

Instituto Tecnológico de Costa Rica

Escuela de Ingeniería en Computación



Estimación de Incertidumbre de redes generativas antagónicas (GAN) para
simular datos del detector de partículas del Cherenkov de imágenes de anillo
(RICH)

**Informe Final de Práctica Profesional para optar por el grado de Bachiller
en Ingeniería en Computación**

José Alberto Arce Morales

Jonathan David Pastor Barrientos

Costa Rica, San José, Noviembre 2024



Estimación de Incertidumbre de redes generativas antagónicas (GAN) para simular datos del detector de partículas del Cherenkov de imágenes de anillo (RICH) © 2024 por José Alberto Arce Morales y Jonathan David Pastor Barrientos tiene Licencia CC BY-NC-SA 4.0

Acta de Aprobación

IC-8842 PRÁCTICA PROFESIONAL

Arce	Morales	José Alberto	2020316685
Primer Apellido	Segundo Apellido	Nombre del estudiante	Carnet

Pastor	Barrientos	Jonathan David	2020023569
Primer Apellido	Segundo Apellido	Nombre del estudiante	Carnet


Estimación de Incertidumbre de redes generativas antagónicas (GAN) para simular datos del detector de partículas del Cherenkov de imágenes de anillo (RICH)	Grupo PARMA-CERN	Eduardo A. Canessa Montero
Nombre del Proyecto	Nombre de la Empresa	Nombre del Profesor Asesor

Nota Final

100

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
PERSONA FISICA, CPF-03-0338-0003.
Fecha declarada: 25/11/2024 06:09:59 p. m.
Razón: Documento aprobado
Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Eduardo A. Canessa Montero
Profesor Asesor



José Alberto Arce Morales
Estudiante

ADRIANA DE LOS
ANGELES
ALVAREZ
FIGUEROA
(FIRMA)

Digitally signed by
ADRIANA DE LOS
ANGELES ALVAREZ
FIGUEROA (FIRMA)
Date: 2024.11.25
21:17:39 -06'00'

Adriana Álvarez Figueroa
Coordinación



Jonathan David Pastor Barrientos
Estudiante



Contenido

1.	Introducción	12
2.	Contexto del Proyecto.....	14
2.1.	Antecedentes	17
3.	Descripción del Problema.....	32
3.1.	El método utilizado actualmente para la estimación UE en GANs es impreciso.	32
3.2.	Justificación	35
3.3.	Tipo de Investigación.....	36
3.4.	Descripción de los Stakeholders	36
3.5.	Formulación del problema	38
3.6.	Hipótesis	39
3.7.	Objetivos.....	39
4.	Contextualización del Problema y Marco Conceptual	41
4.1.	GANs	44
4.2.	Estimación de incertidumbre	45
4.3.	Deep ensembles	49
4.4.	Monte Carlo Dropout.....	49
4.5.	Feature Densities.....	51
4.6.	Redes neuronales de intervalos.....	51
5.	Metodología de la investigación	53
5.1.	Ubicación Temporal y espacial del estudio	53
5.2.	Variables e indicadores	53
5.3.	Proceso y características de los instrumentos para la recolección de información ..	53
5.3.1.	Fase I – Generación de datos del detector RICH.....	54

5.3.2.	Fase II – Lectura de los datos	57
5.3.3.	Fase III - Procedimiento para el análisis de la información	58
5.3.4.	Identificación de las partículas	60
6.	Análisis de los Riesgos	62
7.	Resultados	69
7.1.	Incertidumbre Epistémica	69
7.1.1.	Modificaciones en el modelo	71
7.1.1.1.	Experimento de ruido cero.....	71
7.1.1.2.	Experimento de ruido estático	74
7.1.1.3.	Experimento de 30x30 iteraciones.....	76
7.1.2.	Distancia entre distribuciones.....	81
7.1.2.1.	Kolmogorov-Smirnov Test	81
7.1.2.2.	Earth Mover's Distance	83
7.1.3.	Mapas de calor	84
7.1.4.	Calibración del modelo.....	86
7.1.5.	Optimización y Tiempos de Ejecución	87
7.2.	Incertidumbre Aleatoria	89
8.	Conclusiones y Recomendaciones.....	98
9.	Glosario de términos.....	103
10.	Bibliografía	105
11.	Plan de trabajo.	108
12.	Minutas, Informes de avance y Visitas de la empresa.	109
13.	Evaluaciones	166
14.	Anexo 1	172

Índice de Figuras

Figura 1. Organigrama del departamento Simulation del LHCb [1].	15
Figura 2. Histogramas de datos reales y generados a partir de una muestra del conjunto de datos de prueba dividido.	22
Figura 3. Distancia de distribución de datos preliminares reales versus generados por contenedor de puntuación de incertidumbre de MCD.	24
Figura 4. Mapa de calor de MCD que muestra todo el conjunto de datos de prueba en dos dimensiones, según la pseudorapidez (η) y el momentum.	24
Figura 5. Histogramas preliminares de MCD kaón real versus datos generados, por rango de incertidumbre (bin).	25
Figura 6. Histogramas preliminares de MCD muon real versus datos generados, por rango de incertidumbre (bin).	25
Figura 7. Histogramas preliminares de MCD protón real versus datos generados, por rango de incertidumbre (bin).	25
Figura 8. Histogramas preliminares de MCD electrón real versus datos generados, por rango de incertidumbre (bin).	26
Figura 9. Histogramas preliminares de MCD below thresholds real versus datos generados, por rango de incertidumbre (bin).	26
Figura 10. Distancia de distribución de datos preliminares reales versus generados por grupo de puntuación de incertidumbre de FD.	28
Figura 11. Mapa de calor de FD que muestra todo el conjunto de datos de prueba en dos dimensiones, según la pseudorapidez (η) y el momentum.	28
Figura 12. Histogramas preliminares de MCD kaón real versus datos generados, por rango de incertidumbre (bin).	29
Figura 13. Histogramas preliminares de MCD muon real versus datos generados, por rango de incertidumbre (bin).	29
Figura 14. Histogramas preliminares de MCD protón real versus datos generados, por rango de incertidumbre (bin).	29

Figura 15. Histogramas preliminares de MCD electrón real versus datos generados, por rango de incertidumbre (bin).	30
Figura 16. Histogramas preliminares de MCD below threshold real versus datos generados, por rango de incertidumbre (bin)	30
Figura 17. Resultados estimación de incertidumbre de modelos generativos.[2]	34
Figura 18. Arquitectura del modelo Cramér-GAN por [9] (Página 3, Figura 1).	43
Figura 19. Impacto del Detector RICH en la Identificación de Partículas [26].	54
Figura 20. Arquitectura del Detector RICH y Trayectoria de las Partículas [26].	55
Figura 21. Detector de fotones híbridos [26].	56
Figura 22. Flujo de datos a través del sistema en línea [27].	58
Figura 23. Flujo del procesamiento de la información [28].	60
Figura 24. Clasificación de Riesgos	63
Figura 25. Puntajes de incertidumbre para MCD con ruido cero.	72
Figura 26. Puntajes de incertidumbre para FD con ruido cero.	72
Figura 27. Curvas de confiabilidad para MCD con ruido cero.	72
Figura 28. Curvas de confiabilidad para FD con ruido cero.	73
Figura 29. Puntajes de incertidumbre para MCD con ruido estático.	74
Figura 30. Puntajes de incertidumbre para FD con ruido estático.	74
Figura 31. Curvas de confiabilidad para MCD con ruido estático.	75
Figura 32. Curvas de confiabilidad para FD con ruido estático.	75
Figura 33. Puntajes de incertidumbre para MCD después de 30x30 iteraciones.	77
Figura 34. Puntajes de incertidumbre para FD después de 30x30 iteraciones.	77
Figura 35. Curvas de confiabilidad para MCD después de 30x30 iteraciones.	77
Figura 36. Curvas de confiabilidad para FD después de 30x30 iteraciones	78
Figura 37. Resultado del coeficiente de Pearson para el experimento 30x30 iteraciones para la partícula electrón.	79
Figura 38. Resultado del coeficiente de Pearson para el experimento 30x30 iteraciones para la partícula kaón.	79
Figura 39. Resultado del coeficiente de Pearson para el experimento 30x30 iteraciones para la partícula muón.	80

Figura 40. Resultado del coeficiente de Pearson para el experimento 30x30 iteraciones para la partícula protón.	80
Figura 41. Resultado del coeficiente de Pearson para el experimento 30x30 iteraciones para la partícula por debajo del umbral.	81
Figura 42. Curvas de confiabilidad de Feature Densities para Kolmogorov-Smirnov.	82
Figura 43. Curvas de confiabilidad de Feature Densities para EMD.	83
Figura 44. Mapa de calor según el puntaje de incertidumbre para FD.	84
Figura 45. Mapa de calor según el puntaje de incertidumbre de MCD para la partícula electrón.	84
Figura 46. Mapa de calor según el puntaje de incertidumbre de MCD para la partícula kaón.	85
Figura 47. Mapa de calor según el puntaje de incertidumbre de MCD para la partícula muón.	85
Figura 48. Mapa de calor según el puntaje de incertidumbre de MCD para la partícula protón.	85
Figura 49. Mapa de calor según el puntaje de incertidumbre de MCD para la partícula debajo del umbral.	86
Figura 50. Desviación estándar de los datos en cubos.	90
Figura 51. Diferencia entre la desviación estándar de los datos generados por el modelo y los datos reales utilizando cubos	92
Figura 52. Diferencia absoluta entre la media de los datos generados y los datos reales utilizando cubos	94
Figura 53. Puntajes de incertidumbre de Feature Densities en cubos	95
Figura 54. Puntajes de incertidumbre de Monte Carlo Dropout en cubos.	96
Figura 55. Distancias de Jensen Shannon en cubos.	97

Índice de Tablas

Tabla 1. Lista de coordinadores por departamento.	15
Tabla 2. Experimento de Parámetros fijos.	19
Tabla 3. Experimento de bandas: factores y niveles.	19
Tabla 4. Experimento de bandas: factores y niveles simplificado.	19
Tabla 5. Experimento de cubos: factores y niveles.	20
Tabla 6. Coeficientes de correlación MCD preliminares entre la incertidumbre y las distancias de Jensen-Shannon de cada histograma.	23
Tabla 7. Coeficientes de correlación FD preliminares entre la incertidumbre y las distancias de Jensen-Shannon de cada histograma.	27
Tabla 8. Matriz de interesados del proyecto.	36
Tabla 9. Significado de los niveles de impacto de los posibles riesgos.	63
Tabla 10. Significado de los niveles de ocurrencia.	64
Tabla 11. Significado de los niveles de exposición a los riesgos.	64
Tabla 12. Riesgos previstos para el desarrollo del proyecto.	65
Tabla 13. Colores de clasificación de riesgos.	67
Tabla 14. Matriz de Evaluación de Riesgos Inicial.	68
Tabla 15. Matriz de Evaluación de Riesgos Final.	68
Tabla 16. Coeficientes de correlación de Pearson con ruido cero.	73
Tabla 17. Coeficientes de correlación de Pearson con ruido estático.	75
Tabla 18. Coeficientes de correlación de Pearson después de 30x30 iteraciones.	78
Tabla 19. Coeficientes de Correlación de Pearson con distintos niveles de dropout para MCD.	87
Tabla 20. Coeficiente de Correlación de Pearson con distintas capas del modelo para FD. ...	87
Tabla 21. Optimización de Features Densities.	88
Tabla 22. Tiempos de ejecución para ambos métodos después de 30 iteraciones.	88

RESUMEN

Como parte del experimento del Large Hadron Collider Beauty (LHCb) simulaciones precisas de colisiones de partículas se vuelven necesarias para la planificación y exploración de configuraciones, lo cual permite ahorrar tiempo y recursos al momento de realizar el experimento. Existen simulaciones utilizando redes neuronales generativas adversariales de Cramer (Cramer GAN) siendo desarrolladas para simular la salida del detector de Ring-Imaging Cherenkov (RICH). El determinar si estas simulaciones son confiables o no es un problema complejo, para el cual no existe un estándar definido, por lo que se propone el uso de un nuevo método llamado Feature Densities que permita estimar el nivel de incertidumbre del modelo. Se quiere probar que dicho método ofrece mejoras significativas, tanto a nivel de rendimiento como de precisión, al compararlo con el método de Monte Carlo Dropout, el cual es ampliamente utilizado como el estado del arte.

Palabras claves: Feature Densities; Monte Carlo Dropout; estimación de incertidumbre; coeficiente de correlación; Jensen Shannon.

ABSTRACT

As part of the Large Hadron Collider Beauty (LHCb) experiment, accurate simulations of particle collisions become necessary for the planning and exploration of configurations, which saves time and resources when performing the experiment. There are simulations using Cramer adversarial generative neural networks (Cramer GAN) being developed to simulate the output of the Ring-Imaging Cherenkov detector (RICH). Determining whether these simulations are reliable or not is a complex problem, for which there is no defined standard, so it is proposed to use a new method called Feature Densities to estimate the level of uncertainty of the model. The aim is to prove that this method offers significant improvements, both in terms of performance and accuracy, when compared to the Monte Carlo Dropout method, which is widely used as the state-of-the-art.

Keywords: Feature Densities; Monte Carlo Dropout; uncertainty estimation; correlation coefficient; Jensen Shannon.

1. Introducción

Este informe corresponde al proyecto de práctica profesional de José Alberto Arce Morales y Jonathan David Pastor Barrientos, el cual consiste en la investigación de la estimación de incertidumbre para un modelo GAN utilizando los métodos de Monte Carlo Dropout y Feature Densities en el contexto del experimento LHCb.

En el experimento LHCb, la simulación de colisiones de partículas es crucial para planificar y explorar diferentes escenarios experimentales. Con cada actualización del LHC, el número de colisiones y la cantidad de datos generados aumentan significativamente, especialmente en subsistemas como los detectores Cherenkov de imágenes en anillo (RICH). Estas simulaciones, que actualmente toman días, requieren muchos recursos computacionales debido a la necesidad de recrear condiciones complejas como la propagación y absorción de la luz.

Para mejorar la velocidad de simulación, se han desarrollado modelos basados en aprendizaje profundo, como la red generativa adversaria Cramér GAN, diseñada para replicar datos de los detectores RICH. Sin embargo, uno de los principales desafíos es establecer una métrica confiable que evalúe la precisión de las salidas del modelo, permitiendo a los científicos confiar en su uso en lugar de las simulaciones detalladas y lentas. Este proyecto de investigación busca mejorar el rendimiento de la estimación de incertidumbre (UE) en el modelo Cramér GAN, utilizando métodos avanzados que consideren tanto las incertidumbres epistémicas como aleatorias, y desarrollar una métrica más adecuada que integre la incertidumbre aleatoria.

En la primera sección se describe el entorno en el que se desarrollará el proyecto, incluyendo el quehacer de la empresa y las áreas involucradas. Seguidamente el problema, su justificación, la formulación de este y cuáles son los objetivos para el éxito del proyecto. Y se finaliza esta sección como se formula el problema de manera precisa, se expone la hipótesis de trabajo, y se establecen los objetivos del proyecto.

La siguiente sección del documento aborda la contextualización del problema y el marco conceptual, proporcionando un análisis detallado del entorno en el que se desarrolla el proyecto y los fundamentos teóricos que lo respaldan. Esta sección establece las bases para comprender el alcance y los desafíos del trabajo en curso. A continuación, se describe la metodología de investigación empleada, con especial énfasis en los métodos y técnicas utilizados para la recolección de datos, garantizando su relevancia y calidad para los objetivos del proyecto.

Seguidamente, se incluirá un análisis de riesgos, donde se identificarán, evaluarán y propondrán medidas para mitigar los posibles obstáculos que puedan surgir a lo largo del desarrollo del proyecto. Posteriormente, se presenta un análisis de los resultados obtenidos, acompañado de una interpretación detallada que permite extraer conclusiones relevantes. Esta sección culmina con recomendaciones aplicables y una síntesis de las principales lecciones aprendidas durante la ejecución del proyecto.

Finalmente, se encontrarán las minutas e informes de avance semanales, los cuales documentan el progreso y las decisiones tomadas en cada etapa. Así como las rúbricas de evaluaciones y anexos.

2. Contexto del Proyecto

El Grupo PARMA(Pattern Recognition and Machine Learning) es un grupo de investigación con sede en el Tecnológico de Costa Rica, orientado a trabajar en el área de aprendizaje automático e inteligencia artificial, con el fin de generar investigación científica, así como innovación tecnológica e integración de los diversos sectores del país, aplicando esto gracias al convenio entre la Organización Europea para la Investigación Nuclear (CERN) y el Consejo Nacional de Rectores (CONARE), el cual permite participar a personas de las universidades públicas costarricenses en distintos proyectos.

El CERN es un centro de investigación que opera el laboratorio de física más grande del mundo. En su sede de Suiza se encuentra el Gran Colisionador de Hadrones, un acelerador de partículas de 27 km de circunferencia que constituye el acelerador más grande del mundo, el cual hizo posible la confirmación de la existencia del bosón de Higgs en el 2012.

Uno de los esfuerzos de investigación del Grupo PARMA busca estimar la incertidumbre de un modelo generativo que simula el estado de las partículas obtenidas a partir de colisiones de protones en el Gran Colisionador de Hadrones del CERN, más específicamente, en el detector Cherenkov de imágenes en anillo RICH del detector *Large Hadron Collider beauty* (LHCb). Este trabajo se lleva a cabo en colaboración con el departamento de *Simulation* del experimento LHCb, en el área de *Working Package S: Detailed and Fast Simulations*. El *LHCb Simulation Project* asegura la coordinación y el apoyo general para el análisis de física en todas las corridas de datos del LHC, el rendimiento del detector y los estudios de soporte para futuras mejoras. Este proyecto abarca aplicaciones específicas de simulación y el software asociado, así como la creación y el mantenimiento de los procesos necesarios para la producción de muestras simuladas.

En la Figura 1, ilustra el organigrama del departamento de *Simulation*, mientras que en la Tabla 1, el rol y el responsable de cada área dentro de este.




Figura 1. Organigrama del departamento Simulation del LHCb [1].

Tabla 1. Lista de coordinadores por departamento.

Role	Responsable
Project Leader	Mark Whitehead
Deputy Project Leaders	Gloria Corti
Deputy Project Leader with U2 mandate	Michal Kreps
WP G Coordinators	Tom Hadavizadeh, Phil Ilten
WP F Coordinators	
WP S Coordinators	Lucio Anderlini, Michele Veltri
WP D Coordinators	Erika de Lucia, Zehua Xu
WP P Coordinators	Adam Morris, Qiuchan Lu
WP R Coordinators	Elena Dall’Occo, Matthias Karacson

En el contexto del experimento LHCb, la simulación de colisiones de partículas es un paso importante para planificar y explorar diferentes entornos de experimentación. Se utilizan varios programas (por ejemplo, GEANT4) para simular la salida del detector LHCb después de las colisiones protón-protón; sin embargo, con cada actualización del LHC, el número de colisiones por grupo es mayor, lo que aumenta la cantidad de datos registrados durante cada ejecución del experimento. Las simulaciones para un subsistema del Sistema de Identificación de Partículas (PID), como los detectores Cherenkov de imágenes en anillo (RICH), requieren particularmente recursos computacionales, dada la necesidad de recrear las condiciones relacionadas con los electrones secundarios de baja energía, así como los efectos sobre la luz, como, propagación, absorción y difracción.

Actualmente se genera una simulación de los detectores RICH en el orden de días, y se espera que con las nuevas actualizaciones que llegarán en el futuro cercano, los detectores aumentarán la cantidad de datos generados, aumentando así las demandas y la complejidad de la simulación. Para mejorar la velocidad de simulación, se han desarrollado diferentes modelos basados en aprendizaje profundo. Uno de ellos es una red neuronal adversaria generativa (GAN) de Cramér entrenada para generar datos como si fueran de un detector RICH; sin embargo, ha sido un desafío proporcionar una métrica confiable que evalúe qué tan confiable es la salida del modelo, para que los científicos puedan utilizarlo de forma segura en lugar de las detalladas y lentas simulaciones existentes.

Este proyecto de investigación se centra en mejorar el rendimiento de UE (*Uncertainty Estimation*) para un modelo Cramér GAN. Nuestra hipótesis es que es posible mejorar dichas estimaciones utilizando métodos de UE de última generación que tengan en cuenta las incertidumbres tanto epistémicas como aleatorias, así como implementando una métrica más adecuada que tenga en cuenta la incertidumbre aleatoria.

2.1. Antecedentes

A lo largo de esta investigación, se ha trabajado en la implementación de dos métodos avanzados de estimación de incertidumbre (UE): *Monte Carlo Dropout* (MCD) y *Features Densities* (FD). *Monte Carlo Dropout*, introducido por Gal y Ghahramani en 2016, aplica *dropout*¹ durante la fase de inferencia para simular un conjunto de redes neuronales, capturando así la incertidumbre epistémica. *Features Densities*, por su parte, se centra en la densidad de las características del conjunto de datos para estimar la incertidumbre, identificando áreas de menor densidad donde las predicciones pueden ser menos confiables. Además de la implementación de estos métodos, se ha establecido una base sólida para un diseño experimental que permitirá comparar de manera rigurosa la efectividad de ambos enfoques. Este diseño experimental ha sido estructurado de la siguiente manera:

2.1.1 Experimento de Bandas

Para comparar el rendimiento de los métodos MCD y FD para UE, proponemos la ejecución de un experimento multifactorial completo, con un total de 40 pruebas y 10 replicaciones, para generar un total de 400 observaciones. Al contar con tal cantidad de observaciones, nuestra intención es obtener datos de mediciones de desempeño robustos, precisos y estadísticamente significativos para realizar comparaciones. Nuestra variable dependiente es la puntuación de incertidumbre de cada método.

Para reducir el sesgo y el efecto de factores no contabilizados tanto como sea posible, usaremos el mismo modelo, pero diferentes instancias en cada replicación. Las pruebas se ejecutarán en orden aleatorio. Compararemos el UE de cada algoritmo utilizando las métricas especificadas en el punto 3.

¹ Técnica de regularización utilizada en redes neuronales que consiste en desactivar aleatoriamente un porcentaje de neuronas durante el entrenamiento para evitar el sobreajuste y mejorar la capacidad de generalización del modelo.

Las siguientes son las variables experimentales más importantes para el procedimiento de calibración del MCD, las definimos como:

- ***Ensemble size***: número de veces que se genera una inferencia a partir de un único modelo MCD, la incertidumbre se obtiene calculando la desviación estándar de los valores generados de cada inferencia. El tamaño mínimo requerido es 2.
- ***Dropout rate***: un valor porcentual que determina la cantidad de neuronas que deben desactivarse.
- ***Dropout distribution***: distribución utilizada para seleccionar neuronas que se eliminarán. Por ejemplo, Cramér GAN se entrenó utilizando una distribución de Bernoulli.

Para el algoritmo FD, definimos las variables más relevantes como:

- ***Embedding layers***: número de capas utilizadas para construir el vector de incrustación. Podrían ser las salidas de una sola capa o una concatenación de salidas de múltiples capas.
- ***Kernel Density Estimation (KDE) function***: función utilizada para estimar la función de densidad de probabilidad (PDF) de una variable aleatoria.
- ***KDE bandwidth***: factor que indica el ancho de la función de KDE.
- ***KDE sample size***: muestra utilizada para estimar el ajuste de la distribución con el método de KDE seleccionado.

La Tabla 2 muestra qué variables se fijarán en el experimento. Mientras que la Tabla 3 y Tabla 4 muestran los factores del experimento, el cual, por cada variación de los 2 métodos se evaluarán en las 10 bandas, tal como se hizo en [2], obteniendo un total de 40 pruebas.

Tabla 2. Experimento de Parámetros fijos.

Variable	Valor
<i>Ensemble size MCD</i>	300
<i>Dropout distribution</i>	Bernoulli Estructurado
<i>FD function</i>	Gaussian
<i>FD KDE method</i>	Dinámico (Scott factor)
<i>FD KDE sample size</i>	1000
<i>Dataset</i>	Pion
<i>Generative Model</i>	Cramér GAN entrenado con un dropout de 0,01, utilizando una distribución estructurada de Bernoulli.

Tabla 3. Experimento de bandas: factores y niveles.

Factores				
	Algoritmo	Dropout	Embedding – Layers	Bandas
Niveles	MCD	0.01	1-5	0-9
	FD	0.05	5	0-9

Dado que Dropout solo se aplica a MCD y *Embedding-Layers* solo se aplica a FD, la tabla de factores se puede simplificar a:

Tabla 4. Experimento de bandas: factores y niveles simplificado.

Factores			
	Algoritmo	Bandas	
Niveles	MCD_0.01	0-9	
	MCD_0.05	0-9	
	FD_1-5	0-9	
	FD_1-5	0-9	

2.1.2 Experimento de Cubos

Este experimento dividirá el espacio de datos en una cuadrícula tridimensional de cubos de $5 \times 5 \times 5$, en lugar de bandas, como en el experimento anterior. Nuestro objetivo es estimar la incertidumbre en regiones con densidad similar, dado que una sola banda presenta un alto grado de heterocedasticidad ya que contiene datos tanto en regiones densas como dispersas. Se espera que algunos cubos no contengan ningún dato; dichas cuadrículas se excluirán del experimento. Los factores identificados para este experimento se especifican en la Tabla 5.

De cada cubo, elegiremos una muestra aleatoria de N subcubos para su UE y compararemos cada algoritmo utilizando las métricas especificadas en el punto 3.

Tabla 5. Experimento de cubos: factores y niveles.

	Factores	
	Algoritmo	Cube id
Niveles	MCD_0.01	0-124
	MCD_0.05	0-124
	FD_1-5	0-124
	FD_1-5	0-124

2.1.3 Métricas de Comparación

Una vez que recopilamos el UE y los valores predichos de cada algoritmo, realizaremos las siguientes comparaciones:

- Organizar los datos generados dividiendo las incertidumbres obtenidas en 9 $bins^2$ igualmente divididas, desde la puntuación de incertidumbre mínima hasta la máxima.

