.2.1. Exactitud Global

Con la exactitud global se evalúa la precisión con la que cada método identifica los píxeles cubiertos y no cubiertos por nubes respecto al producto de la máscara de nubes que ofrece MODIS. En la Tabla 20 se muestra la exactitud global promedio de todas las imágenes para cada método. Se observa que ambos métodos presentan exactitudes altas con valores promedio de 91.00% y 87.37% para RNA e IBCM respectivamente. Así mismo, se observa que las desviaciones estándar para el método de RNA es menor que el de IBCM, indicando que la variación de la

exactitud es menor para RNA en todas las imágenes. A pesar de estas diferencias, existen coincidencias en cuanto a los valores máximos fueron similares.

Tabla 20: Mínimo, máximo, promedio y desviación estándar de la exactitud global de los métodos propuestos con respecto a las máscaras de MODIS

Método	Exactitud Global Promedio (%)	Desviación Estándar EG	Máximo	Mínimo
RNA	91.00	2.49	97.93	84.91
IBCM	87.37	3.45	97.84	81.77

7.4.2.2. Error de omisión y comisión en nubes

Con los errores de omisión y comisión se pretende identificar las diferencias entre la detección de nubes de los métodos propuestos. La Figura 41 muestra los errores de omisión y comisión en la clasificación de nubes de la RNA. El máximo error de omisión es del 44.7% y un mínimo de 3.59%, los cuales presentan un comportamiento inversamente proporcional al porcentaje de nubosidad detectado por MODIS, indicando que entre menor cantidad de nubes presente en la imagen, es mucho mayor el error de omisión. Por otro lado, los errores de comisión presentan una mayor dispersión en función del porcentaje de nubosidad, con valores entre 50.9% y el 8.8%, lo que indica que la máscara de MODIS no considera altos porcentajes de las nubes que si fueron detectadas por RNA.




Figura 41: Errores de omisión y comisión en función del porcentaje de nubosidad entre las máscaras de MODIS y RNA

Para el método IBCM, se observa que los errores de comisión fueron mucho mayores que los de omisión, con valores máximos de 71.7% y 38.5% respectivamente. El comportamiento para ambos errores es inverso al porcentaje de nubosidad determinado por MODIS, es decir, los errores de omisión y comisión

disminuyen a medida que el porcentaje de nubosidad de la zona aumenta (Figura 42).




Figura 42: Errores de omisión y comisión en función del porcentaje de nubosidad entre las máscaras de MODIS e IBCM

7.4.2.3. Cálculo del Coeficiente Kappa

Para evaluar la concordancia entre los métodos RNA e IBCM respecto a la máscara de MODIS, se utilizó el coeficiente Kappa, el cual asigna valores entre [-1,1]. Mientras más cercano a 1, el grado de similitud es mayor y cuanto más cercano a -1, mayor es el grado de discordancia.

Los valores de coeficiente Kappa obtenidos para ambos métodos muestran que ambos presentan concordancias aceptables, moderadas, buenas y muy buenas (Figura 43). Para las máscaras de IBCM se observa que los niveles de concordancia van de aceptables a buenas con valores de 0.37 a 0.72. Por otro lado, las máscaras de RNA presentan niveles de concordancia moderadas a muy buenas cuyos valores varían entre 0.53 hasta 0.87. Por tanto, los productos de máscaras de nubes de RNA presentan mayor concordancia con las máscaras de MODIS que con respecto a las máscaras obtenidas con el IBCM.




Figura 43: Coeficiente Kappa para los métodos RNA e IBCM respecto a la máscara de MODIS en función del porcentaje de nubosidad

7.4.3. Índices globales respecto a datos muestreados

Para la validación de los métodos respecto a datos muestreados, se realizó un muestreo de 7900 puntos, en el cual se hizo una verificación visual para cada pixel evaluando la presencia o ausencia de nubes. Para el muestreo se utilizaron 16 imágenes seleccionadas de forma aleatoria, obteniendo 3383 pixeles sin nubosidad y 4517 con nubosidad.

Las Tablas 21, 22 y 23 muestran la matriz de confusión obtenida para las máscaras de MODIS, RNA e IBCM respectivamente. Se observa que la máscara de MODIS es el método con mayor sobrestimación ya que identificó 484 pixeles que no correspondían a nubes, mientras que el método que presentó menor sobrestimación es el de RNA con 13 pixeles. De los tres métodos, el que pasó por alto mayor cantidad de pixeles con nubes fue el IBCM con 940 pixeles y el que presentó menor confusión fue el de RNA con 125 pixeles.

Tabla 21. Matriz de confusión para los datos muestreados de la máscara de MODIS

MODIS		
	No nube	Nube
No nube	2899	484
Nube	202	4315

Tabla 22. Matriz de confusión para los datos muestreados de la máscara de RNA

RNA		
	No nube	Nube
No nube	3370	13
Nube	125	4392

Tabla 23. Matriz de confusión para los datos muestreados de la máscara de IBCM

IBCM		
	No nube	Nube
No nube	3319	64
Nube	940	3577

La Tabla 24 muestra el error global de clasificación, los errores de omisión y comisión y el coeficiente Kappa para los tres métodos a partir de las matrices de confusión. El método que presentó un menor error global fue el de RNA con 1.75% seguido de la máscara de MODIS con 8.68% y finalmente el de IBCM con 12.71%. Se observa que RNA presentó los menores errores de omisión y comisión para ambas clasificaciones (libre de nube y con presencia de nube). Por otro lado, se observa que el método IBCM presentó errores de omisión en píxeles libres del 22.07% y comisión de píxeles nubosos del 20.81%, siendo estos los errores más altos presentados entre los tres métodos. En cuanto a la concordancia con los datos muestreados, los resultados fueron de 0.82, 0.96 y 0.75 para MODIS, RNA e IBCM con niveles de concordancia muy buenos para los dos primeros y bueno para el tercero.

