Estimación de Energía de Rayos Cósmicos para el Observatorio HAWC aplicando algoritmos de Inteligencia Artificial





Jorge Alfredo Jaimes Teherán – jjalfredo68@gmail.com

Christian Sarmiento Cano, Ibrahim Torres, Tomás Capistrán, Luis Nuñez.

Universidad Industrial de Santander Instituto Nacional de Astrofísica, Óptica y Electrónica Università degli Studi di Torino



Objetivos



Objetivo general

 Estimar la energía de los rayos cósmicos primarios mediante la implementación de algoritmos de inteligencia artificial.

Objetivos específicos

- Recolectar e interpretar la física de los datos obtenidos por el HAWC.
- Diseñar e implementar un modelo de inteligencia artificial capaz de estimar el valor de energía del rayo cósmico primario, teniendo en cuenta el sentido físico de las cascadas atmosféricas extendidas.
- Validar la confiabilidad de los algoritmos mediante comparaciones con otros métodos entrenados y el estado del arte.
- Calcular el espectro de rayos cósmicos con el mejor modelo obtenido.

Estado del arte



Rayos cósmicos

- Núcleos (hidrógeno,..., hierro)
- Remanentes de supernovas, púlsares y agujeros negros
- Interactúan con campos magnéticos y eléctricos

Rayos gamma

- Son fotones
- Explosiones de supernovas, fusión de estrellas de neutrones, AGN's, entre otros
- Viajan en línea recta



Espectro de rayos cósmicos



• La rodilla

• Segunda rodilla

- Tobillo
- Supresión



Cascadas atmosféricas extendidas





Hadrónica

- Nuclear fragments
- p, n, π^{\pm}, K^{\pm}
- Charm mesons
- Leading particle effect
- Concentrated in the rain
 axis
- $N_h \propto N_e^{0.95}$



HAWC

Situado en el volcán Sierra Negra
100 GeV hasta ~ 1 PeV (RC)
300 Tanques Cherenkov en agua

• 4 foto multiplicadores por tanque

Primaryp

N×

2

M

Efecto Cherenkov





Radiación Cherenkov

- Luz emitida cuando una partícula supera la velocidad de la luz en un medio.
- Efecto similar a la onda de choque producida por aviones supersónicos.
- Se manifiesta como un destello de luz azul.

Proceso de detección en HAWC

- Las lluvias de partículas (e^{-}/e^{+} , $\mu \pm$, γ) creadas por la astropartícula atraviesan los tanques de agua ultrapura y producen luz Cherenkov en su interior.
- Fotomultiplicadores (PMT) en el fondo de cada tanque miden la intensidad y el tiempo de llegada de esos fotones.
- A partir del patrón temporal y espacial registrado en los tanques, algoritmos de reconstrucción determinan la dirección, punto de impacto y una estimación de la energía de la partícula primaria.

Ventajas del HAWC

- Monitoreo continuo de dos tercios del cielo.
- Especializado en detectar eventos de alta energía (rayos gamma y rayos cósmicos).
- Alta sensibilidad a fenómenos transitorios y eventos extremos.

Planteamiento del problema



Universidad

Industrial de Santander

Construcción del modelo

Entrenamiento del modelo con eventos simulados

Entrenamos en simulaciones, pero usamos en datos reales



Universidad Industrial de Santander

Variables físicas

Universidad Industrial de Santander



MP4SE

- fHit
- fTank
- Lateral Amp
- CoreD
- CZenith
- fAnnulusCharge (9 variables)

y [m

 $\log_{10}(Q_{eff})$

16 variables +

MP4CE

- fHit
- fTank
- Lateral Amp
- CoreD
- **CZenith**
- fAnnulusCharge (9 variables)
- 16 variables + •
- 5 estimadores de energía .



Esquema de datos HAWC

Se usaron 4.637.942 de eventos simulados

Cortes de selección:

- El ajuste del ángulo y núcleo del evento sea exitoso.
- El evento sea detectado con un mínimo del 20 % del arreglo.
- El número de canales dentro de un radio de 40 metros sea mayor a 40 PMTs.
- El ángulo cenital este entre 0° y 35°.

Nota: Es importante destacar que el entrenamiento de los modelos se realiza exclusivamente con datos simulados. Esto se debe a que solo en los datos simulados se conoce la energía verdadera del evento, necesaria para el aprendizaje supervisado. En cambio, los datos reales se emplean únicamente para evaluar la capacidad del modelo de estimar dicha energía.