² Intervalos o divisiones en los que se agrupan los datos en un rango continuo para facilitar su análisis o representación gráfica


- Por cada cubeta:
 - Tome una submuestra de n observaciones de los datos generados y reales para generar histogramas para cada variable objetivo.
 - Calcule el JSD (*Jensen-Shannon distance*) entre distribuciones de datos reales y generados. Dado que tendremos observaciones de múltiples replicaciones, podemos estimar medianas y desviaciones estándar por algoritmo.
 - Calcule la correlación de Pearson entre el JSD y la incertidumbre promedio de las muestras en el contenedor.
- Compare estadísticamente el rendimiento de cada algoritmo comparando la incertidumbre promedio por cuartil con el JSD para establecer si existen diferencias significativas entre cada algoritmo.

2.1.4 Resultados preliminares

2.1.4.1 Histogramas de datos reales vs generados

Una vez entrenado el modelo, tomamos la parte generadora de GAN, seleccionamos una muestra aleatoria de 100 000 observaciones del conjunto de datos de prueba y generamos resultados para todas estas observaciones.

El modelo produce 5 salidas, por lo tanto, se generó un histograma de datos reales versus datos generados para visualizar las distribuciones de datos de cada salida, Figura 2.



MATPLOTLIB

Figura 2. Histogramas de datos reales y generados a partir de una muestra del conjunto de datos de prueba dividido.

2.1.4.2 Incertidumbre de Monte Carlo Dropout (MCD)

Para evaluar la incertidumbre de los datos generados, se utilizó el modelo generador con la deserción habilitada, se realizó un conjunto de 300 inferencias usando la misma muestra para calcular la desviación estándar de las salidas para el MCD UE.

Las Figuras: Figura 5, Figura 6, Figura 7, Figura 8 y Figura 9 muestran histogramas de datos reales versus datos generados, agrupados por su puntuación de incertidumbre (*bins UE*), dividiendo todo el conjunto de datos en 10 *bins* de rangos igualmente divididos desde la puntuación mínima hasta la máxima. Los histogramas dentro de cada contenedor contienen 25 *buckets*³. Una vez que la información se separó en *buckets*, pudimos calcular dos métricas para el rendimiento del método UE:

- Una métrica de confiabilidad definida como el JSD entre los datos reales y los generados.

³ Categorías o contenedores en los que se agrupan datos según ciertos rangos o criterios


- b. Correlación de Pearson entre la mediana MCD UE y las distancias de Jensen-Shannon de las distribuciones para cada etiqueta de salida.

Para conocer la métrica de confiabilidad resultante por contenedor para cada salida, consulte la Figura 3, mientras que la correlación de Pearson se encuentra en la Tabla 6.

Finalmente, la distribución de cómo se asignó la incertidumbre para todo el conjunto de datos de prueba se ilustra en la Figura 4; sin embargo, dada la densidad de los puntos de datos, es posible que este gráfico no muestre la distribución real de las incertidumbres.


Tabla 6. Coeficientes de correlación MCD preliminares entre la incertidumbre y las distancias de Jensen-Shannon de cada histograma.

Partícula	Correlación de Pearson
Electrón	0.29781
Kaón	0.20747
Muon	0.48301
Protón	0.08602
Debajo del umbral	0.51370




MATPLOTLIB

Figura 3. Distancia de distribución de datos preliminares reales versus generados por contenedor de puntuación de incertidumbre de MCD.




MATPLOTLIB

Figura 4. Mapa de calor de MCD que muestra todo el conjunto de datos de prueba en dos dimensiones, según la pseudorapidez (eta) y el momentum.




MATPLOTLIB

Figura 5. Histogramas preliminares de MCD kaón real versus datos generados, por rango de incertidumbre (bin).




MATPLOTLIB

Figura 6. Histogramas preliminares de MCD muon real versus datos generados, por rango de incertidumbre (bin).




MATPLOTLIB

Figura 7. Histogramas preliminares de MCD protón real versus datos generados, por rango de incertidumbre (bin).



MATPLOTLIB

Figura 8. Histogramas preliminares de MCD electrón real versus datos generados, por rango de incertidumbre (bin).



MATPLOTLIB

Figura 9. Histogramas preliminares de MCD below thresholds real versus datos generados, por rango de incertidumbre (bin).

2.1.4.3 Incertidumbre de Features Densities (FD)

Se utilizó el mismo proceso del MCD que para el FD UE; Se calcularon las mismas métricas y están disponibles en la Figura 10 para la correlación de Jensen-Shannon y Pearson en la Tabla 7.


En consecuencia, los histogramas de UE para cada partícula están disponibles en las Figuras: Figura 12, Figura 13, Figura 14, Figura 15 y Figura 16.

Tabla 7. Coeficientes de correlación FD preliminares entre la incertidumbre y las distancias de Jensen-Shannon de cada histograma

Partícula	Correlación de Pearson
Electrón	0.88042
Kaón	0.94862
Muon	0.84457
Protón	0.82838
Debajo del umbral	0.96581


Hay que tener en cuenta que tuvimos que dividir los datos en 10 grupos desde el puntaje de incertidumbre mínimo al máximo para ambos métodos, ya que las unidades obtenidas en cada método son diferentes y no se pueden usar en una comparación directa. En cambio, la comparación se realiza a través de la métrica de confiabilidad en las figuras Figura 3 y Figura 10.

En la Figura 11 se ilustra una distribución de la puntuación de incertidumbre para todo el conjunto de datos de prueba en un espacio bidimensional; sin embargo, como se mencionó anteriormente, dada la alta densidad y la cantidad de puntos de datos, algunos puntos podrían estar ocluidos por otros.




MATPLOTLIB

Figura 10. Distancia de distribución de datos preliminares reales versus generados por grupo de puntuación de incertidumbre de FD.




MATPLOTLIB

Figura 11. Mapa de calor de FD que muestra todo el conjunto de datos de prueba en dos dimensiones, según la pseudorapidez (eta) y el momentum.




MATPLOTLIB

Figura 12. Histogramas preliminares de MCD kaón real versus datos generados, por rango de incertidumbre (bin).



MATPLOTLIB

Figura 13. Histogramas preliminares de MCD muon real versus datos generados, por rango de incertidumbre (bin).



MATPLOTLIB

Figura 14. Histogramas preliminares de MCD protón real versus datos generados, por rango de incertidumbre (bin).




Figura 15. Histogramas preliminares de MCD electrón real versus datos generados, por rango de incertidumbre (bin).




Figura 16. Histogramas preliminares de MCD below threshold real versus datos generados, por rango de incertidumbre (bin)

2.1.4.4 Análisis de los Resultados Preliminares

- a. Aunque la correlación MCD UE Pearson en la Tabla 6 indica una tendencia a que la puntuación de incertidumbre crezca a medida que crece el JSD, no se aplica a todos los intervalos de puntuación; además, los intervalos inferiores parecen tener mayor incertidumbre que los intervalos intermedios, lo que parece indicar que MCD tiene un rendimiento deficiente en áreas donde los histogramas muestran diferencias considerables entre las distribuciones de datos reales y generados.

- b. Después de inspeccionar el número de *bins* de cada histograma de incertidumbre, hemos detectado que los dos últimos *bins* de MCD para cada salida contienen solo unas pocas observaciones (menos de 20) que presentan un alto grado de variabilidad que causa un mayor JSD como se ve en la Figura 3, los resultados de los dos últimos *bins* podrían no tener relevancia estadística. Este no es el caso de FD, porque todos los *bins* contienen más de cien observaciones. Para los experimentos reales, se requiere una revisión del número de *bins* y observaciones por contenedor.
- c. El FD UE parece mostrar un crecimiento más estable en la métrica de confiabilidad como se ve en la Figura 10. Además, la correlación de pearson (Tabla 6) parece corroborar que la puntuación de incertidumbre crece a medida que crece el JSD para cada etiqueta de salida.
- d. Una ventaja que tiene el método MCD sobre FD es que puede proporcionar un UE separado para cada variable de salida, mientras que FD solo puede proporcionar una puntuación de incertidumbre única para todas las salidas de una única observación de entrada.
- e. Los mapas de calor en las figuras Figura 4 y Figura 11 parecen indicar que existen diferencias fundamentales en cómo ambos métodos asignan incertidumbre a las etiquetas de salida generadas.
- f. Finalmente, estos resultados preliminares parecen indicar que nuestro método propuesto utilizando FD podría ser un enfoque válido para UE de Cramér GAN.

3. Descripción del Problema

3.1. El método utilizado actualmente para la estimación UE en GANs es impreciso.

La física de partículas, con su inherente complejidad y vastos conjuntos de datos, ha buscado herramientas computacionales avanzadas para mejorar la simulación y el análisis de eventos. Las GAN, con su capacidad para modelar distribuciones complejas, han encontrado una aplicación significativa en este dominio [3]. Sin embargo, la UE en GAN sigue siendo un área activa de investigación [4]. A pesar de su poder, las GAN no ofrecen inherentemente una UE. Sin embargo, la importancia de cuantificar la confiabilidad de las predicciones ha llevado al desarrollo de técnicas específicas [5].

Estas técnicas van desde la incorporación de componentes probabilísticos en la arquitectura de la red hasta enfoques de posprocesamiento [6]. A medida que las GAN continúan evolucionando y encuentran nuevas aplicaciones en la física de partículas, la necesidad de técnicas UE robustas se vuelve aún más crítica [7], [8].

La necesidad de estimar la incertidumbre en GANs tiene un impacto significativo en varios aspectos de la física de partículas. En primer lugar, afecta directamente a los físicos que dependen de simulaciones precisas para interpretar los datos experimentales. La falta de una estimación confiable de la incertidumbre podría llevar a interpretaciones erróneas de los resultados, comprometiendo la validez de las conclusiones científicas y, en última instancia, afectando el avance del conocimiento en el campo.

Además, la industria de la computación y los centros de investigación que implementan estas tecnologías también se ven afectados. La implementación de técnicas avanzadas de UE en GANs puede requerir ajustes significativos en la infraestructura computacional, lo que a su vez puede implicar mayores costos y la necesidad de recursos adicionales. Sin embargo, estas inversiones son cruciales para garantizar que las simulaciones generativas sean lo suficientemente robustas como para ser utilizadas en la planificación de futuros experimentos, la validación de modelos teóricos y la exploración de fenómenos aún no observados.

Sin embargo, uno de los problemas con la UE es que no existe una definición acordada ni una taxonomía única [2]. Quizás la clasificación más común y entendida sea referirse a ellas como incertidumbres aleatorias (no reducibles) y epistémicas (reducibles).

La incertidumbre aleatoria: suele estar asociada al ruido inherente a los datos, debido a diferentes factores impredecibles, o falta de precisión en los equipos de medición, etc. Normalmente este tipo de incertidumbre es irreducible, dado que no importa la cantidad de datos recopilados, el ruido aleatorio o el factor de error siempre está presente. La incertidumbre epistémica: en el contexto del aprendizaje automático, se refiere al "conocimiento" que tiene un modelo de los datos y qué tan bien puede representarlos. Este tipo de incertidumbre se considera reducible si los conjuntos de datos se aumentan con observaciones más diversas.

Las incertidumbres aleatoria y epistémica no se excluyen entre sí; ya que nuevas mejoras en los equipos de medición o una mejor comprensión de los fenómenos mal comprendidos podrían reducir el ruido en los datos, convirtiendo parte de la incertidumbre de aleatoria a epistémica.

Al medir la incertidumbre epistémica, de acuerdo con [2] el uso de métodos UE basados en resultados sufre problemas de calibración, ya que los modelos de aprendizaje profundo a menudo son demasiado confiados.

El UE para Cramér-GAN realizado en [9] parece tener poca confianza en regiones de datos densas (los datos se dividieron en bandas) y demasiada confianza en regiones de datos escasos, como se ve en la Figura 17, en la cual el área sombreada corresponde a la estimación de la incertidumbre y cada gráfico de líneas representa la eficiencia de representar tanto kaones (gráfico de la izquierda) como muones (gráfico de la derecha) con diferentes métodos de UE, y la línea azul representa datos de *Ground-Truth*⁴. Los datos se separaron en bandas según la relación entre sus características.

⁴ Término que se refiere a los datos o valores reales y confiables utilizados como referencia para evaluar o entrenar modelos, asegurando su precisión en comparación con la realidad.




Figura 17. Resultados estimación de incertidumbre de modelos generativos.[2]

Por lo tanto, el problema mencionado anteriormente podría deberse a varias razones, como sesgos en el modelado bayesiano [10], falta de datos de entrenamiento en regiones dispersas o incluso una arquitectura de modelo incorrecta [11]. Además de la falta de precisión en la UE, la métrica utilizada por [9] no parece mapear la incertidumbre aleatoria real, lo que presenta un comportamiento heteroscedástico, lo que resulta en una estimación imprecisa.

Otra complicación al realizar el UE es que, en una configuración de modelo generativo, una entrada determinada no dará como resultado la misma salida cada vez, por lo tanto, Cramér-GAN necesitaba capturar la distribución del conjunto de datos RICH al aprender a generar las etiquetas, por lo tanto, cuando se realiza UE, también debemos tener en cuenta el efecto de la incertidumbre aleatoria heteroscedástica.

3.2. Justificación

Este proyecto tiene una gran relevancia para una variedad de audiencias clave, incluyendo científicos e investigadores del CERN que trabajan en el experimento LHCb, así como para la comunidad científica más amplia en el campo de la física de partículas. La necesidad de simulaciones precisas y eficientes es fundamental para entender mejor los fenómenos subatómicos y validar teorías, y este proyecto se enfoca precisamente en mejorar estas simulaciones.

Al mejorar la precisión y confiabilidad de las simulaciones generadas por los modelos Cramér GAN, los científicos podrán llevar a cabo investigaciones más exactas. Esta mayor confiabilidad permitirá reducir el tiempo y los recursos computacionales necesarios, facilitando una utilización más eficiente de los recursos disponibles. Este beneficio es crucial, dado que las actuales simulaciones de los detectores RICH pueden tardar días y se espera que la cantidad de datos generados aumente significativamente con futuras actualizaciones del LHC.

Además, este proyecto contribuye de manera significativa al conocimiento sobre la aplicación de tecnologías de aprendizaje profundo en la simulación de experimentos científicos. Específicamente, aborda la mejora de las estimaciones de incertidumbre en modelos generativos adversarios, un área crítica para garantizar la fiabilidad de estas simulaciones. La implementación de métricas más adecuadas y la consideración de incertidumbres tanto aleatorias como epistémicas proporcionarán una comprensión más profunda y precisa de las incertidumbres en estos modelos, beneficiando así a los desarrolladores de modelos de aprendizaje profundo y a las instituciones académicas que puedan aplicar estas técnicas en sus propias investigaciones.

La innovación tecnológica es otro aspecto clave de este proyecto. Al desarrollar y aplicar nuevas técnicas de estimación de incertidumbre, se mejora la precisión y confiabilidad de los modelos GAN, representando una innovación directa en el campo de la inteligencia artificial y el aprendizaje profundo.

Además, las mejoras en la eficiencia de las simulaciones pueden ser adaptadas a otros campos que requieren simulaciones intensivas, promoviendo así la innovación en la

gestión y utilización de recursos computacionales. La integración de técnicas avanzadas de estimación de incertidumbre en un entorno tan complejo como el del LHCb es una contribución innovadora que puede ser extendida a otros modelos y aplicaciones, impulsando el avance tecnológico en múltiples áreas.

En resumen, este proyecto es crucial para mejorar la precisión y eficiencia de las simulaciones en el experimento LHCb del CERN, aportando beneficios significativos a la comunidad científica y contribuyendo a la innovación tecnológica y al conocimiento en el campo del aprendizaje profundo y la física de partículas.

3.3. Tipo de Investigación

Investigación Aplicada

3.4. Descripción de los Stakeholders

Tabla 8. Matriz de interesados del proyecto.

Interesados del Proyecto			
Rol	Nombre Completo	Institución	Responsabilidades
Coordinador del proyecto e investigación Supervisor	Saúl Calderón Ramírez	ITCR, Escuela de Ingeniería en Computación, Coordinador del PARMA Group	Asistir a las reuniones programadas durante las cuatro visitas del profesor asesor. Ofrecer todas las facilidades necesarias para asegurar el adecuado desarrollo de la práctica. Evaluar el desempeño del estudiante durante el semestre utilizando los instrumentos definidos por la Escuela de Ingeniería en Computación y comunicar los resultados al profesor asesor. Implementar métodos y métricas de UE basados en datos y en salidas del modelo.

Profesor Asesor	Eduardo Canessa	ITCR, Escuela de Ingeniería en Computación	Mantener comunicación y reunirse con el estudiante para dar seguimiento al proyecto. Asistir a al menos cuatro reuniones con el supervisor técnico para dar seguimiento al proyecto. Definir la forma y el contenido de los entregables requeridos por el curso de Práctica Profesional. Revisar y evaluar los entregables del curso. Participar presencialmente en la presentación final de la práctica profesional.
Supervisor	Sergio Arguedas Cuendis	CONARE	Asistir a las reuniones programadas durante las cuatro visitas del profesor asesor. Ofrecer todas las facilidades necesarias para asegurar el adecuado desarrollo de la práctica. Evaluar el desempeño del estudiante durante el semestre utilizando los instrumentos definidos por la Escuela de Ingeniería en Computación y comunicar los resultados al profesor asesor. Implementar métodos y métricas de UE basados en datos y en salidas del modelo.

Investigación	Esteban Villalobos Gómez	ITCR, Escuela de Ingeniería en Computación	Implementar métodos y métricas de UE basados en datos y en salidas del modelo.
Investigación	Fernando Ugarte Green	ITCR, Escuela de Ingeniería en Computación	Implementar métodos y métricas de UE basados en datos y en salidas del modelo.
Investigación	José Arce Morales	ITCR, Escuela de Ingeniería en Computación	Implementar métodos y métricas de UE basados en datos y en salidas del modelo.
Investigación	Jonathan David Pastor Barrientos	ITCR, Escuela de Ingeniería en Computación	Implementar métodos y métricas de UE basados en datos y en salidas del modelo.

3.5. Formulación del problema

Tal como se evidenció en la Figura 17, la cual nos indica que las incertidumbres del modelo Cramér-GAN van desde poco confiables a demasiado confiables en simulaciones del conjunto de datos RICH, se llegan a las siguientes preguntas:

- ¿Podemos idear un mejor método para estimar la incertidumbre del modelo en comparación con el estado del arte?
- ¿Podemos idear una métrica que contemple la incertidumbre aleatoria en los datos de entrenamiento?

3.6. Hipótesis

Nuestro método de estimación de incertidumbre (UE) propuesto y la métrica propuesta que utiliza *Features Densities* superan con significancia estadística la UE de un método y una métrica de última generación cuando se utilizan en simulaciones del conjunto de datos RICH con el modelo Cramér-GAN

3.7. Objetivos

3.7.1. Objetivo General

Implementar un *benchmark*⁵ que permita la comparación de los métodos de estimación de incertidumbre, como *Monte Carlo Dropout* y *Features Densities*, utilizando el lenguaje de programación Python con la herramienta en línea de Google Colab.

3.7.2. Objetivos Específicos

En la presente sección se detallan los objetivos específicos asociados al objetivo general del proyecto especificado en este documento:

- a. Modificar el *benchmark* de los resultados preliminares que compara la diferencia de las distribuciones, mapas de calor y gráficos de eficiencia por umbral entre FD y MCD.
- b. Diseñar el *benchmark* del experimento de los cubos que estima la incertidumbre aleatoria inherente en los datos comparando la desviación estándar de los datos reales y los datos generados por el modelo.
- c. Implementar el *benchmark* del experimento de los cubos que estima la incertidumbre aleatoria inherente en los datos comparando la desviación estándar de los datos reales y los datos generados por el modelo.

⁵ Estándar de referencia utilizado para comparar el rendimiento, la calidad o la eficiencia de un sistema, modelo o proceso frente a otros similares.

- d. Implementar un *benchmark* para la estimación de confiabilidad de los cuantificadores de incertidumbre de *Feature Densities* y *Monte Carlo Dropout* utilizando los métodos de *earth mover's distance* y *Kolmogorov-Smirnov Test*.
- e. Calibrar los modelos utilizados de *Monte Carlo Dropout* y *Feature Densities*, midiendo y optimizando sus tiempos de ejecución.

4. Contextualización del Problema y Marco Conceptual

La estimación de la incertidumbre (UE) se ha convertido en un tema de interés en los últimos años. La popularidad de los algoritmos de aprendizaje automático está creciendo rápidamente, dadas las capacidades de los modelos generativos recientes y su acceso al público en general, en algunos casos de forma gratuita.

Los LLM se utilizan para descubrir patrones y generar texto para muchas disciplinas diferentes y para realizar muchas tareas: desde escribir leyes hasta crear currículums personales, escribir programas informáticos o traducir de un idioma a otro, incluida la generación de imágenes o vídeos a partir de indicaciones de texto. Saber cuándo confiar en estos modelos es bastante importante, incluso esencial en ciertos campos aplicados como la medicina o los vehículos autónomos, donde las vidas humanas pueden confiarse a las decisiones tomadas por estos modelos y si cometen un error debido a un error factual o "alucinan", podría tener consecuencias nefastas [10].

Los científicos de Física Fundamental y de Partículas también buscan beneficiarse de los modelos generativos, tal es el caso del grupo de simulaciones en la colaboración del LHCb en CERN, donde los físicos dependen de un software complejo y que consume muchos recursos para simular eventos de colisiones de partículas a nivel subatómico.

LHCb es uno de los cuatro experimentos principales en CERN, su detector es un "espectrómetro frontal de un solo brazo" destinado al estudio de partículas que tienen quarks b y c, lo que requiere un sistema de identificación de partículas (PID) robusto [11]. Hay cuatro subsistemas diferentes que componen el PID: un sistema de calorímetro, dos detectores Ring-Imaging Cherenkov (RICH) [12] y una estación de muones, que permiten la identificación de electrones, fotones, muones y hadrones de larga vida [13].

Ver [11] para una descripción detallada del LHCb. S. Roiser et al. [14], afirmaron que para el año 2017, aproximadamente el 70% del trabajo de CPU utilizado por el software de simulación se dedicó a simulaciones de Monte Carlo que solo representaron alrededor del 15% de los eventos totales. La cantidad de datos que registra el experimento aumenta con cada actualización de LHCb, lo que se traduce en más tiempo y recursos requeridos por el software de simulación para mantenerse al día con los datos. Los autores también estiman que la Ejecución 3 (2022-2024) del Gran Colisionador de Hadrones (LHC) resultaría en un aumento de entre uno y dos órdenes de magnitud en el trabajo de CPU necesario para las simulaciones.

Las simulaciones de colisiones de alta energía y desintegraciones de partículas que ocurren dentro del acelerador son cruciales para la separación entre la señal y el ruido causado por fuentes de fondo, así como para estudios de eficiencia. M. Barbetti [13] explica cómo se realizan las simulaciones de LHCb, utilizando dos marcos de software principales: Gauss y Boole, ambos basados en un marco llamado Gaudi. Gaudi proporciona la infraestructura, los componentes e interfaces comunes, así como los servicios de configuración. La fase inicial de generación de partículas se realiza mediante simuladores de Monte Carlo (PYTHIA 8, EventGen). Gauss simula cómo las partículas longevas viajan a través de diferentes subdetectores del LHCb, mientras que GEANT4 simula las interacciones y la energía depositada por las partículas supervivientes. Boole replica las salidas de los subdetectores y digitaliza los datos para que tengan el mismo formato que si los informaran los sensores electrónicos del experimento. Los datos simulados pasan entonces por el mismo flujo de trabajo que los datos reales: pasan por los “procedimientos de activación, reconstrucción y análisis” [15]. Gauss se utiliza desde 2004 y ha sufrido varias mejoras a lo largo de los años.

A. Maevskiy et al [16], afirman que entre todos los detectores LHCb, simular los datos registrados por los detectores RICH es notablemente intensivo en recursos, dado que requiere modelos precisos de electrones de baja energía y dinámicas de propagación/difracción/absorción de luz. El sistema RICH detecta la luz emitida por una partícula cuando pasa a través de un medio transparente (fotones de Cherenkov), que forman un cono cuyo ángulo depende del momento de la partícula cargada [17].

En [16], los autores desarrollaron un modelo basado en una red neuronal antagónica generativa Cramer (GAN) [18] para generar datos del detector RICH, como una opción de simulación ultrarrápida para la colaboración LHCb. La arquitectura del modelo se muestra en la Figura 18 de [9].




Figura 18. Arquitectura del modelo Cramér-GAN por [9] (Página 3, Figura 1).

El Cramer-GAN fue entrenado con datos reales de RICH. Los detectores RICH son capaces de detectar trazas dejadas por partículas π (piones), k (kaones), p (protones), μ (muones) y e (electrones). Algunas otras trazas se clasifican como bt: “por debajo del umbral de emisión de luz Cherenkov” [16].

La entrada del modelo generativo $x \in X \subset R^{3+d_{noise}}$, que consiste en características cinemáticas dejadas después de las colisiones de protones: pseudo-rapidez η (ETA), momento P y número de trazas (ntracks); se agrega ruido aleatorio adicional en la entrada. La salida $y \in Y \subset R^5$ corresponde a las Δ log-verosimilitudes de las partículas antes mencionadas cuando se compara con la traza generada por una partícula pion (π), que es la partícula más común producida durante los experimentos de colisión.

4.1. GANs

Las redes generativas adversitivas (GAN) fueron introducidas por Ian Goodfellow et al [5], como un nuevo acercamiento para entrenar modelos generativos. El framework propuesto entrena dos redes neuronales (modeladas con perceptrones multicapa) usando retropropagación, un modelo generativo G -llamado generador- y un modelo discriminativo D , llamado discriminador respectivamente. El modelo G es entrenado para aprender la distribución de los datos, mientras que el modelo D es entrenado para predecir la probabilidad de que una observación pertenezca a los datos en lugar de ser generada por G . D genera un escalar representando la probabilidad de que una muestra x venga de los datos. El objetivo de G es maximizar la probabilidad de engañar D , provocando que este falle en su clasificación, o haciendo que su salida sea cercana a 0.5 para cualquier muestra generada.

El objetivo de la función de un GAN puede ser expresada como un juego de min-max de dos jugadores:

$$\min_G \max_D V(D, G) = E_{x \sim p_{data}(x)} [\log D(x)] + E_{z \sim p_z(z)} [\log (1 - D(G(z)))]$$

Donde p_{data} representa la distribución de los datos reales y la entrada de G es representada por $p_z(Z)$.

