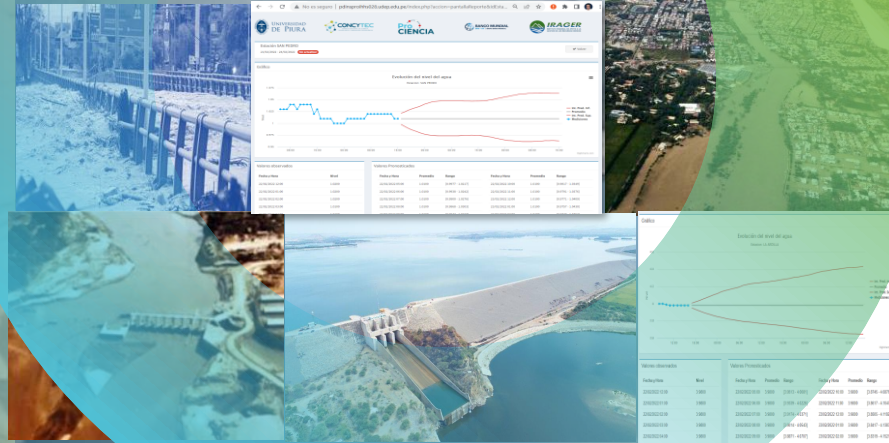


## Cierre de Proyecto

Modelación hidrológica de los caudales de los ríos Chira y Piura:

Evaluación de la red hidrometeorológica actual y elaboración de una herramienta de predicción

Dr. Jorge Reyes Salazar





# Equipo de la investigación

- Dr. Jorge Reyes Investigador principal
- Dr. Ismael Sánchez Investigador
- Dra. Isabel Gonzalez Investigadora
- Mgtr. Marina Farías Investigadora
- Mgtr. Shirley Carrillo Coordinadora
- Ing. Stephanie Villanueva Gestora tecnológica
- Ing. Karina Infante Programadora
- Lic. Juliana Vilcazán Comunicadora

# Equipo de la investigación - tesistas

- Mgtr. Luis Noblecilla Tesista posgrado
- Mgtr. Jorge Peña Tesista posgrado
- Ing. Carlos Martínez Tesista posgrado
- Ing. Alvaro Coronado Tesista pregrado
- Ing. Haaron Chávez Tesista pregrado
- Ing. Antony Abad Tesista pregrado
- Ing. Noelia Avilés Tesista pregrado

Este proyecto, basado en el desarrollo de modelos estadísticos de predicción y un paquete informático, es importante para la región Piura por anomalías climáticas, como El Niño, que influyen en el comportamiento de las cuencas Chira y Piura. Por ello, el resultado de la investigación permitirá conocer, gestionar y predecir con precisión el comportamiento de la hidrología en estas cuencas.

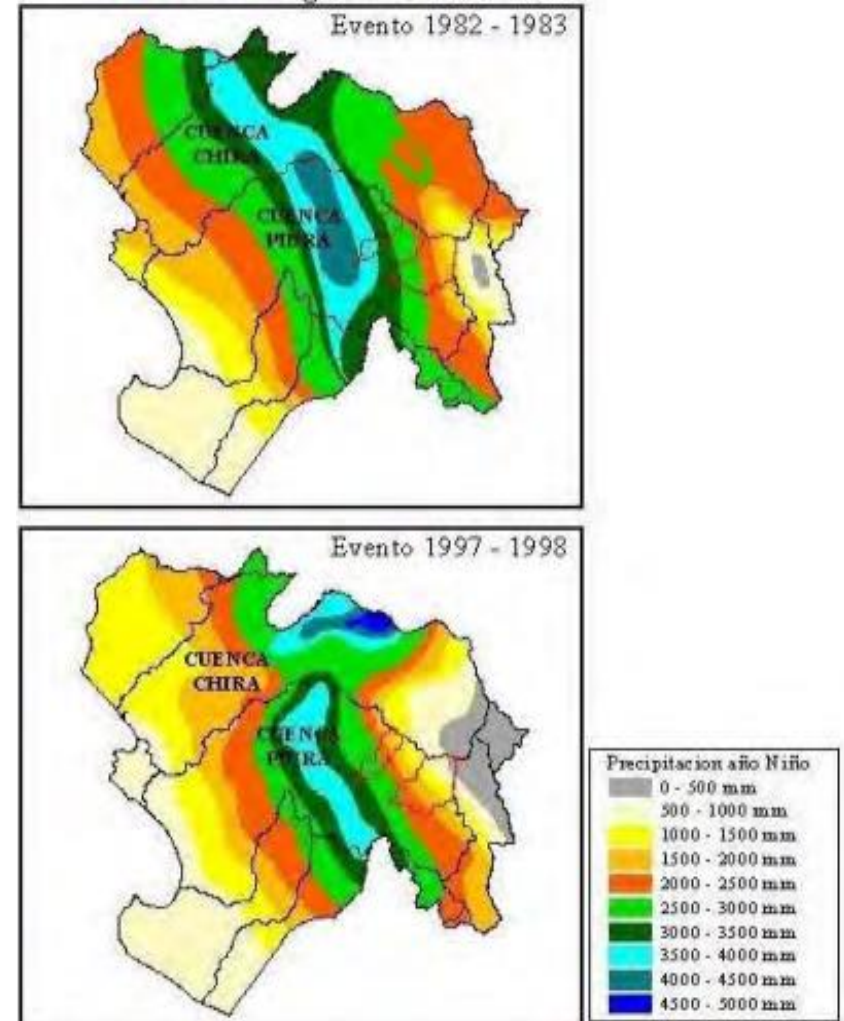
# Objetivos generales del proyecto

- Desarrollar **modelos estadísticos para la predicción a corto plazo** (24, 48, 72 horas) de los caudales de avenida de los ríos Chira y Piura partiendo de un estudio exhaustivo de la red hidrometeorológica, que garantice la calidad de la información empleada en la predicción.
- Elaborar un **paquete informático para obtener de manera automática las predicciones**, a la que tengan acceso entidades como el Proyecto Chira Piura, GORE, COER, IRAGER y usuarios particulares de la Región.



# Objetivos específicos del proyecto

1. Evaluar:
  - a. La red hidrometeorológica actual, con propuestas de mejora para una mejor predicción.
  - b. La variabilidad hidrometeorológica en las cuencas Chira y Piura.



# Objetivos específicos del proyecto

2. Determinar el caudal de ingreso al reservorio Poechos en avenidas: cauce principal y aporte lateral.

En épocas de crecidas el cauce principal no es el único ni el principal aporte (Est. Ardilla), existe contribución lateral difusa, así como de quebradas principales como La Solana [?] los registros de Ardilla no coinciden con el balance.





# Objetivos específicos del proyecto

3. Determinar los niveles del río Piura en las zonas con riesgo de desborde en función de los caudales y de la sedimentación o erosión del fondo.

Con este análisis podremos determinar el nivel esperado del río para los caudales que serán pronosticados con los modelos estadísticos que serán desarrollados en este proyecto.



# Objetivos específicos del proyecto

4. Desarrollar modelos estadísticos para la predicción a corto plazo del caudal de avenida de los ríos Chira y Piura.
5. Desarrollar la plataforma web de publicación de pronósticos.

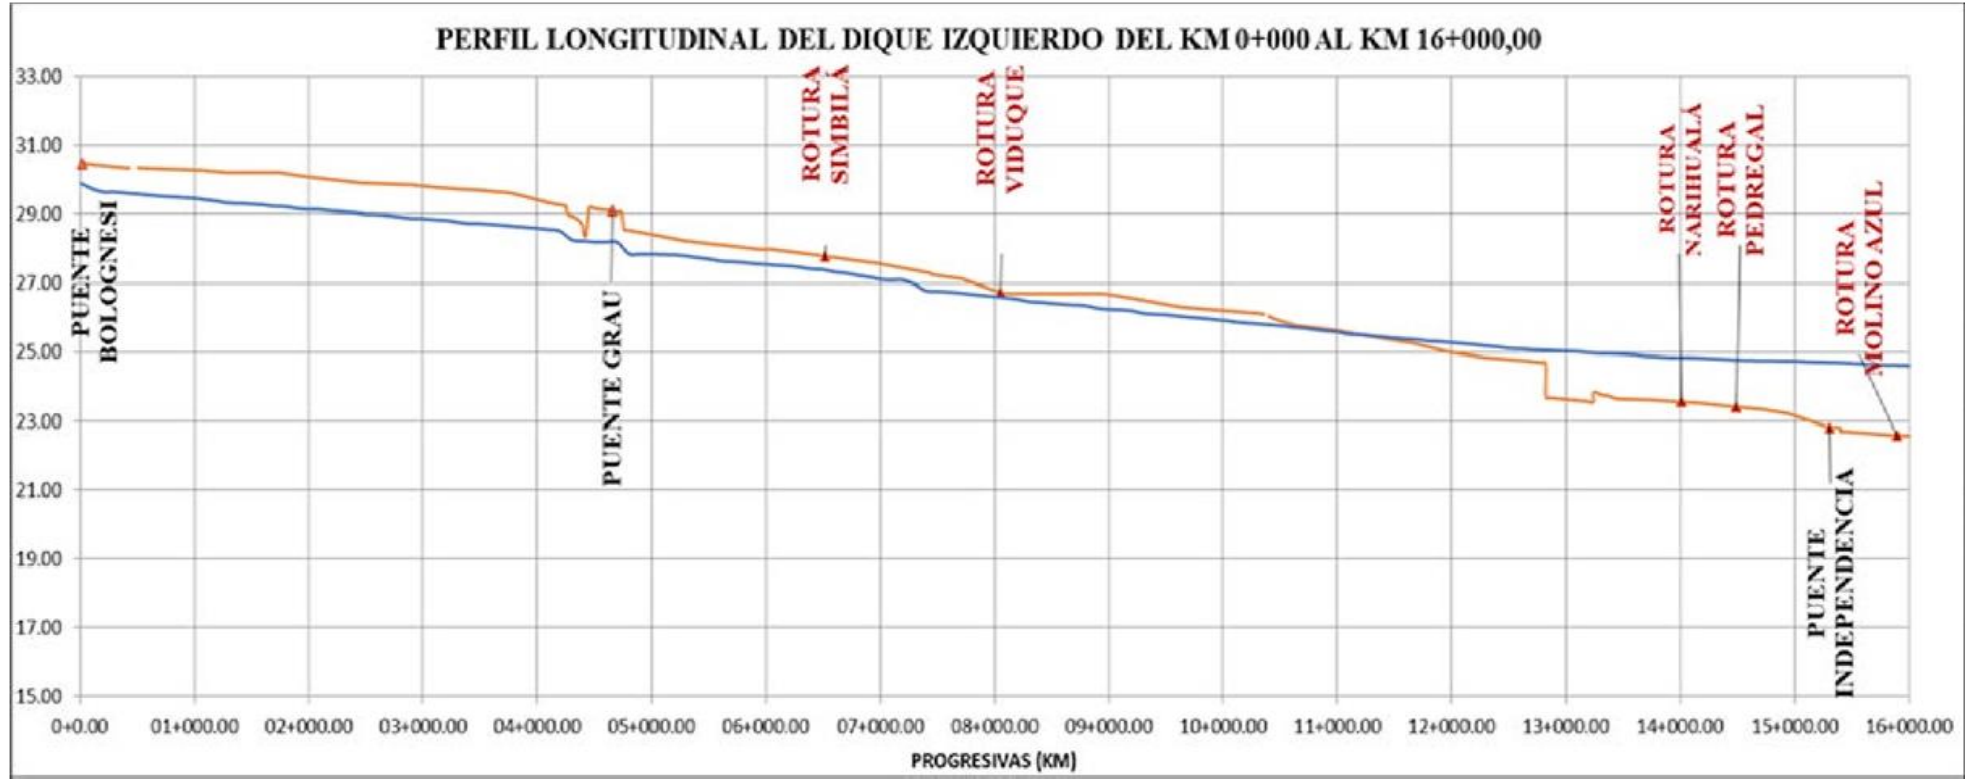
# Resultados

- 02 modelos de pronóstico de caudales
- 02 artículos presentados en revistas indizadas
- 08 ponencias en congresos internacionales
- 03 tesis de posgrado
- 03 tesis de pregrado
- 01 paquete tecnológico
- 02 eventos de difusión

# Puente Cáceres 2017

Nivel del agua 32.3 msnm





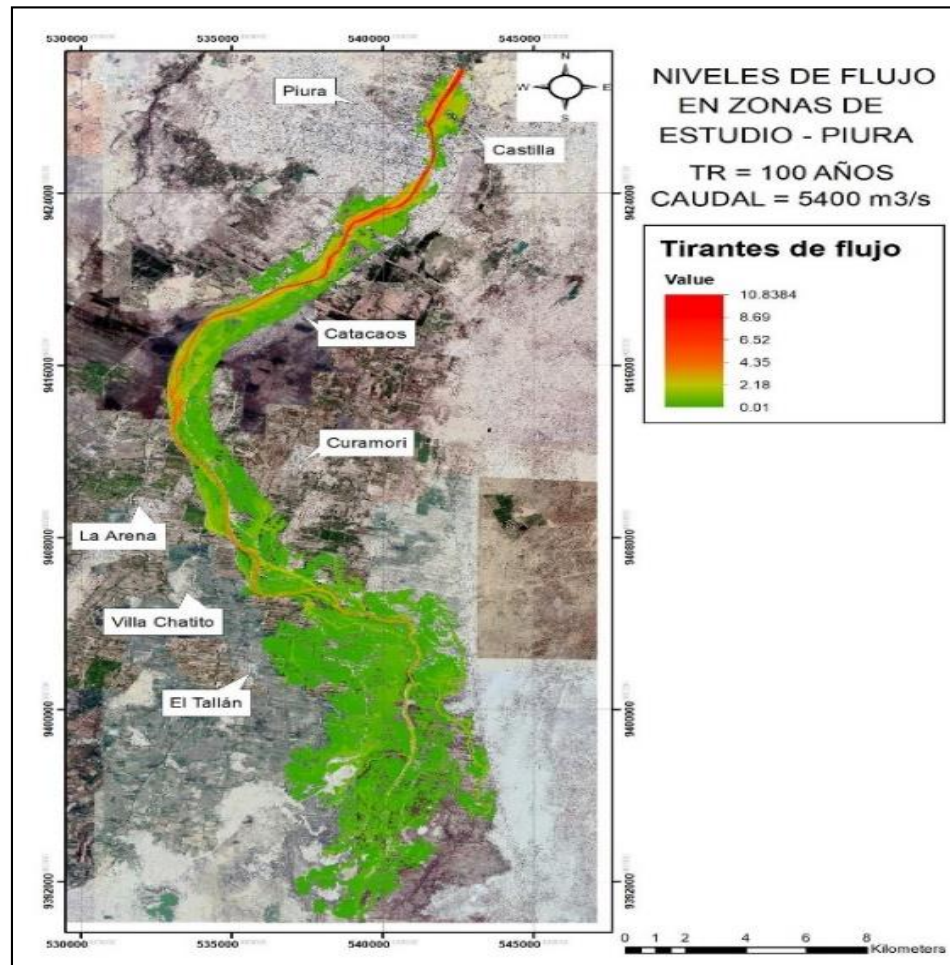
ANÁLISIS DEL COMPORTAMIENTO HIDRÁULICO DEL RÍO PIURA, EN EL TRAMO LOS EJIDOS - PUENTE INDEPENDENCIA Jessica Maza-Sócola






