

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

Jorge Alfredo Jaimes Teherán

Trabajo de Grado para optar al título de Físico

Director:

Christian Sarmiento Cano
Ph.D en Física

Codirectores:

Ibrahim Torres Aguilar
Ph.D en Física
Tomás Capistrán Rojas
Ph.D en Electronica
Luis Nuñez de Villavicencio
Ph.D en Física

Universidad Industrial de Santander
Facultad de Ciencias
Escuela de Física
Física
Bucaramanga
2026

Tabla de Contenido

Introducción	9
1. Rayos cósmicos	11
1.1. Origen y propagación de los rayos cósmicos	13
1.1.1. Fuentes galácticas	14
1.1.2. Fuentes extragalácticas	16
1.1.3. Mecanismos de aceleración	17
1.2. Espectro de energía de los rayos cósmicos	22
1.2.1. Composición química de los rayos cósmicos	24
1.3. Lluvias Atmosféricas Extendidas (EAS)	27
1.3.1. Desarrollo longitudinal	28
1.3.2. Desarrollo lateral	29
1.4. Métodos de Detección de Rayos Cósmicos	30
2. El Observatorio HAWC	32
2.1. Objetivos científicos del observatorio HAWC	32
2.2. Detección de rayos cósmicos en HAWC	33
2.2.1. Radiación Cherenkov	33
2.2.2. Detección en HAWC	35
2.2.3. Tubos Fotomultiplicadores	35
2.2.4. Procesamiento de la señal	37
2.3. Análisis de los Datos	37
2.3.1. Reconstrucción del núcleo de la cascada atmosférica extendida	38
2.3.2. Reconstrucción de la dirección de arribo	38
3. Inteligencia artificial y Aprendizaje Profundo	39
3.1. Introducción a la inteligencia artificial	39
3.2. Aprendizaje supervisado	40
3.2.1. Modelos comunes	41
3.2.2. Proceso de entrenamiento	41
3.3. Redes neuronales artificiales	42
3.3.1. Estructura de las redes neuronales	42
3.3.2. Tipos de arquitectura	42
3.3.3. Proceso de entrenamiento	43

4. Metodología	47
4.1. Descripción de los datos	47
4.1.1. Simulación de lluvias de partículas y generación de datos	47
4.2. Versiones específicas de datos y modelos utilizados	49
4.3. Pipeline de modelado	51
4.4. Arquitecturas	55
4.4.1. Redes neuronales perceptrón multicapa	56
4.4.2. Redes neuronales convolucionales	56
4.4.3. XGBoost	57
4.4.4. LightGBM	58
4.5. Integración del modelo en el framework de HAWC	58
4.5.1. Cálculo del área efectiva	59
4.5.2. Cálculo del espectro utilizando datos simulados de Monte Carlo	60
4.5.3. Cálculo del espectro utilizando datos experimentales	62
4.6. Construcción del Espectro de Energía	63
5. Resultados	64
5.1. Primera aproximación con datos pass5	64
5.1.1. Modelo inicial implementado ROOT	64
5.1.2. Implementación del modelo en TensorFlow	65
5.2. Resultados con datos pass4 (Resultados principales)	66
5.2.1. Pipeline de modelado y metodología	66
5.2.2. MP4CE	72
5.2.3. MP4SE	75
5.3. Interpretación de los Resultados	77
5.3.1. Estimación de la energía	77
5.3.2. Análisis del Área Efectiva en HAWC	78
5.3.3. Análisis de la Matriz de Respuesta en HAWC	80
5.3.4. Análisis del Espectro de Rayos Cósmicos en HAWC	81
6. Conclusiones	83
Referencias Bibliográficas	85

Lista de Tablas

Tabla 1.	Variables utilizadas en cada modelo según versión de los datos simulados.	50
Tabla 2.	Comparación de métricas entre modelos.	71

Lista de Figuras

Figura 1.	Victor Hess en el globo aerostático.	11
Figura 2.	Gráfica de Hillas para posibles fuentes de rayos cósmicos. . . .	14
Figura 3.	Ilustración del mecanismo de aceleración de Fermi de primer orden en una onda de choque.	19
Figura 4.	Representación del espectro de energía de rayos cósmicos multiplicado por $E^{2,6}$	23
Figura 5.	Comparación de las abundancias relativas de elementos en los rayos cósmicos y en el sistema solar.	26
Figura 6.	La cascada atmosférica y sus componentes: electromagnética, muónica y hadrónica.	28
Figura 7.	Perfil longitudinal medio (Auger).	29
Figura 8.	Tanques Cherenkov del HAWC.	33
Figura 9.	Cono de radiación Cherenkov.	34
Figura 10.	Disposición de los tanques Cherenkov del HAWC.	35
Figura 11.	Esquema de un PMT.	36
Figura 12.	Representación esquemática de la reconstrucción de eventos en HAWC.	48
Figura 13.	Diagrama del pipeline de procesamiento y entrenamiento. . .	52
Figura 14.	Comparación de la reconstrucción de la energía por el método tradicional y el modelo construido en ROOT.	64
Figura 16.	Comparación de la reconstrucción de la energía por el método tradicional y el modelo construido en TensorFlow.	65
Figura 18.	Comparación del área efectiva método tradicional vs modelo NN36.	66
Figura 20.	Representación de las métricas de entrenamiento y validación del modelo MLP.	67
Figura 21.	Representación esquemática de la reconstrucción de eventos con el modelo MLP.	68
Figura 22.	Reconstrucción de la energía XGBoost.	69
Figura 23.	Reconstrucción de la energía LightGBM.	69
Figura 24.	Gráfica de las métricas de la CNN.	70
Figura 25.	Reconstrucción de la energía CNN.	71
Figura 26.	Cálculo del área efectiva usando el modelo MP4CE.	72
Figura 27.	Matriz de respuesta del HAWC con el modelo MP4CE.	73
Figura 28.	Histograma de energía del modelo MP4CE.	74

Figura 29.	Espectro $E^{2,6}$ del modelo MP4CE.	75
Figura 30.	Cálculo del área efectiva usando el modelo MP4SE.	76
Figura 31.	Matriz de respuesta del HAWC con el modelo MP4SE.	77
Figura 32.	Histograma de energía del modelo MP4SE.	78
Figura 33.	Espectro $E^{2,6}$ del modelo MP4SE.	79
Figura 34.	Dispersión E_{rec} vs. E_{true} para el método tradicional, modelos MP4CE y MP4SE.	79
Figura 35.	Sesgo de energía para protones y núcleos de hierro.	80
Figura 36.	Área efectiva del método tradicional, modelo MP4CE y MP4SE.	80
Figura 37.	Matriz de respuesta comparada entre método tradicional, modelo MP4CE y MP4SE.	81
Figura 38.	Espectro $E^{2,6}$ comparado entre método tradicional, modelo MP4CE y MP4SE.	81

Resumen

Título: Estimación de energía de rayos cósmicos para el Observatorio HAWC aplicando algoritmos de Inteligencia Artificial*

Autor: Jorge Alfredo Jaimes Teherán [†]

Palabras clave: Rayos cósmicos, Observatorio HAWC, estimación de energía, aprendizaje profundo, redes neuronales, espectro de energía

Descripción:

Los rayos cósmicos son partículas extraterrestres cuya detección es indirecta: al interactuar con la atmósfera generan cascadas secundarias registradas por el Observatorio HAWC (High Altitude Water Cherenkov), ubicado a 4.100 m s. n. m. en Sierra Negra, México. Reconstruir la energía de la partícula primaria es un problema complejo que HAWC aborda con el método de máxima verosimilitud (LH), el cual presenta limitaciones de precisión y sesgo en los extremos del rango energético.

En este trabajo se implementaron algoritmos de inteligencia artificial para estimar dicha energía. Se entrenaron perceptrones multicapa (MLP), redes neuronales convolucionales (CNN) y algoritmos de boosting (XGBoost y LightGBM) sobre simulaciones CORSIKA de las versiones pass5 y pass4, mediante un pipeline de preprocesamiento, selección de variables y optimización de hiperparámetros. Con los datos pass4 se construyeron dos modelos finales: MP4CE, que incorpora los estimadores de energía intrínsecos de la reconstrucción, y MP4SE, que los excluye.

MP4CE presentó la menor dispersión y el sesgo más bajo para protones y núcleos de hierro, con una matriz de respuesta concentrada en la diagonal ideal. MP4SE también superó al método LH, aunque con mayor dispersión a bajas energías, y ambos modelos alcanzaron un área efectiva cercana al área geométrica del arreglo.

En el espectro ponderado por $E^{2.6}$, MP4SE ofreció el comportamiento más consistente, mientras que MP4CE mostró una ligera sobreestimación del flujo a altas energías. Los resultados confirman el potencial de las redes neuronales para mejorar la calibración energética del observatorio.

*Trabajo de Grado

[†]Facultad de Ciencias. Escuela de Física. Director: Christian Sarmiento Cano, Ph.D. Codirector: Ibrahim Torres Aguilar, Ph.D, Tomás Capistrán Rojas, Ph.D, Luis Nuñez de Villavicencio, Ph.D.

Abstract

Title: Cosmic Ray Energy Estimation for the HAWC Observatory Using Artificial Intelligence Algorithms[‡]

Author: Jorge Alfredo Jaimes Teherán [§]

Keywords: Cosmic rays, HAWC Observatory, energy estimation, deep learning, neural networks, energy spectrum

Description:

Cosmic rays are extraterrestrial particles whose detection is indirect: upon interacting with the atmosphere they generate secondary cascades recorded by the HAWC (High Altitude Water Cherenkov) Observatory, located at 4,100 m a. s. l. on Sierra Negra, Mexico. Reconstructing the primary particle energy is a complex problem that HAWC addresses with the maximum likelihood (LH) method, which presents precision limitations and bias at the extremes of the energy range.

In this work, artificial intelligence algorithms were implemented to estimate this energy. Multilayer perceptrons (MLP), convolutional neural networks (CNN), and boosting algorithms (XGBoost and LightGBM) were trained on CORSIKA simulations from the pass5 and pass4 versions, through a pipeline of preprocessing, variable selection, and hyperparameter optimization. Two final models were built with pass4 data: MP4CE, which incorporates the intrinsic energy estimators from the reconstruction, and MP4SE, which excludes them.

MP4CE showed the lowest dispersion and smallest bias for protons and iron nuclei, with a response matrix concentrated along the ideal diagonal. MP4SE also outperformed the LH method, although with greater dispersion at low energies, and both models reached an effective area close to the geometric area of the array.

In the $E^{2.6}$ -weighted spectrum, MP4SE provided the most consistent behavior, while MP4CE showed a slight overestimation of the flux at high energies. The results confirm the potential of neural networks to improve the energy calibration of the observatory.

[‡]Degree Work

[§]Faculty of Sciences. School of Physics. Director: Christian Sarmiento Cano, Ph.D. Co-directors: Ibrahim Torres Aguilar, Ph.D., Tomás Capistrán Rojas, Ph.D., Luis Nuñez de Villavicencio, Ph.D.

Introducción

Los rayos cósmicos son partículas que llegan a la Tierra desde el espacio exterior, constituyendo un fenómeno clave en el estudio de la astrofísica de altas energías. Comprender su origen, composición química y mecanismos de aceleración es fundamental para desentrañar procesos extremos en el universo, como explosiones de supernovas o núcleos activos de galaxias.

El Observatorio HAWC (High Altitude Water Cherenkov) está ubicado a 4,100 m.s.n.m en las faldas del volcán Sierra Negra en Puebla, México, HAWC aprovecha su altitud y su diseño basado en detectores Cherenkov de agua para observar partículas y fotones de energías entre 100 GeV y 100 TeV e incluso rayos cósmicos hasta 1 PeV [1].

La estimación precisa de la energía de los rayos cósmicos es un desafío debido a la naturaleza indirecta de su detección. Al interactuar con la atmósfera terrestre, los rayos cósmicos generan cascadas de partículas secundarias que llegan al detector. La reconstrucción de la energía de la partícula primaria a partir de estas señales secundarias implica manejar una gran cantidad de variables y considerar los efectos de las interacciones atmosféricas y la respuesta del detector.

Tradicionalmente, HAWC ha utilizado métodos estadísticos, un ejemplo es el método de máxima verosimilitud (LH, por sus siglas en inglés) para estimar la energía de los rayos cósmicos. Sin embargo, estos métodos pueden presentar limitaciones en precisión y eficiencia, especialmente en rangos de energías extremas y en la distinción entre diferentes tipos de partículas.

En este trabajo se explora el uso de técnicas de aprendizaje automático y aprendizaje profundo para mejorar la estimación de energía de los rayos cósmicos detectados por HAWC. Las redes neuronales profundas tienen la capacidad de modelar relaciones complejas y no lineales entre las variables de entrada y la energía de las partículas, permitiendo potencialmente una reconstrucción más precisa y eficiente.

Se desarrollaron varios modelos basados en diferentes arquitecturas, incluyendo perceptrones multicapa (MLP), redes neuronales convolucionales (CNN) y algoritmos de *boosting* como XGBoost y LightGBM. Estos modelos fueron entrenados y evaluados utilizando datos simulados y experimentales de HAWC, aplicando técnicas de optimización de hiperparámetros y validación cruzada para asegurar su robustez y generalización.

Los resultados obtenidos muestran que los modelos basados en aprendizaje profundo pueden superar a los métodos tradicionales en la estimación de la energía de

los rayos cósmicos, ofreciendo mejoras significativas en precisión y reducción de sesgos. En particular, los modelos MLP demostraron una alta capacidad para generalizar y proporcionar estimaciones consistentes en diferentes rangos de energía.

La integración del modelo óptimo en el marco de trabajo de HAWC permitió su aplicación en el procesamiento de datos reales, facilitando el cálculo de parámetros físicos como el área efectiva y el espectro energético de los rayos cósmicos. Esto no solo mejora la capacidad del observatorio para analizar eventos en el rango energético de 10^{12} a 10^{16} , sino que también abre la puerta a futuras aplicaciones de inteligencia artificial en la astrofísica de altas energías.

1. Rayos cósmicos

A finales del siglo XIX, científicos como Julius Elster y Hans Geitel observaron que los electroskopios se descargaban espontáneamente incluso cuando estaban aislados de fuentes radiactivas conocidas, lo que planteó interrogantes sobre el origen de la radiación responsable de la ionización observada [2]. Estas observaciones fueron corroboradas por Charles Thomson Rees Wilson, quien también notó la descarga espontánea de electroskopios y estudió la ionización de la atmósfera [3]. Estos hallazgos sugirieron la presencia de una radiación ionizante de origen desconocido que permeaba la atmósfera.

En 1912, el físico austriaco Victor Hess realizó una serie de vuelos en globo aerostático para medir la ionización a diferentes altitudes (ver figura 1). Descubrió que la tasa de ionización aumentaba con la altura, concluyendo que una radiación altamente penetrante provenía del espacio exterior [4]. Este descubrimiento marcó el inicio del estudio de los rayos cósmicos y le valió a Hess el Premio Nobel de Física en 1936.

Figura 1

Victor Hess en el globo aerostático.



Nota. Victor Hess durante sus vuelos en globo aerostático en 1912, donde descubrió la existencia de los rayos cósmicos al medir el aumento de la radiación ionizante con la altitud [5].

Posteriormente, científicos como Robert Millikan y Arthur Compton continuaron investigando la naturaleza de esta radiación, acuñando el término “rayos cósmicos”

y estableciendo su origen extraterrestre [6, 7]. Estos estudios iniciales sentaron las bases para comprender la importancia de los rayos cósmicos en la física y la astrofísica, abriendo nuevas áreas de investigación en la detección y análisis de partículas de alta energía.

Actualmente, se consideran a los rayos cósmicos como partículas subatómicas que llegan a la Tierra desde el espacio exterior, con una energía que varía desde 10^9 eV hasta más de 10^{20} eV, convirtiéndolos en mensajeros únicos de fenómenos astrofísicos del universo [8]. Están compuestos principalmente por protones (alrededor del 90 %), seguidos por núcleos de helio (aproximadamente el 9 %) y una pequeña fracción (alrededor del 1 %) de núcleos más pesados, como carbono, oxígeno, hierro y nitrógeno, además de electrones de muy alta energía [9–11].

Su composición química ofrece datos sobre la abundancia de elementos, contribuyendo al entendimiento de la evolución del universo [12] y pueden utilizarse para estudiar la estructura a gran escala del cosmos. Sin embargo, su estudio enfrenta algunos desafíos: la deflexión por campos magnéticos dificulta trazar sus trayectorias hasta las fuentes originales [13], su bajo flujo a altas energías requiere detectores de gran escala y largos períodos de observación [14] y también la reconstrucción de sus propiedades primarias a partir de observaciones de partículas secundarias es compleja y depende de modelos de interacción hadrónica y simulaciones detalladas [15].

El estudio de los rayos cósmicos constituye una herramienta diagnóstica fundamental en física y astrofísica: medir su composición, energía y dirección de llegada permite reconstruir los mecanismos de aceleración que operan en el universo. A partir de su distribución espectral se pueden identificar fuentes donde las partículas alcanzan energías relativistas, tales como los choques de restos de supernova, las nebulosas de viento de púlsar o los chorros relativistas de núcleos activos de galaxias [8, 16]. Las características particulares de estos entornos, descritas con más detalle en la siguiente sección, proporcionan el laboratorio natural para probar teorías de aceleración, transporte y radiación de partículas de alta energía.

Los rayos cósmicos cubren un rango de energías que va desde $\sim 10^{12}$ eV (TeV) hasta valores ultra-altos por encima de 10^{20} eV [17]. Estas cifras superan con creces el límite de $\sqrt{s} = 14$ TeV $\simeq 1,4 \times 10^{13}$ eV alcanzado en los aceleradores terrestres más potentes, como el Large Hadron Collider (LHC). Detectar y analizar partículas en este régimen permite estudiar procesos hadrónicos con energías en el centro de masa de cientos de TeV un dominio que escapa a los experimentos de laboratorio y buscar indicios de física más allá del modelo estándar [18]. En particular, las colisiones atmosféricas producidas por rayos cósmicos ultra-energéticos ($E \gtrsim 10^{18}$ eV) constituyen “aceleradores naturales” que ofrecen acceso directo a la dinámica de las interacciones de alta energía y a los entornos astrofísicos más extremos del universo, como restos de supernova, chorros de núcleos activos de galaxias y estallidos de rayos gamma [19].

1.1 Origen y propagación de los rayos cósmicos

Los rayos cósmicos se originan en diversos entornos astrofísicos, tanto dentro de nuestra galaxia, la Vía Láctea, como más allá de ella. Según su energía y composición, se pueden clasificar en:

- **Rayos cósmicos de origen galáctico:** predominan en energías inferiores a 10^{15} eV, región conocida como la “rodilla” del espectro. Se cree que provienen de fuentes como supernovas, remanentes de supernovas y púlsares [8].
- **Región de transición** ($10^{15} \lesssim E \lesssim 10^{18}$ eV): entre la “rodilla” y el “tobillo” el espectro se hace gradualmente más duro y la composición se vuelve más pesada hasta un segundo cambio de pendiente “segunda rodilla”, $E \sim 4 \times 10^{17}$ eV). En este intervalo coexisten dos componentes: (i) un remanente galáctico que decae con rigidez límite ($E_{\text{máx}} \propto Z$) y (ii) un componente extragaláctico que comienza a ganar protagonismo. Modelos híbridos (p. ej. Gaisser–Stanev–Tilav) atribuyen la parte alta de esta franja a aceleradores galácticos extremos (supernovas en superburbujas) o a vientos de estrellas masivas, mientras que el aporte extragaláctico temprano suaviza la pendiente [20, 21].
- **Rayos cósmicos de origen extragaláctico:** dominan en energías superiores a 10^{18} eV, cerca del “tobillo” del espectro. Se asocian con fenómenos como núcleos activos de galaxias y estallidos de rayos gamma [22].

Para comprender qué objetos astrofísicos pueden acelerar partículas hasta las energías observadas en los rayos cósmicos, es útil considerar la gráfica de Hillas [23] (ver figura 2). Esta gráfica relaciona el tamaño (R) y la intensidad del campo magnético (B) de posibles aceleradores astrofísicos, estableciendo límites máximos de energía que las partículas pueden alcanzar en dichos entornos.

El criterio de Hillas establece que la energía máxima $E_{\text{máx}}$ que una partícula de carga Ze puede adquirir en un acelerador astrofísico está dada por:

$$E_{\text{máx}} = Ze \beta B R, \quad (1.1)$$

de donde Z es el número de carga de la partícula, e es la carga elemental, $\beta = v/c$ es la velocidad del flujo o choque en unidades de la velocidad de la luz, B es la intensidad del campo magnético en el sitio de aceleración y R es el tamaño característico de la región de aceleración.


La ecuación 1.1 representa una condición necesaria para que una partícula sea confinada y acelerada dentro de una región magnética de tamaño R y campo B . Si el radio de Larmor de la partícula excede el tamaño del acelerador ($r_L > R$), la partícula escapará antes de alcanzar energías más altas.

En la gráfica de Hillas, se representan diferentes objetos astrofísicos en un diagrama logarítmico de R versus B , y se trazan líneas diagonales que corresponden a

energías máximas constantes según la ecuación 1.1. Esto permite visualizar qué fuentes son capaces de acelerar partículas hasta ciertas energías.

Figura 2

Gráfica de Hillas para posibles fuentes de rayos cósmicos.



Nota. Gráfica de Hillas que representa la relación entre el tamaño (R) y el campo magnético (B) de diferentes posibles aceleradores astrofísicos. Las líneas diagonales representan las energías máximas E_{max} que pueden alcanzar las partículas según el criterio de Hillas [23].

En la Figura 2 se observan diversos candidatos a fuentes de rayos cósmicos, como remanentes de supernovas, púlsares, núcleos activos de galaxias, cúmulos de galaxias y estallidos de rayos gamma (GRB) que se trata de un fenómeno transitorio que libera chorros relativistas donde las partículas podrían acelerarse hasta energías extremas [24]. Para explicar los rayos cósmicos de ultra alta energía (UHECRs, por sus siglas en inglés), con energías superiores a 10^{18} eV, se requieren fuentes con tamaños y campos magnéticos que permitan alcanzar dichas energías según el criterio de Hillas.

Una vez acelerados, los rayos cósmicos se desplazan por el espacio intergaláctico y galáctico, interactuando con campos magnéticos y con la materia presente. Estas interacciones pueden desviar su trayectoria, alterar la proporción de diferentes tipos de partículas (como protones, núcleos de helio, hierro, entre otros) y modificar la distribución de sus energías. Estos efectos complican significativamente el estudio de su origen y propagación, ya que es necesario considerar cómo estas interacciones influyen en las propiedades observadas de los rayos cósmicos cuando llegan a la Tierra.

1.1.1 Fuentes galácticas

- **Supernovas y remanentes de supernovas:** Estas son las principales fuentes de rayos cósmicos dentro de nuestra galaxia. Las explosiones de supernovas liberan una energía de un orden de 10^{53} ergs [25], creando frentes de choque que

aceleran las partículas. Estas partículas luego escapan del frente de choque y se propagan por la galaxia, interactuando con el medio interestelar. Un ejemplo es el remanente de supernova IC 443, donde se ha observado la aceleración de hadrones en interacciones con las nubes moleculares, que contribuyen a los rayos cósmicos [26].

