




I N S T I T U T O

*Geográfico Militar*



en colaboración con:



Ministerio  
de Defensa  
Nacional



ecuador  
año la vida

# PREDICCIÓN DE VAPOR DE AGUA PRECIPITABLE CON DATOS DE MEDICIONES GPS UTILIZANDO UNA RED NEURONAL ARTIFICIAL

## SIMPOSIO SIRGAS 2015

Santo Domingo, República Dominicana

18 – 20 Noviembre 2015

Romero, R. & Pilapanta, C.

Instituto Geográfico Militar del Ecuador. Quito – Ecuador



I N S T I T U T O

*Geográfico Militar*



Ministerio  
de Defensa  
Nacional



# INTRODUCCIÓN





I N S T I T U T O

*Geográfico Militar*

## Introducción. Fuente de Errores

### Errores en la posición del satélite

- Efemérides Precisas

### Errores instrumentales en el satélite

- ✓ Reloj
- ✓ Variaciones del centro de fase
- Posicionamiento Diferencial. Parametrización
- Calibración de antenas emisoras

### Propagación de la señal

- ✓ Tropósfera
- ✓ Ionósfera
- ✓ Multicamino (satélite y receptor)
- Modelamiento. Efecto Troposférico
- Modelamiento. Efecto Ionosférico
- Selección del lugar. Parametrización

### Variaciones de la posición del receptor

- ✓ Mareas Terrestres
- ✓ Carga oceánica y atmosférica
- ✓ Movimientos Tectónicos
- Modelamiento de variaciones
- Modelamiento de cargas
- Aplicación de velocidades lineales

### Errores instrumentales en el receptor

- ✓ Reloj
- ✓ Variaciones del centro de fase
- Posicionamiento Diferencial. Parametrización
- Calibración de antenas receptoras

### Ruidos

Fuente. Sánchez L. 2008

## Introducción. Comportamiento de la Señal




Figura 1. Recorrido de la señal GPS a través de la atmósfera

### ✓ Refractividad

Si las variaciones de refractividad no fueran consideradas, fuera posible usar una aproximación geométrica (G) para el recorrido de la señal.

### ✓ Propagación

La velocidad de propagación es **menor en la atmósfera** que en el vacío.

El recorrido verdadero de la señal (S) sigue el principio de Fermat, el cual busca minimizar su longitud (L)

$$\Delta L = \int_S N(s) ds + S - G$$

$$N(s) = (n(s) - 1) \cdot 10^{-6}$$

## Introducción. Retraso Troposférico




Figura 1. Recorrido de la señal GPS a través de la atmósfera

Dependencia de la Presión, Humedad y Ángulo de Elevación

El término (S-G) aporta apenas 1 cm. En la tropósfera para ángulos de elevación >15°

Por convención está conformada por una parte seca (h) y una húmeda (w)

Componente húmedo (w) aporta aprox. 0.2 metros

$$\Delta L = 10^{-6} \int_S N_h(s) ds + 10^{-6} \int_S N_w(s) ds + S - G = \Delta L_h + \Delta L_w + S - G$$

## Introducción. Retraso Cenital Húmedo (ZTW)




Figura 2. Promedio del Retraso Cenital Hidrostático y Húmedo

$$\Delta L_w^z = 10^{-6} \left[ \int_{h_0}^{\infty} \left( k'_2 \left( \frac{P_w}{T} \right) z_w^{-1} \right) dz + \int_{h_0}^{\infty} \left( k_3 \left( \frac{P_w}{T^2} \right) z_w^{-1} \right) dz \right]$$

Donde:

P= Presión

T= Temperatura

z= Ángulo de Elevación

## Introducción. Retraso Cenital Húmedo (ZTW)

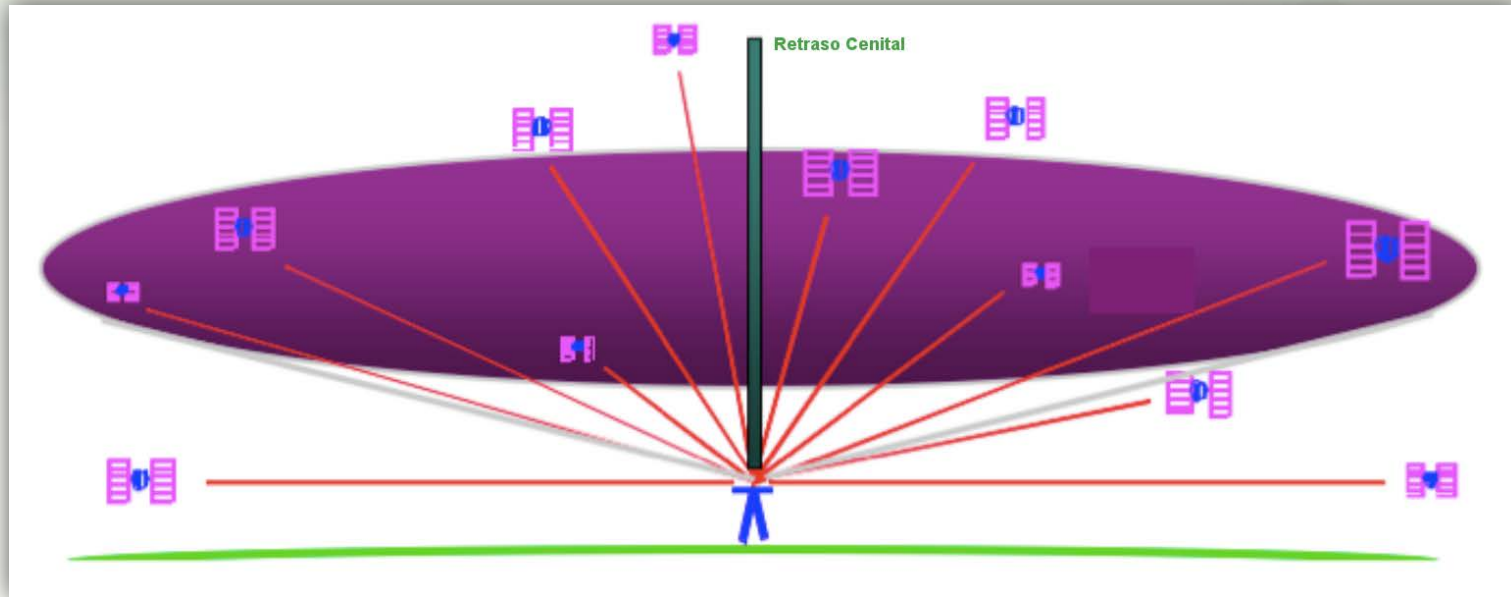


Figura 2. Promedio del Retraso Cenital Hidrostático y Húmedo

### Fuente de Datos Meteorológicos

- VMF/ECMWF
- GPT
- RINEX MET.