El enfoque del entrenamiento adversativo ha probado ser efectivo en generar muestras indistinguibles de distribuciones de datos reales. La principal desventaja del framework GAN es que tanto G como D deben estar sincronizados durante el entrenamiento, para evitar un escenario donde G colapse demasiadas entradas de p_z en el mismo valor x , por lo que no generaría suficiente diversidad en los datos presentes en p_{data} . Por otro lado, las redes adversativas son flexibles y puede representar distribuciones degeneradas.

4.2. Estimación de incertidumbre

Los modelos de aprendizaje profundo (DL) constituyen a un subcampo de machine learning basado en redes neuronales artificiales con perceptrones multicapa, que capturan la información más importante de un conjunto de datos de entrada para lograr un objetivo específico, como una predicción, clasificación, regresión, etc. Una ventaja de delegar dicha tarea a los modelos DL, es que simplifica el diseño del sistema, pero esta delegación más el alto número de parámetros en esos modelos, hace que los modelos DL sean bastante difíciles de interpretar [3].

Si estos modelos DL añaden como salida una estimación de incertidumbre, además de lo que el modelo piensa que es su precisión, sería bastante útil para un usuario que necesita decidir si confiar en el modelo o no.

Se espera que los modelos generativos ANN aprendan la distribución de un conjunto de entrenamiento $D = \{(x_i, y_i)\}$, donde $D \subseteq X \times Y$, $x_i \in R^d$, y $y_i \in R^n$, así cuando las muestras no vistas $x^* \in X$ llegan a los modelos, deberían generar objetivos $y^* \in Y$, asumiendo que D es representativo de $X \times Y$, los ANNs deberían calcular la siguiente distribución condicional, como se menciona en [3]:

$$p(y^*|x^*, D) \equiv p(y^*|x^*, X, Y)$$

Cuando se estima la distribución de salida, un modelo intermediario W puede ser usado:

$$p(y^*|x^*, D) \approx \int_W p(y^*|W, x^*)p(W|X, Y)\delta W$$

La evaluación de dicha integral puede ser muy compleja dado que estimar las distribuciones posteriores para modelos DL pueden ser intratables, por eso la probabilidad puede ser aproximada como:

$$p(y^*|x^*, X, Y) = p(y^*|x^*, W^*)$$

Donde W^* representa el modelo que maximiza la probabilidad de modelar los datos verdaderos X, Y :

$$W^* = \arg \max_w (p(W|X, Y))$$

La incertidumbre puede ser entendida como duda, ambigüedad, impredecibilidad, y puede ser encontrada en cada paso del proceso de machine learning. Los modelos DL usualmente no representan puntajes de incertidumbre en problemas de regresión, y para tareas de clasificación retorna tensores de puntaje normalizados que puede no capturar incertidumbre [19]. Pero, con el uso de redes neuronales bayesianas (BNN) [20], es posible aproximar la incertidumbre de un modelo DL [21].

Existen dos tipos de incertidumbre en el contexto de modelaje: aleatoria y epistémica [22].

4.2.1. Incertidumbre Aleatoria

Representa la aleatoriedad inherente en los datos. Puede ser causado por un error en el equipo de medición o por otros factores externos. No es reducible, porque no importa cuantas observaciones se hagan ni cuantas medidas se tomen, los mismos errores del proceso siempre van a estar presentes. Factores externos a veces pueden mitigarse, pero suelen considerarse fuera de control del entorno del experimento. Asimismo, existen dos tipos de incertidumbre aleatoria.

Incetidumbre aleatoria homocedástica: Asume una constante de error σ para cada observación x_i , usualmente relacionado al ruido derivado del proceso de medición.

Incertidumbre aleatoria heterocedástica: Representa los casos donde los errores en diferentes regiones del espacio de observaciones definido por $\{X\}$ tienen diferentes varianzas, provocando que σ no sea constante.

Esta proviene de fuentes irreducibles de ruido en los datos, y puede ser aproximado de los datos de entrada. Si se entrenan modelos de regresión para este tipo de incertidumbre, estos optimizarán la desviación estándar σ del espacio de entradas.

Cuando los datos tienen un comportamiento homocedástico, se puede asumir una desviación estándar σ constante para todo el conjunto de entrada, pero en un escenario heterocedástico hay partes del espacio de entrada que presentan un ruido mayor comparado con otras partes, por lo que en este caso σ no es constante.

En los casos de heterocedasticidad una red neuronal artificial no bayesiana puede optimizar el parámetro σ . En estas redes los pesos son escalares, en lugar de distribuciones de probabilidades. En una tarea de regresión se puede usar la distancia euclidiana $l^2 = ||y - \bar{y}||^2$ en la función de pérdida del modelo [19]:

$$L_{NN}(W) = \frac{1}{N} \sum_{i=1}^N \frac{||y_i - f(x_i)||^2}{2\sigma_{x_i}^2} + \frac{1}{2} \log \sigma_{x_i}^2$$

Donde $f(x_i)$ es la predicción del modelo. Si la distancia l^2 es alta, el modelo intentará atenuar el residual incrementando $\sigma_{x_i}^2$, pero esto no crecerá de forma indefinida, ya que será regularizada por el $\log \sigma_{x_i}^2$ de la ecuación.

4.2.2. Incertidumbre Epistémica

Se relaciona con la capacidad del modelo de aprender a representar la distribución de los datos. Se cree que se puede reducir aumentando las muestras usadas para entrenar el modelo, de modo que pueda representar mejor la diversidad en los datos.

Esta se puede aproximar asignando una distribución sobre los pesos W de un modelo, e intentando evaluar cuanto varia W dado un conjunto de datos. Este tipo de modelo se le conoce como una red neuronal bayesiana BNN.

Como ejemplo, distribuciones previas sobre la matriz W pueden ser un modelo Gaussiano N , tal que:

$$W \approx N(0, Identity)$$

Donde W no es más una matriz determinística, cada uno de sus pesos son muestreados de distribuciones previas, y el proceso de entrenamiento ya no optimiza a valores discretos, sino que marginaliza sobre todos los valores para los pesos. En este escenario, dado un conjunto de datos $D: X \times Y$, se quiere predecir $y_i \in Y$, dada una entrada $x_i \in X$ con un modelo de red neuronal bayesiana $f^{(W)}(x_i) = \bar{y}_i$, donde la verosimilitud está definida como la probabilidad $p(y_i | f^{(W)}(x_i))$.

Asumiendo que el modelo hace regresión, la verosimilitud estaría dada por:

$$p(y_i | f^{(W)}(x_i)) = N(f^{(W)}(x_i), \sigma(x_i)^2)$$

Donde $\sigma(x_i)^2$ es una matriz diagonal de las varianzas calculadas sobre el dato de entrada x_i , usado σ como parámetro.

Las redes neuronales bayesianas necesitan calcular el $p(W|X, Y)$ usando inferencia bayesiana [19]:

$$p(W|X, Y) = \frac{p(Y|X, W)p(W)}{p(Y|X)}$$

Pero cuándo se trata de usar esta inferencia, aparece un problema complejo: la probabilidad marginal $p(Y|X)$ usualmente es intratable. Para resolver este problema se han sugerido varios acercamientos para aproximar esta probabilidad a lo largo de los años [3], tales como: procesos gaussianos, inferencia variacional, Monte Carlo Dropout o Deep ensembles, entre otros.

4.3. Deep ensembles

Los métodos de redes neuronales bayesianas para estimar incertidumbre tienen que lidiar con la integral en la ecuación de estimación de la distribución de salida, resolviéndola de forma analítica, aproximando una distribución más simple o usando muestreo de Monte Carlo de un conjunto de diferentes modelos.

Deep ensembles depende de un conjunto de modelos $F^{(M)}$ [6], donde para conseguir una predicción de una entrada x_i , se toma la media de las salidas de los modelos individuales:

$$f^{(M)}(x_i) = \frac{1}{M} \sum_{m=1}^M \left(f^{(m)}(x_i) \right)$$

Los modelos son inicializados con pesos aleatorios y son entrenados juntos, compartiendo la misma función de pérdida. Para realizar la estimación de incertidumbre se puede observar la varianza en las salidas de los modelos para una entrada en específico:

$$Ux_i = \sigma^2 \left(f^{(M)}(x_i) \right)$$

Una de las desventajas de usar este método es el costo y el tiempo asociado con entrenar varios modelos, el cual puede ser muy alto para modelos con miles de parámetros.

4.4. Monte Carlo Dropout

Tomar ventaja del concepto de Monte Carlo Dropout para iterar sobre un solo modelo es otro acercamiento que tiene una implementación más simple.

Dropout fue introducido como una técnica de prevención de sobre ajuste para un modelo [7]: este consiste en apagar o habilitar neuronas aleatoriamente durante las iteraciones de entrenamiento, siguiendo alguna distribución como Bernoulli o Gauss para seleccionar las neuronas que van a ser apagadas. Una vez que el modelo está entrenado, el *dropout* no se usa más y los modelos usan el set completo de neuronas para generar predicciones.

Desde una perspectiva de estimación de incertidumbre, Gal y Ghahramani propusieron [23] usar las capas internas de *dropout* de una red neuronal profunda para reducir la divergencia entre la probabilidad de una distribución propuesta $Q(W)$ y la verdadera distribución dada por:

$$p(W|X, Y) = \frac{p(Y|X, W)p(W)}{p(Y|X)}$$

Cuando se hace estimación de incertidumbre con Monte Carlo Dropout, se usan las capas de Dropout para la inferencia, esto para que los pesos W para una capa M_i se seleccionen usando una distribución de probabilidad:

$$W_i = M_i \times \text{diag}([z_{i,j} = 1]),$$

Donde $z_{i,j} \approx \text{Bernoulli}(p_i)$. Si $z_{i,j} = 0$ significa que la unidad i en la capa j va a ser apagada. Se generan predicciones sobre la misma entrada x_i , n veces para obtener un conjunto de n predicciones $\bar{y}_i$

La estimación de incertidumbre es obtenida de la desviación estándar $\sigma(\{\bar{y}_1, \dots, \bar{y}_n\})$ de las predicciones.

Una ventaja de usar este método es que se pueden simular varios modelos a partir de uno, pero cada modelo simulado compartirá los mismos modelos a través de las iteraciones, lo que reduce la diversidad presente cuando se compara con el método de Deep ensembles.

4.5. Feature Densities

El algoritmo de feature density utiliza capas internas de un modelo de aprendizaje profundo (generalmente las últimas) para descomponer una entrada $x_i \in X$ en un set de características $f^d, d \in D$, cuya dimensionalidad está definida por la cantidad de neuronas en la capa seleccionada. Características individuales componen un espacio de característica $F^D = \{f^1, f^2, \dots, f^D\}$ de dimensionalidad R^D . Usando las entradas x del conjunto de datos de entrenamiento D_{train} , un histograma puede ser construido para cada f^d que sirve para aproximar una función de densidad de probabilidad $\bar{p}_d$ para cada característica, tal que $\bar{P}_D = \{\bar{p}_1, \bar{p}_2, \dots, \bar{p}_D\}$. Calderón et al [24] llaman a este acercamiento el método de Feature Histograms (FH).

Ellos usaron este método para identificar muestras de datos fuera de la distribución sin etiquetar en un entorno de aprendizaje profundo semi supervisado (SSDL) para clasificar radiografías de tórax para detectar el COVID-19, asignando un puntaje de “daño” H a las muestras sin etiquetar x_j^u basándose en su probabilidad de ser Independientes e Idénticamente Distribuidos (IID), lo cual es aproximado con las funciones en $\bar{P}_D$. En este contexto, las muestras OOD presentaron bajas probabilidades, lo cual permitió a los investigadores descartarlas al entrenar el modelo SSDL. El puntaje H se calculó como:

$$H(x_j^u) = - \sum_d^D \ln(\bar{p}_d(f_j^{d,u}))$$

4.6. Redes neuronales de intervalos

Otra opción para la estimación de incertidumbre es el uso de redes neuronales de intervalos (INN), las cuáles proveen un rango como resultado de la inferencia, del cual se puede extraer directamente la incertidumbre del modelo. Oala et al [25] mencionan que la ventaja de usar INN para la estimación de incertidumbre es que se adquiere la dirección de la incertidumbre, además de ser más robusta al basarse en acotar la distribución de los datos usando intervalos, en lugar de colocar una distribución normal sobre los parámetros, tal como es el caso de FD y MCD.

En este caso, Oala et al [25] proponen una implementación de INN que se inicializa con los parámetros de un modelo tratándolos como si fueran intervalos puntos y propagándolos por la red, capa a capa, de acuerdo con la siguiente fórmula de propagación a través de una capa l :

$$[\underline{x}, \bar{x}]^{(l+1)} = \varrho([\underline{W}, \bar{W}]^{(l)}[\underline{x}, \bar{x}]^{(l)} + [\underline{b}, \bar{b}]^{(l)}).$$

Donde $[\underline{x}, \bar{x}]$ es el intervalo de entrada, $[\underline{W}, \bar{W}]$ son las matrices de peso con valores de intervalos y $[\underline{b}, \bar{b}]$ son los vectores de sesgo.

Dado que se requiere que los intervalos resultantes contengan los valores objetivos luego del entrenamiento, se define la pérdida del intervalo en cero si el objetivo se encuentra dentro del intervalo, y se define como la distancia cuadrada al límite del intervalo si se encuentra fuera del intervalo. Para evitar que los intervalos cubran todo el rango de los valores objetivos, Oala et al [25] utilizan una penalización lineal en el tamaño del intervalo para el conjunto de datos $\{x_i, y_i\}_{i=1}^m$ de entradas $x_i \in X$ y salidas $y \in Y$, generando la siguiente fórmula de pérdida:

$$\mathcal{L}(\underline{\Phi}, \bar{\Phi}) = \sum_{i=1}^m \max\{y_i - \bar{\Phi}(x_i), 0\}^2 + \max\{\underline{\Phi}(x_i) - y_i, 0\}^2 + \beta \cdot (\bar{\Phi}(x_i) - \underline{\Phi}(x_i)).$$

Aquí, $\bar{\Phi}: X \rightarrow Y$, $\underline{\Phi}: X \rightarrow Y$ son las funciones que mapean las entradas en los límites del intervalo para la salida del INN. El parámetro $\beta > 0$ determina la sensibilidad con la que los intervalos son entrenados.

5. Metodología de la investigación

5.1. Ubicación Temporal y espacial del estudio

La investigación se ha llevado a cabo de manera ininterrumpida desde 2023 hasta la fecha. Durante este periodo, se han realizado varios ciclos de experimentación y análisis, lo que ha permitido una evaluación constante de la estimación de incertidumbre en redes generativas. Este trabajo se ha desarrollado de forma virtual, utilizando herramientas tecnológicas y plataformas de colaboración en línea. El proyecto cuenta con el respaldo del CERN, ubicado en Ginebra, Suiza, y está gestionado bajo el acuerdo CERN-CONARE.

5.2. Variables e indicadores

En esta investigación, utilizamos el conjunto de datos RICH, el cual incluye subgrupos de datos correspondientes a distintos tipos de partículas observadas en 2016 en el experimento LHCb. Cada registro de datos de RICH se compone de arreglos X e Y , donde las entradas $x \in R^3$ contienen las características cinemáticas de las partículas (pseudorrapidez η , momento P y número de trazas). Las salidas $y \in R^5$ reflejan la diferencia de verosimilitud (log-likelihood) entre la hipótesis de partícula y la de pion. Las partículas consideradas incluyen kaón K , protón p , muón μ , electrón e , y cualquier otra partícula que esté por debajo del umbral para emitir radiación Cherenkov.

5.3. Proceso y características de los instrumentos para la recolección de información

La técnica para la recolección de datos del detector RICH se realiza en tres fases. La primera involucra la generación de datos cuando las partículas cargadas atraviesan el detector, provocando la emisión de luz de Cherenkov. En la segunda fase los datos son leídos por sistemas electrónicos y la última fase consiste en procesar y analizar dichos datos.

5.3.1. Fase I – Generación de datos del detector RICH

El sistema RICH está encargado de identificar partículas cargadas en el rango de momento de 1-150 GeV/c, dentro de una aceptación angular de 10-300 miliradianes (mrad).

La identificación de partículas es crucial para reducir el fondo o “ruido” en estados finales seleccionados y para proporcionar una etiqueta eficiente.

En la Figura 19 se ilustra el impacto del detector RICH, en donde se utiliza la identificación de partículas proporcionada por el RICH para poder separar los diferentes procesos, ya que sin él hay una mezcla significativa de señales de diferentes tipos de eventos.




Figura 19. Impacto del Detector RICH en la Identificación de Partículas [26].

5.3.1.1. Detector RICH

El sistema consta de un detector upstream (RICH-1) con aerogel de sílice y radiadores de gas C₄F₁₀, ubicado directamente detrás del VELO, y un detector downstream (RICH-2) con un radiador de gas CF₄, ubicado detrás del imán y el sistema de seguimiento.

El aerogel de sílice es una forma coloidal de cuarzo sólido, pero con una densidad extremadamente baja y un índice de refracción alto (1,01–1,10), lo que lo hace perfecto para las partículas de menor momento (del orden de unos pocos GeV/c).

Para cubrir las regiones de momento medio y alto, LHCb utiliza una combinación de radiadores C_4F_{10} y CF_4 para momentos de alrededor de 10 GeV/c a alrededor de 65 GeV/c, y de alrededor de 15 GeV/c a más de 100 GeV/c, respectivamente [26].

Por lo tanto, con su aerogel de sílice y su radiador de gas C_4F_{10} , el detector RICH-1 está configurado para detectar partículas de bajo momento, mientras que RICH-2 tiene una aceptación limitada a la región de ángulo bajo, donde hay principalmente partículas de alto momento, y utiliza un radiador de gas CF_4 . En la Figura 20, se ilustra la arquitectura y componentes anteriormente mencionados [26].




Figura 20. Arquitectura del Detector RICH y Trayectoria de las Partículas [26].

Ambos detectores RICH utilizan detectores de fotones híbridos (HPD) para medir las posiciones de los fotones Cherenkov emitidos. El HPD es un detector de fotones de vacío en el que un fotoelectrón, liberado cuando un fotón incidente se convierte dentro de un fotocátodo, se acelera mediante un alto voltaje de

típicamente 10-20 kV sobre un detector de silicio con polarización inversa. El tubo enfoca el fotoelectrón electrostáticamente, con un factor de demagnificación de alrededor de cinco, sobre una pequeña matriz de detectores de silicio. En la Figura 21 se ilustra su arquitectura [26].




Figura 21. Detector de fotones híbridos [26].

La colaboración LHCb ha desarrollado un novedoso dispositivo de detección de partículas de alta potencia (HPD) de píxeles dedicado a los detectores RICH, en estrecha colaboración con la industria. En este caso, el detector de silicio está segmentado en 1024 “superpíxeles”, cada uno de ellos de $500\ \mu\text{m} \times 500\ \mu\text{m}$ de área y dispuestos como una matriz de 32 filas y 32 columnas [26].

Cuando un fotoelectrón pierde energía en el silicio, crea pares electrón-hueco con un rendimiento medio de uno por cada 3,6 eV de energía depositada. El voltaje operativo nominal de los HPD del LHCb es de $-20\ \text{kV}$, lo que corresponde a unos 5000 pares electrón-hueco liberados en el silicio. El diseño cuidadoso de la electrónica de lectura y las interconexiones con el detector de silicio dan como resultado una alta eficiencia para detectar fotoelectrones individuales. El experimento requiere 484 tubos en total (196 para RICH-1 y 288 para RICH-2) para cubrir las cuatro superficies de detección [26].

5.3.2. Fase II – Lectura de los datos

El RICH opera de forma autónoma por medio del sistema de control de experimentos_(ECS), el cual utiliza secuencias predefinidas para una operación de detección normal, lo que permite que personas no expertas puedan operen el detector.

El ECS también recolecta información del ambiente que es requerida por el software de reconstrucción del RICH. Para esto existen sistemas que monitorean los movimientos de los espejos del RICH, la calidad de los radiadores de gas y registran la temperatura y presión de los radiadores para corregir el índice de refracción. Los cambios en la temperatura y presión son automáticamente propagados a la base de datos de condiciones [27].

La información grabada y los detectores del RICH son monitoreados en varias etapas de la adquisición de datos y de la cadena de reconstrucción para identificar cualquier potencial problema lo más rápido posible. La Figura 22 ilustra el flujo de datos en línea, resaltando el monitoreo dedicado y las granjas de calibración para análisis usando eventos completamente reconstruidos. Aquí los eventos seleccionados por el *trigger*⁶ L0 son enviados a la granja de *triggers* de alto nivel (HLT) y, si pasan los requisitos de este *trigger*, son enviados al almacenamiento. Normalmente se envía la décima parte de estos datos a la granja de monitoreo. Los algoritmos de monitoreo en línea examinan los datos en busca de irregularidades y envían mensajes al ECS para que active acciones automáticas. Finalmente, los *triggers* especiales son enviados directamente a la granja de calibración evitando el HLT [27].

⁶ Evento o condición que activa una acción específica en un sistema




Figura 22. Flujo de datos a través del sistema en línea [27].

5.3.3. Fase III - Procedimiento para el análisis de la información

El LHC genera 40 millones de colisiones protón a protón por segundo, lo cual es una cantidad de información demasiado alta como para almacenarla toda (se estaría usando un Terabyte por segundo). Debido a esto se realiza una filtración para almacenar únicamente los datos que contienen información interesante.

Las colisiones registradas por el detector LHCb pasan a través de un flujo de datos específicamente diseñado para maximizar la eficiencia de la toma de datos y su calidad. Para lograr esto se realizan los siguientes pasos [28]:

- a. Se filtran los datos del detector por medio del *trigger*, el cual está formado por el L0, implementado en hardware, y el *trigger* de alto nivel (HLT), implementado en software.

- b. Los datos crudos son reconstruidos para transformar los golpes del detector en objetos, tales como trazas y clústeres.
- c. Los datos son nuevamente filtrados por medio de un conjunto de selecciones llamadas *stripping*⁷, las cuales son controladas por la aplicación DaVinci, que escribe la información en formato DST o μ DST, agrupando los datos en *streams*⁸ con selecciones similares para ahorrar espacio en disco y acelerar el acceso para los analistas.
- d. Los usuarios corren sus propias herramientas de análisis para extraer variables de la aplicación DaVinci.

Además de esto también se producen datos Monte Carlo, los cuales hacen referencia a eventos simulados, que se procesan de una forma muy parecida a los datos reales. Hay dos pasos que reemplazan la colisiones protón a protón y la respuesta del detector [28]:

- a. La simulación de las colisiones protón a protón, la hadronización y la caída de las partículas resultantes son controladas por la aplicación Gauss, la cual se encarga de llamar varios generadores Monte Carlo, como Pythia y POWHEG, y controlar EvtGen y Geant4. EvtGen se usa para describir las caídas de las partículas generadas y Geant4 se usa para simular la propagación e interacción de las partículas con el detector.
- b. La aplicación Boole convierte los golpes simulados por el detector virtual en señales que imitan el detector real. La salida de Boole está diseñada para que se parezca lo más posible a la salida del detector real, lo cual permite que los datos sean procesados de acuerdo con el procedimiento anteriormente mencionado.

De esta forma el procesamiento de la información para su análisis se puede representar visualmente con la Figura 23:

⁷ Proceso de selección y filtrado de datos en bruto

⁸ Secuencias de datos que se transmiten de manera continua y en tiempo real




Figura 23. Flujo del procesamiento de la información [28].

5.3.4. Identificación de las partículas

Para llevar a cabo este proceso la información del ángulo de Cherenkov debe combinarse con el momento de la traza es medido por el sistema de seguimiento. Ya que, para reconstruir estos eventos de manera eficiente, se utiliza el algoritmo del logaritmo de la verosimilitud de eventos general, donde todas las trazas en el evento y ambos detectores RICH se consideran simultáneamente.

Esto permite un tratamiento óptimo de las trazas donde los conos de Cherenkov se superponen. Dado que las partículas más abundantes en las colisiones son piones, el procedimiento de minimización de la probabilidad comienza asumiendo que todas las partículas son piones. Luego, se calcula la probabilidad general del evento, calculada a partir de la distribución de impactos de fotones, las trazas asociadas y sus errores, para este conjunto de hipótesis. Seguidamente, para cada traza, se vuelve a calcular la probabilidad cambiando la hipótesis de masa a e , μ , π , K y protón, mientras que se dejan todas las demás hipótesis sin cambios. Se identifica el cambio en la hipótesis de masa entre todas las trazas que produce el mayor aumento en la probabilidad de evento, y la hipótesis de masa para esa traza se establece en su valor preferido. Luego, este procedimiento se repite hasta que todas las trazas se hayan establecido en sus hipótesis óptimas y no se encuentre ninguna mejora adicional en la probabilidad de evento [27].

Para reducir el uso intensivo de CPU en la minimización de probabilidad, se implementan dos optimizaciones. Primero, las trazas se clasifican según el cambio en su probabilidad y se prioriza la traza con mayor cambio. Si esta traza supera un umbral ajustable, se detiene la búsqueda y se cambia su hipótesis. Segundo, si una traza tiene una clara preferencia por una hipótesis de masa, se fija esa hipótesis y se excluye en iteraciones posteriores. Estas optimizaciones reducen significativamente el uso de CPU. La contribución de fondo se calcula antes, comparando la señal esperada en cada HPD, basada en las pistas reconstruidas y su hipótesis de masa, con la señal observada. Cualquier exceso se utiliza para determinar la contribución de fondo y se incluye en el cálculo de probabilidad [27].

Los resultados finales de la identificación de partículas son diferencias en los valores de log de la verosimilitud, que dan para cada traza el cambio en la probabilidad de log del evento general cuando esa pista cambia de la hipótesis del pion a cada una de las hipótesis del electrón, muón, kaón y protón.

6. Análisis de los Riesgos

En esta sección, se abordarán de manera sistemática los riesgos identificados en el proyecto, categorizándolos según su naturaleza, ya sea tecnológica, de personas, políticas u otros. Se evaluarán las posibles causas de estos riesgos, así como su impacto en el proyecto y la probabilidad de que ocurran. Basado en los lineamientos del PMBOK, se calculará la exposición al riesgo mediante el producto del impacto y la probabilidad. Además, se definirán estrategias específicas para evitar, mitigar y, en caso necesario, contingencias para manejar los riesgos si se materializan. Este enfoque garantiza una gestión de riesgos integral y alineada con las mejores prácticas en la gestión de proyectos.