Tabla 24. Error global de clasificación, los errores de omisión y comisión y el coeficiente kappa para los tres métodos

Método	Error global (%)	Comisión libre (%)	Omisión libre (%)	Comisión nube (%)	Omisión nube (%)	Coeficiente Kappa
MODIS	8.68	14.31	6.51	4.47	10.09	0.82
RNA	1.75	0.38	3.58	2.77	0.30	0.96
IBCM	12.71	1.89	22.07	20.81	1.76	0.75

7.4.4. Evaluación de la incertidumbre de la detección de nubes

A continuación se evalúa la precisión de la detección de nubes para los tres productos de máscaras (MODIS, RNA e IBCM). En este caso se emplea los valores del NDVI y la reflectancia de la banda 3. El NDVI, decrece drásticamente cuando hay presencia de nubes sobre las coberturas de vegetación, por tanto, si se conoce los valores de NDVI sobre la vegetación bajo condiciones libres de nubes en un periodo de tiempo estable, se puede utilizar como un punto de partida para establecer la presencia o ausencia de nubes. Así mismo, la banda 3 se usa como indicador para evaluar los resultados de las máscaras de nubes ya que éste presenta valores bajos sobre la superficie del suelo, pero incrementa drásticamente sobre las nubes.

A partir de los productos de máscaras de nubes de los tres métodos, se crea un nuevo producto como resultado de la combinación de estos, con el cual se pretende tener una máscara base asumida como “verdadera”. Posterior a esto, se realiza la extracción de los píxeles libres de nubes a partir de las máscaras de los cuatro productos en el NDVI y la banda 3 de todas las imágenes, obteniendo cuatro escenas libres de nubes por indicador para cada imagen.

Para facilitar el proceso de análisis de esta información, se realiza una selección de píxeles para cada indicador. En cuanto al NDVI, se selecciona aquellos sectores con valores promedio superiores a 0.7 y una desviación estándar menor a 0.05. Por su parte, para la banda 3 se escogen aquellos píxeles con valores promedio menores a 0.2 y con desviación estándar menor a 0.03. Estos umbrales fueron establecidos según Liu & Liu (2013), dado que al usar estos valores, se garantiza un comportamiento estable del NDVI y la banda 3.

Mediante los promedios de NDVI y la banda 3, se calcula el sesgo para cada una de las imágenes correspondientes al periodo de estudio. Esto se realiza con el fin de centralizar la distribución de los datos para que puedan ser comparados bajo los mismos parámetros.

La Figura 44 muestra el promedio de la distribución de los datos correspondiente al sesgo de la banda 3. La línea azul representa los resultados obtenidos a partir de la máscara base o “verdadera”, en la que se observa un comportamiento homogéneo que oscila entre -0.0033 y 0.0022. A partir de ella se tiene que la máscara de redes neuronales se ajusta más a este comportamiento, seguida de MODIS e IBCM. Para las máscaras de RNA los valores varían entre -0.003 y 0.018, mientras que para MODIS e IBCM los valores están desde -0.007 hasta 0.038 y desde 0.0015 hasta 0.0588 respectivamente. Se observa que existen dos intervalos en los que la precisión de los tres métodos presenta mayores divergencias con respecto a la máscara base, correspondiente a los periodos entre el día 25 a 113 y el 305 hasta el 329. Estos periodos coinciden con los mismos periodos en los que se presentó un mayor porcentaje de nubosidad.




Figura 44: Promedio de la distribución de los datos correspondiente al sesgo de la banda 3 en cada uno de los métodos

Dada la Figura 44, se identificaron dos imágenes con valores atípicos y uno con valores más homogéneos para observar la densidad de la distribución para cada máscara. La Figura 45 hace referencia a la distribución del sesgo de la B3 para el día 17, el cual, presenta los valores de dispersión entre los cuatro métodos. Se observa un comportamiento similar entre los métodos tanto en su promedio como en la amplitud de la distribución (-0.025 a 0.025), indicando que los tres métodos presentaron capacidades casi iguales para la detección de nubes en esa fecha. En cuanto a las Figura 46 y 47 de las fechas 97 y 313 respectivamente, se observa que la concordancia entre los métodos difiere significativamente en donde la distribución de los datos para los tres métodos presenta desplazamientos hacia la derecha con respecto al eje, lo que establece que los métodos incluyeron pixeles cubiertos por nubes. Se observa que el método que tiene una distribución mucho más ajustada a la asumida como “verdadera” corresponde al método de RNA seguido por MODIS e IBCM.




Figura 45: Distribución del sesgo de la B3 para el día 17




Figura 46: Distribución del sesgo de la B3 para el día 97




Figura 47: Distribución del sesgo de la B3 para el día 313

Para los sesgos en el NDVI (Figura 48), se observa que en la máscara base los valores se encuentran entre 0.013 y -0.012. En el caso de los promedios del sesgo del NDVI obtenidos mediante las máscaras de RNA, se asemeja más al comportamiento de los promedios de la máscara base, además presenta similitud con respecto a los resultados de la máscara de MODIS en algunas imágenes. No obstante, el método de IBCM presenta valores bajos en el NDVI lo que indica que presenta problemas para la identificación de las nubes en zonas de vegetación.




Figura 48: Promedios del sesgo del NDVI en cada uno de los métodos

Con respecto a las distribuciones de los sesgos de NDVI, las Figuras 49, 50 y 51 ilustran su comportamiento dependiendo de cada método. Para la fecha 17, los valores presentan una distribución homogénea para todas las máscaras, no obstante, las máscaras de RNA y de MODIS son las que presentan mayor similitud para esta fecha. Con respecto al día juliano 97 y 313, la amplitud de las distribuciones de todos los métodos presentó dispersiones significativas con relación a la máscara base, con la claridad de que RNA sigue presentando mayor similitud, seguido de MODIS e IBCM, ya que los datos tienden a estar desplazados hacia la izquierda a partir del eje de la campana de distribución de la máscara base.