# ZONIFICACIÓN DEL RIESGO POR INUNDACIÓN EN EL TRAMO URBANO DEL RÍO PIURA EN SITUACIONES DE FEN

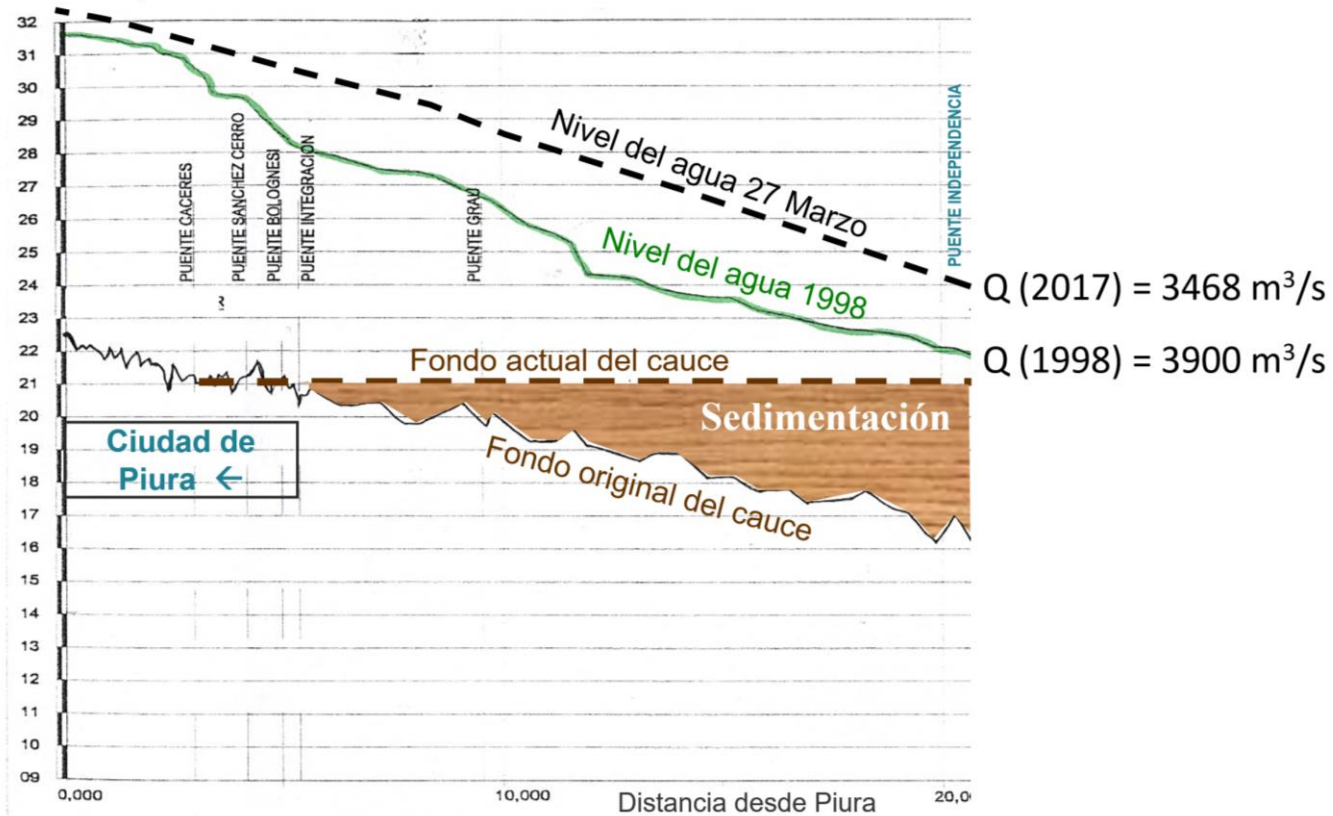
XXIX CONGRESO LATINOAMERICANO DE HIDRÁULICA  
*Peña, Reyes, Farías*



# Cambio del fondo del cauce



# Influencia de la no desembocadura del río al mar



Se concluye que no existe un nivel del agua único para un determinado caudal, este depende del nivel del fondo.

El fondo a su vez es variable dependiendo de las condiciones aguas abajo del Río y de una excesiva producción de sedimentos de la cuenca.

Esta conclusión, ya conocida, se evidencia notablemente comparando el FEN 1998 y 2017.



Es fundamental que las estaciones de medición de caudales, niveles de agua, velocidades también dispongan de medición del fondo del cauce para poder predecir los niveles de agua ante avenidas.



UNIVERSIDAD  
DE PIURA



**IRAGER**  
INSTITUTO REGIONAL DE APOYO A LA  
GESTIÓN DE LOS RECURSOS HÍDRICOS



**Pro  
CIENCIA**



**BANCO MUNDIAL**  
BIRF • AIF | GRUPO BANCO MUNDIAL

## Cálculo de la concentración de sedimentos en suspensión Fórmula de Yang

$$\log C_t = 5.435 - 0.286 \log \frac{\omega D}{\nu} - 0.457 \log \frac{U^*}{\omega} + (1.799 - 0.409 \log \frac{\omega D}{\nu} - 0.314 \log \frac{U^*}{\omega}) \log \left( \frac{US}{\omega} - \frac{U_{cr} S}{\omega} \right)$$

- $C_t$  = Concentración total de sedimentos en partes por millón por peso
- $D$  = Diámetro medio
- $S$  = Pendiente media del nivel de agua o de la línea energética
- $U^*$  = Velocidad de corte
- $U$  = Velocidad Promedio del agua
- $U_{cr}$  = Velocidad promedio crítica del agua en movimiento incipiente
- $\nu$  = Viscosidad cinemática
- $\omega$  = Velocidad terminal de caída
- $\mu$  = Viscosidad dinámica

*Gracias*



Proyecto  
**Concytec**  
**Banco Mundial**



UNIVERSIDAD  
DE PIURA

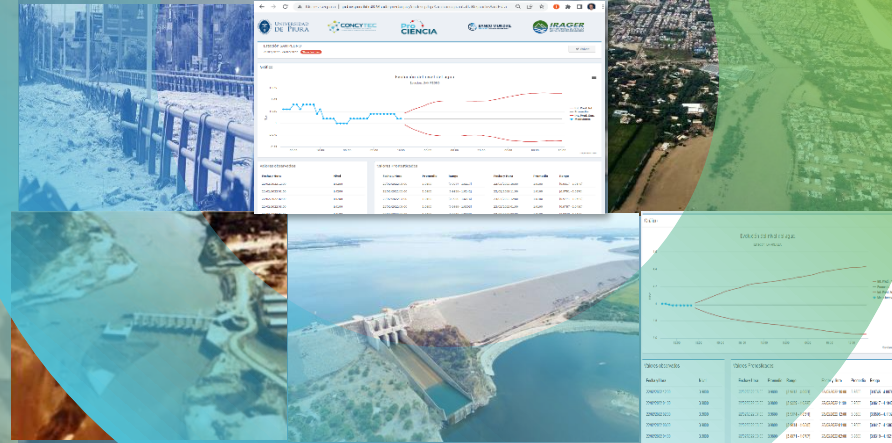


## Cierre de Proyecto

Modelación hidrológica de los caudales de los ríos Chira y Piura:

Evaluación de la red hidrometeorológica actual y elaboración de una herramienta de predicción

Mgtr. Marina Farias de Reyes





# Fases del proyecto

1




Estudio de la red  
hidrometeorológica

2



Recolección de la  
información

3



Construcción de  
los modelos

4

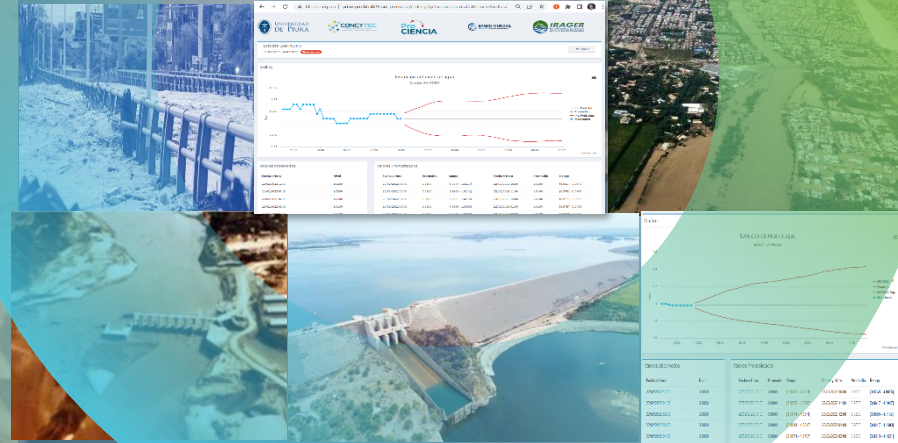


Implementación  
de la plataforma

## Cierre de Proyecto

Evaluación de la red hidrometeorológica de las cuencas hidrográficas Chira y Piura y propuestas de mejora

Mgtr. Ing. Marina Farías de Reyes  
Co-investigadora del proyecto  
Profesora de la facultad de Ingeniería UDEP



# Introducción

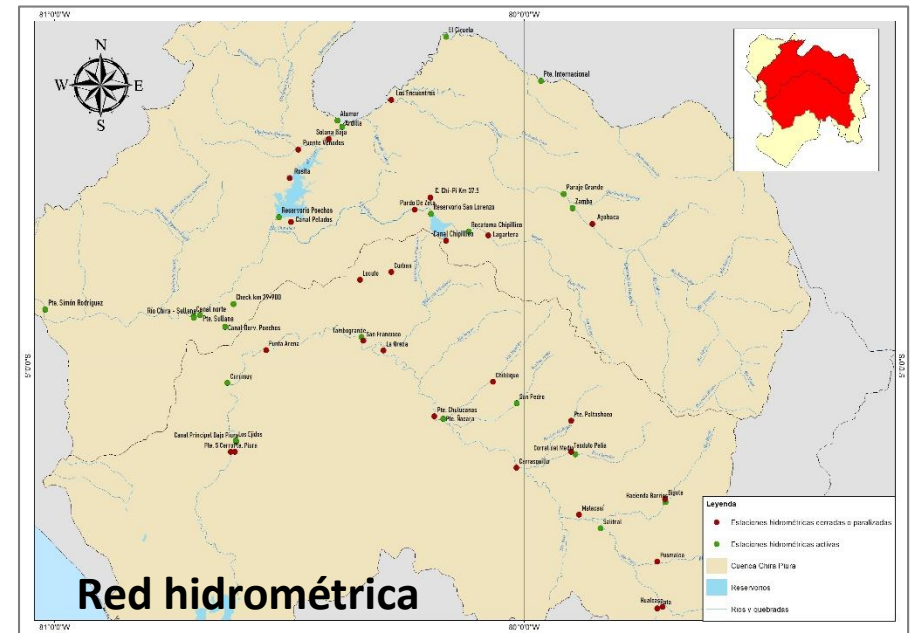
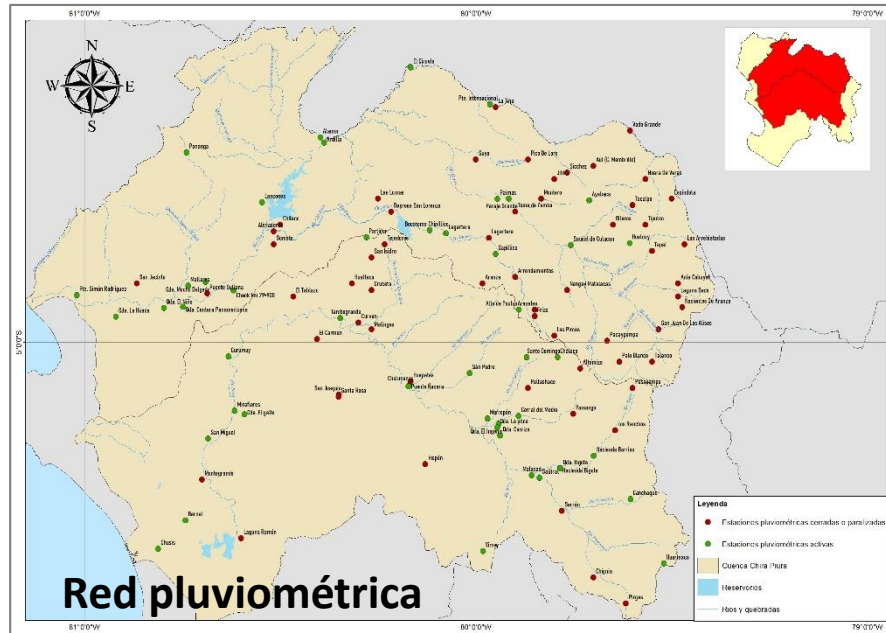
- Para asegurar el cumplimiento de los objetivos del proyecto es muy importante contar con una **base de datos hidrometeorológica sólida y de buena calidad**.

Para ello:

- Se realizaron **coordinaciones** con las principales entidades regionales y nacionales, como el SENAMHI, ANA -a través del Concejo de Recursos Hídricos de la Cuenca hidrográfica Chira Piura-, y PECHP, para la obtención de la información.
- Se realizaron las **visitas** de campo correspondientes a las estaciones pluviométricas e hidrométricas activas de las cuencas Chira y Piura.

# Aspectos desarrollados

- Conocer la red hidrometeorológica Chira – Piura y sus operadores
- Propuesta de guía de evaluación de redes hidrometeorológicas
- Evaluar la red Chira – Piura y proponer mejoras
- Definición de las estaciones que conformarán los modelos





# Conocimiento de la red hidrometeorológica Chira – Piura

## Visitas de la cuenca Piura



E. Puente Ñácara



E. Puente Tambogrande

# Visitas de la cuenca Chira



E. Puente Internacional  
Macará




E. Paraje Grande












E. Puente Venados



# Ficha para la evaluación de las estaciones

"MODELACIÓN HIDROLÓGICA DE LOS CAUDALES DE LOS RÍOS CHIRA Y PIURA: Evaluación de la red hidrometeorológica actual y elaboración de una herramienta de predicción"						
FICHA PARA LA EVALUACIÓN DE ESTACIONES PLUVIOMÉTRICAS						
I. DATOS GENERALES						
Nombre del evaluador	Jorge Alonso Peña Valdivia /Abad Paucar Antony Steevin/Juan Carlos Méndez Lalupu					
Fecha de evaluación	22/05/2019					
Hora de inicio/fin de evaluación	08:50 am - 09:10 am					
Nombre de la estación	Morropón					
Clasificación de estación	Climatológica					
Subclasificación de estación	Ordinaria					
Entidad responsable	SENAMHI					
Nombre del responsable de operación	Gloria Cordova Viuda de Terrones.					
Número de contacto del responsable	987947522					
Periodo de operación	-					
Horarios de lecturas	7 am ; 1:00 pm ; 07:00 pm					
Cuenca hidrográfica	Piura					
Ubicación política		Departamento	Provincia	Distrito	Localidad	
		Piura	Morropón	Morropón	Morropón	
Coordenadas		Geográficas		Altitud (msnm)		
		Latitud	Longitud	141		
		5°11'41.00"S	79°58'16.00"O			
		UTM		Datum		Zona 17S-WGS84
		Norte	Este			
		9425718.63 m S	614028.53 m E			
Referencias ubicación		Margen derecha de la carretera asfaltada, antes de entrar al distrito y dentro de los campos de cultivo				
II. EVALUACIÓN GENERAL						
Condición	Operativo			Inoperativo		
Estado de conservación	Bueno	Regular	Malo			
Periodo y responsable de mantenimiento y/o calibración	Mensualmente ; SENAMHI					
III. EVALUACIÓN ESPECÍFICA						
INSTRUMENTOS	Condición Operativa (O), Inoperativa (I)	Estado de conservación Bueno (B), Regular (R), Malo (M)	Tipo : Convencional (C), Automático(A).	Horarios de lectura	Observaciones : N(ninguna)	Fotografía
1. Pluviómetro convencional	O	B	C	Una vez al día	N	

INSSTRUMENTOS	Condición Operativa (0), Inoperativa (I)	Estado de conservación Bueno (B), Regular (R), Malo (M)	Tipo : Convencional (C), Automático(A).	Horarios de lectura	Observaciones : N(ninguna)	Fotografía
2. Sensor de precipitación 52203 (báscula oscilante)	0	B	A	-	N	
3. Pluviógrafo	0	B	C	-	N	
4. Tanque de evaporación	0	B	C	7am, 1 pm, 7 pm	N	
5. Heliógrafo	0	B	C	7 am - 7 pm	No se encontraba operaba operativa a la hora de la visita	
6. Caseta meteorológica						
6.1 Termómetro de máxima y mínima	0	B	C	7am, 1 pm, 7 pm *	N	
6.2 Psicrómetro	0	B	C	7am, 1 pm, 7 pm *	N	
7. Caja de protección QE9K						
7.1 Plataforma colectora de datos	0	B	A	-	N	
7.2 Sensor de temperatura del aire (TTEP)	0	B	A	-	N	
7.3 Sensor de humedad relativa del aire (THR)	0	B	A	-	N	

INSTRUMENTOS	Condición Operativa (O), Inoperativa (I)	Estado de conservación Bueno (B), Regular (R), Malo (M)	Tipo : Convencional (C), Automático(A).	Horarios de lectura	Observaciones : N(ninguna)	Fotografía
8. Sensor de velocidad del viento 05103	0	B	A	-	N	
9. Sistema de aterrizaje eléctrico (Pararrayos)	0	B	A	-	N	
10. Anemómetro de empuje(Veleta wild)	0	B	C	7 am, 1 pm, 7 pm	N	

#### IV. OBSERVACIONES

- El mantenimiento solo se realiza mensualmente por parte de SENAMHI
- La fuente de alimentación para la estación automática se realiza a través de panel solar PANLW