### Función de Mapeo

- VMF1
- GMF
- NMF

## Introducción. Vapor de Agua en los residuales de fase

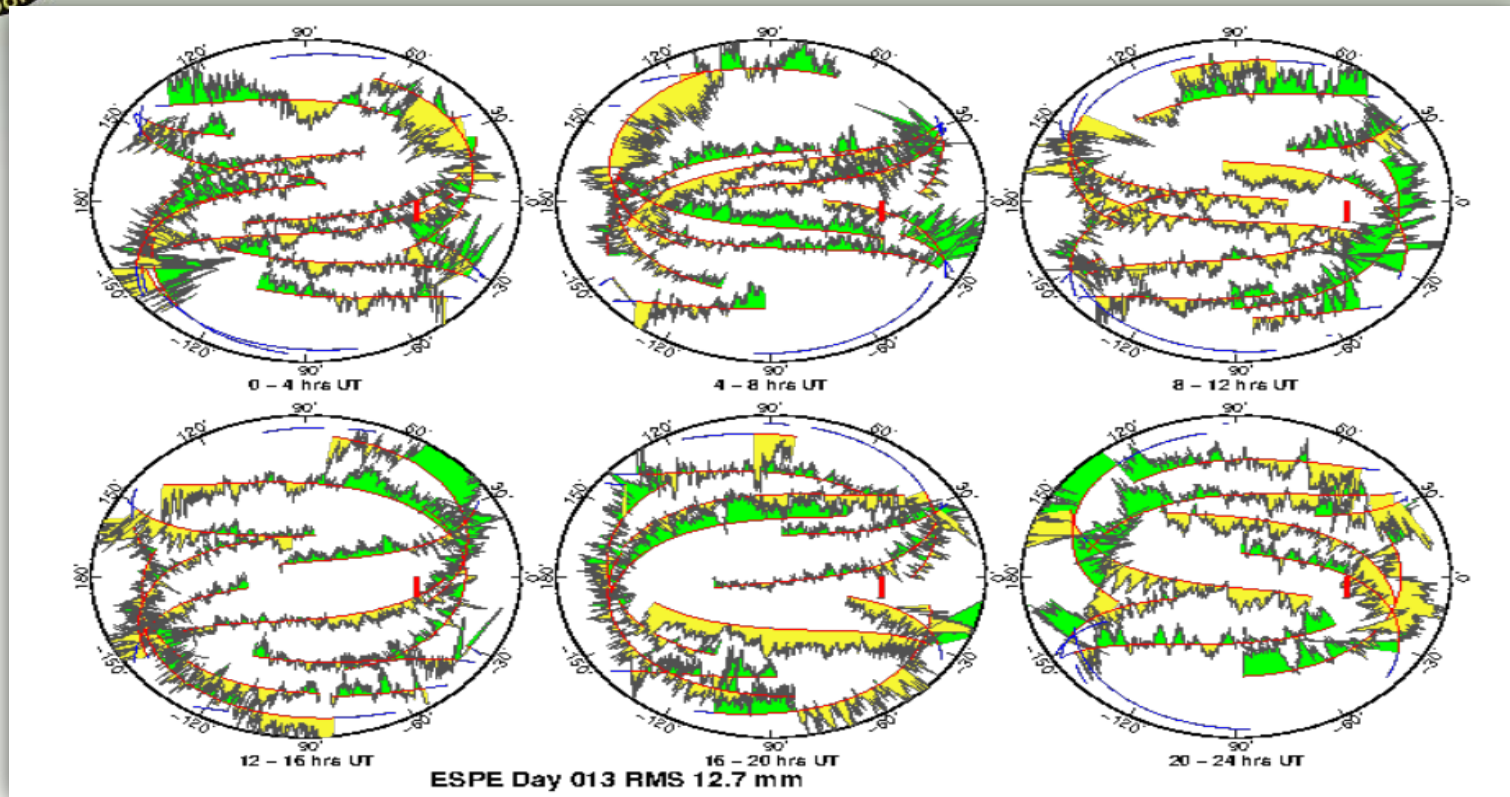


Figura 3. Detección de Vapor de Agua Precipitable en el ruido de la fase

El retraso troposférico Húmedo es proporcional al vapor de agua integrado

$$PWV = \kappa \Delta L_w^z$$





I N S T I T U T O

*Geográfico Militar*



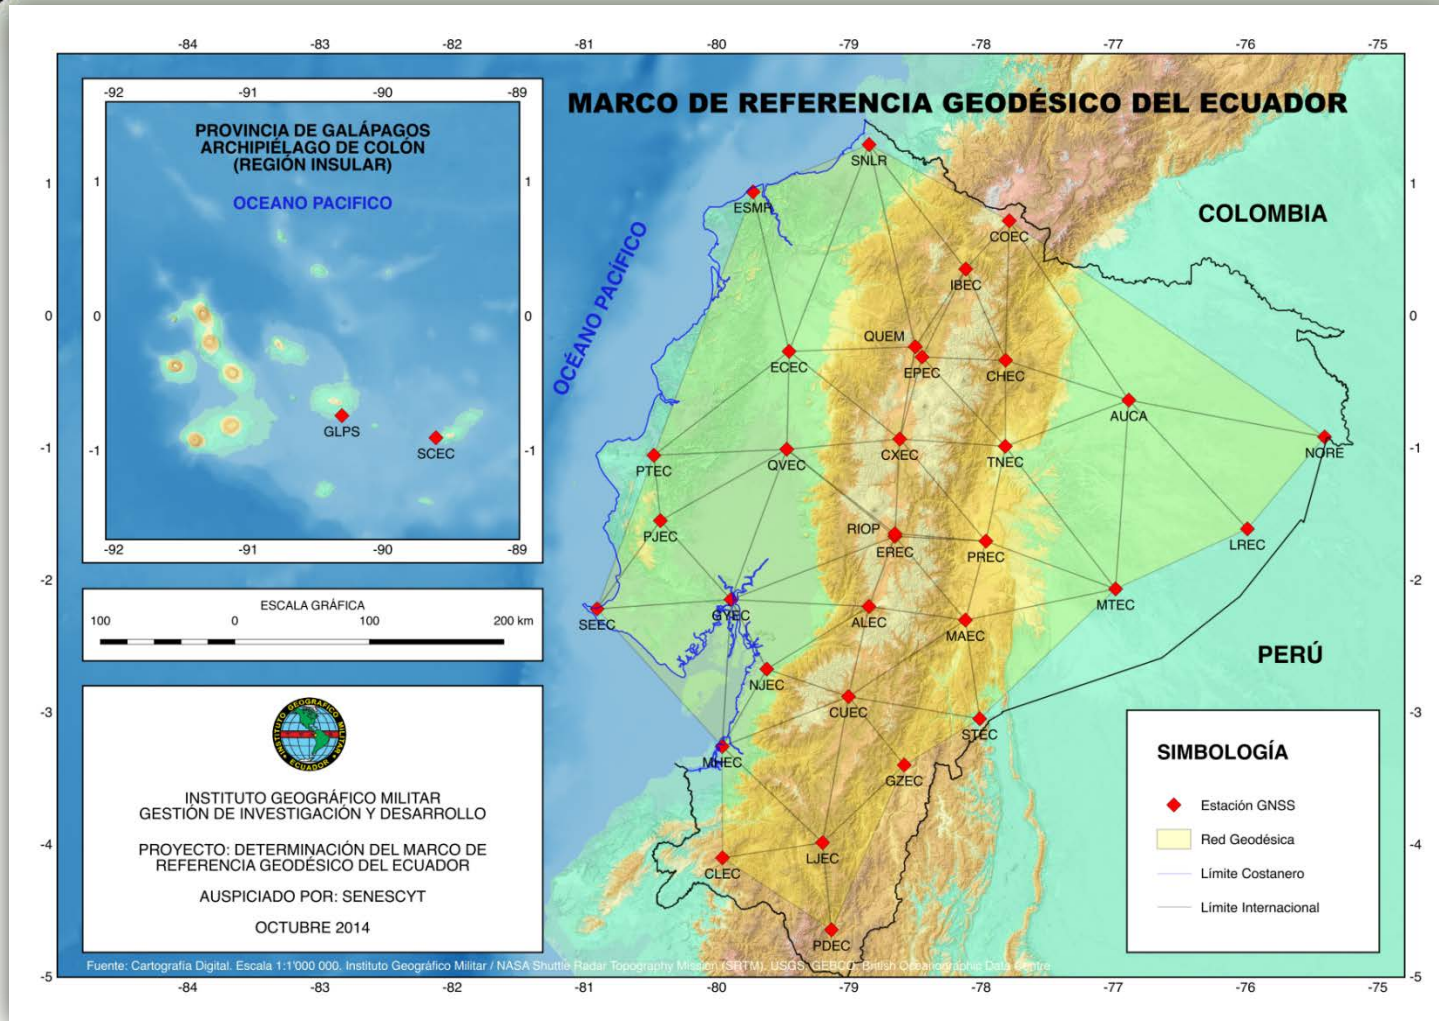
Ministerio  
de Defensa  
Nacional



ecuador  
améica

# METODOLOGÍA

## Metodología. Fuente de Datos



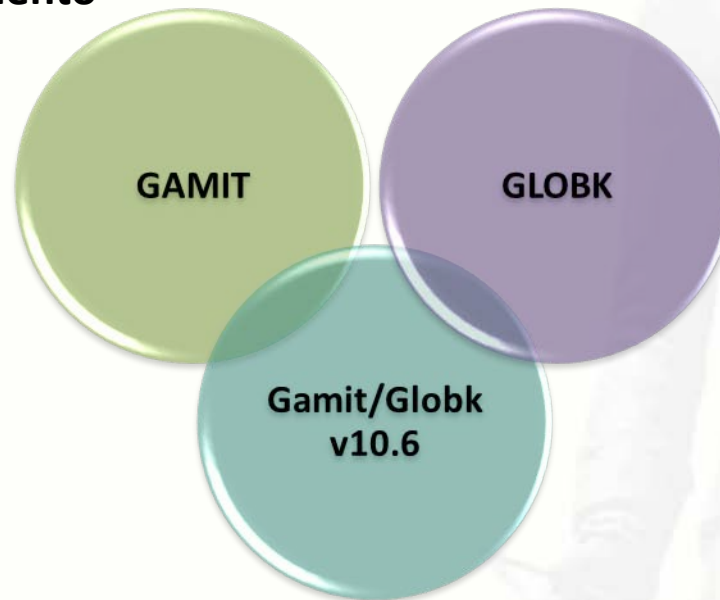
**Figura 4. Estaciones de la Red GNSS de Monitoreo Continuo del Ecuador (REGME) utilizadas**



## Metodología. Procesamiento observaciones GPS



### Software de Procesamiento





## Metodología. Cálculo de Variables Atmosféricas

Tabla 1. Configuración de la estimación de parámetros atmosféricos en el procesamiento GPS

Bloque General	Instrucción	Parámetro/Modelo
Cálculo de Parámetros Atmosféricos	Zenith Delay Estimation	Y
	Interval Zenith	1
	Zenith Constrains	0.5
	Elevation Cutoff	0
	Atmosferic Gradients	Y
	Number of gradients	2
	Gradients constrains	0.01
Modelos atmosféricos utilizados	Met obs Source	GPT 50
	Output MET	Y
	DMap	VMF1
	WMap	VMF1
	Use map.grid	Y