Figura 49: Distribución del sesgo del NDVI en la B3 para el día juliano 17




Figura 50: Distribución del sesgo del NDVI en la B3 para el día 97




Figura 51: Distribución del sesgo del NDVI en la B3 para el día 313

8. DISCUSIÓN

En este proyecto se utilizaron dos metodologías para la detección de nubes en imágenes satelitales MODIS del producto MOD09A1 correspondientes al algoritmo basado en la inflexión propuesto por Liu & Liu (2013) y las redes neuronales artificiales de perceptrón multicapa.

El método IBCM fue implementado en este estudio debido a que no requiere de datos de entrenamiento y a su capacidad de considerar la información temporal de cada pixel, permitiendo establecer un umbral dependiendo del comportamiento de la cobertura a partir del supuesto de que existe un punto de inflexión entre las observaciones libres y cubiertas de nubes (Liu and Liu 2013). Sin embargo, su precisión está determinada por la cantidad de registros históricos de la zona de estudio y de la temporalidad de estos, lo que hace que requiere un mayor gasto computacional, retardando la generación de resultados. En cuanto a las Redes Neuronales Artificiales, fueron utilizadas, ya que, a diferencia de los enfoques clásicos de inteligencia artificial, tienen la capacidad de aprender de experiencias pasadas a partir de datos de entrenamiento, pueden extraer las características esenciales a partir de entradas que presenten información irrelevante y cuentan con la capacidad de adaptarse y auto-organizar la información (Castellano, Wenceslao, and Cao 2009; Caicedo and Lopez 2009). No obstante, se requiere de experticia al hacer la configuración de la red puesto que una arquitectura mal estructurada hace que se limite su desempeño (problemas de sobre y sub- entrenamiento) y que aumente la carga computacional.

Los resultados obtenidos mediante la implementación del algoritmo de IBCM muestran que existe un punto de inflexión entre las coberturas libres y cubiertas de nubes al realizar un ordenamiento de los datos para B3 y R37 en cada pixel de la zona de estudio. Los valores obtenidos en el punto de inflexión para cada cobertura en B3 y R37 son de 0.2 y 0.5 para el bosque tropical; 0.12 y 0.4 para desierto; 0.2 y 1.5 para zona urbana; y 0.12 para el agua en B3. Sin embargo, Liu & Liu (2013), obtuvieron valores de 0.1 y 0.35 para los bosques tropicales; 0.14 y 0.4 para desiertos; 0.1 y 0.5 para zonas urbanas; y 0.5 y 0.1 en B3 para el agua. Las diferencias obtenidas se deben principalmente a la cantidad de información empleada por Liu & Liu (2013) va desde el 2000 hasta el 2011 mientras que para este estudio sólo fue considerada la información correspondiente al año 2010. Además, la inflexión de estas coberturas se ve afectada debido a la presencia frecuente de nubes delgadas en la zona tropical durante la temporada de lluvias (Liu and Liu 2013). Respecto a la factibilidad de la aplicación del algoritmo (ángulo de inflexión), se obtuvo que en la totalidad del país no hay zonas de mayor dificultad para la aplicación de este método, resultado que difiere al obtenido por Liu & Liu (2013) puesto que las zonas críticas que ellos identifican corresponden a la costa pacífica.

El Análisis de Componentes Principales es una técnica estadística que tiene como objetivo reducir de variables que explican un fenómeno al transformarlas en unas nuevas denominadas Componentes Principales que tienen como característica principal que no se encuentran correlacionadas (). Esta técnica fue implementada en (Ahmad & Quegan, 2012) para la detección de nubes en imágenes MODIS, en la cual fue significativo solo un componente mientras que para este estudio se necesitaron de dos componentes. Esto se debe a que (Ahmad & Quegan, 2012) utilizó las bandas de la 1, 2, 3 y 4 (correspondientes al espectro visible y un infrarrojo cercano) y las 29, 31 y 32 (correspondientes a bandas térmicas) mientras que en este caso solo se utilizaron las bandas visibles e infrarrojos cercanos, lo que indica que las bandas térmicas podrían aportar información valiosa para detectar las nubes.

Las RNA han sido implementadas para el enmascaramiento de nubes en imágenes de alta resolución espacial (Taravat et al 2015; Jang et al 2006). En la bibliografía consultada, no se encontró algún documento en el que se emplean las RNA en imágenes satelitales MODIS para máscaras de nubes. Sin embargo, Taravat et al (2015) emplea RNA MLP para la detección de nubes en el satélite Meteosat de segunda generación, para la cual, configura una red con 10 neuronas en la capa oculta obteniendo un EMC de validación de 0.005 a partir de 500 mil muestras de entrenamiento. Los resultados encontrados en este proyecto corresponden a una red 7 neuronas en la capa oculta con un EMC de validación de 0.03 y 3 mil muestras. La variación en los resultados se debe al número de muestras empleado para la configuración de la red y a los datos utilizados en la capa de entrada para el entrenamiento.

A nivel de precisión, Taravat et al. (2015) realiza una evaluación de la precisión de clasificación de la RNA MLP con una exactitud global promedio de 88.96% y unos errores de omisión y comisión de 11.04% y 3.88% respectivamente. En el caso de los métodos propuestos en este proyecto, la exactitud global para RNA fue de 98.25%, un error omisión de 10.09% y de comisión de 4.47%, mientras que para IBCM la exactitud fue de 87.29%, un error de omisión del 1.76% y error de comisión del 20.81%. No obstante, estos indicadores no permiten la determinación de la precisión de cada método en la totalidad de las imágenes porque fueron extraídos a partir de un muestreo de píxeles.