- **Púlsares:** Un púlsar es una estrella de neutrones altamente magnetizada y en rotación que emite haces de radiación electromagnética. Esta radiación sólo puede observarse cuando el haz apunta hacia la Tierra. La radiación de un púlsar suele observarse en forma de pulsos regulares. Los púlsares se forman a partir de los restos de estrellas masivas tras la explosión de una supernova. Cuando estas estrellas estallan, sus capas exteriores se desprenden y el núcleo colapsa por efecto de la gravedad para formar una estrella de neutrones.

El púlsar PSR J0437-4715 contribuye a los rayos cósmicos a través de la aceleración de pares electrón-positrón en su onda de choque frontal, donde estas partículas alcanzan energías suficientemente altas para contribuir a los leptones de rayos cósmicos observados cerca de la Tierra. Las interacciones de este púlsar con el medio interestelar, caracterizadas por su movimiento y las ondas de choque resultantes, potencian los procesos de reaceleración críticos para generar rayos cósmicos de alta energía [27].

- **Vientos Estelares:** Los vientos estelares son flujos de partículas cargadas que las estrellas, especialmente las más masivas y jóvenes, expulsan al espacio. Estos vientos pueden alcanzar velocidades extremadamente altas y tienen suficiente energía como para influir en su entorno intergaláctico. Cuando una estrella masiva sopla un viento supersónico, ese flujo choca con el gas que la rodea y excava una “burbuja” muy caliente ($T \sim 10^6$ K). En el borde interior se produce un choque que actúa como acelerador natural: las partículas cargadas rebotan una y otra vez y ganan velocidad hasta alcanzar energías de TeV–PeV [28].

Observaciones recientes basadas en trece años de datos de *Fermi*-LAT muestran que los cúmulos estelares jóvenes transfieren entre el 1 % y el 10 % de la potencia mecánica de sus vientos a la producción de rayos cósmicos, especialmente en regiones como el Ridge Molecular de Vela [29]. Estos resultados confirman que los vientos estelares, incluso en ausencia de supernovas o púlsares, son fuentes eficientes de aceleración de partículas.

Otra investigación denota el Cocoon Cygnus, en la aceleración de rayos cósmicos galácticos a energías extremadamente altas, superiores a 100 TeV. Estos cúmulos, ricos en estrellas masivas, generan vientos estelares que forman burbujas de viento propicias para la aceleración de partículas. Notablemente, el Cocoon Cygnus fue observado emitiendo un fotón de 1.4 PeV, lo cual fue registrado por LHAASO, reforzando la idea de que estos cúmulos contribuyen significativamente a la región de la rodilla del espectro de rayos cósmicos [30].

- **Superburbujas:**

Las superburbujas son vastas estructuras formadas en el medio interestelar por los vientos estelares y las explosiones de supernovas de estrellas masivas en asociaciones OB. Estas estructuras, que pueden extenderse cientos de años luz, se caracterizan por sus cavidades centrales de baja densidad rodeadas de densos bordes de material acumulado. Son cruciales en la dinámica galáctica, influyendo en la formación estelar y la dispersión de elementos químicos a través de sus poderosas ondas de choque, que también juegan un papel fundamental en la aceleración de los rayos cósmicos.

El estudio de Higdon and Lingenfelter examina detalladamente el origen de los rayos cósmicos galácticos, destacando el papel de las superburbujas, que se forman a partir de explosiones de supernovas en asociaciones OB [31]. Estas superburbujas son esenciales en la aceleración de los rayos cósmicos debido a su rica metalicidad y a la potente dinámica de los vientos estelares. El estudio proporciona evidencia convincente de que una gran parte de las supernovas tipo II y Ib/c, que ocurren en estas superburbujas, son responsables de la aceleración de los rayos cósmicos. Además, analiza cómo los residuos metálicos en estas regiones contribuyen significativamente a la composición química observada en los rayos cósmicos galácticos.

1.1.2 *Fuentes extragalácticas*

Los rayos cósmicos extragalácticos, particularmente aquellos de energía entre 10^{15} eV a 10^{20} eV, se cree que se originan en fuentes astrofísicas poderosas fuera de la Vía Láctea. Los núcleos activos de galaxias (AGNs), con sus agujeros negros supermasivos y chorros relativistas, se encuentran entre los principales candidatos para acelerar partículas a energías del orden de 10^{18} eV y superiores [32, 33]. De manera similar, los estallidos de rayos gamma (GRBs), las explosiones más energéticas del universo, se piensa que generan ondas de choque capaces de acelerar astropartículas a altas energías [34, 35]. Las galaxias con brotes estelares, conocidas por su intensa formación estelar y numerosas supernovas, también proporcionan entornos donde las astropartículas pueden ser aceleradas a energías del orden de 10^{15} eV mediante la actividad colectiva de supernovas y campos magnéticos [36].

Además de estas fuentes, los choques de gran escala que ocurren durante la formación de cúmulos de galaxias también podrían contribuir a la población de rayos cósmicos del orden de 10^{15} eV y superiores [37]. Estos choques, que resultan de la interacción del gas y la materia oscura, pueden acelerar partículas a través de vastas distancias. La interacción de los rayos cósmicos con la radiación de fondo cósmico de microondas (CMB) lleva al límite de Greisen-Zatsepin-Kuzmin, que limita la energía máxima de estas partículas [38].

En general, el origen de los rayos cósmicos extragalácticos es probablemente multifacético, involucrando una combinación de AGNs, GRBs, galaxias con brotes estelares y choques de gran escala. Las investigaciones en curso continúan explorando estas posibilidades, refinando nuestra comprensión de cómo se producen estas enigmáticas

partículas y cómo viajan a través del universo [39].

1.1.3 *Mecanismos de aceleración*

Las propiedades físicas de los rayos cósmicos están determinadas por su energía, masa, carga eléctrica y momento, lo que influye en su interacción con campos magnéticos y materiales. Al ser partículas cargadas, sus trayectorias son afectadas por los campos magnéticos presentes en el medio interestelar e intergaláctico, causando que sigan trayectorias no lineales y lleguen a la Tierra desde direcciones prácticamente isotrópicas, lo que dificulta la identificación de sus fuentes originales [40]. Además, al interactuar con la materia, pueden ionizar átomos, producir radiación secundaria y generar cascadas de partículas, interacciones fundamentales para su detección y estudio [41].

Los mecanismos que permiten a las partículas alcanzar energías tan elevadas son objeto de intensa investigación. Entre los principales mecanismos se encuentran:

1. Aceleración de Fermi

La aceleración de Fermi es un mecanismo fundamental en la astrofísica de partículas que explica cómo las partículas cargadas pueden alcanzar energías extremadamente altas a través de interacciones con campos magnéticos en movimiento. Propuesto originalmente por Enrico Fermi en 1949, este proceso ha sido refinado y adaptado para explicar la aceleración de rayos cósmicos en diversos entornos astrofísicos.

Aceleración de Fermi de Segundo Orden

En su formulación inicial, conocida como aceleración de Fermi de segundo orden, Fermi propuso que las partículas cargadas pueden ganar energía mediante colisiones estocásticas con “espejos magnéticos” en movimiento, que representan irregularidades o nubes magnetizadas en el medio interestelar. Estas nubes se mueven aleatoriamente con una velocidad típica V , y las partículas son reflejadas por los campos magnéticos asociados a ellas.

El proceso es esencialmente estocástico: las partículas pueden ganar o perder energía dependiendo de la orientación y velocidad relativa de las nubes. Sin embargo, en promedio, hay una ganancia neta de energía. Utilizando transformaciones relativistas, se puede demostrar que la energía media ganada por la partícula después de una colisión es proporcional a $(V/c)^2$, donde c es la velocidad de la luz.

La expresión para el cambio de energía en una sola colisión es:

$$\frac{\Delta E}{E} = \frac{2V}{c} \cos\theta + 2\frac{V^2}{c^2}, \quad (1.2)$$

donde θ es el ángulo entre la dirección de la partícula y la normal al espejo magnético. Al promediar sobre todas las posibles direcciones y asumir una distribución isotrópica,

se obtiene que el incremento medio de energía es de segundo orden en V/c :

$$\left\langle \frac{\Delta E}{E} \right\rangle = \frac{8}{3} \frac{V^2}{c^2} . \quad (1.3)$$

Este resultado indica que el proceso es relativamente ineficiente cuando V es mucho menor que c , lo cual es típico en el medio interestelar, donde $V/c \approx 10^{-4}$. Además, la distribución de energías de las partículas se ensancha con el tiempo debido a la naturaleza estocástica del proceso, lo que requiere un tratamiento detallado mediante la ecuación de Fokker-Planck.

Aceleración de Fermi de primer Orden

La aceleración por ondas de choque difusivas, también conocida como aceleración de Fermi de primer orden, es un mecanismo fundamental para explicar cómo los rayos cósmicos alcanzan energías extremadamente altas en el universo. Este proceso fue desarrollado para superar las limitaciones de la versión original de Fermi (aceleración de segundo orden), proporcionando una forma mucho más eficiente de acelerar partículas cargadas en entornos astrofísicos [42].

Este mecanismo ocurre en ondas de choque astrofísicas, como las asociadas con remanentes de supernovas, vientos estelares y chorros relativistas. En un frente de choque, el material antes y después del choque se mueve a velocidades diferentes. Las partículas cargadas cruzan repetidamente el frente de choque, ganando energía en cada cruce debido a la diferencia de velocidades entre ambas regiones.

Ganancia de Energía

La ganancia media de energía en este caso es:

$$\left\langle \frac{\Delta E}{E} \right\rangle = \frac{4}{3} \left(\frac{V_s}{c} \right) , \quad (1.4)$$

donde V_s es la velocidad del choque y c es la velocidad de la luz. Este resultado indica una dependencia lineal en V_s/c , a diferencia de la dependencia cuadrática en la aceleración de segundo orden. Dado que V_s puede ser una fracción significativa de c en estos entornos, la aceleración es mucho más rápida y eficiente.

En la Figura 3 se ilustra cómo las partículas cargadas son reflejadas repetidamente a través del frente de choque, ganando energía en cada cruce. Las partículas se difunden casi isotrópicamente en ambas regiones, lo que les permite atravesar el frente múltiples veces y aumentar su energía de forma significativa.

En ese diagrama, V_u denota la velocidad del plasma que llega al frente desde la región (upstream), mientras que V_d es la velocidad a la que el plasma fluye (downstream) después de cruzar el choque. La razón:

$$r \equiv \frac{V_u}{V_d},$$


se conoce como razón de compresión; para un choque fuerte no relativista en un gas monoatómico suele valer $r \simeq 4$. Bajo la hipótesis de difusión isotrópica y pérdidas mínimas, la teoría de aceleración difusiva de primer orden predice que el espectro diferencial de energías adopta una ley de potencias

$$n(E) dE \propto E^{-\gamma} dE, \quad \text{con} \quad \boxed{\gamma = \frac{r+2}{r-1}}.$$

Para $r \simeq 4$ resulta $\gamma \approx 2$, valor que—modificado por los procesos de propagación en la Galaxia—conduce al índice observado de los rayos cósmicos ($\sim 2,6$). Cuanto mayor es r , más plano (duro) es el espectro; valores menores de r producen espectros más empinados [42–44].

Figura 3

Ilustración del mecanismo de aceleración de Fermi de primer orden en una onda de choque.



Nota. Ilustración del mecanismo de aceleración de Fermi de primer orden en una onda de choque [45].

Los SNRs son sitios ideales para la aceleración de Fermi de primer orden. Las ondas de choque generadas en la explosión se propagan a velocidades de miles de kilómetros por segundo, creando condiciones propicias para la aceleración eficiente de partículas [44].

El éxito de este mecanismo depende críticamente de la capacidad de las partículas para ser dispersadas por fluctuaciones en el campo magnético. Estas fluctuaciones son generadas por las propias partículas energéticas a través de inestabilidades, como la excitación de ondas de Alfvén. El proceso de dispersión evita que las partículas sigan simplemente las líneas del campo magnético y escapen del área de aceleración,

permitiendo múltiples cruces y una ganancia significativa de energía.

Al combinar la ganancia de energía por cruce y la probabilidad de escape, se puede derivar el espectro energético de las partículas aceleradas. Suponiendo que la energía de una partícula después de m cruces es:

$$E_m = E_0 \left(1 + \frac{4 V_s}{3 c}\right)^m \approx E_0 \exp\left(\frac{4 V_s}{3 c} m\right), \quad (1.5)$$

donde E_0 es la energía inicial. La cantidad de partículas que alcanzan al menos una energía E sigue un espectro de potencias, lo que implica que el espectro diferencial de energías es:

$$n(E) = \frac{dN}{dE} \propto E^{-2}. \quad (1.6)$$

Este resultado es consistente con las observaciones de rayos cósmicos que muestran un espectro cercano a $E^{-2.6}$, lo que respalda la relevancia de este mecanismo en la aceleración de partículas de alta energía.

2. Aceleración por reconexión magnética

La reconexión magnética es un proceso fundamental en plasmas astrofísicos, en el cual las líneas de campo magnético se rompen y reconectan, liberando grandes cantidades de energía almacenada en los campos magnéticos. Este fenómeno juega un papel crucial en la aceleración de partículas cargadas a energías altas, y es relevante en diversos entornos astrofísicos como fulguraciones solares, magnetósferas planetarias, remanentes de supernovas y núcleos activos de galaxias [46].

Durante la reconexión magnética, el cambio topológico de las líneas de campo magnético induce campos eléctricos que pueden acelerar partículas a altas energías. El proceso puede ser descrito mediante las ecuaciones de la magnetohidrodinámica (MHD) resistiva. La ecuación de inducción magnética es:

$$\frac{\partial \mathbf{B}}{\partial t} = \nabla \times (\mathbf{v} \times \mathbf{B}) - \nabla \times (\eta \nabla \times \mathbf{B}), \quad (1.7)$$

donde $\mathbf{B}$ es el campo magnético, $\mathbf{v}$ es la velocidad del plasma y η es la resistividad del plasma. El término $\eta \nabla \times \mathbf{B}$ representa los efectos resistivos que permiten la reconexión de las líneas de campo.

En condiciones ideales ($\eta = 0$), el plasma es idealmente conductor y las líneas de campo magnético se congelan en el plasma (teorema de Alfvén). Sin embargo, en regiones donde la resistividad es significativa, como en las capas de corriente, se permite la reconexión magnética.

El modelo de Sweet-Parker [47, 48] proporciona una descripción básica de la reconexión estacionaria en MHD resistiva. La velocidad de reconexión v_{rec} en este modelo

está dada por:

$$v_{\text{rec}} = v_A S^{-1/2}, \quad (1.8)$$

donde v_A es la velocidad de Alfvén y S es el número de Lundquist definido como $S = \frac{Lv_A}{\eta}$, siendo L la longitud característica de la capa de corriente. El número de Lundquist representa la relación entre los tiempos de difusión resistiva y de advección magnética.

No obstante, el modelo de Sweet-Parker predice velocidades de reconexión demasiado lentas para explicar fenómenos astrofísicos observados, como las fulguraciones solares. Para superar esta limitación, se han propuesto modelos como el modelo de reconexión de Petschek [49], que permite velocidades de reconexión más rápidas mediante la formación de regiones de difusión más pequeñas y la presencia de ondas de choque magnéticas.

En el contexto de la aceleración de partículas, la reconexión magnética genera campos eléctricos no potenciales en las regiones de difusión, dado por:

$$\mathbf{E} = -\mathbf{v} \times \mathbf{B} + \eta \mathbf{J}, \quad (1.9)$$

donde $\mathbf{E}$ es el campo eléctrico y $\mathbf{J}$ es la densidad de corriente. En las regiones donde η es significativa, el término resistivo $\eta \mathbf{J}$ permite que exista un campo eléctrico paralelo al campo magnético, lo cual es esencial para la aceleración eficiente de partículas.

Las partículas cargadas pueden ser aceleradas a altas energías mediante varios mecanismos en regiones de reconexión:

- **Aceleración directa:** Las partículas son aceleradas directamente por el campo eléctrico paralelo en la región de difusión. La ganancia de energía está dada por $\Delta E = q \int \mathbf{E} \cdot d\mathbf{l}$, donde q es la carga de la partícula y la integral se realiza a lo largo de la trayectoria de la partícula.
- **Aceleración por contracción de islas magnéticas:** En reconexión turbulenta, se forman estructuras magnéticas tipo isla que pueden contraerse, acelerando partículas por conservación del momento adiabático [50].
- **Aceleración por efecto Fermi de primer orden:** Las partículas reflejadas por los extremos de las islas magnéticas en contracción pueden ganar energía de manera similar al mecanismo de Fermi de primer orden [51].
- **Aceleración estocástica:** En reconexión turbulenta, las partículas pueden ganar energía mediante interacciones aleatorias con fluctuaciones del campo magnético, similar al mecanismo de Fermi de segundo orden [52].

La eficiencia de la aceleración por reconexión magnética depende de varios factores, incluyendo la velocidad de reconexión, la estructura del campo magnético, la

presencia de turbulencia y las condiciones del plasma. Este mecanismo es particularmente relevante en entornos donde las condiciones permiten reconexión rápida, como en los AGNs y en las fulguraciones solares.

Estudios teóricos y simulaciones numéricas han demostrado que la reconexión magnética puede acelerar partículas hasta energías relativistas, contribuyendo a la población de rayos cósmicos y a las emisiones observadas en rayos X y gamma [53].

1.2 Espectro de energía de los rayos cósmicos

El espectro de rayos cósmicos describe cómo varía el flujo de partículas con la energía y revela rasgos distintivos la rodilla ($E \sim 3 \times 10^{15}$ eV) y el tobillo ($E \sim 4 \times 10^{18}$ eV) cuya localización y forma dependen de la población de fuentes y de los mecanismos de aceleración involucrados [17]. Aunque las trayectorias de los rayos cósmicos se dispersan en los campos magnéticos galácticos e intergalácticos y ello impide identificar su origen evento por evento, la posición de la rodilla coincide con el límite de energía que pueden impartir los remanentes de supernova ($Z \times 10^{14-15}$ eV), mientras que el tobillo marca la transición de un componente predominantemente galáctico a otro extragaláctico [19, 20]. Por tanto, la morfología del espectro y su evolución con la composición constituyen una herramienta indirecta, pero cuantitativa, para acotar las propiedades de las fuentes y sus procesos de aceleración.

La relación entre el flujo de partículas en función de la energía puede ser representada mediante una ley de potencia:

$$\frac{d\Phi}{dE} \propto E^{-\gamma}, \quad (1.10)$$

donde el índice espectral γ varía en diferentes rangos de energía. En el rango de energías de ~ 1 GeV hasta ~ 1 PeV, el índice espectral es aproximadamente $\gamma \approx 2,7$, indicando que el flujo decrece rápidamente con la energía [54].

En la Figura 4, se observan claramente las transiciones en el espectro, conocidas como la ‘rodilla’ (a ~ 1 PeV), la ‘segunda rodilla’ y el ‘tobillo’ (a ~ 10 EeV). Cada una de estas características indica cambios en la pendiente del espectro, sugiriendo diferentes orígenes y mecanismos de aceleración para las partículas en estos rangos de energía. El enfoque de este trabajo de investigación es en partículas con energía intermedia cercanas a la rodilla.


■ Rayos cósmicos de baja energía

Este rango abarca energías hasta el orden de 10^{15} eV (1 PeV). Los rayos cósmicos en esta categoría generalmente provienen de dentro de nuestra galaxia, la Vía Láctea, y se cree que son acelerados por los remanentes de supernovas, púlsares, vientos estelares y regiones de formación estelar [54].

■ Rango de Energía entre 100 GeV y 1 PeV

Figura 4

Representación del espectro de energía de rayos cósmicos multiplicado por $E^{2.6}$



Nota. Representación del espectro de energía de rayos cósmicos multiplicado por $E^{2.6}$, mostrando la variación del flujo con la energía. Los puntos de datos provienen de diversas colaboraciones y experimentos, como AMS, CREAM, KASCADE, HAWC, entre otros. Se destacan las regiones conocidas como la ‘rodilla’, la ‘segunda rodilla’ y el ‘tobillo’, que indican cambios significativos en la pendiente del espectro, sugiriendo diferentes orígenes y mecanismos de aceleración para las partículas en estas energías [55].

El rango de energía entre 100 GeV y 1 PeV es de particular interés, ya que corresponde a la transición entre las fuentes de rayos cósmicos de baja energía y las que contribuyen a energías cercanas a la rodilla. En este rango, se considera que los rayos cósmicos son predominantemente de origen galáctico y están compuestos principalmente por protones y núcleos ligeros [56].

Los SNRs han sido propuestos como los principales aceleradores de rayos cósmicos galácticos en este rango de energías. A través del mecanismo de aceleración por ondas de choque difusivas (aceleración de Fermi de primer orden), las partículas pueden ser aceleradas hasta energías del orden de ~ 100 TeV [57]. Sin embargo, alcanzar energías cercanas a 1 PeV requiere condiciones especiales, y aún es objeto de investigación si los SNRs pueden ser responsables de la aceleración hasta estas energías [58].

El observatorio HAWC es un detector de rayos gamma y rayos cósmicos que opera en el rango de energía de ~ 100 GeV a más de 100 TeV. HAWC es particularmente sensible a rayos gamma de altas energías y ha contribuido significativamente al estudio de las fuentes galácticas en este rango energético [59], las cuales son indicativas de regiones donde se aceleran partículas hasta energías del orden de

los PeV. El descubrimiento de varios aceleradores galácticos por parte de HAWC ha proporcionado evidencia de que existen fuentes capaces de acelerar protones y núcleos hasta energías cercanas a 1 PeV [60].

Además, HAWC ha contribuido al estudio de la difusión de rayos cósmicos en el medio interestelar y a la comprensión de los mecanismos de aceleración en distintos objetos astrofísicos, como nebulosas de viento de púlsar, regiones de formación estelar y asociaciones OB [61].

■ Rayos cósmicos de energía intermedia o rodilla

Este segmento ocurre en torno a energías de 10^{15} a 10^{17} eV. La rodilla del espectro representa un punto donde la pendiente del espectro cambia significativamente, indicando una disminución más rápida en la tasa de rayos cósmicos con el aumento de energía.

Varias hipótesis han sido propuestas para explicar la rodilla en el espectro de rayos cósmicos. Una de ellas sugiere un límite en la aceleración de partículas en los SNRs, que no podrían impulsar eficientemente partículas más allá de ciertas energías [62]. Otra hipótesis propone que a energías altas, los rayos cósmicos escapan con mayor facilidad del campo magnético galáctico, disminuyendo su confinamiento y, por ende, su flujo [63]. Finalmente, se ha observado que la composición de los rayos cósmicos tiende a volverse más pesada cerca de la rodilla, pasando de protones a núcleos más pesados, lo cual podría modificar el espectro [64].

Investigaciones recientes han empleado observatorios como el Pierre Auger para analizar la composición de los rayos cósmicos en esta región, sugiriendo una mezcla de núcleos ligeros y pesados, y proporcionando evidencia de la influencia de fuentes extragalácticas [65–67].

■ Rayos cósmicos de alta energía o tobillo

Este rango abarca energías superiores a 10^{18} eV y se extiende hasta más de 10^{20} eV. Los rayos cósmicos de este espectro son de particular interés debido a su inmensa energía. Se cree que su origen es extragaláctico, posiblemente de fuentes como AGNs, cuásares o choques de grandes estructuras cósmicas [68].