6.1. Estrategia

El primer paso en la gestión de riesgos es su identificación, un proceso crucial para asegurar que todos los posibles eventos que puedan impactar negativamente el proyecto sean detectados a tiempo. Durante esta fase, se documentan detalladamente las características de cada riesgo, asignándoles una categoría específica que puede ser tecnológica, operativa, de personas, entre otras. Además, se evalúan dos aspectos clave: la probabilidad de que el riesgo ocurra y el impacto que podría tener sobre el proyecto. Con esta información, se calcula el nivel de exposición al riesgo, que servirá como base para su análisis posterior.

Una vez identificados y caracterizados, los riesgos son sometidos a un análisis cualitativo. Este análisis permite priorizarlos en función de su probabilidad e impacto, facilitando la identificación de aquellos que requieren mayor atención. El resultado de este proceso es la creación de la Matriz de Evaluación, una herramienta recomendada por la Guía PMBOK, que ofrece una visión clara y estructurada de los riesgos más críticos. Finalmente, se desarrollan planes de contingencia específicos, que están diseñados para ser activados si alguno de los riesgos identificados se materializa, garantizando así que el proyecto pueda seguir adelante con el menor impacto posible.

6.2. Categorías

Se utilizará la clasificación de riesgos con tal de mejorar su identificación y organización tal como se ve en la Figura 24.



DRAW IO

Figura 24. Clasificación de Riesgos

6.3. Niveles de impacto

En la Tabla 9 se enlista y se explican los niveles de impacto que pueden tener los riesgos.

Tabla 9. Significado de los niveles de impacto de los posibles riesgos.

Nivel de Impacto	Significado
Alto (3)	Es necesario detener actividades o procesos para llevar a cabo acciones de contingencia. Requerimientos o fases del proyecto pueden cancelarse.
Medio (2)	Reparable, sin embargo, puede ser necesario detener algún proceso o actividad temporalmente.
Bajo (1)	Reparable, sin necesidad de paro de ningún proceso o actividad.

6.4. Probabilidad de ocurrencia

En la Tabla 10 se enlistan y se explican los niveles de probabilidad de ocurrencia que pueden tener los riesgos.

Tabla 10. Significado de los niveles de ocurrencia.

Nivel de Probabilidad	NP	Significado
Alta (3)	$10 < NP < 20$	Es muy posible que suceda.
Media (2)	$6 < NP < 8$	Es posible que suceda alguna vez
Baja (1)	$2 < NP < 4$	No se espera que suceda

6.5. Niveles de exposición

En la Tabla 11 se enlistan y se explican los niveles de exposición que pueden tener el proyecto ante los riesgos.

Tabla 11. Significado de los niveles de exposición a los riesgos.

Nivel de Exposición	Significado
Continua	Continuamente, siempre se está en riesgo.
Frecuente	Varias veces a lo largo de la vida del proyecto, con tiempos cortos entre cada vez que se está en riesgo.
Ocasional	Pocas veces, tiempos largos entre cada vez que se está en riesgo.
Esporádica	Casi nunca. Solo una o dos veces.

6.6. Matriz de Riesgos

A continuación, se enlistan los riesgos previstos para el desarrollo del proyecto, así como su categoría, causa, impacto, probabilidad de ocurrencia, exposición que se tendría ante el riesgo, y finalmente las estrategias de evasión, mitigación y contingencia.

Tabla 12. Riesgos previstos para el desarrollo del proyecto.

Tabla de Riesgos			
ID:	R1	Nombre:	Imposibilidad de acceso a clúster informático avanzado
Categoría:	Técnico	Impacto:	Bajo (1)
Exposición:	Ocasional (2)	Probabilidad:	Media (2)
Causa:	Otros grupos de investigación ya podrían estar involucrados con clústeres disponibles, imposibilitando acceso a ellos.		
Evasión:	Utilizar recursos virtuales como Google Colab.		
Mitigación:	Mantener respaldos de variables y datos resultantes de ejecuciones anteriores del código y que son necesarias para futuras ejecuciones.		
Contingencia:	Continuar trabajando con equipo local.		
Comentarios: Dado que el recurso virtual como Google Colab cumple con las necesidades necesarias para ejecutar el modelo se estima que la probabilidad de que se materialice el riesgo es más baja que en la originalmente estimada. Se estima la nueva probabilidad en media.			
Dado que según el cronograma de actividades planificadas para los próximos 4 meses no contempla el uso de un clúster el impacto de que el riesgo se materialice es más baja. Se estima un nuevo impacto en bajo.			
ID:	R2	Nombre:	Falta de nuevos datos para los experimentos
Categoría:	Técnico	Impacto:	Bajo (1)
Exposición:	Esporádico (1)	Probabilidad:	Baja (1)
Causa:	El trámite para la solicitud de datos recientes puede tomar más tiempo del disponible para la ejecución de los experimentos.		
Evasión:	Realizar el trámite con tres meses de anticipación, a la planificación de su uso.		
Mitigación:	Realizar diversas particiones entre los datos de entrenamiento y de validación.		
Contingencia:	Continuar trabajando con los datos estáticos que se tiene ya disponibles.		

Comentarios: El realizar el trámite de solicitud de nuevos datos con anticipación provoca que la probabilidad de que falten nuevos datos para los experimentos baje. Se estima una nueva probabilidad en baja.			
ID:	R3	Nombre:	Mal desempeño del modelo
Categoría:	Técnico	Impacto:	Medio (2)
Exposición:	Ocasional (2)	Probabilidad:	Baja (1)
Causa:	El modelo generativo puede no estar bien entrenado o ajustado, lo que lleva a una baja calidad en las simulaciones generadas y, por ende, a una estimación inexacta.		
Evasión:	Evaluar el modelo con diferentes conjuntos de datos de menor tamaño para medir la calidad de las simulaciones que genera antes de usar el conjunto de datos reales.		
Mitigación:	Usar la región de los datos que tengan la menor incertidumbre.		
Contingencia:	Reentrenar el modelo utilizando un conjunto de datos más diverso o ampliado para mejorar su capacidad de generalización.		
Comentarios: Al utilizar la región de datos con la menor cantidad de incertidumbre podemos concluir en cuales el modelo funciona mejor y en cuales no, lo cual no impide el avance de la investigación. Por lo cual, se estima un nuevo impacto en medio.			
ID:	R4	Nombre:	Problemas de Escalabilidad
Categoría:	Técnico	Impacto:	Nulo (0)
Exposición:	Nula (0)	Probabilidad:	Bajo (1)
Causa:	Al escalar los datos originales antes de ingresarlos en el modelo, se corre el riesgo de distorsionar la información crítica, lo que podría afectar la precisión del modelo y las estimaciones de incertidumbre.		
Evasión:	Realizar una cuidadosa normalización o estandarización de los datos, asegurando que el proceso de escalado no altere las relaciones importantes entre las variables.		
Mitigación:	Establecer un mecanismo para revertir el escalado y utilizar técnicas alternativas de preprocesamiento si se detectan problemas con los datos escalados.		
Contingencia:	Utilizar otro método de escalado.		
Comentarios: El cambiar de método de escalado no afectaría el cronograma de actividades por el tiempo que tomaría cambiarlo, por el cual se desestima el impacto.			
ID:	R5	Nombre:	Sobre entrenamiento del modelo
Categoría:	Técnico	Impacto:	Alto (3)
Exposición:	Nulo (0)	Probabilidad:	Nulo (0)
Causa:	El modelo puede ser entrenado excesivamente en los datos de entrenamiento, lo que lleva a un sobreajuste y a una generalización pobre en datos nuevos.		

Evasión:	Utilizar técnicas de regularización, como el <i>dropout</i> o la penalización de normas, durante el entrenamiento del modelo para reducir el riesgo de sobre entrenamiento.
Mitigación:	Aplicar un proceso de validación cruzada con múltiples particiones del conjunto de datos para asegurar que el modelo generalice bien a datos no vistos.
Contingencia:	Si se detecta sobre entrenamiento, reentrenar el modelo con un enfoque diferente o ajustar la complejidad del modelo.
Comentarios: Debido a la cantidad de datos actuales que se tiene, así como las capas de dropout que tiene el modelo se desestima la probabilidad.	

6.7. Evaluación de Riesgos

A continuación, se presenta la evaluación de los riesgos previamente mencionados. La Tabla 13 muestra la clasificación de estos riesgos junto con las acciones a tomar según la categoría asignada. Por otro lado, la Tabla 14 clasifica cada riesgo basándose en la Probabilidad de Ocurrencia y el Nivel de Impacto. Los colores en las celdas de la Tabla 13 corresponden a las categorías definidas en la Tabla 14.

Tabla 13. Colores de clasificación de riesgos.

Clasificación	<u>Bajo</u> Aceptable	<u>Medio</u> Razonable	<u>Alto</u> Inaceptable
Acciones Requeridas	No se requieren acciones específicas.	Se deben hacer esfuerzos para reducir el riesgo.	No se debe comenzar la actividad o fase hasta reducir el riesgo.

Tabla 14. Matriz de Evaluación de Riesgos Inicial.

		Impacto		
		Bajo	Medio	Alto
Probabilidad	Baja	R4		R5 R3
	Medio	R2		
	Alto		R1	

Seguidamente, en la Tabla 15 se encontrará la matriz de evaluación de riesgo luego de la reevaluación al informe final.

Tabla 15. Matriz de Evaluación de Riesgos Final

		Impacto		
		Bajo	Medio	Alto
Probabilidad	Baja	R2	R3	
	Medio	R1		
	Alto			

7. Resultados

Nuestras pruebas utilizan un modelo GAN que se entrenó utilizando un *dropout* de 0.01, y la estrategia de *dropout*: "estructura de Bernoulli", y se ajustó a más de 400 épocas utilizando los archivos de partículas π (pion) del conjunto de datos RICH, donde comparamos los puntajes de incertidumbre de MCD y FD. Además, los datos se dividieron en dos conjuntos disjuntos: entrenamiento y validación. Estos datos son divididos linealmente por un umbral predefinido en las características de pseudorrapidez η y momento P , donde el número de trazas no es utilizado al momento de dividir los datos.

En esta sección se llevará a cabo un análisis detallado de las dos principales fuentes de incertidumbre en el modelo: la incertidumbre epistémica y la incertidumbre aleatoria. Se explorarán los métodos utilizados para cuantificar cada tipo de incertidumbre, así como su impacto en los resultados del modelo, con el fin de proporcionar una comprensión integral del comportamiento y la confiabilidad de las predicciones generadas.

7.1. Incertidumbre Epistémica

En primer lugar, se desarrollará la métrica con que se cuantifica la incertidumbre por método y seguidamente se detallan los experimentos para evaluar dichos métodos. En el caso de Monte Carlo Dropout se utilizó todo el conjunto de datos de validación, donde para cada observación se iteró 300 veces sobre el modelo, generando dicha cantidad de muestras por cada observación. Utilizando estas muestras se calcula su incertidumbre como la varianza para cada etiqueta, si todas las muestras generadas presentan una varianza baja para una observación dada, esto indicaría que el modelo está familiarizado con dicha observación, por lo tanto, su incertidumbre sería baja. Por lo tanto, para calcular el MCD σ_j^2 para una observación $x^{(j)}$ utilizamos la fórmula de la varianza como:

$$\sigma_j^2(x^{(j)}) = \frac{1}{N-1} \sum_{i=1}^N (\bar{y}(x^{(j)}) - y_i(x^{(j)}))^2$$

Donde N es el número de repeticiones (inferencias), $x^{(j)}$ es una única observación, y_i es un único valor generado y el promedio de todas las predicciones del conjunto para $x^{(j)}$ es $\bar{y}$.

Para el caso de Features Densities, el primer paso del experimento consistió en generar *embeddings*⁹ para cada una de las observaciones en la división de entrenamiento. Los *embeddings*: v_d , se tomaron de la última capa interna de preactivación, con 128 neuronas $d \in D^{128}$. Después de recolectar los *embeddings*, usamos los histogramas para aproximar una función de densidad de probabilidad $\tilde{p}d$, para cada una de las neuronas, obteniendo un total de 128 funciones. Seguidamente, pasamos cada observación x_n del conjunto de datos de validación a través de la GAN de Cramer y registramos los *embeddings* generados de la última capa interna de preactivación (con D^{128}). Después de recolectar las incrustaciones del conjunto de pruebas, las promediamos y calculamos la probabilidad de cada uno de los 128 valores usando la función de densidad de probabilidad aproximada obtenida en el primer paso. Finalmente, generamos un puntaje de incertidumbre $u(x_n)$ para cada observación restando 1.0 (siendo 1.0 una probabilidad perfecta, nos interesa el complemento) del promedio de todas las probabilidades de los *embeddings*:

$$u(x_n) = 1 - \frac{1}{D} \left(\sum_{d=1}^D \tilde{p}d(v_d^{(x_n)}) \right)$$

Una vez conocido como es que se calcula el puntaje de incertidumbre para ambos métodos se detalla cómo se evaluarán, ya que los puntajes obtenidos tanto de MCD como de FD están en unidades diferentes: una desviación estándar frente a una puntuación de verosimilitud respectivamente, lo que complica la forma en que podemos comparar el rendimiento de cada método entre sí. Para poder realizar una comparación, recurrimos a correlacionar las puntuaciones de incertidumbre obtenidas con otra métrica, como la distancia entre las distribuciones de datos reales y generados.

⁹ Representación vectorial densa de datos en un espacio continuo de menor dimensión

Existen varias métricas que miden las distancias de distribución, incluso se podría utilizar la distancia de Cramer. Para obtener una distribución no tan cercana a la implementación de GAN, utilizamos las distancias de Jensen-Shannon, Kolmogorov-Smirnov y Earth Mover's Distance para este propósito. Nuestro razonamiento es que las observaciones generadas que pertenecen a regiones de mayor distancia con el conjunto de datos real deberían mostrar un puntaje de incertidumbre correspondientemente más alto con cualquiera de los métodos. Además, utilizamos el coeficiente de correlación de Pearson para verificar si existe una relación entre las distancias de distribución y el puntaje de incertidumbre de cada método.

7.1.1. Modificaciones en el modelo

Se realizaron tres distintas variaciones a la hora de medir el modelo, donde para cada una de ellas se crean histogramas donde cada histograma muestra cuantiles de aproximadamente 10000 observaciones, sobre diferentes rangos de puntajes de incertidumbre $u(x_n)$. Los histogramas comparan tanto la salida generada para una partícula dada como el valor real del conjunto de datos RICH. Para poder realizar una comparación por histograma, correlacionamos la distancia entre las distribuciones de datos reales y generados contra el puntaje de incertidumbre de dicho histograma.

7.1.1.1. Experimento de ruido cero

En esta variación se congelaba el ruido y en lugar del ruido que es agregado junto con las variables de entrada se evaluaba con valores de cero, en búsqueda de eliminar la aleatoriedad del modelo. En la Figura 25 y Figura 26 se presenta las distribuciones entre los datos esperados y los generados para MCD y FD para la partícula electrón respectivamente. Además, de igual forma en la Figura 27 y Figura 28, se presenta las curvas de fiabilidad entre la distancia Jensen-Shannon y la incertidumbre, además, en la Tabla 16, se muestra el coeficiente de relación entre estas dos variables mencionadas.




Figura 25. Puntajes de incertidumbre para MCD con ruido cero.




Figura 26. Puntajes de incertidumbre para FD con ruido cero.





Figura 27. Curvas de confiabilidad para MCD con ruido cero.



MATPLOTLIB

Figura 28. Curvas de confiabilidad para FD con ruido cero.

Tabla 16. Coeficientes de correlación de Pearson con ruido cero.

	Coeficientes de Correlación de Pearson				
Método	Electrón	Kaón	Muón	Protón	Debajo del Umbral
MCD	-0.5647	-0.3211	-0.6884	-0.4245	-0.3928
FD	-0.3456	-0.0456	0.3355	-0.3622	-0.5963

Por lo tanto, se concluye que esta modificación en el modelo no se obtiene los resultados esperados que es una correlación de Pearson positiva, ya que a medida que el rango de incertidumbre la distancia entre las distribuciones también debería subir

7.1.1.2. Experimento de ruido estático

En este experimento se mantuvo la adición de ruido, sin embargo, este bajo una misma semilla con tal de generar la misma capa de ruido para todas las observaciones. En la Figura 29 y Figura 30 se presenta las distribuciones entre los datos esperados y los generados para MCD y FD para la partícula electrón respectivamente. Además, de igual forma en la Figura 31 y Figura 32, se presenta las curvas de fiabilidad entre la distancia Jensen-Shannon y la incertidumbre, además, en la Tabla 17 se muestra el coeficiente de relación entre estas dos variables mencionadas.




Figura 29. Puntajes de incertidumbre para MCD con ruido estático.






Figura 30. Puntajes de incertidumbre para FD con ruido estático.



MATPLOTLIB

Figura 31. Curvas de confiabilidad para MCD con ruido estático.



MATPLOTLIB

Figura 32. Curvas de confiabilidad para FD con ruido estático.

Tabla 17. Coeficientes de correlación de Pearson con ruido estático.


	Coeficientes de Correlación de Pearson				
Método	Electrón	Kaón	Muón	Protón	Debajo del Umbral
MCD	-0.8574	-0.9494	-0.7507	-0.7098	-0.2765
FD	0.5303	0.4630	0.5981	-0.01	-0.8555

Por lo tanto, tal como el método anterior no se llega a obtener el comportamiento deseado, a pesar de que FD para los últimos rangos de incertidumbre si aumenta su distancia.

7.1.1.3. Experimento de 30x30 iteraciones


En esta variación se busca realizar 30 iteraciones en el cálculo de la incertidumbre para cada modelo y buscar el promedio de estas iteraciones, sin embargo, se debe tomar en cuenta que para el caso de MCD se calcula la incertidumbre 30 iteraciones sobre el modelo con el *dropout* y otras 30 sin el *dropout*, con el fin de solo obtener solo el efecto del *dropout*.

Una vez obtenido este promedio de las 30 iteraciones, se repite ese proceso otras 30 veces para comprobar la variabilidad de en cada una de las partículas para cada modelo. En la Figura 33 y Figura 34 se presenta las distribuciones entre los datos esperados y los generados para MCD y FD para la partícula electrón respectivamente. Además, de igual forma en la Figura 35 y Figura 36, se presenta las curvas de fiabilidad entre la distancia Jensen-Shannon y la incertidumbre.




MATPLOTLIB

Figura 33. Puntajes de incertidumbre para MCD después de 30x30 iteraciones.




MATPLOTLIB

Figura 34. Puntajes de incertidumbre para FD después de 30x30 iteraciones.



MATPLOTLIB

Figura 35. Curvas de confiabilidad para MCD después de 30x30 iteraciones.




MATPLOTLIB

Figura 36. Curvas de confiabilidad para FD después de 30x30 iteraciones

Además, con tal de evidenciar la variabilidad de los modelos en la Tabla 18, se presenta el promedio de los coeficientes de correlación de Pearson de las 30 iteraciones finales, comparando además entre métricas como Jensen-Shannon Distance y Kolmogorov-Smirnov Test. A su vez, con tal de evidenciar de una manera más visual la dispersión por partícula se pueden visualizar la Figura 37, Figura 38, Figura 39, Figura 40 y Figura 41.


Tabla 18. Coeficientes de correlación de Pearson después de 30x30 iteraciones.

Coeficientes de Correlación de Pearson						
Método	Métrica	Electrón	Kaón	Muón	Protón	Debajo del Umbral
MCD	JS	0.9197 ± 0.0638	0.9563 ± 0.0090	0.6615 ± 0.3513	0.9886 ± 0.0048	0.7072 ± 0.3025
MCD	KS	0.9362 ± 0.0472	0.9621 ± 0.0078	0.6729 ± 0.3366	0.9837 ± 0.0073	0.5642 ± 0.3358
FD	JS	0.9790 ± 0.0013	0.9243 ± 0.0021	0.9700 ± 0.0032	0.7890 ± 0.0053	0.9039 ± 0.0180
FD	KS	0.8995 ± 0.0037	0.9200 ± 0.0021	0.8217 ± 0.0078	0.7900 ± 0.0032	0.7056 ± 0.0123




MATPLOTLIB

Figura 37. Resultado del coeficiente de Pearson para el experimento 30x30 iteraciones para la partícula electrón.




MATPLOTLIB

Figura 38. Resultado del coeficiente de Pearson para el experimento 30x30 iteraciones para la partícula kaón.



MATPLOTLIB

Figura 39. Resultado del coeficiente de Pearson para el experimento 30x30 iteraciones para la partícula muón.



MATPLOTLIB

Figura 40. Resultado del coeficiente de Pearson para el experimento 30x30 iteraciones para la partícula protón.




Figura 41. Resultado del coeficiente de Pearson para el experimento 30x30 iteraciones para la partícula por debajo del umbral.

Por lo tanto, se puede concluir que esta variación fue la que obtuvo el mejor resultado para ambos métodos, a pesar de los resultados tan similares, FD supera ligeramente a MCD por la poca variabilidad que este presenta.

7.1.2. Distancia entre distribuciones

Con tal de verificar el comportamiento presentado entre las distancias de las distribuciones generadas y reales, se implementaron las siguientes dos métricas:


7.1.2.1. Kolmogorov-Smirnov Test

La prueba de Kolmogorov-Smirnov es una prueba estadística no paramétrica utilizada para comparar una distribución empírica con una distribución de referencia, o para comparar dos distribuciones empíricas entre sí. Donde utilizamos el estadístico KS, el cual se define como la mayor diferencia entre las dos funciones de distribución acumulativa y representada como:

$$D_{n,m} = \sup_x |F_{1,n}(x) - F_{2,m}(x)|$$

Donde $F_{1,n}(x)$ es la CDF empírica de la primera muestra y $F_{2,m}(x)$ es la CDF empírica de la segunda muestra y $\sup_x$ indica el supremo, es decir, la máxima diferencia entre $F_{1,n}(x)$ y $F_{2,m}(x)$ para cualquier valor de x .

Con esta función se generó la Figura 42, que muestra la distancia de la distribución generada con respecto a su puntaje de incertidumbre para Feature Densities para cada partícula. Además, dicha figura mantiene un comportamiento muy similar a la métrica Jensen-Shannon, por lo cual, se utilizó en el Experimento de 30x30 iteraciones para realizar la comparación entre dichas métricas.



MATPLOTLIB


Figura 42. Curvas de confiabilidad de Feature Densities para Kolmogorov-Smirnov.

7.1.2.2. Earth Mover's Distance

Para la implementación de la métrica de Earth Mover's Distance (EMD) se utilizó la función “emd2_1d” de la biblioteca Python Optimal Transport, la cual recibe los datos de dos distribuciones y calcula la distancia entre estas usando la siguiente fórmula:

$$\gamma = \underset{\gamma}{\operatorname{argmin}} \sum_i \sum_j \gamma_{ij} d(x_a[i], x_b[j])$$

Con esta función se generó la Figura 43, que muestra la distancia de la distribución generada con respecto a su puntaje de incertidumbre para Feature Densities para cada partícula.



MATPLOTLIB

Figura 43. Curvas de confiabilidad de Feature Densities para EMD.

Debido a que las distancias obtenidas son muy cercanas a cero y que los coeficientes de Pearson disminuyeron sustancialmente con respecto a los obtenidos con Jensen-Shannon, se descarta el uso de Earth Mover's Distance como métrica para la distancia entre distribuciones para este experimento.

7.1.3. Mapas de calor

Con tal de evidenciar en cómo se distribuye la incertidumbre según sus parámetros de entrada, se realizaron mapas de calor entre el parámetro Eta y Momento, que también fueron divididos en 5 rangos por número de trazas. Los resultados de utilizados para generar estos mapas de calor son obtenidos del Experimento de 30x30 iteraciones.

En la Figura 44, se puede evidenciar el comportamiento para Features Densities y en el caso de Monte Carlo Dropout se puede analizar por partícula en la Figura 45, Figura 46, Figura 47, Figura 48 y Figura 49. Sin embargo, en el caso de MCD solo se utilizan 9 de los 10 cuantiles presentados en los histogramas ya que el décimo cuartil aumenta significativamente la escala, lo que afecta la correcta visualización del significado de los mapas de calor, por lo cual, la distribución de los datos varía según la partícula.




Figura 44. Mapa de calor según el puntaje de incertidumbre para FD.




Figura 45. Mapa de calor según el puntaje de incertidumbre de MCD para la partícula electrón.




Figura 46. Mapa de calor según el puntaje de incertidumbre de MCD para la partícula kaón.




Figura 47. Mapa de calor según el puntaje de incertidumbre de MCD para la partícula muón.




Figura 48. Mapa de calor según el puntaje de incertidumbre de MCD para la partícula protón.




Figura 49. Mapa de calor según el puntaje de incertidumbre de MCD para la partícula debajo del umbral.

7.1.4. Calibración del modelo

Para lograr una calibración óptima del modelo, se evaluarán distintos enfoques de configuración tanto para el método MCD como para el método de FD. En el caso de MCD, se probarán varios niveles de *dropout* para determinar el efecto de la variabilidad en la estimación de incertidumbre a través de las iteraciones. Para FD, se explorarán diferentes capas del modelo generativo, identificando aquellas que capturan mejor las distribuciones de las características relevantes. Estas pruebas permitirán ajustar el modelo con una calibración que optimice la precisión y consistencia en la predicción de la incertidumbre.

Para esto primero se hizo un análisis exploratorio de 5 distintos niveles de *dropout* para MCD y en el caso de FD se utilizaron las 5 capas que contempla el modelo y se seleccionaron las mejores 3 variables por método que obtuvieron mejor resultado. Sobre estas 3 mejores variables se aplicó sobre el Experimento de 30x30 iteraciones analizando sobre el coeficiente de correlación de Pearson del promedio de dichas iteraciones utilizando la distancia Jensen-Shannon, la nos muestra los resultados para MCD en la Tabla 19 y en la Tabla 20 para FD.

Tabla 19. Coeficientes de Correlación de Pearson con distintos niveles de dropout para MCD.

	Coeficientes de Correlación de Pearson				
Dropout	Electrón	Kaón	Muón	Protón	Debajo del Umbral
0.05	-0.3547	0.5366	0.7720	0.5135	0.4582
0.01	0.8721	0.9380	0.7780	0.9824	0.6501
0.1	0.9306	0.9072	0.9776	0.9834	0.7472

Tabla 20. Coeficiente de Correlación de Pearson con distintas capas del modelo para FD.