#### V. PANEL FOTOGRÁFICO



Foto 1. Estación Climatológica Ordinaria Morropon



Foto 2. Condiciones Pluviógrafo y Sensor de Precipitación



# Propuesta de guía de evaluación de redes hidrometeorológicas

## Contenido

### Propuesta de guía de evaluación de redes hidrometeorológicas




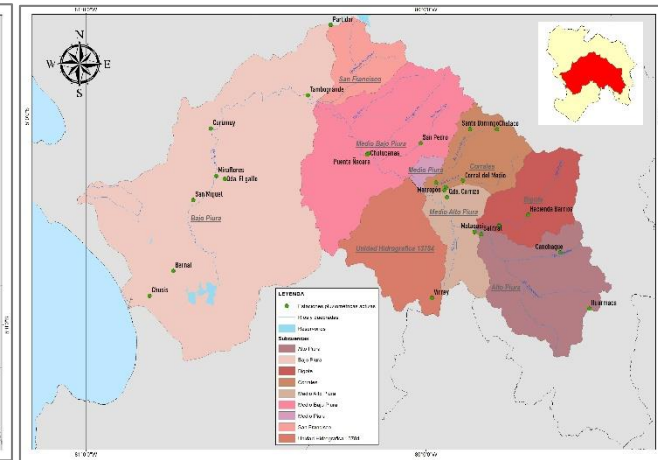
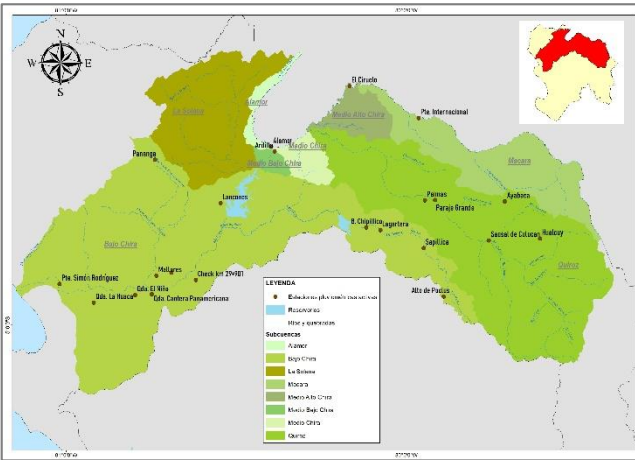
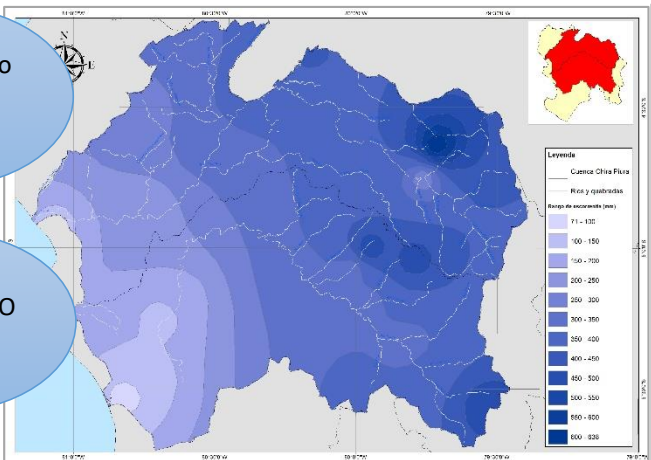
- 3.1 Alcance de la guía
- 3.2 Conceptos generales
- ▲ 3.3 Evaluación de redes existentes
  - ▲ 3.3.1 Distribución geográfica
    - 3.3.1.1 Estaciones climatológicas.
    - 3.3.1.2 Estaciones hidrológicas.
  - 3.3.2 Densidad poblacional
  - 3.3.3 Extensión y validez de registro
  - 3.3.4 Cobertura de zonas críticas
  - 3.3.5 Emplazamiento
  - 3.3.6 Estado y operación
  - 3.3.7 Accesibilidad, seguridad y utilidad
  - ▲ 3.3.8 Análisis matemático de la cobertura
    - 3.3.8.1 Método Kagan
    - 3.3.8.2 Método de ajuste de polinomios por mínimos cuadrados.
    - 3.3.8.3 Método de Karasiev
- ▲ 3.4 Rediseño de red
  - ▷ 3.4.1 Conceptos generales de diseño de redes
  - 3.4.2 Redes meteorológicas
  - 3.4.3 Redes hidrológicas




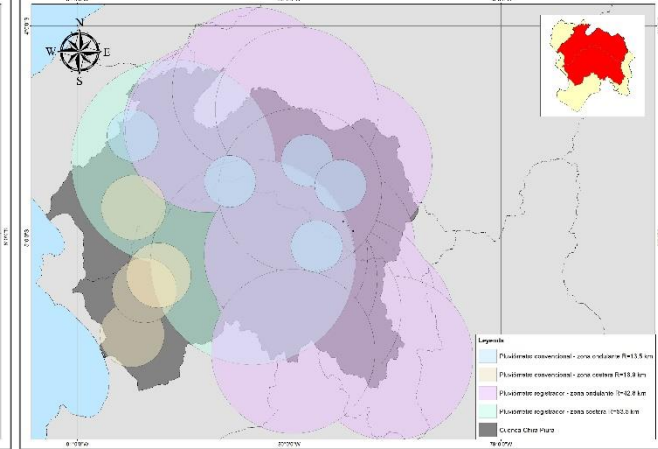


Registro pluviométrico de base de datos consistente

Producto grillado PISCO – SENAMHI 1986-2016



Error de medición	Criterio	Área (km <sup>2</sup> )	
		Cuenca Chira	Cuenca Piura
$\sigma_0 = 10\%$	Gradiente	1226	1273
	Correlación	12	2.5
	Representatividad	600	1000
	Área óptima	619	638
$\sigma_0 = 12\%$	N° de estaciones	18	18
	N° de puntos a implementar	3	9
	Gradiente	1766	1833
	Correlación	24	5
$\sigma_0 = 15\%$	Representatividad	600	1000
	Área óptima	895	919
	N° de estaciones	12	12
	N° de puntos a implementar	-	3
$\sigma_0 = 15\%$	Gradiente	2759	2864
	Correlación	59	13
	Representatividad	600	1000
	Área óptima	1409	1438
$\sigma_0 = 15\%$	N° de estaciones	8	8
	N° de puntos a implementar	-	-

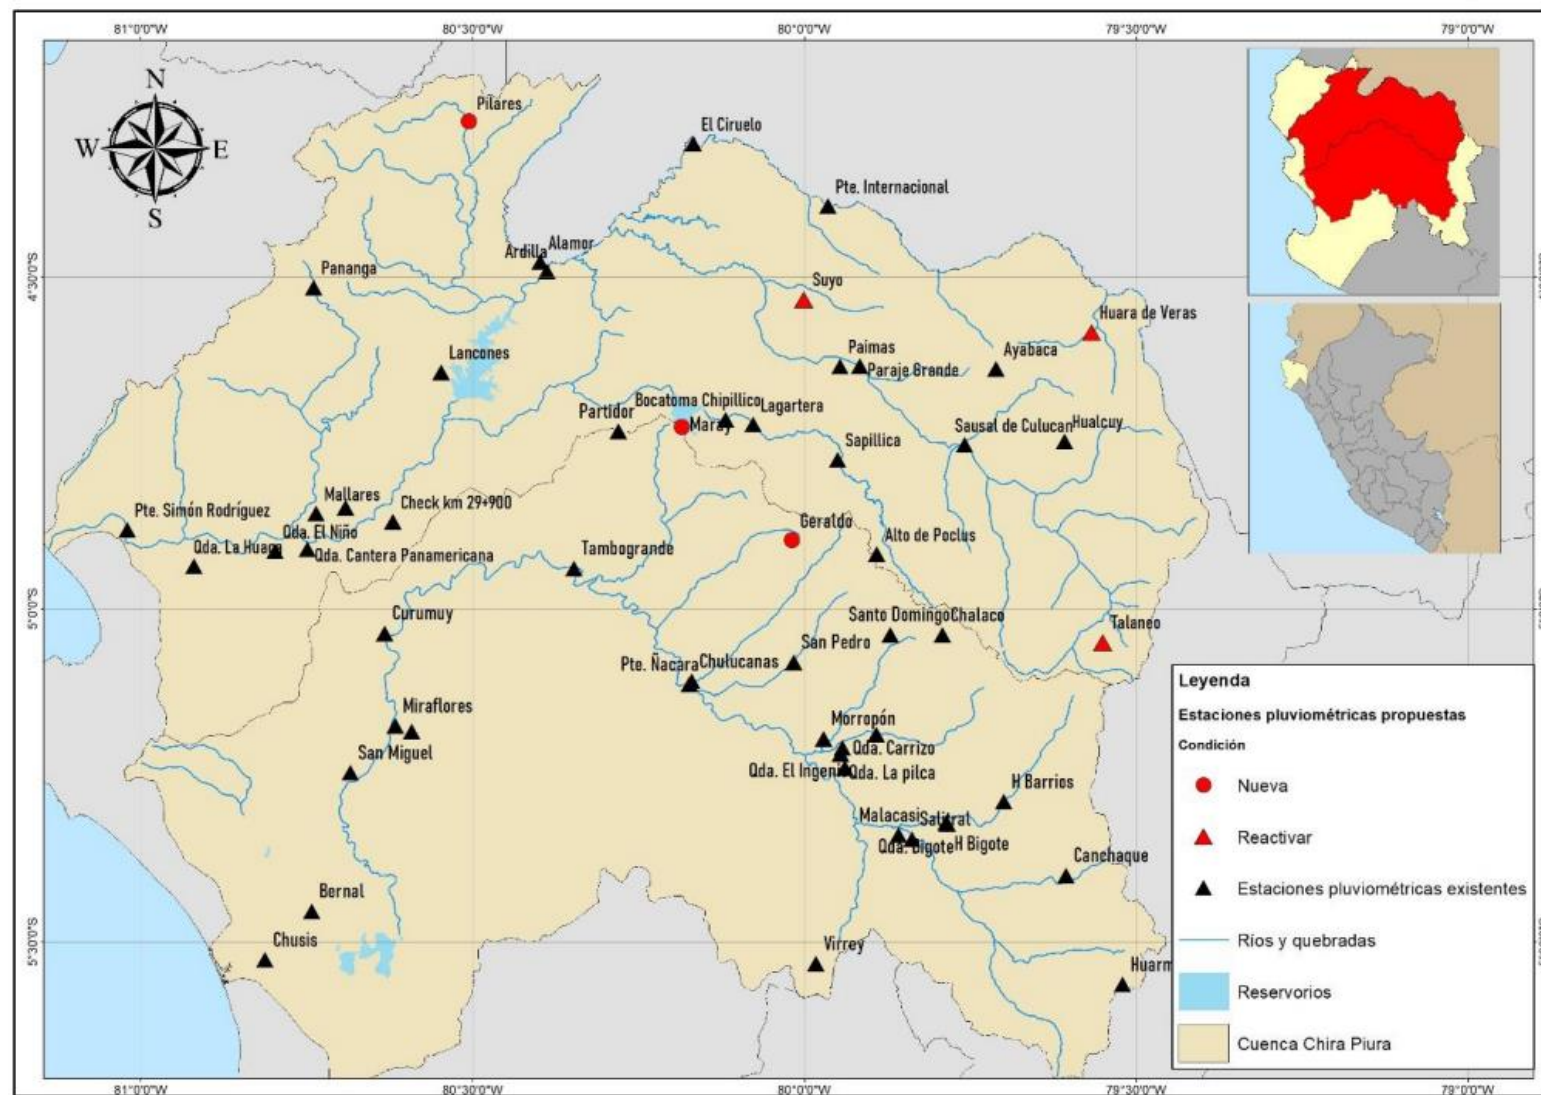


Rango de altitud	Superficie (km <sup>2</sup> )	Superficie (%)	N° de estaciones		Densidad km <sup>2</sup> /est
0-1000	16203.79	76%	40	83.33%	405
1000-2000	2939.29	14%	4	8.33%	735
2000-3000	1702.14	8%	3	6.25%	567
3000-4000	561.62	3%	1	2.08%	562
<b>TOTAL</b>	<b>21406.85</b>	<b>100%</b>	<b>48</b>	<b>100%</b>	<b>446</b>

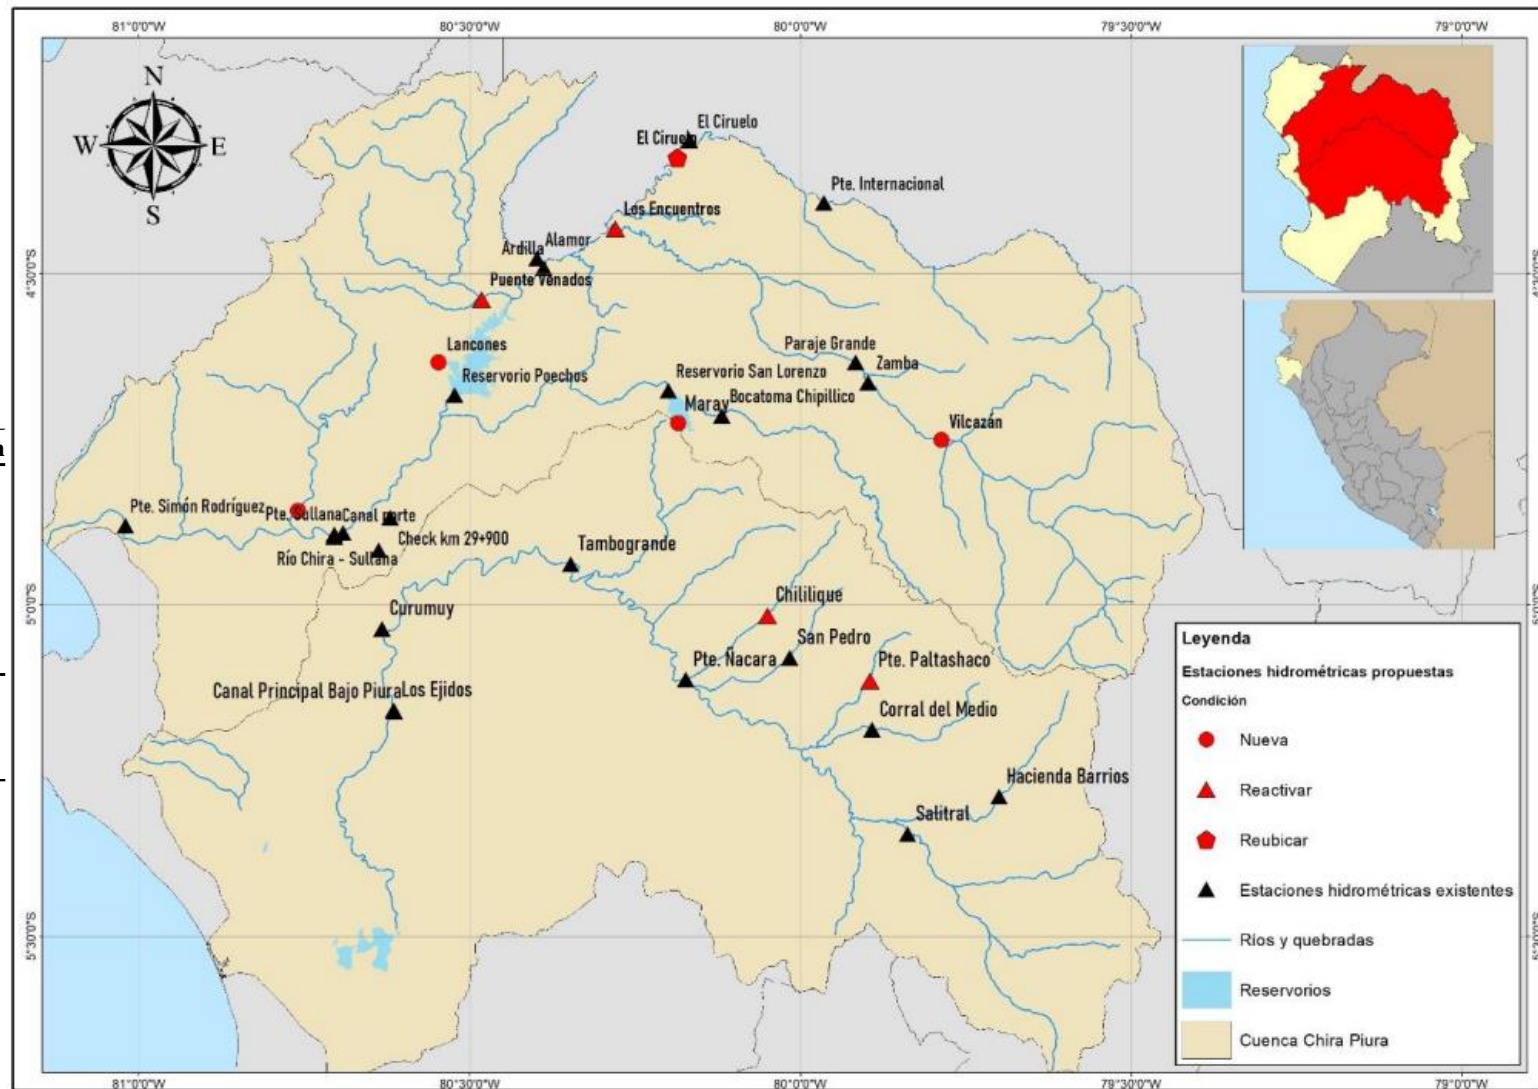


# Propuesta de mejoramiento de la red pluviométrica

Nombre	Altitud (m s.n.m.)	Condición
Huara de Veras	1275	Reactivar
Suyo	474	Reactivar
Talaneo	3021	Reactivar
Pilares	300	Nueva
Geraldo	1568	Nueva
Maray	294	Nueva