1.2.1 Composición química de los rayos cósmicos

La composición química de los rayos cósmicos es un aspecto fundamental para comprender su origen, los mecanismos de aceleración y los procesos de propagación en el medio interestelar e intergaláctico. Los rayos cósmicos están compuestos por una variedad de núcleos atómicos, desde protones hasta núcleos de elementos pesados como el hierro. El estudio detallado de su composición permite inferir información sobre las fuentes astrofísicas que los producen y las condiciones físicas en esas regiones [69].

La composición química de los rayos cósmicos varía con la energía. A energías bajas ($\sim$ MeV a $\sim$ TeV), los rayos cósmicos son medidos directamente mediante detec-

tores en satélites y globos estratosféricos, lo que permite una determinación precisa de su composición. A energías más altas (por encima de ~ 100 TeV), la composición debe inferirse indirectamente a través de la observación de cascadas atmosféricas extensas, lo cual introduce mayores incertidumbres [70].

La fracción relativa de cada especie nuclear no es constante, sino que exhibe una evolución suave con la energía: por debajo de $\sim 10^{14}$ eV domina un componente ligero (protones y helio), alrededor de la “rodilla” la mezcla se hace progresivamente más pesada y, por encima del “tobillo”, vuelve a prevalecer un componente ligero extragaláctico [17, 71].

Para estudiar esta transición se utilizan dos técnicas complementarias. En el rango de MeV decenas de TeV, el flujo es lo bastante alto como para medir cada núcleo de forma directa con detectores en satélites y globos estratosféricos, lo que ofrece una determinación precisa de abundancias isotópicas. Por encima de $\sim 10^{14-15}$ eV el flujo disminuye drásticamente (1 partícula m^{-2} año^{-1}), de modo que la composición debe inferirse indirectamente a partir de observables de las cascadas atmosféricas extensas, profundidad del máximo (X_{max}), número de muones, perfil de Cherenkov, etc. Lo cual introduce incertidumbres asociadas a los modelos hadrónicos [72].

Una forma de profundizar en el estudio de la composición es comparar las abundancias relativas de los elementos en los rayos cósmicos con las del sistema solar. En la Figura 5, se muestra esta comparación normalizada respecto al carbono ($C = 100$). Se observa que, aunque ambos conjuntos presentan el efecto de números atómicos pares e impares (los elementos con número atómico par son más abundantes), existen diferencias significativas entre ellos.

En particular, los rayos cósmicos exhiben una mayor abundancia relativa de elementos ligeros como litio (Li), berilio (Be) y boro (B), así como de elementos como escandio (Sc), titanio (Ti), vanadio (V), cromo (Cr) y manganeso (Mn), en comparación con el sistema solar. Este enriquecimiento se debe a que estos elementos son producidos durante la propagación de los rayos cósmicos a través del medio interestelar mediante procesos de espallación nuclear de núcleos más pesados como el carbono y el oxígeno[54]. Además, los rayos cósmicos muestran una mayor proporción de núcleos con $Z > 1$ en comparación con el material solar, donde el hidrógeno es el elemento más abundante.


Rangos de Energía Baja a Intermedia

En el rango de energías de ~ 1 GeV a ~ 100 TeV, los rayos cósmicos están dominados por protones ($\sim 90\%$), seguido de núcleos de helio ($\sim 9\%$), y una pequeña fracción de núcleos más pesados ($\sim 1\%$). La abundancia relativa de los elementos en los rayos cósmicos difiere de la composición solar, mostrando un enriquecimiento en elementos ligeros como el litio, berilio y boro, así como en elementos pesados como el hierro [73].

Este enriquecimiento se debe a procesos de espalación nuclear durante la propagación de los rayos cósmicos en el medio interestelar. Los núcleos más pesados interactúan con el gas interestelar, produciendo núcleos más ligeros y estables. Por ejemplo, los núcleos de carbono y oxígeno pueden fragmentarse para formar litio, berilio y boro,

Figura 5

Comparación de las abundancias relativas de elementos en los rayos cósmicos y en el sistema solar.



Nota. Comparación de las abundancias relativas de elementos en los rayos cósmicos (símbolos llenos y líneas sólidas) y en el sistema solar (símbolos abiertos), normalizadas respecto al carbono ($C = 100$). Se observa un enriquecimiento de elementos ligeros y elementos producto de espallación en los rayos cósmicos [54].

elementos que son escasos en la composición solar [40].

Rangos de Energía Alta

A energías cercanas a la rodilla del espectro (~ 1 PeV), se observa una tendencia hacia una composición más pesada. Estudios realizados por observatorios como IceTop y KASCADE-Grande indican que la fracción de núcleos pesados como silicio e hierro aumenta con la energía, mientras que la fracción de protones disminuye [64].

Esta tendencia sugiere que las fuentes galácticas de rayos cósmicos tienen límites en la energía máxima de aceleración que dependen del número de carga (Z) de los núcleos. Según el criterio de rigidez, la energía máxima es proporcional a Z , lo que implica que los núcleos más pesados pueden ser acelerados a energías más altas que los protones en las mismas condiciones [74].

A energías superiores al tobillo del espectro (~ 10 EeV), se cree que los rayos cósmicos son predominantemente extragalácticos. Observaciones del Observatorio Pierre Auger indican que la composición en este rango energético es mixta, con una posible tendencia hacia núcleos más pesados, aunque existe debate debido a las incertidumbres en los modelos de interacción hadrónica [75].

1.3 Lluvias Atmosféricas Extendidas (EAS)

En el estudio de los rayos cósmicos, se distingue entre partículas primarias y secundarias según su origen y las interacciones que experimentan al llegar a la Tierra. Las partículas primarias son aquellas que se originan en el espacio exterior y llegan a la atmósfera terrestre sin haber sufrido interacciones significativas con otros materiales. Estas incluyen protones, núcleos pesados y electrones, que conforman la radiación cósmica galáctica y extragaláctica [76]. Al interactuar con las moléculas de la atmósfera terrestre, las partículas primarias generan nuevas partículas secundarias, como piones, kaones, muones, neutrinos, fotones y pares electrón-positrón, constituyendo la radiación cósmica secundaria [77]. La detección de rayos cósmicos en la superficie terrestre se basa principalmente en la observación de estas partículas secundarias producidas durante las lluvias atmosféricas extensas.

Las lluvias atmosféricas extendidas (EAS, por sus siglas en inglés) son cascadas de partículas secundarias producidas cuando un rayo cósmico interactúa con los núcleos de los átomos en la atmósfera terrestre. Estas interacciones inician una serie de procesos que resultan en una avalancha de partículas que pueden abarcar varios kilómetros cuadrados al llegar a la superficie terrestre [78].

Durante una EAS, las partículas que se generan en una cascada de rayos cósmicos se dividen en tres categorías principales:

Componente electromagnética: está compuesta por electrones, positrones y fotones. Para los rayos cósmicos primarios hadrónicos, esta componente surge principalmente del decaimiento de piones neutros en fotones ($\pi^0 \rightarrow \gamma\gamma$). Los fotones producidos en la colisión inicial pueden generar pares de electrones y positrones a través del proceso conocido como producción de pares $\gamma \rightarrow e^+e^-$. Estas partículas, a su vez, pueden producir más fotones a través de la radiación de frenado o bremsstrahlung $e^\pm \rightarrow e^\pm\gamma$. Este proceso de producción de pares y bremsstrahlung puede repetirse muchas veces, formando la parte electromagnética de la cascada [9].


Componente muónica: los muones en la cascada son producidos principalmente por el decaimiento de piones ($\pi^\pm \rightarrow \mu^\pm + \nu_\mu$) y kaones cargados ($K^\pm \rightarrow \mu^\pm + \nu_\mu$), que son mesones generados en la cascada hadrónica. Son partículas que tienen una masa mayor que los electrones, poseen una alta capacidad de penetración en la materia y casi no interactúan, por lo que pueden llegar al suelo sin interactuar [80].

Componente hadrónica: Esta componente está compuesta por partículas pertenecientes a la familia de los hadrones, entre las que se incluyen protones, neutrones, piones, mesones encantados, etc. Estas partículas se generan directamente durante la colisión inicial, siguiendo el eje de la lluvia. Este fenómeno produce el efecto conocido como “leading particle”. Además, se generan en colisiones subsecuentes entre los hadrones y los núcleos atmosféricos [77].

Cada EAS exhibe un desarrollo longitudinal y un desarrollo lateral que reflejan la evolución espacial de estas tres componentes en la atmósfera.

Figura 6

La cascada atmosférica y sus componentes: electromagnética, muónica y hadrónica.



Nota. La cascada atmosférica presenta tres componentes: electromagnética, muónica y hadrónica. La electromagnética, predominante, puede originarse de las otras dos. Mientras la muónica se mantiene constante, la hadrónica domina la región central de la cascada [79].

1.3.1 Desarrollo longitudinal

El perfil longitudinal describe la evolución del número de partículas de la lluvia en función de la profundidad atmosférica X (g cm^{-2}). Después de la primera colisión hadrónica, la cascada crece hasta alcanzar un máximo X_{max} ; a partir de ahí el número de partículas decrece por pérdidas de energía y absorción.

Experimentalmente se comprueba que este comportamiento se ajusta con gran precisión a la parametrización de Gaisser–Hillas [81]:


$$N(X) = N_{\text{max}} \left(\frac{X - X_0}{X_{\text{max}} - X_0} \right)^{\frac{X_{\text{max}} - X_0}{\lambda}} \exp \left(-\frac{X_{\text{max}} - X}{\lambda} \right), \quad (1.11)$$

donde X_0 representa la profundidad de la primera interacción y λ es una escala que depende de la masa y la energía del primario.

La Fig. 7 muestra el perfil longitudinal promedio de lluvias con $E > 10^{18,8}$ eV medido por el telescopio de fluorescencia del Observatorio Pierre Auger. La función de Gaisser–Hillas respalda su uso en la reconstrucción de energía y en la determinación de $X_{\max}$ [82].

Figura 7

Perfil longitudinal medio (Auger).



Nota. Perfil longitudinal medio de lluvias atmosféricas ultra-energéticas simuladas con el marco de trabajo del Observatorio Pierre Auger. Las curvas continuas muestran el perfil generado (MC) para protones (azul) e hierro (rojo) en el rango $10^{18,8}$ – $10^{19,2}$ eV; los símbolos indican el perfil reconstruido a partir de la señal de fluorescencia. Las intensidades se han normalizado al máximo $(dE/dX)_{\max}$ y la profundidad se expresa como $X - X_{\max}$. El panel inferior presenta la razón Reconstruido/Simulado, que permanece dentro de $\pm 5\%$ excepto en la parte muy temprana y en la cola de la cascada. Tomada de [82].

1.3.2 Desarrollo lateral

La distribución lateral describe cómo varía la densidad de partículas $\rho(r)$ a una distancia r perpendicular al eje de la cascada. Para el componente electromagnético se emplea habitualmente la función de Nishimura–Kamata–Greisen (NKG) [83, 84]:

$$\rho(r) = N_e \frac{C(s)}{r_M^2} \left(\frac{r}{r_M} \right)^{s-2} \left(1 + \frac{r}{r_M} \right)^{s-4,5}, \quad (1.12)$$

donde r_M es el radio de Molière y s el parámetro de edad de la cascada.

Ajustes NKG a datos de detectores de superficie muestran que la pendiente de la curva en el rango 100–1500 m codifica información sobre la masa del primario: las lluvias iniciadas por protones presentan distribuciones más suaves que las inducidas por núcleos de hierro, mientras que lluvias fotónicas exhiben pendientes aún más pronunciadas [85]. Esta dependencia se explota para estimar la composición química en análisis de gran estadística.

1.4 Métodos de Detección de Rayos Cósmicos

Detección directa

La detección directa de rayos cósmicos implica la observación de partículas primarias antes de que interactúen con la atmósfera terrestre. Este método se lleva a cabo utilizando instrumentos ubicados en globos estratosféricos y satélites, permitiendo la medición precisa de las propiedades de los rayos cósmicos en el espacio exterior.

Los satélites equipados con detectores de rayos cósmicos orbitan la Tierra y miden los rayos cósmicos primarios en el espacio, evitando así los efectos de la atmósfera terrestre. Entre los ejemplos destacados se encuentra el Espectrómetro Magnético Alfa (AMS-02), que está montado en la Estación Espacial Internacional. El AMS-02 utiliza un potente imán y diversos detectores para medir la energía, el tipo de partícula y la dirección de los rayos cósmicos, buscando también señales de antimateria y materia oscura [86]. Otro ejemplo es el experimento PAMELA (Payload for Antimatter Matter Exploration and Light-nuclei Astrophysics), que ha contribuido significativamente al estudio de la antimateria y la composición de los rayos cósmicos [87].

Detección indirecta

La detección indirecta de rayos cósmicos se basa en la observación de partículas secundarias producidas cuando los rayos cósmicos primarios interactúan con la atmósfera terrestre. Este método incluye varias técnicas que permiten estudiar los extensos sucesos de lluvia atmosférica causados por rayos cósmicos de alta energía.

■ Detectores Cherenkov atmosféricos

Utilizan telescopios que observan los destellos de luz Cherenkov en el cielo nocturno, generados por las cascadas de partículas en la atmósfera terrestre. Estos detectores son esenciales para estudiar rayos cósmicos y rayos gamma de muy alta energía. Ejemplos destacados incluyen el Sistema Estereoscópico de Alta Energía

(H.E.S.S.) y el Sistema de Telescopios de Imágenes de Radiación de Muy Alta Energía (VERITAS) [88, 89].

■ Detectores de Centelleo

Los detectores de centelleo utilizan materiales que emiten luz (centellean) cuando son impactados por partículas cargadas. Estos detectores son efectivos para medir la energía y la dirección de las partículas secundarias en lluvias atmosféricas. El arreglo de Telescopios y el Observatorio Pierre Auger son ejemplos prominentes que utilizan detectores de centelleo para estudiar rayos cósmicos de alta energía [90, 91].

■ Detectores Cherenkov de Agua

Emplean grandes volúmenes de agua como medio para la producción de radiación Cherenkov por partículas secundarias que atraviesan el agua a velocidades superiores a la velocidad de la luz en este medio. Los fotomultiplicadores ubicados alrededor del tanque de agua detectan la luz emitida. Este tipo de detectores es altamente efectivo para medir partículas de alta energía y se utiliza en instalaciones como el Observatorio de Rayos Gamma HAWC y el Observatorio Pierre Auger [92, 93].

■ Detectores de Fluorescencia

Los detectores de fluorescencia observan la luz ultravioleta tenue producida cuando los rayos cósmicos interactúan con las moléculas de nitrógeno en la atmósfera. Estos detectores pueden proporcionar información precisa sobre la energía y la dirección de los rayos cósmicos. Ejemplos destacados incluyen el Observatorio Pierre Auger y el experimento Fly's Eye, que han sido fundamentales para el estudio de los rayos cósmicos de ultra alta energía [94].

■ Detectores de Muones

Los detectores de muones miden los muones, que son partículas secundarias producidas en las lluvias atmosféricas de rayos cósmicos. Los muones pueden penetrar profundamente en el suelo, por lo que estos detectores a menudo se encuentran en laboratorios subterráneos. Ejemplos incluyen el Observatorio Kamioka (Super-Kamiokande) y el Observatorio de Neutrinos IceCube, que utilizan detectores de muones, aprovechando el efecto Cherenkov para su detección, con el fin de estudiar tanto los rayos cósmicos como los neutrinos de alta energía [95, 96].

2.El Observatorio HAWC

El observatorio HAWC (High Altitude Water Cherenkov) es un observatorio de medición indirecta diseñado para el estudio de rayos gamma. Ubicado en Puebla, México, a 4.100 metros sobre el nivel del mar, en la falda del volcán Sierra Negra, el Observatorio HAWC es un referente en la observación de rayos gamma y cósmicos. Este observatorio, gracias a la rotación terrestre, HAWC puede observar hasta dos tercios del cielo, utilizando detectores cherenkov de agua para capturar las partículas de lluvias de cascadas atmosféricas extendidas [1].

HAWC se compone de un conjunto de 300 detectores Cherenkov de agua (WCD, por sus siglas en inglés), abarcando un área total de 20,000 m² (ver figura 8). Cada WCD está constituido por una estructura metálica de aproximadamente 7.3 metros de diámetro y 4.5 metros de altura, diseñada para albergar en su interior una bolsa plástica especial que contiene 180,000 litros de agua ultrapura. Esta agua ultrapura es fundamental para minimizar las impurezas y permitir la propagación precisa de la luz Cherenkov.

Dentro de cada tanque, se instalan cuatro tubos fotomultiplicadores (PMTs, por sus siglas en inglés) estratégicamente ubicados en el fondo del detector, que son sensibles a la tenue luz producida cuando las partículas secundarias atraviesan el agua a velocidades superiores a la de la luz en el medio. Esta instrumentación permite la detección precisa de partículas y ofrece al observatorio la capacidad de captar rayos gamma en un rango de energía desde los 100 GeV hasta los 100 TeV, así como rayos cósmicos desde los 100 GeV hasta 1 PeV [?].

2.1 Objetivos científicos del observatorio HAWC

- Física de rayos cósmicos: Medir el espectro, la composición química y la anisotropía de los rayos cósmicos en el rango de energías de varios TeV hasta la región de la rodilla (PeV).
- Monitoreo del cielo: HAWC está diseñado para monitorear dos tercios del cielo diariamente, permitiendo la detección continua de rayos gamma con energías del orden de TeV, como los emitidos por la Nebulosa del Cangrejo.
- Búsqueda de materia oscura: a través de sus observaciones, HAWC también contribuye a la búsqueda de señales indirectas de materia oscura, una de las áreas

Figura 8

Tanques Cherenkov del HAWC.



Nota. Imagen del Observatorio HAWC, ubicado en las faldas del volcán Sierra Negra en México. Este conjunto de más de 300 tanques de agua detecta partículas cargadas producidas por rayos gamma y rayos cósmicos al atravesar la atmósfera terrestre, permitiendo el estudio de fenómenos astrofísicos de alta energía. Fotografía de *AnaDiBec* (3 ago 2017), publicada bajo licencia CC BY-SA 4.0; extraída de Wikimedia Commons.

más enigmáticas de la física de partículas.

- Colaboraciones interdisciplinarias y formación: HAWC sirve como un centro para la formación de recursos humanos y para fomentar la colaboración entre diferentes disciplinas y comunidades científicas, incluyendo la física de altas energías y la astronomía.

2.2 Detección de rayos cósmicos en HAWC

2.2.1 Radiación Cherenkov

La radiación Cherenkov, nombrada en honor a Pavel Alekseyevich Cherenkov, quien fue el primer científico en detectar experimentalmente este fenómeno en 1934, ocurre cuando partículas cargadas viajan a una velocidad superior a la velocidad de la luz en un medio dieléctrico transparente. Este fenómeno es análogo al estallido sónico producido por un objeto que supera la velocidad del sonido en un medio y resulta en la emisión de luz en forma de un cono alrededor de la dirección de movimiento de la partícula.

El ángulo de apertura del cono de luz Cherenkov, θ_C , está dado por la relación:

$$\cos \theta_C = \frac{c}{vn},$$

donde v representa la velocidad de la partícula cargada, n es el índice de refracción del medio, y c es la velocidad de la luz en el vacío [97]. Para que ocurra la radiación Cherenkov, la partícula cargada debe desplazarse a una velocidad superior a la velocidad de fase de la luz en el medio, es decir,

$$v > \frac{c}{n}.$$


La intensidad de la radiación Cherenkov emitida por unidad de longitud y por unidad de frecuencia está descrita por la fórmula de Frank-Tamm:

$$\frac{d^2 E}{dx d\omega} = \frac{q^2}{4\pi\epsilon_0 c^2} \omega \left(1 - \frac{c^2}{v^2 n^2(\omega)} \right),$$

donde q es la carga de la partícula, ϵ_0 es la permitividad del vacío, y ω representa la frecuencia angular de la radiación.

Figura 9

Cono de radiación Cherenkov.



Nota. Esquema del cono de radiación Cherenkov emitido por una partícula cargada moviéndose a velocidad v en un medio con índice de refracción n . El ángulo θ representa el ángulo de emisión de la radiación respecto a la dirección de la partícula. Adaptado de la imagen *Cherenkov radiation cone.svg* en Wikimedia Commons.


La figura 9 muestra un esquema del cono de radiación Cherenkov emitido por una partícula cargada que atraviesa un medio dieléctrico a velocidad v , formando un ángulo θ_C con la dirección de movimiento.

2.2.2 Detección en HAWC

El observatorio HAWC es capaz de detectar partículas secundarias que alcanzan la superficie terrestre tras sobrevivir las lluvias de cascadas atmosféricas extendidas. Cuando partículas cargadas de una cascada atmosférica ingresan en los WCDs de HAWC y se mueven más rápido que la velocidad de la luz en el agua, generan radiación Cherenkov. Este fenómeno produce un destello azul debido a la perturbación electromagnética en el medio acuoso (ver figura 10). La detección y análisis de esta luz permiten reconstruir las propiedades de las partículas primarias y estudiar fenómenos astrofísicos de alta energía [59].

Figura 10

Disposición de los tanques Cherenkov del HAWC.



Nota. La imagen izquierda detalla la disposición de los tanques Cherenkov de agua del observatorio HAWC, mientras que la imagen derecha revela el interior de un tanque, equipado con cuatro fotomultiplicadores. La línea azul simboliza la radiación Cherenkov emitida por una partícula secundaria atravesando el tanque.

La información temporal y la intensidad de los pulsos Cherenkov constituyen la base para reconstruir la energía y la dirección de la partícula primaria. El transporte, acondicionamiento y digitalización de estas señales y el sistema DAQ se detallan en la Subsección 2.2.4. Los datos resultantes se procesan tanto en tiempo real como de forma diferida para buscar fuentes de rayos gamma, caracterizar el flujo de rayos cósmicos y explorar firmas de nueva física.

2.2.3 Tubos Fotomultiplicadores

Los PMTs son dispositivos optoelectrónicos que convierten señales de luz muy débiles en señales eléctricas amplificadas. Funcionan basándose en el efecto fotoeléctrico y en la emisión secundaria de electrones. En el Observatorio HAWC, se utilizan dos tipos

de PMTs fabricados por Hamamatsu: el modelo R5912 de 8 pulgadas de diámetro y el modelo R7081 de 10 pulgadas. El modelo R7081 ofrece una mayor sensibilidad a eventos de cascadas de baja energía debido a su mayor área de fotocátodo y eficiencia cuántica mejorada [98].

Cuando la luz Cherenkov emitida por partículas cargadas en los WCDs incide en el fotocátodo de un PMT, los fotones liberan electrones mediante el efecto fotoeléctrico [99]. La eficiencia cuántica, η , del fotocátodo determina la probabilidad de que un fotón incidente produzca un fotoelectrón:

$$I_{pe} = \eta I_{\gamma},$$

donde I_{pe} es la corriente de fotoelectrones e I_{γ} es la corriente de fotones incidentes.

Una vez emitidos, los fotoelectrones son acelerados hacia una serie de dínodos mediante un campo eléctrico. En cada dínodo, los electrones provocan la emisión secundaria de más electrones, multiplicando el número total. Si el coeficiente de multiplicación por dínodo es δ y hay n dínodos, la ganancia total del PMT, G , es:


$$G = \delta^n,$$

gracias a este proceso de amplificación, el PMT puede detectar señales de luz extremadamente débiles, que de otro modo pasarían desapercibidas [99].