En cuanto a la validación estadística de la distribución de los datos bajo condiciones controladas propuesto por Liu & Liu (2013) obtuvo que para los valores promedios del sesgo de NDVI fueron de 0.0001, 0.0550 y 0.2129 en la máscara compuesta por IBCM y MODIS, las máscaras de IBCM y las máscaras de MODIS respectivamente, indicando que el mejor método corresponde al IBCM. Para este proyecto, la composición de las tres máscaras (MODIS, RNA e IBCM) se obtuvieron valores de 0.0007, mientras que para MODIS, RNA e IBCM fueron en promedio de 0.05, 0.02 y 0.1 respectivamente, lo que muestra que el mejor método corresponde a RNA. Para la banda 3, Liu & Liu (2013) encontró valores de 0.0001, 0.0125 y 0.2325 para la composición de máscaras de IBCM y MODIS, las máscaras IBCM y las máscaras de MODIS, siendo el mejor método IBCM; en el caso de este proyecto se obtuvo valores

de 0.00009, 0.0140, 0.0063 y 0.0268 para la composición de las tres máscaras, MODIS, RNA e IBCM respectivamente, dando como resultado que la RNA presenta mejores resultados. Estas diferencias se deben a que Liu & Liu (2013) realiza este análisis utilizando imágenes desde el año 2000 hasta el 2011 mientras que en este estudio se utilizó información solo del 2010. Además, el análisis en (Liu & Liu, 2013) es desarrollado a nivel global mientras que en el estudio fue solo para el territorio colombiano, el cual se caracteriza por presentar una nubosidad mucha más alta que el promedio mundial.

9. CONCLUSIONES Y RECOMENDACIONES

El enmascaramiento de nubes mediante los métodos empleados muestra que es un proceso complejo debido a las características físicas y microfísicas propias de las nubes y a las condiciones climatológicas de la zona. Sin embargo, cada uno de estos métodos tiene características diferentes en cuanto a la forma como procesan la información que permiten la detección de las nubes y pueden ser implementados en diferentes campos de estudio, obteniendo resultados satisfactorios.

El Análisis de Componentes Principales (ACP) permitió disminuir el número de variables a utilizar, ya que fue posible identificar aquellas variables que presentaban alta correlación y que no tuvieran una gran contribución sobre las nubes, y de este modo optimizar la carga computacional. A partir del éste análisis fue posible comprobar estadísticamente que existe una relación entre la banda 3 y la banda 7 para la detección de las nubes.

La aplicación de filtros de media aritmética y Sobel para detección de bordes sobre las bandas 3 y 7, muestran que mejoran el proceso de clasificación de una red neuronal ya que el EMC mínimo sin emplear estos filtros corresponde a valores de 0.0378 mientras que con los filtros fue de 0.0322 y 0.0339 respectivamente. Sin embargo, la aplicación del filtro Sobel requiere de seis neuronas de entrada por lo que se utilizó solo el filtro de media aritmética, el cual solo requiere de cuatro.

La red implementada fue entrenada mediante el algoritmo de aprendizaje Levenberg - Marquardt y con funciones de activación tangencial - sigmoidal y lineal para la capa oculta y de salida. Esta configuración acelera la capacidad de convergencia de los datos para la identificación de un EMC de forma mucho más rápida que los otros algoritmos de aprendizaje. Además, las funciones de activación utilizadas garantizan una capacidad de procesamiento no lineal, haciendo más robusta la clasificación y no se saturan la salida de la red.

La comparación entre los productos de máscaras de nubes de cada método implementado respecto a las máscaras de la MOD09A1, permite establecer que tanto RNA como IBCM presentan en promedio valores de concordancia del coeficiente kappa de 0.71 y 0.56 respectivamente. Esto indica que ambos métodos presentan fuerza de concordancia considerable y moderada, a pesar de las diferencias que los

caracterizan. Además, se observó que la concordancia aumenta en función del porcentaje de nubosidad, es decir, que entre más nubes estén presentes en la zona, mayor es la similitud y menor será el error entre estos.

El tiempo para la generación de las máscaras de nubes para un total de 46 imágenes, cada una con un tamaño de 4021x2928, mediante los métodos de IBCM y RNA implementados en este proyecto es de 5 a 6 horas y de 11 horas respectivamente. En este sentido, el tiempo de procesamiento es mucho mayor para la RNA que para el método de IBCM pero la carga computacional en memoria RAM es mucho mayor para este último ya que requiere que la información esté disponible para los análisis por pixel mientras que la RNA trabaja una imagen al tiempo.

A partir de los análisis visuales se observa que con el método de RNA se obtienen mejores resultados en relación con las máscaras de MODIS e IBCM, ya que esta permite una mejor delimitación de los contornos de las nubes y discrimina las demás coberturas presentes en la zona. No obstante, la dificultad que se presenta en estos métodos es que no pueden discriminar la nieve de las nubes, debido a que la reflectancia entre las nubes y la nieve es muy similar.

Con el análisis de la distribución de los sesgos de NDVI y de la banda 3 se identifica que la máscara de MODIS e IBCM presentan problemas al estimar las coberturas nubosas ya que se observan desplazamientos significativos con respecto a los datos asumidos como “verdaderos”. En lo que confiere a RNA, la distribución de los datos fue mucho más acertada debido a que las desviaciones estándar y los promedios del sesgo coinciden con las distribuciones de validación. A pesar de esto, no es posible afirmar que los productos obtenidos mediante RNA sean mejores que los dispuestos por MODIS ya que cada uno presenta ventajas y desventajas sobre el otro como lo es en tiempo de procesamiento, precisión y la capacidad para la detección de nubes tenues.

Se recomienda el uso de técnicas de reducción de variables como lo es el ACP puesto que permiten reducir la cantidad de variables y eliminando la dependencia que existe entre ellas. Esto permitirá reducir la carga computacional y optimizar el tiempo de procesamiento.

Se recomienda que para futuros estudios en los que se implemente Redes Neuronales Artificiales para la detección de nubes se utilice como parte del pre-procesamiento de los datos de entrada de la red, la aplicación de filtros espaciales que permita extraer más información de la contenida en la imagen.