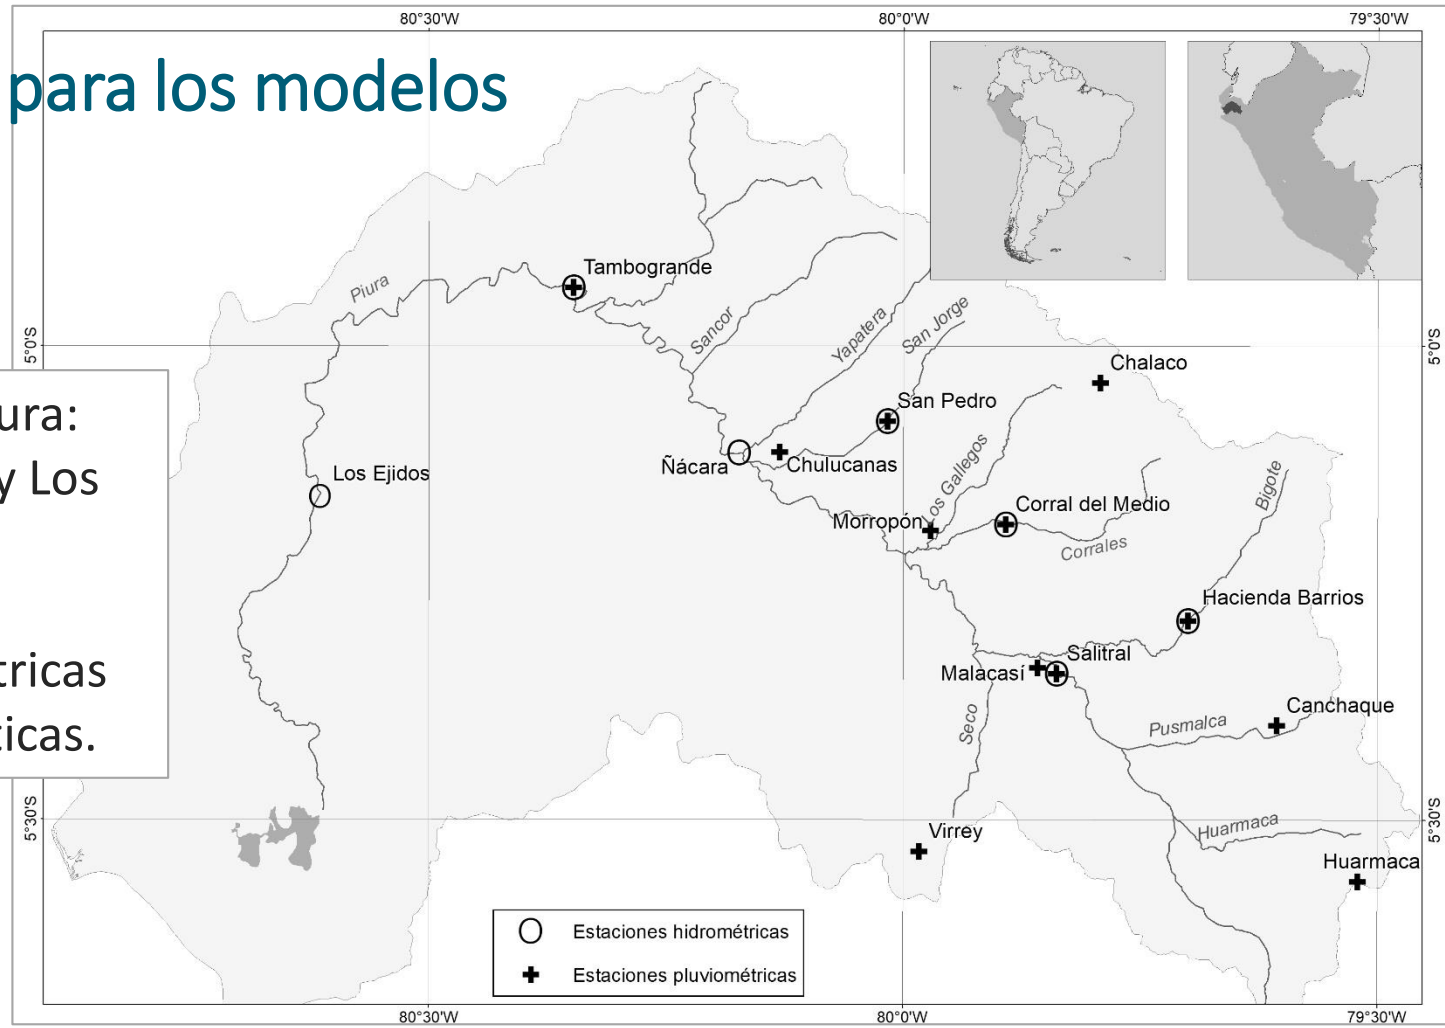
# Propuesta de mejoramiento de la red hidrométrica



Nombre	Cuenca	Río - quebrada	Condición
El Ciruelo	Chira	Río Macará	Reubicar
Puente Venados	Chira	Qda. La Solana	Reactivar
Los Encuentros	Chira	Río Quiroz	Reactivar
Samán	Chira	Río Samán	Nueva
Lancones	Chira	Qda. de Cóndor	Nueva
Vilcazán	Chira	Río Quiroz	Nueva
Maray	Piura	Qda. San Francisco	Nueva
Chililique	Piura	Río Yapatera	Reactivar
Puente Paltashaco	PIura	Río Gallega	Reactivar

# Definición de la red para los modelos

- Proyecto Especial Chira Piura: Caudal estaciones Ardilla y Los Ejidos.
- SENAMHI: Estaciones pluviométricas y hidrométricas de las estaciones automáticas.





*Gracias*



Proyecto  
**Concytec**  
**Banco Mundial**



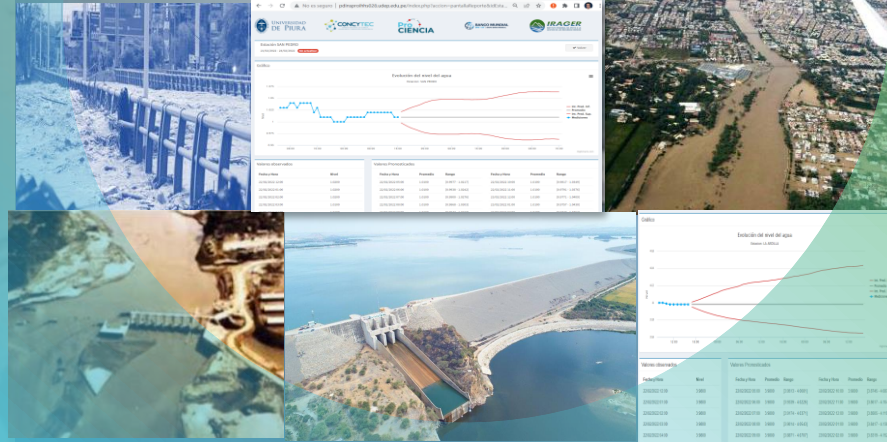
UNIVERSIDAD  
DE PIURA



**BANCO MUNDIAL**  
BIRF • AIF | GRUPO BANCO MUNDIAL

## Modelos de predicción de caudales

1. Modelos univariantes para el caudal horario, aplicado a las cuencas del río Chira y Piura
2. Modelos multivariantes para la predicción del caudal diario en la estación de Los Ejidos
3. Herramienta de predicción





# OBJETIVOS


Construir modelos de predicción para el nivel de agua (altura) horario y el caudal diario de un conjunto de estaciones en las cuencas de los ríos Chira y Piura

1



Estudio de literatura sobre predicción de caudales

2



Sistema de recolección de datos automatizada

3



Construcción de modelo estadísticos

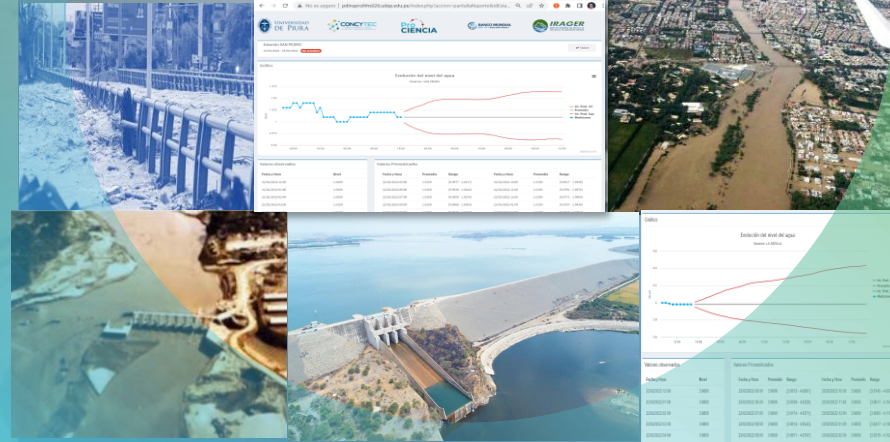
4



Implementación en una herramienta informática para el acceso a los resultados

Modelos univariantes para el nivel de agua horario, aplicado a las cuencas del río Chira y Piura.

Dr. Ismael Sánchez



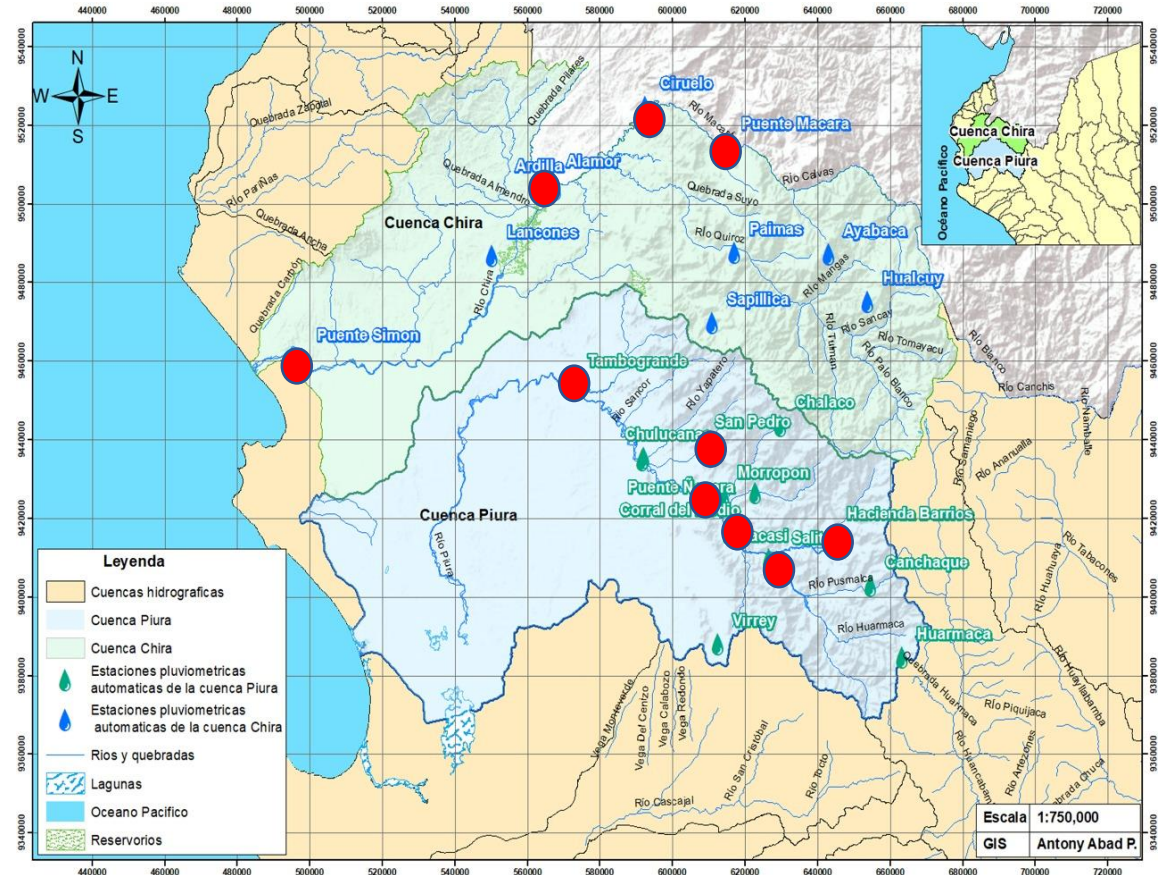
El Senamhi proporciona información horaria de un conjunto de estaciones hidrometeorológicas automáticas:

## Río Chira

ALAMOR  
EL CIRUELO  
LA ARDILLA  
PUENTE MACARA  
PUENTE SIMON RODRIGUEZ

## Río Piura

CORRAL DEL MEDIO  
HACIENDA BARRIOS  
PUENTE ÑACARA  
SALITRAL EHA  
SAN PEDRO  
TAMBOGRANDE





# Modelos univariantes para predecir el nivel horario en un río

También se tiene información de precipitaciones.  
Sin embargo, para realizar predicciones horarias a los próximos dos días, los mejores resultados vienen de *modelos univariantes no-lineales*.

Nivel de un río en la hora  $t+h$

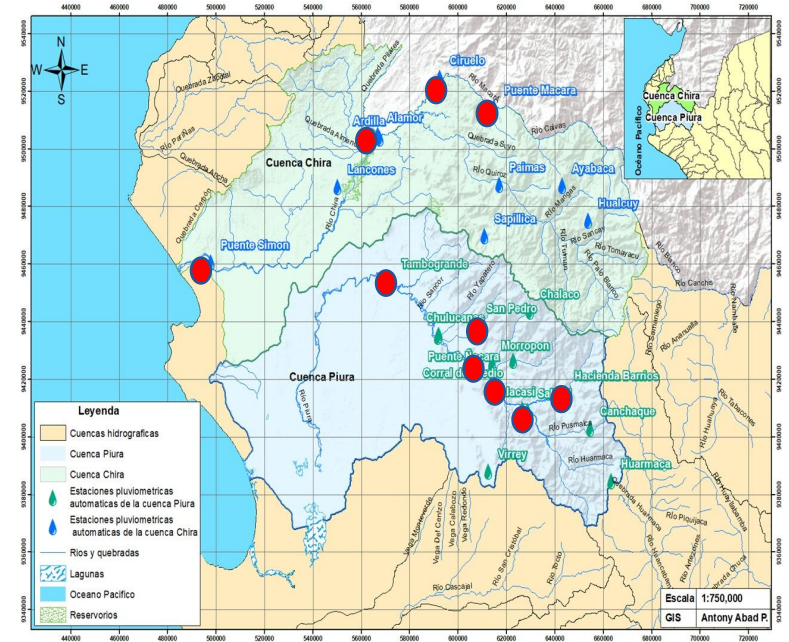



$y_{t+h}$

Predicción del nivel para  $t+h$  con información disponible en  $t$



$\hat{y}_{t+h|t}$






- La fuerte estacionalidad, y las propiedades hidrológicas hacen que se vean patrones similares que se repiten.
- La estacionalidad no tiene una regularidad exacta.