La figura 11 muestra un esquema de un PMT, incluyendo el fotocátodo, los dínodos y el ánodo. Se ilustra el proceso de emisión de fotoelectrones y la multiplicación de electrones a través de los dínodos.

Figura 11

Esquema de un PMT.



Nota. Esquema de un tubo fotomultiplicador (PMT) mostrando el fotocátodo, los dínodos y el ánodo. Los fotones incidentes liberan fotoelectrones en el fotocátodo, que son multiplicados a través de la cadena de dínodos hasta llegar al ánodo, donde se genera una señal eléctrica amplificada. Figura tomada de *Photomultiplier schema de.png*, obra de Jkrieger (2007), CC BY-SA 4.0; extraída de Wikimedia Commons.

Los PMTs en HAWC están ubicados en el fondo de cada WCD, orientados hacia

arriba para maximizar la captura de la luz Cherenkov que se propaga en el agua. Los PMTs del modelo R5912 fueron reutilizados del experimento MILAGRO [100], mientras que los del modelo R7081 se incorporaron específicamente para HAWC debido a sus mejores características de detección a bajas energías [59].

La respuesta temporal de los PMTs es crucial para la reconstrucción de los eventos detectados. Los PMTs utilizados en HAWC tienen una resolución temporal del orden de nanosegundos, lo que permite una reconstrucción precisa de la llegada de las partículas y, por ende, de la dirección de los rayos gamma o cósmicos [101].

El espectro de respuesta de los PMTs también es importante. Los fotocátodos de bialcalino utilizados tienen una alta sensibilidad en el rango de longitud de onda de 300 a 600 nm, que coincide con el espectro de emisión de la luz Cherenkov en el agua [98].

Los PMTs operan bajo un alto voltaje que se distribuye a través de los díodos para mantener el potencial necesario para la multiplicación de electrones. La corriente de salida del ánodo es proporcional al número de fotoelectrones iniciales, lo que permite cuantificar la intensidad de la luz incidente [102].

La integración de los PMTs en el sistema de adquisición de datos (DAQ) es esencial para el funcionamiento del observatorio. Los datos obtenidos permiten no solo detectar la presencia de partículas de alta energía sino también reconstruir sus trayectorias y energías, contribuyendo al estudio de fenómenos astrofísicos de alta energía.

2.2.4 *Procesamiento de la señal*

Las señales electrónicas generadas por los PMTs se transmiten a través de cables coaxiales hacia el centro de adquisición de datos. En este centro, el sistema DAQ recibe las señales y se encarga de amplificarlas y digitalizarlas para su posterior procesamiento. Los PMTs emiten señales que son analizadas mediante la técnica de *Time Over Threshold* (TOT), donde se comparan contra dos umbrales de voltaje diferentes: un umbral bajo y uno alto. Dependiendo de si la señal cruza uno o ambos umbrales, se caracteriza como una señal tipo *two-edge* o *four-edge*, respectivamente [103].

Posteriormente, un disparador (*trigger*) selecciona eventos que cumplen con ciertos criterios, como recibir señales de al menos 28 PMTs en un intervalo de 150 ns, almacenando los datos relevantes para su análisis [104]. Una vez que los datos han sido digitalizados, se envían a un arreglo de servidores para la reconstrucción online y offline de las cascadas atmosféricas de partículas [105].

2.3 Análisis de los Datos

El análisis de los datos en HAWC se centra en reconstruir y caracterizar los eventos de cascadas atmosféricas. A partir de la información obtenida por los PMTs,

se reconstruyen propiedades fundamentales como la posición del núcleo de la cascada, la dirección de arribo de la partícula primaria, y su energía, utilizando algoritmos optimizados y respaldados por simulaciones.

2.3.1 Reconstrucción del núcleo de la cascada atmosférica extendida

El núcleo de la cascada es el punto donde el eje de la cascada impacta el detector. Es una región crucial porque es donde se deposita la mayor cantidad de energía, y su correcta reconstrucción influye en el resto del análisis. La primera estimación de la posición del núcleo se hace a través de un cálculo del “centro de masa” de los *hits* registrados. Posteriormente, se realiza un ajuste con un modelo de distribución lateral, conocido como *Super Fast Fit Core* (SFCF), que mejora la precisión de la estimación [106].

2.3.2 Reconstrucción de la dirección de arribo

Una vez identificado el núcleo, se reconstruye la dirección de arribo de la partícula primaria. La cascada se representa inicialmente como un plano viajando a la velocidad de la luz, pero en la reconstrucción se tiene en cuenta la curvatura del frente de la cascada, que depende de la distancia al núcleo. Esta corrección es importante para obtener una estimación precisa de los ángulos cenital y acimutal de la partícula primaria [103].

Las simulaciones de eventos de rayos cósmicos son fundamentales para calibrar los algoritmos de reconstrucción y validar los resultados obtenidos de los datos experimentales. En HAWC, las simulaciones se realizan utilizando el paquete CORSIKA para modelar la interacción de las partículas secundarias con la atmósfera, y GEANT4 para simular la respuesta del detector [107]. Las simulaciones consideran núcleos atómicos como protones, helio, carbono, y hierro, reproduciendo espectros de energía y distribuciones angulares consistentes con mediciones experimentales directas, como las obtenidas por CREAM y AMS [108].

3. Inteligencia artificial y Aprendizaje Profundo

3.1 Introducción a la inteligencia artificial

Las técnicas de aprendizaje profundo, representando la vanguardia en inteligencia artificial, simulan la capacidad cognitiva humana para analizar datos y generar patrones. A través de redes neuronales artificiales de múltiples niveles, estas técnicas aprenden de conjuntos de datos en modalidades supervisada, no supervisada, o semi-supervisada, impulsando avances en visión computarizada, procesamiento de lenguaje natural y reconocimiento de voz [109, 110].

La inteligencia artificial (IA) se ha integrado eficazmente en diversas áreas, abarcando desde la salud, como en la detección automática de células cancerígenas, hasta la agricultura, en la supervisión de la calidad de productos agrícolas como los limones [111, 112].

En el ámbito de la física de los rayos cósmicos, la aplicación de técnicas de IA se extiende a varios frentes, incluyendo la reconstrucción del espectro de energía y la composición de la masa de los rayos cósmicos [113]. Las redes neuronales convolucionales, por ejemplo, se han utilizado para la clasificación de eventos de rayos cósmicos ultraenergéticos en el rango de 10^{18} a 10^{20} eV, determinando si corresponden a fotones o hadrones [114]. Además, se han implementado métodos de redes neuronales profundas para estimar la profundidad máxima atmosférica alcanzada por las lluvias de rayos cósmicos.

Específicamente, la estimación de la energía de los rayos cósmicos mediante técnicas de aprendizaje profundo se perfila como una prometedora mejora en la precisión y eficiencia del análisis de datos. Este enfoque supera a los métodos tradicionales al identificar patrones complejos en las señales detectadas, lo que facilita una interpretación más precisa de los eventos observados [115].

Machine learning

El aprendizaje automático (Machine Learning, ML) es una rama de la inteligencia artificial que se centra en el desarrollo de algoritmos capaces de aprender de los datos y hacer predicciones o tomar decisiones basadas en ellos, sin estar explícitamente programados para realizar una tarea específica. Esta capacidad de aprendizaje se logra mediante la identificación de patrones y regularidades en los datos que se basa en modelos matemáticos y estadísticos que se ajustan automáticamente a medida que reciben

nuevos datos, mejorando su precisión y eficacia en la toma de decisiones o predicciones. Algunos de los usos más comunes recaen en máquinas de soporte vectorial (SVM), árboles de decisiones, vecinos cercanos (KNN), entre otras.

Deep learning

Deep Learning (DL) es un subconjunto del machine learning que utiliza redes neuronales artificiales con muchas capas para aprender de grandes volúmenes de datos. Las redes neuronales son sistemas inspirados en el funcionamiento del cerebro humano, capaces de aprender tareas de alta complejidad al ajustar pesos y sesgos a través de muchas capas intermedias, o profundas, de neuronas. Pueden modelar relaciones complejas y abstraer características a diferentes niveles de representación. Sin embargo, el deep learning requiere grandes cantidades de datos etiquetados para el entrenamiento y un considerable poder computacional, especialmente para entrenar modelos más grandes y complejos. Algunos de los modelos más reconocidos, son las redes neuronales convolucionales (CNN's), redes neurales recurrentes (RNN), autocodificadores, entre otros.

3.2 Aprendizaje supervisado

El Aprendizaje Supervisado es una de las ramas más fundamentales y ampliamente utilizadas del aprendizaje automático dentro del campo de la IA. Este enfoque se centra en entrenar modelos utilizando conjuntos de datos etiquetados, donde cada ejemplo de entrenamiento consta de una entrada y una salida deseada. El objetivo principal del aprendizaje supervisado es que el modelo aprenda a mapear correctamente las entradas a las salidas, permitiendo realizar predicciones o clasificaciones precisas sobre nuevos datos no vistos durante el entrenamiento [116, 117].

En el aprendizaje supervisado, el proceso de entrenamiento implica ajustar los parámetros del modelo para minimizar la diferencia entre las predicciones del modelo y las etiquetas reales de los datos de entrenamiento. Este ajuste se logra mediante la optimización de una función de pérdida, que cuantifica el error de las predicciones. Dependiendo de la naturaleza del problema, se utilizan diferentes funciones de pérdida, como el error cuadrático medio (MSE, por sus siglas en inglés) para tareas de regresión o la entropía cruzada para tareas de clasificación [118].

El entrenamiento de los modelos se realiza utilizando algoritmos de optimización, siendo el descenso de gradiente estocástico (SGD, por sus siglas en inglés) y sus variantes, como Adam y RMSprop, los más comunes. Estos algoritmos ajustan iterativamente los pesos del modelo en la dirección que reduce la función de pérdida, permitiendo que el modelo aprenda de los datos de manera eficiente.

3.2.1 Modelos comunes

Existen diversos algoritmos dentro del aprendizaje supervisado, cada uno con sus propias ventajas y características que los hacen adecuados para diferentes tipos de problemas y datos. Algunos de los más destacados son:

Máquinas de Soporte Vectorial: Buscan encontrar un hiperplano óptimo que separe las diferentes clases en el espacio de características. Son eficaces en espacios de alta dimensión y en casos donde el número de dimensiones supera al número de muestras [119].

Árboles de Decisión y Bosques Aleatorios: Los árboles de decisión dividen el espacio de características en regiones más pequeñas para realizar predicciones. Los bosques aleatorios, que son conjuntos de árboles de decisión, mejoran la precisión y reducen el riesgo de sobreajuste [120].

K-Vecinos Cercanos: Clasifican una entrada basándose en las etiquetas de sus K vecinos más cercanos en el espacio de características. Es un método simple pero efectivo para problemas de clasificación y regresión [121].

Redes neuronales supervisadas: Incluyen desde las redes neuronales multicapa (MLP) y las redes neuronales recurrentes (RNN, p. ej. LSTM y GRU) hasta las arquitecturas profundas modernas (CNN, Transformers). Las RNN añaden conexiones temporales que les permiten modelar dependencias a lo largo de secuencias, por lo que son fundamentales en tareas como predicción de series, reconocimiento de voz y procesamiento de lenguaje natural. Todas estas redes pueden aprender de manera supervisada ajustando sus pesos mediante retropropagación para minimizar una función de pérdida definida sobre datos etiquetados, capturando relaciones complejas y no lineales en grandes volúmenes de información de alta dimensionalidad [118, 122, 123].

3.2.2 Proceso de entrenamiento

El proceso de entrenamiento en el aprendizaje supervisado consta de varias etapas críticas:

1. Inicialmente, el conjunto de datos se divide en conjuntos de entrenamiento y prueba (y a veces un conjunto de validación). Esta división asegura que el modelo pueda generalizar su aprendizaje a datos no vistos durante el entrenamiento [117].
2. Utilizando el conjunto de entrenamiento, el modelo ajusta sus parámetros internos para minimizar la función de pérdida. Este proceso puede implicar múltiples iteraciones hasta que el modelo alcanza una convergencia aceptable.
3. Se utiliza el conjunto de prueba para evaluar el rendimiento del modelo mediante métricas específicas. Para clasificación, se utilizan métricas como la precisión, el recall y la F1-score. Para regresión, se emplean métricas como el R^2 y el error absoluto medio (MAE, por sus siglas en inglés) [116].

4. A través del conjunto de validación, se ajustan los hiperparámetros del modelo para optimizar su rendimiento y prevenir el sobreajuste [118].

3.3 Redes neuronales artificiales

Las Redes Neuronales Artificiales (RNA) son modelos computacionales inspirados en la estructura y funcionamiento del cerebro humano, diseñados para reconocer patrones, aprender de los datos y realizar predicciones precisas en una amplia variedad de aplicaciones científicas y tecnológicas. Una RNA típica está compuesta por múltiples capas de nodos o "neuronas" interconectadas, cuya organización y función son fundamentales para su capacidad de aprendizaje y procesamiento de información.

3.3.1 Estructura de las redes neuronales

En una RNA, la capa de entrada es la primera capa de la red que recibe los datos iniciales que se desean procesar. Cada nodo en esta capa representa una característica o variable específica del conjunto de datos, sirviendo como el punto de entrada de la información hacia la red. Por ejemplo, en un modelo destinado a la clasificación de imágenes, cada nodo de la capa de entrada podría representar un píxel de la imagen.

Entre la capa de entrada y la capa de salida se encuentran las capas ocultas, que constituyen el núcleo de la red neuronal. Estas capas realizan la mayor parte del procesamiento mediante el uso de funciones de activación no lineales, lo que permite a la red aprender y modelar relaciones complejas y no lineales entre las variables de entrada y las salidas deseadas. Las capas ocultas transforman las entradas en representaciones abstractas y de mayor nivel, facilitando la extracción de características relevantes y la identificación de patrones significativos en los datos [118].

Finalmente, la capa de salida produce el resultado final del procesamiento de la red, que puede ser una clasificación, una regresión u otra tarea específica según el objetivo del modelo. En tareas de clasificación, cada nodo en la capa de salida puede representar una clase diferente, asignando probabilidades o etiquetas a las entradas procesadas. En tareas de regresión, la capa de salida proporciona un valor continuo que representa una predicción numérica basada en los datos de entrada [116].

3.3.2 Tipos de arquitectura

Existen diversas arquitecturas de RNA, cada una adecuada para diferentes tipos de tareas y datos. Las MLP son las más básicas y consisten en múltiples capas completamente conectadas, siendo adecuadas para tareas de clasificación y regresión. Las CNN's están especializadas en el procesamiento de datos con estructura de cuadrícula, como imágenes, utilizando capas convolucionales para extraer características locales y capas de pooling para reducir la dimensionalidad [122]. Por otro lado, las RNN están

diseñadas para procesar datos secuenciales, como series temporales o texto, siendo efectivas para tareas que requieren memoria de estados anteriores. Más recientemente, las Redes de Transformadores han emergido como una arquitectura avanzada que utiliza mecanismos de atención para manejar dependencias a largo plazo en datos secuenciales, superando algunas limitaciones de las RNN tradicionales [124].

3.3.3 Proceso de entrenamiento

El proceso de entrenamiento de una RNA implica ajustar los pesos de las conexiones entre neuronas para minimizar la diferencia entre las predicciones de la red y los valores reales. Este ajuste se realiza mediante varios pasos clave:

1. Propagación hacia Adelante (Forward Propagation): En esta etapa, los datos de entrada se procesan a través de la red, capa por capa, para generar una predicción o salida final. Este proceso implica la multiplicación de las entradas por los pesos sinápticos, la adición de los sesgos y la aplicación de funciones de activación no lineales. Matemáticamente, cada neurona en una capa realiza una transformación lineal seguida de una transformación no lineal, permitiendo a la red modelar relaciones complejas entre las características de entrada y las salidas deseadas.

Para cada capa l desde la primera capa oculta hasta la capa de salida, la activación $\mathbf{a}^{(l)}$ se calcula de la siguiente manera:

$$\begin{aligned}\mathbf{z}^{(l)} &= \mathbf{W}^{(l)}\mathbf{a}^{(l-1)} + \mathbf{b}^{(l)}, \\ \mathbf{a}^{(l)} &= \sigma(\mathbf{z}^{(l)}),\end{aligned}\tag{3.1}$$

aquí, $\mathbf{a}^{(l-1)}$ denota el vector de activaciones de la capa anterior $l - 1$, $\mathbf{W}^{(l)}$ representa la matriz de pesos que conecta la capa $l - 1$ con la capa l , $\mathbf{b}^{(l)}$ es el vector de sesgos de la capa l , y σ se refiere a la función de activación la cual introduce no linealidades en la red, permitiendo que esta aprenda y modele relaciones complejas entre las entradas y las salidas. Las funciones de activación más comunes incluyen:

- **ReLU (Rectified Linear Unit):** La ReLU es ampliamente utilizada debido a su simplicidad y eficacia en redes profundas,

$$\sigma(z) = \max(0, z).$$

- **Sigmoid:** Utilizada principalmente en capas de salida para tareas de clasificación binaria,

$$\sigma(z) = \frac{1}{1 + e^{-z}}.$$

- **Tanh:** Similar a la sigmoid pero con un rango de salida de $[-1, 1]$, lo que puede

acelerar la convergencia en algunos casos,

$$\sigma(z) = \tanh(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}}.$$

2. Cálculo del Error (Loss Calculation): Se evalúa la diferencia entre la predicción y la salida real utilizando una función de pérdida. Para tareas de regresión, una función común es el error Cuadrático Medio (MSE):

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2, \quad (3.2)$$

mientras que para tareas de clasificación, se utiliza la entropía Cruzada (Cross-Entropy):

$$\text{Cross-Entropy} = -\frac{1}{n} \sum_{i=1}^n [y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)]. \quad (3.3)$$

Estas funciones cuantifican la diferencia entre las predicciones de la red y los valores reales, sirviendo como guía para el ajuste de los parámetros de la red [118].

3. Propagación hacia Atrás (Backpropagation): Permite calcular de manera eficiente los gradientes de la función de pérdida con respecto a cada uno de los pesos y sesgos de la red. Este proceso se basa en la regla de la cadena del cálculo diferencial, que facilita la descomposición del gradiente global en gradientes locales a lo largo de las capas de la red. Matemáticamente, para una capa l , el gradiente de la pérdida L respecto a los pesos $\mathbf{W}^{(l)}$ se expresa como:

$$\frac{\partial L}{\partial \mathbf{W}^{(l)}} = \delta^{(l)} (\mathbf{a}^{(l-1)})^T, \quad (3.4)$$

donde $\delta^{(l)}$ es el término de error para la capa l , definido como:

$$\delta^{(l)} = ((\mathbf{W}^{(l+1)})^T \delta^{(l+1)}) \odot \sigma'(\mathbf{z}^{(l)}). \quad (3.5)$$

En esta ecuación, $\mathbf{W}^{(l+1)}$ son los pesos de la capa siguiente $l + 1$, y $\sigma'(\mathbf{z}^{(l)})$ es la derivada de la función de activación aplicada a las entradas de la capa l . El operador $\odot$ representa el producto Hadamard (elemento a elemento). Este cálculo se realiza de manera recursiva, comenzando desde la capa de salida hacia la capa de entrada, permitiendo así la actualización correcta de los parámetros de la red para minimizar la función de pérdida. En el contexto de la estimación de energía de rayos cósmicos, este ajuste fino de los pesos asegura que la red aprenda de manera precisa las relaciones complejas entre las características de entrada y las estimaciones energéticas deseadas.

4. Actualización de Pesos (Weight Update): Una vez calculados los gra-

dientes, se actualizan los pesos y sesgos de la red utilizando un algoritmo de optimización. Uno de los algoritmos más avanzados y eficaces es Adam (Adaptive Moment Estimation), que combina las ventajas de dos otros métodos de optimización: AdaGrad y RMSProp.

El algoritmo Adam actualiza los parámetros de la red de la siguiente manera:

$$\begin{aligned}
 m_t &= \beta_1 m_{t-1} + (1 - \beta_1) \frac{\partial L}{\partial \mathbf{W}_t}, \\
 v_t &= \beta_2 v_{t-1} + (1 - \beta_2) \left(\frac{\partial L}{\partial \mathbf{W}_t} \right)^2, \\
 \hat{m}_t &= \frac{m_t}{1 - \beta_1^t}, \\
 \hat{v}_t &= \frac{v_t}{1 - \beta_2^t}, \\
 \mathbf{W}_t &= \mathbf{W}_{t-1} - \alpha \frac{\hat{m}_t}{\sqrt{\hat{v}_t} + \epsilon},
 \end{aligned} \tag{3.6}$$

donde m_t y v_t representan las estimaciones del primer y segundo momento (media y varianza) de los gradientes, respectivamente, β_1 y β_2 son los factores de decaimiento asociados a estos momentos, comúnmente fijados en 0.9 y 0.999, α denota la tasa de aprendizaje, y ϵ es una pequeña constante utilizada para evitar divisiones por cero.

El optimizador Adam ofrece múltiples ventajas, tales como su adaptabilidad al ajustar automáticamente la tasa de aprendizaje para cada parámetro, una rápida convergencia al combinar las ventajas de AdaGrad y RMSProp, y una alta eficiencia computacional debido a su bajo requerimiento de almacenamiento adicional y su optimización eficiente de recursos computacionales.

5. Regularización: Es una técnica crucial para prevenir el sobreajuste (overfitting), asegurando que la red generalice bien a datos no vistos. Las técnicas más comunes incluyen:

- Normalización por Lotes (Batch Normalization):

$$\begin{aligned}
 \hat{\mathbf{x}}^{(l)} &= \frac{\mathbf{x}^{(l)} - \mu_{\mathcal{B}}}{\sqrt{\sigma_{\mathcal{B}}^2 + \epsilon}}, \\
 \mathbf{y}^{(l)} &= \gamma \hat{\mathbf{x}}^{(l)} + \beta,
 \end{aligned}$$

donde $\mu_{\mathcal{B}}$ y $\sigma_{\mathcal{B}}^2$ representan la media y varianza calculadas sobre la mini-batch, respectivamente, mientras que γ y β son parámetros aprendibles que permiten al modelo ajustar y mantener su capacidad de representatividad después de la normalización. Estos parámetros facilitan que la red neuronal preserve las características esenciales de los datos originales, asegurando que la transformación

aplicada no limite la capacidad del modelo para aprender representaciones complejas y mejorar así su rendimiento general.

- Dropout: Consiste en "apagar" aleatoriamente una fracción de neuronas durante el entrenamiento, forzando a la red a no depender excesivamente de ninguna neurona específica:

$$\mathbf{h}^{(l)} = \mathbf{h}^{(l)} \odot \mathbf{d}^{(l)},$$

donde $\mathbf{d}^{(l)}$ es una máscara binaria generada aleatoriamente.

- Penalización L2 (Regularización de Tikhonov): Añade una penalización proporcional al cuadrado de los pesos a la función de pérdida:

$$L_{\text{total}} = L + \lambda \sum_i (\mathbf{w}_i)^2,$$

donde λ es el parámetro de regularización que controla la magnitud de la penalización.

Estas técnicas ayudan a mantener los pesos de la red en valores razonables y a evitar que la red memorice los datos de entrenamiento, mejorando así su capacidad de generalización.

4. Metodología

4.1 Descripción de los datos

El Observatorio HAWC trabaja con dos conjuntos principales de datos: los datos experimentales y los datos simulados. Los datos experimentales son recolectados directamente por el detector a partir de eventos reales de rayos cósmicos que impactan en la atmósfera y generan lluvias de partículas detectables en los detectores Cherenkov. Estos datos reflejan las mediciones efectivas y observaciones realizadas durante el funcionamiento del observatorio.