Universidad

Industrial de Santander

Pipeline de entrenamiento





Arquitecturas



					MLP	XGBOOST
Modelo	Conjunto	MSE	MAE	R ²	6.5	6.5
MLP	Entrenamiento	0.0276	0.1212	0.9182	5.0- 2.4.5-	5.0 - (Ng) 94.5 -
	Validación	0.0279	0.1218	0.9109	4.0 -	13)60 4.0
XGBoost	Entrenamiento	0.0250	0.1165	0.9201	3.5	3.0
	Validación	0.0281	0.1225	0.9101	2.5 3.0 3.5 4.0 4.5 5.0 5.5 6.0 6.5 log(E _{True} /GeV)	2.5 2.5 3.0 3.5 4.0 4.5 5.0 5.5 log(E _{True} /GeV)
LightGBM	Entrenamiento	0.0262	0.1192	0.9163		
	Validación	0.0282	0.1228	0.9099	60 - 55 -	60- 55-
CNN	Entrenamiento	0.0365	0.1518	0.8832	5.0 - Go	So.
	Validación	0.0367	0.1522	0.8825	4.0 -	20 - 4.0 -

3.0 -

2.5

3.0 3.5 4.0 4.5 5.0

log(E_{True}/GeV)

6.0 6.5

5.5





13

Energía reconstruida



Likelihood MP4CE **MP4SE** 6.5_E 6.5 r 6.5 6 5.5 4.5 $\text{log}_{10}(\text{E}_{\text{Reco}}/\text{GeV})$ $\log_{10}(E_{Reco}\,/GeV)$ $\log_{10}(E_{Reco}~/GeV)$ Counts/second Counts/second Counts/second 6Ē 6E 5.5 5.5 F 10 10 10 -5 5Ē 4.5 10-2 10-2 10⁻² 4 E 4 E 4 3.5 3.5 3.5 10⁻³ 10⁻³ 10⁻³ 3 2.5 2.5 F 2.5 22 5 10-4 5 5.5 10-4 5 5 5.5 6 6.5 6 6.5 10-4 6.5 22 2<u>2</u> 3.5 4.5 5.5 4.5 4.5 2.5 6 2.5 3.5 2.5 3 3.5 3 4 З 4 4 $\log_{10}(E_{True}/GeV)$ $\log_{10}(E_{True}^{}/GeV)$ $\log_{10}(E_{True}^{}/GeV)$ 6.5_E 6.5 $\text{log}_{10}(\text{E}_{\text{Reco}}/\text{GeV})$ $\log_{10}(E_{Reco}~/GeV)$ Counts/second log₁₀(E_{Reco}/GeV) Counts/second Counts/second 6 6<u>–</u> 5.5 5 4.5 5.5 5 4.5 5.5 10 10 10 5 4.5 F 10⁻² 10-2 10⁻² 3.5 4 3.5 3 4 3.5 10⁻³ 10⁻³ 10⁻³ 3 3 2.5 2.5 2.5 2<mark>2</mark> 10-4 10-4 6 6.5 10-4 ²²2 ²² 2 6.5 6.5 3.5 5.5 3.5 5.5 5.5 6 3 4.5 2.5 3 4.5 5 2.5 3 4.5 5 6 2.5 3.5 5 4 4 4 $\log_{10}(\mathrm{E_{True}}\,/\mathrm{GeV})$ $\log_{10}(\mathrm{E_{True}}\,/\mathrm{GeV})$ $\log_{10}(\mathrm{E_{True}}\,/\mathrm{GeV})$

Hierro

Protón

Bias y métricas de testeo





Métricas	Likelihood	MP4CE	MP4SE
MSE	0.0946	0.0265	0.0281
MAE	0.2451	0.1230	0.1271
R ²	0.6906	0.9134	0.9081

Área efectiva y matriz de respuesta





Datos reales

Un día de espectro



MP4SE

Likelihood



MP4CE

Últimos resultados

22

2.5 3 3.5 4 4.5





10-4 6.5

22

2.5 3 3.5 4 4.5 5

5.5 6

 $\log_{10}(\text{E}_{\text{True}}/\text{GeV})$

5

P(E_{rec}IE_{Tr}

P(E_{rec}IE_T

0.3

⁵ 5.5 6 6.5 log₁₀(E_{True} /GeV)

0.7

Espectro





Últimos resultados





Conclusiones



- El modelo MP4CE mejoró la estimación de energía a partir de datos simulados, superando al método tradicional de máxima verosimilitud como al modelo MP4SE.
- Sin embargo, a pesar de estos resultados en simulación, el modelo mostró una sobreestimación del flujo a altas energías cuando se aplicó en el contexto físico, lo cual sugiere que aún se requieren mejoras en aspectos como la simulación y la calibración del modelo.
- Este trabajo muestra que las redes neuronales profundas tienen un potencial valioso como herramientas complementarias en la reconstrucción de energía dentro de experimentos como HAWC, aunque también deja en evidencia la necesidad de un análisis cuidadoso para garantizar su aplicabilidad en contextos físicos reales.
- Finalmente, los resultados obtenidos abren la puerta a la exploración de arquitecturas más complejas, como redes neuronales gráficas (GNN), PINN o modelos basados en transformadores, con el objetivo de seguir mejorando la estimación en futuros estudios.