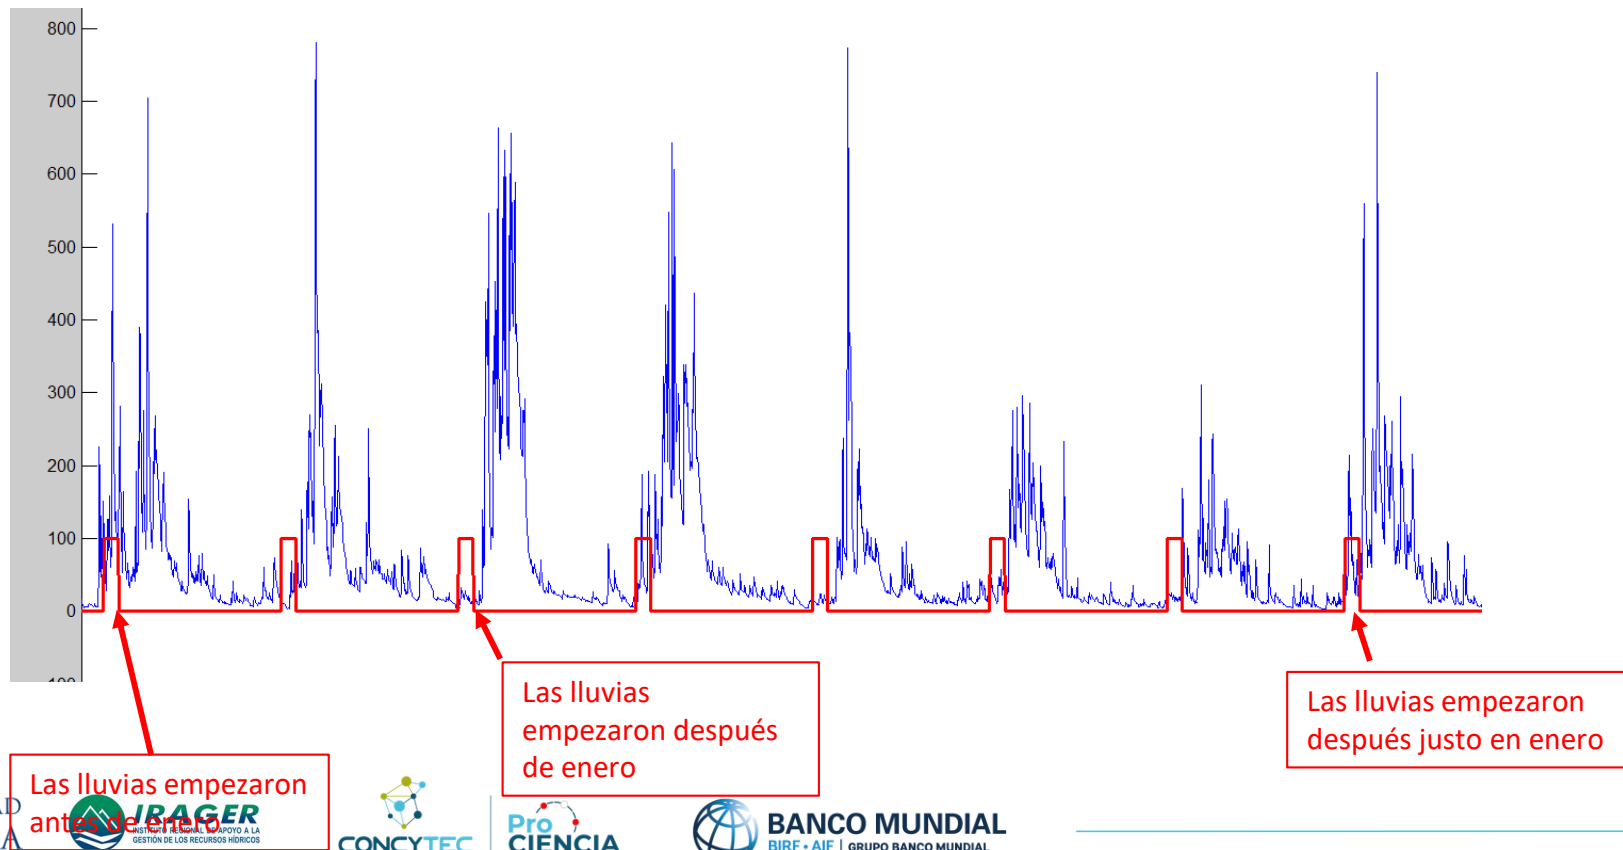
**La estacionalidad no tiene una regularidad exacta.**

Aunque las lluvias son un fenómeno fuertemente estacional, los periodos de lluvias no se producen exactamente en los mismos intervalos de año.






Aunque las lluvias son un fenómeno fuertemente estacional, los periodos de lluvias no se producen exactamente en los mismos intervalos de año.




**Pero sí hay patrones que se repiten muy frecuentemente.**

Cuando termina un periodo de lluvias, el caudal no cae drásticamente, sino de forma suave por el fenómeno de escorrentía




**Pero sí hay patrones que se repiten muy frecuentemente.**

Cuando termina un periodo de lluvias, el caudal no cae drásticamente, sino de forma suave por el fenómeno de escorrentía




Pero sí hay patrones que se repiten muy frecuentemente.

Cuando inicia un periodo con lluvias fuertes, el caudal aumenta con una pendiente pronunciada muy similar




Pero sí hay patrones que se repiten muy frecuentemente.

Muchas épocas de bajo caudal, en invierno, son muy similares







- Algunos analistas que hacen predicciones basadas en patrones, hacen un 'catálogo' de patrones
- En nuestro caso, hay mucha variabilidad, usamos un enfoque más flexible
- La idea es que es muy probable que lo que haya sucedido en los últimos días haya ocurrido en muchas otras ocasiones.
- Si en el pasado ocurrió algo similar, lo que ocurra en los próximos días será también similar a lo que ocurrió aquel pasado



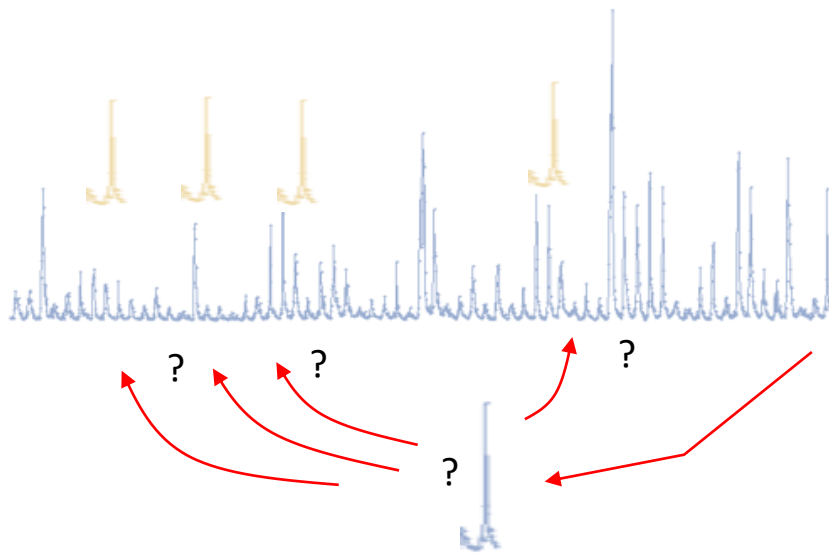
$\times 10^4$




Buscamos en el pasado secuencias de datos que sean muy similares a los últimos D datos observados.

## Niveles

3.93
3.94
3.95
3.96
3.96
3.97
3.98
3.97
3.97
3.97
3.96
3.95
3.95
3.94
3.94
3.94
3.94
3.93
3.92
3.91
3.91
3.91
3.9
3.9
3.89
3.89
3.89






### Niveles

3.93
3.94
3.95
3.96
3.96
3.97
3.98
3.97
3.97
3.97
3.97
3.96
3.95
3.95
3.94
3.94
3.94
3.94
3.94
3.93
3.92
3.91
3.91
3.9
3.9
3.89
3.89
3.89

### Patrones históricos de longitud 3 para predecir a h=2

3.93	3.94	3.95	3.96	3.96
3.94	3.95	3.96	3.96	3.97
3.95	3.96	3.96	3.97	3.98
3.96	3.96	3.97	3.98	3.97
3.96	3.97	3.98	3.97	3.97
3.97	3.98	3.97	3.97	3.97
3.98	3.97	3.97	3.97	3.96
3.97	3.97	3.97	3.96	3.95
3.97	3.97	3.96	3.95	3.95
3.97	3.96	3.95	3.95	3.94
3.96	3.95	3.95	3.94	3.94
3.95	3.95	3.94	3.94	3.94
3.95	3.94	3.94	3.94	3.94
3.94	3.94	3.94	3.94	3.93
3.94	3.94	3.94	3.93	3.92
3.94	3.94	3.93	3.92	3.91
3.94	3.93	3.92	3.91	3.91
3.93	3.92	3.91	3.91	3.91
3.92	3.91	3.91	3.91	3.9
3.91	3.91	3.91	3.9	3.9
3.91	3.91	3.9	3.9	3.89
3.91	3.9	3.9	3.89	3.89
3.9	3.9	3.89	3.89	3.89




### Niveles

3.93
3.94
3.95
3.96
3.96
3.97
3.98
3.97
3.97
3.97
3.97
3.96
3.95
3.95
3.94
3.94
3.94
3.94
3.94
3.93
3.92
3.91
3.91
3.9
3.9
3.89
3.89
3.89

### Patrones históricos de longitud 3 para predecir a h=2

3.93	3.94	3.95	3.96	3.96
3.94	3.95	3.96	3.96	3.97
3.95	3.96	3.96	3.97	3.98
3.96	3.96	3.97	3.98	3.97
3.96	3.97	3.98	3.97	3.97
3.97	3.98	3.97	3.97	3.97
3.98	3.97	3.97	3.97	3.96
3.97	3.97	3.97	3.96	3.95
3.97	3.97	3.96	3.95	3.95
3.97	3.96	3.95	3.95	3.94
3.96	3.95	3.95	3.94	3.94
3.95	3.95	3.94	3.94	3.94
3.95	3.94	3.94	3.94	3.94
3.94	3.94	3.94	3.94	3.93
3.94	3.94	3.94	3.93	3.92
3.94	3.94	3.93	3.92	3.91
3.94	3.93	3.92	3.91	3.91
3.93	3.92	3.91	3.91	3.91
3.92	3.91	3.91	3.91	3.9
3.91	3.91	3.91	3.9	3.9
3.91	3.91	3.9	3.9	3.89
3.91	3.9	3.9	3.89	3.89
3.9	3.9	3.89	3.89	3.89



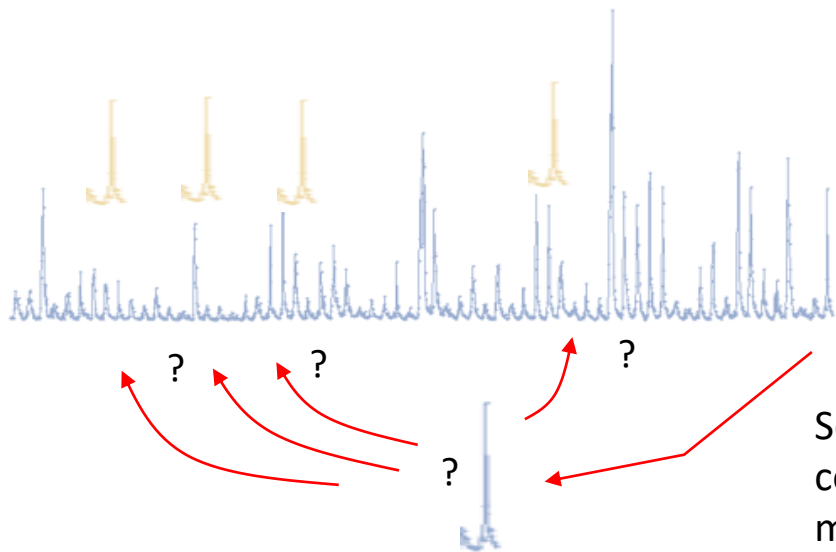


### Niveles

3.93
3.94
3.95
3.96
3.96
3.97
3.98
3.97
3.97
3.97
3.97
3.96
3.95
3.95
3.94
3.94
3.94
3.94
3.94
3.93
3.92
3.91
3.91
3.91
3.9
3.9
3.89
3.89
3.89

### Patrones históricos de longitud 3 para predecir a h=2



3.93	3.94	3.95	3.96	3.96
3.94	3.95	3.96	3.96	3.97
3.95	3.96	3.96	3.97	3.98
3.96	3.96	3.97	3.98	3.97
3.96	3.97	3.98	3.97	3.97
3.97	3.98	3.97	3.97	3.97
3.98	3.97	3.97	3.97	3.96
3.97	3.97	3.97	3.96	3.95
3.97	3.97	3.96	3.95	3.95
3.97	3.96	3.95	3.95	3.94
3.96	3.95	3.95	3.94	3.94
3.95	3.95	3.94	3.94	3.94
3.95	3.94	3.94	3.94	3.94
3.94	3.94	3.94	3.94	3.93
3.94	3.94	3.94	3.93	3.92
3.94	3.94	3.93	3.92	3.91
3.94	3.93	3.92	3.91	3.91
3.93	3.92	3.91	3.91	3.91
3.92	3.91	3.91	3.91	3.9
3.91	3.91	3.91	3.9	3.9
3.91	3.91	3.9	3.9	3.89
3.91	3.9	3.9	3.89	3.89
3.9	3.9	3.89	3.89	3.89



Se identifican las más cercanas con una medida de distancia vectorial

Patrones históricos de longitud 3 para predecir a  $h=2$

3.93	3.94	3.95	3.96	3.96
3.94	3.95	3.96	3.96	3.97
3.95	3.96	3.96	3.97	3.98
→ 3.96	→ 3.96	3.97	3.98	3.97
→ 3.96	3.97	3.98	3.97	3.97
3.97	3.98	3.97	3.97	3.97
3.98	3.97	3.97	3.97	3.96
3.97	3.97	3.97	3.96	3.95
3.97	3.97	3.96	3.95	3.95
3.97	3.96	3.95	3.95	3.94
→ 3.96	→ 3.95	→ 3.95	3.94	3.94
3.95	3.95	3.94	3.94	3.94
3.95	3.94	3.94	3.94	3.94
3.94	3.94	3.94	3.94	3.93
3.94	3.94	3.94	3.93	3.92
3.94	3.94	3.93	3.92	3.91
3.94	3.93	3.92	3.91	3.91
3.93	3.92	3.91	3.91	3.91
→ 3.92	→ 3.91	→ 3.91	3.91	3.9
3.91	3.91	3.91	3.9	3.9
3.91	3.91	3.9	3.9	3.89
3.91	3.9	3.9	3.89	3.89
3.9	3.9	3.89	3.89	3.89





La predicción se realiza a partir de los valores que sucedieron después de dichas secuencias

3.93	3.94	3.95	3.96	3.96
3.94	3.95	3.96	3.96	3.97
3.95	3.96	3.96	3.97	3.98
→	3.96	3.96	3.97	3.98
→	3.96	3.97	3.98	3.97
	3.97	3.98	3.97	3.97
	3.98	3.97	3.97	3.96
	3.97	3.97	3.97	3.96
	3.97	3.97	3.96	3.95
	3.97	3.96	3.95	3.95
	3.97	3.96	3.95	3.95
→	3.96	3.95	3.95	3.94
	3.95	3.95	3.94	3.94
	3.95	3.94	3.94	3.94
	3.94	3.94	3.94	3.94
	3.94	3.94	3.94	3.93
	3.94	3.94	3.94	3.93
	3.94	3.94	3.93	3.92
	3.94	3.93	3.92	3.91
	3.94	3.93	3.92	3.91
	3.93	3.92	3.91	3.91
→	3.92	3.91	3.91	3.91
	3.91	3.91	3.91	3.9
	3.91	3.91	3.9	3.9
	3.91	3.9	3.9	3.89
	3.9	3.9	3.89	3.89



UNIVERSIDAD DE PIURA





Se consigue tanto una senda de predicciones como intervalos de incertidumbre

## Comparación de los modelos

- Para comparar los modelos se usan los siguientes estadísticos.

$$MAE(h) = \frac{\sum_{t=1}^n |\hat{y}_{t+h|t} - \bar{y}_{t+h}|}{n},$$

Error absoluto medio

$$RMSE(h) = \sqrt{\frac{\sum_{t=1}^n (\hat{y}_{t+h|t} - \bar{y}_{t+h})^2}{n}}$$

Error cuadrático medio

$$R_p^2(h) = 1 - \frac{\sum_{t=1}^n (\hat{y}_{t+h|t} - \bar{y}_{t+h})^2}{nS_y^2}$$


R<sup>2</sup> predictivo (NSE)



Se ha analizado la influencia de la medida de distancia  
La mejor es la Euclídea