Por otro lado, los datos simulados se generan mediante técnicas de simulación Monte Carlo. Estas simulaciones recrean de forma detallada el proceso de formación de lluvias de partículas en la atmósfera y su interacción con el detector HAWC. Al generar estos datos, es posible modelar diversos escenarios y condiciones que ayudan a entender el comportamiento esperado del detector frente a diferentes tipos de eventos y energías.

El flujo de trabajo en HAWC implica un procesamiento estructurado donde ambos tipos de datos son esenciales. Los datos simulados permiten calibrar y validar los modelos de detección, entender las eficiencias del sistema y corregir posibles sesgos o errores sistemáticos. Al comparar los datos experimentales con los simulados, se pueden identificar discrepancias y ajustar los modelos teóricos para mejorar la precisión en la reconstrucción de eventos y la estimación de parámetros físicos, como la energía y la dirección de los rayos cósmicos.

Este enfoque combinado de adquisición y simulación de datos es fundamental para el análisis de fuentes astrofísicas. Permite no solo detectar y registrar eventos reales, sino también entender en profundidad cómo se comporta el detector y cómo interpretar los datos obtenidos.


4.1.1 *Simulación de lluvias de partículas y generación de datos*

El flujo de datos y simulaciones en el experimento HAWC se estructura en distintas etapas, como se muestra en la Figura 12. Comienza con la simulación de lluvias atmosféricas mediante el programa CORSIKA se aplican distintos sesgos intencionales para optimizar la simulación de flujos físicos. Por ejemplo, se simulan fotones y hadrones

con un espectro de energía artificialmente endurecido, lo cual garantiza la disponibilidad de eventos de alta energía suficientes para los estudios científicos. Asimismo, se generan sesgos radiales para estudiar mejor la respuesta del detector a eventos lejanos o a bajas energías. Este software simula lluvias de partículas energéticas que se propagan hasta el punto de observación. El archivo de salida de CORSIKA contiene información detallada de las partículas que alcanzan la superficie, pero no incluye información sobre la respuesta del detector.

Figura 12

Representación esquemática de la reconstrucción de eventos en HAWC.



Nota. Flujo de procesamiento y formatos de datos en el experimento HAWC. La figura muestra las principales etapas de simulación y adquisición de datos en HAWC. Los datos se generan a partir de la simulación de lluvias atmosféricas con CORSIKA y se procesan con la aplicación HAWCSim basada en GEANT-4. Los datos experimentales se registran mediante el sistema de adquisición (DAQ/Online) y se almacenan en diferentes formatos XCDF y ROOT, que permiten realizar la reconstrucción y el análisis de los eventos desencadenados.

Luego, se utiliza HAWCSim, una aplicación basada en GEANT-4, para simular la interacción de estas lluvias con el detector de HAWC. En esta etapa, se genera un archivo en formato XCDF que registra la diferencia de voltaje detectada por cada PMT en el arreglo de HAWC. Esta simulación considera la disposición completa del instrumento, modelando las características físicas y geométricas del detector.

Formatos de datos y procesamiento

En la figura 12, se presenta además una representación esquemática de los principales formatos de archivo y los pasos de procesamiento involucrados en la reconstrucción de eventos, desde la simulación inicial de lluvias atmosféricas hasta la generación de archivos de resumen y mapas del cielo.

Los datos registrados en el experimento HAWC se almacenan inicialmente en archivos llamados TRIG, que contienen la información cruda de cada evento en un formato específico llamado XCDF. Estos archivos preservan detalles importantes sobre el tiempo de cada evento y son la fuente principal de datos del observatorio.

Posteriormente, se genera un archivo REC que contiene un resumen comprimido de los datos procesados. Estos archivos incluyen solo la información relevante, eliminando datos innecesarios para reducir el tamaño de almacenamiento. Los archivos REC se utilizan tanto en el análisis inmediato como en análisis posteriores y son fundamentales para crear mapas del cielo y realizar estudios de sensibilidad.

Para estudios detallados de eventos específicos, se genera un archivo *Full-Hits*, el cual es un archivo ROOT que almacena información completa de los impactos y pasos de procesamiento en el detector. Este formato resulta ideal para profundizar en los procesos de reconstrucción y familiarizarse con los datos, aunque es costoso en términos de almacenamiento debido a la redundancia de ramas.

El flujo de simulaciones se complementa con la creación de Archivos de Resumen de simulación *Sim. Summary file*, que son análogos a los archivos REC pero para datos simulados. Estos archivos en formato ROOT contienen un resumen de eventos reconstruidos sin información detallada de impactos, y se utilizan principalmente como etapa intermedia para producir archivos ponderados.

Los Archivos de Resumen de Simulación Ponderada incluyen ramas adicionales que almacenan los pesos calculados para corregir los sesgos introducidos durante la simulación. Estos pesos permiten ajustar los resultados para reflejar flujos físicos reales y características de fuentes puntuales de rayos gamma en tránsito.

4.2 Versiones específicas de datos y modelos utilizados

Durante el desarrollo de este proyecto se emplearon inicialmente los datos simulados correspondientes a la versión denominada **pass5**. Esta elección inicial se fundamentó en la disponibilidad más reciente y la supuesta mejora en la precisión de estos datos simulados. En una primera instancia, se implementó un modelo base en el entorno ROOT, lo que permitió realizar una evaluación inicial del comportamiento esperado de las variables físicas consideradas para la estimación de energía.

Posteriormente, se desarrolló una implementación más robusta utilizando *TensorFlow*, con el fin de aprovechar técnicas avanzadas de aprendizaje profundo y validar

con mayor detalle los datos simulados. Sin embargo, durante el entrenamiento y evaluación de este modelo más avanzado, se detectaron inconsistencias significativas en los datos simulados pass5. Estos problemas se manifestaron como anomalías en la distribución y comportamiento de variables clave que no se correspondían con el comportamiento físico esperado.

Debido a estos hallazgos, se tomó la decisión de recurrir a la versión anterior de los datos simulados, **pass4**, la cual había sido previamente validada y no presentaba tales inconsistencias. Esta transición permitió continuar con el análisis de manera robusta, utilizando dos modelos optimizados específicamente para estos datos: MP4CE y MP4SE.

A continuación, en la Tabla 1, se presentan claramente las variables específicas empleadas por cada uno de los modelos utilizados a lo largo del proyecto, facilitando así la comprensión rápida y precisa de las diferencias y similitudes entre ellos.

Tabla 1

Variables utilizadas en cada modelo según versión de los datos simulados.

Variable	ROOT (pass5)	TensorFlow (pass5)	MP4CE (pass4)	MP4SE (pass4)
CxPE40	✗	✓	✓	✓
LDFAge	✗	✗	✓	✓
LDFamp	✓	✗	✓	✓
LDFChi2	✗	✗	✓	✓
LHLatDistFitEnergy	✗	✓	✗	✗
LHLatDistFitGoF	✗	✓	✗	✗
LHLatDistFitXmax	✗	✓	✗	✗
PINC	✗	✗	✓	✓
SFCFChi2	✗	✗	✓	✓
SFCFNDOF	✗	✗	✓	✓
TankLHR	✗	✓	✗	✗
coreFiduScale	✓	✓	✓	✓
coreFitUnc	✗	✗	✓	✓
disMax	✗	✓	✗	✗
fAnnulusCharge0	✓	✓	✓	✓
fAnnulusCharge1	✓	✓	✓	✓
fAnnulusCharge2	✓	✓	✓	✓
fAnnulusCharge3	✓	✓	✓	✓
fAnnulusCharge4	✓	✓	✓	✓
fAnnulusCharge5	✓	✓	✓	✓
fAnnulusCharge6	✓	✓	✓	✓
fAnnulusCharge7	✓	✓	✓	✓
fAnnulusCharge8	✓	✓	✓	✓
gammalheEnergy	✗	✗	✓	✗
gammalheLLH	✗	✗	✓	✗
logCoreAmplitude	✗	✗	✓	✓
logGPV2	✗	✗	✓	✗
logMaxPE	✗	✓	✓	✓
logNNEnergyV2	✗	✗	✓	✗
logNPE	✗	✓	✓	✓
mPFnHits	✗	✓	✗	✗

Variable	ROOT (pass5)	TensorFlow (pass5)	MP4CE (pass4)	MP4SE (pass4)
mPFp0Weight	✗	✓	✗	✗
mPFp0nAssign	✗	✓	✗	✗
mPFp1Weight	✗	✓	✗	✗
mPFp1nAssign	✗	✓	✗	✗
nChAvail	✗	✓	✗	✗
nHit	✓	✓	✓	✓
nHitMPF	✗	✓	✗	✗
nHitSP10	✗	✓	✓	✓
nHitSP20	✗	✓	✓	✓
nHitTot	✗	✓	✓	✓
nTankAvail	✗	✓	✗	✗
nTankHit	✓	✓	✓	✓
nTankHitTot	✗	✓	✓	✓
planeChi2	✗	✓	✓	✓
planeNDOF	✗	✓	✓	✓
protonlheLLH	✗	✗	✓	✗
windowHits	✗	✓	✓	✓
zenithAngle	✓	✓	✗	✗

Nota. Las variables marcadas con ✓ fueron incluidas en el modelo correspondiente, mientras que las marcadas con ✗ no fueron consideradas. Los modelos ROOT y TensorFlow utilizan datos de la versión pass5; MP4CE y MP4SE utilizan datos de la versión pass4.

Finalmente, la selección de variables específicas en cada modelo fue guiada por análisis estadísticos, particularmente la correlación de Pearson con la energía verdadera, complementado por el conocimiento experto adquirido en el observatorio HAWC. De esta forma, se aseguró que cada conjunto de variables empleado proporcionara un balance óptimo entre precisión en la estimación energética y robustez frente a variaciones en los datos.

4.3 Pipeline de modelado


Para gestionar la complejidad de los diferentes enfoques de modelado, se desarrolló un pipeline de procesamiento que automatiza el flujo de datos desde la preparación inicial hasta la evaluación de los modelos. Este incluye las etapas de preprocesamiento, selección y transformación de características, normalización de los datos de entrada, y configuración y entrenamiento de cada modelo. Además, se integró un componente de optimización de hiperparámetros para ajustar los modelos y maximizar su rendimiento. De esta manera, se garantizó un enfoque sistemático y reproducible, permitiendo realizar experimentos de manera eficiente y evaluar los modelos de forma consistente.

El desarrollo del pipeline de procesamiento y entrenamiento de modelos para la estimación de energías de rayos cósmicos se estructuró en varias etapas clave, como se ilustra en la Figura 13. Cada etapa fue diseñada para abordar los distintos desafíos relacionados con el manejo de los datos, la preparación de características, el entrenamiento y la optimización de los modelos. En las siguientes subsecciones, se detallarán los procedimientos implementados en cada fase del pipeline, incluyendo la entrada y preprocesamiento de datos, la selección de variables relevantes, el entrenamiento de diferentes modelos de inteligencia artificial, la opti-

mización de hiperparámetros, y la evaluación y selección final del mejor modelo para realizar las predicciones.

Figura 13

Diagrama del pipeline de procesamiento y entrenamiento.



Nota. Diagrama del pipeline de procesamiento y entrenamiento de modelos. El diagrama muestra las etapas clave del pipeline diseñado para la estimación de energías de rayos cósmicos en HAWC. Incluye la entrada de datos, el preprocesamiento, la selección de variables, el entrenamiento de diferentes modelos, la optimización de hiperparámetros, la evaluación de los modelos y la selección del modelo óptimo para realizar las predicciones finales.

Procesamiento de los datos

El procesamiento de datos en este proyecto constó de tres etapas principales: entrada de datos, filtrado por cortes de calidad y selección de variables relevantes. En la primera etapa, se realizó la entrada de los datos adquiridos del experimento HAWC, asegurando su correcta

estructuración y verificación de integridad. A continuación, se aplicaron cortes de calidad a los datos con el objetivo de garantizar que solo se incluyan en el análisis aquellos eventos que cumplan con ciertos criterios mínimos de validez:

- 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° .

Estos cortes se basaron en la experiencia del observatorio y consistieron en verificar que variables clave, como la cantidad de fotones detectados o la distancia al centro del evento, se mantuvieran dentro de rangos adecuados. Esto fue crucial para excluir eventos que pudieran estar contaminados por ruido instrumental o por fenómenos no relacionados con los rayos cósmicos.

En la siguiente etapa, se realizó una selección de variables utilizando la correlación de Pearson para identificar aquellas características que mostraban una relación significativa con la variable objetiva, en este caso, la energía de los rayos cósmicos. La correlación de Pearson mide la relación lineal entre dos variables y se expresa mediante la ecuación:

$$\rho_{X,Y} = \frac{\sigma_{X,Y}}{\sigma_X \sigma_Y}, \quad (4.1)$$

donde $\rho_{X,Y}$ es el coeficiente de correlación entre las variables X y Y , $\sigma_{X,Y}$ representa la covarianza entre ambas variables, y σ_X y σ_Y son las desviaciones estándar de X y Y , respectivamente. El coeficiente de Pearson toma valores entre -1 y 1 , donde un valor cercano a 1 indica una fuerte correlación positiva, -1 una fuerte correlación negativa, y 0 la ausencia de correlación lineal.

Para la selección de variables se emplearon dos criterios complementarios. Primero, se fijó un umbral de $|\rho| > 0,30$ en el coeficiente de Pearson con la energía reconstruida, descartándose así las características con baja correlación lineal. Segundo, se incluyeron variables recomendadas por el equipo científico del observatorio sobre la base de resultados publicados: la razón entre la señal total y la señal del PMT más cercano al núcleo y la dispersión radial de los depósitos de carga. Ambas magnitudes han demostrado correlacionarse con la energía y la topología de la cascada en estudios previos de HAWC y Milagro [93, 125].

Este enfoque híbrido filtrado estadístico + conocimiento físico evita depender exclusivamente de relaciones empíricas, las variables elegidas poseen una justificación experimental y teórica, y además superan el umbral cuantitativo de relevancia.

Decisión del modelo

Para gestionar la complejidad de los diferentes enfoques de modelado, se desarrolló un pipeline de procesamiento que automatiza el flujo de datos desde la preparación inicial hasta la evaluación de los modelos. Este pipeline incluye las etapas de preprocesamiento, selección y transformación de características, normalización de los datos de entrada, y configuración y entrenamiento de cada modelo.

Se normalizaron los datos mediante la función `scaler()` de python. La más comúnmente utilizada es la normalización o el escalado estándar, que transforma los datos a una distribución con una media de 0 y una desviación estándar de 1. Esta técnica se lleva a cabo utilizando la siguiente ecuación:

$$z = \frac{x - \mu}{\sigma}, \quad (4.2)$$

donde z es el valor escalado o estandarizado de la variable, x es el valor original de la variable, μ es la media de la variable x y σ es la desviación estándar de la variable x .

Seguido de esto se segmentaron los datos en un conjunto de entrenamiento de 80 % y 20 % de testeo. Para entrenar se utilizaron varias arquitecturas de modelos de inteligencia artificial para abordar el problema de la estimación de energías de rayos cósmicos. Entre las arquitecturas seleccionadas se incluyen CNN's, técnicas de bosque de gradiente aumentado (XGBoost y LightGBM), y MLP.

Además, se integró un componente de optimización de hiperparámetros para ajustar los modelos y maximizar su rendimiento. La técnica usada fue la optimización bayesiana, que es la base de BayesSearchCV, se centra en construir un modelo probabilístico del rendimiento del modelo como función de los hiperparámetros. A diferencia de métodos como GridSearchCV o RandomizedSearchCV, que prueban combinaciones de hiperparámetros de manera exhaustiva o aleatoria respectivamente, BayesSearchCV sigue un enfoque más inteligente basado en las siguientes ideas clave:

- Modelo probabilístico: la optimización bayesiana construye un modelo probabilístico (normalmente un proceso Gaussiano) que aproxima la relación entre los hiperparámetros y el rendimiento del modelo.
- Elección informada de hiperparámetros: cada nueva elección de hiperparámetros se basa en un criterio de adquisición que busca equilibrar la exploración y explotación de la función de rendimiento. Es decir, BayesSearchCV se centra en probar valores de hiperparámetros que tienen más probabilidades de mejorar el rendimiento, en lugar de elegir de manera aleatoria o exhaustiva.
- Menor número de evaluaciones: al elegir cuidadosamente las combinaciones de hiperparámetros a probar, BayesSearchCV reduce el número total de evaluaciones del modelo, haciéndolo mucho más eficiente en comparación con los métodos tradicionales.

Evaluación del modelo

Dado que el problema en cuestión corresponde a una tarea de regresión, es fundamental seleccionar métricas adecuadas para evaluar la precisión y la calidad de las predicciones del modelo. Las métricas más comunes en estos casos incluyen:

1. Error Cuadrático Medio (MSE)

El Error Cuadrático Medio es una métrica que mide el promedio de los cuadrados de los errores, es decir, la diferencia al cuadrado entre los valores predichos y los valores

reales. Esta métrica es sensible a errores grandes, por lo que penaliza de forma significativa las predicciones que se desvían notablemente del valor real. Se define matemáticamente como:

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2, \quad (4.3)$$

donde y_i representa los valores reales y $\hat{y}_i$ las predicciones del modelo.

2. Error Absoluto Medio (MAE)

El Error Absoluto Medio mide la media de los valores absolutos de las diferencias entre las predicciones y los valores reales. A diferencia del MSE, el MAE no penaliza los errores grandes con tanto rigor, lo que lo hace más robusto frente a valores atípicos. Se define como:

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|. \quad (4.4)$$

3. Coeficiente de Determinación (R^2)

El Coeficiente de Determinación, denotado como R^2 , indica la proporción de la varianza de la variable dependiente que es explicada por el modelo. Un valor cercano a 1 implica que el modelo ajusta adecuadamente los datos. Se expresa matemáticamente como:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}, \quad (4.5)$$

donde $\bar{y}$ es la media de los valores reales y_i .

Para seleccionar el modelo más adecuado, es recomendable emplear múltiples enfoques y compararlos utilizando las métricas de rendimiento previamente descritas. Una técnica esencial para realizar esta comparación de forma robusta es la validación Cruzada, la cual consiste en dividir el conjunto de datos en múltiples particiones y entrenar el modelo en diferentes subconjuntos, utilizando los restantes para la validación. Esta técnica ayuda a obtener una evaluación más fiable del rendimiento del modelo y a mitigar el riesgo de sobreajuste. Se eligió el mejor modelo en base a la métrica MSE tanto para entrenamiento como validación.

De esta manera, se garantizó un enfoque sistemático y reproducible, permitiendo realizar experimentos de manera eficiente y evaluar los modelos de forma consistente. La predicción final fue la adaptación de los pesos y los biases para la replicación del modelo en el framework de HAWC.

4.4 Arquitecturas

En el presente estudio, se han implementado y evaluado diversas arquitecturas de modelos de aprendizaje automático y redes neuronales con el objetivo de abordar la estimación de energía de los rayos cósmicos. La selección de estas arquitecturas responde a la necesidad de capturar patrones complejos y no lineales en los datos, así como de proporcionar una solución

robusta y precisa para la tarea de estimación. Entre las arquitecturas utilizadas se encuentran CNN's, XGBoost, LightGBM y MLP. Cada una de estas metodologías se caracteriza por sus propias ventajas y capacidades de modelado, adaptándose de manera específica a diferentes aspectos de la problemática.

Las arquitecturas seleccionadas no solo difieren en su estructura interna y en las técnicas de optimización empleadas, sino también en su enfoque para procesar y extraer información relevante de los datos. Por un lado, las arquitecturas de redes neuronales profundas, como las CNN y los MLP, se centran en la capacidad de aprender representaciones abstractas y no lineales a partir de los datos de entrada. Por otro lado, los modelos basados en ensambles de árboles, como XGBoost y LightGBM, ofrecen un enfoque basado en la construcción de múltiples árboles de decisión optimizados, lo que proporciona robustez frente a ruido y valores atípicos. A continuación, se presentará un análisis detallado de cada una de estas arquitecturas, destacando su funcionamiento y sus ventajas específicas en el contexto de la estimación de energía.

4.4.1 *Redes neuronales perceptrón multicapa*

El MLP es una de las arquitecturas más fundamentales en el ámbito de las redes neuronales. Consiste en múltiples capas de neuronas completamente conectadas, incluyendo una capa de entrada, una o más capas ocultas y una capa de salida. Matemáticamente, el funcionamiento de un MLP puede describirse mediante la siguiente ecuación para cada capa l :

$$\mathbf{a}^{(l)} = \sigma \left(\mathbf{W}^{(l)} \mathbf{a}^{(l-1)} + \mathbf{b}^{(l)} \right), \quad (4.6)$$

donde $\mathbf{a}^{(l)}$ representa las activaciones de la capa l , $\mathbf{W}^{(l)}$ es la matriz de pesos, $\mathbf{b}^{(l)}$ el vector de sesgos, y σ una función de activación no lineal, como la ReLU ($\sigma(z) = \max(0, z)$). Este mecanismo permite al MLP aprender representaciones complejas y no lineales de los datos de entrada, facilitando la captura de relaciones intrincadas entre las características observadas y las estimaciones de energía de los rayos cósmicos.

En el contexto de la estimación de energía de rayos cósmicos, los MLP son efectivos para modelar las relaciones no lineales entre las señales detectadas y las propiedades energéticas de los rayos. Su capacidad para generalizar a partir de grandes volúmenes de datos etiquetados los convierte en una herramienta valiosa para este tipo de análisis. Además, al optimizar la función de pérdida L mediante algoritmos como el SGD, el MLP ajusta los pesos $\mathbf{W}^{(l)}$ y sesgos $\mathbf{b}^{(l)}$ para minimizar el error en las predicciones, mejorando así la precisión de las estimaciones energéticas [118].

4.4.2 *Redes neuronales convolucionales*

Las CNN's son una clase especializada de redes neuronales diseñadas para procesar datos con estructuras de cuadrícula, como imágenes. Una CNN típica incluye capas convolucionales, capas de pooling y capas completamente conectadas. La operación fundamental en una capa convolucional se puede expresar matemáticamente como:

$$\mathbf{h}_{i,j} = \sigma \left(\sum_{m=1}^M \sum_{n=1}^N \mathbf{W}_{m,n} \mathbf{x}_{i+m,j+n} + b \right), \quad (4.7)$$

donde $\mathbf{h}_{i,j}$ es la activación en la posición (i, j) , $\mathbf{W}$ es el filtro convolucional, $\mathbf{x}$ es la entrada, b es el sesgo y σ es la función de activación. Este proceso permite a las CNN extraer características locales de los datos, como bordes y texturas, que son esenciales para identificar patrones complejos en las señales de rayos cósmicos.

En el ámbito de la astrofísica de rayos cósmicos, las CNN se han utilizado para la clasificación de eventos de rayos cósmicos ultraenergéticos, diferenciando entre fotones y hadrones. La capacidad de las CNN para captar patrones espaciales en las señales detectadas permite una clasificación precisa y eficiente, lo que es crucial para la correcta estimación de la energía. Además, mediante técnicas de regularización como el dropout y la normalización por lotes, las CNN pueden prevenir el sobreajuste y mejorar su capacidad de generalización a nuevos datos [114, 122].