# Metodología. Cálculo de Variables Atmosféricas

EPOCA	LATITUD	LONGITUD	ALTURA	ZTD	ZHD	ZWD	SIG_ZWD	PWV	SIG_PWV	PRESION	TEMP	GRAD_NS	SIG_NS	GRAD_EW	SIG_EW
2014.8466	-1.26860509	-78.62765372	2773.6595	1840.90	1684.90	156.00	10.10	24.66	1.60	737.40	282.50	7.00	12.50	6.90	16.20
2014.8444	-1.26860509	-78.62765372	2773.6595	1832.10	1684.90	147.20	7.00	23.27	1.11	737.40	282.50	-6.45	12.49	-7.22	16.23
2014.8445	-1.26860509	-78.62765372	2773.6595	1831.50	1684.90	146.60	6.20	23.17	0.98	737.40	282.50	-5.91	12.48	-7.64	16.16
2014.8446	-1.26860509	-78.62765372	2773.6595	1828.50	1684.90	143.60	5.20	22.70	0.82	737.40	282.50	-5.36	12.48	-8.06	16.09
2014.8447	-1.26860509	-78.62765372	2773.6595	1830.30	1684.90	145.40	5.80	22.98	0.92	737.40	282.50	-4.82	12.47	-8.48	16.01
2014.8448	-1.26860509	-78.62765372	2773.6595	1826.30	1684.90	141.40	4.70	22.35	0.74	737.40	282.50	-4.27	12.46	-8.90	15.94
2014.8449	-1.26860509	-78.62765372	2773.6595	1821.10	1684.90	136.20	4.30	21.53	0.68	737.40	282.50	-3.72	12.45	-9.32	15.87
2014.8451	-1.26860509	-78.62765372	2773.6595	1819.90	1684.90	135.00	4.50	21.34	0.71	737.40	282.50	-3.18	12.44	-9.75	15.80
2014.8452	-1.26860509	-78.62765372	2773.6595	1818.60	1684.90	133.70	5.40	21.13	0.85	737.40	282.50	-2.63	12.43	-10.17	15.72