Se recomienda que al aplicar el algoritmo IBCM, sea empleado cuando se tenga información temporal lo suficientemente significativa ya que en este estudio se trabajó una temporalidad de un año (46 imágenes) y los resultados obtenidos no fueron satisfactorios.

10. BIBLIOGRAFÍA

- Ackerman, Steve. 2010. Discriminating Clear-Sky from Cloud with MODIS Algorithm Theoretical Basis Document. Wisconsin.
- Ahmad, Asmala and Quegan, Shaun. Cloud masking for remotely sensed data using spectral and principal components analysis. 2012. Engineering, Technology & Science Research. Vol 2 (3) 221-225
- Ahrens, Donald. 2012. Meteorology Today: An Introduction to Weather, Climate, and the Environment.
- Alain, Jae-dong Jangt, A Viau, and Francois Anctilj. 2006. "Neural Network Application for Cloud Detection in SPOT VEGETATION Images" 27 (3): 719–34.
- Al-Amri, S, N Kalyankar, and S Khamitkar. 2010. "Image Segmentation By Using Edge Detection." International Journal on Computer Science and Engineering 02 (03): 804–7.
- Aldalur, B, and M Santamaría. 2002. "Realce de Imágenes : Filtrado Espacial." Revista de Teledetección.
- Anegón, Félix De Moya. 1998. "La Aplicación de Redes Neuronales Artificiales (RNA): A La Recuperación de La Información," 147–64.
- Aristizábal, Gloria. 2015. Aspectos de La Circulación Atmosférica de Gran Escala Sobre El Noroccidente de Suramérica Asociada Al Ciclo ENOS 2009-2010 Y Sus Consecuencias En El Régimen de Precipitación En Colombia.
- Aronoff, Stan. 1982. "Classification Accuracy - a User Approach." Photogrammetric Engineering and Remote Sensing 48 (8): 1299–1307.
- Atkinson, Peter, and A Tatnall. 1997. "Introduction Neural Networks in Remote Sensing." International Journal of Remote Sensing 18 (4): 699–709.
- Banco Interamericano de Desarrollo, BID, and CEPAL Comisión Económica para América Latina y el Caribe. 2012. Valoración de Daños Y Pérdidas Ola Invernal En Colombia 2010-2011.
- Banco Mundial. 2014. "Promedio Detallado de Precipitaciones (mm Anuales)." 2014. <http://datos.bancomundial.org/indicador/AG.LND.PRCP.MM/>.
- Bankert, Richard L. 1994. "Cloud Classification of AVHRR Imagery in Maritime Regions Using a Probabilistic Neural Network." Journal of Applied Meteorology 8 (33): 909–18.

Behling, Robert, Mathias Bochow, Saskia Foerster, Sigrid Roessner, and Hermann Kaufmann. 2015. "Automated GIS-Based Derivation of Urban Ecological Indicators Using Hyperspectral Remote Sensing and Height Information." *Ecological Indicators* 48.

Bernal, Juan, María Martínez, and María Soledad. 2004. "Modelización de Los Factores Más Importantes Que Caracterizan Un Sitio En La Red." In *XII Jornadas de ASEPUMA*, 1–13.

Caicedo, Eduardo Francisco, and Jesus Alfonso Lopez. 2009. *La Aproximación Práctica a Las Redes Neuronales Artificiales*. Programa Editorial Universidad del Valle.

Carvajal, Fernando, Manuel Aguilar, Francisco Agüera, and Fernando Aguilar. 2004. "Clasificación de Una Imagen Multiespectral de Satélite de Alta Resolución Espacial Mediante Redes Neuronales Artificiales." *Universidad de Almería*.

Civco, Daniel. 1993. "Artificial Neural Networks for Land-Cover Classification and Mapping." *International Journal of Geographical Information Science* 2 (7): 173–86.

Cohen, J. 1960. "A Coefficient of Agreement for Nominal Scales." *Educ Psychol Meas* 20: 37–46.

Cotton, William, George Bryan, and Susan van der Heever. 2010. *Storm and Cloud Dynamics*. 99th ed.

Delgado, Maria Luisa, and Martin Martin Quintín. 2003. *Aplicaciones de Las Redes Neuronales Artificiales a La Estadística*. Edited by Editorial La Muralla.

Fernandez, Freire, Carlos Gonzales, Alfredo Gomez, and Israel Nieto. 2011. *Introducción a La Teledetección Con ERDAS Imagine*.

Fisher, G, T Danaher, Joint Remote, and Climate Change. 2009. "Automating Woody Vegetation Change Detection at Regional Scales : The Problem of Clouds and Cloud Shadows." In *Earth*, 5.

Flórez López, Raquel, and Jose Miguel Fernández Fernández. 2008. *Las Redes Neuronales Artificiales, Fundamentos Teóricos Y Aplicaciones Prácticas*. Edited by Lorena Bello. Netbiblo. La Coruña - España.

Foody, Giles, Mary McCulloch, and William Yates. 1995. "Classification of Remotely Sensed Data by an Artificial Neural Network: Issues Related to Training Data Characteristics." *Photogrammetric Engineering and Remote Sensing* 4 (61): 391–401.

François Mas, Jean, José Reyes Díaz-Gallegos, and Azucena Pérez Vega. 2003. "Evaluación de La Confiabilidad Temática de Mapas O de Imágenes Clasificadas: Una Revisión." *Investigaciones Geográficas* 51: 53–72.

Gandia, Soledad, and Joaquín Mejía. 1993. La Teledetección En El Seguimiento de Los Fenómenos Naturales. Universitat de Valencia.

García, Jorge. 2009. "Estudio de Filtros Óptimos Para La Eliminación de Ruido En Imágenes Digitales Usando Algoritmos de Multirresolución No Lineales."

Gitelson, Anatoly a., Yi Peng, and Karl F. Huemmrich. 2014. "Relationship between Fraction of Radiation Absorbed by Photosynthesizing Maize and Soybean Canopies and NDVI from Remotely Sensed Data Taken at Close Range and from MODIS 250m Resolution Data." Remote Sensing of Environment 147.