- **Ponencia**: Optimizing a Cosmic-ray Energy Estimator with Machine Learning for the HAWC Collaboration Workshop for Machine Learning for Cosmic Particles, University of Delaware, EE. UU. **Enero 2025**
- Ponencia: Estimación de energía de rayos cósmicos para el Observatorio HAWC aplicando algoritmos de inteligencia artificial | Congreso Colombiano de Astronomía y Astrofísica, Bucaramanga, Colombia. - Noviembre 2024
- Ponencia: Reconstrucción de las propiedades de las cascadas, optimizadas para rayos cósmicos mediante aprendizaje automático con HAWC | LXVII Congreso Nacional de Física, Chihuahua, México — Octubre 2024
- Ponencia: Los algoritmos de aprendizaje en el Observatorio de rayos gamma HAWC
 I Congreso Internacional de Estadística e Ingeniería Aplicada, Salta (Argentina) y Nayarit (México) Diciembre 2023
- Ponencia: Estimación de la energía de los rayos cósmicos usando técnicas de Machine Learning 6° Congreso Estudiantil de Inteligencia Artificial Aplicada a la Ingeniería y Tecnología (CEIAAIT), UNAM — Noviembre 2023
- Poster: Actualización del estimador de energía de rayos cósmicos del observatorio HAWC utilizando técnicas de aprendizaje automático | LXVI Congreso Nacional de Física, Morelia, México — Octubre 2023

Universidad Industrial de Santander





¡Gracias!





High Altitude Water Cherenkov Gamma-Ray Observatory

Back up



rec.nChAvail: Número de canales disponibles para la detección de eventos.

rec.nHitTot: Número total de hits detectados en todo el observatorio. **rec.nHit**: Número de hits detectados en el evento actual.

rec.nHitSP10: Número de hits dentro de una ventana temporal de 10 ns. **rec.nHitSP20**: Número de hits dentro de una ventana temporal de 20 ns. **rec.nTankAvail**: Número de tanques de agua disponibles para la detección.

rec.nTankHitTot: Número total de tanques que detectaron hits durante el evento.

rec.nTankHit: Número de tanques que detectaron hits en el evento actual. **rec.windowHits**: Número de hits detectados en una ventana temporal definida.

rec.planeNDOF: Grados de libertad en el ajuste del plano de la onda del evento.

rec.mPFnHits: Número de hits asociados con el método de partición de planos (PlaneFit).

rec.mPFp0nAssign: Número de hits asignados al primer paso de reconstrucción del ajuste de plano.

rec.mPFp1nAssign: Número de hits asignados al segundo paso del ajuste de plano.

rec.coreFiduScale: Escala de fiducialidad para la posición del núcleo del evento.

rec.zenithAngle: Ángulo cenital del evento, indicando la dirección del rayo cósmico con respecto a la vertical.

rec.planeChi2: Valor de Chi-cuadrado para la calidad del ajuste del plano de la onda.

rec.fAnnulusCharge0: Carga detectada en el primer anillo concéntrico del detector.

rec.fAnnulusCharge1: Carga detectada en el segundo anillo concéntrico.
rec.fAnnulusCharge2: Carga detectada en el tercer anillo concéntrico.
rec.fAnnulusCharge3: Carga detectada en el cuarto anillo concéntrico.
rec.fAnnulusCharge4: Carga detectada en el quinto anillo concéntrico.
rec.fAnnulusCharge5: Carga detectada en el sexto anillo concéntrico.
rec.fAnnulusCharge6: Carga detectada en el sexto anillo concéntrico.
rec.fAnnulusCharge7: Carga detectada en el séptimo anillo concéntrico.
rec.fAnnulusCharge7: Carga detectada en el octavo anillo concéntrico.
rec.fAnnulusCharge8: Carga detectada en el noveno anillo concéntrico.

rec.logNPE: Logaritmo del número total de electrones fotoemisores detectados.

rec.CxPE40: Número estimado de electrones fotoemisores en un área de 40 metros alrededor del núcleo.

rec.logGP: Logaritmo del ajuste de la función de probabilidad geométrica. **rec.mPFp0Weight**: Peso asignado al primer paso en el ajuste de partición de planos.

rec.mPFp1Weight: Peso asignado al segundo paso en el ajuste de partición de planos.

rec.disMax: Distancia máxima entre el núcleo reconstruido y los hits detectados.

rec.TankLHR: Likelihood ratio asociado a los tanques que detectaron hits. **rec.LHLatDistFitXmax**: Parámetro de ajuste para la distancia lateral máxima en el evento.

rec.LHLatDistFitEnergy: Ajuste de la energía basado en la distribución lateral del evento.

rec.LHLatDistFitGoF: Calidad del ajuste de la distribución lateral del evento.