DISTANCIA	RMSE	MAE	R2
EUCLIDEAN	<b>51.52</b>	<b>19.17</b>	<b>0.888</b>
MANHATAN	51.85	19.34	0.886
MINKOWSKI	51.85	19.34	0.886

En cada instante, en cada ejercicio de predicción se busca la longitud óptima



También se comparan diversos modelos alternativos, que pueden ser mejor en cada instante:

- Modelo autorregresivo
- Media ponderada
- Mediana



## Modelos multivariantes para predecir el caudal en el río Piura.

Dra. Isabel González



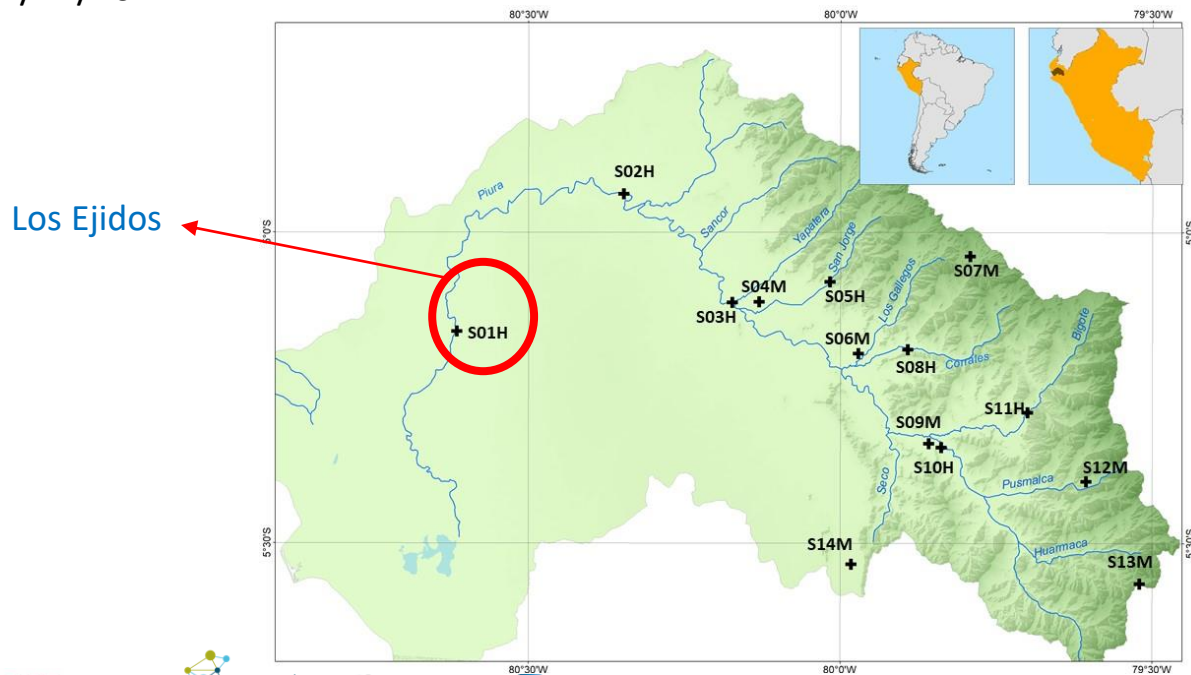
## Objetivo

- Proponer y comparar modelos estadísticos para predecir [el caudal promedio diario](#) en “Los Ejidos”.
- Implementar el modelo más eficiente en una interfaz gráfica.
- Se usarán modelos univariantes y multivariantes.



## Datos disponibles

- Se agradece al [Servicio Nacional de Meteorología e Hidrología \(SENAMHI\)](#) y al [Proyecto Especial Chira Piura \(PECHP\)](#) por facilitar la información necesaria para el desarrollo de los modelos. Se ha considerado el periodo 01/01/2015 a 31/12/2021.



## Datos proporcionados por el PECHP

- **Caudal promedio diario** en la estación “Los Ejidos”.
- La información se recibe mediante email todos los días a las 7am (no es una información que se pueda leer de manera automática)

## Datos proporcionados por SENAMHI

- **Datos hidrometeorológicos horarios** que se pueden leer de forma automática desde su servidor.
- 13 estaciones meteorológicas (precipitaciones): Tambogrande, Ñácara, Chulucanas, San Pedro, Morropón, Chalaco, Corral del Medio, Virrey, Malacasí, Salitral, Hacienda Barrios, Canchaque y Huarmaca.
- 6 estaciones hidrológicas (niveles): Tambogrande, Ñácara, San Pedro, Corral del Medio, Salitral y Hacienda Barrios.

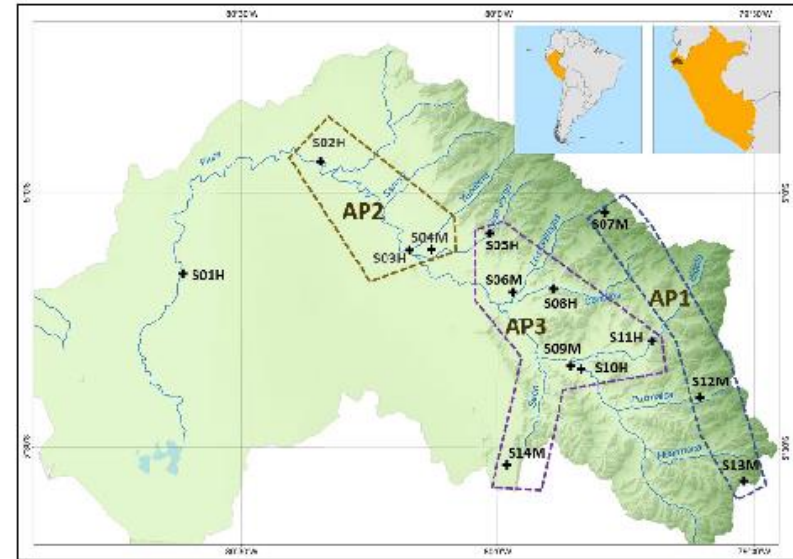

## Tratamiento inicial de los datos

- La medición de las precipitaciones y niveles presenta en varios momentos errores de medición (por parada de equipos u otras causas). Por ello, hay muchos valores “perdidos” (NaN) .

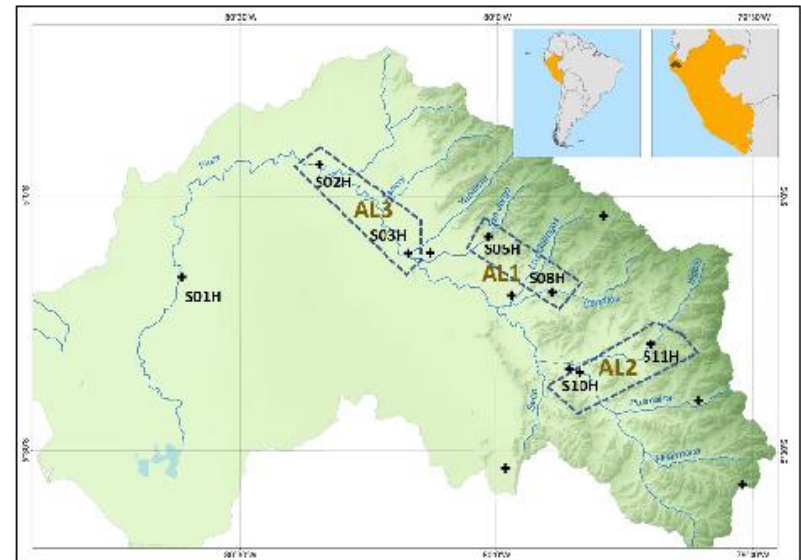

Precipitation variables: % of missing values						
P02	P03	P04	P05	P06	P07	P08
11.2%	43.5%	7.4%	0.6%	8.9%	7.2%	51.7%
P09	P10	P11	P12	P13	P14	□
6.6%	5.4%	0.5%	4.4%	3.7%	3.3%	□
Water level variables: % of missing values						
L02	L03	L05	L08	L10	L11	□
37.0%	65.6%	15.8%	69.2%	8.8%	3.1%	□

- Las variables de precipitaciones y niveles presentan correlación. Se pudo identificar clusters mediante un análisis de conglomerados jerárquico.

### Precipitaciones en 3 grupos: 3 variables explicativas AP1, AP2, AP3



## Niveles en 3 grupos: 3 variables explicativas AL1, AL2, AL3



Station		Variables			Elevation
Label	Type	Actual name	Water level	Precip (mm)	(mamsl)
S01H	Met.	Ejidos	S01 (m <sup>3</sup> /s)		25
S02H	Hydromet.	Tambogrande	L02 (m)	P02	66
S03H	Hydromet	Ñácara	L03 (m)	P03	91
S04M	Met.	Chulucanas		P04	89
S05H	Hydromet.	San Pedro	L05 (m)	P05	240
S06M	Met.	Morropón		P06	128
S07M	Met.	Chalaco		P07	2290
S08H	Hydromet.	Corral del Medio	L08 (m)	P08	212
S09M	Met.	Malacasí		P09	153
S10H	Hydromet.	Salitral	L10 (m)	P10	209
S11H	Hydromet.	Hacienda Barrios	L11 (m)	P11	303
S12M	Met.	Canchaque		P12	1150
S13M	Met.	Huarmaca		P13	2171
S14M	Met.	El Virrey		P14	208



- Cada variable AP1 a AL3 se obtiene como el promedio de las variables incluidas en su cluster.
- Si hay un valor NaN en alguna de las variables del cluster, esa variable no se usa en el promedio. Solo si todas las variables del cluster tienen valor NaN la variable agrupada será también un NaN (de ese modo esta agrupación también permite disminuir considerablemente los valores NaN iniciales)
- La variable caudal se expresa en logaritmos.
- Las variables se han normalizado previamente a  $[0,1]$ .
- Como los datos del caudal en Los Ejidos son diarios y las variables agrupadas son horarias, se pasan a diarias haciendo el promedio de un período de 24 horas (de 7:00am a 6:00am del día siguiente).
- El horizonte de predicción será de 24 y 48 horas.

## Modelos univariantes

- Se usan modelos autorregresivos de media móvil: ARMA.
- Las variables explicativas son el caudal en los Ejidos, desfasado un cierto periodo (se predice  $t + h$ , entonces se usa los caudales en  $t, t - d, t - 2d$ ).

$$y_t = c + \phi_1 y_{t-1} + \dots + \phi_p y_{t-p} + a_t - \theta a_{t-1} - \dots - \theta_q a_{t-q}$$

## Modelos multivariantes

- Se usan modelos dinámicos de regresión donde las variables explicativas son: los valores retardados del caudal en los Ejidos, precipitaciones y niveles agrupados (AP1 a AL3) así como sus valores retardados.

$$y_i = \beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \dots + \beta_j x_{ji} + u_i$$

## Estimación de los parámetros del modelo

- En ambos tipos de modelos: univariantes y multivariantes se hará una estimación por:
  - ✓ Mínimos cuadrados ordinarios (OLS): minimizar la suma de los cuadrados de los residuos.
  - ✓ Regresión local (LR) : permite construir modelos no lineales asignando pesos a las observaciones. Estos pesos son obtenidos mediante funciones Kernel (p.e kernel Gaussiano), las cuales tienen un valor  $b$ , denominado “ancho de banda” que permite asignar una zona “local” y dar más peso a las observaciones más próximas. En este caso se ha elegido  $b = 2s_j$ .

$$\sum_i w_{it} \left( \bar{y}_i - \beta_0 - \sum_{j=1}^J \beta_j (\bar{x}_{ji} - \bar{x}_{jt}) \right)^2$$

$$w_{it} = \prod_{j=1}^J b_j^{-1} K_j \left( \frac{\bar{x}_{jt} - \bar{x}_{ji}}{b_j} \right)$$

## Comparación de los modelos

- Para comparar los modelos se usan los siguientes estadísticos. Todos son calculados fuera de la muestra mediante validación cruzada (cross validation, CV).

$$MAE(h) = \frac{\sum_{t=1}^n |\hat{y}_{t+h|t} - \bar{y}_{t+h}|}{n},$$

Error absoluto medio

$$RMSE(h) = \sqrt{\frac{\sum_{t=1}^n (\hat{y}_{t+h|t} - \bar{y}_{t+h})^2}{n}}$$

Error cuadrático medio


$$R_p^2(h) = 1 - \frac{\sum_{t=1}^n (\hat{y}_{t+h|t} - \bar{y}_{t+h})^2}{nS_y^2}$$

R<sup>2</sup> (NSE)

## Modelos ARMA


		$h = d$				$h = 2d$		
	Model	Method	MAE	RMSE	$R_P^2$	MAE	RMSE	$R_P^2$
M <sub>11</sub>	ARMA(1,0)	OLS	12.7	53.6	0.731	20.6	83.2	0.353
		LLR	11.8	51.9	0.748	18.7	79.3	0.412
M <sub>12</sub>	ARMA(1,1)	OLS	12.6	53.2	0.735	20.5	83.3	0.351
		LLR	12.1	51.5	0.759	19.4	78.7	0.421
M <sub>13</sub>	ARMA(2,0)	OLS	13.3	56.0	0.707	21.0	83.0	0.356
		LLR	12.6	53.1	0.736	20.3	81.0	0.387
M <sub>14</sub>	ARMA(2,1)	OLS	13.1	55.4	0.713	20.9	83.8	0.344
		LLR	12.7	53.7	0.737	20.2	82.2	0.369
M <sub>15</sub>	ARMA(3,1)	OLS	13.2	53.0	0.737	21.0	80.2	0.399
		LLR	12.4	49.8	0.768	19.9	77.7	0.435
M <sub>16</sub>	ARMA(3,2)	OLS	13.2	53.0	0.737	21.3	80.3	0.398
		LLR	14.5	70.2	0.540	20.6	78.0	0.431





## Modelos multivariantes

Model	Variables in $\bar{x}_t$ to predict $\bar{y}_{t+h}$	Method	$h = d$			$h = 2d$		
			MAE	RMSE	$R_P^2$	MAE	RMSE	$R_P^2$
M <sub>21</sub>	AL1 to AL3 at $t, t-d, t-2d$ and AP1 to AP3 at $t, t-d, t-2d$	OLS	32.0	84.1	0.339	35.0	85.5	0.316
		LLR	27.3	70.6	0.534	28.6	76.5	0.537
M <sub>22</sub>	$\bar{y}_t, \bar{y}_{t-d}$ and AL1 to AL3 at $t, t-d, t-2d$ and AP1 to AP3 at $t, t-d, t-2d$	OLS	11.3	65.8	0.596	16.6	94.4	0.170
		LLR	9.2	38.1	0.864	13.1	55.3	0.710
M <sub>23</sub>	$\bar{y}_t, \bar{y}_{t-d}$ and AP1 to AP3 at $t, t-d, t-2d$	OLS	11.7	61.2	0.650	17.1	94.4	0.167
		LLR	9.7	37.5	0.869	13.8	53.6	0.731
M <sub>24</sub>	$\bar{y}_t, \bar{y}_{t-d}$ and AL1 to AL3 at $t, t-d, t-2d$	OLS	8.5	28.2	0.926	13.2	45.4	0.807
		LLR	8.5	28.3	0.930	13.1	44.9	0.812
M <sub>25</sub>	$\bar{y}_t, \bar{y}_{t-d}$ and AL1 to AL3 at $t, t-d, t-2d$ and AP3 at $t, t-d$	OLS	8.3	27.0	0.930	13.1	53.2	0.735
		LLR	8.2	27.3	0.932	12.9	52.9	0.738
M <sub>26</sub>	$\bar{y}_t, \bar{y}_{t-d}$ and AL1 to AL3 at $t, t-d, t-2d$ and AP3 at $t$	OLS	8.3	27.5	0.925	11.7	40.9	0.844
		LLR	8.2	27.3	0.929	11.6	40.5	0.847




## Conclusiones

- Los modelos estadísticos propuestos: basados en información hidrometeorológica tienen una buena capacidad de predicción; de modo que pueden ser usados en una herramienta para predecir el caudal en Los Ejidos.
- En cuanto a las variables más significativas están los caudales retardados y los niveles. En el caso de las precipitaciones, solo un grupo de ellas aportan información significativa para predecir el caudal.
- Los modelos no paramétricos (LLR) son los que permiten obtener predicciones más precisas.

## Estimación probabilística

- Se estima un intervalo de predicción con un nivel de confianza del 90% para cada  $\hat{y}_i$ .
- Para cada predicción  $\hat{y}_i$  se tiene un conjunto de  $n$  residuos.
- Se estima la función de probabilidad de los residuos y se calcula su varianza. Para conseguir homocedasticidad de los residuos se ha hecho el análisis con la variable  $y = \log(\text{caudal})$ .
- Por tanto, se obtiene:  $y_i \sim N(\hat{y}_i, s_i^2)$ , y a partir de aquí se obtiene el intervalo de predicción que puede ser expresado en términos de caudales (deshaciendo el log).