Gómez, Santiago de Pablo. 1995. "ARQUITECTURAS Y ALGORITMOS PARA EL TRATAMIENTO Y LA SEGMENTACIÓN DE IMÁGENES EN TIEMPO REAL." Universidad de Valladolid - España.

Goodwin, Nicholas R, Lisa J Collett, Robert J Denham, Neil Flood, and Daniel Tindall. 2013. "Remote Sensing of Environment Cloud and Cloud Shadow Screening across Queensland , Australia : An Automated Method for Landsat TM / ETM + Time Series." Remote Sensing of Environment 134.

Hagolle, O, M Huc, D Villa Pascual, and G Dedieu. 2010. "Remote Sensing of Environment A Multi-Temporal Method for Cloud Detection , Applied to FORMOSAT-2 , VEN μ S , LANDSAT and SENTINEL-2 Images." Remote Sensing of Environment 114 (8).

Hansen, Matthew C., David P. Roy, Erik Lindquist, Bernard Adusei, Christopher O. Justice, and Alice Altstatt. 2008. "A Method for Integrating MODIS and Landsat Data for Systematic Monitoring of Forest Cover and Change in the Congo Basin." Remote Sensing of Environment.

Hecht-Nielsen, R. 1987. "Kolmogorov's Mapping Neural Network Existence Theorem." In IEEE.

Hilker, Thomas, Alexei I Lyapustin, Compton J Tucker, Piers J Sellers, Forrest G Hall, and Yujie Wang. 2012. "Remote Sensing of Environment Remote Sensing of Tropical Ecosystems : Atmospheric Correction and Cloud Masking Matter." Remote Sensing of Environment 127.

Hmimina, G., E. Dufrêne, J. Y. Pontauiller, N. Delpierre, M. Aubinet, B. Caquet, a. de Grandcourt, et al. 2013. "Evaluation of the Potential of MODIS Satellite Data to Predict Vegetation Phenology in Different Biomes: An Investigation Using Ground-Based NDVI Measurements." Remote Sensing of Environment 132. Elsevier Inc.: 145–58.

Huang, Chengquan, Nancy Thomas, Samuel N Goward, Jeffrey G Masek, Zhiliang Zhu, John R G Townshend, and James E Vogelmann. 2010. "Automated Masking

of Cloud and Cloud Shadow for Forest Change Analysis Using Landsat Images” 31 (20): 5449–64.

Hurtado, Andres Felipe. 2009. “Estimación de Los Campos Mensuales Históricos de Precipitación En El Territorio Colombiano.” Universidad Nacional de Colombia.

Hush, D. 1989. “Classification with Neural Networks: A Performance Analysis. Systems Engineering, 1989.” In IEEE International Conference On, IEEE.

Instituto Geográfico Agustín Codazzi, and Corpoica. 2002. “Zonificación Agroecológica de Colombia.” In Zonificación de Los Conflictos de Uso de Las Tierras En Colombia, 15–47.

Kaasra, I., and M. Boyd. 1996. “Designing a Neural Network for Forecasting Financial and Economic Time Series.” *Neurocomputing* 10 (3): 215–36.

Kaiser, Henry F. 1958. “The Varimax Criterion for Analytic Rotation in Factor Analysis.” *Psychometrika* 23 (3): 187–200.

Kanellopoulos, I, and G Wilkinson. 1987. “Strategies and Best Practice for Neural Network Image Classification.” *International Journal of Remote Sensing* 18 (4): 711–25.

Kavzoglu, Taskin. 2001. “An Investigation of the Design and Use of Feed-Forward Artificial Neural Networks in.” *Information Systems*. University of Nottingham.

Kennedy, Aaron D., Xiquan Dong, Baiké Xi, Patrick Minnis, Anthony D. Del Genio, Audrey B. Wolf, and Mandana M. Khaiyer. 2010. “Evaluation of the NASA GISS Single-Column Model Simulated Clouds Using Combined Surface and Satellite Observations.” *Journal of Climate*

Kussul, Natalia, Michael Korbakov, Alexiy Kravchenko, and Andriy Shelestov. 2005. “Cloud Mask Extracting from Meteosat Data with Use of Parallel Markovian Segmentation Algorithm V”. September: 204–7.

Land Processes Distributed Active Archive Center, LP DAAC. 2014. “Surface Reflectance 8-Day L3 Global 500m, MOD09A1.” <https://lpdaac.usgs.gov>.

Landis, JR, and GG Koch. 1977. “The Measurement of Observer Agreement for Categorical Data.” *Biometrics* 33: 159–74.

Lee, Jonathan, Ronald C. Weger, Sailes K. Sengupta, and Ronald M. Welch. 1990. “A Neural Network Approach to Cloud Classification.” *IEEE Transactions on Geoscience and Remote Sensing* 28 (September): 846–55.

Li, Ming, Yan Wu, and Qiang Zhang. 2009. “SAR Image Segmentation Based on Mixture Context and Wavelet Hidden - Class - Label Markov Random Field.

Computers and Mathematics with Applications.” Computers & Mathematics with Applications 57 (6): 961–69.

Liang, Shunlin. 2005. Quantitative Remote Sensing of Land Surfaces.

Lin, C, B Peng, W Wang, and X Kong. 2012. “Research on PCA and KPCA Self-Fusion Based MSTAR SAR Automatic Target Recognition Alogrithm.” J Electronic Sci Technol 10 (4): 352–57.

Lissens, G., P. Kempeneers, and F. Fierens. 2000. “Development of Cloud, Snow, and Shadow Masking Algorithms for VEGETATION Imagery.” In Proceedings of VEGETATION 2000 Symposium 3: 834–36.

Liu, Ronggao, and Yang Liu. 2013. “Generation of New Cloud Masks from MODIS Land Surface Reflectance Products.” Remote Sensing of Environment 133.

