

ESTUDIO DE LA PREDICTIBILIDAD DE LAS TELECONEXIONES APLICANDO TÉCNICAS DE APRENDIZAJE AUTOMÁTICO

Víctor Galván Fraile

TROPA UCM



CONTENIDOS

1

Motivación y Objetivos

2

Panorama Global y Estado del Arte

3

Introducción al Aprendizaje Automático

4

Metodologías y Preprocesado

5


Análisis de los Resultados

6

Conclusiones y Trabajos Futuros

OBJETIVOS

- Regiones del océano que aportan predictibilidad
- Áreas que son predecibles con estos métodos
- Mecanismos físicos detrás de las predicciones (storylines)



Fuente: EL Nino Southern Oscillation (ENSO), NASA.

ESTRUCTURA



Climatología y predicción estacional



- o Estudiar la climatología y variabilidad.
- o Analizar los mecanismos de teleconexión.
- o Describir las bases de la predicción estacional.

Ciencia de datos



- o Aplicar técnicas de preprocesado.
- o Analizar los datos y descubrir patrones.

Análisis de los resultados



- o Comparar el desempeño de los modelos.
- o Establecer conclusiones de los mismos.
- o Entender mejor el problema.

Inteligencia Artificial



- o Establecer las bases del Machine Learning.
- o Describir las características de los algoritmos.


Modelos de Machine Learning



- o Aprender a programar estos algoritmos.
- o Aplicar la teoría a un caso específico.

REGIÓN EURO-ATLÁNTICA


- Climatología
- Patrones de variabilidad
- Tipos de tiempo




Fuente: Delgado et al. (2022)

MODOS DE VARIABILIDAD

1. Océano Pacífico: ENSO




Fuente: Wikipedia




Fuente: Ashok et al. (2009)

MODOS DE VARIABILIDAD

2. Océano Índico




Fuente: NOAA



Fuente: Beal et al. (2020)

RESPUESTA DE GILL

- Situación baroclina
- Vorticidad



Fuente: Gill (1980)

$$\frac{\partial \xi}{\partial t} + u \frac{\partial \xi}{\partial x} + v \frac{\partial \xi}{\partial y} + v \frac{\partial f}{\partial y} = F$$

$$F = -(f + \xi) \left(\frac{\partial u}{\partial x} + \frac{\partial v}{\partial y} \right) = (f + \xi) \frac{\partial \omega}{\partial p}$$

RESPUESTA DE GILL

- Situación baroclina


- Vorticidad

$$\frac{\partial \xi}{\partial t} + u \frac{\partial \xi}{\partial x} + v \frac{\partial \xi}{\partial y} + v \frac{\partial f}{\partial y} = F$$

$$F = -(f + \xi) \left(\frac{\partial u}{\partial x} + \frac{\partial v}{\partial y} \right) = (f + \xi) \frac{\partial \omega}{\partial P}$$

- Ondas de Rossby



$$\frac{\partial \xi}{\partial t} + u \frac{\partial \xi}{\partial x} + v \frac{\partial \xi}{\partial y} + v \frac{\partial f}{\partial y} = F$$



Fuente: Horel et al. (1981)



TELECONEXIONES EN SECTOR EURO-ATLÁNTICO

1. Océano Pacífico:



Fuente: Jiménez et al. (2018)


2. Océano Índico



Fuente: Adnan et al. (2021)

PREDICCIÓN ESTACIONAL


- Fuentes de predictibilidad
- Modelos dinámicos
- Modelos estadísticos



Fuente: Uccellini et al. (2018)



MACHINE LEARNING

(APRENDIZAJE AUTOMÁTICO)



MACHINE LEARNING


(APRENDIZAJE AUTOMÁTICO)




Fuente: Géron. (2022)

REDES NEURONALES ARTIFICIALES


- Neurona biológica



REDES NEURONALES ARTIFICIALES






- Neurona biológica
- Neurona artificial



REDES NEURONALES ARTIFICIALES


- Neurona biológica
- Neurona artificial
- Estructura general



Fuente: Géron (2022)

REGIONES DE ESTUDIO


	SLP DJF (ERA)	SST SON (HadISST)			
	Euro-Atlántica 📍	Pacífico 📍	Atlántico 📍	Índico 📍	Trópico 📍
Latitudes	70°N-20°N	55°N-20°S	55°N-20°S	30°N-20°S	55°N-20°S
Longitudes	40°W-30°E	120°E-80°W	70°W-20°E	40°E-100°E	180°W-180°E



PREPROCESADO DE DATOS

1. Periodo de estudio (1900-2020)

2. ERA20 (1900-2010).+ ERA5 (2010-2020)
Anomalías estacionales.





Razón de varianzas

[1949-2010]


Diferencia de medias

3.


4.



DIVISIÓN DE LOS DATOS




DIVISIÓN DE LOS DATOS





VALIDACIÓN CRUZADA

Folds	1900	1901	1902	1903	1904	1905	...	...	2017	2018	2019	2020
Fold 1	Test	Entrenamiento										
Fold 2		Test	Entrenamiento									
...			Test	Entrenamiento								
Fold 119	Entrenamiento										Test	
Fold 120	Entrenamiento											Test



ESTRUCTURA GENERAL




ESTRUCTURA GENERAL






SST SON



SLP DJF



ESTRUCTURA GENERAL




MÉTRICAS:

- Raíz del error cuadrático medio (RMSE)
- Coeficiente de correlación de anomalías (ACC)




$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (y^{(i)} - \hat{y}^{(i)})^2}$$

$$ACC = \frac{\sum_{i=1}^m y^{(i)} \times \hat{y}^{(i)}}{\sqrt{\sum_{i=1}^m (y^{(i)} \times \hat{y}^{(i)})^2}}$$


Océano Pacífico




Océano Pacífico




Océano Pacífico



a) ANN Pacific Ocean model






b) SEAS5 model



ACC del modelo SEAS5 inicializado en
Octubre para predecir anomalía de SLP en
DJF

Diferentes Predictores



A world map showing Sea Surface Temperature (SST) anomalies. The map uses a color scale where blue indicates cooler than average and red/orange indicates warmer than average. Significant warm anomalies are visible in the North Atlantic, the North Pacific, and the Indian Ocean. Cooler anomalies are seen in the central North Pacific and parts of the Southern Ocean.

CONCLUSIONES

1. Capacidad de las ANNs de detectar covariabilidad entre anomalías de SST y SLP.
2. Predictibilidad de la cuenca del Pacífico en la alta subtropical.
3. Predictibilidad de los océanos Índico y Atlántico en Europa.
4. Mejora con respecto a los modelos dinámicos actuales.

¡¡MUCHAS GRACIAS POR SU ATENCIÓN!!

¿PREGUNTAS?

Víctor Galván Fraile

Dirección de correo:
vgalva01@ucm.es

TROPA UCM