# Difusión científica



Latin American and Caribbean Consortium of Engineering Institutions

18<sup>th</sup> LACCEI International Multi-Conference for Engineering, Education and Technology

“Engineering, Integration, and Alliances for a Sustainable Development”

“Hemispheric Cooperation for Competitiveness and Prosperity on a Knowledge-Based Economy”

The OAS Summit of Engineering for the Americas



The LACCEI 2020 Technical Committee certifies the presentation of the **FULL PAPER**:

**PRONÓSTICO DE CAUDALES DEL RÍO PIURA CALIBRADO CON EL NIÑO COSTERO 2017**


**FP # 276**

MARINA FARIAS DE REYES (PE)

AMANDA OLIVARES (PE)

DANIEL NEYRA (PE)

ISABEL GONZALEZ FARIAS (PE)



## Journal of Hydrology

**Daily streamflow forecasting using clusters of hydrometeorological information in a basin with a high seasonal component: The case of the Piura river**

--Manuscript Draft--

Manuscript Number:	HYDROL46214
Article Type:	Research paper
Keywords:	Discharge forecast; streamflow forecasting; local regression; non-linear regression; non-supervised clustering
Corresponding Author:	Isabel González Farias, Ph.D Universidad de Piura Facultad de Ingeniería Piura, Piura PERU
First Author:	Isabel González Farias, Ph.D



UNIVERSIDAD  
DE PIURA







Proyecto Concytec – financiado por el Banco Mundial **“Mejoramiento y Ampliación de los Servicios del Sistema Nacional de Ciencia Tecnología e Innovación Tecnológica”** a través de su unidad ejecutora ProCiencia.

Subproyecto: **“Modelación hidrológica de los caudales de los ríos Chira y Piura: evaluación de la red hidrometeorológica actual y elaboración de una herramienta de predicción”**

Se agradece a ProCiencia por el financiamiento brindado; asimismo, al Servicio Nacional de Meteorología e Hidrología y al Proyecto Especial Chira Piura, por la información y las facilidades para la conformación de la base de datos hidrometeorológica.



## La aplicación informática

Dr. Ismael Sánchez





UNIVERSIDAD  
DE PIURA



## PREDICCIÓN HIDROLÓGICA EN LAS CUENCAS CHIRA Y PIURA

Inicia sesión para empezar ...



Sign In



UNIVERSIDAD  
DE PIURA



Email del servidor  
7:00 am Envío  
automático del archivo  
del PECH

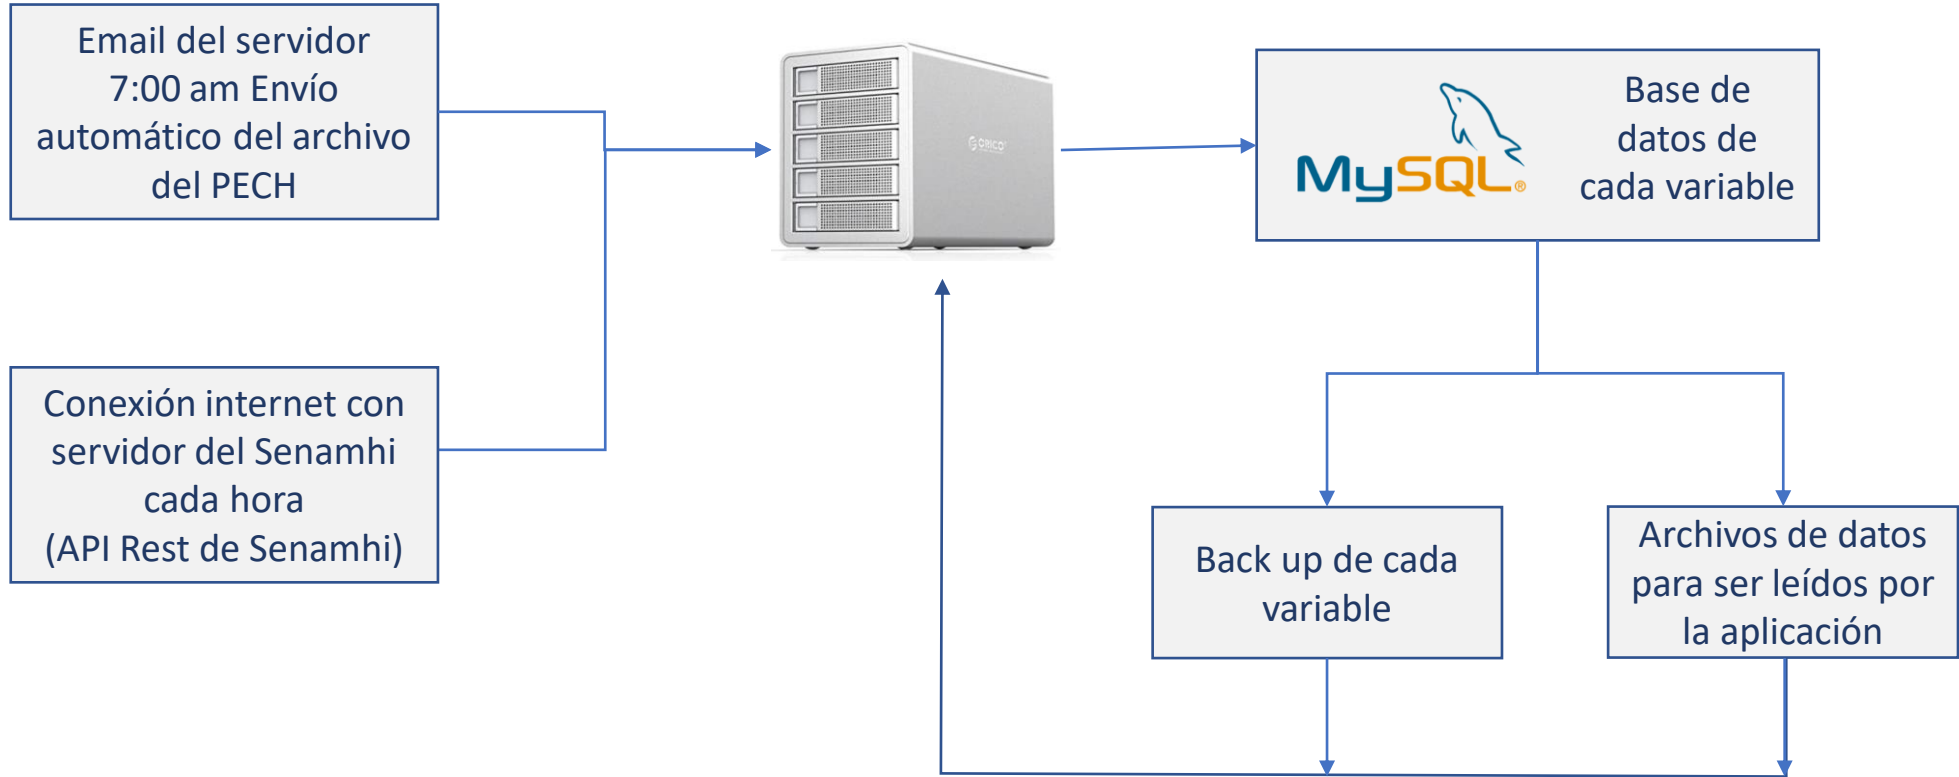
Conexión internet con  
servidor del Senamhi  
cada hora  
(API Rest de Senamhi)