4.4.3 XGBoost

XGBoost (Extreme Gradient Boosting) es un algoritmo de aprendizaje supervisado basado en árboles de decisión que utiliza técnicas de ensamble para mejorar la precisión y robustez de las predicciones [126]. XGBoost implementa un enfoque de boosting, donde múltiples árboles de decisión se construyen de manera secuencial, cada uno corrigiendo los errores del anterior. Matemáticamente, la función de predicción de XGBoost se define como:

$$\hat{y} = \sum_{k=1}^K f_k(\mathbf{x}), \quad (4.8)$$

donde $f_k(\mathbf{x})$ es la función de predicción del árbol k y K es el número total de árboles. La optimización se realiza minimizando una función de pérdida regularizada:

$$\text{Loss} = \sum_{i=1}^n l(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k), \quad (4.9)$$

donde l es la función de pérdida, y Ω es la penalización de complejidad del árbol.

En el contexto de la estimación de energía de rayos cósmicos, XGBoost ha sido implementado para aprovechar su robustez frente a ruido y valores atípicos en los datos. Su capacidad para manejar características altamente dimensionales y su eficiencia en el procesamiento de grandes volúmenes de datos lo hacen ideal para este tipo de análisis. Además, XGBoost incluye características avanzadas como el manejo de valores faltantes y la importancia de las características, lo que facilita la interpretación de los resultados y la identificación de las variables más relevantes para la estimación de energía [113].

4.4.4 *LightGBM*

LightGBM (Light Gradient Boosting Machine) es una implementación optimizada de los algoritmos de Gradient Boosting, enfocada en la eficiencia y escalabilidad [127]. LightGBM mejora el rendimiento de los modelos de Gradient Boosting tradicionales mediante técnicas como el crecimiento de árboles basado en hojas y el uso de histogramas para agrupar valores de características, lo que reduce la complejidad computacional y acelera el proceso de entrenamiento.

El crecimiento de árboles en LightGBM se realiza hoja por hoja, en lugar de nivel por nivel, lo que permite una mejor optimización de las divisiones y una mayor precisión del modelo:

$$\mathbf{h}_{i,j} = \sigma \left(\sum_{m=1}^M \sum_{n=1}^N \mathbf{w}_{m,n} \mathbf{x}_{i+m,j+n} + b \right), \quad (4.10)$$

además, LightGBM utiliza histogramas para discretizar las características, lo que reduce la cantidad de cálculos necesarios durante el entrenamiento:

$$\text{Bin}(x) = \left\lfloor \frac{x - x_{\min}}{x_{\max} - x_{\min}} \times B \right\rfloor, \quad (4.11)$$

donde B es el número de bins.

En el presente estudio, LightGBM ha sido empleado para la estimación de energía de rayos cósmicos, destacándose por su rapidez en el entrenamiento y su capacidad para manejar datos de alta dimensionalidad sin sacrificar la precisión. Su eficiencia en el procesamiento de grandes conjuntos de datos permite realizar estimaciones rápidas y precisas, fundamentales para el análisis en tiempo real de eventos de rayos cósmicos. Además, LightGBM ofrece una mayor eficiencia de memoria y tiempos de entrenamiento más cortos en comparación con otros algoritmos de Gradient Boosting, lo que lo convierte en una opción preferente para proyectos con recursos computacionales limitados [113, 127].

4.5 Integración del modelo en el framework de HAWC

La integración del modelo óptimo al marco de trabajo del observatorio HAWC se llevó a cabo mediante la incorporación de los pesos y sesgos del modelo en los datos reales. Para realizar esta tarea, se implementaron un conjunto de rutinas en bash, c++ y se realizó el aprendizaje del funcionamiento del clúster para procesar los datos suministrados, entre el conjunto de códigos destacan las ecuaciones de la propagación hacia adelante (forward) del modelo utilizando el lenguaje de programación Root basado en C++, con el fin de permitir la inferencia sobre los datos observacionales. Se diseñó un conjunto de algoritmos orientados a ejecutar la inferencia, empleando los datos detectados en un día por el archivo de reconstrucción del observatorio (archivo REC). Adicionalmente, se integró en un marco de trabajo de HAWC para el cálculo del espectro energético basado en estos datos. Los códigos implementados son los siguientes:

- Cálculo del área efectiva.
- Cálculo del espectro utilizando datos simulados de Monte Carlo.
- Cálculo del espectro utilizando datos experimentales.

4.5.1 Cálculo del área efectiva

El cálculo del área efectiva es un paso esencial para estimar la sensibilidad de un observatorio como HAWC al detectar rayos cósmicos. El área efectiva se define como el área dentro de la cual un evento puede ser detectado, reconstruido y pasar los cortes de calidad establecidos. El área efectiva $A_{\text{efectiva}}(E_T)$ se calcula utilizando la siguiente fórmula:

$$A_{\text{efectiva}}(E_T) = \frac{N(E_T)}{\Delta E_T \cdot \Delta t \cdot \Phi_{\text{modelo}} \cdot \Delta \Omega}, \quad (4.12)$$

donde $N(E_T)$ representa el número de eventos reconstruidos en un rango de energía verdadero E_T , ΔE_T es el ancho del bin de energía verdadera, Δt es el tiempo total de observación, Φ_{modelo} es el flujo del modelo de referencia, como el modelo CREAM-II y $\Delta \Omega$ es el elemento sólido diferencial definido como $\sin(\theta) d\theta d\varphi$, considerando un intervalo angular θ_1 a θ_2 .

Pasos de Cálculo y Ecuaciones

1. Inicialización del histograma de eventos y ponderación de eventos

Se inicializan histogramas ponderados para diferentes cortes basados en masas y se ajustan las variables. La selección de eventos se realiza mediante un conjunto de cortes definidos por condiciones de calidad.

2. Calibración de la ley de potencias

La relación entre la energía y el flujo se ajusta utilizando una función de ley de potencias de la forma:

$$f(x) = 2 \times 10^{-16} \cdot x \cdot (10^x)^{-1,5}, \quad (4.13)$$

este ajuste permite modelar la relación entre la energía logarítmica y el flujo de partículas.

3. Cálculo del ancho del bin de energía

Para cada bin, se calcula el valor central del logaritmo de la energía, el valor en GeV y el ancho del bin de energía utilizando:

$$\Delta E_{\text{GeV}} = 10^{\left(\log E_{\text{GeV}} + \frac{\Delta \log E_{\text{GeV}}}{2}\right)} - 10^{\left(\log E_{\text{GeV}} - \frac{\Delta \log E_{\text{GeV}}}{2}\right)}, \quad (4.14)$$

esto permite definir el rango energético cubierto por cada bin.

4. Cálculo del flujo de partículas y área efectiva

Se agrupan los eventos en histogramas de energía ponderados y se calcula el flujo para cada bin, teniendo en cuenta las correcciones por simulaciones de alta energía. El número de eventos ponderados se normaliza dividiendo por el flujo calculado y, posteriormente, se ajusta mediante el ancho del bin de energía y el ángulo sólido:

$$A_{\text{efectiva},i} = \frac{N_{\text{ponderados},i}}{\Delta E_{\text{GeV},i} \cdot \Delta \Omega}, \quad (4.15)$$

aquí, $N_{\text{ponderados},i}$ es el número de eventos observados en el bin i , después de aplicar los pesos correspondientes. El ángulo sólido $\Delta \Omega$ se calcula en función de los límites de ángulo cenital seleccionados.

El error asociado a cada bin de energía se estima tomando en cuenta los errores estadísticos en la distribución ponderada:

$$\Delta A_{\text{efectiva},i} = \frac{\Delta N_{\text{ponderados},i}}{\Delta E_{\text{GeV},i} \cdot \Delta \Omega}, \quad (4.16)$$

donde $\Delta N_{\text{ponderados},i}$ representa la incertidumbre estadística en el conteo de eventos ponderados.

El cálculo del área efectiva permite cuantificar la sensibilidad del observatorio HAWC para detectar rayos cósmicos de diferentes energías. A través de la normalización de los eventos ponderados, la corrección del flujo y la consideración del ángulo sólido, se obtiene un área efectiva que refleja la eficiencia del detector para capturar eventos en distintos rangos energéticos. Este proceso es clave para la reconstrucción del espectro de energía y el análisis de la respuesta del detector a diferentes tipos de partículas.

4.5.2 Cálculo del espectro utilizando datos simulados de Monte Carlo

El código comienza calculando el espectro de energía cruda, utilizando la fórmula para $\Phi_{\text{raw}}(E_R)$. Este espectro crudo proporciona una primera aproximación sin corregir de los datos obtenidos y se obtiene a partir de la energía reconstruida de los datos seleccionados después de aplicar cortes de calidad. Está dado por la fórmula:

$$\Phi_{\text{raw}}(E_R) = \frac{N(E_R)}{\Delta E_R \Delta t A \int_{\theta_1}^{\theta_2} \cos(\theta) d\Omega}, \quad (4.17)$$

donde $N(E_R)$ es el histograma de la energía reconstruida, Δt es el tiempo total de observación, ΔE_R es el ancho del bin de energía, A es el área de superficie de recolección y $d\Omega$ representa el ángulo sólido.

La matriz de respuesta, $P(E_R | E_T)$, se genera mediante simulaciones de Monte Carlo, donde E_T representa la energía verdadera y E_R la energía reconstruida. Esta matriz captura la probabilidad de que un evento con energía verdadera E_T sea detectado como E_R , debido a las limitaciones del detector y los efectos de migración de energía. En el código, se utiliza la

matriz de respuesta para definir la relación entre la energía verdadera y la energía reconstruida, permitiendo la corrección de las mediciones.

El núcleo del método de deconvolución bayesiano se basa en la fórmula de Bayes, aplicada de la siguiente manera:

$$P(E_T | E_R) = \frac{P(E_R | E_T) P_0(E_T)}{\sum_l P(E_R | E_{T_l}) P_0(E_{T_l})}, \quad (4.18)$$

aquí, $P_0(E_T)$ es una probabilidad inicial asignada a la energía verdadera, que puede ser uniforme o derivada de algún conocimiento previo del espectro. La fórmula de Bayes se utiliza para calcular la probabilidad de que un evento registrado como E_R tenga una energía verdadera E_T , dado el conocimiento previo.

A continuación, se calcula el número de eventos en cada bin de energía verdadera mediante la fórmula:

$$N(E_T) = \sum_j P(E_T | E_{R_j}) N(E_{R_j}), \quad (4.19)$$

proceso que se lleva a cabo de manera iterativa, reemplazando las probabilidades iniciales por las probabilidades actualizadas en cada iteración, hasta que se cumpla un criterio de convergencia, como la estabilidad del valor de χ^2 .

Una vez deconvolucionados los datos, se obtiene un espectro de energía total corregido utilizando la fórmula:

$$\Phi_{\text{unf}}(E_T) = \frac{N(E_T)}{\Delta E_T \Delta t A_{\text{eff}} \int_{\theta_1}^{\theta_2} \cos(\theta) d\Omega}, \quad (4.20)$$

donde A_{eff} es el área efectiva del detector, que corrige por la eficiencia y los efectos de los cortes de calidad y el trigger.

El método se valida aplicándolo a datos simulados, comparando el espectro deconvolucionado con el espectro verdadero de los datos de Monte Carlo. La convergencia del método se comprueba cuando el valor de χ^2 alcanza un valor constante después de un número determinado de iteraciones. En el código, se menciona que el método converge después de 10 iteraciones, lo cual se verifica con los resultados obtenidos y la comparación gráfica entre el espectro deconvolucionado y el espectro simulado verdadero.

El método se aplica no solo al espectro de todas las partículas, sino también a componentes específicas de rayos cósmicos como la componente ligera (H + He) y la componente de protones. Para cada componente, se definen diferentes cortes y matrices de respuesta, y se aplica el método de deconvolución para obtener espectros de energía específicos de cada componente.

El código presentado implementa una reconstrucción del espectro de energía de rayos cósmicos utilizando un método de deconvolución bayesiano. Este método, basado en el teorema de Bayes, permite corregir los efectos de la respuesta del detector y obtener un espectro de

energía más cercano a la realidad física. La clave del proceso es la construcción de la matriz de respuesta y la aplicación iterativa del teorema de Bayes para ajustar las probabilidades condicionales y mejorar la estimación del espectro verdadero.

4.5.3 Cálculo del espectro utilizando datos experimentales

El código comienza estableciendo una serie de parámetros esenciales:

- **Ángulo cenital y composición de masa:** Estos son parámetros clave para clasificar los eventos en función de su ángulo de incidencia y la masa del núcleo atómico primario (por ejemplo, protones, helio, carbono, etc). El ángulo cenital influye en la trayectoria que siguen los rayos cósmicos a través de la atmósfera, lo cual afecta la probabilidad de que se registren en el detector.
- **Factor de peso y tiempo de observación:** Aquí, el código ajusta la cantidad de eventos para un tiempo total de observación (Δt), lo cual es esencial para calcular los flujos de energía correctamente y obtener tasas de eventos consistentes.
- **Definición del espectro de energía:** Se establecen una serie de variables para manejar los rangos de energía, los histogramas y los errores asociados, que son fundamentales para construir los espectros de energía corregidos.

El código permite al usuario definir diferentes categorías de núcleos atómicos a reconstruir, mediante cortes en la masa según su identificación en el detector. Esto está basado en el corte aplicado en el parámetro de edad (s), que es una característica de la cascada atmosférica que depende de la masa de la partícula primaria.

La selección de "ligero" o "pesado" se basa en qué núcleos se desean analizar, por ejemplo, corte en He para separar protones y helio, o cortes en C para separar núcleos más pesados. Esta clasificación es esencial para estudiar cómo se distribuyen las diferentes especies nucleares en la energía total observada de los rayos cósmicos.

Aplicación del procedimiento de deconvolución

Cuando el usuario activa el procedimiento de deconvolución (*unfolding*), se realiza lo siguiente:

- La matriz de respuesta ($P(E_R | E_T)$) es recuperada. Esta matriz relaciona la energía verdadera (E_T) de las partículas con la energía reconstruida (E_R), y es clave para corregir los efectos de la respuesta del detector.
- Se aplican factores de eficiencia para ajustar las diferencias en la tasa de detección debido a la estructura del detector.
- Se realiza un proceso iterativo para corregir el histograma de energía reconstruida y obtener un histograma de energía verdadera.

El proceso de deconvolución iterativa busca aproximar cada vez más el espectro observado al espectro verdadero de las partículas primarias.

4.6 Construcción del Espectro de Energía

El código construye diferentes tipos de espectros:

- **Espectro de energía simple:** $\text{Flux}(E)$, que corresponde al número de eventos por intervalo de energía corregido por el área efectiva y el tiempo de observación.
- **Espectros ponderados:** Se presentan diferentes formas del espectro ponderado, como multiplicado por la energía (E), o por un factor de potencia como E^γ . Esto es útil para resaltar la estructura del espectro y para comparar con predicciones teóricas, ya que a menudo el espectro de rayos cósmicos sigue una ley de potencia.

El código ajusta los espectros utilizando funciones de ley de potencia. La ley de potencia es una aproximación común para los espectros de rayos cósmicos, y los parámetros se ajustan para encontrar la mejor representación de los datos observados.

Finalmente, el código guarda los resultados de las gráficas y los histogramas en archivos ROOT, para su posterior análisis y comparación.

El código en esencia trata de convertir las observaciones hechas por HAWC (energías reconstruidas) en espectros de energía más cercanos a las distribuciones físicas verdaderas de los rayos cósmicos. La deconvolución aplicada aquí permite corregir las distorsiones introducidas por la instrumentación del detector, y las selecciones de masa y ángulo permiten estudiar la composición y dinámica de los rayos cósmicos.

El análisis se centra en aislar diferentes componentes del espectro (protones, helio, elementos pesados) y ajustar los modelos a los datos corregidos. Esto es crucial para entender tanto el origen de los rayos cósmicos como su propagación a través del espacio y la atmósfera terrestre.

5.Resultados


5.1 Primera aproximación con datos pass5

5.1.1 Modelo inicial implementado ROOT

La primera implementación para la estimación de energía se realizó utilizando el paquete TMVA de ROOT. Este modelo inicial contó con una estructura sencilla: una capa de entrada con 14 neuronas, dos capas ocultas con 10 neuronas cada una, y una capa de salida, utilizando el optimizador BFGS. Este modelo fue principalmente una prueba de concepto para evaluar la viabilidad de las redes neuronales en la estimación energética de rayos cósmicos. El conjunto de datos utilizado corresponde al **Sim. Summary file (ROOT)** de la versión pass5, con las variables descritas en la Tabla 1, columna ROOT (pass5).

Figura 14

Comparación de la reconstrucción de la energía por el método tradicional y el modelo construido en ROOT.



Nota. El gráfico muestra la relación entre el logaritmo de la energía verdadera $\log(E_{\text{true}}/\text{GeV})$ y la energía reconstruida $\log(E_{\text{Reco}}/\text{GeV})$ por el método tradicional (LH, izquierda) y el modelo desarrollado en ROOT (derecha).

En la figura 14 se puede observar que la reconstrucción empleada por el método tradicional (LH) tiene peores estimaciones en altas energías generando subestimaciones e inclusive tiene un comportamiento inusual en la parte superior como un tumor, algo que se corrige en el modelo de ROOT mitigando estas subestimaciones y generando una estimación más confiable de la energía. La línea diagonal negra representa la igualdad ideal entre ambas


energías, mientras que el mapa de colores indica la densidad de eventos. La distribución de los eventos a lo largo de la línea de identidad sugiere una buena precisión del modelo en la reconstrucción de energías.

5.1.2 Implementación del modelo en TensorFlow

Luego de comprobar la eficiencia de las redes neuronales para la estimación de los rayos cósmicos frente al método tradicional empleado por HAWC, se decidió pasar de una prueba de concepto a un desarrollo más robusto. Se utilizó sobre el mismo conjunto de datos un modelo de TensorFlow denominado NN36, con una arquitectura de cuatro capas ocultas de 256, 128, 64 y 32 neuronas respectivamente, con activaciones ReLU y el optimizador Adam. Este modelo se entrenó con las variables descritas en la Tabla 1, columna TensorFlow (pass5).

Figura 16

Comparación de la reconstrucción de la energía por el método tradicional y el modelo construido en TensorFlow.




Nota. El gráfico muestra la relación entre el logaritmo de la energía verdadera $\log(E_{\text{true}}/\text{GeV})$ y la energía reconstruida $\log(E_{\text{Reco}}/\text{GeV})$ por el método tradicional (LH, izquierda) y el modelo desarrollado en TensorFlow (derecha).

En la figura 16 se puede observar que la estimación de la energía mejora aún más comparado con el modelo en ROOT, haciendo que la dispersión del eje central desaparezca y logrando una estimación más precisa a altas energías 10^{15} – $10^{16.5}$ eV, rango donde el modelo ROOT presentaba un comportamiento inadecuado para energías mayores que 10^{16} eV. Con este modelo se decidió continuar con la siguiente fase: el cálculo del espectro con datos simulados del observatorio (Sim. Summary file) y reales (REC file).

Luego de obtener la estimación de la energía se realizaron las validaciones con los datos observacionales. El primer paso fue el cálculo del área efectiva del observatorio. Para ello, el modelo fue implementado en el framework de HAWC escrito en C++, construyendo una cadena de códigos para hacer inferencia usando los pesos y los sesgos en la propagación hacia adelante sobre los datos observacionales. Seguido de esto se utilizó el código del cálculo del área efectiva explicado en la subsección 4.5.1.

La figura 18 representa el área efectiva que el HAWC puede detectar. Como se puede observar en los últimos puntos, existe un comportamiento inusual de la eficiencia a altas

Figura 18*Comparación del área efectiva método tradicional vs modelo NN36.*

Nota. El gráfico muestra el área efectiva A_{eff} en función de la energía verdadera $\log_{10}(E_{\text{true}}/\text{GeV})$ comparando el método tradicional (LH, izquierda) y el modelo NN36 (derecha).

energías: a medida que aumenta tiende a estabilizarse. Al realizar la misma gráfica con el método clásico se encontró que también presenta esta discrepancia. La razón de este comportamiento se desconoce, aunque una posibilidad es que la cadena de simulaciones deba ser corregida. Debido a esto, se decidió volver a la cadena de simulaciones de la versión anterior, pass4.

5.2 Resultados con datos pass4 (Resultados principales)

Debido a la discrepancia observada para el área efectiva en HAWC con datos pass5, se validaron los modelos con la versión anterior del conjunto de simulaciones, pass4. Para asegurar que el modelo escogido fuera el mejor, se implementó el pipeline descrito en la sección 4.3. Con este conjunto de datos se probaron dos modelos: MP4CE y MP4SE.

5.2.1 Pipeline de modelado y metodología

Para elegir el mejor modelo para trabajar con pass4 se implementó el pipeline explicado en la sección 4.3. Se presentan los resultados para el modelo MP4CE y su desempeño en las diferentes arquitecturas para el conjunto de testeo y validación. Los datos se dividieron en un 80 % de entrenamiento y un 20 % de testeo; todas las arquitecturas se implementaron con búsqueda bayesiana de hiperparámetros.

Multi layer perceptron (MLP)

La red neuronal se construyó utilizando el método `Sequential` de Keras, con una arquitectura de cinco capas densamente conectadas:


- Capa de Entrada: 256 neuronas con activación ReLU.

- Capa Oculta 2: 128 neuronas con activación ReLU.
- Capa Oculta 3: 64 neuronas con activación ReLU.
- Capa Oculta 4: 32 neuronas con activación ReLU.
- Capa de Salida: 1 neurona (regresión).

El modelo se compiló con el optimizador Adam. Durante la última época alcanzó un MSE de 0.0276 y un MAE de 0.1212 en entrenamiento.

Figura 20

Representación de las métricas de entrenamiento y validación del modelo MLP.



Nota. Gráfica que muestra el comportamiento del Error Absoluto Medio (MAE) y el Error Cuadrático Medio (MSE) a lo largo de las épocas para los conjuntos de entrenamiento y validación, junto con la puntuación R^2 para ambos entrenamiento y validación.

En validación, el modelo alcanzó un MSE de 0,0279 y un MAE de 0,1218, valores casi idénticos a los de entrenamiento, lo que indica buena generalización sin sobreajuste ni subajuste.

La línea diagonal negra de la figura 21 representa la igualdad ideal entre ambas energías; el mapa de colores indica la densidad de eventos. El R^2 en entrenamiento fue 0,9182 y en validación 0,9109, lo que implica que el modelo explica más del 90% de la variabilidad en los datos.


Modelo XGBoost

Los parámetros óptimos obtenidos mediante búsqueda bayesiana fueron:

- `colsample_bytree`: 0.8423
- `gamma`: 0.0
- `learning_rate`: 0.2
- `max_depth`: 6
- `n_estimators`: 500
- `subsample`: 0.9940

Figura 21

Representación esquemática de la reconstrucción de eventos con el modelo MLP.



Nota. El gráfico muestra la relación entre el logaritmo de la energía verdadera $\log(E_{\text{true}}/\text{GeV})$ y la energía reconstruida $\log(E_{\text{Reco}}/\text{GeV})$ por el modelo MLP.

En entrenamiento se obtuvo un MSE de 0.0250 y MAE de 0.1165; en prueba, MSE de 0.0281 y MAE de 0.1225.

El modelo XGBoost alcanzó un R^2 de 0.9201 en entrenamiento y 0.9101 en prueba, confirmando buena generalización.