2014.8453	-1.26860509	-78.62765372	2773.6595	1817.00	1684.90	132.10	4.40	20.88	0.70	737.40	282.50	-2.09	12.43	-10.59	15.65
2014.8454	-1.26860509	-78.62765372	2773.6595	1811.70	1684.90	126.80	4.80	20.04	0.76	737.40	282.50	-1.54	12.42	-11.01	15.58
2014.8455	-1.26860509	-78.62765372	2773.6595	1810.00	1684.90	125.10	5.30	19.77	0.84	737.40	282.50	-1.00	12.41	-11.43	15.50
2014.8456	-1.26860509	-78.62765372	2773.6595	1809.60	1684.90	124.70	4.50	19.71	0.71	737.40	282.50	-0.45	12.40	-11.85	15.43
2014.8457	-1.26860509	-78.62765372	2773.6595	1813.50	1684.90	128.60	5.30	20.33	0.84	737.40	282.50	0.10	12.39	-12.27	15.35
2014.8459	-1.26860509	-78.62765372	2773.6595	1815.40	1684.90	130.50	4.50	20.63	0.71	737.40	282.50	0.64	12.38	-12.69	15.28
2014.8460	-1.26860509	-78.62765372	2773.6595	1813.50	1684.90	128.60	4.90	20.33	0.77	737.40	282.50	1.19	12.38	-13.11	15.20
2014.8461	-1.26860509	-78.62765372	2773.6595	1813.10	1684.90	128.20	5.00	20.26	0.79	737.40	282.50	1.73	12.37	-13.53	15.12
2014.8462	-1.26860509	-78.62765372	2773.6595	1816.40	1684.90	131.50	4.40	20.79	0.70	737.40	282.50	2.28	12.36	-13.95	15.05
2014.8463	-1.26860509	-78.62765372	2773.6595	1809.20	1684.90	124.30	4.30	19.65	0.68	737.40	282.50	2.83	12.35	-14.37	14.97