	Coeficientes de Correlación de Pearson				
Capa	Electrón	Kaón	Muón	Protón	Debajo del Umbral
1 (Primera)	0.9944	0.9795	0.9790	0.9289	0.8088
3 (Tercera)	0.9198	0.9672	0.9358	0.9477	0.9731
5 (Última)	0.9815	0.9394	0.9612	0.7657	0.7356

7.1.5. Optimización y Tiempos de Ejecución

Computacionalmente FD es menos exigente que MCD ya que el costo computacional por observación para FD viene dado por $O(r + d)$, donde r es el costo de evaluar la red neuronal y d el costo de evaluar d densidades. Mientras que MCD su costo viene dado por $O(r \times n)$, donde n , es el número de evaluaciones realizadas o también como tamaño del ensemble.

Sin embargo, la implementación de FD que se encontraba anteriormente se utilizaba KDE sobre los histogramas que nos dan las características de la capa utilizada al evaluar el *dataset*¹⁰ de entrenamiento sobre este nuevo modelo, sin embargo, debido a la cantidad de datos que cada histograma posee, el utilizar el histograma como función de densidad de probabilidad es una buena opción. Al realizar estas modificaciones, se obtuvo el siguiente resultado, que se puede ver en la Tabla 21.

¹⁰ Conjunto de datos estructurados utilizados para entrenar, validar o probar modelos

Tabla 21. Optimización de Features Densities

Método	Tiempo de ejecución en segundos
KDE	36.2274 ± 3.0094
Histogramas	0.5506 ± 0.0930

Por lo cual, realizada esta optimización se comprobará dicha afirmación, donde para evaluar los tiempos de ejecución de cada método, se realizarán 30 iteraciones sobre MCD como para FD. En cada iteración, se registrarán los tiempos individuales de procesamiento, lo que permitirá calcular el promedio y la desviación estándar de los tiempos.

Los experimentos de tiempo de ejecución fueron realizados en el entorno de Google Colab, utilizando una unidad de procesamiento gráfico (GPU) para acelerar el cálculo de incertidumbres. Aunque el uso de GPU reduce significativamente los tiempos de procesamiento en comparación con una CPU, existen limitaciones inherentes al entorno de Colab, tales como la variabilidad en el rendimiento de la GPU asignada, restricciones de memoria y limitaciones de tiempo de uso. Estos factores pueden ocasionar ligeras variaciones en los tiempos de ejecución entre diferentes sesiones, especialmente en experimentos repetidos o en cargas computacionales intensivas.

Mediante la Tabla 22 se puede observar el resultado obtenido después de las 30 iteraciones por método.

Tabla 22. Tiempos de ejecución para ambos métodos después de 30 iteraciones.


Método	Tiempo de ejecución en segundos
MCD	9.9370 ± 1.5575
FD	0.5506 ± 0.0930

7.2. Incertidumbre Aleatoria

7.2.1. Experimento de los cubos

Este experimento está relacionado con la incertidumbre aleatoria presente en los datos usados por el modelo, el cual busca ubicar y representar áreas donde se presente un rango de incertidumbre aleatoria constante por medio del cálculo de una desviación estándar.

Para esto se dividen los datos de acuerdo con el rango de valores de sus tres entradas, de modo que para cada entrada se definen cuatro rangos en los que van a ubicarse los datos, generando así 4^3 áreas o cubos de mismo tamaño. Luego de esto se realizan pequeños grupos o mini cubos de observaciones con un rango de entre 10 a 50 observaciones cada uno. Con estos datos se elaboró el siguiente gráfico para cada partícula, el cual permite observar la incertidumbre aleatoria de los datos:




MATPLOTLIB

Figura 50. Desviación estándar de los datos en cubos

Con la ayuda de estos gráficos es posible determinar los rangos de los resultados del modelo en los cuales se puede esperar que dichos resultados sean certeros y

presenten poca incertidumbre, como por ejemplo en el caso de que el momento sea menor a -2.6 se espera una baja incertidumbre, siendo útil para medir el desempeño del modelo.


Aquí se vuelve importante medir la diferencia entre la desviación estándar del modelo con respecto a la desviación estándar de los datos reales para lograr visualizar la incertidumbre, tanto epistémica como aleatoria, del modelo con respecto a los datos reales. Esto se puede apreciar en la Figura 51.



MATPLOTLIB


Figura 51. Diferencia entre la desviación estándar de los datos generados por el modelo y los datos reales utilizando cubos

Del mismo modo se utilizó este método de graficación para crear visualizaciones de la diferencia entre la media de los datos generados por el modelo y los datos reales, la incertidumbre de Feature densities y de Monte Carlo Dropout y la distancia de Jensen Shannon entre la distribución de los datos reales y la distribución de los datos generados por el modelo, los cuales corresponden a las Figura 52, Figura 53, Figura 54 y Figura 55 respectivamente.




MATPLOTLIB

Figura 52. Diferencia absoluta entre la media de los datos generados y los datos reales utilizando cubos




MATPLOTLIB

Figura 53. Puntajes de incertidumbre de Feature Densities en cubos



MATPLOTLIB

Figura 54. Puntajes de incertidumbre de Monte Carlo Dropout en cubos



MATPLOTLIB

Figura 55. Distancias de Jensen Shannon en cubos

8. Conclusiones y Recomendaciones

Tal como se definió anteriormente el objetivo general de esta investigación estaba dado como: Implementar un *benchmark* que permita la comparación de los métodos de estimación de incertidumbre, como Monte Carlo Dropout y Features Densities, utilizando el lenguaje de programación Python con la herramienta en línea de Google Colab, el cual fue completado por medio de la realización de cada uno de los siguientes objetivos específicos:

Modificar el *benchmark* de los resultados preliminares que compara la diferencia de las distribuciones, mapas de calor y gráficos de eficiencia por umbral entre FD y MCD.

Dicho objetivo específico estaba encargado principalmente del análisis de la Incertidumbre Epistémica. Para esto principalmente se modificó en cómo se agrupaban los *bins* para analizar la diferencia de las distribuciones, esto se modificó de realizarlos por rangos de incertidumbre a *bins* de igual tamaño para eliminar el error de muestreo en ciertos *bins*. Además, se trabajó en la variación del modelo para realizar una comparación más justa y efectiva entre ambos métodos y se realizaron modificaciones en la presentación de los mapas de calor para evidenciar el comportamiento a lo largo de las 3 variables de entrada y no solo 2, así como, utilizar solo los *bins* necesarios para generar estos mapas de calor y así comprender correctamente el comportamiento de MCD.

Además, los gráficos de eficiencia han sido evaluados con distintas variaciones del cálculo de estos, sin embargo, en ninguna de estas se llegó a obtener el comportamiento esperado, por lo cual, se tiene como prioridad para futuras iteraciones.

Diseñar un *benchmark* que permita la estimación de incertidumbre aleatoria inherente en los datos, por medio del experimento de los cubos.

Dicho diseño fue completado satisfactoriamente, los datos se dividen según los rangos de sus tres variables, estableciendo cuatro intervalos para cada una. Esto da lugar a un total de 4^3 áreas o cubos de igual tamaño. Posteriormente, dentro de cada cubo, se crean subgrupos o mini cubos con entre 10 y 50 observaciones en cada uno y se puede obtener la incertidumbre aleatoria.

Implementar un *benchmark* que permita la estimación de incertidumbre aleatoria inherente en los datos, por medio del experimento de los cubos.

Una vez completo el diseño anterior, se evaluó directamente sobre los datos reales para obtener solamente su incertidumbre aleatoria, además, se midió la diferencia entre la desviación estándar del modelo con respecto a la desviación estándar de los datos reales para lograr visualizar la incertidumbre, tanto epistémica como aleatoria, del modelo con respecto a los datos reales. Gracias a esta comparación se logró observar que la incertidumbre aleatoria presente en los datos se mantiene en los datos generados, además de que se correlaciona con la incertidumbre epistémica del modelo, al tener un patrón similar.

Implementar un *benchmark* para la estimación de confiabilidad de los cuantificadores de incertidumbre de Feature Densities y Monte Carlo Dropout utilizando los métodos de earth mover's distance y Kolmogorov-Smirnov Test.

Este objetivo fue perfectamente completado mediante la implementación de ambas métricas, sin embargo, a partir de esta implementación se determinó que la métrica earth mover's distance sancionaba con puntajes muy bajos en casos donde las distancias entre las distribuciones eran muy notables, por lo tanto, no se decidió seguir trabajando con esta métrica y solo utilizar la métrica Kolmogorov-Smirnov y realizar comparaciones con la ya utilizada, Jensen-Shannon distance.

Calibrar los modelos utilizados de Monte Carlo Dropout y Feature Densities, midiendo y optimizando sus tiempos de ejecución.

Este objetivo específico fue completado correctamente, para el cual, el primer lugar se hizo un proceso de calibración para ambos métodos, donde se buscó el mejor valor de *dropout* para MCD y la capa que más abstraía las características de las 5 partículas para FD, donde los mejores resultados se pueden observar en la Tabla 19 y Tabla 20.

Seguidamente, se trabajó principalmente en FD para su optimización, ya que computacionalmente debe ser menos exigente que MCD y fue comprobado mediante los tiempos de ejecución de 30 iteraciones del cálculo del puntaje de incertidumbre, comprobando que esto se cumplió en la Tabla 22.

Además, basados en la hipótesis establecida como: Nuestro método de estimación de incertidumbre (UE) propuesto y la métrica propuesta que utiliza Features Densities superan con significancia estadística la UE de un método y una métrica de última generación cuando se utilizan en simulaciones del conjunto de datos RICH con el modelo Cramér-GAN, podemos concluir que se cumple por las siguientes razones:

1. A pesar de tener resultados muy similares en los Coeficientes de Correlación de Pearson, como se ve en la Tabla 18, FD es menos variable para las partículas electrón, muón y todo lo que esté por debajo del umbral.
2. Tal como se afirmó la sección Optimización y Tiempos de Ejecución y por medio de la Tabla 22, FD es computacionalmente menos exigente que MCD.
3. El FD UE parece mostrar un crecimiento más estable en la métrica de confiabilidad como se ve en la Figura 36. Además, la correlación de Pearson, que se muestra en la Tabla 18, parece corroborar que la puntuación de incertidumbre crece a medida que crece el JSD para cada etiqueta de salida.
4. Una ventaja que tiene el método MCD sobre FD es que puede proporcionar un UE separado para cada variable de salida, mientras que FD solo puede proporcionar una puntuación de incertidumbre única para todas las salidas de una única observación de entrada.
5. Tal como se ve en la Tabla 20, según la capa que se utilice en FD se obtiene un mejor resultado con mucha diferencia en algunas partículas, por lo cual, el utilizar todas o más capas del modelo para obtener el puntaje daría un mejor resultado, ya que se estarían obteniendo las abstracciones de más capas, sin embargo, se debe tomar en cuenta que el tiempo computacional aumentaría.
6. Como se ve en la Figura 44, donde se presenta el mapa de calor para FD, este tiene sentido que a bajo momento, la incertidumbre tiende a ser menor, lo cual es consistente con la facilidad de identificación de partículas en este rango, donde los patrones son más claros y distinguibles. Además, a bajos valores de η , también se observa una menor incertidumbre debido a que estas regiones tienen menos ocupación, ya que esto facilita la identificación de partículas.

7. Tal como se mostró en los mapas de calor de MCD, para partículas de menor masa, como el electrón (0.5 MeV) y el muón (150 MeV), se observa que las regiones con mayor momento y pseudorapidez tienden a tener incertidumbres más bajas, ver Figura 45. Mapa de calor según el puntaje de incertidumbre de MCD para la partícula electrón. y Figura 47. En contraste, para partículas más masivas, como el kaón (497 MeV) y el protón (938 MeV), las incertidumbres menores se encuentran en las regiones con menor momento y pseudorapidez, ver Figura 46 y Figura 48.

8. Como se puede apreciar en la Figura 53, FD muestra un comportamiento mucho más estable y uniforme entre partículas al medir su incertidumbre que MCD, lo cual se aprecia en la Figura 54.

9. Al medir el error absoluto en la desviación estándar de los datos reales con respecto a los datos generados por el modelo, tal y como se muestra en la Figura 51, se puede apreciar que este último es capaz de reproducir y conservar la incertidumbre aleatoria presente en los datos.

10. Del mismo modo, cuando se compara la Figura 50 y Figura 51 que muestra la incertidumbre aleatoria en los datos, con la Figura 53 y la Figura 54, se puede apreciar como la incertidumbre aleatoria en los datos afecta la incertidumbre epistémica del modelo, las cuales presentan una forma similar, demostrando que existe una correlación entre estas dos y que deben ser calculas y estudiadas en conjunto.

Además, como recomendaciones:

1. En caso de que se quieran comparar la distancia entre distribuciones, se recomienda analizar con distintas métricas, ya que como se mencionó en la sección Earth Mover's Distance, esta métrica no penalizaba tanto las distancia entre las distribuciones, lo cual sí hacen Jensen-Shannon distance y Kolmogorov-Smirnov.

2. Se recomienda siempre almacenar respaldos de los resultados de los distintos métodos y variación realizada por cada método, con tal de entender y documentar cuales cambios o ajusten generan un mejor resultado. Además, de que estos permitan la reproducibilidad para replicar los experimentos.

3. En caso de utilizar un nuevo *dataset* para evaluar el modelo, se debe recordar que el proceso de calibración debe ser generado nuevamente para cada uno de los métodos de estimación de incertidumbre utilizados.

9. Glosario de términos.

A

ANN

Artificial Neural Network, 44

B

BNN

Bayesian Neural Network, 45, 46

C

CERN

European Organization for Nuclear Research, 13,
34, 35, 40

CONARE

Consejo Nacional de Rectores, 13, 36

D

DL

Deep Learning, 44, 45

F

FD

Features Densities, 16, 17, 18, 19, 26, 27, 30, 38,

G

GAN

Generative Adversarial Network, 1, 8, 11, 15, 17,
20, 30, 31, 32, 33, 34, 37, 38, 42, 43, 44

J

JSD

Jensen-Shannon Distance, 20

K

KDE

Kernel Density Estimation, 17

L

LHC

Large Hadron Collider, 11, 13, 15, 34, 41,

LHCb

LL

LLM

Large Language Model, 40

M

MCD

Monte Carlo Dropout, 16, 17, 18, 19, 21, 22, 23,
24, 25, 26, 28, 29, 30, 38,

O

OOD

Out of Distribution, 50

P

PARMA

Pattern Recognition and Machine Learning, 13,
35

PDF

Probability Density Function, 17

PID

Particle Identification System, 15, 40

R

RICH

Ring-imaging Cherenkov detector, 1, 8, 11, 13,
15, 33, 34, 37, 38, 40, 41, 42, 43,

S

SSDL

Semi-supervised Deep Learning, 50

U

UE

Uncertainty Estimation, 11, 15, 16, 19, 21, 22, 26,
29, 30, 31, 32, 33, 35, 36, 37, 38, 40,

10. Bibliografia

- [1]“The LHCb Simulation Project,” *Cern.ch*, 2021. Available: <https://lhcb-simulation.web.cern.ch/index.html>. [Accessed: Sep. 09, 2024]
- [2]L. Anderlini, C. Chimpoesh, N. Kazeev, A. Shishigina, and LHCb collaboration, “Generative models uncertainty estimation,” in *IOP Publishing*, 2023, p. 012088.
- [3]J. Mena, O. Pujol, and J. Vitrià, “A Survey on Uncertainty Estimation in Deep Learning Classification Systems from a Bayesian Perspective,” *ACM Computing Surveys*, vol. 54, Art. no. 9, Dec. 2022, doi: <https://doi.org/10.1145/3477140>. Available: <https://dl.acm.org/doi/10.1145/3477140>. [Accessed: Aug. 2023]
- [4]A. Mehrtash, W. M. Wells, C. M. Tempany, P. Abolmaesumi, and T. Kapur, “Confidence calibration and predictive uncertainty estimation for deep medical image segmentation,” *IEEE transactions on medical imaging*, vol. 39, Art. no. 12, 2020.
- [5]V. Kuleshov, N. Fenner, and S. Ermon, “Accurate uncertainties for deep learning using calibrated regression,” PMLR, 2018, pp. 2796–2804. Available: <https://proceedings.mlr.press/v80/kuleshov18a.html>. [Accessed: Oct. 2023]
- [6]I. J. Goodfellow *et al.*, “Generative adversarial networks,” 2014.
- [7]B. Lakshminarayanan, A. Pritzel, and C. Blundell, “Simple and scalable predictive uncertainty estimation using deep ensembles,” *Advances in neural information processing systems*, vol. 30, 2017.
- [8]N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov, “Dropout: a simple way to prevent neural networks from overfitting,” *The journal of machine learning research*, vol. 15, Art. no. 1, 2014.
- [9]L. Anderlini *et al.*, “Towards reliable neural generative modeling of detectors,” in *IOP Publishing*, 2023, p. 012130.
- [10]Y. Chen *et al.*, “Hallucination detection: Robustly discerning reliable answers in large language models,” Birmingham, United Kingdom: Association for Computing Machinery, 2023, pp. 245–255. doi: <https://doi.org/10.1145/3583780.3614905>. Available: <https://doi.org/10.1145/3583780.3614905>
- [11]Alves *et al.*, “The LHCb detector at the LHC,” *Journal of instrumentation*, vol. 3, Art. no. 08, 2008.

- [12]M. Adinolfi *et al.*, “Performance of the LHCb RICH detector at the LHC,” *The European Physical Journal C*, 2012, doi: <https://doi.org/10.48550/ARXIV.1211.6759>. Available: <https://arxiv.org/abs/1211.6759>. [Accessed: Sep. 2023]
- [13]M. Barbetti, “Lamarr: LHCb ultra-fast simulation based on machine learning models deployed within Gauss,” 2023.
- [14]S. Roiser and C. Bozzi, “The LHCb software and computing upgrade towards LHC run 3,” in *IOP Publishing*, 2018, p. 032049.
- [15]M. Clemencic *et al.*, “The LHCb simulation application, Gauss: design, evolution and experience,” in *IOP Publishing*, 2011, p. 032023.
- [16]A. Maevskiy, D. Derkach, N. Kazeev, A. Ustyuzhanin, M. Artemev, and L. Anderlini, “Fast data-driven simulation of cherenkov detectors using generative adversarial networks,” in *Journal of Physics: Conference Series*, IOP Publishing Ltd, Jul. 2020. doi: <https://doi.org/10.1088/1742-6596/1525/1/012097>
- [17]B. M. Bolotovskii, “Vavilov–Cherenkov radiation: its discovery and application,” *Physics-Uspekhi*, vol. 52, Art. no. 11, 2009.
- [18]M. G. Bellemare *et al.*, “The cramer distance as a solution to biased wasserstein gradients,” 2017.
- [19]A. Kendall and Y. Gal, “What Uncertainties Do We Need in Bayesian Deep Learning for Computer Vision?,” Curran Associates, Inc., 2017. Available: https://proceedings.neurips.cc/paper_files/paper/2017/hash/2650d6089a6d640c5e85b2b88265dc2b-Abstract.html. [Accessed: Oct. 2023]
- [20]D. J. MacKay, “A practical Bayesian framework for backpropagation networks,” *Neural computation*, vol. 4, Art. no. 3, 1992.
- [21]Y. Gal, “Uncertainty in deep learning,” PhD thesis, University of Cambridge, 2016.
- [22]Kiureghian, Armen Der and O. Ditlevsen, “Aleatory or epistemic? Does it matter?,” *Structural Safety*, vol. 31, Art. no. 2, Mar. 2009, doi: <https://doi.org/10.1016/j.strusafe.2008.06.020>. Available: <https://linkinghub.elsevier.com/retrieve/pii/S0167473008000556>. [Accessed: Oct. 2023]
- [23]Y. Gal and Z. Ghahramani, “Dropout as a bayesian approximation: Representing model uncertainty in deep learning,” New York, NY, USA: JMLR.org, 2016, pp. 1050–1059.
- [24]S. Calderon-Ramirez, S. Yang, D. Elizondo, and A. Moemeni, “Dealing with

distribution mismatch in semi-supervised deep learning for COVID-19 detection using chest X-ray images: A novel approach using feature densities,” *Applied Soft Computing*, vol. 123, p. 108983, 2022.


[25]L. Oala, C. Heiß, J. Macdonald, M. März, W. Samek, and G. Kutyniok, “Interval neural networks: Uncertainty scores,” Mar. 2020, arXiv:2003.11566. [Online]. Available: <http://arxiv.org/abs/2003.11566>

[26]“RICH detectors,” *Large Hadron Collider Beauty*. Available: <https://lhcb-outreach.web.cern.ch/detector/rich-detectors/>

[27]T. Lhcb *et al.*, “Performance of the LHCb RICH detector at the LHC LHCb RICH collaboration,” 2013.

[28]“The LHCb data flow — LHCb Starterkit Lessons documentation,” *Github.io*, 2015. Available: <https://lhcb.github.io/starterkit-lessons/first-analysis-steps/dataflow.html>.

11. Plan de trabajo.



12. Minutas, Informes de avance y Visitas de la empresa.

12.1. Semana 1



Minuta de Reunión 1

Información General	
Fecha: 24 de Julio del 2024	Hora: 12:30pm
Inicio: 12:35pm	Duración: 1h 30 minutos
Finalización: 2:05 pm	

Participantes	
Nombre Completo	Cargo
Ing. Eduardo Canessa	Profesor Asesor
José Alberto Arce Morales	Estudiante

Temas Tratados

1. Toda la documentación del curso de práctica debe ser realizada dentro del horario de clases.
2. Creación Google Drive un espacio para compartir información (con permisos de escritura para ecanessa@gmail.com)
3. Revisión de formato de minutas de reuniones, informes semanales, formato de visitas del profesor asesor a la empresa.

Compromisos Asumidos	
Descripción	Responsable
Creación de la carpeta en drive con acceso al profesor, además, agregar los datos de la empresa.	José Arce
Creación de la minuta de reunión e informe de avance de semana	José Arce
Creación e inicio del informe de avance 1	José Arce
Minutas Firmadas	Eduardo Canessa
Próxima Reunión	Lunes 29 de Julio del 2024

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
PERSONA FISICA, CPF-03-0338-0003.
Fecha declarada: 30/07/2024 05:33:42 PM
Razón: Documento aprobado
Lugar: San José Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa

Profesor Asesor



José Arce Morales
Estudiante

Informe de Avance Semanal 1

Nombre: José Alberto Arce Morales

Periodo del: 22 de Julio del 2024 al 29 de Julio del 2024

1. Actividades planeadas en este periodo:
 - a. Lectura de artículos y revisión de presentaciones sobre el avance hasta el momento de la investigación.
 - b. Eliminación del ruido generado por el modelo, para realizar comparaciones entre el modelo Features Densities y Monte Carlo Dropout.
2. Actividades realizadas en este periodo:
 - a. Se realizó la lectura y revisión de los artículos.
 - b. Se eliminó el ruido generado por el modelo para eliminar la aleatoriedad del experimento.
3. Actividades realizadas durante este periodo, que no estaban planeadas:
 - a. Avance del Informe I del curso de práctica.
4. Actividades que quedaron pendientes para el próximo periodo:
 - a. Ninguna.
5. Actividades por hacer el próximo periodo:
 - a. Actualizar los datos con los producidos con el modelo sin ruido.
 - b. Modificar la creación del gráfico de eficiencia por umbral, donde se evidencie también los datos esperados sobre los generados para visualizar su comportamiento.

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
PERSONA FISICA, CPF-03-0338-0003
Fecha declarada: 30/07/2024 05:38:26 PM
Razón: Documento aprobado
Lugar: San José Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa
Profesor Asesor



José Arce Morales
Estudiante

12.2. Semana 2



Minuta de Reunión 2

Información General	
Fecha: 30 de Julio del 2024	Hora: 5:30pm
Inicio: 5:30pm	Duración: 30 minutos
Finalización: 6:00pm	

Participantes	
Nombre Completo	Cargo
Ing. Eduardo Canessa	Profesor Asesor
José Alberto Arce Morales	Estudiante

Temas Tratados

1. Saludo.
2. Distribución de la carga de trabajo del informe 1 en 6 semanas.
3. Dar como prioridad a la sección de Descripción del Problema y Análisis de Riesgos.
4. Avance de la sección de descripción del problema para la siguiente semana.
5. Revisión del formato de la sección de riesgos.
6. Agendar reunión con supervisor para la sección de riesgos.

Compromisos Asumidos	
Descripción	Responsable
Creación de la distribución de la carga de trabajo para el primer informe	José Arce
Avance de la sección de descripción del problema para la siguiente semana.	José Arce
Agendar reunión con supervisor o compañeros de investigación para analizar los riesgos.	José Arce
Creación de la minuta de reunión e informe de avance de semana	José Arce
Creación e inicio del informe de avance 2	José Arce
Documentos Firmados	Eduardo Canessa
Próxima Reunión	Lunes 05 de Agosto del 2024

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
PERSONA FÍSICA, CPF-03-0338-0003
Fecha declarada: 05/08/2024 11:29:40 AM
Razón: Documento aprobado
Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa
Profesor Asesor

José Arce Morales
Estudiante

Informe de Avance Semanal 2

Nombre: José Alberto Arce Morales

Periodo del: 29 de Julio del 2024 al 05 de Agosto del 2024

1. Actividades planeadas en este periodo:
 - a. Actualizar los datos con los producidos con el modelo sin ruido.
 - b. Modificar la creación del gráfico de eficiencia por umbral, donde se evidencie también los datos esperados sobre los generados para visualizar su comportamiento.
2. Actividades realizadas en este periodo:
 - a. Actualizar los datos con los producidos con el modelo, se modificó de un modelo sin ruido a una serie de N iteraciones para agregarle la aleatoriedad en lugar de eliminar el ruido.
3. Actividades realizadas en este periodo, que no estaban planeadas:
 - a. Se modificó la prueba en lugar de eliminar el ruido, se realizaba una cantidad de N iteraciones y se promediaba las densidades obtenidas.
4. Actividades que quedaron pendientes para el próximo periodo:
 - a. Modificar la creación del gráfico de eficiencia por umbral, donde se evidencie también los datos esperados sobre los generados para visualizar su comportamiento.
5. Actividades por hacer el próximo periodo
 - a. Transformar las imágenes a .tex para ser agregadas al artículo.