LightGBM

Los parámetros óptimos fueron:


- colsample_bytree: 1.0
- learning_rate: 0.2
- max_depth: 7
- n_estimators: 500
- reg_alpha: 0.2
- reg_lambda: 0.0
- subsample: 0.7

En entrenamiento se obtuvo MSE de 0.0262 y MAE de 0.1192; en prueba, MSE de 0.0282 y MAE de 0.1228.

El modelo LightGBM alcanzó un R^2 de 0.9163 en entrenamiento y 0.9099 en prueba.

Figura 22*Reconstrucción de la energía XGBoost.*

Nota. El gráfico muestra la relación entre el logaritmo de la energía verdadera $\log(E_{\text{true}}/\text{GeV})$ y la energía reconstruida $\log(E_{\text{Reco}}/\text{GeV})$ por el modelo XGBoost.

Figura 23*Reconstrucción de la energía LightGBM.*

Nota. El gráfico muestra la relación entre el logaritmo de la energía verdadera $\log(E_{\text{true}}/\text{GeV})$ y la energía reconstruida $\log(E_{\text{Reco}}/\text{GeV})$ por el modelo LightGBM.


Convolutional Neural Network (CNN)

La arquitectura utilizada fue:

- Capa Conv1D con 64 filtros y kernel 3, activación ReLU.
- Capa Conv1D con 64 filtros y kernel 3, activación ReLU.
- Capa MaxPooling1D con ventana de 2.
- Capa Dropout con tasa de 0.1.
- Capa Conv1D con 128 filtros y kernel 3, activación ReLU.
- Capa MaxPooling1D con ventana de 2.
- Capa Dropout con tasa de 0.1.
- Capa Flatten.
- Capa Dense con 128 unidades y activación ReLU.
- Capa Dropout con tasa de 0.1.
- Capa Dense con 64 unidades y activación ReLU.
- Capa Dense con 1 unidad de salida (regresión).

Figura 24

Gráfica de las métricas de la CNN.




Nota. Gráfica que muestra el comportamiento del error absoluto medio (MAE) y el error cuadrático medio (MSE) junto con la puntuación R^2 para ambos entrenamiento y validación.

En entrenamiento se obtuvo un MSE de 0.0365 y MAE de 0.1518; en prueba, MSE de 0.0367 y MAE de 0.1522.

El modelo CNN alcanzó un R^2 de 0.8832 en entrenamiento y 0.8825 en prueba.

Elección del mejor modelo

El desempeño de los modelos varía en función de su arquitectura. La elección se basó no solo en la mejor métrica sino también en el desempeño en la reconstrucción de altas energías;

Figura 25*Reconstrucción de la energía CNN.*

Nota. El gráfico muestra la relación entre el logaritmo de la energía verdadera $\log(E_{\text{true}}/\text{GeV})$ y la energía reconstruida $\log(E_{\text{Reco}}/\text{GeV})$ por el modelo CNN.

todos los modelos presentan un margen de error mayor a bajas energías.

Tabla 2*Comparación de métricas entre modelos.*

Modelo	Conjunto	MSE	MAE	R^2
MLP	Entrenamiento	0.0276	0.1212	0.9182
	Prueba	0.0279	0.1218	0.9109
XGBoost	Entrenamiento	0.0250	0.1165	0.9201
	Prueba	0.0281	0.1225	0.9101
LightGBM	Entrenamiento	0.0262	0.1192	0.9163
	Prueba	0.0282	0.1228	0.9099
CNN	Entrenamiento	0.0365	0.1518	0.8832
	Prueba	0.0367	0.1522	0.8825

Nota. Cuadro comparativo de las métricas principales (MSE, MAE y R^2) para cada modelo en los conjuntos de entrenamiento y prueba/validación.

La Tabla 2 muestra que XGBoost alcanzó el mejor rendimiento en entrenamiento, pero en prueba el MLP mostró un rendimiento ligeramente superior. Esta discrepancia indica que XGBoost podría estar experimentando sobreajuste, mientras que el MLP mantuvo un equilibrio más consistente entre entrenamiento y prueba, lo que sugiere mejor capacidad de generalización. La CNN presentó el rendimiento más bajo en ambas etapas, posiblemente porque está diseñada para datos con estructura espacial o temporal, no para este tipo de variables tabulares. Se seleccionó el modelo MLP para continuar con el desarrollo.

5.2.2 MP4CE


Simulación

Este modelo se entrenó con las variables descritas en la Tabla 1, columna MP4CE (pass4). La diferencia principal respecto a MP4SE es que MP4CE incluye estimadores de energía intrínsecos de la reconstrucción de los diferentes softwares. El conjunto de datos permitió obtener un MSE de 0,0276. Se procedió con el cálculo de los parámetros físicos.

Área efectiva

Figura 26

Cálculo del área efectiva usando el modelo MP4CE.



Nota. La figura muestra el área efectiva (A_{eff}) para la detección de rayos cósmicos en el experimento HAWC en función de la energía verdadera de las partículas, representada como $\log_{10}(E_{\text{True}}/\text{GeV})$ en el eje horizontal para el modelo MP4CE.


En la figura 26, los puntos negros representan el área efectiva en diferentes energías, evidenciando un aumento conforme incrementa la energía, lo cual es esperado porque a energías más altas aumenta la probabilidad de detección. La línea punteada azul indica el área geométrica total del detector HAWC. A energías bajas ($\log_{10}(E_{\text{True}}/\text{GeV}) < 4$), el área efectiva es menor que el área geométrica, reflejando menor eficiencia de detección. A medida que la energía aumenta, el área efectiva se aproxima y estabiliza en torno al área geométrica.

Matriz de respuesta

La matriz de respuesta es una herramienta fundamental que relaciona la energía verdadera $\log_{10}(E_{\text{True}}/\text{GeV})$ con la energía reconstruida $\log_{10}(E_{\text{Reco}}/\text{GeV})$ medida por el detector. Describe cómo el detector responde a diferentes energías y permite corregir los efectos de distorsión introducidos por la instrumentación. En el análisis se utiliza para aplicar procedimientos de deconvolución que ajustan el espectro reconstruido hacia el espectro físico verdadero.

Figura 27

Matriz de respuesta del HAWC con el modelo MP4CE.



Nota. La imagen muestra la matriz de respuesta del experimento HAWC, la cual representa la probabilidad $P(E_{\text{reco}}|E_{\text{True}})$ de que un evento con una energía verdadera E_{True} sea reconstruido con una energía E_{reco} en el detector para el modelo MP4CE.

La figura 27 muestra la probabilidad $P(E_{\text{reco}} | E_{\text{True}})$. La escala de color indica la probabilidad de reconstrucción: zonas en azul corresponden a baja probabilidad y zonas en amarillo a probabilidad alta, cercana a 1. La diagonal principal representa los eventos en los que la energía reconstruida coincide con la verdadera; las zonas dispersas indican incertidumbre debida a efectos de instrumentación.

Espectro de rayos cósmicos


El flujo de rayos cósmicos en función de la energía se calcula mediante la expresión descrita en la subsección 4.5.1:

$$\text{Flujo}(E) = \frac{N(E)}{A_{\text{eff}} \Delta t \Delta \Sigma}. \quad (5.1)$$

Finalmente, se realiza un ajuste de ley de potencia para representar la variación del flujo con la energía.

Figura 28

Histograma de energía del modelo MP4CE.




Nota. La imagen muestra un histograma del número de eventos de rayos cósmicos detectados por el experimento HAWC en función de la energía reconstruida, expresada como $\log_{10}(E_{\text{rec}}/\text{GeV})$. Este histograma representa los datos recopilados durante un día de observación, etiquetado como “Run05481”.

La figura 28 muestra el histograma de eventos en función de la energía reconstruida durante el Run05481, restringido a ángulos cenitales de 0 a 35. El pico entre $\log_{10}(E_{\text{rec}}/\text{GeV}) \approx 3,5$ y 4,5 indica los valores donde HAWC detecta la mayor cantidad de rayos cósmicos; el número de eventos disminuye a energías más bajas y más altas por menor probabilidad de detección y menor abundancia de partículas, respectivamente.

Para profundizar en la distribución de energía se construyó el espectro ponderado por $E^{2,6}$:

La gráfica 29 presenta un comportamiento inusual: el flujo ponderado aumenta con la energía reconstruida en lugar de mantenerse constante o decrecer ligeramente. Este incremento sugiere posibles problemas en el procesamiento de los datos, como errores en la matriz de respuesta, inconsistencias en la reconstrucción de la energía o una ponderación incorrecta. La tendencia ascendente indica la necesidad de revisar el procedimiento de reconstrucción y las correcciones aplicadas al flujo.

Figura 29*Espectro $E^{2,6}$ del modelo MP4CE.*

Nota. Espectro de rayos cósmicos ponderado por un factor de energía $E^{2,6}$ para resaltar la tendencia del flujo en función de la energía reconstruida.

5.2.3 MP4SE

Simulación


Este modelo se entrenó con las variables descritas en la Tabla 1, columna MP4SE (pass4). La diferencia principal respecto a MP4CE es que MP4SE **no** incluye estimadores de energía intrínsecos de la reconstrucción. El modelo alcanzó un MSE de 0,0295 y un MAE de 0,1227 en validación.

Área efectiva

En la figura 30 se observa el mismo comportamiento general que en MP4CE (figura 26): el área efectiva aumenta con la energía y se aproxima al área geométrica a altas energías. A energías bajas ($\log_{10}(E_{\text{True}}/\text{GeV}) < 4$) la eficiencia es menor que el área geométrica, aunque ligeramente inferior a la de MP4CE en ese rango.

Matriz de respuesta

La matriz de respuesta para MP4SE se calcula con el mismo procedimiento descrito para MP4CE en la subsección anterior.

Figura 30*Cálculo del área efectiva usando el modelo MP4SE.*

Nota. La figura muestra el área efectiva (A_{eff}) para la detección de rayos cósmicos en el experimento HAWC en función de la energía verdadera de las partículas, representada como $\log_{10}(E_{\text{True}}/\text{GeV})$ en el eje horizontal para el modelo MP4SE.


Al comparar la figura 31 con la del modelo MP4CE (figura 27), se aprecia que MP4SE presenta una mayor dispersión, especialmente en los rangos de baja energía reconstruida, lo que indica mayor ruido en esa región. A energías bajas, MP4SE tiende a asignar una gama más amplia de valores de energía reconstruida para un mismo valor de energía verdadera. En contraste, MP4CE muestra una alineación más clara y menor dispersión, sugiriendo mejor capacidad de reconstrucción con menor ruido.

Espectro de rayos cósmicos

El histograma de eventos durante el Run05481 para el modelo MP4SE muestra un comportamiento similar al de MP4CE (figura 28).

Para profundizar en la distribución de energía se construyó el espectro ponderado por $E^{2,6}$.

La gráfica 33 presenta un espectro ponderado por $E^{2,6}$ con un comportamiento más adecuado que el de MP4CE: sigue una tendencia relativamente constante en la mayoría del rango de energías, lo cual es un indicio positivo de que el modelo captura adecuadamente el flujo de rayos cósmicos. Se observa una ligera tendencia ascendente que comienza a descender a partir de $10^{15,5}$ eV. A pesar de esta leve inclinación, MP4SE proporciona una representación razonable del espectro; para mejorar la precisión se recomienda revisar la calibración de la matriz de respuesta y la reconstrucción de la energía.

Figura 31*Matriz de respuesta del HAWC con el modelo MP4SE.*

Nota. La imagen muestra la matriz de respuesta del experimento HAWC, la cual representa la probabilidad $P(E_{\text{reco}}|E_{\text{True}})$ de que un evento con una energía verdadera E_{True} sea reconstruido con una energía E_{reco} en el detector para el modelo MP4SE.

5.3 Interpretación de los Resultados


5.3.1 Estimación de la energía

La Figura 34 muestra la reconstrucción de la energía en el experimento HAWC, comparando el método clásico (LH), el modelo MP4CE y el modelo MP4SE. En cada gráfico se observa la relación entre la energía reconstruida $\log_{10}(E_{\text{rec}}/\text{GeV})$ y la energía verdadera $\log_{10}(E_{\text{true}}/\text{GeV})$, con una línea de referencia $y = x$ (diagonal negra) que representa la reconstrucción ideal. La escala de color indica la densidad de eventos en cuentas por segundo.

- **Método Clásico (LH):** Exhibe una dispersión amplia, especialmente a bajas energías, lo que introduce ruido y afecta la calidad general de la reconstrucción.
- **Modelo MP4CE:** Presenta una mejora considerable: la distribución de eventos se concentra alrededor de la línea de referencia con menor dispersión, especialmente en energías bajas a intermedias.
- **Modelo MP4SE:** También mejora respecto al método clásico, pero muestra mayor dispersión que MP4CE a bajas energías. A altas energías sigue la línea de referencia de manera aceptable.

El modelo MP4CE demuestra ser el más adecuado para la reconstrucción de la energía en HAWC, con menor dispersión y mayor precisión en la estimación de la energía verdadera.

Sesgo (Bias)

Figura 32*Histograma de energía del modelo MP4SE.*

Nota. La imagen muestra un histograma del número de eventos de rayos cósmicos detectados por el experimento HAWC en función de la energía reconstruida, expresada como $\log_{10}(E_{\text{rec}}/\text{GeV})$. Este histograma representa los datos recopilados durante un día de observación, etiquetado como “Run05481”.

Las gráficas muestran el sesgo en la reconstrucción de energía, definido como la diferencia entre $\log_{10}(E_{\text{rec}}/\text{GeV})$ y $\log_{10}(E_{\text{true}}/\text{GeV})$ en función de $\log_{10}(E_{\text{true}}/\text{GeV})$. La imagen izquierda corresponde a protones y la derecha a núcleos de hierro; se comparan el método Likelihood (rojo), MP4SE (negro) y MP4CE (azul).


- **Sesgo para protones:** El método LH presenta el mayor sesgo, especialmente a bajas energías. MP4SE muestra un sesgo más consistente y cercano a cero que LH. MP4CE mantiene el sesgo más bajo y estable en todo el rango.
- **Sesgo para hierro:** El comportamiento es similar al de protones. MP4CE mantiene el sesgo más bajo y constante en todo el rango energético, siendo el más preciso para núcleos de hierro.

En ambas partículas, MP4CE demuestra ser el más efectivo para minimizar el sesgo, lo que lo hace superior tanto a MP4SE como al método LH.


5.3.2 Análisis del Área Efectiva en HAWC

La Figura 36 muestra la comparación del área efectiva A_{eff} en función de la energía verdadera $\log_{10}(E_{\text{True}}/\text{GeV})$ para el método clásico (LH) y los modelos MP4CE y MP4SE.

- **Método Clásico (LH):** El área efectiva aumenta hasta estabilizarse alrededor de 10^4 m^2 y se acerca al área geométrica a altas energías, aunque con menor eficiencia que

Figura 33*Espectro $E^{2.6}$ del modelo MP4SE.*

Nota. Espectro de rayos cósmicos ponderado por un factor de energía $E^{2.6}$ para resaltar la tendencia del flujo en función de la energía reconstruida.

Figura 34*Dispersión E_{rec} vs. E_{true} para el método tradicional, modelos MP4CE y MP4SE.*

(a) Método clásico


(b) Modelo MP4CE

(c) Modelo MP4SE

Nota. Comparación de la reconstrucción de la energía entre el método clásico (LH) y los modelos MP4CE y MP4SE en el experimento HAWC. La dispersión en cada gráfico representa la relación entre la energía reconstruida $\log_{10}(E_{rec}/\text{GeV})$ y la energía verdadera $\log_{10}(E_{true}/\text{GeV})$. La línea diagonal negra representa la reconstrucción ideal $y = x$. El modelo MP4CE muestra la menor dispersión y una mayor precisión en la estimación de energía, seguido de MP4SE, mientras que el método clásico exhibe una dispersión significativa, especialmente a bajas energías.

los modelos IA en la mayoría del rango.


- **Modelo MP4CE:** Alcanza valores cercanos al área geométrica en una gama más amplia de energías, indicando mayor eficiencia en la detección y reconstrucción de eventos, especialmente a bajas energías.
- **Modelo MP4SE:** Mejora respecto al método clásico, aunque su área efectiva es li-

Figura 35*Sesgo de energía para protones y núcleos de hierro.*

(a) Sesgo protón

(b) Sesgo hierro

Nota. Sesgo en la reconstrucción de la energía para protones (imagen izquierda) y núcleos de hierro (imagen derecha) en el experimento HAWC, comparando el método clásico de Likelihood (LH) y los modelos MP4CE y MP4SE. El sesgo se define como la diferencia entre el logaritmo de la energía reconstruida $\log_{10}(E_{\text{rec}}/\text{GeV})$ y el logaritmo de la energía verdadera $\log_{10}(E_{\text{true}}/\text{GeV})$ en función de $\log_{10}(E_{\text{true}}/\text{GeV})$.

Figura 36*Área efectiva del método tradicional, modelo MP4CE y MP4SE.*

(a) Método clásico

(b) Modelo MP4CE

(c) Modelo MP4SE

Nota. Comparación del área efectiva A_{eff} en función de la energía verdadera $\log_{10}(E_{\text{true}}/\text{GeV})$ entre el método clásico (LH) y los modelos MP4CE y MP4SE en el experimento HAWC. El área geométrica del HAWC se muestra como una línea azul discontinua. MP4CE muestra la mayor área efectiva en todo el rango de energías, seguido de cerca por MP4SE, mientras que el método clásico exhibe un área efectiva menor, especialmente en el rango de bajas energías.

geramente inferior a la de MP4CE a bajas energías. A altas energías, ambos modelos convergen a valores similares.

En términos de área efectiva, MP4CE ofrece la mejor performance en todo el rango energético.


5.3.3 Análisis de la Matriz de Respuesta en HAWC

La Figura 37 muestra la comparación de la matriz de respuesta para los tres métodos. La probabilidad $P(E_{\text{rec}} | E_{\text{true}})$ se indica con una escala de color donde los valores cercanos a 1 (amarillo) representan mejor correspondencia.

- **Método Clásico (LH):** Dispersión considerable a baja y media energía; muchos eventos desplazados de la diagonal ideal.

Figura 37

Matriz de respuesta comparada entre método tradicional, modelo MP4CE y MP4SE.



(a) Método clásico

(b) Modelo MP4CE

(c) Modelo MP4SE

Nota. Comparación de la matriz de respuesta $P(E_{\text{rec}} | E_{\text{true}})$ entre el método clásico (LH) y los modelos MP4CE y MP4SE en el experimento HAWC. La diagonal representa la correspondencia ideal entre la energía reconstruida y la energía verdadera. El modelo MP4CE muestra la menor dispersión y la mejor correspondencia entre ambas energías, seguido por MP4SE, mientras que el método clásico presenta la mayor dispersión y menor precisión.

- **Modelo MP4CE:** La mayoría de los eventos se concentran cerca de la diagonal, especialmente a energías intermedias y altas, con menor dispersión que LH y MP4SE.
- **Modelo MP4SE:** Mejora respecto a LH, aunque con dispersión más amplia que MP4CE a bajas energías.


MP4CE es el modelo preferido para la reconstrucción de energía en HAWC cuando se requiere alta precisión en la correspondencia entre energía reconstruida y verdadera.

5.3.4 Análisis del Espectro de Rayos Cósmicos en HAWC

La Figura 38 presenta el espectro de rayos cósmicos ponderado por $E^{2.6}$ para los tres métodos, en función de $\log_{10}(E_{\text{rec}}/\text{GeV})$.

Figura 38

Espectro $E^{2.6}$ comparado entre método tradicional, modelo MP4CE y MP4SE.



(a) Método clásico

(b) Modelo MP4CE

(c) Modelo MP4SE

Nota. Comparación del espectro de rayos cósmicos reconstruido ponderado por $E^{2.6}$ entre el método clásico (LH) y los modelos MP4CE y MP4SE en el experimento HAWC. La ponderación aplicada compensa la caída rápida del flujo a altas energías, permitiendo observar la consistencia en la reconstrucción del flujo para cada modelo. MP4SE muestra la mayor consistencia en el espectro a altas energías, mientras que MP4CE, aunque es el mejor en otros aspectos, presenta una ligera sobreestimación en este rango.

- **Método Clásico (LH):** Muestra una distribución relativamente constante en todo el rango, aunque con menor precisión general en la reconstrucción.
- **Modelo MP4CE:** Presenta una ligera tendencia ascendente a altas energías, lo que podría indicar sobreestimación del flujo en ese rango, posiblemente por una sobrecorrección en la reconstrucción o por discrepancias entre las variables de Monte Carlo y los datos reales. Se requieren ajustes adicionales.
- **Modelo MP4SE:** Muestra un espectro ponderado más estable a lo largo de todo el rango de energías, ofreciendo una representación más realista del flujo de rayos cósmicos y evitando la tendencia ascendente de MP4CE.

En términos de área efectiva y matriz de respuesta, MP4CE supera claramente a los demás modelos. Sin embargo, en el espectro de rayos cósmicos, MP4SE demuestra ser más consistente y realista. Se necesitan análisis más detallados para determinar cuál espectro tiene el comportamiento correcto; una combinación o ajuste de ambos modelos podría ser ideal para mejorar la reconstrucción del flujo de energía en el experimento HAWC.

6. Conclusiones

El objetivo principal de esta tesis fue mejorar la estimación de la energía de los rayos cósmicos detectados por el observatorio HAWC mediante el desarrollo y comparación de diferentes modelos basados en redes neuronales. Inicialmente, se implementó un modelo utilizando el paquete TMVA de ROOT con datos de simulaciones reconstruidas de la versión pass5. Este modelo evidenció que las redes neuronales podían mejorar al método actual de Likelihood (LH) en la estimación de la energía, especialmente en altas energías, donde este mostraba subestimaciones significativas.

Tras evidenciar las limitaciones en los datos de pass5, se decidió utilizar la versión anterior de simulaciones, pass4, y se desarrollaron dos modelos más robustos: MP4CE y MP4SE. El modelo MP4CE incluyó estimadores de energía intrínsecos de la reconstrucción, mientras que MP4SE los excluyó. Ambos modelos fueron optimizados mediante un *pipeline* que ajustó la arquitectura y los hiperparámetros de las redes neuronales para maximizar su rendimiento.

La estimación de la energía del modelo MP4CE mostró la menor dispersión y el sesgo más bajo en la reconstrucción de la energía, tanto para protones como para núcleos de hierro. Esto indica una mayor precisión y consistencia en comparación con MP4SE y el método tradicional LH. MP4SE también mejoró respecto a LH, pero presentó mayor dispersión, especialmente a bajas energías. En el área efectiva, todos los modelos alcanzaron un área efectiva cercana al área geométrica del HAWC en un amplio rango de energías, evidenciando una eficiencia similar en la detección y reconstrucción de eventos. La matriz de respuesta de MP4CE mostró una menor dispersión y una alta concentración de eventos cerca de la diagonal ideal, reflejando una reconstrucción más precisa de la energía verdadera. MP4SE presentó una dispersión mayor en energías bajas debido a la subestimación que presentó en la reconstrucción de energías, aunque mejor que el método LH, que mostró la mayor dispersión y menor precisión.

