



DEEPCLOUD

PREDICCIÓN SATELITAL INTRA-DÍA DE NUBOSIDAD
USANDO TÉCNICAS DE APRENDIZAJE PROFUNDO

IGNACIO CAMIRUAGA - ANDRÉS HERRERA - FRANCO MOZO

TUTORES

Rodrigo Alonso Suárez
Alberto Castro
Franco Marchesoni

TRIBUNAL

Agustín Laguarda
Pablo Musé
Facundo Benavides





ÍNDICE

- Introducción
- Dataset
- Métricas
- Modelos base
- Modelos de aprendizaje profundo
- Resultados
- Conclusión





INTRODUCCIÓN

- Motivaciones
- Características de la energía solar
- Predicción de la energía solar
- Objetivos



MOTIVACIONES


Mejor aprovechamiento de la energía solar




Mapa Solar de Uruguay



CARACTERÍSTICAS DE LA ENERGÍA SOLAR




Participación de cada fuente en el total de inyecciones al Sistema Interconectado Nacional (SIN) en 2021.





PREDICCIÓN DE LA ENERGÍA SOLAR



*: Foco del proyecto

** : Paso a series temporales para predicción en sitios



OBJETIVOS

- Expandir la línea de I+D de predicción satelital de nubosidad en Uruguay.
- Aplicar modelos del estado del arte del aprendizaje profundo para predicción satelital de nubosidad.
- Crear un sistema competitivo con el sistema actual del LES, utilizando un modelo aplicable en un contexto de producción.






DATASET

- Banco de imágenes del LES
- Preprocesamiento
- Filtrado de imágenes
- Recortes y partición de datos




BANCO DE IMÁGENES DEL LES

- Satélite: **GOES-16**
- Cadencia: **10 minutal**
- Año: **2020**
- Tamaño: **(2501, 3001) px**
- Resolución: **(1100 x 1100) m/px**
- Cantidad: **52.314**







PREPROCESAMIENTO



Ejemplo al comienzo del día



Sin normalizar




Normalizada





Mapa de cosenos cenitales



FILTRADO DE IMÁGENES




Cantidad de imágenes filtradas por tipo e imágenes útiles restantes.




Ejemplos de datos con errores en transmisión



RECORTES Y PARTICIÓN DE DATOS



Nombre	Tamaño en px	Número de imágenes post-filtrado
MVD	256 x 256	22.224
URU	512 x 512	21.820
REGION3	1024 x 1024	20.842





MÉTRICAS

- MAE, RMSE
- Métricas relativas y Forecasting Skill
- SSIM (Structural Similarity Index Measure)



MAE, RMSE

Error absoluto medio y error cuadrático medio

$$MAE(\hat{X}, X) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W |\hat{x}_{ij} - x_{ij}|$$

$$RMSE(\hat{X}, X) = \sqrt{\frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W (\hat{x}_{ij} - x_{ij})^2}$$



MÉTRICAS RELATIVAS Y FORECASTING SKILL


$$\text{MÉTRICA}\% = \frac{\text{MÉTRICA}(\hat{X}, X)}{\bar{X}} \times 100$$

$$\text{FS} = 1 - \frac{\text{RMSE}(\hat{X}, X)}{\text{RMSE}(\text{Modelo base})}$$



SSIM

Structural Similarity Index Measure






MODELOS BASE

- Persistencia
- CMV
- Blurred CMV



PERSISTENCIA


Entrada en t_0



Copia




Predicción en t_k







CMV

Cloud Motion Vectors






BLURRED CMV



Predicción CMV



Predicción CMV con blur




MODELOS DE APRENDIZAJE PROFUNDO

- U-Net
- U-Net Diff
- IrradianceNet
- IrradianceNet GEO
- Redes Generativas Adversarias (GAN)



U-NET



Arquitectura





U-NET

Tamaño de la red y el batch size







FACULTAD DE
INGENIERÍA

MODELOS DE A.P.

U-NET

Tamaño de la red y el batch size




Dataset: **REGION3**
Horizonte de pronóstico: **1 hora**




U-NET

Entradas adicionales

Input CMV



Información temporal




Dataset: **MVD**

Horizonte de pronóstico: **10 minutos**




U-NET DIFF

Prediciendo la diferencia



Entrenamiento




Inferencia




U-NET DIFF



Ejemplo





Última entrada



Predicción



Salida a 2 horas





Objetivo a 2 horas



IRRADIANCENET

Modelo basado en parches




Cantidad de parámetros: **12.024.321**




IRRADIANCENET GEO

Agregando datos geográficos



Latitud



Longitud




Elevación





REDES GENERATIVAS ADVERSARIAS (GAN)

Cómo lo implementamos








REDES GENERATIVAS ADVERSARIAS (GAN)

Evolución en la definición de las predicciones


Secuencia de entrada:



Ground truth a 10 min:



Salidas:



Ep 1

Ep 3

Ep 5

Ep 10

Ep 15



MODELOS SELECCIONADOS PARA LA EVALUACIÓN FINAL

Modelos Base

- Persistencia
- CMV
- Blurred CMV

Modelos de aprendizaje profundo

REGION3

- U-Net
- U-Net Diff
- IrradianceNet
- IrradianceNet GEO

MVD

- U-Net
- U-Net InputCMV
- GAN





RESULTADOS

- Resultados en el dataset REGION3
- Resultados en el dataset MVD
- Ejemplos



RESULTADOS EN EL DATASET REGION3



Métricas absolutas





RESULTADOS EN EL DATASET REGION3


Métricas relativas





RESULTADOS EN EL DATASET REGION3




Análisis espacial sobre RMSE






RESULTADOS EN EL DATASET MVD

RMSE%, RMSE y SSIM






EJEMPLO 1





EJEMPLO 2


Explicación del video






EJEMPLO 2


Ground Truth



1 hora



2 horas




3 horas



4 horas



5 horas





CONCLUSIÓN

- Resumen
- Contribuciones



RESUMEN

- Se diseñó un pipeline de entrenamiento de modelos
- Se hizo una revisión bibliográfica del área
- Se entrenaron de forma extensiva distintos modelos del estado del arte
- Se reportaron sus desempeños sobre un conjunto de datos no vistos
- **Se cumplieron todos los objetivos planteados**



CONTRIBUCIONES

- Prueba de que los modelos de aprendizaje profundo se pueden utilizar para generar pronósticos intra-día confiables y de buen desempeño
- Numerosos análisis sobre las arquitecturas y sus componentes los cuales proveen un mejor entendimiento de las mismas para futuros trabajos.
- Comparación de desempeño con modelo del estado del arte IrradianceNet
- **Línea de estudio** de predicción de nubosidad intra-día utilizando aprendizaje profundo en Uruguay
- **Modelo del estado del arte liviano que supera el modelo en producción del LES**



¿PREGUNTAS?

Contacto:

ignacio.camiruaga@fing.edu.uy

andres.herrera@fing.edu.uy

franco.mozo@fing.edu.uy



FINAL

NORMALIZACIÓN DE IMÁGENES




Figure 2.5: (a) Reflectance image. (b) Cosangs mask used to normalized. (c) Thresholded cosangs mask. (d) Normalized image in daylight pixels. (e) Normalized image where cosangs pixels are in between $[0, 0.15]$. (f) Image resulting from the normalization step.

REVISIÓN BIBLIOGRÁFICA

Principales

- Cloud Cover Nowcasting with Deep Learning | **Meteo France**, *Francia*.
- MetNet: A Neural Weather Model for Precipitation Forecasting | **Google Research**, *Estados Unidos*.
- IrradianceNet: Spatiotemporal deep learning model for satellite-derived solar irradiance short-term forecasting | **Aarhus University**, *Dinamarca*.

Secundarios

PORCENTAJE DE VALORES VALIDOS PARA EL CMV EN FUNCIÓN DEL HORIZONTE DE PRONÓSTICO

30 min	60 min	90 min
6.93%	13.69%	20.01%

Table 4.1: Mean percentage of NaN values for the CMV predictions on the MVD validation dataset, for 30, 60, and 90 minutes prediction horizons.





Figure C.1: Percent of valid values of the CMV prediction for different border sizes evaluated on the URU validation dataset.

MÉTRICAS DE ENTRENAMIENTO

Métrica de validación	Función de error de entrenamiento			
	MAE	MSE	SSIM	MAE-SSIM
MAE	0.06595	0.06971	0.06754	0.06656
MSE	0.01326	0.01266	0.01465	0.01404
SSIM	0.6034	0.5922	0.6105	0.6093


Métrica de validación	Función de error de entrenamiento			
	MAE	MSE	SSIM	MAE-SSIM
MAE	0.0%	5.69%	2.40%	0.91%
MSE	4.72%	0.0%	15.67%	10.86%
SSIM	1.17%	3.08%	0.0%	0.19%
Promedio	1.97%	2.93%	6.02%	3.99%

EFECTO DEL AMANECER-ANOHECER EN EL DESEMPEÑO





DESEMPEÑO U-NET DIFF POR HORA PARA CADA HORIZONTE DE PRONÓSTICO



RMSE



RMSE%




U-NET: DATA AUGMENTATION




U-NET: VARIACIONES


Attention U-Net:



Nested U-Net:




R2U-Net:




UNET: VARIACIONES

Entrenamiento



10 minutos



60 minutos



Validación



Dataset: URU

Horizonte de pronóstico: 10 y 60 minutos

MODELOS RECURRENTES: FORMAS DE CALCULAR EL ERROR




Figure 3.11: Recurrent Neural Network for sequence prediction. Figure taken from Udelar Engineering Faculty course Deep Learning for computer vision, class 14.





Figure 3.12: Recurrent Neural Network for sequence prediction, using only the last output to calculate the Loss and update the weights. Figure edited, original taken from Udelar Engineering Faculty course Deep Learning for computer vision, class 14.

MODELO VANILLA DE GAN



EJEMPLO SOBRE MVD




Figure 5.16: Example of a prediction on one hour lead time for the (a) U-Net, (b) wGAN and (c) U-Net InputCMV.