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
PERSONA FISICA, CPF-03-0338-0003
Fecha declarada: 05/08/2024 11:13:36 AM
Razón: Documento aprobado
Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa

Profesor Asesor



José Arce Morales

Estudiante

12.3. Semana 3

En esta semana se realizó la primera visita de la empresa para José Arce.



Visita del Profesor Asesor #1

Información General	
Fecha: 8 de Agosto del 2024	Hora: 9:30 am
Inicio: 9:30 am	Duración: 40 minutos
Finalización: 10:10 am	

Tipo de Reunión	
☐ Presencial	☐ Telefónica
☒ Chat - Videoconferencia	☐ Otro Especifique:

Participantes	
Nombre Completo	Cargo
Ing. Eduardo Canessa	Profesor Asesor
Sergio Arguedas Cuendis	Supervisor
José Alberto Arce Morales	Estudiante

Temas Tratados

1. Saludo
2. Presentación de Sergio
3. Presentación de Eduardo
4. Importancia de documentar ideas.
5. Documentar siempre el código para generar algo que sea entendido por todos.
6. El tiempo para desarrollar los informes es dentro del asignado.
7. Recordatorio de las próximas 3 reuniones, son para revisar cada uno de los informes, en Semana 8, 12 y 16.
8. Se le recuerda al supervisor el método de evaluación al estudiante, por medio de un formulario por cada informe generado.

Compromisos Asumidos	
Descripción	Responsable
Visita firmada	Eduardo Canessa

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
 PERSONA FISICA, CPF-03-0338-0003.
 Fecha declarada: 13/08/2024 05:39:12 PM
 Razón: Documento aprobado
 Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa
 Profesor Asesor

José Arce Morales
 Estudiante

Minuta de Reunión 3

Información General	
Fecha: 5 de Agosto del 2024	Hora: 11:00 am
Inicio: 11:05 am	Duración: 1 hora 10 minutos
Finalización: 12:15 pm	

Participantes	
Nombre Completo	Cargo
Ing. Eduardo Canessa	Profesor Asesor
José Alberto Arce Morales	Estudiante

Temas Tratados

1. Saludo.
2. Indicó ser más explícito en las minutas, y se modificó la anterior.
3. Plan de trabajo del informe 1, modificar introducción al terminar cada sección.
4. La comunicación como parte crucial en caso de no tener avance de alguna sección, ser directo y comunicarlo lo antes posible.
5. Tener un plan en caso de existir feriados y demás, dándole siempre prioridad al informe.
6. Agregar el organigrama sobre el departamento que se trabaja del CERN.
7. Agregar la definición a conceptos del informe.
8. Modificar la sección de enunciado del problema, así como la de formulación.
9. En esta semana dar prioridad a la sección de objetivos y análisis de riesgos.

Compromisos Asumidos	
Descripción	Responsable
Solicitar el organigrama del departamento del CERN al supervisor	José Arce
Modificar la sección de enunciado del problema y formulación del problema	José Arce
Avance sobre la sección de objetivos y análisis de riesgos.	José Arce
Documentos Firmados	Eduardo Canessa
Próxima Reunión	12 de Agosto del 2024

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
PERSONA FÍSICA, CPF-03-0338-0003.
Fecha declarada: 13/08/2024 05:40:51 PM
Razón: Documento aprobado
Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa
Profesor Asesor


José Arce Morales
Estudiante

Informe de Avance Semanal 2

Nombre: José Alberto Arce Morales

Periodo del: 05 de Agosto del 2024 al 12 de Agosto del 2024

1. Actividades planeadas en este periodo:
 - a. Modificar la creación del gráfico de eficiencia por umbral, donde se evidencie también los datos esperados sobre los generados para visualizar su comportamiento.
 - b. Transformar las imágenes a .tex para ser agregadas al artículo.
2. Actividades realizadas en este periodo:
 - a. Modificar la creación del gráfico de eficiencia por umbral, donde se evidencie también los datos esperados sobre los generados para visualizar su comportamiento.
 - b. Transformar las imágenes a .tex para ser agregadas al artículo.
3. Actividades realizadas en este periodo, que no estaban planeadas:
 - a. Ninguna
4. Actividades que quedaron pendientes para el próximo periodo:
 - a. Ninguna
5. Actividades por hacer el próximo periodo
 - a. Modificar los valores de las variables de entradas a los originales para ser presentados en el mapa de calor de incertidumbre, además, de generar 3 gráficos, 1 por cada combinación de variables de entrada.

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
PERSONA FISICA, CPF-03-0338-0003.
Fecha declarada: 13/08/2024 05:43:11 PM
Razón: Documento aprobado
Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa

Profesor Asesor



José Arce Morales

Estudiante

12.4. Semana 4

A partir de esta semana David Pastor se unió al grupo de trabajo, por lo cual, se presentará una minuta de reunión general y el informe de avance semanal para José Arce y seguidamente el de David Pastor.



Minuta de Reunión 4

Información General	
Fecha: 13 de Agosto del 2024	Hora: 5:30 pm
Inicio: 5:35 pm	Duración: 1 hora
Finalización: 6:35 pm	

Participantes	
Nombre Completo	Cargo
Ing. Eduardo Canessa	Profesor Asesor
José Alberto Arce Morales	Estudiante

Temas Tratados

1. Saludo.
2. Agregar a las minutas un tracking de lo que se tiene informe, lo revisado y lo que se tiene por revisar.
3. Agendar reunión con el supervisor para tener el cronograma de actividades más detalladamente.
4. Agregar el plan de trabajo en la sección de apéndices.
5. Se conversó de la incorporación de David Pastor al equipo de trabajo, se habló de una nueva modalidad de reunión, ya que se trabajará sobre el mismo informe.
6. Finalizamos la revisión de la sección del contexto del problema, se deben agregar los objetivos cuando David se incorpore.
7. Para la siguiente reunión se abordará la sección de revisión de riesgos y contextualización del problema y marco conceptual.

Compromisos Asumidos	
Descripción	Responsable
Documentos Firmados	Eduardo Canessa
Agendar reunión con Sergio y Saúl para designar las actividades tanto de David, así como las mías.	José Arce
Avance sobre la sección de análisis de riesgos y contextualización del problema y marco contextual.	José Arce
Próxima Reunión	19 de Agosto del 2024

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
PERSONA FISICA, CPF-03-0338-0003
Fecha declarada: 19/08/2024 06:24:12 PM
Razón: Documento aprobado
Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa
Profesor Asesor



José Arce Morales
Estudiante

Informe de Avance Semanal 4

Nombre: José Alberto Arce Morales

Periodo del: 12 de Agosto del 2024 al 19 de Agosto del 2024

1. Actividades planeadas en este periodo:
 - a. Modificar los valores de las variables de entradas a los originales para ser presentados en el mapa de calor de incertidumbre, además, de generar 3 gráficos, 1 por cada combinación de variables de entrada.
2. Actividades realizadas en este periodo:
 - a. Se obtienen ya los valores reales de los datos para realizar los mapas de calor.
3. Actividades realizadas en este periodo, que no estaban planeadas:
 - a. Modificar los plots de eficiencia en lugar de realizar las cubetas por incertidumbre modificarlas a cuantiles.
4. Actividades que quedaron pendientes para el próximo periodo:
 - a. Generar los mapas de calor, ya se tiene sus unidades reales.
5. Actividades por hacer el próximo periodo:
 - a. Realizar los mapas de calor.
 - b. Ejemplificar por medio de las distribuciones y los gráficos de eficiencia porque esta no es una buena métrica.

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
PERSONA FÍSICA, CPF-03-0338-0003.
Fecha declarada: 19/08/2024 06:25:41 PM
Razón: Documento aprobado
Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa
Profesor Asesor


José Arce Morales
Estudiante

Informe de Avance Semanal 1

Nombre: Jonathan David Pastor Barrientos

Periodo del: 12 de agosto del 2024 al 19 de agosto del 2024

1. Actividades planeadas en este periodo:
 - a. Lectura de Artículos sobre la investigación realizada hasta el momento.
2. Actividades realizadas en este periodo:
 - a. Lectura de Artículos.
3. Actividades realizadas en este periodo, que no estaban planeadas:
 - a. Avance de informe 1 – marco conceptual.
4. Actividades que quedaron pendientes para el próximo periodo:
 - a. Ninguna.
5. Actividades por hacer el próximo periodo
 - a. Modificar el código de generación de gráficos de cubos para la distribución de entradas del modelo para que muestre correctamente los datos.
 - b. Optimización del código de generación de gráficos.

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
PERSONA FISICA, CPF-03-0338-0003
Fecha declarada: 26/08/2024 06:12:26 PM
Razón: Documento aprobado
Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa

Profesor Asesor



David Pastor Barrientos

Estudiante

12.5. Semana 5



Minuta de Reunión 5

Información General	
Fecha: 19 de Agosto del 2024	Hora: 6:00 pm
Inicio: 6:10 pm	Duración: 1 hora
Finalización: 7:00pm	

Participantes	
Nombre Completo	Cargo
Ing. Eduardo Canessa	Profesor Asesor
José Alberto Arce Morales	Estudiante
Jonathan David Pastor Barrientos	Estudiante

Temas Tratados


1. Saludo.
2. Presentar los informes en las fechas designadas, solo para el caso del último informe David amplía el informe final.
3. Se realizará una única minuta por reunión, sin embargo, el informe semanal si es de manera individual.
4. Agregar un consecutivo con las iniciales para los informes semanales para identificar cual es el de cada uno y se diferencie en el informe final.
5. Trabajar sobre el mismo Drive, cambiar el nombre y darle acceso a David.
6. Se converso acerca de la actualización sobre el avance semanal.
7. Se debe reevaluar sobre secciones de evasión y mitigación de los riesgos.
8. Realizar la matriz de evaluación de riesgos.
9. Medición de los objetivos en porcentaje.
10. Finalizar sobre la sección de contextualización y Marco conceptual.

Compromisos Asumidos	
Descripción	Responsable
Documentos Firmados	Eduardo Canessa
Reevaluar la sección de evasión y mitigación de los riesgos.	José Arce David Pastor
Medición de porcentajes	José Arce

	David Pastor
Finalizar sobre la sección de Contextualización y Marco Conceptual	José Arce David Pastor
Próxima Reunión	26 de Agosto del 2024

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
 PERSONA FISICA, CPF-03-0338-0003
 Fecha declarada: 26/08/2024 06:10:33 PM
 Razón: Documento aprobado
 Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa
 Profesor Asesor


 David Pastor
 Estudiante


 José Arce Morales
 Estudiante

Informe de Avance Semanal 5

Nombre: José Alberto Arce Morales

Periodo del: 19 de Agosto del 2024 al 26 de Agosto del 2024

1. Actividades planeadas en este periodo:
 - a. Realizar los mapas de calor.
 - b. Ejemplificar por medio de las distribuciones y los gráficos de eficiencia porque esta no es una buena métrica.
2. Actividades realizadas en este periodo:
 - a. Realizar los mapas de calor.
 - b. Ejemplificar por medio de las distribuciones y los gráficos de eficiencia porque esta no es una buena métrica.
3. Actividades realizadas en este periodo, que no estaban planeadas:
 - a. Creación de la presentación al CERN.
4. Actividades que quedaron pendientes para el próximo periodo:
 - a. Agregar los resultados de los experimentos sin ruido y con una semilla fija a la presentación.
 - b. Realizar los mapas de calor, pero promediando los puntos por bins.
5. Actividades por hacer el próximo periodo:
 - a. Finalizar la presentación.
 - b. Finalizar los mapas de calor, pero promediando los puntos por bins.
 - c. Redacción

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
PERSONA FISICA, CPF-03-0338-0003.
Fecha declarada: 26/08/2024 06:11:48 PM
Razón: Documento aprobado
Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa
Profesor Asesor



José Arce Morales
Estudiante

Informe de Avance Semanal 2

Nombre: Jonathan David Pastor Barrientos

Periodo del: 19 de agosto del 2024 al 26 de agosto del 2024

1. Actividades planeadas en este periodo:
 - a. Modificar el código de generación de gráficos de cubos para la distribución de entradas del modelo para que muestre correctamente los datos.
 - b. Optimización del código de generación de gráficos.
 - c. Avance de informe 1 – marco conceptual
2. Actividades realizadas en este periodo:
 - a. Modificar el código de generación de gráficos de cubos para la distribución de entradas del modelo para que muestre correctamente los datos.
 - b. Avance de informe 1 – marco conceptual
3. Actividades realizadas en este periodo, que no estaban planeadas:
 - a. Avance de informe sobre el experimento de los cubos
4. Actividades que quedaron pendientes para el próximo periodo:
 - a. Optimización del código de generación de gráficos.
5. Actividades por hacer el próximo periodo
 - a. Redacción de informe sobre el experimento de los cubos

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
PERSONA FISICA, CPF-03-0338-0003.
Fecha declarada: 26/08/2024 06:14:09 PM
Razón: Documento aprobado
Lugar: Heredia Contacto: edcanessa@tcr.ac.cr

Ing. Eduardo Canessa
Profesor Asesor



David Pastor Barrientos
Estudiante

12.6. Semana 6

En esta semana se hizo la primera visita a la empresa por parte de David Pastor.



Visita del profesor Asesor #1

Información General	
Fecha: 29 de Agosto del 2024	Hora: 9:30 am
Inicio: 9:40 am	Duración: 20 minutos
Finalización: 10:00 am	

Tipo de Reunión	
☐ Presencial	☐ Telefónica
☒ Chat - Videoconferencia	☐ Otro Especifique: _____

Participantes	
Nombre Completo	Cargo
Ing. Eduardo Canessa	Profesor Asesor
Saul Calderón Ramírez	Supervisor
Jonathan David Pastor Barrientos	Estudiante

Temas Tratados

1. Saludo.
2. Agradecimiento por la oportunidad que se le da al estudiante para realizar la práctica.
3. Se recuerda el cronograma del estudiante, este se encuentra en semana 3 y se deben realizar las presentaciones de los informes a entregar en semana 8, 12 y 16.
4. Se específico el contenido general que debe incluir cada informe, el primer informe constituye un marco conceptual del proyecto, el segundo informe se discute el diseño usado y el tercer informe concluye el proyecto desarrollado.
5. Se define que el estudiante debe enviar el formulario de evaluación de informe al supervisor una semana antes de la presentación del informe correspondiente, a su vez dicha evaluación cierra con la presentación del informe.
6. El profesor no juzgará la nota que ponga el supervisor de la empresa, cada uno realizará su evaluación individual que definirá la nota del estudiante para cada informe.
7. Se recordó la importancia de tener canales abiertos tanto con el profesor asesor como con el supervisor de la empresa, ya que si algo pasa deben ser los primeros en enterarse.
8. Recordatorio al estudiante de leer bastante acerca del estado del arte del área que se está investigando con el fin de entender bien el problema y ser proactivo con el desarrollo de la investigación.

Compromisos Asumidos	
Descripción	Responsable
Visita firmada	Eduardo Canessa

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
PERSONA FISICA, CPF-03-0338-0003
Fecha declarada: 09/09/2024 05:59:55 PM
Razón: Documento aprobado
Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa
Profesor Asesor

David Pastor Barrientos
Estudiante

Minuta de Reunión 6

Información General	
Fecha: 26 de Agosto del 2024	Hora: 6:00 pm
Inicio: 6:05 pm	Duración: 1 hora
Finalización: 7:05 pm	

Participantes	
Nombre Completo	Cargo
Ing. Eduardo Canessa	Profesor Asesor
José Alberto Arce Morales	Estudiante
Jonathan David Pastor Barrientos	Estudiante

Temas Tratados

1. Saludo.
2. Revisando los informes semanales, Eduardo mencionó la importancia de plasmar en estos informes cualquier avance o logro que se realice en la semana.
3. Se revisaron los riesgos del proyecto, junto con su clasificación en la matriz de evaluación de riesgos.
4. Se explicó el método para realizar el análisis de exposición de riesgos, junto con la información que debe incluir los comentarios de los riesgos.
5. Se especificó el formato de la matriz de evaluación de riesgos.
6. Se revisó la descripción del problema, se mencionó la información que hace falta en esta sección.
7. Se leyó la contextualización del problema y marco conceptual hasta la sección de incertidumbre epistémica.

Compromisos Asumidos	
Descripción	Responsable
Documentos Firmados	Eduardo Canessa
Realizar análisis de exposición de riesgos	José Arce David Pastor
Reunirse con los asesores para discutir riesgos propuestos	José Arce David Pastor
Añadir a la descripción del problema los objetivos del proyecto de David	David Pastor
Próxima Reunión	2 de Septiembre del 2024

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
PERSONA FÍSICA, CPF-03-0338-0003
Fecha declarada: 02/09/2024 06:02:23 PM
Razón: Documento aprobado
Lugar: Heredia, Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa
Profesor Asesor


José Arce Morales
Estudiante


David Pastor Barrientos
Estudiante

Informe de Avance Semanal 6

Nombre: José Alberto Arce Morales

Periodo del: 26 de Agosto del 2024 al 2 de Septiembre del 2024

1. Actividades planeadas en este periodo:
 - a. Finalizar la presentación.
 - b. Finalizar los mapas de calor, pero promediando los puntos por bins.
 - c. Redacción de la sección de experimentos realizados del artículo.
2. Actividades realizadas en este periodo:
 - a. Finalizar la presentación.
 - b. Finalizar los mapas de calor, pero promediando los puntos por bins.
 - c. Inicio del análisis de conjuntos por bins, mediante ANOVA.
3. Actividades realizadas en este periodo, que no estaban planeadas:
 - a. Cambio en los plots de eficiencia, agregarle la desviación estándar por bin.
 - b. Cambio en los heatmaps, realizar diferentes gráficas por número de tracks.
 - c. Análisis de cada uno de los conjuntos por bins mediante ANOVA.
4. Actividades que quedaron pendientes para el próximo periodo:
 - a. Finalizar el análisis mediante ANOVA.
 - b. Cambio en los heatmaps, realizar diferentes gráficas por número de tracks.
 - c. Redacción de la sección de experimentos realizados del artículo.
5. Actividades por hacer el próximo periodo
 - a. Generar los cambios de plots de eficiencia, heatmaps y el análisis de ANOVA y agregarlos a la presentación al grupo de simulación.
 - b. Finalizar los mapas de calor, pero promediando los puntos por bins.
 - c. Redacción Redacción de la sección de experimentos realizados del artículo.

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
PERSONA FISICA, CPF-03-0338-0003.
Fecha declarada: 02/09/2024 06:08:28 PM
Razón: Documento aprobado
Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa
Profesor Asesor



José Arce Morales
Estudiante

Informe de Avance Semanal 3

Nombre: Jonathan David Pastor Barrientos

Periodo del: 26 de Agosto del 2024 al 02 de Septiembre del 2024

1. Actividades planeadas en este periodo:
 - a. Redacción de informe sobre el experimento de los cubos.
 - b. Optimización del código de generación de gráficos.
2. Actividades realizadas en este periodo:
 - a. Redacción de informe sobre el experimento de los cubos.
 - b. Optimización del código de generación de gráficos.
3. Actividades realizadas en este periodo, que no estaban planeadas:
 - a. Búsqueda de artículos sobre earth mover's distance
4. Actividades que quedaron pendientes para el próximo periodo:
 - a. Ninguna
5. Actividades por hacer el próximo periodo:
 - a. Investigación sobre earth mover's distance

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
PERSONA FISICA, CPF-03-0338-0003
Fecha declarada: 02/09/2024 06:05:30 PM
Razón: Documento aprobado
Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa
Profesor Asesor



David Pastor Barrientos
Estudiante

12.7. Semana 7



Minuta de Reunión 7

Información General	
Fecha: 2 de Septiembre del 2024	Hora: 6:00 pm
Inicio: 6:00 pm	Duración: 1 hora
Finalización: 7:00pm	

Participantes	
Nombre Completo	Cargo
Ing. Eduardo Canessa	Profesor Asesor
José Alberto Arce Morales	Estudiante
Jonathan David Pastor Barrientos	Estudiante

Temas Tratados

1. Saludo.
2. Se discutió el avance general de la semana de cada uno, además, se mostró la presentación que se realizó el pasado jueves, en la reunión con Lucio.
3. Se finalizó la revisión de la sección de riesgos.
4. Verificar del contexto del problema que podría ampliar David.
5. Finalizar las secciones restantes del documento.
6. Se indicaron las secciones más importantes de la presentación:
 - a. Portada
 - b. Introducción, se debe hablar sobre el CERN en la unidad en la que se realiza y los antecedentes del proyecto
 - c. Descripción del problema
 - d. Tipo de investigación, Formulación y objetivos.
 - e. Contextualización del problema, mencionar los puntos que se crear más importantes
 - f. Matriz de inicio y de primer informe de los riesgos, presentar sobre el que más se trabajó.
 - g. Muestra del trabajo realizado y un resumen de los resultados obtenidos.

Compromisos Asumidos	
Descripción	Responsable
Documentos Firmados	Eduardo Canessa
Finalizar la sección de introducción y glosario.	José Arce David Pastor
Iniciar la presentación con las secciones mencionas.	José Arce David Pastor
Próxima Reunión	9 de Septiembre de 2024

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
 PERSONA FISICA, CPF-03-0338-0003.
 Fecha declarada: 09/09/2024 05:58:19 PM
 Razón: Documento aprobado
 Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa
 Profesor Asesor


 David Pastor
 Estudiante


 José Arce Morales
 Estudiante

Informe de Avance Semanal 7

Nombre: José Alberto Arce Morales

Periodo del: 2 de Septiembre del 2024 al 9 de Septiembre del 2024

1. Actividades planeadas en este periodo:
 - a. Generar los cambios de plots de eficiencia, heatmaps y el análisis de ANOVA y agregarlos a la presentación al grupo de simulación.
 - b. Finalizar los mapas de calor, pero promediando los puntos por bins.
 - c. Redacción de la sección de experimentos realizados del artículo.
2. Actividades realizadas en este periodo:
 - a. Generar los cambios de plots de eficiencia, heatmaps y el análisis de ANOVA y agregarlos a la presentación al grupo de simulación.
 - b. Finalizar los mapas de calor, pero promediando los puntos por bins.
3. Actividades realizadas en este periodo, que no estaban planeadas:
 - a. Ninguna.
4. Actividades que quedaron pendientes para el próximo periodo:
 - a. Redacción de la sección de experimentos realizados del artículo.
5. Actividades por hacer el próximo periodo
 - a. Redacción de la sección de experimentos realizados del artículo.
 - b. Generar los plot de los heatmaps vectorizados y agregarlos al artículo.

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
PERSONA FÍSICA, CPF-03-0338-0003.
Fecha declarada: 09/09/2024 06:01:43 PM
Razón: Documento aprobado
Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa
Profesor Asesor


José Arce Morales
Estudiante

Informe de Avance Semanal 4

Nombre: Jonathan David Pastor Barrientos

Periodo del: 02 de Septiembre del 2024 al 09 de Septiembre del 2024

1. Actividades planeadas en este periodo:
 - a. Investigación sobre earth mover's distance
2. Actividades realizadas en este periodo:
 - a. Investigación sobre earth mover's distance
3. Actividades realizadas en este periodo, que no estaban planeadas:
 - a. Ninguna
4. Actividades que quedaron pendientes para el próximo periodo:
 - a. Ninguna
5. Actividades por hacer el próximo periodo
 - a. Implementación de earth mover's distance para comparar MC dropout con Feature densities

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
PERSONA FÍSICA, CPF-03-0338-0003
Fecha declarada: 09/09/2024 06:02:26 PM
Razón: Documento aprobado
Lugar: Heredia Contacto: edcanessa@tcr.ac.cr

Ing. Eduardo Canessa

Profesor Asesor



David Pastor Barrientos

Estudiante

12.8. Semana 8



Minuta de Reunión 8

Información General	
Fecha: 9 de Septiembre del 2024	Hora: 6:00 pm
Inicio: 6:00 pm	Duración: 30 minutos
Finalización: 6:30 pm	

Participantes	
Nombre Completo	Cargo
Ing. Eduardo Canessa	Profesor Asesor
José Alberto Arce Morales	Estudiante
Jonathan David Pastor Barrientos	Estudiante

Temas Tratados

1. Saludo.
2. Se mencionaron los avances semanales de cada estudiante.
3. Se revisó la introducción del primer informe.
4. Se revisó la portada del primer informe.
5. Se revisó la presentación del primer informe.
6. Se explicó los contenidos que se deben agregar para el segundo informe.
7. Se recordaron las semanas en las que se debe entregar y presentar cada informe.
8. Aclaración de que existe la posibilidad de enviar los informes al asesor antes de la fecha asignada para una revisión preliminar antes de entregar la versión final.
9. El profesor aconsejó a los estudiantes usar el mismo formato para presentar resultados.
10. Recordatorio de que los informes deben ir según el formato de la biblioteca.

Compromisos Asumidos	
Descripción	Responsable
Documentos Firmados	Eduardo Canessa
Empezar el segundo informe	José Arce David Pastor
Finalizar la presentación del primer informe	José Arce David Pastor
Próxima Reunión	16 de Septiembre del 2024

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
 PERSONA FÍSICA, CPF-03-0338-0003.
 Fecha declarada: 16/09/2024 06:17:49 PM
 Razón: Documento aprobado
 Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa
 Profesor Asesor


 José Arce Morales
 Estudiante


 David Pastor Barrientos
 Estudiante

Informe de Avance Semanal 8

Nombre: José Alberto Arce Morales

Periodo del: 9 de Septiembre del 2024 al 16 de Septiembre del 2024

1. Actividades planeadas en este periodo:
 - a. Redacción de la sección de experimentos realizados del artículo.
 - b. Generar los plot de los heatmaps vectorizados y agregarlos al artículo.
2. Actividades realizadas en este periodo:
 - a. Redacción de la sección de experimentos realizados del artículo.
 - b. Generación de los plots de heatmaps vectorizados.
3. Actividades realizadas en este periodo, que no estaban planeadas:
 - a. Modificación en el cálculo de la eficiencia.
4. Actividades que quedaron pendientes para el próximo periodo:
 - a. Consultar cuales de los gráficos de los heatmaps son los más representativos para agregarlos al artículo.
5. Actividades por hacer el próximo periodo
 - a. Agregar a la sección de experimentos del artículo también los resultados del ejecutarlo con una semilla fija y eliminar la variación con ruido cero.
 - b. Verificar el modo en cual está el modelo a la hora de realizar el Monte Carlo Dropout y modificarlo en caso de que este esté erróneo.