Aunque en el espectro de rayos cósmicos MP4CE demostró superioridad en aspectos anteriores, presentó una ligera sobreestimación en el flujo a altas energías en el espectro ponderado por $E^{2.6}$ dando un comportamiento ascendente que no representa el comportamiento natural del espectro de rayos cósmicos, este comportamiento puede deberse a dos posibilidades, fluctuación estadística debido a que se está calculando el espectro con día observacional o discrepancia en el comportamiento entre las variables añadidas para este modelo (estimadores de energía) de monte Carlo y datos reales. Por otro lado, MP4SE ofreció una representación más consistente y realista del espectro de rayos cósmicos, evitando la tendencia ascendente observada en MP4CE, en relación con LH se observa que el espectro MP4SE tiene un comportamiento más cordial, presentando una ascendencia y luego descenso significativo más suavizado, en cambio, el modelo LH tiene un comportamiento más abrupto y radical. Se necesitan análisis más detallados para saber cuál espectro funcionaría mejor y tiene el

comportamiento correcto entre los modelos de estimación de energía LH y MP4SE.

Finalmente, el modelo MP4CE se posiciona como el más preciso, cumpliendo el objetivo principal de la tesis: mejorar el estimador de energía de los rayos cósmicos en HAWC y superar al modelo MP4SE y al método tradicional LH en términos de dispersión, sesgo y eficiencia. Una calibración precisa de la energía mejora la separación gamma/hadrón al afinar los cortes dependientes de energía, lo que incrementa la sensibilidad a fuentes astrofísicas transitorias. Sin embargo, la sobreestimación observada en el espectro ponderado $E^{2,6}$ indica que se requieren ajustes adicionales (correcciones de eficiencia o retraining con datos reales) antes de explotar plenamente estas ventajas científicas.

Referencias Bibliográficas

- [1] HAWC Collaboration. HAWC: High-Altitude Water Cherenkov Gamma-Ray Observatory; 2024. <https://www.hawc-observatory.org/>.
- [2] Carlson P. Early history of cosmic ray studies. *Astroparticle Physics*. 2012;39–40:2-11.
- [3] Wilson CTR. On the Ionisation of Atmospheric Air. *Proceedings of the Royal Society of London*. 1901;68:151-61.
- [4] Hess VF. Über Beobachtungen der durchdringenden Strahlung bei sieben Freiballonfahrten. *Physikalische Zeitschrift*. 1912;13:1084-91.
- [5] CERN. Victor Hess discovers cosmic rays; 1912. <https://timeline.web.cern.ch/victor-hess-discovers-cosmic-rays-0>.
- [6] Millikan RA. Cosmic Rays as Evidence of a Creative Intelligence. *Nature*. 1925;116:845-7.
- [7] Compton AH. A Geographic Study of Cosmic Rays. *Physical Review*. 1933;43(5):387-403.
- [8] Blasi P. The Origin of Galactic Cosmic Rays. *Astronomy and Astrophysics Review*. 2013;21:70.
- [9] Gaisser TK, Engel R, Resconi E. *Cosmic Rays and Particle Physics*. 2nd ed. Cambridge University Press; 2016.
- [10] Adriani O, Barbarino GC, Bazilevskaya GA, et al. PAMELA measurements of cosmic-ray proton and helium spectra. *Science*. 2011;332(6025):69-72.
- [11] Aguilar M, Aisa D, Alpat B, et al. Precision Measurement of the Proton Flux in Primary Cosmic Rays from Rigidity 1 GV to 1.8 TV with the Alpha Magnetic Spectrometer on the International Space Station. *Physical Review Letters*. 2015;114(17):171103.
- [12] Kachelrieß M, Neronov A, Semikoz DV. Signatures of a Galactic Origin of Anisotropy in the Arrival Directions of Ultra-High Energy Cosmic Rays. *Physical Review D*. 2019;99(4):043007.
- [13] Harari D, Mollerach S, Roulet E. Magnetic lensing of extremely high energy cosmic rays in a galactic wind. *Journal of High Energy Physics*. 2002;2002(07):006.

- [14] Kampert KH, Unger M. Measurements of the cosmic ray composition with air shower experiments. *Astroparticle Physics*. 2012;35(10):660-78.
- [15] Pierog T, Karpenko I, Katzy JM, Yatsenko E, Werner K. EPOS LHC: Test of collective hadronization with LHC data. *Physical Review C*. 2015;92(3):034906.
- [16] Grenier IA, Black JH, Strong AW. The nine lives of cosmic rays in galaxies. *Annual Review of Astronomy and Astrophysics*. 2015;53:199-246.
- [17] Particle Data Group. Review of Particle Physics. *Progress of Theoretical and Experimental Physics*. 2024;2024(8):083C01.
- [18] Anchordoqui LA. Ultra-High-Energy Cosmic Rays. *Physics Reports*. 2019;801:1-93.
- [19] Kotera K, Olinto AV. The Astrophysics of Ultrahigh-Energy Cosmic Rays. *Annual Review of Astronomy and Astrophysics*. 2011;49:119-53.
- [20] Hörandel JR. Models of the Knee in the Energy Spectrum of Cosmic Rays. *Astroparticle Physics*. 2004;21:241-65.
- [21] Gaisser TK, Stanev T, Tilav S. Cosmic Ray Energy Spectrum from Measurements of Air Showers. *Frontiers of Physics*. 2013;8(6):748-58.
- [22] Kotera K, Olinto AV. The astrophysics of ultrahigh energy cosmic rays. *Annual Review of Astronomy and Astrophysics*. 2011;49:119-53.
- [23] Hillas AM. The origin of ultra-high-energy cosmic rays. *Annual Review of Astronomy and Astrophysics*. 1984;22:425-44.
- [24] Waxman E. Cosmological Gamma-Ray Bursts and the Highest Energy Cosmic Rays. *Physical Review Letters*. 1995;75:386-9.
- [25] Burrows A, Vartanyan D. Core-collapse supernova explosion theory. *Nature*. 2021;589(7840):29-39.
- [26] Tavani M, Giuliani A, et al. Direct Evidence for Hadronic Cosmic-Ray Acceleration in the Supernova Remnant IC 443. *The Astrophysical Journal Letters*. 2010;710(2):L151.
- [27] Bykov AM, Amato E, Petrov AE, Krassilchtchikov AM, Levenfish KP. Pulsar Wind Nebulae with Bow Shocks: Non-thermal Radiation and Cosmic Ray Leptons. *Space Science Reviews*. 2017;207(1):235-90.
- [28] Weaver R, McCray R, Castor J, Shapiro P, Moore R. Interstellar bubbles. II. Structure and evolution. *The Astrophysical Journal*. 1977;218:377-95.
- [29] Peron G, Casanova S, Gabici S, Baghmany V, Aharonian F. The contribution of winds from star clusters to the Galactic cosmic-ray population. *Nature Astronomy*. 2024;8(4):530-7.
- [30] Morlino G, Menchiari S, Amato E, Bucciantini N. Contribution to Galactic cosmic rays from young stellar clusters; 2023. [arXiv:2310.15640](https://arxiv.org/abs/2310.15640).

- [31] Higdon JC, Lingenfelter RE. The superbubble origin for galactic cosmic rays. *Advances in Space Research*. 2006;37(10):1913-7.
- [32] Rafferty DA, McNamara BR, Nulsen PEJ, Wise MW. The Feedback-regulated Growth of Black Holes and Bulges through Gas Accretion and Starbursts in Cluster Central Dominant Galaxies. *The Astrophysical Journal*. 2006;652(1):216-31.
- [33] Romero GE, Vila GS. The active galactic nuclei as sources of cosmic rays and neutrinos. *Journal of Physics: Conference Series*. 2008;120:062022.
- [34] Zhang B. *The Physics of Gamma-Ray Bursts*. Cambridge University Press; 2018.
- [35] Mészáros P. Gamma-ray bursts. *Reports on Progress in Physics*. 2006;69(8):2259-321.
- [36] Krumholz MR, Crocker RM, Xu S, Lazarian A, Rosevear MT, Bedwell-Wilson J. Cosmic ray transport in starburst galaxies. *Monthly Notices of the Royal Astronomical Society*. 2020;493(2):2817-33.
- [37] Jones TW, Kang H. Cosmic-Ray Acceleration during the Impact of Shocks on Dense Clouds. *The Astrophysical Journal*. 1993;402:560.
- [38] Alves Batista R, Biteau J, et al. Open Questions in Cosmic-Ray Research at Ultrahigh Energies. *Frontiers in Astronomy and Space Sciences*. 2019;6:23.
- [39] Blandford R, Meier D, Readhead A. Relativistic Jets from Active Galactic Nuclei. *Annual Review of Astronomy and Astrophysics*. 2019;57(1):467-509.
- [40] Strong AW, Moskalenko IV, Ptuskin VS. Cosmic-ray propagation and interactions in the galaxy. *Annual Review of Nuclear and Particle Science*. 2007;57:285-327.
- [41] Grieder PKF. *Extensive Air Showers*. Springer; 2010.
- [42] Blandford R, Eichler D. Particle acceleration at astrophysical shocks: A theory of cosmic-ray origin. *Physics Reports*. 1987;154:1-75.
- [43] Drury LO. An introduction to the theory of diffusive shock acceleration of energetic particles in tenuous plasmas. *Reports on Progress in Physics*. 1983;46(8):973-1027.
- [44] Bell AR. The acceleration of cosmic rays in shock fronts. I. *Monthly Notices of the Royal Astronomical Society*. 1978;182:147-56.
- [45] Pulupa M. Cartoon picture of Bell's diffusive shock acceleration; 2013. Courtesy of Dr. Mark Pulupa's space physics illustration, <http://sprg.ssl.berkeley.edu/~pulupa/illustrations/>.
- [46] Zweibel EG, Yamada M. Magnetic Reconnection in Astrophysical and Laboratory Plasmas. *Annual Review of Astronomy and Astrophysics*. 2009;47:291-332.
- [47] Parker EN. Sweet's Mechanism for Merging Magnetic Fields in Conducting Fluids. *Journal of Geophysical Research*. 1957;62(4):509-20.
- [48] Sweet PA. The Neutral Point Theory of Solar Flares. In: Lehnert B, editor. *Electromagnetic Phenomena in Cosmical Physics*; 1958. p. 123-34.

- [49] Petschek HE. Magnetic Field Annihilation. In: Hess WN, editor. *The Physics of Solar Flares*. NASA; 1964. p. 425-39.
- [50] Drake JF, Swisdak M, Che H, Shay MA. Electron Acceleration from Contracting Magnetic Islands During Reconnection. *Nature*. 2006;443(7111):553-6.
- [51] Kowal G, de Gouveia Dal Pino EM, Lazarian A. Magnetohydrodynamic Simulations of Reconnection and Particle Acceleration: Three-dimensional Effects. *The Astrophysical Journal*. 2011;735(2):102.
- [52] Lazarian A, Kowal G, Takamoto M, de Gouveia Dal Pino E, Cho J. Turbulent Reconnection and Its Implications. *Philosophical Transactions of the Royal Society A*. 2015;373(2041):20140144.
- [53] Hoshino M, Lyubarsky Y. Relativistic Reconnection and Particle Acceleration. *Space Science Reviews*. 2012;173(1-4):521-33.
- [54] Gaisser TK, Engel R, Resconi E. *Cosmic Rays and Particle Physics*. 2nd ed. Cambridge University Press; 2016.
- [55] Particle Data Group. Review of Particle Physics. *Progress of Theoretical and Experimental Physics*. 2020;2020(8):083C01.
- [56] Aharonian FA, Akhperjanian AG, Barrio JA, et al. Evidence for TeV gamma ray emission from Cassiopeia A. *Astronomy & Astrophysics*. 2001;370(1):112-20.
- [57] Bell AR. Cosmic ray acceleration. *Astroparticle Physics*. 2013;43:56-70.
- [58] Gabici S, Aharonian F, Blasi P. The origin of galactic cosmic rays. *International Journal of Modern Physics D*. 2019;28(15):1930022.
- [59] Abeysekara AU, Albert A, Alfaro R, et al. The 2HWC HAWC Observatory Gamma-Ray Catalog. *The Astrophysical Journal*. 2017;843(1):40.
- [60] Abeysekara AU, Albert A, Alfaro R, et al. Multiple Galactic Sources with Emission Above 56 TeV Detected by HAWC. *Physical Review Letters*. 2020;124(2):021102.
- [61] Albert A, Alfaro R, Ashkar H, et al. Science Case for a Wide Field-of-View Very-High-Energy Gamma-Ray Observatory in the Southern Hemisphere. *Bulletin of the American Astronomical Society*. 2019;51(7):145.
- [62] Lagage PO, Cesarsky CJ. The maximum energy of cosmic rays accelerated by supernova shocks. *Astronomy & Astrophysics*. 1983;125(2):249-57.
- [63] Ptuskin VS, Soutoul A. Decaying cosmic ray nuclei in the interstellar medium. *Astronomy & Astrophysics*. 1998;337:859-65.
- [64] Apel WD, et al. Ankle-like feature in the energy spectrum of light elements of cosmic rays observed with KASCADE-Grande. *Physical Review D*. 2013;87(8):081101.
- [65] Hörandel JR. Models of the knee in the energy spectrum of cosmic rays. *Astroparticle Physics*. 2004;21(3):241-65.

- [66] Aab A, et al. Evidence for a mixed mass composition at the ‘ankle’ in the cosmic-ray spectrum. *Physics Letters B*. 2016;762:288-95.
- [67] Apel WD, Arteaga-Velázquez JC, Bekk K, et al. The KASCADE-Grande experiment. *Nuclear Instruments and Methods in Physics Research Section A*. 2010;620(2–3):202-16.
- [68] Abbasi RU, et al. Indications of Proton-Dominated Cosmic-Ray Composition above 1.6 EeV. *Physical Review Letters*. 2010;104(16):161101.
- [69] Simpson JA. Elemental and isotopic composition of the galactic cosmic rays. *Annual Review of Nuclear and Particle Science*. 1983;33(1):323-82.
- [70] Olive KA, et al. Review of Particle Physics. *Chinese Physics C*. 2014;38(9):090001.
- [71] Kampert KH, Unger M. Measurements of the Cosmic Ray Composition with Air Shower Experiments. *Astroparticle Physics*. 2012;35:660-78.
- [72] Aloisio R. Cosmic Rays from the Knee to the Ankle: Status and Prospects. *Universe*. 2022;8(2):96.
- [73] Binns WR, et al. Observation of the ^{60}Fe nucleosynthesis-clock isotope in galactic cosmic rays. *Science*. 2005;307(5714):1779-83.
- [74] Peters B. Primary cosmic radiation and extensive air showers. *Il Nuovo Cimento*. 1961;22(4):800-19.
- [75] Aab A, et al. Observation of a large-scale anisotropy in the arrival directions of cosmic rays above 8×10^{18} eV. *Science*. 2017;357(6537):1266-70.
- [76] Beatty JJ, Matthews J, Wakely SP. Cosmic Rays. *Progress of Theoretical and Experimental Physics*. 2018;2018(8):083C01.
- [77] Engel R, Heck D, Pierog T. Extensive air showers and hadronic interactions at high energy. *Annual Review of Nuclear and Particle Science*. 2011;61:467-89.
- [78] Auger P, Ehrenfest P, Maze R, Daudin J, Fréon RA. Extensive Cosmic-Ray Showers. *Reviews of Modern Physics*. 1939;11(3–4):288-91.
- [79] Prada J, Rosales M, Guada C. Montaje y calibración de un detector de Ioduro de Sodio-NaI(Tl), para medir la componente electromagnética de baja energía en una cascada de partículas de radiación cósmica. [La Hechicera, estado Mérida, 1893 msnm, 800 gr/cm²] [Trabajo de grado]. Universidad de Los Andes; 2020.
- [80] Cazon L. Extensive Air Showers: from the muonic smoking guns to the hadronic backbone. *arXiv preprint arXiv:13013340*. 2013.
- [81] Gaisser TK, Hillas AM. Reliability of the Method of Constant Intensity Cuts for Reconstructing the Average Development of Vertical Showers. In: *Proceedings of the 15th International Cosmic Ray Conference (ICRC)*. vol. 8; 1977. p. 353.
- [82] Aab A, et al. Measurement of the average shape of longitudinal profiles of cosmic-ray air showers at the Pierre Auger Observatory. *Journal of Cosmology and Astroparticle Physics*. 2019;(03):018.

- [83] Kamata K, Nishimura J. The Lateral and the Angular Structure Functions of Electron Showers. *Progress of Theoretical Physics Supplement*. 1958;6:93-155.
- [84] Greisen K. The Extensive Air Showers. *Annual Review of Nuclear Science*. 1960;10:63-108.
- [85] Pierre Auger Collaboration. The mass composition of cosmic rays above 10^{17} eV from hybrid data of the Pierre Auger Observatory. In: *Proceedings of the 32nd International Cosmic Ray Conference*. Beijing, China; 2011. .
- [86] Aguilar M, Alcaraz J, Allaby J, et al. First Result from the Alpha Magnetic Spectrometer on the International Space Station: Precision Measurement of the Positron Fraction in Primary Cosmic Rays of 0.5–350 GeV. *Physical Review Letters*. 2013;110:141102.
- [87] Adriani O, Barbarino GC, Bazilevskaya GA, et al. The PAMELA Mission: Heralding a new era in precision cosmic ray physics. *Physics Reports*. 2013;544:323-70.
- [88] Aharonian F, Akhperjanian AG, Bazer-Bachi R, et al. Observations of the Crab Nebula with H.E.S.S. *Astronomy & Astrophysics*. 2006;457:899-915.
- [89] Holder J, Atkins RW, Badran HM, et al. The first VERITAS telescope. *Astroparticle Physics*. 2006;25:391-401.
- [90] Abu-Zayyad T, Aida R, Allen M, et al. The surface detector array of the Telescope Array experiment. *Nuclear Instruments and Methods in Physics Research Section A*. 2012;689:87-97.
- [91] Aab A, Abreu P, Aglietta M, et al. The Pierre Auger Cosmic Ray Observatory. *Nuclear Instruments and Methods in Physics Research Section A*. 2015;798:172-213.
- [92] Abraham J, Abreu P, Aglietta M, et al. The fluorescence detector of the Pierre Auger Observatory. *Nuclear Instruments and Methods in Physics Research Section A*. 2010;620:227-51.
- [93] Abeysekara AU, Alfaro R, Alvarez C, et al. On the sensitivity of the HAWC observatory to gamma-ray bursts. *Astroparticle Physics*. 2013;35:641-50.
- [94] Bergman DR, Belz JW. Cosmic rays: The second knee and beyond. *Journal of Physics G: Nuclear and Particle Physics*. 2007;34:R359-400.
- [95] Fukuda Y, Hayakawa T, Ichihara E, et al. Measurement of a small atmospheric muon-neutrino to electron-neutrino ratio. *Physical Review Letters*. 1998;81:1562-7.
- [96] Aartsen MG, Ackermann M, Adams J, et al. The IceCube Neutrino Observatory: Instrumentation and Online Systems. *Journal of Instrumentation*. 2017;12:P03012.
- [97] Jelley JV. *Cerenkov Radiation and its Applications*. Pergamon Press; 1958.
- [98] Hamamatsu Photonics K K . *Photomultiplier Tubes: Basics and Applications*. 3rd ed. Hamamatsu Photonics; 2007.
- [99] Knoll GF. *Radiation Detection and Measurement*. 4th ed. John Wiley & Sons; 2010.

- [100] Abeysekara AU, et al. HAWC: Design, Operation, Reconstruction and Analysis. In: Proceedings of the 34th International Cosmic Ray Conference (ICRC 2015). The Hague, Netherlands; 2015. .
- [101] Smith AJ. The HAWC Observatory: Design, Operation, Reconstruction and Analysis. In: Proceedings of the 34th International Cosmic Ray Conference (ICRC 2015); 2015. .
- [102] Leo WR. Techniques for Nuclear and Particle Physics Experiments. 2nd ed. Springer-Verlag; 1994.
- [103] Wischnewski R, et al. Overview and Performance of the HAWC Observatory. Proceedings of Science. 2015;236:1001.
- [104] Smith A, et al. Operation and Performance of the HAWC Observatory. Astroparticle Physics. 2018;106:11-7.
- [105] Frank M, et al. HAWC: Observation of the High-Energy Universe. Reviews of Modern Physics. 2018;90(3):1004.
- [106] Leon O, et al. Advanced Reconstruction Techniques for HAWC Observatory. Journal of Instrumentation. 2019;14:P04001.
- [107] Ostapchenko S. QGSJET-II: Towards Reliable Description of Very High Energy Hadronic Interactions. Nuclear Physics B-Proceedings Supplements. 2015;151:143-6.
- [108] Erdmann M, et al. Cosmic Ray Simulations with CORSIKA. Astroparticle Physics. 2019;108:50-62.
- [109] Lappin S. Assessing the Strengths and Weaknesses of Large Language Models. Journal of Logic, Language and Information. 2024;33(1):9-20.
- [110] Kheddar H, Hemis M, Himeur Y. Automatic speech recognition using advanced deep learning approaches: A survey. Information Fusion. 2024;109:102422.
- [111] UrRehman Z, et al. Effective lung nodule detection using deep CNN with dual attention mechanisms. Scientific Reports. 2024;14(1):3934.
- [112] Karaja MB, Abu-Naser SS. Using Deep Learning to Detect the Quality of Lemons. International Journal of Academic Information Systems Research. 2024;8(4):97-104.
- [113] Kuznetsov MY, Petrov NA, Plokhikh IA, Sotnikov VV. Energy spectra of elemental groups of cosmic rays with the KASCADE experiment data and machine learning. Journal of Cosmology and Astroparticle Physics. 2024;(05):125.
- [114] Carrillo-Perez F, Herrera LJ, Carceller JM, Guillén A. Deep learning to classify ultra-high-energy cosmic rays by means of PMT signals. Neural Computing and Applications. 2021;33(15):9153-69.
- [115] Alfaro RJ, Alvarado DA. Cosmic-ray energy reconstruction using machine learning techniques. In: Proceedings of 38th International Cosmic Ray Conference (ICRC2023); 2023. p. 402.

- [116] Bishop CM. Pattern Recognition and Machine Learning. Springer; 2006.
- [117] Hastie T, Tibshirani R, et al. The Elements of Statistical Learning: Data Mining, Inference, and Prediction. Springer; 2009.
- [118] Goodfellow I, Bengio Y, Courville A. Deep Learning. MIT Press; 2016.
- [119] Cortes C, Vapnik V. Support-vector networks. Machine Learning. 1995;20(3):273-97.
- [120] Breiman L. Random forests. Machine Learning. 2001;45(1):5-32.
- [121] Cover T, Hart P. Nearest neighbor pattern classification. IEEE Transactions on Information Theory. 1967;13(1):21-7.
- [122] LeCun Y, Bengio Y, Hinton G. Deep learning. Nature. 2015;521(7553):436-44.
- [123] Hochreiter S, Schmidhuber J. Long Short-Term Memory. Neural Computation. 1997;9(8):1735-80.
- [124] Vaswani A, Shazeer N, et al. Attention Is All You Need. In: Advances in Neural Information Processing Systems; 2017. .
- [125] Smith SJ, HAWC Collaboration. Energy Estimation and Gamma/Hadron Separation with HAWC. In: Proceedings of the 34th International Cosmic Ray Conference. The Hague, Netherlands; 2016. .
- [126] Chen T, Guestrin C. XGBoost: A Scalable Tree Boosting System. In: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining; 2016. p. 785-94.
- [127] Ke G, Meng Q, Finley T, Wang T, Chen W, Ma W, et al. LightGBM: A Highly Efficient Gradient Boosting Decision Tree. In: Advances in Neural Information Processing Systems. vol. 30; 2017. p. 3146-54.