Figura 5. Contenido del archivo meteorológico con las variables estimadas en el procesamiento




Figura 6. Vapor de Agua Precipitable de diferentes regiones del Ecuador (a. Costa – b. Sierra – c. Amazonía)

## Red Neuronal Artificial de Función Radial (RBF)

- Enfoque de interpolación en espacios altamente dimensionales que deriva de la teoría de aproximación (*Broomhead and Lowe, 1988*).
- Aprendizaje supervisado (patrones entrada y salida), algoritmo de retropropagación.
- *Senkal, O. (2015)*, mostró un alto grado de correlación entre parámetros meteorológicos y la localización para el cálculo de PWV.
- Por otro lado, *Bordi et al, (2015)* comprobó que la resolución temporal de una serie de tiempo meteorológica, afecta la interpretación de los valores de meteorológicos.

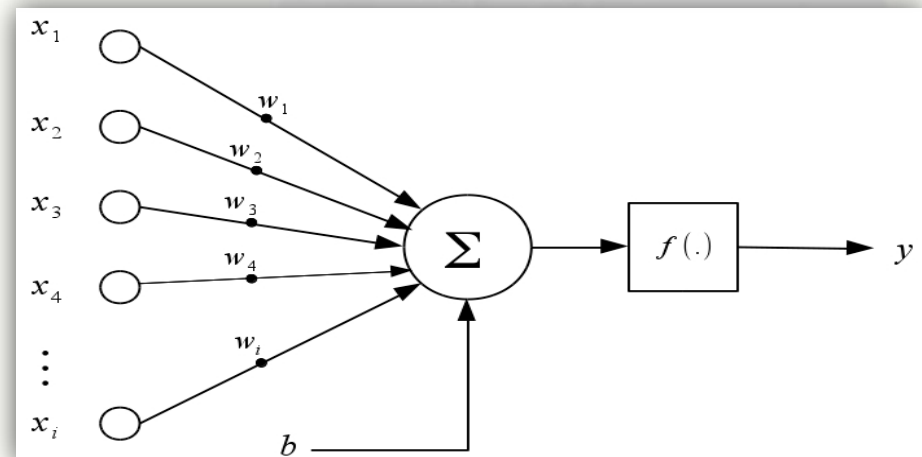
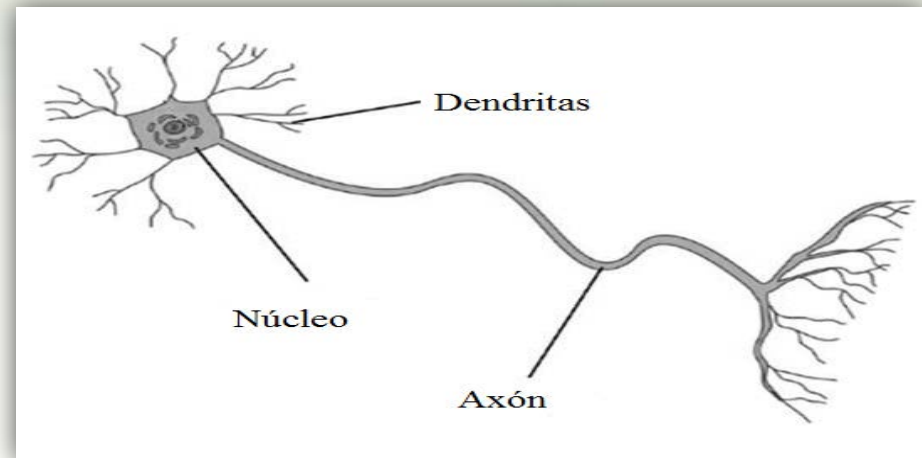
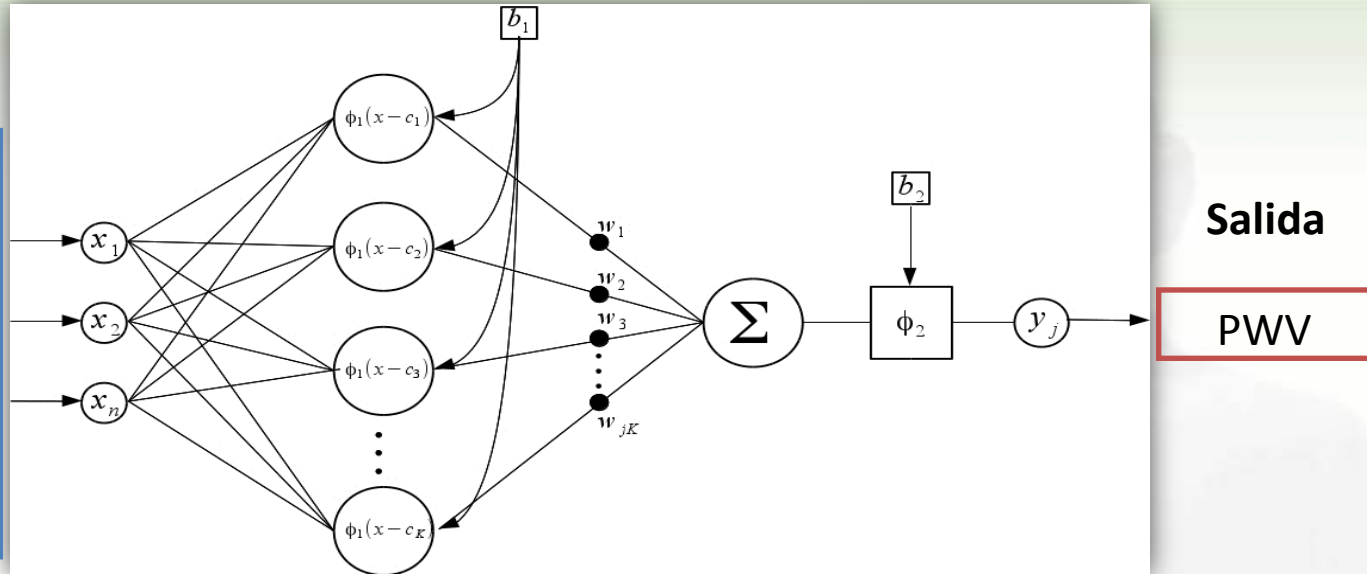