Lózares, Carlos, and Pedro López. 1991. “El Análisis de Componentes Principales: Aplicación Al Análisis de Datos Secundarios.” Revista de Sociologia 37: 31–63.

Lyapustin, A, Y Wang, and R Frey. 2008. “An Automatic Cloud Mask Algorithm Based on Time Series of MODIS Measurements” 113 (August): 1–15.

Martin, Randall V. 2008. “Satellite Remote Sensing of Surface Air Quality.” Atmospheric Environment 42 (34).

Martinuzzi, Sebastián, Wa Gould, and Omr González. 2007. “Creating Cloud-Free Landsat ETM+ Data Sets in Tropical Landscapes: Cloud and Cloud-Shadow Removal.” General Technical Report IITF-GTR-32, 1–18.

Montealegre, J. E. 1996. “Análisis Del Comportamiento de La Precipitación En Colombia Durante Los Períodos de Ocurrencia de Los Fenómenos ENOS (El Niño-Oscilación Del Sur) Y Anti-El Niño.” Atmosfera 24: 41–53.

Montealegre, Jose Edgar. 2007. Modelo Institucional Del IDEAM Sobre El Efecto Climático de Los Fenómenos El Niño Y La Niña En Colombia. Bogota, D.C.

Mulla, David J. 2013. “Twenty Five Years of Remote Sensing in Precision Agriculture: Key Advances and Remaining Knowledge Gaps.” Biosystems Engineering 114 (4).

NASA. 2014a. “About MODIS.” <http://modis.gsfc.nasa.gov/about/>.

NASA. 2014b. “Desing Concept.” <http://modis.gsfc.nasa.gov/about/design.php>.

Olabe, Xabier. 1998. Redes Neuronales Artificiales Y Sus Aplicaciones. Medicina Intensiva. Vol. 29. Bilbao, España. doi:10.1016/S0210-5691(05)74198-X.

Oreopoulos, Lazaros, and Michael J Wilson. 2011. "Implementation on Landsat Data of a Simple Cloud-Mask Algorithm Developed for MODIS Land Bands" 8 (4): 597–601.

Paola, J., and R Schowengerdt. 1994. "A Review and Analysis of Backpropagation Neural Networks for Classification of Remotely-Sensed Multi-Spectral Imagery." *International Journal of Remote Sensing* 16 (16): 3033–58.

Parques Nacionales Naturales de Colombia. 2014. "Bosque Seco Tropical." <http://www.parquesnacionales.gov.co/>.

Pinilla, C, A Alcalá, and F Ariza. 1997. "Filtrado de Imágenes En El Dominio de La Frecuencia." *Revista de Teledetección* 8: 1–5.

Poveda, Germán. 2011. "El Papel de La Amazonía En El Clima Global Y Continental: Impactos Del Cambio Climático Y La Deforestación." In , 145–56.

Qi, Yujiao, Fengri Li, Zhili Liu, and Guangze Jin. 2014. "Agricultural and Forest Meteorology Impact of Understorey on Overstorey Leaf Area Index Estimation from Optical Remote Sensing in Five Forest Types in Northeastern China." *Agricultural and Forest Meteorology* 198-199.

Ripley, B.D. 1993. "Statistical Aspects of Neural Networks. Networks and Chaos—statistical and Probabilistic Aspects." Springer, 40–123.

Rogers, Roddy, and M Yau. 1989. *A Short Course in Cloud Physics*.

Sanchez, Nilda. 2003. "Panorama Actual de Las Técnicas Mixtas de Clasificación de Imágenes Mediante Segmentación Espectral Y Por Texturas. Aplicación a Las Imágenes de Alta Resolución Espacial." *Mapping: Map and Sig Consulting* 88: 32–35.

Sano, E. E, L. G Ferreira, G. P Asner, and E. T. Steinke. 2007. "Spatial and Temporal Probabilities of Obtaining Cloud-Free Landsat Images over the Brazilian Tropical Savanna." *International Journal of Remote Sensing* 28 (12): 2739–52.

Sedano, Fernando, Pieter Kempeneers, Peter Strobl, Jan Kucera, Peter Vogt, Lucia Seebach, and Jesús San-miguel-ayanz. 2011. "ISPRS Journal of Photogrammetry and Remote Sensing A Cloud Mask Methodology for High Resolution Remote Sensing Data Combining Information from High and Medium Resolution Optical Sensors." *ISPRS Journal of Photogrammetry and Remote Sensing* 66 (5). International Society for Photogrammetry and Remote Sensing, Inc. (ISPRS): 588–96.

Serrano, Antonio J, Emilio Soria, and Jose D Martín. 2009. *Redes Neuronales Artificiales*. Escuela Técnica Superior de Ingeniería. Universitat d Valencia.