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
PERSONA FISICA, CPF-03-0338-0003.
Fecha declarada: 16/09/2024 06:16:24 PM
Razón: Documento aprobado
Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa
Profesor Asesor


José Arce Morales
Estudiante

Informe de Avance Semanal 5

Nombre: Jonathan David Pastor Barrientos

Periodo del: 09 de Septiembre del 2024 al 16 de Septiembre del 2024

1. Actividades planeadas en este periodo:
 - a. Implementación de earth mover's distance para comparar MC dropout con Feature densities
2. Actividades realizadas en este periodo:
 - a. Implementación de earth mover's distance para comparar MC dropout con Feature densities
3. Actividades realizadas en este periodo, que no estaban planeadas:
 - a. Avance en la redacción del artículo
4. Actividades que quedaron pendientes para el próximo periodo:
 - a. Ninguna
5. Actividades por hacer el próximo periodo
 - a. Implementación del experimento de los cubos utilizando los resultados generados por el modelo.

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
PERSONA FISICA, CPF-03-0338-0003.
Fecha declarada: 16/09/2024 06:17:04 PM
Razón: Documento aprobado
Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa
Profesor Asesor



David Pastor Barrientos
Estudiante

12.9. Semana 9

En esta semana se realizó la revisión del primer informe para José Arce.



Visita del Profesor Asesor #2

Información General	
Fecha: 19 de Setiembre del 2024	Hora: 10:00 am
Inicio: 10:00 am	Duración: 30 minutos
Finalización: 10:30 am	

Tipo de Reunión	
☐ Presencial	☐ Telefónica
☒ Chat - Videoconferencia	☐ Otro Especifique:

Participantes	
Nombre Completo	Cargo
Ing. Eduardo Canessa	Profesor Asesor
Sergio Arguedas Cuendis	Supervisor
José Alberto Arce Morales	Estudiante

Temas Tratados

1. Saludo.
2. Se realizó la presentación del primer informe por parte de José Arce.
3. Se realiza una sección de preguntas y dudas con respecto a la presentación.
4. Se recuerda al supervisor la evaluación por medio de la rúbrica enviada.
5. Y se recuerda el cronograma de las próximas dos presentaciones en semana 12 y 16.

Compromisos Asumidos	
Descripción	Responsable
Visita firmada	Eduardo Canessa

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
 PERSONA FISICA, CPF-03-0338-0003.
 Fecha declarada: 23/09/2024 06:02:39 PM
 Razón: Documento aprobado
 Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa
 Profesor Asesor


 José Arce Morales
 Estudiante

Minuta de Reunión 9

Información General	
Fecha: 16 de Septiembre del 2024	Hora: 6:00 pm
Inicio: 6:00 pm	Duración: 1 hora
Finalización: 7:00pm	

Participantes	
Nombre Completo	Cargo
Ing. Eduardo Canessa	Profesor Asesor
José Alberto Arce Morales	Estudiante
Jonathan David Pastor Barrientos	Estudiante

Temas Tratados


1. Saludo.
2. Se discutió el avance general de la semana de cada uno.
3. Se determinó que para el primer informe de David Pastor ampliar sobre conceptos que sean necesarios y aún no estén aún en la sección de contextualización y marco conceptual.
4. Se revisó nuevamente el formato de los próximos dos informes y se determinó que la sección de metodología de la investigación y resultados deben ir después de la contextualización.
5. Se verificó la presentación del primer informe de José Arce que será presentada el jueves a la contraparte.
6. Se revisó el avance sobre la sección de metodología y ubicación temporal de metodología de investigación y se queda a la espera de la información por parte de la contraparte para trabajar sobre las siguientes secciones.

Compromisos Asumidos	
Descripción	Responsable
Documentos Firmados	Eduardo Canessa
Agregar a la contextualización los conceptos que sean necesarios y no hayan sido abarcados.	David Pastor

Agregar las secciones del informe dos sobre el documento que ya se tenía.	José Arce David Pastor
Continuar con la sección de metodología de investigación.	José Arce David Pastor
Próxima Reunión	23 de Septiembre de 2024

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
PERSONA FÍSICA, CPF-03-0338-0003.
Fecha declarada: 23/09/2024 06:03:44 PM
Razón: Documento aprobado
Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa
Profesor Asesor


David Pastor
Estudiante


José Arce Morales
Estudiante

Informe de Avance Semanal 9

Nombre: José Alberto Arce Morales

Periodo del: 16 de Septiembre del 2024 al 23 de Septiembre del 2024

1. Actividades planeadas en este periodo:
 - a. Agregar a la sección de experimentos del artículo también los resultados del ejecutarlo con una semilla fija y eliminar la variación con ruido cero.
 - b. Verificar el modo en cual está el modelo a la hora de realizar el Monte Carlo Dropout y modificarlo en caso de que este esté erróneo.
2. Actividades realizadas en este periodo:
 - a. Agregar a la sección de experimentos del artículo también los resultados del ejecutarlo con una semilla fija y eliminar la variación con ruido cero.
 - b. Verificar el modo en cual está el modelo a la hora de realizar el Monte Carlo Dropout y modificarlo en caso de que este esté erróneo.
3. Actividades realizadas en este periodo, que no estaban planeadas:
 - a. Modificación en el cálculo del MCD.
4. Actividades que quedaron pendientes para el próximo periodo:
 - a. Ninguna.
5. Actividades por hacer el próximo periodo:
 - a. Modificación en el cálculo de la eficiencia
 - b. Continuar y modificar con la sección de experimentos del artículo

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
PERSONA FÍSICA, CPF-03-0338-0003.
Fecha declarada: 23/09/2024 06:05:35 PM
Razón: Documento aprobado
Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa
Profesor Asesor



José Arce Morales
Estudiante

Informe de Avance Semanal 6

Nombre: Jonathan David Pastor Barrientos

Periodo del: 16 de Septiembre del 2024 al 23 de Septiembre del 2024

1. Actividades planeadas en este periodo:
 - a. Implementación del experimento de los cubos utilizando los resultados generados por el modelo.
2. Actividades realizadas en este periodo:
 - a. Implementación del experimento de los cubos utilizando los resultados generados por el modelo.
3. Actividades realizadas en este periodo, que no estaban planeadas:
 - a. Avanzar con la redacción del artículo
4. Actividades que quedaron pendientes para el próximo periodo:
 - a. Ninguna
5. Actividades por hacer el próximo periodo:
 - a. Avanzar con la redacción del artículo

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
PERSONA FISICA, CPF-03-0338-0003.
Fecha declarada: 23/09/2024 06:04:47 PM
Razón: Documento aprobado
Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa
Profesor Asesor



David Pastor Barrientos
Estudiante

Minuta de Reunión 10

Información General	
Fecha: 23 de Septiembre del 2024	Hora: 6:00 pm
Inicio: 6:00 pm	Duración: 45 minutos
Finalización: 6:45 pm	

Participantes	
Nombre Completo	Cargo
Ing. Eduardo Canessa	Profesor Asesor
José Alberto Arce Morales	Estudiante
Jonathan David Pastor Barrientos	Estudiante

Temas Tratados

1. Saludo.
2. Se mencionaron los avances semanales de cada estudiante.
3. Se mencionaron los días y horas en las que el profesor tiene disponibilidad para realizar visitas a la empresa.
4. Se revisaron los cambios realizados en el primer informe por parte de David, que incluyen las secciones de introducción, objetivos y marco conceptual.
5. Se revisaron los avances realizados en el segundo informe con respecto a la sección de metodología de la investigación.


Compromisos Asumidos	
Descripción	Responsable
Documentos Firmados	Eduardo Canessa
Trabajar la sección de resultados del segundo informe	José Arce David Pastor
Finalizar la presentación del primer informe	David Pastor
Coordinar la visita a la empresa para la revisión del primer informe	David Pastor
Próxima Reunión	30 de Septiembre del 2024

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
 PERSONA FÍSICA, CPF-03-0338-0003.
 Fecha declarada: 30/09/2024 06:15:44 PM
 Razón: Documento aprobado
 Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa
 Profesor Asesor



José Arce Morales
 Estudiante



David Pastor Barrientos
 Estudiante

Informe de Avance Semanal 10

Nombre: José Alberto Arce Morales

Periodo del: 23 de Septiembre del 2024 al 30 de Septiembre del 2024

1. Actividades planeadas en este periodo:
 - a. Modificación en el cálculo de la eficiencia
 - b. Continuar y modificar con la sección de experimentos del artículo
2. Actividades realizadas en este periodo:
 - a. Modificación en el cálculo de la eficiencia
 - b. Modificación con la sección de experimentos del artículo
3. Actividades realizadas en este periodo, que no estaban planeadas:
 - a. Modificación en el cálculo del MCD, realizarlo por 30 iteraciones también.
4. Actividades que quedaron pendientes para el próximo periodo:
 - a. Ninguna.
5. Actividades por hacer el próximo periodo
 - a. Continuar y modificar con la sección de experimentos del artículo.

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
PERSONA FISICA, CPF-03-0338-0003.
Fecha declarada: 30/09/2024 06:13:21 PM
Razón: Documento aprobado
Lugar: Heredia Contacto: edcanessa@tcr.ac.cr

Ing. Eduardo Canessa

Profesor Asesor



José Arce Morales

Estudiante

Informe de Avance Semanal 7

Nombre: Jonathan David Pastor Barrientos

Periodo del: 23 de Septiembre del 2024 al 30 de Septiembre del 2024

1. Actividades planeadas en este periodo:
 - a. Avanzar con la redacción del artículo
2. Actividades realizadas en este periodo:
 - a. Avanzar con la redacción del artículo
3. Actividades realizadas en este periodo, que no estaban planeadas:
 - a. Ninguna
4. Actividades que quedaron pendientes para el próximo periodo:
 - a. Ninguna
5. Actividades por hacer el próximo periodo
 - a. Avanzar con la redacción del artículo
 - b. Correr el experimento de los cubos con los datos originales

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
PERSONA FISICA, CPF-03-0338-0003.
Fecha declarada: 30/09/2024 06:14:46 PM
Razón: Documento aprobado
Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa

Profesor Asesor



David Pastor Barrientos

Estudiante

12.11. Semana 11

En esta semana se realizó la revisión del primer informe para David Pastor.



Visita del profesor Asesor #2

Información General	
Fecha: 03 de Octubre del 2024	Hora: 9:30 am
Inicio: 9:30 am	Duración: 50 minutos
Finalización: 10:20 am	

Tipo de Reunión	
☐ Presencial	☐ Telefónica
☒ Chat - Videoconferencia	☐ Otro Especifique: _____

Participantes	
Nombre Completo	Cargo
Ing. Eduardo Canessa	Profesor Asesor
Saul Calderón Ramírez	Supervisor
Sergio Arguedas Cuendis	Supervisor
Jonathan David Pastor Barrientos	Estudiante

Temas Tratados

1. Saludo.
2. Presentación del primer informe por parte de David Pastor
3. Preguntas, comentarios y dudas respecto a la presentación por parte de los supervisores
4. Recordatorio de las fechas para las presentaciones en semana 12 y semana 16

Compromisos Asumidos	
Descripción	Responsable
Visita firmada	Eduardo Canessa

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
 PERSONA FÍSICA, CPF-03-0338-0003.
 Fecha declarada: 07/10/2024 06:10:44 p. m.
 Razón: Documento aprobado
 Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa
 Profesor Asesor

David Pastor Barrientos
 Estudiante

Minuta de Reunión 11

Información General	
Fecha: 30 de Septiembre del 2024	Hora: 6:00 pm
Inicio: 6:05 pm	Duración: 45 minutos
Finalización: 6:45pm	

Participantes	
Nombre Completo	Cargo
Ing. Eduardo Canessa	Profesor Asesor
José Alberto Arce Morales	Estudiante
Jonathan David Pastor Barrientos	Estudiante

Temas Tratados

1. Saludo.
2. Se discutió el avance general de la semana de cada uno.
3. Se determinó hacer la presentación del informe 2 de José Arce en semana 13.
4. Se revisó completamente la sección de resultados, falta revisar un par de secciones que serán agregadas.
5. Recordar a la contraparte la información para finalizar la sección de metodología de la investigación.

Compromisos Asumidos	
Descripción	Responsable
Documentos Firmados	Eduardo Canessa
Agendar la reunión para el informe 2 con la contraparte	José Arce
Finalizar la sección de resultados.	José Arce David Pastor
Solicitar la información restante de la sección de metodología de investigación.	José Arce David Pastor
Próxima Reunión	07 de Octubre de 2024

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
PERSONA FISICA. CPF-03-0338-0003.
Fecha declarada: 07/10/2024 06:14:26 p. m.
Razón: Documento aprobado
Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa
Profesor Asesor



David Pastor
Estudiante



José Arce Morales
Estudiante

Informe de Avance Semanal 11

Nombre: José Alberto Arce Morales

Periodo del: 30 de Septiembre del 2024 al 07 de Octubre del 2024

1. Actividades planeadas en este periodo:
 - a. Continuar y modificar con la sección de experimentos del artículo.
2. Actividades realizadas en este periodo:
 - a. Modificación la sección de experimentos del artículo según los cambios a la hora de hacer los cambios de 30x30 iteraciones para MCD y FD
3. Actividades realizadas en este periodo, que no estaban planeadas:
 - a. Agregar resultados a presentación previa que va a ser presentada en el CERN.
 - b. Modificación en los heatmaps para utilizar solo los primeros 9 quantiles en el caso de MCD.
 - c. Modificar el cálculo de la incertidumbre tanto para MCD y FD en 30x30 iteraciones y calcular la covarianza de método.
4. Actividades que quedaron pendientes para el próximo periodo:
 - a. Ninguna.
5. Actividades por hacer el próximo periodo:
 - a. Trasladar todos los nuevos resultados de las 30x30 iteraciones al artículo.

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
PERSONA FÍSICA, CPF-03-0338-0003.
Fecha declarada: 07/10/2024 06:12:52 p. m.
Razón: Documento aprobado
Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa
Profesor Asesor



José Arce Morales
Estudiante

Informe de Avance Semanal 8

Nombre: Jonathan David Pastor Barrientos

Periodo del: 30 de Septiembre del 2024 al 7 de Octubre del 2024

1. Actividades planeadas en este periodo:
 - a. Avanzar con la sección del estado del arte del artículo
 - b. Correr el experimento de los cubos con los datos originales
2. Actividades realizadas en este periodo:
 - a. Avanzar con la sección del estado del arte del artículo
 - b. Correr el experimento de los cubos con los datos originales
3. Actividades realizadas en este periodo, que no estaban planeadas:
 - a. Ninguna
4. Actividades que quedaron pendientes para el próximo periodo:
 - a. Ninguna
5. Actividades por hacer el próximo periodo
 - a. Actualizar los gráficos del experimento de los cubos y plasmar los resultados en el artículo

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
PERSONA FÍSICA, CPF-03-0338-0003.
Fecha declarada: 07/10/2024 06:11:45 p. m.
Razón: Documento aprobado
Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa
Profesor Asesor



David Pastor Barrientos
Estudiante

12.12. Semana 12

Minuta de Reunión 12

Información General	
Fecha: 07 de Octubre del 2024	Hora: 6:00 pm
Inicio: 6:10 pm	Duración: 35 minutos
Finalización: 6:45 pm	

Participantes	
Nombre Completo	Cargo
Ing. Eduardo Canessa	Profesor Asesor
José Alberto Arce Morales	Estudiante
Jonathan David Pastor Barrientos	Estudiante

Temas Tratados

1. Saludo.
2. Se mencionaron los avances semanales de cada estudiante.
3. Se revisaron los avances realizados en el segundo informe con respecto a la sección de metodología de la investigación y de resultados.
4. Se mencionó el trabajo pendiente que hace falta para terminar con lo estipulado en el plan de trabajo.
5. Se recordaron las fechas de los siguientes informes y presentaciones, así como la información que hace falta completar del informe.
6. Se mencionó la información que deben incluir las presentaciones del segundo y tercer informe.
7. Se mencionó el contenido que debe incluir el tercer informe.

Compromisos Asumidos	
Descripción	Responsable
Documentos Firmados	Eduardo Canessa
Completar la información que hace falta del segundo informe	José Arce David Pastor
Preparar la presentación del segundo informe	José Arce
Próxima Reunión	14 de Octubre del 2024

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
PERSONA FÍSICA, CPF-03-0338-0003
Fecha declarada: 14/10/2024 06:07:25 p. m.
Razón: Documento aprobado
Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa
Profesor Asesor

José Arce Morales
Estudiante

David Pastor Barrientos
Estudiante

Informe de Avance Semanal 12

Nombre: José Alberto Arce Morales

Periodo del: 07 de Octubre del 2024 al 14 de Octubre del 2024

1. Actividades planeadas en este periodo:
 - a. Trasladar todos los nuevos resultados de las 30x30 iteraciones al artículo.
2. Actividades realizadas en este periodo:
 - a. Trasladar todos los nuevos resultados de las 30x30 iteraciones al artículo.
3. Actividades realizadas en este periodo, que no estaban planeadas:
 - a. Ninguna
4. Actividades que quedaron pendientes para el próximo periodo:
 - a. Ninguna.
5. Actividades por hacer el próximo periodo
 - a. Optimizar el código que genera la estimación de incertidumbre para FD.

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
PERSONA FISICA, CPF-03-0338-0003.
Fecha declarada: 14/10/2024 06:09:11 p. m.
Razón: Documento aprobado
Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa

Profesor Asesor



José Arce Morales

Estudiante

Informe de Avance Semanal 9

Nombre: Jonathan David Pastor Barrientos

Periodo del: 7 de Octubre del 2024 al 14 de Octubre del 2024

1. Actividades planeadas en este periodo:
 - a. Actualizar los gráficos del experimento de los cubos y plasmar los resultados en el artículo
2. Actividades realizadas en este periodo:
 - a. Actualizar los gráficos del experimento de los cubos y plasmar los resultados en el artículo
3. Actividades realizadas en este periodo, que no estaban planeadas:
 - a. Ninguna
4. Actividades que quedaron pendientes para el próximo periodo:
 - a. Ninguna
5. Actividades por hacer el próximo periodo:
 - a. Diseñar la implementación de redes neuronales para la estimación de incertidumbre

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
PERSONA FISICA, CPF-03-0338-0003.
Fecha declarada: 14/10/2024 06:08:19 p. m.
Razón: Documento aprobado
Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa
Profesor Asesor



David Pastor Barrientos
Estudiante

12.13. Semana 13

En esta semana se realizó la revisión del segundo informe para José Arce.



Visita del Profesor Asesor #3

Información General	
Fecha: 17 de Octubre del 2024	Hora: 9:30 am
Inicio: 9:35 am	Duración: 25 minutos
Finalización: 10:00 am	

Tipo de Reunión	
☐ Presencial	☐ Telefónica
☒ Chat - Videoconferencia	☐ Otro Especifique:

Participantes	
Nombre Completo	Cargo
Ing. Eduardo Canessa	Profesor Asesor
Sergio Arguedas Cuendis	Supervisor
José Alberto Arce Morales	Estudiante

Temas Tratados

1. Saludo.
2. Se realizó la presentación del segundo informe por parte de José Arce.
3. Se realiza una sección de preguntas y dudas con respecto a la presentación.
4. Se menciona al supervisor la evaluación por medio de la rúbrica enviada.
5. Y se recuerda la convocatoria para la última presentación en la semana 16.

Compromisos Asumidos	
Descripción	Responsable
Visita firmada	Eduardo Canessa

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
 PERSONA FÍSICA, CPF-03-0338-0003.
 Fecha declarada: 21/10/2024 04:58:14 p. m.
 Razón: Documento aprobado
 Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa
 Profesor Asesor

José Arce Morales
 Estudiante

Minuta de Reunión 13

Información General	
Fecha: 14 de Octubre del 2024	Hora: 6:00 pm
Inicio: 6:05 pm	Duración: 45 minutos
Finalización: 6:45pm	

Participantes	
Nombre Completo	Cargo
Ing. Eduardo Canessa	Profesor Asesor
José Alberto Arce Morales	Estudiante
Jonathan David Pastor Barrientos	Estudiante

Temas Tratados

1. Saludo.
2. Se discutió el avance general de la semana de cada uno.
3. Se finalizó la revisión de la sección 5. Metodología de la investigación.
4. Se hizo la revisión final general del informe número 2 para la entrega de José Arce.
5. Se revisó la presentación del informe número 2 de José Arce.
6. Se revisó el formato para el informe número 3 de ambos.

Compromisos Asumidos	
Descripción	Responsable
Documentos Firmados	Eduardo Canessa
Inicio de las nuevas secciones para el tercer informe.	José Arce David Pastor
Próxima Reunión	21 de Octubre de 2024

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
PERSONA FÍSICA, CPF-03-0338-0003.
Fecha declarada: 21/10/2024 05:00:31 p. m.
Razón: Documento aprobado
Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa
Profesor Asesor



David Pastor
Estudiante



José Arce Morales
Estudiante

Informe de Avance Semanal 13

Nombre: José Alberto Arce Morales

Periodo del: 14 de Octubre del 2024 al 21 de Octubre del 2024

1. Actividades planeadas en este periodo:
 - a. Optimizar el código que genera la estimación de incertidumbre para FD.
2. Actividades realizadas en este periodo:
 - a. Avance en la optimización el código que genera la estimación de incertidumbre para FD.
3. Actividades realizadas en este periodo, que no estaban planeadas:
 - a. Avance de calibración de Features Densities
4. Actividades que quedaron pendientes para el próximo periodo:
 - a. Continuar con la optimización de Features Densities.
5. Actividades por hacer el próximo periodo
 - a. Calibración los métodos de estimación de incertidumbre Monte Carlo Dropout y Feature Densities.

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
PERSONA FISICA, CPF-03-0338-0003.
Fecha declarada: 21/10/2024 04:57:23 p. m.
Razón: Documento aprobado
Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa

Profesor Asesor



José Arce Morales

Estudiante

Informe de Avance Semanal 10

Nombre: Jonathan David Pastor Barrientos

Periodo del: 14 de Octubre del 2024 al 21 de Octubre del 2024

1. Actividades planeadas en este periodo:
 - a. Diseñar la implementación de redes neuronales para la estimación de incertidumbre.
2. Actividades realizadas en este periodo:
 - a. Ninguna
3. Actividades realizadas en este periodo, que no estaban planeadas:
 - a. Modificación de los títulos y datos utilizados para la generación de los gráficos de los cubos.
 - b. Avance de calibración de Monte Carlo Dropout
4. Actividades que quedaron pendientes para el próximo periodo:
 - a. Diseñar la implementación de redes neuronales para la estimación de incertidumbre.
5. Actividades por hacer el próximo periodo
 - a. Calibración y optimización de los métodos de estimación de incertidumbre monte carlo Dropout y Feature Densities.

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
PERSONA FISICA, CPF-03-0338-0003.
Fecha declarada: 21/10/2024 04:59:20 p. m.
Razón: Documento aprobado
Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa

Profesor Asesor



David Pastor Barrientos

Estudiante

Minuta de Reunión 14

Información General	
Fecha: 21 de Octubre del 2024	Hora: 6:00 pm
Inicio: 6:00 pm	Duración: 15 minutos
Finalización: 6:15 pm	

Participantes	
Nombre Completo	Cargo
Ing. Eduardo Canessa	Profesor Asesor
José Alberto Arce Morales	Estudiante
Jonathan David Pastor Barrientos	Estudiante

Temas Tratados

1. Saludo.
2. Se mencionaron los avances semanales de cada estudiante.
3. Se recordaron las fechas de los siguientes informes y presentaciones.
4. Se revisaron los avances en la sección de resultados del informe

Compromisos Asumidos	
Descripción	Responsable
Documentos Firmados	Eduardo Canessa
Completar la información que hace falta para el tercer informe	José Arce
Preparar la presentación del segundo informe	David Pastor
Próxima Reunión	28 de Octubre del 2024

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
 PERSONA FISICA, CPF-03-0338-0003.
 Fecha declarada: 28/10/2024 06:01:57 p. m.
 Razón: Documento aprobado
 Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa
 Profesor Asesor



José Arce Morales
 Estudiante



David Pastor Barrientos
 Estudiante

Informe de Avance Semanal 14

Nombre: José Alberto Arce Morales

Periodo del: 21 de Octubre del 2024 al 28 de Octubre del 2024

1. Actividades planeadas en este periodo:
 - a. Continuar con la optimización de Features Densities.
 - b. Calibración los métodos de estimación de incertidumbre Monte Carlo Dropout y Feature Densities.
2. Actividades realizadas en este periodo:
 - a. Continuar con la optimización de Features Densities.
 - b. Calibración los métodos de estimación de incertidumbre Monte Carlo Dropout y Feature Densities.
3. Actividades realizadas en este periodo, que no estaban planeadas:
 - a. Ninguna.
4. Actividades que quedaron pendientes para el próximo periodo:
 - a. Ninguna.
5. Actividades por hacer el próximo periodo
 - a. Medir los tiempos de ejecución de ambos métodos.
 - b. Realizar cambios con respecto a los gráficos de la eficiencia.