Figura 7. Comparación neurona biológica y una neurona artificial

# Metodología. Modelo de Predicción Espacio - Temporal

## Entradas

Época  
Latitud  
Longitud  
Altura  
ZTD  
Presión  
Temperatura



## Salida

PWV

Figura 8. Modelo de RNA-RBF utilizado

Función de Base Radial

$$\varphi(v) = -e^{-(v^2 \sigma^2)}$$

Salida de la RNA – RBF

$$y_j = \varphi_2 \left[ b_2 + w_{jK} \sum_{i=1}^K \varphi_1 (\|x - c_1\|) b_1 \right]$$

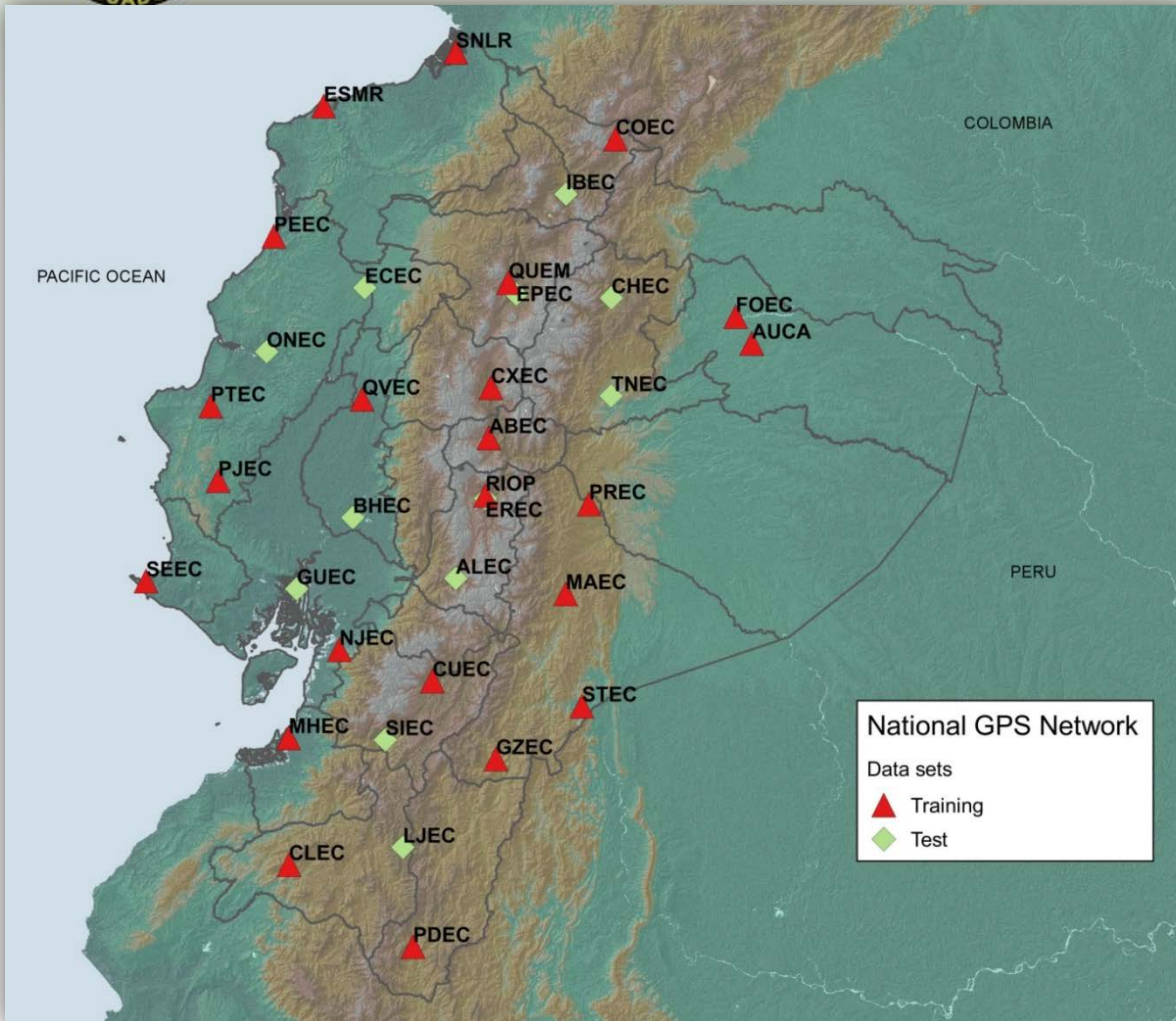
Evaluación de la Salida

$$\varepsilon_j = d_j - y_j$$

Error de la RNA

$$E_\tau = \frac{1}{2} \sum_1^j \varepsilon_j^2$$

## Metodología. Entrenamiento RNA-RBF



### Criterios Entrenamiento RNA

- ✓ **Selección Espacial**  
Estaciones que cubran la mayor parte del territorio.
- ✓ **Selección Temporal**  
Estaciones con series de tiempo sin saltos de ciclos significativos.
- ✓ **Distribución de los Datos**  
Valores extremos (mínimos y máximos) de PWV y sus respectivas variables dependientes, relación con la topografía.

**70% Entrenamiento**  
**30% Validación o Test**

Figura 9. Distribución del conjunto de datos para el entrenamiento de la RNA-RBF





## Metodología. Parámetros de Aprendizaje. RNA - RBF

Tabla 2. Parámetros implementados en la RNA-RBF para la predicción de PWV

Parámetro / Función	Valor / Nombre
Función de Activación	Función Gaussiana
Función de salida	Función Lineal
Normalización	Escalamiento desde 0 a 1
Número de unidades ocultas	50
Iteraciones	50000
“Spread”	0,63
Tasa de aprendizaje	1 E -8
Error	1e-3
Momentum	0,9





I N S T I T U T O

*Geográfico Militar*



Ministerio  
de Defensa  
Nacional




# RESULTADOS




# Resultados. Vapor de Agua vs. Valores de Entrada


a. PWV-Latitude




b. PWV-Longitude




c. PWV-Height




d. PWV-ZTD



e. PWV-Pressure



f. PWV-Temperature




**Figura 10. Correlación gráfica entre valores de Vapor de Agua Precipitable y las Variables de entrada**

Predicción de Vapor de Agua Precipitable con datos de mediciones GPS utilizando una Red Neuronal Artificial. Romero R. & Pilapanta C.