Back up



MP4CE

1. rec.LDFAmp 2. rec.fAnnulusCharge0 3. rec.fAnnulusCharge1 4. rec.fAnnulusCharge2 5. rec.fAnnulusCharge3 6. rec.fAnnulusCharge4 7. rec.fAnnulusCharge5 8. rec.fAnnulusCharge6 9. rec.fAnnulusCharge7 10.rec.fAnnulusCharge8 11.rec.nHitSP20 12.rec.nTankHitTot 13.rec.logGPV2 14.rec.coreFitUnc 15.rec.nHitTot 16.rec.logNNEnergyV2 17.rec.logCoreAmplitude 18.rec.LDFChi2 19.rec.nHit

20.rec.logNPE 21.rec.gammalheEnergy 22.rec.logMaxPE 23.rec.nTankHit 24.rec.windowHits 25.rec.nHitSP10 26.rec.PINC 27.rec.CxPE40 28.rec.protonlheLLH 29.rec.planeNDOF 30.rec.coreFiduScale 31.rec.planeChi2 32.rec.LDFAge 33.rec.SFCFNDOF 34.rec.SFCFChi2 35.rec.gammalheLLH

1. rec.LDFAmp 2. rec.fAnnulusCharge0 3. rec.fAnnulusCharge1 4. rec.fAnnulusCharge2 5. rec.fAnnulusCharge3 6. rec.fAnnulusCharge4 7. rec.fAnnulusCharge5 8. rec.fAnnulusCharge6 9. rec.fAnnulusCharge7 10.rec.fAnnulusCharge8 11.rec.nHitSP20 12.rec.nTankHitTot 13.rec.coreFitUnc 14.rec.nHitTot 15.rec.logCoreAmplitude 16.rec.LDFChi2 17.rec.nHit 18.rec.logNPE 19.rec.logMaxPE 20.rec.nTankHit 21.rec.windowHits

MP4SE

22.rec.nHitSP10 23.rec.PINC 24.rec.CxPE40 25.rec.planeNDOF 26.rec.coreFiduScale 27.rec.planeChi2 28.rec.LDFAge 29.rec.SFCFNDOF 30.rec.SFCFChi2rec.LDFAmp Back up



$$f(x;\mu,\sigma^2)=rac{1}{\sqrt{2\pi\sigma^2}}\exp\left(-rac{(x-\mu)^2}{2\sigma^2}
ight)$$

La función de verosimilitud para un conjunto de datos $X = \{x_1, x_2, \dots, x_n\}$ es:

$$L(\mu,\sigma^2\mid X) = \prod_{i=1}^n rac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-rac{(x_i-\mu)^2}{2\sigma^2}
ight)$$

En este caso, podemos derivar y resolver para μ y σ^2 que maximizan la verosimilitud. Esto nos llevará a los estimadores de máxima verosimilitud para una distribución normal:

$$\hat{\mu} = rac{1}{n}\sum_{i=1}^n x_i \quad ext{(media muestral)}$$
 $\hat{\sigma^2} = rac{1}{n}\sum_{i=1}^n (x_i - \hat{\mu})^2 \quad ext{(varianza muestral)}$

Back up - correlación MP4CE





Correlación con mc.logEnergy

Back up - correlación MP4SE





Correlación con mc.logEnergy

Back up - correlación MP4SE



Métricas	Likelihood	MP4CE	MP4SE	MP4G3V3
MSE	0.0946	0.0265	0.0281	0.0310
MAE	0.2451	0.1230	0.1271	0.1323
R ²	0.6906	0.9134	0.9081	0.8987

Modelo	Conjunto	MSE	MAE	R^2
MID	Entrenamiento	0.0276	0.1212	0.9182
MLF	Prueba	0.0279	0.1218	0.9109
VCPoost	Entrenamiento	0.0250	0.1165	0.9201
AGD00st	Prueba	0.0281	0.1225	0.9101
LinkerDM	Entrenamiento	0.0262	0.1192	0.9163
LIGHTGDM	Prueba	0.0282	0.1228	0.9099
CNN	Entrenamiento	0.0365	0.1518	0.8832
CININ	Prueba	0.0367	0.1522	0.8825