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
PERSONA FISICA, CPF-03-0338-0003.
Fecha declarada: 28/10/2024 06:02:44 p. m.
Razón: Documento aprobado
Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa

Profesor Asesor



José Arce Morales

Estudiante

Informe de Avance Semanal 11


Nombre: Jonathan David Pastor Barrientos

Periodo del: 21 de Octubre del 2024 al 28 de Octubre del 2024

1. Actividades planeadas en este periodo:
 - a. Calibración y optimización de los métodos de estimación de incertidumbre Monte Carlo Dropout y Feature Densities.
2. Actividades realizadas en este periodo:
 - a. Calibración y optimización de los métodos de estimación de incertidumbre Monte Carlo Dropout y Feature Densities.
3. Actividades realizadas en este periodo, que no estaban planeadas:
 - a. Ninguna
4. Actividades que quedaron pendientes para el próximo periodo:
 - a. Diseñar la implementación de redes neuronales de intervalos para la estimación de incertidumbre.
5. Actividades por hacer el próximo periodo
 - a. Medir el tiempo de ejecución de Monte Carlo Dropout y Feature Densities

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
PERSONA FÍSICA, CPF-03-0338-0003.
Fecha declarada: 28/10/2024 06:03:53 p. m.
Razón: Documento aprobado
Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa
Profesor Asesor



David Pastor Barrientos
Estudiante

12.15. Semana 15

En esta semana se realizó la revisión del segundo informe para David Pastor



Visita del profesor Asesor #3

Información General	
Fecha: 31 de Octubre del 2024	Hora: 9:30 am
Inicio: 9:40 am	Duración: 60 minutos
Finalización: 10:40 am	

Tipo de Reunión	
☐ Presencial	☐ Telefónica
☒ Chat - Videoconferencia	☐ Otro Especifique: _____

Participantes	
Nombre Completo	Cargo
Ing. Eduardo Canessa	Profesor Asesor
Saul Calderón Ramírez	Supervisor
Sergio Arguedas Cuendis	Supervisor
Jonathan David Pastor Barrientos	Estudiante
José Alberto Arce Morales	Estudiante
Esteban villalobos	Estudiante
Fernando Ugalde	Estudiante

Temas Tratados

1. Saludo.
2. Presentación del segundo informe por parte de David Pastor.
3. Preguntas, comentarios y dudas respecto a la presentación por parte de los supervisores.
4. Se mencionó el trabajo que falta por realizar para culminar la práctica profesional.
5. Se solicitó y confirmó el cambio de un objetivo específico por el hecho de que no va a alcanzar el tiempo para poder completarlo.
6. Se confirmó la fecha de presentación del informe final de David Pastor

Compromisos Asumidos	
Descripción	Responsable
Visita firmada	Eduardo Canessa

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
 PERSONA FISICA, CPF-03-0338-0003.
 Fecha declarada: 06/11/2024 10:19:46 a. m.
 Razón: Documento aprobado
 Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa
 Profesor Asesor

David Pastor Barrientos
 Estudiante

Minuta de Reunión 15

Información General	
Fecha: 28 de Octubre del 2024	Hora: 6:00 pm
Inicio: 6:05 pm	Duración: 45 minutos
Finalización: 6:45pm	

Participantes	
Nombre Completo	Cargo
Ing. Eduardo Canessa	Profesor Asesor
José Alberto Arce Morales	Estudiante
Jonathan David Pastor Barrientos	Estudiante

Temas Tratados

1. Saludo.
2. Se discutió el avance general de la semana de cada uno.
3. Se revisó el avance de la sección de conclusiones y recomendaciones.
4. Se debe consultar en la biblioteca el trámite para subir el documento final.
5. Se debe subir solo un informe a la biblioteca y la nota será otorgada hasta que se compruebe que se subió a la plataforma.
6. Se debe realizar el corte del informe y la presentación del informe número 3 de José Arce.
7. Ambos deben agendar la cita del informe 3, David debe hablar con profesor Saúl Calderón para poder realizar la presentación del informe 3 a más tardar el 26 de noviembre.

Compromisos Asumidos	
Descripción	Responsable
Documentos Firmados	Eduardo Canessa
Consultar sobre el proceso para subir el documento al sistema de la biblioteca	José Arce David Pastor

Finalizar el informe y presentación del informe 3	José Arce
Agendar la cita del tercer informe	José Arce David Pastor
Próxima Reunión	06 de Noviembre de 2024

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
PERSONA FÍSICA, CPF-03-0338-0003.
Fecha declarada: 06/11/2024 10:18:08 a. m.
Razón: Documento aprobado
Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa

Profesor Asesor



David Pastor

Estudiante



José Arce Morales

Estudiante

Informe de Avance Semanal 15

Nombre: José Alberto Arce Morales

Periodo del: 28 de Octubre del 2024 al 4 de Noviembre del 2024

1. Actividades planeadas en este periodo:
 - a. Medir los tiempos de ejecución de ambos métodos.
 - b. Realizar cambios con respecto a los gráficos de la eficiencia.
2. Actividades realizadas en este periodo:
 - a. Medir los tiempos de ejecución de ambos métodos.
3. Actividades realizadas en este periodo, que no estaban planeadas:
 - a. Realizar la optimización de FD utilizando histogramas para aproximar las funciones de verosimilitud
4. Actividades que quedaron pendientes para el próximo periodo:
 - a. Cambios con respecto a los gráficos de la eficiencia.
5. Actividades por hacer el próximo periodo
 - a. Continuar con los cambios con respecto a los gráficos de la eficiencia.

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
PERSONA FISICA, CPF-03-0338-0003.
Fecha declarada: 06/11/2024 10:17:11 a. m.
Razón: Documento aprobado
Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa

Profesor Asesor



José Arce Morales

Estudiante

Informe de Avance Semanal 12

Nombre: Jonathan David Pastor Barrientos

Periodo del: 28 de Octubre del 2024 al 1 de Noviembre del 2024

1. Actividades planeadas en este periodo:
 - a. Medir el tiempo de ejecución de Monte Carlo Dropout y Feature Densities
2. Actividades realizadas en este periodo:
 - a. Medir el tiempo de ejecución de Monte Carlo Dropout y Feature Densities
3. Actividades realizadas en este periodo, que no estaban planeadas:
 - a. Cambiar el método de KDE en la inferencia de Feature Densities por el uso de un histograma con la población.
4. Actividades que quedaron pendientes para el próximo periodo:
 - a. Ninguna
5. Actividades por hacer el próximo periodo:
 - a. Asistencia al 26th ACM International Conference on Multimodal Interaction (ICMI)

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
PERSONA FISICA, CPF-03-0338-0003.
Fecha declarada: 06/11/2024 10:13:55 a. m.
Razón: Documento aprobado
Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa

Profesor Asesor



David Pastor Barrientos

Estudiante

12.16. Semana 16

En esta semana se realizó la revisión del tercer informe para José Arce.



Visita del Profesor Asesor #4

Información General	
Fecha: 07 de Noviembre del 2024	Hora: 9:30 am
Inicio: 9:32 am	Duración: 30 minutos
Finalización: 10:02 am	

Tipo de Reunión	
☐ Presencial	☐ Telefónica
☒ Chat - Videoconferencia	☐ Otro Especifique:

Participantes	
Nombre Completo	Cargo
Ing. Eduardo Canessa	Profesor Asesor
Sergio Arguedas Cuendis	Supervisor
José Alberto Arce Morales	Estudiante

Temas Tratados

1. Saludo.
2. Se realizó la presentación del tercer informe por parte de José Arce.
3. Se realiza una sección de preguntas y dudas con respecto a la presentación.
4. Se realiza un cierre final acerca del proceso y experiencia del tiempo de práctica.

Compromisos Asumidos	
Descripción	Responsable
Visita firmada	Eduardo Canessa

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
 PERSONA FISICA, CPF-03-0338-0003.
 Fecha declarada: 11/11/2024 05:29:08 p. m.
 Razón: Documento aprobado
 Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa
 Profesor Asesor


 José Arce Morales
 Estudiante

Minuta de Reunión 16

Información General	
Fecha: 6 de Noviembre del 2024	Hora: 10:00 pm
Inicio: 10:05 pm	Duración: 1 hora y 5 minutos
Finalización: 11:05pm	


Participantes	
Nombre Completo	Cargo
Ing. Eduardo Canessa	Profesor Asesor
José Alberto Arce Morales	Estudiante
Jonathan David Pastor Barrientos	Estudiante

Temas Tratados

1. Saludo.
2. Se discutió sobre el formato del documento para entregar a la biblioteca. Añadir el acta de aprobación de práctica, además, añadir al pie de página los conceptos en inglés.
3. Se revisó los cambios finales al informe 3 de José Arce.
4. Se revisó la presentación final de José Arce.

Compromisos Asumidos	
Descripción	Responsable
Documentos Firmados	Eduardo Canessa
Realizar los cambios para el formato del documento.	José Arce David Pastor
Trabajar sobre los cambios del informe 3	David Pastor
Próxima Reunión	11 de Noviembre de 2024

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
PERSONA FÍSICA, CPF-03-0338-0003.
Fecha declarada: 11/11/2024 05:28:19 p. m.
Razón: Documento aprobado
Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa
Profesor Asesor

David Pastor
Estudiante

José Arce Morales
Estudiante

Informe de Avance Semanal 16

Nombre: José Alberto Arce Morales

Periodo del: 4 de Noviembre del 2024 al 11 de Noviembre del 2024

1. Actividades planeadas en este periodo:
 - a. Continuar con los cambios con respecto a los gráficos de la eficiencia.
2. Actividades realizadas en este periodo:
 - a. Inició con los cambios en los gráficos de eficiencia.
3. Actividades realizadas en este periodo, que no estaban planeadas:
 - a. Realizar la comparación de optimización de FD.
4. Actividades que quedaron pendientes para el próximo periodo:
 - a. Finalizar los gráficos de eficiencia.
5. Actividades por hacer el próximo periodo:
 - a. Ninguna

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
PERSONA FISICA, CPF-03-0338-0003.
Fecha declarada: 11/11/2024 05:25:50 p. m.
Razón: Documento aprobado
Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa

Profesor Asesor



José Arce Morales

Estudiante

Informe de Avance Semanal 13

Nombre: Jonathan David Pastor Barrientos

Periodo del: 4 de Noviembre del 2024 al 8 de Noviembre del 2024

1. Actividades planeadas en este periodo:
 - a. Asistencia al 26th ACM International Conference on Multimodal Interaction (ICMI)
2. Actividades realizadas en este periodo:
 - a. Asistencia al 26th ACM International Conference on Multimodal Interaction (ICMI)
3. Actividades realizadas en este periodo, que no estaban planeadas:
 - a. Ninguna
4. Actividades que quedaron pendientes para el próximo periodo:
 - a. Ninguna
5. Actividades por hacer el próximo periodo:
 - a. Implementar gráficos de eficiencia para los métodos de Feature Densities y Monte Carlo Dropout

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
PERSONA FISICA, CPF-03-0338-0003.
Fecha declarada: 11/11/2024 05:27:26 p. m.
Razón: Documento aprobado
Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa

Profesor Asesor



David Pastor Barrientos

Estudiante

12.17. Semana 17

Minuta de Reunión 17

Información General	
Fecha: 11 de Noviembre del 2024	Hora: 5:35 pm
Inicio: 5:35 pm	Duración: 15 minutos
Finalización: 5:50 pm	

Participantes	
Nombre Completo	Cargo
Ing. Eduardo Canessa	Profesor Asesor
José Alberto Arce Morales	Estudiante
Jonathan David Pastor Barrientos	Estudiante

Temas Tratados


1. Saludo.
2. Se definieron las fechas de entrega del tercer informe y defensa de este.
3. Se especificaron los contenidos de la presentación del tercer informe.
4. Se recordaron las secciones del tercer informe que hacen falta de completar.
5. Se debe obtener una licencia de Creative Commons para ponerla en el informe.
6. Se mencionó la forma en la que se debe subir el informe, tanto para la biblioteca como para el tec digital.

Compromisos Asumidos	
Descripción	Responsable
Documentos Firmados	Eduardo Canessa
Completar la información que hace falta para el tercer informe	José Arce David Pastor
Preparar la presentación del tercer informe	David Pastor
Próxima Reunión	18 de Noviembre del 2024

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
PERSONA FISICA, CPF-03-0338-0003.
Fecha declarada: 18/11/2024 04:08:30 p. m.
Razón: Documento aprobado
Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa
Profesor Asesor


José Arce Morales
Estudiante


David Pastor Barrientos
Estudiante

Informe de Avance Semanal 14

Nombre: Jonathan David Pastor Barrientos

Periodo del: 11 de Noviembre del 2024 al 18 de Noviembre del 2024

1. Actividades planeadas en este periodo:
 - a. Lectura y comprensión del código de los gráficos de eficiencia actuales.
 - b. Implementar gráficos de eficiencia para los métodos de Feature Densities y Monte Carlo Dropout.
2. Actividades realizadas en este periodo:
 - a. Lectura y comprensión del código de los gráficos de eficiencia actuales.
3. Actividades realizadas en este periodo, que no estaban planeadas:
 - a. Ninguna
4. Actividades que quedaron pendientes para el próximo periodo:
 - a. Implementar gráficos de eficiencia para los métodos de Feature Densities y Monte Carlo Dropout.
5. Actividades por hacer el próximo periodo
 - a. Preparar presentación para el CERN.
 - b. Preparar material para el workshop.

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
PERSONA FISICA, CPF-03-0338-0003.
Fecha declarada: 18/11/2024 04:21:55 p. m.
Razón: Documento aprobado
Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa

Profesor Asesor



David Pastor Barrientos

Estudiante

12.18. Semana 18

En esta semana se realizó la revisión del informe final para David Pastor.



Visita del profesor Asesor #4

Información General	
Fecha: 25 de Noviembre del 2024	Hora: 9:30 am
Inicio: 9:40 am	Duración: 50 minutos
Finalización: 10:30 am	

Tipo de Reunión	
☐ Presencial	☐ Telefónica
☒ Chat - Videoconferencia	☐ Otro Especifique:

Participantes	
Nombre Completo	Cargo
Ing. Eduardo Canessa	Profesor Asesor
Saul Calderón Ramírez	Supervisor
Sergio Arguedas Cuendis	Supervisor
Jonathan David Pastor Barrientos	Estudiante

Temas Tratados

1. Saludo.
2. Presentación del informe final por parte de David Pastor.
3. Preguntas, comentarios y dudas respecto a la presentación por parte de los supervisores.
4. Se discutió trabajo futuro que puede ser realizado con base en el trabajo realizado por David Pastor

Compromisos Asumidos	
Descripción	Responsable
Visita firmada	Eduardo Canessa

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
 PERSONA FISICA, CPF-03-0338-0003.
 Fecha declarada: 25/11/2024 01:14:53 p. m.
 Razón: Documento aprobado
 Lugar: Heredia Contacto: edcanessa@itor.ac.cr

Ing. Eduardo Canessa
 Profesor Asesor

David Pastor Barrientos
 Estudiante

Minuta de Reunión 18

Información General	
Fecha: 18 de Noviembre del 2024	Hora: 4:10 pm
Inicio: 4:10 pm	Duración: 40 minutos
Finalización: 4:50 pm	

Participantes	
Nombre Completo	Cargo
Ing. Eduardo Canessa	Profesor Asesor
José Alberto Arce Morales	Estudiante
Jonathan David Pastor Barrientos	Estudiante

Temas Tratados


1. Saludo.
2. Se revisaron los cambios finales realizados al tercer informe.
3. Se recordaron los requisitos que se deben cumplir para entregar el tercer informe a la biblioteca.
4. Se revisó la presentación del informe final de David Pastor
5. Se definieron fechas para la entrega del informe final y la presentación de esta.

Compromisos Asumidos	
Descripción	Responsable
Documentos Firmados.	Eduardo Canessa
Completar los requisitos que pide la biblioteca para la entrega del informe final.	José Arce David Pastor
Próxima Reunión	25 de Noviembre del 2024

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
PERSONA FISICA, CPF-03-0338-0003.
Fecha declarada: 25/11/2024 01:16:51 p. m.
Razón: Documento aprobado
Lugar: Heredia Contacto: edcanessa@itcr.ac.cr


Ing. Eduardo Canessa

Profesor Asesor



José Arce Morales

Estudiante



David Pastor Barrientos

Estudiante

Informe de Avance Semanal 15

Nombre: Jonathan David Pastor Barrientos

Periodo del: 18 de Noviembre del 2024 al 25 de Noviembre del 2024

1. Actividades planeadas en este periodo:
 - a. Implementar gráficos de eficiencia para los métodos de Feature Densities y Monte Carlo Dropout.
 - b. Preparar presentación para el CERN.
 - c. Preparar material para el workshop.
2. Actividades realizadas en este periodo:
 - a. Implementar gráficos de eficiencia para los métodos de Feature Densities y Monte Carlo Dropout.
 - b. Preparar presentación para el CERN.
 - c. Preparar material para el workshop.
3. Actividades realizadas en este periodo, que no estaban planeadas:
 - a. Ninguna
4. Actividades que quedaron pendientes para el próximo periodo:
 - a. Ninguna
5. Actividades por hacer el próximo periodo:
 - a. Ninguna

EDUARDO ADOLFO CANESSA MONTERO (FIRMA)
PERSONA FÍSICA, CPF-03-0338-0003.
Fecha declarada: 25/11/2024 01:13:09 p. m.
Razón: Documento aprobado
Lugar: Heredia Contacto: edcanessa@itcr.ac.cr

Ing. Eduardo Canessa

Profesor Asesor



David Pastor Barrientos

Estudiante

13.Evaluaciones

1. Primera Evaluación

NOMBRE ESTUDIANTE	EMPRESA	EVALUADOR	FECHA
JOSE ARCE MORALES	PARMA	SERGIO ARGUEDAS CUENDIS	20/09/2024

Criterios básicos de evaluación por parte de la Empresa

EVALUACIÓN #:

€ No. 1 X € No. 2 € No.3

Criterios

A. ASPECTOS GENERALES

● Nivel de responsabilidad

● Puntualidad

● Cumplimiento de las normas de la organización

● Relaciones interpersonales y de comunicación

● Otros: _____

B. ACERCA DEL TRABAJO REALIZADO A LA FECHA (40% de 40%)

● Cumplimiento del cronograma y de las metas establecidas

● Cumplimiento de objetivos

● Calidad de sus aportes

● Resolución de problemas mediante metodologías adecuadas y de un proceso ingenieril

● Calidad del conocimiento técnico

● Disposición para aprender

● Otros: _____

C. ASPECTOS ACERCA DEL INFORME No. ____ (40% de 40%)

● Formato del informe

● Completitud del informe

● Redacción del informe

● Claridad

● Calidad de los productos generados a la fecha

● Otros: _____

Observaciones:

NOTA TOTAL: 100

FIRMA: 



Escuela de Computación
Bachillerato en Ingeniería en Computación, Sede Central
Curso: IC-8842 Práctica Profesional

Criterios básicos de evaluación por parte de la Empresa

NOMBRE ESTUDIANTE	EMPRESA	EVALUADOR	FECHA
DAVID PASTOR	PARMA-CERN	SAUL CALDERON RAMIREZ	03/10/2024

EVALUACIÓN #:

☒ **No. 1**

☐ **No. 2**

☐ **No.3**

Criterios

A. ASPECTOS GENERALES

- Nivel de responsabilidad
- Puntualidad
- Cumplimiento de las normas de la organización
- Relaciones interpersonales y de comunicación
- Otros: _____

Porcentaje total asignado
(_20_ % de 20%)

B. ACERCA DEL TRABAJO REALIZADO A LA FECHA

(_40_ % de 40%)

- Cumplimiento del cronograma y de las metas establecidas
- Cumplimiento de objetivos
- Calidad de sus aportes
- Resolución de problemas mediante metodologías adecuadas y de un proceso ingenieril
- Calidad del conocimiento técnico
- Disposición para aprender
- Otros: _____

C. ASPECTOS ACERCA DEL INFORME No. ____

(_40_ % de 40%)

- Formato del informe
- Completitud del informe
- Redacción del informe
- Claridad
- Calidad de los productos generados a la fecha
- Otros: _____

Observaciones: Excelente trabajo de parte de David.


NOTA TOTAL: _100_

FIRMA: _____

Saul Calderon N.



2. Segunda Evaluación



Escuela de Computación
Bachillerato en Ingeniería en Computación, Centro Académico San
José
Curso: IC-8842 Práctica Profesional

Criterios básicos de evaluación por parte de la Empresa

NOMBRE ESTUDIANTE	EMPRESA	EVALUADOR	FECHA
JOSE ARCE MORALES	PARMA	SERGIO ARGUEDAS CUENDIS	17/10/2024

EVALUACIÓN #:

€ No. 1

€ No. 2 X

€ No.3

Criterios

A. ASPECTOS GENERALES

- Nivel de responsabilidad
- Puntualidad
- Cumplimiento de las normas de la organización
- Relaciones interpersonales y de comunicación
- Otros: _____

Porcentaje total asignado
(20% de 20%)

B. ACERCA DEL TRABAJO REALIZADO A LA FECHA

(40% de 40%)

- Cumplimiento del cronograma y de las metas establecidas
- Cumplimiento de objetivos
- Calidad de sus aportes
- Resolución de problemas mediante metodologías adecuadas y de un proceso ingenieril
- Calidad del conocimiento técnico
- Disposición para aprender
- Otros: _____



C. ASPECTOS ACERCA DEL INFORME No. ____

(40% de 40%)

- Formato del informe
- Completitud del informe
- Redacción del informe
- Claridad
- Calidad de los productos generados a la fecha
- Otros: _____

Observaciones:

NOTA TOTAL: 100

FIRMA: _____

**Escuela de Computación
Bachillerato en Ingeniería en Computación, Sede Central
Curso: IC-8842 Práctica Profesional**

Criterios básicos de evaluación por parte de la Empresa

NOMBRE ESTUDIANTE	EMPRESA	EVALUADOR	FECHA
DAVID PASTOR	PARMA/CERN	SAUL CALDERON RAMIREZ	31/10/2024

EVALUACIÓN #:

☐ No. 1

☒ No. 2

☐ No.3

Criterios

A. ASPECTOS GENERALES

Porcentaje total asignado
(__20__ % de 20%)

- Nivel de responsabilidad
- Puntualidad
- Cumplimiento de las normas de la organización
- Relaciones interpersonales y de comunicación
- Otros: _____

B. ACERCA DEL TRABAJO REALIZADO A LA FECHA

(__40__ % de 40%)

- Cumplimiento del cronograma y de las metas establecidas
- Cumplimiento de objetivos
- Calidad de sus aportes
- Resolución de problemas mediante metodologías adecuadas y de un proceso ingenieril
- Calidad del conocimiento técnico
- Disposición para aprender
- Otros: _____

C. ASPECTOS ACERCA DEL INFORME No. ____

(__40__ % de 40%)

- Formato del informe
- Completitud del informe
- Redacción del informe
- Claridad
- Calidad de los productos generados a la fecha
- Otros: _____

Observaciones: EXCELENTE TRABAJO DE DAVID


NOTA TOTAL: __100__

FIRMA:

Saul Calderon Ramirez



3. Tercera Evaluación



Escuela de Computación
Bachillerato en Ingeniería en Computación, Centro Académico San
José
Curso: IC-8842 Práctica Profesional

Criterios básicos de evaluación por parte de la Empresa

NOMBRE ESTUDIANTE	EMPRESA	EVALUADOR	FECHA
JOSE ARCE MORALES	PARMA	SERGIO ARGUEDAS CUENDIS	08/11/2024

EVALUACIÓN #:

€ No. 1

€ No. 2

€ No.3 X

Criterios

A. ASPECTOS GENERALES

Porcentaje total asignado
(20% de 20%)

- Nivel de responsabilidad
- Puntualidad
- Cumplimiento de las normas de la organización
- Relaciones interpersonales y de comunicación
- Otros: _____

B. ACERCA DEL TRABAJO REALIZADO A LA FECHA

(40% de 40%)

- Cumplimiento del cronograma y de las metas establecidas
- Cumplimiento de objetivos
- Calidad de sus aportes
- Resolución de problemas mediante metodologías adecuadas y de un proceso ingenieril
- Calidad del conocimiento técnico
- Disposición para aprender
- Otros: _____



C. ASPECTOS ACERCA DEL INFORME No. ____

(40% de 40%)

- Formato del informe
- Completitud del informe
- Redacción del informe
- Claridad
- Calidad de los productos generados a la fecha
- Otros: _____

Observaciones:

NOTA TOTAL: 100

FIRMA:

**Escuela de Computación
Bachillerato en Ingeniería en Computación, Sede Central
Curso: IC-8842 Práctica Profesional**

Criterios básicos de evaluación por parte de la Empresa

NOMBRE ESTUDIANTE	EMPRESA	EVALUADOR	FECHA
David Pastor Barrientos	CERN/PARMA	Saul Calderón Ramírez	25/11/2024

EVALUACIÓN #:

☐ No. 1

☐ No. 2

☒ No.3

Criterios

A. ASPECTOS GENERALES

- Nivel de responsabilidad
- Puntualidad
- Cumplimiento de las normas de la organización
- Relaciones interpersonales y de comunicación
- Otros: _____

Porcentaje total asignado

(__20__ % de 20%)

B. ACERCA DEL TRABAJO REALIZADO A LA FECHA

(__40__ % de 40%)

- Cumplimiento del cronograma y de las metas establecidas
- Cumplimiento de objetivos
- Calidad de sus aportes
- Resolución de problemas mediante metodologías adecuadas y de un proceso ingenieril
- Calidad del conocimiento técnico
- Disposición para aprender
- Otros: _____

C. ASPECTOS ACERCA DEL INFORME No. ____

(__40__ % de 40%)

- Formato del informe
- Completitud del informe
- Redacción del informe
- Claridad
- Calidad de los productos generados a la fecha
- Otros: _____

Observaciones:

NOTA TOTAL: _100_____

FIRMA: _____

Saul Calderón



14. Anexo 1

Hoja de Información

Información del estudiante 1:

Nombre: José Alberto Arce Morales

Cédula o No. Pasaporte: 118090034

Carné ITCR: 2020316685

Dirección de su residencia en época lectiva: San Isidro, Heredia

Dirección de su residencia en época no lectiva: San Isidro, Heredia

Teléfono en época lectiva: 88011253

Teléfono época no lectiva: 88011253

Email: josearce@estudiantec.cr

Fax: N/A

Información del estudiante 2:

Nombre: Jonathan David Pastor Barrientos

Cédula o No. Pasaporte: 118560169

Carné ITCR: 2020023569

Dirección de su residencia en época lectiva: Zapote, San José

Dirección de su residencia en época no lectiva: Zapote, San José

Teléfono en época lectiva: 71621520

Teléfono época no lectiva: 71621520

Email: davidpastorb@estudiantec.cr

Fax: N/A

Información del Proyecto:

Nombre del Proyecto: Estimación de Incertidumbre de redes generativas antagónicas (GAN) para simular datos del detector de partículas del Cherenkov de imágenes de anillo (RICH)

Profesor Asesor: Sergio Arguedas Cuendis / Saúl Calderón Ramírez

Horario de trabajo del estudiante: 8am-5pm

Información de la Empresa: El CERN es una organización internacional dedicada a la investigación científica avanzada, enfocada en entender los componentes básicos del universo. Es conocido por sus experimentos de física de partículas y el desarrollo de tecnologías innovadoras.

Nombre: CERN

Dirección: Suiza

Teléfono: N/A

Fax: N/A

Apartado: N/A

Actividad Principal: Investigación