## Resultados. Distribución de Patrones de Entrada



**Figura 11. Distribución de los patrones de entrada normalizados antes del entrenamiento de la RNA**

## Resultados. Resultados del Entrenamiento

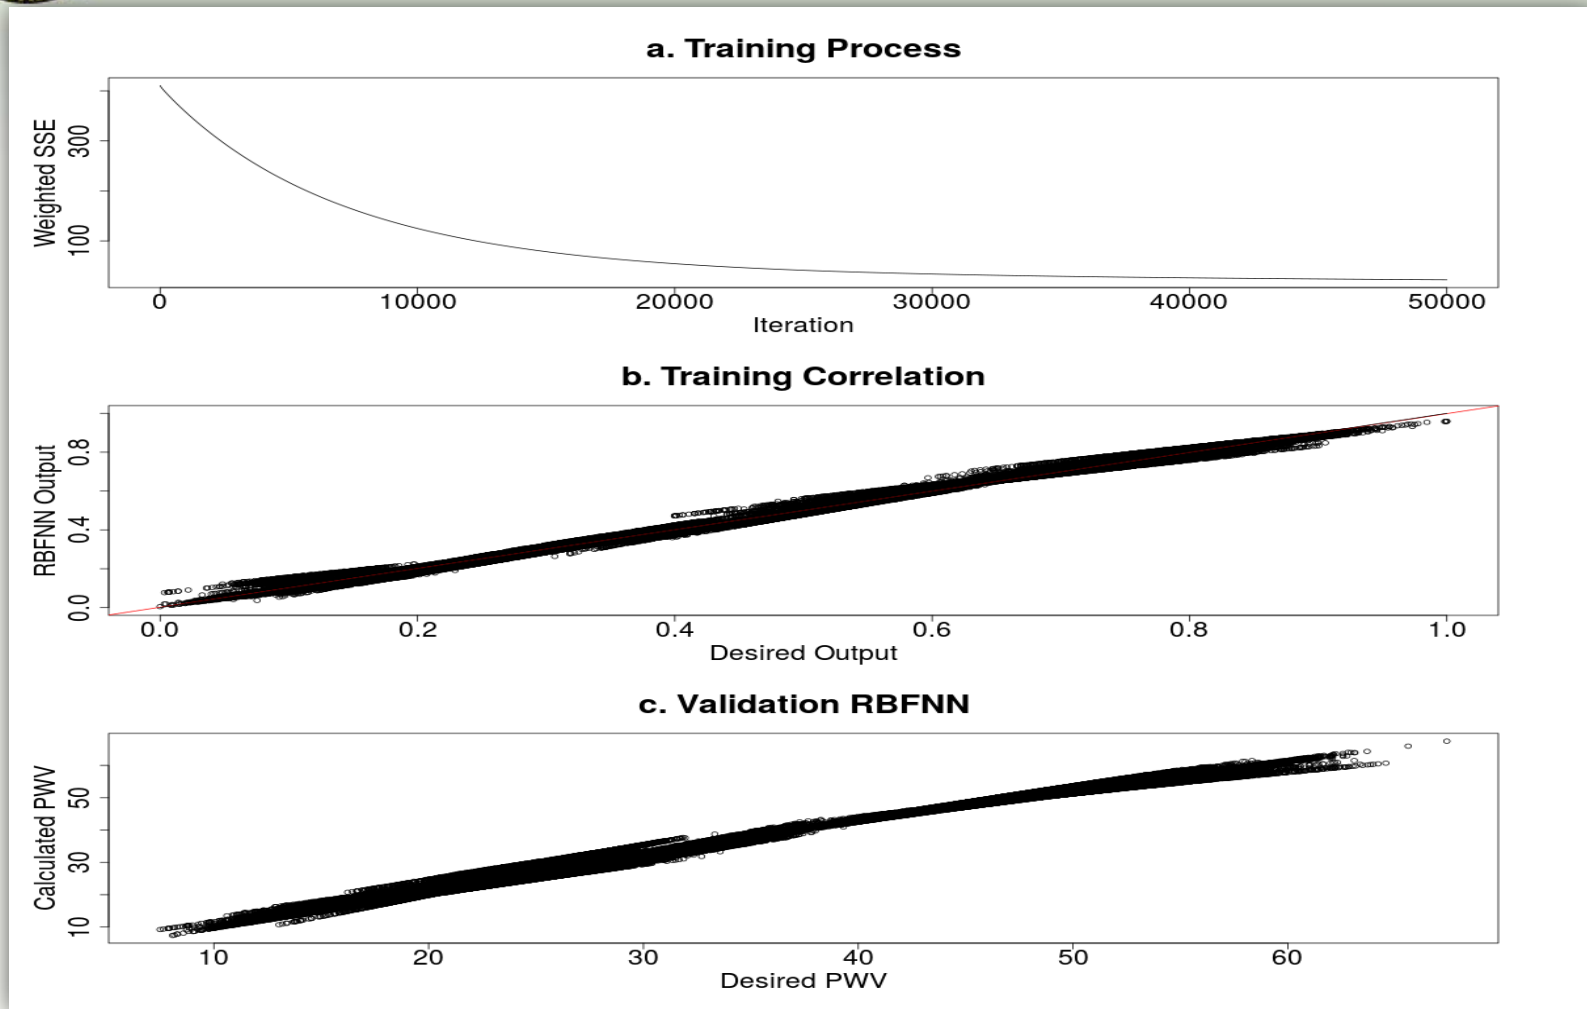



Figura 12. Resultados del Entrenamiento y Validación de la RNA - RBF



## Resultados. Resultados del Entrenamiento

PWV Modelado y Error de la Predicción



**Figura 13. Resultados del Entrenamiento y Validación de la RNA - RBF**



## Resultados. Estadísticos Principales

Tabla 3. Estadísticos principales del modelo neuronal utilizado

Parámetro	Valor
Coeficiente de Correlación	0,98
RMSE	2,33 mm
MAE	1,95 mm
Índice de Concordancia (Agreement)	0,99
Desviación Estándar	1,33 mm



I N S T I T U T O

*Geográfico Militar*



Ministerio  
de Defensa  
Nacional



# CONCLUSIONES







I N S T I T U T O

*Geográfico Militar*

## Conclusiones

- ✓ Se calculó el modelo neuronal para la predicción de Vapor de Agua basado en un modelo de función de base radial, a partir de los datos del procesamiento GPS de la REGME con un RMSE = 2 mm.
- ✓ Los parámetros de entrada (variables independientes) utilizados tales como la posición, retraso troposférico y variables meteorológicas mostraron correlación con el vapor de agua.
- ✓ La metodología de redes neuronales artificiales se propone como alternativa para establecer un modelo general de predicción de PWV, considerando diferentes variantes para los patrones (entradas - salida) del entrenamiento.
- ✓ La aplicabilidad del modelo se vería reflejada en diferentes áreas relacionadas con la gestión del riesgo, hidrología, meteorología y ciencias de la Tierra afines.



I N S T I T U T O

*Geográfico Militar*



# GRACIAS POR SU ATENCIÓN ...

Ricardo V. Romero Ch.  
ricardo.romero@mail.igm.gob.ec

Christian G. Pilapanta A.  
christian.pilapanta@mail.igm.gob.ec