- Shahtahmassebi, AmirReza, Yang, Ning, Wang, Ke, Moore, Nathan and Shen, Zhangquan. 2013. "Review of shadow detection and De-shadowing methods in remote sensing." *Chinese Geographical Science*, 23(4) 403 - 420
- Tapakis, R, and A G Charalambides. 2013. "Equipment and Methodologies for Cloud Detection and Classification : A Review." *Solar Energy* 95.
- Taravat, A., Proud, S., Peronaci, S., Del Frate, F., & Oppelt, N. 2015. Multilayer Perceptron Neural Networks Model for Meteosat Second Generation SEVIRI Daytime Cloud Masking. *Remote Sensing*, 7(2), 1529-1539.
- Torres, Carlos Edgar. 2010. Análisis de La Ocurrencia de Incendios Forestales En Bogotá D.C., Durante El Fenómeno Del Niño 2009-2010. Bogota, D.C.
- Van der Meer, Freek D., Harald M a van der Werff, Frank J a van Ruitenbeek, Chris a. Hecker, Wim H. Bakker, Marleen F. Noomen, Mark van der Meijde, E. John M Carranza, J. Boudewijn de Smeth, and Tsehaie Woldai. 2012. "Multi- and Hyperspectral Geologic Remote Sensing: A Review." *International Journal of Applied Earth Observation and Geoinformation* 14 (1).
- Van Westen, Cees J. 2013. "Remote Sensing and GIS for Natural Hazards Assessment and Disaster Risk Management." *Remote Sensing GISci Geomorphol* 3 (17): 259–98.
- Wang, C. 1994. "A Theory of Generalization in Learning Machines with Neural Application." The University of Pennsylvania.
- Widrow, Bernard, Rodney Winter, and Robert Baxter. 1987. "Widrow 1987.pdf." *IEEE* 345 (47): 411–29.
- Zhao, Q, Z Xie, H Li, and X Li. 2012. "Color-Feature Extraction of Remote Sensing Image Based on Principal Components Analysis and K-Means." *Microelectron Comput* 29 (10): 61–68.
- Zhu, Zhe, and Curtis E Woodcock. 2012. "Remote Sensing of Environment Object-Based Cloud and Cloud Shadow Detection in Landsat Imagery." *Remote Sensing of Environment* 118.
- Zhu, Zhe, and Curtis E Woodcock. 2014. "Remote Sensing of Environment Automated Cloud , Cloud Shadow , and Snow Detection in Multitemporal Landsat Data : An Algorithm Designed Speci Fi Cally for Monitoring Land Cover Change." *Remote Sensing of Environment* 152.

ANEXOS

ANEXO A. Productos de máscaras de nube implementado los métodos de RNAe IBCM para la zona de estudio en el año 2010




Figura 52. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Enero 1 de 2010




Figura 53. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Enero 9 de 2010




Figura 54. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Enero 17 de 2010




Figura 55. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Enero 25 de 2010




Figura 56. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Febrero 2 de 2010




Figura 57. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Febrero 10 de 2010




Figura 58. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Febrero 18 de 2010




Figura 59. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Febrero 26 de 2010




Figura 60. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Marzo 6 de 2010




Figura 61. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Marzo 14 de 2010




Figura 62. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Marzo 22 de 2010




Figura 63. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Marzo 30 de 2010




Figura 64. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Abril 7 de 2010




Figura 65. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Abril 15 de 2010




Figura 66. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Abril 23 de 2010




Figura 67. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Mayo 1 de 2010




Figura 68. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Mayo 09 de 2010




Figura 69. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Mayo 17 de 2010




Figura 70. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Mayo 25 de 2010




Figura 71. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Junio 2 de 2010




Figura 72. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Junio 10 de 2010




Figura 73. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Junio 18 de 2010




Figura 74. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Junio 26 de 2010




Figura 75. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Julio 4 de 2010




Figura 76. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Julio 12 de 2010




Figura 77. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Julio 20 de 2010




Figura 78. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Julio 28 de 2010




Figura 79. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Agosto 5 de 2010




Figura 80. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Agosto 13 de 2010




Figura 81. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Agosto 21 de 2010




Figura 82. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Agosto 29 de 2010




Figura 83. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Septiembre 6 de 2010




Figura 84. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Septiembre 14 de 2010




Figura 85. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Septiembre 22 de 2010




Figura 86. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Septiembre 30 de 2010




Figura 87. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Octubre 8 de 2010




Figura 88. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Octubre 16 de 2010




Figura 89. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Octubre 24 de 2010




Figura 90. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Noviembre 1 de 2010




Figura 91. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Noviembre 9 de 2010




Figura 92. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Noviembre 17 de 2010




Figura 93. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Noviembre 25 de 2010




Figura 94. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Diciembre 3 de 2010




Figura 95. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Diciembre 11 de 2010




Figura 96. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Diciembre 19 de 2010




Figura 97. Máscaras de nubes implementando RNA e IBCM para las imágenes MOD09A1 del día Diciembre 27 de 2010

ANEXO B. MANUAL DE LA INTERFAZ GRÁFICA DE USUARIO

Como resultado del desarrollo de este trabajo se realizó una interfaz gráfica en Matlab ® que utiliza la Red Neuronal Artificial obtenida para la generación de máscaras de nubes. La Figura 98 ilustra la interfaz gráfica, la cual se compone de un visualizador de imágenes, botones que permiten cargar una o varias imágenes para ser procesadas.




Figura 98 Interfaz gráfica creada que implementa la RNA entrenada

En el panel Visualizador, se observan cuatro botones que permite observar en mayor detalle la imagen a procesar, puesto que se pueden hacer combinaciones RGB (*Red Green Blue*) entre las bandas. Así mismo se puede obtener información referente al archivo Raster como la ruta en que se encuentra, el tamaño de la imagen, el sistema de coordenadas, etc. En la parte superior existen botones de visualización que permiten realizar acercar y alejar la imagen, desplazarla e identificar los valores en un pixel de la imagen para la configuración RGB. En la parte inferior existe un campo que cambia a color a verde en el momento en una imagen es cargada (Figura 99).



Figura 99 Interfaz gráfica con la imagen MOD09A1 del Valle del Cauca

La interfaz permite la selección de un fichero de salida en el que todos los resultados serán almacenados en formato TIF. Esto es realizado mediante el botón que se encuentra en el panel de salida, que al momento de dar clic permite cambiar el directorio por defecto a uno nuevo. En cuanto al panel de Máscaras de Nubes, se presentan dos botones, el primero permite generar la máscara de nubes de la imagen cargada mientras que el segundo permite seleccionar un fichero en el que se encuentren varias imágenes para que sean procesadas. Para ambos botones se muestra un mensaje en el que se debe identificar las bandas 3 y 7 del producto MOD09A1, esto se hace para evitar problemas en caso de que la imagen no tenga la misma composición de bandas que el orden del producto. Posterior a esto, se genera una imagen en el visualizador donde se aprecia la imagen con la máscara de nubes (Figura 100)



Figura 100 Interfaz gráfica con imagen MOD09A1 del Valle del Cauca y su respectiva máscara de nubes