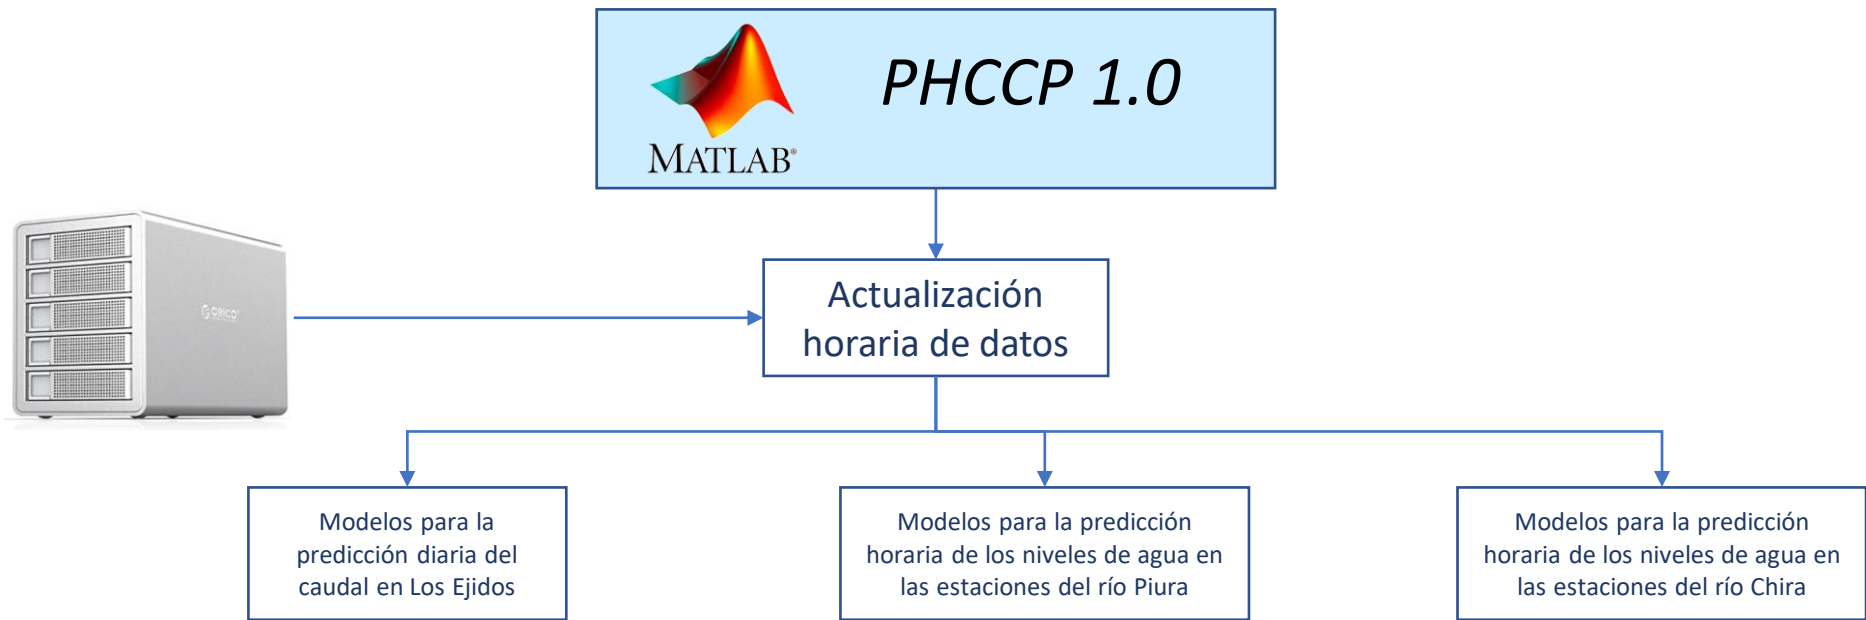


Base de datos de cada variable

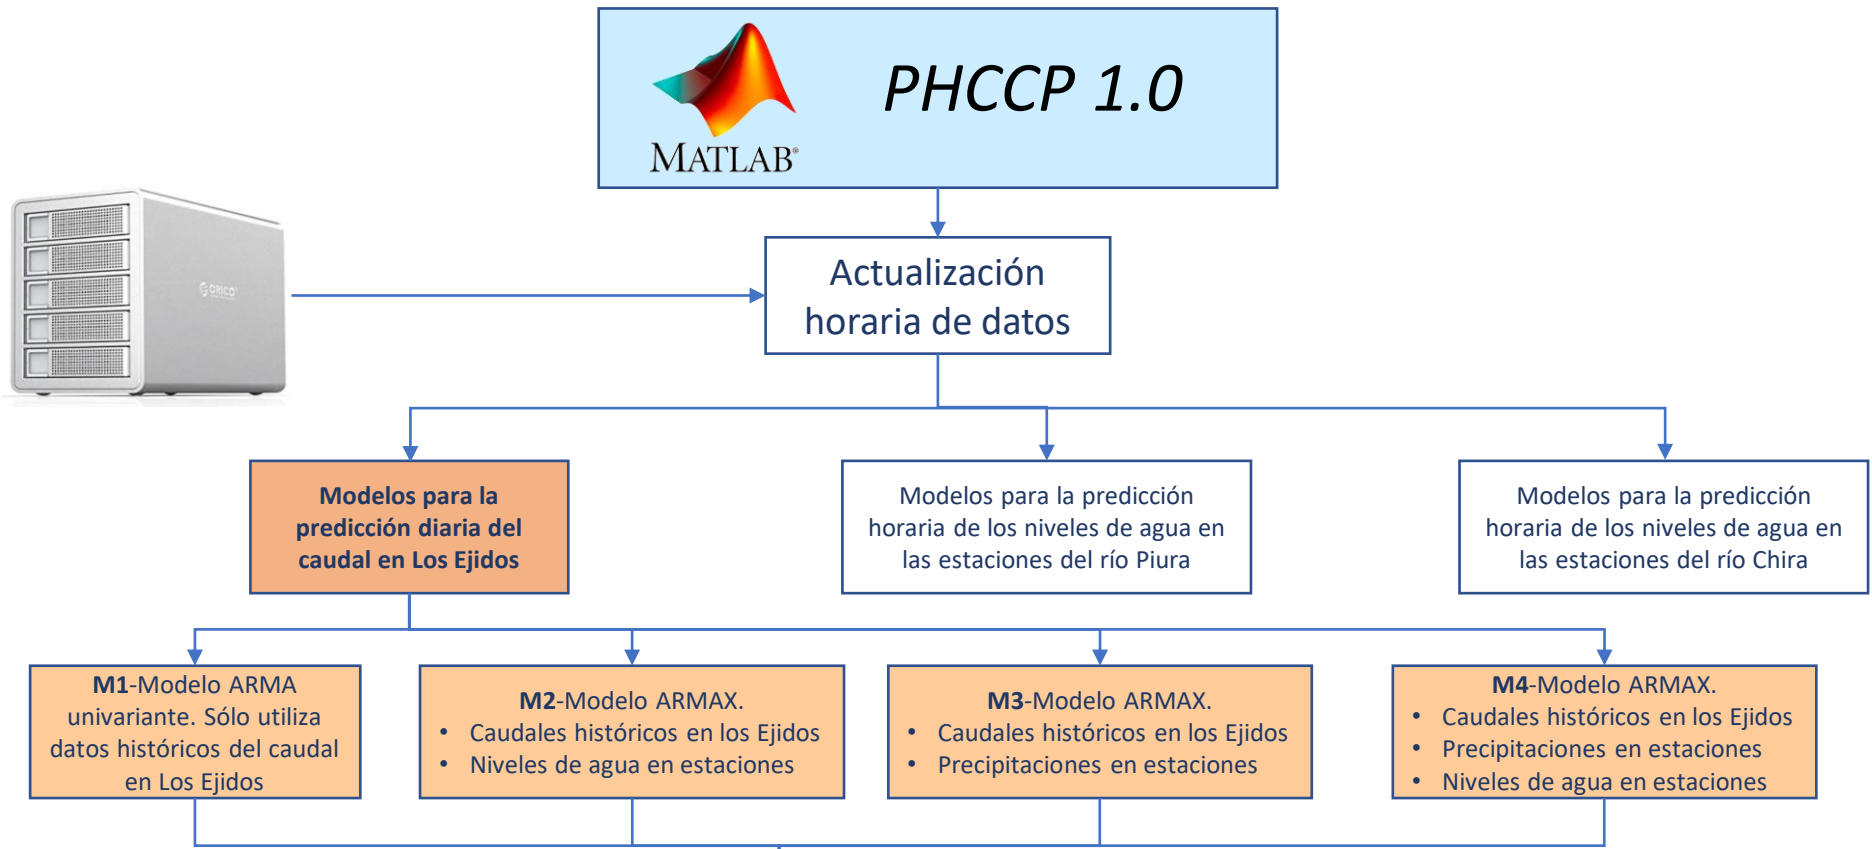


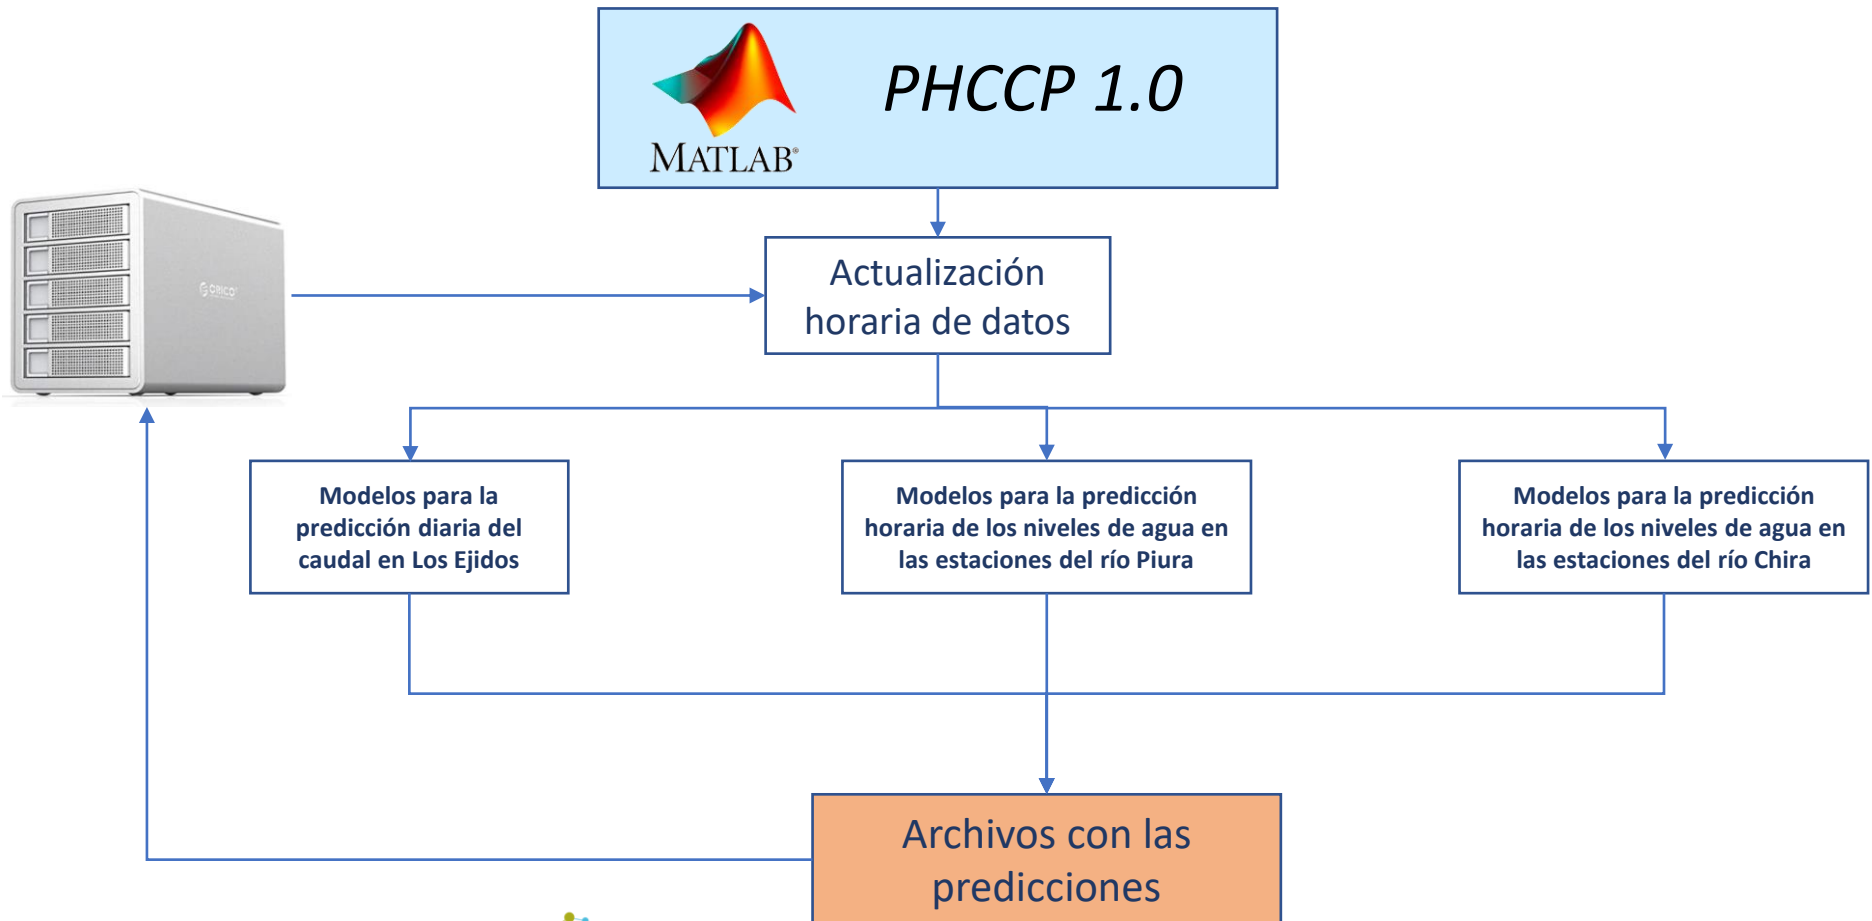
Station		Variables			Elevation
Label	Type	Actual name	Water level	Precip (mm)	(mamsl)
S01H	Met.	Ejidos	S01 (m <sup>3</sup> /s)		25
S02H	Hydromet.	Tambogrande	L02 (m)	P02	66
S03H	Hydromet	Ñácara	L03 (m)	P03	91
S04M	Met.	Chulucanas		P04	89
S05H	Hydromet.	San Pedro	L05 (m)	P05	240
S06M	Met.	Morropón		P06	128
S07M	Met.	Chalaco		P07	2290
S08H	Hydromet.	Corral del Medio	L08 (m)	P08	212
S09M	Met.	Malacasí		P09	153
S10H	Hydromet.	Salitral	L10 (m)	P10	209
S11H	Hydromet.	Hacienda Barrios	L11 (m)	P11	303
S12M	Met.	Canchaque		P12	1150
S13M	Met.	Huarmaca		P13	2171
S14M	Met.	El Virrey		P14	208




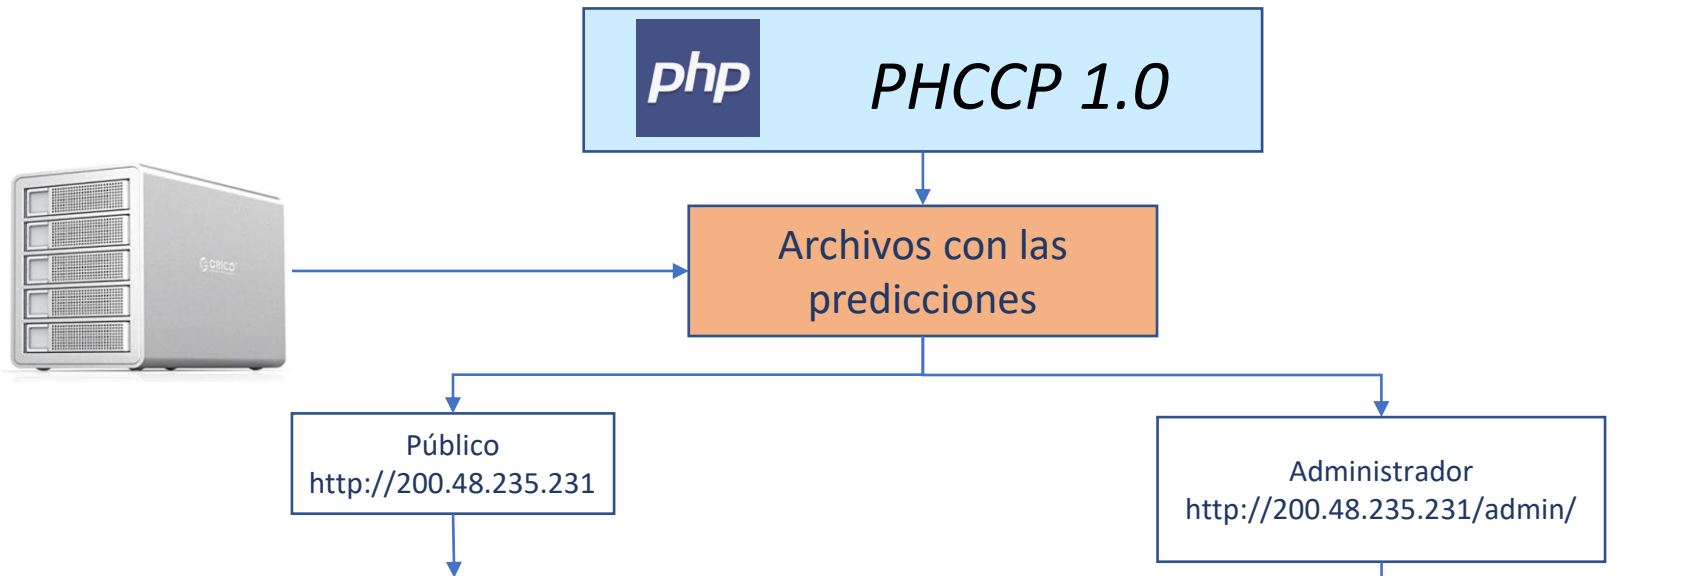












UNIVERSIDAD DE PIURA | CONCYTEC | Pro CIENCIA | BANCO MUNDIAL | IRAGER

Lista de Estaciones

Show 10 entries

Código	Nombre	Tipo	Cuenca	Acciones
47E937CA	CORRAL DEL MEDIO	HIDROMETEREOLÓGICA	PIURA	Ver
47E9415A	PUENTE ÑACARA	HIDROMETEREOLÓGICA	PIURA	Ver
47E9522C	TAMBO GRANDE	HIDROMETEREOLÓGICA	PIURA	Ver
47E96786	SALITRAL EHA	HIDROMETEREOLÓGICA	PIURA	Ver
47E974C0	HACIENDA BARRIDOS	HIDROMETEREOLÓGICA	PIURA	Ver
47E98444	SAN PEDRO	HIDROMETEREOLÓGICA	PIURA	Ver

UNIVERSIDAD DE PIURA | CONCYTEC | Pro CIENCIA | BANCO MUNDIAL | IRAGER

### PREDICCIÓN HIDROLÓGICA EN LAS CUENCAS CHIRA Y PIURA

Inicia sesión para empazar ...

Login

Password

Sign In



# Hybrid models based on mode decomposition and recurrent neural networks for streamflow forecasting in the Chira river in Peru

Gerson La Rosa Lama  
Dirección de Investigación  
Universidad de Piura  
Piura, Perú  
gerson.larosa@udep.edu.pe

Ismael Sánchez  
Departamento de Ingeniería Industrial y Sistemas  
Universidad de Piura  
Piura, Perú  
ismael.sanchez@udep.edu.pe

**Abstract**—Streamflow forecasting at short horizons is vital for the management of water resources. However, the streamflow behaviour is non-linear and not stationary. To address this challenge, artificial intelligence techniques have been used to increase accuracy. Additionally, signal decomposition techniques such as empirical mode decomposition, ensemble empirical mode decomposition, and variational mode decomposition, have been applied in different fields as a pre-processing stage prior to modelling to improve forecasting. In this study we evaluate the effect of the aforementioned decomposition techniques used with an artificial recurrent neural called long short-term memory to increase the precision of the daily prediction of the Chira river

The special dynamics of the Chira river makes it difficult to calculate a prediction of the flows using only physical models, due to the data requirements, uncertainties and complexities that would imply to put it into practice [3]. However, data-driven models can be a useful alternative to improve streamflow prediction.


Data-driven models for streamflow prediction have been studied from different approaches, among these are ARIMA time series models, where the hypothesis of linear models is assumed. In practice these models work well when the prediction horizons are monthly, quarterly or annually. These models have been studied in the Chira river [2]

sedimentation. The capacity of the reservoir could be restored by using appropriate operation. Opening the reservoir outlets when the water level is high enough releases water flows at high pressure. This flow makes it possible to scrub the deposited sediments. This practice, however, needs accurate daily streamflow predictions, since the reservoir needs to be filled again in a short period of time to allow normal operations and attend water demand. That is why it is very important to know the prediction of flows at short horizons.

This work was supported by CONCYTEC, Peru, under contract 60-2018-FONDECYT-BM-IADT-AV.

applying pre-processing.

The paper is organized as follows. In section 2 the study area and the data used are described. In section 3 the methodology used for the experiments is presented. In section 4 the pre-processing techniques used and the LSTM are introduced. Later in section 5 the results found, and their comparisons are shown to finally present conclusions in section 6.



## Hybrid models based on mode decomposition and recurrent neural networks for streamflow forecasting in the Chira river in Peru

Publisher: IEEE [Cite This](#) [PDF](#)

Gerson La Rosa Lama ; Ismael Sánchez [All Authors](#)

44  
Full  
Text Views



Repositorio CONCYTEC / 6. Investigación científica / 6.1 Proyectos de investigación científica

Por favor, utiliza este identificador para citar o enlazar este ítem: <http://hdl.handle.net/20.500.12390/2470>

Título: Hybrid models based on mode decomposition and recurrent neural networks for streamflow forecasting in the Chira river in Peru

Autor(es): La Rosa Lama G   
Sanchez I

Resumen: Streamflow forecasting at short horizons is vital for the management of water resources. However, the streamflow behaviour is non-linear and not stationary. To address this challenge, artificial intelligence techniques have been used to increase accuracy. Additionally, signal decomposition techniques such as empirical mode decomposition, ensemble empirical mode decomposition, and variational mode decomposition, have been applied in different fields as a pre-processing stage prior to modelling to improve forecasting. This study evaluates the effect of the aforementioned decomposition techniques used with a recurrent neural network called long short-term memory to increase the precision of the daily prediction of the Chira river streamflow in northern Peru, characterized by a special dynamic due to a strong seasonal behavior and the influence of the El Niño-Southern Oscillation (ENSO). © 2020 IEEE



UNIVERSIDAD DE PIURA



# Hybrid models based on mode decomposition and recurrent neural networks for streamflow forecasting in the Chira river in Peru

Gerson La Rosa Lama  
Dirección de Investigación  
Universidad de Piura  
Piura, Perú  
gerson.larosa@udep.edu.pe

Ismael Sánchez  
Departamento de Ingeniería Industrial y Sistemas  
Universidad de Piura  
Piura, Perú  
ismael.sanchez@udep.edu.pe

**Abstract**—Streamflow forecasting at short horizons is vital for the management of water resources. However, the streamflow behaviour is non-linear and not stationary. To address this challenge, artificial intelligence techniques have

The special dynamics of the Chira river makes it difficult to calculate a prediction of the flows using only physical models, due to the data requirements, uncertainties and complexities that would imply to put it into practice [3].

operations and attend water demand. That is why it is very important to know the prediction of flows at short horizons.

This work was supported by CONCYTEC, Peru, under contract 60-2018-FONDECYT-BM-IADT-AV.

978-1-7281-8367-1/20/\$31.00 ©2020 IEEE

IEEE Xplore® Browse My Settings Help

All

Conferences > 2020 IEEE Engineering Interna...

### Hybrid models based on mode decomposition and recurrent neural networks for streamflow forecasting in the Chira river in Peru

Publisher: IEEE Cite This PDF

Gerson La Rosa Lama ; Ismael Sánchez All Authors

44 Full Text Views

sedime  
by usin  
when t  
high p  
deposi  
daily s  
filled  
operat  
import  
The  
2018-FO



Autor(es): La Rosa Lama G Sanchez I

Resumen:

Streamflow forecasting at short horizons is vital for the management of water resources. However, the streamflow behaviour is non-linear and not stationary. To address this challenge, artificial intelligence techniques have been used to increase accuracy. Additionally, signal decomposition techniques such as empirical mode decomposition, ensemble empirical mode decomposition, and variational mode decomposition, have been applied in different fields as a pre-processing stage prior to modelling to improve forecasting. This study evaluates the effect of the aforementioned decomposition techniques used with a recurrent neural network called long short-term memory to increase the precision of the daily prediction of the Chira river streamflow in northern Peru, characterized by a special dynamic due to a strong seasonal behavior and the influence of the El Niño-Southern Oscillation (ENSO). © 2020 IEEE



UNIVERSIDAD DE PIURA







JUNTOS ESTAMOS  
TRANSFORMANDO  
EL PERÚ



Proyecto  
**Concytec**  
**Banco Mundial**



UNIVERSIDAD  
DE PIURA



**BANCO MUNDIAL**  
BIRF • AIF | GRUPO BANCO MUNDIAL

*Gracias*